

پیش‌بینی میانگین بارش ماهانه در شمال غرب ایران با به‌کارگیری روش‌های یادگیری ماشین و دورپیوندها

مرتضی پاکدامن^{۱*}، ابراهیم فتاحی^۲ و زهره جوانشیری^۱

^۱ استادیار پژوهشگاه هواشناسی و علوم جو، تهران، ایران

^۲ دانشیار پژوهشگاه هواشناسی و علوم جو، تهران، ایران

(دریافت: ۱۴۰۲/۰۷/۱۷، پذیرش: ۱۴۰۲/۰۹/۲۵)

چکیده

در این مقاله با کمک چند روش یادگیری ماشین و استفاده از سه شاخص دورپیوند WP، NAO و Nino 3.4، میانگین بارش ماهانه منطقه‌ای در شمال غرب ایران شامل حوزه آبریز دریاچه ارومیه پیش‌بینی می‌شود. دلیل انتخاب این سه شاخص، مؤثر بودن آنها بر بارش منطقه مورد مطالعه در شمال غرب ایران است. برای این منظور دو روش مدل‌سازی ماهانه و فصلی با یکدیگر مقایسه می‌شوند. از آنجاکه شاخص‌های دورپیوند ممکن است با تأخیر بر بارش مؤثر باشند، تأخیرهای مختلف صفر تا سه ماهه برای هر سه شاخص مورد مطالعه لحاظ و بهترین نتیجه استخراج شد. در این پژوهش از سه روش یادگیری ماشین جنگل تصادفی، شبکه عصبی و گرادیان تقویتی استفاده شد. در حالت ماهانه، عملکرد روش گرادیان تقویتی (با سه ماه تأخیر برای شاخص WP و دو شاخص دیگر بدون تأخیر) بهتر از روش جنگل تصادفی بود و شبکه عصبی در جایگاه آخر عملکرد قرار گرفت. از نظر تخمین بارش‌های حدی نیز روش گرادیان تقویتی عملکردی پذیرفتنی دارد. در مدل‌سازی فصلی، برای سه فصل بهار (مارس - آوریل - مه)، پاییز (سپتامبر - اکتبر - نوامبر) و زمستان (دسامبر - ژانویه - فوریه)، عملکرد جنگل تصادفی و برای فصل تابستان (ژوئن - ژوئیه - اوت)، عملکرد روش تقویت گرادیان نسبت به سایر روش‌ها برتری داشت.

کلمه‌های کلیدی: بارش، دورپیوند، یادگیری ماشین، جنگل تصادفی، شبکه عصبی، گرادیان تقویتی

۱ مقدمه

پیش‌بینی بارش ماهانه و فصلی هم از منظر آب‌شناسی برای تأمین منابع آب و هم از دیدگاه اقلیم‌شناسی و مخاطرات جوّی بسیار حائز اهمیت است. پیش‌بینی‌های ماهانه و فصلی به‌صورت گسترده در بخش‌هایی نظیر انرژی و کشاورزی استفاده می‌شوند. از سوی دیگر، ثابت شده است که دورپیوندها و شاخص‌های بزرگ‌مقیاس جوّی بر شرایط جوّی بخش‌های مختلف زمین اثرگذار هستند. احمدی و همکاران (۲۰۲۲) از پنجاه و دو شاخص دورپیوند برای تحلیل‌های آماری و مدل‌سازی مفهومی و همچنین شبیه‌سازی نوسانات دما و بارش در ایران استفاده کردند. طبق یافته‌های آن مطالعه، بیشتر این شاخص‌ها به میزان متفاوتی در نوسانات بارشی و دمایی ایران مؤثر بوده‌اند. هلالی و همکاران (۱۴۰۰) ارتباط بین چندین شاخص دورپیوند و بارش‌های فصل بهار را در حوضه‌های آبریز ایران بررسی و امکان استفاده از آنها را به‌عنوان متغیرهای پیش‌بینی‌کننده ارزیابی کردند. آنها همبستگی چهل شاخص دورپیوند با فرکانس‌های مختلف را با بارش فصل بهار بررسی کردند. نتایج نشان داد درصد ایستگاه‌هایی که همبستگی بارش فصل بهار آنها با شاخص‌های دورپیوند معنادار است، بسته به حوضه آبریز متغیر است. به‌طور کلی، شاخص‌های مرتبط با ENSO و SST بیشترین فراوانی همبستگی‌های معنادار را با بارش بهار در نیمه شمالی، شمال غربی، شمال شرقی و گاهی جنوب غربی دارند. این شاخص‌ها بیشترین مقدار را در حوضه دریای خزر در تأخیر سه تا شش ماهه، در خلیج فارس - دریای عمان در تأخیر یک تا سه ماهه، در دریاچه ارومیه در تأخیر سه ماهه، در فلات مرکزی در تأخیر یک تا چهار ماهه، در مرز شرقی در تأخیر یک و شش ماهه و در حوزه قره‌قوم در تأخیر یک و سه ماهه دارند. آنها به این نتیجه رسیدند که بارش فصل بهار در بسیاری از ایستگاه‌های واقع در حوضه‌های آبریز نیمه شمالی ایران با شاخص‌های دورپیوند همبستگی معنادار

دارد، درحالی‌که کمترین همبستگی را در بخش جنوبی، فلات مرکزی و بخش شرقی دارد که این موضوع به دلیل بارش کم در مناطق جنوبی در این فصل است. امینی و همکاران (۲۰۲۰) از مدل واپازش چندک بیزی (Bayesian quantile regression) برای بررسی ارتباط بین شاخص‌های بزرگ اقیانوسی - جوّی و شاخص بارش استاندارد شده خشکسالی (SPI) در ایران استفاده کردند. آنها از سه شاخص اقیانوسی - اتمسفر، نوسان اقیانوس اطلس شمالی (NAO)، شاخص نوسان جنوبی (SOI) و شاخص چندمتغیره ال‌نینو/نوسان جنوبی (MEI) به‌عنوان متغیرهای کمکی استفاده کردند. نتایج نشان داد که NAO ضعیف‌ترین تأثیر را بر خشکسالی در کمیت‌ها و مناطق مختلف ایران دارد. شرایط لائینا خشکسالی را در تمام چندک‌های SPI در مناطق غربی، ساحلی دریای خزر و جنوبی تقویت می‌کند. فاز مثبت MEI به‌طور چشمگیری چندک‌های SPI پایین (شرایط خشکسالی) را در سراسر منطقه زاگرس، مناطق ساحلی دریای خزر و مناطق جنوبی تعدیل می‌کند. این مطالعه نشان داد شاخص‌های بزرگ اقیانوسی - جوّی تأثیرات ناهمگنی بر شرایط خشک و مرطوب دارند.

برای پیش‌بینی پارامترهای مختلف جوّی از روش‌های یادگیری ماشین به‌صورت گسترده استفاده می‌شود. دلیل استفاده از این روش‌ها، توانایی زیاد مدل‌سازی این الگوریتم‌ها در مواجهه با حجم زیاد داده است. درعین حال این الگوریتم‌ها توانایی‌های زیاد دیگری نیز دارند نظیر توانایی مدل‌سازی عدم قطعیت. پاکدامن و همکاران (۲۰۲۰) به‌منظور پیش‌بینی ماهانه بارش در ایران از شبکه‌های عصبی مصنوعی برای پس‌پردازش خروجی مدل‌های همادی آمریکای شمالی استفاده کردند. شرفی و همکاران (۱۳۹۹) از دو مدل هوشمند برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان برای پیش‌بینی بارش ماهانه استان اردبیل استفاده کردند. در آن مطالعه پارامترهای ورودی

اقليمی، که داده‌هایشان از مراکز اقليمي اروپایی صادر می‌شود، به‌عنوان ورودی استفاده کردند. طبق نتایج، عملکرد شبکه عصبی و جنگل تصادفی در مقایسه با درخت تصمیم و ماشین بردار پشتیبان بهتر بود. از سوی دیگر، جوانشیری و همکاران (۲۰۲۳) با استفاده از تبدیل موجک، به بررسی روابط بین بیست دورپیوند و تغییرپذیری بارش طی سال‌های ۱۹۶۰ تا ۲۰۱۸ در ایران پرداختند. آنها نشان دادند دورپیوندهای مختلف بررسی‌شده بر بارش مناطق مختلف ایران مؤثر هستند؛ لذا در مقاله حاضر با در نظر گرفتن مقدار سه شاخص و به کمک سه روش یادگیری ماشین جنگل تصادفی، شبکه عصبی و گرادیان تقویتی به پیش‌بینی بارش ماهانه منطقه خواهیم پرداخت. برای این منظور، دو روش مدل‌سازی ماهانه و فصلی مقایسه می‌شود. از آنجا که شاخص‌های دورپیوند ممکن است با تأخیر بر بارش مؤثر باشند، تأخیرهای مختلف صفر تا سه ماهه برای هر سه شاخص مورد مطالعه لحاظ و بهترین نتیجه استخراج می‌شود. بخش دوم مقاله شامل معرفی مواد، روش‌ها، ناحیه مورد مطالعه و داده‌های استفاده‌شده است. بخش سوم، نتایج اجرای الگوریتم‌ها را برای دو حالت ماهانه و فصلی نشان خواهد داد و در نهایت، بخش چهارم شامل بحث و نتیجه‌گیری است.

۲ مواد و روش‌ها

۲-۱ منطقه مورد مطالعه و داده‌ها


ایران به علت پانزده درجه اختلاف عرض جغرافیایی موجود بین جنوبی‌ترین و شمالی‌ترین نقطه آن و همچنین به علت چین‌خوردگی‌ها و پستی‌وبلندی‌های زیادی که در سطح آن به چشم می‌خورد، اقلیم‌های مختلفی دارد و به بیست و چهار ناحیه اقليمي بارش-دما می‌تواند تقسیم شود. از لحاظ رطوبت، بیشتر مساحت کشور در مناطق نیمه‌خشک و خشک قرار دارد (اسدی اسکوتی و همکاران، ۲۰۲۲). منطقه مطالعه‌شده در این پژوهش (شکل ۱)، در شمال

مدل‌ها شامل داده‌های بارش، دما و رطوبت نسبی در مقیاس ماهانه بود. نتایج نشان داد عملکرد مدل وایزش بردار پشتیبان بهتر بوده است. بامری و خالقی (۱۴۰۱) شش مدل مختلف یادگیری ماشین شامل شبکه عصبی مصنوعی، درخت تصمیم، کیوبست، جنگل تصادفی، ماشین بردار پشتیبان و وایزش خطی را برای مدل‌سازی روزانه دمای خاک در شش عمق مختلف در کرمان به کار گرفتند. آنها از داده‌های هواشناسی دمای بیشینه و کمینه، رطوبت نسبی، نقطه شبنم، تبخیر-تعرق و فشار جو به‌عنوان ورودی برای یک دوره هجده ساله استفاده کردند. نتایج نشان‌دهنده برتری شبکه عصبی، جنگل تصادفی و ماشین بردار پشتیبان بود. پاکدامن و همکاران (۲۰۲۲ الف) به‌منظور ارائه روش چندمدلی پیش‌بینی بارش ماهانه در جنوب غربی آسیا یک رویکرد یادگیری مبتنی بر شبکه عصبی مصنوعی (Artificial Neural Network, ANN) و الگوریتم‌های جنگل تصادفی (Random Forest, RF) برای پس‌پردازش خروجی مدل‌های پیش‌بینی اقليمي ارائه کردند. ایشان چهار مدل پیش‌بینی شامل GEM-NEMO، NASA-COLA-RSMAS-CCSM4 و CanCM4i، GEOS2S را که در پروژه گروه مدل‌های همادی آمریکای شمالی (NMME) گنجانده شده‌اند، برای ورودی الگوریتم‌های یادگیری در نظر گرفتند. از آنجایی که هر مدل نه زمان مختلف دارد، در مجموع صد و هشت مدل ANN و RF مختلف برای هر ماه از سال آموزش داده شد. برای آموزش مدل‌های ANN و RF پیشنهادی، از مجموعه داده‌های بازتحلیل ERA5 استفاده شد. نتایج نشان داد عملکرد پس-پردازش ANN و RF بهتر از مدل‌های NMME منفرد است. علاوه‌براین، RF در تمام زمان‌ها و ماه‌های سال از ANN بهتر عمل کرد. همچنین پاکدامن و همکاران (۲۰۲۲ ب) چندین روش یادگیری ماشین شامل ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی و شبکه عصبی را برای پیش‌بینی ماهانه بارش به کار گرفتند. آنها از چهار مدل

پیشین، سه روش مهم جنگل تصادفی (RF)، شبکه عصبی مصنوعی (ANN) و تقویت گرادیان (Gradient Boosting, GB) ارزیابی می‌شود. روش‌های یادگیری ماشین را می‌توان به دو دسته روش‌های انفرادی (مانند روش‌های درخت تصمیم، ماشین بردار پشتیبان و K-نزدیک‌ترین همسایه) و گروهی (مانند جنگل تصادفی و تقویت گرادیان) تقسیم کرد. روش‌های انفرادی الگوریتم‌های پایه هستند و ممکن است برای مسائل پیچیده و حجم داده زیاد عملکرد مناسبی نداشته باشند. اغلب به کمک برخی رویکردها در یادگیری گروهی، الگوریتم‌های پایه توسعه داده می‌شوند تا عملکرد مناسب‌تری داشته باشند. در این مقاله، با توجه به اهمیت و توانایی زیاد روش‌های یادگیری گروهی، از دو روش RF و GB و در میان الگوریتم‌های پایه نیز از روش ANN به واسطه توانایی زیاد و گستردگی به کارگیری آن در گذشته استفاده می‌شود.

شبکه‌های عصبی مصنوعی یکی از مهم‌ترین الگوریتم‌های یادگیری ماشین هستند که علاوه بر تنوع، در مسائل متفاوت وایزش و طبقه‌بندی نیز استفاده می‌شوند. شکل ۲ معماری کلی یک شبکه عصبی چندلایه را نشان می‌دهد. در این شکل، هر گره نشان‌دهنده یک عصب (neuron) شبکه است که تابع فعالیت خاص خود است. با اعمال شبکه عصبی بر داده‌های آموزش، از الگوریتم‌های یادگیری که اغلب روش‌های ریاضی بهینه‌سازی هستند، برای آموزش شبکه استفاده می‌شود. برای هر شبکه عصبی چندلایه به شکل ۲، لازم است پارامترهای متعدد شبکه با هدف تعیین بهترین معماری متناسب با داده‌ها تنظیم شوند. به عمل یافتن بهترین مقادیر پارامترهای شبکه، بهینه‌سازی پارامتر گفته می‌شود. تعداد لایه‌های مناسب شبکه عصبی، تعداد عصب در هر لایه شبکه، نوع تابع فعالیت عصب‌ها در لایه‌ها، نوع الگوریتم بهینه‌سازی و یادگیری شبکه از مهم‌ترین پارامترهایی هستند که باید مشخص شوند.

غرب ایران و در حوزه آبریز دریاچه ارومیه واقع شده است. این منطقه به طول جغرافیایی ۴۴/۶۹ تا ۴۷/۵۳ درجه و عرض جغرافیایی ۳۵/۷۳ تا ۳۸/۵۵ درجه محدود است. در این منطقه تعداد چهار و یک ایستگاه شامل بیست و هشت ایستگاه باران‌سنجی، دو ایستگاه اقلیم‌شناسی و یازده ایستگاه همدید قرار گرفته‌اند. شایان ذکر است در این مقاله از داده‌های همگن شده ایستگاه‌ها (جوانشیری و همکاران، ۲۰۲۱) استفاده و میانگین وزنی به روش تیسن (Thiessen) (برای مثال بایراکتار و همکاران، ۲۰۰۵) برای داده‌های بارش منطقه به صورت ماهانه محاسبه شده است.



شکل ۱. نقشه منطقه مورد مطالعه و موقعیت ایستگاه‌های هواشناسی.

بازه زمانی مورد مطالعه داده‌های ماهانه از جولای ۱۹۹۱ تا دسامبر ۲۰۲۰ یعنی حدود سی سال است. دلیل انتخاب این منطقه، اهمیت زیست‌محیطی آن و واقع شدن دریاچه ارومیه در منطقه است. از سوی دیگر، طبق مطالعات هلالی و همکاران (۱۴۰۰)، بارش نیمه شمالی کشور بیشتر تحت تأثیر دورپیوندهاست.

۲-۲ الگوریتم‌های مورد استفاده

روش‌های متعدد یادگیری ماشین برای مسائل وایزش پیشنهاد شده است، اما در این مقاله با توجه به مطالعات

انتخاب فضای ویژگی تصادفی در ساخت مجموعه یادگیری برای افزایش تنوع الگوریتم پایه بهره می‌برد. الگوریتم جنگل تصادفی چندین درخت تصمیم را با کمک رویه فوق می‌سازد و با توجه به معیار حداکثر رأی، نتایج پیش‌بینی این درختان را ترکیب می‌کند (اگراوال، ۲۰۱۵).

در مقابل روش‌های گروهی مبتنی بر BAGGING، روش‌های گروهی متعدد مبتنی بر تقویت (BOOSTING)

نیز وجود دارند. یکی از مهم‌ترین این الگوریتم‌ها، روش تقویت گرادیان (GB) است. این مدل ترکیبی خطی شامل مجموعه‌ای از مدل‌های پایه است که به صورت تناوبی برای ایجاد یک مدل نهایی قوی ساخته شده است، به طوری که یک مدل پیش‌بینی را در قالب مجموعه‌ای از مدل‌های پیش‌بینی گروهی ضعیف ارائه می‌دهد که معمولاً درخت‌های تصمیم هستند (هستی و همکاران، ۲۰۰۹).

هنگامی که یک درخت تصمیم یادگیرنده ضعیف باشد، الگوریتم حاصل، درخت تصمیم تقویت گرادیان (Gradient Boosted Decision Tree) نامیده می‌شود که معمولاً در مقایسه با جنگل تصادفی عملکرد بهتری دارد (پیریونسی و الدیرابی، ۲۰۲۱). مدل درخت تقویت گرادیان، مانند سایر روش‌های تقویتی به صورت مرحله‌ای ساخته می‌شود، درحالی‌که سایر روش‌ها با بهینه‌سازی یک تابع هزینه مشتق‌پذیر دلخواه تعمیم داده می‌شوند. ایده روش تقویت گرادیان از مشاهدات بریمن (۲۰۰۱) سرچشمه گرفته است که بر اساس آن، تقویت (BOOSTING) را


می‌توان به‌عنوان یک الگوریتم بهینه‌سازی برای تابع هزینه مناسب تفسیر کرد (بریمن، ۲۰۰۱). پس از آن فریدمن (۱۹۹۹) الگوریتم‌های تقویت گرادیان وایزش صریح را هم‌زمان با دیدگاه کلی‌تر روش تقویت گرادیان تابعی ماسون و همکاران (۱۹۹۹) توسعه داد. در دو پژوهش یادشده، دیدگاه الگوریتم‌های تقویتی به‌عنوان الگوریتم‌های کاهش گرادیان تابعی تکراری معرفی شد؛ به این معنا که الگوریتم‌ها با انتخاب مکرر یک تابع (فرضیه

الگوریتم‌های یادگیری نیز پارامترهایی تنظیم‌شونده دارند (پاکدامن، ۱۴۰۱)؛ برای مثال در معماری شبکه‌های عصبی از توابع سیگموئید (رابطه ۱) و تابع واحد یک‌سوشده خطی (Rectified Linear Unit, RELU) (رابطه ۲) به صورت گسترده استفاده می‌شود:

$$S(X) = \frac{1}{1 + e^{-X}} \quad (1)$$

$$R(X) = \max(0, X) \quad (2)$$

برای بهینه‌سازی پارامترهای شبکه و یافتن معماری بهینه روش‌های متعددی وجود دارد که اغلب مبتنی بر جستجو هستند. در برخی بسته‌های نرم‌افزاری به‌خصوص در زبان برنامه‌نویسی پایتون، توابعی از پیش تعریف شده وجود دارند که عمل بهینه‌سازی پارامترها را انجام می‌دهند. به‌هرحال تجربه کاربر استفاده‌کننده در کاربردهای خاص نیز بسیار راهگشاست.



شکل ۲. شکل کلی یک شبکه عصبی چندلایه.

در روش‌های یادگیری گروهی، به جای استفاده از یک روش به‌تنهایی، نتایج چندین روش با هم ترکیب می‌شوند. جنگل تصادفی را که می‌توان نوعی الگوریتم یادگیری گروهی دانست، از مراحل اصلی BAGGING (مخفف Bootstrap Aggregating) تبعیت و برای ساخت الگوریتم پایه از الگوریتم درخت تصمیم استفاده می‌کند. علاوه بر اینکه در BAGGING از نمونه‌گیری بوت‌استرپ و رأی‌دهی به اکثریت استفاده می‌شود، جنگل تصادفی از

ضعیف) در جهت گرادیان منفی، یک تابع هزینه را در فضای تابعی بهینه می‌کنند. دیدگاه تقویت گرادیان تابعی سبب توسعه الگوریتم‌های تقویت در بسیاری از حوزه‌های یادگیری ماشین و آمار، فراتر از وایزش و طبقه‌بندی شده است.

۲-۳ اجرای الگوریتم‌ها

در این مقاله از زبان برنامه‌نویسی پایتون و کتابخانه scikit-learn برای اجرای الگوریتم‌های یادگیری، تنظیم پارامترهای آنها و تقسیم داده‌ها به داده آزمون و آموزش استفاده شده است. کتابخانه scikit-learn برای نرمال‌سازی داده‌ها نیز توابع آماده‌ای دارد که در این مقاله از آنها بهره‌گیری شده است. جهت آموزش روش‌های یادگیری ماشین، از ۷۵ درصد داده‌ها و برای آزمون نیز از ۲۵ درصد داده‌ها استفاده شده است. گفتنی است تقسیم داده‌ها به دو بخش آزمون و آموزش به صورت تصادفی انجام شده است. همچنین برای افزایش دقت و جلوگیری از بیش‌برازش، روش اعتبارسنجی متقاطع به کار رفته است. برای این منظور داده‌های آموزش به ده بخش تقسیم و هر بار از یک بخش برای آزمون و از نه بخش دیگر برای آموزش مدل‌ها استفاده شده است.

برای تنظیم پارامترهای شبکه عصبی، به ترتیب شبکه‌های تک‌لایه، دولایه و سه‌لایه آزمایش شد. برای هر شبکه نیز پارامترهایی نظیر نوع الگوریتم آموزش (Adam, lbfgs)، تعداد عصب در هر لایه (بین ۵ تا ۲۰ تا با طول گام پنج‌تایی) و نوع تابع فعالیت (ReLU-logistic) آزمایش شد. برای بررسی حالت‌های مختلف از تابع GridSearchCV استفاده شد که در کتابخانه scikit-learn قرار دارد. این تابع بهترین ترکیب را با توجه به حالت‌های مختلف معماری پیشنهادی کاربر انتخاب می‌کند. بهترین نتیجه را معماری شبکه عصبی با تعداد ۱۷ عصب در لایه اول و ۵ عصب در لایه دوم مخفی، تابع فعالیت logistic و الگوریتم آموزش lbfgs

ارائه کرد.

برای اجرای روش‌های RF و GB از کتابخانه scikit-learn استفاده شد. برای این منظور توابع Random ForestRegressor و GradientBoostingRegressor از این کتابخانه فراخوانی شدند. از آنجا که روش‌های RF و GB روش‌هایی گروهی هستند، باید تعداد الگوریتم‌های پایه (n_estimators) مورد استفاده مشخص شوند. در نرم‌افزار تعداد این تخمینگرها ۱۰۰ در نظر گرفته شده است. در این مقاله تعداد ۵۰ تا ۲۰۰ تخمینگر با طول گام ۱۰، آزمایش و بهترین نتیجه گزارش شد. سایر پارامترها در سطح پیش‌فرض لحاظ شدند. در این راستا بهترین تعداد تخمینگر برای RF و GB به ترتیب ۱۱۰ و ۹۰ به دست آمد.

۳ نتایج

در این بخش، با هدف ارائه پیش‌بینی‌هایی با افق زمانی متفاوت، دو روش پیش‌بینی ماهانه و فصلی ارزیابی می‌شوند. گفتنی است برای هر یک از این دو افق زمانی، اثر سه شاخص دورپیوند به صورت جداگانه بررسی می‌شود و هر سه مدل RF، ANN و GB ارزیابی می‌شوند. علاوه بر این، از آنجا که شاخص‌های دورپیوند ممکن است با تأخیرهای زمانی مختلف بر بارش منطقه مورد مطالعه اثرگذار باشند، چهار تأخیر صفر، یک، دو و سه ماهه برای ورودی الگوریتم‌ها بررسی می‌شود. با توجه به وجود سه شاخص و برای هر یک چهار حالت تأخیری مختلف، در مجموع برای هر الگوریتم ۴۳ یعنی ۶۴ مدل متفاوت ساخته و بهترین نتیجه گزارش می‌شود. دلیل انتخاب تأخیرهای حداکثر سه ماهه این است که با افزایش ماه‌های تأخیر، تعداد مدل‌های آزمایش شده نیز به شدت افزایش می‌یابد؛ برای مثال برای تأخیرهای تا چهار ماه با توجه به وجود سه دورپیوند، تعداد مدل‌های آزمایش شده ۵۲ یعنی ۱۲۵ حالت مختلف برای هر الگوریتم خواهد بود. با در نظر گرفتن سه الگوریتم مختلف، این عدد برای تعداد اجرای آموزش مدل‌ها، سه برابر می‌شود.

و مشاهدات هستند و n تعداد کل داده‌ها است.

۲-۳ روش تک‌مدل ماهانه

در این بخش برای تمام داده‌ها در تمام ماه‌های سال، از یک مدل استفاده می‌شود. همچنین برای هر یک از شاخص‌های NAO، Nino 3.4 و WP تأخیرهای صفر ماه، یک ماه، دو ماه و سه ماه در نظر گرفته می‌شود. سپس مدل‌های مختلف برای تمام حالت‌های مختلف آموزش داده می‌شوند و بهترین مدل و بهترین زمان‌های تأخیر انتخاب می‌شوند. با توجه به اینکه برای هر یک از سه شاخص مذکور چهار حالت مختلف تأخیر لحاظ می‌شود، در مجموع ۶۴ حالت مختلف برای ورودی سه مدل یادگیری ماشین وجود خواهد داشت. نظر به زیاد بودن تعداد مدل‌ها، عملکرد هر سه روش یادگیری ماشین برای بهترین ورودی ارائه می‌شود.

عملکرد کلی الگوریتم‌ها برای داده‌های آزمایش در جدول ۱ آمده است. در این جدول ملاحظه می‌شود که بهترین نتیجه مربوط به روش تقویت گرادیان است که ورودی‌های آن مقادیر هم‌زمان شاخص‌های Nino 3.4 و NAO بدون تأخیر و شاخص WP با سه ماه تأخیر است. گفتنی است برای هر یک از سه روش جنگل تصادفی، تقویت گرادیان و شبکه عصبی، ۶۴ حالت مختلف ورودی‌ها آزمایش و بهترین نتیجه در جدول ۱ ارائه شده است.

جدول ۱. نتایج ارزیابی اجرای الگوریتم‌ها روی داده‌های آموزش و آزمون برای حالت تک‌مدل ماهانه.

		داده‌های آزمون			داده‌های آموزش		
		RF	GB	ANN	RF	GB	ANN
Cor		۰/۷۴۸	۰/۸۳۵	۰/۶۹۸	۰/۸۹۷	۰/۹۰۱	۰/۸۶۶
RMSE(mm)		۱۹/۹۳۳	۱۶/۹۷۰	۲۱/۶۶۵	۱۵/۱۰۶	۱۴/۱۶۵	۱۹/۷۸۴
NSE		۰/۵۴۳	۰/۶۸۱	۰/۴۶۲	۰/۷۹۱	۰/۸۰۱	۰/۶۵۱
میزان تأخیر (ماه)	Nino 3.4	یک	صفر	دو	یک	صفر	دو
	NAO	صفر	صفر	دو	صفر	صفر	دو
	WP	صفر	سه	یک	صفر	سه	یک

۱-۳ شاخص‌های ارزیابی عملکرد

شاخص‌های زیادی برای ارزیابی عملکرد الگوریتم‌ها وجود دارد، اما در این مقاله از سه شاخص ریشه میانگین مربعات (Root Mean Square Error, RMSE)، ضریب همبستگی (Correlation Coefficient, Cor) و نش-ساتکلیف (Nash-Sutcliffe Efficiency, NSE) استفاده می‌شود. این شاخص‌ها در ادامه معرفی می‌شوند. شاخص ریشه میانگین مربعات از رابطه زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - O_i)^2}{n}} \quad (۳)$$

شاخص ضریب همبستگی به کمک رابطه (۴) محاسبه می‌شود:

$$Cor = \frac{\sum_{i=1}^n (X_i - \bar{X})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (۴)$$

ضریب همبستگی عددی بین -1 و 1 است ($-1 \leq Cor \leq 1$). عدد 1 همبستگی مستقیم کامل و عدد -1 همبستگی معکوس کامل را نشان می‌دهد.

شاخص نش-ساتکلیف ($NSE \leq 1$) از رابطه (۵) محاسبه می‌شود (نش و ساتکلیف، ۱۹۷۰):


$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - X_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۵)$$

در شاخص NSE مقدار یک نشان‌دهنده بهترین عملکرد است.


در روابط (۳) تا (۵)، X و O به ترتیب معرف مقادیر مدل

مشخص می‌شود. در این شکل ملاحظه می‌شود که عملکرد روش جنگل تصادفی مناسب است، اما در تخمین بارش‌های حدی تا حدودی ناتوان بوده و این بارش‌ها را کم برآورد کرده است. در شکل ۴ دیده می‌شود که روش تقویت گرادیان تا حد بسیار زیادی بهتر توانسته است بارش‌های حدی را در مقایسه با جنگل تصادفی تخمین بزند؛ لذا علاوه بر نتایج ارزیابی عملکرد روش‌ها در جدول ۱، ملاحظه می‌شود که روش تقویت گرادیان هم از نظر شاخص‌های ارزیابی عملکرد و هم از نظر تخمین بارش‌های حدی عملکرد مناسب‌تری در مقایسه با سایر روش‌ها دارد.


با توجه به جدول ۱ بهترین عملکرد روش تقویت گرادیان بین ۶۴ حالت مختلف ورودی‌ها زمانی اتفاق می‌افتد که شاخص WP با تأخیر سه ماهه در نظر گرفته شود و دو شاخص Nino 3.4 و NAO نیز به صورت هم‌زمان (بدون تأخیر) باشند. پس از روش تقویت گرادیان، روش جنگل تصادفی در رتبه بعدی دقت قرار می‌گیرد. این برتری در هر سه شاخص ارزیابی دیده می‌شود. برای مقایسه مقادیر تخمینی به کمک روش جنگل تصادفی و روش تقویت گرادیان با مقادیر واقعی، شکل‌های ۳ و ۴ را ببینید. توانایی تقریب جنگل تصادفی با توجه به شکل ۳



شکل ۳. مقایسه میزان بارش تخمینی جنگل تصادفی (RF) و مقدار بارش واقعی (y) طی کل دوره مورد مطالعه.



شکل ۴. مقایسه میزان بارش تخمینی گرادیان تقویت (GB) و مقدار بارش واقعی (y) در کل دوره مورد مطالعه.

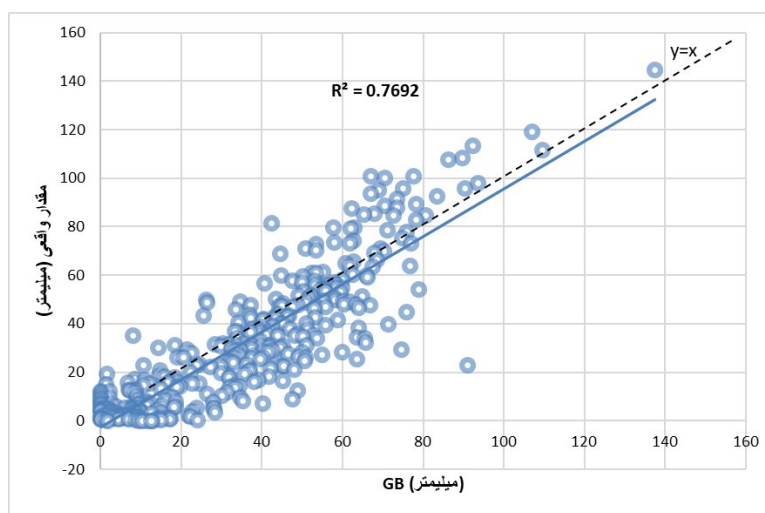


شکل ۵. مقایسه میزان بارش تخمینی شبکه عصبی (MLP) و مقدار بارش واقعی (y) در کل دوره مورد مطالعه.

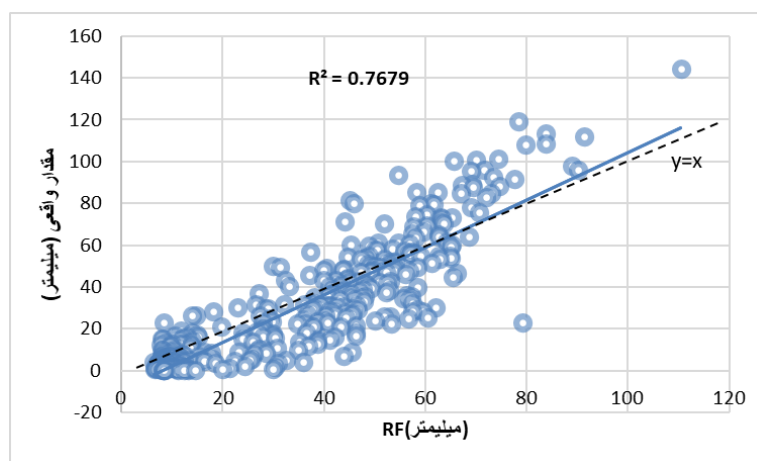
ذکر است که در بسته نرم‌افزاری این اهمیت ویژگی‌ها به‌صورت خودکار پس از آموزش مدل تولید می‌شود. اهمیت ویژگی‌های شاخص WP با تأخیر سه ماهه، Nino 3.4 بدون تأخیر و NAO بدون تأخیر به ترتیب برابر ۰/۳۲، ۰/۲۷ و ۰/۴۱ بود؛ بنابراین ترتیب اهمیت شاخص‌ها از بیشترین تا کمترین عبارت است از: شاخص NAO بدون تأخیر؛ WP با تأخیر سه ماهه؛ Nino 3.4 بدون تأخیر. به عبارت دیگر، در بین سه شاخص مذکور بیشترین اهمیت در پیش‌بینی بارش مربوط به شاخص NAO بدون تأخیر بوده است.

شکل ۵ خروجی روش شبکه عصبی را نشان می‌دهد. مشاهده می‌شود این روش در مقایسه با روش‌های جنگل تصادفی و تقویت گرادیان عملکرد ضعیف‌تری دارد. برای نمایش بهتر و مقایسه توانایی دو روش جنگل تصادفی و تقویت گرادیان، در شکل ۶ نمودار پراکنش مقادیر تخمینی دو الگوریتم در مقابل مقادیر مشاهداتی نشان داده شده است.

در روش تقویت گرادیان که بهترین ارزیابی را در میان حالت‌های مختلف و روش‌های دیگر داشت، اهمیت ویژگی‌ها (feature importance) نیز محاسبه شد. شایان



(الف)



(ب)

شکل ۶. نمودار پراکنش خروجی (الف) روش تقویت گرادیان (ب) روش جنگل تصادفی در مقابل داده واقعی برای پیش‌بینی ماهانه و برای تمام داده‌ها.

۳-۳ روش مدل‌های فصلی

در این بخش نیز همانند بخش قبل همه ۶۴ حالت ممکن تأخیر برای سه شاخص لحاظ می‌شود با این تفاوت که به جای ارائه یک مدل واحد برای همه ماه‌ها، برای هر فصل یک مدل ارائه می‌شود؛ لذا ابتدا لازم است داده‌های مربوط به فصل‌های بهار (مارس- آوریل- مه) (MAM)، پاییز


(سپتامبر- اکتبر- نوامبر) (SON)، زمستان (دسامبر- ژانویه- فوریه) (DJF) و تابستان (ژوئن- ژوئیه- اوت) (JJA)، از داده‌های اصلی استخراج و مدل‌های مختلف با تأخیرهای متفاوت برای هر فصل آزمایش شوند. برای این منظور هر سه روش GB، RF و ANN ارزیابی و نتایج ارزیابی‌ها در جدول ۲ گردآوری شد.

جدول ۲. ارزیابی مدل‌ها به صورت فصلی برای فصل‌های بهار (MAM)، تابستان (JJA)، پاییز (SON) و زمستان (DJF).

فصل	MAM			JJA			SON			DJF		
	RF	GB	ANN	RF	GB	ANN	RF	GB	ANN	RF	GB	ANN
مدل												
Cor	۰/۸۵	۰/۶۹	۰/۳۹	۰/۹۳	۰/۹۲	۰/۷۸	۰/۹۲	۰/۸۸	۰/۷۷	۰/۸۵	۰/۸۲	۰/۵۸
RMSE(mm)	۱۳/۲۰	۱۷/۰۷	۲۱/۰۸	۸/۳۵	۷/۴۱	۱۱/۱۵	۱۵/۵۶	۱۹/۶	۲۵/۵۸	۱۳/۳۵	۱۳/۹۷	۱۹/۱۴
NSE	۰/۶۶	۰/۴۳	۰/۱۵	۰/۶۷	۰/۷۳	۰/۴۲	۰/۸۴	۰/۷۴	۰/۵۷	۰/۶۲	۰/۵۸	۰/۲۱
میزان تأخیر (ماه)	Nino 3.4	۰	۰	۲	۲	۳	۳	۱	۱	۰	۰	۰
	NAO	۰	۰	۰	۱	۰	۳	۱	۲	۱	۲	۳
	WP	۲	۲	۰	۳	۳	۳	۰	۲	۰	۳	۲

MAM متوالی طی دوره مطالعه به صورت ماه به ماه مشخص شده‌اند. همان‌طور که ملاحظه می‌شود، بارش‌های حدی شدید در مقایسه با بارش‌های کمتر از ۴۰ میلی‌متر بهتر پیش‌بینی شده‌اند. در واقع برای بارش‌های کمتر از ۴۰ میلی‌متر، مقدار بارش در روش جنگل تصادفی به خصوص برای فصل‌های بهار در سال‌های اخیر بیشتر برآورد شده است.

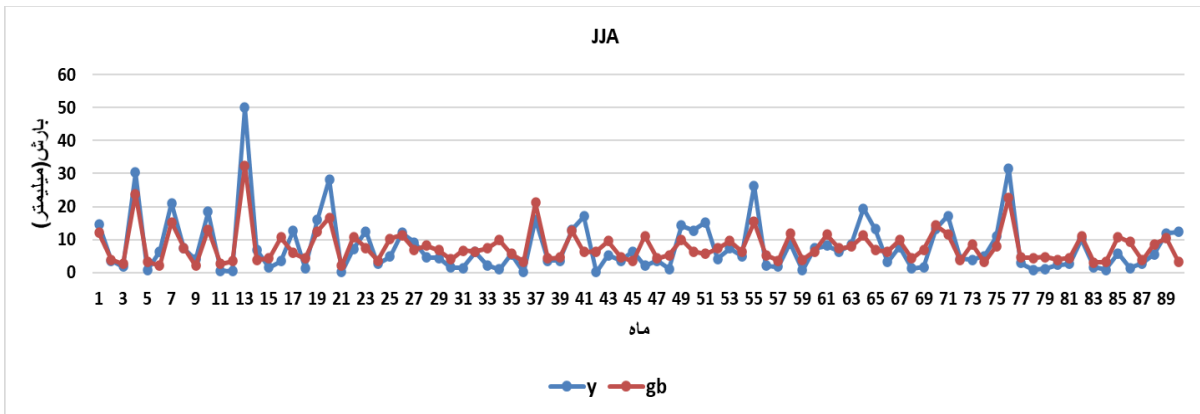
مطابق جدول ۲ در فصل بهار (MAM) عملکرد الگوریتم RF بهتر از ANN و GB است. همچنین ملاحظه می‌شود که شاخص WP با دو ماه تأخیر و دو شاخص دیگر بدون تأخیر، به بهترین پیش‌بینی منجر می‌شوند. دقت روش جنگل تصادفی مناسب است، اما برای مقایسه میزان بارش پیش‌بینی‌شده در این الگوریتم با مقدار مشاهده‌شده، شکل ۷ ترسیم شده است. در محور افقی این شکل فصل‌های



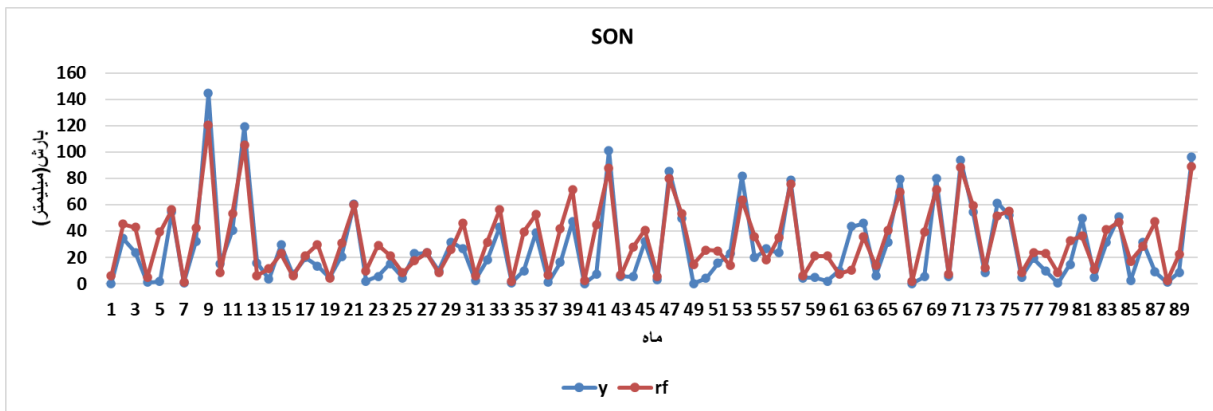
شکل ۷. مقایسه میزان بارش تخمینی جنگل تصادفی (RF) و مقدار بارش واقعی (y) در تمام ماه‌های MAM دوره مطالعه.

۸ ترسیم شده است. در محور افقی این شکل فصول JJA متوالی طی دوره مطالعه به‌صورت ماه به ماه مشخص شده‌اند. همان‌طور که ملاحظه می‌شود، بارش‌های حدی شدید تا حدی پذیرفتنی پیش‌بینی شده‌اند. در مقایسه با عملکرد روش جنگل تصادفی در فصل MAM که مقادیر کم بارش بیش‌برآورد شدند، این نقطه ضعف در روش GB کمتر است.

مطابق جدول ۲ در فصل JJA عملکرد الگوریتم GB و RF نزدیک به هم است و هر دو نسبت به شبکه عصبی بهتر هستند. در مجموع، عملکرد بهتر مربوط به الگوریتم GB است. همچنین ملاحظه می‌شود که شاخص NAO بدون تأخیر و دو شاخص دیگر با سه ماه تأخیر، به بهترین پیش‌بینی منجر می‌شوند. برای مقایسه میزان بارش پیش‌بینی شده در الگوریتم GB با مقدار مشاهده‌شده، شکل



شکل ۸. تخمینی گرادیان تقویتی (GB) و مقدار بارش واقعی (y) طی تمام ماه‌های JJA دوره مطالعه.




شکل ۹. مقایسه میزان بارش تخمینی جنگل تصادفی (RF) و مقدار بارش واقعی (y) طی تمام ماه‌های SON دوره مطالعه.

ماه مشخص شده‌اند. همان‌طور که ملاحظه می‌شود، بارش‌های حدی شدید با دقتی پذیرفتنی پیش‌بینی شده‌اند. همچنین بارش‌های کم نیز بیش‌برآورد نشده‌اند. مطابق جدول ۲ در فصل DJF، عملکرد GB و RF نزدیک به هم است، اما عملکرد الگوریتم RF بهتر است. همچنین ملاحظه می‌شود که شاخص‌های Nino 3.4، NAO و WP به‌ترتیب بدون تأخیر، با دو ماه تأخیر و با سه

مطابق جدول ۲ در فصل SON عملکرد الگوریتم RF (با تفاوت زیاد) بهتر از GB و ANN است. همچنین ملاحظه می‌شود که شاخص WP بدون تأخیر و دو شاخص دیگر با یک ماه تأخیر، به بهترین پیش‌بینی منجر می‌شوند. با هدف مقایسه میزان بارش پیش‌بینی شده در الگوریتم RF با مقدار مشاهده‌شده، شکل ۹ ترسیم شده است. در محور افقی این شکل فصول SON متوالی طی دوره مطالعه به‌صورت ماه به

ماه مشخص شده‌اند. همان‌طور که ملاحظه می‌شود، بارش‌های حدی شدید با دقت مناسب پیش‌بینی شده‌اند. برای بارش‌های کمتر، مقدار بارش با روش جنگل تصادفی بیشتر برآورد شده است.

ماه تأخیر، منجر به بهترین پیش‌بینی می‌شوند. برای مقایسه میزان بارش پیش‌بینی شده در این الگوریتم با مقدار مشاهده شده، شکل ۱۰ ترسیم شده است. در محور افقی این شکل فصول DJF متوالی طی دوره مطالعه به صورت ماه به



شکل ۱۰. مقایسه میزان بارش تخمینی جنگل تصادفی (RF) و مقدار بارش واقعی (y) در تمام ماه‌های DJF دوره مطالعه.

حدی نیز روش گرادیان تقویتی در مقایسه با روش جنگل تصادفی عملکرد بهتری دارد. در مدل‌سازی فصلی، برای سه فصل بهار، پاییز و زمستان عملکرد جنگل تصادفی و برای فصل تابستان، عملکرد روش تقویت گرادیان نسبت به سایر روش‌ها برتری داشت. روش جنگل تصادفی بهترین نتیجه را برای فصل بهار با داده‌های بدون تأخیر شاخص‌های Nino 3.4 و NAO و تأخیر دو ماهه WP، برای فصل پاییز با داده‌های بدون تأخیر WP و یک ماه تأخیر برای هر دو شاخص Nino 3.4 و NAO و برای فصل زمستان با داده‌های بدون تأخیر، دو و سه ماه تأخیر برای شاخص‌های به ترتیب Nino 3.4، NAO و WP ارائه کرد. همچنین برای فصل تابستان، روش تقویت گرادیان بهترین نتیجه را برای داده‌های با سه ماه تأخیر برای دو شاخص Nino 3.4 و WP و بدون تأخیر برای شاخص NAO داشت.

شایان ذکر است که در بررسی ۶۴ حالت ممکن، برای هر سه شاخص تأخیرهای مختلف (صفر تا سه ماه) لحاظ و بهترین نتیجه گزارش شد. بررسی‌ها نشان داد شاخص‌ها بهترین نتایج را در زمان‌های مختلف سال با تأخیرهای

۴ بحث و نتیجه‌گیری

در این مقاله، با استفاده از سه روش یادگیری ماشین جنگل تصادفی (RF)، شبکه عصبی مصنوعی (ANN) و تقویت گرادیان (GB) تلاش شد تا بارش منطقه شمال غرب کشور (شامل حوزه آبریز دریاچه ارومیه) به کمک سه شاخص دورپیوند Nino 3.4، WP و NAO در دو افق زمانی ماهانه و فصلی پیش‌بینی شود. برای این منظور و با توجه به اینکه اثر سه شاخص دورپیوند بر بارش ممکن است با تأخیر همراه باشد، تأخیر صفر، یک، دو و سه ماهه برای هر یک از سه شاخص در نظر گرفته شد؛ لذا ۶۴ حالت مختلف برای ورودی مدل‌های یادگیری ماشین آزمایش و بهترین نتیجه برای پیش‌بینی ماهانه و فصلی استخراج شد.

در پیش‌بینی ماهانه بارش، عملکرد روش گرادیان تقویتی (با سه ماه تأخیر برای شاخص WP و دو شاخص Nino 3.4 و NAO بدون تأخیر) بهتر از روش جنگل تصادفی بود و شبکه عصبی در جایگاه آخر عملکرد قرار گرفت. با ترسیم میزان بارش تخمینی در دو روش برتر (تقویت گرادیان و جنگل تصادفی) مشخص شد که از نظر تخمین بارش‌های

شرفی، م.، صمدیان فرد، س.، هاشمی، س.، ۱۳۹۹، پیش‌بینی بارش ماهانه با استفاده از مدل‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان: سامانه‌های سطوح آبگیر باران، ۸(۴)، ۶۳-۷۱.

هلالی، ج.، حسین‌زاده، ت.، چراغعلی‌زاده، م.، محمدی قلعه‌نی، م.، ۱۴۰۰، امکان‌سنجی استفاده از شاخص‌های پیوند از دور در پیش‌بینی بارش فصل بهار حوضه‌های آبریز ایران: تحقیقات آب و خاک ایران، ۵۲(۳)، ۷۶۹-۷۴۹.

Aggarwal, C. C., 2015, Data Mining: The Textbook: Springer.

Ahmadi, M., Kamangar, M., Salimi, S., Hosseini, S. A., Khamoushian, Y., Heidari, S., and Yarmoradi, Z., 2022, A new approach in evaluation impacts of teleconnection indices on temperature and precipitation in Iran: Theoretical and Applied Climatology, 150(1-2), 15-33.

Amini, M., Ghadami, M., Fathian, F., and Modarres, R., 2020, Teleconnections between oceanic-atmospheric indices and drought over Iran using quantile regressions: Hydrological Sciences Journal, 65(13), 2286-2295.

Asadi Oskouei, E., Khaki, B. D., Kouzegaran, S., Navidi, M. N., Haghghatd, M., Davatgar, N., and Lopez-Baeza, E., 2022, Mapping Climate Zones of Iran Using Hybrid Interpolation Methods: Remote Sensing, 14(11), 2632.

Bayraktar, H., Turalioglu, F. S., and Şen, Z., 2005, The estimation of average areal rainfall by percentage weighting polygon method in Southeastern Anatolia Region, Turkey: Atmospheric Research, 73(1-2), 149-160.

Breiman, L., 2001, Random Forests: Machine Learning, 45, 5-32.

Friedman, J. H., 1999, Greedy function approximation: A gradient boosting machine: The Annals of Statistics, 29(5), 1189-1232, DOI: 10.1214/aos/1013203451.

Hastie, T., Tibshirani, R.; and Friedman, J. H., 2009, The Elements of Statistical Learning (2nd ed.): Springer, 337-384.

Javanshiri, Z., Babaeian, I., and Pakdaman, M., 2023, Influence of large-scale climate signals on the precipitation variability over Iran: Stochastic Environmental Research and Risk Assessment, 37(5), 1745-1762.

Javanshiri, Z., Pakdaman, M., and Falamarzi, Y.,

متفاوت ارائه می‌دهند. دلیل اصلی این موضوع روش یادگیری ماشین و آموزش آن، منطقه مورد مطالعه و دوره زمانی مورد نظر بوده است؛ لذا ممکن است با تغییر منطقه مورد مطالعه یا الگوریتم مورد استفاده این تأخیرها تغییر یابند به نحوی که برای مثال، یک مدل دیگر یادگیری ماشین برای همین منطقه یا منطقه دیگری از کشور، بتواند بین تأخیرهای کمتر یا بیشتر و میزان بارش، رابطه دقیق‌تری پیدا کند. دوره زمانی و تاریخی داده‌ها نیز حائز اهمیت است؛ زیرا ممکن است با افزایش و گسترش این دوره زمانی، تأخیرها تغییر کنند. به این ترتیب علاوه بر دلایل فیزیکی-اقلیمی، پارامترهای دیگری نیز در میزان این تأخیرها مؤثر هستند. از سوی دیگر، ممکن است با تنها یک متغیر ورودی (سیگنال اقلیمی)، دقت تغییر کند یا حتی نتایج بهبود یابد؛ زیرا با کاهش تعداد ورودی‌ها، حجم محاسبات بسیار کاهش می‌یابد و برازش مدل یادگیری ماشین به داده‌ها ممکن است ساده‌تر شود، اما نکته مهم از دیدگاه فیزیکی مسئله این است که ممکن است یک شاخص اقلیمی به‌تنهایی نتواند تمام ابعاد تغییرات بارش را در منطقه مورد مطالعه و در دوره زمانی مورد نظر مدل‌سازی کند؛ لذا برای دستیابی به نتایج پایدارتر و در نظر گرفتن ابعاد بیشتر (و نه همه آن ابعاد) فیزیک بارش، به جای یک شاخص، سه شاخص لحاظ شده است.

منابع

بامری، ا.، خالقی، م.، ۱۴۰۱، تخمین دمای سطحی و عمقی خاک از داده‌های هواشناسی با استفاده از تکنیک‌های یادگیری ماشین در اقلیم فراهشک: تحقیقات کاربردی خاک، ۱۰(۱)، ۵۴-۶۸.

پاکدامن، م.، ۱۴۰۱، تأثیر نوع الگوریتم آموزش شبکه عصبی پرسپترون چندلایه در دقت پیش‌بینی بارش ماهانه ایران، مطالعه موردی: مدل ECMWF: فیزیک زمین و فضا، ۴۸(۱)، ۲۱۳-۲۲۶.

- 2021, Homogenization and trend detection of temperature in Iran for the period 1960–2018: *Meteorology and Atmospheric Physics*, **133**, 1233-1250.
- Mason, L., Baxter, J., Bartlett, P., and Frea, M., 1999, Boosting algorithms as gradient descent: Proceeding of the 12th international conference on neural information processing systems, 512-518.
- Nash, J. E., and Sutcliffe, J. V., 1970, River flow forecasting through conceptual models part I— A discussion of principles: *Journal of Hydrology*, **10**(3), 282-290.
- Pakdaman, M., Babaeian, I., and Bouwer, L. M., 2022a, Improved monthly and seasonal multi-model ensemble precipitation forecasts in Southwest Asia using machine learning algorithms: *Water*, **14**(17), 2632.
- Pakdaman, M., Babaeian, I., Javanshiri, Z., and Falamarzi, Y., 2022b, European multi model ensemble (EMME): A new approach for monthly forecast of precipitation: *Water Resources Management*, **36**(2), 611-623.
- Pakdaman, M., Falamarzi, Y., Babaeian, I., and Javanshiri, Z., 2020, Post-processing of the North American multi-model ensemble for monthly forecast of precipitation based on neural network models: *Theoretical and Applied Climatology*, **141**(1-2), 405-417.
- Piryonesi, S. M., and El-Diraby, T., 2021, Using machine learning to examine impact of type of performance indicator on flexible pavement deterioration modeling: *Journal of Infrastructure Systems*, **27**(2).

Forecasting the average monthly rainfall in the northwest of Iran using teleconnections and machine learning

Morteza Pakdaman^{1*}, Ebrahim Fattahi² and Zohreh Javanshiri¹

¹ Assistant Professor, Research Institute of Meteorological and Atmospheric Science (RIMAS), Tehran, Iran

² Associate Professor, Research Institute of Meteorological and Atmospheric Science (RIMAS), Tehran, Iran

(Received: 23 October 2023, Accepted: 16 December 2023)

Summary

Forecasting monthly and seasonal rainfall is very important from a hydrological point of view, including the water resources management, as well as from climatic and atmospheric hazards perspective. Monthly and seasonal forecasts are widely used in sectors such as energy and agriculture. On the other hand, it has been proven that large-scale atmospheric teleconnections and indices have an effect on the atmospheric conditions of different parts of the earth. Machine learning methods are widely used to predict different atmospheric variables. The reason for using these methods is the high modeling ability of these algorithms when faced with a large amount of data. At the same time, these algorithms have many other capabilities such as the ability to model uncertainty.

In this article, three machine learning methods, namely artificial neural network, gradient boosting and random forest are used for prediction. The performance of these algorithms will be compared with each other in monthly and seasonal forecasting scales. The studied area is a part of northwestern Iran, including the area of Lake Urmia basin. Three evaluation criteria, namely Nash-Sutcliffe, correlation coefficient and root mean square error were used to evaluate the results. Moreover, by using the Nino 3.4, WP, and NAO indices, the regional average monthly rainfall in the region is predicted with the help of three mentioned machine learning methods. The reason for choosing these three indicators is their effectiveness on the rainfall of the studied area. Two monthly and seasonal modeling methods are compared. Since teleconnections may be effective on precipitation with a delay, different delays of zero to three months were considered for all three studied teleconnections and the best results were obtained. Three methods of machine learning, i.e., random forest, neural network and gradient boosting were used. In the monthly mode, the performance of the gradient boosting method (with a three-month delay for the WP index and the other two indices without delay) was better than the random forest method, and the neural network ranked last in terms of performance. In terms of estimating the extreme precipitation, the gradient boosting method has an acceptable performance. In seasonal modeling, for the three seasons of spring (March-April-May), autumn (September-October-November) and winter (December-January-February), the performance of random forest and for the summer season (June-July-August), the performance of the gradient boosting method were superior to other methods.

Keywords: Precipitation, machine learning, teleconnection, artificial neural network, gradient boosting, random forest