



University of Tehran Press

Environmental

Hazards

Management



Iranian Hazardology Association
Online ISSN: 2383-0530

Home Page: <https://jhsci.ut.ac.ir>

Dew Point Temperature Modeling Based on Machine Learning Algorithms

Nikrooz Bagheri^{ID}

Associate Professor, Agricultural Engineering Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran. Email: nikroozbagheri@yahoo.com.au

ARTICLE INFO

Article type:
Research Article

Article History:

Recived: 14 September 2026,

Revised: 13 October 2026,

Accepted: 14 October 2026,

Published: 22 October 2026

Keywords:

Dew Point Temperature,
Forecasting,
Frost,
Intelligent Agriculture,
Machine Learning.

ABSTRACT

One of the most important applications of the dew point in agriculture is forecasting radiation frost. The dew point can play a role in conditions conducive to frost occurrence and in its management. Radiation frost is one of the major hazards affecting the agricultural sector, causing substantial annual losses in crop yield and quality, particularly in fruit trees. Accurate and timely prediction of radiation frost is therefore of great importance for effective damage management. The occurrence of frost is not solely dependent on air temperature; atmospheric moisture-related variables also play an important role in its development. Accordingly, this study aimed to evaluate the short-term prediction of dew point temperature and investigate the effects of meteorological–physical features on the performance of machine learning-based models using meteorological data from Tehran, Iran, covering the period from 2005 to 2025. Air temperature, relative humidity, and dew point temperature were considered as the baseline variables. In addition, saturation vapor pressure, actual vapor pressure, vapor pressure deficit (VPD), and the difference between air temperature and dew point temperature were incorporated into the models as physical features. Seven algorithms, including Ridge Regression, Support Vector Regression (SVR), K-Nearest Neighbors (KNN), Random Forest (RF), Extremely Randomized Trees (Extra Trees), Gradient Boosting Regression, and XGBoost, were evaluated over two forecasting horizons of 6 and 12 hours, and their performance was compared with that of the baseline model. The results showed that, when meteorological–temporal features were used, Ridge Regression achieved the best overall performance at both the 6- and 12-hour forecasting horizons, with mean absolute error (MAE) values of 2.19 and 2.76 °C and root mean square error (RMSE) values of 3.01 and 3.77 °C, respectively. With the addition of meteorological–physical features, XGBoost demonstrated superior performance at both forecasting horizons in terms of reducing numerical prediction errors. Specifically, at the 6-hour horizon, the MAE and RMSE were 2.14 and 3.03 °C, respectively, whereas at the 12-hour horizon, the corresponding values were 2.61 and 3.62 °C. Support Vector Regression achieved better classification performance at the 6-hour horizon, with an F1-score of 0.911 and a Critical Success Index (CSI) of 0.837, while Ridge Regression performed better at the 12-hour horizon, with an F1-score of 0.878 and a CSI of 0.783. Furthermore, increasing the forecasting horizon from 6 to 12 hours resulted in a decrease in prediction accuracy across all models. Comparison of the models with the baseline model also indicated that machine learning models were capable of significantly improving prediction performance, although the differences among some of the top-performing models were not statistically significant. The findings demonstrate that machine learning algorithms can provide a suitable framework for short-term dew point temperature prediction and forecasting conditions conducive to radiation frost.

Cite this article: Bagheri, N. (2026). Dew Point Temperature Modeling Based on Machine Learning Algorithms. *Environmental Hazards Management*, 13 (2), 163-179. DOI: <http://doi.org/10.22059/jhsci.2026.423021.958>



© The Author(s).

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/jhsci.2026.423021.958>

Introduction

Radiation frost is one of the major environmental hazards affecting agricultural production and can cause substantial losses in crop yield and quality, particularly in fruit orchards. Radiation frost generally occurs during clear and calm nights as a result of radiative heat loss from the soil, vegetation, and near-surface atmosphere. Because a single frost event can damage or destroy

agricultural crops within one night, accurate and timely prediction of frost-prone conditions is essential for effective frost management and the development of early-warning systems. Conventional frost prediction approaches are often based primarily on air temperature and predefined temperature thresholds. However, the occurrence and intensity of radiation frost are also strongly influenced by atmospheric moisture conditions. Consequently, incorporating humidity-related variables into prediction models may provide additional information for identifying conditions favorable for frost formation.

In recent years, machine learning (ML) algorithms have increasingly been applied to weather and agricultural forecasting because of their ability to identify nonlinear relationships within complex meteorological datasets. Previous studies have demonstrated the potential of algorithms such as Support Vector Machines, Random Forest, Artificial Neural Networks, and XGBoost for frost detection and local temperature prediction. Nevertheless, the performance of these models is highly dependent on the characteristics of the study area, the forecasting horizon, and the variables used as model inputs. In particular, most existing frost prediction studies have focused on air temperature or direct frost classification, whereas relatively limited attention has been given to short-term prediction of dew point temperature as a physically meaningful indicator of atmospheric moisture and frost-prone conditions.

Therefore, the present study aimed to evaluate the short-term prediction of dew point temperature as an important parameter for identifying radiation frost conditions and to investigate the effect of incorporating meteorological–physical features on the performance of machine learning models. Meteorological observations from Tehran, Iran, were used to evaluate seven machine learning algorithms over 6- and 12-hour forecasting horizons. The specific objectives were to compare model performance using meteorological–temporal variables alone and after incorporating additional physical features related to atmospheric moisture, and to identify the most appropriate model for each forecasting horizon and prediction objective.

Methods

Meteorological observations recorded at Mehrabad Airport station in Tehran were used for the period from 1 March 2005 to 21 May 2025. For each year, the period from 1 March to 21 May was selected because it corresponds to the seasonal period during which radiation frost may occur in the study region. The original dataset consisted of 13,490 records with a six-hour temporal resolution. Air temperature, relative humidity, and dew point temperature were considered the primary meteorological variables. Dew point temperature at 6 and 12 hours ahead was defined as the target variable, and the prediction problem was formulated as a multivariate time-series regression problem.

To account for temporal dependencies in the meteorological variables, lagged features were generated at 6, 12, 18, and 24 hours prior to each prediction time. Short-term temporal changes, moving averages, recent minimum and maximum values, and cyclical representations of the hour of the day and day of the year were also incorporated into the input dataset. These transformations were used to represent both short-term persistence and diurnal and annual periodicity while avoiding inappropriate treatment of cyclical temporal variables as linear quantities.

Two groups of predictor variables were subsequently constructed. The first group, referred to as meteorological–temporal features, included the current meteorological observations, lagged variables, temporal differences, moving averages, recent minimum and maximum values, and cyclical time features. The second group, referred to as meteorological–physical features, included all variables in the first group plus saturation vapor pressure, actual vapor pressure, vapor pressure deficit (VPD), and the difference between air temperature and dew point temperature. These additional variables were introduced to provide a more explicit representation of atmospheric moisture conditions and their physical characteristics.

The dataset was divided chronologically to preserve the temporal structure of the observations and prevent information from future periods from entering model training. Data from 2005–2020 were used for training, observations from 2021–2022 were used for validation, and data from 2023–2025 were reserved as an independent test set. Missing values in the input variables were replaced using the median calculated exclusively from the training data. For the target variable, observations without an available future dew point temperature were excluded from the corresponding forecasting dataset.

Seven machine learning algorithms were evaluated: Ridge Regression, Support Vector Regression (SVR), K-Nearest Neighbors (KNN), Random Forest (RF), Extremely Randomized Trees (Extra Trees), Gradient Boosting Regression (GBR), and Extreme Gradient Boosting (XGBoost). A persistence-based baseline model was also developed, in which the most recently observed dew point temperature was used as the prediction for the future time. Model performance was assessed using the coefficient of determination (R^2), mean absolute error (MAE), root mean squared error (RMSE), and additional classification-oriented indicators for identifying conditions associated with frost risk, including precision, recall, F1-score, and the Critical Success Index (CSI). A skill score was also used to evaluate the improvement of the machine learning models relative to the persistence baseline.

Results

The results based on meteorological–temporal features showed that Ridge Regression achieved the best overall numerical performance at both forecasting horizons. For the 6-hour forecast, Ridge Regression produced an MAE of 2.19 °C, an RMSE of 3.10 °C, and an R^2 of 0.72. In comparison, the persistence baseline yielded an MAE of 2.77 °C and an RMSE of 3.76 °C. Thus, Ridge Regression reduced the MAE by approximately 21% and the RMSE by approximately 17.7% relative to the baseline. XGBoost and Gradient Boosting Regression showed performance close to Ridge Regression, whereas KNN exhibited the weakest performance among the machine learning models, with an MAE of 2.49 °C, an RMSE of 3.44 °C, and an R^2 of 0.653.

For the 12-hour forecasting horizon using meteorological–temporal features, Ridge Regression again achieved the best overall performance, with an MAE of 2.76 °C, an RMSE of 3.76 °C, and an R^2 of 0.584. The corresponding persistence baseline produced an MAE of 3.76 °C and an RMSE of 4.93 °C. Ridge Regression therefore reduced the MAE and RMSE by approximately 26.8% and 23.7%, respectively. XGBoost was the second-best model, with an MAE of 2.81 °C, an RMSE of 3.81 °C, and an R^2 of 0.573. Similar to the 6-hour horizon, KNN showed the weakest performance among the machine learning algorithms.

Adding meteorological–physical features, including saturation vapor pressure, actual vapor pressure, VPD, and the air temperature–dew point temperature difference, resulted in an overall positive but relatively limited improvement in model performance. These variables provided additional information about atmospheric moisture conditions and the proximity of the atmosphere to saturation, which can be relevant for identifying critical conditions associated with radiation frost.

At the 6-hour forecasting horizon, XGBoost achieved the best numerical performance after the addition of the physical features, with an MAE of 2.14 °C and an RMSE of 3.03 °C. Its precision, recall, F1-score, and CSI were 0.916, 0.902, 0.909, and 0.833, respectively. Gradient Boosting Regression showed very similar performance, with an MAE of 2.14 °C, an RMSE of 3.04 °C, an F1-score of 0.907, and a CSI of 0.830. Although SVR did not achieve the lowest numerical error, it produced the highest precision and recall, at 0.919 and 0.904, respectively, resulting in the highest F1-score (0.911) and CSI (0.837) among the evaluated models. Therefore, SVR was particularly suitable when the primary objective was identifying conditions conducive to frost, whereas XGBoost was preferable when minimizing numerical prediction errors was the primary objective.

At the 12-hour horizon, XGBoost again achieved the lowest numerical errors, with an MAE of 2.61 °C and an RMSE of 3.62 °C. Its F1-score and CSI were 0.873 and 0.774, respectively. Ridge Regression showed balanced performance, with a precision of 0.886, recall of 0.870, F1-score of 0.878, and CSI of 0.783, representing the highest F1-score and CSI at this forecasting horizon. Thus, Ridge Regression provided the most balanced performance for identifying frost-prone conditions over the 12-hour horizon.

Comparison of the two forecasting horizons demonstrated a consistent decline in predictive performance when the horizon increased from 6 to 12 hours. This reduction indicates that longer forecasting horizons are associated with greater uncertainty, even when additional physical features describing atmospheric moisture are included. Although the meteorological–physical features generally improved model performance, the magnitude of improvement was relatively limited. This may partly be attributed to the physical dependence of variables such as VPD, saturation vapor pressure, and the air temperature–dew point temperature difference on the basic meteorological

variables, meaning that they provide complementary representations rather than completely independent information.

Statistical pairwise comparisons were also conducted to determine whether differences in model performance represented statistically meaningful improvements rather than merely small numerical differences. The Holm correction was applied to account for multiple pairwise comparisons. At the 6-hour horizon, XGBoost showed statistically significant improvements over KNN, the persistence baseline, and Gradient Boosting Regression, whereas its differences from Ridge Regression, SVR, Extra Trees, and Random Forest were not statistically significant. At the 12-hour horizon, although Ridge Regression achieved the lowest RMSE, its performance did not differ significantly from that of SVR, XGBoost, Extra Trees, Gradient Boosting Regression, or Random Forest.

Conclusion

This study demonstrated the potential of machine learning algorithms for short-term prediction of dew point temperature as a physically relevant indicator for forecasting conditions conducive to radiation frost. All evaluated machine learning models outperformed the persistence-based baseline, indicating that the meteorological and temporal information contained in the predictor variables provided useful information for predicting future dew point temperature. However, model performance depended on both the forecasting horizon and the type of input features.

When only meteorological–temporal features were used, Ridge Regression provided the most stable and balanced overall performance at both the 6- and 12-hour horizons. After incorporating meteorological–physical features, XGBoost achieved the lowest numerical prediction errors at both horizons, while SVR at 6 hours and Ridge Regression at 12 hours provided better performance according to the classification-oriented measures used to identify frost-prone conditions. These findings emphasize that the model with the lowest numerical error is not necessarily the most appropriate model for identifying critical frost conditions.

The addition of saturation vapor pressure, actual vapor pressure, VPD, and the air temperature–dew point temperature difference had a positive but limited effect on predictive performance. Nevertheless, these features provide a more explicit representation of atmospheric moisture conditions and can complement conventional meteorological predictors. The decline in model performance from 6 to 12 hours also highlights the increasing uncertainty associated with longer forecasting horizons. Overall, the results indicate that a dew-point-temperature-based machine learning framework, combined with meteorological variables and physically meaningful atmospheric moisture features, can provide a suitable basis for the development of short-term radiation frost forecasting and early-warning systems. Future studies should incorporate additional spatial observations, surface and atmospheric variables, and data from different agricultural regions to improve the generalizability and practical applicability of the proposed forecasting framework.

Ethical Consideration

The author avoided data fabrication, falsification, plagiarism, and misconduct.

Funding

This paper did not receive financial support.

Conflict of Interest

The author declares no conflict of interest.



شاپا الکترونیکی: ۴۱۶۸-۲۴۲۳

مدیریت مخاطرات محیطی

سایت نشریه: <https://jhsci.ut.ac.ir>



انتشارات دانشگاه تهران

مدل سازی دمای نقطه شبنم بر پایه الگوریتم های یادگیری ماشین

نیکروز باقری

عضو هیأت علمی مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران. رایانامه: nikroozbagheri@yahoo.com.au

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ های مقاله:

تاریخ دریافت: ۱۴۰۵/۰۶/۲۳

تاریخ بازنگری: ۱۴۰۵/۰۷/۲۱

تاریخ پذیرش: ۱۴۰۵/۰۷/۲۲

تاریخ انتشار: ۱۴۰۵/۰۷/۳۰

کلیدواژه ها:

سرمزدگی،

پیش بینی،

دمای نقطه شبنم،

کشاورزی هوشمند،

یادگیری ماشین.

یکی از مهم ترین کاربردهای دمای نقطه شبنم در کشاورزی، پیش بینی سرمازدگی تابشی است. پیش بینی دقیق و به موقع سرمازدگی تابشی از اهمیت زیادی در مدیریت خسارت ها برخوردار است. وقوع سرمازدگی تنها به دمای هوا وابسته نیست و متغیرهای مرتبط با وضعیت رطوبتی جو نیز در شکل گیری آن نقش دارند. این پژوهش با هدف ارزیابی پیش بینی کوتاه مدت دمای نقطه شبنم و بررسی اثر ویژگی های هواشناسی - فیزیکی بر عملکرد مدل های مبتنی بر یادگیری ماشین با داده های هواشناسی شهر تهران انجام گرفت. متغیرهای دمای هوا، رطوبت نسبی هوا و دمای نقطه شبنم، متغیرهای ورودی در نظر گرفته شدند. همچنین فشار بخار اشباع، فشار بخار واقعی، کسری فشار بخار و اختلاف دمای هوا از دمای نقطه شبنم به عنوان ویژگی های فیزیکی به مدل ها افزوده شدند. هفت الگوریتم یادگیری ماشین شامل رنج، رگرسیون بردار پشتیبان، نزدیک ترین همسایه، جنگل تصادفی، درختان فوق تصادفی، رگرسیون تقویتی گرادیانی و XGBoost در دو افق زمانی پیش بینی شش و دوازده ساعته ارزیابی و عملکرد آنها با مدل پایه مقایسه شد. بر اساس نتایج، با استفاده از ویژگی های هواشناسی - زمانی، مدل رنج در هر دو افق زمانی بهترین عملکرد کلی را داشت و مقادیر میانگین مطلق خطای آن برای افق زمانی شش و دوازده ساعته، به ترتیب ۲/۱۹ و ۲/۷۶ درجه سلسیوس و ریشه میانگین مربعات خطای آن به ترتیب ۳/۰۱ و ۳/۷۷ درجه سلسیوس به دست آمد. با افزودن ویژگی های هواشناسی - فیزیکی، مدل XGBoost در هر دو افق زمانی، از نظر کاهش خطای عددی عملکرد بهتری نشان داد؛ به طوری که در افق زمانی شش ساعته، میانگین مطلق خطا و ریشه میانگین مربعات خطای به ترتیب ۲/۱۴ و ۳/۰۳ درجه سلسیوس و در افق زمانی دوازده ساعته، میانگین مطلق خطا و ریشه میانگین مربعات خطای به ترتیب ۲/۶۱ و ۳/۶۲ درجه سلسیوس داشت. مدل رگرسیون بردار پشتیبان در برآورد ۶ ساعت پیش رو با امتیاز F1 برابر ۰/۹۱۱ و شاخص موفقیت بحرانی برابر ۰/۸۳۷ و مدل رنج در برآورد ۱۲ ساعت پیش رو با امتیاز F1 برابر ۰/۸۷۸ و شاخص موفقیت بحرانی برابر ۰/۷۸۳ عملکرد مطلوب تری داشتند. همچنین افزایش افق زمانی پیش بینی از ۶ به ۱۲ ساعت، موجب کاهش دقت در همه مدل ها شد. مقایسه مدل ها با مدل پایه نیز نشان داد که مدل های مبتنی بر الگوریتم های یادگیری ماشین توانایی بهبود پیش بینی دمای نقطه شبنم را دارند. یافته ها نشان می دهد که الگوریتم های یادگیری ماشین می توانند چارچوب مناسبی را برای پیش بینی کوتاه مدت دمای نقطه شبنم به عنوان شاخصی برای پیش بینی شرایط مستعد سرمازدگی تابشی فراهم کنند.

استناد: باقری، نیکروز (۱۴۰۵). مدل سازی دمای نقطه شبنم بر پایه الگوریتم های یادگیری ماشین. مدیریت مخاطرات محیطی، ۱۳ (۲)، ۱۶۳-۱۷۹.

DOI: <http://doi.org/10.22059/jhsci.2026.423021.958>

© نویسندگان ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/jhsci.2026.423021.958>



مقدمه

دمای نقطه شبنم یکی از متغیرهای مهم هواشناسی برای توصیف وضعیت رطوبتی جو بوده و بیانگر دمایی است که در آن، با سرد شدن هوا و در صورت ثابت ماندن مقدار بخار آب، هوا به حالت اشباع می‌رسد. سرمازدگی تابشی به‌طور معمول در شب‌های صاف و آرام رخ می‌دهد؛ در این شرایط، سطح زمین و پوشش گیاهی از طریق گسیل تابش بلندموج انرژی از دست می‌دهند و سرد می‌شوند. در چنین شرایطی، دمای نقطه شبنم اطلاعات مهمی درباره مقدار بخار آب موجود در هوا و احتمال وقوع چگالش یا تشکیل یخ روی سطوح گیاهی فراهم می‌کند. هنگامی که دمای سطح گیاه به دمای نقطه شبنم برسد، بخار آب شروع به چگالش می‌کند و در صورت کاهش بیشتر دما، امکان تشکیل یخ افزایش می‌یابد. بنابراین از دمای نقطه شبنم می‌توان برای پیش‌بینی شرایط مساعد رخداد سرمازدگی استفاده کرد (Snyder & de Melo-Abreu, 2005). همچنین افزایش مدت خیس ماندن برگ در شرایط دمایی مناسب می‌تواند احتمال رشد برخی بیماری‌های گیاهی را افزایش دهد. به همین دلیل، از اطلاعات مربوط به دمای نقطه شبنم می‌توان برای ارزیابی شرایط مساعد بیماری‌های گیاهی نیز استفاده کرد (Rowlandson et al., 2015). بنابراین پایش و پیش‌بینی این متغیر برای طراحی سامانه‌های پیش‌بینی و هشدار مخاطراتی مانند سرمازدگی تابشی و شیوع بیماری‌های کشاورزی ضروری است (Snyder & de Melo-Abreu, 2005; Rowlandson et al., 2015).

سرمازدگی تابشی یکی از مخاطرات بزرگ محیطی است (Bhatti et al., 2026) که ممکن است در طول تنها یک شب، تمام مزرعه یا درختان باغ را از بین ببرد (Talsma et al., 2023; Tarraga et al., 2025). مخاطرات محیطی همه خطرهای بالقوه‌ای را که ممکن است انسان، موجودات زنده و محیط زیست را به خطر بیندازد شامل می‌شود (Abdolshah, 2024). بنابراین شناخت مخاطرات و بررسی رفتار آنها، می‌تواند آسیب‌های ناشی از آن را به موجودات زنده و طبیعت کاهش دهد. تغییر اقلیم یکی از چالش‌های مهم زیست‌محیطی قرن حاضر به شمار می‌رود که پیامدهای جدی اقتصادی و اجتماعی دارد و دارای تأثیر منفی بر امنیت غذایی است. بنابراین راهکارهای سازگاری با اقلیم، از موضوع‌های مهم روز پژوهش‌های کشاورزی است (Bazgir et al., 2016).

مرور پژوهش‌های پیشین نشان می‌دهد که دمای نقطه شبنم یکی از متغیرهای هواشناسی مؤثر در تحلیل شرایط سرمازدگی، به‌ویژه سرمازدگی تابشی است. از سوی دیگر، پژوهش‌های مربوط به پیش‌بینی سرمازدگی نشان داده‌اند که افزودن متغیر دمای نقطه شبنم به متغیر حداقل دمای هوا می‌تواند عملکرد سامانه‌های پیش‌بینی سرمازدگی را بهبود بخشد و تعداد هشدارهای کاذب را کاهش دهد (Omazić et al., 2024).

در سال‌های اخیر، کاربرد الگوریتم‌های یادگیری ماشین^۱ برای برآورد و پیش‌بینی دمای نقطه شبنم در حال توسعه است (Song et al., 2021) و این مدل‌ها در مقایسه با مدل‌های آماری سنتی، عملکرد بهتری (Bhakare et al., 2025) به‌ویژه برای پیش‌بینی‌های محیط زیستی نشان داده‌اند (Torres-Cruz et al., 2025). مدل‌های یادگیری ماشین به دلیل توانایی در شناسایی روابط غیرخطی موجود در مجموعه داده‌های پیچیده، فرصت‌های جدیدی را برای پیش‌بینی‌های هواشناسی کشاورزی در مقیاس خرد فراهم کرده است (Talsma et al., 2023; Tarraga et al., 2025; Zhang et al., 2026). در سال‌های اخیر، پژوهش‌های متعددی با استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی رخداد‌های هواشناسی انجام گرفته است. در پژوهشی با هدف بهبود برآورد دمای نقطه شبنم، یک مدل یادگیری ماشین مبتنی بر شبکه پژواک عمیق (DeepESN) ارائه شد. این مدل با استفاده از متغیرهای هواشناسی شامل دمای هوا، فشار اتمسفری، رطوبت نسبی، سرعت باد و تابش خورشیدی بنیان نهاده شد. عملکرد شبکه با مدل‌های ماشین‌های یادگیری افراطی، درخت‌های کاملاً تصادفی و درخت رگرسیون مقایسه شد. نتایج نشان داد که شبکه عمیق از نظر شاخص‌های ارزیابی عملکرد بهتری نسبت به مدل‌های مقایسه‌ای دارد (Alizamir et al., 2020). در پژوهش دیگری، با هدف پیش‌بینی زودهنگام سرمازدگی محصولات کشاورزی، از مدل‌های یادگیری عمیق استفاده شد. بر اساس نتایج، مدل مبتنی بر یادگیری عمیق به دقت ۹۷ درصد و حساسیت ۸۹/۹ درصد دست یافت (Cadenas et al., 2020).

(al., 2020). در پژوهش دیگری سه روش یادگیری ماشین شامل جنگل تصادفی، ماشین بردار پشتیبان و شبکه عصبی پرسپترون چندلایه، برای پیش‌بینی سرمازدگی مقایسه شد. نتایج نشان داد که روش جنگل تصادفی با دقت بیش از ۹۰ درصد کارآمدترین الگوریتم برای تشخیص سرمازدگی است (Diniz et al., 2021). در پژوهشی دیگر، روش ماشین بردار پشتیبان در مقایسه با الگوریتم‌های دیگر، عملکرد بهتری در پیش‌بینی سرمازدگی داشت. نتایج نشان داد که عملکرد مدل به عوامل متعددی مانند روش پردازش داده‌ها، متغیرهای استفاده شده و تنظیم پارامترهای الگوریتم وابسته است (Xu et al., 2021). در پژوهش دیگری قابلیت دو روش جنگل تصادفی و مارس^۱ برای پیش‌بینی میانگین ماهانه بلندمدت دمای نقطه شب‌نم بررسی شد (Zhang et al., 2022). این پژوهش با استفاده از داده‌های هواشناسی انجام گرفت. متغیرهای ورودی شامل دمای هوا، مدت تابش آفتاب، رطوبت نسبی، تابش خورشیدی و اطلاعات مکانی بودند. نتایج نشان داد که هر دو روش قابلیت مناسبی برای برآورد دمای نقطه شب‌نم دارند و استفاده از ترکیب مناسب متغیرهای هواشناسی و جغرافیایی، موجب بهبود عملکرد مدل‌ها می‌شود. در پژوهشی دیگر از الگوریتم‌های یادگیری ماشین برای پیش‌بینی رخداد‌های سرمازدگی استفاده شد. در این پژوهش، سه مدل شامل شبکه عصبی عمیق^۲، شبکه عصبی کانولوشنی^۳ و جنگل تصادفی برای پیش‌بینی در بازه‌های زمانی ۶ تا ۴۸ ساعت بررسی شد. نتایج نشان داد که این مدل‌ها از دقت خوبی برای پیش‌بینی دما و رخداد‌های سرمازدگی برخوردارند (Talsma et al., 2023). در تحقیق دیگری از الگوریتم‌های جنگل تصادفی، شبکه کانولوشن و XGBoost برای پیش‌بینی رخداد‌های سرمازدگی در استان فارس استفاده شد. این مدل‌ها با استفاده از متغیرهای جوی مانند دما، رطوبت، سرعت باد و فشار حاصل از ایستگاه هواشناسی آموزش داده شدند تا رخداد‌های سرمازدگی را ۲۴ ساعت زودتر پیش‌بینی کنند. نتایج این پژوهش نشان داد که مدل‌های یادگیری ماشین، به‌ویژه جنگل تصادفی و XGBoost، عملکردی به‌مراتب بهتری از مدل‌های آماری دارند (Barroni et al., 2023). در یک پژوهش، با هدف بهبود پیش‌بینی سرمازدگی بهاره در ۱۲ ساعت پیش از وقوع، ۹ مدل جنگل تصادفی برای پیش‌بینی دمای کمینه روزانه در سطح تاج‌پوشش با کمک داده‌های هواشناسی محلی ایجاد شد. بر اساس نتایج، مدل‌های جنگل تصادفی در مقایسه با مدل سنتی فرانکلین، خطای جذر میانگین مربعات را کاهش دادند و در طبقه‌بندی سرمازدگی به دقت ۹۱ تا ۹۵ درصد دست یافتند (Bhatti et al., 2026). برای ارزیابی خطر سرمازدگی در مزارع چای از الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و جنگل تصادفی استفاده شده و مدل جنگل تصادفی به دقت ۹۳ درصد دست یافت. این پژوهش‌ها اهمیت ترکیب متغیرهای توپوگرافی و هواشناسی را برای پیش‌بینی بهتر و دقیق‌تر نشان داده‌اند (Zhang et al., 2026).

بر اساس مرور پژوهش‌ها، می‌توان نتیجه گرفت که پیش‌بینی دمای نقطه شب‌نم گام مؤثری در پیش‌بینی سرمازدگی تابشی است. از طرفی، مدل‌های پیش‌بینی جهان‌شمول نیستند و در هر منطقه برحسب نوع و تعداد داده‌ها نتایج متفاوتی به دست آمده است. بنابراین باید برای هر منطقه متناسب با داده‌های هواشناسی همان منطقه، مدل‌های پیش‌بینی با دقت مناسب شناسایی شوند. هدف این پژوهش، توسعه و ارزیابی یک چارچوب پیش‌بینی کوتاه‌مدت دمای نقطه شب‌نم در دو افق زمانی ۶ و ۱۲ ساعت، برای داده‌های هواشناسی شهر تهران با تأکید بر نقش همزمان ویژگی‌های زمانی و ترمودینامیکی - فیزیکی متغیرهای هواشناسی است. در این چارچوب، افزون بر کاربرد متغیرهای پایه هواشناسی و ویژگی‌های تأخیری و چرخه‌ای، مجموعه‌ای از ویژگی‌های فیزیکی به مدل‌ها افزوده و اثر آنها بر عملکرد الگوریتم‌های مختلف یادگیری ماشین ارزیابی شده است. همچنین مقایسه عملکرد مدل‌ها در دو افق زمانی و در برابر مدل پایه، امکان ارزیابی الگوریتم‌های یادگیری ماشین و اثر افزایش افق زمانی بر دقت پیش‌بینی را فراهم کرده است. نتایج این پژوهش مبنایی برای کاربردهای بعدی در هواشناسی کشاورزی و سامانه‌های پایش مخاطرات جوی خواهد بود.

داده‌ها و روش‌ها

در این پژوهش، از داده‌های هواشناسی ثبت شده از ۱۳۸۳/۱۲/۰۱ تا ۱۴۰۴/۰۲/۳۱ شهرستان تهران (ایستگاه هواشناسی فرودگاه

1. Multivariate Adaptive Regression Splines (MARS)
2. Deep Neural Network
3. Convolutional Neural Network (CNN)

مهرآباد) استفاده شد. بازه زمانی داده‌های هر سال از ۱ اسفند تا ۳۱ اردیبهشت سال بعد انتخاب شد. این بازه زمانی مربوط به دوره‌هایی از سال است که احتمال بروز سرمازدگی تابشی در منطقه وجود دارد. داده‌ها با تفکیک زمانی شش‌ساعته در دسترس بودند. متغیرهای اصلی شامل دمای هوا (T)، رطوبت نسبی (RH) و دمای نقطه شبنم (T_d) بودند. مجموع داده‌های اولیه برابر با ۱۳۴۹۰ رکورد بود.

بررسی اولیه داده‌ها نشان داد که تعداد مقادیر گمشده در متغیرهای دمای هوا، رطوبت نسبی و دمای نقطه شبنم به ترتیب ۳۷، ۵۳ و ۲۴ بود. با توجه به تعداد محدود داده‌های گمشده، مقدار میانه هر متغیر صرفاً از داده‌های مجموعه آموزش (به‌منظور جلوگیری از نشت داده‌ها^۱) محاسبه و برای جایگزینی مقادیر گمشده همان متغیر استفاده شد. برای متغیر هدف، یعنی دمای نقطه شبنم در افق پیش‌بینی ۶ یا ۱۲ ساعت آینده، اگر مقدار واقعی دمای نقطه شبنم در دسترس نبود، نمونه مربوط از مجموعه مورد استفاده برای آن افق پیش‌بینی حذف شد؛ زیرا وجود مقدار واقعی برای آموزش و ارزیابی عملکرد مدل ضروری است.

تعریف مسئله و متغیر هدف

هدف اصلی این پژوهش، پیش‌بینی دمای نقطه شبنم در دو افق زمانی مستقل ۶ و ۱۲ ساعت آینده بود. بنابراین برای هر زمان t ، متغیر هدف به‌صورت زیر تعریف شد:

$$y_{t+h} = T_d(t+h) \quad (۱)$$

که در آن h افق پیش‌بینی و برابر با ۶ یا ۱۲ ساعت است.

مدل‌ها به‌طور مستقل برای هر افق زمانی آموزش داده و ارزیابی شدند. بدین ترتیب، مسئله اصلی پژوهش به‌صورت یک مسئله رگرسیون سری زمانی چندمتغیره تعریف شد.

ساخت سری زمانی

به‌منظور استفاده از حافظه زمانی متغیرهای هواشناسی، برای هر متغیر ورودی ویژگی‌های تأخیری در فواصل زمانی مختلف ایجاد شد. برای هر متغیر X ، ویژگی تأخیری (D) به‌صورت زیر تعریف شد:

$$D = X_{t-k} \quad (۲)$$

که در آن K زمان تأخیر است.

افزون‌بر ویژگی‌های تأخیری، تغییرات کوتاه‌مدت متغیرها نیز با استفاده از تفاضل زمانی بر اساس رابطه زیر محاسبه شد:

$$\Delta X_{t,k} = X_t - X_{t-k} \quad (۳)$$

ویژگی‌های زمانی و چرخه‌ای داده‌ها

به‌منظور در نظر گرفتن تغییرات دوره‌ای در مقیاس شبانه‌روزی و سالانه، ساعت شبانه‌روز و روز سال به ویژگی‌های چرخه‌ای تبدیل شدند که در روابط ریاضی زیر ارائه شده است:

$$Hour_{sin} = \sin\left(\frac{2\pi \times Hour}{24}\right) \quad (۴)$$

$$Hour_{cos} = \cos\left(\frac{2\pi \times Hour}{24}\right) \quad (۵)$$

به‌طور مشابه، ویژگی‌های چرخه‌ای مربوط به روز سال نیز ایجاد شدند:

$$DOY_{sin} = \sin\left(\frac{2\pi \times DOY}{365}\right) \quad (۶)$$

$$DOY_{cos} = \cos\left(\frac{2\pi \times DOY}{365}\right) \quad (۷)$$

این تبدیل از تفسیر نادرست متغیرهای دوره ای به صورت متغیرهای خطی جلوگیری می کند؛ برای مثال فاصله بین ساعت ۲۳ و ۰ را به صورت فاصله عددی بزرگی در نظر نمی گیرد.

ویژگی های فیزیکی – هواشناسی

به منظور بررسی نقش داده های فیزیکی در بهبود پیش بینی، دو مجموعه ویژگی به عنوان متغیرهای ورودی به صورت زیر ایجاد شد:

مجموعه اول: متغیرهای هواشناسی – زمانی

این مجموعه شامل متغیرهای زیر است:

- مقادیر فعلی T ، RH و T_d ؛
- ویژگی های تأخیری در افق های ۶، ۱۲، ۱۸ و ۲۴ ساعت گذشته؛
- تغییرات زمانی شش و دوازده ساعته؛
- میانگین های متحرک؛
- کمترین و بیشترین مقادیر اخیر؛
- ویژگی های چرخه ای ساعت شبانه روز و ویژگی های چرخه ای روز سال.

مجموعه دوم: متغیرهای هواشناسی – فیزیکی

افزون بر ویژگی های مجموعه اول، متغیرهای فیزیکی زیر نیز محاسبه و به مدل ها اضافه شدند که در روابط ریاضی زیر ارائه شده است (Irmak & Kukal, 2022; Yang & Song, 2026):

- فشار بخار اشباع (e_s)؛
- فشار بخار واقعی (e_a)؛
- کسری فشار بخار؛
- اختلاف دمای هوا و دمای نقطه شبنم.

$$e_s = 0.6108 \exp\left(\frac{17.27T}{T + 237.3}\right) \quad (8)$$

$$e_a = \frac{RH}{100} \times e_s \quad (9)$$

$$VPD = e_s - e_a \quad (10)$$

$$\Delta T_d = T - T_d \quad (11)$$

آماده سازی داده ها برای مدل سازی

به دلیل ماهیت سری زمانی داده ها، داده ها بر اساس زمان به سه بخش تقسیم شدند:

- داده های آموزش: داده های سال های ۲۰۰۵ تا ۲۰۲۰؛
- داده های اعتبارسنجی: داده های سال های ۲۰۲۱ و ۲۰۲۲؛
- آزمون مستقل: داده های سال های ۲۰۲۳ تا ۲۰۲۵.

الگوریتم های یادگیری ماشین

در این پژوهش هفت الگوریتم یادگیری ماشین برای پیش بینی دمای نقطه شبنم اجرا و مقایسه شدند:

۱. رگرسیون ریدج^۱؛

۲. رگرسیون بردار پشتیبان^۱؛

۳. نزدیک‌ترین همسایه^۲؛

۴. جنگل تصادفی^۳؛

۵. درختان فوق تصادفی^۴؛

۶. رگرسیون تقویت گرادیانی^۵؛

۷. روش XGBoost^۶.

برای مقایسه عملکرد مدل‌های مبتنی بر یادگیری ماشین با یک روش مرجع ساده، مدل پایه نیز طبق رابطه ۱۲ استفاده شد. در این روش فرض می‌شود که مقدار دمای نقطه شبنم در زمان پیش‌بینی، برابر با آخرین مقدار مشاهده‌شده آن است:

$$\hat{T}_d(t+h) = T_d(t) \quad (12)$$

معیارهای ارزیابی

عملکرد مدل‌ها در پیش‌بینی دمای نقطه شبنم با استفاده از معیارهای زیر ضریب تبیین ارزیابی شد:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

که در آن y_i مقدار مشاهده‌شده، $\hat{y}_i$ مقدار پیش‌بینی‌شده، $\bar{y}$ میانگین مقادیر مشاهده‌شده و n تعداد نمونه‌هاست. به‌منظور ارزیابی مقدار بهبود مدل‌های یادگیری ماشین نسبت به مدل پایه، از شاخص مهارت پیش‌بینی^۷ طبق رابطه ۱۶ استفاده شد:

$$SS = 1 - \frac{RMSE_{model}}{RMSE_{Persistence}} \quad (16)$$

مقادیر SS مثبت نشان‌دهنده عملکرد بهتر مدل یادگیری ماشین نسبت به مدل پایه، و مقدار صفر این شاخص بیانگر عملکرد مشابه دو روش است. شاخص‌های دیگر نیز برای ارزیابی مدل‌ها به‌شرح روابط ریاضی زیر محاسبه شد (Cadenas et al., 2020; Hand et al., 2021; Rozante et al., 2023):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (18)$$

$$Specificity = \frac{TN}{TN + FP} \quad (19)$$

$$F - Score = \frac{2TP}{2TP + FP + FN} \quad (20)$$

1. Support Vector Regression (SVR)
2. K-Nearest Neighbors (KNN)
3. Random Forest (RF)
4. Extremely Randomized Trees
5. Gradient Boosting Regression (GBR)
6. Extreme Gradient Boosting
7. Skill Score

$$CSI = \frac{TP}{TP + FP + FN} \quad (21)$$

که در آن: TP: مثبت درست؛ FP: مثبت کاذب؛ FN: منفی کاذب؛ TN: منفی درست؛ و CSI: شاخص موفقیت بحرانی است.

نتایج و بحث

نتایج این پژوهش به شرح زیر است:

عملکرد مدل های یادگیری ماشین در پیش بینی دمای نقطه شبنم ۶ و ۱۲ ساعت آینده بر اساس ویژگی های هواشناسی - زمانی

نتایج ارزیابی مدل های یادگیری ماشین در پیش بینی دمای نقطه شبنم ۶ و ۱۲ ساعت پیش رو بر اساس ویژگی های هواشناسی - زمانی در جدول ۱ ارائه شده است. نتایج پیش بینی شش ساعته نشان می دهد که مدل ريج با مقدار میانگین قدر مطلق خطای^۲ برابر با ۲/۱۹ درجه سلسیوس، ریشه میانگین مربعات خطای^۳ برابر با ۳/۱۰ درجه سلسیوس و ضریب تبیین ۰/۷۲، بهترین عملکرد را در بین مدل ها داشته است. در مقایسه با مدل پایه، عملکرد ريج به طور چشمگیری بهتر بود. مدل پایه دارای میانگین قدر مطلق خطای برابر با ۲/۷۷ درجه سلسیوس، ریشه میانگین مربعات خطای برابر با ۳/۷۶ درجه سلسیوس و ضریب تبیین ۰/۵۸۵ بود. در واقع مدل ريج توانست میانگین قدر مطلق خطا را حدود ۲۱ درصد و ریشه میانگین مربعات را حدود ۱۷/۷ درصد کاهش دهد. این نتایج نشان می دهد که استفاده از متغیرهای ورودی و روش های یادگیری ماشین نسبت به مدل پایه، پیش بینی دقیق تری دارد. پس از مدل ريج، مدل های XGBoost و رگرسیون تقویت گرادیانی عملکرد بسیار نزدیکی به آن دارند. مدل XGBoost دارای میانگین قدر مطلق خطای ۲/۲۰ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۱۰ درجه سلسیوس و ضریب تبیین ۰/۷۱۸ بود؛ درحالی که رگرسیون تقویت گرادیانی به میانگین قدر مطلق خطای برابر با ۲/۲۰ درجه سلسیوس، ریشه میانگین مربعات خطای برابر با ۳/۱۱ درجه سلسیوس و ضریب تبیین ۰/۷۱۷ دست یافت. نزدیکی نتایج این مدل ها به مدل ريج نشان می دهد که کاربرد مدل های پیچیده تر لزوماً سبب افزایش چشمگیر دقت پیش بینی نمی شود. مدل جنگل تصادفی نیز عملکرد مناسبی داشت و مقدار میانگین قدر مطلق خطا، ریشه میانگین مربعات خطا و ضریب تبیین آن به ترتیب ۲/۲۲ درجه سلسیوس، ۳/۱۴ درجه سلسیوس و ۰/۷۱۱ بود. مقدار میانگین قدر مطلق خطا، ریشه میانگین مربعات خطا و ضریب تبیین مدل درختان فوق تصادفی نیز به ترتیب ۲/۲۳ درجه سلسیوس، ۳/۱۴ درجه سلسیوس و ۰/۷۱۰ به دست آمد. بنابراین مدل جنگل تصادفی کمی بهتر از مدل درختان فوق تصادفی عمل می کند، اما اختلاف عملکرد این دو مدل بسیار کم است. در هر حال، هر دو مدل نسبت به مدل ريج عملکرد ضعیف تری داشتند؛ هرچند این مدل ها همچنان توانایی مناسبی در پیش بینی دمای نقطه شبنم نسبت به مدل پایه نشان می دهند. مدل رگرسیون بردار پشتیبان نیز با میانگین قدر مطلق خطای ۲/۲۴ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۱۴ درجه سلسیوس و ضریب تبیین ۰/۷۱۰، عملکرد مقبولی دارد؛ اما نسبت به مدل ريج خطای بیشتری ایجاد می کند و ضریب تبیین کمتری دارد. از سوی دیگر، مدل نزدیک ترین همسایه با میانگین قدر مطلق خطای ۲/۴۹ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۴۴ درجه سلسیوس و ضریب تبیین ۰/۶۵۳، خطای بیشتری نسبت به مدل های دیگر داشت و تنها توانست حدود ۶۵/۳ درصد از تغییرات را توضیح دهد. این روش نسبت به بقیه الگوریتم های ارزیابی شده عملکرد ضعیف تری داشت. به طور کلی برای پیش بینی در افق زمانی شش ساعته و بر اساس ویژگی های هواشناسی - فیزیکی، رتبه بندی مدل ها بر اساس عملکرد نشان می دهد که مدل ريج بهترین مدل است (زیرا همزمان کمترین میانگین قدر مطلق خطا و ریشه میانگین مربعات خطا و بیشترین ضریب تبیین را به دست آورده است) و پس از آن به ترتیب XGBoost، رگرسیون تقویت گرادیانی، جنگل تصادفی، درختان فوق تصادفی و رگرسیون بردار پشتیبان قرار می گیرند؛ درحالی که مدل نزدیک ترین همسایه ضعیف ترین عملکرد را در بین مدل های یادگیری ماشین داشته است. نکته مهم دیگر، برتری همه مدل های یادگیری ماشین نسبت به مدل پایه است که

1. Critical Success Index

2. Mean Absolute Error (MAE)

3. Root Mean Squared Error (RMSE)

نشان می‌دهد این مدل‌ها توانسته‌اند الگوها و روابط موجود در متغیرهای ورودی را بهتر از یک روش ساده مبتنی بر تداوم شرایط قبلی استخراج کنند.

نتایج ارزیابی مدل‌های یادگیری ماشین در پیش‌بینی دمای نقطه شبنم ۱۲ ساعت پیش رو بر اساس ویژگی‌های هواشناسی-زمانی نشان می‌دهد که مدل رنج بهترین عملکرد را در بین مدل‌ها داشت. این مدل با مقدار میانگین قدر مطلق خطای برابر با ۲/۷۶ درجه سلسیوس، ریشه میانگین مربعات خطای برابر با ۳/۷۶ درجه سلسیوس و ضریب تبیین ۰/۵۸۴، بهترین عملکرد را داشت. مدل پایه دارای میانگین قدر مطلق خطای ۳/۷۶ درجه سلسیوس، ریشه میانگین مربعات خطای ۴/۹۳ درجه سلسیوس و ضریب تبیین ۰/۲۸۶ بود. بنابراین، مدل رنج توانست میانگین قدر مطلق خطا را حدود ۲۶/۸ درصد و ریشه میانگین مربعات خطا را حدود ۲۳/۷ درصد کاهش دهد. بنابراین کاربرد مدل رنج نسبت به مدل پایه، سبب بهبود چشمگیر دقت پیش‌بینی می‌شود و نشان می‌دهد که متغیرهای ورودی به‌کاررفته در مدل اطلاعات مفیدی برای پیش‌بینی دما دارند. پس از مدل رنج، مدل XGBoost بهترین عملکرد را در بین مدل‌ها داشت. این مدل دارای میانگین قدر مطلق خطای ۲/۸۱ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۸۱ درجه سلسیوس و ضریب تبیین ۰/۵۷۳ است. عملکرد این مدل بسیار نزدیک به مدل رنج است؛ اگرچه در هر سه معیار اندکی ضعیف‌تر عمل کرده است. پس از آن، مدل رگرسیون تقویت‌گرایانی با میانگین قدر مطلق خطای ۲/۸۳ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۸۴ درجه سلسیوس و ضریب تبیین ۰/۵۶۸ قرار داشت. بنابراین هر دو مدل عملکرد به‌نسبت مناسبی داشتند، با این حال نتوانستند عملکرد مدل رنج را بهبود دهند. مدل درختان فوق تصادفی نیز با میانگین قدر مطلق خطای ۲/۸۴ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۸۵ درجه سلسیوس و ضریب تبیین ۰/۵۶۶ عملکرد مقبولی نشان داد. عملکرد این مدل، کمی بهتر از مدل جنگل تصادفی بود. مدل جنگل تصادفی میانگین قدر مطلق خطای ۲/۸۶ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۸۷ درجه سلسیوس و ضریب تبیین ۰/۵۶۱ داشت. عملکرد این دو مدل به هم نزدیک و از عملکرد مدل رنج ضعیف‌تر بود. مدل رگرسیون بردار پشتیبان با میانگین قدر مطلق خطای ۲/۸۲ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۸۶ درجه سلسیوس و ضریب تبیین ۰/۵۶۳ عملکرد متوسطی داشت. همچنین مدل نزدیک‌ترین همسایه با میانگین قدر مطلق خطای ۳/۰۳ درجه سلسیوس، ریشه میانگین مربعات خطای ۴/۰۶ درجه سلسیوس و ضریب تبیین ۰/۵۱۶ ضعیف‌ترین عملکرد را در بین مدل‌های مبتنی بر یادگیری ماشین داشت.

جدول ۱. نتایج ارزیابی مدل‌های یادگیری ماشین برای پیش‌بینی دمای نقطه شبنم ۶ ساعت آتی بر اساس ویژگی‌های هواشناسی-زمانی

پیش‌بینی شش ساعته				پیش‌بینی دوازده ساعته		
مدل	میانگین قدر مطلق خطا (°C)	ریشه میانگین مربعات خطا (°C)	ضریب تبیین	میانگین قدر مطلق خطا (°C)	ریشه میانگین مربعات خطا (°C)	ضریب تبیین
مدل پایه	۲/۷۷	۳/۷۶	۰/۵۸۵	۳/۷۶	۴/۹۳	۰/۲۸۶
رنج	۲/۱۹	۳/۱۰	۰/۷۱۹	۲/۷۶	۳/۷۶	۰/۵۸۴
رگرسیون بردار پشتیبان	۲/۲۴	۳/۱۴	۰/۷۱۰	۲/۸۲	۳/۸۶	۰/۵۶۳
نزدیک‌ترین همسایه	۲/۴۹	۳/۴۴	۰/۶۵۳	۳/۰۳	۴/۰۶	۰/۵۱۶
جنگل تصادفی	۲/۲۲	۳/۱۴	۰/۷۱۱	۲/۸۶	۳/۸۷	۰/۵۶۱
درختان فوق تصادفی	۲/۲۳	۳/۱۴	۰/۷۱۰	۲/۸۴	۳/۸۵	۰/۵۶۶
رگرسیون تقویت‌گرایانی	۲/۲۰	۳/۱۱	۰/۷۱۷	۲/۸۳	۳/۸۴	۰/۵۶۸
XGBoost	۲/۲۰	۳/۱۰	۰/۷۱۸	۲/۸۱	۳/۸۱	۰/۵۷۳

عملکرد مدل‌های یادگیری ماشین در پیش‌بینی دمای نقطه شب‌نم در ۶ و ۱۲ ساعت پیش رو با افزودن ویژگی‌های هواشناسی-فیزیکی

نتایج ارزیابی عملکرد مدل‌ها در پیش‌بینی دمای نقطه شب‌نم در حالت افزودن ویژگی‌های هواشناسی-فیزیکی در جدول ۲ ارائه شده است. در افق پیش‌بینی شش‌ساعته، مدل XGBoost از نظر مقدار خطا، بهترین عملکرد را نشان داد. این مدل با میانگین قدر مطلق خطای ۲/۱۴ درجه سلسیوس و ریشه میانگین مربعات خطای ۳/۰۳ درجه سلسیوس، کمترین خطا را در بین مدل‌های ارزیابی شده به دست آورد. همچنین مقدار دقت آن ۰/۹۱۶، فراخوانی آن ۰/۹۰۲، امتیاز F1 برابر با ۰/۹۰۹ و CSI برابر با ۰/۸۳۳ بود. پس از XGBoost مدل رگرسیون تقویت‌گرایانی عملکرد بسیار نزدیکی به آن داشت. این مدل، دارای میانگین قدر مطلق خطای ۲/۱۴ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۰۴ درجه سلسیوس، امتیاز F1 برابر با ۰/۹۰۷ و CSI برابر با ۰/۸۳۰ است؛ بنابراین اختلاف عملکرد این دو مدل بسیار کم بود. مدل رگرسیون بردار پشتیبان نیز در افق زمانی شش‌ساعته، عملکرد بسیار مناسبی داشت. اگرچه میانگین قدر مطلق خطا و ریشه میانگین مربعات خطای آن به ترتیب ۲/۱۹ و ۳/۰۱ درجه سلسیوس بوده و مقادیر آن از مقادیر معادل برای مدل‌های XGBoost و رگرسیون تقویت‌گرایانی بیشتر بود؛ اما این مدل بیشترین دقت (۰/۹۱۹) و مقدار فراخوانی (۰/۹۰۴) را داشت. در نتیجه رگرسیون بردار پشتیبان دارای بیشترین مقدار امتیاز F1 (۰/۹۱۱) و بیشترین CSI (۰/۸۳۷) بود. بنابراین اگر هدف اصلی پیش‌بینی دمای نقطه شب‌نم باشد، رگرسیون بردار پشتیبان یکی از مناسب‌ترین مدل‌ها در افق شش‌ساعته محسوب می‌شود؛ درحالی که اگر کاهش خطای عددی اهمیت بیشتری داشته باشد، XGBoost عملکرد بهتری ارائه می‌دهد. مدل رنج نیز عملکرد مقبولی داشت و میانگین قدر مطلق خطا و ریشه میانگین مربعات خطای آن به ترتیب ۲/۱۵ و ۳/۰۴ درجه سلسیوس به دست آمد. با این حال، از نظر معیارهای پیش‌بینی دمای نقطه شب‌نم، عملکرد آن از عملکرد مدل‌های رگرسیون بردار پشتیبان و XGBoost ضعیف‌تر بود. مدل‌های جنگل تصادفی و درختان فوق تصادفی نیز عملکرد مناسبی داشتند، اما نسبت به مدل‌های XGBoost، رگرسیون تقویت‌گرایانی و رگرسیون بردار پشتیبان ضعیف‌تر بودند. در مقابل، مدل نزدیک‌ترین همسایه ضعیف‌ترین عملکرد را در بین الگوریتم‌های یادگیری ماشین داشت و میانگین قدر مطلق خطا و ریشه میانگین مربعات خطای آن به ترتیب ۲/۵۰ و ۳/۵۰ درجه سلسیوس به دست آمد. مدل پایه نیز با میانگین قدر مطلق خطای برابر با ۲/۷۹ درجه سلسیوس، ریشه میانگین مربعات خطای برابر با ۳/۷۷ درجه سلسیوس، امتیاز F1 برابر با ۰/۸۸۳ و CSI برابر با ۰/۷۹۱، ضعیف‌ترین عملکرد را نشان داد. از طرفی، در پیش‌بینی زمانی در افق شش‌ساعته بر اساس ویژگی‌های هواشناسی-فیزیکی، همه مدل‌ها نسبت به مدل پایه عملکرد بهتری داشتند.

در افق پیش‌بینی دوازده‌ساعته نیز عملکرد مدل‌ها از مدل پایه بهتر بود. اما همانند نتایج قبلی، افزایش افق زمانی موجب کاهش دقت پیش‌بینی شد. مدل XGBoost از نظر خطای عددی بهترین عملکرد را داشت و میانگین قدر مطلق خطای آن ۲/۶۱ درجه سلسیوس و ریشه میانگین مربعات خطای آن ۳/۶۲ درجه سلسیوس بود. همچنین این مدل دارای امتیاز F1 برابر با ۰/۸۷۳ و CSI برابر با ۰/۷۷۴ بود. مدل رگرسیون تقویت‌گرایانی نیز عملکرد بسیار مناسبی داشت و مقدار امتیاز F1 و شاخص CSI آن به ترتیب ۰/۸۷۲ و ۰/۷۷۳ به دست آمد. مدل رنج نیز در افق دوازده‌ساعته، عملکرد متعادلی نشان داد و با دقت ۰/۸۸۶، فراخوانی ۰/۸۷۰، امتیاز F1 برابر با ۰/۸۷۸ و CSI برابر با ۰/۷۸۳، عملکرد بسیار خوبی داشت. در واقع، مدل رنج در افق دوازده‌ساعته بیشترین مقدار F1 و CSI را به دست آورد. مدل رگرسیون بردار پشتیبان نیز در افق دوازده‌ساعته دارای میانگین قدر مطلق خطای ۲/۷۱ درجه سلسیوس، ریشه میانگین مربعات خطای ۳/۷۸ درجه سلسیوس، امتیاز F1 برابر با ۰/۸۷۰ و CSI برابر با ۰/۷۷۰ بود. از این‌رو این مدل با وجود مناسب بودن عملکرد، نسبت به مدل‌های رنج و رگرسیون تقویت‌گرایانی تا حدی ضعیف‌تر است. مدل درختان فوق تصادفی با میانگین قدر مطلق خطای ۲/۶۷ درجه سلسیوس و ریشه میانگین مربعات خطای ۳/۷۰ درجه سلسیوس کمی بهتر از مدل جنگل تصادفی با میانگین قدر مطلق خطای ۲/۶۷ درجه سلسیوس و ریشه میانگین مربعات خطای ۳/۷۰ درجه سلسیوس عمل کرده است. مدل نزدیک‌ترین همسایه نیز ضعیف‌ترین مدل یادگیری ماشین بود و میانگین قدر مطلق خطا و ریشه میانگین مربعات خطای آن به ترتیب ۲/۹۳ و ۴/۰۱ درجه سلسیوس به دست آمد. در مقابل، مدل

پایه با میانگین قدر مطلق خطای $3/67$ درجه سلسیوس و ریشه میانگین مربعات خطای $4/82$ درجه سلسیوس، امتیاز F1 برابر با $0/831$ و شاخص CSI برابر با $0/711$ ، ضعیف‌ترین عملکرد کلی را نشان داد.

مقایسه نتایج ارزیابی مدل‌ها در دو افق زمانی پیش‌بینی، نشان می‌دهد که افزایش زمان پیش‌بینی از ۶ به ۱۲ ساعت موجب کاهش عملکرد همه مدل‌ها شد. این موضوع نشان می‌دهد که حتی با استفاده از ویژگی‌های فیزیکی اضافی، افزایش افق پیش‌بینی سبب افزایش عدم قطعیت و در نتیجه افزایش خطای مدل می‌شود. اثر افزودن ویژگی‌های فیزیکی مثبت اما محدود بود. این ویژگی‌ها سبب ایجاد جهشی بسیار بزرگ در عملکرد مدل‌ها نشد، اما بهبود تدریجی و چشمگیری ایجاد کرد. یکی از دلایل محدود بودن این اثر آن است که بخشی از ویژگی‌های جدید مانند کسری فشار بخار، فشار بخار اشباع و اختلاف دمای هوا و نقطه شبنم، از متغیرهای پایه یا روابط فیزیکی مرتبط با آنها به دست می‌آیند؛ بنابراین اطلاعات کاملاً مستقلی به مدل اضافه نمی‌کنند، بلکه اطلاعات موجود را به شکل دیگری بیان می‌کنند.

جدول ۲. نتایج ارزیابی مدل‌های یادگیری ماشین برای پیش‌بینی دمای نقطه شبنم ۶ و ۱۲ ساعت آتی بر اساس ویژگی‌های هواشناسی-فیزیکی

افق زمانی	مدل	میانگین قدر مطلق خطا ($^{\circ}\text{C}$)	ریشه میانگین مربعات خطا ($^{\circ}\text{C}$)	دقت	فراخوانی	F1	CSI
شش ساعته	پایه	$2/79$	$3/77$	$0/883$	$0/884$	$0/883$	$0/791$
	ریج	$2/15$	$3/04$	$0/906$	$0/898$	$0/902$	$0/822$
	رگرسیون بردار پشتیبان	$2/19$	$3/10$	$0/919$	$0/904$	$0/911$	$0/837$
	نزدیک‌ترین همسایه	$2/50$	$3/47$	$0/909$	$0/899$	$0/904$	$0/825$
	جنگل تصادفی	1542	$3/07$	$0/907$	$0/899$	$0/903$	$0/824$
	درختان فوق تصادفی	$2/18$	$3/08$	$0/911$	$0/902$	$0/906$	$0/829$
	رگرسیون تقویت گرادیانی	$2/14$	$3/04$	$0/912$	$0/902$	$0/907$	$0/830$
	XGBoost	$2/14$	$3/03$	$0/916$	$0/902$	$0/909$	$0/833$
	پایه	$3/67$	$2/82$	$0/829$	$0/833$	$0/831$	$0/711$
	ریج	$2/63$	$3/63$	$0/886$	$0/870$	$0/878$	$0/783$
دوازده ساعته	رگرسیون بردار پشتیبان	$2/71$	$3/78$	$0/880$	$0/860$	$0/870$	$0/770$
	نزدیک‌ترین همسایه	$2/93$	$4/01$	$0/861$	$0/843$	$0/852$	$0/742$
	جنگل تصادفی	$2/67$	$3/70$	$0/868$	$0/864$	$0/866$	$0/764$
	درختان فوق تصادفی	$2/67$	$3/69$	$0/875$	$0/863$	$0/869$	$0/768$
	رگرسیون تقویت گرادیانی	$2/66$	$3/67$	$0/873$	$0/872$	$0/872$	$0/773$
	XGBoost	$2/61$	$3/62$	$0/869$	$0/877$	$0/873$	$0/774$

اختلاف‌های عددی کوچک در ریشه میانگین مربعات خطا لزوماً نشان‌دهنده تفاوت واقعی در عملکرد پیش‌بینی نیستند، از این‌رو مدل‌ها با استفاده از آزمون‌های آماری زوجی مقایسه شدند. به منظور کنترل مقایسه‌های زوجی متعدد، اصلاح هولم روی مقادیر p حاصل اعمال و نتایج آن در جدول ۳، ارائه شده است. در افق شش ساعته، مدل XGBoost پس از اصلاح آماری، عملکرد بهتری نسبت به مدل نزدیک‌ترین همسایه، مدل پایه و رگرسیون تقویت گرادیانی داشت و این تفاوت‌ها از نظر آماری

معنادار بودند. با این حال، تفاوت آن با مدل‌های ريج، رگرسیون بردار پشتیبان، درختان فوق تصادفی و جنگل تصادفی از نظر آماری معنادار نبود. مدل XGBoost کمترین ریشه میانگین مربعات خطا را به دست آورد، اما شواهد آماری نشان نمی‌دهد که این مدل به‌طور قطعی از مدل‌های دیگر بهتر است. در افق دوازده‌ساعته نیز مدل ريج از نظر عددی، کمترین ریشه میانگین مربعات خطا را داشت، اما عملکرد آن با مدل‌های رگرسیون بردار پشتیبان، XGBoost، درختان فوق تصادفی، رگرسیون تقویت گرادیانی و جنگل تصادفی تفاوت معناداری نداشت.

جدول ۳. مقایسه مدل‌های یادگیری ماشین از نظر آماری

افق (ساعت)	مقایسه مدل‌ها	مقدار p تعدیل شده	تفسیر
۶	XGBoost - رگرسیون تقویت گرادیانی	کمتر از ۰/۰۰۱	تفاوت معنادار
	XGBoost - نزدیک‌ترین همسایه	کمتر از ۰/۰۰۱	تفاوت معنادار
	XGBoost - مدل پایه	کمتر از ۰/۰۰۱	تفاوت معنادار
	XGBoost - ريج	بیش از ۰/۰۵	غیرمعنادار
	XGBoost - رگرسیون بردار پشتیبان	بیش از ۰/۰۵	غیرمعنادار
	ريج - مدل پایه	کمتر از ۰/۰۰۱	تفاوت معنادار
۱۲	ريج - نزدیک‌ترین همسایه	کمتر از ۰/۰۰۱	تفاوت معنادار
	ريج - رگرسیون بردار پشتیبان	بیش از ۰/۰۵	غیرمعنادار
	ريج - XGBoost	بیش از ۰/۰۵	غیرمعنادار
	ريج - جنگل تصادفی	بیش از ۰/۰۵	غیرمعنادار

نتیجه‌گیری

در این پژوهش از داده‌های هواشناسی مربوط به سال‌های ۱۳۸۳ تا ۱۴۰۴ ایستگاه هواشناسی تهران برای پیش‌بینی دمای نقطه شب‌نم در دو افق زمانی ۶ و ۱۲ ساعت با به‌کارگیری مدل‌های یادگیری ماشین استفاده شد. نتایج این پژوهش نشان داد که پیش‌بینی دمای نقطه شب‌نم با استفاده از روش‌های یادگیری ماشین می‌تواند نسبت به مدل پایه (اتکا به مقدار مشاهده‌شده قبلی برای پیش‌بینی دمای آتی)، اطلاعات مؤثرتری برای برآورد دمای نقطه شب‌نم ساعت‌های آینده فراهم کند.

در هر دو افق زمانی ۶ و ۱۲ ساعت، عملکرد مدل‌های یادگیری ماشین از مدل پایه بهتر بود؛ با این حال، افزایش افق پیش‌بینی از ۶ به ۱۲ ساعت با افزایش عدم قطعیت و کاهش دقت همراه شد. این موضوع بیانگر آن است که محدودیت اصلی تنها به انتخاب الگوریتم مربوط نیست و ماهیت پیش‌بینی بلندتر شرایط جوّی نیز نقش مهمی در مقدار خطای مدل دارد.

از بین مدل‌های ارزیابی‌شده، مدل ريج در حالت استفاده از ویژگی‌های هواشناسی - زمانی عملکرد متعادل و پایداری نشان داد و در هر دو افق زمانی بهترین عملکرد کلی را به دست آورد. در مقابل، پس از افزودن ویژگی‌های فیزیکی، مدل XGBoost عملکرد بهتری در کاهش خطای پیش‌بینی دمای نقطه شب‌نم داشت. این تفاوت نشان می‌دهد که برتری یک الگوریتم را نمی‌توان مستقل از نوع متغیرهای ورودی و هدف نهایی پیش‌بینی تعیین کرد. به عبارت دیگر، مدلی که برای کمینه کردن خطای عددی مناسب‌تر است، الزاماً بهترین گزینه برای پیش‌بینی نیست.

افزودن فشار بخار واقعی، فشار بخار اشباع، کسری فشار بخار و اختلاف دمای هوا و دمای نقطه شب‌نم، در مجموع اثر مثبت اما محدودی بر عملکرد مدل‌ها داشت. محدود بودن این بهبود را می‌توان تا حدی به وابستگی فیزیکی این متغیرها به متغیرهای دما و رطوبت نسبت داد؛ از این رو این ویژگی‌ها بیشتر نقش تکمیل‌کننده و بازنمایی دقیق‌تر وضعیت رطوبتی جو را داشتند تا اینکه اطلاعات کاملاً جدیدی به مدل اضافه کنند.

از دیدگاه کاربردی، نتایج نشان می‌دهد که انتخاب مدل باید متناسب با هدف پیش‌بینی انجام گیرد. اگر هدف اصلی، برآورد دقیق‌تر مقدار دمای نقطه شب‌نم باشد، مدل XGBoost در اعمال ویژگی‌های هواشناسی - فیزیکی افزون‌بر ویژگی‌های هواشناسی - زمانی گزینه مناسبی است؛ با این حال، نتایج آزمون‌های آماری نشان داد که اختلاف بین برخی مدل‌های برتر از نظر

آماري معنادار نيست و بنا بر اين نمي توان تنها بر اساس اختلاف هاي كوچك در معيارهاي خطا، برتري قطعي يك مدل بر ديگر مدل هاي برتر را ادعا كرد.

در مجموع مي توان گفت كه پيش بيني دماي نقطه شبنم، در كنار استفاده از متغيرهاي هواشناسي و ويژگي هاي فزيكي مرتبط با وضعيت رطوبتي جو، مبناي مناسبى براى توسعه سامانه هاي پيش بيني و هشدار سرمازدگي تابشي است.

ملاحظات اخلاقي

نويسنده اصول اخلاقي را در اجرا و انتشار پژوهش رعايت کرده است.

مشاركت نويسندگان

همه مراحل داده برداري، تحليل داده ها و تاليف مقاله توسط نويسنده انجام گرفته است.

تعارض منافع

بنا بر اظهار نويسنده، اين مقاله تعارض منافع ندارد.

حامی مالی

اين مقاله حمايت مالي نداشته است.

منابع

- Abdolshah, M. (2024). Identification and assessment of environmental hazards using the COCOSO technique - Excavation case: East Semnan industrial town. *Environmental Hazards Management*, 11 (3), 175-192. DOI: <http://doi.org/10.22059/jhsci.2024.381982.840>
- Alizamir, M., Kim, S., Kisi, O., & Zounemat-Kermani, M. (2020). Deep echo state network: A novel machine learning approach to model dew point temperature using meteorological variables. *Hydrological Sciences Journal*, 65(7), 1173–1190. <https://doi.org/10.1080/02626667.2020.1735639>
- Bazgir, S., Mohammadi, H., Sharifi, L., & Soleimani, N. (2016). Analysis of frost and freezing hazards to horticultural crops in West Azerbaijan Province. *Environmental Hazards Management*, 3(4), 365–378. <https://doi.org/10.22059/jhsci.2016.62371>
- Bhakare, S., Matiu, M., Crespi, A., & Zardi, D. (2025). Spatial Downscaling of Daily Temperature Minima Using Machine Learning Methods and Application to Frost Forecasting in Two Alpine Valleys. *Atmosphere*, 16, 38. <https://doi.org/10.3390/atmos16010038>
- Bhatti, S., Jeranyama, P., Kennedy, C. D., Buda, A. R., Millar, D. J., Wiegman, A. R. H., & Zalapa, J. E. (2026). Forecasting spring frost events in agriculture using machine learning: A case study from southeastern Massachusetts, United States. *Smart Agricultural Technology*, 13, 101720. <https://doi.org/10.1016/j.atech.2025.101720>
- Cadenas, J. M., Garrido, M. C., Martínez-España, R., & Guillén-Navarro, M. A. (2020). Making decisions for frost prediction in agricultural crops in a soft computing framework. *Computers and Electronics in Agriculture*, 175, 105587. <https://doi.org/10.1016/j.compag.2020.105587>
- Diniz, E.S., Lorenzon, A.S., Castro, N.L.M., Marcatti, G.E., Santos, O.P., Júnir, J.C., Cavalcante, R.B.L., Fernandes-Filho, E.I., Amaral, C.H. (2021). Forecasting frost risk in forest plantations by the combination of spatial data and machine learning algorithms. *Agric. For. Meteorol.* 306, 108450. <https://doi.org/10.1016/j.agrformet.2021.108450>
- Hand, D. J., Christen, P., & Kirielle, N. (2021). F*: an interpretable transformation of the F-measure. *Machine Learning*, 110(3), 451-456. <https://doi.org/10.1007/s10994-021-05964-1>
- Irmak, S., & Kukal, M. S. (2022). Temporal trends in agriculturally relevant climate indicators across nine agroecosystems of Turkey. *Journal of Applied Meteorology and Climatology*, 61(6), 631–649. <https://doi.org/10.1175/JAMC-D-21-0209.1>
- Omazić, B., Anić, M., Telišman Prtenjak, M., Kvakić, M., & Blašković, L. (2024). Analysis of different existing measurement-based methods and a new approach for frost probability detection. *Agricultural and Forest Meteorology*, 347, 109898. <https://doi.org/10.1016/j.agrformet.2024.109898>
- Rowlandson, T., Gleason, M., Sentelhas, P., Gillespie, T., Thomas, C., & Hornbuckle, B. (2015). *Reconsidering leaf wetness duration determination for plant disease management*. *Plant Disease*, 99(3). <https://doi.org/10.1094/PDIS-05-14-0529-FE> Rozante, J. R.,
- Song, H., Hu, Y., Lu, Y., Wang, J., Pan, Q., & Li, P. A. (2021). Review of Methods and Techniques for Detecting Frost on Plant Surfaces. *Agriculture*, 11, 1142. <https://doi.org/10.3390/agriculture11111142>
- Talsma, C.J., Solander, K.C., Mudunuru, M.K., Crawford, B., & Powell, M.R. (2023) Frost prediction using machine learning and deep neural network models. *Front. Artif. Intell.* 5:963781. doi: 10.3389/frai.2022.963781
- Tarraga, J. P., Castillo-Cara, M., Arias-Antúnez, E., & Dujovne, D. (2025). Frost forecasting through machine learning algorithms. *Earth Science Informatics*, 18, 183. <https://doi.org/10.1007/s12145-025-01710-6>
- Torres-Cruz, F., Yana-Yucra, D. M., & Vilca-Solorzano, R. A. (2025). Comparative analysis of statistical, machine learning, and deep learning approaches for frost prediction in the Peruvian Altiplano. *International Journal of Advanced Computer Science and Applications*, 16(9).
- Xu, J., Guga, S., Rong, G., Riao, D., Liu, X., Li, K., Zhang, J., 2021. Estimation of frost hazard for tea tree in zhejiang province based on machine learning. *Agriculture* 11, 607. <https://doi.org/10.3390/agriculture11070607>.
- Yang, C., & Song, H. (2026). Short-term frost prediction during apple flowering in Luochuan using a 1D-CNN–BiLSTM network with attention mechanism. *Horticulturae*, 12(1), 47. <https://doi.org/10.3390/horticulturae12010047>
- Zhang, Z., Li, P., & Wang, J. (2026). An Interpretable Machine Learning Framework for Next-Day Frost Forecasting in Tea Plantations Using Multi-Source Meteorological Data. *Horticulturae*, 12(3), 392. <https://doi.org/10.3390/horticulturae12030392>
- Zhang, G., Bateni, S. M., Jun, C., Khoshkam, H., Band, S. S., & Mosavi, A. (2022). Feasibility of random forest and multivariate adaptive regression splines for predicting long-term mean monthly dew point temperature. *Frontiers in Environmental Science*, 10, 826165. <https://doi.org/10.3389/fenvs.2022.826165>