


Monthly Drought Modeling Using Post-Processed Output of CFS.v2-RegCM4 System during 1982-2010 (Case Study: Iran)

Falamarzi, Y.¹ 

1. Atmospheric Science and Meteorological Research Center, Climate Research Institute, Mashhad, Iran.

Corresponding Author E-mail: yashar.fa@gmail.com

(Received: 13 June 2022, Revised: 1 Oct 2022, Accepted: 10 Jan 2023, Published online: 30 Aug 2023)

Summary

Iran and its neighboring countries are located in an arid and semi-arid region, so they have been always affected by various climate disasters. Drought as one of the most important climatic hazards in the region, has attracted lots of researches. Drought could have negative impacts on different areas such as agriculture, water resources, industry, transportation and urbanization. Drought is basically a qualitative phenomenon that could have various definitions in different sectors. In a basic categorization, drought could be climatic, hydrological, agricultural and social droughts. Researches have always keen on defining appropriate indices for each kind of drought. Standardized Precipitation Index (SPI) and Standardized Precipitation and potential Evapotranspiration Index (SPEI) are good examples of climatic drought indices which have been widely used and popular between researchers.

While monitoring the changes of these indices are a good way of drought analysis, effective drought management also needs accurate forecast of drought. A widely applied approach to forecast drought is through using the outputs of Coupled atmosphere- land- ocean General Circulation Models (CGCMs). CGCMs simulate the atmosphere-land-ocean system in a simplified way. Although, these models have been developed a lot in recent years, the forecasts are not well enough to be used in small regions. Thus, downscaling and post-processing methods have been widely applied to increase the resolution and accuracy of CGCM's outputs, respectively.

Downscaling methods could be in a way grouped into two categories: 1. Statistical, 2. Dynamical. Dynamical methods are based on physical theories and using parametrization and initial hypothesis. Statistical methods investigate the relationship between modeled variables and their corresponding observation in a period of time. This relationship is then applied to forecast that variable. Both mentioned methods have their own advantages and disadvantages. In recent years, combined dynamical and statistical approaches have been widely used. In this study, SPI and SPEI were forecasted using the outputs of CFS.v2. Firstly, the outputs of CFS.v2 in the reforecast period (1982-2010) were downscaled to 30km horizontal resolution using RegCM4. Due to limitation in computational power, the dynamical downscaling was limited to 1-month lead time. Then needed outputs for the rest of analysis were post-processed using Decision Tree (DT) and Support Vector Machine (SVM). The outputs of CFS.v2-RegCM4 system for precipitation and ERA5 were used as inputs and ideal outputs, respectively, of DT and SVM for calibration and validation. These post-processed outputs were then applied to calculate SPI. In order to calculate modeled SPEI, firstly, ET was computed using Hargreaves-Samani approach and the needed climatic modeled variables by CFS.v2-RegCM4 system. The reanalysis ERA5 data was utilized to calculate reanalysis ET. Then, in order to calibrate and validate DT and SVM models, modeled ET and reanalysis ET were applied as input and ideal output, respectively. Finally, the postprocessed precipitation and ET were employed to compute modeled SPEI. These modeled SPI and SPEI were spatially compared with SPI and SPEI computed using ERA5 data. The results showed that both DT and SVM improved the accuracy of precipitation and ET forecasted by CFS.v2-RegCM4 system. However, DT model performed much better than SVM. The ability of DT in post-processing precipitation was higher than it for ET. Comparing spatial pattern of modeled SPI and SPEI with reanalysis SPI and SPEI showed that DT model could replicate these values at an acceptable level of accuracy.

Keywords: Decision tree, Support vector machine, RegCM4, SPI, SPEI.

مدل‌سازی ماهانه خشکسالی با استفاده از برونداد پس‌پردازش شده سامانه

CFS.v2-RegCM4 در دوره ۱۹۸۲ تا ۲۰۱۰ (مطالعه موردی: ایران)

یاشار فلامرزی^۱

۱. پژوهشگاه هواشناسی و علوم جو، پژوهشکده اقلیم‌شناسی، مشهد، ایران.

رایانامه نویسنده مسئول: yashar.fa@gmail.com

(دریافت: ۱۴۰۱/۳/۲۳، بازنگری: ۱۴۰۱/۷/۹، پذیرش نهایی: ۱۴۰۱/۱۰/۲۰، انتشار آنلاین: ۱۴۰۲/۶/۸)

چکیده

از آنجاکه کشور ایران در منطقه‌ای خشک و نیمه‌خشک واقع شده است، همواره در معرض کمبود بارش، دما و تبخیر بالا و در نتیجه خشکسالی‌های متعدد با اثرات مخرب بوده است. لذا پایش، مدل‌سازی و پیش‌بینی این پدیده، به‌ویژه در مقیاس ماهانه می‌تواند نقش به‌سزایی در مدیریت ریسک خشکسالی داشته باشد. هدف مطالعه حاضر، توسعه مدلی با قابلیت محاسبه شاخص‌های SPI و SPEI در پیش‌دید یک‌ماهه با بهره‌گیری از برونداد بارش و دمای مدل CFS.v2 که توسط مدل منطقه‌ای RegCM4 ریزمقیاس شده است، می‌باشد. ابتدا با استفاده از داده‌های دمای ریزمقیاس شده مدل CFS.v2 در دوره ۱۹۸۲-۲۰۱۰ و همچنین داده‌های ERA5، مقادیر تبخیر-تعرق پتانسیل ماهانه به روش هارگریوز-سامانی محاسبه شد؛ سپس داده‌های ریزمقیاس شده بارش و تبخیر-تعرق پتانسیل سامانه CFS.v2-RegCM4 توسط مدل‌های درخت تصمیم و ماشین بردار پشتیبان پس‌پردازش شدند. داده‌های ریزمقیاس شده به‌عنوان ورودی و داده‌های بازتحلیل ERA5 به‌عنوان مرجع جهت آموزش (۲۰۰۳-۲۰۱۰) و آزمون (۲۰۱۰-۲۰۰۳) استفاده شدند. در پایان، از داده‌های ریزمقیاس شده و پس‌پردازش شده جهت محاسبه مقادیر SPI و SPEI یک‌ماهه مدل و از داده‌های ERA5 برای محاسبه مقادیر نظیر مرجع استفاده شد. مقایسه داده‌های پس‌پردازش شده بارش و تبخیر-تعرق پتانسیل با داده‌های نظیر بازتحلیل ERA5 نشان داد که مدل درخت تصمیم از کارایی بالاتری نسبت به مدل ماشین بردار پشتیبان برخوردار است. همچنین مقادیر SPI و SPEI محاسبه شده با داده‌های منتج از سامانه CFS.v2-RegCM4 که با مدل درخت تصمیم پس‌پردازش شده‌اند با مقادیر نظیر منتج از داده‌های بازتحلیلی ERA5 همخوانی قابل‌قبولی داشتند.

واژه‌های کلیدی: درخت تصمیم، ماشین بردار پشتیبان، CFS.v2-RegCM، SPI، SPEI.

۱. مقدمه

صحيح خشکسالی و اثرات ناشی از آن می‌تواند در کاهش خسارات نقش به‌سزایی داشته باشد. پیش‌بینی صحیح این پدیده در مقیاس‌های زمانی میان‌مدت (ماهانه و فصلی) و بلندمدت یکی از ابزارهای مفید برای مدیران و تصمیم‌سازان جهت در پیش‌گرفتن بهینه‌ترین استراتژی‌ها است.

خشکسالی ذاتاً یک پدیده کیفی است جویباری مقدم و رستمی، (۲۰۱۸)، که می‌تواند در هر بخش تعریف و معیار مخصوص به خود را داشته باشد. در یکی از تقسیم‌بندی‌ها خشکسالی به خشکسالی آب‌وهوایی، آب‌شناسی، کشاورزی و اجتماعی تقسیم‌بندی می‌شود. برای هر یک

ایران و کشورهای همجوار با توجه به قرارگیری در منطقه‌ای خشک و نیمه‌خشک از جهان همواره تحت‌تأثیر بلایای مختلف جوی بوده است. خشکسالی به‌عنوان یکی از مهم‌ترین چالش‌هایی که از شدت و ماندگاری بیشتری در این منطقه جغرافیایی برخوردار است، همواره مورد توجه محققین قرار گرفته است. خشکسالی بر بسیاری از زمینه‌های از جمله کشاورزی، منابع آب، صنعت، حمل و نقل، شهرسازی و... تأثیرات منفی زیادی دارد. کاهش تولیدات کشاورزی و در نتیجه درآمد حاصل از آن منجر به گسترش فقر، افزایش بیکاری و کاهش سطح رضایت‌مندی اجتماعی در کشورها می‌شود. لذا مدیریت

است (بین، ۲۰۱۱). لذا محققین همواره در تلاش بوده‌اند تا با روش‌هایی بر این چالش فائق آیند. به‌طور کلی، استفاده از تکنیک‌های ریزمقیاس‌نمایی به‌عنوان یکی از متداول‌ترین راه‌کارها استفاده می‌شود. این شیوه‌ها معمولاً تفکیک مکانی کوچک‌تری در حد منطقه و یا ایستگاه برای ما فراهم می‌کنند (بین، ۲۰۱۱؛ مقیم و برس، ۲۰۱۷؛ تیان و همکاران، ۲۰۱۷).

تصحیح خطا و ریزمقیاس‌نمایی متغیرهای آب‌وهوایی از طریق دو روش کلی آماری و دینامیکی صورت می‌پذیرد. روش‌های دینامیکی قادر به تولید متغیرهای هواشناسی بر پایه تئوری‌های فیزیکی هستند، اما فرضیات و پارامترسازی در این شیوه خود می‌تواند منجر به افزایش عدم قطعیت و خطای بیشتر در برون‌داد شود (میرونوو و راسچندورفر، ۲۰۰۱). این مشکلات شیوه‌های دینامیکی، به‌خصوص هزینه‌های محاسباتی، کاربرد آنها برای تصحیح و ریزمقیاس‌نمایی‌های بزرگ مقیاس را به‌شدت محدود می‌کند. ژو و همکاران (۲۰۲۱) با استفاده از مدل منطقه‌ای RegCM متغیرهای دمای (دمای میانگین، کمینه و بیشینه دما) برون‌داد مدل اقلیمی GFDL-ESM2M را ریزمقیاس کردند. نتایج این ریزمقیاس‌نمایی برای تحلیل تغییر اقلیم در استان‌های جلگه‌ای کانادا استفاده شد. گنیتو و همکاران (۲۰۱۹)، از مدل آب‌وهوای منطقه‌ای مرکز روسی نسخه ۴ (RCA4) برای ریزمقیاس‌نمایی برون‌داد مدل گردش کلی جو استفاده کردند. نتایج حاکی از بهبود برون‌داد با ریزمقیاس‌نمایی است. رحیمی بندرآبادی و همکاران (۱۴۰۰)، از مدل PRECIS برای ریزمقیاس‌نمایی برآورد بارش و دما برای دوره ۲۰۷۰ تا ۲۱۰۰ و تحت دو سناریو A2 و B2 استفاده کردند. نتایج ارزیابی حاکی از تأثیر مثبت استفاده از این مدل ریزمقیاس‌نمایی بر برآورد بارش و دما در حوضه دز داشت. شیوه‌های آماری به‌دلیل کارایی و معقول‌بودن محاسبات آنها می‌تواند یک جایگزین مناسب برای تصحیح خطا در مقیاس بزرگ باشد. ایده اصلی روش‌های آماری برقراری رابطه‌ای بین متغیر مدل‌سازی شده و مشاهده شده در یک دوره تاریخی و استفاده از رابطه برای پیش‌بینی‌های آینده است (مقیم و

از نوع خشکسالی‌ها محققین همواره در تلاش بوده‌اند تا با تعریف شاخص‌هایی، خشکسالی کیفی را با یک شاخص کمی نشان دهند. برای مثال شاخص‌های بارش استاندارد شده بارش (SPI) و بارش-تبخیر-تعرق پتانسیل استاندارد شده (SPEI) از جمله شاخص‌های خشکسالی آب‌وهوایی است که از محبوبیت و مقبولیت زیادی برخوردار هستند. زارعی و همکاران (۲۰۲۱) کارایی شاخص‌های خشکسالی SPI، SPEI و RDI را در برخی از ایستگاه‌های ایران ارزیابی کردند و ارجحیت شاخص SPEI را بیان داشتند. کوهستانی و همکاران (۲۰۲۱) نیز شاخص‌های ترکیبی برای تعیین خشکسالی در حوضه آبریز خوزستان را ارزیابی کردند. نتایج نشان داد که شاخص SPI بهترین شاخص برای پایش خشکسالی در این منطقه است. پایش این شاخص‌ها می‌تواند در تعیین وضعیت خشکی آب‌وهوایی منطقه نقش مهمی ایفا کند. ولی برای مدیریت صحیح خشکسالی در منطقه، علاوه بر پایش، مدل‌سازی و پیش‌بینی این شاخص‌ها نیز می‌تواند نقش به‌سزایی در تصمیم‌سازی‌ها داشته باشد. یکی از متداول‌ترین شیوه‌ها، استفاده از برون‌داد مدل‌های جفت‌شده گردش کلی جو (CGCM) است.

مدل‌های جفت‌شده گردش کلی جو برای پیش‌بینی‌ها در مقیاس‌های زمانی مختلف مانند پیش‌بینی‌های میان‌مدت، پیش‌بینی‌های فصلی، و پیش‌نگری‌های آب‌وهوایی مورد استفاده قرار می‌گیرند (سها و همکاران، ۲۰۱۴). این مدل‌ها، فرایندهای فیزیکی کنترل‌کننده اتمسفر، زمین و گردش‌های اقیانوسی را شبیه‌سازی می‌کنند. روابط به‌شدت غیرخطی بین سیستم زمین-اقیانوس-جو در مدل‌های گردش کلی جو ساده‌سازی می‌شوند (لو و ژانگ، ۲۰۱۲). اگرچه این مدل‌ها در طول زمان بهبود یافته‌اند، ولی هنوز برون‌داد آنها دارای تفکیک مکانی بزرگ مقیاس هستند و خطای این مدل‌ها یک نقطه نگرانی در مطالعات اقلیمی است (هیئت بین‌دولتی تغییر اقلیم، ۲۰۰۷؛ دای، ۲۰۰۱). اگرچه این میزان تفکیک برای مشخصه‌های بزرگ مقیاس کافی است، اما این میزان تفکیک یک چالش اساسی برای مشخصه‌های منطقه‌ای

شبکه عصبی کانولوشنال استفاده شد. روش ترکیبی ارائه شده روشی کارا برای مدل‌سازی بارش بیان شده و از میزان هزینه پردازشی در مقایسه با روش کاملاً دینامیکی به‌طور قابل ملاحظه‌ای کم می‌کند.

اگرچه پیش‌بینی ماهانه و فصلی متغیرهای آب‌وهوایی به‌ویژه دما و بارش در تحقیقات زیادی در ایران بررسی و تحلیل شده است، اما استفاده از این پیش‌بینی‌ها برای پیش‌بینی شاخص‌های خشکسالی آب‌وهوایی کمتر مدنظر بوده است. در بسیاری از مطالعات پیش‌بینی مقادیر SPI و SPEI از روش‌های تحلیل و مدل‌سازی سری‌های زمانی استفاده شده است (کریمی و همکاران، ۲۰۱۹؛ مرید و همکاران، ۲۰۰۷؛ شیرمحمدی و همکاران، ۲۰۱۳) و در مطالعاتی هم که از برون‌داد مدل‌های جفت‌شده گردش کلی جو استفاده شده است، مطالعات غالباً محدود به یک یا چند حوضه آبریز و به‌صورت ایستگاهی بوده است (بابایان و همکاران، ۲۰۲۱؛ بابایان و همکاران، ۱۳۹۷؛ صمدی نقاب و همکاران، ۱۳۹۷). در مطالعه حاضر سعی بر ارائه روش کاری است تا قادر باشد مقادیر SPI و SPEI یک‌ماهه را با استفاده از برون‌داد مدل CFS.v2 که توسط مدل منطقه‌ای RegCM4 به‌صورت دینامیکی برای ایران و برخی کشورهای همسایه ریزمقیاس‌شده و توسط مدل‌های یادگیری ماشین پس‌پردازش شده است، مدل‌سازی کند. شایان ذکر است از آنجاکه نتایج ریزمقیاس‌نمایی دینامیکی در مرزهای محدوده مطالعه به‌طور معمول دارای خطا است، تحلیل‌های فقط برای ایران صورت گرفته است.

۲. داده‌ها و روش تحقیق

۲-۱. منطقه مورد مطالعه و داده‌ها

منطقه مورد مطالعه شامل ایران و بخشی از کشورهای همسایه که در محدوده طول جغرافیایی ۲۴/۴۸ تا ۶۵/۵۲ درجه شرقی و عرض جغرافیایی ۲۰/۲۷ تا ۴۳/۷۳ شمالی می‌باشد (شکل ۱). این محدوده شامل ایران و بخش‌هایی از کشورهای افغانستان، آذربایجان، گرجستان، عراق، پاکستان، قزاقستان، ترکمنستان، سوریه، ترکیه، روسیه،

برس، ۲۰۱۷). یکی از این شیوه‌های آماری، استفاده از تحلیل رگرسیون برای یافتن رابطه خطی و یا غیرخطی بین تخمین و تخمین‌زننده است که متداول‌ترین شیوه ریزمقیاس‌نمایی آماری است (برگر، ۱۹۹۶؛ کرین و هویتسون، ۱۹۹۸؛ ون ستورچ، ۱۹۹۹). از جمله معایب روش‌های آماری می‌توان به عدم در نظر گرفتن روابط فیزیکی حاکم می‌باشد. عساکره و غلامی (۱۴۰۰) از روش شبکه عصبی مصنوعی برای ریزمقیاس‌نمایی دمای بیشینه ایستگاه قزوین استفاده کردند. نتایج کارایی قابل قبول شبکه عصبی مصنوعی در ریزمقیاس‌نمایی آماری را داشت. شیخ ربیعی و همکاران (۱۴۰۰) نتایج دو مدل ریزمقیاس‌نمایی آماری CCT و SDSM برای شبیه‌سازی بارش، دمای بیشینه، کمینه و متوسط را در حوضه آبخیز گرگانود مقایسه کردند. نتایج نشان از برتری مدل SDSM بر CCT داشت.

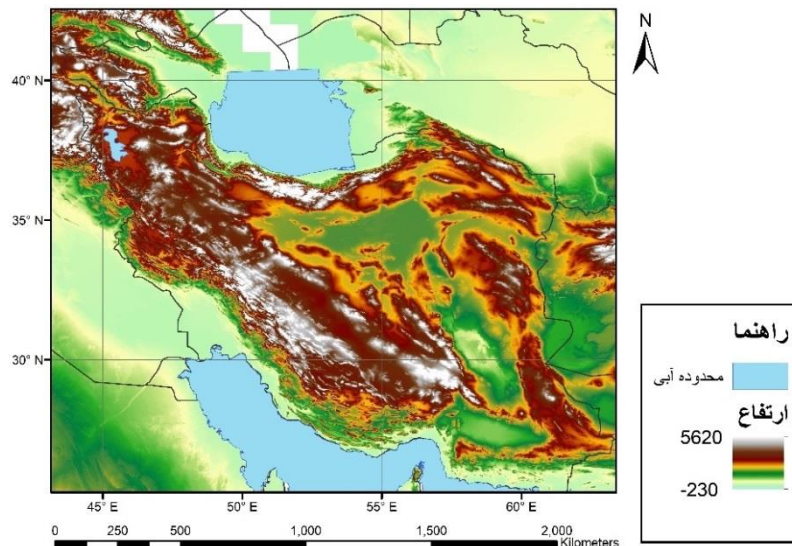
روش‌های ریزمقیاس‌نمایی دینامیکی و آماری علی‌رغم مزایا و معایبشان به‌طور گسترده مورد استفاده قرار گرفته‌اند و شیوه‌ای که برتری کامل بر دیگر روش‌ها داشته باشد، وجود نداشته است. اما با افزایش قدرت و قابلیت اطمینان مدل‌های اقلیمی منطقه‌ای، اخیراً ترکیب هر دو شیوه مورد توجه قرار گرفته است تا بتوان از مزایای هر دو روش ریزمقیاس‌نمایی استفاده کرد. یکی از این شیوه‌ها روش آماره خروجی مدل (MOS) است که در آن ابتدا خروجی مدل گردش کلی جو توسط یک مدل منطقه‌ای ریزمقیاس‌شده و سپس یک مدل آماری برای تصحیح خطا آماری به‌کار گرفته می‌شود (بین، ۲۰۱۱). بابایان و همکاران (۲۰۲۱)، از مدل RegCM4.5 به‌عنوان مدل دینامیکی و از عامل تغییر به‌عنوان مدل آماری برای ریزمقیاس‌نمایی دینامیکی-آماری در استان‌های شرقی ایران استفاده کردند. نتایج نشان داد که روش ریزمقیاس‌نمایی ترکیبی استفاده‌شده باعث نزدیک شدن داده‌های مدل به دیدبانی شده است. ژو و همکاران (۲۰۲۱) یک چارچوب کاری ترکیبی ریزمقیاس‌نمایی دینامیکی-آماری را ارائه دادند. در این روش کار از مدل دینامیکی منطقه‌ای WRF و مدل ریزمقیاس‌نمایی آماری

دینامیکی فرایندی زمانبر است و نیاز به توان پردازشی بالایی دارد، در زمان انجام این مطالعه نتایج اجرای مدل RegCM4 برای دوره ۱۹۸۲ تا ۲۰۱۰ در دسترس بود.

از آنجاکه داده‌های بازتحلیل و داده‌های خروجی سامانه CFSv2-RegCM4 هم از لحاظ مقیاس زمانی و هم از لحاظ شبکه‌بندی مکانی با هم تفاوت دارند قبل از هرگونه عملیات بیشتر باید این داده‌ها از لحاظ شبکه‌بندی مکانی و مقیاس زمانی همسان شوند. لذا عملیات پیش‌پردازشی برای هردو گروه داده‌ها صورت پذیرفت. از آنجاکه تفکیک مکانی داده‌های خروجی سامانه CFSv2-RegCM4 بزرگ‌مقیاس‌تر از داده‌های ERA5 بود، کلیه داده‌های ERA5 نیز با استفاده از الگوریتم درون‌یابی دو خطی به شبکه‌بندی سامانه CFSv2-RegCM4 بزرگ‌مقیاس شدند. شایان ذکر است که قبل از انجام بزرگ‌نمایی مقیاس کلیه داده‌ها در صورت لزوم به مقیاس زمانی ماهانه تبدیل شدند. جدول ۱ مشخصات داده‌ها را نشان می‌دهد.

عربستان سعودی، امارات متحده عربی و ازبکستان با مساحت تقریبی ۶/۵ میلیون کیلومتر مربع است. متوسط ارتفاع از سطح دریا در این منطقه از ۲۳۰- تا ۵۶۲۰ متر متغیر می‌باشد.

در این مطالعه داده‌ها به دو بخش داده‌های بازتحلیل ERA5 (مرجع) و مدل تقسیم می‌شوند. دلیل استفاده از داده‌های بازتحلیل اولاً عدم دسترسی به داده‌های مشاهداتی در کل منطقه مورد مطالعه و ثانیاً به دلیل تأیید دقت قابل قبول داده‌های بازتحلیل ERA5 در مطالعات گذشته است (ایزدی و همکاران، ۲۰۲۱؛ ملایری و همکاران، ۲۰۲۱؛ تقی‌زاده و همکاران، ۲۰۲۱). داده‌های بارش و دمای ماهانه، بازتحلیل ERA5 از پایگاه داده Copernicus برای سال‌های ۱۹۸۲ تا ۲۰۱۰ با تفکیک مکانی ۰/۱ درجه دریافت شد. منظور از داده‌های مدل در این مطالعه، داده‌های مدل CFS.v2 در دوره تاریخی (۱۹۸۲ تا ۲۰۱۰) است که توسط مدل RegCM4 تا مقیاس مکانی ۳۰ کیلومتر ریزمقیاس شده است. از آنجاکه ریزمقیاس‌نمایی



شکل ۱. منطقه مورد مطالعه.

جدول ۱. مشخصات تفکیک مکانی و زمانی داده‌های مورد استفاده.

| سامانه CFSv2-RegCM4 | | بازتحلیل ERA5 | | نوع داده |
|---------------------|------------------------|-------------------------|-------------------------|------------------------|
| تفکیک زمانی | تفکیک مکانی | تفکیک زمانی | تفکیک مکانی | |
| ۶ ساعت | ۰/۲۷ درجه (۳۰ کیلومتر) | متوسط ماهانه | ۰/۱ درجه (۱/۱۱ کیلومتر) | دما ماهانه سطح دو متری |
| | | متوسط روزانه | | دما پیشینه و کمینه |
| | | متوسط نرخ روزانه در ماه | | بارش |

۲-۲. مدل RegCM4

در این مطالعه از مدل RegCM 4.2 (RegCM4) که در مرکز بین‌المللی فیزیک تئوری عبدالسلام توسعه یافته است، استفاده شد. این مدل با بهره‌گیری از مختصات عمودی سیگما- p قادر است شرایط مختلف حساسیت و محلی بودن در مناطق متفاوت را در نظر بگیرد. در مدل RegCM4 طرحواره شرایط مرزی کره اصلاح شده هولتسلاگ ۱۹۹۰ و دانشگاه واشنگتن (توسعه یافته توسط گرنیر و برتھرتون، ۲۰۰۱)، طرحواره رطوبت SEBEX توسعه یافته توسط پال و همکاران (۲۰۰۰)، طرحواره‌های نرخ شار طول موج بلند و کوتاه و شار تشعشع حرارتی برگرفته از مدل آب و هوایی جامعه مرکز ملی تحقیقات آب و هوایی (NCAR) (کیهل و همکاران، ۱۹۹۶)، مدل انتقال تابش سریع (RRTM) (ملاور و همکاران، ۱۹۹۷)، مدل زمین جامعه (CLM) (برونکه و همکاران، ۲۰۱۶)، طرحواره‌های تشکیل ابر همرفتی اصلاح شده کو (انتھاس و همکاران، ۱۹۸۷)، گرل (گرل، ۱۹۹۳)، اماموئل (امانوئل، ۱۹۹۱)، تایتک (تایدتکه، ۱۹۸۹)، کین-فریچ ۱۹۹۰ (کین، و فریتسچ ۱۹۹۰) و ۲۰۰۴ (کین، ۲۰۰۴) در تنظیمات فیزیکی مدل RegCM4 برای انتخاب در دسترس هستند.

مدل RegCM4 در این مطالعه با پارامترسازی‌های جدول ۲ اجرا شد. این پارامترسازی بر اساس مطالعات گذشته (بابایان و همکاران، ۲۰۲۱) انجام شده است. جهت اجرای مدل داده‌های شرایط مرزی و شرایط اولیه دوره ۱۹۸۲ تا ۲۰۱۰ (دوره پیش‌بینی گذشته‌نگر مدل) از بانک اطلاعاتی این مدل (<https://cfs.ncep.noaa.gov/cfsv2/downloads.html>) بارگیری شد. شایان ذکر است که برای این دوره تنها داده‌های پیش دید یک در دسترس عموم محققین می‌باشد. شرایط اولیه و مرزی شامل کلیه متغیرهای اصلی رطوبت نسبی، فشار، ارتفاع ژئوپتانسیل، دما و باد با دقت مکانی حدود ۱ در ۱ کیلومتر است. با بهره‌گیری از این پارامترسازی ذکر شده در جدول ۲ برونداد خروجی مدل CFS.v2 تا مقیاس مکانی ۳۰ کیلومتر توسط مدل منطقه‌ای

RegCM4 ریزمقیاس‌نمایی شد. اطلاعات پوشش گیاهی و ارتفاعی مورد استفاده در مدل RegCM4 به ترتیب داده‌های GLCC و GTOPO می‌باشند. دمای سطح دریا (SST) مورد استفاده در این مطالعه نیز از داده‌های GISST مرکز هادلی سنتر با دقت مکانی یک درجه استفاده شد. مدل با دریافت شرایط اولیه در شروع ماه و شرایط مرزی ماه پیش‌رو، برای یک ماه آینده شبیه‌سازی را با تفکیک مکانی ۳۰ کیلومتر و زمانی ۶ ساعته انجام داد. این عمل برای تمام دوره مورد مطالعه به صورت ماه به ماه و با در نظر گرفتن سه روز برای زمان تطبیق انجام شد.

جدول ۲. مشخصه‌های مدل RegCM4 استفاده شده در این مطالعه.

| طرحواره شرایط مرزی کره | طرحواره‌های تشکیل ابر همرفتی | طرحواره رطوبت |
|---------------------------|------------------------------|----------------------|
| هولتسلاگ و همکاران (۱۹۹۰) | تایدتکه (۱۹۸۹) | پال و همکاران (۲۰۰۰) |

۲-۳. درخت تصمیم

درخت تصمیم یکی از روش‌های داده‌کاوی و ابزارهای قوی و متداول برای دسته‌بندی و پیش‌بینی می‌باشد که برخلاف شبکه‌های عصبی به تولید قانون می‌پردازد (دستورانی و همکاران، ۱۳۹۱). یعنی درخت تصمیم پیش‌بینی خود را در قالب یک سری قوانین توضیح می‌دهد. در حالی که در شبکه‌های عصبی تنها پیش‌بینی بیان می‌شود و چگونگی آن در خود شبکه پنهان باقی می‌ماند. علاوه بر آن در درخت تصمیم‌گیری برخلاف شبکه‌های عصبی، می‌توان از داده‌های غیر عددی نیز استفاده کرد، به عبارتی این ساختار تصمیم‌گیری می‌تواند به شکل تکنیک‌های ریاضی و محاسباتی که به توصیف دسته‌بندی و عام‌سازی یک مجموعه از داده‌ها کمک می‌کنند، نیز معرفی شود (هند و همکاران، ۲۰۰۱). درختان تصمیم‌گیری به دو نوع درختان طبقه‌بندی شده و رگرسیونی تقسیم می‌شوند؛ به طوری که اگر متغیر پاسخ مقداری گسسته داشته باشد به آن درخت طبقه‌بندی شده و

تابع ریسک تجربی را محاسبه کرد:

$$R_{emp}[f(\vec{x})] = \frac{1}{N} \sum_{i=1}^N l(y_i - f(\vec{x}_i)) \quad (۳)$$

که در آن N تعداد داده‌ها است. این کمینه‌سازی ریسک تجربی کلاسیک بدون هیچ ابزار کنترل ساختار یا قانون‌گذاری توصیه نمی‌شود. بنابراین، یک تابع ریسک قانون‌گذاری شده با حداقل شیب از میان توابعی که تابع ریسک کلاسیک را کمینه می‌کنند، می‌تواند استفاده شود:

$$R_{reg}[f(\vec{x})] = R_{emp}[f(\vec{x})] + \gamma \|\vec{w}\|^2 \quad (۴)$$

که در آن γ یک ثابت بیشتر یا مساوی صفر است. اجزای اضافی فضای مدل را کم کرده و بنابراین پیچیدگی راه‌حل را کاهش می‌دهند. به همین دلیل ساختار پیش‌روی این رابطه می‌تواند در نظر گرفته شود (کیمن، ۲۰۰۸؛ سمولا، ۱۹۹۶):

$$R_{reg}[f(\vec{x})] = C_c \sum_{\vec{x}_i \in X} l_\varepsilon(y_i - f(\vec{x}_i)) + \frac{1}{2} \|\vec{w}\|^2 \quad (۵)$$

که در آن C_c ثابت مثبت (پارامتر کنترل ظرفیت اضافی) است که از قبل باید تعیین شود (باتوجه به استفاده از بسته ماشین بردار پشتیبان نرم‌افزار متلب در این مطالعه، این مقدار با یک روش ابتکاری توسط خود بسته تعیین و بهینه می‌شود). این ثابت روی نرخ تبادل بین یک خطای تخمین تأثیرگذار است و بردار (وزن) رگرسیون $\|\vec{w}\|$ یک پارامتر طراحی است. تابع هدررفت در این عبارت که تابع هدررفت غیرحساس ε نامیده می‌شود این مزیت را دارد که برای توصیف بردار رگرسیون \vec{w} نیاز به تمام داده‌ها نخواهد داشت و می‌تواند به صورت زیر بازنویسی شود:

$$l_\varepsilon(y_i - f(\vec{x}_i)) = \begin{cases} 0 & \text{for } |y_i - f(\vec{x}_i)| < \varepsilon \\ |y_i - f(\vec{x}_i)| & \text{otherwise} \end{cases} \quad (۶)$$

این تابع به هنگام ترکیب شدن با عبارت قانون‌گذاری $(\gamma \|\vec{w}\|^2)$ مانند یک تخمین‌گر بایاس عمل می‌کند. میزان هدررفت زمانی صفر است که اختلاف بین مقدار تخمینی و مقدار مورد انتظار کمتر از ε باشد. انتخاب ε معمولاً آسان‌تر از انتخاب C_c است زیرا این مقدار معمولاً به‌عنوان درصدی از خروجی‌های مورد انتظار است. بنابراین، تابع رگرسیون غیرخطی به شکل زیر است (کیمن،

زمانی که درخت مقادیر پیوسته را پیش‌بینی کند، نوع رگرسیونی را به آن نسبت می‌دهند (طالبی و اکبری، ۱۳۹۲). در این پژوهش درخت تصمیم رگرسیونی به‌عنوان یکی از انواع درختان تصمیم جهت پس‌پردازش خروجی سامانه CFS.v2-RegCM4 استفاده شده است. ساختار این درختان بر سه اصل استوار است:

(۱) مجموعه‌های از سؤالات به شکل $x \leq d$ که در آن x یک متغیر مستقل و d یک مقدار ثابت است و جواب هر سؤال بله یا خیر است.

(۲) بهترین معیار شاخه‌زدن جهت انتخاب بهترین متغیر مستقل برای ایجاد شاخه جدید.

(۳) ایجاد آمار خلاصه برای گره انتهایی (برایمان و همکاران، ۱۹۸۴).

۲-۴. مدل ماشین بردار پشتیبان

ایده اصلی ماشین بردار پشتیبان که به نام فرایند کلاس‌بندی رگرسیون معروف است توسط واینیک (۲۰۱۳) توسعه داده شد. رگرسیون بردار پشتیبان برای بیان رگرسیون با بردارهای پشتیبان در متن باز استفاده می‌شود. در تقریب رگرسیون با استفاده از رگرسیون بردار پشتیبان تلاش می‌شود تا یک تابع وابستگی $f(\vec{x})$ بین یک سری داده نمونه X و مقادیر هدف Y برقرار شود. با فرض این که این نمونه‌ها از یک تابع توزیع احتمالی ناشناس $(P(\vec{X}, Y))$ و یک کلاس از توابع حاصل شده باشد، رابطه زیر برقرار است:

$$F = \{f | f(\vec{x}) = (\vec{w}, \vec{x}) + B : \vec{w} \in R^n, R^n \rightarrow R\} \quad (۱)$$

که در آن \vec{w} و B ضرایبی هستند که باید به دست آیند. \vec{x} سری نمونه و F مجموعه توابع است. در اینجا مشکل اصلی یافتن تابع $f(\vec{x}) \in F$ است که تابع را کاهش دهد:

$$R[f(\vec{x})] = \int l(y - f(\vec{x}), \vec{x}) dP(\vec{x}, y) \quad (۲)$$

که در آن l تابع هدررفت است که اختلاف بین میزان هدف y و میزان تخمینی را بیان می‌کند. از آنجا که تابع توزیع احتمالی $P(\vec{x}, y)$ ناشناخته است، کمینه‌کردن $R[f(\vec{x})]$ به صورت مستقیم ممکن نیست و تنها می‌توان

۲۰۰۸؛ گون، ۱۹۹۸؛ واپنیک، ۲۰۱۳):

$$f(x) = \sum_{i=1}^N (\alpha_i^* - \alpha_i) K(x, x_i) + B \quad (7)$$

که در آن α_i و $\alpha_i^* \geq 0$ ضرایب لاگرانژ، B بایاس، و $K(x, x_i)$ تابع کرنل که بر اساس فضای هیلبرت کرنل بازسازی شده است. به طور معمول فرض می شود که میانگین داده ها صفر است (این کار با پیش پردازش می تواند حاصل شود)، لذا جزء بایاس حذف می شود. تابع کرنل منجر می شود تا عملیات در فضای ورودی صورت پذیرد تا در فضای به مراتب گسترده تر مشخصه ها. بنابراین هر محصول داخلی در فضای مشخصه ها یک کرنل معادل در فضای ورودی دارد. به طور معمول توابع کرنل که توسط رگرسیون بردار پشتیبان استفاده می شوند توابع چند جمله ای، پرسپترون چند لایه، اسپلی لاین و غیره هستند. در این مطالعه به علت حجم بالای داده ها و محدودیت های پردازشی از تابع کرنل خطی استفاده شد.

در طول فرایند یادگیری توسط رگرسیون تابع بردار، هدف یافتن تابع غیرخطی رابطه ۷ که تابع ریسک (رابطه ۳) را کمینه می کند، است. این امر برای کمینه کردن یک شاخص خطا (مانند ریشه متوسط مربعات خطا) برای پارامترهای ثابت C_c و ϵ و توابع کرنل مختلف با مقادیر ثابت σ انجام می شود. این فرایند در محیط نرم افزار متلب صورت گرفت.

۲-۵. شاخص بارش استاندارد شده

درک این که بارندگی تأثیرهای مختلفی بر منابع آب مانند آب زیرزمینی، ذخایر آب سطحی و برف دارد، منجر به این شد که شاخص بارش استاندارد شده، تدوین و ارائه شود. شاخص SPI برای اندازه گیری کمبود بارندگی از منابع مختلف می باشد. رطوبت خاک در زمان کوتاه تری شرایط غیرنرمال بارندگی را منعکس می کند، در حالی که آب زیرزمینی، جریان های سطحی و ذخایر آب سطحی در زمان طولانی تری نسبت به آن عکس العمل نشان می دهند. SPI در هر منطقه بر اساس آمار بلندمدت و برای دوره مورد نظر محاسبه می شود. برای این کار در ابتدا

توزیع آماری گاما بر آمار بلندمدت بارندگی ها ماهانه و یا مجموع بارندگی در هر مقیاس زمانی دلخواه برآزش داده می شود (مک کی و همکاران، ۱۹۹۳) و تابع توزیع احتمال تجمعی آن محاسبه می شود. با انتقال این احتمال تجمعی به توزیع نرمال مقادیر شاخص SPI برای آن منطقه و دوره مورد محاسبه می شود (جهت مطالعه ریز محاسبات این شاخص به سعیدی پور و همکاران، ۱۳۹۸ مراجعه کنید). مقدار مثبت SPI نشان دهنده بارندگی بیش از بارندگی میانه می باشد و مقدار منفی معنای عکس آن را دارد. از آنجایی که SPI یک شاخص استاندارد شده است، برای اقلیم های خشک و مرطوب قابل استفاده، و نتایج برای دوره مورد نظر قابل مقایسه است. طبق این روش دوره خشکسالی هنگامی اتفاق می افتد که SPI به طور مستمر منفی و به مقدار -1 یا کمتر برسد، و هنگامی پایان می یابد که SPI مثبت شود و مقادیر تجمعی SPI نیز، بزرگی و شدت دوره خشکسالی را نشان می دهد. طبقه بندی مقادیر SPI در جدول ۳ آمده است.

جدول ۳. محدوده های شاخص های SPI و SPEI و توصیف آنها (سعیدی پور و همکاران، ۱۳۹۸).

| مقدار SPI یا SPEI | توصیف |
|-------------------|-------------------|
| ۲ و بالاتر | بسیار بسیار مرطوب |
| ۱/۵۰ تا ۱/۹۹ | بسیار مرطوب |
| ۱ تا ۱/۴۹ | نسبتاً مرطوب |
| ۰/۹۹ تا -۰/۹۹ | نزدیک نرمال |
| -۱/۴۹ تا -۱/۰ | نسبتاً خشک |
| -۱/۹۹ تا -۱/۵۰ | بسیار خشک |
| -۲ و کمتر | بسیار بسیار خشک |

۲-۶. شاخص استاندارد شده بارش-تبخیر-تعرق

شاخص خشکسالی استاندارد بارش-تبخیر-تعرق توسط ویسنه سرامو و همکاران (۲۰۱۰) ارائه شد. SPEI یک شاخص خشکسالی اقلیمی می باشد که درجه خشکسالی و ترسالی را نشان می دهد. محاسبه این شاخص همانند محاسبه شاخص SPI است با این تفاوت که شاخص SPEI بر اساس بارش، دما و تبخیر-تعرق پتانسیل محاسبه

حساب سانتی‌گراد است. ضریب K_T توسط رابطه زیر تعیین می‌شود:

$$K_T = 0.00185(TD^2) - 0.0433TD + 0.4023 \quad (11)$$

و مقدار R_a نیز به شکل زیر محاسبه می‌شود:

$$R_a = 37.6dr(W_s \sin\phi \cdot \sin\delta + \cos\phi \cos\delta \sin W_s) \quad (12)$$

$$W_s = \arccos(-\tan\phi \tan\delta) \quad (13)$$

$$dr = 1 + 0.033\cos(0.0172J) \quad (14)$$

$$\delta = 0.409\sin(0.0172J - 1.39) \quad (15)$$

$$J = \text{integer}(30.5M - 14.6) \quad (16)$$

که در آن R_a تابش بر زمین ($MJm^{-2}d^{-1}$)، W_s زاویه ساعتی غروب خورشید (رادیان)، dr فاصله نسبی زمین تا خورشید، δ ، زاویه میل خورشیدی (رادیان)، ϕ ، عرض جغرافیایی (رادیان)، M ، شماره ماه میلادی و J شماره روز ژولیوسی از ابتدای سال میلادی هستند. میزان تبخیر-تعرق پتانسیل ماهانه با استفاده داده‌های دمای بازتحلیل ERA5 به‌عنوان داده‌های مرجع و با استفاده از داده‌های دمای خروجی سامانه CFSv2-RegCM به‌عنوان داده‌های ورودی به مدل‌های پس‌پردازش محاسبه و مورد استفاده قرار گرفتند.

۲-۸. روش کار

در مطالعه حاضر جهت دستیابی به اهداف، ابتدا پیش‌بینی‌های ماهانه بارش مدل CFS.v2 با پیش‌دید یک در دوره ۱۹۸۲ تا ۲۰۱۰ با استفاده از مدل RegCM4 تا تفکیک مکانی ۳۰ کیلومتر ریزمقیاس شدند. این داده‌های بارش سپس به‌عنوان ورودی به مدل‌های درخت تصمیم و ماشین بردار پشتیبان و داده‌های بارش ERA5 به‌عنوان داده‌های مرجع جهت پس‌پردازش خورانده شد. جهت پیش‌بینی ماهانه تبخیر-تعرق پتانسیل نیز، ابتدا با استفاده از داده‌های بارش و دما (دو متری سطح زمین، بیشینه و کمینه) ERA5 و با بهره‌گیری از روش هارگریوز-سامانی تبخیر-تعرق پتانسیل بازتحلیل محاسبه شد. با بهره‌گیری از

می‌شود. در این روش ابتدا میزان تبخیر-تعرق پتانسیل محاسبه شده، سپس اختلاف بارش و تبخیر تعرق برای ماه i ام به وسیله رابطه ۸ محاسبه می‌شود:

$$D_i = P_i - ET_{0i} \quad (8)$$

که D اختلاف مقدار تبخیر ماهانه از مقدار بارندگی (mm/day)، P_i بارندگی ماهانه (mm) و ET_{0i} تبخیر تعرق مرجع ماهانه (mm) می‌باشند. تبخیر-تعرق مرجع با روش‌های تجربی محاسبه می‌شود و یا این که از برون‌داد مدل‌های پیش‌بینی یا داده‌های بازتحلیل استفاده شود. شایان ذکر است در این مطالعه از روش هارگریوز-سامانی برای محاسبه تبخیر-تعرق پتانسیل استفاده شد. پس از محاسبه این اختلاف، ابتدا تابع تراکم احتمال D بر اساس تابع توزیع لوگ لوجستیک (ویسته سرامو و همکاران، ۲۰۱۰) محاسبه می‌شود. سپس تابع توزیع احتمالی سری D نیز به‌دست آمده و شاخص SPEI بر اساس معادله ۹ محاسبه می‌شود (سعیدی پور و همکاران، ۱۳۹۸).

$$SPEI = W - \frac{C_0 + C_1W + C_2W^2}{1 + d_1W + d_2W^2 + d_3W^3} \quad (9)$$

که در آن $W = \sqrt{2\ln(P)}$ برای $P \leq 0.5$ و P احتمال بیشتر شدن مقادیر تعیین شده D هستند. مقادیر $d_3=1.432788$ ، $d_2=0.189269$ ، $d_1=0.001308$ ، $C_2=2.515517$ و $C_1=0.802853$ ، $C_0=0.010328$ جدول ۲ طبقه‌بندی این شاخص را نشان می‌دهد (ویسته سرامو و همکاران، ۲۰۱۰).

۲-۷. هارگریوز سامانی

روش هارگریوز-سامانی (هارگراوس و سامانی، ۱۹۸۵) یکی از روش‌های تخمین تبخیر-تعرق پتانسیل بر پایه دما است. معادله اساسی روش هارگریوز-سامانی به شکل زیر است:

$$ET_0 = 0.0135(K_T) \cdot R_a \cdot TD^{0.5} (T + 17.8) \quad (10)$$

که در آن، ET_0 تبخیر-تعرق مرجع میلی‌متر در روز، TD اختلاف دما بیشینه و کمینه ماه، T متوسط دمای ماهانه بر

در ماه) سامانه دینامیکی CFS.v2-RegCM4 را نشان می‌دهد. بهترین شاخص‌های آماری داده‌های خام سامانه CFSv2-RegCM4 در ماه‌های دسامبر و ژانویه مشاهده می‌شود. درحالی که پس از پس‌پردازش توسط مدل‌های درخت تصمیم و ماشین بردار پشتیبان بهترین شاخص‌های به‌ترتیب در ماه‌های می و مارس مشاهده می‌شوند. طبق جدول، اگر چه هر دو روش پس‌پردازش قادر به بهبود دقت پیش‌بینی‌ها بوده‌اند، ولی مدل درخت تصمیم بر اساس شاخص‌های ارزیابی کاراتر از مدل بردار پشتیبان ظاهر شده است. در مقایسه میزان بهبود حاصله در شاخص‌های ارزیابی قبل و بعد از پس‌پردازش (شکل ۲)، باز هم مدل درخت تصمیم شاخص‌های کارایی را به مراتب بهتر از مدل بردار پشتیبان بهبود بخشیده است به گونه‌ای که حداکثر بهبود حاصل شده در دقت پیش‌بینی‌ها توسط مدل درخت تصمیم حدود ۳۵۰ درصد و برای شاخص مجذور متوسط مربعات خطا در ماه می قابل مشاهده است و میزان بهبود حاصله توسط مدل بردار پشتیبان تنها حدود ۱۴۰ درصد برای همان شاخص و در همین ماه است. وجه مشترک هر دو مدل حصول نتایج ضعیف‌تر در ماه‌های پربارش در مقایسه با ماه‌های کم بارش است.

جهت مقایسه مکانی کارایی مدل‌های پس‌پردازش درخت تصمیم و ماشین بردار پشتیبان نقشه کلیه مقادیر RMSE، R^2 و NS برای همه ماه‌ها ترسیم شدند. از آنجا که تعداد این نقشه‌ها زیاد هستند (۱۰۸ نقشه برای هر متغیر) در اینجا نقشه شاخص NS - که سخت‌گیرترین شاخص ارزیابی به کارگرفته شده در این مطالعه است - برای ماه دسامبر ارائه شده است (شکل ۳). در نقشه ترسیم شده با توجه به تعریف شاخص NS، به مقادیر بیش از صفر این شاخص که حاکی از بهتر بودن استفاده از مدل به جای میانگین طولانی مدت است، برچسب قابل قبول و به مقادیر کمتر از صفر برچسب قابل قبول الصاق شد. به علاوه به پیکسل‌هایی با شاخص NS بیش از ۰/۵ برچسب خوب اطلاق شده است. همان‌گونه که در شکل مشاهده می‌شود، هر دو مدل در محدوده شرقی و جنوب شرق کشور

داده‌های مشابه حاصل از خروجی سامانه پیش‌بینی ماهانه CFS.v2-RegCM4 و روش مشابه، تبخیر-تعرق پتانسیل پیش‌بینی نیز محاسبه شد. مدل‌های درخت تصمیم و ماشین بردار پشتیبان برای تخمین تبخیر-تعرق پتانسیل باز تحلیل با استفاده از مقدار مشابه پیش‌بینی سامانه CFS.v2-RegCM4 آموزش داده و آزموده شدند. شایان ذکر است داده‌های دوره ۱۹۸۲ تا ۲۰۰۲ برای آموزش و داده‌های دوره ۲۰۰۳ تا ۲۰۱۰ برای آزمون مدل‌ها به کار گرفته شدند و شاخص‌های نش (NS)، ضریب همبستگی (R^2) و ریشه مربعات خطاها (RMSE) برای بررسی کارایی مدل‌ها استفاده شدند. در پایان پیش‌بینی‌های بهترین مدل پس‌پردازش برای بارش و تبخیر-تعرق پتانسیل جهت محاسبه مقادیر شاخص بارش استاندارد شده و شاخص بارش تبخیر-تعرق پتانسیل استاندارد شده مورد استفاده قرار گرفتند. این شاخص‌ها با شاخص‌های محاسبه شده با داده‌های ERA5 مقایسه و تحلیل شد.

$$R^2 = \frac{\sum_{t=1}^n ((P_t - \bar{P})(\hat{P}_t - \bar{\hat{P}}))}{\sqrt{\sum_{t=1}^n ((P_t - \bar{P}))^2 \sum_{t=1}^n ((\hat{P}_t - \bar{\hat{P}}))^2}} \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{P}_t - P_t)^2} \quad (18)$$

$$NS = 1 - \frac{(\bar{\hat{P}} - \bar{P})^2}{(\bar{P} - \bar{\hat{P}})^2} \quad (19)$$

که در آن P_t متغیر مشاهداتی در زمان t ، \bar{P} متوسط متغیر مشاهداتی، \hat{P}_t میزان تخمینی متغیر، $\bar{\hat{P}}$ میانگین میزان تخمینی متغیر و n تعداد داده‌ها است. بر اساس این تحلیل کاراترین مدل پس‌پردازش انتخاب شده و با استفاده از بارش و تبخیر تعرق خروجی این مدل مقادیر SPI و SPEI محاسبه می‌شود. این مقادیر به صورت مکانی با مقادیر SPI و SPEI محاسبه شده با داده‌های بازتحلیل مقایسه می‌شود.

۳. نتایج

۳-۱. بارش

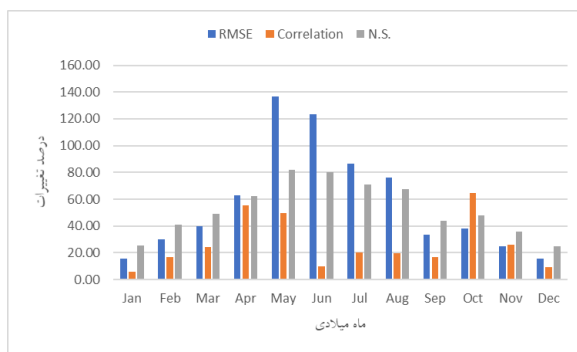
جدول ۴ میزان شاخص‌های آماری RMSE، R^2 و NS را برای کارایی مدل درخت تصمیم (DT) و ماشین بردار پشتیبان (SVM) در پس‌پردازش پیش‌بینی بارش (میلیمتر

لذا از لحاظ مکانی نیز درخت تصمیم در این ماه تا حدودی بهتر از مدل ماشین بردار پشتیبان عمل کرده که با نتایج ذکر شده در جدول ۴ برای ماه دسامبر همخوانی دارد.


کارایی بالاتری نسبت سایر مناطق از خود نشان داده‌اند. وسعت محدوده‌ها با کارایی قابل قبول در هر دو مدل بسیار نزدیک است اما به هنگام استفاده از مدل درخت تصمیم محدوده‌ها با شاخص NS خوب بیشتر به چشم می‌خورد.

جدول ۴. مقادیر شاخص‌های کارایی پیش‌بینی بارش سامانه CFS.v2-RegCM4، مدل ماشین بردار پشتیبان و درخت تصمیم.

| CFS.v2-RegCM4 | | | CFS.v2-RegCM4-SVM | | | CFS.v2-RegCM4-DT | | | مدل |
|---------------|----------------|-------|-------------------|----------------|-------|------------------|----------------|-------|------------|
| NS | R ² | RMSE | NS | R ² | RMSE | NS | R ² | RMSE | ماه میلادی |
| -۰/۱۱ | ۰/۴۲ | ۴۱/۰۶ | ۰/۱۷ | ۰/۴۴ | ۳۵/۵ | ۰/۵۶ | ۰/۷۷ | ۲۵/۷۶ | ژانویه |
| -۰/۵ | ۰/۳۵ | ۴۶/۰۳ | ۰/۱۱ | ۰/۴۱ | ۳۵/۳۸ | ۰/۵ | ۰/۷۴ | ۲۶/۴۱ | فوریه |
| -۰/۴۷ | ۰/۴ | ۴۸/۸۸ | ۰/۲۴ | ۰/۵ | ۳۴/۹۹ | ۰/۴۹ | ۰/۷۳ | ۲۸/۶۵ | مارس |
| -۱/۰۷ | ۰/۳۷ | ۵۹/۲۶ | ۰/۲۲ | ۰/۵۷ | ۳۶/۴۲ | ۰/۶۵ | ۰/۸۱ | ۲۴/۲۳ | آوریل |
| -۳/۷۴ | ۰/۳۲ | ۸۰/۸۹ | ۰/۱۵ | ۰/۴۸ | ۳۴/۲۱ | ۰/۷۹ | ۰/۸۹ | ۱۷/۲۱ | می |
| -۳/۶۶ | ۰/۳۴ | ۷۹/۰۵ | ۰/۰۷ | ۰/۳۷ | ۳۵/۳۶ | ۰/۷۲ | ۰/۸۵ | ۱۹/۵۱ | ژوئن |
| -۲/۳۹ | ۰/۳۳ | ۵۷/۹۹ | ۰/۰۳ | ۰/۴ | ۳۱/۱۱ | ۰/۷۹ | ۰/۹ | ۱۴/۳۲ | ژولای |
| -۱/۹۷ | ۰/۲۶ | ۴۷/۴۲ | ۰/۰۴ | ۰/۳۱ | ۲۶/۹۴ | ۰/۶۴ | ۰/۸۵ | ۱۶/۵۸ | آگوست |
| -۰/۷۱ | ۰/۳ | ۴۳/۸۲ | ۰/۰۴ | ۰/۳۵ | ۳۲/۸۹ | ۰/۷۷ | ۰/۸۸ | ۱۵/۹ | سپتامبر |
| -۰/۶۲ | ۰/۳ | ۴۵/۷۶ | ۰/۱۵ | ۰/۴۹ | ۳۳/۱۰ | ۰/۷۰ | ۰/۸۴ | ۱۹/۷۹ | اکتبر |
| -۰/۲۸ | ۰/۳۸ | ۴۱/۵۴ | ۰/۱۸ | ۰/۴۸ | ۳۳/۲۵ | ۰/۵۱ | ۰/۷۶ | ۲۵/۶۸ | نوامبر |
| -۰/۱۵ | ۰/۴ | ۴۰/۳۸ | ۰/۱۴ | ۰/۴۳ | ۳۵/۰۱ | ۰/۴۷ | ۰/۷۴ | ۲۷/۳۵ | دسامبر |

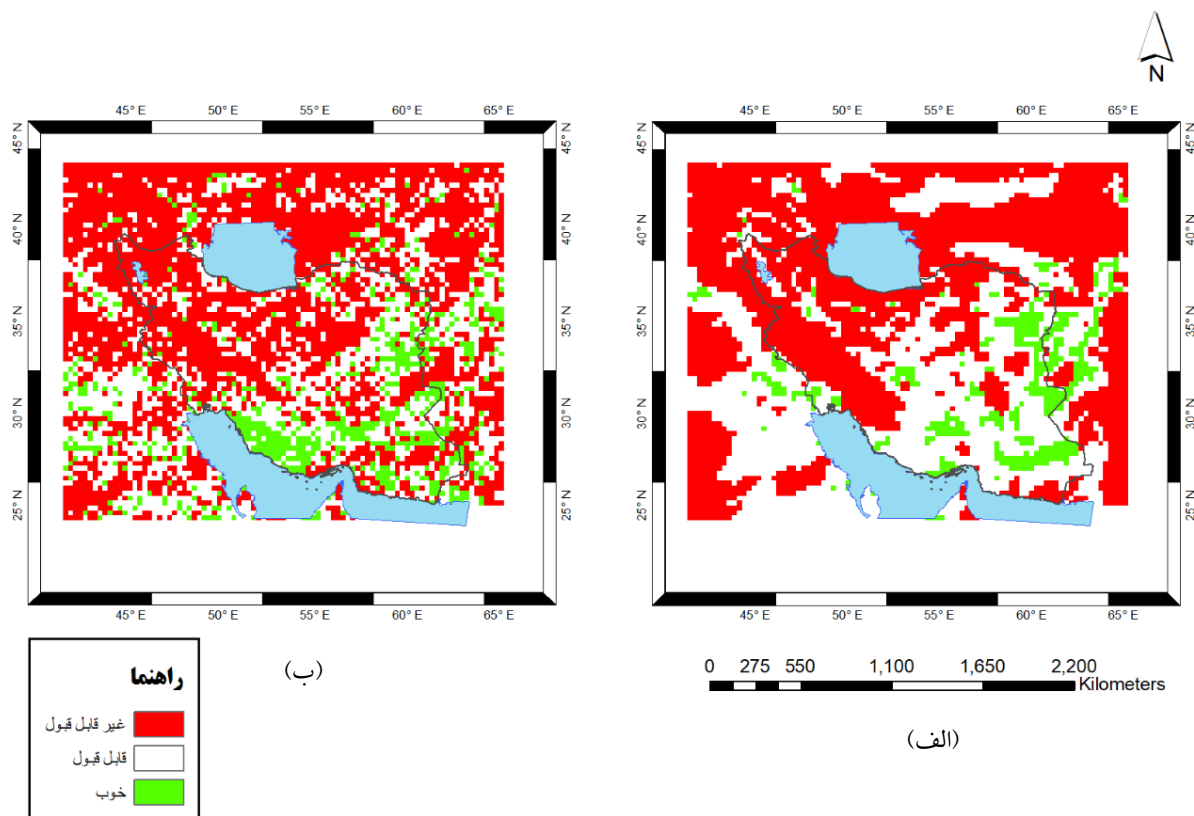


(ب)



(الف)

شکل ۲. درصد تغییرات در شاخص‌های کارایی پیش‌بینی بارش بعد از پس‌پردازش آماری توسط مدل‌های درخت تصمیم (الف) و ماشین بردار پشتیبان (ب).



شکل ۳. مقادیر مکانی شاخص نش (NS) برای متغیر بارش در ماه دسامبر، الف) مدل ماشین بردار پشتیبان، ب) مدل درخت تصمیم).


ماه‌های دسامبر و آپریل میزان بهبود شاخص‌ها به ترتیب در بیشترین و کمترین میزان خود بوده است (شکل ۴). همانند متغیر بارش، نقشه مقادیر مکانی NS برای تبخیر-تعرق پتانسیل در ماه دسامبر به‌عنوان نمونه در شکل ۵ آورده شده است. هر دو مدل در جنوب شرق کشور عملکرد بالاتری از خود نشان داده‌اند. در نقشه ترسیمی از نتایج مدل درخت تصمیم محدوده با مقادیر NS قابل قبول به‌وضوح وسیع‌تر از آن برای مدل ماشین بردار پشتیبان است. به‌علاوه در این نقشه نقاط با شاخص NS خوب دیده می‌شود ولی در نقشه تولیدی توسط مدل ماشین بردار پشتیبان محدوده‌ای با شاخص NS خوب دیده نمی‌شود. لذا در مورد متغیر تبخیر-تعرق پتانسیل نیز می‌توان مدل درخت تصمیم را انتخاب بهتری نسبت به مدل ماشین بردار پشتیبان در ماه دسامبر دانست.

۲-۳. تبخیر-تعرق پتانسیل

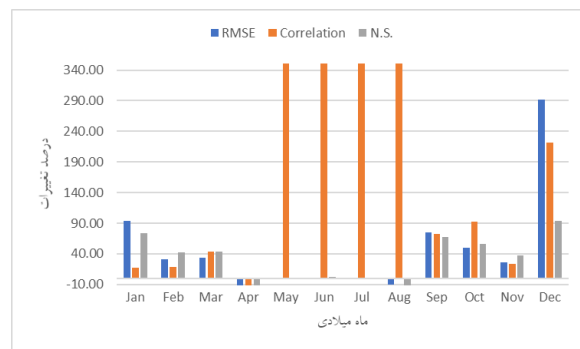
جدول ۵ میزان شاخص‌های آماری برای کارایی مدل‌های درخت تصمیم و ماشین بردار پشتیبان در پس پردازش پیش‌بینی تبخیر-تعرق پتانسیل ماهانه سامانه دینامیکی CFS.v2-RegCM4 (میلیمتر در ماه) را نشان می‌دهد. سامانه CFS.v2-RegCM4 در نوامبر بالاترین توانایی در مدل‌سازی تبخیر-تعرق پتانسیل را داشته است. پس پردازش داده‌های خام این سامانه توسط هر دو مدل درخت تصمیم و ماشین بردار پشتیبان منجر به حصول بهترین عملکرد در ژانویه شده است. استفاده از هر دو مدل برای پس پردازش پیش‌بینی‌ها باعث افزایش دقت در تمام ماه‌ها به جز ماه‌های آپریل تا آگوست شده است. در این ماه‌ها تنها مقادیر ضریب همبستگی بهبود پیدا کرده‌اند ولی دو شاخص دیگر بهبود قابل‌قبولی نداشته‌اند. در

جدول ۵. مقادیر شاخص های کارایی پیش بینی تبخیر-تعرق پتانسیل سامانه CFS.v2-RegCM4، مدل ماشین بردار پشتیبان و درخت تصمیم.

| CFS.v2-RegCM4 | | | CFS.v2-RegCM4-SVM | | | CFS.v2-RegCM4-DT | | | مدل |
|---------------|----------------|--------|-------------------|----------------|--------|------------------|----------------|--------|------------|
| NS | R ² | RMSE | NS | R ² | RMSE | NS | R ² | RMSE | ماه میلادی |
| -۰/۳۳ | ۰/۶۹ | ۳/۶۸ | ۰/۴۹ | ۰/۷۱ | ۲/۲۹ | ۰/۶۵ | ۰/۸۲ | ۱/۹ | ژانویه |
| ۰/۲۶ | ۰/۶۶ | ۵/۴۷ | ۰/۴۱ | ۰/۶۹ | ۴/۹ | ۰/۵۷ | ۰/۷۸ | ۴/۱۶ | فوریه |
| ۰/۰۵ | ۰/۵۲ | ۸/۱۶ | ۰/۲۴ | ۰/۵۵ | ۷/۳۲ | ۰/۴۷ | ۰/۷۴ | ۶/۱ | مارس |
| ۰/۰۹ | ۰/۴۶ | ۱۴/۲۴ | ۰/۲۲ | ۰/۴۷ | ۱۳/۲۲ | -۳/۶۵ | ۰/۲۴ | ۳۲/۱۶ | آوریل |
| -۰/۰۳ | ۰ | ۳۴۴/۴۶ | -۰/۰۳ | ۰/۰۷ | ۳۴۴/۴۲ | -۰/۰۲ | ۰/۱۲ | ۳۴۲/۶۲ | می |
| -۰/۰۲ | ۰/۰۱ | ۳۱۳/۳ | -۰/۰۲ | ۰/۰۴ | ۳۱۳/۵۷ | ۰ | ۰/۱۵ | ۳۱۰/۱۵ | ژوئن |
| ۰ | ۰ | ۱۸۱/۲۷ | -۰/۰۱ | ۰/۰۲ | ۱۸۱/۴۱ | ۰ | ۰/۰۶ | ۱۸۱/۱ | ژولای |
| ۰ | ۰/۰۱ | ۱۶۶/۰۵ | ۰ | ۰/۰۲ | ۱۶۶/۱۷ | -۰/۲۵ | ۰/۰۷ | ۱۸۵/۱۹ | اگوست |
| -۰/۴۲ | ۰/۴۴ | ۷/۹۸ | ۰/۱۵ | ۰/۴۳ | ۶/۱۹ | ۰/۵۴ | ۰/۷۷ | ۴/۵۶ | سپتامبر |
| -۰/۱ | ۰/۴ | ۵/۱۹ | ۰/۱۶ | ۰/۴۳ | ۴/۵۲ | ۰/۵۱ | ۰/۷۷ | ۳/۴۵ | اکتبر |
| ۰/۲۷ | ۰/۶۱ | ۴/۱۵ | ۰/۳۲ | ۰/۶۲ | ۴ | ۰/۵۴ | ۰/۷۵ | ۳/۲۹ | نوامبر |
| -۷/۸۱ | ۰/۲۲ | ۸/۶۱ | -۱/۷۱ | ۰/۲۸ | ۴/۷۸ | ۰/۴۲ | ۰/۷۲ | ۲/۲ | دسامبر |

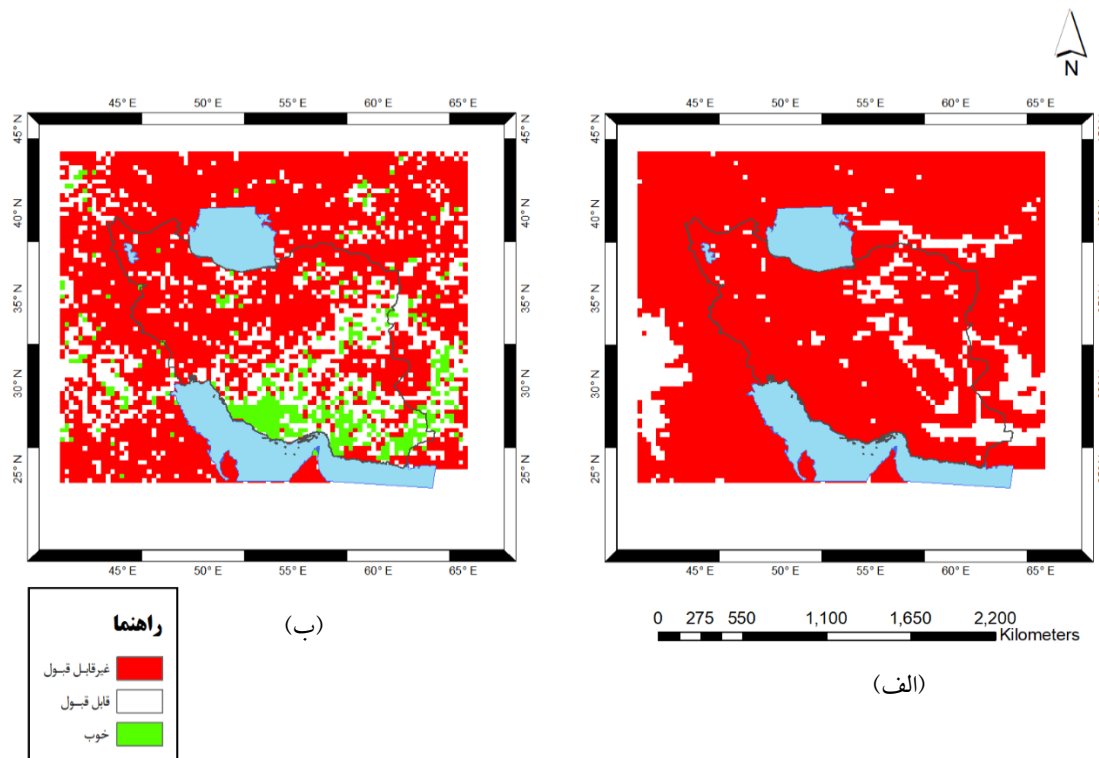


(ب)



(الف)

شکل ۴. درصد تغییرات در شاخص های کارایی پیش بینی تبخیر-تعرق پتانسیل بعد از پس پردازش آماری توسط مدل درخت تصمیم (الف) و ماشین بردار پشتیبان (ب).

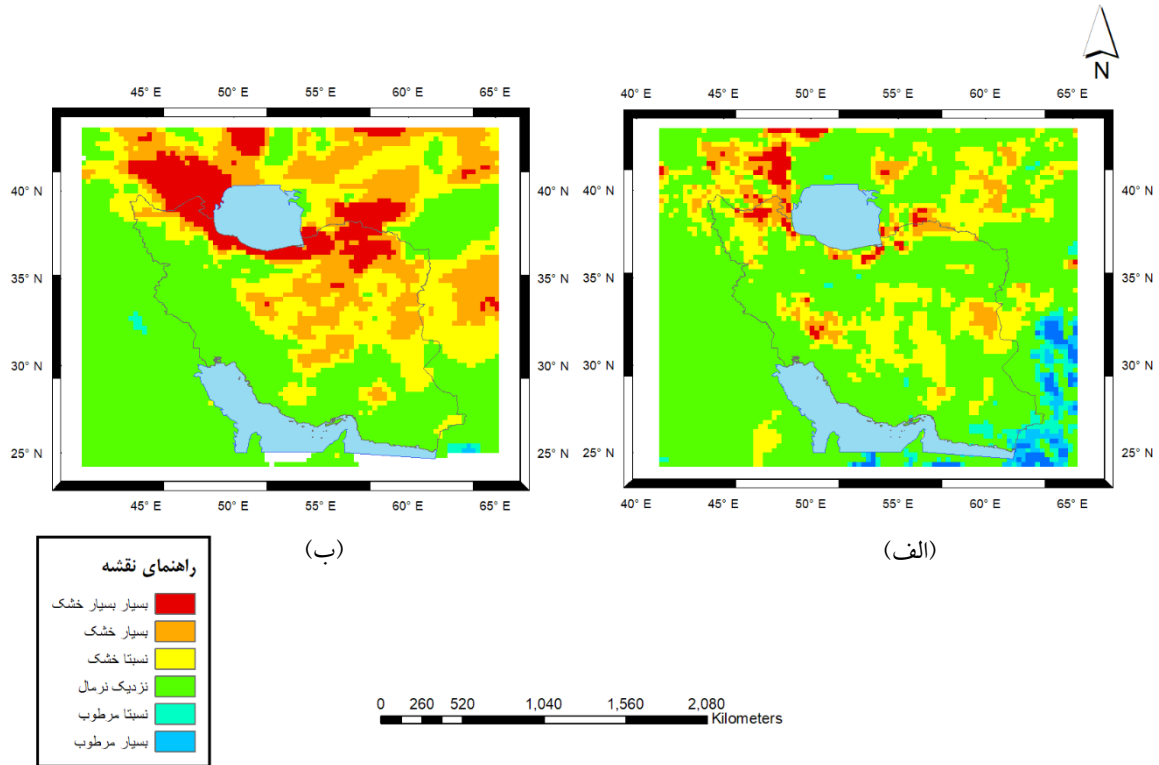


شکل ۵. مقادیر مکانی شاخص نش (N.S.) برای متغیر تبخیر-تعرق در ماه دسامبر، الف) مدل ماشین بردار پشتیبان، ب) مدل درخت تصمیم).

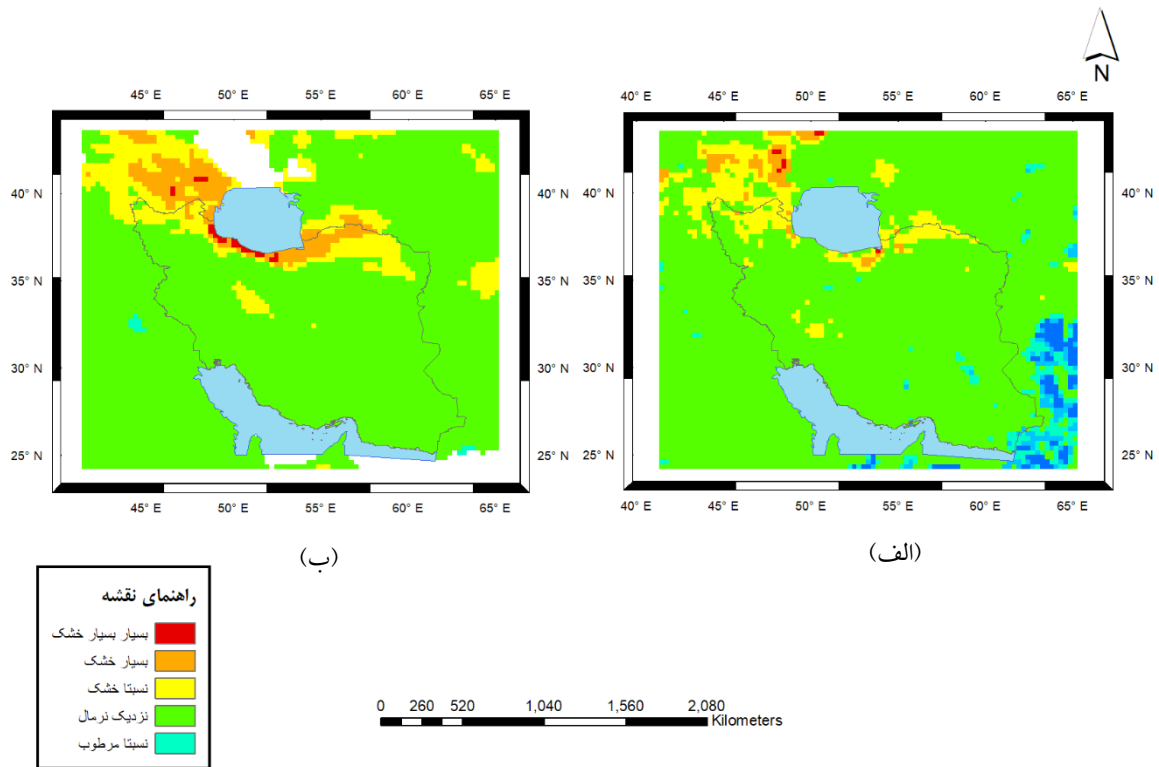
۳-۳. مدل سازی SPI و SPEI یک ماهه

از آنجا که مدل تصمیم درختی در پیش بینی شاخص بارش بهتر از سایر مدل ها عمل کرد، از پیش بینی های این مدل برای محاسبه مقدار SPII از ابتدای دوره مطالعاتی ۱۹۸۲ تا دسامبر ۲۰۱۰ استفاده شد (۳۳۵ نقشه). نقشه این شاخص با نقشه شاخص محاسبه شده با استفاده از داده های بازتحلیل مقایسه شدند. از آنجا که بیشترین اختلاف بین نقشه های بازتحلیل و پیش بینی برای ماه دسامبر ۲۰۱۰ مشاهده شد، نقشه این ماه در این مقاله به عنوان نمونه ارائه شده است. همان گونه که در شکل ۶ مشاهده می شود هر دو نقشه در اکثر مناطق شرایط نرمال بارش را نشان می دهد. اما اختلاف هایی در برخی مناطق به خصوص روی کشور عراق، ترکمنستان، افغانستان، جنوب شرق و مرکز ایران مشاهده می شود. با این حال مجموعاً دقت پیش بینی SPII را می توان تا حدودی قابل قبول دانست. شکل ۷ مقادیر SPEI برای دسامبر ۲۰۱۰ را نشان می دهد. نقشه های این شاخص نیز همانند شاخص SPII

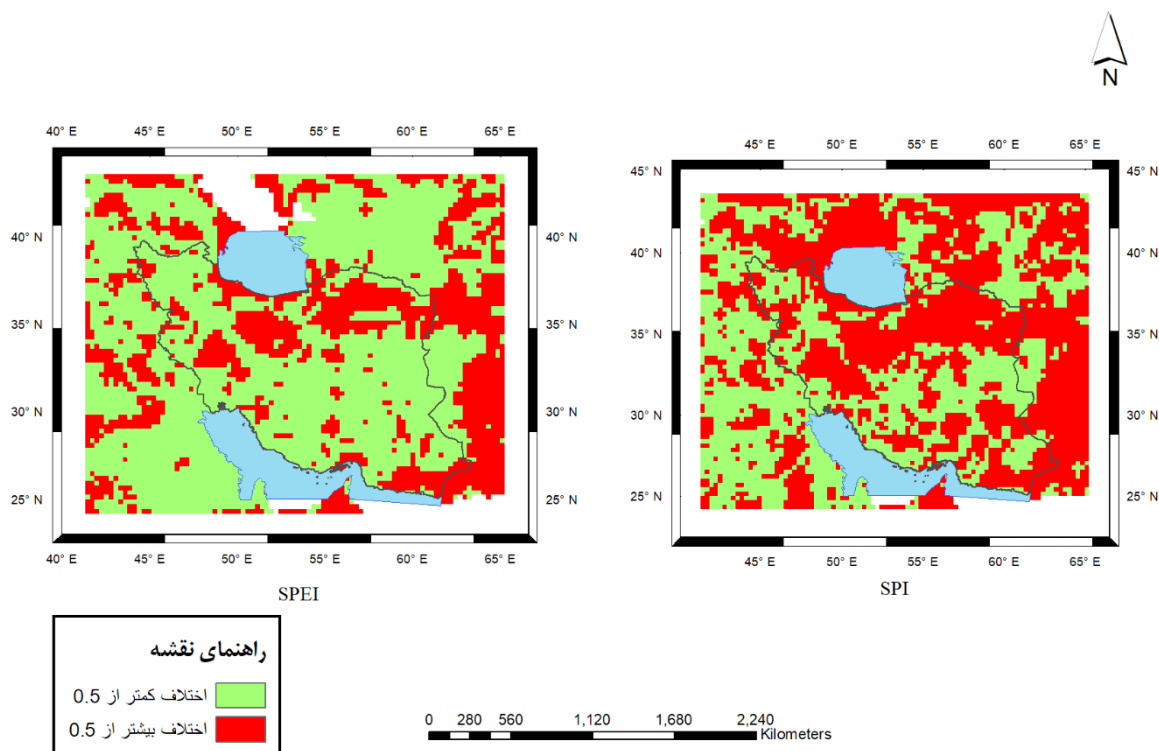
حاکی از نرمال بودن شرایط خشکسالی در اکثر مناطق کشور است و هماهنگی بین نقشه تولید شده توسط مدل پس پردازش درخت تصمیم و داده های باز تحلیل به جز جنوب شرق، شمال غرب و نوار شمالی ایران قابل قبول است. شکل ۸ اختلاف بین مقادیر شاخص های خشکسالی محاسبه شده با استفاده از خروجی سامانه CFS.v2-RegCM4-DT و مقادیر نظیر محاسبه شده با داده های بازتحلیل ERA5 را نشان می دهد. از آنجا که طبق جدول ۳ فاصله طبقه بندی های ۰/۵ هستند در این نقشه نیز اختلاف های بیشتر از ۰/۵ با رنگ قرمز و کمتر از ۰/۵ با رنگ سبز نشان داده شده است. همان گونه که مشاهده می شود اختلاف شاخص SPII در نیمه شمالی کشور نسبت به نیمه جنوبی آن بیشتر است. برای شاخص SPEI شمال غرب، جنوب غرب، جنوب، مرکز، جنوب شرق و شرق کشور اختلاف های اندکی مشاهده می شوند و فقط برای بخشی از محدوده شمالی کشور اختلاف ها بیش از ۰/۵ است.



شکل ۶. شاخص SPI1 ماه دسامبر ۲۰۱۰، (الف) محاسبه شده با استفاده از داده‌های پس‌پردازش شده، (ب) محاسبه شده با استفاده از داده‌های بازتحلیل).



شکل ۷. شاخص SPEI1 ماه دسامبر ۲۰۱۰، (الف) محاسبه شده با استفاده از داده‌های پس‌پردازش شده، (ب) محاسبه شده با استفاده از داده‌های بازتحلیل).



شکل ۸. طبقه‌بندی اختلاف شاخص خشکسالی مقادیر محاسبه شده با خروجی سامانه CFS.v2-RegCM4-DT و داده‌های بازتحلیل ERA5.

۴. بحث و نتیجه‌گیری

دستیابی به اهداف، ابتدا پیش‌بینی‌های ماهانه بارش و دما (دو متری سطح زمین، بیشینه و کمینه) مدل CFS.v2 با پیش‌دید یک در دوره ۱۹۸۲ تا ۲۰۱۰ با استفاده از مدل RegCM4 تا تفکیک مکانی ۳۰ کیلومتر ریزمقیاس شدند. سپس داده‌های بارش با استفاده از مدل‌های درخت تصمیم و ماشین بردار پشتیبان به‌عنوان ورودی و داده‌های بارش ERA5 به‌عنوان داده‌های مرجع پس پردازش شدند. جهت پیش‌بینی ماهانه تبخیر-تعرق پتانسیل نیز، ابتدا با استفاده از داده‌های بارش و دما (دو متری سطح زمین، بیشینه و کمینه) ERA5 و با بهره‌گیری از روش هارگریوز-سامانی تبخیر-تعرق پتانسیل بازتحلیل محاسبه شد. با بهره‌گیری از داده‌های مشابه حاصل از خروجی سامانه پیش‌بینی ماهانه CFS.v2-RegCM4 و روش مشابه تبخیر-تعرق پتانسیل پیش‌بینی نیز محاسبه شد. مدل‌های درخت تصمیم و ماشین بردار پشتیبان برای تخمین تبخیر-تعرق پتانسیل بازتحلیل با استفاده از مقدار مشابه پیش‌بینی سامانه CFS.v2-RegCM4 به‌عنوان ورودی آموزش داده و آزموده شدند. نتایج نشان داده که مدل درخت تصمیم در پس‌پردازش هر دو متغیر بارش و تبخیر-تعرق پتانسیل کارا تر از مدل

ایران در عرض‌های میانی کره زمین و در مکانی واقع شده است که بارندگی در آن از میانگین جهانی کمتر بوده و میزان تبخیر-تعرق نیز بیشتر از میانگین جهانی است. در نتیجه خشکسالی همواره یک چالش اساسی در بسیاری از زمینه‌های از جمله کشاورزی، منابع آب، صنعت، حمل و نقل، شهرسازی و... بوده است. شاخص‌های بارش استاندارد شده بارش (SPEI) و بارش-تبخیر-تعرق پتانسیل استاندارد شده (SPEI) از جمله شاخص‌های خشکسالی آب‌وهوایی است که از محبوبیت و مقبولیت زیادی برخوردار هستند. پایش، مدل‌سازی و پیش‌بینی این شاخص‌ها می‌تواند در تعیین وضعیت خشکی آب‌وهوایی منطقه نقش مهمی ایفا کند. یکی از متداول‌ترین شیوه‌ها، استفاده از برون‌داد مدل‌های جفت‌شده جو-زمین-اقیانوس گردش کلی جو است. اما استفاده از برون‌داد این مدل‌ها به‌خصوص در مقیاس منطقه‌ای مستلزم تصحیح خطا و ریزمقیاس‌نمایی است. تصحیح خطا و ریزمقیاس‌نمایی متغیرهای آب‌وهوایی از طریق دو روش کلی آماری و دینامیکی صورت می‌پذیرد. در مطالعه حاضر جهت

تولید شده با داده‌های بازتحلیل ERA5 نشان می‌دهد که سواحل خزر و بخش‌های شمالی شمال غرب و شمال شرق در شرایط خشکسالی قرار داشته‌اند. این محدوده‌ها با وسعت و شدت خشکی کمتر در نقشه منتج از داده‌های مدل‌سازی شده نیز مشاهده می‌شوند. پیشنهاد می‌شود ساختار کاری ارائه شده برای پیش‌دیدهای دیگر و با بهره‌گیری از روش دیگر پس‌پردازش نیز آزموده شود تا ضعف و قدرت‌های آن بیشتر آشکار شود.

منابع

- ماشین بردار پشتیبان است. این مدل در سطح قابل‌قبولی توانست دقت پیش‌بینی ماهانه بارش را بهبود بخشد. بیشترین افزایش دقت‌ها در ماه‌های آپریل تا آگوست که ماه‌های گرم سال هستند مشاهده می‌شود. با توجه به این امر که روش‌های پس‌پردازش آماری در حذف خطاهای سیستماتیک کارا تر هستند می‌توان این نتیجه را گرفت که سامانه CFS.v2-RegCM از خطای سیستماتیک به خصوص در ماه‌های گرم سال رنج می‌برد. این یافته با نتایج بابیان و همکاران (۲۰۲۱) که اشاره به اربیی بالای خروجی مدل RegCM4 دارد، همخوانی دارد. شرایط در مورد پیش‌بینی ماهانه تبخیر-تعرق پتانسیل کمی متفاوت است به طوری که مدل‌های پس‌پردازش مورد استفاده در ماه‌های آپریل تا آگوست توانایی قابل‌قبولی از خود نشان نداده‌اند و در سایر ماه‌ها هم مدل درخت تصمیم بهتر از مدل ماشین بردار پشتیبان عمل کرده است. تحلیل مکانی شاخص NS برای ماه دسامبر برای هر دو متغیر بارش و تبخیر-تعرق پتانسیل نیز نشان داد که مدل درخت تصمیم می‌تواند گزینه بهتری برای پس‌پردازش خروجی سامانه CFS.v2-RegCM باشد. از آنجا که مدل درخت تصمیم بهتر از مدل ماشین بردار پشتیبان عمل کرد، از خروجی این مدل برای رسم و تحلیل نقشه شاخص‌های SPI1 و SPEI1 استفاده شد. مدل تا حد قابل‌قبولی توانسته مقادیر این دو شاخص را در قیاس با مقادیر تولید شده با داده‌های بازتحلیل ERA5 محاسبه کند. نقشه مدل‌سازی شده SPI با استفاده از داده‌های پس‌پردازش شده، شرایط نسبتاً خشک تا بسیار بسیار خشک را در محدوده شمال غرب، مرکز و نوار کوچکی از شمال را نشان می‌دهد. در حالی که نقشه منتج از داده‌های ERA5 محدوده گسترده‌تری شامل شمال شرق، شمال غرب، شمال و نیمی از کشور را در شرایط خشکی نمایش می‌دهد. اگرچه دقت مدل در پیش‌بینی مقادیر تبخیر-تعرق پتانسیل کمتر از آن برای بارش بود، اما نقشه SPEI1 به واقعیت نزدیک‌تر است و اختلافات کمتری مشاهده می‌شود. شاخص SPEI
- بابیان، ا.؛ خزانه‌داری، ل.؛ عباسی، ف.؛ مدیریان، ر.؛ کریمیان، م. و ملبوسی، ش. (۱۳۹۷). پیش‌بینی ماهانه خشکسالی در حوضه آبریز جنوب غرب کشور با استفاده از مدل CFS.v2.2. مجله تحقیقات منابع آب ایران، ۱۴، ۱۴۵-۱۳۳.
- دستورانی، م.؛ حبیبی‌پور، ا.؛ اختصاصی، م.؛ طالبی، ع. و محجوبی، ج. (۱۳۹۱). بررسی کارایی مدل درخت تصمیم در پیش‌بینی بارش (مطالعه موردی ایستگاه سینوپتیک یزد). مجله تحقیقات منابع آب ایران، ۸، ۲۷-۱۴.
- رحیمی بندرآبادی، س.؛ گودرزی، م. و رضیعی، ط. (۱۴۰۰). بررسی تغییرات اقلیمی حوضه دز با استفاده از ریزمقیاس‌نمایی دینامیکی. فصل‌نامه جغرافیای طبیعی، ۱۳(۵۳)، ۱۹-۳۷.
- سعیدی پور، م.؛ رادمنش، ف.؛ اسلامیان، س. و شریفی، م. ر. (۱۳۹۸). تحلیل منطقه‌ای خشکسالی در حوضه آبریز کارون با استفاده از شاخص‌های SPI و SPEI. مجله علوم آب و خاک، ۲۳(۲)، ۴۱۵-۳۹۷.
- شیخ‌ریعی، م.؛ پیروان، ح.؛ دانشکار آراسته، پ.؛ اکبری، م. و معتمدوزیری، ب. (۱۴۰۰). مقایسه ی کارایی مدل‌های SDSM و CCT در مطالعات تغییر اقلیم (مطالعه موردی حوزه آبخیز کرگانرود). هواشناسی و علوم جو، ۴(۲)، ۱۲۸-۱۴۶.
- صمدی نقاب، س.؛ ساری صراف، ب.؛ ملبوسی، ش. و

- علوم آب و خاک، ۱۷، ۱۰۹-۱۲۱.
- عساکره، ح. و غلامی، آ. (۱۴۰۰). شبیه سازی دمای بیشینه ایستگاه سینوپتیک قزوین با استفاده از ریزمقیاس نمایی آماری خروجی مدل CanESM2. فصلنامه علمی- پژوهشی اطلاعات جغرافیایی سپهر، ۳۰(۱۱۸)، ۴۱-۲۵.
- Anthes, R.A., Hsie, E.-Y., & Kuo, Y.-H. (1987). Description of the Penn State/NCAR Mesoscale Model Version 4 (MM4). NCAR Boulder.
- Babaeian, I., Karimian, M., Modiriyani, R., Falamarzi, Y., & Koochi, M. (2021). Future Precipitation and Temperature Projection over Eastern Provinces of Iran using Combined Dynamical-Statistical Downscaling Technique. *Clim. Chang. Res.*, 2, 41-58. <https://doi.org/10.30488/ccr.2020.252239.1026>.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and Regression Trees*, Chapman & Hall/CRC Press, Boca Raton, FL.
- Brunke, M.A., Broxton, P., Pelletier, J., Gochis, D., Hazenberg, P., Lawrence, D.M., Leung, L.R., Niu, G.Y., Troch, P.A., & Zeng, X. (2016). Implementing and evaluating variable soil thickness in the Community Land Model, version 4.5 (CLM4.5). *J. Clim.*, 29, 3441-3461. <https://doi.org/10.1175/JCLI-D-15-0307.1>
- Bürger, G. (1996). Expanded downscaling for generating local weather scenarios. *Clim. Res.*, 7, 111-128. <https://doi.org/10.3354/cr007111>
- Çimen, M. (2008). Estimation of daily suspended sediments using support vector machines. *Hydrol. Sci. J.*, 53, 656-666. <https://doi.org/10.1623/hysj.53.3.656>
- Crane, R.G., & Hewitson, B.C. (1998). Doubled CO2 precipitation changes for the Susquehanna basin: Down-scaling from the GENESIS general circulation model. *Int. J. Climatol.*, 18, 65-76. [https://doi.org/10.1002/\(SICI\)1097-0088\(199801\)18:165::AID-JOC2223.0.CO;2-9](https://doi.org/10.1002/(SICI)1097-0088(199801)18:165::AID-JOC2223.0.CO;2-9)
- Dai, A. (2001). Global precipitation and thunderstorm frequencies. Part I: Seasonal and interannual variations., *J. Clim.*, 14, 1092-1111. [https://doi.org/10.1175/1520-0442\(2001\)0141092:GPATFP2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)0141092:GPATFP2.0.CO;2)
- Emanuel, K.A. (1991). A scheme for representing cumulus convection in large-scale models. *J. Atmos. Sci.*, 48, 2313-2335. [https://doi.org/10.1175/1520-0469\(1991\)0482313:asfrcc2.0.co;2](https://doi.org/10.1175/1520-0469(1991)0482313:asfrcc2.0.co;2).
- Gnitou, G. T., Ma, T., Tan, G., Ayugi, B., Nooni, I. K., Alabdulkarim, A., & Tian, Y. (2019). Evaluation of the Rossby Centre Regional Climate Model Rainfall Simulations over West Africa using large-scale spatial and temporal statistical metrics. *Atmosphere*, 10(12), 802.
- Grenier, H., & Bretherton, C. S. (2001). A moist PBL parameterization for large-scale models and its application to subtropical cloud-topped marine boundary layers. *Monthly weather review*, 129(3), 357-377.
- Grell, G.A. (1993). Prognostic evaluation of assumptions used by cumulus parameterizations. *Mon. Weather Rev.*, 121, 764-787. [https://doi.org/10.1175/1520-0493\(1993\)1210764:PEOAUB2.0.CO;2](https://doi.org/10.1175/1520-0493(1993)1210764:PEOAUB2.0.CO;2).
- Gunn, S.R. (1998). Support Vector Machines for Classification and Regression. Technical Report, University of Southampton, England.
- Hand, D., Mannila, H., & Smyth, P. (2001). Principles of Data Mining". The MIT Press. In A comprehensive, highly technical look at the math and science behind extracting useful information from large databases, 546.
- Hargreaves, G.H., & Samani, Z.A. (1985). Reference Crop Evapotranspiration from Ambient Air Temperature. Pap. - Am. Soc. Agric. Eng.
- Holtzlag, A.A.M., De Bruijn, E.I.F., & Pan, H.L. (1990). A high-resolution air mass transformation model for short-range weather forecasting. *Mon. Weather Rev.*, 118, 1561-1575. [https://doi.org/10.1175/1520-0493\(1990\)1181561:AHRAMT2.0.CO;2](https://doi.org/10.1175/1520-0493(1990)1181561:AHRAMT2.0.CO;2).
- IPCC. (2007). Climate Change 2007: The Physical Science Basis. Cambridge University Press, 996 pp.
- Izadi, N., Karakani, E.G., Saadatabadi, A.R., Shamsipour, A., Fattahi, E., & Habibi, M. (2021). Evaluation of era5 precipitation accuracy based on various time scales over iran during 2000-2018. *Water (Switzerland)* 13. <https://doi.org/10.3390/w13182538>.
- Jouybari Moghaddam, Y., & Rostami, S. Q. (2018). Fusion of Markov Chain and SAX Method for Drought Probability Analysis

- (Case Study: Eastern District of Isfahan, Iran). *Environmental Management Hazards*, 5(3), 295-311. doi: 10.22059/jhsci.2018.267316.414.
- Kain, J.S., & Fritsch, J.M. (1990). A one-dimensional entraining/detraining plume model and its application in convective parameterization. *J. Atmos. Sci.*, 47, 2784-2802. [https://doi.org/10.1175/1520-0469\(1990\)0472784:AODEPM2.0.CO;2](https://doi.org/10.1175/1520-0469(1990)0472784:AODEPM2.0.CO;2)
- Kain, J.S. (2004). The Kain--Fritsch convective parameterization: an update. *J. Appl. Meteorol.*, 43, 170-181.
- Karimi, M., Melesse, A.M., Khosravi, K., Mamuye, M., & Zhang, J. (2019). Analysis and prediction of meteorological drought using SPI index and ARIMA model in the Karkheh River Basin, Iran, in: *Extreme Hydrology and Climate Variability: Monitoring, Modelling, Adaptation and Mitigation*. Elsevier, 343-353. <https://doi.org/10.1016/B978-0-12-815998-9.00026-9>
- Kiehl, J.T., Hack, J.J., Bonan, G.B., Boville, B.A., Briegleb, B.P., Williamson, D.L. & Rasch, P.J. (1996). Description of the NCAR Community Climate Model (CCM3). NCAR Tech. Note NCAR/TN-420+STR.
- Kouhanestani, Z. K., Khorsandi, F., & Mokhtari, F. (2021). Zoning and determine the best indicator of drought in southwest Iran. In 2021 ASABE Annual International Virtual Meeting (p. 1). American Society of Agricultural and Biological Engineers.
- Luo, L., & Zhang, Y. (2012). Did we see the 2011 summer heat wave coming? *Geophys. Res. Lett.* 39. <https://doi.org/10.1029/2012GL051383>
- Malayeri, A.K., Saghafian, B., & Raziiei, T. (2021). Performance evaluation of ERA5 precipitation estimates across Iran. *Arab. J. Geosci.*, 14, 2676. <https://doi.org/10.1007/s12517-021-09079-8>
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In: *Proceedings of the 8th Conference on Applied Climatology*, 5(10), 179-184.
- Mironov, D., & Raschendorfer, M. (2001). Evaluation of Empirical Parameters of the Technical Report No. 1 New LM Surface-Layer Parameterization Scheme: Results from Numerical Experiments Evaluation of Empirical Parameters of the New LM Including the Soil Moisture Analysis. DWD.
- Mlawer, E.J., Taubman, S.J., Brown, P.D., Iacono, M.J. & Clough, S.A. (1997). Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave. *J. Geophys. Res. Atmos.*, 102, 16663-16682. <https://doi.org/10.1029/97jd00237>
- Moghim, S., & Bras, R.L. (2017). Bias correction of climate modeled temperature and precipitation using artificial neural networks. *J. Hydrometeorol.*, 18, 1867-1884. <https://doi.org/10.1175/JHM-D-16-0247.1>
- Morid, S., Smakhtin, V., & Bagherzadeh, K. (2007). Drought forecasting using artificial neural networks and time series of drought indices. *Int. J. Climatol.*, 27, 2103-2111. <https://doi.org/10.1002/joc.1498>.
- NOAA. (2022). Operational CFSv2 7 Day Rotating Archive, <https://cfs.ncep.noaa.gov/cfsv2/downloads.html>.
- Pal, J.S., Small, E.E., & Eltahir, E.A.B. (2000). Simulation of regional-scale water and energy budgets: Representation of subgrid cloud and precipitation processes within RegCM. *J. Geophys. Res. Atmos.*, 105, 29579-29594. <https://doi.org/10.1029/2000JD900415>
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., Behringer, D., Hou, Y.T., Chuang, H.Y., Iredell, M., Ek, M., Meng, J., Yang, R., Mendez, M.P., Van Den Dool, H., Zhang, Q., Wang, W., Chen, M., & Becker, E. (2014). The NCEP climate forecast system version 2. *J. Clim.*, 27, 2185-2208. <https://doi.org/10.1175/JCLI-D-12-00823.1>
- Shirmohammadi, B., Moradi, H., Moosavi, V., Semiromi, M.T., & Zeinali, A. (2013). Forecasting of meteorological drought using Wavelet-ANFIS hybrid model for different time steps (case study: Southeastern part of east Azerbaijan province, Iran). *Nat. Hazards* 69, 389-402. <https://doi.org/10.1007/s11069-013-0716-9>
- Smola, A. (1996). Regression estimation with support vector learning machines. Master's thesis, Tech. Univ. M unchen.
- Taghizadeh, E., Ahmadi-Givi, F., Brocca, L., & Sharifi, E. (2021). Evaluation of satellite/reanalysis precipitation products over Iran. *Int. J. Remote Sens.*, 42, 3474-3497. <https://doi.org/10.1080/01431161.2021.1875508>
- Tian, D., Wood, E., & Yuan, X. (2017). CFSv2-based sub-seasonal precipitation and temperature forecast skill over the contiguous United States. *Hydrol. Earth Syst. Sci.*, 21, 1477-1490. <https://doi.org/10.5194/hess-21-1477-2017>
- Tiedtke, M. (1989). A comprehensive mass flux scheme for cumulus parameterization in large-scale models. *Mon. Weather Rev.*, 117, 1779-1800. [https://doi.org/10.1175/1520-0493\(1989\)1171779:ACMFSF2.0.CO;2](https://doi.org/10.1175/1520-0493(1989)1171779:ACMFSF2.0.CO;2)
- Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business

- media.
- Serrano V., Sergio M., Beguería, S., & López-Moreno, J., I. (2010). A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *Journal of climate*, 23(7), 1696-1718.
- Von Storch, H. (1999). On the use of “inflation” in statistical downscaling. *J. Clim.*, 12, 3505–3506. [https://doi.org/10.1175/1520-0442\(1999\)0123505:OTUOII2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)0123505:OTUOII2.0.CO;2).
- Yin, Ch. (2011). Applications of self-organizing maps to statistical downscaling of major regional climate variables. Diss. University of Waikato.
- Zarei, A. R., Shabani, A., & Moghimi, M. M. (2021). Accuracy assessment of the SPEI, RDI and SPI drought indices in regions of Iran with different climate conditions. *Pure and Applied Geophysics*, 178(4), 1387-1403.
- Zhou, X., Huang, G., Li, Y., Lin, Q., Yan, D., & He, X. (2021). Dynamical downscaling of temperature variations over the Canadian prairie provinces under climate change. *Remote Sensing*, 13(21), 4350.