




Bias Correction of Short-Term Minimum and Maximum Temperature Forecasts of the WRF Model by Using the Pursuit Machine

Shokouhi, M.¹  | Mesrizadeh, M.¹  | Asadi Oskouei, E.¹ 

1. Atmospheric Science and Meteorological Research Center (ASMERC), Tehran, Iran.

Corresponding Author E-mail: mojtabashokohi@gmail.com

(Received: 19 Aug 2023, Revised: 11 Sep 2023, Accepted: 9 Jan 2024, Published online: 6 July 2024)

Summary

The importance of accurate forecasting in agricultural hydrometeorology is clear. This research is an approach towards the use of a tracking machine with a hidden layer for error prediction at stationary points. The predicted error will be used to modify the model output. One of the strengths of this method is the use of a meteorological variable such as maximum and minimum temperature in applications. A tracking machine with a hidden layer tracks the time series of the short-term prediction error of the maximum and minimum temperature of the model with the kernel of trigonometric functions, which is formulated as follows:

$$x_t = \sum_{n=1}^{\infty} a_n \phi_n \left(A_n t^2 + B_n t + C_n e^{-D_n \left(\frac{t}{T}\right)^2} \right) + C \epsilon_t \quad t \in T$$

It provides an error prediction that will effectively modify the model prediction. This machine is compact in terms of computing. The value of the standard deviation of the statistical population of the maximum temperature during the period was 10 celsius, which shows a significant improvement from the value of 9.5 to 10.01 by the tracking machine. Also, the standard deviation of the minimum temperature was about 8.5 degrees Celsius, which was improved by the machine from 7.7 to 8.4 degrees Celsius. In this research, we use the skill score criterion, whose value will show that the skill score of the model for short-term maximum temperature has grown from a negative value with a leap to more than 0.8, which shows the significant impact of the machine in improving forecasting. The minimum temperature prediction skill score of the model will show an increase in the way of improving the prediction. The comparison of the obtained results shows that the skill score and RMSE of predicting the maximum and minimum temperature of the modification of the output of the model have increased significantly compared to the model. Also, the monthly change in the skill score indicates the effect of the chasing car on the ability to correct the forecast, especially for the short-term maximum temperature. Investigations will show that the modification of the model has a uniform overfitting in the studied period. In addition, a powerful index independent of the concept of accuracy size will be introduced and used as a method to check the reliability of the model and tracking machine outputs, which indicates the level of confidence that can be had in the model and machine outputs. In this case, the reliability of the maximum and minimum temperature predictions and the significant growth of the index have shown stability in providing the output. After bias correction, the variability of the skill score has been significantly reduced, and by reducing the amount of forecasting error, the reliability of the model forecasts has increased from 60% to more than 85%. Depending on the location and time, the WRF model's forecasting performance is different, but after bias correction, this dependence is removed, and forecasting in all regions and times has almost the same performance.

Keywords: Machine Learning, Reliability, Skill Score, Spectral Error, Time Series.

Cite this article: Shokouhi, M., Mesrizadeh, M., & Asadi Oskouei, E. (2024). Bias Correction of Short-Term Minimum and Maximum Temperature Forecasts of the WRF Model by Using the Pursuit Machine. *Journal of the Earth and Space Physics*, 50(2), 465-479. DOI: <http://doi.org/10.22059/jesphys.2024.363736.1007552>

E-mail: (1) mehdi.mesrizadeh1983@yahoo.com | e.asadi.o@gmail.com



تصحیح خطای پیش‌بینی‌های کوتاه‌مدت دمای کمینه و بیشینه مدل WRF با استفاده از ماشین تعقیب‌کننده

مجتبی شکوهی^۱ | مهدی مصری زاده^۱ | ابراهیم اسعدی اسکویی^۱

۱. پژوهشگاه هواشناسی و علوم جو، تهران، ایران.

رایانامه نویسنده مسئول: mojtabashokohi@gmail.com

(دریافت: ۱۴۰۲/۵/۲۸، بازنگری: ۱۴۰۲/۶/۲۰، پذیرش نهایی: ۱۴۰۲/۱۰/۱۹، انتشار آنلاین: ۱۴۰۳/۴/۱۶)

چکیده

برونداد مدل‌های پیش‌بینی عددی وضع هوا دارای خطا است. جهت اصلاح پیش‌بینی‌های کوتاه‌مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای بیشینه و کمینه مدل WRF، از یک روش یادگیری ماشین به نام ماشین تعقیب‌کننده استفاده شد. در این روش با سری زمانی ۳۰۰ روزه از خطای برونداد مدل و با به‌کارگیری روش کمترین مربعات طیفی شبه فوریه-سری زمانی، خطای پیش‌بینی‌های مدل WRF برآورد شد. خطای پیش‌بینی‌ها در دوره ۲۰۲۰/۱۱/۰۱ الی ۲۰۲۳/۰۳/۰۵ برای ۵۶۰ ایستگاه هواشناسی برآورد شد. یکی از نقاط قوت این روش، استفاده از تنها یک متغیر برای کاهش خطای پیش‌بینی‌های است. عملکرد پیش‌بینی مدل WRF بسته به مکان و زمان متفاوت است، مثلاً نمره مهارت مدل برای دمای بیشینه در ماه سپتامبر نسبت به سایر ماه‌ها کمتر و در مناطق جنوب غربی زاگرس نسبت به سایر مناطق کمتر است، که بعد از اصلاح این وابستگی حذف، و پیش‌بینی در تمام مناطق و زمان‌ها عملکرد یکسانی دارد. نتایج نشان داد نمره مهارت، RMSE و شاخص اطمینان‌پذیری پس از اصلاح خطای مدل به شکل قابل‌توجهی بهبود می‌یابد. پس از اصلاح خطا، نمره مهارت مدل برای پیش‌بینی دمای بیشینه از ۰/۱- به ۰/۸۵+ و برای دمای کمینه از ۰/۳۸- به ۰/۷۲+ می‌رسد. به‌طور متوسط RMSE برای پیش‌بینی دمای بیشینه از ۶ به ۲ درجه و برای دمای کمینه از ۴/۵ به ۳ درجه سلسیوس می‌رسد. پس از اصلاح خطای مدل، تغییرپذیری نمره مهارت پیش‌بینی‌ها کاهش یافته و با کاهش مقدار خطای پیش‌بینی‌ها، قابلیت اطمینان‌پذیری به پیش‌بینی‌های مدل به‌طور متوسط از ۶۰ درصد به ۸۵ درصد می‌رسد.

واژه‌های کلیدی: خطای طیفی، سری زمانی، قابلیت اطمینان، نمره مهارت، یادگیری ماشین.

۱. مقدمه

پیش‌بینی کوتاه‌مدت و اقلیمی قابل استفاده است. ناهمواری‌های سطح زمین و پدیده‌های محلی و همچنین استفاده از روش‌های عددی، از جمله دلایل مولد خطا در تولید پیش‌بینی‌های مدل نسبت به مشاهدات هستند (آزادی و محمدی، ۱۳۹۸). از این رو محققین بسیاری با روش‌های آماری و محاسباتی سعی در تصحیح خطای پیش‌بینی‌های مدل برای پدیده‌های کوتاه‌مدت داشته‌اند. عامل این نوع از خطاها عوامل توپوگرافی زمین، کاربری زمین و نقص در طراحی فرایندهای فیزیکی مدل است که به‌عنوان خطای سیستماتیک مدل در نظر گرفته می‌شود (مرادی و مرتضی‌پور، ۱۳۹۷). والاپیل و همکاران (۲۰۲۰) با استفاده

پیش‌بینی دمای بیشینه و کمینه روزانه از لحاظ مواجهه با تنش‌های آبی و گرمایی دام و طیور و مقابله با آفات حائز اهمیت است (قره‌داغی و دیندار، ۱۴۰۰). همه مدل‌های پیش‌بینی عددی وضع هوا (Numerical Weather Prediction) که برای پیش‌بینی متغیرهای وضع هوا مورد استفاده قرار می‌گیرند به‌طور ذاتی به‌ویژه در نزدیکی سطح زمین دارای انحراف از مشاهدات هستند (محمدی و همکاران، ۲۰۱۷). مدل (Weather Research and Forecasting) WRF یک مدل عددی جهت پیش‌بینی متغیرهای وضع هوا است که با مفروضات عددی به‌عنوان مقادیر اولیه و مرزی قابل اجرا و برونداد حاصل به‌عنوان

استناد: شکوهی، مجتبی؛ مهدی زاده، مهدی و اسعدی اسکویی، ابراهیم (۱۴۰۳). تصحیح خطای پیش‌بینی‌های کوتاه‌مدت دمای کمینه و بیشینه مدل WRF با استفاده از ماشین تعقیب‌کننده. مجله فیزیک زمین و فضا، ۵۰(۲)، ۴۶۵-۴۷۹. DOI: <http://doi.org/10.22059/jesphys.2024.363736.1007552>

رایانامه: (۱) a-e.asadi.o@gmail.com | mehdi.mesrizadeh1983@yahoo.com

روزانه ایستگاه‌ها به دو دسته ایستگاه‌های آزمون و ایستگاه‌های ارزیاب، با استفاده از داده‌های نقاط ایستگاهی مشاهدات و پیش‌بینی ۵ روزه مدل WRF، به یافتن خطای مدل متناظر کوتاه‌مدت در نقاط آزمون پرداختند و با استفاده از میانگین‌گیری ۵ روزه خطای مدل، یک پس‌پردازش آماری برای تصحیح مدل به‌دست آوردند. سپس به تعمیم نتایج حاصل‌شده بر روی کل نقاط ایستگاهی مبادرت ورزیدند. آنها برای ارزیابی کار خود از ایستگاه‌های ارزیاب استفاده کردند. نتایج نشان داد که پس‌پردازش به‌کارگرفته‌شده توسط آنها به‌طور قابل‌توجهی در تصحیح بروناد مدل بر افزایش نمره مهارت مدل خواهد داشت.

الگوریتم‌های یادگیری ماشین (Machine Learning) مانند ماشین بردار پشتیبان (Support Vector Machine) و شبکه‌های عصبی (Artificial Neural Network) یکی از ابزارهای پرکاربرد مورد استفاده محققین مختلف است و به‌طور گسترده‌ای در پیش‌بینی دمای روزانه استفاده شده است (آبهیشک و همکاران، ۲۰۱۲؛ چوالیر و همکاران، ۲۰۱۰). ماشین بردار پشتیبان با هسته توابع شعاعی جهت پیش‌بینی دما، بیشترین کاربرد را در تحقیقات اخیر داشته است. اورتز گارسیا و همکاران (۲۰۱۲) بر اساس ماشین پشتیبان برداری با هسته توابع شعاعی یک رگرسیون برای پیش‌بینی دمای ۶ ساعته به‌دست آوردند. آنها از داده‌های دمایی سال ۲۰۰۹ فرودگاه بارسلون و استفاده از هفت پارامتر جوی، اقدام به پیش‌بینی دمای ۶ ساعته کردند. سپس به مقایسه نتایج خود با شبکه عصبی پرداخته و نشان دادند که روش به‌کارگرفته‌شده جهت پیش‌بینی دما، نسبت به سایر روش‌ها از دقت بیشتری برخوردار بوده است. میلیت و همکاران (۲۰۱۱)، یک ماشین پشتیبان با کمترین مربعات را برای پیش‌بینی دمای ۶ ساعته با پارامترهای آب‌وهوایی مورد استفاده قراردادند. مقایسه نتایج آنها با روش‌های لایه‌های چندگانه پرسپترون شبکه عصبی توابع شعاعی و شبکه عصبی تصادفی صورت گرفت و نشان داد روش به‌کارگرفته‌شده نسبت به سایر شبکه‌های عصبی از دقت بیشتری برخوردار بوده است.

از روش‌های اصلاح نسبت ضربی (multiplicative Ratio Correction) و فیلتر کالمن (Kalman Filter) به اصلاح انحراف پراکندگی، ارببی و کشیدگی متغیرهای دمایی و رطوبت برای اصلاح خطای سیستماتیک مدل اقدام کردند. آزادی و همکاران (۱۳۸۷) با استفاده از فیلتر خطی کالمن به اصلاح پیش‌بینی دمای بیشینه و کمینه دومتری مدل WRF برای ۱۱۷ ایستگاه کشور مبادرت ورزیدند. آنها مشاهده کردند هنگامی که خطای مدل زیاد است به‌کارگیری این روش تأثیر محسوسی در افزایش دقت پیش‌بینی خواهد داشت. روش رگرسیون خطی برای ارزیابی مدل WRF توسط نصر اصفهانی و همکاران (۱۳۹۸) در حوضه آبریز زاینده‌رود برای پیش‌بینی سرمازدگی دیررس بهاره انجام شده بود که نتایج آنها از ارتباط قابل‌قبول بین مشاهدات و نتایج مدل حکایت داشت. محمدی و همکاران (۲۰۱۷) در پژوهشی که انجام دادند، ابتدا با استفاده از داده‌های مشاهدات و مدل WRF یک خطا را در نقاط ایستگاهی را در طی دوره بلندمدت به‌دست آوردند و سپس با استفاده از چند روش درون‌یابی مکانی به تعمیم خطا در نقاط شبکه مدل مبادرت ورزیدند و با استفاده از این پهنه‌بندی به اصلاح پیش‌بینی حاصل از مدل اقدام کردند. نتایج آنها نشان داد که روش درون‌یابی کریجینگ (Kriging) به‌طور متوسط سبب افزایش دقت ۲۶ درصدی نتایج پیش‌بینی خواهد شد. هاگر و ریف (۲۰۰۷) با استفاده از تحلیل آماری روش تقریبی را برای پیش‌بینی خطای سیستماتیک دمای نزدیک سطح زمین ساختند. آنها دو مدل کواریانسی ساختند یکی برای سری زمانی ایستای از خطاها با استفاده از یک تابع همانندساز بین مشاهدات و خطاهای متوسط در حال اجرا و برای سری دینامیک را به دو بخش سری زمانی گذشته پیش‌بینی گذشته و پیش‌بینی خطای ممکن تقسیم کردند. برای ارزیابی روش خود داده‌های ۶ ماهه و ۱۲ ساعته مدل و مشاهدات را مورد ارزیابی قرار دادند. ارزیابی آنها برای دمای ۲ متری سطح زمین نشان داد که مؤلفه‌های خطای سیستماتیک به‌طور کارایی به روی نقاط شبکه قابل پیش‌بینی شده‌اند. شکوهی و همکاران (۱۴۰۱) با افراز

مدل اصلاح می‌شود. به عبارتی در این روش به جای در نظر گرفتن میانگین خطاها در فرایند اصلاح خطای مدل، ملاک اصلاح برون داد مدل WRF، خطاهای پیش‌بینی شده توسط ماشین تعقیب کننده است. از این رو در این مطالعه توانایی الگوریتم یادگیری ماشین تعقیب کننده در اصلاح خطای پیش‌بینی‌های کوتاه مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای بیشینه و کمینه مدل WRF در سراسر کشور مورد ارزیابی قرار گرفت.


۲. روش پژوهش

۲-۱. داده‌ها

ایران به علت موقعیت خاص و ویژگی‌های توپوگرافیک، از آب و هوایی متفاوت برخوردار است. ویژگی‌های توپوگرافیک ایران در شکل (۱-الف) نشان داده شده است. آب و هوای خشک و نیمه خشک بیشتر مناطق کشور را پوشش می‌دهد. داده‌های مشاهده شده دمای کمینه و بیشینه روزانه برای کلیه ایستگاه‌های هواشناسی سطح کشور (همدی، اقلیم‌شناسی) برای دوره ۲۰۲۰/۱۱/۰۱ الی ۲۰۲۳/۰۳/۰۵ تهیه شده است. تعداد کل این ایستگاه‌ها بیش از ۵۰۰ عدد می‌باشد که در شکل (۱-ب) موقعیت مکانی آنها نشان داده شده است.


ماشین تعقیب کننده (Pursuit Machine)، یک ماشین یادگیری است و برای داده‌های سری زمانی استفاده می‌شود که در زمینه‌های شیمی-فیزیک (گریور و همکاران، ۲۰۲۱)، مراقبت‌های بهداشتی (تورنس و همکاران، ۲۰۲۱) و پزشکی (گوردون و همکاران، ۲۰۲۰) کاربرد دارد.

از آنجا که الگوریتم‌های یادگیری ماشین مانند ماشین تعقیب کننده به عنوان ابزاری کارا در پیش‌بینی‌های مختلف به کار گرفته شده است، هدف اصلی این پژوهش کاهش و اصلاح خطای پیش‌بینی‌های کوتاه مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای بیشینه و کمینه مدل WRF در سراسر کشور با بهره‌گیری از الگوریتم یادگیری ماشین تعقیب کننده با استفاده از کمترین مربعات خطای طیفی شبه فوریه-سری زمانی با یک لایه پنهان است. اکثر روش‌های تصحیح خطای پیش‌بینی مدل بر مبنای محاسبه میانگین خطای مدل در یک دوره آموزش و تعمیم آن به پیش‌بینی‌های پیش‌رو است. در این مطالعه بر اساس سری زمانی خطای مدل در یک دوره آموزش، خطای مدل در دوره‌های پیش‌رو با استفاده از ماشین تعقیب کننده پیش‌بینی می‌شود و این خطاهای پیش‌بینی شده بر برون داد مدل اعمال شده و پیش‌بینی‌های



• Meteorological stations

(ب)



(الف)

شکل ۱. الف) نقشه عوارض جغرافیایی ایران، ب) پراکنش مکانی ایستگاه‌های هواشناسی مورد استفاده در این مطالعه.

دوره تناوب غیر یکنواخت به‌عنوان یک رگرسیون غیرخطی بین متغیر زمان و متغیر سری زمانی و مرحله دوم، تحلیل اتورگرسیون خطی جمله باقی‌مانده خطا است (عمریشیخ، ۲۰۰۶). در این روش مضارب معادله رگرسیون غیرخطی با استفاده از داده‌های سری زمانی متغیر موردنظر در دوره گذشته حاصل می‌شود. از ویژگی‌های این ماشین حافظه کوتاه‌مدت آن است. یعنی یادگیری ماشین به نوع کل رفتار داده‌های متغیر مورد نظر وابسته نیست بلکه به رفتار بازه سمت چپ نزدیک به رخداد مرجع وابسته است. جزئیات مباحث نظری پیاده‌سازی ماشین تعقیب‌کننده در مرجع (کرایمر، ۲۰۰۲) آمده است

تفاوت بین مقادیر برون‌داد مدل و مشاهده‌شده در محل ایستگاه‌ها طی دوره آموزش (Train)، (۳۰۰ روز ابتدای سری زمانی داده‌های دمای بیشینه و کمینه) به‌عنوان خطای برون‌داد مدل فرض شد. حال فرض کنید $\{x_t\}_{t \in \text{Train}}$ سری زمانی از این خطاها باشد. به‌عبارتی سری زمانی خطاها، متغیر مورد نظر در تحلیل‌های ماشین تعقیب‌کننده است. در ادامه با ماشین تعقیب‌کننده و استفاده از سری زمانی خطاها، خطای مدل در پیش‌بینی‌ها برآورد شده که مبنای تصحیح خطای پیش‌بینی‌های کوتاه‌مدت مدل است. می‌توان سری زمانی خطاها x_t در دوره آموزش (Train) را به‌صورت زیر بیان کرد (کرایمر، ۲۰۰۲).

$$x_t = \sum_{n=1}^{41} a_n \phi_n(\alpha_n(t)) + \gamma \epsilon_t \quad t \in \text{Train} \quad (1)$$

که در آن $\phi_n(\alpha_n(t))$ یک دنباله از توابع پایه‌ای تقریب‌زننده روی دامنه زمانی Train (دوره آموزش) است. $\alpha_n(t) = A_n t^2 + B_n t + C_n e^{-D_n (\frac{t}{T})^2}$ به‌عنوان لایه پنهان ماشین در نظر گرفته شد. a_n, A_n, B_n, C_n, D_n و γ ضرایب حقیقی هستند که با استفاده از روش کمترین مربعات خطا طی دوره آموزش برآورد می‌شوند. T برابر با مقدار ثابت ۳۶۵ در نظر گرفته شد. ϵ_t خطای باقی‌مانده است. ϵ_t یک سری زمانی ایستا با توزیع نرمال استاندارد است که با یک رابطه اتورگرسیون خطی به‌صورت زیر به‌دست می‌آید (کرایمر، ۲۰۰۲).

۲-۲. خروجی مدل WRF

در این مطالعه از خروجی مدل WRF که توسط سازمان هواشناسی کشور به‌صورت روزانه اجرا می‌شود، استفاده شد. مدل شامل دو دامنه تو در تو با تفکیک افقی دامنه بزرگ‌تر ۲۷ کیلومتر و دامنه کوچک‌تر ۹ کیلومتر است. خروجی‌های اجرای مدل WRF استفاده‌شده در این مطالعه که توسط سازمان هواشناسی کشور به‌صورت روزانه به‌دست می‌آید، توسط سایر محققین نیز در سطح کشور مورد استفاده قرار گرفته است (محمدی و همکاران، ۲۰۱۷؛ آزادی و همکاران، ۱۳۹۰، شکوهی و همکاران، ۱۴۰۱).

۲-۳. استخراج پیش‌بینی کوتاه‌مدت بیشینه و کمینه دمای مدل

مدل به‌صورت روزانه در ساعت ۱۲ UTC اجرا، و بازه زمانی پیش‌بینی آن ۱۲۰ ساعته بوده است. به‌منظور تصحیح خطای پیش‌بینی‌های کوتاه‌مدت یک، دو و سه روزه (پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته) دمای کمینه، این پیش‌بینی‌ها برای هرروز در دوره ۲۰۲۰/۱۱/۱ الی ۲۰۲۳/۳/۵ از برون‌داد مدل استخراج شد. در این مطالعه منظور از پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته، به‌ترتیب پیش‌بینی روز بعد، دو و سه روز بعد از، روز اجرای مدل است. به‌عنوان مثال منظور از پیش‌بینی ۲۴ ساعته، پیش‌بینی اولین روز بعد از روز اجرای مدل است. به‌منظور استخراج پیش‌بینی دمای بیشینه و کمینه برای هر روز از خروجی مدل، به‌ترتیب حداکثر و حداقل دمای پیش‌بینی‌شده، از پیش‌بینی‌های ساعتی استخراج شده و به‌عنوان دمای بیشینه و کمینه برای آن روز لحاظ می‌شود.

۲-۴. ماشین تعقیب‌کننده

ماشین تعقیب‌کننده با روش کمترین مربعات طیفی شبه‌فوریه-سری زمانی (Least square spectral pseudo-Fourier-time series method) در این مطالعه شامل دو مرحله است. مرحله اول، شامل استفاده از توابع مثلثاتی با

۵-۲. ارزیابی روش تصحیح خطای پیش‌بینی روش

نمره مهارت SS (Skill Score) شاخصی برای ارزیابی تطابق خصوصیات متغیر نرمال Y نسبت به متغیر نرمال X است. هر چه از لحاظ شباهت گشتاورهای اول و دوم این دو متغیر منطبق باشند و همبستگی بین آنها بیشتر باشد دو متغیر دارای جامعه آماری نزدیک‌تری هستند. مقدار این اندازه مقیاس از لحاظ ریاضی به صورت زیر محاسبه می‌شود

$$SS = \rho_{X,Y}^2 - \left(\rho_{X,Y} - \frac{\sigma_Y}{\sigma_X} \right)^2 - \left(\frac{\mu_Y - \mu_X}{\sigma_X} \right)^2 \quad (۷)$$

که از بالا به ۱ محدود است و زمانی اتفاق می‌افتد که $Y = X$ وابسته خطی باشد.

۶-۲. اطمینان‌پذیری به نتایج پیش‌بینی مدل و ماشین

صحت‌سنجی عملکرد یک سیستم به‌طور عمومی باید شامل دو مؤلفه پایداری در ارائه خروجی و اطمینان‌پذیری (Reliability) حاصل از عملکرد نسبتاً یکنواخت سیستم محاسباتی باشد (کومار و همکاران، ۲۰۰۰). مؤلفه اطمینان‌پذیری سبب یک اطمینان خاطر و دوری از ریسک پذیرش نتایج خروجی یک سیستم محاسباتی خواهد بود (کومار و رام، ۲۰۲۱). برای به‌دست آوردن میانگین اطمینان‌پذیری خطای پیش‌بینی مدل و مدل اصلاح‌شده نسبت به مشاهدات اصلی برای دمای (کمینه و بیشینه) روزانه از معادله (کومار و رام، ۲۰۲۱)

$$Rlb(e^*) = \frac{b-e^*}{b-a} \quad (۸)$$

استفاده می‌شود که در آن b حداکثر خطاها (حداکثر خطای پیش‌بینی مدل یا مدل اصلاح‌شده) و a حداقل خطاها (حداقل خطای پیش‌بینی مدل یا مدل اصلاح‌شده) و e^* میانگین خطاها (میانگین خطای پیش‌بینی مدل یا مدل اصلاح‌شده) است.

۳. نتایج و بحث

با توجه به ساختار داده‌های مورد استفاده در پیاده‌سازی ماشین تعقیب‌کننده، ۱۰ ماه پایانی دوره آماری به‌عنوان دوره آزمون در نظر گرفته شد. مقایسه بین انحراف معیار،

$$\epsilon_t = b_1 \epsilon_{t-1} + \dots + b_k \epsilon_{t-k} + C' z_t \quad (۲)$$

در اینجا منظور از z_t یک متغیر تصادفی نرمال استاندارد، مستقل از زمان است. توابع پایه‌ای $\Phi_n(\alpha_n(t))$ به صورت زیر تعریف شد

$$\phi_n(\alpha_n(t)) = \begin{cases} 1 & n = 1 \\ \sin\left(\frac{2\pi n \alpha_n(t)}{T}\right) & 2 \leq n \leq 11 \\ \cos\left(\frac{2\pi(n-11)\alpha_n(t)}{T}\right) & 12 \leq n \leq 21 \\ \sin\left(\frac{2\pi t \alpha_n(t)}{T(n-21)}\right) & 22 \leq n \leq 31 \\ \cos\left(\frac{2\pi \alpha_n(t)}{T(n-31)}\right) & 32 \leq n \leq 41 \end{cases} \quad (۳)$$

پس از محاسبه ضرایب حقیقی لایه پنهان A_n ، B_n ، C_n و D_n در دوره آموزش می‌توان از رابطه (۱) برای برآورد خطای پیش‌بینی مدل در دوره آزمون (۳۰۰ روز پس از دوره آموزش) استفاده کرد. حال برای روز $t+1$ در دوره آزمون، یک پیش‌بینی از خطای ۲۴، ۴۸ و ۷۲ ساعته مدل با استفاده از رابطه (۱) برآورد می‌شود. از آنجاکه ضرایب a_n برای دوره آزمون در رابطه (۱) مجهول هستند، با استفاده از داده‌های ۱۰۰ روز قبل روز $t+1$ ام $(t, t-1, \dots, t-99)$ به صورت زیر به دست می‌آیند.

$$a = (\Phi' \Phi)^{-1} \Phi' X \quad (۴)$$

که در آن Φ ماتریس ضرایب حاصل از رابطه (۱) است و Φ' ماتریس ترانزپوز Φ و a بردار ضرایب a_n و X بردار خطاهای مدل در ۱۰۰ روز قبل است. با قراردادن مقدار متغیر $t+1$ در معادله (۱) پیش‌بینی خطای مدل در زمان $t+1$ برآورد می‌شود.

متوسط کل خطاها طی دوره آماری و برای تمام ایستگاه‌ها، \bar{E} به صورت زیر بیان شد

$$\bar{E} = \frac{\sum_{i=1}^n E_i}{n} \quad (۵)$$

که در آن n تعداد روز و E_i متوسط خطای تمام ایستگاه‌ها در روز i ام است که به شکل زیر است

$$E_i = \frac{\sum_{k=1}^K e_{ki}}{K} \quad (۶)$$

که در آن e_{ki} خطای ایستگاه k ام در روز i ام، و K تعداد ایستگاه‌ها است.


مهارت بسیار کمتر و به یک نزدیک‌تر می‌شود. دامنه تغییرات فشرده‌تر نمره مهارت برای مدل اصلاح‌شده نشان‌دهنده یکنواخت‌تر شدن پیش‌بینی و کاهش تأثیر عوامل جغرافیایی، محلی و فصلی بر برون‌داد مدل اصلاح‌شده می‌باشد. در شکل ۳-ب نمودار جعبه‌ای نمره مهارت فقط برای مدل اصلاح‌شده با جزئیات بیشتری آورده شده است. مشهود است که میانه نمره مهارت پس از تصحیح از حدود $0/1$ - به بیش از $0/85$ افزایش یافته است (شکل ۳-ب).

شکل ۴، نمودار جعبه‌ای نمره مهارت پیش‌بینی 24 ، 48 و 72 ساعته دمای کمینه مدل و مدل اصلاح‌شده جهت مقایسه تأثیر تصحیح مدل با استفاده ماشین تعقیب‌کننده نشان داده شده است. روش اصلاح خطا برای دمای کمینه بردامنه تغییرات و میانه نمره مهارت به‌طور محسوسی مؤثر بوده است به‌عنوان مثال دامنه تغییرات نمره مهارت 24 ساعته مدل که بین $0/1$ الی $0/7$ بوده را برای اصلاح برون‌داد مدل به دامنه $0/5$ الی $0/9$ تغییر یافته است (شکل ۴-الف). میانه جامعه نمره مهارت ایستگاهی از $0/4$ به بیش از $0/7$ افزایش داشته است که به معنی افزایش دقت پیش‌بینی پس از تصحیح در کل ایستگاه‌های کشور است. شکل ۴-ب نشان‌دهنده جزئیات تغییرات دامنه و میانه نمره مهارت پس از اصلاح برون‌داد مدل است.

همبستگی و RMSE پیش‌بینی‌های 24 ، 48 و 72 ساعته دمای کمینه و دمای بیشینه مدل WRF و مدل اصلاح‌شده (Corr WRF) با داده‌های مشاهده‌شده در نمودار تیلور شکل ۲ نشان داده شده است. در شکل ۲-الف برای دمای بیشینه، ضریب همبستگی پس از اصلاح برون‌داد مدل از $0/9$ به حدود $0/99$ ، انحراف معیار از حدود $9/5$ به $10/1$ درجه سلسیوس افزایش و مقدار خطا (RMSE) نیز کاهش داشته است که در نهایت سبب شده پیش‌بینی‌های مدل به مشاهدات نزدیک‌تر شوند (شکل ۲-الف). برای دمای کمینه، ضریب همبستگی پس از اصلاح خطای مدل از حدود $0/85$ به $0/95$ ، انحراف معیار از حدود $8/4$ به $7/7$ درجه سلسیوس رسیده و مقدار خطا (RMSE) نیز کاهش داشته است که در نهایت سبب نزدیک‌تر شدن پیش‌بینی‌های مدل به مشاهدات شده است. مقایسه پیش‌بینی دمای بیشینه و کمینه اصلاح‌شده با مدل، نشان از عملکرد مؤثرتر روش تصحیح خطا در بهبود پیش‌بینی‌های دمای بیشینه نسبت به دمای کمینه است.

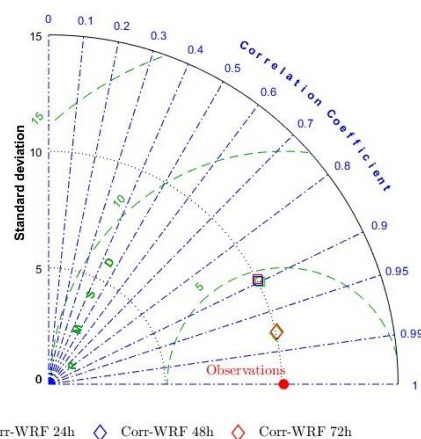
نمودار جعبه‌ای نمره مهارت مدل WRF به‌همراه مدل اصلاح‌شده (Corr WRF) برای پیش‌بینی‌های 24 ، 48 و 72 ساعته دمای بیشینه در شکل ۳ نشان داده شده است. نتایج نشان می‌دهد در تمام پیش‌بینی‌های، تصحیح مدل سبب افزایش مقدار نمره مهارت شده است (شکل ۳-الف). پس از تصحیح خطای مدل، دامنه تغییرات نمره

Taylor diagram for daily min temp via WRF, Corr-WRF



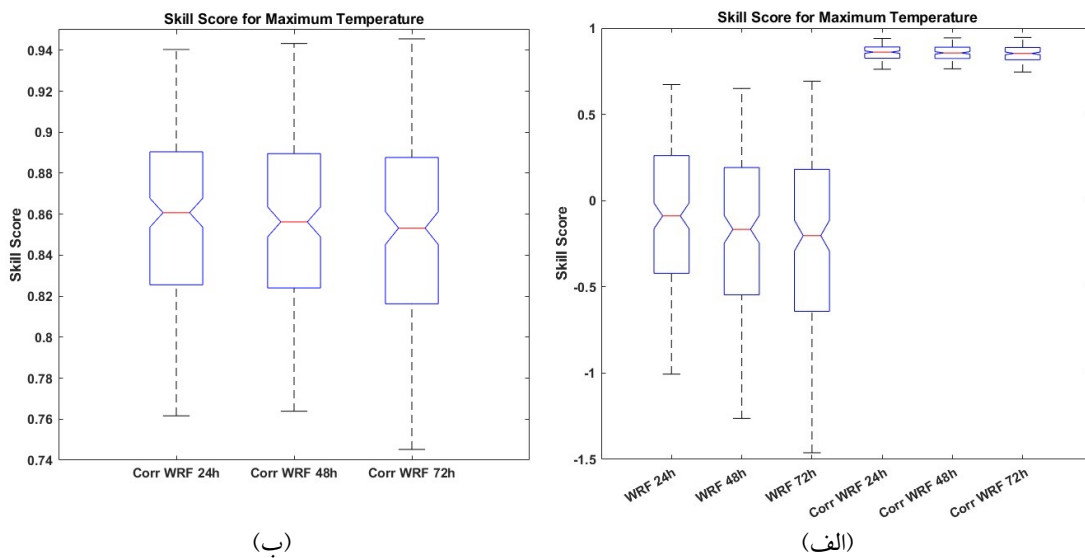
(ب)

Taylor diagram for daily max temp via WRF, Corr-WRF

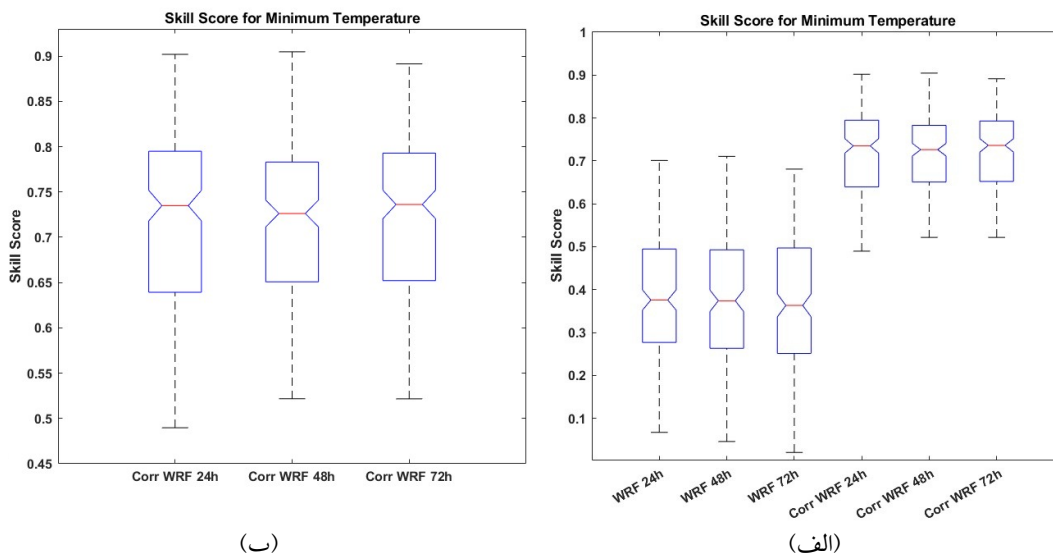


(الف)

شکل ۲. نمودار تیلور، برای مقایسه پیش‌بینی‌های 24 ، 48 و 72 ساعته (24h, 48h, 72h) مدل WRF و مدل اصلاح‌شده (Corr WRF) با مشاهدات (Observations) برای، الف) دمای بیشینه و ب) دمای کمینه.



شکل ۳. نمودار جعبه‌ای نمره مهارت برای پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای بیشینه، الف) مدل WRF به همراه مدل اصلاح‌شده (Corr WRF)، ب) مدل اصلاح‌شده (Corr WRF).



شکل ۴. نمودار جعبه‌ای نمره مهارت برای پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه، الف) مدل WRF به همراه مدل اصلاح‌شده (Corr WRF)، ب) مدل اصلاح‌شده (Corr WRF).


مدل WRF). با شروع فصول سرد سال، نمره مهارت ماهانه پیش‌بینی‌های دمای بیشینه مدل با یک تغییر، روند افزایشی به خود گرفته و تا ۰/۳ افزایش می‌یابد (شکل ۵، مدل WRF). در هر سه نمودار شکل ۵ روند تغییرات نمره مهارت مدل اصلاح‌شده (Corr WRF) بیش از ۰/۸ و بر خلاف مدل از یک پایایی و ثبات در پیش‌بینی بدون توجه به روند تغییر فصول برخوردار بوده است (شکل ۵). این پایداری در صدور پیش‌بینی نسبت به مدل حاکی از قابل

میان ماهانه نمره مهارت پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای بیشینه برای مدل WRF و مدل اصلاح‌شده (Corr WRF) در شکل ۵ نشان داده شده است. نمره مهارت پیش‌بینی‌های دمای بیشینه مدل بین ماه‌های متوالی مارس الی سپتامبر با گرم‌تر شدن هوا یک روند نزولی و کاهشی از ۰/۳ تا -۱ را نشان می‌دهد تا این که در ماه سپتامبر با فروکش کردن گرمای هوا و آغاز فصول سرد سال دچار یک اختلال در پیش‌بینی دمای بیشینه می‌شود (شکل ۵،


پیش‌بینی مشاهده می‌شود. نمره مهارت پیش‌بینی‌های مدل اصلاح‌شده برای دمای کمینه نسبت به مدل از تغییرپذیری کمتری برخوردار است و به‌جز ماه مارس و آوریل از یکنواختی و ثبات در نمره مهارت ماهانه برخوردار است. به‌طور کلی می‌توان گفت نمره مهارت پیش‌بینی مدل WRF در فصل تابستان (ماه‌های جولای، آگوست و سپتامبر) برای دمای بیشینه و کمینه نسبت به سایر فصول کمتر است (شکل ۵ و ۶). مطالعات دیویس و بوسارت (۲۰۰۲) نشان می‌دهد که این ممکن است به خطای سیستماتیک طرح پارامترسازی کومولوس مرتبط باشد.

اطمینان‌پذیرتر بودن اصلاح برونداد مدل نسبت به پیش‌بینی‌های خام مدل است.

میان‌ماهانه نمره مهارت پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه برای مدل WRF و مدل اصلاح‌شده (Corr WRF) در شکل ۶ نشان داده شده است. نمره مهارت ماهانه مدل دارای یک روند نوسانی با دامنه تغییرات بین ۰/۲ الی ۰/۴ است. مشابه شکل ۵، یک روند نزولی را با افزایش دمای هوا بین ماه‌های مارس تا جولای مشاهده می‌کنیم. از ماه آگوست تا نوامبر یک روند افزایشی را در نمره مهارت از ۰/۲ به ۰/۴ مشاهده می‌شود. در ماه دسامبر یک جهش کاهشی در نمره مهارت



شکل ۵. میان‌ماهانه نمره مهارت پیش‌بینی دمای بیشینه برای مدل WRF (خطوط آبی‌رنگ) و مدل اصلاح‌شده (Corr WRF خطوط سبزرنگ) برای پیش‌بینی ۲۴ ساعته (24h)، پیش‌بینی ۴۸ ساعته (48h) و پیش‌بینی ۷۲ ساعته (72h).



شکل ۶. میان‌ماهانه نمره مهارت پیش‌بینی دمای کمینه برای مدل WRF (خطوط آبی‌رنگ) و مدل اصلاح‌شده (Corr WRF خطوط سبزرنگ) برای پیش‌بینی ۲۴ ساعته (24h)، پیش‌بینی ۴۸ ساعته (48h) و پیش‌بینی ۷۲ ساعته (72h).

۲/۲ درجه سلسیوس رسیده و این موضوع در افزایش نمره مهارت مدل اصلاح شده نسبت به مدل از ۰/۰۴- به ۰/۸۵ تطابق دارد (جدول ۱ و ۲). افزایش نمره مهارت پیش‌بینی ۲۴، ۴۸ و ۷۲ ساعته کمینه دما برای مدل اصلاح شده نسبت به مدل از ۰/۳۸ به بالای ۰/۷ کاملاً مشهود است (جدول ۱). نتایج نشان داد میانگین واریانس خطا برای پیش‌بینی دمای بیشینه و کمینه پس از تصحیح خطا به‌طور قابل توجهی کاهش می‌یابد (جدول ۲). اگرچه مقدار RMSE برای پیش‌بینی‌های دمای کمینه پس از اصلاح خطا تقریباً از ۴/۵ درجه به ۳ درجه کاهش می‌یابد اما این مقدار خطا نسبت به دمای بیشینه بیشتر است. علت کاوی این مسئله در نحوه توزیع مکانی میانگین خطای مدل و اصلاح برون‌داد مدل ریشه دارد که در ادامه توضیح داده می‌شود. شکوهی و همکاران (۱۴۰۱)، با استفاده از روش تصحیح خطای تعمیم میانگین خطای ۵ روزه نشان دادند که میانه نمره مهارت مدل WRF در پیش‌بینی‌های دمای کمینه و بیشینه پس از تصحیح خطا به ترتیب به ۰/۵۳ و ۰/۷۳ می‌رسد. در حالی که در این مطالعه میانه نمره مهارت مدل WRF در پیش‌بینی‌های دمای کمینه و بیشینه پس از تصحیح خطا به ترتیب به ۰/۷۳ و ۰/۸۵ رسیده است. بنابراین می‌توان گفت ماشین تعقیب‌کننده نسبت به روش‌های تعمیم میانگین خطا، عملکرد بهتری در اصلاح خطای پیش‌بینی‌های مدل داشته است.

میانه و میانگین نمره مهارت و همچنین میانگین، خطا، واریانس خطا و RMSE پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای بیشینه و کمینه مدل و مدل اصلاح شده (Corr WRF) در جدول ۱ و ۲ آورده شده است. میانه و میانگین نمره مهارت مدل برای پیش‌بینی‌های دمای بیشینه دارای مقادیر منفی و کمتر از ۰/۰۴- هستند. میانه و میانگین نمره مهارت مدل برای پیش‌بینی‌های دمای کمینه به ترتیب ۰/۳۸ و ۰/۳۳ است. می‌توان گفت مدل WRF در کل دمای کمینه را بهتر از دمای بیشینه پیش‌بینی می‌کند. مقایسه میانگین و میانه RMSE مدل برای دمای بیشینه و کمینه مؤید یک انحراف به راست ناچیز مقادیر است که نشان‌دهنده وجود انحراف خطای زیاد تعداد کمی از داده‌های مدل نسبت به مشاهدات است. تحلیل مشابه با شدت کمتری برای مقادیر نمره مهارت و خطای RMSE برای مدل اصلاح شده برقرار است. نمره مهارت پیش‌بینی‌های دمای بیشینه پس از اصلاح خطای مدل حاکی از افزایش مؤثر مقادیر نمره مهارت و کاهش مقدار RMSE تا ۲ درجه است (جدول ۱ و ۲). ماشین تعقیب‌کننده، پیش‌بینی‌های مدل را برای دوره کوتاه مدت اصلاح کرده و سبب افزایش دقت برون‌داد مدل شده است. ملاحظه می‌شود میانه و میانگین RMSE برای دمای بیشینه از کاهش ۳ برابری خطای برون‌داد مدل حکایت دارد به طوری که RMSE از ۶ درجه سلسیوس به

جدول ۱. میانه و میانگین نمره مهارت پیش‌بینی‌های دمای بیشینه و کمینه برای مدل WRF و مدل اصلاح شده (Corr WRF).

نمره مهارت					
دمای بیشینه		دمای کمینه		دوره پیش‌بینی	
Corr-WRF	WRF	Corr-WRF	WRF		
۰/۸۶	-۰/۰۴	۰/۷۳	۰/۳۸	۲۴ h	میانه
۰/۸۶	-۰/۱۳	۰/۷۳	۰/۳۸	۴۸ h	
۰/۸۵	-۰/۱۴	۰/۷۴	۰/۳۷	۷۲ h	
۰/۸۵	-۰/۰۹	۰/۷	۰/۳۳	۲۴ h	میانگین
۰/۸۵	-۰/۱۸	۰/۷	۰/۳۳	۴۸ h	
۰/۸۴	-۰/۲۲	۰/۷	۰/۳۳	۷۲ h	

جدول ۲. میانگین، خطا، واریانس خطا و RMSE پیش‌بینی‌های دمای بیشینه و کمینه برای قبل و بعد از تصحیح برونداد مدل.

دمای بیشینه						دمای کمینه						دوره پیش‌بینی
RMSE		واریانس خطا		خطا		RMSE		واریانس خطا		خطا		
قبل	بعد	قبل	بعد	قبل	بعد	قبل	بعد	قبل	بعد	قبل	بعد	
۲/۲۲	۶/۰۲	۴/۷۳	۲۰/۱۲	۰/۰۷	-۳/۹۱	۳/۱۶	۴/۶۶	۸/۴۳	۱۹/۵۴	-۰/۱۸	-۰/۸۱	۲۴ h
۲/۲۴	۶/۲۲	۴/۷۳	۲۰/۵۷	۰/۲۹	-۴/۱۴	۳/۱۸	۴/۷	۸/۵۶	۱۹/۵۸	۰/۰۹	-۱/۰۷	۴۸ h
۲/۲۸	۶/۳۲	۴/۸۳	۲۱/۰۱	۰/۳۹	-۴/۲۴	۳/۱۶	۴/۷	۸/۴۱	۱۹/۵۰	۰/۱۴	-۱/۱۶	۷۲ h

دقت پیش‌بینی مدل و کاهش RMSE از مقادیر بیش از ۴/۵ درجه سلسیوس به کمتر از ۲/۵ درجه سلسیوس بوده است. می‌توان گفت در مناطقی که خطای پیش‌بینی مدل بسیار زیاد بوده مانند نواحی شمالی و شرقی خوزستان تا استان کهگیلویه و بویراحمد که خطای مدل بیش از ۱۰ درجه است، روش تصحیح خطا به خوبی توانسته خطا را به طرز چشم‌گیری کاهش داده و پیش‌بینی یکنواخت با تغییرپذیری کمتری ارائه دهد (شکل ۷). نصر اصفهانی و همکاران (۱۳۹۸) بیان کردند خطای متوسط مدل WRF برای پیش‌بینی دما در حوزه زاینده‌رود در محدوده ۲ تا ۳ درجه است. پيله‌وران و اکبری (۱۳۹۷) نشان دادند متوسط خطای پیش‌بینی دمای بیشینه و کمینه مدل WRF در استان لرستان بیش از ۳ درجه است. افشاری (۱۳۹۳) ذکر کرد که پیش‌بینی دمایی مدل WRF بر روی ایران می‌تواند در برخی مناطق به ۱۲ درجه برسد. مقدار خطای متوسط مدل WRF برای پیش‌بینی دما در این مطالعه با تحقیقات انجام‌شده در مناطق مختلف کشور در یک حد بوده‌اند.

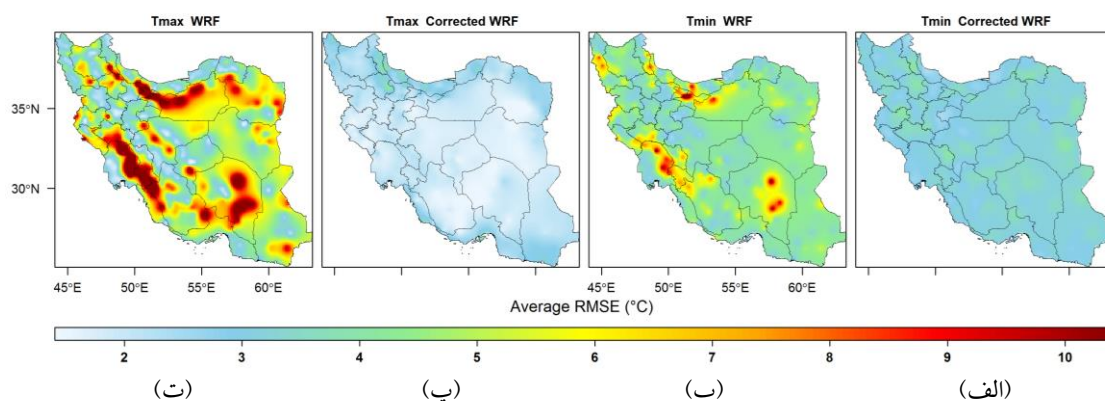
توزیع مکانی طبقات میانگین خطای پیش‌بینی‌های کوتاه‌مدت دمای بیشینه و کمینه برای مدل WRF و مدل اصلاح‌شده (Corrected WRF) در شکل ۸ نشان داده شده است. در مناطق با خطای بیشتر (نواحی سه‌گانه اشاره‌شده)، خطای پیش‌بینی‌های کوتاه‌مدت دمای بیشینه و کمینه برای مدل WRF کمتر از ۸- درجه سلسیوس است (شکل ۸). پهنه‌بندی میانگین خطای طی دوره آماری مورد مطالعه برای دمای کمینه نسبت به دمای بیشینه

توزیع مکانی میانگین RMSE پیش‌بینی‌های کوتاه‌مدت دمای بیشینه و کمینه برای مدل WRF و مدل اصلاح‌شده (Corrected WRF) در شکل ۷ نشان داده شده است. یکی از عوامل مؤثر بر برونداد مدل برای پیش‌بینی دمای بیشینه و کمینه، الگوی توزیع ناهمواری‌های ایران (شکل ۱-الف) است. خطای مدل برای پیش‌بینی دمای بیشینه و کمینه در سه منطقه نسبت به سایر مناطق بیشتر است (شکل ۷). این مناطق شامل نواحی زاگرس جنوبی در مجاورت به ارتفاعات دنا، زرد کوه، اشترانکوه و شمال خوزستان، نواحی جنوبی رشته کوه البرز و نواحی مجاور به کوه‌های لاله‌زار و هزار در استان کرمان است (شکل ۷). در این مناطق گرادیان ارتفاعی زیاد است به عبارتی نواحی بسیار پست در کنار ارتفاعات قرار گرفته‌اند و این سبب بروز گرادیان ارتفاعی شدیدی در این مناطق شده است که این می‌تواند سبب بروز خطای بیشتر مدل شود. علاوه بر این در نواحی مابین استان تهران و البرز و سمنان به دلیل وجود نواحی صنعتی و تراکم بالای جمعیت، می‌توان گفت وجود جزیره‌های حرارتی، سبب بروز خطا در برونداد مدل می‌شود. در مناطق با خطای بیشتر، خطای پیش‌بینی دمای بیشینه مدل نسبت به دمای کمینه طی دوره مورد مطالعه بیشتر است (شکل ۷). مقایسه پهنه‌بندی میانگین RMSE دمای بیشینه بین مدل و مدل اصلاح‌شده نشان می‌دهد که ماشین تعقیب‌کننده صرف‌نظر از عوارض زمین به‌طور یکنواخت دقت مدل را افزایش داده و RMSE را به زیر ۲/۵ درجه سلسیوس رسانیده است (شکل ۷). بررسی پهنه‌بندی میانگین RMSE برای دمای کمینه بر افزایش

کوتاه‌مدت دمای بیشینه و کمینه برای مدل WRF و مدل اصلاح‌شده (Corrected WRF) در شکل ۹ نشان داده شده است. به‌طور کلی اطمینان‌پذیری به پیش‌بینی دمای کمینه مدل در کشور تقریباً ۷۰ درصد و برای دمای بیشینه چندان مطلوب نبوده و در حدود ۶۰ درصد است (شکل ۹). وخامت الگوی نرخ اطمینان‌پذیری مدل برای دمای بیشینه، همبستگی بالایی با مناطق با خطای بیشتر (نواحی سه‌گانه اشاره‌شده) دارد و کمتر از ۵۰ درصد است (شکل ۹). البته این الگو برای دمای کمینه با شدت کمتری مشهود و در این مناطق کمتر از ۶۰ درصد است (شکل ۹). این در حالی است که اصلاح خطای پیش‌بینی‌های مدل برای دمای کمینه و بیشینه، نرخ اطمینان‌پذیری را تا بیش از ۸۵ درصد در سراسر کشور به‌صورت یکنواخت افزایش داده است (شکل ۹).

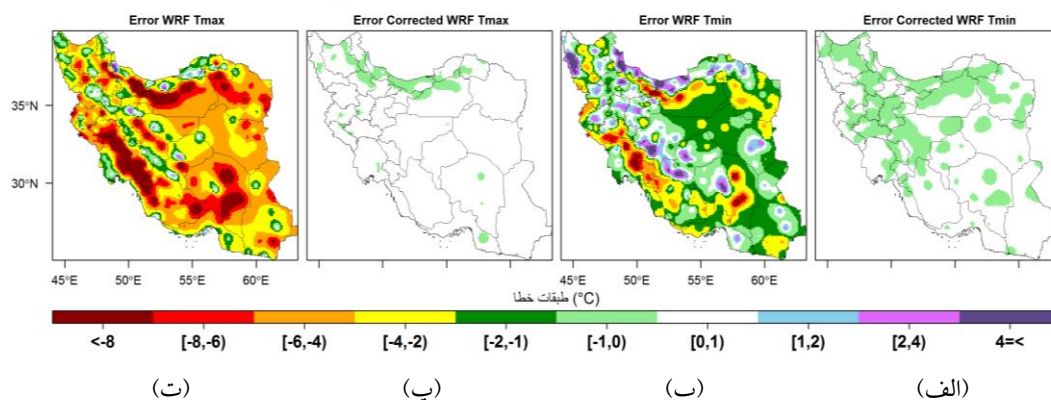
یکنواخت‌تر و از نوسانات کمتری برخوردار است. پهنه‌بندی میانگین خطای مدل اصلاح‌شده برای دمای بیشینه و کمینه با استفاده از ماشین تعقیب‌کننده سبب یکنواخت و کمتر شدن شدن مقادیر خطا بوده است. به‌طور کلی می‌توان گفت، پیش‌بینی‌های کوتاه‌مدت دمای بیشینه و کمینه مدل در اکثر نقاط با کم‌برازشی همراه است، به‌عبارتی مدل دمای بیشینه را کمتر از مقدار رخ داده و دمای کمینه را بیشتر از مقدار رخ داده پیش‌بینی کرده است. از معیار اندازه اطمینان‌پذیری جهت سنجش اطمینان‌پذیری نتایج حاصل از مدل و مدل اصلاح‌شده استفاده شد. اندازه اطمینان‌پذیری نسبتی بین ۰ و ۱۰۰ درصد است که میزان اطمینان به برون‌داد مدل و مدل اصلاح‌شده را اندازه‌گیری می‌کند. توزیع مکانی میانگین اطمینان‌پذیری پیش‌بینی‌های

Average RMSE for short-term forecasts Tmax and Tmin

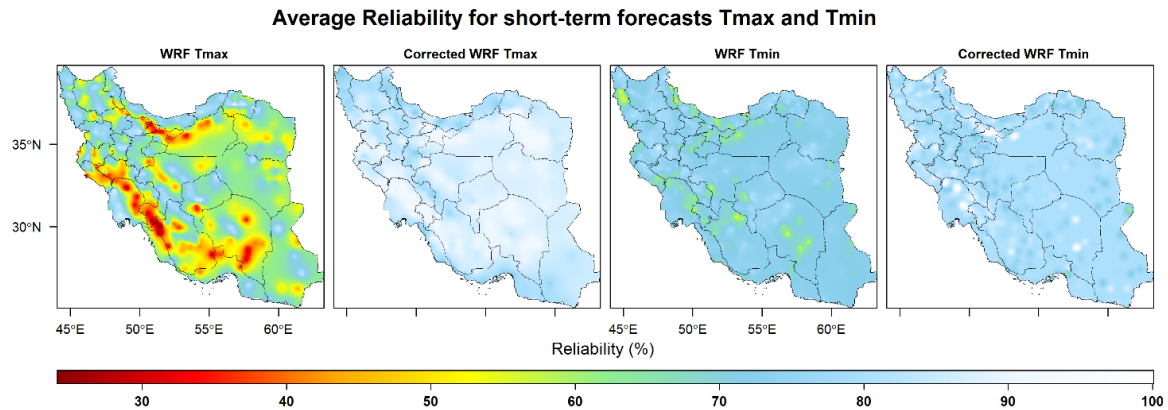


شکل ۷. میانگین RMSE پیش‌بینی‌های کوتاه‌مدت، برای دمای کمینه، الف) مدل اصلاح‌شده (Corrected WRF)، ب) مدل WRF، و برای دمای بیشینه، پ) مدل اصلاح‌شده (Corrected WRF)، ت) مدل WRF.

Average Error for short-term forecasts Tmax and Tmin



شکل ۸. طبقات میانگین خطای پیش‌بینی‌های کوتاه‌مدت، برای دمای کمینه، الف) مدل اصلاح‌شده (Corrected WRF)، ب) مدل WRF، و برای دمای بیشینه، پ) مدل اصلاح‌شده (Corrected WRF)، ت) مدل WRF.



شکل ۹. میانگین اطمینان‌پذیری پیش‌بینی‌های کوتاه‌مدت، برای دمای کمینه، الف) مدل اصلاح‌شده (Corrected WRF)، ب) مدل WRF، و برای دمای بیشینه، پ) مدل اصلاح‌شده (Corrected WRF)، ت) مدل WRF.

کاهش می‌دهد؛ به‌خصوص در مناطق با خطای زیاد که بر کانون‌های جمعیتی، صنعتی و کشاورزی کشور نیز منطبق هستند و سبب تأخیر در مدیریت بحران در این نقاط مهم و حیاتی کشور خواهد شد. اصلاح برونداد مدل تا حدود زیادی این مسئله را مخصوصاً برای پیش‌بینی دمای بیشینه به‌طور مستقیم بهبود بخشیده است. پیشنهاد می‌شود با توجه به یکنواختی اندک بیش‌برازشی در پیش‌بینی دمای کمینه، می‌توان با افزودن یک لایه اصلاحی دیگر جنبه احتیاطی پیش‌بینی دمای کمینه را بیش از این بهبود داد.

مراجع

افشاری، ف. (۱۳۹۳). پیش‌بینی عددی دمای دو متری با استفاده از برونداد مدل WRF بر روی ایران. *پایان نامه کارشناسی ارشد*. به راهنمایی مجید آزادی و پروین غفاریان. دانشگاه هرمزگان، دانشکده علوم پایه.

آزادی، م. و محمدی، س. ع. (۱۳۹۸). پیش‌بینی احتمالاتی دمای کمینه و بیشینه روزانه روی ایران با استفاده از سامانه همادی دو عضوی. *نیوار*، ۴۳، ۴۳-۵۴.

۶۲.

آزادی، م؛ شیرغلامی، م؛ حجام، س. و صحراپیان، ف. (۱۳۹۰). پس‌پردازش برونداد مدل WRF برای بارندگی روزانه در ایران. *مجله تحقیقات منابع آب*، ۷، (۴)، ۷۱-۸۱.

۴. نتیجه‌گیری

ماشین تعقیب‌کننده با به‌کارگیری لایه پنهان، با استفاده از داده‌های خطای پیش‌بینی مدل WRF آموزش داده شد. در ادامه با استفاده از داده‌های دوره آزمون، توانایی ماشین تعقیب‌کننده در کاهش خطای پیش‌بینی مدل مورد ارزیابی قرار گرفت. این پژوهش بر کاهش خطای برونداد مدل WRF با استفاده از پیش‌بینی خطا (خطای پیش‌بینی‌شده) و اعمال آن بر برونداد کوتاه‌مدت مدل متمرکز است. لذا انتظار می‌رود این رویکرد اصلاح برونداد مدل، شامل مزایای مدل هم شود. علاوه بر این، اصلاح برونداد مدل فقط با استفاده از متغیر دمایی، سبب افزایش دقت، کاهش خطا و افزایش اطمینان‌پذیری برونداد مدل پس از اصلاح خطا شده است. نتایج نشان داد روش بیان‌شده در این مطالعه نسبت به روش‌های میانگین لغزان عملکرد بهتری در کاهش خطای برونداد مدل دارد. اصلاح برونداد مدل بدون توجه به فصول، مکان‌های مختلف و جهش‌های دمایی، پیش‌بینی‌های دقیق‌تری نسبت به مدل خام ارائه داده است. از مزایای این روش اصلاح، یکنواختی و کاهش تغییرپذیری و افزایش اطمینان‌پذیری در ارائه پیش‌بینی‌های کوتاه‌مدت دمای بیشینه و کمینه است. کم‌برازشی دمای بیشینه و بیش‌برازشی دمای کمینه یکی از نقاط ضعف مدل است زیرا جنبه احتیاط و هشدار دمایی را که یکی از انگیزه‌های ارائه پیش‌بینی دمای بیشینه و کمینه است را

- آزادی، م.؛ جعفری، س.؛ میرزایی، ا. و عربلی، پ. (۱۳۸۷). پس‌پردازش پرونداد مدل میان مقیاس ۵ MM برای دمای بیشینه و کمینه با استفاده از فیلتر کالمن. *مجله فیزیک زمین و فضا*، ۳۴ (۱)، ۴۵-۶۱.
- پیله وران، ر. و اکبری، ز. (۱۳۹۷). پس‌پردازش پرونداد مدل WRF برای دماهای بیشینه و کمینه در استان لرستان. *نخستین همایش ملی آینده‌نگاری راهبردی در حوزه علوم جغرافیایی و مطالعات شهری- منطقه‌ای*.
- شکوهی، م.؛ اسعدی اسکویی، ا. و محمدپور پنجاه، م. ر. (۱۴۰۱). پس‌پردازش خروجی مدل WRF به روش کوکریجینگ، برای کمیت‌های دمای کمینه و بیشینه بر روی ایران. *مجله فیزیک زمین و فضا*، ۴۸ (۱)، ۲۲۷-۲۴۲.
- قره داغی، ر. و دیندار، ا. (۱۴۰۰). مروری بر تنش گرمایی در جوجه‌های گوشتی و نقش عوامل تغذیه‌ای و افزودنی‌ها در کنترل آن. *علمی-ترویجی (حرفه‌ای) دامستیک*، ۲۱ (۳)، ۲۲-۲۹.
- مرادی، م. و مرتضی‌پور، س. (۱۳۹۷). پس‌پردازش خروجی مدل WRF به روش میانگین لغزان برای دما، دمای نقطه شبنم، دمای بیشینه و دمای کمینه، در ایستگاه هواشناسی فرودگاه رشت. *نشریه هواشناسی و علوم جو*، ۱ (۲)، ۱۹۰-۲۰۲.
- نصراصفهانی، م.؛ یزدان پناه، ح.ا. و نصراصفهانی، م.ع. (۱۳۹۸). ارزیابی مدل WRF برای پیش‌بینی دما و رخداد سرمازدگی در حوضه آبریز زاینده رود. *پژوهشهای جغرافیای طبیعی*، ۵۱ (۱)، ۱۶۳-۱۸۲.
- Abhishek. K., Singh. M., Ghosh. S. & Anand. A. (2012). Weather Forecasting Model using Artificial Neural Network. *Procedia Technol*, 4, 311-318.
- Avery T., Patterson C., & Jacobs, D. J. (2021). Molecular function recognition by supervised projection pursuit machine learning. *Scientific repor*, 4, 42-47.
- Chevalier, R.F., Hoogenboom, G., McClendon, R.W., & Paz J.A. (2010). Support vector regression with reduced training sets for air temperature prediction: A comparison with artificial neural networks. *Neural Comput*, 9, 151-159.
- Craymer, M. (2002). The Least Squares Spectrum, Its Inverse Transform and Autocorrelation Function: Theory and Some Applications in Geodesy. *Ph.D. Dissertation*, University of Toronto, Canada.
- Davis, C., & Bosart, L. F. (2002). Numerical simulations of the genesis of Hurricane Diana (1984). Part II: Sensitivity of track and intensity prediction. *Monthly weather review*, 130(5), 1100-1124.
- Grear, T., Avery, C., Patterson, J., & Jacobs, D. J. (2021). Molecular function recognition by supervised projection pursuit machine learning. *Scientific reports*, 11(1), 4247.
- Gordon. I., Lupo. W. J., Sands-Lincoln. C., George. M., Jackson. J., & Ganguli. D. W. (2020). Machine learning and the pursuit of high-value health care. *NEJM Catalyst Innovations in Care Delivery*.
- Hacker, J. P. and Rife, D. L. (2007). A Practical Approach to Sequential Estimation of Systematic Error on Near-Surface Mesoscale Grids. *Weather and Forecasting*. 22, 1257-1273.
- Kumar A. & Ram M. (2021). The Handbook of Reliability, Maintenance, and System Safety through Mathematical Modeling. *Academic Press*.
- Kumar, U.D., Crocker, J., Knezevic, J., El-Haram, M., Kumar, U.D., Crocker, J., Knezevic, J., & El-Haram, M. (2000). Reliability, Maintenance, and Logistic Support — Introduction. In: Reliability, Maintenance and Logistic Support. *Springer, Boston, MA*. https://doi.org/10.1007/978-1-4615-4655-9_1
- Mellit, A., Pava, A. M., & Benghanem, M. (2011). Least squares support vector machine for short-term prediction of meteorological time series. *Theor. Appl. Climato*, 111.297-307.
- Mohammadi, S. A., Azadi, M., & Rahmani, M. (2017). Comparison of spatial interpolation methods for gridded bias removal in surface temperature forecasts. *Journal of Meteorological Research*, 31, 791-799.
- Omerbashich, M. (2006). Gauss-Vanicek spectral analysis of the Sepkoski compendium: no new life cycles. *Computing in Science & Engineering*, 4, 26-30.
- Ortiz-García, E., Salcedo-Sanz, C. U., Casanova-Mateo, C., Paniagua-Tineo, A., & Portilla-Figuera, J. (2012). Accurate local very short-term temperature prediction based on synoptic situation Support Vector Regression banks. *Atmos*, 107.1-8.

Torrance, C. H., Scheinerman, R. & Yoon, N. (2021). Machine learning in medicine: should the pursuit of enhanced interpretability be abandoned. *Journal of Medical Ethics*, 48(9), 581-585.

Valappil, V. K., Temimi, M., Weston, M.,

Fonseca, R., Nelli, N. R., Thota, M., & Kumar, K. N. (2020). Assessing Bias correction methods in support of operational weather forecast in arid environment. *Asia-Pacific Journal of Atmospheric Sciences*, 56, 333-347.