

مقایسه مهارت مدل‌های استوکاستیک و شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی مقادیر و طبقات شاخص بارندگی استاندارد شده

سمیه حجایی* - دانشجوی کارشناسی ارشد هواشناسی کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران
جواد بذرافشان - استادیار گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران
نوذر قهرمان - استادیار گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران

پذیرش مقاله: ۱۳۹۱/۰۲/۰۲ تأیید نهایی: ۱۳۹۲/۰۴/۱۰

چکیده

هدف از پژوهش پیش رو، مقایسه کارایی مدل‌های استوکاستیک و شبکه‌های عصبی مصنوعی در پیش‌بینی کمی شاخص بارندگی استاندارد شده (SPI) در اقلیم‌های خشک و مرطوب ایران است. برای این امر، محاسبه SPI، در مقیاس‌های زمانی سه‌ماهه، شش‌ماهه و دوازده‌ماهه در چهار ایستگاه سینوپتیک کشور طی دوره ۲۰۰۷-۱۹۷۳ انجام شد. در گام بعد، مدل‌سازی سری‌های زمانی SPI برای پیش‌بینی‌های یک تا دوازده گام به جلو، به سه روش مدل‌سازی استوکاستیک، شبکه عصبی بازگشتی (RMSNN) و شبکه عصبی مستقیم (DMSNN) انجام گرفت. مقادیر SPI مربوط به دوره ۱۹۷۳ تا ۲۰۰۰، برای توسعه مدل‌ها و مابقی برای صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. در مرحله صحت‌سنجی، مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده SPI با استفاده از آزمون‌های آماری، ضریب همبستگی و شاخص خطا انجام شد. همچنین برای بررسی قابلیت مدل‌ها در پیش‌بینی طبقات SPI، از آماره کاپای کوهن استفاده شد. در نهایت، اولویت دقت مدل‌ها از دیدگاه‌هایی چون، افق زمانی پیش‌بینی و مقیاس زمانی بررسی خشکسالی تعیین شد. نتایج به‌دست آمده نشان داد: (۱) در مقیاس زمانی سه‌ماهه و دوازده‌ماهه، به‌طور کلی مدل‌های استوکاستیک (به ترتیب با میانگین خطای ۰/۶۷۸، ۰/۵۶۹ و ۰/۳۴۴ و میانگین ضریب همبستگی ۰/۶۸۲، ۰/۷۷۷ و ۰/۹۱۹) از نظر مهارت پیش‌بینی مقادیر SPI در اولویت کاربرد قرار دارند. (۲) در مقیاس زمانی سه‌ماهه، شش‌ماهه و دوازده‌ماهه به ترتیب، مدل‌های DMSNN، RMSNN و استوکاستیک (با میانگین کاپای ۰/۳۹۷، ۰/۵۳۰ و ۰/۷۵۰) از نظر مهارت پیش‌بینی طبقات SPI در اولویت کاربرد قرار دارند.

کلیدواژه‌ها: اقلیم‌های خشک و مرطوب، پیش‌بینی، خشکسالی، شاخص بارندگی استاندارد شده، مدل‌های استوکاستیک، مدل‌های شبکه عصبی مصنوعی.

مقدمه

خشکسالی یک رخداد هواشناسی تکرار شونده و موقتی است که ناشی از کاهش بارندگی طی یک دوره زمانی بلندمدت است. از آنجایی که پیش‌آگاهی از علائم اولیه خشکسالی‌های محتمل، در راهبردهای کاهش خسارات خشکسالی مؤثر است، پیش‌بینی خشکسالی نقش مهمی در برنامه‌ریزی و مدیریت سیستم‌های منابع آب ایفا می‌کند.

مدل‌های استوکاستیک^۱ در دهه‌های اخیر، به‌طور گسترده‌ای برای پیش‌بینی متغیرهای هیدرولوژیکی مانند بارندگی و جریان‌های سالانه و ماهانه رودخانه‌ها مورد استفاده قرار گرفته‌اند. رائو و پادمانابهان (۱۹۸۴) طبیعت استوکاستیک شاخص شدت خشکسالی پالمر^۲ (PDSI) را مورد ارزیابی قرار دادند و با استفاده از مدل‌های استوکاستیک منتخب آنها را توصیف کردند تا سری‌های زمانی PDSI را شبیه‌سازی و پیش‌بینی کنند. چانگ و سالاس (۲۰۰۰)، مدل‌های میانگین متحرک خودهمبسته گسسته^۳ (DARMA) را برای برآورد احتمالات وقوع رخداد‌های خشکسالی استفاده کردند. میشرای و دزای (۲۰۰۵) بر مبنای شاخص بارندگی استاندارد شده^۴ (SPI)، مدل‌های استوکاستیک خطی را برای پیش‌بینی خشکسالی در حوضه رودخانه کانساباتی هند استفاده کردند. مدرس (۲۰۰۷) با کاربرد مدل‌های استوکاستیک برای پیش‌بینی جریان‌های ماهانه رودخانه زاینده‌رود، نشان داد که این مدل‌ها توانایی خوبی در پیش‌بینی خشکسالی‌های هیدرولوژیکی رودخانه مذکور دارند. فرناندز و همکاران (۲۰۰۹) با استفاده از مدل‌های استوکاستیک، به پیش‌بینی خشکسالی هیدرولوژیکی در شمال غربی اسپانیا پرداختند. اما در کل، مدل‌های استوکاستیک برای سری‌های زمانی‌ای کاربرد دارند که دارای رفتار خطی هستند. بنابراین، در صورت غیر خطی یا ناپایستا بودن سری زمانی هیدرولوژیکی، بررسی کارایی مدل‌های دیگر در مدل‌سازی سری زمانی ضرورت می‌یابد.

در دهه‌های اخیر شبکه‌های عصبی مصنوعی^۵ (ANN)، به دلیل برخورداری از طبیعت انعطاف‌پذیر و غیرخطی در مدل‌سازی، کارایی بالایی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و ناپایستا از خود نشان داده‌اند. میشرای و دزای (۲۰۰۶)، مدل‌های استوکاستیک خطی و شبکه‌های عصبی مصنوعی را برای پیش‌بینی خشکسالی بر مبنای شاخص خشکسالی SPI مقایسه کردند.

مرید و همکاران (۲۰۰۷) از مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی خشکسالی بر اساس شاخص‌های خشکسالی SPI و شاخص خشکسالی مؤثر^۶ (EDI) استفاده کردند.

فتح‌آبادی و همکاران (۲۰۰۹)، به مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی، مدل‌های استوکاستیک و روش نزدیک‌ترین همسایگی^۷ (KNN) در پیش‌بینی شاخص بارندگی استاندارد شده پرداختند.

1. Stochastic
2. Palmer Drought Severity Index
3. Discrete Autoregressive Moving Average
4. Standardized Precipitation Index
5. Artificial Neural Network
6. Effective Drought Index
7. K-Nearest Neighbor

فاتحی مرج و میجرینک (۲۰۱۱) با استفاده از مدل شبکه‌های عصبی مصنوعی و بر اساس تصاویر ماهواره‌ای و شاخص‌های اقلیمی به پیش‌بینی خشکسالی کشاورزی پرداختند. با توجه به تعدد وقوع خشکسالی‌ها در ایران و ضرورت تعیین بهترین مدل پیش‌بینی با توجه به خصوصیت‌های اقلیمی منطقه، مطالعه پیش رو با هدف مقایسه مهارت مدل‌های استوکاستیک و شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی خشکسالی، به توسعه مدل‌های مذکور روی سری‌های زمانی SPI در تعدادی از ایستگاه‌های سینوپتیک ایران پرداخته شد.

مواد و روش‌ها

داده‌ها و ایستگاه‌های مورد مطالعه

ایستگاه‌های مورد مطالعه، شامل چهار ایستگاه بندر انزلی، همدان نوژه، بوشهر و زاهدان هستند که بر مبنای روش دومارتن گسترش‌یافته (خلیلی، ۱۳۷۶)، نماینده اقلیم‌های خیلی مرطوب تا فراخشک هستند. مشخصه‌های ایستگاه‌های مورد مطالعه در جدول شماره ۱ ارائه شده است. داده‌های مورد استفاده، شامل داده‌های بارندگی ماهانه مربوط به سال‌های ۲۰۰۷-۱۹۷۳ است.

به دلیل ناچیز بودن مقدار خلاءهای آماری (کمتر از یک درصد کل داده‌ها)، میانگین دوره مورد بررسی برای هر ماه سال در هر یک از ایستگاه‌ها محاسبه و در بخش خلاءها جای‌گذاری شده است. برای بررسی کفایت داده‌ها، از آزمون هارست^۱ (هارست، ۱۹۵۱) استفاده شد. از آنجا که مقدار آماره آزمون در همه موارد بیشتر از ۰/۵ بود، کفایت داده‌ها تأیید شده است.

جدول ۱. مشخصه‌های ایستگاه‌های مورد مطالعه

ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)	طبقه اقلیمی	دوره آماری مورد مطالعه
بندر انزلی	۲۷° ۴۹' شرقی	۳۷° ۲۹' شمالی	-۲۳/۶	خیلی مرطوب نوع ب- معتدل	۱۹۷۳-۲۰۰۷
بوشهر	۴۹° ۵۰' شرقی	۲۸° ۵۸' شمالی	۹	خشک- گرم	۱۹۷۳-۲۰۰۷
همدان نوژه	۴۳° ۴۸' شرقی	۳۵° ۱۲' شمالی	۱۶۷۹/۷	نیمه خشک- فرا سرد	۱۹۷۳-۲۰۰۷
زاهدان	۵۳° ۶۰' شرقی	۲۹° ۲۸' شمالی	۱۳۷۰	فرا خشک- سرد	۱۹۷۳-۲۰۰۷

شاخص بارندگی استاندارد شده

یکی از مهم‌ترین شاخص‌های پایش خشکسالی، شاخص بارندگی استاندارد شده (SPI) است. این شاخص را نخستین بار مک‌کی و همکاران (۱۹۹۳: ۱۸۴-۱۷۹) برای پایش خشکسالی در ایالت کلرادو ارائه کردند. شاخص بارندگی استاندارد شده یعنی، مقداری از تابع توزیع نرمال استاندارد که احتمال تجمعی آن با احتمال تجمعی متغیر بارندگی از تابع

توزیع معین، مساوی باشد (ادواردز و مک‌کی، ۱۹۹۷: ۴۷). به دلیل قابلیت تعریف SPI در مقیاس‌های زمانی مختلف، امکان توصیف شرایط خشکسالی در دامنه کاربردهای هواشناسی، هیدرولوژیکی و کشاورزی، فراهم است که از مزایای شاخص بارندگی استاندارد شده به شمار می‌رود (هایس و همکاران، ۱۹۹۹). طبقه‌بندی SPI (مک‌کی و همکاران، ۱۹۹۵: ۲۳۶-۲۳۳) در جدول شماره ۲ ارائه شده است.

جدول ۲. طبقه‌بندی SPI

SPI	< ۲	۱/۵ تا ۲	۱ تا ۱/۵	-۱ تا -۱/۵	-۱/۵ تا -۰/۵	۰/۵ تا ۰/۵	۰/۵ تا ۱	۱ تا ۱/۵	۲ تا ۱/۵	> ۲
طبقه	خیلی شدید	شدید	متوسط	خفیف	نرمال	خفیف	متوسط	شدید	خیلی شدید	
	خشکسالی					ترسالی				

مک‌کی و همکاران (۱۹۹۳: ۱۸۴-۱۷۹) اظهار داشتند که بهترین توزیع قابل برازش بر داده‌های بارندگی ماهانه در ایالات متحده، تابع توزیع احتمال گاما است. با رویکرد به اینکه در مورد مقیاس‌های زمانی بیش از یک ماهه SPI، فرض پیروی داده‌های بارندگی از توزیع گاما، همواره صادق نیست (بلین، ۲۰۱۱؛ گاتمن، ۱۹۹۹)، در این مطالعه پس از محاسبه مقادیر بارندگی هر ماه در مقیاس‌های زمانی سه، شش و دوازده‌ماهه، ابتدا با استفاده از نرم‌افزار Easy fit، بر مبنای آماره کلموگروف - اسمیرنوف^۱، بهترین توزیع قابل برازش بر مقادیر بارندگی هر ماه تعیین شد. سپس با انتقال احتمال تجمعی توزیع بهینه به توزیع احتمال تجمعی نرمال استاندارد، مقادیر SPI در مقیاس‌های زمانی سه، شش و دوازده‌ماهه برای سال‌های ۱۹۷۳ تا ۲۰۰۷ محاسبه شد. در گام بعد، توسعه مدل‌های استوکاستیک و ANN بر سری‌های زمانی SPI مربوط به سال‌های ۱۹۷۳ تا ۲۰۰۰ انجام گرفت و مقادیر SPI مربوط به سال‌های ۲۰۰۱ تا ۲۰۰۷، برای صحت‌سنجی مدل‌های استوکاستیک و شبکه‌های عصبی مصنوعی به کار گرفته شد.

مدل‌سازی استوکاستیک سری‌های زمانی SPI

مدل‌های خودهمبسته^۲ (AR) ساده‌ترین نوع مدل‌های استوکاستیک هستند که بر مبنای مدل‌های زنجیره مارکوف^۳ توسعه یافته‌اند. این مدل‌ها همبستگی بین توالی زمانی متغیرها را در نظر می‌گیرند. به بیان دیگر، مقدار متغیر در یک زمان معین، بستگی به مقدار آن متغیر در زمان‌های قبلی دارد. از فرضیه‌های اولیه این مدل‌ها، نرمال بودن سری زمانی است. مدل‌های AR توانایی لازم برای مدل‌سازی سری‌های زمانی کم‌نوسان را دارند، اما چنانچه نوسان‌ها در سری‌های زمانی زیاد باشد، می‌توان با اضافه کردن مؤلفه مدل میانگین متحرک^۴ (MA) به مدل‌های AR، نتایج مدل‌سازی را بهبود بخشید. این دسته از مدل‌های استوکاستیک، مدل‌های خودهمبسته میانگین متحرک^۵ (ARMA) نامیده می‌شوند.

1. Kolmogorov-Smirnov
2. Autoregressive
3. Markov chain
4. Moving Average
5. Autoregressive Moving Average

شرط استفاده از مدل‌های ARMA، عدم انحراف ظاهری از حالت ایستایی در سری زمانی است. چنانچه این شرط برقرار نباشد، می‌توان با استفاده از عملگر تفاضل، سری زمانی را ایستا کرد. استفاده از dامین تفاضل سری و مدل‌سازی آن با مدل ARMA منجر به پیدایش سری جدیدی از مدل‌های استوکاستیک غیرفصلی، موسوم به مدل‌های خودهمبسته میانگین متحرک تجمعی^۱ (ARIMA) می‌شود. در صورت استفاده از عملگر تفاضل فصلی با تأخیر w، مدل‌های استوکاستیک فصلی به‌وجود می‌آید. ترکیبی از مدل‌های فصلی و غیرفصلی، مدل‌های موسوم به آریمای مکرر^۲ را تشکیل می‌دهند که فرم پایه آنها به‌صورت رابطه ۱ است (باکس و جنکینز، ۱۹۷۶: ۱۹):

$$\Phi_P(B^w)\phi_p(B)(1-B^w)^D(1-B)^d Z_t = \Theta_Q(B^w)\theta_q(B)\varepsilon_t \quad (\text{رابطه ۱})$$

که p مرتبه مدل AR غیر فصلی، P مرتبه مدل AR فصلی، q مرتبه مدل MA غیر فصلی، Q مرتبه مدل MA فصلی، w طول فصل، ε_t متغیر تصادفی، B عملگر تفاضل به‌صورت $B(Z_t) = Z_{t-1}$ ، $(1-B)^d$ معادل dامین تفاضل غیر فصلی و $(1-B^w)^D$ معادل D امین تفاضل فصلی به‌اندازه w است.

توسعه مدل‌های استوکاستیک شامل سه مرحله شناسایی، برآورد پارامتر و آزمون کفایت مدل است (باکس و جنکینز، ۱۹۷۶: ۱۹). در مرحله شناسایی، ساختار همبستگی زمانی سری، به‌وسیله آزمون توابع خودهمبستگی^۳ (ACF) و خودهمبستگی جزئی^۴ (PACF) تعیین می‌شود، سپس این اطلاعات برای تعیین شکل کلی مدل یک متغیره استفاده می‌شود. با توجه به تعداد گام‌های معنادار در هر یک از نمودارهای ACF و PACF، می‌توان محدوده تغییرات مرتبه مدل‌ها را به‌دست آورده و درنهایت با ترکیب آنها به مدل‌های داوطلب دست یافت. مدلی که کمترین معیار اطلاعات آکائیک^۵ (AIC) (آکائیکه، ۱۹۷۴) و معیار شوارتز - بیزین^۶ (SBC) (شوارتز، ۱۹۷۸: ۴۶۴-۴۶۱) را داشته باشد، بهترین مدل شمرده و انتخاب می‌شود.

فرمول ریاضی AIC به‌صورت رابطه ۲ است:

$$AIC = -2\log L + 2m \quad (\text{رابطه ۲})$$

فرمول ریاضی SBC به‌صورت رابطه ۳ است:

$$SBC = -2\log L + m \ln(n) \quad (\text{رابطه ۳})$$

که در روابط فوق، $m = p + q + P + Q$ تعداد پارامترهای برآورد شده در مدل و L تابع درست‌نمایی مدل‌های استوکاستیک و n تعداد مشاهدات است.

برای برآورد اولیه پارامترهای مدل استوکاستیک، از ACF سری‌های زمانی استفاده می‌شود که مقادیر در مرحله شناسایی به‌دست می‌آید. سپس برآوردهای اولیه، به‌منزله مقادیر اولیه، در یک الگوریتم بهینه‌سازی تکراری، برای حداقل

1. Autoregressive Integrated Moving Average
 2. Multiplicative ARIMA
 3. Autocorrelation Function
 4. Partial Autocorrelation Function
 5. Akaike Information Criterion
 6. Schwarz's Bayesian Criterion

کردن مجموع مربعات باقیمانده‌ها استفاده می‌شود. در این مطالعه، برای برآورد پارامترهای مدل‌های منتخب، از نرم‌افزار MINTAB 14 استفاده شد.

در مرحلهٔ آزمون کفایت مدل، ابتدا سری باقیمانده‌ها از تفاضل سری زمانی مشاهده شده SPI و سری زمانی حاصل از برازش مدل منتخب بر سری زمانی SPI محاسبه می‌شود و سپس آزمون‌های صحت‌سنجی روی باقیمانده‌ها، شامل آزمون کلموگروف - اسمیرنوف و آزمون فقدان برازش پرت‌مانتیو^۱ برای بررسی کفایت مدل منتخب انجام می‌گیرد. آماره آزمون کلموگروف - اسمیرنوف به صورت رابطه ۴ است:

$$D = \max |P_x(X) - S_n(x)| \quad (\text{رابطه ۴})$$

که D آماره آزمون، $P_x(x)$ تابع توزیع نظری تجمعی تحت فرضیه صفر و $S_n(x)$ تابع چگالی تجمعی نمونه بر اساس n مشاهده است.

آماره آزمون فقدان برازش پرت‌مانتیو از رابطه ۵ به دست می‌آید (مکریداکیس و همکاران، ۲۰۰۳: ۱۸۵):

$$Q(r) = n(n+2) \sum_{k=1}^L (n-k)^{-1} r_k^2 \quad (\text{رابطه ۵})$$

که n تعداد مشاهدات سری و $L = 0.1n + p + q$ و r_k تابع ACF سری باقیمانده‌ها است. مقادیر $Q(r)$ با مقادیر χ^2 جدول با درجه آزادی 0.1n مقایسه می‌شود. چنانچه مقدار $Q(r)$ کمتر از χ^2 جدول باشد، انتخاب مدل به درستی انجام گرفته است.

مدل‌های شبکهٔ عصبی مصنوعی


در این مطالعه از دو روش مختلف شبکهٔ عصبی چندگامی بازگشتی^۲ (RMSNN) و شبکهٔ عصبی چندگامی مستقیم^۳ (DMSNN) برای پیش‌بینی چندگام به جلو استفاده شده است. در سمت راست شکل ۱، نمایی از مدل RMSNN ارائه شده است. از آنجا که روش RMSNN یک نرون خروجی دارد، مشابه مدل استوکاستیک است. در این روش بر مبنای یک نرون 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.

در سمت چپ شکل ۱ نیز، نمایی از مدل DMSNN ارائه شده است. مزیت مدل DMSNN نسبت به مدل استوکاستیک، داشتن خروجی‌های چندگانه است، یعنی لایهٔ خروجی بر خلاف مدل استوکاستیک و مدل RMSNN، دارای چندین نرون است و هر نرون خروجی یک گام زمانی را پیش‌بینی می‌کند. در این مطالعه، لایهٔ خروجی DMSNN دارای ۱۲ نرون است که نشان‌دهندهٔ افق زمانی یک تا دوازده ماهه است.

در هر دو روش ANN، الگوریتم آموزش مورد استفاده، الگوریتم لوبنبرگ - مارکوات بر مبنای الگوریتم آموزش

1. Portmanteau
2. Recursive Multi-Step Neural Network
3. Direct Multi-Step Neural Network

پس‌انتشار خطا و تابع انتقال مورد استفاده در لایه مخفی و خروجی، به ترتیب تابع انتقال تانژانت - سیگموئید و تابع انتقال خطی بودند. تعداد تکرار^۱ برابر ۵۰۰ بار تعیین شد و تنها یک لایه مخفی برای شبکه در نظر گرفته شد.



شکل ۱. مدل RMSNN (راست) و DMSNN (چپ)

برای داشتن بالاترین دقت پیش‌بینی، تعداد نرون‌های ورودی و مخفی بهینه از طریق آزمون تعیین شد. بدین گونه که تعداد نرون‌های لایه ورودی و مخفی از یک تا n تغییر می‌کرد و تعداد نرون‌های لایه مخفی از یک تا $2m+1$ متغیر بود (m تعداد نرون‌های ورودی متناظر). دوره زمانی ۱۹۷۳ تا ۲۰۰۰ برای آموزش شبکه استفاده شد. تمام ساختارهای داوطلب، از طریق برنامه‌نویسی در محیط نرم‌افزار متلب مورد بررسی قرار گرفت و ساختارهایی که بر اساس شاخص ریشه میانگین مربعات خطا^۲ (RMSE)، کمترین خطای پیش‌بینی را داشتند، ساختار بهینه مدل RMSNN و DMSNN معرفی شدند.

صحت‌سنجی مدل‌های منتخب

برای صحت‌سنجی مدل‌های منتخب، در ابتدا پیش‌بینی‌های یک گام تا دوازده گام به جلو برای سری‌های زمانی SPI، در دوره ۲۰۰۱ تا ۲۰۰۷، بر اساس مدل‌های منتخب انجام گرفت. سپس مقادیر مشاهده‌شده و پیش‌بینی‌شده یک تا دوازده گام به جلو SPI در دوره ۲۰۰۱ تا ۲۰۰۷، از طریق محاسبه شاخص RMSE و ضریب همبستگی پیرسون^۳ مورد مقایسه قرار گرفتند. علاوه بر مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده، به مقایسه طبقات مشاهده‌شده و پیش‌بینی‌شده SPI پرداخته شد. برای این امر، از آماره کاپای کوهن^۴ استفاده شد.

1. Epoch
2. Root Mean Square Error
3. Pearson Correlation Coefficient
4. Cohen's Kappa statistic

آماره کاپا

آماره کاپا را نخستین بار کوهن (۱۹۶۰) به‌عنوان معیار اندازه‌گیری توافق طبقات معرفی کرد. اگر نسبت کل اجزایی از سری زمانی باشد که به طبقه i از یک سری و به طبقه j از سری دوم اختصاص دارد، این نسبت‌ها می‌توانند داخل یک ماتریس شکل بگیرند که قطر اصلی آن شامل نسبت‌های منحصربه‌فرد P_{ij} اجزایی است که در هر دو سری مطابقت دارند. P_0 مجموع مقادیر P_{ij} است. با در نظر گرفتن به‌عنوان حاصل ضرب مجموع نسبت‌های ردیف و ستون مربوطه ($P_{e,ij} = P_{i.} \cdot P_{.j}$)، مقدار قابل انتظار توافق، برابر است با جمع مقادیر $P_{e,ij}$ ؛ این جمع را P_e می‌نامند. آماره کاپا به‌صورت رابطه ۶ تعریف می‌شود:

$$K = \frac{P_0 - P_e}{1 - P_e} \quad \text{رابطه ۶}$$

مقدار کاپا مشابه ضریب همبستگی، بین ۱- تا ۱ تغییر می‌کند و مقادیر مثبت نشان‌دهنده توافق مثبت و مقادیر منفی نشان‌دهنده توافق منفی هستند. لندیس و کوچ (۱۹۷۷) پیشنهاد کردند که مقادیر K کمتر از ۰/۴ نشان‌دهنده توافق ضعیف تا خیلی ضعیف، مقادیر ۰/۴۰-۰/۵۵ نشان‌دهنده توافق متوسط، مقادیر ۰/۷۰-۰/۵۵ نشان‌دهنده توافق خوب و مقادیر بیش از ۰/۷۰ نشان‌دهنده توافق خیلی خوب تا عالی هستند. در مقایسه طبقات مشاهده‌شده و پیش‌بینی‌شده، عدم توافق طبقات نزدیک به هم، به بزرگی عدم توافق طبقات دور از هم نیست (کوهن، ۱۹۶۸). از این رو با در نظر گرفتن وزن‌های معین برای هر یک از حالات عدم توافق، می‌توان مقایسه دقیق‌تری از طبقات SPI در سری‌های زمانی مشاهده‌شده و پیش‌بینی‌شده داشت. با در نظر گرفتن وزن w_{ij} برای عدم توافق در درایه ij ماتریس، عدم توافق وزنی از مجموع حاصل ضرب نسبت P_{ij} در w_{ij} به‌دست می‌آید. بنابراین، آماره کاپای وزنی از رابطه ۷ به‌دست می‌آید:

$$K = 1 - \frac{\sum w_{ij} P_{ij}}{\sum w_{ij} P_{e,ij}} \quad \text{رابطه ۷}$$

آماره آزمون معناداری آماره کاپای وزنی با فرضیه صفر عدم توافق، به‌صورت رابطه ۸ است:

$$t = \frac{K}{\sqrt{\frac{\sum w_{ij}^2 P_{e,ij} - (\sum w_{ij} P_{e,ij})^2}{n(\sum w_{ij} P_{e,ij})^2}}} \quad \text{رابطه ۸}$$

در این رابطه n تعداد مشاهدات سری است.

یافته‌های تحقیق

نتایج مدل‌سازی سری‌های زمانی SPI با استفاده از مدل‌های استوکاستیک

مدل‌های منتخب سری‌های زمانی SPI و مقادیر AIC و SBC آنها در جدول ۳ ارائه شده است. نتایج آزمون‌های کفایت مدل‌های استوکاستیک منتخب شامل آزمون کلموگروف - اسمیرنوف و آزمون فقدان برآزش در جدول ۴ ارائه شده است.

جدول ۳. مدل‌های منتخب سری‌های زمانی SPI

SBC	AIC	مدل منتخب	SPI	ایستگاه
۷۵۳/۰۷	۷۴۱/۶۵	ARIMA(۰,۰,۲)	SPI3	بندر انزلی
۶۲۴/۹۷	۶۰۹/۷۸	ARIMA(۱,۱,۱)(۰,۰,۱) _۶	SPI6	
۳۴۸/۲۸	۳۳۶/۹۴	ARIMA (۰,۱,۱)(۰,۰,۱) _{۱۲}	SPI12	
۷۱۱/۳۴	۶۸۴/۸۱	ARIMA (۰,۰,۲)(۲,۱,۲) _۶	SPI3	بوشهر
۷۳۹/۱۹	۷۱۶/۴۰	ARIMA (۲,۱,۱)(۲,۰,۰) _۶	SPI6	
۲۵۰/۶۶	۲۲۷/۹۸	ARIMA (۰,۱,۱)(۲,۰,۲) _{۱۲}	SPI12	
۷۲۰/۳۵	۷۰۸/۹۱	ARIMA (۰,۰,۲)	SPI3	همدان نوژه
۶۰۸/۳۸	۵۷۰/۳۶	ARIMA (۲,۰,۱)(۰,۰,۱) _۶	SPI6	
۳۷۶/۲۹	۳۶۴/۹۵	ARIMA (۱,۱,۰)(۰,۰,۱) _{۱۲}	SPI12	
۷۱۷/۵۱	۷۰۶/۰۷	ARIMA (۰,۰,۲)	SPI3	زاهدان
۵۳۳/۸۱	۴۹۹/۵۹	ARIMA (۱,۰,۱)(۰,۰,۱) _۶	SPI6	
۱۳۲/۱۹	۱۲۰/۸۵	ARIMA (۱,۱,۰)(۰,۰,۱) _{۱۲}	SPI12	

جدول ۴. نتایج آزمون کلموگروف - اسمیرنوف و آزمون فقدان برازش


آزمون فقدان برازش			آزمون کلموگروف - اسمیرنوف		SPI	ایستگاه
χ^2	df	Q(r)	P-value	آماره K-S		
۴۴/۹۷	۳۱	۲۸/۳۳	۰/۰۵۴	-/۰۷۳	SPI3	بندر انزلی
۴۰/۱۱	۲۷	۱۸/۸۴	۰/۱۲۵	-/۰۶۴	SPI6	
۴۳/۷۷	۳۰	۲۹/۱۵	۰/۰۰۶	-/۰۹۵	SPI12	
۳۸/۸۹	۲۶	۳۲/۹۷	۰/۲۹۵	-/۰۵۳	SPI3	بوشهر
۴۱/۳۴	۲۸	۳۲/۹۲	۰/۰۳۶	-/۰۷۷	SPI6	
۴۰/۱۱	۲۷	۲۷/۵۹	۰/۰۰۰	-/۲۵۰	SPI12	
۴۴/۹۷	۳۱	۳۹/۸۴	۰/۹۳۲	-/۰۲۹	SPI3	همدان نوژه
۴۲/۵۶	۲۹	۳۳/۵۵	۰/۰۳۷	-/۰۷۷	SPI6	
۴۳/۷۷	۳۰	۲۷/۹۹	۰/۰۰۰	-/۱۱۵	SPI12	
۴۴/۹۷	۳۱	۲۵/۱۲	۰/۰۷۲	-/۰۷۰	SPI3	زاهدان
۴۳/۷۷	۳۰	۲۳/۶۰	۰/۰۸۹	-/۰۶۸	SPI6	
۴۳/۷۷	۳۰	۲۳/۲۸	۰/۰۰۰	-/۱۷۵	SPI12	

نتایج بیانگر این است که در مورد SPI3 و SPI6، فرضیه صفر مبنی بر نرمال بودن باقیمانده‌ها در همه ایستگاه‌ها در سطح اشتباه یک درصد پذیرفته می‌شود. اما در مورد SPI12، فرضیه صفر مبنی بر نرمال بودن باقیمانده‌ها در تمام ایستگاه‌ها رد می‌شود. نتایج آزمون فقدان برازش، بیان می‌کند که فرضیه صفر، مبنی بر پیروی سری زمانی از مدل

منتخب، در سطح اشتباه یک درصد در مورد تمام مدل‌های منتخب پذیرفته می‌شود، از این رو انتخاب مدل‌های استوکاستیک منتخب، صحیح است.

نتایج مدل‌سازی سری‌های زمانی SPI با استفاده از مدل‌های ANN

شکل ۲ برای نمونه، نمودار تغییرات ضریب همبستگی ترکیب‌های مختلف نرون‌های ورودی و مخفی برای سری زمانی SPI12 بندرانزلی بر اساس رهیافت DMSNN را نشان می‌دهد.



شکل ۲. ضریب همبستگی ترکیب‌های مختلف نرون‌های ورودی و مخفی برای سری زمانی SPI12 بندرانزلی بر اساس مدل DMSNN (ساختار شبکه: [a-b]، تعداد نرون ورودی: a تا ۱۲، تعداد نرون لایه مخفی: b تا ۱ تا ۲a)

با توجه به شکل، ساختار مدل DMSNN با نه نرون ورودی و چهار نرون در لایه مخفی، بیشترین ضریب همبستگی ($r=0/899$) را نسبت به سایر ساختارهای داوطلب دارد. ساختارهای بهینه مدل RMSNN و DMSNN برای سری‌های زمانی SPI در هر یک از ایستگاه‌های مورد مطالعه، در قالب تعداد نرون‌های ورودی و تعداد نرون‌های لایه مخفی در جدول ۵ ارائه شده است. لایه خروجی مدل RMSNN و DMSNN، به ترتیب دارای یک نرون و ۱۲ نرون است.

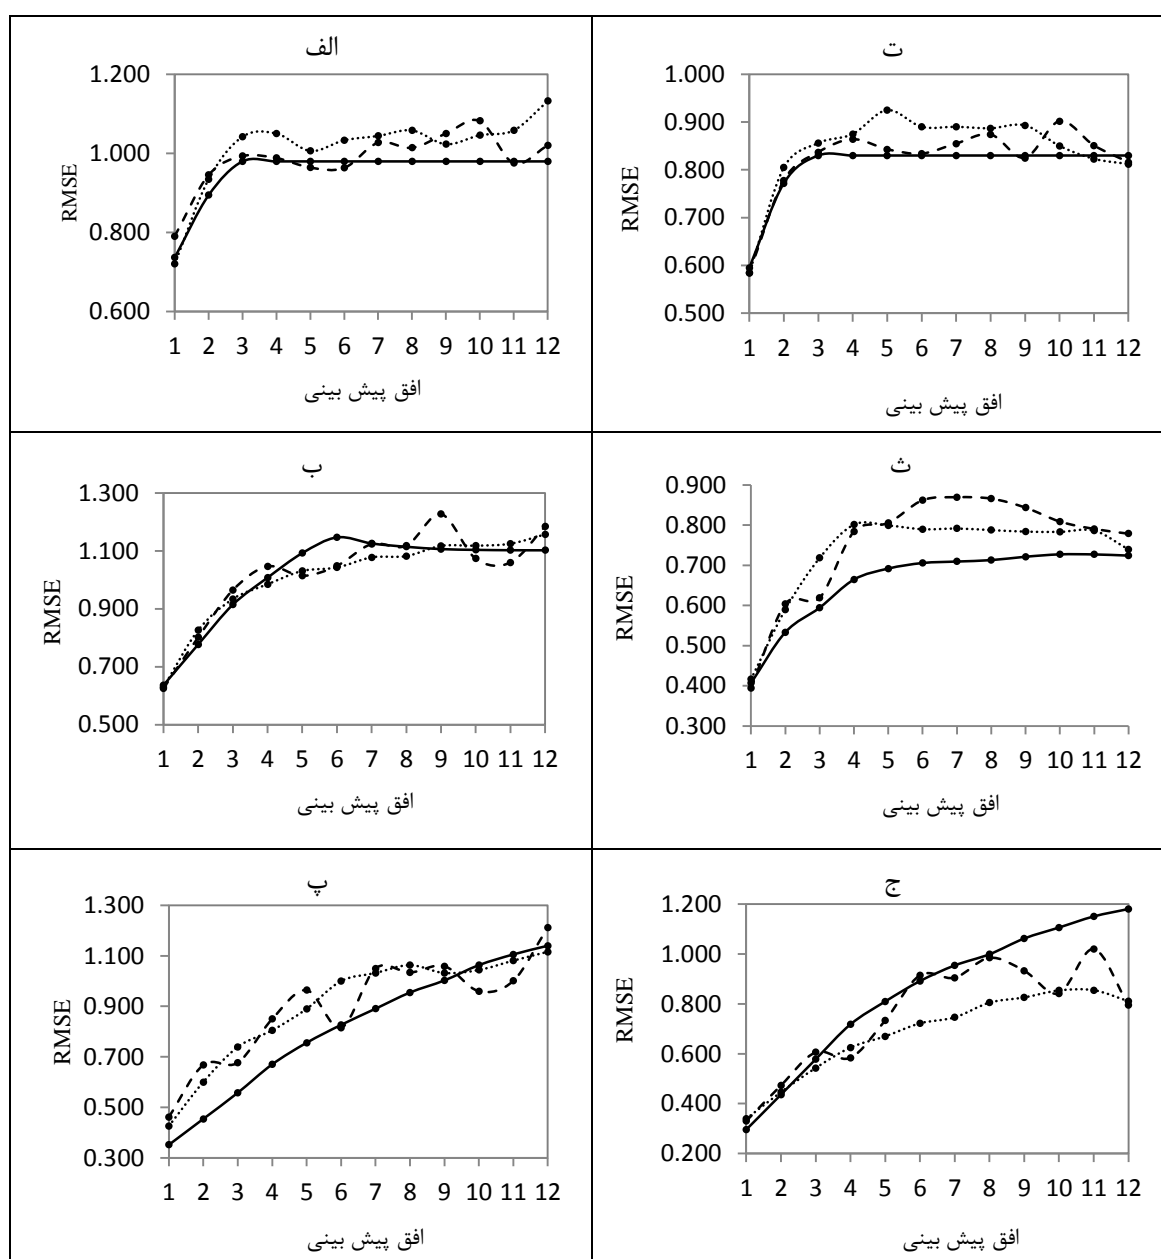
جدول ۵. مدل‌های منتخب شبکه‌های عصبی مصنوعی

DMSNN			RMSNN			ایستگاه
SPI12	SPI6	SPI3	SPI12	SPI6	SPI3	
(۹-۴-۱۲)	(۷-۸-۱۲)	(۸-۹-۱۲)	(۱۲-۳-۱)	(۷-۷-۱)	(۱۲-۲-۱)*	بندرانزلی
(۱۲-۷-۱۲)	(۶-۴-۱۲)	(۱۱-۷-۱۲)	(۱۲-۱-۱)	(۷-۲-۱)	(۶-۱-۱)	بوشهر
(۱۲-۵-۱۲)	(۹-۴-۱۲)	(۵-۶-۱۲)	(۹-۶-۱)	(۱۲-۳-۱)	(۴-۲-۱)	همدان نوژه
(۱۱-۲-۱۲)	(۸-۸-۱۲)	(۱۱-۶-۱۲)	(۸-۵-۱)	(۷-۸-۱)	(۹-۱۲-۱)	زاهدان

* تعداد نرون‌های لایه خروجی - تعداد نرون‌های لایه مخفی - تعداد نرون‌های ورودی

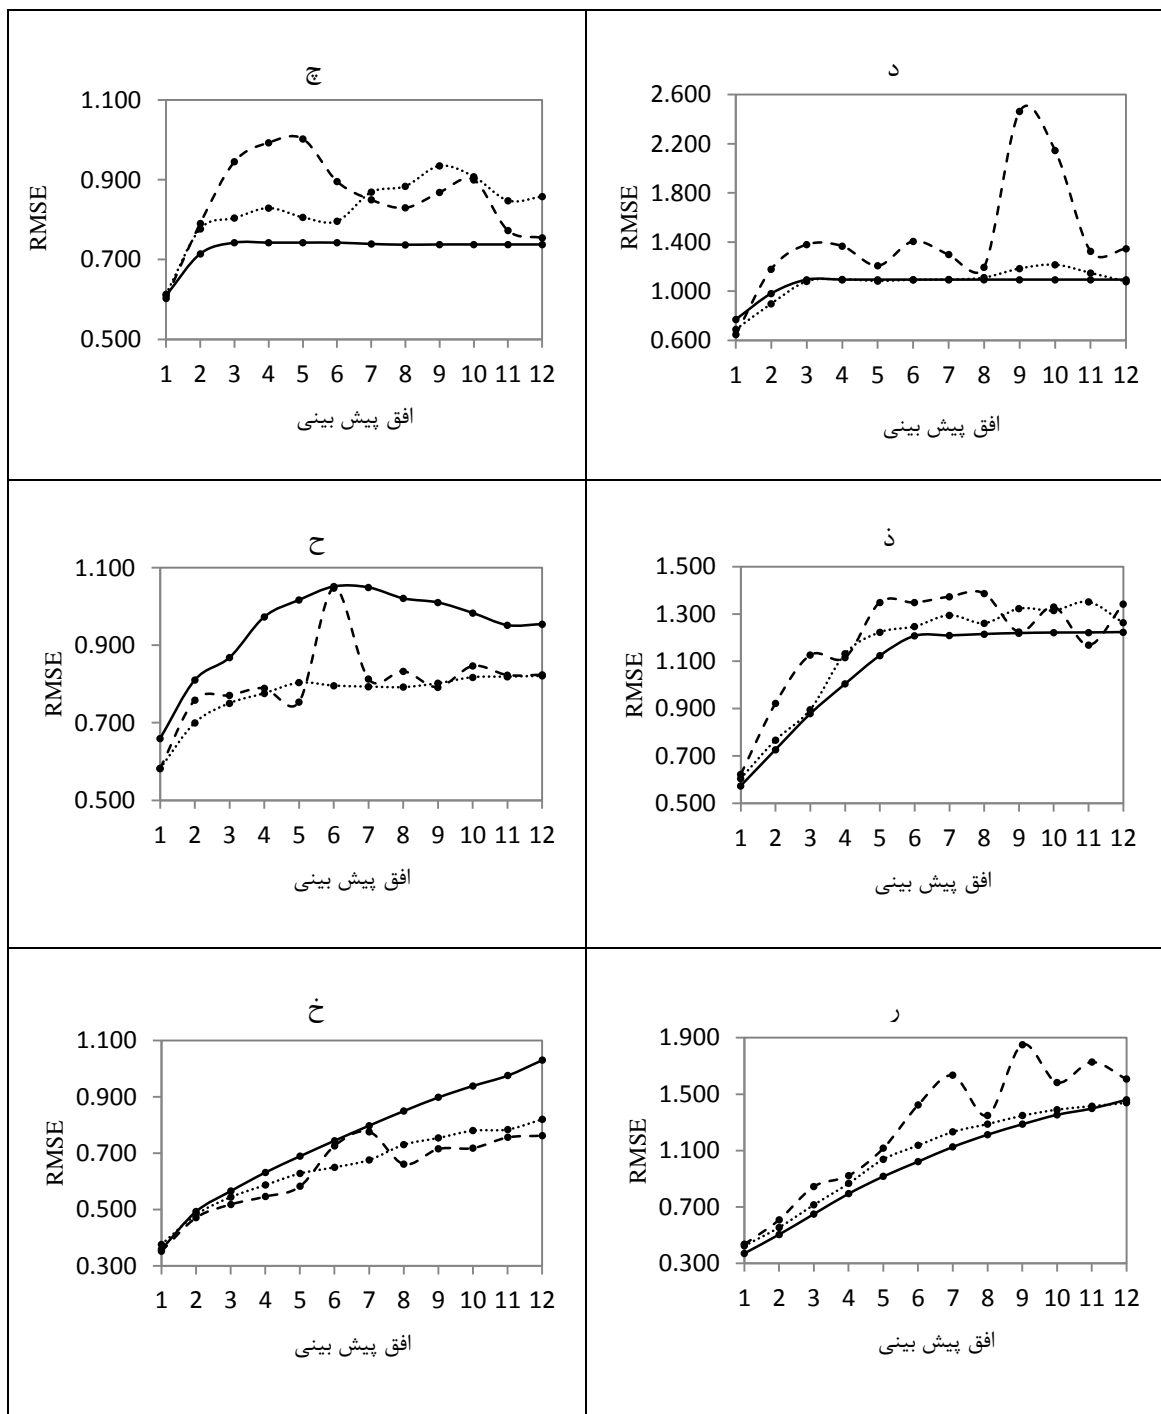
صحت سنجی مدل‌های منتخب و مقایسه مدل‌ها

شکل ۳ نمودار تغییرات RMSE را به‌ازای افزایش افق پیش‌بینی برای هر یک از مدل‌ها در ایستگاه‌های مورد مطالعه نشان می‌دهد. همچنین حداکثر گام معناداری ضریب همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده SPI برای هر یک از مدل‌های منتخب در جدول ۶ ارائه شده است.



—●— Stochastic - - - - RMSNN DMSNN

شکل ۳. نمودار تغییرات RMSE به‌ازای افزایش افق پیش‌بینی در ایستگاه بندر انزلی (الف - SPI3، ب - SPI6، پ - SPI12) و ایستگاه همدان نوژه (ت - SPI3، ث - SPI6، ج - SPI12)



— Stochastic - - - RMSNN DMSNN

ادامه شکل ۳. نمودار تغییرات RMSE به ازای افزایش افق پیش بینی در ایستگاه بوشهر (چ - SPI3، ح - SPI6، خ - SPI12) و ایستگاه زاهدان (د - SPI3، ذ - SPI6، ر - SPI12)

جدول ۶. حداکثر گام معناداری ضریب همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده برای هر یک از مدل‌های منتخب

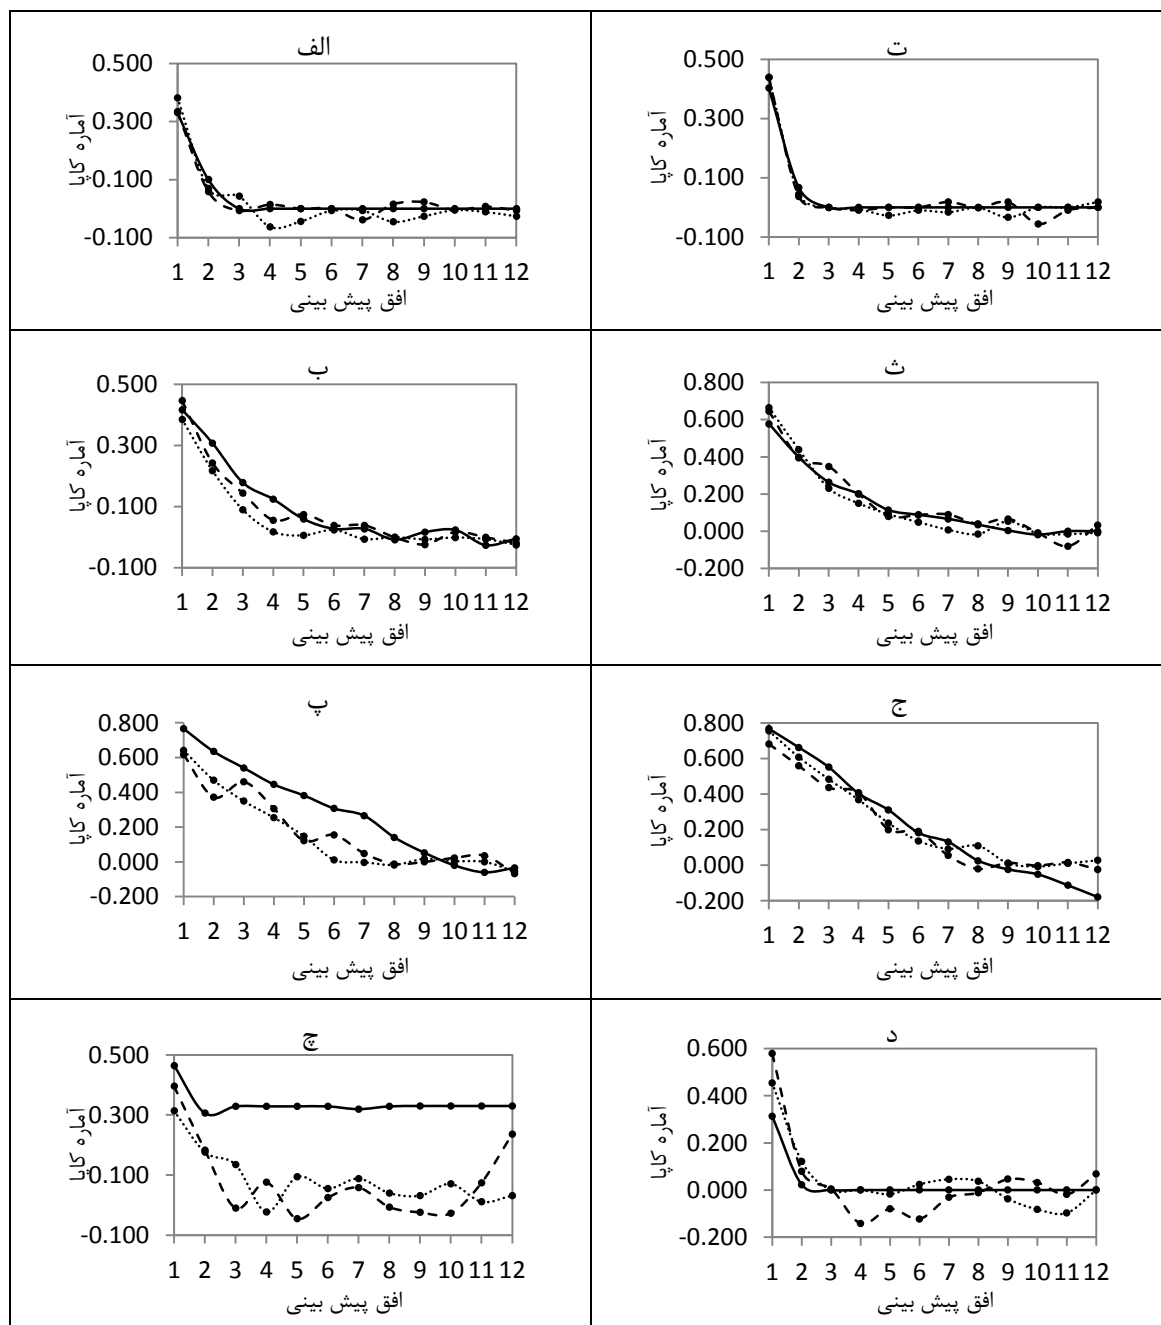
مدل استوکاستیک			DMSNN			RMSNN			ایستگاه
SPI12	SPI6	SPI3	SPI12	SPI6	SPI3	SPI12	SPI6	SPI3	
۹	۷	۲	۵	۴	۲	۶	۵	۲	بندر انزلی
۷	۳	۱۲	۱۱	۳	۳	۶	۲	۲	بوشهر
۷	۱۰	۲	۷	۴	۲	۸	۴	۲	همدان نوژه
۸	۵	۲	۷	۵	۳	۶	۴	۲	زاهدان

مطابق شکل ۳، نمودار تغییرات RMSE مدل استوکاستیک نسبت به دو مدل دیگر از روند منظم‌تری برخوردار است، اما به‌طور کلی در هر سه مدل با افزایش افق پیش‌بینی، میزان خطای روندی فزاینده داشته و با افزایش مقیاس زمانی SPI دقت پیش‌بینی افزایش می‌یابد.

مقایسه نمودار تغییرات RMSE سه مدل منتخب در ایستگاه بندر انزلی بیان می‌کند که در مقیاس سه‌ماهه، مدل استوکاستیک تا پیش‌بینی‌های دو گام به جلو از دقت بیشتری برخوردار است (شکل ۳-الف). در مقیاس شش ماهه، مدل استوکاستیک تا پیش‌بینی‌های سه گام به جلو مناسب بوده و برای پیش‌بینی‌های چهار و پنج گام به جلو، به ترتیب مدل DMSNN و RMSNN از دقت بیشتری برخوردار هستند (شکل ۳-ب). همچنین در مقیاس دوازده‌ماهه، استفاده از مدل استوکاستیک برای پیش‌بینی‌های یک تا نه گام به جلو نسبت به دو مدل دیگر در اولویت قرار دارد (شکل ۳-پ). مقایسه نمودار تغییرات RMSE سه مدل منتخب در ایستگاه همدان نوژه بیانگر این است که در مقیاس سه‌ماهه، مدل استوکاستیک برای پیش‌بینی‌های یک تا دو گام به جلو و در مقیاس شش ماهه، مدل استوکاستیک برای پیش‌بینی‌های یک تا ده گام به جلو مناسب است (شکل ۳-ت و ث). همچنین در مقیاس دوازده‌ماهه مدل استوکاستیک برای پیش‌بینی‌های یک تا دو گام به جلو و مدل DMSNN برای پیش‌بینی‌های سه تا هشت گام به جلو، از دقت بیشتری برخوردار هستند (شکل ۳-ج).

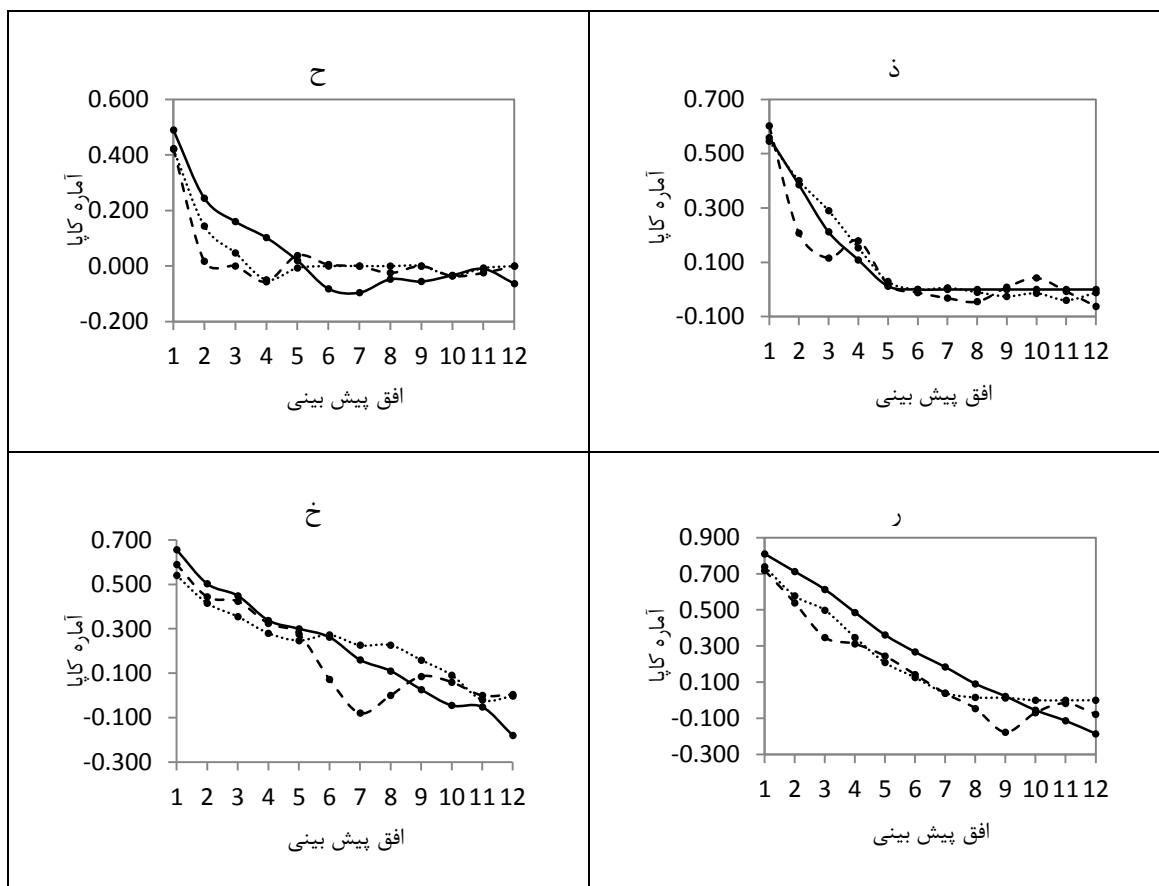
با توجه به شکل (۳-چ) در ایستگاه بوشهر، مدل استوکاستیک مناسب‌ترین مدل برای پیش‌بینی‌های یک تا دوازده گام به جلو برای سری زمانی SPI3 است. براساس شکل (۳-ح) مدل DMSNN مناسب‌ترین مدل پیش‌بینی برای افق زمانی یک تا سه گام به جلو برای سری زمانی SPI6 در ایستگاه بوشهر است. براساس شکل (۳-خ) مدل RMSNN برای پیش‌بینی یک تا پنج گام به جلو و مدل DMSNN برای پیش‌بینی شش تا یازده گام به جلو از دقت بیشتری برای پیش‌بینی مقادیر SPI12 در ایستگاه بوشهر برخوردار هستند. شکل (۳-د) بیان می‌کند که مدل DMSNN مناسب‌ترین مدل برای پیش‌بینی‌های یک تا سه گام به جلو مقادیر SPI3 در ایستگاه زاهدان است. براساس شکل (۳-ذ) و (۳-ر)، مدل استوکاستیک برای پیش‌بینی‌های یک تا پنج گام به جلو مقادیر SPI6 و برای پیش‌بینی‌های یک تا هشت گام به جلو مقادیر SPI12 از دقت بیشتری نسبت به سایر مدل‌ها برخوردار است. مقایسه نتایج مدل‌های استوکاستیک و RMSNN و DMSNN نشان می‌دهد که در حالت کلی در هر سه مقیاس زمانی، استفاده از مدل‌های استوکاستیک نسبت به مدل‌های DMSNN و RMSNN برای پیش‌بینی مقادیر SPI در اولویت قرار دارد.

نمودار تغییرات آماره کاپا به‌ازای افزایش افق پیش‌بینی برای هر یک از مدل‌ها در ایستگاه‌های مورد مطالعه در شکل ۴ نشان داده شده است. همچنین حداکثر گام معناداری آماره کاپا برای هر یک از مدل‌های منتخب در جدول ۷ ارائه شده است. حداکثر گام معناداری آماره کاپا، بیانگر این است که به‌ازای گام‌های بیشتر از مقدار مذکور، مدل‌ها قابلیت مدل‌سازی طبقات خشکسالی را ندارند.



— Stochastic - - - RMSNN DMSNN

شکل ۴. نمودار تغییرات آماره کاپا به‌ازای افزایش افق پیش‌بینی در ایستگاه بندر انزلی (الف - SPI3، ب - SPI6، پ - SPI12) و ایستگاه همدان (ت - SPI3، ث - SPI6، ج - SPI12) و



— Stochastic - - - RMSNN DMSNN

ادامه شکل ۴. نمودار تغییرات آماره کاپا به ازای افزایش افق پیش بینی در ایستگاه بوشهر (چ- SPI3، ح- SPI6، خ- SPI12) و ایستگاه زاهدان (د- SPI3، ذ- SPI6، ر- SPI12)

جدول ۷. حداکثر گام معناداری آماره کاپا برای هر یک از مدل‌های منتخب

مدل استوکاستیک			DMSNN			RMSNN			ایستگاه
SPI12	SPI6	SPI3	SPI12	SPI6	SPI3	SPI12	SPI6	SPI3	
۷	۳	۱	۵	۲	۱	۴	۲	۱	بندر انزلی
۶	۲	۱۲	۸	۱	۲	۵	۱	۲	بوشهر
۶	۴	۱	۵	۳	۱	۶	۴	۱	همدان نوژه
۷	۳	۱	۶	۴	۱	۶	۲	۱	زاهدان

بر اساس شکل ۴، نمودار تغییرات آماره کاپای مدل استوکاستیک نسبت به دو مدل دیگر از روند منظم‌تری برخوردار است، اما به طور کلی در هر سه مدل، با افزایش افق پیش بینی میزان آماره کاپا روندی کاهنده داشته و با افزایش مقیاس زمانی SPI، توافقات طبقات مشاهده شده و پیش بینی شده افزایش می‌یابد. مقایسه نمودار تغییرات آماره کاپای سه مدل

منتخب در ایستگاه بندر انزلی بیانگر این است که مدل DMSNN تا پیش‌بینی‌های یک گام به جلو از دقت بیشتری برای پیش‌بینی طبقات SPI3 برخوردار است (شکل ۴-الف). در مقیاس شش ماهه، مدل RMSNN برای پیش‌بینی‌های یک گام به جلو طبقات SPI مناسب بوده و برای پیش‌بینی‌های دو و سه گام به جلو مدل استوکاستیک از دقت بیشتری برخوردار است (شکل ۴-ب). همچنین در مقیاس دوازده‌ماهه، استفاده از مدل استوکاستیک برای پیش‌بینی‌های یک تا هفت گام به جلو نسبت به دو مدل دیگر در اولویت قرار دارد (شکل ۴-پ). مقایسه نمودار تغییرات آماره کاپای سه مدل منتخب در ایستگاه همدان نوژه، بیان می‌کند که در مقیاس سه ماهه، مدل DMSNN و RMSNN با دقت یکسانی برای پیش‌بینی‌های یک گام به جلو مناسب هستند (شکل ۴-ت) و در مقیاس شش‌ماهه، مدل DMSNN برای پیش‌بینی‌های یک تا دو گام به جلو و مدل RMSNN برای پیش‌بینی‌های سه تا چهار گام به جلو مناسب هستند (شکل ۴-ث). همچنین در مقیاس دوازده‌ماهه، مدل استوکاستیک برای پیش‌بینی‌های یک تا شش گام به جلو از دقت بیشتری برخوردار است (شکل ۴-ج). با توجه به شکل (۴-چ)، در ایستگاه بوشهر، مدل استوکاستیک مناسب‌ترین مدل برای پیش‌بینی‌های یک تا دوازده گام به جلو طبقات SPI3 است. بر اساس شکل (۴-ح)، مدل استوکاستیک مناسب‌ترین مدل پیش‌بینی برای افق زمانی یک تا دو گام به جلو طبقات SPI6 در ایستگاه بوشهر است. شکل (۴-خ) نشان می‌دهد که مدل استوکاستیک برای پیش‌بینی یک تا شش گام به جلو و مدل DMSNN برای پیش‌بینی هفت تا هشت گام به جلو از دقت بیشتری برای پیش‌بینی طبقات SPI12 در ایستگاه بوشهر برخوردار هستند. شکل (۴-د) بیانگر این است که مدل RMSNN مناسب‌ترین مدل برای پیش‌بینی‌های یک به جلو طبقات SPI3 در ایستگاه زاهدان است. بر اساس شکل (۴-ذ)، مدل RMSNN برای پیش‌بینی‌های یک گام به جلو و مدل DMSNN برای پیش‌بینی دو تا چهار گام به جلو طبقات SPI6 از دقت بیشتری برخوردار هستند. مطابق شکل (۴-ر)، مدل استوکاستیک برای پیش‌بینی‌های یک تا هفت گام به جلو طبقات SPI12 از دقت بیشتری نسبت به سایر مدل‌ها برخوردار است.

مقایسه نتایج مدل‌های استوکاستیک و RMSNN و DMSNN نشان می‌دهد که در حالت کلی، در مقیاس زمانی سه، شش و دوازده‌ماهه، به ترتیب استفاده از مدل‌های DMSNN، RMSNN و استوکاستیک برای پیش‌بینی طبقات SPI در اولویت قرار دارند.

بحث و نتیجه‌گیری

در این مطالعه با هدف مقایسه کارایی مدل‌های استوکاستیک و ANN در مدل‌سازی و پیش‌بینی خشکسالی، به توسعه مدل‌های مذکور روی سری‌های زمانی شاخص SPI در تعدادی از ایستگاه‌های سینوپتیک در گستره ایران پرداخته شد. در هر سه مدل و به‌طور کلی در هر سه مقیاس زمانی با افزایش گام پیش‌بینی، میزان ضریب همبستگی روندی کاهنده و میزان خطا روندی فزاینده دارد. همچنین با افزایش مقیاس زمانی SPI، دقت پیش‌بینی افزایش می‌یابد. مطالعات پیش‌رو دزای (۲۰۰۵) و فتح‌آبادی و همکاران (۲۰۰۹) نیز، افزایش دقت مدل استوکاستیک در مقیاس‌های زمانی بالاتر SPI و کاهش ضریب همبستگی در گام‌های پیش‌بینی بیشتر را تأیید می‌کند. در هر سه مدل، مقایسه مقادیر کاپا در هر یک از

مقیاس‌های SPI بیانگر این است که میزان توافق طبقات مشاهده‌شده و پیش‌بینی‌شده با افزایش مقیاس زمانی افزایش می‌یابد. علاوه بر این، در مورد هر سه مقیاس زمانی SPI، با افزایش گام پیش‌بینی میزان توافق طبقات مشاهده‌شده و پیش‌بینی‌شده کاهش می‌یابد. مقایسه نتایج مدل‌های استوکاستیک و RMSNN و DMSNN نشان می‌دهد که در حالت کلی، در مقیاس زمانی سه، شش و دوازده‌ماهه، به‌طور کلی مدل‌های استوکاستیک (به‌ترتیب با میانگین خطای ۰/۶۷۸، ۰/۵۶۹ و ۰/۳۴۴ و میانگین ضریب همبستگی ۰/۶۸۲، ۰/۷۷۷ و ۰/۹۱۹) از نظر مهارت پیش‌بینی مقادیر SPI در اولویت کاربرد قرار دارند. نتایج مطالعه فتح‌آبادی و همکاران (۲۰۰۹) نیز برتری مدل‌های استوکاستیک به مدل‌های ANN را تأیید می‌کند. درحالی‌که مطالعه میشر و دزای (۲۰۰۶) خلاف این را نشان می‌دهد. بنابراین می‌توان نتیجه گرفت که رفتار متفاوت سری‌های زمانی، سبب می‌شود که نتوان به‌طور کلی در مورد برتری هر یک از این مدل‌ها با قطعیت کامل نظر داد. مقایسه کارایی مدل‌های مورد بررسی در پیش‌بینی طبقات SPI نشان می‌دهد که در حالت کلی، در مقیاس زمانی سه، شش و دوازده‌ماهه، به‌ترتیب استفاده از مدل‌های DMSNN، RMSNN و استوکاستیک (با میانگین کاپای ۰/۳۹۷، ۰/۵۳۰ و ۰/۷۵۰) برای پیش‌بینی طبقات SPI در اولویت قرار دارند. با توجه به اهمیت بالای پیش‌آگاهی شدت خشکسالی‌ها برای مدیریت بهینه منابع آب، مدل‌های پیشنهاد شده در این پژوهش، می‌توانند به‌عنوان گزینه‌های قابل اعتمادتر و دقیق‌تر در پیش‌بینی‌های خشکسالی به‌کار روند. علاوه بر این، با توجه به عدم قطعیت‌های فراوان در پیش‌بینی خشکسالی و وابستگی آن به معیارهای گوناگون هواشناسی و اقلیمی، استفاده از سایر پارامترها، مانند سیگنال‌های بزرگ مقیاس اقلیمی برای پیش‌بینی خشکسالی توصیه می‌شود.

منابع

- خلیلی، ع. (۱۳۷۶). طرح جامع آب کشور، مطالعات هواشناسی، جلد چهارم، وزارت نیرو، تهران.
- Akaike, H., 1974, **A Look at the Statistical Model Identification**, IEEE Transactions Automatic Control AC, Vol. 19, No. 6, PP. 716-723.
- Blain, G.C., 2011, **Standardized Precipitation Index based on Pearson Type III Distribution**, Journal of Revista Brasileira de Meteorologia, Vol. 26, No. 2, PP. 167-180.
- Box, G.E.P. and Jenkins, G.M., 1976, **Time Series Analysis Forecasting and Control**, Holden-Day, San Francisco.
- Chung, C.H. and Salas, J.D., 2000, **Drought Occurrence Probabilities and Risks of Dependent Hydrological Processes**, Journal of Hydrologic Engineering, Vol. 5, No. 3, PP. 259-268.
- Cohen, J.A., 1960, **Coefficient of Agreement for Nominal Scales**, Educational and Psychological Measurement, Vol. 20, PP. 37-46.
- Cohen, J.A., 1968, **Weighted Kappa: Nominal Scale Agreement with Provision for Scaled Disagreement or Partial Credit**, Psychological Bulletin, Vol. 70, PP. 213-220.
- Edwards, D.C. and McKee, T.B., 1997, **Characteristics of 20th Century Drought in the United States at Multiple Time Scales**, Colorado State University, Fort Collins.

- Fatehi Marj, A. and Meijerink, A.M.J., 2011, **Agricultural Drought Forecasting Using Satellite Images, Climate Indices and Artificial Neural Network**, International Journal of Remote Sensing, Vol. 32, No. 24, PP. 9707-9719.
- Fathabadi, A., H., Gholami, A., Salajeghe, H., Azanivand and H., Khosravi, 2009, **Drought Forecasting Using Neural Network and Stochastic Models**, American Eurasian Network for Scientific Information, Vol. 3, No. 2, PP. 137-146.
- Fernández, C., Vega, J.A., Fonturbel, T. and Jiménez, E., 2009, **Stream Flow Drought Time Series Forecasting: A Case Study in a Small Watershed in North West Spain**, Stochastic Environmental Research & Risk Assessment, Vol. 23, No. 8, PP. 1063-1070.
- Guttman, N.B., 1999, **Accepting the Standardized Precipitation Index: a Calculation Algorithm**, Journal of the American Water Resources Association, Vol. 35, No. 2, PP. 311-322.
- Hayes, M.J., Svoboda, M.D., Wilhite, D.A. and Vanyarkho, O.V., 1999, **Monitoring the 1996 Drought Using the Standardized Precipitation Index**, Bulletin of American Meteorological Society, Vol. 80, PP. 429-438.
- Hurst, H., 1951, **Long Term Storage Capacity of Reservoirs**, Transactions of the American Society of Civil Engineers, Vol. 116, PP. 770-799.
- Khalili, A., 1997, **Integrated Water Plan of Iran**, Meteorological Studies, Ministry of Energy, Vol. 4.
- Landis, J.R. and Koch, G.G., 1977, **The Measurement of Observer Agreement for Categorical Data**, Journal of Biometrics, Vol. 33, PP. 159-174.
- Makridakis, S., Wheelwright, S.C. and Hyndman, R., 2003, **Forecasting Methods and Applications**, Wiley (ASIA) Pvt Ltd., Singapore.
- McKee, T. B., Doesken N.J. and Kleist, J., 1993. **The Relationship of Drought Frequency and Duration to Time Scale. Preprints**, Eighth Conf. on Applied Climatology, Anaheim, CA, American Meteorological Society, PP. 179-184.
- McKee, T. B., Doesken, N. J. and Kleist, J., 1995, **Drought Monitoring with Multiple Time Scales**, Proceedings of the Ninth Conference on Applied Climatology, American Meteorological Society, Boston.
- Mishra, A. K. and V. R., Desai, 2006. **Drought Forecasting Using Feed-forward Recursive Neural Network**, Journal of Ecological Modeling, Vol. 198, PP. 127-138.
- Mishra, A.K. and Desai, V.R., 2005, **Drought forecasting using stochastic models**, Stochastic Environmental Research and Risk Assessment, Vol. 19, PP. 326-339.
- Modarres, R., 2007, **Streamflow Drought Time Series Forecasting**, Stochastic Environmental Research and Risk Assessment, Vol. 21, PP. 223-233.
- Morid, S., Smakhtin, V., Bagherzadeh, K., 2007, **Drought Forecasting Using Artificial Neural Networks and Time Series of Drought Indices**, International Journal of Climatology, Vol. 27, PP. 2103-2111.
- Rao, A.R. and Padmanabhan, G., 1984, **Analysis and Modeling of Palmers Drought Index Series**, Journal of Hydrology, Vol. 68, PP. 211-229.
- Schwartz, G., 1978, **Estimating the Dimension of a Model**, Annals of statistics, Vol. 6, PP. 461-464.

*Comparison of Stochastic and Artificial Neural Networks Models in
Modeling and Forecasting the Standardized Precipitation Index
Values and Classes*

Hejabi S. *

M.Sc. Student in Agrometeorology, College of Agriculture and Natural Resources, University of Tehran

Bazrafshan J.

Assistant Prof., Dep. of Irrigation and Reclamation Engineering, College of Agriculture and Natural resources, University of Tehran

Gahreman N.

Assistant Prof., Dep. of Irrigation and Reclamation Engineering, College of Agriculture and Natural resources, University of Tehran

Received: 21/04/2012 Accepted: 01/07/2013

Extended Abstract

Introduction

Drought is a temporary and recurring meteorological event which results from the lack of precipitation over an unusual extended period of time. Early indication of possible droughts can help set out drought mitigation strategies and measures, in advance. Therefore, the drought forecasting plays an important role in the planning and management of water resource systems.

Stochastic models have been extensively used for forecasting hydrologic variables such as annual and monthly stream flow, precipitation, and etc. in the past. But they are basically linear models assuming that data are stationary, and have a limited ability to capture non-stationarities and nonlinearities in the hydrologic data. However, it is necessary to consider alternative models when nonlinearity and non-stationarity play a significant role in the forecasting. In the recent decades, artificial neural networks have shown great ability in modeling and forecasting nonlinear and non-stationary time series due to their innate nonlinear property and flexibility for modeling.

The aim of this study is to compare the stochastic and artificial neural network models in

forecasting the standardized precipitation index (SPI) in some stations of Iran. This is because of the multiplicity of drought occurrences in Iran and the necessity to determine the best forecasting model.

Methodology

The monthly total precipitation data (1973-2007) related to four synoptic stations of Iran including Bandar Anzali (with very wet climate), Hamedan Nojeh (with semi arid climate), and Bushehr (with arid climate) and Zahedan (with hyper arid climate) have been used after the homogeneity and adequacy of data have been confirmed by statistical tests.

In the present study standardized precipitation index (SPI) time series (at 3-, 6- and 12-month timescales) have been calculated for the period of 1973-2007. The most suitable distribution function for precipitation at 3-, 6- and 12- month timescales has been determined by Easyfit software on the basis of kolmogorov-Smirnov statistic. This is performed separately for each month. Then, each cumulative probability density function is transformed into a cumulative standardized normal distribution. The SPI values for the period of 1973-2000 are used to calibrate the models and the rest of the data to be tested.

Development of stochastic model consists of three stages of identification, estimation, and diagnostic checking (Box and Jenkins, 1976, 19). During the identification stage the candidate forms of the models are determined using the autoregressive function (ACF) and partial autoregressive function (PACF) and general forms of the models are determined on the basis of **Schwarz** Bayesian information criterion (Schwartz, 1978, 461-464) and Akaike information criterion (Akaike, 1974, 716-723). In the estimation stage the model parameters were calculated using Minitab14 software. Finally, diagnostic checks of the model are performed using kolmogorov-Smirnov (K-S) and Portmanteau test (Makridakis et al., 2003, 185) to reveal possible model inadequacies and to assist in selecting the best model.

In the present paper two different approaches of neural networks including recursive multi-step neural network approach (RMSNN) and direct multi-step neural network approach (DMSNN) are used for forecasting several time steps ahead. The RMSNN approach based on one output node forecasts a single step ahead, and the network is applied recursively, using the previous predictions as inputs for the subsequent forecasts. DMSNN is based on the multiple outputs, when several nodes are included in the output layer, and each output node represents one time step to be forecasted.

The models are evaluated with statistical tests, correlation coefficient, and error index for 1- to 12-lead time ahead forecasting over the period of 2001- 2007. Also, the capability of the models in forecasting the SPI classes is investigated using Cohen's Kappa statistic (Cohen, 1960, 37-46).

Results and Discussion

The results of stochastic modeling of SPI time series showed that the null hypothesis related to the normality of residuals is accepted for 3- and 6- month time scales but rejected for 12-month

time scales at 1% significant level in all stations. The results of Portmanteau test signify that the chosen stochastic models are adequate on the available data at 1% significant level.

The results of artificial neural networks (RMSNN and DMSNN) modeling of each SPI time series are presented as optimal architectures of the best number of input and hidden neurons. The significance lead times of drought forecasting are determined based on correlation coefficient and Kappa statistic between the observed and forecasted values of the SPI time series in the stations of interest. Accordingly, the most appropriate models for SPI values and classes have been determined by a comparison of three models for each time series.

Conclusion

The results have revealed that generally, for 3-, 6- and 12-month time scales, stochastic models (with average error of 0.678, 0.569 and 0.344 and average correlation coefficient of 0.682, 0.777 and 0.919, respectively) are more accurate than artificial neural network models to forecast SPI values. The comparison of models in forecasting SPI classes also showed that the most accurate model for forecasting SPI classes for 3-, 6- and 12-month time scales is DMSNN, RMSNN and stochastic model (with average Kappa of 0.397, 0.530 and 0.750) in sequence.

Keywords: Artificial Neural Network Models, Drought, Forecasting, Standardized Precipitation Index, Stochastic Models, Wet and Dry Climates.