



## Research Article

# Prediction of Dew Point Temperature Using Tree and Kernel Based Models

A Hamidzadeh<sup>1</sup>, S Samadianfard<sup>2\*</sup> 

Received: December 26, 2023

Accepted: September 10, 2023

Revised: July 21, 2023

Published online: September 22, 2024

1-M.Sc. Student, Water Engineering and Management Department, Faculty of Agriculture, Tarbiat Modares University, Tehran, Iran

2-Assoc. Prof., Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

\* Corresponding Author, Email: s.samadian@tabrizu.ac.ir

## Abstract

### Background and Objectives

Iran's agricultural sector faces unique obstacles due to the diversity of its climatic conditions, underscoring the crucial importance of safeguarding crops against the impacts of climate change. One effective strategy to mitigate damage to the agricultural industry is the ability to accurately predict dew point temperature. The dew point refers to the temperature at which water vapor in the air condenses into liquid water or dew, given a constant air pressure. Notably, an excessively high dew point can adversely affect the performance of air conditioning systems and reduce the efficiency of coolant-based ventilation mechanisms. The formation of dew in ecosystems is influenced by a triad of key factors: radiative exchange between the Earth's surface and the atmosphere, turbulent heat transfer, and vapor pressure. While the dew point is typically measured using a moisture meter, there also exist empirical equations that relate air temperature and humidity. However, reliable dew point forecasting often requires common meteorological parameters, such as relative humidity and precipitation, which are not consistently measured at many weather stations or may be subject to significant error. As such, regression-based estimation methods are frequently employed. Recognizing the importance of data-driven approaches in dew point estimation, this study explores the use of several predictive models, including support vector regression (SVR), the M5P tree model, the M5Rules rule-generation algorithm, Gaussian process regression (GPR), linear regression (LR), random forest (RF), and random tree (RT) models. These models were applied to data collected from two stations in Gorgan and Shahrekord, Iran, to estimate dew point temperature.

### Methodology

The Gorgan basin is geographically situated between 25°54' east longitude and 36°50' north latitude, while the Shahrekord basin is located between 50°49' east longitude and 32°20' north latitude. Topographically, Shahrekord lies in the eastern segment of the Zagros Mountain range, along the Zagros fault margin. The input parameters for this study were obtained from the Iran Meteorological Organization, covering the period from 1990 to 2021. These parameters include daily maximum temperature ( $T_{max}$ ), daily minimum temperature ( $T_{min}$ ), daily average temperature ( $T_m$ ), sunshine hours (sshn), average wind speed (ffm), average relative humidity ( $RH_m$ ), maximum relative humidity ( $RH_{max}$ ), and minimum relative humidity ( $RH_{min}$ ). To assess the accuracy of the input parameters and models, the dew point (DP) was extracted from the testing data and evaluated using regression and tree-based models. Additionally, eight potential scenarios were defined to estimate the daily DP.

### Findings

The study findings revealed that scenarios 1, 2, and 3 exhibited the highest correlation with dew point temperature, while scenarios 4, 5, 6, 7, and 8 displayed the lowest correlation. However, upon evaluating the scenarios based on the established criteria, it was determined that scenarios 1, 2, and 3 performed less effectively than the other scenarios. Consequently, the placement of the majority of parameters (scenarios 6,



7, and 8) led to a decrease in the models' errors. The results obtained for the Gorgan models showed that the R-value ranged from 1 to 0.952. In the Gorgan station, the highest RMSE was observed for RT-3 at 2.0307, and the lowest RMSE was for SVR-8 at 0.222. Furthermore, the best fit for SVR-8 was characterized by RMSE: 0.222, NSE: 0.999, MBE: 0.092, MAE: 0.147, WI: 1, and SI: 0.017, while the worst fit was for RT-3 with RMSE: 2.307, NSE: 0.882, MBE: 0.875, MAE: 1.745, WI: 0.971, and SI: 0.179. The results for the Shahrekord models indicated that the R-value ranged between 0.996 and 0.615. In the Shahrekord station, the highest RMSE was observed for RT-2 at 4.952, and the lowest RMSE was for SVR-7 at 0.550. Additionally, the best fit for SVR-7 was characterized by RMSE: 0.550, NSE: 0.989, MBE: 0.374, MAE: 0.346, WI: 0.997, and SI: -0.15, while the worst fit was for RT-2 with RMSE: 4.957, NSE: 0.131, MBE: 1.43, MAE: 3.914, WI: 0.754, and SI: -1.352.

### **Conclusion**

In this study, meteorological data were fitted using various modeling techniques, including Gaussian Process Regression (GPR), Linear Regression (LR), M5P, M5Rules, Random Forest (RF), Regression Tree (RT), and Support Vector Regression (SVR), to obtain the dew point temperature at the Gorgan and Shahrekord weather stations. The performance of these models was then evaluated under different scenarios, and the best-performing models were selected for estimating the dew point temperature. The results indicate that the estimation accuracy of the models using a single input parameter, such as minimum temperature ( $T_{\min}$ ), was lower compared to the other models in both the Shahrekord and Gorgan stations. The SVR model with scenario 8 and the M5P model with scenario 7 demonstrated the best performance in estimating the dew point temperature for the Gorgan and Shahrekord stations, respectively. Furthermore, the comparison of the selected models revealed that the SVR model had the highest accuracy among the models evaluated. For the Gorgan station, the models were ranked from high to low accuracy as follows: SVR, M5P, M5Rules, GPR, RF, and LR. For the Shahrekord station, the ranking was M5P, M5Rules, GPR, RF, RT, and LR. Additionally, the comparison of the tree-based and regression-based models showed that the regression models, such as SVR and LR, had higher accuracy in estimating the dew point temperature compared to the tree-based models, such as M5P, M5Rules, and RT.

**Keywords:** Dew point temperature, Gorgan, Regression models, Shahrekord, Tree models.



## مقاله پژوهشی

### پیش‌بینی دمای نقطه شبنم با استفاده از مدل‌های مبتنی بر درخت و هسته

علی حمیدزاده<sup>۱</sup>، سعید صمدیان فرد<sup>۲\*</sup>

تاریخ پذیرش: ۱۴۰۲/۰۶/۱۹

تاریخ دریافت: ۱۴۰۲/۱۰/۰۵

تاریخ انتشار آنلاین: ۱۴۰۳/۱۰/۰۱

تاریخ ویرایش: ۱۴۰۲/۰۴/۳۰

۱- دانشجوی کارشناسی ارشد، گروه مهندسی و مدیریت آب، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران، ایران

۲- دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

\* مسئول مکاتبات، پست الکترونیکی: [s.samadian@tabrizu.ac.ir](mailto:s.samadian@tabrizu.ac.ir)

#### چکیده

دمای نقطه شبنم یکی از کاربردی‌ترین پارامترهای هواشناسی است که در علم مکانیک (بخش تهویه و مطبوع) و کشاورزی بسیار مورد استفاده قرار می‌گیرد. در این پژوهش، توانمندی مدل‌های رگرسیون بردار پشتیبان، مدل درختی، مدل تولید قوانین از مدل درختی، مدل فرآیند گاوسی، مدل رگرسیون خطی، مدل جنگل تصادفی و مدل درخت تصادفی در تخمین دمای نقطه شبنم مورد ارزیابی قرار گرفته است. داده‌های هواشناسی روزانه دو ایستگاه گرگان و شهرکرد، برای بازه زمانی سال‌های ۱۹۹۰ تا ۲۰۲۱ استفاده شده است. همچنین، پارامترهای هواشناسی دمای میانگین، دمای حداکثر، دمای حداقل، میانگین سرعت باد، ساعات آفتابی، میانگین رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی نسبت به هم ارزیابی و ۸ سناریوی مختلف به عنوان پارامتر ورودی برای هر مدل در نظر گرفته شد. نتایج نشان داد که مدل رگرسیون بردار پشتیبان، برای سناریوی ۸، با جذر میانگین مربعات خطا ۰/۲۲۲، معیار انحراف خطا ۰/۰۹۲، میانگین خطای مطلق ۰/۱۴۷، شاخص توافق ویلموت ۱ در ایستگاه گرگان و مدل رگرسیون بردار پشتیبان برای سناریوی ۷، با جذر میانگین مربعات خطا ۰/۰۵۵، معیار انحراف خطا ۰/۲۸۵، میانگین خطای مطلق ۰/۳۴۶، شاخص توافق ویلموت ۰/۹۹۷ در ایستگاه شهرکرد، به عنوان مدل‌های برتر برای تخمین دمای نقطه شبنم روزانه هستند. در نهایت، روش رگرسیون بردار پشتیبان، به عنوان روشی توانمند در پیش‌بینی دمای نقطه شبنم برای استفاده در مقاصد کشاورزی معرفی گردید.

واژه‌های کلیدی: دمای نقطه شبنم، شهرکرد، مدل‌های درختی، گرگان، مدل‌های رگرسیونی.

## مقدمه

RF را با استفاده از داده‌های شش ایستگاه هواشناسی آذربایجان شرقی مورد ارزیابی قرار داد. ایشان چنین بیان نمودند که مدل GEP با اختلاف نسبت به مدل RF دقت بالایی در تخمین پارامتر نقطه شبنم داشته است. قاسم و همکاران (۲۰۱۹) در پژوهش خود با هدف مدل‌سازی و تخمین دمای نقطه شبنم، داده‌های هواشناسی بیست سال ایستگاه تبریز را با مدل‌های GEP، مدل درخت M5 و مدل رگرسیون بردار پشتیبان<sup>۱</sup> SVR مورد بررسی قرار دادند. طی تحقیقات انجام شده، مدل M5 نسبت به مدل‌های دیگر دقت تخمین بهتری داشت. محمدی و همکاران (۲۰۱۹) برای پیش‌بینی دمای نقطه شبنم، داده‌های هواشناسی روزانه دو ایستگاه در بخش مرکزی و جنوب مرکزی ایران را با استفاده از سیستم عصبی فازی ANFIS مورد آزمون قرار دادند. نتایج به دست آمده، نشان دهنده دقت بالای مدل برای پیش‌بینی دمای نقطه شبنم بود. کیسی و همکاران (۲۰۱۳) داده‌های هشت سال ایستگاه‌های Daego, Pohang, Ulsan کره جنوبی را تخمین دمای نقطه شبنم بررسی کردند. نتایج مقایسه مدل‌ها نشان داد که مدل‌های مختلف شبکه عصبی مصنوعی ANFIS-GP, ANFIS-SC و شبکه‌های عصبی رگرسیون تعمیم یافته GRNNM، دقت بالا و عملکرد بهتری نسبت به مدل شبکه‌های خودسازماندهی کوهونن KSOFM را داشتند. دانگ و همکاران (۲۰۲۰) برای تخمین دمای نقطه شبنم در ایستگاهی در چین ده مدل یادگیری ماشین ANN, ANFIS, RF, SVM, ELM, MARS, Bat- ماشین ELM, GA-ELM, PSO-ELM, KNEA را با استفاده از شش ترکیب ورودی مختلف داده‌ها بررسی نمودند. نتایج نشان داد مدل Bat-ELM دقت بیشتری داشته و مدل بهینه‌ای است. دکا و همکاران (۲۰۱۸) برای تخمین دمای نقطه شبنم روزانه در مناطق مرطوب و نیمه خشک هند،

کشاورزی در ایران به دلیل تنوع شرایط اقلیمی با مشکلات خاصی رو به رو است. به همین دلیل، حفاظت از گیاهان در برابر تغییرات آب و هوایی بسیار حائز اهمیت است. یکی از راه‌های جلوگیری از صدمات وارده به بخش کشاورزی، پیش‌بینی دمای نقطه شبنم است. دمای نقطه شبنم دمایی است که در آن بخار آب، با فرض ثابت ماندن فشار هوا، به آب مایع یا شبنم متراکم می‌شود. دمای نقطه شبنم در حد بسیار بالا می‌تواند بر استفاده از تهویه مطبوع تاثیرگذار باشد و همچنین کارایی تهویه‌ها را که از خنک کننده‌ها بهره می‌برند کاهش دهد (شانک و همکاران ۲۰۰۸). عوامل موثر در شکل‌گیری پدیده شبنم در اکوسیستم را می‌توان تبادل تابش بین سطح زمین و جو، گرمای متلاطم و فشار بخار نام برد (شیری و همکاران ۲۰۱۸). مقدار نقطه شبنم معمولاً با رطوبت سنج اندازه‌گیری می‌شود، اگرچه معادلات تجربی برای ارتباط میان دمای هوا و رطوبت هوا با نقطه شبنم وجود دارد (شیری ۲۰۱۹). پیش‌بینی نقطه شبنم، نیازمند پارامترهای متداول هواشناسی مانند رطوبت نسبی و بارندگی است که در اکثر ایستگاه‌های هواشناسی اندازه‌گیری نمی‌شوند و یا دارای خطای زیادی هستند و با استفاده از روش‌های رگرسیونی تخمین زده می‌شوند (دانگ و همکاران ۲۰۲۰).

در سال‌های اخیر، بیشتر مدل‌های داده محور مانند مدل‌های درختی جهت تحلیل و بررسی متغیرها و مسائل هیدرولوژیکی مورد استفاده قرار گرفته‌اند. مطالعات زیادی در این زمینه صورت گرفته است. لاورنس (۲۰۰۵) یک رابطه ریاضی بین دمای نقطه شبنم و رطوبت نسبی با استفاده از معادلات تجربی به دست آورد. شیری (۲۰۱۹) برای تخمین و پیش‌بینی دمای نقطه شبنم، توانایی دو مدل برنامه‌ریزی ژنتیک GEP و مدل جنگل تصادفی

<sup>1</sup> Support Vector Regression

عصبی چند لایه MLPNN و مدل MARS به بررسی و پیش‌بینی دمای نقطه شب‌نم در دو ایستگاه Durham و Riverside ایالات متحده پرداختند. طبق نتایج به دست آمده از شاخص‌های آماری و مقایسه آنها در هر مدل، عملکرد مدل KELM برای تخمین دمای نقطه شب‌نم نسبت به مدل‌های ذکر شده بهتر بود. ناگانا و همکاران (۲۰۱۹) دمای نقطه شب‌نم را با ترکیب مدل شبکه عصبی چند لایه MLP با الگوریتم‌های بهینه‌سازی جستجوی گرانشی GSA و کرم شب‌تاب FFA مورد ارزیابی قرار دادند. در آن تحقیق، دو منطقه با آب و هوای مرطوب و نیمه خشک با مدل‌های MLP-GSA و MLP-FFA ارزیابی شدند. نتایج نشان داد که دقت تخمین دمای نقطه شب‌نم با مدل‌های ترکیبی بسیار افزایش پیدا کرده است. کرمانی و همکاران (۲۰۱۲) در مطالعات خود دو مدل رگرسیون چندخطی MLR و مدل ANN با الگوریتم لوبنبرگ-مارکوارت LM را در تخمین دمای نقطه شب‌نم مورد مطالعه قرار دادند. نتایج تحقیق نشان داد که مدل ANN عملکرد بهتری برای پیش‌بینی دمای نقطه شب‌نم با پارامترهای ورودی دارد. مجاهدی و همکاران (۲۰۱۶) در زمینه پیش‌بینی دمای نقطه شب‌نم با مدل ماشین یادگیری شدید ELM و الگوریتم موجک WL تحقیق کردند. طبق نتایج برآورد شده مدل ترکیبی ELM-WL دقت بالایی در تخمین دمای نقطه شب‌نم روزانه داشت. اصولی و همکاران (۲۰۲۲) برای تخمین دمای نقطه شب‌نم روزانه در دو ایستگاه اردبیل و پارس‌آباد، مدل‌های RF، مدل درختی M5P، مدل گرادیان تقویتی GBT و جنگل تصادفی تقویت شده با الگوریتم ژنتیک RF-GA را مورد آزمون و ارزیابی قرار دادند. آنها اظهار داشتند که مدل M5P نسبت به مدل‌های مذکور دقیق‌تر عمل کرده است.

با توجه به تحقیقات صورت گرفته در زمینه تخمین نقطه شب‌نم، می‌توان به اهمیت روش‌های داده محور در

از دو مدل ماشین بردار پشتیبان SVM و ماشین یادگیری شدید ELM استفاده کردند. نتایج تحقیقات، حاکی از آن است که مدل ELM از توانایی بیشتری نسبت به مدل SVM برخوردار است. دانگ و همکاران (۲۰۲۲) برای تخمین نقطه شب‌نم در منطقه‌ای از چین، از داده‌های هواشناسی استفاده کردند. سپس، مدل‌های تقویت گرادیان شدید هیبریدی با الگوریتم بهینه‌سازی ملخ GOA-XGBoost را با الگوریتم تقویتی XGBoost و مدل RF مقایسه کردند. نتایج نشان داد که مدل XGBoost بهترین عملکرد را داشته و مدل RF در مرحله اعتبارسنجی در مقیاس زمانی روزانه، مشکلات شدید برآش دارد. در تحقیق دیگر، مهدی زاده و همکاران (۲۰۱۷) با تحقیق بر روی داده‌های هواشناسی پانزده سال تبریز و اورمیه با استفاده از مدل GEP برای تخمین دمای نقطه شب‌نم، به نتایجی دست یافتند که نشان می‌داد در بین تمام پارامترهای ورودی، فشار بخار واقعی ( $e_a$ ) و حداقل دمای هوا ( $T_{min}$ ) تاثیر زیادی در تخمین دمای نقطه شب‌نم داشته است. فتح الله زاده عطار و همکاران (۲۰۱۸) با بررسی داده‌های هواشناسی مناطق خشک ایران برای برآورد نقطه شب‌نم، از سیزده ایستگاه برای دوره زمانی ۵۵ ساله استفاده کردند. در آن پژوهش، سه مدل SVM، GEP و خطوط رگرسیون تطبیقی چند متغیره MARS به کار گرفته شد که نتایج به دست آمده حاکی از دقت بالای مدل MARS در تخمین دمای نقطه شب‌نم بود. محمدی و همکاران (۲۰۱۵) در بررسی دمای نقطه شب‌نم برای ایستگاه‌های بندعباس و طبس از مدل ELM استفاده کردند. نتایج نشان داد، داده‌های مدل ELM در برآورد نقطه شب‌نم بسیار دقیق بودند و همچنین مدل مذکور می‌تواند جایگزین خوبی برای مدل‌های SVM و ANN باشد. الیازمیر و همکاران (۲۰۲۰) با استفاده از مدل‌های ماشین یادگیری شدید هسته KELM، درخت رگرسیون تقویت شده BRT، شبکه عصبی شعاعی RBFNN، شبکه

اهمیت پیدا می‌کند. در این تحقیق، ابتدا با استفاده از روش‌های درختی و رگرسیونی، مقادیر دمای نقطه شبنم روزانه پیش‌بینی شد. سپس با معیارهای ارزیابی مختلف دقت مدل‌ها بررسی گردید. هدف از بکارگیری مدل‌های درختی با مدل‌های رگرسیونی، استفاده از مدلی با قابلیت اطمینان بالا است تا بتوان با استفاده از دقیق‌ترین مدل، دمای نقطه شبنم متناسب با اقلیم هر منطقه را توسط پارامترهای هواشناسی پیش‌بینی کرد.

تصادفی از میان ایستگاه‌های مختلف برای دو اقلیم متفاوت برگزیده شده‌اند تا مدل‌ها توسط پارامترهای یکسان و سناریوهای متفاوت باهم مقایسه شوند. مشخصات جغرافیایی ایستگاه‌های مورد مطالعه در جدول ۱ قابل مشاهده است.

جدول ۱- مشخصات جغرافیایی ایستگاه‌ها.

ایستگاه	عرض	طول	ارتفاع از سطح دریا (متر)	اقلیم
گرگان	۳۶/۸۴°	۲۶/۵۴°	۱۵۵	آب و هوای معتدل با تابستان نسبتاً گرم و مرطوب
شهرکرد	۳۲/۲۹°	۵۰/۴۸°	۲۰۶۰	معتدل نیمه مرطوب با تابستان‌های ملایم و زمستان‌های بسیار سرد

بختیاری و با مساحت ۲۰۰۶ کیلومترمربع بالغ بر ۱۲٪ از کل مساحت استان چهارمحال بختیاری را به خود اختصاص داده است. از لحاظ توپوگرافی شهرستان شهرکرد در بخش شرقی کوه‌های زاگرس و در حاشیه گسل زاگرس قرار دارد. مهم‌ترین ارتفاعات آن کوه جهان‌بین است. در شکل ۱، موقعیت جغرافیایی دو ایستگاه مورد مطالعه مشخص شده‌اند.

این زمینه پی برد. لذا در این پژوهش، توانایی مدل‌های رگرسیون بردار پشتیبان SVR، مدل درختی M5P، مدل تولید قوانین از مدل درختی M5Rules، مدل فرآیند گاوسی<sup>۱</sup> (GPR)، مدل رگرسیون خطی<sup>۲</sup> (LR)، مدل جنگل تصادفی<sup>۳</sup> (RF) و مدل درخت تصادفی<sup>۴</sup> (RT) در تخمین دمای نقطه شبنم در دو ایستگاه گرگان و شهرکرد در بازه زمانی بلند مدت ۳۰ ساله مورد ارزیابی قرار گرفته است. با توجه به دقت مدل‌های درختی و رگرسیونی در مطالعات پیشین، استفاده از مدلی با دقت و عملکرد بالا

### مواد و روش‌ها

#### منطقه مورد مطالعه

در این تحقیق از داده‌های هواشناسی اخذ شده از سازمان هواشناسی ایران برای دو ایستگاه گرگان و شهرکرد استفاده شده است. این دو ایستگاه به صورت

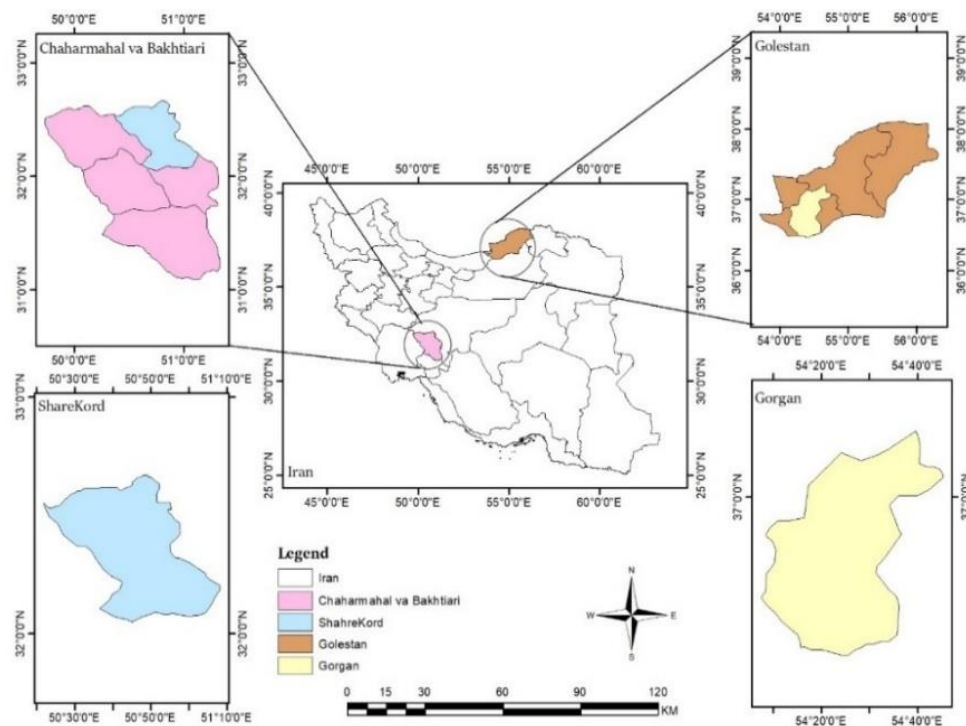
شهرستان گرگان با قرار گرفتن در مرکز استان گلستان با مساحت ۱۷۰۰ کیلومترمربع حدوداً ۸/۴ درصد از کل مساحت استان را به خود اختصاص می‌دهد. شهرستان گرگان از لحاظ توپوگرافی در شمال رشته کوه‌های البرز و از جنوب شرقی با دریای خزر همسایگی دارد. به همین دلیل، از لحاظ نزولات جوی در وضعیت خوبی قرار دارد. همچنین، شهرستان شهرکرد در مرکز استان چهارمحال

<sup>3</sup> Random Forest

<sup>4</sup> Random Trees

<sup>1</sup> Gaussian Process Regression

<sup>2</sup> Linear Regression



شکل ۱- موقعیت جغرافیایی ایستگاه‌های مورد مطالعه.

در این پژوهش، داده‌های هواشناسی دو ایستگاه گرگان و شهرکرد برای یک دوره ۳۲ ساله (۱۹۹۰ تا ۲۰۲۱) از سازمان کل هواشناسی ایران گرفته شده است. لذا پارامترهای دمای میانگین ( $T_m$ )، دمای حداکثر ( $T_{max}$ )، دمای حداقل ( $T_{min}$ )، میانگین سرعت باد ( $ffm$ )، ساعات آفتابی ( $sshn$ )، میانگین رطوبت نسبی ( $RH_m$ )، حداکثر رطوبت نسبی ( $RH_{max}$ )، حداقل رطوبت نسبی ( $RH_{min}$ ) به عنوان پارامترهای ورودی برای سنجش و پیش‌بینی دمای نقطه شبیم (DP) استفاده شده‌اند. همچنین، مشخصات آماری پارامترهای مذکور برای دو مرحله اعتبارسنجی و صحت‌سنجی در جدول ۲ ارائه گردیده‌اند.

جدول ۲- مشخصات جغرافیایی ایستگاه‌ها.

ایستگاه	مجموعه داده ها	داده های ورودی و خروجی	واحد	میانگین	حداقل	حداکثر	انحراف استاندارد
گرگان	داده های آموزش	دمای میانگین	°C	۱۷/۵۹	-۴/۹	۳۴/۶	۸/۰۴
		دمای حداکثر	°C	۲۳/۴۲	-۰/۴	۴۵	۸/۷۵
		دمای حداقل	°C	۱۲/۷۶	-۱۱/۸	۲۹/۲	۸/۰۶
		ساعات آفتابی	h	۶/۲۸	۰	۱۳/۹	۴/۱۳
		سرعت باد	m/s	۱/۶۶	۰	۱۱/۷۵	۱/۳۷
	داده های ارزیابی	میانگین رطوبت نسبی	%	۷۳/۳۵	۲۴/۳۸	۹۹/۳۸	۱۰/۵
		حداکثر رطوبت نسبی	%	۸۸/۵۱	۴۶	۱۰۰	۷/۲۴
		حداقل رطوبت نسبی	%	۵۲/۷۵	۲	۹۸	۱۶
		دمای نقطه شبیم	°C	۱۲/۲۳	-۷/۱۹	۲۵/۱۳	۶/۸۳
		دمای میانگین	°C	۱۷/۹۶	-۴/۷	۳۳/۹	۸/۴۴
گرگان	داده های ارزیابی	دمای حداکثر	°C	۲۴/۵۸	-۲/۸	۴۶/۹	۹/۳۶
		دمای حداقل	°C	۱۲/۵۶	-۷/۴	۲۸/۶	۸/۳۵
		ساعات آفتابی	h	۶/۵۶	۰	۱۳/۳	۴/۱۸
		سرعت باد	m/s	۲/۶	۰	۱۳/۲۵	۱/۳۹
		میانگین رطوبت نسبی	%	۷۵/۶۵	۳۳/۶۳	۹۸/۵	۱۰/۴۶
		حداکثر رطوبت نسبی	%	۹۲/۰۲	۶۲	۱۰۰	۵/۹۳

حد اقل رطوبت نسبی	%	۵۳/۱	۷	۹۷	۱۷/۰۴
دمای نقطه شبنم	°C	۱۲/۸۹	-۷/۳۴	۲۶/۳۴	۶/۷۱
دمای میانگین	°C	۱۱/۹۷	-۲۲/۱	۳۰/۷	۹/۳۵
دمای حداکثر	°C	۲۰/۵۳	-۱۰	۳۸/۸	۱۰/۱۷
دمای حداقل	°C	۲/۸۴	-۳۲/۴	۲۵	۷/۹۸
ساعات آفتابی	h	۸/۹۷	۰	۱۳/۳	۳/۱
سرعت باد	m/s	۱/۵۶	۰	۱۱/۶۳	۱/۴۴
میانگین رطوبت نسبی	%	۴۵/۳۲	۱۳/۸۸	۹۵/۷۵	۱۷/۳۴
حداکثر رطوبت نسبی	%	۶۸/۸۱	۲۶	۱۰۰	۱۷/۱
حد اقل رطوبت نسبی	%	۲۴/۸۷	۲	۹۳	۱۵/۷۷
دمای نقطه شبنم	°C	-۱/۷۵	-۲۴/۹	۱۱/۵۶	۵/۳۵
دمای میانگین	°C	۱۲/۳۲	-۱۸/۵	۲۹/۱	۸/۹۲
دمای حداکثر	°C	۲۱/۶۴	-۸	۳۹	۹/۷۲
دمای حداقل	°C	۲/۲۷	-۲۸	۲۱/۸	۷/۵
ساعات آفتابی	h	۸/۹۴	۰	۱۳/۳	۳
سرعت باد	m/s	۲/۶۷	۰	۹/۳۸	۱/۲۸
میانگین رطوبت نسبی	%	۴۱/۳۶	۹/۲۵	۹۶/۵	۱۹/۵۱
حداکثر رطوبت نسبی	%	۶۴/۳۹	۱۶	۱۰۰	۲۱/۴۳
حد اقل رطوبت نسبی	%	۲۱/۴۹	۱	۹۱	۱۶/۰۱
دمای نقطه شبنم	°C	-۳/۶۷	-۲۳/۵	۱۱/۱	۵/۳۲

داده های آموزش

شهرکرد

داده های ارزیابی

محاسبات صحت‌سنجی بر روی ۳۰٪ باقیمانده داده‌ها صورت گرفته است.

بر اساس پارامترهای هواشناسی هشت سناریوی مختلف برای تخمین دمای نقطه شبنم تعریف گردیده است (جدول ۳). سپس محاسبات واسنجی بر روی ۷۰٪ داده‌ها و

جدول ۳- سناریوهای مختلف برای پارامترهای ورودی در برآورد دمای نقطه شبنم.

گرگان		شهرکرد	
سناریو	پارامترهای ورودی	سناریو	پارامترهای ورودی
۱	Tmin	۱	Tmin
۲	Tmin, T	۲	Tmin, T
۳	Tmin, T, Tmax	۳	Tmin, T, Tmax
۴	Tmin, T, Tmax, RHmax	۴	Tmin, T, Tmax, RHmax
۵	Tmin, T, Tmax, RHmax, RH	۵	Tmin, T, Tmax, RHmax, RH
۶	Tmin, T, Tmax, RHmax, RH, ffm	۶	Tmin, T, Tmax, RHmax, RH, ffm
۷	Tmin, T, Tmax, RHmax, RH, ffm, sshn	۷	Tmin, T, Tmax, RHmax, RH, ffm, Rhmin
۸	Tmin, T, Tmax, RHmax, RH, ffm, sshn, RHmin	۸	Tmin, T, Tmax, RHmax, RH, ffm, RHmin, sshn

بین متغیرهای ورودی و متغیر هدف را با ابر صفحه منتقل کند (قاسم و همکاران ۲۰۱۹). این عملکرد مدل را به ابزاری قدرتمند برای کارهای رگرسیونی که ممکن است بین متغیرهای ورودی و متغیر هدف وجود داشته باشد، تبدیل می‌کند. با فرض اینکه معادله ابرصفحه به صورت زیر باشد، داریم:

مدل رگرسیون بردار پشتیبان (SVR)

رگرسیون بردار پشتیبان نوعی الگوریتم یادگیری ماشینی است که هدف آن ساختن رابطه‌ای است برای ارتباط متغیرهای ورودی با حداقل رساندن خطا. مدل SVR در تلاش برای ایجاد ابر صفحه‌ای است که در آن نقاط داده را در فضای پیوسته در اختیار داشته باشد (شکل ۲). همچنین مدل SVR قادر است روابط غیرخطی



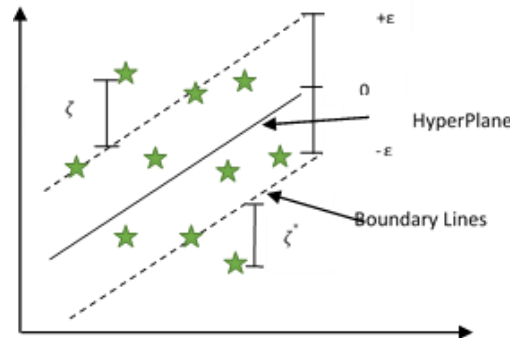
$$\text{Minimize: } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad [۱]$$

$$y_i - wx_i - b \leq \varepsilon + \zeta_i$$

$$wx_i + b - y_i \leq \varepsilon + \zeta_i^*$$

$$\zeta_i^*, \zeta_i \geq 0$$

$$f(x) = wx + b$$



شکل ۲- عملکرد داده‌ها در مدل (SVR).

انحراف استاندارد (SDR) به صورت روابط ۲ و ۳ می‌باشد:

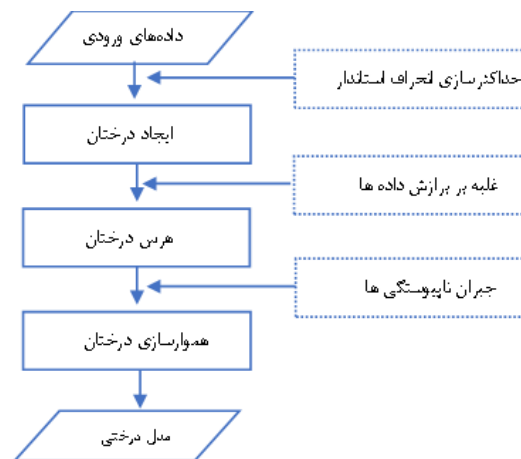
$$\begin{aligned} \text{SDR} \\ &= \text{sd}(T) \\ &= \sum \frac{|T_i|}{T} \text{sd}(T_i) \end{aligned} \quad [۲]$$

$$\begin{aligned} \text{sd}(T) \\ &= \sqrt{\sum_{i=1}^n \frac{(T_i - \bar{T})^2}{n-1}} \end{aligned} \quad [۳]$$

که در آن، sd انحراف معیار، T مجموعه‌ای از داده‌های وارد شده به گره،  $T_i$  زیرمجموعه‌ای از داده‌ها و n تعداد نمونه‌ها می‌باشند (قاسم و همکاران ۲۰۱۹).

#### مدل درختی (M5P)

مدل درختی M5P بازسازی شده الگوریتم M5 کوئینلان بوده و برای القای درختان مدل رگرسیونی است. این مدل به جای حداکثر رساندن اطلاعات در یک گره از معیار تقسیم استفاده می‌کند. همچنین گره‌ها را با توابع رگرسیونی خطی ترکیب و طبقه بندی می‌کند. در مرحله اول ابتدا، الگوریتم استنباطی درخت تصمیم برای ساختن درخت استفاده می‌شود. سپس هنگام هرس هر گره داخلی به یک برگ با صفحه رگرسیونی تبدیل می‌شود. در نتیجه، برای جلوگیری از ناپیوستگی در درخت القایی از یک روش هموارسازی در مسیر برگ و ریشه درخت استفاده می‌شود (شکل ۳). الگوریتم استنباطی برای مدل M5P از عملکرد انحراف استاندارد هر طبقه به دست می‌آید و بیانگر میزان خطای مدل می‌باشد (اصولی و همکاران ۲۰۲۲). فرمول محاسبه



شکل ۳- فلوجارت مدل درختی M5P (ژان و همکاران ۲۰۱۲).

ناپارامتریک و احتمال مشترک و شرطی وجود دارد. فرآیندهای گاوسی GPR توانایی انجام پیش‌بینی‌هایی از روی هسته‌های قبلی را دارند. مدل فرآیند گاوسی به دلیل انعطاف پذیری و معیارهای عدم قطعیت ذاتی در مورد پیش‌بینی‌ها به طور گسترده در الگوریتم‌های یادگیری ماشینی استفاده می‌شوند.

#### مدل رگرسیون خطی (LR)

یکی از روش‌های تحلیل رگرسیون، رگرسیون خطی است. رگرسیون مدل آماری است که برای پیش‌بینی یک متغیر از روی یک یا چند متغیر انجام می‌گیرد. در رگرسیون خطی که نوعی تابع پیش‌بینی کننده خطی است که همواره متغیر وابسته از روی متغیرهای دیگر پیش‌بینی می‌شود و به صورت ترکیب خطی از متغیرهای مستقل برآورد می‌شود. فرآیند پیش‌بینی به گونه‌ای عمل می‌کند که ضرایب مدل رگرسیون با داده‌های برآورد شده همخوانی داشته باشد. از روش‌های متداول در پیش‌بینی، روش حداقل مربعات است که در آن مجموع مربع تفاضل پیش‌بینی‌ها و داده‌های وابسته کمینه می‌شود. رگرسیون خطی به‌طور گسترده‌ای در علوم زیستی، رفتاری، اجتماعی، دارایی، اقتصاد و محیط‌زیست مورد استفاده قرار می‌گیرد. همچنین رگرسیون خطی و

#### مدل تولید قوانین از الگوریتم درختی (M5Rules)

مدل تولید قوانین از الگوریتم درختی روشی است که در مرحله اول، درختان مدل به مجموعه داده‌های آموزشی اعمال و یک درخت هرس شده آموخته می‌شود. سپس بهترین برگ درخت به صورت قانون در می‌آید و درخت دور ریخته می‌شود و تمام نمونه‌ها تحت پوشش قانون از مجموعه حذف می‌شوند. این فرآیند برای نمونه‌های باقی مانده تا زمانی که تحت پوشش یک یا چند قانون قرار گیرند، اعمال می‌شود. این فرآیند همان استراتژی جداسازی و تسخیر برای یادگیری قوانین مدل M5Rules است. مدل مذکور به جای درخت‌های نیمه کاوش شده، درخت کامل می‌سازد. از آنجا که قانون هر درخت تولید شده کنار گذاشته می‌شود، برای هموارسازی قوانین از مدل‌های خطی استفاده می‌شود. در آخر، برای انتخاب بهترین نامزد از برگ درختان به عنوان قانون، برگی که بیشترین نمونه را پوشش می‌دهد، انتخاب می‌شود (هلمس و همکاران ۲۰۰۷).

#### رگرسیون فرایند گاوسی (GPR)


مدل رگرسیون خطی یک یادگیری ماشینی با نظارت احتمالی است که در کارهای رگرسیونی و طبقه‌بندی کاربرد دارد. برای درک مدل فرآیند رگرسیون گاوسی نیاز به دانش توزیع نرمال چند متغیره، هسته‌ها، مدل

درختان بیشتر باشد، جنگل در برابر عوامل دیگر مقاوم خواهد بود. به طور مشابه، الگوریتم جنگل تصادفی از این ساختار جنگل پیروی می‌کند (شکل ۴). هر چقدر تعداد درختان بیشتر باشد، الگوریتم با دقت به حل مسئله می‌پردازد (بریمن ۲۰۰۱).

مشتقات آن یکی از ابزارهای شناخته شده و پرکاربرد در یادگیری ماشین هستند (فیسچر ۲۰۱۵).

#### مدل جنگل تصادفی (RF)

الگوریتم جنگل تصادفی یک روش یادگیری ماشینی ترکیبی برای طبقه بندی و رگرسیون است. یک جنگل از تعداد زیادی درخت تشکیل شده است و هر چقدر تعداد

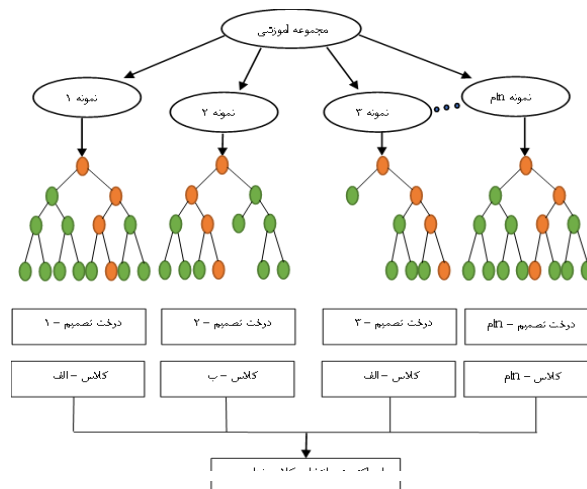


شکل ۴- فلوجارت مدل جنگل تصادفی (RF).

درخت تصمیم استفاده می‌کند (شکل ۵). در این الگوریتم طبقه بندی کننده، درختان تصادفی ویژگی ورودی را می‌گیرد و آن را با هر درخت طبقه بندی می‌کند (کالمق ۲۰۱۵).

#### مدل درخت تصادفی (RT)

الگوریتم درخت تصادفی یک الگوریتم طبقه بندی کننده با یادگیری گروهی است که تعداد زیادی از یادگیرنده‌ها را ایجاد می‌کند. الگوریتم RT از ایده طبقه بندی برای تولید مجموعه تصادفی از داده‌ها برای ساخت



شکل ۵- فلوجارت مدل درخت تصادفی (RT).

معیارهای ارزیابی مدل‌ها

[۸]

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

[۹]

$$SI = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}}{\bar{x}}$$

[۱۰]

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y_i - x_i)^2 \sum_{i=1}^n (y_i - x_i)^2}}$$

در روابط فوق،  $y_i$  مقدار برآورد شده دمای نقطه شب‌بنم،  $x_i$  مقدار دمای مشاهداتی در ایستگاه‌ها،  $\bar{y}$  میانگین مقادیر مشاهده‌ای و پیش‌بینی شده دمای نقطه شب‌بنم و  $n$  تعداد می‌باشند.

### نتایج و بحث

مقادیر ضریب همبستگی بین پارامترهای ورودی با دمای نقطه شب‌بنم روزانه در جدول ۴ برای هر دو ایستگاه مورد مطالعه آورده شده است.

جدول ۴- ضریب همبستگی بین دمای نقطه شب‌بنم با پارامترهای ورودی هواشناسی هر ایستگاه.

ایستگاه	میانگین	حداقل	حداکثر	ساعات	سرعت	میانگین	حداقل	حداکثر
	رطوبت نسبی	رطوبت نسبی	رطوبت نسبی	آفتابی	باد	دما	دما	دما
گرگان	-۰/۳۰۳	-۰/۱۶۸	-۰/۳۲۷	۰/۱۸۹	۰/۲۵	۰/۹۴۸	۰/۹۶۵	۰/۸۶
شهرکرد	-۰/۰۶۸	۰/۰۲۴	-۰/۰۷۲	-۰/۰۱۸	۰/۰۲۵	۰/۶۶۲	۰/۷۷۶	۰/۵۴۹

نمودار، بیشترین همبستگی دمای نقطه شب‌بنم با پارامتر حداقل دمای روزانه است که برابر ۰/۹۶۵۶۶ در ایستگاه گرگان و ۰/۷۷۶۸۰ در ایستگاه شهرکرد می‌باشند.

در این پژوهش، برای ارزیابی دقت نتایج مدل‌های پیشنهادی از شاخص‌های جذر میانگین مربعات خطا<sup>۱</sup> (RMSE)، معیار انحراف خطا<sup>۲</sup> (MBE)، میانگین خطای مطلق<sup>۳</sup> (MAE)، شاخص توافق ویلموت<sup>۴</sup> (WI)، راندمان نش-ساتکلیف<sup>۵</sup> (NSE)، شاخص پراکندگی<sup>۶</sup> (SI) و ضریب همبستگی<sup>۷</sup> (R) مطابق روابط زیر استفاده شده است.

[۴]

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}}$$

[۵]

$$MBE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)$$

[۶]

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n}$$

[۷]

$$WI = 1 - \left( \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (|y_i - \bar{y}| + |x_i - \bar{x}|)^2} \right)$$

در شکل ۶ رابطه همبستگی پارامترها با یکدیگر و با دمای نقطه شب‌بنم بر روی نقشه حرارتی ترسیم شده‌اند. طبق شکل ۶، پارامترها با همبستگی بیشتر به رنگ قرمز و با همبستگی کمتر به رنگ آبی نشان داده شده‌اند. در این

<sup>5</sup> Nash-Sutcliffe Efficiency

<sup>6</sup> Scatter Index

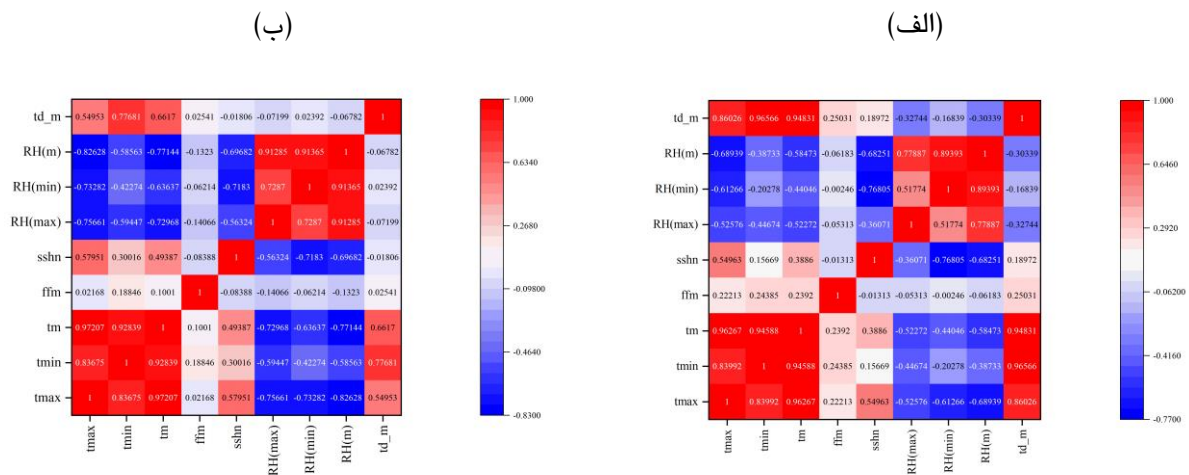
<sup>7</sup> Correlation Coefficient

<sup>1</sup> Root mean square error

<sup>2</sup> Mean Bias Error

<sup>3</sup> Mean Absolute Error

<sup>4</sup> Willmott's Index of agreement



شکل ۶- نمودارهای نقشه حرارت دمای نقطه شبیم در ایستگاه گرگان (الف) و شهرکرد (ب).

و نتایج حاصل در جدول‌های ۵ و ۶ ارائه گردیده است. با توجه به نتایج ارائه شده در جدول‌های مذکور، در ایستگاه گرگان، مدل‌های RT-5, RF-8, M5P-8, SVR-8, M5Rules, LR-6, GPR-5 و در ایستگاه شهرکرد مدل‌های GPR-7, LR-4, M5Rules, SVR-7, M5P-7, RF-8, RT-7 عنوان دقیق‌ترین مدل‌ها برگزیده شدند.

با توجه به ۸ سناریوی مختلف تشکیل شده از پارامترهای هواشناسی، برای برآورد دمای نقطه شبیم از مدل‌های مختلف M5P, SVR, M5Rules, GPR, RF, RT, LR استفاده شده است. برای تعیین دقت مدل‌های مذکور در مرحله صحت سنجی، پارامترهای آماری RMSE, NSE, MBE, WI, MAE, SI (مطابق روابط ۴، ۵، ۶، ۷، ۸، ۹، ۱۰) برای هر سناریو و در هر ایستگاه محاسبه شده

جدول ۵- نتایج عملکرد مدل‌ها در مرحله صحت سنجی (ایستگاه گرگان).

مدل‌ها	سناریو‌ها	R	RMSE	SI scatter	MAE	NSE	WI	MBE
GPR	۱	-/۹۶۵	۱/۹۸۴	-/۱۵۴	۱/۵۸۱	-/۹۱۳	-/۹۷۸	۰/۸۳۴
	۲	-/۹۷۷	۱/۶۴۹	-/۱۲۸	۱/۳۱۵	-/۹۴۰	-/۹۸۵	۰/۷۹۷
	۳	-/۹۷۸	۱/۶۶	-/۱۲۹	۱/۳۲۰	-/۹۳۹	-/۹۸۵	۰/۸۸۶
	۴	-/۹۸۷	۱/۰۸۶	-/۰۸۴	۰/۸۲۶	-/۹۷۴	-/۹۹۳	۰/۱۲۷
	۵	-/۹۹۹	۰/۳۳۲	۰۰۲۶	۰/۲۱۲	-/۹۹۸	-/۹۹۹	۰/۰۷۴
	۶	-/۹۹۹	۰/۳۶۲	-/۰۲۸	۰/۲۲۷	-/۹۹۷	-/۹۹۹	۰/۰۷۴
	۷	-/۹۹۸	۰/۴۱۲	-/۰۳۲	۰/۲۵۷	-/۹۹۶	-/۹۹۹	۰/۰۶۶
	۸	-/۹۹۸	۰/۳۹۷	-/۰۳۱	۰/۲۴۳	-/۹۹۶	-/۹۹۹	۰/۰۷۷
LR	۱	-/۹۶۵	۱/۹۸۳	-/۱۵۴	۱/۵۸۰	-/۹۱۳	-/۹۷۸	۰/۸۱۸
	۲	-/۹۷۵	۱/۶۹۱	-/۱۳۱	۱/۳۴۴	-/۹۳۷	-/۹۸۴	۰/۷۰۴
	۳	-/۹۷۶	۱/۶۸۶	-/۱۳۱	۱/۳۴۳	-/۹۳۷	-/۹۸۵	۰/۷۸۷
	۴	-/۹۸۶	۱/۱۶۵	-/۰۹۰	۰/۸۹۰	-/۹۷۰	-/۹۹۳	۰/۰۳۰
	۵	-/۹۹۸	۰/۴۸۷	-/۰۳۸	۰/۳۲۰	-/۹۹۵	-/۹۹۹	۰/۱۹۱
	۶	-/۹۹۸	۰/۴۸۱	-/۰۳۷	۰/۳۲۰	-/۹۹۵	-/۹۹۹	۰/۱۷
	۷	-/۹۹۸	۰/۴۸۲	-/۰۳۷	۰/۳۲۹	-/۹۹۵	-/۹۹۹	۰/۱۶۸
	۸	-/۹۹۸	۰/۴۸۲	-/۰۳۷	۰/۳۲۹	-/۹۹۵	-/۹۹۹	۰/۱۶۸
M5Rules	۱	-/۹۶۵	۱/۹۸۱	-/۱۵۴	۱/۵۷۳	-/۹۱۳	-/۹۷۸	۰/۸۳۲
	۲	-/۹۷۷	۱/۶۴۳	-/۱۲۸	۱/۳۰۶	-/۹۴۰	-/۹۸۵	۰/۷۶۸

۰/۸۷۰	۰/۹۸۵	۰/۹۳۹	۱/۳۲۰	۰/۱۲۸	۱/۶۵۶	۰/۹۷۸	۳	
۰/۰۶۹	۰/۹۹۴	۰/۹۷۵	۰/۸۰۸	۰/۰۸۳	۱/۰۷	۰/۹۸۸	۴	
۰/۱۰۲	۱/۰۰۰	۰/۹۹۸	۰/۱۸۱	۰/۰۲۱	۰/۲۶۷	۰/۹۹۹	۵	
۰/۱۰۳	۱/۰۰۰	۰/۹۹۸	۰/۱۸۵	۰/۰۲۱	۰/۲۷۱	۰/۹۹۹	۶	
۰/۱۱۲	۱/۰۰۰	۰/۹۹۸	۰/۱۹۱	۰/۰۲۳	۰/۲۹۵	۰/۹۹۹	۷	
۰/۱۱۱	۱/۰۰۰	۰/۹۹۹	۰/۱۶۹	۰/۰۲۰	۰/۲۵۶	۰/۹۹۹	۸	
۰/۵۸۳	۰/۹۸۷	۰/۹۱۲	۱/۵۸۳	۰/۱۵۵	۱/۹۹۵	۰/۹۶۶	۱	
۰/۱۷۹	۰/۹۸۶	۰/۹۴۳	۱/۳۶۱	۰/۱۲۵	۱/۶۰۸	۰/۹۷۷	۲	
۰/۷۸۵	۰/۹۸۶	۰/۹۴۴	۱/۲۵	۰/۱۲۴	۱/۵۹۳	۰/۹۷۹	۳	
۰/۰۵۱	۰/۹۹۴	۰/۹۷۴	۰/۸۰۶	۰/۰۸۳	۱/۰۷۳	۰/۹۸۷	۴	
۰/۰۸۸	۱/۰۰۰	۰/۹۹۹	۰/۱۵۳	۰/۰۱۸	۰/۲۲۷	۱/۰۰۰	۵	SVR
۰/۰۸۴	۱/۰۰۰	۰/۹۹۹	۰/۱۵۶	۰/۰۱۸	۰/۲۳۳	۰/۹۹۹	۶	
۰/۰۸۲	۱/۰۰۰	۰/۹۹۹	۰/۱۶۲	۰/۰۱۹	۰/۲۴۶	۰/۹۹۹	۷	
۰/۰۹۲	۱/۰۰۰	۰/۹۹۹	۰/۱۴۷	۰/۰۱۷	۰/۲۲۲	۱/۰۰۰	۸	
۰/۸۳۲	۰/۹۷۸	۰/۹۱۳	۱/۵۷۳	۰/۱۵۴	۱/۹۸۱	۰/۹۶۵	۱	
۰/۷۰۲	۰/۹۸۵	۰/۹۳۹	۱/۳۱۷	۰/۱۲۹	۱/۶۵۹	۰/۹۷۷	۲	M5P
۰/۸۶۹	۰/۹۸۵	۰/۹۳۹	۱/۳۱۵	۰/۱۲۸	۱/۶۵۴	۰/۹۷۸	۳	
۰/۰۶۸	۰/۹۹۴	۰/۹۷۵	۰/۸۱۰	۰/۰۸۳	۱/۰۷۲	۰/۹۸۸	۴	
۰/۱۱۹	۱/۰۰۰	۰/۹۹۸	۰/۱۸۰	۰/۰۲۱	۰/۲۶۸	۰/۹۹۹	۵	
۰/۱۱۸	۱/۰۰۰	۰/۹۹۸	۰/۱۷۹	۰/۰۲۱	۰/۲۶۸	۰/۹۹۹	۶	
۰/۱۱۷	۱/۰۰۰	۰/۹۹۸	۰/۱۷۹	۰/۰۲۱	۰/۲۶۷	۰/۹۹۹	۷	
۰/۱۱۳	۱/۰۰۰	۰/۹۹۹	۰/۱۶۸	۰/۰۲۰	۰/۲۵۴	۰/۹۹۹	۸	
۰/۸۰۳	۰/۹۷۸	۰/۹۱۲	۱/۵۹۰	۰/۱۵۵	۱/۹۹۶	۰/۹۶۴	۱	
۰/۷۹۸	۰/۹۸۱	۰/۹۲۲	۱/۴۵۴	۰/۱۴۵	۱/۸۷۱	۰/۹۶۹	۲	
۰/۸۸۵	۰/۹۸۳	۰/۹۳۱	۱/۳۷۹	۰/۱۳۷	۱/۷۶۴	۰/۹۷۵	۳	
۰/۱۴۶	۰/۹۹۲	۰/۹۶۹	۰/۸۹۳	۰/۰۹۲	۱/۱۸۵	۰/۹۸۵	۴	RF
۰/۰۶۸	۰/۹۹۹	۰/۹۹۵	۰/۳۲۶	۰/۰۳۵	۰/۴۵۷	۰/۹۹۸	۵	
۰/۰۵۴	۰/۹۹۹	۰/۹۹۵	۰/۳۴۹	۰/۰۳۸	۰/۴۸۶	۰/۹۹۷	۶	
۰/۰۴۴	۰/۹۹۹	۰/۹۹۴	۰/۳۶۹	۰/۰۳۹	۰/۵۰۶	۰/۹۹۷	۷	
۰/۰۲۴	۰/۹۹۹	۰/۹۹۶	۰/۳۰۸	۰/۰۳۴	۰/۴۴۰	۰/۹۹۸	۸	
۰/۷۹	۰/۹۷۸	۰/۹۱	۱/۵۹۸	۰/۱۵۶	۲/۰۱۳	۰/۹۶۳	۱	
۰/۷۹۳	۰/۹۷۳	۰/۸۸۹	۱/۷۰۳	۰/۱۷۴	۲/۲۳۹	۰/۹۵۴	۲	
۰/۸۷۵	۰/۹۷۱	۰/۸۸۲	۱/۷۴۵	۰/۱۷۹	۲/۳۰۷	۰/۹۵۲	۳	
۰/۱۲۷	۰/۹۸۵	۰/۹۳۸	۱/۳۶۳	۰/۱۳۰	۱/۶۷۰	۰/۹۷۰	۴	RT
۰/۱۰۰	۰/۹۹۷	۰/۹۸۸	۰/۵۰۲	۰/۰۵۶	۰/۷۲۲	۰/۹۹۴	۵	
۰/۰۵۴	۰/۹۹۶	۰/۹۸۴	۰/۵۶۳	۰/۰۶۵	۰/۸۴۲	۰/۹۹۲	۶	
۰/۰۶۵	۰/۹۹۵	۰/۹۸۱	۰/۶۴۸	۰/۰۷۱	۰/۹۱۹	۰/۹۹۱	۷	
۰/۰۲۴	۰/۹۹۶	۰/۹۸۵	۰/۵۷۵	۰/۰۶۵	۰/۸۳۲	۰/۹۹۲	۸	

جدول ۶- نتایج عملکرد مدلها در مرحله صحت سنجی (ایستگاه شهرکرد).

مدلها	سناریو ها	R	RMSE	SI scatter	MAE	NSE	WI	MBE
	۱	۰/۶۵۴	۴/۴۰۰	۰/۲۰۰	۳/۵۲۵	۰/۳۱۵	۰/۷۷۳	۱/۶۱۱
	۲	۰/۶۹۰	۴/۱۵۲	۰/۱۳۳	۳/۳۱۲	۰/۳۹۰	۰/۸۰۰	۱/۴۲۵
	۳	۰/۷۱۳	۴/۴۰۰	۰/۰۹۱	۳/۱۸۳	۰/۴۳۴	۰/۸۲۰	۱/۲۸۳
	۴	۰/۹۱۵	۲/۵۲	۰/۶۱۴	۱/۷۱۳	۰/۸۲۱	۰/۹۴۹	۰/۶۵۲
GPR	۵	۰/۹۸۵	۱/۰۱۱	۰/۲۷۶	۰/۵۹۱	۰/۹۶۴	۰/۹۹۰	۰/۳۹۶
	۶	۰/۹۸۵	۱/۰۰۱	۰/۲۷۳	۰/۵۹۴	۰/۹۶۵	۰/۹۹۱	۰/۳۶۹
	۷	۰/۹۸۸	۰/۹۳۱	۰/۲۵۴	۰/۵۲۱	۰/۹۶۹	۰/۹۹۲	۰/۹۳۰
	۸	۰/۹۸۸	۰/۹۵۳	۰/۲۶۰	۰/۵۴۶	۰/۹۶۸	۰/۹۹۱	۰/۴۰۳
	۱	۰/۶۴۳	۴/۴۴۵	۰/۲۱۳	۳/۵۷۸	۰/۳۰۱	۰/۷۶۴	۱/۵۹
	۲	۰/۶۷۲	۴/۲۵۷	۰/۱۶۱	۳/۴۰۲	۰/۳۵۹	۰/۷۸۷	۱/۴۵۲
	۳	۰/۶۸۰	۴/۲۰۱	۰/۱۴۶	۳/۳۵۲	۰/۳۷۶	۰/۷۵۹	۱/۳۸۹
LR	۴	۰/۹۱۳	۲/۳۲۸	۰/۶۵۳	۱/۷۸۲	۰/۸۰۸	۰/۹۴۶	۰/۸۲۹
	۵	۰/۹۴۰	۲/۰۴	۰/۵۵۷	۱/۴۳۴	۰/۸۵۳	۰/۹۶۲	۰/۸۹۴
	۶	۰/۹۴۰	۲/۰۶۵	۰/۵۶۳	۱/۴۴۷	۰/۸۴۹	۰/۹۶۱	۰/۹۵۷

۰/۹۵۷	-/۹۶۲	-/۸۵۰	۱/۴۵۱	-۰/۵۶۲	۲/۰۶۲	-/۹۴۱	۷	M5Rules
۰/۹۶۳	-/۹۶۲	-/۸۴۹	۱/۴۵۳	-۰/۵۶۳	۲/۰۶۵	-/۹۴۱	۸	
۱/۶۰۹	-/۷۷۳	-/۳۱۶	۳/۵۱۹	-۱/۱۹۹	۴/۳۶۹	-/۶۵۵	۱	
۱/۴۵۲	-/۷۹۴	-/۳۶۸	۳/۳۶۹	-۱/۱۵۳	۴/۲۲۷	-/۶۷۹	۲	
۱/۳۵۰	-/۸۰۹	-/۳۶۹	۳/۲۸۲	-۱/۱۲۷	۴/۱۳۳	-/۶۹۵	۳	
۰/۶۶۷	-/۹۵۰	-/۸۲۵	۱/۷۰۰	-۰/۶۰۷	۲/۲۲۶	-/۹۱۷	۴	
۰/۳۵۸	-/۹۹۳	-/۹۷۴	۰/۵۲۱	-۰/۲۳۳	۰/۸۵۵	-/۹۸۹	۵	
۰/۳۸۹	-/۹۹۱	-/۹۶۳	۰/۵۸۲	-۰/۲۷۸	۱/۰۱۷	-/۹۸۴	۶	
۰/۳۷۴	-/۹۹۴	-/۹۷۸	۰/۴۶۷	-۰/۲۱۳	۰/۷۸۱	-/۹۹۲	۷	
۰/۳۹۱	-/۹۹۴	-/۹۷۷	۰/۴۷۹	-۰/۲۲۲	۰/۸۱۳	-/۹۹۱	۸	
۱/۷۱۵	-/۷۶۷	-/۳۱۱	۳/۵۴۲	-۱/۲۰۴	۴/۴۱۵	-/۶۵۵	۱	SVR
۱/۵۱۵	-/۸۱۱	-/۴۰۳	۳/۲۴۳	-۱/۱۲	۴/۱۰۷	-/۷۰۷	۲	
۱/۴۳۰	-/۸۳۰	-/۴۴۴	۳/۱۰۶	-۱/۰۸۲	۳/۹۶۷	-/۷۳۱	۳	
۰/۷۵۴	-/۹۵۱	-/۸۲۳	۱/۷۰۴	-۰/۶۱۰	۲/۲۳۶	-/۹۱۸	۴	
۰/۲۸۸	-/۹۹۶	-/۹۸۶	۰/۴۰۷	-۰/۱۷۱	۰/۶۲۸	-/۹۵۵	۵	
۰/۲۷۳	-/۹۹۶	-/۹۸۵	۰/۴۲۶	-۰/۱۷۹	۰/۶۵۶	-/۹۹۴	۶	
۰/۲۵۸	-/۹۹۷	-/۹۸۹	۰/۳۴۶	-۰/۱۵۰	۰/۵۵۰	-/۹۹۶	۷	
۰/۲۹۰	-/۹۹۷	-/۹۸۹	۰/۳۵۸	-۰/۱۵۳	۰/۵۶۱	-/۹۹۶	۸	
۱/۶۰۹	-/۷۷۳	-/۳۱۶	۳/۵۱۹	-۱/۱۹۹	۴/۳۹۶	-/۶۵۵	۱	M5P
۱/۴۵۵	-/۷۹۶	-/۳۷۲	۳/۳۵۱	-۱/۱۴۹	۴/۲۱۲	-/۶۸۳	۲	
۱/۳۳۲	-/۸۱۵	-/۴۱۵	۳/۲۲۱	-۱/۱۱۰	۴/۰۶۸	-/۷۰۵	۳	
۰/۶۵۹	-/۹۵۰	-/۸۲۵	۱/۷۰۲	-۰/۶۰۶	۲/۲۲۲	-/۹۱۷	۴	
۰/۳۲۴	-/۹۹۵	-/۹۸۰	۰/۴۶۸	-۰/۲۰۷	۰/۷۵۹	-/۹۲۲	۵	
۰/۳۱۰	-/۹۹۵	-/۹۸۰	۰/۴۶۰	-۰/۲۰۳	۰/۷۴۳	-/۹۹۲	۶	
۰/۳۲۸	-/۹۹۶	-/۹۸۵	۰/۴۰۱	-۰/۱۸۰	۰/۶۶۰	-/۹۹۴	۷	
۰/۳۳۷	-/۹۹۶	-/۹۸۵	۰/۴۰۶	-۰/۱۸۰	۰/۶۶۰	-/۹۹۴	۸	
۱/۶۴۳	-/۷۶۷	-/۲۹۶	۳/۵۵۸	-۱/۲۱۷	۴/۴۶۲	-/۶۴۴	۱	RF
۱/۳۴۳	-/۷۹۳	-/۳۲۳	۳/۴۶۱	-۱/۱۹۳	۴/۳۷۴	-/۶۶۲	۲	
۱/۲۵۲	-/۸۱۵	-/۳۹۷	۳/۲۴۹	-۱/۱۲۷	۴/۱۳۱	-/۶۹۷	۳	
۰/۷۲۴	-/۹۸۳	-/۷۸۲	۱/۸۸۱	-۰/۶۶۷	۲/۴۸۰	-/۸۹۵	۴	
۰/۴۷۷	-/۹۸۲	-/۹۳۴	۰/۸۲۶	-۰/۳۷۲	۱/۳۶۴	-/۹۷۱	۵	
۰/۴۸۰	-/۹۸۱	-/۹۳۰	۰/۸۵۷	-۰/۳۸۳	۱/۴۰۴	-/۹۷۰	۶	
۰/۵۰۵	-/۹۸۴	-/۹۴۳	۰/۷۶۰	-۰/۳۴۷	۱/۲۷۱	-/۹۷۸	۷	
۰/۵۰۱	-/۹۸۴	-/۹۴۳	۰/۷۵۵	-۰/۳۴۶	۱/۲۶۷	-/۹۷۸	۸	
۱/۶۵۷	-/۷۶۲	-/۲۷۸	۳/۵۹۴	-۱/۲۳۳	۴/۵۱۹	-/۶۳۶	۱	RT
۱/۴۳۰	-/۷۵۴	-/۱۳۱	۳/۹۱۴	-۱/۳۵۲	۴/۹۵۷	-/۵۹۴	۲	
۱/۳۶۸	-/۷۷۰	-/۱۷۷	۳/۷۴۶	-۱/۳۱۵	۴/۸۲۳	-/۶۱۵	۳	
۰/۶۶۰	-/۹۰۶	-/۶۴۶	۲/۴۴۴	-۰/۸۶۴	۳/۱۶۶	-/۸۳۰	۴	
۰/۳۶۸	-/۹۷۳	-/۸۹۹	۱/۱۳۳	-۰/۴۶۲	۱/۶۹۳	-/۹۵۱	۵	
۰/۴۲۳	-/۹۶۹	-/۸۸۲	۱/۲۱۹	-۰/۴۹۸	۱/۸۲۷	-/۹۴۳	۶	
۰/۴۸۱	-/۹۷۴	-/۹۰۴	۱/۱۲۵	-۰/۴۴۹	۱/۶۵۴	-/۹۵۵	۷	
۰/۴۳۹	-/۹۷۱	-/۸۹۲	۱/۱۸۱	-۰/۴۷۷	۱/۷۴۹	-/۹۴۸	۸	

در سناریوی ۱ ضعیف‌ترین عملکرد را نسبت به سایر سناریوها دارند. البته لازم به ذکر است تمامی مدل‌ها در سناریوهای ۱ تا ۴ با خطای بیشتری مواجه هستند. علاوه بر این، مدل‌های ایستگاه گرگان بر خلاف ایستگاه شهرکرد با عملکرد مطلوب‌تری، دمای نقطه شب‌نیم را پیش‌بینی نموده‌اند. به عبارت دیگر، ضریب همبستگی بالا

جدول ۷ میزان دقت مدل‌های منتخب استفاده شده در پیش‌بینی دمای نقطه شب‌نیم روزانه را نشان می‌دهد. مدل‌های منتخب شده علاوه بر ضریب همبستگی زیاد، دارای جذر میانگین مربعات خطای کمتر نسبت به مدل‌های برارزش شده دیگر هستند. به عبارت دیگر، داده‌های پیش‌بینی شده مدل‌های زیر دارای بیشترین همبستگی با داده‌های مشاهداتی هستند. هر دو ایستگاه

و خطای کمتری داشتند. همچنین، مدل SVR عملکرد مطلوبی در هر دو ایستگاه داشته است.

جدول ۷- منتخب مدل‌ها در سناریوهای مختلف.


منتخب مدل‌های گرگان							
	GPR-5	LR-6	M5Rules-8	SVR-8	M5P-8	RF-8	RT-5
MBE	۰/۰۷۴	۰/۱۷	۰/۱۱۱	۰/۰۹۲	۰/۱۱۳	۰/۰۲۴	۰/۱
WI	۰/۹۹۹	۰/۹۹۹	۱	۱	۱	۰/۹۹۹	۰/۹۹۷
NSE	۰/۹۹۸	۰/۹۹۵	۰/۹۹۹	۰/۹۹۹	۰/۹۹۹	۰/۹۹۶	۰/۹۸۸
MAE	۰/۲۱۲	۰/۳۲	۰/۱۶۹	۰/۱۴۷	۰/۱۶۸	۰/۳۰۸	۰/۵۰۲
SI scatter	۰/۰۲۶	۰/۰۳۷	۰/۰۲	۰/۰۱۷	۰/۰۲	۰/۰۲۴	۰/۵۰۶
RMSE	۰/۳۳۲	۰/۴۸۱	۰/۲۵۶	۰/۲۲۲	۰/۲۵۴	۰/۴۴	۰/۷۲۲
R	۰/۹۹۹	۰/۹۹۸	۰/۹۹۹	۱	۰/۹۹۹	۰/۹۹۸	۰/۹۹۴

منتخب مدل‌های شهرکرد							
	GPR-7	LR-4	M5Rules-7	SVR-7	M5P-7	RF-8	RT-7
MBE	۰/۳۹	۰/۸۲۹	۰/۳۷۴	۰/۲۸۵	۰/۳۲۸	۰/۵۰۱	۰/۴۸۱
WI	۰/۹۹۲	۰/۹۴۶	۰/۹۹۴	۰/۹۹۷	۰/۹۹۶	۰/۹۸۴	۰/۹۷۴
NSE	۰/۹۶۹	۰/۸۰۸	۰/۹۷۸	۰/۹۸۹	۰/۹۸۵	۰/۹۴۳	۰/۹۰۴
MAE	۰/۵۲۱	۱/۷۸۲	۰/۴۶۷	۰/۳۴۶	۰/۴۰۱	۰/۷۵۵	۱/۱۲۵
SI scatter	-۰/۲۵۴	-۰/۶۳۵	-۰/۲۱۳	-۰/۱۵	-۰/۱۸	-۰/۳۴۶	-۰/۴۴۹
RMSE	۰/۹۳۱	۲/۳۲۸	۰/۷۸۱	۰/۵۵	۰/۶۶	۱/۲۶۷	۱/۶۴۵
R	۰/۹۸۸	۰/۹۱۳	۰/۹۹۲	۰/۹۹۶	۰/۹۹۴	۰/۹۷۸	۰/۹۵۵


نمودار راداری قابل مشاهده است. همچنین، مدل LR-4 با RMSE بیشتر، نسبت به سایر مدل‌ها در ایستگاه شهرکرد و مدل RT-5 در ایستگاه گرگان به عنوان مدل‌های ضعیف شناخته شدند.

در شکل ۷، مدل‌های منتخب هر دو ایستگاه مورد مطالعه بر روی شاخه‌های ارزیابی و به صورت نمودارهای راداری ترسیم شده‌اند. بر اساس معیارهای ارزیابی در ایستگاه‌های گرگان و شهرکرد، مدل SVR به ترتیب با کمترین MAE, MBE, RMSE به عنوان مدل کارآمد در

گرگان



شهرکرد

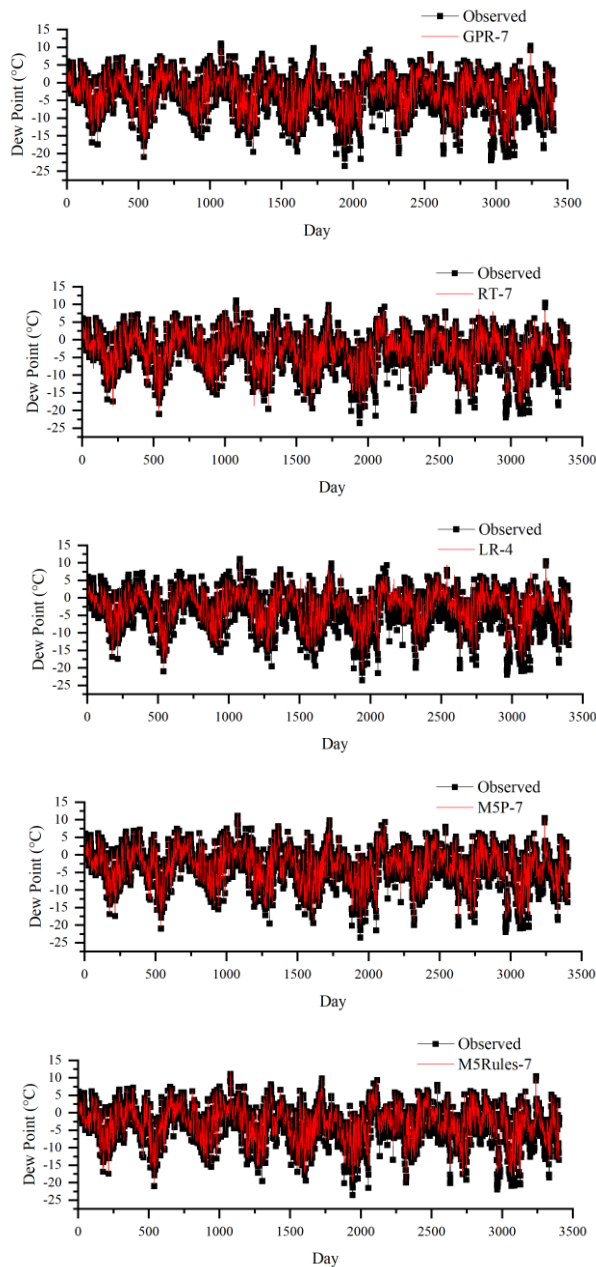


شکل ۷- نمودارهای راداری دمای نقطه شب‌نم در ایستگاه‌های گرگان و شهرکرد.

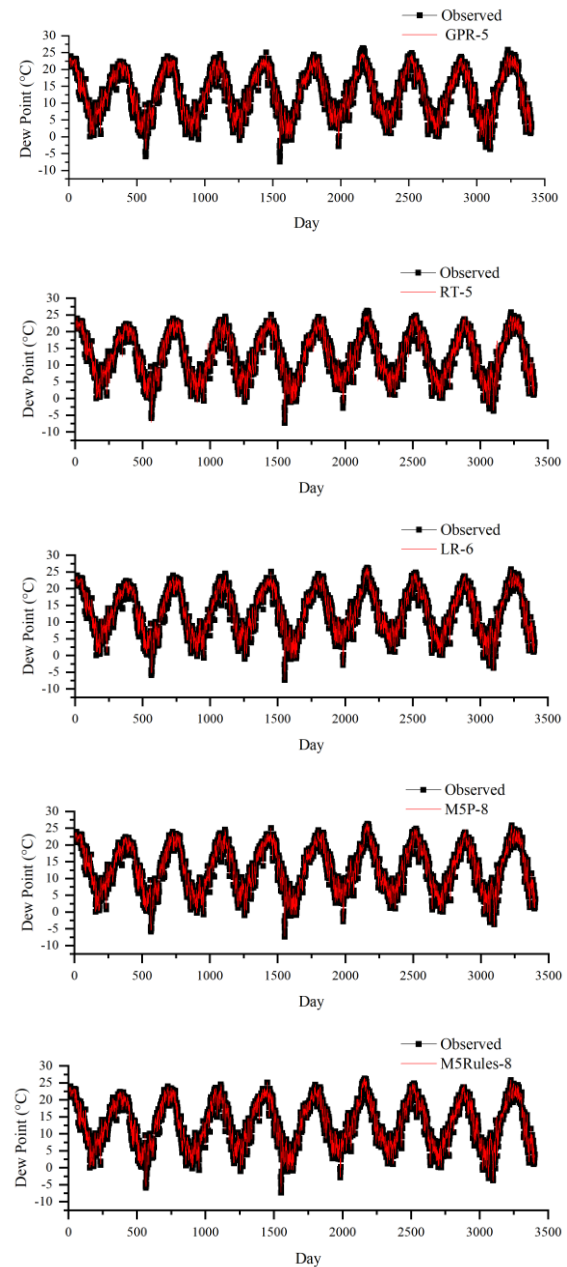


توسط مدل‌های منتخب با مقادیر مشاهده‌ای در شکل ۸ ترسیم و ارائه گردیده است. با توجه به نمودارهای تغییرات زمانی دمای نقطه شب‌نم پیش بینی شده با مقادیر مشاهده‌ای، چنین استنباط می‌شود که مقادیر پیش‌بینی شده بر روی مقادیر مشاهده‌ای طبق برازش‌های قبلی (جدول ۷) منطبق هستند و همچنین می‌توان دقت بالای مدل‌های SVR-8, SVR-7 را در تخمین دمای نقطه شب‌نم روزانه مشاهده نمود.



گرگان





شهرکرد



همانطوری که قبلاً و با توجه به نتایج ارائه شده در جدول ۱ ذکر گردید، در هر دو ایستگاه مورد مطالعه، میانگین دما و دمای حداقل بیشترین همبستگی را با دمای نقطه شب‌نم داشتند. اما در حالت کلی این پارامترها برای تخمین دقیق کافی نبودند و علی‌رغم کم بودن همبستگی برخی پارامترها طبق جدول مذکور، قرارگیری آنها در ترکیبی خطی باعث ایجاد همبستگی بالا با دمای نقطه شب‌نم شده و قدرت پیش‌بینی مدل‌ها را افزایش داده‌اند. لذا، نمودار تغییرات زمانی دمای نقطه شب‌نم پیش‌بینی






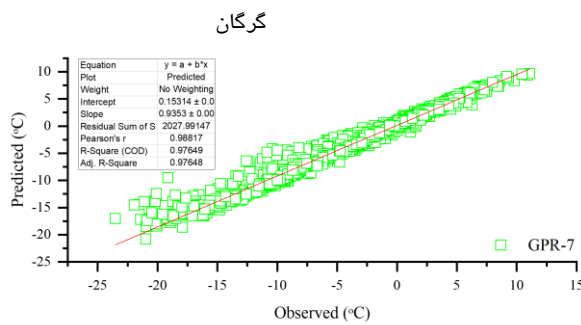
شکل ۸- نمودارهای تغییرات زمانی مقادیر دمای نقطه شبنم پیش‌بینی شده با مقادیر مشاهداتی ایستگاه‌ها.





شکل ۸- ادامه.

با توجه به شکل ۹ و روابط رگرسیونی ارائه شده برای نمودارها، مدل SVR با دقت تخمین خوب نسبت به مدل‌های دیگر به ترتیب برای ایستگاه‌های گرگان و شهرکرد با ضریب تعیین ۰/۹۹۲۳۱ و ۰/۹۹۹۱ پیش‌بینی دمای نقطه شبنم توصیه می‌گردد.

علاوه بر این، در شکل ۹ نمودار پراکنش بهترین مدل‌ها برای تخمین و پیش‌بینی دمای نقطه شبنم قابل مشاهده است. پراکنش نقاط حول محور نیمساز در ایستگاه گرگان نسبت به ایستگاه شهرکرد کمتر است. به عبارت دیگر، نقاط تقریباً روی محور نیمساز برازش یافته‌اند. لذا











شکل ۹- نمودارهای پراکنش دمای نقطه شبینم در ایستگاه‌های گرگان و شهرکرد.



گرگان

شهرکرد



گرگان

شهرکرد




شکل ۹- ادامه.


مشاهداتی دارند. علاوه بر این، نتایج این تحقیق و مقایسه با نتایج پژوهش قاسم و همکاران (۲۰۱۹) نشان دادند که با پنج پارامتر هواشناسی شامل میانگین دمای روزانه، رطوبت نسبی، فشار بخار واقعی، ساعات آفتابی و سرعت باد، مدل SVR با جذر میانگین مربعات خطای ۰/۵۵ به عنوان مدل ضعیف‌تر نسبت به مدل M5P برای تخمین دمای نقطه شبنم، در تضاد است.

همچنین، شکل ۱۰ نمودار جعبه‌ای بهترین مدل‌های مورد مطالعه برای هر ایستگاه را به صورت جداگانه نشان می‌دهد. مشاهده می‌گردد که میانگین منطقه‌ای نمودار جعبه‌ای گرگان بیشتر و نمودار فاقد داده پرت است در حالی که میانگین منطقه‌ای شهرکرد، کوچک و دارای داده‌های پرت است. در نمودار جعبه‌ای گرگان و شهرکرد، جعبه‌های مربوط به مدل‌های SVR-7 و SVR-8 به ترتیب بیشترین تشابه را با جعبه مربوط به مقادیر

گرگان



شهرکرد



شکل ۱۰- نمودارهای جعبه‌ای دمای نقطه شبنم در ایستگاه گرگان و شهرکرد.

نشان می‌دهد که مدل SVR از دقت بیشتری نسبت به سایر مدل‌ها برخوردار است و در ادامه به ترتیب مدل‌های M5P, M5Rules, GPR, RF, LR, RT برای ایستگاه گرگان از دقت بیشتر به کمتر برای تخمین دمای نقطه شبنم روزانه رتبه‌بندی شدند. همچنین، برای ایستگاه شهرکرد مدل‌های M5P, M5Rules, GPR, RF, LR از دقت بیشتر به کمتر برای تخمین دمای نقطه شبنم روزانه رتبه‌بندی شدند. در نهایت، از مقایسه مدل‌های داده محور درختی و رگرسیونی چنین برآورد شد که در حالت کلی مدل‌های رگرسیونی برای تخمین دمای نقطه شبنم نسبت به مدل‌های درختی از دقت بالایی برخوردار هستند.

## نتیجه‌گیری کلی

در این پژوهش با به کارگیری مدل‌های یادگیری ماشین مختلف اعم از GPR, LR, M5P, M5Rules, RF, RT, SVR و با استفاده از پارامترهای هواشناسی، توانایی مدل‌های مذکور در تخمین دمای نقطه شبنم در ایستگاه‌های گرگان و شهرکرد مورد ارزیابی قرار گرفت. دقت برآورد مدل‌ها با استفاده از تک پارامتر ورودی شامل  $T_{min}$  در دو ایستگاه شهرکرد و گرگان عملکرد ضعیف‌تری نسبت به سایر پارامترهای ورودی داشتند. همچنین، برآورد دمای نقطه شبنم روزانه در ایستگاه‌های گرگان و شهرکرد با مدل‌های SVR, M5P به ترتیب با سناریوی ۸ و ۷ بهترین عملکرد را داشتند. مقایسه مدل‌های منتخب با یکدیگر

منابع مورد استفاده

- Alizamir M, Kim S, Zounemat-Kermani M, Heddami S, Kim NW and Singh VP, 2020. Kernel extreme learning machine: An efficient model for estimating daily dew point temperature using weather data. *Water* 12(9): 2600.
- Mojahedi MA, Mohammadi K, Shamshirband S, Seyed Danesh A, Mostafaeipour A and Kamsin A, 2016. A hybrid computational intelligence method for predicting dew point temperature. *Environmental Earth Sciences* 75: 415.
- Brieman L, 2001. Random Forests. *Machine Learning*, 45: 5-23.
- Deka P, Patil AP, Yeswanth Kumar P and Naganna SR, 2017. Estimation of dew point temperature using SVM and ELM for humid and semi-arid regions of India. *ISH Journal of Hydraulic Engineering* 24(2): 190-197.
- Dong J, Wu L, Liu X, Li Z, Gao Y, Zhang Y and Yang Q, 2020. Estimation of daily dew point temperature by using bat algorithm optimization based extreme learning machine. *Applied Thermal Engineering* 165: 114569.
- Dong J, Zeng W, Lei G, Wu Lifeng, Chen H, Wu J, Huang J, Gaiser T, and Srivastava AK, 2022. Simulation of dew point temperature in different time scales based on grasshopper algorithm optimized extreme gradient boosting. *Journal of Hydrology* 606: 127452.
- Fathollahzadeh N, Khalili K, Behmanesh J and Khanmohammadi N, 2018. On the reliability of soft computing methods in the estimation of dew point temperature: The case of arid regions of Iran. *Computers and Electronics in Agriculture* 153: 334-346.
- Fischer MM, 2015. Spatial Analysis in Geography. *International Encyclopedia of the Social & Behavioral Sciences*. Elsevier 12: 14752-14758.
- Holmes G, Hall M and Prank B, 2007. Generating rule sets from model trees. *Advanced topics in artificial intelligence. Lecture Notes in Computer Science*: 1774.
- Kalmeg S, 2015. Analysis of weka data mining algorithm reptime, simple cart and random tree for classification of indian news. *Engineering Technician* 2(2): 444602.
- Kermani MZ, 2011. Hourly predictive Levenberg–Marquardt ANN and multi linear regression models for predicting of dew point temperature. *Meteorology and Atmospheric Physics* 117: 181-192.
- Kisi O, Kim S and Shiri J, 2013. Estimation of dew point temperature using neuro-fuzzy and neural network techniques. *Theoretical and Applied Climatology* 114: 365-373.
- Lawrence MG, 2005. The relationship between relative humidity and the dewpoint temperature in moist air: a simple conversion and applications. *Bulletin of the American Meteorological Society* 86: 225-234.
- Mahdizadeh S, Behmanesh J and Khalili K, 2017. Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapotranspiration. *Computers and Electronics in Agriculture* 139: 103-114.
- Mohammadi K, Shamshirband S, Motamedi S, Petković D, Hashim R and Gocic M, 2015. Extreme learning machine based prediction of daily dew point temperature. *Computers and Electronics in Agriculture* 117: 214-225.
- Mohammadi K, Shamshirband S, Petković D, Yee PL and Mansor Z, 2016. Using ANFIS for selection of more relevant parameters to predict dew point temperature. *Applied Thermal Engineering* 96: 311–319.
- Naganna S, Deka P, Ghorbani M, Biazar S, Al-Ansari N and Yaseen Z, 2019. Dew point temperature estimation: application of artificial intelligence model integrated with natureinspired optimization algorithms. *Water* 11(4): 742.
- Osouli M, Mikaeili F and Samadianfard S, 2022. Evaluating capabilities of gradient boosted tree and optimized random forest models in estimating daily dew point temperature. *Environment and Water Engineering* 8(3): 654–668 (in Persian with English abstract)
- Qasem SN, Samadianfard S, Sadri Nahand H, Mosavi A, Shamshirband S and Chau KW, 2019. Estimating daily dew point temperature using machine learning algorithms. *Water* 11(3): 582.
- Shank DB, McClendon RW, Paz J and Hoogenboom G, 2008. Ensemble artificial neural networks for prediction of dew point temperature. *Applied Artificial Intelligence* 22(6): 523-542.
- Shiri J, 2019. Prediction vs. estimation of dew point temperature: assessing GEP, MARS and RF models. *Hydrology: Current Research* 50(2): 633–643.
- Shiri J, Kim S and Kisi O, 2014. Estimation of daily dew point temperature using genetic programming and neural networks approaches. *Hydrology: Current Research* 45(2): 165- 181.

Zhan C, Gan A and Hadi M, 2011. Prediction of lane clearance time of freeway incidents using the M5P tree algorithm. *IEEE Transactions on Intelligent Transportation Systems* 12(4): 1549–1557.