ASPI | Afarand Scholarly Publishing Institute; Turkey
ISSN: 2538-4384; Geographical Researches. 2025;40(3):243-252 10.58209/geores.40.3.243

Role of Surface and Upper-Air Data in Predicting Daily Minimum Temperature

ARTICLE INFO

Article Type
Original Research

Authors
Babaeian A.H.* *MSc*

How to cite this article
Babaeian AH. Role of Surface and Upper-Air Data in Predicting Daily Minimum Temperature. Geographical Researches. 2025;40(3):243-252.

Department of Industrial Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

Correspondence
Address: Department of Industrial Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Azadi Square, Mashhad, Iran. Postal Code: 917794895
Phone: +98 (51) 38806000
babaeian.am@gmail.com

Article History
Received: July 27, 2025
Accepted: September 17, 2025
ePublished: September 27, 2025

ABSTRACT

Aims Accurate prediction of daily minimum temperature (Tmin) plays a crucial role in agricultural management, frost prevention, and energy consumption. Despite advances in machine learning methods, systematic comparisons of surface and upper-air data performance for Tmin prediction in arid and semi-arid regions such as Mashhad remain limited. This study evaluates five ensemble learning algorithms (CatBoost, XGBoost, LightGBM, AdaBoost, and Random Forest) under three data scenarios: Upper-air, surface, and combined, for next-day Tmin prediction.

Methodology The present study is applied in nature and was conducted in 2025 using data collected from the Mashhad meteorological station. Daily meteorological data from the Mashhad synoptic station and ERA5 reanalysis at 300, 500, and 700 hPa levels were utilized for the period 2000-2023. All predictors were incorporated with a one-day lag relative to the target Tmin. The algorithms were trained using cross-validation. Multicollinearity among predictors was controlled using the VIF, and the optimal subset of features was determined through the Best Subset Selection (BSS) method based on the coefficient of determination (R2).

Findings Integrating surface and upper-air data significantly improved the accuracy and stability of the models. In the combined scenario, the LightGBM algorithm achieved the best performance on the test set (R2=93.90%, MAE=1.63°C, RMSE=2.10°C, and KGE=0.93). The BSS method identified five key predictors (Tmin, relative humidity and specific humidity at 700 hPa, minimum surface humidity, and the categorical variable for summer season) as the most influential combination, effectively integrating upper-air thermodynamic and surface conditions.

Conclusion Combining surface and upper-air data within the LightGBM framework, along with systematic feature selection, provides the most accurate approach for short-term Tmin prediction.

Keywords Daily Minimum Temperature Prediction; Ensemble Learning; Surface Data; Upper-Air Data; Mashhad

CITATION LINKS

[Aghalpoor & Nadi , 2018] Comparison of the performance of autoregressive and moving average ...; [Ahadi *et al.*, 2025] Projection of future drought trends in Iran using the CMIP6 ...; [Asakereh & Matlabizad, 2017] Comparison of the performance of SDSM and artificial neural network ...; [Chai & Draxler, 2014] Root mean square error (RMSE) or mean absolute error (MAE)? ...; [Cohen *et al.*, 2020] Divergent consensuses on arctic amplification influence on midlatitude ...; [Elbeltagi *et al.*, 2025] Air temperature estimation and modeling using data driven ... [Fan *et al.*, 2018] Evaluating the effect of air pollution on global ...; [Ghaffari *et al.*, 2024] Weather analysis with deep learning based on ...; [Hanoon *et al.*, 2021] Developing machine learning algorithms for meteorological temperature ...; [Hosseini & Alamatiyan, 2022] Using machine learning methods to predict air temperature ...; [Huang *et al.*, 2019] A prediction scheme for daily maximum and minimum ...; [IPCC, 2023] Climate change 2021-the physical science basis ...; [Jose *et al.*, 2022] Improving multiple model ensemble predictions of daily ...; [Karimi *et al.*, 2020] Evaluation of the support vector machine, random forest ...; [Kisi *et al.*, 2025] Integration of Gaussian process regression and K means ...; [Kretschmer *et al.*, 2018] The different stratospheric influence on cold-extremes in Eurasia ...; [Lee, 2025] Estimating near-surface air temperature from satellite-derived ...; [Oduro *et al.*, 2026] Leveraging machine learning for accurate near-surface ...; [Pande *et al.*, 2024] Forecasting of meteorological drought using ensemble and machine ...; [Roshani *et al.*, 2023] Analyzing trend and forecast of rainfall and temperature in Valmiki Tiger ...; [Sattari *et al.*, 2024] Modeling daily and monthly rainfall in Tabriz using ensemble learning ...; [Shahabi & Izadi, 2024] Evaluation of different regression modeling approaches for temperature prediction ...; [Shokouhi *et al.*, 2024] Bias correction of short-term minimum and maximum temperature ...; [Tabatabaei *et al.*, 2018] Performance comparison of GP, ANN, BCSD and SVM models ...; [Ustaoglu *et al.*, 2008] Forecast of daily mean, maximum and minimum temperature time ...; [Zhou *et al.*, 2023] Atmosphere air temperature forecasting using the honey badger optimization algorithm ...;

Copyright© 2025, the Authors | Publishing Rights, ASPI. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.

نقش داده‌های سطح زمین و جو بالا در پیش‌بینی دمای حداقل

امیرحسین بابائیان* MSc
گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

چکیده

اهداف: پیش‌بینی دمای حداقل روزانه نقشی اساسی در مدیریت کشاورزی، پیشگیری از سرمازدگی و مصرف انرژی دارد. با وجود پیشرفت روش‌های یادگیری ماشین، مقایسه نظام‌مند کارآیی داده‌های سطح زمین و جو بالا در پیش‌بینی دمای حداقل مناطق خشک و نیمه‌خشک همچون مشهد کمتر انجام شده است. این پژوهش با هدف ارزیابی پنج الگوریتم یادگیری گروهی شامل CatBoost، XGBoost، LightGBM، AdaBoost و Random Forest در سه سناریو (جو بالا، سطح زمین و ترکیب هر دو) برای پیش‌بینی دمای حداقل روز بعد انجام شد.

روش‌شناسی: پژوهش حاضر از نوع کاربردی بوده و در سال ۱٤۰٤ بر روی داده‌های جمع‌آوری‌شده از ایستگاه هواشناسی مشهد انجام شد. داده‌های روزانه ایستگاه سینوپتیک مشهد و بازتحلیل ERA5 در ترازهای ۳۰۰، ۵۰۰ و ۷۰۰ هکتوپاسکال طی سال‌های ۲۰۰۰ تا ۲۰۲۳ استفاده شدند. همه متغیرها با تاخیر یک‌روزه نسبت به دمای هدف وارد مدل گردیدند. الگوریتم‌ها با اعتبارسنجی متقاطع زمانی آموزش داده شدند. برای کنترل هم‌خطی از شاخص VIF استفاده و ویژگی‌های بهینه با روش انتخاب بهترین زیرمجموعه براساس R^2 انتخاب شد.

یافته‌ها: ادغام داده‌های سطح زمین و جو بالا دقت و پایداری مدل‌ها را به طور معنادار بهبود داد. در سناریوی ترکیبی، الگوریتم LightGBM بهترین عملکرد را روی داده‌های آزمون به‌دست آورد (R^2=٪۹۳/۹۰، MAE=۱/٦۳°C، RMSE=۲/۱۰°C و KGE=۰/۹۳). روش انتخاب ویژگی بهترین زیرمجموعه پنج متغیر کلیدی شامل دمای حداقل روز قبل، رطوبت نسبی و رطوبت ویژه تراز ۷۰۰ هکتوپاسکال، رطوبت نسبی حداقل سطح زمین و متغیر مجازی فصل تابستان را به عنوان موثرترین ترکیب شناسایی کرد.

نتیجه‌گیری: ترکیب داده‌های سطح زمین و جو بالا در قالب مدل LightGBM، همراه با انتخاب ویژگی نظام‌مند، دقیق‌ترین چارچوب برای پیش‌بینی کوتاه‌مدت دمای حداقل روزانه فراهم می‌کند.

کلیدواژگان: پیش‌بینی روزانه دمای کمینه، روش‌های یادگیری، داده‌های سطح زمین، داده‌های جو بالا، مشهد

تاریخ دریافت: ۱۴۰۴/۰۵/۰۵
تاریخ پذیرش: ۱۴۰۴/۰۶/۲۶

*نویسنده مسئول: babaeian.am@gmail.com

مقدمه

گرمایش جهانی اگرچه به طور میانگین موجب افزایش دمای کمینه شده است [IPCC, 2023]، اما از طریق مکانیزم‌هایی مانند تضعیف تاوه قطبی، می‌تواند منجر به نفوذ هوای سرد قطبی به عرض‌های پایین‌تر و افزایش رویدادهای حدی سرد شود [Kretschmer *et al.*, 2018; Cohen *et al.*, 2020]. این پدیده، پیش‌بینی دقیق دمای کمینه را در مناطق با اقلیم پیچیده مانند ایران که اقتصاد آن وابسته به کشاورزی است، به موضوعی راهبردی تبدیل کرده است. پیش‌بینی به موقع دمای کمینه، امکان اجرای تمهیدات حفاظتی مانند آبیاری بارانی و استفاده از پوشش‌های محافظ را در برابر یخبندان‌های دیررس بهاره فراهم می‌کند. همچنین این پیش‌بینی در مدیریت مصرف انرژی و برنامه‌ریزی حمل و نقل در شرایط یخبندان نقش کلیدی ایفا می‌نماید.

روش‌های مرسوم پیش‌بینی عددی وضع هوا به دلیل وضوح مکانی درشت و هزینه‌های محاسباتی بالا، در پیش‌بینی پارامترهای محلی با محدودیت مواجه هستند. در این راستا، روش‌های یادگیری ماشین به عنوان جایگزینی قدرتمند با توانایی یادگیری الگوهای پیچیده از داده‌های تاریخی مطرح شده‌اند. با این حال، کاربرد سامانمند این روش‌ها در پیش‌بینی دمای کمینه، به‌ویژه در ایران، کمتر مورد توجه قرار گرفته است. یکی از چالش‌های اصلی در این زمینه، انتخاب مجموعه داده‌های ورودی بهینه است. این سوال اساسی مطرح است که آیا داده‌های سطح زمین به‌تنهایی کافی هستند، یا تلفیق آنها با داده‌های جو بالا برای دستیابی به دقت مطلوب ضروری است؟ پاسخ به این پرسش می‌تواند به طراحی مدل‌های کارآمدتر و قابل اعتمادتر برای پیش‌بینی دمای حداقل بیانجامد.

مطالعات متعددی کارآیی یادگیری ماشین در پیش‌بینی دما را در مناطق مختلف تایید کرده‌اند. برای نمونه *فان* و همکاران [Fan *et al.*, 2018] با استفاده از SVM و ELM به پیش‌بینی دقیق دما در پکن پرداخته‌اند. *اوستاوغلو* و همکاران [Ustaoglu *et al.*, 2008] با مقایسه سه مدل شبکه عصبی و رگرسیون خطی برای پیش‌بینی دمای روزانه در ترکیه، دریافتند مدل RBF با R^2=۰/۹۸ و RMSE=۱/٦٤ بهترین عملکرد را در پیش‌بینی دمای حداقل داشته است. *جوزه* و همکاران [Jose *et al.*, 2022] با ارزیابی الگوریتم‌های یادگیری ماشین برای پیش‌بینی دما از داده‌های CMIP5 و CMIP6، دریافته‌اند که مدل LSTM با R^2=۰/۸۹ و RMSE=۱/۰٤ دقیق‌ترین نتایج را در پیش‌بینی دمای حداقل روزانه داشته است. *هوانگ* و همکاران [Huang *et al.*, 2019] با ارایه مدل ترکیبی شبکه عصبی بازگشتی برای پیش‌بینی دمای روز بعد در چین، نشان داده‌اند که حدود ۸۰٪ از پیش‌بینی‌های دمای حداقل با خطای کمتر از ۲ درجه و ۵۰٪ آنها با خطای زیر ۱ درجه سلسیوس محقق شده است. الگوریتم‌های پیشرفته‌تر نیز نتایج امیدوارکننده‌ای داشته‌اند، *ژو* و همکاران [Zhou *et al.*, 2023] با مدل ترکیبی HBA-ANN به دقت بالا در مناطق گرم دست یافته‌اند و *اودورو* و همکاران [Oduro *et al.*, 2026] در غنا، عملکرد برتر SVR را بین پنج الگوریتم مورد آزمایش گزارش کرده‌اند. در مصر، *البلتاگی* و همکاران [Elbeltagi *et al.*, 2025] مدل M5P را دقیق‌ترین روش برای پیش‌بینی دمای کمینه معرفی نموده‌اند. همچنین مدل‌های یادگیری عمیق مانند LSTM، TCN و N-BEATS [Lee, 2025] و روش‌های کلاسیک مانند جنگل تصادفی و شبکه‌های عصبی [Hanoon *et al.*, 2021; Roshani *et al.*, 2023] نیز در پیش‌بینی پارامترهای جوی موفق عمل کرده‌اند.

عاقل‌پور و *نادی* [Aghalpoor & Nadi, 2018] در مطالعه‌ای با مقایسه مدل‌های سری‌زمانی اتورگرسیو (AR) و میانگین متحرک (MA) برای پیش‌بینی دمای روزانه در رشت، دریافته‌اند که از بین

مدل‌های آماری سری زمانی، مدل خودهمبستگی با شاخص R^2=٪۹٤/۵ بهترین عملکرد را دارد. *عساکره* و *مطلبی‌زاد* [Asakereh & Matlabizad, 2017] در پژوهشی با مقایسه دو مدل SDSM و شبکه عصبی مصنوعی در پیش‌بینی دمای حداقل در ارومیه، دریافته‌اند که مدل شبکه عصبی با ضریب تبیین ۰/۹۳ و خطای ۲/۲۷ درجه، دقت بالاتری دارد. *شهابی* و *ایزدی* [Shahabi & Izadi, 2024] در پژوهشی با مقایسه هشت مدل رگرسیونی برای پیش‌بینی دمای خیلی کوتاه‌مدت، دریافته‌اند که مدل SVR با ضریب تبیین ۰/۹۹۳ و خطای ۰/۵۸ درجه، دقیق‌ترین عملکرد را دارد. *کریمی* و همکاران [Karimi *et al.*, 2020] در مطالعه‌ای روی ۳۰ ایستگاه هواشناسی ایران، برتری جنگل تصادفی را نشان داده‌اند. *طباطبایی* و همکاران [Tabatabaei *et al.*, 2018] در شبیه‌سازی دمای روزانه اهواز، مدل SVM را با ضریب همبستگی ۰/۹۹٦ و RMSE معادل ۰/٦۸ درجه سانتی‌گراد به عنوان دقیق‌ترین روش معرفی کرده‌اند. در حوزه تصحیح خطای مدل‌های عددی، *شکوهی* و همکاران [Shokouhi *et al.*, 2024] با به‌کارگیری ماشین بردار پشتیبان، مهارت مدل WRF در پیش‌بینی دمای کمینه و بیشینه را به طور قابل توجهی بهبود بخشیده‌اند به طوری که نمره مهارت برای دمای بیشینه از ۰/۱- به ۰/۸۵ و برای دمای کمینه از ۰/۳۸ به ۰/۷۲ افزایش یافت. همچنین، *حسینی* و *علامتیان* [Hosseini & Alamatiyan, 2022] در پیش‌بینی دمای مشهد عملکرد برتر مدل MLP را نسبت به SVR تایید می‌کنند. در مطالعه‌ای دیگر، *غفاری* و همکاران [Ghaffari *et al.*, 2024] با ترکیب الگوریتم یادگیری کلاغ و LSTM به دقت ۹٦/۹۲٪ در پیش‌بینی دمای حداقل دست یافته‌اند که بهبود محسوسی نسبت به کاربرد جداگانه این مدل‌ها نشان می‌دهد. این پژوهش با هدف بررسی کارآیی الگوریتم‌های یادگیری ماشین در پیش‌بینی دمای حداقل روزانه انجام شد؛ بدین منظور عملکرد پنج الگوریتم CatBoost، XGBoost، LightGBM، AdaBoost و جنگل تصادفی در سه سناریوی داده‌ای سطح زمین، جو بالا و ترکیبی مقایسه گردید و اثر تلفیق داده‌ها و انتخاب ویژگی متوالی بر دقت و سادگی مدل مورد ارزیابی قرار گرفت.

روش‌شناسی

پژوهش حاضر از نوع کاربردی بوده و در سال ۱٤۰٤ بر روی داده‌های جمع‌آوری‌شده از سال‌های۲۰۰۰ تا ۲۰۲۳ در ایستگاه هواشناسی مشهد انجام شد.

داده‌ها

در این مطالعه، به منظور پیش‌بینی دمای کمینه روزانه در ایستگاه هواشناسی مشهد، از دو مجموعه داده مجزای سطح زمین و جو بالا و همچنین ترکیب این دو مجموعه استفاده گردید. این رویکرد با هدف تلفیق شرایط جوی محلی در سطح زمین با متغیرهای دینامیکی و ترمودینامیکی جو بالا طراحی شد. داده‌های مورد استفاده در بازه زمانی ۲۰۰۰ تا ۲۰۲۳ جمع‌آوری شده و برای ارزیابی عملکرد مدل‌ها، به دوره آموزش ۲۰۱۷-۲۰۰۰ و دوره آزمون ۲۰۲۳-۲۰۱۸ تقسیم‌بندی شدند.

متغیرهای منبع اول شامل دمای بیشینه، دمای کمینه، دمای میانگین، رطوبت نسبی بیشینه، رطوبت نسبی کمینه، رطوبت نسبی میانگین، سرعت باد، فشار هوا در سطح دریا، میزان ابرناکی و بارش ۲۴ساعته بودند. افزون بر این متغیرها، یک ویژگی طبقه‌ای با عنوان فصل نیز به داده‌ها افزوده شد که چهار حالت «بهار»، «تابستان»، «پاییز» و «زمستان» را شامل می‌شد. لازم به ذکر است که تمامی متغیرهای اصلی عددی بوده و با یک روز تاخیر زمانی (lag=۱) نسبت به روز هدف در مدل استفاده شدند. آمار توصیفی متغیرهای سطح زمین شامل مقادیر میانگین، حداقل، حداکثر، چارک‌های اول تا سوم و انحراف‌معیار محاسبه شد تا به درک بهتر دامنه تغییرات و پراکندگی داده‌ها کمک نماید (جدول ۱).

جدول ۱) فهرست متغیرهای سطح زمین و توصیف کلی آنها

نام متغیر (واحد)	میانگین	حداقل	حداکثر	چارک اول	چارک دوم	چارک سوم
Tmax دمای بیشینه (°C)	۲۲/٦۷±۱۰/٦۹	-۱۰/۱۰	٤۳/٤۰	۱٤	۲۳/۷	۳۲/۳
Tmin دمای کمینه (°C)	۹/۵۵±۸/٦	-۲۱/۰۰	۲۹/۳۰	۲/۳۵	۹/۷	۱۷/۲
Tave دمای میانگین (°C)	۱۵/۸٦±۹/۸۵	-۱٤/٦۰	۳٤/۸۰	۷/۵	۱٦/۳	۲۵
Umax رطوبت نسبی بیشینه (درصد)	٦٦/۳۵±۲٤/۹	۱۵/۰۰	۱۰۰	٤۳	٦۸	۹۱
Umin رطوبت نسبی کمینه (درصد)	۳۰/٤۵±۲۰/۵۹	۱/۰۰	۱۰۰	۱۵	۲۵	٤۱
Uave رطوبت نسبی میانگین (درصد)	٤۷/٤۹±۲۲/۹٤	۹/۸۸	۱۰۰	۲۷/۵	٤٤/۱۲	٦۵/۵
WS سرعت باد (متر بر ثانیه)	۲/۷۲±۱/۲	۰	۱۰	۱/۸۸	۲/٦۲	۳/۵
MSLP فشار در سطح دریا (hPa)	۱۰۱٤/٦٦±۸/۵۱	۹۹۲/۲٦	۱۰٤۳/۷۲	۱۰۰۷/۸۹	۱۰۱٤	۱۰۲۰/۹
nm میزان ابرناکی (اکتا)	٤/۳۸±۲/۱	۰	۸	۳/۱۵	٤/۸	٦/۱٤
R24بارش روزانه (میلی‌متر)	۰/٦۲±۲/٦۲	۰	٤۷/۲۰	۰	۰	۰

منبع دوم داده‌ها از پایگاه بازتحلیلی ERA5 وابسته به مرکز پیش‌بینی میان‌مدت هواشناسی اروپا (ECMWF) اخذ شد. این داده‌ها برای مختصات جغرافیایی ایستگاه مشهد و با تفکیک روزانه استخراج گردیدند. متغیرهای انتخابی شامل ارتفاع ژئوپتانسیل، رطوبت نسبی، رطوبت ویژه، مولفه‌های افقی باد (u و v)، چرخندگی و دما در سه تراز فشاری ۷۰۰، ۵۰۰ و ۳۰۰ هکتوپاسکال اسنپت که به‌ترتیب به عنوان نماینده سطوح زیرین، میانی و فوقانی تروپوسفر در نظر گرفته شدند. انتخاب این ترازهای فشاری به گونه‌ای صورت پذیرفت که

بتوانند لایه‌های موثر در دمای هوا را پوشش دهند به طور مشابه با داده‌های سطح زمین، در این مجموعه داده نیز کلیه متغیرها از نوع عددی بوده و با یک روز تاخیر زمانی نسبت به روز هدف در مدل مورد استفاده قرار گرفتند. همچنین، ویژگی طبقه‌ای فصل به منظور لحاظ کردن اثرات تغییرات فصلی بر ساختار دینامیکی و ترمودینامیکی جو افزوده و همانند داده‌های سطح زمین به صورت متغیر مجازی کدگذاری شد. آمار توصیفی متغیرهای جو بالا شامل مقادیر میانگین، حداقل، حداکثر، چارک‌ها و انحراف‌معیار نیز محاسبه گردید (جدول ۲). متغیرهای جو بالا به همراه آمار توصیفی آنها نیز جمع‌آوری شدند (جدول ۲). در این جدول، پیشوند GH بیانگر ارتفاع ژئوپتانسیل (بر حسب متر)، Rel-Hum نشان‌دهنده رطوبت نسبی (بر حسب درصد) و Spe-Hum نشان‌دهنده رطوبت ویژه (گرم بر کیلوگرم) است. مولفه‌های u و v به‌ترتیب نشان‌دهنده مولفه‌های افقی باد در راستای مداری (شرقی-غربی) و نصف‌النهاری (شمالی-جنوبی) هستند. متغیر Vort بیانگر چرخندگی افقی جو (بر حسب بر ثانیه) است که به عنوان شاخصی برای ارزیابی ناپایداری جوی استفاده می‌شود. همچنین متغیر Temp دمای هوا (بر حسب کلوین) را در ترازهای فشاری مختلف نشان می‌دهد.

جدول ۲) فهرست متغیرهای جو بالا و توصیف کلی آنها

نام شاخص/تراز (واحد)	میانگین	حداقل	حداکثر	چارک اول	چارک دوم	چارک سوم
GH300 ارتفاع ژئوپتانسیل ۳۰۰ هکتوپاسکال (متر)	۹۲۳۸/۲۰۶/۳±۵	۸۶۸۲/۶	۹۶۳۵/۷	۹۰۶۹	۹۲۴۷/۶	۹۴۱۷/۲
GH500 ارتفاع ژئوپتانسیل ۵۰۰ هکتوپاسکال (متر)	۵۶۳۴/۳±۱۰۳/۹	۵۳۱۶/۸	۵۸۲۰/۳	۵۵۵۲/۱	۵۶۵۴/۱	۵۷۲۲/۶
GH700 ارتفاع ژئوپتانسیل ۷۰۰ هکتوپاسکال (متر)	۳۰۴۵/۹±۴۶/۱	۲۸۴۲/۹	۳۱۵۹/۳	۳۰۱۵/۹	۳۰۵۶/۱	۳۰۸۰/۸
Rel-Hum300 رطوبت نسبی ۳۰۰ هکتوپاسکال (درصد)	۳۷/۶±۲۸/۸	۰/۸	۱۰۷	۱۰/۹	۳۲/۵	۶۰/۴
Rel-Hum500 رطوبت نسبی ۵۰۰ هکتوپاسکال (درصد)	۳۶/۵±۲۳/۱	۰/۹	۱۰۲/۸	۱۶/۴	۳۳/۷	۵۴
Rel-Hum700 رطوبت نسبی ۷۰۰ هکتوپاسکال (درصد)	۴۴/۱±۲۰/۸	۱/۶	۹۷/۸	۲۸/۶	۴۲	۵۸/۷
Spe-Hum300 رطوبت ویژه ۳۰۰ هکتوپاسکال (گرم بر کیلوگرم)	۰	۰	۰/۰۰۱	۰	۰	۰
Spe-Hum500 رطوبت ویژه ۵۰۰ هکتوپاسکال (گرم بر کیلوگرم)	۰/۰۰۱±۰/۰۰۱	۰	۰/۰۰۴	۰	۰/۰۰۱	۰/۰۰۱
Spe-Hum700 رطوبت ویژه ۷۰۰ هکتوپاسکال (گرم بر کیلوگرم)	۰/۰۰۳±۰/۰۰۲	۰	۰/۰۰۹	۰/۰۰۲	۰/۰۰۳	۰/۰۰۴
u300 مولفه مداری باد در تراز ۳۰۰ هکتوپاسکال (متر بر ثانیه)	۲۱/۶±۱۲/۱	-۲۱/۶	۷۸/۲	۱۳/۵	۲۰/۸	۲۸/۶
u500 مولفه مداری باد در تراز ۵۰۰ هکتوپاسکال (متر بر ثانیه)	۱۰/۵±۷/۳	-۱۳/۵	۳۹/۷	۵/۳	۱۰/۶	۱۵/۵
u700 مولفه مداری باد در تراز ۷۰۰ هکتوپاسکال (متر بر ثانیه)	۳/۲±۶/۱	-۱۵/۸	۲۴/۲	۸۹۹+۸۹-۱/۲	۳/۱	۷/۲
v300 مولفه نصف‌النهاری باد در تراز ۳۰۰ هکتوپاسکال (متر بر ثانیه)	-۱/۲±۹/۹	-۴۰/۷	۴۷/۷	-۷/۵	-۱/۶	۴/۸
v500 مولفه نصف‌النهاری باد در تراز ۵۰۰ هکتوپاسکال (متر بر ثانیه)	-۱/۱±۶/۶	-۲۸/۹	۲۷/۶	-۵/۶	-۱/۷	۳
v700 مولفه نصف‌النهاری باد در تراز ۷۰۰ هکتوپاسکال (متر بر ثانیه)	-۰/۶±۴/۳	-۱۵/۵	۱۶/۶	-۳/۶	-۰/۵	۲/۳
Vort300 چرخندگی افقی در تراز ۳۰۰ هکتوپاسکال (بر ثانیه)	۰	۰	۰	۰	۰	۰
Vort500 چرخندگی افقی در تراز ۵۰۰ هکتوپاسکال (بر ثانیه)	۰	۰	۰	۰	۰	۰
Vort700 چرخندگی افقی در تراز ۷۰۰ هکتوپاسکال (بر ثانیه)	۰	۰	۰	۰	۰	۰
Temp300 دمای هوا در تراز ۳۰۰ هکتوپاسکال (کلوین)	۲۳۳/۱±۸/۰	۲۱۶/۵	۲۵۱/۷	۲۲۶/۸	۲۳۱/۱	۲۳۹/۹
Temp500 دمای هوا در تراز ۵۰۰ هکتوپاسکال (کلوین)	۲۵۸/۹±۶/۶	۲۳۷/۹	۲۷۵	۲۵۳/۷	۲۵۹	۲۶۴/۵
Temp700 دمای هوا در تراز ۷۰۰ هکتوپاسکال (کلوین)	۲۷۶/۴±۷/۱	۲۵۳/۴	۲۹۲/۲	۲۷۰/۹	۲۷۷/۱	۲۸۲/۴

سیستم نام‌گذاری متغیرها به گونه‌ای است که عدد انتهایی هر متغیر، تراز فشاری مربوطه (بر حسب هکتوپاسکال) را مشخص می‌کند. به عنوان مثال، GH500 بیانگر ارتفاع ژئوپتانسیل در تراز ۵۰۰ هکتوپاسکال، Rel-Hum700 و Spe-Hum700 به‌ترتیب نشان‌دهنده رطوبت نسبی و رطوبت ویژه در تراز ۷۰۰ هکتوپاسکال و Temp700 دمای هوا در تراز ۷۰۰ هکتوپاسکال هستند.

در این پژوهش، داده‌ها در قالب سه سناریوی مجزا به عنوان ورودی مدل‌ها مورد استفاده قرار گرفتند. در سناریوی نخست، تنها داده‌های جو بالا به کار گرفته شد؛ در سناریوی دوم، مدل صرفاً بر پایه داده‌های سطح زمین آموزش داده شد و در سناریوی سوم، ترکیب هر دو مجموعه داده برای ایجاد یک ماتریس ویژگی یکپارچه مورد استفاده قرار گرفت. در تمامی سناریوها، با اعمال تاخیر زمانی یک‌روزه (lag=۱)، اطمینان حاصل گردید که کلیه متغیرهای ورودی مربوط به روز قبل از روز هدف پیش‌بینی شده باشند. این رویکرد تلفیقی، امکان لحاظ‌کردن همزمان شرایط جوی سطحی و پارامترهای جو بالا را فراهم آورده و موجب بهبود قابل توجه عملکرد مدل‌ها در پیش‌بینی دمای کمینه روزانه شد.

الگوریتم‌های یادگیری ماشین

در این پژوهش، برای پیش‌بینی دمای کمینه روزانه از طیف وسیعی از الگوریتم‌های رگرسیون مبتنی بر یادگیری گروهی بهره گرفته شد. این مجموعه شامل الگوریتم‌های جنگل تصادفی، AdaBoost، XGBoost، CatBoost و LightGBM بود. الگوریتم‌های یادگیری گروهی با ترکیب چندین مدل پایه، از قابلیت بالایی در شناسایی روابط غیرخطی پیچیده، کاهش خطای سامانمند و جلوگیری از پدیده بیش‌برازش برخوردار بوده و برای مدل‌سازی پدیده‌های پیچیده جوی مانند دمای کمینه گزینه‌های مناسبی به شمار می‌رفتند.

معیارهای عملکرد مدل‌ها

برای ارزیابی عملکرد مدل‌های رگرسیونی در پیش‌بینی دمای کمینه روزانه، از پنج شاخص استاندارد شامل RMSE، MAE، ضریب تعیین (R^2)، ضریب تعیین تعدیل‌شده و شاخص کلینگ-گوپتا

(KGE) استفاده گردید. این معیارها با رویکردی مکمل، جنبه‌های مختلف دقت و کارآیی مدل را مورد سنجش قرار داده و تصویر جامعی از قابلیت پیش‌بینی ارایه می‌نمایند. شاخص ریشه میانگین مربعات خطا (RMSE) معیاری استاندارد برای ارزیابی دقت مدل‌های پیش‌بینی است که میزان پراکندگی مقادیر پیش‌بینی‌شده حول مقادیر واقعی را می‌سنجد. این شاخص با محاسبه جذر میانگین مربعات اختلاف بین مقادیر پیش‌بینی و مشاهداتی، به طور ویژه نسبت به خطاهای بزرگ، حساسیت نشان می‌دهد. میانگین قدر مطلق خطا (MAE) با محاسبه متوسط اختلافات مطلق بین مقادیر پیش‌بینی‌شده و مقادیر واقعی، برآوردی مستقیم از میزان خطای مدل را ارایه می‌دهد. R^2 معیاری است که مشخص می‌کند چه نسبتی از پراکندگی مقادیر واقعی حول میانگین، توسط مدل پیش‌بینی‌شده توجیه می‌گردد. Adjusted R^2 ضریب تعیین تعدیل‌شده نسخه‌ای اصلاح‌شده از R^2 است که اثر تعداد متغیرهای مستقل را در ارزیابی دقت مدل در نظر می‌گیرد. برخلاف R^2 که همواره با افزودن متغیرهای جدید افزایش می‌یابد، مقدار Adjusted R^2 تنها زمانی رشد می‌کند که متغیر افزوده‌شده واقعاً به بهبود مدل کمک کند. شاخص KGE به عنوان معیاری ترکیبی برای ارزیابی جامع عملکرد مدل به کار می‌رود. این شاخص با درنظرگرفتن همزمان سه مولفه اصلی شامل همبستگی (r)، تغییرپذیری (α) و اریبی (β)، دیدی متوازن از دقت آماری و پویایی مدل ارایه می‌دهد. برتری KGE نسبت به شاخص‌های خطامحور، در توانایی آن برای تفکیک منشا اختلاف میان مقادیر پیش‌بینی‌شده و مشاهداتی نهفته است [Chai & Draxler, 2014; Kisi *et al.*, 2025; Sattari *et al.*, 2024; Pande *et al.*, 2024; Ahadi *et al.*, 2025].

انتخاب ویژگی‌ها

در این پژوهش، به منظور کاهش ابعاد داده‌ها و شناسایی مجموعه‌ای بهینه از متغیرهای ورودی که بیشترین نقش را در پیش‌بینی دمای کمینه ایفا می‌کنند، از روش بهترین زیرمجموعه (BSS) استفاده شد. این روش یکی از دقیق‌ترین رویکردهای انتخاب ویژگی به شمار می‌آید که تمامی ترکیب‌های ممکن از متغیرها را تا اندازه‌ای مشخص مورد ارزیابی قرار داده و ترکیبی را که بهترین عملکرد مدل را ارایه می‌دهد، به عنوان مجموعه بهینه انتخاب می‌کند.

فرض کنید مجموعه اولیه ویژگی‌ها به صورت $X=\{x_1, x_2, ..., x_p\}$ تعریف شود. در این صورت، زیرمجموعه‌ای از اندازه k به شکل $S_k \subseteq S$ و $k = |X_k|$ در نظر گرفته می‌شود. هدف، یافتن زیرمجموعه‌ای است که معیار ارزیابی مدل را بیشینه کند، به طوری که $S_k^* = \arg max_{S_k \subseteq X} R^2(S_k)$ باشد، که در آن $R^2(S_k)$ ضریب تعیین حاصل از مدل آموزش‌دیده با ویژگی‌های موجود در زیرمجموعه S_k است. برای سنجش کارآیی هر زیرمجموعه، از اعتبارسنجی متقاطع زمانی استفاده گردید و میانگین مقدار R^2 در تمامی فولدها به عنوان معیار نهایی مقایسه در نظر گرفته شد. به منظور کنترل هزینه محاسباتی و جلوگیری از افزایش نمایی تعداد ترکیب‌ها، حداکثر اندازه زیرمجموعه‌ها برابر با هفت ویژگی تعیین شد. همچنین، با اتکا بر دانش پیشین، دمای کمینه روز قبل ($Tmin_{t-1}$) به عنوان ویژگی اجباری در تمامی زیرمجموعه‌ها لحاظ گردید تا اثر سایر متغیرها در حضور این پارامتر کلیدی بررسی شود.

یافته‌ها

در این بخش، عملکرد پنج مدل یادگیری ماشین (شامل رگرسیون جنگل تصادفی، AdaBoost، XGBoost، CatBoost و LightGBM) برای پیش‌بینی دمای حداقل با یک روز تاخیر زمانی (lag=۱) در شهر مشهد مورد ارزیابی قرار گرفت. به منظور دستیابی به بیشترین دقت ممکن در پیش‌بینی، پارامترهای هر مدل از طریق روش GridSearchCV به صورت دقیق تنظیم شد. در این فرآیند، مجموعه‌ای از مقادیر محتمل برای پارامترهای اصلی مدل‌ها تعریف و با اجرای اعتبارسنجی متقابل پنج‌تایی، ترکیب بهینه پارامترها براساس بیشترین مقدار معیار R^2 انتخاب گردید. این روش باعث شد تا ارزیابی مدل‌ها به شکل منصفانه و بهینه انجام شود و از بروز بیش‌برازش جلوگیری گردد. در پایان نیز، برای سنجش دقت و کارآیی مدل‌های آموزش‌دیده بر روی داده‌های آموزش و آزمون، از معیارهای آماری MAE، RMSE، R^2، Adjusted R^2 و KGE استفاده گردید.

مطالعه حاضر در سه مرحله مجزا پیاده‌سازی شد. در مرحله نخست، مدل‌های یادگیری ماشین با استفاده از ویژگی‌های استخراج‌شده از داده‌های جو بالا آموزش داده شدند تا تاثیر اطلاعات لایه‌های فوقانی جو بر دقت پیش‌بینی دمای حداقل با یک روز تاخیر زمانی ارزیابی شود. در مرحله دوم، همان الگوریتم‌ها با بهره‌گیری از داده‌های سطح زمین آموزش دیدند تا امکان مقایسه عملکرد مدل‌ها براساس نوع داده ورودی فراهم گردد. در هر دو مرحله، به منظور افزایش پایداری مدل‌ها و جلوگیری از اثر هم‌خطی چندگانه میان متغیرها، شاخص تورم واریانس (VIF) محاسبه شد و متغیرهای دارای هم‌خطی بالا از مجموعه ویژگی‌ها حذف گردیدند. در مرحله سوم، رویکرد ترکیبی با هدف بهره‌گیری همزمان از داده‌های سطح زمین و جو بالا مورد استفاده قرار گرفت. در این مرحله، پس از ادغام دو مجموعه داده و کنترل هم‌خطی با استفاده از VIF، برای کاهش ابعاد و انتخاب مجموعه‌ای بهینه از متغیرهای موثر، الگوریتم BSS به کار گرفته شد. انتخاب نهایی ویژگی‌ها براساس بیشترین مقدار ضریب تعیین R^2 در اعتبارسنجی متقاطع زمانی پنج‌تایی انجام گرفت تا ترکیب نهایی ویژگی‌ها با بیشترین دقت پیش‌بینی و کمترین پیچیدگی محاسباتی تعیین شود.

برای مقایسه و تحلیل دقیق‌تر نتایج، عملکرد پنج مدل یادگیری ماشین در پیش‌بینی دمای حداقل روز بعد بررسی شد (جدول ۳). این جدول نتایج مدل‌ها را در سه سناریوی داده‌ای مختلف نمایش می‌دهد که در آن سناریوی S مبتنی بر داده‌های سطح زمین، سناریوی U براساس داده‌های جو بالا و سناریوی S & U حاصل از

ترکیب همزمان دو مجموعه داده است. در هر مدل، دو ردیف متوالی در جدول در نظر گرفته شده است که ردیف نخست عملکرد مدل بر روی داده‌های آزمون و ردیف دوم عملکرد آن بر روی داده‌های آموزش را نشان می‌دهد. ستون‌های جدول شامل مقادیر پنج شاخص ارزیابی یعنی MAE، RMSE، R^2، Adjusted R^2 و KGE هستند که امکان ارزیابی جامع عملکرد مدل‌ها در هر سناریو را فراهم می‌سازند. این ساختار، بستری برای مقایسه میان الگوریتم‌ها براساس نتایج آنها در داده‌های آزمون ایجاد می‌کند.

جدول ۳) عملکرد پنج مدل یادگیری ماشین در پیش‌بینی حداقل دما روز بعد با استفاده از سه رویکرد S، U و S & U

الگوریتم		MAE			R^2			Adjusted R^2			RMSE			KGE		
		S	U	S & U	S	U	S & U	S	U	S & U	S	U	S & U	S	U	S & U
جنگل تصادفی	آزمون	۲/۱۵	۲/٤٥	۱/۹۹	۸۹/٦۰	۸٦/٥۰	۹۰/۹۰	۸۹/٦۰	۸٦/٤۰	۹۰/۹۰	۲/۷٤	۳/۱۳	۲/٥٦	۰/۸۷	۰/۸۱	۰/۸۸
	آموزش	۱/۹۸	۲/۲۷	۱/۷۹	۹۱/۱۳	۸۷/۹٦	۹۲/٤۱	۹۱/۱۲	۹۷/۹۳	۹۲/٤۰	۲/٥۷	۲/۹۹	۲/۳۷	۰/۸۹	۰/۸٤	۰/۹۰
AdaBoost	آزمون	۱/۸۲	۲/۱۲	۱/۷۰	۹۲/۲۰	۹۰/۱۰	۹۳/٤۰	۹۲/۲۰	۹۰/۰۰	۹۳/٤۰	۲/۳۸	۲/٦۸	۲/۱۹	۰/۹٤	۰/۹۲	۰/۹۳
	آموزش	۱/۲۲	۱/۸۸	۱/۰٦	۹۷/۰۳	۹۲/٥۳	۹۷/۹۲	۹۷/۰۲	۹۲/٥۰	۹۷/۹۲	۱/٤۸	۲/۳٦	۱/۲٤	۰/۹۷	۰/۹٦	۰/۹۸
XGBoost	آزمون	۱/۷۹	۱/۷۰	۱/٦٤	۹۲/٥۰	۹۳/۳۰	۹۳/۸۷	۹۲/٤۰	۹۳/۳۰	۹۳/۸۷	۲/۳٤	۲/۲۰	۲/۱۱	۰/۹٤	۰/۹۲	۰/۹۲
	آموزش	۱/٥۸	۱/۱۲	۱/٤۳	۹٤/۳۲	۹۷/۱۷	۹٥/۲۳	۹٤/۳۱	۹۷/۱٦	۹٥/۲۲	۲/۰٥	۱/٤٥	۱/۸۸	۰/۹٥	۰/۹۷	۰/۹٦
CatBoost	آزمون	۱/۷۹	۱/٦٥	۱/٦٦	۹۲/٥۰	۹۳/۷٦	۹۳/٥٤	۹۲/٤٥	۹۳/۷۰	۹۳/٥۳	۲/۳٤	۲/۱۳	۲/۱۷	۰/۹٤	۰/۹۳	۰/۹۲
	آموزش	۱/٥٥	۱/۰۷	۱/٥۰	۹٤/٤۷	۹۷/٤۰	۹٤/۷٤	۹٤/٤٦	۹۷/۳۹	۹٤/۷٤	۲/۰۳	۱/۳۹	۱/۹۸	۰/۹٦	۰/۹۷	۰/۹٥
LightGBM	آزمون	۱/۷۹	۱/۷۰	۱/٦۳	۹۲/٦۰	۹۳/٤۰	۹۳/۹۰	۹۲/٥۳	۹۳/۳۰	۹۳/۹۰	۲/۳۳	۲/۱۹	۲/۱۱	۰/۹٤	۰/۹۲	۰/۹٤
	آموزش	۱/٥۰	۰/۹۳	۱/۳۹	۹٤/۸۱	۹۸/۱۰	۹٥/٥۱	۹٤/۸۰	۹۸/۰۹	۹٥/٥۱	۱/۹٦	۱/۱۹	۱/۸۲	۰/۹٥	۰/۹۷	۰/۹۷

داده‌های جو بالا

در مرحله نخست، مدل‌های یادگیری ماشین با استفاده از داده‌های جو بالا آموزش داده شدند تا نقش لایه‌های فوقانی جو در پیش‌بینی دمای حداقل روز بعد مورد ارزیابی قرار گیرد. پیش از اجرای مدل‌ها، برای جلوگیری از اثر هم‌خطی چندگانه میان متغیرها، شاخص VIF برای تمامی ویژگی‌ها محاسبه شد. نتایج اولیه نشان داد که ویژگی‌های GH500، GH300، Temp500 و Temp700 به دلیل رفتار فیزیکی مشابه و همبستگی بالا در ترازهای مختلف فشار، دارای VIF بزرگ‌تر از حد مجاز بودند و از مجموعه حذف گردیدند. پس از حذف این متغیرها، مقدار VIF سایر ویژگی‌ها به کمتر از ۵ کاهش یافت و هم‌خطی میان متغیرها برطرف شد. در نهایت، مجموعه نهایی ویژگی‌های به‌کاررفته در مدل‌های جو بالا شامل ارتفاع ژئوپتانسیل در تراز ۷۰۰ هکتوپاسکال، رطوبت نسبی، رطوبت ویژه، چرخندگی و مولفه‌های افقی باد در ترازهای فشاری ۳۰۰، ۵۰۰ و ۷۰۰ هکتوپاسکال، دمای هوا در تراز ۳۰۰ هکتوپاسکال و متغیرهای فصلی بوده است.

براساس مجموعه پالایش‌شده ویژگی‌ها، آموزش و ارزیابی مدل‌های مختلف انجام شد (جدول ۳). تحلیل داده‌های آزمون نشان داد که مدل CatBoost با اختلاف قابل توجهی بهترین عملکرد را در میان الگوریتم‌های مورد بررسی داشت. این مدل با ثبت مقادیر R^2=۹۳/۷٦، Adjusted R^2=۹۳/۷۰، MAE=۱/٦٥، RMSE=۲/۱۳ و KGE=۰/۹۳ بالاترین دقت پیش‌بینی را ارایه داد.

این نتایج نشان دادند که مدل CatBoost ضمن برخورداری از پایداری بالا در داده‌های آزمون، توانست ساختار پیچیده روابط میان متغیرهای جو بالا و دمای حداقل را به‌خوبی شناسایی کند. سایر مدل‌ها از جمله XGBoost و LightGBM نیز عملکردی نسبتاً نزدیک به CatBoost داشتند، در حالی که الگوریتم جنگل تصادفی پایین‌ترین دقت را در این سناریو به ثبت رساند.

داده‌های سطح زمین

در سناریوی دوم، مدل‌های یادگیری ماشین بر پایه داده‌های سطح زمین آموزش داده شدند تا نقش متغیرهای سطحی در پیش‌بینی دمای حداقل روز بعد مورد بررسی قرار گیرد. مشابه سناریوی نخست، شاخص VIF برای تمامی ویژگی‌ها محاسبه شد و نتایج نشان داد که متغیرهای Tm و Um به دلیل میانگین‌گیری از دما و رطوبت و در نتیجه هم‌خطی بالا با سایر متغیرهای گروه خود، باید از مجموعه حذف شوند. همچنین در گروه دما، به دلیل همبستگی قوی میان Tmax و Tmin، تنها Tmin به عنوان نماینده این گروه حفظ گردید. پس از حذف این متغیرها، مقادیر VIF سایر ویژگی‌ها به زیر ۵ کاهش یافت و هم‌خطی میان متغیرها به میزان قابل توجهی کاهش پیدا کرد. در نهایت، مجموعه نهایی ویژگی‌های به‌کاررفته در مدل‌ها شامل Tmin، pm، Umax، Umin، ffm، nm، rrr24 و متغیرهای مربوط به فصول بوده است. آموزش و ارزیابی مدل‌ها با استفاده از این ویژگی‌ها انجام شد (جدول ۳).

در میان مدل‌های مورد ارزیابی، الگوریتم LightGBM بهترین نتایج را بر روی داده‌های آزمون ارایه داد و توانست با ثبت مقادیر R^2=۹۲/٦۰، Adjusted R^2=۹۲/٥۳، MAE=۱/۷۹، RMSE=۲/۳۲ و KGE=۰/۹٤، بر سایر مدل‌ها برتری یابد. این نتایج نشان دادند که مدل LightGBM با ساختار تقویتی خود قادر بود الگوهای غیرخطی میان متغیرهای سطح زمین و دمای حداقل را به‌خوبی شناسایی کند و پیش‌بینی‌های دقیقی ارایه دهد. اختلاف اندک میان عملکرد داده‌های آموزش و آزمون نیز نشان داد که پارامترها به طور مناسب تنظیم شده بودند و بیش‌برازش در این مدل رخ نداده است.

داده‌های ترکیبی

در این سناریو، مدل‌های یادگیری ماشین بر پایه داده‌های ترکیبی حاصل از سطح زمین و لایه‌های بالایی جو توسعه یافتند تا اثر همزمان متغیرهای سطحی و جوی در پیش‌بینی دمای حداقل روز

بعد بررسی شود. در گام نخست، به منظور افزایش پایداری مدل و کاهش اثرات هم‌خطی میان متغیرها، شاخص VIF برای تمامی ویژگی‌ها محاسبه شد. مجموعه‌ای از متغیرها، شامل ارتفاع ژئوپتانسیل (GH300 و GH500)، دما (Temp300، Temp500 و Temp700)، و همچنین متغیرهای سطحی Tm، Tmax، Um و pm دارای مقادیر بالای VIF بودند و هم‌خطی شدیدی با سایر ویژگی‌ها داشتند. این همبستگی بالا که ناشی از روابط فیزیکی مشابه میان متغیرهای جوی در سطوح مختلف فشار و همچنین میانگین‌گیری در برخی متغیرهای سطحی بود، می‌توانست موجب افزایش واریانس ضرایب و کاهش پایداری مدل شود.

به منظور حل این چالش، متغیرهای دارای هم‌خطی بالا به صورت مرحله‌ای از مجموعه حذف شدند تا افزونگی اطلاعاتی کاهش یابد و ساختار داده‌ها پایدارتر گردد. پس از حذف این ویژگی‌ها، مقادیر VIF سایر متغیرها به کمتر از ۵ کاهش یافت و از میان ۳۴ متغیر اولیه، ۲۵ ویژگی نهایی برای تحلیل باقی ماندند. با وجود این کاهش، ابعاد داده‌ها همچنان نسبتاً زیاد بود و می‌توانست بر زمان آموزش و تفسیرپذیری مدل تاثیر بگذارد. از این رو، در گام بعد، برای شناسایی موثرترین ویژگی‌ها و انتخاب مجموعه‌ای بهینه از متغیرهای ورودی، از روش BSS استفاده شد. این روش با ارزیابی تمام ترکیب‌های ممکن از متغیرها و انتخاب زیرمجموعه‌ای که بالاترین دقت پیش‌بینی را ارایه می‌داد، تعادلی میان دقت و پیچیدگی مدل برقرار کرد.

بر پایه نتایج حاصل از روش BSS، منحنی روند تغییرات میانگین R^2 حاصل از اعتبارسنجی متقاطع زمانی در برابر تعداد ویژگی‌های انتخاب‌شده تهیه شد (شکل ۱). همان‌گونه که مشاهده شد، مقدار R^2 در ابتدا روندی نسبتاً نزولی داشت و پس از آن با افزایش تعداد ویژگی‌ها تا پنج متغیر، به بیشترین مقدار خود رسید و سپس مجدداً کاهش یافت. بر این اساس، زیرمجموعه شامل پنج ویژگی به عنوان بهترین ترکیب انتخاب شد، زیرا ضمن دستیابی به بیشترین مقدار R^2=۰/۹۲۵ با انحراف‌معیار نسبتاً پایین (±۰/۰۰۴۲)، تعادلی مطلوب میان دقت پیش‌بینی و سادگی مدل برقرار کرد.

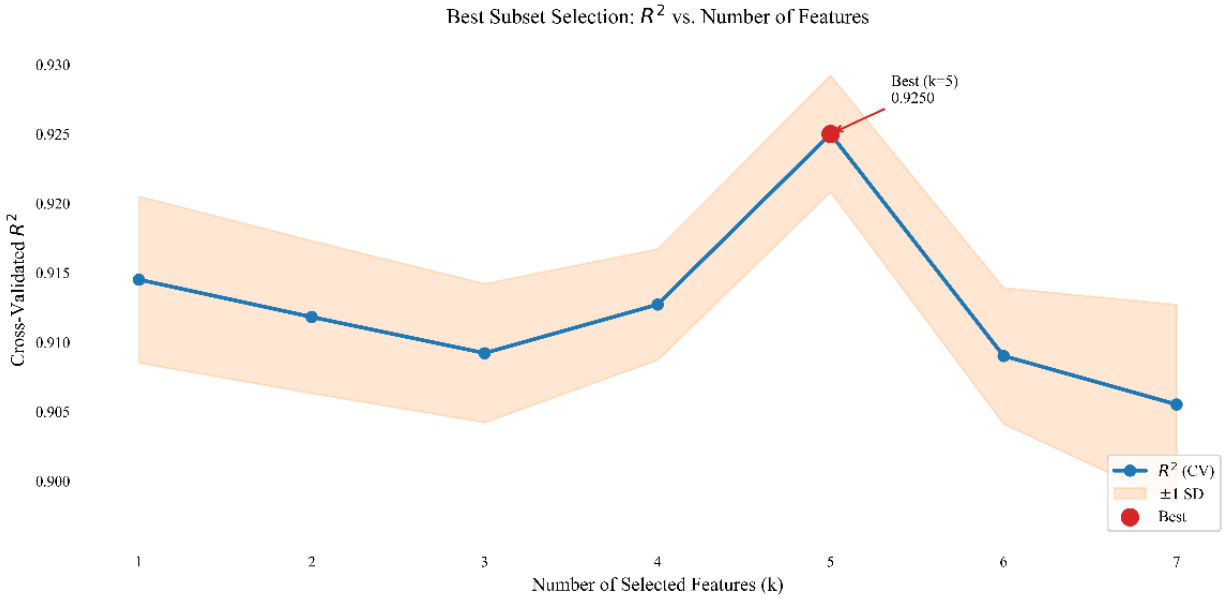

شکل ۱) انتخاب ویژگی‌ها با استفاده از روش BSS

ویژگی‌های منتخب در این ترکیب عبارت بودند از Tmin، Rel-Hum700، Spe-Hum700، Umin و season-Summer. این مجموعه از متغیرها توانست ترکیبی از شرایط ترمودینامیکی جو بالا و اثرات فصلی و سطحی را به صورت همزمان در مدل لحاظ کند. در این ترکیب، متغیر Tmin به عنوان مولفه اصلی و پیش‌نگر رفتاری دما در بازه زمانی یک‌روزه عمل کرد. متغیرهای Rel-Hum700 و Spe-Hum700 به‌ترتیب میزان اشباع و ظرفیت رطوبتی لایه زیرین جو را نمایش دادند و نقش مهمی در تنظیم توازن گرمایی شبانه و شکل‌گیری دمای حداقل داشتند. از سوی دیگر، Umin شرایط تهویه سطح زمین را منعکس کرد و از طریق کاهش سرمایش تشعشعی در شب بر دمای حداقل اثر گذاشت. در نهایت، متغیر season-Summer تفاوت‌های فصلی در رفتار دما را در نظر گرفت و تعمیم‌پذیری مدل را در طول سال بهبود بخشید. این نتایج نشان دادند که روش BSS توانست مجموعه‌ای بهینه از ویژگی‌ها را شناسایی کند که با حداقل پیچیدگی، بیشترین توان توضیحی را برای پیش‌بینی دمای حداقل روز بعد فراهم آورد.

نتایج حاصل از رویکرد S & U نشان دادند که ادغام داده‌های سطح زمین و داده‌های جو بالا منجر به بهبود قابل توجه دقت پیش‌بینی و افزایش پایداری مدل‌ها شد. این ترکیب با دربرگرفتن همزمان ویژگی‌های ترمودینامیکی لایه‌های بالایی جو و شاخص‌های سطحی، توانست سیگنال‌های مرتبط با تغییرات دمای حداقل را به طور کامل‌تری در مدل لحاظ کند. در میان الگوریتم‌های یادگیری ماشین مورد بررسی، مدل LightGBM عملکرد برتری در تمامی شاخص‌های ارزیابی نشان داد. این مدل در داده‌های آزمون توانست

مقادیر R^2=۹۳/۹۰، Adjusted R^2=۹۳/۹۰، MAE=۱/۶۳، RMSE=۲/۱۰ و KGE=۰/۹۳ را به ثبت برساند. این نتایج بیانگر آن بودند که مدل LightGBM با ساختار تقویتی خود قادر بود الگوهای غیرخطی میان متغیرهای سطحی و جو بالا را توضیح دهد و خطای پیش‌بینی را کاهش دهد. دقت بالای مدل در داده‌های آزمون و نزدیکی مقادیر آن به داده‌های آموزش نیز نشان داد که مدل از پایداری آماری بالایی برخوردار بود و بیش‌برازش در فرآیند یادگیری رخ نداد. با توجه به آنکه نتایج به‌دست‌آمده از مدل LightGBM در سناریوی ترکیبی (S & U) نسبت به عملکرد بهترین مدل‌ها در دو سناریوی مجزای سطح زمین (S) و جو بالا (U) برتری داشتند، می‌توان نتیجه گرفت که ترکیب داده‌های سطح زمین و جو بالا در قالب مدل LightGBM کارآمدترین پیکربندی برای پیش‌بینی دمای حداقل روز بعد بود.

در شکل ۲، مقادیر واقعی و پیش‌بینی‌شده دمای حداقل روزانه برای مدل برتر پژوهش، یعنی LightGBM در سناریوی داده‌های ترکیبی (S & U)، نمایش داده شدند. در این نمودار، دمای حداقل مشاهده‌شده (خط آبی) در کنار مقادیر برآوردی مدل (خط نارنجی) برای کل دوره زمانی ترسیم شد و خط‌چین قرمز آغاز بازه داده‌های آزمون در اول ژانویه ۲۰۱۸ را مشخص کرد. همان‌گونه که مشاهده شد، مدل توانست الگوی نوسانات فصلی و روندهای بین‌سالی دمای حداقل را به‌خوبی بازتولید کند. نزدیکی چشمگیر منحنی‌های مشاهده‌شده و پیش‌بینی‌شده در بیشتر بازه‌ها نشان داد که LightGBM قادر بود روابط غیرخطی و پویای میان متغیرهای جوی و سطحی را شناسایی کند و عملکردی پایدار در طول زمان ارایه دهد. اختلافات جزیی میان مقادیر واقعی و پیش‌بینی‌شده عمدتاً در بازه‌های دارای نوسانات شدید دمایی (زمستان‌ها) مشاهده شد که می‌توانست ناشی از تغییرات کوتاه‌مدت و ناگهانی شرایط هواشناسی باشد. با وجود این، همپوشانی گسترده دو منحنی توان بالای مدل در بازتولید الگوی زمانی دمای حداقل روز بعد و پایداری نتایج در داده‌های آزمون را تایید کرد.

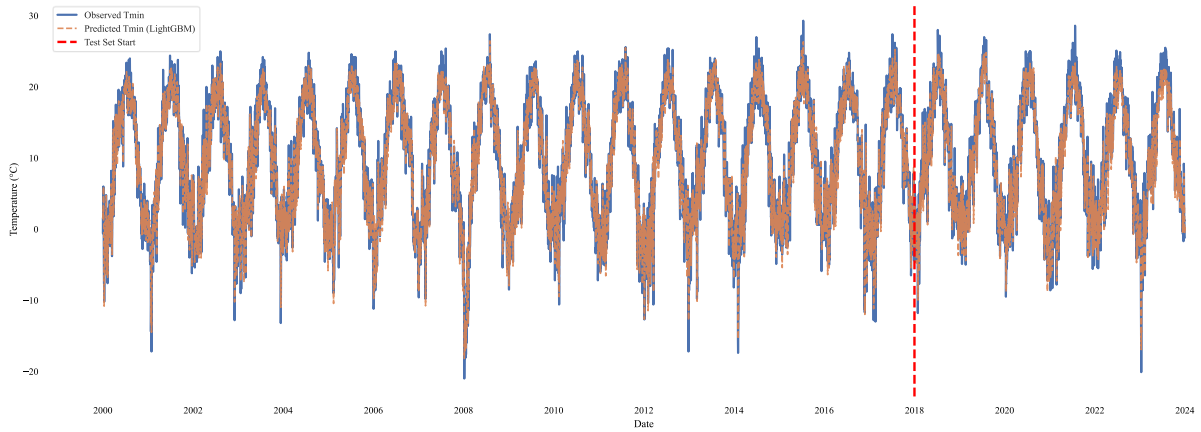

شکل ۲) مقایسه حداقل دما روزانه مشاهده‌شده و پیش‌بینی‌شده در ایستگاه مشهد با استفاده از مدل LightGBM بر روی داده‌های S & U

بحث

هدف این پژوهش ارزیابی کارآیی الگوریتم‌های یادگیری ماشین در پیش‌بینی دمای حداقل روز بعد و بررسی نقش تلفیق داده‌های سطح زمین و جو بالا در بهبود دقت و پایداری مدل بود. در این راستا، پنج الگوریتم یادگیری گروهی شامل Random Forest، AdaBoost، XGBoost، CatBoost و LightGBM در سه سناریوی داده‌ای مستقل ارزیابی شدند.

مطالعات پیشین نیز با اهداف مشابه، تلاش کرده‌اند دمای حداقل روزانه را در مقیاس‌های مختلف پیش‌بینی کنند. در این میان، *عاقل‌پور* و *نادی* [Aghalpoor & Nadi, 2018] با استفاده از مدل‌های سری‌زمانی AR و MA به پیش‌بینی دمای بیشینه و کمینه دمای یک روز آینده در ایستگاه سینوپتیک رشت با استفاده از مقادیر دمای پنج روز گذشته (Lag=۵) پرداخته‌اند. نتایج نشان می‌دهد که مدل‌های AR (۵) و MA (۵) بالاترین دقت را داشته و می‌توانند تغییرات روزانه دما را با R^2=۹۴/۵ و RMSE≈۱/۷ بازتولید کنند. هرچند این یافته‌ها کارآیی مدل‌های خطی کلاسیک را در شرایط ایستایی تایید می‌کند، اما به دلیل فقدان متغیرهای فیزیکی جو، قابلیت تعمیم و تبیین‌پذیری آنها محدود است. در پژوهشی دیگر، *اوستاوغلو* و همکاران [Ustaoglu *et al.*, 2008] با هدف پیش‌بینی دمای میانگین، بیشینه و کمینه روزانه در ایستگاه‌های Geyve و Sakarya ترکیه، از سه ساختار شبکه عصبی پرسپترون پیش‌خور، شبکه تابع پایه شعاعی (RBF) و شبکه رگرسیون تعمیم‌یافته به همراه رگرسیون خطی چندگانه استفاده کرده‌اند. داده‌های ورودی شامل مقادیر دما در هفت روز گذشته و یک شاخص فصلی هستند. نتایج نشان می‌دهد که شبکه عصبی RBF در پیش‌بینی دمای حداقل نسبت به سایر مدل‌ها برتری دارد و با R≈۰/۹۸ و RMSE=۱/٦٤ دقیق‌ترین نتایج را ارایه داده است. همچنین، استفاده از داده‌های ایستگاه مجاور موجب کاهش خطا و افزایش پایداری مدل شده است، که اهمیت استفاده از داده‌های مکمل مکانی را نشان می‌دهد.

نتایج پژوهش حاضر با دو مطالعه یادشده همراستا اما از نظر رویکرد و گستره داده پیشرفته‌تر است. در حالی که پژوهش‌های پیشین

تنها از داده‌های تاریخی دما استفاده کرده‌اند، این مطالعه با ترکیب داده‌های سطح زمین و متغیرهای جو بالا (رطوبت نسبی و ویژه، دما و مولفه‌های باد در ترازهای ۳۰۰، ۵۰۰ و ۷۰۰ هکتوپاسکال) توانست ساختارهای فیزیکی موثر بر سرمایش شبانه را مدل‌سازی کند. علاوه بر آن، ارزیابی همزمان چند الگوریتم یادگیری گروهی با استفاده از اعتبارسنجی متقاطع زمانی، رویکردی جامع‌تر برای تحلیل پایداری مدل فراهم کرد. از نظر کمّی، LightGBM در سناریوی ترکیبی (S & U) با R≈۰/۹٤ و RMSE=۲/۱۰ عملکردی قابل مقایسه با مدل‌های RBF و AR/MA نشان داد. گرچه مقدار RMSE آن اندکی بالاتر بود، اما شاخص KGE=۰/۹۳ نشانگر پایداری زمانی بیشتر و سازگاری بهتر پیش‌بینی‌ها بود. افزون بر این، استفاده از متغیرهای جوی موجب افزایش تفسیرپذیری و قابلیت تعمیم مدل در شرایط ناپایدار شد، در حالی که مدل‌های پیشین عمدتاً مبتنی بر داده‌های ایستا هستند. در نتیجه، می‌توان گفت چارچوب یادگیری گروهی چندمنبعی در این پژوهش توازنی مطلوب میان دقت عددی، پایداری و منطق فیزیکی برقرار کرده است.

به طور مفهومی، هر دو مطالعه پیشین و پژوهش حاضر تاکید دارند که افزودن اطلاعات کمکی بیرون از تاریخچه دما موجب افزایش مهارت پیش‌بینی می‌شود. با این تفاوت که *اوستاوغلو* و همکاران از داده‌های ایستگاه‌های مجاور بهره برده‌اند، در حالی که در این پژوهش داده‌ها در راستای قائم (جو بالا در سه تراز ۳۰۰، ۵۰۰ و ۷۰۰ هکتوپاسکال) به عنوان منبع مکمل اطلاعاتی مورد استفاده قرار گرفتند. در واقع، پژوهش حاضر نوعی گسترش عمودی همان منطق استفاده از همسایگی مکانی را ارایه داد. این نتیجه، بر اهمیت استفاده از داده‌های چندبُعدی (مکانی و عمودی) در بهبود مهارت پیش‌بینی دما در مقیاس روزانه تاکید دارد.

در مجموع، یافته‌های این پژوهش نشان داد که تلفیق داده‌های سطح زمین و جو بالا در چارچوب الگوریتم‌های یادگیری گروهی، دقیق‌ترین و پایدارترین روش برای پیش‌بینی کوتاه‌مدت دمای حداقل در مقیاس ایستگاهی است؛ نتیجه‌ای که نسبت به مدل‌های خطی سنتی و شبکه‌های عصبی تک‌منبعی، گامی موثر برای توسعه پیش‌بینی‌های داده‌محور و فیزیکی به شمار می‌آید.

داده‌های این پژوهش محدود به یک ایستگاه بوده و تعمیم نتایج نیازمند تحلیل چندایستگاهی است. همچنین، تنها تاخیر زمانی یک‌روزه بررسی شد؛ در حالی که درنظرگرفتن چند تاخیر روزانه متوالی می‌تواند پویایی سری را بهتر نمایش دهد. تعداد سطوح فشاری مورد استفاده نیز محدود به سه تراز (۳۰۰، ۵۰۰ و ۷۰۰) بود؛ افزودن ترازهای بالاتر و پایین‌تر می‌تواند دقت مدل را افزایش دهد. برای پژوهش‌های آتی، به‌کارگیری مدل‌های دنباله‌ای مانند LSTM و GRU، استفاده از داده‌های ایستگاه‌های متعدد و ترکیب خروجی مدل‌های عددی پیش‌بینی وضع هوا با یادگیری ماشین (مدل‌های هیبریدی) پیشنهاد می‌شود. همچنین بهره‌گیری از روش‌های تبیین‌پذیری مانند SHAP می‌تواند نقش متغیرهای سطح زمین و جو بالا را در کنترل دمای حداقل به صورت روشن‌تر آشکار سازد.

نتیجه‌گیری

ترکیب داده‌های سطح زمین و جو بالا موجب بهبود قابل توجه دقت و پایداری مدل‌ها می‌شود. الگوریتم LightGBM در قالب سناریوی ترکیبی، ساختاری کارآمد و متعادل از نظر سادگی، پایداری و توانایی شناسایی الگوهای غیرخطی ارایه می‌دهد.

تشکر و قدردانی: از سازمان هواشناسی کشور برای ارایه داده‌های ایستگاه هواشناسی مشهد قدردانی می‌شود.

تاییدیه اخلاقی: موردی برای گزارش وجود ندارد.

تعارض منافع: موردی برای گزارش وجود ندارد.

سهم نویسندگان: امیرحسین بابائیان تمام امور مقاله را انجام داده است (۱۰۰٪)

منابع مالی: موردی برای گزارش وجود ندارد.

منابع

- Aghalpoor P, Nadi M (2018). Comparison of the performance of autoregressive and moving average models in predicting daily maximum and minimum temperature. Proceedings of the National Conference on Water Resources Management Strategies and Environmental Challenges. Sari: CIVILICA. [Persian]
- Ahadi M, Zeynali B, Salahi B, Shoja F, Fazl Kazemi A, Babaeian I, et al (2025). Projection of future drought trends in Iran using the CMIP6 multi-model ensemble. Journal of Natural Environmental Hazards. 14(46):43-74. [Persian]
- Asakereh H, Matlabizad S (2017). Comparison of the performance of SDSM and artificial neural network models in predicting minimum temperature variations (case study: Urmia Station). The Journal of Spatial Planning and Geomatics. 21(4):140-160. [Persian]
- Chai T, Draxler RR (2014). Root mean square error (RMSE) or mean absolute error (MAE)?-Arguments against avoiding RMSE in the literature. Geoscientific Model Development. 7(3):1247-1250.
- Cohen J, Zhang X, Francis J, Jung T, Kwok R, Overland J, et al (2020). Divergent consensuses on arctic amplification influence on midlatitude severe winter weather. Nature Climate Change. 10(1):20-29.
- Elbeltagi A, Vishwakarma DK, Katipoğlu OM, Sushanth K, Heddam S, Singh BP, et al (2025). Air temperature estimation and modeling using data driven techniques based on best subset regression model in Egypt. Scientific Reports. 15(1):20200.
- Fan J, Wu L, Zhang F, Cai H, Wang X, Lu X, et al (2018). Evaluating the effect of air pollution on global and diffuse solar radiation prediction using support vector machine modeling based on sunshine duration and air temperature. Renewable and Sustainable Energy Reviews. 94:732-747.
- Ghaffari HR, Shahraki S, Malbousi S (2024). Weather analysis with deep learning based on feature selection with crow learning algorithm. Journal of Climate Research. 1402(55):177-193. [Persian]
- Hanoon MS, Najah Ahmed A, Zaini N, Razzaq A, Kumar P, Sherif M, et al (2021). Developing machine learning algorithms for meteorological temperature and humidity forecasting at Terengganu state in Malaysia. Scientific Reports. 11(1):18935.
- Hosseini AA, Alamatiyan E (2022). Using machine

- Pande CB, Sidek LM, Varade AM, Elkhrachy I, Radwan N, et al (2024). Forecasting of meteorological drought using ensemble and machine learning models. Environmental Sciences Europe. 36(1):160.
- Roshani, Haroon S, Tamal Kanti S, Md Hibjur R, Md M, Yatendra S, et al (2023). Analyzing trend and forecast of rainfall and temperature in Valmiki Tiger Reserve, India, using non-parametric test and random forest machine learning algorithm. Acta Geophysica. 71(1):531-552.
- Sattari MT, Bagheri R, Shirini K, Allahverdipour P (2024). Modeling daily and monthly rainfall in Tabriz using ensemble learning models and decision tree regression. Journal of Climate Change Research. 5(18):31-48. [Persian]
- Shahabi R, Izadi A (2024). Evaluation of different regression modeling approaches for temperature prediction using international meteorological conditions. Proceedings of the 24th International Conference on Information Technology,Computer and Telecommunication. Tehran: CIVILICA. [Persian]
- Shokouhi M, Mesrizadeh M, Asadi Oskouei E (2024). Bias correction of short-term minimum and maximum temperature forecasts of the WRF model by using the pursuit machine. Journal of the Earth and Space Physics. 50(2):465-479. [Persian]
- Tabatabaei S, Nazeri Tahroudi M, Dastourani M (2018). Performance comparison of GP, ANN, BCSD and SVM models for temperature simulation comparison performance of GP, ANN, BCSD and SVM models in temperature simulation. Journal of Meteorology and Atmospheric Science. 1(1):53-64. [Persian]
- Ustaoglu B, Cigizoglu HK, Karaca M (2008). Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods. Meteorological Applications. 15(4):431-445.
- Zhou J, Wang D, Band SS, Mirzania E, Roshni T (2023). Atmosphere air temperature forecasting using the honey badger optimization algorithm: on the warmest and coldest areas of the world. Engineering Applications of Computational Fluid Mechanics. 17(1):2174189.
learning methods to predict air temperature (case study: Weather stations in Mashhad County). Proceedings of the 15th International Conference on Science and Technology Advances. Mashhad:CIVILICA. [Persian]
- Huang Y, Zhao H, Huang X (2019). A prediction scheme for daily maximum and minimum temperature forecasts using recurrent neural network and rough set. IOP Conference Series: Earth and Environmental Science. 237(2):22005.
- IPCC (2023). Climate change 2021-the physical science basis: Working group I contribution to the sixth assessment report of the intergovernmental panel on climate change. Cambridge: Cambridge University Press.
- Jose DM, Vincent AM, Dwarakish GS (2022). Improving multiple model ensemble predictions of daily precipitation and temperature through machine learning techniques. Scientific Reports. 12(1):4678.
- Karimi SM, Kisi O, Porrajabali M, Rouhani-Nia F, Shiri J (2020). Evaluation of the support vector machine, random forest and geo-statistical methodologies for predicting long-term air temperature. ISH Journal of Hydraulic Engineering. 26(4):376-386.
- Kisi O, Heddam S, Parmar KS, Petroselli A, Külls C, Zounemat-Kermani M (2025). Integration of Gaussian process regression and K means clustering for enhanced short term rainfall runoff modeling. Scientific Reports. 15(1):7444.
- Kretschmer M, Cohen J, Matthias V, Runge J, Coumou D (2018). The different stratospheric influence on cold-extremes in Eurasia and North America. NPJ Climate and Atmospheric Science. 1(1):44.
- Lee J (2025). Estimating near-surface air temperature from satellite-derived land surface temperature using temporal deep learning: A comparative analysis. IEEE Access. 13:28935-28945.
- Oduro C, Osibo BK, Amankwah SOY, Khan S, Gyamfi Kedjanyi EA, Darteh OF, et al (2026). Leveraging machine learning for accurate near-surface air temperature prediction to enhance climate adaptation in Ghana. Journal of African Earth Sciences. 233:105877.