

## کاربرد آنتروپی شانون برای انتخاب ورودی‌های بهینه در پیش‌بینی جریان رودخانه با استفاده از مدل‌های هوشمند (مطالعه موردی: صوفی چای)

فاطمه آخونی پورحسینی<sup>۱\*</sup> و محمد علی قربانی<sup>۲</sup>

۱- نویسنده مسئول، دانشجوی کارشناسی ارشد مهندسی منابع آب، دانشکده کشاورزی، دانشگاه تبریز. fateme.pourhosseini@yahoo.com

۲- دانشیار بخش مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز.

تاریخ پذیرش: ۹۵/۱۲/۱۱

تاریخ دریافت: ۹۵/۵/۱۱

### چکیده

پیش‌بینی جریان رودخانه یکی از موارد مهم در مدیریت منابع آب‌های سطحی، بهره‌برداری از مخازن سدها، کنترل سیلاب و خشکسالی می‌باشد. انتخاب ورودی‌های مناسب برای افزایش دقت و کارایی مدل‌های هوشمند از اهمیت به‌سزایی برخوردار است. در این تحقیق به ارزیابی عملکرد آنتروپی شانون در تعیین ورودی‌های مناسب و کارایی مدل‌های، شبکه عصبی مصنوعی و شبکه بیزین، در پیش‌بینی جریان ماهانه رودخانه صوفی چای در ایستگاه تازه‌کند، در طی بازه‌ی زمانی (۱۳۵۲-۱۳۹۱) پرداخته شده است. آنتروپی شانون، به‌عنوان روشی برای بیان اطلاعات یا عدم قطعیت یک پدیده مورد استفاده قرار می‌گیرد. همچنین به‌عنوان شاخصی برای کمی کردن میزان عدم آگاهی و دانش نسبت به مشخصات یک سامانه، استفاده می‌شود. داده‌های جریان ماهانه با تأخیرهای مختلف به‌عنوان ورودی به آنتروپی شانون در نظر گرفته شد. نتایج آنتروپی نشان داد که جریان رودخانه با سه تأخیر زمانی، عملکرد بهتری نشان می‌دهد. سپس نتایج حاصل از پیش‌بینی، با دو مدل شبکه عصبی مصنوعی و شبکه بیزین مقایسه گردید. عملکرد این دو مدل با شاخص‌های آماری ضریب تبیین ( $R^2$ )، جذر میانگین مربعات خطا (RMSE) و شاخص پراکندگی (SI) ارزیابی شد. نتایج نشان داد که مدل شبکه عصبی مصنوعی با ضریب تبیین بیشتر و جذر میانگین مربعات خطا کمتر و شاخص پراکندگی کمتر در مقایسه با شبکه بیزین، از کارایی بالاتری برخوردار است و از این رو آنتروپی شانون در تعیین ترکیب بهینه‌ی ورودی‌ها به مدل‌های هوشمند مناسب می‌باشد.

کلیدواژه‌ها: آنتروپی، جریان، رودخانه صوفی چای، شبکه بیزین، شبکه عصبی مصنوعی.

### مقدمه

از آنجاکه پیش‌بینی جریان رودخانه در منابع آب از اهمیت زیادی برخوردار می‌باشد، محققین طی چندین دهه‌ی گذشته روش‌های مختلفی را در این زمینه مورد تحقیق و بررسی قرار داده‌اند (Borhani and Fatehi, 2008). به‌منظور پیش‌بینی جریان رودخانه در طی سالیان گذشته، روش‌های مختلفی ابداع شده است. به‌طور کلی می‌توان به دودسته مدل‌های مفهومی و مدل‌های مبتنی بر داده یا آماری (Data-driven method) طبقه‌بندی کرد. مدل‌های آماری، کاربردی‌تر از مدل‌های مفهومی می‌باشد. زیرا درک ساختار داخلی آن‌ها، از فرآیندهای فیزیکی مدل‌سازی، مستقل است. طی چهار دهه‌ی گذشته، مدل‌های سری زمانی، کاربرد گسترده‌ای در پیش‌بینی جریان رودخانه پیدا کرده‌اند (Dawson et al., 2008). امروزه سیستم‌های هوشمند برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد. روش شبکه بیزین (Bayesian Network) و شبکه عصبی مصنوعی (Artificial Neural Network) از جمله‌ی این روش‌ها می‌باشد. در سال‌های اخیر مدل‌های غیرخطی مانند شبکه عصبی مصنوعی به‌طور گسترده‌ای برای مدل‌سازی سری زمانی استفاده شده است. در این راستا، از شبکه‌های عصبی مصنوعی، برای غلبه بر مشکلات موجود در مدل‌سازی سری زمانی متغیرهای

هیدرولوژیکی، استفاده می‌گردد. Ahmadi et al. (2013) به مقایسه مدل‌های غیرخطی سری زمانی و برنامه‌ریزی ژنتیک، در پیش‌بینی جریان روزانه رودخانه‌ی باراندوزچای ارومیه پرداختند. نتایج نشان داد که برنامه‌ریزی ژنتیک با ۲۲/۹ درصد خطای کمتر، نسبت به مدل‌های غیرخطی سری زمانی، توانست جریان رودخانه را به‌خوبی پیش‌بینی نماید. Satari و Abdolahpour (2014) به پیش‌بینی جریان روزانه رودخانه اهر چای با استفاده از روش‌های شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی، پرداختند. نتایج نشان داد سیستم استنتاج فازی-عصبی تطبیقی با دقت بالاتری نسبت به شبکه‌های عصبی مصنوعی، توانست جریان روزانه رودخانه اهر چای را پیش‌بینی نماید. (2014) Gizilbash et al. از دوروش برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی، به‌منظور تخمین ضریب یکنواختی توزیع آب در آبیاری بارانی در ایستگاه تحقیقات پنبه هاشم‌آباد گرگان استفاده کردند. نتایج نشان داد که هر دوروش قابلیت تخمین ضریب یکنواختی را دارند از آنجایی‌که مدل بیان ژن، قادر به ارائه‌ی رابطه‌ی صریح برای تخمین ضریب یکنواختی است، جنبه‌ی کاربردی بیشتری نسبت به شبکه عصبی مصنوعی دارد. Rajaee و Ebrahimi (2013) برای پیش‌بینی ویژگی‌های غیرایستا و غیرخطی سری زمانی تراز آب زیرزمینی دشت قم، از روش مدل شبکه عصبی-

آوردن توزیع شرطی جریان بر اساس رخداد بارش معین، بیشینه نمودند. آنگاه پارامترهای تابع توزیع مذکور را بر اساس اطلاعات موجود، شامل میانگین سری زمانی داده‌های بارش، جریان و کوواریانس آن‌ها، تخمین زدند. Hui-Chung و Chiang (2014) تئوری آنتروپی انتقال اطلاعات را در طراحی شبکه‌ی باران‌سنجی در تایوان مورد استفاده قرار دادند. مطالعه‌ی موجود در مورد اثر تغییرات مکانی و زمانی بارش، با محاسبه حداکثر آنتروپی مشترک، انجام گرفت. نتایج بیانگر این بود که محاسبه حداکثر آنتروپی مشترک، با توجه به اثر تغییرات مکانی و مقایسه با مقیاس‌های زمانی بارش، در تعیین تعداد باران‌سنج‌ها برای منطقه‌ی مورد مطالعه مناسب می‌باشد.

این تحقیق با هدف نحوه‌ی استفاده از تئوری آنتروپی شانون، برای یافتن بهترین ترکیب از متغیرهای ورودی به مدل‌های هوشمند شبکه عصبی مصنوعی و شبکه بیزین، برای پیش‌بینی جریان مورد نظر می‌باشد. لذا برای این منظور رودخانه صوفی‌چای محل مورد مطالعه انتخاب گردید.

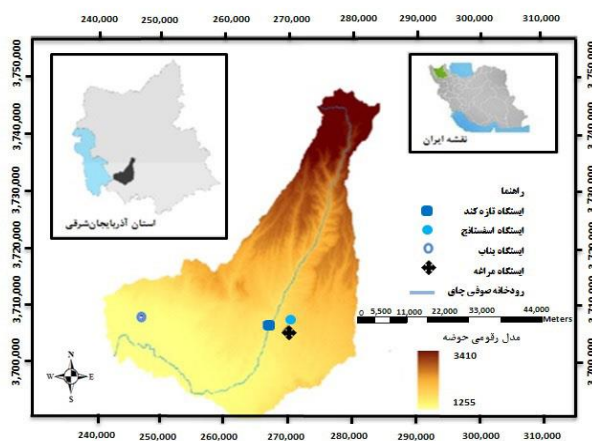
### مواد و روش‌ها

#### منطقه مورد مطالعه و داده‌های مورد استفاده


رودخانه‌ی صوفی‌چای با طول ۱۲۰ کیلومتر از دامنه‌های جنوب غربی کوه سهند واقع در استان آذربایجان شرقی سرچشمه می‌گیرد. این رودخانه در داخل حوضه‌ی آبریز صوفی‌چای، یکی از زیر حوضه‌های دریاچه ارومیه قرار دارد. در بالادست سد علویان، پنج ایستگاه هیدرومتری خرما زرد، تازه کند، چکان، اسفستانج و کهلیک دره سی احداث شده‌اند که نزدیک‌ترین ایستگاه به مخزن سد، ایستگاه تازه کند بوده و در این تحقیق از اطلاعات آن استفاده می‌گردد. در شکل (۱) موقعیت جغرافیایی منطقه مورد نظر نشان داده شده‌است. در این تحقیق، از داده‌های دبی ورودی به سد علویان از سال ۱۳۵۲ تا ۱۳۹۱ استفاده می‌گردد. شکل (۲) نمودار تغییرات جریان و در جدول (۱) خصوصیات آماری دبی در بازه‌ی زمانی مذکور آورده شده است.

موجک استفاده کردند. نتایج نشان داد که خطای این مدل در مقایسه با مدل شبکه عصبی مصنوعی و خطی چند متغیره کمتر می‌باشد. Shekhalipour et al. (2014) برای برآورد رسوب رودخانه سیستان، به مقایسه‌ی روش‌های هوش مصنوعی پرداختند. آن‌ها از سیستم‌های هوشمند، شامل شبکه‌های عصبی مصنوعی، سیستم استنتاج تطبیقی عصبی - فازی و برنامه‌ریزی بیان ژن استفاده کردند. نتایج نشان داد که هر سه روش بکار رفته، برای تخمین بار معلق رسوب مناسب می‌باشند. لیکن روش برنامه‌ریزی بیان ژن، به دلیل ارائه‌ی رابطه‌ی ریاضی، نسبت به دو مدل دیگر ارجح می‌باشد. Nikmanesh (2014) به پیش‌بینی آبدی متوسط ماهانه رودخانه‌ی کر، با استفاده از مدل تلفیقی شبکه عصبی مصنوعی و تبدیل موجک پرداخت. نتایج نشان داد مدل تلفیقی شبکه عصبی مصنوعی و تبدیل موجک، با مناسب‌ترین ساختار بهترین عملکرد را داشت. Ghorbani et al. (2016b) برای پیش‌بینی جریان ماهانه از روش‌های هیدرولوژیکی مفهومی IHACRES و روش‌های داده‌کاوی M5 و KNN در ایستگاه هیدرومتری آراز کوسه، استفاده کردند. نتایج نشان داد که کاربرد مدل‌های داده‌کاوی منجر به بهبود نتایج نسبت به کاربرد مدل هیدرولوژیکی مفهومی، گردید. هم‌چنین بررسی سری زمانی نشان داد که دقت مدل‌های داده‌کاوی در تخمین جریان‌های کم، بهتر از تخمین جریان‌های زیاد می‌باشد. Ahmadi et al. (2014) به مقایسه عملکرد روش‌های ماشین بردار پشتیبان و شبکه‌ی بیزین در پیش‌بینی جریان روزانه رودخانه باراندوزچای پرداختند. نتایج نشان داد هر دو روش از نظر تحلیل‌های آماری نزدیک به هم بوده و برای شبیه‌سازی جریان رودخانه، مناسب می‌باشد. اما در پیش‌بینی دبی متوسط و کمینه مدل ماشین بردار پشتیبان، به مراتب از مدل شبکه بیزین بهتر می‌باشند.

تئوری آنتروپی شانون اولین بار توسط شانون توسعه داده شد و سپس به‌طور گسترده در مسائل مختلف علمی مورد استفاده قرار گرفت (Shanon, 1948). Sonuga (1976) اصل حداکثر آنتروپی را برای مدل‌سازی فرآیند بارش - جریان به کار بردند. ایشان عبارت آنتروپی شرطی را بر اساس قیود معین، برای به‌دست




شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه



شکل ۲- مقادیر مشاهداتی دبی ماهانه ایستگاه هیدرومتری تازه کند (دوره زمانی ۱۳۹۱-۱۳۵۲)

جدول ۱- مشخصات آماری دبی ماهانه ایستگاه هیدرومتری تازه کند

پارامتر	کل	آموزش	صحت سنجی
تعداد	۴۸۰	۳۳۶	۱۴۴
میانگین	۳/۷۸	۴/۰۸	۳/۰۷
حداقل	۰/۳۵	۰/۵۵	۰/۳۵
حداکثر	۳۰/۹۸	۳۰/۹۸	۲۰/۱۳
انحراف معیار	۴/۵۸	۴/۸۶	۳/۶۸
ضریب چولگی	۲/۳۱	۲/۳۱	۱/۹۸
ضریب کشیدگی	۵/۹۸	۵/۷۷	۳/۸۲



شکل ۳- تابع همبستگی متقابل سری زمانی دبی ماهانه ایستگاه تازه کند

احتمال وقوع رخداد کمتر باشد، اطلاعات حاصل از آن بیشتر است. اطلاعات جدید موجب کاهش عدم قطعیتها می‌شود. از این رو ارزش اطلاعات جدید متناسب با مقداری است که از عدم قطعیت کاسته می‌شود. به دین ترتیب عدم قطعیت و اطلاعات پارامترها، وابسته به هم هستند. از تئوری آنتروپی به عنوان شاخصی برای کمی کردن موارد مربوطه استفاده می‌شود (Masoumi, 2007 و Kerachiyani).

مراحل محاسبه آنتروپی شانون به صورت زیر می‌باشد: چنانچه تعداد  $m$  نمونه برای ارزیابی  $(i=1, 2, \dots, m)$  در دسترس باشد. هر نمونه،  $n$  پارامتر  $(1, 2, \dots, n)$  داشته باشد. ماتریس داده‌های مشاهداتی  $Y$  برای نمونه‌ها، به صورت رابطه (۱) در نظر می‌باشد (Wu et al., 2015)

به منظور تخمین جریان ماه آینده، از جریان ماه‌های قبل استفاده می‌گردد. با استفاده از ماتریس همبستگی سری زمانی با تأخیر زمانی شش ماهه، ورودی به آنتروپی شانون معرفی گردید (شکل ۳). هم‌چنین جریان ماه بعد، به عنوان خروجی نامگذاری می‌شود.

به دین ترتیب شش متغیر  $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}$  و  $Q_{t-6}$  متغیرهای ورودی و  $Q_t$  به عنوان متغیر خروجی از آنتروپی شانون نام گذاری می‌شود.

### تئوری آنتروپی شانون

Shannon در سال (۱۹۴۸) نشان داد وقایع با احتمال وقوع زیاد، اطلاعات کمتری از خود نشان می‌دهد. برعکس هرچه قدر،

از اثرات متقابل متغیرهایی است که میبایست الگوبندی شوند و در شبکه بیزین علاوه بر اینکه کیفیت رابطه بین متغیرهای مسئله را نشان داده می‌شود، کمیت ارتباط بین متغیرها نیز به نمایش گذاشته می‌شود. این روش بر مبنای محاسبات احتمالات شرطی (قانون بیز) بوده که معادله زیر، رابطه بیز را نشان می‌دهد. (Davies, 2007)

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

که در رابطه (۷)  $P(a)$  احتمال وقوع پیشامد  $a$ ،  $P(b)$  احتمال وقوع پیشامد  $b$ ،  $p(a|b)$  احتمال وقوع پیشامد  $a$  به شرطی که پیشامد  $b$ ،  $p(b|a)$  احتمال وقوع پیشامد  $b$  به شرطی که پیشامد  $a$  اتفاق بیافتد.

شبکه‌ی بیزین طبق تعریف عبارت از: تعدادی گره که نشان دهنده‌ی آن دسته از متغیرهای تصادفی هستند که با یکدیگر در تعامل می‌باشند. این برهم کنش، به وسیله‌ی ارتباط بین گره‌ها ایجاد می‌شود (Cain, 2001). متغیرهایی که در مسایل زیست محیطی و منابع آب به کار می‌روند، می‌توانند کمی یا کیفی باشند. تعیین تعداد مناسبی از متغیرها در مدل‌سازی، از مسائل چالش برانگیزی است که باید با دقت به آن پرداخته شود. قانون احتمالات اعمال شده نیز باید بر مبنای بهترین یافته‌های موجود یا اطلاعات کمی و کیفی بین متغیرها باشد. پیشنهادها و تصمیم‌هایی که برای اجرا ارائه می‌شود، بر اساس حداکثر سود پیش بینی شده است (Mohajerani et al., 2010).

هر شبکه بیزین از سه جز تشکیل شده است:

۱- گره‌ها، که در واقع متغیرهای سیستم مدیریتی هستند. این گره‌ها می‌توانند متغیرهای پیوسته و ناپیوسته، اعداد ثابت و یا توابع پیوسته باشند. هر گره به چند طبقه و یا کلاس تقسیم می‌شود. گره‌ها از نظر نوع متغیر به دو گروه والد و ولد تقسیم می‌شوند گره والد متغیر مستقل گره ولد در برگیرنده متغیر وابسته می‌باشد. با توجه به این برخی گره‌ها ولد که حاوی متغیرهای وابسته است از چندین گره والد که در واقع متغیر مستقل می‌باشد تشکیل می‌شود.

۲- بندها روابط سببی بین متغیرها اطلاع می‌شوند. (Sadedin et al. 2005) این روابط به وسیله‌ی پیکان نمایش داده شده است. عدم وجود پیکان بین گره‌ها، بیان‌گر استقلال متغیرها می‌باشد (Pollino and Hart, 2006). گره‌هایی که هیچ پیکانی به آن‌ها وارد نشود، گره‌های والد ورودی هستند. گرهی که پیکان به آن وارد و از آن خارج شود، بیان‌گر گره ولد وضعیت می‌باشد و گره‌هایی که از آن‌ها هیچ پیکانی وارد نشود نشان دهنده‌ی 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 (Pollino and Hart, 2006).

$$Y = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \quad (۱)$$

با توجه به یکسان بودن دیمانسیون پارامترهای ورودی، معمولاً با استفاده از تابع نرمال‌سازی، داده‌ها آماده‌سازی می‌شوند. روش‌های متعددی به منظور نرمال‌سازی وجود دارند. در مطالعه‌ی حاضر از رابطه‌ی (۲) برای نرمال‌سازی داده‌ها استفاده شده است.

$$y_{ij} = \frac{x_{ij} - x_{ij\min}}{x_{ij\max} - x_{ij\min}} \quad (۲)$$

ماتریس داده‌های مشاهداتی، پس از نرمال‌سازی به صورت رابطه (۳) می‌باشد:

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{m1} & y_{m2} & \dots & y_{mn} \end{bmatrix} \quad (۳)$$

مقدار شاخص پارامتر  $j$  ام در نمونه  $i$  ام بر اساس رابطه (۴) محاسبه می‌شود (Kerachiyani و Masoumi, 2007):

$$P_{ij} = \frac{y_{ij}}{\sum_{i=1}^m y_{ij}} \quad (۴)$$

که در رابطه (۴)  $P_{ij}$  احتمال وقوع مشترک  $i$  و  $j$  می‌باشد. بدین منظور احتمال  $P_{ij}$  در رابطه (۴) ممکن است صفر شود و صفر شدن این پارامتر در معادلات بعدی مشکل ایجاد خواهد کرد تصحیح رابطه‌ی (۴) به صورت رابطه‌ی (۵) انجام می‌شود (Ren و Zhang 2011).

$$P_{ij} = \frac{(y_{ij} + 0.0001)}{\sum_{i=1}^m (y_{ij} + 0.0001)} \quad (۵)$$

اطلاعات آنتروپی به صورت رابطه‌ی (۶) بیان می‌شود:

$$e_j = - \frac{1}{\ln m} \sum_{i=1}^m P_{ij} \ln P_{ij} \quad (۶)$$

### شبکه بیزین

شبکه بیزین، الگوی نموداری احتمالات شامل مجموعه‌ای از متغیرها و احتمال متناظر به هر یک می‌باشد. یک گراف مستقیم و غیرچرخه‌ای است که در آن، گره‌ها بیانگر متغیرهای مسئله می‌باشد. ساختار یک شبکه بیزین، در واقع نمایش نموداری

مدل‌های شبکه عصبی مصنوعی مقاومت‌های اتصالی بین نرون‌ها می‌باشند که به‌عنوان وزن و اربب نامیده می‌شوند. لایه‌های مختلف در شبکه عصبی و همچنین نرون‌های موجود در لایه‌ها می‌توانند دارای توابع تحریک متفاوت یا یکسانی باشند. شبکه‌های عصبی از نظر ساختار و ارتباطات بین نرون‌ها به گروه‌های مختلفی تقسیم می‌شوند. شبکه پرسپترون چندلایه رایج‌ترین مدل شبکه عصبی استفاده‌شده در مسائل آبی می‌باشد که برای آموزش شبکه از الگوریتم پس انتشار خطا که یک روش یادگیری با ناظر است، استفاده می‌شود.

#### تجزیه و تحلیل داده‌ها

برای استفاده از داده‌های موردنیاز در مدل‌های شبکه بیزین و شبکه عصبی مصنوعی ابتدا داده‌ها به‌صورت تصادفی به دو قسمت تقسیم‌بندی شدند. ۷۰ درصد داده‌های اولیه برای آموزش مدل ۳۰ درصد انتهایی داده‌ها برای بخش صحت سنجی استفاده گردید (Ghorbani et al., 2016a)

به‌منظور افزایش کارایی مدل، همه داده‌ها ابتدا به شکل نرمال بین دو عدد ۰ و ۱ استاندارد می‌شوند (Xu et al., 2007).

$$X_n = \frac{X_i - X_{max}}{X_{min} - X_{max}} \quad (8)$$


در این رابطه  $X_i$  داده‌های مشاهداتی،  $X_n$  داده‌های استاندارد شده،  $X_{min}$  و  $X_{max}$  به ترتیب معرف داده‌های حداکثر و حداقل می‌باشد.

از نرم‌افزار GeNIe2.0 برای شبیه‌سازی با شبکه بیزین استفاده شد. خطای همگرایی ۰/۰۰۱ انتخاب گردید.

۳- مجموعه‌ای از احتمالات: هر کدام برای متغیر، شرایط تصمیمی را مشخص می‌کنند. این شرایط از طریق متغیرهایی که مستقیماً آن را تحت تاثیر قرار می‌دهند، به آن نسبت داده می‌شوند (Cain, 2001). گره‌هایی که قبل از آن‌ها گره دیگری در گراف وجود دارد با توزیع احتمال شرطی تعریف می‌شود، در غیر این صورت، با احتمال آغازین بیان می‌شوند. احتمال شرطی، احتمال میزان تاثیر یک گره ورودی به یک گره مفروض در شبکه و احتمال آغازین، بیانگر میزان احتمال قراردادی یک متغیر ورودی در یک رسته معین می‌باشد. احتمالات مربوط به پایین‌ترین بخش به شبکه بیزین از طریق قانون احتمال کلی به دست می‌آید و احتمال‌های مرتبط با بخش‌های بالایی شبکه، براساس قانون بیز می‌باشند. بنا به تعریف، اگر گره  $x$  دارای والد نباشد گره غیر مشروط و در غیر این صورت گره مشروط می‌باشد (Kuikka and Varis, 1997). شکل (۴) نمونه‌ای از ساختار شبکه بیزین را نشان می‌دهد.

#### شبکه عصبی مصنوعی

گرایش به استفاده از شبکه عصبی مصنوعی روند روبه رشدی داشت که شبکه‌ها با هر اندازه عملی نمی‌توانند به‌طور مؤثری آموزش ببینند. در حالت کلی شبکه عصبی مصنوعی دارای سه لایه می‌باشد (شکل (۵)). لایه ورودی که وظیفه آن معرفی پارامترها به شبکه می‌باشد لایه خروجی محل استقرار پارامترهای خروجی شبکه و لایه پنهان، لایه‌های مابین لایه ورودی و خروجی می‌باشد که نقش پردازشگری اطلاعات را بر عهده دارد. یک شبکه عصبی مصنوعی علائم را از واحدهای ورودی دریافت کرده و این سیگنال‌ها، در طول شبکه انتشار یافته و در نهایت به‌سوی نرون خروجی حرکت می‌نماید. پارامترهای کنترلی اصلی



شکل ۴- نمایش گراف مستقیم و چرخه‌ای شبکه بیزین

$$SI = \frac{\frac{1}{n} \sum_{i=1}^n |x_i - y_i|}{\bar{x}} \quad (11)$$


برای مقایسه داده‌های مشاهداتی و پیش‌بینی شده از شاخص‌های آماری ضریب تبیین ( $R^2$ )، ریشه متوسط مربعات خطا (RMSE) و شاخص پراکندگی (SI) استفاده گردید (Dehghani و Ghorbani, 2015).

**نتایج و بحث**


در تحقیق حاضر، با توجه به شکل (۶) می‌توان نتیجه گرفت که تأثیر  $Q_{(t-1)}$ ،  $Q_{(t-2)}$  و  $Q_{(t-3)}$  به ترتیب بر میزان خروجی  $Q_t$  نسبت به سایر پارامترها بیشتر بوده و می‌توان به‌عنوان ترکیب بهینه‌ی پارامترهای ورودی به مدل‌ها معرفی گردد. جدول شماره (۲) مقادیر شاخص آماری محاسبه‌شده مربوط به نتایج بخش آموزش و صحت‌سنجی در هر دو مدل شبکه عصبی مصنوعی و شبکه بیزین را نشان می‌دهد.

$$R^2 = \left[ \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \cdot \sum_{i=1}^N (y_i - \bar{y})^2}} \right]^2 \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (10)$$



شکل ۵- ساختار کلی یک شبکه عصبی مصنوعی چندلایه




شکل ۶- مقدار آنتروپی پارامترهای مورد استفاده در ایستگاه تازه کند

جدول ۲- نتایج شبکه بیزین و شبکه عصبی مصنوعی استفاده‌شده در مراحل آموزش و صحت‌سنجی


صحت سنجی			آموزش			پارامترهای ورودی	ساختار	نام مدل
RMSE(m <sup>3</sup> /s)	SI	R <sup>2</sup>	RMSE(m <sup>3</sup> /s)	SI	R <sup>2</sup>			
۴/۷۱۸	۰/۶۶۳	۰/۳۵۷	۷/۵۲۳	۱/۷۳۲	۰/۴۲۲	$Q_{t-1}$	(۱-۹-۱)	شبکه
۳/۵۱۴	۰/۸۱۶	۰/۴۶۷	۴/۲۴۱	۰/۷۶۱	۰/۵۹۳	$Q_{t-1}, Q_{t-2}$	(۲-۱۱-۱)	بیزین (BN)
۲/۸۷۱	۰/۵۵۰	۰/۴۵۴	۳/۴۱۲	۰/۴۸۵	۰/۵۹۷	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	(۳-۱۲-۱)	شبکه
۲/۹۶۷	۰/۶۱۳	۰/۳۷۲	۳/۴۲۷	۰/۵۳۸	۰/۵۵۵	$Q_{t-1}$	(۱-۲۰-۱)	عصبی مصنوعی
۲/۶۳۲	۰/۴۵۳	۰/۵۴۱	۳/۰۶۲	۰/۴۶۴	۰/۶۵۳	$Q_{t-1}, Q_{t-2}$	(۲-۱۵-۱)	شبکه
۲/۴۷۷	۰/۴۴۲	۰/۵۶۵	۲/۵۴۹	۰/۳۸۶	۰/۷۵۲	$Q_{t-1}, Q_{t-2}, Q_{t-3}$	(۳-۱۳-۱)	(ANN)

آموزش میزان  $R^2$  برابر با ۰/۷۵۲ است که نسبت به ترکیبات قبلی بزرگتر می‌باشد. همچنین میزان شاخص پراکندگی ۰/۳۸۶ و جذر میانگین مربعات خطا ۲/۵۴۹ است. در بخش صحت‌سنجی نیز وضعیت به همین ترتیب می‌باشد. مقدار  $R^2$  در سومین ترکیب این بخش، بزرگتر از ترکیبات قبلی و برابر با ۰/۵۶۵ است. میزان شاخص پراکندگی ۰/۴۴۲ و جذر میانگین مربعات خطا ۲/۴۷۷ می‌باشد که نسبت به تمام ترکیب‌های مدل‌سازی شده از دقت بیشتری برخوردار می‌باشد. در شکل (۱۰)، مقادیر مشاهده‌ای و پیش‌بینی‌شده برای ترکیب سوم نشان داده شده‌است. در شکل (۷) و (۸) میزان ضریب تبیین، جذر میانگین مربعات خطا و شاخص پراکندگی در بخش آموزش و صحت‌سنجی برای دو مدل شبکه بیزین و شبکه عصبی مصنوعی نشان داده شده‌است.

همان‌طور که در جدول (۲) مشاهده می‌شود، میزان  $R^2$  در بخش آموزش سومین ترکیب مدل شبکه بیزین برابر با ۰/۵۹۷ به دست آمده که نسبت به ترکیبات قبلی بزرگتر می‌باشد. همچنین میزان شاخص پراکندگی  $SI=0/485$  و جذر میانگین مربعات خطا  $RMSE=3/412 (m^3/s)$  است. در بخش صحت‌سنجی نیز وضعیت به همین ترتیب است. مقدار  $R^2$  در سومین ترکیب این بخش، بزرگتر از ترکیبات قبلی و برابر با ۰/۴۵۴ است. میزان شاخص پراکندگی  $SI=0/55$  و جذر میانگین مربعات خطا  $RMSE=2/871 (m^3/s)$  هستند. در شکل (۹)، مقادیر مشاهده‌ای و پیش‌بینی‌شده برای ترکیب سوم نشان داده شده‌است. نتایج حاصل از شبیه‌سازی با شبکه عصبی مصنوعی با مینیمم میزان یادگیری ۰/۰۰۱ و ماکزیمم میزان یادگیری ۰/۳ و ضریب مونتوم ۰/۸ نشان می‌دهد ترکیب سوم در جدول (۲) در بخش




شکل ۷- مقایسه نتایج مدل شبکه عصبی مصنوعی و شبکه بیزین در مرحله‌ی آموزش برای پیش‌بینی جریان در ایستگاه تازه کند




شکل ۸- مقایسه نتایج مدل شبکه عصبی مصنوعی و شبکه بیزین در مرحله‌ی صحت‌سنجی برای پیش‌بینی جریان در ایستگاه تازه کند





شکل ۹- مقادیر مشاهده‌ای و پیش‌بینی شده دبی ایستگاه تازه کند رودخانه صوفی چای با شبکه عصبی مصنوعی (ترکیب ۳) بخش آموزش و صحت سنجی



شکل ۱۰- مقادیر مشاهده‌ای و پیش‌بینی شده دبی ایستگاه تازه کند رودخانه صوفی چای با شبکه بیزین (ترکیب ۳) بخش آموزش و صحت سنجی

شاخص‌های اقلیمی یک سال قبل توانست جریان یک سال بعد را با دقت قابل قبولی پیش‌بینی نماید.

### نتیجه‌گیری

شبیه‌سازی جریان رودخانه، یکی از مولفه‌های مهم در مدیریت منابع آب و پیش‌بینی سیلاب می‌باشد. از طرفی، انتخاب ترکیبی مناسب برای شبیه‌سازی یکی از عوامل تاثیر گذار در مدل سازی به شمار می‌آید. در این تحقیق، برای تعیین ترکیبی مناسب از متغیرهای ورودی، از روش آنتروپی شانون استفاده گردید. همچنین جریان ماهانه رودخانه‌ی صوفی‌چای، با استفاده از شبکه‌ی عصبی مصنوعی و شبکه‌ی بیزین تخمین زده شد و با معیارهای ارزیابی مورد مقایسه قرار گرفت. به طور کلی نتایج حاصل از تحقیق، به صورت زیر خلاصه می‌شود:

نتایج مطالعه‌ی حاضر، در مجموع شبکه عصبی مصنوعی را به عنوان یک روش دقیق برای پیش‌بینی جریان رودخانه صوفی‌چای پیشنهاد می‌کند. این پیشنهاد، با نتایج حاصل از مطالعات Selgi et al. (2014) که به پیش‌بینی جریان ماهانه در حوضه رودخانه شور قروه با شبکه عصبی مصنوعی پرداختند. نتایج نشان داد شبکه عصبی مصنوعی جریان ماهانه این رودخانه را با دقت نسبتاً بالایی می‌تواند شبیه‌سازی کند. Jalali et al. (2015) برای پیش‌بینی جریان رودخانه حوضه قره آغاج استان فارس از روش شبکه عصبی مصنوعی بهره بردند. نتایج نشان داد که شبکه عصبی مصنوعی با تابع یادگیری LM کارایی بهتری را نشان می‌دهد. در تحقیق که، Fatehi و Borhani (2008) در پیش‌بینی جریان حوضه آبریز نازلوچای یکی از زیرحوضه‌های دریاچه‌ی ارومیه انجام دادند، شبکه عصبی مصنوعی با



ارزیابی شبکه‌ی عصبی مصنوعی و شبکه‌ی بیزین بر مبنای سه آماره‌ی  $R^2$  و  $SI$  و  $RMSE$  نشان می‌دهد که دقت شبیه‌سازی شبکه‌ی عصبی مصنوعی نسبت به شبکه‌ی بیزین بیشتر بوده و از خطای کمتری برخوردار می‌باشد. در مجموع نتایج تحقیق نشان می‌دهد، شبکه عصبی مصنوعی به عنوان یک روشی با خطای کمتر و دقت بیشتر جهت شبیه سازی جریان رودخانه‌ی صوفی چای مناسب می‌باشد.

ترکیب بهینه‌ی ورودی به دو مدل شبکه عصبی مصنوعی و شبکه بیزین با استفاده از آنتروپی شانون به دست آمد که شامل جریان ماهانه با یک ماه تاخیر ( $Q_{t-1}$ )، جریان ماهانه با دوماه تاخیر ( $Q_{t-2}$ ) و جریان ماهانه با سه ماه تاخیر ( $Q_{t-3}$ ) می‌باشد. استفاده از آنتروپی شانون در تعیین ترکیب بهینه به عنوان یک روش نوین، باعث صرفه جویی در وقت و افزایش دقت مدل‌ها در شبیه سازی می‌شود.

#### منابع

- 1- Abdolohpour, M.R., and Satari, M.T., 2014. Prediction of Ahar River flow by using artificial neural networks and comparing it with fuzzy-neural network inference system. *Journal of Water and Soil Conservation*, 22(1), pp. 287-298 ( In Persian).
- 2- Ahmadi, F., Radmanesh, F. and Mirabasi Najafabadi, R., 2014. Comparing the performance of Support Vector Machines and Bayesian networks in predicting daily river flow (Case study: Baranduz Chai River), *Journal of Water and Soil Conservation*, 22(6), pp.171-186 ( In Persian).
- 3- Ahmadi, F., Dinpazhoh, Y. Fakherifard, A. and Darbandi, S., 2013. Comparing nonlinear time series models and genetic programming for daily river flow forecasting (Case study: Barandouz-Chai River), *Journal of Water and Soil Conservation*, 22(1), pp.151-169 ( In Persian).
- 4- Bohrani, A. and Fatehi, A., 2008. Application of Artificial Neural Network in Stream Flow Forecasting using Climatic Indices (Case Study: Nazloochay River Basin), *Journal of Civil and Environmental Engineering University of Tabriz*, 35(3), pp. 51-62.( In Persian).
- 5- Cain, J. 2001. *Planning improvement in natural resource management*. Centre for Ecology and Hydrology (CEH). Wallingford, UK.
- 6- Chiang, W. Hui-Chung, Y. 2014. Spatiotemporal Scaling Effect on Rainfall Network Design Using Entropy. *Journal of Entropy*. 16, pp. 4626-4647.
- 7- Davies, P. 2007. *Conservation of Freshwater Ecosystem Values Project*, Department of Primary Industries and Water Resources Division.
- 8- Dawson, C.W. Abrahart, R.J. Shamseldin, A.Y. Wibly, R.L. 2008. Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*. 319, pp. 391-409.
- 9- Ghorbani, M.A. Ahmad Zadeh, H. Isazadeh, M. Terz, O. 2016a. A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction, *Journal Environmental Earth Science*. 75., pp.465-476.
- 10- Ghorbani, Kh., Sohrabiyan, A. and Salari jezi, M., 2016b. Assessment of hydrological and data mining methods in simulating and predicting monthly flow flow (Case study: Arzakoush Hydrometry Station), *Journal of Water and Soil Conservation*, 23(1), pp. 203-217.( In Persian).
- 11- Ghorbani, M.A., and Dehgani, R., 2015. Application of Bayesian Neural Networks, Support Vector Machines and Gene Expression Programming Analysis of Rainfall - Runoff Monthly (Case Study: Kakarza River). *Journal of Irrigation Sciences and Engineering*, 20. 39(2), pp.125-138.( In Persian).
- 12- Gizilbash, Z., Zakeriniya, M. Hezarjaribi, A. and Dehgani, A., 2014. Performance comparison of gene expression programming and artificial neural network methods to estimate water distribution uniformity in sprinkler irrigation, *Journal of Water and Soil Conservation*, 22(6), pp. 95-114.( In Persian).

- 13- Jalali, M., Pirniya, A. Soleimani, K. and Habibneghad roshan, M.,2015. Investigating the Function of Artificial Neural Network in River Flow Forecasting (Case Study: Ghareaghaj Basin of Fars Province). *Journal of the Ecosystem of Desert Engineering*,6(4), pp.15-26.( In Persian).
- 14- Kuikka S. and O., Varis 1997. Uncertainties of climate change impacts in Finnish watersheds: a Bayesian network analysis of expert knowledge, *Journal of Boreal Environment Research*. 2,pp.109-128.
- 15- Masoumi, F. and Kerachiyani, R., 2007. Optimal Design of Groundwater Groundwater Quality Monitoring Systems Using Discrete Entropy Theory Case Study: Tehran Aquife, *Third National Congress of Civil Engineering, Shahid Beheshti, Tehran*. ( In Persian).
- 16- Mohajerani, H., Mosaedi, A. Kholgi, M. and Meftah halgi, M., 2010. Introduction of business decision making networks and its application in water resource management, *First National Conference on Coastal Water Resources Management.Sari, Mazandaran*. ( In Persian).
- 17- Nikmanesh, M., 2014. Prediction of monthly average discharge using the hybrid model of artificial neural network and wavelet transforms (Case study: KorRiver-Pol-e-Khan Station), *Journal of Water and Soil Conservation*, 22(3) ,pp. 231-239.( In Persian).
- 18- Pollino, C. and Hart, B., 2006. Bayesian network models in natural resource management. *Integrated Catchment Assessment and Management (ICAM) Centre of the Australian*. National water commission.
- 19- Rajaei, T. and Ebrahimi, H., 2013. Application of neural network-wavelet model for prediction of non-stationary and non-linear characteristics of time series of groundwater level. *Journal of Water and Soil Conservation*,22(5), pp.99-115 ( In Persian).
- 20- Sadedin, A., Letcher, R. A., Jackeman, A. J. and Newham L. A., 2005. Bayesian decision network approach for assessing the ecological impact of salinity management. *Journal of Mathematics and Computer in Simulation*, 69, pp. 162-176.
- 21- Selgi, A., Radmanesh, F. and Soltani, K., 2014. Intelligent Modeling of the Monthly Period of Shur Ghorve River Basin with Artificial Neural Network. *Journal of Water and Soil Conservation*, 22(1), pp. 309-318.( In Persian).
- 22- Shannon, CE. 1948. A mathematical theory of communications, *Journal of The Bell System Technical*, 27,pp. 379-423.
- 23- Sheikhalipour, Z., Hasanpour, F. and Azimi, V.,2014. Comparison of artificial intelligence methods in estimation of suspended sediment load (Case Study: Sistan River), *Journal of Water and Soil Conservation*, 22(2) ,pp. 41-60.( In Persian).
- 24- Sonuga, J.O., 1976. Entropy principle applied to the rainfall-runoff process. *Journal of Hydrology*, 30(1-2), pp.81-94.
- 25- Xu, L. J. Wang, J. Guan, and F. Huang. 2007. A Support Vector Machine Model for Mapping of Lake Water Quality from Remote-Sensed Images. *Journal of Intelligent Computing in Medical Sciences & Image Processing* , 1(1),pp. 57-66.
- 26- Wu, J. Li, P. and Qian, H. 2015. On the sensitivity of entropy weight to sample statistics in assessing water quality statistical analysis based on large stochastic samples. *Journal of Environmental Earth Science*. 74, pp.2185-2195.
- 27- Zhang JL, Ren J. 2011. The deficiencies and amendments of the calculation formulate of entropy and entropy weight in the theory of entropy. *Journal of Statistics and Information Forum China Academic*, 26(1), pp.1-5 (in Chinese).