



کاربرد شبکه عصبی مصنوعی در پیش‌بینی رواناب ناشی از ذوب برف (مطالعه موردی: حوزه آبخیز سد لتيان)

فاطمه صدیقی^۱، مهدی وفاخواه^۲ و محمد رضا جوادی^۳

۱- دانشجوی دکتری، دانشگاه تربیت مدرس

۲- دانشیار، دانشگاه تربیت مدرس، (نویسنده مسؤول): vafakhah@modares.ac.ir

۳- استادیار، دانشگاه آزاد اسلامی واحد نور

تاریخ دریافت: ۹۱/۱۱/۱۱ تاریخ پذیرش: ۹۲/۶/۲۴

چکیده

سیل یکی از پدیده‌های ویرانگر طبیعی است که پیش‌بینی آن از اهمیت بالایی برخوردار است. فرآیند بارش- رواناب و ایجاد سیلاب پدیده‌های فیزیکی هستند که بررسی آنها به سبب تاثیرگذیری از پارامترهای مختلف، دشوار می‌باشد. تاکنون روش‌های مختلفی برای تحلیل این پدیده‌ها ارایه شده است. پژوهش حاضر با هدف بررسی کارآمدی شبکه‌های عصبی مصنوعی در شبیه‌سازی فرآیند بارش- رواناب با دلالت دادن ارتفاع آب معادل برف در حوزه آبخیز لتيان واقع در استان تهران صورت گرفته است. بدین منظور ۹۲ تصویر سنجنده مودبیس در طی سه سال آبی ۸۲-۸۴-۸۵ تا ۱۳۸۲-۸۳ تا ۱۳۸۴-۸۵ از سایت ناسا دریافت گردید و سطح پوشش برف در هر یک از تصاویر استخراج و میزان ارتفاع آب معادل برف در طی سال‌های مورد نظر محاسبه شد. همچنین داده‌های ارتفاع بارندگی، درجه حرارت و دبی در سال‌های مورد نظر در دسترس بوده که از شبکه‌های پرسپترون چندلایه و الگوریتم پس انتشار خطاب را یافتن ساختار شبکه استفاده شد. نتایج نشان داد شبکه عصبی با ساختار ۱-۱۰-۱-۴ با ۴ نرون در لایه ورودی، ۱۰ نرون در لایه میانی و ۱ نرون در لایه خروجی با ضریب کارایی ۰/۸۵ و ضریب تبیین ۰/۶۸ و ریشه میانگین مربعات خطای ۰/۰۴ به عنوان بهترین ساختار از دقت مناسبی در برآورد رواناب برخوردار بود و دلالت دادن آب معادل برف باعث افزایش دقت مدل شد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، مدل بارش- رواناب، ارتفاع آب معادل برف، حوزه آبخیز لتيان

امکان‌پذیر نیست (۳۰) لذا پیش‌بینی دقیق مقدار رواناب حاصل از بارندگی بسیار مشکل می‌باشد. در دهه‌های گذشته به دلیل وجود چنین مشکلاتی هیدرولوژیست‌ها و محققان سعی کرده‌اند مدل‌های ساده شده و تحریبی را برای پیش‌بینی و محاسبه خصوصیات مختلف و مهم رواناب مانند دبی اوج سیلاب، زمان وقوع دبی اوج و غیره به کار گیرند. استفاده از این روش‌ها علی‌رغم سادگی، دارای خطای زیادی در برآورد است و در بسیاری از مناطق نمی‌توان بر نتایج حاصل از آنها تکیه و استناد کرد (۹). یکی از این روش‌هایی که در بسیاری از علوم از جمله هیدرولوژی توسعه یافته است، استفاده از روش‌های محاسبات نرم نظری منطق فازی، شبکه عصبی مصنوعی و با ترکیبی از این دو روش است. بدین منظور مطالعاتی نظری فرهمند و همکاران (۱۰)، زارع ابینه و بیاتورکشی (۲۹)، دستورانی و همکاران (۹)، دشموخ و همکاران (۲۴) در سال‌های اخیر صورت گرفته است. همچنین کرتولوس (۶) در تحقیقی شبکه‌های عصبی مصنوعی (ANN) و عصبی- فازی تطبیقی (ANFIS) را برای پیش‌بینی دبی روزانه حوزه آبخیزهای آهکی مورد استفاده قرار دادند و با مقایسه کردن آبنمودهای پیش‌بینی شده و مشاهده شده به این نتیجه رسیدند که هر دو مدل (ANN و ANFIS) پیش‌بینی‌های دقیقی از دبی‌های روزانه مجموعه آهکی

مقدمه


ذخیره برفی در حوضه‌های کوهستانی منشا اصلی جریان‌های آب سطحی در فصل بهار به شمار می‌آید. این باشت برف و ذوب تدریجی توده‌های برف، موجب فراهم آمدن شرایط مساعد برای نفوذ و تغذیه آب‌های زیرزمینی و ایجاد رودخانه‌های دائمی و فصلی در حوزه‌های آبریز می‌شود. طبق بررسی‌های انجام شده، حدود ۶۰ درصد از آب‌های سطحی و ۵۷ درصد آب‌های زیرزمینی کشور از ذوب برف تغذیه می‌شود (۱۹). حوزه آبخیز لتيان یکی از مهمترین حوزه‌های آبخیز تهران است و در حال حاضر آب مورد نیاز بخش عظیمی از ساکنان تهران متکی به این آبخیز است (۱۸). برف یکی از اشکال مهم بارش در حوزه آبخیز سد لتيان بوده که در تأمین منابع آب آشامیدنی و کشاورزی به صورت جریان‌های تأخیری در فصول پرآبی و جریان‌های کمینه در فصول کم آبی و تولید انرژی نقش ارزنده ایفا می‌کند از سوی دیگر رواناب حاصل از ذوب برف به دلیل نقش تأخیری آن، منبع اصلی تغذیه سفره‌های آب زیرزمینی و در برخی از موارد به دلیل همزمانی با بارش‌های بهاره منشأ بروز سیلاب‌های مخرب با حجم جریان بیش از ظرفیت رودخانه‌ها می‌شود. فرآیند بارندگی- رواناب، فرآیندی غیرخطی و از حيث زمانی و مکانی کاملاً تصادفی می‌باشد و تشریح آن با مدل‌های ساده به راحتی

مهم مدنظر محققین و پژوهشگران مرتبط با علوم آب قرار گرفته است. تحقیق حاضر نیز در حوزه آبخیز لتیان که تحتتأثیر برف است صورت گرفته، امکان تخمین دقیق رواناب با استفاده از شبکه عصبی و شبکه عصبی- فازی تطبیقی با دخالت دادن آب معادل برف مدنظر است. سعی بر آن است تا گامی هر چند کوچک در جهت کاربرد بیشتر این روش در جهت پیش‌بینی دقیق‌تر مقادیر رواناب خروجی از حوزه آبخیز برداشته شود.

مواد و روش ویژگی‌های منطقه تحقیق

حوزه آبخیز رودک در محدوده طول جغرافیایی $51^{\circ} - 51^{\circ}$ الی $46^{\circ} - 46^{\circ}$ و عرض جغرافیایی $35^{\circ} - 50^{\circ}$ الی 36° با مساحت تقریبی ۴۳۶ کیلومترمربع که شامل زیرحوزه‌های آبخیز (گرمابدر، میگون، آهار، امامه، رودک) در استان تهران قرار داشته است. این آبخیز کوهستانی بوده با ارتفاعات ۱۷۰۰ تا ۴۲۱۲ متر و ارتفاع میانگین ۲۸۳۰ متر و شیب میانگین $45/6\%$ که به سمت شمال، ارتفاع آن افزایش می‌باید یا به عبارت دیگر شیب عمومی آن به سمت جنوب است.

ANFIS فراهم می‌کنند. همچنین نتایج نشان داد که مدل عملکرد بهتری را نسبت به مدل ANN برای پیش‌بینی کردن جریان اوج نشان می‌دهد. واخواه و همکاران (۳۰) رواناب حاصل از ذوب برف به کمک شبکه عصبی مصنوعی و نروفازی در حوزه آبخیز طالقان واقع در استان البرز را شبیه‌سازی کردند و به این نتیجه رسیدند که شبکه عصبی مصنوعی دارای کارآیی بالاتری نسبت به نروفازی در پیش‌بینی جریان بوده و دخالت دادن ارتفاع آب معادل برف در دو ایستگاه باعث افزایش کارآیی ساختار شبکه شده و افزایش تعداد ورودی‌ها از یک دوره زمانی پیشین به سه دوره زمانی پیشین در دو ایستگاه باعث عملکرد نامناسب تر مدل‌ها شده است. پوستیزاده و همکاران (۲۱) کاربرد شبکه عصبی مصنوعی را با سیستم استنتاج فازی در پیش‌بینی جریان رودخانه زاینده‌رود مقایسه نمودند. نتایج این تحقیق حاکی از برتری سیستم استنتاج فازی نسبت به شبکه عصبی مصنوعی می‌باشد. توجه به تحقیقات صورت گرفته نشان می‌دهد، روش شبکه عصبی مصنوعی در شبیه‌سازی پدیده‌های مختلف هیدرولوژی به میزان زیادی مورد استفاده قرار می‌گیرند، در حالی که استفاده از این روش در مدل‌سازی پدیده بارش-رواناب در مراحل اولیه توسعه و تکامل خود بوده و امروزه به عنوان مبحثی



شکل ۱- نقشه شبکه آبراهه، خصوصیات توپوگرافی و محل ایستگاه‌های باران‌سنگی، دما و برف‌سنگی در حوزه آبخیز رودک با اقتباس از زینی‌وند (۳۲)

وارد، خوانده و نمایش داده شد. بدین منظور ۱۹۳ تصویر ماهواره MODIS از سایت دریافت شد که به دلیل پوشش ابر تنها ۹۲ تصویر مورد استفاده قرار گرفت. پردازش تصاویر رقومی ماهواره‌ای که به کمک رایانه انجام شد، شامل مراحل پیش پردازش و آماده‌سازی داده‌ها،

روش پژوهش
استخراج سطح پوشش برف از تصاویر سنجنده MODIS ابتدا تصاویر رقومی ماهواره MODIS منطقه از سایت ناسا (NASA) (<http://ladsweb.nascom.nasa.gov>) با فرمت HDF دریافت، ذخیره و در محیط پردازشگر ENVI

معیار، در صورتی می‌توان نتایج شاخص NDSI را قبول کرد که میزان انعکاس باند دو بیشتر از ۱۱ درصد باشد. دومین معیار تحت عنوان اهداف تیره توسط کلاین و همکاران (۱۵) مطرح شده است. در این حالت، انعکاس ۱۰ درصد در باند چهار به عنوان حد پایین تشخیص و تفکیک پوشش گیاهی از برف شناخته می‌شود. برای پیکسل‌های طبقه‌بندی شده به عنوان برف، انعکاس در باند چهار باید مساوی یا بیشتر از ۱۰ درصد بوده باشد. علی‌رغم ارزش بالای شاخص NDSI، در مواردی هدف‌های تیره مانع طبقه‌بندی صحیح برف می‌شوند. بنابراین، با توجه به دو معیار فوق‌الذکر، الگوریتم پوشش برف در صورتی یک پیکسل را برف تلقی خواهد نمود که شرایط مندرج در ذیل محقق شده باشد. (۱) باند دو دارای بازتابش بیش از ۱۱ درصد باشد. (۲) باند چهار دارای بازتابش برابر یا بیشتر از ۱۰ درصد باشد. (۳) در مجموع باید مقدار NDSI بیشتر از ۰/۴ بروآورد گردد. لازم به توضیح است که نقشه‌ی برفی نهایی در فرمت باپنری بوده و از منطق بولین پیروی می‌کند و در این مدل، کل تصویر به دو پهنه برفی و بدون برف طبقه‌بندی می‌گردد.

استخراج سطح پوشش برف در روزهای بدون تصویر ماهواره

بعد از استخراج سطح پوشش برف در زمان‌های مختلف با استفاده از تصاویر سنجنده MODIS، سطح پوشش برف در روزهای بدون تصویر، با استفاده از عمق تجمعی ذوب برف (M) به دست آمد. عمق تجمعی ذوب برف (M) تابعی از فاکتور درجه-روز (a) و تعداد درجه روز بالای درجه روز بحرانی (T^+) است و در بازه زمانی بین t_2 و t_1 از رابطه (۲) به دست می‌آید.

$$\Delta M(t_1, t_2) = \sum_{t_1}^{t_2} (aT^+) \quad t_1 \langle t_x \rangle t_2 \quad (2)$$

$$a = \frac{1}{1 - \frac{s}{w}} \quad (3)$$

در این رابطه s ... چگالی برف و w ... چگالی آب می‌باشد و در صورت بارش برف جدید فاکتور درجه روز اصلاح و وارد مدل گردید. فرض کنید دو تصویر ماهواره‌ای در زمان‌های t_1 و t_2 موجود است و سطح پوشش برف استخراج شده با استفاده از این دو تصویر $SCA(t_1)$ و $SCA(t_2)$ می‌باشد. اگر در فاصله زمانی بین t_A و t_E دما پایین‌تر از دمای بحرانی باشد، ذوب برف متوقف می‌شود که در این صورت سطح پوشش برف در زمان t_E از رابطه (۴) به دست می‌آید.

طبقه‌بندی داده‌ها و استخراج اطلاعات و پردازش نهایی می‌باشد. زمین مرجع کردن تصاویر با استفاده از جعبه ابزار نرم‌افزار ENVI به صورت خودکار انجام گرفت. تصحیحات جوی روی تصاویر با استفاده از میزان بازتابش امواج از دریاچه سد لیلان صورت گرفت. سعی بر آن شد که از تصاویری استفاده شود که قادر پوشش ابر روی منطقه مورد مطالعه باشد. برای تهیه نقشه پوشش برف الگوریتمی به وسیله هال و همکاران (۱۱) با استفاده از باندهای با قدرت تفکیک زمینی ۵۰۰ به منظور جدا نمودن برف از ابر ارائه شده است. الگوریتم استفاده شده برای تهیه نقشه پوشش برف بر این اساس می‌باشد که برف در طول موج مرئی (۰/۵ تا ۰/۷ میکرومتر) دارای انعکاس زیاد و در طول موج کوتاه مادون قرمز (۱ تا ۴ میکرومتر) دارای انعکاس کم است (۱۱). از باندهای ۴ و ۶ به طور اتوماتیک برای استخراج شاخص برفی تفاضلی نرمال شده (NDSI) و بر اساس معادله (۱) محاسبه می‌گردد.

$$NDSI = \frac{MODIS_{Band\ 4} - MODIS_{Band\ 6}}{MODIS_{Band\ 4} + MODIS_{Band\ 6}} \quad (1)$$

در این رابطه: NDSI شاخص برفی تفاضلی نرمال شده، $MODIS_{Band4}$ تصویر باند چهارم سنجنده MODIS پس از انجام تصحیحات رادیومتریک $MODIS_{Band6}$ تصویر باند شش سنجنده MODIS پس از انجام تصحیحات رادیومتریک است. از این شاخص می‌توان برای تفکیک برف و بیخ از یکدیگر و همچنین برای جداسازی برف از ابرهای ارتفاع بالای اتمسفر نظیر ابرهای کومولونیبوس استفاده نمود. در واقع، این شاخص معیاری برای محاسبه‌ی مقدار نسبی خواص تفاضلی است که از بازتابش بین باندهای مرئی و مادون قرمز طول موج کوتاه برف حاصل می‌شود. شاخص مذکور به گستره‌ی شرایط نوردهی غیر حساس بوده و نسبت به تاثیرات اتمسفری، قابل تنظیم است. به بیان دیگر این شاخص فقط به مقادیر بازتابش در یک باند بستگی ندارد، بلکه به میزان ارزش رقومی بازتابش پیکسل‌ها نیز وابسته است. هال و همکاران (۱۱) ثابت نمودند که الگوریتم استفاده شده برای تهیه نقشه برفی در مناطق با پوشش گیاهی کم پشت از قبیل علفزارها، زمین‌های کشاورزی و توندرها به بهترین نحوه عمل می‌کند. در این شرایط، باند دو MODIS اساساً برای شناسایی برف پردازش قرار می‌گیرد و مولفه‌های NDSI الگوریتم نقشه‌ی برفی، به طور موثر ابرها (به استثناء ابرهای ارتفاع بالا) را فیلتر می‌کند. این ابرها در برگیرنده‌ی تکه‌های بیخ بوده و ممکن است باعث طبقه‌بندی نادرست پوشش برف شوند. با توجه به این

شبکه در نرم‌افزار STATISTICA به دست آمد و ورودی‌ها به شرح زیر به دست آمدند:

$$Qt = f(R_t)$$

$$\begin{aligned} Qt &= f(R_t, R_{t-1}) \\ Qt &= f(R_t, R_{t-1}, R_{t-2}, T_t, T_{t-1}, T_{t-2}, \\ M_t, M_{t-1}) \end{aligned}$$

$$Qt = f(R_t, T_t, M_t, M_{t-1})$$

$$Qt = f(R_t, T_t)$$

$$Qt = f(R_t, R_{t-1}, T_t, T_{t-1})$$

$$Qt = f(R_t, T_t, T_{t-1})$$

$$\begin{aligned} Qt &= f(R_t, R_{t-1}, R_{t-2}, T_t, T_{t-1}, T_{t-2}) \\ Qt &= f(R_t, R_{t-1}, R_{t-2}, R_{t-3}, T_t, T_{t-1}, \\ T_{t-2}, T_{t-3}) \end{aligned}$$

$$Qt = f(R_t, T_t, M_t)$$

$$Qt = f(R_t, R_{t-1}, T_t, T_{t-1}, M_t, M_{t-1})$$

متغیر خروجی تمام شبکه‌های مورد بررسی دبی نرمال شده ایستگاه هیدرومتری رودک (Qt) می‌باشد.

ب- استاندارد کردن داده‌ها

برای جلوگیری از کوچک شدن بیش از حد وزن‌های شبکه‌های عصبی مصنوعی، ورودی‌های شبکه‌های عصبی مصنوعی باید استاندارد شوند. در این تحقیق نیز به منظور استانداردسازی داده‌ها از رابطه ۵ استفاده شد.

$$N_i = 0.8 \times \left(\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) + 0.1 \quad (5)$$

که در آن: N_i : مقادیر استاندارد شده، x_i : مقادیر واقعی x_{\min} : حداقل مقادیر واقعی و x_{\max} : حداکثر مقادیر واقعی می‌باشد که این رابطه ورودی‌های شبکه عصبی را بین ۰/۱ و ۰/۹ نرمال می‌نماید.

ساختار شبکه عصبی مصنوعی

ساختار کلی ANN شامل سه لایه با وظایف مجزا می‌باشد. لایه ورودی با نقش توزیع داده‌ها 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 می‌دهد (۲). در شکل ۲ یک شبکه متعارف از شبکه عصبی پرسپترون سه لایه که کارایی زیادی در هیدرولوژیک در زمان تاخیرهای مختلف است. است که بین لایه ورودی و خروجی یک لایه پردازشگر در نظر گرفته شده است.

$$SCA(t_x) = SCA(t_{x-1}) - \frac{SCA(t_1) - SCA(t_2)}{\Delta M(t_1, t_A) + \Delta M(t_E, t_2)} \Delta M(t_{x-1}, t_x) \quad (4)$$

در این رابطه: $SCA(t_x)$ = سطح پوشش برف در زمان t_x ، $SCA(t_{x-1})$ = سطح پوشش برف در زمان t_{x-1} ، $SCA(t_1)$ ، t_{x-1} = سطح پوشش برف در زمان t_1 ، $SCA(t_2)$ = سطح پوشش برف در زمان t_2 ، $\Delta M(t_1, t_A)$ = عمق تجمیعی ذوب برف در بین زمان t_1 و t_A ، $\Delta M(t_E, t_2)$ = عمق تجمیعی ذوب برف در بین زمان t_E و t_2 و $\Delta M(t_{x-1}, t_x)$ = عمق تجمیعی ذوب برف در بین زمان t_{x-1} و t_x می‌باشد.


تعیین آب معادل برف با مراجعه به شرکت تحقیقات منابع آب آمار معادل برف ایستگاه برف‌سنجدی امامه در سال‌های ۱۳۸۲ تا ۱۳۸۵ دریافت شد. به منظور تعیین ارتفاع آب معادل برف در روزهای فاقد اندازه‌گیری از رابطه رگرسیونی ارتفاع آب معادل برف اندازه گیری شده و سطح پوشش برف استفاده گردید.

داده‌های هواشناسی و آب‌سنجدی

با مراجعه به شرکت تحقیقات منابع آب آمار بارندگی روزانه در ایستگاه‌های هواشناسی (رودک، امامه، گلستان (کمرخانی)، راحت آباد، آهار، گرمابد، شمشک، روبار قصران) و آمار دمای روزانه در ایستگاه‌های هواشناسی (امامه، راحت آباد، گلستان) و دبی روزانه در ایستگاه آب‌سنجدی رودک در طی سال‌های ۱۳۸۵-۱۳۸۲ شد. به منظور تعیین متوسط روزانه بارندگی و دما حوزه آبخیز از چند ضلعی‌های تیسن استفاده شد

الف- تعیین پارامترهای ورودی

انتخاب داده‌ها اولین گام در ساختن شبکه عصبی مناسب به منظور برآورد روابط بارندگی-رواناب است. به طور کلی دو نوع داده را می‌توان به عنوان داده‌های ورودی به شبکه عصبی مورد استفاده قرار داد که شامل داده‌های صرفاً آماری که مربوط به مشاهدات بارندگی روزانه، دمای روزانه، ارتفاع آب معادل برف روزانه است. برای انتخاب مقادیر ورودی به شبکه یکی از راه حل‌های مناسب استفاده از مشاهدات هیدرولوژیک در زمان تاخیرهای مختلف است. بدین منظور با استفاده از نمودار خودهمبستگی جزئی تعداد تاخیرهای لازم برای مدل‌سازی متغیرهای ورودی به



شکل ۲- ساختار شبکه عصبی پرسپترون سه لایه

می باشد. بدین منظور از نرم افزار متلب استفاده شد.

۵- معیارهای ارزیابی عملکرد شبکه ها

به منظور مقایسه نتایج حاصل از هر شبکه عصبی با مقادیر واقعی در مرحله آزمون و مقایسه شبکه های مختلف و انتخاب بهترین مدل، از مقادیر آستانه ای استفاده می شود. ضریب تبیین (R^2) مقادیر مشاهده ای و برآورده رایج ترین شاخص مقایسه ای است. با این وجود ضریب تبیین یک شاخص کلی بوده و نمی تواند شاخص مناسبی باشد (۱۴). بنابراین در این تحقیق علاوه بر ضریب تبیین، ضریب کارایی (CE) و ریشه میانگین مربعات خطای (RMSE) شاخص دیگر مورد استفاده قرار گرفتند:

$$CE = 1 - \frac{\sum_{i=1}^n (Q_{ci} - Q_{oi})^2}{\sum_{i=1}^n (Q_{oi} - \bar{Q}_{oi})^2} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{ci} - Q_{oi})^2}{n}} \quad (7)$$

$$R^2 = \frac{\sum_{i=1}^n (Q_{ci} - \bar{Q}_{oi})^2}{\sum_{i=1}^n (Q_{oi} - \bar{Q}_{oi})^2} \quad (8)$$

نتایج و بحث

جدول ۱ خصوصیات آمار توصیفی داده های ورودی و خروجی را نشان می دهد. در جداول ۲ تا ۴ نتایج مدل های مختلف شبکه عصبی مصنوعی به منظور پیش بینی ذوب برف آورده شده است.

ج- دسته بندی داده ها

در این تحقیق داده های متوسط بارندگی روزانه (P) بر حسب میلی متر، متوسط دمای روزانه (t) بر حسب درجه سانتی گراد، ارتفاع آب معادل برف روزانه (SWE) بر حسب میلی متر و همچنین متوسط دمای روزانه (Q) بر حسب متر مکعب بر ثانیه در ایستگاه هیدرومتری رودک در سال های ۱۳۸۲ تا ۱۳۸۵ به مدت سه سال آمی و کل ۱۰۶ داده در ایستگاه هیدرومتری استفاده گردید.

کل داده ها به سه دسته آموزش، صحبت سنジ و آزمون تقسیم شد به طوری که ۷۰٪ داده ها برای آموزش (Training Set) ۱۵٪ (Validation Set) ۱۵٪ (Test Set) ۱۶٪ داده استفاده گردید.

د- توابع محرک

توابع انتقال معمول مورد استفاده در شبکه های عصبی مصنوعی تابع سیگموئید و تانژانت هیپربولیک در لایه میانی و تابع محرک خطی در لایه خروجی می باشد که در این تحقیق نیز استفاده شدند.

د- معماری و الگوریتم آموزش شبکه عصبی مصنوعی در این پژوهش، با توجه به مقاله کولبیالی و همکاران (۸)، شبکه پیش خور با الگوریتم آموزش انتشار خطأ به عقب و توقف آموزش مورد استفاده قرار گفت. نوع الگوریتم مورد استفاده الگوریتم لونبرگ مارکواردت

جدول ۱- خصوصیات آمار توصیفی داده‌های ورودی و خروجی

پارامتر	دسته‌بندی داده‌ها	تعداد داده	میانگین	انحراف معیار	حداکثر	حداقل
بارندگی (mm)	آموزش	۷۶۸	۲/۰۸	۵/۴۷	۶۸/۹۰	.
	صحت‌سنجی	۱۶۴	۳/۰۹	۶/۲۸	۳۱/۶۷	.
	آزمون	۱۶۴	۰/۹۵	۲/۵۵	۳۶/۶۸	.
	کل داده	۱۰۹۶	۲/۰۶	۵/۳۹	۶۸/۹۰	.
درجه حرارت (C°)	آموزش	۷۶۸	۱۰/۹۴	۸/۴۶	۲۹/۲۶	-۴/۴۵
	صحت‌سنجی	۱۶۴	۲/۶۴	۵/۲۰	۱۱/۵۰	-۹/۳۲
	آزمون	۱۶۴	۲۰	۴/۱۶	۲۶/۹۲	۴/۱۶
	کل داده	۱۰۹۶	۱۱/۰۶	۹/۰۳	۲۹/۲۶	-۹/۳۲
آب معادل برف (mm)	آموزش	۷۶۸	۸۰/۸۷	۱۱۳	۲۹۲/۶۸	.
	صحت‌سنجی	۱۶۴	۱۵۴/۷۷	۱۱۶/۸۳	۲۹۲/۲۳	.
	آزمون	۱۶۴	۴/۰۷	۹/۷۴	۸۱/۷۱	.
	کل داده	۱۰۹۶	۸۰/۴۳	۱۱۲/۶۶	۲۹۲/۶۸	.
دبی (m³ s⁻¹)	آموزش	۷۶۸	۸/۹۹	۱۰/۲۱	۱۱۹	۲/۳۲
	صحت‌سنجی	۱۶۴	۱۲/۱۴	۱۰/۸۲	۳۸/۷	۲/۸۶
	آزمون	۱۶۴	۷/۸۲	۷	۳۳/۷	۲/۱۷
	کل داده	۱۰۹۶	۹/۲۸	۹/۹۷	۱۱۹	۲/۱۷

جدول ۲- مدل‌های شبکه عصبی پیش‌بینی رواناب با ورودی باران و دما

ورودی	معماری شبکه	تابع انتقال لایه	آموزش	صحت‌سنجی	آزمون	R ²	RMSE
Rt	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۹۱	۰/۰۷	۰/۱۴	۰/۰
Rt	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۵	۰/۰۵	۰/۰
Rt, Rt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۲	۰/۰۵	۰/۰۹	۰/۰۶
Rt, Rt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۵	۰/۰۴	۰/۰۴
Rt, Rt-۱, Rt-۲	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۸	۰/۰۵	۰/۰۹	۰/۰۹
Rt, Rt-۱, Rt-۲	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۱۷	۰/۰۶	۰/۳۰	۰/۰۶
Rt, Rt-۱, Rt-۲, Rt-۳	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۶	۰/۰۶	۰/۰۶	۰/۰۶
Rt, Rt-۱, Rt-۲, Rt-۳	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۶	۰/۰۶	۰/۰۶	۰/۰۲
Rt, Tt	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۵	۰/۳۶	۰/۰۷
Rt, Tt	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۵	۰/۰۷	۰/۰۵
Rt, Rt-۱, Tt, Tt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۶	۰/۰۵	۰/۰۶	۰/۱۶
Rt, Rt-۱, Tt, Tt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۵	۰/۰۷	۰/۱۷
Rt, Rt-۱, Rt-۲, Tt, Tt-۱, Tt-۲	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۶	۰/۰۴	۰/۰۴	۰/۰۵
Rt, Rt-۱, Rt-۲, Tt, Tt-۱, Tt-۲	سیگموئید	سیگموئید	۰/۰۵	۰/۰۵	۰/۰۷	۰/۰۵	۰/۳۷
Tt, Tt-۱, Tt-۲, Tt-۳	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۰۶
Rt, Rt-۱, Rt-۲, Tt, Tt-۱, Tt-۲, Tt-۳	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۰۶
Rt, Rt-۱, Rt-۲, Tt, Tt-۱, Tt-۲, Tt-۳	سیگموئید	سیگموئید	۰/۰۵	۰/۰۵	۰/۰۴	۰/۰۵	۰/۰۵
Rt, Rt-۱, Rt-۲, Tt, Tt-۱, Tt-۲, Tt-۳	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۰۶
Rt, Tt, Tt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۱۲
Rt, Tt, Tt-۱	سیگموئید	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۱۸
Rt, Tt, Tt-۱	تائزانت هیبریولیک	سیگموئید	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۶	۰/۳۱

جدول ۳- مدل‌های ورودی باران، دما و آب معادل برف برای شبیه‌سازی رواناب با استفاده از شبکه عصبی

رودی	ساختار شبکه	لایه ورودی	تابع انتقال	آموزش	صحت سنجی	آزمون			
R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²			
0.80	0.05	0.15	0.07	0.12	0.06	خطی	تازه‌تات	۳-۲-۱	Rt, Tt, Mt
0.53	0.04	0.02	0.04	0.22	0.03	خطی	سیگموئید	۳-۷-۱	Rt, Tt, Mt
0.43	0.06	0.03	0.05	0.64	0.04	خطی	تازه‌تات	۶-۷-۱	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1
0.60	0.05	0.11	0.04	0.66	0.03	خطی	سیگموئید	۶-۲-۱	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1
0.45	0.04	0.26	0.04	0.52	0.04	خطی	تازه‌تات	۲-۶-۱	Rt, Mt
0.16	0.05	0.49	0.05	0.24	0.05	خطی	سیگموئید	۲-۲-۱	Rt, Mt
0.26	0.05	0.39	0.05	0.64	0.04	خطی	هیبروبولیک	۴-۹-۱	Rt, Rt-1, Mt, Mt-1
0.25	0.06	0.38	0.05	0.31	0.05	خطی	سیگموئید	۴-۴-۱	Rt, Rt-1, Mt, Mt-1
0.68	0.04	0.79	0.04	0.69	0.03	خطی	هیبروبولیک	۴-۱۰-۱	Rt, Rt-1, Mt, Mt-1
0.67	0.04	0.52	0.03	0.67	0.03	خطی	سیگموئید	۴-۳-۱	Rt, Rt-1, Mt, Mt-1
0.46	0.03	0.60	0.04	0.63	0.04	خطی	هیبروبولیک	۴-۵-۱	Rt, Rt-1, Rt-2, Mt
0.55	0.04	0.55	0.05	0.71	0.03	خطی	سیگموئید	۴-۸-۱	Rt, Rt-1, Rt-2, Mt
0.48	0.06	0.35	0.05	0.35	0.05	خطی	هیبروبولیک	۴-۳-۱	Rt, Rt-1, Rt-2, Mt
0.45	0.04	0.59	0.04	0.81	0.03	خطی	سیگموئید	۴-۱۰-۱	Rt, Rt-1, Rt-2, Mt
0.67	0.04	0.68	0.03	0.80	0.03	خطی	هیبروبولیک	۵-۷-۱	Rt, Rt-1, Rt-2, Mt, Mt-1
0.44	0.04	0.70	0.04	0.64	0.04	خطی	سیگموئید	۵-۳-۱	Rt, Rt-1, Rt-2, Mt, Mt-1
0.56	0.03	0.47	0.04	0.68	0.04	خطی	تازه‌تات هیبروبولیک	۵-۳-۱	Rt, Rt-1, Rt-2, Mt, Mt-1
0.64	0.04	0.57	0.03	0.64	0.04	خطی	سیگموئید	۵-۲-۱	Rt, Rt-1, Rt-2, Mt, Mt-1
0.28	0.05	0.26	0.07	0.46	0.05	خطی	تازه‌تات	۷-۷-۱	Rt, Rt-1, Rt-2, Rt-3, Rt-4, Rt-5, Mt
0.61	0.05	0.72	0.04	0.74	0.03	خطی	سیگموئید	۷-۱۴-۱	Rt, Rt-1, Rt-2, Rt-3, Rt-4, Rt-5, Mt

جدول ۴- بهترین مدل‌های شبیه‌سازی شده با ورودی باران، دما و آب معادل برف برای پیش‌بینی رواناب با استفاده از شبکه عصبی مصنوعی


رودی	ساختار شبکه	لایه ورودی	تابع انتقال	آموزش	صحت سنجی	آزمون				
CE (m ³ /s)	R ²	RMSE	R ²	RMSE	R ²	RMSE				
0.06	0.09	0.06	0.51	0.06	0.23	0.05	سیگموئید	۳-۴-۱	Rt, Rt-1, Rt-2	۱
0.30	0.53	0.05	0.44	0.05	0.49	0.04	سیگموئید	۸-۴-۱	Rt, Rt-1, Rt-2, Rt-3, Tt, Tt-1, Tt-2, Tt-3	۲
0.85	0.68	0.04	0.79	0.04	0.69	0.03	تازه‌تات هیبروبولیک	۴-۱۰-۱	Rt, Tt, Mt, Mt-1	۳
0.55	0.45	0.04	0.26	0.04	0.52	0.04	تازه‌تات هیبروبولیک	۲-۶-۱	Rt, Mt	۴

همچنین با مقایسه عملکرد مدل شماره ۳ که شامل ورودی باران، دما و آب معادل برف با یک روز تاخیر با ریشه میانگین مرreبعات خطای ۰.۰۴ و ضریب تبیین ۰.۶۸ نسبت به سایر مدل‌ها پیش‌بینی دقیق‌تری داشته‌اند که می‌توان نتیجه گرفت وارد کردن آب معادل برف به مدل‌ها باعث بهبود عملکرد مدل‌ها و افزایش دقت آن شده است که با نتایج توکار و جاهنسون (۲۹)، طبری و همکاران (۲۸) و فاخواه و همکاران (۳۰) مطابقت دارد. به طور کلی نتایج مدل شماره ۳ با ساختار ۱-۱-۴ با ۰.۰۹ نرون در لایه ورودی، ۱۰ نرون در لایه میانی و ۱ نرون در لایه خروجی


با توجه به جدول ۴ شبکه عصبی مصنوعی با ورودی باران و دما با سه روز تاخیر (مدل شماره ۲) با تابع انتقال سیگموئید با ریشه میانگین مرreبعات خطای ۰.۰۵ مترمکعب بر ثانیه و ضریب تعیین ۰.۵۳ در مرحله آزمون نسبت به مدل با ورودی باران با ۲ روز تاخیر (مدل شماره ۱) با استفاده از تابع انتقال سیگموئید با ریشه میانگین مرreبعات خطای ۰.۰۶ و ضریب تبیین ۰.۰۹ دارای عملکرد بهتری بوده که نتایج نشان‌دهنده آن است که دخالت دادن دما بهبود عملکرد مدل‌ها را به دنبال داشته که با نتایج لورایی و سچی (۱۶) و راگاآوانشی و همکاران (۲۳) هم‌خوانی دارد.

رضائی (۲۵) و شریفی و صالحی (۲۷)، طبری و همکاران (۲۸)، جهانگیر و همکاران (۱۳)، فرهمند و همکاران (۱۰)، زارع ابنيه و بيات وركشي (۳۱)، وفاخواه و همکاران (۳۰) و دستوراني و همکاران (۹) هم خوانی دارد. شکل ۳ نتایج دبی مشاهده‌ای و برآورده مدل شماره ۳ در مرحله آموزش، صحبت‌سنجدی و آزمون را نشان می‌دهد و شکل‌های ۴ تا ۷ نمودار پراکنش دبی مشاهده‌ای و برآورده مدل‌های شماره ۱ تا ۴ در مرحله آزمون نشان می‌دهند.


با ضریب کارایی ۰/۸۵ و ضریب تبیین ۰/۶۸ و ریشه میانگین مربعات خطای ۰/۰۴ نسبت به سایر مدل‌ها به عنوان بهترین مدل انتخاب گردید. نتایج این تحقیق با دیگر قابلیت‌های شبکه عصبی را در مدل‌سازی بارش-رواناب مورد تایید قرار داد که با نتایج تحقیقات لورائی و سچی (۱۶)، شمسدین (۲۶)، توکار و جوهانسون (۲۹)، کاستلانومندز و همکاران (۷)، براتی و همکاران (۴)، راگلوانشی و همکاران (۲۲)، باهاتاچاریا و سولوماتین (۵)، باره و همکاران (۳)، حسینی (۱۲)، میثاقی و محمدی (۱۷)، اکبرپور و همکاران (۱)، رادمان و همکاران (۲۲)




شکل ۳- مقایسه دبی مشاهده‌ای و برآورده با ورودی بارندگی، دما و آب معادل برف (مدل شماره ۳)




شکل ۴- نمودار پراکنش دبی مشاهده‌ای و برآورده با شبکه عصبی مصنوعی با ورودی بارندگی (مدل شماره ۱)



شکل ۵- نمودار پراکنش داده‌های دبی مشاهده‌ای و برآورده با شبکه عصبی مصنوعی با ورودی بارندگی و دما (مدل شماره ۲)



شکل ۶- نمودار پراکنش داده‌های دبی مشاهده‌ای و برآورده با شبکه عصبی مصنوعی با ورودی بارندگی و دما (مدل شماره ۳)



شکل ۷- نمودار پراکنش دبی مشاهده‌ای و برآورده با شبکه عصبی مصنوعی با ورودی بارندگی و آب معادل برف (مدل شماره ۴)

استفاده قرار می‌گیرند، در حالی که استفاده از این روش در مدل سازی پدیده بارش-رواناب در مراحل اولیه توسعه و تکامل خود بوده و امروزه به عنوان مبحثی مهم مدنظر محققین و پژوهشگران مرتبط با علوم آب قرار گرفته است (۲). تحقیق حاضر نیز در حوزه آبخیز لطیان که تحت تاثیر برف است صورت گرفته، امکان تخمین دقیق رواناب با استفاده از شبکه عصبی مصنوعی با دخالت دادن آب معادل برف مدنظر است. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی دارای کارآیی بالایی در شبیه‌سازی رواناب حاصل از ذوب برف بوده به طوری که تنها با استفاده از بارندگی و درجه حرارت می‌توان آن را شبیه‌سازی نمود ولی دخالت دادن ارتفاع آب معادل برف باعث افزایش کارآیی شبیه‌سازی شده و میزان خطا کاهش خواهد یافت. بهترین ساختار شبکه ساختاری با ۴ نرون در لایه ورودی، ۱۰ نرون در لایه میانی و ۱ نرون در لایه خروجی (۱۰-۱-۴) است. پیشنهاد می‌شود این تحقیق به خاطر لحاظ نمودن شرایط مختلف منطقه‌ای و جغرافیایی در مناطق دیگری تکرار و نتایج مورد آزمون قرار گیرد و از تصاویر ماهواره‌ی با قدرت تفکیک مکانی متفاوت در تحقیق حاضر استفاده شود.

تشکر و قدردانی

از جناب آقای دکتر حسین زینی‌وند و جناب آقای مهندس محسن جوربندی که با سخاوت و گشاده‌رویی از هیچ‌گونه یاری دریغ ننمودند، تشکر و قدردانی می‌شود.

کاربرد شبکه عصبی مصنوعی در پیش‌بینی رواناب ناشی از ذوب برف با توجه به شکل‌های ۴ تا ۷ مدل‌های ۱، ۲، ۳ و ۴ اولین حداکثر رواناب مشاهده‌ای (۳۸/۷ مترمکعب بر ثانیه) را به ترتیب به میزان ۷/۸۱ (۷۹/۸۲ درصد کمتر)، (۶۳/۵۲ درصد کمتر)، (۳۲/۲۷ (۱۶/۶۲ درصد کمتر)، (۱۵/۹۷ (۵۸/۷۴ درصد کمتر) مترمکعب بر ثانیه مدل‌های ۳ نسبت به بقیه مدل‌ها پیش‌بینی صحیح‌تری انجام داده‌اند. در ضمن دومین حداکثر رواناب مشاهده‌ای (۳۸/۱ مترمکعب بر ثانیه) را مدل‌های ۱، ۲، ۳ و ۴ به ترتیب به میزان ۱۱/۲۰ (۶۸/۴۸ درصد کمتر)، (۱۲/۰۱ (۷۰/۶۱ درصد کمتر)، (۳۹/۶۱ (۲۳/۰۱ درصد کمتر) مترمکعب بر ثانیه که با توجه به نتایج حاصله مشخص می‌گردد که مدل ۳ نسبت به بقیه مدل‌ها پیش‌بینی صحیح‌تری انجام داده است.

رابطه بارندگی-رواناب متاثر از پارامترهای اقلیمی و فیزیکی حوضه مانند تغییرات زمانی بارندگی، شبیب، ارتفاع، پوشش گیاهی، رطوبت خاک، آب زیرزمینی و... است. این موضوع باعث شده رابطه بارندگی-رواناب از حالت خطی خارج شده و به یک رابطه غیرخطی پیچیده تبدیل شود. مدل‌های فیزیکی زیادی برای ایجاد این رابطه توسعه پیدا کرده‌اند اما عدم وجود برخی پارامترهای مورد نیاز و ساده‌سازی برخی روابط باعث کاهش کارآمدی این مدل‌ها شده است (۲۰). توجه به تحقیقات صورت گرفته نشان می‌دهد، شبکه عصبی مصنوعی در شبیه‌سازی پدیده‌های مختلف هیدرولوژی به میزان زیادی مورد

منابع

1. Akbarpour, M., M.B. Rahnama and Gh.A. Barani. 2003. Comparsion of artificial neural network and HEC-HMS models on rainfall-runoff process. In Proceedings of 4th Iranian Hydraulic Conference, Shiraz University, Shiraz, 1025-1032. (In Persian)
2. Anctil, F., C. Michel, C. Perrin and V. Andreassian. 2004. A soil moisture index as an auxiliary ANN input for stream flow forecasting. Journal of Hydrology. 286: 155-167.
3. Baareh, A.K.M., A.F. Sheta and K. Al-khanifes. 2006. Forecasting river flow in the USA: a comparison between auto-regressive and neural network non-parametric models. Journal of Computer Science. 2(10): 775-780.
4. Baratti, R.B., A. Cannas Fanni, M. Pintus, G.M. Sechi and N. Toreno. 2003. River flow forecast for reservoir management through neural networks. Journal of Neurocomputing, 55: 421-437.
5. Bhattacharya, B. and D.P. Solomatine. 2000. Application of artificial neural network in stage- discharge relationship. In Proceedings of 4th International Conference on Hydroinformatics. Iowa City.USA.
6. Castellano-Mendez, M., W. Gonzalez-Mantciga, M. Febrero-Bande, J.M. Prado-Sanchez and R. Lozano-Calderon. 2004. Modeling of the monthly and daily behavior of the runoff of the Xallas River Basin using box-jenkins and neural networks methods. Journal of Hydrology, 296: 38-58.
7. 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.
8. Dastorani, M.T., H. Sharifidarami, A. Talebi and A.R. MoghadamNia. 2010. Evaluation of the application of artificial neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modeling in Zayandeh-rood dam basin, Iranian Journal of Water & Wastewater, 80: 114-125. (In Persian)
9. Deshmukh, R.P. and A.A. Ghatol. 2010. Short term flood forecasting using recurrent neural networks a comparative study. IACSIT International Journal of Engineering and Technology, 5: 430-434.
10. Farahmand, A.S., F. Golkar and M.V. Farahmand. 2011. Modeling of rainfall-runoff in a river basin using artificial neural network. In Proceedings of the First Conference of Applied Research of Water Resources. Kermanshah University of Technology, 141-147. (In Persian)

- ۵۳
11. Hall, D. K., G.A. Riggs and V.V. Salomonson. 2001. Algorithm theoretical basis document (ATBD) for the MODIS snow and sea ice mapping Algorithms, Available at: http://modis.gsfc.nasa.gov/data/atbd/atbd_mod10.pdf
 12. Hosseini, H. 1999. Artificial neural network model for determining flood hydrograph. M.Sc. Thesis in Civil Engineering. Iran University of Science and Technology. 103 pp. (In Persian)
 13. Jahangeer, A.R., M. Raeini and M.Z. Ahmadi. 2008. Comparison of artificial neural networks (ANNs) and HEC-HMS model for rainfall-runoff simulation in Kardeh Watershed. Journal of Water and Soil, 22: 72-84. (In Persian)
 14. Khan, S.M., P. Coulibaly and Y. Dibike. 2006. Uncertainty analysis of statistical downscaling methods. Journal of Hydrology, 319: 357-382.
 15. Klein, A.G., D.K. Hall and G.A. Seidel. 1998. Algorithm intercomparison for accuracy assessment of the MODIS snow-mapping algorithm. In Proceedings of 55th Annual Eastern Snow Conference. New Hampshire, June 2-3 Jackson.
 16. Kurtulus, B. and M. Razack. 2010. Modeling daily discharge responses of a large karstic aquifer using soft computing methods: artificial neural network and neuro-fuzzy. Journal of Hydrology, 381(1):101-111.
 17. Lorrai, M. and H.M. Sechi. 1995. Neural networks for modeling rainfall-runoff transformations, Water Resources Management, 9: 299-313.
 18. Mahmodian, A., H. Ghasemi, Gh. Hoshmand Fini and M. Sarmadi. 2009. Shemiran Township, Iranian Encyclopedia Foundation Press, 3rd Edition, Chapter 1, 330 pp.
 19. Mashayekhi, D. 1990. The use of snow hydrology for water resources. Office of Water Resources, Surface Water Section. (In Persian)
 20. Mosaedi, F. and K. Mohammadi. 2002. Simulation of rainfall-runoff and river routing using neural networks. In Proceedings of the Sixth International Conference on River Engineering. Ahvaz. 455-462. (In Persian)
 21. Nasri, M., R. Modarresand M.T. Dastorani. 2009. Application of artificial neural network for runoff estimation case study: Plajan Basin-Zayandehrud Watershed, Journal Quarterly Environment, 2: 23-37.
 22. Pustizadeh, N. and N. Najafi. 2011. Discharge prediction by comparing artificial neural network with fuzzy inference system (case study: Zayandehrud River).Iran-Water Resources Research, 7: 92-97. (In Persian)
 23. Radman, R.A., S.A. Mohammadi and E. Jabbari. 2004. Comparison of artificial neural network types to predict the river flow. In Proceedings of the First Annual Conference of Water Resources, Society of Sciences and Water Resources Engineering, Faculty of Tehran University. (In Persian)
 24. Raghuwanshi, N.S., R. Singh and L.S. Reddy. 2006. Runoff and sediment yield modeling using artificial neural networks: Upper Siwane River, India, Journal of Hydrologic Engineering, 11: 71-79.
 25. Rezaei, A. 2005. Peak discharge modeling using artificial neural network, In Proceeding of Second Watershed Management and Soil and Water Resource Conference, Shahid Bahonar University of Kerman, 2353-2343. (In Persian)
 26. Shamseldin, A.Y. 1997. Application of a neural network technique to rainfall-runoff modeling, Journal of Hydrology, 199: 272-294.
 27. Sharifi, M. and S. Salehi. 2006. Application of neural networks in forecasting river flows in Kardh watershed, Khorasan province. Regional Water Company Research Committee. Office of Applied Research and Technology of Iran. (In Persian)
 28. Tabari, H., P. Maroofi, H. Zare Abyaneh, R. Amiri Chayjan and M. Sharifi. 2008. Comparison of methods for the combination of artificial neural network estimation of snow water equivalent in the Samsami subbasins. In Proceeding of Third Conference on Water Resources of Iran, pp: 1-6. (In Persian)
 29. Tokar, A.S. and P.A. Johnson. 1999. Rainfall-runoff modeling using artificial neural networks, Journal of Hydrologic Engineering, 4: 232-239.
 30. Vafakhah, M., M. Mohseni Saravi, M. Mahdavi and S.K. Alavipanah. 2011. Snowmelt runoff prediction by using artificial neural network and adaptive neuro-fuzzy inference system in Taleghan Watershed. Iran-Watershed Management Science & Engineering 5: 23-35. (In Persian)
 31. Zare Abyaneh, H. and M. Bayat Varkeshi. 2011. Evaluation of artificial intelligent and empirical models in estimation of annual runoff. Journal of Water and Soil. 25: 365-379. (In Persian)
 32. Zeinivand, H. and F. De Smedt. 2009. Hydrological modeling of snow accumulation and melting on river basin scale, Water Resource Management. 23: 2271-2287.

Application of Artificial Neural Network for Snowmelt-Runoff (Case Study: Latyan Dam Watershed)

Fatemeh Sedighi¹, Mehdi Vafakhah² and Mohamad Reza Javadi³

1- PhD. Student, Tarbiat Modares University

2- Associate Professor, Tarbiat Modares University (Corresponding author: vafakhah@modares.ac.ir)

3- Assistant Professor, Islamic Azad University, Noor Branch

Received: January 30, 2013 Accepted: September 15, 2013

Abstract

Flood is one of the natural disaster phenomena and flood prediction is very important. The rainfall-runoff process and flood are physical phenomena that these analyses are difficult due to the influence of various parameters. There are different methods and models for these phenomena analysis. This study is carried out for rainfall-runoff process simulation using artificial neural network (ANN) involving snow water equivalent (SWE) in Latyan watershed located in Tehran province. For this reason, 92 images of MODIS were obtained during three years from 2003-2004 to 2006-2007 from the NASA site. Snow cover areas (SCAs) were extracted from each images and SWE were computed during these years. The rainfall, temperature and stream flow were available during these years. Multilayer perception networks with back propagation algorithm were used for finding the structure of the networks. Results showed that ANN with 4-10-1 structure, 4 neurons in input layer, 10 neurons in middle layer and 1 neuron in output layer, with performance coefficient of 0.85, determination coefficient of 0.68 and root mean squared error of 0.04 as the best structure had good precision in runoff estimation and SWE was caused to increase the accuracy of the model.

Keywords: Artificial neural network, Rainfall–runoff modeling, Snow water equivalent, Latyan watershed