

ارائه یک رویکرد نوین در افزایش کارایی مدل منحنی سنجه رسوب در برآورد بار رسوب معلق حوزه‌های آبخیز (مطالعه موردی: رودخانه مهاباد چای، استان آذربایجان غربی)

محمودرضا طباطبائی^۱، امین صالح پورجم^۲ و سید احمد حسینی^۳

۱- استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران، (نویسنده مسوول: taba1345@hotmail.com)

۲- استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ دریافت: ۹۷/۱/۱۵ تاریخ پذیرش: ۹۷/۷/۲۹

صفحه: ۱۸۱ تا ۱۹۳

چکیده

برآورد صحیح مقدار رسوب معلق نقش مهمی در طراحی بهینه سازه‌های آبی، مطالعات فرسایش و رسوب و مطالعات کیفی آب دارد. منحنی سنجه رسوب، یک مدل رگرسیونی مرسوم و شناخته‌شده در این زمینه بوده، با این حال به دلیل تبدیلات لگاریتمی در واسنجی این مدل، مقادیر برآوردی آن اغلب کمتر از مقدار واقعی است. در پژوهش حاضر، با استفاده از داده‌های دبی لحظه‌ای جریان و بار رسوب معلق ایستگاه هیدرومتری بیطاس در رودخانه مهاباد چای، مدل منحنی سنجه رسوب واسنجی و پس‌از آن، با استفاده از الگوریتم ژنتیک چند هدفه با مرتب‌سازی نامغلوب (NSGA-II)، ضرایب این مدل مجدداً بهینه شد. این الگوریتم یک‌روال خودکار بوده و می‌تواند توابع هدف مختلفی را در فرآیند واسنجی به‌طور هم‌زمان مورد استفاده قرار دهد. در این رابطه در فرآیند واسنجی مدل از چهار تابع هدف RMSE، MAE، NSE و LOGE به‌طور دوجه‌دو استفاده گردید که با توجه به نتایج ارزیابی مدل، توابع هدف NSE و LOGE به‌عنوان بهترین توابع هدف جهت بهینه‌سازی مدل انتخاب شدند. همچنین به‌منظور افزایش قدرت تعمیم دهی مدل‌ها، از شبکه عصبی بدون ناظر نگاشت خودسازمان‌ده (SOM) برای خوشه‌بندی داده‌ها و تشکیل دو مجموعه داده همگن (مجموعه‌های واسنجی و ارزیابی) به نسبت ۷۰ و ۳۰ درصد استفاده شد. نتایج نشان داد که استفاده از الگوریتم NSGA-II سبب افزایش کارایی مدل شده به‌نحوی که نتایج آن، از نتایج دیگر مدل‌های مرسوم منحنی سنجه رسوب (نظیر منحنی سنجه حد وسط دسته‌ها، منحنی سنجه‌های تصحیح‌شده با ضرایب تصحیحی) بهتر است. در این رابطه، مقدار خطای (RMSE) داده‌های آزمون در بهترین مدل منحنی سنجه، ۳۸۳/۶۵ تن در روز محاسبه گردید که با استفاده از الگوریتم NSGA-II به ۱۰۲/۹۴ تن در روز کاهش یافت. در مجموع، با استفاده از الگوریتم NSGA-II می‌توان ضرایب مدل منحنی سنجه رسوب را به‌نحوی بهینه نمود که کارایی آن بیشتر از سایر مدل‌های سنتی گردد.

واژه‌های کلیدی: الگوریتم بهینه‌سازی چند هدفه با مرتب‌سازی نامغلوب، رسوب معلق، خوشه‌بندی، شبکه عصبی مصنوعی، منحنی سنجه رسوب، نگاشت خودسازمان‌ده

مقدمه

متنوعی نظیر ضریب تخمین‌گر شبه‌بیشینه درست‌نمایی^۴ (۱۶)، ضریب برآوردگر ناریب با حداقل واریانس^۵ (۷،۴۳)، ضریب ناپارامتریک اسمیرینگ^۶ (۱۲) و غیره معرفی شده‌اند که در تمامی آن‌ها، هدف، افزایش مقدار برآوردی بار رسوب معلق است (۲۰، ۳۴). با این حال استفاده از این ضرایب تصحیحی در پاره‌ای از مواقع سبب بروز نوع دیگری از خطا، به‌صورت بیش تخمینی شده یا سبب ایجاد نتایج متفاوت با داده‌های یکسان می‌گردد (۲۴). در سال‌های اخیر به دلیل برخی از محدودیت‌های موجود در الگوریتم‌های مشتق‌منا در واسنجی مدل‌ها، از الگوریتم‌های جستجوی فرا مکاشفه‌ای^۷ در واسنجی مدل‌ها و همگرایی به‌سوی مقادیر بهینه پارامترهای موجود در مدل‌ها استفاده می‌شود (۴، ۴۰). در این رابطه، کوک و همکاران (۲۹) در حوضه Sungai Bedup در کشور مالزی، به‌منظور بهینه‌سازی یک مدل شبکه عصبی بارش-رواناب روزانه، از الگوریتم PSO استفاده نمودند. تحقیق آنان نشان داد که آموزش شبکه عصبی از طریق الگوریتم یادشده، موفقیت‌آمیز بوده است. آلتونکیناک (۱) ضرایب مدل منحنی سنجه رسوب در رودخانه می‌سی‌سی‌پی را با کمک الگوریتم ژنتیک بهینه نمود. نتایج گرفته‌شده نشان داد که این مدل در مقایسه با مدل‌های سنتی آن از کارایی بیشتری برخوردار

آگاهی از وضعیت رسوب‌دهی حوزه‌های آبخیز و برآورد صحیح بار رسوب معلق^۱ آن‌ها، نقش مهمی در طراحی بهینه سازه‌های آبی و دیگر عملیات آبخیزداری مرتبط دارد (۵، ۴۴). با توجه به محدودیت‌های موجود (هزینه نمونه‌برداری، زمان و ...)، محاسبه بار رسوب معلق غالباً به‌صورت غیرمستقیم و با استفاده از مدل رگرسیونی منحنی سنجه رسوب^۲ (SRC) محاسبه می‌گردد (۴۴):

$$SSL_{(t)} = aQ_{(t)}^b \quad (\text{رابطه ۱})$$

که در آن، $SSL_{(t)}$: بار رسوب معلق (دبی) (ton/day)، $Q_{(t)}$: متوسط جریان روزانه (m^3/s) و a و b : ضرایب مدل می‌باشند. نتایج مطالعات انجام‌شده در زمینه کاربرد مدل SRC نشان می‌دهد که در مرحله واسنجی مدل (محاسبه ضرایب a و b) به دلیل تبدیلات لگاریتمی داده‌ها، توزیع خطا (اختلاف مقادیر مشاهده‌ای رسوب و برآوردی آن) نرمال نبوده (میانگین آن بیشتر از صفر است)، سبب می‌شود تا مقادیر برآوردی توسط مدل غالباً کمتر از میزان واقعی آن باشد^۳ (۱۶). این مشکل در دبی‌های سیلابی بیشتر نمود داشته و سبب خطاهای بزرگ‌تر می‌گردد. به‌منظور رفع این خطا تاکنون، ضرایب تصحیحی

1- Suspended Sediment Load (SSL)

2- Sediment Rating Curve (SRC)

3- Underestimation

4- Quasi-Maximum Likelihood Estimator (QMLE)

5- Minimum Variance Unbiased Estimator (MVUE)

6- Smearing

7- Meta-Heuristic Algorithms (or Evolutionary Algorithms)

می‌نماید (۳۶). با توجه به نظر مولتا (۳۷)، دقت واسنجی چند هدفه می‌تواند با استفاده از یک تابع هدف از هر گروه بهبود یابد. به‌عنوان مثال استفاده از تابع MAE، که حساس به جریان‌های کم بوده و توابع NSE یا RMSE که حساس به جریان‌های بالا می‌باشند می‌تواند ترکیب مناسبی باشد. الگوریتم ژنتیک چند هدفه با رتبه‌بندی نامغلوب^۸ (NSGA-II) نسخه جدیدی از الگوریتم NSGA بوده و توسط سرینیواس و دب ارائه شده است (۴۱). در این الگوریتم بهینه‌سازی، می‌توان از چندین تابع هدف، به‌منظور واسنجی خودکار چندمنظوره استفاده نمود. یاپو و همکاران (۴۷) نشان دادند که در این روش، به‌جای یافتن تنها یک مقدار بهینه سرتاسری برای یک پارامتر، می‌توان، مجموعه‌ای از مقادیر نامغلوب^۹ برای آن پارامتر را محاسبه نمود، به‌نحوی که مقادیر بهینه برای توابع هدف چندگانه نمایش داده شوند. در این رابطه، چودهاری و سیل (۶) از NSGA-II و توابع هدف مختلف به‌منظور واسنجی مدل و شبیه‌سازی دبی جریان و بار رسوب معلق در حوضه رودخانه می‌سی‌سی‌پی، ایالات‌متحده استفاده کردند. نتایج به‌دست‌آمده نشان داد که یک مدل یکپارچه با اهداف چندگانه را می‌توان برای توصیف دو متغیر هیدرولوژیکی با عملکرد رضایت‌بخش توسعه داد. برآورد بار رسوب معلق روزانه رودخانه مه‌باد چای با استفاده از مدل SRC سنتی و مدل SRC اصلاح‌شده توسط ضرایب اصلاحی، بهینه‌سازی ضرایب این مدل با استفاده از الگوریتم‌های ژنتیک تک هدفه و چند هدفه و مقایسه عملکرد آن‌ها با یکدیگر، از جمله اهداف این پژوهش می‌باشند. تأکید بر همگن‌سازی داده‌ها از طریق خوشه‌بندی آن‌ها قبل از واسنجی مدل و نیز استفاده از الگوریتم ژنتیک چند هدفه در بهینه‌سازی ضرایب مدل SRC از جمله نوآوری‌های این پژوهش محسوب می‌شوند.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده

پژوهش حاضر در حوزه آبخیز رودخانه مه‌باد چای (واقع در حوضه آبریز دریاچه ارومیه)، در محل ایستگاه هیدرومتری بیطاس انجام شده است. این حوضه در موقعیت $36^{\circ} 23'$ تا $36^{\circ} 47'$ عرض شمالی و $45^{\circ} 25'$ تا $45^{\circ} 47'$ طول شرقی در استان آذربایجان غربی واقع است، شکل (۱).

است. محمدرضا پور و همکاران (۳۵) نیز در مطالعه دیگری از الگوریتم‌های تک هدفه ژنتیک و PSO در بهینه‌سازی مدل SRC استفاده نمودند. نتایج آن‌ها نیز حاکی از برتری این روش واسنجی نسبت به روش‌های مشتق مینا بود. در پژوهشی مشابه، بهمنش و همکاران (۳) با بهینه نمودن ضرایب منحنی سنج رسوب با الگوریتم ژنتیک توانستند، با کاهش مقدار خطای RMSE (در مرحله ارزیابی) تا ۲۵ درصد، کارایی مدل را افزایش دهند. در پژوهشی که توسط داننده مهر و همکاران (۹) در حوضه دریاچه ارومیه جهت برآورد رسوب معلق روزانه رودخانه ليقوان چای انجام گردید، از برنامه‌ریزی ژنتیک (GP) و دبی جریان استفاده شد. نتایج حاصل، حاکی از کارایی بالای این روش در پیش‌بینی بار رسوب معلق رودخانه در مقایسه با شبکه عصبی مصنوعی است. اصلانی و همکاران (۲) به‌منظور تخمین پارامترهای مدل مفهومی ناش (n,k) از الگوریتم ژنتیک پیوسته در واسنجی مدل استفاده نمودند. کارایی این روش با به‌کارگیری پارامترهای تخمینی در شبیه‌سازی وقایع مختلف بارندگی- رواناب واقع در حوزه کسلیبان در استان مازندران مورد ارزیابی قرار گرفت. معیارهای ارزیابی و نتایج نشان می‌دهند که مدل ارائه‌شده، قادر به تعیین پارامترهای ورودی مدل ناش با دقت و کارایی بالا است. ابتهاج و بنکدار (۱۳) از الگوریتم‌های بهینه‌سازی انبوه ذرات^۱ (PSO) و رقابت استعماری^۲ (ICA) در برآورد عدد فرود^۳ استفاده کردند. نتایج نشان داد که الگوریتم ICA نتایج بهتری داشته است. مطالعات نشان می‌دهد که موفقیت یک فرآیند واسنجی به‌شدت وابسته به تابع هدف انتخاب شده به‌عنوان معیار واسنجی است (۱۸،۱۹). توابع ناش-ساتکلیف^۴ (NSE)، ریشه میانگین مربعات خطا^۵ (RMSE) و میانگین مربعات خطا^۶ (MSE) که مربع باقی‌مانده را به حداقل می‌رسانند، سبب می‌شوند تا میزان خطای حاصله از شبیه‌سازی متغیر در مقادیر زیاد آن به دلیل استفاده از مربع انحرافات بسیار زیاد شده، لذا مدل‌های هیدرولوژیکی را برای شبیه‌سازی جریان‌های کم، کمتر حساس می‌نمایند (۸،۲۸،۳۰). بنابراین، پارامترهای این‌گونه مدل‌ها به نحوی واسنجی می‌شوند که بتوانند مقادیر بالای متغیرها را بهتر شبیه‌سازی کنند. تابع هدف میانگین قدر مطلق خطا^۷ MAE نسبت به مقادیر زیاد جریان حساسیت کمتری داشته و برعکس نسبت به مقادیر کم جریان حساسیت بیشتری دارد و در نتیجه عملکرد مدل را یکنواخت‌تر

1- Particle Swarm Optimization (PSO)

2- Imperialist Competitive Algorithm (ICA)

3- Froude Number

4- Nash-Sutcliffe Efficiency (NSE)


5- Root Mean Square Error

6- Mean Square Error

7- Mean Absolute Error

8- Non-Dominated Sorting Genetic Algorithm II (NSGA-II)

9- Non-Dominated (Pareto Optimal)



شکل ۱- موقعیت حوزه آبخیز مهاباد چای و ایستگاه هیدرومتری بیطاس
Figure 1. The location of Mahabad-Chai Watershed and Beytas Hydrometric Station

در جدول ۱ ارائه شده است. همان طور که از اطلاعات آماری جدول ۱ استنباط می‌شود، دبی رسوب دارای چولگی و ضریب تغییرات زیاد بوده و تغییرات بین حداقل و حداکثر آن بسیار زیاد است. این موضوع به همراه سایر آماره‌های محاسبه‌شده، حکایت از پیچیدگی مدل‌سازی برآورد رسوب معلق رودخانه دارد.

مساحت حوضه ۸۱۱۷۲٫۶۳ هکتار و ارتفاع متوسط آن ۱۷۷۹ متر از سطح دریا است. آمار مورد استفاده در این پژوهش، شامل داده‌های آب‌سنجی دبی لحظه‌ای جریان و دبی رسوب ایستگاه هیدرومتری بیطاس در یک دوره زمانی ۴۸ ساله (۱۳۴۲ تا ۱۳۹۰) به تعداد ۲۴۸ رکورد اطلاعاتی است. خصوصیات آماری داده‌های مورد استفاده در این مدت،

جدول ۱- ویژگی‌های آماری داده‌های مورد استفاده

Table 1. Statistical characteristics of the data used during the study

مجموعه داده	متغیر	میانگین	انحراف معیار	بیشینه	کمینه	چولگی	ضریب تغییرات
کل داده‌ها	دبی جریان (مترمکب در ثانیه)	۲/۵۰	۳/۷۸	۲۶/۰۱	۰/۰۱	۳/۳۶	۱/۵۱
	بار رسوب معلق (تن در روز)	۱۲۹/۲۶	۶۳۶/۷۴	۶۴۲۰/۱	۰/۰۱	۷/۷۳	۴/۹۲

خوشه‌های بهینه، توسط شاخص‌های ارزیابی دیویس-بولدین انجام گرفته است. به‌منظور تحلیل نتایج آماری حاصل از خوشه‌بندی داده‌ها در دو مجموعه واسنجی و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی ...) از آزمون نا پارامتری دو نمونه‌ای کلموگروف-اسمیرنوف جهت بررسی یکسان بودن توزیع داده‌های دو مجموعه استفاده شده است که در ادامه به‌اختصار به آن‌ها اشاره می‌شود:

تهیه داده‌های همگن جهت واسنجی و آزمون مدل‌ها
به‌منظور افزایش قدرت تعمیم‌دهی و ساخت هر چه دقیق‌تر مدل‌های منحنی سنجی رسوب، لازم است داده‌های مورد استفاده در واسنجی مدل‌ها، معرف و نماینده داده‌های کل دوره آماری باشند. همچنین به‌منظور آزمون و ارزیابی صحیح نتایج مدل‌ها، لازم است داده‌های آزمون، مشابه داده‌های واسنجی بوده و از توزیع یکسانی با آن‌ها برخوردار باشند. بدین منظور در پژوهش حاضر از شبکه عصبی SOM، جهت خوشه‌بندی داده‌ها و از روش تخصیص برابر، به‌منظور نمونه‌گیری از خوشه‌ها استفاده شده است. تعیین تعداد

1- Two-Sample Kolmogorov-Smirnov Test (KS)

حسب مقدار فاصله‌ای که از BMU دارند (فاز همکاری) بر طبق رابطه‌ی ۲ به هنگام می‌شوند (فاز تطبیق) (۲۲).


$w_{ji}(t+1) = w_{ji}(t) + \theta(t) * \eta(t) * [xi(t) - w_{ji}(t)]$
 که در آن، t : نماینده زمان، $\theta(t)$: تابعی است که فاصله نورون‌های همسایه BMU را به نسبتی از همسایگی تبدیل می‌کند و $\eta(t)$: نرخ یادگیری است.
 (شکل ۲) ساختار شبکه عصبی نگاشت خود سازمان‌ده را نشان می‌دهد.

ب- شاخص‌های ارزیابی خوشه‌ها (تعیین تعداد بهینه خوشه‌ها)

به منظور تعیین تعداد بهینه خوشه‌ها، روش‌های مختلفی وجود دارد (شاخص دون، ضریب سیلهوت، شاخص دیویس بولدین، شاخص اعتبار سنجی و...) که در این پژوهش از شاخص دیویس بولدین به دلیل کارایی آن استفاده شده و پیاده‌سازی آن در نرم‌افزار MATLAB انجام شده است. این شاخص، میانگین شباهت بین هر خوشه با شبیه‌ترین خوشه به آن را محاسبه می‌نماید (۲۵، ۴۸). هرچه مقدار محاسبه‌شده این شاخص کمتر باشد خوشه‌بندی باکیفیت بهتری انجام شده است.

الف- خوشه‌بندی داده‌ها با استفاده مدل شبکه عصبی نگاشت خودسازمان‌ده (SOM)

شبکه عصبی SOM، یک شبکه عصبی مصنوعی غیرنظارتی بوده و الگوریتم آموزش آن، به صورت رقابتی و بدون ناظر انجام می‌شود. ساختار SOM، از یک لایه ورودی و یک لایه خروجی (لایه کوهن^۱) تشکیل می‌شود (۲۷). در این ساختار، نورون‌های لایه ورودی، محل ارتباط داده‌های ورودی با شبکه بوده و برای هر متغیر ورودی، یک نورون در این لایه وجود دارد (به عنوان مثال دبی، بارش و...). لایه خروجی، ماتریس یا شبکه‌ای (عموماً یک شبکه دوبعدی) از نورون‌ها را تشکیل داده به نحوی که هر نورون این شبکه، به کلیه نورون‌های لایه ورودی متصل بوده ولی به نورون‌های دیگر این لایه متصل نیست (۲۳). فرآیند آموزش در شبکه SOM از سه مرحله رقابت^۲، همکاری^۳ و تطبیق^۴ تشکیل می‌گردد. در ابتدا وزن نورون‌های لایه خروجی به صورت تصادفی تعریف شده و در طی فرایند آموزش و در طول زمان، به مقادیر متغیرهای بردارهای ورودی بیشتر شبیه می‌گردد. پس از آنکه شبیه‌ترین نورون به بردار ورودی^۵ (BMU) مشخص گردید، وزن‌های آن و وزن‌های دیگر نورون‌های همسایه آن، بر



شکل ۲- یک شبکه ۵×۵ دوبعدی نگاشت خودسازمان‌ده (به نقل از کلت و همکاران (۲۳))
 Figure 2. A 5×5 two-dimensional self-organizing map (modified from Kalteh et al., (23))

د- تحلیل آماری داده‌های حاصل از خوشه‌بندی
 به منظور بررسی و مقایسه همگنی و مشابهت داده‌های دو مجموعه واسنجی و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی و ...) از آزمون ناپارامتری کولموگروف-اسمیرنوف دو نمونه‌ای (KS)، جهت بررسی یکسانی و تشابه جمعیت دو مجموعه استفاده گردید. در این آزمون، فرض H_0 و H_1 ، به ترتیب یکسان بودن و یکسان نبودن توزیع داده‌ها در دو جمعیت را بیان می‌نماید. در این پژوهش از نرم‌افزار MATLAB جهت انجام این آزمون استفاده شده است.

تهیه مدل منحنی سنج رسوب

این مدل رگرسیونی بر اساس داده‌های آب‌سنجی (دبی جریان و دبی رسوب) ایستگاه بیطاس و با استفاده از داده‌های همگن‌شده بخش واسنجی به روش یک‌خطی و حد وسط دسته‌ها تهیه گردید. در ذیل، این دو روش و ضرایب اصلاحی آن به طور اجمالی معرفی شده است:

ج- روش نمونه‌گیری از خوشه‌ها

به منظور تهیه دو مجموعه حتی‌الامکان مشابه و همگن (مجموعه‌های واسنجی و آزمون)، بایستی از خوشه‌های تولیدی به شکل مناسبی نمونه‌گیری شده که در این رابطه از روش تخصیص متناسب^۶ استفاده شده است (به نسبت ۸۰٪ داده‌ها برای واسنجی و ۲۰ درصد مابقی داده‌ها برای آزمون). در این روش، تعداد نمونه‌ها، متناسب با اندازه خوشه تغییر کرده بدین نحو که با افزایش اندازه هر خوشه، تعداد نمونه‌گیری از آن‌ها افزایش یافته و بالعکس:

$$nh = n \frac{N_h}{\sum_{j=1}^H N_j} \quad \text{(رابطه ۳)}$$

که در آن، nh : تعداد نمونه گرفته‌شده از خوشه h ، n : تعداد داده موردنیاز، N_h : تعداد داده‌ها در خوشه h و N_j : تعداد داده در سایر خوشه‌ها است.

1- Kohonen Layer 2- Competitive Phase 3- Co-operative Phase 4- Adaptive Phase
 5- Best Matching Unit (BMU) 6- Davies-Bouldin Index 7- Proportional Allocation

که در آن: C_o ، غلظت یا دبی رسوب معلق مشاهده‌ای (mg l^{-1} یا tonday^{-1})، C_e ، غلظت یا دبی رسوب تخمینی (mg l^{-1} یا tonday^{-1}) و n ، تعداد نمونه‌ها است.

– ضریب اصلاحی ناپارامتری^۴

این ضریب که با آن ضریب CF_2 نیز می‌گویند توسط کوچ و اسمایی (۲۶) با رد توزیع نرمال خطاهای باقیمانده، ضریب اصلاحی غیر پارامتری را برای حذف اربیبی داده‌ها توصیه نمودند که از روابط ۸ و ۹ قابل محاسبه است:

$$CF_2 = \frac{1}{n} \sum_{i=1}^n 10^{e_i} \quad (\text{رابطه ۸})$$

$$e_i = \log C_{o_i} - \log C_{e_i} \quad (\text{رابطه ۹})$$

در این روابط، e_i : خطای برآورد و n : تعداد نمونه‌ها است. در پژوهش حاضر، به‌منظور مقایسه ساده‌تر مدل‌ها با یکدیگر، نام آن‌ها کوتاه‌تر شده و به ترتیبی که در فوق بیان شده از چپ به راست عبارت‌اند از:

SRC, SRC-MeanLoad, SRC-FAO, SRC-CF1, SRC-CF2

بهینه‌سازی چند هدفه

هنگامی که مشکل بهینه‌سازی بیش از یک تابع هدف را شامل می‌شود، فرآیند پیدا کردن یک یا چند راه‌حل ممکن بهینه می‌تواند به‌عنوان بهینه‌سازی چندمنظوره تلقی گردد. در چنین شرایطی، یافتن پاسخی که تمام اهداف را بهینه سازد تقریباً غیرممکن است و لذا باید تلاش گردد تا مجموعه‌ای از راه‌حل‌ها (مجموعه پارتو) با مطلوبیت نسبی^۵ برای همه اهداف تعیین شود (۱۰). به این ترتیب، در مجموعه‌ی بهینه پارتو، هیچ‌یک از راه‌حل‌ها بر دیگری غالب نیستند و حرکت از یک نقطه (پاسخ یا راه‌حل) به نقطه دیگر، یک تابع هدف را بهتر نموده و تابع هدف دیگر را بدتر می‌نماید (۴۹).

الگوریتم بهینه‌سازی چند هدفه با مرتب‌سازی نامغلوب (NSGA-II)

الگوریتم ژنتیک چند هدفه با مرتب‌سازی نامغلوب مرتبه دوم (NSGA-II)، که یک نسخه بهبودیافته از الگوریتم NSGA است (۵۵)، یک الگوریتم بهینه‌سازی چندمنظوره بوده که در ایجاد یک‌روال واسنجی خودکار استفاده می‌شود. این الگوریتم از الگوریتم‌های تکاملی چند هدفه معاصر است که از عملکرد بالائی برخوردار است و امروزه در رشته‌های مختلف کاربرد گسترده‌ای دارد (۴). در این الگوریتم از یک رویکرد مرتب‌سازی سریع و غیر غالب برای افتراق راه‌حل‌ها بر پایه مفهوم غالبیت و بهینه پارتو^۶ استفاده می‌شود. با توجه به تعریف و نمادگذاری ارائه‌شده توسط ولدوزین و لامونت (۴۵)، مفهوم غلبه و بهینه پارتو برای یک مسئله به حداقل رسانی چند هدفه می‌تواند به شرح زیر بیان شود (۴):

$$(\text{رابطه ۱۰})$$

$$\text{Minimize } f(x) = (f_1(x), f_2(x), \dots, f_n(x))$$

$$\text{Subject to } g(x) = (g_1(x), g_2(x), \dots, g_m(x)) \leq 0$$

جایی که $f(x)$: تابع ارزش بردار، x : بردار تصمیم و $g(x)$: بردار محدودیت است. با توجه به دو بردار تصمیم‌گیری a و b ، گفته می‌شود که a به b غلبه می‌کند:

الف- منحنی سنجه‌ی یک خطی

در این روش، داده‌های غلظت یا دبی رسوب معلق و دبی جریان متناظر آن‌ها، به یک دستگاه مختصات تمام لگاریتمی منتقل شده و بهترین خط برازش با استفاده از روش حداقل مربعات خطا از میان نقاط عبور داده می‌شود (۲۰):

$$\log Q_s = b \log Q_w + \log a \quad (\text{رابطه ۴})$$

که در آن، Q_s و Q_w به ترتیب: دبی رسوب (tonday^{-1}) و دبی جریان ($\text{m}^3 \text{s}^{-1}$) و a و b : ضرایب معادله خط می‌باشند.

پس از محاسبه دبی رسوب، بایستی این مقدار مجدداً از قالب لگاریتمی به شکل اولیه خود (در شکل حسابی) تبدیل شوند^۱، یا به عبارتی آنتی‌لوگ از آن‌ها گرفته شود.

ب- منحنی سنجه‌ی حد وسط دسته‌ها^۲

در این روش که آن را جانسون (۲۰) پیشنهاد کرده است، دبی جریان، با یک مقدار ثابت به تعدادی دسته تقسیم شده و برای دبی متوسط هر دسته، دبی رسوب متوسط همان دسته تعیین می‌شود. در آخر، ضرایب منحنی سنجه‌ی رسوب مشابه با بند الف و با استفاده از روش حداقل مربعات خطا به دست می‌آید.

ج- ضرایب اصلاحی منحنی سنجه‌ی رسوب

همان‌طور که پیش‌تر بیان شد، این ضرایب سبب افزایش مقادیر برآورد رسوب محاسباتی می‌شوند. برخی از این ضرایب به شرح زیر می‌باشند:

– ضریب اصلاحی فائو (FAO)

این ضریب تصحیح توسط جونز و همکاران (۲۱) ارائه شده است و به‌صورت زیر (رابطه ۵) محاسبه می‌شود (۲۱):

$$CF = \frac{\overline{Q_s}}{(\overline{Q_w})^b} \quad (\text{رابطه ۵})$$

که در آن: CF ، ضریب اصلاحی فائو، $\overline{Q_s}$ ، میانگین دبی رسوب یا غلظت رسوب نمونه‌های مشاهده‌ای (tonday^{-1}) یا $\overline{Q_w}$ ، میانگین دبی جریان نمونه‌های مشاهده‌ای ($\text{m}^3 \text{s}^{-1}$) و b ، پارامتر بکار رفته در مدل منحنی سنجه‌ی رسوب است. پس از محاسبه ضریب اصلاحی فائو (CF)، این ضریب جایگزین پارامتر a ، در رابطه توانی (رابطه ۱) می‌شود.

– ضریب اصلاحی پارامتری یا تخمین‌گر شبه پیشینه درست‌نمایی^۳

ضریب اصلاحی تخمین‌گر شبه پیشینه درست‌نمایی (QMLE)، که به آن ضریب CF_1 نیز می‌گویند توسط فرگوسن (۱۶) برای اصلاح اثر تبدیل لگاریتمی و با فرض توزیع نرمال خطاهای باقیمانده به کار گرفته شده است. این روش بر اساس مجذور خطای استاندارد باقی‌مانده رگرسیون بوده و رابطه آن به شکل زیر است:

$$CF_1 = e^{(2.651S^2)} \quad (\text{رابطه ۶})$$

که در آن: e ، تابع نمایی و S^2 ، مجذور خطای استاندارد (اشتباه استاندارد) خط رگرسیون در لگاریتم با مبنای ۱۰ است که از رابطه زیر به دست می‌آید:

$$S^2 = \frac{\sum_{i=1}^n (\log C_{o_i} - \log C_{e_i})^2}{n-2} \quad (\text{رابطه ۷})$$

1- Back-Transformed
4- Smearing

2- Mean Load Method
5- Pareto Optimal Set

3- Quasi-Maximum Likelihood Estimator=QMLE
6- Pareto Dominance and Optimality

توابع هدف مورد استفاده در واسنجی مدل‌ها

در این پژوهش، به منظور واسنجی صحیح‌تر SSL و افزایش کارایی مدل از یک تابع چند هدفه با انتخاب یک تابع هدف از هر گروه (NSE یا RMSE برای تأکید بر SSL بالا و MAE یا LOGE برای تأکید بر SSL پایین) استفاده شده است، رابطه‌های ۱۵ تا ۱۸:

$$LOGE = \sqrt{\frac{1}{N} \times \sum_{j=1}^N (\log(\frac{O_j}{S_j}))^2} \quad (\text{رابطه ۱۵})$$

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{j=1}^N (O_j - S_j)^2} \quad (\text{رابطه ۱۶})$$

$$MAE = \frac{\sum_{j=1}^N |O_j - S_j|}{N} \quad (\text{رابطه ۱۷})$$

$$NSE = 1 - \frac{\sum_{j=1}^N (O_j - S_j)^2}{\sum_{j=1}^N (O_j - \bar{O}_j)^2} \quad (\text{رابطه ۱۸})$$

در رابطه‌های فوق، O_j و S_j به ترتیب: دبی رسوب معلق مشاهده‌ای و برآورد شده (تن در روز)، N : تعداد داده‌های معرفی شده به مدل (داده‌های بخش واسنجی) و \bar{O}_j : متوسط دبی رسوب مشاهداتی است.

لازم به ذکر است که به هنگام استفاده از رابطه ۱۸ به عنوان یک تابع هدف، تنها بخش کسری آن (بدون ۱ و علامت منها) استفاده شده است (رابطه ۱۹) و لذا در زمان واسنجی مدل، با به حداقل رساندن این بخش، مقدار NSE افزایش می‌یابد.

$$NS_objfun = \frac{\sum_{j=1}^N (O_j - S_j)^2}{\sum_{j=1}^N (O_j - \bar{O}_j)^2} \quad (\text{رابطه ۱۹})$$

سناریوهای مدل‌سازی با الگوریتم ژنتیک

در این پژوهش، فرایندهای بهینه‌سازی شامل بهینه‌سازی تک هدفه (سناریوی اول، SRC-GA-I) و چند هدفه (سناریوی دوم، SRC-GA-II) به کمک روابط (۱۵) تا (۱۷) و رابطه ۱۹، انجام شده است. در الگوریتم‌های ژنتیک، متغیرهای تصمیم^۱، پارامترهای مدل منحنی سنجه رسوب (ضرایب a و b در معادله ۱) بوده و یک بردار از آن‌ها، یک راه حل خاص^{۱۱} برای مسئله واسنجی است. نتایج واسنجی این دو سناریو سپس بر اساس معیارهای ارزیابی (بخش بعدی) مورد ارزیابی قرار می‌گیرند.

در پژوهش حاضر، به منظور خوشه‌بندی داده‌ها، پیاده‌سازی الگوریتم‌های ژنتیک و PSO، و همچنین انجام تحلیل‌های آماری، از نرم‌افزار MATLAB نسخه R2015b استفاده شده است.

(رابطه ۱۱)

$$iff \forall i \in \{1, 2, \dots, n\} : f_i(a) \leq f_i(b) \text{ and} \\ \exists i \in \{1, 2, \dots, n\} : f_i(a) < f_i(b)$$

مجموعه بردارهای تصمیم که بهینه پارتو در فضای جستجو هستند باهم، یک جبهه بهینه پارتو را تشکیل می‌دهند. از آنجایی که الگوریتم NSGA-II به عنوان یک الگوریتم مبتنی بر جمعیت شناخته می‌شود، این الگوریتم با نسل تصادفی از جمعیت والدین (P_t) که شامل راه‌حل‌های بالقوه (در این پژوهش، ضرایب a و b در معادله ۱) برای یک مسئله هستند آغاز می‌شود. پس از آن با استفاده از عملگر انتخاب مسابقه‌ای دودویی^۱ مجموعه‌ای از افراد آن نسل برای شرکت در تقاطع و جهش^۲ انتخاب می‌شوند. بر روی بخشی از مجموعه افراد انتخاب‌شده، عمل تقاطع و بر روی بقیه، عمل جهش انجام می‌گردد و جمعیتی از فرزندان، و جهش‌یافتگان ایجاد می‌شود (Q_t). در ادامه، این جمعیت با جمعیت اصلی ادغام می‌شود (R_t). اعضای جمعیت تازه تشکیل‌یافته، ابتدا برحسب رتبه^۳ و به صورت صعودی مرتب می‌شوند. مقدار رتبه یک مقدار شایستگی^۴ است که برحسب غلبگی پارتو^۵ و معادل با سطح نامغلوبی^۶ محاسبه می‌شود. برای مثال رتبه ۱، منطبق با بهترین سطح نامغلوبی، رتبه ۲، برای بهترین سطح بعدی و الی‌آخر. بر اساس مقدار رتبه هر راه‌حل، آن راه‌حل به جبهه‌های^۸ مختلف اختصاص می‌یابد. بنابراین اولین جبهه شامل راه‌حلهایی است که راه‌حل‌های دیگر جبهه را مغلوب می‌نماید (شکل ۳).

اعضایی از جمعیت که دارای رتبه یکسانی هستند، برحسب فاصله تراکمی (ازدحامی)^۹ و به صورت نزولی مرتب می‌شوند (روابط ۱۲ تا ۱۴).

$$d_i^1 = \frac{f_1(x_{i+1}) - f_1(x_{i-1})}{f_1^{max} - f_1^{min}} \quad (\text{رابطه ۱۲})$$

$$d_i^2 = \frac{f_2(x_{i+1}) - f_2(x_{i-1})}{f_2^{max} - f_2^{min}} \quad (\text{رابطه ۱۳})$$

$$d_i = d_i^1 + d_i^2 \quad (\text{رابطه ۱۴})$$

که در آن، d_i^1 و d_i^2 به ترتیب: مقادیر فاصله تراکمی، i^{th} : راه‌حل برای اولین و دومین تابع هدف (f_1, f_2)، $f_1(x_{i+1})$ و $f_2(x_{i+1})$: مقادیر اولین و دومین تابع هدف برای $(i+1)^{th}$ راه‌حل، $f_1(x_{i-1})$ و $f_2(x_{i-1})$: مقادیر اولین و دومین تابع هدف برای $(i-1)^{th}$ راه‌حل، $f_1^{max}, f_1^{min}, f_2^{max}, f_2^{min}$ به ترتیب: مقادیر کمینه و بیشینه برای توابع هدف اول و دوم می‌باشند.

نتیجه آنکه، اعضای جمعیت در درجه اول برحسب رتبه، و در درجه دوم برحسب فاصله تراکمی مرتب‌سازی می‌گردند. در ادامه، برابر با تعداد افراد جمعیت اصلی (P_t)، اعضای از بالای فهرست مرتب‌شده، انتخاب‌شده و بقیه اعضای جمعیت، دور ریخته می‌شوند (۱۱). اعضای انتخاب‌شده، جمعیت نسل بعدی را تشکیل می‌دهند، و چرخه مذکور در این بخش، تا محقق شدن شرایط خاتمه، تکرار می‌شود.

1- Binary Tournament Selection	2- Cross Over	3- Mutation	4- Rank
5- Fitness Value	6- Pareto Dominance	7- Non-Domination Level	
8- Front	9- Crowding-Distance	10- Decision Variables	11- Solution

ارزیابی و مقایسه کارایی مدل‌ها

به منظور ارزیابی نتایج حاصل از مدل‌های مختلف منحنی سنج رسوب، شامل مدل‌های سنتی منحنی سنج رسوب (SRC)، (SRC-CF1، SRC-CF2، SRC-FAO، SRC-MeanLoad) و مدل‌های واسنجی شده با الگوریتم‌های ژنتیک (SRC-GA-I و SRC-GA-II) و مقایسه نتایج آن‌ها با داده‌های مشاهده‌ای (SSL مجموعه آزمون)، ترسیمات گرافیکی و اندازه‌گیری‌های خطاها (به کمک روابط ۱۶ تا ۱۸ و ۲۰) انجام شد.


$$R^2 = \left[\frac{\sum_{j=1}^N (O_j - \bar{O}_j) \times (S_j - \bar{S}_j)}{\sqrt{\sum_{j=1}^N (O_j - \bar{O}_j)^2 \times \sum_{j=1}^N (S_j - \bar{S}_j)^2}} \right]^2 \quad (20)$$

در رابطه ۲۰، \bar{O}_j : متوسط دبی رسوب مشاهداتی داده‌های مجموعه آزمون است.

نتایج و بحث

نتایج خوشه‌بندی داده‌ها

با استفاده از الگوریتم خوشه‌بندی SOM و شاخص دیوین بولدین، تعداد خوشه‌های بهینه در داده‌های مورد مطالعه، ۳۶ خوشه تعیین شد (شکل ۴). همچنین نتایج پارامترهای آماری آزمون KS مجموعه داده‌های واسنجی و آزمون به ترتیب در جدول ۲ و ۳ نشان داده شده است. در جدول ۳، حرف h، آماره آزمون KS در نرم‌افزار MATLAB بوده و زمانی که $h=0$ به این معنی است که فرضیه نول (H_0) رد نشده (تأیید فرض H_0 آزمون) و در سطح خطای یک درصد ($\alpha=1\%$) سطح اطمینان ۹۹ درصد توزیع داده‌ها در هر دو مجموعه، یکسان و مشابه است.



شکل ۴- تعیین تعداد بهینه خوشه‌ها با استفاده از خوشه‌بندی SOM و شاخص دیوین بولدین
Figure 4. Determining the optimal number of clusters using SOM clustering and Davies-Bouldin index

جدول ۲- پارامترهای آماری متغیرهای مورد استفاده در مجموعه‌های واسنجی و آزمون

Table 2. Statistical parameters of the variables used in calibration and test data sets						
متغیرهای مدل / مجموعه داده	میانگین	انحراف معیار	بیشینه	کمینه	چولگی	ضریب تغییرات (درصد)
دبی جریان (مترمکعب در ثانیه)	۲/۵۰	۳/۸۰	۲۶/۰۱	۰/۰۱	۳/۴۰	۱۵۲/۰۷
مجموعه واسنجی	۲/۵۲	۳/۷۸	۲۳/۹۷	۰/۰۲	۳/۲۶	۱۵۰/۰۵
مجموعه آزمون	۱۲۲/۱۰	۵۷۴/۶۸	۵۷۶۸/۷۳	۰/۰۱	۷/۴۳	۴۷۰/۶۵
بار رسوب معلق (تن در روز)	۱۴۵/۳۸	۷۶۲/۱۷	۶۴۲۰/۱۲	۰/۰۲	۷/۶۰	۵۲۴/۲۸
مجموعه واسنجی						
مجموعه آزمون						

جدول ۳- نتایج آزمون آماری کولموگروف-اسمیرنوف (KS) دو نمونه‌ای داده‌ها

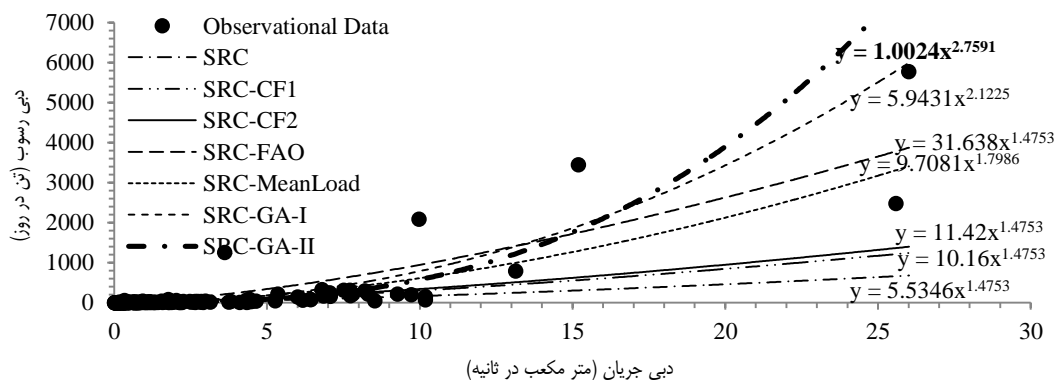
Table 3. Results of two-sample Kolmogorov-Smirnov test of the data			
متغیرهای مدل	مجموعه داده	P-value	Dc
دبی جریان (مترمکعب در ثانیه)	مجموعه واسنجی	۰/۹۸	۰/۰۵۹
بار رسوب معلق (تن در روز)	مجموعه آزمون	۰/۷۶	۰/۰۹

مدل SRC-GA-II دارای عملکرد مناسب‌تری است. در میان توابع هدف، عملکرد دو تابع هدف NSE و LOGE بهتر از بقیه بوده و بنابراین این دو تابع به‌عنوان بهترین توابع هدف برای مدل‌های SRC-GA-I و SRC-GA-II انتخاب شدند. شکل ۵، برآزش مدل‌های مختلف SRC به داده‌های مشاهداتی (مجموعه داده‌های واسنجی) را نشان می‌دهد.

جدول ۴ نتایج ارزیابی مدل‌های مختلف SRC که با استفاده از مجموعه داده‌های آزمون به‌دست آمده است را نشان می‌دهد. مدل‌های GA (مدل‌های SRC-GA-I و SRC-GA-II) در مجموع، کارایی بهتری نسبت به مدل‌های سنتی منحنی سنج رسوب (SRC)، (SRC-MeanLoad، SRC-CF1، SRC-CF2، SRC-FAO) داشته‌اند. همچنین مقایسه مدل SRC-GA-I و SRC-GA-II نشان می‌دهد که

جدول ۴- نتایج ارزیابی مدل‌های مختلف منحنی سنجه رسوب با داده‌های آزمون
Table 4. Results of evaluating various SRC models with test data set

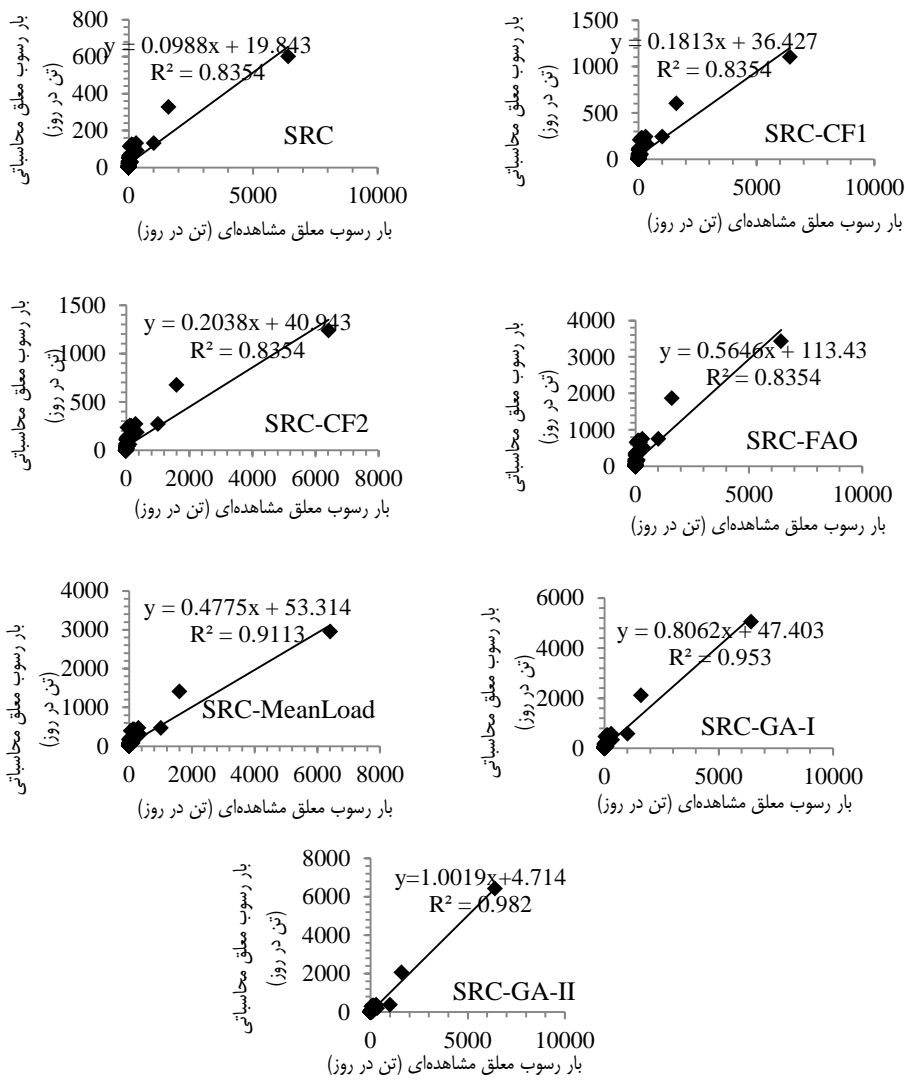
نام مدل	معادله	ریشه میانگین مربعات خطا (تن در روز)	میانگین قدر مطلق خطا (تن در روز)	ناش-ساتکلیف	ضریب تبیین
منحنی سنجه رسوب (SRC)	$Q_s = 5/5345Q_w^{1/4753}$	۶۹۲/۱۵	۱۲۱/۷۵	-۰/۱۶	-۰/۸۳
منحنی سنجه رسوب با ضریب اصلاحی پارامتریک (SRC-CF1)	$Q_s = 10/1601Q_w^{1/4753}$	۶۲۸/۳۰	۱۱۴/۴۳	-۰/۳۱	-۰/۸۳
منحنی سنجه رسوب با ضریب اصلاحی نا پارامتریک (SRC-CF2)	$Q_s = 11/4197Q_w^{1/4753}$	۶۱۱/۳۱	۱۱۳/۶۰	-۰/۳۴	-۰/۸۳
منحنی سنجه رسوب با ضریب اصلاحی فائو (SRC-FAO)	$Q_s = 31/6380Q_w^{1/4753}$	۳۲۸/۶۵	۱۳۵/۴۵	-۰/۷۴	-۰/۸۳
منحنی سنجه رسوب حد وسط دسته‌ها (SRC-MeanLoad)	$Q_s = 9/7081Q_w^{1/7986}$	۴۱۱/۹۹	۹۲/۰۲	-۰/۷۰	-۰/۹۱
منحنی سنجه رسوب بهینه‌شده با الگوریتم ژنتیک تک هدفه (SRC-GA-I)	$Q_s = 5/9431Q_w^{2/1225}$	۲۰۰/۶۶	۷۰/۶۰	-۰/۹۲	-۰/۹۵
منحنی سنجه رسوب بهینه‌شده با الگوریتم ژنتیک چند هدفه (SRC-GA-II)	$Q_s = 1/0024Q_w^{2/7591}$	۱۰۲/۹۴	۳۵/۹۵	-۰/۹۸	-۰/۹۸



شکل ۵- برازش مدل‌های مختلف منحنی سنجه رسوب به داده‌های مشاهداتی (مجموعه داده واسنجی)
Figure 5. Fitness of various SRC models to the observational data (calibration data set)

دبی جریان است. با توجه به نتایج رودریگز-بلانکو و همکاران (۳۹)، تنها ۱۹ درصد از واریانس دبی رسوب معلق را می‌توان با دبی جریان توصیف نمود. بنابراین، کیفیت پایین داده‌ها از یک سو و استفاده از تنها یک متغیر پیش‌بینی کننده در مدل رگرسیون منحنی سنجه رسوب از سوی دیگر، باعث می‌شود که این مدل قادر به شبیه‌سازی کامل داده‌های رسوب در جریان‌های کم و زیاد نباشد. شکل ۶ نمودار پراکندگی و نتایج حاصل از شبیه‌سازی دبی رسوب معلق مشاهده شده (در مجموعه داده‌های آزمون) توسط مدل‌های مختلف را نشان می‌دهد.

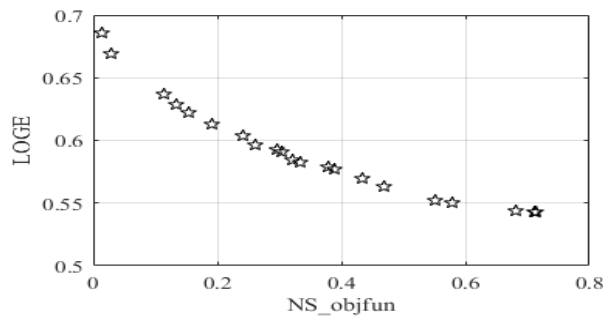
همان‌طور که در شکل نیز می‌توان به صورت بصری مشاهده نمود، مدل‌های GA نسبت به سایر مدل‌ها برازش بهتری به داده‌ها داشته‌اند. در اغلب مدل‌ها، برخی از داده‌ها از خط رگرسیون دور هستند. این مشکل را می‌توان در دو بخش توضیح داد. نخست آنکه، یکی از مشکلات اصلی در داده‌های رسوب‌سنجی اندازه‌گیری شده در ایستگاه‌های هیدرومتری، کمبود و یا فقدان نمونه‌هایی از شرایط سیلابی است، بنابراین پایین بودن کیفیت داده‌های مشاهداتی، کارایی مدل‌های واسنجی شده را کاهش می‌دهد. دوم آنکه، در مدل منحنی سنجه رسوب، تنها یک متغیر پیش‌بینی کننده وجود داشته که



شکل ۶- نمودارهای پراکنش نقطه‌ای دبی رسوب معلق محاسباتی - مشاهداتی (مرحله آزمون) مدل‌های مختلف منحنی سنج رسوب
Figure 6. Scatter plots of observed and estimated SSL (SSL for the test data set) from different SRC models

دو تابع هدف NS_objfun و LOGE در مرحله واسنجی محاسبه شده‌اند را نشان می‌دهد. این شکل، موازنه قابل توجه بین دو تابع هدف و مجموعه‌ای از راه‌حل‌های مناسب مسئله (جواب‌های نامغلوب) که می‌توانند نتایج (برآورد) مناسبی از SSL را ارائه دهند را نشان می‌دهد (بهینه پاره تو).

در مدل SRC-GA-II، مقادیر شیب خط رگرسیون، عرض از مبدأ^۱ و R^2 (به ترتیب ۱/۰۰۱۹، ۴/۷۱۴۱ و ۰/۹۸) از سایر مدل‌ها بهتر است. شکل ۷، جبهه بهینه پارتو مشتمل بر راه‌حل‌های غیر مغلوب (ضرایب a و b در رابطه ۱) که با استفاده از الگوریتم ژنتیک NSGA-II و به‌کارگیری هم‌زمان



شکل ۷- جبهه بهینه پارتو به همراه دو تابع هدف NS_objfun و LOGE
Figure 7. Pareto optimal front with two NS_objfun and LOGE objective functions

1- Intercept

به‌طور کلی برآورد صحیح بار رسوب معلق در برنامه‌ریزی، طراحی و عملکرد مطلوب سازه‌های منبع آب بسیار ضروری است. مدل‌های مبتنی بر روش‌های رگرسیون مانند مدل SRC، فرضیات محدودکننده‌ای از قبیل نرمال بودن، خطی بودن و واریانس ثابت دارند. این مدل‌ها قادر به ارائه یک راه‌حل (ضرایب a و b) برای برآورد بار رسوب هستند. از سوی دیگر، الگوریتم‌های تکاملی مانند GAs می‌توانند بیش از یک راه‌حل تولید کنند که رابطه بهینه بین دبی جریان و دبی رسوب را فراهم می‌کند. همچنین، الگوریتم‌ها به فرضیات رگرسیون محدود نمی‌شوند (۱). به‌طور کلی، برای بهینه‌سازی ضرایب مدل SRC، از تبدیل لگاریتمی داده و به‌کارگیری رگرسیون خطی با استفاده از روش کمترین مربعات خطا^۱ استفاده می‌شود. تبدیل لگاریتمی داده‌ها موجب ایجاد یک خطا در محاسبه ضرایب مدل شده که در نتیجه آن، کم برآوردی^۲ مقدار SSL را سبب می‌شود. این مشکل در دبی‌های سیلابی نمود بیشتری داشته و خطای مدل با افزایش دبی جریان زیادتر می‌گردد. تاکنون، ضرایب مختلفی برای اصلاح این خطا ارائه شده است. با این حال، این ضرایب گاه خود منجر پیدایش خطای دیگری در افزایش برآورد^۳ SSL یا تولید نتایج متفاوت با داده‌های یکسان می‌شوند. در این پژوهش، علاوه بر مدل‌های سنتی منحنی سنجه رسوب (SRC، SRC-MeanLoad، SRC-CF1، SRC-CF2، SRC-FAO)، از الگوریتم‌های تکاملی (الگوریتم ژنتیک تک هدفه SRC-GA-I و چندهدفه NSGA-II) نیز به‌منظور بهینه‌سازی ضرایب مدل SRC استفاده که نتایج آن‌ها مطلوب‌تر از مدل‌های متعارف SRC بود. این نتایج، با نتایج آلتونکیناک (۱)، اسوین و ساهو (۴۲) محمدرضا پور و همکاران (۳۵)، بهمنش و همکاران (۳) و اصلانی و همکاران (۲) همخوانی دارد. به‌طور کلی در واسنجی خودکار مدل‌ها و به‌منظور سنجش نیکوئی برازش آن‌ها در اغلب موارد، رویه^۴ واسنجی، اساساً بر روی یک تابع هدف کلی (برای مثال MSE) تمرکز یافته است (۳۲). یاپو و همکاران (۴۷) نشان دادند که در این روش‌ها، توجه اصلی به انتخاب و جستجو در پارامترهای مدل به نحوی است که فاصله بین داده‌های مشاهده‌ای و شبیه‌سازی شده به حداقل برسد. لازم است به این نکته توجه شود که استفاده از یک تابع هدف به تنهایی نمی‌تواند تمامی جنبه‌های مهم یک سیستم را که در داده‌های مشاهده‌ای آن سیستم به‌صورت پنهان وجود دارد آشکار نموده و آن را شبیه‌سازی نماید (۳۲). در این رابطه شاخص کارایی ناش-ساتکلیف^۵ (NSE) که توسط ناش و ساتکلیف معرفی گردید (۳۸)، یکی از محبوب‌ترین شاخص‌های اندازه‌گیری کارایی مدل‌ها است (۱۹). علیرغم محبوبیت این شاخص، NSE دارای محدودیت‌هایی است (۸،۲۸). حساسیت زیاد این شاخص به مقادیر بالای یک متغیر (مثلاً حداکثر جریان) سبب می‌شود تا میزان خطای حاصله از شبیه‌سازی متغیر در مقادیر زیاد آن به دلیل استفاده از مربع انحرافات بسیار زیاد شده، لذا مدل‌های هیدرولوژیکی را برای شبیه‌سازی جریان‌های کم، کمتر حساس می‌کند (۸،۲۸،۳۰). بنابراین، پارامترهای این‌گونه مدل‌ها به نحوی واسنجی می‌شوند که بتوانند مقادیر بالای متغیرها را بهتر شبیه‌سازی نمایند. در دیگر توابع هدف نظیر

RMSE و MSE که مربع باقی‌مانده را به حداقل می‌رسانند، شرایط مشابهی وجود دارد. در مقایسه با توابع هدف یادشده (NSE و RMSE) توابع هدف MAE یا LOGE نسبت به مقادیر زیاد جریان، حساسیت کمتری داشته و بر عکس نسبت به مقادیر کم جریان، حساسیت بیشتری دارد و در نتیجه عملکرد مدل را یکنواخت‌تر می‌نماید (۵،۳۶). با توجه به نظر مولتا (۳۷)، دقت واسنجی چند هدفه می‌تواند با استفاده از یک تابع هدف از هر گروه بهبود یابد. با توجه به مطالب گفته‌شده، در پژوهش حاضر به‌منظور واسنجی چند هدفه مدل‌ها، از الگوریتم ژنتیک NSGA-II که استفاده هم‌زمان از چندین تابع هدف را میسر می‌نماید استفاده شد. در این رابطه، کارایی توابع هدف LOGE، RMSE، MAE و NSE مورد بررسی قرار گرفت و با توجه به کارایی بیشتر توابع هدف NSE و LOGE در برآورد SSL، این توابع به‌عنوان بهترین توابع هدف در واسنجی چند هدفه خودکار مدل SRC انتخاب شدند. استفاده هم‌زمان از این دو تابع در مدل چند هدفه SRC-GA-II موجب شد تا کارایی این مدل در برآورد مقادیر SSL بهتر از مدل تک هدفه SRC-GA-I باشد. استفاده هم‌زمان از توابع هدف چندگانه در واسنجی خودکار مدل‌ها در این پژوهش با نتایج کارهای مولتا (۳۷)، بکلی و همکاران (۴)، چودهاری و همکاران (۶)، افسرانیادیس و کوتسویانیس (۱۴) و ارکن و گودال (۱۵) همخوانی دارد. علاوه بر واسنجی مدل‌ها، همگن‌سازی و خوشه‌بندی داده‌ها قبل از مدل‌سازی، از جمله نکاتی است که به دلیل اهمیت در این پژوهش مورد توجه و تأکید قرار گرفت. به‌طور کلی به‌منظور افزایش قدرت تعمیم دهی مدل‌های داده مینا، لازم است نمونه‌های مورد استفاده در واسنجی مدل‌ها، نماینده و معرف داده‌های سیستم در طول دوره آماری باشند. از سوی دیگر، به‌منظور ارزیابی صحیح مدل‌ها بایستی، داده‌های مورد استفاده در آزمون مدل‌ها، مشابه با داده‌های استفاده شده در واسنجی آن‌ها باشند. این مسئله، یکی از مسائل مهم و از چالش‌های اساسی در مدل‌سازی محسوب شده به‌نحوی که عدم استفاده از داده‌های مشابه و همگن در مجموعه‌های واسنجی و آزمون می‌تواند نتایج مدل‌سازی را تا حد زیادی تحت تأثیر قرار دهد (۳۳). در این راستا در پژوهش حاضر، با استفاده از شبکه عصبی نگاشت خودسازمان‌ده (SOM)، اقدام به تهیه مجموعه‌های همگن و مشابه از داده‌ها جهت واسنجی و آزمون مدل‌ها گردید. نتایج این بخش از پژوهش با کار لی و همکاران (۳۱) مطابقت دارد. در مجموع، استفاده از نتایج این پژوهش می‌تواند به‌عنوان یک رویکرد مناسب و جدید در بهبود کارایی مدل‌های منحنی سنجه رسوب در برآورد بار رسوب معلق رودخانه‌ها مورد استفاده قرار گیرد.

تشکر و قدردانی

این مقاله حاوی برخی نتایج گرفته شده از اجرای یک پروژه ملی در ایستگاه‌های هیدرومتری منتخب کشوری است که در پژوهشکده حفاظت خاک و آبخیزداری کشور و توسط نویسنده به اجرا درآمده است که بدین‌وسیله از حمایت‌های مادی و معنوی این پژوهشکده تشکر و قدردانی می‌شود.

1- Least Square Error Method
5-Nash-Sutcliffe Efficiency (NSE)

2- Underestimation

3- Overestimation

4- Procedures

منابع

1. Altunkaynak, A. 2009. Sediment load prediction by genetic algorithms. *Advances in Engineering Software*, 40: 928-934.
2. Aslani, M., R. Fazl Ola and M. Ahmadzadeh. 2015. Determination of Nash conceptual model parameter using auto calibration in Kasilian watershed. *Journal of Watershed Management Research* 6(12):21-28 (In Persian).
3. Bahmanesh, J., M. Mohammadpour and M.M. Bateni. 2017. Comparison of river suspended sediment load estimation, using regression and GA methods. *Journal of Watershed Management Research* 8(16):132-141 (In Persian).
4. Bekele, E.G. and J.W. Nicklow. 2007. Multi-objective automatic calibration of SWAT using NSGA-II. *Journal of Hydrology*, 341(3): 165-176.
5. Buyukyildiz, M. and S.Y. Kumcu. 2017. An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models. *Water Resources Management*, 31(4): 1343-1359.
6. Choudhury, P. and B.S. Sil. 2010. Integrated water and sediment flow simulation and forecasting models for river reaches. *Journal of Hydrology*, 385(1): 313-322.
7. Cohn, T.A., L.L. Delong, E.J. Gilroy, R.M. Hirsch and D.K. Wells. 1989. Estimating constituent loads. *Water Resources Research*, 25(5): 937-942.
8. Criss, R.E. and W.E. Winston. 2008. Do Nash values have value? Discussion and alternate proposals. *Hydrological Processes*, 22(14): 2723.
9. Danndhmhr, A., A. Olyiaie and M.A. Ghorbani. 2010. Suspended sediment load prediction based on river discharge and genetic programming method. *Iranian journal of Watershed Management Researches Journal (Pajouhesh & Sazandegi)*, 88: 44-54 (In Persian).
10. Deb, K. 2001. *Multi-objective optimization using evolutionary algorithms*, Wiley, New York, USA, 512 pp.
11. Deb, K., A. Pratap, S. Agarwal and T. Meyarivan. 2002. A fast and elitist multi-objective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2): 182-197.
12. Duan, N. 1983. Smearing estimate: a nonparametric transformation method. *Journal of the American Statistical Association*, 78(383): 605-610.
13. Ebtahaj, I. and H. Bonakdari. 2016. Assessment of evolutionary algorithms in predicting non-deposition sediment transport. *Urban Water Journal*, 13: 499-510.
14. Efstratiadis, A. and D. Koutsoyiannis. 2010. One decade of multi-objective calibration approaches in hydrological modelling: a review. *Hydrological Sciences Journal*, 55(1): 58-78.
15. Ercan, M.B. and J.L. Goodall. 2016. Design and implementation of a general software library for using NSGA-II with SWAT for multi-objective model calibration. *Environmental Modelling and Software*, 84:112-120.
16. Ferguson, R.I. 1986. River loads underestimated by rating curves. *Water Resources Research*, 22: 74-76.
17. Gupta, H.V., S. Sorooshian and P.O. Yapo. 1998. Toward improved calibration of hydrologic models: multiple and noncommen surable measures of information. *Water Resources and Research*, 34(4): 751-763.
18. Gupta, H.V., S. Sorooshian and P.O. Yapo. 1999. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. *Journal of Hydrologic Engineering*, 4(2): 135-143.
19. Gupta, H.V., H. Kling, K.K. Yilmaz and G.F. Martinez. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modeling. *Journal of Hydrology (Amsterdam)*, 377(1-2): 80-91.
20. Jansson, M.B. 1996. Estimating a sediment rating curve of the Reventazon river at Palomo using logged mean loads within discharge classes. *Journal of Hydrology*, 183(3-4): 227-241.
21. Jones, K.R., O. Berney, D.P. Carr and E.C. Barrett. 1981. *Arid zone hydrology for agricultural development*. FAO Irrigation and Drainage Paper, Rome, Italy, 271 pp.
22. Kalteh, A.M. 2008. Rainfall-runoff modelling using artificial neural networks (ANNs): modeling and understanding. *Caspian Journal of Environmental Sciences*, 6: 53-58.
23. Kalteh, A.M., P. Hjorth and R. Berndtsson. 2008. Review of the self-organizing map (SOM) approach in water resources: analysis, modelling and application. *Environmental Modeling and Software*, 23: 835-845.
24. Kao, S.J., T.Y. Lee and J.D. Milliman. 2005. Calculating highly fluctuated suspended sediment fluxes from mountainous rivers in Taiwan. *Terrestrial Atmospheric and Oceanic Sciences*, 16: 653-675.
25. Kaufman, L. and P.J. Rousseeuw. 2009. *Finding groups in data: an introduction to cluster analysis (Vol. 344)*, John Wiley & Sons, New Jersey, USA, 342 pp.
26. Koch, R.W. and G.M. Smillie. 1986. Comment on "River loads underestimated by rating curves" by RI Ferguson. *Water Resources Research*, 22(13): 2121-2122.
27. Kohonen, T. 1982. Analysis of a simple self-organizing process. *Biological Cybernetics*, 44: 135-140.
28. Krause, P., D.P. Boyle and F. Bäse. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5: 89-97.
29. Kuok, K.K., S. Harun and S.M. Shamsuddin. 2010. Particle swarm optimization feed forward neural network for modeling runoff. *International Journal of Environmental Science and Technology*, 7: 67-78.
30. Legates, D.R. and G.J. McCabe. 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1): 233-241.

31. Li, X., M.H. Nour, D.W. Smith and E.E. Prepas. 2010. Neural networks modelling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environmental Technology*, 31: 495-510.
32. Madsen, H. 2000. Automatic calibration of a conceptual rainfall-runoff model using multiple objectives. *Journal of Hydrology*, 235(3): 276-288.
33. May, R.J., H.R. Maier and G.C. Dandy. 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Networks*, 23: 283-294.
34. Miller, D.M. 1984. Reducing transformation bias in curve fitting. *The American Statistician*, 38(2): 124-126.
35. Mohammad Rezapour, O., P. Nourjou and M.J. Zeynali. 2016. Compression of genetic algorithm and particle swarm algorithm models for optimizing coefficients of sediment rating curve in the estimation of suspended sediment in Sistan river (Case Study: Kohak station). *The Iranian Society of Irrigation and Water Engineering*, 6: 76-89 (In Persian).
36. Muhammedi, A., G. Akbari and G. Azizzian. 2012. Suspended sediment concentration estimation using artificial neural networks and neural-fuzzy inference system case study: Karaj Dam. *Indian Journal of Science and Technology*, 5: 3188-3193.
37. Muleta, M.K. 2011. Model performance sensitivity to objective function during automated calibrations. *Journal of Hydrologic Engineering*, 17(6): 756-767.
38. Nash, J.E. and J.V. Sutcliffe. 1970. River flow forecasting through conceptual models part I-A discussion of principles. *Journal of Hydrology*, 10(3): 282-290.
39. Rodriguez-Blanco, M.L., M.M. Taboada-Castro, L. Palleiro-Suárez and M.T. Taboada-Castro. 2010. Temporal changes in suspended sediment transport in an Atlantic catchment, NW Spain. *Geomorphology*, 123: 181-188.
40. Schwefel, H.P.P. 1995. *Evolution and optimum seeking: the sixth generation*. John Wiley & Sons, Inc., New York, USA, 456 pp.
41. Srinivas, N. and K. Deb. 1994. Multiple objective optimizations using non-dominated sorting in genetic algorithms. *Evolutionary Computation* 2(2): 221-248.
42. Swain, R. and B. Sahoo. 2017. Mapping of heavy metal pollution in river water at daily time-scale using spatio-temporal fusion of MODIS-aqua and Landsat satellite imageries. *Journal of Environmental Management*, 192: 1-14.
43. Thomas, R.B. 1985. Estimating total suspended sediment yield with probability sampling. *Water Resources Research*, 21(9): 1381-1388.
44. Ulke, A., G. Tayfur and S. Ozkul. 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. *Journal of Hydrologic Engineering*, 14: 954-965.
45. Veldhuizen, D.A.V. and G.B. Lamont. 2000. Multiobjective evolutionary algorithms: analyzing the state-of-the-art. *Evolutionary Computation*, 8(2): 125-147.
46. Vercruyssen, K., R.C. Grabowski and R.J. Rickson. 2017. Suspended sediment transport dynamics in rivers: Multi-scale drivers of temporal variation. *Earth-Science Reviews*, 166: 38-52.
47. Yapo, P.O., H.V. Gupta and S. Sorooshian. 1998. Multi-objective global optimization for hydrologic models. *Journal of Hydrology*, 204(1-4): 83-97.
48. Yar Kiani, A. 2009. *Intelligent Systems*. Press Center of Poyesh Andisheh, Tehran, Iran, 260 pp (In Persian).
49. Yee, K.Y., A.K. Ray and G.P. Rangaiah. 2003. Multi-objective optimization of industrial styrene reactor. *Computers and Chemical Engineering*, 27: 111-130.

Presenting a New Approach to Increase the Efficiency of the Sediment Rating Curve Model in Estimating Suspended Sediment Load in Watersheds (Case Study: Mahabad-Chai River, Lake Urmia Basin, West Azarbayejan Province, Iran)

Mahmoud Reza Tababaei¹, Amin Salehpourjam² and Seyed Ahmad Hosseini²

1- Assistant Professor, Soil and Water Conservation Research Institute, Agricultural Research and Training Organization, Tehran, Iran (Corresponding Author: taba1345@hotmail.com)

2- Assistant Professor, Soil and Water Conservation Research Institute, Agricultural Research and Education Organization, Tehran, Iran

Received: April 4, 2018

Accepted: October 21, 2018

Abstract

The estimation of the correct amount of suspended sediment has an important role in the optimal design of water structures, erosion studies and water quality studies. The sediment rating curve (SRC) is a conventional and well-known regression model. However, due to logarithmic transformations in calibrating this model, its estimated values are often less than actual values. In the present study, using the instantaneous flow discharge and suspended sediment load of Beytas hydrometric station in the Mahabad-Chai River, the SRC model was calibrated, and then using Non-dominated Sorting Genetic Algorithm II (NSGA-II), the coefficients of this model optimized again. This algorithm is an automatic procedure and can use different objective functions in the calibration process simultaneously. In this regard, in the calibration process of the model, four objective functions RMSE, MAE, NSE, and LOGE were used as pairwise combinations. According to the results of the model evaluation, the NSE and LOGE objective functions were selected as the best objective functions for optimization of the model. In order to increase the power of the model's generalization, the self-organizing map (SOM) neural network was used to cluster data and form two homogeneous data sets (calibration and evaluation sets) of 70% and 30% respectively. The results showed that the use of the NSGA II algorithm resulted in improved model efficiency so that the results are much more favorable than the other results of conventional SRC models (such as the rating curve of mean load within discharge classes, SRC models corrected by correction factors). In this regard, the error value (RMSE) of the test data set in the best model of the conventional SRC models was 383.65 tons/day, which was reduced by using the NSGA II algorithm to 102.94 tons/day. In sum, using the NSGA-II algorithm, we can optimize the coefficients of the SRC model, which is more efficient than the other conventional models.

Keywords: Artificial Neural Network, Clustering, Curve, Non-dominated Sorting Genetic Algorithm II (NSGA-II), Sediment Rating Self-Organizing Map, Suspended Sediment