

تاریخ دریافت: ۱۳۹۰/۱۱/۱۱

تاریخ پذیرش: ۱۳۹۱/۸/۲۳

نشریه مرتع و آبخیزداری
دوره ۶۶، شماره ۸، زمستان ۱۳۹۲

۴۹۳

مقایسه کارایی مدل‌های آماری و مفهومی در پیش‌بینی خشک‌سالی هیدرولوژی (مطالعه موردی: حوزه آبخیز کرخه)

- ❖ ام‌البنین بذرافشان: استادیار دانشکده منابع طبیعی دانشگاه هرمزگان
- ❖ علی سلاجقه*: دانشیار دانشکده کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ احمد فاتحی مرج: استادیار مرکز تحقیقات کم‌آبی و خشک‌سالی در کشاورزی و منابع طبیعی، تهران
- ❖ محمد مهدوی: استاد دانشکده کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ جواد بذرافشان: استادیار دانشکده کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ سمیه حجابی: دانشجوی دکتری دانشکده کشاورزی و منابع طبیعی دانشگاه تهران

چکیده

خشک‌سالی پدیده‌ای است که برای پیش‌بینی آن نمی‌توان از مدل مشخصی استفاده کرد. بر این اساس، محققان تلاش می‌کنند با استفاده از مدل‌های پیشرفته دقت پیش‌بینی‌ها را افزایش دهند. در این زمینه، مدل‌های استوکاستیک خطی، شبکه عصبی مصنوعی، و مدل‌های هیبرید می‌توانند در دقت پیش‌بینی مفید باشند. تحقیق حاضر به بررسی کارایی مدل‌های اتورگرسیو میانگین متحرک تجمعی (ARIMA)، شبکه عصبی مصنوعی مستقیم (DMSNN)، شبکه عصبی مصنوعی چندگامی بازگشتی (RMSNN)، مدل هیبرید آریمما- شبکه عصبی مصنوعی چندگامی مستقیم (HSNNDM)، و مدل هیبرید آریمما- شبکه عصبی مصنوعی چندگامی بازگشتی (HSNNRA) در پیش‌بینی خشک‌سالی هیدرولوژی در دو مقیاس زمانی ماهانه و فصلی می‌پردازد. شاخص استاندارد شده جریان (SDI) به عنوان نمایه جریان و شاخص پیش‌بینی شونده در حوزه آبخیز کرخه انتخاب شد. نتایج این پژوهش نشان می‌دهد مدل هیبرید شبکه عصبی مستقیم- آریمما (HSNNDA) نسبت به سایر مدل‌ها دارای عملکرد بهتری در پیش‌بینی SDI است و همچنین کارایی مدل در پیش‌بینی ماهانه بهتر از مقیاس فصلی است.

واژگان کلیدی: پیش‌بینی، خشک‌سالی هیدرولوژی، شبکه‌های عصبی مصنوعی، مدل‌های استوکاستیک، مدل‌های هیبرید.

مقدمه

خشک‌سالی را می‌توان پدیده‌ای گذرا، آرام، تکرارشونده، و جزئی جدانشدنی از اقلیم هر منطقه دانست. اگرچه منشأ همه خشک‌سالی‌ها کاهش بارندگی است، تأخیر تأثیرات آن بر منابع آبی موجب بروز خسارات زیادی می‌شود. بنابراین، پیش‌بینی خشک‌سالی هیدرولوژی، به‌ویژه در مقیاس بلندمدت، یکی از مهم‌ترین اهداف در مدیریت و برنامه‌ریزی منابع آبی به‌شمار می‌رود. متداول‌ترین روش‌ها برای پیش‌بینی مقوله خشک‌سالی کاربرد تئوری دنباله‌ها، مدل‌های استوکاستیکی، و مدل‌های مفهومی است. پیش‌بینی دترمینیستی و استوکاستیکی خشک‌سالی، بیش از هر فرایند دیگر، نظر هیدرولوژیست‌ها را به خود جلب کرده است. پدیده خشک‌سالی در بعد مکان و زمان بیشترین تغییرات را داشته و شبیه‌سازی آن، به لحاظ سرشت غیرخطی و ابعاد زیاد آن، همواره با مشکلات زیادی روبه‌رو بوده است [۸].

مدل‌های آماری برای پیش‌بینی خشک‌سالی شامل مدل‌های رگرسیونی پارامتری، مدل‌های رگرسیونی ناپارامتری، و مدل استوکاستیک هستند که به دلیل ماهیت خطی و ایستابودن، توانایی محدودی دارند و برای داده‌هایی با ماهیت غیرخطی و ناپایستا نامناسب‌اند. مدل‌های ARIMA^۱ از نوع مدل‌های استوکاستیک‌اند که از آن‌ها به‌طور گسترده‌ای برای پیش‌بینی بسیاری از متغیرهای هیدرولوژیکی، نظیر بارندگی و جریان، استفاده می‌شود، با وجود این، ضروری است که هیدرولوژیست‌ها از مدل‌هایی با ماهیت غیرخطی و ناپایستا استفاده کنند [۹]. در چند دهه اخیر شبکه‌های عصبی مصنوعی

(ANNs)^۲ قابلیت بالای خود را در مدل‌سازی سری‌های ناپایستا و غیرخطی هیدرولوژیکی نشان داده‌اند. مدل‌هایی که بر پایه شبکه عصبی مصنوعی‌اند ماهیت تجربی دارند و قادرند راه‌حل‌های دقیقی برای فرمول‌بندی و استخراج روابط بر مبنای داده‌های ورودی و خروجی ارائه دهند [۳].

در سال‌های اخیر، به‌دیدگاه ترکیب مدل‌های آماری و مفهومی برای پیش‌بینی خشک‌سالی هیدرولوژی در مقیاس زمانی بلندمدت و میان‌مدت در بسیاری از رودخانه‌ها توجه شده است، زیرا سری‌های زمانی هیدرولوژی به‌ندرت خطی یا غیرخطی و اغلب فصلی یا پرودیگ‌اند، بنابراین، ترکیب مدل‌های آماری با مدل‌های شبکه عصبی مصنوعی قادر است خصوصیات خشک‌سالی را بهتر پیش‌بینی کند [۷].

[۱۷] برای پیش‌بینی خشک‌سالی ماهانه و سالانه از مدل‌های استوکاستیک و شاخص پالمر استفاده کردند. نتایج نشان می‌دهد کارایی مدل استوکاستیک در مقیاس زمانی ماهانه بهتر از سالانه است. [۹] با استفاده از شاخص پالمر و شبکه عصبی مصنوعی پیش‌خور چندلایه به پیش‌بینی خشک‌سالی در حوزه آبخیز رودخانه کونچس^۳ در مکزیکو^۴ پرداختند، نتایج مطالعه نشان‌دهنده کارایی قابل قبول این شبکه در پیش‌بینی خشک‌سالی است. [۱۳] با استفاده از شاخص SPI و مدل هیبرید، که ترکیبی از مدل استوکاستیک خطی و مدل شبکه عصبی مصنوعی غیرخطی است، به پیش‌بینی خشک‌سالی پرداختند. نتایج نشان داد مدل هیبرید دارای کارایی بهتری نسبت به سایر مدل‌هاست. [۱۵] شاخص SDI^۵

1. Auto Regressive Integrated Moving Average
4. Mexico

2. Artificial Neural Networks
5. Standardized Discharge Index

3. Conches

مربع آن در مناطق کوهستانی و مرتفع قرار دارد و حدود ۱۷۰۹۴ کیلومتر مربع آن را دشت‌ها و کوهپایه‌ها تشکیل می‌دهند. از نظر مختصات جغرافیایی، بین $۴۶^{\circ} ۰۶'$ و $۴۹^{\circ} ۱۰'$ طول شرقی و بین $۳۰^{\circ} ۵۲'$ و $۳۴^{\circ} ۵۶'$ عرض شمالی قرار گرفته است (شکل ۱). این حوضه از شمال به حوضه‌های رودخانه‌های سیروان، سفیدرود، و قره‌چای، از غرب به رودخانه‌های مرزی و غرب ایران (عراق)، و از شرق به رودخانه دز محدود می‌شود. در پایاب این حوضه سد کرخه احداث شده است که از آب ذخیره‌شده در مخزن این سد برای تأمین آب در بخش کشاورزی، صنعت، و شرب استفاده می‌شود.

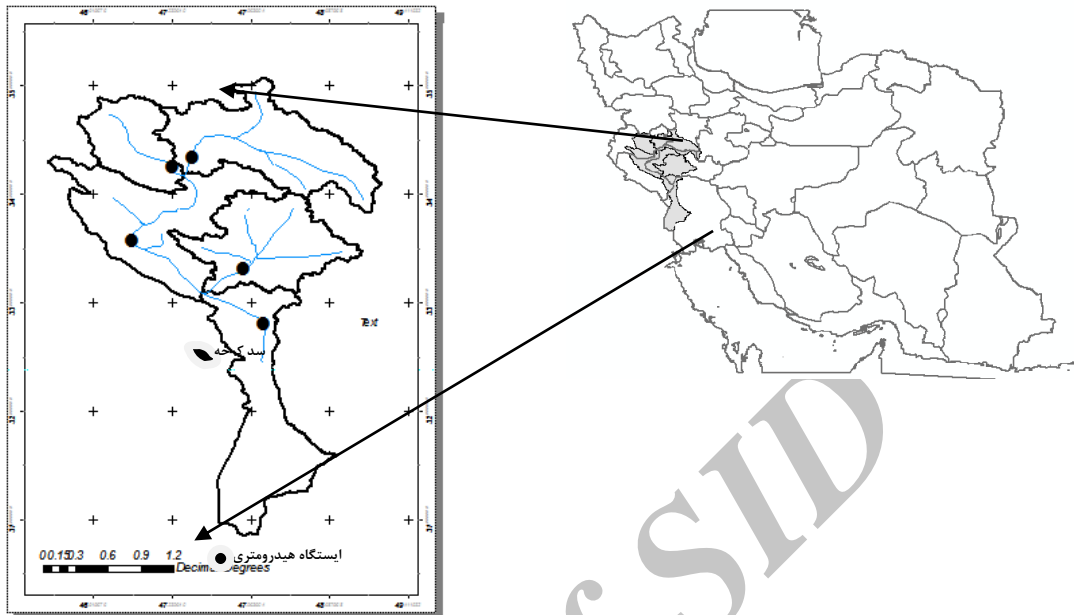
از بین ایستگاه‌های واقع در پنج زیرحوضه اصلی حوضه آبخیز کرخه، با توجه به توزیع مکانی مناسب و دارا بودن آمار کافی، ۵ ایستگاه هیدرومتری با طول دوره آمار ۳۲ ساله (۱۳۵۳-۱۳۸۷) انتخاب شد (جدول ۱). تغییرات میانگین سالانه دبی از ۸۶ تا ۳۳ متر مکعب بوده، مقدار حداکثر دبی $۱۹۰/۶$ متر مکعب و مربوط به ایستگاه پل زال، و حداقل دبی $۱/۲$ متر مکعب و مربوط به ایستگاه آفرینه است. میزان انحراف معیار در ایستگاه پل زال بالاترین مقدار را به خود اختصاص می‌دهد.

را برای محاسبه خشک‌سالی هیدرولوژی در چهار مقیاس ۳، ۶، ۹، و ۱۲ ماهه استفاده نمود. نتایج این مطالعه نشان داد این شاخص فاکتور مناسبی برای برآورد خشک‌سالی هیدرولوژی است. [۱۸] به بررسی کارایی مدل‌های سری زمانی و شبکه عصبی مصنوعی در پیش‌بینی خشک‌سالی هواشناسی با شاخص SPI پرداختند. نتایج نشان‌دهنده کارایی و عملکرد بهتر مدل سری زمانی در پیش‌بینی خشک‌سالی هواشناسی است.

با توجه به پیشینه بررسی، که در بالا به برخی از موارد آن اشاره شد، هدف از ارائه این مقاله عبارت است از ترکیب مدل‌های استوکاستیک و شبکه عصبی مصنوعی و توسعه مدل هیبرید و استفاده از شاخص استاندارد شده جریان (SDI) به عنوان فاکتور پیش‌بینی شونده برای پیش‌بینی خشک‌سالی هیدرولوژی و مقایسه نتایج مدل هیبرید با کاربست مجزای هر یک از مدل‌ها.

روش شناسی

حوضه آبخیز کرخه در غرب کشور در مناطق میانی و جنوبی زاگرس قرار دارد و دارای مساحتی بالغ بر ۵۰۷۶۸ کیلومتر مربع است که حدود ۳۳۶۷۴ کیلومتر



شکل ۱. موقعیت ایستگاه‌های هیدرومتری و حوزه آبخیز کرخه

جدول ۱. ویژگی‌های ایستگاه‌های واقع در حوزه آبخیز کرخه

مشخصات آماری سری سالانه دبی (۱۹۷۴-۲۰۰۸)

مشخصات جغرافیایی

نام زیرحوزه	نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی	عرض جغرافیایی	میانگین دبی (mm/d)	انحراف معیار	حدافل	حداکثر	چراگی	کشیدگی
گاماسیاب	پل چهر	۱۳۰۶	۴۷° ۲۶'	۳۴° ۲'	۳۲/۵	۱۵/۲	۶/۲	۷۷/۳	۰/۶۷۸	۱/۴۰۸
قره‌سو	قورباغستان	۱۳۰۰	۴۷° ۱۵'	۳۴° ۱۳'	۲۰/۶	۹/۴	۳/۳	۴۰/۶	۰/۰۴۵	۰/۶۴۳
کشکان	کشکان	۸۲۰	۴۷° ۵۳'	۳۴° ۱۹'	۳/۳	۰/۵۲	۱/۲۸	۴/۴	-۱/۵۱۵	۷/۷۱۴
سیمره	آفرینه	۷۴۲	۴۶° ۵۰'	۳۴° ۳۳'	۳/۹	۱/۶	۱/۲	۸/۴	۰/۴۱۰	۰/۰۴۲
کرخه پایین	پل زال	۹۰	۴۸° ۰۹'	۳۲° ۲۵'	۸/۶	۳/۶۵	۱۴/۴	۱۹۰/۶	۰/۴۲۵	۰/۹۴۷

شاخص SDI به عنوان شاخص پیش‌بینی شونده

جریان

برای مطالعه خشک‌سالی هواشناسی شاخص‌های متعددی ابداع شده است که معروف‌ترین آن‌ها شاخص بارش استاندارد SPI [۱۰] است. اما در زمینه خشک‌سالی هیدرولوژی تاکنون دو شاخص معروف با عنوان شاخص خشک‌سالی هیدرولوژی

پالمر^۱ PHDI [۱] و شاخص ذخیره آب سطحی^۲ SWSI [۲۱] پیشنهاد شده است. که، به دلیل نیاز به محاسبات زیاد و پیچیدگی، کمتر بدان‌ها توجه شده است. بنابراین، برای حل این مشکل می‌توان از شاخصی شبیه شاخص بارش استاندارد با عنوان شاخص استاندارد شده جریان (SDI) استفاده کرد که

1. Palmer Hydrologic Drought Index
2. Surface Water Supply Index

به صورت معادله ۲ است:

$$\varphi(B)(1-B)^d Z_t = \theta(B)\varepsilon_t \quad (2)$$

به طور کلی، چندین تیپ از ARIMA برای مدل‌سازی جریان در مقیاس ماهانه یا فصلی وجود دارد که شامل SARIMA^۴، PARIMA^۵، و DARIMA^۶ است [۲۲].

شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی ابزاری است برای تخمین نگاشت‌های خطی یا غیرخطی در زمانی که نتوان این نگاشت را با استفاده از روابط ریاضی معمولی بیان کرد. یک شبکه عصبی مصنوعی مجموعه‌ای از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهد. در یک شبکه عصبی مصنوعی هر نورون مستقل عمل می‌کند و رفتار کلی شبکه برآیند رفتار نورون‌های متعدد است. شبکه پرسپترون چندلایه پیش‌خور پُرکاربردترین شبکه عصبی در عرصه‌های کاربردی است. در این شبکه تعداد نورون‌های لایه اول برابر با تعداد متغیرهای مستقل پیش‌بینی (ورودی‌ها) است. همان‌گونه که بایاس در مدل‌های رگرسیونی باعث افزایش انعطاف‌پذیری مدل می‌گردد، در شبکه عصبی مصنوعی نیز از بایاس استفاده می‌شود. تعداد نورون‌های لایه میانی میزان انعطاف شبکه و دقت در پیش‌بینی را کنترل می‌کند و روش مشخص و مستقیمی برای تخمین تعداد نورون‌های لایه میانی وجود ندارد. تعداد نورون‌های لایه سوم معادل تعداد متغیرهای بردار پیش‌بینی است. تحقیقات نشان می‌دهد که شبکه‌های عصبی مصنوعی با یک لایه

بر اساس متوسط جریان ماهانه است و اولین بار توسط [۴] پیشنهاد گردید. اصول این شاخص همانند شاخص SPI است. جدول ۲ طبقه‌بندی خشک‌سالی هیدرولوژی را بر اساس SDI نشان می‌دهد [۱۶].

جدول ۲. رده‌بندی شدت خشک‌سالی جریان در شاخص SDI

مقادیر SDI	کلاس خشک‌سالی
> ۲	ترسالی خیلی شدید
(۱,۵) تا (۲)	ترسالی شدید
(۱) تا (۱,۵)	ترسالی متوسط
(۱) تا ۰	ترسالی ملایم
۰ تا (-۱)	خشک‌سالی ملایم
(-۱) تا (-۱,۵)	خشک‌سالی متوسط
(-۱,۵) تا (-۲)	خشک‌سالی شدید
< -۲	خشک‌سالی بسیار شدید

مأخذ: منبع [۱۶]

مدل‌های استوکاستیک

به طور کلی، مدل‌های استوکاستیک شامل AR^۱، MA^۲، ARMA^۳، و ARIMA است. از ترکیب یک مدل AR از مرتبه p و یک مدل MA از مرتبه q یک مدل خودهمبسته میانگین متحرک از مرتبه p و q، ARMA(p,q) به وجود می‌آید. شرط اساسی برای استفاده از مدل ARMA ایستابودن سری زمانی است. فرم پایه مدل‌های ARMA برای متغیر نرمال استاندارد شده Z_t به صورت معادله ۱ است:

$$Z_t = \sum_{i=1}^p \varphi_i Z_{t-i} - \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad \text{for } \theta_j = -1 \quad (1)$$

مدل‌های ARIMA فرم خاصی از مدل‌های ARMA هستند که از آن‌ها برای سری‌های نایستا استفاده می‌شود که به صورت فصلی، غیر فصلی، و یا ترکیب این دو به کار می‌رود. فرم کلی مدل‌های آریما

1. Auto Regressive
4. Seasonal ARIMA

2. Moving Average
5. Periodic ARIMA

3. Auto Regressive Moving Average
6. Discrete ARIMA

در مطالعه حاضر با استفاده از نرم‌افزار MATLAB شبکه عصبی چندگامی بازگشتی تنظیم شد. الگوریتم آموزش مورد استفاده الگوریتم پس‌انتشار خطا بر مبنای روش آموزش Gradient Descent with Momentum (traingdm) و تابع انتقال مورد استفاده در لایه مخفی و خروجی به ترتیب تانزانت سیگموئید و خطی یادگیری و تعداد اپاک ۵۰۰ در نظر گرفته شد. با توجه به مطالعات پیشین، مشخص شد که برای داشتن دقت مطلوب تخمین فقط یک لایه مخفی برای شبکه عصبی کافی است، بنابراین، در مطالعه حاضر فقط یک لایه مخفی برای شبکه در نظر گرفته شد. تعداد نورون‌های ورودی و مخفی بهینه به منظور داشتن بالاترین دقت از طریق آزمون تعیین شد. بدین صورت که تعداد نورون‌های لایه ورودی از ۱ تا $n [12]$ و تعداد نورون‌های لایه مخفی از ۱ تا $2m+1$ متغیر است، که m تعداد نورون‌های ورودی متناظر است. با اجرای برنامه، کلیه این حالات بررسی شد و ساختاری که بیشترین ضریب همبستگی را داشت ساختار بهینه شبکه عصبی معرفی گردید و پیش‌بینی یک تا دوازده گام به جلو برای مقیاس ماهانه و چهار گام برای مقیاس فصلی صورت گرفت.


روش شبکه عصبی چندگامی مستقیم^۳ (DMSNN)

مزیت این مدل نسبت به مدل ARIMA داشتن خروجی‌های چندگانه است. یعنی لایه خروجی، برخلاف مدل ARIMA و مدل شبکه عصبی بازگشتی، دارای چندین نورون است و هر نورون خروجی یک گام زمانی را پیش‌بینی می‌کند [۱۲]. (شکل ۳)

مخفی با توابع تبدیل سیگموئیدی در لایه میانی قادر به تقریب کلیه توابع غیرخطی با هر درجه تقریبی هستند مشروط بر اینکه در لایه مخفی به اندازه کافی نورون داشته باشیم. تعداد لایه‌ها و نورون‌های یک شبکه در قالب معماری شبکه تعیین می‌شود. همچنین، رایج‌ترین الگوریتم آموزش الگوریتم پس‌انتشار خطا^۱ است که، طبق گزارش‌ها، ۹۰ درصد تجارب انجام‌شده در این زمینه با شبکه‌های پیش‌خور چندلایه با الگوریتم پس‌انتشار خطا صورت می‌گیرد [۹]. در این بررسی از دو روش مختلف از شبکه‌های عصبی برای پیش‌بینی چندگام به جلو استفاده شد.

روش شبکه عصبی چندگامی بازگشتی^۲ (RMSNN)

این روش از نظر اینکه دارای یک گره یا نورون خروجی است مشابه مدل ARIMA است. در این روش، بر مبنای یک گره خروجی، پیش‌بینی یک گام به جلو صورت می‌گیرد و شبکه به صورت بازگشتی با استفاده از پیش‌بینی‌های قبلی، به عنوان ورودی‌ها، برای پیش‌بینی‌های بعدی به کار برده می‌شود [۱۲] (شکل ۲).



شکل ۲. شبکه عصبی چندگامی بازگشتی

1. Back Propagation
2. Recursive multi-step neural network
3. Direct multi-step neural network

برازش داده شد. دو نوع مدل هیبرید وجود دارد: یکی مدل هیبرید شبکه عصبی بازگشتی - استوکاستیک^۱ (HSNNRA) که یک مدل ARIMA را با یک مدل شبکه عصبی چندگامی بازگشتی ترکیب می‌نماید و دیگری مدل هیبرید شبکه عصبی مستقیم - استوکاستیک^۲ (HSNNDA) که یک مدل ARIMA را با یک مدل شبکه عصبی چندگامی مستقیم ترکیب می‌کند [۱۳].


نتایج

توسعه مدل ARIMA

در مطالعه حاضر، سری‌های زمانی مقادیر SDI در مقیاس زمانی ماهانه و فصلی با استفاده از داده‌های دبی طول آماری ۳۲ سال آبی (۱۳۵۴-۱۳۸۷) محاسبه شد و ۷ سال آماری پایانی (۱۳۸۰-۱۳۸۷) برای توسعه و صحت‌سنجی مدل استفاده گردید. مراحل توسعه مدل‌های سری زمانی شامل سه مرحله شناسایی، برآورد پارامترهای مدل، و آزمون کفایت مدل است [۵، ۶].

شناسایی مدل آریما

به طور کلی، شناسایی شکل کلی یک مدل یک‌متغیره شامل دو مرحله است: مرحله اول شامل بررسی سری داده‌ها به لحاظ ایستایی و نرمال‌بودن است که در صورت نایستایی سری زمانی تفاضل (یک یا دو) برای ایجاد ایستایی و نرمال‌بودن صورت می‌گیرد [۱۹]. در مرحله دوم ساختار همبستگی زمانی داده‌های تبدیل‌شده به وسیله آزمون توابع



شکل ۳. شبکه عصبی چندگامی مستقیم

در مطالعه حاضر در مقیاس ماهانه شبکه لایه خروجی دارای ۱۲ نورون و در مقیاس فصلی دارای ۴ نورون است، که به ترتیب نشان‌دهنده گام‌های زمانی ۱ تا ۱۲ ماهه و ۱ تا ۴ فصل است. در این شبکه نیز الگوریتم آموزش، تابع انتقال، و تعداد اپاک‌ها مشابه روش شبکه عصبی چندگامی بازگشتی است.

مدل هیبرید مدل‌های استوکاستیک و شبکه

عصبی مصنوعی

یک مدل هیبرید شامل یک مدل ARIMA برای بخش خطی سری زمانی و یک مدل شبکه عصبی مصنوعی برای بخش غیرخطی است و سری غیرخطی به وسیله باقی‌مانده‌های به‌دست‌آمده بعد از برازش مدل ARIMA تشکیل می‌شود که رابطه آن به صورت معادله ۳ است.

$$Y_i = L_i + N_i \quad (3)$$



در این رابطه Y_i سری زمانی اصلی است، L_i بخش خطی بر مبنای مدل ARIMA، و N_i بخش غیرخطی بر مبنای مدل شبکه عصبی [۱۳]. در مطالعه حاضر، نخست مدل‌های ARIMA برای سری‌های زمانی مختلف SDI در هر ایستگاه در مقیاس ماهانه و فصلی به‌کار گرفته شد. سپس، سری باقی‌مانده‌ها پس از برازش مدل ARIMA بر داده‌های اصلی به‌دست آمد و، در نهایت، یک شبکه عصبی بر باقی‌مانده‌ها

1. Hybrid stochastic neural network of recursive approach
2. Hybrid stochastic neural network of direct approach



متحرک را پیشنهاد کند و PACF در گام زمانی سوم معنی‌دار است که می‌تواند یک مدل AR را پیشنهاد کند. علاوه بر این، PACF در مقیاس ماهانه، در گام‌های زمانی ۱۲، ۲۴، ۳۶، ۴۸ و در مقیاس فصلی در گام‌های زمانی ۴، ۸ و ۱۲ معنی‌دار است. بنابراین، سری در مقیاس ماهانه دارای تناوبی ۱۲ ماهه و در مقیاس فصلی دارای تناوب ۴ فصله است. بنابراین، ترکیبی از مدل‌های AR و MA به صورت مدل آریما مکتر برای مدل‌سازی این سری پیشنهاد می‌شود.

خودهمبستگی^۱ (ACF) و خودهمبستگی جزئی^۲ (PACF) تعیین می‌شود [۵]. سپس، این اطلاعات برای تعیین شکل کلی مدل یک‌متغیره استفاده می‌شود. شکل ۴ و ۵ نمودارهای ACF و PACF مربوط به سری زمانی ماهانه و فصلی ایستگاه پل چهر رودخانه گاماسیاب را نشان می‌دهد.

با توجه به شکل‌ها، ACF سری مورد نظر نایستاست که به عملگر تفاضل فصلی یا غیرفصلی برای ایستایی نیاز دارد و می‌تواند یک مدل میانگین



شکل ۴. ACF و PACF مربوط به سری زمانی ماهانه ایستگاه پل چهر



شکل ۵. ACF و PACF مربوط به سری زمانی فصلی ایستگاه پل چهر

برآورد پارامترهای مدل آریما و آزمون کفایت مدل بعد از مرحله شناسایی مدل، پارامترهای مدل منتخب با استفاده از نرم‌افزار MINITAB محاسبه شد. مقادیر پارامترهای مدل منتخب در مقیاس ماهانه و فصلی در جداول ۳ و ۴ فهرست شده است. خطای استاندارد محاسبه شده برای هر یک از پارامترهای مدل عموماً در مقایسه با پارامترها کوچک بودند. بنابراین، می‌توان از این پارامترها در مدل‌سازی استفاده کرد.

با توجه به تعداد گام‌های معنی‌دار در هر یک از نمودارهای ACF و PACF می‌توان محدودۀ تغییرات مرتبۀ مدل‌ها را به دست آورد و، در نهایت، با ترکیب آن‌ها به مدل‌های داوطلب دست یافت. مدلی که حداقل AIC^3 ، AIC^4 و SBC^5 را داشته باشد به عنوان بهترین مدل انتخاب و مدل‌سازی می‌شود.

1. Auto Correlation Function
3. Akaike Information Criterion
5. Schwarz Bayesian Criterion

2. Partial Auto Correlation Function
4. Akaike Information Criterion Corrected

توسعه مدل شبکه عصبی چندگامی بازگشتی و مستقیم

مقادیر SDI ماهانه و فصلی مربوط به سال‌های ۱۳۵۳ تا ۱۳۷۹ به عنوان ورودی و برای آموزش شبکه و مقادیر مربوط به سال‌های ۱۳۸۰ تا ۱۳۸۷ برای صحت‌سنجی مدل استفاده شد و ساختار بهینه شبکه عصبی بازگشتی و مستقیم برای دو مقیاس ماهانه در

هر ایستگاه هیدرومتری به دست آمد. به عنوان مثال، ترکیب بهینه در ایستگاه قورباغستان در مقیاس ماهانه در شبکه چندگامی بازگشتی RMSNN (۱-۳-۸) و در مقیاس فصلی (۱-۱-۵) است و در شبکه چندگامی مستقیم DMSNN در مقیاس ماهانه و فصلی به ترتیب (۱۲-۶-۱۰) و (۴-۵-۲) است.

جدول ۳. پارامترهای مدل‌های منتخب در مقیاس ماهانه در هر ایستگاه

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	t-Ratio	P < ۰/۰۵
پل چهر	ARIMA (۳۱۳)(۲۰۱) _{۱۲}	Φ_1	۰٫۲۹۸۰	۰٫۱۹۹۴	۱٫۵۰	۰٫۱۳۶
		Φ_2	-۰٫۲۹۰۲	۰٫۱۷۹۷	-۱٫۶۱	۰٫۱۰۷
		Φ_3	۰٫۳۹۱۸	۰٫۱۲۸۸	۳٫۰۴	۰٫۰۰۳
		θ_1	-۰٫۷۱۴۲	۰٫۳۶۰۷	-۱٫۹۸	۰٫۰۴۹
		θ_2	۰٫۲۰۴	۰٫۰۸۹۵	۰٫۲۳	۰٫۸۲۰
		θ_3	۰٫۲۵۶۴	۰٫۱۸۹۴	۱٫۳۵	۰٫۱۷۷
		Φ_1	-۰٫۰۰۵۲	۰٫۱۶۱۷	-۰٫۰۳	۰٫۹۷۴
		Φ_2	۰٫۵۹۸۰	۰٫۱۱۸۴	۰٫۰۵	۰٫۰۰۰
قورباغستان	ARIMA (۱۱۱)(۱۰۲) _{۱۲}	Θ_2	-۰٫۸۱۰۴	۰٫۳۵۸۸	-۲٫۲۶	۰٫۰۲۵
		Φ_1	۰٫۷۶۹۵	۰٫۰۴۳۴	۱۷٫۷۴	۰٫۰۰۰
		Φ_1	۰٫۶۳۸۰	۰٫۱۶۱۸	۳٫۹۴	۰٫۰۰۰
		θ_1	۰٫۹۵۰۴	۰٫۰۲۱۳	۴۴٫۶۸	۰٫۰۰۰
		Θ_1	۰٫۶۸۱۵	۰٫۱۶۸۵	۴٫۰۵	۰٫۰۰۰
		Θ_2	۰٫۱۳۸۲	۰٫۰۷۳۹	۱٫۸۷	۰٫۰۶۲
		Φ_1	۰٫۷۳۸۷	۰٫۰۳۸	۱۹٫۴۶	۰٫۰۰۰
		θ_1	۰٫۹۶۶۵	۰٫۰۰۶۵	۱۴۷٫۶۰	۰٫۰۰۰
کشکان	ARIMA (۱۱۱)(۰۰۱) _{۱۲}	Θ_1	۰٫۰۵۶۴	۰٫۰۵۶۴	۰٫۰/۱	۰٫۳۱۹
		Φ_1	۰٫۷۴۶۷	۰٫۰۳۳۷	۲۲٫۱۶	۰٫۰۰۰
		θ_1	۰٫۷۰۰۸	۰٫۰۵۱۵	۱۳٫۶۱	۰٫۰۰۰
		θ_2	۰٫۰۴۰۱	۰٫۰۵۲۹	۰٫۷۶	۰٫۴۴۹
		Θ_1	۰٫۷۴۶۷	۰٫۰۳۳۷	۲۲٫۱۶	۰٫۰۰۰
		Θ_2	۰٫۷۰۰۸	۰٫۰۵۱۵	۱۳٫۶۱	۰٫۰۰۰
		Θ_3	۰٫۰۴۰۱	۰٫۰۵۲۹	۰٫۷۶	۰٫۴۴۹
		Φ_1	۰٫۸۱۶۲	۰٫۰۵۴۸	۱۴٫۸۹	۰٫۰۰۰
پل زال	AR (۳۰۰)	Φ_2	-۰٫۲۶۰۱	۰٫۰۶۹۸	-۳٫۷۲	۰٫۰۰۰
		Φ_3	۰٫۱۹۹۵	۰٫۰۵۴۸	-۳٫۶۴	۰٫۰۰۰

مآخذ: یافته‌های تحقیق

جدول ۴. پارامترهای مدل‌های منتخب در مقیاس فصلی در هر ایستگاه

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	t-Ratio	P < ۰,۰۵
پل چهر	ARIMA (۱۱۱)(۰۰۳) _t	Φ_1	۰,۳۴۷۴	۰,۱۶۴۹	۲,۱۱	۰,۰۳۸
		Φ_1	۰,۸۰۷۴	۰,۱۰۷۹	۷,۴۸	۰/۰۰۰
		Θ_1	۰,۰۳۱۷	۰,۱۰۷۲	۰,۳۰	۰,۷۶۸
		Θ_2	۰,۲۶۴۵	۰,۰۹۸۱	۲,۷۰	۰,۰۰۸
		Θ_3	۰,۳۲۹۵	۰,۱۰۸۵	۳,۰۴	۰,۰۰۳
قورباغستان	ARIMA (۰۱۲)(۱۰۱) _t	Φ_1	۰,۶۹۴۸	۰,۱۱۵۱	۴,۰۶	۰/۰۰۰
		θ_1	۰,۴۸۳۴	۰,۰۹۷۶	۴,۹۵	۰/۰۰۰
		θ_2	۰,۲۵۸۵	۰,۰۹۹۳	۲,۶۰	۰,۰۱۱
		Θ_1	۰,۹۴۴۵	۰,۰۷۳۴	۱۲,۸۶	۰/۰۰۰
		ϕ_1	۰,۴۵۸۴	۰,۰۸۸۵	۵,۱۸	۰/۰۰۰
کشکان	ARIMA (۱۱۱)(۰۰۱) _t	θ_1	۰,۹۷۷۰	۰,۰۲۳۸	۴۱,۰۸	۰/۰۰۰
		Θ_1	-۰,۲۴۰۹	۰,۰۹۶۹	۲,۴۹	۰,۰۱۵
		θ_1	۰,۵۰۴۹	۰,۰۹۹۷	۵,۰۶	۰/۰۰۰
		θ_2	۰,۱۸۱۱	۰,۱۰۳۲	۱,۷۶	۰,۰۸۲
		Θ_1	۰,۲۴۳۶	۰,۱۰۵۱	۲,۳۲	۰,۰۲۲
آفرینه	ARIMA (۰۱۲)(۰۰۳) _t	Θ_2	۰,۳۷۸۱	۰,۰۹۸۷	۳,۸۳	۰/۰۰۰
		Θ_3	۰,۲۴۴۸	۰,۱۰۷۹	۲,۲۷	۰,۰۲۵
		ϕ_1	۰,۴۹۹۰	۰,۰۹۰۰	۵,۵۵	۰/۰۰۰
		Φ_1	-۰,۶۵۷۴	۰,۱۴۶۱	-۴,۴۸	۰/۰۰۰
		θ_1	۰,۹۷۳۷	۰,۰۲۹۱	-۳۳,۴۷	۰/۰۰۰
پل زال	ARIMA(۱۱۱)(۱۰۲) _t	Θ_1	-۰,۶۶۷۸	۰,۱۷۱۴	-۳,۹۰	۰/۰۰۰
		Θ_2	-۰,۲۵۲۴	۰,۱۱۷۶	۲,۱۵	۰,۰۳۴

مأخذ: یافته‌های تحقیق

توسعه مدل هیبرید

پس از برازش مدل ARIMA بر سری‌های ماهانه و فصلی، سری باقی‌مانده‌ها از اختلاف سری اصلی و سری حاصل از برازش به‌دست آمد و از مدل شبکه عصبی (به دلیل انعطاف‌پذیری بالا و قابلیت مدل‌سازی روابط غیرخطی) برای مدل‌سازی سری باقی‌مانده‌ها استفاده شد و، در نهایت، با جمع سری حاصل از برازش مدل ARIMA بر مقادیر اصلی و سری حاصل از برازش شبکه عصبی بر سری

باقی‌مانده‌ها، سری حاصل از مدل هیبرید به‌دست آمد و در مرحله بعد مقادیر SDI مربوط به سال‌های ۱۳۸۰ تا ۱۳۸۷ برای صحت‌سنجی مدل استفاده شد و نتایج مدل هیبرید با مدل آریمای و شبکه عصبی مصنوعی مقایسه گردید.

از ترکیب مدل آریمای با شبکه عصبی چندگامی بازگشتی مدل HSNRA و از ترکیب مدل آریمای با شبکه عصبی چندگامی مستقیم مدل HSNDA به‌دست می‌آید. به عنوان مثال، مدل SDI ماهانه

یک ماه آینده است ($r=0.785$)، اما با مشاهده سایر گام‌های پیش‌بینی شده در این مدل مقادیر ضریب همبستگی، RMSE، و MAE با شیب تندی تغییر می‌کنند و با افزایش گام زمانی مقدار خطا نسبت به سایر مدل‌ها افزایش بیشتری را نشان می‌دهد، این حالت در مدل DMSNN نیز مشاهده می‌شود. اما نتایج مدل هیبرید شبکه عصبی چندگامی مستقیم HSNDA با ترکیب مدل خطی $(1,0,2)$ و $(3,1,3)$ نشان می‌دهد که مدل هیبرید باعث بهبود پیش‌بینی شبکه شده است. اگرچه مقدار ضریب همبستگی ($r=0.783$) نسبت به مدل RMSNN کمتر است، مقدار خطای پیش‌بینی در سایر گام‌ها کمتر است، بنابراین، برای پیش‌بینی خشک‌سالی هیدرولوژی در زیرحوزه گاماسیاب استفاده از مدل HSNDA از دقت بالاتری نسبت به سایر مدل‌ها برخوردار است.

در ایستگاه قورباغستان واقع در زیرحوزه قره‌سو $r=0.749$ مربوط به DMSNN و $r=0.747$ مربوط به مدل HSNDA است، اما در روش DMSNN با افزایش گام پیش‌بینی میزان ضریب همبستگی بسیار متغیر است، به طوری که در گام پیش‌بینی ۱۲ به $r=-0.342$ نیز می‌رسد و دارای مقادیر بالای خطای پیش‌بینی است. اما در مدل هیبرید این شبکه با $(2,0,1)$ و $(1,1,1)$ ARIMA نتایج بسیار بهبود می‌یابد و خطای پیش‌بینی کاهش قابل ملاحظه‌ای می‌یابد. مقایسه خطای مدل HSNDA ($RMSE=0.594$) در گام دوازده پیش‌بینی نسبت به DMSNN ($RMSE=1.201$) و $(2,0,1)$ ARIMA ($RMSE=0.611$) نشان‌دهنده کارایی مناسب این مدل در این ایستگاه است.

مقایسه خطای مدل HSNDA ($RMSE=0.474$) در گام دوازده پیش‌بینی در ایستگاه کشکان نسبت

HSNNRA ایستگاه پل چهر بر اساس ترکیب مدل خطی $(1,0,2)$ و $(3,1,3)$ ARIMA و معماری شبکه عصبی مصنوعی بازگشتی (۱-۴-۸) و مدل HSNDA بر اساس ترکیب مدل خطی $(1,0,2)$ و $(3,1,3)$ ARIMA و معماری شبکه عصبی مصنوعی مستقیم (۱۲-۳-۷) خواهد بود. ترکیب سایر مدل‌ها در مقیاس ماهانه تا دوازده گام به جلو برای پنج ایستگاه تحت مطالعه صورت گرفت. همچنین، در مقیاس فصلی در ایستگاه پل چهر مدل HSNRA از ترکیب مدل خطی $(3,0,0)$ و $(1,1,1)$ ARIMA و معماری شبکه عصبی مصنوعی بازگشتی (۱-۲-۳) و مدل HSNDA بر اساس ترکیب مدل خطی $(3,0,0)$ و $(1,1,1)$ ARIMA و معماری شبکه عصبی مصنوعی مستقیم (۴-۶-۵) خواهد بود. به همین ترتیب، ترکیب سایر مدل‌ها در مقیاس فصلی تا چهار گام به جلو برای پنج ایستگاه تحت مطالعه صورت گرفت.

مقایسه نتایج مدل هیبرید با شبکه عصبی مصنوعی و آریم


کارایی مدل‌های مختلف با استفاده از ضریب همبستگی (r)، میانگین مربع خطا (RMSE)، و میانگین خطای مطلق (MAE) در گام‌های مختلف زمانی و مقیاس زمانی ماهانه و فصلی برای هر ایستگاه محاسبه شد.

مقایسه نتایج مدل هیبرید با شبکه عصبی مصنوعی و آریم در مقیاس ماهانه

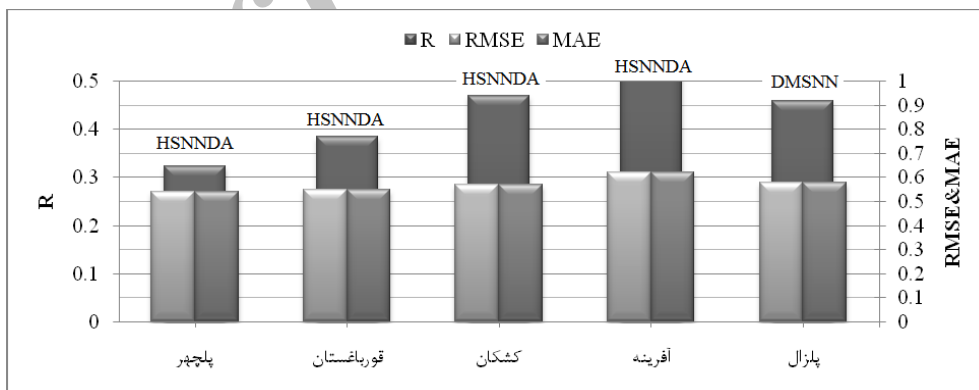
نتایج در ایستگاه پل چهر نشان می‌دهد بالاترین مقدار ضریب همبستگی بین مقادیر مشاهده‌ای و مقادیر پیش‌بینی مربوط به مدل RMSNN و در گام پیش‌بینی

سپس وارد سد کرخه می‌شود. مقادیر پیش‌بینی در این ایستگاه نشان می‌دهد که بهترین نتایج ($r=0.623$) مربوط به مدل DMSNN و ($r=0.6$) مربوط به مدل RMSNN در گام اول پیش‌بینی است. میزان ضریب همبستگی مدل DMSNN ($r=0.101$) در پیش‌بینی دوازده گام به جلو در مقایسه با مدل HSNNDRA ($r=-0.041$) و مدل HSNNDRA ($r=0.031$) درخورد توجه است. مقایسه مقادیر ضرایب تعیین برای همه ایستگاه‌ها در گام زمانی یک ماه بعد در شکل ۶ ارائه شد.

به DMSNN ($RMSE=1.201$) و $(2,0,1)$ و $(1,1,1)$ ARIMA ($RMSE=0.711$) نشان‌دهنده کارایی مناسب این مدل در این ایستگاه است و استفاده از مدل هیبرید شبکه عصبی مستقیم-آریمای می‌تواند برای پیش‌بینی خشک‌سالی چندگام زمانی بعد پیشنهاد شود. در ایستگاه آفرینه بالاترین مقدار ضریب همبستگی بین مقادیر مشاهده‌ای و مقادیر پیش‌بینی مربوط به مدل HSNNDRA ($r=0.77$) در گام پیش‌بینی یک است. ایستگاه پل زال در پایاب حوزه آبخیز بزرگ کرخه قرار دارد و همه رواناب حاصل از چهار زیرحوزه ایستگاه واقع در بالادست بدان منتقل و



شکل ۶. ضرایب تعیین مدل‌های منتخب در مقایسه زمانی ماهانه در ایستگاه‌های تحت مطالعه



شکل ۷. ضرایب تعیین مدل‌های منتخب در مقایسه زمانی فصلی در ایستگاه‌های تحت مطالعه

پل چهر مربوط به مدل HSNNDRA ($r=0.324$) و مدل خطی استوکاستیک $(3,0,0)$ و $(1,1,1)$ ARIMA با $r=0.277$ است، اما مقدار خطای پیش‌بینی در مدل

مقایسه نتایج مدل هیبرید با شبکه عصبی مصنوعی و آریمای در مقیاس فصلی بهترین نتایج پیش‌بینی در مقیاس فصلی در ایستگاه

مطالعه حاضر از دو مدل آماری (ARIMA) و مدل تخمینگر (شبکه عصبی مصنوعی مستقیم و بازگشتی) و ترکیبی از این دو مدل (مدل هیبرید) برای پیش‌بینی خشک‌سالی در مقیاس ماهانه و فصلی در حوزه آبخیز کرخه استفاده شد.

مدل ARIMA بر مبنای حافظه سری زمانی قبلی مقادیر را به صورت خطی پیش‌بینی می‌کند و در همه ایستگاه‌ها در مقیاس ماهانه دارای کارایی بهتری نسبت به مقیاس فصلی در همه گام‌های پیش‌بینی است. از آنجایی که این مدل برای پیش‌بینی هر گام به جلو از گام پیش‌بینی قبلی استفاده می‌کند، مقادیر خطای پیش‌بینی با افزایش گام زمانی به صورت تجمعی افزایش و مقادیر ضریب همبستگی کاهش می‌یابد. این حالت به وضوح در مقیاس فصلی یا ماهانه ایستگاه پل زال واقع در خروجی حوزه آبخیز کرخه، که دارای نوسانات بسیار بالای دبی در هر ماه یا فصل است و رفتاری غیرخطی دارد، به خوبی قابل لمس است. این نتایج با نتایج [۱۸] و [۱۴]، مبنی بر عملکرد بهتر مدل‌های سری زمانی در پیش‌بینی خشک‌سالی هواشناسی در استان خراسان رضوی، همخوانی ندارد، بنابراین، این مدل برای داده‌های رواناب یا خشک‌سالی هیدرولوژی با رفتار غیرخطی و ناپیدا پیشنهاد نمی‌شود.

در مورد شبکه عصبی مصنوعی بازگشتی RMSNN اگرچه در برخی ایستگاه‌ها نتایج مقادیر ضرایب تعیین نسبت به مدل ARIMA بهتر است، روند نتایج نیز به همین منوال است، زیرا این مدل نیز از گره پیش‌بینی شده قبلی برای پیش‌بینی گره بعدی استفاده می‌کند. کارایی همه مدل‌های RMSNN در تمامی ایستگاه‌ها در مقیاس ماهانه مناسب است، ولی با افزایش گام زمانی میزان کارایی آن سریعاً کاهش

خطی آریمما ($RMSE=0.601$ و $MAE=0.821$) در گام زمانی چهار فصل بعد در مقایسه با مدل HSNND ($RMSE=1.21$ و $MAE=1.38$) و HSNND ($RMSE=0.619$ و $MAE=0.864$) بهتر است.

در مقایسه نتایج مدل هیبرید با شبکه عصبی مصنوعی و آریمما در مقیاس فصلی ایستگاه قورباغستان بیشترین ضریب همبستگی ($r=0.383$) مربوط به مدل HSNND در پیش‌بینی یک گام به جلو است و مقدار خطای پیش‌بینی این مدل در این گام $RMSE=0.679$ و $MAE=0.654$ است.

نتایج مدل‌های به کار گرفته شده در ایستگاه کشکان نشان می‌دهد بیشترین ضریب همبستگی مربوط به DMSNN ($r=0.674$) و مدل هیبرید HSNND ($R=0.449$) با $(1,0,1)$ و $(2,1,0)$ ARIMA است. مقدار ضریب همبستگی در مدل HSNND در گام دو و سه پیش‌بینی کاهشی چشمگیر می‌یابد و در گام چهارم به یکباره افزایش می‌یابد.

در ایستگاه آفرینه بهترین نتایج پیش‌بینی ($r=0.555$) مربوط به مدل HSNND و مدل DMSNN ($r=0.385$) در یک گام زمانی بعد است. نتایج کارایی مدل‌ها در ایستگاه پل زال نشان می‌دهد مدل RMSNN با ضریب همبستگی 0.46 و پس از آن مدل DMSNN با ضریب همبستگی 0.328 بهتر از مدل $(2,0,1)$ ARIMA ($r=-0.61$) و HSNND ($r=0.087$) یک گام به جلو را پیش‌بینی کرده‌اند. مقایسه مقادیر ضرایب تعیین برای همه ایستگاه‌ها در گام زمانی یک فصل بعد در شکل ۷ ارائه شد.

بحث و نتیجه‌گیری

پیش‌بینی ماهانه و فصلی خشک‌سالی در تصمیم‌گیری و مدیریت منابع آبی مسئله‌ای مهم به‌شمار می‌رود. در

HSNND در پیش‌بینی خشک‌سالی هواشناسی در حوزه آبخیز کانسباتی^۱ هند، همخوانی ندارد.

در روش سری‌های زمانی عدم قطعیت در پیش‌بینی مقادیر SDI ناشی از احتمال در نظر گرفته می‌شود، در صورتی که در روش‌های هوش مصنوعی این عدم قطعیت ناشی از عدم قطعیت در عامل‌ها و غیرخطی بودن فرایند تحت بررسی است. فرایند خشک‌سالی هیدرولوژی، که از تأثیر عوامل مختلفی بر رواناب به‌وجود می‌آید، فرایندی غیرخطی است، اما در خشک‌سالی هواشناسی مقادیر بارش به‌طور مستقیم دخالت داده می‌شود و فرایندی احتمالاتی و مارکف است.

به‌طور کلی، با توجه به نتایج عملکرد بهتر مدل HSNND نسبت به سایر مدل‌ها، این مدل برای پیش‌بینی خشک‌سالی هیدرولوژی در حوزه آبخیز کرخه پیشنهاد می‌شود.

نتایج حاصل از پیش‌بینی ماهانه نسبت به پیش‌بینی فصلی کارایی بهتری دارد، بنابراین، پیشنهاد می‌شود برای بهبود نتایج در مقیاس فصلی از سایر پارامترهای ورودی مانند آمار رژیم برف ایستگاه‌ها و بارندگی استفاده شود.

در پایان، پیشنهاد می‌شود، برای مدیریت صحیح منابع آبی در این حوزه، پیش‌بینی خشک‌سالی هیدرولوژی با سایر ابزارهای پیش‌بینی، مثل موجک، مدل هیبرید موجک - شبکه عصبی مصنوعی، و ماشین بردار پشتیبان، و کاربرد سایر پیش‌بینی‌کننده‌ها، مثل سیگنال اقلیمی، بارندگی، و خروجی‌های مدل GCM، صورت گیرد.

می‌یابد، زیرا در این شبکه، با افزایش گام زمانی، خطا به صورت تجمعی افزایش می‌یابد. کارایی این مدل در مقیاس فصلی نیز بسیار پایین است، زیرا، علاوه بر خطای اندازه‌گیری که به صورت میانگین در داده‌های فصلی وارد شده است، مقادیر خطای تجمعی نیز بدان اضافه می‌شود. اما در مدل هیبرید آن با ARIMA سبب بهبود مدل می‌شود و در اکثر ایستگاه‌ها در مقیاس ماهانه دارای جواب قابل قبولی است و در مقیاس فصلی جواب نسبتاً مناسبی دارد، اما همانند مدل غیرهیبرید آن، با افزایش گام زمانی، مقدار ضریب همبستگی کاهش چشمگیری دارد. این بخش از نتایج با نتایج [۱۳]، مبنی بر عملکرد بهتر شبکه هیبرید آریمما و شبکه عصبی مصنوعی بازگشتی در مقایسه با کارست مجزای مدل، همخوانی دارد.

مدل شبکه عصبی مستقیم DMSNN، برخلاف مدل RMSNN و ARIMA، چندین نورون خروجی دارد و هر نورون به صورت مستقل یک گام زمانی را پیش‌بینی می‌کند، بنابراین، مقادیر ضرایب خطا افزایش تجمعی نداشته و در همه ایستگاه‌ها بهترین خروجی را ارائه داده است. در مدل هیبرید این شبکه با آریمما (HSNND) نتایج در مقایسه با مدل مجزای آن بهبود چشمگیری دارد و بهترین مقادیر ضریب همبستگی را ارائه داده است، زیرا در مدل هیبرید آن، علاوه بر کاربرد حافظه سری زمانی (مدل آریمما)، از روابط ریاضی بین مقادیر داده‌ها (شبکه عصبی مصنوعی) نیز بهره برده و نتایج بسیار مناسب‌تری ارائه کرده است. این نتایج با نتایج [۱۱]، مبنی بر کارایی بهتر مدل A

1. Kansabati

References

- [1]. Alley, W.M. (1984). The Palmer Drought Severity Index: limitations and assumptions. *Journal of Climate and Applied Meteorology* 23, 1100-1109.
- [2]. Akaike, H. (1974). A new look at the statistical model identification: *Journal of IEEE Transactions on Automatic Control* 19, 716-723.
- [3]. Basheer, I.A., Hajmeer, M. (2000). Artificial Neural Networks: Fundamental, Computing, Design and Applications. *Journal of Microbiology Methods* 43,3-31.
- [4]. Ben-Zvi, A. (1987). Indices of hydrological drought in Israel. *Journal of Hydrology*, 92:179-191.
- [5]. Box, GEP., Jenkins, GM., Reinsel, GC. (1994). Time series analysis, 'forecasting and control.' *Water Resources press*, 480 p.
- [6]. Bras, R.L., Rodriguez-Iturbe, I. (1985). Random functions and hydrology, *Addison-Wesley press*, 627 p.
- [7]. Karamouz, M., and Zahraie, B. (2004). Seasonal stream flow forecasting using snow budget and El Niño-southern oscillation climate signals: Application to the Salt River Basin in Arizona. *Journal of Hydrologic Engineering*, 9(6), 523-533.
- [8]. Karamouz, M., Araghinezhad, S. (2002). Advanced hydrology. University of Amirkabir Press, 250 p.
- [9]. Kim, T., Valdes, J.B., Aparicio, j. (2003). Frequency and spatial characteristics of drought in the Conches River Basin, Mexico. *Journal of Water International*,27(3),420-430.
- [10]. McKee, T.B., Doesken, N.J., Kleist, J. (1993). The relationship of drought frequency and duration to time scales. Preprints. 8th Conference on Applied Climatology, California, America. pp. 179-184.
- [11]. Mishra, A.K., Desai, V.R. (2005). Drought forecasting using stochastic models, *Environment Research Risk Assess*, 19, 326-339.
- [12]. Mishra, A.K., Desai, V.R. (2006). Drought Forecasting Using feed-forward recursive neural network, *Journal of Ecological Modelling*, 198, 127-138.
- [13]. Mishra, A.K., Desai, V.R., Singh, P. (2007). Drought Forecasting Using Hybrid Stochastic and Neural Network Model, *Journal of Hydrologic Engineering*, 6(626),1084-0699.
- [14]. Morid, S., Smakhtinb, V., Bagherzadehc, K. (2007). Drought forecasting using artificial neural networks and time series of drought indices. *Journal of Climatology* 27, 2103-2111.
- [15]. Nalbantis, I. (2008). Evaluation of hydrological drought index. *European Water*, 23(24), 67-77.
- [16]. Nalbantis, N., Tsakiris, G. (2009). Assessment off hydrological drought revisited. *Journal of water resource management* 23, 883-897.
- [17]. Rao, AR., Padmanabhan, G. (1984). Analysis and modelling of Palmers drought index series. *J Hydrol* 68,211-229.
- [18]. Salajegheh, A., Fathabadi, H., Najafi Hajivari, M. (2008). Comparison of Time series model and Artificial Neural Network in Drought forecasting (Case study: Khorasane Razavi Province). *Journal of Iran Watrershed Management Science & Engineering*, 2(4), 74-77.
- [19]. Salas, J.D., Delleur, J.W., Yevjevich, V., Lane W.L. (1988). Applied modeling of hydrological time series, *Water Resources Publication*, 483 p.
- [20]. Schwartz, G. (1978). Estimating the dimension of a model. *Ann Stat*, 6, 461-464.

- [21]. Shafer, B.A., Dezman, L.E. (1982). Development of surface water supply Index (SWSI) to Assess the Severity of Drought Conditions in SnowPack Runoff Areas. 50th Annual Western Snow Conference. Reno, Nevada.
- [22]. Shalamu, A., Chun-Liang, C., James, K., Kaiser, A. (2010). Comparison of performance of statistical models in forecasting monthly stream flow of Kizil River, China. *Water Science and Engineering*, 3(3), 269-281.

Archive of SID