



"مقاله پژوهشی"

ارزیابی کارایی مدل هیدرولوژیکی IHACRES و شبکه عصبی مصنوعی به منظور پیش‌بینی جریان در رودخانه بختیاری

مرتضی چوبین^۱ و محمد بشیر گنبد^۲

۱- عضو هیئت علمی دانشکده فنی، دانشگاه ملایر، (نویسنده مسوول: m.chobin@edu.ikau.ac.ir)

۲- عضو هیئت علمی دانشکده منابع طبیعی و محیط‌زیست، دانشگاه ملایر

تاریخ دریافت: ۱۴۰۱/۶/۲۳ تاریخ پذیرش: ۱۴۰۱/۸/۱۷

صفحه: ۱۱۵ تا ۱۲۲

چکیده مبسوط

مقدمه و هدف: در سال‌های اخیر پیش‌بینی جریان در رودخانه یکی از مسائل مهم و مورد توجه برای مدیریت منابع آب در ایران است. این پیش‌بینی نیازمند آمار و اطلاعات است که متأسفانه اغلب حوضه‌های کشور فاقد داده‌های با کمیت و کیفیت مورد نظر می‌باشند. مدل‌سازی هیدرولوژیکی و استفاده از هوش مصنوعی از نمونه راهکارهایی است که برای برطرف کردن چالش عدم کفایت و عدم وجود داده‌های با کیفیت مناسب در هیدرولوژی مورد استفاده قرار می‌گیرد. معیار انتخاب مدل مناسب برای این فرایند، ارزیابی عملکرد مدل‌ها با توجه به شرایط هیدرولوژیکی هر منطقه است.

مواد و روش‌ها: مدل‌های زیادی برای پیش‌بینی جریان رودخانه مورد استفاده قرار می‌گیرند. در این تحقیق از مدل بارش-رواناب IHACRES و شبکه عصبی مصنوعی به‌عنوان مدل داده محور برای پیش‌بینی جریان، در رودخانه بختیاری استفاده شد. از داده‌های سال‌های ۱۹۸۴ تا ۱۹۹۴ به‌عنوان داده‌های مرحله واسنجی و از داده‌های سال‌های ۱۹۹۵ تا ۲۰۰۶ برای صحت‌سنجی مدل هیدرولوژیکی استفاده شد. همچنین از شبکه Dence با تعداد نرون‌های ۱۰، ۲۰، ۵۰ و ۱۰۰ استفاده شد. معیار بهینه‌سازی Adam برای بهبود روند آموزش در نظر گرفته شد و تابع خطای استفاده‌شده MSE است و تابع فعال‌ساز به علت پیوسته بودن داده‌ها sgmoid انتخاب شد.

یافته‌ها: نتایج ارزیابی مدل هیدرولوژیکی و شبکه عصبی مصنوعی با استفاده از شاخص‌های کلینگ-گوپتا، نش-سانکلیف، ضریب تعیین، میانگین مربعات خطا و میانگین مطلق مورد بررسی قرار گرفت و نتایج نشان داد شبکه عصبی مصنوعی در کلیه معیارهای ارزیابی، نتایج بهتری در شبیه‌سازی جریان روزانه نسبت به مدل هیدرولوژیکی دارد. مقادیر معیارهای ارزیابی کلینگ-گوپتا، نش-سانکلیف، ضریب تعیین، میانگین مربعات خطا، میانگین مطلق خطا در مرحله صحت‌سنجی به ترتیب برای مدل هیدرولوژیکی و شبکه عصبی مصنوعی ۰/۷۴، ۰/۷۵، ۰/۷۷، ۰/۱۲۵، ۰/۱۷ و ۰/۹۴، ۰/۸۹، ۰/۸۹، ۰/۵۷، ۰/۲۶ محاسبه شد.

نتیجه‌گیری: بر اساس نتایج روش‌های مورد استفاده در تحقیق روش شبکه عصبی مصنوعی نسبت به مدل هیدرولوژیکی IHACRES پیش‌بینی دقیق‌تری از جریان روزانه رودخانه بختیاری دارد. توانایی قابل قبول شبکه عصبی در شبیه‌سازی جریان‌های اوج علاوه بر شبیه‌سازی جریان روزانه از نتایج قابل توجه این تحقیق است.

واژه‌های کلیدی: بارش-رواناب، حوضه بختیاری، شبیه‌سازی جریان، مدل‌های داده محور

مقدمه

آگاهی از میزان آب در دسترس در طی یک دوره بلندمدت در یک منطقه از الزامات برنامه‌ریزی و تأمین آب در یک منطقه به شمار می‌آید. به همین دلیل فراهم‌سازی یک مدل که بتواند پیش‌بینی‌های بلندمدتی را در اختیار کارشناسان قرار دهد ضروری به نظر می‌رسد (۲۶). مدل‌هایی که برای این نوع پیش‌بینی‌ها مورد استفاده قرار می‌گیرند در حال حاضر به دو دسته مدل‌های بارش رواناب و مدل‌های داده محور تقسیم‌بندی می‌شوند. مدل‌های بارش رواناب به فاکتورهای متعددی برای شبیه‌سازی نیاز دارند که در تعداد زیادی از این مدل‌ها وجود داده‌هایی نظیر مقدار بارش، میزان رواناب، تبخیر و تعرق، میزان رطوبت خاک، میزان نفوذ و سطح برف و مقدار ذوب آن ضروری است. مدل‌های مفهومی بارش رواناب از جمله این مدل‌ها هستند که سعی شده ساختار آن‌ها طوری برنامه‌ریزی شود که در عین سادگی و با استفاده از حداقل اطلاعات ورودی با دقت قابل قبولی پیش‌بینی را انجام دهد (۲۷،۲۸). یکی از مدل‌هایی که در این زمینه کاربرد زیادی داشته و با معادلات ساختاری خودپاسخ‌های قابل قبولی در شرایط شبیه‌سازی جریان خروجی حوضه داشته است مدل IHACRES^۱ است. بارش رواناب دارای اشکالاتی برای شبیه‌سازی دقیق رفتار جریان هستند که ناشی از روابط پیچیده بین اجزای مختلف پارامترهای ورودی است که کمبود

داده‌های هیدرولوژیکی تکمیل فرایند مدل‌سازی را دچار مشکل می‌کند (۲۱).

دسته دیگر روش‌های مورد استفاده برای پیش‌بینی جریان، مدل‌های داده محور هستند که روش‌های نوینی در علوم مهندسی است. از میان روش‌های متفاوت داده محور یکی از روش‌های پرکاربرد برای شبیه‌سازی جریان رودخانه روش شبکه عصبی مصنوعی است که با استفاده از توابع تعریف‌شده ریاضی رفتار درون‌سولوی مغز را شبیه‌سازی می‌کند و با وزن‌های محاسباتی موجود در راه‌های ارتباطی نرون‌ها، عملکرد سیناپسی را در نرون‌های طبیعی به شکل مدل در آورد. ماهیت تجربی و قابل‌انعطاف این روش باعث می‌شود تا در مسائلی مانند بحث پیش‌بینی که روش‌های متفاوتی برای آن وجود دارد به‌خوبی قابل استفاده باشد (۲۴، ۲۰، ۱۸). در روش‌های داده محور تنها از سری زمانی داده‌های ثبت‌شده برای پیش‌بینی جریان استفاده می‌شود (۵). در این تحقیق با استفاده از یک مدل بارش رواناب و روش شبکه عصبی مصنوعی جریان روزانه در رودخانه بختیاری مورد بررسی قرار گرفت تا کارایی نسبی آن‌ها بررسی شود. در سال‌های اخیر تحقیقات زیادی در زمینه کاربرد روش‌های مختلف در شبیه‌سازی رواناب انجام گرفته است. کریپپور و همکاران (۱۶) با مقایسه مدل IHACRES و شبکه عصبی مصنوعی در رودخانه سیوند فارس به این نتیجه رسیدند که شبکه


متحده آمریکا استفاده کردند. نتایج نشان داد که شبکه عصبی مصنوعی برای شرایط مختلفی از قبیل مقیاس حوضه، توپوگرافی‌های متفاوت و الگوهای آب و هوایی روش قدرتمندی در شبیه‌سازی است.

یکی دلایل اصلی شکست برنامه‌های مدیریت منابع آب ناشی از عدم آگاهی از پاسخ صحیح حوضه به تغییرات رژیم آب رودخانه‌ها است. خشکسالی‌های چند سال اخیر بخصوص در سال‌های ۱۳۷۰-۱۳۸۰ نیز لزوم آگاهی از وضعیت منابع آب‌های سطحی را دو چندان کرده است. به همین دلیل استفاده از روشی که بتواند معیار درستی برای شبیه‌سازی رفتار هیدرولوژیکی رودخانه‌ها باشد ضروری به نظر می‌رسد. لذا در این پژوهش عملکرد یک مدل هیدرولوژیکی و یک مدل داده‌منا جهت پیش‌بینی جریان در رودخانه بختیاری ارزیابی شد.

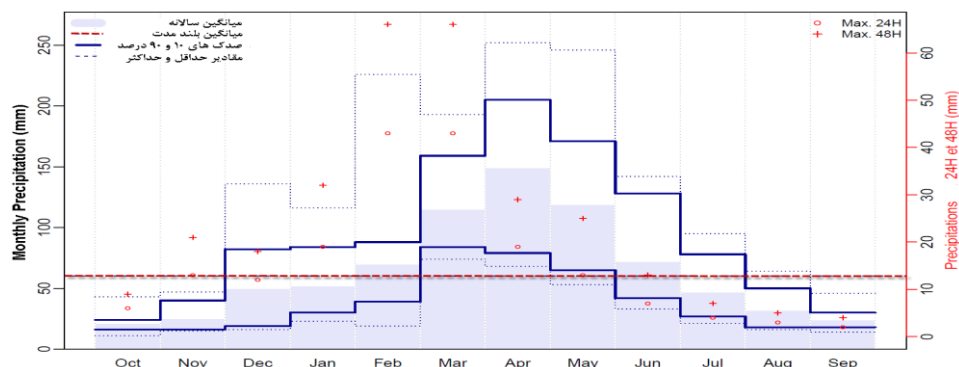
مواد و روش‌ها منطقه مورد مطالعه

حوزه آبخیز رودخانه بختیاری با ارتفاع متوسط ۲۲۹۵ متر از سطح دریا و میانگین بارش سالانه ۷۶۴ میلی‌متر در سال و میانگین حداکثر دمای سردترین ماه سال ۱۰/۲۸ و گرم‌ترین ماه سال ۳۸/۴۳ در جنوب غرب کشور و در محدوده مختصات جغرافیایی ۱۵-۴۸° تا ۲۰-۵۰° طول شرقی و ۳۰-۳۳° الی ۳۰-۳۳° عرض شمالی و در محدوده استان‌های چهارمحال و بختیاری، اصفهان، لرستان و خوزستان با مساحت ۶۳۹۰ کیلومترمربع قرار گرفته است. میانگین رواناب سالانه این حوضه ۷۱۰ میلی‌متر و حداکثر جریان مشاهده‌شده در رودخانه بختیاری مربوط به اردیبهشت ماه است. بیشترین درصد مساحت مربوط به کاربری اراضی در این حوضه، مرتع با درصد مساحت ۵۳ درصد و انواع جنگل با مساحت ۳۴/۶ درصد است. این حوضه در بالادست حوزه آبخیز رودخانه دز واقع شده که حوزه آبخیز دز نیز در تقسیم‌بندی حوضه‌های کشور جزو حوزه آبخیز کارون بزرگ محسوب می‌شود (۴). موقعیت و رژیم بارش ماهانه حوضه مورد مطالعه در شکل‌های (۱ و ۲) ارائه شده است.

عصبی دینامیک با ضریب تبیین ۰/۸۸ و ۰/۹۴ در دوره واسنجی و صحت‌سنجی نتایج قابل قبول‌تری را نسبت به مدل بارش رواناب ارائه می‌کند. احمد پور و همکاران (۱) نسبت به ارزیابی مدل مفهومی IHACRES و مدل هیبریدی ARIMA-ANN برای پیش‌بینی جریان روزانه در حوضه مارون با استفاده از داده‌های سال‌های ۱۳۷۰-۱۳۸۵ اقدام نمودند. نتایج بررسی معیارهای ارزیابی عملکرد مدل، حاکی از برتری نسبی مدل هیبریدی ARMA-ANN نسبت به سایر مدل‌های مورد استفاده در این پژوهش دارد. به طوری که مدل ARMA-ANN بیشترین مقادیر عددی ضریب تبیین ۰/۸۶ و ضریب نش-ساتکلیف ۰/۸۱ به خود اختصاص داده است. این مطلب نشان‌دهنده توانایی و عملکرد مدل هیبریدی-ARMA-ANN در شبیه‌سازی و پیش‌بینی جریان روزانه حوضه مارون در مقایسه با سایر مدل‌ها است. مدرسی و همکاران (۱۹) در پژوهشی نسبت به ارزیابی سه روش مدل‌سازی داده مینا شبکه عصبی مصنوعی، شبکه عصبی رگرسیون تعمیم‌یافته و k نزدیک‌ترین همسایگی در مقایسه به مدل مفهومی IHACRES در حوضه کرخه پرداختند. استفاده از ۳۲ سال آمار دما، بارش و جریان ورودی به سد کرخه در مقیاس ماهانه به‌عنوان ورودی مدل و معیارهای ارزیابی نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) حاکی از برتری روش شبکه عصبی مصنوعی نسبت به سایر روش‌ها در پیش‌بینی جریان رودخانه دارد. قربانی و همکاران (۱۱) در مقایسه روش‌های مختلف هوش مصنوعی با روش ماشین بردار پشتیبان در شبیه‌سازی فرایند بارش رواناب با استفاده از سری ماهانه رواناب رودخانه سیمینه‌رود در دوره آماری ۱۳۷۷-۱۳۹۰ به این نتیجه دست یافتند که چهار مدل به کار گرفته‌شده در تحقیق نتایج قابل قبولی را با در نظر گرفتن معیار ارزیابی ضریب همبستگی، ریشه میانگین مربع خطا و ضریب نش-ساتکلیف دارد و مدل برنامه‌ریزی بیان ژن با بیشترین ضریب همبستگی مناسب‌ترین روش به حساب می‌آید. توکار و مارکوس (۲۵) از مدل مفهومی IHACRES و شبکه عصبی مصنوعی برای شبیه‌سازی جریان رودخانه در سه منطقه مختلف در ایالات



شکل ۱- موقعیت منطقه مورد مطالعه در ایران و حوضه کارون بزرگ
Figure 1. Bakhtiari watershed location in Iran and Karoon catchment




شکل ۲- رژیم ماهانه بارش در منطقه مورد مطالعه (۱۹۸۴-۲۰۰۶)
Figure 2. Precipitation Regime in Bakhtiary watershed (2006-1984)

انتخاب پایه زمانی مشترک در پارامترهای ورودی سبب شد بازه زمانی سال‌های ۱۹۸۴-۲۰۰۶ به‌عنوان بازه زمانی شبیه‌سازی انتخاب شود. سپس با روش چند ضلعی‌های تیسن مقدار متوسط بارش منطقه محاسبه و در مدل هیدرولوژیکی استفاده شد. جدول (۱) نام و مشخصات مربوط به هر یک از ایستگاه‌ها را نشان می‌دهد. به‌منظور واسنجی و صحت‌سنجی مدل هیدرولوژیکی از داده‌های دبی مشاهده‌ای روزانه ایستگاه تنگ پنج بختیاری که در خروجی حوضه واقع شده استفاده شد. سری زمانی داده‌های مورد استفاده در شکل (۳) آمده است.

داده‌های مورد استفاده

در این تحقیق به‌منظور ارزیابی کارایی مدل هیدرولوژیکی IHACRES و شبکه عصبی مصنوعی در پیش‌بینی جریان در حوزه آبخیز رودخانه بختیاری به‌دلیل وسعت حوضه و تغییرات شدید توپوگرافی آن از داده‌های بارش روزانه مربوط به ۱۶ ایستگاه هواشناسی منتخب در داخل و اطراف حوضه مورد مطالعه در طی سال‌های ۱۹۸۴-۲۰۰۶ انتخاب شد. به دلیل اینکه برخی ایستگاه‌های هواشناسی متعلق به وزارت نیرو در سال‌های بعد از ۲۰۰۶ فاقد داده‌های بارش یا دما بوده و همچنین ایستگاه هیدرومتری نصب شده در خروجی حوضه در سال ۲۰۰۸ فاقد داده‌های ثبت شده است از اینرو



شکل ۳- سری زمانی داده‌های مشاهده‌ای ارتفاع رواناب، بارش و دما در منطقه مورد مطالعه
Figure 3. Run-off height, Precipitation and Temperature time series in Bakhtiary watershed

جدول ۱- مشخصات ایستگاه‌های هواشناسی مورد استفاده در منطقه مورد مطالعه

Table 1. Specifications of meteorological stations used in Bakhtiary watershed						
سال‌های آماری Statistical Year	ارتفاع از سطح دریا (متر) Altitude (MASL)	عرض جغرافیایی Latitude	طول جغرافیایی Longitude	نام ایستگاه Station Name	متولی ایستگاه Station Manager	کد ایستگاه Station ID
47	770	33.13	48.61	Keshvar	Ministry of Power	21289
46	970	33.21	48.88	Sepiddasht Zaz	Ministry of Power	21285
46	540	32.93	48.76	Tang-e Panj	Ministry of Power	21293
46	1930	33.30	49.41	Kamandan	Ministry of Power	21273
33	2000	33.15	49.66	Kazem Abad	Ministry of Power	21400
32	1750	33.08	49.60	Sokaneh	Ministry of Power	21968
31	2392	33.01	49.80	Zardfahre	Ministry of Power	21402
28	1712	33.36	49.94	Abtoriki	Ministry of Power	21435
66	1147	33.43	48.28	Khoramabad	Meteorological Org	40782
31	2022	33.40	49.7	Aligoodarz	Meteorological Org	40783
22	1870	33.47	50.28	Golpaygan	Meteorological Org	99417
25	2290	32.97	50.37	Daran	Meteorological Org	40787
58	2048	32.28	50.85	ShahreCORD	Meteorological Org	40798
21	767	31.85	49.87	Izeh	Meteorological Org	99455
32	320.5	31.93	49.28	Masjed Soleyman	Meteorological Org	40812
51	143	32.4	48.38	Dezfol Airport	Meteorological Org	40795

مدل هیدرولوژیکی IHACRES

این مدل یک مدل بارش _ رواناب مفهومی است که توسط جکمن و هورنبرگ (۱۹۹۳) برای اولین بار ارائه شد (۱۵). این مدل از دو مدول غیرخطی کاهش و مدول خطی هیدروگراف تشکیل شده است. به این منظور در ابتدا بارندگی (r_k) و دما (t_k) در هر گام زمانی (K) توسط مدول غیرخطی به بارندگی مؤثر (u_k) تبدیل شده و سپس به وسیله مدول خطی هیدروگراف واحد به رواناب سطحی در همان گام زمانی تبدیل می‌شود (۱۲).

$$U_k = [C(\varphi_k - l)]^p r_k \quad (1)$$

که در آن C : ضریب تعادل حجم بارش، l آستانه شاخص رطوبت خاک، p : عامل واکنش غیرخطی و r_k : بارش مشاهداتی است. φ_k : شاخص رطوبت خاک که با استفاده از رابطه (۲) ارائه شد.

$$\varphi_k = r_k + \left(1 - \frac{1}{\tau_\omega}\right) \varphi_{k-1} \quad (2)$$

$$\tau_{\omega(t_k)} = \tau_\omega^0 \cdot \exp[(20 - t_k)/f] \quad (3)$$

در رابطه (۲) τ_ω : ثابت زمانی تلفات حوزه آبخیز بر اساس t_k دمای روزانه (سلسیوس) مطابق رابطه (۳) است. در مدل خطی، تبدیل بارش مؤثر به رواناب با استفاده از روابط خطی محاسبه می‌شود. دو مؤلفه در روندیابی جریان سریع و کند وجود دارد. این دو مؤلفه در روندیابی جریان سریع و آهسته وجود دارد. این دو مؤلفه می‌توانند به صورت موازی و یا سری متصل باشند. در مطالعات انجام شده توصیه شده است فرایند به صورت موازی استفاده شود به جز در مناطق نیمه خشک و یا مناطقی که دارای جریان پایه فصلی هستند (۱۴، ۹). ترکیب مؤلفه‌های جریان سریع X_k^q و آهسته X_k^s منجر به تولید رواناب X می‌شود که طبق روابط زیر محاسبه می‌شوند.

$$X_k = X_k^q + X_k^s \quad (4)$$

$$X_k^{(s)} = -\alpha_s X_{k-1}^{(s)} + \beta_s u_k \quad (5)$$

$$X_k^{(q)} = -\alpha_q X_{k-1}^{(q)} + \beta_q u_k \quad (6)$$

که α_q و β_q : پارامترهای ثابت زمانی برای جریان سریع و α_s و β_s : پارامترهای ثابت زمانی برای جریان آهسته هستند. محاسبه پاسخ دینامیک هیدروگراف واحد برای جریان سریع و آهسته در روابط زیر ارائه شده است.

$$\tau_q = \frac{-\Delta}{\ln(-\alpha_q)} \quad (7)$$

$$\tau_s = \frac{-\Delta}{\ln(-\alpha_s)} \quad (8)$$

که در آن Δ : بازه زمانی، τ_s و τ_q : ثابت زمانی افت

جریان‌های روزانه سریع و آهسته است. حجم نسبی جریان سریع جریان آهسته با استفاده از رابطه زیر محاسبه می‌شود.

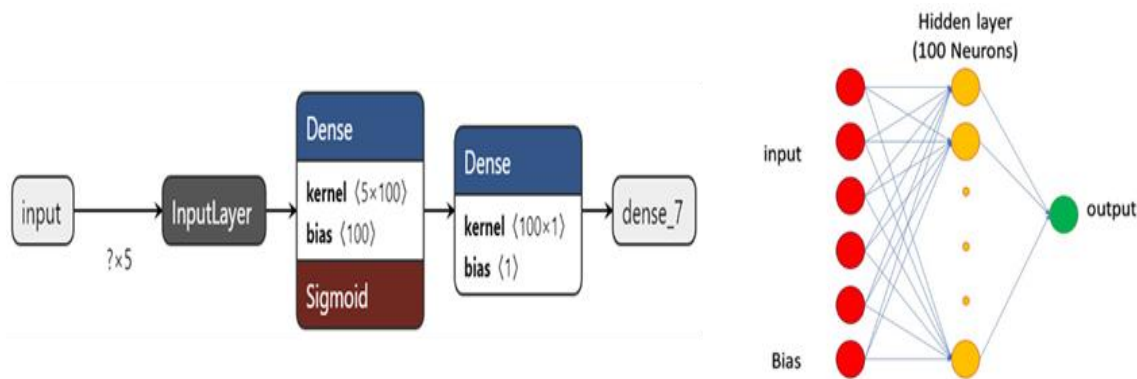
$$V_q = 1 - V_s = \frac{\beta_q}{1 + \alpha_q} = 1 - \frac{\beta_s}{1 + \alpha_s} \quad (9)$$

که V_q : نسبت جریان سریع به جریان کل ($1 - V_s$) و V_s : حجم نسبی از جریان آهسته است.

در این تحقیق از داده‌های سال‌های ۱۹۸۴ تا ۱۹۹۴ به عنوان داده‌های واسنجی و از داده‌های سال‌های ۱۹۹۵ تا ۲۰۰۶ به عنوان داده‌های صحت سنجی در بسته Hydromad نسخه ۰/۹-۲۶ در محیط نرم افزار Rstudio استفاده شد (۳).

شبکه‌های عصبی مصنوعی

مدل پایه شبکه عصبی مصنوعی برای اولین بار توسط مک کولج و پیترز در ۱۹۴۳ ارائه شد. ساختار کلی شبکه عصبی مصنوعی الهام گرفته از مغز انسان است و قادر به انجام عملیاتی تقریباً همانند سیستم‌های عصبی زیستی ولی در مقیاس ابتدایی است (۱۶). معماری معمول شبکه عصبی معمولاً متشکل از سه لایه است: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌کند و لایه خروجی که نتایج را به ازای ورودی‌های مشخص استخراج می‌کند. یک شبکه می‌تواند چندین لایه پنهان داشته باشد ولی تحقیقات انجام شده نشان می‌دهد یک لایه پنهان برای این گونه مدل‌ها می‌تواند هر تابع پیچیده و غیر خطی را تقریب بزند. بیش از ۹۰ درصد شبکه‌های عصبی مصنوعی که در مسائل مربوط به آب استفاده می‌شود از نوع الگوریتم پس انتشار خطا هستند (۶). شبکه پرسپترون چندلایه، شبکه‌ای با الگوریتم پس انتشار خطا که تابع انتقال در لایه پنهان از تابع محرکه تانژانت سیگموئید و در لایه خروجی از تابع محرکه خطی است و تابع یادگیری وزن‌ها تابع learnngdm و تابع آموزش آن تابع لونبرگ ماراکوات (trainlm) استفاده می‌کند که این آموزش تا زمانی ادامه پیدا می‌کند که خطای صحت سنجی به حداقل میزان کاهش یابد. در این شبکه‌ها اطلاعات ورودی توسط نرون‌های ورودی دریافت شده، سپس به نرون‌های لایه پنهان فرستاده می‌شود و پردازش مورد نظر روی آن‌ها انجام می‌شود و نتیجه به نرون‌های لایه خروجی فرستاده شده تا به عنوان خروجی شبکه نمایش داده شود (۲۳). در این تحقیق از شبکه Dence با تعداد نرون‌های ۱۰، ۲۰، ۵۰ و ۱۰۰ استفاده شد. انتخاب تعداد مناسب نرون‌ها در لایه میانی و تعداد تکرار مطلوب بر اساس مقایسه شاخص میانگین مربعات خطا در آزمون ترکیب‌های متفاوت صورت گرفت. به دلیل کاهش شدید معیار MSE در شبیه‌سازی از تعداد ۱۰۰ نرون و تکرار ۱۰۰ epoch استفاده شد. معیار بهینه‌سازی Adam برای بهبود روند آموزشی در نظر گرفته شد. تابع خطای استفاده شده MSE است و تابع فعال‌ساز به علت پیوسته بودن داده‌ها sgmoid انتخاب شد. از میان کل تعداد داده‌ها که ۳۴۱۰ داده است ۷۰ درصد در آموزش و ۳۰ درصد در آزمون استفاده شد. معماری بسته و باز شبکه در شکل (۴) نشان داده شده است.



شکل ۴- معماری بسته (چپ) و باز (راست) شبکه عصبی
Figure 4. Close and open (left, right) structure of artificial neural network

نتایج و بحث

واسنجی و صحت سنجی مدل

شبیه‌سازی جریان نیازمند واسنجی و اعتباریابی مدل هیدرولوژیکی است. انتخاب دوره‌های واسنجی و اعتباریابی با استفاده از روش سعی و خطا و با در نظر گرفتن معیار ارزیابی نش- ساتکلیف انجام شده به این ترتیب که دوره‌های مختلف به‌عنوان ورودی وارد مدل شد و سپس با اجرای فرایند شبیه‌سازی و دریافت نتایج، مقدار ضریب کارایی، مبنای قضاوت انتخاب دوره مورد نظر شد. اولین سال در هر نوبت شبیه‌سازی به‌عنوان دوره گرم کردن لحاظ شد. واسنجی مدل با استفاده از روش PORT و با حداکثر تکرار (تولید جمعیت) ۱۰۰ انجام شد. شکل (۵) نتایج شبیه‌سازی در مرحله واسنجی هر دو مدل موضوع تحقیق را نشان می‌دهد. همچنین جدول (۱) نتایج معیارهای ارزیابی عملکرد مدل IHACRES و شبکه عصبی مصنوعی را در دو مرحله واسنجی و اعتباریابی نشان می‌دهد. با بررسی معیارهای ارزیابی در دو مرحله واسنجی و صحت‌سنجی مشخص شد که به‌جز معیار کلینگ-گوپتا سایر معیارهای ارزیابی در مرحله اعتباریابی مدل هیدرولوژیکی مقادیر قابل قبول‌تری را نشان می‌دهد که حاکی از کارایی مدل و الگوریتم بهینه‌سازی آن در شرایط رطوبتی حوضه مورد مطالعه است.

$$KGE = 1 - \sqrt{(r-1)^2 + (\beta-1)^2 + (\gamma-1)^2} \quad (14)$$

همچنین داده‌های حاصل از معیارهای ارزیابی شبیه‌سازی شبکه عصبی مصنوعی شرایط به‌مراتب بهتر از مدل مفهومی بارش رواناب است به‌طوری‌که کلیه معیار ارزیابی در مرحله آموزش و در مرحله آزمون مقادیر قابل قبول‌تری را نشان می‌دهد. بررسی نتایج مدل هیدرولوژیکی و شبکه عصبی در مقایسه با مقادیر مشاهده‌شده نشان داد که میزان متوسط تفاضل خطای مطلق شبیه‌سازی در شرایط استفاده از شبکه عصبی ۰/۲۵ میلی‌متر و مدل هیدرولوژیکی ۰/۷۷ میلی‌متر است که حاکی از ارجحیت شبکه عصبی نسبت به مدل هیدرولوژیکی است. بر اساس نتایج یانگ (۲۰۰۵) در تایوان و دای و کروک (۲۰۰۳) در چند حوضه در آفریقای جنوبی مدل IHACRES توانایی بالاتری در شبیه‌سازی جریان در زیر حوضه‌های با مساحت کم دارد. با توجه به وسیع بودن حوضه

معیارهای ارزیابی

برای افزایش سطح اعتماد کاربر به قابلیت شبیه‌سازی مدل، ارزیابی آن در شبیه‌سازی ضروری است. در فرایندهای واسنجی و صحت‌سنجی و همچنین برای مقایسه نتایج مدل‌ها با مقادیر واقعی از شاخص‌های مختلفی استفاده می‌شود. در این تحقیق از روش‌های مختلفی برای ارزیابی نتایج هر دو مدل استفاده شد. ضریب کلینگ-گوپتا (۱۳) مطابق رابطه (۱۰) محاسبه می‌شود و این ضریب توسط سه محتوای همبستگی، انحراف معیار و میانگین تعریف می‌شود. تابع هدف حداکثر کردن مقدار ضریب کلینگ-گوپتا است که حداکثر مقدار آن یک است.

ضریب کارایی نش- ساتکلیف (NSE) در رابطه (۱۱)

نشان‌دهنده این است که تناسب کامل بین داده‌های مشاهده‌ای و شبیه‌سازی شده وجود دارد که حداکثر مقدار آن عدد یک است. اگر این مقدار بین ۰/۳۶ و ۰/۷۵ باشد نتایج مدل رضایت‌بخش به شمار می‌رود و اگر بیشتر از ۰/۷۵ باشد، نتایج شبیه‌سازی مدل خوب توصیف می‌گردد (۱۷،۲۲).

$$NSE = 1 - \frac{\sum_{t=1}^N (X_o - X_s)^2}{\sum_{t=1}^N (X_o - \bar{X}_o)^2} \quad (10)$$

ضریب تعیین (R^2) نیز معیاری بدون بعد و بهترین مقدار آن برابر یک است. رابطه (۱۲) نحوه محاسبه آن را نشان می‌دهد.

$$R^2 = \frac{\sum_{t=1}^N X_o \cdot X_s}{\sqrt{\sum_{t=1}^N X_o^2 \sum_{t=1}^N X_s^2}} \quad (11)$$

میانگین مربعات خطا (MSE) رابطه (۱۳) که می‌تواند از صفر در عملکرد عالی تا بی‌نهایت تغییر کند.

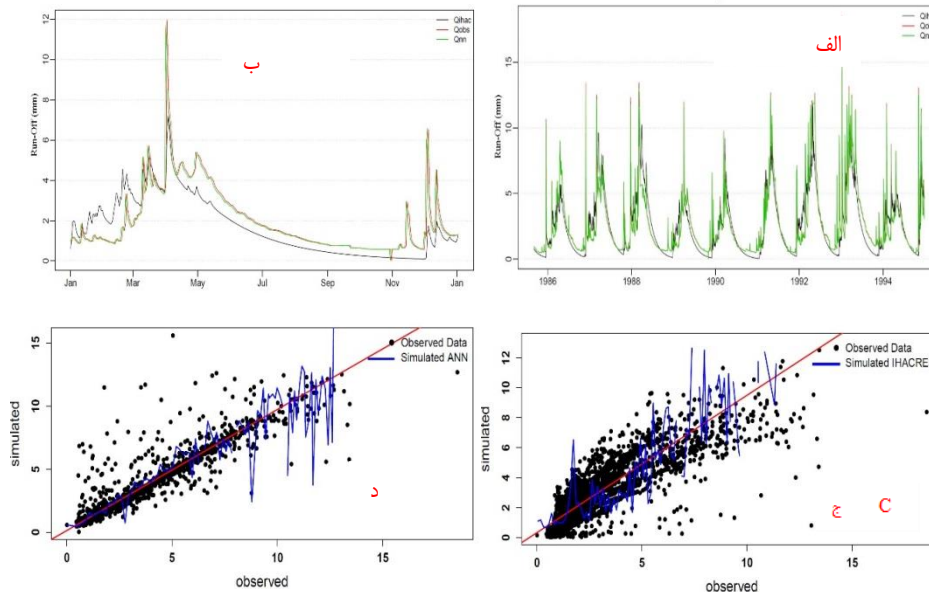
$$MSE = \frac{1}{N} \sum_{t=1}^N (X_o - X_s)^2 \quad (12)$$

میانگین مطلق خطا (MAE) رابطه (۱۴) برای مقایسه عبارت به عبارت خطای نسبی مقادیر شبیه‌سازی شده با توجه به مقادیر اندازه‌گیری شده به کار می‌رود.

$$MAE = \frac{\sum_{t=1}^N |X_o - X_s|}{N} \quad (13)$$

نتایج نشان داد شبکه عصبی نسبت به مدل هیدرولوژیکی IHACRES به دلیل معادلات ساختاری خود نتایج قابل قبولی در شبیه‌سازی بارش رواناب در مقایسه با مقادیر مشاهده‌شده در خروجی دارد، ضرایب معیارهای ارزیابی قابل قبول حتی در مرحله واسنجی مبنای قضاوت در خصوص کارایی این مدل است که این مورد با یافته‌های کریم‌پور و همکاران (۱۳۹۸)، مدرسی و همکاران (۱۴۰۱) و حافظ پرست و همکاران (۲۰۲۱) مطابقت دارد.

بختیاری توصیه می‌شود نتایج این تحقیق در حوضه با مساحت کمتری مورد بررسی قرار گیرد. همچنین تغییرات ارتفاعی منطقه مورد مطالعه در این تحقیق و نیز رژیم برفی بارانی آن استفاده از یک مدل نیمه توزیعی به منظور دستیابی به کارایی بهتر نسبت به مدل IHACRES ضروری می‌داند. مطابق شکل (۵) توانایی قابل قبول شبکه عصبی در شبیه‌سازی جریان‌های اوج علاوه بر شبیه‌سازی جریان روزانه از نتایج قابل توجه این تحقیق است که با نتایج حسن و همکاران (۲۰۱۴) مطابقت دارد.



شکل ۱- نتایج شبیه‌سازی در کلیه سال‌های مرحله واسنجی (الف) و یک سال (ب) از دوره واسنجی مدل‌های هیدرولوژیکی و شبکه عصبی نمودارهای (ج و د) به ترتیب مقادیر دبی‌های مشاهده‌ای در مقابل مقادیر شبیه‌سازی مدل هیدرولوژیکی و شبکه عصبی
Figure 5. Calibration period results in total years (A) and one year (B) by hydrological model and ANN
Observed and simulation graphs by hydrological model and ANN shown in (C, D) section, respectively

جدول ۲- معیارهای ارزیابی مدل هیدرولوژیکی و شبکه عصبی

Artificial Neural Network شبکه عصبی مصنوعی		IHACRES Model مدل IHACRES		Model & Simulation Step مدل و مرحله شبیه‌سازی	Evaluation Criteria معیار ارزیابی
Validation صحت‌سنجی	Optimization بهینه‌سازی	Validation صحت‌سنجی	Calibration واسنجی		
0.94	0.86	0.74	0.85		Kling-Gupta Coefficient ضریب کلینگ-گوپتا
0.89	0.79	0.75	0.74		Nash-Sutcliffe Efficiency ضریب کارایی نش-ساتکلیف
0.89	0.81	0.77	0.75		Determination Coefficient ضریب تعیین
0.57	0.61	1.25	1.36		Mean Square Error میانگین مربعات خطا
0.26	0.34	0.7	0.78		Absolute Mean Error میانگین مطلق خطا

۱۹۹۵ تا ۲۰۰۶ برای صحت‌سنجی استفاده شد. نتایج این تحقیق نشان داد بر اساس معیارهای ارزیابی، شبکه عصبی مصنوعی کارایی بیشتری نسبت به مدل هیدرولوژیکی در مدل‌سازی بارش-رواناب دارد. شبکه عصبی مصنوعی به دلیل در نظر گرفتن روابط غیرخطی موجود میان داده‌های ورودی و خروجی و به دنبال آن افزایش دقت در مدل‌سازی می‌تواند جایگزین مناسبی برای مدل‌های مفهومی یکپارچه نظیر IHACRES باشد.

نتیجه‌گیری کلی

در این تحقیق کارایی مدل مفهومی IHACRES و مدل داده‌مبنای شبکه عصبی مصنوعی (ANN) برای شبیه‌سازی فرایند بارش - رواناب در حوضه بختیاری مورد بررسی قرار گرفت. بر اساس بسیاری از روش‌های معمول در مدل‌سازی، داده‌های جریان مشاهده‌شده به دو دوره واسنجی و صحت‌سنجی تقسیم شد. داده‌های سال‌های ۱۹۸۴ تا ۱۹۹۴ به عنوان داده‌های مرحله واسنجی و از داده‌های سال‌های

منابع

- Ahmadpour, A., S. Mirhashemi and P. Haghghat jou. 2020. Evaluation of Classical, Conceptual IHACRES and Hybrid ARMA-ANN Models in Simulation and Prediction of Daily Discharge of Maroun River. Iranian Journal of Soil and Water Research, 51(3): 727-736 (In Persian).
- Ahooghalandari, M., M. Khiadani and G. Kothapalli. 2015. Assessment of Artificial Neural Networks and IHACRES models for simulating streamflow in Marillana catchment in the Pilbara, Western Australia. Australasian Journal of Water Resources, 19(2): 116-126.
- Andrews, F.T., B.F.W. Croke and A.J. Jakeman. 2011. An open software environment for hydrological model assessment and development. Environmental Modelling & Software, 26(10): 1171-1185.
- Bashirgonbad, M. 2022. Rainfall-Runoff Modeling to Predict Maximum Daily Flow under Climate Change Conditions. Journal of Watershed Management Research, 13(26):115-124.
- Box, G.E.P., G.M. Jenkins, G.C. Reinsel and G.M. Ljung. 2015. Time series analysis: forecasting and control. John Wiley & Sons.
- Braddock, R.D., M.L. Kremmer and L. Sanzogni. 1998. Feed-forward artificial neural network model for forecasting rainfall run-off. Environmetrics, 9(4): 419-432.
- Carcano, E.C., P. Bartolini., M. Muselli and L. Piroddi. 2008. Jordan recurrent neural network versus IHACRES in modelling daily streamflows. Journal of Hydrology, 362(3-4): 291-307.
- Chen, J and B.J. Adams. 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. Journal of Hydrology, 318(1-4): 232-249.
- Croke, B.F.W. and A.J. Jakeman. 2008. Use of the IHACRES rainfall-runoff model in arid and semi arid regions. In: Howard, W., S. Sorooshian and K. D. Sharma (eds.) Hydrological Modelling in Arid and Semi-Arid Areas, Cambridge University Press, United Kingdom. 41-48 pp.
- Dye, P.J. and B.F.W. Croke. 2003. Evaluation of streamflow predictions by the IHACRES rainfall-runoff model in two South African catchments. Environmental Modelling & Software, 18(8): 705-712.
- Ghorbani, M.A., A. Azani and L. Naghipour. 2016. Comparison of the Performance of Support Vector Machine with other Intelligent Techniques to Simulate Rainfall-Runoff Process. Journal of Watershed Management Research, 7(13): 103-92 (In Persian).
- Goodarzi, M., B. Salahi and A. Hoseini. 2018. Assessment of IHACRES Model in Simulating River Discharge in Urmia Lake Basin. Iranian Journal of Watershed Management Science and Engineering, 12(43): 1-10 (In Persian).
- Gupta, H.V., H. Kling., K.K. Yilmaz and G.F. Martinez. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. Journal of Hydrology, 377(1-2): 80-91.
- Hafezparast, M. and S. Marabi. 2021. Prediction of discharge using artificial neural network and IHACRES models due to climate change. Journal of Renewable Energy and Environment, 8(3): 75-85.
- Jakeman, A. J and G. M. Hornberger. 1993. How much complexity is warranted in a rainfall-runoff model? Water Resources Research, 29(8): 2637-2649.
- Karimpour, F., A. Darzi-Naftchali and M. Nadi. 2019. Technical Report"Performance Comparison of IHACRES Model and Artificial Neural Network to Predict the Flow of Sivand River. Journal of Watershed Management Research, 10(20): 262-267 (In Persian).
- McIntyre, N and A. Al-Qurashi. 2009. Performance of ten rainfall-runoff models applied to an arid catchment in Oman. Environmental Modelling & Software, 24(6): 726-738.
- MINNS, A.W. and M.J. HALL. 1996. Artificial neural networks as rainfall-runoff models. Hydrological Sciences Journal, 41(3): 399-417.
- Modaresi, F., K. Ebrahimi and S. Araghinejad. 2022. Ranking Evaluation of Data-driven and Conceptual Modelling of Rainfall-Runoff Process in Monthly Time Scale. Irrigation and Water Engineering, 12(4): 258-273 (In Persian).
- Mohammadi, K., H.R. Eslami and D.S.H. Dayani. 2005. Comparison of regression, ARIMA and ANN models for reservoir inflow forecasting using snowmelt equivalent (a case study of Karaj). Journal Of Agricultural Science and Technology (Jast), 21(7): 17-30.
- Napolitano, G., F. Serinaldi and L. See. 2011. Impact of EMD decomposition and random initialisation of weights in ANN hindcasting of daily stream flow series: An empirical examination. Journal of Hydrology, 406(3): 199-214.
- Nash, J.E. and J.V. Sutcliffe. 1970. River flow forecasting through conceptual models part I-A discussion of principles. Journal of Hydrology, 10(3): 282-290.
- Nazeri Tahroudi, M., M. Amirabadyzadeh and M.J. Zeynali. 2018. Evaluation of the Accuracy of Artificial Intelligence and Regression Models in Simulation the Daily Temperature. Journal of Meteorology and Atmospheric Science, 1(1): 65-76 (In Persian).
- Raman, H. and N. Sunilkumar. 1995. Multivariate modelling of water resources time series using artificial neural networks. Hydrological Sciences Journal, 40(2): 145-163.
- Tokar, A.S. and M. Markus. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. Journal of Hydrologic Engineering, 5(2): 156-161.
- Yang, T.C., P.S. Yu and C.C. Chen. 2005. Long-term runoff forecasting by combining hydrological models and meteorological records. Hydrological Processes, 19(10): 1967-1981.

Evaluation of IHACRES, Conceptual Rainfall Runoff Model and Artificial Neural Network Models in Simulation and Stream flow Prediction in Bakhtiary River Basin

Morteza Choubin¹ and Mohammad Bashirgonbad²

1- Faculty of Engineering, Malayer University, Malayer, Iran, (Corresponding author: m.chobin@edu.ikau.ac.ir)

2- Faculty of Natural Resources and Environmental Sciences, Malayer University, Malayer, Iran

Received: 14 September, 2022

Accepted: 8 November, 2022

Extended Abstract

Introduction and Objective: In recent years, river flow forecasting is one of the most important issues for water resources management in Iran. This prediction requires statistics and information, unfortunately, most of the basins of the country lack data of the desired quantity and quality.

Material and Methods: Therefore, hydrological modelling and the use of artificial intelligence are examples of solutions that are used to solve this challenge in hydrology. The criteria for selecting the appropriate model for this process are to evaluate the performance of the models according to the hydrological conditions of each region. In this research, IHACRES model and Artificial Neural Network (ANN) were used to predict the streamflow in Bakhtiary basin. The data from 1984 to 1994 were used as calibration period and the data from 1995 to 2006 were used for validation.

Results: The evaluation results of the hydrological model and the artificial neural network were evaluated using Kling-Gupta, Nash-Sutcliffe indices, coefficient of determination, mean squared error and absolute mean error. Results showed that the artificial neural network had better results in the simulation in all the evaluated evaluation criteria.

Conclusion: According to the results of the methods used in the research, the artificial neural network method has a more accurate prediction of the Bakhtiary river flow than the hydrological model.

Keywords: Bakhtiary basin, Data-driven models, Flow simulation, Rainfall-runoff