

علوم و تکنولوژی محیط زیست، دوره بیست و دوم، شماره چهار، تیر ماه ۹۹

مدل سازی جریان روزانه رودخانه با استفاده از فرامدل های شبیه ساز

(مطالعه موردی: رودخانه گاماسیاب)

معصومه زینعلی^۱

محمدرضا گلایی^{*۲}

hamidgolabi65@gmail.com

محمد حسین نیک سخن^۳

محمدرضا شریفی^۴

تاریخ پذیرش: ۹۷/۰۳/۰۲

تاریخ دریافت: ۹۶/۱۰/۰۹

چکیده

زمینه و هدف: هدف در ابتدا بیان نمودن تفاوتها و شناسایی^۳ مدل به نامهای، برنامه ریزی بیان ژن (GEP)، شبکه عصبی - فازی (ANFIS) و شبکه بیزین (BN) است و مقایسه آنها با یکدیگر و سوال اساسی تحقیق این است که آیا فرامدل شبیه ساز برتر در این مطالعه می تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل های مفهومی باشد.

روش بررسی: داده های مورد استفاده برای این پژوهش، داده های بارش و جریان روزانه رودخانه گاماسیاب نهاوند در یک دوره ۱۰ ساله ۱۳۸۱-۱۳۹۱ می باشد. برای مرحله پیش بینی یا شبیه سازی از داده های سال آبی ۱۳۹۱-۱۳۹۰ استفاده شده است.

یافته ها: در مرحله آموزش و با توجه به ضریب تبیین و پارامتر جذر میانگین مربعات خطا و معیار AIC، مشاهده می شود که در هر ۳ مدل، هم در مرحله آموزش و هم در مرحله تست شاهد اختلاف بسیار اندک در مقدار این پارامترها هستیم و نتایج هر ۳ مدل تقریباً با اختلاف بسیار اندک، نزدیک به هم است و تقریباً برتری نسبی مدل GEP را می توان مشاهده کرد.

بحث و نتیجه گیری: نتایج بیانگر آن است که فرامدل^۵ شبیه ساز بیان ژن توانایی خوبی برای شبیه سازی و پیش بینی جریان روزانه رودخانه دارد و این فرامدل شبیه ساز، می تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل های مفهومی باشد. علاوه بر این سرعت اجرای مدل برنامه ریزی بیان ژن نسبت به بقیه مدل ها بیشتر بوده و در زمان کوتاهی قادر به ارائه نتایج بوده است.

واژه های کلیدی: مدل سازی جریان، مدل GEP، مدل ANFIS، مدل BN، گاماسیاب .

۱- دانشجوی دکتری منابع آب، گروه مهندسی آبیاری و آبادانی؛ پردیس کشاورزی و منابع طبیعی دانشگاه تهران؛ کرج؛ ایران.

۲- دکترای منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز، ایران. (نویسنده مسئول)

۳- دانشیار دانشکده محیط زیست، دانشگاه تهران، ایران.

۴- استادیار دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز، ایران.

Modeling Daily River Flow Using Simulator Meta-Models

(Case study: Gamasiab River)

Masoumeh Zeinali¹

Mohammad Reza Golabi²

hamidgolabi65@gmail.com

Mohammad Hossien Niksokhan³

Mohammad Reza Sharifi⁴

Accepted: 2018.05.23

Received: 2017.12.30

Abstract

Background and Aim: The aim is first to express the differences and identify three models, namely, Gene Expression Programming (GEP), Neural-Fuzzy Network (ANFIS), and Bayesian Network (BN), and compare them with each other. Furthermore, the research's central question is whether the superior simulation meta-modal in this study can be a suitable alternative to conceptual models in the conditions of lack of data and information.

Methods: The data used for this study are the daily rainfall and flow data of the Gamasiab Nahavand River in 10 years from 2002 to 2012. For the prediction or simulation stage, the data of the blue year 2012-2011 have been used.

Results: In the training phase and according to the coefficient of explanation and the square root of the mean squares error and the AIC criterion, it is observed that in all three models, both in the training phase and in the test phase, we see a minimal difference in the amount of these parameters. Moreover, all three models' results are close to each other with almost a minimal difference, and almost the relative superiority of the GEP model can be seen.

Discussion & Conclusion: The results indicate that the simulator meta-model of gene expression has an excellent ability to simulate and predict the river's daily flow, this simulation meta-model can be a suitable alternative to models in the absence of data and information. Be conceptual. Also, the speed of implementation of the gene expression programming model was faster than other models and was able to provide results in a short time.

Keywords: Flow Modeling, GEP Model, ANFIS Model, BN Model, Gamasiab

1- Ph.D. Candidate Water Resources, Department of Irrigation & Reclamation Engineering, Faculty of Agricultural Engineering & Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

2- PhD in Water Resources, Faculty of Water Science Engineering, Shahid Chamran University of Ahvaz, Iran. (Corresponding Author)

3- Associate Professor, Faculty of Environment, University of Tehran, Iran.

4- Assistant Professor, Faculty of Water Science Engineering, Shahid Chamran University of Ahvaz, Iran.

مقدمه

بهره برداری بهینه و مناسب از منابع آب یکی از وظایف مهم مدیران منابع آب است. از طرف دیگر عدم تخمین مناسب رواناب حاصل از بارش در حوضه های آبریز، مدیریت بهینه منابع آبی و به ویژه مدیریت بهره برداری از مخازن سدها را دچار مشکل می نماید. در این میان مقوله شبیه‌سازی به عنوان راهکاری مناسب جهت تخمین رواناب، نمود پیدا می‌کند. تاکنون مدل‌ها و روش‌های مختلفی برای تخمین و شبیه‌سازی فرآیند بارش- رواناب ارائه شده است که با استفاده از آن‌ها شدت جریان رودخانه‌ها پیش‌بینی می‌شود. برای پیش‌بینی جریان رودخانه، استفاده از مدل‌های آماری، هیدرولیکی و هیدرولوژیکی دارای سابقه‌ای طولانی هستند. در این بین نبود قطعیت و غیرخطی بودن قوی روابط بین متغیرها، مسأله را پیچیده می‌کند. همچنین مدل‌های فیزیکی و مفهومی هیدرولوژیکی به دلیل نیاز به اطلاعات فراوان، پارامترهای گوناگون و واسنجی وقت‌گیر، کمتر مورد توجه قرار گرفته‌اند. به همین دلیل برآورد صحیح و دقیق جریان رودخانه با استفاده از مدل‌های مختلف یکی از موضوعاتی است که در منابع آب مورد بررسی پژوهشگران می‌باشد. این مسئله به عنوان یکی از چالش‌های مدیریت منابع آب در دهه‌های اخیر مطرح بوده است در این راستا استفاده از مدل‌های جدید در این زمینه می‌تواند به مدیریت و برنامه‌ریزی صحیح کمک کند. فرامدل‌های شبیه ساز برنامه ریزی بیان ژن (GEP)، شبکه عصبی - فازی (ANFIS) و شبکه بیزین (BN) از جدیدترین الگوریتم‌های فراکاوشی^۱ هستند که به دلیل دارا بودن دقت کافی، مورد توجه پژوهشگران قرار گرفته‌اند. زیرا با استفاده از آن‌ها، عدم قطعیت‌های موجود را به همراه درک روابط ذاتی میان داده‌ها که ریاضیات کلاسیک قادر به حل آن‌ها نمی‌باشد، می‌توان مدل‌سازی نمود. در زمینه استفاده از مدل‌های یاد شده بالا، برای پیش‌بینی جریان رودخانه می‌توان به مطالعات زیر اشاره نمود:

قربانی و همکاران (۲۰۱۰) عملکرد سه روش برنامه‌ریزی ژنتیک، شبکه عصبی مصنوعی و نروفازی را در روندیابی سیلاب رودخانه قزل ایرماق ترکیه مورد ارزیابی قرار دادند. نتایج این مطالعه نشان داد که از بین سه روش یاد شده مدل برنامه‌ریزی ژنتیک با دقت بیشتری هیدروگراف خروجی را شبیه‌سازی کرده است (۱). داندنمه‌مهر و همکاران (۲۰۱۴) به منظور پیش‌بینی جریان رودخانه در مقیاس ماهانه از روش شبکه‌های عصبی مختلف و برنامه‌ریزی ژنتیک در دو ایستگاه در کشور ترکیه استفاده کردند. نتایج نشان دهنده برتری و کارایی برنامه‌ریزی ژنتیک نسبت به دیگر روش‌های ذکر شده است (۲). شایب^۲ و همکاران (۲۰۱۵) با استفاده از ترکیب برنامه‌ریزی بیان ژن با مدل موجک به پیش بینی رواناب در چهار حوضه از نواحی مختلف جهان که داده‌های بارش و رواناب داشتند، پرداختند. نتایج نشان داد که ترکیب برنامه‌ریزی بیان ژن با مدل موجک Dmey عملکرد بهتری نسبت به برنامه‌ریزی بیان ژن به تنهایی دارد (۳).

کریمی و همکاران (۲۰۱۵) پیش‌بینی کوتاه‌مدت و بلندمدت جریان رودخانه فلیوس^۳ در ترکیه را با استفاده از مدل ترکیبی برنامه‌ریزی بیان ژن-موجک مورد بررسی قرار دادند. نتایج نشان داد که مدل ترکیبی عملکرد بهتری نسبت به مدل GEP دارد. آن‌ها همچنین از مدل‌های ARMA^۴، ANN و ANFIS برای مقایسه استفاده کردند. نتایج نشان داد که عملکرد مدل ترکیبی از بقیه مدل‌ها بهتر بوده است (۴). سینگ^۵ و همکاران (۲۰۱۵) به مدل‌سازی رواناب روزانه حاصل از حوضه کاپگری در شرق هندوستان پرداختند. آنها با استفاده از روش نمونه گیری مجدد تعداد لایه‌های پنهان و تعداد نرون‌های بهینه را پیشنهاد دادند و نشان دادند این روش حتی در مرحله آموزش سری‌های زمانی

2- Shoaib

3- Filyos

4- Auto regressive moving average

5- Singh

1- Heuristic

توجه به دقت در مرحله آموزش و تست می‌تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل‌های مفهومی باشد.

مواد و روش‌ها

منطقه مورد مطالعه، رودخانه گاماسیاب است که در غرب کشور، در محدوده استان‌های همدان، کرمانشاه و لرستان واقع شده است. رودخانه گاماسیاب از چشمه‌های کارستی گاماسیاب در ۲۰ کیلومتری جنوب غربی شهر نهاوند و در فاصله اندکی از جاده ارتباطی نهاوند به نورآباد لرستان، از ارتفاع ۱۸۶۰ متری از محلی به نام کوه سنگ سوراخ سرچشمه می‌گیرد. در این پژوهش به بررسی بخشی از حوضه آبریز رودخانه گاماسیاب از قسمت ابتدا تا نقطه ایستگاه وراینه پرداخته شده است. ایستگاه وراینه در موقعیت جغرافیایی ۴۸ درجه و ۲۴ دقیقه و ۱۵ ثانیه طول شرقی و ۳۴ درجه و ۰۴ دقیقه و ۳۲ ثانیه عرض شمالی قرار دارد. این ایستگاه در سال ۱۳۴۸ تأسیس شده است و دارای ارتفاع ۱۷۹۵ متر از سطح دریا با میانگین بارش سالانه دراز مدت ۵۲۱ میلی‌متر می‌باشد. داده‌های مورد استفاده برای این پژوهش، داده‌های بارش و جریان روزانه رودخانه گاماسیاب نهاوند در یک دوره ۱۰ ساله (۱۳۹۱-۱۳۸۱) است. ابتدا داده‌های روزانه از سازمان آب منطقه‌ای همدان دریافت شد، با توجه به این که داده‌ها به صورت کامل موجود بودند، بررسی داده‌ها فقط از نظر داده‌های پرت مورد بررسی قرار گرفته و مشکلات موجود برطرف گردید. با فرض وابستگی جریان رودخانه به جریان روزهای قبل، اقدام به تخمین جریان روز بعد با استفاده از داده‌های بارش و جریان امروز می‌شود. از بین داده‌های ورودی ۷۵٪ (۲۷۳۹ داده) از آنها را برای آموزش مدل و ۲۵٪ (۹۱۳ داده) برای تست مدل انتخاب می‌شود. برای مرحله پیش‌بینی یا شبیه‌سازی از داده‌های سال آبی (۱۳۹۰-۱۳۹۱) استفاده شده است.

شبکه عصبی-فازی (ANFIS)

نظریه مجموعه فازی توسط پروفیسور لطفی‌عسگرزاده مشهور به زاده در سال ۱۹۶۵ پیشنهاد شد و به طور گسترده در بسیاری از

کوتاه مدت نتایج خوبی را ارائه می‌دهد (۵). نوری و کالین^۱ (۲۰۱۶) از مدل شبکه عصبی مصنوعی و SWAT به منظور پیش‌بینی روزانه جریان رودخانه در ۲۹ حوضه آبریز نزدیک اطراف آتلانتا در جنوب شرقی ایالات متحده استفاده کردند. با توجه به نتایج به دست آمده از مدل‌ها و خطای آنها هر دو مدل شبکه عصبی مصنوعی و SWAT عملکرد خوبی برای این هدف داشته‌اند (۶). قربانی و همکارانش (۲۰۱۶) کارایی سه مدل شبکه عصبی بیزین، GEP و SVM را در تخمین رواناب ماهانه رودخانه کاکارضا مقایسه کردند. از میان سه مدل یاد شده، شبکه عصبی بیزین بهترین عملکرد را داشته است (۷). نعیمی کلوزی و همکاران (۲۰۱۷) سه روش شامل مدل درختی، نزدیک‌ترین همسایگی و رگرسیون خطی چند متغیره را برای برآورد آبدی در حوضه‌های آبریز بدون آمار استان گلستان بررسی کردند (۸). معتمدنیا و همکاران (۲۰۱۷) با استفاده از داده‌های هواشناسی و هیدرومتری طی دوره زمانی ۱۳۵۰-۱۳۴۹ تا ۱۳۹۱-۱۳۹۰ رواناب در حوضه آبریز امامه با استفاده از مدل‌های شبکه عصبی پرسپترون چند لایه، تابع پایه شعاعی و سیستم عصبی فازی تطبیقی تخمین زدند. نتایج مطالعه آنها نشان داد از بین مدل‌های یاد شده سیستم عصبی فازی تطبیقی عملکرد بسیار خوبی داشته است و به خوبی می‌تواند رواناب را پیش‌بینی کند (۹).

لذا هدف از این مطالعه در ابتدا بیان نمودن تفاوت‌ها و شناسایی این ۳ مدل و سپس مدل سازی جریان رودخانه گاماسیاب با استفاده از فرامدل‌های شبیه ساز برنامه ریزی بیان ژن (GEP)، شبکه عصبی - فازی (ANFIS) و شبکه بیزین (BN) است که در اکثر مطالعات، با توجه به تعداد زیاد مدل‌های موجود برای شبیه‌سازی، برتری خود را ثابت کرده اند و مقایسه آنها با یکدیگر برای تشخیص این که کدام یک از این فرامدل‌های شبیه ساز نسبت به بقیه برتری دارد و در نهایت پیش بینی جریان رودخانه با استفاده از بهترین مدل انجام می‌شود و سوال اساسی این تحقیق این است که آیا فرامدل شبیه‌ساز برتر در این مطالعه با

مدل‌های دیگر از جمله شبکه عصبی مصنوعی این است که در فرامدل شبیه ساز بیان ژن، ابتدا ساختار (متغیرهای ورودی، هدف و مجموع توابع) تعریف شده و سپس ساختار بهینه مدل و ضرایب طی فرایند آموزش تعیین می‌شوند، در حالی که در شبکه‌های عصبی، فقط ضرایب مدل طی فرایند آموزش حاصل می‌شوند. همچنین این الگوریتم به طور خودکار می‌تواند متغیرهای ورودی که در مدل بیشترین تأثیر را دارند، انتخاب کند. در این روش کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه که در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک ترکیب می‌شوند. اولین مرحله در الگوریتم مدل، تولید جمعیت اولیه از راه حل‌هاست. این امر می‌تواند به وسیله فرآیند تصادفی و یا در نظر گرفتن اطلاعات ورودی درباره مسأله انجام یابد. سپس کروموزوم‌ها به صورت بیان درختی ارائه شده و توسط تابع برازش ارزیابی می‌شوند. در صورت دستیابی به راه‌حل مطلوب و یا رسیدن نسل‌ها به تعداد معین، تکامل متوقف شده و بهترین راه حل ارائه می‌شود. اگر شرایط توقف یافت نشود، نخبه‌گزینی انجام می‌گیرد و باقی راه‌حل‌ها به فرآیندی گزینشی واگذار می‌شوند. این فرآیند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو کیفیت جمعیت نیز به طور نسبی بهبود می‌یابد (۱۵).

فرامدل شبیه ساز بیان ژن نیز همانند الگوریتم ژنتیک و برنامه‌ریزی ژنتیک، یک الگوریتم ژنتیکی است به طوری که از جمعیتی از افراد استفاده می‌کند که آن‌ها را مطابق برازندگی انتخاب می‌کند و تغییرات ژنتیکی را با استفاده از یک یا چند عملگر ژنتیکی اعمال می‌نماید. تفاوت اساسی بین این سه الگوریتم، مربوط به ماهیت افراد آن‌ها می‌باشد، به طوری که در الگوریتم ژنتیک، افراد رشته‌های خطی با طول ثابت (کروموزوم‌ها) و در برنامه‌ریزی ژنتیک، نهاده‌های غیر خطی با اندازه‌ها و اشکال متفاوت (درختان تجزیه) می‌باشند، در حالی که در فرامدل شبیه ساز بیان ژن، افراد به صورت رشته‌های خطی با طول ثابت (ژنوم) یا کروموزوم‌ها) کد گذاری شده و سپس به شکل نهاده‌های غیر

زمینه‌ها استفاده می‌شود (۱۰). این نظریه، ابزاری توانمند و انعطاف‌پذیر برای مدل‌سازی عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی و بیان عبارت‌های زبانی برگرفته از تجربه و دانش بشر در قالب روابط ریاضی به شمار می‌آید. پیچیدگی و عدم قطعیت در سیستم‌های هیدرولوژیکی، کمبود اطلاعات در بسیاری از فرآیندهای هیدرولوژیکی، مبهم و غیر صریح بودن این داده‌ها موجب شد تا استفاده از نظریه فازی در زمینه هیدرولوژی و بارش-رواناب که از اصلی‌ترین فرآیندهای هیدرولوژیکی است، افزایش یابد (۱۰). با وجود این، مشکل اصلی منطق فازی این است که روند سینماتیکی برای یک کنترل کننده فازی وجود ندارد. به عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند، جفت‌های ورودی و خروجی، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. بدین منظور پروفیسور ژانگ و همکاران در سال ۱۹۹۷ مدل سیستم شبکه عصبی- فازی تطبیقی را ارائه کردند که قابلیت ترکیب توانایی دو روش یاد شده را داشت (۱۱).

مدل فازی عصبی تطبیقی براساس تغییر در میزان مقادیر و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. در مدل سیستم استنتاج عصبی فازی تطبیقی از روش استنتاجی تاکاگی سوگونو استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین شوند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیشترین مقدار را داشته باشند. جهت کسب اطلاعات بیشتر با این مدل به منابع (۱۲ و ۱۳) مراجعه شود.

برنامه ریزی بیان ژن (GEP)

برنامه‌ریزی بیان ژن که در ادامه سیر تکاملی مدل‌های هوشمند به وجود آمده است، جزء روش‌های الگوریتم گردشی محسوب می‌شود که مبنای تمامی آنها بر اساس نظریه تکامل داروین استوار است (۱۴). مزیت فرامدل شبیه ساز بیان ژن نسبت به

معیارهای ارزیابی مدل‌ها

برای ارزیابی مدل‌ها از سه معیار، ضریب تبیین (R^2)، جذرمیانگین مربعات خطا (RMSE) و پارامتر نش (NASH) استفاده شد. پارامتر آماری نش در سال ۱۹۷۰ توسط نش و ساتکلیف^۴ معرفی گردید (۲۰). در زیر روابط این معیارها ارائه شده است.

$$RMSE = \sqrt{\frac{\sum(Q_{obs} - Q_{pre})^2}{n}} \quad (1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \quad (2)$$

$$NASH = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \quad (3)$$

در روابط بالا، n: تعداد داده‌ها، Q_{obs} : داده‌های مشاهداتی، \bar{Q} : میانگین داده‌های مشاهداتی، Q_{pre} : داده‌های محاسباتی، Q_{max} : حداکثر داده‌ها، Q_{min} : حداقل داده‌ها می‌باشد. ضریب R^2 میزان انطباق داده‌هایی که توسط مدل به وجود می‌آید و داده‌های واقعی را نشان می‌دهد. RMSE جذرمیانگین مربع خطاهای داده‌های محاسباتی و مشاهداتی را بیان می‌کند. واضح است که هر چه مقدار این عدد کمتر باشد به تبع، آموزش و شبیه‌سازی داده‌ها بهتر صورت گرفته است. همچنین هرچه مقدار پارامتر نش به یک نزدیکتر باشد، نشان دهنده تطابق بیشتر مقادیر شبیه‌سازی شده با مقادیر مشاهداتی است.

بحث و نتایج

نتایج شبکه عصبی- فازی (ANFIS)

برای داشتن مدل‌سازی مناسب باید تک تک توابع عضویت را یک به یک مورد بررسی قرار داد و با توجه به معیارهای ارزیابی مدل

خطی با اندازه‌ها و اشکال متفاوت (یعنی نمایش دیاگرام ساده یا بیان درختی) بیان می‌شوند (۱۶). جهت کسب اطلاعات بیشتر با این مدل به منابع (۱۵ و ۱۶) مراجعه شود.

شبکه بیزین (BN)



روش بیزین نخستین بار در اوایل دهه ۱۹۹۰ به وسیله بنتین و بعدها مک‌کی^۱ (۱۹۹۲) برای شبکه‌های عصبی مصنوعی به کار برده شد و با سرعت به یک ابزار انتخاب برای کاربردهای هوش مصنوعی تبدیل شده است (۱۷). در شبکه‌های بیزین برخلاف شبکه‌های عصبی متداول هدف یافتن یک بردار وزن بهینه نیست، بلکه ارائه عدم قطعیت صریح با توجه به مقادیر وزن به وسیله توزیع احتمال ثانویه است (۱۸). شبکه بیزین^۲، نمایش بامعنی روابط نامشخص بین پارامترها در یک فرآیند می‌باشد و گرافی جهت‌دار غیرحلقوی از گره‌ها، برای نمایش متغیرهای تصادفی و کم‌ان‌ها، برای نمایش روابط احتمالی میان متغیرها به‌شمار می‌رود. مک‌کی (۱۹۹۲) دو سطح از استنتاج‌های بیزی را که می‌تواند در مدل‌سازی شبکه عصبی بیزین^۳ به کار رود تشریح کرده است. اولین سطح شامل استخراج شبکه وزن‌ها می‌باشد. البته با این فرض که ساختار شبکه انتخاب شده صحیح است. سطح دوم شامل مقایسه مدل‌ها و انتخاب مدل است (۱۹). شبکه عصبی بیزین ابزاری مفید جهت تجزیه و تحلیل عدم قطعیت در مدل‌سازی شبکه‌های عصبی مصنوعی و یکی از روش‌های سیستم پشتیبان تصمیم‌گیری است که از یک شکل هوش مصنوعی استفاده کرده و براساس قانون یادگیری شبکه بیزین آموزش دیده و با استفاده از اطلاعات مبهم، ناکافی، متضاد و غیرقطعی هم در گذشته و هم در حال حاضر، پارامترها را به صورت عصب به یکدیگر ارتباط می‌دهد که فعالیت سلسله اعصاب یک شبکه و چگونگی پیوند بین آنها مبنای هوشمندی شبکه را نشان می‌دهد. شبکه‌های عصبی بیزین در حل مسائلی که روابط بین متغیرها به درستی مشخص نباشد، بسیار مفید هستند.

4- Nash and Sutcliffe

1- MacKay
2- Bayesian Network
3- Bayesian Neural Network

تبیین مقادیر مشاهداتی و خروجی مرحله آموزش ۰/۹۲۳۵ می- باشد و نشان از عملکرد خوب مدل در مرحله آموزش است. همچنین ضریب تبیین بین این خروجی و داده‌های مشاهداتی در مرحله تست ۰/۹۰۰۵ می‌باشد که بازهم نشان از عملکرد خوب مدل دارد. شکل (۱) مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز عصبی-فازی در مرحله تست را نشان می‌دهد.

بهترین مدل را انتخاب نمود. با بررسی ترکیب‌های مختلف مدل عصبی فازی و انتخاب هر یک از انواع توابع عضویت مربوط به پارامترهای ورودی و خروجی مدل در نهایت مدلی با تابع عضویت ورودی نوع دوزنقه‌ای (Trapmf) و تابع عضویت خروجی نوع constant کمترین مقدار خطای مرحله تست را داشته و انتخاب شد. مقدار خطای مرحله آموزش و تست به ترتیب برابر ۰/۵۸۴۲ و ۰/۴۹۷۹۱ می‌باشد. بعد از ذخیره سازی مدل، ضریب



شکل ۱- مقایسه نتایج مدل عصبی فازی با مقادیر مشاهده‌ای، مرحله تست.

Figure 1- Comparison of fuzzy neural model results with observational values, test stage.

نتایج برنامه ریزی بیان ژن (GEP)


با استفاده از انواع ترکیب ها از تعداد کروموزومها و تعداد ژن ها و اندازه هد (سر) (جدول ۱) و بررسی ترکیب های مختلف مدل برنامه ریزی بیان ژن با استفاده از معیارهای ارزیابی مدل مانند جذرمیانگین مربعات خطا (RMSE) و ضریب تبیین (R^2)

بهترین مدل با ضریب تبیین ۰/۹۹۳۰ و جذر میانگین مربعات ۰/۵۸۶۷ در مرحله آموزش و ضریب تبیین ۰/۹۰۲۵ و جذر میانگین مربعات ۰/۴۹۳۶ در مرحله تست انتخاب شد. شکل (۲) مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز بیان ژن در مرحله تست را نشان می دهد.


جدول ۱-مقادیر پارامترهای استفاده شده در روش برنامه ریزی بیان ژن

Table 1 - Values of parameters used in gene expression programming method

عملکردهای ژنتیکی		تنظیمات کلی	
۰/۰۴۴	نرخ جهش	۳۰	تعداد کروموزومها
۰/۱	نرخ وارون سازی	۷	اندازه راس
۰/۱	نرخ ترانهش درج متوالی	۳	تعداد ژن در هر کروموزوم
۰/۱	نرخ ترانهش ریشه درج متوالی	۱۰۰۰	تعداد جمعیت تولیدی
۰/۳	نرخ ترکیب تک نقطه ای	مجموع (+)	تابع پیوند



مرحله تست




شکل ۲- مقایسه نتایج مدل برنامه ریزی بیان ژن با مقادیر مشاهده ای، مرحله تست.

Figure 2 - Comparison of gene expression programming model results with observational values, test stage.

نیازی به ساختارهای نسبتاً پیچیده برای گسترش در هر مرحله نخواهد بود. در این شکل مقادیر C مربوط به ضرایب فرامدل شبیه ساز بیان ژن و مقادیر d مربوط به پارامترهای ورودی می باشد که شامل بارش و جریان روز قبل می باشد.

در شکل ۳ ساختار درختی برای ترکیب برتر فرامدل شبیه ساز بیان ژن نشان داده شده است. این ساختار در هر مرحله جمعیت اولیه را به صورت ساختار خطی ساده نشان می دهد و همهی تغییرات فقط بر روی ساختارهای ساده انجام می گیرد، در نتیجه

Sub-ET 1



Sub-ET 2



شکل ۳- ساختار درختی ترکیب برتر مدل برنامه ریزی بیان ژن

Figure 3- Tree structure of the superior composition of the gene expression programming model

مدل مفهومی: در مطالعه حاضر از سری روزانه داده های بارش و جریان به عنوان ورودی های اصلی استفاده شد. حال در تعریف مفهومی برای مدل بیژین این گونه در نظر گرفته شد که، دبی فردا متأثر از دبی روز گذشته و بارش می باشد (شکل ۴).


۳- آموزش شبکه و به دست آوردن رابطه بین داده ها: پس از تشکیل چارچوب و تعریف مدل، نوبت به آموزش شبکه ساخته شده می رسد. در این مرحله با استفاده از ورودی های مختلف (بارش و دبی) در مدل سعی در ایجاد ارتباط بین داده ها شده و شکل ریاضی این ارتباط به دست آمد. حال با ارتباط ریاضی موجود می توان داده مصنوعی تولید کرده و عملکرد مدل را مورد ارزیابی قرار داد.

شبکه بیژین (BN)

مراحل ساخت و توسعه مدل شبکه بیژین در مطالعه حاضر برای مدل سازی جریان روزانه رودخانه گاماسیاب بصورت زیر انجام شد:

۱- تشکیل چارچوب مدل: شامل تعریف متغیرها و روابط موجود بین آنها در سیستم است و معمولاً بر اساس یک مدل مفهومی از سیستمی که قرار است مدل سازی و مدیریت شود، شکل می گیرد. بنابراین ساخت مدل مفهومی، اولین قدم در ساختن مدل بیژین است. در این مطالعه مدل مفهومی بیژین از طریق الگوهای ورودی ساخته شد (شکل ۴).

۲- تعیین نوع ارتباط بین ورودی های مختلف مدل در ساختار



شکل ۴- مدل مفهومی ساخته شده برای شبکه بیزین



Figure 4- Conceptual model made for Bayesian network

مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز بیزین در مرحله تست را نشان می‌دهد.

(۴)

$$Q_2 = -0.00861381 * P_t + 0.961715 * Q_1 + Normal(0.129008, 0.600809)$$

همچنین رابطه ریاضی حاصل از الگوی ورودی به صورت رابطه ۴ به دست آمد. مدل بیزین با ضریب تبیین ۰/۹۱۲ و جذر میانگین مربعات ۰/۵۷۲۱ در مرحله آموزش و ضریب تبیین ۰/۸۹۱۲ و جذر میانگین مربعات ۰/۵۳۱۷ در مرحله تست انتخاب شد. شکل (۵)



شکل ۵- مقایسه نتایج مدل شبکه بیزین با مقادیر مشاهده‌ای، مرحله تست.

Figure 5 - Comparison of Bayesian network model results with observational values, test stage.

مقایسه نتایج مدل های استفاده شده

کمی بین سه مدل از چهار معیار ارزیابی به نام های ضریب تبیین، جذر میانگین مربعات خطا، مقدار آکائیکه و پارامتر نش استفاده شد. نتایج این بررسی در جدول ۲ ارائه شده است.

در این قسمت به منظور این که مقایسه مناسبی بین عملکرد سه مدل صورت گیرد مقایسه کمی صورت گرفته است. برای مقایسه

جدول ۲- مقایسه مدل های استفاده شده در این تحقیق


Table 2 - Comparison of models used in this research

مدل Model	ضریب تبیین R ²		جذرمیانگین مربعات خطا RMSE		مقدار آکائیکه AIC		پارامتر نش NASH	
	آموزش Train	تست Test	آموزش Train	تست Test	آموزش Train	تست Test	آموزش Train	تست Test
ANFIS	۰/۹۲۳۵	۰/۹۰۰۵	۰/۵۸۴۱	۰/۴۹۷۹	۵۴۷۶/۹۲	۱۸۲۴/۶۰	۰/۹۱۲۵	۰/۹۰۰۲
GEP	۰/۹۲۳۰	۰/۹۰۲۵	۰/۵۸۶۷	۰/۴۹۳۶	۵۴۷۶/۹۳	۱۸۲۴/۵۸	۰/۹۱۳۵	۰/۹۰۲۰
BN	۰/۹۱۲	۰/۸۹۱۲	۰/۵۷۲۱	۰/۵۳۱۷	۵۵۴۹/۳۲	۱۸۲۴/۷۳	۰/۸۷۴۲	۰/۸۸۶۲

به بقیه مدل ها دارای برتری نسبی می باشد. بنابراین می توان با مشاهده مقادیر جدول به این نتیجه رسید که برای مدل سازی جریان روزانه رودخانه گاماسیاب عملکرد فرا مدل شبیه ساز بیان ژن با اختلاف بسیار جزئی بهتر از بقیه فرامدل های شبیه ساز است. طبق جدول ۲، برنامه ریزی بیان ژن در رتبه اول و شبکه عصبی- فازی در رتبه دوم و مدل شبکه بیزین در این مطالعه در رتبه سوم قرار می گیرد.

در مرحله بعد از مدل سازی و انتخاب فرا مدل شبیه ساز بیان ژن، هدف پیش بینی مقادیر جریان برای روزهای آتی با استفاده از فرا مدل شبیه ساز بیان ژن می باشد. که نمودار آن در شکل ۶ نشان داده شده است. برای انجام این مرحله از داده های سال آبی ۱۳۸۱-۱۳۸۰ استفاده شده است، همان طور که مشخص است، پیش بینی جریان رودخانه برای یک سال آبی و به مدت ۳۶۵ روز انجام یافته است.

با توجه به جدول ۲ و مقایسه مدل ها مشاهده می شود در مرحله آموزش و با توجه به ضریب تبیین نتایج هر ۳ مدل تقریباً با اختلاف بسیار اندک، نزدیک به هم است و تقریباً برتری نسبی مدل GEP را می توان مشاهده کرد. از طرفی با توجه به پارامتر جذر میانگین مربعات خطا، اگرچه در این جا هم شاهد اختلاف بسیار اندک در مقدار این پارامتر هستیم ولی تقریباً برتری نسبی مدل GEP را می توان مشاهده کرد. بر اساس معیار AIC که هرچه مقادیر آن کمتر باشد، مدل عملکرد بهتری دارد، مشاهده می شود که در هر ۳ مدل، هم در مرحله آموزش و هم در مرحله تست شاهد اختلاف بسیار اندک در مقدار این پارامتر هستیم و همچنان برتری نسبی مدل GEP را می توان مشاهده کرد و بر اساس معیار NASH که هرچه مقادیر این پارامتر به یک نزدیک تر باشد، مدل عملکرد بهتری دارد، مشاهده می شود که مدل ANFIS عملکرد بهتری نسبت به مدل BN داشته است، ولی همچنان مدل GEP نسبت



شکل ۶- مقادیر مشاهداتی و پیش‌بینی شده دبی روزانه رودخانه گاماسیاب، با مدل برنامه‌ریزی بیان ژن

Figure 6- Observational and predicted values of daily discharge of Gamasiab river, with Gene expression planning model

نتیجه‌گیری

در این تحقیق از سه مدل به نام‌های برنامه‌ریزی بیان ژن (GEP)، شبکه عصبی - فازی (ANFIS) و شبکه بی‌زین (BN) جهت مدل‌سازی جریان روزانه رودخانه گاماسیاب استفاده شد. هدف از این مطالعه نشان دادن تفاوت‌های بین سه مدل و همچنین بررسی توانایی آن‌ها برای مدل‌سازی جریان روزانه رودخانه گاماسیاب بوده است. نتایج بیانگر این است که فرامدل شبیه‌ساز بیان ژن عملکرد بهتری نسبت به دو مدل دیگر دارد و همان‌طور که از نمودار مقادیر پیش‌بینی شده مشخص است در داده‌های پیش‌بینی، فصل یا تناوب و همچنین سیکل، به درستی شبیه‌سازی و پیش‌بینی شده و این امر بیانگر آن است که فرامدل شبیه‌ساز بیان ژن توانایی خوبی برای شبیه‌سازی و پیش‌بینی جریان روزانه رودخانه دارد و این فرامدل شبیه‌ساز، با توجه به دقت برآورد در مرحله آموزش و تست می‌تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل‌های مفهومی باشد. علاوه بر این سرعت اجرای مدل برنامه‌ریزی بیان ژن نسبت به بقیه مدل‌ها بیشتر بوده و در زمان کوتاهی قادر به ارائه نتایج است.

منابع

1. Ghorbani, M. A., Kisi, O., Aalinezhad, M. A., 2010. A probe into the chaotic nature of daily stream flow time series by correlation dimension and largest Lyapunov methods. *Applied Mathematical Modelling*. 34(12):4050-4057.
2. DanandehMehr, A., Kahya, E. and Yerdelen, C., 2014. Linear Genetic Programming Application for Successive-Station Monthly Stream Flow Prediction, *Journal of Computers and Geosciences*, 70: 63-72.
3. Shoaib, M., Shamseldin, A. Y., Melville, B. W., and Khan, M. M., 2015. Runoff forecasting using hybrid wavelet gene expression programming (WGEP) approach; *J. Hydrol.* 527: 326-344.
4. Karimi, S., Shiri, J., Kisi, O., and Shiri, A.A., 2015. Short-term and long-term streamflow prediction by using 'wavelet-gene expression'

12. Meshkani, A., Nazemi, A., 2009. Introduction to Data Mining. Ferdowsi University Publishing Institute, Mashhad. 456 pages.
13. Singh, V.P., Translation: Najafi, M.R., 2002. Hydrological systems of rainfall-runoff modeling. Volume 1. University of Tehran Press. First Edition. 578 pages.
14. Danandehmehr, A., Majdzadeh Tabatabai, M. R., 2010. Prediction of Daily Discharge Trend of River Flow Based on Genetic Programming. Journal of Water and Soil. 24(2), 325-333.
15. Ferreira, C., 2006. Gene Expression Programming: Mathematical Modeling by an Artificial Intelligence (Studies in Computational Intelligence). ed n, editor. Springer-Verlag New York, Inc. Secaucus, NJ, USA.
16. Ferreira, C., 2001. Gene expression programming: a new adaptive algorithm for solving problems. Complex Syst, 13:87-129.
17. MacKay, D.J.C., 1992. A Practical Bayesian Framework for Backpropagation Networks " Neural Computation. 4: 48-472.
18. Kingston, G. B., 2005. Lambert M F and Maier H R. Bayesian training of artificial neural networks used for water resources modeling. Water Resources Research. 41(W12409).
19. Nash, J. E., and Sutcliffe, J.V., 1970. River flow forecasting through conceptual models part I — A discussion of principles. Journal of Hydrology. 10 (3), 282–290.
5. Singh, G., Panda, R. K., and Lamers, M., 2015. Modeling of daily runoff from a small agricultural watershed using artificial neural network with resampling techniques, J. of hydroinformatics. vol.17 (1). 56-74.
6. Noori, N., Kalin, L., 2016. Coupling SWAT and ANN models for enhanced daily streamflow prediction, J. of Hydrology. 533: 141–151.
7. Ghorbani, M. A., Dehghani, R., 2015. Application of Bayesian Neural Networks, Support Vector Machines and Gene Expression Programming Analysis of Rainfall - Runoff Monthly (Case Study: Kakarza River). Irrigation Science and Engineering. 39(2), 125-138.
8. Naeimi Kalourazi, Z., Ghorbani, Kh., Salarijazi, M., Dehghani, A.A., 2016. Investigation of effect of basin's physiographic and climatic parameters in seasonal river flow simulation. Ecohydrology. 3(4), 545-556.
9. Moatamednia, M., Nohegar, A., Malekian, A., Saberi, M., Karimi, K., 2017. Runoff prediction using intelligent models. Ecohydrology. 4(4), 955-968.
10. Ross, T. J., 1995. Fuzzy logic with engineering application. McGraw Hill Inc., USA.
11. Jang, J.S.R., Sun, C. T., and Mizutani, E., 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice-Hall International. New Jersey.