

## بهبود شبیه‌سازی متغیرهای اقلیمی با تلفیق مدل‌های گردش عمومی جو و الگوریتم جنگل تصادفی

هادی رضانی اعتدالی<sup>۱\*</sup>، مؤگان احمدی<sup>۲</sup>

<sup>۱</sup>استاد گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

<sup>۲</sup>دانش‌آموخته دکتری، گروه علوم و مهندسی آب، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

تاریخ دریافت: ۱۴۰۴/۱۰/۰۵، تاریخ پذیرش: ۱۴۰۵/۰۲/۱۵

### چکیده

شناخت روندهای آینده تغییر اقلیم و ارزیابی عملکرد مدل‌های اقلیمی در پیش‌نگاری دما و بارش، گامی اساسی در برنامه‌ریزی و مدیریت منابع آب به‌شمار می‌رود. در این مطالعه، به شبیه‌سازی بارش، دمای حداقل و حداکثر و تبخیر و تعرق در ایستگاه هم‌دید قزوین پرداخته شده است. برای این منظور، داده‌های ماهانه دمای حداقل (درجه سانتی‌گراد)، دمای حداکثر (درجه سانتی‌گراد)، تبخیر و تعرق (میلی‌متر) و بارش (میلی‌متر) مدل‌های اقلیمی CanESM5، GFDL-ESM4 و HadGEM3 با داده ایستگاه هم‌دید قزوین در دوره پایه ۱۹۸۶-۲۰۱۴ به‌صورت جداگانه و گروهی مقایسه شد. نتایج نشان داد که اجرای گروهی سه مدل گردش عمومی جو به روش جنگل تصادفی، برای منطقه مورد مطالعه منجر به کاهش خطای شبیه‌سازی و در نتیجه افزایش دقت پیش‌بینی‌ها گردیده است. به‌طوری‌که در شبیه‌سازی دمای حداقل، مدل‌های منفرد RMSE حدود ۲/۴-۲/۶ (درجه سانتی‌گراد) دارند، درحالی‌که مدل ترکیبی در داده‌های آموزش و آزمون به ترتیب ۱ و ۱/۸۳ (درجه سانتی‌گراد) دارد. همبستگی Spearman در هر دو حالت بالا (۰/۹۷-۰/۸۵) است. روند تغییرات متغیرهای اقلیمی با استفاده از آزمون کندال و روش شیب‌سن بررسی شد و نتایج نشان داد که در دوره‌های آینده تحت سناریوهای SSP5-8.5 و SSP2-4.5 روند کاهشی بارش به‌صورت معنی‌دار و در مقابل روند افزایشی دمای حداقل و حداکثر و تبخیر و تعرق به‌صورت معنی‌دار است. به‌طور کلی نتایج نشان داد که در منطقه مورد مطالعه در دهه‌های آینده تحت تأثیر سناریوهای تغییر اقلیم با گرم‌تر شدن دما و کاهش بارش‌های سالانه روبه‌رو خواهد بود؛ موضوعی که لزوم برنامه‌ریزی سازگارانه در بخش آب و کشاورزی را برجسته می‌سازد.

کلمات کلیدی: بارش، تبخیر و تعرق، دما، یادگیری ماشین.

## مقدمه

خشکسالی‌ها از جمله مخاطرات طبیعی هستند که می‌توانند در تمامی مناطق آب‌وهوایی رخ دهند و تأثیرات اقتصادی، اجتماعی و محیط‌زیستی بلندمدتی بر جای گذارند (مرلو و همکاران<sup>۱</sup> (۲۰۲۳)). بسته به افق زمانی و متغیرهای مورد استفاده، این پدیده به انواع مختلفی از جمله خشکسالی‌های هواشناسی، آب‌شناختی و کشاورزی طبقه‌بندی می‌شود (مک کیب و همکاران<sup>۲</sup> (۲۰۲۳)). تغییر اقلیم موجب شده است که خشکسالی به یکی از بزرگ‌ترین مخاطرات طبیعی در اروپا تبدیل شود و مناطق و جمعیت‌های گسترده‌ای را تحت تأثیر قرار دهد (اریملویه و همکاران<sup>۳</sup> (۲۰۲۲)). در ایالات متحده، کمبود بارش عامل اصلی خشکسالی‌های بزرگ گذشته بوده است و دما به‌منزله محرک ثانویه در نظر گرفته می‌شود (ایواز و همکاران<sup>۴</sup> (۲۰۲۲)). در آفریقای جنوبی نیز خشکسالی‌ها منجر به از دست رفتن فرصت‌های شغلی در بخش کشاورزی و کاهش درآمد خانوارها شده‌اند (پاندا و همکاران<sup>۵</sup> (۲۰۲۰)).

خشکسالی‌ها بر اجزای مختلف محیطی از جمله فرآیندهای خاک، رشد و پوشش گیاهی، حیات وحش، کیفیت آب و زیست‌بوم‌های آبی تأثیر منفی می‌گذارند. این پدیده‌ها با محدود کردن دسترسی به منابع آب، می‌توانند پیامدهایی فراتر از مرزهای ملی داشته باشند و امنیت غذایی و محیط‌زیستی را در سطح بین‌المللی تهدید کنند.

در قاره آسیا، افزایش دما، تغییر الگوهای بارش و رشد جمعیت، شدت و فراوانی خشکسالی‌ها را در سال‌های اخیر افزایش داده است. بسیاری از کشورهای آسیایی، از جمله ایران، با چالش‌های جدی در زمینه

مدیریت منابع آب مواجه هستند. در ایران، روند کاهش بارش، بهره‌برداری بی‌رویه از منابع زیرزمینی و تغییر اقلیم موجب گسترش و تشدید دوره‌های خشکسالی شده است که اثرات قابل توجهی بر کشاورزی، منابع آب و پایداری محیط‌زیستی کشور بر جای گذاشته است.

پیش‌بینی خشکسالی به چند دلیل مهم است که در ادامه به آنها اشاره می‌شود. اول، این امر امکان انجام اقدامات اولیه برای کاهش اثرات رویدادهای خشکسالی را فراهم می‌کند. این می‌تواند شامل اقداماتی مانند تخلیه زود هنگام دام و استراتژی‌های مدیریت آب باشد (بوسکر و همکاران<sup>۶</sup> (۲۰۲۲)). دوم، پیش‌بینی دقیق خشکسالی می‌تواند به مدیریت منابع آب زیرزمینی، کشاورزی و اکوسیستم‌ها کمک کند و در نتیجه آسیب‌های اجتماعی و اقتصادی ناشی از خشکسالی را کاهش دهد (یاسین و شاهدی<sup>۷</sup> (۲۰۲۱)). علاوه بر این، پیش‌نگاری شرایط خشکسالی آینده برای جلوگیری از آسیب به منابع کشاورزی و آب‌شناختی در مدل‌هایی که می‌توانند برای پیش‌بینی طبقات شدت خشکسالی استفاده شوند، بسیار مهم است (سون و همکاران<sup>۸</sup> (۲۰۲۳)). همچنین، پیش‌بینی خشکسالی مبتنی بر تأثیر می‌تواند اطلاعات حیاتی برای آمادگی و سازگاری با بلا یا ارائه دهد و تاب‌آوری جامعه را افزایش دهد (رشید و همکاران<sup>۹</sup> (۲۰۲۳)). در نهایت، پیش‌بینی خشکسالی در مقیاس زمانی فصلی می‌تواند بینش‌های مفیدی در مورد افزایش فراوانی و شدت رویدادهای شدید و مکان آنها ارائه دهد (دالمونته و همکاران<sup>۱۰</sup> (۲۰۲۳)). پیش‌بینی دقیق خشکسالی برای کاهش اثرات منفی خشکسالی که بر کشاورزی، مدیریت آب و تاب‌آوری جامعه تأثیر می‌گذارد، ضروری است. این امر برنامه‌ریزی راهبردی کشاورزی را تسهیل می‌کند،

<sup>6</sup> Busker et al

<sup>7</sup> Yaseen & Shahid

<sup>8</sup> Son et al

<sup>9</sup> Rasheed et al

<sup>10</sup> Del Monte et al

<sup>1</sup> Merlo et al

<sup>2</sup> McCabe

<sup>3</sup> Orimoloye et al

<sup>4</sup> Eyvaz et al

<sup>5</sup> Panda et al

و شدت‌های مختلف رخ می‌دهند، مفید باشد. مدل‌های متنوع یادگیری ماشین مانند ماشین بردار پشتیبان (کج و همکاران<sup>۱۱</sup> (۲۰۱۷)، فن و همکاران<sup>۱۲</sup> (۲۰۱۸) ، شبکه‌های عصبی مصنوعی (مورنو و همکاران<sup>۱۳</sup> (۲۰۱۱) ، کومار و همکاران<sup>۱۴</sup> (۲۰۱۵)، گوموش و سکر<sup>۱۵</sup> (۲۰۲۴)) و الگوریتم XGBoost (مختار و همکاران<sup>۱۶</sup> (۲۰۲۱)، گان و همکاران<sup>۱۷</sup> (۲۰۲۵)) به کار گرفته شده‌اند.

در سال‌های اخیر، ایران با چالش‌های فزاینده‌ای در زمینه کاهش بارش، افزایش دما و بهره‌برداری بی‌رویه از منابع آب زیرزمینی روبه‌رو بوده است؛ عواملی که در کنار تغییر اقلیم، موجب گسترش و تشدید پدیده خشکسالی در بخش‌های مختلف کشور شده‌اند. استان قزوین به‌مثابه یکی از قطب‌های مهم کشاورزی ایران، به‌شدت از این تغییرات متأثر گردیده و کاهش منابع آبی در این منطقه پیامدهای قابل توجهی برای امنیت غذایی و پایداری محیط‌زیستی به همراه داشته است. از این‌رو، ارزیابی و پیش‌بینی روندهای آبی خشکسالی در این منطقه از اهمیت ویژه‌ای برخوردار است. در این پژوهش، با هدف ارائه برآوردی دقیق‌تر از شرایط اقلیمی آینده در استان قزوین، سه متغیر کلیدی شامل دما، بارش و تبخیر و تعرق مرجع برای دوره‌های آبی تحت سناریوهای مختلف تغییر اقلیم مورد شبیه‌سازی قرار گرفتند. بدین منظور، خروجی‌های چند مدل منتخب گردش عمومی جو استخراج شده و به‌منظور کاهش عدم قطعیت و افزایش دقت، با الگوریتم یادگیری ماشین جنگل تصادفی تلفیق شدند برای اینکه یک مدل گروهی<sup>۱۸</sup> کارآمد توسعه یابد. استفاده از این رویکرد ترکیبی امکان بازتولید الگوهای پیچیده و غیرخطی رفتار اقلیم را فراهم کرده و

تخصیص منابع آب را بهینه می‌کند و سیستم‌های هشدار اولیه را برای آمادگی در برابر مشکلات مرتبط با خشکسالی بهبود می‌بخشد. پیش‌بینی‌های دقیق برای سازگاری با تغییر اقلیم از طریق هدایت شیوه‌های پایدار و توسعه سیاست‌ها ضروری است. این روش جامع برای پیش‌بینی خشکسالی، تولید کشاورزی در منطقه را افزایش می‌دهد، منابع آب پایدار را تضمین می‌کند و مقاومت در برابر چالش‌های مرتبط با آب و هوا را تقویت می‌کند. بنابراین، پیش‌بینی خشکسالی سنگ بنای مدیریت ریسک پیشگیرانه و مؤثر است. این امر به ذینفعان این امکان را می‌دهد که تصمیمات آگاهانه بگیرند، مداخلات به موقع را اجرا کنند و در مواجهه با تغییر اقلیم، تاب‌آوری ایجاد کنند و در نهایت به توسعه پایدار مناطق آسیب‌پذیر در برابر خشکسالی کمک کنند.

با توسعه فناوری رایانه، یادگیری ماشین، که زیرمجموعه‌ای از هوش مصنوعی است، مدل‌هایی در آب‌شناسی برای مقابله با پدیده‌های پیچیده (معروف‌پور و همکاران<sup>۱</sup> (۲۰۲۳)، عبدالفتاح و عبدو<sup>۲</sup> (۲۰۲۰)، البلتاگی و همکاران<sup>۳</sup> (۲۰۲۰)) از جمله پیش‌بینی خشکسالی (گانگولی و ام‌جی‌ردی<sup>۴</sup> (۲۰۱۴)، موآتادی و همکاران<sup>۵</sup> (۲۰۱۸)، گرانتا و همکاران<sup>۶</sup> (۲۰۱۹)، فنگ و همکاران<sup>۷</sup> (۲۰۱۹)) به کار گرفته شده‌اند. علاوه بر این، استفاده از ابزارهای یادگیری ماشین عملکرد فوق‌العاده‌ای را نشان می‌دهد، زمان کمتری می‌برد و دقت خوبی را ارائه می‌دهد (ماسینده<sup>۸</sup> (۲۰۱۴)، پوزی و همکاران<sup>۹</sup> (۲۰۱۸)، ژو و همکاران<sup>۱۰</sup> (۲۰۱۸)). انعطاف‌پذیری و سازگاری هوش مصنوعی می‌تواند برای پیش‌بینی وقوع خشکسالی‌هایی که با مدت زمان، بسامد

<sup>10</sup> Xu et al

<sup>11</sup> Quej et al

<sup>12</sup> Fan et al

<sup>13</sup> Moreno et al

<sup>14</sup> Kumar et al

<sup>15</sup> Gumus and Seker

<sup>16</sup> Mokhtar et al

<sup>17</sup> Gan et al

<sup>18</sup> Ensemble model

<sup>1</sup> Maroufpoor et al

<sup>2</sup> Abdel-Fattah and Abdo

<sup>3</sup> Elbeltagi et al

<sup>4</sup> Ganguli and M. J. Reddy

<sup>5</sup> Mouatadid et al

<sup>6</sup> Granta et al

<sup>7</sup> Feng et al

<sup>8</sup> Masinde

<sup>9</sup> Pozi et al

موجب بهبود چشمگیر در شبیه‌سازی مؤلفه‌های اقلیمی مورد مطالعه می‌شود. یافته‌های حاصل از این پژوهش می‌تواند تصویری روشن‌تر از روندهای احتمالی تغییرات دما، بارش و تبخیر و تعرق در سناریوهای آینده ارائه دهد و به‌مثابه ابزاری علمی و کاربردی در مدیریت منابع آب، برنامه‌ریزی کشاورزی و تدوین راهبردهای سازگاری با تغییر اقلیم در منطقه قزوین مورد استفاده قرار گیرد.

### مواد و روش‌ها

منطقه مورد مطالعه

استان قزوین در بخش شمال‌غربی ایران جای گرفته و از نظر فعالیت‌های کشاورزی، یکی از مناطق کلیدی کشور محسوب می‌شود. وجود دشت حاصلخیز قزوین با مساحتی نزدیک به ۴۵۰ هزار هکتار، اهمیت ویژه‌ای به این استان در تولید محصولات کشاورزی بخشیده است. بارندگی سالانه در استان تغییرپذیر بوده و از حدود ۲۱۰ میلی‌متر در نواحی شرقی تا بیش از ۵۵۰ میلی‌متر در ارتفاعات شمال‌شرقی افزایش می‌یابد. برای انجام این پژوهش از داده‌های ایستگاه هم‌دید قزوین استفاده شد (جدول ۱).

جدول ۱- مشخصات ایستگاه هواشناسی هم‌دید قزوین

طول جغرافیایی	۵۰/۰۳ درجه شرقی
عرض جغرافیایی	۳۶/۱۵ درجه شمالی
ارتفاع	۱۲۷۹/۲
دوره داده	۲۰۱۴-۱۹۸۵

روش پژوهش

مدل‌های گردش عمومی جو

عملکرد مدل‌ها در دوره تاریخی و تحلیل علل تفاوت در پیش‌بینی‌های آینده است. این همکاری مجموعه‌ای از شبیه‌سازی‌های استاندارد را طراحی می‌کند تا امکان مقایسه نتایج و شناسایی نقاط توافق و اختلاف میان مدل‌ها فراهم شود. در آخرین مرحله (CMIP6)، ۴۹ گروه مدل‌سازی اقلیم با اجرای ۱۰۰ مدل اقلیمی مشارکت دارند؛ در حالی که در مرحله‌ی پیشین (CMIP5)، ۲۰ گروه مجموعاً ۴۰ مدل اقلیم جهانی را توسعه داده بودند. مدل‌های اقلیمی تحت چندین سناریوی مختلف انتشار گازهای گلخانه‌ای اجرا می‌شوند که آینده‌های ممکن مختلفی را نشان می‌دهند. سناریوهای مشخص شده توسط CMIP به همه گروه‌های مدل‌سازی اطلاعات یکسانی را برای استفاده در مدل‌های اقلیمی خود ارائه می‌دهند. در CMIP6، سناریوها به‌منزله مسیره‌ای اجتماعی-اقتصادی مشترک یا SSPها شناخته می‌شوند. SSPها نشان‌دهنده تغییرات در جمعیت، رشد اقتصادی،

طرح<sup>۱</sup> CMIP6 جدیدترین مرحله از همکاری بین‌المللی در قالب پروژه‌ی مقایسه مدل‌های اقلیمی جفت‌شده (CMIP) است. داده‌های CMIP6 به‌روزترین و معتبرترین داده‌های مدل‌های اقلیم جهانی محسوب می‌شوند و مبنای علمی گزارش ششم هیئت بین‌دولتی تغییر اقلیم (IPCC AR6) را تشکیل می‌دهند. پروژه‌ی CMIP زیر نظر برنامه پژوهش اقلیم جهانی سازمان ملل متحد (WCRP) اجرا می‌شود و تیم‌های مدل‌سازی اقلیم از سراسر جهان در آن مشارکت دارند. این برنامه، چارچوب طراحی آزمایش‌ها و مجموعه‌ای از شبیه‌سازی‌های اصلی را برای جامعه مدل‌سازی اقلیم تعیین می‌کند. هدف CMIP ارتقای درک از تغییر اقلیم گذشته، حال و آینده از طریق ارزیابی

<sup>2</sup> Shared Socio-economic Pathways

<sup>1</sup> Coupled Model Intercomparison Project Phase 6

میانی و یک مسیر پراشتار هستند و طیف معقولی از شرایط اجتماعی-اقتصادی و میزان انتشار گازهای گلخانه‌ای در آینده را پوشش می‌دهند. استفاده همزمان از این دو سناریو امکان بررسی حساسیت نتایج به مسیرهای متفاوت انتشار و مقایسه تغییرات اقلیمی تحت شرایط مختلف توسعه را فراهم می‌کند.

در این مطالعه، تبخیر و تعرق مرجع به روش هارگریوز سامانی محاسبه شد (معادله (۱)) (هارگریوز و سامانی<sup>۶</sup>، ۱۹۸۵).

$$ET_0 = R_a \times 0.408 \times 0.0023 \times (T_{mean} + 17.8) \times (T_{max} - T_{min})^{0.5} \quad (1)$$

که در آن  $ET_0$  تبخیر و تعرق مرجع (mm day<sup>-1</sup>)،  $R_a$  تابش فرازمینی (MJ m<sup>-2</sup> d<sup>-1</sup>)،  $T_{max}$ ،  $T_{mean}$  و  $T_{min}$  به ترتیب میانگین، حداکثر و حداقل دمای روزانه (°C)، ۰.۴۰۸ ضریب تبدیل MJ m<sup>-2</sup> d<sup>-1</sup> به mmday<sup>-1</sup> می‌باشد.

#### جنگل تصادفی

الگوریتم جنگل تصادفی (RF)<sup>۸</sup> برای رگرسیون و طبقه‌بندی، از زمان معرفی در سال ۲۰۰۱ (بریمان<sup>۹</sup> (۲۰۰۱))، به‌طور قابل توجهی مورد توجه قرار گرفته و به یک روش استاندارد در حوزه‌های علمی مختلف تبدیل شده است. جنگل تصادفی یک روش ناپارامتری است که نسبت به سایر روش‌های یادگیری ماشین، پیش‌بینی‌های دقیق‌تر و سریع‌تری ارائه می‌دهد (لطفی فرد و همکاران (۲۰۲۲)).

در این پژوهش، به منظور کاهش عدم قطعیت ناشی از به‌کارگیری مدل‌های اقلیمی مختلف، داده‌های بارش خروجی سه مدل منتخب با استفاده از الگوریتم جنگل

آموزش، شهرنشینی و میزان توسعه فناوری هستند که بر انتشار گازهای گلخانه‌ای در آینده تأثیر می‌گذارند و طرحی از چگونگی رسیدن به سطوح خاصی از گرمایش ارائه می‌دهند.

در این پژوهش از داده‌های مجموعه‌ی-GDDP CMIP6 استفاده شده است که بر پایه‌ی خروجی مدل‌های گردش عمومی جو در چارچوب پروژه‌ی CMIP6 و در ارتباط با گزارش ششم تغییر اقلیم<sup>۱</sup> IPCC توسعه یافته‌اند (آیرینگ و همکاران<sup>۲</sup> (۲۰۱۶)). این مجموعه شامل داده‌های شبیه‌سازی شده تحت سناریوهای انتشار گازهای گلخانه‌ای بر اساس مسیرهای اجتماعی-اقتصادی مشترک (SSPs) است؛ از جمله SSP2-4.5 و SSP5-8.5 (انیل و همکاران<sup>۳</sup> (۲۰۱۶))، ماینشوزن و همکاران<sup>۴</sup> (۲۰۲۰)). خروجی مدل‌ها با بهره‌گیری از روش آماری BCSD به صورت روزانه تصحیح آریبی و ریزمقیاس شده و از طریق گوگل ارث (GEE)<sup>۵</sup> در دسترس پژوهشگران قرار گرفته‌اند (تراشر و همکاران<sup>۶</sup> (۲۰۲۲)). این داده‌ها دارای تفکیک مکانی ۰/۲۵ درجه و تفکیک زمانی روزانه هستند. در این مطالعه، داده‌های روزانه‌ی دمای حداقل، دمای حداکثر و بارش مدل‌های اقلیمی CanESM5، GFDL-ESM4 و HadGEM3 تحت دو سناریوی SSP2-4.5 و SSP5-8.5، در دوره‌ی پایه‌ی ۱۹۸۶ تا ۲۰۱۴ و سه بازه‌ی زمانی آینده ۲۰۲۶-۲۰۵۰، ۲۰۵۱-۲۰۷۵ و ۲۱۰۰-۲۰۷۶ مورد تحلیل قرار گرفتند. سه مدل گردش عمومی جو با توجه به عملکرد مناسب آن‌ها در منطقه مطالعه (دسترنج و رستمی (۱۳۹۹))، عساکره و غلامی (۱۴۰۰))، تنوع ساختاری و در دسترس بودن خروجی‌ها تحت سناریوهای منتخب انتخاب شدند. سناریوهای-SSP2 SSP2-8.5 و 4.5 به ترتیب نمایانگر یک مسیر انتشار

<sup>6</sup> Thrasher et al

<sup>7</sup> Hargreaves and Samani

<sup>8</sup> Random Forest

<sup>9</sup> Breiman

<sup>1</sup> Intergovernmental Panel on Climate Change

<sup>2</sup> Eyring et al

<sup>3</sup> O'Neill et al

<sup>4</sup> Meinshausen et al

<sup>5</sup> Google Earth Engine

## آزمون اسپیرمن

آزمون اسپیرمن در اوایل دهه ۱۹۰۰ میلادی توسط چارلز اسپیرمن ارائه شد (یو و همکاران<sup>۴</sup>، ۲۰۰۲). آزمون اسپیرمن یک آزمون غیرپارامتری است (معادله ۵). فرض صفر این آزمون، یکنواختی توزیع و مستقل بودن داده‌ها در سری زمانی و فرض مقابل آن روند افزایشی یا کاهش داده‌ها در سری زمانی است.

$$P = 1 - \frac{6(\sum d_i^2)}{n(n^2 - 1)} \quad (5)$$

P ضریب همبستگی اسپیرمن، n تعداد مشاهده‌ها و  $d_i^2$  مجموع مجذورات تفاوت دو رتبه است. در این پژوهش برای محاسبه ضریب اسپیرمن از نرم‌افزار R استفاده شد.

## ≡ بحث و نتایج

داده‌های ماهانه دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های اقلیمی CanESM5، GFDL-ESM4 و HadGEM3 با داده ایستگاه هم‌دید قزوین در دوره پایه ۲۰۱۴-۱۹۸۶ به صورت جداگانه و گروهی مقایسه شد (جدول ۲). در این مطالعه، به منظور بهبود برآورد داده‌های دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش حاصل از سه مدل گردش عمومی (GCM)، از روش جنگل تصادفی با هدف کمینه‌سازی ریشه میانگین مربعات خطا (RMSE) نسبت به داده‌های مشاهداتی استفاده شد. در این روش، مدل گروهی به روش جنگل تصادفی به گونه‌ای تنظیم شد که ترکیب حاصل، کمترین خطا را نسبت به داده‌های مشاهداتی داشته باشد. به منظور افزایش دقت مدل، ضرایب اصلاحی بارش در فرایند کالیبراسیون تنظیم شدند تا مدل قادر به بازتولید روندهای اقلیمی آینده باشد.

تصادفی ترکیب شدند. جنگل تصادفی با بهره‌گیری از مجموعه‌ای از درخت‌های تصمیم و انتخاب تصادفی متغیرها در فرایند آموزش، قادر است روابط پیچیده و الگوهای پنهان در داده‌ها را شناسایی کرده و پیش‌بینی‌های دقیق‌تری ارائه دهد. در این مطالعه از نرم افزار R برای روش جنگل تصادفی استفاده شده است.

## آماره ارزیابی

برای ارزیابی نتایج به دست آمده از آماره‌های ارزیابی جذر میانگین مربعات خطا (RMSE<sup>۱</sup>)، میانگین مطلق خطا (MAE<sup>۲</sup>)، خطای اریبی (MBE<sup>۳</sup>) و ضریب اسپیرمن استفاده شد. محاسبه شاخص‌های مذکور با استفاده از روابط (۲) تا (۴) امکان‌پذیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (2)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (3)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (4)$$

در روابط یادشده  $O_i$ : مقادیر داده‌های اندازه‌گیری شده،  $P_i$ : مقادیر داده‌های شبیه‌سازی شده،  $\bar{O}_i$ : میانگین مقادیر داده‌های اندازه‌گیری شده،  $\bar{P}_i$ : میانگین مقادیر داده‌های شبیه‌سازی شده و n: تعداد داده‌ها است. RMSE میانگین مقادیر انحراف شبیه‌سازی شده را از مقادیر اندازه‌گیری شده نشان می‌دهد. هرچه مقدار RMSE کوچکتر باشد به معنی مطلوب بودن مدل می‌باشد. شاخص MBE بیانگر میزان اریبی روش است، در یک تخمین نسبتاً دقیق بایستی نزدیک به صفر باشد. شاخص MAE (میانگین مطلق خطا)، میانگین قدر مطلق اختلاف مقدار اندازه‌گیری شده مدل با مقدار واقعی کمیت می‌باشد. هرچه مقدار آن کمتر باشد دقت مدل بالاتر است.

<sup>3</sup> Mean Bias Error<sup>4</sup> Yue et al<sup>1</sup> Root Mean Squared Error<sup>2</sup> Mean Absolute Error

جدول ۲- ارزیابی دمای حداقل، دمای حداکثر، بارش و تبخیر تعرق (۲۰۱۴-۱۹۸۶)



متغیر	مدل	RMSE	MAE	MBE	Spearman
بارش (میلی‌متر)	CanESM5	۳۲/۵۵	۱۹/۵۸	-۶/۳۶	۰/۵۹
	HadGEM3	۳۲/۳۷	۱۹/۳۶	-۵/۸۷	۰/۶۲
	GFDL-ESM4	۳۲/۹۱	۲۰/۵۱	-۵/۳۵	۰/۵۶
	Ensemble (Train)	۲۱/۴۴	۱۳/۵۰	-۰/۱۳	۰/۹۱
	Ensemble (Test)	۲۲/۹۱	۱۷/۵۸	۴/۸۱	۰/۶۲
دمای حداکثر (درجه سانتیگراد)	CanESM5	۲/۶۶	۲/۰۳	۰/۴۰	۰/۹۶
	HadGEM3	۲/۸۸	۲/۱۹	۰/۳۱	۰/۹۶
	GFDL-ESM4	۲/۷۰	۲/۱۰	۰/۱۴	۰/۹۶
	Ensemble (Train)	۱/۵۰	۱/۱۴	-۰/۰۱	۰/۹۱
	Ensemble (Test)	۲/۳۷	۱/۷۸	-۰/۳۴	۰/۸۳
دمای حداقل (درجه سانتیگراد)	CanESM5	۲/۵۵	۲/۱۵	۱/۶۱	۰/۹۷
	HadGEM3	۲/۶۶	۲/۲۲	۱/۵۸	۰/۹۷
	GFDL-ESM4	۲/۴۵	۲/۰۴	۱/۴۶	۰/۹۷
	Ensemble (Train)	۱	۰/۷۵	۰/۰۱	۰/۹۲
	Ensemble (Test)	۱/۸۳	۱/۳۵	۰/۰۹	۰/۸۵
تبخیر و تعرق (میلی‌متر)	CanESM5	۱۴/۴۰	۱۰/۹۶	۰/۵۲	۰/۹۷
	HadGEM3	۱۴/۱۷	۱۱/۲۲	-۰/۶۱	۰/۹۶
	GFDL-ESM4	۱۴/۸۸	۱۱/۵۶	-۰/۸۸	۰/۹۷
	Ensemble (Train)	۵/۴۰	۴/۲۵	-۰/۰۷	۰/۹۵
	Ensemble (Test)	۱۳/۶۷	۱۰/۶۷	-۰/۸۹	۰/۸۱

مدل‌های منفرد دارای RMSE حدود ۳۲-۳۳ میلی‌متر و MAE حدود ۱۹-۲۰ میلی‌متر هستند که نشان‌دهنده خطای نسبتاً زیاد در برآورد بارش است. مدل جنگل تصادفی در داده‌های آموزش عملکرد بسیار بهتری دارد (RMSE = 21.44 Spearman = 0.91) که نشان‌دهنده توان بالای آن در یادگیری الگوهای بارش است. در داده‌های آزمون (Test) نیز اگرچه مقدار RMSE به ۲۲/۹۱ افزایش یافته، اما همچنان نسبت به مدل‌های منفرد بهتر است و همبستگی ۰/۶۲ نشان می‌دهد که مدل توانایی بازتولید نوسانات بارش را به صورت قابل‌قبولی حفظ کرده است. این نتایج نشان‌دهنده برتری مدل ترکیبی در کاهش خطا و افزایش دقت بارش است. در همه مدل‌ها همبستگی بالا (Spearman ≈ 0.96) نشان می‌دهد که تغییرات زمانی دمای حداکثر به خوبی



مدل‌های منفرد دارای RMSE حدود ۳۲-۳۳ میلی‌متر و MAE حدود ۱۹-۲۰ میلی‌متر هستند که نشان‌دهنده خطای نسبتاً زیاد در برآورد بارش است. مدل جنگل تصادفی در داده‌های آموزش عملکرد بسیار بهتری دارد (RMSE = 21.44 Spearman = 0.91) که نشان‌دهنده توان بالای آن در یادگیری الگوهای بارش است. در داده‌های آزمون (Test) نیز اگرچه مقدار

مطالعه اشرف و همکاران (۱۳۹۳) نشان داد که اجرای گروهی پنج مدل گردش عمومی جو برای منطقه شمال شرق ایران منجر به کاهش خطای شبیه‌سازی و در نتیجه افزایش دقت پیش‌بینی‌ها گردیده است. نتایج مطالعات فنک و فو<sup>۱</sup> (۲۰۱۳) نشان داد که اجرای گروهی هشت مدل گردش عمومی جو به روش وزنی، موجب کاهش معنی‌دار خطای اریبی در شبیه‌سازی بارش و دما در مقایسه با اجرای منفرد هر مدل شده است. این نتایج با یافته‌های مطالعه حاضر هم‌راستا و تأییدکننده کارایی روش‌های ترکیبی در بهبود عملکرد مدل‌های اقلیمی است. پیش‌نگری میانگین سالانه دمای حداقل و حداکثر، بارش و تبخیر و تعرق در دوره آینده و تاریخی در شکل (۱) آورده شده است.

شبیه‌سازی شده است. مدل ترکیبی در مرحله آموزش (RMSE = 1.50 MAE = 1.14)، خطا را تقریباً نصف مدل‌های منفرد کاهش داده است. در داده‌های آزمون RMSE = 2.37 است که همچنان بهتر از سه مدل اولیه است. در مجموع، مدل جنگل تصادفی توانسته دقت بالا و تعمیم‌پذیری مناسب را در برآورد دمای بیشینه نشان دهد. در دمای حداقل، عملکرد مدل‌ها مشابه دمای حداکثر است. مدل‌های منفرد RMSE حدود ۲/۴-۲/۶ دارند، در حالی که مدل ترکیبی در داده‌های آموزش تنها RMSE = 1.00 و در داده‌های آزمون RMSE = 1.83 دارد. همبستگی Spearman در هر دو حالت بالا (۰/۹۷-۰/۸۵) است. در تبخیر و تعرق مدل جنگل تصادفی در مرحله آموزش (RMSE = 5.40) و در تبخیر و تعرق مدل جنگل Spearman = 0.95، عملکرد بسیار خوبی دارد. نتایج



<sup>1</sup> Feng and Fu



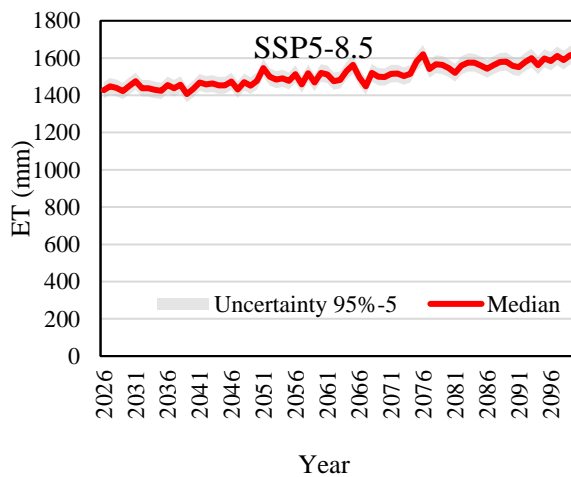



شکل ۱- شبیه‌سازی بارش، دمای حداقل و حداکثر و تبخیر و تعرق در دوره‌های آتی

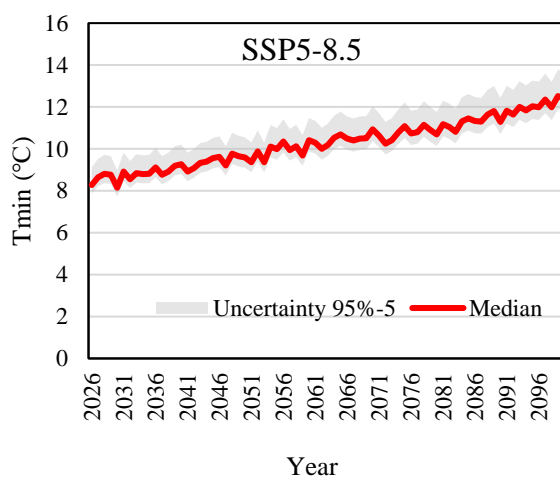



نتایج (شکل ۱) نشان می‌دهد که دمای حداکثر در دوره‌های آتی افزایش می‌یابد به طوری که میزان تغییرات دمای حداکثر نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۲۵ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۱/۵۷ و ۲/۲۱ درجه سانتی‌گراد، در دوره ۲۰۷۵-۲۰۵۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۲/۶۷ و ۴/۶۷ درجه سانتی‌گراد و در دوره ۲۱۰۰-۲۰۷۶ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۳/۳۳ و ۴/۹۹ درجه سانتی‌گراد خواهد بود. دمای حداقل در دوره‌های آتی افزایش می‌یابد و میزان تغییرات آن نسبت به دوره پایه در دوره ۲۰۲۶-۲۰۵۰ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب ۱/۴۹ و ۱/۹۳ درجه سانتی‌گراد خواهد بود. بارش در دوره‌های آتی کاهش می‌یابد و تغییرات آن نسبت به دوره پایه در دوره ۲۰۷۵-۲۰۵۱ برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۱۱/۰۷- و ۲۰/۰۲- میلی‌متر خواهد بود. تبخیر و تعرق در دوره‌های آتی افزایش می‌یابد و میزان تغییرات آن در دوره ۲۱۰۰-۲۰۷۶ نسبت به دوره پایه برای سناریوهای SSP2-4.5 و SSP5-8.5 به ترتیب برابر ۱۳۷/۸۰ و ۲۱۸/۳۳ میلی‌متر خواهد بود. کریمی و همکاران (۱۴۰۲) به بررسی اثرات تغییر اقلیم بر

تبخیر و تعرق مرجع بر اساس سناریوهای گزارش ششم در ایستگاه خرم آباد پرداختند. برای محاسبه تبخیر و تعرق از روش هارگریوز استفاده کردند و نتایج آنها نشان داد که متوسط دمای حداقل و حداکثر و تبخیر و تعرق در دوره‌های آتی نسبت به دوره پایه افزایش می‌یابد که با نتایج مطالعه حاضر همخوانی دارد. دین پژوه و اللهوردی پور (۱۴۰۴) تغییرات تبخیر و تعرق مرجع دشت مغان را مطابق گزارش ششم بررسی کردند. نتایج آنها نشان داد که دمای حداقل و حداکثر تحت بدبینانه‌ترین سناریو (SSP5-8.5) به ترتیب از ۹/۹۵ و ۲۱/۱۲ درجه سانتی‌گراد دوره پایه، به ۱۶/۰۴ و ۲۷/۶۸ درجه سانتی‌گراد در دوره ۲۱۰۰-۲۰۸۱ خواهد رسید. میانگین تبخیر و تعرق مرجع دشت مغان از ۱۱۱۴ (میلی‌متر بر سال) در دوره پایه، با ۲۰ درصد افزایش به ۱۳۳۴ (میلی‌متر بر سال) در دوره ۲۱۰۰-۲۰۸۱ می‌رسد که با نتایج مطالعه حاضر همخوانی دارد. سکر و گیومز (۲۰۲۲) به بررسی پیش‌بینی بارش و دما در منطقه مدیترانه پرداختند. آنها با استفاده از ۲۲ مدل گردش عمومی جواز فاز ششم پروژه CMIP6 و روش کوچک مقیاس‌سازی آماری مبتنی بر شبکه‌های عصبی مصنوعی نشان دادند که مدل‌های گروهی (MME) در شبیه‌سازی دما و بارش عملکرد

تاریخی محاسبه شد. عدم قطعیت پیش‌نگری‌ها با استفاده از صدک‌های ۵ و ۹۵ درصد خطای نسبی تاریخی مدل گروهی برآورد شد که امکان مقیاس‌پذیری عدم قطعیت متناسب با مقدار متغیر را فراهم می‌کند. عدم قطعیت متغیرها در شکل (۲) و میانگین دوره‌ها در جدول (۳) آورده شده است.

بهتری نسبت به مدل‌های منفرد دارند. بر اساس سناریوهای SSP2-4.5 و SSP5-8.5، میانگین بارش به ترتیب حدود ۱۵ و ۲۰ درصد کاهش و میانگین دما به ترتیب ۱ تا ۲/۲ و ۱/۸ تا ۳/۱ درجه سلسیوس افزایش خواهد یافت که با نتایج مطالعه حاضر همخوانی دارد. عدم قطعیت با استفاده از روش کوانتایلی مبتنی بر خطای





شکل ۲- عدم قطعیت پیش‌نگری‌های آینده متغیر بارش، تبخیر و تعرق، دمای حداقل و حداکثر

جدول ۳- محاسبه میانگین عدم قطعیت پیش‌نگری‌های آینده متغیر بارش، تبخیر و تعرق، دمای حداقل و حداکثر برای دوره‌های آبی

متغیر	سناریو	دوره	میانگین	P05	P95
بارش	SSP2-4.5	۲۰۲۶-۲۰۵۰	۳۲۶/۷۳	۲۴۸/۹۷	۵۲۶/۲۷
		۲۰۵۱-۲۰۷۵	۳۲۳/۶۳	۲۴۶/۶۱	۵۲۱/۲۷
		۲۰۷۶-۲۱۰۰	۲۹۶/۳۰	۲۲۵/۷۸	۴۷۷/۲۴
	SSP2-8.5	۲۰۲۶-۲۰۵۰	۳۱۷/۷۸	۲۴۲/۱۵	۵۱۱/۸۵
		۲۰۵۱-۲۰۷۵	۲۹۱	۲۲۱/۷۴	۴۶۸/۷۱
		۲۰۷۶-۲۱۰۰	۲۷۶/۹۱	۲۱۱/۰۱	۴۶۶/۰۲
تبخیر و تعرق	SSP2-4.5	۲۰۲۶-۲۰۵۰	۱۴۱۴/۸۷	۱۳۷۱/۰۱	۱۴۵۸/۷۳
		۲۰۵۱-۲۰۷۵	۱۴۶۲/۱۲	۱۴۱۶/۸۰	۱۵۰۷/۴۵
		۲۰۷۶-۲۱۰۰	۱۴۹۳/۸۲	۱۴۴۷/۵۱	۱۵۴۰/۱۲
	SSP2-8.5	۲۰۲۶-۲۰۵۰	۱۴۷۷/۴۲	۱۴۰۲/۵۵	۱۴۹۲/۲۹
		۲۰۵۱-۲۰۷۵	۱۵۰۵/۴۹	۱۴۵۸/۸۲	۱۵۵۲/۱۶
		۲۰۷۶-۲۱۰۰	۱۵۷۴/۳۵	۱۵۲۵/۵۴	۱۶۲۳/۱۵
دمای حداقل	SSP2-4.5	۲۰۲۶-۲۰۵۰	۲۲/۹۹	۲۲/۲۱	۲۳/۷۷

۲۴/۹۲	۲۳/۲۸	۲۴/۱۰	۲۰۵۱-۲۰۷۵	
۲۵/۶۰	۲۳/۹۲	۲۴/۷۶	۲۰۷۶-۲۱۰۰	
۲۴/۴۴	۲۲/۸۴	۲۳/۶۴	۲۰۲۶-۲۰۵۰	
۲۵/۹۵	۲۴/۲۵	۲۵/۱۰	۲۰۵۱-۲۰۷۵	SSP2-8.5
۲۷/۳۲	۲۵/۵۳	۲۶/۴۳	۲۰۷۶-۲۱۰۰	
۹/۴۷	۸/۱۶	۸/۶۰	۲۰۲۶-۲۰۵۰	
۱۰/۳۳	۸/۹۰	۹/۳۸	۲۰۵۱-۲۰۷۵	SSP2-4.5
۱۰/۹۲	۹/۴۱	۹/۹۲	۲۰۷۶-۲۱۰۰	
۹/۹۵	۸/۵۸	۹/۰۴	۲۰۲۶-۲۰۵۰	دمای حداکثر
۱۱/۳۲	۹/۷۵	۱۰/۲۸	۲۰۵۱-۲۰۷۵	SSP2-8.5
۱۲/۶۸	۱۰/۹۳	۱۱/۵۲	۲۰۷۶-۲۱۰۰	

کاهشی است، اما عدم قطعیت پیش‌نگری آن همچنان بالا بوده و رفتار بارش در آینده با نوسانات قابل توجهی همراه است. در سناریوی SSP2-8.5، هم مقدار میانه بارش و هم بازه عدم قطعیت کاهش بیشتری نسبت به SSP2-4.5 نشان می‌دهد، به‌ویژه در دوره ۲۰۷۶-۲۱۰۰ که میانه بارش به ۲۷۶/۹ می‌رسد. این کاهش همراه با عدم قطعیت قابل توجه بیانگر حساسیت بالای بارش به سناریوی انتشار است. تبخیر و تعرق در هر دو سناریو روند افزایشی مشخصی دارد و همزمان بازه عدم قطعیت آن نیز گسترش می‌یابد. در سناریوی SSP2-4.5، میانه تبخیر و تعرق از ۱۴۱۴/۹ در دوره ۲۰۵۰-۲۰۲۶ به ۱۴۹۳/۸ در دوره پایانی افزایش می‌یابد. در سناریوی SSP2-8.5 این افزایش شدیدتر بوده و مقدار میانه در دوره ۲۰۷۶-۲۱۰۰ به ۱۵۷۴/۴ می‌رسد. افزایش همزمان مقدار مرکزی و عدم قطعیت تبخیر و تعرق نشان می‌دهد که این متغیر نسبت به تغییرات دما و سناریوهای انتشار بسیار حساس است و می‌تواند پیامدهای مهمی برای تراز آبی و مدیریت منابع آب در آینده داشته باشد. دمای حداقل در هر دو سناریو روند افزایشی یکنواختی را نشان می‌دهد. در سناریوی SSP2-4.5، میانه دمای حداقل از ۲۲/۹۹ درجه سانتی‌گراد در دوره ۲۰۵۰-۲۰۲۶ به ۲۴/۷۶ درجه سانتی‌گراد در دوره ۲۰۷۶-۲۱۰۰ افزایش می‌یابد. این


شکل (۲) تغییرات مقدار میانه و بازه عدم قطعیت متغیرهای اقلیمی در دوره‌های آینده را تحت دو سناریوی SSP2-4.5 و SSP2-8.5 نشان می‌دهد. برای تمامی متغیرها، باندهای سایه‌دار بیانگر افزایش عدم قطعیت با طولانی‌تر شدن افق زمانی هستند. همچنین، مقایسه دو سناریو نشان می‌دهد که سناریوی SSP2-8.5 به‌طور کلی منجر به مقادیر میانه بالاتر و بازه‌های عدم قطعیت گسترده‌تر، به‌ویژه در دوره ۲۰۷۶-۲۱۰۰، می‌شود. نتایج جدول (۳) نشان می‌دهد که عدم قطعیت پیش‌نگری متغیرهای اقلیمی در دوره آینده به‌طور محسوسی به سناریوی انتشار و افق زمانی وابسته است. برای تمامی متغیرها، بازه عدم قطعیت (فاصله بین صدک‌های ۵ و ۹۵ درصد) با حرکت از دوره ۲۰۵۰-۲۰۲۶ به ۲۱۰۰-۲۰۷۶ افزایش می‌یابد که بیانگر انباشت عدم قطعیت در افق‌های زمانی بلندمدت است. برای بارش، در هر دو سناریو افزایش قابل توجه عدم قطعیت مشاهده می‌شود. در سناریوی SSP2-4.5، مقدار میانه بارش از حدود ۳۲۶/۷ در دوره ۲۰۵۰-۲۰۲۶ به ۲۹۶/۳ در دوره ۲۱۰۰-۲۰۷۶ کاهش می‌یابد، در حالی که پهنای بازه عدم قطعیت همچنان بزرگ باقی می‌ماند (حدود ۲۷۷ میلی‌متر در دوره اول و ۲۵۱ میلی‌متر در دوره پایانی). این موضوع نشان می‌دهد که اگرچه گرایش مرکزی بارش


افزایش در سناریوی SSP2-8.5 شدیدتر بوده و میانه دما در دوره پایانی به ۲۶/۴۳ درجه سانتی‌گراد می‌رسد. اگرچه بازه عدم قطعیت دمای حداقل نسبت به بارش محدودتر است، اما افزایش تدریجی آن در دوره‌های زمانی آینده نشان می‌دهد که عدم قطعیت دما نیز در افق‌های بلندمدت قابل چشم‌پوشی نیست. نتایج مربوط به دمای حداکثر نیز افزایش پیوسته دما و عدم قطعیت را در هر دو سناریو نشان می‌دهد. در سناریوی SSP2-8.5، میانه دمای حداکثر از ۹/۰۴ درجه سانتی‌گراد در دوره ۲۰۲۶-۲۰۵۰ به ۱۱/۵۲ درجه سانتی‌گراد در دوره ۲۰۷۶-۲۱۰۰ افزایش یافته که همزمان با افزایش قابل توجه بازه عدم قطعیت همراه است. مقایسه دو سناریو نشان می‌دهد که دمای حداکثر، مشابه دمای حداقل، نسبت به مسیر انتشار گازهای گلخانه‌ای حساس بوده و سناریوی

پراشتار منجر به افزایش شدیدتر هم مقدار مرکزی و هم عدم قطعیت پیش‌بینی‌ها می‌شود.

به‌طور کلی، نتایج نشان می‌دهد که عدم قطعیت پیش‌نگری‌ها با افزایش افق زمانی بیشتر می‌شود. سناریوی SSP2-8.5 همواره عدم قطعیت و تغییرات شدیدتری نسبت به SSP2-4.5 ایجاد می‌کند. بارش بیشترین عدم قطعیت را در میان متغیرها دارد، در حالی که دما عدم قطعیت محدودتر اما روند افزایشی واضح‌تری نشان می‌دهد. افزایش تبخیر و تعرق همراه با عدم قطعیت بالا می‌تواند فشار مضاعفی بر منابع آب منطقه در آینده وارد کند.

پیش‌نگری سری زمانی بارش، دمای حداقل و حداکثر و تبخیر و تعرق در شکل (۳) و نتایج آزمون من کندال و شیب سن در جدول (۴) آورده شده است.





شکل ۳- سری زمانی بارش، دمای حداقل و حداکثر و تبخیر و تعرق در دوره‌های تاریخی و آینده

جدول ۴- نتایج آزمون من کندال و روش شیب سن

Sen_slope	Kendall_p	Kendall_tau	سناریو	متغیر
-۰/۲۱۰	۰/۲۶۸	-۰/۱۴۸	Historical	بارش (میلی متر بر سال)
-۰/۵۶۱	p<۰/۰۰۰	-۰/۳۵۴	SSP2-4.5	
-۰/۶۷۰	p<۰/۰۰۰	-۰/۳۹۷	SSP5-8.5	
۰/۰۵۸	۰/۰۰۱	۰/۴۳۸	Historical	دمای حداکثر (درجه سانتی گراد)
۰/۰۳۵	p<۰/۰۰۰	۰/۶۹۰	SSP2-4.5	
۰/۰۵۵	p<۰/۰۰۰	۰/۸۵۱	SSP5-8.5	
۰/۰۴۲	۰/۰۰۱	۰/۴۵۳	Historical	دمای حداقل (درجه سانتی گراد)
۰/۰۲۶	p<۰/۰۰۰	۰/۷۲۵	SSP2-4.5	
۰/۰۵۰	p<۰/۰۰۰	۰/۸۹۰	SSP5-8.5	
۰/۱۰۹	۰/۲۵۳	۰/۱۵۳	Historical	تبخیر و تعرق (میلی متر بر سال)
۱/۴۵۰	p<۰/۰۰۰	۰/۵۹۶	SSP2-4.5	
۱/۴۰۲	p<۰/۰۰۰	۰/۷۳۶	SSP5-8.5	

ضعیف و غیرمعنی دار بوده است، اما در دوره‌های آینده تحت سناریوهای SSP2-4.5 و SSP5-8.5 روند کاهشی بارش به صورت معنی دار مشاهده می‌شود. شیب

نتایج بررسی روند تغییرات متغیرهای اقلیمی با استفاده از آزمون کندال و روش شیب سن نشان داد که در دوره تاریخی، بارش دارای روند کاهشی

منفی بیشتر در سناریوی SSP5-8.5 بیانگر شدت بالاتر کاهش بارش است. در مقابل، حداکثر و حداقل دما در دوره تاریخی روندی افزایشی و معنی‌دار داشته و این روند در سناریوهای آینده تقویت شده است، به گونه‌ای که بالاترین مقادیر ضریب کندال و شیب‌سن در سناریوی SSP5-8.5 به دست آمده است. این امر نشان‌دهنده افزایش قابل توجه میانگین دمای سالانه در آینده است. نتایج مربوط به تبخیر و تعرق پتانسیل نیز نشان دهنده روند افزایشی شدید و معنی‌دار در سناریوهای آتی است که در سناریوی SSP5-8.5 بیشترین مقدار را نشان می‌دهد. به طور کلی، نتایج حاکی از آن است که منطقه مورد مطالعه در آینده با کاهش بارش، افزایش دما و افزایش تبخیر و تعرق پتانسیل مواجه خواهد بود؛ موضوعی که بیانگر افزایش تنش آبی و تشدید شرایط خشک در دوره‌های آتی است.

### نتیجه‌گیری

تغییر اقلیم تأثیرات زیادی بر فرایندهای محیط‌زیستی و جامعه دارد. در این مطالعه داده‌های ماهانه دمای حداقل، دمای حداکثر، تبخیر و تعرق و بارش مدل‌های اقلیمی HadGEM3، GFDL-ESM4، CanESM5 با داده ایستگاه هم‌دید قزوین در دوره پایه ۲۰۱۴-۱۹۸۶ به صورت جداگانه و گروهی مقایسه شد. نتایج نشان داد که اجرای گروهی سه مدل گردش عمومی جو برای منطقه مورد مطالعه منجر به کاهش خطای شبیه‌سازی و در نتیجه افزایش دقت پیش‌بینی‌ها گردیده است. نتایج شبیه‌سازی مدل گروهی در دوره‌های آتی تحت دو سناریو SSP5-8.5 و SSP2-4.5 نشان داد که بارش کاهش و دمای حداقل و حداکثر و تبخیر و تعرق افزایش می‌یابد. روند تغییرات متغیرهای اقلیمی با استفاده از آزمون کندال و روش شیب‌سن بررسی شد و نتایج نشان داد که در دوره‌های آینده تحت سناریوهای SSP5-8.5 و SSP2-4.5 روند کاهشی بارش به صورت معنی‌دار و در مقابل روند افزایشی دمای حداقل و حداکثر و

تبخیر و تعرق به صورت معنی‌دار است. به طور کلی نتایج نشان داد که مدل‌های به کاررفته در ارزیابی سناریوهای تغییر اقلیم توانسته‌اند روندهای محتمل آینده را به خوبی شبیه‌سازی کنند. تحلیل روند متغیرهای اقلیمی بیانگر تغییرات قابل توجهی در بارش، دما و تبخیر و تعرق در دوره‌های آتی است. این تغییرات می‌توانند پیامدهای گسترده‌ای بر منابع آب و شرایط اقلیمی منطقه به دنبال داشته باشند.

### منابع

- اشرف، ب.، علیزاده، ا.، موسوی بایگی، م.، و بنایان اول، م. (۱۳۹۳). صحت سنجی داده‌های دما و بارش شبیه‌سازی شده توسط اجرای منفرد و گروهی پنج مدل AOGCM برای منطقه شمال شرق ایران. آب و خاک، ۲۸ (۲): ۲۶۶-۲۵۳.
- دسترنج، ع.، و رستمی، م. (۱۳۹۹). ارزیابی و پیش‌بینی تغییرات اقلیم در دهه‌های آینده با استفاده از ریزمقیاس‌نمایی مدل‌های گردش عمومی جو (GCMs). جغرافیا و روابط انسانی، ۳ (۱): ۲۶۸-۲۵۲.
- دین پژوه، ی.، و اللهوردی پور، پ. (۱۴۰۴). پایش و پیش‌آگاهی از تغییرات تبخیر-تعرق مرجع دشت مغان نطابق گزارش ششم IPCC. محیط زیست و مهندسی آب، ۱۱ (۱): ۴۷-۵۶.
- عساکره، ح.، و غلامی، ا. (۱۴۰۰). شبیه‌سازی دمای بیشینه ایستگاه هم‌دید قزوین با استفاده از ریزمقیاس‌نمایی آماری خروجی مدل CanESM2. اطلاعات جغرافیایی، ۳۰ (۱۱۸): ۴۱-۲۵.
- کریمی، ر.، نصرالهی، ع.ح.، و ایران‌شاهی، م. (۱۴۰۲). بررسی اثرات تغییر اقلیم بر تبخیر و تعرق مرجع بر اساس سناریوهای گزارش ششم تغییر اقلیم (مطالعه موردی: ایستگاه خرم‌آباد). تحقیقات آب و خاک ایران، ۵۴ (۱۱): ۱۷۷۷-۱۷۵۹.
- Abdel-Fattah, M. K., Mokhtar, A., & Abdo, A. I. (2021). Application of neural network and time series modeling to study the suitability of drain water quality for irrigation: a case study from

19. Gumus, V., & Seker, M. (2024). Projection of meteorological drought in Türkiye's Mediterranean region based on multi-model ensemble from CMIP6. *Hydrological Sciences Journal*, 69(9), 1228-1243.
20. Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Applied engineering in agriculture*, 1(2), 96-99.
21. Kumar, R., Aggarwal, R. K., & Sharma, J. D. (2015). Comparison of regression and artificial neural network models for estimation of global solar radiations. *Renew. Sustain. Energy Rev*, 52, 1294-1299.
22. Lotfirad, M., Esmaeili-Gisavandani, H., & Adib, A. (2022). Drought monitoring and prediction using SPI, SPEI, and random forest model in various climates of Iran. *Journal of Water and Climate Change*, 13(2), 383-406.
23. Maroufpoor, S., Maroufpoor, E., Bozorg-Haddad, O., Shiri, J., & Yaseen, Z. M. (2019). Soil moisture simulation using hybrid artificial intelligent model: Hybridization of adaptive neuro fuzzy inference system with grey wolf optimizer algorithm. *Journal of Hydrology*, 575, 544-556.
24. Masinde, M. (2014). Artificial neural networks models for predicting effective drought index: factoring effects of rainfall variability. *Mitigation and adaptation strategies for global change*, 19(8), 1139-1162.
25. McCabe, G. J., Wolock, D. M., Lombard, M., Dudley, R. W., Hammond, J. C., Hecht, J. S., ... & Wiczorek, M. (2023). A hydrologic perspective of major US droughts. *International Journal of Climatology*, 43(3), 1234-1250.
26. Meinshausen, M., Nicholls, Z. R. J., Lewis, J., Gidden, M. J., Vogel, E., Freund, M., Beyerle, U., Gessner, C., Nauels, A., Bauer, N., Canadell, J. G., Daniel, J. S., John, A., Krummel, P. B., Luderer, G., Meinshausen, N., Montzka, S. A., Rayner, P. J., Reimann, S., Smith, S. J., van den Berg, M., Velders, G. J. M., Vollmer, M. K., and Wang, R. H. J. (2020). The shared socio-economic pathway (SSP) greenhouse gas concentrations and their extensions to 2500. *Geosci. Model Dev.*, 13, 3571-3605.
27. Merlo, M., Giuliani, M., Du, Y., Pechlivanidis, I., & Castelletti, A. (2023, May). A pan-European analysis of drought events and impacts. In *EGU General Assembly Conference Abstracts* (pp. EGU-12961). <https://doi.org/10.5194/egusphere-egu23-12961>
28. Mokhtar, A., Jalali, M., He, H., Al-Ansari, N., Elbeltagi, A., Alsafadi, K., ... & Rodrigo-Comino, J. (2021). Estimation of SPEI meteorological drought using machine learning algorithms. *IEEE Access*, 9, 65503-65523.
29. Moreno, A., Gilabert, M. A., & Martínez, B. (2011). Mapping daily global solar irradiation over Egypt. *Environmental Science and Pollution Research*, 28(1), 898-914.
7. Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
8. Busker, T., de Moel, H., van den Hurk, B., & Aerts, J. C. (2023). Impact-based seasonal rainfall forecasting to trigger early action for droughts. *Science of the Total Environment*, 898, 165506.
9. Dal Monte, T., Cherchi, A., Alessandri, A., & Gaetani, M. (2023, May). Assessing the predictability of droughts through seasonal forecasts. In *EGU General Assembly Conference Abstracts* (pp. EGU-14731).
10. Elbeltagi, A., Aslam, M. R., Malik, A., Mehdinejadani, B., Srivastava, A., Bhatia, A. S., & Deng, J. (2020). The impact of climate changes on the water footprint of wheat and maize production in the Nile Delta, Egypt. *Science of the Total Environment*, 743, 140770.
11. Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9(5), 1937-1958.
12. Eyvaz, M., Albahnasawi, A., Tekbaş, M., Gürbulak, E., Eyvaz, M., Albahnasawi, A., Tekbaş, M., & E. (2022). <https://doi.org/10.5772/intechopen.97906> Drought—Impacts and Management.
13. Fan, J., Wu, L., Zhang, F., Cai, H., Wang, X., Lu, X., & Xiang, Y. (2018). Evaluating the effect of air pollution on global and diffuse solar radiation prediction using support vector machine modeling based on sunshine duration and air temperature. *Renewable and Sustainable Energy Reviews*, 94, 732-747.
14. Feng, S., & Fu, Q. (2013). Expansion of global drylands under a warming climate. *Atmospheric Chemistry and Physics*, 13(19), 10081-10094.
15. Feng, Y., Cui, N., Chen, Y., Gong, D., & Hu, X. (2019). Development of data-driven models for prediction of daily global horizontal irradiance in northwest China. *Journal of cleaner production*, 223, 136-146.
16. Gan, Z., Xie, X., Su, C., Ge, W., Pan, H., & Yang, L. (2025). Understanding the evolutionary processes and causes of groundwater drought using an interpretable machine learning model. *Scientific Reports*, 15(1), 20981.
17. Ganguli, P., & Reddy, M. J. (2014). Ensemble prediction of regional droughts using climate inputs and the SVM-copula approach. *Hydrological Processes*, 28(19), 4989-5009.
18. Granata, F. (2019). Evapotranspiration evaluation models based on machine learning algorithms—A comparative study. *Agricultural Water Management*, 217, 303-315.

- techniques to estimate daily global solar radiation in a warm sub-humid environment. *Journal of Atmospheric and Solar-Terrestrial Physics*, 155, 62-70.
36. Rasheed, N. K. A., Otieno, V., Misiani, H., Ouma, J., Otenyo, E., Kinuya, J., & Amdihun, A. (2023, May). Automatic generation of impact-based drought forecast, implications for early warning and action in East Africa. In *EGU General Assembly Conference Abstracts* (pp. EGU-10940).
  37. Seker, M., & Gumus, V. (2022). Projection of temperature and precipitation in the Mediterranean region through multi-model ensemble from CMIP6. *Atmospheric Research*, 280, 106440.
  38. Son, B., Lee, J., Im, J., & Park, S. (2023, May). Future drought prediction using time-series of drought factors and the US drought monitor data based on deep learning over CONUS. In *EGU General Assembly Conference Abstracts* (pp. EGU-11208).
  39. Thrasher, B., Depsky, N., Taylor, M. A., and Nemani, R. (2022). NASA-NEX-GDDP-CMIP6 Dataset. NASA Earth Exchange.
  40. 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.
  41. Yaseen, Z. M., & Shahid, S. (2021). Drought index prediction using data intelligent analytic models: a review. *Intelligent Data Analytics for Decision-Support Systems in Hazard Mitigation*, 1-27.
  42. Yue, S., Pilon, P., & Cavadias, G. (2002). Power of the Mann-Kendall and Spearman's rho tests for detecting monotonic trends in hydrological series. *Journal of hydrology*, 259(1-4), 254-271.
  - Spain: a comparative study of selected approaches. *Solar Energy*, 85(9), 2072-2084.
  30. Mouatadid, S., Raj, N., Deo, R. C., & Adamowski, J. F. (2018). Input selection and data-driven model performance optimization to predict the Standardized Precipitation and Evaporation Index in a drought-prone region. *Atmospheric research*, 212, 130-149.
  31. O'Neill, B. C., Tebaldi, C., van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J.-F., Lowe, J., Meehl, G. A., Moss, R., Riahi, K., and Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geosci. Model Dev.*, 9, 3461-3482.
  32. Orimoloye, I. R., Belle, J. A., Orimoloye, Y. M., Olusola, A. O., & Ololade, O. O. (2022). Drought: A common environmental disaster. *Atmosphere*, 13(1), 111.
  33. Panda, A., Sahoo, N., Panigrahi, B., & Das, D. M. (2020). Drought Assessment using Standardized Precipitation Index and Normalized Difference Vegetation Index. *Int. J. Curr. Microbiol. App. Sci*, 9, 1125-1136. <https://doi.org/10.20546/ijcmas.2020.907.132>
  34. Pozzi, W., Sheffield, J., Stefanski, R., Cripe, D., Pulwarty, R., Vogt, J. V., ... & Lawford, R. (2013). Toward global drought early warning capability: Expanding international cooperation for the development of a framework for monitoring and forecasting. *Bulletin of the American Meteorological Society*, 94(6), 776-785.
  35. Quej, V. H., Almorox, J., Arnaldo, J. A., & Saito, L. (2017). ANFIS, SVM and ANN soft-computing

# Improving the simulation of climate variables by combining atmospheric general circulation models and the random forest algorithm

Hadi Ramezani Etedali<sup>1\*</sup>, Mojgan Ahmadi<sup>2</sup>

<sup>1</sup>Associate Professor, Department of Water Science and Engineering, Imam Khomeini International University, Qazvin, Iran.

<sup>2</sup>Ph.D. Graduate, Department of Water Science and Engineering, Imam Khomeini International University, Qazvin, Iran.

\*Corresponding Author Email: [ramezani@eng.ikiu.ac.ir](mailto:ramezani@eng.ikiu.ac.ir)

Received: 26 December 2025, Accepted: 05 May 2026

## ABSTRACT

Understanding future trends in climate change and assessing the performance of climate models in predicting temperature and precipitation are essential steps in water resources planning and management. In this study, precipitation, minimum and maximum temperatures, and evapotranspiration were simulated for the Qazvin synoptic station. Monthly data on minimum temperature (°C), maximum temperature (°C), evapotranspiration (mm), and precipitation (mm) from the CanESM5, GFDL-ESM4, and HadGEM3 climate models were compared with the observed data from the Qazvin station for the baseline period 1986–2014, both individually and in combination. The results indicate that ensemble simulations using the random forest method, based on the three general circulation models, reduced simulation errors and consequently increased prediction accuracy. For instance, in the minimum temperature simulation, individual models showed RMSE values of approximately 2.4–2.6 °C, while the combined model achieved RMSE values of 1.0 °C and 1.83 °C for the training and test datasets, respectively. The Spearman correlation coefficients were high for both cases (0.85–0.97). The trends in climate variables were analyzed using the Kendall test and the slope estimation method. The findings reveal that under future climate scenarios SSP5-8.5 and SSP2-4.5, precipitation will exhibit a significant decreasing trend, while both minimum and maximum temperatures as well as evapotranspiration will show significant increasing trends. Overall, the results suggest that the study area is likely to experience warmer conditions and reduced annual precipitation in the coming decades due to climate change — emphasizing the urgent need for adaptive planning in the water and agricultural sectors.

**Keywords:** precipitation, evapotranspiration, temperature, machine learning.

## HOW TO CITE THIS ARTICLE

Ramezani Etedali, H. and Ahmadi, M. (2026). Improving the simulation of climate variables by combining atmospheric general circulation models and the random forest algorithm. *Journal of Meteorology and Atmospheric Science.*, 8(1): 91- 108. Doi: 10.22034/jmas.2026.568747.1260

## COPYRIGHTS

Copyright for this article is retained by the author(s), with publication rights granted to the JMAS Journal. This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

