

تحلیل روش پس پردازش خروجی مدل‌های دینامیکی با استفاده از داده‌های شبکه بر روی خشکسالی شمال غرب ایران

سینا صمدی نقاب^{۱*}، بهروز ساری صراف^۲، علی اکبر رسولی^۳، مجید حبیبی نوخندان^۴، شراره ملبوسی^۵

۱. مدیر گروه پژوهشی اقلیم‌شناسی بلایای جوی، پژوهشکده اقلیم‌شناسی، مشهد، ایران

۲. مدیر گروه آب و هواشناسی، دانشگاه تبریز، تبریز، ایران

۳. استاد گروه آب و هواشناسی، دانشگاه تبریز، تبریز، ایران

۴. رئیس پژوهشکده اقلیم‌شناسی، مشهد، ایران

۵. کارشناس پژوهشی پژوهشکده اقلیم‌شناسی، مشهد، ایران

چکیده

از دیرباز پیش‌بینی وضعیت بارش و بررسی ناهنجاری خشکسالی در حوضه‌های آبریز شمال غرب کشور ایران به دلیل حساسیتی که دریاچه ارومیه نسبت به میزان آبدهی حوضه‌های مربوطه دارد یکی از مهمترین چالش‌ها در مدیریت بهینه منابع آبی بوده است و مدیریت سرمایه‌های عظیم منابع آبی و تولید انرژی کشور در منطقه مذکور به شدت متأثر از این عوامل است. بنابراین با توجه به نوسانات پارامترهای اقلیمی و وقوع رفتارهای غیرمتعادل در الگوی بارش کشور، استفاده از روش‌های دینامیکی می‌تواند کمک بسیاری را در تبیین این شرایط ایجاد نماید. در این تحقیق، بدلیل توزیع نامناسب داده‌های دیده‌بانی شده، ابتدا با استفاده از داده‌های بارش شبکه آفرودیت ۱ و بکارگیری روش‌های پس‌پردازش MOS_2 بر روی خروجی مدل پیش‌بینی دینامیکی $MRI-CGCM3$ در یک دوره ۲۸ ساله (۲۰۰۷-۱۹۸۰ میلادی)، بارش شبکه‌ای مدل پس‌پردازش شده و با وزن دهی متغیرهای اقلیمی خروجی مدل دینامیکی برای هر سلول شبکه داده و با تعیین ضرایب مدل آماری همبستگی چند متغیره، عمل پس‌پردازش کامل گردید و خطاهای سیستماتیک خروجی مدل جهت استفاده در مقیاس‌های کوچک تا حدود زیادی کاهش یافت. سپس داده‌های پیش‌بینی پس‌پردازش شده مدل دینامیکی، جهت محاسبه شاخص خشکسالی (SPI) در راستای ارائه پیش‌آگاهی خشکسالی استفاده گردید و توانمندی روش پس‌پردازش انتخاب شده با استفاده از شاخص‌های ارزیابی مورد سنجش قرار گرفت. نتایج نشان داد که اعمال پس‌پردازش آماری بر روی خروجی مستقیم مدل دینامیکی موجب بهبود پیش‌بینی ماهانه بارش تا میزان ۲۹ درصد در روش پس‌پردازش انتخابی می‌شود. صحت پیش‌بینی شاخص خشکسالی SPI می‌تواند به مقدار ۲۲،۳ ۲۲،۳ درصد نسبت به حالت بدون پس‌پردازش افزایش یافته به طوری که این میزان بعد از اجرای پس‌پردازش به ۷۹/۵ درصد رسید.

کلید واژه‌ها: پس‌پردازش، خشکسالی، مدل‌های دینامیک، پیش‌بینی فصلی

1. Aphrodite
2. Model Output Statistics

مقدمه

مدلهای دینامیکی عددی می باشد. خروجی مدل های یاد شده می تواند به عنوان ورودی سایر مدل های کاربردی مورد استفاده قرار گیرد. هدف از پیش بینی شرایط اقلیمی به روش دینامیکی، پیش بینی آینده وضعیت متغیرهای اقلیمی با توجه به اطلاعات و شرایط فعلی آن و استفاده از تقریب های عددی برای معادلات دینامیکی است. در روش دینامیکی ابتدا پیش بینی با استفاده از مدل گردش عمومی تهیه می شود و سپس توسط یک مدل منطقه ای بر روی منطقه مورد نظر ریزمقیاس نمایی دینامیکی می گردد. مدل های گردش عمومی (GCM) سیستم اقلیم را با پیچیدگی بیشتری شبیه سازی می کنند. بخش دینامیک شامل طرحواره های عددی است که انتقالات جوی کلان مقیاس را محاسبه می کنند. این انتقالات یا در یک فضای فیزیکی یا یک فضای طیفی محاسبه می شوند.

امروزه خروجی این مدل ها توسط مراکز بین المللی پیش بینی فصلی در اختیار کاربران قرار می گیرد. با توجه به مقیاس نسبتا بزرگ خروجی این مدل ها که از حدود $1/1 \times 1/1$ درجه جغرافیایی تا $2/5 \times 2/5$ درجه جغرافیایی را در بر می گیرد که این امر سبب تفکیک پذیری کمتر و خطای بیشتر در استفاده مستقیم از خروجی این مدل ها می شود و لذا برون داد آنها بخصوص برای متغیرهای نزدیک سطح زمین مانند بارش، دارای خطا بوده که نیازمند تصحیح و پس پردازش آماری است. روش های گوناگونی برای پس پردازش آماری برون داد مدل های پیش بینی عددی وجود دارند که می توان از آن جمله به روش MOS^1 اشاره کرد. اینکه هر پارامتری از خروجی مدل دارای چه اثر و ضریب همبستگی با شرایط اقلیمی منطقه مورد مطالعه است خود نیازمند بکار بردن تکنیک ها و شرایط خاص می باشد (Azadi et al., 2011). یکی دیگر از مشکلات در استفاده از روش های پس پردازش، عدم توزیع مکانی و زمانی داده های دیده بانی شده جهت استفاده در پس پردازش خروجی مدل های دینامیکی می باشد. در این خصوص استفاده از داده های آفرودیت به میزان بسیار زیادی می تواند خطای محاسبات را کاهش داده و توزیع مناسبی از زمان و مکان را در مقوله پس پردازش لحاظ نماید (Yatagai A., et al., 2012). روش های گوناگونی

خشکسالی بعنوان یک پارامتر اساسی در مباحث توسعه پایدار همیشه مد نظر بوده است و بعنوان یکی از شاخص ترین ناهنجاریهای اقلیمی چه در مقیاس زمانی کوتاه و چه درازمدت همیشه مطرح می باشد. با توجه به اینکه خشکسالی یکی از بلاایای طبیعی شاخص در ایران محسوب می شود و در چند سال اخیر بخش های مختلفی از کشور تحت تاثیر این بلیه بوده است، لذا ارزیابی، پایش و پیش آگاهی آن از اهمیت ویژه ای برخوردار است. یکی از روش های کمی کردن ناهنجاری خشکسالی استفاده از شاخص های خشکسالی است که می توان به کمک آنها شدت و وسعت خشکسالی را به طور دوره ای ارزیابی کرد. تاکنون از این شاخص ها جهت پایش خشکسالی استفاده می شده است ولیکن میتوان با بکارگیری خروجی پیش بینی های فصلی، این نمایه ها را نیز پیش بینی کرد. پیش بینی های فصلی، اطلاعاتی را در ارتباط با میانگین های بلندمدت ارایه می دهد. خصوصیات سطح زمین، به خصوص نوسان های آرام دمای رویه اقیانوس ها، می توانند بر وضعیت هوای زمین تاثیر بگذارند. این اثرات در مقیاس زمانی روز به روز قابل رویت نیستند، اما اثرات آن در مقیاس زمانی بزرگتر از ماه و در میانگین های فصلی قابل مشاهده هستند.

در این زمینه مطالعات نسبتا متعددی در داخل و خارج از کشور انجام شده است، اما غالب مطالعات با استفاده از داده های دیده بانی هیدرواقلیمی و یا شاخص های اقلیمی مانند ENSO¹ و NAO² و برقراری ارتباط بین بارش و سیگنال های بزرگ مقیاس اقلیمی بوده اند و بندرت از روش های دینامیکی در پیش بینی بارش استفاده شده است. بنابراین با توجه به تغییرات اقلیمی سال های اخیر و وقوع رفتارهای نامتعارف در الگوی بارش اکثر نقاط کشور، استفاده از روش های دینامیکی دارای مزیت های زیادی نسبت به روش های آماری که صرفا بر پایه رفتار های دوره آماری می باشند، خواهد داشت.

امروزه روش متداول در مراکز بین المللی برای پیش بینی بارش در مقیاس های زمانی ساعتی تا فصلی، استفاده از

2. North Atlantic Oscillation

1. El-Nino Southern Oscillation

همبستگی ماهانه دما از ۰/۴۲ به ۰/۶۵ و بارش از ۰/۳۷ به ۰/۶۳ تغییر می‌کند. ضرایب تصحیح برای دما نیز بین ۱۸ تا ۴۲ درصد و بارش بین ۱۴ تا ۳۹ درصد می‌باشد (Kim et al., 2012b). در پژوهشی لیم و همکاران (۲۰۰۹) بارش فصلی پیش‌بینی شده (NCEP/CFS) را با قدرت تفکیک ۲/۵ درجه به مقیاس فضایی ۲۰ کیلومتر بر روی جنوب شرقی ایالات متحده، شامل فلوریدا، جورجیا و آلاباما به کمک مدل CSEOF که بر پایه ریزمقیاس نمائی آماری است، ریزگردانی کردند (Lim et al., 2009). جفری و همکاران (۲۰۰۵) ثابت کردند که استفاده از تکنیک MOS (کاربرد روشهای آماری بر روی خروجی مدل‌های دینامیکی) باعث بهبود پیش‌بینی‌های دو هفته‌ای خواهد شد. آنها این روش را بر روی مدل‌های جهانی NCEP و ECMWF بکار بردند. کاربرد تکنیک MOS بر روی دو مدل نتایج پیش‌بینی‌ها را بیشتر از کاربرد این تکنیک MOS بر روی یک مدل بهبود می‌بخشد (Jeffrey, S., et al., 2005). کریشنامورتی و همکاران در سال ۲۰۰۰ در ارتباط با پیش‌بینی فصلی و اقلیمی با استفاده از بکارگیری پیش‌بینی چندگانه تصحیحی مطالعاتی را انجام دادند. در این تحقیق مهارت پیش‌بینی‌های مدل‌های چندگانه بررسی شد و سپس نتایج با تمام مدل‌ها به صورت مجزا مقایسه گردید. در نهایت با استفاده از رگرسیون چند متغیره خطی وزن آماری هر مدل تعیین شد. آنها نتیجه گرفتند که پیش‌بینی از مدل چندگانه نسبت به مدل‌های تک‌گانه عملکرد بهتری دارد. نتایج نشان داد که استفاده از روش آماری در پس‌پردازش پیش‌بینی‌های چندمدله می‌تواند سیستم پیش‌بینی‌های چندگانه مدل‌های مجزا را بهبود بخشد (Krishnamurti, T. K., et al., 2000).

پاره‌ای از روش‌های پس‌پردازش آماری نیازمند داده‌های بلندمدت خروجی مدل نمی‌باشند که از آن جمله می‌توان به روش استفاده از شبکه عصبی (Fathi et al. 2010, Hasanzadeh et al. 2012) و یا روش الگوریتم ژنتیکی (Kishtawal C.M., 2003) و یا روش پالایه کالمن (Rastgu et al. 2010,) و روش میانگین متحرک (Azadi, et al. 2011, McCollor 2008, Johnson and)

در پس‌پردازش خروجی مدل‌های دینامیکی استفاده گردیده است، بعنوان مثال بابائیان و همکاران (۲۰۱۳) از روش رگرسیون چندگانه خطی برای پس‌پردازش برون‌داد بارش مدل MRI-CGCM3 به منظور پیش‌بینی ماهانه بارش استفاده کردند. آنها داده‌های پیش‌بینی تاریخی (پیش‌بینی‌های گذشته‌نگر) را برای طراحی معادلات ماهانه پس‌پردازش آماری بکار بردند (Babaeian I., et al., 2013). در مطالعه دیگری کیم و همکاران (۲۰۱۲) پیش‌بینی فصل زمستان را در نیمکره شمالی با استفاده از سیستم‌های پیش‌بینی فصلی که اخیراً به کمک ECMWF و NCEP به روز شده‌اند، از طریق بازنگری پیش‌بینی‌های دوره (۲۰۱۰-۱۹۸۲) سیستم‌های پیش‌بینی اقلیمی فصلی جفت شده جو-اقیانوس و به کمک داده‌های ECMWF System 4 (Sys4) و مرکز ملی پیش‌بینی زیست‌محیطی (NCEP) مدل (CFSv2)، مورد ارزیابی قرار داده و تجزیه و تحلیل‌ها را با استفاده از هر دو مجموعه داده واکاوی انجام دادند (Kim et al., 2012a). همچنین در تحقیق دیگری ویلکس (۲۰۰۸) با استفاده از روش آماری توسعه یافته مبتنی بر داده‌های دمای سطح پهنه‌های آبی اقیانوس آرام شمالی، پیش‌بینی فصلی پارامتر دما را به صورت شبکه‌ای بر روی آمریکای شمالی ارائه داد. در این تحقیق دو سری زمانی از داده‌های بلندمدت (از سال ۱۸۸۰ تا ۲۰۰۷) و کوتاه مدت (از سال ۱۹۵۰ تا ۲۰۰۷) دمای سطح پهنه‌های آبی از نوع داده‌های شبکه‌ای ERSST v.2¹ با قدرت تفکیک افقی ۲×۲ درجه جغرافیایی را در مدل‌های آماری CCA² و MCA³ آزموده شد و نشان داده شد که استفاده از داده‌های با دوره زمانی طولانی، علیرغم دقت کم برخی از آنها، می‌تواند موجب ارتقاء عمده در صحت پیش‌بینی‌های فصلی دمای فصل زمستان گردد (Wilks D.S., 2008). همچنین کیم و همکاران (۲۰۱۲) جهت ارائه پیش‌بینی فصلی در کشور کره جنوبی با استفاده از شاخص‌های دورپیوندی از روش همبستگی خطی چند متغیره استفاده کردند. در این تحقیق حداکثر از پنج متغیر پیش‌بینی‌کننده برای ساختن مدل همبستگی چند متغیره استفاده گردید. نتایج کیم و همکاران بیانگر آن بود که ضرایب

2. Canonical Correlation Analysis
3. Maximum Covariance Analysis

1. Extended Reconstructed Sea Surface Temperature version 2

(MRI/JMA)، برای مناطق مرطوب و جنب مرطوب پاکستان با قدرت تفکیک ۰/۰۵ درجه به صورت دهه ای توسعه دادند (Rasu et al., 2012). یاسوتامی و همکاران (۲۰۱۱) توسعه سری داده های روزانه دمای شبکه بندی شده بلندمدت و کاربرد آن را در تفکیک بارش/ برف در بارش‌های روزانه مورد مطالعه قرار دادند (Yasutomi N. et al., 2011).

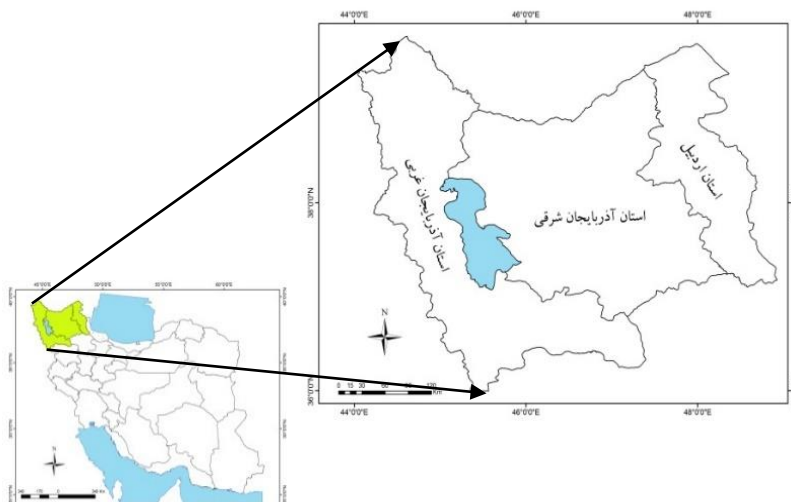
لذا بطور کلی استفاده از تکنیک پس پردازش میتواند استفاده از خروجی مدل های دینامیکی را جهت استفاده در مقیاس های کوچک ارتقاء بخشیده و میتوان با نگرش جامع تری خروجی این مدل ها را در مدیریت های کلان محیطی اعمال نمود. هدف اصلی این تحقیق ارتقاء درستی پیش بینی های فصلی بارش منطقه شمال غرب کشور با بکارگیری روش پس پردازش خروجی مدل های دینامیکی در جهت مدیریت بلیه خشکسالی است.

مواد و روش ها

داده ها

در این مطالعه از سه سری داده استفاده شده است؛ سری اول داده های دیدبانی بارش ماهانه ایستگاه های هواشناسی استان‌های شمال غرب ایران شامل استان های آذربایجان غربی و آذربایجان شرقی و استان اردبیل می باشد (شکل ۱). انتخاب ایستگاه ها با توجه به در دسترس بودن داده های بارش دیدبانی بلندمدت (۲۰۰۷-۱۹۸۰ میلادی) متناسب با داده های پیش بینی و داده های آفرودیت است.

Swinbank, 2009) اشاره کرد. ژن و رنویک (2003) پیش بینی فصلی دمای نیوزلند را با به کارگیری روش همبستگی چند متغیره خطی و استفاده از فراسنج های دمای هوا، بارش و دمای سطح پهنه های آبی اقیانوس آرام عملی ساختند (Zheng, X., Renwick J. A., 2003). کیتو و همکاران (۲۰۱۱) تحقیقی را بر روی اقلیم شناسی بارش خاورمیانه با استفاده از داده های شبکه ای آفرودیت و مقایسه آنها با خروجی مدل MRI-CGCM3 انجام دادند و به این نتیجه رسیدند که استفاده از داده های آفرودیت به میزان بسیار بالایی میتواند دقت مکانی تحقیق را افزایش داده و بالاخص استفاده از داده های شبکه ای بجای داده های دیده بانی ایستگاهی در مناطق دارای شرایط توپوگرافی کوهستانی میتواند باعث افزایش عملکرد استفاده از روش های ریزگردانی مدل های اقلیمی گردد (Kitoh A. et al., 2011) در تحقیقی دیگر کاسانوکی و کوبایاشی (۲۰۰۳)، توانایی احتمال پیش بینی و قابلیت پیش بینی فصلی جو را با استفاده از مدل گردش عمومی جو^۱ (AGCM) سرویس هواشناسی ژاپن^۲ (JMA)، که یک مدل طیفی جهانی با قدرت تفکیک T63 است، ارزیابی کردند. نتایج نشان داد که پیش بینی احتمالاتی برخلاف پیش بینی قطعی به برخی تشابهات فصلی و منطقه ای نظیر توانایی نسبی بالاتر در زمستان های نیمکره شمالی و شرق آسیا و شمال آمریکا مربوط است (Kusunoki S., C. Kobayashi, 2003). همچنین در تحقیقی راسا و همکاران (۲۰۱۲) داده های آفرودیت را توسط موسسه تحقیقات بشری و طبیعت (RIHN) و موسسه تحقیقات هواشناسی ژاپن



شکل ۱- منطقه مورد مطالعه (شمال غرب ایران)

جدول ۱ شامل ایستگاه‌های دیده بانی موجود در منطقه مورد مطالعه به همراه داده‌های بارش ایستگاهی دیده بانی شده می‌باشد که به ترتیب فصول سال آورده شده‌اند.

جدول ۱- آمار اقلیمی ایستگاه‌های دیده بانی منطقه مورد مطالعه

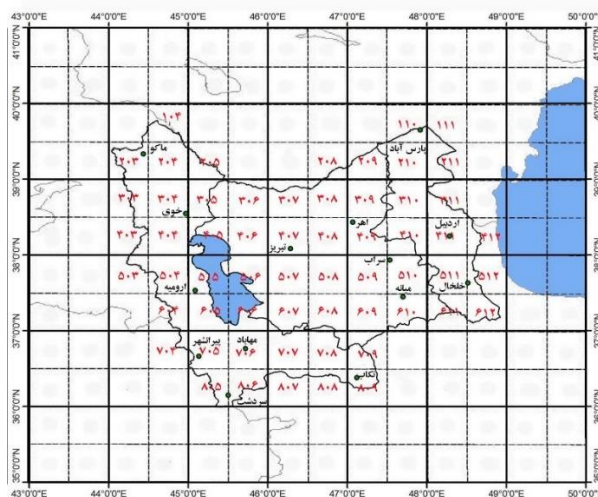
استان	ایستگاه	بارندگی (میلیمتر)			مجموع بارندگی (میلیمتر)				درصد بارندگی (%)			دامنه تغییرات	واریانس	
		میانگین	حداکثر	حداقل	فصل بهار	فصل تابستان	فصل پاییز	فصل زمستان	فصل بهار	فصل تابستان	فصل پاییز			فصل زمستان
استان آذربایجان شرقی	ارومیه	۳۱۲/۳	۵۱	۲/۲	۱۱۴/۲	۱۴/۱	۹۱/۷	۹۲/۳	۳۷/۱	۵٪	۲۹٪	۳۰٪	۴۸/۸	۳۰۷/۲۳
	پیرانشهر	۶۶۲/۹	۱۰۶/۵	۱/۶	۱۷۰/۷	۷/۱	۱۹۶/۸	۲۸۸/۳	۲۶/۱	۱٪	۳۰٪	۴۳٪	۱۰۴/۹	۱۹۲۷
	تکاب	۳۳۷/۵	۶۰	۳/۱	۱۲۵/۳	۱۳/۳	۹۳	۱۰۵/۹	۳۷/۱	۴٪	۲۸٪	۳۱٪	۵۶/۹	۳۹۵
	خوی	۲۶۳/۲	۵۲/۶	۶/۲	۱۱۴/۹	۲۹/۲	۶۴/۷	۵۴/۴	۴۴/۴	۱۱٪	۲۵٪	۲۱٪	۴۶/۴	۱۶۳/۵۵
	سردشت	۸۳۳/۵	۱۳۵/۹	۱/۳	۲۱۴/۴	۴/۹	۲۵۳	۳۶۱/۲	۲۶/۱	۱٪	۳۰٪	۴۳٪	۱۳۴/۶	۳۲۴۸/۱۳
	ماکو	۳۰۵/۱	۶۰/۱	۱۲/۶	۱۴۲/۲	۴۸/۹	۶۲/۴	۵۱/۶	۴۷/۱	۱۶٪	۲۰٪	۱۷٪	۴۷/۵	۲۱۴/۷۸
	مهاباد	۳۹۷	۶۳/۱	۱/۲	۱۱۵/۹	۶/۶	۱۲۴	۱۵۰/۵	۲۹/۱	۲٪	۳۱٪	۳۸٪	۶۱/۹	۵۹۸/۴۲
استان آذربایجان غربی	اهر	۲۸۷/۶	۵۵/۴	۶/۴	۱۲۳/۸	۲۵/۵	۷۵/۵	۶۲/۸	۴۳/۱	۹٪	۲۶٪	۲۲٪	۴۹	۱۹۰/۷۷
	تبریز	۲۴۷/۲	۴۶/۸	۳/۴	۱۰۲/۳	۱۳/۷	۶۵/۶	۶۵/۶	۴۱/۱	۶٪	۲۷٪	۲۷٪	۳۳/۴	۱۸۰/۵۶
	سراب	۲۴۴/۴	۵۱	۷	۱۰۷/۷	۲۹/۱	۵۹/۶	۴۸	۴۴/۴	۱۲٪	۲۴٪	۲۰٪	۴۴	۱۵۸/۹۷
استان اردبیل	میانه	۲۷۸/۴	۴۸/۴	۳/۱	۱۰۱/۶	۱۴/۳	۷۵/۷	۸۶/۸	۳۶/۱	۵٪	۲۷٪	۳۱٪	۴۵/۳	۲۱۸/۶۴
	اردبیل	۲۷۵/۳	۴۳/۸	۵/۱	۹۹/۸	۲۲/۷	۸۰/۵	۷۲/۳	۳۶/۱	۸٪	۲۹٪	۲۶٪	۴۸/۷	۱۳۷/۷۴
	پارس آباد	۲۷۴/۲	۳۴/۶	۶/۲	۹۱/۱	۳۲/۶	۹۲/۷	۵۷/۸	۳۳/۱	۱۲٪	۳۴٪	۲۱٪	۲۸/۴	۹۴/۴۲
	خلخال	۳۷۲/۸	۶۲/۲	۶/۱	۱۴۴/۲	۲۵/۷	۱۰۱/۸	۱۰۱/۱	۳۹/۱	۷٪	۲۷٪	۲۷٪	۵۶/۱	۳۳۶/۲۳

بر اساس مشاهدات باران سنجها آغاز شد. افرویدت شامل یک برنامه همکاری‌های بین‌المللی برای جمع‌آوری و تجزیه و تحلیل داده‌های دیدبانی بارانسنجی از هزاران ایستگاه در آسیا علاوه بر ایستگاه‌هایی که سیستم جهانی ارتباط از دور WMO گزارش شده است، می‌باشد که منجر به ایجاد سری داده‌های بارش روزانه برای ۵۷ سال می‌شود. این پایگاه داده با روش درون‌یابی ADW تهیه شده است. داده‌های افرویدت، داده‌های یکپارچه مشاهداتی بارندگی آسیا با

سری دوم داده‌ها، داده‌های افرویدت است. در سال ۲۰۰۶ پروژه افرویدت با هدف ایجاد سری داده‌های بارش روزانه در شبکه‌هایی با قدرت تفکیک بالا برای سراسر آسیا توسعه یافت (Yatagai, et al. 2012). در این سال پروژه ای تحت عنوان APHRODITE توسط مرکز تحقیقات بشر و طبیعت و مرکز تحقیقات هواشناسی کشور ژاپن، به منظور ایجاد پایگاه داده‌های بارندگی روزانه شبکه بندی شده در سراسر قاره آسیا با قدرت تفکیک مکانی بالا و

ایستگاه های سینوپتیک و بارانسنجی منطقه شمال غرب ایران شامل استان های اردبیل و آذربایجان شرقی و آذربایجان غربی که از بانک اطلاعات افروودیت استخراج گردیدند، مقایسه شد. شکل ۲ شبکه بندی منطقه مورد نظر را از حیث استفاده از داده های افروودیت نشان می دهد. منطقه مورد نظر دارای ۵۹ شبکه 0.5×0.5 درجه می باشد که داده های افروودیت متناظر از طریق برنامه نویسی و تغییر فرمت استخراج گردیدند.

قدرت تفکیک بالا به منظور ارزیابی منابع آب به صورت سه مجموعه مجزا شامل مناطق موسمی آسیا، خاور میانه و روسیه را با قدرت تفکیک مکانی در شبکه 0.25×0.25 و 0.5×0.5 و با مقیاس زمانی روزانه در اختیار قرار می دهد. گام اولیه در استفاده از این داده ها راستی آزمایی و تطابق آنها با داده های دیدبانی مناطق دارای ایستگاه بارانسنجی است. بدین منظور داده های دیدبانی در دوره مشابه با داده های افروودیت بر روی



شکل ۲- شبکه های منظم 0.5×0.5 درجه داده های افروودیت بر روی منطقه مورد مطالعه

اقیانوسی به نام MRI.COM تشکیل شده که مولفه جوی آن با مدل آئروسول MASINGAR km-2 جفت شده است. فاصله زمانی جفت شدن یا تبادل اطلاعات بین مدل جوی و اقیانوسی یک ساعت و در مدل هواویز نیم ساعت می باشد. در مدل جوی MRI-AGCM3 مولفه جوی مدل به صورت طیفی است که در آن از معادلات هیدروستاتیک بسط به عنوان پیش یابی کننده استفاده می شود. قدرت تفکیک افقی مدل T1159 (حدود ۱۲۰ کیلومتر) با ۴۸ لایه قائم در سیستم مختصات اتا می باشد. ساختار این مدل شامل سه بخش عمده است که عبارتند از: (الف) داده های میدان اولیه ورودی مدل که از طریق آنالیز متغیرهای هواشناسی، اقیانوسی و سطح زمین بدست می آیند، (ب) سامانه پیش بینی تلفیقی جو، اقیانوس و خشکی و (ج) سامانه ارزیابی و تحلیل خطا و محصولات نقشه ای. متغیرها و شاخص های مورد استفاده به همراه توضیحات مربوطه در جدول ۲ آورده شده است.

سری سوم داده ها، پیش بینی های گذشته نگر بارش و برخی متغیرهای هواشناسی تاثیرگذار بر آن مانند ارتفاع ژئوپتانسیل، ضخامت لایه های مختلف، فشار سطح زمین و سایر متغیرهای هواشناسی برون داد مدل می باشد. به طور کلی هر مدل پیش بینی فصلی طی هر ارتقاء مدل بایستی برای یک دوره ۳۰ ساله گذشته اجرا شود تا نتایج آن با داده های مشاهداتی مقایسه گردد. با مقایسه پیش بینی های صادره ۳۰ سال گذشته با مقادیر مشاهداتی، صحت مدل پیش بینی فصلی مورد ارزیابی قرار می گیرد و در صورت تایید مدل مذکور برای صدور پیش بینی فصلی به صورت عملیاتی استفاده می شود. در این تحقیق از داده های پیش بینی مجدد برون داد مدل MRI-CGCM شامل ۱۴ متغیر و شاخص کلی خروجی مدل و ۶ متغیر پیش بینی گذشته نگر مربوط به شبکه مربوط به ایستگاه های مورد مطالعه استفاده گردید. مدل MRI-CGCM3 (Yukimoto et al., 2012) از دو مولفه گردش عمومی جوی به نام MRI-AGCM3 و گردش عمومی

جدول ۲- پارامترهای خروجی مدل MRI-CGCM3

پارامتر	متغیر	پارامتر	متغیر	پارامتر	متغیر
Z2030	ارتفاع ژئوپتانسیل ۵۰۰ میلی باری	NINOSST	دمای سطح آب	H500	ارتفاع ژئوپتانسیل ۵۰۰ میلی باری
Z3040	ارتفاع ژئوپتانسیل ۵۰۰ میلی باری	NINOWESTSST	دمای سطح آب	SLP	فشار سطح متوسط دریا
Z4050	میانگین ارتفاع ژئوپتانسیل ۵۰۰ میلی باری	DLRAIN	بارش	SST	دمای سطح آب
Z5060	ارتفاع ژئوپتانسیل ۵۰۰ میلی باری	WIORAIN	بارش	T2M	دمای ۲ متری
THMD	ضخامت بین سطح ۳۰۰ و ۸۵۰ میلی باری	SAMOIRAIN	بارش	T850	دمای ۸۵۰ میلی باری
THEX	ضخامت بین سطح ۳۰۰ و ۸۵۰ میلی باری	WNPRAIN	بارش	Model-Pr	بارش در شبکه
WIOSST	دمای سطح آب	MCRAIN	بارش		

مدل شده و مشاهداتی به شمار می رود. شکل کلی معادله همبستگی چند متغیره مطابق رابطه (۱) است.

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

که در آن Y_t متغیر وابسته یا پیش بینی شونده و X_{kt} متغیرهای مستقل یا پیش بینی کننده ها هستند. از آنجا که از تعداد ۲۰ متغیر پیش بینی فصلی برای توسعه مدل همبستگی چند متغیره استفاده شده است که تعدادی از آنها ارتباط معنی داری با بارش مشاهداتی منطقه ندارند، لذا برای حذف متغیرهای بی تاثیر، تمامی متغیرهای پیش بینی 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 آماره های F و t نیز موثر می باشند. R^2 درصد تغییرات متغیر پیش بینی شونده به وسیله متغیرهای پیش بینی کننده را توضیح می دهد. Adjust R^2 یا Adjust R^2 متعادل شده وقتی مورد استفاده قرار می گیرند که تعداد متغیرهای مستقل افزایش یابند. هرچه تعداد نمونه ها افزایش یابند R^2 و Adjust- R^2 به هم نزدیکتر می شوند. مقادیر منفی ضریب تبیین متعادل شده قابل قبول نیستند. مزیت روش همبستگی چندگانه خطی این است که علیرغم عدم دخالت فرآیندهای فیزیکی جو، می توان ارتباطی

تعداد ۱۴ پارامتراول خروجی مدل MRI-CGCM3 که هر ماهه در مرکز اقلیم توکیو (TCC) جهت پس پردازش مورد استفاده قرار می گیرد، طوری انتخاب شده اند که متناسب با اقلیم جنوب شرق آسیا می باشند، اما تعداد قابل توجهی از آنها برای اقلیم کشورمان مناسب هستند. علاوه بر ۱۴ شاخص یاد شده، تعداد ۶ متغیر دیگر شامل H500، SLP، T2M، Model-Pr و T850 نیز از فایل های خروجی مدل استخراج شدند.

پس پردازش داده بارش و صحت سنجی نتایج

روش مورد استفاده در پس پردازش آماری روش رگرسیون چندمتغیره خطی بر روی داده های بارش می باشد. روش های رگرسیون چند متغیره می تواند هر دو نوع خطای سیستماتیک و تصادفی را در خروجی های مدل اصلاح نمایند. قابلیت پیش بینی خطای تصادفی به مراتب مشکل تر از خطای سیستماتیک است. در روش مورد نظر، داده های پیش بینی و دیدبانی به دو دوره آموزش یا طراحی مدل پس پردازش آماری و دوره آزمون تقسیم گردید. روش رگرسیون چند متغیره روشی برای ساختن معادله مدل از سری داده های گذشته می باشد (Shimizu et al., 2009). این روش یکی از قویترین روش ها برای تبیین ارتباط بین متغیرهای

که برای محاسبه آن لازم است خطای میانگین مربعات^۵ MSE داده‌های مشاهداتی (MSE_c) و پیش بینی (MSE_f) محاسبه گردد.

$$MSE_f = \frac{1}{n} \sum_{i=1}^n (f_i - x_i)^2 \quad (۳)$$

$$MSE_c = \frac{1}{n} \sum_{i=1}^n (x_i)^2 \quad (۴)$$

که در آن f_i و x_i به ترتیب i امین مقدار پیش بینی و i امین مقدار مشاهداتی از n داده می باشند. و مقادیر $RMSE_f$ و $RMSE_c$ به ترتیب با جذرگیری از مقادیر میانگین خطای مربعات پیش بینی و مشاهداتی بدست می آیند. در یک پیش بینی دقیق مقدار جذر میانگین مربعات خطای پیش بینی یک ($MSSS=1$) و در یک پیش بینی کاملاً ناصحیح ($MSSS=0$) خواهد بود که نشان دهنده آنست که استفاده از خروجی مدل پس پردازش شده با خروجی پس پردازش نشده فرقی ندارند. مقادیر $MSSS > 0$ نشان می دهد که دقت مدل پس پردازش شده پیش بینی در مقایسه با میانگین های اقلیمی چقدر موفق تر است (Gheti, R., 2007).

علاوه بر دو شاخص یاد شده، شاخص های میانگین اریبی (MBE) و میانگین خطای نسبی نیز در بررسی توانمندی روش پس پردازش مورد استفاده قرار گرفتند ه مطابق روابط (۵) و (۶) محاسبه شدند.

$$MBE = \frac{1}{n} (\sum_{i=1}^n M_i - \sum_{i=1}^n O_i) \quad (۵)$$

که در آن M_i و O_i به ترتیب مقادیر پیش بینی و مشاهداتی هستند.

خطای نسبی (RE) پیش بینی ها به صورت رابطه (۶) محاسبه شد.

$$RE = \frac{\frac{1}{n} (\sum_{i=1}^n M_i - \sum_{i=1}^n O_i)}{\sum_{i=1}^n O_i} \quad (۶)$$

از طرفی با استفاده از جدول توافقی می توان منحنی ROC و همچنین شاخص های پیش بینی صحیح HR^1 و پیش بینی نادرست FAR^v را برای هر طبقه از پیش بینی ها محاسبه کرد که مساحت زیر منحنی ROC بیانگر ارزیابی پیش بینی بوده که هرچه به عدد یک نزدیکتر باشد به معنی توانایی بیشتر مدل خواهد بود (WMO, 2006).

معناداری بین پارامترهای پیش بینی شونده منطقه و پارامترهای پیش بینی کننده بزرگ مقیاس خروجی مدل گردش عمومی جو برقرار نمود و سپس نتایج آن را جهت ریزمقیاس نمایی پارامترهای محلی مانند بارش مورد استفاده قرار داد (Lee, J., 2003).

در این تحقیق دوره ۲۸ ساله داده های مدل پیش بینی فصلی به دو دوره ۲۲ ساله و ۶ ساله تقسیم شد. از داده های دوره ۲۲ ساله برای استخراج رفتار بارشی مدل MRI-CGCM3 بر روی نقاط شبکه ای مورد مطالعه استفاده گردید. این کار از طریق تعیین متغیر شاخص های پیش بینی دارای بیشترین همبستگی با بارش نقطه ای شبکه و تعیین ضرایب مدل آماری همبستگی چند متغیره بدست آمد. سپس مدل آماری حاصل از ۲۲ سال برون داد مدل MRI-CGCM3 و داده های شبکه ای بارشی، برای یک دوره ۶ ساله به منظور پیش بینی بارش ماهانه مورد استفاده قرار گرفت. در این تحقیق از نرم افزار جامپ (JMP4) به منظور تعیین همبستگی جزئی بین ۲۰ متغیر شاخص برون داد مدل MRI-CGCM3 با بارش دیدبانی شده ایستگاه استفاده گردید. بررسی ها بیانگر آنست که در صورتی که تعداد متغیرهای ورودی مدل چندمتغیره از ۳ بیشتر باشند، به همین میزان نیز خطای پس پردازش افزایش یافته و پیش بینی بارش نقاط شبکه افزایش می یابد، لذا مدل چندمتغیره براساس ۳ متغیر ورودی طراحی گردید.

همچنین برای بررسی توانمندی روش پس پردازش انتخاب شده در پیش بینی بارش نقطه ای شبکه ایستگاه های منطقه مورد مطالعه، از چهار شاخص ارزیابی $MSSS^1$ ، شاخص پیش بینی طبقه ای بارش (ROC^2)، اریبی (MBE^3) و خطای نسبی (RE^4) استفاده شد. به کمک شاخص $MSSS$ دقت نسبی پیش بینی حاصل از مدل پس پردازش شده در مقایسه با مقادیر واقعی داده های مشاهداتی را محاسبه گردید، بطوریکه:

$$MSSS = 1 - \frac{RMSE_f}{RMSE_c} \quad (۲)$$

5. Mean Square Error
6. Hit Rate
7. False Alarm Rate

1. Mean Square Skill Score
2. Relative Operating Characteristics
3. Mean Bias Error
4. Relative Error

پیش بینی شاخص خشکسالی SPI

با توجه به اهمیت آگاهی از وضعیت خشکسالی طی ماههای آتی در برنامه ریزی های بخش کشاورزی، منابع آب و محیط زیست، با به کارگیری بارش های پیش بینی شده، شاخص خشکسالی SPI در مقیاس ماهانه و فصلی (۳ ماهه) برای سلول های شبکه ای مورد مطالعه، محاسبه شد دلیل انتخاب این شاخص وجود داده های ماهانه شبکه آفرودیت و به طبع آن در اختیار داشتن داده های پس پردازش ماهانه است. لذا از آنجا که شاخص SPI تنها با در اختیار داشتن داده های ماهانه بارش قابل محاسبه می باشد، لذا استفاده از این شاخص جهت پیش آگاهی خشکسالی پیشنهاد می گردد.

شاخص SPI توسط مک کی و همکاران به منظور کمی سازی بارش و پیش خشکسالی ارائه شد. تنوع کاربرد، شاخص SPI این امکان پیش خشکسالی را در مقیاس های کوتاه مدت نظیر رطوبت خاک و بلندمدت نظیر آب های سطحی و آب های زیرزمینی فراهم می سازد (Fattahi A. et al., 2007). براساس روش SPI، دوره خشکسالی هنگامی اتفاق می افتد که SPI به طور مستمر منفی و به مقدار ۱- یا کمتر برسد و هنگامی پایان می یابد که SPI مثبت شود. مقادیر تجمعی SPI نیز بزرگی و شدت دوره خشکسالی و همچنین دوره های مرطوب را نشان می دهد. در جدول ۳ طبقه بندی مقادیر SPI ملاحظه می شود (Ensafi moghaddam t., 2007)

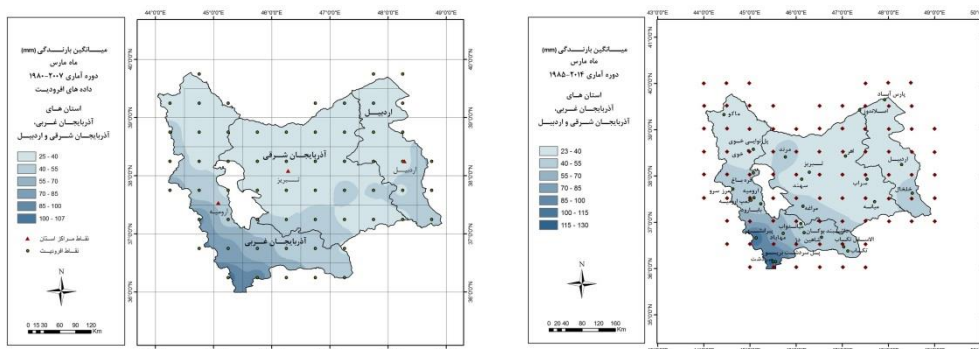
جدول ۳- طبقه بندی شاخص SPI بر اساس مک کی و همکاران

طبقه بندی شاخص خشکسالی SPI بر اساس مک کی و دیگران (انصافی مقدم، ۱۳۸۶)			
وضعیت	شاخص SPI	وضعیت	شاخص SPI
فرا مرطوب	بزرگتر یا مساوی ۲	نسبتا خشک	۱,۴۹- تا ۱-
بسیار مرطوب	۱,۵ تا ۱,۹۹	بسیار خشک	۱,۹۹- تا ۱,۵-
نسبتا مرطوب	۱ تا ۱,۴۹	فرا خشک	کوچکتر یا مساوی ۲-
نزدیک نرمال	۰,۹۹- تا ۰,۹۹+		

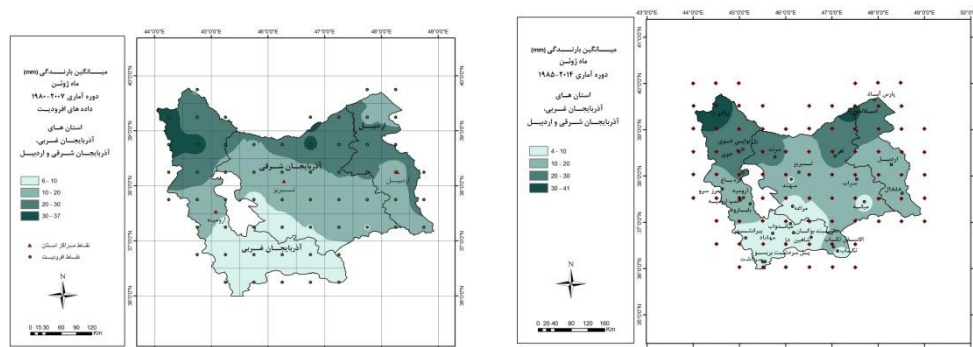
نتایج:

در این تحقیق دوره منتخب مطالعه سال های ۱۹۸۰ تا ۲۰۰۷ میلادی در نظر گرفته شد که ۷۰ درصد طول این دوره یعنی سال های ۲۰۰۱-۱۹۸۰ بعنوان دوره آزمون برای تهیه معادلات رگرسیونی پس پردازش ماهانه و ۳۰ درصد آن یعنی سال های ۲۰۰۲-۲۰۰۷ بعنوان دوره راستی آزمائی در نظر گرفته شد. داده های آفرودیت شبکه بندی شده در ۵۹ سلول

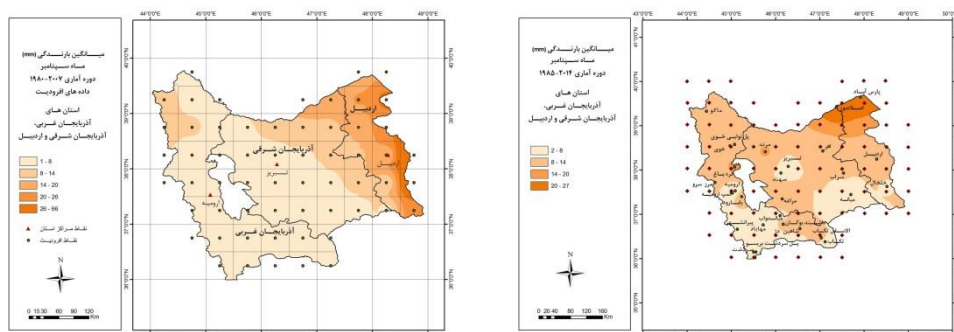
شبکه ای ۵/۵×۵/۵ درجه برای منطقه مورد مطالعه استخراج و با داده های دیده بانی شده ایستگاهی منطقه صحت سنجی شدند که نتایج بیانگر صحت خوب داده های آفرودیت بود که نهایتا منجر به استفاده از آنها بجای داده های پراکنده ایستگاهی گردید (شکل های ۳ تا ۷). البته لازم به ذکر است که با توجه به شرایط توپوگرافی منطقه مورد مطالعه و پراکندگی ایستگاهها مسلما داده های شبکه ای آفرودیت دقت تحقیق را افزایش داده اند.



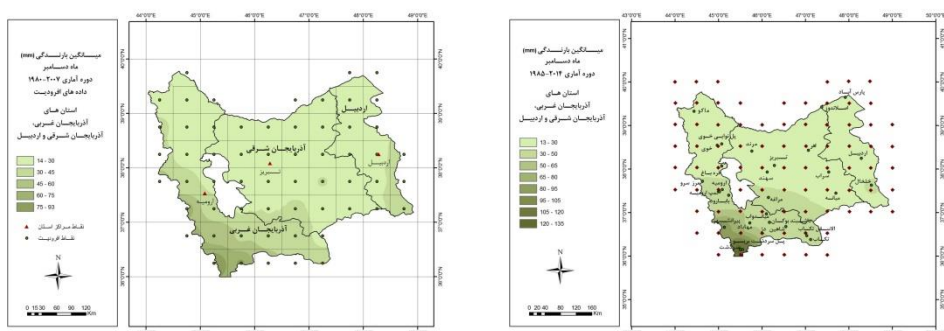
شکل ۳- پهنه بندی داده های بارش ماه مارس، راست داده های دیده بانی و چپ داده های آفرودیت



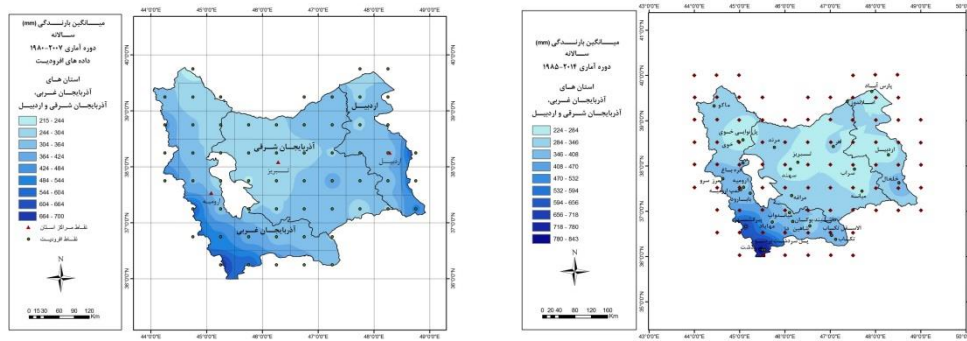
شکل ۴- پهنه بندی داده های بارش ماه ژوئن، راست داده های دیده بانی و چپ داده های آفرودیت



شکل ۵- پهنه بندی داده های بارش ماه سپتامبر، راست داده های دیده بانی و چپ داده های آفرودیت



شکل ۶- پهنه بندی داده های بارش ماه دسامبر، راست داده های دیده بانی و چپ داده های آفرودیت



شکل ۷- پهنه بندی داده های بارش سالانه، راست داده های دیده بانی و چپ داده های آفرودیت

پیش بینی شده در شاخص SPI، پهنه بندی پیش بینی بلیه خشکسالی در منطقه مورد مطالعه حاصل شد. بدلیل حجم بالای نقشه ها و نمودارها که برای هر سلول بطور جداگانه تهیه شده، در این مقاله تحلیل سلول ۵۰۵ با مشخصات جغرافیایی ۴۵،۲۵ درجه طول جغرافیایی و ۳۷،۷۵ درجه عرض جغرافیایی بعنوان نمونه ارائه شده است که قابل تعمیم به سایر سلول ها نیز می باشد. در جدول ۴ پارامترهای ورودی برای ماه های مختلف سال سلول شبکه مورد نظر که از طریق معادلات رگرسیونی چند متغیره حاصل شده است و جهت مدل بارش پس پردازش شده تعیین گردیده به همراه صحت پیش بینی طبقه ای بارش ماهانه و بایاس قبل و بعد از فرآیند پس پردازش آورده شده است.

در گام نخست متناظر با دوره آزمون پیش بینی بارش در دوره ۱۹۸۰-۲۰۰۱ میلادی مورد واسنجی قرار گرفت و برای هر سلول شبکه متغیرهایی که دارای بیشترین همبستگی با بارش ماهانه را دارا بودند استخراج و معادلات پس پردازش شده ماهانه آنها طراحی گردید. در گام بعدی با بکارگیری معادلات پس پردازش شده ماهانه برای هر سلول شبکه در حوضه مورد مطالعه، خروجی خام بارش مدل MRICGCM3 برای تک تک سلول های شبکه اصلاح و پیش بینی بارش سلول در دوره آزمون ۲۰۰۲-۲۰۰۷ میلادی استخراج گردید و نهایتاً جهت صحت اجرایی شدن نتایج و معادلات در پیش بینی های آتی، نتایج دوره راستی آزمایی مورد صحت سنجی با داده های واقعی قرار گرفت. سپس با بکارگیری نتایج بارش


جدول ۴- مدل پیش بینی حاصل از پارامترهای مدل MRI-CGCM3 جهت پس پردازش بارش سلول شبکه ای ۵۰۵ طی دوره آماری

۱۹۸۰-۲۰۰۷ میلادی


MRE		MBE		صحت پیش بینی طبقه ای (%)	MSSS	Model Index	Month
After Post Process	Before Post Process	After Post Process	Before Post Process				
۰.۲۸	۱.۱۵	-۶.۵۳	۲۶.۴۵	۷۲.۲۲	۰.۷۴	Sst, h2, IOBW Rain	Jan
-۰.۱۷	۰.۵۹	۵.۳۳	۱۸.۴۱	۸۸.۸۹	۰.۸۸	MC Rain, IOBW SST, Z4050	Feb
۰.۰۶	۰.۳۹	۲.۴۹	۱۴.۹۴	۵۰.۰۰	۰.۶۱	SST, h2, THEX	Mar
-۰.۳۳	۰.۲۵	-۲۱.۵۲	۱۶.۳۴	۳۸.۸۹	۰.۷۸	WIO SST, Z3040, DL Rain	Apr
۰.۳۴	۱.۴۰	۱۴.۱۷	۵۸.۶۳	۳۸.۸۹	۰.۵۷	H2, SST NNOWEST SST, NNO3	May
۰.۵۶	۱۱.۵۱	-۳.۵۷	۷۳.۴۵	۸۳.۳۳	۰.۱۶	Z2030, h2, Z4050	Jun
-۰.۸۶	۱۱.۹۴	-۶.۴۴	۸۹.۷۸	۶۶.۶۷	۰.۱۳	SST, Z2030, THTR	Jul
-۰.۸۶	۶۸.۳۹	۰.۹۹	۷۸.۶۵	۸۳.۳۳	۰.۱۹	DL Rain, IOBW Rain, MC, Rain	Aug
۳.۳۰	۸۱۰.۹۸	۰.۴۴	۱۰۸.۱۳	۶۶.۶۷	-۱۲.۲۲	P850, WNP Rain, TPR	Sep
۰.۲۶	۱.۹۴	۶.۸۴	۵۰.۶۲	۵۰.۰۰	۰.۴۰	MC Rain, WIO SST, DL Rain	Oct
۰.۳۳	۱.۳۵	-۱۲.۸۲	۵۲.۲۹	۷۲.۲۲	۰.۶۸	Z3040, Z4050, NNO WEST	Nov
۰.۷۴	۱۲.۶۳	۴.۷۷	۸۱.۶۹	۱۰۰.۰۰	۰.۳۰	ELO SST, WIO Rain, ELO Rain	Dec
۰.۱۱	۷۶.۸۷	۶.۶۷	۵۵.۷۸	۶۷.۵۹		Average	

در شکل ۸ نمودارهای بارش پیش بینی شده توسط مدل MRI-CGCM3 برای ماه‌های فوریه (الف)، می (ب)، اوت (ج) و نوامبر (د) شامل داده‌های مدل قبل از پس پردازش (Train)، بعد از فرآیند پس پردازش (PostProc)، بارش شبکه آفرودیتی (Observation) و بارش دوره آزمون مدل سازی (Post-Processing) برای سلول ۵۰۵ بطور نمونه نشان داده شده است.


مطابق جدول ۴ از دیدگاه شاخص کمترین خطای مربعات (MSS)، بهترین توانمندی مدل پس پردازش در ماه فوریه با ۰/۸۸ و کمترین توانمندی در ماه ژوئیه با ۰/۱۳ مشاهده شد. بر این اساس میانگین صحت پیش بینی ماهانه در طول سال ۶۷/۵۹ درصد می‌باشد. به کارگیری روش پس پردازش آماری اریبی و خطای نسبی را به ترتیب از ۵۵/۷۸ به ۶/۷۶ میلیمتر و از ۷۶/۸۷ به ۰/۱۱ کاهش داده است.




(ب)



(الف)



(د)

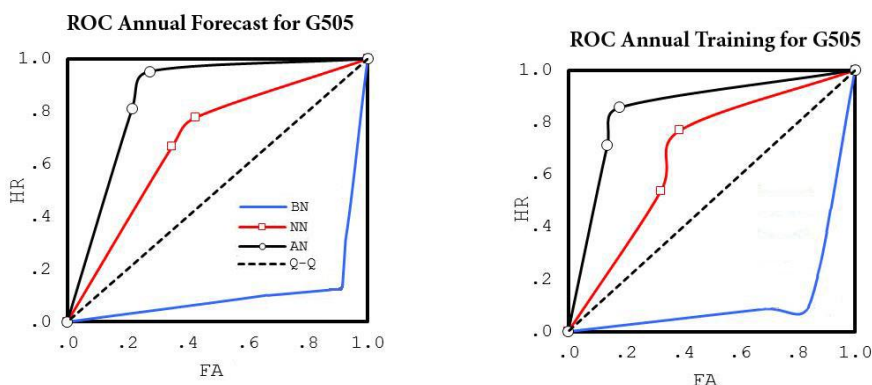


(ج)

شکل ۸- نتایج پس پردازش خروجی مدل MRI-CGCM3 طی دوره آموزش و پیش بینی روی شبکه آفرودیت ۵۰۵ طی دوره ۱۹۸۰-۲۰۰۷ میلادی

محور افقی شاخص پیش بینی های نادرست است. نتایج بیانگر آنست که بیشترین کارایی مدل زمانیست که بارش در محدوده نرمال تا بیشتر از نرمال پیش بینی شده باشد و در ماه های کم بارش از دقت کمتری برخوردار است.


شکل ۹ منحنی ROC داده های بارش پس پردازش شده را به روش رگرسیون چندمتغیره برای شبکه ۵۰۵ طی دو دوره آموزش و پیش بینی در مقیاس سالانه نشان می دهد. در این شکل محور قائم بیانگر شاخص پیش بینی های درست و



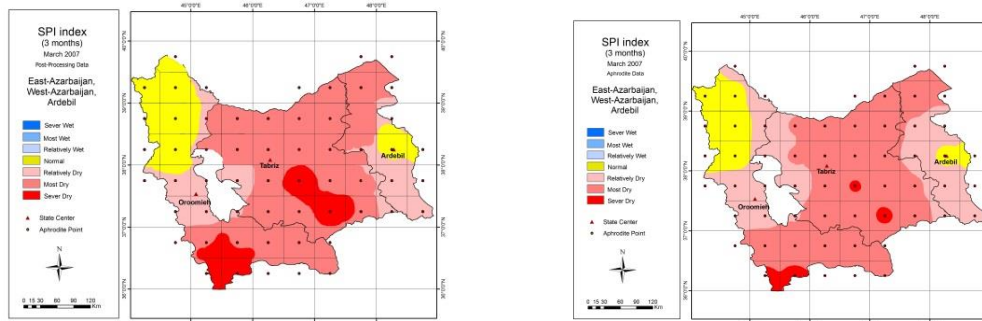
شکل ۹- منحنی ROC داده های بارش پس پردازش شده به روش رگرسیون چند متغیره برای دوره آموزش (راست) و دوره پیش بینی (چپ) در مقیاس سالانه برای شبکه ۵۰۵

در شکل های ۱۱ تا ۱۴ پهنه بندی شاخص خشکسالی SPI اصلاح شده با استفاده از بارش شبکه آفرودیت و بارش پیش بینی شده توسط مدل MRI-CGCM3 با اعمال فرآیند پس پردازش آورده شده است. در شکل های مذکور شاخص SPI برای دوره های سه ماهه منتهی به مارس (زمستان)، ژوئن (بهار)، سپتامبر (تابستان) و دسامبر (پائیز) ارایه شده است. همانطور که ملاحظه می شود الگوهای خشکسالی پس از اعمال فرآیند پس پردازش بر روی بارش های مدل پیش بینی فصلی به میزان نسبتاً زیادی با الگوهای خشکسالی مشاهداتی ناشی از شبکه دیده بانی آفرودیت هماهنگی دارد.

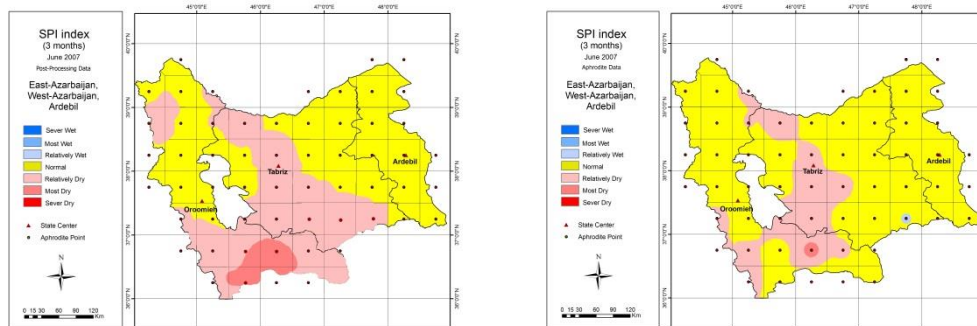
شکل ۱۰ میانگین داده های بارش شبکه آفرودیت، داده های خام مدل و داده های پس پردازش شده به روش رگرسیون چندمتغیره را برای شبکه ۵۰۵ طی دوره پیش بینی (سال های ۲۰۰۲-۲۰۰۷ میلادی) نشان می دهد. نتایج بیانگر آنست که تفاوت معنی داری بین خروجی پیش بینی خام و پس پردازش شده مدل وجود دارد. بطوریکه پیش بینی پس پردازش شده مدل با داده های آفرودیت شبکه دارای همخوانی خوبی بوده و این تناسب و همخوانی در ماه های پربارش نتایج بهتری را به دنبال دارد.



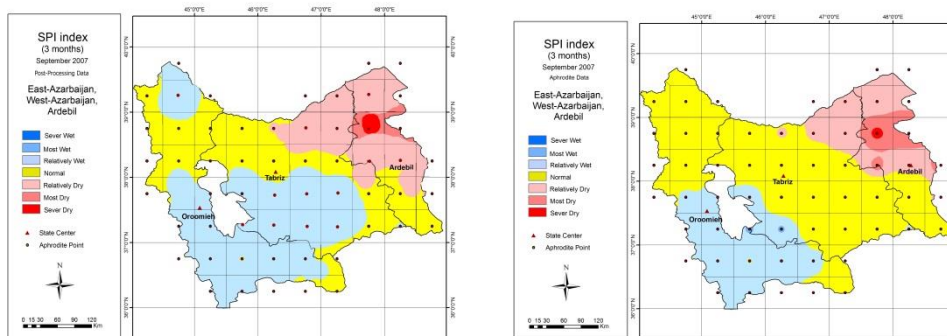
شکل ۱۰- مقایسه بارش شبکه آفرودیت، خروجی خام مدل و خروجی پس پردازش شده به روش رگرسیون چند متغیره برای شبکه ۵۰۵



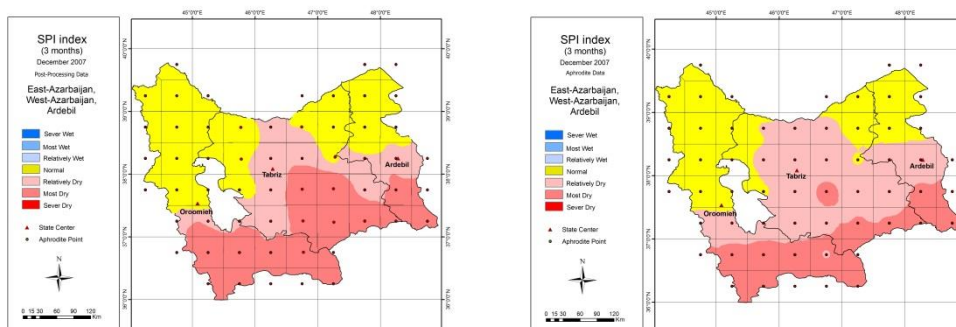
شکل ۱۱- پهنه بندی شاخص SPI ماه مارس (زمستان)، راست داده های آفرودیت و چپ داده های پس پردازش شده مدل



شکل ۱۲- پهنه بندی شاخص SPI ماه ژوئن (بهار)، راست داده های آفرودیت و چپ داده های پس پردازش شده مدل



شکل ۱۳- پهنه بندی شاخص SPI ماه سپتامبر (تابستان)، راست داده های آفرودیت و چپ داده های پس پردازش شده مدل



شکل ۱۴- پهنه بندی شاخص SPI ماه دسامبر (پائیز)، راست داده های آفرودیت و چپ داده های پس پردازش شده مدل

پردازش آماری در سلول شبکه ای ۵۰۵ آفرودیتی منطقه مورد مطالعه آورده شده است. در ستون های دوم و سوم این جدول

در جدول ۵ میزان افزایش صحت پیش بینی شاخص SPI توسط مدل MRI-CGCM3 بعد از اجرای فرآیند پس

در قبل و بعد از انجام فرآیند پس پردازش بر روی خروجی مدل درج شده است.

میزان صحت پیش بینی شاخص خشکسالی فصلی بر مبنای طبقه بندی اصلاح شده مکی و همکاران ارایه شده است و در دو ستون آخر نیز میزان همبستگی بین شاخص خشکسالی

جدول ۵- توانمندی مدل MRI-CGCM3 در پیش بینی شاخص SPI فصلی در شبکه ۵۰۵ در دوره ۲۰۰۱ تا ۲۰۰۷

شبکه	صحت پیش بینی طبقه ای (درصد)		همبستگی پیش بینی SPI مدل با دیدبانی	
	قبل از پس پردازش	بعد از پس پردازش	قبل از پس پردازش	بعد از پس پردازش
۵۰۵	۶۰/۹	۷۸/۴	۰/۰۶۸	۰/۴۶
میانگین شبکه ها	۶۱/۷	۷۹/۵	۰/۰۶۱	۰/۴۹

این تحقیق سعی گردید تا با استفاده از روش رگرسیون چندمتغیره جهت پس پردازش خروجی مدل پیش بینی فصلی MRI-CGCM3 بر روی منطقه فوق الذکر، دقت بکارگیری پیش بینی های ماهانه و همچنین شاخص خشکسالی را ارتقاء بخشید. برای این منظور از روش رگرسیون چندمتغیره بر روی ۲۰ شاخص مدل و داده های آفرودیت شبکه بندی شده که نسبت به داده های دیده بانی ایستگاهی دارای خطای توزیع مکانی و زمانی بسیار کمتری هستند، استفاده گردید. تعداد نقاط شبکه آفرودیت در این منطقه ۵۹ نقطه با گام مکانی ۰/۵ درجه جغرافیایی بود که بعد از صحت سنجی با داده های ایستگاهی دارای دقت بسیار بالایی بودند و لذا استفاده از آنها برای منطقه مورد مطالعه که شرایط توپوگرافی خاصی دارد، می تواند دقت انجام پس پردازش را ارتقاء بخشد. دوره آماری مورد استفاده یک دوره ۲۸ ساله، ۱۹۸۰ تا سال ۲۰۰۷ میلادی، در نظر گرفته شد که در هر دو سری داده مدل و آفرودیت بصورت یکنواخت موجود بود. دوره فوق به یک دوره ۲۲ ساله جهت تعیین معادلات رگرسیون چندمتغیره برای تک تک نقاط شبکه و برای ماه های مختلف سال و همچنین یک دوره ۶ ساله جهت ارائه پیش بینی و صحت سنجی پیش بینی ها با داده های واقعی تقسیم بندی شد. سپس نتایج جهت پیش بینی شاخص خشکسالی SPI مورد استفاده قرار گرفت. نتایج حاصل با استفاده از شاخص های آماری مورد صحت و سنجش قرار گرفت. نتایج بیانگر آنست که بکارگیری روش رگرسیون چندمتغیره در پس پردازش خروجی مدل فارغ از بازه مکانی، در فصول پربارش و سرد سال دارای دقت بالاتری بوده و در فصول کم بارش

در جدول فوق صحت پیش بینی شاخص خشکسالی در دوره ۲۰۰۱ تا ۲۰۰۷ برای سلول شبکه ۵۰۵ و همچنین میانگین حاصل از کل ۵۹ شبکه آفرودیتی موجود در منطقه مورد مطالعه آورده شده است، به عبارت دیگر برای هر سال ۱۲ پیش بینی برای شاخص SPI وجود دارد. مطابق این جدول، میزان همبستگی بین مقادیر SPI محاسبه شده از بارش پس پردازش نشده مدل MRI-CGCM3 برای شبکه ۵۰۵ میزان ۰/۰۶۸ بوده که پس از پس پردازش به ۰/۴۶ رسیده است و برای میانگین شبکه ها این میزان از ۰/۰۶۱ به ۰/۴۹ ارتقاء یافته است. همچنین صحت پیش بینی این شاخص مطابق طبقه بندی ارائه شده در جدول ۵ برای شاخص SPI پس پردازش نشده برای شبکه ۵۰۵، به میزان ۶۰/۹ درصد و برای SPI پس پردازش شده ۷۸/۴ درصد شده که این میزان برای میانگین شبکه های مورد مطالعه از ۶۱/۷ درصد به ۷۹/۵ درصد ارتقاء یافته است که نشان دهند ارتقاء صحت پیش بینی این شاخص به میزان ۲۲/۳ درصد پس از اجرای فرآیند پس پردازش آماری است.

نتیجه گیری

با توجه به اهمیت در اختیار داشتن پیش بینی های فصلی و همچنین پیش بینی شرایط خشکسالی برای ماه های آتی در منطقه شمال غرب ایران و بخصوص سه استان آذربایجان شرقی، آذربایجان غربی و اردبیل که تا حدودی حوضه های آبریز دریاچه ارومیه را شامل می شوند و از این حیث دارای اهمیت بسزائی هستند و نیز مدیریت منابع آبی و انرژی در منطقه مذکور که به شدت متأثر از شرایط اقلیمی است، در

- indicators beyond the neural barley yields: a case study for Isfahan, Iran. *International Journal of Ayer* 2:451-469 (In Persian)
5. Fattahi A., y.Sedaghatkendar, 2007, Curve analysis of time and severity of drought frequency: Case study in south west stations of Iran, 5(10):77-90 (in Persian)
 6. Finnis J., W. W.Hsieh, H.Lin, and W.Merryfield, 2011, Nonlinear post-processing of numerical seasonal climate forecasts: *Journal of Atmosphere-Ocean*, 26, 1-34.
 7. Gheti R., 2007, Statistical post-processing of dynamical surface air temperature seasonal predictions using the leading ocean-forecd spatial patterns, Msc Thesis, McGill University, 87pp
 8. Hasanzadeh Y., A. Abdi Kordani, A.Fakherifard, 2012, forecasting drought by using Genetic Algorithm and wavelet-neural network hybrid model. *Journal of Water & Wastewater* 3:48-59 (In Persian)
 9. Jeffrey S., X. Wei, 2005, Improving week two forecast with multi-model re-forecast ensemble. *Monthly Weathear Rviewi*, pp. 1-25.
 10. Johnson C., Swinbank R., 2009, Medium-range multi-model ensemble combination and calibration. UK met-office Technical Note 517:31
 11. Kamiguchi K., O. Arakawa, A. Kitoh, A. Yatagai, A. Hamada, N. Yasutomi, 2010, Development of APHRO_JP, the First Japanese High-resolution Daily Precipitation Product for More than 100 Years, *Hydrol. Res. Lett.*, 4, 60-64.
 12. Kim H., P.J. Webster, J.A. Curry, 2012a, Seasonal Prediction Skill of ECMWF System 4 and NCEP CFSv2 Retrospective Forecast for the Northern Hemisphere Winter, *Climate Dynamics Observational, Theoretical and Computational Research on the Climate System*.
 13. Kim H., P.J. Webster, J.A. Curry, V.E. Toma, 2012b, Asian Summer Monsoon Prediction in ECMWF System 4 and NCEP CFSv2 Retrospective Seasonal Forecasts, *Climate Dynamics Observational, Theoretical and Computational Research on the Climate System*.
 14. Kishtawal C.M., S. Basu, F. Patadia, P.K. Thapliyal, 2003, Forecasting Summer Rainfall over India Using Genetic Algorithm, *Geophys. Res. Lett.*, 30(23), 2203, doi: 10.1029/2003GL018504.
 15. Kitoh A., Arakawa O., 2011, Precipitation Climatology over the Middle East Simulated by the High-Resolution MRI-AGCM3, از دقت کمتری برخوردار است و همچنین میزان اریبی ماهانه بارش نیز از ۶۷ میلیمتر قبل از پس پردازش به ۹ میلیمتر بعد از پس پردازش تقلیل یافته که بیانگر تاثیر مثبت بکارگیری روش پس پردازش بر روی خروجی مدل می باشد. نهایتا با بکارگیری نتایج در شاخص SPI میزان همبستگی شاخص پس پردازش شده و پس پردازش نشده خروجی صحت سنجی گردید که این میزان برای میانگین نقاط شبکه از ۰/۶۱/۰ به ۰/۴۵/۰ افزایش یافت و صحت پیش بینی های طبقه ای نیز از ۶۱/۷ به ۷۹/۵ درصد ارتقاء یافت که این میزان به معنی ارتقاء ۲۲/۵ درصدی استفاده از روش پس پردازش در خروجی مدل است. علاوه بر این، نتایج این تحقیق نشان داد که استفاده از روش پس پردازش بر روی خروجی های مدل می تواند کاربرد نتایج را در مقیاس های مکانی کوچکتر، از دقت بالاتری برخوردار نماید و همچنین استفاده از داده های شبکه ای آفرودیت بجای داده های پراکنده ایستگاهی، می تواند به مراتب رسیدن به نتایج بهتر را ارتقاء بخشد. بکارگیری نتایج پس پردازش شده در شاخص SPI نیز منجر به تبیین مدل جامعی جهت استفاده از شاخص خشکسالی در مقوله پیش بینی خشکسالی گردیده و ارائه پیش بینی های فصلی بلبه خشکسالی را امکان پذیر می نماید و این امر می تواند مدیریت کلان آبی را در مقوله اقلیم و خشکسالی ارتقاء بخشد.

منابع

1. Azadi M., Shirgholami M., Hojam S., Sahraeean F. (2011) Post processing WRF model output for daily precipitation in Iran. *Iran-Water Resources Research* 7(4):71-80 (In Persian)
2. 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).
3. Ensafi Moghadam T., 2007, An Investigation and assessment of climatological indices and determination of suitable index for climatological droughts in the Salt Lake Basin of Iran, 14(2): 271-288 (in Persian)
4. Fathi Margh A., MH.Mahdeian, 2010, Predicting winter precipitation using

- of Climate Research 1(3 and 4):93-106 (In Persian)
23. 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
 24. Wilks D.S., 2008, Improved Statistical Seasonal Forecasts Using Extended Training Data, Int. J. Climatol., 28: 1589-1598.
 25. Yasutomi N., A. Hamada, A. Yatagai, 2011, Development of a Long-term Daily Gridded Temperature Dataset and its Application to Rain/Snow Discrimination of Daily Precipitation, Global Environmental Research.
 26. Yatagai A., K. Kamiguchi, O. Arakawa, A. Hamada, N. Yasutomi, A. Kitoh, 2012, Constructing a Long-Term Daily Gridded Precipitation Dataset for Asia Based on a Dense Network of Rain Gauges, American Meteorological Society.
 27. 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
 28. 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
 29. Zheng, X., and Renwick J. A., 2003, a regression-based scheme for seasonal forecasting of New Zealand temperature: Journal of Climate, 16, 1843-1853
 16. Krishnamurti, T. K., C. M., Kishtawal, Z., Zhang, T., Larow, D., Bachiochi, E., Williford, 2000, Multimodel ensemble forecasts for weather and seasonal climate, Journal of Climate, NO. 13, pp. 4196-4216.
 17. Kusunoki S., C. Kobayashi, 2003, Skill Evaluation of Probabilistic Forecasts by the Atmospheric Seasonal Predictability Experiments, Journal of the Meteorological Society of Japan, Vol. 81, No. 1, pp. 85-112, 2003 85.
 18. Lee, J. Y., 2003, Data and Model Description, Assessment of Potential Seasonal Predictability with a Multi-Model Dynamical- Statistical Ensemble System: Ph.D. thesis, Faculty of the Graduate School of the Seoul National University.
 19. Lim Y.K., S. Cocke, D.W. Shin, J.T. Schoof, T.E. LaRow, J.J. O'Brien, 2009, Downscaling Large-Scale NCEP CFS to Resolve Fine-Scale Seasonal Precipitation and Extremes for the Crop Growing Seasons over the Southeastern United States, Climate Dynamics Observational, Theoretical and Computational Research on the Climate System.
 20. McCollor D., Stull R., 2008, Hydrological accuracy enhancement via post processing of numerical weather forecasts in complex terrain, Weather and Forecasting 23:131-144
 21. Rasu A.G.G., T. Mahmood, Q. Zaman, S.B. Cheema, 2012, Validation of APHRODITE Precipitation Data for Humid and Sub Humid Regions of Pakistan, Pakistan Journal of Meteorology, Vol.9, Issue 17.
 22. Rastgu Z, Azadi M, Hojani 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 Global Environmental Research, 15/2011: 139-146