

بررسی تاثیر عامل بارش پیشین در برآورد جریان رودخانه توسط مدل سازی هوشمند بارش رواناب

علیرضا اسکندری نیا^{۱*}، میرخالق ضیاءتبار احمدی^۲، هادی نظرپور^۳، مهدی تیموری^۴،
محمد ذاکر مشفق^۵

^۱ - دانش آموخته کارشناسی ارشد سازه های آبی و کارشناس سازمان جهاد کشاورزی استان همدان

^۲ - استاد بخش مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی ساری

^۳ - استادیار بخش مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی ساری

^۴ - مربی و عضو هیات علمی دانشکده کشاورزی و منابع طبیعی شیروان - دانشگاه فردوسی مشهد

^۵ - عضو هیات علمی دانشگاه جندی شاپور اهواز

*Email: Ar_Eskandarinia@yahoo.com

خلاصه

در دهه گذشته استفاده از شبکه عصبی در شبیه سازی فرایندهای هیدرولوژیکی افزایش چشمگیری داشته است. نظر به اینکه بیشتر تحقیقات در این زمینه معطوف به رابطه بین این شبکه ها و سایر مدل های بارش رواناب و یا ارزیابی الگوریتمهای آموزش است پژوهشی جهت بررسی های 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 (MLP) استفاده و جهت نیل به اهداف فوق به بررسی نقش بارش پیشین (API) در فرایند بارش- رواناب پرداخته شد و این پارامتر نیز به ورودی های مدل اضافه و بهبود قابل توجهی در نتایج پیش بینی 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 حوضه در پیش گویی جریان روزانه رودخانه می باشند.

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

۱. مقدمه

با توجه به بروز سیلاب های گوناگون و خطرهایی که جوامع انسانی و سازه های سر راه خود را تهدید می کند، بررسی فرآیند بارش _ رواناب و اطلاع از مقدار جریان 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 ارایه شده است. شبکه های عصبی مصنوعی یکی از دستاوردهایی هستند 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 فرایندهای هیدرولوژیکی و بررسی آنها پرداخته اند. هر چند 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^۱ (شبکه عصبی مصنوعی) 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 (آنتیل و همکاران ۲۰۰۴، سجنوسکی و روزنبرگ ۱۹۸۴). علت این امر پردازش توزیعی اطلاعات در آن است و به جای اینکه تمام بار محاسبه به یک واحد پردازشگر تحمیل شود، تعداد

^۱ - Artificial Neural Network

زیدی 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 (آنکتیل و همکاران ۲۰۰۴).

توکار و مارکوس (۲۰۰۰) با انتخاب بارش روزانه، دما و مقدار ذوب برف، رواناب تولید شده از ANN یک مدل ساده تفهیمی را مقایسه نمودند که نتایج نشان داد شبکه عصبی استفاده شده با تعداد داده کمتر و صرف زمان کوتاهتر، اندازه های واقعی تری را ارائه می دهد. آنکتیل و رات (۲۰۰۵) از داده های ۴۷ حوزه 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 حوضه ها خواهد شد. در ایران هم میثاقی و محمدی (۱۳۸۱) 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^۱ 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.

در بررسی بعضی از سوابق تحقیق ملاحظه شد که 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 ANN مثل بعضی از مدل های بارش رواناب از مباحث ریاضی مناسبی برای توصیف فرایندهای فیزیکی جهت جبران اطلاعات ورودی ناقص استفاده نمی کند، به همین ترتیب شناخت ورودی های غیر ضروری نیز به بهینه شدن مدل ما کمکی نخواهد کرد. هدف از این تحقیق نیز بررسی نقش کارایی ورودی های مختلف در شبکه عصبی مصنوعی به منظور شبیه سازی جریان رودخانه و مخصوصاً عامل بارش پیشین که به عنوان یکی از مهمترین متغیرها در پیش گویی جریان رودخانه ها می باشد و به عنوان گام اساسی در بهبود یافته های ما از درک پدیده پیچیده غیر خطی بارش رواناب محسوب می گردد.

۲. مواد و روشها

حوضه مورد مطالعه

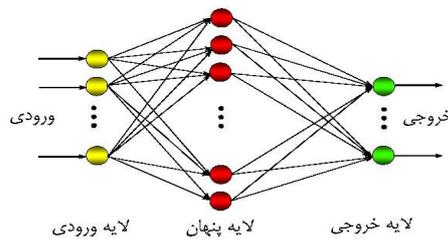
حوزه آبریز بختیاری واقع در جنوب غربی کشور و محدود به مختصات جغرافیایی ۱۵' و ۴۸' تا ۲۰' و ۵۰' طول شرقی و ۳۰' و ۳۳' عرض شمالی می باشد. سطح حوضه رودخانه تا محل سد بختیاری ۶۴۹۵ کیلومتر مربع است. رودخانه بختیاری یکی از شاخه های اصلی رودخانه دز می باشد و در ارتفاعات بالاتر، شاخه هایی همچون وهرگان، کاکلستان 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 پنج، زردفهره، کاظم آباد و قلیان اندازه گیری و کنترل و پس از پیوستن به شاخه سزار، رودخانه دز علیا را تشکیل می دهد. جریان بالا در حوضه 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 تنگ 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 (شرکت مهندسی مشاور ۱۳۷۷). دوره آماری انتخاب شده برای این مطالعات بر اساس ایستگاه تنگ پنج از سال ۱۳۶۰ لغایت ۱۳۸۱ می باشد.

توپولوژی 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 (آنکتیل و همکاران ۲۰۰۴) ساختار اصلی یک شبکه عصبی پرسپترون چند لایه را تشکیل می دهند. در شکل ۱ یک شبکه متعارف از شبکه عصبی پرسپترون

^۱ - Perceptron

چند لایه که کارایی زیادی در هیدرولوژی دارند (کولیالی و همکاران ۲۰۰۰، میر و دندی ۲۰۰۰) نشان داده شده است که بین لایه ورودی و خروجی یک لایه پردازشگر در نظر گرفته شده است.



شکل ۱ - شبکه عصبی پرسپترون چند لایه

اطلاعات نورون ها (x_1, \dots, x_i) در وزن های (w_1, \dots, w_i) 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 فرایند یادگیری این وزن ها مشخص می شود (رابطه ۱):

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

در مرحله بعدی 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 (منهاج ۱۳۷۷).

جالبترین ویژگی شبکه های عصبی مصنوعی، توانایی آن در یادگیری بر مبنای الگوهای آموزشی است که به آن داده می شود که از طریق فرایند 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 (آنکتیل و همکاران ۲۰۰۴). در هر الگوریتم آموزشی، هدف کمینه کردن کل خطا است که بصورت میانگین مربعات خطا^۱ و به صورت رابطه (۲) تعریف می شود:

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

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

شاخص بارش پیشین

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 (آنکتیل و همکاران ۲۰۰۴). هگن (۲۰۰۱) این شاخص را تابعی از میانگین متحرک بارش معرفی می کند:

$$API_i(t) = \sum_{j=1}^i P_{t-j} k^{-j} \quad (3)$$

API: میانگین متحرک بارش، t: شماره روز های گذشته، k: ثابت کاهش و P_{t-j} : بارش کل برای روز t-j.

از آنجایی که خصوصیات منطقه تاثیری بر 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 حوضه متفاوت می باشد و معمولاً بین ۰/۸ تا ۰/۹۸ متغیر است (هگن ۲۰۰۱)، در این تحقیق عدد یک

^۱ - Mean Square Error

^۲ - Antecedent precipitation Index

برای آن در نظر گرفته شده است تا بیانگر غیر کاهشی بودن میانگین متحرک باشد (آنکتیل و همکاران ۲۰۰۴). 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. معیارهای مورد استفاده در این تحقیق در هر یک از آزمون ها مشتمل بر سه معیار زیر است:

الف) ضریب همبستگی^۱ که به طور گسترده ای در ارزیابی نیکویی برازش مدل های هیدرولوژی و هیدرودینامیک مورد استفاده واقع می شود (لگات و مک کابر ۱۹۹۹). این ضریب توسط ایجاد رگرسیون خطی بین مقادیر 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^۲ 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^۳:

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

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

۳. بحث و نتایج

طراحی شبکه عصبی

گزینه های زیادی در هنگام استفاده از ANN در مدل های بارش رواناب وجود دارد که کاربر بایستی بر اساس 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 بر اساس الگوریتم پس انتشار Levenberg–Marquardt (هاگان و منهاج ۱۹۹۴) می باشد. این الگوریتم یک تکنیک بهینه سازی غیرخطی درجه دوم است و معمولاً سریعتر و منطقی تر از سایر انواع پس انتشار است (ماسترز ۱۹۹۵، برتسکاس و سیتسیکلیس ۱۹۹۶، تان و کاوونرگ ۱۹۹۹).

^۱ - Correlation Coefficient

^۲ - Root Mean Square Error

^۳ - Volume Error

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

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t)\} \quad (۷)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1)\} \quad (۸)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), Q(t-2)\} \quad (۹)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), API_1\} \quad (۱۰)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), API_7\} \quad (۱۱)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), API_{15}\} \quad (۱۲)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), Q(t-2), API_1\} \quad (۱۳)$$

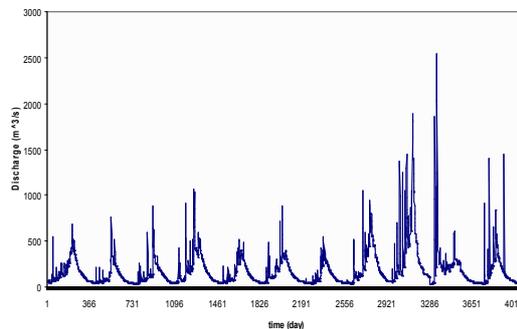
$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), Q(t-2), API_7\} \quad (۱۴)$$

$$Q(t) = f\{P_{ka}(t), P_{za}(t), P_{gh}(t), P_{ta}(t), Q(t-1), Q(t-2), API_{15}\} \quad (۱۵)$$

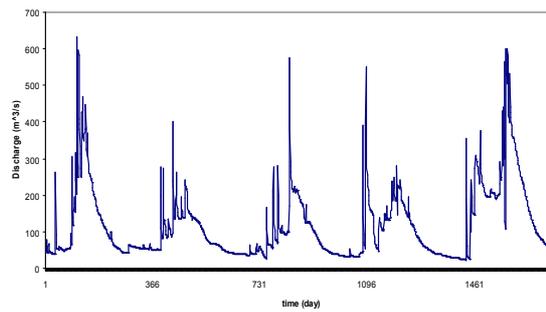
که Q متوسط دبی روزانه ایستگاه تنگ پنج و P_{ka} ، P_{za} ، P_{gh} و P_{ta} متوسط بارندگی روزانه ایستگاه کاظم آباد، زرد فهره، قلیان و تنگ پنج و API میزان بارش پیشین در ۱، ۷ و ۱۵ روز گذشته می باشند.

پیش پردازش، آموزش و آزمون شبکه

این مرحله شامل انتخاب متغیر های موثر، انتخاب الگوهای آموزش و آزمون، دسته بندی الگوها و نیز نرمال کردن (استاندارد کردن) الگوها به منظور هم ارزش کردن تمامی عناصر موجود در یک الگو می باشد. پس از نرمال کردن تمامی الگوها انتخاب الگوهای آموزش و آزمون انجام می گیرد. هیدروگراف هر دو دسته آزمون و آموزش مربوط به ایستگاه تنگ پنج به صورت شماتیک در شکل های ۲ و ۳ رسم شده اند. مطابق این شکلها ملاحظه می شود که مقادیر حدی در دوره اول (آموزش) واقع شده اند. جدول نتایج الگوهای آموزش و آزمون های مختلف نیز در ادامه (جدول ۱) آمده است.



شکل ۲- هیدروگراف آبدهی روزانه ایستگاه تنگ پنج در دوره آموزش



شکل ۳- هیدروگراف آبدهی روزانه ایستگاه تنگ پنج در دوره آزمون

جدول ۱- نتایج حاصل از الگوهای آموزش و آزمون با الگوی های مختلف

معماری شبکه	معیار ارزیابی	واسنجی	صحت سنجی
۴-۳-۱	RMSE	۲/۸۲۶۹	۲/۵۴۴۸
۵-۳-۱	RMSE	۱/۰۹۶۲	۰/۸۴۴
۶-۵-۱	RMSE	۱/۰۶۰۲	۰/۸۶۳۵
۶-۵-۱	RMSE	۱/۰۴۹۷	۰/۸۳۱۵
۶-۳-۱	RMSE	۱/۰۳۶۸	۰/۶۹۰۵
۶-۲-۱	RMSE	۱/۱۴۳۰	۰/۸۳۵۹
۷-۵-۱	RMSE	۱/۰۳۳۲	۰/۸۳۴۶
۷-۳-۱	RMSE	۱/۰۷۸	۰/۸۶۰۶
۷-۵-۱	RMSE	۱/۰۱۳۵	۰/۸۴۴۹

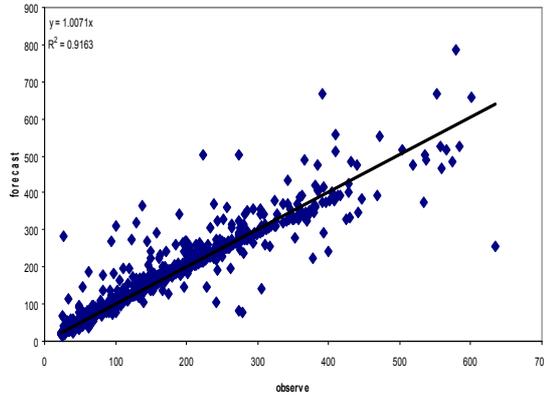
با توجه به نتایج حاصل از معیارهای ارزیابی، شبکه MLP^۱ (پرسپترون چند لایه) با شش ورودی معرفی شده در رابطه ۱۱ بهترین همبستگی و کمترین خطا را نسبت با سایر الگوها نشان داده که معماری شبکه پس از آزمون و خطاهای مکرر بصورت (۶-۳-۱) به معنای ۶ نرون ورودی، ۳ نرون پنهان و یک نرون خروجی (جدول ۲) بهینه شده است (شکل ۴).

جدول ۲- نتایج حاصل از الگوهای آموزش و آزمون با الگوی پنجم (رابطه ۱۱)

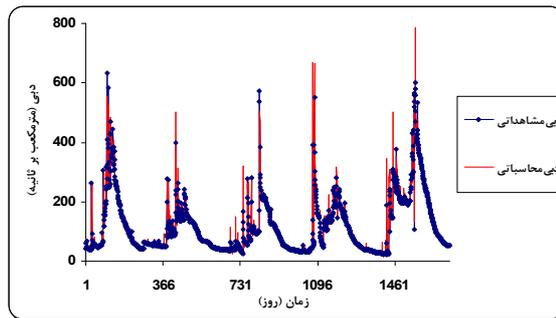
معماری شبکه	معیار ارزیابی	واسنجی	صحت سنجی
۶-۲-۱	RMSE	۰/۷۰۶۵	۱/۱۵۰۵
	%VE	۹/۲۰۷۶	۱۰/۰۶۴۳
	CORREL	۰/۹۵۵۳	۰/۹۱۲۸
۶-۳-۱	RMSE	۰/۶۹۰۵	۱/۰۳۶۸
	%VE	۷/۸۰۶۷	۸/۲۸۵۰
	CORREL	۰/۹۵۷۵	۰/۹۴۰۷
۶-۵-۱	RMSE	۰/۷۲۴۴	۱/۰۰۱۴
	%VE	۸/۵۵۲۷	۱۰/۴۱۲۲
	CORREL	۰/۹۵۲۶	۰/۹۱۴۳

^۱- Multiple Layer Perceptron

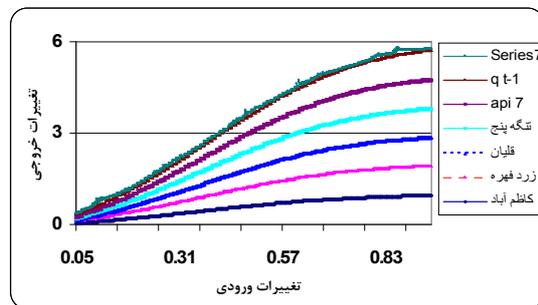
به منظور ارزیابی گرافیکی مدل بهینه، در شکل ۴ منحنی پراکندگی دبی پیش بینی شده در مقابل دبی مشاهده ای در مرحله آزمون و در شکل ۵ هیدروگراف های مشاهداتی و محاسباتی الگوی بهینه ترسیم گردیده است. شکل ۶ نیز به بررسی حساسیت مدل شبکه عصبی مصنوعی آموزش یافته به تغییرات در پارامترهای ورودی پرداخته است.



شکل ۴- منحنی پراکندگی دبی پیش بینی شده در مقابل دبی مشاهداتی با الگوی ۵ (رابطه ۱۱)



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



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

۴. نتیجه گیری

تعیین مقدار جریان سیلاب حاصل از بارندگی در حوزه های آبخیز، به دیگر پارامترهای هیدرولیکی و هیدرولوژیکی حوضه بسیار وابسته است که عدم امکان اندازه گیری دقیق آنها، توصیف رابطه ریاضی رابطه بین رواناب و دیگر متغیرها برای حصول نتایج نزدیک به واقعیت را تاکنون میسر نساخته است. در این تحقیق نیز به منظور پیش بینی روزانه جریان رودخانه و جهت نیل به اهداف بیان شده به بررسی نقش بارش پیشین در فرایند بارش- رواناب پرداخته شد و این پارامتر نیز به ورودی های مدل اضافه گردید.

همانطور که در جدول نتایج حاصل از الگوهای آزمایش و آزمون مختلف نیز مشاهده شد 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 تأثیر مثبتی در بهبود شبکه خواهند داشت؛ همچنین در پیش بینی جریان رودخانه، دبی روز قبل نقش اساسی را در مدل ایفا می کند و اگر از این پارامتر در الگوی ورودی استفاده نشود مدل های شبکه عصبی قادر به پیش بینی صحیح نمی باشند. از بررسی آنالیز حساسیت نیز مشاهده می گردد که در این الگو پارامترهایی که بیشترین تأثیر 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 تأثیر 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.

۵. منابع

- ۱- شرکت مهندسی مشاور مهتاب قدس (۱۳۷۷)، "طرح سد مخزنی و نیروگاه برقابی بختیاری". مطالعات مرحله اول پیوست (۳-۲). گزارش هیدرولوژی، شرکت توسعه منابع آب و نیروی ایران (آب نیرو).
- ۲- منهای، م. ب. (۱۳۷۷). "هوش محاسباتی (جلد اول)، مبانی شبکه های عصبی"، انتشارات دانشگاه صنعتی امیرکبیر.
- ۳- میثاقی، ف. و ک. محمدی. (۱۳۸۱)، "شبیه سازی بارش-رواناب و روندیابی رودخانه با استفاده از شبکه عصبی مصنوعی". مجموعه مقالات ششمین سمینار بین المللی مهندسی رودخانه. اهواز. ص ۴۵۵-۴۶۲.
4. 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.
5. Sejnowski, T and Roscnberg, C. (1987), "Parallel networks that learn to pronounce English text". Complex system, Vol. 1, 68-145.
6. Tokar, A.S. and M. Markus. (2000), "Precipitation runoff modeling using artificial neural networks." J. Hydrologic Engrg. ASCE, 5(2): 156-161.
7. Anctil, F. and A. Rat, (2005), "Evaluation of neural network stream flow forecasting on 47 watersheds," J. Hydrologic Engrg., ASCE, 10(1), 85-88.
8. Coulibaly, P., Anctil, F., and Bobee, B. (2000), "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach". Journal of Hydrology. Vol. 230, 244-257.
9. Maier, H.R., Dandy, G.C. (2000), "Neural Networks for prediction and forecasting of water resources variables: Review of modeling issues and applications". Environ. Model. Software 15, 101-124.
10. Heggen, R.J., (2001), "Normalized antecedent precipitation index". J. Hydrol. Engng 6(5), 377-381.
11. Legates, D.R., McCabe Jr., G.J., (1999), "Evaluating the use of goodness-of-fit measures in hydrologic and hydro-climatic model validation". Water Resources Research 35 (1), 233-241.
12. Hagan, M.T., Menhaj, M., (1994), "Training feed forward networks with the Marquardt algorithm." IEEE Trans. Neural Networks 5(6), 989-993.
13. Masters, T. (1995), "Advanced algorithms for Neural Networks: A C++ Sourcebook", Wiley, New York.
14. Bertsekas, D. P., Tsitsiklis, J.N., (1996), "Nero- Dynamic Programming, Athena Scientific", Belmont, MA.
15. Tan, Y., Van Cauwenberghe, A., (1999), "Neural Network based step ahead predictors for nonlinear systems with time delay". Eng. Appl. Artif. Intel. 12, 21-25.