

شبیه‌سازی فرآیند بارش - رواناب با شبکه عصبی مصنوعی (ANN) و

مقایسه با مدل HEC-HMS در حوزه معرف کارده

علیرضا جهانگیر - محمود رائینی* - میرخالق ضیاء احمدی^۱

تاریخ دریافت: ۸۵/۹/۶

تاریخ شروع: ۸۷/۱۱/۲۰

چکیده

سیل یکی از پدیده‌های ویرانگر طبیعی است که پیش‌بینی آن از اهمیت بالایی برخوردار است. برآورد بارش-رواناب و سیل، به دلیل تأثیرگذاری عوامل مختلف، دشوار است. تا کنون روش‌های مختلفی برای تحلیل این پدیده‌ها پیشنهاد شده است. هدف این پژوهش مقایسه کارآمدی شبکه‌های عصبی مصنوعی (ANNs) در شبیه‌سازی فرآیند بارش - رواناب با نتایج مدل HEC-HMS است. به این منظور حوزه کارده واقع در شمال شرقی خراسان برگزیده شد و باران‌نمودهای چندین پیشامد بارندگی و آبنمودهای رواناب آن‌ها (مجموع ۴۵۰ داده مربوط به ۳۰ پیشامد گزینش شده) مبنای کار قرار گرفت. سپس شبکه عصبی مصنوعی با الگوریتم پس‌پراکنش و استفاده از تابع تبدیل S-شکل آموزش داده شد. معیار گزینش پارامترهای شبکه در مرحله آموزش، تولید کمترین مقدار ریشه میانگین مربعات خطا (RMSE) در خروجی‌های آن بود. مدل HMS به روش پیشنهادی SCS اجرا گردید. برای ارزیابی کارایی ANN، داده‌های شبیه‌سازی شده و مشاهده‌ای مربوط به کل دبی و حجم رواناب، دبی‌های اوج و زمان‌های اوج مقایسه شدند. نتایج نشان داد که بر پایه قانون آموزش دلتا، شبکه پرسپترون چندلایه (MLP) با تعداد ۲۹ نرون در تنها لایه میانی (پنهان)، فرآیند بارش - رواناب را با دقت خوبی شبیه‌سازی می‌نماید. ضریب همبستگی کل داده‌های دبی و حجم رواناب شبیه‌سازی شده و مشاهده‌ای، به ترتیب ۰/۹۸ و ۰/۹۹ به دست آمد. ANN اندازه و زمان دبی‌های اوج را نیز به خوبی (به ترتیب، ۰/۹۸ و ۰/۸۳) برآورد کرد. با بررسی عملکرد مدل HMS، ضریب همبستگی کل داده‌های دبی و حجم رواناب ۰/۸۲ و ۰/۹۸ به دست آمد. همچنین ضریب همبستگی مربوط به اندازه و زمان دبی‌های اوج رواناب برآورد شده با مدل به ترتیب ۰/۹۷ و ۰/۷۰ برآورد شد. در آزمون t با سطح اعتماد ۹۹ درصد، اختلاف معنی‌داری میان اندازه‌های مشاهده‌ای و شبیه‌سازی شده مربوط به همه پارامترهای مورد نظر دیده نشد. در نتیجه، گرچه تفاوت معنی‌داری میان دو روش یافت نشد، ولی مقایسه عملکرد شبکه و مدل به کار رفته نشان می‌دهد که در تمام پارامترها، دقت ANN بیشتر از مدل HMS بوده است.

واژه‌های کلیدی: شبیه‌سازی، مدل هیدرولوژیکی، بارش - رواناب، شبکه عصبی مصنوعی، مدل HEC-HMS، حوزه کارده

مقدمه

رواناب و سیل، و از سوی دیگر پیچیدگی و دشواری مسایل مربوط به فرآیند بارش-رواناب، روش‌ها و مدل‌های چندی برای برآورد آن‌ها پیشنهاد شده است. شبکه‌های عصبی مصنوعی^۲ (ANN) یکی از دستاوردهایی می‌باشد که با

به سبب پیامدهای ویرانگر و آسیب‌های بی‌شمار ناشی از

۱- به ترتیب دانش‌آموخته کارشناسی ارشد سازه‌های آبی، استادیار و استاد گروه مهندسی آب، دانشکده مهندسی زراعی، مجتمع علوم کشاورزی و منابع طبیعی ساری،

دانشگاه مازندران

*- نویسنده مسئول Email: m.raeini@umz.ac.ir

حوزه، مدل HEC-1 در واسنجی پارامترها و شبیه سازی دقت بیشتری دارد. برای برآورد دبی سیلاب در حوزه جاغرق، در شمال خراسان، میرزاخان (۱۰) از دو روش شیب-سطح و سامانه مدل سازی آبشناختی^۷ (HMS) استفاده کرد. او نتیجه گرفت که برای برآورد دبی سیلاب روش شیب-سطح نسبتاً دقیق است، ولی بسیار وقت گیر و حساس می باشد. افزون بر این، چنانچه از رابطه کیریچ^۸ برای تعیین زمان تمرکز^۹ در مدل HMS استفاده شود، نتایج بهتری نسبت به دیگر روش ها به دست خواهد آمد. مینس و هال (۱۷) با بررسی ANN در مرحله آموزش، و استفاده از یک و دو لایه پنهان، پیشنهاد کردند که، گرچه به ازای لایه های پنهان بیشتر در اجرای شبکه بهبودی حاصل می شود، اما محاسبات اضافی برای تعیین درجه اهمیت رفتار ناخطی بارش و تداوم جریان توجیه پذیر نیست. داوسون و وایلی (۱۴)، ضمن تشریح روند کلی کاربرد ANN در پیش بینی سیلاب مربوط به حوزه هایی با ویژگی های متفاوت، از تابع تبدیل S شکل^{۱۰} استفاده کردند. نتایج آنان نشان داد که حتی با وجود خطا در اطلاعات ورودی، ANN می تواند اندازه های واقعی را با دقت بالایی پیش بینی کند. اما، تعیین پارامترهای بهینه آموزش ANN، به اطلاعات بیشتری از آشناسی حوزه نیاز دارد. تاگر و مارکوس (۲۱)، شبکه عصبی مصنوعی و یک مدل مفهومی را برای پیش بینی رواناب در حوزه هایی با ویژگی های فیزیکی و اقلیمی متفاوت به کار بستند. از مقایسه نتایج دو روش مشخص شد که در همه موارد شبکه دقت و سرعت بیشتری، و زمان تمام شده کمتری دارد، و در شبیه سازی بارش-رواناب با بازه های زمانی متفاوت توانا تر از روش مفهومی است. راجورکار و همکاران (۱۸)، مدل

الگوبرداری از شبکه عصبی مغز انسان، می تواند پدیده های پیچیده و ناشناخته را به خوبی بررسی نماید (۹). دیدگاه نوین شبکه عصبی، با افزودن عمل شرط گذاری^۱ به عنوان قانون آموزش مطرح شد که با پیدایش شبکه پرسپترون تک لایه^۲ و قانون یادگیری ای با همین نام توسعه یافت. سپس با طرح الگوریتم پس پراکنش^۳ (BP) و گسترش ریزپردازنده ها^۴، دگرگونی شگرفی در دنیای شبکه عصبی مصنوعی پدید آمد (۹).

برای پدیده بارش-رواناب و فرآیندهای پی آمد آن، پژوهشگران از مدل های گوناگونی برای شبیه سازی استفاده کرده اند. محمد صالحی (۸) با بهره گیری از مدل ریاضی مبتنی بر «سامانه اطلاعات جغرافیایی»^۵ فرآیند بارش-رواناب را برای حوزه آبریز امامه شبیه سازی کرد، و مدل با دقت بالایی حجم و زمان اوج سیلاب را برآورد نمود. فرهمندکناری (۷) برای پهنه بندی خطر رخداد سیلاب در رودخانه بابلرود از مدل هیدرولیکی HEC-RAS در محیط GIS استفاده کرد. میرزاخان (۱۰) نیز برای پهنه بندی سیلاب در رودخانه طالقان، مدل HEC-1 به کار بست و با مقایسه نتایج حاصل از روش «سرویس پایش خاک»^۶ SCS و موج سینماتیکی پیشنهاد کرد که روش SCS با خطای نسبی کمتر از یک درصد، دبی های اوج رویدادهای مورد نظر را بهتر از موج سینماتیکی برآورد می کند. اکبرپور (۲)، با شبیه سازی بارش-رواناب در حوزه های معرف امامه و کسلیان، مدل های HEC-1 و TR-20 را نسبت به مدل آنمود ژئومورفو-آب و هوایی مناسب تر دانست. همچنین با داشتن داده های بیشتر مربوط به ویژگی های فیزیکی سطح و رطوبت خاک

- 1 - Conditioning
- 2 - Single Layer Perceptron
- 3 - Back-Propagation Algorithm (BP)
- 4 - Microprocessors
- 5 - Geographic Information System
- 6 - Soil Conservation Service

- 7 - Hydrologic Modeling System
- 8 - Kirpich
- 9 - Concentration Time
- 10 - Sigmoid

ناخظی ANN را برای شبیه‌سازی جریان روزانه در دو حوزه با موقعیت جغرافیایی متفاوت به کار بردند. آنان با مقایسه نتایج پیشنهاد کردند که حوزه‌های بزرگ بایستی به چند زیرحوزه تقسیم شوند. انکتیل و همکاران (۱۱)، برای برآورد جریان سیل یک روز آینده با بهره‌گیری از شبکه پرسپترون چندلایه و مقایسه نتایج آن با یک مدل مفهومی، چنین تشخیص دادند که شبکه پرسپترون چندلایه، در مرحله آموزش، متأثر از طول دوره داده‌ها بوده و برای داده‌های طولانی‌تر از یک روز بهتر از مدل مفهومی عمل می‌کند. سلطانی (۵)، با مقایسه عملکرد مدل‌های مفهومی و شبکه عصبی مصنوعی در شبیه‌سازی فرآیند بارش-روانآب، چنین عنوان کرد که در مقایسه با دیگر مدل‌ها، ANN به اطلاعات کمتری نیاز دارد و روند واسنجی و صحت‌یابی آن سریع‌تر و آسان‌تر است. از سویی دیگر، ANN در زمان کم‌آبی و مدل‌های مفهومی در زمان پرآبی عملکرد بهتری دارند. بر پایه آموزش مدیریت شده، او شمار تکرارهای آموزش را در عملکرد شبکه بسیار تأثیرگذار دانست.

به باور بیشتر پژوهشگران (۱ و ۵) و به دو دلیل عمده، در تحلیل مسایل ناشناخته و پیچیده، ANN عملکرد بهتری دارد. نخست اینکه با برخورداری از توانایی تشخیص الگو، رابطه خوبی میان ورودی و خروجی داده‌های پدیده مورد نظر برقرار می‌کند. دوم اینکه در قیاس با دیگر الگوها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی از خود نشان می‌دهد. دلیل این امر به خاطر پردازش پخشیده^۱ اطلاعات است، به طوری که فرآیند پردازش کاملاً کاملاً موازی صورت گرفته و به جای این که تمام بار محاسبه به یک یکان پردازشگر تحمیل شود، شمار بسیاری از یکان‌های پردازشگر همزمان عمل کرده و با کم شدن سهم هر یک از آن‌ها، تأثیر منفی کمتری در عملکرد و

خروجی شبکه ایجاد می‌شود (۹).

ساختار کلی ANN از سه لایه متفاوت تشکیل شده است (شکل ۱- الف). لایه ورودی که پخش داده‌ها در شبکه و لایه میانی (پنهان)^۲ فرآیند پردازش آن‌ها را بر عهده دارد. لایه خروجی نیز افزون بر پردازش داده‌ها، به ازای بردار ورودی شبکه، خروجی و عملکرد آن را نشان می‌دهد (۵).

نرون^۳ (شکل ۱- ب)، کوچکترین یکان پردازشگر شبکه است. چنان که در رابطه ۱ نشان داده شده است، عملکرد شبکه عصبی مصنوعی به گونه‌ای است که مقدار ورودی خالص در هر نرون را از مجموع حاصل ضرب ماتریس ورودی P با عناصر $P_i (i=1, 2, \dots, r)$ و ماتریس وزن W با عناصر $W_i (i=1, 2, \dots, r)$ به همراه مقدار ثابت ۱ با وزن b، تولید می‌کند.

$$n = \sum_{i=1}^k p_i w_{i1} + b = WP + b \quad (1)$$

در رابطه بالا، k تعداد پارامترهای بردار ورودی و b وزن اریب^۴ است. در پایان با اعمال تابع فعالیت (تبدیل)^۵، خروجی شبکه به صورت رابطه ۲ خواهد بود (۹).

$$a = f(WP + b) \quad (2)$$

در مرحله معماری یا همان تعیین ساختار کلی شبکه، گزینش تعداد و چگونگی قرار گرفتن لایه‌ها و همچنین وزن‌های اتصال به عهده فرد طراح است (۱۲ و ۱۵).

به منظور بررسی فرآیند بارش-روانآب و سیل تا کنون روش‌های مختلفی پیشنهاد شده است، ولی تا آنجا که ما می‌دانیم تا کنون مقایسه‌ای روی کارآمدی روش‌ها انجام نشده است. هدف این پژوهش مقایسه کارآمدی شبکه‌های عصبی مصنوعی (ANNs) در شبیه‌سازی فرآیند بارش-روانآب در مقایسه با نتایج مدل HEC-HMS می‌باشد.

2 - Middle (Hidden) Layer


3 - Neuron

4 - Bias Weight

5 - Activation (Transfer) Function

1 - Distributed Processing

Archive of SID



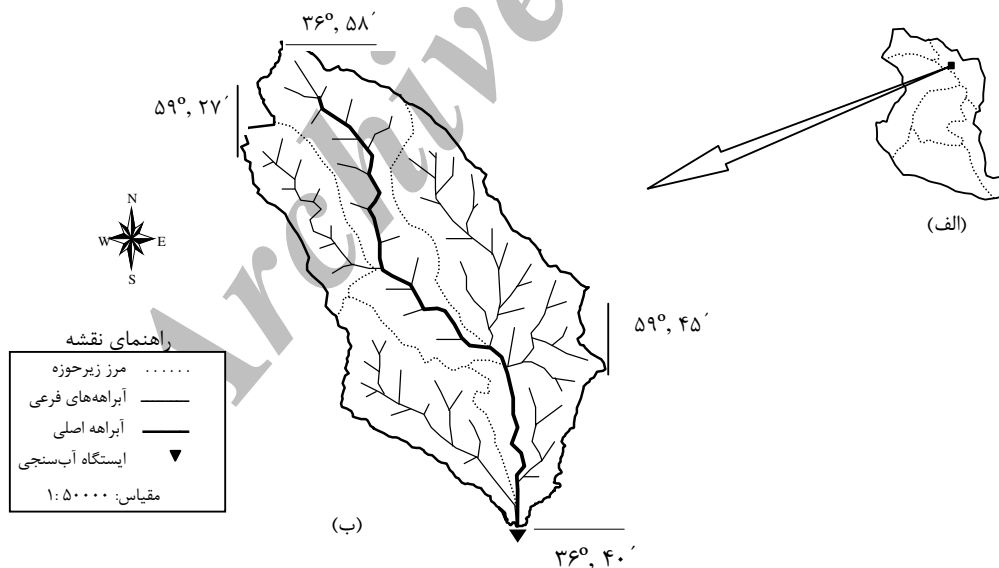
شکل ۱- (الف) ساختار کلی شبکه عصبی مصنوعی، (ب) نرون عصبی با تعداد ۲ ورودی

اندازه گیری و ثبت داده‌ها می‌باشد (۳). برای گردآوری و تهیه داده‌های مورد نیاز این پژوهش، آمار مربوط به چندین پیشامد بارندگی و رواناب متناظر آن‌ها از گزارش‌های سازمان آب منطقه‌ای خراسان برای سال‌های ۱۳۶۲ تا ۱۳۸۲ خورشیدی (۴) استخراج گردید. کل داده‌ها شامل ۴۵۰ مورد بارش و رواناب نظیر آن‌ها بود که از ۳۰ پیشامد متفاوت گزینش شده به دست آمد.

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز کارده با ۵۴۳ کیلومتر مربع پهنا، شیب ۰/۲۶٪، طول آبراهه اصلی ۴۴/۲۴ کیلومتر و شماره منحنی ۸۰ در شمال خاوری خراسان بزرگ (شکل ۲)، بین عرض‌های جغرافیایی ۳۶°۴۰' و ۳۶°۵۸' شمالی، و طول جغرافیایی ۴۵°۵۹' و ۴۵°۲۷' خاوری قرار دارد. کارده یکی از حوزه‌های معرف کشور و مجهز به ابزارهای مناسب برای



شکل ۲- (الف) نقشه موقعیت، و (ب) شبکه آبراهه‌های حوزه آبریز کارده در شمال خراسان بزرگ

آمار مورد استفاده در این بررسی از ایستگاه‌های باران - نگاری و ایستگاه آبنسجی واقع در حوزه که داده‌های بارش

پرسپترون چندلایه با الگوریتم BP برگزیده شد. این شبکه در نرم افزار «NeuralWorks Professional II/PLUS» اجرا گردید که در آن امکان تعیین همه پارامترهای مربوط به طراحی ساختار بهینه شبکه وجود دارد. مهمترین این پارامترها شمار نرون لایه پنهان، تعداد تکرارهای آموزش و اندازه چرخه آموزش شبکه است، که طبق نظر پدیدآورندگان آن (۱۵ و ۱۹)، به صورت آزمون و خطا انجام می گیرد. تابع ناخطی S شکل (رابطه ۳)، به عنوان تابع تبدیل شبکه مورد استفاده قرار گرفت:

$$f(x_i) = \frac{1}{1 + e^{-x_i}} \quad (3)$$

در رابطه بالا، x_i داده استفاده شده در هر مرحله از اجرای شبکه است.

بر این اساس شبکه‌هایی با تعداد لایه‌های پنهان و تعداد نرون متفاوت در هر لایه، طراحی و نتایج آن‌ها بررسی و مقایسه گردید. معیار گزینش ساختار بهینه شبکه، کمینه اندازه ریشه میانگین مربعات خطای $(RMSE)^2$ آن بود (رابطه ۴).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{obs} - x_{est})^2}{n}} \quad (4)$$

در رابطه بالا، x_{obs} و x_{est} به ترتیب مقدار مشاهده‌ای و برآورد شده داده و n تعداد کل داده‌ها است.

روش آموزش شبکه، همانند دیگر گزارش‌ها (۹ و ۱۹)، بر پایه قانون آموزش دلتا بود. به این منظور پس از آماده‌سازی داده‌ها، آن‌ها به دو دسته جداگانه تقسیم شدند. داده‌های هر پیشامد در یک ردیف قرار گرفته و کل داده‌ها، کل ردیف‌ها را می‌سازند. گزینش چند ردیف برای آموزش و ردیف‌های باقیمانده برای صحت‌یابی مدل به صورت تصادفی (با دستور RAND در محیط EXCEL) انجام

متوسطی از داده‌های کل ایستگاه‌های باران‌سنجی در سطح حوزه و داده‌های رواناب متناظر هر بارش از ایستگاه واقع در خروجی منتهی به ورودی مخزن سد کارده بود برداشت شده است. برای اطمینان بیشتر از گزینش مناسب باران‌نمودها^۱ و آبنمودها^۲، زمان تمرکز حوزه به روش SCS محاسبه گردید (۶). سپس داده‌هایی که با زمان به دست آمده همخوانی بیشتری داشتند، یعنی با حذف داده‌های ناقص و یا مشکوک از نظر اندازه و یا زمان رخداد، مبنای کار قرار گرفتند. برای اجرای مرحله‌های آموزش و آزمون شبکه، ارتفاع بارندگی در ساعت‌های مختلف بارش به عنوان ورودی (نهاد) شبکه و دبی‌های رواناب متناظر آنها به عنوان خروجی (ستانده) شبکه برگزیده شد. مدل به کار رفته نیز بر پایه‌ی همین داده‌ها و دیگر اطلاعات مورد نیاز مدل، به‌ویژه خصوصیات فیزیکی سطح حوزه، مانند مساحت، زمان تمرکز، درصد نفوذناپذیری سطح، شماره منحنی معرف و نوع کاربری استفاده شد. برای اجرای شبکه و همخوانی خروجی آن با خروجی مدل و امکان مقایسه آن‌ها، تعداد بردارهای ورودی شبکه (زمان تداوم بارش) و تعداد بردارهای خروجی شبکه (زمان تداوم رواناب متناظر هر بارش) به اندازه بزرگترین زمان تداوم بارش (۱۱ ساعت) و رواناب (۱۵ ساعت) در نظر گرفته شده تا امکان استفاده از همه پیشامدها وجود داشته باشد.

شبکه عصبی استفاده شده

بر اساس پژوهش‌های انجام شده (۱۲ و ۱۳)، ۹۰ درصد شبکه‌های عصبی مصنوعی که در مسایل آب‌شناختی مورد استفاده قرار گرفته‌اند، از نوع الگوریتم پس‌پراکنش (BP) هستند. از این رو برای شبیه‌سازی فرآیند بارش-رواناب، شبکه

1 - Hyetograph
2 - Hydrograph

3 - Root of Mean Squares Error

فرمول زیر استفاده گردید (۲۲):

$$T_l = \frac{L^{0.8} (S + 1)^{0.7}}{1900y^{0.5}} \quad (۶)$$

در رابطه بالا، T_l پسماند زمانی (ساعت)، L و y به ترتیب طول (فوت) و شیب (درصد) آبراهه اصلی حوزه است.

به منظور ارزیابی عملکرد ANN و مدل HMS، افزون بر مقایسه کیفی نمودارهای مربوط به هر یک از پارامترهای مورد نظر و RMSE، از معیارهای ضریب همبستگی (r)، میانگین قدر مطلق خطا^۴ (MAE) و درصد خطای کل^۵ (TE) نیز استفاده شد. از نرم افزار آماری SAS (۲۰) برای محاسبه و آزمون این روابط استفاده شد.

$$MAE = \frac{\sum |X_{obs,i} - X_{est,i}|}{n} \quad (۷)$$

$$TE = \frac{(\sum X_{obs,i} - \sum X_{est,i})}{\sum X_{obs,i}} \times 100 \quad (۸)$$

در رابطه‌های بالا، X_{obs} اندازه مشاهده‌ای و X_{est} اندازه پیش‌بینی شده توسط شبکه عصبی مصنوعی و یا مدل از پارامتر مورد نظر رواناب می‌باشد.

نتایج و بحث

الف- تعیین ساختار بهینه ANN

برای دستیابی به ساختار بهینه ANN، شبکه‌هایی با تعداد نرون‌های متفاوت در لایه پنهان مورد ارزیابی قرار گرفت. در میان شبکه‌های مورد بررسی شبکه‌ی ۲۹ نرون در لایه پنهان از کمترین مقدار RMSE برخوردار بود (شکل ۳). در این زمینه پژوهشگران دیگری (۱۶ و ۱۸) نیز شمار نرون‌های لایه میانی، برای چنین پدیده‌ای را در همین حد پیشنهاد کردند. در این آزمایش، این مرحله برای لایه دوم نیز به اجرا درآمد، که بهبودی چشمگیری در عملکرد شبکه

می‌گیرد تا دقت بیشتری داشته باشد. برخی نویسندگان (۱ و ۵) بر این باورند که تا ۸۰ درصد داده‌ها برای آموزش شبکه و بازمانده آن‌ها برای آزمون و صحت‌یابی نتایج به کار گرفته می‌شود. این بررسی‌ها در محیط نرم‌افزارهای EXCEL و SAS (۲۰) انجام شد.

مدل HEC-HMS

مدل آشناختی HEC-HMS، که از سوی مرکز مهندسی آشناسی^۱ (HEC) ارتش امریکا ارائه گردید، توانایی بررسی بارش - رواناب و روندیابی جریان را دارد. در نسخه‌های نوین این مدل (HEC-GeoHMS)، امکان ارتباط با دیگر نرم‌افزارها، مانند سامانه اطلاعات جغرافیایی، وجود دارد که این باعث ارتباط درست و سریع‌تر شده و روند بررسی هر گونه پیشامد آشناسی را در زمان کوتاه‌تری ممکن می‌سازد (۲۲). در HMS رابطه‌ای از رواناب سطحی گنجانده شده است که بر مبنای باران نمود بارش ورودی عمل می‌کند. به طوری که پس از کسر تلفات اولیه، و بر پایه روابط SCS (رابطه ۵)، بارش مازاد را محاسبه نموده و آبنمود رواناب آن را به دست می‌دهد (۶). برای این منظور بایستی پسماند زمانی^۲، درصد نفوذناپذیری و شماره منحنی^۳ (CN) حوزه به مدل داده شود (۲۲).

$$P_e = \frac{(P - I_a)^2}{P - I_a + S} \quad (۵)$$

که در آن، P_e ارتفاع رواناب، P ارتفاع بارندگی، I_a تلفات اولیه، $(I_a = 0.2S)$ ، و S نگهداشت سطح حوزه است که به روش میانگین وزنی، بر مبنای شماره منحنی برآوردی به دست می‌آید.


برای برآورد پسماند زمانی حوزه در روش SCS از

4 - Mean of Absolute Error
5 - Total Error

1 - Hydrology Engineering Center (HEC)
2 - Lag Time
3 - Curve Number

به دست آمد (شکل ۴). به باور شماری از پژوهشگران (۵ و ۱)، این اندازه هر چه بزرگتر باشد دقت پیش‌بینی بیشتر خواهد بود، به همین دلیل برای عدد پیش‌فرض نرم‌افزار (۵۰۰۰۰ تکرار) اندازه‌های کمتر و بیشتر مورد بررسی قرار گرفت تا نتایج از اعتبار بیشتری برخوردار گردد. همچنین انکتیل و همکاران (۱۱) پیشنهاد کردند که در این مرحله، دقت به طول دوره زمانی داده‌ها وابسته است.

دیده نشد. مینس و هال (۱۷) با بررسی ANN در مرحله آموزش و استفاده از یک و دو لایه پنهان، پیشنهاد کردند که، گرچه به ازای لایه‌های پنهان بیشتر در اجرای شبکه بهبودی حاصل می‌شود، ولی محاسبات اضافی برای تعیین درجه اهمیت آن توجیه‌پذیر نخواهد بود. برای تعیین اثر شمار تکرارهای آموزش، عملکرد شبکه با تکرارهای متفاوت بررسی شد که بیشترین دقت شبکه با ۷۰ هزار تکرار



شکل ۳- مقایسه RMSE شبکه بر پایه شمار نرون‌های لایه پنهان (●: اندازه گزینش شده است)


همچنین با گزینش چرخه‌های آموزش^۱ متفاوت (تعداد ردیف‌های داده‌ها که شبکه در مرحله آموزش به طور همزمان در بر گرفته و تا رسیدن به پایان ردیف داده‌ها ادامه می‌دهد)، مشاهده شد که با کم شدن اندازه چرخه، سرعت آموزش شبکه کندتر شد، ولی دقت خروجی آن بهبود یافت. کمترین مقدار خطای شبکه با اندازه چرخه یک به دست آمد (شکل ۵). در بررسی‌های مشابه‌ای (۱ و ۵) دیده شده که هرچه این اندازه کمتر باشد، شبکه ضمن آموزش، شمار دفعات خوانش داده‌ها را بیشتر انجام داده و در نتیجه خروجی آن از دقت بالاتری برخوردار می‌شود. همان‌طور که در شکل‌های (۳، ۴ و ۵)، مشخص است نتایج تغییرات پارامترهای ساختار شبکه روند خاصی را طی نکرده و از این‌رو گزینش اندازه بهینه پارامترهای ساختار شبکه به

صورت آزمون و خطا صورت می‌گیرد. این مسئله توسط دیگر پژوهشگران (۹، ۱۲ و ۱۹)، در بررسی‌های مشابه‌ای از این پدیده، نیز تأیید شده است.

ب- ارزیابی عملکرد ANN و مدل HEC-HMS


همبستگی‌های بالا و معنی‌داری میان دبی‌های مشاهده‌ای و پیش‌بینی‌شده، هم برای ANN و هم برای مدل HMS (شکل ۶ الف) دیده شد (به ترتیب ۰/۹۸ و ۰/۸۲)، که این گویای آن است که هم شبکه و هم مدل با دقت خوبی رواناب را شبیه‌سازی می‌کنند. برای بررسی همانندی دو مدل، داده‌های پیش‌بینی شده‌ی دو مدل برای پیشامدهای مورد بررسی، با بهره‌گیری از آزمون t-استودنت، مقایسه گردیدند.

1 - Epoch



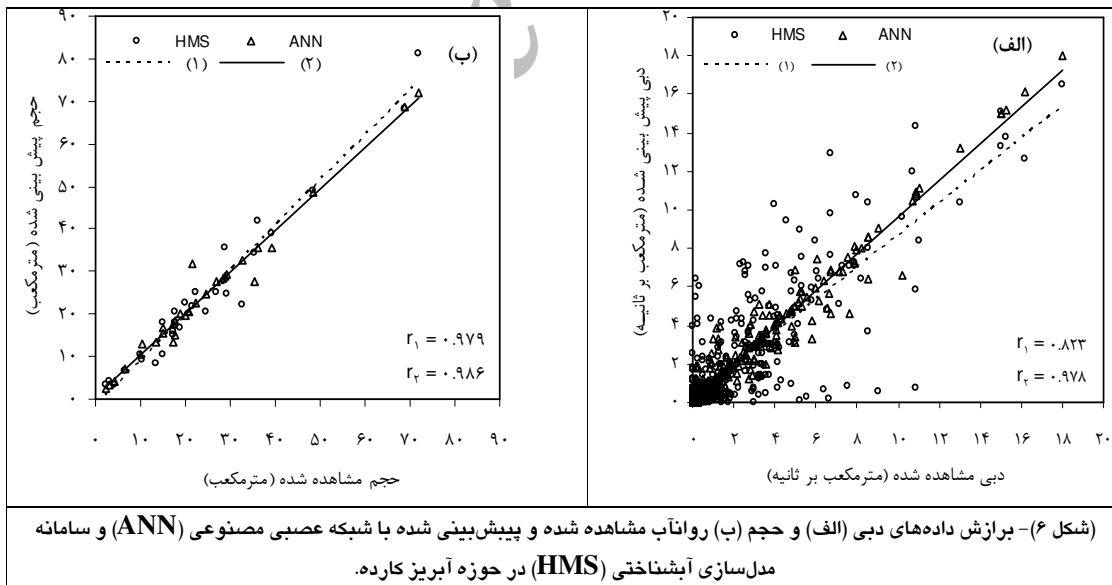
تعداد تکرارهای آموزش (هزار)

(شکل ۴) - مقایسه RMSE شبکه بر پایه شمار تکرارهای آموزش (●: اندازه گزینش شده است)



اندازه چرخه آموزش

(شکل ۵) - مقایسه RMSE شبکه بر پایه اندازه چرخه آموزش (●: اندازه گزینش شده است)




(شکل ۶) - برآزش داده‌های دبی (الف) و حجم (ب) رواناب مشاهده شده و پیش‌بینی شده با شبکه عصبی مصنوعی (ANN) و سامانه مدل‌سازی آشنناختی (HMS) در حوزه آبریز کارده.

مدل توانایی بالایی در پیش‌بینی پیشامدهای باران-رواناب دارند. ولی چون همبستگی در شبکه بالاتر


نتایج این مقایسه نشان داد که تفاوت معنی‌داری میان داده‌های برآورد شده دو مدل دیده نمی‌شود، بنابراین هر دو

گزارش کرده‌اند، این دلالت بر دقت بالای این دو مدل دارد. علت این است که محاسبه حجم رواناب آبنمودها بدون در نظر گرفتن پسماند زمانی آن نسبت به نمونه واقعی صورت گرفت. با مقایسه دبی‌ها و زمان‌های اوج دیدبانی و برآورد شده، ضرایب بین دبی‌های اوج (شکل ۷ الف) و زمان‌های اوج (شکل ۷ ب) مشاهده‌ای و برآورد شده شبکه و مدل همبستگی‌های بالا و معنی‌داری (به ترتیب ۰/۹۸ و ۰/۹۷؛ ۰/۸۳ و ۰/۷۰) دیده شد، و آزمون t (سطح اعتماد ۹۹ درصد) نیز تفاوت معنی‌داری میان آن دو نیافت. برخی نویسندگان (۱۰ و ۱۹) پیشنهاد کردند که در مدل HMS امکان رسیدن به دبی اوج با دقت بیشتری وجود دارد، که البته در این صورت خطای حجم رواناب افزایش چشمگیری خواهد داشت.



است ($r = 0/98$)، خروجی شبکه نسبت به خروجی مدل از دقت بیشتری برخوردار بود. این نتایج مشابه مواردی است که از در پژوهش‌های قبلی (۱۰، ۱۱ و ۱۸) بیان شده است. دلیل اصلی این است که شبکه بر اساس مقدار دبی ساعتی آموزش دیده و در پایان بر همان مبنا پاسخ می‌دهد، اما مدل HMS از روابط مشخصی پیروی کرده و از ویژگی‌های حوزه و بارش تأثیر زیادی می‌پذیرد.

همبستگی میان حجم رواناب مشاهده‌ای و برآورد شده در یک بازه زمانی ثابت یک ساعته در آبنمودها، برای شبکه و مدل بسیار بالا و معنی‌دار بود (به ترتیب ۰/۹۹ و ۰/۹۸) ($r = 0/98$) (شکل ۶ ب). اختلاف معنی‌داری (آزمون t استودنت) نیز بین حجم رواناب برآوردی و دیدبانی شده برای شبکه و مدل دیده نشد، و همان‌گونه که دیگران (۵ و ۱۰) نیز





(شکل ۷- برآزش داده‌های دبی اوج (الف) و زمان اوج (ب) رواناب مشاهده شده و پیش‌بینی شده با شبکه عصبی مصنوعی (ANN) و سامانه مدل‌سازی آبخاکی (HMS) در حوزه آبریز کارده.

(شکل ۸ الف)، و نبود تفاوت معنی‌داری میان آن‌ها، به نظر می‌رسد مدل در برآورد پیشامدها از دقت خوبی برخوردار باشد. همچنین به دلیل توانایی شبکه در برآورد زمان پایه آبنمود، برآزشی از زمان‌های پایه‌ی برآورد شده با شبکه، و

به منظور بررسی بیشتر عملکرد ANN و HMS و دستیابی به نتایج بهتر، مقایسه‌ای میان فاصله مرکز ثقل آبنمودهای واقعی و شبیه‌سازی شده با مدل صورت گرفت، که با توجه به ضریب همبستگی بالا ($r = 0/93$)

اندازه‌های واقعی آن‌ها (شکل ۸ ب) صورت گرفت که

همبستگی بالایی ($r = 0.90$) میان آن‌ها به دست آمد.



(شکل ۸) - برازش داده‌های زمان مرکز ثقل (الف) و زمان پایه (ب) رواناب مشاهده شده و پیش‌بینی شده به ترتیب با سامانه مدل‌سازی آبخشناختی (HMS) و شبکه عصبی مصنوعی (ANN) در حوزه آبریز کارده.

سرعت شبکه که تابع طول دوره زمانی داده‌ها است کندتر می‌شود، ولی همان‌گونه که انکتیل و همکاران (۱۱) پیشنهاد کردند نتایج شبکه از دقت و اعتبار بیشتری برخوردار خواهد بود. افزون بر این، بر پایه یک پژوهش (۱۸)، با توجه به بزرگی سطح حوزه، چنانچه شبکه با داده‌های هر زیرحوزه جداگانه انجام شود، نتایج شبکه از همخوانی بیشتری در مقایسه با مدل برخوردار خواهد بود.

سپاسگزاری

در راستای انجام این پژوهش از آقایان دکتر ابوالفضل اکبریور، دکتر افشین اشرف‌زاده، مهندس مهدی جهانگیر و مهندس قاسم آقاجانی به خاطر راهنمایی و همکاری‌های بی‌دریغشان سپاسگزاری می‌شود.

دیگر معیارهای مربوط به ارزیابی عملکرد ANN و HMS در (جدول ۱) آورده شده است. گرچه بر پایه آزمون t-استودنت تفاوت معنی‌داری میان داده‌های برآوردی شبکه عصبی مصنوعی و مدل HMS دیده نشد، ولی داده‌های (جدول ۱) نشان می‌دهند که شبکه در برآورد پیشامدهای باران-رواناب از دقت بیشتری برخوردار بوده است که این مطلب در بررسی دیگری (۱۴) نیز تأیید شده است. در نتیجه، ما در این ارزیابی شبکه‌های عصبی مصنوعی را، در برآورد رخدادهای بارش-رواناب، برتر از مدل HMS می‌دانیم. در این بررسی همسان با سایر بررسی‌ها (۵ و ۱۸)، مشخص شد که مدل آبخشناختی بکار رفته نسبت به شبکه عصبی مصنوعی به داده‌های بیشتری از وضعیت آبخشناختی حوزه نیاز دارد و با یکسری داده مشابه، شبکه عصبی یک روش سریع‌تر برای برآورد پارامترهای رواناب خواهد بود. همچنین مشخص شد که هرچه شمار تکرارهای آموزش بیشتر در نظر گرفته شود،

جدول ۱- معیارهای ارزیابی عملکرد شبکه عصبی مصنوعی (ANN) و سامانه مدل‌سازی آبشناختی (HMS) برای حوزه آبریز کارده.

مشخصه رواناب								
R ²	RMSE	MAE	TE (%)	میانگین	بیشینه	کمینه		
۰/۶۸	۱/۶۵	۰/۸۹	۰/۷۵	۱/۶۰	۱۶/۴۷	۰/۰۰	HMS	دبی (مترمکعب بر ثانیه)
۰/۹۶	۰/۵۷	۰/۲۴	۰/۰۵	۱/۶۱	۱۸/۰۳	۰/۰۰	ANN	
۰/۹۶	۳/۷۲	۲/۶۵	۰/۷۵	۲۳/۹۸	۸۱/۱۷	۳/۳۳	HMS	حجم (مترمکعب)
۰/۹۷	۲/۷۰	۱/۳۴	۰/۰۵	۲۴/۱۵	۷۱/۸۰	۲/۳۱	ANN	
۰/۹۵	۱/۳۰	۰/۹۶	۹/۳۷	۶/۸۶	۱۶/۴۷	۰/۷۳	HMS	دبی اوج (مترمکعب بر ثانیه)
۰/۹۶	۰/۹۵	۰/۵۵	۴/۸۷	۷/۲۰	۱۸/۰۳	۰/۶۷	ANN	
۰/۴۸	۰/۹۱	۰/۶۵	۶/۸۰	۴/۲۳	۶	۲	HMS	زمان اوج (ساعت)
۰/۶۹	۰/۷۵	۰/۳۷	۵/۸۳	۳/۷۷	۷	۲	ANN	
۰/۸۰	۱/۵۷	۱/۰۷	۹/۳۳	۱۲/۵۰	۱۵	۴	ANN	زمان پایه (ساعت)
۰/۸۶	۰/۷۷۲	۰/۶۳۴	۱/۲۳	۴/۰۲	۷/۴	۱/۳۸	HMS	زمان مرکز نقل (ساعت)

منابع

- اشرف‌زاده، ا. ۱۳۷۸. کاربرد شبکه‌های عصبی مصنوعی در برآورد تبخیر از سطح حوضچه‌های تبخیری. پایان‌نامه کارشناسی ارشد. دانشگاه تهران. ۱۰۱ ص.
- اکبرپور، ا. ۱۳۷۷. ارزیابی عملکرد مدل‌های هیدرولوژیک در حوزه‌های آبریز معرف امامه و کسلیان. پایان‌نامه کارشناسی ارشد. دانشگاه فردوسی مشهد. ۱۱۴ ص.
- سازمان توسعه منابع آب کشور (تماب). ۱۳۷۴. شناسایی و معرفی حوزه‌های آبریز معرف. بولتن وضعیت منابع آب کشور. بخش آب‌های سطحی. شماره‌های ۹ و ۱۰.
- سازمان آب منطقه‌ای خراسان. ۳۶۲ تا ۱۳۸۲. گزارش‌های آماری حوزه معرف کارده. واحد تلفیق. دفتر مطالعات آب‌های سطحی.
- سلطانی، س. ۱۳۸۱. مقایسه مدل‌های تفهیمی با شبکه‌های عصبی مصنوعی در شبیه‌سازی بارش-رواناب. پایان‌نامه کارشناسی ارشد. دانشگاه تربیت مدرس. ۹۸ ص.
- علیزاده، ا. ۱۳۷۶. اصول هیدرولوژی کاربردی. چاپ نهم، مرکز انتشارات آستان قدس رضوی. دانشگاه فردوسی مشهد. ۶۳۴ ص.
- فرهنگ‌کناری، س. ش.، رائینی، م.، سلیمانی، ک. و نوروزی، ف. ۱۳۸۶. پهنه‌بندی خطر وقوع سیل با استفاده از مدل هیدرولیکی HEC-RAS در محیط GIS (مطالعه موردی: رودخانه بابلرود). مجموعه مقالات سومین کنگره سراسری آبخیزداری و مدیریت منابع آب و خاک، کرمان، ۲۱-۲۰ شهریور ۱۳۸۶. جلد دوم، صفحات ۱۰۳۳-۱۰۲۹.
- محمدصالحی، پ.، رائینی، م.، شکوهی، ع. ر. و ضیاءتبار احمدی، م. خ. ۱۳۸۵. تدوین مدل ریاضی هیدرولیکی-هیدرولوژیکی مبتنی بر برای شبیه‌سازی فرآیند بارش-رواناب در حوزه آبریز امامه. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز، دانشکده مهندسی علوم آب. ۱۲ تا ۱۴ اردیبهشت ۱۳۸۵، اهواز.
- منهاج، م. ب. ۱۳۸۱. مبانی شبکه‌های عصبی (هوش محاسباتی). جلد اول. مرکز نشر دانشگاه صنعتی امیر کبیر. ۷۱۵ ص.

- ۱۰- میرزاخان، ح. ۱۳۸۰. مقایسه مدل شبیه سازی بارش- رواناب به روش شیب- سطح با مدل HEC-HMS در حوزه آبخیز جاغرق خراسان. پایان نامه کارشناسی ارشد. دانشگاه علوم کشاورزی و منابع طبیعی گرگان. ۱۱۷ ص.
- 11- Anctil, F., C.H. Perrin and V. Andreassian. 2003. Impact of the length of observed records on the performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models. *Environmental Modeling & Software*, 19: 357-368.
- 12- ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application. *Journal of Hydrologic Engineering*, 5: 124-137.
- 13- Braddock, R.D., M.L. Kremmer and L. Sanzogni. 1998. Feedforward artificial neural network model for forecasting rainfall-runoff. *Environmental Sciences*, 9: 419-432.
- 14- Dawson, C.W. and R. Wilby. 1998. An artificial neural network approach to rainfall-runoff modeling. *Hydrological Sciences Journal*, 43: 47-66.
- 15- Fausett, L. 1994. *Fundamental of neural networks: Architectures, algorithms and applications*. Englewood Cliffs, New Jersey, Prentice-Hall, Inc.
- 16- Lallahem, S. and J. Mania. 2002. A Non-linear rainfall-runoff model using neural network technique. *Mathematical and Computer Modeling*, 37: 1047-1061.
- 17- Minns, A.W. and M.J. Hall. 1996. Artificial neural network as rainfall-runoff models. *Hydrological Sciences Journal*, 41: 399-417.
- 18- Rajurkar, M.P., U.C. Kothiyari and U.C. Chube. 2004. Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, 285: 96-113.
- 19- Salehi, F., R. Lacroix and K.M. Wade. 1998. Effects of learning parameters and data presentation on the performance of back propagation networks. *Transactions of the ASCE.*, 41: 253-259.
- 20- SAS Institute Inc. SAS procedure guide, version 6.12. Cary, NC: SAS Institute Inc, 1994.
- 21- Tokar, A.S. and M. Markus. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrology Engineering*, 45: 156-161.
- 22- U.S. Army Corps of Engineers. 2001. Hydrologic Engineering Center. Hydrologic Modeling System (HEC-HMS): User's Manual, 178 pp.

Archive SID

Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed

A.R.Jahangeer – M.Raeini – Sarjaz* – M.Z.Ahmadi¹

Abstract

Flood is one of the destructive natural phenomena and being able to forecast it is of great importance. Simulation of rainfall-runoff and flood is difficult due to influence of several factors. So far, different methods have been suggested for their analysis. The aim of this study was to compare the efficiency of artificial neural networks (ANNs) in simulating rainfall-runoff process with HEC-HMS model. For this purpose, the Kardeh watershed which is located in northeast part of Great Khorasan province was chosen and based on several precipitation hyetographs and their runoff hydrographs (total of 450 data from 30 selected phenomena) the study was performed. Back-Propagation (BP) algorithm ANN was learnt to the data using sigmoid activation function. The criterion for selecting the network parameters in learning stage was producing the least RMSE in ANN outputs. Based on the SCS method and curve number (CN) the HMS model was performed. To evaluate the ANN performance, the simulated and observed data of total discharge and volume of runoff, peak discharges and peak times were compared. The results showed that based on Delta learning rule the multi layers Perceptron (MLP) network with 29 neurons, simulated the rainfall-runoff process with a high accuracy only in the middle (hidden) layer. The correlation coefficients of the total discharge and volume of runoff were found to be highly significant ($r=0.98$ and 0.99 , respectively). The ANN model could significantly simulate the peak discharge and peak time values ($r=0.98$ and 0.83 , respectively). By analyzing the HMS model performance, the correlation coefficients of the observed and simulated discharges and volumes of runoff were found to be 0.82 and 0.98 , respectively. Also, the correlation coefficients of simulated peak discharges and peak times with this model were 0.97 and 0.70 , respectively. By performing the T-test analysis at 99% confidence level no significant differences between observed and predicted data was observed. It can be concluded that although no significant differences was found between the two methods, however, the results of evaluated parameters showed that ANN predictions were more precise in comparison with those of HMS model.

Key words: Simulation, hydrologic model, Rainfall-runoff, artificial neural network, HEC-HMS model, Kardeh watershed.

* - Corresponding author Email: m.raeini@umz.ac.ir

¹ - Faculty of Agricultural Engineering, Agriculture Natural Resource Sciences Complex of sari, University of Mazandaran