



برآورد بار معلق در سیستم رودخانه‌ای با استفاده از روش گروهی کنترل داده‌ها (GMDH)

زهرا ایوانی^۱، محمد مهدی احمدی^۲ و کوروش قادری^۲

۱- دانشجوی کارشناسی ارشد، دانشگاه شهید باهنر کرمان، (نویسنده مسؤل: eivani4181@yahoo.com)

۲- استادیار، دانشگاه شهید باهنر کرمان

تاریخ پذیرش: ۹۳/۴/۳۱

تاریخ دریافت: ۹۲/۶/۲۱

چکیده

برآورد دقیق میزان انتقال بار رسوب در رودخانه‌ها و مخازن اهمیت زیادی در برنامه‌ریزی، طراحی، اجرا و نگهداری سازه‌های آبی دارد. استخراج روابط ریاضی حاکم بر پدیده انتقال رسوبات بسیار پیچیده است. برای شبیه‌سازی چنین پدیده‌هایی، می‌توان از روش‌های داده‌محوری مانند روش کنترل گروهی داده‌ها (GMDH) استفاده کرد که یک رویکرد خودسازماندهی داده بوده و روشی برای شناسایی روابط غیرخطی بین متغیرهای ورودی و خروجی به کار می‌رود. در پژوهش حاضر، با استفاده از روش فوق مدلی برای پیش‌بینی نرخ انتقال رسوب در سیستم رودخانه توسعه داده شده است. برای بررسی کارایی مدل‌ها از داده‌های دبی روزانه جریان و غلظت بار معلق رسوب دو ایستگاه Rio Valencia و Quebrada Blanca استفاده شده است. بررسی کارایی مدل‌ها با استفاده از معیارهای آماری MSE، RB و R^2 انجام شده است. مقادیر معیارهای آماری به دست آمده و نیز مقایسه نتایج با سایر الگوریتم‌ها مانند شبکه‌های عصبی، نروفازی و برنامه‌ریزی ژنتیک خطی نشان داد که روش گروهی کنترل داده‌ها نسبت به سایر روش‌ها از قابلیت بالاتری برای پیش‌بینی و شبیه‌سازی نرخ انتقال رسوب در رودخانه‌ها برخوردار است.

واژه‌های کلیدی: نرخ انتقال رسوب، شبیه‌سازی، روش گروهی کنترل داده‌ها (GMDH)

مقدمه

تعداد انتقال رسوب به دست آمده‌اند که این شرایط در رودخانه‌های طبیعی خیلی کم اتفاق می‌افتد. بنابراین، دبی رسوب برآورد شده با توجه به فرضیات ساده کننده مذکور دقیق نمی‌باشد (۹). برآورد دقیق بار رسوب به علت رابطه نزدیک آن با جریان، مکانیزم غیرخطی و برهم کنش‌های پیچیده این پدیده، بسیار مشکل است (۱۷). برای شبیه‌سازی پدیده‌هایی از این دست، می‌توان از روش‌های داده‌محور که زیرمجموعه‌ای از روش‌های محاسبات نرم هستند و نیازی به روابط پیچیده حاکم بر پدیده ندارند، استفاده نمود. اجزای اصلی محاسبات نرم شامل منطق فازی، شبکه‌های عصبی و الگوریتم‌های تکامل‌گرا می‌باشند که توانایی‌های زیادی در شناسایی سیستم‌های غیرخطی و مسائل کنترلی دارند (۱۱).

رودخانه یک سیستم دینامیکی است که از سوی فرآیندهای هیدرولیکی و انتقال رسوب کنترل می‌شود. رودخانه به مرور زمان با تغییر مقطع عرضی کانال، افزایش یا کاهش قابلیت حمل رسوب و فرسایش و رسوب‌گذاری در طول کانال که همه ثبات و استحکام ساحل و مورفولوژی رودخانه را تحت تاثیر قرار می‌دهند، وضعیت خود را تغییر می‌دهد (۴). با افزایش اهمیت استفاده صحیح از منابع آب موضوع انتقال رسوب در جریان‌های رودخانه‌ای اهمیت بیش‌تری پیدا می‌کند (۲۱). هم‌چنین، برآورد دقیق میزان انتقال بار رسوبات حمل شده از طریق رودخانه در بسیاری از پروژه‌های مهندسی منابع آب از قبیل کانال‌های کشتیرانی، اجرای مخازن سدها، طول عمر تجهیزات هیدروالکتریکی، مسائل زیست‌محیطی و سایر موضوعات مرتبط مورد نیاز است (۱۷). معادلات زیادی بر پایه روش‌های مختلف برای برآورد نرخ انتقال رسوب در رودخانه‌ها توسعه داده شده است. روش‌های متداول که در بسیاری از مدل‌سازی‌ها استفاده شده اند غالباً با یک شکل ساده شده از توابع تجربی یا تحلیلی آغاز می‌شوند و با یک تحلیل رگرسیونی یا مشخص کردن منحنی سنججه مناسب با استفاده از داده‌های آزمایشگاهی برای تعیین ضرایب مجهول مدل دنبال می‌شوند (۲۷). تقریباً همه معادلات تجربی برآورد بار رسوب برای شرایط ساده جریان‌های یکنواخت دائمی و

محققین زیادی هم‌چون آیتک (۳)، آلپ و همکاران (۲)، کیسی (۱۳، ۱۴، ۱۵، ۱۷)، میلیسی و همکاران (۱۸)، قانی و همکاران (۸)، عظمت‌اله و همکاران (۵)، فیرات (۷) از الگوریتم‌های مختلفی مانند شبکه عصبی، منطق فازی، الگوریتم ژنتیک (GA)، سیستم تطبیقی استنتاج فازی-عصبی (ANFIS)، الگوریتم پس انتشار خطا (FFBP)، الگوریتم پیشخور (FFNN) و ... برای شبیه‌سازی بار معلق، بار بستر و تعیین رابطه بین دبی و بار رسوب در رودخانه‌ها استفاده کرده‌اند. نتایج به دست آمده از سوی این محققین نشان می‌دهد که در مقایسه با روش‌های تجربی و منحنی‌های سنججه رسوب،

هدف از پژوهش حاضر، توسعه مدلی برای پیش‌بینی نرخ انتقال بار رسوب معلق در سیستم رودخانه‌ای با استفاده از الگوریتم GMDH است. به این منظور مدلی بر اساس رویکرد خودسازماندهی GMDH در قسمت برنامه‌نویسی نرم‌افزار MATLAB توسعه داده شده است. برای بررسی کارایی مدل از داده‌های دبی روزانه جریان و غلظت بار معلق رسوب دو ایستگاه Rio Valenciano و Quebrada Blanca که از طرف اداره‌ی نقشه‌برداری و زمین‌شناسی ایالات متحده (USGS) جمع‌آوری شده استفاده شده است. توجه به این نکته حائز اهمیت است که چون GMDH بر مبنای داده‌های حاصل از سیستم رودخانه عمل می‌کند، ویژگی‌های رودخانه بر برآورد نتایج تأثیرگذار است.

مواد و روش‌ها

روش کنترل‌گروهی داده‌ها (GMDH)

در این قسمت به طور خلاصه مفهوم اولیه GMDH، چگونگی حل مسئله با این روش، فرمول‌بندی، ساختار و الگوریتم آن ارائه شده است. رزنبلات در سال ۱۹۵۸ مفهوم پرسپترون را بر اساس عملکرد نرون‌ها ارائه کرد. GMDH یکی از رویکردهای استقرائی مبتنی بر تئوری پرسپترون بوده که برای شناسائی سیستم‌ها، مدل‌سازی و پیش‌بینی سیستم‌های پیچیده توسعه داده شده است. GMDH ترکیبی از N-آدلاین‌ها (نرون‌ها) می‌باشد و نسبت به ساختار نوع پرسپترون دارای دقت بالاتری است چرا که از طبقه‌بندی اطلاعات به صورت مفید و غیرمفید استفاده کرده و به تعداد داده‌های مشاهداتی کمتری احتیاج دارد و هم‌چنین زمان انجام محاسبات کمتر می‌شود (۱۹).

ساختار GMDH

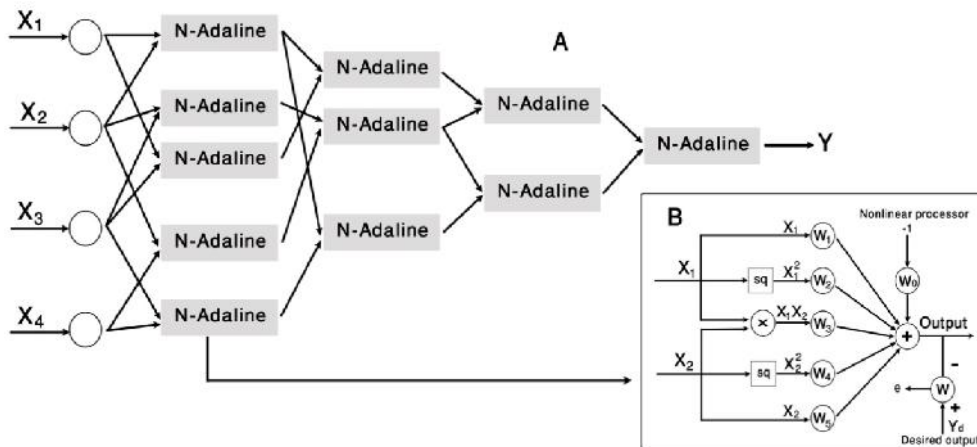
در شکل ۱ دیاگرام شماتیک شبکه GMDH همراه با نمایی از ساختار N-آدلاین با تابع محرک چندجمله‌ای درجه دو نشان داده شده است. Sq و \times به ترتیب بیانگر مجذور و حاصل‌ضرب، x_1 و x_2 ورودی‌ها و y خروجی می‌باشد. معیار آستانه برای تعیین ساختار شبکه به صورت زیر تعریف می‌شود:

$$R^2 = \frac{\sum_{t=1}^N (\hat{y}(t) - \bar{\hat{y}})^2}{\sum_{t=1}^N (y(t) - \bar{y})^2} \quad (1) \text{ رابطه}$$

که در آن، y : خروجی مطلوب، \hat{y} : خروجی محاسباتی، $\bar{\hat{y}}$: میانگین خروجی‌های محاسباتی، \bar{y} : میانگین خروجی‌های مطلوب است.

مدل‌های مختلف شبکه‌های عصبی و سیستم‌های فازی قادر هستند نرخ انتقال بار رسوب را با دقت بسیار بالاتری تخمین بزنند. یکی از انواع روش‌های داده محور که کاربردهای زیادی نیز در بخش‌های مختلف داشته است، مدل فراذهنی برخورد گروهی با داده‌ها (GMDH) می‌باشد. این روش یک رویکرد خودسازماندهی داده بوده و به تدریج مدل‌های پیچیده‌تری در طول ارزیابی عملکرد مجموعه داده‌های ورودی و خروجی تولید می‌کند (۱۱). اولین بار ایواخنکو در سال ۱۹۶۸ این الگوریتم را بر پایه مفهوم پرسپترون ارائه نمود. طرح اصلی این الگوریتم محاسبه ساختار بهینه یک مدل پیچیده، صرفاً بر پایه داده‌ها و نه بر پایه دانسته‌های قبلی محقق می‌باشد (۶). الگوریتم GMDH برای سیستم‌های پیچیده بسیار مناسب است و می‌تواند به طور مستقیم اطلاعات را در مورد تابع هدف، از نمونه‌برداری داده‌ها استخراج کند. این روش قابلیت استفاده در موضوعات متنوعی چون کشف روابط، پیش‌بینی، مدل‌سازی سیستم‌ها، بهینه‌سازی و شناخت الگوهای غیرخطی را دارا می‌باشد. نکته حائز اهمیت در این الگوریتم استنتاجی، قابلیت شناسایی و غربال کردن متغیرهای کم اثر ورودی در دوره آموزش شبکه و حذف آن‌ها در روند شبیه‌سازی در آزمون می‌باشد (۱). GMDH کاربردهای موفقیت‌آمیزی در مهندسی، علوم و اقتصاد شامل شناسائی قوانین فیزیکی، پیش‌بینی کوتاه مدت فرآیندها، شناسائی الگوها در متغیرهای گسسته و پیوسته داشته است (۲۰). نیکولاو و هیتوشی (۲۲) از این روش برای مدل‌سازی سری‌های زمانی در شاخه‌های مختلف علمی مانند اکولوژی، هواشناسی و اقتصادی استفاده کردند.

نریمان‌زاده و همکاران (۲۰) از این روش برای بهینه‌سازی چندمنظوره دینامیک حرارتی موتورهای سوخت هواپیما بهره گرفتند. نیشیکاوا و شیمیزو (۲۳) از GMDH در شبکه پیش‌بینی فروش ماشین در صنعت خودروسازی ژاپن استفاده کردند. ابریشمی و همکاران (۱) به منظور دستیابی به پیش‌بینی‌های بهتر در بازار نفت، قواعد موجود در آن را با استفاده از الگوریتم GMDH استخراج کردند. قادری و همکاران (۲۶) نیز از این روش برای مدل‌سازی بهره‌برداری از مخازن بهره گرفتند. نتایج آنها حاکی از دقت و قدرت این روش در مدل‌سازی مبتنی بر داده‌های مشاهداتی بوده است. پورنعمت و همکاران (۲۵) از این روش برای شبیه‌سازی فرآیند بارش رواناب استفاده کردند. نتایج حاصل از توسعه مدل GMDH در این تحقیق حاکی از عملکرد بالای این روش در پیش‌بینی و شناسایی روابط پیچیده بین متغیرها در مسائل مختلفی نظیر پیش‌بینی رواناب ناشی از بارندگی می‌باشد.



شکل ۱- (A): شماتیکی از ساختار GMDH و (B): ساختار هر N-Adaline.

واسنجی پارامترها:

هر نرون در ساختار GMDH یک تابع غیرخطی از ورودی‌ها را اجرا می‌کند. این تابع غیرخطی می‌تواند به صورت‌های زیر باشد:

رابطه (۲)

$$y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2$$

رابطه (۳)

$y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1 x_2$
ضرایب شش‌گانه هر نرون در شبکه از طریق رویکرد حداقل مربعات محاسبه می‌شوند که مراحل انجام این کار به صورت زیر است:

فرض کنید N بردار ورودی $X_n = (X_{n1}, X_{n2}, \dots, X_{np})$ و $n = 1, 2, 3, \dots, N$ در مجموعه آموزشی وجود دارد. مقدار مطلوب خروجی m با ϕ_n نشان داده می‌شود. باید مجموعه‌ای از ضرایب ϕ گانه برای هر نرون پیدا شود طوری که میانگین مربعات خطا بین خروجی‌های این نرون، y_n و مقدار خروجی واقعی ϕ_n حداقل باشد. با استفاده از معادلات نرمال گوسین، ضرایب به صورت زیر به دست می‌آیند:

رابطه (۴)

$$\phi_1 = w_0 + w_1 X_{1i} + w_2 X_{1j} + w_3 X_{1i}^2 + w_4 X_{1j}^2 + w_5 X_{1i} X_{1j}$$

$$\phi_2 = w_0 + w_1 X_{2i} + w_2 X_{2j} + w_3 X_{2i}^2 + w_4 X_{2j}^2 + w_5 X_{2i} X_{2j}$$

$$\phi_N = w_0 + w_1 X_{Ni} + w_2 X_{Nj} + w_3 X_{Ni}^2 + w_4 X_{Nj}^2 + w_5 X_{Ni} X_{Nj}$$

که به صورت ماتریس کلی زیر نوشته می‌شود:

رابطه (۵)

$\phi = X W$
ماتریس‌های ϕ ، X و W دارای ابعاد $1 \times N$ ، $6 \times N$ ، $1 \times N$ هستند. معادلات نرمال با استفاده از ضرب طرفین رابطه بالا در ترانپوز ماتریس X به دست می‌آیند:

$$X^T \phi = (X^T X) W \Rightarrow W = (X^T X)^{-1} X^T \phi \quad (۶)$$

الگوریتم یادگیری GMDH شامل مراحل زیر است (۲۲):

- ۱- انتخاب متغیرهای ورودی به مدل
- ۲- جمع‌آوری مجموعه‌ای از داده‌های مشاهداتی مرتبط با موضوع مورد بررسی
- ۳- تقسیم‌بندی داده‌ها به دو گروه داده‌های واسنجی و صحت‌سنجی
- ۴- ساخت N -آدلاین برای تمام ترکیبات دوتایی از متغیرهای ورودی
- ۵- انتخاب نوع تابع محرک برای هر نرون
- ۶- تخمین ضرایب وزنی برای تمام N -آدلاین‌ها با روش تخمین حداقل مربعات (LSE) و محاسبه معیار فیلتراسیون
- ۷- مقایسه معیار محاسبه شده برای تمام N -آدلاین‌ها با مقدار آستانه تعیین شده. اگر مقدار آستانه بزرگ‌تر از معیار باشد، N -آدلاین حذف می‌شود و دیگر N -آدلاین‌ها برای لایه بعد باقی می‌مانند. می‌توان برای تمام لایه‌ها یک مقدار آستانه ثابت یا برای هر لایه یک مقدار آستانه در نظر گرفت.
- ۸- اگر بزرگ‌ترین معیار در لایه جاری بزرگ‌تر از معیار لایه قبلی بود و چندین N -آدلاین بزرگ‌تر از آستانه وجود داشت، در صورت فقدان توسعه شبکه می‌توان N -آدلاین با بزرگ‌ترین معیار را به عنوان خروجی شبکه در نظر گرفت.
- ۹- اگر بزرگ‌ترین معیار در لایه جاری کم‌تر یا مساوی یکی از لایه‌های قبل بود، N -آدلاین لایه قبل با بیش‌ترین معیار برای خروجی در نظر گرفته می‌شوند. در غیر این صورت یکی از N -آدلاین‌ها را لایه جاری بعنوان خروجی در نظر گرفته شده N -آدلاین‌های مرتبط با این خروجی به صورت GMDH شبکه در نظر گرفته می‌شوند.

وجود آنکه پراکندگی داده‌ها کار مدل‌سازی را مشکلتر می‌کند این داده‌های جدا افتاده نیز در آموزش مدل در نظر گرفته شده است. جداول ۱ و ۲ پارامترهای آماری مربوط به هر ایستگاه شامل مینیمم، ماکزیمم، میانگین، انحراف معیار، ضریب چولگی و ضریب تغییر داده‌های مورد استفاده را نشان می‌دهد. پیش از استفاده از داده‌ها در اجرای مدل، مجموعه داده‌های مورد استفاده برای آموزش و آزمون با فرمول زیر نرمال شدند:

$$a \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} + b \quad \text{رابطه (۷)}$$

که در آن x_{\max} و x_{\min} به ترتیب مینیمم و ماکزیمم مجموعه داده‌ها هستند. مقادیر a و b در این مطالعه به ترتیب $۰/۶$ و $۰/۲$ در نظر گرفته شده است.

بررسی صحت‌سنجی مدل GMDH توسعه داده شده

قبل از آن که مدل‌های مورد نظر در هر ایستگاه اجرا شود لازم است صحت و سقم مدل توسعه داده شده از سوی توابع استاندارد مورد بررسی قرار گیرد. در ادامه نشان داده می‌شود که چگونه مدل هوشمند فزادنی GMDH توسعه داده شده در این پژوهش قادر است برای پیش‌بینی مقادیر آینده یک سری زمانی مغشوش مورد استفاده قرار بگیرد. سری زمانی مورد استفاده در این تحقیق برای صحت‌سنجی مدل، معادله دیفرانسیلی Mackey-Glass است که به صورت زیر تعریف می‌شود:

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad \text{رابطه (۸)}$$


که مقادیر a و b به ترتیب $۰/۲$ و $۰/۱$ می‌باشد. پیش‌بینی مقادیر آینده این سری زمانی یک مسئله پایه در مدل‌سازی می‌باشد که از سوی محققان بسیاری مورد استفاده قرار گرفته است. هدف این مدل‌سازی استفاده از مقادیر گذشته این سری زمانی تا زمان t برای پیش‌بینی مقادیر این سری زمانی در گام زمانی $(t+p)$ می‌باشد. روش استاندارد برای انجام این نوع پیش‌بینی ایجاد یک نگاهت از نقاط D این سری زمانی که به فاصله Δ از هم هستند یعنی $\{x(t), x(t-\Delta), \dots, x(t-(D-1)\Delta)\}$ در فضای ورودی‌ها برای پیش‌بینی مقادیر آینده $x(t+p)$ می‌باشد. برای این کار مقادیر پارامترهای D ، Δ و p مشابه با آنچه دیگر محققان در نظر گرفته‌اند.

$X^T X$ یک ماتریس 6×6 بوده و می‌توان ضرایب را با استفاده از روش معکوس به دست آورد. ماتریس W شامل مجموعه‌ای از ۶ ضریب می‌باشد که قادر به تقریب خروجی‌های صحیح با حداقل میانگین مربعات خطا می‌باشد.


مراحل فوق برای تمام عناصر لایه اول و نیز برای تمام عناصر لایه‌های بعدی نیز تکرار می‌شوند. بعد از به دست آمدن ضرایب بر اساس داده‌های آموزشی، شاخص عملکرد عناصر به دست آمده از طریق هم‌بستگی یا محاسبه میانگین خطای مربعات بین خروجی‌های واقعی داده‌های کنترل محاسبه می‌شوند و تنها عناصری که دارای شاخص عملکرد بالاتر از مقدار آستانه هستند برای ادامه مسیر انتخاب می‌شوند.

داده‌های مورد استفاده

برای صحت‌سنجی و کارایی مدل توسعه داده شده، از داده‌های روزانه دبی جریان و غلظت بار معلق رسوب در ایستگاه‌های Rio Valencia no و Quebrada Blanca که از سوی اداره‌ی نقشه‌برداری و زمین‌شناسی ایالات متحده جمع‌آوری شده (<http://webserver.cr.usgs.gov/sediment>) استفاده شده است. مساحت حوزه آبریز ایستگاه‌ها به ترتیب $۴۳/۵۷$ و $۸/۶۳$ کیلومتر مربع بوده و تراز آنها به ترتیب ۹۸ و ۱۳۰ متر از سطح دریا می‌باشد. دوره تاریخی از اول اکتبر ۱۹۹۳ تا ۳۰ سپتامبر ۱۹۹۴ (سال آبی ۱۹۹۴) معادل ۳۶۵ داده برای آموزش مدل و دوره تاریخی از اول اکتبر ۱۹۹۴ تا ۳۰ سپتامبر ۱۹۹۵ (سال آبی ۱۹۹۵) معادل ۳۶۵ داده برای آزمون مدل می‌باشد. نمودار پراکندگی کل داده‌های مورد استفاده در اشکال ۲ و ۳ نشان داده شده است. مشاهده می‌شود یک رابطه غیرخطی بین داده‌های دبی و رسوب در هر دو ایستگاه وجود دارد ضمن آن که نمودارها وجود یک جدا افتادگی در مجموعه داده‌های هر دو ایستگاه را نشان می‌دهد. چنانچه از مشخصات نقاط جدا افتاده در نمودارهای ۲ و ۳ مشخص است در ایستگاه Rio Valencia no به ازای دبی $۰/۰۹۰۶ \text{ (m}^3/\text{s)}$ مقدار غلظت بار معلق رسوب برابر است با ۱۲۰۰ (mg/l) در حالی که سایر مقادیر داده‌های غلظت بار رسوب در محدوده دبی کم‌تر از ۱۰۹۰ (mg/l) قرار دارند. هم‌چنین در ایستگاه Quebrada Blanca به ازای دبی $۵/۷ \text{ (m}^3/\text{s)}$ مقدار غلظت بار معلق رسوب برابر است با ۷۱۳ (mg/l) در حالی که سایر داده‌ها در محدوده دبی کم‌تر از m^3/s و غلظت کم‌تر از ۶۳۵ (mg/l) قرار گرفته‌اند. با



شکل ۳- نمودار پراکندگی کل داده‌ها در ایستگاه Rio Valenciano



شکل ۲- نمودار پراکندگی کل داده‌ها در ایستگاه Quebrada Blanca

جدول ۱- پارامترهای آماری مربوط به ایستگاه Quebrada Blanca

داده‌های آموزشی		داده‌های آموزشی		مجموعه همه داده‌ها		پارامترهای آماری
دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	
۰/۰۱۱	۱	۰/۰۰۹۳	۱	۰/۰۰۹۳	۱	مینیمم
۲/۳۸	۶۳۵	۵/۶۹	۷۱۳	۵/۶۹	۷۱۳	ماکزیمم
۰/۱۳۲	۲۰/۷۵	۰/۱	۱۵	۰/۱۱۴۵	۱۷/۹	میانگین
۰/۲۶	۶۳	۰/۳۳	۵۲	۰/۲۹۶	۵۷/۸	انحراف معیار
۵/۴۳	۷/۱	۱۴	۹/۱	۱۱/۴	۷/۹	ضریب چولگی
۱/۹۵	۳	۳/۴	۳/۴۶	۲/۶	۳/۲۳	ضریب تغییر

جدول ۲- پارامترهای آماری مربوط به ایستگاه Rio Valenciano

داده‌های آموزشی		داده‌های آموزشی		مجموعه همه داده‌ها		پارامترهای آماری
دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	دبی جریان (m ³ /s)	غلظت رسوب (mg/l)	
۰/۰۵۱	۴	۰/۰۴	۲	۰/۰۴	۲	مینیمم
۲۴/۶۳	۱۰۹۰	۳۵/۱	۱۲۰۰	۳۵/۱	۱۲۰۰	ماکزیمم
۱/۰۴۴	۷۱/۳۱	۰/۶۱	۴۱/۷۸	۰/۸۲۶	۵۶/۵۴	میانگین
۲/۴۷	۱۴۷/۲۵	۲/۰۶	۱۰۵/۸	۲/۲۸	۱۲۹	انحراف معیار
۵/۷۴	۴/۳۲	۱۳/۶	۷/۴۵	۸/۶۵	۵/۳۷	ضریب چولگی
۲/۳۵	۲/۰۶	۳/۴	۲/۵۳	۲/۷۵	۲/۲۸	ضریب تغییر

انحراف نسبی (RB) استفاده شده است که فرمول‌های آنها به صورت زیر است:

$$MSRE = \frac{1}{n} \sum_{i=1}^n \left(\frac{Q_i - \hat{Q}}{Q_i} \right)^2 \quad \text{رابطه (۹)}$$

$$MPRE = \frac{100}{n} \sum_{i=1}^n abc \left(\frac{Q_i - \hat{Q}}{Q_i} \right)$$

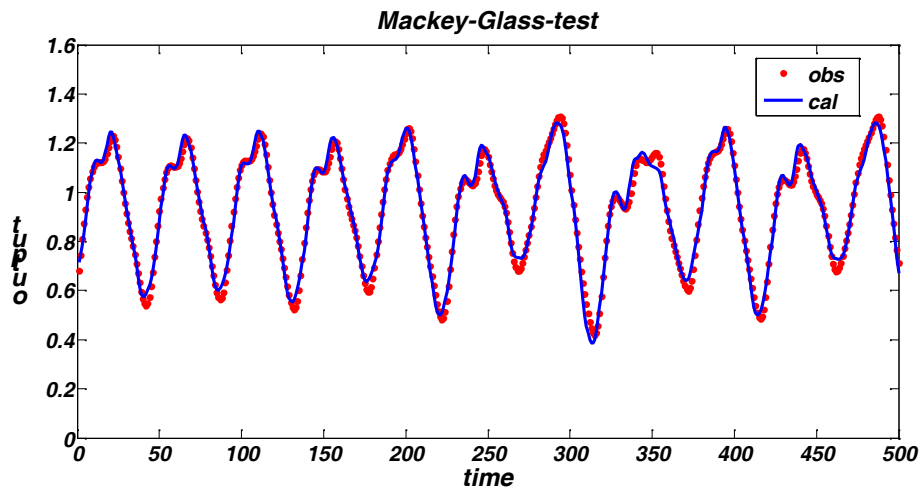
$$CE = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q})^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}$$

$$RB = \frac{1}{n} \sum_{i=1}^n \left(\frac{Q_i - \hat{Q}}{Q_i} \right)$$

به صورت $D=4$ و $p=4=6$ انتخاب شده‌اند. گام زمانی انتخاب شده برای مسئله فوق برابر با 0.1 و شرایط اولیه در نظر گرفته شده به صورت $x(0)=1/2$ و $x(17)=1$ می‌باشد. به این ترتیب با استفاده از حل عددی مقادیر $x(t)$ برای t بین 0 تا 2000 به دست می‌آید. از حل سری زمانی Mackey-Glass، 1000 جفت داده ورودی- خروجی با شکل $x(t-18)$ ، $x(t-12)$ ، $x(t-6)$ ، $\{x(t), x(t+6)\}$ به دست می‌آید که t بین 118 تا 1117 قرار می‌گیرد. از 500 جفت داده اولیه به عنوان داده‌های آموزش و از 500 جفت داده باقی مانده برای اعتبارسنجی استفاده شده است. برای بررسی نتایج به دست آمده از مدل‌سازی از چندین معیار آماری شامل مجموع مربعات خطای نسبی (MSRE)، مجموع مطلق میانگین خطای نسبی (MPRE)، ضریب راندامان (CE) و

مقادیر سری زمانی Mackey-Glass را به خوبی پیش‌بینی کرده است. نتایج شاخص‌های آماری MSRE، MPRE، CE و RB در پیش‌بینی سری زمانی Mackey-Glass از سوی مدل توسعه داده شده GMDH در مرحله آزمون به ترتیب برابر است با ۰/۰۰۱۳، ۰/۵۷۷، ۰/۹۴۸ و ۰/۰۱۱.

که n تعداد داده‌ها، Q_i داده‌های مشاهده‌ای، \bar{Q} داده‌های مدل و \bar{Q} میانگین داده‌های مشاهده‌ای است. شکل ۴ نمودار پیش‌بینی سری زمانی Mackey-Glass از سوی مدل توسعه داده شده GMDH را در مرحله آزمون نشان می‌دهد. همان‌طور که از نمودار ارائه شده مشخص است تطابق خوبی بین مقادیر مشاهده‌ای و محاسباتی وجود دارد و مدل توسعه داده شده در این پژوهش



شکل ۴- پیش‌بینی سری زمانی Mackey-Glass از سوی مدل توسعه داده شده GMDH در مرحله آزمون.

که در بعضی مدل‌ها مقدار R^2 در تابع محرک (Func2) نسبت به تابع اول اندکی کم‌تر است. هم‌چنین اشکال ۵ و ۶ نمودارهای مربوط به مقایسه نتایج محاسباتی و مشاهده‌ای حاصل از اجرای مدل در مرحله آزمون برای چند نمونه از ساختارهای اجرا شده در ایستگاه‌های مورد مطالعه که بهترین نتایج را داشته‌اند نشان می‌دهند. چنانچه از نمودارهای مرحله آزمون مدل مشخص است تطابق خوبی بین مقادیر مشاهده‌ای و محاسباتی غلظت رسوب مشاهده می‌شود. هم‌چنین، الگوریتم GMDH مقادیر پیک دبی رسوب را در هر دو ایستگاه با دقت خوبی تخمین زده است. اشکال ۷ و ۸ نیز نمودارهای پراکندگی مقادیر داده‌های دبی رسوب مشاهده‌ای و محاسباتی را در مرحله آزمون نشان می‌دهند. در این نمودارها نیز براساس معادله خط برازش داده شده و مقدار R^2 را می‌توان مشاهده کرد که مقادیر مشاهده‌ای و محاسباتی دبی رسوب بسیار به هم نزدیک هستند.

نتایج و بحث

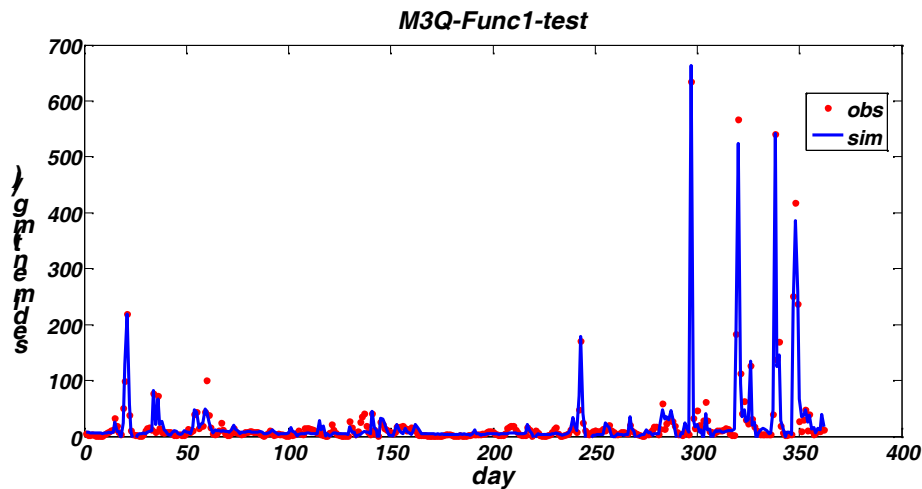
در پژوهش حاضر، با استفاده از الگوریتم GMDH مدل‌هایی برای شبیه‌سازی نرخ انتقال رسوب در ایستگاه‌های مورد نظر توسعه داده شد. ورودی‌های هر مدل شامل ترکیبات مختلفی از دبی جریان با تاخیرهای زمانی مختلف شامل گام زمانی کنونی (Q_t) تا گام زمانی (Q_{t-4}) و غلظت رسوب با تاخیرهای زمانی مختلف شامل (S_{t-1}) تا گام زمانی (S_{t-4}) می‌باشند. خروجی کلیه مدل‌ها غلظت رسوب در گام زمانی کنونی (S_t) در نظر گرفته شده است. در اجرای مدل‌ها از فرمول‌های (۲) و (۳) به ترتیب به صورت توابع محرک (Func1) و (Func2) استفاده شده است. هم‌چنین در مرحله آزمون مدل‌ها از پارامترهای آماری MSE، RB و R^2 برای ارزیابی نتایج استفاده شده است. ساختار مورد استفاده و نتایج حاصل از الگوریتم GMDH برای مدل‌های توسعه داده شده در دو ایستگاه مورد مطالعه در جداول ۳ و ۴ نشان داده شده است. نتایج اجرای مدل‌ها با هر دو تابع محرک در حد قابل قبول و بسیار خوب قرار دارند با ذکر این نکته

جدول ۳- ساختار مدل‌های مورد استفاده و نتایج پارامترهای آماری برای ایستگاه Quebrada Blanca در مرحله آزمون


مدل	ساختار ورودی	Func1			Func2		
		R ²	RB	MSE _{test} (mg ² l ⁻²)	R ²	RB	MSE _{test} (mg ² l ⁻²)
M1Q	$SSC_t = f(Q_t, Q_{t-1}, Q_{t-2}, S_{t-1})$	۰/۹۷۴	-۰/۰۰۱۰	۱۰۲/۲	۰/۹۶۰	-۰/۰۰۱۲	۱۵۸/۶
M2Q	$SSC_t = f(Q_t, Q_{t-1}, S_{t-1}, S_{t-2})$	۰/۹۶۷	-۰/۰۰۱۱	۱۲۸/۲	۰/۹۶۱	-۰/۰۰۱۲	۱۵۵/۴
M3Q	$SSC_t = f(Q_t \text{ to } Q_{t-3}, S_{t-1})$	۰/۹۷۶	-۰/۰۰۰۹	۹۴/۵	۰/۹۴۲	-۰/۰۰۱۱	۲۲۸/۹
M4Q	$SSC_t = f(Q_t, Q_{t-1}, S_{t-1}, S_{t-2}, S_{t-3})$	۰/۹۶۷	-۰/۰۰۱۰	۱۲۸/۳	۰/۹۷۰	-۰/۰۰۱۱	۱۱۶/۷
M5Q	$SSC_t = f(Q_t \text{ to } Q_{t-2}, S_{t-1} \text{ to } S_{t-3})$	۰/۹۶۱	-۰/۰۰۱۰	۱۵۲/۹	۰/۹۶۷	-۰/۰۰۱۰	۱۲۸/۵
M6Q	$SSC_t = f(Q_t \text{ to } Q_{t-3}, S_{t-1} \text{ to } S_{t-3})$	۰/۹۷۶	-۰/۰۰۱۰	۹۲/۶	۰/۹۷۳	-۰/۰۰۱۱	۱۰۴/۸

جدول ۴- ساختار مدل‌های مورد استفاده و نتایج آزمون‌های آماری برای ایستگاه Rio Valencia


مدل	ساختار ورودی	Func1			Func2		
		R ²	RB	MSE _{test} (mg ² l ⁻²)	R ²	RB	MSE _{test} (mg ² l ⁻²)
M1R	$SSC_t = f(Q_t, S_{t-1}, S_{t-2}, S_{t-3})$	۰/۹۱۸	-۰/۰۰۳۴	۱۷۸۳/۸	۰/۹۱۸	-۰/۰۰۳۴	۱۷۷۵/۴
M2R	$SSC_t = f(Q_t, S_{t-1} \text{ to } S_{t-4})$	۰/۹۲۵	-۰/۰۰۳۲	۱۶۲۲/۴	۰/۹۲۱	-۰/۰۰۳۳	۱۷۰۶/۱
M3R	$SSC_t = f(Q_t \text{ to } Q_{t-5})$	۰/۹۱۸	-۰/۰۰۳۳	۱۷۷۱/۵	۰/۹۰۶	-۰/۰۰۳۳	۲۰۳۲/۴
M4R	$SSC_t = f(Q_t \text{ to } Q_{t-4}, S_{t-1})$	۰/۹۲۱	-۰/۰۰۳۳	۱۷۱۶/۵	۰/۹۰۴	-۰/۰۰۲۹	۲۰۸۴
M5R	$SSC_t = f(Q_t \text{ to } Q_{t-5}, S_{t-1})$	۰/۹۳۱	-۰/۰۰۲۹	۱۴۸۷/۶	۰/۹۳۰	-۰/۰۰۲۸	۱۵۲۹
M6R	$SSC_t = f(Q_t \text{ to } Q_{t-4}, S_{t-1}, S_{t-2})$	۰/۹۱۹	-۰/۰۰۳۳	۱۷۷۰	۰/۹۱۸	-۰/۰۰۳۳	۱۷۷۱



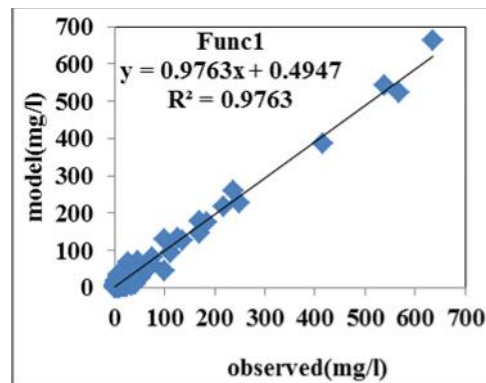
شکل ۵- نمودار مقایسه نتایج مشاهداتی و محاسباتی الگوریتم GMDH برای مدل M3Q در مرحله آزمون، ایستگاه Quebrada Blanca.



شکل ۶- نمودار مقایسه نتایج مشاهداتی و محاسباتی الگوریتم GMDH برای مدل M4R در مرحله آزمون، ایستگاه Rio Valenciano.



شکل ۸- نمودار پراکندگی داده‌ها در مرحله آزمون برای مدل M4R، ایستگاه Rio Valenciano.



شکل ۷- نمودار پراکندگی داده‌ها در مرحله آزمون برای مدل M3Q، ایستگاه Quebrada Blanca.

از آن‌جا که نقاط پیک در تعیین مقدار ظرفیت ذخیره و یا آگذری سازه‌های مختلف اهمیت دارند این مقادیر از جمله مهم‌ترین اطلاعات مورد نیاز در طراحی همه سازه‌های آبی بشمار می‌روند. لذا برای ارزیابی بیش‌تر صحت عملکرد مدل توسعه داده‌شده، میزان مقادیر مشاهداتی و محاسباتی نقاط پیک بار معلق هر دو ایستگاه نیز مورد بررسی قرار گرفته است. میزان خطای نسبی برای همه مقادیر پیک مورد نظر در همه مدل‌ها محاسبه شده و قدرمطلق خطاها با هم جمع شده است و بر اساس مجموع خطاها مدلی که کمترین میزان خطای نسبی را داشته است، بهترین مدل انتخاب شده است.

مقادیر تخمین زده شده از سوی مدل‌ها و هم‌چنین مقادیر خطای نسبی محاسبه شده در هر ایستگاه در جدول‌های ۵ و ۶ نشان داده شده است. مدل M3Q در ایستگاه Quebrada Blanca با ۵ ورودی شامل Q_{t-3} , Q_{t-2} , Q_{t-1} , Q_t ، S_{t-1} ، S_t و خروجی S_t و خروجی S_t و Q_{t-1} ، Q_t ، S_{t-1} ، S_t و Q_{t-4} ، Q_{t-3} ، Q_{t-2} ، Q_{t-1} ، Q_t ، S_{t-1} ، S_t بهترین پیش‌بینی و کم‌ترین خطای نسبی را داشته‌اند. در ایستگاه Quebrada Blanca مدل‌های M1Q و M4Q مقدار دبی پیک (mg/l) را به میزان ۱٪ و مدل‌های M5Q و M6Q به ترتیب به میزان ۸٪ و ۲۶٪ بیش از مقدار واقعی و مدل M2Q به میزان ۲٪ کمتر از مقدار واقعی برآورد کرده‌اند، در حالی که مدل M3Q بدون خطای نسبی این مقدار را دقیقاً (mg/l) ۲۱۹ برآورد کرده است. در ایستگاه Rio Valenciano نیز مدل M5R مقدار دبی پیک (mg/l) ۱۰۲۰ را ۲٪ بیش از مقدار واقعی و مدل‌های M1R، M2R، M3R و M6R به ترتیب به میزان ۷٪، ۱۳/۵٪، ۱٪ و ۴٪ کمتر از مقدار واقعی برآورد کرده‌اند. مدل M4R با ۱٪ خطای نسبی این مقدار را (mg/l) ۱۰۳۱ برآورد کرده است.

مقادیر تخمین زده شده از سوی مدل‌ها و هم‌چنین مقادیر خطای نسبی محاسبه شده در هر ایستگاه در جدول‌های ۵ و ۶ نشان داده شده است. مدل M3Q در ایستگاه Quebrada Blanca با ۵ ورودی شامل Q_{t-3} , Q_{t-2} , Q_{t-1} , Q_t ، S_{t-1} ، S_t و خروجی S_t و خروجی S_t و Q_{t-1} ، Q_t ، S_{t-1} ، S_t و Q_{t-4} ، Q_{t-3} ، Q_{t-2} ، Q_{t-1} ، Q_t ، S_{t-1} ، S_t بهترین پیش‌بینی و کم‌ترین خطای نسبی را داشته‌اند. در ایستگاه Rio Valenciano نیز مدل M5R مقدار دبی پیک (mg/l) ۱۰۲۰ را ۲٪ بیش از مقدار واقعی و مدل‌های M1R، M2R، M3R و M6R به ترتیب به میزان ۷٪، ۱۳/۵٪، ۱٪ و ۴٪ کمتر از مقدار واقعی برآورد کرده‌اند. مدل M4R با ۱٪ خطای نسبی این مقدار را (mg/l) ۱۰۳۱ برآورد کرده است.

جدول ۵- مقایسه نتایج پیش بینی نقاط پیک از سوی مدل‌های مختلف در ایستگاه Quebrada Blanca در مرحله آزمون

خطای نسبی (%)												مقادیر مشاهداتی پیک (≥ 180 mg/l)
M6Q	M5Q	M4Q	M3Q	M2Q	M1Q	M6Q	M5Q	M4Q	M3Q	M2Q	M1Q	
-۳	-۵	-۲	-۴	-۴	-۴	۱۷۸	۱۷۳	۱۸۰	۱۷۶	۱۷۶	۱۷۶	۱۸۳
۲۶	۸	۱	۰	-۲	۱	۲۷۶	۲۳۶	۲۲۱	۲۱۹	۲۱۴	۲۲۲	۲۱۹
-۳	۵	۶	۹	۱۵	۱۶	۲۲۹	۲۴۸	۲۵۲	۲۵۹	۲۷۴	۲۷۶	۲۳۷
-۱۴	-۱۱	-۶	-۹	-۴	-۴	۲۱۴	۲۲۲	۲۳۶	۲۲۸	۲۳۹	۲۴۰	۲۵۰
۰	۲۰	۷	-۷	۱۵	۷	۴۱۶	۵۰۲	۴۴۸	۳۸۶	۴۸۰	۴۴۸	۴۱۷
۱	۲	-۲	۰	-۱	۰	۵۴۷	۵۵۰	۵۲۷	۵۴۲	۵۳۲	۵۴۰	۵۴۰
-۵	-۲۴	-۲۱	-۷	-۱۶	-۱۰	۵۴۰	۴۳۳	۴۴۹	۵۲۳	۴۷۳	۵۱۱	۵۶۷
۱	۰	۷	۵	۲	۱	۶۴۳	۶۳۴	۶۷۹	۶۶۴	۶۵۰	۶۴۱	۶۳۵
۵۳	۷۵	۵۲	۴۱	۵۹	۴۳	مجموع قدرمطلق						
						۰/۴۶	۰/۵۹	۰/۵۴	۰/۴۶	۰/۵۴	۰/۴۸	SI=RMSE/Sm can

جدول ۶- مقایسه نتایج پیش بینی نقاط پیک از سوی مدل‌های مختلف در ایستگاه Rio Valenciano در مرحله آزمون

خطای نسبی (%)												مقادیر مشاهداتی پیک (≥ 600 mg/l)
M6R	M5R	M4R	M3R	M2R	M1R	M6R	M5R	M4R	M3R	M2R	M1R	
۱۳	۲۱	۱۲	۱۲	۱۱	۱۱	۷۸۰	۸۳۸	۷۷۵	۷۷۶	۷۶۷	۷۶۵	۶۹۰
۴	-۴	۴	۵	۰	۱	۷۴۳	۶۸۷	۷۴۰	۷۴۵	۷۱۴	۷۲۳	۷۱۲
-۸	۳	-۳	-۶	-۲	۲	۶۹۲	۷۷۶	۷۲۹	۷۰۸	۷۴۰	۷۷۱	۷۵۵
-۱۱	-۹	-۳	-۲	۹	۱۵	۷۳۷	۷۵۵	۸۰۹	۸۱۰	۹۰۷	۹۵۷	۸۳۱
-۲۷	-۲۸	-۲۷	-۲۹	-۱۸	-۳۵	۶۸۶	۶۷۶	۶۸۰	۶۶۶	۷۶۵	۶۱۰	۹۳۶
-۴۶	-۴۳	-۴۶	-۴۷	-۴۵	-۴۶	۵۲۸	۵۵۱	۵۱۹	۵۱۱	۵۳۱	۵۱۹	۹۷۱
-۴	۲	۱	-۱	-۱۳	-۷	۹۸۰	۱۰۴۳	۱۰۳۱	۱۰۱۱	۸۸۲	۹۴۸	۱۰۲۰
۱	۱	-۵	-۳	۵	۱	۱۱۰۰	۱۰۹۷	۱۰۳۷	۱۰۵۴	۱۱۴۹	۱۱۰۶	۱۰۹۰
۱۱۴	۱۱۱	۱۰۱	۱۰۵	۱۰۳	۱۱۸	مجموع قدرمطلق						
						۰/۵۹	۰/۵۴	۰/۵۸	۰/۵۹	۰/۵۶	۰/۵۹	SI=RMSE/Sm can

ایستگاه را با سایر مدل‌های شبکه عصبی به همراه پارامترهای آماری محاسبه شده برای هر الگوریتم نشان می‌دهد. مقایسه پارامترهای آماری محاسبه شده نشان از عملکرد بهتر الگوریتم GMDH دارد. مقادیر پیش‌بینی شده از طریق این الگوریتم نسبت به سایر مدل‌های شبکه عصبی به مقدار واقعی نزدیک‌تر است.

هم‌چنین مقادیر پیش‌بینی شده بار معلق رسوب از سوی الگوریتم GMDH با سایر مدل‌های شبکه عصبی شامل LGP^۱، NDE^۲، ANN، NF^۳، ANN-ABC(log)، ANN-ABC^۴ که با داده‌های دو ایستگاه حاضر اجرا شده بودند مقایسه شد. جدول‌های ۷ و ۸ نتایج حاصل از مقایسه بهترین مدل‌های الگوریتم GMDH در هر

1- Linear Genetic Programming
3- Neuro-Fuzzy

2- Neural Differential Evolution
4-Artificial Neural Network- Bee Colony Algorithm

جدول ۷- مقایسه بهترین مدل الگوریتم GMDH در ایستگاه Quebrada Blanca با نتایج سایر الگوریتم‌های شبکه عصبی

خطای نسبی (%)														مقادیر مشاهداتی پیک ≥ ۱۸۰ mg/l
GMDH M3Q	LGP	NDE	ANN	NF	ANN- ABC (log)	ANN- ABC	GMDH M3Q	LGP	NDE	ANN	NF	ANN- ABC (log)	ANN- ABC	
-۴	-۱۰	-۳	۱۶	۷	۱	-۱۲	۱۷۶	۱۶۴	۱۸۰	۲۱۲	۱۹۲	۱۸۵	۱۶۲	۱۸۳
۰	۱۷	۱۹	۳۰	۱۸	۴	۸	۲۱۹	۲۵۶	۲۶۱	۲۸۴	۲۵۹	۲۲۷	۲۳۷	۲۱۹
۹	۲۳	۲۳	۳۳	۲۰	۳	۱۲	۲۵۹	۲۹۱	۲۹۱	۳۱۵	۲۸۵	۲۳۰	۲۶۶	۲۳۷
-۹	-۱۰	-۶	۳	-۵	-۴	-۱۵	۲۲۸	۲۲۵	۲۳۴	۲۵۹	۲۳۷	۲۵۹	۲۱۲	۲۵۰
-۷	۲۲	۲۴	۱۵	۲۴	۱۵	۲۳	۳۸۶	۵۰۹	۵۱۵	۴۸۰	۵۱۶	۴۸۲	۵۱۴	۴۱۷
۰	۲	۹	۰	۲۳	۱۲	۱۷	۵۴۲	۵۵۱	۵۹۰	۵۳۸	۶۶۲	۶۰۳	۶۲۹	۵۴۰
-۷	-۱۶	۱۶	-۲۱	-۱۹	-۲۲	-۱۹	۵۲۳	۴۷۸	۴۷۴	۴۴۸	۴۶۲	۴۴۴	۴۶۲	۵۶۷
۵	-۱۸	-۱۷	-۲۴	-۱۶	-۷	-۱۶	۶۶۴	۵۱۸	۵۲۸	۴۸۴	۵۳۶	۵۸۸	۵۳۲	۶۳۵
۴۱	۱۱۸	۱۱۶	۱۴۲	۱۳۰	۶۸	۱۲۲	مجموع قدرمطلق							
مقایسه عملکرد الگوریتم‌های مختلف														بهترین شاخص‌ها
														MSE
														R ²
														SI

جدول ۸- مقایسه بهترین مدل الگوریتم GMDH در ایستگاه Rio Valenciano با نتایج سایر الگوریتم‌های شبکه عصبی

خطای نسبی (%)														مقادیر مشاهداتی پیک ≥ ۶۰۰ mg (l)
GMDH M4R	LGP	NDE	ANN	NF	ANN- ABC (log)	ANN- ABC	GMDH M4R	LGP ^۱	NDE ^۳	ANN ^۲	NF ^۲	ANN- ABC ^۱ (log)	ANN- ABC ^۱	
۱۲	۱۳	-۱۴	-۸	-۳	۶	۱۰	۷۷۵	۷۸۱	۵۹۵	۶۳۷	۶۷۱	۷۲۹	۷۶۲	۶۹۰
۴	۲	-۱۷	۰	-۱۲	۵	-۶	۷۴۰	۷۲۸	۵۹۳	۷۱۴	۶۲۹	۷۴۵	۶۶۸	۷۱۲
-۳	۱	-۲۱	-۳	-۱۰	۲۲	-۷	۷۳۹	۷۶۶	۵۹۵	۷۳۱	۶۸۰	۹۲۴	۷۰۳	۷۵۵
-۳	۲۵	۲۲	۱۷	۱۷	۲۳	۱۷	۸۰۹	۱۰۳۷	۱۰۱۶	۹۷۰	۹۷۶	۱۰۲۵	۹۶۸	۸۳۱
-۲۷	-۳۱	-۳۷	-۳۰	-۳۱	-۱۳	-۳۲	۶۸۰	۶۴۶	۵۹۴	۶۵۶	۶۴۳	۸۱۵	۶۴۰	۹۳۶
-۴۶	-۴۹	-۴۵	-۵۲	-۵۵	-۱۲	-۵۵	۵۱۹	۵۰۰	۵۳۶	۴۶۴	۴۳۶	۸۵۱	۴۴۲	۹۷۱
۱	-۳	-۰/۴	-۹	-۱۳	-۵	-۸	۱۰۳۱	۹۸۷	۱۰۱۶	۹۲۵	۸۹۲	۹۷۰	۹۴۲	۱۰۲۰
-۵	-۲	-۷	-۶	-۳	-۳	-۵	۱۰۳۷	۱۰۶۷	۱۰۱۶	۱۰۱۹	۱۰۶۲	۱۰۵۴	۱۰۲۱	۱۰۹۰
۱۰۱	۱۲۶	۱۶۳	۱۲۵	۱۴۴	۸۹	۱۴۰	مجموع قدرمطلق							
مقایسه عملکرد الگوریتم‌های مختلف														بهترین شاخص‌ها
														MSE
														R ²
														SI

1- Kisi et al., (2012)
2- Kisi (2005)

3- Kisi (2010)
4- Kisi and Guven (2010)

Valencia no استفاده شده با دو تابع هدف و مقادیر پارامترهای آماری نشان داد که الگوریتم GMDH مانند سایر روش‌های شبکه عصبی از قابلیت بالایی برای پیش‌بینی نرخ انتقال رسوب در رودخانه‌ها برخوردار است. همچنین، مقایسه نتایج این مدل با نتایج سایر مدل‌های شبکه عصبی نشان داد که الگوریتم GMDH نسبت به سایر مدل‌های شبکه عصبی از دقت بالاتری برخوردار است. در مطالعات آتی می‌توان پارامترهای ورودی به مدل را تغییر داد و اثر سایر پارامترهای موثر بر انتقال رسوب را بررسی کرد. می‌توان از سایر روش‌های آموزش پارامترها مانند بهینه‌سازی بر اساس مشتق‌گیری یا الگوریتم‌های تکامل‌گرا مانند الگوریتم ژنتیک برای آموزش پارامترهای مورد نظر در GMDH استفاده کرد.

در پژوهش حاضر، با استفاده از روش کنترل گروهی داده‌ها (GMDH) مدلی برای شبیه‌سازی نرخ انتقال رسوب در رودخانه‌ها توسعه داده شد. در این روش احتیاجی به شناخت روابط حاکم بر سیستم و خطی‌سازی روابط وجود ندارد. فقط لازم است که یک سری از داده‌های ورودی و خروجی از سیستم در دسترس باشند. زمان انجام محاسبات در این روش کم است ضمن آن که با افزایش تعداد لایه‌های توسعه داده‌شده دقت پاسخ‌های تولید شده اضافه می‌گردد اما روابط تولید شده بین متغیرهای ورودی و خروجی بسیار پیچیده می‌شود که از این مورد می‌توان به یکی از نقاط ضعف روش مورد استفاده یاد کرد. بررسی نتایج حاصل از آموزش و آزمون مدل‌های توسعه داده شده با داده‌های دو ایستگاه Quebrada Blanca و Rio

منابع

1. Abrishami, H., Gh. Abdoli, H. Ahrari and S. Dolatabadi. 2012. Application of GMDH Algorithm to Extract Rules from the Behavior of Oil Price. The Quarterly of Studying Energies Economy, 32: 147-168 (In Persian).
2. Alp, M. and H. Kerem Cigizoglu. 2005. Suspended Sediment Load Simulation by Two Artificial Neural Network Methods Using Hydrometeorological Data. Environmental Modelling & Software, 22: 2-13.
3. Aytok, A. and O. Kisi. 2007. A Genetic Programming Approach to Suspended Sediment Modeling. Journal of Hydrology, 351: 288-298.
4. Azamathulla, H.M.D., Ch.K. Chang, A.A.B. Ghani, J. Ariffin, N.A. Zakaria and Z. Abu Hasan. 2008. An ANFIS-Based Approach for Predicting the Bed Load for Moderately Sized Rivers. Journal of Hydro-Environment Research, 3: 35-44 (In Persian).
5. Azamathulla, H., Y. Cuan, A.A.B. Ghani and Ch.K. Chang. 2012. Suspended Sediment Load Prediction of River Systems: GEP Approach. Arabian Journal of Geosciences, 3: 3469-3480.
6. Farlow, S.J. 1981. The GMDH Algorithm of Ivakhnenko. The American Statistician. 35: 210-215.
7. Firat, M. and M. Gungor. 2009. Monthly Total Sediment Forecasting Using Adaptive Neuro Fuzzy Inference System. Stoch Environ Res Risk Assess, 24: 259-270.
8. Ghani, A.A.B., H.M.D. Azamathulla, Ch.K. Chang, N.A. Zakaria and Z. Abu Hasan. 2010. Prediction of Total Bed Material Load for Rivers in Malaysia: A Case Study of Langat, Muda and Kurau Rivers. Environ Fluid Mech, 11: 307-318.
9. Hesavi, M. and M. Shafae-bajestan. 2010. Estimate of Sediment Bed Load in Karoon River Ahwaz Station. 8th International River Engineering Conference, Ahwaz, Iran. 1-9
10. Hwang, H.S. 2006. Fuzzy GMDH-Type Neural Network Model and Its Application to Forecasting of Mobile Communication. Computers and Industrial Engineering, 50: 450-457.
11. Ivakhnenko, A.G. 1968. The Group Method of Data Handling-a Rival of the Method of Stochastic Approximation, Soviet Automatic Control c/c of Avtomatika, 1: 43-55.
12. Ivakhnenko, A.G. 1976. The Group Method of Data Handling in Prediction Problems, Soviet Automatic Control of Avtomatika, 9: 21-30.
13. Kisi, O. 2004. Multi-Layer Perceptrons with Levenberg-Marquardt Training Algorithm for Suspended Sediment Concentration Prediction and Estimation, Hydrological Sciences Journal, 49: 1025-1040.
14. Kisi, O. 2005. Suspended Sediment Estimation Using Neuro-Fuzzy and Neural Network Approaches, Hydrological. Sciences Journal, 50: 683-696.
15. Kisi, O. 2010. River Suspended Sediment Concentration Modeling Using a Neural Differential Evolution Approach." Journal of Hydrology, 389: 227-235.
16. Kisi, O. and A. Guven. 2010. A Machine Code-Based Genetic Programming for Suspended Sediment Concentration Estimation. Advances in Engineering Software, 41: 939-945.
17. Kisi, O., C. Ozkan and A. Bahriye. 2012. Modeling Discharge-Sediment Relationship Using Neural Networks with Artificial Bee Colony Algorithm, Journal of Hydrology, 428-429: 94-103.
18. Melesse, A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2010. Suspended Sediment Load Prediction of River Systems: An Artificial Neural Network Approach. Agricultural Water Management, 98: 855-866.
19. Muller, J.A. and A.G. Ivakhnenko. 1996. Self-Organizing Modeling in Analysis and Prediction of Stock Market, in Proceedings of the Second International Conference on Application of Fuzzy Systems and Soft Computing-ICAIFS, 96: 491-500.
20. Nariman-Zadeh, N., A. Darvizhe and H. Gharabaghi. 2002. Modeling of Explosive Cutting Process of Plates Using GMDH Neural Networks and Singular Value Decomposition. Journal of Materials Processing Technology, 28: 80-87
21. Negm, A.M., M.M. Elfiky, T.M. Owais and M.H. Nassar. 2003. Prediction of Suspended Sediment Concentration in River Flow Using Artificial Neural Networks, 6th Int. River Engineering Conference, Shahid-Chamran University of Ahvaz, Iran. 1-12.
22. Nikolaev, Y. and I. Hitoshi. 2003. Polynomial Harmonic GMDH Learning Networks for Time Series Modeling, Neural Networks, 16: 1527-1540.
23. Nishikawa, T. and Sh. Shimizu. 1980. Identification and Forecasting in Management Systems Using the GMDH Method. Appl. Math. Modelling.
24. Oehler, F., G. Coco, M. Green and K. Bryan. 2012. A data-Driven Approach to Predict Suspended-Sediment Reference Concentration Under non-Breaking Waves. Continental Shelf Research 46: 96-106.
25. Pournemat, A., K. Qaderi and Sh. Karimi. 2011. Rainfall-Runoff Simulation using Inductive Approach (GMDH)-Case Study. 5th National Conference on Watershed Management and Soil and Water Resources Management, Kerman, 659-666 (In Persian).
26. Qaderi, K., D.R. Arab, M. Teshnehlab and A. Ghazagh. 2010. Intelligent Operation Modeling of Reservoirs Using Group Method of Data Handling (GMDH) Iran-Water Resources Research, 6: 55-67 (In Persian).
27. Zakaria, N., H.M.D. Azamathulla, Ch.K. Chang and A.A.B. Ghani. 2010. Gene expression programming for total bed material load estimation-a case study. Science of the Total Environment, 408: 5078-5085 (In Persian).

Estimation of Suspended Sediment Load Concentration in River System using Group Method of Data Handling (GMDH)

Zahra Eivani¹, Mohammad Mehdi Ahmadi² and Kouros Qaderi²

1- M.Sc. Student, University of Shahid Bahonar, Kerman
(Corresponding author: eivani4181@yahoo.com)

2- Assistant Professor, University of Shahid Bahonar, Kerman
Received: September 12, 2013 Accepted: July 22, 2014

Abstract

Accurate estimation of sediment load in rivers and reservoirs is an important issue in hydraulic engineering as it affects the design, management and operation of water resources projects. Extract of mathematical relationship in sediment transportation has special complexity. Data-driven methods can be used for Modeling of these phenomena. One of these heuristic self organization methods is Group Method of Data Handling (GMDH) that is uses as a method to detect non-linear relationships between input and output variables. In this research, based on GMDH, a model has been developed for the prediction of suspended sediment concentration in river systems. The daily stream flow and suspended sediment concentration data from two stations, Rio Valencia no Station and Quebrada Blanca Station, were used for evaluating the ability of model. The accuracy of model was evaluated using mean square error (MSE), Relative Bias (RB) and determination coefficient (R^2) statistics. Comparison between the results of statistical parameters of model with other algorithms like Neural Networks, Neuro-Fuzzy and Genetic Programming indicated that GMDH has high capability for predicting and simulating of suspended sediment concentration than other models.

Keywords: Group Method of Data Handling (GMDH), Sediment Transportation Rate, Simulation