



پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)

فرشاد احمدی^{۱*}، میرمحمود ولی‌نیا^۲

۱. استادیار، گروه هیدرولوژی و مهندسی منابع آب، دانشکده مهندسی علوم آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

۲. کارشناس دفتر فنی، شرکت آب منطقه‌ای استان آذربایجان غربی، ارومیه، ایران.

تاریخ پذیرش مقاله: ۱۳۹۹/۰۳/۲۸

تاریخ دریافت مقاله: ۱۳۹۹/۰۱/۲۸

چکیده

یکی از مسائل مهم در مدیریت منابع آب، تهیه و توسعه مدل‌های مناسب به منظور پیش‌بینی دقیق‌تر فرایند جریان رودخانه‌ها می‌باشد. به این منظور در مطالعه حاضر برای پیش‌بینی جریان ماهانه رودخانه بختیاری، در دوره آماری ۱۳۹۵-۱۳۳۴، از مدل‌های سری زمانی خطی (ARMA)، مدل هوشمند شبکه بیزین (BN) و مدل تلفیقی BN-ARMA استفاده شد. عملکرد مدل‌های توسعه یافته بر اساس شاخص‌های آماری جذر میانگین مربعات خطا (RMSE)، ضریب همبستگی (CC) و آماره کلینگ-گوپتا (KGE) مورد ارزیابی قرار گرفتند. از بین مدل‌های سری زمانی برازش یافته به داده‌ها، مدل AR(3) با داشتن کم‌ترین مقدار معیار آکایکه اصلاح شده برابر با ۱۰۸۹/۳ به عنوان مدل مناسب سری ماهانه جریان انتخاب گردید. نتایج نشان داد که مدل AR(3) با خطای $47.786 \text{ (m}^3/\text{s)}$ از عملکرد قابل قبولی برخوردار است. برای مدل‌سازی جریان ماهانه رودخانه با استفاده از مدل BN از حافظه‌های دبی یک ماه قبل، دو ماه قبل تا پنج ماه قبل استفاده شد. نتایج نشان داد که با توالی سه ماه جریان عملکرد مدل به بهینه‌ترین حالت ممکن رسیده و با افزایش تعداد ورودی‌ها عملکرد آن تضعیف می‌شود. ضریب همبستگی، جذر میانگین مربعات خطا و KGE در بهترین حالت مدل BN در مرحله آزمون به ترتیب 0.826 ، $45.303 \text{ (m}^3/\text{s)}$ و 0.789 می‌باشد. در مرحله بعد تلفیق مدل‌های BN و ARMA(3,0) انجام شد. نتایج حاصل نشان داد که مدل تلفیقی BN-ARMA به طور قابل ملاحظه‌ای دقت مدل‌سازی را افزایش داده و خطای پیش‌بینی را از $45.303 \text{ (m}^3/\text{s)}$ به $15.021 \text{ (m}^3/\text{s)}$ کاهش داد.

کلیدواژه‌ها: آزمون ایستایی، الگوی ورودی، توسعه مدل، شبکه بیزین.

Prediction of Monthly River Flow Using Hybridization of Linear Time Series Models and Bayesian network (Case Study: Bakhtiari River)

Farshad Ahmadi^{1*}, Mir Mahmood Valinia²

1. Assistant Professor, Hydrology & Water Resources Engineering Department, Faculty of Water & Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

2. Technical Office Expert at West Azerbaijan Regional Water Authority, Urmia, Iran.

Received: April 16, 2020

Accepted: June 17, 2020

Abstract

One of the most important issues in water resources management is the preparation and development of appropriate models in order to predict the streamflow more accurately. For this purpose, in the present study, linear time series models (ARMA), intelligent Bayesian network (BN) and BN-ARMA hybrid model have been developed for forecasting the monthly river flow of Bakhtiari River in 1955-2016. The performance of the developed models was evaluated based on statistical indices such as root mean square error (RMSE), correlation coefficient (CC) and Kling-Gupta index (KGE). Among the time series models fitted to the data, the AR (3) model was selected as the appropriate model for monthly stream flow series, with the lowest value of the modified Akaike information criterion equal to 1089.3. The results showed that the AR (3) model with an error of $47.786 \text{ (m}^3/\text{s)}$ has acceptable performance. The monthly river flow from the previous month, two months and five months ago was used to model the monthly river flow using the BN model. The results indicated that with three months intervals, the model performance is optimized and its performance is weakened by increasing the number of inputs. The correlation coefficient, root mean square error and KGE in the best case of BN model in the test stage are 0.826, 45.303 and 0.789 $\text{(m}^3/\text{s)}$, respectively. Next, the combination of BN and ARMA (3.0) models was performed. The results showed that the BN-ARMA hybrid model significantly increases the accuracy of the modeling and reduces the prediction error from $45.303 \text{ (m}^3/\text{s)}$ to $15.021 \text{ (m}^3/\text{s)}$.

Keywords: Bayesian network, Input pattern, Model development, Stationary test.

مقدمه

داده‌ها به صورت مؤثر در اختیار مدل قرار گیرند، اما سری‌های زمانی ثبت شده هیدرولوژیک با مشکلاتی هم چون خاصیت تناوبی و وجود نویز سفید در داده‌ها مواجه هستند. عوامل مذکور موجب کاهش عملکرد مدل‌های هوشمند شده و برآوردها را به حالت نارایب تبدیل می‌نمایند. برای حل این مشکلات می‌توان از روش‌هایی هم چون تلفیق مدل‌های هوشمند و سری زمانی (برای مدل‌سازی هرچه بهتر نویز سفید داده‌ها) استفاده نمود. مهدی‌زاده و ثالث (۲۱) از مدل‌های تلفیقی BN-ARMA و GEP-ARMA برای پیش‌بینی جریان ماهانه رودخانه‌های شفارود و پل‌رود استفاده نمودند. نتایج این مطالعه نشان داد که استفاده از مدل‌های تلفیقی در مقایسه با مدل‌های تک‌پایه از عملکرد بسیار بهتری برخوردار بوده و به طور قابل ملاحظه‌ای مقدار خطای پیش‌بینی را کاهش داده‌اند. عباسی و همکاران (۷) با ترکیب مدل برنامه‌ریزی بیان ژن (GEP) و مدل سری زمانی مبتنی بر واریانس ناهمسان شرطی (GARCH) مدلی تلفیقی را برای پیش‌بینی خشکسالی در مقیاس‌های زمانی سه، شش و ۱۲ ماهه مورد بررسی قرار دادند. نتایج نشان داد که خطای مدل GEP-GARCH در همه مقیاس‌های زمانی کاهش پیدا می‌کند و این بهبود عملکرد در مقیاس‌های زمانی کوتاه مدت ملموس‌تر می‌باشد، به نحوی که ضریب همبستگی در مقیاس زمانی سه‌ماهه در مدل ساده GEP از ۰/۶۲۲ به ۰/۸۹۱ در مدل ترکیبی افزایش پیدا کرده است. مهدی‌زاده و همکاران (۲۲)، فتحیان و همکاران (۱۶) و آنویام و پانی (۱۱) در مطالعات خود گزارش نمودند که تلفیق مدل‌های سری زمانی و مدل‌های هوشمند، دقت برآوردها را به صورت قابل ملاحظه‌ای افزایش می‌دهد و از این رو آن را به عنوان یک روش مناسب در برآورد پارامترهای هیدرولوژیک توصیه نموده‌اند.

با توجه به بررسی منابع انجام شده می‌توان نتیجه گرفت که همواره بهبود پیش‌بینی‌های پارامترهای

پیش‌بینی جریان رودخانه‌ها همواره یکی از مسائل پر اهمیت در علم هیدرولوژی بوده و نقش بسیار مهمی را در مدیریت، بهره‌برداری و برنامه‌ریزی منابع آب دارد. به این منظور تاکنون مدل‌های آماری، هیدرولیکی و هیدرولوژیکی متعددی توسعه یافته که از نقاط قوت و ضعف متفاوتی نیز برخوردار هستند (۱۳، ۱۴، ۱۷). چرا که عوامل مؤثر در فرایندهای هیدرولوژیکی بسیار متنوع بوده و اعمال کلیه آن‌ها در مدل‌های طراحی شده بسیار مشکل می‌باشد. علاوه بر این، نبود قطعیت‌ها و غیرخطی بودن روابط بین متغیرها، مسأله را پیچیده کرده و مدل‌های فیزیکی و مفهومی هیدرولوژیکی به دلیل نیاز به اطلاعات فراوان در خصوص پارامترهای گوناگون و واسنجی وقت‌گیر، کم‌تر مورد توجه قرار گرفته‌اند. بنابراین، در سال‌های اخیر، رویکرد به مدل‌های هوشمند نظیر شبکه‌های بیزین^۱ (BN) به عنوان ابزاری توانمند در پیش‌بینی پارامترهای هیدرولوژیک، افزایش یافته است. شبکه‌های بیزین، روشی سودمند است که می‌تواند اطلاعات و داده‌های کمی را به خوبی با دانش کیفی کارشناسی همسو نماید. از طرف دیگر این شبکه‌ها را می‌توان به عنوان هوش مصنوعی نیز قلمداد کرد. تکنیک‌های مدل‌سازی بیزین دارای ویژگی‌هایی هستند که آن‌ها را برای پرسش‌های تحلیلی و مدیریتی داده‌های جهان واقعی، کاربردی و مفید ساخته‌اند. امروزه این مدل‌های احتمالاتی کاربرد وسیعی در علوم مربوط به محیط زیست و منابع آب پیدا کرده‌اند (۲، ۱۸، ۲۵، ۲۳ و ۲۷).

در کاربرد مدل‌های هوشمند، انتخاب جمعیت‌های اولیه تصادفی مختلف و تأثیرگذار در پدیده که از آن‌ها به عنوان داده‌های آموزشی یاد می‌شود، به منظور آموزش ماهیت سازوکار حاکم، نه تنها سبب پیچیدگی الگو و افزایش حافظه درگیر خواهد شد بلکه سبب کاهش دقت نیز می‌شود (۶). لذا در الگوسازی جریان رودخانه‌ها باید همواره سعی نمود

پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های خطی سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)

۱۳۹۵ برای ایجاد مدل‌ها استفاده شده است. رودخانه بختیاری یکی از دو سرشاخه اصلی رودخانه دز می‌باشد که از ارتفاعات جنوبی اشترانکوه سرچشمه گرفته و در نزدیکی ایستگاه تنگ‌پنج به رودخانه سزار می‌پیوندد و رود دز را تشکیل می‌دهد. براساس تصمیمات اتخاذ شده توسط مدیران صنعت آب کشور مقرر گردیده سد و نیروگاه بختیاری که در بخش سفلاي رودخانه بختیاری در استان لرستان و در بخش جنوب‌غربی ایران، در دامنه‌های جنوب‌غربی کوه‌های زاگرس چین خورده و در شمال‌غرب ایستگاه تنگ‌پنج بختیاری در مسیر راه‌آهن تهران- اهواز روی رودخانه مورد مطالعه احداث شود. هدف از ساخت این سد، جلوگیری از ورود رسوبات رودخانه بختیاری به مخزن سد دز و افزایش عمر مفید آن از جمله اهداف این سد است و امکان مدیریت بهینه منابع آب به‌منظور افزایش سطح زیر کشت اراضی پایین‌دست، کنترل سیلاب‌های مخرب فصلی و افزایش ایمنی سد دز از دیگر اهداف مهم ساخت سد بختیاری به‌شمار می‌رود. در شکل (۱) موقعیت حوضه آبریز بختیاری و ایستگاه تنگ‌پنج بختیاری ارائه شده و جدول (۱) نشان‌دهنده خصوصیات آبدی و فیزیوگرافی منطقه مورد مطالعه می‌باشد.

هیدرولوژیک مورد توجه بوده و به این منظور روش‌های متعددی از جمله مدل‌های تجربی، نیمه‌تجربی، سری‌های زمانی، مدل‌های هوشمند و مدل‌های هیبریدی ارائه شده‌اند. یکی از نقاط ضعف مدل‌های هوشمند عدم در نظر گرفتن خاصیت تصادفی در فرایند مدل‌سازی است چرا که برای دستیابی به بهترین عملکرد از روابط ریاضی مشخص استفاده نموده و به عبارت دیگر جواب‌های حاصله قطعی می‌باشد. از طرف دیگر مدل‌های سری زمانی با در نظر گرفتن خاصیت تصادفی داده‌ها می‌توانند اطلاعات مفیدی را برای مدل‌های هوشمند فراهم نمایند (۲۲). لذا در این تحقیق سعی گردیده است تا میزان بهبود عملکرد روش BN با استفاده از مدل‌های خطی (خانواده ARMA) سری زمانی و تأثیر خاصیت تصادفی مورد بررسی و ارزیابی قرار گرفته و مناسب‌ترین ترکیب هیبریدی برپایه BN معرفی گردد.

مواد و روش‌ها

داده‌ها و منطقه مورد مطالعه

در این مطالعه از اطلاعات ایستگاه هیدرومتری تنگ‌پنج بختیاری واقع بر رودخانه بختیاری در دوره آماری ۱۳۳۵ تا

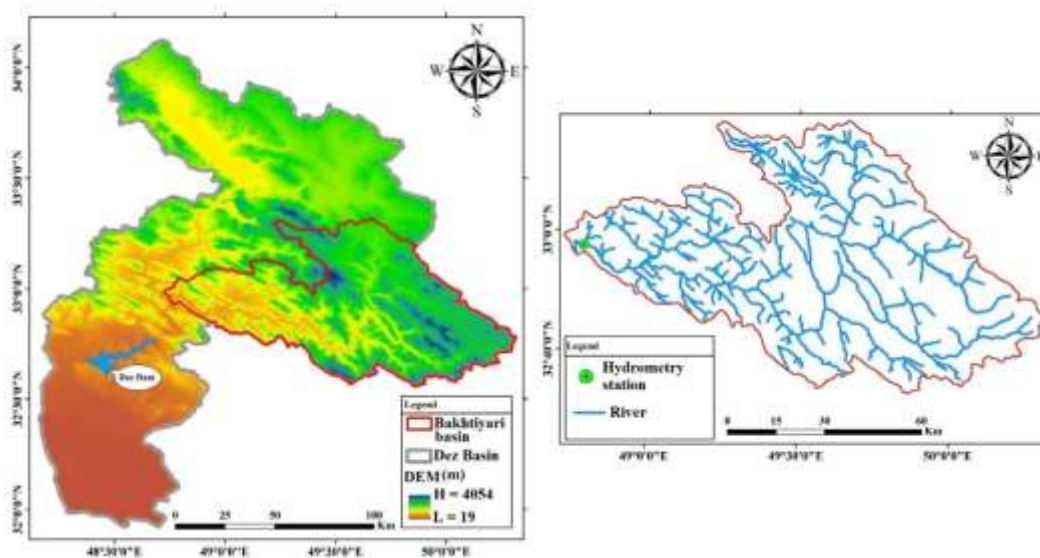


Figure 1. Location of the study area along Dez river basin.

Table 1. Physiographical and hydrological characteristics of studied watershed (1955-2016).

Row	Parameter	Bakhtiyari basin
1	The average annual discharge volume (MCM)	4211.3
2	The average annual discharge volume n (m ³ /s)	133.5
3	Minimum discharge	0.0
4	Maximum discharge	1179.3
5	Standard deviation	118.5
6	Area (Km ²)	6437.2
7	Perimeter (Km)	525.7
8	length of main river (Km) The	251.4

تحلیل اولیه داده‌ها

بسیاری از مدل‌های سری زمانی با این فرض اساسی در هیدرولوژی به کار برده می‌شوند که متغیرهای موردنظر از توزیع نرمال تبعیت کرده و ایستا هستند. اما در بسیاری از موارد داده‌های ثبت‌شده برای دبی جریان توزیعی نامتقارن دارند و در برخی موارد (مانند وجود روند، خاصیت تناوبی و غیره) نایستا می‌باشند. بنابراین، لازم است که داده‌ها قبل از مدل‌سازی نرمال‌شده و از ایستایی سری اطمینان حاصل گردد. یک سری زمانی ایستاست، اگر سری فاقد روند، پرش یا حالت تناوبی باشد. در این صورت امید ریاضی و واریانس سری مستقل از زمان می‌باشد (۴). در این مطالعه از آزمون‌های چولگی و دیکی- فولر تعمیم‌یافته^۲ (ADF) به ترتیب برای بررسی نرمال بودن و تحلیل ایستایی سری جریان رودخانه مورد مطالعه استفاده شد. دیکی و فولر (۱۵) یک توزیع محدود را برای آماره آزمون ADF در نظر گرفتند. فرض صفر (H₀) مبنی بر نایستایی پذیرفته می‌شود اگر مقدار آماره t محاسبه‌شده کوچک‌تر از مقادیر بحرانی در سطح معنی‌داری α باشد. در غیر این صورت فرض صفر رد شده و فرض مخالف یا (H₁) (ایستایی سری) تأیید می‌شود. مقادیر بحرانی آزمون ADF در سطوح معنی‌داری ۱، ۵ و ۱۰ درصد به ترتیب برابر با -۳/۴۴، -۲/۸۶ و -۲/۵۷ می‌باشد (۴). آزمون‌های ADF و چولگی در مطالعات مختلفی هم‌چون خلیلی و همکاران (۴ و ۵) و احمدی و همکاران (۱) مورد استفاده قرار گرفته و روابط ریاضی آن‌ها به‌طور مبسوط شرح داده شده است.

مدل‌های خطی سری زمانی

مدل ARMA^۳ رایج‌ترین مدل کاربردی در پیش‌بینی سری‌های زمانی هیدرولوژیکی بوده و رابطه آن به شرح زیر بیان می‌گردد:

$$ARMA(p,q): Z_t = \sum_{i=1}^p (\varphi_i \cdot Z_{t-i}) - \sum_{j=1}^q (\theta_j \cdot \varepsilon_{t-j}) + \varepsilon_t \quad (1)$$

در رابطه فوق Z_t سری زمانی نرمال و استاندارد، φ_j ضرایب مدل خودهمبسته (AR)، ε_t سری زمانی مستقل یا سری تصادفی مدل، p و q رسته یا مرتبه مدل می‌باشند (۱). مدل ARMA(p,0) همان مدل AR(P) و مدل ARMA(0,q) همان مدل MA(q) می‌باشد. برای تعیین مرتبه مناسب مدل ARMA از روش آکایکه اصلاح‌شده^۴ (AICC) استفاده شد. به این منظور مقادیر p و q به‌طور دلخواه انتخاب و سپس مقدار معیار AICC هر مدل از رابطه (۲) به‌دست آمد. مدلی که کمترین مقدار AICC را دارا بود، به‌عنوان مدل مناسب انتخاب گردید (۱).

$$AICC(p,q) = nLn(\hat{\sigma}_\varepsilon^2) + \frac{2(p+q+1)n}{(n-p-q-2)} \quad (2)$$

که در رابطه فوق n تعداد داده‌ها، p مرتبه مدل در بخش خود همبسته، q مرتبه مدل در بخش میانگین متحرک و $\hat{\sigma}_\varepsilon^2$ واریانس مانده‌ها یا خطاها می‌باشد که از رابطه (۳) به‌دست آمد.

$$\hat{\sigma}_\varepsilon^2 = \frac{s^2(1-\hat{\rho}_1^2)}{(1-2\hat{\rho}_1\hat{\theta}_1+\hat{\theta}_1^2)} \quad (3)$$

در این مطالعه پس از تعیین مرتبه مناسب، پارامترهای مدل با استفاده از روش گشتاورها برآورد گردید. در روش گشتاورها پس از تشخیص مرتبه، شکل کلی مدل

پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های خطی سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)

نشان می‌دهد. این شبکه یک گراف مستقیم و غیرچرخه‌ای است که در آن گره‌ها در حکم متغیرهای مسئله هستند. این روش بر مبنای محاسبات احتمالات وابسته یا قانون بیز می‌باشد (۸).

$$P(b|a) = P(a|b) \times \frac{P(b)}{P(a)} \quad (۷)$$

که در رابطه فوق $P(a)$ احتمال وقوع پیشامد a ، $P(b)$ احتمال وقوع پیشامد b ، $P(b|a)$ احتمال وقوع پیشامد b به شرطی که a اتفاق افتاده باشد و $P(a|b)$ احتمال وقوع پیشامد a به شرطی که b اتفاق افتاده باشد، هستند (۲). متغیرهایی که در مسائل زیست‌محیطی و منابع آب به کار می‌روند، می‌توانند کیفی یا کمی باشند. هر شبکه بیزین از سه جزء اصلی تشکیل شده است ۱- مجموعه‌ای از گره‌ها که در واقع متغیرهای سیستم مدیریتی هستند. این گره‌ها می‌توانند متغیرهای پیوسته یا ناپیوسته، اعداد ثابت و یا توابع پیوسته باشند. هر گره به چند طبقه یا کلاس تقسیم می‌شود. در حالت کلی گره‌ها یا والد هستند یا ولد (فرزند). یک گره ولد می‌تواند از چندین والد تولید شده باشد (۲۰)، ۲- مجموعه‌ای از بندها؛ روابط سببی بین متغیرها به وسیله بندها به وجود می‌آیند (۲۶). این روابط به وسیله پیکان نمایش داده می‌شوند. گره‌ها به وسیله پیکان‌ها به هم مربوط می‌شوند. عدم وجود پیکان بین گره‌ها، بیانگر استقلال متغیرها می‌باشد (۲۴). گره‌هایی که هیچ پیکانی به آن‌ها وارد نشده است، گره‌های والد ورودی هستند. گرهی که پیکان به آن وارد و از آن خارج می‌شود، بیانگر گره ولد وضعیت می‌باشند و گره‌هایی که از آن‌ها هیچ پیکانی خارج نمی‌شود، نشان‌دهنده گره‌های ولد خروجی می‌باشند. منظور منطقی پیکانی که از سمت متغیر x به سمت متغیر y می‌رود، این است که متغیر x اثر مستقیمی بر متغیر y دارد. مثلاً دما اثر مستقیم بر تبخیر و تفرق می‌گذارد (۲۴)؛ ۳- مجموعه‌ای از احتمالات؛

مشخص شده و سپس با تابع خودهمبستگی به دست آمده، پارامترهای مدل مشخص می‌گردند. به عنوان مثال، در مورد مدل ARMA(1,1) ضرایب مدل (ϕ_1) و (θ_1) و σ_ε^2 از روابط (۴) و (۵) محاسبه شدند (۲۷):

$$\hat{\phi}_1 = \frac{r_2}{r_1} \quad (۴)$$

$$\theta_1 = \frac{-b + \sqrt{b^2 - 4(r_1 - \hat{\phi}_1)^2}}{2(r_1 - \hat{\phi}_1)} \quad (۵)$$

که در روابط فوق Γ_1 و Γ_2 تخمین‌گر ضریب خودهمبستگی سری به ترتیب با تأخیر یک و دو بوده و پس از تعیین مرتبه و ضرایب مدل می‌باید نکویی برازش آن مورد ارزیابی و آزمون قرار گیرد. برای این منظور می‌توان از آزمون پورت مانثو استفاده نمود. در روش پورت مانثو ابتدا سری باقی‌مانده مدل به دست آمده، سپس برای تعداد تأخیر مشخص ضرایب خودهمبستگی سری محاسبه شد. آنگاه آماره پورت مانثو (Q) با استفاده از رابطه (۶) بیان می‌شود:

$$Q = n \sum_{k=1}^L r_k^2(\varepsilon_t) \quad (۶)$$

که در آن n تعداد داده، L حداکثر تعداد تأخیر بوده که در این مطالعه بنا به توصیه سالاس (۲۷) برای سری ماهانه ۲۵ درصد تعداد کل داده‌ها در نظر گرفته شد، $r_k(\varepsilon_t)$ ضریب خود همبستگی مرتبه k ام و ε_t سری باقیمانده مدل می‌باشد. آماره Q دارای توزیع کی دو با درجه آزادی $(L-p-q)$ است و در صورتی که $Q \leq \chi^2_{(1-\alpha), (L-p-q)}$ باشد، مقادیر ε_t ناهمبسته بوده و مدل نظیر آن کفایت لازم را برای استفاده در پیش‌بینی دارد (۱). در این مطالعه سطح معنی‌داری $\alpha=0/05$ در نظر گرفته شد.

شبکه‌های بیزین

شبکه بیزین یک مدل گرافیکی احتمالاتی است که مجموعه‌ای از متغیرها و احتمالات مربوط به هر کدام را

مدل‌های ARMA و P_t مقدار نهایی سری‌های زمانی جریان رودخانه می‌باشد.

ارزیابی مدل‌ها

در این مطالعه برای ارزیابی مدل‌های مورد بررسی از آماره‌های ضریب همبستگی (CC)، جذر میانگین مربعات خطا^۵ (RMSE) و معیار کلینگ گوپتا^۶ (KGE) استفاده شد.

$$RMSE = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n} \right)^{0.5} \quad (9)$$

$$CC = \left(1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \right)^{0.5} \quad (10)$$

$$KGE = 1 - \sqrt{(CC - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (11)$$

که در روابط فوق Q_i مقدار مشاهده شده در گام زمانی i ام، \hat{Q}_i مقدار محاسبه شده در همان زمان، n تعداد داده‌ها، CC ضریب همبستگی بین داده‌های مشاهداتی و محاسباتی، α نسبت انحراف معیار Q ، \hat{Q} و β نسبت میانگین Q ، \hat{Q} و \bar{Q} میانگین مقادیر مشاهداتی می‌باشد. مدلی به‌عنوان مناسب‌ترین گزینه انتخاب می‌گردد که کم‌ترین مقدار RMSE و بیش‌ترین مقدار CC و KGE را به‌خود اختصاص دهد.

نتایج و بحث

پیش‌بینی جریان رودخانه با استفاده از مدل‌های سری زمانی

قبل از انجام آزمون ایستایی، لازم است که خاصیت تناوبی و روند از داده‌ها حذف و سری ماهانه نرمال گردد. در این مطالعه از توابع نرمال‌ساز مختلف نظیر باکس-کاکس، جذر، تابع نمایی و لگاریتم‌گیری استفاده شد. به این منظور در ابتدا مقدار چولگی سری زمانی جریان ماهانه

هرکدام برای متغیر شرایط تصمیمی را مشخص می‌کند که این شرایط از طریق متغیرهایی که به‌طور مستقیم آن را تحت تأثیر قرار می‌دهند (والدین آن)، به آن نسبت داده می‌شوند (۱۲). گره‌هایی که قبل از آن‌ها گره دیگری در گراف وجود دارد با توزیع احتمالی شرطی تعریف می‌شوند و در غیر این صورت، با احتمال آغازین (اولیه) بیان می‌شوند. احتمال شرطی، احتمال میزان تأثیر یک گره ورودی به یک گره مفروض در شبکه را به‌دست می‌دهد و احتمال آغازین بیانگر میزان احتمال قرارگیری یک متغیر ورودی در یک کلاس معین می‌باشد و از طریق اطلاعات اولیه موجود راجع به متغیرها به‌دست می‌آید. احتمالات مربوط به پایین‌ترین بخش در شبکه بیزین از طریق قانون احتمال کل به‌دست می‌آید و احتمالات مرتبط با بخش‌های بالایی شبکه، براساس قانون بیز هستند. در حالت کلی، اگر گره x دارای والد نباشد گره غیرمشروط و در غیر این صورت گره مشروط می‌باشد (۱۹).

مدل‌های هیبریدی

در این مطالعه برای ایجاد مدل‌های هیبریدی از سه مدل AR، BN و ARMA استفاده می‌شود. به این منظور پس از برازش مدل‌های سری زمانی به داده‌ها و تعیین ضرایب، مدل‌های تلفیقی به شرح زیر ایجاد می‌گردد:

۱- سری زمانی خطا یا نویز که با ϵ_t نمایش داده می‌شود از بهترین مدل برازشی محاسبه و استخراج می‌گردد.

۲- نتایج حاصل از اجرای بهترین مدل BN با استفاده از آماره‌های ارزیابی تعیین می‌گردد.

۳- گام نهایی تلفیق ϵ_t و بهترین نتیجه BN براساس رابطه زیر می‌باشد (۷).

$$P_t = D_t + E_t \quad (8)$$

که در رابطه فوق D_t جزء قطعی سری‌های زمانی داده‌های دبی جریان به‌دست‌آمده از مدل BN، E_t جزء تصادفی سری‌های زمانی جریان محاسبه‌شده از بهترین

پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های خطی سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)

مدل منتخب جهت پیش‌بینی جریان ماهانه رودخانه، آزمون نکویی برازش با استفاده از آزمون پورت مانتو انجام شد. مقدار آماره Q این آزمون برای سری باقیمانده مدل AR(3) برابر با ۸۹/۲۷ به دست آمد که کم‌تر از مقدار کی دو جدول با درجه آزادی ۱۸۰ با مقدار ۱۴۴/۳ در سطح اطمینان پنج درصد می‌باشد. بنابراین می‌توان نتیجه گرفت که نتایج حاصل از این روش صحت و کفایت مدل برازشی AR(3) را تأیید می‌نماید. در جدول (۳) نتایج تحلیل آماری مدل به‌کاررفته در پیش‌بینی جریان رودخانه بختیاری ارائه شده است. با توجه به این جدول مشاهده می‌شود که عملکرد مدل AR در حد قابل قبولی می‌باشد.

Table 3. The performance results of AR(3) model in Tange Pange Bakhtiyari station

Training phase			Testing phase		
KGE	CC	RMSE (m ³ /s)	KGE	CC	RMSE (m ³ /s)
0.725	0.811	74.021	0.774	0.822	47.786

شکل (۲) نیز نمودارهای گرافیکی و پراکنندگی مقادیر مشاهداتی و مقادیر پیش‌بینی شده حاصل از مدل AR(3) را در مرحله تست برای سری ماهانه جریان رودخانه بختیاری نشان می‌دهد. به طوری که از شکل (۲) می‌توان نتیجه گرفت، مدل مذکور مقادیر دبی جریان ماهانه رودخانه مورد مطالعه را به‌طور قابل قبولی پیش‌بینی کرده اما در برآورد دبی‌های پیک دچار مشکل شده و در برخی از موارد جریان را بزرگ‌تر و یا کوچک‌تر از مقادیر واقعی پیش‌بینی نموده است.




Figure 2. Time series and scatter plots of the observed against the modeled streamflow of the Tange Pange Bakhtiyari station for the o AR(3) model during the test stage

رودخانه بختیاری محاسبه و چنانچه خارج از محدوده قابل قبول بود تبدیل صورت می‌گرفت. در نهایت تابع نرمال‌ساز $Y_t = \ln(X_t + 4.308)$ توانست مقدار چولگی داده‌های جریان ماهانه مشاهداتی را از ۲/۵۸ به صفر کاهش داده و در نتیجه سری مورد مطالعه را نرمال نماید. در مرحله بعد نوبت به بررسی ایستایی داده‌ها می‌رسد. جدول (۲) نتایج آزمون ADF را برای سری‌های نرمال و استاندارد ماهانه نشان می‌دهد. با توجه به نتایج این جدول، سری ماهانه نرمال ایستا نبوده و با استاندارد کردن آن سری ایستا شده و در نتیجه می‌توان از مدل‌های سری زمانی برای ادامه محاسبات استفاده نمود.

Table 2. The results of ADF test for normalized and standardized monthly flow series of Bakhtiyari river

Series type	Lag	Test statistic	P-Value	Result
Normal	26	-1.42	0.14	Non stationary
Standard	9	-3.45	0.02	Stationary

پس از نرمال کردن و حذف عوامل نایستایی از سری ماهانه جریان رودخانه، مرتبه مدل مناسب براساس کم‌ترین مقدار معیار آکایکه اصلاح شده تشخیص داده شد و پارامترهای آن تخمین زده شدند. به این منظور ۸۰ درصد داده‌ها برای آموزش (۵۸۸ ماه) و ۲۰ درصد باقی (۱۴۴ ماه) برای تست در نظر گرفته شد. مدل AR(3) کم‌ترین مقدار معیار آکایکه برابر با ۱۰۸۹/۳ را از بیش از ۲۰ مدل برازشی به‌خود اختصاص داد. قبل از استفاده از

معمولاً براساس یک مدل مفهومی از سیستمی که قرار است مدل‌سازی و مدیریت شود، شکل می‌گیرد. بنابراین ساخت مدل مفهومی، اولین قدم در ساختن مدل بیزین است. در این مطالعه، مدل مفهومی بیزین از طریق الگوهای ورودی ساخته شد (شکل ۴).

گام دوم) تعیین نوع ارتباط بین ورودی‌های مختلف مدل در ساختار مفهومی: در مطالعه حاضر از حافظه سری روزانه جریان به‌عنوان ورودی‌های اصلی استفاده شد. حال در تعریف مفهومی برای مدل بیزین این‌گونه در نظر گرفته شد که، دبی ماه آتی متأثر از توالی‌های گذشته خود می‌باشد (شکل ۴).

گام سوم) آموزش شبکه و به‌دست‌آوردن رابطه بین داده‌ها: پس از تشکیل چارچوب و تعریف مدل، نوبت به آموزش شبکه ساخته‌شده می‌رسد. در این مرحله با استفاده از الگوهای مختلف ورودی، مدل سعی در ایجاد ارتباط بین داده‌ها داشته و شکل ریاضی این ارتباط را به‌دست می‌آورد. حال با رابطه ریاضی موجود می‌توان داده‌ی مصنوعی تولید کرده و عملکرد مدل را مورد ارزیابی قرار داد.

گام چهارم) ارزیابی مدل: مجموعه‌ای از ابزار اعتبارسنجی می‌تواند در مورد ارزیابی شبکه به‌کار برده شود که این ارزیابی‌ها می‌توانند از طریق داده‌ها و معیارهای ارزیابی موجود در مواد و روش‌ها صورت گیرد.




Figure 3. PACF plot for Bakhtiari river monthly flow in the location of hydrometric station

پیش‌بینی جریان رودخانه با استفاده از مدل‌های BN و هیبریدی

در مطالعه حاضر برای مدل‌سازی جریان ماهانه رودخانه بختیاری با استفاده از مدل‌های شبکه بیزین و هیبریدی، به مانند مدل سری زمانی خطی از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد مابقی برای تست استفاده شد تا امکان مقایسه مدل‌ها فراهم آید. یکی از مهم‌ترین مراحل مدل‌سازی و پیش‌بینی پارامترهای هیدرولوژیک تعیین ورودی‌های موردنیاز مدل برای محاسبه لایه خروجی است. به‌منظور پیش‌بینی جریان رودخانه می‌توان از اطلاعاتی هم‌چون بارش، دما، تبخیر و سایر پارامترهای مؤثر در پدیده استفاده نمود اما لزوماً استفاده از این متغیرها موجب بهبود عملکرد مدل نشده و هزینه‌های جمع‌آوری اطلاعات را نیز افزایش می‌دهد. بنابراین در مطالعات متعددی هم‌چون احمدی و همکاران (۲)، چمنی و روشنگر (۳) و نبی‌زاده و همکاران (۱۰) از توالی دبی ماه‌های قبل در پیش‌بینی دبی ماه فعلی برای مدل‌سازی استفاده شده است. اما همواره سوال اصلی در این روش، انتخاب تعداد تأخیرهای مناسب برای مدل‌سازی است. به این منظور می‌توان از تابع PACF استفاده نمود (۹). در شکل (۳) نمودار تابع مذکور برای سری ماهانه ایستگاه تنگ پنج بختیاری ارائه شده است. با توجه به این شکل مشاهده می‌شود که بعد از تأخیر پنجم، مقادیر PACF خارج از باند اطمینان واقع می‌شود. از این‌رو، در مطالعه حاضر تا پنج تأخیر برای مدل‌سازی در نظر گرفته شده و به شرح جدول (۴) مدل‌های مستقل و هیبریدی شبکه بیزین توسعه داده شدند.

در این مطالعه مراحل ساخت و توسعه مدل شبکه بیزین به شرح زیر صورت گرفته است:

گام اول) تشکیل چارچوب مدل: که شامل تعریف متغیرها و روابط موجود بین آن‌ها در سیستم است و

پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های خطی سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)

با افزایش تعداد ورودی‌ها تا تأخیر سوم عملکرد مدل بیزین بهبود می‌یابد، اما در تأخیرهای چهارم و پنجم دقت برآوردها کاهش یافته و خطا افزایش می‌یابد. شکل (۵) نیز نمودار مقادیر مشاهداتی و محاسباتی حاصل از مدل BN(M3) را نشان می‌دهد. داندنمه‌مهر و مجدزاده طباطبایی (۶) یکی از دلایل مهم این امر را ورود اطلاعات اضافی و درگیر شدن حافظه مدل‌های هوشمند عنوان نموده‌اند.

در شکل (۶-b) مقادیر استاندارد شده حاصل از مدل BN در الگوی سوم ارائه شده است. با تجمیع این دو نمودار مدل تلفیقی BN-ARMA ایجاد گردیده و در شکل (۶-c) نتیجه نهایی نشان داده شده است. مقایسه مقادیر محاسباتی مدل BN-ARMA و مشاهداتی استاندارد شده در شکل (۶-c) نشان می‌دهد که تطابق بسیار خوبی بین داده‌ها وجود داشته و عملکرد مدل تلفیقی بسیار مناسب می‌باشد.

Table 4. Optimal input combinations used for development of BN and hybrid models

Row	Model type	Pattern	Inputs
1		M1	Q(t-1)
2		M2	Q(t-1), Q(t-2)
3	Standalone	M3	Q(t-1), Q(t-2), Q(t-3)
4		M4	Q(t-1), Q(t-2), Q(t-3), Q(t-4)
5		M5	Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5)
6		HM1	Q(t-1), ε_t
7		HM2	Q(t-1), Q(t-2), ε_t
8	Hybrid	HM3	Q(t-1), Q(t-2), Q(t-3), ε_t
9		HM4	Q(t-1), Q(t-2), Q(t-3), Q(t-4), ε_t
10		HM5	Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5), ε_t




Figure 4. Conceptual model of BN model for M3 input pattern

Table 5. The performance results of BN model in Tange Pange Bakhtiyari station

Model	Training phase			Testing phase		
	KGE	CC	RMSE (m ³ /s)	KGE	CC	RMSE (m ³ /s)
M1	0.641	0.814	73.624	0.736	0.788	50.746
M2	0.679	0.826	70.964	0.769	0.801	47.539
M3	0.705	0.859	65.011	0.789	0.826	45.303
M4	0.691	0.850	66.326	0.778	0.809	46.989
M5	0.683	0.841	68.746	0.771	0.804	47.371

در جدول (۵) نتایج ارزیابی الگوهای مختلف ورودی به مدل شبکه بیزین با در نظر گرفتن اثر توالی دبی‌های جریان رودخانه در دو مرحله آموزش و صحت‌سنجی ارائه شده است. با توجه به این جدول مشاهده می‌شود که




Figure 5. Time series and scatter plots of the observed against the modeled streamflow of the Tange Pange Bakhtiyari station for the optimum BN model during the test stage.

و همکاران (۷) و مهدی‌زاده و همکاران (۲۲) نیز در مطالعات خود به نتایج مشابهی دست یافته و اعلام نموده‌اند که تلفیق مدل‌های سری زمانی و روش‌های هوشمند نظیر شبکه بیزین و برنامه‌ریزی بیان ژن می‌تواند برآوردها و داده‌های مشاهداتی را به همدیگر بسیار نزدیک نماید.

نتیجه‌گیری

در اکثر مطالعات مربوط به مدل‌سازی جریان رودخانه‌ها بیش‌تر به یک مدل خاص توجه شده و کم‌تر تلفیق مدل‌ها از خانواده‌های مختلف مورد توجه بوده است. از این‌رو، در مطالعه حاضر تلفیق مدل خطی سری زمانی با مدل هوش مصنوعی شبکه بیزین در پیش‌بینی جریان ماهانه رودخانه بختیاری مورد بررسی قرار گرفت.

در جدول (۶) نتایج حاصل از ارزیابی مدل هیبرید با الگوهای ورودی مختلف ارائه شده است. با توجه به این جدول می‌توان نتیجه گرفت که دقت برآوردها افزایش و خطا کاهش چشم‌گیری داشته است. همچنین روند بهبود نتایج و تغییر الگوی دقت برآوردها در مدل BN-ARMA مطابق با حالت مستقل BN بوده به‌طوری‌که بهترین عملکرد روش هیبرید با الگوی HM3 به‌دست آمده است. در شکل (۷) جریان مشاهداتی و محاسباتی حاصل از مدل هیبریدی بهینه (الگوی HM3) نشان داده شده است. این شکل به‌خوبی تأییدکننده دقت بالای پیش‌بینی مدل هیبریدی بوده و تکمیل‌کننده نتایج ارائه‌شده از شکل (۶) می‌باشد. در شکل (۷) می‌توان مشاهده نمود که مقادیر حدی شامل جریان‌های کمینه و دبی‌های پیک به‌خوبی برآورد گردیده است. عباسی

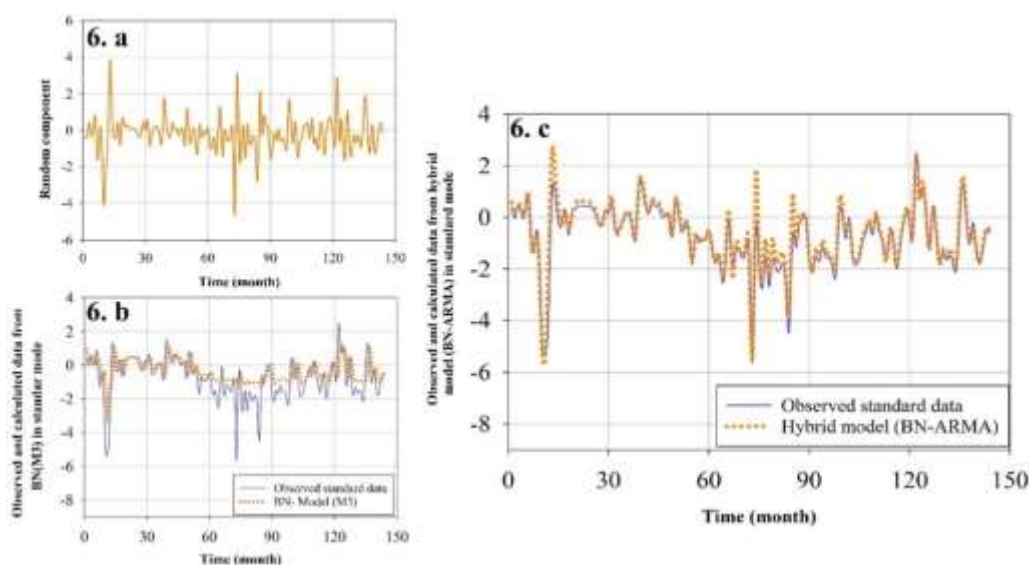


Figure 6. Development process of hybrid models: a) Residual series of AR (3) model, b) Standardized observational and computational values of the optimum BN model and c) Combination of BN and ARMA models and comparison of results with observational values

Table 6. The performance results of BN-ARMA model in Tange Pange Bakhtiyari station

Model	Training phase			Testing phase		
	KGE	CC	RMSE (m ³ /s)	KGE	CC	RMSE (m ³ /s)
HM1	0.921	0.942	17.642	0.873	0.966	18.721
HM2	0.933	0.979	16.993	0.889	0.969	17.236
HM3	0.948	0.995	14.871	0.921	0.984	15.021
HM4	0.941	0.988	15.523	0.910	0.980	16.112
HM5	0.939	0.983	16.234	0.902	0.974	16.884

پیش‌بینی جریان ماهانه رودخانه با استفاده از ترکیب مدل‌های خطی سری زمانی و شبکه‌های بیزین (مطالعه موردی: رودخانه بختیاری)




Figure 7. Time series and scatter plots of the observed against the modeled streamflow of the Tange Pange Bakhtiyari station for the best hybrid model (BN-ARMA) during the test stage.

در مرحله آزمون مقادیر شاخص‌های جذر میانگین مربعات خطا، ضریب همبستگی و آماره KGE در مرحله آزمون به ترتیب برابر با 0.798 و 0.826 ، $45/303$ (m^3/s) و $AR(3)$ نشان‌دهنده عملکرد گردید. مقیاسه دو روش BN و $AR(3)$ نشان‌دهنده عملکرد بهتر مدل BN می‌باشد. اما توسعه مدل تلفیقی توانست مقادیر خطای (دقت) برآوردها را به‌طور چشم‌گیری کاهش (افزایش) داده و نسبت به مدل $AR(3)$ و BN از عملکرد بسیار بهتری برخوردار بود.

یکی دیگر از نتایج مهمی که در این مطالعه حاصل شد، تأثیر مثبت استفاده از ترم تصادفی در بهبود عملکرد مدل BN در برآورد جریان ماهانه بود. ترم تصادفی صرفاً براساس داده‌های موجود و روابط ریاضی نسبتاً ساده محاسبه شده و هیچ‌گونه هزینه‌ای را از نظر جمع‌آوری اطلاعات به کاربران تحمیل نمی‌نماید. حال آن‌که در اکثر مطالعات برای بهبود دقت و عملکرد مدل‌های هوشمند از داده‌های هیدرولوژیکی دیگر نظیر بارش، دماهای مینیمم، متوسط و ماکزیمم، تبخیر و غیره بهره برده می‌شود. استفاده از این اطلاعات علاوه بر درگیرکردن حافظه مدل لزوماً باعث بهبود عملکرد آن نشده و هزینه‌های اجرای مدل را از نظر زمانی و تهیه و آماده‌سازی اطلاعات افزایش می‌دهند. از این‌رو، پیشنهاد می‌گردد که در

در ابتدا با استفاده از آزمون‌های چولگی و ADF نرمال‌بودن و ایستایی سری‌های جریان رودخانه بختیاری مورد بررسی قرار گرفت. نتایج نشان داد که تابع نرمال‌ساز $Y_t = \ln(X_t + 4.308)$ بهترین عملکرد را در نرمال‌سازی داده‌ها داشته و مقدار چولگی را از $2/58$ به صفر کاهش داده است. در مرحله بعد آزمون ADF برای سری‌های نرمال و استاندارد ماهانه انجام شده و با استانداردکردن داده‌ها شرط ایستایی حاصل گردید. پس از تأیید ایستایی داده‌های جریان، مدل‌های مختلف سری زمانی به داده‌ها برازش داده شد. براساس معیار آکایکه مدل $AR(3)$ کم‌ترین مقدار (برابر با $1089/3$) را به‌خود اختصاص داد و از این رو به‌عنوان مناسب‌ترین مدل سری زمانی انتخاب گردید. نتایج حاصل از آماره‌های ارزیابی نشان داد که مدل منتخب در پیش‌بینی جریان ماهانه رودخانه بختیاری از دقت قابل‌قبولی برخوردار است. در این مطالعه به‌منظور تعریف الگوهای مختلف ورودی به مدل هوشمند شبکه بیزین از تابع PACF استفاده شده و تعداد تأخیرهای لازم برای انجام مدل‌سازی برابر با پنج به‌دست آمد. در مرحله بعد الگوهای ورودی در دو حالت مدل مستقل BN و مدل هیبریدی BN-ARMA تعریف گردید. نتایج نشان داد که مدل BN با سه تأخیر در دبی جریان و در الگوی M3 به بیش‌ترین دقت دست یافته و

و. (۱۳۹۱). بررسی تأثیر تغییر اقلیم روی دمای هوا و جریان رودخانه شهرچای واقع در غرب دریاچه ارومیه با استفاده از تحلیل روند و ایستایی. علوم و مهندسی آبیاری. ۳۵ (۴): ۹۷-۱۰۸.

۵. خلیلی، ک.، احمدی، ف.، دین پژوه، ی و بهمنش، ج. (۱۳۹۳). تحلیل رفتار خطی و غیرخطی سری‌های زمانی هیدرولوژیک (مطالعه موردی رودخانه‌های غرب دریاچه ارومیه). تحقیقات منابع آب ایران. ۱۰ (۲): ۱۲-۲۰.

۶. داندن مهر، ع و مجدزاده طباطبائی، م. (۱۳۸۹). بررسی تأثیر توالی دبی روزانه در پیش‌بینی جریان رودخانه‌ها با استفاده از برنامه‌ریزی ژنتیک. آب و خاک. ۲۴ (۲): ۳۲۵-۳۳۳.

۷. عباسی، ع.، خلیلی، ک.، بهمنش، ج و شیرزاد، ا. (۱۳۹۸). پیش‌بینی خشک‌سالی با استفاده از مدل ترکیبی GEP-GARCH (مطالعه موردی: ایستگاه سینوپتیک سلماس). تحقیقات آب و خاک ایران. ۵۰ (۶): ۱۳۱۷-۱۳۲۹.

۸. کاردان مقدم، ح و روزبهنی، ع. (۱۳۹۴). ارزیابی مدل شبکه‌های بیزین در پیش‌بینی ماهانل سطح آب زیرزمینی (مطالعه موردی: آبخوان بیرجند). مدیریت آب و آبیاری. ۵ (۲): ۱۵۱-۱۳۹.

۹. منتصری، م و زمان زاد قویدل، ق. (۱۳۹۳). پیش‌بینی جریان رودخانه با محاسبات نرم. آب و خاک. ۲۸ (۲): ۳۹۴-۴۰۵.

۱۰. نبی‌زاده، م.، مساعدی، ا. و دهقانی، ا. (۱۳۹۱). تخمین هوشمند دبی روزانه با بهره‌گیری از سامانه استنباط فازی-عصبی تطبیقی. مدیریت آب و آبیاری. ۲ (۱): ۸۰-۶۹.

مطالعات آتی نیز تلفیق مدل‌های سری زمانی با مدل‌های هوشمند دیگر نظیر شبکه عصبی مصنوعی، سیستم استنتاج عصبی فازی تطبیقی و برنامه‌ریزی بیان ژن مدنظر قرار گیرد.

تقدیر و تشکر

از حمایت معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در انجام این تحقیق، تشکر و قدردانی می‌گردد.

پی‌نوشت

1. Bayesian Networks
2. Augmented Dickey-Fuller test
3. Autoregressive Moving Average (ARMA)
4. Corrected Akaike Information Criterion
5. Root Mean Sauer Error (RMSE)
6. Kling Gupta Efficiency (KGE)

منابع

۱. احمدی، ف.، دین پژوه، ی.، فاخری فرد، ا و خلیلی، ک. (۱۳۹۳). مقایسه مدل‌های خطی و غیرخطی سری‌زمانی در پیش‌بینی جریان رودخانه (مطالعه موردی: رودخانه باراندوزچای ارومیه). علوم و مهندسی آبیاری. ۳۷ (۱): ۹۳-۱۰۵.
۲. احمدی، ف.، رادمنش، ف و میرعباسی نجف آبادی، ر. (۱۳۹۵). کاربرد شبکه‌های بیزین و برنامه‌ریزی ژنتیک در پیش‌بینی جریان روزانه رودخانه (مطالعه موردی: رودخانه باراندوزچای). علوم و مهندسی آبیاری. ۳۹ (۴): ۲۲۳-۲۳۱.
۳. چمنی، م. و روشنگر، ک. (۱۳۹۸). ارزیابی مدل تلفیقی تجزیه مد تجربی یکپارچه کامل-گوسی در پیش‌بینی زمانی و مکانی دبی رودخانه. مدیریت آب و آبیاری. ۹ (۲): ۲۷۷-۲۸۹.
۴. خلیلی، ک.، احمدی، ف.، بهمنش، ج و وردی نژاد،

11. Anupam, S., & Pani, P. (2020). Flood forecasting using a hybrid extreme learning machine-particle swarm optimization algorithm (ELM-PSO) model. *Modeling Earth Systems and Environment*, 6(1), 341-347.
12. Cain, J. (2001). Planning improvements in natural resource management. Guidelines for using Bayesian networks to support the planning and management of development programmers in the water sector and beyond. Centre for Ecology and Hydrology, *Crowmarsh Gifford, Wallingford Press*.
13. Chen, Y., Marek, G. W., Marek, T. H., Moorhead, J. E., Heflin, K. R., Brauer, D. K., & Srinivasan, R. (2019). Simulating the impacts of climate change on hydrology and crop production in the Northern High Plains of Texas using an improved SWAT model. *Agricultural Water Management*, 221, 13-24.
14. Desta, Y., Goitom, H., & Aregay, G. (2019). Investigation of runoff response to land use/land cover change on the case of Aynalem catchment, North of Ethiopia. *Journal of African Earth Sciences*, 153, 130-143.
15. Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366), 427-431.
16. Fathian, F., Mehdizadeh, S., Sales, A. K., & Safari, M. J. S. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models. *Journal of Hydrology*, 575, 1200-1213.
17. Gupta, A., Himanshu, S. K., Gupta, S., & Singh, R. (2020). Evaluation of the SWAT Model for Analysing the Water Balance Components for the Upper Sabarmati Basin. In *Advances in Water Resources Engineering and Management* (pp. 141-151). Springer, Singapore.
18. Kong, X., Zeng, X., Chen, C., Fan, Y., Huang, G., Li, Y., & Wang, C. (2019). Development of a maximum entropy-Archimedean copula-based Bayesian network method for streamflow frequency analysis (A case study of the Kaidu river basin, china). *Water*, 11(1), 42.
19. Kuikka, S., & Varis, O. (1997). Uncertainties of climatic change impacts in Finnish watersheds: a Bayesian network analysis of expert knowledge. *Boreal Environment Research*, 2, 109-109.
20. McCann, R. K., Marcot, B. G., & Ellis, R. (2006). Bayesian belief networks: applications in ecology and natural resource management. *Canadian Journal of Forest Research*, 36(12), 3053-3062.
21. Mehdizadeh, S., & Sales, A. K. (2018). A comparative study of autoregressive, autoregressive moving average, gene expression programming and Bayesian networks for estimating monthly streamflow. *Water Resources Management*, 32(9), 3001-3022.
22. Mehdizadeh, S., Fathian, F., & Adamowski, J. F. (2019). Hybrid artificial intelligence-time series models for monthly streamflow modeling. *Applied Soft Computing*, 80, 873-887.
23. Mohammady, M., Moradi, H. R., Zeinivand, H., Temme, A. J. A. M., Yazdani, M. R., & Pourghasemi, H. R. (2018). Modeling and assessing the effects of land use changes on runoff generation with the CLUE-s and WetSpa models. *Theoretical and Applied Climatology*, 133(2), 459-471.
24. Pollino, C. A., & Hart, B. T. (2007). Bayesian network model in natural resources management. Information sheet prepared by the Integrated Catchment Assessment and Management Centre, *Australian National University*.
25. Ravindranath, A., Devineni, N., Lall, U., Cook, E. R., Pederson, G., Martin, J., & Woodhouse, C. (2019). Streamflow Reconstruction in the Upper Missouri River Basin Using a Novel Bayesian Network Model. *Water Resources Research*, 55(9), 7694-7716.
26. Sadoddin, A., Letcher, R. A., Jakeman, A. J., & Newham, L. T. (2005). A Bayesian decision network approach for assessing the ecological impacts of salinity management. *Mathematics and Computers in Simulation*, 69(2), 162-176.
27. Salas, J. D. (1993). Analysis and modeling of hydrological time series. In: *Handbook of Hydrology*, Edited by David R, Maidment, McGraw-Hill, New York, 19, 1-19.
28. Wagena, M. B., Goering, D., Collick, A. S., Bock, E., Fuka, D. R., Buda, A., & Easton, Z. M. (2020). Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling & Software*, 126, 104669.