

## مدل سازی پیش یابی بارش ماهانه در حوضه آبریز بلوچستان جنوبی

پذیرش نهایی: ۱۳۹۶/۲/۱۵

دریافت مقاله: ۱۳۹۵/۱۱/۲۲

### چکیده

افزایش رخداد بارش های حدی و از سوی دیگر عدم بارش در یک گستره، خسارات قابل توجهی در دهه های اخیر به بوم سامانه های طبیعی و مصنوعی وارد ساخته است. از این رو پیش یابی مقادیر بارش برای مدیریت مناسب منابع آبی در این گستره ها بسیار اهمیت دارد. هدف این پژوهش پیشنهاد مدل و بررسی دقت پیش یابی بارش ماهانه با روش های شبکه عصبی مصنوعی و مدل های تصادفی در پهنه جنوب شرق کشور واقع در استان سیستان و بلوچستان می باشد. این منطقه به لحاظ تاثیر پذیری از سامانه های گوناگون باران زا و کمی متفاوت از سایر مناطق کشور، دارای رژیم بارش رگباری نامنظم و تقریباً پیچیده ای است. پیش یابی بارش معرف منطقه با استناد بر روش های سری زمانی ساریما و شبکه عصبی با تاخیر زمانی انجام گرفت. داده های مورد بررسی شامل سری بارش ماهانه دوره آماری ۱۳۵۲-۱۳۵۱ تا ۸۸-۱۳۸۷ برای ایستگاه های منتخب منطقه می باشد، که بر پایه پراکنش مناسب ایستگاه ها و کیفیت داده ها برگزیده شدند. مقایسه نتایج پیش یابی دو روش مورد بررسی نشان از برتری روش شبکه عصبی تاخیر زمانی نسبت به سری زمانی ساریما برای گستره مطالعاتی دارد. این امر به تاثیر سامانه های مختلف باران زا، رژیم بارش های رگباری و بسیار پراکنده پهنه جنوب شرق کشور مربوط می شود.

واژه های کلیدی: بارش، شبکه عصبی، سری زمانی، پیش یابی، حوضه بلوچستان جنوبی.

### مقدمه

بشر برای درک و کنترل بهتر محیط پیرامون خود از مدل ها استفاده می کند. نگرش های قطعی (دترمینیستیک) و تصادفی (استوکاستیک) دو دیدگاه اصلی برای شناخت طبیعت هستند. قاعده کلی مدل های قطعی بر پایه روابط علی- معلولی بنا شده است که به طور معمول به وسیله معادلات ریاضی بیان می شوند. در حالی که نقطه نظر اصلی در نگرش تصادفی آن است که روابط موجود بین پدیده ها را نمی توان به راحتی به صورت روابط علی- معلولی ساده و یا حتی پیچیده بیان کرد. در عوض در این مدل ها سعی بر شناخت خصوصیات متغیرهای طبیعی با توجه به مقادیر مشاهده شده آنها و با استفاده از فرآیندهای تصادفی و آماره های ریاضی دارد (Yevjevich, 1987:17). روش های مختلفی برای مدل سازی داده ها و استفاده از مدل برای پیش بینی وجود دارد. از جمله مهم ترین این روش ها می توان به مدل های سری زمانی، زنجیره مارکف و شبکه عصبی مصنوعی و غیره اشاره کرد. در این پژوهش از مدل های سری زمانی و شبکه عصبی استفاده شد.

در استفاده از سری های زمانی در مدل سازی پارامترهای هیدرولوژیکی هم چون بارندگی، دما و جریان های رودخانه پژوهش های متعددی صورت گرفته است. الگوسازی در خانواده آرما، آریمای فصلی یکی از شیوه های مهم و معتبر در شبیه سازی

پارامترهای اقلیمی است (Box et al, 2013). بورلاندو<sup>۱</sup> و همکاران (۱۹۹۶) از مدل‌های آریما جهت پیش‌بینی بارندگی‌های ساعتی در زمان وقوع آن‌ها استفاده کردند و مقادیر به دست آمده را با داده‌های باران‌سنجی مقایسه نمودند. آنها در پژوهش خود به این نتیجه رسیدند که با افزایش مدت دوام بارندگی، پیش‌بینی‌ها روند دقیق‌تری داشتند و با کوتاه‌تر شدن دوام بارندگی، اختلاف میزان باران پیش‌بینی از مقدار واقعی متناظر خود بیشتر می‌شود. همچنین در این زمینه می‌توان به کارهای جونز<sup>۲</sup> (۱۹۸۶)، هانسن و لبدف<sup>۳</sup> (۱۹۸۸)، بلوفلید و نیچکا<sup>۴</sup> (۱۹۹۲) و فولاند<sup>۵</sup> (۱۹۹۰) اشاره نمود. نوآکز<sup>۶</sup> و همکاران (۱۹۸۵) قدرت پیش‌بینی کوتاه مدت مدل‌های آریما، ساریما و مدل‌های خودهمبسته دوره‌ای را بر روی سری ۳۰ ماهه جریان مقایسه کردند و نشان دادند که مدل‌های خودهمبسته دوره‌ای دقیق‌ترین پیش‌بینی را دارند. آنها همچنین برتری تبدیل لگاریتمی را به دیگر تبدیل‌های باکس-کاکس بر اساس روش حداکثر درست‌نمایی را به دست آوردند. پاراس و ماتور<sup>۷</sup> (۲۰۱۲) دو روش سری زمانی و رگرسیون چند متغیره غیر خطی را برای پیش‌بینی بارش ماهانه هندوستان مناسب معرفی کردند. رویرو و پوچتا<sup>۸</sup> (۲۰۱۴) در مقایسه دو روش سری زمانی و شبکه عصبی مصنوعی، روش نخست را برای منطقه آرژانتین بسیار مناسب دانستند. الهاشمی<sup>۹</sup> (۲۰۱۴) در پیش‌بینی بارش ماهانه یمن سه روش شبکه عصبی، سری زمانی و رگرسیون چند متغیره را مقایسه کردند و به ترتیب روش‌های شبکه عصبی مصنوعی، مدل آریما و در نهایت رگرسیون چند متغیره را مناسب دانستند. از پژوهش‌های داخلی نیز می‌توان به کار جمشیدی<sup>۱۰</sup> (۱۹۸۹) در مدل دما-بارش ایستگاه تهران، مالکی<sup>۱۱</sup> (۱۹۸۹) در الگوسازی دما و بارش غرب کشور و رسولی<sup>۱۲</sup> (۲۰۰۲) برای پیش‌بینی دمای ماهانه شهر تبریز اشاره نمود. خردمندیا و عساکره<sup>۱۳</sup> (۲۰۰۱) برای پیش‌بینی درجه حرارت متوسط ماهانه منطقه جاسک از مدل‌سازی ساریما استفاده نمودند. مسعودیان (۱۳۸۲) در بررسی روند ماهانه بارش ایران بیان داشت که بارش ماهانه در بیشتر مناطق کشور به جز کرانه خزر بدون روند است. آشگرطوسی (۱۳۸۲) با استفاده از سری‌های زمانی، خشکسالی منطقه شیروان در استان خراسان را پیش‌بینی نمود و براساس نتایج به دست آمده، بهترین الگوی کشت را پیشنهاد کرد. مسعودیان و همکاران (۱۳۸۹) روند تعداد روزهای همراه با بارش در ماه را بررسی و کاهشی بودن روند را گزارش کردند. فیضی و همکاران (۱۳۸۹)، در بررسی روند تغییرات ماهانه و فصلی دما و بارش در استان سیستان و بلوچستان، کاهش مشخص روند بارش ماه‌های گرم را گزارش کردند. بابازاده و همکاران (۱۳۹۱) به پیش‌بینی بارش ماهانه در ایستگاه شیراز با استفاده از مدل آریما پرداخته و پس از ارزیابی مدل احتمال افزایش بارش در آینده نزدیک را پیش‌بینی کردند. حسینعلی‌زاده و همکاران (۱۳۹۳) نیز در پژوهشی مشابه مدل‌های سری زمانی در پیش‌بینی بارش ایستگاه گرگان را مناسب دانسته و موفق به پیش‌بینی بارش در ۱۲ ماه آینده در این ایستگاه گردیدند. عبدالله نژاد (۱۳۹۴) نیز در تحقیق خود به مقایسه مدل‌های مختلف سری زمانی برای پیش‌بینی مجموع بارش پرداخته و بعد است. از مقایسه نتایج مدل‌های اتورگرسیو، میانگین متحرک، مدل‌های تلفیقی و مدل‌های فصلی، در نهایت مدل ساریما را بهترین مدل برازش شده برای ایستگاه هاشم آباد گرگان معرفی کردند. بایزیدی و همکاران (۱۳۹۵) در تحلیل خشک‌سالی حوضه آبریز سلماس به پیش‌بینی ۷ ساله بارش و دما پرداختند و استفاده از مدل‌های سری زمانی در تحلیل بارش و پیش‌بینی شاخص‌های خشک‌سالی را مناسب دانستند. از سوی دیگر شبکه عصبی مصنوعی به عنوان یک روش نوین، در مدل‌سازی و پیش‌بینی

<sup>1</sup> Burlando et al

<sup>2</sup> Jones

<sup>3</sup> Hansen & Lebedeff

<sup>4</sup> bloomfield & Nychka

<sup>5</sup> Folland

<sup>6</sup> Noakes

<sup>7</sup> Paras & Mathur

<sup>8</sup> Rivero & Pochata

<sup>9</sup> Alhashimi

<sup>10</sup> Jamshidi

<sup>11</sup> Maleki

<sup>12</sup> Rasuli

<sup>13</sup> Kheradmand Nia&Asakereh

## مدل‌سازی پیش‌یابی بارش ماهانه در حوضه آبریز بلوچستان جنوبی / ۱۵۱

سری‌های زمانی غیرخطی و غیرماندگار فرآیندهایی که برای شناخت و توصیف دقیق آنها راه حل و رابطه صریحی وجود ندارد، عملکرد خوبی از خود نشان داده است. اکنون این شبکه‌ها با ساختارهای متنوع و وسیع، در بسیاری از علوم، از جمله مهندسی آب، گسترش یافته‌اند. فرنچ<sup>۱</sup> و همکاران (۱۹۹۲: ۳۱-۱) بارندگی در یک مکان و یک ساعت بعد را با استفاده از روش شبکه عصبی مصنوعی و اطلاعات توزیع مکانی و زمانی بارندگی پیش‌بینی کردند. احمد و سیمونیک<sup>۲</sup> (۲۰۰۰: ۲۵۱-۲۳۶) از شبکه‌های عصبی سه لایه با خاصیت انتشار به عقب خطا و داده‌های بارندگی ماهانه جهت پیش‌بینی بارش ماهانه، در مجارستان و اوکراین، استفاده نمودند. نتایج تحقیق آنها نشان داد، داده‌های آموزشی و آزمایشی جورشدگی و انطباق خوبی با داده‌های واقعی دارند و این روش در پیش‌بینی بارش، دارای حداکثر توانایی است. والورد رامی رز<sup>۳</sup> و همکاران (۲۰۰۵: ۱۶۲-۱۴۶) کاربرد روش شبکه عصبی مصنوعی را در پیش‌بینی بارش، برای سائوپائولو، بررسی کردند. نتایج بررسی آنها نشان داد، پیش‌بینی‌های این روش نسبت به دیگر روش‌ها از دقت بالاتر و صحت بیشتری برخوردار است. هانگ<sup>۴</sup> و همکاران (۲۰۰۹) در پیش‌یابی بارش در تایلند کاربرد شبکه عصبی مصنوعی را بسیار مناسب دانسته و در کنار داده‌های بارش استفاده از داده‌های دمای تر را در پیش‌بینی دقیق‌تر بارش بسیار موثر معرفی کردند. کومار<sup>۵</sup> و همکاران (۲۰۱۳) در مقایسه روش‌های سری زمانی و شبکه عصبی مصنوعی، روش شبکه عصبی مصنوعی را با توجه به سری زمانی پیچیده بارش‌های هند مناسب‌تر دانستند. نایاک<sup>۶</sup> و همکاران (۲۰۱۳) با مروری بر روش‌های پیش‌بینی بارش در هند، شبکه عصبی مصنوعی را در مقایسه بارش‌های پیش‌بینی عددی مناسب‌تر معرفی کردند. میسلان<sup>۷</sup> و همکاران (۲۰۱۵) نیز نتایج مشابهی در پیش‌بینی بارش ماهانه با استفاده از روش شبکه عصبی مصنوعی اعلام داشتند. جهانگیر (۱۳۸۴) کارآمدی شبکه عصبی مصنوعی را در شبیه‌سازی فرآیند بارش - رواناب، در حوضه کارده، بررسی کرد و با استفاده از شبکه پرسپترون چند لایه، فرآیند بارش - رواناب را با دقت خوبی تخمین زد. خسروی و شکیبیا (۱۳۸۹)، در تحلیل نتایج خروجی مدل شبکه عصبی برای پیش‌بینی بارش ایستگاه ایرانشهر در استان سیستان و بلوچستان نشان دادند که این مدل توانایی بهتر و دقت بالایی برای پیش‌بینی بارش نسبت به روش‌های آماری معمول داشته است و با افزایش فاکتورهای ورودی، شبکه دقت بالاتری را در پیش‌بینی ارائه می‌دهد. حلبیان و دارند (۱۳۹۱) در پژوهش خود برای پیش‌بینی بارش ماهانه شهر اصفهان، بیان داشتند که شبکه عصبی به خوبی رابطه غیر خطی بین مقادیر ماهانه بارش را پیش‌بینی می‌کند. در عین حال نتایج حاصل از تصادفی کردن داده‌ها تفاوت چندانی با مرتب بودن داده‌ها برای آموزش شبکه ندارد. ایلدرمی و همکاران (۱۳۹۲) در پژوهش خود با تکنیک مقیاس بندی مجدد و نمای هرست، پیش‌بینی پدیده بارش در سه منطقه شیراز، کرمان و مشهد را مورد آزمون قرار دادند. در ادامه ایشان در پژوهش خود با استفاده از ۳-۴ پارامتر هواشناسی و شبکه عصبی مصنوعی به پیش‌بینی بارش اقدام کردند و استفاده از اطلاعات دمایی و رطوبتی در طراحی شبکه عصبی را راهی مناسب در توصیف فرآیند بارش معرفی نمودند. امیدوار و همکاران (۱۳۹۴) با بهره‌گیری از شبکه عصبی مصنوعی و استفاده از عوامل اقلیمی موثر بر بارش به عنوان ورودی و بارش روزانه به عنوان خروجی، به پیش‌بینی بارش روزانه در استان کرمان اقدام کردند. ایشان در پژوهش خود مدل‌های مطلوب شبکه عصبی مصنوعی در حالت تغییرات افزایشی نسبت به رطوبت نسبی را دارای بیشترین حساسیت دانستند. رضایی و همکاران (۱۳۹۴) در مقایسه روش‌های شبکه عصبی مصنوعی و SDMS در پیش‌بینی بارش سالانه در ایستگاه‌های کرمان، راور و رابر، روش استفاده از شبکه عصبی را مناسب دانستند.

<sup>1</sup> French et al

<sup>2</sup> Ahmad & Simonovic

<sup>3</sup> Valverde Ramirez et al

<sup>4</sup> Hung et al

<sup>5</sup> Kumar et al

<sup>6</sup> Nayak et al

<sup>7</sup> Mislan et al



ماه تا اواسط شهریور ماه که دوره نهایی پیشرفت و برگشت آن می‌باشد- به سواحل دریای عمان در این منطقه بارندگی‌هایی تولید می‌نماید. برای نمونه رژیم بارش ایستگاه پیشین نشانگر رخدادهای بیشینه بارش در بهمن ماه و کمینه آن در اردیبهشت است.

### مدل سری زمانی

تجزیه و تحلیل سری‌های زمانی به داده‌هایی مربوط می‌شوند که مستقل نبوده و بطور متوالی به هم وابسته‌اند و این وابستگی بین مشاهدات متوالی مورد توجه قرار می‌گیرد (کارآموز، عراقی‌نژاد، ۱۳۸۴، خرمی، بزرگ‌نیا، ۱۳۸۶). مهم‌ترین اهداف تجزیه و تحلیل سری‌های زمانی عبارتند از، کشف و شناسایی مدل احتمالاتی تولید و ساخت داده‌ها و پیش‌بینی مقادیر آینده سری بر مبنای مقادیر گذشته آن است. همچنین، مراحل مدل‌سازی یک سری زمانی به صورت، شناسایی مدل اولیه، برآورد پارامترهای مدل شناسایی شده، بررسی کارایی مدل با استفاده از نمایه‌های ارزیابی می‌باشد.

داده‌های سری زمانی ماهانه بارندگی اطلاعات ارزشمندی را در جهت پیش‌بینی مقادیر آتی فراهم آورده و پارامترهای اصلی در تعیین مقادیر مورد نظر از قبیل روند، اثرات فصلی و شوک‌ها را در اختیار برنامه‌ریزان و پژوهشگران قرار می‌دهد. الگوی میانگین متحرک هم‌انباشته خودتوضیحی فصلی<sup>۱</sup> بسط الگوی میانگین متحرک هم‌انباشته خودتوضیحی می‌باشد. الگوی آریما ترکیبی از دو نوع الگوی سری زمانی تک متغیره شامل الگوی خودتوضیحی و الگوی میانگین متحرک است (Pfaff, 2008). این الگو مقادیر گذشته سری زمانی را برای پیش‌بینی مقادیر آتی سری زمانی مورد استفاده قرار خواهد داد. الگوی آریما را به همراه درجات  $p$ ،  $d$  و  $q$  به صورت  $ARIMA(p,d,q)$  نشان داده می‌شود که در آن  $p$ ، تعداد وقفه‌های خودتوضیحی،  $d$ ، درجه انباشتگی به منظور ایستادن داده و  $q$  تعداد وقفه‌های میانگین متحرک الگو می‌باشد (Kleiber, Zeiles, 2008).

سری زمانی ماهانه بارندگی ایستگاه‌های برگزیده را  $PE_t$  را  $ARIMA(p,d,q)$  نامیده، اگر  $\Delta d NPE_t = (1-L) d PE_t$  به صورت  $ARMA(p,q)$  باشد. به طور کلی، رابطه فوق را می‌توان به صورت زیر نوشت (Enders, 1995):

$$\phi(L)(1-L)^d PE_t = \theta(L)\varepsilon_t \quad (1)$$

در رابطه فوق،  $\varepsilon_t$  ویژگی فرآیند نوفه سفید<sup>۲</sup> ( $PE$ ) را دارا می‌باشد. عملگر وقفه<sup>۳</sup> را نیز می‌توان به صورت  $L^k PE_t = PE_{t-k}$  تعریف نمود، از سوی دیگر، دو عملگر خودتوضیحی<sup>۴</sup> و میانگین متحرک<sup>۵</sup> به صورت زیر بیان می‌شود (Pfaff, 2008):

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

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q \quad (3)$$

در فرآیند فوق،  $\phi(L) \neq 0$  بوده و  $|\phi| < 1$  می‌باشد. بسط الگوی آریما به ساریما زمانی ضرورت داشته که سری زمانی دارای هر دو رفتار فصلی و غیرفصلی باشد. وجود چنین رفتاری الگوی آریما را ناکارا نموده، زیرا در این حالت الگو تنها قادر به سنجش رفتار حول بخش فصلی سری زمانی بوده و منجر به انتخاب درجه نادرست برای جزء غیرفصلی می‌شود (Eric, 2005). اغلب الگوی ساریما را میانگین متحرک هم‌انباشته خودتوضیحی فصلی فزاینده<sup>۶</sup> نامیده و سری زمانی ماهانه بارندگی در منطقه مورد بررسی را با  $SARIMA(p,d,q) PE(P,D,Q)S$  نشان می‌دهند. فرم کلی الگوی ساریما برای سری زمانی ماهانه بارندگی به صورت زیر است:

<sup>1</sup> Seasonal Autoregressive Integrated Moving Average

<sup>2</sup> White Noise

<sup>3</sup> Lag Operator

<sup>4</sup> Autoregressive Operator

<sup>5</sup> Moving Average Operator

<sup>6</sup> Multiplicative Seasonal Autoregressive Integrated Moving Average

$$\begin{aligned} \phi(L)\Phi(L^S)(1-L)^d(1-L^S)^D NPE_t &= \theta(L)\Theta(L^S)\varepsilon_t \\ \phi(L) &= 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \\ \Phi(L^S) &= 1 - \Phi_1 L^S - \Phi_2 L^{2S} - \dots - \Phi_p L^{pS} \\ \theta(L) &= 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q \\ \Theta(L^S) &= 1 - \Theta_1 L^S - \Theta_2 L^{2S} - \dots - \Theta_o L^{oS} \end{aligned} \quad (4)$$

در الگوی فوق،  $p$ ،  $d$  و  $q$  به ترتیب درجه خودتوضیحی، تفاضل گیری و میانگین متحرک غیر فصلی بوده و  $D$  و  $Q$  به ترتیب درجه خودتوضیحی، تفاضل گیری و میانگین متحرک فصلی می باشد. جزء  $\varepsilon_t$  جمله خطای دارای شرایط نوفه سفید (شوک تصادفی) و  $S$  درجه فصلی (برای داده های ماهانه برابر با ۱۲) را نشان می دهد. به منظور برآورد الگو، در گام نخست باید ایستایی سری زمانی را مورد بررسی قرار داد. ایستایی به مفهوم ثابت بودن مقادیر میانگین، واریانس و خودهمبستگی سری زمانی در طول زمان است. در صورتی که سری زمانی ایستا باشد میانگین هر زیرمجموعه سری زمانی نباید به طور معنی داری از میانگین زیرمجموعه دیگر متفاوت باشد. از سوی دیگر، واریانس هر زیرمجموعه سری زمانی تنها به صورت تصادفی از واریانس زیرمجموعه دیگر متفاوت خواهد بود. برقراری شرایط ایستایی، پایداری ضرایب رگرسیون خودتوضیحی را در طول بازه مشخصی به همراه داشته، همچنین، وارون پذیری<sup>۱</sup> ضرایب رگرسیون میانگین متحرک را تضمین خواهد نمود (Hamilton, 1994). با برقراری شرایط فوق، امکان انجام پیش بینی با بهره گیری از الگوی برازش شده فراهم خواهد شد.

به منظور آزمون ایستایی سری زمانی، وجود یا عدم وجود ریشه واحد<sup>۲</sup> بررسی می شود. آزمون ریشه واحد در پی تعیین روند تصادفی یا قطعی در سری زمانی است. در صورت قرار داشتن ریشه های واحد در خارج از دایره واحد<sup>۳</sup> سری زمانی ایستا خواهد بود. به بیان دیگر، در صورتی که ضرایب الگوی برازش شده بر حسب مقادیر مطلق کمتر از واحد بوده، سری زمانی ایستا می باشد. به منظور انجام آزمون ایستایی برای سری زمانی دارای رفتار فصلی و غیر فصلی، آزمون مورد استفاده باید در بردارنده اجزاء فصلی و غیر فصلی باشند. در این راستا از آزمون های آماری چون دیکی فولر، هگی، اف هاچ و تیلور می توان استفاده نمود (Hyllberg et al, 1990:215, Canova and Hansen, 1995:237, Franses and Hobijn, 1997:25, Tylor, 1997:307). آزمون ریشه واحد سری زمانی ماهانه، از آزمون ریشه واحد در برنامه متلب استفاده شد. که با رد فرض صفر (مبتنی بر نا ایستایی) مانایی سری زمانی ماهانه در گام تاخیری مورد نظر مورد تأیید قرار گرفت (Dickey and Fuller, 1979:427). هنگامی که سری زمانی ایستا باشد، تعیین درجه خودتوضیحی غیر فصلی، درجه میانگین متحرک غیر فصلی، درجه خودتوضیحی فصلی و درجه میانگین متحرک فصلی میسر خواهد شد. در این راستا، بهره گیری از توابع خودهمبستگی<sup>۴</sup> و خودهمبستگی جزئی<sup>۵</sup> نمونه مدنظر قرار گرفت. تعداد خیزهای<sup>۶</sup> معنی دار آماری این دو تابع، درجات الگو را تعیین می نماید (Shumway and Stoffer, 2006). ضروری است تا الگوی ساریما اولیه را با استفاده از درجات پیشنهادی فوق تشکیل داد اما در نهایت الگوی برتر با توجه به مقادیر شاخص های اطلاعات مانند آکائیک، الگوهای ساریما با درجات مختلف حاصل از اعمال تغییر در الگوی اولیه انتخاب خواهد شد. پس از تشخیص الگوی ساریما، در مرحله بعد، برازش الگو با استفاده از رهیافت برآورد حداکثر راستمنائی<sup>۷</sup> مدنظر قرار گرفت. برقراری شرایط نوفه سفید برای اجزاء اخلال، شرط حیاتی در مرحله برازش الگو است. در گام سوم، تشخیص نیکوئی برازش مدنظر بوده، فرض اساسی الگوهای آریما این است که اجزاء اخلال تصادفی، یک سری مستقل و دارای توزیع همسان با میانگین

<sup>1</sup> Invertible<sup>2</sup> Unit root<sup>3</sup> Unit circle<sup>4</sup> Autocorrelation Function<sup>5</sup> Partial Autocorrelation Function<sup>6</sup> Spikes<sup>7</sup> Maximum Likelihood Estimation

و واریانس محدود باشد (Eric, 2010). اگر  $\epsilon_t$  دارای توزیع نرمال با میانگین صفر و واریانس  $\sigma^2$  باشد، سری را نوفه سفید گوسی می‌نامند. در سری‌های نوفه سفید مقادیر خودهمبستگی به لحاظ آماری برابر با صفر خواهد بود. در مرحله تشخیص نیکوئی برازش بررسی وجود خودهمبستگی، ناهمسانی واریانس و نرمال بودن اجزاء اخلاص مدنظر بوده، که در این راستا به ترتیب استفاده از آزمون‌های  $Q$  یا آماره  $Q^*$ ، آزمون شاپیرو توصیه می‌شود (Enders, 2012). گام چهارم در استفاده از الگوی ساریما پیش‌بینی است. اگر الگوی مناسب توضیح‌دهنده فرآیند تولید داده<sup>۲</sup> شناسایی شد، می‌توان آن را به منظور پیش‌بینی مقادیر آتی مورد استفاده قرار داد. به منظور انتخاب الگوی برتر به لحاظ صحت پیش‌بینی استفاده از آماره‌های دقت پیش‌بینی که در ادامه آمده است، استفاده شد. با توجه به رویکرد ارائه شده، در این تحقیق به منظور تبیین الگوی مناسب جهت بررسی رفتار و پیش‌بینی مقادیر آتی سری زمانی ماهانه بارندگی گستره مورد بررسی، نخست ماهیت رفتار ماهانه سری زمانی با استفاده از رهیافت آزمون ریشه واحد تعیین شد. پس از تعیین وجود ریشه‌های غیرفصلی و فصلی در فراوانی‌های مربوطه، در گام بعد، با بهره‌گیری از فیلتر مناسب الگوی ساریما برازش شده و در نهایت پس از انجام مراحل تشخیص و گزینش الگوهای پایدار، الگوی برتر به منظور پیش‌بینی انتخاب شد. الگوی برتر سری زمانی در بین چندین مدل مناسب تشخیص داده شده با آزمون‌های باقیمانده‌ها، بر اساس معیار آکائیک تشخیص داده شد. از بین مدل‌های مختلف، مدلی مناسب‌تر است که مقدار آکائیک کمتری داشته باشد و در صورتی که بین چندین مدل، این معیار مشابه باشد طبق اصل امساک مدلی مناسب‌تر است که پارامترهای آن ( $p$  و  $q$ ) مقادیر پائین‌تری نسبت به بقیه داشته باشد.

$$AIC = N \cdot \ln(\sigma_e^2) + 2(p + q) \quad (5)$$

که در آن،  $N$  تعداد سال‌های آماری،  $\sigma_e^2$  واریانس خطا و  $p$  و  $q$  به ترتیب مرتبه مدل اتورگرسیو و مدل میانگین متحرک است (کارآموز، عراقی نژاد، ۱۳۸۴).

### شبکه‌های عصبی با تاخیر زمانی<sup>۳</sup>

شبکه عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی بنام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرآیندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایند یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود (Dayhoff, 1990). شبکه‌های عصبی استاتیک فقط الگوهای ورودی که طبیعت مکانی (فضایی) دارند، یعنی الگوهای ورودی که می‌توانند در طول یک یا چند محور فضایی قرار گیرند را پردازش نمایند. اما در بعضی از مسائل، الگوهای ورودی شامل یک یا چند سیگنال زمانی نیز می‌باشند، که به عنوان نمونه می‌توان مسائل تشخیص گفتار، پیش‌بینی سری زمانی و فیلتر کردن سیگنال‌ها را نام برد. یک شبکه عصبی تاخیر زمانی همانند شبکه چند لایه‌اند، با این تفاوت که خروجی شبکه عصبی، همان ورودی است که با تاخیرهای زمانی مختلف نسبت داده‌های ورودی انتخاب می‌شود.

<sup>1</sup> Box-Pierce or Ljung-Box


<sup>2</sup> Data Generation Process

<sup>3</sup> Time Delay Neural Network

**جدول ۱- معماری شبکه‌های عصبی مصنوعی با تاخیر زمانی برتر مورد استفاده در پیش‌یابی بارش**

| ساختار شبکه            | نوع شبکه       | لایه ورودی | گام تاخیری | تعداد نرون‌ها | لایه خروجی |
|------------------------|----------------|------------|------------|---------------|------------|
| RBF S12 I: s-N-N-N: O  | شعاعی مبنا     |            |            |               |            |
| GRNN S12 I: s-N-N-N: O | تعمیم رگرسیونی | I          | S          | N             | O          |

در شکل ۲، هدف، مدل‌سازی سری زمانی S است. در لایه ورودی، هر مقدار سری زمانی در زمان t در مقابل مقدار بعدی سری زمانی در زمان t+1 به عنوان خروجی قرار گرفته است. در این تحقیق پس از آموزش، پردازش و بررسی شبکه‌های مختلف در نهایت دو مدل شبکه شعاع مبنا و شبکه تعمیم رگرسیونی با معماری مطابق جدول ۱ ارائه شد.



شکل ۲- ساختار شبکه عصبی مصنوعی برای پیش‌بینی یک گام به جلو  $S_t$  ورودی در زمان t و  $S_{t+1}$  خروجی در زمان t+1

**نمایه‌های ارزیابی خطا**

برای ارزیابی خطای مدل‌های پیش‌یابی بارش ماهانه از نمایه‌های ریشه دوم میانگین مربعات خطا<sup>۱</sup>، میانگین مطلق خطا<sup>۲</sup> (Fox,1981:599)، کسر بایاس<sup>۳</sup> (Kumar,2000) و نمایه میانگین خطای بایاس<sup>۴</sup> (Addiscott, Whitmore,1987:141) استفاده شد. کوچک بودن نمایه ریشه دوم میانگین مربعات خطا نشانه نزدیک بودن داده‌های شبیه‌سازی شده به داده‌های مشاهده شده و در نتیجه خوب بودن عملکرد مدل است. این نمایه حساسیت زیادی به وجود مقادیر حدی در سری داده‌ها نشان می‌دهد زیرا به صورت توان دوم اختلافات بیان می‌شود. نمایه دیگری که در این تحقیق مورد استفاده قرار گرفت نمایه میانگین مطلق خطا بوده است که هر چه به صفر نزدیکتر باشد، بیانگر این مطلب است، مقادیر محاسبه شده توسط مدل، به مقادیر حقیقی نزدیکتر و در نتیجه مدل از خطای کمتری برخوردار است. نمایه کسر بایاس می‌تواند مقادیر بین  $+2$  و  $-2$  داشته باشد و مقدار نزدیک به صفر نشان دهنده پیش‌یابی مناسب مدل می‌باشد. نمایه میانگین خطای بایاس می‌تواند منفی، مثبت و یا صفر باشد ولی بهترین مقدار آن صفر است. برای ارزیابی مدل از نمودار پراکنش<sup>۵</sup> داده‌های اندازه‌گیری شده در مقابل داده‌های شبیه‌سازی شده در اطراف خط مستقیم ۱:۱ استفاده شد.

<sup>1</sup> Root mean squared error

<sup>2</sup> Mean Absolute Error

<sup>3</sup> Fractional Bias

<sup>4</sup> Mean Bias Error

<sup>5</sup> Scatter diagram



## یافته‌های پژوهش

در این تحقیق، برای مدل‌سازی از مدل‌های دینامیکی شبکه عصبی با گام تأخیر و الگوی سری زمانی میانگین متحرک هم‌انباشته خودتوضیحی فصلی استفاده شد. همان‌طور که پیش‌تر بیان شد، مقادیر ماهیانه بارش معرف حوضه نیز به روش میانگین‌گیری وزنی بر اساس پراکنش ایستگاه‌های هواشناسی مناسب انتخاب و در مدل‌سازی و تحلیل نتایج استفاده شد. بر اساس مقادیر فعلی هر یک از سری زمانی، مقادیر گام به جلو ماهانه آن با استفاده از ساریما و شبکه عصبی با گام تأخیر مدل‌سازی شد. معماری شبکه‌های عصبی با گام تاخیری برتر و بهترین الگوی ساریما با مشخصات کامل در جدول ۲ آمده است.


جدول ۲- مشخصه‌ها و معماری مدل‌های برتر پیش‌یابی بارش ماهانه

| مدل           | RBF<br>s12 1:12-15-<br>1:1 | RBF<br>s12 1:12-11-<br>1:1 | GRNN<br>s12 1:12-200-<br>2-1:1 | GRNN<br>s12 1:12-200-<br>2-1:1 |
|---------------|----------------------------|----------------------------|--------------------------------|--------------------------------|
| صحت آموزش     | ۰/۸۸                       | ۰/۹۵                       | ۰/۶۹                           | ۰/۷۳                           |
| صحت انتخاب    | ۰/۸۷                       | ۰/۹۰                       | ۰/۹۳                           | ۰/۹۳                           |
| صحت آزمون     | ۰/۸۹                       | ۰/۹۷                       | ۰/۷۷                           | ۰/۷۸                           |
| خطای آموزش    | ۰/۶۱                       | ۰/۶۶                       | ۰/۴۹                           | ۰/۵۲                           |
| خطای انتخاب   | ۰/۵۱                       | ۰/۵۲                       | ۰/۵۵                           | ۰/۵۵                           |
| خطای آزمون    | ۰/۶۲                       | ۰/۶۸                       | ۰/۵۴                           | ۰/۵۵                           |
| لایه مخفی (۱) | ۱۵                         | ۱۱                         | ۲۰۰                            | ۲۰۰                            |
| لایه مخفی (۲) | ۰                          | ۰                          | ۲                              | ۲                              |

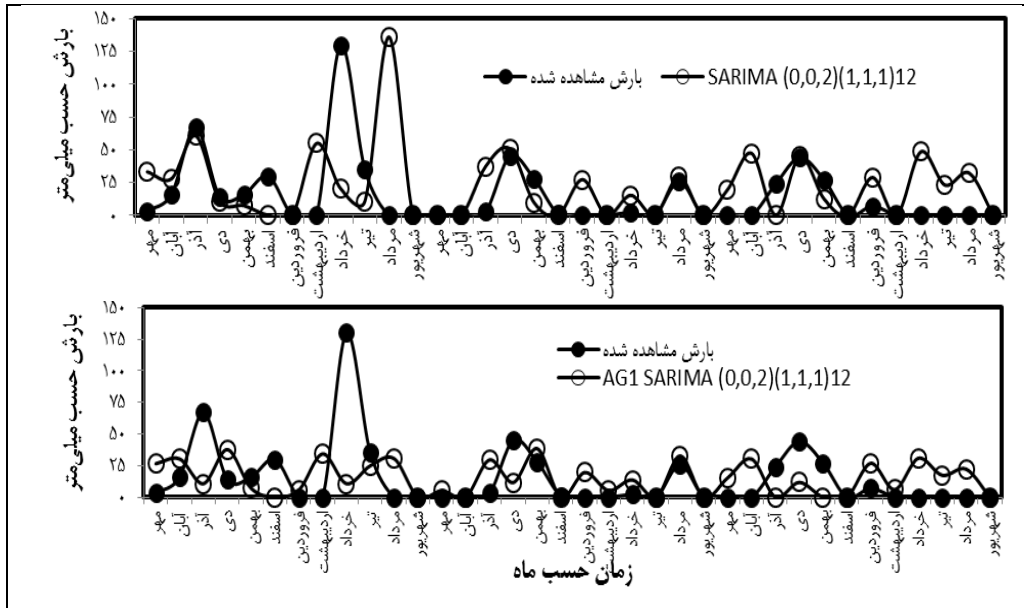
نتایج پیش‌یابی بارش توسط شبکه عصبی با گام تأخیر برای سال آبی ۸۵-۱۳۸۴ تا ۸۸-۱۳۸۷ به دست آمد که در شکل ۳ ارائه شده است. همچنین نتایج پیش‌یابی بارش با بهترین الگوی ساریما برای سال آبی ۸۵-۱۳۸۴ تا ۸۸-۱۳۸۷ بدست آمده در شکل ۴ ارائه شده است. در نهایت، خطای مدل‌های برتر شبکه عصبی و مدل ساریما با استفاده از شاخص‌های یاد شده و برخی از مشخصه‌های آماری داده‌ها ارزیابی شده است که در جدول ۳ منعکس شده است. همچنین نمودار پراکنش داده‌های بارش ماهانه مشاهده شده در مقابل داده‌های برآورد شده حاصل از مدل‌های سری زمانی فصلی و شبکه‌های عصبی در شکل ۵ نشان داده شده است. اگرچه در برخی از سال‌ها و ایستگاه‌ها مقادیر بارش تأثیرپذیری نامنظم بارش‌های منطقه از جریانات مونسون جنوبی را نشان می‌دهد. اما با توجه به نمودارهای بارش معرف در منطقه، رژیم بارندگی و میانگین متحرک هم‌انباشته خودتوضیحی فصلی فزاینده، نشان‌دهنده رفتار فصلی داده‌های بارش حوضه مورد مطالعه است. همانند نتایج دیگر تحقیقات انجام شده در حوضه سیستان جنوبی بارش این منطقه اگرچه روند صعودی و نزولی نداشته اما در سال‌های اخیر از نوسانات زیاد در طول سال برخوردار بوده (گندم‌کار، ۱۳۸۷) و بارش‌های عمده این مناطق از رفتار فصلی که خاستگاه آن منطبق بر الگوی فشاری موسمی هند است سرچشمه می‌گیرید (شبانکاری و حلییان، ۱۳۹۱: ۱۸۴-۱۶۵). بر اساس بهترین مدل‌های انتخاب شده مقادیر بارش ماهانه برای سه سال پیاپی آبی ۸۵-۱۳۸۴ تا ۸۸-۱۳۸۷ محاسبه و با مقادیر بارش‌های وقوع پیوسته مقایسه شد. در مجموع مقادیر نمایه‌های خطا کسر بایاس و میانگین کسر بایاس نشان می‌دهد، مدل‌های شبکه عصبی نتایج بهتری را در مقایسه با مدل استوکستیک ارائه می‌دهد. به‌طوری که مقادیر نمایه‌های پراکنندگی در جدول ۳ و مقایسه شکل ۳ و ۴ نشان می‌دهد اگرچه بارش منطقه بسیار نامنظم است مدل‌های شبکه عصبی با گام تاخیر توانسته روند فصلی بارش را در مقایسه با دیگر مدل‌ها شبیه‌سازی کند.

**جدول ۳- مشخصه‌های آماری داده‌ها و نمایه‌های خطا برای مدل‌های پیش‌یابی بارش**


| اندازه‌گیری شده | SARIMA (0,0,2)(1,1,1) | AGI SARIMA (0,0,2)(1,1,1) | GRNN s12 1:12-200-2-1:1 | GRNN s12 1:12-200-2-1:1 | RBF s12 1:12-11-1:1 | RBF s12 1:12-15-1:1 | مدل          |
|-----------------|-----------------------|---------------------------|-------------------------|-------------------------|---------------------|---------------------|--------------|
| ۴۲۰             | ۴۲۰                   | ۴۲۰                       | ۴۲۰                     | ۴۲۰                     | ۴۲۰                 | ۴۲۰                 | تعداد        |
| ۰               | ۰                     | ۰                         | ۰                       | ۰                       | ۰                   | ۰                   | کمینه        |
| ۲۶۹/۵           | ۲۰۷/۲                 | ۶۵/۳                      | ۱۷۶/۵                   | ۱۷۶/۶                   | ۴۴/۶                | ۵۴/۶                | بیشینه       |
| ۱۰/۷            | ۱۴/۹                  | ۱۲/۱                      | ۱۵/۴                    | ۱۵/۵                    | ۱۱/۹                | ۱۳/۱                | میانگین      |
| ۲۵/۳            | ۱۹/۸                  | ۱۲                        | ۱۱/۲                    | ۱۱/۸                    | ۱۰/۶                | ۱۲/۲                | انحراف معیار |
| ۱/۲             | ۰/۹۷                  | ۰/۵۸                      | ۰/۵۴                    | ۰/۵۸                    | ۰/۵۲                | ۰/۶                 | خطای معیار   |
| ۴/۷             | ۳/۳                   | ۱/۰۲                      | ۷/۳                     | ۶/۳                     | ۰/۵۹                | ۰/۷۴                | چولگی        |
| ۳۳              | ۲۳/۴                  | ۰/۸۶                      | ۱۰۲/۴                   | ۸۰/۹                    | -۰/۳                | -۰/۰۸               | کشیدگی       |
| -               | ۳۲/۸                  | ۲۷/۸                      | ۳۰/۶                    | ۳۱                      | ۲۹/۳                | ۳۰/۹                | RMSE         |
| -               | ۴/۲۴                  | ۱/۴۵                      | ۴/۷۴                    | ۴/۷۸                    | ۱/۲۲                | ۲/۳۵                | MBE          |
| -               | ۰/۳۳                  | ۰/۱۳                      | ۰/۳۶                    | ۰/۳۶                    | ۰/۱۱                | ۰/۲                 | FB           |
| -               | ۱۹/۱                  | ۱۶/۷                      | ۱۹/۴                    | ۱۹/۷                    | ۱۷/۸                | ۱۹/۴                | MAE          |



شکل ۳- نتایج پیش‌یابی شبکه عصبی با گام تأخیر برای بارش ماهانه سال آبی در بازه زمانی ۸۵-۱۳۸۴ تا ۸۸-۱۳۸۷



شکل ۴- نتایج پیش یابی الگوی سری زمانی میانگین متحرک هم انباشته خود توضیحی فصلی بارش ماهانه در بازه زمانی ۸۵-۱۳۸۴ تا ۸۸-۱۳۸۷



شکل ۵- پراکنش داده های بارش ماهانه مشاهده شده و برآورد شده حاصل از مدل های سری زمانی فصلی و شبکه های عصبی

### نتیجه گیری

بارش یکی از مهمترین داده های ورودی برای مدل ها و الگوریتم های مدیریتی در بخش منابع آب به شمار می رود. اهمیت پیش آگاهی بارش در کشوری با اقلیم خشک و کم آب همانند ایران، غیرقابل اجتناب است. در این مطالعه در نهایت به منظور انتخاب یک مدل مناسب برای پیش یابی بارش ماهانه حوضه مورد مطالعه از بین دو مدل سری زمانی و شبکه عصبی مصنوعی، از ارقام جدول ۳ استفاده شد. همچنین درصد خطای نسبی بهترین مدل های سری زمانی با بهترین مدل های شبکه عصبی مقایسه شد. بررسی نتایج مربوط به درصد نسبی خطای پیش یابی نشان داد که پیش یابی بارش با شبکه های عصبی بهتر از مدل های تصادفی در گستره بلوچستان جنوبی انجام می شود که با نتایج دیگر محققان (جهانگیر، ۱۳۸۴، خسروی، شکیبیا، ۱۳۸۹) همخوانی دارد. این امر به دلیل پراکنندگی زیاد داده های بارش ماهانه در منطقه و روند غیر ساده و غیر خطی است که در گستره مطالعاتی حاکم می باشد. تاثیر پذیری نامنظم بارش های منطقه از جریانات مونسون جنوبی در فصل گرم و از سوی رخداد بارش های رگباری با شدت زیاد



و تداوم اندک، مدل‌سازی تصادفی بارش‌های منطقه را با چالش روبرو می‌سازد. بارش‌های سیستان بسیار کم بوده و به‌طور معمول از مهرماه آغاز و حداکثر تا اردیبهشت ادامه دارد. میانگین کمینه بارش در خرداد ماه ۰/۲ میلی‌متر و بیشینه آن در دی‌ماه ۱۸/۹ میلی‌متر است. ضریب تغییرات سالانه نیز بین ۳۰ تا ۱۶۳ درصد متفاوت است. این تفاوت در میزان بارندگی سالانه، می‌تواند به علت تأثیر جریان‌ات جوی و تغییرات ارتفاعی حاکم بر حوضه سیستان جنوبی باشد. بنابراین بالا بودن ضریب تغییرپذیری درون سالی بارش در ایستگاه‌ها نشان‌دهنده عدم نظم و غیر قابل پیش‌بینی بودن بارندگی در ماه‌های مختلف سال می‌باشد. تغییرپذیری درون سالی بالا نشان‌دهنده شرایط اقلیمی خشک می‌باشد. این ضریب از ۱۵۰/۵ درصد در ایستگاه خاش تا ۲۱۹/۶ درصد در ایستگاه بمپور تغییر می‌کند. با این حال مدل منتخب شبکه عصبی برای پیش‌بینی بارش‌های ماهانه به عنوان مناسبترین مدل برگزیده شد.

### منابع و مآخذ

- آشگر طوسی، شادی (۱۳۸۲). پیش‌بینی وقوع خشکسالی در استان خراسان. پایان‌نامه کارشناسی ارشد، دانشگاه فردوسی مشهد، دانشکده کشاورزی، گروه مهندسی آب.
- امیدوار، کمال، نبوی زاده، معصومه، میثم ثمره، قاسم (۱۳۹۴)، ارزیابی دقت شبکه عصبی مصنوعی بازگشتی نارکس در پیش‌بینی بارش روزانه در استان کرمان. فصلنامه جغرافیای طبیعی، شماره ۲۷، صص ۹۰-۷۳.
- ایلدرمی، علیرضا، زارع ابیانه، حمید، بیات ورکشی، مریم (۱۳۹۲)، برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیر بارشی در سه منطقه شیراز، مشهد و کرمان، مجله جغرافیا و برنامه ریزی، شماره ۴۳، صص ۴۰-۲۱.
- بابازاده، حسین، شمس‌نیا، امیر، بوستانی، فردین، نوروزی اقدم، الناز، خدادای دهکردی، داوود (۱۳۹۱)، بررسی خشک‌سالی و ترسالی و پیش‌بینی پارامترهای خشک‌سالی بارش و درجه حرارت منطقه شیراز با استفاده از روش‌های استوکستیک، مجله جغرافیا و برنامه ریزی، شماره ۴۱، صص ۴۷-۲۳.
- بایزیدی، مطلب، سی و سه مرده، معروف، عصرآگاه، آزیتا (۱۳۹۵)، پیش‌بینی و بررسی روند خشک‌سالی هواشناسی با استفاده از سری زمانی (مطالعه موردی: حوضه آبریز سلماس)، مجله محیط زیست و مهندسی آب، شماره ۴، صص ۳۵۹-۳۴۶.
- جهانگیر، علیرضا، رائینی، محمود، احمدی، میرخالق (۱۳۸۷)، شبیه‌سازی فرآیند بارش-رواناب با شبکه عصبی مصنوعی و مقایسه با مدل HEC-HMS حوضه معرف کارده، مجله آب و خاک، شماره ۲۲، صص ۸۴-۷۲.
- حسینی‌زاده، محسن، حسنعلی زاده، نفیسه، بابانژاد، منوچهر، رضا نژاد، محسن (۱۳۹۳)، پیش‌بینی بارش ماهانه با استفاده از بسته‌های تخصصی سری‌های زمانی در محیط نرم‌افزار R (مطالعه موردی: ایستگاه اراز کوسه استان گلستان)، نشریه حفاظت و بهره‌برداری از منابع طبیعی، شماره ۲، صص ۱۲-۱.
- حلبیان، امیرحسین و دارند، محمد (۱۳۹۱). پیش‌بینی بارش اصفهان با استفاده از شبکه عصبی مصنوعی، مجله علوم جغرافیایی، شماره ۲۶، صص ۶۳-۴۷.
- خرمی، مصطفی، بزرگ‌نیا، ابوالقاسم (۱۳۸۶)، تجزیه و تحلیل سری‌های زمانی با نرم‌افزار MINITAB14، نشر سخن گستر.
- خسروی، محمود و شکیبیا، هانیه (۱۳۸۹)، پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل، مورد: شهرستان ایرانشهر، مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیدانان جهان اسلام. ایران-زاهدان.
- رضایی، مریم، نهتانی، مریم، مقدم‌نیا، علیرضا، آبکار، علیجان، رضایی، معصومه (۱۳۹۴)، مقایسه روش‌های شبکه عصبی مصنوعی و SDSM در ریزمقیاس کردن اندازه بارش سالانه مطالعه موردی کرمان، راور و رابر، مجله مهندسی منابع آب، شماره ۲۴، صص ۴۰-۲۵.
- شبانکاری مهران، حلبیان امیرحسین (۱۳۹۱)، تحلیل هم‌بستگی ارتباط بین نوسان بارش روزانه در کرانه‌های جنوبی ایران و تغییرات فشار تراز دریا، فصلنامه تحقیقات جغرافیایی، دوره ۲۷، شماره ۱۰۴، صص ۱۸۴-۱۶۵.

## مدل‌سازی پیش‌یابی بارش ماهانه در حوضه آبریز بلوچستان جنوبی ۱۶۱

- عبدالله نژاد، کامل (۱۳۹۴)، مدل‌های تصادفی سری زمانی در پیش‌بینی بارندگی ماهانه (مطالعه موردی ایستگاه هاشم آباد گرگان)، مجله آمایش جغرافیایی فضا، شماره ۱۷.
- فیضی، وحید، فرج زاده، منوچهر، نودری، رباب (۱۳۸۹)، مطالعه تغییر اقلیم در استان سیستان و بلوچستان به روش من-کندال، مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیدانان جهان اسلام، ایران-زاهدان.
- کارآموز، محمد، عراقی نژاد، شهاب (۱۳۸۴)، هیدرولوژی پیشرفته، انتشارات دانشگاه امیر کبیر.
- گندمکار، امیر (۱۳۸۷)، بررسی روند تغییرات بارش در زابل، اولین کنفرانس بین‌المللی بحران آب، دانشگاه زابل.
- مسعودیان، ابوالفضل (۱۳۸۲)، بررسی پراکندگی جغرافیایی بارش در ایران به روش تحلیل عاملی دوران یافته، فصلنامه جغرافیا و توسعه، شماره ۱، صص ۷۹-۸۸.

- Addiscott, Thim, and Whitmore, Stephen. (1987), Computer simulation of changes in soil mineral nitrogen and crop nitrogen during autumn, winter and spring. *The Journal of Agricultural Science*, 109(01), pp.141-157 .
- Ahmad, S., Simonovic, s.(2005), An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *Journal of Hydrology*, 315(1), pp.236-251 .
- Ahhashimi, Shaymaa (2014), Prediction of monthly rainfall in Kirkuk using artificial neural network and time series models. *Journal of engineering and development*, 18 (1), pp.129-142.
- Babazadeh, H. Shamsnia, A., Bostani, F. Noroozi Aghdam, E. , Khodadadi Dehkordi, D. (1391), Analysis of Drought, Wetness Year and Forecasting of Climate Parameters, Precipitation and Temperature Using Stochastic Methods in Shiraz City. *Journal of geography and*
- Bloomfield, Peter, and Nychka, Douglas (1992), Climate spectra and detecting climate change. *Climatic Change*, 21(3), pp.275-287 .
- Box, G., Jenkins, G., Reinsel, G. (2013), *Time series analysis: forecasting and control*: John Wiley and Sons.
- Burlando, P., Montanari, A., and Ranzi, R. (1996), Forecasting of storm rainfall by combined use of radar, rain gages and linear models. *Atmospheric research*, 42(1), pp.199-216 .
- Canova, F., Bruce, H. (1995), Are seasonal patterns constant over time? A test for seasonal stability. *Journal of Business and Economic Statistics*, 13(3), pp.237-252 .
- Dayhoff, J. (1990), *Neural Network Principles*. : Prentice-Hall International, U.S.A.
- Dickey, D., Fuller, W. (1979), Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), pp. 427-431 .
- Enders, W.(2008), *Applied econometric time series*: John Wiley and Sons.
- Enders, Walters (1995), *Applied econometric time series*: John Wiley and Sons.
- Eric, A. (2010), *Modeling and Forecasting Inflation Rates in Ghana: an Application of SARIMA Models*, dissertation. Thesis of M.S. submitted to the School of Technology and Business Studies.
- Folland, Ch. (1990), *Observed Climatic Variation and Change, Climate Change: The IPCC Scientific Assessment*. Cambridge University Press. pp.195-238.
- Fox, D. (1981), Judging air quality model performance. *Bulletin of the American Meteorological Society*, 62(5), pp. 599-609 .
- Franses, Ph., Hobijn, B. (1997), Critical values for unit root tests in seasonal time series. *Journal of Applied Statistics*, 24(1), pp. 25-48 .
- French, M., Krajewski, W., Cuykendall, R. (1992), Rainfall forecasting in space and time using a neural network. *Journal of Hydrology*, 137(1), pp.1-31 .
- Hamilton, J. (1994), *Time series analysis*. vol (2). Princeton university press Princeton.
- Hansen, J. (1988), Global surface air temperature. *Geology Letter*,(15), pp. 323-326 .
- Hung, N., Babel, M., Weesakul S., thripathi, N. (2009), An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Science*, 13, pp.1414-1425.
- Hylleberg, S., Engle, R., Granger, C., Yoo, B. (1990), Seasonal integration and cointegration. *Journal of econometrics*, 44(1), pp.215-238 .
- Jamshidi, V. (1989), *Evaluation of Temperature and Rainfall in Tehran City by Time Series*. Thesis of M.S. Tarbiat Modares University, Statistics, Dept., pp. 263.
- Jones, P., Raper, S., Bradley, R., Diaz, H., Kellyo, P., Wigley, T.(1986), Northern Hemisphere surface air temperature variations: 1851-1984. *Journal of Climate and Applied Meteorology*, 25(2), pp.161-179 .
- Kheradmand-Nia, M.Asakereh, H.(2001), Patterning of ARIMA for Annual Average Temperature in Jask (Iran), Paper presented at the 3rd Conference of Stochastic Process, Isfahan University .
- Kleiber, Christian (2008). *Applied Econometrics with R*. : Springer Science Business Media, LLC, NY, USA.
- Kumar, A. (2000), *Dispersion and risk modeling*. Department of Civil Engineering, University of Toledo .
- Kumar, S., Tripathy, D., Nayak, S., Mohaparta, S. (2013), Prediction of rainfall in India using artificial neural network models. *International Journal of intelligent system and applications*, 12, pp.1-22.



- Maleki, M.(1989), Investigation and Modeling of Temperature and Rainfall in West Country. 184 pp.
- Mislán, H., Hardwinarto, S. Aipassa, M. (2015), Rainfall monthly prediction based on artificial neural network: a case study in Tenggara station, east Kalimantan, Indonesia. International conference in computer science and computational intelligent, pp.142-151.
- Nayak, D., Mahapatra, A., Mishra, P. (2013), A survey on rainfall prediction using artificial neural network. International journal of computer applications, 72 (16), pp.32-40.
- Noakes, D., McLeod, I., Hipel, K. (1985), Forecasting monthly riverflow time series. International Journal of Forecasting, 1(2), pp.179-190 .
- Paras, D., Mathur, S. (2012), A simple weather forecasting model using mathematical regression. Indian research journal of extension education, 1, pp.161-169.
- Pfaff, B. (2008), Analysis of integrated and cointegrated time series with R: Springer.
- Rasuli, A.(2002), Modeling of Climate Parameters in Country North-West. Forecasting Monthly Temperature of Tabriz City (Iran) by ARIMA model. Tabriz University, Journal of Sociology Science, 8 .
- Rivero, C. Pucheta, J. (2014), Forecasting rainfall time series with stochastic output approximated by neural networks Bayesian approach. International journal of advanced computer science and applications, 5 (6), pp.145-151..
- Shumway, R., Stoffer, D. (2010), Time series analysis and its applications: with R examples: Springer.
- Taylor, R. (1997), On the practical problems of computing seasonal unit root tests. International Journal of Forecasting, 13(3), pp.307-318 .
- Valverde Ramírez, M., de Campos Velho, H., Ferreira, N. (2005), Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. Journal of Hydrology, 301(1),pp. 146-162 .
- Yevjevich, V. (1987), Stochastic models in hydrology. Stochastic Hydrology and Hydraulics, 1(1), pp.17-36.