

نشریه علمی- پژوهشی جغرافیا و برنامه‌ریزی، سال ۲۱، شماره ۶۲، زمستان ۱۳۹۶، صفحات ۱۳۷-۱۱۷

تاریخ دریافت: ۱۳۹۴/۱۱/۰۳

تاریخ پذیرش نهایی: ۱۳۹۵/۰۳/۲۲

برآورد رواناب حوضه بار اریه با استفاده از مدل‌های WetSpa و شبکه عصبی مصنوعی

حسین رحمتی^۱

صمد امامقلی زاده^۲

حسین انصاری^۳

چکیده

برآورد صحیح رواناب حوضه نقش بسیار مهمی در مدیریت آن دارد. تا به حال محققین زیادی از مدل‌های یکپارچه، توزیعی و همچنین از روش‌های هوشمند مصنوعی به منظور برآورد رواناب حوضه استفاده نمودند. در تحقیق حاضر برای برآورد آبدهی حوضه بار اریه با مساحتی معادل با ۱۱۲ کیلومتر مربع و متوسط بارش سالانه ۳۰۶/۷۲ میلی‌متر از دو مدل توزیعی WetSpa و مدل هوشمند شبکه عصبی مصنوعی ANN استفاده گردید. به منظور اجرای مدل WetSpa از دو دسته اطلاعات شامل نقشه‌های رستری و اطلاعات هواشناسی و برای مدل شبکه عصبی مصنوعی تنها از اطلاعات هواشناسی استفاده گردید. اجرای مدل‌های مذکور در دوره‌ی ۵ ساله صورت پذیرفت.

۱- دانشجوی دکتری رشته‌ی مهندسی آبیاری و زهکشی، دانشگاه شهید چمران اهواز، دانشکده مهندسی علوم آب.
Email: Hosein.rahmati86@gmail.com

۲- دانشیار رشته‌ی سازه‌های آبی، عضو هیئت علمی گروه آب و خاک دانشکده کشاورزی دانشگاه شاهرود (نویسنده مسئول)
Email: s_gholizadeh517@Shahroodut.ac.ir.

Email: ansary@um.ac.ir

۳. استاد گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد.

به‌منظور مقایسه نتایج مدل‌ها، از معیارهای ارزیابی ضریب همبستگی R^2 ، مجذور میانگین خطای استاندارد RMSE و میانگین قدر مطلق خطا MAE استفاده شد. نتایج بدست آمده نشان داد مدل WetSpa با R^2 و RMSE برابر با $0/920 \text{ m}^3/\text{s}$ و $0/346 \text{ m}^3/\text{s}$ و همچنین مدل شبکه عصبی مصنوعی با R^2 و RMSE برابر با $0/959 \text{ m}^3/\text{s}$ و $0/310 \text{ m}^3/\text{s}$ توانایی شبیه‌سازی جریان رودخانه بار اریه را دارند. همچنین استفاده از مدل شبکه عصبی مصنوعی موجب کاهش خطای برآورد رواناب حوضه به مقدار $11/6$ درصد در مقایسه با مدل WetSpa شده است.

واژگان کلیدی: حوضه بار اریه، رواناب، شبکه عصبی مصنوعی، مدل‌سازی، WetSpa.

مقدمه

محدودیت منابع آب در ابعاد مختلف از جمله تولید مواد غذایی، تولیدات صنعتی، آب شرب، محیط زیست و حتی ابعاد سیاسی و اجتماعی، مشکلات و مسائل متعددی را در آینده‌ای نه چندان دور ایجاد خواهد کرد. مهار آب‌های سطحی و زیرسطحی خصوصاً در کشور ما که در منطقه خشک و نیمه‌خشک کره زمین قرار گرفته است و همچنین شناسایی و به مدل درآوردن رفتار رودها و شریان‌های آبی جهت برنامه‌ریزی‌های بلند مدت و استفاده بهینه از پتانسیل‌های آنها امری لازم است (ضیایی، ۱۳۸۱: ۱۲). به همین دلیل شبیه‌سازی فرآیند بارش-رواناب در حوضه از نقطه نظر درک بهتر مسائل مدیریت منابع آب، مهندسی رودخانه، سازه‌های کنترل سیل و ذخیره سیلاب اهمیت ویژه‌ای دارد (گودرزی و همکاران، ۱۳۹۰: ۱۳۳؛ لاجوردی و همکاران، ۱۳۹۲: ۲۳۸). مدل‌های شبیه‌سازی حوضه به طور گسترده‌ای برای تحقیق بین مولفه‌های چرخه هیدرولوژی به کار می‌روند. پس از واسنجی مدل‌ها امکان ارزیابی اثرات تغییرات طبیعی یا تغییرات مدیریتی، زمانی که در حالت واقعی و مشاهده مستقیم امکان بررسی آن در حوضه وجود ندارد را برای ما فراهم می‌سازند. با استفاده از مدل‌های می‌توان طرح‌های مختلف را قبل از اجرا مورد ارزیابی قرار داده و از پیامدهای ناخواسته آن جلوگیری نمود. هرچند مدل‌های مفهومی با در نظر گرفتن فرآیندهای حاکم بر پدیده‌های مورد مطالعه، برای حوضه‌های بدون ایستگاه‌های اندازه‌گیری و تعیین اقدامات مدیریتی در حوضه مناسب هستند، از طرف دیگر با توجه به پیچیدگی‌های

حاکم بر حوضه واسنجی این گونه مدل‌ها دشوار و زمان‌بر بوده و همچنین تعیین دقیق برخی اطلاعات و ورودی‌های مورد نیاز مدل‌ها در بسیاری از موارد امری دشوار بوده و کاربر تنها قادر به تعیین حدودی از پارامترهای مورد نیاز مدل است که عدم قطعیت موجود در پارامترهای ورودی خود باعث ایجاد عدم قطعیت در نتایج خروجی مدل خواهد شد (شفیعی، ۱۳۸۸: ۷). مدل‌ها را می‌توان به دو گروه مدل‌های یکپارچه و توزیعی طبقه‌بندی کرد (رحمتی: ۱۳۹۲: ۳۰) در مدل‌های یکپارچه، توزیع مکانی در متغیرهای ورودی و پارامترها ورودی در نظر گرفته نمی‌شود، اما در مدل‌های توزیعی، تنوع مکانی برای هر یک از متغیرهای ورودی اندازه‌گیری یا برآورد می‌شود (Nurmohamed et al., 2006: 2). مدل‌های هیدرولوژیکی توزیعی به اطلاعات اندازه‌گیری شده فراوانی نیاز دارند و از آنجایی که در بسیاری از حوضه‌های ایران چنین اطلاعاتی وجود ندارد، کاربرد این مدل‌ها مشکل است. بنابراین در انتخاب مدل مناسب، باید به مولفه‌هایی مانند توزیعی یا یکپارچه بودن ساختار آن، ساده یا پیچیده بودن، در دسترس بودن یا نبودن اطلاعات و داده‌های مورد نیاز به عنوان ورودی مدل توجه داشت (رحمتی، ۱۳۹۲: ۳۰).

Bahremand et al. (2007: 1389) فرآیندهای هیدرولوژیکی حوضه توریسا واقع در اسلواکی را مورد بررسی قرار دادند. آنها با استفاده از این مدل و اطلاعات ۴۴ ایستگاه بارش، ۴ ایستگاه دما و ۱ ایستگاه تبخیر و تعرق، اقدام به شبیه‌سازی حوضه هورناد با مساحت 4264 Km^2 و میانگین بارش ۶۶۴ میلی‌متر نمودند. نتایج بدست آمده نشان داد، انطباق خوبی بین هیدروگراف شبیه‌سازی شده و مشاهده‌ای در زیرحوضه‌های اصلی و در خروجی حوضه وجود دارد. (Nurmohamed et al. (2006:15) توانایی مدل WetSpa را در شبیه‌سازی حوضه سورینام به مساحت 7860 Km^2 مورد بررسی قرار دادند. نتایج تحقیق آنها نشان دهنده توانایی بالای مدل در شبیه‌سازی فرآیندهای هیدرولوژیکی بود. Safari et al. (2012:78) مدل WetSpa را در پروژه‌ای با عنوان DMIP2^۴ در کشور آمریکا مورد استفاده قرار دادند. در آن تحقیق نقشه‌های شبکه‌بندی شده با ابعاد 30 m^2 و اطلاعات هواشناسی ساعتی مورد استفاده قرار گرفت. بعد از کالیبراسیون، در تمامی حوضه‌ها بجز

^۴-Distributed Model Intercomparison Project

حوضه رودخانه بلو، نتایج مدل در بازه خیلی خوب تا عالی متغیر بودند و هم‌چنین در دوره ارزیابی به نتایجی در محدوده خوب تا خیلی خوب دست یافتند که این مطلب حاکی از توانایی بالای مدل در شبیه‌سازی فرآیندهای هیدرولوژیکی است. Vansteenkiste et al. (2014:335) در پژوهشی پنج مدل NAM، PDM، VHM، WetSpa و MIKE SHE را مورد مقایسه قرار دادند. بعد از کالیبراسیون مدل‌ها بر اساس نتایج مشخص شد که تمامی مدل‌ها در تخمین رواناب و جریان‌های حداکثر دارای کارایی قابل قبولی هستند. Dams et al. (2015:1601) در تحقیقی به بررسی اثر تغییر اقلیم بر رواناب حوضه‌ای در بلژیک پرداختند. آن‌ها در این پژوهش دو مدل SWAT و WetSpa را مورد مقایسه قرار دادند و هم‌چنین به بررسی عدم قطعیت مدل‌ها و اطلاعات ورودی بر نتایج خروجی پرداختند. علاوه بر مدل‌های هیدرولوژیکی توزیعی و نیمه توزیعی، روشی که در سال‌های اخیر توسط محققین در مهندسی آب مورد توجه قرار گرفته است، استفاده از مدل‌های هوشمند مانند شبکه عصبی مصنوعی است. بررسی منابع نشان می‌دهد از این مدل برای برآورد بار معلق رسوبی به مخازن سد (Sahu et al., 2001: 438; Melesse et al., 2011: 855)، برآورد حجم رسوبات تخلیه شونده در رسوب‌شویی تحت فشار (Emamgholizadeh et al., 2013: 2551)، برآورد پارامترهای کیفی آب (Palani et al., 2008:1586)، برآورد آب‌سنگی پای پل (Batani et al., 2007: 401) مورد استفاده قرار گرفته است. هم‌چنین محققین مختلفی مانند Sivakumar et al. (2002: 225)؛ Kerh and Lee (2006: 533)؛ Wu (2001: 394)؛ Chua and Wong (2010: 92)؛ Dorum et al. (2009: 6587)؛ Zounemat-kermani et al. (2013: 4633)؛ Sahu et al. (2001: 438)؛ and Chau al (2013: 470) و Asadi et al. (2013: 470) از مدل شبکه عصبی مصنوعی با هدف شبیه‌سازی بارش-رواناب حوزه‌های آبخیز استفاده کردند. در مطالعه Kisi et al. (2013:115) مشخص گردید که مدل شبکه عصبی مصنوعی توانایی شبیه‌سازی بارش-رواناب حوضه‌های کوچک در کشور ترکیه را دارد. هم‌چنین Nourani et al. (2009: 2877) مدل شبکه عصبی مصنوعی را برای حوضه ليقوان چای شهر تبریز بکار بردند. نتایج اجرای


مدل ANN نشان داد مدل مذکور توانایی پیش‌بینی کوتاه مدت و بلند مدت رواناب حوضه را دارد.

در زمینه شبیه‌سازی فرآیندهای مختلف از جمله رواناب، رسوب و غیره اگرچه استفاده از مدل‌های توزیعی با در نظر گرفتن فرآیندهای حاکم بر پدیده‌های مورد مطالعه برای حوضه‌ها مناسب است ولی با توجه به پیچیدگی‌های حاکم بر حوضه، واسنجی این گونه مدل‌ها امری دشوار و زمان‌بر است؛ لذا اگر تنها هدف، شبیه‌سازی رواناب باشد روش‌های هوشمند با قابلیت بالا در مدل‌سازی مسائل غیرخطی می‌توانند جایگزین مناسبی برای مدل‌های نیمه توزیعی و توزیعی باشد و اما اگر علاوه بر شبیه‌سازی رواناب به دنبال شبیه‌سازی سایر اجزا چرخه هیدرولوژیک حوضه، مانند مولفه‌های بیلان، جریان زیرسطحی، جریان سطحی و جریان زیرزمینی باشیم استفاده از مدل‌های توزیعی و نیمه توزیعی اجتناب‌ناپذیر است و به همین منظور در این تحقیق توانایی دو مدل WetSpa و شبکه عصبی مصنوعی در مدل‌سازی بارش - رواناب حوضه بار اریه مورد بررسی قرار گرفت.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه رودخانه بار اریه با مساحت 112 Km^2 به عنوان یکی از زیرحوضه‌های، حوضه نیشابور است که در شمال شرق این شهرستان قرار گرفته است. رودخانه اصلی این حوضه از دامنه جنوب غربی سلسله جبال بینالود سرچشمه گرفته و پس از عبور از نیشابور به رودخانه کال سبزوار می‌پیوندد. این حوضه در محدوده‌ای بین طول جغرافیایی $05^{\circ} 21' 58''$ تا 06° شمالی و عرض جغرافیایی $18^{\circ} 20' 36''$ تا $18^{\circ} 29' 36''$ شمالی قرار دارد (شکل ۱).



شکل (۱) موقعیت جغرافیایی حوزه بار اریه

با بررسی آمار ایستگاه‌های هواشناسی و آب‌سنجی موجود در محدوده حوزه بار اریه و با توجه به هدف تحقیق و نیاز مدل به ورودی‌هایی با گام زمانی روزانه، پیوسته و هم‌زمان بودن سری زمانی، نهایتاً دوره زمانی ۱۳۸۲-۱۳۸۳ تا ۱۳۸۶-۱۳۸۷ انتخاب گردید. سپس ۳۶ ماه اول اطلاعات به ترتیب برای واسنجی و آموزش دو مدل WetSpa و شبکه عصبی مصنوعی و ۲۱ ماه آخر اطلاعات به منظور ارزیابی دو مدل انتخاب گردیدند.

مدل WetSpa

این مدل از جمله مدل‌های پیوسته و توزیعی بوده که با هدف پیش‌بینی انتقال آب و انرژی بین خاک، گیاهان و اتمسفر توسط (Wang et al. 1996:189) در دانشگاه بروکسل VUB در بلژیک کدنویسی شده و سپس De Smedt et al. (2000:303) توسط در سال ۲۰۰۰، Liu et al. (2004:1111) در سال ۲۰۰۳ و زینی‌وند (۲۰۰۹:۷) در سال ۲۰۰۹ توسعه پیدا کرده است. اطلاعات ورودی مدل در دوسته کلی نقشه‌های رستری که شامل نقشه رقوم ارتفاعی، بافت خاک و کاربری اراضی و اطلاعات هواشناسی شامل بارش، دما و تبخیر و تعرق تقسیم‌بندی می‌شوند و به منظور ارزیابی نتایج شبیه‌سازی از دبی واقعی اندازه‌گیری شده توسط ایستگاه آب‌سنجی بار اریه در خروجی حوضه استفاده می‌شود.

در مدل، رواناب سطحی با استفاده از روش ضریب رواناب مبتنی بر رطوبت خاک محاسبه می‌شود:

$$S = C_r P_n \frac{\theta}{\theta_s} \quad (1)$$

که در آن $S(L/T)$ رواناب سطحی، $P_n(L)$ بارش خالص که عبارت است از بارش منهای تلفات اولیه، $\theta \left[\frac{m^3}{m^3} \right]$ میانگین رطوبت خاک، $\theta_s \left[\frac{m^3}{m^3} \right]$ رطوبت خاک در حالت اشباع و C_r ضریب رواناب که بر اساس شیب، کاربری اراضی و بافت خاک بدست می‌آید.

جریان زیرسطحی بر اساس قانون دارسی و معادلات موج سینماتیکی بصورت زیر محاسبه می‌گردد (Bahremand, 2006: 1489):

$$F = \frac{C_f D S_0 K(\theta)}{W} \quad (2)$$

که در این رابطه $D[m]$ عمق ریشه، $S \left[\frac{m}{m} \right]$ شیب سطح، $K(\theta) \left[\frac{mm}{hr} \right]$ هدایت هیدرولیکی در حالت غیراشباع، $W[m]$ عرض سلول، $\theta \left[\frac{m^3}{m^3} \right]$ رطوبت خاک، C_f ضریبی که تابعی از بافت خاک و کاربری اراضی هستند.

مدل با استفاده از روش معادلات تقریب موج پخشی سنت و نانت روندیابی جریان سطحی و جریان آبراهه را انجام می‌دهد (Bahremand, 2006:150):

$$\frac{\partial Q}{\partial t} = D \frac{\partial^2 Q}{\partial X^2} - c \frac{\partial Q}{\partial X} \quad (3)$$

که در آن Q [m³/T] دبی، D [L²/T] ضریب میرایی موج، c [L/T] سرعت موج، X [L] مسافت طی شده و T [T] زمان می‌باشند.

در نهایت رواناب مستقیم در خروجی حوضه و یا در هر نقطه که جریان بهم می‌پیوندد از رابطه زیر محاسبه می‌گردد (Bahremand, 2006: 152):

$$Q(t) = \int_A \int_0^t V(\tau) U(T-\tau) d\tau dA \quad (4)$$


$Q(t)$ [L³/T] مقدار دبی خروجی، τ تاخیر زمانی و V [L³/T] حجم رواناب خروجی می‌باشند.

خروجی‌های اصلی مدل شامل هیدروگراف جریان‌های سطحی، زیرسطحی و جریان زیرزمینی برای خروجی حوضه و یا زیرحوضه‌ها، بیلان آبی و توزیع مکانی فرآیندهای هیدرولوژیکی است.

پس از معرفی اطلاعات مورد نیاز مدل WetSpa مانند باران، تبخیر و تعرق پتانسیل، دما و دبی، مدل اجرا گردید. در شروع عملیات بهینه‌سازی لازم است برای تمام پارامترهای بکار رفته در مدل مقادیر اولیه‌ای اختیار گردد، عملیات بهینه‌سازی با حصول بهترین تطبیق بین هیدروگراف‌های شبیه‌سازی شده و مشاهده‌ای به اتمام می‌رسد. به منظور واسنجی و ارزیابی مدل، اطلاعات مشاهده‌ای به دو گروه تقسیم شدند. از ۳۶ ماه اول اطلاعات برای واسنجی مدل و از ۲۱ ماه آخر برای ارزیابی مدل استفاده شد. در صورت قابل قبول بودن نتایج دوره ارزیابی، می‌توان نسبت به انتخاب صحیح پارامترهای ورودی اطمینان خاطر حاصل کرد.

مدل شبکه عصبی مصنوعی^۵

مدل شبکه عصبی مصنوعی که در واقع مدل ساده شده‌ای از مغز انسان است، اولین بار در سال ۱۹۴۳ معرفی شد (Mc Culloch, 1943: 115). از میان مدل‌های مختلف شبکه عصبی، شبکه عصبی پرسپترون چند لایه^۶ MLP یکی از متداول‌ترین مدل‌ها است که در تحقیق حاضر از آن استفاده شده است. این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آنها که مستقیماً به اطلاعات ورودی و نتایج خروجی متصل نیستند، تشکیل یافته‌اند (Demuth and Beale 1998) (شکل ۲). واحدهای لایه ورودی وظیفه توزیع مقادیر ورودی‌ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال‌های خروجی را ارائه می‌دهد. در این دولایه، تعداد نرون‌ها برابر با تعداد ورودی‌ها و خروجی‌ها است و لایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های ورودی به لایه‌های خروجی و به دست آوردن روابط خطی و غیرخطی را بر عهده دارند (Minasny and McBratney, 2002: 352) ساختار پرسپترون چند لایه به توابع غیرخطی نیاز دارد که به طور پیوسته مشتق‌پذیر باشد یا به عبارت دیگر هموار باشد (Asadi et al., 2013:476).



شکل (۲) ساختار شبکه عصبی مصنوعی پرسپترون چند لایه

الگوریتم پس انتشار^۷ که توسط رامتل هارتز و همکاران (Rumelhart et al., 1986) پیشنهاد شده است، یک الگوریتم بسیار رایج است که برای آموزش شبکه MLP مورد

⁵ - Artificial Neural Network(ANN)

⁶ - Multi-Layer Perceptron(MLP)

⁷ - Back-propagation

استفاده قرار می‌گیرد (Demuth and Beale, 1998; Fausett, 1994: 1998). الگوریتم پس انتشار شامل دو گام است. در گام اول محاسبات رو به سمت جلو بطرف لایه خروجی انجام شده و بعد از اینکه خطاها محاسبه شد، در گام دوم خطاهای لایه خروجی با انجام اصلاحات لازم با در نظر گرفتن وزن بر اساس رابطه زیر به سمت عقب انجام می‌شود:

$$\Delta w_{ij}(n) = -\varepsilon \times \frac{\partial E}{\partial w_{ij}} + \alpha \times \Delta w_{ij}(n-1) \quad (5)$$

که در آن $\Delta w_{ij}(n)$ و $\Delta w_{ij}(n-1)$ ترتیب افزایش وزن بین گره‌های i ام و j ام در خلال n امین و $n-1$ امین، E خطا، ε و α ضریب مومنتم و ضریب یادگیری بوده، که مقدار آنها بین ۰ تا ۱ می‌باشد. خروجی هر نرون توسط رابطه زیر تعریف می‌شود:

$$y = f(u) = f\left(\sum_{i=1}^n p_i W_{j,i} + b_j\right) \quad (6)$$

$W_{j,i}$ مقدار وزن اتصال بین نرون j ام لایه مذکور با نرون i ام لایه قبل است که بیانگر اهمیت ارتباط بین دو نرون در دو لایه متوالی است. b_j وزن مربوط به بایاس Bias برای نرون j ام، P_i مقدار خروجی از نرون i ام لایه قبل، a مقدار خروجی از نرون j ام، f تابع آستانه نرون j ام. از آنجاییکه در شبکه عصبی مصنوعی تابع انتقال، تعداد لایه‌های میانی و همچنین ترکیب داده‌های ورودی در یادگیری آن مؤثر هستند. در تحقیق حاضر برای اجرای مدل از ساختار یک لایه ورودی، یک تا چند لایه میانی و یک لایه خروجی با تابع‌های سیگموئید، گوس، تانژانت هیپربولیک و سکانت هیپربولیک استفاده گردید و سپس داده‌های مورد نظر بصورت ۳ گره ورودی شامل باران، تبخیر و تعرق پتانسیل، دما، ۳ گره میانی و ۱ گره خروجی شامل دبی در ایستگاه بار اریه به مدل معرفی گردیدند. همانند مدل WetSpa از ۳۶ ماه اول اطلاعات برای آموزش مدل و از ۲۱ ماه آخر اطلاعات برای صحت‌سنجی مدل استفاده شد.

معیارهای ارزیابی

به منظور ارزیابی عملکرد و کارایی مدل از پارامترهای آماری ضریب تبیین R^2 ، ریشه میانگین خطا استاندارد RMSE و متوسط قدر مطلق خطا MAE استفاده گردید:

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (8)$$

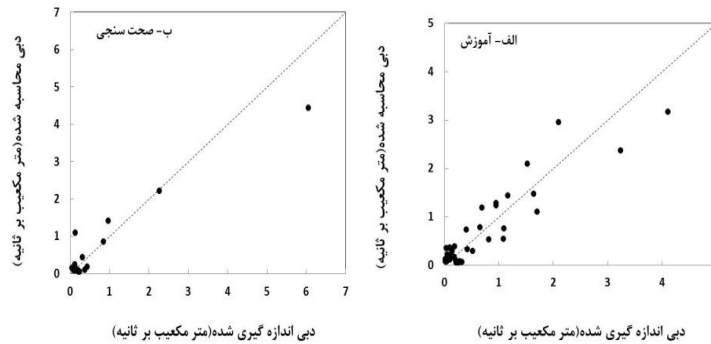
$$R^2 = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (9)$$

که در آن n تعداد داده‌ها، O_i داده‌های مشاهداتی، P_i داده‌های پیش‌بینی شده و علامت بار بیانگر متوسط متغیرها می‌باشد.

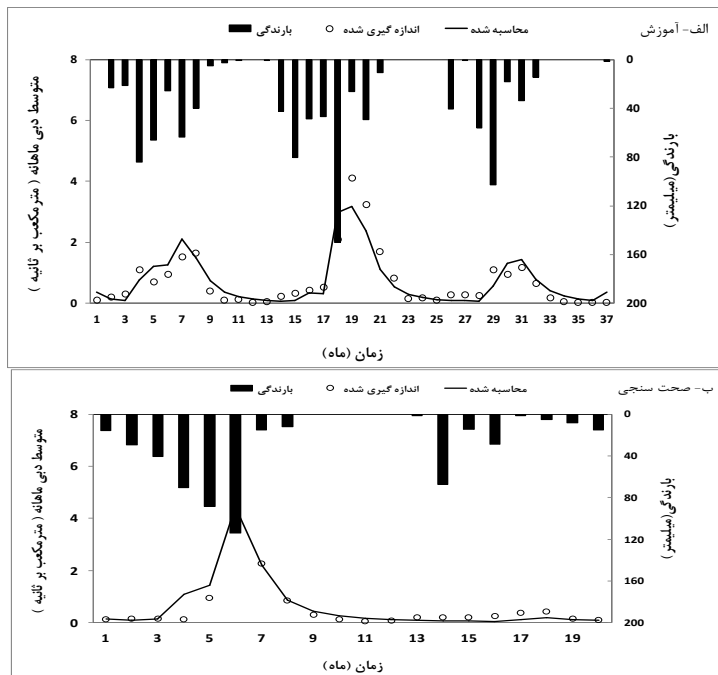
یافته‌ها و بحث

نتایج اجرای مدل WetSpa

نتایج اجرای مدل در شکل‌های ۳ و ۴ نشان داده شده است. هم‌چنین معیارهای آماری محاسبه شده در دو مرحله واسنجی و ارزیابی در جدول ۱ آمده است. همان‌طوریکه نتایج جدول ۱ نشان می‌دهد مدل WetSpa با داشتن ضریب همبستگی ۰/۸۳۶ و RMSE برابر ۰/۳۶۴ در مرحله واسنجی و هم‌چنین با داشتن ضریب همبستگی ۰/۹۲۰ و RMSE برابر ۰/۳۴۶ در مرحله ارزیابی دارای دقت خوبی در برآورد رواناب حوضه است (شکل‌های ۳ و ۴).



شکل (۳) پراکنش بین دبی‌های مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل Wetspa. الف - مرحله واسنجی، ب - مرحله صحت‌سنجی



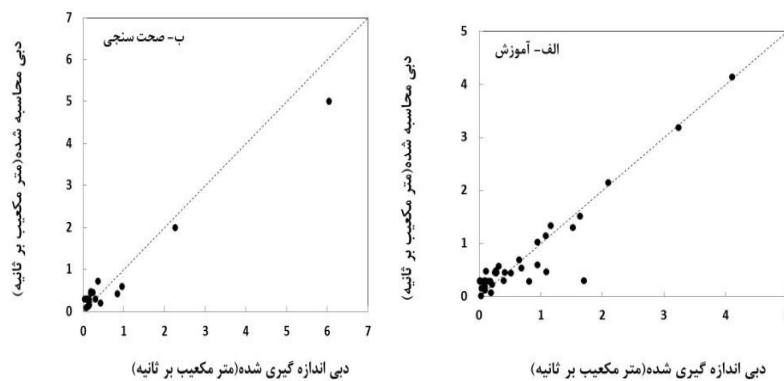
شکل (۴) سری زمانی دبی ماهانه مشاهده‌ای و شبیه‌سازی شده ایستگاه آب‌سنجی بار اریه با استفاده از مدل Wetspa الف - مرحله واسنجی، ب - مرحله صحت‌سنجی

نتایج اجرای مدل شبکه عصبی مصنوعی

نتایج اجرای مدل نشان می‌دهد زمانی که تابع انتقال تانژانت هیپربولیک با یک لایه میانی مورد استفاده قرار گرفت، بهترین نتیجه با ضریب همبستگی و RMSE برابر با ۰/۸۷۷ و ۰/۳۱۴ در مرحله آموزش، و هم‌چنین ۰/۹۵۹ و ۰/۳۱۰ در مرحله صحت‌سنجی بدست آمد. سایر معیارهای آماری بدست آمده در جدول ۱ آمده است. پراکنش بین دبی اندازه‌گیری شده و محاسبه شده و هم‌چنین سری زمانی دبی ماهانه شبیه‌سازی توسط مدل شبکه عصبی در دو مرحله آموزش و صحت‌سنجی به ترتیب در شکل‌های ۵ و ۶ نشان داده شده است.

جدول (۱) مقادیر معیارهای کارایی مدل در دوره واسنجی و آزمون

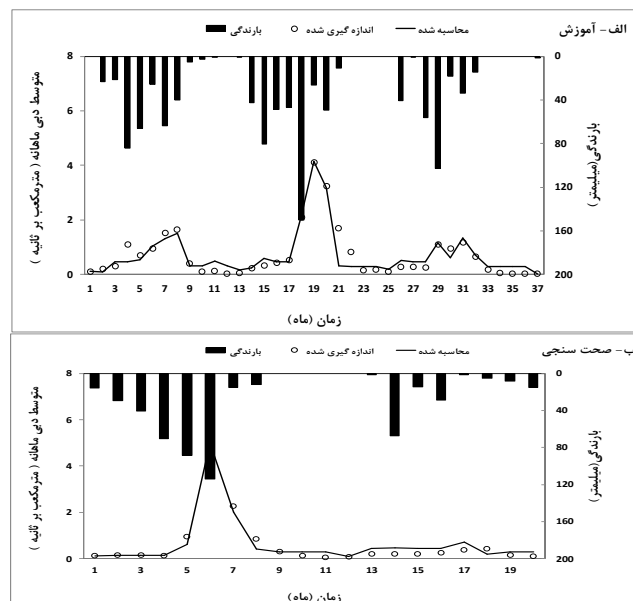
پارامترهای ارزیابی			دوره	نام مدل
MAE(m ³ /s)	RMSE(m ³ /s)	R ²		
۰/۲۸۳	۰/۳۶۴	۰/۸۳۶	آموزش	WetSpa
۰/۲۳۴	۰/۳۴۶	۰/۹۲۰	صحت سنجی	
۰/۲۲۲	۰/۳۱۴	۰/۸۷۷	آموزش	ANN
۰/۲۰۲	۰/۳۱۰	۰/۹۵۹	صحت سنجی	



شکل (۵) پراکنش بین دبی مشاهده‌ای و شبیه‌سازی شده با استفاده از مدل شبکه عصبی الف- مرحله آموزش، ب- مرحله صحت‌سنجی


مقایسه مدل ANN و WetSpa

به منظور بررسی توانایی مدل شبکه عصبی مصنوعی و مدل WetSpa از معیارهای آماری R^2 ، RMSE و MAE استفاده شد. نتایج بدست آمده از اجرای مدل در جدول ۱ برای دوره آموزش و صحت‌سنجی آورده شده است. همان‌طوریکه نتایج این جدول نشان می‌دهد هر دو مدل به خوبی توانسته‌اند رواناب حوضه را با ضریب همبستگی بیشتر از ۰/۸۳ پیش‌بینی کنند. اما مدل شبکه عصبی مصنوعی دارای دقت بالاتری نسبت به مدل WetSpa می‌باشد. هم‌چنین مقایسه دو مدل نشان می‌دهد دقت مدل ANN نسبت به مدل WetSpa در برآورد دبی‌های بالا بهتر بوده است. در مجموع مقایسه RMSE دو مدل مذکور نشان می‌دهد که مدل شبکه عصبی مصنوعی توانسته است مقدار خطا RMSE را ۱۱/۶ درصد کاهش دهد.



شکل (۶) سری زمانی دبی ماهانه مشاهده‌ای و شبیه‌سازی شده ایستگاه آب‌سنجی بار اریه با استفاده از مدل شبکه عصبی الف - مرحله آموزش و ب - مرحله صحت‌سنجی

هم‌چنین ضریب همبستگی از ۰/۹۲۰ به ۰/۹۵۹ در مرحله صحت‌سنجی افزایش یابد. در شکل ۷ خطای نسبی برآورد دبی با استفاده از مدل شبکه عصبی مصنوعی ANN/MLP و مدل WetSpa نشان داده شده است. همان‌طوریکه در شکل نشان داده شده است خطای نسبی مدل WetSpa بیشتر از مدل شبکه عصبی مصنوعی ANN/MLP است. با توجه به ساختار مدل WetSpa، استفاده از اطلاعات مکانی علاوه بر اطلاعات هواشناسی و فرآیند پیچیده واسنجی مدل این خطا قابل قبول بوده است.



شکل ۷) خطای نسبی برآورد دبی با استفاده از مدل شبکه عصبی مصنوعی (ANN/MLP) و مدل WetSpa

نتیجه‌گیری

با توجه به اهمیت برآورد و پیش‌بینی رواناب حاصل از بارندگی در حوضه‌های آبخیز بخصوص در ارتباط با مطالعات هیدرولوژیکی، هیدرولیکی، مدیریت منابع و آبخیزداری در این تحقیق سعی شده با مقایسه دو روش متفاوت به برآورد رواناب پرداخته شود. بدین منظور حوضه بار اریه واقع در استان خراسان رضوی که یکی از زیر حوضه‌های حوضه نیشابور است به صورت مطالعه موردی انتخاب گردید و با استفاده از دو مدل شبکه عصبی مصنوعی (ANN) و مدل WetSpa به شبیه‌سازی رواناب حوضه بار اریه پرداخته شد. همان‌طوری که نتایج اجرای مدل‌ها نشان می‌دهد (جدول ۱) هر دو مدل با داشتن ضریب

همبستگی بیشتر از ۰/۹۳ و ۰/۹۸ به ترتیب در مرحله واسنجی و صحت‌سنجی دارای توانایی شبیه‌سازی رواناب حوضه هستند. بنابراین به منظور شبیه‌سازی رواناب منطقه مورد مطالعه می‌توان از این مدل‌ها استفاده نمود. همچنین مقایسه نتایج شکل‌های ۴ و ۶ به ترتیب برای دو مدل مدل WetSpa و شبکه عصبی مصنوعی نشان می‌دهد دقت مدل شبکه عصبی مصنوعی نسبت مدل WetSpa به خصوص در سیلاب‌های بزرگتر، بهتر است. برای مثال مقایسه انجام شده در دبی‌های بزرگتر از ۲ مترمکعب در ثانیه نشان می‌دهد مقدار خطای نسبی مدل شبکه عصبی مصنوعی برابر با ۷ درصد بوده است ولی مقدار خطای نسبی مدل WetSpa برابر با ۲۳ درصد بوده است. به عبارتی، مدل ANN مقدار خطا را ۱۶ درصد در مقایسه با مدل WetSpa در دبی‌های بالا کاهش داده است. همچنین با توجه به اینکه پارامترهای مورد نیاز (پارامترهای هیدرولوژیکی و هواشناسی) برای اجرای مدل WetSpa بیشتر از مدل شبکه عصبی مصنوعی بوده و اندازه‌گیری آن‌ها هزینه‌بر و گاهی اوقات در برخی از حوضه‌ها ممکن است وجود نداشته باشد، بنابراین از این جهت به منظور شبیه‌سازی بارش-رواناب مدل شبکه عصبی مصنوعی نسبت به مدل WetSpa دارای برتری نسبی است.

منابع

- رحمتی، حسین (۱۳۹۲)، «مدل‌سازی بیلان سطحی توسط مدل WetSpa (مطالعه موردی حوضه بار اریه)». پایان‌نامه دوره ارشد، دانشکده کشاورزی، دانشگاه فردوسی. ۱۳۶ ص.
- شفیعی، مجتبی (۱۳۸۸)، «مدل‌سازی هیدرولوژیک بیلان آب‌های سطحی توسط مدل SWAT و سیستم‌های اطلاعات جغرافیایی (مطالعه موردی حوضه نیشابور)». پایان‌نامه دوره ارشد، دانشکده کشاورزی، دانشگاه فردوسی. ۱۰۸ ص.
- ضیایی، حجت‌اله (۱۳۸۱)، «اصول مهندسی آبخیزداری» چاپ دوم انتشارات دانشگاه امام رضا (ع).
- گودرزی، مسعود؛ جهانبخش اصل، سعید؛ رضائی بنفشه، مجید (۱۳۹۰)، «تهیه و بررسی منحنی‌های عمق-سطح-تداوم بارش در استان اصفهان»، *نشریه جغرافیا و برنامه‌ریزی تبریز*، شماره ۳۷، صص ۱۳۳-۱۴۹.
- لاجوردی، محمود؛ خالدی، شهریار؛ ستاری، شاپور (۱۳۹۲)، «پهنه‌بندی پتانسیل سیل‌خیزی حوضه آبریز مردق‌چای (آذربایجان شرقی)»، *نشریه جغرافیا و برنامه‌ریزی تبریز*، شماره ۴۴، صص ۲۳۷-۲۵۵.
- Asadi, S., Shahrabi, J., Abbaszadehb, P., Tabanmehr, S. (2013), New hybrid artificial neural networks for rainfall-runoff process modeling. *Neuro Computing*, 121: 470-480.
- Bahremand, A., De Smedt, F., Corluy, J., Liu, Y.B., Poorova, J., Velcicka, L. Kunikova, E. (2007), WetSpa model application for assessing reforestation impacts on floods in Margecany-Hornad watershed, Slovakia. *Journal of Water Resources Management*, 21: 1373-1391.
- Bahremand, A. (2006), *Simulating the effects of reforestation on floods using spatially distributed hydrologic modeling and GIS*. PhD Thesis, Vrije Universiteit Brussel, Belgium, p.186.

- Bahremand, A., Corluy, J., Y.B., Liu, Y.B., De Smedt, F. (2005), Stream flow simulation by WetSpa model in Hornad river basin, Slovakia. in: J. van Alphen, E. van Beek, M. Taal (eds.), **Floods, from Defence to Management**, Taylor & Francis Group, London, 67-74.
- Bateni SM, Borghei SM, Jeng DS. (2007), Neural network and neuro fuzzy assessments for scour depth around bridge piers. **Eng Appl Artif Intel**, 20: 401-414.
- Beven, K. J. (2000), **Rainfall-Runoff Modeling**. John Willey and Sons Ltd, England.
- Chua, L. H.C., and Wong, T. S.W. (2010), Improving event-based rainfall-runoff modeling using a combined artificial neural network-kinematic wave approach. **Journal of Hydrology**. 390: 92-107.
- Dams ,J., Nossent, J., Senbeta, T.B., Willems, P., Batelaan ,O. (2015), Multi-model approach to assess the impact of climate change on runoff. **Journal of Hydrology**. 529: 1601-1616.
- De Smedt, F., Liu, Y.B. and Gebremeskel, S. (2000), Hydrological modeling on a catchment scale using GIS and remote sensed land use information, in: C.A. Brebbia (ed.), **Risk Analysis II**, WTI press, Boston, 295-304.
- Demuth H., and Beale M. (1998), **Neural Network Toolbox for Use with MATLAB**.
- Dorum, A., Yazar, A., Sevimli, M.F., Onüçyildiz., M. (2010), Modelling the rainfall-runoff data of susurluk basin. **Expert Systems with Applications**, 37:6587-6593.
- Emamgholizadeh S, Bateni S.M, Jeng D.S. (2013), Artificial intelligence-based estimation of flushing half-cone geometry. **Eng Appli Arti Inte**, 126: 2551-2558.
- Fausett L. (1994), **Fundamentals of neural networks: architectures, algorithms, and applications**. Prentice-Hall, Englewood Cliffs, NJ.

- Kerh, T., and Lee, C.S. (2006), Neural networks forecasting of flood discharge at an unmeasured station using river upstream information Original, *Advances in Engineering Software*, 37: 533-543.
- Kisi, O., Shiri, J., and Tombul, M. (2013), Modeling rainfall-runoff process using soft computing techniques. *Computers & Geosciences*, 51: 108-117.
- Lippman, R.P., (1987), An Introduction to Computing with Neural Nets, IEEE ASSP Magazine.
- Haykin, S. (1999), *Neural network a comprehensive foundation*. Prentice-Hall, New Jersey.
- Liu, Y.B., De Smedt, F. (2004), WetSpa Extension, A GIS-based Hydrologic Model for Flood Prediction and Watershed Management. Department of Hydrology and Hydraulic Engineering Vrije Universiteit Brussel, p. 126.
- McClelland JL (eds) Parallel distributed processing. MIT Press, Cambridge, MA, pp 318-362.
- Mc Culloch WS, Pitts W. (1943), A logical calculus of the ideas imminent in nervous activity. *Bull Math Biophys*, 5: 115-133.
- Melesse, A. M., Ahmad, S., McClain, M. E., Wang, X., and Lim, Y. H. (2011), Suspended sediment load prediction of river systems: An artificial neural network approach. *Journal of Agricultural Water Management*, 98 : 855-866.
- Minasny B., and McBratney A.B. (2002), The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66: 352-361.
- Nourani, V., Komasi, M., Mano., A. (2009), A Multivariate ANN-Wavelet Approach for Rainfall-Runoff Modeling. *Water Resources Management*, 23: 2877-2894.
- Nurmohamed. R., Naipal. S., De Smedt, F. (2006), Hydrologic Modeling of the Upper Suriname. *Journal of Spatial Hydrology*, 1(6): 1-17.

- Palani S, Liong SY, Tkalich P. 2008. An ANN application for water quality forecasting. *Mar Pollut Bull*, 56: 1586–1597.
- Rumelhart DE, Hinton GE, Williams RJ. (1986), *Learning internal representation by error back propagation*. In: Rumelhart DE.
- Safari, A., De Smedt, F. Moreda, F. (2012). WetSpa model application in the distributed model intercomparison project (DMIP2). *Journal of Hydrology*, 418: 78-89.
- Sahu, M., Khatua, K.K., Mahapatra S.S. (2011), A neural network approach for prediction of discharge in straight compound open channel flow Original , *Flow Measurement and Instrumentation*, 22: 438-446.
- Sivakumar, B., Jayawardena, A.W. Fernando, T.M.K.G. (2002), River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches Original Research Article. *Journal of Hydrology*, 265: 225-245.
- Vafakhah, M. (2012). Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting. *Journal of Arab J Geosci*. DOI 10.1007/s12517-012-0550-5.
- Vansteenkiste, T., Tavakoli, M., Steenbergen, N. V., De Smedt, F., Batelaan, O., Pereira, F., Willems. (2014), Intercomparison of five lumped and distributed models for catchment runoff and extreme flow simulation. *Journal of Hydrology*, 511: 335-342.
- Wang, Z., Batelaan, O, and De Smedt, F. (1996), A distributed model for water and energy transfer between soil, plants and atmosphere (WetSpa). *Journal of Physics and Chemistry of the Earth*, 21: 189–193.
- Wasserman, P.D. (1989), *Neural computing: theory and practice*. Van Nostrand Reinhold, New York.
- Wu, C.L., and Chau, K.W. (2011), Rainfall–runoff modeling using artificial neural network coupled with singular spectrum analysis. *Journal of Hydrology*, 399: 394–409.

- Zeinivand. H. 2009. *Development of spatially distributed hydrological WetSpa modules for snowmelt, soil erosion, and sediment transport*. PhD Thesis, Department of Hydrology and Hydraulic Engineering, Vrije Universiteit Brussel (VUB), Brussels, Belgium, p. 234.
- Zounemat-kermani, M., Kisi, O., Rajaei, T. (2013), Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff Original, *Applied Soft Computing*, 13: 4633-4644.