



بررسی تاثیر عامل بارش پیشین در برآورد جریان رودخانه توسط شبکه عصبی مصنوعی (مطالعه موردی: رودخانه بختیاری)

ع. ر. اسکندری نیا^۱، ه. نظری پور^۲، م. ض. احمدی^۳، م. تیموری^۴ و م. ذ. مشفق^۵

۱- دانش آموخته کارشناسی ارشد سازه های آبی و کارشناس سازمان جهاد کشاورزی استان همدان ، نویسنده مسوول:

ar_eskandarinia@yahoo.com

۲- استادیار دانشگاه صنعتی نوشیروانی بابل

۳- استاد دانشگاه علوم کشاورزی و منابع طبیعی ساری

۴- مربی دانشگاه فردوسی مشهد

۵- استادیار دانشگاه صنعتی جندی شاپور

چکیده

در دهه گذشته استفاده از شبکه عصبی در شبیه سازی فرآیندهای هیدرولوژیکی افزایش چشمگیری داشته است. نظر به این که بیشتر تحقیقات در این زمینه معطوف به رابطه بین این شبکه ها و سایر مدل های بارش رواناب و یا ارزیابی الگوریتم های آموزش است پژوهشی جهت بررسی ورودی های اساسی و کمکی، جهت پیش گویی جریان ضروری به نظر می رسد. در این تحقیق به منظور پیش بینی روزانه جریان رودخانه بختیاری از شبکه پرسپترون چند لایه استفاده و جهت نیل به اهداف فوق به بررسی نقش بارش پیشین در فرایند بارش- رواناب پرداخته شد و این پارامتر نیز به ورودی های مدل اضافه و بهبود قابل توجهی در نتایج پیش بینی (با ضریب تعیین $+0/94$ در مرحله صحت سنجی) حاصل گردید. بررسی آنالیز حساسیت مدل نسبت به پارامترهای ورودی نشان دهنده این مطلب بود که دبی یک روز قبل، میزان بارش ۷ روز قبل و بارش در ایستگاه باران سنجی تنگ پنج، پارامترهای اصلی این حوزه در پیش گویی جریان روزانه رودخانه می باشند.

واژه های کلیدی: مدل سازی بارش- رواناب، شبکه عصبی مصنوعی، شاخص بارش پیشین، رودخانه بختیاری

مقدمه

رودخانه ها اهمیت ویژه ای دارد. به سبب دشواری و پیچیدگی مسایل مربوط به این پدیده، تاکنون از سوی متخصصان روش ها و الگوهای مختلفی ارائه شده است. شبکه های عصبی مصنوعی^۱ یکی از دستاوردهایی هستند

با توجه به بروز سیلاب های گوناگون و خطرهایی که جوامع انسانی و سازه های سرراه خود را تهدید می کند، بررسی فرآیند بارش- رواناب و اطلاع از مقدار جریان

1- Artificial Neural Network (ANN)

مقایسه نمودند که نتایج نشان داد شبکه عصبی استفاده شده با تعداد داده کمتر و صرف زمان کوتاهتر، مقادیر واقعی تری را ارائه می دهد. آنکتیل و همکاران (۱) نیز از داده های رودخانه های لیف و سرین^۱ به ترتیب واقع در ایالات متحده آمریکا و فرانسه برای پیش بینی روزانه جریان از ANN استفاده کردند. آنها از ۱۰ ورودی شامل تبخیر و تعرق پتانسیل، شاخص بارش پیشین در روزهای مختلف و شاخص رطوبت قبلی خاک در میزان بارشهای مختلف استفاده کردند. نتایج این تحقیق بدین گونه عنوان شد که تنها سری های زمانی شاخص رطوبتی خاک برای پیش بینی جریان یک روز پیش مفید است و پتانسیل تبخیر و تعرق و سری های زمانی بارش پیشین در بهبود عملکرد شبکه عصبی مصنوعی نتایج ضعیفی دارد. آنکتیل و رات (۲) از داده های ۴۷ حوزه آبخیز واقع در فرانسه و آمریکای مرکزی، برای پیش بینی جریان از شبکه پیشرو با روش آموزش پس انتشار خطا استفاده کردند و سه سناریوی مختلف را بررسی نموده و مشاهده کردند افزودن داده های مربوط به تبخیر و تعرق باعث ضعیف تر شدن عملکرد شبکه و همچنین استفاده از اختلاف داده های رواناب به عنوان خروجی باعث بهبود عملکرد شبکه در تمام زیر حوزه های آبخیز خواهد شد.

سلیمانی و درواری (۱۶) نیز در بررسی کارایی شبکه عصبی در پیشگویی جریان رودخانه کسلیان اظهار داشتند که الگوریتم LM^۲ نسبت به CG^۳ کارایی بهتری دارد.

شمس الدین (۱۵) در مدل سازی جریان رودخانه نیل در سودان به همراه متغیر بارش از

که با الگوبرداری از شبکه عصبی مغز انسان، قادرند پدیده های پیچیده و ناشناخته را به خوبی بررسی نمایند و کاربران با استفاده از این تکنیک ها به تقلید فرآیندهای هیدرولوژیکی و بررسی آنها پرداخته اند. هرچند که بیشتر پژوهش های اخیر در شبکه عصبی به مقایسه انواع شبکه ها و یا تعیین نوع الگوریتم آنها پرداخته اند، لیکن انتخاب ورودی ها یک گام بسیار مهم در کاربرد شبکه های عصبی می باشد.

به باور بیشتر پژوهشگران، ANN به دو دلیل عمده در تحلیل مسایل ناشناخته و پیچیده، عملکرد خوبی از خود نشان می دهد، اول اینکه با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین ورودی و خروجی داده ها برقرار می کند. همچنین در قیاس با دیگر الگوها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی از خود نشان می دهد (۱ و ۱۴). علت این امر پردازش توزیعی اطلاعات در آن است و به جای اینکه تمام بار محاسبه به یک واحد پردازشگر تحمیل شود، تعداد زیادی از واحدهای پردازشگر همزمان وارد عمل شده و در نتیجه با کم شدن سهم هر یک از آنها، تأثیر منفی بسیاری در عملکرد شبکه و خروجی آن نمی گذارد (۱).

محققین زیادی از شبکه عصبی در مطالعات خود استفاده نموده اند که در ادامه به بعضی از جدیدترین آنها اشاره می شود. از جمله توکار و مارکوس (۱۸) با انتخاب بارش روزانه، دما و مقدار ذوب برف، رواناب تولید شده از ANN و یک مدل ساده مفهومی را

ANN مثل بعضی از مدل های بارش- رواناب از مباحث ریاضی مناسبی برای توصیف فرآیندهای فیزیکی جهت جبران اطلاعات ورودی ناقص استفاده نمی کند، به همین ترتیب شناخت ورودی های غیرضروری نیز به بهینه شدن مدل، کمکی نخواهد کرد. هدف از این تحقیق نیز کاربرد مدل شبکه عصبی مصنوعی در شبیه سازی جریان رودخانه به منظور بررسی نقش عامل بارش پیشین به عنوان یکی از مهمترین متغیرها در پیش گویی جریان رودخانه در رودخانه بختیاری است که به عنوان گام اساسی در بهبود یافته ها از درک پدیده پیچیده غیرخطی بارش- رواناب محسوب می شود.

مواد و روش ها

حوزه آبخیز مورد مطالعه

حوزه آبخیز بختیاری واقع در استان چهارمحال و بختیاری و محدود به مختصات جغرافیایی ۴۸ درجه و ۱۵ دقیقه تا ۵۰ درجه و بیست دقیقه طول شرقی و ۳۲ درجه و ۳۰ دقیقه تا ۳۳ درجه و ۳۰ دقیقه عرض شمالی می باشد. مساحت حوزه آبخیز تا محل سد بختیاری ۶۴۹۵ کیلومتر مربع است. رودخانه بختیاری یکی از شاخه های اصلی رودخانه دز می باشد و در ارتفاعات بالاتر، شاخه هایی همچون و هرگان، کاکلستان و قلیان را نیز در بر می گیرد که همگی از بلندی های جنوب غربی زاگرس میانی سرچشمه می گیرند. رودخانه های مذکور به ترتیب توسط ایستگاههای هیدرومتری تنگ پنچ، زردفهره، کاظم آباد و قلیان اندازه گیری و کنترل و پس

پیشگویی های بارش و رواناب فصلی توسط مدل غیرخطی خود همبستگی به عنوان ورودی های مدل استفاده نموده و بهبود نتایج را مشاهده نمودند و شبکه عصبی را دارای پتانسیل بالا برای پیشگویی در کشورهای در حال توسعه معرفی نمودند.

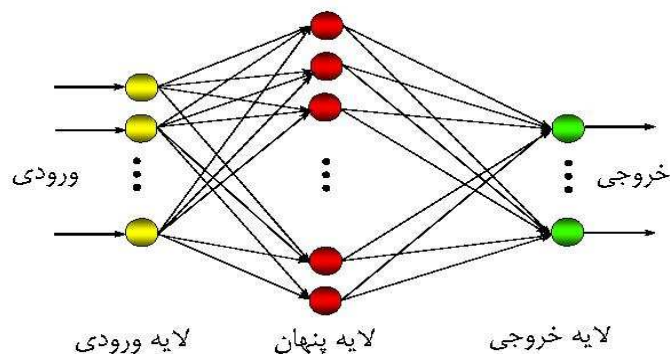
میثاقی و محمدی (۱۳) در شبیه سازی بارش- رواناب و روندیابی رودخانه از شبکه عصبی مصنوعی با بردارهای ورودی مختلف استفاده کرده و عنوان نمودند با کاهش تعداد نرون های لایه خروجی، توانایی شبکه در آموزش و رسیدن به نتایج مطلوب بهبود خواهد یافت. همچنین شبکه پرسپترون چند لایه با روش دلتا در مراحل آموزش و صحت یابی، از کارایی بیشتر برخوردار بوده و استفاده از توابع محرک متنوع به جای یک تابع محرک ثابت، رضایت بخش تر است. دستورانی (۵) نیز در تحقیق خود به منظور تحلیل توانایی ها و نقطه ضعف های روش شبکه های عصبی مصنوعی در مدل سازی جریان رودخانه ای به این نکته اشاره می کند که تواناییهای این تکنیک با توجه به ساختارهای مختلف آن متفاوت است و شبکه پرسپترون چند لایه در ترکیب با نرم افزارهای دیگر نسبت به کاربرد تنهای آن به مراتب بهتر عمل می کند.

همانطور که در بعضی از سوابق فوق ملاحظه شد علیرغم اینکه انتخاب ورودی (های) مناسب یک ضرورت جهت اجرای ANN می باشد کمبود ورودی (های) مناسب نیز باعث تضعیف شبکه در برآورد جریان رودخانه می شود، بخصوص اینکه

توبولوژی و آموزش شبکه عصبی

ساختار کلی ANN شامل سه لایه با وظایف مجزا می باشد. لایه ورودی با نقش توزیع داده ها در شبکه، لایه میانی (پنهان) که عمل پردازش اطلاعات را بر عهده دارد و لایه خروجی که علاوه بر پردازش، به ازای بردار ورودی شبکه، نتایج و خروجی آن را نشان می دهد (۱) ساختار اصلی یک شبکه عصبی پرسپترون چند لایه را تشکیل می دهند. در شکل ۱ یک شبکه متعارف از شبکه عصبی پرسپترون چند لایه که کارایی زیادی در هیدرولوژی دارند (۴ و ۱۰) نشان داده شده است که بین لایه ورودی و خروجی یک لایه پردازشگر در نظر گرفته شده است.

از پیوستن به شاخه سزار، رودخانه دز علیا را تشکیل می دهد. جریان بالا در حوزه مورد نظر نشان دهنده مجموعه عوامل شیب زیاد، نفوذ پذیری و پوشش گیاهی نسبتاً کم و بارندگی بالای این منطقه (۱۰۲۴ میلیمتر) بوده که در محل ایستگاه تنگه پنج به بیش از ۱۴۵ مترمکعب بر ثانیه می رسد. رودخانه بختیاری از نظر سیلاب در ردیف رودخانه های وحشی ایران به شمار می آید و به دلایل فوق الذکر دارای ضریب جریان بالایی است که احتمال وقوع سیلاب های تاریخی و استثنایی زیاد خواهد بود (۹). دوره آماری انتخاب شده برای این مطالعات براساس ایستگاه تنگه پنج از سال ۱۳۶۰ لغایت ۱۳۸۱ می باشد.



شکل ۱- شبکه عصبی پرسپترون چند لایه.

$$net_j = \sum_{i=1}^n w_{ij} \times x_i + b_j \quad (1)$$

در مرحله بعد یک تابع فعالیت به جمع ورودی ها در هر نورون اعمال شده که طی آن سطح خروجی از نورون تعیین می گردد. مرسوم ترین تابع در این خصوص تابع سیگموئید می باشد که محدوده فعالیت آن [۰، ۱] است

اطلاعات نورون ها (x_1, \dots, x_n) در وزن های (w_1, \dots, w_n) ضرب و سپس جمع می شوند (net_j) و بدین ترتیب مجموع کل ورودی ها برای نورون مشخص می شود. وزن ها وابستگی اتصال نورون ها به هم هستند و طی فرآیند یادگیری این وزن ها مشخص می شود:

(۱۲).

معمولاً سریعتر و منطقی تر از سایر انواع پس انتشار است (۳، ۱۱ و ۱۷).

شاخص بارش پیشین^۱

میزان بارش پیشین و وضعیت رطوبتی قبلی خاک نقش مهمی در زمان و مقدار جریان سطحی دارد، این شاخص عبارت است از کل بارش های اتفاق افتاده در گذشته که در ظرفیت نفوذپذیری خاک تاثیر داشته و با فراوانی و ارتفاع بارش های قبلی مرتبط است (۱). هگن (۷) این شاخص را تابعی از میانگین متحرک بارش معرفی می کند:

$$API_i(t) = \sum_{j=1}^i P_{t-j} k^{-j} \quad (۳)$$

که در آن API : میانگین متحرک بارش، i : شماره روز های گذشته، k : ثابت کاهش و P_{t-j} : بارش کل برای روز $t-j$: می باشد.

از آنجایی که خصوصیات زمین شناسی و پوشش منطقه تاثیری روی این شاخص ندارند بدیهی است که بین مناطق مختلف نیز قابل مقایسه نمی باشند. ضریب افت k نیز یک پارامتر فصلی است که در هر حوزه متفاوت می باشد و معمولاً بین ۰/۸ تا ۰/۹۸ متغیر است (۷)، در این تحقیق عدد یک برای آن در نظر گرفته شده است تا بیانگر فرض غیرکاهشی بودن میانگین متحرک باشد (۱). همچنین میزان بارش پیشین به عنوان متغیرهای کمکی در ۱، ۷ و ۱۵ روز پیش مورد سنجش قرار گرفت.

معیارهای ارزیابی مدل

دقت پیش بینی بوسیله معیارهای سنجش خطا و دقت مورد بررسی قرار می گیرد.

جالبترین ویژگی شبکه های عصبی مصنوعی، توانایی آن در یادگیری بر مبنای الگوهای آموزشی است و به آن داده می شود که از طریق فرآیند یادگیری، شبکه های عصبی مقادیر بهینه وزن ها را پیدا خواهند کرد. الگوریتم های مختلفی برای آموزش شبکه عصبی تنظیم شده اند که از بین آنها روش آموزش پس انتشار خطا بطور وسیعی در مدل های هیدرولوژیکی استفاده می شود (۱). در هر الگوریتم آموزشی، هدف کمینه کردن کل خطاست که به صورت میانگین مربعات خطا و به صورت رابطه (۲) تعریف می شود:

$$E = \frac{1}{P} \sum_{q=1}^p \sum_{i=1}^n (S_i - T_i)^2 \quad (۲)$$

که در آن E : خطای الگوی آموزشی، p : تعداد الگوهای آموزشی، T_i : خروجی هدف در نرون i (مقدار مشاهده شده)، S_i : خروجی شبکه در نرون i : (مقدار محاسبه شده) و n : تعداد نرون های خروجی می باشد.

گزینه های زیادی در هنگام استفاده از ANN در مدل های بارش رواناب وجود دارد که کاربر بایستی براساس تجربیات خود فرضیاتی را از جمله نوع توپولوژی شبکه، الگوریتم آموزشی، انتخاب ورودی و بهینه سازی اندازه شبکه لحاظ کند. توپولوژی مورد استفاده در این تحقیق شبکه MLP سه لایه براساس الگوریتم پس انتشار ML (۶) می باشد. این الگوریتم یک تکنیک بهینه سازی غیرخطی درجه دوم است و

معمولاً بارندگی اولین گزینه برای شبیه سازی رواناب می باشد و برای در نظر گرفتن دبی پایه می توان از دبی یک تا دو روز قبل به عنوان ورودی استفاده کرد. سپس ورودی های دیگری مانند شاخص رطوبتی پیشین به آن اضافه گردید و در مجموع مدل های ورودی پیشنهادی عبارت بودند از: الگوی اول: بارش چهار ایستگاه کاظم آباد، زرد فهره، قلیان و تنگ پنج الگوی دوم: بارش چهار ایستگاه به همراه دبی روز قبل

الگوی سوم: بارش چهار ایستگاه به همراه دبی یک و دو روز قبل الگوی چهارم: بارش چهار ایستگاه به همراه دبی و شاخص بارش پیشین یک روز قبل الگوی پنجم: بارش چهار ایستگاه و دبی روز قبل و شاخص بارش پیشین ۷ روز قبل الگوی ششم: بارش چهار ایستگاه و دبی روز قبل و شاخص بارش پیشین ۱۵ روز قبل الگوی هفتم: بارش چهار ایستگاه و دبی یک و دو روز قبل و شاخص بارش پیشین یک روز قبل الگوی هشتم: بارش چهار ایستگاه و دبی یک و دو روز قبل و شاخص بارش پیشین ۷ روز قبل الگوی نهم: بارش چهار ایستگاه و دبی یک و دو روز قبل و شاخص بارش پیشین ۱۵ روز قبل

نتایج و بحث

پیش پردازش، آموزش و آزمون شبکه این مرحله شامل انتخاب متغیر های موثر، انتخاب داده های آموزش و آزمون، دسته بندی الگوها و نیز نرمال کردن (استاندارد کردن)

معیارهای مورد استفاده در این تحقیق در هر یک از آزمون ها مشتمل بر سه معیار زیر است:

الف) ضریب همبستگی که به طور گسترده ای در ارزیابی نیکویی برازش مدل های هیدرولوژی و هیدرودینامیک مورد استفاده واقع می شود (۸). این ضریب توسط ایجاد رگرسیون خطی بین مقادیر ANN پیش گویی شده و مقادیر مشاهده شده محاسبه می شود (رابطه ۴).

الف) ضریب همبستگی:

$$R = \frac{\sum_{i=1}^N t_i P_i}{\sqrt{\sum_{i=1}^N t_i^2} \sqrt{\sum_{i=1}^N P_i^2}} \quad (4)$$

ب) معیار خطای مربع میانگین ریشه^۱ که توانایی مقادیر پیش بینی ANN برای تطابق با مقادیر مشاهده ای توسط این آماره ارزیابی می شود و توسط رابطه (۵) محاسبه می شود.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - P_i)^2} \quad (5)$$

ج) معیار درصد خطای حجم^۲:

$$\% VE = \frac{1}{N} \sum_{i=1}^N \left| \frac{T_i - P_i}{T_i} \right| \quad (6)$$


که در روابط فوق N تعداد نمونه ها، $p_i = P_i - \bar{P}$ ، $t_i = T_i - \bar{T}$ مقادیر شادداتی و پیش بینی شده برای $i = 1, \dots, N$ و \bar{P} و \bar{T} نیز مقادیر میانگین داده های مشاهداتی و پیش بینی شده می باشند.

طراحی شبکه عصبی


در تحقیق حاضر مدل شبکه عصبی با ورودی های مختلفی مورد ارزیابی قرار گرفت.

مربوط به ایستگاه تنگ پنج به صورت شماتیک در اشکال ۲ و ۳ رسم شده اند. مطابق این شکلها ملاحظه می شود که مقادیر حدی در دوره اول (آموزش) واقع شده اند.

داده‌ها به منظور هم ارزش کردن تمامی عناصر موجود در یک الگو می باشد. پس از نرمال کردن تمامی الگوها، نوبت به انتخاب الگوهای آموزش و آزمون می رسد. هیدروگراف هر دو دسته آزمون و آموزش



شکل ۲- مقادیر دبی روزانه ایستگاه تنگ پنج در دوره آموزش.



شکل ۳- مقادیر دبی روزانه ایستگاه تنگ پنج در دوره آزمون.


الگوهای مورد بررسی در جدول ۱ آورده شده است و منحنی پراکندگی دبی پیش بینی شده

به منظور ارزیابی عملکرد مدل، ضرایب تعیین بین دبی‌های مشاهداتی و محاسباتی

در مقابل دبی مشاهده‌ای در الگوی پنجم به شکل ۴ نشان داده شده است. عنوان بهترین الگو نیز به عنوان نمونه در

جدول ۱- معادله خط و ضریب تعیین الگوهای مختلف

نوع الگو	معادله خط	ضریب تعیین
الگوی اول	$Y=0.8455X$	-۲/۸۶۷۵
الگوی دوم	$Y=0.9932X$	۰/۸۷۳۸
الگوی سوم	$Y=0.9929X$	۰/۸۶۷۲
الگوی چهارم	$Y=0.9927X$	۰/۸۸۰۶
الگوی پنجم	$Y=1/0.071X$	۰/۹۱۶۳
الگوی ششم	$Y=0.9895X$	۰/۸۷۶۴
الگوی هفتم	$Y=0.9922X$	۰/۸۷۶۷
الگوی هشتم	$Y=0.9969X$	۰/۸۷۲۸
الگوی نهم	$Y=0.9896X$	۰/۸۷۳۹




شکل ۴- منحنی پراکندگی دبی پیش بینی شده در مقابل دبی مشاهداتی در الگوی بهینه (پنجم).

معماری شبکه پس از آزمون و خطاهای مکرر بصورت (۱-۳-۶) به معنای ۶ نرون ورودی، ۳ نرون پنهان و یک نرون خروجی (جدول ۲) بهینه شده است (شکل ۵).

با توجه به نتایج حاصل از معیارهای ارزیابی، شبکه MLP با شش ورودی معرفی شده در الگوی پنجم بهترین همبستگی و کمترین خطا را نسبت با سایر الگوها نشان داده که

جدول ۲- نتایج حاصل از الگوهای آموزش و آزمون با الگوی پنجم

معماری شبکه	معیار ارزیابی	واسنجی	صحت سنجی
۶-۲-۱	خطای مربع میانگین ریشه	۰/۷۰۶۵	۱/۱۵۰۵
	درصد خطای حجم	۹/۲۰۷۶	۱۰/۰۶۴۳
	ضریبی همبستگی	۰/۹۵۵۳	۰/۹۲۷۹
۶-۳-۱	خطای مربع میانگین ریشه	۰/۶۹۰۵	۱/۰۳۶۸
	درصد خطای حجم	۷/۸۰۶۷	۸/۲۸۵۰
	ضریبی همبستگی	۰/۹۵۷۵	۰/۹۴۰۷
۶-۵-۱	خطای مربع میانگین ریشه	۰/۷۲۴۴	۱/۰۰۱۴
	درصد خطای حجم	۸/۵۵۲۷	۱۰/۴۱۲۲
	ضریبی همبستگی	۰/۹۵۲۶	۰/۹۴۴۳



شکل ۵- مقادیر دبی پیش بینی شده و دبی مشاهداتی حاصل از الگوی پنجم (بهینه).


آنالیز حساسیت

همانطور که در شکل ۶ مشاهده می شود، در این الگو پارامترهایی که بیشترین تاثیر را در میان سایر پارامترهای ورودی دارند پارامتر آبدهی روز قبل و بارش هفت روز قبل می باشند. مقدار بارندگی سایر ایستگاه های بالادست (غیر از ایستگاه تنگه پنج) نیز تاثیر

همانطور که مشاهده می شود بهبودی در الگوهای با پارامترهای بیشتر نسبت به پارامترهای دیگر وجود ندارد و می توان به این موضوع پی برد که افزایش تعداد ورودی ها نمی تواند این تصور را ایجاد کند که مدل های شبکه عصبی حتماً تاثیر مثبتی در بهبود شبکه خواهند داشت.

شبکه عصبی را با سه پارامتر بارندگی همان روز ایستگاه تنگه پنج، آبدهی روز قبل همان ایستگاه و میزان بارش چهار ایستگاه موجود کالیبره نمود.

چندانی بر روی آبدهی روزانه ایستگاه هیدرومتری تنگه پنج ندارد. در نتیجه بارش یک روز قبل، پانزده روز قبل و مقدار آبدهی دو روز قبل اثر چندانی در واسنجی شبکه و نتایج نهایی شبکه ندارد، بنابراین می توان



شکل ۶- بررسی حساسیت مدل شبکه عصبی مصنوعی آموزش یافته به تغییرات در پارامترهای ورودی.

میثاقی و محمدی (۱۳) نیز در تحقیقات خود کاهش تعداد نورون های لایه خروجی را باعث افزایش صحت مدل دانسته بودند در این تحقیق نیز علاوه بر کاهش تعداد نورون های خروجی نقش منفی ورودی های غیرموثر در کارایی مدل مشخص گردید.

تشکر و قدردانی

این پژوهش بخشی از پایان نامه کارشناسی ارشد مولف اول بوده که بدین وسیله از معاونت پژوهشی دانشگاه علوم کشاورزی و منابع طبیعی ساری سپاسگزاری می گردد.

از بررسی های فوق می توان دریافت که استفاده از شبکه عصبی مصنوعی با داشتن قابلیت تشخیص الگو، رابطه مناسبی بین ورودی و خروجی داده ها برقرار می سازد. همچنین همانطور که آنکتیل و همکارانش (۱) نیز اشاره داشته اند به علت پردازش توزیعی اطلاعات، این روش حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی از خود نشان می دهد و بجای اینکه تمام بار محاسبه به یک واحد پردازشگر تحمیل شود تعداد زیادی از واحدهای پردازشگر وارد عمل شده و با کم شدن سهم هر یک از آنها باعث عدم تاثیر منفی در عملکرد شبکه می گردد. همانطور که

منابع

1. Anctil, F., C. Michel, C. Perrin and V. Andreassian. 2004. A soil moisture index as an auxiliary ANN input for stream flow forecasting. *J. Hydrology*. 286: 155-167.
2. Anctil, F. and A. Rat. 2005. Evaluation of neural network stream flow forecasting on 47 watersheds. *J. Hydrologic Engrg., ASCE*, 10(1): 85-88.
3. Bertsekas, D.P. and J.N. Tsitsiklis. 1996. *Neuro-Dynamic Programming*. Athena Scientific, Belmont, MA.
4. Coulibaly, P., F. Anctil and B. Bobee. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*. 230: 244-257.
5. Dastourani, M. 2007. ANN method in river flow modeling (Analysis of opportunity and problems). *Proceeding of the 7th International river congress*. Ahvaz pp: 221-231.
6. Hagan, M.T. and M. Menhaj. 1994. Training feedforward networks with the Marquardt algorithm. *IEEE Trans. Neural Networks* 5(6): 989-993.
7. Heggen, R.J. 2001. Normalized antecedent precipitation index. *J. Hydrologic Engineering* 6(5): 377-381.
8. Legates, D.R. and G.J. McCabe. 1999. Evaluating the use of goodness-of-fit measures in hydrologic and hydro-climatic model validation. *Water Resources Research* 35(1): 233-241.
9. Mahab ghods Consulting Engineering Company. 1999. Project of bakhtiari storage and powerplant dam. First plant. Attachment (2, 3). Hydrological report. Iranian company of water resources development and power. 117 pp.
10. Maier, H.R. and G.C. Dandy. 2000. Neural Networks for prediction and forecasting of water resources variables: Review of modeling issues and applications. *Environment Modeling Software* 15: 101-124.
11. Masters, T. 1995. *Advanced algorithms for Neural Networks: A C++ Sourcebook*, Wiley, New York.
12. Menhaj, M. 2010. *computational Intelligence. First volume. Introduction to neural network*. Amirkabir Industrial University. 715 pp.
13. Misaghi, F. and K. Mohammadi. 2003. Simulation of rainfall runoff and river routing using ANN. *Proceeding of the 6th International river congress*. Ahvaz. pp: 455-462.
14. Sejnowski, T. and C. Rosenberg. 1987. Parallel networks that learn to pronounce English text. *Complex system*, 1: 68-145.
15. Shamseldin, A. 2010. Artificial neural network model for river flow forecasting in a developing country, *J of hydroinformatics*. 12(1): 22-35.
16. Solaimani, K. and Z. Darvari. 2008. Suitability of Artificial Neural Network in Daily Flow Forecasting, *Journal of Applied Science*, 8(17): 2949-2957.
17. Tan, Y. and A. Van Cauwenbergh. 1999. Neural Network based step ahead predictors for nonlinear systems with time delay. *Eng. Appl. Artif. Intel.*, 12: 21-25.
18. Tokar, A.S. and M. Markus. 2000. Precipitation runoff modeling using artificial neural networks. *J. Hydrologic Engineering*. ASCE. 5(2): 156-161.

An Investigation of Antecedent Precipitation Index Role in River Flow Forecasting Using Artificial Neural Network (Case Study: Bakhtiari River)

A.R. Eskandarinia¹, H. Nazarpour², M.Z. Ahmadi³, M. Teimouri⁴ and M.Z. Moshfegh⁵

1- Expert, Jihade Agriculture, Malayer (Corresponding author: ar_eskandarinia@yahoo.com)

2- Assistant Professor, Babol Noshirvani University of Technology

3- Professor, Sari Agriculture and Natural Resources University

4- Assistant Professor, University of Ferdowsi, Mashhad

5- Assistant Professor, Jundi Shapur University of Technology

Abstract

In hydrology, there has been a virtual explosion in the use of artificial neural networks (ANNs) over the last 10 years. However, most of the recent ANN research have been devoted to comparing ANNs and more established rainfall runoff models or to assessing ANN training algorithms, while norms are still lacking that would help hydrologists to create and train efficient ANN models in a systematic way. In the present study was used multi layer perceptron for forecasting of Bakhtiari's of daily inflow. For this purpose was examined role of antecedent precipitation index in rainfall runoff process and this parameter added to model inputs and considerable improvement was resulted in forecasting result (with determination coefficient of 0.94 in verification step). The results of sensitivity analysis verified that one day ago inflow and 7 days ago precipitation in Tangpanj station are important parameters in river daily inflow forecasting.

Keywords: Rainfall-Runoff modeling, Artificial Neural Network, Antecedent Precipitation index, Bakhtiari River