



مقایسه عملکرد ماشین بردار پشتیبان با سایر مدل‌های هوشمند در شبیه‌سازی فرآیند بارش- رواناب

محمدعلی قربانی^۱، عاطفه ازانی^۲ و لیلا نقی‌پور^۳

۱- دانشیار، دانشگاه تبریز، (نویسنده مسئول: ghorbani@tabrizu.ac.ir)

۲ و ۳- دانشجوی کارشناس ارشد و کارشناس ارشد، دانشگاه تبریز

تاریخ دریافت: ۱۳۹۲/۵/۱۲ تاریخ پذیرش: ۱۳۹۲/۹/۲۰

چکیده

شبیه‌سازی فرآیند بارش- رواناب به عنوان مهم‌ترین گام در مطالعات مهندسی آب و مدیریت منابع آب است. در این تحقیق فرآیند بارش- رواناب ماهانه سیمینه‌رود در دوره آماری (۱۳۷۷-۱۳۹۰) با استفاده از مدل‌های ماشین بردار پشتیبان با توابع کرنل پایه شعاعی، چندجمله‌ای و خطی، مدل شبکه بیزی با الگوریتم یادگیری PC و نیز مدل‌های متداول شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن شبیه‌سازی شده و نتایج آن‌ها مورد مقایسه قرار گرفته است. از پارامترهای ضریب هم‌بستگی، ریشه میانگین مربعات خطا و ضریب نش‌ساتکلیف برای ارزیابی صحت مدل‌ها استفاده گردید. نتایج گویای عملکرد قابل قبول هر چهار مدل و برتری مدل برنامه‌ریزی بیان ژن با بیش‌ترین ضریب هم‌بستگی (CC=۰/۹۱)، کم‌ترین ریشه میانگین مربعات خطا (RMSE=۳/۱ m³/s) و مقدار ضریب نش‌ساتکلیف NS=۰/۸۲ در مرحله صحت‌سنجی است.

واژه‌های کلیدی: بارش- رواناب، برنامه‌ریزی بیان ژن، سیمینه‌رود، شبکه بیزی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

مقدمه

بیان ژن در شبیه‌سازی فرآیند بارش- رواناب روزانه حوزه آبخیز ليقوان، با تعریف دو مجموعه عملکرد ریاضی به این نتیجه دست یافتند که مدل حاصل از مجموعه عملکردهای اصلی مناسب‌تر است.

جایاواردنا و همکاران (۱۰) با استفاده از برنامه‌ریزی ژنتیک فرآیند بارش- رواناب را با داده‌های روزانه در دو حوزه نسبتاً بزرگ چین شبیه‌سازی کردند که نتایج حاصل با داده‌های واقعی مطابقت داشت. آیتک و همکاران (۱) با شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن بارش- رواناب روزانه حوزه رودخانه جونیاتا^۴ در ایالت پنسیلوانیای آمریکا را شبیه‌سازی کردند و نتیجه گرفتند که برنامه‌ریزی بیان ژن با دقت بهتری نسبت به شبکه‌های عصبی مصنوعی فرآیند بارش- رواناب را شبیه‌سازی می‌نماید. میسرا و همکاران (۱۶) با مقایسه مدل ماشین بردار پشتیبان با شبکه عصبی مصنوعی به پیش‌بینی رواناب و بار رسوب با استفاده از داده‌های روزانه، هفتگی و ماهانه در حوزه آبخیز هند پرداختند.

نتایج نشان داد ماشین بردار پشتیبان هم در زمینه پیش‌بینی رواناب و هم بار رسوب نسبت به شبکه عصبی مصنوعی بهتر می‌باشد. یون و همکاران (۲۵) دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان را به منظور پیش‌بینی تغییرات سطح آب زیرزمینی به کار گرفتند، که نتیجه این تحقیق حاکی از برتری مدل ماشین بردار پشتیبان می‌باشد. باتسیس و همکاران

برنامه‌ریزی بهره‌برداری از منابع آب‌های سطحی و زیرزمینی، ساماندهی رودخانه‌ها و هشدار سیل نیاز به پیش‌بینی آینده رودخانه و رواناب حوزه آبخیز دارد. به طوری که، آگاهی از چگونگی ارتباط بین بارندگی و رواناب حوزه‌های آبخیز بخش جدا نشدنی مطالعات طرح‌های آبی است. خاصیت غیرخطی، نبود قطعیت ذاتی این فرآیند، نیاز به اطلاعات وسیع، و پیچیده بودن مدل‌های فیزیکی از دلایلی است که باعث شده محققان به سوی مدل‌های متداول شامل شبکه عصبی مصنوعی (ANN)^۱ و برنامه‌ریزی بیان ژن (GEP)^۲ و مدل‌های جدیدی هم‌چون شبکه‌های تصمیم بیزی (BN)^۳ و ماشین بردار پشتیبان (SVM)^۴ رو آورند. دریاچه ارومیه یکی از بزرگ‌ترین و مهم‌ترین اکوسیستم‌های آبی در ایران می‌باشد. با توجه به این که افزایش دما و کاهش (تغییرات) زیاد بارش، در سال‌های اخیر به کاهش شدید تراز سطح آب دریاچه منجر شده است، آگاهی از میزان بارش و یا رواناب ناشی از آن در تفسیر و بررسی ذخیره آبی و نیز مسائل مربوط به برنامه‌ریزی و مدیریت منابع آب این حوزه مؤثر است. لذا در این تحقیق سیمینه‌رود، یکی از مهم‌ترین رودخانه‌های این حوزه مورد مطالعه قرار گرفته است.

مطالعات متعددی با روش‌های ذکر شده در زمینه هیدرولوژی و به ویژه فرآیند بارش- رواناب صورت گرفته است. سلطانی و همکاران (۲۲) با کاربرد برنامه‌ریزی

1- Artificial Neural Network
4-Support Vector Machine

2- Gene Expression Programming
5- Juniata

3- Bayesian Network

به یک جواب بهینه کلی منجر می‌گردد. در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز) مشخص شود.

$$f(x) = W^T \cdot \phi(x) + b \quad \text{رابطه (۱)}$$

$$y = f(x) + \text{noise} \quad \text{رابطه (۲)}$$

که در این معادله W : بردار ضرایب و b : ثابت مشخصه‌های تابع رگرسیونی و ϕ : نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVM از طریق مجموعه‌ای از نمونه‌ها (مجموعه آموزش) محقق می‌شود. برای محاسبه w و b لازم است تابع خطا (معادله ۳) در مدل SVM- با در نظر گرفتن شرایط مندرج (قیود) در معادله (۴) بهینه شود.

$$W^T \cdot \phi(X_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad \text{رابطه (۳)}$$

$$\text{رابطه (۴)}$$

$$\frac{1}{2} W^T \cdot W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* y_i - W^T \cdot \phi(X_i) - b \leq \varepsilon + \varepsilon_i, \varepsilon_i^* \geq 0, i = 1, 2, \dots, N$$

در معادلات بالا C : عددی صحیح و مثبت است، که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است. ϕ : تابع کرنل، N : تعداد نمونه‌ها و دو مشخصه ε_i و ε_i^* متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می‌توان به فرم زیر بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \phi(x_i)^T \cdot \phi(x) + b \quad \text{رابطه (۵)}$$

در معادله (۵) $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ می‌باشد. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل SVM رگرسیون انتخاب یک تابع کرنل به صورت رابطه زیر است:

$$K(X_j, X) = \phi(X_j)^T \cdot \phi(X) = \sqrt{b^2 - 4ac} \quad \text{رابطه (۶)}$$

می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف SVM- استفاده کرد. انواع توابع کرنل قابل استفاده در مدل SVM رگرسیونی عبارتند از: کرنل چندجمله‌ای^۱ با سه مشخصه هدف، کرنل توابع پایه شعاعی^۲ (RBF) با یک مشخصه هدف و کرنل خطی^۳ در مطالعات بارش- رواناب عمدتاً از مدل RBF استفاده می‌شود (۵). برای انجام فرآیند محاسبات کدی در محیط متلب نوشته شده است.

شبکه تصمیم بیزی

شبکه بیزی یک الگوی نموداری احتمالاتی است که مجموعه‌ای از متغیرها و احتمالات مربوط به هر یک را نشان می‌دهد. این شبکه یک گراف مستقیم و

بارش- رواناب روزانه در کالیفرنیا را شبیه‌سازی کردند، مدل ماشین بردار پشتیبان با سه نوع تابع کرنل با مدل شبکه عصبی مصنوعی مورد مقایسه قرار گرفت، در نتیجه این تحقیق ماشین بردار پشتیبان شبیه‌سازی دقیق‌تری از بارش- رواناب داشت (۲). شهپازی و همکاران (۲۱) مطالعه‌ای در زمینه پیش‌بینی فصلی خشکسالی درحوزه سدهای طالقان و ماملو با مدل ماشین بردار پشتیبان انجام دادند. ماشین بردار پشتیبان برای پیش‌بینی نمایه بارش استاندارد (SPI)^۱ استفاده گردید که نتایج حاصل در اکثر موارد دقت خوبی را نشان داد. طاهری و همکاران (۲۳) دو روش یادگیری فعال^۲ و ماشین بردار پشتیبان را برای شبیه‌سازی جریانان روزانه رودخانه کارون مورد مقایسه قرار دادند و قابلیت بالای ماشین بردار پشتیبان در شبیه‌سازی رواناب را مطرح نمودند. مهاجرانی و همکاران (۱۷) با کاربرد شبکه بیزی در مدیریت بهره‌برداری از آب زیرزمینی، بیان کردند که استفاده از شبکه بیزی در مدیریت بهره‌برداری از منابع آب زیرزمینی می‌تواند به مدیران و برنامه‌ریزان به منظور برنامه‌ریزی و مدیریت صحیح منابع آب کمک شایانی کند. فرمانی و همکاران (۷) با شبکه‌های بیزی به مدیریت بهینه آلودگی آب‌های زیرزمینی در کنه‌ها پرداختند. نتیجه به دست آمده حاکی از موفقیت‌آمیز بودن کاربرد الگوهای شبکه بیزی در مدیریت آلودگی آب‌های زیرزمینی منطقه بوده است. کارمونا و همکاران (۴) برای مدیریت منابع آب زیرزمینی در دو مطالعه موردی واقع در اسپانیا از الگوی شبکه بیزی که یک سامانه مناسب پشتیبانی استفاده نموده‌اند. صادقی‌حصار و همکاران (۱۹) به منظور پیش‌بینی بارش ماهانه استان خراسان قابلیت مدل شبکه بیزی را مطرح و تأیید نموده‌اند.

افزون بر مطالعات ذکر شده می‌توان به تحقیقات انجام شده از سوی دیباک و همکاران (۴)، فربودفام و همکاران (۶)، قربانی و همکاران (۹،۸)، خطیبی و همکاران (۱۳،۱۲،۱۱)، مدیر و همکاران (۱۵) و نوری و همکاران (۱۸) اشاره کرد. با توجه به موارد ذکر شده و اهمیت حوزه سیمین‌رود در این تحقیق سعی شده است فرآیند بارش- رواناب با استفاده از مدل‌های ماشین بردار پشتیبان، شبکه بیزی، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن شبیه‌سازی شده و عملکرد هر یک مورد بررسی قرار گیرد.

مواد و روش‌ها

مدل ماشین بردار پشتیبان

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و

1- Standard Precipitation Index
4- Radial Basis Function


2- Active Learning Method
5- Linear

3- Polynomial

که در آن، $p(a)$: احتمال وقوع پیشامد a ، $p(b)$: احتمال وقوع پیشامد b ، $p(b|a)$: احتمال شرطی پیشامد b است، به شرطی که پیشامد a اتفاق افتاده باشد و $p(a|b)$: احتمال شرطی پیشامد a است. هر شبکه بیزی از سه جزء اصلی تشکیل شده است: مجموعه‌ای از گره‌ها (متغیرهای سامانه مدیریتی)، مجموعه‌ای از بندها (روابط سببی بین متغیرها) و مجموعه‌ای از احتمالات. شکل (۱) نمونه‌ای از گراف شبکه بیزی را به صورت چرخه‌ای و مستقیم نشان می‌دهد.

غیرچرخه‌ای است که در آن گره‌ها در حکم متغیرهای مسئله هستند. ساختار یک شبکه بیزی در واقع یک نمایش نموداری از اثرات متقابل متغیرهایی است که باید الگوبندی شوند، علاوه بر این که کیفیت رابطه بین متغیرهای مسئله را نشان می‌دهد، کمیت ارتباط بین این متغیرها را نیز به نمایش می‌گذارد. این روش بر مبنای محاسبات احتمالات شرطی (قانون بیز)^۱ است. معادله (۷) رابطه بیز را نشان می‌دهد:

$$p(a|b) = \frac{p(b|a) \cdot p(a)}{p(b)} \quad \text{رابطه (۷)}$$



شکل ۱- نمایش گراف چرخه‌ای و مستقیم شبکه بیزی.

کل^۲ به دست می‌آید. احتمالات مرتبط با بخش‌های بالایی شبکه بر اساس قانون بیز می‌باشند. شکل (۲) مراحل ساخت و توسعه الگوی شبکه بیزی را به صورت خلاصه بیان می‌کند (۱۷). با استفاده از نرم‌افزار GenIE 2.0 ساختار شبکه بیزی تشکیل و نتایج این تحقیق حاصل شده است.

در حالت کلی، گره‌ها یا والد^۳ هستند یا ولد (فرزند)^۴، یک گره فرزند می‌تواند از سوی چندین والد تولید شده باشد، گره‌هایی که قبل از آنها گره دیگری در گراف وجود دارد با توزیع احتمال شرطی^۴ تعریف می‌شوند، در غیر این صورت با احتمال آغازین^۵ (اولیه) بیان می‌شوند. پایین‌ترین بخش در شبکه بیزی از طریق قانون احتمال

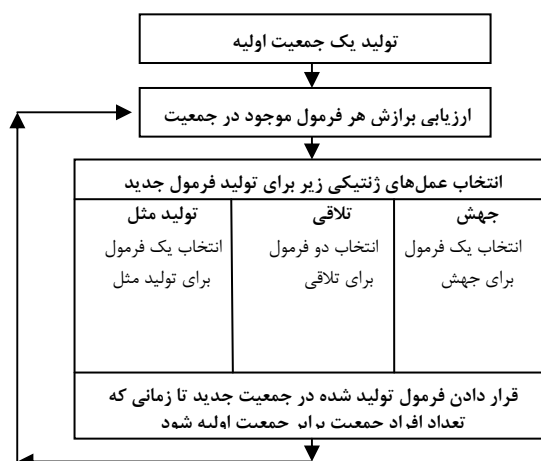


شکل ۲- نمایش مراحل ساخت و توسعه شبکه بیزی.

ثابت تصادفی)، ۲- مجموعه عملگرهای ریاضی مورد استفاده در فرمول‌ها، ۳- انتخاب تابع برازش، برای سنجش برازش فرمول‌ها، ۴- تعیین پارامترهای کنترل‌کننده اجرای برنامه، ۵- معیار پایان و ارائه نتایج اجرای برنامه (مثل، تعداد تولید جمعیت جدید، تعیین یک مقدار مشخص برای برازش فرمول‌ها که اگر میزان برازش برابر یا بیش‌تر از آن مقدار شد، اجراء متوقف شود. طرح کلی گام‌های اجرایی برنامه‌ریزی بیان ژن در شکل (۳) نشان داده شده است. برای اطلاعات بیش‌تر در این مورد می‌توان به رفرنس (۲۲) مراجعه نمود.

برنامه‌ریزی بیان ژن

برنامه‌ریزی بیان ژن تعمیم یافته الگوریتم ژنتیک است که برای اولین بار بر اساس تئوری داروین ارائه شد. به این ترتیب که جمعیتی در جهت تکامل به صورت انتخابی، جمعیت نامناسب را رها کرده و فرزندان اصلاح شده ایجاد می‌کنند. ساختارهای درختی از مجموعه توابع (عملگرهای ریاضی مورد استفاده در فرمول‌ها) و ترمینال‌ها (متغیرهای مسئله و اعداد ثابت) ایجاد می‌شوند (۱۴). قبل از مراحل اجرایی برنامه‌ریزی بیان ژن گام‌های مقدماتی زیر باید از سوی کاربر تعیین شوند: ۱- مجموعه ترمینال‌ها (متغیرهای مسئله، اعداد




شکل ۳- مروری بر شکل کلی گام‌های اجرایی مدل برنامه‌ریزی بیان ژن (۲۲).

شبکه می‌باشد، لایه خروجی محل استقرار پارامترهای خروجی شبکه و لایه پنهان، لایه‌های ما بین لایه ورودی و خروجی می‌باشند، که نقش پردازشگری اطلاعات را بر عهده دارد.

در این تحقیق در راستای شبیه‌سازی فرآیند بارش- رواناب با مدل برنامه‌ریزی بیان ژن از نرم‌افزار GeneXproTools 4.0 استفاده شد.

شبکه‌های عصبی مصنوعی

در حالت کلی شبکه عصبی شامل سه لایه است شکل (۴). لایه ورودی که وظیفه آن معرفی پارامترها به



شکل ۴- نمای کلی یک شبکه عصبی مصنوعی سه لایه.

پارامترها در شبکه پرسپترون چند لایه از طریق سیگنال خطا و سیگنال ورودی صورت می‌گیرد. تعیین تعداد لایه‌ها و نرون‌های موجود در آنها از مهم‌ترین مسائل در شبیه‌سازی با شبکه عصبی مصنوعی است (۲۰). توکار و جانسون رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی را توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کردند (۲۴).

معیارهای ارزیابی

برای ارزیابی دقت و قابلیت مدل‌ها از نمایه‌های ضریب همبستگی (CC)^۱، ریشه میانگین مربعات خطا (RMSE)^۲ و معیار نش-ساتکلیف (NS)^۳ طبق روابط ۸، ۹ و ۱۰ صورت گرفت. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

یک شبکه عصبی مصنوعی علائم را از واحدهای ورودی دریافت کرده و این سیگنال‌ها در طول شبکه انتشار یافته و در نهایت به سوی نرون خروجی حرکت می‌نمایند. پارامترهای کنترلی اصلی مدل‌های شبکه عصبی مصنوعی مقاومت‌های اتصالی بین نرون‌ها هستند، که وزن‌ها و گرایش‌ها^۱ نامیده می‌شوند. لایه‌های مختلف در شبکه عصبی و نیز نرون‌های موجود در لایه‌ها می‌توانند دارای توابع محرک متفاوت یا یکسانی باشند. شبکه‌های عصبی از نظر ساختار و ارتباطات بین نرون‌ها به گروه‌های مختلفی تقسیم می‌شوند. شبکه پرسپترون چند لایه رایج‌ترین مدل شبکه عصبی استفاده شده در مسائل مهندسی آب می‌باشد که برای آموزش این شبکه از الگوریتم پس انتشار خطا که یک روش یادگیری با ناظر است استفاده می‌شود. تنظیم

1- Bias

2- Correlation Coefficient

3- Root Mean Square Error

4- Nash Sutcliffe

معرفی منطقه و داده‌های مورد استفاده

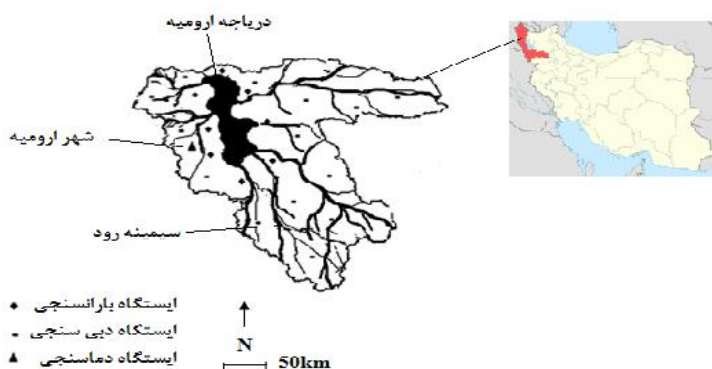
سیمینه‌رود در استان آذربایجان غربی قرار گرفته و یکی از زیر حوزه‌های حوزه آبخیز دریاچه ارومیه می‌باشد. این رودخانه از ارتفاعات اطراف سقز در جنوب دریاچه ارومیه سرچشمه می‌گیرد و در جهت جنوب به شمال جریان دارد. حوزه این رودخانه با مساحت ۷۶۹ کیلومتر مربع در ارتفاع ۱۳۹۴ متری از سطح دریا در عرض جغرافیایی ۲۶° ۳۶' و طول جغرافیایی ۴۵° ۵۶' واقع شده است. در این تحقیق اطلاعات باران سنجی و آبسنجی ماهانه ایستگاه قزل‌گنبد از سال ۱۳۷۷ تا ۱۳۹۰ مورد استفاده قرار گرفته است. در شکل (۵) موقعیت جغرافیایی و نقشه حوزه آبخیز منطقه مورد مطالعه نشان داده شده است. در شکل (۶) نمودار تغییرات بارش و رواناب و در جدول (۱) ویژگی‌های آماری در بازه زمانی (۱۳۷۷-۱۳۹۰) نشان داده شده است.

$$CC = \frac{\sum_{i=1}^N (Q_{oi} - \bar{Q}_o)(Q_{ci} - \bar{Q}_c)}{\sqrt{\sum_{i=1}^N (Q_{oi} - \bar{Q}_o)^2 \sum_{i=1}^N (Q_{ci} - \bar{Q}_c)^2}} \quad \text{رابطه (۸)}$$


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{oi} - Q_{ci})^2} \quad \text{رابطه (۹)}$$

$$NS = 1 - \frac{\sum_{i=1}^N (Q_{oi} - Q_{ci})^2}{\sum_{i=1}^N (Q_{oi} - \bar{Q}_c)^2} \quad \text{رابطه (۱۰)}$$

در روابط بالا Q_{oi} و Q_{ci} به ترتیب مقادیر مشاهداتی و محاسباتی رواناب ماهانه در گام زمانی N ، تعداد داده‌ها، \bar{Q}_o و \bar{Q}_c به ترتیب میانگین مقادیر مشاهداتی و محاسباتی رواناب ماهانه ایستگاه قزل‌گنبد سیمینه‌رود می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی نسبت به زمان جهت مقایسه و تحلیل بیش‌تر استفاده شده است.



شکل ۵- موقعیت حوزه آبخیز منطقه مورد مطالعه.



شکل ۶- مقادیر مشاهداتی بارش و رواناب ماهانه سیمینه رود (۱۳۷۷-۱۳۹۰).

جدول ۱- خصوصیات آماری مقادیر بارش- رواناب ماهانه مورد استفاده در بازه زمانی (۱۳۷۷-۱۳۹۰)

مشخصه‌های آماری	بارش (mm)	دبی (m ³ /s)
تعداد داده‌ها	۱۵۶	۱۵۶
میانگین	۲۷	۶
واریانس	۱۱۱۲	۸۱
حداقل	۰	۰
حداکثر	۱۵۶	۱۳۶
انحراف معیار	۳۳/۳۵	۸/۹۹
واریانس	۱۱۱۲	۸۱
چولگی	۱/۴۴	۲/۳۷
خطای معیار	۲۶/۱۳	۶/۵۱

نتایج و بحث

در این تحقیق به منظور بررسی و مقایسه نتایج مدل‌ها از داده‌های بارش و رواناب ماهانه ایستگاه قزل‌گنبد سیمین‌رود استفاده و داده‌های مهر ۱۳۷۷ تا خرداد ۱۳۸۶ به منظور آموزش مدل‌ها و داده‌های تیر ۱۳۸۶ تا ۱۳۹۰ برای صحت‌سنجی انتخاب گردید. ترکیب‌های مختلفی از ورودی‌ها شامل دبی و بارش هم‌زمان و زمان‌های قبل مورد بررسی قرار گرفت. نهایتاً ترکیب $P(t-3)$ ، $P(t-2)$ ، $P(t-1)$ ، $P(t)$ و $Q(t-1)$ (که به ترتیب بارش در زمان $t-3$ ، $t-2$ ، $t-1$ ، t و رواناب در زمان $t-1$ می‌باشند) ورودی و $Q(t)$ (رواناب در زمان t) خروجی این مدل‌ها در نظر گرفته شد. این ترکیب به دلیل داشتن بیش‌ترین حافظه زمانی و تعداد پارامتر و همچنین تطابق با تعداد و ترکیب‌های ورودی ذکر شده در منابع معتبر (۱) به اضافه $P(t-3)$ لحاظ شده است. در ادامه نتایج حاصل از مدل‌های مورد استفاده ارائه می‌گردد.

مدل ماشین بردار پشتیبان

به منظور شبیه‌سازی جریان از طریق مدل SVM می‌توان انواع تابع کرنل را مورد بررسی قرار داد، که از بین توابع کرنل، کرنل‌های خطی، چندجمله‌ای و تابع

پایه شعاعی - که از انواع رایج مورد استفاده در هیدرولوژی می‌باشند - انتخاب و از طریق سعی و خطا نتایج بهینه این نوع کرنل‌ها محاسبه شد که در جدول (۲) آمده است. با توجه به این نتایج دو نوع کرنل خطی و چندجمله‌ای با ضریب هم‌بستگی $CC=0/895$ و $RMSE=4/180$ m³/s و $NS=0/676$ در مرحله صحت‌سنجی عملکرد تقریباً یکسانی داشته و تابع پایه شعاعی (RBF) با بیش‌ترین میزان ضریب هم‌بستگی $CC=0/825$ و کم‌ترین میزان ریشه میانگین مربعات خطا $RMSE=4/159$ m³/s و $NS=0/679$ جهت شبیه‌سازی رواناب جواب بهینه‌تری را به همراه داشته است، که این نتیجه دلیل استفاده از این نوع کرنل در شبیه‌سازی بارش- رواناب را از سوی هیدرولوژیست‌ها نشان می‌دهد. با وجود این که در بسیاری از تحقیقات هیدرولوژی فقط از این نوع کرنل استفاده می‌شود اما بهتر است که هر سه مورد بررسی قرار گیرند زیرا با توجه به تحقیق باتسیس و همکاران که دقیقاً برای مدل‌سازی بارش- رواناب انجام شده است ماشین بردار پشتیبان با تابع کرنل خطی از دقت بیش‌تری برخوردار بوده است (۲).

جدول ۲- نتایج سه نوع کرنل استفاده شده در مدل SVM برای داده‌های مرحله آموزش و صحت‌سنجی

کرنل	آموزش			صحت‌سنجی		
	NS	RMSE (m ³ /s)	CC	NS	RMSE (m ³ /s)	CC
چند جمله‌ای	۰/۵۴۶	۶/۳۵۴	۰/۷۴۹	۰/۶۷۶	۴/۱۸۰	۰/۸۲۲
خطی	۰/۵۴۶	۶/۳۵۵	۰/۷۴۹	۰/۶۷۶	۴/۱۸۱	۰/۸۲۲
تابع پایه شعاعی	۰/۵۴۶	۶/۳۵۴	۰/۷۴۱	۰/۶۷۹	۴/۱۵۹	۰/۸۲۵


شبکه بیزی

از مزیت‌های عمده این روش مدل‌سازی، می‌توان به سادگی استفاده آن‌ها بعد از طراحی و واسنجی اشاره نمود که از سوی یک کاربر نیمه ماهر نیز می‌تواند برای شبیه‌سازی مورد استفاده قرار گیرد. در این تحقیق با فرض وابستگی رواناب به رواناب و بارش روزهای قبل با استفاده و انتخاب الگوریتم یادگیری PC^۱ (با انتخاب سطح معنی‌داری ۵ درصد) برای آموزش ساختاری شبکه، ساختار شبکه با توجه به تأثیر پارامترها روی

یکدیگر، به صورت شکل (۷) تشکیل شد و جهت فلش‌ها نشان‌دهنده تأثیر یک گره بر گره دیگر می‌باشد، مثلاً جهت خط ارتباطی $Q(t-1)$ به سمت $Q(t)$ نشان‌دهنده تأثیرپذیری رواناب از رواناب روز قبل می‌باشد، هدف اصلی از این روش یافتن ارتباط بین رواناب و مشخصه‌های تأثیرگذار بر آن می‌باشد، لذا رابطه (۱۱) حاصل شد.

رابطه (۱۱)

$$Q(t) = 0.0169268 * P(t-3) - 0.0181073 * P(t-2) + 0.0365877 * P(t-1) + 0.139917 * P(t) + 0.36635 * Q(t-1) + \text{Normal}(-1.14677, 6.35126)$$



شکل ۷- ساختار شبکه بیزی به کار رفته برای شبیه‌سازی بارش- رواناب.

صادقی حصار و همکاران نیز قابلیت این مدل را در زمینه پیش‌بینی بارش ماهانه به اثبات رسانده‌اند (۱۹). لذا می‌توان این مدل را برای توسعه مدل‌های پیش‌بینی در مطالعات منابع آب مورد استفاده قرار داد.

جدول ۳ نتایج مرحله صحت‌سنجی حاصل از شبیه‌سازی با روش شبکه بیزی می‌باشد، که این نتایج نشان می‌دهد این شبکه توانسته است رواناب منطقه مورد مطالعه را با دقت مناسبی شبیه‌سازی نماید.

جدول ۳- نتایج حاصل از شبکه تصمیم بیزی

مرحله	NS	RMSE (m ³ /s)	CC
آموزش	۰/۵۴۲	۶/۴۲۷	۰/۷۴۲
صحت سنجی	۰/۶۵۲	۴/۳۹۵	۰/۸۲۴

برنامه‌ریزی بیان ژن

در شبیه‌سازی فرآیند بارش- رواناب حوزه سیمینه‌رود با استفاده از برنامه‌ریزی بیان ژن به دلیل این که این مدل دارای توان انتخاب متغیرهای مؤثر در مدل و حذف متغیرهایی است که تأثیر کم‌تری دارند، می‌باشد. لذا در این تحقیق هر پنج ورودی بارش و رواناب شامل $P(t)$, $P(t-1)$, $P(t-2)$, $P(t-3)$ و $Q(t-1)$ برای تعیین متغیرهای معنی‌دار استفاده و برای بررسی بیش‌تر علاوه بر مجموعه عملگرهای ریاضی پیش فرض برنامه (F_1)، حالت‌هایی بر اساس مقادیر چهار عملگر اصلی (F_2) و مجموعه عملگرهای F_3 و F_4 لحاظ شده است:

رابطه (۱۲)

$$F_1: \{+, -, *, /, \sqrt{}, \exp, \ln, x^2, x^3, \sqrt[3]{}, \sin, \cos, \text{atan}\}$$

رابطه (۱۳)

$$F_2: \{+, -, *, /\}$$

رابطه (۱۴)

$$F_3: \{+, -, *, /, x^2\}$$

رابطه (۱۵)

$$F_4: \{+, -, *, /, x^3\}$$

پارامترهای مورد استفاده و نرخ آنها در استخراج مدل‌های شبیه‌سازی برای فرآیند بارش- رواناب با استفاده از روش برنامه‌ریزی بیان ژن به طور خلاصه در جدول (۴) ارائه شده است.

جدول ۴- مقادیر پارامترهای مورد استفاده با استفاده از روش برنامه‌ریزی بیان ژن

عملگرهای ژنتیکی	تنظیمات کلی
۰/۰۴۴	تعداد کروموزوم‌ها
۰/۱	اندازه راس
۰/۱	تعداد ژن‌ها در هر کروموزوم
۰/۱	تعداد جمعیت تولیدی
۰/۳	تابع پیوند
۰/۳	تابع برازش
۰/۱	معیار خطا
۰/۱	نرخ جهش
۰/۱	نرخ وارون سازی
۰/۱	نرخ ترانهش درج متوالی
۰/۳	نرخ ترانهش ریشه درج متوالی
۰/۳	نرخ ترکیب تک نقطه ایی
۰/۳	نرخ ترکیب دو نقطه ایی
۰/۱	نرخ ترکیب ژن
۰/۱	نرخ ترانهش ژن

رواناب با استفاده از مدل برنامه‌ریزی بیان ژن را نشان می‌دهد. نتایج حاصل از مدل برنامه‌ریزی بیان ژن با عملگرهای به کار گرفته شده در جدول (۶) آمده است. اگرچه سلطانی و همکاران در شبیه‌سازی فرآیند بارش- رواناب روزانه ليقوان، استفاده از مجموعه عملگر

روابط نهایی حاصل از چهار مجموعه از عملگرهای ریاضی تعریف شده برای حوزه سیمینه‌رود در جدول (۵) اهمیت هر یک از پارامترهای ورودی در شبیه‌سازی را مشخص می‌نماید، که روابط این جدول تأثیر پارامترهای $P(t)$, $P(t-1)$ و $Q(t-1)$ در شبیه‌سازی

داشتن ساختار ساده ریاضی و سهولت محاسبه، با کمترین ضریب همبستگی $CC=0/823$ و بیشترین ریشه میانگین مربعات خطا $RMSE=4/23 \text{ m}^3/\text{s}$ و $NS=0/671$ عملکرد ضعیفتری داشته است. بنابراین در تحقیقات باید بررسی شود که کدام مجموعه عملگر نتیجه بهینه این مدل را سبب می‌شود.

ریاضی اصلی را نسبت به مجموعه عملگر پیش فرض برنامه F_1 بهتر دانسته‌اند (۲۲)، اما در تحقیق حاضر عملگر F_1 با بیشترین ضریب همبستگی $CC=0/911$ و کمترین ریشه میانگین مربعات خطا $3/107 \text{ m}^3/\text{s}$ و $RMSE=0/822$ و $NS=0/822$ در مرحله صحت‌سنجی نسبت به سایر عملگرها از دقت بیشتری برخوردار است، این در حالی است که F_2 (مجموعه چهار عملگر اصلی) با وجود

جدول ۵- معادلات برنامه‌ریزی بیان ژن برای چهار مجموعه عملگر ریاضی انتخابی

عملگر	معادلات GEP
F_1	$Q(t) = \text{Atan}[(Q(t-1) - P(t)^6) * \sin(-2.46)^2] + \sqrt{P(t)} * Q(t-1) + \sqrt{P(t)}$
F_2	$Q(t) = 0.29Q(t-1) + 0.047P(t-1) + 0.11P(t) + 1.82$
F_3	$Q(t) = Q(t-1) + 11.29Q(t-1) - 0.96P(t)$
F_4	$Q(t) = -0.79Q(t-1) + 0.12P(t) + 0.8$

جدول ۶- نتایج روش برنامه‌ریزی بیان ژن با استفاده از چهار مجموعه عملگر ریاضی

عملگر	آموزش			صحت سنجی		
	NS	RMSE (m^3/s)	CC	NS	RMSE (m^3/s)	CC
F_1	۰/۵۴۹	۶/۳۴۶	۰/۷۴۴	۰/۸۲۲	۳/۱۰۷	۰/۹۱۱
F_2	۰/۵۴۰	۶/۴۰۲	۰/۷۳۷	۰/۶۷۱	۴/۲۳۰	۰/۸۲۳
F_3	۰/۵۳۱	۶/۴۵۷	۰/۷۲۹	۰/۶۸۶	۴/۱۱۴	۰/۸۳۱
F_4	۰/۵۳۱	۶/۴۵۷	۰/۷۳۱	۰/۷۱۲	۳/۹۴۰	۰/۸۴۴

شبکه‌های عصبی مصنوعی

به منظور شبیه‌سازی فرآیند بارش- رواناب حوزه سیمینه‌رود از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چندلایه با تعداد نرون‌های متفاوت و نیز توابع محرک مختلف استفاده شده است. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم لونیگ- مارکوارت به دلیل همگرایی سریع‌تر در آموزش شبکه استفاده گردید. تعداد تکرارهای لازم در

فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آن که تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. نتایج حاصل از فرآیند مدل‌سازی در جدول (۷) ارائه شده است.

جدول ۷- ساختار و توابع محرک بهینه شبکه‌های عصبی و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

شماره	ساختار	تابع محرک		آموزش		تست	
		لایه (های) پنهان	لایه خروجی	NS	RMSE (m^3/s)	NS	RMSE (m^3/s)
۱	۵-۲-۱	سیگموئید	سیگموئید	۰/۵۵۶	۶/۲۸۲	۰/۷۴۶	۴/۱۰۹
۲	۵-۲-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۳۶	۵/۶۹۱	۰/۷۹۸	۳/۵۹۸
۳	۵-۵-۱	سیگموئید	سیگموئید	۰/۵۶۸	۶/۲۰۰	۰/۷۵۳	۴/۰۵۵
۴	۵-۵-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۵۱	۵/۵۶۸	۰/۸۰۷	۳/۶۰۸
۵	۵-۷-۱	سیگموئید	سیگموئید	۰/۵۵۷	۶/۲۷۷	۰/۷۴۶	۴/۱۲۵
۶	۵-۷-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۳۹	۵/۶۶۴	۰/۸۰۰	۳/۵۳۸
۷	۵-۲-۲-۱	تانژانت هیپربولیک	سیگموئید	۰/۵۶۵	۶/۲۲۰	۰/۷۵۲	۴/۲۷۲
۸	۵-۵-۵-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۵۵	۵/۵۳۸	۰/۸۰۹	۳/۶۸۷
۹	۵-۷-۷-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۴۷	۵/۶۰۵	۰/۸۰۴	۳/۵۲۵
۱۰	۵-۱۰-۱۰-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۴۱	۵/۶۵۲	۰/۸۰۱	۳/۳۵۹
۱۱	۵-۱۱-۱۱-۱	تانژانت هیپربولیک	سیگموئید	۰/۶۵۵	۵/۵۳۹	۰/۸۰۹	۳/۶۵۹

مقایسه عملکرد مدل‌ها

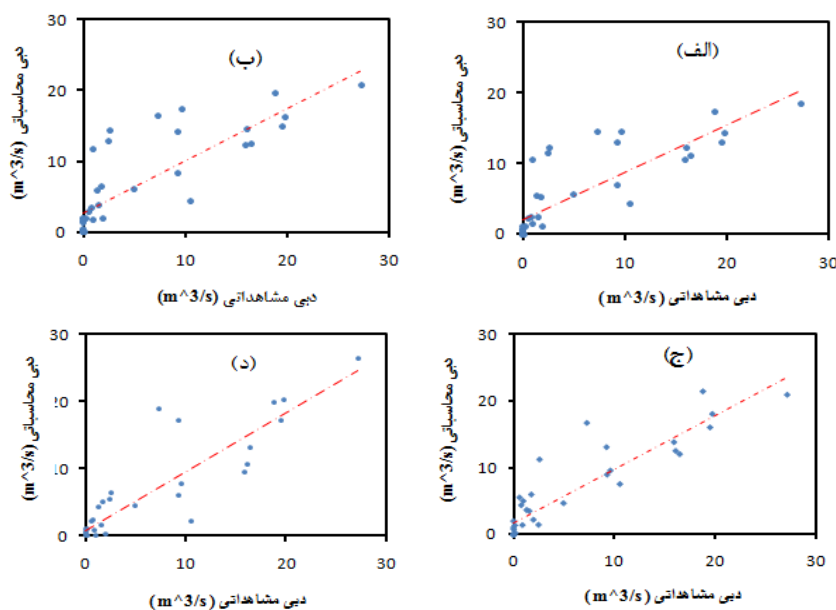
در ادامه با انتخاب جواب بهینه هر مدل و مقایسه آنها با یکدیگر مشخص شد که هر چهار مدل شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن، ماشین بردار پشتیبان و شبکه بیزی به ترتیب با ضریب همبستگی ۰/۸۹۵، ۰/۹۱۱، ۰/۸۲۵ و ۰/۸۲۴ و ریشه میانگین مربعات خطای ۳/۳۵۹، ۳/۱۰۷، ۴/۱۵۹ و ۴/۳۹۵ و ضریب نش‌ساتکلیف ۰/۷۹۱، ۰/۸۲۲، ۰/۶۷۹ و ۰/۶۵۲ با دقت قابل قبولی فرآیند بارش - رواناب حوزه سیمینه‌رود را شبیه‌سازی کرده‌اند. همان‌طور که در جدول (۸) مشاهده می‌شود از بین این مدل‌ها برنامه‌ریزی بیان ژن با بیش‌ترین دقت $CC=0/911$ و کم‌ترین ریشه میانگین مربعات خطا $RMSE=3/107$ m^3/s و $NS=0/822$ در مرحله صحت‌سنجی در مقایسه با سایر مدل‌ها بهترین نتیجه شبیه‌سازی فرآیند بارش - رواناب را دارا می‌باشد. در شکل (۸) میزان تطابق مقادیر مشاهداتی با مقادیر محاسباتی بهینه هر چهار مدل و قرار گرفتن بیش‌تر نقاط مدل برنامه‌ریزی بیان ژن روی یا نزدیکی خط نیم‌ساز دقت بیش‌تر این مدل در شبیه‌سازی بارش - رواناب را نشان می‌دهد.

ابتدا با در نظر گرفتن سه لایه و تغییر تابع محرک لایه پنهان به تانژانت هیپربولیک دقت و همبستگی افزایش و با تغییر تعداد نرون‌های این لایه به ۷، کاهش یافت. بیش‌ترین ضریب همبستگی $CC=0/886$ و کم‌ترین ریشه میانگین مربعات خطا $3/608$ m^3/s مربوط به ساختار شماره (۴) می‌باشد. در حالیکه با اضافه نمودن یک لایه پنهان به شبکه و انتخاب توابع محرک تانژانت هیپربولیک و تعداد ۵، ۲، ۷، ۱۰ و ۱۱ نرون برای هر کدام از لایه‌های پنهان و تابع محرک سیگموئید برای لایه خروجی، ساختار شماره (۱۰) با بیش‌ترین ضریب همبستگی $CC=0/895$ و کم‌ترین ریشه میانگین مربعات خطا $3/359$ m^3/s و $RMSE=0/791$ و $NS=0/791$ در مرحله صحت‌سنجی از بین تمام ساختارهای سه و چهار لایه عملکرد بهتری از خود نشان داد.

در تحقیق انجام شده از سوی صف‌شکن و همکاران علاوه بر این که برتری شبکه عصبی مصنوعی با انتخاب تابع تانژانت هیپربولیک و سیگموئید نشان داده شده است، دقت بالای آن در تخمین دبی حداکثر نیز به اثبات رسیده است (۲۰).

جدول ۸- نتایج نهایی چهار مدل ماشین بردار پشتیبان، شبکه عصبی، برنامه‌ریزی بیان ژن و شبکه بیزی


مدل	آموزش			صحت سنجی		
	NS	RMSE (m^3/s)	CC	NS	RMSE (m^3/s)	CC
SVM	۰/۵۴۶	۶/۳۵۴	۰/۷۴۱	۰/۶۷۹	۴/۱۵۹	۰/۸۲۵
BN	۰/۵۴۲	۶/۴۲۷	۰/۷۴۲	۰/۶۵۲	۴/۳۹۵	۰/۸۲۴
GEP	۰/۵۴۹	۶/۳۴۶	۰/۷۴۴	۰/۸۲۲	۳/۱۰۶	۰/۹۱۱
ANN	۰/۶۴۱	۵/۶۵۲	۰/۸۰۱	۰/۷۹۱	۳/۳۵۹	۰/۸۹۵



شکل ۸- نمودار پراکنش مقادیر مشاهداتی - محاسباتی مرحله صحت‌سنجی: الف) ماشین بردار پشتیبان، ب) شبکه بیزی، ج) برنامه‌ریزی بیان ژن و د) شبکه عصبی مصنوعی.

مدل‌سازی مقادیر حداکثر عملکرد خوبی به همراه نداشته و با اختلاف زیاد به صورت کم تخمین عمل نموده است؛ بنابراین، این برتری نسبی بوده و در پیش‌بینی‌های مهم به ویژه سیلاب باید مدنظر قرار گرفته شود. مدل‌های ماشین بردار پشتیبان و شبکه بیزی در تخمین مقادیر حدی عملکرد مشابهی داشته‌اند.

شکل ۹ نیز نشان می‌دهد مدل بهینه چهار لایه شبکه عصبی مصنوعی در شبیه‌سازی مقادیر حدی، بویژه حداکثر نسبت به هر چهار مدل بهتر عمل کرده است و توانسته است دبی اوج را به خوبی مدل‌سازی نماید و مدل برنامه‌ریزی بیان ژن با وجود دقت بیش‌تر در مدل‌سازی بارش- رواناب منطقه مورد مطالعه در



شکل ۹- نمودار رواناب مشاهداتی و محاسباتی چهار مدل ماشین بردار پشتیبان، شبکه بیزی، برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی.

نتایج به دست آمده با تحقیق آیتک و همکاران (۱) که در شبیه‌سازی بارش- رواناب برنامه‌ریزی بیان ژن را بهتر از عصبی دانسته‌اند مطابقت دارد. عملکرد شبکه عصبی مصنوعی بهتر از ماشین بردار پشتیبان بود، این در حالی است که یون و همکاران (۲۵) در پیش‌بینی تغییرات سطح آب زیرزمینی عکس این مساله را به اثبات رسانده بودند، که این امر می‌تواند به دلیل تغییر در ماهیت پدیده مورد مطالعه باشد. تا به حال قابلیت بالای شبکه بیزی به اثبات رسیده ولی تحقیقی که در آن شبکه بیزی با سایر مدل‌ها مقایسه شده باشد، مشاهده نشده است. لذا می‌توان این چهار مدل را در بخش‌های مختلف هیدرولوژی به کار برده و با توجه به ماهیت مساله تطابقات و یا اختلافات را مشاهده و دلیل آن را مورد بررسی قرار داد.

در این تحقیق فرآیند بارش- رواناب ماهانه سیمینه‌رود در دوره آماری (۱۳۷۷-۱۳۹۰) با استفاده از مدل‌های ماشین بردار پشتیبان، شبکه بیزی و همچنین مدل‌های متداول شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن شبیه‌سازی شده و نتایج آنها مورد مقایسه قرار گرفته است. با توجه به این که چهار مدل مورد مطالعه تا به حال به صورت مجزا یا دو به دو در مسائل هیدرولوژی مورد بررسی قرار گرفته‌اند، نتایج حاصل از بررسی عملکرد این مدل‌ها در کنار یک‌دیگر نشان می‌دهد هر چهار مدل در شبیه‌سازی فرآیند بارش- رواناب مورد قبول می‌باشند. برنامه ریزی بیان ژن به عنوان مدل برتر، شبکه عصبی مصنوعی بعد از آن و ماشین بردار پشتیبان و شبکه بیزی با اختلاف کمی در اولویت‌های بعدی قرار گرفتند.

منابع

1. Aytek, A., M. Asce and M. Alp. 2008. An Application of Artificial Intelligence for Rainfall-Runoff Modeling. Journal of Earth System Science. 117: 145-155.
2. Botsis, D., P. Latinopoulos and K. Diamantaras. 2011. Rainfall-Runoff Modeling Using Support Vector Regression and Artificial Neural Networks. 12th International Conference on Environmental Science and Technology (CEST2011), Rhodes, Greece, 8-10 September.
3. Carmona, G.J., L. Molina, J. Bromley, C. Varela-Ortega and J.L. Garcia-Arostegui. 2011. Object-Oriented Bayesian Network for Participatory Water Management: Two Case Studies in Spain Journal of Water Resources Planning and Management. 137: 366-376.
4. Dibike, Y.B., S. Velikov, D. Solomatine and M.B. Abbott. 2001. Model Induction with of Support Vector Machines: Introduction and Applications Journal of Computing in Civil Engineering. 15: 208-216.
5. Eskandari, A., R. Noori, H. Meeraji and A. Kiaghaderi. 2011. Development of an Appropriate Model Based on Artificial Neural Network and Support Vector Machine to predict the 5-Day Biochemical Oxygen Demand while. Ecology. 38: 71-82.
6. Farbodfam, N., M.A. Ghorbani and M.T. Aalami. 2010. Stream Flow Forecasting Using Genetic Programming Planning. Journal of Agricultural Knowledge. 19: 107-123.
7. Farmani, R., H.J. Henriksen and D. Savic. 2009. An Evolutionary Bayesian Belief Network Methodology for Optimum Management of Groundwater Contamination. Environmental. Modelling & Software, 24: 303-310.

8. Ghorbani, M.A., R. Khatibi, H. Asadi and P. Yousefi. 2012. Inter-Comparison of an Evolutionary Programming Model of Suspended Sediment Time-Series with Other Local Models. In: V. Sebastian (Ed.), Genetic Programming-New Approaches and Successful Applications, In Tech, DOI: 10.5772/47801. 255-284.
9. Ghorbani, M.A., V.P. Singh, R. Daneshfaraz and M. Hasanpour Kashani. 2012. Modelling Pan Evaporation Using Genetic Programming. *Journal of Statistics: Advances in Theory and Application*, 8: 15-36.
10. Jayawardena, A.W., N. Muttill and T.M.K.G. Fernando. 2005. Rainfall-Runoff Modeling Using Genetic Programming. International Congress on Modeling and Simulation Society of Australia and New Zealand December 2005, 1841-1847.
11. Khatibi, R., L. Naghipour, M.A. Ghorbani, M.S. Smith, V. Karimi, R. Farhoudi, H. Delafuz and H. Arvanaghi. 2012. Developing a Predictive Tropospheric Ozone Model for Tabriz. *Atmospheric Environment*, 68: 286-294.
12. Khatibi, R., L. Naghipour, M.A. Ghorbani and M.T. Aalami. 2012. Predictability of Relative Humidity by Two Artificial Intelligence Techniques Using Noisy Data from Two Californian Gauging Stations. *Neural Computing and Application*, 13: 643-941.
13. Khatibi, R., M.A. Ghorbani, M.T. Aalami, K. Kasim, O. Makarynskyy, D. Makarynskyy and M. Alinezhad. 2011. *Ocean Dynamic*, 61: 1797-1807.
14. Koza, J.R. 1992. Genetic Programming: On the Programming of Computers by Means of Natural Selection. Cambridge. MIT Press. ISBN 0-262-11170-5, 813 pp.
15. Mediero, L.L. Garrote and F. Martin-Carrasco. 2007. A Probabilistic Model to Support Reservoir Operation Decisions during Flash Floods. *Hydrological Sciences Journal*, 52: 523-537.
16. Misra, D.T. Oommen, A. Agarwal and S.K. Mishra. 2009. Application and Analysis of Support Vector Machine Based Simulation for Runoff and Sediment Yield Bios stems Engineering. 103: 527-535.
17. Mohajerani, H. and M. Kholghi. 2013. Aquifer Based on Bayesian Network is a Management Decision. *Journal of Water and Soil*, 26: 1522-1534.
18. Noori, R., A. Khakpoor, M. Dehghani and A. Farrokhnia. 2012. Monthly Flow Forecasting Using Support Vector Machine Based on Principal Component Analysis. *Water and Waste*, 1: 118-123.
19. Sadeghi Hesar, A., H. Tabatabaee and M. Jalali. 2012. Monthly Rainfall Forecasting Using Bayesian Belief Network. *International Research Journal of Applied and Basic Sciences*, 3: 2226-2231.
20. Safshekan, F., N. Pirmoradian and R. Sharifian. 2012. Hydrograph Simulated Rainfall-Runoff Due to Rainfall Patterns and the Use of Artificial Neural Networks in the Catchment as Kasilian Watershed Management Science & Engineering, 5: 1-10.
21. Shahbazi, A., B. Zahraei and M. Naseri. 2012. Seasonal Meteorological Drought Prediction Using Support Vector Machine. *Water and Waste*, 2: 73-85.
22. Soltani, A., M.A. Ghorbani, A. Fakherifard, S. Darbandi and D. Farsadi. 2010. Genetic Programming and Its Application in Rainfall-Runoff Modeling. *Journal of Water and Soil Knowledge*, 20: 61-71.
23. Taheri, H. and M. Ghafouri. 2012. Comparison between Active Learning Method and Support Vector Machine for Runoff Modeling. *Journal of Hydrology and Hydromechanics*. 1: 16-32.
24. Tokar, A.S. and P.A. Johnson. 1999. Rainfall- Runoff Modeling Using Artificial Neural Networks. *Journal of Hydrology Engineering*, 3: 232-239.
25. Yoon, H., S.C. Jun, Y. Hyun, G.O. Bae and K.K. Lee. 2011. A Comparative Study of Artificial Neural Networks and Support Vector Machines for Predicting Groundwater Levels in a Coasta Laquifer *Journal of Hydrology*, 396: 128-138.

Comparison of the Performance of Support Vector Machine with other Intelligent Techniques to Simulate Rainfall-Runoff Process

Mohammad Ali Ghorbani¹, Atefe Azani² and Leyla Naghipour³

1- Associate Professor, Tabriz University (Corresponding author: ghorbani@tabrizu.ac.ir)

2 and 3- M.Sc. Student and M.Sc., Tabriz University

Received: August 3, 2013

Accepted: December 11, 2013

Abstract

Simulation of rainfall-runoff process is a major step in water engineering studies and water resources management. In this study, the rainfall-runoff process of the Siminehroud monthly (1377-1390) were simulated using Support Vector Machines (SVM) with Radial Basis kernel Function, Polynomial and linear Bayesian Network (BN) with a PC Learning Algorithm, also conventional methods such as Artificial Neural Networks (ANNs) and Gene Expression Programming (GEP) were used; finally, the results were compared with each other. Correlation Coefficient (CC), Root Mean Square Error (RMSE) and Nash-Sutcliff coefficient (NS) were used to evaluate the performance of the models. The results indicate the acceptable performance of the models and GEP model shows the highest CC (CC = 0.91), minimum RMSE (RMSE = 1.3 m³/s) and NS = 0.82 in verification stage.

Keywords: Artificial Neural Networks, Bayesian Networks, Gene Expression Programming, Rainfall-Runoff, Siminehroud, Support Vector Machine