



دانشگاه گوارزی و منابع طبیعی

نشریه پژوهش‌های حفاظت آب و خاک

جلد بیست و دوم، شماره دوم، ۱۳۹۴

<http://jwsc.gau.ac.ir>

مقایسه روش‌های هوش مصنوعی در برآورد بار معلق رسوب (مطالعه موردی: رودخانه سیستان)

زینب شیخعلی پور^۱، *فرزاد حسن پور^۲ و وحید عظیمی^۳

^۱دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه زابل، آستادیار گروه مهندسی آب، دانشگاه زابل،

^۲دانش آموخته کارشناسی ارشد گروه مهندسی آب، دانشگاه تبریز

تاریخ دریافت: ۹۲/۶/۲۹؛ تاریخ پذیرش: ۹۳/۲/۲۰

چکیده

سابقه و هدف: برآورد صحیح حجم رسوبات معلق در رودخانه‌ها، یکی از مهم‌ترین مسائل در پروژه‌های مهندسی رودخانه، منابع آب و محیط زیست می‌باشد. رودخانه سیستان شاخه اصلی منشعب از رودخانه هیرمند بوده که وظیفه آبیاری ۷۰ درصد زمین‌های کشاورزی دشت سیستان و همچنین تأمین بخشی از آب هامون هیرمند را به عهده دارد. با توجه به مشکلات زیاد ناشی از رسوبات در رودخانه‌ها، پژوهشگران علم رسوب تلاش‌های زیادی به منظور دستیابی به روابط انتقال رسوب بر اساس مطالعات آزمایشگاهی و میدانی انجام داده‌اند. به دلیل کثرت پارامترهای دخیل در انتقال رسوبات و همچنین پیچیدگی فرآیند فرسایش و انتقال ذرات، اکثر روابط رسوب نیاز به حل معادلات پیچیده ریاضی داشته و نتیجه دقیقی نمی‌دهند، از سوی دیگر روابط رگرسیونی مابین دبی آب و دبی رسوب نیز دارای ضریب همبستگی مطلوبی نمی‌باشند. کوبانار و همکاران (۲۰۰۸) توانایی روش نروفازی در تخمین غلظت رسوب معلق را با سه روش مختلف شبکه عصبی مصنوعی مقایسه کردند. نتایج مقایسه نشان داد که مدل‌های نروفازی برای مجموعه داده‌های این پژوهش نتایج بهتری نسبت به سایر مدل‌ها دارند (۸). آیتک و کیشی (۲۰۰۸) مدلی ضمنی بر پایه برنامه‌ریزی ژنتیک توسعه دادند. نتایج پژوهش آن‌ها نشان داد که فرمول پیشنهادی برنامه‌ریزی ژنتیک نسبت به منحنی سنج رسوب و رگرسیون چندخطی کاملاً خوب بوده و کاربرد آن خیلی عملی است (۳).

مواد و روش‌ها: در سال‌های اخیر استفاده از سیستم‌های هوشمند در راستای افزایش دقت برآورد میزان رسوبات رودخانه مرسوم گردیده است. در این پژوهش از سیستم‌های هوشمند شامل شبکه‌های عصبی مصنوعی، سیستم استنتاج تطبیقی عصبی- فازی و برنامه‌ریزی بیان ژن به منظور پیش‌بینی بار معلق رسوب رودخانه سیستان استفاده گردید. برای ارزیابی دقت مدل‌ها از شاخص‌های آماری میانگین مربعات خطا (RMSE)، خطای سوءگیری (MBE) و ضریب تعیین (R^2) استفاده شد.

یافته‌ها: در میان روش‌های هوش مصنوعی سناریوی سوم سیستم استنتاج تطبیقی عصبی- فازی با مقدار خطای جذر میانگین مربعات $۲۰۹۸۳/۴۳$ و ضریب همبستگی $۰/۹۷$ بهترین نتیجه را در برآورد بار معلق رسوب دارد. همچنین بین نتایج روش‌های هوشمند اختلاف معنی‌داری در سطح ۹۵٪ وجود نداشته و با توجه به مقادیر خطا هر سه روش از دقت بالایی برخوردارند.

* مسئول مکاتبه: hassanpourir@gmail.com

نتیجه‌گیری: با توجه به نتایج به‌دست آمده در این پژوهش سه روش به‌کار رفته برای تخمین بار معلق رسوب مناسب می‌باشند اما روش برنامه‌ریزی بیان ژن به‌دلیل ارائه رابطه ریاضی برای مدل نسبت به دو مدل دیگر ارجح است. تأثیر چشمگیر استفاده از دبی کلاسه‌بندی شده در دقت تخمین بار معلق رسوب پرواضح است. با توجه به نتایج پژوهش پیشنهاد می‌گردد برآورد بار معلق رسوب رودخانه سیستان با استفاده از روش‌های هوش مصنوعی انجام شود.

واژه‌های کلیدی: بار معلق، رودخانه سیستان، شبکه عصبی مصنوعی، سیستم استنتاج تطبیقی عصبی - فازی، برنامه‌ریزی بیان ژن

مقدمه

تعیین بار رسوبی رودخانه‌ها مستلزم تهیه داده‌های آماری و انجام اندازه‌گیری‌های میدانی و تهیه اطلاعات پایه مرتبط با سامانه رودخانه‌ای و حوضه آبریز آن می‌باشد. از نظر اهمیت و نقش ثبت داده‌های آماری در بررسی و شناخت پدیده انتقال رسوب استفاده از روش‌های تجربی از اوایل قرن نوزدهم میلادی متداول گردید و برای اولین بار اندازه‌گیری بار معلق توسط گراس و سابورس در ۱۸۰۸ انجام گرفت (۳۹). در طرح‌های مهندسی با هدف بهره‌برداری از منابع آب رودخانه مانند تأسیسات تنظیم و انحراف جریان، سدهای مخزنی و ایستگاه‌های پمپاژ، بار رسوبی رودخانه از جمله عوامل مهم و تأثیرگذار در تعیین مشخصه‌های هندسی سازه و عمر مفید آن‌ها تلقی می‌شود. در ساماندهی رودخانه‌ها که به‌منظور مهار فرسایش و رسوب‌گذاری و یا تثبیت بستر و دفع سیلاب انجام می‌گیرد آگاهی از میزان رسوب حمل شده توسط رودخانه و تأثیرپذیری آن از اقدامات حفاظتی، ضروری می‌باشد. از آنجایی که استفاده از روش‌های تجربی و معادله سنجه رسوب در برآورد بار معلق رسوب همواره با خطای زیادی همراه است، بنابراین لزوم استفاده از روش‌های هوشمند^۱ مانند شبکه عصبی مصنوعی^۲، سیستم استنتاج تطبیقی

عصبی - فازی^۳ و برنامه‌ریزی بیان^۴ در برآورد مقدار بار معلق محسوس است. تایفور و همکاران (۲۰۰۳) از روش‌های منطق فازی، شبکه عصبی مصنوعی و مدل‌های فیزیکی برای تخمین مقادیر انتقال رسوب استفاده کردند. مقایسه نتایج این مدل‌ها با داده‌های مشاهداتی نشان می‌دهد که استفاده از مدل فازی برای شرایط بحرانی جواب دقیق‌تری می‌دهد (۳۷). میرباقری و رجایی (۲۰۰۴) بار معلق عبوری از رودخانه‌ها را با استفاده از سری زمانی دبی جریان و غلظت بار معلق، توسط شبکه عصبی مصنوعی پیش‌بینی نمودند. نتایج نشان‌دهنده برتری محسوس مدل شبکه عصبی نسبت به روش منحنی سنجه در کل فرایند پیش‌بینی بوده است (۲۹). بایزیدی و همکاران (۲۰۰۵) عملکرد شبکه عصبی پرسپترون چندلایه را در برآورد بار معلق روزانه بررسی کردند و با مقایسه نتایج آن با رگرسیون چندمتغیره و منحنی سنجه رسوب به این نتیجه رسیدند که برتری شبکه عصبی پرسپترون چندلایه نسبی بوده و نیاز به بررسی‌های پیش‌تر می‌باشد (۵). کیشی (۲۰۰۵) با استفاده از روش‌های شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی - فازی مقدار رسوب معلق را برای ایستگاه کوبرادا بالانس و ریو والنسیا متعلق به USGS تخمین زد و عملکرد آن‌ها را نسبت به رگرسیون

3- Adaptive Neuro-Fuzzy Inference System
4- Genetic Expression Programming

1- Intelligent Methods
2- Artificial Neural Network

الگوریتم پیش‌خور و پس‌خور برای این کار استفاده کردند و نتایج آن‌ها را با رگرسیون خطی چندگانه مقایسه کردند که الگوریتم پس‌خور نتیجه بهتری را نشان می‌دهد (۲). آلپ و سیگیزاوغلو (۲۰۰۷) بار رسوب معلق حوزه جونیاتا را با شبکه عصبی مصنوعی شبیه‌سازی نموده و نتایج به‌دست آمده را با رگرسیون چندگانه خطی مرسوم مقایسه کردند و هیدروگراف‌های رسوب معلق به‌دست آمده را با روش شبکه عصبی مصنوعی شبیه‌سازی نمودند (۱). آیتک و کیشی (۲۰۰۸) رسوب معلق را با استفاده از برنامه‌ریزی ژنتیک مدل‌سازی کردند. آن‌ها مدل برنامه‌ریزی ژنتیک را با روش‌های منحنی سنجه رسوب و رگرسیون چندمتغیره مقایسه نمودند و نتیجه گرفتند که روش برنامه‌ریزی ژنتیک با داشتن خاصیت فرمول‌دهی نسبت به دو روش دیگر عملکرد بهتری دارد (۳). کیشی و همکاران (۲۰۰۸) در پژوهش خود عملکرد سیستم استنتاج تطبیقی عصبی-فازی در تخمین رسوب معلق ماهانه دو رودخانه کیولوس و سالورکوپروسو در ترکیه نسبت به مدل‌های شبکه عصبی مصنوعی و منحنی سنجه رسوب بررسی کردند. نتایج این پژوهش نشان داد روش سیستم استنتاج تطبیقی عصبی-فازی عملکرد بهتری در تخمین میزان بار معلق رودخانه نسبت به دو روش دیگر داشته است (۲۴). کوبانار و همکاران (۲۰۰۸) با استفاده از روش‌های سیستم استنتاج تطبیقی عصبی-فازی، شبکه عصبی مصنوعی و منحنی سنجه به تخمین بار معلق رودخانه ماد در ایالت متحده آمریکا پرداختند. نتایج حاصل از این پژوهش نشان داد مقادیرهای تخمینی با سیستم استنتاج تطبیقی عصبی-فازی به داده‌های مشاهداتی نزدیک‌تر می‌باشند (۸). پارتال و سیگیزاوغلو (۲۰۰۸) با استفاده از شبکه‌های عصبی-موجک رسوب معلق روزانه را پیش‌بینی و

چندمتغیره و منحنی سنجه رسوب مقایسه کرد. در نهایت نتایج این پژوهش نشان داد که روش سیستم استنتاج تطبیقی عصبی-فازی عملکرد بهتری نسبت به سایر روش‌ها داشته است (۲۲). سیگیزاوغلو و آلپ (۲۰۰۶) به نقش شبکه عصبی رگرسیونی تعمیم‌یافته در مدل‌سازی رسوب رودخانه آبخیز جونیاتا در آمریکا پرداخته‌اند و آن را با روش‌های پس‌انتشار خطا، منحنی سنجه رسوب و رگرسیون چندمتغیره خطی مقایسه نمودند. نتایج نشان‌دهنده عملکرد بهتر شبکه عصبی مصنوعی نسبت به روش‌های متداول می‌باشد (۶). سیگیزاوغلو و کیشی (۲۰۰۶) در پژوهش خود از روش شبکه‌های عصبی مصنوعی برای پیش‌بینی بار معلق رسوب استفاده کردند. آن‌ها در پژوهش خود با دقت روی برخی از پارامترها، تأثیر آن‌ها را در بهینه کردن کار شبکه عصبی بررسی نمودند (۷). جلالی و همکاران (۲۰۰۷) مدل‌های مختلف برآورد رسوب را بر اساس معیارهای هیدرولوژیکی به کمک روش منحنی سنجه رسوب و شبکه عصبی مصنوعی، مدل پرسپترون چندلایه با الگوریتم پس‌انتشار خطا در ایستگاه آلبو (واقع در نکارود) برای دوره آماری ۱۵ ساله مورد آزمون قرار دادند. نتایج برتری نسبی شبکه عصبی را با دارا بودن کم‌ترین میزان خطا نسبت به منحنی سنجه رسوب نشان داد (۲۰). شوشتری و کاشفی‌پور (۲۰۰۷) از شبکه عصبی مصنوعی برای برآورد بار معلق ایستگاه اهواز استفاده کردند که از سه پارامتر دبی، عرض سطح آب و بارندگی روز قبل برای شبیه‌سازی استفاده کردند. نتایج این روش با روش منحنی سنجه و *SPSS* مقایسه شد که شبکه عصبی نتایج بهتری نسبت به دو روش دیگر به دست داد (۳۶). آردیکلیوگو و همکاران (۲۰۰۷) از شبکه عصبی مصنوعی برای برآورد بار معلق رسوب استفاده کردند. آن‌ها از دو

در آمریکا پرداختند. نتایج این پژوهش نشان داد که سیستم استنتاج تطبیقی عصبی- فازی همبستگی زیاد و مقدار خطای کم‌تری دارد (۳۵). کیشی (۲۰۱۰) با استفاده از ترکیب روش‌های شبکه عصبی مصنوعی و تبدیل موجک گسسته بار معلق روزانه را شبیه‌سازی نمود. در این پژوهش از داده‌های دو ایستگاه بر روی رودخانه تانگوی مونتانا استفاده شد. نتایج نشان داد که روش عصبی- موجک می‌تواند دقت برآورد را افزایش دهد (۲۳). غفاری‌جونقانی و گیوه‌چی (۲۰۱۱) در برآورد رسوب معلق رودخانه زاینده‌رود به مقایسه روش‌های کلاسیک با شبکه عصبی مصنوعی پرداختند. نتایج این مقایسه نشان‌دهنده دقیق‌تر بودن روش شبکه عصبی مصنوعی نسبت به روش کلاسیک بوده است (۱۴). گوون و کیشی (۲۰۱۱) مقدار رسوب معلق در رودخانه‌های طبیعی را با استفاده از برنامه‌ریزی ژنتیک خطی کدنویسی شده تخمین زدند و نتایج حاصل را با مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک مقایسه نمودند. نتایج بیانگر برتری برنامه‌ریزی ژنتیک خطی نسبت به دو روش دیگر بود (۱۶). ملیسه و همکاران (۲۰۱۱) بار معلق رسوبی را در رودخانه‌ها با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند و نتایج را با روش‌های رگرسیون خطی چندمتغیره، رگرسیون غیرخطی چندمتغیره و مدل آریمای مقایسه نمودند. نتایج به‌دست آمده نشان داد شبکه عصبی نسبت به روش‌های دیگر پیش‌بینی دقیق‌تری ارائه داده و عملکرد بهتری دارد. این روش می‌تواند از تراکم عملیات پرهزینه در اندازه‌گیری رسوب بکاهد (۲۷). وفاخواه (۲۰۱۲) به مقایسه روش‌های کوکریجینگ، کریجینگ، شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی- فازی در برآورد بار معلق رسوبی پرداخت. نتایج حاصل از پژوهش نشان داد روش‌های هوش مصنوعی عملکرد

برآورد نمودند. نتایج حاصل از این پژوهش نشان داد عملکرد شبکه‌های عصبی- موجک نسبت به شبکه‌های عصبی و منحنی سنجه رسوب بهتر می‌باشد. همچنین در روش عصبی موجک تعداد برآوردهای نادرست به‌طور قابل‌توجهی کاهش می‌یابد و مجموع رسوب تجمعی حاصل نزدیک به مقادیر مشاهداتی است (۳۱). رجائی (۲۰۰۹) در پژوهشی به پیش‌بینی غلظت رسوب در ایستگاه ليقوان چای با استفاده از شبکه عصبی مصنوعی، منحنی سنجه رسوب و سیستم استنتاج تطبیقی عصبی- فازی پرداخت. نتایج این پژوهش نشان داد که مدل نروفازی عملکرد بهتری را نتیجه می‌دهد (۳۲). سلاجقه و همکاران (۲۰۰۹) به تخمین رسوب معلق رودخانه طالقان رود با استفاده از سیستم استنتاج تطبیقی عصبی- فازی پرداختند. نتایج این پژوهش نشان داد سیستم استنتاج فازی- عصبی تطبیقی نسبت به مدل‌های شبکه عصبی مصنوعی و منحنی سنجه رسوب عملکرد خوبی داشته است (۳۳). یانگ و همکاران (۲۰۰۹) مدل شبکه‌های عصبی مصنوعی را با استفاده از چهار پارامتر غالب، از فرمول‌های رسوب انتقال‌یافته، آموزش دادند. برای آموزش شبکه عصبی مصنوعی، سرعت جریان متوسط، شیب‌های سطح آب، عمق جریان متوسط و قطر متوسط ذرات به‌عنوان پارامترهای غالب به‌منظور برآورد بار مواد بستر کل استفاده شده است (۴۲). جعفری‌میانه‌ای و کشاورزی (۲۰۱۰) دبی رسوب معلق رودخانه اسکانا با استفاده از الگوریتم‌های منطق فازی پیش‌بینی نمودند. آن‌ها به نتیجه رسیدند که الگوریتم‌های منطق فازی نسبت به منحنی سنجه رسوب عملکرد بهتری در مدل‌سازی دارند (۱۹). شیرری و همکاران (۲۰۱۰) در مطالعه‌ای با استفاده از سیستم استنتاج تطبیقی عصبی- فازی به تخمین بار رسوب معلق در رودخانه کامبرلند

بهتری نسبت به روش‌های کریجینگ دارند. همچنین روش استنتاج تطبیقی عصبی- فازی نسبت به روش شبکه عصبی مصنوعی و روش کوکریجینگ نسبت به روش کریجینگ برتری دارد (۴۰). مصطفی و همکاران (۲۰۱۲) با استفاده از الگوریتم‌های آموزشی متنوع شبکه عصبی پرسپترون چندلایه، رسوب معلق رودخانه‌ها را در مالزی پیش‌بینی نمودند. آن‌ها از چهار الگوریتم *LM*، *SCG*، *GDM*، *GD* و آموزش شبکه عصبی مصنوعی بهره جستند (۳۰). دهقانی و وفاخواه (۲۰۱۳) به مقایسه روش‌های تخمین رسوب معلق روزانه با استفاده از روش‌های منحنی سنجه رسوب و شبکه عصبی در ایستگاه قزاقلی استان گلستان پرداختند و به این نتیجه رسیدند که از بین روش‌های مختلف سنجه رسوب، روش دبی کلاسه و از بین شبکه‌های پرسپترون چندلایه و تابع پایه شعاعی، شبکه پرسپترون چندلایه با ورودی‌های دبی همان روز، دبی ۱ و ۲ روز قبل از دقت بالاتری برخوردار هستند. نگاهی به نتایج پژوهشگران تا به حال نشانگر برتری قابل توجه روش‌های هوش مصنوعی نسبت به روش‌های تجربی و معادلات منحنی سنجه می‌باشد (۳۴). از این رو در این پژوهش به مقایسه سه روش هوشمند شبکه عصبی مصنوعی، سیستم استنتاج تطبیقی عصبی- فازی و برنامه‌ریزی بیان ژن در برآورد بار معلق رسوب رودخانه سیستان پرداخته شده است. همچنین نتایج حاصل از روش‌های مورد مطالعه با استفاده از شاخص‌های آماری مورد مقایسه قرار گرفته است.

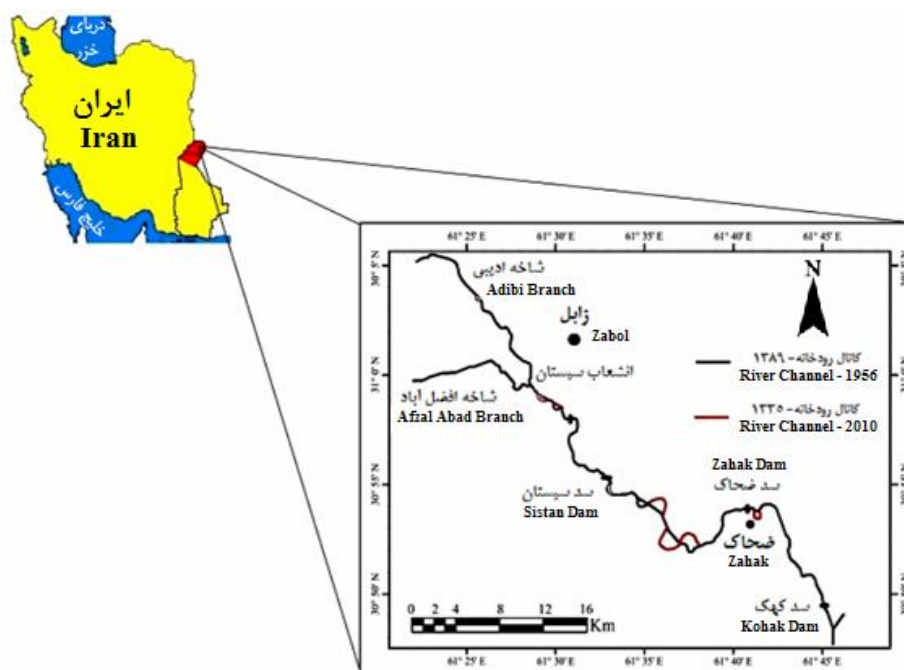
مواد و روش‌ها

منطقه مورد مطالعه: دشت سیستان با مرکزیت شهر زابل در جنوب شرقی ایران و در مرز افغانستان واقع شده است. در حدود ۱۵۰۰۰۰ هکتار از زمین‌های این

دشت دارای پتانسیل کشاورزی بوده و می‌تواند در چرخه تولید زراعی قرار گیرد. متوسط ارتفاع این دشت از سطح دریا ۴۸۵ متر است (۳۴). متوسط بارندگی سالانه در سیستان بسیار ناچیز و بین ۵۰ تا ۵۵ میلی‌متر است که در حدود ۷ درصد متوسط بارندگی در خشکی‌های کره زمین است. میزان تبخیر سالانه آن بسیار بالا و در حدود ۴۸۰۰ میلی‌متر گزارش شده است، متوسط حداکثر درجه حرارت در این منطقه ۳۴/۵ درجه سانتی‌گراد و متوسط حداقل درجه حرارت ۸/۵ درجه سانتی‌گراد است (سامانی، ۲۰۰۴). منابع آب سیستان منحصر به رودخانه سیستان، رودخانه پریان مرکزی و هامون‌های هیرمند می‌باشند. رودخانه هیرمند با طی مسافتی حدود ۱۱۰۰ کیلومتر در مکانی به نام جریکه در مرز ایران و افغانستان به دو شاخه اصلی پریان و سیستان تقسیم می‌شود. رودخانه هیرمند از چندین هزار سال پیش با بر جای گذاشتن رسوبات خود، مایه پیدایش دشت سیستان شده است. شیب کم بستر رودخانه سیستان، آن را مستعد رسوب‌گذاری نموده همچنین ساخت سدهای زهک و کهک و افزایش میزان رسوب‌گذاری این رودخانه را سبب شده است (۱۸). جمع کل مساحت مفید حوضه آبریز رود هیرمند برابر ۱۵۰۰۰۰ کیلومترمربع هست که حدود ۲۴ درصد کل مساحت کشور افغانستان را تشکیل می‌دهد (۳۸). محدوده مورد مطالعه پایانه سفر بسیار طولانی رودخانه هیرمند از مناطق خارج از کشور است. این رودخانه مواد محموله خود را با سفری طولانی به ایران‌زمین می‌آورد. جریان پرتلاطم آب رودخانه با ورود به دشت‌های مسطح و هامون‌ها آرامش یافته، فرصتی برای بر جای نهادن بار خود تا ریزترین ذرات پیدا می‌کند. عرصه هامون‌ها و اراضی مشرف به آن‌ها محل انباشت رسوبات و یا به بیانی دیگر، مکان ترسیب

همچنین از عمده‌ترین عوامل افزایش خطر سیل منطقه از گذشته تا به امروز بوده است. شکل ۱ نمایی کلی از موقعیت منطقه سیستان و رودخانه سیستان را نشان می‌دهد.

خواهند شد؛ بنابراین شناخت بیش‌تر پدیده‌های مؤثر در جریان و رسوب منطقه و جستجو برای کاهش هزینه تحلیل‌های مختلف می‌تواند نتایج بسیار بهتر را به دنبال داشته باشد. رسوب‌گذاری در رودخانه سیستان از جمله مهم‌ترین موانع برای تهیه آب و



شکل ۱- موقعیت منطقه سیستان و طرح رودخانه سیستان.

Figure 1. The Sistan region location and Sistan river schematic.


متداول هیدرولوژیکی در تخمین بار معلق رسوب، ایجاد ارتباطی بین داده‌های دبی رسوب با داده‌های دبی جریان متناظر آنها می‌باشد که از برازش منحنی بین مقادیر دبی جریان و رسوب معلق متناظر آن به دست می‌آید ($Q_s = a \cdot Q_w^b$) که در آن Q_s دبی رسوب معلق بر حسب تن بر روز، Q_w دبی جریان متناظر با آن بر حسب مترمکعب بر ثانیه و a و b ضرایب معادله می‌باشند).

به منظور افزایش دقت برآورد رسوب به روش منحنی سنجه، روش‌های مختلفی در مطالعات انجام یافته پیشنهاد شده است که یکی از آنها دسته‌بندی

پژوهشگران بخش رسوب روش‌های مختلفی و متعددی را برای برآورد بار معلق رسوب به کار برده‌اند که بر شامل روش‌های هیدرولیکی، هیدرولوژیکی، هوش مصنوعی و یا ترکیبی از این روش‌هاست. در سال‌های اخیر روش‌های هیدرولیکی به جهت استفاده از پارامترهای مختلف هیدرولیک جریان که اندازه‌گیری آنها مشکل می‌باشد آن‌چنان توسعه نیافته‌اند اما روش‌های هیدرولوژیکی به جهت سهولت به‌کارگیری آنها هنوز در مطالعات بار معلق رسوب مورد استفاده و گاهی نیز در کنار روش‌های هوشمند مورد مقایسه قرار می‌گیرند. از جمله روش‌های

سیستان در دوره آماری ۱۳۴۹ تا ۱۳۹۰ آمده است که مقادیر ضرایب a و b برای معادله رسوب این رودخانه بر اساس داده‌های مورد استفاده به ترتیب $۶۰۵/۹۶$ و ۱۱۶۵۰ می‌باشد. همچنین مقدار ضریب تبیین برای داده‌های مورد استفاده $۰/۸۲$ به دست آمد.

داده‌ها به صورت‌های مختلف می‌باشد. دسته‌بندی داده‌ها می‌تواند به صورت سالانه، فصلی، ماهانه، حدوسط دسته‌ها، دبی کلاسه، دوره مشابه هیدرولوژیکی، دوره کم‌آبی و پرآبی انجام شود. در شکل ۲ منحنی سنجه ایستگاه هیدرومتری کهک بر روی رودخانه



شکل ۲- منحنی سنجه رسوب رودخانه سیستان.

Figure 2. Sediment rating curve of Sistan river.

معلق رسوب استفاده گردید. در این پژوهش پس از سعی و خطا بر روی کل داده‌ها از میان ۶۰ تا ۸۵ درصد داده‌ها برای مرحله آموزش، بهترین نتیجه ۷۵ درصد به دست آمد و به این ترتیب ۲۵ درصد داده‌ها به منظور آزمون مدل در نظر گرفته شد بنابراین به تعداد ۱۷۴۰ داده که شامل ۷۵ درصد از کل داده‌ها است، به مرحله آموزشی تعلق گرفت و تعداد ۵۷۵ داده که شامل ۲۵ درصد داده‌ها است، برای مرحله آزمون تعلق گرفت. در جدول ۲ همبستگی بین پارامترهای ورودی مدل‌ها و دبی رسوب به عنوان خروجی مدل‌ها آمده است. خصوصیات آماری دبی جریان و رسوب در ایستگاه هیدرومتری کهک بر روی رودخانه سیستان برای دوره آماری ۹۱-۱۳۴۹ برای مراحل آموزش و آزمون در جدول ۳ ارائه شده است.

امروزه برای برآورد بار معلق رسوب از بین روش‌های مورد استفاده، روش‌های هوشمند بیش‌ترین کاربرد را دارا می‌باشند، بنابراین در این پژوهش بار معلق رسوب رودخانه سیستان با استفاده از روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی، استنتاج تطبیقی عصبی- فازی و برنامه‌ریزی ژنتیک، مورد پیش‌بینی قرار گرفت. پارامترهای ورودی سناریوها بر اساس دسترس بودن و اثرگذاری روی دبی انتخاب شدند. به علت متناظر نبودن داده‌های بارش و باد علی‌رغم اثر بیش‌تر این پارامترها نسبت به دما بر روی دبی از آن پارامترها استفاده نشد. از سه سناریو برای مدل‌سازی در هر سه روش هوش مصنوعی استفاده گردید (جدول ۱). در روش برآورد رسوب با استفاده از این سه مدل از تعداد ۲۳۱۵ داده برای برآورد بار

جدول ۱- ترکیبی از مدل‌های ورودی.

Table 1. Combination of input models.

ترکیب ورودی‌ها Combination of inputs	سناریو Scenario
دبی، اختلاف بیشینه و کمینه دما Water discharge, TD	1
دبی، بیشینه دما، کمینه دما Water discharge, Maximum temperature and Minimum temperature	2
بیشینه دما، کمینه دما، دبی کلاس‌بندی شده، اختلاف بیشینه و کمینه دما Maximum temperature, Minimum temperature, Water discharge, Classified discharge, TD	3

جدول ۲- ضریب همبستگی بین دبی رسوب و پارامترهای ورودی به مدل.

Table 2. The correlation coefficient between the water discharge and model input parameters.

اختلاف بیشینه و کمینه دما TD	دبی کلاس‌بندی شده Classified discharge	کمینه دما Minimum temperature	بیشینه دما Maximum temperature	دبی Water discharge	دبی رسوب Sediment discharge	
0.07	0.85	0.11	0.13	0.7	1	دبی رسوب Sediment discharge
0.05	0.97	0.04	0.06	1		دبی Water discharge
0.40	0.06	0.83	1			بیشینه دما Maximum temperature
0.25	0.04	1				کمینه دما Minimum temperature
0.05	1					دبی کلاس‌بندی شده Classified discharge
1						اختلاف بیشینه و کمینه دما TD

جدول ۳- خصوصیات آماری داده‌ها برای ایستگاه هیدرومتری کهک بر روی رودخانه سیستان.

Table 3. The statistical properties of data for Kohak hydrometry station on Sistan river.

چولگی Skewness	انحراف معیار SD/Mean	انحراف معیار SD	حداکثر Maximum	حداقل Minimum	میانگین Mean	متغیر Variable	مرحله Step
2.67	1.72	186.87	1178.45	0.39	108.27	دبی جریان (m ³ s ⁻¹) Water Discharge	آموزش Training
4.34	2.6	135021.59	1566836	1.33	51798.19	دبی رسوب (ton day ⁻¹) Sediment discharge	
3.46	1.59	53.36	488.59	0.195	33.39	دبی جریان (m ³ s ⁻¹) Water Discharge	آزمون Testing
5.79	3.34	50549.2	577483.22	1.7	11115.82	دبی رسوب (ton day ⁻¹) Sediment discharge	

1- Difference between maximum and minimum temperature

2- Standard Deviation

شبکه‌های عصبی مصنوعی: شبکه‌های عصبی مصنوعی از جمله مدل‌های محاسباتی هستند 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 متصل می‌باشند تعیین کنند. ساختار شبکه‌های عصبی که به آن معماری شبکه گفته می‌شود، به نحوی است که نرون‌ها در دسته‌هایی که لایه نامیده می‌شوند مرتب می‌گردند. معماری معمول برای این شبکه‌ها شامل سه لایه ورودی، پنهان و خروجی می‌باشد. لایه ورودی داده‌ها را در شبکه توزیع می‌کند، لایه پنهان داده‌ها را پردازش و لایه خروجی نتایج را به‌ازای ورودی‌های مشخص، استخراج می‌کند و هر شبکه می‌تواند چندین لایه داشته باشد (۱۷ و ۲۸).

مدل شبکه عصبی مصنوعی پیش‌خور چندلایه با الگوریتم پس‌انتشار خطا استفاده شد و توابع انتقال در لایه پنهان و خروجی به‌ترتیب تابع سیگموئیدی و خطی می‌باشند. شبکه عصبی انتخابی دارای سه لایه ورودی، میانی و خروجی می‌باشد که معماری شبکه بر اساس ارتباط بین نرون‌ها در لایه‌های مختلف می‌باشد.

سیستم استنتاج تطبیقی عصبی - فازی: شبکه‌های عصبی - فازی با الگوبرداری از سیستم کارکرد مغز انسان، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسأله، قانون نهفته مابین داده‌ها را کشف می‌نمایند. نکته مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی می‌باشد و

مکانیسم اولیه برای انجام این کار لیستی از جملات If-Then است که قانون نامیده می‌شوند. در فرآیند آموزش، این قوانین به‌صورت موازی ارزیابی و تعیین می‌شوند. از طرف دیگر شبکه‌های عصبی دارای توانایی آموزش از محیط (جفت‌های ورودی - خروجی) می‌باشد. جانگ (۱۹۹۳) برای اولین بار با در نظر گرفتن توانایی‌های تئوری فازی و شبکه عصبی، مدل سیستم استنتاج تطبیقی عصبی - فازی را ارائه داد (۲۱). مدل سیستم استنتاج تطبیقی عصبی - فازی (ANFIS) شبکه‌ای چندلایه، متشکل از گره‌ها و کمان‌های اتصال‌دهنده گره‌ها می‌باشد. به‌عنوان یک مثال ساده، یک سیستم استنتاج فازی با دو ورودی x و y و یک خروجی z فرض شده است. مدل فازی سوگنو مرتبه یک، ضابطه‌ای نوعی می‌باشد که با دو قانون اگر - آنگاه فازی جفت شده و می‌تواند چنین بیان شود:


(۱)

$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ THEN } f_1 = p_1x + q_1y + r_1$$

(۲)

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ THEN } f_2 = p_2x + q_2y + r_2$$

ساختار ANFIS متناظر در شکل ۳ نشان داده شده است. گره‌ها در همان لایه، توابع مشابهی دارند. خروجی گره i ام در لایه ۱ با $O_{1,i}$ مشخص شده است.



شکل ۳- نمایشی از یک سیستم استنتاج عصبی- فازی با تابع عضویت مثلثی (۲۱).

Figure 3. Schematic of a adaptive neuro-fuzzy inference system by triangular membership function (21).

تشخیص مانند توابع پر کاربرد عضویت مثلثی شکل نیز نامزدهای واجد شرایط برای توابع گره در این لایه می‌باشند. پارامترها در این لایه، به نام پارامترهای فرضی موسوم‌اند. خروجی‌های این لایه مقادیر بخش فرضی می‌باشند.

لایه ۲: این لایه از گره‌های برچسب‌گذاری شده با Π تشکیل شده است که سیگنال‌های ورودی را تقسیم کرده و به‌عنوان محصول خروجی ارسال می‌کند. برای نمونه:

$$O_{2,i} = w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2 \quad (6)$$

هر گره خروجی بیانگر شدت برانگیختگی یک قانون می‌باشد.

لایه ۳: در این لایه، گره‌هایی که با برچسب N مشخص شده‌اند، نسبت شدت برانگیختگی قاعده i ام به مجموع شدت‌های برانگیختگی تمام قوانین را محاسبه می‌کند:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (7)$$

خروجی‌های این لایه شدت‌های برانگیختگی نرمال‌سازی شده نامیده می‌شوند.

لایه ۴: گره‌های این لایه منطبق با توابع گره می‌باشند:

لایه ۱: هر گره i در این لایه، یک گره، منطبق با تابع گره می‌باشد:

$$O_{1,i} = \mu_{A_i}(x) \quad \text{for } i = 1,2 \quad (3)$$

$$O_{1,i} = \mu_{B_{i-2}}(y) \quad \text{for } i = 3,4 \quad (4)$$

که در آن، x (یا y) ورودی گره i ام بوده و A_i (یا B_{i-2}) یک متغیر زبانی (هم‌چون کم یا زیاد) منطبق با این گره می‌باشد. به عبارت دیگر، $O_{1,i}$ درجه عضویت یک مجموعه فازی که در آن، x (یا y) ورودی گره i ام بوده و $A=(A_1, A_2, B_1 \text{ or } B_2)$ می‌باشد و درجه اختصاص داده شده به ورودی x (یا y) که به کمیت سنج A اختصاص می‌یابد را مشخص می‌کند. توابع عضویت برای A و B عموماً با توابع زنگی توصیف شده و تعمیم داده شده‌اند. به‌عنوان مثال:

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (5)$$

که در آن، $\{a_i, b_i, c_i\}$ مجموعه پارامترها می‌باشند. هنگامی که مقادیر پارامترها تغییر می‌کند، تابع زنگی شکل مطابق با آن تغییر می‌کند، بنابراین انواع مختلف توابع عضویت در متغیر زبانی A_i نمایش داده شده است. در حقیقت هر تابع پیوسته و تکه‌ای قابل

(۱) رابطه موجود بین متغیرهای مسئله به خوبی شناخته نشده باشد یا صحت و سقم شناخت فعلی از رابطه مذکور با تردید همراه باشد،

(۲) پیدا کردن اندازه و شکل روش حل نهایی بسیار سخت بوده و بخش عمده مسأله را تشکیل دهد،

(۳) روش‌های معمول تحلیل ریاضی قادر به ارائه روش‌های حل تحلیل نباشند،

(۴) راه‌حل تقریبی قابل قبول باشد،

(۵) هر گونه بهبود جزئی در عملکرد به صورت منظم اندازه‌گیری شده و این بهبود از ارزش زیادی برخوردار باشد،

(۶) تعداد داده‌هایی که باید به وسیله رایانه مورد آزمون، دسته‌بندی و جمع‌بندی قرار گیرند زیاد باشد.

برنامه‌ریزی بیان ژن توسط فریرا (۱۹۹۹) ابداع شد (۱۱). برنامه‌ریزی بیان ژن از نخبه‌گزینی ساده استفاده می‌کند و بهترین افراد یک نسل را برای نسل بعد نگه می‌دارد. برنامه‌ریزی بیان ژن بر خلاف الگوریتم ژنتیک و برنامه‌ریزی ژنتیک چندین عملگر ژنتیکی برای تکثیر افراد با اصلاحات دارد (۲۶). بیان درختی، تحت فرآیندی به نام ترجمه از کروموزومها استخراج می‌شود و نمایش درختی آن در محیط، برآزش آن و کروموزوم‌های متناظرش را تعیین می‌کند، در حالی که این کروموزوم تحت انتخاب و فعالیت عملگرهای ژنتیکی قرار می‌گیرد (۴۱).

مجموعه توابع مورد استفاده در برنامه‌ریزی بیان ژن، معمولاً شامل توابع اصلی حسابی $\{+, -, \times, \div\}$ ، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر $\sqrt{\quad}, X^2, \exp, \log, \sin, \cos, \dots$ و یا توابع تعریف شده توسط کاربر است که معتقد است، می‌توانند برای تفسیر مدل مناسب باشند. سری توابع مورد استفاده توسط پژوهشگران در این پژوهش در جدول ۳ ارائه شده است. همچنین در این پژوهش از

$$O_{4,i} = \overline{w_i f_i} = \overline{w_i (p_i x + q_i y + r_i)} \quad (۸)$$

که در آن، $\overline{w_i}$ خروجی لایه ۳ بوده و $\{p_i, q_i, r_i\}$ مجموعه پارامترها می‌باشند. پارامترهای این لایه به نام پارامترهای استنتاجی موسوم‌اند.

لایه ۵: تنها گره این لایه، یک گره ثابت به نام \sum می‌باشد که تمامی خروجی‌ها را به عنوان مجموع تمام سیگنال‌های ورودی محاسبه می‌کند:

$$O_{5,i} = \sum_i \overline{w_i f_i} = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (۹)$$

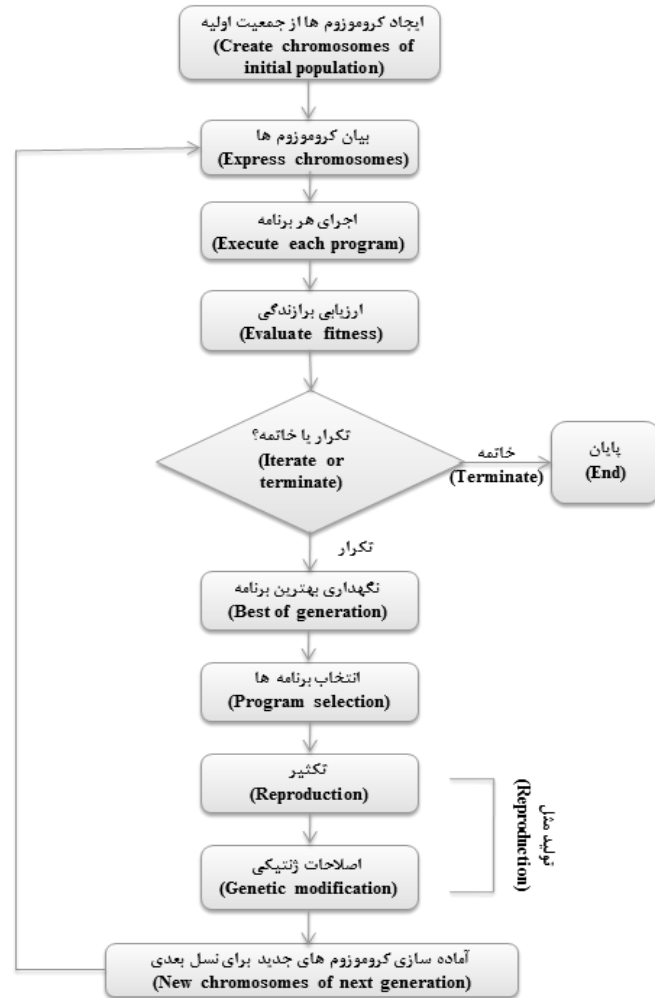
بنابراین یک شبکه تطبیقی که از نظر وظیفه معادل با یک سیستم استنتاج فازی مرتبه یک می‌باشد، ایجاد شده است.

برنامه‌ریزی بیان ژن: برنامه‌ریزی ژنتیک مدلی شبیه الگوریتم ژنتیک می‌باشد (۱۵) با این تفاوت که در سیستم جستجوی جواب خود از مدل درختی استفاده می‌نماید. اولین بار جان کزا (۱۹۹۲) بر اساس تئوری داروین، برنامه‌ریزی ژنتیک را ارائه نمود. این روش تکنیکی برای برنامه‌ریزی خودکار جهت حل مسأله به صورت برنامه کامپیوتری ارائه می‌نماید و قابلیت بهینه‌سازی ساختار مدل و مؤلفه‌های آن را دارد (۲۵). در برنامه‌ریزی ژنتیک از ساختار درختی استفاده می‌شود ولی الگوریتم ژنتیک بر پایه سیستم دودویی است که تفاوت اساسی ساختاری این دو سیستم محسوب می‌گردد. کاربرد این روش در مسائلی که روش‌های معمول ریاضی محاسباتی قادر به حل آن‌ها نباشند یا از روابط مابین متغیرهای مسأله شناخت دقیقی در دسترس نباشد، به سرعت در حال ترقی است (فریرا، ۲۰۱۱؛ فریرا، ۲۰۰۴) (شکل ۴).

این روش در مورد مسائل زیر می‌تواند به راحتی پاسخگو باشد (۴):

نرم‌افزار ویرایش جدیدی از برنامه‌ریزی ژنتیک می‌باشد که به استنتاج مدل‌های رایانه‌ای با اندازه‌ها و شکل‌های مختلف می‌پردازد.

برنامه GeneXproTools 4.0 برای توسعه و اجرای مدل‌های مبتنی بر برنامه‌ریزی بیان ژن استفاده شده است که توسط فریرا (۲۰۰۱) ارائه گردید. این



شکل ۴- فلوجارت نحوه عملکرد برنامه‌ریزی بیان ژن (۱۱).

Figure 4. The flowchart of Gene Expression Programming performance (11).

جدول ۴- توابع ریاضی استفاده شده برای مدل برنامه‌ریزی بیان ژن.

Table 4. Mathematical functions used for gene expression programming model.

عملگرهای محاسباتی و توابع پایه ریاضی Arithmetic operators and basic math functions	سری توابع Function Series
+ , - , * , /	A
+ , - , * , / , Exp(x)	B
+ , - , * , / , □	C
+ , - , * , / , Exp(x) , ln(x) , □	D
+ , - , * , / , Exp(x) , ln(x) , □ , Sin(x) , Cos(x) , Tan(x)	E

که بهترین مدل برای سناریو ۱، ۲ و ۳ به ترتیب مدل‌های با ۶، ۸ و ۵ نرون بهترین نتیجه را داشتند. با توجه به نتایج به دست آمده سناریو ۳ با ریشه دوم میانگین مربعات خطای ۲۱۹۰۱/۷۴، خطای سوءگیری ۱۸۲۰/۵۶- و ضریب تعیین ۰/۹۶ در مرحله آموزش و با ریشه دوم میانگین مربعات خطای ۱۵۰۴۳/۸۸، خطای سوءگیری ۲۸۴۱/۰۷- و ضریب تعیین ۰/۹۴ در مرحله آزمون بهترین نتیجه را دارد و سناریوهای ۲ و ۱ به ترتیب در اولویت‌های بعدی هستند. پراکنش بار معلق رسوب برای داده‌های مشاهداتی و تخمینی برای بهترین مدل شبکه عصبی در شکل ۵ نمایش داده شده است. نتایج شاخص‌های آماری برای ارزیابی دقت سناریوها در برآورد بار معلق رسوب با استفاده از شبکه عصبی مصنوعی در جدول ۴ ارائه شده است. نتایج به دست آمده از روش شبکه عصبی مصنوعی با نتایج پژوهشگران (۲۹، ۲۲، ۶، ۳۶، ۱، ۳۱، ۳۲، ۲۳، ۲۷ و ۳۰) همخوانی دارد.

داده‌ها قبل از ورود به شبکه‌های هوش مصنوعی با استفاده از رابطه زیر نرمال‌سازی شدند:


$$N = 0.8 \times \frac{X_i - MIN_{X_i}}{MAX_{X_i} - MIN_{X_i}} + 0.1 \quad (10)$$

که در آن، X_i متغیر یا مؤلفه i ام، MIN_{X_i} حداقل مقدار متغیر یا مؤلفه، MAX_{X_i} حداکثر مقدار متغیر یا مؤلفه موردنظر و N نیز مقادیر استانداردسازی شده است. با استفاده از این رابطه محدوده هر متغیر بین ۰/۱ تا ۰/۹ قرار می‌گیرد.

به منظور سنجش و ارزیابی دقت مدل‌ها نیز از آماره‌های ضریب تبیین (R^2)، ریشه دوم میانگین مربعات خطا (RMSE) و میانگین خطای سوءگیری (MBE) استفاده شد.

نتایج و بحث

در شبکه‌های عصبی هر یک از سناریوها به ترتیب با ۵، ۶، ۷، ۸ و ۹ نرون و دولایه پنهان مدل‌سازی شدند



شکل ۵- پراکنش داده‌های مشاهداتی و تخمینی بار معلق رسوب در مرحله آزمون برای سناریوی سه مدل شبکه عصبی مصنوعی با ۵ نرون.

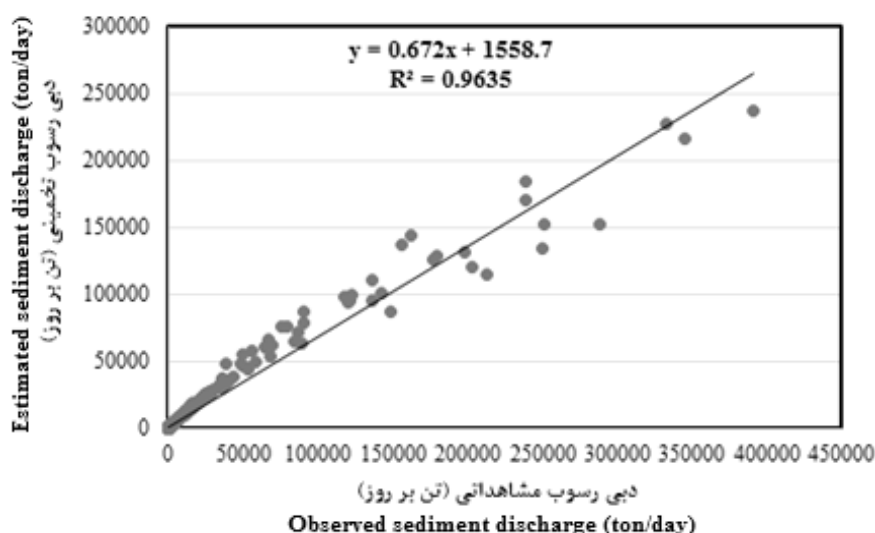
جدول ۵- نتایج آموزش و آزمون برای مدل‌های شبکه عصبی مصنوعی.

Table 5. Training and testing results for artificial neural network.

آزمون (Testing)			آموزش (Training)			تعداد نرون‌ها Number of neurons	سناریو Scenario
R ²	RMSE (تن بر روز) ton/day	MBE (تن بر روز) ton/day	R ²	RMSE (تن بر روز) ton/day	MBE (تن بر روز) ton/day		
0.91	21697.52	-3179.37	0.88	49906.21	-5112.7	6	1
0.92	21347.17	-3503.88	0.95	29138.50	-1998.63	8	2
0.94	15043.88	-2841.07	0.96	21901.74	-1820.56	5	3

شکل ۶ نمایش داده شده است. نتایج شاخص‌های آماری برای ارزیابی دقت سناریوها در برآورد بار معلق رسوب با استفاده از سیستم استنتاج تطبیقی عصبی- فازی در جدول ۵ ارائه شده است. همچنین نتایج حاصل از مدل‌های استنتاج تطبیقی عصبی- فازی با نتایج کیشی (۲۰۰۵)، کیشی و همکاران (۲۰۰۸)، کوبانار و همکاران (۲۰۰۸)، رجایی (۲۰۰۹)، سلاجقه و همکاران (۲۰۰۹)، شیرینی و همکاران (۲۰۱۰) و وفاخواه (۲۰۱۲) همخوانی دارد.

با توجه به نتایج به دست آمده از مدل‌های استنتاج تطبیقی عصبی- فازی سناریو ۳ با ریشه دوم میانگین مربعات خطای ۲۰۹۸۳/۴۳، خطای سوءگیری ۱۶۷۶/۱۱- و ضریب تعیین ۰/۹۷ در مرحله آموزش و با ریشه دوم میانگین مربعات خطای ۱۴۶۲۳/۶۳، خطای سوءگیری ۲۷۴۳/۶۳- و ضریب تعیین ۰/۹۶ در مرحله آزمون بهترین نتیجه را دارد و سناریوهای ۲ و ۱ به ترتیب در اولویت‌های بعدی هستند. پراکنش بار معلق رسوب برای داده‌های مشاهداتی و تخمینی برای بهترین مدل سیستم استنتاج تطبیقی عصبی- فازی در



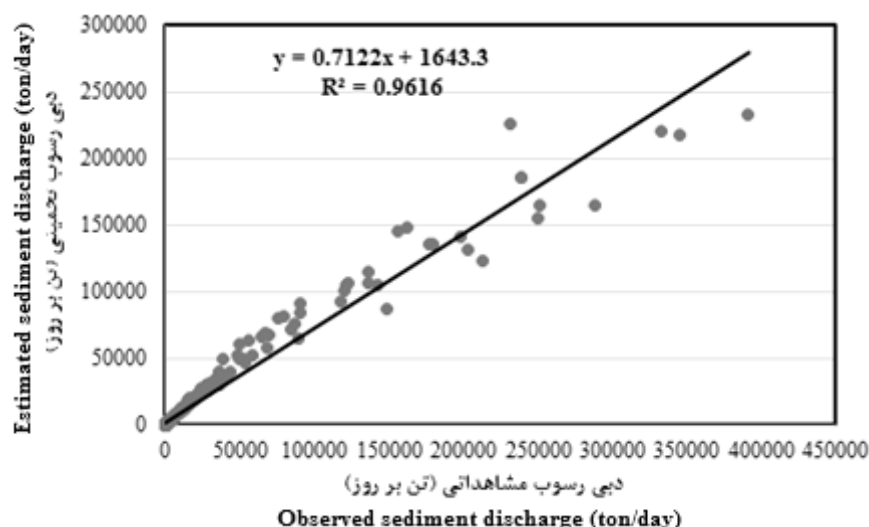
شکل ۶- پراکنش داده‌های مشاهداتی و تخمینی بار معلق رسوب در مرحله آزمون برای سناریوی سه در مدل سیستم استنتاج تطبیقی- فازی.

جدول ۶- نتایج آموزش و آزمون برای مدل‌های سیستم استنتاج تطبیقی عصبی- فازی.

آزمون (Testing)			آموزش (Training)			سناریو Scenario
R ²	RMSE (تن بر روز) ton/day	MBE (تن بر روز) ton/day	R ²	RMSE (تن بر روز) ton/day	MBE (تن بر روز) ton/day	
0.90	23109.21	-3663.19	0.87	49381.76	-3280.12	1
0.92	22014.95	-3597.81	0.96	26195.14	-2110.27	2
0.96	14623.63	-2743.29	0.97	20983.43	-1676.11	3

آزمون بهترین نتیجه را دارد و سناریوهای ۱ و ۲ به ترتیب در اولویت‌های بعدی هستند. پراکنش بار معلق رسوب برای داده‌های مشاهداتی و تخمینی برای بهترین مدل برنامه‌ریزی بیان ژن در شکل ۷ نمایش داده شده است. نتایج شاخص‌های آماری برای ارزیابی دقت سناریوها در برآورد بار معلق رسوب با استفاده از برنامه‌ریزی بیان ژن در جدول ۷ ارائه شده است. همچنین نتایج حاصل از مدل‌های برنامه‌ریزی بیان ژن آیتک و کیشی (۲۰۰۸) و گوون و کیشی (۲۰۱۱) همخوانی دارد.

بار معلق رسوب برای هر یک از سناریوهای مدل برنامه‌ریزی بیان ژن با استفاده از ۵ سری توابع ذکر شده در جدول ۳ مدل‌سازی شد. برای سناریو ۱ سری توابع E، برای سناریو ۲ سری توابع D و برای سناریو ۳ سری توابع A جواب قابل قبول‌تری نسبت به سایر سری‌های توابع دادند. با توجه به نتایج به دست آمده از مدل‌های برنامه‌ریزی بیان ژن سناریو ۳ با ریشه دوم میانگین مربعات خطای ۲۶۶۷۹/۷، خطای سوءگیری ۲۴۲۰/۳۵- و ضریب تعیین ۰/۹۵ در مرحله آموزش و با ریشه دوم میانگین مربعات خطای ۸۳۷۱/۵۷، خطای سوءگیری ۲۰۴۲/۹۳- و ضریب تعیین ۰/۹۶ در مرحله



شکل ۷- پراکنش داده‌های مشاهداتی و تخمینی بار معلق رسوب در مرحله آزمون برای سناریوی سه مدل برنامه‌ریزی بیان ژن با ۴ تابع.

جدول ۷- نتایج آموزش و آزمون برای مدل‌های برنامه‌ریزی بیان ژن.

R ²	آزمون (Testing)		آموزش (Training)		سری توابع Function Series	سناریو Scenario
	RMSE (تن بر روز) ton/day	MBE (تن بر روز) ton/day	R ²	RMSE (تن بر روز) ton/day		
0.82	29514.85	-4677.94	0.86	52259.73	-3873.22	E 1
0.92	12078.35	-3051.78	0.91	41173.79	-3157.79	D 2
0.96	8371.57	2042.93	0.95	26679.70	2420.35	A 3


بیان درختی رابطه ریاضی همین سناریو را نشان می‌دهد.

(11)

$$Q_s = [24/235 + (T_{min} - 7/9)] + [Q_c] + [7/9 - (T_{min} - 8/437)]$$

که در آن، Q_s دبی رسوب معلق (تن بر روز)، T_{min} مقدار کمینه دما (درجه سلسیوس) و Q_c دبی کلاس‌بندی شده (مترمکعب بر ثانیه) می‌باشد.

ساختار درختی مدل برنامه‌ریزی بیان ژن باعث گردیده این روش در سال‌های اخیر در علوم مهندسی آب جایگاه ویژه‌ای باز کند و از نظر این‌که این مدل رابطه ریاضی بر پایه بیان درختی برای پیش‌بینی ارائه می‌دهد می‌تواند برای داده‌هایی که در آینده ثبت خواهند شد نیز مورد استفاده قرار گیرد (۱۳). معادله ریاضی ساده شده برای سناریو سوم با سری توابع A در رابطه (۱۱) آمده است. شکل ۸ نیز



شکل ۸- بیان درختی رابطه حاصل از برنامه‌ریزی بیان ژن برای سناریو سه.

Figure 8. Tree expression relationship of gene expression programming for scenario 3.

نتیجه گیری

در این پژوهش تخمین بار معلق رسوب در رودخانه سیستان با استفاده از روش‌های هوش مصنوعی شبکه عصبی مصنوعی، سیستم استنتاج تطبیقی عصبی- فازی و برنامه‌ریزی بیان ژن مورد بررسی قرار گرفت و نتایج زیر به دست آمد:

هر سه روش مورد استفاده در این پژوهش به خوبی می‌توانند بار معلق رسوب را تخمین نمایند و تفاوت معنی‌داری از نظر دقت برآورد در بین مدل‌ها وجود ندارد.

از نظر سرعت عمل مدل‌ها در برآورد مدل سیستم استنتاج تطبیقی عصبی- فازی در جایگاه اول و مدل

شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در جایگاه‌های بعدی قرار دارند.

روش برنامه‌ریزی بیان ژن به دلیل ارائه رابطه ریاضی برای مدل و امکان استفاده آن رابطه برای داده‌های آینده دارای اهمیت بوده و از این نظر برای استفاده جهت مدلسازی می‌تواند نسبت به دو مدل دیگر ارجحیت داشته باشد.

استفاده از دبی کلاس‌بندی شده در مدلسازی تأثیر چشمگیری در دقت تخمین بار معلق داشته و اثر آن در نتایج آماری مدل‌ها به وضوح روشن است.

منابع

1. Alp, M., and Cigizoglu, H.K. 2007. Suspended sediment load simulation by two artificial neural network method using hydrometeorological data. *J. Environ. Model. Soft.* 22: 2-13.
2. Ardicioglu, M., Kishi, O., and Haktanir, T. 2007. Suspended sediment prediction using two different feed-forward back-propagation algorithms. *Can. J. Civ. Eng.* 34: 1. 120-125.
3. Aytek, A., and Kishi, O. 2008. A genetic programming approach to suspended sediment modeling. *J. Hydrol.* 351: 3-4. 288-298.
4. Banzhaf, W., Nordin, P., Keller, R.E., and Francone, F.D. 1998. *Genetic Programming*. Morgan Kaufmann, San Francisco, CA.
5. Bayazidi, S., Yasy, M., Fattahi, R., and Kargar A. 2005. Prediction and estimation of daily suspended load by using artificial neural networks - MLP model, 5th Iranian Hydraulic Conference, Kerman, Iran, Pp: 555-562. (In Persian)
6. Cigizoglu, H.K., and Alp, M. 2006. Generalized regression neural network in modeling river sediment yield. *J. Adv. Eng. Soft.* 37: 63- 68.
7. Cigizoglu, H.K., and Kishi, O. 2006. Methods to improve the neural network performance in suspended sediment estimation, *J. Hydrol.* 317: 3-4. 221-238.
8. Cobaner, M., Unal, B., and Kishi, O. 2008. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network using hydro-meteorological data, *J. Hydrol.* 367: 1-2. 52-61.
9. Dehghani, N., and Vafakhah, M. 2013. Comparison of daily suspended sediment load estimations by sediment rating curve and neural network models (Case study: Ghazaghi Station in Golestan Province), *J. Water Soil Cons. Res.* 20: 2. 221-230.
10. Ferreira, C. 2001a. Gene Expression Programming in Problem Solving, invited tutorial of the 6th Online World Conference on Soft Computing in Industrial Applications, September, Pp: 10-24.
11. Ferreira, C. 2001b. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*, 13: 2. 87-129.
12. Ferreira, C. 2004. Gene Expression Programming and the Evolution of Computer Programs. *Recent Developments in Biologically Inspired Computing*, Idea Group Publishing, Pp: 82-103.

13. Ferreira, C. 2010. "What is GEP?" From GeneXproTools Tutorials - A Gepsoft Web Resource. <http://www.gepsoft.com/tutorialI002.htm> Retrieved 23rd August.
14. Ghaffari Jonaghani, M., and Givechi, M. 2011. Compression classic methods with neural network for estimating suspended sediment, First Regional Water Resources Conference, University of Sistan and Baluchestan, Iran. (In Persian)
15. Goldberg, D.E. 1989. Genetic algorithms in search, optimization, and machine learning. Addison-Wesley, Reading, Mass.
16. Guven, A., and Kishi, O. 2011. Estimation of Suspended Sediment Yield in Natural Rivers Using Machine-coded Linear Genetic Programming. *Water Resour Manage.* 25: 2. 691-704.
17. Hagan, M.T., and Menhaj, M.B. 1994. Training feed-forward networks with the Marquardt algorithm. *IEEE T Neural Network*, 5: 6. 989-993.
18. Hassan Pour, F. 2000. Identifying the critical points of sedimentation and mathematical models to determine the optimal dredging interval, Case study: Sistan River, M.Sc. Thesis, Faculty of Agriculture, Tarbiat Modarres University, Tehran, 146p. (In Persian)
19. Jafari Mianaei, S., and Keshavarzi, A.R. 2010. Prediction of riverine suspended sediment discharge using fuzzy logic algorithms, and some implications for estuarine settings. *Geo-Mar Lett.* 30: 1. 35-45.
20. Jalali, M., Soleymani, K., Mojadadi, H., Omidvar, A., and Habib Nezhad-E-Roshan, M. 2007. Estimation of suspended sediment load in Abloo-Nekarood hydrometry station using sediment rating curves and artificial neural network, 4th Iranian National Conference on Watershed Science and Engineering-Basin Management, University of Tehran, Karaj, Iran.
21. Jang, J.R. 1993. ANFIS: Adaptive Network-Based Fuzzy Inference System, Proc., IEEE Conf. Trans Syst. Man Cybern. 23: 665-685.
22. Kishi, O. 2005. Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrol. Sci. J.* 50: 4. 683-696.
23. Kishi, O. 2010. River suspended sediment concentration modeling using a neural differential evolution approach. *J. Hydrol.* 389: 1-2. 227-235.
24. Kishi, O., Haktanir, T., Ardicioglu, M., Ozturk, O., Yalcin, E., and Uludag, S. 2008. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Adv Eng. Soft.* 40: 6. 438-444.
25. Koza, J. 1992. Genetic programming on the programming of computers by natural selection. MIT Press, Cambridge, MA.
26. Lopez, E.G., Poli, R., and Coello, C.A. 2004. Reusing Code in Genetic Programming. Genetic Programming, P 359-368. In: 7th European Conference, EuroGP Proceedings, Coimbra, Portugal.
27. Melesse, A.M., Ahmad, S., McClain, M.E., Wang, X., and Lim, Y.H. 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *J. Agr. Water Manage.* 98: 5. 855-866.
28. Menhaj, M.B. 2010. Foundations of Neural Networks, Amirkabir University Publication (Tehran Polytechnic), Tehran, Iran. (In Persian)
29. Mir Bagheri, S.A., and Rajaie, T. 2004. Using artificial neural networks in prediction and estimation of suspended load in rivers, First Iranian Water Resources Management Annual Conference, University of Tehran, Tehran, Iran. (In Persian)
30. Mustafa, M.R., Rezaur, R.B., Saiedi, S., and Isa, M.H. 2012. River Suspended Sediment Prediction Using Various Multilayer Perceptron Neural Network Training Algorithms - A Case Study in Malaysia. *J. Water Res. Manage.* 26: 7. 1879-1897.
31. Partal, T., and Cigizoglu, H.K. 2008. Estimation and forecasting of daily suspended sediment data using wavelet-neural networks. *J. Hydrol.* 358: 3-4. 317-331.
32. Rajaie, T. 2009. Lighvan tea station Prediction of sediment concentration in Lighvanchay station using neural networks and ANFIS, 8th International River Engineering Conference, University of Shahid Chamran, Ahvaz, Iran. (In Persian)

33. Salajegheh, A., Fath Abadi, A., and Gholami, H. 2009. estimation of suspended sediment in Taleghanrood river using ANFIS, 5th National Iranian Watershed Sciences and Engineering Conference, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. (In Persian)
34. Samani, J.M. 2004. Report on the legal infrastructure of Sistan plain water resources, Iran Water Resources Management Co., Code: 410. (In Persian)
35. Shiri, J., Sadraddini, A., and Nazemi, A. 2010. Suspended sediment modeling using adaptive neuro fuzzy inference system. 8th International River Engineering Conference. Shahid Chamran University, Ahwaz.
36. Shoushtari, Sh., and Kashefipour, M. 2007. Estimating of suspended sediment load using artificial neural networks, case study Ahvaz station, P 343-356. In: Proceeding of 7th International Conference on River Engineering, Shahid Chamran University, Ahwaz, Iran. (In Persian)
37. Tayfur, G., Ozemir, S., and Singh, V.P. 2003. Fuzzy logic algorithm for runoff-induced sediment transport from bare soil surfaces. J. Adv. Water Res. 26: 1249-1246.
38. Tehran Sahab Consulting Engineers Co. 1982. Report of the Sistan River Flood Control Studies, Tehran, Iran. (In Persian)
39. Tehran Sahab Consulting Engineers Co. 1992. Sistan River Flood control report, Tehran, Iran. (In Persian)
40. Vafakhah, M. 2012. Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting, Arab J. Geosci. 6: 8. 3003-3018.
41. Wilson, G.C., and Banzhaf, W. 2008. A Comparison of Cartesian Genetic Programming and Linear Genetic Programming, P 182-193. Conference on Genetic Programming, Naples, Italy.
42. Yang, C.T., Marsooli, R., and Aalami, M.T. 2009. Evaluation of total load sediment transport formulas using ANN. Int. J. Sed. Res. 24: 3. 274-281.



Comparison of artificial intelligence methods in estimation of suspended sediment load (Case Study: Sistan River)

Z. Sheikhalı Pour¹, *F. Hassan Pour² and V. Azimi³

¹M.Sc. Student, Dept. of Water Engineering, University of Zabol, ²Assistant Prof., Dept. of Water Engineering, University of Zabol, ³M.Sc. Graduate, Dept. of Water Engineering, Tabriz University

Received: 09/20/2013; Accepted: 05/10/2014

Abstract

Background and Objectives: Correct estimation of suspended sediments volume in rivers is one of important issues in river engineering, water resources and environment projects. *Sistan* river is one of split main branch of *Helmand* river, which task of irrigate 70% agricultural plain and is responsible for providing part of *Hamoon* water in *Helmand*. Given the many problems caused by sediment in rivers, sediment science researchers have done many effort to achieve sediment transport relations according laboratory and field studies. Because of multiplicity parameters involved in sediment transport and complexity process of erosion and transport particles, most of the sediment relationships need to solution complex mathematical equations, however, it aren't accurate results. Also regression relations between water discharge and sediment discharge aren't good correlation. Cobaner et al. (2008) is compared the potential of neuro-fuzzy technique with those of the three different artificial neural network technique in suspended sediment concentration estimation. The comparison results shown the neuro-fuzzy models perform better than the other models for the particular data sets (8). Aytek and Kişı (2008) develop an explicit model based on genetic programming. Their research's results indicated that the proposed GP formulation performs quite well compared to sediment rating curves and multi linear regression models and is quite practical for use (3).

Materials and Methods: The recent years using of smart systems in order to increase accuracy of estimating of river sediments are common. In this study were used the smart systems including Artificial Neural Networks (ANNs), Adaptive Neuro-Fuzzy Inference System (ANFIS) and Genetic Expression Programming (GEP) in order to estimation of suspended sediment load in *Sistan* River. Root mean square error (RMSE), mean bias error (MBE) and determination coefficient (R^2) statistics are used for evaluating the accuracy of the models.

Results: All smart ways estimate suspended sediment load better than empirical relations. The third scenario of ANFIS from artificial intelligence (AI) methods with RMSE=20983.43 and $R^2=0.97$ is the best result in estimation suspended sediment load. Also AI methods obtained at 95% absent aren't significant difference between results and according to error rates all AI methods are highly accurate.

Conclusion: According to the obtained results in this study used three methods to estimate the suspended sediment load are suitable but Genetic Expression Programming is preferable to the other two models because of develop a mathematical model. The dramatic impact of the classification of discharge is clear in the precision of the suspended sediment load estimation. According to this research results, suggest estimation of suspended sediment load is suggested using AI methods in *Sistan* River.

Keywords: Suspended load, *Sistan* River, ANNs, ANFIS, GEP

* Corresponding Author; Email: hassanpourir@gmail.com