



## Performance of Statistical Post Processing Techniques in Improvement of Monthly Precipitation Forecast of MRI-CGCM3 Model over Khorasan-Razavi Province

I. Babaeian<sup>1\*</sup>, M. Karimian<sup>2</sup>, R. Modirian<sup>2</sup>,  
F. Bayatani<sup>3</sup> and E. Fahiminejad<sup>3</sup>

### Abstract

Precipitation forecast in monthly to seasonal time scales is one of the challenges facing the Iran meteorological organization. It is also one of the fundamental needs of water resources management in agriculture, industry and drinking water sectors. In Iran the numerical prediction in monthly time scale is much less practiced than the numerical short term prediction. Despite the need to the short term weather predictions, there is no operational numerical monthly to seasonal forecast model in Iran. Each year the lack of a reliable operational seasonal forecast system causes huge damages to water resources, agriculture and natural resources sectors all over the country. MRI-CGCM3 is the operational dynamical seasonal forecast model which is being used in Japan Meteorological Administration (JMA). In this paper output of MRI-CGCM3 was post processed using three different techniques of multiple regressions (MR), moving average (MA), and artificial neural network (ANN) over three sites of Mashad, Sabzevar, and Torbat-e-heydarieh in north eastern Iran. Post processed monthly precipitations were then compared with Direct Model Output (DMO). It is shown that the performance of monthly forecast has been increased by 6% up to 20% by applying post processing techniques to direct model output. Result confirmed that multiple regressions (MR) techniques have the highest performance in improving the monthly forecast skill over selected stations.

**Keywords:** Numerical prediction, MRI-CGCM3, Post processing, Precipitation, Khorasan Razavi.

Received: March 22, 2016

Accepted: May 11, 2016

## کارآیی روش‌های پس پردازش آماری در بهبود پیش‌بینی ماهانه بارش مدل MRI-CGCM3 در خراسان رضوی

ایمان بابائیان<sup>۱\*</sup>، مریم کریمیان<sup>۲</sup>، راهله مدیریان<sup>۲</sup>،  
فاطمه بیاتانی<sup>۳</sup> و الهام فهیمی نژاد<sup>۳</sup>

### چکیده

پیش‌بینی ماهانه بارش یکی از موضوعات چالشی در حوزه هیدرواکلیم می‌باشد. از آنجا که استفاده عملیاتی از مدل‌های عددی پیش‌بینی ماهانه در کشورمان به اندازه مدل‌های کوتاه مدت نمی‌باشد، لذا تاکنون مدل‌های پیش‌بینی عددی ماهانه در کشورمان عملیاتی نشده‌اند؛ دلیل مهم این مشکل عدم دسترسی به کد مدل‌های دینامیکی جهانی و عدم وجود داده‌های شرایط اولیه برای آغازگری آنها می‌باشد. این وضعیت موجب می‌شود تا هر ساله به دلیل عدم وجود سامانه پیش‌بینی فصلی قابل اعتماد، خسارات سنگینی به بخش‌های منابع آب، کشاورزی و منابع طبیعی کشورمان وارد گردد. به همین دلیل در این تحقیق برونداد مدل پیش‌بینی فصلی دینامیکی MRI-CGCM3 که هم اکنون در سازمان هواشناسی ژاپن برای پیش‌بینی ماهانه متغیرهای هواشناسی استفاده می‌شود، به سه روش رگرسیون چندگانه، میانگین متحرک و شبکه عصبی مصنوعی بر روی ایستگاههای همدیدی مشهد، سبزوار و تربت حیدریه پس‌پردازش شدند. بارش پس‌پردازش شده به روش‌های یادشده با برونداد مستقیم مدل (DMO) مقایسه گردیدند. نتایج نشان می‌دهند که اعمال پس‌پردازش آماری بر روی برونداد مستقیم مدل موجب بهبود پیش‌بینی ماهانه بارش بین ۶ درصد در روش میانگین متحرک تا ۲۰ درصد در روش رگرسیون چند متغیره می‌گردد و کارآیی روش رگرسیون چندگانه به مراتب از دو روش میانگین متحرک و شبکه عصبی بهتر است. بر اساس منحنی ROC، پیش‌بینی‌های در محدوده نرمال تا بیش از نرمال از صحت بیشتری برخوردار می‌باشند.

**کلمات کلیدی:** پیش‌بینی عددی، مدل MRI-CGCM3، پس‌پردازش، بارش، خراسان رضوی.

تاریخ دریافت مقاله: ۹۵/۱/۳

تاریخ پذیرش مقاله: ۹۵/۲/۲۲

1- Assistant Professor, Climate Change Division, Climate Research Institute (CRI), Mashhad, Iran. Email: ibabaeian@yahoo.com

2- Expert in charge of Climate Change Modeling, Climate Change Division, Climate Research Institute (CRI), Mashhad, Iran.

3- PhD Candidate, Hakim Sabzevari University, Sabzevar, Iran.

\*- Corresponding Author

۱- استادیار گروه پژوهشی تغییر اقلیم، پژوهشکده اقلیم‌شناسی، مشهد، ایران.

۲- کارشناس پژوهشی، گروه پژوهشی تغییر اقلیم، پژوهشکده اقلیم‌شناسی، مشهد، ایران.

۳- دانشجوی دکتری اقلیم‌شناسی، دانشگاه حکیم سبزواری، سبزوار، ایران.

\*- نویسنده مسئول

**۱- مقدمه**

(MRI-CGCM3) این داده‌ها را در اختیار کاربران قرار می‌دهند. بنابراین عمدۀ مطالعات در حوزه پس‌پردازش برونداد مدل‌های پیش‌بینی فصلی از روش‌های مبتنی بر داده‌های بلند مدت استفاده می‌کنند. تفاوت عمدۀ در برونداد مدل‌های پیش‌بینی کوتاه مدت و فصلی در قدرت تفکیک آنها می‌باشد، به طوریکه مقیاس نهایی شبکه‌بندی مدل در پیش‌بینی‌های کوتاه مدت به طور معمول کمتر از  $10 \times 10$  درجه جغرافیایی (معادل کمتر از  $10 \times 10$  کیلومتر مربع) بوده، در حالیکه در مدل‌های پیش‌بینی فصلی مقیاس شبکه مدل از حدود  $1 \times 1$  درجه (معادل  $100 \times 100$  کیلومتر مربع) مانند مدل CFSv2 آمریکا تا  $2/5 \times 2/5$  درجه جغرافیایی (معادل  $250 \times 250$  کیلومتر مربع) مانند مدل MRI-CGCM3 ژاپن در تغییر هستند. اخیراً مرکز پیش‌بینی‌های میان‌مدت اروپا<sup>۳</sup> داده‌های با تفکیک‌پذیری  $0/5 \times 0/5$  را با پرداخت هزینه در اختیار کاربران قرار می‌دهد. بنابراین برونداد خام مدل‌های پیش‌بینی فصلی در مقایسه با مدل‌های پیش‌بینی کوتاه مدت دارای تفکیک‌پذیری کمتر و خطای بیشتری بوده و نیازمند پس‌پردازش آماری هستند. پس‌پردازش آماری در مدل‌های پیش‌بینی فصلی نسبت به مدل‌های کوتاه مدت از اهمیت بیشتری برخوردار است. از آنجا که در کشورمان برخلاف پیش‌بینی‌های کوتاه مدت، برای پیش‌بینی ماهانه مدل دینامیکی اجرا نمی‌شود و سازمان هواشناسی کشور برای پیش‌بینی فصلی بارش از برونداد خام مدل‌های مرکز بین‌المللی پیش‌بینی فصلی استفاده می‌کند، لذا طراحی روش پس‌پردازش قابل اعتماد می‌تواند به سازمان هواشناسی کشور و سایر دستگاه‌های مرتبط با مدیریت منابع آب و کشاورزی کمک قابل توجهی برای پیش‌بینی قابل اعتماد آب و هوا و مدیریت منابع آب در ماههای آینده نماید. بر این اساس در این پژوهش از دیدگاه مبتنی بر استفاده از داده‌های طولانی مدت و کوتاه مدت برونداد مدل پیش‌بینی فصلی برای پس‌پردازش بارش استفاده گردید و نتایج مورد مقایسه قرار گرفتند.

**۲- پیکربندی مدل MRI-CGCM3**

مدل MRI-CGCM3 (Yukimoto et al., 2012) از دو مولفه گردش کلی جوی به نام MRI-AGCM3 و گردش کلی اقیانوسی به نام MRI.COM تشکیل شده است که مؤلفه جوی آن با مدل هوایی MASINGAR mk-2 جفت شده است. فاصله زمانی جفت شدن یا تبادل اطلاعات بین مدل جوی و اقیانوسی یک ساعت و در مدل هوایی نیم ساعت می‌باشد. مؤلفه جوی مدل از نوع طیفی می‌باشد که در آن از معادلات هیدروستاتیک بسیط به عنوان پیش‌بایی کننده استفاده می‌شود. از یک طرحواره نیمه ضمیم نیمه

امروزه روش متداول در مراکز بین‌المللی برای پیش‌بینی بارش در مقیاس‌های زمانی ساعت تا فصلی، اجرای از مدل‌های دینامیکی عددی می‌باشد. برونداد مدل‌های یاد شده می‌تواند به عنوان ورودی مدل‌های بارش-رواناب، آلدگی هوا، عملکرد محصول به ترتیب برای پیش‌بینی رواناب، انتشار آلودگی و عملکرد محصول مورد استفاده قرار گیرد. از آنجا که پیش‌بینی مدل‌های عددی در مقیاس شبکه‌های محاسباتی با ابعاد درشت انجام می‌گیرد، لذا لحاظ تمام خواص سطحی مانند نوع خاک، ناهمواری‌ها و پوشش سطحی در مدل امکان‌پذیر نبوده و برونداد آنها بخصوص برای متغیرهای نزدیک سطح زمین مانند بارش، دارای خطاهای زیادی هستند که نیازمند تصحیح و پس‌پردازش آماری می‌باشند. روش‌های گوناگونی برای پس‌پردازش آماری برونداد مدل‌های پیش‌بینی عددی وجود دارند که می‌توان به روش‌های MOS و PPM اشاره کرد که در عمل به داده‌های طولانی مدت برونداد مدل‌های پیش‌بینی عددی نیازمند هستند (Azadi et al., 2011). بایانیان و همکاران (۲۰۱۳) از روش رگرسیون چندگانه خطی برای پس‌پردازش برونداد بارش مدل MRI-CGCM3 به منظور پیش‌بینی ماهانه بارش استفاده کردند. آنها از داده‌های پیش‌بینی تاریخی (پیش‌بینی‌های گذشته‌نگر) برای طراحی معادلات ماهانه پس‌پردازش آماری استفاده کردند. روش یاد شده برای پس‌پردازش بارش فصلی برونداد مدل ژاپن CPTEC (Pezzi and Kayano, 2008) مورد استفاده قرار گرفت که موجب افزایش معنی‌دار کارآیی مدل گردید. فینیتس و همکارانش (۲۰۱۱)، روش مشابهی را برای پس‌پردازش فصلی مدل CGCM3 به کار بردن. برخی روش‌های پس‌پردازش آماری مورد استفاده در پیش‌بینی فصلی نیازمند داده‌های بلند مدت تاریخی برونداد مدل‌های پیش‌بینی عددی نیستند که از جمله این روش‌ها می‌توان به شبکه عصبی (Hasanzadeh et al., 2012; Fathi et al., 2010) Zahraei et al., 2008)، الگوریتم ژنتیک (Gholabi et al., 2014 Rastgu et al., 2009)، پالایه کالمون (Bakhshaii and Stull, 2009 Azadi et al., 2010)، میانگین متحرک (Libonati et al., 2008:2010 Johnson and Swinbank, 2010:McCollor, 2008:2011 Woodcock et al., 2005:Engel, 2005) بهترین برآوردگر ساده (Kay and MacGill, 2010:Durrant et al., 2008:2005) کرد. در پیش‌بینی فصلی دینامیکی مشکل اصلی دسترسی به برونداد طولانی مدت تاریخی مدل‌های دینامیکی نیست و اغلب مراکز بین‌المللی پیش‌بینی فصلی مانند سازمان هواشناسی و اقیانوس‌شناسی آمریکا (مدل CFS v2) و سازمان هواشناسی ژاپن

**رگرسیون چند متغیره خطی:** رگرسیون چند متغیره روشی برای ساختن معادله مدل از سری داده‌های گذشته می‌باشد (Shimizukawa et al., 2009). این روش یکی از قویترین روش‌ها برای تبیین ارتباط بین متغیرهای مدل شده و مشاهداتی به شمار می‌رود. شکل کلی معادله همبستگی چند متغیره به صورت زیر می‌باشد:

$$Y_t = \alpha + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \cdots + \beta_k X_{kt} + \varepsilon_t \quad (1)$$

که در آن  $Y_t$  متغیر وابسته یا پیش‌بینی شونده و  $X_{kt}$  متغیرهای مستقل یا پیش‌بینی کننده‌ها هستند. از آنجا که از تعداد ۲۰ متغیر پیش‌بینی فصلی برای توسعه مدل همبستگی چند متغیره استفاده شده است که تعدادی از آنها ارتباط معنی‌داری با بارش مشاهداتی استگاه‌های هواشناسی استان ندارند، لذا برای حذف متغیرهای بی‌تأثیر از روش حذف پس‌رو استفاده شد. در این روش ابتدا تمامی متغیرهای پیش‌بینی کننده (مستقل) وارد مدل شده و سپس متغیری که دارای همبستگی کمتری بود، حذف گردید. در انتخاب متغیرهای نهایی ضریب تبیین  $R^2$ ، ضریب تبیین متعادل شده  $-Adjust - R^2$  و آماره‌های  $F$  و  $t$  نیز مؤثر می‌باشند.  $R^2$  درصد تغییرات متغیر پیش‌بینی شونده به وسیله متغیرهای پیش‌بینی کننده را توضیح می‌دهد. می‌گیرید که تعداد متغیرهای مستقل افزایش یابند. هر چه تعداد نمونه‌ها افزایش یابند  $R^2$  و  $-Adjust - R^2$  به هم نزدیکتر می‌شوند. مقادیر منفی ضریب تبیین متعادل شده قابل قبول نیستند. با به بکارگیری این روش روابط بین خروجی مدل با داده‌های دیدبانی مربوطه مورد بررسی قرار گرفته و در نهایت معادلات پس پردازش ماهانه بدست می‌آیند. مزیت روش همبستگی چندگانه خطی در این است که با داشتن اطلاعات کمی از فرآیندهای فیزیکی جو، می‌توان ارتباطی بین فراسنج پیش‌بینی شونده محلی و فراسنج‌های پیش‌بینی کننده بزرگ مقیاس برونداد مدل گردش کلی جو برقرار کرد و سپس آنرا برای ریزمقیاس‌نمایی فراسنج محلی مانند بارش مورد استفاده قرار داد (Babaeian et al., 2013).

**میانگین متحرک:** روش میانگین متحرک میتمنی بر میانگین وزنی و فرمول‌های بازگشتی زوج دیدبانی-پیش‌بینی می‌باشد. این روش خطای برونداد مدل را بدون نیاز به داده‌های طولانی مدت کاهش می‌دهد. این روش ستجهایی به نام درجه موازنه جرم  $DMB^*$  را برای اصلاح پیش‌بینی‌های مستقیم مقادیر کمی بارش برونداد مدل پیشنهاد می‌کند (Azadi et al., 2011). درجه موازنه جرم طبق رابطه ۲ بدست می‌آید.

لاگرانژی با دو سطح زمانی برای انتگرالگیری استفاده می‌شود. قدرت تفکیک افقی مدل TL159 (حدود ۱۲۰ کیلومتر) با ۴۸ لایه قائم در سیستم مختصات اتا می‌باشد. منتهی‌الیه سطح فوقانی (TOA) جو منطبق بر سطح فشاری ۰/۰۱ هکتوپاسکال در نظر گرفته شده است که بخش آرام سپهر را به طور کامل پوشش می‌دهد. همرفت قائم چندگانه با ارتفاعات متفاوت، مانند طرحواره AS (Arakawa and Schubert, 1974) به صورت پیوسته بین مقادیر پیشینه و کمینه نرخ توربو‌لانس ( $\lambda_{min}$  و  $\lambda_{max}$ ) در نظر گرفته می‌شود. مولفه اقیانوسی معادلات بسیط را با لحاظ تقریب‌های بوزینسک و هیدروستاتیک حل می‌کند. قدرت تفکیک افقی مدل اقیانوسی ۱ درجه در راستای طول جغرافیایی و ۵/۰ درجه در راستای عرض جغرافیایی می‌باشد. مدل اقیانوسی از ۵۰ لایه قائم به علاوه یک لایه مرزی تعنانی تشکیل شده است. مدل هواویز پنج نوع هواویز شامل سولفات‌های غیر نمک دریا، کربن سیاه، کربن اقیانوسی، نمک دریا و غبارهای معدنی را در نظر می‌گیرد. قدرت تفکیک مدل متغیر است و تفکیک افقی آن در مدل تلفیقی MRI-CGCM3 (معادل ۱۸۰ کیلومتر) و در مدل جوی TL159 (معادل ۱۲۰ کیلومتر) می‌باشد.

### ۳- داده‌ها و روش کار

در این مطالعه از دو سری داده استفاده شده است؛ سری اول داده‌های دیدبانی شده بارش ماهانه سه ایستگاه هواشناسی استان خراسان رضوی شامل مشهد، سبزوار و تربت حیدریه می‌باشد. انتخاب این ایستگاهها به دلیل در دسترس بودن داده‌های بارش دیدبانی بلند مدت (۱۹۸۰-۲۰۰۷) مناسب با داده‌های پیش‌بینی تاریخی مدل می‌باشد. سری دوم داده‌ها، پیش‌بینی‌های گذشته‌نگر (تاریخی) بارش و برخی متغیرهای هواشناسی تاثیرگذار بر آن مانند ارتفاع ژئوپتانسیل، خصامت لایه‌های مختلف، فشار سطح زمین و سایر متغیرهای هواشناسی برونداد مدل می‌باشد. سه روش رگرسیون چند متغیره خطی، میانگین متحرک و شبکه عصبی برای پس پردازش ماهانه بارش استفاده شدند. روش میانگین متحرک برای حذف خطای سامانمند مورد استفاده قرار می‌گیرد، اما روش‌های رگرسیون چند متغیره و شبکه عصبی می‌توانند هر دو نوع خطای سامانمند و تصادفی را اصلاح نمایند. قابلیت پیش‌بینی خطای تصادفی به مراتب مشکل تر از خطای سامانمند می‌باشد. در هر یک از روش‌های گفته شده داده‌های پیش‌بینی و دیدبانی به دو دوره آموزش با طراحی مدل پس پردازش آماری و دوره آزمون تقسیم گردید.

قابل تغییر است. مقدار بیشتر از ۵٪ این شاخص نشان‌دهنده شبیه‌سازی خوب توسط مدل است (Akhavan et al., 2010). مطابق دستورالعمل سازمان جهانی هواشناسی یکی دیگر از روش‌های راستی‌آزمایی پیش‌بینی‌های فصلی استفاده از جدول توافقی برای ارزیابی پیش‌بینی‌های یقینی دو یا چند طبقه‌ای می‌باشد. با استفاده از جدول توافقی می‌توان منحنی و نمره  $ROC$ ، نمایه‌های  $HR$ <sup>۱</sup> (پیش‌بینی صحیح) و  $FAR$ <sup>۲</sup> (پیش‌بینی نادرست) را برای هر طبقه از پیش‌بینی‌ها محاسبه کرد. مساحت زیر منحنی  $ROC$  به عنوان یکی از نمایه‌های ارزیابی پیش‌بینی می‌باشد که هر چه به عدد ۱ نزدیکتر باشد به معنی توانایی بیشتر پیش‌بینی‌ها می‌باشد (WMO, 2006).

#### ۴- نتایج و بحث

بررسی کارآیی پیش‌بینی‌های ماهانه با و بدون پس پردازش به سه روش رگرسیون چند متغیره خطی، میانگین متحرک و شبکه عصبی مصنوعی مورد بررسی قرار گرفت. در ادامه نتایج هر یک از روش‌های مورد اشاره موربد بحث و بررسی قرار می‌گیرد:

**الف-برونداد مستقیم مدل ( $DMO$ ):** در این حالت خروجی خام مدل در شبکه‌های  $2/5 \times 2/5$  درجه بدون هیچ گونه پس پردازشی مستقیماً برای پیش‌بینی بارش ایستگاه‌های منتخب استفاده شد. میانگین سالانه صحت پیش‌بینی‌های ماهانه این روش برای شهر مشهد  $53/9$  درصد می‌باشد که بیشترین صحت در ماه می به میزان درصد  $66/1$  درصد و کمترین صحت مربوط به ماههای سپتامبر و اکتبر با درصد  $41/1$  درصد می‌باشد. نمره  $ROC$  هیچ کدام از ماهها در حد قابل قبول نمی‌باشند. در جدول ۱ نمایه‌های آماری درصد صحت، اربیبی، نمره  $ROC$  و میانگین مربع خطای شهرهای مشهد، سبزوار و تربت حیدریه آورده شده است. صحت پیش‌بینی‌ها در اکثر موارد زیر  $50$  درصد و نمره  $ROC$  در محدوده غیر قابل قبول بوده و مقادیر اربیبی‌ها نیز بسیار بالا می‌باشند؛ به عنوان مثال در ماه جولای که بارش در هیچ یک از شهرهای استان خراسان رضوی به بیش از  $5$  میلیمتر نمی‌رسد، بارش پیش‌بینی شده مدل در حدود  $100$  میلیمتر می‌باشد.

**ب-رگرسیون چند متغیره خطی:** در این روش با  $70$  درصد داده‌های پیش‌بینی تاریخی معادلات رگرسیونی پس پردازش ماهانه تهیه شدند و با  $30$  درصد انتهاهای داده‌های یادشده که دوره  $2007-2003$  میلادی ( $6$  سال) را شامل می‌شود، راستی آزمایی صورت گرفت. نتایج این روش در شهرهای مشهد، سبزوار و تربت حیدریه در جدول ۲ آورده شده است. یافته‌ها نشان می‌دهند که بیشترین صحت

$$DMB_N = \frac{\sum_{k=1}^N x_k^f}{\sum_{k=1}^N y_k^o} \quad (2)$$

که در آن  $DMB_N$  درجه موازنۀ جرم در بازه زمانی  $N$  روز،  $x_k^f$  پیش‌بینی مقدار بارندگی برای روز  $k$  ام و  $y_k^o$  مقدار بارندگی دیدبانی شده در روز متناظر می‌باشد. درجه موازنۀ جرم باید یک دوره زمانی دارای بارندگی را پوشش دهد. پس از محاسبه درجه موازنۀ جرم، پیش‌بینی کمی اصلاح شده بارش از رابطه  $3$  بدست می‌آید که در آن  $QPF_c$  پیش‌بینی تصحیح شده،  $DMO^d$  برونداد مستقیم مدل برای بارش و  $DMB_N$  درجه موازنۀ جرم برای روز  $N$  ام می‌باشد.

$$QPF_c = \frac{DMO}{DMB_N} \quad (3)$$

**شبکه عصبی مصنوعی:** شیوه پردازش شبکه عصبی مصنوعی شبیه مغز انسان است. مهمترین عنصر در پردازش سیستم‌های زیستی، نرون است. هر نرون تعدادی ورودی را از داده‌های اصلی و یا از خروجی نرون‌های دیگر دریافت می‌کند. اتصالاتی که بین نرون‌ها وجود دارد، دارای وزن هستند که این وزن‌ها در هنگام عبور داده‌ها از آن اتصال، در داده عبوری ضرب می‌شوند. شبکه استفاده شده برای پیش‌بینی، شبکه عصبی پیش‌خور چند لایه است که به آن شبکه پرسپترون چند لایه هم می‌گویند (Fathi et al., 2010). برای اینکه شبکه عصبی بتواند پیش‌بینی مدل‌ها را تا حد امکان به مقدار هدف (دیدبانی) نزدیک کند، به آموزش نیاز دارد. آموزش عبارت است از پیدا کردن مناسب‌ترین بردار وزن، کمینه کردن تابع خطای بین داده‌های محاسباتی (خروجی) و داده‌های مشاهداتی (هدف) که عموماً از رابطه میانگین مربع خطایها استفاده می‌شود. یکی از الگوریتم‌های آموزشی، روش انتشار برگشتی است که با بدست آوردن مقدار وزن‌های اصلاح شده در هر مرحله، سبب بهبود نتایج می‌شود. در نهایت بعد از خاتمه آموزش، شبکه برای دادن جواب‌های منطقی به داده‌های جدید توانا می‌شود (Hasanzade et al., 2012). سری داده‌های مربوط به لایه‌های ورودی و خروجی به دو بخش  $70$  درصد و  $30$  درصد به ترتیب برای آموزش و راستی آزمایی تقسیم شدند (Halabian et al., 2012). برای ارزیابی کارآیی مدل از آن دسته از داده‌های پیش‌بینی تاریخی که در فرآیند آموزش مشارکت نداشتند، استفاده شد.

**سنجه‌های ارزیابی پیش‌بینی:** برای مقایسه کارآیی روش‌های مختلف پس پردازش، از نمایه‌های خطای میانگین مربعات، اربیبی، درصد خطای طبقه‌ای بارش و امتیاز مهارتی  $ROC$  استفاده شد. علاوه بر نمایه‌های یاد شده، شاخص‌های میانگین اربیبی ( $MBE$ )، خطای میانگین مربعات ( $RMSE$ ) و شاخص ناش ساتکلیف ( $NS$ ) نیز مورد استفاده قرار گرفتند. شاخص ناش از منفی بی‌نهایت تا یک

مربعات در ماه آوریل رخ داده است. ضرایب ناش ساتکلیف برای شهرهای مشهد، سبزوار و تربت حیدریه در مقیاس‌های ماهانه و سالانه غیر قابل قبول می‌باشد که نشان‌دهنده کارایی ضعیف بر اساس این معیار می‌باشد.

در روش رگرسیون چندگانه بیشترین صحت طبقه‌ای بارش در مشهد با میانگین سالانه  $73/4$  درصد و کمترین آن در سبزوار با  $69/4$  درصد می‌باشد.

پیش‌بینی‌های ماهانه مربوط به ماه سپتامبر و کمترین مقدار مربوط به دسامبر می‌باشد. صحت پیش‌بینی‌های سالانه برای شهرهای مشهد، سبزوار و تربت حیدریه به ترتیب  $73/4$ ،  $69/4$  و  $70/3$  درصد است. علیرغم اینکه اریبی و خطای میانگین مرבעات به مقدار بسیار زیادی بهبود یافته است اما همانند برونداد مستقیم مدل، نمره  $ROC$  در تمامی ماهها در محدوده غیرقابل قبول می‌باشد. بیشترین اریبی به میزان  $91/1$  میلی‌متر هرماه با خطای میانگین مرבעات به میزان  $127/8$  میلی‌متر در ماه می و مربوط به شهر مشهد می‌باشد. در شهرهای سبزوار و تربت حیدریه بیشترین اریبی و خطای میانگین

**جدول ۱- کارآیی مدل MRI-CGCM3 بدون اعمال پس پردازش آماری (برونداد مستقیم)**

سالانه	شاخص آماری											
	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت
۵۳/۹	۶۵/۲	۵۲/۷	۴۱/۱	۴۱/۱	۶۵/۲	۴۷/۳	۵۵/۴	۶۶/۱	۶۱/۶	۵۵/۴	۵۳/۶	۴۴/۶
۴۹/۳	۶۴/۳	۵۰	۴۱/۱	۴۴/۶	۴۵/۵	۵۲/۷	۴۴/۶	۴۸/۲	۵۶/۳	۴۳/۸	۴۷/۳	۵۳/۶
۵۴/۳	۶۴/۳	۵۳/۶	۴۰/۲	۵۲/۷	۶۵/۲	۵۴/۵	۴۳/۸	۶۲/۵	۵۸/۹	۵۶/۳	۵۰/۹	۴۹/۱
-/۵۱	-/۵۵	-/۵۲	-/۵۰	-/۳۴	-/۵۰	-/۵۰	-/۵۰	-/۴۸	-/۴۸	-/۴۹	-/۶۴	-/۵۲
-/۵۱	-/۳۳	-/۲۷	-/۴۵	-/۴۱	-/۴۰	-/۵۰	-/۵۰	-/۶۱	-/۴۹	-/۴۶	-/۵۸	-/۴۲
-/۵۱	-/۵۴	-/۵۰	-/۵۰	-/۵۰	-/۵۰	-/۳۹	-/۶۴	-/۴۳	-/۴۴	-/۶۱	-/۴۴	-/۴۴
۹۲/۷	۹۶/۷	۱۰/۷/۴	۱۰/۰/۳	۱۰/۷/۶	۱۰/۹/۴	۱۱۶/۱	۹۹/۴	۹۵/۸	۸۷/۳	۶۳/۷	۶۴/۱	۶۷/۵
۹۵/۲۴	۹۴/۵۵	۱۰/۸/۵۸	۹۷/۱۸	۱۰/۴/۴۹	۱۰/۷/۲۹	۱۱۳/۳۸	۹۶/۴۸	۱۰/۵/۴۱	۱۰/۰/۲۱	۷۳/۱۹	۷۱/۱۹	۷۰/۴۷
۹۱/۶۰	۸۸/۰/۴	۱۰/۷/۹۸	۱۰/۰/۱۳	۱۰/۶/۱۰	۱۰/۹/۸۶	۱۱۶/۴۵	۹۹/۴۹	۱۰/۵/۸۱	۹۵/۴۹	۶۱/۶۵	۴۹/۹۸	۵۸/۲۲
۹۸/۹	۱۰/۱	۱۱۲/۱	۱۰/۳/۴	۱۰/۷/۴	۱۱۲/۸	۱۱۹/۹	۱۰/۱/۷	۱۰/۱/۴	۹۴/۳	۷۸/۲	۷۵/۴	۷۹
۱۰۰/۹	۹۸/۴	۱۱۲/۶	۱۰/۰/۷	۱۰/۶/۸	۱۱۰/۶	۱۱۷/۱	۹۸/۷	۱۰/۹/۹	۱۰/۴/۵	۸۸/۶	۸۲/۳	۸۰/۶
۹۹/۲	۹۳/۴	۱۱۳	۱۰/۴/۶	۱۰/۸/۳	۱۱۳/۲	۱۲۰	۱۰/۲/۵	۱۱۰/۵	۱۰/۱/۷	۸۰/۴	۶۹/۵	۷۳

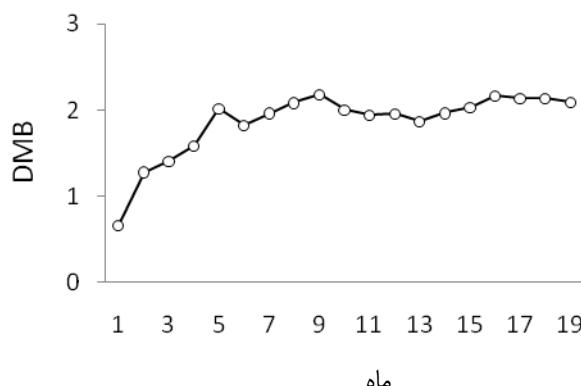
**جدول ۲- کارآیی مدل MRI-CGCM3 بعد از پس پردازش به روش رگرسیون چند متغیره**

سالانه	شاخص آماری											
	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت	مشهد	سبزوار	تربت
۷۳/۴	۶۱/۶	۷۱/۴	۷۸/۶	۸۴/۸	۷۳/۲	۷۸/۶	۷۲/۳	۷۴/۱	۷۵/۹	۶۹/۶	۷۳/۲	۶۷/۹
۶۹/۴	۵۷/۱	۶۴/۳	۷۳/۲	۸۱/۳	۶۵/۲	۷۱/۴	۷۶/۸	۷۵	۶۷/۹	۶۷	۶۷	۶۷
۷۰/۳	۵۷/۱	۷۲/۱	۷۰/۵	۷۹/۵	۶۸/۸	۶۹/۶	۷۵/۹	۶۹/۶	۷۲/۲	۷۱/۴	۶۷	۶۷
-/۴۵	-/۵۰	-/۵۲	-/۴۷	-/۶۳	-/۵۰	-/۵۰	-/۴۷	-/۵۴	-/۴۷	-/۵۲	-/۵۳	-/۴۵
-/۵۱	-/۵۶	-/۵۳	-/۴۸	-/۶۱	-/۴۵	-/۵۰	-/۵۰	-/۶۲	-/۴۹	-/۴۹	-/۴۲	-/۴۸
-/۵۱	-/۴۳	-/۴۶	-/۵۰	-/۴۸	-/۵۰	-/۵۷	-/۵۹	-/۵۵	-/۵۵	-/۵۱	-/۶۲	-/۵۸
۱۳/۵	۳۵/۳	-۱۰/۶	۲/۷	-۲/۶	۰/۹	۵۶/۷	۱/۱	۹۱/۱	۳۶/۳	-۳۰/۹	-۳/۳	-۱۴/۹
۶/۷۲	۳۲/۱۳	-۱۱/۶۵	۳۲/۳۹	۰/۹۳	-۰/۵۳	-۱/۵۰	-۰/۵۳	۱۸/۸۳	۴۴/۰۵	-۶۴۸	-۱۸/۸۳	-۱۲/۱۸
۱۶/۰۶	۵/۴۱	-۳/۲۲	۲۷/۵۷	-۱/۰۱	۱/۸۹	۵۴/۲۶	۱۶/۱۳	۳۷/۳۵	۸۰/۷۱	-۳۷/۷۵	-۳/۰۸	۱۴/۴۹
۳۵/۴	۴۲/۲	۱۴/۴	۱۰/۷	۶/۴	۲/۶	۷۴/۲	۹/۲	۱۲۷/۸	۴۶/۳	۳۹/۳	۲۸/۳	۲۲/۴
۶/۷۲	۴۷/۱	۱۵/۱	۵۳/۷	۱/۸	۱/۷	۵/۶	۵	۴۶/۵	۵۹/۷	۲۹/۷	۲۶/۴	۲۲/۵
۴۸/۶	۳۸/۳	۲۰/۳	۶۱	۳/۲	۳/۲	۶۶	۳۲/۸	۶۸/۳	۱۳۶/۸	۴۷/۹	۷۷/۹	۲۸
-۵۴/۵	-۴/۵	-۰/۸	-۰/۳	-۰/۱	-۰/۶	-۵۹۴	۰/۱	-۲۲/۲	-۱/۵	-۵/۲	-۰/۰۳	-۰/۰۵
-۵/۷	-۵/۱	-۱/۳	-۳۶/۱	۰/۲	-۰/۱	-۰/۰۷	۰/۴	-۱۷/۷	-۸/۸	۰/۱	-۰/۰۳	-۰/۰۲
-۳۲/۹	-۱/۱	-۱/۵	-۲۰/۵	-۰/۰۳	-۳/۰۴	-۳۱۶/۹	-۵/۸	-۱۲/۹	-۲۷/۳	-۲/۶	-۳/۴	-۰/۰۳

نتایج نشان می‌دهد که بیشترین صحت ماهانه در شهرهای مشهد، سبزوار و تربت حیدریه به ترتیب در ماههای می، دسامبر و می با صحت سالانه  $59/2$ ،  $63/2$  و  $60/4$  درصد رخ داده است که حدود  $10\%$  درصد از روش رگرسیون چندگانه کمتر بوده اما حدود  $8\%$  درصد نسبت به برونداد مستقیم مدل بهبود یافته است. نمره  $ROC$  این روش همانند دو روش قبل غیر قابل قبول است. بیشترین مقدار اریبی و خطای میانگین مربعات در ماه فوریه می‌باشد. بیشترین کاهش در اریبی و خطای میانگین مربعات در این روش رخ داده است. ضرایب ناش ساتکلیف برای شهرهای مشهد، سبزوار و تربت حیدریه در مقیاس‌های ماهانه و سالانه همانند روشهای دیگر غیر قابل قبول می‌باشد که نشان‌دهنده کارآبی ضعیف بر اساس این معیار می‌باشد.

**۵-شبکه عصبی مصنوعی:** در این روش ابتدا آموزش شبکه عصبی با استفاده از  $70\%$  درصد داده‌های دیدبانی (دوره  $1980-2002$ ) و پیش‌بینی‌های تاریخی صورت گرفت و راستی آزمایی شبکه عصبی در پیش‌بینی بارش ماهانه ایستگاههای منتخب با  $30\%$  درصد داده‌های باقیمانده (دوره  $2003-2007$ ) انجام شد. صحت سنجی مدل بر مبنای داده‌های پس پردازش شده توسط شبکه عصبی در دوره راستی آزمایی ( $30\%$  درصد داده‌ها) انجام گرفت. در شکل ۲ به عنوان نمونه نمودار پس پردازش در دو مرحله آموزش و راستی آزمایی بر روی ایستگاههای مشهد، سبزوار و تربت حیدریه در ماه دسامبر آورده شده است.

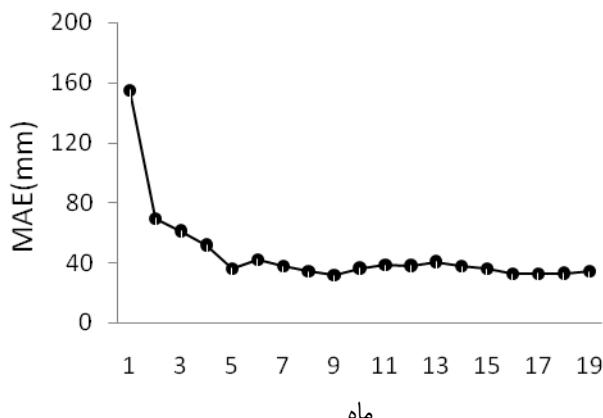
در شکل ۲ ملاحظه می‌شود که کارآبی شبکه عصبی در مدل‌سازی بارش ماهانه ایستگاههای منتخب خراسان رضوی در بخش آموزش بهتر از بخش پیش‌بینی می‌باشد.



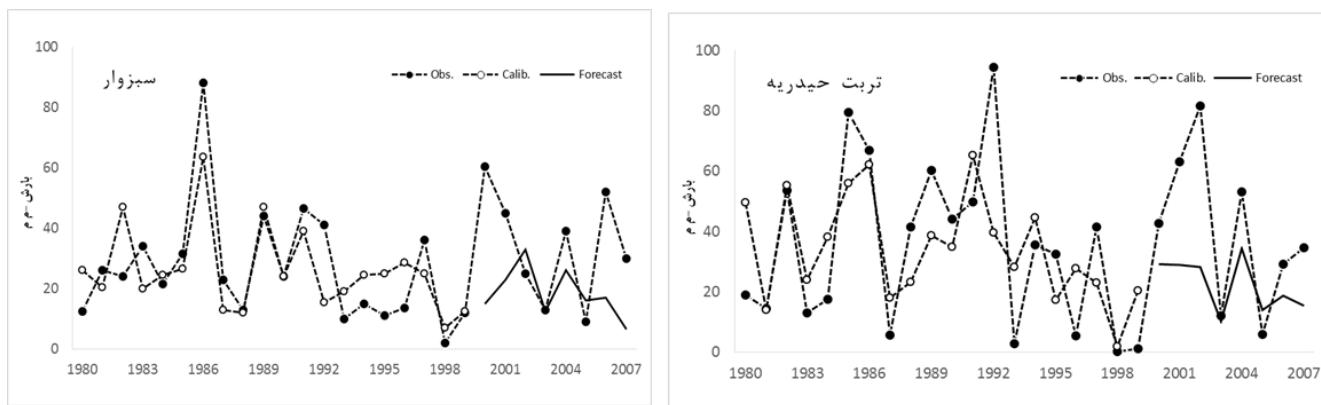
به طور کلی میانگین صحت پیش‌بینی‌های این روش در مجموع سه شهر مورد مطالعه بیش از  $70\%$  درصد می‌باشد. همچنین اریبی و خطای میانگین مربعات حدود  $80\%$  درصد نسبت به برونداد مستقیم (پس پردازش نشده) بهبود یافته است.

همانطور که مشاهده می‌شود این روش دارای بیشترین صحت طبقه‌ای بارش ماهانه به طور میانگین با  $71/0$  درصد را دارا می‌باشد و کارآبی آن نسبت به روش‌های شبکه عصبی، میانگین متحرک و برونداد مستقیم (بدون پس پردازش) به ترتیب  $8/5$ ،  $8/1$  و  $18/5$  درصد بهتر است؛ اما همانند سه روش پیش گفته نمایه  $ROC$  آن در محدوده قابل قبول نیست.

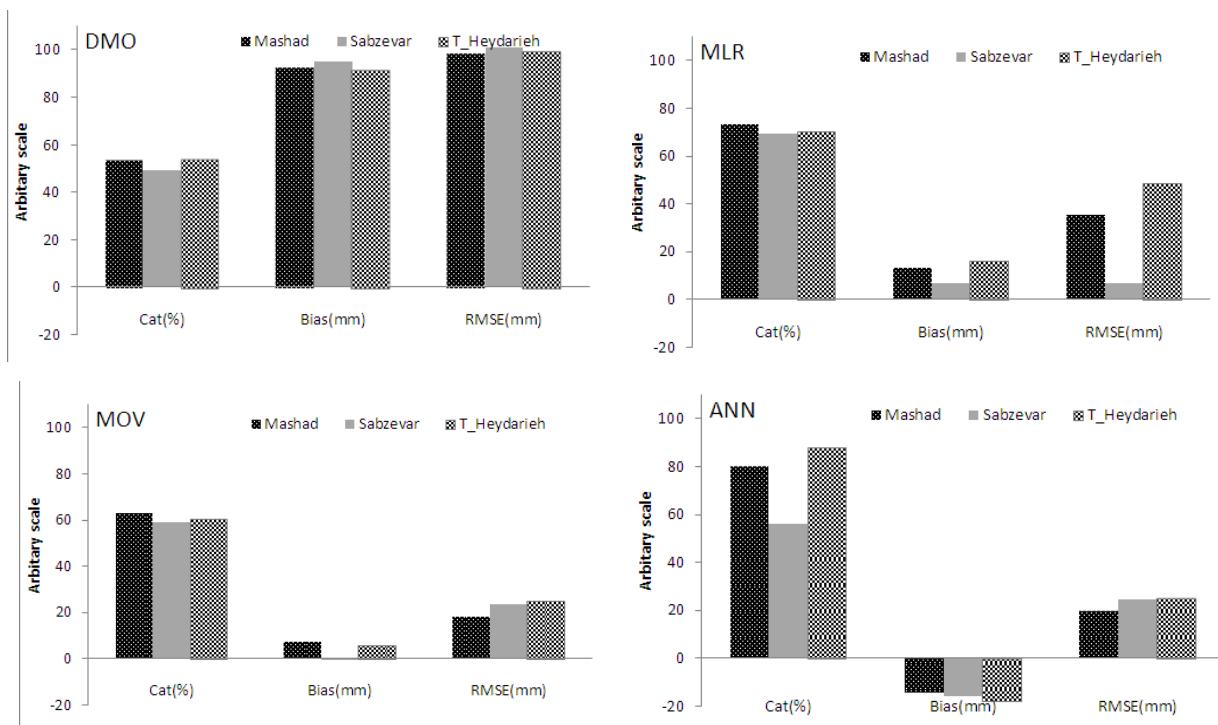
**ج-میانگین متحرک:** در شکل ۱ (چپ) میانگین درجه موازن جرم پیش‌بینی‌های بارش ماه فوریه (به عنوان نمونه) با تغییر پنجره میانگین گیری از  $1$  تا  $19$  ماه برای ایستگاه مشهد به روش میانگین متحرک آورده شده است. نمودار  $DMB$  در پنجره بین ماه نهم تا شانزدهم به مقدار تقریباً ثابتی رسیده و موازن جرم را به مقدار  $29$  درصد بهبود بخثیده است. در شکل (راست) میانگین خطای مطلق نیز در پنجره یاد شده از حدود  $160$  میلیمتر به کمتر از  $40$  میلیمتر رسیده است که معادل  $78\%$  درصد بهبود در میانگین خطای مطلق می‌باشد. در جدول ۳ نمایه‌های آماری کارآبی مدل در پیش‌بینی ماهانه بارش پس از اعمال پس پردازش آماری به روش میانگین متحرک در سه ایستگاه مشهد، سبزوار و تربت حیدریه آورده شده است. محاسبات مشابه برای تمامی ماههای سال در هر سه ایستگاه مورد مطالعه انجام گردید که برای پرهیز از ارائه نموارهای تکراری، از آوردن آنها صرفنظر شده است.



شکل ۱- میانگین درجه موازن جرم (چپ) و خطای مطلق (راست) برای بارش ماه فوریه مشهد



شکل ۲-پیش‌بینی بارش ماه دسامبر مدل MRI-CGCM3 پس از پس پردازش به روش شبکه عصبی



شکل ۳-کارآیی پس پردازش به روش‌های رگرسیون (MLR)، میانگین متحرک (MOV) و شبکه عصبی مصنوعی (ANN)

همانطور که ملاحظه می‌شود، ضرایب ناش-ساتکلیف پیش‌بینی‌های فصلی در تمامی روش‌های مورد استفاده قابل قبول نیستند؛ دلیل این موضوع می‌تواند ناشی از تفاوت دیدگاه‌های بین پیش‌بینی کوتاه مدت چند روزه و پیش‌بینی‌های فصلی باشد. در حالی که در پیش‌بینی‌های کوتاه مدت چند روزه، هدف پیش‌بینی مقادیر کمی بارش برای چند روز آینده می‌باشد اما در پیش‌بینی‌های بلند مدت هدف پیش‌بینی موقعیت بارش نسبت به میانگین بلندمدت است و اینکه مقدار پیش‌بینی شده در کدامیک از طبقات زیرنرمال، نرمال یا پیش از نرمال قرار خواهد گرفت (WMO, 2006).

در مجموع بیشترین صحت پیش‌بینی ماهانه با ۶۵ درصد مربوط به شهر مشهد می‌باشد؛ در شهرهای تربت حیدریه و سبزوار صحت پیش‌بینی‌ها به ترتیب  $58/9$  و  $57/8$  درصد می‌باشد. میانگین اریبی سالانه در هر سه ایستگاه کمتر از ۱۰ میلیمتر و خطای میانگین مربعات حدود ۲۰ میلیمتر می‌باشد. ضرایب ناش ساتکلیف محاسبه شده برای شهرهای مشهد، سبزوار و تربت حیدریه در مقیاس‌های ماهانه و سالانه غیر قابل قبول می‌باشد که نشان‌دهنده کارایی ضعیف بر اساس این معیار می‌باشد.

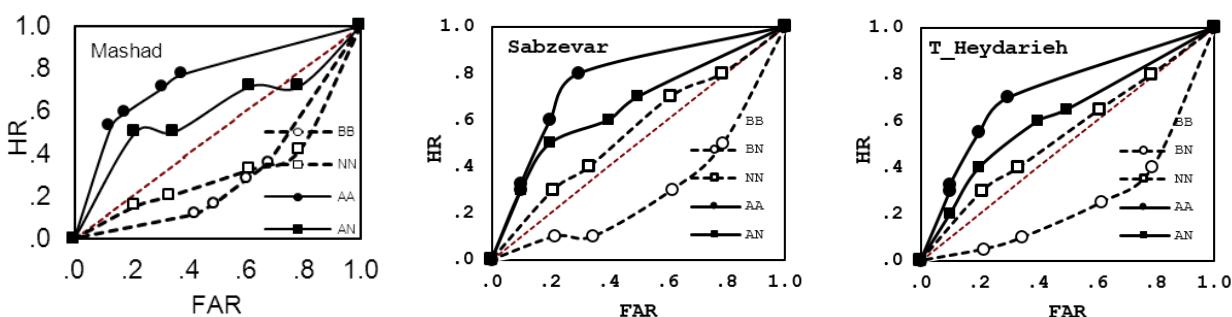
$ROC > 0.5$  پیش‌بینی‌های مدل با مقادیر دیدبانی شده هماهنگ بوده و می‌توانند قابل قبول باشند. در شکل ملاحظه می‌شود که منحنی‌های  $ROC$  در پیش‌بینی‌های بیش از نرمال و نرمال تا بیش از نرمال بالای خط یک به یک  $ROC = 0.5$  قرار دارند؛ این در حالی است که منحنی‌های مربوط به پیش‌بینی‌های کمتر از نرمال زیر خط یک به یک قرار گرفته‌اند. در شکل یاد شده محور قائم پیش‌بینی‌های درست و محور افقی پیش‌بینی‌های نادرست می‌باشند.

## ۵- جمع‌بندی

کشورمان بیش از یک دهه با خشکسالی و سایر رخدادهای فرین اقلیمی درگیر می‌باشد که خسارت‌ها و پیامدهای زیانباری در بخش‌های کشاورزی، منابع آب، بهداشت و سایر بخش‌های اقتصادی و اجتماعی کشور را در پی داشته است. آگاهی گروдарان از پیش‌بینی ماهانه بارش و موقع خشکسالی احتمالی می‌تواند از طریق اتخاذ روش‌های سازگاری مناسب، خسارات خشکسالی را کاهش داده و مقاومت اقتصاد کشور را در برابر خشکسالی افزایش دهد. برخلاف پیش‌بینی‌های کوتاه مدت که دانش فنی آن به مقدار نسبتاً زیادی در کشورمان وجود داشته و هر روزه در مراکز پیش‌بینی هواشناسی استان‌ها مدل‌های دینامیکی عددی برای صدور پیش‌بینی‌های کمتر از یک هفته آینده اجرا می‌شوند، اما تاکنون مدل عددی دینامیکی عملیاتی برای پیش‌بینی ماهانه در کشورمان وجود نداشته و ارائه پیش‌بینی ماهانه در کشور وابسته به دریافت داده‌های خام آنها از مراکز بین‌المللی می‌باشد. از آنجا که پس پردازش آماری نیاز اساسی در بهبود پیش‌بینی ماهانه و یکی از حلقه‌های اصلی در تکمیل دانش پیش‌بینی ماهانه دینامیکی می‌باشد، لذا در این مطالعه از سه روش پس پردازش آماری شامل شبکه عصبی مصنوعی، میانگین متحرک و رگرسیون خطی چندگانه برای کاهش خطای پیش‌بینی خام مدل MRI-CGCM3 مرکز اقلیم توکیو استفاده شد.

به منظور مقایسه کارآیی سه روش پس پردازش مورد استفاده، نمودار ستونی نمایه‌های آماری درصد صحت، اریبی و خطای میانگین مربعات در شکل ۳ آورده شده است. با توجه به وجود اریبی‌های ماهانه حدود ۱۰۰ میلیمتر-حتی در ماههای تابستان- در برونداد مستقیم مدل، لذا استفاده از پس پردازش آماری کاملاً ضروری می‌باشد. همانطور که در شکل ۳ ملاحظه می‌شود پس پردازش آماری به هر یک از سه روش به کاربرده شده در این تحقیق به مقدار قابل ملاحظه‌ای موجب کاهش اریبی و خطای میانگین مربعات گردیده است. تقریباً توانایی هر سه روش در کاهش اریبی و خطای میانگین مربعات با هم مساوی هستند؛ اما تفاوت قابل توجهی بین صحت طبقه‌ای پیش‌بینی بارش ماهانه به روش رگرسیون چند متغیره با سایر روش‌ها دیده می‌شود. این روش توانسته است صحت پیش‌بینی‌ها را به مقدار حداقل ۱۱ درصد نسبت به سایر روش‌ها بهبود دهد. میزان بهبود پیش‌بینی ماهانه بارش در این روش نسبت به برونداد خام مدل ( $DMO$ ) حدود ۲۳ درصد می‌باشد.

در بررسی نتایج هر یک از روش‌های پس پردازش ملاحظه شد که نمایه  $ROC$  در هیچ یک از روش‌های استفاده شده در محدوده قابل قبولی نمی‌باشد؛ لذا کارآیی روش‌های مختلف با جزئیات بیشتر و در طبقات بارشی گوناگون مورد بررسی قرار گرفت. یافته‌ها نشان می‌دهند که بیشترین کارآیی مدل MRI-CGCM3 در پیش‌بینی ماهانه بارش هنگامی رخ می‌دهد که بارش در محدوده نرمال تا بیش از نرمال پیش‌بینی شده باشد؛ کارآیی این مدل در هنگامی که بارش کمتر از نرمال باشد، کم بوده و در مواردی قابل قبول نمی‌باشد. این موضوع در نمودارهای  $ROC$  که به عنوان نمونه برای ماه دسامبر و برای روش رگرسیون چند متغیره (بهترین روش) ترسیم شده است به وضوح قابل رویت می‌باشد (شکل ۴). در شکل ۴، خط یک به یک قطری با مقدار  $ROC = 0.5$  حالتی را نشان می‌دهد که پیش‌بینی مدل با پیش‌بینی احتمالاتی دوره آماری برابر است. در حالت  $ROC < 0.5$  پیش‌بینی مدل قابل قبول نیست؛ اما در حالت



شکل ۴- منحنی  $ROC$  پیش‌بینی بارش پس از اعمال پس پردازش به روش رگرسیون چند متغیره

تحقیقات منابع آب ایران، سال دوازدهم، شماره ۲، تابستان ۱۳۹۵

Volume 12, No. 2, Summer 2016 (IR-WRR)

### جدول ۳- کارآیی روش‌های مختلف پس پردازش بارش مدل MRI-CGCM3 (درصد)

شهر	برونداد مستقیم مدل	رگرسیون چند متغیره	میانگین متحرک	شیکه عصی
مشهد	۵۳.۹	۷۳.۴	۶۳.۲	۶۵
سبزوار	۴۹/۳	۶۹/۴	۵۹	۵۷/۸
تربت حیدریه	۵۴/۳	۷۰/۴	۶۰/۴	۵۸/۹

8- Root Mean Square Error (RMSE)

9- Nash-Sutcliffe

10- Hit Rate

11- False Alarm Rate

12- European Center for Medium-range Weather Forecast (ECMWF)

13- Climate Forecast System

### - مراجع

Akhavan S, Abedi J, Mousavi F, Abaspoor K, Afyon M, Eslamian S (2010) Estimation of blue and green water using SWAT in Hamedan sub-basin. Journal of Water and Soil Science Article#53 (In Persian)

Arakawa A, Schubert WH (1974) Interaction of a cumulus cloud ensemble with the large scale environment. Part I of Journal Atmospheric Science 31:674–701

Azadi M, Shirgholami M, Hojam S, Sahraeian F (2011) Post processing WRF model output for daily precipitation in Iran. Iran-Water Resources Research 7(4):71-80 (In Persian)

Amiri F, Charmi M, Enayt L (2011) Evaluation ORYZA 2000 model in scarcity of irrigation and nitrogen fertilizer (calibration and validation). Journal of Water and Soil 25(4):757-769 (In Persian)

Babaeian I, Karimian M, Modirian R (2013) Statistical post processing MRI-CGCM3 output for seasonal precipitation forecast over Khorasan-Razavi province. Iranian Journal of Geophysics 7(3):119-133 (In Persian).

Bakhshaii A, Stull R (2009) Deterministic ensemble forecasts using gene expression Programming. Weather and Forecasting 24:1431-1451 (In Persian)

Durrant T H, Woodcock F, Greenslade D J M (2008) Consensus forecast of modeled wave parameters. Australia Bureau of Meteorology Technical Note 16

Engel C (2005) Hourly operational consensus forecasts (OCF). BMRC Research Report 115:107

Fathi Margh A, Mahdeian MH (2010) Predicting winter precipitation using indicators beyond the neural

جدول ۳ جمع‌بندی نتایج هر یک از روش‌های مختلف پس پردازش را نشان می‌دهد. مطابق جدول یاد شده صحت پیش‌بینی مدل با اعمال فرآیند پس پردازش بین حدود ۶ درصد در روش میانگین متحرک تا حدود ۲۰ درصد در روش رگرسیون چند متغیره نسبت به برونداد مستقیم بهبود یافت. توانایی روش رگرسیون چندگانه در بهبود پیش‌بینی ماهانه بارش مدل MRI-CGCM3 با یافته‌های مصطفوی و همکاران (Mostafaviet al., 2015) و بابائیان و همکاران (Babaeian et al., 2013) هماهنگی دارد.

کارآیی پس پردازش آماری در طبقات مختلف بارشی در پنج طبقه کمتر از نرمال، کمتر از نرمال تا نرمال، نرمال تا بیش از نرمال و بیش از نرمال با ترسیم منحنی ROC نشان می‌دهد در شرایطی که پیش‌بینی‌ها در محدوده نرمال تا بیش از نرمال باشد دارای صحت بیشتری می‌باشند؛ به عبارت دیگر اعتمادپذیری به پیش‌بینی‌های مدل MRI-CGCM3 در دوره‌های ترسالی بیشتر از دوره‌های خشکسالی است. با توجه به نیاز میرم طیف وسیعی از کاربران از جمله بخش‌های کشاورزی، آب و حوادث غیرمتوقبه به پیش‌بینی‌های ماهانه قابل اعتماد، پیشنهاد می‌شود به منظور ارتقاء صحت پیش‌بینی‌های ماهانه سازمان هواشناسی کشور از برونداد سایر مدل‌های دینامیکی پیش‌بینی فصلی معتبر جهانی مانند CFS<sup>۱۳</sup> (مرکز پیش‌بینی‌های میان‌مدت اروپا) و ECMWF<sup>۱۴</sup> (سازمان هواشناسی و اقیانوس‌شناسی آمریکا) استفاده شود و نسبت به عملیاتی شدن مدل پیش‌بینی ماهانه دینامیکی در کشور اقدام شود تا کشورمان در تهییه داده‌های شرایط مرزی مورد نیاز پیش‌بینی‌های روزانه و فصلی خودکفا شود.

### پی نوشت‌ها

- 1- Model Output Statistics(MOS)
- 2- Perfect Prognosis Method(PPM)
- 3- Top of Atmosphere (TOA)
- 4- Degree of Mass Balance(DMB)
- 5- Direct Model Output (DMO)
- 6- Relative Operating Characteristics
- 7- Mean Bias Error (MBE)

- barley yields: a case study for Isfahan, Iran. International Journal of Ayer 2:451-469 (In Persian)
- Pezzi L P, Kayano M T (2008) An analysis of the seasonal precipitation forecasts in South America using wavelets. International Journal of Climatology 29:1560-1573
- Rastg Z, Azadi M, Hojam S (2010) Post processing WRF model output for level 10-m wind velocity and level 2-m temperature by using Palayeh nonlinear Kalman. Journal of Climate Research 1(3 and 4):93-106 (In Persian)
- Shimizukawa J, Chen C Y, Iba K (2009) Multi-regression model for peak load forecast in demand side like university campus. In: Proc. of the International Conference on Electrical Engineering, 5-9 July, China
- WMO (2006) Standardized verification system (SVS) for long-range forecasts (LRF), new attachment to manual of GDPFS (WMO-No. 485). Vol.1, Final Report of the Joint Expert Teams on Long-Range Forecasting, ECMWF, April 2006
- Woodcock F, Engel C (2005) Hourly operational consensus forecasts (OCF). Weather Forecasting 20:101-111
- Yukimoto S, Adachi Y, Hosaka M, Sakami T, Yoshimura H, Hirabara M, Tanaka TY, Shindo E, Tsujino H, Deushi M, Mizuta R, Yabu S, Obata A, Nakano H, Koshiro T, Ose T, Kitoh A (2012) A new global climate model of the meteorological research Institute: MRI-CGCM3-Model description and basic performance. Journal of the Meteorological Society of Japan 90:23-64
- Zahraei B, Roozbani A (2008) Clustering meteorological signal due to changes in precipitation (Case Study: rainfall prediction of Sistan va Baluchestan province. Iranian Journal of Watershed Management Science and Engineering 1(2):20-29 (In Persian)
- network method in Urmia Lake. Watershed Management Research 85:42-52 (In Persian)
- Finnis J, Hsieh W W, Lin H, Merryfiled W (2011) Nonlinear post-processing of numerical seasonal climate forecast. Journal of Atmosphere-Ocean 26:1-34
- Gholabi M, Akhond A, Radmanesh F (2014) Comparing the performance of different algorithms in neural network modeling case study seasonal rainfall selected stations in Khuzestan province. Scientific Journal of Management System 13(30):151-169 (In Persian)
- Halabian A, Darand M (2012) Precipitation forecast over Isfahan using neural networks. Journal of Applied Researches in Geographical Science 12(26):47-63 (In Persian)
- Hasanzadeh Y, Abdi Kordani A, Fakherifard A (2012) Forecasting drought by using Genetic Algorithm and wavelet-neural network hybrid model. Journal of Water & Wastewater 3:48-59 (In Persian)
- Johnson C, Swinbank R (2009) Medium-range multi-model ensemble combination and calibration. UK met-office Technical Note 517:31
- Kay M, MacGill I (2010) Improving weather forecasts for wind energy applications. In: Proc. of 17th National Conference of the Australian Meteorological and Oceanographic Society, 27-29 January, Canberra
- Libonati R, Trigo I, DaCamara C (2008) Correction of 2-m temperature forecasts using Kalman filtering technique. Atmospheric Research 87:183-197
- McCollor D, Stull R (2008) Hydrological accuracy enhancement via post processing of numerical weather forecasts in complex terrain. Weather and Forecasting 23:131-144
- Mostafavi Darani S M, Koshhal Dastjerdi J, Stone R, Babaeian I, Abbasi F (2015) Linkage a general circulation model with a crop model to forecast