

## Development of Monthly Ensemble Precipitation Forecasting System in Sefidrud Basin, IRAN

HOSSEIN DEHBAN<sup>1</sup>, KUMARS EBRAHIMI<sup>1\*</sup>, SHAHAB ARAGHINEJAD<sup>1</sup>, JAVAD BAZRAFESHAN<sup>1</sup>

1. Department of Irrigation and Reclamation Engineering, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran.

(Received: July. 20, 2019- Revised: Dec. 17, 2019- Accepted: Dec. 17, 2019)

### ABSTRACT

Precipitation forecasting is one of the most important tools in water resources planning and management. Recently, new methods called atmospheric dynamic models have been used to predict many hydro-climate variables including precipitation. Before using the predictions of these models in planning and decision making, the accuracy of the mentioned predictions and their bias correction should be evaluated. Therefore the objective of this study is to ascertain the biases and to combine the results of precipitation forecasting with a set of global dynamic forecasting models. To achieve this aim, firstly the precipitation forecast results of each model were compared separately with the regional recorded precipitation data in the period of 1982 to 2017. Using this approach, the systematic errors were removed and corrected, i.e. using the quantile mapping method. This work was done for different forecast periods and also for different months. Furthermore, based on the accuracy of each model, a hybrid/multi-model prediction system was developed using Bayesian averaging method (BMA). The results showed that after the bias correction, using the quantitative mapping, at least one model among 78 prediction models have a relatively high correlation value of about 0.7. This result was recorded for the next one-month horizon. This correlation was increased to more than 0.8, by combining 78 predictive members, using Bayesian averaging method. Therefore, the accuracy of the predicted precipitation increases significantly using bias correction in tandem with combining the prediction models.

**Keywords:** Precipitation Forecasting, NMME Models, Uncertainty, Bayesian Model Averaging, Quantile Mapping.

## توسعه سامانه پیش‌بینی چند مدلی بارش ماهانه در حوضه آبریز سفیدرود

حسین دهبان<sup>۱</sup>، کیومرث ابراهیمی<sup>۱\*</sup>، شهاب عراقی‌نژاد<sup>۱</sup>، جواد بذرافشان<sup>۱</sup>

۱. گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران.

(تاریخ دریافت: ۱۳۹۸/۴/۲۹ - تاریخ بازنگری: ۱۳۹۸/۹/۲۶ - تاریخ تصویب: ۱۳۹۸/۹/۲۶)

### چکیده

پیش‌بینی بارش یکی از ابزارهای مهم در برنامه‌ریزی و مدیریت منابع آب به حساب می‌آید. اخیراً از روش‌های جدیدی به نام مدل‌های دینامیکی جو برای پیش‌بینی بسیاری از متغیرهای هیدرو-اقلیمی از جمله بارش استفاده می‌شود. قبل از استفاده از پیش‌بینی‌های این مدل‌ها در برنامه‌ریزی و تصمیم‌گیری، لازم است ارزیابی دقت و تصحیح آریبی آن‌ها انجام شود. از این رو هدف مقاله حاضر، تصحیح آریبی و ترکیب نتایج پیش‌بینی بارش مربوط به مجموعه‌ای از مدل‌های پیش‌بینی دینامیکی جهانی می‌باشد. برای این کار، ابتدا نتایج پیش‌بینی بارش هریک از مدل‌ها به صورت جداگانه با داده‌های بارش ایستگاهی منطقه برای دوره تاریخی ۱۹۸۲ تا ۲۰۱۷ مقایسه شدند و خطای سامانمند هریک از آن‌ها به روش نگاشت چندک تصحیح شد. این کار برای افق‌های پیش‌بینی مختلف و برای پیش‌بینی‌های صادره از ماه‌های مختلف انجام شده است. در گام بعدی متناسب با دقت هر یک از مدل‌های پیش‌بینی، سامانه پیش‌بینی ترکیبی یا چند مدلی با استفاده از روش میانگین‌گیری بیزین توسعه داده شد. نتایج نشان داد پس از تصحیح آریبی به روش نگاشت چندک، حداقل یک مدل پیش‌بینی از ۷۸ مدل پیش‌بینی دارای همبستگی نسبتاً بالا در حدود ۰/۷ می‌باشد. این نتیجه برای افق پیش‌بینی ۱ ماه آینده بیشتر دیده شد. بعد از ترکیب ۷۸ عضو پیش‌بینی با استفاده از روش میانگین‌گیری بیزین، این میزان همبستگی به بیشتر از ۰/۸ افزایش یافت. بنابراین با تصحیح آریبی و ترکیب مدل‌های پیش‌بینی با یکدیگر، دقت بارش پیش‌بینی‌شده به مقدار قابل توجهی افزایش می‌یابد.

**واژه‌های کلیدی:** پیش‌بینی بارش، مدل‌های NMME، عدم قطعیت، میانگین‌گیری بیزین، نگاشت چندک.

### مقدمه

پیش‌بینی بارش و جریان آب سطحی به خصوص جریان ورودی به مخازن یکی از فاکتورهای مهم در برنامه‌ریزی و مدیریت منابع آب به حساب می‌آید. تاکنون پیش‌بینی بارش ماهانه عموماً با استفاده از روش‌های مختلفی از جمله روش‌های مرسوم به مدل‌های سری زمانی خود همبسته (Han et al., 2010)، شبکه‌های عصبی (Le et al., 2017)، یادگیری عمیق (Bai et al., 2016)، تحلیل طیف تکین (Foroughi and Araginejad, 2017)، شبکه‌های عصبی رگرسیون تعمیم‌یافته (Modarresi et al., 2016) و روش رگرسیون چند متغیره خطی و رگرسیون بردار پشتیبان (Abbasi et al., 2019) انجام شده است. این روش‌ها معروف به روش‌های داده‌مبنا بوده و در بیشتر موارد خیلی قابل اعتماد نمی‌باشند؛ زیرا خصوصیات فیزیکی و فرآیندهای موجود در سامانه‌های اقلیمی را در نظر نمی‌گیرند. در مقابل، مدل‌های دیگری تحت عنوان مدل‌های دینامیکی اقلیمی برای پیش‌بینی وجود دارد که سامانه‌های جو-اقیانوس-زمین و اندرکنش بین

آن‌ها را بهتر شبیه‌سازی می‌کنند (Xu et al., 2018). این نوع از مدل‌ها اطلاعاتی از خصوصیات اقلیمی از جمله وضعیت بارش ماهانه برای آینده را تولید می‌کنند که می‌تواند برای پیش‌بینی هیدرولوژیکی نیز قابل استفاده باشد (Zhao et al., 2019). مدل‌های اقلیمی در حال حاضر توسط مراکز اقلیمی معتبر برای تولید پیش‌بینی‌های عملیاتی، اجرا می‌شوند (Jia et al., 2015). تعداد زیادی از این نوع مدل‌ها که بیشتر به‌عنوان مدل‌های دینامیک جو شناخته می‌شوند برای پیش‌بینی‌های هواشناسی و اقلیمی در مقیاس زمانی روزانه، هفته‌ای و ماهانه توسعه داده شده‌اند (از جمله مدل‌های <sup>۱</sup>CFSv2، <sup>۲</sup>ECMWF). با وجود اینکه پیشرفت‌های زیادی که در زمینه مدل‌های دینامیک جو حاصل شده است، همواره باید دقت کرد که قبل از استفاده از پیش‌بینی‌های حاصل از مدل‌های دینامیکی، این پیش‌بینی‌ها پس‌پردازش و تصحیح آریبی شوند (Xu et al., 2019)، زیرا این مدل‌ها به دلیل عدم قطعیت موجود در شرایط اولیه و ساختار خود، دارای خطا هستند (Ahmadalipour et al., 2018). روش‌های متعددی برای پس‌پردازش خروجی مدل‌های دینامیکی وجود

با پیش‌بینی جریان آب با استفاده از جفت کردن مدل‌های دینامیکی اقلیمی با مدل‌های هیدرولوژیکی، پژوهشی در کشور چین با هدف مدیریت بهتر منابع آب و انرژی انجام شد. نتایج آن‌ها نشان داد که ارائه پیش‌بینی‌های به صورت چند مدلی حاصل از مدل‌های دینامیک جو و مدل‌های هیدرولوژیکی باعث افزایش پتانسیل پیش‌بینی جریان برای افق‌های پیش‌بینی طولانی‌تر می‌شود (Liu et al., 2019). بنابراین نتایج مطالعات گذشته نشان می‌دهد که پس‌پردازش مدل‌های پیش‌بینی دینامیکی و ترکیب مدل‌های مختلف پیش‌بینی با یکدیگر، باعث بهبود در دقت پیش‌بینی‌ها خواهد شد. از طرفی با توجه به اینکه پیش‌بینی ماهانه و فصلی بارش در زمینه‌های مختلف از جمله مدیریت منابع آب، کاربردی و ارزشمند است، پیش‌بینی‌های صورت گرفته باید قابل اعتماد و دارای دقت کافی باشند تا برای تصمیم‌گیران قابل ارائه باشد. از این رو به دلیل وجود خطای سامانمند در مدل‌های اقلیمی، باعث ایجاد ضرورت استفاده از روش‌های پس‌پردازش برای تصحیح خطاهای موجود در پیش‌بینی بارش می‌شود. از طرفی نیز با ترکیب نتایج پیش‌بینی مدل‌های اقلیمی مختلف می‌توان به پیش‌بینی‌های دقیق‌تر و قابل اعتماد دست یافت. بنابراین با توجه به اینکه پتانسیل خوبی در زمینه پیش‌بینی بارش در مقیاس ماهانه و فصلی حاصل از مدل‌های اقلیمی در جهان به وجود آمده است لذا در مقاله حاضر، هدف استفاده از روش پس‌پردازش به منظور تصحیح اریبی پیش‌بینی‌ها و ترکیب نتایج مدل‌های مختلف با یکدیگر است تا بتوان دقت پیش‌بینی بارش ماهانه حاصل از مدل‌های اقلیمی را در منطقه مورد بررسی (حوضه آبریز سفیدرود) افزایش داد. این در صورتی است که تاکنون در کشور ایران برای تولید چنین پیش‌بینی‌هایی، عمدتاً از روش‌های داده مبنای مبتنی بر داده‌های مشاهداتی استفاده شده است. لذا در پژوهش حاضر به جای استفاده از روش‌های سنتی در پیش‌بینی بارش، از مدل‌های دینامیکی اقلیم برای پیش‌بینی بارش ماهانه بهره گرفته شده است.

## مواد و روش‌ها

### منطقه مورد مطالعه

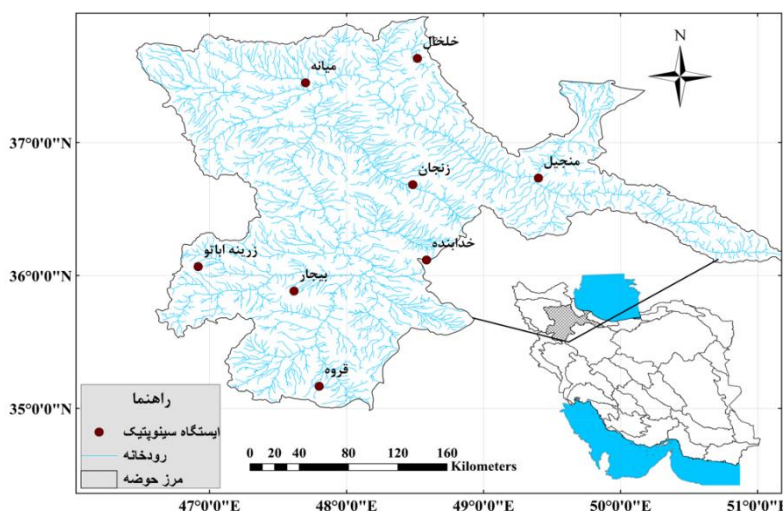
حوضه آبریز سفیدرود در تقسیم‌بندی کلی هیدرولوژی ایران، بخشی از حوضه آبریز دریای خزر محسوب شده و در محدوده تلاقی رشته‌کوه‌های البرز، زاگرس و مرکزی قرار دارد. این حوضه آبریز بین مختصات جغرافیائی ۲۷°-۴۶° تا ۱۱°-۵۱° طول شرقی و ۳۴°-۵۳° تا ۳۷°-۵۶° عرض شمالی قرار گرفته است که از شمال به حوضه‌های آبریز تالش و ارس، از شرق به حوضه‌های

دارد که می‌توان با تکیه بر آن‌ها، تا حدودی دقت پیش‌بینی‌های حاصل از مدل‌های دینامیکی را افزایش داد. در سال‌های اخیر استفاده از پیش‌بینی ترکیبی (همادی) حاصل از چندین مدل پیش‌بینی اقلیمی برای افزایش دقت پیش‌بینی‌ها در مقیاس ماهانه توسعه یافته است (Xu et al., 2018). مطالعات مختلفی نشان می‌دهد که پیش‌بینی‌های چند مدلی نسبت به پیش‌بینی‌های حاصل از مدل‌های منفرد، از عملکرد بالاتری برخوردار هستند (Ma et al., 2016). این در حالی است که رشد فعلی مدل‌های دینامیکی اقلیمی در مؤسسات مختلف باعث شده است تا زمینه ترکیب مدل‌های مختلف اقلیمی فراهم شود و امکان ارائه پیش‌بینی‌های ماهانه و فصلی چند مدلی در نقاط مختلف دنیا وجود داشته باشد. در ارتباط با توسعه سامانی پیش‌بینی چند مدلی اقلیمی، مرکز پیش‌بینی چند مدلی آمریکای شمالی (NMME<sup>۱</sup>) که متشکل از مجموعه‌ای از مدل‌های اقلیمی گردش عمومی جو است، پیش‌بینی برخی از پارامترهای اقلیمی از جمله دمای ارتفاع ۲ متری، دمای سطح دریا، رطوبت خاک و بارش را در مقیاس زمانی ماهانه و فصلی به صورت همادی برای تمام دنیا فراهم کرده است (Narapusetty et al., 2018). برخی از مطالعات گزارش کرده‌اند که مرکز NMME توانسته است با همکاری چندین مرکز پیش‌بینی اقلیمی، عدم قطعیت موجود در پیش‌بینی‌های اقلیمی را نیز کاهش دهد (Xu et al., 2019). در حال حاضر نیز بسیاری از پژوهش‌ها به ارزیابی مدل‌های NMME در نقاط مختلف جهان پرداخته‌اند ولی هنوز دقت پیش‌بینی این مدل‌ها در بسیاری از مناطق و مقیاس‌های محلی، نیاز به بررسی بیشتر دارد (Manganello et al., 2017). پژوهش‌های انجام شده در ارتباط با ارزیابی و تصحیح اریبی پیش‌بینی‌های حاصل از مدل‌های دینامیکی، بیانگر بهبود پیش‌بینی‌های بعد از انجام پس‌پردازش آماری است (Barbero et al., 2017; Khajehei et al., 2018). برای مثال پژوهشی در کشور آلمان در ارتباط با پس‌پردازش و ترکیب مدل‌های پیش‌بینی با هدف افزایش دقت پیش‌بینی بارش و دما انجام شد (Courbariaux et al., 2018). در پژوهش دیگری نیز جهت برطرف نمودن ضعف‌های موجود در پیش‌بینی‌های فصلی حاصل از مدل‌های دینامیکی در پیش‌بینی بارش و دمای ماهانه، از رویکرد پس‌پردازش و ترکیب مدل‌های پیش‌بینی آماری مبتنی بر داده تاریخی مدل‌های دینامیکی استفاده شد. مدل‌های دینامیکی مورد استفاده در پژوهش آن‌ها مربوط به مرکز پیش‌بینی NMME بود. نتایج آن‌ها نشان داد که به‌کارگیری روش‌های پس‌پردازش در مدل‌های پیش‌بینی و ارائه پیش‌بینی‌های ترکیبی باعث بهبود در دقت پیش‌بینی‌های فصلی و ماهانه بارش و دما می‌شود (Strazzo et al., 2019). در ارتباط

شرقی، اردبیل، تهران، زنجان، قزوین، کردستان، گیلان و همدان می‌باشند. در شکل (۱)، منطقه مورد مطالعه و پراکندگی ایستگاه‌های مورد استفاده که در ادامه در مورد آن‌ها توضیح داده شده است، ارائه شده است.

جدول (۱) مشخصات ایستگاه‌های همدیدی موجود در منطقه با طول آماری مناسب را که به‌عنوان ایستگاه‌های مبنا به‌منظور ارزیابی مدل‌های پیش‌بینی مورد استفاده قرار گرفته است، نشان می‌دهد.

آبریز دریای نمک و هراز تا سفیدرود، از غرب به حوضه دریاچه ارومیه و از جنوب به حوضه‌های کرخه و سیروان منتهی می‌گردد. حوضه آبریز قزل‌اوزن-سفیدرود بعد از حوضه دریاچه نمک از نظر اراضی قابل آبیاری بزرگ‌ترین حوضه کشور است. مساحت این حوضه ۶۳۹۴۵ کیلومترمربع می‌باشد. این حوضه آبریز از دو شاخه رودخانه‌ای اصلی به نام قزل‌اوزن و شاهرود تشکیل یافته است که در محل سد سفیدرود به هم می‌پیوندند و رودخانه سفیدرود را تشکیل می‌دهند. ذینفعان این حوضه شامل استان‌های آذربایجان



شکل ۱- موقعیت حوضه آبریز سفیدرود و پراکندگی ایستگاه‌های همدیدی واقع در آن

اربابی و مقیاس‌گاهی بارش پیش‌بینی‌شده از طریق مقایسه با داده‌های بارش مشاهداتی تاریخی ثبت‌شده در ایستگاه‌های همدیدی، انجام شد. برای ارزیابی و تحلیل عدم قطعیت موجود در پیش‌بینی بارش، از روش همادی یا ترکیب مدل‌های پیش‌بینی بارش و با در نظر گرفتن ۷۸ عضو پیش‌بینی، استفاده شد.

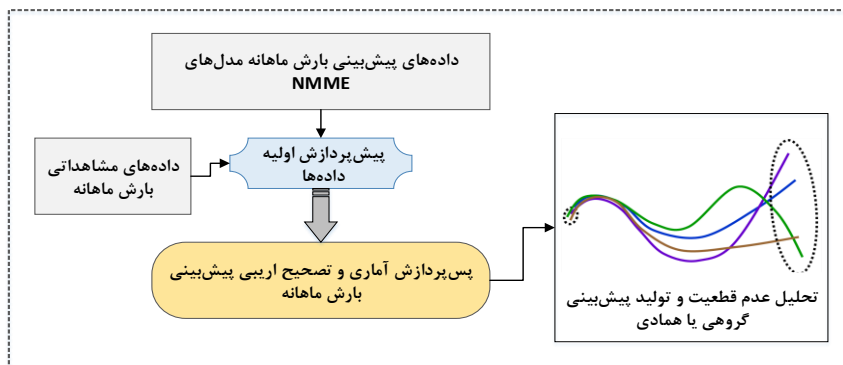
#### داده‌های پیش‌بینی بارش

داده‌های پیش‌بینی دوره تاریخی مدل‌های NMME از موسسه تحقیقات بین‌المللی دانشگاه کلمبیا<sup>۱</sup> دریافت شد. تفکیک مکانی این مدل‌ها یک درجه و تفکیک زمانی آن‌ها، ماهانه می‌باشد. مشخصات مربوط به مدل‌های NMME مورد استفاده برای پیش‌بینی بارش در جدول (۲) ارائه شده است. لازم به ذکر است که در پژوهش حاضر از ۷۸ عضو همادی حاصل از شش مدل پیش‌بینی به‌منظور ارائه پیش‌بینی همادی بارش استفاده شد.

جدول ۱- مشخصات ایستگاه‌های همدیدی واقع در منطقه مورد مطالعه

نام ایستگاه	طول جغرافیایی	عرضی جغرافیایی	متوسط بارش بلندمدت
میانه	۴۷/۷۰	۳۵/۴۵	۲۷۵
خلخال	۴۸/۵۲	۳۷/۶۳	۳۷۳
خدابنده	۴۸/۵۸	۳۶/۱۲	۳۹۴
زنجان	۴۸/۴۸	۳۶/۶۸	۲۹۱
بیجار	۴۷/۶۲	۳۵/۸۸	۳۳۷
زرینه اباتو	۴۶/۹۲	۳۶/۰۶	۳۷۳
قروه	۴۷/۸۰	۳۵/۱۷	۳۳۰
منجیل	۴۹/۴۰	۳۶/۷۳	۲۱۲

مطابق با شکل (۲) که در آن مراحل کلی انجام پژوهش حاضر ارائه شده است، ابتدا نتایج پیش‌بینی دوره تاریخی بارش ماهانه حاصل از مدل‌های پیش‌بینی NMME برای منطقه مورد مطالعه (حوضه آبریز سفیدرود) دریافت شدند، سپس تصحیح



شکل ۲- مراحل کلی انجام پژوهش

جدول ۲- مشخصات مدل‌های پیش‌بینی دینامیکی مورد استفاده مربوط به مرکز NMME (Kirtman et al., 2014)

مدل	مرکز توسعه‌دهنده	دوره پیش‌بینی تاریخی	قدرت تفکیک مکانی	افق پیش‌بینی
CVSv2	مرکز ملی پیش‌بینی‌های زیست‌محیطی آمریکا	۱۹۸۲ تاکنون		
COLA-RSMAS-CCSM4	مرکز مطالعات جو-اقیانوس-زمین آمریکا			
CMC1-CanCM3	مرکز پیش‌بینی زیست‌محیطی کانادا	۱۹۸۱ تاکنون	۱ درجه	۱ تا ۱۱ ماه
CMC2-CanCM4				
GFDL-CM2p5-FLOR-A06	آزمایشگاه دینامیک شماره‌ها و ژئوفیزیک آمریکا	۱۹۸۰ تاکنون		
GFDL-CM2p5-FLOR-B01				

داده‌های بارش ماهانه‌ی ایستگاه‌های همدیدی واقع در حوضه آبریز سفیدرود از سازمان هواشناسی کشور برای دوره ۱۹۸۲ تا ۲۰۱۷ تهیه و بعد از کنترل کیفی آماری آن‌ها شامل بررسی همگنی داده‌ها و حذف داده‌های ناهمگون، به عنوان داده‌های مرجع بارش ماهانه به منظور مقایسه با بارش پیش‌بینی شده در نظر گرفته شد.

#### روش تصحیح اریبی

قبل از استفاده پیش‌بینی بارش، با به‌کارگیری روش نگاشت چندک ( $QM^1$ )، هر یک از مدل‌های پیش‌بینی به صورت نقطه‌ای در محل ایستگاه‌های همدیدی تصحیح اریبی شدند (برای مطالعه بیشتر، رجوع شود به Gudmundsson et al., 2012). روش QM با استفاده از توابع توزیع تجمعی سری بارش مشاهده‌ای و پیش‌بینی شده و مقایسه آن‌ها با یکدیگر، باعث حذف اریبی از مقادیر بارش پیش‌بینی شده می‌شود (Voisin et al., 2010). روش نگاشت چندک برای ۷۸ عضو از مدل‌های پیش‌بینی و برای پیش‌بینی ۱ تا ۳ ماه آینده در هر ایستگاه همدیدی به کار برده شد به این صورت که چندک هر یک از اعضای مدل‌های پیش‌بینی جهانی برای هر ماه، متناسب با توزیع احتمال تجمعی آن، محاسبه شده و با چندک مشابه در تابع احتمال تجمعی مقادیر

داده‌های پیش‌بینی بارش ماهانه دوره تاریخی مدل‌های NMME (از سال ۱۹۸۲ تا ۲۰۱۷ برای ماه‌های مختلف) برای افق پیش‌بینی تا ۳ ماه آینده برای حوضه آبریز سفیدرود دریافت شد. برای مثال، پیش‌بینی‌هایی که در اول ماه ژانویه برای افق پیش‌بینی ۱ تا ۳ ماه آینده ارائه می‌شود به ترتیب بارش ماه‌های ژانویه، مارس و آوریل را پیش‌بینی می‌کنند. لازم به ذکر است که برای ارزیابی و پس‌پردازش آماری به منظور تصحیح اریبی مدل‌های پیش‌بینی و بررسی عدم قطعیت آن‌ها، این مدل‌ها برای ماه‌های مختلف در دوره تاریخی (مطابق با جدول ۲) اجرا شده‌اند و طیف وسیعی از اطلاعات پیش‌بینی از دوره گذشته را به منظور ارزیابی دقت آن‌ها، در اختیار قرار داده‌اند. همچنین ذکر این نکته ضروری است که برای ماه‌هایی از سال، داده‌های پیش‌بینی بارش برای آن‌ها دریافت شد که متناسب با آن‌ها، میزان بارش در کشور قابل توجه است اما به دلیل حجم زیاد محاسبات و نتایج حاصل، در مقاله حاضر تنها بخشی از نتایج به صورت نمونه و برای پیش‌بینی بارش ارائه شده از اول ماه ژانویه تا افق پیش‌بینی ۱ تا ۳ ماه آینده گزارش شده است.

#### داده‌های مشاهده‌ای

به منظور ارزیابی مدل‌های NMME در پیش‌بینی بارش ماهانه،

مشاهدات جایگزین شد. روش QM به صورت رابطه (۱) ارائه می‌شود (Voisin et al., 2010):

$$P_o = F_o^{-1}(F_s(P_s)) \quad (\text{رابطه ۱})$$

که در آن،  $P_o$ : بارش مشاهداتی،  $F_o$ : تابع توزیع تجمعی بارش مشاهداتی،  $F_s$ : تابع توزیع تجمعی بارش پیش‌بینی شده و  $P_s$ : بارش پیش‌بینی شده می‌باشد. لازم به ذکر است که برای پیاده‌سازی روش اصلاح اربیبی QM از محیط برنامه‌نویسی R<sup>۱</sup> استفاده شد.

### ترکیب نتایج مدل‌های پیش‌بینی

به منظور ترکیب نتایج مدل‌های مختلف پیش‌بینی بارش با در نظر گرفتن ۷۸ عضو پیش‌بینی، از روش میانگین‌گیری بیزی (BMA<sup>۲</sup>) استفاده شد. روش BMA از جمله روش‌های ترکیبی اطلاعات حاصل از مدل‌های مختلف و بررسی تحلیل عدم قطعیت موجود در مدل‌های پیش‌بینی است. در این روش، وزن‌ها یا اثربخشی هر مدل در نتیجه نهایی، وابسته به میزان پشتیبانی داده‌ها از هر مدل است. این وزن‌ها با استفاده از احتمال پسین هر مدل محاسبه می‌شود. روش BMA به صورت رابطه (۲) ارائه شده است (Raftery et al., 2005).

$$W_k = P(f_k | y^T) \quad (\text{رابطه ۲})$$

که در آن  $y$ : متغیر پیش‌بینی مربوط به مدل پیش‌بینی و  $P_k(y | f_k, y^T)$ : تابع احتمال شرطی متناظر با  $y$  متناسب با تابع چگالی احتمال مدل ( $f_k$ )، متغیر  $k$ : تعداد مدل‌های پیش‌بینی و  $W_k$ : احتمال پسین انتخاب مدل  $k$  می‌باشد. لازم به یادآوری است که مجموع  $W_k$  برابر یک خواهد بود. در مقاله حاضر با استفاده از روش میانگین‌گیری بیزی، تعداد ۷۸ عضو پیش‌بینی بارش حاصل از ۶ مدل اقلیمی، با یکدیگر ترکیب شدند. این کار با استفاده از کتابخانه ENSEMBLEBMA موجود در محیط برنامه‌نویسی نرم‌افزار R صورت گرفت.

### معیار سنجش عدم قطعیت

برای سنجش عدم قطعیت، ضرایب P-Factor و R-Factor برای ۷۸ عضو از مدل‌های پیش‌بینی محاسبه شدند. ضریب P-Factor نشان دهنده درصد داده‌های مشاهداتی در طول دوره تاریخی است که درون باند عدم قطعیت ۹۰ درصد (۹۰ درصد در مقاله حاضر) حاصل از ۷۸ عضو پیش‌بینی قرار می‌گیرد و مقدار بهینه آن برابر با یک است (Abbaspur., 2009). اگر میانگین فاصله بین

باند بالا و پایین ( $\bar{d}$ ) به صورت رابطه (۳) نشان داده شود:

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n (B_u - B_l)_i \quad (\text{رابطه ۳})$$

که در آن،  $n$ : تعداد داده‌های مشاهداتی در دوره تاریخی است. در شرایطی که میزان عدم قطعیت موجود در پیش‌بینی‌ها کم باشد، مقدار  $\bar{d}$  نزدیک به صفر خواهد بود ولی به دلیل وجود خطا در داده‌های مشاهداتی و عدم قطعیت موجود در مدل‌های پیش‌بینی، چنین حالتی اتفاق نمی‌افتد. به همین دلیل برای ارزیابی مقدار  $\bar{d}$ ، معمولاً از ضریب R-Factor که به صورت رابطه (۴) محاسبه می‌شود.

$$R - Factor = \frac{\bar{d}}{\sigma} \quad (\text{رابطه ۴})$$

که در آن  $\sigma$ : انحراف معیار داده‌های مشاهداتی در دوره تاریخی می‌باشد. مقدار بهینه ضریب R-Factor کمتر از ۱ و نزدیک به صفر می‌باشد (Yang et al., 2014).

بعد از اینکه داده‌های پیش‌بینی بارش در دوره تاریخی برای ۷۸ عضو از ۶ مدل پیش‌بینی برای منطقه مورد مطالعه دریافت شد در هر ایستگاه، گره‌های پیش‌بینی مجاور آن برای هر مدل پیش‌بینی انتخاب شدند و بعد از اعمال تصحیح اربیبی در هر گره و برای هر عضو از مدل پیش‌بینی، بهترین گره پیش‌بینی متناظر با هر مدل برای ایستگاه مورد نظر انتخاب شد. معیار انتخاب بهترین گره پیش‌بینی بر اساس بیشینه ضریب همبستگی (COR<sup>۳</sup>) و کمینه جذر میانگین مربعات خطا (RMSE<sup>۴</sup>) بین بارش پیش‌بینی شده و مشاهداتی در ایستگاه مورد نظر، در نظر گرفته شد. در نهایت در هر ایستگاه، ۷۸ پیش‌بینی بارش اصلاح‌شده به دست آمد. سپس در مرحله بعد با استفاده از روش میانگین‌گیری بیزی، ۷۸ مدل پیش‌بینی بارش با هم ترکیب و پیش‌بینی واحد بارش به حاصل شد.

برای مقایسه مقادیر بارش پیش‌بینی شده و مقدار مشاهداتی متناظر با آن، از سه شاخص جذر میانگین مربعات خطا، ضریب همبستگی و شاخص نش-ساتکلیفت (NSE<sup>۵</sup>) استفاده شد. مقدار هر یک از این شاخص‌ها از رابطه‌های (۵) الی (۷) محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - F_i)^2}{N}} \quad (\text{رابطه ۵})$$

$$Corr = \frac{\sum (O_i - \bar{O})(F_i - \bar{F})}{\sqrt{\sum (O_i - \bar{O})^2 \sum (F_i - \bar{F})^2}} \quad (\text{رابطه ۶})$$

$$NSE = 1 - \frac{\sum (O_i - F_i)^2}{\sum (O_i - \bar{O})^2} \quad (\text{رابطه ۷})$$

4. Root Mean Square Error

5. Nash-Sutcliffe model efficiency coefficients

1. <https://www.r-project.org/> (Last access, Jul 2019)

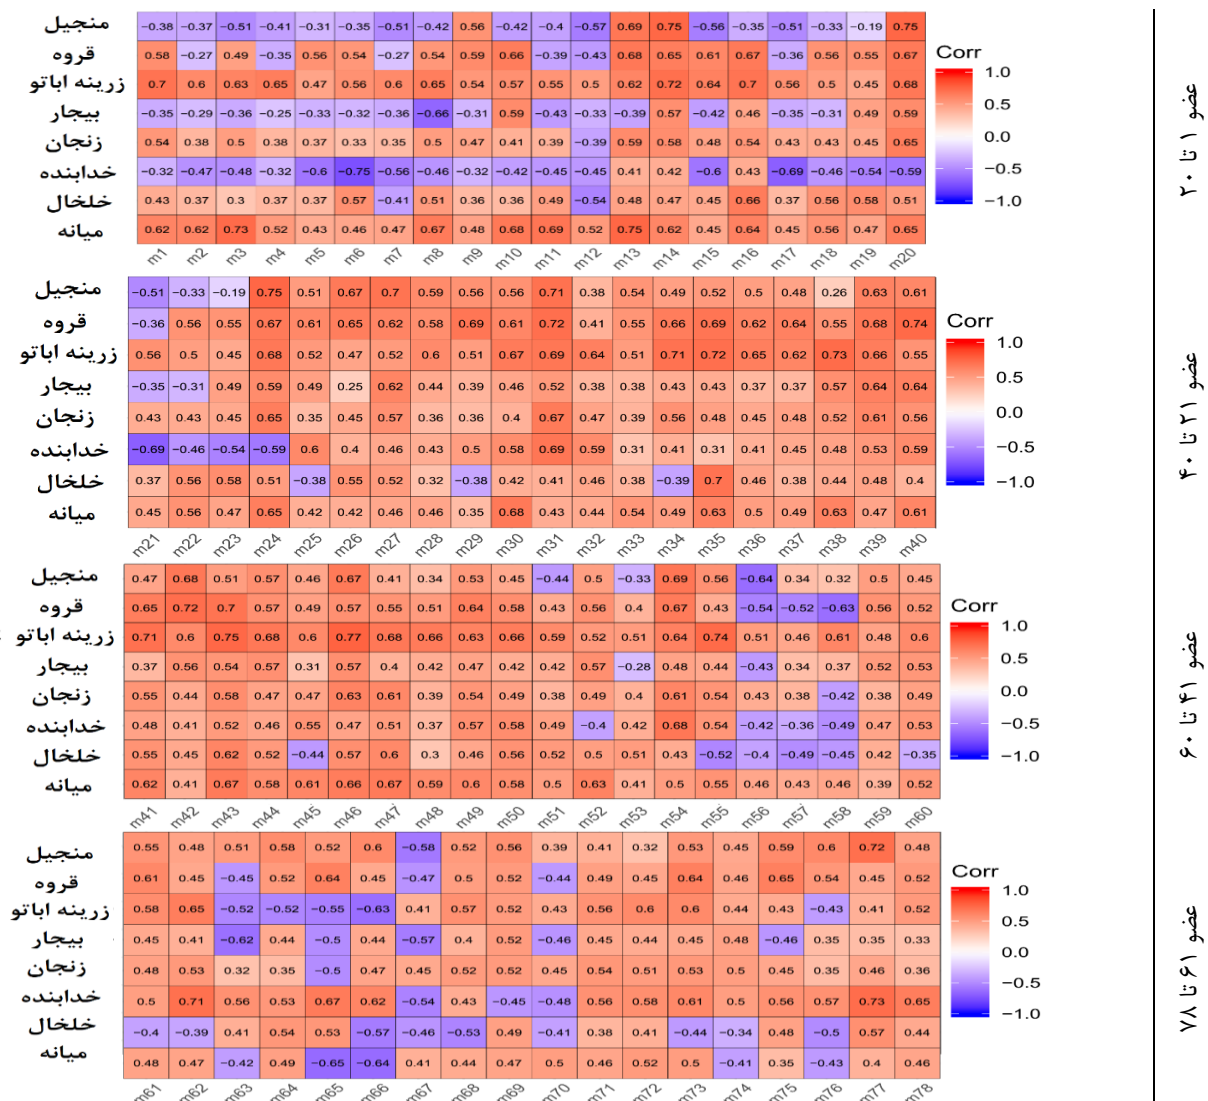
2. Bayesian model averaging

3. Correlation

در شکل‌های (۳) و (۴)، نتایج مربوط به ضریب همبستگی بین بارش مشاهداتی ماه ژانویه و بارش پیش‌بینی‌شده به ترتیب برای افق پیش‌بینی از ۱ و ۲ ماه آینده برای ۷۸ عضو از مدل‌های پیش‌بینی (بعد اعمال تصحیح اریبی با روش نگاشت چندک) ارائه شده است. هریک از شکل‌های مذکور (۳ و ۴) از چهار بخش تشکیل شده که در مجموع بیانگر ۷۸ عضو مدل‌های پیش‌بینی می‌باشند. به عبارت دیگر برای هر ایستگاه، ۷۸ عضو پیش‌بینی بارش با بارش مشاهداتی ایستگاه مقایسه شده و ضریب همبستگی هریک از آن‌ها ارائه شده است.

که در آن،  $F_i$ : مقدار بارش پیش‌بینی‌شده مدل،  $O_i$ : مقدار بارش مشاهداتی،  $N$ : تعداد مشاهدات،  $\bar{F}$ : میانگین پیش‌بینی هر مدل در دوره تاریخی و  $\bar{O}$ : میانگین مشاهدات در دوره تاریخی است. هر چه میزان شاخص‌های RMSE و NSE کمتر و میزان Corr به یک نزدیک‌تر باشد، مدل پیش‌بینی از دقت بالاتری برخوردار است.

### نتایج و بحث



شکل ۳- ضریب همبستگی مربوط به هریک از اعضای پیش‌بینی در مقایسه با بارش ایستگاهی-افق پیش‌بینی ۱ ماه

منجیل، عضوهای پیش‌بینی ۱۴، ۲۰ و ۲۴ ضریب همبستگی ۰/۷۵ را دارند. در واقع عضوهایی از ۷۸ عضو پیش‌بینی وجود دارد که از دقت مطلوبی از نظر همبستگی برخوردار بوده و دارای ارزش بیشتری برای ترکیب نتایج ۷۸ عضو نسبت به سایر اعضا باشد.

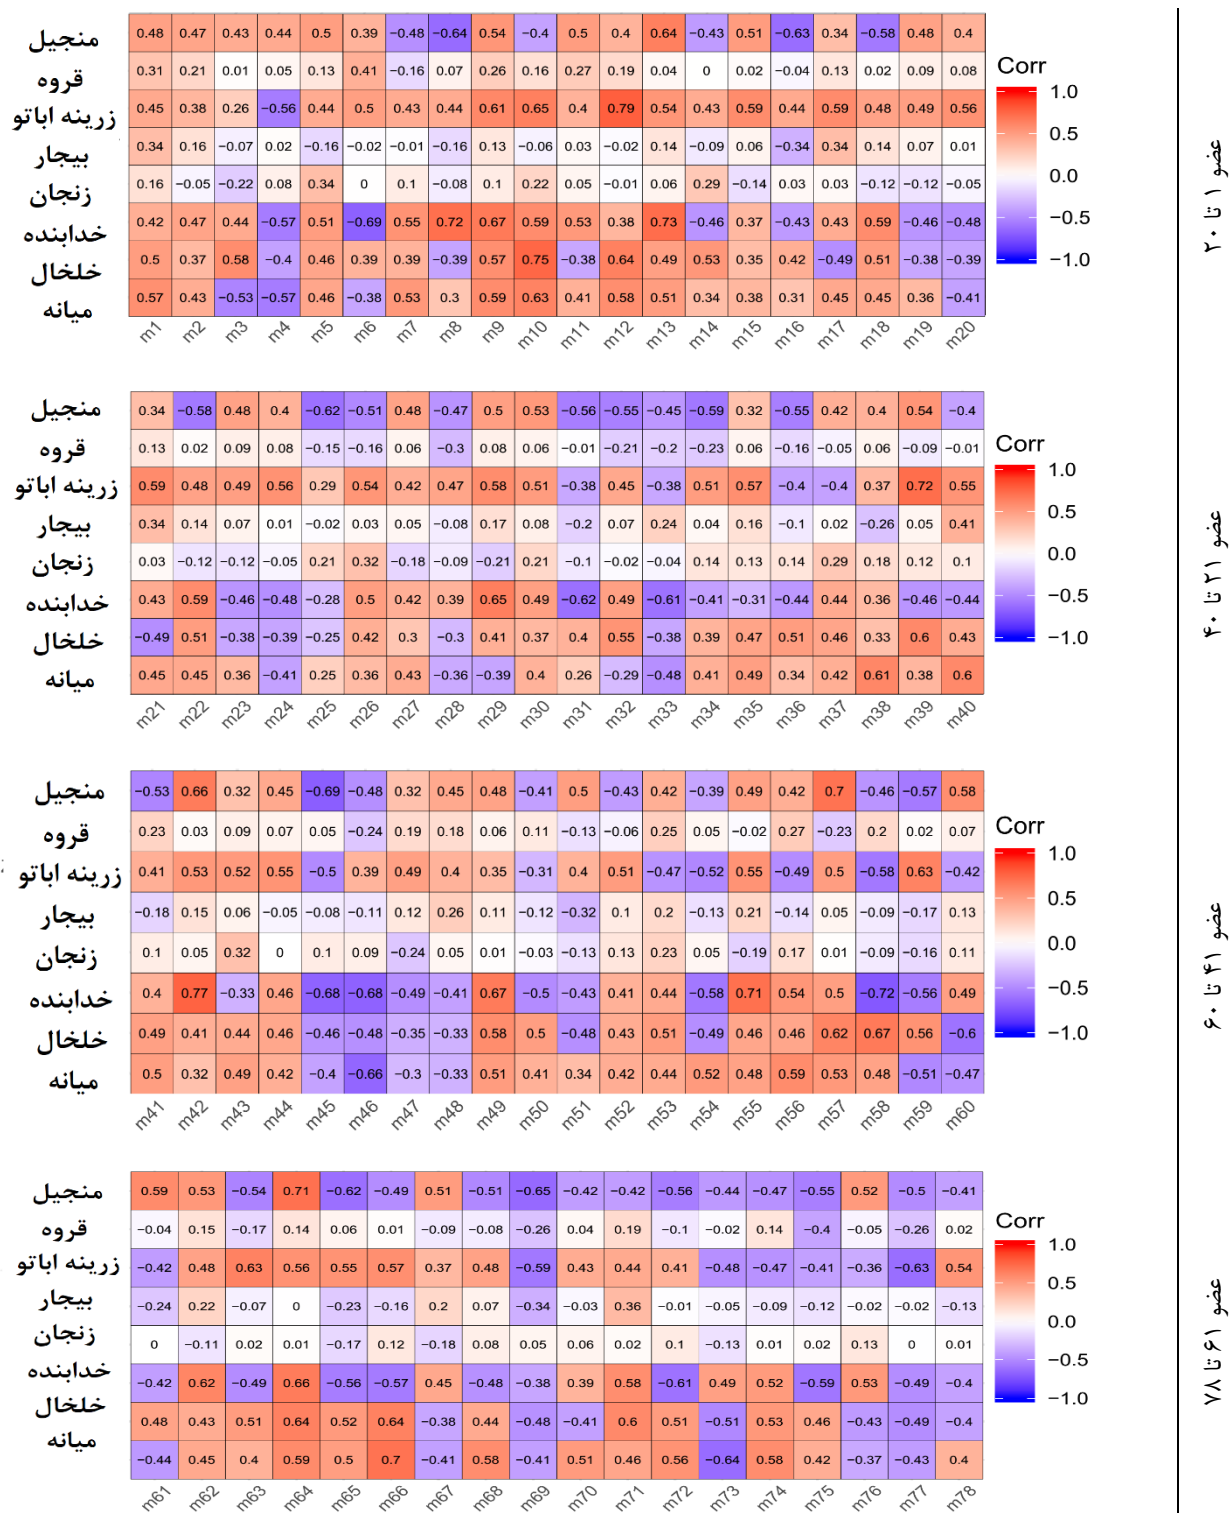
بر اساس مقادیر ضریب همبستگی ارائه شده در شکل (۳)، مشاهده می‌شود که بعد از تصحیح اریبی پیش‌بینی‌های بارش در ایستگاه‌های موردبررسی، حداقل یک عضو پیش‌بینی از ۷۸ عضو پیش‌بینی از میزان همبستگی نزدیک به ۰/۷ و یا بیشتر برای افق پیش‌بینی ۱ ماه آینده برخوردار است (برای مثال در ایستگاه

عضو ۱ تا ۲۰

عضو ۲۱ تا ۴۰

عضو ۴۱ تا ۶۰

عضو ۶۱ تا ۷۸



شکل ۴- ضریب همبستگی مربوط به هریک از اعضای پیش بینی در مقایسه با بارش ایستگاهی-افق پیش بینی ۲ ماه

بین ۷۸ عضو پیش بینی در هر ایستگاه، حداقل یک عضو با ضریب همبستگی نسبتاً بالا (به طور متوسط حدود ۰/۶) برخوردار است ولی تعداد اعضوها با همبستگی بالا در مقایسه با افق پیش بینی ۱ ماه آینده، کمتر می باشد. این موضوع در مورد ایستگاه های قروه، بیجار و زنگان کمتر صادق بوده و میزان ضریب همبستگی برای

مطابق با شکل (۴) که مقادیر ضریب همبستگی را برای افق پیش بینی ۲ ماه آینده در ایستگاه های مورد بررسی نشان می دهد، مشخص است که میزان ضریب همبستگی با افق پیش بینی ۲ ماه در مقایسه با میزان همبستگی با افق پیش بینی ۱ ماه در اکثر اعضوها، دارای مقادیر کمتری است ولی همچنان از



پیش‌بینی ۱ تا ۳ ماه آینده از ۰/۷۳ به ۰/۶۲ و مقادیر حداقل آن از ۰/۳ به ۰/۱۷ کاهش یافته و مقادیر بیشینه و کمینه مجذور میانگین مربعات خطا نیز به ترتیب از ۲۷ و ۱۱ به مقادیر ۴۶ و ۱۸ افزایش یافته است که بیانگر کاهش دقت مدل‌های پیش‌بینی با افزایش افق پیش‌بینی است.

همه عضوهای پیش‌بینی در این سه ایستگاه، مقادیر قابل توجهی ندارد. در جدول (۳) نیز مقادیر حداکثر و حداقل ضریب همبستگی و مجذور میانگین مربعات خطا برای افق پیش‌بینی ۱ تا ۳ ماه آینده ارائه شده است. بر اساس اعداد ارائه شده در جدول (۳)، به‌طور متوسط مقادیر حداکثر ضریب همبستگی از افق

جدول ۳- حداقل و حداکثر ضریب همبستگی و RMSE برای افق‌های پیش‌بینی مختلف از بین ۷۸ عضو پیش‌بینی

افق پیش‌بینی ۱ ماه (بارش ژانویه)				افق پیش‌بینی ۲ ماه (بارش فوریه)				افق پیش‌بینی ۳ ماه (بارش مارس)				ایستگاه
RMSE		Corr		RMSE		Corr		RMSE		Corr		
Max	Min	Max	Min	Max	Min	Max	Min	Max	Min	Max	Min	
۴۹	۱۸	۰/۶۹	۰/۲۹	۳۰	۱۳	۰/۷۰	۰/۲۵	۳۴	۱۳	۰/۷۵	۰/۳۵	میانه
۴۷	۱۷	۰/۶۸	۰/۲۱	۴۳	۱۷	۰/۷۵	۰/۲۵	۲۶	۱۲	۰/۷۰	۰/۳۰	خلخال
۵۰	۲۱	۰/۷۶	۰/۲۸	۴۳	۱۳	۰/۷۷	۰/۲۸	۳۰	۱۲	۰/۷۵	۰/۳۱	خدابنده
۴۸	۱۷	۰/۴۴	۰	۲۶	۱۰	۰/۳۴	۰	۲۳	۱۱	۰/۶۷	۰/۳۲	زنجان
۵۲	۲۲	۰/۴۷	۰	۲۸	۱۱	۰/۴۱	۰	۲۸	۱۲	۰/۶۶	۰/۲۵	بیجار
۳۹	۱۶	۰/۷۶	۰/۳۱	۴۲	۱۴	۰/۷۹	۰/۲۶	۲۹	۱۱	۰/۷۷	۰/۴۱	زرینه اباتو
۴۹	۲۰	۰/۴۳	۰	۳۳	۱۴	۰/۴۱	۰	۲۸	۱۱	۰/۷۴	۰/۲۷	قروه
۳۳	۱۳	۰/۷۲	۰/۲۸	۳۶	۹	۰/۷۱	۰/۳۲	۲۳	۹	۰/۷۵	۰/۱۹	منجیل
<u>۴۶</u>	<u>۱۸</u>	<u>۰/۶۲</u>	<u>۰/۱۷</u>	<u>۳۵</u>	<u>۱۲</u>	<u>۰/۶۰</u>	<u>۰/۱۶</u>	<u>۲۷</u>	<u>۱۱</u>	<u>۰/۷۳</u>	<u>۰/۳۰</u>	میانگین

دهنده پوشش پیش‌بینی بارش حاصل از ۷۸ عضو پیش‌بینی نسبت به داده‌های مشاهداتی در سطح اطمینان ۹۰ درصد (برای تمام افق‌های پیش‌بینی در همه ایستگاه‌های موردبررسی) است. مقادیر R-Factor نیز بین ۱ تا ۲ به دست آمد که هرچه به مقدار صفر نزدیک‌تر باشد، بیانگر این نکته است که میزان عدم قطعیت بارش پیش‌بینی‌شده در سطح اطمینان ۹۰ درصد، کم است. با توجه به اعداد به دست آمده برای P-Factor، حداکثر این ضریب عدد ۲ و برای ایستگاه‌های زنجان و بیجار (برای افق پیش‌بینی ۱ ماه) و مقدار ۲/۲ در ایستگاه بیجار (برای افق پیش‌بینی ۳ ماه) به دست آمد که نشان‌دهنده عدم قطعیت نسبتاً بالای پیش‌بینی بارش در ایستگاه‌های مذکور می‌باشد. به‌طور کلی می‌توان نتیجه گرفت که بازه عدم قطعیت بارش پیش‌بینی حاصل از ۷۸ عضو پیش‌بینی بالا است که این موضوع بعد از ترکیب مدل‌ها با یکدیگر تا حدودی برطرف می‌شود. در ارتباط با بیش‌برآورد و یا کم‌برآورد مدل‌های پیش‌بینی نیز نتایج نشان می‌دهد که تقریباً در تمامی ایستگاه‌های موردبررسی، اکثر مدل‌های پیش‌بینی دارای اریبی مثبت برای پیش‌بینی بارش هستند به‌طوری‌که پیش‌بینی بارش آن‌ها در ماه‌های مختلف سال بیشتر از مقادیر مشاهداتی در دوره تاریخی (بر اساس مقادیر ثبت‌شده در ایستگاه‌های همدیدی) بوده است. این موضوع در شکل (۵) نیز قابل استنباط است. برای مثال در ایستگاه زنجان برای دو افق پیش‌بینی ۱ و ۲ ماه آینده، مشخص است که بازه پیش‌بینی مربوط به مدل‌های مختلف

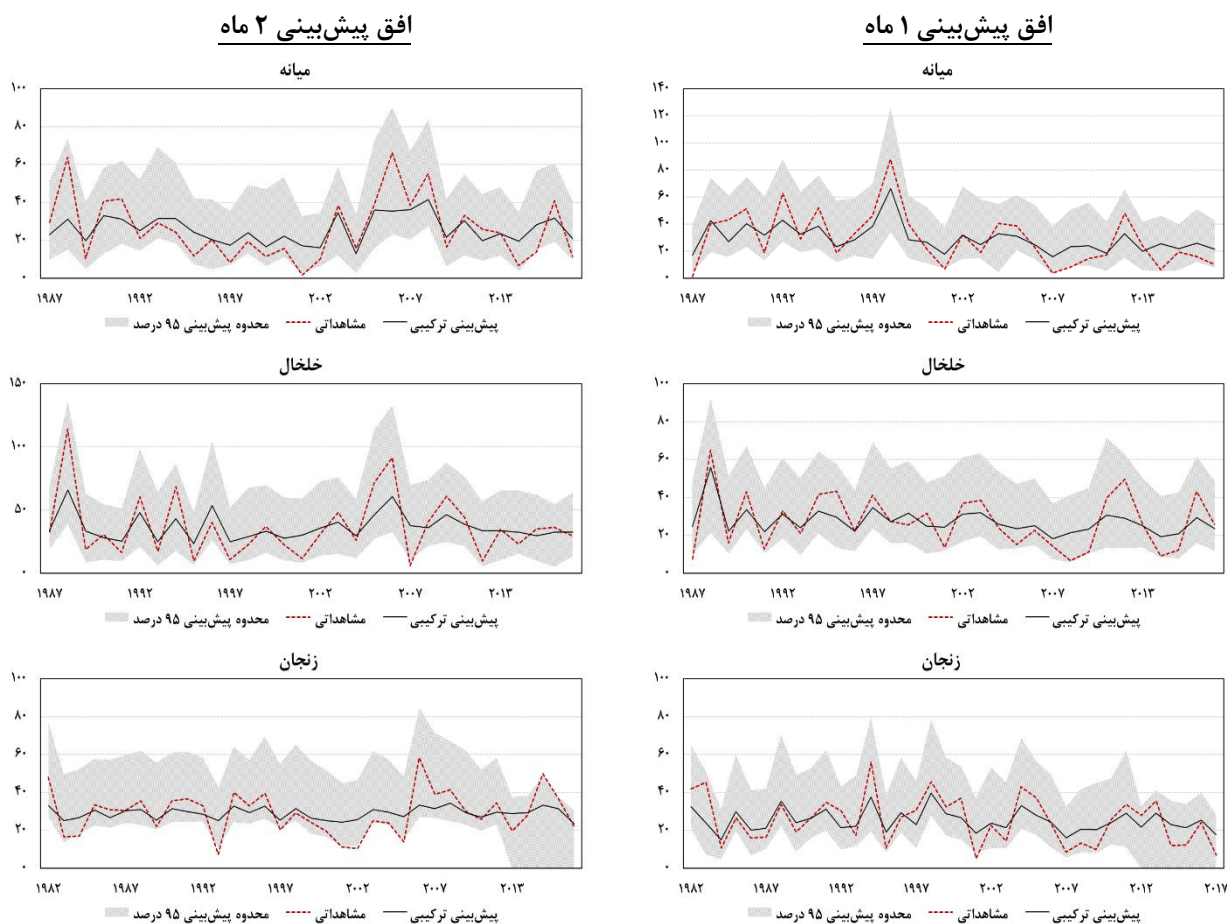
با توجه به نتایج مربوط به ضریب همبستگی ارائه شده در شکل‌های (۳) و (۴) و جدول (۳)، انتظار می‌رود با ترکیب نتایج پیش‌بینی بارش مربوط به ۷۸ عضو، پیش‌بینی نهایی بارش ماهانه از دقت بیشتری نسبت به حالت عضوهای منفرد برخوردار باشد.

#### پیش‌بینی همادی بارش

برای ترکیب نتایج پیش‌بینی بارش حاصل از ۷۸ عضو از ۶ مدل جهانی اقلیمی، از روش BMA استفاده شد. در شکل (۵)، نمودار مربوط به پیش‌بینی ترکیبی بارش و محدوده اطمینان ۹۰ درصد در دوره شبیه‌سازی به صورت نمونه برای برخی از ایستگاه‌ها (میانه، خلخال و زنجان) و برای افق پیش‌بینی ۱ ماه آینده (شکل سمت راست) و افق پیش‌بینی ۲ ماه آینده (شکل سمت چپ) نشان داده شده است. بر اساس شکل (۵)، مشخص است که بعد از ترکیب مدل‌های پیش‌بینی، پیش‌بینی نهایی بارش (پیش‌بینی همادی) نسبت به بارش مشاهداتی بهبود یافته است به‌طوری‌که در بیشتر موارد تطابق زیادی با الگوی بارش مشاهداتی در ایستگاه‌ها دارد.

به‌منظور ارزیابی بازه عدم قطعیت مدل‌های پیش‌بینی (شکل ۵) و کمی کردن آن، ضرایب P-Factor و R-Factor برای ۷۸ عضو پیش‌بینی در طول دوره شبیه‌سازی محاسبه شد. نتایج آن در جدول (۴) ارائه شده است. بر اساس مقادیر ارائه شده در جدول (۴) می‌توان گفت که به‌طور متوسط در همه ایستگاه‌ها، میزان P-Factor بین ۰/۶۳ تا ۰/۹۷ به دست آمده است که نشان

(منطقه هاشور) بیشتر در بالای خط مربوط به بارش مشاهداتی ایستگاهی (خط نقطه چین) واقع شده است.



شکل ۵- پیش‌بینی بارش در محدوده اطمینان ۹۰ درصد و پیش‌بینی ترکیبی حاصل از ۷۸ عضو در دوره تاریخی برای افق پیش‌بینی ۱ و ۲ ماه آینده

جدول ۴- مقادیر ضرایب P-Factor و R-Factor برای ۷۸ عضو پیش‌بینی برای محدوده اطمینان ۹۰ درصد پیش‌بینی بارش

ایستگاه	افق پیش‌بینی ۱ ماه (بارش ژانویه)		افق پیش‌بینی ۲ ماه (بارش فوریه)		افق پیش‌بینی ۳ ماه (بارش مارس)	
	P-Factor	R-Factor	P-Factor	R-Factor	P-Factor	R-Factor
میانه	۰/۸۷	۱/۶	۰/۹۰	۱/۷	۰/۷۷	۱/۴
خلخال	۰/۹۷	۱/۹	۰/۹۳	۱/۷	۰/۹۷	۱/۲
خدابنده	۰/۸۷	۱/۷	۰/۸۳	۱/۴	۰/۸۷	۱/۵
زنجان	۰/۹۲	۲/۰	۰/۷۴	۱/۴	۰/۶۹	۱/۴
بیجار	۰/۹۰	۲/۰	۰/۶۳	۱/۴	۰/۹۳	۲/۲
زرینه اباتو	۰/۸۵	۱/۵	۰/۹۳	۱/۵	۰/۹۳	۱/۸
قروه	۰/۸۹	۱/۶	۰/۷۹	۱/۸	۰/۸۹	۲/۰
منجیل	۰/۷۹	۱/۵	۰/۷۵	۱/۶	۰/۷۹	۱/۳

میزان ضریب همبستگی نسبت به مدل‌های انفرادی، بهبود یافته است به طوری که میزان آن در همه ایستگاه‌ها به بیش از ۰/۸ رسیده است. برای مثال در ایستگاه میانه، منجیل و قروه، میزان همبستگی تا مقدار ۰/۹ در افق‌های پیش‌بینی مختلف به دست آمده است.

به‌منظور ارزیابی میزان دقت و اهمیت پیش‌بینی همادی (ترکیبی) بارش، شاخص‌های آماری مربوط به پیش‌بینی همادی بارش نیز محاسبه و مقادیر آن در جدول (۵) ارائه شده است. بر اساس مقادیر ارائه شده در جدول (۵)، واضح است که بعد از اینکه پیش‌بینی‌های بارش حاصل مدل‌های مختلف با هم ترکیب شدند،

جدول ۵- مقادیر شاخص‌های آماری حاصل از ارزیابی پیش‌بینی همادی بارش ماهانه

ایستگاه	افق پیش‌بینی ۱ ماه (ژانویه)				افق پیش‌بینی ۲ ماه (فوریه)				افق پیش‌بینی ۳ ماه (مارس)			
	Corr	RMSE	NSE	Logterm	Corr	RMSE	NSE	Logterm	Corr	RMSE	NSE	Logterm
میانه	۰/۹۱	۱۱	۰/۶۷	۲۹	۰/۸۲	۱۱	۰/۵۳	۲۶	۰/۸۵	۱۶	۰/۴۹	۳۶
خلخال	۰/۸۵	۹	۰/۵۹	۲۷	۰/۸۸	۱۶	۰/۵۵	۳۷	۰/۸۳	۱۴	۰/۵۹	۴۹
خدابنده	۰/۶۸	۹	۰/۶۸	۳۶	۰/۸۸	۱۴	۰/۴۴	۴۵	۰/۸۹	۱۸	۰/۵۸	۶۱
زنجان	۰/۸۴	۸	۰/۵۷	۲۵	۰/۸۵	۹	۰/۳۷	۲۹	۰/۸۳	۱۴	۰/۴۵	۳۹
بیجار	۰/۸۲	۹	۰/۵۶	۳۴	۰/۸۶	۱۰	۰/۳۸	۳۴	۰/۸۹	۱۷	۰/۵۹	۵۵
زرینه اباتو	۰/۸۸	۱۰	۰/۶۱	۳۷	۰/۸۲	۱۶	۰/۴۸	۴۰	۰/۸۸	۱۴	۰/۶۷	۵۶
قروه	۰/۸۶	۱۰	۰/۵۸	۳۲	۰/۹۱	۱۱	۰/۵۶	۳۷	۰/۹۱	۱۸	۰/۵۸	۶۰
منجیل	۰/۸۸	۷	۰/۶۱	۱۷	۰/۹۳	۸	۰/۵۸	۲۰	۰/۷۹	۱۲	۰/۴۸	۳۰

که در نقاط مختلف جهان انجام شده است، مطابقت دارد. برای مثال در ارتباط با ضریب همبستگی به دست آمده در مقاله حاضر می‌توان گفت که در سایر پژوهش‌های انجام شده مشابه نیز، مقادیر ضریب همبستگی محاسبه شده چندان قابل توجه نبوده و عمدتاً بین ۰/۵ تا ۰/۷ به دست آمده است (Najafi et al., 2018, Slater et al., 2017, Kolachian and Saghafian., 2019). بنابراین از نتایج پژوهش حاضر و سایر پژوهش‌های انجام شده در جهان می‌توان این نتیجه را گرفت که علی‌رغم پیشرفت‌های زیادی که در زمینه پیش‌بینی‌های حاصل مدل‌های دینامیکی اقلیمی صورت گرفته است، هنوز این مدل‌ها دقت بسیار بالایی جهت پیش‌بینی پارامترهای اقلیمی از جمله بارش در مقیاس ماهانه و فصلی را ندارند و می‌بایست قبل از استفاده از نتایج آن‌ها در سطح عملیاتی، ارزیابی دقت و پس‌پردازش آماری شوند. ولی ذکر این نکته حائز اهمیت است که در اختیار داشتن حتی تصویر کلی از وضعیت بارش و به همراه آن وضعیت منابع آب در ماه‌های آینده می‌تواند کمک‌های فراوانی را به مدیران منابع آب کند. در حال حاضر داشتن اطلاعات مربوط به پیش‌بینی‌های حاصل از مدل‌های دینامیکی در میزان دقت و کارایی فعلی می‌تواند در بسیاری از امور برنامه‌ریزی و تصمیم‌گیری در حوزه منابع مفید واقع شود. به عنوان نمونه در حال حاضر در کشور انگلیس از پیش‌بینی یا به عبارت دیگر، چشم‌اندازهای هیدرو-اقلیمی حاصل از مدل‌های دینامیکی، به صورت عملیاتی استفاده می‌شود<sup>۱</sup>.

### نتیجه‌گیری کلی

در مقاله حاضر هدف، ارزیابی بارش ماهانه پیش‌بینی شده توسط مجموعه‌ای از مدل‌های مرکز NMME در حوضه آبریز سفیدرود بود. ابتدا نتایج پیش‌بینی بارش ماهانه حاصل از ۷۸ عضو حاصل از ۶ مدل پیش‌بینی بارش با روش نگاشت چندک، تصحیح آریبی

در حالت ارزیابی مدل‌های منفرد که نتایج آن در جدول (۳) ارائه شد، قبل از ترکیب عضوهای پیش‌بینی، حداکثر ضریب همبستگی به‌طور متوسط در تمام ایستگاه‌ها و برای افق پیش‌بینی ۱ تا ۳ ماه آینده به ترتیب برابر ۰/۷۳، ۰/۶ و ۰/۶۲ بود که بعد از ترکیب مدل‌ها با یکدیگر، متوسط ضریب همبستگی در ایستگاه‌های موردبررسی برای افق پیش‌بینی ۱ تا ۳ ماه به ترتیب برابر ۰/۸۷، ۰/۸۶ و ۰/۸۶ به دست آمد که نشان‌دهنده بهبود پیش‌بینی‌های بارش بعد از ترکیب ۷۸ عضو پیش‌بینی است. مقادیر RMSE ارائه شده در جدول (۵) نیز نشان می‌دهد که بعد از ترکیب ۷۸ عضو پیش‌بینی با روش BMA، میزان RMSE نیز در مقایسه با عضوهای منفرد، کاهش یافته است. ضریب NSE محاسبه شده نیز برای افق پیش‌بینی ۱ تا ۳ ماه آینده و برای تمام ایستگاه‌ها بین ۰/۳۷ تا ۰/۶۸ به دست آمده است. این در صورتی است که اگر مقادیر NSE به یک نزدیک باشد، همخوانی مناسبی بین داده‌های مشاهداتی و مدل پیش‌بینی وجود دارد (Moriasi et al., 2007) و اگر مقدار آن بزرگ‌تر از ۰/۷۵ به دست آید نتایج مدل، خوب توصیف می‌شود و اگر بین ۰/۳۶ تا ۰/۷۵ به دست آید، نتایج مدل خوب تا متوسط است (Motovilov et al., 1999). بنابراین نتایج پیش‌بینی بارش ماهانه حاصل از مدل ترکیبی بر اساس مقادیر NSE به دست آمده در مقاله حاضر، خوب تا متوسط می‌باشد.

بر اساس نتایج به دست آمده در مقاله حاضر، می‌توان نتیجه گرفت نتایج اولیه مدل‌های پیش‌بینی دینامیکی (بدون پس‌پردازش) دارای دقت مناسبی نمی‌باشند و بعد از پس‌پردازش و ترکیب مدل‌ها با یکدیگر، میزان دقت پیش‌بینی‌ها از لحاظ شاخص‌های آماری محاسبه شده، بهبود می‌یابد. نتایج به دست آمده در پژوهش حاضر نشان می‌دهد که میزان دقت به دست آمده برای مدل‌های مرکز NMME، با نتایج بسیاری از پژوهش‌ها

1. <https://www.hydotuk.net/> (Laste access)

همادی چند مدلی پیش‌بینی بارش در منطقه دست یافت. در ارتباط با عدم قطعیت موجود در پیش‌بینی بارش ماهانه نیز باید گفت که بازه عدم قطعیت پیش‌بینی بارش تا حدودی زیاد بوده و برای استفاده عملیاتی پیش‌بینی بارش ماهانه حاصل از مدل‌های مرکز NMME در امور برنامه‌ریزی و تصمیم‌گیری، توصیه می‌شود تا از نتایج پیش‌بینی همادی یا ترکیبی مدل‌ها استفاده شود. به‌طور کلی می‌توان نتیجه گرفت که پیش‌بینی همادی بارش ماهانه در پژوهش حاضر برای منطقه مورد مطالعه، خوب تا متوسط بوده است.

### تشکر و قدردانی

بدین وسیله از دانشگاه تهران، شرکت مدیریت منابع آب ایران، مؤسسه تحقیقات آب وزارت نیرو و سازمان هواشناسی کشور به دلیل تأمین امکانات و داده‌های لازم به‌منظور انجام این تحقیق و تهیه مقالات مربوطه تشکر و قدردانی می‌شود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

### REFERENCES

- Abbasi, M., Araghinejad, Sh. and Ebrahimi, K. (2019). Evaluation of Moving Average Pre-processing Approach to Improve the Efficiency of Support Vector Regression Model for Inflow Prediction. *Iranian Journal of Soil and Water Research*, 50:1, 247-258 (In Farsi).
- Abbaspur, Kc. (2009). SWAT-CUP2; SWAT calibration and uncertainty programs user manual. Federal institute of aquatic science and technology (Eawag), Swiss.
- Ahmadalipour, A., Moradkhani, H., & Rana, A. (2018). Accounting for downscaling and model uncertainty in fine-resolution seasonal climate projections over the Columbia River Basin. *Climate dynamics*, 50(1-2), 717-733.
- Bai, Y., Chen, Z., Xie, J., & Li, C. (2016). Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models. *Journal of hydrology*, 532, 193-206.
- Barbero, R., Abatzoglou, J. T., & Hegewisch, K. C. (2017). Evaluation of statistical downscaling of North American multimodel ensemble forecasts over the western United States. *Weather and Forecasting*, 32(1), 327-341.
- Courbariaux, M., Barbillon, P., Perreault, L., & Parent, É. (2018). Post-processing multi-ensemble temperature and precipitation forecasts through an Exchangeable Gamma Normal model and its Tobit extension. *arXiv preprint arXiv:1804.09233*.
- Foroughi, F. and Araghinejad, Sh. (2017). Long-lead streamflow forecasting using singular spectrum analysis in the Karkheh basin. *Iranian Journal of Soil and Water Research*, 48:2, 309-321 (In Farsi).
- Gudmundsson, L., Bremnes, J. B., Haugen, J. E., & Skaugen, T. E. (2012). Downscaling RCM precipitation to the station scale using quantile mapping--a comparison of methods. *Hydrology & Earth System Sciences Discussions*, 9(5).
- Han, P., Wang, P. X., Zhang, S. Y., & Zhu, D. H. (2010). Drought forecasting based on the remote sensing data using ARIMA models. *Mathematical and computer modelling*, 51(11-12), 1398-1403.
- Jia, L., Yang, X., Vecchi, G. A., Gudgel, R. G., Delworth, T. L., Rosati, A., ... & Msadek, R. (2015). Improved seasonal prediction of temperature and precipitation over land in a high-resolution GFDL climate model. *Journal of Climate*, 28(5), 2044-2062.
- Khajehei, S., Ahmadalipour, A., & Moradkhani, H. (2018). An effective post-processing of the North American multi-model ensemble (NMME) precipitation forecasts over the continental US. *Climate dynamics*, 51(1-2), 457-472.
- Kirtman, B. P., Min, D., Infanti, J. M., Kinter III, J. L., Paolino, D. A., Zhang, Q., ... & Peng, P. (2014). The North American multimodel ensemble: phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction. *Bulletin of the American Meteorological Society*, 95(4), 585-601.
- Kolachian, R., & Saghafian, B. (2019). Deterministic and probabilistic evaluation of raw and post processed sub-seasonal to seasonal precipitation forecasts in different precipitation regimes. *Theoretical and Applied Climatology*, 137(1-2), 1479-1493.
- Le, J. A., El-Askary, H. M., Allali, M., & Struppa, D. C. (2017). Application of recurrent neural networks for drought projections in California. *Atmospheric research*, 188, 100-106.

شدند و بعد از محاسبه شاخص‌های ارزیابی، مشخص شد که دقت و ارزش هر یک از مدل‌ها در پیش‌بینی بارش از ۱ تا ۳ ماه آینده به چه میزان است به طوری که میزان ضریب همبستگی در حالت مدل‌های انفرادی و برای بهترین عضوهای پیش‌بینی بارش برای افق پیش‌بینی ۱ و ۳ ماه آینده به ترتیب ۰/۷۳ و ۰/۶۳ به دست آمد و مقدار بیشینه مجذور میانگین مربعات خطا ۲۷ و ۴۶ میلی-متر محاسبه شد که این موضوع نشان‌دهنده کاهش دقت مدل‌های پیش‌بینی با افزایش افق پیش‌بینی است. در گام بعدی با ترکیب نتایج پیش‌بینی بارش مدل‌های مختلف با روش BMA (بعد از تصحیح اربیبی)، مشخص شد که دقت پیش‌بینی بارش بهبود می‌یابد و میزان ضریب همبستگی در این حالت نسبت به حالت مدل‌های انفرادی به‌طور متوسط برای ۳ افق پیش‌بینی افزایش (حدود ۲۱ درصد) و همچنین میزان ضریب RMSE نیز کاهش یافت (حدود ۵۰ درصد). بنابراین با ترکیب نتایج بارش پیش‌بینی‌شده حاصل از ۷۸ عضو مدل‌های پیش‌بینی، می‌توان دقت پیش‌بینی‌های بارش را تا حدودی بهبود بخشید و به سامانه

- Liu, L., Xiao, C., Du, L., Zhang, P., & Wang, G. (2019). Extended-Range Runoff Forecasting Using a One-Way Coupled Climate-Hydrological Model: Case Studies of the Yiluo and Beijiang Rivers in China. *Water*, 11(6), 1150.
- Ma, F., Ye, A., Deng, X., Zhou, Z., Liu, X., Duan, Q., & Gong, W. (2016). Evaluating the skill of NMME seasonal precipitation ensemble predictions for 17 hydroclimatic regions in continental China. *International Journal of Climatology*, 36(1), 132-144.
- Manganello, J. V., Cash, B. A., Hodges, K. I., & Kinter, J. L. (2017). Seasonal forecasts of North Atlantic tropical cyclone activity in the North American multi-model ensemble. *Climate Dynamics*, 1-16.
- Modarresi, F., Araghinejad, Sh. and Ebrahimi. K. (2016). The Combined Effect of Seasonal Fluctuations of Persian Gulf and Mediterranean Sea Surface Temperature on Monthly Streamflow Forecasting of Karkheh River, Iran. *Iranian Journal of Soil and Water Research*, 46:4, 597-607 (In Farsi).
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Motovilov, Y. G., Gottschalk, L., Engeland, K., & Rodhe, A. (1999). Validation of a distributed hydrological model against spatial observations. *Agricultural and Forest Meteorology*, 98, 257-277.
- Najafi, H., Massah Bavani, A., Irannejad, P., & Viliam Robertson, A. (2018). Developing Real-time Multi-Model Ensemble and Downscaling of Seasonal Precipitation Forecast Systems: Application of Canonical Correlation Analysis. *Journal of the Earth and Space Physics (JESP)*, 44(1), 245-264.
- Narapusetty, B., Collins, D. C., Murtugudde, R., Gottschalk, J., & Peters-Lidard, C. (2018). Bias correction to improve the skill of summer precipitation forecasts over the contiguous United States by the North American multi-model ensemble system. *Atmospheric Science Letters*, 19(5), e818.
- Raftery, A. E., Gneiting, T., Balabdaoui, F., & Polakowski, M. (2005). Using Bayesian model averaging to calibrate forecast ensembles. *Monthly weather review*, 133(5), 1155-1174.
- Slater, L.J., Villarini, G. and Bradley, A.A. (2017). Weighting of NMME temperature and precipitation forecasts across Europe. *Journal of Hydrology*, 552, 646-659.
- Strazzo, S., Collins, D. C., Schepen, A., Wang, Q. J., Becker, E., & Jia, L. (2019). Application of a Hybrid Statistical-Dynamical System to Seasonal Prediction of North American Temperature and Precipitation. *Monthly Weather Review*, 147(2), 607-625.
- Voisin, N., Schaake, J. C., & Lettenmaier, D. P. (2010). Calibration and downscaling methods for quantitative ensemble precipitation forecasts. *Weather and Forecasting*, 25(6), 1603-1627.
- Xu, L., Chen, N., Zhang, X., & Chen, Z. (2018). An evaluation of statistical, NMME and hybrid models for drought prediction in China. *Journal of hydrology*, 566, 235-249.
- Xu, L., Chen, N., Zhang, X., Chen, Z., Hu, C., & Wang, C. (2019). Improving the North American multi-model ensemble (NMME) precipitation forecasts at local areas using wavelet and machine learning. *Climate Dynamics*, 1-15.
- Zhao, T., Zhang, Y., & Chen, X. (2019). Predictive performance of NMME seasonal forecasts of global precipitation: A spatial-temporal perspective. *Journal of Hydrology*, 570, 17-25.