



مدلسازی فرآیند بارش - رواناب با استفاده از روش کنترل گروهی داده‌ها (GMDH) و شبکه‌های عصبی مصنوعی (ANN) در حوزه آبخیز پلرود

عادل پورنعمت رودسری^۱، کورش قادری^۲ و شهرام کریمی گوغری^۳

۱ و ۳- دانشجوی کارشناسی ارشد و استادیار، دانشگاه شهید باهنر کرمان

۲- استادیار، دانشگاه شهید باهنر کرمان، (نویسنده مسوول: kouroshqaderi@uk.ac.ir)

تاریخ دریافت: ۹۱/۷/۹ تاریخ پذیرش: ۹۲/۳/۶

چکیده

مدلسازی بارش- رواناب یک فرآیند ضروری و پیچیده می‌باشد که در بهره‌برداری مناسب از مخازن و مدیریت و برنامه‌ریزی صحیح منابع آب نقش عمده‌ای دارد. مدلسازی این فرآیند با استفاده از روش‌های مختلفی امکانپذیر است. از نظر تئوری، در مدلسازی یک سیستم می‌بایست روابط صریح بین متغیرهای ورودی و خروجی معلوم باشند. در حالیکه به علت معلوم نبودن روابط صریح بین متغیرها و عدم قطعیت‌های ذاتی آنها، استخراج چنین مدلی بسیار مشکل می‌باشد. بنابراین استفاده از روش‌های داده‌محور که محاسبات را در شرایط غیردقیق انجام می‌دهند و کاربردهای فراوانی در مسائل شناسایی کنترلی داشته‌اند، اجتناب‌ناپذیر است. روش کنترل گروهی داده‌ها (GMDH) یکی از انواع این روش‌ها می‌باشد که به تدریج یک نداشت بین متغیرهای ورودی و خروجی تولید می‌کند. در این تحقیق برای شبیه‌سازی فرآیند بارش- رواناب حوزه آبریز پلرود، یک مدل بر اساس رویکرد GMDH توسعه داده شده است. ارزیابی نتایج با استفاده از معیارهای آماری انجام شده و همچنین با نتایج شبکه‌های عصبی (ANN) نیز مقایسه شده است. نتایج حاکی از توانایی بالای هر دو روش در پیش‌بینی و شناسایی روابط پیچیده بین متغیرها در پیش‌بینی رواناب روزانه ناشی از بارندگی می‌باشند. مقادیر نتایج معیارهای آماری بیانگر عملکرد بهتر رویکرد استقرائی GHMD نسبت به شبکه‌های عصبی در مدلسازی بارش- رواناب در این حوزه می‌باشد.

واژه‌های کلیدی: مدلسازی بارش- رواناب، روش‌های داده‌محور، روش کنترل گروهی داده‌ها، شبکه‌های عصبی، حوزه آبریز پلرود

مقدمه

کمک شایانی به بخش‌های مختلف مهندسی آب مانند طراحی سیل‌گیرها برای محافظت مناطق شهری و کشاورزی، بهره‌برداری صحیح از منابع برای بخش‌های مختلف کشاورزی، شرب، برقایی و زیست‌محیطی نماید (۱۶).

مدلسازی بارش- رواناب یکی از مهم‌ترین اجزاء فرآیندهای هیدرولوژی در مدیریت منابع آب می‌باشد. تخمین دقیق کوتاه مدت و بلند مدت رواناب و جریان‌های رودخانه‌ای می‌تواند

و کاربرد روش‌های داده‌محور در مدل‌سازی فرآیند بارش-رواناب در چند دهه اخیر گسترش فزاینده‌ای داشته است. اگرچه مدل‌سازی با روش‌های داده‌محور ممکن است توانائی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشند اما بطور صحیح و دقیقی می‌توانند رواناب خروجی حوضه را تخمین بزنند (۱۵). گسترش و توسعه روزافزون علوم کامپیوتری (سخت‌افزاری و نرم‌افزاری) و در دسترس بودن داده‌های بیشتر و دقیق‌تر باعث ارتقاء کمی و کیفی رویکردهای مدل‌سازی داده‌محور برای شناسایی الگوهای موجود در سری‌های زمانی فرآیندهای هیدرولوژیکی شده است.

از اجزای اصلی روش‌های داده‌محور که در چند دهه اخیر کاربردهای زیادی در مدل‌سازی سری‌های زمانی غیرخطی و داده‌های مغشوش داشته است می‌توان به شبکه‌های عصبی اشاره کرد. توانایی و قابلیت شبکه‌های عصبی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و مغشوش توسط محققین زیادی به اثبات رسیده است. از جمله این محققین می‌توان به سو و همکاران (۲)، مینز و هال (۸)، آبراهارت و سی (۱)، هو و همکاران (۳)، کیسی (۷) و وانگ و همکاران (۱۷) و ... اشاره نمود.

شبکه‌های عصبی پیشرو (FFNN) پرکاربردترین نوع شبکه‌های عصبی در مدل‌سازی بارش-رواناب و پیش‌بینی جریان‌های رودخانه‌ای بوده‌اند (۴).

یکی دیگر از روش‌های داده‌محور، مدل فراذهنی GMDH می‌باشد که توسط

بنابراین استفاده و توسعه روش‌های دقیق و قابل اعتماد برای مدل‌سازی فرآیند بارش-رواناب یک عامل بسیار مهم و تاثیرگذار در طراحی و مدیریت منابع آب می‌باشد.

به طور کلی دو روش عمده برای مدل‌سازی فرآیند بارش رواناب وجود دارد. روش اول مدل‌سازی مبتنی بر دانش و روش دوم مبتنی بر داده می‌باشد. روش‌های دانش محور به عنوان رویکردهای مدل‌سازی مبتنی بر خصوصیات و قوانین فیزیکی حاکم بر حوزه نیز شناخته می‌شوند. مدل فیزیکی دربرگیرنده تعداد زیادی از پارامترها و متغیرهای مشاهداتی است که می‌بایست یک فرآیند هیدرولوژیکی پیچیده را توصیف نماید (۱۵). در این روش از یک چهارچوب ریاضی بر اساس خصوصیات حوضه مانند شدت و مدت بارش، اندازه، شکل، شیب و خصوصیات ذخیره‌ای حوضه، توپوگرافی، کاربری اراضی، نوع خاک و گیاه و خصوصیات اقلیمی حوضه برای مدل‌سازی فرآیند بارش-رواناب استفاده می‌شود. علاوه بر خصوصیات فوق، شرایط اولیه متغیرها و شرایط مرزی نیز می‌بایست توسط معادلات دیفرانسیل مشخص شده باشند. در اکثر مناطق و به‌ویژه در کشورهای در حال توسعه یا چنین اطلاعاتی وجود ندارند یا به‌دست آوردن آنها بسیار مشکل است (۱۵).

پایه و اساس روش‌های داده‌محور برای مدل‌سازی فرآیندهای هیدرولوژیکی، استفاده و استخراج اطلاعاتی است که بصورت ضمنی درون داده‌های هیدرولوژیکی وجود دارند بدون اینکه هیچ اطلاعات دقیقی از خصوصیات و قوانین فیزیکی حاکم وجود داشته باشد. توسعه

گرفته است. کاربردهای بسیار کمی از این روش در مهندسی منابع آب گزارش شده است (۱۶).

کاربردهای موفقیت‌آمیزی از GMDH در مهندسی، علوم و اقتصاد شامل شناسایی قوانین فیزیکی، پیش‌بینی کوتاه‌مدت فرآیندها، شناسایی الگوها در متغیرهای گسسته و پیوسته گزارش شده است (۱۶). نیکولایف و هیتوشی (۱۱) از این روش برای مدلسازی سری‌های زمانی در شاخه‌های مختلف علمی مانند اکولوژی، هواشناسی و اقتصادی استفاده کردند. نریمان‌زاده و همکاران (۱۰) از این روش برای بهینه‌سازی چندمنظوره دینامیک حرارتی موتورهای سوخت هواپیما بهره گرفتند. قادری و همکاران (۱۳) از این روش در مدلسازی بهره‌برداری هوشمند از مخازن استفاده نمودند. هوانگ (۵) برای پیش‌بینی قیمت فروش ارتباطات مخابراتی از ترکیب GMDH با منطق فازی استفاده نمود.

در این تحقیق با توجه به خصوصیات محدوده مطالعاتی، وجود روابط غیرخطی بین متغیرهای ورودی و خروجی، تعداد زیاد متغیرها، عدم قطعیت‌های موجود و در دسترس بودن داده‌های مشاهده‌ای، یک مدل قدرتمند GMDH که قابلیت یادگیری بسیار بالا و توانایی برخورد با مسائلی با متغیرهای زیاد را دارد، در محیط برنامه‌نویسی نرم‌افزار MATLAB توسعه داده شده است. برای بررسی و تایید نتایج مدل توسعه یافته، نتایج این مدل با نتایج مدلسازی فرآیند بارش رواناب با استفاده از شبکه‌های عصبی در حوضه پلرود گیلان مقایسه شده است.

ایواخنکو (۶) به عنوان یک روش تجزیه و تحلیل چند متغیره برای شناسایی و مدلسازی سیستم‌های پیچیده توسعه داده شد. GMDH می‌تواند برای مدل کردن سیستم‌های پیچیده بدون در دست داشتن دانش ویژه اولیه‌ای مورد استفاده قرار بگیرد. ایده اصلی GMDH بصورت ساختن یک تابع تحلیلی مبتنی بر یک شبکه پیش‌رونده بر اساس توابع انتقالی دو جمله‌ای می‌باشد (۹). GMDH روشی برای شناسایی سیستم‌های غیرخطی با متغیرهای ورودی زیاد می‌باشد که شکل ریاضی آن توسط شبکه‌ای متوالی از توصیفات جزئی بیان می‌شود. خروجی هر لایه به عنوان ورودی لایه بعدی بکار می‌رود. ساختار آن به صورت یک شبکه چندلایه پیش‌رونده می‌باشد که مشابه با شبکه‌های عصبی مصنوعی است با این تفاوت که برعکس شبکه‌های عصبی، ساختار این شبکه، تعداد نرون‌ها در هر لایه و تعداد لایه‌ها نامعلوم می‌باشند که می‌بایست در طول فرآیند آموزش تعیین شوند. ساختار شبکه‌های عصبی توسط طراح تعیین می‌گردد. این در حالی است که در GMDH طراح نقش بسیار کمتری در تعیین بهترین توپولوژی و ساختار شبکه دارد و این خود شبکه است که به مرور ساختار خود را بازسازی می‌کند. آموزش پارامترهای این شبکه براساس رویکرد تخمین حداقل مربعات انجام می‌شود (۱۲). این مدل بطور گسترده‌ای در زمینه‌های مختلف تحقیقاتی و کاربردی برای برخورد با عدم قطعیت‌ها، سیستم‌های خطی و غیرخطی توسط محققان مختلفی مورد استفاده قرار

مواد و روش‌ها

روش کنترل گروهی داده‌ها (GMDH)

تحقیقات زیادی برای استفاده از روش‌های تکامل‌گرا به عنوان ابزار موثری جهت شناسایی سیستم‌ها صورت گرفته است. یکی از این روش‌ها، الگوریتم GMDH می‌باشد که یک رویکرد خودسازماندهی بوده و به تدریج مدل‌های پیچیده‌تری در طول ارزیابی عملکرد مجموعه داده‌های ورودی و خروجی تولید می‌کند. ارتباط بین متغیرهای ورودی-خروجی را می‌توان با سری توابع ولترا که مشابه با چندجمله‌ای گسسته شده کولموگروف-گابور می‌باشد بیان نمود.

(۱)

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ijk} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijkl} x_i x_j x_k + \dots$$

که بردار متغیرهای ورودی $X = (x_1, x_2, \dots, x_m)$ و بردار وزن‌ها می‌باشند. $A = (a_0, a_1, a_2, \dots, a_m)$ چند جمله‌ای کولموگروف-گابور می‌تواند هر توالی تصادفی ایستا را تقریب بزند و توسط هر روش تطبیقی یا یک سیستم معادلات نرمال گوسین قابل محاسبه است. ایواخنکو با الهام از این چندجمله‌ای، الگوریتم GMDH را توسعه داد (۶). روش GMDH به خانواده روش‌های فراکوشی خود سازمان‌دهی تعلق دارد که از مفاهیم جعبه سیاه، مفهوم همبستگی و استقرا استفاده می‌کند (۱۱). ساختار این روش بصورت یک شبکه پیشرونده چندلایه می‌باشد که از یک سری نرون‌های

پشتیبانی تشکیل شده است. نرون‌های پشتیبانی حداقل دارای دو ورودی هستند. تابع انتقال یا محرک این نرون‌ها می‌تواند بصورت یک چندجمله‌ای خطی یا غیرخطی بصورت زیر بیان شود:

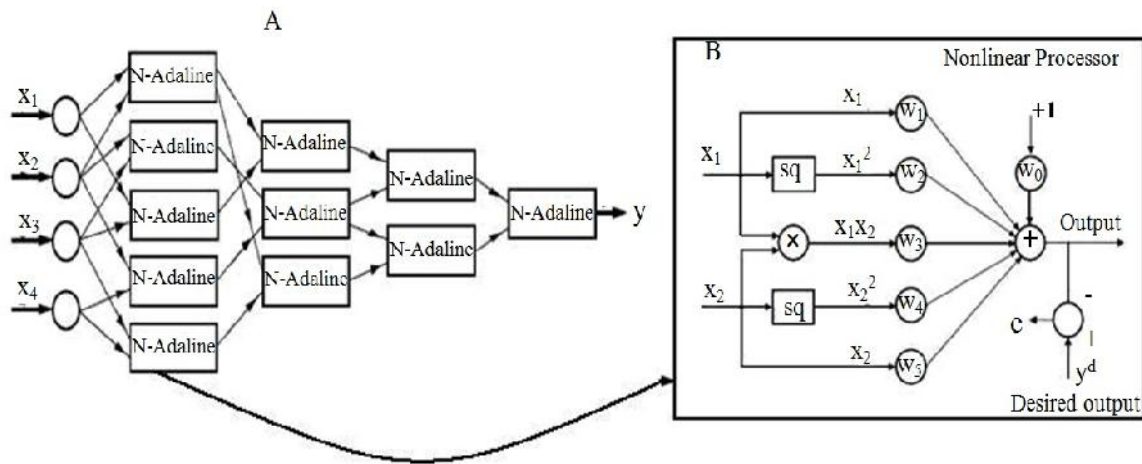
(۲)

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

که w_0 تا w_5 ضرایب چندجمله‌ای هستند. شماتیکی از این روش همراه با ساختار هر نرون (N-Adaline) در شکل (۱) ارائه شده است. در الگوریتم GMDH برای تولید نرون‌های لایه اول، تمام متغیرهای ورودی با هم ترکیب شده و تمام ترکیبات دوتایی متغیرهای ورودی در نظر گرفته می‌شوند. بعنوان مثال اگر تعداد متغیرهای ورودی m باشد، تعداد نرون‌های لایه اول برابر با $L_1 = \binom{m}{2} \text{ or } m(m-1)/2$ می‌باشد. برای تعیین ساختار شبکه، می‌بایست از معیار آستانه برای انتخاب نرون توصیف کننده اهداف می‌باشند استفاده نمود. این معیار به صورت زیر است:

$$R^2 = \frac{\sum_{t=1}^N (\hat{y}(t) - \bar{\hat{y}})^2}{\sum_{t=1}^N (y(t) - \bar{y})^2} \quad (۳)$$

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



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

آموزش پارامترها

هر نرون در ساختار GMDH یک تابع غیرخطی از ورودی‌ها را اجرا می‌کند. این تابع غیرخطی بصورت رابطه (۲) می‌باشد. ضرایب ۶ گانه 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 $X_n = (x_{n1}, x_{n2}, \dots, x_{np})$ که $n = 1, 2, \dots, N$ در مجموعه آموزشی وجود داشته باشد که هر کدام از P مقدار صحیح تشکیل شده‌اند. مقدار مطلوب خروجی n ام با ϕ_n نشان داده می‌شود. می‌بایست مجموعه‌ای از ضرایب ۶ گانه برای هر نرون پیدا شود طوری که میانگین مربعات خطا بین خروجی‌های این نرون y_n و مقدار واقعی ϕ_n حداقل باشد. با استفاده از معادلات نرمال گوسین، این ضرایب بصورت زیر به دست می‌آیند:

(۴)

$$\begin{aligned} \phi_1 &= w_0 + w_1 x_{1i} + w_2 x_{1j} + w_3 x_{1i}^2 + w_4 x_{1j}^2 + w_5 x_{1i} x_{1j} \\ \phi_2 &= w_0 + w_1 x_{2i} + w_2 x_{2j} + w_3 x_{2i}^2 + w_4 x_{2j}^2 + w_5 x_{2i} x_{2j} \\ &\vdots \\ \phi_N &= w_0 + w_1 x_{Ni} + w_2 x_{Nj} + w_3 x_{Ni}^2 + w_4 x_{Nj}^2 + w_5 x_{Ni} x_{Nj} \end{aligned}$$

معادلات فوق را می‌توان به صورت یک ماتریس نشان داد:

$$\phi = XW \quad (5)$$

ماتریس‌های ϕ ، X و W دارای ابعاد $N \times 1$ ، $N \times 6$ و 6×1 هستند. معادلات نرمال با استفاده از ضرب طرفین رابطه بالا در ترانهاده ماتریس X بدست می‌آیند:

(۶)

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

$X^T X$ یک ماتریس 6×6 بوده و می‌توان ضرایب را با استفاده از روش معکوس به دست آورد.

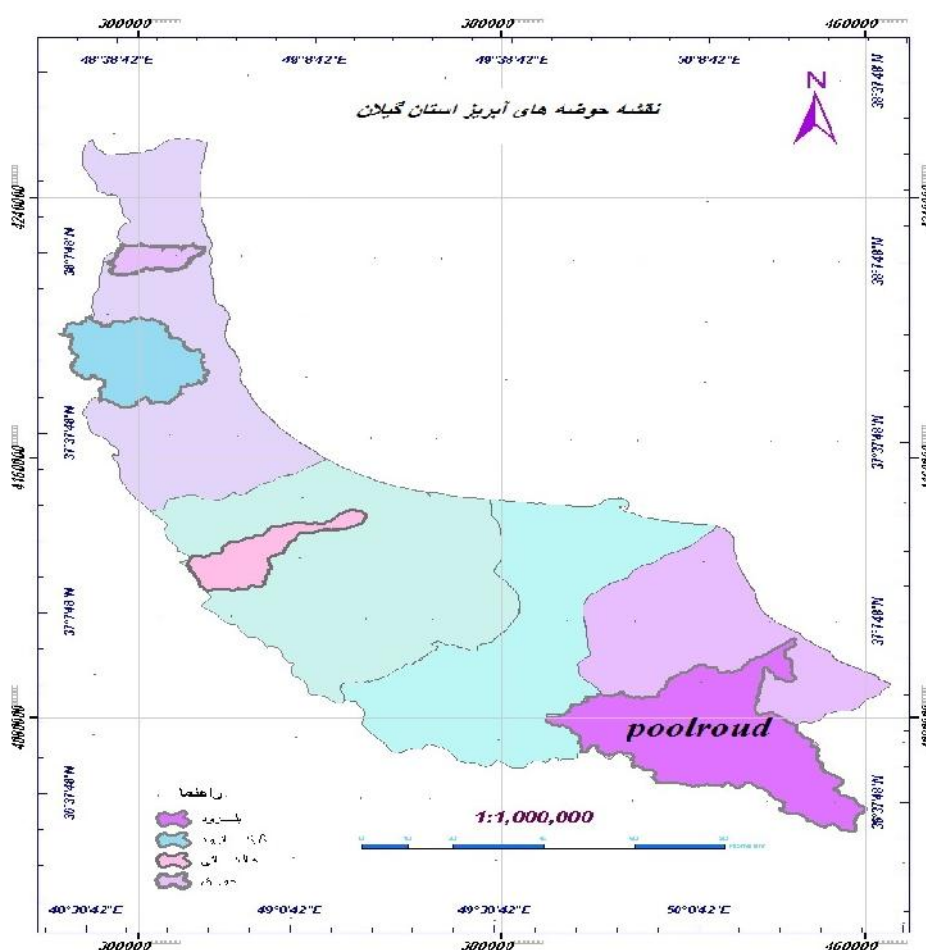
دارد. پلرود رودخانه نسبتاً بزرگی است که آب‌های قسمت وسیعی از دامنه‌های شمالی ارتفاعات البرز مرکزی را که شامل ارتفاعات جنوب و غرب دیلمان نیز می‌شود جمع‌آوری و به دریای خزر می‌رساند. شاخه‌های اولیه رودخانه از کوه‌های سماموس (ارتفاع ۳۶۹۵ متر) و خشچال (ارتفاع ۳۹۴۵ متر) واقع در ۵۰ کیلومتری شمال شرقی قزوین سرچشمه می‌گیرد. شیب رودخانه پلرود زیاد است و پس از ورود به دشت از آب آن جهت آبیاری بیش از ۸۰۰۰ هکتار از اراضی کشاورزی استفاده می‌گردد.

حوزه پلرود و موقعیت ایستگاه‌های هواشناسی و هیدرومتری در این حوزه در شکل (۳) نشان داده شده است. در این تحقیق از داده‌های بارندگی ایستگاه‌های کاکرود $R_{(ka)}$ ، درازلات $R_{(dr)}$ ، موسی کلایه $R_{(mo)}$ ، اسپیلی $R_{(es)}$ و دیارجان $R_{(di)}$ که بصورت روزانه و دارای طول آماری هفت سال بین سال‌های ۱۳۸۹-۱۳۸۲ می‌باشند و داده‌های مشاهداتی رواناب در زمان‌های قبل به عنوان متغیرهای ورودی مدل استفاده شده است. داده‌های مشاهداتی جریان رودخانه $Q_{(t)}$ در ایستگاه هیدرومتری درازلات به عنوان متغیر خروجی برای شبیه‌سازی فرآیند بارش- رواناب حوزه آبریز پلرود توسط دو مدل GMDH و ANN در نظر گرفته شده است.

ماتریس W شامل مجموعه‌ای از ۶ ضریب است که قادر به تقریب خروجی‌های صحیح با حداقل میانگین مربعات خطا می‌باشد. مراحل فوق برای تمام نرون‌های لایه اول و همچنین برای تمام نرون‌های لایه‌های بعدی نیز تکرار می‌شوند. بعد از بدست آمدن ضرایب بر اساس داده‌های آموزشی، شاخص عملکرد نرون‌های بدست آمده از طریق همبستگی یا محاسبه میانگین خطای مربعات بین خروجی‌های واقعی داده‌های کنترل محاسبه می‌شوند و تنها نرون‌هایی که دارای شاخص عملکرد بالاتر از مقدار آستانه (رابطه ۳) هستند برای ساخت لایه بعدی انتخاب می‌شوند.

مشخصات حوزه مورد مطالعه

حوزه آبریز پلرود در بخش انتهایی شرق گیلان بین طول‌های $X=435000$ تا $X=450000$ و عرض‌های $Y=4095000$ تا $Y=4110000$ در سیستم UTM واقع شده است. مساحت حوزه آبریز رودخانه پلرود ۱۷۶۵ کیلومتر مربع می‌باشد. شکل حوزه آبریز بادبزی و محیط حوزه ۲۲۳ کیلومتر و طول شاخه اصلی آن ۸۰ کیلومتر می‌باشد. موقعیت حوزه آبریز پلرود در استان گیلان در شکل (۲) نشان داده شده است. رودخانه پلرود، رودخانه‌ای دائمی است که پس از سفیدرود یکی از پرآب‌ترین رودخانه‌های منطقه گیلان بوده و در شهرستان رودسر قرار



شکل ۲- موقعیت حوزه آبخیز پلرود در استان گیلان

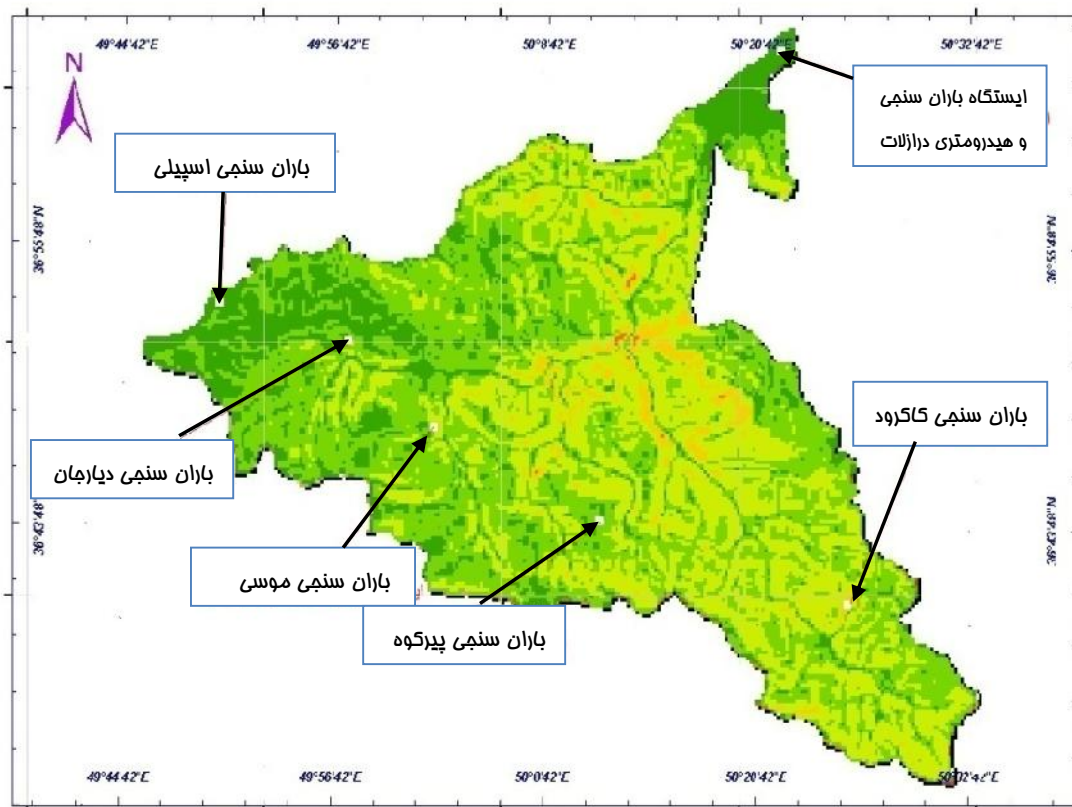
دیفرانسیلی Mackey-Glass می‌باشد که بصورت زیر تعریف می‌گردد:

$$\frac{dx(t)}{dt} = \frac{ax(t+1)}{1 + x^{10}(t+1)} - bx(t) \quad (7)$$

که مقادیر a و b به ترتیب برابر با 0.2 و 0.1 می‌باشند. پیش‌بینی مقادیر آینده این سری زمانی یک مسئله پایه در مدلسازی می‌باشد که توسط محققان بسیاری مورد استفاده قرار گرفته است (۱۵).

بررسی صحت مدل

قبل از اینکه نتایج بدست آمده از مدل هوشمند GMDH ارائه گردد لازم است که صحت مدل توسعه داده شده توسط توابع استاندارد مورد بررسی قرار گیرد. در ادامه نشان داده شده است که چگونه مدل هوشمند فرادهنی GMDH توسعه داده شده برای پیش‌بینی مقادیر آینده یکسری زمانی مغشوش مورد استفاده قرار گرفته است. سری زمانی مورد استفاده در این تحقیق معادله



شکل ۳- موقعیت ایستگاه‌های باران‌سنجی و هیدرومتری در نقشه حوزه آبریز پلرود

شده بصورت $x_{(0)}=1/2$ و $\dagger = 17$ می‌باشد. به این ترتیب با استفاده از حل عددی مقادیر $x_{(t)}$ برای t بین صفر تا ۲۰۰۰ بدست می‌آید. از حل سری زمانی Mackey-Glass، ۱۰۰۰ جفت داده ورودی- خروجی به صورت $\{x_{(t+6)} : x_{(t)}, x_{(t-6)}, x_{(t-12)}, x_{(t-18)}\}$ بدست می‌آید که t بین ۱۱۸ تا ۱۱۱۷ قرار دارد. از ۵۰۰ جفت داده اولیه به عنوان داده‌های آموزشی و از ۵۰۰ جفت داده باقی‌مانده برای اعتبارسنجی استفاده شده است. برای بررسی نتایج بدست آمده از مدل‌سازی از چندین معیار آماری استفاده شده است. این معیارهای آماری شامل مجموع

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 ، P و Δ مشابه با آنچه که دیگر محققان در نظر گرفتند بصورت $D=4$ و $P=\Delta=6$ انتخاب شده‌اند. گام زمانی انتخاب شده برای مسئله فوق برابر با $0/1$ و شرایط اولیه در نظر گرفته

می‌باشد. دامنه تغییرات MSRE بین صفر تا ∞ می‌باشد در حالیکه مقادیر بین صفر تا ۰/۵ مقادیر قابل قبول هستند. دامنه تغییرات MPRE نیز بین صفر تا ∞ می‌باشد. دامنه تغییرات RB بین $-\infty$ تا ∞ می‌باشد که مقادیر منفی بیانگر تخمین بیش از حد و مقادیر مثبت بیانگر تخمین کمتر از حد می‌باشند. همچنین دامنه تغییرات (CE) بین $-\infty$ تا +۱ بوده و بنا به نظر محققان مقادیر بالای ۰/۹ بسیار رضایت‌بخش و مقادیر بالای ۰/۷ قابل قبول می‌باشند (۱۷). نتایج حاصل از مدلسازی سری زمانی مکی‌گلاس در دوره آموزش و اعتبارسنجی در شکل‌های ۴ و ۵ و مقادیر محاسبه شده برای شاخص‌های آماری در جدول ۱ ارائه شده است. مقایسه مقادیر مطلوب و تخمین زده شده مقادیر این سری زمانی در دوره آموزش و اعتبارسنجی و همچنین مقادیر بسیار مطلوب شاخص‌های آماری چه در دوره آموزش و چه دوره اعتبارسنجی حاکی از توانایی و عملکرد بسیار بالای مدل توسعه داده شده در تخمین و پیش‌بینی سری‌های زمانی می‌باشد.

مربعات میانگین خطای نسبی (MSRE)، مجموع مطلق میانگین خطای نسبی (MSRE)، ضریب راندمان (CE) و انحراف نسبی (RB) می‌باشند. این معیارها به صورت زیر تعریف می‌شوند.

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

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

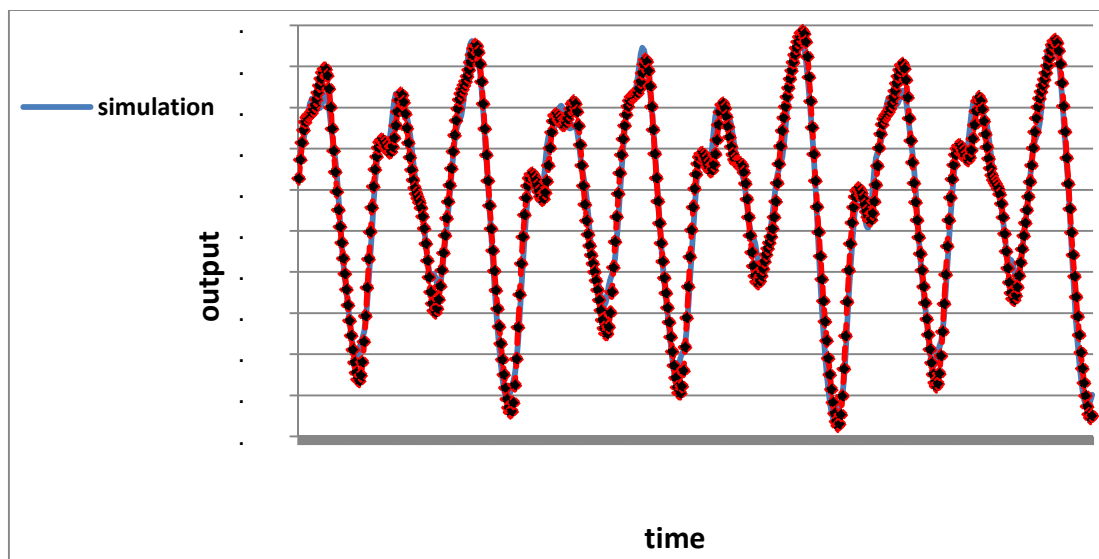
$$R^2 = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q})^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}$$

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

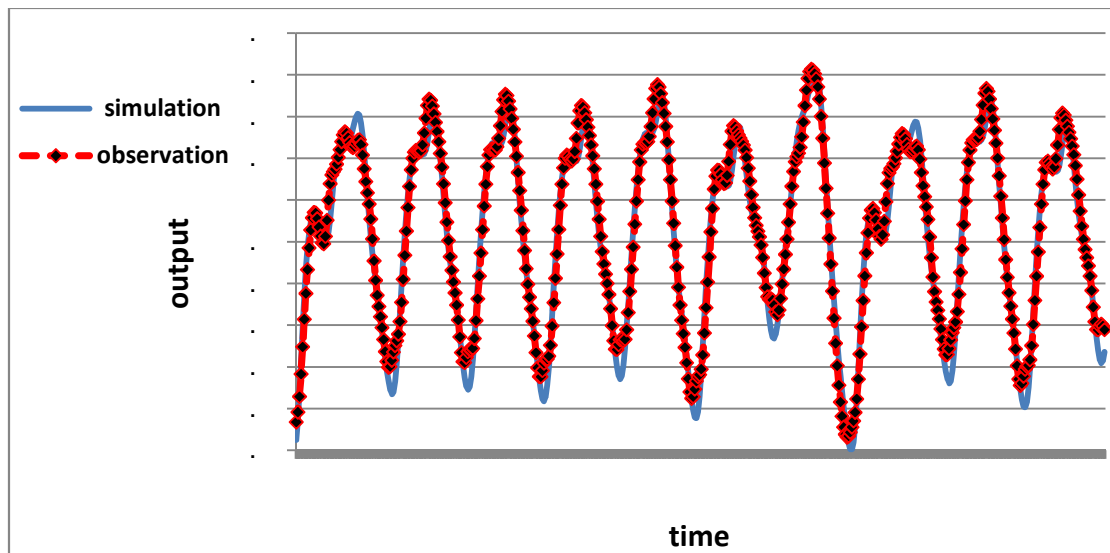
که n تعداد داده‌ها، Q_i داده‌های مشاهداتی، \hat{Q} داده‌های محاسباتی و \bar{Q} میانگین داده‌های مشاهداتی است. MSRE و MPRE بیانگر شاخصی برای بیان دقت نسبی مدلسازی، RB بیانگر این است که پاسخ‌های تولید شده نسبت به مقادیر مطلوب کمتر تخمین زده شده‌اند یا بیشتر و (CE) بیان‌کننده شاخصی برای تولید مناسب پاسخ‌ها توسط مدل

جدول ۱- شاخص‌های آماری پیش‌بینی سری زمانی Mackey-Glass در مرحله آموزش و اعتبارسنجی

معیارها	CE	MSRE	MPRE	RB
مرحله آموزش	۰/۹۷	۰/۰۰۲۵	۰/۰۳۶	-۰/۰۰۲۶
مرحله اعتبارسنجی	۰/۹۶	۰/۰۰۲۸	۰/۰۳۶۵	-۰/۰۱۲



شکل ۴- مقایسه مقادیر مطلوب و شبیه‌سازی شده سری زمانی Mackey-Glass در مرحله آموزش



شکل ۵- مقایسه مقادیر مطلوب سری زمانی Mackey-Glass در مرحله اعتبارسنجی

نتایج و بحث

حال که صحت مدل توسعه داده شده توسط پیش‌بینی مقادیر آینده سری زمانی مکی‌گلاس مورد تایید قرار گرفت، می‌توان از آن برای شبیه‌سازی فرآیند بارش رواناب در محدوده مورد مطالعه استفاده نمود. در این تحقیق از داده‌های بارندگی ایستگاه‌های کاکرود، موسی کلاویه، دیارجان،

اسپیلی و درازلات که به صورت روزانه و دارای طول آماری هفت سال بین سال‌های ۱۳۸۲ تا سال ۱۳۸۹ می‌باشند به عنوان ورودی و از داده‌های مربوط به جریان رودخانه که در پایین‌دست این ایستگاه‌های باران سنجی در ایستگاه هیدرومتری درازلات بصورت روزانه اندازه‌گیری شده به عنوان خروجی مشاهداتی برای شبیه‌سازی فرآیند بارش- رواناب در مدل

همبستگی تقاطعی (CCF) و بین داده‌های رواناب آزمون خودهمبستگی (ACF) انجام شد. مشخص گردید که رابطه معنی‌داری بین میزان رواناب در زمان t با میزان رواناب در تاخیرهای زمانی $t-1$ تا $t-5$ وجود دارد. در نتیجه از داده‌های رواناب با تاخیرهای زمانی $t-1$ تا $t-5$ به عنوان متغیرهای ورودی استفاده شده است. با استفاده از آزمون‌های فوق ساختار ورودی‌ها بدست آمده که حالت‌های مختلف آن در جدول (۲) آورده شده است.

GMDH و ANN در نظر گرفته شده‌اند. تمام داده‌ها قبل از مدلسازی توسط رابطه زیر به صورت نرمال در آمده‌اند.

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (۸)$$

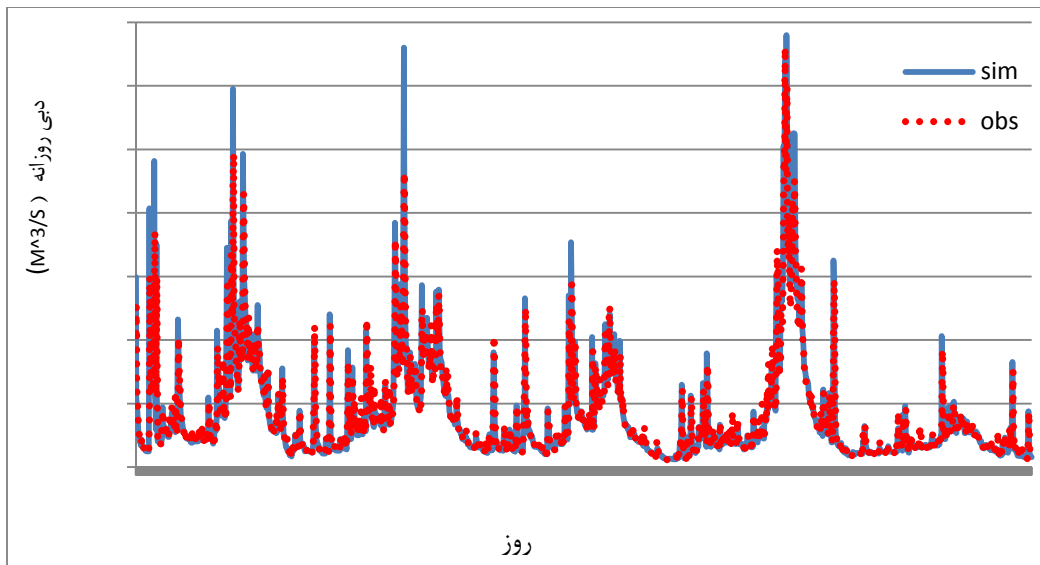
که X_n داده نرمال شده، X داده‌های هر سری و X_{min} و X_{max} به ترتیب بیشترین و کمترین مقدار در هر سری می‌باشد. برای انتخاب متغیرهای ورودی با استفاده از نرم‌افزار SPSS بین داده‌های بارندگی و داده‌های رواناب آزمون

جدول ۲- حالت‌های مختلف ورودی به مدل GMDH

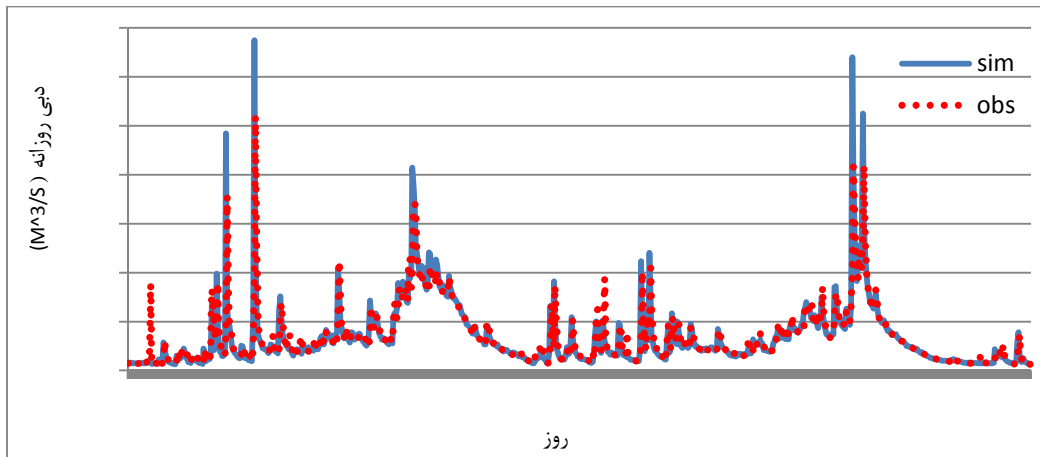
حالت	ساختار ورودی‌ها
حالت ۱	$Q(t) = f \{ R(ka), R(mo), R(di), R(dr), R(es), Q(t-1), Q(t-2) \}$
حالت ۲	$Q(t) = f \{ R(ka), R(mo), R(di), R(es), R(dr), Q(t-1) \}$
حالت ۳	$Q(t) = f \{ R(ka), R(mean dr, es, mo, di), Q(t-1), Q(t-2), Q(t-3) \}$
حالت ۴	$Q(t) = f \{ R(ka), R(es), R(di), R(dr), Q(t-1), Q(t-2), Q(t-3) \}$
حالت ۵	$Q(t) = f \{ R(mean es, mo, di), R(ka), R(dr), Q(t-1), Q(t-2), Q(t-3), Q(t-4) \}$
حالت ۶	$Q(t) = f \{ R(ka), R(dr), Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5) \}$

روزانه با استفاده از مدل توسعه داده شده GMDH و مقادیر مشاهداتی دبی در دوره آموزش نشان داده شده است. در شکل ۷ مقادیر شبیه‌سازی شده و مقادیر مشاهداتی دبی روزانه در دوره اعتبارسنجی ارائه شده است. همچنین مقادیر دبی روزانه شبیه‌سازی شده با استفاده از مدل شبکه عصبی در دوره اعتبارسنجی نیز در شکل ۸ ارائه شده است.

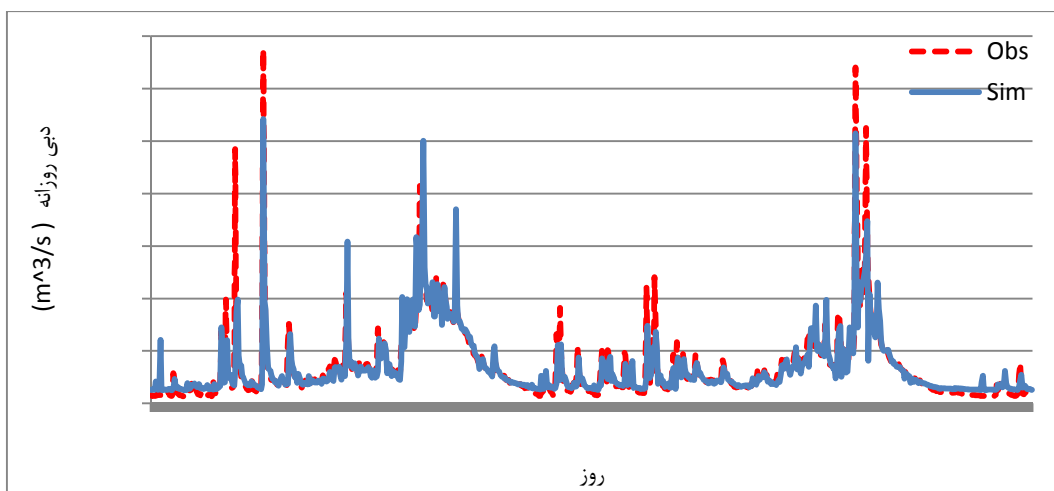
در توسعه مدل GMDH از ۷۰ درصد داده‌ها برای آموزش و از ۳۰ درصد داده‌ها برای اعتبارسنجی استفاده شده است. به عنوان نمونه نتایج حاصل از توسعه مدل GMDH و ANN برای شبیه‌سازی فرآیند بارش - رواناب در حالت پنجم بصورت نمودار در شکل‌های ۶ تا ۸ و معیارهای آماری محاسبه شده برای کلیه حالت‌ها در جداول ۳ و ۴ آورده شده است. در شکل ۶ مقادیر شبیه‌سازی شده دبی



شکل ۶- رواناب محاسباتی و مشاهداتی در دوره آموزش مربوط به مدل GMDH



شکل ۷- رواناب محاسباتی و مشاهداتی در دوره اعتبارسنجی مربوط به مدل GMDH



شکل ۸- رواناب شبیه‌سازی شده و رواناب مشاهداتی توسط ANN

جدول ۳- شاخص‌های آماری مربوط به مدل توسعه داده شده GMDH در مرحله آموزش و اعتبارسنجی

RB	MPRE	MSRE	CE	معیارها	
-۰/۰۶	۰/۱۹	۰/۱۲	۰/۸۶۵	آموزش	حالت اول
-۰/۱۷	۰/۳	۰/۶	۰/۸۳۴	اعتبارسنجی	
-۰/۰۶	۰/۲	۰/۱۱	۰/۸۹۵	آموزش	حالت دوم
-۰/۲	۰/۳۱	۰/۷	۰/۸۳۶	اعتبارسنجی	
-۰/۱	۰/۱۸	۰/۱	۰/۸۹	آموزش	حالت سوم
-۰/۱۵	۰/۲۹	۰/۶	۰/۷۹	اعتبارسنجی	
-۰/۰۵	۰/۱۹	۰/۱	۰/۸۶	آموزش	حالت چهارم
-۰/۲	۰/۲۸	۰/۶	۰/۸۱	اعتبارسنجی	
-۰/۰۶	۰/۱۹	۰/۱	۰/۹۴	آموزش	حالت پنجم
-۰/۱۳	۰/۲۸	۰/۳۴۵	۰/۸۹۵	اعتبارسنجی	
-۰/۰۶	۰/۲	۰/۱۲	۰/۹۰۵	آموزش	حالت ششم
-۰/۰۹	۰/۲۲	۰/۱۳	۰/۸۷	اعتبارسنجی	

جدول ۴- شاخص‌های آماری مربوط به مدل ANN در دوره اعتبارسنجی

RB	MPRE	MSRE	CE	معیارها	
-۰/۳۱	۰/۳۲	۰/۴	۰/۸۵		حالت اول
-۰/۴۹	۰/۳۴	۰/۳۴	۰/۸۰		حالت دوم
-۰/۴۱	۰/۳۳	۰/۳۰	۰/۸۱		حالت سوم
-۰/۵۱	۰/۴۲	۰/۳۴	۰/۷۹		حالت چهارم
-۰/۳۰	۰/۳۳	۰/۴۵	۰/۸۶		حالت پنجم
-۰/۳۰	۰/۳۱	۰/۴۱	۰/۸۴		حالت ششم

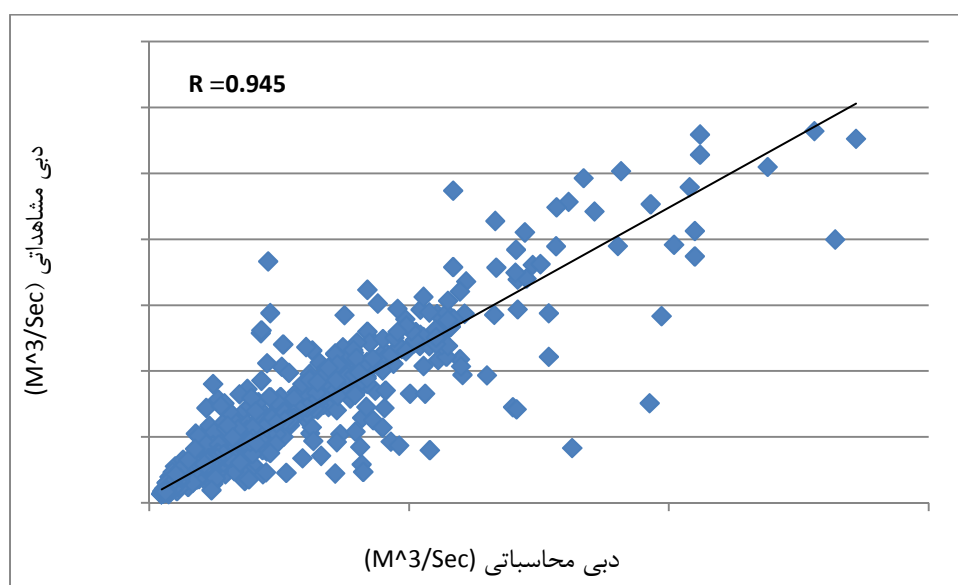
ضریب CE برای مدل GMDH برابر با ۰/۸۹۵ و برای مدل ANN برابر با ۰/۸۶ بدست آمده است. هرچه مقدار این ضریب به یک نزدیکتر باشد بیانگر رضایت بخشی بیشتر نتایج بدست آمده می‌باشد. معیار MSRE به ترتیب برای مدل GMDH و ANN برابر با ۰/۳۴۵ و ۰/۴۵ محاسبه شده که مقادیر بین صفر تا ۰/۵ قابل قبول می‌باشند و هرچه مقدار این شاخص به صفر نزدیکتر باشد نتایج شبیه‌سازی مطلوبتر می‌باشد. معیار MPRE بدست آمده از نتایج مدل GMDH و ANN برابر با ۰/۲۸ و ۰/۳۳ محاسبه شده که هرچه این مقادیر به صفر نزدیکتر باشد بیانگر این است که نتایج شبیه‌سازی از دقت بالاتری برخوردارند. معیار

مقایسه نتایج شبیه‌سازی فرآیند بارش- رواناب در حوزه آبخیز پلرود در مقیاس زمانی روزانه توسط دو مدل GMDH و ANN نشان می‌دهد که هر دو مدل GMDH و ANN دارای توانایی بالایی در شبیه‌سازی فرآیند بارش- رواناب می‌باشند. در هر دو مدل استفاده از داده‌های رواناب با تاخیرهای زمانی مختلف تاثیر مطلوبی در بهبود نتایج داشته است. در مجموع نتایج مدل GMDH در شبیه‌سازی فرآیند بارش- رواناب در حوزه آبخیز پلرود در مقیاس روزانه بهتر از مدل ANN بوده است. به عنوان نمونه مقایسه‌ای بین مقادیر شاخص‌های آماری در حالت پنجم مدلسازی در دوره اعتبارسنجی ارائه شده است.

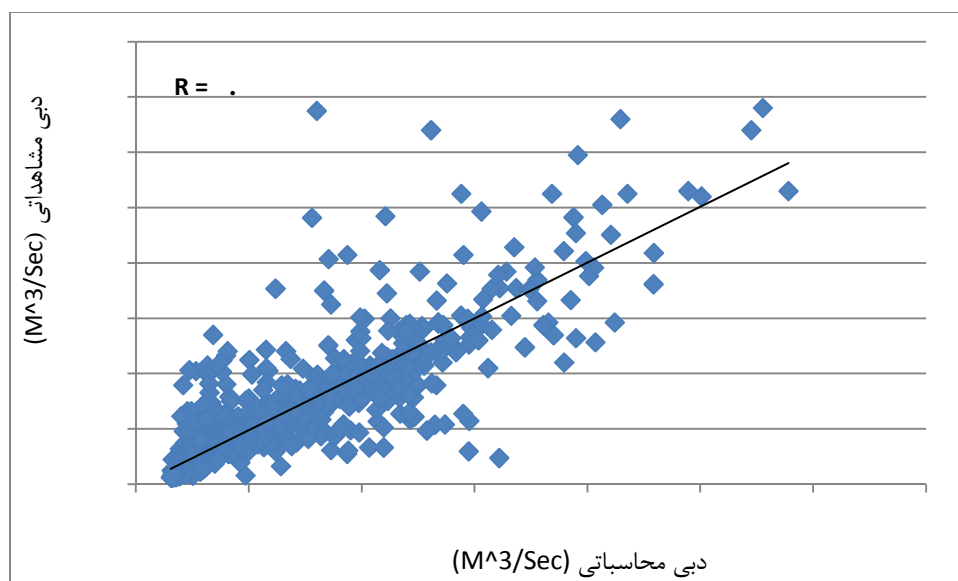
دقت مدل GMDH بیشتر از مدل ANN می‌باشد.

در این تحقیق با استفاده از روش کنترل گروهی داده‌ها (GMDH) مدلی جهت شبیه‌سازی فرآیند بارش-رواناب رودخانه پلرود توسعه داده شده است. نتایج حاصل از آموزش و ارزیابی این مدل نشان می‌دهد که روش GMDH می‌تواند به عنوان یک ابزار مناسب جهت مدلسازی فرآیند بارش-رواناب و سری‌های زمانی فرآیندهای پیچیده هیدرولوژیکی با دقت مناسب به کار برده شود. همچنین مقایسه نتایج این مدل با شبکه‌های عصبی مصنوعی برای شبیه‌سازی فرآیند بارش رواناب در مقیاس روزانه نشان می‌دهد که در اغلب موارد معیارهای آماری در مدل GMDH دارای مقادیر مناسب‌تری بوده‌اند.

RB محاسبه شده از نتایج مدل GMDH و ANN به ترتیب برابر با ۰/۱۳- و ۰/۳۰- می‌باشند که هرچه این مقادیر به صفر نزدیکتر باشد بیانگر تخمین مناسب‌تر پاسخ‌های تولید شده نسبت به پاسخ‌های مطلوب می‌باشد. همچنین در شکل‌های ۹ و ۱۰ به عنوان نمونه برای حالت سوم نمودار رگرسیونی همراه با ضریب R برای مقایسه دو مدل GMDH و ANN آورده شده است. ضریب رگرسیون محاسبه شده برای نتایج بدست آمده از مدل GMDH برابر با ۰/۹۴۵ و برای شبکه‌های عصبی برابر با ۰/۸۹۵ بوده است. همانطور که مقادیر این ضرایب نیز نشان می‌دهد نتایج تخمین زده شده برای رواناب خروجی از حوزه پلرود در ایستگاه درازلات با استفاده از دو مدل استفاده شده دارای دقت بسیار بالایی هستند. ولی در همه حالات ارائه شده در جدول (۲)،



شکل ۹- رواناب شبیه‌سازی شده و مشاهداتی توسط GMDH



شکل ۱۰- رواناب شبیه‌سازی شده و مشاهداتی توسط ANN

منابع

1. Abrahart, R.J. and L.M. See. 2000. Comparing neural network and autoregressive moving average techniques for the provision of continues river flow forecast in two contrasting catchments. *Hydrological Process*, 14: 2157-2172.
2. Hsu, K.L., H.V. Gupta and S. Sorooshian. 1995. Artificial neural network modeling of the rainfall runoff process. *Water Resources Research*, 31(10): 2517-2530.
3. Hu, T., F. Wu and X. Zhang. 2007. Rainfall runoff modeling using principal component analysis and neural network. *Nordic Hydrology*, 38(3): 235-248.
4. Hung, N.Q., M.S. Babel, S. Weesakul and N.K. Tripathi. 2009. An Artificial Neural Network model rainfall forecasting in Bangkok, Thiland. *Hydrologic, Earth Systems. Science*, 13: 1413-1425.
5. 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.
6. 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(3): 43-55.
7. Kisi, O. 2008. River flow forecasting and estimation using different artificial neural network technique. *Hydrology Resource*, 39(1): 27-40.
8. Minns, A.W. and M.J. Hall. 1996. Artificial neural network as rainfall-runoff model. *Hydrological Science Journal*, 41(3): 399-417.
9. 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-ICAFS'96*, 491-500, Siegen, Germany.
10. 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 Material process and technology*, 128(1): 80-87.
11. Nikolaev, Y. and I. Hitoshi. 2003. Polynomial Harmonic GMDH Learning Networks for Time Series Modeling. *Neural Networks*, 16: 1527-1540.

12. Onwubolu, G.C. 2008. Design of hybrid differential evolution and group method of data handling networks for modeling and prediction. *Journal of Hydroinformatics*, 10(2): 127-137.
13. Qaderi, K., D. Arab, M. Teshnehlab and A. Ghazagh. 2010. Intelligent reservoir operation modeling using Group Method of Data Handling (GMDH). *Iran-Water Resource Research*, 6(3): 45-57.
14. Shamseldin, A.Y. 1997. Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology*, 199: 272-294.
15. Solomatine, D.P. and A. Ostfeld. 2008. Data-driven modeling: some past experience and new approaches. *Journal of Hydroinformatics*, 10: 3-22.
16. Sumsudin, R., P. Saad and A. Shabri. 2010. A hybrid least square support vector machines and GMDH approach for river flow forecasting. *Hydrology and Earth System Science Discussions*, 7: 3691-3731.
17. Wang, W.C., K.W. Chau, C.T. Cheng and L. Qui. 2009. A comparison of performance of several Artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374: 294-306.

Rainfall Runoff Modeling using Group Method of Data Handling (GMDH) and Artificial Neural Network (ANN) IN In Polrood Basin

Adel Pournemat Roudsari¹, Kouros Qaderi² and Shahram Karimi-Googhari³

1 and 3- M.Sc. Student and Assistant Professor, Shahid Bahonar University of Kerman

2 - Assistant Professor, Shahid Bahonar University of Kerman

(Corresponding author: kourosqaderi@uk.ac.ir)

Received: September 30, 2012

Accepted: May 27, 2013

Abstract

Rainfall-runoff modeling is an essential process and very complicated phenomena that is necessary for proper reservoir system operation and successful water resources planning and management. There are different methods like conceptual and numerical methods for modeling of this process. Theoretically, a system modeling required explicit mathematical relationships between inputs and outputs variables. Developing such explicit model is very difficult because of unknown relationship between variables and substantial uncertainty of variables. In this case, Data driven methods which are based on imprecise conditions and evolutionary algorithms have shown capabilities in many nonlinear systems identification and control issues. One of these intelligent methods is Group Method of Data Handling (GMDH). This method produce complex model during the performance evaluation of input and output information sets increasingly. So in this research we have developed a model based on GMDH for rainfall-runoff modeling in Polrood basin located in North of Iran in Guilan province. Results have evaluated using statistical criteria and compared with an artificial neural network (ANN) model. Results have shown the high performance of two methods for rainfall runoff modeling in dairy scales. Based on statistical criteria, experiment results indicates that the GMDH model was powerful tool to model rainfall runoff time series and can be applied successfully in complex hydrological modeling.

Keywords: Rainfall-Runoff modeling, Data Driven Method, GMDH, ANN, Polrood basin