

ریزمقیاس‌سازی داده‌های بارش ماهواره TRMM به کمک داده‌های NDVI، مدل رقوم ارتفاعی و دمای سطح زمین با استفاده از مدل‌های یادگیری رگرسیونی

مهدی مهبد^{۱*}، سعیده صفری^۲ و محمدرفع رفیعی^۲

^۱ استادیار، دانشکده کشاورزی، دانشگاه جهرم و ^۲ کارشناس ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه جهرم

تاریخ پذیرش: ۱۴۰۰/۰۸/۱۵

تاریخ دریافت: ۱۴۰۰/۰۵/۰۸

چکیده

تعیین الگوی مکانی بارش در یک حوزه آبخیز، اهمیت فراوانی برای محاسبه کمیت‌هایی مانند دبی رواناب یا میزان رطوبت خاک دارد. محدودیت تعداد ایستگاه‌های هواشناسی و همچنین، تغییرپذیری مکانی بارش، مانعی در برابر تخمین مکانی دقیق بارش هستند. توسعه فناوری سنسج از دور و امکان استفاده از محصولات بارش تولید شده به‌وسیله سنسجده‌های ماهواره، مسیر دستیابی به الگوهای دقیق مکانی بارش را هموار کرده است. بزرگ مقیاس بودن مکانی نتایج محصولات بارش ماهواره‌ای، لزوم توسعه روش‌های ریزمقیاس‌سازی را برجسته می‌کند. در این پژوهش، داده‌های بارش TRMM با استفاده از شاخص نرمال شده تفاوت پوشش گیاهی (NDVI)، میانگین دمای روزانه، شبانه و اختلاف دمای شبانه‌روز در سطح زمین، مختصات و ارتفاع مرکز پیکسل‌ها برای رسیدن به تفکیک مکانی بالاتر، با جعبه ابزار یادگیری رگرسیونی در محیط نرم‌افزار MATLAB، برای ۱۹ مدل در سال‌های ۲۰۰۱ الی ۲۰۱۷ ریزمقیاس‌سازی شده است. این مدل‌ها به پنج دسته کلی رگرسیون خطی، درخت تصمیم، بردار پشتیبان، مدل‌های ترکیبی و مدل‌های گاوسی تقسیم می‌شود. از بین این ۱۹ مدل، مدل مربوط به دسته مدل‌های ترکیبی در همه سال‌ها دارای جذر میانگین مربعات خطای کمتر و ضریب همبستگی بیشتری بودند. همچنین، برای واسنجی کردن نتایج ریزمقیاس‌سازی، از دو روش فاصله جغرافیایی و نسبت اصلاح جغرافیایی استفاده شد که روش فاصله اصلاح جغرافیایی در همه مدل‌ها دارای خطای کمتری بود.

واژه‌های کلیدی: استان فارس، الگوی مکانی بارش، ایستگاه هواشناسی، فاصله اصلاح جغرافیایی، MODIS

مقدمه

باران‌سنج‌ها هستند. در چند دهه اخیر، استفاده از اطلاعات سامانه‌های سنسج از دور ماهواره‌ای با توجه به ویژگی‌های منحصر به فرد آن از قبیل پوشش وسیع و یکپارچه و سرعت انتقال اطلاعات با استقبال زیادی روبه‌رو شده است. سنسج از دور به معنی تشخیص و اندازه‌گیری ویژگی‌های یک جسم بدون تماس با آن جسم است. سنسج از دور به‌عنوان ابزاری مناسب در ارزیابی، نظارت، کنترل و مدیریت منابع آب و خاک،

بارندگی یکی از مهمترین عناصر اقلیم‌شناسی و هواشناسی است. اندازه‌گیری شدت و میزان بارش در زمینه‌های مدیریت منابع آب، کشاورزی و مدیریت سیلاب‌های احتمالی کاربرد وسیعی دارد. روش‌های سنتی برای اندازه‌گیری بارش معمولاً مبتنی بر ایستگاه‌های اقلیم‌شناسی، سینوپتیک زمینی و

تعداد زیادی از داده‌های سنجش از دور حاوی اطلاعاتی در مورد ویژگی‌های سطح زمین مانند شاخص پوشش گیاهی نرمال شده (NDVI)^۵، مدل رقوم ارتفاعی (DEM)^۶ و دمای سطح زمین (LST)^۷ هستند. این ویژگی‌ها با بارندگی در ارتباط بوده و رابطه معنی‌داری بین این متغیرها و بارندگی وجود دارد. از آنجایی‌که این داده‌ها با تفکیک مکانی بالایی در دسترس بوده می‌توان از آن‌ها برای ریزمقیاس‌سازی داده‌های بارندگی ماهواره‌ای استفاده کرد. در مطالعات ریزمقیاس‌سازی رابطه معنی‌داری بین داده‌های بارندگی ماهواره‌ای با تفکیک مکانی کم (برای مثال ۲۵ کیلومتر) و ویژگی‌های ذکرشده مربوط به سطح زمین برقرار می‌شود. سپس، از این روابط یا مدل‌های به‌دست آمده برای تخمین بارندگی در تفکیک‌های مکانی بیشتر (برای مثال یک کیلومتر) استفاده می‌شود. تفاوت عمده بین مطالعات ریزمقیاس‌سازی، نوع مدل‌های استفاده شده برای تخمین بارندگی بر اساس ویژگی‌های اندازه‌گیری شده و انتخاب این ویژگی‌ها است. Jia و همکاران (۲۰۱۱)، از هر دو اطلاعات مربوط به توپوگرافی (نقشه نقاط ارتفاعی DEM) و گیاه (شاخص NDVI) استفاده کردند تا دقت مکانی تصاویر محصول TRMM 3B43 را برای سال‌های ۱۹۹۹ تا ۲۰۰۹ از ۰/۲۵ درجه (۲۵ کیلومتر) به یک کیلومتر افزایش داده و میزان بارش باران را در حوزه آبخیز قایدیم چین، محاسبه کنند. Immerzeel و همکاران (۲۰۰۹)، از داده‌های ماهواره‌ای NDVI که تفکیک مکانی بیشتری را نسبت به مدل TRMM دارا بودند، استفاده کردند تا نتایج تخمین بارش مدل TRMM را در اسپانیا و پرتغال از ۲۵ کیلومتر به یک کیلومتر، ریزمقیاس‌سازی کنند. Duan و Bastiaanssen (۲۰۱۳)، یک روش جدید برای واسنجی نتایج ریزمقیاس‌سازی محصولات TRMM پیشنهاد کردند. ریزمقیاس‌سازی مکانی با روابط چند جمله‌ای مرتبه دوم بین TRMM و NDVI ایجاد شد، در حالی‌که فرایند واسنجی بر اساس تجزیه و تحلیل

جنگل‌ها، مراتع، کشاورزی و محیط زیست به‌کار گرفته شده است (Miri و همکاران، ۲۰۲۰).

تا کنون سامانه‌های متعددی برای تخمین بارندگی بر اساس داده‌های ماهواره‌ای سنجش از دور ایجاد شده‌اند که برای نمونه می‌توان به پروژه بارش اقلیم جهانی^۱ (Huffman و همکاران، ۱۹۹۷ و ۲۰۰۹)، نقشه بارش ماهواره جهانی^۲ (Kubota و همکاران، ۲۰۰۷؛ Jia و همکاران، ۲۰۱۱) و سنجش بارش گرمسیری^۳ (Huffman و همکاران، ۲۰۰۷، Kummerow و همکاران، ۱۹۹۸) اشاره کرد. یکی از پرکاربردترین سامانه‌های تخمین ماهواره‌ای بارش، سامانه TRMM است که در جهان و ایران مورد ارزیابی قرار گرفته است. برای نمونه از مطالعات انجام شده در کشور ایران، می‌توان به مطالعات Madadi و همکاران (۲۰۱۷)، Teimory و همکاران (۲۰۱۹)، Kazemzadeh و Akbari (۲۰۲۰) و Miri و همکاران (۲۰۲۰) اشاره کرد. ماهواره‌های هواشناسی، داده‌های بارش را با تفکیک زمانی بالایی ارائه می‌دهند، اما قدرت تفکیک مکانی آن‌ها (۰/۲۵ تا ۰/۵ درجه جغرافیایی)، به‌منظور بررسی تغییرات بارش در یک حوزه آبخیز بسیار بزرگ است. چنین مقیاس مکانی برای بررسی دقیق میزان بارندگی در حوضه‌های کوچک و شبکه آبیاری و زهکشی کاربرد بالایی ندارد. توسعه دانش فنی در ساخت سنجنده‌های دقیق توانسته دقت برآوردهای مکانی را افزایش دهد. به‌عنوان نمونه ماهواره GPM^۴ در ۲۸ فوریه ۲۰۱۴ از مرکز فضایی تانینگاشیما در ژاپن به فضا پرتاب شد. این سامانه تخمین بارندگی جهانی، دارای تفکیک مکانی ۰/۱ درجه و تفکیک زمانی ۳۰ دقیقه می‌باشد. با توجه به تفکیک مکانی سامانه‌های موجود برای تخمین بارش، ریزمقیاس‌سازی داده‌های آن‌ها به هدف افزایش تفکیک مکانی از اهمیت ویژه‌ای برخوردار است.

¹ Global Precipitation Climatology Project (GPCP)

² Global Satellite Mapping of Precipitation (GSMaP)

³ Tropical Rainfall Measuring Mission (TRMM)

⁴ Global Precipitation Measurement

⁵ Normalized Difference Vegetation Index

⁶ Digital Elevation Model

⁷ Land Surface Temperature

تفکیک مکانی را بهبود داده و با داده‌های مشاهداتی ایستگاه‌های باران‌سنجی تطابق خوبی داشت. با توجه به اهمیت مدل انتخابی، در این مطالعه توانایی مدل‌های مختلف یادگیری رگرسیونی مورد مقایسه قرار گرفت. تا کنون هیچ مطالعه‌ای در سطح ملی یا بین‌المللی، تمام این مدل‌ها (رگرسیون خطی، درخت تصمیم، بردار پشتیبان، مدل‌های ترکیبی و مدل‌های گاوسی) را با هم مورد مقایسه قرار نداده است. از طرف دیگر، برخی از روش‌های مورد استفاده برای اولین بار در فرایند ریزمقیاس‌سازی به کار گرفته شده‌اند. در این مطالعه، استان فارس که یکی از مناطق خشک و نیمه‌خشک کشور است و همواره در زمینه بررسی میزان بارندگی از نظر متخصصان حائز اهمیت بوده است، به عنوان منطقه مورد مطالعه انتخاب شد. در پژوهش حاضر، داده‌های بارندگی سالانه ماهواره TRMM 3B43 با استفاده از شاخص پوشش گیاهی (NDVI) و مدل رقوم ارتفاعی (DEM)، میانگین دمای روزانه، شبانه و اختلاف دمای شبانه‌روز از سطح زمین، مختصات طول و عرض و ارتفاع مرکز پیکسل‌ها برای رسیدن به تفکیک مکانی بالاتر، ریزمقیاس‌سازی شد. هدف اصلی در این مطالعه، استفاده از روش‌های مختلف یادگیری رگرسیونی در به دست آوردن مدل‌هایی توانمند نسبت به مدل‌های رگرسیون خطی برای تعیین بارندگی بر اساس عوامل محیطی و ریزمقیاس‌سازی با دقت بالاتر بود. نتایج این مدل‌ها با استفاده از روش پیشنهادی Duan و Bastiaanssen (۲۰۱۳)، واسنجی شدند و روش مناسب واسنجی نتایج ریزمقیاس‌سازی بر اساس اعتبارسنجی نتایج به دست آمده با مشاهدات زمینی اندازه‌گیری شده در ایستگاه‌های باران‌سنجی استان فارس معرفی شد.

مواد و روش‌ها

منطقه مورد پژوهش: استان فارس با وسعت ۱۲۵۶۹۷ کیلومتر مربع حدود ۷/۵ درصد مساحت کشور را در برمی‌گیرد و پنجمین استان پر جمعیت کشور می‌باشد. استان فارس در جنوب منطقه مرکزی ایران بین مدارهای ۲۷° ۲' و ۳۱° ۴۲' عرض شمالی و ۵۰° ۴۲' و ۵۵° ۳۶' طول شرقی قرار گرفته است.

نسبت جغرافیایی بود. Nichol و Abbas (۲۰۱۵)، رابطه بین بارندگی TRMM با تفکیک مکانی ۲۵ کیلومتر و شاخص پوشش گیاهی (NDVI) در یک کیلومتر در شبه‌جزیره Iberian را بررسی کردند و نشان دادند که ارتباط معنی‌دار آماری بین این شاخص‌ها، مقیاس محصولات TRMM 3B43 را به میزان یک کیلومتر کاهش داد. Shi و همکاران (۲۰۱۵)، الگوریتم کاهش مقیاس را با معرفی یک الگوریتم یادگیری ماشین^۱ به نام جنگل‌های تصادفی^۲ برای شناسایی روابط بارندگی با NDVI و DEM توسعه دادند. نتایج اعتبارسنجی آن‌ها نشان داد که مدل ریزمقیاس‌سازی بر اساس RF از مدل رگرسیون خطی و رگرسیون‌های نمایی بهتر بود. Katsanos و همکاران (۲۰۱۶)، محصولات بارندگی ماهواره‌های CHIRPS (Funk و همکاران، ۲۰۱۴) را در قبرس ریزمقیاس‌سازی کردند. آن‌ها از داده‌های DEM و NDVI و مدل‌های شبکه عصبی مصنوعی استفاده نمودند.

Li و همکاران (۲۰۱۰) و Zhang و همکاران (۲۰۱۸)، با استفاده از روش‌های رگرسیون وزنی جغرافیایی برای داده‌های بارش ماهانه TRMM ریزمقیاس‌سازی شده یک کیلومتری میزان جذر میانگین مربعات خطا (RMSE) را به ترتیب ۲۵ و ۲۲/۲ میلی‌متر و میانگین مطلق خطا (MAE) را ۱۶ و ۱۳/۵ میلی‌متر گزارش کردند. Zanjani و همکاران (۲۰۱۹)، از روش رگرسیون وزنی جغرافیایی (GWR) برای ریزمقیاس‌سازی نمایی مکانی داده‌های بارندگی ماهواره‌های TRMM 3B42V7 در سال آبی ۹۰-۱۳۸۹ برای حوزه آبخیز سد دز واقع در جنوب غربی ایران استفاده کردند. در این مطالعه، ریزمقیاس‌سازی با ایجاد روابط نایستا بین بارش TRMM و ویژگی‌های به دست آمده از مدل رقوم ارتفاعی، شاخص پوشش گیاهی نرمال شده، شاخص گیاهی بهبودیافته (EVI) و دمای سطح زمین (LST) انجام شد. نتایج نشان داد که ریزمقیاس‌سازی داده‌های بارش به طور معنی‌داری

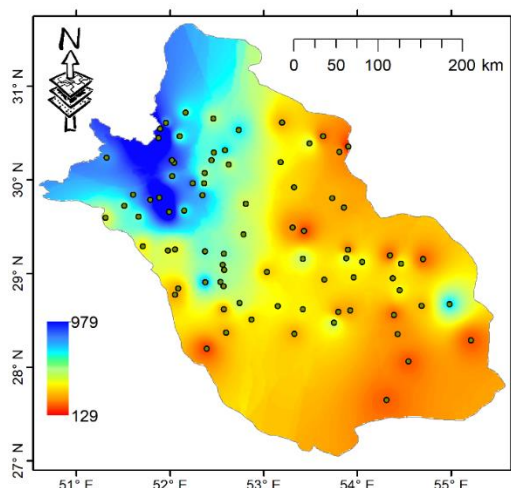
¹ Machine learning algorithm

² Random Forest (RF)

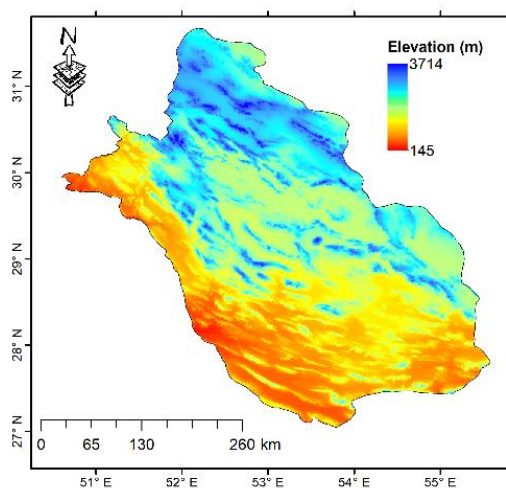
ایستگاه‌های باران‌سنجی به‌وسیله شرکت سهامی آب منطقه‌ای استان فارس تهیه شده است. برای واسنجی داده‌های ماهواره از آمار بارندگی ایستگاه‌های باران‌سنجی استفاده شد. برای این منظور، از تعداد ۸۹ ایستگاه همگن موجود (شکل ۱-ب) برای بازه زمانی سال ۲۰۰۱ الی ۲۰۱۷، تنها ۸۲ ایستگاه بود که موقعیت جغرافیایی آن‌ها در کاربری اراضی منتخب برای انجام این پژوهش قرار می‌گرفتند. برای تقسیم تصادفی ایستگاه‌ها برای واسنجی و اعتبارسنجی مدل‌های ریزمقیاس‌سازی، این ایستگاه‌ها بر اساس مقدار متوسط بارندگی سالانه مرتب و ایستگاه‌های شماره فرد برای واسنجی و ایستگاه‌های شماره زوج برای اعتبارسنجی استفاده شدند (شکل ۲).

میانگین دما در سردترین ماه سال بین ۲- تا ۷- درجه سانتی‌گراد و در گرم‌ترین ماه سال بین ۳۵ تا ۴۰ درجه سانتی‌گراد در نوسان است. جهت عمومی کوه‌های این استان، شمال غربی-جنوب شرقی است و از طرف شمال به جنوب از ارتفاع کوهستان به‌طور عمومی کاسته می‌شود (شکل ۱). بیشترین مقدار بارندگی در استان مربوط به شمال غرب و کمترین مقدار بارندگی مربوط به شرق و جنوب استان است.

داده‌های مورد استفاده: داده‌های مورد نیاز در این تحقیق، شامل داده‌های ایستگاه‌های باران‌سنجی، داده‌های بارش ماهواره‌های TRMM، NDVI، DEM، LST روزانه، LST شبانه و اختلاف دمای شبانه‌روز، مختصات و ارتفاع مرکز پیکسل‌ها می‌باشد. اطلاعات

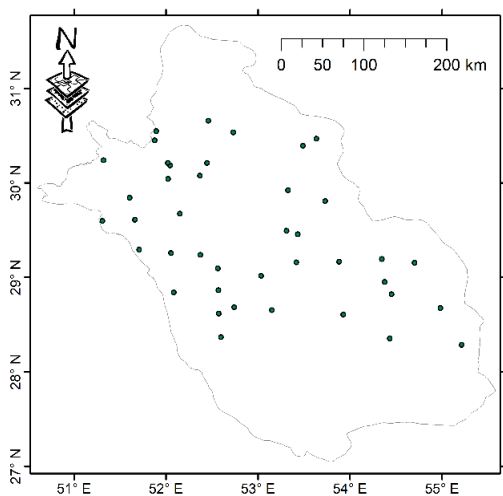


(ب)




(الف)

شکل ۱- الف) نقشه توپوگرافی استان فارس و ب) موقعیت جغرافیایی ایستگاه‌های باران‌سنجی مورد استفاده در این مطالعه



(ب)



(الف)

شکل ۲- موقعیت ایستگاه‌های انتخاب شده، الف) ۴۱ ایستگاه برای واسنجی و ب) ۴۱ ایستگاه برای اعتبارسنجی

هستند، لذا، در ریزمقیاس‌سازی در نظر گرفته نشده‌اند.

روش پژوهش

یادگیری ماشین: روش‌های رگرسیونی مورد استفاده در این مطالعه زیرمجموعه روش‌های یادگیری ماشین (Machine Learning) قرار می‌گیرند. بنابراین، در این قسمت، به اختصار به معرفی اصول نظری این روش‌ها پرداخته می‌شود. به‌عنوان یکی از شاخه‌های وسیع و پرکاربرد هوش مصنوعی، یادگیری ماشینی به تنظیم و اکتشاف شیوه‌ها الگوریتم‌هایی می‌پردازد که بر اساس آن‌ها رایانه‌ها توانایی یادگیری و سپس، پیش‌بینی یا تخمین پیدا می‌کنند. یادگیری ماشینی به رایانه‌ها امکان استفاده از داده‌ها و یادگیری از آن‌ها برای بهبود پیش‌بینی و تخمین را می‌دهد. در این پژوهش، از ۱۹ مدل موجود در جعبه ابزار یادگیری رگرسیون در نرم‌افزار MATLAB استفاده شد. این ۱۹ مدل، به پنج دسته کلی رگرسیون خطی، رگرسیون درختی، رگرسیون بردار پشتیبان، رگرسیون ترکیبی و رگرسیون گاوسی تقسیم می‌شود (جدول ۲).

در این مطالعه، از داده‌های بارندگی ماهواره‌ای TRMM 3B43 استفاده شد که از سایت mirador.gsfc.nasa.gov/ دانلود شدند. این داده‌ها تفکیک زمانی یک ماه و تفکیک مکانی ۲۵ کیلومتر دارند. بارش سالانه از سال ۲۰۰۰ الی ۲۰۱۷ با جمع داده‌های ماهانه از ماهواره TRMM (محصول شماره 3B43) برای ۱۲ ماه از هر سال محاسبه شد. نقشه رقوم ارتفاعی (DEM) از رادار SRTM و سایت earthexplorer.usgs.gov با تفکیک مکانی ۹۰ متر، شاخص NDVI از سنجنده مادیس (محصول شماره MOD13A3، تفکیک زمانی یک ماه و تفکیک مکانی یک کیلومتر) و دمای سطح زمین (LST) محصول دیگر سنجنده مادیس با تفکیک زمانی روزانه و تفکیک مکانی یک کیلومتر از سایت ladsweb.modaps.eosdis.nasa.gov/search دریافت شدند. محصول MCD12Q1 سنجنده مادیس، کاربری اراضی را به‌صورت سالانه و با قدرت تفکیک مکانی ۵۰۰ متر در ۱۷ طبقه مختلف طبقه‌بندی می‌کند. مقدار NDVI در کاربری‌های آب، زمین‌های کشاورزی و شهرها مستقل از میزان بارندگی

جدول ۲- مدل‌های رگرسیونی استفاده‌شده در پژوهش

SVM (Fine Gaussian SVM)	۱۱	Linear Regression (Linear)	۱
SVM (Medium Gaussian SVM)	۱۲	Linear Regression (Interactions Linear)	۲
SVM (Coarse Gaussian SVM)	۱۳	Linear Regression (Robust Linear)	۳
Ensemble (Boosted Trees)	۱۴	Linear Regression (Stepwise Linear)	۴
Ensemble (Bagged Trees)	۱۵	Tree (Fine Tree)	۵
Gaussian Process Regression (Squared Exponential GPR)	۱۶	Tree (Medium Tree)	۶
Gaussian Process Regression (Matern 5/2 GPR)	۱۷	Tree (Coarse Tree)	۷
Gaussian Process Regression (Exponential GPR)	۱۸	SVM (Linear SVM)	۸
Gaussian Process Regression (Rational Quadratic GPR)	۱۹	SVM (Quadratic SVM)	۹
		SVM (Cubic SVM)	۱۰

شرطی درختی به‌عنوان مدل پیش‌گو استفاده می‌کند که مشاهدات در مورد یک شیء را به نتایجی در مورد ارزش هدف این شیء می‌نگارد.

ماشین‌های بردار پشتیبانی (Support Vector Machines): در اصل یک دسته‌بندی کننده دو طبقه‌ای است که طبقات را به‌وسیله یک مرز خطی از

رگرسیون خطی (Linear Regression): نوعی تابع پیش‌بینی کننده خطی است که در آن متغیر وابسته (متغیری که قرار است، پیش‌بینی شود) به‌صورت ترکیبی خطی از متغیرهای مستقل پیش‌بینی می‌شود. درخت تصمیم (Decision tree learning): یک ابزار برای پشتیبانی از تصمیم است که از یک الگوی

هم جدا می‌کند. در این روش نزدیک‌ترین نمونه‌ها به مرز تصمیم‌گیری را بردارهای پشتیبان می‌نامند. این بردارها معادله مرز تصمیم‌گیری را مشخص می‌کنند. یادگیری ترکیبی (Ensemble): از ترکیب چندین الگوی طبقه‌بندی (Classifier) استفاده می‌کند. در واقع این طبقه‌بندها، هر کدام مدل خود را بر روی داده‌ها ساخته و این مدل را ذخیره می‌کنند. در نهایت، برای طبقه‌بندی نهایی یک مقایسه در بین طبقه‌بندها انجام می‌شود و آن طبقه‌ای که بیشترین امتیاز را بیاورد، روش نهایی محسوب می‌شود.

$$\varepsilon_{LR} = P_{3B43,LR} - f \left(\begin{matrix} NDVI_{LR}, T_{Day,LR}, T_{Night,LR}, T_{Dif,LR} \\ X_{LR}, Y_{LR}, Z_{LR} \end{matrix} \right) \quad (2)$$

یادگیری گاوسی (Gaussian Regression): فرایند گاوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد دلخواه محدودی از آن‌ها با توزیع‌های گاوسی سازگار شده‌اند. فرایند گاوسی به‌طور کامل به‌وسیله تابع میانگین و تابع کوواریانس آن مشخص می‌شود. مدل‌های رگرسیون گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره همدیگر باشند. مدل‌های رگرسیون فرایند گاوسی قادر به درک توزیع پیش‌بینی متناظر با ورودی آزمون هستند (Statistics and Machine Learning Toolbox, ۲۰۱۶).

$$P_{3B43,HR} = f \left(\begin{matrix} NDVI_{HR}, T_{Day,HR}, T_{Night,HR}, T_{Dif,HR} \\ X_{HR}, Y_{HR}, Z_{HR} \end{matrix} \right) \quad (3)$$

الگوریتم ریزمقیاس‌سازی نمایی: در این مطالعه، پارامترهای عرض و طول جغرافیایی، شاخص گیاهی NDVI، میانگین سالانه دمای روزانه سطح زمین، میانگین سالانه دمای شبانه سطح زمین، میانگین سالانه اختلاف دمای شب و روز و ارتفاع از سطح دریا به‌عنوان پارامترهای مؤثر در تخمین بارندگی سالانه در نظر گرفته شدند. بنابراین، در ابتدا بین مقادیر بارندگی سالانه حاصل از ماهواره TRMM ($P_{3B43,LR}$) و مقادیر بزرگ‌مقیاس شده عوامل مستقل (تفکیک مکانی ۲۵ کیلومتر) رابطه رگرسیونی برقرار شد و برای هر سال از داده‌ها، ۱۹ مدل یادگیری رگرسیونی (f) به شرح زیر به‌دست آمد.

$$P_{3B43,LR} = f \left(\begin{matrix} NDVI_{LR}, T_{Day,LR}, T_{Night,LR}, T_{Dif,LR} \\ X_{LR}, Y_{LR}, Z_{LR} \end{matrix} \right) + \varepsilon_{LR} \quad (1)$$

که در آن، $NDVI$ شاخص نرمال شده پوشش گیاهی، T_{Day} میانگین سالانه دمای روزانه سطح زمین T_{Night} میانگین سالانه دمای شبانه سطح زمین

میانگین سالانه اختلاف دمای شب و روز T_{Dif} ، $(^{\circ}C)$ سطح زمین X و Y به ترتیب عرض و طول جغرافیایی مرکز پیکسل‌های داده‌های بارندگی ماهواره‌ای (درجه) و Z متوسط ارتفاع در پیکسل‌های 3B43 (m) هستند. علامت LR نشان‌دهنده پارامترها به‌صورت بزرگ‌مقیاس یعنی با تفکیک مکانی ۲۵ کیلومتر هستند. تابع f تابع یادگیری رگرسیونی انتخاب شده در جعبه ابزار یادگیری رگرسیون (Regression learner) نرم‌افزار MATLAB است که بر داده‌های مطالعه برآزش می‌یابد. ε مقدار باقی‌مانده رگرسیون می‌باشد و نشان‌دهنده آن مقدار از تغییرات P_{3B43} می‌باشد که به‌وسیله تابع f پیش‌بینی نشده است. در گام بعدی با استفاده از مدل به‌دست آمده (f)، مقدار باقی‌مانده برای هریک از پیکسل‌های بزرگ‌مقیاس (۲۵ کیلومتر) به‌صورت زیر محاسبه شد.

سپس، مقدار باقی‌مانده درشت‌مقیاس (ε_{LR}) با استفاده از روش مناسب میان‌یابی شد و با تفکیک مکانی یک کیلومتر (ε_{HR}) ذخیره شد. با استفاده از مقدار پارامترهای عرض و طول جغرافیایی، NDVI، میانگین سالانه دمای روزانه سطح زمین، میانگین سالانه دمای شبانه سطح زمین، میانگین سالانه اختلاف دمای شب و روز و ارتفاع از سطح دریا به‌عنوان پارامترهای مؤثر در تخمین بارندگی سالانه در نظر گرفته شدند. بنابراین، در ابتدا بین مقادیر بارندگی سالانه حاصل از ماهواره TRMM ($P_{3B43,LR}$) و مقادیر بزرگ‌مقیاس شده عوامل مستقل (تفکیک مکانی ۲۵ کیلومتر) رابطه رگرسیونی برقرار شد و برای هر سال از داده‌ها، ۱۹ مدل یادگیری رگرسیونی (f) به شرح زیر به‌دست آمد.

که در آن، $NDVI$ شاخص نرمال شده پوشش گیاهی، T_{Day} میانگین سالانه دمای روزانه سطح زمین T_{Night} میانگین سالانه دمای شبانه سطح زمین T_{Dif} ، $(^{\circ}C)$ سطح زمین X و Y به ترتیب عرض و طول جغرافیایی مرکز پیکسل‌های داده‌های بارندگی ماهواره‌ای (درجه) و Z متوسط ارتفاع در پیکسل‌های 3B43 (m) هستند. علامت LR نشان‌دهنده پارامترها به‌صورت بزرگ‌مقیاس یعنی با تفکیک مکانی ۲۵ کیلومتر هستند. تابع f تابع یادگیری رگرسیونی انتخاب شده در جعبه ابزار یادگیری رگرسیون (Regression learner) نرم‌افزار MATLAB است که بر داده‌های مطالعه برآزش می‌یابد. ε مقدار باقی‌مانده رگرسیون می‌باشد و نشان‌دهنده آن مقدار از تغییرات P_{3B43} می‌باشد که به‌وسیله تابع f پیش‌بینی نشده است. در گام بعدی با استفاده از مدل به‌دست آمده (f)، مقدار باقی‌مانده برای هریک از پیکسل‌های بزرگ‌مقیاس (۲۵ کیلومتر) به‌صورت زیر محاسبه شد.

$$P_{3B43,HR} = f \left(\begin{matrix} NDVI_{HR}, T_{Day,HR}, T_{Night,HR}, T_{Dif,HR} \\ X_{HR}, Y_{HR}, Z_{HR} \end{matrix} \right) + \varepsilon_{HR} \quad (4)$$

سپس، مقدار باقی‌مانده درشت‌مقیاس (ε_{LR}) با استفاده از روش مناسب میان‌یابی شد و با تفکیک مکانی یک کیلومتر (ε_{HR}) ذخیره شد. با استفاده از مقدار پارامترهای عرض و طول جغرافیایی، NDVI، میانگین سالانه دمای روزانه سطح زمین، میانگین سالانه دمای شبانه سطح زمین، میانگین سالانه اختلاف دمای شب و روز و ارتفاع از سطح دریا به‌عنوان پارامترهای مؤثر در تخمین بارندگی سالانه در نظر گرفته شدند. بنابراین، در ابتدا بین مقادیر بارندگی سالانه حاصل از ماهواره TRMM ($P_{3B43,LR}$) و مقادیر بزرگ‌مقیاس شده عوامل مستقل (تفکیک مکانی ۲۵ کیلومتر) رابطه رگرسیونی برقرار شد و برای هر سال از داده‌ها، ۱۹ مدل یادگیری رگرسیونی (f) به شرح زیر به‌دست آمد.

محاسبه شده مربوط به آن در محل ایستگاه هواشناسی محاسبه می‌شود.

$$R_i^j = \frac{P_{g_i^j}}{P_{3B43,HR^j}} \quad (8)$$

که در آن، R مقدار نسبت واسنجی، P_g مقدار بارندگی سالانه اندازه‌گیری شده در ایستگاه شماره i و سال z هستند. با محاسبه R در ایستگاه‌های واسنجی، نقشه تغییرات آن در کل استان با استفاده از روش کریجینگ میان‌یابی و تهیه شد. سپس، مقدار واسنجی شده بارندگی محاسبه شده در مراحل قبلی ریزمقیاس‌سازی ($P_{3B43,HR}$) با مقدار میان‌یابی شده R در مکان هر پیکسل (یک کیلومتری) ضرب شد و مقدار اصلاح‌شده و نهایی ریزمقیاس‌سازی شده ($P_{3B43,HR,cal}$) محاسبه شد (معادله ۹).

$$P_{3B43,HR',calGRA} = P_{3B43,HR'} \times R \quad (9)$$

در نهایت، مقادیر بارندگی ریزمقیاس‌سازی شده و اصلاح‌شده به‌وسیله هر دو روش GRA و GDA با مقادیر بارندگی سالانه در ۴۱ ایستگاه دیگر که در فرایند واسنجی استفاده نشدند، اعتبارسنجی شدند.

اعتبارسنجی: نتایج ریزمقیاس‌سازی بارندگی برای سال‌های ۲۰۰۱ تا ۲۰۱۷ با استفاده از مجموعه داده‌های ۴۱ ایستگاه باران‌سنجی، اعتبارسنجی شدند. برای این منظور، مقدار بارندگی هر ایستگاه با مقدار بارندگی پیکسل دربردارنده آن ایستگاه مقایسه شد. شاخص‌های مورد استفاده برای اعتبارسنجی، ضریب تعیین (R^2)، ضریب همبستگی پیرسون (R) ریشه دوم میانگین مربع خطا (RMSE) بودند. R^2 بین صفر و +۱ متغیر می‌باشد و نشان‌دهنده بخشی از واریانس متغیر وابسته است که به‌وسیله یک مدل تبیین می‌شود. با توجه به این‌که R^2 نشان‌دهنده جهت همبستگی بین داده‌های مورد بررسی نیست، در مقایسه نهایی بین بارندگی ریزمقیاس‌سازی شده و ایستگاه‌های باران‌سنجی از ضریب همبستگی پیرسون (R) استفاده شد. لازم به توضیح این‌که در برخی از مدل‌های یادگیری ماشین در بعضی سال‌های مورد مطالعه ضریب همبستگی بین بارندگی ریزمقیاس‌سازی شده و داده‌های ایستگاهی منفی به‌دست آمد که باعث کاهش متوسط ضریب همبستگی شدند. در صورتی که از R^2 استفاده می‌شد،

برای بررسی تأثیر و لزوم میان‌یابی باقی‌مانده مدل‌های مورد استفاده، یک‌بار هم $P_{3B43,HR}$ با ε_{LR} به شرح زیر اصلاح شد و نتایج آن با سایر حالت‌ها مقایسه شد.

$$P_{3B43,HR''} = f \left(\begin{matrix} NDVI_{HR}, T_{Day,HR}, T_{Night,HR}, T_{Dif,HR} \\ X_{HR}, Y_{HR}, Z_{HR} \end{matrix} \right) + \varepsilon_{LR} \quad (5)$$

در فرایند ریزمقیاس‌سازی داده‌های ماهواره‌ای با داده‌های ایستگاه‌های زمینی نیز واسنجی شدند. به‌منظور واسنجی از روش پیشنهادی Duan و Bastiaanssen (۲۰۱۳) استفاده شد. در این روش می‌توان $P_{3B43,HR}$ را با استفاده از نسبت اصلاحی جغرافیایی (GRA^۱) یا فاصله اصلاحی جغرافیایی (GDA^۲) واسنجی کرد که در این پژوهش از هر دو روش استفاده شد.

فاصله اصلاحی جغرافیایی (GDA): در این روش، ابتدا فاصله بین بارش اندازه‌گیری شده در هر سال با مقدار محاسبه شده مربوط به آن در محل ایستگاه هواشناسی محاسبه می‌شود.

$$D_i^j = P_{g_i^j} - P_{3B43,HR^j} \quad (6)$$

که در آن، D مقدار فاصله واسنجی، P_g مقدار بارندگی سالانه اندازه‌گیری شده در ایستگاه شماره i و سال z هستند. با محاسبه D در ایستگاه‌های واسنجی، نقشه تغییرات آن در کل استان با استفاده از روش کریجینگ (Juang و همکاران، ۱۹۹۸) میان‌یابی و تهیه شد. روش کریجینگ با استفاده از جعبه ابزار Geospatial Wizard در نرم‌افزار Arc-Map انجام شد. در طی روال میان‌یابی کم‌خطاترین نیم‌تغییرنا انتخاب شد و برای میان‌یابی استفاده شد. سپس، مقدار واسنجی شده بارندگی محاسبه شده در مراحل قبلی ریزمقیاس‌سازی ($P_{3B43,HR'}$) با مقدار میان‌یابی شده D در مکان هر پیکسل (یک کیلومتری) جمع شد و مقدار اصلاح‌شده و نهایی ریزمقیاس‌سازی شده ($P_{3B43,HR',calGDA}$) محاسبه شد.

$$P_{3B43,HR',calGDA} = P_{3B43,HR'} + D \quad (7)$$

نسبت اصلاحی جغرافیایی (GRA): در این روش ابتدا، نسبت بین بارش اندازه‌گیری شده در هر سال با مقدار

^۱ Geographic Ratio Adjustment


^۲ Geographic Difference Adjustment

مدل‌های ۱۴، ۱۶، ۱۷، ۱۸ و ۱۹ دارای ضریب تعیین (به ترتیب ۰/۸۹، ۰/۹۱، ۰/۹۱، ۰/۹۰ و ۰/۹۰) بالاتری بودند. نکته مهم این‌که مدل‌های رگرسیون خطی (۱) الی (۴) دارای عملکرد ضعیفی از نظر RMSE (به ترتیب ۰/۶۸، ۰/۷۲، ۰/۷۱) و R^2 (۶۶/۹ و ۶۹/۸، ۶۴/۸، ۶۶/۷ و ۰/۷۱) در مقایسه با سایر مدل‌ها بودند. لازم به ذکر است که در این مرحله هنوز ریزمقیاس‌سازی انجام نشده، بنابراین، برای مشاهده و مقایسه عملکرد همه مدل‌ها در ریزمقیاس‌سازی شرکت داده شدند. بنابراین، برای هر سال، ابتدا مقدار بارندگی در ایستگاه‌های واسنجی با مقدار بارندگی پیکسل در بردارنده آن‌ها مقایسه شد. در ادامه، با استفاده از روش‌های توضیح داده‌شده در بخش مواد و روش‌ها $P_{3B43,HR}, P_{3B43,HR'}, P_{3B43,HR''}, P_{3B43,HR,calGDA}$ و $P_{3B43,HR,calGRA}$ محاسبه و با مقادیر بارندگی در ایستگاه‌های واسنجی مقایسه و مقادیر RMSE و R برای ۱۹ مدل یادگیری رگرسیونی محاسبه شدند. میانگین RMSE و R برای مدل‌های یادگیری رگرسیونی در سال‌های ۲۰۰۱ الی ۲۰۱۷ به ترتیب در شکل‌های ۵ و ۶ نشان داده شده‌اند.


مقدار میانگین ضریب تعیین به‌طور مصنوعی (نه واقعی) هماهنگی بیشتری بین نتایج را نشان می‌داد. RMSE نشان‌دهنده میزان خطای نتایج تخمینی است و هر چه به صفر نزدیک‌تر باشد، دقت ریزمقیاس‌سازی بیشتر بوده است.

نتایج و بحث

مقدار RMSE و ضریب تعیین (R^2) برای ۱۹ مدل یادگیری رگرسیونی (معادله ۱) در ۱۷ سال محاسبه شد. این مقادیر برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶ در شکل‌های ۳ و ۴ نشان داده شده‌اند. شکل ۳، نشان می‌دهد که در بین مدل‌های مورد بررسی، مدل‌های شماره ۱۴، ۱۶، ۱۷، ۱۸ و ۱۹ دارای کمترین مقدار RMSE (به ترتیب ۰/۳۷، ۰/۳۷، ۰/۳۷، ۰/۳۷ و ۰/۳۷ میلی‌متر) نسبت به بقیه مدل‌ها بودند. هرچند کارایی این مدل‌ها نزدیک به هم بود، شکل ۳ نشان می‌دهد که در سال ۲۰۰۱ و ۲۰۱۶ مقدار RMSE برای مدل شماره ۱۴ (Ensemble boosted trees) کمتر از مدل‌های یادگیری رگرسیون گاوسی بود. همین روند برای ضریب تعیین هم مشاهده شد (شکل ۴) و



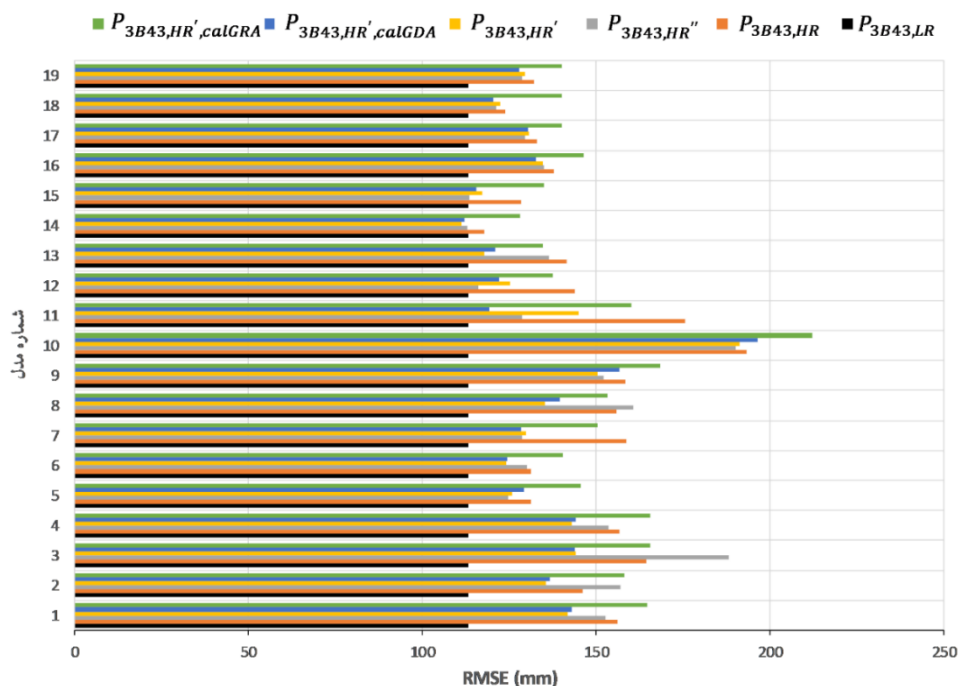
شکل ۳- مقدار RMSE بین مقادیر بارندگی سالانه اندازه‌گیری شده به‌وسیله ماهواره TRMM و پیش‌بینی شده به‌وسیله مدل‌های یادگیری رگرسیونی مختلف واسنجی شده در سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶



شکل ۴- مقدار R^2 بین مقادیر بارندگی سالانه اندازه‌گیری شده به‌وسیله ماهواره TRMM و پیش‌بینی شده به‌وسیله مدل‌های یادگیری رگرسیونی مختلف واسنجی شده در سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶

شکل ۵، نشان می‌دهد که در همه مدل‌های یادگیری رگرسیونی، میزان متوسط RMSE در $P_{3B43,HR}$ نسبت به $P_{3B43,LR}$ (۱۱۳/۳ میلی‌متر) افزایش یافته است که این روند مشابه نتایج به‌دست آمده از مطالعات Duan و Bastiaansse (۲۰۱۳) در حوضه دریای خزر ایران و Li و همکاران (۲۰۱۰) در منطقه شنزن چین بود. اگر چه این محققین به ترتیب از مدل‌های نمایی و رگرسیون وزنی جغرافیایی ریزمقیاس‌سازی استفاده کردند، اما مشابه نتایج به‌دست آمده، مطالعه حاضر در بیشتر مدل‌های رگرسیونی آن‌ها، میزان خطای تخمین بارندگی برای $P_{3B43,HR}$ نسبت به $P_{3B43,LR}$ افزایش یافت. البته آن‌ها نشان دادند که با اصلاح $P_{3B43,HR}$ از طریق اعمال مقادیر میان‌یابی شده باقی‌مانده‌ها (ϵ_{HR}) دقت فرایند ریزمقیاس‌سازی افزایش می‌یابد. با توجه به شکل ۵، مقدار RMSE برای $P_{3B43,HR}$ در مدل ۱۴ و ۱۸ (به ترتیب ۱۱۷/۷ و ۱۲۳/۷ میلی‌متر) کمترین مقادیر در بین مدل‌های مورد بررسی بود. با اصلاح $P_{3B43,HR}$ با استفاده از ϵ_{HR} مقدار RMSE برای همه مدل‌ها برای $P_{3B43,HR}'$ کاهش یافت. نکته دیگر این‌که مقدار RMSE برای $P_{3B43,HR}''$ به‌طور متوسط پنج میلی‌متر بالاتر از مقدار به‌دست آمده برای $P_{3B43,HR}'$ بود. بنابراین، میان‌یابی باقی‌مانده مدل‌های رگرسیونی تأثیر معنی‌داری روی کاهش خطا نداشت. در بین مدل‌های بررسی‌شده کمترین مقدار RMSE برای $P_{3B43,HR}'$ به ترتیب در مدل‌های شماره ۱۴ (۱۱۱ میلی‌متر)، ۱۵ (۱۱۷/۲ میلی‌متر) و ۱۳ (۱۱۷/۸ میلی‌متر) به‌دست آمد. این مقدار تنها در مدل ۱۴ از مقدار به‌دست آمده برای $P_{3B43,LR}$ کمتر بود که نشان می‌دهد، استفاده از این مدل رگرسیونی و ریزمقیاس‌سازی بدون واسنجی نتایج، مقدار خطا در تخمین بارندگی را کاهش داده است. همچنین، شکل ۵ نشان می‌دهد که مقدار RMSE حاصل از $P_{3B43,HR}', calGRA$ (میانگین به‌دست آمده از همه مدل‌ها ۱۵۱/۸ میلی‌متر) بیشتر از مقدار به‌دست آمده برای $P_{3B43,HR}', calGDA$ (میانگین به‌دست آمده از همه مدل‌ها ۱۳۳/۸ میلی‌متر) در همه مدل‌ها بود که این اختلاف در سطح احتمال پنج درصد معنی‌دار بود. با مقایسه $P_{3B43,HR}', calGDA$ و $P_{3B43,HR}'$ ، شکل ۵ نشان داد که میزان RMSE در

واسنجی به روش فاصله اصلاحی، تفاوت چندانی نداشت، به طوری که مقدار میانگین اختلاف RMSE بین این دو حالت، یک میلی‌متر بود که در سطح احتمال پنج درصد معنی‌دار نبود. بنابراین، واسنجی به روش نسبت اصلاحی با توجه به مقدار خطای مضاعف قابل استفاده نبود و روش فاصله اصلاحی نیز باعث افزایش دقت ریزمقیاس‌سازی به‌طور معنی‌داری نشد، هرچند که کمترین مقدار خطا مربوط به واسنجی مدل یادگیری رگرسیونی ۱۴ بود. هدف در مطالعات ریزمقیاس‌سازی افزایش تفکیک مکانی محصولات تولید شده به‌وسیله سامانه‌های ماهواره‌ای است. حالت ایده‌آل زمانی است که مقدار خطای تخمین در محصولات ماهواره‌ای با انجام ریزمقیاس‌سازی افزایش نیابد (Immerzeel و همکاران، ۲۰۰۹). در شکل ۵، نمودار میله‌ای سیاه رنگ نشان‌دهنده مقدار متوسط خطای تخمین بارندگی به‌وسیله ماهواره TRMM می‌باشد. سایر نمودارهای میله‌ای با رنگ‌های متفاوت نشان‌دهنده نتیجه ریزمقیاس‌سازی با روش‌های متفاوت هستند. با توجه به نتایج به‌دست آمده، شکل ۵ تایید می‌کند که نتایج ریزمقیاس‌سازی با استفاده از مدل شماره ۱۴ کمترین مقدار خطای مضاعف را ایجاد کرده است. نکته مهم در نتایج به‌دست آمده مقدار خطای محاسبه شده (۱۱۱ میلی‌متر) نسبت به مقدار بارندگی متوسط منطقه فارس در سال‌های ۲۰۰۱ الی ۲۰۱۶ (۳۴۸ میلی‌متر) است که در تحقیقات دیگر مشابه آن گزارش شده است. Jing و همکاران (۲۰۱۶)، ریزمقیاس‌سازی برای بارش ماهانه TRMM در شمال چین (متوسط بارندگی ماهانه ۳۶ میلی‌متر) انجام دادند و متوسط RMSE محاسبه شده برای بهترین مدل پیشنهادی (جنگل‌های تصادفی) ۱۵/۷ میلی‌متر به‌دست آمد. Chen و همکاران (۲۰۱۵)، با گزارش برتری روش رگرسیون وزنی جغرافیایی نسبت به روش رگرسیون چندگانه برای منطقه از چین با متوسط بارندگی سالانه ۲۹۲ میلی‌متر، مقدار RMSE در اعتبارسنجی ریزمقیاس‌سازی ۱۱۰ میلی‌متر گزارش دادند. افزایش خطا در تخمین بارندگی ریزمقیاس‌سازی شده در مطالعه Alexakis و Tsanis (۲۰۱۶) در منطقه کرت یونان نیز مشاهده شد.



شکل ۵- مقدار میانگین RMSE بین مقادیر بارندگی تخمین زده شده به وسیله ماهواره TRMM ($P_{3B43,LR}$) و روش‌های مختلف ریزمقیاس‌سازی ($P_{3B43,HR}$ ، $P_{3B43,HR'}$ ، $P_{3B43,HR''}$ ، $P_{3B43,HR',calGDA}$ ، $P_{3B43,HR',calGRA}$) با داده‌های بارندگی ایستگاه‌های اعتبارسنجی در ۱۹ مدل رگرسیونی برای سال ۲۰۰۱ الی ۲۰۱۷


در بین مدل‌های مورد بررسی برای حالت‌های ریزمقیاس‌سازی $P_{3B43,HR'}$ و $P_{3B43,HR',calGDA}$ در مدل ۱۴ به دست آمد. بدین ترتیب، مدل شماره ۱۴، بهترین کارایی در ریزمقیاس‌سازی داده‌های بارندگی را داشت. بنابراین، در ادامه نتایج ریزمقیاس‌سازی بارندگی حاصل از این مدل برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶ نشان داده شد.

در شکل ۷، نقشه تغییرات مکانی $P_{3B43,HR}$ در سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶ (سال‌های تصادفی انتخاب‌شده) نشان داده شده است. نقاط سفید، محل پیکسل‌هایی است که مقدار تغییرات وضعیت پوشش گیاهی تابع بارندگی نبود و حذف شده‌اند. برای اصلاح این سه نقشه با استفاده از باقی‌مانده رگرسیون‌ها، ابتدا مقدار باقی‌مانده با تفکیک مکانی ۲۵ کیلومتر (ϵ_{LR}) محاسبه شد که در شکل ۸ نشان داده شده‌اند. ۲۲۳ پیکسل داده ماهواره‌ای کل استان فارس را در بر می‌گرفتند. برای چهار پیکسل که در محدوده مرکز استان و در اطراف دریاچه مهارلو قرار می‌گرفتند، مقدار بارندگی سالانه به مقدار قابل توجهی به وسیله ماهواره TRMM در برخی سال‌ها بیش برآورد می‌شد.

شکل ۶، نشان می‌دهد که مقدار همبستگی بین مقادیر بارندگی ایستگاه‌ها و ماهواره در تمام حالت‌های ریزمقیاس‌سازی برای همه مدل‌ها نسبت به مقادیر به دست آمده برای $P_{3B43,LR}$ کاهش یافت. این موضوع را می‌توان به دلیل همبسته‌سازی داده‌های ریزمقیاس‌سازی شده با عوامل محیطی (پوشش گیاهی و رقوم ارتفاعی و دمای سطح زمین) دانست. البته این کاهش ضریب همبستگی در مدل ۱۴ کمتر از سایر مدل‌ها بود، به طوری که متوسط این کاهش ضریب همبستگی برای $P_{3B43,HR'}$ و $P_{3B43,HR',calGDA}$ در ۱۷ سال مورد مطالعه به ترتیب ۰/۰۴ و ۰/۰۳ بود که در سطح احتمال پنج درصد معنی‌دار نبودند. نکته مهم و قابل توجه این بود که مقدار R در روش واسنجی فاصله اصلاحی ($P_{3B43,HR',calGDA}$)، به طور متوسط به اندازه ۰/۰۱ از مقدار آن برای $P_{3B43,HR'}$ بیشتر بود که در سطح احتمال پنج درصد معنی‌دار نبود. همچنین، واسنجی به روش نسبت اصلاحی (GRA) باعث کاهش معنی‌دار ضریب همبستگی به اندازه ۰/۱۴ در سطح احتمال پنج درصد شد. همچنین، بیشینه ضریب همبستگی

ایجاد می‌کردند، اعداد مربوط به این چهار پیکسل حذف شدند.

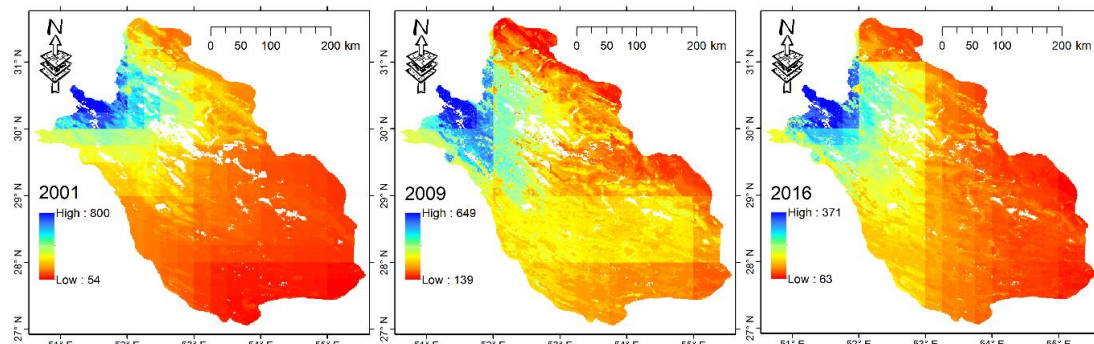
در هنگام برازش دادن مدل‌های یادگیری رگرسیونی با توجه به خطای مضاعفی که در به‌دست آوردن مدل‌ها




شکل ۶- مقدار میانگین R بین مقادیر بارندگی تخمین زده شده به‌وسیله ماهواره TRMM ($P_{3B43,LR}$) و روش‌های مختلف ریزمقیاس‌سازی ($P_{3B43,HR}$ ، $P_{3B43,HR'}$ ، $P_{3B43,HR''}$ ، $P_{3B43,HR',caIGDA}$ ، $P_{3B43,HR',caIGRA}$) با داده‌های بارندگی ایستگاه‌های اعتبارسنجی در ۱۹ مدل رگرسیونی برای سال ۲۰۰۱ الی ۲۰۱۷

شکل ۸، نشان می‌دهد که این چهار پیکسل در مرکز استان فارس دارای بیشترین مقدار باقی‌مانده در مدل رگرسیونی ترکیبی Boosted Trees (مدل ۱۴) بودند. این وضعیت به دلیل طبیعت دریاچه و جلبک‌های صورتی آن است که در تابستان به دلیل خشک‌تر شدن محدوده دریاچه مهارلو و انعکاس از سطح دریاچه این خطا اتفاق می‌افتد (Mahbod و همکاران، ۲۰۱۹). به‌غیر از آنچه برای منطقه مرکزی فارس بیان شد، به نظر نمی‌رسد که الگوی مکانی یا زمانی کاملاً مشخصی برای ε_{LR} وجود داشته باشد و به‌طور کلی مقدار آن در سطح استان زیاد نیست که با توجه به ضریب تعیین بالای مدل شماره ۱۴ (بیش از ۰/۸۰) نشان داده شد که واریانس تغییرات بارندگی ماهواره TRMM بر اساس عواملی که در مدل یادگیری رگرسیونی به‌کار گرفته شدند (شاخص پوشش گیاهی نرمال شده، مدل رقوم ارتفاعی، دمای سطح زمین و موقعیت جغرافیایی)، به خوبی

پیش‌بینی شده است. با میان‌یابی ε_{LR} به روش کریجینگ، نقشه ε_{HR} به‌دست آمد که برای سال‌های نمونه انتخابی در شکل نشان داده شده‌اند. با اصلاح نقشه‌های $P_{3B43,HR}$ با استفاده از ε_{HR} و ε_{LR} ، به ترتیب نقشه‌های $P_{3B43,HR'}$ و $P_{3B43,HR''}$ به‌دست آمدند که به ترتیب در شکل‌های ۱۰ و ۱۱ نشان داده شده‌اند. اگرچه قبلاً نشان داده شد که تفاوت معنی‌داری بین استفاده از مقدار باقی‌مانده ریزمقیاس‌سازی و درشت‌مقیاس در بهبود نتایج وجود نداشت، اما نقشه‌های $P_{3B43,HR'}$ دارای تغییرات مکانی ملایم‌تری بودند. در نهایت، با توجه به عملکرد بهتر واسنجی به روش فاصله‌اصلاحی، نقشه $P_{3B43,HR'}$ واسنجی شده و نتایج آن در شکل ۱۲ ارائه شد. در نتایج بررسی مدل‌های رگرسیونی مشاهده شد که واسنجی به‌طور معنی‌داری بر روی افزایش دقت ریزمقیاس‌سازی تأثیری نداشت.




شکل ۷- مقدار بارندگی ریزمقیاس‌سازی شده ($P_{3B43,HR}$) با استفاده از مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶



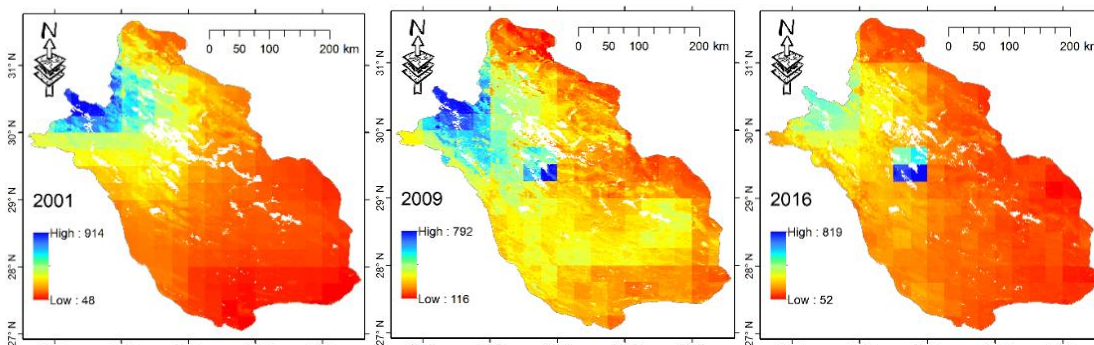
شکل ۸- مقدار باقی‌مانده رگرسیون با تفکیک مکانی ۲۵ کیلومتر (ϵ_{LR}) برای مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶

۲۰۱۶



شکل ۹- مقدار باقی‌مانده رگرسیون با تفکیک مکانی یک کیلومتر (ϵ_{LR}) برای مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶

۲۰۱۶

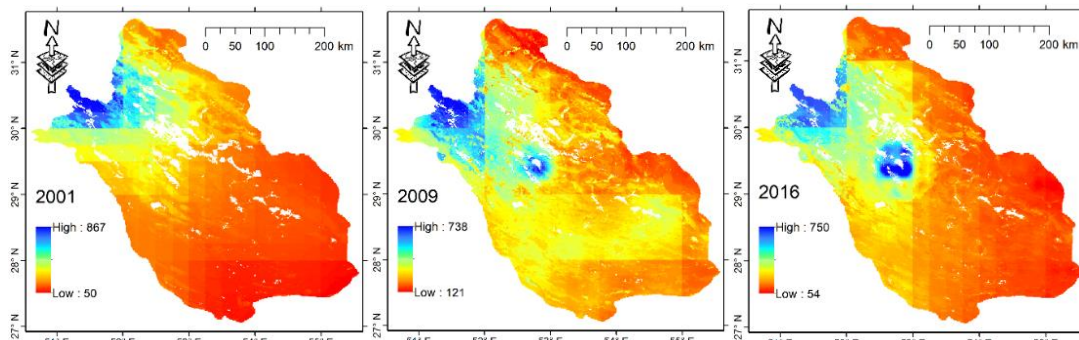


شکل ۱۰- مقدار بارندگی ریزمقیاس‌سازی شده و اصلاح شده با استفاده از باقی‌مانده ۲۵ کیلومتری ($P_{3B43,HR''}$) برای مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶

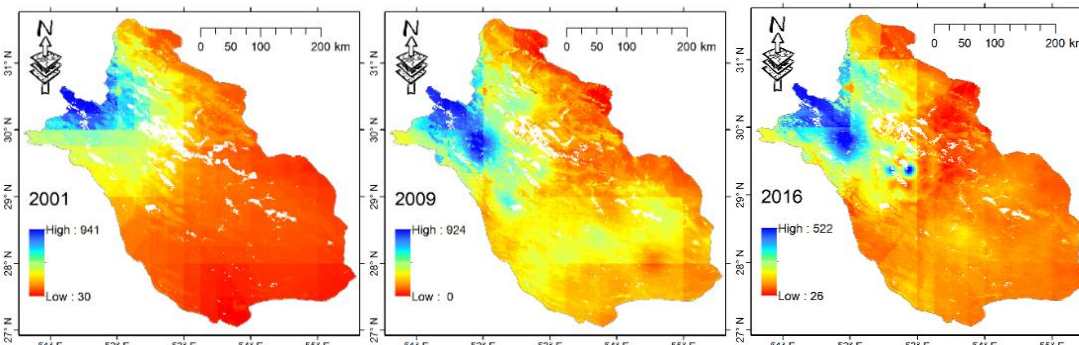
۲۰۱۶

به دست آمده در این محدوده وجود داشت، دقت نتایج حاصل از $P_{3B43,HR',calGDA}$ به مقدار قابل توجهی بهبود می‌یافت.

اما، در شکل ۱۲، مشاهده می‌شود که استفاده از واسنجی نتایج، مقدار بارندگی بیش برآورد شده را در چهار پیکسل مرکزی استان کاهش داده است و اگر ایستگاه‌های باران‌سنجی برای اعتبارسنجی نتایج



شکل ۱۱- مقدار بارندگی ریزمقیاس‌سازی شده و اصلاح شده با استفاده از باقی‌مانده یک کیلومتری ($P_{3B43,HR'}$) برای مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶



شکل ۱۲- مقدار بارندگی ریزمقیاس‌سازی شده و واسنجی شده با فاصله اصلاحی ($P_{3B43,HR',calGDA}$) برای مدل رگرسیونی شماره ۱۴ برای سال‌های ۲۰۰۱، ۲۰۰۹ و ۲۰۱۶

یادگیری رگرسیونی، باقی‌مانده ریزمقیاس‌سازی نشده و ریزمقیاس‌سازی شده، واسنجی شده به روش فاصله اصلاحی و واسنجی شده به روش نسبت اصلاحی ارزیابی شد. در آخر، نتایج حاصل با داده‌های ایستگاهی در منطقه فارس اعتبارسنجی شدند. به‌طورکلی، از بین مدل‌های یادگیری رگرسیونی استفاده شده، مدل‌های ترکیبی Ensemble Boosted Trees دارای کمترین مقدار RMSE برای واسنجی در فرایند ریزمقیاس‌سازی بودند که با استفاده از این روش، یادگیری ماشین تفکیک مکانی و دقت برآورد داده‌های بارندگی ماهواره TRMM افزایش یافت. بنابراین، مدل Ensemble Boosted Trees برای ریزمقیاس‌سازی داده‌های ماهواره TRMM در استان فارس پیشنهاد می‌شود. همچنین، میان‌یابی مقادیر

نتیجه‌گیری

استان فارس یکی از مناطق خشک و نیمه‌خشک کشور است که همواره در زمینه بررسی میزان بارندگی از نظر متخصصان بسیار حائز اهمیت بوده است. بنابراین، در پژوهش حاضر، تفکیک مکانی داده‌های بارندگی سالانه ماهواره TRMM با استفاده از داده‌های پوشش گیاهی NDVI و DEM، میانگین دمای روزانه، شبانه و اختلاف دمای شبانه‌روز از سطح زمین، مختصات طول و عرض و ارتفاع و کاربری اراضی از ۲۵ کیلومتر به یک کیلومتر ریزمقیاس‌سازی شد. برای این منظور، از جعبه ابزار یادگیری ماشین در برنامه MATLAB و ۱۹ مدل یادگیری ماشین، استفاده شد. در این مطالعه، بارندگی ریزمقیاس‌سازی شده در حالت‌های مختلف یعنی استفاده از تنها مدل‌های

داد. بنابراین، استفاده از روش نسبت اصلاحی در ریزمقیاس‌سازی بارندگی در استان فارس پیشنهاد نمی‌شود. همچنین، کاهش مقدار RMSE بین دو حالت استفاده از روش فاصله اصلاحی و عدم استفاده هر یک از روش‌های اصلاحی به‌طور متوسط یک میلی‌متر بود که بر اساس آن انجام روش‌های اصلاحی ضروری نیست.

باقی‌مانده در کاهش مقدار خطای ریزمقیاس‌سازی تأثیر معنی‌داری نداشت و به‌طور متوسط پنج میلی‌متر افزایش یافت. در نتیجه، در استان فارس ریزمقیاس‌سازی را بدون میان‌یابی مقادیر باقی‌مانده رگرسیونی می‌توان انجام داد. در بین دو روش فاصله اصلاحی و نسبت اصلاحی، روش نسبت اصلاحی به‌طور معنی‌داری خطای ریزمقیاس‌سازی را افزایش

منابع مورد استفاده

1. Alexakis, D.D. and I.K. Tsanis. 2016. Comparison of multiple linear regression and artificial neural network models for downscaling TRMM precipitation products using MODIS data. *Environmental Earth Sciences*, 75(14): 1-13.
2. Chen, C., S. Zhao, Z. Duan and Z. Qin. 2015. An improved spatial downscaling procedure for TRMM 3B43 precipitation product using geographically weighted regression. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(9): 4592-4604.
3. Duan, Z. and W. Bastiaanssen. 2013. First results from version 7 TRMM 3B43 precipitation product in Combination with a new downscaling-calibration procedure. *Remote Sensing of Environment*, 131: 1-13.
4. Funk, C., P. Peterson, M. Landsfeld, D. Pedreros, J. Verdin, J. Rowland, B. Remero, G. Husak, J. Michaelsen and A. Verdin. 2014. A quasi-global precipitation time series for drought monitoring. *U.S. Geological Survey Data Series*, 832(4): 1-12.
5. Huffman, G.L., D.T. Bolvin, E.J. Nelkin, D.B. Wolff, R.F. Adler, G. Gu, Y. Hong, K.P. Bowman and E.F. Stocker. 2007. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, 8(1): 38-55.
6. Huffman, G.L., R.F. Adler, D.T. Bolvin and G. Gu. 2009. Improving the global precipitation record: GPCP version 2.1. *Geophysical Research Letters*, 36(17): 1-5.
7. Huffman, G.L., R.F. Adler, P. Arkin, A. Chang, R. Ferraro, A. Gruber, J. Janowiak, A. McNab, B. Rudolf and U. Schneider. 1997. The Global Precipitation Climatology Project (GPCP) combined precipitation dataset. *Bulletin of the American Meteorological Society*, 78(1): 5-20.
8. Immerzeel, W., M. Rutten and P. Droogers. 2009. Spatial downscaling of TRMM precipitation using vegetative response on the Iberian Peninsula. *Remote Sensing of Environment*, 113(2): 362-370.
9. Jia, S., W. Zhu, A. Lu and T. Yan. 2011. A statistical spatial downscaling algorithm of TRMM precipitation based on NDVI and DEM in the Qaidam Basin of China. *Remote Sensing of Environment*, 115(12): 3069-3079.
10. Jing, W., Y. Yang, X. Yue and X. Zhao. 2016. A comparison of different regression algorithms for downscaling monthly satellite-based precipitation over North China. *Remote Sensing*, 8(10): 835-859.
11. Juang, K., D. Lee and C. Hsiao. 1998. Kriging with cumulative distribution function of order statistics for delineation of heavy-metal contaminated soils. *Soil Science*, 163: 797-804.
12. Katsanos, D., A. Retalis and S. Michaelides. 2016. Validation of a high resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. *Atmospheric Research*, 169: 459-464.
13. Kazemzadeh, M. and J. Akbari. 2020. Spatial resolution analysis of TRMM satellite images to estimate meteorological drought index, case study: Iran. *Watershed Engineering and Management*, 11(4): 903-916 (in Persian).
14. Kubota, T., S. Shige, H. Hashizume, K. Aonashi, N. Takahashi, S. Seto, M. Hirose, Y.N. Takayabu, T. Ushio and K. Nakagawa. 2007. Global precipitation map using satellite-borne microwave radiometers by the GSMaP project: production and validation. *IEEE Transactions on Geoscience and Remote Sensing*, 45(7): 2259-2275.
15. Kummerow, C., W. Barnes, T. Kozu, J. Shiue and J. Simpson. 1998. The Tropical Rainfall Measuring Mission (TRMM) sensor package. *Journal of Atmospheric and Oceanic Technology*, 15(3): 809-817.
16. Li, S., Z. Zhao, X. Miaomiao and Y. Wang. 2010. Investigating spatial non-stationary and scale-dependent relationships between urban surface temperature and environmental factors using geographically weighted regression. *Environmental Modelling and Software*, 25(12): 1789-1800.

17. Madadi, Gh., S. Hamzeh and A. Noroozi. 2017. Assessment of TRMM satellite imagery in temporal and spatial drought monitoring, case study: West Frontier Basin. *Watershed Engineering and Management*, 8(4): 362-376 (in Persian).
18. Mahbod, M., F. Veronesi and A. Shirvani. 2019. An evaluative study of TRMM precipitation estimates over multi-day scales in a semi-arid region, Iran. *International Journal of Remote Sensing*, 40(11): 4143-4174.
19. Miri, M., M. Rahimi and A. Noroozi. 2020. Evaluation and comparison of GPM and TRMM daily precipitation with observed precipitation across Iran. *Watershed Engineering and Management*, 11(4): 972-983 (in Persian).
20. Nichol, J. and S. Abbas. 2015. Integration of remote sensing datasets for local scale assessment and prediction of drought science of the total. *Environment*, 505: 503-507.
21. Shi, Y., L. Song, Z. Xia, Y. Hin, R. Myneni, S. Choi, L. Wang, X. Ni, C. Lao and F. Yang. 2015. Mapping annual precipitation across mainland China in the period 2001-2010 from TRMM 3B43 product using spatial downscaling approach. *Remote Sensing*, 7: 5849-5878.
22. Statistics and Machine Learning Toolbox-MATLAB, 2016. URL <https://www.mathworks.com/products/statistics.html> (accessed 3.14.20).
23. Teimory, M., Kh. Asadollah and M. Bakhtiarikia. 2019. Evaluation of remotely sensed precipitation data in runoff simulation for Kalam Basin, Hormozgan using SWAT. *Watershed Engineering and Management*, 11(3): 562-574 (in Persian).
24. Zanjani, B., H. Seyed Kaboli and M. Rashidian. 2019. Downscaling TRMM satellite-based precipitation data using non-stationary relationships between precipitation and land surface characteristics. *Journal of RS and GIS for Natural Resources*, 10(2): 85-101 (in Persian).
25. Zhang, T., B. Li, Y. Yuan, X. Gao, Q. Sun, L. Xu and Y. Jiang. 2018. Spatial downscaling of TRMM precipitation data considering the impacts of macro-geographical factors and local elevation in the Three-River Headwaters Region. *Remote Sensing of Environment*, 215: 109-119.