

Dr. S. Marofi

دکتر صفر معروفی*، استاد گروه علوم و مهندسی آب، دانشگاه بوعلی سینا همدان

R. Norooz valeshedi

رضا نوروز ولاشیدی، دانشجوی دکتری هواشناسی کشاورزی، دانشگاه بوعلی سینا همدان

F. Golkar

فروغ گلکار، دانشجوی دکتری هواشناسی کشاورزی، دانشگاه بوعلی سینا همدان

smarofi@yahoo.com

مدل‌سازی پیش‌یابی بارش ماهانه در حوضه آبریز بلوچستان جنوبی

پذیرش نهایی: ۱۳۹۶/۲/۱۵

دریافت مقاله: ۱۳۹۵/۱۱/۲۲

چکیده

افزایش رخداد بارش‌های حدی و از سوی دیگر عدم بارش در یک گستره، خسارات قابل توجهی در دهه‌های اخیر به بوم‌سامانه‌های طبیعی و مصنوعی وارد ساخته است. از این رو پیش‌یابی مقادیر بارش برای مدیریت مناسب منابع آبی در این گستره‌ها بسیار اهمیت دارد. هدف این پژوهش پیشنهاد مدل و بررسی دقیق پیش‌یابی بارش ماهانه با روش‌های شبکه عصبی مصنوعی و مدل‌های تصادفی در پهنه جنوب شرق کشور واقع در استان سیستان و بلوچستان می‌باشد. این منطقه به لحاظ تاثیرپذیری از سامانه‌های گوناگون بارانزا و کمی متفاوت از سایر مناطق کشور، دارای رژیم بارش رگباری نامنظم و تقریباً پیچیده‌ای است. پیش‌یابی بارش معرف منطقه با استناد بر روش‌های سری زمانی ساریما و شبکه عصبی با تاخیر زمانی انجام گرفت. داده‌های مورد بررسی شامل سری بارش ماهانه دوره آماری ۱۳۵۱-۵۲ تا ۱۳۸۷-۸۸ برای ایستگاه‌های منتخب منطقه می‌باشد، که بر پایه پراکنش مناسب ایستگاه‌ها و کیفیت داده‌ها برگزیده شدند. مقایسه نتایج پیش‌یابی 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 سامانه‌های مختلف بارانزا، رژیم بارش‌های رگباری و بسیار پراکنده پهنه جنوب شرق کشور مربوط می‌شود.

واژه‌های کلیدی: بارش، شبکه عصبی، سری زمانی، پیش‌یابی، حوضه بلوچستان جنوبی.

مقدمه

بشر برای درک و کنترل بهتر محیط پیرامون خود از مدل‌ها استفاده می‌کند. نگرش‌های قطعی (دترمینیستیک) و تصادفی (استوکاستیک) دو دیدگاه اصلی برای شناخت طبیعت هستند. قاعده کلی مدل‌های قطعی بر پایه روابط علی-معلولی بنا شده است که به طور معمول به وسیله معادلات ریاضی بیان می‌شوند. در حالی که نقطه نظر اصلی در نگرش تصادفی آن است که روابط موجود بین پدیده‌ها را نمی‌توان به راحتی به صورت روابط علی-معلولی ساده و یا حتی پیچیده بیان کرد. در عوض در این مدل‌ها سعی بر شناخت خصوصیات متغیرهای طبیعی با توجه به مقادیر مشاهده شده آنها و با استفاده از فرآیندهای تصادفی و آمارهای ریاضی دارد (Yevjevich, 1987:17). روش‌های مختلفی برای مدل‌سازی داده‌ها و استفاده از مدل برای پیش‌بینی وجود دارد. از جمله مهم‌ترین این روش‌ها می‌توان به مدل‌های سری زمانی، زنجیره مارکف و شبکه عصبی مصنوعی و غیره اشاره کرد. در این پژوهش از مدل‌های سری زمانی و شبکه عصبی استفاده شد.

در استفاده از سری‌های زمانی در مدل‌سازی پارامترهای هیدرولوژیکی همچون بارندگی، دما و جریان‌های رودخانه پژوهش‌های متعددی صورت گرفته است. الگوسازی در خانواده آرما، آریما و آریما فصلی یکی از شیوه‌های مهم و معتبر در شبیه‌سازی

پارامترهای اقلیمی است (Box et al, 2013). بورلاندو^۱ و همکاران (۱۹۹۶) از مدل‌های آریما جهت پیش‌بینی بارندگی‌های ساعتی در زمان وقوع آن‌ها استفاده کردند و مقادیر به دست آمده را با داده‌های باران‌سنجد 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^۲ (۱۹۸۶)، هانسن و لبدف^۳ (۱۹۸۸)، بلوفیلد و نیچکا^۴ (۱۹۹۲) و فولاند^۵ (۱۹۹۰) اشاره نمود. نواکز^۶ 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^۷ (۲۰۱۲) دو روش سری زمانی و رگرسیون چند متغیره غیر خطی را برای پیش‌بینی بارش ماهانه هندوستان مناسب معرفی کردند. رویرو و پوچتا^۸ (۲۰۱۴) در مقایسه دو روش سری زمانی و شبکه عصبی مصنوعی، روش نخست را برای منطقه آرژانتین بسیار مناسب دانستند. الهاشمی^۹ (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^{۱۰} (۱۹۸۹) در مدل دما-بارش ایستگاه تهران، مالکی^{۱۱} (۱۹۸۹) در الگوسازی دما و بارش غرب کشور و رسولی^{۱۲} (۲۰۰۲) برای پیش‌بینی دمای ماهانه شهر تبریز اشاره نمود. خردمندیا و عساکر^{۱۳} (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 تغیرات 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 برآشش 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

¹ Burlando et al² Jones³ Hansen & Lebedeff⁴ bloomfield & Nychka⁵ Folland⁶ Noakes⁷ Paras & Mathur⁸ Rivero & Pochata⁹ Alhashimi¹⁰ Jamshidi¹¹ Maleki¹² Rasuli¹³ Kheradmand Nia&Asakereh

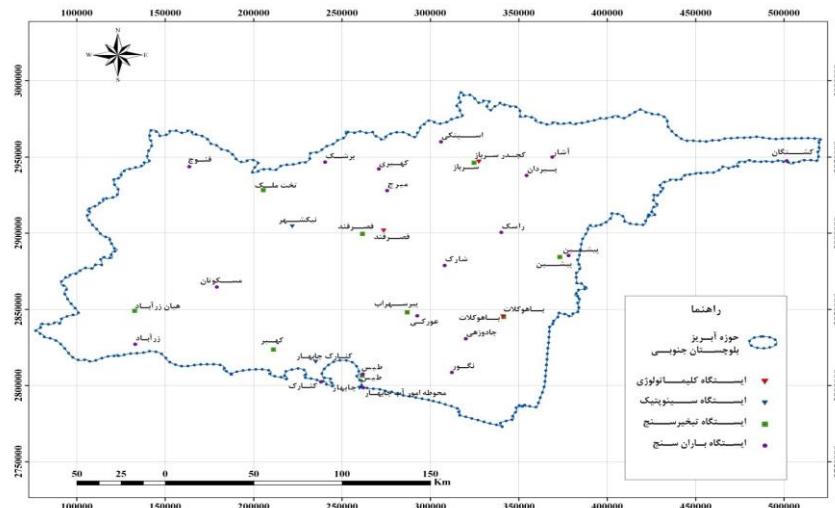
سری‌های زمانی غیرخطی و غیرماندگار فرآیندهایی که برای شناخت و توصیف دقیق آنها راه حل و رابطه صریحی وجود ندارد، عملکرد خوبی از خود نشان داده است. اکنون این شبکه‌ها با ساختارهای متنوع و وسیع، در بسیاری از علوم، از جمله مهندسی آب، گسترش یافته‌اند. فرنچ^۱ و همکاران (۱۹۹۲: ۳۱-۱) بارندگی در یک مکان و یک ساعت بعد را با استفاده از روش شبکه عصبی مصنوعی و اطلاعات توزیع مکانی و زمانی بارندگی پیش‌بینی کردند. احمد و سیموونیک^۲ (۲۰۰۰: ۲۵۱-۲۳۶) از شبکه‌های عصبی سه لایه با خاصیت انتشار به عقب خطأ و داده‌های بارندگی ماهانه جهت پیش‌بینی بارش ماهانه، در مجارستان و اوکراین، استفاده نمودند. نتایج تحقیق آنها نشان داد، داده‌های آموزشی و آزمایشی جورشده‌گی و انطباق خوبی با داده‌های واقعی دارند و این روش در پیش‌بینی بارش، دارای حداکثر توانایی است. والورد رامی رز^۳ 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^۴ و همکاران (۲۰۰۹) در پیش‌بینی 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^۵ 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^۶ و همکاران (۲۰۱۳) با مروری بر روش‌های پیش‌بینی بارش در هند، شبکه عصبی مصنوعی را در مقایسه بارش‌های پیش‌بینی عددی مناسب‌تر معرفی کردند. میسلان^۷ 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 شبیه سازی فرآیند بارش-رواناب، در حوضه کارد، بررسی کرد و با استفاده از شبکه پرسپترون چند لایه، فرآیند بارش-رواناب را با دقت خوبی تخمین زد. خسروی و شکیبا (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 تصادفی کردن داده‌ها تفاوت چندانی با مرتب بودن داده‌ها برای آموزش شبکه ندارد. ایلدرمی و همکاران (۱۳۹۲) در پژوهش خود با تکنیک مقیاس‌بندی مجدد و نمای هrst، پیش‌بینی پذیبی بارش را پیش‌بینی می‌کند. در عین حال نتایج حاصل از قراردادن در ادامه ایشان در پژوهش خود با استفاده از ۳-۴ پارامتر هواشناسی و شبکه عصبی مصنوعی به پیش‌بینی بارش اقدام کرددند و استفاده از اطلاعات دمایی و رطوبتی در طراحی شبکه عصبی را راهی مناسب در توصیف فرایند 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.

¹ French et al² Ahmad & Simonovic³ Valverde Ramirez et al⁴ Hung et al⁵ Kumar et al⁶ Nayak et al⁷ Mislan et al

در این پژوهش تلاش شده با استفاده از آمار بارندگی دوره برگزیده ایستگاه‌های معرف حوضه و به کارگیری تکنیک سری‌های زمانی و شبکه عصبی مصنوعی، مناسب‌ترین مدل برای پیش‌بینی بارندگی در مقیاس فصلی برای بخشی از حوضه بلوچستان جنوبی واقع در منطقه جنوب شرقی کشور ارائه گردد.

داده‌ها و روش پژوهش

گستره مورد بررسی بخشی از حوضه آبریز بلوچستان جنوبی به وسعت ۴۸۶۶۲ کیلومتر مریع واقع در استان سیستان و بلوچستان می‌باشد. بر اساس طبقه‌بندی‌های اقلیمی مختلف، دارای اقلیم ییبانی گرم شدید، خشک با تابستان‌های گرم و زمستان‌های ملایم می‌باشد (شکل ۱). این گستره رژیم بارندگی منحصر به فردی در کشور دارد. تاثیرپذیری از سامانه‌های باران‌زای شمال-شمال غرب و جنوب-جنوب غرب در فصل‌های پاییز، زمستان و بهار از یک سو و تاثیر جریانات موسمی هندوستان در تابستان از سوی دیگر رژیم بارش پیچیده‌ای را به وجود آورده است. در مجموع در این گستره، تعداد ۳ ایستگاه همدید، چهار ایستگاه اقلیم‌شناسی، ۲۹ ایستگاه باران‌سنجدی تحت پوشش سازمان هواشناسی کشور و همچنین آمار بارش تعداد ۱۱ ایستگاه باران‌سنجد معمولی، ۱۷ ایستگاه تبخیر‌سنجدی و ۱۲ ایستگاه باران‌سنجد ذخیره‌ای موجود می‌باشد. پس از بررسی‌های ابتدایی در کلیه ایستگاه‌های موجود (به جز ذخیره‌ای)، ایستگاه‌های مناسب از دیدگاه پراکنش و طول دوره آماری بارش برگزیده شدند. تعداد ایستگاه‌های بروگزیده ۲۱ ایستگاه با شرایط آماری و پراکنش مناسب در حوضه می‌باشد. سپس آزمون کفایت داده‌ها انجام شد و سری بلند مدت داده‌های ماهانه مورد پذیرش قرار گرفت. در نهایت با توجه به عدم توزیع یکنواخت ایستگاه‌های آماری بارش، برای پیش‌بینی فصلی از بارش معرف حوضه که به روش میانگین‌گیری وزنی استخراج شد، بهره برده شد. دوره آماری برگزیده از سال آبی ۱۳۵۱-۵۲ شروع و به سال آبی ۱۳۸۷-۸۸ ختم می‌شود که دوره ۱۳۸۴-۸۵ تا ۱۳۸۷-۸۸ برای کالیره نمودن و صحت پیش‌بینی مدل انتخاب و کنار گذاشته شد.



شکل ۱- موقعیت محدوده مطالعاتی و پراکنش ایستگاه‌های منتخب در میان مرز حوضه آبریز بلوچستان جنوبی

بررسی بارندگی فصلی ایستگاه‌های برگزیده نشان می‌دهد که نزدیک به ۸۰ درصد بارندگی سالانه در زمستان و بقیه در تابستان رخ می‌دهد. دامنه تغییرات بارندگی ماهانه به مراتب بیشتر از بارندگی سالانه است. معمولاً ریزش بارندگی در پاییز و بهار به صورت رگبارهای شدید و این ریزش در زمستان به صورت باران ریز و معمولی است. نفوذ بادهای موسمی اقیانوس هند-از اواسط تیر

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 رخداد بیشینه بارش در بهمن ماه و کمینه آن در اردیبهشت است.

مدل سری زمانی

تجزیه و تحلیل سری‌های زمانی به داده‌های 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^۱ 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 ایستا نمودن داده و q : تعداد وقفه‌های میانگین متحرک الگو می‌باشد (Kleiber, Zeiles, 2008).

سری زمانی ماهانه بارندگی ایستگاه‌های برگزیده را PE_t (p,d,q) نامیده، اگر Δd 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، ε_t ویژگی فرآیند نوفه سفید^۲ (PE) را دارد می‌باشد. عملگر وقفه^۳ را نیز می‌توان به صورت $L^k PE_t = PE_{t-k}$ تعریف نمود، از سوی دیگر، دو عملگر خودتوضیحی^۴ و میانگین متحرک^۵ 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، $\phi(L) \neq 0$ 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^۶ 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:

¹ Seasonal Autoregressive Integrated Moving Average

² White Noise

³ Lag Operator

⁴ Autoregressive Operator

⁵ Moving Average Operator

⁶ Multiplicative Seasonal Autoregressive Integrated Moving Average



$$\begin{aligned}
 \phi(L)\Phi(L^s)(1-L)^d(1-L^s)^DNPE_i &= \theta(L)\Theta(L^s)\varepsilon_i \\
 \phi(L) &= 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \\
 \Phi(L^s) &= 1 - \Phi_1 L^s - \Phi_2 L^{2s} - \dots - \Phi_p L^{ps} \\
 \theta(L) &= 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q \\
 \Theta(L^s) &= 1 - \Theta_1 L^s - \Theta_2 L^{2s} - \dots - \Theta_q L^{qs}
 \end{aligned} \tag{۴}$$

در الگوی فوق، p ، d و q به ترتیب درجه خودتوضیحی، تفاضل‌گیری و میانگین متحرک غیرفصلی بوده و P ، D و Q به ترتیب درجه خودتوضیحی، تفاضل‌گیری و میانگین متحرک فصلی می‌باشد. جزء ε_i جمله خطای دارای شرایط نوفه سفید (شوک تصادفی) و S درجه فصلی (برای داده‌های ماهانه برابر با ۱۲) را نشان می‌دهد. 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 معنی‌داری 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، وارون‌پذیری^۱ ضرایب رگرسیون میانگین متحرک را تضمین خواهد نمود (Hamilton, 1994). با برقراری شرایط فوق، امکان انجام پیش‌بینی با بهره‌گیری از الگوی برازش شده فراهم خواهد شد.

به منظور آزمون ایستایی سری زمانی، وجود یا عدم وجود ریشه واحد^۲ بررسی می‌شود. آزمون ریشه واحد در پی تعیین روند تصادفی یا قطعی در سری زمانی است. در صورت قرار داشتن ریشه‌های واحد در خارج از دایره واحد^۳ 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 می‌باشد. به منظور انجام آزمون ایستایی برای سری زمانی دارای رفتار فصلی و غیرفصلی، آزمون مورد استفاده باید در بردارنده اجزاء فصلی و غیرفصلی باشند. در این راستا از آزمون‌های آماری چون دیکی فولر، هگی، اف هاچ و تیلور می‌توان استفاده نمود (Hyllberg et al, 1990:215, Canova and Hansen, 1995:237, Frances 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 ناایستایی) مانایی سری زمانی ماهانه در گام تاخیری مورد نظر مورد تأثیر قرار گرفت (Dickey and Fuller, 1979:427). هنگامی که سری زمانی ایستا باشد، تعیین درجه خودتوضیحی غیرفصلی، درجه میانگین متحرک غیرفصلی، درجه خودتوضیحی فصلی و درجه میانگین متحرک فصلی میسر خواهد شد. در این راستا، بهره‌گیری از توابع خودهمبستگی^۴ و خودهمبستگی جزئی^۵ نمونه مدنظر قرار گرفت. تعداد خیزهای^۶ معنی‌دار آماری این دو تابع، درجات الگو را تعیین می‌نماید (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 شاخص‌های 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 حداقل راستنمایی^۷ 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

¹ Invertible² Unit root³ Unit circle⁴ Autocorrelation Function⁵ Partial Autocorrelation Function⁶ Spikes⁷ Maximum Likelihood Estimation

و واریانس محدود باشد (Eric, 2010). اگر ϵ دارای توزیع نرمال با میانگین صفر و واریانس σ^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 اخلال مدنظر بوده، که در این راستا به ترتیب استفاده از آزمون‌های^۱ Q یا آماره^{*} Q، آزمون شاپیرو تووصیه می‌شود (Enders, 2012). گام چهارم در استفاده از الگوی ساریما پیش‌بینی است. اگر الگوی مناسب توضیح‌دهنده فرآیند تولید داده^۲ 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 رائنه 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 غیرفصلي 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 امساك مدلی مناسب‌تر است که پارامترهای آن (q و p) مقادیر پائین‌تری نسبت به بقیه داشته باشد.

$$AIC = N \cdot \ln(\sigma_{\epsilon}^2) + 2(p + q) \quad (5)$$

که در آن، N تعداد سال‌های آماری، σ^2_{ϵ} واریانس خطأ و p و q به ترتیب مرتبه مدل اتورگرسیو و مدل میانگین متحرک است (کارآموز، عراقی نژاد، ۱۳۸۴).

شبکه‌های عصبی با تاخیر زمانی^۳

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) رائمه 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 دست‌بایی 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.

¹ Box-Pierce or Ljung-Box

² Data Generation Process

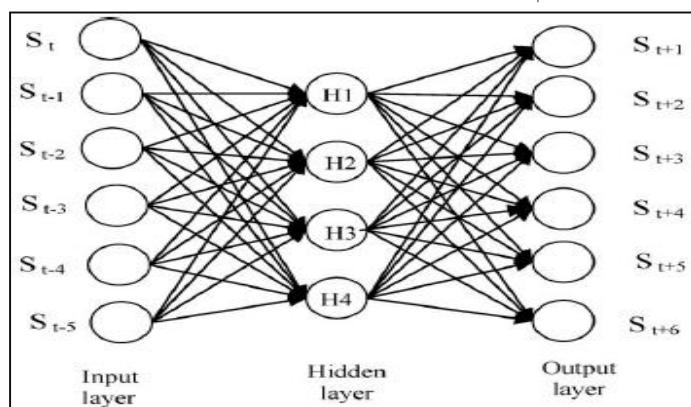
³ Time Delay Neural Network



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

ساختار شبکه	نوع شبکه	لایه تاخیری	لایه ورودی	تعداد نرونها	گام	لایه خروجی
RBF S12 I: s-N-N-N: O	شعاعی مبنا					
GRNN S12 I: s-N-N-N: O	تعییم 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 شعاعی مبنا و شبکه تعییم رگرسیونی با معماری مطابق جدول ۱ ارائه شد.



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

نمایه‌های ارزیابی خطای

برای ارزیابی خطای مدل‌های پیش‌یابی بارش ماهانه از نمایه‌های ریشه دوم میانگین مربعات خطای^۱، میانگین مطلق خطای^۲ (Fox,1981:599)، کسر بایاس^۳ (Kumar,2000) و نمایه میانگین خطای بایاس^۴ (Addiscott ,Whitmore,1987:141) استفاده شد. کوچک بودن نمایه ریشه دوم میانگین مربعات خطای 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 خطای 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^۵ داده‌های اندازه‌گیری شده در مقابل داده‌های شبیه‌سازی شده در اطراف خط مستقیم ۱:۱ استفاده شد.

¹ Root mean squared error

² Mean Absolute Error

³ Fractional Bias

⁴ Mean Bias Error

⁵ Scatter diagram

یافته‌های پژوهش

در این تحقیق، برای مدل‌سازی از مدل‌های دینامیکی شبکه عصبی با گام تأخیر و الگوی سری زمانی میانگین متحرک همانباشه خودتوضیحی فصلی استفاده شد. همان‌طور که پیش‌تر بیان شد، مقادیر ماهیانه بارش معرف حوضه نیز به روش میانگین گیری 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 بتر پیش‌یابی بارش ماهانه

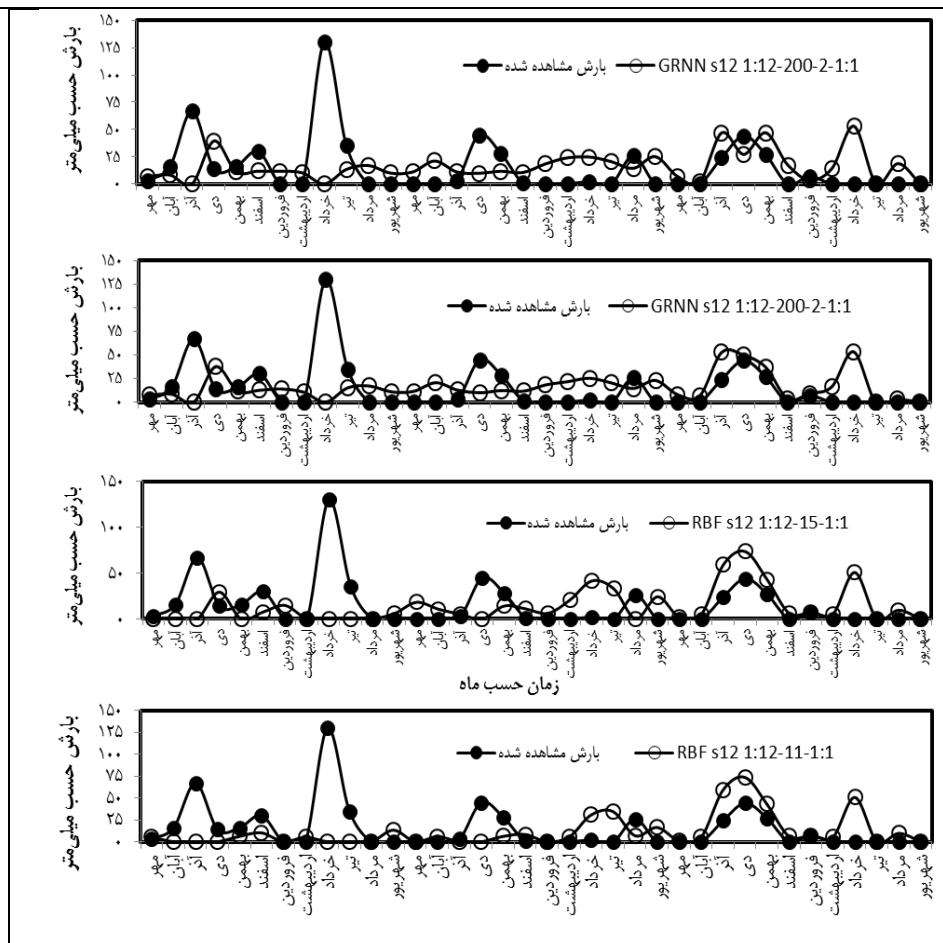
مدل	RBF 1:1	RBF 1:1	RBF 1:1	GRNN 1:1
	s12 1:12-15-1:1	s12 1:12-11-1:1	s12 1:12-200-2-1:1	s12 1:12-200-2-1:1
صحت آموزش	۰/۸۸	۰/۹۵	۰/۶۹	۰/۷۳
صحت انتخاب	۰/۸۷	۰/۹۰	۰/۹۳	۰/۹۳
صحت آزمون	۰/۸۹	۰/۹۷	۰/۷۷	۰/۷۸
خطای آموزش	۰/۶۱	۰/۶۶	۰/۴۹	۰/۵۲
خطای انتخاب	۰/۵۱	۰/۵۲	۰/۵۵	۰/۵۵
خطای آزمون	۰/۶۲	۰/۶۸	۰/۵۴	۰/۵۵
لایه مخفی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

نتایج پیش‌یابی بارش توسط شبکه عصبی با گام تأخیر برای سال آبی ۱۳۸۴-۸۵ تا ۱۳۸۷-۸۸ به دست آمد که در شکل ۳ ارایه شده است. همچنین نتایج پیش‌یابی بارش با بهترین الگوی ساریما برای سال آبی ۱۳۸۴-۸۵ تا ۱۳۸۷-۸۸ بدست آمده در شکل ۴ ارایه شده است. در نهایت، خطای مدل‌های بتر 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 تاثیرپذیری نامنظم بارش‌های منطقه از جریانات مونسون جنوبی را نشان می‌دهد. اما با توجه به نمودارهای بارش معرف در منطقه، رژیم بارندگی و میانگین متحرک همانباشه خودتوضیحی فصلی فزاینده، نشان‌دهنده رفتار فصلی داده‌های بارش حوضه 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 عمدۀ این مناطق از رفتار فصلی که خاستگاه آن منطبق بر الگوی فشاری موسمی هند است سرچشمۀ می‌گیرید (شبانکاری و حلیان، ۱۳۹۱: ۱۸۴-۱۸۵). بر اساس بهترین مدل‌های انتخاب شده مقادیر بارش ماهانه برای سه سال پیاپی آبی ۱۳۸۴-۸۵ تا ۱۳۸۷-۸۸ محاسبه و با مقادیر بارش‌های وقوع پیوسته مقایسه شد. در مجموع مقادیر نمایه‌های خطای 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 پراکندگی 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.

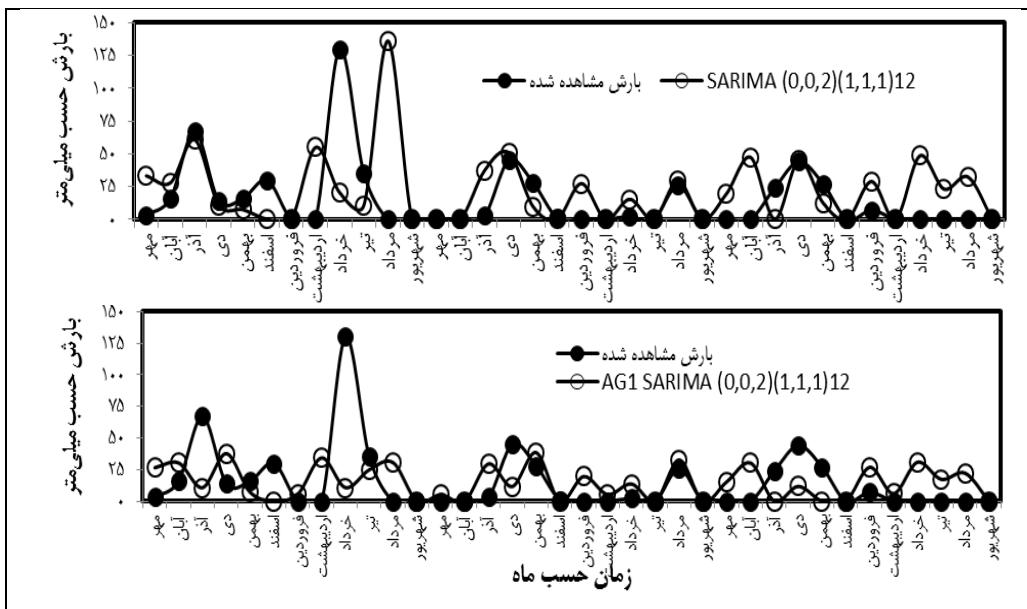


جدول ۳- مشخصه های آماری داده ها و نمایه های خطا برای مدل های پیش یابی بارش

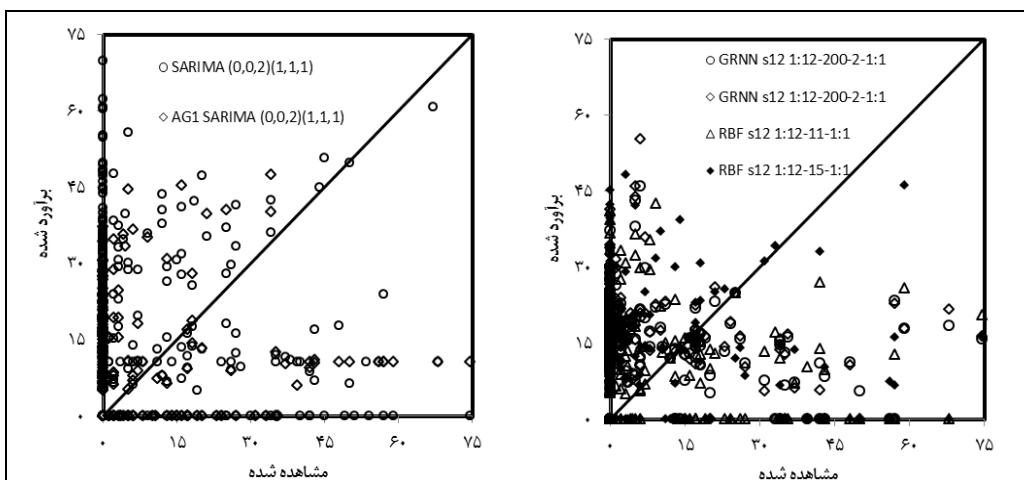
اندازه گیری شده	SARIMA (0,0,2)(1, 1,1)	AG1 SARIMA (0,0,2)(1, 1,1)	GRNN s12 1:12-200- 2-1:1	GRNN s12 1:12-200-2- 1:1	RBF s12 1:12-11- 1:1	RBF s12 1:12-15- 1:1	مدل
۴۲۰	۴۲۰	۴۲۰	۴۲۰	۴۲۰	۴۲۰	۴۲۰	تعداد
.	کمینه
۲۶۹/۵	۲۰۷/۲	۶۵/۳	۱۷۶/۵	۱۷۶/۶	۴۴/۶	۵۴/۶	بیشینه
۱۰/۷	۱۴/۹	۱۲/۱	۱۵/۴	۱۵/۵	۱۱/۹	۱۳/۱	میانگین
۲۵/۳	۱۹/۸	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 پیش یابی شبکه عصبی با گام تأخیر برای بارش ماهانه سال آیی در بازه زمانی ۱۳۸۷-۸۸ تا ۱۳۸۴-۸۵



شکل ۴- نتایج پیش‌یابی الگوی سری زمانی میانگین متغیر ک هم‌انباشته خودتوضیحی فصلی
بارش ماهانه در بازه زمانی ۱۳۸۷-۸۸ تا ۱۳۸۲-۸۵



شکل ۵- پراکنش داده‌های بارش ماهانه مشاهده شده و برآورده شده حاصل از مدل‌های سری زمانی
فصلی و شبکه‌های عصبی

نتیجه گیری

بارش یکی از مهمترین داده‌های ورودی برای مدل‌ها و الگوریتم‌های مدیریتی در بخش منابع آب به شمار می‌رود. اهمیت پیش‌آگاهی 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 پیش‌یابی 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 مدل‌های سری زمانی با بهترین مدل‌های شبکه عصبی مقایسه شد. بررسی نتایج مربوط به درصد نسبی خطای پیش‌یابی نشان داد که پیش‌یابی بارش با شبکه‌های عصبی بهتر از مدل‌های تصادفی در گستره بلوچستان جنوبی انجام می‌شود که با نتایج دیگر محققان (جهانگیر، ۱۳۸۴، خسروی، شکیبا، ۱۳۸۹) همخوانی دارد. این امر به دلیل پراکندگی زیاد داده‌های بارش ماهانه در منطقه و روند غیر ساده و غیر خطی است که در گستره مطالعاتی حاکم می‌باشد. تاثیر پذیری نامنظم بارش‌های منطقه از جریانات مونسون جنوبی در فصل گرم و از سویی رخداد بارش‌های رگباری با شدت زیاد

و تداوم اندک، مدل‌سازی تصادفی بارش‌های منطقه را با چالش روبرو می‌سازد. بارش‌های سیستان بسیار کم بوده و به طور معمول از مهرماه آغاز و حداکثر تا اردیبهشت ادامه دارد. میانگین کمینه بارش در خرداد ماه $0/2$ میلی‌متر و بیشینه آن در دی ماه $18/9$ میلی‌متر است. ضریب تغییرات سالانه نیز بین 30 تا 163 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. تغییر پذیری درون سالی بالا نشان‌دهنده شرایط اقلیمی خشک می‌باشد. این ضریب از $5/150$ درصد در ایستگاه خاش تا $6/219$ 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 مأخذ

- آشگر طوسی، شادی (۱۳۸۲). پیش‌بینی وقوع خشکسالی در استان خراسان. پایان‌نامه کارشناسی ارشد، دانشگاه فردوسی مشهد، دانشکده کشاورزی، گروه مهندسی آب.
- امیدوار، کمال، نبی‌زاده، معصومه، میثم ثمره، قاسم (۱۳۹۴)، ارزیابی دقیق شبکه عصبی مصنوعی بازگشته نارکس در پیش‌بینی بارش روزانه در استان کرمان. فصلنامه جغرافیای طبیعی، شماره ۲۷، صص ۹۰-۷۳.
- ایلدرمی، علیرضا، زارع ایانه، حمید، بیات و رکشی، مریم (۱۳۹۲)، برآورد بارش به کمک شبکه عصبی مصنوعی با داده‌های هواشناسی غیر بارشی در سه منطقه شیراز، مشهد و کرمان، مجله جغرافیا و برنامه‌ریزی، شماره ۴۳، صص ۴۰-۲۱.
- بابازاده، حسین، شمس نیا، امیر، بوستانی، فردین، نوروزی اقدم، الناز، خدادای دهکردی، داود (۱۳۹۱)، بررسی خشکسالی و ترسالی و پیش‌بینی پارامترهای خشکسالی بارش و درجه حرارت منطقه شیراز با استفاده از روش‌های استوکستیک، مجله جغرافیا و برنامه‌ریزی، شماره ۴۱، صص ۴۷-۲۳.
- بازیزیدی، مطلب، سی و سه مرده، معروف، عصرآگاه، آزیتا (۱۳۹۵)، پیش‌بینی و بررسی روند خشکسالی هواشناسی با استفاده از سری زمانی (مطالعه موردنی: 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.
- حسینعلی زاده، محسن، حسنعلی زاده، نفیسه، بابانژاد، منوچهر، رضا نژاد، محسن (۱۳۹۳)، پیش‌بینی بارش ماهانه با استفاده از بسته‌های تخصصی سری‌های زمانی در محیط نرم افزار R (مطالعه موردنی: ایستگاه اراز کوسه استان گلستان)، نشریه حفاظت و بهره برداری از منابع طبیعی، شماره ۲ صص ۱۲-۱.
- حلیبان، امیرحسین و دارنده، 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 شکیبا، 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، مقدم نیا، علیرضا، آبکار، علیجان، رضایی، معصومه (۱۳۹۴)، مقایسه روش‌های شبکه عصبی مصنوعی و SDSM در ریز مقیاس کردن اندازه بارش سالانه مطالعه موردنی کرمان، راور و رابر، مجله مهندسی منابع آب، شماره ۲۴، صص ۴۰-۲۵.
- شبانکاری مهران، حلیبان امیرحسین (۱۳۹۱)، تحلیل هماید ارتباط بین نوسان بارش روزانه در کرانه‌های جنوبی ایران و تغییرات فشار تراز دریا، فصلنامه تحقیقات جغرافیایی، دوره ۲۷، شماره ۱۰۴، صص ۱۸۴-۱۶۵.

عبدالله نژاد، کامل (۱۳۹۴)، مدل‌های تصادفی سری زمانی در پیش‌بینی بارندگی ماهانه (مطالعه موردی ایستگاه هاشم آباد گرگان)، مجله آمایش جغرافیایی فضای، شماره ۱۷.

- فیضی، وحید، فرج زاده، منوچهر، نوذری، رباب (۱۳۸۹)، مطالعه تغییر اقلیم در استان سیستان و بلوچستان به روش من-کندا، مجموعه مقالات چهارمین کنگره بین‌المللی جغرافیدانان جهان اسلام، ایران- Zahedan.

- کارآموز، محمد، عراقی نژاد، شهاب (۱۳۸۴)، هیدرولوژی پیشرفت، 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 ۸۸-۷۹

- 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 artifitial 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 artifitual neural network model for rainfall forcasting in Bangkok, Tailand. *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), Pattering 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 artifitial 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.
- Mislan, H., Hardwinarto, S. Aipassa, M. (2015), Rainfall monthly prediction based on artifitual neural network: a case study in Tenggarong station, east Kalimantan, Indonesia. International confrence 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 approximattted 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.