

بررسی مهارت و کارایی مدل‌های هیبرید شبکه عصبی مصنوعی -

استوکاستیک در پیش‌بینی

خشکسالی‌های هیدرولوژی با استفاده از آماره کاپا (مطالعه موردی: حوزه

آبخیز رودخانه گاماسیاب)

ام البنین بذرافشان^۱، علی سلاجقه^۲، احمد فاتحی مرج^۳، محمد مهدوی^۴، جواد بذرافشان^۵،

سمیه حجابی^۶ و مهشیدسوری^۷

۱- دانشجوی دوره دکترای تخصصی مهندسی منابع طبیعی- آبخیزداری OBazrafsha@ut.ac.ir

۲- عضو هیات علمی دانشکده منابع طبیعی، دانشگاه تهران.

۳- عضو هیات علمی مرکز تحقیقات خشکسالی مرکز تحقیقات کم آبی و خشکسالی در کشاورزی و منابع طبیعی.

۴- استادیار، گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران.

۵- دانشجوی کارشناسی ارشد هواشناسی کشاورزی، گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران.

۶- عضو هیات علمی دانشکده منابع طبیعی- دانشگاه ارومیه.

چکیده

خشکسالی یک رخداد طبیعی تکرارشونده و موقتی است که ناشی از کاهش بارندگی نسبت به میانگین بلندمدت آن می‌باشد و می‌تواند در هر اقلیمی رخ دهد. از آنجائی که خشکسالی پدیده‌ای تصادفی و غیرخطی است، استفاده از مدل‌های استوکاستیک خطی، شبکه عصبی مصنوعی و مدل‌های هیبرید می‌تواند در توسعه نتایج پیش‌بینی مفید باشد. مطالعه حاضر به بررسی کارایی مدل‌های *ARIMA*، شبکه عصبی مصنوعی و مدل هیبرید آریما - شبکه عصبی مصنوعی در پیش‌بینی خشکسالی هیدرولوژی در دو مقیاس زمانی ماهانه و فصلی می‌پردازد و شاخص *SDI* بعنوان شاخص پیش‌بینی کننده در حوزه آبخیز گاماسیاب انتخاب گردید. نتایج نشان دادند که در تمام گام‌های پیش‌بینی، ترکیب مدل‌های شبکه عصبی- استوکاستیک (هیبرید) نتیجه بسیار مناسب‌تری نسبت به مدل مجزای آن‌ها در مقیاس ماهانه دارد و آماره کاپا نیز در مدل هیبرید دارای حداکثر میزان توافق بین مقادیر مشاهده‌ای و پیش‌بینی شده است.

واژگان کلیدی: خشکسالی هیدرولوژی، پیش‌بینی، مدل‌های هیبرید، شاخص *SDI*، حوزه آبخیز گاماسیاب.

مقدمه

درازمدت سالانه باشد، به طوری که در ۱۳ سال از ۲۳ سال

گذشته این حالت در کشور استوار بوده است.

پیش‌بینی خشکسالی هیدرولوژی یکی از مهمترین اهداف در مدیریت و برنامه ریزی منابع آبی بشمار می‌رود. پیش‌بینی میان مدت یا بلند مدت خشکسالی در مقیاس هفتگی، ماهانه، فصلی و یا سالانه می‌تواند راهبرد مفیدی در جهت تخصیص و مدیریت آب در بخش آبیاری یا مخازن ذخیره آب و همچنین وضع قوانین مرتبط با برنامه‌ریزی و مدیریت منابع آب باشد. متداول‌ترین روش‌ها برای پیش‌بینی مقوله خشکسالی استفاده از مدل‌های استوکاستیکی و مدل‌های مفهومی است. پیش‌بینی دترمینستیکی و استوکاستیکی خشکسالی بیش از هر فرایند دیگر نظر هیدرولوژیست‌ها را به خود جلب نموده

از چهل بلای طبیعی که در کشورهای جهان وجود دارد، ۳۱ مورد آن در ایران اتفاق افتاده است که خشکسالی به دلیل گستردگی و تبعات کوتاه مدت و بلند مدت اقتصادی، اجتماعی و زیست‌محیطی، از مهمترین آنها محسوب می‌شود. خشکسالی بر خلاف سایر بلایا به آرامی آغاز می‌شود، پیشروی نموده و موجب نابودی منابع می‌شود. گر چه امروزه به علت پیشرفت‌های علمی و گسترش ارتباطات و حمل و نقل بروز آثار خشکسالی به شکل قحطی و مرگ دسته جمعی کمتر بروز می‌کند، اما آثار و تبعات دیگر ناشی از خشکسالی همچنان پا برجاست. قرارگیری ایران در نواحی خشک و بیابانی سبب شده که میزان بارندگی در برخی دوره‌ها کمتر از میانگین

است. پدیده خشکسالی در بعد مکان و زمان بیشترین تغییرات را داشته و شبیه سازی آنها به لحاظ سرشت غیر خطی و ابعاد زیاد آن همواره با مشکلات زیادی روبرو بوده است (Karamouz & Araghinezhad, 2002).

کومار^۱ و همکاران در سال ۲۰۰۷ طی مقاله‌های با عنوان پیش بینی بارش با استفاده از سیگنال‌های اقلیمی و هوش مصنوعی در منطقه یاوراسیابه بررسی پیش‌بینی بارش در مقیاس زمانی ماهانه و فصلی پرداختند. در این تحقیق ارتباط بین بارندگی منطقه وسیگنالهای بزرگ مقیاس مانند نوسانات جنوبی ENSO، نوسانات اقیانوس هند و شاخص‌های محلی مانند دمای سطح اقیانوس OLTC مورد بررسی قرار گرفت و نتایج به دست آمده حاکی از مطلوبیت شبکه عصبی در پیش‌بینی بارش می‌باشد. میشرا و همکاران (۲۰۰۷) یک مدل هیبرید که ترکیبی از مدل استوکاستیک خطی و مدل شبکه عصبی مصنوعی غیر خطی است، برای پیش‌بینی خشکسالی استفاده کردند. مدل هیبرید در مقایسه با سایر مدل‌ها دارای دقت بالاتری بود. نالبانتیس (۲۰۰۸) شاخص SDI^۲ را برای محاسبه خشکسالی هیدرولوژی در چهار مقیاس ۳، ۶، ۹ و ۱۲ ماهه استفاده کردند.

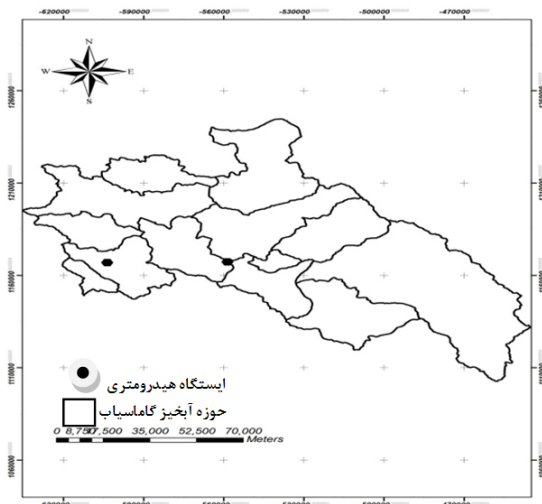
هانگ^۳ و همکاران در ۲۰۰۸ به بررسی پیش‌بینی بارش با استفاده از شبکه عصبی در بانکوک (تایلند) پرداختند. در این تحقیق از بین ۶ مدل آنالیز شبکه عصبی مدل Feed forward شبکه و Hyperbolic تابع تانژانت استفاده شد و نسبت رطوبت، فشار هوا، دمای بلب خشک، ابرناکیو میزان بارش به عنوان ورودی انتخاب گردیدند. نتایج به دست آمده نشان می‌دهد شبکه عصبی به منظور پیش‌بینی بارش مطلوب می‌باشد.

با توجه به پیشینه بررسی که در بالا به برخی از موارد آن اشاره شد، هدف از ارائه این مقاله ترکیب مدل‌های استوکاستیک و شبکه عصبی مصنوعی و توسعه مدل هیبرید و استفاده از شاخص استاندارد شده جریان (SDI) بعنوان فاکتور پیش‌بینی کننده جهت پیش‌بینی

خشکسالی هیدرولوژی و مقایسه نتایج آن با هر یک از این مدل‌ها به تنهایی است.

کارآموز و همکاران (۱۳۸۱) به بررسی کارایی شبکه عصبی مصنوعی در مدل سازی هیدرواقلمی پیش‌بینی جریان ورودی رودخانه زاینده رود به مخزن سد آن پرداختند. جهت پیش‌بینی بلندمدت جریان رودخانه از دو رویکرد مختلف استفاده نمودند.

حوزه آبخیز گاماسیاب در غرب کشور، در مناطق میانی و جنوبی زاگرس قرار دارد و دارای مساحتی بالغ بر ۱۱۶۹۰ کیلومترمربع است که حداکثر ارتفاع آن ۳۵۸۰ متر و حداقل ارتفاع آن ۱۲۴۲ است. این حوزه آبخیز یکی از زیرحوزه‌های اصلی رودخانه بزرگ کرخه را تشکیل می‌دهد و با داشتن دو رودخانه اصلی گاماسیاب و دیناور نقش مهمی در آبدهی حوزه آبخیز کرخه دارا می‌باشد. از نظر مختصات جغرافیایی بین ۳۵'، ۴۷° و ۱۰'، ۴۸° طول شرقی و بین ۳۰'، ۳۵° و ۵۶'، ۳۴° عرض شمالی قرار گرفته است (شکل ۱). در این حوزه دو ایستگاه هیدرومتری واقع در میانه و پایاب انتخاب و مورد تجزیه و تحلیل قرار گرفت



شکل ۱- موقعیت ایستگاه‌های هیدرومتری و حوزه آبخیز گاماسیاب

جدول ۱- ویژگی‌های ایستگاه‌های واقع در حوزه آبخیز کرخه

مشخصات آماری سری سالانه دبی (۱۹۷۴-۲۰۰۸)				مشخصات جغرافیایی				
نام	نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی	عرض جغرافیایی	میانگین دبی (m ³ /s)	انحراف معیار	حداقل	حداکثر
گاماسیاب	دوآب	۱۴۱۰	۴۷° ۵۴'	۳۴° ۲۲'	۱۵/۴	۷/۶	۴/۰۶	۳۲/۴
زیرحوزه	پل چهر	۱۳۰۶	۴۷° ۲۶'	۳۴° ۲۰'	۳۲/۵	۱۵/۲	۶/۲	۷۷/۳

شاخص SDI بعنوان شاخص پیش‌بینی کننده جریان

جهت مطالعه خشکسالی هواشناسی شاخص‌های متعددی ابداع گردیده است، که معروفترین آنها تحت عنوان شاخص بارش استاندارد⁴ SPI (McKee et al, 1993) می‌باشد. که برای خشکسالی هیدرولوژی می‌توان از شاخصی شبیه شاخص بارش استاندارد تحت عنوان شاخص خشکسالی جریان (SDI) استفاده نمود که براساس جریان ماهانه استاندارد می‌باشد و اولین بار توسط Ben-Zvi (1987) پیشنهاد گردید. اصول این شاخص همانند شاخص SPI می‌باشد.

طبقه بندی خشکسالی هیدرولوژی بر اساس SDI در جدول ۲ آمده است (Nalbantis & Tsakiris, 2009).

$$SDI = \frac{Q_i - \bar{Q}}{sd} \quad (1)$$

Q_i : جریان در ماه i

\bar{Q} : میانگین جریان در طول دوره آماری (یا هر سطح

برش دیگر)

Sd : انحراف معیار جریان

جدول ۲- رده بندی شدت خشکسالی جریان در شاخص SDI

مقادیر SDI	کلاس خشکسالی
> 2	ترسالی خیلی شدید
$(1/5)$ تا (2)	ترسالی شدید
(1) تا $(1/5)$	ترسالی متوسط
0 تا (1)	ترسالی ملایم
0 تا (-1)	خشکسالی ملایم
(-1) تا $(-1/5)$	خشکسالی متوسط
$(-1/5)$ تا (-2)	خشکسالی شدید
< -2	خشکسالی بسیار شدید

مدل‌های تصادفی

مدل‌های خودهمبسته (AR)⁵ ساده‌ترین نوع مدل‌های پیوسته‌اند که به طور کلی به دو دسته قابل تقسیم‌اند:

الف) مدل‌های AR با پارامترهای ثابت که برای مدل‌سازی سری‌های زمانی سالانه رایج می‌باشند. مدل‌های AR توانایی لازم برای مدل‌سازی جریان کم رودخانه در فصول کم‌آب (با نوسانات کم) که عمدتاً از منابع آب زیرزمینی تامین می‌شود را دارند اما در فصول

پرآب (با نوسانات زیاد) می‌توان با اضافه کردن مولفه مدل میانگین متحرک (MA) به مدل‌های AR نتایج مدل‌سازی را بهبود بخشید. 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) را بوجود می‌آورند. شرط اساسی برای استفاده از مدل ARMA ایستا بودن سری زمانی است. فرم پایه مدل‌های ARMA برای متغیر نرمال استاندارد شده Z_t به صورت زیر است:

$$Z_t = \sum_{i=1}^p \phi_i Z_{t-i} - \sum_{j=0}^q \theta_j \varepsilon_{t-j} \quad \text{for } \theta_0 = -1 \quad (2)$$

اگر یک سری زمانی ایستا نباشد، می‌توان با استفاده از عملگر تفاضل، آن سری زمانی را ایستا نمود. استفاده از d امین تفاضل سری و مدل‌سازی آن با ARMA(p,q) منجر به پیدایش سری جدیدی از مدل‌های غیرفصلی خود-همبسته میانگین متحرک تجمعی (ARIMA(p,d,q)) می‌شود. فرم پایه مدل ARIMA غیرفصلی به صورت زیر است:

$$\phi(B)(1-B)^d Z_t = \theta(B)\varepsilon_t \quad (3)$$

که $\phi(B)$ و $\theta(B)$ به ترتیب چندجمله‌ای مرتبه p مدل AR و چندجمله‌ای مرتبه q مدل MA می‌باشند و از روابط زیر بدست می‌آیند:

$$\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (4)$$

$$\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (5)$$

در صورت استفاده از عملگر تفاضل فصلی با تاخیر w و برآزش آنها با مدل‌های ARMA(p,q) فصلی $ARIMA(P,D,Q)_w$ بوجود می‌آید. ترکیبی از مدل‌های فصلی و غیرفصلی، مدل‌های موسوم به آریمای مکرر^۶ را تشکیل می‌دهند. فرم پایه مدل آریمای مکرر به صورت زیر است:

$$\Phi_P(B^w)\phi_p(B)(1-B^w)^D(1-B)^d Z_t \quad (6)$$

$$= \Theta_Q(B^w)\theta_q(B)\varepsilon_t$$

که p مرتبه مدل AR غیرفصلی، P مرتبه مدل AR فصلی، q مرتبه مدل MA غیرفصلی، Q مرتبه مدل MA فصلی، w طول فصل، ε_t متغیر تصادفی (اغتشاش خالص)، عملگر تفاضل به صورت $B(Z_t) = Z_{t-1}$ ،

$(1-B)^d$ معادل d امین تفاضل غیرفصلی و $(1-B^w)^D$ معادل D امین تفاضل فصلی به اندازه w می باشد.

ترکیب مدل‌های ARIMA و شبکه عصبی (هیبرید)

برای مدلسازی سری باقیمانده‌ها، شبکه عصبی به دلیل توانایی مدلسازی روابط غیرخطی، مناسب هستند. بنابراین یک مدل هیبرید شامل یک مدل ARIMA برای بخش خطی سری زمانی و یک مدل ANN برای بخش غیرخطی است. سری غیرخطی به وسیله باقیمانده‌های بدست آمده بعد از برازش مدل ARIMA تشکیل می‌شود.

$$Y_i = Li + Ni \quad (12)$$

که Y_i سری زمانی اصلی، Li بخش خطی بر مبنای مدل ARIMA و Ni بخش غیرخطی بر مبنای مدل شبکه عصبی است. در این مطالعه، ابتدا، مدل‌های ARIMA برای سری‌های زمانی مختلف SDI به کار برده شد. سپس، یک سری باقیمانده‌ها پس از برازش مدل ARIMA بر داده‌های اصلی بدست آمد و در نهایت، یک شبکه عصبی بر باقیمانده‌ها برازش داده شد و مدل هیبرید مدل ARIMA را با یک مدل شبکه عصبی چندگامی مستقیم ترکیب می‌کند $(HSNND)$.


آماره‌ی کاپا

آماره‌ی کاپا نخستین بار توسط کوهن به عنوان معیار اندازه‌گیری توافق در علم روان‌شناسی معرفی شد. فرض کنید P_{ij} نسبت کل اجزایی از سری زمانی است که به طبقه‌ی i از یک سری و به طبقه‌ی j از سری دوم اختصاص دارد. این نسبت‌ها می‌توانند داخل یک ماتریس شکل بگیرند که قطر اصلی آن شامل نسبت‌های منحصراً بفرده P_{ii} اجزایی است که در هر دو سری مطابقت دارند. مجموع مقادیر P_{ii} است. با در نظر گرفتن Pe, ii به عنوان حاصل ضرب مجموع نسبت‌های ردیف و ستون مربوطه $(Pe, ii = P_i \cdot P_i)$ ، مقدار قابل انتظار توافق، برابر است با جمع مقادیر Pe, ii ؛ این جمع را Pe می‌نامیم. آماره‌ی کاپا به صورت زیر تعریف می‌شود:

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (13)$$

لندیس و کوچ، پیشنهاد کردند که مقادیر K کمتر از ۰/۴ نشان‌دهنده‌ی توافق ضعیف تا خیلی ضعیف بوده، مقادیر ۰/۴۰-۰/۵۵ نشان‌دهنده‌ی توافق متوسط، مقادیر ۰/۵۵-۰/۷۰ نشان‌دهنده‌ی توافق خوب و مقادیر بیش از

روش شبکه عصبی چندگامی مستقیم $(DMSNN)$: در این مطالعه از روش از شبکه‌های عصبی مستقیم برای پیش‌بینی چندگام به جلو استفاده شد. مزیت این مدل نسبت به مدل ARIMA داشتن خروجی‌های چند-گانه است. یعنی لایه خروجی برخلاف مدل ARIMA و مدل شبکه عصبی بازگشتی دارای چندین نرون است و هر نرون خروجی یک گام زمانی را پیش‌بینی می‌کند. (شکل ۲)



شکل ۲- شبکه عصبی چندگامی مستقیم

در مطالعه حاضر شبکه لایه خروجی دارای ۱ نرون است که نشان‌دهنده گام‌های زمانی ۱ ماهه و برای فصلی هم فصل بعد می باشد. برنامه‌ای با استفاده از نرم‌افزار MATLAB برای شبکه عصبی یک گامه مستقیم نوشته شد. الگوریتم آموزش مورد استفاده، الگوریتم پس‌انتشار-خطا و تابع انتقال مورد استفاده در لایه مخفی و خروجی به ترتیب تانژانت سیگموئید و خطی بود. سرعت یادگیری، ضریب مومنتوم و تعداد اپاک به ترتیب برابر ۰/۰۱، ۰/۹ و ۵۰۰ در نظر گرفته شد و تنها یک لایه مخفی برای شبکه در نظر گرفته شد. تعداد نرون‌های ورودی و مخفی بهینه به منظور داشتن بالاترین دقت، مشابه روش بازگشتی از طریق آزمون تعیین شد و مقدار n برابر با ۲۰ در نظر گرفته شد و تعداد نرون‌های لایه مخفی از ۱ تا $2m+1$ متغیر بود. با اجرای برنامه کلیه حالات بررسی شد و ساختاری که بیشترین ضریب همبستگی را داشت به عنوان ساختار بهینه شبکه عصبی معرفی شد.

$$t = \frac{K}{\sqrt{\frac{\sum w_{ij}^2 P_{e,ij} - (\sum w_{ij} P_{e,ij})^2}{n(\sum w_{ij} P_{e,ij})^2}}} \quad (15)$$

که n تعداد مشاهدات سری است.

نتایج و بحث

توسعه مدل ARIMA و برآورد پارامترها

بعد از مرحله شناسایی مدل، پارامترهای مدل منتخب با استفاده از نرم‌افزار MINITAB در مقیاس ماهانه و فصلی محاسبه شد. مقادیر پارامترهای مدل منتخب در جدول 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.

۰/۷۰ نشان‌دهنده‌ی توافق خیلی خوب تا عالی می‌باشند. در مقایسه‌ی طبقات SPI در سری‌های مشاهده‌شده و پیش‌بینی‌شده، عدم توافق بین طبقه‌ی خشکسالی خفیف و خشکسالی متوسط به بزرگی عدم توافق بین طبقه‌ی خشکسالی خفیف و خشکسالی شدید نیست. از این‌رو با در نظر گرفتن وزن‌های معین برای هر یک از حالات عدم توافق می‌توان مقایسه‌ی دقیق‌تری از طبقات SPI در سری‌های مشاهده‌شده و پیش‌بینی‌شده داشت. با در نظر گرفتن وزن w_{ij} برای عدم توافق در درایه‌ی ij ماتریس، عدم توافق وزنی از مجموع حاصل ضرب نسبت P_{ij} در w_{ij} بدست می‌آید. بنابراین، آماره‌ی کاپای وزنی از رابطه زیر بدست می‌آید:

$$K = 1 - \frac{\sum w_{ij} P_{ij}}{\sum w_{ij} P_{e,ij}} \quad (14)$$

آماره‌ی آزمون معنی‌داری آماره‌ی کاپای وزنی با فرضیه‌ی صفر عدم توافق، به صورت زیر است:

جدول ۳- پارامترهای مدل‌های منتخب در مقیاس ماهانه

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	t-Ratio	P < 0.05
پل چهر	ARIMA(۳۱۳)(۲۰۱) _{۱۲}	\square_1	۰/۲۹۸	۰/۱۹۹۴	۱/۵	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	۰/۰۲۰۴	۰/۰۸۹۵	۰/۲۳	۰/۸۲
		θ_3	۰/۲۵۶۴	۰/۱۸۹۴	۱/۳۵	۰/۱۷۷
		Φ_1	-۰/۰۰۵۲	۰/۱۶۱۷	-۰/۰۳	۰/۹۷۴
		Φ_2	۰/۵۹۸	۰/۱۱۸۴	۰/۰۵	۰
		Θ_2	-۰/۸۱۰۴	۰/۳۵۸۸	-۲/۲۶	۰/۰۲۵
		\square_1	۰/۷۶۹۵	۰/۰۴۳۴	۱۷/۷۴	۰
		Φ_1	۰/۶۳۸	۰/۱۶۱۸	۳/۹۴	۰
		دوآب	ARIMA(۲۱۱)(۱۰۰) _{۱۲}	\square_1	-۰/۸۷۶۹	۰/۰۷۵
\square_2	-۰/۰۰۸۸			۰/۰۵۸۳	-۰/۱۵	۰/۸۸
Φ_1	-۰/۱۰۸۵			۰/۰۵۷۵	-۱/۸۹	۰/۰۶
θ_1	-۰/۹۲۵۱			۰/۰۴۹۸	-۱۸/۵۸	0

جدول ۴- پارامترهای مدل‌های منتخب در مقیاس ماهانه

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	t-Ratio	P < 0.05
پل چهر	ARIMA (111)(003) _f	\square_1	۰/۳۴۷۴	۰/۱۶۴۹	۲/۱۱	۰/۰۳۸
		Φ_1	۰/۸۰۷۴	۰/۱۰۷۹	۷/۴۸	۰
		Θ_1	۰/۰۳۱۷	۰/۱۰۷۲	۰/۳	۰/۷۶۸
		Θ_2	۰/۲۶۴۵	۰/۰۹۸۱	۲/۷	۰/۰۰۸
		Θ_3	۰/۳۲۹۵	۰/۱۰۸۵	۳/۰۴	۰/۰۰۳
		Φ_1	۰/۶۹۴۸	۰/۱۱۵۱	۴/۰۶	۰
		θ_1	۰/۲۸۳۹	۰/۰۹۸۷	۲/۹	۰/۰۰۵
دوآب	ARIMA (013)(002) _f	θ_2	۰/۱۹۷۹	۰/۱۰۲	۱/۹۴	۰/۰۵۵
		θ_3	۰/۲۳۵۱	۰/۱۰۱	۲/۳۳	۰/۰۲۲
		Θ_1	۰/۰۱۵۵	۰/۱۰۴۹	۰/۱۵	۰/۸۳۳
		Θ_2	۰/۲۶۹۷	۰/۱۰۴۳	۱/۵۸	۰/۰۱۱

توسعه مدل هیبرید

پس از برازش مدل ARIMA بر سری SDI سری باقیمانده‌ها از اختلاف سری اصلی و سری حاصل از برازش به دست آمد. آزمون‌های مختلف بیانگر این بودند که باقیمانده‌ها اغتشاش خالص هستند، و هیچ‌گونه ساختار رابطه خطی در سری باقیمانده‌ها مشاهده نمی‌شود. بنابراین 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 به دست آمد.

ویژگی‌های آماری اصلی بین مقادیر مشاهده‌شده و پیش‌بینی‌شده با استفاده از آزمون Z برای میانگین و آزمون F برای انحراف استاندارد مقایسه شد. نتایج در جدول ۵ و ۶ ارائه شده است.

طبق جدول ارائه شده برای ضریب همبستگی و حداقل مربعات خطا در دو مقیاس ماهانه و فصلی، بیشترین ضریب و کمترین خطا مربوط به مدل هیبرید می‌باشد. همچنین دقت مدل در مدل‌های فصلی بسیار پایین است.

ویژگی‌های آماری اصلی بین مقادیر مشاهده‌شده و پیش‌بینی‌شده با استفاده از آزمون Z برای میانگین و آزمون F برای انحراف استاندارد مقایسه شد. نتایج در جدول ۵ و ۶ ارائه شده است. از آنجایی که مقادیر Z محاسبه‌شده، بین مقادیر بحرانی جدول Z (۱.۹۶±) برای سطح معنی‌داری ۵٪ قرار داشتند، در نتیجه تفاوت معنی‌داری بین میانگین مقادیر مشاهده‌شده و پیش‌بینی‌شده وجود نداشت.

توسعه مدل شبکه عصبی مصنوعی

چندگامی مستقیم

مقادیر SDI ماهانه و فصلی مربوط به سال‌های ۱۳۵۳ تا ۱۳۷۹ برای آموزش شبکه و مقادیر مربوط به سال‌های ۱۳۸۰ تا ۱۳۸۷ برای صحت‌سنجی مدل استفاده شد. ساختار بهینه شبکه عصبی مستقیم برای مقادیر دو مقیاس ماهانه و فصلی محاسبه و ویژگی‌های آماری اصلی بین مقادیر مشاهده‌شده و پیش‌بینی‌شده با استفاده از آزمون Z برای میانگین و آزمون F برای انحراف استاندارد مقایسه شد. نتایج در جدول ۵ و ۶ ارائه شده است. از آنجایی که مقادیر Z محاسبه‌شده، بین مقادیر بحرانی جدول Z (۱.۹۶±) برای سطح معنی‌داری ۵٪ قرار داشتند، در نتیجه تفاوت معنی‌داری بین میانگین مقادیر مشاهده‌شده و پیش‌بینی‌شده وجود ندارد.

جدول ۵- مقایسه میانگین و انحراف استاندارد مقادیر SDI مشاهده شده و پیش‌بینی شده بوسیله آزمون Z و F در مقیاس ماهانه

نام ایستگاه	مدل	واریانس مشاهده شده	واریانس پیش‌بینی شده	F	میانگین مشاهده شده	میانگین پیش‌بینی شده	Z
پل چهر	ARIMA(۳۱۳)(۲۰۱) _{۱۲}	۱/۱۹	۰/۶۸	۰/۵۷	-۰/۴۹۸	-۰/۵۳۵	۰/۲۴
دوآب	ARIMA(۲۱۱)(۱۰۰) _{۱۲}	۰/۵۷۴	۰/۵۷۸	۰/۹۷	-۰/۷۲۱	-۰/۷۲۶	-۰/۰۴۳
پل چهر	DMSNN (۲-۱-۱)	۱/۱۹	۰/۴۹	۰/۴۱	-۰/۴۹۸	-۰/۴۴۴	۰/۳۸
دوآب	DMSNN (۴-۸-۱)	۰/۵۷۴	۰/۲۶۱	۱/۱	-۰/۷۲۱	-۰/۷۲۴	۰/۰۵
پل چهر	HSNNDA= ARIMA(۳۱۳)(۲۰۱) _{۱۲} + DMSNN (12-4-1)	۱/۱۹	۰/۰۷۲	۰/۶	-۰/۴۹۸	-۰/۵۵۴	۰/۳۶
دوآب	HSNNDA= ARIMA(۲۱۱)(۱۰۰) _{۱۲} + DMSNN (۸-۱۴-۱)	۰/۵۷۴	۰/۵۰	۱/۱۲	-۰/۷۲۱	-۰/۷۱۶	۰/۳۰

جدول ۶- مقایسه میانگین و انحراف استاندارد مقادیر SDI مشاهده شده و پیش‌بینی شده بوسیله آزمون Z و F در مقیاس فصلی

نام ایستگاه	مدل	واریانس مشاهده شده	واریانس پیش‌بینی شده	F	میانگین مشاهده شده	میانگین پیش‌بینی شده	Z
پل چهر	ARIMA (۱۱۱)(۰۰۳) _۴	۰/۵۶۷	۰/۱۸	۰/۳۱	-۰/۴۹۴	-۰/۴۹۲	۰/۰۱۶
دوآب	ARIMA (۰۱۳)(۰۰۲) _۴	۰/۴۹۲	۰/۲	۰/۴۸	-۰/۷۱۰	-۰/۷۹۶	۰/۹۹
پل چهر	DMSNN (۱۱-۱-۱)	۰/۵۶۷	۰/۰۱۴	۰/۰۲۵	-۰/۴۹۴	-۰/۵۲۶	۰/۳۷۵
دوآب	DMSNN (۵-۵-۱)	۰/۴۹۲	۰/۱۱۹	۰/۲۹۰	-۰/۷۱۰	-۰/۶۰۵	۱/۳۱
پل چهر	HSNNDA= ARIMA(۱۱۱)(۰۰۳) _۴ + DMSNN (۳-۲-۱)	۰/۵۶۷	۰/۰۷۲	۰/۱۲۷	-۰/۴۹۴	-۰/۵۸۸	۱/۰۷
دوآب	HSNNDA= ARIMA(۰۱۳)(۰۰۲) _۴ + DMSNN (۲-۳-۱)	۰/۴۹۲	۰/۱۵۶	۰/۳۸۱	-۰/۷۱۰	-۰/۷۷۴	۰/۷۶۳

جدول ۷- مقادیر ضریب همبستگی، RMSE و MAE در مدل پیش بینی در مقیاس ماهانه

نام ایستگاه	مدل	R	RMSE	MAE
پل چهر	ARIMA(۳۱۳)(۲۰۱) _{۱۲}	۰/۷۵۶	۰/۵۸۶	۰/۴۴۵
دوآب	ARIMA(۲۱۱)(۱۰۰) _{۱۲}	۰/۷۴۹	۰/۵۳۷	۰/۴
پل چهر	DMSNN (۲-۱-۱)	۰/۷۷۷	۰/۵۳۹	۰/۴۰۳
دوآب	DMSNN (۴-۸-۱)	۰/۷۸	۰/۵	۰/۳۷۹
پل چهر	HSNNDA= ARIMA(۳۱۳)(۲۰۱) _{۱۲} + DMSNN (12-4-۱۲)	۰/۷۸۳	۰/۵۶۱	۰/۴۳۲
دوآب	HSNNDA= ARIMA(۲۱۱)(۱۰۰) _{۱۲} + DMSNN (۸-۱۴-۱)	۰/۷۹	۰/۵۲	۰/۳۸

جدول ۸- مقادیر ضریب همبستگی، RMSE و MAE در مدل پیش بینی در مقیاس فصلی

نام ایستگاه	مدل	R	RMSE	MAE
پل چهر	ARIMA (۱۱۱)(۰۰۳) _۴	۰/۲۷۷	۰/۷۴۱	۰/۵۶۳
دوآب	ARIMA (۰۱۳)(۰۰۲) _۴	۰/۳۶۴	۰/۶۴۴	۰/۴۸۳
پل چهر	DMSNN(۱۱-۱-۱)	۰/۲۶۲	۰/۷۱۹	۰/۵۷
دوآب	DMSNN (۵-۵-۱)	۰/۳۴	۰/۶۳	۰/۴۵
پل چهر	HSNNDA= ARIMA(۱۱۱)(۰۰۳) _۴ + DMSNN (۳-۲-۱)	۰/۳۶۷	۰/۷۳۱	۰/۵۴
دوآب	HSNNDA= ARIMA(۰۱۳)(۰۰۲) _۴ + DMSNN (۲-۳-۱)	۰/۳۸	۰/۶۲	۰/۴۵

جدول ۹- مقادیر آماره کاپا در مقیاس ماهانه و فصلی

نام ایستگاه	مدل	آماره کاپای ماهانه	آماره کاپای فصلی
پل چهر	ARIMA (۱۱۱)(۰۰۳) _۴	۰/۵۲۸	۰/۲
دوآب	ARIMA (۰۱۳)(۰۰۲) _۴	۰/۵۱۹	۰/۱۵۶
پل چهر	DMSNN(۱۱-۱-۱)	۰/۵۳۹	۰/۰۵
دوآب	DMSNN (۵-۵-۱)	۰/۴۳۷	۰/۲۳۱
پل چهر	HSNNDA= ARIMA(۱۱۱)(۰۰۳) _۴ + DMSNN (۳-۲-۱)	۰/۵۵۰	۰/۱۰۱
دوآب	HSNNDA= ARIMA(۰۱۳)(۰۰۲) _۴ + DMSNN (۲-۳-۱)	۰/۵۴۵	۰/۲۰۸

اعداد برجسته: آماره‌ی کاپا با $P\text{-value} < 0.05$ معنی‌دار است.

بحث و نتیجه گیری

مطالعه‌ی حاضر با هدف ارزیابی مهارت مدل‌های استوکاستیک، شبکه عصبی مصنوعی و مدل هیبرید در مدل‌سازی و پیش‌بینی سری‌های زمانی خشکسالی هیدرولوژی با استفاده از شاخص SDI پرداخته شد. نتایج حاصل از انواع مدل‌ها نشان می‌دهد بیشترین ضریب همبستگی بین مقادیر مشاهده‌ای و پیش‌بینی

شده مربوط به مدل هیبرید است لذا ترکیب مدل‌های مفهومی و آماری سبب عملکرد بهتر مدل‌ها می‌گردد. مقادیر کاپای وزنی بیانگر این است که مدل هیبرید در دو ایستگاه مورد مطالعه دارای حداکثر میزان توافق بین مقادیر مشاهده‌ای و پیش‌بینی شده است. عملکرد تمامی مدل‌ها در برآورد یک گام به جلوی خشکسالی هیدرولوژی در مقیاس فصلی بسیار پایین است لذا پیشنهاد می‌گردد جهت پیش‌بینی فصلی خشکسالی هیدرولوژی از سایر مدل‌های پیش‌بینی استفاده گردد.

منابع

1. McKee, T. B., N. J. Doesken, and J. Kleist, 1993. The relationship of drought frequency and duration to time scales. Preprints. Eighth Conf. on Applied Climatology. Anaheim. CA. Amer. Meteor. Soc. pp. 179-184.
2. Akaike, H., 1974, A new look at the statistical model identification: IEEE Transactions on Automatic Control, v. 19, p. 716-723.
3. Box GEP, Jenkins GM, Reinsel GC (1994) Time series analysis, 'forecasting and control.' Prentice Hall, Englewood Cliffs, NJ
4. Mishra, A. K., Desai, V. R., Singh, P., 2007, Drought Forecasting Using Hybrid Stochastic and Neural Network Model, Journal of Hydrologic Engineering, DOI 10.1061/(ASCE)1084-0699,12:6(626).
5. Mishra, A. K., Desai, V. R., 2006, Drought Forecasting Using feed-forward recursive neural network, Journal of Ecological Modelling, 198: 127-138.
6. Mishra, A. K., Desai, V. R., 2005, Drought forecasting using syochastic models, Stoch Environ Res Risk Assess, 19: 326-339.
7. Karamouz, M., Araghinezhad, S., 2002. Advanced hydrology. University of Amirkabir Press, 250-380 pp.
8. Yevjevich V (1967) An objective approach to definition and investigation of continental hydrological droughts. Hydrology Paper No. 23, Colarado State University, Fort collins, Colarado, USA.
9. Nalbantis, N., Tsakiris, G., 2009. Assessment off hydrological drought revisited. Journal of water resource management 23:883-897.