

مقایسه روش اصلاح نداشت چندی و مدل جنگل تصادفی در ریزمقیاس نمایی دمای کمینه در منطقه بیرجند

الهام قوچانیان حقوردی^{۱*}، مهدی امیرآبادی زاده^۲، امید خراشادیزاده^۳

۱- دانشجوی دکتری منابع آب، گروه علوم و مهندسی آب، پردیس کشاورزی، دانشگاه بیرجند، خراسان جنوبی.

۲- دانشیار گروه علوم و مهندسی آب، پردیس کشاورزی، دانشگاه بیرجند، خراسان جنوبی.

۳- کارشناس ارشد مهندسی منابع آب، شرکت آب منطقه‌ای خراسان جنوبی، شرکت مدیریت منابع آب، بیرجند، خراسان جنوبی.

چکیده

پیش‌بینی دقیق دمای حداقل در مناطق با توپوگرافی پیچیده اهمیت بالایی دارد، زیرا این متغیر ارتباط مستقیمی با وقوع دوره‌های یخبندان دارد. مدل‌های گردش عمومی جو، به دلیل تفکیک مکانی درشت و وجود خطاهای سیستماتیک، قادر به بازنمایی دقیق فرآیندهای اقلیمی منطقه‌ای نیستند و نیازمند روش‌های اصلاح بایاس و ریزمقیاس نمایی می‌باشند. در این پژوهش، عملکرد دو رویکرد آماری نگاشت چارکی (BCSD) با تابع انتقال expasympt و الگوریتم یادگیری ماشین جنگل تصادفی در تصحیح بایاس دمای حداقل ماهانه ایستگاه سینوپتیک بیرجند بررسی شد. داده‌های مشاهداتی طی دوره ۱۹۹۱ تا ۲۰۲۰ و خروجی مدل اقلیمی IPSL-CM6A-LR از پروژه CMIP6 تحت سناریوی SSP245 مورد استفاده قرار گرفت. داده‌های ۱۹۹۱-۲۰۱۰ برای واسنجی و ۲۰۱۱-۲۰۲۰ برای اعتبارسنجی مدل‌ها به کار رفت. نتایج نشان داد که الگوریتم جنگل تصادفی با مقادیر آماری $R^2=0.94$ ، $NSE=0.93$ و $KGE=0.91$ دقت بالاتری نسبت به روش نگاشت چارکی ($R^2=0.9$)، $NSE=0.9$ و $KGE=0.9$ دارد. همچنین میزان خطای مدل جنگل تصادفی ($RMSE=1.96\text{ }^{\circ}\text{C}$ و $MAE=1.63\text{ }^{\circ}\text{C}$) کمتر از روش نگاشت چارکی ($RMSE=2.39\text{ }^{\circ}\text{C}$ و $MAE=1.93\text{ }^{\circ}\text{C}$) بود. نمودارهای پراکنش و توزیع تجمعی تجربی نیز نشان دادند که مدل جنگل تصادفی همبستگی نزدیک‌تری با داده‌های مشاهداتی برقرار کرده و به‌ویژه در بازتولید مقادیر میانی و بالایی توزیع دما عملکرد بهتری داشته است. بر این اساس، نتایج این پژوهش نشان می‌دهد که در مقیاس ایستگاه سینوپتیک بیرجند و بر اساس خروجی مدل IPSL-CM6A-LR تحت سناریوی SSP245 الگوریتم جنگل تصادفی عملکرد بهتری نسبت به روش نگاشت چارکی در تصحیح بایاس دمای حداقل دارد. با این حال، تعمیم این نتایج به سایر مناطق، مدل‌ها و سناریوهای اقلیمی مستلزم انجام مطالعات چند ایستگاهی، چندمدلی و چند سناریویی است.

کلید واژه‌ها: تصحیح بایاس، ریزمقیاس نمایی، مدل اقلیمی CMIP6، نگاشت چندی، یادگیری ماشین.

مقدمه

پیش‌بینی‌های دقیق دمای حداقل هوای سطح زمین برای کاربردهای مختلف اهمیت زیادی دارد (Dewekker et al., 2018)، به‌ویژه در مناطق با توپوگرافی پیچیده که ارتفاع و ناهمواری‌های زمین نقش مهمی در تغییرات دما دارند (Conangla et al., 2018). پیش‌بینی دمای حداقل روزانه با تفکیک‌پذیری مکانی بالا برای حفاظت محصولات کشاورزی ضروری است، زیرا این دماها با بروز پدیده یخبندان ارتباط مستقیم دارند و یخبندان می‌تواند خسارات شدیدی به محصولات و بهره‌وری آن‌ها وارد کند (Talsma et al., 2023). با افزایش غلظت گازهای گلخانه‌ای، شرایط اقلیمی زمین تغییر کرده و به نظر می‌رسد این روند در آینده هم ادامه داشته باشد. بنابراین، تحلیل و ارزیابی اثرات احتمالی تغییرات آینده اقلیم برای تدوین سیاست‌های سازگاری و کاهش اثرات آن ضروری است (Saadi et al., 2017). در ایران نیز مطالعات متعددی تغییرات اقلیمی و روند افزایشی دما و کاهش بارش را تأیید کرده‌اند (انصاری و همکاران، ۱۴۰۱؛ جواهریان و همکاران، ۱۳۹۹؛ فروزان مهر و شهیدی، ۱۴۰۱؛ استاد علی عسگری و همکاران، ۱۳۹۹). با توجه به اهمیت تحلیل رویدادهای حدی دما در ایران، چندین پژوهش داخلی به بررسی تغییرات و روند این شاخص‌ها پرداخته‌اند. به‌عنوان مثال، یک مطالعه اخیر بر اساس خروجی مدل‌های CMIP6 نشان داد که شاخص‌های حدی دمای مانند بیشینه دمای روزانه (TXx) و شب‌های گرم (TN90p) در منطقه شمال شرق ایران تحت سناریوهای تغییر اقلیم افزایش معنی‌دار خواهند داشت و شاخص‌های سرد نظیر شب‌های سرد (TN10p) کاهش می‌یابند، که می‌تواند بر نیاز آبی محصولات کشاورزی و تولیدات منطقه تأثیر بگذارد (Chamanehfar et al., 2024). علاوه بر این، تحلیل دیگری در استان خراسان جنوبی با بهره‌گیری از داده‌های روزانه دما و شاخص‌های حدی تعریف‌شده توسط گروه ETCCDI نشان داده است که نمایه‌های حدی سرد مانند CSDI و TXn در بسیاری از ایستگاه‌ها در حال افزایش هستند و شاخص‌های مرتبط با سرما کاهش می‌یابند، نتایجی که تأییدکننده تغییرات اقلیمی در بخش‌هایی از شرق کشور است (عابدینی و همکاران، ۱۴۰۰). همچنین، افزایش دمای ۰.۸ درجه سانتی‌گراد طی ۱۰۰ سال گذشته و پیش‌بینی افزایش تا ۳ درجه تا سال ۲۱۰۰ گزارش شده است (زارعیان، ۱۴۰۰). برای ارزیابی اثر تغییر اقلیم در

آینده، ابتدا باید متغیرهای اقلیمی تحت تأثیر تغییرات غلظت گازهای گلخانه‌ای شبیه‌سازی شوند. پروژه CMIP6 پیش‌بینی‌های تغییر اقلیم را تحت سناریوهای جدید برای کشورهای مختلف از جمله ایران ارائه می‌دهد (Fan et al., 2022). خروجی این مدل‌های اقلیمی جهانی، به دلیل تفکیک مکانی درشت و وجود سوگیری‌های سیستماتیک مانع از ریزمقیاس دقیق فرآیندهای اقلیمی منطقه‌ای می‌شود (Yang et al., 2019). از این رو، اصلاح سوگیری‌های مدل گامی ضروری در فرآیند پیش‌بینی‌های اقلیمی است (Beyer et al., 2020). روش‌های متعددی برای ریزمقیاس نمایی توسعه یافته‌اند تا خطاهای سیستماتیک مدل‌ها و تأثیرات آن‌ها بر فرآیندهای هیدرولوژیکی به حداقل برسد (Eekhout & de Vente, 2019). تفاوت دقت روش‌های ریزمقیاس نمایی می‌تواند باعث اختلاف در نتایج شبیه‌سازی گردد، که این امر موجبات بررسی دقت روش‌های ریزمقیاس نمایی را فراهم می‌کند. روش‌های ریزمقیاس نمایی به‌طور کلی به دو روش ریزمقیاس نمایی دینامیکی و آماری تقسیم می‌شوند. روش‌های ریزمقیاس نمایی دینامیکی به داده‌های زیاد و تخصص بالا نیاز دارند اما روش‌های ریزمقیاس نمایی آماری با شناسایی ارتباط آماری بین پیش‌بینی‌کننده‌ها و متغیرها، امکان پیش‌بینی ریزمقیاس از متغیر هدف را فراهم می‌کنند. از مزایای روش‌های آماری کاهش محاسبات و سهولت استفاده است. بعضی از روش‌های آماری همچنین به‌عنوان روش‌های پس پردازش برای بهبود کیفیت داده‌ها به کار می‌روند. یکی از پرکاربردترین روش‌ها، نگاشت چارکی است که باهدف حذف سوگیری‌های وابسته به چارک‌ها استفاده می‌شود. در این روش، تابع تبدیل احتمالاتی بر اساس تابع توزیع تجربی داده‌ها تعریف می‌شود (Zhu et al., 2022). نگاشت چارکی به دلیل سادگی، قابلیت پیاده‌سازی آسان و عملکرد مناسب در شرایط متنوع اقلیمی، در بسیاری از مطالعات تصحیح سوگیری کاربرد دارد. یکی از نسخه‌های پیشرفته این روش، تابع انتقال PTF است که در پکیج Qmap زبان R پیاده‌سازی شده و ساختارهای آماری پیچیده‌تر داده‌ها را بهتر مدل می‌کند. Crespi و همکاران (۲۰۲۱) از مدل نگاشت چندکی برای اصلاح بایاس داده‌های SEAS5 در اروپا استفاده کردند که به شکل مؤثری این روش دقت پیش‌بینی‌های ماهانه دما و بارش را بهبود بخشید. (امینی و همکاران، ۱۳۹۹) نیز با روش نگاشت چندکی سوگیری داده‌های خام را حذف و عملکرد سیستم‌های

کردند. آن‌ها با داده‌های جوی ایستگاهی یخبندان را ۲۴ ساعت قبل با دقت بالا پیش‌بینی کردند. همچنین، Diedrichs و همکاران (۲۰۱۸) در آرژانتین از ANN، RF و شبکه‌های بیزی برای پیش‌بینی یخبندان با داده‌های ایستگاهی استفاده کردند. در این مطالعه حسگرهای اینترنت اشیاء (IoT) برای جمع‌آوری داده‌های جوی بلادرنگ به کار رفت. استفاده از مدل‌های یادگیری ماشین به‌ویژه ANN، RF و سایر الگوریتم‌ها در مطالعات هواشناسی و هیدرولوژی برای ارزیابی اثرات تغییر اقلیم بسیار کاربردی است (Pan et al., 2017; Salman et al., 2018) و همکاران (۲۰۲۰) در منطقه شاخ آفریقا ریزمقیاس نمایی داده‌های SEAS5 به‌وضوح ۳ کیلومتر را انجام دادند و نشان دادند که بایاس گرمایی بر پیش‌بینی دما پس از ریزمقیاس نمایی اثرگذار است. بررسی مطالعات پیشین نشان می‌دهد که روش‌های ریزمقیاس نمایی آماری به‌طور گسترده‌ای برای ارزیابی اثرات تغییر اقلیم در ایران به کار گرفته شده‌اند. به‌عنوان نمونه، کوزه‌گران و همکاران (۱۴۰۳) با استفاده از روش ریزمقیاس نمایی آماری تصحیح بایاس و تفکیک مکانی (BCSD)، به بررسی تغییرات شاخص‌های حدی دمایی در شمال شرق ایران تحت سناریوهای تغییر اقلیم پرداختند و نشان دادند که این روش توانایی مناسبی در باز تولید روندها و الگوهای دمایی در مقیاس منطقه‌ای دارد. با این حال، روش ریزمقیاس نمایی اقلیمی نگاشت چارکی ذاتاً مبتنی بر تطبیق توزیع‌های آماری و فرض ایستایی روابط آماری بین دوره‌های تاریخی و آینده است و ممکن است در شرایط تغییر اقلیم با محدودیت‌هایی در بازنمایی روابط غیرخطی و غیرایستا مواجه شود. بر اساس بررسی جامع منابع علمی موجود، تاکنون هیچ پژوهشی در محدوده جغرافیایی ایران به مقایسه مستقیم روش ریزمقیاس نمایی آماری با الگوریتم یادگیری ماشین جنگل تصادفی (RF) در زمینه تصحیح سوگیری مدل‌ها و پیش‌بینی دمای کمینه ماهانه مبتنی بر خروجی مدل‌های اقلیمی CMIP6 تحت سناریوهای مسیرهای مشترک اجتماعی-اقتصادی (SSP) نپرداخته است. این خلأ پژوهشی، ضرورت انجام مطالعات تطبیقی میان روش‌های کلاسیک آماری و الگوریتم‌های یادگیری ماشین را بیش‌ازپیش برجسته می‌سازد. از این رو، پژوهش حاضر با بهره‌گیری از داده‌های به‌روز مدل‌های CMIP6 و سناریوهای SSP، رویکردی نوآورانه در اصلاح خطای مدل‌های اقلیمی و افزایش دقت پیش‌بینی اقلیم آینده ارائه می‌دهد. نوآوری اصلی

پیش‌بینی بارش جهانی را ارزیابی کردند. نتایج آن‌ها نشان داد که در مناطق مرطوب، نیمه مرطوب، مدیترانه‌ای و خشک مثل جنوب غرب، شمال غرب و شمال شرق ایران، پیش‌بینی بارش با داده‌های مشاهداتی هماهنگی خوبی دارد، اما در مناطق نیمه خشک و خیلی خشک، ضریب همبستگی بین داده‌های پیش‌بینی و مشاهداتی بسیار پایین بود. علاوه بر روش نگاشت چارکی، روش‌های آماری و یادگیری ماشین نیز برای اصلاح بایاس به کار گرفته شده‌اند. یادگیری ماشین به دلیل توانایی مدل‌سازی روابط غیرخطی و استخراج الگوهای پنهان در داده‌ها، به‌عنوان روشی جایگزین مطرح است (Vandal et al., 2017). از جمله روش‌های متداول می‌توان به رگرسیون خطی چندگانه (Ahmed et al., 2015) (MLR)، تحلیل مؤلفه‌های اصلی (Chu et al., 2008) (PCA)، ماشین بردار پشتیبان (Chen et al., 2010) (SVM) و جنگل تصادفی (Shi et al., 2015) (Random Forest – RF) اشاره کرد. مطالعات متعددی استفاده از مدل‌های ANN، RF، SVM و XGBoost را برای ریزمقیاس نمایی نقطه‌ای دما تأیید کرده‌اند (Duhan & Pandey., 2015, Nourani et al., 2019). نتایج مطالعات مقایسه‌ای نشان می‌دهد که هیچ مدل واحدی در همه مناطق عملکرد بهتر و پایدارتری ندارد، بنابراین مقایسه و انتخاب مدل متناسب با منطقه مطالعه اهمیت دارد. برای مثال، Pang و همکاران (۲۰۱۷) در حوزه آبریز رودخانه پرل در چین دریافتند که RF عملکرد بهتری نسبت به ANN و MLR دارد، اما در تحقیقی در فرودگاه ممفیس گزارش کردند که ANN بهتر از مدل‌های دیگر عمل می‌کند. (آذری و همکاران، ۱۴۰۰). جنگل تصادفی یکی از محبوب‌ترین الگوریتم‌های یادگیری ماشین برای مسائل رگرسیون و طبقه‌بندی است. این الگوریتم با استفاده از درخت‌های تصمیم‌گیری متعدد و نمونه‌گیری تصادفی، دقت و پایداری بالایی دارد و در پیش‌بینی متغیرهای اقلیمی مانند دما، بارش و تبخیر موفق عمل کرده است (Reichstein et al., 2019; Li et al., 2019). eccle. et al., 2019) و همکاران (۲۰۰۷) در ایتالیا با استفاده از RF و ANN به‌یوهای نسبت به مدل‌های سنتی گزارش کردند. talesma و همکاران (۲۰۲۳) نیز با به‌کارگیری این مدل‌ها در نیومکزیکو، دقت بالایی در پیش‌بینی دمای کمینه در بازه ۶ تا ۴۸ ساعت گزارش دادند. Barooni و همکاران (۲۰۲۳) در استان فارس ایران، با استفاده از RF، شبکه عصبی پیچشی زمانی و XGBoost رخدادهای یخبندان را پیش‌بینی

Forest در بازه زمانی بین سال‌های ۱۹۹۱ تا ۲۰۲۰ به عنوان دوره پایه استفاده شد. این ایستگاه در موقعیت عرض جغرافیایی ۳۲ درجه و ۵۳ دقیقه شمالی و طول جغرافیایی ۵۹ درجه و ۱۷ دقیقه شرقی قرار دارد. شکل ۱ موقعیت ایستگاه مورد مطالعه و جدول ۱ مشخصات ایستگاه سینوپتیک شهرستان بیرجند را نشان می‌دهد. با توجه به قرارگیری شهرستان بیرجند در اقلیم نیمه خشک و ارتفاع نسبتاً بالا، این منطقه دارای نوسانات شدید دمای بوده و به ویژه در فصول سرد سال مستعد وقوع یخبندان است. در چنین شرایطی، دمای کمینه نقش مهمی در بروز تنش سرما و خسارت به محصولات کشاورزی، به ویژه باغات و محصولات حساس دارد. از این رو، حتی تغییرات اندک در دمای حداقل می‌تواند پیامدهای قابل توجهی بر زمان، شدت و فراوانی یخبندان‌ها داشته باشد. بنابراین، بررسی و اصلاح سوگیری دمای کمینه در این منطقه از نظر آسیب‌پذیری اقلیمی و مدیریت ریسک کشاورزی اهمیت ویژه‌ای دارد.

داده‌ها

در این پژوهش، به منظور بررسی و مقایسه عملکرد دو روش تصحیح بایاس شامل نگاشت چارکی و جنگل تصادفی، داده‌های دمای کمینه ماهانه از ایستگاه سینوپتیک بیرجند اخذ گردید. داده‌های مورد استفاده شامل:

- ۱- داده‌های مشاهده شده از ایستگاه‌های هواشناسی در سال‌های (۱۹۹۱-۲۰۲۰)
- ۲- داده‌های شبیه‌سازی شده مدل‌های جهانی اقلیمی (GCMs) از نسل ششم CMIP6، برای دوره‌ی تاریخی (۱۹۹۱-۲۰۲۰) و آینده (۲۰۳۰-۲۰۵۹) گرفته شد.

این مطالعه در ارزیابی و مقایسه عملکرد یک روش آماری مبتنی بر توزیع (BCSD) با یک الگوریتم یادگیری ماشین توانمند در مدل‌سازی روابط غیرخطی و چندبعدی (Random Forest) برای بازتولید و پیش‌بینی دمای کمینه ماهانه نهفته است.

با توجه به اهمیت بالای پیش‌بینی دمای کمینه در برنامه‌ریزی‌های زیست‌محیطی، کشاورزی و مدیریت منابع آب، اهداف اصلی این پژوهش به شرح زیر تعریف می‌شود:


- ۱- ریزمقیاس نمایی دمای کمینه ماهانه با استفاده از روش نگاشت چندکی (BCSD) و الگوریتم جنگل تصادفی
- ۲- مقایسه عملکرد این دو روش با بهره‌گیری از شاخص‌های آماری RMSE، MAE، ضریب تعیین (R)، شاخص کارایی نش-ساتکلیف (NSE) و شاخص کارایی کلینگ-گوپتا (KGE)

هدف نهایی این پژوهش، ارزیابی دقت و قابلیت دو رویکرد مذکور در بازتولید داده‌های مشاهده‌ای و پیش‌بینی شرایط اقلیمی آینده در منطقه بیرجند است، به گونه‌ای که نتایج آن بتواند مبنایی علمی برای انتخاب روش‌های مناسب ریزمقیاس نمایی در مطالعات اقلیم‌محور آینده در ایران فراهم آورد.

مواد و روش‌ها

منطقه مورد مطالعه

شهرستان بیرجند یکی از شهرستان‌های استان خراسان جنوبی است که دارای آب‌وهوای خشک و نیمه‌خشک و متوسط دمای سالیانه ۱۶ درجه سانتی گراد با متوسط بارش سالیانه ۱۷۱ میلی‌متر است (یعقوب زاده و همکاران، ۱۳۹۸). در این پژوهش از اطلاعات دمای کمینه ماهانه ایستگاه سینوپتیک بیرجند به منظور مقایسه اصلاح چارکی به دو روش BCSD و Random



شکل ۱- موقعیت منطقه مورد مطالعه

جدول ۱- مشخصات ایستگاه هواشناسی سینوپتیک بیرجند

نوع ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع	Y(utm)	X(utm)
ایستگاه سینوپتیک بیرجند	59-12-00	32-52-00	1463	3638651	705844

پیش‌پردازش داده‌ها

پیش از انجام تصحیح بایاس و مدل‌سازی، چندین مرحله پیش‌پردازش بر روی داده‌ها اعمال شد. در گام نخست، داده‌های گمشده شناسایی و اصلاح گردید تا از کیفیت داده‌ها اطمینان حاصل شود. سپس به منظور کاهش اثر مقادیر پرت، از روش دامنه چارکی استفاده شد، به این صورت که چارک اول و چارک سوم محاسبه و مقادیری که خارج از بازه قرار داشتند حذف شدند. این فرایند برای سری‌های دمای مشاهده‌ای و شبیه‌سازی شده اعمال گردید. به منظور حفظ انسجام زمانی، داده‌ها به دو دوره‌ی واسنجی (۱۹۹۱-۲۰۱۰) و اعتبارسنجی (۲۰۱۱-۲۰۲۰) تقسیم شدند. در مدل جنگل تصادفی، متغیرهای پیش‌بین شامل دمای هوای نزدیک سطح (tas)، بارش (pr)، تابش موج‌بلند (rlds)، فشار سطح دریا (psl)، رطوبت نسبی (hur)، مؤلفه‌های باد شمالی-جنوبی و شرقی-غربی (vas, uas) و ارتفاع ژئوپتانسیل (zg) به‌عنوان ورودی استفاده شد و دمای کمینه به‌عنوان متغیر هدف در نظر گرفته شد. در روش BCSD، مقادیر مشاهده‌ای و تاریخی دمای کمینه برای برازش تابع نگاشت چارکی مورد استفاده قرار گرفت و در ادامه، سری‌های تاریخی و آینده شبیه‌سازی شده دمای کمینه تصحیح بایاس شدند.

مدل‌های تغییر اقلیم جهانی

در این مطالعه مدل IPSL-CM6A-LR از مجموعه مدل‌های پیش‌بینی CMIP6 به منظور شبیه‌سازی دمای کمینه انتخاب شد. این مدل به دلیل عملکرد مناسب در بازتولید الگوهای دمایی، پوشش کامل سناریوهای آینده و دسترسی به داده‌های منسجم و باکیفیت از پایگاه ESGF، گزینه‌ای مناسب برای تحلیل دمای کمینه محسوب می‌شود. همچنین، به منظور تمرکز بر ارزیابی و مقایسه روش‌های ریزمقیاس‌نمایی و تصحیح بایاس و جلوگیری از تأثیر عدم قطعیت بین مدلی، تنها یک مدل اقلیمی در این پژوهش مورد استفاده قرار گرفت. این رویکرد امکان تحلیل دقیق‌تر عملکرد روش‌های به کار رفته را فراهم می‌کند. داده‌ها از مسیر (<https://esgf-> ESGF

node.llnl.gov/search/cmip6 دانلود شد. در این مدل

داده‌های دمای کمینه به‌صورت پیوسته برای هر دو بازه زمانی شامل دوره‌ی شبیه‌سازی تاریخی (۱۹۹۱ تا ۲۰۲۰) و سناریوهای آینده (۲۰۳۰ تا ۲۰۵۹) وجود دارد. به همین دلیل فرایند اصلاح بایاس و مقایسه‌ی دقیق بین دوره‌های گذشته و آینده انجام شد. از آنجا که مدل‌های GCM نتایج را در مقیاس جهانی و با تفکیک مکانی نسبتاً درشت تولید می‌کنند، معمولاً مقادیر متغیرهای اقلیمی در مقیاس‌های منطقه‌ای و جهانی بیش‌برآورد یا کم‌برآورد می‌شوند و قادر به نمایش نوسانات اقلیمی در مقیاس‌های محلی و جزئی نیستند (احمدی پور و همکاران، ۲۰۱۷). در این پژوهش تنها از سناریوی SSP2-4.5 استفاده شد که یکی از سناریوهای میانی انتشار گازهای گلخانه‌ای ارائه‌شده توسط هیئت بین دولتی تغییرات اقلیم (IPCC) است. انتخاب این سناریو به دلیل ماهیت واقع‌بینانه و میانه آن، که شرایط توسعه اجتماعی-اقتصادی و سیاست‌های اقلیمی محتمل در آینده را بازتاب می‌دهد، انجام شد. همچنین، به منظور تمرکز بر ارزیابی عملکرد روش‌های اصلاح بایاس و جلوگیری از افزایش پیچیدگی و عدم قطعیت ناشی از مقایسه چند سناریوی مختلف، تنها یک سناریو به‌عنوان سناریوی نماینده در این مطالعه در نظر گرفته شد.

روش آماری BCSD

روش BCSD در مرحله تصحیح سوگیری از تکنیک آماری مانند Quantile Mapping استفاده می‌کند که هدف آن هم‌راستا ساختن توزیع آماری داده‌های شبیه‌سازی شده با داده‌های مشاهده شده است. روش نگاشت چارکی شامل ایجاد یک تابع انتقال برای تغییر توزیع وقوع بارش و دما است. این روش با چند نام مختلف از جمله "نگاشت احتمال"، "نگاشت چندکی"، "کاهش مقیاس آماری" شناخته می‌شود. برای بارش، این روش برحسب تابع توزیع تجمعی گاما و معکوس آن و برای دما برحسب تابع توزیع تجمعی گاوسی و معکوس آن انجام می‌شود. اگر F و G به ترتیب

توابع توزیع تجمعی (CDF) خروجی مدل و مشاهدات باشند و x مقداری از خروجی مدل باشد. هدف از نگاشت، کمیت یافتن تابع انتقال $t(x)$ است که:

$$G(t(x)) = F(x) \quad (۱)$$

به عبارت دیگر، تابع انتقال، چندک های CDF مدل را به کمیت های متناظر CDF مشاهده شده، نگاشت می کند، به طوری که دو CDF مطابقت داشته باشند. جهت اطلاع بیشتر از جزئیات روش های مذکور می توان به مقاله (Maraun., 2016) مراجعه نمود. برای تصحیح سوگیری داده های اقلیمی، ابتدا روش آماری اصلاح چارکی (Quantile Mapping) با استفاده از تابع انتقال پارامتری (PTF) و تابع تبدیل (expasymp) به کار گرفته شد. این روش با استفاده از پکیج Qmap در محیط R انجام شد. در این روش داده های ایستگاه زمینی به عنوان داده های مشاهداتی و داده های تاریخی مدل اقلیمی به عنوان ورودی به مدل در نظر گرفته شد. برای بررسی دقت مدل از شاخص های آماری شامل: جذر میانگین مربعات خطا، میانگین قدر مطلق خطا، ضریب نش ساتکلیف، معیار تطابق کلی، ضریب تعیین استفاده شد. مدل آموزش یافته سپس برای تصحیح بایاس داده های آینده به کار رفت و در نهایت، توابع توزیع تجمعی تجربی (ECDF) برای داده های مشاهداتی، تاریخی، تصحیح شده و آینده رسم شد تا تطابق توزیعی بررسی گردد.

روش جنگل تصادفی

مدل جنگل تصادفی یکی از روش های یادگیری ماشین است که از درخت های رگرسیون برای ایجاد تصادفی بودن در جنگل های تصمیم گیری استفاده می کند (Breiman, 2001). این درخت ها با زیرمجموعه ای از متغیرها که به صورت تصادفی از داده های آموزشی انتخاب شده اند ساخته می شوند (Noor et al., 2020; Pang et al., 2017). اطلاعات به دست آمده از هر درخت میانگین گیری شده و برای برآورد استفاده می شود. به این ترتیب، مشکلاتی مانند بیش برازش کاهش می یابد. مدل جنگل تصادفی به دلیل عملکرد خوب، نیاز به پارامترهای کم و هزینه محاسباتی پایین، به طور گسترده ای مورد استفاده قرار گرفته است. اصول عملکرد این الگوریتم به شرح زیر است (Noor et al., 2020). ابتدا،

مجموعه ای از نمونه های تصادفی از داده های مشاهده شده با استفاده از روش نمونه گیری بوت استرپ ایجاد می شود. داده هایی که در هر نمونه بوت استرپ حضور ندارند، به عنوان داده های خارج از نمونه (OOB) در نظر گرفته می شوند. سپس برای هر نمونه تصادفی، یک درخت رگرسیونی بدون هرس با استفاده از الگوریتم درخت های طبقه بندی و رگرسیون (CART) توسعه داده می شود. در این الگوریتم، در هر گره تنها یک زیرمجموعه تصادفی از متغیرهای ورودی در نظر گرفته شده و بهترین متغیر برای انجام عمل جداسازی انتخاب می شود. برآورد مقادیر برای داده های جدید از طریق میانگین گیری از خروجی تمام درخت های ایجاد شده انجام می گیرد. همین فرآیند برای داده های خارج از نمونه (OOB) نیز تکرار می شود تا عملکرد مدل ارزیابی گردد. در نهایت، پس از هر تکرار، مقدار خطا محاسبه شده و مدلی که کمترین مقدار خطای پیش بینی را داشته باشد، به عنوان بهترین مدل جنگل تصادفی انتخاب می شود.

در این مطالعه، از بسته (https://cran.r-project.org/package=randomForest) نویسی R برای پیش بینی و تصحیح بایاس دمای کمینه استفاده شد. داده ها به دو بخش آموزش (۱۹۹۱-۲۰۱۱) و اعتبار سنجی (۲۰۱۱-۲۰۲۰) تقسیم شدند. مدل با ۵۰۰ درخت تصمیم گیری آموزش داده شد. در این مدل داده های دمای کمینه به عنوان تابع هدف و میانگین دما، بارش، تابش موج بلند به سطح زمین، فشار سطح دریا، رطوبت نسبی، باد و ارتفاع ژئو پتانسیل متغیرهای وابسته هستند.

جهت بررسی عملکرد از پارامترهای ارزیابی عملکرد شامل جذر میانگین مربعات خطا، میانگین قدر مطلق خطا، ضریب نش ساتکلیف، معیار تطابق کلی، ضریب تعیین استفاده شد و توابع توزیعی تجربی برای داده های مشاهده شده، داده های مدل (بدون تصحیح)، پیش بینی شده در دوره اعتبارسنجی، و پیش بینی های آینده رسم گردید.

به منظور تنظیم بهینه پارامترهای مدل جنگل تصادفی، آزمون حساسیت اولیه روی تعداد درخت ها (ntree) و تعداد متغیرهای انتخابی در هر گره (mtry) انجام شد. نتایج نشان داد با افزایش تعداد درخت ها بیش از ۳۰۰، مقدار خطای پیش بینی تغییر محسوسی نداشته و مدل به حالت پایدار می رسد.

$$NS = 1 - \frac{\sum(Y_a - X_a)^2}{\sum(X_a - \bar{X})^2} \quad (۴)$$

مقدار ایده آل این معیار برابر یک است که نشان‌دهنده برابر بودن مقادیر مشاهداتی و شبیه‌سازی شده می‌باشد.

معیار KGE: یکی از جدیدترین معیارهای ارزیابی می‌باشد که توسط (Gupta et al., 2009) ارائه گردیده و در حقیقت تغییر یافته معیار نش-ساتکلیف است. CC ضریب همبستگی خطی بین مقادیر مشاهداتی و شبیه‌سازی شده، نسبت انحراف معیار داده‌های شبیه‌سازی شده بر انحراف معیار داده‌های مشاهداتی و میانگین داده‌های شبیه‌سازی شده به میانگین داده‌های مشاهداتی می‌باشد. مقدار ایده‌آل این معیار برابر یک می‌باشد و هر چه از یک فاصله بگیرد نشان‌دهنده عملکرد پایین مدل می‌باشد.

$$KGE = 1 - \sqrt{(CC - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (۵)$$

ضریب تعیین R²: ضریب تعیین (R²) معیاری برای ارزیابی دقت مدل‌های رگرسیونی است و نشان می‌دهد که چه نسبتی از تغییرات متغیر وابسته توسط مدل قابل پیش‌بینی است. این ضریب از تقسیم مجموع مربعات قابل تبیین توسط مدل به مجموع مربعات کل به دست می‌آید.

$$R^2 = \frac{\sum(\hat{Y}_t - \bar{Y})^2}{\sum(Y_t - \bar{Y})^2} \quad (۶)$$

نتایج

مدل نگاشت چارکی

عملکرد روش آماری نگاشت چارکی بر روی داده‌های دمای کمینه نشان داد که مدل قادر است مقادیر دما را در بازه کلی با دقت مناسبی بازتولید کند. شاخص‌های ارزیابی شامل (RMSE=2.39°C, MAE=1.93°C, R²=0.9, NSE=0.9, KGE=0.9) نشان‌دهنده همبستگی قوی بین داده‌های پیش‌بینی شده و داده‌های مشاهداتی در دوره اعتبارسنجی است. نمودار پراکندگی نقاط حول خط ۱:۱ و منحنی توزیع تجمعی تجربی (ECDF) نیز انطباق مناسبی را نشان می‌دهد و بیانگر کاهش بایاس سیستماتیک در داده‌های اصلاح شده است. مقادیر پارامترهای ارزیابی عملکرد مدل به شرح جدول (۲) است.

بر این اساس، مقدار ntree برابر با ۵۰۰ انتخاب شد تا ضمن تضمین پایداری نتایج، از نوسانات تصادفی مدل نیز کاسته شود. تعداد متغیرهای انتخابی در هر گره نیز بر اساس مقدار پیش‌فرض پیشنهاد شده در بسته Random Forest برای مسائل رگرسیونی، یعنی برابر با یک سوم تعداد کل متغیرهای ورودی، انتخاب گردید. از آنجا که تعداد متغیرهای پیش‌بین در این مطالعه برابر با ۷ متغیر بوده است، مقدار mtry برابر با ۲ در نظر گرفته شد که بهترین عملکرد را از نظر حداقل سازی خطای OOB نشان داد.

معیارهای ارزیابی

در این پژوهش، به منظور ارزیابی عملکرد مدل‌های نگاشت چارکی و جنگل تصادفی از معیارهای ریشه میانگین مربع خطا، میانگین خطای مطلق، نش-ساتکلیف، ضریب گوپا و ضریب تعیین استفاده شد که در پژوهش‌های اقلیمی مختلف جهت سنجش دقت مدل‌های اقلیمی استفاده شده‌اند (Nouri et al., 2021; Amini et al., 2020). فرمول و روابط معیارهای مورد استفاده در ذیل آورده شده است.

معیار RMSE: مقدار ایده‌آل این معیار برابر صفر می‌باشد و بیانگر این است که مقادیر مشاهداتی و شبیه‌سازی شده هیچ اختلافی ندارند. N تعداد کل داده‌ها، X_a مقدار مشاهداتی و Y_a مقدار شبیه‌سازی شده است. (Chai and Draxler., 2014)

$$RMSE = \sqrt{\frac{1}{N} \sum_a^N (X_a - Y_a)^2} \quad (۲)$$

معیار MAE: این معیار میزان اختلاف میان مقادیر پیش‌بینی شده و مقادیر واقعی را بدون توجه به جهت خطا (مثبت یا منفی) نشان می‌دهد. مقدار ایده‌آل این معیار برابر صفر است و به معنای پیش‌بینی کاملاً دقیق است.

$$MAE = \frac{1}{N} \sum_a^N |X_a - Y_a| \quad (۳)$$

معیار NS: ضریب نش-ساتکلیف یکی از رایج‌ترین معیارهای ارزیابی است و نسبت واریانس باقی‌مانده را به واریانس مقادیر مشاهداتی نشان می‌دهد (Nash and Sutcliffe, 1970).


جدول ۲- نتایج واسنجی مدل نگاشت چارکی در شبیه‌سازی پارامتر دمای حداقل در منطقه بیرجند

مقدار	معیار ارزیابی
2.39°C	RMSE
1.93°C	MAE
0.9	R ²
0.9	NSE
0.9	KGE


مشاهده‌شده (نمودار به رنگ آبی)، داده‌های تاریخی گرفته‌شده از مدل‌های اقلیمی جهانی (نمودار به رنگ قرمز)، داده‌های تصحیح‌شده (نمودار به رنگ سبز) و پیش‌بینی مدل برای آینده (نمودار به رنگ نارنجی) در محیط R رسم شد. منحنی توزیع تجمعی تجربی مربوط به داده‌های تصحیح‌شده، انطباقی بسیار خوبی با داده‌های مشاهداتی دارد. این همپوشانی نشان‌دهنده عملکرد بالای مدل اصلاح چارکی با تابع انتقال (expasympt) در تصحیح بایاس موجود در داده‌های خام مدل اقلیمی است. اختلاف بین منحنی مدل خام و داده‌های مشاهده‌ای، نشان‌دهنده انحراف قابل‌توجهی در داده‌های اولیه مدل است که بدون تصحیح می‌تواند منجر به خطاهای تحلیلی شود.

مقایسه منحنی دمای حداقل در آینده با داده‌های تاریخی نشان‌دهنده جابجایی توزیع دمای کمینه به سمت مقادیر بالاتر در خروجی مدل است که بیانگر روند افزایشی دمای کمینه در شبیه‌سازی انجام‌شده می‌باشد. با این حال، لازم به ذکر است که این نتیجه صرفاً مبتنی بر خروجی مدل اقلیمی تصحیح‌شده بوده و بدون تحلیل عدم قطعیت‌های مرتبط با مدل و سناریوی انتشار، نمی‌توان آن را به‌عنوان شاهد قطعی تغییر اقلیم تعبیر کرد.

شکل ۲ نمودار پراکنش بین مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده دمای کمینه را توسط روش اصلاح چارکی نشان می‌دهد. همان‌طور که در شکل مشاهده می‌شود مدل اصلاح چارکی توانسته مقدار دمای کمینه را با دقت مناسبی بازسازی کند و نزدیکی نقاط به خط برازش یافته نشان‌دهنده خطای سیستماتیک (BIAS) بسیار کم بین داده‌های مدل و داده‌های مشاهداتی است. همان‌طور که مشاهده می‌شود داده‌ها به‌طور یکنواخت در اطراف خط توزیع‌شده‌اند که نشان می‌دهد مدل در کل بازه دمایی عملکرد یکنواختی داشته و دچار بیش برازش یا کم برازش نشده است. با این حال، بررسی دقیق نتایج نشان داد که مدل نگاشت چارکی قادر به بازتولید مقادیر دمای کمتر از صفر نیست و همه این مقادیر به صفر تبدیل شده‌اند. این محدودیت ناشی از نحوه برازش تابع انتقال (expasympt) به داده‌های تاریخی است و می‌تواند منجر به دست‌کم‌گیری رخداد‌های دمایی بسیار پایین در دوره آینده شود. بررسی داده‌های تاریخی نشان داد که تعداد داده‌های زیر صفر بسیار کم است، بنابراین اثر این محدودیت بر تحلیل کلی تغییرات دمای کمینه محدود است، اما در تفسیر نتایج آینده باید در نظر گرفته شود. همچنین به‌منظور ارزیابی عملکرد روش نگاشت چارکی، نمودار تابع تجمعی تجربی برای چهار دسته داده شامل مقادیر



شکل ۲- نمودار پراکنش دمای حداقل مشاهده‌شده در برابر مقادیر پیش‌بینی‌شده به همراه خط رگرسیون خطی



شکل ۳- نمودار توزیع تجمعی تجربی (ECDF) دمای حداقل برای داده‌های مشاهده‌شده، تاریخی، اعتبارسنجی و آینده

نشان می‌دهد مدل جنگل تصادفی در جنبه‌های مختلف از لحاظ همبستگی و پراکندگی مناسب است زیرا معیار کلینگ-گوپتا ترکیبی از ضریب همبستگی و واریانس است. در نمودار مربوط به پراکنش، پراکندگی داده‌ها در اطراف خط برازش نشان دهنده تطابق کامل داده‌های پیش‌بینی‌شده و مقادیر واقعی است و به‌طور کلی این نمودار نشان می‌دهد جنگل تصادفی در پیش‌بینی دمای کمینه دقت بالایی دارد و به‌خوبی توانسته نتایج قابل قبولی ارائه دهد. این روش برخلاف روش قبل قادر به بازتولید دماهای کمتر از صفر می‌باشد.


در تحلیل نمودار توزیع تجمعی تجربی داده‌های کمینه توسط روش جنگل تصادفی، همپوشانی نزدیک بین منحنی مشاهداتی و اعتبارسنجی بیانگر موفقیت مدل در بازتولید توزیع دمای کمینه تاریخی است. منحنی دمای حداقل در آینده در خروجی مدل جنگل تصادفی بیانگر افزایش مقادیر دمای کمینه نسبت به دوره تاریخی در چارچوب شبیه‌سازی انجام شده است. با این حال، این نتیجه صرفاً مبتنی بر خروجی یک مدل بوده و بدون بررسی عدم قطعیت و استفاده از چند مدل و سناریو، قابل تعمیم به‌عنوان شاهد قطعی تغییر اقلیم نیست.

در مدل جنگل تصادفی با استفاده از ۵۰۰ درخت تصمیم‌گیری بر روی داده‌های اقلیمی دوره پایه (۱۹۹۱-۲۰۱۰) آموزش داده شد و سپس داده‌های سال‌های ۲۰۱۱ تا سپتامبر ۲۰۲۰ به عنوان دوره اعتبارسنجی مورد بررسی قرار گرفت. نتایج حاصل از مدل با استفاده از معیارهای ارزیابی و نمودار پراکنش و نمودار تابع تجمعی تجربی مورد ارزیابی قرار گرفت که نتایج به تفصیل بیان می‌گردد.


جدول ۳- نتایج واسنجی مدل جنگل تصادفی در شبیه‌سازی پارامتر دمای حداقل

مقدار	معیار ارزیابی
1.96°C	RMSE
1.63°C	MAE
0.94	R2
0.93	NSE
0.91	KGE

مقدار بالای ضریب تعیین ($R^2=0.94$) و ضریب نش-ساتکلیف ($NSE=0.93$) نشان‌دهنده میزان بالای همبستگی بین مقادیر پیش‌بینی‌شده و مشاهداتی است. مقدار نزدیک به ۱ این پارامترها نشان‌دهنده توانایی بالای مدل جنگل تصادفی در بازسازی الگوهای دمای است. مقدار ($RMSE=1.96$) نشان می‌دهد که در بیشتر موارد تفاوت بین مقادیر پیش‌بینی شده و واقعی ناچیز بوده و مدل دقت مناسبی دارد. MAE نیز معیاری برای بیان میزان خطای مدل بدون توجه به جهت خطا (بیش‌برآورد یا کم‌برآورد) است. مقدار پایین آن نشان می‌دهد که پیش‌بینی‌های مدل به‌طور میانگین در محدوده نزدیک به مقادیر واقعی قرار دارند. مقدار ($KGE=0.91$)



شکل ۴- نمودار پراکنش دمای حداقل مشاهده شده در برابر مقادیر پیش‌بینی شده به همراه خط رگرسیون خطی



شکل ۵- نمودار توزیع تجربی (ECDF) دمای حداقل برای داده‌های مشاهده شده، تاریخی، اعتبارسنجی و آینده

بحث

چارکی، توانایی آن در مدل‌سازی روابط غیرخطی و چندبعدی بین متغیرهای اقلیمی است. درحالی‌که روش نگاشت چارکی مبتنی بر تطبیق توزیع آماری داده‌ها بوده و به‌طور ضمنی فرض ایستایی روابط آماری را در دوره‌های تاریخی و آینده در نظر می‌گیرد، مدل جنگل تصادفی بدون نیاز به چنین فرضی، قادر است الگوهای پیچیده و غیرایستا را از داده‌ها استخراج کند. این موضوع به‌ویژه در شرایط تغییر اقلیم که ساختار آماری متغیرها دستخوش تغییر می‌شود، اهمیت بیشتری می‌یابد (Maraun, 2016; Das et al., 2022). بررسی نمودارهای تابع توزیع تجربی نیز نشان داد که خروجی مدل RF تطابق نزدیک‌تری با داده‌های مشاهداتی دارد، به‌ویژه در نواحی انتهایی توزیع که بازنمایی حداقل‌های دمایی از اهمیت بالایی برخوردار است. مطالعات متعددی گزارش کرده‌اند که روش‌های آماری کلاسیک در بازتولید

نتایج این پژوهش نشان داد که مدل جنگل تصادفی در مقایسه با روش آماری نگاشت چارکی، عملکرد به‌مراتب بهتری در بازسازی دمای کمینه طی دوره اعتبارسنجی دارد. برتری مدل جنگل تصادفی از منظر شاخص‌های آماری شامل ضریب تعیین (R^2)، ضریب نش-ساتکیف (NSE) و ضریب کلینگ-گوپتا (KGE) و همچنین کاهش خطاهای RMSE و MAE، بیانگر توان بالای این مدل در شبیه‌سازی رفتار واقعی متغیر دما است. این نتایج با یافته‌های مطالعات پیشین همخوانی دارد که نشان داده‌اند الگوریتم‌های یادگیری ماشین، به‌ویژه جنگل تصادفی، در بازسازی و تصحیح داده‌های اقلیمی عملکرد بهتری نسبت به روش‌های آماری کلاسیک دارند هم‌خوانی دارد (Raeesi et al., 2023). یکی از نکات کلیدی در برتری مدل جنگل تصادفی نسبت به روش نگاشت

گزینه‌ای مناسب‌تر از روش‌های آماری هستند. برای مطالعات آینده، پیشنهاد می‌شود که تمرکز بر رفع محدودیت بازتولید دماهای بسیار پایین و بررسی عملکرد الگوریتم‌های پیشرفته‌تر باشد. به‌طور خاص الگوریتم‌هایی مانند XGBoost و شبکه‌های عصبی می‌توانند روابط غیرخطی پیچیده بین متغیرهای اقلیمی و دمای کمینه را بهتر مدل‌سازی کنند و محدودیت نداشت چارکی در بازتولید دماهای زیر صفر را کاهش دهند.

منابع

1. Abedini, E., Mousavi bayegi, M., Khashei siuki, A., & Selahvarzi, Y. 2022. Investigating the Trend of extreme Temperature Events Based on the Fifth IPCC Report (Case Study: South Khorasan Province). *Journal of Climate Research*, 1400(48), 1-22.
2. Ahmadalipour, A., Rana, A., Moradkhani, H., & Sharma, A. 2017. Multi-criteria evaluation of CMIP5 GCMs for climate change impact analysis. *Theoretical and Applied Climatology*, 128, 71–87. Available from: <https://doi.org/10.1007/s00704-015-1695-4>.
3. Ahmed, K., Shahid, S. & Harun, S. 2015. Statistical downscaling of rainfall in an arid coastal region: a radial basis function neural network approach. *Applied Mechanics and Materials*, 735, 190–194.
4. Amini, S., Azizian, A., & Arasteh, P. D. 2020. Improving the performance of global rainfall forecasting systems in different climate areas of Iran using quantile mapping method. *Iranian Journal of Soil and Water Research*, 51(9):2275-2291. 10.22059/IJSWR.2020.302208.668602.
5. Azari, B., Hasan, K., Pierce, J., & Ebrahimi, S. 2022. Evaluation of machine learning methods application in temperature prediction. *Computational Research Progress in Applied Science and Engineering*, 8(1), 1-12. DOI:10.52547/crpase.8.1.2747.
6. Ansari, S., Dehban, H., Zareian, M., & Farokhnia, A. 2022. Investigation of temperature and precipitation changes in the Iran's basins in the next 20 years based on the output of CMIP6 model. *Iranian Water Researches Journal*, 16(1), 11-24. <https://doi.org/10.22034/iwrj.2022.11204>.
7. Breiman, L. 2001. Random forests. *Machine Learning*, 45, 5–32. Available from: <https://doi.org/10.1023/A:1010933404324>
8. Beyer, R., Krapp, M., & Manica, A. 2020. An empirical evaluation of bias correction methods for palaeoclimate simulations.

مقادیر حدی (extremes) با محدودیت مواجه هستند، در حالی که مدل‌های مبتنی بر یادگیری ماشین توانایی بیشتری در شبیه‌سازی این مقادیر دارند (Salsedo-sanz et al., 2022). در نمودار پراکنش نیز مدل جنگل تصادفی توانست همبستگی قوی‌تری بین داده‌های مشاهداتی و پیش‌بینی‌شده برقرار کند، درحالی‌که روش نگاشت چارکی با پراکندگی و انحراف بیشتری همراه بود. این مسئله نشان می‌دهد که اگرچه روش نگاشت چارکی می‌تواند توزیع کلی داده‌ها را اصلاح کند، اما در بازسازی ساختار همبستگی و دینامیک زمانی داده‌ها محدودیت دارد. درمجموع، نتایج این پژوهش نشان می‌دهد که در مقیاس ایستگاه مورد مطالعه و بر اساس خروجی‌های مدل اقلیمی IPSL-CM6A-LR تحت سناریو SSP2-4.5 مدل جنگل تصادفی در مقایسه با روش نگاشت چارکی عملکرد بهتری در بازسازی دمای کمینه طی دوره اعتبارسنجی دارد. با این حال، با توجه به محدود بودن مطالعه به یک ایستگاه، یک مدل اقلیمی و یک سناریو، نتایج حاضر قابلیت تعمیم منطقه‌ای یا اقلیمی ندارند و تعمیم‌پذیری آن‌ها نیازمند تحلیل چند ایستگاهی، چندمدلی و چند سناریویی در مطالعات آینده است.

نتیجه‌گیری و پیشنهادات

در این پژوهش، دو رویکرد متفاوت شامل نگاشت چارکی (BCSD) و مدل جنگل تصادفی (RF) برای تصحیح بایاس دمای حداقل ماهانه بررسی شد. مقایسه عملکرد این دو روش نشان داد که مدل جنگل تصادفی، به دلیل توانایی در شناسایی روابط غیرخطی میان متغیرهای ورودی و خروجی، عملکرد به‌مراتب بهتری نسبت به روش آماری داشت. درحالی‌که مدل آماری با فرض ایستایی و استفاده از توزیع‌های آماری، تنها قادر به اصلاح توزیع کلی داده‌ها بود. در بازتولید دماهای زیر صفر محدودیت وجود دارد و نگاشت چارکی قادر به بازتولید این مقادیر نیست، درحالی‌که مدل RF عملکرد بهتری در این بازه دارد. مدل جنگل تصادفی توانست هم‌زمان توزیع، مقادیر نقطه‌ای و روندهای زمانی را با دقت بالاتری بازسازی کند. بر اساس این یافته‌ها، می‌توان نتیجه گرفت که روش‌های یادگیری ماشین، به‌ویژه جنگل تصادفی، برای تصحیح بایاس و ریزمقیاس‌نمایی دمای کمینه در شرایط اقلیمی پیچیده،

- mountains. *Atmosphere*, 9(10), 371. <https://doi.org/10.3390/atmos9100371>.
18. Diedrichs, A.L., Bromberg, F., Dujovne, D., Brun-Laguna, K. & Watteyne, T. 2018. Prediction of frost events using Bayesian networks and Random Forest. *IEEE Internet Things J.* 5, 4589–4597. <https://doi.org/10.1109/JIOT.2018.2867333>.
 19. Duhan, D. & Pandey, A. 2015. Statistical downscaling of temperature using three techniques in the Tons River basin in Central India. *Theor. Appl. Climatol.* 121, 605–622. DOI:10.1007/s00704-014-1253-5.
 20. Eccel, E., Ghielmi, L., Granitto, P., Barbiero, R., Grazzini, F. & Cesari, D. 2007. Prediction of minimum temperatures in an alpine region by linear and non-linear post-processing of meteorological models. *Nonlinear Process in Geophysics*, 14, 211–222. <https://doi.org/10.5194/npg-14-211-2007>.
 21. Eekhout, J.P.C. & de Vente, J. 2019. The implications of bias correction methods and climate model ensembles on soil erosion projections under climate change. *Earth Surface Processes and Landforms*, 44, 1137–1147. Available from: <https://doi.org/10.1002/esp.4563>.
 22. Fan, X., Duan, Q., Shen, C., Wu, Y. & Xing, C. 2022. Evaluation of historical CMIP6 model simulations and future projections of temperature over the Pan-Third Pole region. *Environmental Science and Pollution Research*, 29, 26214–26229. Available from: <https://doi.org/10.1007/s11356-021-17474-7>.
 23. Forouzanmehr, M., & Shahidi, A. 2022. Evaluation of downscaling methods for minimum and maximum temperature parameters (Case study: Birjand and Rasht synoptic stations). *Journal of Climatological Research*, 13(49), 7–22. .
 24. Javaherian, MR., Ebeahimi, H. & Amininezhad, B. 2020. Prediction of changes in climatic parameters using CanESM2 model based on Rcp scenarios (case study): Lar dam basin. *Ain Shams Engineering Journal*, 12(1), 445-454. <https://doi.org/10.1016/j.asej.2020.04.012>
 25. Kouzegaran, S., Mousavi Baygi, M., & Babaeian, I. 2024. Temperature extreme indices projection based on RCP scenarios in northeast of Iran. *Journal of Water and Soil*.34(6). <https://doi.org/10.22067/jsw.v34i6.85845>. .
 26. Maraun, D. 2016. Bias correcting climate change simulations-a critical review. *Current Climate Change Reports* 2:211-220. DOI:10.1007/s40641-016-0050-x.
 27. Nash, J.E. & Sutcliffe, J.V. 1970. River flow forecasting through conceptual models' part Climate of the Past, 16, 1493–1508. <https://doi.org/10.5194/cp-16-1493-2020>
 9. Barooni, M., Ziarati, K., & Barooni, A. 2023. Frost Prediction Using Machine Learning Methods in Fars Province. In *Proceedings of the 2023 28th International Computer Conference, Computer Society of Iran (CSICC), Tehran, Iran, 25–26 January 2023*; IEEE: Piscataway, NJ, USA, 2023; pp. 1–6.
 10. Chai, T., & Draxler, R. R. 2014. Root mean square error (RMSE) or mean absolute error (MAE) Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>, 2014.
 11. Chu, J. L., Kang, H., Tam, C. Y., Park, C. K., & Chen, C. T. 2008. Seasonal forecast for local precipitation over northern Taiwan using statistical downscaling. *Journal of Geophysical Research Atmospheres*, 113, D12118. <https://doi.org/10.1029/2007JD009424>.
 12. Chen, S.T., Yu, P.S., & Tang, Y.H. 2010. Statistical downscaling of daily precipitation using support vector machines and multivariate analysis. *Journal of Hydrology*, 385, 13–22. <https://doi.org/10.1016/j.jhydrol.2010.01.021>
 13. Chamanehfar, S., Baygi, MM., Modaresi, F., & Babaeian, I. 2024. Near future variations in temperature extremes in northeastern Iran under CMIP6 projections. *Environ Monit Assess.* 23;196(10):972. doi: 10.1007/s10661-024-13125-9.
 14. Conangla, L., Cuxart, J., Jimenez, M.A., Martinez-Villagrasa, D., Miro, J.R., Tabarelli, D. & Zardi, D. 2018. Cold-air pool evolution in a wide Pyrenean valley. *Journal of Climatology*, 38, 2852–2865. <https://doi.org/10.1002/joc.5467>.
 15. Crespi, A., Petitta, M., Marson, P., Viel, C. & Grigis, L. 2021. Verification and bias adjustment of ECMWF SEAS5 seasonal forecasts over Europe for climate service applications. *Climate*, 9(12), 181. <https://doi.org/10.3390/cli9120181>.
 16. Das, P., Zhang, Z. & Ren, h. 2022. Evaluation of four bias correction methods and random forest model for climate change projection in the Mara River Basin, East Africa. *Journal of Water and Climate Change*.13(4), <https://doi.org/10.2166/wcc.2022.299>
 17. DeWekker, S.F., Kossmann, M., Knievel, J.C., Giovannini, L., Gutmann, E.D. & Zardi, D. 2018. Meteorological applications benefiting from an improved understanding of atmospheric exchange processes over

- Atmospheric Research, 197, 446–460. <https://doi.org/10.1016/j.atmosres.2022.106101>.
37. Salcedo-Sanz, Sancho., Pérez-Aracil, Jorge., Ascenso, Guido. & Del Ser, Javier. 2022. Analysis, Characterization, Prediction and Attribution of Extreme Atmospheric Events with Machine Learning: a Review. Theoretical and Applied Climatology. DOI - 10.48550/arXiv.2207.07580
 38. Shi, W., Schaller, N., MacLeod, D., Palmer, T.N. & Weisheimer, A. 2015. Impact of hindcast length on estimates of seasonal climate predictability. Geophysical Research Letters, 42, 1554–1559. <https://doi.org/10.1002/2014GL062829>
 39. Talsma, C.J., Solander, K.C., Mudunuru, M.K., Crawford, B. & Powell, M.R. (2023). Frost prediction using machine learning and deep neural network models. Front. Artif. Intell. 5, 963781. <https://doi.org/10.3389/frai.2022.963781>
 40. Gupta, H.V., Kling, H., Yilmaz, K.K. & Martinez, G.F. 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. Journal of Hydrology, 377: 1. 80-91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
 41. Yaghoobzadeh, M., Khashei, A., Ramazeni, Y. & Hosseini, S. A. 2019. The selection of the best from climate change model in the estimation of climatology variables for east region of the country by use fifth report data. Journal of Arid Regions Geographic Studies, 10(37), 68-78. <https://sid.ir/paper/381961/en>.
 42. Zareian, M. 2022. Effects of Climate Change on Temperature and Precipitation in Yazd Province Based on Combined Output of CMIP6 Models, Journal of Hydrology and Soil Science, 26(2), 91-105. <http://jstnar.iut.ac.ir/article-1-4156-en.html>.
 43. Zhu, L., Kang, W., Li, W., Luo, J.-J. & Zhu, Y. 2022. The optimal bias correction for daily extreme precipitation indices over the Yangtze-Huaihe River basin, insight from BCC-CSM1.1-m. Atmospheric Research, 271, 106101. <https://doi.org/10.1016/j.atmosres.2022.106101>.
 - I—A discussion of principles. Journal of Hydrology, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).
 28. Noor, M., Ismail, T. & Ullah, S. 2020. A non-local model output statistics approach for the downscaling of CMIP5 GCMs for the projection of rainfall in Peninsular Malaysia. Journal Water Climate, 11(4), 944–955. <https://doi.org/10.2166/wcc.2019.041>.
 29. Nourani, V., Razzaghzadeh, Z., Baghanam, A.H. & Molajou, A. 2019. ANN-based statistical downscaling of climatic parameters using decision tree predictor screening method. Theoretical and Applied Climatology, 137, 1729–1746. DOI:10.1007/s00704-018-2686-z
 30. Nouri, M., Morid, S., Karimi, N. & Gholami, H. 2021. Spatial and temporal variation of temperature and precipitation trends of Aras transboundary river basin. Iran-Water Resources Research 17(3):104-117.
 31. Ostad-Ali-Askari, K., Ghorbanizadeh Kharazi, H., Shayannejad, M. & Zareian, M. J. 2020. Effect of climate change on precipitation patterns in an arid region using GCM models: case study of Isfahan-Borkhar Plain. Natural Hazards Review, 21(2), 04020006. [https://doi.org/10.1061/\(ASCE\)NH.1527-6996.0000367](https://doi.org/10.1061/(ASCE)NH.1527-6996.0000367).
 32. Pang, B., Yue, J., Zhao, G. & Xu, Z. 2017. Statistical downscaling of temperature with the random forest model. Advances in meteorology, 2017, 7265178. <https://doi.org/10.1155/2017/7265178>.
 33. Li, H., Yu, C., Xia, J., Wang, Y., Zhu, J. & Zhang, P. 2019. A model output machine learning method for grid temperature forecasts in the Beijing area. Advances in Atmospheric Sciences, 36, 1156–1170. <https://doi.org/10.1007/s00376-019-9023-z>.
 34. Raeesi, M., Zolfaghari, A. A., Kaboli, S. H., Rahimi, M., de Vente, J., & Eekhout, J. P. C. 2024. Using quantile mapping and random forest for bias-correction of high-resolution reanalysis precipitation data and CMIP6 climate projections over Iran. International Journal of Climatology, 44(12), 4495–4514. <https://doi.org/10.1002/joc.8593>
 35. Salman, S. A., Shahid, S., Ismail, T., et al. 2018. Selection of climate models for projection of spatiotemporal changes in temperature of Iraq with uncertainties. Atmospheric Research, 213, 509–522. <https://doi.org/10.1016/j.atmosres.2018.07.008>.
 36. Sa'adi, Z., Shahid, S. & Chung, E. S. 2017. Projection of spatial and temporal changes of rainfall in Sarawak of Borneo Island using statistical downscaling of CMIP5 models.