

ارزیابی و مقایسه روش شبکه عصبی مصنوعی و نرم افزار HEC-HMS در شبیه‌سازی آبنمود بارش - رواناب در حوضه آبخیز معرف کسلیان

فرشید صف شکن^{۱*}، نادر پیرمادیان^۲، رضا افشین شریفان^۳
تاریخ دریافت: ۹۴/۲/۸ تاریخ پذیرش: ۹۶/۳/۲۸

چکیده

فرایند بارش - رواناب یک پدیده‌ی کاملاً پیچیده و غیرخطی در آبشناسی و منابع آب می‌باشد. در سالهای اخیر، شبکه‌های عصبی مصنوعی کاربرد گسترده‌ای را در شبیه‌سازی روابط غیرخطی و پیچیده مانند رابطه‌ی بارش - رواناب پیدا کرده است. در این تحقیق، به منظور شبیه‌سازی آبنمود بارش - رواناب در حوضه‌ی آبخیز معرف کسلیان از روش شبکه‌ی عصبی مصنوعی (با ساختار ۷-۱۰-۹) و نرم‌افزار HEC-HMS استفاده گردید. به منظور آموزش بهتر نرم افزار شبکه‌ی عصبی مصنوعی داده‌های بارندگی بر اساس الگوی زمانی، مطابق با توزیع بارندگی هاف، به چهار گروه تقسیم شدند. به‌طور کلی نتایج این تحقیق نشان دادند که محدوده‌ی قدرمطلق درصد خطای نسبی فراسنج‌های Q_P ، T_P ، T_b ، W_{Δ} ، $W_{V\Delta}$ ، T_{Δ} و $T_{V\Delta}$ شبیه‌سازی شده به وسیله‌ی شبکه عصبی به ترتیب ۵۱/۹۷-۰/۰۲، ۴۱/۲۳-۰/۵۵، ۵۴/۰۷-۰/۲۶، ۲۰۲/۶۲-۰/۲۳، ۶۹/۸۸-۰/۵۲، ۸۲/۰۷-۲/۲۱ و ۵۷/۷۶-۲/۴۲ می‌باشند، در حالی که با شبیه‌سازی به وسیله‌ی نرم‌افزار HEC-HMS این حدود به ترتیب ۷۵۶/۵۳-۰/۵۸، ۲۵۰-۰، ۱۴۱/۱۸-۰، ۵۷۵-۲/۸۴، ۱۶۷/۸۶-۰/۹۳، ۳۵۰-۳/۳۳ و ۲۶۶/۶۷-۲ محاسبه شده‌اند. با توجه به درصد خطای نسبی مربوط به فراسنج‌های خروجی هر واقعه می‌توان نتیجه گرفت که شبکه‌ی عصبی در اکثر موارد تمامی فراسنج‌ها و شکل کلی آبنمود را به‌خوبی و با خطای ناچیزی نسبت به نرم افزار HEC-HMS شبیه‌سازی نموده است، البته در بعضی موارد، نرم افزار HEC-HMS توانسته است که شبیه‌سازی بده اوج آبنمود، زمان پایه و شکل کلی آن را به خوبی، یا به ندرت دقیقتر از شبکه‌ی عصبی انجام دهد.

واژه های کلیدی: آبنمود بارش - رواناب، شبکه‌ی عصبی مصنوعی، مدل HEC-HMS.

^۱ دانشگاه آزاد اسلامی، واحد داریون، باشگاه پژوهشگران جوان و نخبگان، داریون، ایران.

نویسنده مسئول: ۰۹۱۷۸۱۶۱۷۵۰-۰۷۱-۳۷۳۱۰۴۴۹ Email: safshekan.2020@yahoo.com

^۲ استادیار گروه مهندسی آب، دانشکده کشاورزی دانشگاه گیلان، رشت.

^۳ استادیار دانشگاه آزاد اسلامی، واحد شیراز، گروه مهندسی منابع آب، شیراز، ایران.

۱- مقدمه

پیش‌بینی رواناب یک موضوع تحقیقی فعال و اجتناب‌ناپذیر در زمینه آشناسی^۴ آبهای سطحی بوده، و همچنان به خاطر عدم قطعیت‌های موجود در فراسنج‌های^۵ هواشناسی و آشناسی مسئله‌ای پابرجاست (هارون و همکاران، ۲۰۰۲). علاوه بر این، برنامه‌ریزی برای بهره‌برداری از منابع آبهای سطحی و زیرزمینی، ساماندهی رودخانه و هشدار سیل نیاز به برآورد آبدی رودخانه و رواناب حوضه‌ی آبخیز دارد (جهانگیر و همکاران، ۱۳۸۴). چون در فرایند بارش- رواناب یک ارتباط غیرخطی بین فراسنج‌های مجهول (رواناب) و معلوم (بارش) وجود دارد و تعیین عوامل موثر بر این فرایند با عدم قطعیت همراه است، از طرفی، درک صحیحی از فرایندهای آشناسی درونی موجود نمی‌باشند همواره باعث ایجاد خطا در پیش‌بینی‌ها خواهد شد و شبیه‌سازی آن با شبیه‌های^۶ مرسوم مشکل و حتی در بعضی موارد غیر ممکن می‌باشد. چندین روش از روابط تجربی یا آماری گرفته تا ریاضی گسسته شده^۷، برای پیش‌بینی رواناب توسعه یافته‌اند. شبیه‌سازهای ریاضی، بر اساس بررسی فرایندهای فیزیکی به دو گروه یعنی شبیه‌های مفهومی و جعبه‌سیاه تقسیم می‌گردند (سیمونویچ و احمد، ۲۰۰۵). شبیه‌های مفهومی براساس خصوصیات فراسنج‌ها و متغیرهای شبیه می‌توانند خود به یعنی توزیعی مانند MIKE SHE و SWMM و یکپارچه مانند HEC-1، و نسخه‌ی پیشرفته آن به نام HEC-HMS تقسیم گردند، که در درجه‌ی اول بهترین انتخاب جهت توصیف فرایند بارش- رواناب در حوضه‌های آبخیز می‌باشند، اما به خاطر نیاز فراوان این شبیه‌ها به داده‌های هواشناسی، آشناسی و هندسی حوضه و اطلاعات جزئی از سامانه تحت بررسی و همچنین زمان بسیار زیاد جهت واسنجی آنها به ویژه در حالت توزیعی، کاربرد عملی این مدلها محدود شده است (سیمونویچ و احمد، ۲۰۰۵).

طی دهه‌های اخیر، یکی از روشهای هوش محاسباتی (CI)^۸ موسوم به روش شبکه‌ی عصبی مصنوعی (ANN)^۹ کاربرد گسترده‌ای را در تحقیقات مختلف آشناسی، از جمله شبیه‌سازی فرایند بارش-

رواناب، یا پدیده‌هایی که الگوریتم مشخصی برای آنها وجود ندارد، و یا با روشهای معمول دارای راه حل طولانی و زمانبر می‌باشند، پیدا کرده است. شبکه‌های عصبی مصنوعی از جمله شبیه‌های جعبه سیاه و سامانه‌های پویایی هوشمند مدل آزاد^{۱۰} می‌باشند که مبتنی بر داده‌های تجربی بوده و با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. شبکه‌های عصبی مصنوعی می‌توانند به سهولت غیرخطی بودن فرایندهای تحت بررسی را بدون حل معادلات دیفرانسیل جزئی شبیه‌سازی نمایند. علاوه بر این، چند منظوره بودن کاربرد شبکه‌های عصبی به آنها اجازه می‌دهد که برای دامنه وسیعی از مسائل آشناسی و در رشته‌های مختلف علمی به کار برده شوند (پن و وانگ، ۲۰۰۵).

در تحقیقی سهیل و همکاران (۲۰۰۸) برای تحلیل رواناب در حوضه‌ی آبخیز تونو در ژاپن از شبکه‌ی عصبی مصنوعی و شبیه‌های خودهمبسته استفاده کردند نتایج آنها نشان داد که شبکه‌ی عصبی نسبت به شبیه‌های خودهمبسته پیش‌بینی رواناب را با دقت خوبی انجام داده بود. همچنین در گزارشی روش‌های^{۱۱} SFM (شبیه تابع ذخیره‌ای) و شبکه‌های عصبی پرسپترون چند لایه^{۱۲} (MLP) برای پیش‌بینی سیلاب در حوضه‌ی آبخیز مایوچوم در کره مقایسه شدند، در این تحقیق نتیجه گرفته شد که شبکه‌ی عصبی نسبت به شبیه SFM پیش‌بینی دقیقی را حاصل کرد، به طوری که خطای نسبی در بده اوج با کاربرد شبکه عصبی و شبیه SFM به ترتیب برابر با ۰/۶۱ و ۱/۹۶ درصد بدست آمد (کیم و همکاران، ۲۰۰۰).

در گزارشی شبیه‌سازی بارش- رواناب حوضه‌ی نیل با کمک شبکه‌ی عصبی و شبیه توزیعی MFS انجام شد. نتایج نشان دادند که شبیه‌سازی بارش- رواناب توسط شبکه‌ی عصبی دقیق‌تر می‌باشد، به طوری که ضریب همبستگی برای شبکه‌ی عصبی و شبیه توزیعی به ترتیب برابر با ۰/۹۹ و ۰/۹۷ حاصل گردید (آنتار و همکاران، ۲۰۰۶).

هارون و همکاران (۲۰۰۲)، در تحقیقی جهت شبیه‌سازی بارش- رواناب در مقیاس روزانه در حوضه‌ی آبخیز

⁸ Artificial Neural Network (ANN)

⁹ Free Models

¹¹ Storage Function Models

¹² Multi Layer Perceptron (MLP)

⁴ Hydrology

⁵ Parameters

⁶ Models

⁷ Discrete Mathematic Models

⁷ Computational Intelligence (CI)

دقیق‌تری را نسبت به منحنی بده-خط‌کش ارائه کرده بود. به طوری که فراسنج‌های آماری جذر متوسط مربع خطا و ضریب همبستگی به ترتیب برابر با ۰/۰۶۷۸ و ۰/۹۹۹۸ و برای روش شبکه‌ی عصبی پرسپترون چند لایه و ۰/۶۹۳۷ و ۰/۹۸۱۷ برای منحنی بده-خط‌کش نظیر آن حاصل گردید.

جهانگیر و همکاران (۱۳۸۴)، با استفاده از شبکه‌ی عصبی پرسپترون چند لایه و قانون آموزش دلتا، شبیه-سازی فرایند بارش- رواناب را در حوضه‌ی آبریز معرف کرده در شمال شرقی خراسان انجام دادند. بر اساس سعی و خطا شبکه با تعداد ۲۹ نرون در لایه‌ی مخفی بهترین عملکرد را دارا بود، به گونه‌ای که ضریب همبستگی کلی برای داده‌های بده و حجم رواناب واقعی و شبیه‌سازی شده ۰/۹۶۹ و ضریب همبستگی مقدار و زمان وقوع بده‌های اوج به ترتیب ۰/۹۸۷۲ و ۰/۹۰۵۲ حاصل گردید.

تیفور و مورامارکو (۲۰۰۷) پیش‌بینی آبنمود سیلاب حوضه رودخانه تیبر^{۱۵} در ایتالیا را با یک شبکه عصبی مصنوعی سه لایه‌ی پیشخور و الگوریتم پس‌انتشار و تابع تبدیل سیگموئید انجام دادند. نتایج نشان دادند که برای گام‌های زمانی ۴ و ۸ ساعت پیش‌بینی سیلاب به وسیله‌ی روش شبکه عصبی به ویژه گام زمانی ۴ ساعته نسبت به روش ماسکینگام از دقت و خطای بالاتری برخوردار بود.

هدف اصلی این تحقیق شبیه‌سازی آبنمود بارش- رواناب با استفاده از روش شبکه‌ی عصبی مصنوعی و نرم افزار HEC-HMS در حوضه‌ی آبخیز معرف کسلیان و در نتیجه مقایسه و سنجش توانایی شبکه عصبی نسبت به نرم افزار HEC-HMS می‌باشد.

۲- مواد و روش‌ها

۲-۱- منطقه‌ی مورد مطالعه

منطقه‌ی مورد نظر جهت مطالعه در این تحقیق حوضه‌ی آبخیز معرف کسلیان واقع در استان مازندران بود. این حوضه در محدوده عرض جغرافیایی "۳۰، ۵۸، ۳۵° و "۷، ۳۶، شمالی و طول جغرافیایی "۳۰، ۱۰، ۵۳° و "۱۸، ۵۳، شرقی واقع شده است. رود کسلیان یکی از شاخه‌های رود تالار است که در دامنه‌ی شمالی سلسله جبال البرز در جهت جنوب به شمال قرار دارد. مساحت حوضه ۶۷/۵

سانگایی لویی در مالزی از دو نوع شبکه‌ی عصبی یعنی پرسپترون چند لایه و شبکه‌ی عصبی تابع پایه شعاعی استفاده کردند. ورودی‌ها شامل بارندگی روز جاری و روزهای قبل از آن، و خروجی فقط رواناب روز جاری می‌باشد. در این تحقیق نتایج حاصل از شبکه‌های عصبی فوق با نرم افزار HEC-HMS و روش رگرسیون چند متغیره مقایسه شد که مشخص شد شبکه‌ی عصبی تابع پایه شعاعی بهینه‌ترین روش نسبت به سایر شبیه‌ها می‌باشد که معیارهای ارزیابی از قبیل ضریب همبستگی و متوسط مربع خطاها به ترتیب برابر با ۰/۹۳۶ و ۰/۹۲۷ مترمکعب بر ثانیه برای مرحله آموزش، و ۰/۸۱۱ و ۱/۲۶ برای مرحله آزمایش نرم افزار بهینه حاصل شد. در پژوهشی به وسیله‌ی لورایی و سچی (۱۹۹۵) شبیه‌سازی فرایند بارش- رواناب در حوضه‌ی آبخیز آراکسیسی در ساردینیا با استفاده از شبکه‌ی عصبی پرسپترون چند لایه (MLP) و به کارگیری اطلاعات بارندگی متوسط و درجه حرارت انجام شد، و نتایج رضایت بخشی حاصل گردید.

فیرات و گانگور (۲۰۰۷) تخمین جریان روزانه رود گریت مندیس^{۱۳} در غرب ترکیه را با استفاده از شبکه‌ی عصبی مصنوعی انجام دادند. در نهایت نتیجه گرفته شد که شبکه‌ی عصبی پرسپترون چند لایه با تعداد دو ورودی (بده تا دو روز قبل)، و شبکه‌ی عصبی تابع شعاعی با تعداد ۳ ورودی (بده تا ۳ روز قبل) بهترین عملکرد را دارا بودند. سیمونوویچ و احمد (۲۰۰۵) شبیه‌سازی آبنمود سالانه‌ی رود رد^{۱۴} در مانیتوبا را به کمک شبکه‌ی عصبی پرسپترون چند لایه با الگوریتم پس انتشار خطا انجام دادند. متوسط قدرمطلق خطا در تخمین بده اوج و زمان وقوع آن به ترتیب ۶ درصد و ۴ روز حاصل شد، در حالی که همبستگی بین مقادیر مشاهداتی و شبیه‌سازی شده دبی اوج و زمان وقوع آن به ترتیب برابر با ۰/۹۹ و ۰/۸۸ حاصل گردید.

پیش‌بینی جریان در آبراهه ای در هاوایی با استفاده از شبکه‌های عصبی پرسپترون چند لایه و شبکه عصبی تابع پایه شعاعی به وسیله‌ی شو و ری (۲۰۰۶) انجام شد. نتایج حاصل از شبیه‌سازی شبکه‌ی عصبی با نتایج به دست آمده از منحنی بده- خط‌کش مقایسه شد. نتایج نشان دادند که شبکه‌ی عصبی پرسپترون چند لایه جواپهای

¹⁴ Tiber


¹² Great Mendees

¹³ Red

۲-۳- جمع‌آوری آمار و آماده‌سازی اطلاعات مورد نیاز

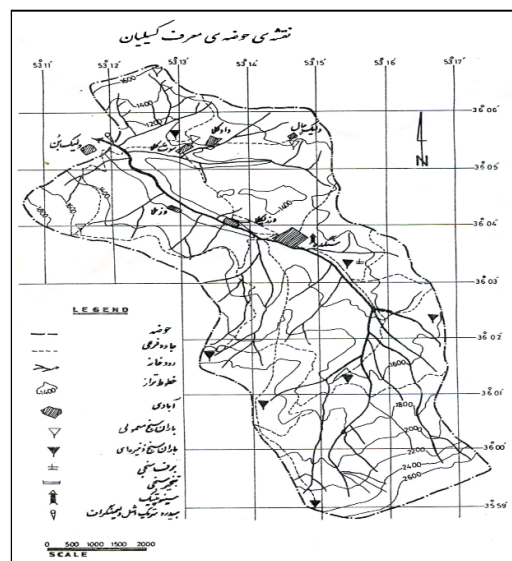
اطلاعات مورد نیاز در این تحقیق شامل نمودار هم باران بارندگی‌های ثبت شده در ایستگاه بارانسنجی سنگده (در مرکز ثقل حوضه)، بارندگی‌های روزانه در ایستگاه مذکور و آبنمود سیلاب‌های متناظر ثبت شده در ایستگاه آب‌سنجی ولیک‌بن (در خروجی حوضه) بود. اطلاعات فوق برای ۱۳۱ واقعه که در این تحقیق قابل استفاده بودند جمع‌آوری گردیدند. از آنجا که وقایع بارندگی مورد استفاده در این تحقیق دارای شدت، توزیع و تداوم‌های متفاوتی بودند، به کارگیری این اطلاعات بدون متمایز ساختن آنها از نظر خصوصیات مذکور فرایند شبیه‌سازی را تحت تاثیر قرار داده و موجب ناپایداری، واگرایی و نداشتن یک شبیه‌ساز معتبر می‌گردید. برای جلوگیری از این امر می‌بایست اطلاعات موجود را به نحوی که سبب همگنی آنها گردد تفکیک کرد. در این تحقیق، ابتدا از روی نمودارهای هم-باران موجود منحنی تجمعی بارش ترسیم و توزیع زمانی بارندگی به صورت بی بعد استخراج گردید. سپس بر اساس الگوی توزیع زمانی بارندگی هاف، وقایع موجود با این اصل که بیشترین درصد بارش در کدام چارک زمانی از کل تداوم بارش نزول کرده است، در چهار گروه تقسیم‌بندی گردیدند. به این ترتیب وقایع موجود از نظر الگوی زمانی توزیع بارش همگن گردیدند. تعداد وقایع برای گروه‌های اول تا چهارم به ترتیب برابر با ۴۲، ۲۵، ۳۲ و ۳۲ بود. پس از جداسازی جریان پایه، اطلاعات ورودی در قالب چهار گروه مذکور دسته‌بندی گردید و برای استفاده در روش شبکه عصبی آماده شد.

۲-۴- روش شبکه عصبی مصنوعی



شکل ۲- نمای کلی یک شبکه‌ی عصبی مصنوعی سه لایه.


کیلومتر مربع و بین ارتفاعات ۱۱۰۰ و ۲۷۰۰ متری از سطح دریا قرار گرفته است. زمان تمرکز حوضه (با استفاده از روش کیریچ) ۳/۵ ساعت، محیط حوضه ۴۳ کیلومتر و طول بزرگترین آبراهه‌ی رود ۱۵/۲ کیلومتر می‌باشد. شکل (۱) نقشه‌ی تراز حوضه را نشان می‌دهد. ایستگاه هواشناسی سنگده در ارتفاع ۱۳۵۰ متری از سطح دریا واقع شده است. در نزدیکی دهکده ولیک‌بن در خروجی حوضه ایستگاه آب‌سنجی ولیک‌بن قرار دارد. در این تحقیق از اطلاعات ایستگاه‌های هواشناسی سنگده (در مرکز ثقل حوضه) و آب‌سنجی ولیک‌بن (در خروجی حوضه) استفاده شد (تماپ).



شکل ۱- نقشه‌ی حوضه‌ی آبخیز معرف کسلیان (۲).

۲-۲- مروری بر الگوی توزیع بارندگی هاف

هاف (۱۹۶۷)، ۱۱ سال بارندگی حوضه‌ای به مساحت ۴۰۰ مایل مربع، متشکل از ۴۹ باران‌سنج را مورد تحلیل قرار داد. او توزیع بارش را نسبت به اینکه حداکثر مقدار بارش در چارک اول، دوم، سوم و یا چهارم از تداوم بارش اتفاق می‌افتد، به چهار دسته تقسیم کرد. نتایج به دست آمده نشان دادند که برای باران‌های کوتاه مدت، در بیشتر حالات قسمت اعظم بارش در ربع اول و یا دوم از زمان بارش اتفاق می‌افتد. هاف تعدادی منحنی توزیع زمانی بدون بعد را برای مقادیر مختلف سطوح احتمال، در چهار دسته ارائه داد که در این تحقیق، منحنی‌های مربوط به سطح احتمال ۵۰ درصد ملاک تقسیم‌بندی اطلاعات قرار گرفته‌اند.



شکل ۳- طرح‌واره‌ی یک نرون مصنوعی و چگونگی

دریافت علامت ورودی و تولید علامت خروجی .

می‌باشد که برای آموزش این شبکه از الگوریتم پس انتشار خطا، که یک روش یادگیری نظارت شده است استفاده می‌شود (هارون و همکاران، ۲۰۰۲). منظور از آموزش یک شبکه‌ی عصبی، تنظیم فرانسج‌های شبکه (وزن‌ها و اریبی‌ها) با ارائه الگوهای آموزشی است به طوری- که با ارائه مجدد همان الگوها خطای حاصل بین خروجی واقعی و خروجی شبکه حداقل گردد. به طور کلی، در شبکه‌ی پرسپترون چند لایه عموماً دو نوع علامت، یعنی علائمی که در مسیر رفت (از لایه‌ی ورودی به طرف لایه‌ی خروجی) و دیگری علائمی که در مسیر برگشت (از لایه‌ی خروجی به طرف لایه‌ی ورودی) حرکت می‌کنند استفاده می‌شود، که به ترتیب به نام علامت تابعی و خطا^{۱۸} معروفند. تنظیم فرانسج‌ها در شبکه‌ی پرسپترون چند لایه توسط علامت خطا و علامت ورودی صورت می‌گیرد. تعیین تعداد لایه‌ها و نرون‌های موجود در آنها از مهمترین مسائل در شبیه‌سازی با شبکه عصبی مصنوعی است (منه‌اج، ۱۳۸۶). توکار و مارکوس (۲۰۰۰) و توکار و جانسون (۱۹۹۹) رایج‌ترین توابع تحریک استفاده شده در شبکه‌های انتشار برگشتی را توابع تحریک سیگموئید و تانژانت هذلولی شکل ذکر کرده‌اند. از طرفی، توابع تحریک موجود در نرم افزار Qnet2000 جهت به کارگیری در لایه‌های پنهان و خروجی توابع تحریک سیگموئید، تانژانت هذلولی شکل، سکانت هیپربولیک و گائوسین می‌باشند. در این تحقیق، با سعی و خطا، شبکه‌ی پرسپترون سه لایه با یک لایه‌ی پنهان (جهت تسریع در فرایند آموزشی و کمینه کردن تعداد فرانسج‌ها) به عنوان ساختار بهینه برگزیده شد که تعداد نرون‌ها در لایه‌ی مخفی مطابق با پیشنهاد جی و همکاران (۲۰۰۵)، و به منظور صرف زمان کمتر جهت سعی و خطا در این مورد به صورت دو- سوم جمع تعداد نرون‌ها در لایه‌های ورودی و خروجی در نظر گرفته شد. علاوه بر

هر شبکه‌ی عصبی مصنوعی به طور کلی از سه لایه تشکیل شده است (شکل ۲). لایه‌ی ورودی که نقش معرفی فرانسج‌های ورودی را به شبکه بر عهده دارد، لایه‌ی خروجی محل استقرار فرانسج‌های خروجی شبکه و لایه‌ی پنهان (لایه‌های مابین لایه ورودی و خروجی) که در واقع نقش پردازشگری اطلاعات را بر عهده دارند (جین و شبکه همکاران، ۱۹۹۶). یک شبکه‌ی عصبی مصنوعی علائم^{۱۶} را از واحدهای ورودی دریافت کرده و این علائم در طول انتشار یافته و در نهایت به سوی نرون خروجی حرکت می‌نمایند.

فرانسج‌های کنترلی اصلی روشهای شبکه عصبی مصنوعی مقاومت‌های اتصالی^{۱۷} بین نرون‌ها می‌باشند که به عنوان وزن‌ها و اریبی‌ها نامیده می‌شوند. هر نرون مطابق شکل (۳) خروجی‌های وزن دار شده $(w_{j,i} x_i)$ نرون‌های لایه قبلی را دریافت و مجموع آنها، ورودی خالص به نرون زام (net_j) را مطابق رابطه زیر تولید می‌کند (منه‌اج، ۱۳۸۶).

$$net_j = \sum w_{j,i} x_i + b_j \quad (1)$$

که در رابطه‌ی فوق: net_j سطح تحریک سلول عصبی زام یا ورودی خالص به نرون زام، $w_{j,i}$ وزن اتصالی بین گره‌های i و j ، x_i ورودی به گره i و b_j اریبی گره زام می‌باشد.

نرون‌ها برای محاسبه‌ی خروجی خود (y_j)، ورودی خالص دریافتی را از یک تابع فعال‌سازی (تحریک) عبور می‌دهند. توابع تحریک دارای انواع مختلفی نظیر سیگموئیدی، تانژانت هذلولی شکل، خطی و گائوسین می‌باشند. مرسوم‌ترین توابع در این زمینه، تابع سیگموئیدی است که به صورت زیر می‌باشد (جی و همکاران، ۲۰۰۵).

$$y_j = f(net_j) = \frac{1}{1 + \exp(-net_j)} \quad (2)$$

لایه‌های مختلف در

شبکه‌ی عصبی و همچنین نرون‌های موجود در لایه‌ها می‌توانند دارای توابع تحریک متفاوت یا یکسانی باشند. شبکه‌های عصبی از نظر ساختار و ارتباطات بین نرون‌ها به گروه‌های مختلفی تقسیم می‌شوند. شبکه‌ی پرسپترون چند لایه رایج‌ترین روش شبکه‌ی عصبی استفاده شده در مسائل فنی- مهندسی

¹⁸error and functional signals

¹⁶signals

¹⁷connection resistances

سامانه‌های زهکشی، شبیه‌سازی فرایند بارش- رواناب، روندیابی جریان، کمی‌کردن اثر تغییر کاربری اراضی در مورد سیلاب و غیره استفاده می‌شود (سینگ و ولحیسر، ۲۰۰۲). علاوه بر این نرم افزار HEC-HMS یک شبیه‌سازی یکپارچه می‌باشد که ورودی نرم افزار بارندگی و توزیع آن، فراسنج‌های نفوذ، گیتاشناسی حوضه، شماره‌ی منحنی، زمان تمرکز، درصد سطح نفوذناپذیر حوضه و... و خروجی نرم افزار، آبنمود رواناب می‌باشند. در این تحقیق، بارندگی به شکل نمودار هم‌باران به عنوان ورودی و آبنمود متناظر با این نمودار هم‌باران به عنوان خروجی برای نرم‌افزار در نظر گرفته شدند. در مدل HEC-HMS برای شبیه‌سازی بارش- رواناب بایستی فرایندهای تلفات، رواناب مستقیم و ... جداگانه شبیه‌سازی شوند که برای هر کدام از این فرایندها روشهای مختلفی در این نرم‌افزار وجود دارد. در این پژوهش روشهای شماره‌ی منحنی SCS و آبنمود واحد SCS به خاطر جهانی و معتبر بودن آنها به ترتیب برای محاسبه تلفات و تبدیل بارش به رواناب برگزیده شد که از روش جستجوی شیب تک متغیره جهت بهینه‌سازی ضرایب واسنجی استفاده گردید. برای محاسبه‌ی تلفات و شبیه‌سازی بارش- رواناب با استفاده از روش‌های شماره‌ی منحنی و روش آبنمود واحد SCS به ترتیب از روابط (۳) تا (۶) استفاده شده است. لازم به ذکر است که چون بده پایه را از آبنمودهای موجود حذف کرده‌ایم نیاز به محاسبه-ی بده پایه نمی‌باشد.

روش شماره‌ی منحنی سازمان حفاظت خاک آمریکا، مقدار رواناب (R) را به صورت تابعی از بارش جمعی، پوشش خاک، کاربری اراضی و رطوبت پیشین به صورت معادله‌ی زیر برآورد می‌کند:

$$R = \frac{(P-0.2*S)^2}{P+0.8S} \quad (3)$$

در رابطه‌ی فوق R : ارتفاع رواناب جمعی در زمان t ، P : عمق بارندگی جمعی و S : حداکثر نگهداشت سطحی می‌باشد.

مقدار کل رواناب برای هر گام زمانی به صورت اختلاف بین بارندگی اضافی در انتها و شروع آن گام تعریف می‌شود. حداکثر نگهداشت حوضه (S) و خصوصیات حوضه آبخیز با استفاده از یک فراسنج میانی موسوم به شماره‌ی منحنی (CN) به صورت زیر با هم ارتباط دارند:

این، امکان به کارگیری توابع تحریک مختلف در محاسبات مربوطه، آموزش سریع و کمینه بودن فراسنج‌های آن نسبت به سایر روشهای شبکه‌ی عصبی، کاربرد وفور این روش شبکه عصبی در علوم مهندسی، و از طرفی محدود بودن نرم افزار Qnet2000 در دارا بودن صرفاً این روش را می‌توان از دلایل انتخاب شبکه‌ی پرسپترون دانست.

۲-۴-۱- انتخاب ورودی‌های روش شبکه عصبی

همان‌طور که ذکر شد، تقسیم‌بندی اطلاعات در این پژوهش جهت ایجاد همگنی در اطلاعات و ارائه‌ی روشی با اعتبار و دقت بالاتر انجام گردید. فراسنج‌های ورودی برای روش شبکه عصبی شامل درصد از کل بارش در چارک‌های زمانی اول تا چهارم، بده پایه در شروع بارش و قبل از شروع سیلاب (استخراج شده از آبنمود سیلاب)، مقدار کل بارش، مقدار بارش تا وقوع زمان تمرکز حوضه، تداوم بارش و شاخص بارش پیشین بود. شاخص بارش پیشین در این تحقیق با سعی و خطا بر اساس بارندگی ۱۵ روز قبل در نظر گرفته شد که بیشترین تاثیر را نسبت به سایر مقیاس-ها داشت. از طرف دیگر، جهت شبیه‌سازی آبنمود بارش- رواناب، آبنمودهای سیلاب بایستی به نحوی به عنوان جواب‌های مطلوب به شبکه‌ی عصبی معرفی شوند. در اینجا فراسنج‌هایی از آبنمود سیلاب شامل بده اوج سیلاب (Q_p)، زمان رسیدن به بده اوج (t_p)، زمان پایه آبنمود (T_b)، عرض‌های آبنمود در ۵۰ و ۷۵ درصد بده اوج (W_{50}, W_{75}) و زمان رسیدن به بده‌های ۵۰ و ۷۵ درصد بده اوج (t_{50}, t_{75}) به عنوان فراسنج‌های خروجی شبکه‌ی عصبی (سینگ و ولحیسر، ۲۰۰۲) در نظر گرفته شدند. این فراسنج‌ها شکل کلی آبنمود را ارائه می‌دهند. لازم به ذکر است که جهت تسریع در همگرایی و بهبود شبکه‌ی عصبی بهنجارسازی^{۱۹} اطلاعات به وسیله‌ی نرم‌افزار به طور خودکار انجام گردیده که اطلاعات ورودی و خروجی را بین ۰/۱۵-۰/۸۵ محدود می‌نماید.

۲-۵- نرم‌افزار HEC-HMS

در این مطالعه، جهت مقایسه‌ی نتایج حاصل از شبکه‌ی عصبی مصنوعی در شبیه‌سازی بارش- رواناب از شبیه‌سازی آبی HEC-HMS استفاده شده است. این نرم افزار یک شبیه مفهومی یکپارچه می‌باشد که برای طراحی

حوضه موجود نمی‌باشند؛ بنابراین، لازم به واسنجی این ضرایب از قبیل تلفات اولیه، شماره‌ی منحنی، درصد نفوذناپذیری و زمان تاخیر می‌باشد. برای واسنجی این ضرایب، وقایع مشابه با واقعه‌ی مورد آزمون (مشابه از نظر مقدار، تداوم بارندگی و آبمدهای ایجاد شده) از مجموعه-ی اطلاعات آموزش هر گروه انتخاب، و برای تک‌تک آنها واسنجی ضرایب صورت گرفت. سپس با کاربرد ضرایب واسنجی مربوط به تک‌تک وقایع مشابه و همچنین ضرایب واسنجی میانگین‌گیری شده مربوط به وقایع مشابه، با هر کدام از وقایع مورد نظر جهت آزمون، شبیه‌سازی بارش-رواناب صورت گرفت. در نهایت، ضرایبی که منجر به شبیه‌سازی بهتری برای واقعه مورد آزمون گردیده است به عنوان ضرایب بهینه برگزیده شدند و آبمدهای شبیه‌سازی شده حاصل از این ضرایب مبنای مقایسه قرار گرفتند. لازم به ذکر است که درصد نفوذناپذیری حوضه با توجه به گزارشهای مربوطه بین ۰ تا ۲۵ درصد در سطح حوضه متغیر است، که در این تحقیق با سعی و خطا در مورد این ضریب، و در نظر گرفتن مقادیر مختلف برای وقایع مختلف نتیجه گرفته شد که انتخاب ۱۰ درصد برای تمامی وقایع به واسنجی بهتر و دقیق‌تری منجر می‌گردد. بدین خاطر ضریب مزبور برای تمام وقایع و گروه‌های مختلف اطلاعات برابر با مقدار ثابت ۱۰ درصد در نظر گرفته شد. برای واسنجی مدل از روش جستجوی شیب تک متغیره جهت بهینه‌سازی ضرایب واسنجی استفاده گردید.

۳- معیارهای ارزیابی و سنجش روشها

جهت ارزیابی و سنجش روش شبکه‌ی عصبی از معیارهای ضریب همبستگی، جذر میانگین مربعات خطا و خطای نسبی استفاده گردید. ضریب همبستگی برای سنجش میزان همبستگی و درجه نزدیکی دو متغیر به هم استفاده می‌شود که از رابطه‌ی زیر محاسبه می‌گردد:

$$R^2 = \frac{\sum (y_{obs} - \bar{y}_{obs}) \times (y_{model} - \bar{y}_{model})}{\sqrt{\sum_{i=1}^n (y_{obs} - \bar{y}_{obs})^2} \times \sqrt{\sum_{i=1}^n (y_{model} - \bar{y}_{model})^2}} \quad (7)$$

در رابطه‌ی فوق، y_{obs} و y_{model} : به ترتیب مقدار مشاهده‌ای و شبیه‌سازی شده با کاربرد روشها و n تعداد داده‌ها می‌باشد.

منظور از جذر میانگین مربعات خطا (RMSE)^{۲۰} در شبیه‌سازی، جذر میانگین مربع خطاهای ایجاد شده بین

$$S = \frac{1000}{CN} - 10 \quad (4)$$

در نرم‌افزار HEC-HMS چندین نوع روش تجربی مانند آب‌نمود واحد خصوصی، آب‌نمود واحد مصنوعی، آب‌نمود واحد اشنایدر، آب‌نمود واحد SCS، آب‌نمود واحد کلارک و آب‌نمود واحد مدکلارک وجود دارند.

در این مطالعه برای شبیه‌سازی بارش-رواناب با توجه به اطلاعات موجود امکان استفاده از روشهایی از قبیل کلارک، آب‌نمود واحد اشنایدر و آب‌نمود واحد SCS فراهم بود که با بررسی‌ها و تحلیل‌های اولیه‌ای که در شبیه‌سازی بارش-رواناب انجام گردید، نتیجه گرفته شد که استفاده از روش آب‌نمود واحد SCS نسبت به سایر روشها فرایند واسنجی را با دقت بهتری انجام می‌دهد. بدین ترتیب، در تحقیق حاضر این روش انتخاب گردید. از طرفی، این روش، یک روش جهانی، ساده و در مقایسه با سایر روشها نیاز به اطلاعات کمتری دارد.

روش آب‌نمود واحد SCS، یک آب‌نمود بدون بعد می‌باشد. این آب‌نمود بدون بعد، بده را به صورت نسبت بده اوج آب‌نمود برای هر زمان، به زمان رسیدن بده اوج بیان می‌کند. SCS رابطه‌ی بین بده اوج آب‌نمود و زمان رسیدن بده اوج را می‌توان به صورت زیر تعریف نمود:

$$Q_p = \frac{C.A}{T_p} \quad (5)$$

در رابطه‌ی فوق، A: مساحت حوضه آبخیز و C: ثابت تبدیل می‌باشند. بده اوج با تداوم بارش اضافی به صورت زیر در ارتباط می‌باشد:

$$T_p = \frac{\Delta t}{2} + t_{lag} \quad (6)$$

که در آن زمان تداوم بارش و t_{lag} زمان تاخیر حوضه است که به صورت اختلاف زمانی بین مرکز بارش اضافی و بده اوج آب‌نمود واحد تعریف می‌گردد. با مشخص بودن زمان تاخیر، HEC-HMS معادله‌ی (۶) را برای محاسبه زمان اوج آب‌نمود واحد، و معادله‌ی (۵) را برای محاسبه بده اوج آب‌نمود واحد حل می‌کند. با داشتن این دو مشخصه می‌توان با استفاده از آب‌نمود بدون بعد SCS، آب‌نمود رواناب را محاسبه کرد.

۲-۵-۱- واسنجی نرم‌افزار HEC-HMS

جهت شبیه‌سازی آب‌نمود رواناب برای وقایع انتخابی جهت آزمون در گروه‌های مختلف اطلاعات، چون ضرایب یا فراسنج‌های مربوط به روشهای انتخابی برای

¹⁹ Root Mean Square Error (RMSE)

افزار HEC-HMS می باشد. برای آموزش شبکه ی عصبی پرسپترون چند لایه از الگوریتم یادگیری پس انتشار خطا در نرم افزار Qnet2000 استفاده گردید. همچنین، در این پژوهش، روشهای شماره ی منحنی SCS و آبنمود واحد SCS در نرم افزار HEC-HMS، به خاطر جهانی و معتبر بودن آنها به ترتیب برای محاسبه ی تلفات و تبدیل بارش به رواناب برگزیده شدند که از روش جستجوی شیب تک متغیره جهت بهینه سازی ضرایب واسنجی استفاده گردید. جهت سهولت در آموزش روش شبکه ی عصبی، و همگنی در اطلاعات، دسته بندی وقایع بر اساس توزیع بارندگی مبتنی بر روش هاف انجام شده بر این اساس، چهار گروه اطلاعات که هر کدام معرف چارک های اول، دوم، سوم و چهارم هاف می باشند تفکیک گردیدند.

از وقایع موجود در هر گروه از اطلاعات حدود ۱۵ تا ۲۰ درصد جهت آزمایش، و مابقی حدود ۸۰ تا ۸۵ درصد جهت آموزش روش شبکه ی عصبی استفاده گردید (سیمونوویچ و احمد، ۲۰۰۵). شبیه سازی برای هر کدام از گروه ها جداگانه انجام گردید و از ترکیبات مختلف توابع تحریک در لایه های مخفی و خروجی استفاده شد. ترکیبات بهینه توابع تحریک در لایه های ورودی و خروجی برای گروه های مختلف اطلاعات به همراه شاخص های آماری ضریب همبستگی و RMSE در مراحل آموزش و آزمایش برای هر گروه در جدول (۱) ارائه شده است. ضریب همبستگی و RMSE در شبیه سازی تمامی آبنمودها در گروه های مختلف اطلاعات به ترتیب برابر با ۰/۹۱۰۷ و ۰/۸۸۲ در دسته ی اول، ۰/۹۴۰۹ و ۰/۸۱۸ در دسته ی دوم، ۰/۹۵۳۸ و ۰/۶۳ در دسته ی سوم و ۰/۹۹۰۹ و ۰/۶۷۸ در دسته ی چهارم از اطلاعات حاصل گردید.

جدول ۱- ترکیبات بهینه ی توابع تحریک در لایه های ورودی و خروجی برای گروه های مختلف اطلاعات به همراه شاخص های آماری ضریب همبستگی و RMSE در مراحل آموزش و آزمایش.

گروه	توابع محرک		معیارهای ارزیابی و انتخاب مدل	
	لایه ی پنهان	لایه ی خروجی	ضریب همبستگی	RMSE
اول	تانزانانت هذلولی شکل	سیگموئید	آموزش ۰/۹۶۳ آزمایش ۰/۹۱۲	آموزش ۰/۰۴۲ آزمایش ۰/۰۸۸
دوم	تانزانانت هذلولی شکل	سیگموئید	آموزش ۰/۹۹۴ آزمایش ۰/۹۴۱	آموزش ۰/۰۲۳ آزمایش ۰/۰۸۲
سوم	تانزانانت هذلولی شکل	سیگموئید	آموزش ۰/۹۸۲ آزمایش ۰/۹۵۴	آموزش ۰/۰۳۴ آزمایش ۰/۰۶۳
چهارم	تانزانانت هذلولی شکل	تانزانانت هذلولی شکل	آموزش ۰/۹۹۱ آزمایش ۰/۹۳۱	آموزش ۰/۰۲۵ آزمایش ۰/۰۶۸

خروجی های مشاهده ای و شبیه سازی شده به وسیله ی یک روش می باشد. مقدار این آماره اولاً" به تعداد داده های مورد نظر، و ثانیاً" به حدود نگاشت شده داده ها بستگی دارد. مقدار RMSE در حالت کلی از رابطه ی زیر به دست می آید:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{obs} - Y_{model})^2}{n}} \quad (۸)$$

در رابطه ی فوق Y_{obs} و Y_{model} : به ترتیب مقدار مشاهده ای و شبیه سازی شده با کاربرد روشها و n : تعداد داده ها می باشند.

جهت ارزیابی روش ها به کمک این آماره بایستی از مقدار آماره مزبور در هر دو مرحله واسنجی (آموزش) و آزمایش (آزمون) روش استفاده نمود و در مورد روش بهینه قضاوت کرد.

جهت مقایسه ی عملکرد شبکه ی عصبی مصنوعی با نرم افزار HEC-HMS نیز از شاخص درصد خطای نسبی به صورت زیر استفاده می شود:

$$RE = \frac{Y_{obs} - Y_{model}}{Y_{obs}} \times 100 \quad (۹)$$

در رابطه ی فوق، Y_{obs} و Y_{model} : به ترتیب مقدارهای مشاهده ای و شبیه سازی شده با کاربرد روشها و n : تعداد داده ها می باشد. در این تحقیق خطای نسبی مربوط به هر کدام از فراسنج های آبنمود برای وقایع مختلف محاسبه و مورد ارزیابی قرار می گیرد.

۱- بحث و نتایج

در این پژوهش تمرکز اصلی در مورد کاربرد شبکه ی عصبی MLP (رایجترین نوع شبکه عصبی) در شبیه سازی آبنمود بارش- رواناب و ارزیابی دقت آن در مقایسه با نرم

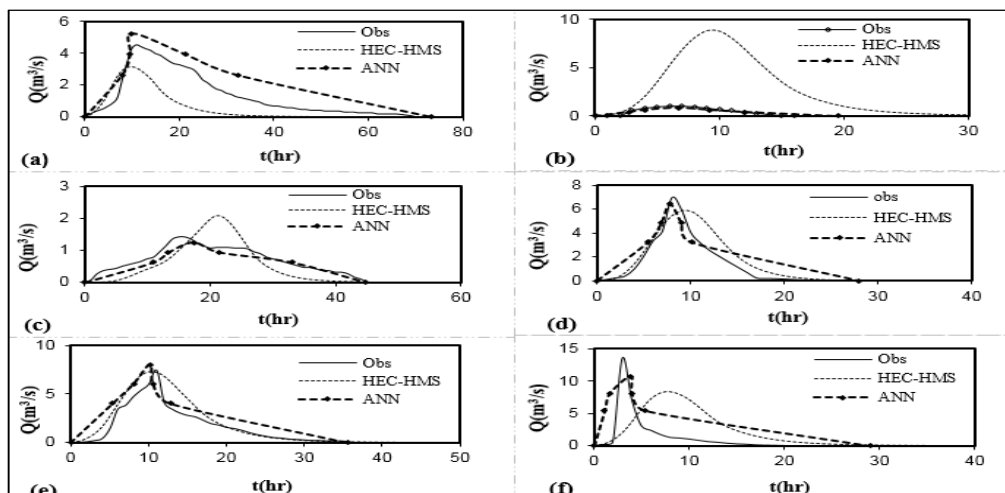
در پیش‌بینی فراسنج‌های آبنمود برای گروه‌های مختلف اطلاعات استفاده شد که در جداول (۲) تا (۵) گزارش شده‌اند.

برای گروه اول اطلاعات، با توجه به جدول (۲) و شکل (۴)، نتیجه گرفته می‌شود که برای مورد (a)، روش شبکه‌ی عصبی فراسنج‌های بده اوج، زمان پایه، زمان رسیدن به بده برابر با ۵۰ و ۷۵ درصد بده اوج را با خطای بسیار کمتری نسبت به نرم افزار HEC-HMS شبیه‌سازی کرده، در حالی

برای این گروه‌ها، عملیات شبیه‌سازی با کاربرد نرم-افزار HEC-HMS نیز انجام شد. به‌طوری‌که متوسط RMSE در شبیه‌سازی ابعاد آبنمود در بازه‌های یک ساعته برای وقایع مورد آزمون به ترتیب برابر با ۲/۱۳، ۱/۷، ۱/۷۶ و ۱/۳ مترمکعب بر ثانیه برای گروه‌های اول تا چهارم حاصل گردید. آبنمودهای شبیه‌سازی شده به وسیله‌ی این دو روش در شکل‌های (۴) تا (۷) ارائه شده‌اند. همچنین، جهت مقایسه‌ی این دو روش از معیار درصد خطای نسبی

جدول ۲- مقایسه‌ی درصد خطای نسبی فراسنج‌های مربوط آبنمودهای شبیه‌سازی شده به وسیله‌ی نرم-افزار HEC-HMS و روش شبکه‌ی عصبی برای وقایع مورد آزمون در گروه اول.

وقایع	فراسنج‌های خروجی						روش	
	Q_p	T_p	T_b	w_{75}	w_{50}	T_{50}		T_{75}
a	-۱۴/۸۵	۹/۴۵	-۴/۹۸	-۱۲۲/۳۸	-۴۴/۲۶	۲/۲۱	-۵/۹۸	ANN
	۳۰/۹۹	۹/۰۹	۲۸/۵۷	-۳۹/۰۵	۳۲/۳۵	۳۷/۵۰	۲۵/۵۶	HEC-HMS
b	۱۷/۳۰	-۱۱/۶۱	-۲۲/۰۲	۶/۶۹	-۷/۱۶	۶/۵۱	-۵/۹۲	ANN
	-۷۵۶/۵۳	-۵۰/۰۰	-۱۳۱/۲۵	-۳/۴۷	-۱/۵۰	-۸۹/۶۶	-۷۶/۳۲	HEC-HMS
c	۱۳/۰۶	-۱۵/۷۱	-۱/۹۴	-۸/۴۵	-۸/۸۳	-۶/۲۸	-۸/۵۶	ANN
	-۴۶/۹۰	-۴۰/۰۰	۰/۰۰	۱۲/۱۶	۴۶/۲۹	-۴۶/۶۰	-۴۶/۳۴	HEC-HMS
d	۷/۴۹	۲/۹۳	-۷/۴۶	-۴/۵۴	-۶/۸۰	۶/۴۴	۳/۸۱	ANN
	۱۵/۸۰	-۱۲/۵۰	-۳۰/۷۷	-۱۶۵/۷۰	-۹۴/۴۷	۶/۵۷	۵/۰۶	HEC-HMS
e	-۶/۸۱	۲/۶۸	۱/۱۳	-۲۶/۳۴	-۸/۴۴	۹/۵۸	۹/۹۴	ANN
	۲/۷۱	۴/۷۶	-۲۲/۲۲	-۲۲۵/۰۰	-۵۰/۰۰	۳/۳۳	۱۸/۸۹	HEC-HMS
f	۲۰/۵۹	-۲۷/۳۵	-۴۵/۰۱	-۱۹۰/۱۵	-۱۹/۸۵	۵۴/۵۱	۴۱/۹۰	ANN
	۳۸/۱۱	-۱۶۶/۶۷	-۸۰/۰۰	-۵۷۵/۰۰	-۱۳۸/۸۹	-۶۶/۶۷	-۹۶/۴۳	HEC-HMS



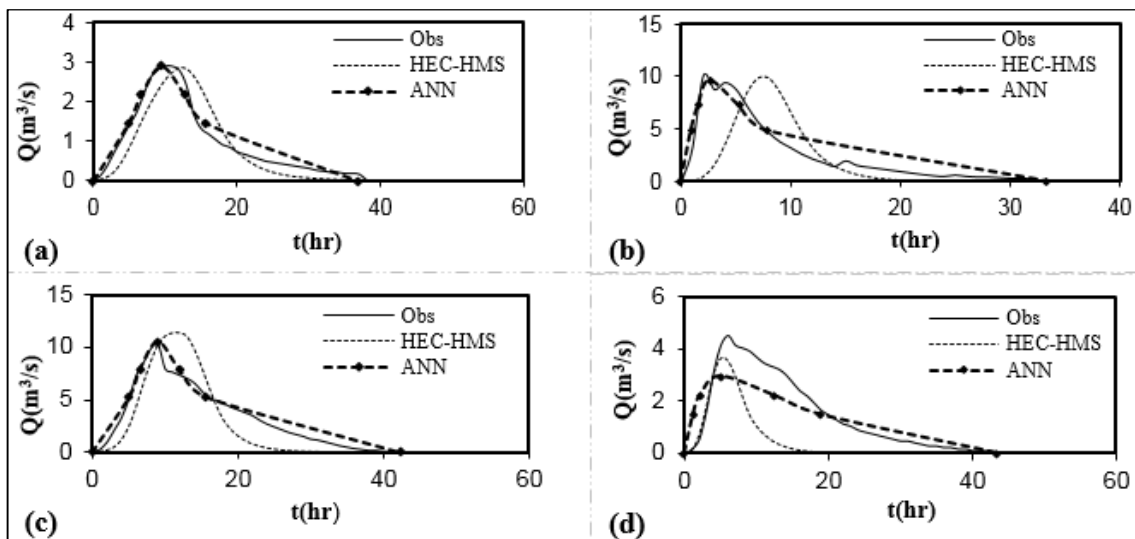
شکل ۴- آبنمودهای واقعی و شبیه‌سازی شده به وسیله‌ی دو روش برای وقایع انتخابی از گروه اول (تاریخ وقوع رخدادهای a تا f به ترتیب ۶۸/۸/۱۲، ۶۶/۱۰/۲۳، ۷۱/۱۰/۱۴، ۷۳/۹/۲۶، ۷۳/۱۰/۲۱ و ۷۲/۱۱/۱۶ می باشند).

با توجه به شکل (۵) و جدول (۳) می توان نتیجه گرفت که در گروه دوم برای واقعه‌ی (a)، هر دو روش از دقت بالایی در شبیه سازی شکل کلی آبنمودها، به ویژه در بده اوج (Q_p) برخوردارند، ولی دقت روش شبکه‌ی عصبی در شبیه سازی تمام فراسنج‌ها به استثنای عرض آبنمود در ۷۵ درصد بده اوج (W_{75}) به مراتب بهتر از نرم افزار HEC-HMS بوده است. برای واقعه‌ی (b)، آبنمود شبیه سازی شده به وسیله‌ی شبکه‌ی عصبی تقریباً "منطبق بر آبنمود مشاهده‌ای بوده و فراسنج‌ها با خطای ناچیزی شبیه سازی شده‌اند. البته، آبنمود شبیه سازی شده به وسیله‌ی نرم افزار HEC-HMS از نظر شکل کلی شبیه به آبنمود واقعی است، اما آبنمود با یک جابه جایی زمانی حدود $3/5$ و $2/5$ برابر به ترتیب در زمان رسیدن به بده 50 درصد بده اوج (T_{50}) و زمان وقوع بده اوج (P_T) روبرو شده است. در مورد واقعه‌ی (c)، هر دو روش شکل کلی آبنمود را نسبتاً خوب شبیه سازی کرده‌اند، اما شبیه سازی تمامی فراسنج‌ها در این واقعه با کاربرد روش شبکه‌ی عصبی با خطای نسبی بسیار کمتری نسبت به نرم افزار HEC-HMS انجام گردیده است. برای واقعه‌ی (d)، شبیه سازی به وسیله‌ی دو روش ضعیف انجام گردیده است، اما نرم افزار HEC-HMS فراسنج‌های Q_p ، T_p ، W_{50} و T_{75} را با خطای کمتری نسبت به روش شبکه‌ی عصبی شبیه سازی نموده است. به طور کلی، می توان گفت که برای این گروه روش شبکه‌ی عصبی به استثنای واقعه‌ی (d) آبنمود حاصل از سایر وقایع را با دقت خوبی شبیه سازی نموده است.

که دو روش، زمان وقوع بده اوج را با خطای تقریباً یکسانی شبیه سازی نموده اند. اما شبیه سازی عرض‌های آبنمود در 50 و 75 درصد بده اوج، به ویژه عرض آبنمود در 75 درصد با خطای کمتری با کاربرد نرم افزار HEC-HMS شبیه سازی شده است. برای واقعه‌ی (b) مثل واقعه‌ی (a)، شبیه سازی تمام فراسنج‌ها به استثنای عرض‌های آبنمود در 50 و 75 درصد بده اوج با کاربرد شبکه‌ی عصبی با خطای ناچیزی نسبت به نرم افزار HEC-HMS برآورد شده‌اند، به طوری که بده اوج در این واقعه با کاربرد نرم افزار HEC-HMS حدود $7/5$ برابر مقدار واقعی حاصل گردیده است. در مورد واقعه‌های (c) و (d)، تمامی فراسنج‌ها به استثنای فراسنج زمان پایه‌ی آبنمود در واقعه‌ی (c) با روش شبکه‌ی عصبی بهتر شبیه سازی شده‌اند. البته، در مورد واقعه‌ی (d) نرم افزار HEC-HMS فراسنج‌های بده اوج، زمان وقوع آن و زمان رسیدن به 50 و 75 درصد بده را با خطای کمتری نسبت به واقعه‌ی (c) شبیه سازی نموده است. در مورد واقعه‌ی (e)، دقت نرم افزار HEC-HMS در شبیه سازی بده اوج و زمان رسیدن به بده 50 درصد اوج خیلی بهتر از روش شبکه عصبی بوده است. برای واقعه‌ی (f)، هر دو روش ضعیف عمل نموده‌اند. به طور کلی، می توان گفت که در این دسته از اطلاعات اکثر آبنمودهای شبیه سازی شده با کاربرد روش شبکه‌ی عصبی از دقت بالاتر و خطای کمتری نسبت به نرم افزار HEC-HMS برخوردار بوده‌اند. البته، در مورد (d) و (e)، شبیه سازی شکل کلی آبنمود با کاربرد نرم افزار HEC-HMS به خوبی انجام شده است.

جدول ۳- مقایسه‌ی درصد خطای نسبی فراسنج‌های مربوط به آبنمودهای شبیه سازی شده به وسیله‌ی نرم افزار HEC-HMS و روش شبکه‌ی عصبی برای وقایع مورد آزمون در گروه دوم.

وقایع	فراسنج‌های خروجی							روش
	Q_p	T_p	T_b	W_{75}	W_{50}	T_{50}	T_{75}	
a	۰/۳۳	۵/۱۱	۰/۴۵	۹/۹۳	-۳/۱۴	-۲۴/۴۴	-۵/۶۴	ANN
	۱/۸۸	-۲۰/۰۰	-۸/۱۱	-۳/۴۱	-۵/۸۶	-۶۵/۸۲	-۳۳/۳۱	HEC-HMS
b	۳/۷۸	-۲۹/۹۰	-۱/۰۷	۱۱/۶۲	-۸/۲۲	۹/۷۹	-۳/۱۰	ANN
	۲/۳۳	-۲۵/۰/۰	۱۸/۱۸	۲/۸۴	-۰/۹۳	-۳۵/۰/۰	-۲۶۶/۶۷	HEC-HMS
c	-۱/۴۷	-۰/۵۵	-۰/۸۴	-۵/۶۸	۸/۶۳	-۸/۵۷	-۲/۴۲	ANN
	-۹/۳۷	-۳۳/۳۳	۲۱/۴۳	-۳۰/۳۵	۱۶/۵۹	-۴۲/۲۵	-۲۴/۴۲	HEC-HMS
d	۳۴/۹۰	۱۶/۹۷	۱/۱۰	-۳۵/۹۳	-۲۶/۷۹	۴۵/۳۵	۴۵/۷۰	ANN
	۲۰/۲۱	۱۶/۶۷	۴۳/۱۸	-۴۴/۷۴	۱۸/۵۷	-۳۶/۳۶	۷/۵۰	HEC-HMS



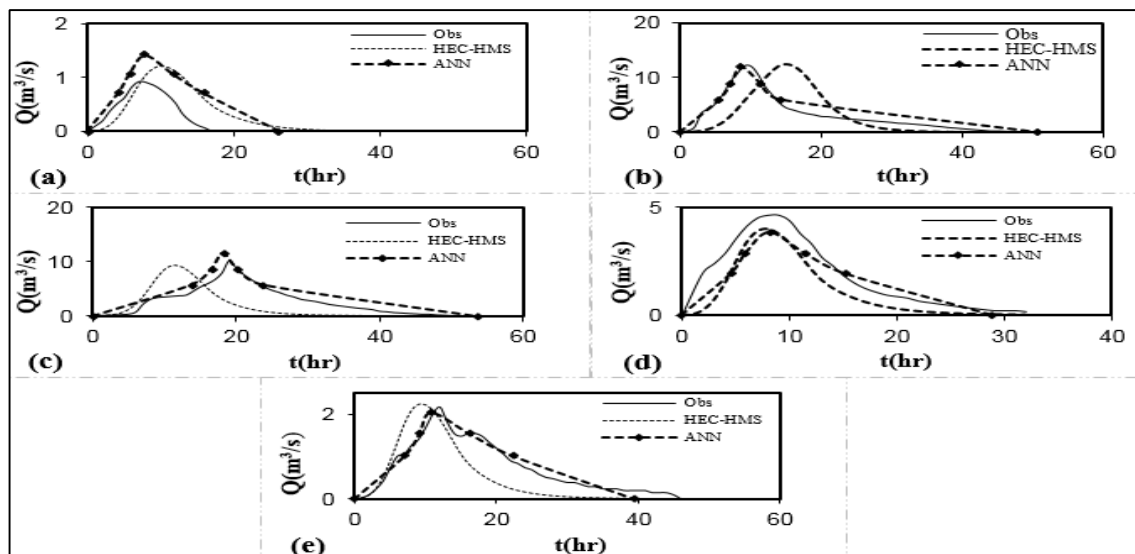
شکل ۵- آبنمودهای واقعی و شبیه‌سازی شده به وسیله‌ی دو روش برای وقایع انتخابی از گروه دوم (تاریخ وقوع رخدادهای a تا d به ترتیب ۶۷/۹/۲۹، ۶۸/۱۱/۲۳، ۷۸/۱۱/۱۹ و ۸۱/۱۲/۲۶ می باشند).

نسبت به روش شبکه‌ی عصبی (۱۲/۰۶ درصد) شبیه‌سازی نموده، در صورتی که در مورد سایر فراسنج‌ها و شکل کلی آبنمود از دقت پایین‌تری برخوردار است. همچنین، برای واقعه‌ی (d)، هر دو روش آبنمودهایی نزدیک به هم را ایجاد کرده‌اند، ولی نرم‌افزار HEC-HMS فراسنج‌های T_p ، Q_p و T_b را با خطای نسبی کمتری شبیه‌سازی کرده است. در نهایت، برای واقعه‌ی (e)، مطابق شکل آبنمود شبیه‌سازی شده به وسیله‌ی شبکه‌ی عصبی، مطابقت بیشتری به آبنمود مشاهده‌ی ای دارد، اما بایستی توجه کرد که دقت نرم‌افزار HEC-HMS در شبیه‌سازی فراسنج‌های Q_p ، T_b و W_{v5} بهتر از روش شبکه‌ی عصبی است.

با توجه به شکل (۶) و جدول (۴) برای گروه سوم می‌توان نتیجه گرفت که برای واقعه‌ی (a)، فراسنج‌های T_p ، T_b ، W_{v5} ، T_{Δ} و T_{v5} با کاربرد شبکه عصبی با خطای نسبی کمتری نسبت به نرم‌افزار HEC-HMS شبیه‌سازی شده‌اند، در حالی که نرم‌افزار HEC-HMS شبیه‌سازی Q_p و W_{Δ} را با خطای کمتری نسبت به شبکه‌ی عصبی انجام داده است. برای واقعه‌ی (b)، دو روش، بده اوج و زمان پایه آبنمود را به خوبی شبیه‌سازی نموده‌اند، اما دقت روش شبکه‌ی عصبی در شبیه‌سازی تمام فراسنج‌ها، و شکل کلی آبنمود، قابل توجه می‌باشد. در مورد واقعه‌ی (c)، نرم‌افزار HEC-HMS تنها بده اوج را با خطای کمتری (۹/۸۷ درصد)

جدول ۴- مقایسه‌ی درصد خطای نسبی فراسنج‌های مربوط به آبنمودهای شبیه‌سازی شده به وسیله‌ی نرم‌افزار HEC-HMS و روش شبکه‌ی عصبی برای وقایع مورد آزمون در گروه سوم.

وقایع	فراسنج‌های خروجی							روش
	Q_p	T_p	T_b	W_{v5}	W_{Δ}	T_{Δ}	T_{v5}	
a	-۵۱/۹۷	-۱۳/۱۶	-۵۴/۰۷	-۰/۲۳	-۳۳/۴۵	-۲۳/۱۴	-۱۹/۶۹	ANN
	-۳۰/۳۵	-۴۲/۸۶	-۱۴۱/۱۸	-۱۱/۶۷	-۱۴/۷۷	-۷۳/۵۳	-۴۷/۹۲	HEC-HMS
b	۰/۹۸	۳/۴۸	-۵/۵۶	۹/۹۱	-۶/۵۴	۲۵/۴۷	-۴/۲۸	ANN
	-۲/۰۰	-۵۵/۵۶	۸/۳۳	-۴۸/۳۵	-۳۶/۳۱	-۵۴/۵۵	-۵۳/۵۷	HEC-HMS
c	-۱۲/۰۶	۴/۱۴	-۱/۱۳	-۱۳/۵۹	-۱/۲۹	۴/۹۵	۵/۳۹	ANN
	۹/۸۷	۴۲/۱۱	۲۴/۵۳	-۷۹/۶۹	۹/۷۴	۴۷/۵۹	۵۰/۰۰	HEC-HMS
d	۱۷/۰۱	-۱/۹۴	۱۲/۵۴	۱/۲۶	-۱۴/۳۳	-۳۰/۲۳	-۱۹/۲۴	ANN
	۱۴/۱۶	۰/۰۰	۳/۰۳	۹/۷۵	۱۹/۷۹	-۳۷/۱۴	-۱۲/۰۰	HEC-HMS
e	۶/۰۱	۹/۳۱	۱۴/۱۳	-۷۲/۶۰	-۱۲/۴۴	-۸/۳۰	۵/۶۳	ANN
	-۳/۹۴	۲۵/۰۰	۱۰/۸۷	-۵۰/۲۴	۳۰/۱۰	۱۹/۳۳	۳۳/۰۶	HEC-HMS



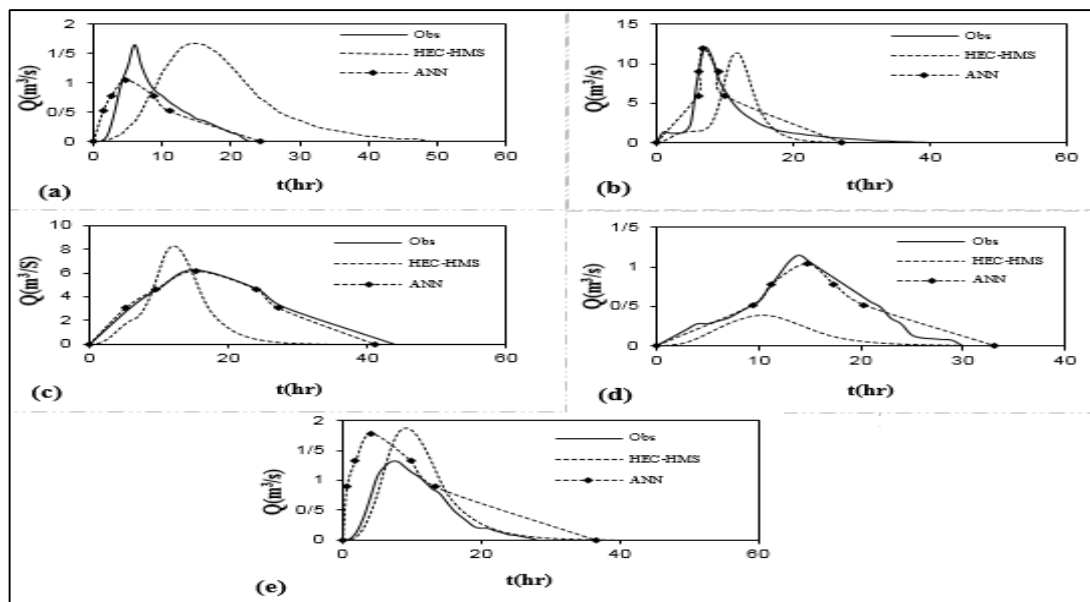
شکل ۶- آبنمودهای واقعی و شبیه‌سازی شده به وسیله‌ی دو روش برای وقایع انتخابی از گروه سوم (تاریخ وقوع رخدادهای a تا e به ترتیب ۷/۱۳/۷۶، ۲۳/۰۹/۶۹، ۰۸/۱۰/۷۶، ۱۶/۱۰/۶۸ و ۲۶/۱۱/۵۹ می باشند).

کرده است. برای واقعه‌ی (c)، روش شبکه‌ی عصبی نتایج قابل توجهی را در شبیه‌سازی شکل کلی آبنمود و فراسنج-های مربوط به آن حاصل کرده است البته، T_{V5} به وسیله‌ی HEC-HMS با خطای کمتری (۲ درصد) نسبت به روش شبکه‌ی عصبی (۳/۹۹ درصد) شبیه‌سازی شده است. در واقعه‌ی (d)، آبنمود حاصل از روش شبکه عصبی با آبنمود مشاهده‌ای تطابق خوبی داشته، و اکثر فراسنجه‌ها را با خطای ناچیزی شبیه‌سازی نموده است. در نهایت، برای واقعه‌ی (e)، روش HEC-HMS تمام فراسنجه‌ها را با استثنای Q_P و T_b با درصد خطای نسبی کمتری

بالاخره، برای گروه چهارم اطلاعات با بررسی شکل (۷) و جدول (۵) نتیجه گرفته می‌شود که در واقعه‌ی (a)، اگر چه روش شبکه‌ی عصبی اکثر فراسنجه‌ها را به خوبی شبیه‌سازی نموده، اما فراسنج بده اوج را با خطای بالایی (۳۶/۹ درصد)، برعکس نرم‌افزار HEC-HMS (۵۸ درصد) برآورد کرده است. برای واقعه‌ی (b)، تمام فراسنجه‌ها به استثنای W_{V5} ، با کاربرد شبکه‌ی عصبی با خطای کمتری نسبت به روش دیگر شبیه‌سازی شده‌اند. البته در این مورد، مدل HEC-HMS بده اوج (خطای نسبی ۴/۹۵ درصد) و شکل کلی را با دقت خوبی پیش‌بینی

جدول ۵- مقایسه‌ی درصد خطای نسبی فراسنجه‌های مربوط به آبنمودهای شبیه‌سازی شده به وسیله‌ی نرم-افزار HEC-HMS و روش شبکه‌ی عصبی برای وقایع مورد آزمون در گروه چهارم.

وقایع	فراسنجه‌های خروجی							روش
	Q_P	T_P	T_b	w_{V5}	w_5	T_5	T_{V5}	
a	۳۶/۹	۲۶/۹۱	-۱/۳۷	-۲۰۲/۶۲	-۶۹/۸۸	۶۴/۱	۴۸/۳۱	ANN
	-۰/۵۸	-۱۳۰/۷۷	-۱۰۴/۱۷	-۳۸۵/۰۰	-۱۶۷/۸۶	-۱۱۲/۵۰	-۱۰/۱/۹۲	HEC-HMS
b	۰/۰۲	۱/۹۱	-۰/۲۶	-۱۵/۳۹	۱۸/۴۸	-۸/۹۹	-۳/۷۵	ANN
	۴/۹۵	-۷۱/۴۳	۰/۰۰	-۳۷/۵۰	-۶/۲۵	-۷۰/۹۱	-۷۰/۰۰	HEC-HMS
c	۱/۸۲	-۱/۶۲	۶/۳۹	-۳/۷۷	۰/۵۲	۱۲/۱۸	۳/۹۹	ANN
	-۳۲/۵۰	۲۰/۰۰	۱۸/۱۸	۶۷/۵۰	۶۶/۳۶	-۴۸/۳۳	-۲/۰۰	HEC-HMS
d	۹/۲۱	-۴/۷۳	-۱۰/۱۳	-۲/۵۵	۱/۹۰	۵/۴۶	۲/۴۴	ANN
	۶۶/۰۴	۲۸/۵۷	۰/۰۰	-۱۰/۰۰	۱۰/۹۱	۴۳/۰۰	۳۹/۱۳	HEC-HMS
e	-۳۵/۷۸	۴۱/۲۳	-۳۱/۱۵	-۴۹/۳۸	-۴۴/۰۹	۸۲/۰۷	۵۵/۷۶	ANN
	-۴۳/۴۴	-۲۸/۵۷	-۴۶/۴۳	-۱۰/۰۰۶	-۳/۲۵	-۵۵/۸۸	-۵۳/۴۹	HEC-HMS



شکل ۷- آبنمودهای واقعی و شبیه‌سازی شده به وسیله‌ی دو روش برای وقایع انتخابی از گروه چهارم (تاریخ وقوع رخدادهای a تا e به ترتیب ۶۳/۹/۱۵، ۶۱/۱۰/۰۳، ۶۶/۱۱/۱۹، ۷۴/۹/۰۶ و ۷۷/۱۱/۲۷ می باشند).

زمان پایه و شکل کلی آن را به خوبی یا به ندرت دقیقتر از شبکه‌ی عصبی انجام دهد. شایان ذکر است که در صورت موجود بودن اطلاعات جزئی و فراسنج‌های اندازه‌گیری شده از حوضه‌ی آبخیز جهت استفاده از روشهای انتخابی در نرم‌افزار HEC-HMS، ممکن است واسنجی این مدل با دقت بیشتری انجام شده و از توان بالایی در شبیه‌سازی فرایند بارش- رواناب برخوردار باشد. روش شبکه‌ی عصبی افزون بر دقت بالای آن در شبیه‌سازی فرایند مذکور از سرعت و دقت بیشتری در آموزش و محدودیت کمتری از نظر آموزش در مقایسه با واسنجی نرم‌افزار HEC-HMS برخوردار است. علاوه بر این، هر چند اطلاعات موجود در تحقیق حاضر، جهت جلوگیری از واگرایی شبکه و بهبود آن، تقسیم‌بندی شده‌اند، اما وقایع موجود در هر گروه دارای تداوم‌های متعدد بوده و از شراکت تمام آنها جهت به‌دست آوردن فراسنج‌های شبکه‌ی عصبی (وزن‌ها و اریب-ها) استفاده شده است. این امر انعطاف‌پذیری شبکه‌ی عصبی را جهت شبیه‌سازی وقایع متعدد و متفاوت از مجموعه‌ی آموزشی نمایان می‌سازد. همچنین، نتیجه گرفته شد که افزایش اطلاعات آموزشی برای شبکه‌ی عصبی می‌تواند منجر به همگرایی بهتر و پایداری فرایند آموزش گردد.

شبیه‌سازی نموده، و از نظر شکل کلی به جز در دو نقطه‌ی مذکور نتایج خوبی نسبت به شبکه عصبی حاصل گردیده- اند.

۵- بحث و نتیجه‌گیری

در این تحقیق توانایی روش شبکه‌ی عصبی مصنوعی در شبیه‌سازی رابطه بارش- رواناب مورد ارزیابی قرار گرفت، و نتایج حاصل از آن با نتایج حاصل از نرم‌افزار HEC-HMS مقایسه گردیدند. به‌طور کلی محدوده‌ی قدرمطلق درصد خطای نسبی فراسنج‌های Q_p ، T_p ، T_b ، T_{75} و T_{50} ، W_{50} ، W_{75} شبیه‌سازی شده به وسیله‌ی شبکه عصبی به ترتیب ۵۱/۹۷-۰/۰۲، ۴۱/۲۳-۰/۵۵، ۵۴/۰۷-۰/۲۶، ۲۰۲/۶۲-۰/۲۳، ۶۹/۸۸-۰/۵۲، ۸۲/۰۷-۲/۲۱ و ۵۷/۷۶-۲/۴۲ می‌باشند، در حالی که با شبیه‌سازی به وسیله‌ی نرم‌افزار HEC-HMS این حدود به ترتیب ۷۵۶/۵۳-۰/۵۸، ۲۵۰-۰، ۱۴۱/۱۸-۰، ۵۷۵-۲/۸۴، ۱۶۷/۸۶-۰/۹۳، ۳۵۰-۳/۳۳ و ۲۶۶/۶۷-۲ به دست می‌آیند. با توجه به درصد خطای نسبی مربوط به فراسنج‌های خروجی هر واقعه می‌توان نتیجه گرفت که شبکه‌ی عصبی در اکثر موارد تمامی فراسنج‌ها و شکل کلی آبنمود را به خوبی و با خطای ناچیزی نسبت به نرم‌افزار HEC-HMS شبیه‌سازی نموده است. البته، در بعضی موارد، نرم‌افزار HEC-HMS توانسته است شبیه‌سازی بده اوج آبنمود،

- ۱۵) Pan, T.Y., and Wang, R.Y. 2005. Using recurrent neural networks to reconstruct rainfall-runoff processes. *Hydrological Process*. 19(18): 3603-3619.
- ۱۶) Shoo, G.B., and Ray, C. 2006. Flow forecasting for a Hawaii stream using rating curves and neural networks. *Journal of Hydrology*. 317: 63-80.
- ۱۷) Simonovic, S.P., and Ahmad, S. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology*. 315: 236-251.
- ۱۸) Singh, V.P., and Woolhiser, D.A. 2002. Mathematical modelling of watershed hydrology. *Journal of Hydrology*. 7(4): 270-292.
- ۱۹) Sohail, A., Watanabe, K., and Takeuchi, S. 2008. Runoff analysis for a small watershed of Tono area Japan by back propagation artificial neural network with seasonal data. *Water Resource Management*. 22(1): 1-22.
- ۲۰) Tayfur, G., and Moramarco, T. 2007. Forecasting flood hydrographs at Tiber River Basin in Italy by Artificial Neural Network. *International Congress on River Basin Management, Antalya, Turkey*, H: 485-497.
- ۲۱) Tokar, A.S. and Markus, M. 2000. Precipitation-Runoff Modelling Using Artificial Neural Networks and Conceptual Models. *Journal of Hydrology Engineering*. 2: 156-161.
- ۲۲) Tokar, A.S., and Johnson, P.A. 1999. Rainfall-runoff modelling using artificial neural networks. *Journal of Hydrology Engineering*, 3: 232-239.
- ۶- منابع
- ۱) جهانگیر، ع.، رائینی، م.، احمدی، م. ض. و اکبرپور، ا. ۱۳۸۴. شبیه‌سازی فرایند بارش- رواناب با استفاده از شبکه‌ی عصبی مصنوعی در حوضه کارده. مجموعه مقالات پنجمین کنفرانس هیدرولیک ایران. دانشکده مهندسی دانشگاه شهید با هنر کرمان.
- ۲) گزارش‌های آماری حوضه آبخیز معرف کسلیان از سال آبی ۶۱-۱۳۶۰ الی ۷۸-۱۳۷۷. مرکز تحقیقات منابع آب ایران(تماب).
- ۳) منهای م. ب. ۱۳۸۶. مبانی شبکه‌های عصبی. جلد اول(هوش محاسباتی)، مرکز نشر دانشگاه صنعتی امیر کبیر. ۷۱۵ص.
- 4) Antar, M.A., Ellassiouti, I., and Allam, M.N. 2006. Rainfall-runoff modelling using artificial neural networks technique: a Blue Nile catchment case study. *Hydrol. Process*. 20: 1201-1216.
- 5) Aytek, A., and Alp, M. 2008. An Application of artificial intelligence for rainfall-runoff modeling. *J. Earth Syst. Sci*. 117: 145-155.
- 6) Department of Civil Engineering National Institute of Technology, Rourkela.p:40.
- 7) Firat, M., and Gungor, M. 2007. River flow estimation using feed forward and radial basis neural networks approaches. *International Congress on River Basin Management*. 599-611.
- 8) Harun, S., Ahmat, N.I., and Kassim, A.H.M. 2002. Artificial neural network model for rainfall-runoff relationship. *Journal Technology*. 37(B) Dis: 1-12.
- 9) Huff, F.A. 1967. Time distribution of rainfall in heavy storms. *Water Resources Research*. 3(4): 1007-1101.
- 10) Jain, A.K., Mao, J., and Mohiuddin, k. m. 1996. Artificial neural networks: a tutorial. *Computer, IEEE P*. 31-44.
- 11) Jy, W.M., Han, j., Annambhotla, S. and Bryant, S. 2005. Artificial neural networks for forecasting watershed runoff and stream flows. *Journal of Hydrologic Engineering*. ASCE. 10(3): 216-223.
- 12) Kim, M.S., Shim, S.B., and Yeon, G.B. 2000. The rainfall -runoff models for real time flood forecasting in Geum river watershed.
- 13) Kumar, P., and Singh, A. 2010. Rainfall-runoff modeling of River Kosi using SCS-CN method and ANN. a thesis submitted in partial fulfillment of the requirements for the degree of bachelor of technology
- 14) Lorria, M., and Sechi, G.M. 1995. Neural networks for modeling rainfall runoff transformations. *Water Resource Management*. 9: 299-313.