علوم و مهندسی آبیاری
جلد ۴۱، شماره‌ی۲، تابستان ۹۷، ص. ۱۹۵-۱۸۳

کاربرد آنتروپی شانون برای انتخاب ورودی‌های بهینه درپیش‌بینی جریان رودخانه بااستفاده از مدل‌های هوشمند(مطالعه موردی: صوفی چای)

فاطمه آخونی پورحسینی[1*] و محمد علی قربانی[2]

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 دریافت: ۹۵/۵/۱۱ تاریخ پذیرش: ۹۵/۱۲/۱۱

چکیده

پیش‌بینی جریان رودخانه یکی از موارد مهم در مدیریت منابع آب‌های سطحی، بهره برداری از مخازن سدها، کنترل سیلاب و خشکسالی می‌باشد. انتخاب ورودی‌های مناسب برای افزایش دقت وکارایی مدل‌های هوشمند از اهمیت به‌سزایی برخوردار است. در این تحقیق به ارزیابی عملکرد آنتروپی شانون درتعیین ورودی‌های مناسب و کارایی مدل‌های، شبکه عصبی مصنوعی و شبکه بیزین، در پیش‌بینی جریان ماهانه‌ی رودخانه‌ی 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 مورداستفاده 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 گرفته‌شد. 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 برخورداراست و ازاین 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

ازآنجاکه پیش‌بینی جریان رودخانه در منابع آب از اهمیت زیادی برخوردار می‌باشد، محققین طی چندین دهه‌ی گذشته روش‌های مختلفی را در این زمینه موردتحقیق و بررسی قرار داده‌اند(Borhani and Fatehi, 2008). به‌منظور پیش‌بینی جریان رودخانه در طی سالیان گذشته، روش‌های مختلفی ابداع‌شده است. به‌طورکلی می‌توان به دودسته مدل‌های مفهومی و مدل‌های مبتنی برداده 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 پیداکرده‌اند (Dawson et al., 2008). امروزه سیستم‌های هوشمند برای پیش‌بینی پدیده‌های غیرخطی مورداستفاده قرار می‌گیرد. روش شبکه بیزین (Bayesian Network) و شبکه عصبی مصنوعی (Artificial Neural Network) ازجمله‌ی 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. Abdolahpour و Satari (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 رادارند ازآنجایی‌که مدل بیان ژن، قادر به ارائه‌ی رابطه‌ای 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–

موجک استفاده کردند. نتایج نشان داد که خطای این مدل در مقایسه با مدل شبکه عصبی مصنوعی و خطی چند متغیره کمتر می‌باشد. Sheikhalipour 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 آبدهی 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 ازنظر تحلیل-های آماری نزدیک به هم بوده و برای شبیه‌سازی جریان رودخانه، مناسب می‌باشد. اما در پیش‌بینی دبی متوسط و کمینه مدل ماشین بردار پشتیبان، به‌مراتب از مدل شبکه بیزین بهتر می‌باشند.

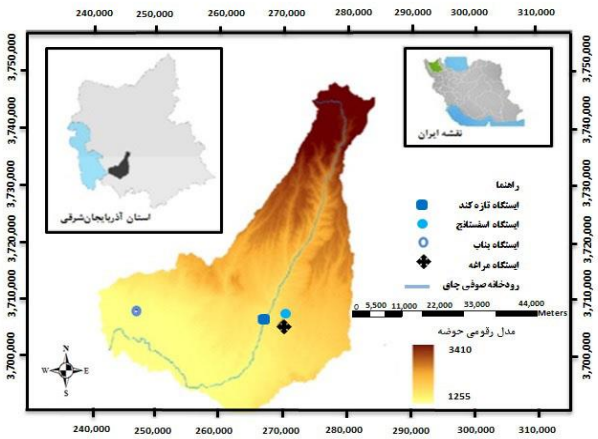
تئوری آنتروپی شانون اولین بار توسط شانون توسعه داده شد و سپس به‌طور گسترده در مسائل مختلف علمی مورداستفاده قرارگرفت (Shanon,1948). Sonuga (1976) اصل حداکثر آنتروپی را برای مدل‌سازی فرآیند بارش- جریان به کاربردند. ایشان عبارت آنتروپی شرطی را بر اساس قیود معین، برای به‌دست آوردن توزیع شرطی جریان بر اساس رخداد بارش معین، بیشینه نمودند آنگاه پارامترهای تابع توزیع مذکور را بر اساس اطلاعات موجود، شامل میانگین سری زمانی داده‌های بارش، جریان وکوواریانس آن‌ها، تخمین زدند. Chiang و Hui-Chung (2014) تئوری آنتروپی انتقال اطلاعات را در طراحی شبکه‌ی باران‌سنجی در تایوان مورداستفاده قراردادند. مطالعه‌ی موجود در مورد اثر تغییرات مکانی و زمانی بارش، با محاسبه حداکثرآنتروپی مشترک، انجام گرفت. نتایج بیانگر این بود که محاسبه حداکثرآنتروپی مشترک، با توجه به اثر تغییرات مکانی و مقایسه با مقیاس‌های زمانی بارش، در تعیین تعداد باران‌سنج‌ها برای منطقه‌ی موردمطالعه 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 پیش بینی جریان مورد نظر می باشد. لذا برای این منظور رودخانه صوفی‌چای محل مورد مطالعه انتخاب گردید.

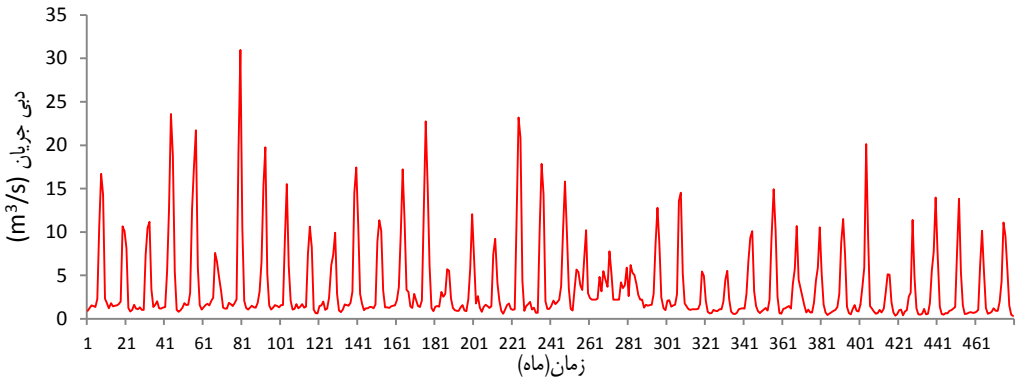
مواد و روش‌ها

منطقه موردمطالعه و داده‌های مورداستفاده

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



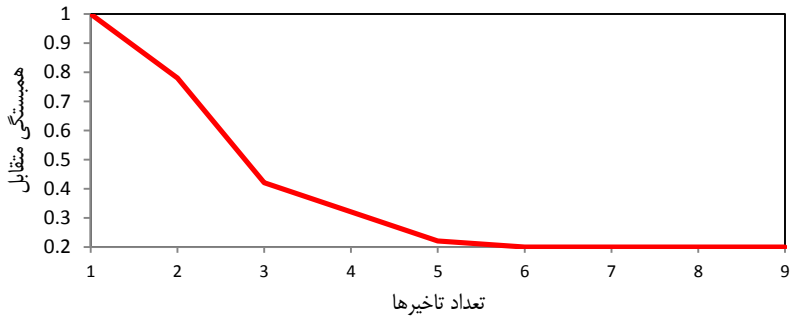
شکل ۱-موقعیت جغرافیایی منطقه موردمطالعه



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

جدول۱- مشخصات آماری دبی ماهانه ایستگاه هیدرومتری تازه‌کند

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



شکل۳- تابع همبستگی متقابل سری زمانی دبی ماهانه ایستگاه تازه کند

به‌منظور 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 (شکل۳). هم‌چنین جریان ماه بعد، به‌عنوان خروجی نامگذاری می‌شود.

به‌دین‌ترتیب شش متغیر Q_{t-1}، Q_{t-2}، Q_{t-3}، Q_{t-4}، Q_{t-5}وQ_{t-6} متغیرهای ورودی و Q_t به‌عنوان متغیر خروجی از آنتروپی شانون نام‌گذاری می شود.

تئوری آنتروپی شانون

Shannon در سال (۱۹۴۸) نشان داد وقایع با احتمال وقوع زیاد، اطلاعات کمتری از خود نشان می‌دهد. برعکس هرچقدر، 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 دین‌ترتیب عدم قطعیت و اطلاعات پارامترها، وابسته به هم هستند. از تئوری آنتروپی به‌عنوان شاخصی برای کمی کردن موارد مربوطه استفاده می‌شود (Masoumi ,2007 و Kerachiyan,).

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

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

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

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

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

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

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

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

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) به‌صورت رابطه‌ی (۵) انجام می‌شود (Zhang و Ren 2011) .

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

اطلاعات آنتروپی به‌صورت 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، درواقع نمایش نموداری از اثرات متقابل متغیرهایی است که میبایست الگوبندی شوند و درشبکه 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 برمبنای بهترین یافته‌های موجود یا اطلاعات کمی و کیفی بین متغیرها باشد. پیشنهادها و تصمیم‌هایی که برای اجرا ارائه می‌شود، براساس 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. گره ها از نظر نوع متغیر به دو گروه والد و ولد تقسیم می شوند 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).

۳- مجموعه‌ای از احتمالات: هرکدام برای متغیر، شرایط تصمیمی را مشخص می‌کنند. این شرایط از طریق متغیرهایی که مستقیما 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 هراندازه 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 انتشاریافته و درنهایت به‌سوی نرون خروجی حرکت می‌نماید. پارامترهای کنترلی اصلی مدل‌های شبکه عصبی مصنوعی مقاومت‌های اتصالی بین نرون‌ها می‌باشند که به‌عنوان وزن و اریب نامیده می‌شوند. لایه‌های مختلف در شبکه عصبی و همچنین نرون‌های موجود در لایه‌ها می‌توانند دارای توابع تحریک متفاوت یا یکسانی باشند. شبکه‌های عصبی ازنظر 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.

تجزیه‌وتحلیل داده‌ها

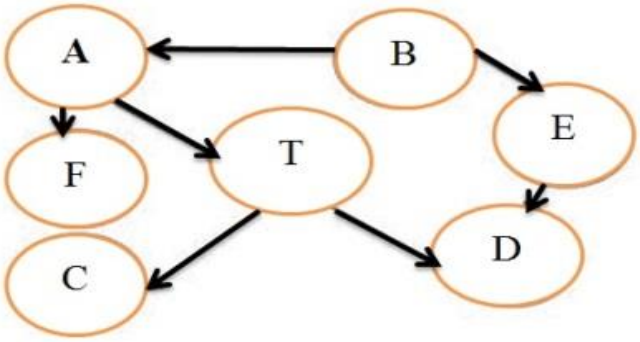
برای استفاده از داده‌های موردنیاز در مدل‌های شبکه بیـزین و شبکه عصبی مصنوعی ابتدا داده‌ها به‌صورت تصادفی به دو قسمت تقسیم‌بندی شدند. ۷۰ درصد داده‌های اولیه بـرای آمـوزش مـدل ۳۰درصد انتهایی داده‌ها برای بخش صحت سنجی استفاده گردید (Ghorbani et al., 2016a)

به‌منظور افزایش کارایی مدل، همه داده‌ها ابتدا به شکل نرمال بین دو عدد ۰و۱استاندارد می‌شوند(Xu et al.,2007).

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

در این رابطه X_iداده‌های مشاهداتی، X_nداده‌هـای استانداردشـده، X_{max}وX_{min} بـه ترتیـب معـرف داده‌هـای حـداکثر و حـداقل می‌باشد.

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



شکل ٤- نمایش گراف مستقیم و چرخه‌ای شبکه بیزین

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

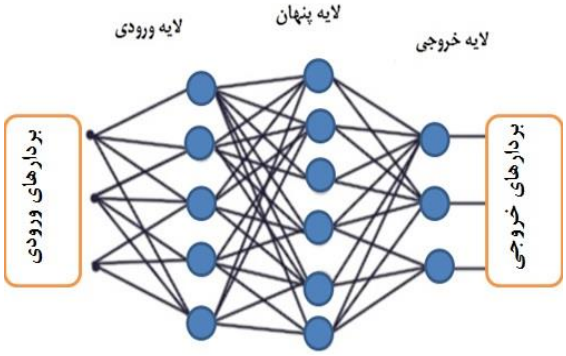
$$R^2 = [\frac{\sum_N^{i=1}(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_N^{i=1}(x_i-\bar{x})^2.\sum_N^{i=1}(y_i-\bar{y})^2}}]^2 \quad (۹)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(x_i-y_i)^2}{N}} \quad (۱۰)$$

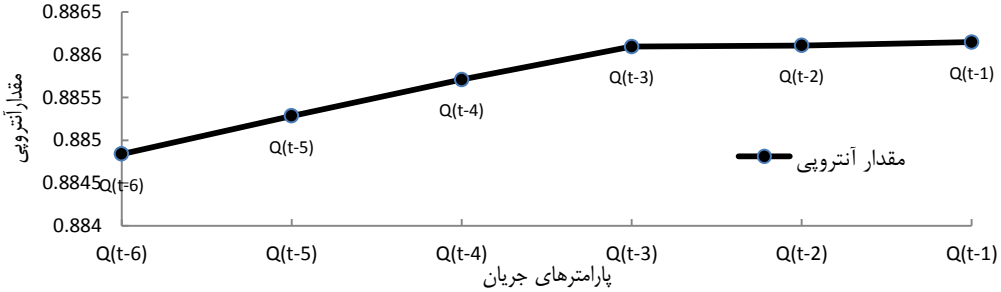
$$SI = \frac{\frac{1}{n}\sum_{i=1}^{n}|x_i-y_i|}{\bar{x}} \quad (۱۱)$$

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 خروجیQ_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 صحت سنجی در هر دو مدل شبکه عصبی مصنوعی و شبکه بیزین را نشان می‌دهد.



شکل۵- ساختار کلی یک شبکه عصبی مصنوعی چندلایه

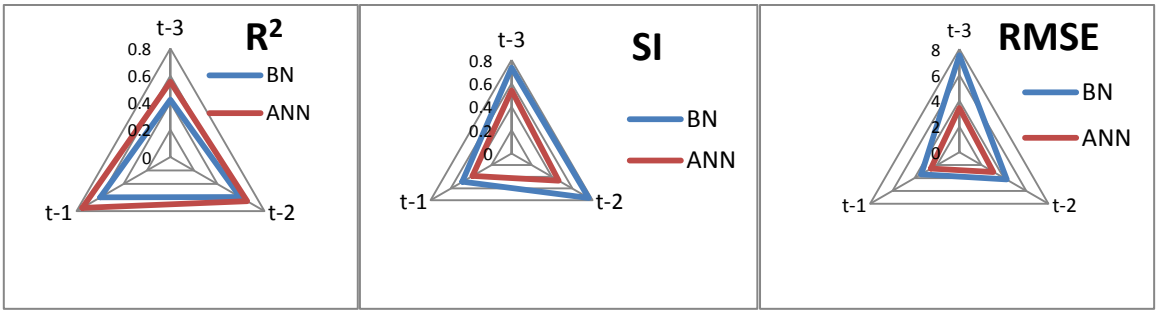


شکل٦-مقدار آنتروپی پارامترهای مورداستفاده در ایستگاه تازه کند

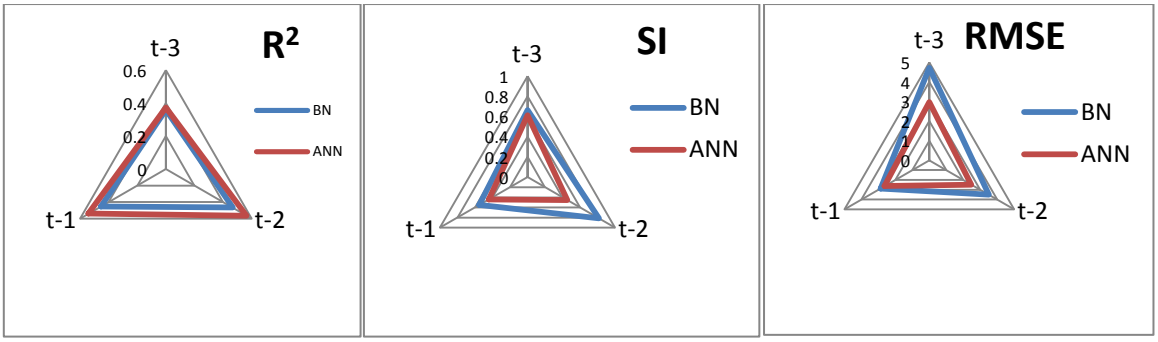
جدول ۲- نتایج شبکه بیزین و شبکه عصبی مصنوعی استفاده‌شده در مراحل آموزش و صحت‌سنجی

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

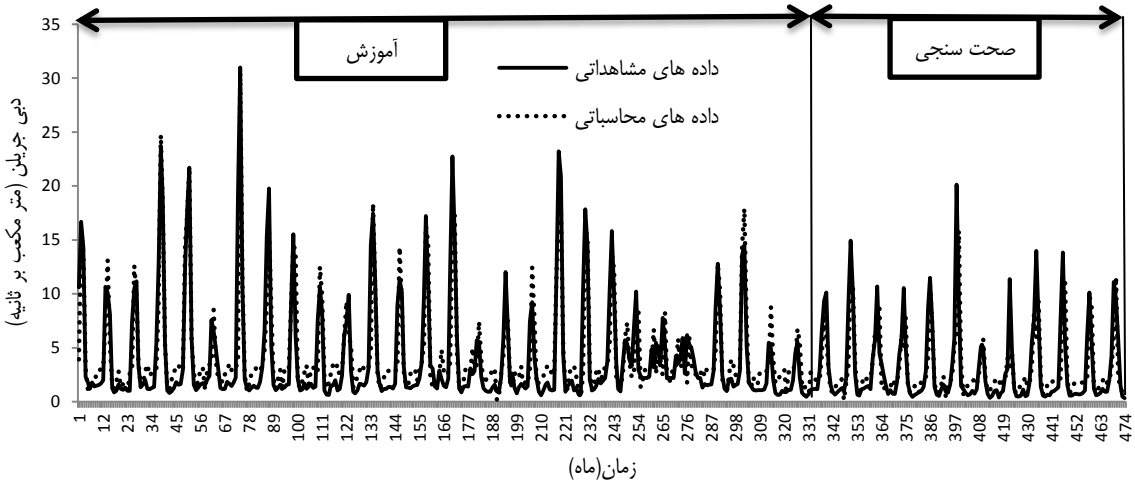
همان‌طور که در جدول(۲) مشاهده می‌شود، میزان R^2 در بخش آموزش سومین ترکیب مدل شبکه بیزین برابر با ۰/۵۹۷ به‌دست‌آمده که نسبت به ترکیبات قبلی بزرگ‌تر می‌باشد. همچنین میزان شاخص پراکندگی SI=۰/۴۸۵ و جذر میانگین مربعات خطا RMSE= ۳/۴۱۲ (m^3/s) است. در بخش صحت‌سنجی نیز وضعیت به همین ترتیب است. مقدار R^2 در سومین ترکیب این بخش، بزرگ‌تر از ترکیبات قبلی و برابر با ۰/۴۵۴ است. میزان شاخص پراکندگی SI=۰/۵۵ و جذر میانگین مربعات خطا RMSE=۲/۸۷۱(m^3/s) هستند. در شکل(۹)، مقادیر مشاهداتی و پیش‌بینی‌شده برای ترکیب سوم نشان داده‌شده است. نتایج حاصل از شبیه‌سازی با شبکه عصبی مصنوعی با مینیمم میزان یادگیری ۰۰۱ /۰ و ماکزیمم میزان یادگیری ۰/۳ و ضریب مومنتوم ۰/۸ نشان می‌دهد ترکیب سوم در جدول(۲) در بخش آموزش میزان R^2 برابر با ۰/۷۵۲ است که نسبت به ترکیبات قبلی بزرگ‌تر می‌باشد. همچنین میزان شاخص پراکندگی۰/۳۸۶ و جذر میانگین مربعات خطا ۲/۵۴۹است. 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 پراکندگی۰/۴۴۲ و جذر میانگین مربعات خطا ۲/۴۷۷ می‌باشد که نسبت به تمام ترکیب‌های مدل‌سازی شده از دقت بیشتری برخوردارمی‌باشد. در شکل (۱۰)، مقادیر مشاهداتی و پیش‌بینی‌شده برای ترکیب سوم نشان داده‌شده‌است. 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 داده‌شده است.



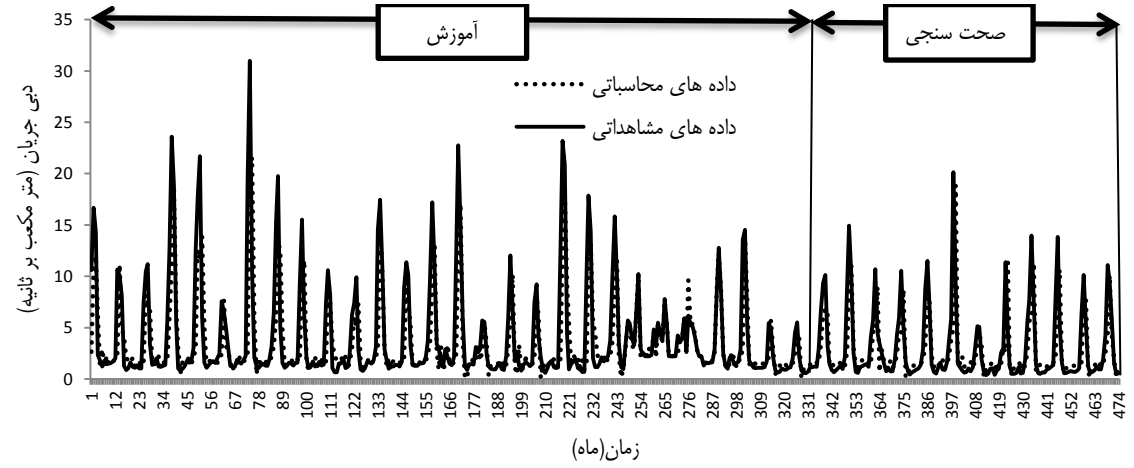
شکل۷- مقایسه نتایج مدل شبکه عصبی مصنوعی و شبکه بیزین در مرحله‌ی آموزش برای پیش‌بینی جریان در ایستگاه تازه کند



شکل۸- مقایسه نتایج مدل شبکه عصبی مصنوعی و شبکه بیزین در مرحله‌ی صحت‌سنجی برای پیش‌بینی جریان در ایستگاه تازه کند



شکل۹- مقادیر مشاهداتی و پیش‌بینی‌شده دبی ایستگاه تازه کند رودخانه صوفی چای با شبکه عصبی مصنوعی (ترکیب۳) بخش آموزش و صحت سنجی



شکل۱۰- مقادیر مشاهداتی و پیش‌بینی‌شده دبی ایستگاه تازه کند رودخانه صوفی چای با شبکه بیزین(ترکیب۳) بخش آموزش و صحت سنجی

نتایج مطالعه‌ی حاضر، در مجموع شبکه عصبی مصنوعی را به عنوان یک روش دقیق برای پیش بینی جریان رودخانه صوفی‌چای پیشنهاد می‌کند. این پیشنهاد، با نتایج حاصل از مطالعات Selgi et al. (2014) که به پیش بینی 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 نسبتا بالایی می‌تواند شبیه سازی کند. Jalali et al. (2015) برای پیش بینی 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، Borhani و Fatehi (2008) در پیش‌بینی جریان حوضه‌ی آبریز نازلوچای یکی از زیرحوضه‌های دریاچه‌ی ارومیه انجام دادند، شبکه عصبی مصنوعی با شاخص‌های اقلیمی یک سال قبل توانست جریان یک سال بعد را با دقت قابل قبولی پیش بینی نماید.

نتیجه‌گیری

شبیه‌سازی جریان رودخانه ،یکی از مولفه‌های مهم در مدیریت منابع آب و پیش‌بینی سیلاب می‌باشد. از طرفی، انتخاب ترکیبی مناسب برای شبیه سازی 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 ماهانه‌ی 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:

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 به‌عنوان یک روش نوین، باعث صرفه جویی در وقت و افزایش دقت مدل‌ها در شبیه سازی می شود.

ارزیابی شبکه‌ی عصبی مصنوعی و شبکه‌ی بیزین برمبنای 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.

منابع

1- Abdolahpour, 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 uzingartifitial 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 Kerachiyan, 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- Rajaee, 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 qualitystatistical 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).

Irrigation Sciences and Engineering Vol. 41, No. 2, Summer 2018, p183-195

Shahid Chamran University of Ahvaz

EXTENDED ABSTRACT

Application of Shannon Entropy for Selecting the Optimum input Variables in River Flow Simulation using Intelligent Models (Case Study: SofyChay)

F. Akhoni Pourhosseini[1*] and M.A. Ghorbani[2]

1*- Corresponding Author, Ms.c student of Water Resources Engineering, University of Tabriz, Iran*(fateme.pourhosseini@yahoo.com).*

2- Associate Professor, University of Tabriz, Iran.

Received:1 August 2016 Accepted:1 March 2017

Keywords: Artificial Neural Network, Bayesian Network, Entropy, river flow, Sofychay River.

Introduction

Accurate prediction of the river flow is an important element in the management of surface water resources, dam reservoir operation, flood control and drought. Selecting appropriate inputs for intelligent models is vital to increase the accuracy and efficiency of the models. Since river flow prediction is of great importance in water resources, researchers have been exploring different approaches over the past several decades. Various methods have been devised to predict the flow of the river over the past years. In general, we can classify conceptual models and data-driven methods. Over the past four decades, time series models have been widely used in river flow prediction (Dawson et al., 2008). Intelligent systems are used to predict nonlinear phenomena. The Bayesian Network and the Artificial Neural Network are among these methods. Ahmadi et al. (2014) studied the comparison of performance of support vector machine and network methods in forecasting daily flow of the Barandozachay River. The results showed that, both methods are close to each other and are suitable for river flow simulation. But in mid-range forecasting and the minimum backup car model, it's much better than the business network model. Shannon entropy theory was first developed by Shannon and then widely used in various scientific issues.

The purpose of this study is to use the Shannon Entropy Theory to find the best combination of input variables for artificial neural network and Bayesian network models to predict the flow. Therefore, for this purpose, the Sufi River of the studied area was selected.

Methodolog

The Sufychy River is a 120 km long river from the southeastern area of Sahand Mount Sahand, East Azarbaijan Province. In this research, the Tazekan station information is used. In order to estimate the flow of the next month, the flow of the previous months is used. Using the time series correlation matrix with a delay of six months, input to the Shannon entropy was introduced. Shannon (1948) showed that events with high probability of occurrence shows less information. Conversely, the more likely it is to occur, the more information it receives. New information reduces uncertainties. Entropy theory is used as an indicator for quantifying relevant items (Masoumi, 2007, Kerachiyan, and others).

Bayesian network, a probabilistic graph pattern, consistedof a set of variables and a corresponding probability for each one. A direct and non-circular graph in which nodes represent the variables of the problem and in the Bayesian network, in addition to the quality of the relationship between the variables of the problem,An artificial neural network receives signals

from input units, and these signals are embedded over the network and eventually move to the output neuron. The main controlling parameters of artificial neural network models are connective resistances between neurons, which are referred to as weight and inertia.
In order to compare the observational and predictive values, the R^2, RMSE and SI scores were used (Ghorbani and Dehgani 2015).

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

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

$$SI = \frac{\frac{1}{n}\sum_{i=1}^{n}|x_i-y_i|}{\bar{x}} \quad (3)$$

Results and Discussion

In the present study, according to Fig. 1, it can be concluded that the effects of $Q_{(t-1)}$, $Q_{(t-2)}$ and $Q_{(t-3)}$ on the output $Q_{(t-6)}$, relative to other parameters, respectively, and can be introduced as an optimal combination of input parameters to models.

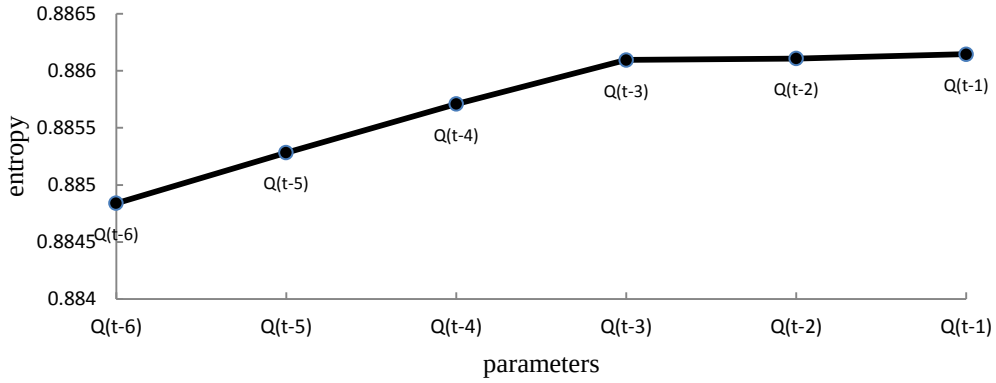


Figure 1- Entropy values of the parameters used at the station

The level of R^2 in the training sector is the third largest combination of the Bayesian network model, equivalent to 0.597, which is larger than the previous ones. Also, the dispersion index is SI = 5.485 and the root mean square error is RMSE = 3.421(m3 / s0.
The results of this study suggest an artificial neural network as a precise method for predicting the flow of the SofyChay River. Bohrani, Fatehi(2008) In predicting the flow of Nazluchay watershed, one of the sub-basins of Lake Urmia, the artificial neural network with climate indicators one year ago was able to predict the flow of one year with acceptable accuracy.

Discussion

River flow simulation is one of the important components in water resources management and flood forecasting. On the other hand, the proper combination of simulation is one of the factors influencing modeling. In this study, Shannon entropy was used to select the optimum input variables. Monthly river flow of SofyChay at the period of 1973-2012 was forecasted using Artificial Neural Networks and Bayesian Neural Network in Tazekand hydrometric station. Information entropy is used to quantify the amount of information in a data set. Shannon entropy used as a measure for quantifying the absence of knowledge about the characteristics of a system.

The monthly river flow data of Sofychay River with different antecedent are considered as input to the Shannon entropy. Shannon entropy results showed that time series with three antecedents provides better results to predict. Comparing the performance of ANN and BN models indicated that the performance of ANN method was better than BN method in predicting. In addition, the results showed that the Shannon entropy has better performance in selection of Optimum Combination of Variables into intelligent models.

References

1- 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).

2- 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).

3- Dawson, C.W. Abrahart, R.J. Shamseldin, A.Y. Wibly, R.L. 2006. Flood estimation at ungauged sites uzingartifitial neural networks. *Journal of Hydrology. 319*,pp. 391-409.

4- 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).

5- Masoumi, F. and Kerachiyan, 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.*

6- Shannon, CE. 1948. A mathematical theory of communications, I and II. Bell Sys. Technol. *J. 27: 379-423.*