

پیش‌بینی بار معلق رودخانه‌ها بر مبنای دبی جریان با استفاده از برنامه‌ریزی ژنتیک

• علی داننده مهر، دانش‌آموخته کارشناسی ارشد مهندسی رودخانه، دانشگاه صنعت آب و برق، تهران (نویسنده مسئول)
• احسان علیایی، دانش‌آموخته کارشناسی مهندسی آب، دانشگاه تبریز
• محمد علی قربانی، استادیار دانشکده کشاورزی، دانشگاه تبریز
تاریخ دریافت: آذر ماه ۱۳۸۷ تاریخ پذیرش: بهمن ماه ۱۳۸۸
تلفن تماس: ۰۹۱۴۴۱۲۶۴۸۶
Email: danandeh@pwut.ac.ir

چکیده

پیش‌بینی دقیق پارامترهای مؤثر در طرح‌های منابع آب، یکی از مهمترین مباحث تحقیقی مهندسان آب می‌باشد. از جمله این پارامترها حجم رسوبات معلق رودخانه‌ها است که بدلیل اثرات منفی آن بر روی شاخص‌های کیفی آب، تقلیل گنجایش مخازن و تغییر در مورفولوژی رودخانه‌ها از اهمیت ویژه‌ای برخوردار است. در حقیقت حصول روش‌های مناسب و دقیق در پیش‌بینی بار رسوبی رودخانه‌ها را می‌توان به عنوان یکی از مهمترین چالش‌ها در فرایند فرسایش و رسوبگذاری دانست. اگر چه در دهه اخیر تحقیقات متنوعی در خصوص کاربرد مدل‌های هیدرولوژیکی (جعبه سیاه) متکی بر شبکه‌های عصبی مصنوعی (ANN) و برتری دقت این مدل‌ها بر روابط تجربی همچون منحنی سنج رسوب ارائه شده است ولی به دلیل غیر صریح بودن این مدل‌ها استفاده از آنها در عمل به طور مناسب توسعه نیافته است. لذا هنوز توسعه یک مدل صریح میان رابطه دبی جریان و بار رسوبی ضروری می‌باشد. در تحقیق حاضر روش صریح برنامه‌ریزی ژنتیک (GP) برای پیش‌بینی بار معلق رودخانه‌ها ارائه شده و دقت نتایج حاصله با روش شبکه عصبی مصنوعی مورد مقایسه قرار گرفته است. پیش‌بینی‌ها با استفاده از دبی جریان و رسوب معلق روزانه رودخانه ليقوان چای واقع در حوزه آبخیز دریاچه ارومیه، برای مدل‌سازی و تأیید برنامه‌ریزی ژنتیک پیشنهادی بکار گرفته شده است. نتایج حاصل، حاکی از دقت بالای برنامه‌ریزی ژنتیک در مقایسه با شبکه عصبی مصنوعی و کارایی آن در پیش‌بینی بار معلق رودخانه‌ها می‌باشد.

کلمات کلیدی: بار معلق، برنامه‌ریزی ژنتیک، دبی جریان، شبکه عصبی مصنوعی

Suspended sediment load prediction based on river discharge and genetic programming method

By: A. Danandehmehr, River Engineering Expert, Power and Water University of Technology, Tehran (Corresponding Author; Tel:+989144126486), E. Olliaie, Water Engineering Expert, University of Tabriz and M. A. Ghorbani, Assistant Professor, University of Tabriz

The correct prediction of effective factors in water resource projects is one of the most important problems of water resource engineers. Suspended sediment volume carried by rivers is one of these important factors due to its negative issues in water quality, reservoirs capacity and river morphology. In fact deriving a proper method for sediment volume estimation can be one of the most important problems in erosion and sedimentation process. Although During recent decades, some black box models based on artificial neural networks (ANN), have been developed to overcome this problem and those accuracy privilege to empirical relations such as sediment rating curves have been shown, But these type of models are implicit that can not be simply used by other investigators. Therefore it is still necessary to develop an explicit model for the discharge-sediment relationship. It is aimed in this study, to develop an explicit model based on genetic programming (GP). Explicit models obtained using the GP are compared with artificial neural network technique in suspended sediment load estimation. The daily stream flow and suspended sediment data from one station on Lighvan River in Orumieh lake basin are used as a case study. The results indicate that the proposed GP method performs quite well compared to artificial neural network models and is quite practical for use.

Keywords: Suspended load, Genetic programming, Flow discharge, Artificial neural networks

مقدمه

مختلّف بر دقت بالای این روش در مقایسه با روابط تجربی و رگرسیونی تاکید نموده‌اند. Coulibaly و همکاران (۱۷) اقدام به پیش بینی نوسانات عمق سطح ایستابی در حالت‌های مختلف شبکه های عصبی مصنوعی نموده و شبکه عصبی بازگشتی را به عنوان مناسب ترین حالت معرفی نمودند. Bhattacharya و Solomatine (۱۴) از روش‌های شبکه عصبی مصنوعی و مدل M5 (از مدل های سلسله مراتبی) برای مدل سازی رابطه بین سطح آب و دبی جریان بهره بردند که بر اساس نتایج حاصل، دقت روش‌های فوق بیشتر از روش‌های معمول برآورد گردید. Makarynskyy و همکاران (۲۹) با پیش بینی نوسانات سطح آب در ناحیه مرزی بین اقیانوس هند و اقیانوس منجمد جنوبی در استرالیا بدین نتیجه دست یافتند که استفاده از روش شبکه عصبی مصنوعی سبب حصول مقادیر واقعی تری می‌شود. مطالعات ذاکر مشفق و همکاران (۳۷)، Kisi (۲۴) و همچنین Dawson و Wilby (۱۹) بر روی جریانات رودخانه‌ای حاکی از آنست که با کاربرد روش شبکه عصبی مصنوعی می توان دبی عبوری از رودخانه را با دقت قابل قبولی برآورد نمود. Alvisi و همکاران (۷) اقدام به پیش بینی سطح آب با استفاده از روش‌های شبکه عصبی مصنوعی و منطبق فازی نموده و بدین نتیجه دست یافتند که در مواردی که از اطلاعات ورودی دقیق تری استفاده به عمل آید، دقت روش شبکه عصبی مصنوعی نسبت به منطق فازی بیشتر خواهد بود.

در خصوص بهره‌گیری از مدل‌های ضمنی شبکه عصبی مصنوعی در تخمین بار معلق رودخانه‌ها Cigizoglu (۱۶) اقدام به پیش‌بینی میزان رسوبات معلق با استفاده از شبکه عصبی مصنوعی و مقایسه نتایج با روش منحنی سنجه رسوب نمود و نشان داد که شبکه عصبی مصنوعی در مقایسه با منحنی سنجه رسوب از دقت بالاتری برخوردار است. Ariffin

فرسایش و رسوب‌گذاری، یک رفتار مخرب در مراتع، اراضی کشاورزی و رودخانه‌ها است که منجر به از دست رفتن خاک حاصلخیز کشاورزی به صورت کاهش توان تولیدی و تخریب خصوصیات فیزیکی و شیمیایی خاک و اعمال خسارت هنگفت در طرح‌های منابع آب همچون، تخریب و تغییر ابعاد کانال‌های آبیاری می‌شود. از سوی دیگر رسوب انتقال یافته توسط یک رودخانه به مخازن، ظرفیت ذخیره آنها را کاهش داده و بر آب قابل استفاده برای نیروگاه های برق، آبیاری و کاربردهای صنعتی و خانگی تأثیرگذار است (۳). از این رو متخصصان همواره در جهت تخمین صحیح بار معلق رودخانه و تدقیق روش‌های موجود تلاش می‌نمایند. تاکنون روابط گوناگون و پیچیده‌ای به منظور پیش‌بینی میزان انتقال رسوبات معلق رودخانه‌ها همچون روابط مبتنی بر سرعت و تنش برشی بحرانی، ارائه شده است، لیکن روابط ارائه شده به دلیل عدم شناخت دقیق و نیز پیچیدگی سازوکار جابجایی رسوبات در بسیاری از موارد با مقادیر واقعی اندازه‌گیری شده تطابق نداشته و در مواقعی نیز میزان مقادیر محاسبه شده از روابط گوناگون تفاوت معنی داری با یکدیگر داراست. از سوی دیگر پرهزینه بودن آزمایشات مربوط به نمونه برداری رسوبات معلق رودخانه‌ها و همچنین عدم واسنجی روابط محاسباتی و پیچیدگی این روابط، محققان مختلف برقراری روابط مختلف رگرسیون خطی یا غیرخطی بین دبی جریان و بار معلق رودخانه را پیشنهاد و سالیان متمادی مورد استفاده قرار داده‌اند (۹، ۱۸، ۳۰، ۳۱، ۳۴). با گسترش روزافزون کاربرد مدل‌های رایانه‌ای در سال‌های اخیر، استفاده از مدل‌های ضمنی متکی بر شبکه‌های عصبی مصنوعی، بطور گسترده‌ای در مطالعات مربوط به پیش بینی پارامترهای مختلف منابع آب مورد استفاده قرار گرفته و محققان

از روش برنامه‌ریزی ژنتیک بدین نتیجه دست یافتند که پیش‌بینی رفتار بارش- رواناب در حوضه‌های آبریز به کمک برنامه‌ریزی ژنتیک سبب بروز خطای کمتری خواهد شد. Dorado و همکاران (۲۰) با استفاده از روش برنامه‌ریزی ژنتیک به مدلسازی بارش- رواناب در حوضه‌های شهری پرداخته و نتایج حاصله را با روش شبکه عصبی مصنوعی مورد ارزیابی قرار داده‌اند. Rabunal و همکاران (۳۲) نیز با استفاده از روش برنامه‌ریزی ژنتیک نسبت به ارائه آبنمود واحد در حوضه‌های شهری اقدام نموده‌اند. Ustoorkar و Deo (۳۵) با بکارگیری برنامه‌ریزی ژنتیک در تخمین داده‌های ناقص مربوط به ارتفاع امواج در خلیج مکزیک دریافتند که این روش از دقت بسیار مطلوبی در پیش‌بینی داده‌های مربوط به سری‌های زمانی برخوردار است. در خصوص استفاده از روش برنامه‌ریزی ژنتیک در مدل‌سازی رسوب نیز تنها سه مورد مطالعاتی مشاهده شد: Babaoric (۱۲) با استفاده از داده‌های یک فلوام آزمایشگاهی یک رابطه جدید میان بار بستر و بار معلق ارائه نموده است. Kizhisseri و همکاران (۲۵) به کمک داده‌های مشاهداتی و نتایج حاصل از یک روش عددی با استفاده از شیوه‌شناسی برنامه‌ریزی ژنتیک به ارائه یک رابطه با همبستگی بالاتر میان الگوی زمانی جریان سیال و انتقال رسوب پرداخته است. Aytel و Kisi (۱۱) نیز با مدلسازی پدیده حمل رسوب بر روی دو ایستگاه روی رودخانه تانگ^۵ ایالت مانتانا آمریکا به روش برنامه‌ریزی ژنتیک و مقایسه نتایج حاصله با منحنی سنج رسوب و روش‌های رگرسیونی، روش برنامه‌ریزی ژنتیک را به عنوان یک رهیافت مناسب جهت مدل‌سازی رسوبات معلق رودخانه‌ها معرفی نموده‌اند. هدف از تحقیق حاضر توسعه یک روش صریح برای پیش‌بینی بار معلق رودخانه‌ها بر مبنای برنامه‌ریزی ژنتیک می‌باشد. بدین منظور از داده‌های دبی جریان و رسوب معلق روزانه ثبت شده ایستگاه آبسنجی ليقوان بر روی رودخانه ليقوان چای واقع در حوزه آبریز دریاچه ارومیه، به عنوان مطالعه موردی استفاده شده و دقت نتایج حاصله از مدل برنامه‌ریزی ژنتیک با نتایج حاصل از کاربرد روش شبکه عصبی مصنوعی مورد مقایسه قرار گرفته است.

مواد و روش‌ها برنامه‌ریزی ژنتیک

برنامه‌ریزی ژنتیک که برای اولین بار توسط Koza (۲۶) ارائه شده است، جزو روش‌های الگوریتم گردشی محسوب می‌شود که مبنای تمامی آنها بر اساس نظریه تکاملی داروین استوار است. الگوریتم‌های یاد شده اقدام به تعریف یک تابع هدف در قالب معیارهای کیفی نموده و سپس تابع یاد شده را برای اندازه‌گیری و مقایسه روش‌های مختلف حل کرده و در یک فرآیند گام به گام تصحیح ساختار داده‌ها به کار گرفته و در نهایت، روش حل مناسب را ارائه می‌نمایند. برنامه‌ریزی ژنتیک جدیدترین شیوه از بین روش‌های الگوریتم گردشی می‌باشد که به دلیل دارا بودن دقت کافی، به عنوان یک روش کاربردی مطرح می‌شود (۷).

در برنامه‌ریزی ژنتیک، ابتدا بلوک‌های موجود که شامل متغیرهای ورودی و هدف و نیز تابع ارتباط دهنده آنها می‌باشند، تعریف گردیده و سپس ساختار مناسب مدل و ضرایب آن تعیین می‌شود. این روش شامل یک معادله ارتباط دهنده بین متغیرهای ورودی و خروجی بوده، لذا قادر به انتخاب خودکار متغیرهای مناسب مدل و حذف متغیرهای غیر مرتبط است که این امر سبب کاهش ابعاد متغیرهای ورودی خواهد شد. انتخاب ورودی‌های

و همکاران (۸) از مدل شبکه عصبی مصنوعی و مدل رگرسیونی خطی برای پیش‌بینی میزان رسوبات استفاده نمودند. آنها توانستند بین چهار پارامتر تاثیرگذار بر میزان رسوب و غلظت رسوبات با استفاده از دو روش مذکور روابطی برقرار نمایند. نتایج حاصله نشانگر دقت بالای روش شبکه عصبی مصنوعی نسبت به مدل رگرسیونی در تخمین رسوبات بوده است. Sarangi و Bhattacharya (۳۳) در حوزه آبریز^۶ هندوستان با استفاده از مدل‌های شبکه عصبی و رگرسیونی دبی رسوب را برای هر دو مدل برآورد نموده و نتیجه گرفتند که مدل شبکه عصبی از دقت بالاتری برخوردار است. فتاحی و همکارانش (۶) برای پیش‌بینی رسوب معلق رودخانه نکا در استان مازندران از مدل شبکه عصبی مصنوعی بهره‌جسته و برتری این روش را با خطایی حدود ۰.۰۰۰۱ به روش منحنی سنج رسوب اثبات نمودند. عباسی شوشتری و همکاران (۴) نیز دقت بالای روش شبکه عصبی مصنوعی را در مقایسه با روش‌های آماری و رگرسیونی بر روی رودخانه کارون در ایستگاه اهواز اثبات نموده‌اند. در زمینه مقایسه روش‌های شبکه عصبی مصنوعی در پیش‌بینی بار رسوبی Kisi (۲۳) میزان رسوبات معلق را با استفاده از شبکه‌های فازی-عصبی و عصبی پیش‌بینی نمود. بر اساس این تحقیق روش فازی-عصبی انعطاف‌پذیری بیشتر و نیز تطابق بیشتری با واقعیت پدیده مورد مطالعه دارا بوده است. اسدیانی یکتا و همکاران (۲) نیز با استفاده از داده‌های رودخانه دلاواری^۴ ایالت نیوجرسی آمریکا کارایی بیشتر مدل تطبیقی عصبی-فازی در پیش‌بینی غلظت رسوبات معلق نسبت به شبکه عصبی مصنوعی را نمایش داده‌اند. اگر چه در تمامی تحقیقات مذکور برتری دقت مدل‌های متکی بر شبکه‌های عصبی مصنوعی نسبت به بر روابط تجربی همچون منحنی سنج رسوب و مدل‌های رگرسیونی نشان داده شده است لیکن بدلیل غیر صریح بودن این مدل‌ها استفاده از این‌گونه مدل‌ها در عمل به طور مناسبی توسعه نیافته است. لذا توسعه یک مدل صریح میان رابطه دبی جریان و بار رسوبی ضروری می‌باشد. در تحقیق حاضر یک مدل صریح برای تخمین بار معلق رودخانه‌ها بر مبنای برنامه‌ریزی ژنتیک ارائه می‌شود.


از برنامه‌ریزی ژنتیک به طور وسیعی در کاربرد هوش مصنوعی در مسائل مهندسی آب و تعیین ساختار پدیده‌ها استفاده شده است. از این روش به طور موفقیت‌آمیزی می‌توان در شرایط زیر بهره‌جست: (۱) هرگاه تشخیص ارتباط داخلی میان متغیرهای وابسته بسیار پیچیده باشد (۲) یافتن اندازه و یا شکل متغیر نهایی بسیار پیچیده است (۳) حل تحلیلی مسئله به روش‌های ریاضی متداول غیر ممکن و یا بسیار پیچیده بوده ولی حصول جواب‌های تقریبی کفایت می‌کند (۴) اصلاحات جزئی و متداول اجرایی بر روی نتایج به راحتی قابل لحاظ و اندازه‌گیری می‌باشد (۵) حجم بالای داده‌های ورودی نیازمند به آزمون و طبقه‌بندی (مانند زنجیره DNA در مباحث زیست مولکولی، داده‌های ماهواره‌ای و یا داده‌های مربوط به امور مالی و بانکی) (۱۱).

مطالعات کتابخانه‌ای انجام شده نشان می‌دهد که تحقیقات اندکی در خصوص کاربرد برنامه‌ریزی ژنتیک در زمینه مهندسی منابع آب صورت گرفته است. Khu و همکاران (۲۲) در یک تحقیق در مورد حوضه آبریز اورگوال فرانسه، از برنامه‌ریزی ژنتیک برای پیش‌بینی رواناب بهره‌برده و نتایج حاصل را با مقادیر مشاهداتی و نیز مقادیر محاسبه شده توسط روش‌های کلاسیک مورد مقایسه قرار دادند. حاصل تحقیق، بیانگر دقت قابل قبول برنامه‌ریزی ژنتیک می‌باشد. Babovic و Keijzer (۱۳) و همچنین Liong و همکاران (۲۸) به مدل‌سازی بارش- رواناب با استفاده

تکرار خواهد شد (۱۱، ۱۵).

به عنوان نمونه کاربرد برنامه ریزی ژنتیک در مدل سازی معادله درجه دوم در شکل های ۲ تا ۳ نشان داده شده است. فرض کنیم a, b و c سه متغیر ورودی مربوط به معادله درجه دوم باشند. ساختار درختی برنامه ساده

شکل ۲- ساختار درختی برنامه $(2 \times a) \left(b + \sqrt{b^2 - 4 \times a \times c} \right)$ در شکل ۲ نشان داده شده است (۲۷). با توجه به مراحل چهار گانه فرآیند برنامه ریزی ژنتیک که در بخش



شکل ۲- ساختار درختی برنامه $(2 \times a) \left(b + \sqrt{b^2 - 4 \times a \times c} \right)$

قبل مورد بررسی قرار گرفت، روند حل برنامه نشان داده شده در شکل ۱ به صورت زیر خواهد بود:

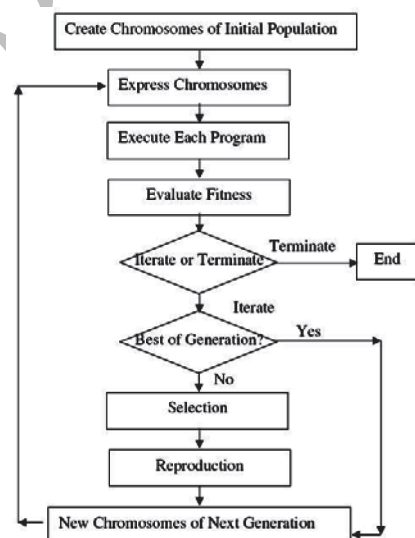
ایجاد کروموزومها از جمعیت اولیه: یک جمعیت از درخت های ممین برنامه به صورت اولیه تشکیل داده و فرآیند ژنتیک بر روی این درختان عمل می شود تا افراد جامعه با کمک دنباله پایانه ها (T) و دنباله توابع (F) تولید شوند. بر این اساس برای شکل ۱ می توان نوشت: $\{a, b, c, 4, 2\} \subseteq T$ دنباله پایانه ها:

$\{-, +, \times, \sqrt, / \} \subseteq F$ دنباله توابع:


به منظور تولید یک جمعیت تصادفی بایستی به نحوی اقدام به گزینش تصادفی از مجموعه $T \cup F$ نمود تا تمامی شاخه ها به پایانه ها منتهی شوند.

مناسب مدل یکی از مهم ترین مواردی است که بایستی در این روش مورد توجه قرار گیرد. این امر در شرایطی که از داده های ورودی ثانویه نیز بهره برده می شود، از اهمیت مضاعفی برخوردار خواهد بود. چرا که ارائه داده های ورودی غیر مرتبط، سبب کاهش دقت مدل و ایجاد مدل های پیچیده تری می گردد که تفسیر آنها با دشواری های بیشتری مواجه است.

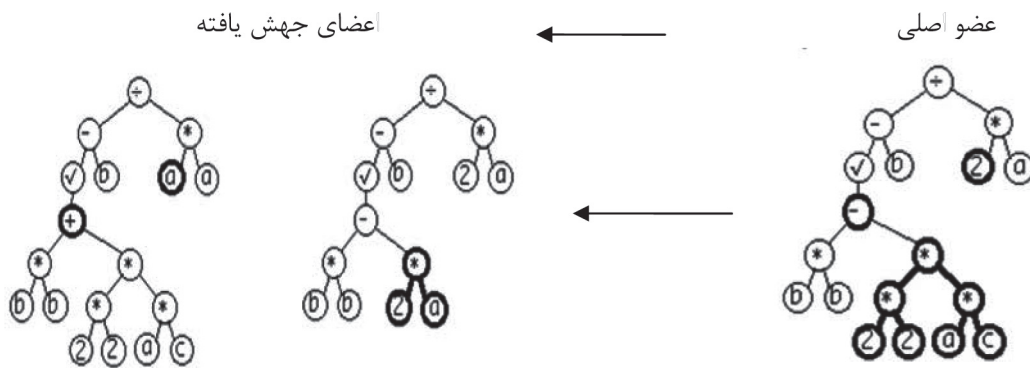
در کاربردهای مهندسی، از برنامه ریزی ژنتیک به طور وسیعی در مدل سازی مسائل مربوط به تعیین ساختار پدیده ها استفاده می شود. فرآیند گام به گام برنامه ریزی ژنتیک به صورت مراحل زیر است: (۱) یک جمعیت اولیه از توابع مرکب نشان دهنده مدل های پیش بینی، به صورت تصادفی در نظر گرفته می شود (ایجاد کروموزومها). (۲) معرفی جمعیت اولیه (کروموزومها) به رایانه و ارزیابی هر یک از افراد (ژن) جمعیت مذکور با استفاده از توابع برازش (شناسایی موثرترین افراد در ماهیت پدیده). (۳) انتخاب ژن های موثر به منظور تکثیر، جهش، جفت گیری و تولید مثل افراد جدید با صفات اصلاح شده (فرزندان). (۴) اعمال فرآیند توسعه ای تکراری بر روی فرزندان در هر تولید. مطابق شکل ۱ گام چهارم به تعداد معین و یا تا حصول بهترین پاسخ



شکل ۱ - فلوچارت برنامه ریزی ژنتیک (۱۱)



شکل ۳- عملیات تلاقی با والدین مختلف



شکل ۳- عملیات جهش

به انجام محاسبات لازم می‌نمایند. یک شبکه عصبی شامل چندین نرون یا گره‌های محاسباتی می‌باشد و در مواردی که از ورودی‌های وزن دار بهره برده شود، این گره‌ها قادر به تولید خروجی‌های متناسب با آن با استفاده از توابع تبدیلی خواهد بود. هر لایه ممکن است از چندین عصب تشکیل شود و هر شبکه عصبی مصنوعی نیز شامل یک یا چندین لایه متصل به هم خواهد بود. در شکل ۵ ساختار یک شبکه عصبی سه لایه‌ای متشکل از یک لایه ورودی I ، یک لایه مخفی H ، و یک لایه خروجی O نشان داده شده است.

عناصر اصلی یک شبکه عصبی، عصب‌ها یا نرون‌های مصنوعی هستند. الگوی ورودی به یک گره شبیه دندریت یک سلول بیولوژیک است که می‌توان آن را با برداری با n متغیر یا نرون به صورت $X = (x_1, x_2, \dots, x_n)$ نشان داد. مجموع حاصلضرب ورودی‌ها در وزن‌های نظیرشان را می‌توان با کمیت اسکالر s نمایش داد:

$$s = \sum_{n=1}^N w_n \cdot x_n = W^T \cdot X \quad (1)$$

که در آن $W = (w_1, w_2, \dots, w_n)$ بردار وزن نرون‌ها است. کمیت s سپس وارد یک تابع غیر خطی f می‌شود تا خروجی را نتیجه دهد:

$$y = f(s) \quad (2)$$

تابع غیر خطی انتقال معمولاً به فرم یک تابع حلقوی به صورت زیر تعریف می‌شود:

$$f(s) = (1 + \exp(-s))^{-1} \quad (3)$$

خروجی y می‌تواند نتیجه مدل و یا ورودی لایه بعدی در شبکه‌های چند لایه باشد. الگوریتم‌های مختلفی جهت محاسبه وزن‌های بهینه ارائه شده‌است که در این میان الگوریتم "پس انتشار خطا" پرکاربردترین آن‌هاست. شبکه‌هایی که در این تحقیق به منظور مدل‌سازی فرایند انتقال رسوب استفاده شده‌اند از نوع شبکه‌های پرسپترون چند لایه (MLP) هستند. این شبکه‌ها به صورت پیشرو عمل نموده و در ساختار تمامی آنها سعی شده تا حتی الامکان طراحی بهینه با یک لایه میانی صورت پذیرد. آموزش شبکه‌های MLP با استفاده از الگوریتم آموزش پس انتشار خطا انجام می‌شود. فرایند عملکرد این شبکه‌ها بدین نحو است که لایه ورودی، نسبت به پذیرش داده‌ها اقدام نموده و لایه (لایه‌های) میانی عمل فرآوری داده‌ها را انجام می‌دهند. در

تلاقی

از درون برنامه اخیر اقدام به انتخاب دو ژن تصادفی (والد) گردیده و سپس زیر درخت‌های حاصل شده از دو والد تعویض می‌گردند و بدین ترتیب یک برنامه جدید نظیر آنچه در شکل ۳ دیده می‌شود بدست می‌آید.

جهش

مطابق شکل ۴ در مرحله جهش یک زیر درخت به طور تصادفی با یک زیر درخت دیگر جابجا می‌شود.


تولید مثل

این مرحله به معنی اجرای مجدد برنامه است و این امر در صورتی انجام می‌پذیرد که معیارهای برازش، صحت برنامه را تایید نمایند.

در این تحقیق به روشی مشابه روش فوق برای مدل‌سازی رسوب معلق رودخانه لیقوان‌چای بر اساس اطلاعات رسوب و دبی جریان روزهای قبل استفاده شده و نتایج حاصله با روش شبکه عصبی مصنوعی مورد ارزیابی قرار خواهد گرفت. لذا در ادامه مروری اجمالی بر روش شبکه‌های عصبی مصنوعی نیز ارائه می‌شود.

شبکه‌های عصبی مصنوعی

این شبکه‌ها با تقلید از شبکه‌های عصبی موجود در موجودات زنده و با استفاده از تعداد بسیار زیادی از عصب‌های مصنوعی به هم پیوسته اقدام



شکل ۵- ساختار یک شبکه عصبی مصنوعی (۱۰)

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (6)$$

که در آنها، x_i مقدار مشاهده شده در گام زمانی i ام، y_i مقدار محاسبه شده در همان زمان، N تعداد گام‌های زمانی، \bar{x} میانگین مقادیر مشاهداتی و \bar{y} نیز میانگین مقادیر محاسباتی می‌باشد. کم بودن میزان RMSE و بالا بودن ضریب R بیانگر دقت قابل قبول مدل و برتری آن نسبت به مدل دیگر است.

منطقه مورد مطالعه

تحقیق حاضر بر اساس داده‌های ثبت شده ایستگاه آبخیزداری ليقوان واقع بر روی رودخانه ليقوان جای انجام پذیرفته است. حوزه آبخیز ليقوان چای یکی از زیرحوزه‌های دریاچه ارومیه بوده و با وسعتی معادل ۷۶ کیلومتر مربع در دامنه شمالی سهند بین طول‌های شرقی "۳۰'۲۰-۴۶° تا "۳۰'۲۷-۴۶° و عرض‌های شمالی "۵۵'-۴۲-۳۷° تا "۳۰'-۴۹-۳۷° گسترده شده است (شکل ۶). به طور کلی حوزه آبریز ليقوان به علت وجود پوشش‌های برفی دائمی در ارتفاعات مختلف آن دارای رژیم برفی است. ذوب برف در دبی جریان و انتقال رسوب معلق آن مؤثر و قابل ملاحظه است. ریزش باران در ماه‌های بهار و تابستان شدید است و این اثر قابل توجهی در بالا بردن مقدار دبی رودخانه دارد (۵). داده‌ها شامل اندازه‌گیری دبی روزانه جریان و دبی رسوب روزانه در سال‌های ۱۳۵۰ الی ۱۳۸۱ می‌باشد که در این تحقیق از داده‌های شش سال اخیر به عنوان جمعیت اولیه استفاده شده است. بررسی داده‌ها و مشاهدات به عمل آمده حاکی از آنست که میزان رسوبات معلق دارای نوسانات فصلی قابل توجهی بوده و حداکثر میزان رسوبات مربوط به اواخر فصل بهار و اوایل فصل تابستان می‌باشد. این امر ناشی از تأثیر قابل

نهایت، لایه خروجی نیز به نمایش خروجی‌های حاصل از کاربرد مدل اقدام می‌نماید. در طی مرحله مدل‌سازی، ضرایب مربوط به خطای موجود در گره‌ها به صورت سعی و خطا تصحیح می‌شود که در اغلب موارد از شاخص خطای متوسط داده‌ها بهره برده می‌شود. این امر از طریق مقایسه خروجی‌های مدل با داده‌های ورودی مشاهداتی انجام می‌پذیرد.

نرمال‌سازی داده‌ها

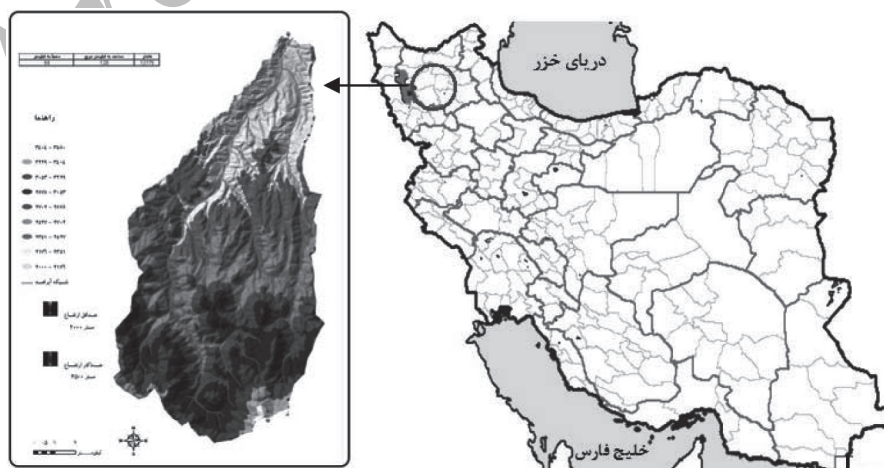
اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای احراز از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی صورت گرفته است که این کار مانع از کوچک شدن بیش از حد وزن‌ها و باعث جلوگیری از اشباع زود هنگام نرون‌ها می‌شود. غالباً، نرمال کردن داده‌ها در بازه (۰/۹ و ۰/۱) صورت می‌گیرد. در این تحقیق کلیه داده‌های ورودی قبل از اعمال به شبکه با استفاده از رابطه زیر نرمال شده‌اند:

$$X_{normal} = 0.1 + 0.8 \times \left(\frac{X_0 - X_{min}}{X_{max} - X_{min}} \right) \quad (4)$$

که در این رابطه X_{normal} مقدار نرمال شده، X_0 مقدار مشاهده شده، X_{min} و X_{max} به ترتیب مقادیر ماکزیمم و مینیمم داده‌ها می‌باشند. در هر دو مدل برنامه‌ریزی ژنتیک و شبکه‌های عصبی مصنوعی داده‌ها برای آموزش و آزمون به دو دسته تقسیم می‌شوند. در این تحقیق ۸۳/۳ درصد داده‌ها به عنوان داده‌های آموزش و ۱۶/۷ درصد داده‌ها به عنوان داده‌های آزمون در نظر گرفته شده است.

معیارهای ارزیابی

برای ارزیابی مدل‌های مورد نظر از شاخص‌های ضریب همبستگی و جذر میانگین مربعات خطا بهره برده شده است که به ترتیب با استفاده از روابط زیر قابل محاسبه می‌باشند:



شکل ۶- محدوده جغرافیایی و حوزه آبخیز رودخانه ليقوان چای (علیانی و همکاران ۱۳۸۷).

نیز بایستی سعی نمود موثرترین داده‌های مشاهداتی را به عنوان داده‌های آموزشی انتخاب کرد. در تحقیق حاضر نیز به منظور پیش‌بینی بار معلق روزانه، صرفاً از داده‌های نرمال شده دبی جریان مربوط به همان روز به همراه دبی جریان و بار رسوبی معلق روزهای قبل (تا ۵ روز) به عنوان داده‌های آموزشی، به صورت ترکیب‌های مختلف استفاده شده است. این ترکیب‌های مختلف که همان جمعیت اولیه یا کروموزم های ورودی به برنامه می‌باشند مطابق روابط ذیل معرفی شده و از این پس از آنها به عنوان الگو نام برده خواهد شد. به عبارت دیگر برای تعیین بهترین مدل، الگوهای مختلفی به برنامه‌ریزی ژنتیک معرفی می‌شود و در نهایت از بین الگوهای مختلف، الگویی که در ارزیابی مقایسه‌ای، بهترین نتایج را ایجاد می‌کند به عنوان مناسب‌ترین مدل انتخاب می‌شود. الگوهای پیشنهادی در این تحقیق عبارتند از:

$$1: S_t = f(Q_t)$$

$$2: S_t = f(Q_t, S_{t-1}, Q_{t-1})$$

$$3: S_t = f(Q_t, S_{t-1}, Q_{t-1}, S_{t-2}, Q_{t-2})$$


$$4: S_t = f(Q_t, S_{t-1}, Q_{t-1}, S_{t-2}, Q_{t-2}, S_{t-3}, Q_{t-3})$$

ملاحظه ذوب برف در ماه‌های مذکور می‌باشد. نوسانات مشاهده شده بین ۰/۰ (برای دبی پایه صفر) و ۱۲۵ تن در روز (اردیبهشت ۱۳۷۸) می‌باشد. داده‌های مشاهداتی مربوط به سال‌های ۱۳۷۵ تا ۱۳۸۰ به منظور تعیین مدل مناسب (داده‌های آموزش) مورد استفاده قرار گرفته و از داده‌های مربوط به سال ۱۳۸۱ در آزمون (صحت‌سنجی) مدل‌های مورد نظر بهره برده شد. شکل ۷ نمودار نوسانات دبی جریان و دبی رسوب معلق در دوره زمانی یاد شده را نشان می‌دهد. در جدول ۱ نیز مشخصات آماری داده‌های مشاهداتی ایستگاه آب‌سنجی لبقوان ارائه شده است.

نتایج

مدلسازی رسوب معلق به روش برنامه‌ریزی ژنتیک

همان‌گونه که پیشتر نیز ذکر شد، انتخاب جمعیت‌های اولیه تصادفی مختلف و تاثیرگذار در پدیده (که در برنامه‌ریزی ژنتیک به عنوان داده‌های آموزشی از آنها یاد می‌شود)، به منظور آموزش ماهیت سازوکار حاکم بر پدیده، نه تنها سبب پیچیدگی مدل و افزایش حافظه درگیر خواهد شد، بلکه سبب کاهش دقت مدل نیز می‌شود. لذا در مدلسازی بار رسوب معلق



شکل ۷- مقادیر مشاهداتی دبی جریان و دبی رسوب روزانه در دوره شش ساله

جدول ۱- مشخصات آماری داده‌های ایستگاه آب‌سنجی لبقوان به صورت خام و نرمال

مشخصه آماری	دبی خام جریان (m ³ /s)	دبی خام رسوب (ton/day)	دبی نرمال جریان (m ³ /s)	دبی نرمال رسوب (ton/day)
تعداد داده‌ها	۲۱۸۷	۲۱۸۷	۲۱۸۷	۲۱۸۷
مقدار حداکثر	۵/۳۸	۱۲۴/۵۷	۰/۹	۰/۹
مقدار حداقل	۰/۰	۰/۰	۰/۱	۰/۱
میانگین	۰/۶۶	۶/۳۲	۰/۱۹۸	۰/۱۴۱
واریانس	۰/۵۴۴	۱۰۵/۶۵	۰/۰۱۲	۰/۰۰۴۴
انحراف معیار استاندارد	۰/۷۳۸	۱۰/۲۸	۰/۱۰۹	۰/۰۶۶

ضریب همبستگی مطلوب را نشان می‌دهد. (۴) حداکثر تعداد برنامه‌هایی را نشان می‌دهد که بایستی مورد ارزیابی واقع شوند. (۵) تعداد افراد هر جمعیت را نشان می‌دهد. (۶) نرخ جهش تصادفی بین زیر درخت‌های مجاور را نشان می‌دهد. (۷) نرخ تلاقی تصادفی بین زیر درخت‌های مجاور را نشان می‌دهد. در جدول ۳ مشخصات آماری حاصل از اجرای مدل برنامه ریزی ژنتیک ارائه شده است. همانگونه که در این جدول مشاهده می‌شود مدل GP با الگوی ورودی ۳ که دبی و رسوب را تا دو روز قبل مد نظر قرار می‌دهد دارای کمترین مقدار جذر میانگین مربعات خطا (۰/۰۰۱) بوده و در آن ضریب همبستگی بسیار به ۱ نزدیک شده است.

این بدان معنی است که اگرچه از روز سوم به بعد تعداد پارامترهای دخیل در پیش‌بینی رسوب افزایش می‌یابد ولی این افزایش صرفاً بر پیچیدگی مدل افزوده و نتایج پیش‌بینی را رفته رفته ضعیف‌تر می‌کند. لذا الگوی ورودی شماره ۳ به عنوان بهترین مدل پیشنهادی برای تخمین رسوب معلق رودخانه لیقوان چای معرفی می‌شود. همچنین اجرای GP با الگوی ورودی اول که فقط دبی جریان روزانه را در نظر می‌گیرد، ضعیف‌ترین نتایج را در بر دارد و این موضوع نشانگر تاثیر بالای حرکت رو به عقب در پیش‌بینی بار رسوبی است.

مدلسازی رسوب معلق به روش شبکه عصبی مصنوعی

به منظور بررسی دقت برنامه‌ریزی ژنتیک و کنترل صحت نتایج، از مدل ضمنی شبکه عصبی مصنوعی با همان الگوهای ورودی و داده‌های ورودی نرمال استفاده شده است. بدین منظور برای هر کدام از الگوهای ورودی با تغییر در تعداد لایه‌های پنهان و تعداد نرونهای لایه پنهان، شبکه‌های عصبی مختلفی ساخته شده و پس از آموزش به کمک داده‌های مربوط به ۵ سال اول، بهترین ساختار برای هر الگو انتخاب شده است. محاسبات مربوط به ANN توسط نرم افزار Qnet ۲۰۰۰ انجام شده و مشخصات آماری حاصل در جدول ۴ ارائه شده است. نتایج نشان می‌دهد با لحاظ داده‌های مربوطه تا روز چهارم، رفته رفته مدل رو به بهبود بوده ولی بعد از روز چهارم نتایج رفته رفته ضعیف‌تر می‌شوند. اگرچه تغییرات ضریب همبستگی از ۱ روز قبل الی ۵ روز قبل بسیار ناچیز بوده و نمی‌توان بین الگوهای ۲ تا ۶ به صورت

جدول ۴- مشخصات آماری نتایج شبکه عصبی مصنوعی

الگوهای ورودی	تعداد گره در لایه مخفی	آموزش		آزمون	
		RMSE	R	RMSE	R
۱	۳	۰/۰۳۶	۰/۸۶۴	۰/۱۱۷	۰/۹۴۱
۲	۴	۰/۰۱۸	۰/۹۶۷	۰/۰۲۹	۰/۹۱۲
۳	۲	۰/۰۱۶	۰/۹۷۴	۰/۰۲۳	۰/۸۹۲
۴	۲	۰/۰۱۶	۰/۹۷۵	۰/۰۲۱	۰/۸۶۱
۵	۲	۰/۰۱۵	۰/۹۷۷	۰/۰۲۱	۰/۸۹۱
۶	۲	۰/۰۱۸	۰/۹۶۶	۰/۰۲۲	۰/۸۷۱

$$5: S_t = f(Q_t, S_{t-1}, Q_{t-1}, S_{t-2}, Q_{t-2}, S_{t-3}, Q_{t-3}, S_{t-4}, Q_{t-4})$$

$$6: S_t = f(Q_t, S_{t-1}, Q_{t-1}, S_{t-2}, Q_{t-2}, S_{t-3}, Q_{t-3}, S_{t-4}, Q_{t-4}, S_{t-5}, Q_{t-5})$$

که در آن Q_t و S_t به ترتیب بیانگر دبی جریان روز و دبی رسوب همان روز بوده و Q_{t-1} و S_{t-1} به ترتیب دبی جریان و دبی رسوب در یک روز قبل (همگی به صورت نرمال) می‌باشد و به همین ترتیب الگوهای ورودی تا ۵ روز قبل در نظر گرفته شده است.

جهت معرفی الگوها به رایانه و شناسایی موثرترین داده‌ها در ماهیت انتقال رسوب با استفاده از توابع برازش و انجام فرایندهای توسعه‌ای و تکرار از نرم‌افزار Discipulus محصول انستیتو فنی رجیستر^۷ با مشخصات برنامه‌ریزی مطابق جدول ۲ استفاده شده است. توضیح مفاهیم بکار رفته در این جدول به ترتیب بدین شرح می‌باشد (۲۱): (۱) مؤلفه‌ای است که بر اساس آن معیار توقف اجرای برنامه در هر گام دلخواه تنظیم می‌شود. (۲) بر اساس این معیار می‌توان تعداد تولید جمعیت در هر یک از مراحل اجرای برنامه را تنظیم نمود. (۳) تعداد برنامه‌های اجرا شده در هر مرحله به منظور نیل به

جدول ۲- مشخصات برنامه‌ریزی ژنتیک بکار گرفته شده در تحقیق حاضر

مقدار عددی	معیار مورد نظر	ردیف
۱۵۰	تولید بدون بهبود	۱
۲۰۰	تولید از زمان شروع	۲
۱۰۰	حداکثر مقدار اجرا	۳
۲۵۶	اندازه حدکسر برنامه	۴
۲۰۰	اندازه جمعیت	۵
٪ ۹۵	نرخ جهش	۶
٪ ۲۰	نرخ تلاقی	۷

جدول ۳- مشخصات آماری نتایج برنامه‌ریزی ژنتیک

الگوهای ورودی	تعداد اجرا	آموزش		آزمون (صحت سنجی)	
		RMSE	R	RMSE	R
۱	۱۰۰	۰/۰۴۵	۰/۸۷۸	۰/۰۴۴	۰/۹۵۱
۲	۱۰۰	۰/۰۱۵	۰/۹۸۲	۰/۰۰۳	۰/۹۱۴
۳	۱۰۰	۰/۰۰۱	۰/۹۹۹	۰/۰۰۲	۰/۹۵۳
۴	۱۰۰	۰/۰۱۶	۰/۹۷۹	۰/۰۰۶	۰/۷۸۴
۵	۱۰۰	۰/۰۱۷	۰/۹۷۴	۰/۰۰۶	۰/۷۶۱
۶	۱۰۰	۰/۰۱۸	۰/۹۷۳	۰/۰۰۷	۰/۷۵۸

است. از سوی دیگر نمودار توزیع رسوبات روزانه پیش‌بینی شده به روش شبکه عصبی مصنوعی نشان می‌دهد که این روش برای برخی مقادیر پایین بار معلق، مقدار منفی پیش‌بینی می‌نماید که این امر به لحاظ فیزیکی غیر ممکن است در صورتیکه روش برنامه‌ریزی ژنتیک تمام مقادیر پیش‌بینی را به صورت مثبت ارائه نموده است.


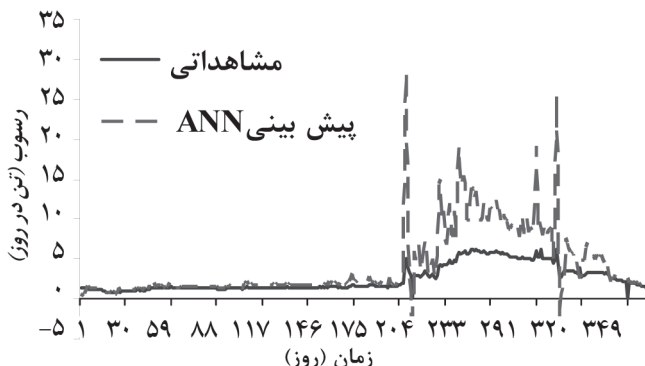

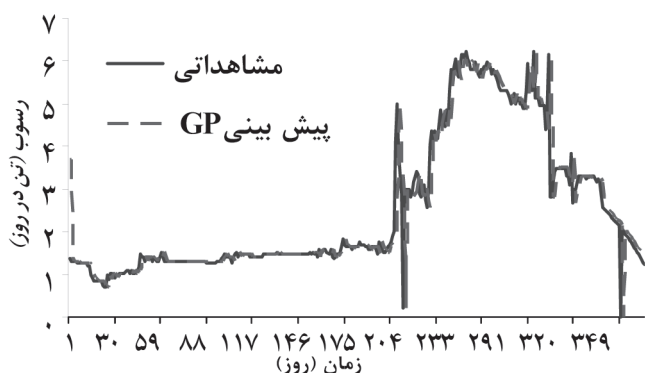
نتیجه‌گیری

در مجموع مطالعه انجام شده، روش برنامه‌ریزی ژنتیک را به عنوان یک روش دقیق و عملی برای مدلسازی رابطه بین دبی جریان و بار معلق معرفی می‌نماید. دقت بالای نتایج حاصل از این روش در مقایسه با روش شبکه عصبی مصنوعی در کنار نتایج حاصل از تحقیقات سایر محققان که حاکی از برتری دقت روش شبکه‌های عصبی مصنوعی نسبت به روشهای آزمایشگاهی و روابط رگرسیونی خطی و غیرخطی (۱، ۸، ۱۶، ۳۳، ۳۶) می‌باشد از یک سو و سادگی استفاده از این روش و عدم نیاز به دانش بالای میانی ریاضی الگوریتم و برنامه‌ریزی ژنتیک از سوی دیگر موید قابلیت این روش به عنوان یک ابزار مفید و سریع در حل مسائل منابع آب همچون تخمین بار معلق رودخانه‌ها است. اگرچه با علم بر میانی ریاضی الگوریتم ژنتیک و یا سایر روش‌های بهینه‌سازی پیشرفته همچون روش‌های جستجوی تابو، کولونی مورچه‌ها و ... می‌توان معادله صریح حاکم بر پیش‌بینی را استخراج نمود. استخراج این رابطه و مقایسه دقت آن با نتایج حاصل از روشهای بهینه‌سازی پیشرفته‌تر می‌تواند به عنوان موضوع تحقیق دیگری مطرح شود.

قاطع تصمیم‌گیری کرد ولی به منظور مقایسه نتایج با نتایج حاصل از روش برنامه‌ریزی ژنتیک، الگوی ورودی شماره ۵ با ضریب همبستگی ۰.۹۷۷ به عنوان بهترین مدل ANN انتخاب شده است.

بحث

شاخص‌های آماری مربوط به نتایج حاصل از کاربرد روش‌های برنامه‌ریزی ژنتیک و شبکه عصبی مصنوعی در شبیه‌سازی تغییرات بار معلق در جداول شماره ۳ و ۴ ارائه گردید. از مقایسه جداول یاد شده چنین بر می‌آید که در تمامی الگوهای ورودی چه در مرحله آموزش و چه در مرحله آزمون، برنامه‌ریزی ژنتیک نسبت به شبکه‌های عصبی مصنوعی از RMSE کمتری برخوردار است. اگرچه در مرحله آزمون مقدار ضریب همبستگی روش شبکه عصبی مصنوعی در الگوهای ۴، ۵ و ۶ نسبت به روش برنامه‌ریزی ژنتیک بالاتر است ولی به دلیل پایین بودن مقادیر RMSE در روش برنامه‌ریزی ژنتیک، دقت این روش در مرحله آزمون نیز به مراتب بالاتر از روش شبکه‌های عصبی مصنوعی است. اثبات این موضوع در شکل ۸ با مقایسه نتایج حاصل از پیش‌بینی بار معلق رودخانه به روش‌های برنامه‌ریزی ژنتیک و شبکه‌های عصبی مصنوعی در مقایسه با رسوب معلق مشاهده شده در دوره آزمون نشان داده شده است. در این شکل دقت بالای برنامه‌ریزی ژنتیک در پیش‌بینی بار معلق بدلیل همبستگی بالای میان رسوبات پیش‌بینی شده با مقادیر رسوبات معلق مشاهده شده نسبت به روش شبکه عصبی مصنوعی کاملاً مشهود



شکل ۸- مقایسه بار معلق مشاهده شده و پیش‌بینی شده دوره آزمون به روش GP و ANN

11- Ayttek, A., and Kisi. O. (2008) A genetic programming approach to suspended sediment modeling. *J. Hydrol.*, 351, 288-298

12- Babovic, V. (2000) Data mining and knowledge discovery in sediment transport. *Comput.-Aided Civ. Infrastruct. Eng.* 15 (5), 383-389.

13- Babovic, V. and Keijzer. M. (2002) Declarative and preferential bias in GP-based scientific discovery. *Genet. Program. Evol. Mach.* 3(1).

14- Bhattacharya, B., and Solomatine. D.P. (2005) Neural networks and M5 model trees in water level- discharge relationship. *Neurocomputing*.63, 381-396.

15- Borelli, A., De Falco, I., Della, C.A., Nicodemi, M. and Trautteur, G. (2006) Performance of genetic programming to extract the trend in noisy data series. *Physica A.* 370, 104-108.

16- Cigizoglu, H. (2002) Suspended sediment estimation for rivers using artificial neural networks and sediment rating curves. *Turkish journal Eng. Env. Sci*

17- Coulibaly, p., Ancil, F., Aravena, R. and Bobee. B. (2001) Artificial neural network modeling of water table depth fluctuation. *Water Resources. Res.* 37(4), 885-896.

18- Crowder, D.W., Demissie, M. and Markus. M. (2007) The accuracy of sediment loads when log-transformation produces nonlinear sediment load-discharge relationships. *J. Hydrol.* 336, 250- 268.

19- Dawson C .W. and Wilby. R. (1998) A comparison of artificial neural network used for river flow forecasting, *J. of Hydrology and Earth System Sciences*, 3(4), 529-540.

20- Dorado, J., Rabunal, J.R., Pazos, A., Rivero, D., Santos, A. and Puertas., J. (2003) Prediction and modelling of the rainfall-runoff transformation of a typical urban basin using ANN and GP. *Appl. Artif. Intell.* 17, 329-343.

21- Franco, D.F. (2000) *Discipulus TM Software Owner's Manual*, Version 3.0 Register Machine Learning Technologies, Inc., Littleton, Colorado.

22- Khu, S.T., Liong, S.Y., Babovic, V., Madsen, H., and Muttill, N. (2001) Genetic programming and its application in real- time runoff forming. *J. Am. Water Res. Assoc.* 37(2), 439-451.

23- Kisi, O. (2000) Suspended sediment estimation using neuro-fuzzy and neural network approaches, *Hydrological Sciences Journal*, IAHS Press

24- Kisi, O. (1999) River flow modeling using artificial network, *J. of Hydrology*, Vol.214, 32-48.

25- Kizhisseri, A.S., Simmonds, D., Rafiq, Y., Borthwick, M., (2005) *An Evolutionary computation approach to sediment transport modeling*. Fifth International Conference on Coastal Dynamics,

پاورقی‌ها

- 1- Artificial Neural Networks
- 2- Genetic Programming
- 3- Banha
- 4- Delaware
- 5- Tongue
- 6- Training Data
- 7- Register Machine Learning Technologies Inc

منابع مورد استفاده

۱- آوریده، ف. بنی حبیب م.ا. و طاهرشمسی.ا. (۱۳۸۰) کاربرد شبکه‌های عصبی مصنوعی جهت تخمین دبی رسوب رودخانه‌ها. مجموعه مقالات سومین کنفرانس هیدرولیک ایران، تهران، دانشکده فنی دانشگاه تهران. ص ۲۶۹-۲۷۵.

۲- اسدیانی یکتا، ا.ح. و سلطانی. ف. (۱۳۸۵) تخمین میزان رسوبات معلق رودخانه با استفاده از مدل تطبیقی عصبی فازی و شبکه عصبی مصنوعی. مجموعه مقالات هفتمین سمینار بین المللی مهندسی رودخانه (لوح فشرده)، اهواز، دانشگاه شهید چمران.

۳- تلوری، ع. ن. بیرودیان و منوچهری.ا. (۱۳۸۶) مدلسازی تغییرات زمانی رسوب مطالعه موردی حوزه آبریز گاران در کردستان. فصلنامه پژوهش و سازندگی در منابع طبیعی، شماره ۷۵، ص ۶۴-۷۰.

۴- عباسی شوشتری، ش. و کاشفی پور. س.م. (۱۳۸۵) برآورد بار معلق رسوب با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی ایستگاه اهواز). مجموعه مقالات هفتمین سمینار بین المللی مهندسی رودخانه (لوح فشرده)، اهواز، دانشگاه شهید چمران.

۵- علیانی، ا. م. قربانی ع. و جباری خامنه. ح. (۱۳۸۷) عملکرد حافظه مدل اتورگرسیو و شبکه‌های عصبی مصنوعی در پیش بینی جریان روزانه رودخانه لیقوان. مجموعه مقالات سومین کنفرانس مدیریت منابع آب ایران (لوح فشرده)، تبریز، دانشگاه تبریز.

۶- فتاحی، م. س. طوسی و ضیاء تبار احمدی. م.خ. (۱۳۸۵) تخمین میزان رسوب رودخانه نکا به روش شبکه عصبی مصنوعی. مجموعه مقالات هفتمین سمینار بین المللی مهندسی رودخانه، اهواز، دانشگاه شهید چمران.

7- Alvisi, S., Mascellani, G., Franchini, M., and Bardossy. A. (2005) Water level forecasting through fuzzy logic and artificial neural network approaches. *Hydrol. Earth Sys. Sci. Discuss.*, 2, 1107-1145.

8- Ariffin, J., Abdul Ghani, A., Zakaria, N. and Shukri Yahya, A. (2003) *Sediment prediction using ANN and regression approach*, 1st International Conference on Managing rivers in the 21st Century: Issues & Challenges

9- Asselman, N.E.M. (2000) Fitting and interpretation of sediment rating curves. *J. Hydrol.* 234, 228-248.

10- Ayttek, A., Asce, M. and Alp, M. (2008) An application of artificial intelligence for rainfall runoff modeling. *J. Earth Syst. Sci.* 117(2), 145-155.

- 32- Rabunal, J.R., Puertas, J., Suarez, J., Rivero, D. (2007) Determination of the unit hydrograph of a typical urban basin using genetic programming and artificial neural networks. *Hydrol. Process.* 21, 476-485.
- 33- Sarangi, A. and Bhattacharya. A.K. (2005) Comparison of artificial neural network and regression models for sediment loss prediction from banha watershed in India, Water technology Center, IARI, Pusa Campus, New Dehli 110012, India.
- 34- Thomas, R.B., (1985) Estimating total suspended sediment yield with probability sampling. *Water Resour. Res.* 21, 1381-1388.
- 35- Ustoorikar, K., and Deo. M.C. (2008) Filling up gaps in wave data with genetic programming. *Marine Structures.*, 21, 177-195.
- 36- Yitian, L., Gu, R.R. (2003) Modeling flow and sediment transport in a river system using an artificial neural network, *Eviron. Manage* 319(1): 122-134.
- 37- Zaker Moshfeg, M., Ghodsian, M., and Montazer. Gh. A. (2004) *River flow forecasting using artificial neural networks.*, *Proceeding of the hydraulics of dams and river structures.* Yazdandoost and Attari (eds). London.
- Barcelona, Spain.
- 26- Koza, J.R., (1992) *Genetic Programming: On the Programming of Computers by means of Natural Selection.* The MIT Press, Cambridge, MA.
- 27- Koza, J.R., (2008) *The home page of John R.Koza at Genetic Programming Inc .* www.genetic-programming.com .
- 28- Liong, S.Y., Gautam, T.R., Khu, S.T., Babovic, V., Keijzer, M., and Muttil, N. (2002) Genetic programming, A new paradigm in rainfall runoff modeling. *J. Am. Water Res. Assoc.* 38(3), 705-718.
- 29- Makarynsky, O., Makarynska, D., Kuhn, M., and Featherstone, W.E. (2004) Predicting sea level variations with artificial neural networks at Hillary Harbour, Western Australia. *Estuaries, Coastal and Shelf Sci.* 61, 351-360.
- 30- McBean, E.A. and Al-Nassri. S. (1988) Uncertainty in suspended sediment transport curves. *J. Hydr. Eng.* ASCE 114 (1), 63-74.
- 31- Picoet, C., Hingray, B. and Olivry. J.C (2001) Empirical and conceptual modeling of the suspended sediment dynamics in large tropical African River: The Upper Niger River Basin. *J. Hydrol.* 250, 19-39.

□ □ □ □ □ □ □ □ □ □

Archive of S&T