

در ایستگاه دوآب (بخش میانی)  $RME = 0.22$  و  $K = 0.232$  است.

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

#### مقدمه

از چهل بلای طبیعی که در کشورهای جهان وجود دارد، سی‌ویک مورد آن در ایران اتفاق افتاده است که خشکسالی به دلیل گستردگی و تبعات کوتاه مدت و بلند مدت اقتصادی، اجتماعی و زیست محیطی، از مهمترین آنها محسوب می‌شود. خشکسالی بر خلاف سایر بلاها به آرامی آغاز می‌شود، پیشروی نموده و موجب نابودی منابع طبیعی می‌گردد. گرچه امروزه به علت پیشرفت‌های علمی و گسترش ارتباطات و حمل‌ونقل بروز آثار خشکسالی به شکل قحطی و مرگ دسته جمعی کمتر بروز نمی‌کند، اما آثار و تبعات دیگر ناشی از خشکسالی همچنان پا برجاست. قرارگیری بخش وسیعی از مساحت کشورمان در نواحی خشک و بیابانی سبب شده که میزان بارندگی در برخی دوره‌ها کمتر از میانگین دراز مدت سالانه باشد، به طوری که در ۱۳ سال از ۲۳ سال گذشته این حالت در کشور استوار بوده است [۶].

پیش‌بینی خشکسالی هیدرولوژیکی یکی از مهمترین اهداف در مدیریت و برنامه‌ریزی منابع آبی بشمار می‌رود. پیش‌بینی میان مدت یا بلندمدت خشکسالی در مقیاس‌های 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 غیرقطعی<sup>۵</sup> و مدل‌های مفهومی است. پیش‌بینی قطعی و غیرقطعی خشکسالی بیش از هر فرایند دیگر نظر هیدرولوژیست‌ها را به خود جلب نموده است. پدیده خشکسالی در بعد مکان و زمان بیشترین تغییرات را داشته و شبیه‌سازی آنها به لحاظ سرشت غیر خطی و ابعاد زیاد آن همواره با مشکلات زیادی روبرو بوده است [۵].

کومار<sup>۶</sup> و همکاران [۱۱] طی پژوهشی با عنوان پیش‌بینی بارش با استفاده از سیگنال‌های اقلیمی و هوش مصنوعی در منطقه‌ی اوراسیا

**بررسی کارایی مدل‌های هیبرید شبکه عصبی مصنوعی - استوکاستیک در پیش‌بینی خشکسالی‌های هیدرولوژیکی با استفاده از آماره کاپا (مطالعه موردی: حوزه آبخیز رودخانه گاماسیاب)**

ام البنین بذرافشان<sup>۱\*</sup>، علی سلاجقه<sup>۲</sup>، محمد مهدوی<sup>۳</sup>، جواد بذرافشان<sup>۴</sup>

و احمد فاتحی‌مرج<sup>۵</sup>

تاریخ دریافت: ۱۳۹۰/۰۳/۰۷ تاریخ پذیرش: ۱۳۹۲/۸/۲۸

#### 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 در دو ایستگاه هیدرومتری واقع در بخش میانی و خروجی در حوزه آبخیز گاماسیاب در دوره آماری (۱۳۵۳-۱۳۸۷) می‌پردازد و شاخص SDI بعنوان شاخص پیش‌بینی کننده انتخاب گردید. بازه زمانی آماری (۱۳۵۳-۱۳۷۹) برای مرحله واسنجی و ۸ سال باقیمانده جهت مرحله صحت سنجی مدل‌ها مورد استفاده قرار گرفت. نتایج نشان می‌دهد، در میان سه مدل مورد استفاده جهت پیش‌بینی یک گام زمانی بعد، ترکیب مدل‌های شبکه عصبی - استوکاستیک (هیبرید) نتیجه مناسبی نسبت به مدل‌های مجزای آنها در مقیاس ماهانه و فصلی دارد بطوری که مقادیر میانگین خطای نسبی و آماره کاپای این مدل در مقیاس زمانی ماهانه در ایستگاه پل چهر (بخش خروجی) به ترتیب  $RME = 0.079$  و  $K = 0.565$  و در مقیاس زمانی فصلی

۱- \*نویسنده مسئول و عضو هیات علمی دانشکده کشاورزی و منابع طبیعی،

دانشگاه هرمزگان. Email: O.Bazrafshan@hormozgan.ac.ir

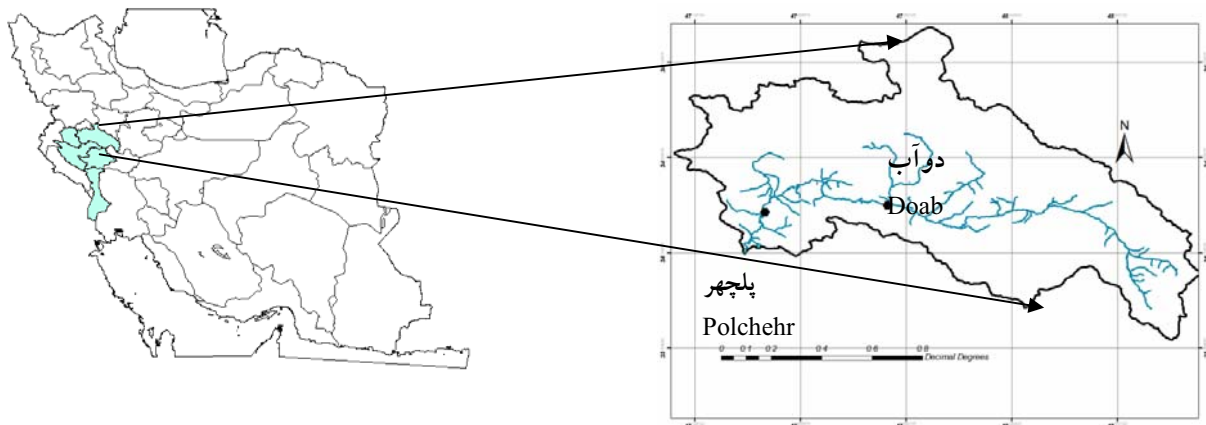
۲- عضو هیات علمی دانشکده منابع طبیعی، دانشگاه تهران.

۳- عضو هیات علمی دانشکده کشاورزی، دانشگاه تهران.

۴- عضو هیات علمی پژوهشکده حفاظت خاک و آبخیزداری.

5. Stochastic

6. kumar



شکل ۱- موقعیت ایستگاه‌های هیدرومتری در حوزه آبخیز گاماسیاب  
 Fig 1. Location of Hydrometrics stations used in the Gamasiab Watershed Basin

### مقدمه

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

### شاخص IDS بعنوان نمایه خشکسالی هیدرولوژی

جهت مطالعه خشکسالی هواشناسی شاخص‌های متعددی ابداع گردیده است، که معروف‌ترین آنها تحت عنوان شاخص بارش استاندارد SPI<sup>۱</sup> است که برای اولین بار توسط مک‌کی و همکاران [۱۲] ابداع گردید اما برای خشکسالی هیدرولوژی می‌توان از شاخص شبیه شاخص بارش استاندارد تحت عنوان شاخص استاندارد جریان (SDI) استفاده نمود که براساس جریان ماهانه نرمال استاندارد می‌باشد و اولین بار توسط بن‌زوی<sup>۲</sup> در سال ۱۹۸۷ [۸] پیشنهاد گردید. اصول محاسباتی این شاخص در شکل ۲ ارائه گردید. طبقه‌بندی شدت خشکسالی هیدرولوژی بر اساس نمایه SDI در جدول ۲ ارائه گردید [۱۸].

به پیش‌بینی بارش در مقیاس زمانی ماهانه و فصلی پرداختند. در این تحقیق ارتباط بین بارندگی منطقه و سیگنال‌های بزرگ مقیاس مانند نوسانات جنوبی ENSO، نوسانات اقیانوس هند و شاخص‌های محلی مانند دمای سطح اقیانوس مورد بررسی قرار گرفت و نتایج به دست آمده حاکی از مطلوبیت نتایج شبکه عصبی در پیش‌بینی بارش می‌باشد.

میشرا و همکاران [۱۷] از یک مدل هیبرید که ترکیبی از مدل غیرقطعی خطی و مدل شبکه عصبی مصنوعی غیرخطی است، جهت پیش‌بینی خشکسالی هواشناسی استفاده کردند. نتایج حاکی از دقت بالاتر مدل هیبرید در مقایسه با سایر مدل‌ها است.

نالباننیتس و تاکریس [۱۸] از شاخص SDI<sup>۱</sup> بعنوان نمایه محاسبه خشکسالی هیدرولوژی در چهار مقیاس ۳، ۶، ۹ و ۱۲ ماهه استفاده کردند. نتایج نشان می‌دهد با افزایش مقیاس زمانی شدت خشکسالی هیدرولوژیکی کاهش می‌یابد.

والنسا و همکاران [۲۱] به بررسی کارایی شبکه عصبی پرسپترون چند لایه و مدل سری زمانی PARMA<sup>۲</sup> در پیش‌بینی جریان ماهانه رودخانه در مقیاس زمانی ۱ تا ۱۲ گام بعد پرداختند که نتایج این مقایسه حاکی از حداقل ۵۰٪ کاهش خطا در پیش‌بینی‌های مدل ANN<sup>۳</sup> نسبت به PARMA می‌باشد.

با توجه به پیشینه بررسی که در بالا به برخی از موارد آن اشاره گردید، هدف از ارائه این تحقیق ترکیب مدل‌های غیرقطعی 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 هر یک مدل‌های مذکور با استفاده از آماره کاپا<sup>۴</sup> است.

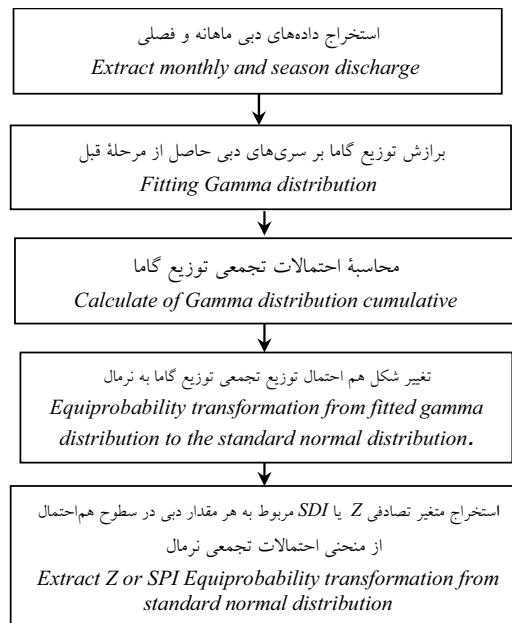
1. Standardized Stream flow Index
2. Periodic Auto Regressive Moving Average
3. Artificial Neural Network
4. Kappa

5. Standardized Precipitation Index  
 6. Ben Zvi

جدول ۱- ویژگی‌های ایستگاه‌های واقع در حوزه آبخیز گاماسیاب

Table 1. Hydrometric stations

مشخصات جغرافیایی		مشخصات آماری سری سالانه دبی (۱۳۵۳-۱۳۸۸)					
Geographic coordinates		Statistical properties of annual discharge series (۱۹۷۴-۲۰۰۸)					
نام ایستگاه	ارتفاع از سطح دریا (متر)	عرض جغرافیایی طول جغرافیایی	میانگین	انحراف معیار	حداقل	حداکثر	
Hydrometric station	Elevation(m)	Latitude	Longitude	Mean (m <sup>3</sup> /s)	Standard deviation	Min	Max
دوآب Doab	1410	°47 54	°34 22	0.415	7.6	4.06	32/4
پل چهر Polchehr	1306	°47 26	°34 20	32.5	15.2	6.2	77/3




شکل ۲- روش شناسی SDI  
Fig 2. Methodology SDI

جدول ۲- رده بندی شدت خشکسالی هیدرولوژی با استفاده از شاخص SDI

Table 2. Drought classification based on SDI

مقادیر SDI SDI Value	کلاس خشکسالی	Class
>2	ترسالی خیلی شدید	Extremely wet
2 1.5to	ترسالی شدید	Very wet
1to 1.5	ترسالی متوسط	Moderately wet
1 to 0	ترسالی ملایم	Near Normal wet
0 to -1	خشکسالی ملایم	Near Normal dry
-1 to -1.5	خشکسالی متوسط	Moderately dry
-1.5 to 2	خشکسالی شدید	Severely dry
<-2	خشکسالی بسیار شدید	Extremely dry



شکل ۳- شبکه عصبی مستقیم

Fig3. Direct artificial neural network

به صورت  $B(Z_t) = Z_{t-1} (1-B)^d$  معادل  $d$  امین تفاضل غیرفصلی و  $(1-B)^p$  معادل  $D$  امین تفاضل فصلی به اندازه  $w$  می باشد [۹ و ۲۲]. پس از محاسبه مرتبه مدل، شناسایی مدل مناسب با استفاده از تست معیار اطلاعات آکائیک<sup>۶</sup> صورت می گیرد [۷ و ۹].

### روش شبکه عصبی مستقیم

در این مطالعه از روش از شبکه های عصبی مستقیم<sup>۷</sup> (DANN) برای پیش بینی یک گام به جلو استفاده شد. از مزایای شبکه عصبی مصنوعی مستقیم نسبت به مدل های غیرقطعی قدرت آموزش و یادگیری و در نظر گرفتن بخش غیرخطی سری های زمانی است [۱۶]. (شکل ۳)

در مطالعه حاضر لایه خروجی شبکه دارای یک نرون است که نشان دهنده گام زمانی به ترتیب یک ماهه و یک فصل بعد در مقیاس زمانی ماهانه و فصلی است. برنامه ای با استفاده از نرم افزار MATLAB برای شبکه عصبی یک گامه مستقیم نوشته شد. الگوریتم آموزش مورد استفاده، الگوریتم پس انتشار خطا، تکنیک یادگیری مارکوورت-لونیبرگ<sup>۸</sup> و تابع انتقال مورد استفاده در لایه مخفی و خروجی به ترتیب تانژانت سیگموئید و خطی بود. سرعت یادگیری، ضریب مومنتوم و تعداد دوره<sup>۹</sup> 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 نرون های ورودی و مخفی بهینه به منظور داشتن بالاترین دقت از طریق آزمون و خطا تعیین و مقدار  $n$  (تعداد نرون های ورودی) برابر با ۲۰ و تعداد نرون های لایه مخفی از ۱ تا  $1+2n$  متغیر در نظر گرفته شد. با اجرای برنامه کلیه حالات بررسی شد و ساختاری که بیشترین ضریب همبستگی و کمترین مقادیر خطا را داشت به عنوان ساختار بهینه شبکه عصبی مصنوعی مستقیم معرفی گردید [۱۶ و ۲۳].

### ترکیب مدل های ARIMA و شبکه عصبی مصنوعی مستقیم (مدل هیبرید):

شبکه عصبی به دلیل توانایی بالا در مدل سازی روابط غیرخطی جهت مدل سازی سری باقیمانده ها، بسیار مناسب هستند. بنابراین

### مدل های تصادفی

مدل های خودهمبسته (AR)<sup>۱</sup> ساده ترین نوع مدل های پیوسته اند که به طور کلی به دو دسته قابل تقسیم اند: الف) مدل های AR با پارامترهای ثابت که برای مدل سازی سری های زمانی سالانه رایج می باشند. مدل های AR توانایی لازم برای مدل سازی جریان کم رودخانه در فصول کم آب (با نوسانات کم) که عمدتاً از منابع آب زیرزمینی تامین می شود را دارند اما در فصول پر آب (با نوسانات زیاد) می توان با اضافه کردن مولفه مدل میانگین متحرک (MA)<sup>۲</sup> به مدل های AR نتایج مدل سازی را بهبود بخشید. ترکیب یک مدل AR از مرتبه  $p$  و یک مدل MA از مرتبه  $q$ ، یک مدل میانگین متحرک خودهمبسته از مرتبه  $p$  و  $q$ ،  $ARMA(p,q)$  را بوجود می آورند. شرط اساسی برای استفاده از مدل  $ARMA$  ایستا بودن سری زمانی است. فرم پایه مدل های  $ARMA$  برای متغیر نرمال استاندارد شده  $Z_t$  به صورت زیر است [۹]:

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

اگر یک سری زمانی ایستا نباشد، می توان با استفاده از عملگر تفاضل، سری زمانی مورد نظر را ایستا نمود. استفاده از  $d$  امین تفاضل سری و مدل سازی آن با  $ARMA(p,q)$  منجر به پیدایش سری جدیدی از مدل های غیرفصلی خودهمبسته میانگین متحرک تجمعی ( $ARIMA(p,d,q)$ )<sup>۴</sup> می شود. فرم پایه مدل  $ARIMA$  غیرفصلی به صورت زیر است [۹]

$$(2)$$

که  $\theta(B)$  و  $B\theta(B)$  به ترتیب چند جمله ای مرتبه  $p$  مدل AR و چند جمله ای مرتبه  $q$  مدل MA می باشند و از روابط زیر بدست می آیند [۹ و ۲۲]:

$$\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (3)$$

$$\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (4)$$

در صورت استفاده از عملگر تفاضل فصلی با تاخیر  $w$  و برازش آنها با مدل های  $ARMA(q,p)$  مدل های فصلی  $ARIMA(Q,D,P)$  بوجود می آید. ترکیبی از مدل های فصلی و غیرفصلی، مدل های موسوم به آریمای مکتور<sup>۵</sup> را تشکیل می دهند. فرم پایه مدل آریمای مکتور به صورت زیر است [۹ و ۲۲]:

$$\Phi_p(B^w) \phi_p(B) (1-B^w)^D (1-B)^d Z_t = \Theta_Q(B^w) \theta_q(B) \varepsilon_t \quad (5)$$

که  $p$  مرتبه مدل AR غیرفصلی،  $P$  مرتبه مدل AR فصلی،  $q$  مرتبه مدل MA غیرفصلی،  $Q$  مرتبه مدل MA فصلی،  $w$  طول فصل،  $\varepsilon_t$  متغیر تصادفی (اغتشاش خالص)،  $B$  عملگر تفاضل

1. Auto Regressive
2. Moving Average
3. Auto Regressive Moving Average
4. Auto Regressive Integrated Moving Average
5. Multiplicative ARIMA

6. Akaike Information Criterion(AIC)

7. Direct Artificial neural network

8. Marquard- Levenberg

9. Epoch

$$K = 1 - \frac{\sum w_j P_j}{\sum w_j P_{e,j}} \quad \text{بدست می‌آید [۱۰]:} \quad (8)$$

آماره‌ی آزمون معنی‌داری آماره‌ی کاپای وزنی با فرضیه‌ی صفر عدم توافق، به صورت زیر است [۱۰]:

$$t = \frac{K}{\sqrt{\frac{\sum w_j^2 P_{e,j} - (\sum w_j P_{e,j})^2}{n(\sum w_j P_{e,j})^2}}} \quad (9)$$

که n تعداد مشاهدات سری است.

### معیارهای ارزیابی عملکرد شبکه

به منظور ارزیابی و مقایسه عملکرد مدل‌های مورد بررسی از معیارهای مختلف سنجش نکویی برازش، به شرح زیر استفاده گردید:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - E_i)^2}{n}} \quad \text{ریشه میانگین مربعات خطا (RMSE<sup>r</sup>)} \quad (10)$$

که در رابطه فوق  $O_i$  مقادیر مشاهده‌ای و  $E_i$  مقادیر پیش‌بینی شده است. پایین بودن ریشه میانگین مربعات خطا هر مدل نشان دهنده عملکرد بهتر آن است [۱۵].

$$MAE = \frac{\sum_{i=1}^n |O_i - E_i|}{n} \quad \text{میانگین قدر مطلق خطا (MAE<sup>t</sup>)} \quad (11)$$

پایین بودن قدرمطلق مربعات خطا هر مدل نشان‌دهنده عملکرد بهتر آن است [۱۵].

$$R^2 = \frac{\sum_{t=1}^n (x_t - \bar{x}_t)(\hat{x}_t - \bar{\hat{x}}_t)}{\sqrt{\sum_{t=1}^n (x_t - \bar{x}_t)^2 \sum_{t=1}^n (\hat{x}_t - \bar{\hat{x}}_t)^2}} \quad \text{ضریب همبستگی<sup>۰</sup> بین مقادیر مشاهده‌ای و پیش‌بینی (R<sup>r</sup>)} \quad (12)$$

در رابطه ۱۲ مقادیر  $x_t$  مربوط به سری مشاهداتی و  $\bar{x}_t$  مربوط به سری پیش‌بینی شده است. بالا بودن این ضریب نشان‌دهنده توافق بیشتر بین مقادیر مشاهده‌ای یا مقادیر پیش‌بینی شده و عملکرد بهتر مدل است [۱۵].

- میانگین درصد خطای نسبی بین مقادیر مشاهده‌ای و پیش‌بینی

$$RME = \frac{1}{n} \sum_{i=1}^n RE_i \quad (13)$$

$$RE_i = \frac{|O_{obs} - O_{pre}|}{O_{obs}} \times 100$$

یک مدل هیبرید شامل یک مدل ARIMA برای بخش خطی سری زمانی و یک مدل ANN برای بخش غیرخطی است. سری غیرخطی به‌وسیله باقیمانده‌های بدست‌آمده بعد از برازش مدل ARIMA تشکیل می‌شود [۱۶].

$$Y_i = L_i + N_i \quad (1)$$

که  $Y_i$  سری زمانی اصلی،  $L_i$  بخش خطی بر مبنای مدل ARIMA و  $N_i$  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 مستقیم ترکیب می‌کند که نام این مدل، مدل هیبرید شبکه عصبی مصنوعی مستقیم- غیرقطعی است (HSNNDA) [۱۶].

### آماره‌ی کاپا

آماره‌ی کاپا نخستین بار توسط کوهن<sup>۲</sup> در سال ۱۹۶۸ [۱۰] به‌عنوان معیار اندازه‌گیری توافق در علم روان‌شناسی معرفی گردید. 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 منحصر بفرد  $P_{ii}$  اجزایی است که در هر دو سری مطابقت دارند. P مجموع مقادیر  $P_{ii}$  است. با در نظر گرفتن  $P_{e,ii}$  به عنوان حاصل ضرب مجموع نسبت‌های ردیف و ستون مربوطه ( $P_{e,ii} = P_{ii}$ )، مقدار قابل انتظار توافق، برابر است با جمع مقادیر  $P_{e,ii}$ ؛ این جمع را  $P_e$  می‌نامیم. آماره‌ی کاپا به صورت زیر تعریف می‌شود [۱۰]:

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

لندیس و کوچ به نقل از [۱۰]، پیشنهاد کردند که مقادیر K کمتر از ۰/۴ نشان‌دهنده‌ی توافق ضعیف تا خیلی ضعیف بوده، مقادیر ۰/۵۰-۰/۴۰ نشان‌دهنده‌ی توافق متوسط، مقادیر ۰/۷۰-۰/۵۰ نشان‌دهنده‌ی توافق خوب و مقادیر بیش از ۰/۷۰ نشان‌دهنده‌ی توافق خیلی خوب تا عالی می‌باشند. در مقایسه‌ی طبقات SDI 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 در  $w_{ij}$  بدست می‌آید. بنابراین، آماره‌ی کاپای وزنی از رابطه زیر

3. Root Mean Square Error

4. Mean Absolute Error

5. Root square

1. Hybrid stochastic neural network of direct approach

2. Kohn

جدول ۳- پارامترهای مدل‌های منتخب در مدل آریما در مقیاس زمانی ماهانه

Tab3. Analysis of ARIMA model parameters selected candidate models in monthly scale

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	آماره t	معنی داری
Station	Stochastic Model	Model parameters	Value of parameters	Standard error	t-Ratio	P-Value
پل چهر Polchehr	ARIMA <sub>(۲۰۱)</sub> (۳۱۳)	$\square_1$	0.298	0.1994	1.5	0.136
		$\Phi_2$	-0.2902	0.1779	-1.61	0.107
		$\Phi_3$	0.3918	0.1288	3.04	0.003
		$\theta_1$	-0.7142	0.3607	-1.98	0.049
		$\theta_2$	0.0204	0.0895	0.23	0.82
		$\theta_3$	0.2564	0.1894	1.35	0.177
		$\Phi_1$	-0.0052	0.1617	-0.03	0.974
		$\Phi_2$	0.598	0.1184	0.05	•
		$\Theta_2$	-0.8104	0.3588	-2.26	0.025
		$\square 1$	0.7965	0.0434	17.74	•
دوآب Doab	ARIMA <sub>(۱۰۰)</sub> (۲۱۱)	$\Phi 1$	0.638	0.1618	3.94	•
		$\square 1$	-0.8769	0.075	-11.69	•
		$\square 2$	-0.0088	0.0583	-0.15	0.88
		$\Phi 1$	-0.1085	0.0575	-1.89	-0.06
		$\theta 1$	-0.9251	0.0498	-18.58	0

خطای نسبی کمتری (RME=۰.۲۲/۳) نسبت به ایستگاه دوآب (RME=۰.۳۰/۳) است. این در حالیست که در مقیاس زمانی فصلی با مقادیر خطای بیشتر این نتیجه عکس بدست آمده است، بطوریکه ایستگاه پل چهر واقع در خروجی حوضه دارای میانگین درصد خطای نسبی بیشتر (RME=۰.۱۷۲) نسبت به ایستگاه دوآب (RME=۰.۱۵۴) است (جداول ۵ و شکل ۸). نتایج آنالیز F و Z با توجه به جداول ۶ و ۷ در مقیاس زمانی ماهانه و فصلی، بیانگر عدم تفاوت معنی‌دار بین واریانس و میانگین مقادیر مشاهده‌ای و پیش‌بینی شده است و فرضیه‌ی صفر مبنی بر برابری واریانس‌ها و میانگین‌های مقادیر مشاهده‌ای و پیش‌بینی شده پذیرفته می‌شود. لذا نتایج نشان می‌دهد مدل‌های استوکاستیک توانایی مناسبی در حفظ واریانس سری زمانی مشاهده‌ای دارد.

#### توسعه مدل شبکه عصبی مصنوعی 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 [۱۵]. ساختار بهینه شبکه عصبی مستقیم برای 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 ۶ و ۷ ارائه شده است. از آنجایی که مقادیر Z محاسبه‌شده، بین مقادیر بحرانی جدول Z (۱/۹۶)± برای سطح معنی‌داری ۵٪ قرار

کند در رابطه فوق  $O_{obs}$  مقادیر مشاهده‌ای و  $O_{pre}$  مقادیر پیش‌بینی شده و n مقادیر مشاهده‌ای است. پایین بودن میانگین درصد خطای نسبی هر مدل نشان‌دهنده عملکرد بهتر آن است [۱۳ و ۱۴]. ویژگی‌های آماری اصلی بین مقادیر مشاهده‌شده و پیش‌بینی‌شده با استفاده از آزمون Z برای میانگین و آزمون F برای انحراف استاندارد مقایسه شد.

#### نتایج

##### توسعه مدل ARIMA و برآورد پارامترها

در مطالعه حاضر سری‌های زمانی مقادیر SDI در مقیاس زمانی ماهانه و فصلی، با استفاده از مقادیر دبی ۳۴ سال آبی (۵۴-۱۳۵۳ تا ۸۸-۱۳۸۷) محاسبه گردید و ۸ سال آماری پایانی (۸۱-۱۳۸۰ تا ۸۸-۱۳۸۷) جهت صحت‌سنجی مدل استفاده گردید.

بعد از مرحله شناسایی مدل، پارامترهای مدل منتخب با استفاده از نرم‌افزار MINITAB در مقیاس زمانی ماهانه و فصلی برای یک گام زمانی بعد محاسبه گردید. مقادیر پارامترهای مدل منتخب در جدول ۳ و ۴ فهرست شده است. خطای استاندارد محاسبه‌شده برای هریک از پارامترهای مدل، عموماً در مقایسه با پارامترها کوچک بوده، بنابراین می‌توان از این پارامترها در مدل‌سازی استفاده کرد.

توابع ارزیابی عملکرد در این مدل در مقیاس زمانی ماهانه نسبت به فصلی دارای نتایج بهتری است و از طرفی در مقیاس زمانی ماهانه ایستگاه پل چهر واقع در خروجی حوزه دارای میانگین درصد

جدول ۴- پارامترهای مدل‌های منتخب در مدل ARIMA در مقیاس زمان فصلی

Tab4. Analysis of model parameters selected candidate models in seasonal scale

نام ایستگاه	مدل‌های استوکاستیک	پارامترهای مدل	مقادیر پارامترها	خطای استاندارد	آماره t	معنی داری
Station	Stochastic Model	Model parameters	Value of parameters	Standard error	t-Ratio	P-Value
پل چهر Polchehr	ARIMA (۱۱۱)(۰۰۳) <sub>۴</sub>	$\square_1$	0.3474	0.1649	2.11	0.038
		$\Phi_1$	0.8074	0.1079	7.48	۰
		$\Theta_1$	0.0317	0.1072	0.3	0.768
		$\Theta_2$	0.2645	0.098	2.7	0.008
		$\Theta_3$	0.3925	0.1085	3.04	0.003
		$\Phi_1$	0.6948	0.1151	4.06	۰
		$\theta_1$	0.2839	0.0987	2.9	0.005
دوآب Doab	ARIMA (۰۱۳)(۰۰۲) <sub>۴</sub>	$\theta_2$	0.1979	0.102	1.94	0.55
		$\theta_3$	0.2351	0.101	2.33	0.022
		$\Theta_1$	0.0155	0.1049	0.15	0.833
		$\Theta_2$	0.2697	0.1043	1.58	0.011

جدول ۵ ارائه گردید. طبق جدول ارائه شده اگر چه مقادیر ضرائب تبیین  $R^2$ ، RMSE و MAE در مدل هیبرید نسبت به دو مدل دیگر بهبود چندانی نشان نمی‌دهد، اما میانگین درصد خطای نسبی بوضوح تفاوت نتایج حاصل از مدل‌های خطی، غیرخطی و ترکیبی از این دو را نشان می‌دهد، بطوریکه مقدار RME در مدل هیبرید شبکه عصبی مصنوعی - استوکاستیک نسبت به مدل استوکاستیک چهاربرابر بهبود و نسبت به مدل شبکه عصبی مصنوعی دوبرابر بهبود در مقیاس زمانی ماهانه و تقریباً بیش از دو برابر در مقیاس زمانی فصلی نشان می‌دهد، این نتایج در شکل ۸ ارائه گردیده است.

شکل ۶ و ۷ نتایج پیش بینی یک ماهه مدل‌های استوکاستیک، شبکه عصبی و هیبرید با مقادیر واقعی در مقیاس زمانی ماهانه در ایستگاه‌های مورد مطالعه را نشان می‌دهد. نتایج، کارایی بهتر تمامی مدل‌ها در مقیاس زمانی ماهانه نسبت به فصلی را در دو ایستگاه تأیید می‌نمایند.

نتایج حاصل از مدل هیبرید در هر ایستگاه به لحاظ الگوی مکانی نیز مشابه دو مدل دیگر بکار گرفته شده است، بطوریکه نتایج در مقیاس زمانی ماهانه در ایستگاه خروجی بهترین عملکرد (MAE=۰/۴۲۳، RMSE=۰/۵۶۱،  $R^2=۰/۷۸۳$ ، RME=۰/۵/۷۹) و در مقیاس زمانی فصلی در ایستگاه میانی بهترین پاسخ (RME=۰/۲۲/۴) را ارائه داده است. (MAE=۰/۴۵ و RMSE=۰/۶۲،  $R^2=۰/۳۸$ )

نتایج آنالیز میانگین و واریانس در مقیاس زمانی ماهانه و فصلی در مدل هیبرید بیانگر عدم تفاوت معنی دار بین میانگین و واریانس مقادیر مشاهده‌ای و پیش‌بینی شده است و فرضیه‌ی صفر مبنی بر برابری میانگین و واریانس مقادیر مشاهده‌ای و پیش‌بینی شده با استفاده از مدل مذکور پذیرفته می‌شود.

داشتند، در نتیجه تفاوت معنی‌داری بین میانگین مقادیر مشاهده‌شده و پیش‌بینی شده وجود ندارد و نتایج آنالیز واریانس در این مدل بیانگر عدم تفاوت معنی‌دار بین واریانس مقادیر مشاهده‌ای و پیش‌بینی شده است و فرضیه‌ی صفر مبنی بر برابری واریانس‌ها مقادیر مشاهده‌ای و پیش‌بینی شده پذیرفته می‌شود.

توابع عملکرد در این مدل در دو ایستگاه مورد مطالعه (شکل ۸ و جدول ۵) به لحاظ مقادیر درصد میانگین خطای نسبی تفاوت قابل ملاحظه‌ای را نشان می‌دهد و از طرفی کارایی مناسب این مدل را نسبت به مدل استوکاستیک نشان می‌دهد بطوریکه میزان خطای محاسبه در مدل شبکه عصبی مصنوعی بخصوص در مقیاس زمانی ماهانه تقریباً پنجاه درصد بهبود نشان می‌دهد (شکل ۶).

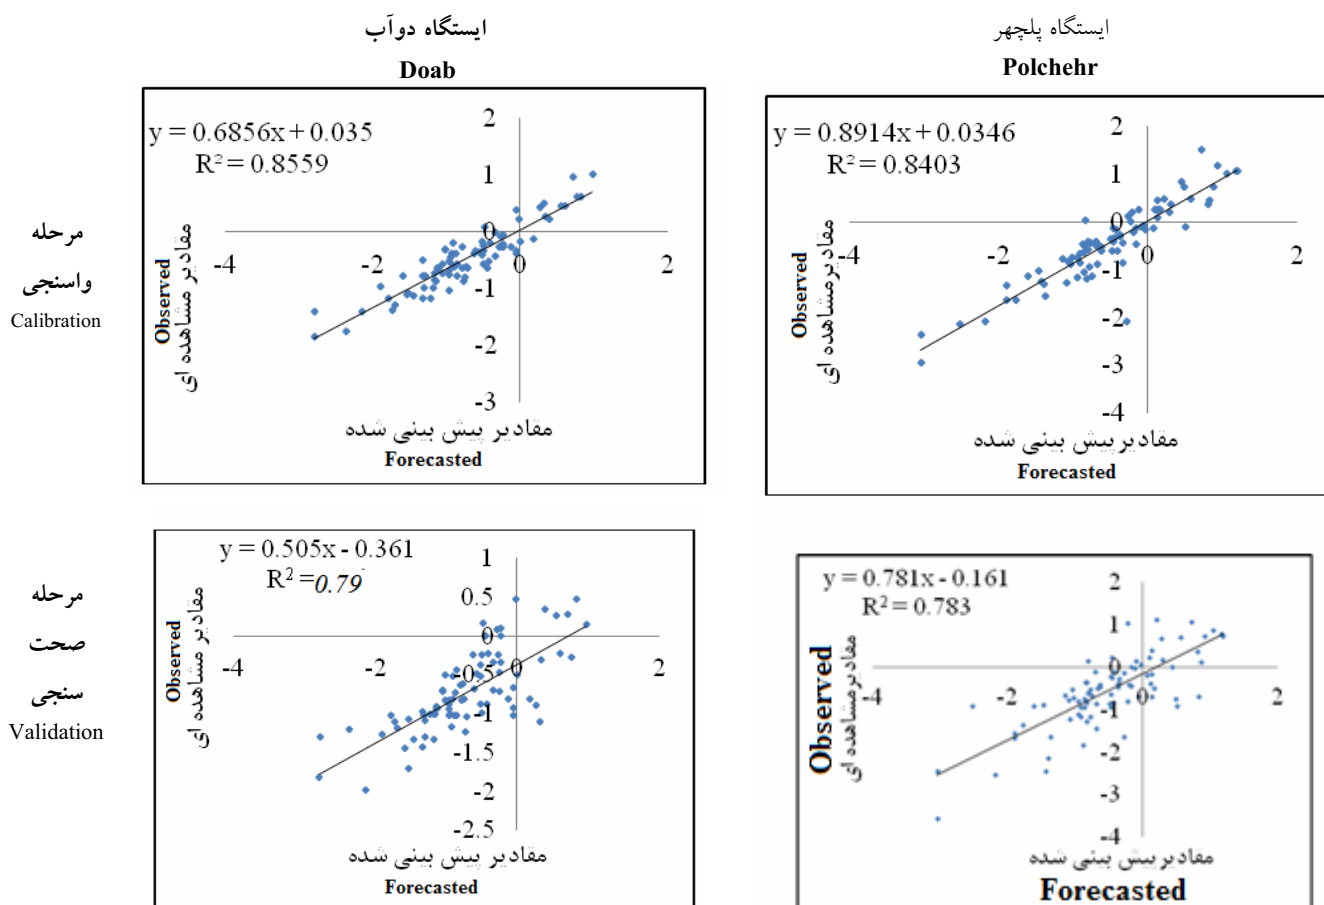
توسعه مدل هیبرید شبکه عصبی مصنوعی - استوکاستیک

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. شکل ۴ و ۵ مقادیر ضرایب همبستگی بین مقادیر مشاهده‌ای و پیش‌بینی شده در دو مرحله واسنجی و صحت‌سنجی را نشان می‌دهد. بر اساس نتایج بدست آمده در مقیاس زمانی فصلی در دو مرحله مذکور (واسنجی و صحت‌سنجی) مدل فوق‌قادر به ارائه عملکرد مناسبی نبوده است. نتایج عملکرد حاصل از هریک از مدل‌های مورد استفاده در

جدول ۵- مقایسه مقادیر پیش‌بینی و مشاهداتی

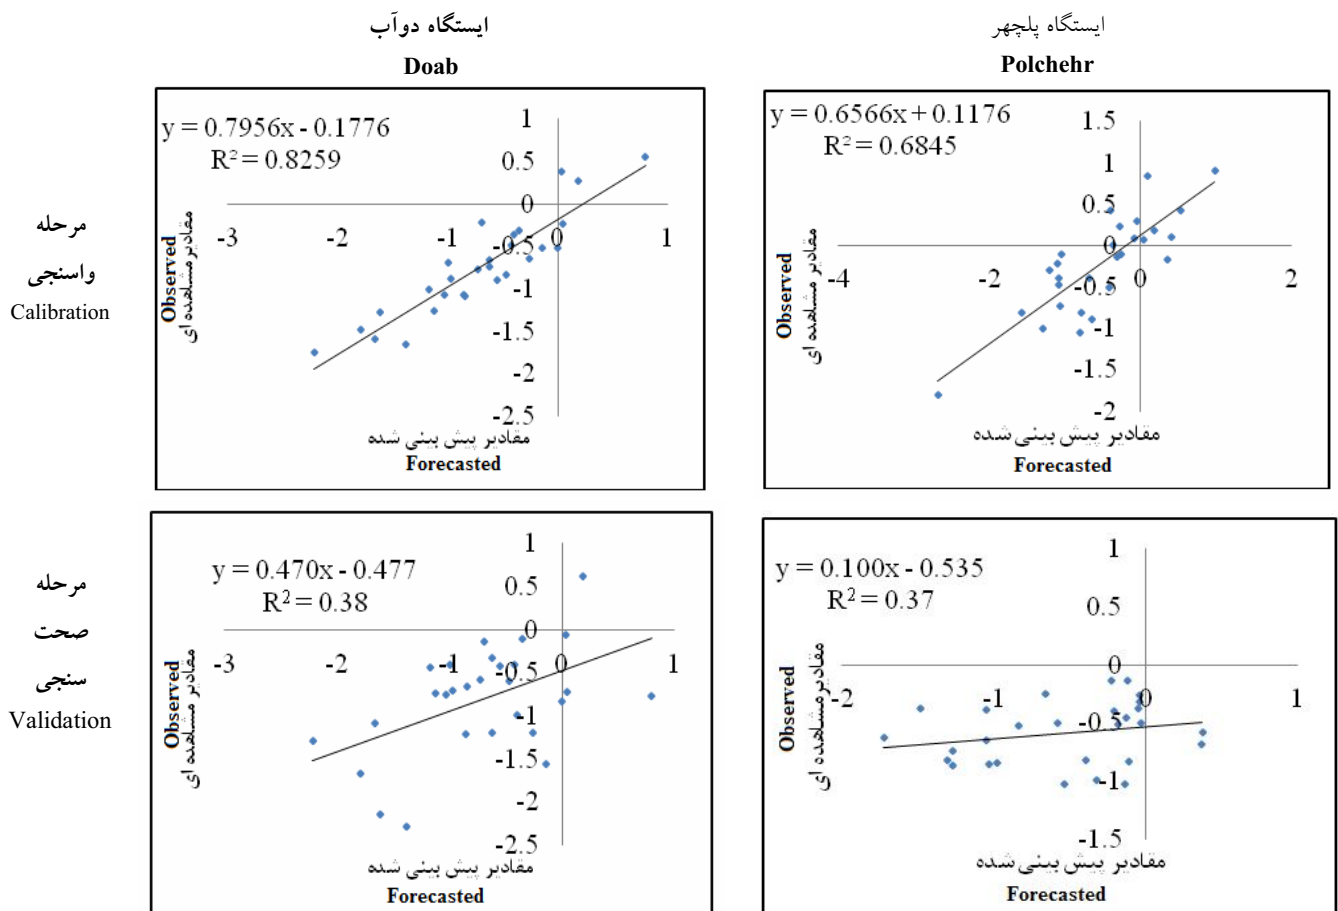
Table5. Comparison of forecasting measures between observed and predicted data

نام مدل Model	نام ایستگاه Station	ماهانة Monthly				فصلی Seasonal			
		ضریب همبستگی R <sup>2</sup>	مربع خطا RMSE	قدرمطلق خطا MAE	خطای نسبی RME	ضریب همبستگی R <sup>2</sup>	مربع خطا RMSE	قدرمطلق خطا MAE	خطای نسبی RME
172.7	0.563	0.741	0.277	22.3	0.445	0.586	0.756	پل چهر Polchehr	
154.7	0.483	0.644	0.364	30.3	0.4	0.537	0.749	دوآب Doab	آریمما ARIMA
۱۷۳	0.57	0.719	0.262	10.2	0.403	0.539	0.777	پل چهر Polchehr	
202.2	0.45	0.63	0.34	46.61	0.308	0.52	78.0	دوآب Doab	شبکه عصبی مستقیم DANN
۱۰۷	0.54	0.731	0.367	5.79	0.432	0.561	0.783	پل چهر Polchehr	
22.43	0.45	0.62	0.38	22.98	0.36	0.48	0.79	دوآب Doab	هیبرید HSNNDA



شکل ۴- مقایسه بین مقادیر مشاهده شده و پیش‌بینی شده در مقیاس زمانی فصلی در مدل هیبرید  
Fig4. A comparison between observed data and predicted data over Hybrid model in the monthly scale





شکل ۵- مقایسه بین مقادیر مشاهده شده و پیش بینی شده در مقیاس زمانی فصلی در مدل هیبرید  
 Fig5. A comparison between observed data and predicted data over Hybrid model in the seasonal scale

نتایج مطالعه شلامو و همکاران [۲۰] و عبقری [۴] می باشد. مدل های ARIMA بر مبنای حافظه سری زمانی قبلی مقادیر را بصورت خطی پیش بینی می نماید، و لذا این مدل برای پیش بینی خشکسالی هیدرولوژی که دارای رفتار غیرخطی و ناپایستا هستند، پاسخ مناسبی ارائه نمی دهد، این در حالیست که بسیاری از محققین مانند سلاجقه و همکاران [۳]، میسرا و دسای [۱۶ و ۱۷] مدل های ARIAM را در پیش بینی خشکسالی هواشناسی بسیار موفق معرفی کرده اند.

نتایج حاصل از سه مدل نشان می دهد کمترین مقدار میانگین درصد خطای نسبی بین مقادیر مشاهده ای و پیش بینی شده مربوط به مدل هیبرید است لذا ترکیب مدل های مفهومی و آماری سبب عملکرد بهتر مدل ها می گردد. مدل ARIMA بر مبنای حافظه سری زمانی قبلی مقادیر را بصورت خطی پیش بینی می نماید و تنها با استفاده از روابط ریاضی، بخش خطی سری زمانی را در نظر می گیرند، این در حالیست که در مدل هیبرید و شبکه عصبی مصنوعی علاوه بر در نظر گرفتن بخش غیرخطی سری زمانی با آزمایش، آموزش و خطا به کشف رابطه بین اجزاء می پردازد، که با نتایج حجایی [۱] و میسرا و همکارا [۱۵، ۱۶ و ۱۷] همخوانی دارد.

مقایسه نتایج مدل استوکاستیک، شبکه عصبی مصنوعی و هیبرید در مقیاس ماهانه و فصلی، دال بر عملکرد نامناسب تمامی مدل ها

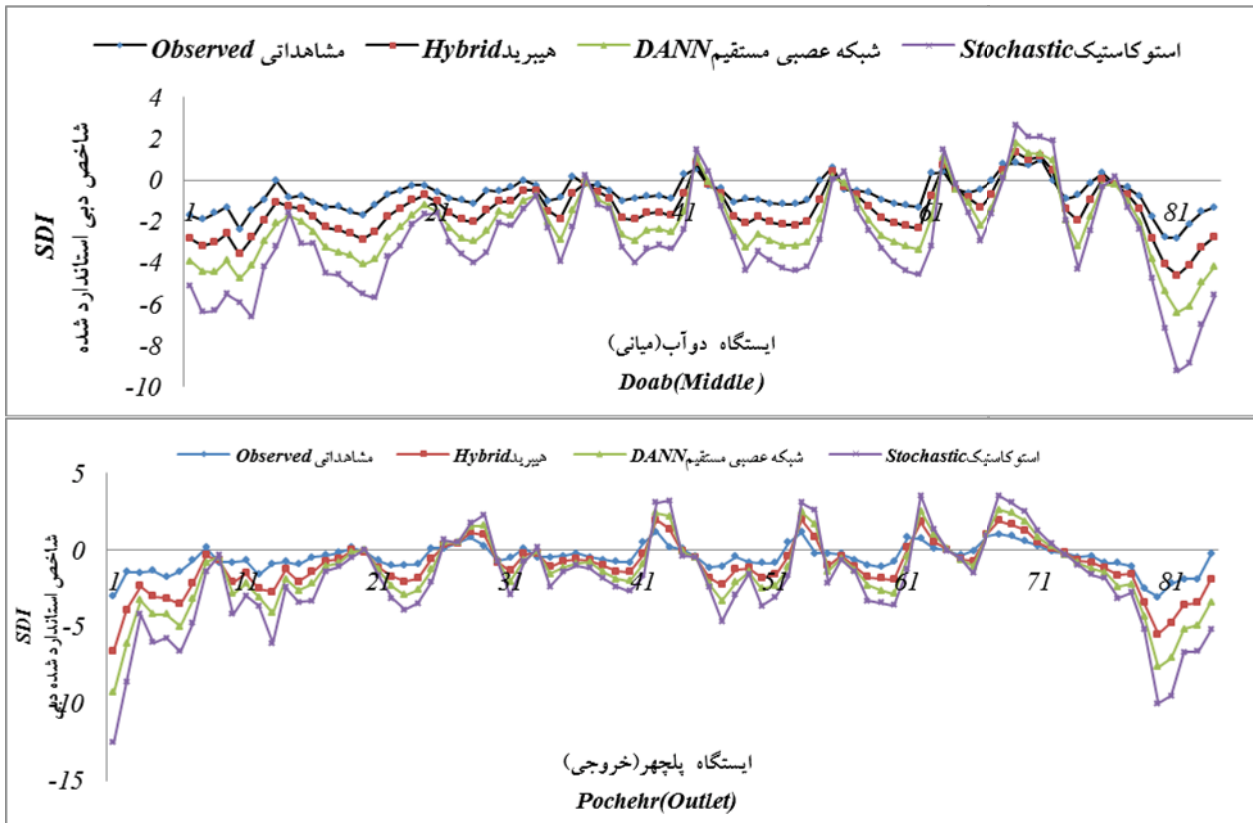
### نتایج بدست آمده از آماره کاپا

جدول ۸ مقادیر بدست آمده حاصل از آماره کاپا در دو مقیاس زمانی ماهانه و فصلی را نشان می دهد. نتایج بیانگر این است که آماره کاپای وزنی در تمامی مدل ها در مقیاس زمانی ماهانه دارای توافق خوب بوده و حداکثر توافق مربوط به مدل هیبرید و در ایستگاه پلچهر (خروجی) با مقدار کاپای ۰/۵۶۵ می باشد که نشان می دهد، میزان توافق طبقات مشاهده شده و پیش بینی شده در این مدل و ایستگاه بالاست. در مقیاس زمانی فصلی توافق مناسبی بین طبقات مشاهده ای و پیش بینی شده مشاهده نشده و حداکثر توافق (توافق ضعیف تا خیلی ضعیف) مربوط به مدل هیبرید در ایستگاه دوآب (میانی) با مقدار کاپای ۰/۲۳۱ می باشد.

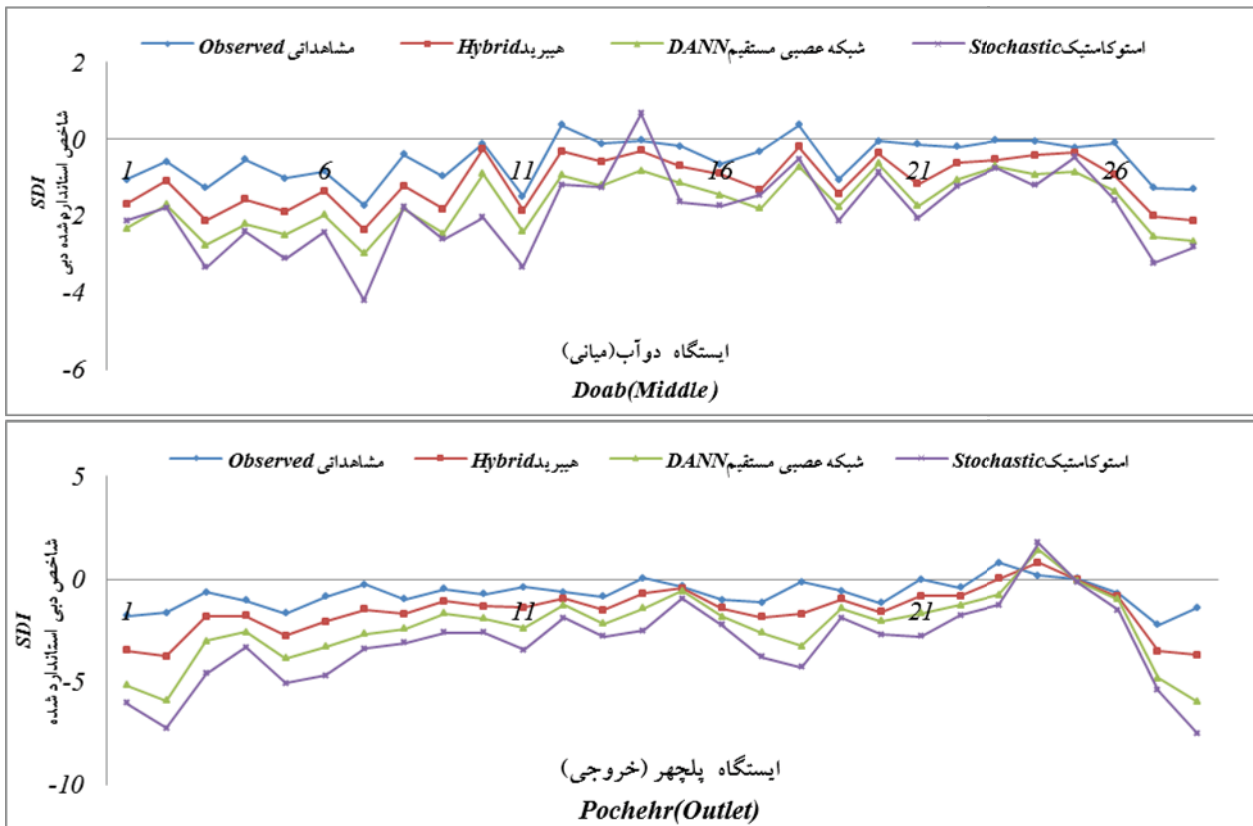
### بحث و نتیجه گیری

مطالعه حاضر با هدف ارزیابی مهارت مدل های استوکاستیک، شبکه عصبی مصنوعی و مدل هیبرید در مدل سازی و پیش بینی سری های زمانی خشکسالی هیدرولوژی با استفاده از شاخص SDI پرداخته شد.

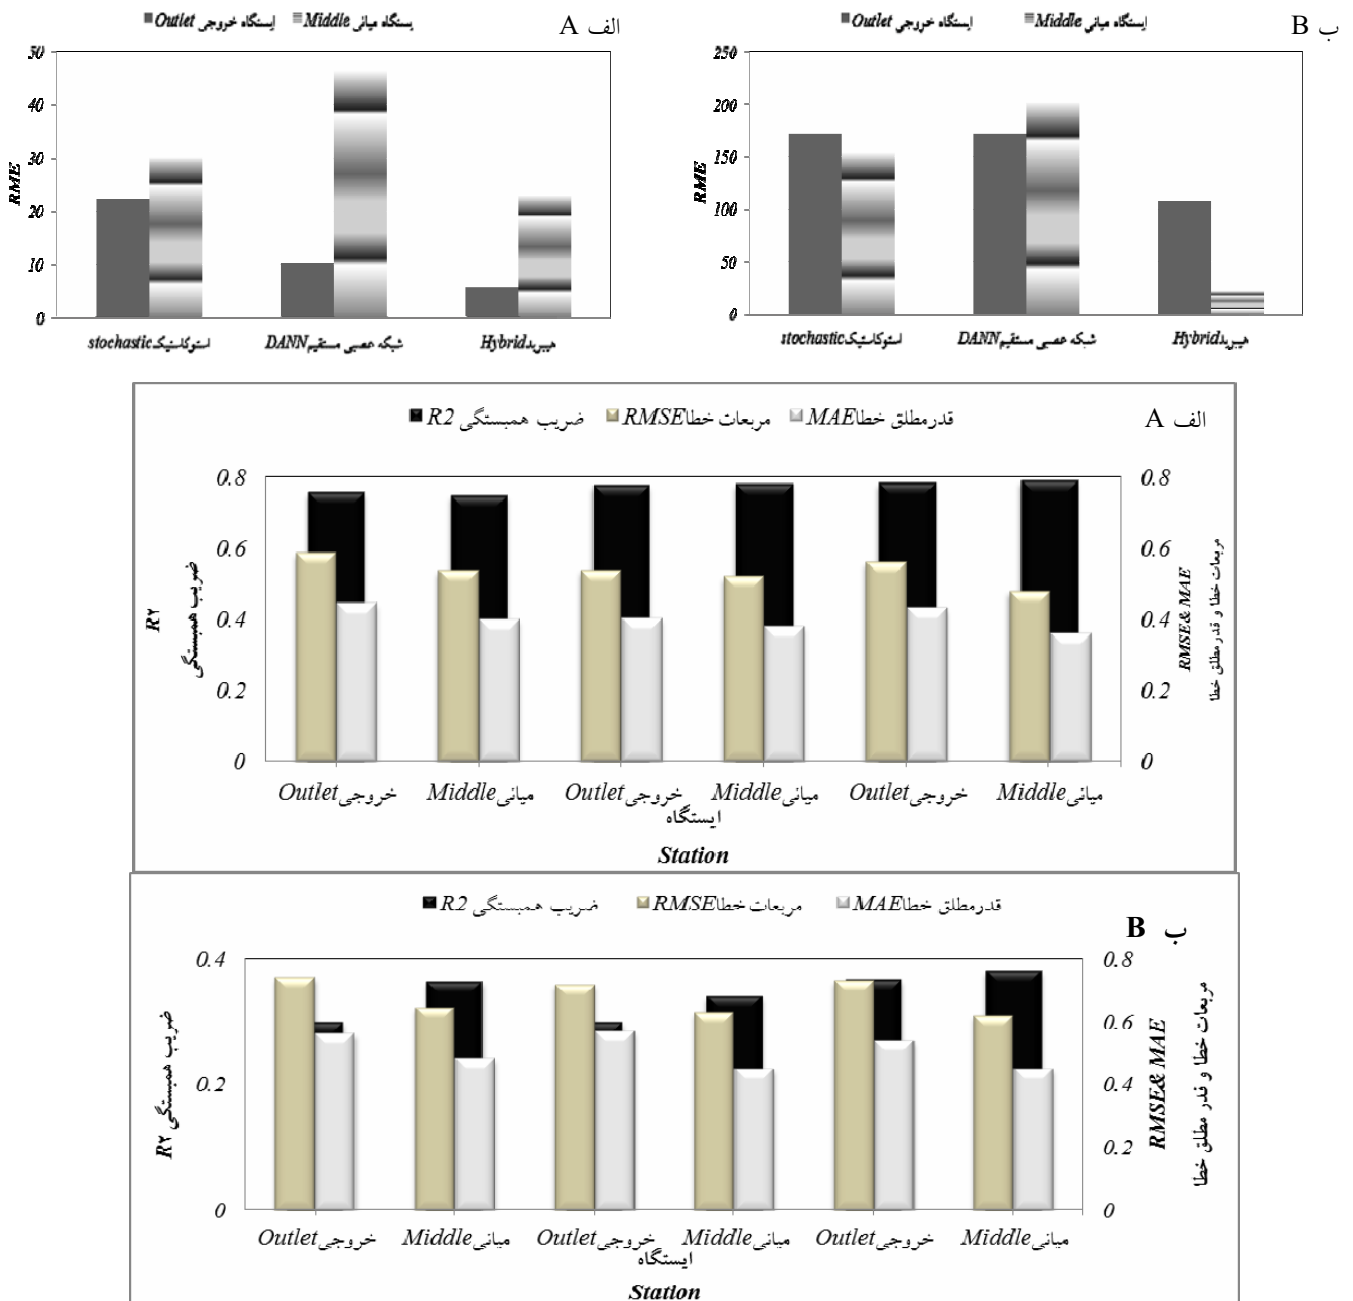
مقایسه مدل های استوکاستیکی و شبکه عصبی نشانگر قابلیت بالای شبکه در یافتن حافظه بین داده های سری زمانی بوده و موید



شکل ۶- مقایسه نتایج پیش بینی یک ماهه در مدل‌ها با مقادیر واقعی در مقیاس زمانی ماهانه در ایستگاه‌های مورد مطالعه  
 Fig6. A comparison between observed data and predicted data over 1-month lead time using for all monthly scale



شکل ۷- مقایسه نتایج پیش بینی یک ماهه در مدل‌ها با مقادیر واقعی در مقیاس زمانی فصلی در ایستگاه‌های مورد مطالعه  
 Fig7. A comparison between observed data and predicted data over 1-month lead time using for all seasonal scale



شکل ۸- مقایسه  $R^2$ , RMSE, MAE, RME مدل‌های مورد استفاده در مقیاس زمانی ماهانه (الف) و فصلی (ب) در ایستگاه‌های مورد مطالعه  
 Fig8. Comparison of  $R^2$ , RMSE, MAE and RME selected candidate stations, monthly (A) and Seasonal (B)

ایستگاه‌های هیدرومتری خروجی دارای کارایی بهتر و مناسب‌تر از ایستگاه واقع در بخش میانی حوزه است و در مقیاس فصلی ایستگاه‌های واقع در بخش میانی بهترین پاسخ را ارائه نموده‌اند. این بخش از نتایج با نتایج روی و همکاران [۱۹] در بررسی خشکسالی هیدرولوژی مبنی بر پاسخ مناسب ایستگاه‌های واقع در مرکز ثقل در مقیاس‌های بلند مدت مطابقت دارد. بطور کلی با افزایش مقیاس زمانی از فصلی به نه ماهه، یکساله و دو ساله ایستگاه‌های بخش میانی و با کاهش آن (ماهانه، روزانه و...) ایستگاه‌های واقع در خروجی حوزه بهترین پاسخ را در مدل‌سازی ارائه می‌دهند، چرا که مقادیر میانگین رواناب در آمار بلندمدت بنوعی نماینده شدت بارش

در مقیاس زمانی فصلی است، که مهمترین دلیل آن را می‌توان کم بودن تعداد داده‌ها در مقیاس فصلی (۱۳۶ داده) نسبت به مقیاس ماهانه (۴۰۸ داده) در مرحله صحت‌سنجی دانست. از طرفی تکنیک آموزش مارکوارت - لونیبرگ در مدل شبکه عصبی مصنوعی و هیبرید، در مواقعی که با کمبود داده در مرحله صحت‌سنجی مواجه باشد، کارایی مناسبی ندارد که این نتایج به طور دقیق مشابه نتایج خوشحال دستجردی و حسینی [۲] است. نتایج بررسی کارایی هر یک از مدل‌ها در مقیاس زمانی ماهانه و فصلی در هر یک از زیرحوزه‌ها به تنهایی نشان می‌دهد که کارایی مدل‌ها در پیش‌بینی خشکسالی هیدرولوژی در مقیاس ماهانه در

جدول ۶- مقایسه خصوصیات آماری مقادیر مشاهداتی و پیش‌بینی شده در مقیاس ماهانه

Tab6. Comparison of statistic properties of the observed and predicted data in monthly scale

نام ایستگاه	شکل مدل	واریانس	واریانس	F	میانگین	میانگین	Z
Station	Model	مشاهده شده Variance observed	پیش‌بینی شده Mean Forecasted		مشاهده شده Mean Observed	پیش‌بینی شده Mean Forecasted	
پل چهر Polchehr	ARIMA(313) (201) <sub>12</sub>	1.19	0.68	0.57	0.498-	-0.535	0.24
دوآب Doab	ARIMA(211) (100) <sub>12</sub>	0.574	0.578	0.97	-0.721	-0.726	-0.043
پل چهر Polchehr	ANN(2-1-1)	1.19	0.49	41.0	0.498-	-0.444	0.38
دوآب Doab	ANN(4-8-1)	0.574	0.261	1.1	-0.721	-724.0	0.05
پل چهر Polchehr	HSNNDA ARIMA(313) (201) <sub>12</sub> + ANN (12-4-1)	1.19	0.072	0.6	0.498-	-554.0	0.36
دوآب Doab	HSNNDA ARIMA(211) (100) <sub>12</sub> + ANN (8-14-1)	0.574	0.5	1.12	-0.721	-716.0	0.3

جدول ۷- مقایسه خصوصیات آماری مقادیر مشاهداتی و پیش‌بینی شده در مقیاس فصلی

Tab7. Comparison of statistic properties of the observed and predicted data in seasonal scale

نام ایستگاه	شکل مدل	واریانس	واریانس	F	میانگین	میانگین	Z
Station	Model	مشاهده شده Variance observed	پیش‌بینی شده Mean Forecasted		مشاهده شده Mean Observed	پیش‌بینی شده Mean Forecasted	
پل چهر Polchehr	ARIMA (111)(003) <sub>4</sub>	0.567	0.18	0.31	-0.494	-0.492	0.016
دوآب Doab	ARIMA (013)(002) <sub>4</sub>	0.492	0.2	0.48	-0.710	-0.796	0.99
پل چهر Polchehr	ANN(11-1-1)	0.567	0.014	0.025	-0.494	-0.526	0.375
دوآب Doab	ANN(5-5-1)	0.492	0.119	0.290	-0.790	-0.605	1.31
پل چهر Polchehr	HSNNDA ARIMA <sub>4</sub> (111) (003) + ANN (3-2-1)	0.567	0.072	0.127	-0.494	-0.588	1.07
دوآب Doab	HSNNDA ARIMA <sub>4</sub> (013) (002) + ANN (2-3-1)	0.492	0.159	0.381	-0.710	-0.774	0.763

جدول ۸- مقادیر آماره کاپا در مقیاس ماهانه و فصلی در تحقیق

Tab 8. Kappa Value in the monthly and seasonal scale in research

نام مدل Model Name	نام ایستگاه Station Name	آماره کاپای ماهانه Kappa Monthly	آماره کاپای فصلی Kappa Seasonly
استوکاستیک ARIMA	پل چهر Polchehr	0.528*	0.2
	دوآب Doab	0.519*	0.156
شبکه عصبی مستقیم DANN	پل چهر Polchehr	0.539*	0.05
	دوآب Doab	0.437*	0.231*
هیبرید HSNNDA	پل چهر Polchehr	0.565*	0.101
	دوآب Doab	0.555*	0.208

\* آماره‌ی کاپا با  $P\text{-value} < 0.05$  معنی دار است.

\*P-value < 0.05 is significant.

ورودی در شبکه استفاده شده و از سایر مدل‌های پیش‌بینی مانند مدل‌های تلفیقی نروفازی<sup>۱</sup>، هیبرید موجک - شبکه عصبی مصنوعی<sup>۲</sup> و... استفاده شده و نتایج با این تحقیق مقایسه گردد.

#### منابع

- 1- Abghari, H. 2008. Investigation of wavelet neural networks and auto-regressive models to intelligent prediction of monthly river flow. Ph.D. Dissertation. Faculty of Natural resources. Tehran University, 173p. (In Persian)
- 2- Akaike, H., 1974. A new look at the statistical model identification: IEEE Transactions on Automatic Control. 19: 716-723.
- 3- Ben-Zvi, A. 1987. Indices of hydrological drought in Israel. J Hydrol 92:179-191.
- 4- Box, G.E.P. and and Pierce, D. A. 1970. Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. Journal of the American Statistical Association. 65: 1509-1526.
- 5- Cohen, J. 1968. Weighted kappa: nominal scale agreement with provision for scaled disagreement or partial credit. Psychological Bulletin. 70, 213-220.
- 6- Hejabi, S. 2012. An Adaptive study of meteorological drought

در زمان تمرکز حوزه بوده که ایستگاه‌های میانی اعم از هواشناسی و هیدرومتری می‌توانند منعکس کننده رواناب کل حوزه باشند و برعکس با کاهش مقیاس، ایستگاه‌های خروجی حوزه نماینده تولید رواناب کل حوزه هستند [۱۹].

نتایج حاصل از مقادیر کاپای وزنی بیانگر این است که تمامی مدل‌ها در مقیاس زمانی ماهانه قادر بوده‌اند طبقات خشکسالی را با توافق خوب پیش‌بینی نمایند اما توانایی آنها در مقیاس فصلی بسیار ضعیف برآورد گردید و همچنین بیشترین مقدار آماره کاپای وزنی مربوط به ایستگاه پل چهر (خروجی) بوده است.

بطور کلی شبکه‌های عصبی به علت داشتن خاصیت غیرخطی و نامعین نسبت به روش‌های آماری و استوکاستیک از اهمیت بیشتری برخوردارند. البته شایان ذکر است که شبکه‌های عصبی مصنوعی در درون خود مدل‌های خطی را نیز شامل می‌شوند اما با بکارگیری مدل‌های هیبرید کارایی آنها دو چندان می‌گردد و به تناسب با روش‌های آماری و استوکاستیک، بسیار جامعتر هستند. لذا مدل شبکه عصبی مصنوعی - استوکاستیک، بدلیل در نظر گرفتن جزء خطی و غیرخطی سری زمانی، مدلی قدرتمند با توانمندی بالاست که می‌توان با دیدگاهی مثبت در پیش‌بینی مسائل هیدرولوژیکی به آن نگریت، بخصوص آنجا که این مدل قادر است قوانین حاکم بر داده‌ها، حتی داده‌های مغشوش را استخراج نماید و این خصوصیت برجسته‌ترین ویژگی این مدل در مقایسه با مدل‌های کلاسیک است.

در خشکسالی هیدرولوژیکی عوامل اقلیمی و ادافیکی زیادی موثرند، لذا در پایان جهت افزایش دقت پیش‌بینی خشکسالی هیدرولوژی پیشنهاد می‌گردد از پارامترهایی نظیر میزان پوشش گیاهی، میزان بارندگی، سیگنال‌های اقلیمی و... بعنوان یک پارامتر

1. Nero fuzzy  
2. Wavelet Neural Network Hybrid Model

- 16- Mishra, A. K. Desai, V. R. 2006. Drought Forecasting Using feed-forward recursive neural network. *Journal of Ecological Modelling*, 198: 127-138.
- 17- Nalbantis, N. Tsakiris, G. 2009. Assessment off hydrological drought revisited. *Journal of water resource management*. 23: 883-897.
- 18- Ryu, J. H. Svoboda, M. D. Lenter, J. D. Tadesse, T. and Knutson, C. L. 2009. Potential extents for ENSO-driven hydrologic drought forecasts in the United States. *Journal of Climate change*, (101) 3-4, 111-119p.
- 19- Salajegheh, A. Fath Abadi, A.H. and Najafi Hajivar, M. 2009. Comparison of artificial neural networks and time series model in drought forecast (Case study: Khorasan Razavi Province). *Iranian Journal of Watershed Management Science and Engineering*. 2(4): 74-77. (In Persian).
- 20- 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.
- 21- Valenca, M. Ludermir, T., and Valenca, A. 2005. River Flow Forecasting for Reservoir management through Neural Networks. In: *Proceedings of the Fifth International Conference on Hybrid Intelligent Systems* 64-75.
- 22- 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.
- 23- Zhang, G. Patuwo, B.E. and Hu, M.Y. 1998. Forecasting with artificial neural networks: the state of arts. *Int. J. Forecast*. 14, 35-61.
- forecasting methods in dry and wet Climates of Iran. M.S. Thesis. Faculty of Agriculture. Tehran University, 240p. (In Persian)
- 7- Kar Amouz, M. and Araghinezhad, S. 2009. Advanced hydrology. The Amir Kabir University Press, Tehran, 461p. (In Persian)
- 8- Kardavani, P. 2000. Drought and contrast in Iran. The Tehran University Press, Tehran, 198p. (In Persian)
- 9- Khoshhal Datjerdy, j. and Hoseini, S.M. 2010. Using artificial neural networks in the drought and climatic factors forecast (Case study: Isfahan Province). *Geography and environmental planning*. 39: 107-120. (In Persian)
- 10- Kumar, M.N. Murthy, C.S. Sesha Sai, MVR. and Roy, PS. 2009. On the use of Standardized Precipitation Index (SPI) for Drought Intensity Assessment. *Journal of Meteorological Application*. 16: 381- 389.
- 11- McKee, T. B. Doesken, N. J. and Kleist, J. 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.
- 12- Mendeenahll, W. Reinmuth, J.E. and Beaver, R. 1989. *Stat. Management Econ*. 700-710.
- 13- Mendenhall, W. wacyerly, D.D. and Scheaffer, R.L. 1990. *Mathematical statistics with application*. Cengage Learnin press, 944p.
- 14- Mishra, A. K. Desai, V. R. 2005 Drought forecasting using syochastic models. *Stoch Environ Res Risk Assess*, 19: 326-339.
- 15- Mishra, A. K. Desai, V. R. Singh, P. 2007. Drought Forecasting Using Hybrid Stochastic and Neural Network Model. *Journal of Hydrologic Engineering*. 12(6): 626-638.