



"گزارش فنی"

مقایسه کارایی مدل IHACRES و شبکه عصبی مصنوعی برای پیش‌بینی جریان رودخانه سیوند

فهیمه کریمپور^۱، عبدالله درزی نفت چالی^۲ و مهدی نادی^۳

۱- دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲- دانشیار، گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۳- استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری، (نویسنده مسؤول: mehdi.nadi@gmail.com)

تاریخ دریافت: ۹۶/۴/۳۱ تاریخ پذیرش: ۹۸/۳/۱۹

صفحه: ۲۶۷ تا ۲۶۲

چکیده

تعیین دقیق جریان رودخانه در آبخیزهای فاقد آمار از چالش‌های مهم در هیدرولوژی می‌باشد. در این راستا، با توجه به تنوع مدل‌های هیدرولوژیکی موجود، انتخاب مدل مناسب مستلزم ارزیابی عملکرد مدل‌ها در شرایط هیدرولوژیکی هر منطقه است. هدف از این پژوهش مقایسه کارایی روش شبکه عصبی مصنوعی (ANN) و مدل یکپارچه IHACRES برای پیش‌بینی جریان رودخانه سیوند در حوضه طشك- بختگان واقع در استان فارس به عنوان یک منطقه گرم و خشک می‌باشد. از داده‌های سال‌های ۱۳۶۱ تا ۱۳۷۴ برای واسنجی و ۱۳۹۱ تا ۱۳۷۵ برای صحبت‌سنگی مدل استفاده شد. برای ارزیابی قابلیت شبکه‌های عصبی مصنوعی، از جعبه ابزار مربوط به شبکه عصبی نرم‌افزار متلب استفاده شد. مقادیر جریان شبیه‌سازی شده بوسیله مدل IHACRES برای دبی سیلانی در دوره واسنجی بیشتر و در دوره صحبت‌سنگی، کمتر از مقادیر مشاهداتی بود. مقادیر ضریب تبیین در فرایند واسنجی و صحبت‌سنگی این مدل به ترتیب ۰/۶۲ و ۰/۵۴ بود. کمترین و بیشترین مقدار ضریب تبیین شبکه عصبی دینامیک در دوره‌های واسنجی و صحبت‌سنگی به ترتیب ۰/۸۸ و ۰/۹۴ بود در حالی که برای شبکه‌های عصبی ایستا به ترتیب ۰/۵۱ و ۰/۶۹ بود. براساس نتایج، شبکه‌های عصبی مصنوعی با دقت بیشتری نسبت به مدل IHACRES، جریان ماهانه رودخانه سیوند را پیش‌بینی کردند.

واژه‌های کلیدی: آبخیز، سیلان، شبکه‌های استاتیک، شبکه‌های دینامیک

مقدمه

با توجه به فقدان ایستگاه هیدرومتری دارای آمار طولانی مدت در بیشتر حوزه‌های آبخیز کشور و به دلیل پیچیدگی زیاد اکوسیستم‌های هیدرولوژیکی، استفاده از روش‌هایی که بتوان به کمک آن‌ها میزان رواناب حاصل از بارندگی را در حوضه‌های فاقد آمار یا دارای آمار ناقص تخمین زد، از اهمیت قابل توجهی برخوردار است. یکی از این روش‌ها، استفاده از قابلیت‌های مدل‌های هیدرولوژیکی در شبیه‌سازی فرایندهای هیدرولوژیکی است که از اولین مرافق اقدامات مدیریت و برنامه‌ریزی منابع آب و نیز بررسی اثرات هیدرولوژیکی تغییر کاربری اراضی و نحوه بهره‌برداری از منابع طبیعی در یک حوزه آبخیز می‌باشد (۱۵). به دلیل محدودیت امکان اندازه‌گیری دبی جریان در زمان‌ها و مکان‌های مختلف، مدل‌های بارش و رواناب ابزار مناسب برای بهبود مدیریت منابع آب سطحی می‌باشند (۶). از سوی دیگر، شبیه‌سازی بارش-رواناب برای سامانه‌های پیش‌بینی سیلان اهمیت بهسازی دارد چرا که مدل‌های تجربی قادر به شبیه‌سازی رفتار غیرطبیعی حوضه‌ها در تولید سیلان نیستند. برای شبیه‌سازی ویژگی‌های حوضه، مدل‌ها و روش‌های متفاوتی وجود دارد که از جمله آنها می‌توان به مدل شبکه عصبی مصنوعی (ANN)، رگرسیون چند متغیره و مدل‌های مفهومی از جمله IHACRES^۳ اشاره کرد.

تحقیقات زیادی در زمینه کاربرد روش‌های مختلف در شبیه‌سازی رواناب حوضه انجام گرفت. توکار و مارکوس (۱۸) با مقایسه مدل شبکه عصبی مصنوعی و مدل‌های مفهومی

برای برآورد رواناب حوزه آبخیز رودخانه (فراس)^۳ در کلرادو امریکا، به متغیره و IHACRES استفاده کردند، نتایجی که بدست آمد نشان دهنده برتری مدل شبکه عصبی مصنوعی نسبت به مدل IHACRES و رگرسیون چند متغیره بود. چنانگیر و همکاران (۱۱)، در تحقیقی برای شبیه‌سازی فرایند بارش-رواناب برای حوزه آبخیز کارده نشان داده شد که خروجی شبکه عصبی مصنوعی دقیق‌تر از خروجی مدل HEC-HMS می‌باشد. کومار و همکاران (۱۲)، در پژوهشی روی حوضه رودخانه سارادا دریافتند که شبکه‌های عصبی برای پیش‌بینی دبی‌های پیک در حوضه‌های کوچک در مناطق نیمه‌خشک که دارای بارش‌های پراکنده و نامنظم می‌باشند مناسبند. با توجه به این که در برخی حوزه‌های آبخیز امکان اندازه‌گیری تمام کمیت‌های مورد نیاز جهت بررسی عکس العمل حوضه میسر نمی‌باشد، لذا انتخاب مدلی که بتواند با استفاده از حداقل اطلاعات ورودی مورد نیاز، پیش‌بینی قابل قبولی ارایه کند، اهمیت قابل توجهی دارد (۱۷). مدل IHACRES با وجود عدم نیاز به داده ورودی زیاد، می‌توانند نتایج مناسبی را ارایه دهد. داده‌های اصلی ورودی این مدل تنها بارش و دما در مقیاس روزانه می‌باشند که در اکثر حوزه‌های آبخیز وجود دارد (۱۳). بر این اساس، در این پژوهش قابلیت مدل‌های IHACRES و شبکه عصبی مصنوعی برای پیش‌بینی دبی رودخانه سیوند در یک منطقه خشک و نیمه خشک کشور واقع در استان فارس مورد ارزیابی قرار گرفت.

1- Artificial Neural Network

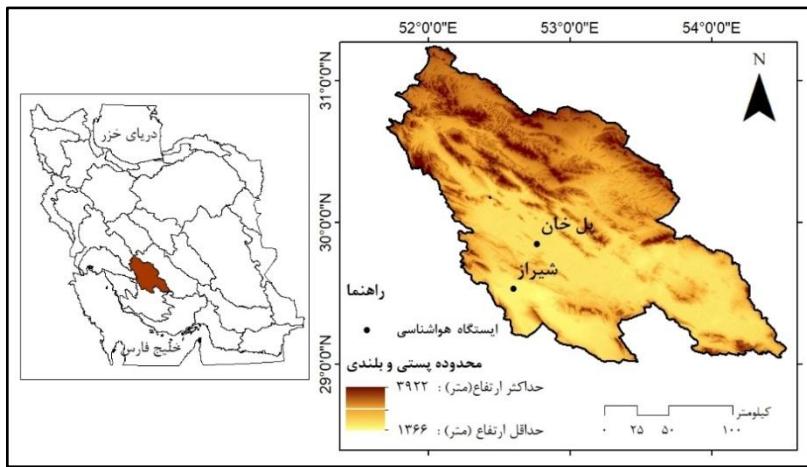
2- Identification of unit Hydrograph And Component flows from Rainfall, Evaporation and Streamflow data

3- Fraser river

مناطق گرمسیری با دمای حداکثر ۴۵ درجه سانتی‌گراد در نواحی جنوب و جنوب شرقی وجود دارد (۲). شکل (۱) موقعیت این حوضه و ایستگاه هیدرومتری پل خان را نشان می‌دهد. در این تحقیق از داده‌های دما و بارش و دبی ایستگاه‌های سینوپتیک شیراز و هیدرومتری پل خان استفاده شد.

مواد و روش‌ها

محدوده مطالعاتی این تحقیق براساس داده‌های ایستگاه پل خان و شیراز واقع در استان فارس انجام شد. دریاچه‌های طشك و بختگان از نظر وسعت دومین دریاچه کشور بهشمار می‌آید. در این حوضه، پارامترهای هواشناسی بسیار متغیر است به گونه‌ای که نقاط سردسیری با حداقل مطلق دمای ۲۸- درجه سانتی‌گراد در مناطق شمال تا شمال غربی تا



شکل ۱- موقعیت حوزه آبخیز طشك-بختگان در کشور و ایستگاه‌های هواشناسی و هیدرومتری
Figure 1. Location of Tashak-Bakhtegan watershed in Iran and meteorology and hydrometry stations

که دارای اتصالات پس‌خورد و پیش‌خورد می‌باشد. برای شبیه‌سازی با شبکه عصبی مصنوعی، از شبکه‌های دینامیکی (NAR) و شبکه ساده دینامیکی (NARX) استفاده شد. در این مدل‌ها، توابع آموزش مورد استفاده، تابع Levenberg-Marquardt (LM) می‌باشد.

معیارهای ارزیابی
قبل از استفاده از مدل برای حوضه، انجام واستنجی با روش سعی و خطأ بر مبنای آمار مشاهداتی ایستگاه هیدرومتری موجود در منطقه مطالعه انجام شد. همچنین، برای افزایش سطح اعتماد کاربر به قابلیت شبیه‌سازی مدل، صحت‌سنجی آن ضروری است. در فرایندهای واستنجی و صحت‌سنجی همچنین برای مقایسه نتایج مدل‌ها با مقادیر واقعی، از شاخص‌های R² و BIAS، R² ARPE استفاده شد. هرچه قدر مقادیر R² بیشتر و مقادیر پارامتر ARPE کمتر باشد نتایج مدل ایده‌آل‌تر می‌باشد (۱۳). لازم به ذکر است که از داده‌های سال‌های ۱۳۶۱ تا ۱۳۷۴ برای واستنجی مدل و از داده‌های مربوط به سال‌های ۱۳۷۵ تا ۱۳۹۱ برای صحت‌سنجی آن استفاده شد.

نتایج و بحث

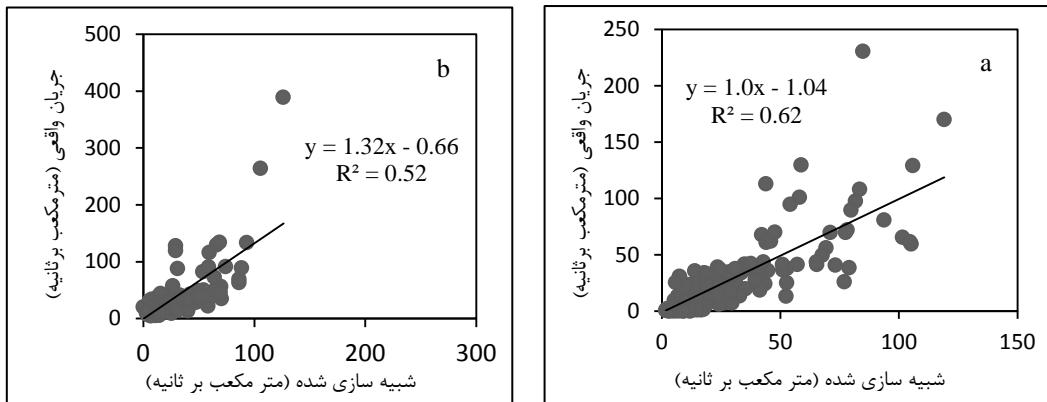
و استنجی و صحت‌سنجی مدل IHACRES
نتایج واستنجی و صحت‌سنجی مدل IHACRES در جدول ۱ نشان داده شده است. بر اساس نتایج این جدول میزان خطای مدل در دوره‌های واستنجی و صحت‌سنجی به ترتیب ۱/۵۶ و ۲/۰۷ و مقدار ضریب تبیین در این دوره‌ها

IHACRES مدل IHACRES مدلی پارامتریک و کارآمد است که برای اکثر حوضه‌ها قابل استفاده است. این مدل دارای دو بخش است: (الف) مدل غیرخطی که بارش را در پایه زمانی به بارش موثر (بخشی از بارش که سرانجام وارد جریان رودخانه می‌شود) و بارش مازاد که سرانجام توسط تبخیر- تعرق از بین می‌رود (با فرض غیرقابل نفوذ بدن حوضه آبخیز) تبدیل می‌کند و (ب) یک تابع تبدیل خطی یا هیدروگراف واحد، که بارش موثر را به جریان مدل‌سازی شده، تبدیل می‌کند. این بخش‌ها به ترتیب بخش تلفات و بخش تابع تبدیل (هیدروگراف واحد) نامیده می‌شوند. بخش تلفات برای تمام فرایندهای غیرخطی بارش- جریان در مقیاس حوضه آبخیز در نظر گرفته می‌شود. بخش تابع تبدیل مبتنی بر تئوری سیستم‌های خطی است (۱۴).

مدل شبکه عصبی مصنوعی
محدوده کاربرد این مدل بسیار گسترده است که کاربردهای طبقه بندي، درون‌بایی، برآورد، آشکارسازی و غیره را شامل می‌شود (۸). هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد (۹). در این تحقیق برای شبکه عصبی مصنوعی از جعبه ابزار مربوط به شبکه عصبی نرم‌افزار متلب استفاده شد. این ابزار مبتنی بر شبکه عصبی مصنوعی با ساختار پویا می‌باشد

صحت‌سنگی نسبت به دوره واسنجی، افزایش دبی و ثابت زمانی خشکیدگی حوضه را به همراه داشته که در نتیجه آن دبی‌های سیلابی بیشتری مشاهده شده و در نتیجه مقدار ضریب تبیین کاهش یافته است. رابطه بین دبی واقعی و شبیه‌سازی شده در مراحل واسنجی و صحت‌سنگی نیز در شکل ۲ ارایه شده که موید توانایی مناسب مدل در شبیه‌سازی دبی می‌باشد. میزان همبستگی مقادیر دبی واقعی و شبیه‌سازی شده در فرایندهای واسنجی و صحت‌سنگی بهتری 0.62 دارد. در صورت صرف‌نظر از محدود دبی‌های سیلابی، این مقادیر تا حد زیادی افزایش خواهد یافت.

بهترتب 0.54 و 0.62 بود. مقادیر مثبت و منفی خطای کل نشان‌دهنده‌ی کمتر و بیشتر بودن متوسط دبی شبیه‌سازی شده نسبت به دبی واقعی است. در جدول ۱، P و Q به ترتیب بارش کل و بخشی از بارش دوره (واسنجی/صحت‌سنگی) است که در ایجاد جریان رودخانه مشارکت داشته است که مقدار هر دو پارامتر در دوره صحت‌سنگی نسبت به دوره واسنجی افزایش یافته است. همچنین ثابت زمانی خشکیدگی حوزه آبخیز (τ_w) در دوره صحت‌سنگی افزایش ولی فاکتور تعديل حرارتی حوضه (f) تغییری نیافتد. کاهش مقدار شاخص ARPE در دوره صحت‌سنگی نسبت به دوره واسنجی حاکی از خطای بیشتر این مدل در این دوره است که البته کاملاً طبیعی به‌نظر می‌رسد چرا که افزایش چرا در دوره



شکل ۲- مقایسه مقادیر دبی واقعی و شبیه‌سازی شده در مرحله واسنجی (a) و صحت‌سنگی (b)
Figure 2: Comparison of measured and simulated flow rates in the calibration (a) and validation (b) stages

جدول ۱- نتایج عملکرد مرحله واسنجی و صحت‌سنگی مدل IHACRES برای حوضه طشك- بختگان

Table 1. Results of the IHACRES model Performance for the Tashk-Bakhtegan watershed during calibration and validation

مرحله	واسنجی	صحت‌سنگی
$P(\text{mm/yr})$	$Q(\text{m}^3/\text{s})$	$f(\text{c}^{-1})$
۳۱۱/۷۱۶	۶۲/۳۵۴	۳/۹
۶۴۶/۲۳۵	۸۰/۱۱۳	۳/۹
		$\tau_w (\text{day})$
		۴
		۱۴
		R^2
		۰/۶۲
		-۰/۵۶
		۰/۰۵۳
		۰/۰۷
		۰/۰۴۳
		ARPE

به‌طور قابل توجهی بیشتر از مقدار آن برای شبکه‌های استاتیکی ($0/۵۵$ تا $0/۶۹$) بود. رابطه مقادیر دبی جریان واقعی و شبیه‌سازی شده به‌وسیله شبکه عصبی مصنوعی در مراحل آموزش و صحت‌سنگی در شکل (۳) ارایه شده است. همانطور که ملاحظه می‌شود مقادیر شبیه‌سازی شده با مقادیر اندازه‌گیری شده دارای همپوشانی خوبی هستند که این نشان از دقت مدل می‌باشد. مقدار R^2 برای مرحله‌ی آموزش برابر $0/۷۶$ و برای مرحله صحت‌سنگی برابر با $0/۶۴$ می‌باشد.

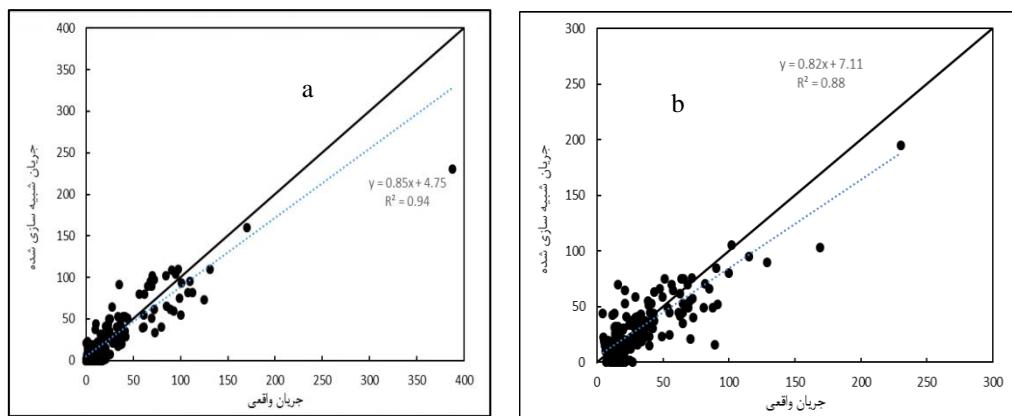
ارزیابی مدل شبکه عصبی مصنوعی

پارامترهای ارزیابی مدل شبکه عصبی مصنوعی در جدول ۲ ارایه شد. از میان شبکه‌های دینامیکی مختلف، شبکه NARX با پنج نمون دارای کمترین مقدار خطای $0/۰۰۲$ و شبکه NAR با ده نمون دارای بیشترین خطای $0/۰۰۳$ بود. در دوره صحت‌سنگی نیز، شبکه‌های دینامیک عملکرد مناسبی در پیش‌بینی دبی داشتند. میزان خطای شبکه‌های دینامیکی و استاتیکی در این مرحله، بهترتب در محدوده $0/۰۰۴۲$ تا $0/۰۰۱۴$ و $0/۰۱۶$ تا $0/۰۹$ قرار داشت. ضریب تبیین شبکه‌های دینامیکی ($0/۷۳$ تا $0/۹۴$) در دوره صحت‌سنگی

جدول ۲- مقادیر پارامترهای مربوط به ارزیابی مدل شبکه عصبی مصنوعی

Table 2. Parameters related to the evaluation of artificial neural network model

دوره صحت سنجی				دوره آموزش			
نوع شبکه	تعداد نرون	MSE	R ²	نوع شبکه	تعداد نرون	MSE	R ²
(NAR) دینامیک	۵	.۰۰۷۳	.۰۷۳	(NAR) دینامیک	۵	.۰۰۹	.۰۸
(NAR) دینامیک	۱۰	.۰۰۰۲	.۰۷۸	(NAR) دینامیک	۱۰	.۰۰۳	.۰۸۶
(NARX) دینامیک	۱۰	.۰۰۰۶۵	.۰۹۴	(NARX) دینامیک	۱۰	.۰۰۰۹۹	.۰۸۸
(NARX) دینامیک	۵	.۰۰۰۴۲	.۰۹	(NARX) دینامیک	۵	.۰۰۰۲	.۰۸۱
(Simple) دینامیک	۵	.۰۰۱۳	.۰۷	(Simple) دینامیک	۵	.۰۰۲۴	.۰۶
(Simple) دینامیک	۱۰	.۰۰۱۴	.۰۷۵	(Simple) دینامیک	۱۰	.۰۱۹	.۰۶۷
ایستا	۵	.۰۰۳۱	.۰۵۵	ایستا	۵	.۰۰۲۱	.۰۳۶
ایستا	۱۰	.۰۰۱۶	.۰۵۵	ایستا	۱۰	.۰۰۳۲	.۰۴۵
ایستا	۱۵	.۰۰۷	.۰۶	ایستا	۱۵	.۰۰۲۳	.۰۴۱
ایستا	۲۰	.۰۰۷۳	.۰۶۵	ایستا	۲۰	.۰۰۲۵	.۰۴۳
ایستا	۲۵	.۰۰۹	.۰۶۶	ایستا	۲۵	.۰۰۳۸	.۰۵۳
ایستا	۵۰	.۰۰۱۹	.۰۶۹	ایستا	۵۰	.۰۰۷۸	.۰۵۱



شکل ۳- رابطه بین جریان واقعی و شبیه‌سازی شده بهوسیله مدل دینامیک با تعداد ۱۰ نرون شبکه عصبی مصنوعی در مرحله آموزش (a) و صحت سنجی (b)

Figure 3. Relationship between measured and simulated flow by dynamic model with 10 neurons of artificial neural network during training(a) and validation(b) stages

واردی حتی از دقت پایین‌تری نسبت به این مدل برخوردار بودند. علاوه بر این، مدل IHACRES بیشتر در دبی‌های پایین شبیه‌سازی را به خوبی انجام داد. در مجموع می‌توان نتیجه گرفت که شبکه‌های عصبی برای شبیه‌سازی جریان در منطقه مطالعه مناسب‌تر بودند که نشان‌دهنده مفید بودن کاربرد آنها در مطالعات هیدرولوژیکی است. با این وجود، استفاده از مدل IHACRES نیز بهدلیل کاربری آسان، ورودی‌های کم و کاهش صرف زمان با توجه به سطح دقت نشان داده شده آن‌ها در این مطالعه، می‌تواند نتایج معقولی را به همراه داشته باشد.

مقایسه کلی نتایج مدل IHACRES و شبکه عصبی مصنوعی

با توجه به ارزیابی نتایج دو مدل بدست آمده از مقایسه دو مدل شبکه مصنوعی و IHACRES مشخص شد که شبکه مصنوعی نسبت به مدل IHACRES از دقت بیشتری برخوردار است. مدل شبکه عصبی مصنوعی بهدلیل در نظر گرفتن روابط غیرخطی موجود میان داده‌های ورودی و خروجی و به دنبال آن افزایش دقت در مدل‌سازی می‌تواند جایگزین مناسبی برای مدل IHACRES باشد. همان‌طور که نتایج نشان می‌دهد شبکه‌های دینامیکی دقت بالاتری نسبت به مدل IHACRES داشتند در حالی که شبکه‌های ایستا در

منابع

1. Abdollahipoor, A., S. Moazami-Godarzi, M. Zakeri-Nayeri and H. Ghalkhani. 2015. Performance evaluation of three models of Artificial Neural Network, Multivariate Regression and IHACRES to estimate daily flow-case study: Zarrineh rud watershed. National Conference on Civil and Environmental Engineering, Islamic Azad University of Qazvin (In persian).
2. Anonymous. 2009. Reports of the studies on the water resource atlas of the Tasch-Bakhtegan Lake and Maharloo Lake basin. Fars Regional Water Company.
3. ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application Journal of Hydrologic Engineering, 5: 124-137.
4. Astatkie, T. and W.E. Watt. 1988. Multipleinput transfer function modeling of daily Streamflow series using non-linear inputs. Water Resources Research, 34(10): 2717-2725.
5. Avarideh, F. 1998. Application of hydroinformatics theory in sediment transport. MSc thesis, Amir Kabir University of Technology (In persian).
6. Beven, K.J. 2001. "Rainfall-runoff modelling: The Primer". John Wiley and Sons Press, Department of Geography Royal Holloway, University of London Egham, Surrey.
7. Carla Carcano E., P. Bartolini, M. Muselli and L. Piroddi. 2008."Jordan recurrent neural network versus IHACRES in modelling daily streamflows". Journal of Hydrology, 362: 291-307.
8. Das, G. 2000. Hydrology and soil conservation Engineering, Asoke K. Ghosh, Prentic-Hall of India, 489 pp.
9. Dayhoff, J.E. 1990. Neural Network Principles. Prentice-Hall International. U.S.A. 197 pp.
10. Dousti, M., K. Shahedi, M. Habibnezhad roshan, M. Miryaghoubzadeh. 2014. Simulating daily flow using the IHACRES semi-conceptual model (case study: Tamar watershed). Journal of Soil and Water Conservation, 21(2): 277-292 (In persian).
11. Jahangir, A., M. Raeini and M. Ziatabar-Ahmadi. 2008. Simulation of rainfall –runoff processes with nural Network and comparison with the HEC-HMS model in the Kernel Representative watershed. Journal of Soil and Water (Science and Technology of Agriculture), 22(2): 72-84 (In persian).
12. Kumar, P., T. Sundara, V. Praveen and M. Anjanaya Prasad. 2016. Artificial Neural Network Model for Rainfall-Runoff-A Case Study.
13. Littlewood L.G., R.T. Clarke, W. Collischonn and B.F.W. Croke. 2007. Predicting daily Streamflow using rainfall forecasts, a simple loss module and unit hydrographs: Two Brazilian catchments. Environmental Modelling and Software, 22: 1229-1239.
14. Littlewood, I.G. and A.J. Jakeman. 1994. A new method of rainfall runoff modeling and its application in catchments hydrology. In: Zannetti, P. (Ed.) Environmental Modelling, Computational Mechanics Publications, Southampton, UK, 2: 143-171.
15. Najafi, M.R. 2008. Hydrological Systems (Rainfall Modeling), Tehran University Publication, (In persian).
16. Post, D.A., J.A. Jones and G.E. Grant. 1998. An improved methodology for predicting the daily hydrologic response of ungauged catchments, Environmental Modeling and Software, 13: 395-403.
17. Sharifi, F., Sh. Saffarpoosh and S.A. Ayobzadeh. 2004. Evaluation of a computer model in simulation of hydrological processes of some watersheds of Iran. Research and construction, 63: 35-42 (In persian).
18. 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.

"Technical Report"

Performance Comparison of IHACRES Model and Artificial Neural Network to Predict the Flow of Sivand River

Fahimeh Karimpour¹, Abdullah Darzi-Naftchali² and Mehdi Nadi³

1- M.Sc. Student Sari Agricultural Sciences and Natural Resources University, Water Engineering Department
2- Associated Professor Sari Agricultural Sciences and Natural Resources University, Water Engineering Department
3- Assistant Professor Sari Agricultural Sciences and Natural Resources University, Water Engineering Department
(Corresponding author: mehdi.nadi@gmail.com)

Received: July 22, 2017

Accepted: June 9, 2019

Abstract

The accurate determination of river flow in watersheds without sufficient data is one of the major challenges in hydrology. In this regard, given the diversity of existing hydrological models, selection of an appropriate model requires evaluation of the performance of the hydrological models in each region. The objective of this study was to compare the performance of artificial neural network (ANN) and IHACRES integrated model to predict the flow of sivand river in Tashak Bakhtegan watershed located in Fars province as a warm and arid area. Calibration and validation procedures were done by using data from 1982-1995 and 1996- 2012, respectively. Neural Network Toolbox of MATLAB software were used to evaluate the capabilities of neural networks. In both calibration and validation periods, simulated flows by the IHACRES model for flood flows, were less than the observed data. The determination coefficients of the model during calibration and validation were 0.62 and 0.54, respectively. The determination coefficients of dynamic neural networks and static neural networks during calibration and validation ranged from 0.88- 0.94 to 0.51- 0.69, respectively. The results demonstrated that artificial neural networks predicted monthly flow of sivand river more accurately than the IHACRES model.

Keywords: Watershed, Flood, Static networks, Dynamic networks