

مقایسه عملکرد الگوریتم‌های یادگیری ماشین MLP، RF و GPR در پیش‌بینی تبخیر (مورد مطالعه: ایستگاه اقلیم‌شناسی دهخدا)

محمد پرویز پور^۱، پیام زالی کاکش^۲، حکیم ناصری^۳، زینب حمید^{۴*}

^۱ رئیس اداره آب و خاک مطالعات کاربردی، کشت و صنعت نیشکر دهخدا، اهواز، ایران.

^۲ مدیر مطالعات کاربردی، کشت و صنعت نیشکر دهخدا، اهواز، ایران.

^۳ معاون کشاورزی کشت و صنعت نیشکر دهخدا، اهواز، ایران.

^۴ دانشجوی دکتری آبیاری و زهکشی، دانشکده آب و محیط زیست، دانشگاه شهید چمران اهواز.

تاریخ دریافت: ۱۴۰۴/۰۴/۲۴، تاریخ پذیرش: ۱۴۰۴/۰۶/۰۸

چکیده

تبخیر یکی از فرایندهای اصلی چرخه هیدرولوژیکی است. در اقلیم‌های گرم، تلفات آب ناشی از تبخیر از رودخانه‌ها، کانال‌ها و سطوح آزاد آبی عاملی حیاتی است؛ بنابراین، استفاده از مدل‌های پیش‌بینی در این زمینه امری ضروری است. در این تحقیق کارایی سه مدل پیشرفته شبکه عصبی پرسپترون، الگوریتم جنگل تصادفی و رگرسیون فرایند گاوسی در پیش‌بینی پارامتر تبخیر مورد بررسی قرار گرفته است. بدین منظور، از داده‌های روزانه میانگین سرعت باد، میانگین دما، میانگین رطوبت نسبی و تبخیر در یک دوره شش‌ساله ایستگاه اقلیم‌شناسی کشت و صنعت دهخدا اهواز استفاده شد. سپس، خروجی مدل‌ها با داده‌های اندازه‌گیری شده مقایسه شد. تحلیل با استفاده از نرم‌افزار متلب ۲۰۲۲ انجام شد. نتایج ارزیابی عملکرد مدل‌ها همانند R^2 ، RMSE، نشان داد، که در مدل پرسپترون داده‌ها در مرحله آموزش ($R^2=0.92$) و ($RMSE=1.44$) عملکرد بهتری نسبت به صحت‌سنجی ($R^2=0.87$) و ($RMSE=1.77$) و آزمون ($R^2=0.91$) و ($RMSE=1.68$) دارد، همچنین نتایج ارزیابی کلی مدل ($R^2=0.93$) و ($RMSE=1.40$) نشانگر دقت بالای مدل در شبیه‌سازی تبخیر است. در الگوریتم جنگل تصادفی و رگرسیون فرایند گاوسی نتایج ارزیابی به ترتیب ($R^2=0.93$) و ($RMSE=1.41$)، ($R^2=0.93$) و ($RMSE=1.42$) بود که نشان‌دهنده دقت بالای سه مدل برای پیش‌بینی تبخیر است. بنابراین، می‌توان از مدل شبکه عصبی مصنوعی پرسپترون (MLP) در مرتبه اول، الگوریتم جنگل تصادفی در مرتبه دوم و در مرتبه سوم از رگرسیون فرایند گاوسی برای پیش‌بینی تبخیر استفاده کرد.

کلمات کلیدی: پرسپترون، جنگل تصادفی، رگرسیون گاوسی، تبخیر، پیش‌بینی

تبخیر یکی از فرایندهای اصلی چرخه هیدرولوژیکی است. مدیریت منابع محدود آب برای آبیاری به منظور تولید پایدار محصولات کشاورزی در مواجهه با افزایش جمعیت، روزبه‌روز از اهمیت بیشتری برخوردار می‌شود. در اقلیم‌های گرم، تلفات آب ناشی از تبخیر از رودخانه‌ها، کانال‌ها و سطوح آزاد آبی عاملی حیاتی است؛ زیرا، سهم قابل توجهی از منابع آب را مورد استفاده قرار می‌دهد. در مناطق مرطوب نیز تلفات ناشی از تبخیر قابل توجه است، اگرچه بارش‌های تجمعی معمولاً آن را پنهان می‌کنند و تنها در دوره‌های بدون باران قابل تشخیص است.

از جمله روش‌های محاسبه تبخیر می‌توان به روش‌های تشت تبخیر، روش بیلان آب و معادلات تجربی اشاره کرد. روش بیلان آب، روش مستقیم اندازه‌گیری تبخیر است؛ که، بر اساس ورودی و خروجی آب سیستم کار می‌کند و به داده‌های زیادی نیاز دارد. روش تشت تبخیر شناخته‌شده‌ترین روش برای اندازه‌گیری مقدار تبخیر از سطح آب آزاد است. در بیشتر ایستگاه‌های اقلیمی جهان، تشت‌های تبخیر با اشکال مختلف ریاضی برای ثبت میزان تبخیر، نصب می‌شوند. باین حال، هزینه‌های نصب و نگهداری تجهیزات ثبت داده‌های اقلیمی بالا است و دقت آن بسته به شرایط محلی متفاوت است. علاوه بر این، معادلات تجربی مثل هفنر، مایر، ماریانو هم استفاده می‌شوند؛ که، به داده‌های دقیق هواشناسی وابسته‌اند و در همه اقلیم‌ها همیشه دقت بالایی ندارند. به همین دلیل در این مطالعه از الگوریتم‌های یادگیری ماشین استفاده شد، چون می‌توانند روابط پیچیده و غیرخطی بین عوامل

هواشناسی و تبخیر را بهتر شناسایی کنند و پیش‌بینی دقیق‌تری ارائه دهند.

با توجه به اهمیت تبخیر به‌ویژه در مناطق خشک و کم باران به دلیل کاهش منابع ذخیره آب و پایین آمدن سطح تراز آب و همچنین پیچیدگی و زمان‌بر بودن اندازه‌گیری این پارامتر هواشناسی، شبیه‌سازی آن امری ضروری به نظر می‌رسد.

روش‌های پیش‌بینی متغیرهای هواشناسی به‌طور گسترده مورد مطالعه قرار گرفته‌اند، چرا که، آگاهی پیشاپیش از این متغیرها امکان مدیریت کارآمد انرژی‌های تجدیدپذیر و همچنین کاربردهای علمی دیگر در حوزه‌هایی، مانند، کشاورزی، سلامت، مهندسی، انرژی و غیره را فراهم می‌کند (سیگویا^۱ و همکاران، ۲۰۲۳). مدل‌های شبکه عصبی (ANN^۲)، با تکیه بر ساختار ریاضی و نادیده گرفتن ماهیت فیزیکی پدیده طبیعی، روابط پیچیده غیرخطی بین داده‌های ورودی و خروجی را تشخیص می‌دهد. این مدل‌ها در دسته‌بندی مدل‌های داده‌محور هستند و برای مدل‌سازی نیاز به داده‌های منطقه وجود دارد. استفاده از روش‌های مختلف شبیه‌سازی توسط پژوهشگران در دهه‌های اخیر باعث شده که در موارد بررسی شده به نتایج با اهمیتی دست یابند. سیگویا و همکاران به‌منظور شبیه‌سازی پارامترهای اقلیمی، از جمله، رطوبت نسبی، دما، تابش خورشیدی و سرعت باد با استفاده از مدل‌های مختلف از جمله رگرسیون خطی چندگانه، رگرسیون چندجمله‌ای، جنگل تصادفی، درخت تصمیم به این نتیجه رسیدند، که درخت تصمیم با بالاترین میزان R در بین مابقی مدل‌ها بهترین روش برای شبیه‌سازی پارامترهای هواشناسی است (سیگویا و همکاران، ۲۰۲۳). استساتریان^۳ و همکاران (۲۰۲۱)، در ارمنستان به‌منظور پیش‌بینی دمای

3- Astsatryan

1 - Segovia

2- Artificial Neural Network

نشان‌دهنده کارایی مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی در پیش‌بینی دما است. به طوری که ضریب همبستگی برابر با ۰/۹۹ و میانگین درصد خطای مدل برابر با ۱/۹۷ درصد بود. امیدوار و همکاران (۱۳۹۴)، به منظور پیش‌بینی بارش روزانه از شبکه‌های عصبی مصنوعی با ساختار پرسپترون چندلایه و شبکه عصبی بازگشتی نارکس استفاده کردند. نتایج نشان داد، که مدل ترکیبی بر پایه قانون آموزش لوبنبرگ مارکوات و تابع محرک سیگموئید با همه پارامترهای هواشناسی در هر سه ایستگاه از دقت قابل قبولی برخوردار است. شاهی^۴ و همکاران (۲۰۲۱)، به منظور شبیه‌سازی تبخیر از شبکه عصبی مصنوعی در قالب یک روش غیرخطی برای شبیه‌سازی تبخیر استفاده کردند. نتایج نشان داد، که استفاده از پارامترهای حداقل و حداکثر دما، رطوبت نسبی میانگین، سرعت باد، ساعات آفتابی و فشار، بهترین خروجی را برای پیش‌بینی تبخیر داشتند. قاسم^۵ و همکاران (۲۰۱۹)، برای پیش‌بینی نرخ تبخیر از مدل‌های رگرسیون بردار پشتیبان (SVR^۶) و شبکه‌های عصبی مصنوعی (ANN) و ترکیب آن‌ها با تبدیل موجک (WSVR^۷ و WANN^۸) در ایستگاه‌های تبریز (ایران) و آنتالیا (ترکیه) استفاده کردند. نتایج نشان داد، که شبکه عصبی مصنوعی (ANN) روندهای منطقی تری برای مدل‌سازی تبخیر در هر دو ایستگاه تبریز و آنتالیا ارائه می‌دهد. پاتل^۹ و همکاران (۲۰۲۰)، از روش‌های رگرسیون خطی چندگانه (MLR^{۱۰}) و شبکه عصبی مصنوعی (ANN) برای تخمین تبخیر ماهانه از تشتک استفاده شده کردند. نتایج مطالعه نشان می‌دهد، که مدل‌های ANN عملکرد کمی بهتر نسبت به مدل‌های MLR در پیش‌بینی تبخیر ماهانه از تشتک در منطقه مورد مطالعه داشته‌اند.

هوا تا ۲۴ ساعت آینده از روش یادگیری ماشین استفاده کردند. مدل پیشنهادی به دقت‌های چشمگیر میزان R، ۸۷.۳۱٪ برای پیش‌بینی سه‌ساعته و میزان R، ۷۵.۵۷٪ برای پیش‌بینی ۲۴ ساعته دست‌یافته است. پورمحمدی و انوری (۱۴۰۲)، به منظور شبیه‌سازی رواناب از روش‌های رگرسیون چند متغیره و روش‌های هوش مصنوعی از جمله مدل‌های شبکه عصبی مصنوعی (ANN) استفاده کردند. نتایج نشان داد، که مدل شبکه مصنوعی در دو مرحله واسنجی $R^2=0.77$ و صحت سنجی $R^2=0.87$ عملکرد بهتری نسبت به رگرسیون چند متغیره دارد. افخمی و همکاران (۱۳۹۷)، به منظور شبیه‌سازی تبخیر از روش‌های شبکه عصبی مصنوعی، شبکه‌های استنتاج فازی و درخت تصمیم رگرسیونی در ایستگاه سینوپتیک یزد استفاده کردند. نتایج نشان داد، که شبکه عصبی مصنوعی با $R=0.97$ بهترین کارایی را در بین مدل‌ها داشت. پناهی و همکاران (۱۳۹۵)، به منظور شبیه‌سازی و پیش‌بینی تبخیر و تعرق در تبریز از شبکه‌های مصنوعی SVM^۱، MLP^۲، RBF^۳ استفاده کردند، بدین منظور از داده‌های سال ۳۰ ساله و روش فائو پنمن مانیتث تبخیر و تعرق روزانه گیاه مرجع استفاده شد و سپس داده‌ها به منظور مدل‌سازی مورد استفاده قرار گرفت و با داده‌های محاسبه شده مقایسه شد. نتایج نشان داد، که شبکه عصبی مصنوعی - SVM kernel RBF با تأخیر زمانی M5 دارای RMSE و R^2 به ترتیب برابر با ۰/۱۵ میلی‌متر در روز و ۰/۹۲ بهترین عملکرد را داشت. بابائی و همکاران (۱۴۰۱)، در تحقیقی به منظور مدل‌سازی و پیش‌بینی دما از نرم‌افزار متلب و مدل پرسپترون چندلایه (MLP) استفاده کردند، از میانگین دمای ماهانه ایستگاه سینوپتیک سنندج در طول دوره آماری ۳۸ ساله در قالب داده‌های ورودی به مدل استفاده شد، نتایج به دست آمده

7 - Wavelet-Support Vector Regression
8 - Wavelet-Artificial Neural Network
9 - Patle
10 - Multiple Linear Regression

1 - Support Vector Machine
2 - Multilayer Perceptron
3 - Radial Basis Function
4 Shahi
5-Qasem
6 - Support Vector Regression

مبنای GPR^۱ بر ماهیت بیزی و غیر پارامتریک آن استوار است؛ که، این امکان را فراهم می‌آورد؛ برای اینکه، پدیده‌های مختلف جوی را به شکل انعطاف‌پذیر مدل‌سازی کند. توانایی GPR در مدیریت داده‌های چندمتغیره با استفاده از کاپولاهای گاوسی (Gaussian Copulas) بیش‌تر تقویت شده است. این ابزارها به ترکیب مؤثر پیش‌بینی‌های تک متغیره در قالب توزیع‌های مشترک منسجم کمک می‌کنند (مولر^۲ و همکاران، ۲۰۱۲). این رویکرد چند متغیره، نه تنها کالیبراسیون پیش‌بینی‌ها را بهبود می‌بخشد؛ بلکه، درک روابط میان متغیری را که در پیش‌بینی وضعیت آب‌وهوا بسیار حیاتی است، تسهیل می‌کند. چین^۳ و همکاران (۲۰۱۴) در تحقیقی به منظور پیش‌بینی سرعت باد از مدل GPR استفاده کردند. نتایج نشان داد، مدل پیشنهادی حدود ۴٪ تا ۱۱٪ بهبود در دقت پیش‌بینی نسبت به مدل شبکه عصبی مصنوعی (ANN) ارائه داده است. لواتی^۴ و همکاران (۲۰۲۰)، توان تولید انرژی خورشیدی با توجه به شرایط آب‌وهوایی در بازه زمانی ۴۸ ساعته و چهارساعته توسط مدل GPR را بررسی کردند. نتایج نشان داد، که مدل در شرایطی، که میزان پوشش ابر پایدار باشد، قادر به پیش‌بینی توان تولیدی سامانه‌های PV^۵ با دقت خوبی هست؛ اما، در شرایطی که پوشش ابری به سرعت تغییر می‌کند و ابرها پراکنده هستند، مدل در ردیابی این تغییرات سریع با چالش مواجه شده است.

الگوریتم جنگل تصادفی (Random Forest) به‌طور فزاینده‌ای، یک ابزار قدرتمند، در پیش‌بینی وضعیت آب‌وهوا شناخته می‌شود؛ این امر به دلیل توانایی آن در مدیریت داده‌های پیچیده و بهبود دقت پیش‌بینی‌ها است. این فن یادگیری ماشین که از مجموعه‌ای از درخت‌های

تصمیم برای تحلیل داده‌های چند متغیره بهره می‌گیرد، به‌طور مؤثری در مواجهه با چالش‌های مختلف هواشناسی همچون پیش‌بینی رویدادهای شدید آب‌وهوایی، بارندگی و شرایط محیطی مؤثر بر تولید انرژی به کاررفته است. ژانگ^۶ و همکاران (۲۰۲۵)، برای بررسی پیش‌بینی دما از ترکیب مدل الگوریتم جنگل تصادفی با شبکه حافظه کوتاه‌مدت LSTM^۷ استفاده کردند. نتایج نشان داد، که در مقایسه با مدل LSTM تنها، مدل ترکیبی RF-LSTM^۸ به ترتیب مقادیر RMSE، MAE و MAPE را بهبود داده است (به میزان ۰/۲۷، ۰/۲۲ و ۰/۰۷) و مدل در پیش‌بینی دمای شهر نانجینگ عملکرد قابل توجه داشته و دقت و پایداری بالایی را ارائه می‌دهد. الداهیدی^۹ و همکاران (۲۰۲۲)، برای پیش‌بینی تابش خورشیدی از ترکیب الگوریتم‌های جنگل تصادفی (Random Forest) و CatBoost^{۱۰} استفاده کردند، نتایج نشان‌دهنده کارایی بالای الگوریتم‌های جنگل تصادفی و CatBoost، به صورت جداگانه و یک مدل ترکیبی (ensemble) است. تقی دین^{۱۱} و همکاران (۲۰۲۴)، به منظور پیش‌بینی وضعیت آب‌وهوا در اسلیمان از الگوریتم جنگل تصادفی استفاده کردند. نتایج نشان داد، که الگوریتم جنگل تصادفی در پیش‌بینی آب‌وهوای منطقه عملکرد خوبی دار (R²=0.691). در تحقیقی دیگر پوترا^{۱۲} و همکاران (۲۰۲۴)، از مدل RF^{۱۳} در مقایسه با مدل (Grid Search Cross-Validation) برای پیش‌بینی بارش استفاده کردند. نتایج نشان داد، مدل RF به دلیل

8 - Random Forest - Long Short-Term Memory
9- Al-Dahidi
10 - Categorical Boosting
11 - Taqiyuddin
12 - Putra
13 - Random Forest

1 - Gaussian Process Regression
2 - Möller
3 - Chen
4 - Lawati
5 - Photovoltaic
6 - Zhang
7 - Long Short-Term Memory

پایداری و دقت بالای آن برای پیش‌بینی بارش باران مناسب است.


پژوهش‌های اخیر نشان داده‌اند، که شبکه‌های عصبی مصنوعی می‌توانند جایگزین امیدوارکننده‌ای برای روش‌های مرسوم تخمین پارامترهای هواشناسی به‌خصوص تبخیر باشند. در تحقیق حاضر با استفاده از شبکه‌های عصبی در نرم‌افزار متلب نسخه ۲۰۲۲ از مدل پرسپترون چندلایه (MLP) استفاده شد. این مدل از پرکاربردترین مدل‌های شبکه‌های عصبی مصنوعی از مؤلفه‌های هوش مصنوعی در زمینه پیش‌بینی عناصر جوی و اقلیمی است؛ که، می‌تواند بدون در نظر گرفتن معادلات پیچیده غیرخطی، خروجی مدل را پیش‌بینی کند. همچنین، در این نرم‌افزار، از مدل‌های الگوریتم جنگل تصادفی (RF) و رگرسیون فرایند گوسی (GPR) استفاده شد و مقادیر تبخیر به‌منزله خروجی مدل‌ها استخراج و با مقدار واقعی تبخیر اندازه‌گیری شده توسط تشت تبخیر مقایسه شد. لازم به ذکر است، که انجام پیش‌پردازش دقیق داده‌ها، تحلیل ایستایی و حساسیت

داده‌های ورودی به مدل‌ها و همچنین ارزیابی جامع عملکرد سه مدل بررسی شده سبب بهبود دقت پیش‌بینی تبخیر شده است. همچنین تمرکز بر داده‌های محلی منطقه گرم و خشک ایستگاه دهخدا، امکان بومی‌سازی نتایج و افزایش کاربردپذیری مدل‌ها را فراهم می‌آورد.

مواد و روش‌ها

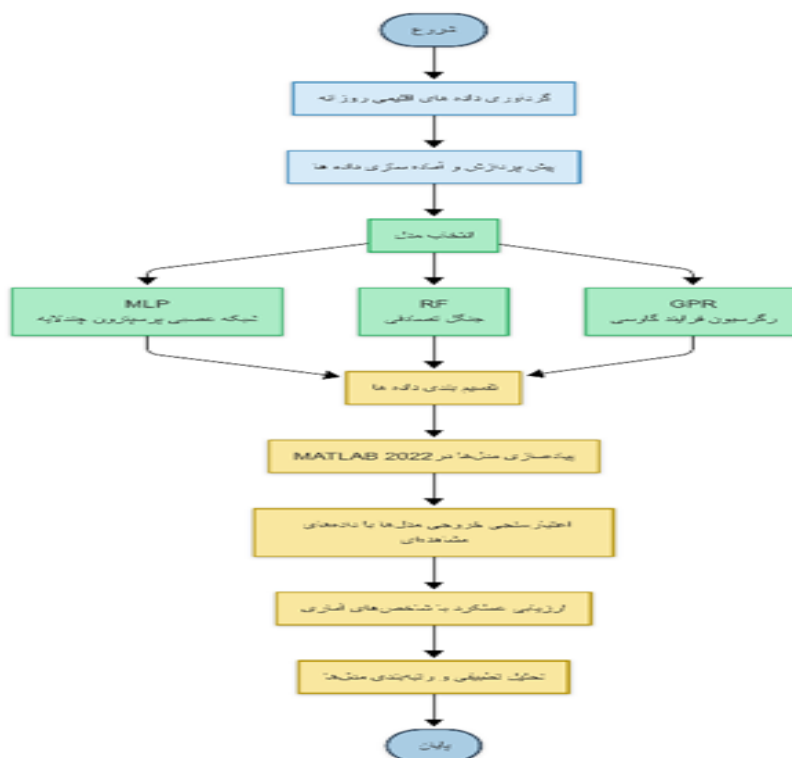
منطقه مورد مطالعه

موقعیت مورد مطالعه در این تحقیق ایستگاه اقلیم‌شناسی صنعت، کشت و صنعت نیشکر دهخدا است. کشت و صنعت دهخدا یکی از هفت واحد شرکت توسعه نیشکر و صنایع جانبی است؛ که، در ۴۸:۳۹ طول شرقی و ۳۱:۴۲ عرض شمالی در ۲۰ کیلومتری شمال شهر اهواز قرار دارد. این واحد کشت و صنعت از سطح دریا ۱۸/۱ متر است، بیشترین درجه حرارت آن در تابستان ۴۶/۰۹ درجه سانتی‌گراد در تابستان و حداقل درجه حرارت ۸/۱۱ در زمستان و میزان تبخیر ۱۴/۲۵ در تابستان و ۳/۱۵ در زمستان است، شکل ۱ منطقه مورد مطالعه و موقعیت ایستگاه مورد مطالعه را نشان می‌دهد.



شکل ۱- موقعیت ایستگاه مورد مطالعه در سطح کشور و استان خوزستان


شکل (۲)، روندنمای پژوهش است.



شکل ۲- روندنمای پژوهش

نمایش داده های غیرخطی هستند، که روابط بین منابع داده را نشان می دهند. (کومار^{۲۷} و همکاران، ۲۰۲۳). کاربردترین نوع شبکه عصبی مصنوعی، شبکه های پیشرو سه لایه هستند؛ که، تعداد عصب های لایه ورودی خروجی وابسته به نوع کاربرد دارند. ولی تعداد عصب های لایه پنهان با سعی و خطا به دست می آید (پورمحمدی و انوری، ۱۴۰۲). ساختار شبکه عصبی از سه لایه تشکیل شده است، لایه واحدهای ورودی، لایه واحدهای پنهان، لایه واحدهای خروجی (شکل ۳).


شبکه های عصبی مصنوعی (ANN) شبکه عصبی مصنوعی (ANN) یک سیستم مدل سازی غیرخطی داده است؛ که، در آن مدلها یا الگوها برای روابط پیچیده بین ورودیها و خروجیها ایجاد می شوند. شبکه های عصبی دارای قابلیت های یادگیری برتری هستند. شبکه عصبی که با نام «پرسپترون» نیز شناخته می شود، نخستین بار در اوایل دهه ۱۹۴۰ معرفی شد. این شبکه ها اخیراً به یکی از اجزای مهم هوش مصنوعی تبدیل شده اند. شبکه های عصبی، ابزارهای



شکل ۳- شبکه عصبی مصنوعی

همان‌گونه که ذکر شد، ساختار شبکه عصبی از سه لایه: لایه واحدهای ورودی، لایه واحدهای پنهان، لایه واحدهای خروجی تشکیل شده است. لایه ورودی شامل سه لایه و خروجی شامل یک لایه و تعداد نرون‌های لایه پنهان نیز به گونه‌ای انتخاب شد، که بتوان بهترین تقریب را از شبکه به دست آورد. داده‌ها به صورت یک ماتریس $[4 \times 2564]$ برای سه صفت شامل میانگین سرعت باد روزانه، میانگین دمای روزانه و میانگین درصد رطوبت نسبی روزانه در قالب متغیرهای ورودی مدل و میزان تبخیر محاسباتی به روش تشت تبخیر در قالب متغیر هدف برای ۲۵۶۴ داده هواشناسی تعریف شدند. شکل ۴ طرح‌واره شبکه عصبی MLP را نشان می‌دهد.

ساختار پیاده شده شبکه‌ی پرسپترون چندلایه یکی از مهم‌ترین ساختارهای ANN است. به‌طور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسّی (عصب‌های پایه) می‌باشند. هر لایه شامل تعدادی عصب یا گره است. اتصال‌های بین لایه‌های ورودی و لایه پنهان ماتریس وزن ورودی و تمام اتصال‌های بین لایه پنهان و لایه خروجی ماتریس وزن خروجی را تشکیل می‌دهد. بین عصب‌های لایه‌های مختلف اتصالاتی وجود دارد؛ که، هر کدام دارای وزن‌هایی می‌باشند. در اثنای فرایند آموزش این وزن‌ها و مقادیر ثابتی که در آن‌ها جمع می‌شود به‌طور پی‌درپی تغییر می‌کند؛ برای اینکه، خطای بین مقادیر تخمین زده شده با مقادیر واقعی به حداقل خود برسد (شریفی و همکاران، ۱۳۹۹).




شکل ۴- طرح‌واره شبکه مصنوعی MLP با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی

الگوریتم جنگل تصادفی

بهره می‌برد و با استفاده از اصول بگینگ (bagging) و زیر فضای تصادفی (random subspace)، دقت پیش‌بینی را افزایش داده و مشکل بیش‌برازش

این الگوریتم، نخستین بار توسط بریمن (Breiman) در سال ۲۰۰۱ معرفی شد، که یک فن یادگیری تجمعی (ensemble learning) است؛ که، از درخت‌های تصمیم

است. یکی از این محدودیت‌ها، چالش در تفسیرپذیری (interpretability) نتایج آن است؛ زیرا ماهیت پیچیده مدل می‌تواند در مقایسه با روش‌های آماری سنتی، درک پیش‌بینی‌ها را دشوار سازد (گوود^۴ و همکاران، ۲۰۲۱). یکی از نقاط قوت کلیدی RF، انعطاف‌پذیری آن در مدیریت روابط غیرخطی و تعاملات پیچیده میان متغیرهای متعددی است؛ که، در داده‌های هواشناسی وجود دارند (سکولز^۵ و همکاران، ۲۰۲۵). بنابراین الگوریتم جنگل تصادفی، یک ابزار مقاوم و انعطاف‌پذیر در پیش‌بینی وضعیت آب‌وهوا هست و در طیف گسترده‌ای از کاربردها، از پیش‌بینی رویدادهای شدید جوی گرفته تا ارزیابی‌های محیطی به کار گرفته شده است. شکل ۵ طرح‌واره الگوریتم RF را نشان می‌دهد.



شکل ۵- طرح‌واره الگوریتم RF

داده‌های ورودی و خروجی هواشناسی به کار می‌رود؛ قابلیت‌هایی که در کاربردهایی نظیر پیش‌بینی دما و سرعت باد بسیار حائز اهمیت است. یکی از ویژگی‌های اصلی GPR، قابلیت ذاتی آن در ارائه میزانی از عدم قطعیت همراه با پیش‌بینی‌ها است؛ که، این امر امکان تصمیم‌گیری بهتر و آگاهانه‌تری را در زمینه‌هایی چون علوم محیطی و مهندسی فراهم می‌کند (یانگ^۶ و همکاران، ۲۰۱۹؛ لوب^۷ و همکاران، ۲۰۲۰؛ فان^۸ و

(overfitting) را کاهش می‌دهد. (فو^۱ و همکاران، ۲۰۲۳). این الگوریتم به دلیل انعطاف‌پذیری و پایداری در مدیریت انواع مختلف داده‌ها، به‌ویژه در وظایف طبقه‌بندی (classification) و رگرسیون (regression)، توجه گسترده‌ای را در حوزه‌های مختلف به خود جلب کرده است (آگناتکو^۲ و همکاران، ۲۰۲۴). یکی از مزایای اصلی الگوریتم Random Forest، توانایی آن در مدیریت فضاهای ویژگی با ابعاد بالا (high-dimensional feature spaces)؛ ضمن اینکه در برابر بیش‌برازش مقاوم بوده و در بسیاری از کاربردها سطوح قابل توجهی از دقت را ارائه می‌دهد (ایلما^۳ و همکاران، ۲۰۲۳). با این حال، علی‌رغم نقاط قوت فراوان، الگوریتم جنگل تصادفی با برخی محدودیت‌ها نیز مواجه

رگرسیون فرایند گاوسی (GPR)

یک رویکرد قدرتمند، غیر پارامتریک و مبتنی بر بیز است؛ که، به‌طور گسترده در حوزه‌های مختلفی از جمله ژئواستاتستیک، یادگیری ماشین و محاسبات علمی به کار می‌رود. به دلیل توانایی مدل در کمی‌سازی عدم قطعیت‌های ذاتی موجود در پیش‌بینی‌های جوی؛ یک ابزار قدرتمند در پیش‌بینی وضعیت آب‌وهوا هست و برای مدل‌سازی روابط پیچیده و اغلب غیرخطی بین

5 - Schulz
6 - Yang
7 - Lubbe
8 - Phan

1 - Fu
2 - Ignatenko
3 - Ilma
4 - Goode

همکاران، ۲۰۲۲). یکی از مزایای مهم GPR، انعطاف‌پذیری بالای آن در مواجهه با داده‌های غیرخطی و فضاهایی با ابعاد بالا است. این انعطاف‌پذیری از طریق استفاده از توابع هم‌پراکنندگی (covariance functions) یا کرنل‌ها (kernels) به دست می‌آید. این توابع، روابط بین نقاط داده را در فضای ورودی تعریف می‌کنند (وانگ^۱ و همکاران، ۲۰۲۳؛ پارک^۲ و همکاران، ۲۰۲۰). بنابراین، رگرسیون فرایند گاوسی یک نوآوری کلیدی

در پیش‌بینی وضعیت آب‌وهوا محسوب می‌شود. این روش با بهره‌گیری از چارچوب احتمالاتی خود، به مدل‌سازی عدم قطعیت‌ها، پس پردازش پیش‌بینی‌های دسته‌جمعی و در نظر گرفتن روابط چندمتغیره میان متغیرهای مختلف جوی می‌پردازد. این ویژگی‌ها، مدل را به یک ابزار ارزشمند در ارتقای دقت و قابلیت اطمینان پیش‌بینی‌های هواشناسی تبدیل می‌کنند. در جدول ۱ تفاوت بین سه مدل به‌طور خلاصه شرح شد.

جدول ۱- خلاصه خصوصیات مدل‌های استفاده‌شده در تحقیق

ویژگی	شبکه عصبی (MLP)	رگرسیون فرایند گاوسی (GPR)	الگوریتم جنگل تصادفی (RF)
نوع مدل	مدل یادگیری با وزن‌ها (پارامتریک)	مدل آماری غیر پارامتریک	الگوریتم جمعی (Ensemble of trees)
نحوه یادگیری	بهینه‌سازی وزن‌ها با گرادیان	فرایند آماری بر اساس توزیع احتمال	مجموعه‌ای از درخت‌های تصمیم‌گیری
مقیاس‌پذیری	خوب در داده‌های بزرگ	تحلیل ضعیف در داده‌های زیاد	عالی در داده‌های بزرگ
تفسیرپذیری	ضعیف‌تر	خوب	نسبتاً خوب
پیش‌بینی همراه با عدم قطعیت	معمولاً باید جداگانه اضافه شود	به‌طور طبیعی و دقیق	می‌توان حدود عدم قطعیت تقریبی داد (مثلاً از واریانس درخت‌ها)
داده‌ی ورودی	همه نوع داده (عدد، تصویر، متن، ...)	داده جدولی	داده جدولی، ویژگی‌ها عددی / طبقه‌ای

معیارهای ارزیابی

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$R = \frac{\sum_{i=1}^n (y_i - \hat{y}_i) \times (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2 \times \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$ME = \frac{1}{n} \times \sum_{i=1}^n (y_i - \hat{y}_i) \quad (6)$$

$$MAD = \frac{1}{n} \times \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

$$MAPE = \frac{100}{n} \times \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (8)$$

$$NSE = 1 - \sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{(y_i - \bar{y})^2} \quad (9)$$

برای سنجش نتایج استحصالی مدل، از شاخص‌های آماری ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، میانگین مربعات خطا (MSE)، ضریب همبستگی (R)، میانگین قدر مطلق خطاها (MAE)، میانگین خطاها (ME)، تفاوت میانگین انحرافات مطلق (MSAD)، میانگین درصد خطای مطلق (MAPE) و ضریب نش ساتکلایف (NSE) استفاده می‌شود:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

در فرمول‌های ارائه شده، \hat{y}_i مقادیر پیش‌بینی شده، y_i مقادیر اندازه‌گیری شده، n تعداد نمونه‌ها، y_{ave} مقدار متوسط پارامترهای مشاهده شده و \hat{y}_{ave} مقدار متوسط پارامترهای پیش‌بینی شده است. چنانچه تمامی مقادیر پیش‌بینی شده و اندازه‌گیری باهم برابر باشند، مقدار عددی $MAPE$ ، MAD ، ME ، MAE ، MSE ، $RMSE$ برابر صفر R^2 ، NSE و R برابر ۱ خواهد شد.

بحث و نتایج

جدول ۲- خلاصه‌ای از مشخصات داده‌های هواشناسی استفاده شده در تحقیق

پارامترها	واحد	حداکثر	حداقل	میانگین	حداقل	میانگین	انحراف از معیار
دمای روزانه	C^0	۸۰/۴۱	۴/۶۰	۲۲/۷۳	۴/۶۰	۲۲/۷۳	۲۵/۸۱
درصد رطوبت نسبی	%	۹۷	۱۵/۵۰	۵۹/۸۰	۱۵/۵۰	۵۹/۸۰	۵۳/۲۵
متوسط سرعت باد	m/s	۱۱/۸۷	۰	۱/۳۷	۰	۱/۳۷	۱/۳۷
تبخیر روزانه	mm	۲۶/۱۰	۰/۳۲	۸/۲۳	۰/۳۲	۸/۲۳	۸/۲۳

برای اطمینان از صحت تحلیل و دقیق بودن نتایج خروجی با کمترین خطا، در ابتدا داده‌های ورودی از نظر ایستایی توسط آزمون ریشه واحد آگوستین-دیکی-فولر (ADF) مورد بررسی قرار گرفتند. نتایج نشان داد، که به‌جز میانگین دما، داده‌های ورودی به مدل ایستا هستند.

برای اطمینان از صحت تحلیل و دقیق بودن نتایج خروجی با کمترین خطا، در ابتدا داده‌های ورودی از نظر ایستایی توسط آزمون ریشه واحد آگوستین-دیکی-فولر (ADF) مورد بررسی قرار گرفتند. نتایج نشان داد، که به‌جز میانگین دما، داده‌های ورودی به مدل ایستا هستند.

جدول ۳- خلاصه آمار و تحلیل نتایج ایستایی داده‌های ورودی

پارامترها	تست ایستایی قبل از پیش پردازش	مقدار احتمال قبل از پیش پردازش	وضعیت ایستایی قبل از پیش پردازش	تست ایستایی قبل از پیش پردازش	مقدار احتمال قبل از پیش پردازش	وضعیت ایستایی قبل از پیش پردازش
متوسط سرعت باد	-۱۳/۵۷	۰/۰۰۱	ایستا	-۱۳/۵۷	۰/۰۰۱	ایستا
دمای روزانه	-۱/۷۱	۰/۰۸۲	نا ایستا	-۵۷/۸۶	۰/۰۰۱	ایستا
درصد رطوبت نسبی	-۳/۹۳	۰/۰۰۱	ایستا	-۳/۹۳	۰/۰۰۱	ایستا
تبخیر روزانه	-۳/۹۰	۰/۰۰۱	ایستا	-۳/۹۰	۰/۰۰۱	ایستا

معرفی مدل‌های Random Forest، GPR و MLP در نرم‌افزار متلب و تعریف سناریوهای مختلف از جمله، تعداد نورون‌ها، پارامترهای ورودی مدل‌ها، تعداد درخت‌ها و تقسیم‌بندی داده‌ها از مراحل تعیین بهترین سناریو برای پیش‌بینی بود و با استفاده از آزمون و خطا تعیین گردید. جدول ۴ نتایج کالیبراسیون را نشان می‌دهد.

جدول ۴- مشخصات مدل‌های پس از کالیبراسیون

مشخصات	شبکه عصبی (MLP)	رگرسیون فرایند گاوسی (GPR)	الگوریتم جنگل تصادفی (RF)
نوع مدل	پرسپترون چندلایه (پیش‌خور)	مدل غیر پارامتریک احتمالی	مدل مبتنی بر درخت تصمیم
ساختار/لایه‌ها	(ورودی-پنهان-خروجی) ۱-۱۰-۳	بدون لایه (تابع کرنل)	۱۰۰ درخت تصمیم
تعداد نورون/درخت	۱۰ نورون در لایه پنهان	ندارد (مدل مبتنی بر کرنل)	۱۰۰ درخت
توابع فعال‌سازی	پنهان: سیگمود، خروجی: خطی	کرنل: Squared Exponential	-
الگوریتم آموزش	آموزش با تنظیم بیزی (trainbr)	بهینه‌سازی ماکزیمم درست‌نمایی (MLE)	Bagging
تقسیم‌بندی داده‌ها	تقسیم داخلی ۱۰/۱۰/۸۰ + 5-Fold CV	5-Fold CV	5-Fold CV
پیش‌پردازش	نرمال‌سازی + حذف ویژگی ثابت	استانداردسازی خود کار	-
معیارهای ارزیابی	MSE, RMSE, R ² , MAE, MAPE, NSE	MSE, RMSE, R ² , MAE, MAPE, NSE	MSE, RMSE, R ² , MAE, MAPE, NSE
تأثیر تعداد نورون‌ها	افزایش نورون‌ها ⇒ افزایش ظرفیت مدل (ریسک بیش‌برازش)	-	هر درخت معادل یک "نورون تصمیم"


برای دستیابی به ساختار بهینه در مدل‌های مورد بررسی از روش اعتبارسنجی متقابل (Cross-Validation) استفاده شد. روش اعتبارسنجی متقابل روش آماری برای ارزیابی عملکرد مدل‌های یادگیری ماشین است. در این روش به جای اینکه داده‌ها فقط یک‌بار به بخش آموزش و آزمون تقسیم شوند چند بار تقسیم‌بندی شده و در هر بار مدل توسط شاخص‌های آماری ارزیابی می‌شود. تقسیم‌بندی داده‌ها به صورت کاملاً تصادفی صورت گرفت؛ برای اینکه، از هرگونه سوگیری در روند یادگیری مدل جلوگیری شود و در آخر بهترین فولد برای ساختار و تقسیم‌بندی بهینه انتخاب می‌شود. همان‌گونه که در جدول ۳ ذکر شد در این تحقیق از پنج تکرار (Fold) برای بررسی استفاده شد. همچنین تعداد مختلفی از

ورودی‌ها (متغیرهای) لایه ورودی از جمله، حداکثر دما، حداقل دما، میانگین دما، رطوبت نسبی حداقل و حداکثر، میانگین رطوبت نسبی، تعداد ساعات آفتابی، سرعت باد در صبح، ظهر و عصر و میانگین سرعت باد به مدل‌ها داده شود و با آزمون و خطا مورد بررسی قرار گرفتند بهترین حالت در هر سه مدل با تعداد سه پارامتر ورودی (میانگین دما، میانگین رطوبت و میانگین سرعت باد) بهینه‌سازی شد.

برای دستیابی به ساختار بهینه شبکه MLP تعداد عصب‌های مختلف در لایه پنهان مورد آزمون و خطا قرار گرفت و بهترین شبکه با تعداد ۱۰ نورون در لایه مخفی بهینه‌سازی شد؛ در شکل (۶)، ساختار ورودی به شبکه عصبی ترسیم شد. داده‌های ورودی به سه دسته TRAIN

انتخاب بهترین نسخه مدل است و ۱۰ درصد داده‌ها به این بخش تعلق گرفت. در بخش TEST داده‌ها برای ارزیابی و صحت سنجی مدل استفاده می‌شود و ۱۰ درصد باقی‌مانده از داده‌ها برای این بخش بود. تحلیل آماری بر روی هر سه بخش به‌طور جداگانه انجام شد.

TEST، VALIDATION (اعتبارسنجی) و (آموزش) (آزمون) تقسیم‌بندی شدند. توزیع داده‌ها در میان این سه بخش کاملاً تصادفی بود. در بخش TRAIN مدل توسط داده‌های داده‌شده آموزش می‌بیند و در این تحقیق ۸۰ درصد داده‌های ورودی به این بخش تعلق گرفت، بخش VALIDATION، برای تنظیم پارامترهای مدل برای




شکل ۶- طرح‌واره ماتریس ورودی به شبکه عصبی MLP

استفاده شد. مدل GPR با تابع پایه ثابت (constant basis function) و کرنل نمایی مربعی (squared exponential kernel) آموزش داده شد. این فرایند برای هر فولد تکرار شد و مدل در هر مرحله از ابتدا آموزش داده شد. در پایان، بهترین فولد بر اساس مقدار کمینه‌ی MSE و مقدار بیشینه R^2 انتخاب شد و نتایج آن به‌طور دقیق تحلیل و گزارش گردید.


نمودارهای پراکندگی بین مقادیر واقعی و پیش‌بینی‌شده در شکل ۷، ۸ و ۹ آورده شد. نتایج نمودارها نشان داد، که هر سه مدل قدرت بالایی در پیش‌بینی دارند؛ و مدل شبکه عصبی مصنوعی دارای کمترین اختلاف بین مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده است ($R^2 = 0.93$)

در مدل الگوریتم جنگل تصادفی (Random Forest)، در هر تکرار (Fold)، از چهار بخش داده در قالب مجموعه آموزش (Training Set) برای آموزش مدل استفاده شد و بخش پنجم در قالب مجموعه آزمون (Test Set) برای ارزیابی مدل مورد استفاده قرار گرفت. این فرایند برای هر پنج Fold تکرار شد و مدل در هر مرحله از ابتدا آموزش داده شد. در هر تکرار، عملکرد مدل توسط شاخص‌های آماری مورد ارزیابی قرار گرفت. در پایان، بهترین فولد بر اساس مقدار کمینه‌ی MSE و مقدار بیشینه R^2 انتخاب شد و نتایج آن به‌طور دقیق تحلیل و گزارش گردید.


در مدل رگرسیون فرایند گاوسی (GPR) در هر تکرار (Fold)، ۸۰٪ داده‌ها برای آموزش مدل و ۲۰٪ برای تست



شکل ۷- نمودار پراکنندگی داده‌های واقعی در برابر مقادیر پیش‌بینی شده توسط مدل در الگوریتم جنگل تصادفی در بهترین فولد



شکل ۸- نمودار پراکنندگی داده‌های واقعی در برابر مقادیر پیش‌بینی شده توسط مدل در رگرسیون فرایند گاوسی در بهترین فولد



شکل ۹- نمودار پراکنندگی داده‌های واقعی در برابر مقادیر پیش‌بینی شده توسط مدل در شبکه عصبی مصنوعی پرسپترون در بهترین فولد

جدول ۵- ارزیابی عملکرد شبکه عصبی چندلایه پرسپترون (MLP) در فولدهای مختلف، با استفاده از شاخص‌های آماری

MSE	RMSE	R	R ²	MAE	ME	MSAD	MAPE	NSE	TrainInternal	ValInternal	TestInternal	TestExternal	Fold
2.17	1.47	0.96	0.91	1.12	-0.01	0.04	18.88	0.91	1641	205	206	512	1
2.23	1.49	0.96	0.93	1.12	0.03	0.12	19.58	0.93	1640	205	206	513	2
2.31	1.52	0.96	0.91	1.14	0.00	0.05	20.17	0.91	1640	205	206	513	3
2.64	1.63	0.95	0.91	1.19	0.08	0.17	18.87	0.91	1640	205	206	513	4
1.96	1.42	0.96	0.93	1.06	-0.03	0.10	17.26	0.93	1640	205	206	513	5

جدول ۶- ارزیابی عملکرد مدل فرایند گاوسی (GPR) در فولدهای مختلف اعتبارسنجی، با استفاده از شاخص‌های آماری

MSE	RMSE	R	R ²	MAE	ME	MSAD	MAPE	NSE	TrainSize	TestSize	Fold
2.12	1.46	0.96	0.92	1.12	-0.03	0.10	19.26	0.92	2052	512	1
2.26	1.50	0.96	0.92	1.12	0.04	0.12	19.45	0.92	2051	513	2
2.28	1.51	0.96	0.92	1.13	0.00	0.05	20.18	0.92	2051	513	3
2.71	1.65	0.95	0.90	1.19	0.04	0.18	19.00	0.90	2051	513	4
2.01	1.42	0.96	0.93	1.07	-0.03	0.10	18.22	0.93	2051	513	5

جدول ۷- ارزیابی عملکرد مدل جنگل تصادفی (Random Forest) در فولدهای مختلف، با استفاده از شاخص‌های آماری

MSE	RMSE	R	R ²	MAE	ME	MSAD	MAPE	NSE	TrainSize	TestSize	Fold
2.25	1.50	0.95	0.91	1.15	-0.03	0.11	19.90	0.91	2052	512	1
2.44	1.56	0.96	0.92	1.16	0.03	0.11	19.82	0.92	2051	513	2
2.50	1.58	0.95	0.91	1.17	-0.02	0.07	20.56	0.91	2051	513	3
2.65	1.63	0.95	0.91	1.20	0.02	0.15	19.08	0.91	2051	513	4
1.99	1.41	0.96	0.93	1.08	-0.04	0.11	17.70	0.93	2051	513	5

جدول‌های ۵ الی ۷ نشانگر تقسیم‌بندی‌ها داده‌ها و

عملکرد مدل‌ها در فولدهای مختلف است. همان‌گونه که

در جدول‌ها پیداست فولد پنج (Fold 5) بهترین فولد

برای هر مدل است. هر سه مدل دارای ضریب تعیین

بالایی بوده و از سه مدل می‌توان برای پیش‌بینی تبخیر

استفاده کرد. از بین مدل‌های استفاده‌شده، شبکه عصبی

MLP با مقدار $R^2=0.93$ ، $RMSE=1.40$ و $MAE=1.06$

بهترین مدل برای پیش‌بینی تبخیر و بعد از آن مدل

Random Forest با مقدار $R^2=0.93$ ، $RMSE=1.41$ و

$MAE=1.08$ مدلی مناسب برای پیش‌بینی است.

عملکرد شبکه عصبی MLP بر اساس

شاخص‌های آماری به منظور پیش‌بینی تبخیر در

سه مرحله، آموزش، اعتبارسنجی و آزمون در

بهترین Fold در جدول ۸ ارائه شده است

در جدول‌ها پیداست فولد پنج (Fold 5) بهترین فولد

برای هر مدل است. هر سه مدل دارای ضریب تعیین

بالایی بوده و از سه مدل می‌توان برای پیش‌بینی تبخیر

استفاده کرد. از بین مدل‌های استفاده‌شده، شبکه عصبی

MLP با مقدار $R^2=0.93$ ، $RMSE=1.40$ و $MAE=1.06$

بهترین مدل برای پیش‌بینی تبخیر و بعد از آن مدل

جدول ۸ - ارزیابی عملکرد شبکه عصبی MLP در بهترین فولد، با استفاده از شاخص‌های آماری در چارچوب تقسیم‌بندی داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون

MSE	RMSE	R	R2	MAE	MAPE	NSE	Fold
2.09	1.44	0.96	0.92	1.11	19.22	0.92	Train Internal
3.15	1.77	0.93	0.87	1.24	20.05	0.87	Validation Internal
2.84	1.68	0.95	0.91	1.15	20.60	0.90	Test Internal
1.96	1.40	0.96	0.92	1.06	17.26	0.92	Test External

در عراق، سودانی و سالم (۲۰۲۲)، بر قابلیت RF در شبیه‌سازی دقیق تبخیر ماهانه تأکید کردند و نشان دادند که این مدل می‌تواند تعاملات پیچیده بین متغیرهای ورودی را بدون پیش‌فرض درباره توزیع آن‌ها مدل‌سازی کند. مالک^۳ و همکاران (۲۰۲۱)، نشان دادند که مدل‌های ترکیبی شامل تکنیک‌های MLP در مناطق کشاورزی با اقلیم‌های متفاوت عملکرد برتری در برآورد تبخیر روزانه از تست تبخیر دارند، به گونه‌ای که مقادیر R^2 در برخی موارد تا ۰/۹۰۷ گزارش شده است. این امر نشان‌دهنده تطبیق‌پذیری بالای مدل‌های MLP در محیط‌های متنوع و پتانسیل آن‌ها برای پیش‌بینی دقیق تبخیر است. همچنین در تحقیقی شعبانی^۴ و همکاران (۲۰۲۰)، نشان دادند برآورد تبخیر با ورودی‌های دما (T)، رطوبت نسبی (RH)، سرعت باد (W) و ساعات آفتابی (S) مدل GRP با RMSE برابر ۱/۵۲۱، ۱/۲۴۴ و ۱/۲۵۴ میلی‌متر در روز بیشترین دقت را برای پیش‌بینی دارد.

تحلیل حساسیت

تحلیل حساسیت داده‌های ورودی به مدل‌ها برای به دست آوردن بهترین شبکه برازش شده برای پیش‌بینی در هر سه مدل انجام شد (شکل ۱۰). در هر مرحله با روش حذف یکی از داده‌های ورودی، مدل‌ها مجدداً آموزش داده شدند و عملکرد آن با ضریب تعیین بررسی شد. با

بخش آموزش به دلیل دارا بودن بیشترین داده‌های ورودی، معیار بررسی دقت مدل است. همان‌گونه که در جدول ۷ مشاهده می‌شود، داده‌ها در سه بخش با حداقل مقدار $R^2=0.87$ هستند که نشان‌گر دقت بالای مدل در شبیه‌سازی است و مهم‌ترین بخش ارزیابی مدل (بخش آموزش) و همچنین بخش تست خارجی که برای ارزیابی عملکرد مدل استفاده می‌شود، دارای بیشترین مقدار R^2 هستند که نشان می‌دهد توانایی و دقت مدل در پیش‌بینی تبخیر بالاست. همچنین در تحقیقی دیگر، به منظور شبیه‌سازی تبخیر در هند به مقایسه دو مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه پرداختند، نتایج نشان داد، که با به کار بردن چهار ورودی دما، رطوبت نسبی، سرعت باد و ساعات آفتابی به مدل عملکرد شبکه عصبی مصنوعی نسبت به رگرسیون خطی چندگانه بهتر بوده؛ برای مجموعه داده آزمون، R^2 برای ANN با قانون یادگیری DBD و L-M از ۰/۹۰۴۶ تا ۰/۸۹۷۵ متغیر است، از ۰/۹۶۰ تا ۰/۹۶/۲۵ و RMSE از ۱/۰۳۲ تا ۱/۰۰۶ به روش آزمون و خطا تغییر می‌کند (ساران^۱ و همکاران، ۲۰۱۷). در تحقیقی دیگر کومار و سینگ^۲ (۲۰۲۲)، نشان دادند که مدل RF برای برآورد تبخیر روزانه نسبت به مدل‌های سنتی دقت بیشتری دارد ($R^2 > 0.82$)، مدل RF در دوره آموزش عملکرد بسیار خوبی داشت، اما نتوانست برای دوره آزمایش تعمیم پیدا کند. در تحقیقی

3-Malik

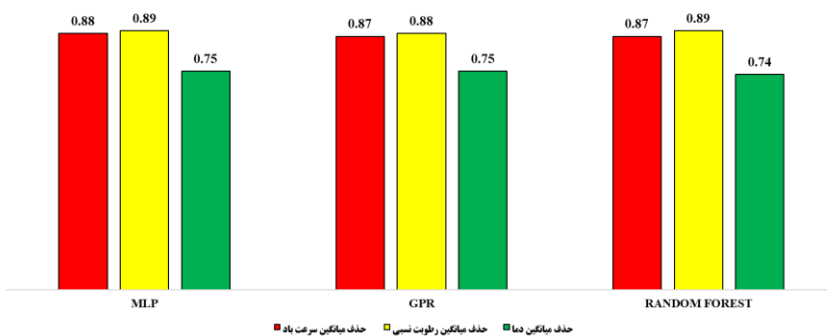
4 - Shabani

1 - Saran

2 - Kumar & Singh

مستقیم با تبخیر بوده و بیشترین اثرگذاری بین پارامترهای ورودی به آن تعلق می‌گیرد. در رتبه دوم میانگین رطوبت نسبی دارای رابطه عکس با تبخیر بوده و بعد از دما اثرگذاری زیادی بر روی تبخیر دارد.

توجه به تحلیل انجام شده، می‌توان بیان کرد که میانگین دما دارای بیشترین حساسیت و سرعت باد دارای کمترین حساسیت است. در جدول ۹ ضریب همبستگی هر یک از داده‌های ورودی و تأثیرگذاری آن‌ها بر تبخیر مشخص شد، نتایج نشان داد، که میانگین دمای روزانه دارای رابطه



شکل ۱۰- بررسی حساسیت حذف پارامترهای ورودی نسبت به متغیر هدف

جدول ۹- بررسی ضریب همبستگی و سطح معناداری بین داده‌های ورودی و خروجی به مدل‌ها

میانگین دما	میانگین رطوبت نسبی	میانگین سرعت باد	-	تبخیر روزانه
0.904**	-0.860**	0.394**	ضریب همبستگی	
.000	.000	.000	سطح معناداری دوطرفه	
2564	2564	2564	تعداد نمونه	

**همبستگی در سطح اطمینان ۹۹٪ (دوطرفه) معنادار است.

از شاخص‌های آماری همانند ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، میانگین مربعات خطا (MSE) استفاده شد. با بررسی نتایج و تحلیل عملکرد مدل‌ها با استفاده از شاخص‌های آماری، بالا بودن دقت هر سه مدل در پیش‌بینی پارامتر تبخیر اثبات شد. نتایج ارزیابی عملکرد مدل‌ها همانند R^2 ، RMSE، نشان داد، که در مدل پرسپترون داده‌ها در مرحله آموزش صحت‌سنجی ($R^2=0.92$) و ($RMSE=1.44$) عملکرد بهتری نسبت به صحت‌سنجی ($R^2=0.87$) و ($RMSE=1.77$) و آزمون ($R^2=0.91$) و ($RMSE=1.68$) دارد، همچنین نتایج ارزیابی کلی مدل ($R^2=0.93$) و ($RMSE=1.40$) نشانگر دقت بالای مدل در شبیه‌سازی تبخیر است؛ در الگوریتم جنگل تصادفی و رگرسیون فرایند گاوسی

جمع‌بندی

در این تحقیق آمار شش‌ساله ایستگاه اقلیم‌شناسی، کشت و صنعت دهخدا اهواز برای شبیه‌سازی تبخیر روزانه اندازه‌گیری شده به روش تشت تبخیر مورد استفاده قرار گرفت. برای شبیه‌سازی از مدل‌های الگوریتم جنگل تصادفی، رگرسیون فرایند گاوسی و شبکه عصبی پرسپترون استفاده شد. برای بالا بردن دقت مدل‌ها از روش اعتبارسنجی متقابل استفاده شد و داده‌ها در پنج تکرار برای هر مدل آموزش دیدند. در هر سه مدل تکرار پنجم بهترین نتیجه را داشت. در مدل MLP داده‌ها به سه بخش آموزش، صحت‌سنجی و آزمون تقسیم شدند. در مدل‌های RF و GPR داده‌ها به دو بخش آموزش و آزمون تقسیم شدند. برای صحت‌سنجی مدل‌ها

8. Astsatryan, H., Grigoryan, H., & Poghosyan, A. (2021). Air temperature forecasting using artificial neural network for Ararat valley. *Earth Science Informatics*, 14, 711–722. <https://doi.org/10.1007/s12145-021-00583-9>
9. Cao, J., Guinness, J., Genton, M. G., & Katzfuß, M. (2022). Scalable gaussian-process regression and variable selection using Vecchia approximations. *Journal of Computational and Graphical Statistics*, 31(4), 1–12. <https://doi.org/10.48550/arXiv.2202.12981>
10. Chen, N., Qian, Z., Nabney, I., & Meng, X. (2014). Wind power forecasts using Gaussian processes and numerical weather prediction. *IEEE Transactions on Power Systems*, 29(2), 656–665. <http://dx.doi.org/10.1109/TPWRS.2013.2282366>
11. Fu, X., Chen, Y., Yan, J., Chen, Y., & Xu, F. (2023). BGRF: A broad granular random forest algorithm. *Journal of Intelligent and Fuzzy Systems*, 44(5), 8103–8117. <http://dx.doi.org/10.3233/JIFS-223960>
12. Goode, K., Weber, M. J., Matthews, A., & Pierce, C. L. (2021). Evaluation of a random forest model to identify invasive carp eggs based on morphometric features. *North American Journal of Fisheries Management*, 43(1), 46–60. <https://doi.org/10.1002/nafm.10616>
13. Ignatenko, V., Surkov, A., & Koltcov, S. (2024). Random forests with parametric entropy-based information gains for classification and regression problems. *PeerJ Computer Science* 10, E1775. <https://doi.org/10.7717/peerj-cs.1775>
14. Ilma, H., Notodiputro, K. A., & Sartono, B. (2023). Association rules in random forest for the most interpretable model. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(1), 0185–0196. <https://doi.org/10.30598/barekengvol17iss1pp0185-0196>
15. Kim, J., & Lee, J. (2021). Identifiability of covariance kernels in the gaussian process regression model. *Journal of Computational and Graphical Statistics*, 30(4), 1234–1245. <https://doi.org/10.48550/arXiv.2108.04715>
16. Kumar, P., & Singh, A. K. (2022). A comparison between mlr, mars, svr and rf techniques: hydrological time-series modeling. *Journal of Human, Earth, and Future*, 3(1), 90–98. <https://doi.org/10.28991/hef-2022-03-01-07>
17. Lawati, Y. A., Kelly, J., & Stowell, D. (2020). Short-term prediction of photovoltaic power generation using Gaussian process regression. *Renewable Energy*, 157, 1022–1034. <https://doi.org/10.48550/arXiv.2010.02275>
18. Lubbe, F., Maritz, J., & Harms, T. (2020). Evaluating the potential of Gaussian process regression for solar radiation forecasting: A case study. *Energies*, 13(20), 5509. <https://doi.org/10.3390/en13205509>
19. Malik, A., Tikhmarine, Y., Al-Ansari, N., Shahid, S., Sekhon, H. S., Pal, R. K., & Sammen, S. S. (2021). Daily pan-evaporation estimation in different agro-climatic zones using novel hybrid support vector regression optimized by salp swarm algorithm in conjunction with gamma test.

نتایج ارزیابی به ترتیب $(R^2=0.93)$ و $(RMSE=1.41)$ ، $(R^2=0.93)$ و $(RMSE=1.42)$ بود. در هر سه مدل اختلاف در شاخص‌های آماری همانند ضریب تعیین بسیار کم و ناچیز بود؛ بنابراین برای صرفه‌جویی در هزینه‌های اندازه‌گیری و تخمین دقیق میزان تبخیر روزانه می‌توان از این سه مدل استفاده کرد و به‌طور کلی مدل MLP در رتبه اول، مدل RF در رتبه دوم و مدل GPR در رتبه سوم قرار دارند.

منابع

۱. امیدوار، ک.، نبوی زاده، م.، و ثمره قاسم، م. (۱۳۹۴). ارزیابی دقت شبکه عصبی مصنوعی بازگشتی نارکس در پیش‌بینی بارش روزانه در استان کرمان. *جغرافیای طبیعی*، ۲۷ (۸)، ۷۳–۸۹. <https://civilica.com/doc/1328549>
۲. بابائی، م.، لوانی، م.، و عرب، س.ر. (۱۴۰۱). پیش‌بینی دمای حداکثر با استفاده از روش ترکیب شبکه عصبی و تکامل تفاضلی (کاربرد داده‌کاوی در هواشناسی). *در: سومین کنفرانس ملی داده‌کاوی در علوم زمین*، اراک. <https://civilica.com/doc/1674136>
۳. پناهی، س.، کرباسی، م.، و نیکبخت، ج. (۱۳۹۵). پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه‌های عصبی مصنوعی MLP، RBF، و SVM محیط زیست و مهندسی آب، ۲ (۱)، ۶۳–۵۱. <https://civilica.com/doc/752518>
۴. پورمحمدی، س.، و انوری، ص. (۱۴۰۳). پیش‌بینی رواناب به کمک روش‌های آماری، هوش مصنوعی و مدل‌های هواشناسی (مطالعه موردی: سد امیرکبیر). *مدل‌سازی و مدیریت آب و خاک*، ۲ (۲)، ۴–۱۰۵–۱۲۰. <https://doi.org/10.22098/mmws.2023.12217.1210>
۵. شریفی، س.، منجزی، ن.، و حافظی، ن. (۱۳۹۹). عملکرد مدل‌های شبکه عصبی پرسپترون چندلایه و توابع پایه شعاعی در برآورد میزان محصول نیشکر. *دانش کشاورزی و تولید پایدار*، ۴ (۴)، ۳۰–۲۱۳–۲۲۸. <https://doi.org/10.22034/saps.2020.12313>
6. Al-Dahidi, S., Muhsen, H., Sari, M., Alrbai, M., Louzazni, M., & Omran, N. (2022). An adaptive approach-based ensemble for 1 day-ahead production prediction of solar PV systems. *Advances in Mechanical Engineering*, 14(3). <http://dx.doi.org/10.1177/16878132221089436>
7. Al-Sudani, Z. A., & Salem, G. S. A. (2022). Evaporation rate prediction using advanced machine learning models: a comparative study. *Advances in Meteorology*, 2022, 1-13. <https://doi.org/10.1155/2022/1433835>

31. Shabani, S., Samadianfard, S., Sattari, M. T., Shamshirband, S., Mosavi, A., Kmet', T., & Várkonyi-Kóczy, A. R. (2020). Modeling daily pan evaporation in humid climates using gaussian process regression. <https://doi.org/10.20944/preprints201907.0351.v1>
32. Shahi, S., Mousavi, S. F., & Hosseini, K. (2021). Simulation of pan evaporation rate by ANN artificial intelligence model in Damghan Region. *Journal of Soft Computing in Civil Engineering*, 5(3), 75–87. <https://doi.org/10.22115/scce.2021.286933.1321>
33. Stucke, I., Morgenstern, D., Diendorfer, G., Mayr, G. J., Pichler, H., Schulz, W., & Zeileis, A. (2021). Spatio-seasonal risk assessment of upward lightning at tall objects using meteorological reanalysis data. *Earth and Space Science*, 12(2). <https://doi.org/10.1029/2023JD039505>
34. Taqiyuddin, M., & Sasongko, T. B. (2024). Prediksi cuaca kabupaten Sleman menggunakan algoritma random forest. *Jurnal Media Informatika Budidarma*, 8(3), 1683-1692. <https://doi.org/10.30865/mib.v8i3.7897>
35. Wang, B., & Chen, T. (2015). Gaussian process regression with multiple response variables. *Chemometrics and Intelligent Laboratory Systems*, 142, 159–165. <https://doi.org/10.1016/j.chemolab.2015.01.016>
36. Wang, S., Gong, J., Gao, H., Liu, W., & Feng, Z. (2023). Gaussian process regression and cooperation search algorithm for forecasting nonstationary runoff time series. *Water*, 15(11), 2111. <https://doi.org/10.3390/w15112111>
37. Yang, X., Barajas-Solano, D. A., Tartakovsky, G., & Tartakovsky, A. M. (2019). Physics-informed cokriging: A Gaussian-process-regression-based multifidelity method for data-model convergence. *Journal of Computational Physics*, 395, 410–431. <https://doi.org/10.1016/j.jcp.2019.06.041>
38. Zhang, W., Li, Z., & Tian, Y. (2025). Research on temperature prediction based on RF-LSTM modeling. *TechRxiv*. <https://doi.org/10.36227/techrxiv.173603336.69370585/v3>
39. Zhang, Y., & Xu, X. (2020). Machine learning properties of electrolyte additives: A focus on redox potentials. *Industrial and Engineering Chemistry Research*, 60(1), 343–354. <https://doi.org/10.1021/acs.iecr.0c05055>
20. Meenal, R., Angel, P., Pamela, D., & Rajasekaran, E. (2021). Weather prediction using random forest machine learning model. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(3), 1208-1215. <http://dx.doi.org/10.11591/ijeecs.v22.i2>
21. Möller, A., Lenkoski, A., & Thorarinsdottir, T. L. (2012). Multivariate probabilistic forecasting using ensemble bayesian model averaging and copulas. *Quarterly Journal of the Royal Meteorological Society*, 139(673), 982-991. <https://doi.org/10.1002/qj.2009>
22. Park, C., Borth, D. J., Wilson, N. S., Hunter, C. N., & Friedersdorf, F. (2020). Robust gaussian process regression with a bias model. *Journal of Machine Learning Research*, 21(1), 1-25. <https://doi.org/10.1016/j.patcog.2021.108444>
23. Patan, K. (2019). Neural networks. In K. Patan (Ed.), *Neural networks: Robust and fault-tolerant control neural-network-based solutions* (pp. 9–58). Springer. https://doi.org/10.1007/978-3-030-14195-0_2
24. Patle, G. T., Chettri, M., & Jhajharia, D. (2020). Monthly pan evaporation modelling using multiple linear regression and artificial neural network techniques. *Water Supply*, 20(3), 800–808. <https://doi.org/10.2166/ws.2019.189>
25. Phan, A. T., Vu, T. T. H., Nguyen, D. Q., Sanseverino, E. R., Thuý, H. L. T., & Bui, V. C. (2022). Data compensation with Gaussian processes regression: Application in smart building's sensor network. *Energies*, 15(23), 9190. <https://doi.org/10.3390/en15239190>
26. Putra, A. F. D., Azmi, M. N., Wijayanto, H., & Utama, S. P., Wirawan, I. (2024). Optimizing rain prediction model using random forest and grid search cross-validation for agriculture sector. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 23(3), 519–530. <https://doi.org/10.30812/matrik.v23i3.3891>
27. Qamar, R., & Zardari, B. (2023). Artificial Neural Networks: An Overview. *Mesopotamian Journal of ComputerScienc*, 1-9. <https://doi.org/10.58496/MJCSC/2023/015>
28. Qasem, S. N., Kisi, O., Salih, S. Q., & Al-Ansari, N. (2019). Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. *Engineering Applications of Computational Fluid Mechanics*, 13(1), 177–187. <https://doi.org/10.1080/19942060.2018.1564702>
29. Saran, B. K., & Kumar, P. P. (2017). Evaporation estimation by multilayer perceptron based artificial neural network and multiple linear regression techniques. *Indian Journal of Ecology*. 44(1). 108-112.
30. Segovia, J. A., Toaquiza, J. F., Llanos, J. R., & Rivas, D. R. (2023). Meteorological variables forecasting system using machine learning and open-source software. *Electronics*, 12(10), 1007. <https://doi.org/10.3390/electronics12041007>

Comparison of the Performance of Machine Learning Algorithms MLP, RF, and GPR in Evaporation Prediction: A Case Study of Ahvaz

Mohammad Parvizpour¹. Payam Zali Kakash². Hakim Naseri³. Zeynab Hamid^{4*}

¹Head of Applied Water and Soil Studies Department, Dehkadeh Sugarcane Agro-Industry, Ahvaz, Iran

² Manager of Applied Studies, Dehkadeh Sugarcane Agro-Industry, Ahvaz, Iran

³ Deputy of Agriculture, Dehkadeh Sugarcane Agro-Industry, Ahvaz, Iran

⁴ Ph.D. Student in Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Iran

*Corresponding Author Email: Enzeynabhamid@gmail.com

Received: 15 July 2025, Accepted: 30 August 2025

ABSTRACT

Evaporation plays a crucial role in the hydrological cycle. In warm climates, water loss due to evaporation from rivers, canals, and open water surfaces poses a significant challenge, making the use of reliable predictive models essential. This study assesses the performance of three advanced models—Multilayer Perceptron (MLP) neural network, Random Forest (RF) algorithm, and Gaussian Process Regression (GPR)—in forecasting evaporation rates. Six years of daily meteorological data were utilized, including mean wind speed, air temperature, relative humidity, and evaporation, recorded at the Dehkhoda agro-Industrial meteorological station in Ahvaz. Model outputs were compared with observed values, and all analyses were conducted using MATLAB 2022. Evaluation metrics such as the coefficient of determination (R^2) and root mean square error (RMSE) indicated that the MLP model achieved the highest accuracy during the training phase ($R^2 = 0.92$, RMSE = 1.44), outperforming both the validation ($R^2 = 0.87$, RMSE = 1.77) and testing ($R^2 = 0.91$, RMSE = 1.68) phases. The overall performance of the MLP model ($R^2 = 0.93$, RMSE = 1.40) confirmed its strong predictive capability. The RF and GPR models also demonstrated high accuracy, with overall results of $R^2 = 0.93$, RMSE = 1.41 and $R^2 = 0.93$, RMSE = 1.42, respectively. Based on these findings, the MLP model is recommended as the primary tool for evaporation prediction, followed closely by RF and GPR.

Keywords: Perceptron, Random Forest, Gaussian Regression, Evaporation, Prediction

HOW TO CITE THIS ARTICLE

Parvizpour, M. , Zali Kakash, P. , Naseri, H., Hamid, Z. (2025). Comparison of the Performance of Machine Learning Algorithms MLP, RF, and GPR in Evaporation Prediction: A Case Study of Ahvaz. *Journal of Meteorology and Atmospheric Science.*, 7(2): 01-19. Doi: 10.22034/jmas.2025.534726.1246

COPYRIGHTS

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

