

پیش‌بینی دمای کمینه و بیشینه روزانه با استفاده از ماشین تعقیب کننده

مجتبی شکوهی^۱، مهدی مصری زاده^۲، ابراهیم اسعدی اسکویی^{۳*}، یاشار فلامرزی^۱

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

^۲ کارشناس پژوهشی، پژوهشگاه هواشناسی و علوم جو، تهران، ایران

تاریخ دریافت: ۱۴۰۰/۱۲/۱۱، تاریخ پذیرش: ۱۴۰۱/۰۳/۱۰

چکیده

پیش‌بینی دمای کمینه و بیشینه روزانه بمنظور کاهش خسارات در زمینه های کشاورزی، آب و دامپروری قابل توجه است. در این پژوهش با استفاده از یادگیری ماشین تعقیب کننده با استفاده از کمترین مربعات خطای طیفی شبه فوریه- سری زمانی، با یک دوره آموزشی ۱۰۰ روزه، دمای کمینه و بیشینه روزانه پیش بینی شد. در این راستا از داده‌های بیش از ۵۰۰ ایستگاه هواشناسی در سراسر کشور در یک دوره دوساله استفاده شد. پیش‌بینی‌های روش یادگیری ماشین با خروجی مدل عددی WRF با یکدیگر و با مشاهدات مقایسه، و توانایی آنها با نمره مهارت ارزیابی شد. نتایج نشان داد که پیاده‌سازی روش الگوریتم یادگیری ماشین در پیش‌بینی های کوتاه مدت موفق بوده و متوسط نمره مهارت بیش از ۰/۶ می باشد. این در حالی است که به طور متوسط نمره مهارت برای مدل WRF تقریباً ۰/۰۱ است. مزیت اصلی این روش نسبت به مدل WRF این است که از پیچیدگی محاسباتی کمتری برخوردار است و در محاسبات فقط از داده‌های ۱۰۰ روز گذشته بهره‌مند می‌شود. مزیت دیگر این روش استفاده از یک الگوریتم یادگیری ماشین با حافظه کوتاه مدت است که تاثیر نامطلوب فقدان طولانی مدت داده‌ها در سری زمانی دوره آموزش را بر خروجی پیش‌بینی ها کاهش می‌دهد. در این روش با هزینه محاسباتی کمتر و در زمانی بسیار کوتاه می‌توان، پیش‌بینی های کوتاه مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای کمینه و بیشینه را برای سراسر نقاط ایستگاهی کشور با دقت مناسبی ارائه داد.

کلمات کلیدی: خطای طیفی، سری زمانی، مدل WRF، نمره مهارت، یادگیری ماشین.

پیش‌بینی‌های هواشناسی از لحاظ طول مدت زمان پیش‌بینی به سه دسته، کوتاه، متوسط و بلند مدت تقسیم می‌شوند. پیش‌بینی‌های کوتاه مدت حداکثر تا دو هفته در نظر گرفته می‌شوند. این دسته از پیش‌بینی‌ها به دلیل نوع مخاطرات آب و هوایی مانند سیل، توفان‌های تندری، رعد و برق و غیره مورد توجه مدیران و دستگاه‌های امدادی جهت مدیریت فوری بلایا و عواقب رخدادها هستند. پدیده‌هایی که بر وضع آب و هوایی فصلی یا سالانه و حتی دوره‌های بیشتر تاثیر دارند مانند تغییرات نزولات آسمانی، دمای هوا و غیره بر سکونتگاه‌های انسانی اثرات عمیقی دارند و جز پدیده‌های طول مدت یا اقلیمی دسته‌بندی می‌شود (عساکره، ۱۳۹۸). پیش‌بینی این مخاطرات تحت تاثیر عدم فوریت و تاثیر عمیق بر زندگی جوامع بشری مورد توجه و بر سیاست‌های کلان توسعه کشاورزی، اقتصادی و توسعه شهری مد نظر قرار می‌گیرند. دسته دیگری از پدیده‌ها، میان مدت هستند و بازه زمانی بین دو هفته تا کمتر از یک فصل را شامل می‌شوند. از لحاظ فوریت نسبت به پدیده‌های کوتاه مدت از فوریت کمتری برخوردارند و حتی از لحاظ شدت تاثیر بر جوامع با تاثیر کمتری نسبت به پدیده‌های اقلیمی هستند. می‌توان این نوع پدیده‌ها را بنا به انتظار رخداد و شدت آن جز پدیده‌های اقلیمی یا کوتاه مدت دسته‌بندی کرد (عساکره، ۱۳۹۸).

مدل WRF¹ یک مدل عددی جهت پیش‌بینی پدیده‌های هواشناسی است که با مفروضات عددی به عنوان مقادیر اولیه و مرزی مدل آن قابل اجرا است و نتایج حاصل شده به عنوان خروجی پیش‌بینی کوتاه مدت و اقلیمی قابل استفاده است. ناهموازی‌های 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، ۱۳۹۸). از این رو محققین بسیاری با روش‌های آماری و محاسباتی سعی در تصحیح خطای پیش‌بینی‌های مدل برای پدیده‌های کوتاه مدت داشته‌اند. آزادی و همکارانش (۱۳۹۸) پیش‌بینی احتمالاتی دماهای کمینه و بیشینه روزانه نقاط ایستگاهی ایران را ارائه داده‌اند. آنها برای کمی کردن عدم

قطعیت در پیش‌بینی وضع هوا و صدور پیش‌بینی احتمالاتی دماهای کمینه و بیشینه روزانه یک تا پنج روزه مدل WRF ایستگاه‌های همدیدی مراکز استان‌های کشور، با دو روش آماری موسوم به آماره برون‌داد مدل (EMOS) و مدل میانگین‌گیری بیزی (BMA) برای برآورد تابع چگالی احتمال پیش‌بینی استفاده کرده‌اند. علت بررسی احتمالاتی دمای هوای کمینه و روزانه، ماهیت آشوبناکی جو است که انتظار می‌رود که با تغییر جزئی مقادیر شرایط مرزی و آغازین، نتایج مدل تغییرات زیادی داشته باشد. بنابراین در پژوهش آزادی و همکاران (۱۳۹۸) برای برآورد تابع چگالی احتمال پیش‌بینی دماهای کمینه و بیشینه روزانه از دو روش آماری EMOS و BMA استفاده شده است. منگ و همکاران (۲۰۲۲) از مدل ترکیبی سری زمانی ARMA-GARCH، برای بدست آوردن پارامترهای توزیع نرمال (میانگین و واریانس) دمای کمینه و بیشینه بهره برده‌اند. در این فرآیند پارامترهای توزیع در دو مدل سری زمانی (برای میانگین مدل ARMA و برای واریانس GARCH) را در نظر گرفته شدند. آنها از کار خود دو هدف عمده را دنبال نمودند، اول آنکه، یک مدل مناسب سری زمانی برای کمینه و بیشینه دما پیدا کنند. هدف دوم جواب دادن به این سوال که آیا مدل سری زمانی مورد نظر می‌تواند از پیش‌بینی مدل ریاضی NWP دقیق‌تر باشد؟ نتایج بدست آمده توسط آنها نشان داد در بیشتر روزهای دوره آماری مورد مطالعه نتایج به طور محسوسی در نقاط جهش دمایی بهبود قابل توجهی داشته است.

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 به طور گسترده‌ای در پیش‌بینی دمای روزانه استفاده شده است (آبهیشک و همکاران، ۲۰۱۲-چوالیر و همکاران، ۲۰۱۰). بیشترین مدل شبکه‌های عصبی که برای پیش‌بینی دما مورد استفاده قرار گرفته می‌توان به مدل‌های پرسپترون چندلایه (Multilayer Perceptron Neural Networks) (اوتیزگارسیا و همکاران، ۲۰۱۲) و شبکه عصبی توابع شعاعی (Radial Basis Function Neural Networks) (عساکره، ۱۳۹۸)

1 Weather Research and Forecasting, WRF

و ۷۲ ساعته دمای کمینه و بیشینه برای تمام نقاط ایستگاه های هواشناسی کشور است.

مواد و روش‌ها

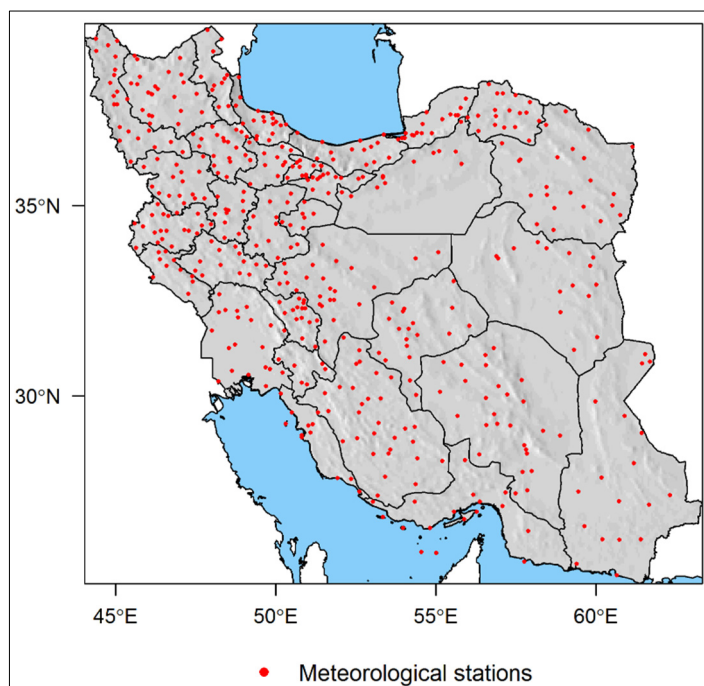
ایران به علت موقعیت خاص و ویژگی های کوهساری، از آب و هوایی متفاوت برخوردار است. آب و هوای خشک و نیمه خشک بیشتر مناطق کشور را پوشش می دهد. داده های مشاهده شده دمای کمینه و بیشینه روزانه برای کلیه ایستگاه های هواشناسی سطح کشور (همدی، اقلیم شناسی) برای دوره یکم نوامبر سال ۲۰۲۰ الی پنجم مارس سال ۲۰۲۳ تهیه شده است. تعداد کل این ایستگاه ها بیش از ۵۰۰ عدد می باشد که در شکل ۱ موقعیت مکانی آنها نشان داده شده است.

در این مطالعه از خروجی مدل WRF که توسط سازمان هواشناسی کشور به صورت روزانه اجرا می شود، استفاده شد. مدل شامل دو دامنه تو در تو با تفکیک افقی دامنه بزرگتر ۲۷ کیلومتر و دامنه کوچکتر ۹ کیلومتر است. خروجی های اجرای مدل WRF استفاده شده در این مطالعه که توسط سازمان هواشناسی کشور به صورت روزانه بدست می آید، توسط سایر محققین نیز در سطح کشور مورد استفاده قرار گرفته است (محمدی، ۲۰۱۷-آزادی، ۱۳۹۰).

مدل به صورت روزانه در ساعت UTC ۱۲ اجرا، و بازه زمانی پیش بینی آن ۱۲۰ ساعته بوده است. به منظور تصحیح خطای پیش بینی های کوتاه مدت یک، دو و سه روزه (پیش بینی های ۲۴، ۴۸، و ۷۲ ساعته) دمای کمینه، این پیش بینی ها برای هرروز در دوره یکم نوامبر سال ۲۰۲۰ الی پنجم مارس سال ۲۰۲۳، از برون داد مدل استخراج شد. در این مطالعه منظور از پیش بینی های ۲۴، ۴۸، و ۷۲ ساعته، به ترتیب پیش بینی روز بعد، دو و سه روز بعد از، روز اجرای مدل است. به عنوان مثال منظور از پیش بینی ۲۴ ساعته، پیش بینی اولین روز بعد از روز اجرای مدل است. به منظور استخراج پیش بینی دمای بیشینه و کمینه برای هر روز از خروجی مدل، به ترتیب حداکثر و حداقل دمای پیش بینی شده، از پیش بینی های ساعتی (با گام زمانی یک ساعته) استخراج شده و به عنوان دمای بیشینه و کمینه برای آن روز لحاظ می شود

نام برد (لانزا و همکاران، ۲۰۰۱). پژوهش میانوو و همکاران (۱۹۹۴) با به کارگیری روش پرسپترون چند لایه با گرادیان کاهشی تصادفی، برای داده های دمایی بین سال های ۱۹۸۶-۱۹۰۶ بررسی شد و بر اساس نتایج بدست آمده مدل برای سه دوره مختلف مورد ارزیابی قرار گرفته شد. برآورد خطای این سه دوره با روش ریشه دوم مربعات خطا مقدار ۰،۱۵ درجه سلسیوس گزارش شد. نتایج ارائه شده در این روش نسبت به روش شبکه های عصبی معمولی، از دقت بالاتری برخوردار بوده است. لانزا و همکارانش (۲۰۰۱) یک مدل شبکه عصبی با هسته توابع شعاعی را برای پیش بینی دمای ساعتی به کار گرفتند. با استفاده از این روش، دقت خطای میانگین مطلق ۰،۵ درجه سلسیوسی دما بدست آمد. ماشین بردار پشتیبان با هسته توابع شعاعی جهت پیش بینی دما، بیشترین کاربرد را در تحقیقات اخیر داشته است. اورتز گارسیا و همکارانش (۲۰۱۲) بر اساس ماشین پشتیبان برداری با هسته توابع شعاعی یک رگرسیون برای پیش بینی دمای ۶ ساعته بدست آورند. آنها از داده های دمایی سال ۲۰۰۹ فرودگاه بارسلون و استفاده از هفت پارامتر جوی، اقدام به پیش بینی دمای ۶ ساعته کردند. سپس به مقایسه نتایج خود با شبکه عصبی پرداخته و نشان دادند که روش به کار گرفته شده ایشان جهت پیش بینی دما، نسبت به سایر روش ها از دقت بیشتری برخوردار بوده است. میلیت و همکارانش (۲۰۱۱)، یک ماشین پشتیبان با کمترین مربعات را برای پیش بینی دمای ۶ ساعته با پارامترهای آب و هوایی مورد استفاده قرار دادند. مقایسه نتایج ایشان با روش های لایه های چندگانه پرسپترون شبکه عصبی توابع شعاعی و شبکه عصبی تصادفی نشان داد که روش به کار گرفته شده نسبت به سایر شبکه های عصبی از دقت بیشتری برخوردار بوده است.

ماشین تعقیب کننده (Pursuit Machine)، یک ماشین یادگیری است و برای داده های سری زمانی استفاده می شود که در زمینه های شیمی-فیزیک (گیر و همکاران، ۲۰۲۱)، مراقبت های بهداشتی (یان و همکاران، ۲۰۲۲) و پزشکی (گوردون و همکاران، ۲۰۲۰) کاربرد دارد. هدف اصلی در این پژوهش استفاده و ارزیابی توانایی الگوریتم یادگیری ماشین تعقیب کننده با استفاده از کمترین مربعات خطای طیفی شبه فوری-سری زمانی برای پیش بینی های کوتاه مدت ۲۴، ۴۸



شکل ۱. پراکنش مکانی ایستگاه‌های هواشناسی مورد استفاده در این مطالعه

method) دارای دو لایه است. در لایه اول، از توابع مثلثاتی با دوره تناوب غیر یکنواخت به عنوان یک رگرسیون غیرخطی بین متغیر زمان و داده‌های دمایی بدست آمد (ممکن است طول گام زمانی یکنواخت نباشد و حتی می‌تواند طول گام زمانی به عنوان یک متغیر تصادفی در نظر گرفته شود) سپس با استفاده از تحلیل اتورگرسیون خطی به بررسی جمله باقی‌مانده خطا پرداخته شد (عمریشیخ، ۲۰۰۶). در این روش مضارب رگرسیون غیرخطی برای یک برش از بازه زمانی برای داده‌های گذشته یادگرفته می‌شود. این نوع از یادگیری به عنوان ماشین تعقیب کننده یاد می‌شود. از ویژگی‌های این ماشین نیاز به حافظه کوتاه مدت داده‌های دمایی مورد بررسی برای آن است. یعنی یادگیری ماشین به نوع کل رفتار داده‌ها وابسته نیست بلکه به رفتار بازه سمت چپ نزدیک به رخداد مرجع وابسته است. خلاصه‌ای از پیاده‌سازی ماشین در ادامه آورده می‌شود. برای مطالعه جزئیات بیشتر به مرجع (کرایمر، ۲۰۰۲) مراجعه شود.

فرض می‌شود $\{x_t\}_{t \in T}$ سری زمانی از دمای کمینه یا بیشینه باشد. روش کمترین مربعات طیفی یک دنباله از توابع پایه‌ای روی دامنه زمانی T (لزوماً دارای گام یکنواخت

سری زمانی دمای کمینه و بیشینه یک منطقه خاص، تناوب سالانه‌ای را برای میانگین دمای سالانه نشان می‌دهد. می‌توان دما را یک تابع نویزدار (Noise) از یک تابع متناوب در نظر گرفت. در تئوری سیگنال احتمالی (statistical signal processing) به دنبال یافتن توزیع احتمال طیف فرکانس برای تخمین فرکانس سیگنال با استفاده از کمترین مربعات سینوسی داده‌های نمونه، مشابه آنالیز فوریه هستند (مورفی، ۱۹۸۸- بنژیو و وینسنت، ۲۰۰۲). به دلیل پدیده‌های موثر بر دما مانند حرکت انتقالی زمین و فعالیت چرخه‌ای خورشید سری زمانی دماهای کمینه و بیشینه دارای ماهیت متناوب‌اند. سری زمانی دما با استفاده از توابع سینوسی و کسینوسی با دوره متناوب ریز و درشت مقیاس برای چرخه سالانه و پدیده‌هایی با چرخه چند ساله می‌توان تجزیه نمود. جمله باقی مانده حاصل از تفاضل دمای بیشینه و کمینه با قسمت کمترین مربعات طیفی به عنوان یک سری زمانی ایستا خواهد بود که با استفاده از روش اتورگرسیون خطی میانگین متحرک AM تحلیل خواهد شد. ماشین تعقیب کننده با به کارگیری روش کمترین مربعات طیفی شبه فوریه- سری زمانی (Least square spectral pseudo-Fourier-time series

ماشین تعقیب کننده را تحت آموزش قرار می‌دهد

$$X = \Phi a + C \epsilon_t \quad (4)$$

در اینجا Φ ماتریس ضرایب متناظر توابع پایه‌ای و E بردار متغیرهای باقی مانده آموزشی هستند. با استفاده از حل معادله (۴) و استفاده از روش کمترین مربعات خطا، بردار یادگیری a حاصل می‌شود. سری زمانی مورد مطالعه را نسبت به مرجع زمانی که قرار است پیش‌بینی صورت گیرد به صورت زیر نمایش می‌دهیم

$$x_t = \Phi(t)a + C \epsilon_t \quad (5)$$

با تحلیل سری زمانی ایستای ϵ_t یک رابطه اتورگرسیون خطی به صورت زیر بدست می‌آید

$$\epsilon_t = b_1 \epsilon_{t-1} + \dots + b_k \epsilon_{t-k} + C' z_t \quad (6)$$

در اینجا منظور از z_t یک متغیر تصادفی نرمال استاندارد، مستقل از زمان است. انتظار داریم خطای پیش‌بینی ماشین با اندازه اطمینان $1-\alpha$ دارای کران بالای $CC' |z_{\frac{\alpha}{2}}$ باشد و به عنوان دقت احتمالاتی پیش‌بینی در نظر گرفته خواهد شد. در این پژوهش دو ماشین مورد استفاده قرار می‌گیرد. هر جا صحبت از روش اول (Method1: M1) شد منظور ماشین تعقیب کننده با استفاده از روش کمترین مربعات طیفی شبه فوریه بدون در نظر گرفتن جمله باقی مانده است یعنی فقط از قسمت $\Phi(t)a$ در پیش‌بینی استفاده می‌شود. منظور از روش دوم (Method2: M2) یعنی تصحیح مقادیر ماشین تعقیب کننده روش اول با یک جمله باقی مانده‌ی تصحیح خطای $C \epsilon_t$ است.

نمره مهارت (Skill Score: SS) معیاری برای سنجش 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

نیست حتی ممکن است طول گام تصادفی باشد) به عنوان یک سری از توابع تقریب زننده در نظر گرفته می‌شود. و می‌توان سری زمانی را با توجه به دنباله پایه‌ای مورد نظر به صورت زیر تقریب زد

$$x_t = \sum_{n=1}^{\infty} a_n \phi_n(t) + C \epsilon_t \quad t \in T \quad (1)$$

در اینجا a_n و C ضرایب حقیقی و ثابت طی یک برش زمانی منتهی به مرجع زمانی خاص هستند. در حقیقت این ضرایب تابعی از مرجع زمانی در طول دوره هستند و برای هر مرجع جدید باید به روزرسانی شوند. علاوه بر این ϵ_t خطای باقی‌مانده روش، یک سری زمانی ایستا با توزیع نرمال استاندارد است. تعیین توابع پایه‌ای تقریب زننده با کمترین مقدار ضریب C جز یکی از مباحثی مورد بررسی در مرجع معرفی شده است. با توجه به ماهیت متناوب سری زمانی مورد مطالعه و پیچیدگی محاسباتی برای بدست آوردن توابع پایه‌ای، دو دسته توابع مثلثاتی A_1 و A_2 در زیر معرفی شده‌اند و در تولید ماشین تعقیب کننده استفاده شده می‌شود

$$A_1 = \left\{ 1, \sin\left(\frac{2\pi n_s t}{T}\right), \cos\left(\frac{2\pi n_c t}{T}\right) \right\}_{n_s, n_c=1}^{N_s, N_c} \quad (2)$$

و

$$A_2 = \left\{ \sin\left(\frac{2\pi t}{T n_s}\right), \cos\left(\frac{2\pi t}{T n_c}\right) \right\}_{n_s, n_c=1}^{I N_s, I N_c} \quad (3)$$

مجموعه A_1 همان مجموعه توابع پایه‌ای مورد استفاده در تقریب فوریه است. برای پدیده‌هایی با دوره تناوبی چندساله مانند پدیده چرخه تابشی خورشید، از توابع مجموعه A_2 به عنوان تقریب زننده استفاده می‌شود. پارامترهای $N_s, N_c, I N_s, I N_c$ تعداد اعضای مجموعه از توابع پایه‌ای هستند که به عنوان پارامترهای ماشین، در طول دوره آموزش مقادیر ثابت ۲۰ در نظر گرفته می‌شوند. فرض کنید مجموعه آموزشی $X = (x_t)_{t \in T}$ به عنوان یک بردار یادگیری در زیر مجموعه زمانی T ، زیر بردار مشاهدات سری زمانی نسبت به یک مرجع زمانی t است و می‌خواهیم در آن مرجع پیش‌بینی ارائه دهیم. این بردار،

$$SS = \rho_{X,Y}^2 - \left(\rho_{X,Y} - \frac{\sigma_Y}{\sigma_X} \right)^2 - \left(\frac{\mu_Y - \mu_X}{\sigma_X} \right)^2 \quad (7)$$

که از بالا به ۱ محدود است و زمانی اتفاق می‌افتد که $Y = X$ وابسته خطی باشد. کمترین مقدار آن زمانی رخ می‌دهد که این دو متغیر مستقل از هم و دارای واریانس‌ها و میانگین‌های کاملاً متفاوتی باشند. رابطه بین $\rho_{X,Y}$ و SS رابطه خطی است با این تفاوت که نسبت بین واریانس‌ها به عنوان شیب خط و فاصله بین میانگین‌ها موثر در جمله بایاس است.

برای مقایسه بین دو روش پیش‌بینی با یکدیگر، از نمره مهارت پیش‌بینی (Skill Score Forecasting: SSF) (مورفی، ۱۹۸۸) معرفی شده استفاده می‌کنیم

$$SS_{12} = 1 - \frac{\sum_{i=1}^n (F_{i,1} - O_i)^2}{\sum_{i=1}^n (F_{i,2} - O_i)^2} \quad (9)$$

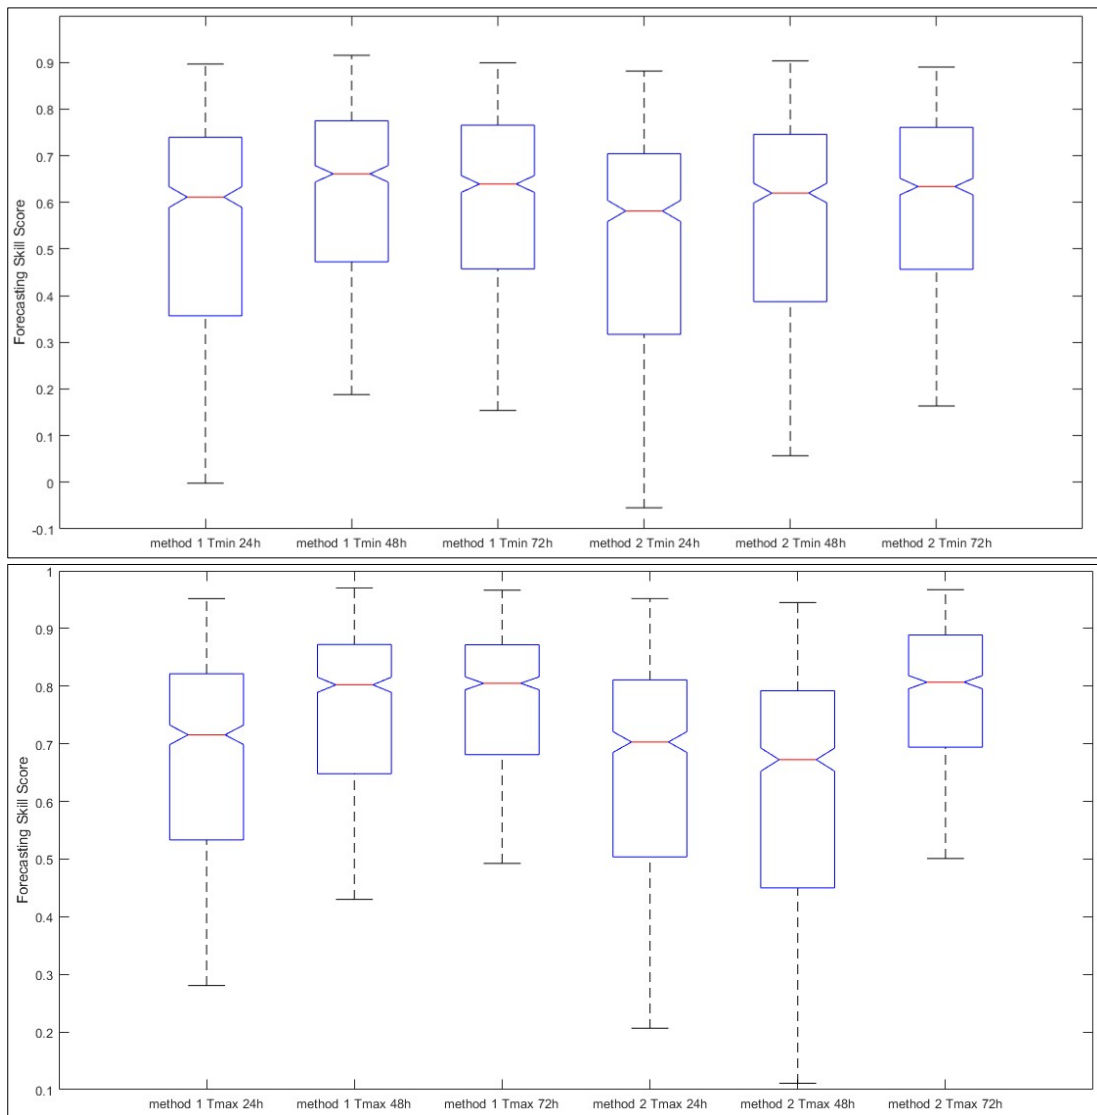
در اینجا O_i مشاهدات $i=1, \dots, n, j=1, 2$ پیش‌بینی روش‌های اول و دوم هستند. به آسانی می‌توان تحقیق کرد که $s_{12} \leq 1$ یک نسبت ارزیابی عملکرد را بین دو روش پیش‌بینی ارائه می‌دهد هر چقدر روش اول در پیش‌بینی نسبت به روش دوم عملکرد بهتری داشته باشد در این صورت مقدار نمره آزمون پیش‌بینی به عدد یک نزدیک‌تر است. اگر روش دوم نسبت به روش اول دقت بیشتری داشته باشد این مقدار به منفی بینهایت نزدیک‌تر است. اگر هر دو روش از لحاظ دقت به هم نزدیک باشند این کمیت از لحاظ مقداری به صفر نزدیک‌تر است. در کل، مثبت بودن نمره مهارت پیش‌بینی به معنی عملکرد بهتر روش اول نسبت به روش دوم است و بالعکس، منفی بودن نمره مهارت پیش‌بینی به معنی عملکرد ضعیف‌تر روش اول نسبت به روش دوم خواهد بود.

برای اعتبارسنجی روش‌های مورد مطالعه شده نسبت به مدل WRF از نمره مهارت (SS)، نمره مهارت پیش‌بینی (SSF) و ریشه میانگین مربعات خطا (RMSE) استفاده شد. در ادامه درباره نتایج این شاخص‌ها به طور کامل بحث می‌شود.

نتایج و بحث

یک معیار برای مقایسه دو روش پیش‌بینی، نمره مهارت پیش‌بینی (SSF) است. در شکل ۲، نمره مهارت پیش‌بینی (SSF) روزانه دمای کمینه و بیشینه برای روش‌های اول و دوم در مقایسه با مدل WRF نشان داده شده است. نمره مهارت پیش‌بینی (SSF) دمای کمینه و بیشینه روزانه ۲۴،۴۸ و ۷۲ ساعته برای تمامی نقاط ایستگاهی دارای مقادیر مثبت هستند که به معنی دقیق‌تر بودن روش اول و دوم نسبت به مدل WRF در پیش‌بینی دمای کمینه و بیشینه روزانه ۲۴،۴۸ و ۷۲ ساعته است. پراکندگی نمره مهارت پیش‌بینی (SSF) دمای کمینه نسبت به دمای بیشینه بیشتر است (شکل ۲). همچنین میانه نمره مهارت پیش‌بینی (SSF) دمای بیشینه بین ۰/۷ تا ۰/۸ است و این مقدار برای دمای کمینه حدوداً ۰/۶ است. با توجه به نمره مهارت پیش‌بینی (SSF)، ماشین تعقیب کننده دمای بیشینه را بهتر از دمای کمینه پیش‌بینی کرده است (شکل ۲). به طور کلی مهارت روش‌های اول و دوم در پیش‌بینی‌های کوتاه مدت دمای کمینه و بیشینه در مقایسه با مدل WRF بالاتر است (شکل ۲).

از ابزارهای مقایسه بین یک روش پیش‌بینی و مشاهدات مورد مطالعه، بررسی تطابق پذیری گشتاورهای اول و دوم توزیع جامعه آماری دو مجموعه داده‌ای با فرض نرمال بودن توزیع‌های آن دو نمونه است. نمودار جعبه‌ای نمره مهارت (SS) برای پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای بیشینه و کمینه با استفاده از پیش‌بینی‌های مدل WRF و روش‌های اول و دوم در شکل ۳ نشان داده شده است. نمره مهارت (SS) روش‌های اول و دوم نسبت به مدل افزایش یافته است. همچنین نمره مهارت (SS) هر یک از روش‌ها با توجه به یکنواختی روش‌ها در پیش‌بینی، دارای دامنه پراکندگی فشرده‌تری نسبت به مدل است و به عبارتی دارای تغییرپذیری کمتری است (شکل ۳). توزیع آماری نمره مهارت (SS) دمای کمینه و بیشینه روزانه ایستگاهی دارای میانه‌ای بین ۰/۶ تا ۰/۸ هستند. هر چند به نظر می‌رسد وضعیت برای دمای کمینه کمی بهتر باشد. به علاوه پراکندگی جامعه آماری نمره مهارت (SS) دمای کمینه نسبت به دمای بیشینه بازه فشرده‌تری دارد.

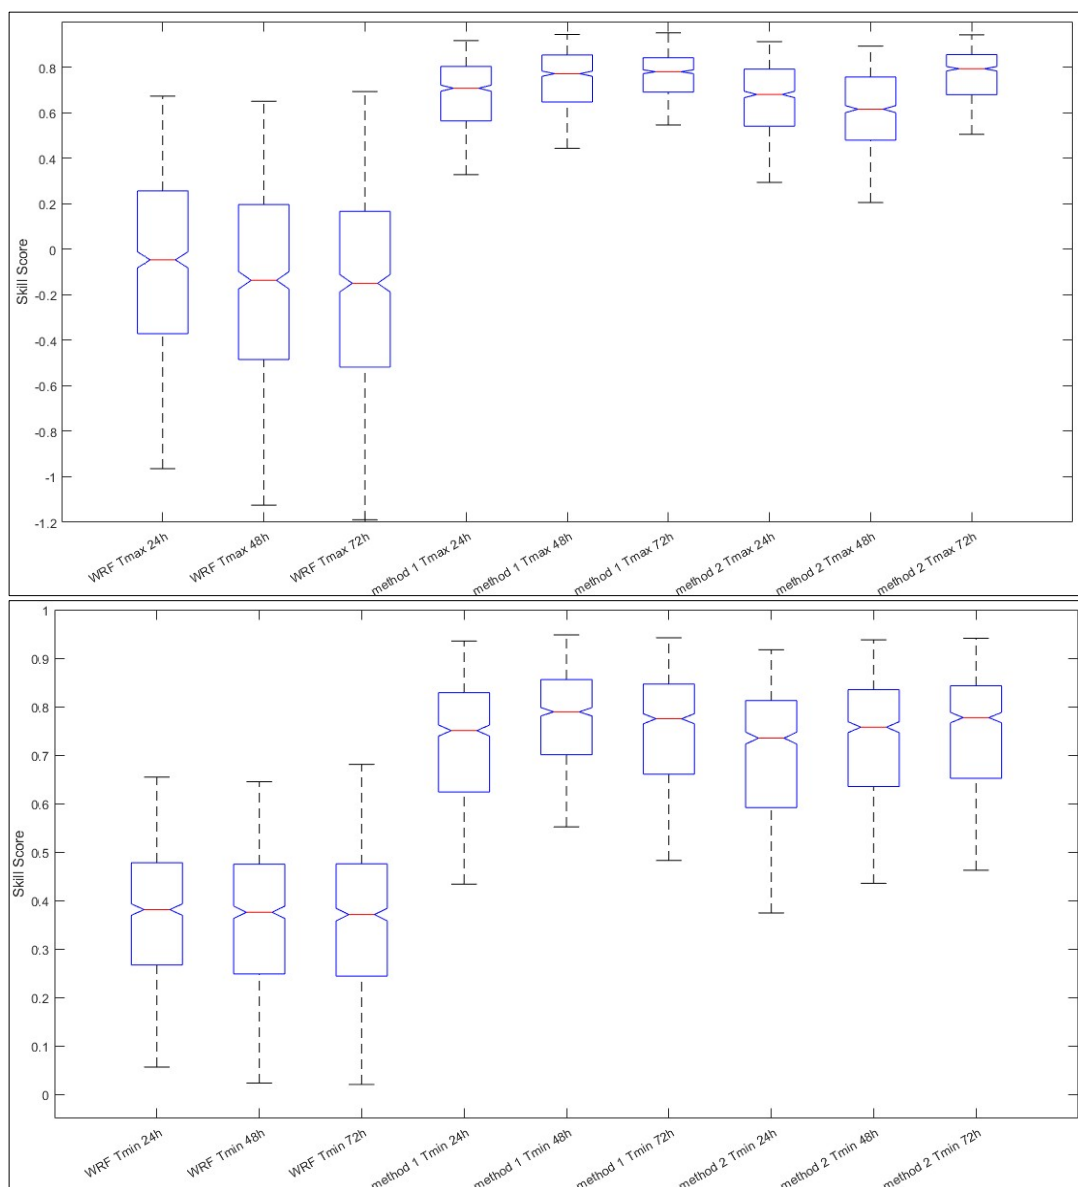


شکل ۲. نمودار جعبه‌ای نمره مهارت پیش‌بینی (SSF) برای پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه (شکل بالا) و بیشینه (شکل پایین) برای پیش‌بینی‌های روش‌های اول (method 1) و دوم (method 2) در مقایسه با مدل WRF.

کرده‌اند. طی ماه‌های دوره مورد مطالعه، نمره مهارت (SS) ماشین تعقیب کننده نسبت به مدل بیشتر بوده است (شکل ۴ و ۵). روند میانگین نمره مهارت (SS) ماهانه برای دمای بیشینه، روندی یکنواخت‌تری را نسبت به دمای کمینه نشان می‌دهد. همانگونه که در نمودارهای شکل ۴ ملاحظه می‌شود، نمره مهارت (SS) دمای بیشینه روزانه ۴۸، ۲۴ و ۷۲ ساعته مدل در ماه سپتامبر دارای کمترین مقدار و برای ماه مارس بیشترین مقدار را دارد و همچنین نمره مهارت (SS) پیش‌بینی

نکته جالب اینکه پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای بیشینه و کمینه با استفاده از روش‌های اول و دوم نسبت به مدل WRF دارای تغییرپذیری بسیار کمتر با نمره مهارت بالاتر بوده است (شکل ۳).

میانگین ماهانه نمره مهارت پیش‌بینی‌های کوتاه مدت دمای بیشینه و کمینه برای مدل WRF و روش‌های اول و دوم در شکل ۴ و ۵ نشان داده شده است. نتایج نشان می‌دهند که روش‌های اول و دوم در پیش‌بینی ماهانه مشابه هم عمل




شکل ۳. نمودار جعبه‌ای نمره مهارت (SS) برای پیش‌بینی‌های ۴۸، ۷۲ و ۲۴ ساعته دمای بیشینه (شکل بالا) و کمینه (شکل پایین) با استفاده از پیش‌بینی‌های مدل WRF و روش‌های اول (method 1) و دوم (method 2).

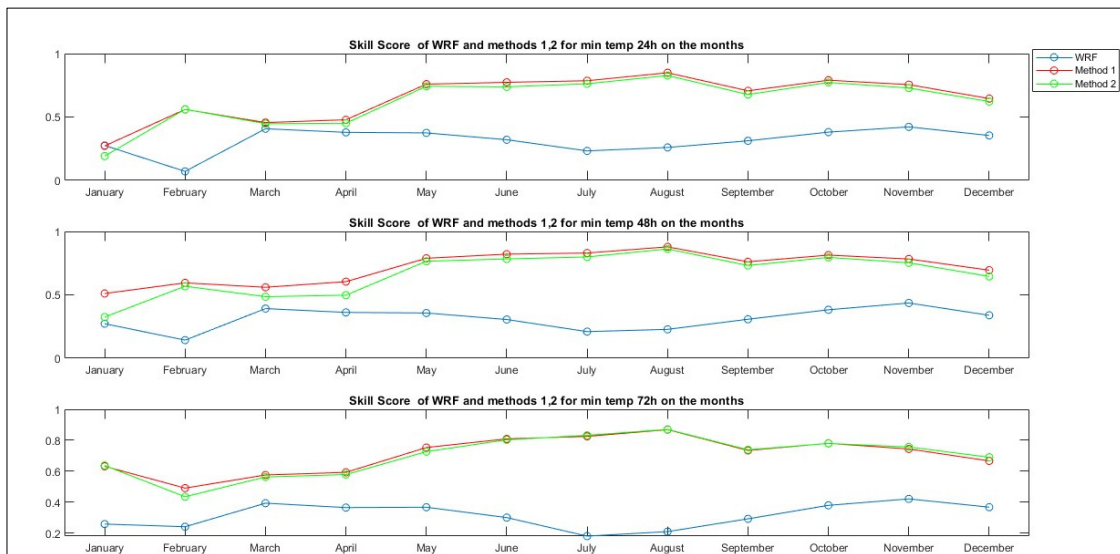
فوریه، میانگین نمره مهارت (SS) ماهانه روند نزولی را نشان می‌دهد و بین ماه فوریه و مارس یک جهش در نمودار نمره مهارت (SS) ماهانه مشهود است (شکل ۵ نمودار WRF). در نمودارهای نمره مهارت (SS) ماهانه برای ماشین تعقیب کننده به غیر از پیش‌بینی‌های ۲۴ ساعته که یک جهش را بین ماه دسامبر و ژانویه نشان می‌دهد، نمودارهای نمره مهارت (SS) ۴۸ و ۷۲ ساعته روند تقریباً یکنواختی را دارند. نمودار

دمای بیشینه مدل از ماه مارس تا ماه سپتامبر با گرم شدن دمای هوا یک روند نزولی را نشان می‌دهد.

میانگین ماهانه نمره مهارت پیش‌بینی‌های کوتاه مدت کمینه برای مدل WRF و روش‌های اول و دوم در شکل ۵ نشان داده شده است. به غیر از فاصله زمانی بین ماه‌های نوامبر تا فوریه، نمره مهارت (SS) مدل تقریباً برای پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته یکنواخت است. در بین ماه نوامبر تا



شکل ۴. میانگین ماهانه نمره مهارت (SS) برای پیش بینی دمای بیشینه از بالا به پایین ۲۴، ۴۸ و ۷۲ ساعته ایستگاه‌های سراسر کشور. نمودار آبی مربوط مدل WRF و نمودار قرمز و سبز مربوط به روش اول و دوم هستند.

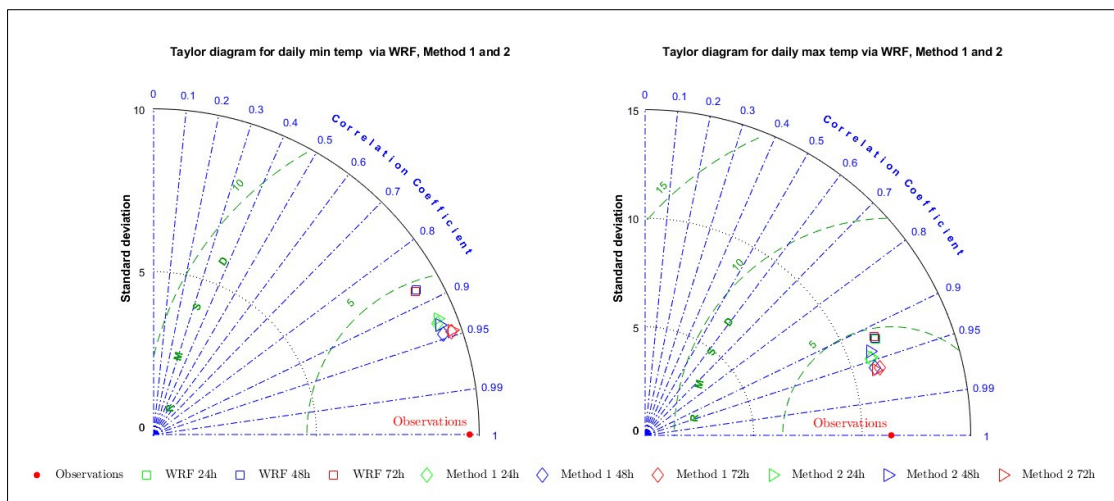


شکل ۵. میانگین ماهانه نمره مهارت (SS) برای پیش بینی دمای کمینه از بالا به پایین ۲۴، ۴۸ و ۷۲ ساعته ایستگاه‌های سراسر کشور. نمودار آبی مربوط مدل WRF و نمودار قرمز و سبز مربوط به روش اول و دوم هستند.

برای ماشین تعقیب کننده (روش‌های اول و دوم)، در تمام ماه‌ها دارای مقادیر بالاتر و روند یکنواخت با تغییرپذیری بسیار کمتر است (شکل ۴ و ۵).

شکل ۶، مقایسه بین انحراف معیار و همبستگی پیرسون پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ دمای کمینه (شکل سمت چپ)

نمره مهارت (SS) ماهانه دمای کمینه نسبت به دمای بیشینه، مقادیر کمتر و نوسانات بیشتری دارد که به معنی مهارت بیشتر ماشین تعقیب شونده در پیش‌بینی دمای بیشینه نسبت به دمای کمینه است. برخلاف پیش‌بینی مدل WRF، میانگین ماهانه نمره مهارت (SS) پیش‌بینی‌های دمای کمینه و بیشینه



شکل ۶. نمودار تیلور، برای مقایسه پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته (24h, 48h, 72h) دمای کمینه و بیشینه خروجی مدل WRF، روش‌های اول (Method1) و دوم (Method2) با مشاهدات (Observations). نمودار سمت راست برای دمای بیشینه و سمت چپ دمای کمینه.

جدول ۱. میانگین و میانه نمره مهارت (SS) پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه و بیشینه، برای روش‌های M1، M2 و مدل WRF

دمای بیشینه			دمای کمینه			دوره پیش‌بینی	
M ^۲	M ^۱	WRF	M ^۲	M ^۱	WRF		
۰٫۶۸	۰٫۷۰	-۰٫۰۴	۰٫۷۳	۰٫۷۵	۰٫۳۸	۲۴ ساعته	میانه نمره مهارت
۰٫۶۲	۰٫۷۷	-۰٫۱۳	۰٫۷۶	۰٫۷۹	۰٫۳۸	۴۸ ساعته	
۰٫۷۹	۰٫۷۸	-۰٫۱۴	۰٫۷۸	۰٫۷۷	۰٫۳۷	۷۲ ساعته	
۰٫۶۰	۰٫۶۳	-۰٫۰۹	۰٫۶۳	۰٫۶۵	۰٫۳۳	۲۴ ساعته	میانگین نمره مهارت
۰٫۵۷	۰٫۷۲	-۰٫۱۸	۰٫۶۷	۰٫۷۲	۰٫۳۳	۴۸ ساعته	
۰٫۷۴	۰٫۷۳	-۰٫۲۲	۰٫۷۰	۰٫۷۱	۰٫۳۳	۷۲ ساعته	

روش‌های اول و دوم نسبت به پیش‌بینی‌های مدل WRF به مشاهدات نزدیکتر است (شکل ۶). پیش‌بینی‌های روش اول اندکی نسبت به روش دوم به مشاهدات نزدیکتر است (اشکال لوزی در شکل ۶).

جدول ۱ میانگین و میانه نمره مهارت پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه و بیشینه را برای کل دوره آماری نشان داده شده است. مقادیر میانگین و میانه نشان می‌دهد نمره مهارت (SS) هر یک از روش‌های M1 و M2 بر خلاف برنوداد مدل WRF دارای مقادیر مثبت و بزرگ‌تر از ۰/۵ است. ماشین تعقیب کننده در پیش‌بینی دمای کمینه و بیشینه در دوره آماری مورد مطالعه بسیار بهتر از مدل WRF عمل کرده است، به طوری که تقریباً نمره مهارت هر دو روش

و دمای بیشینه (شکل سمت راست) برای داده‌های مشاهده شده، مدل و هریک از روش‌های اول و دوم را در نمودار تیلور نشان می‌دهد. ملاحظه می‌شود که مقادیر انحراف معیار روش‌های اول و دوم نزدیک به مقادیر انحراف معیار مشاهدات هستند. افزایش همبستگی بین مشاهدات و ماشین تعقیب شونده نسبت به مدل مشهود است. مقدار انحراف معیار دمای کمینه و بیشینه روزانه مشاهدات به ترتیب ۹/۴ و ۱۱/۱ است که ماشین تعقیب شونده این مقادیر را ۹/۶ و ۱۱ تقریب زده است. همچنین بهبود در همبستگی مقادیر پیش‌بینی‌های دمای کمینه و بیشینه روزانه ۴۸، ۲۴ و ۷۲ ساعته که توسط ماشین صورت گرفته شده است مشخص است. پیش‌بینی‌های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه و بیشینه با استفاده از

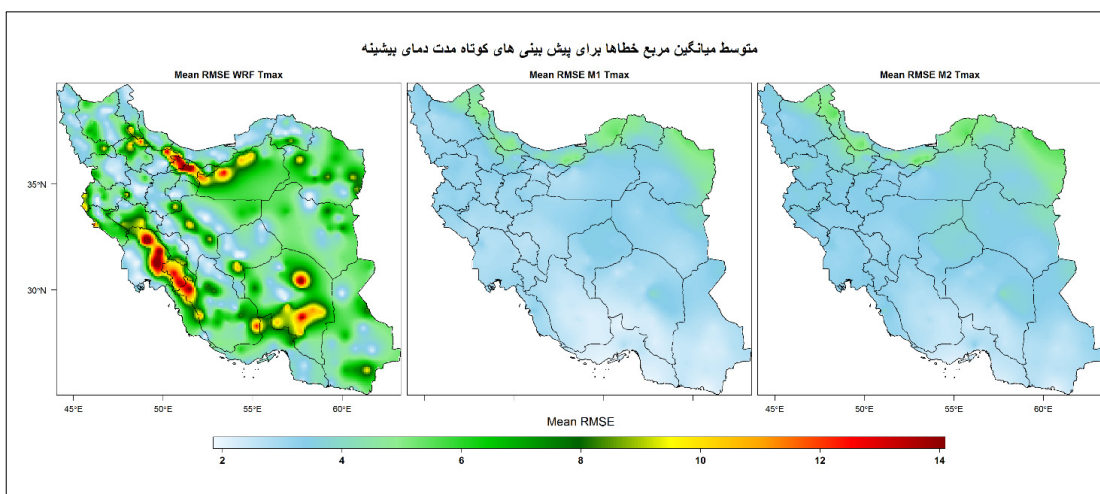
جدول ۲. میانگین و میانه RMSE پیش بینی های ۴۸، ۲۴ و ۷۲ ساعته دمای کمینه و بیشینه، برای روش های M1، M2 و مدل WRF

دمای بیشینه			دمای کمینه			دوره پیش بینی	میانه RMSE
M2	M1	WRF	M2	M1	WRF		
۳,۲۸	۳,۱۷	۵,۹۹	۳,۰۳	۲,۹۳	۴,۶۱	۲۴ ساعته	RMSE
۳,۵۶	۲,۷۰	۶,۲۸	۲,۹۲	۲,۶۷	۴,۶۶	۴۸ ساعته	
۲,۶۴	۲,۸۱	۶,۲۸	۲,۸۶	۲,۷۹	۴,۶۸	۷۲ ساعته	
۳,۵۰	۳,۴۱	۵,۹۹	۳,۴۰	۳,۲۷	۴,۷۱	۲۴ ساعته	میانگین RMSE
۳,۷۷	۲,۹۶	۶,۲۲	۳,۲۱	۲,۹۵	۴,۷۹	۴۸ ساعته	
۲,۸۶	۲,۹۳	۶,۳۱	۳,۰۴	۳,۰۱	۴,۷۶	۷۲ ساعته	

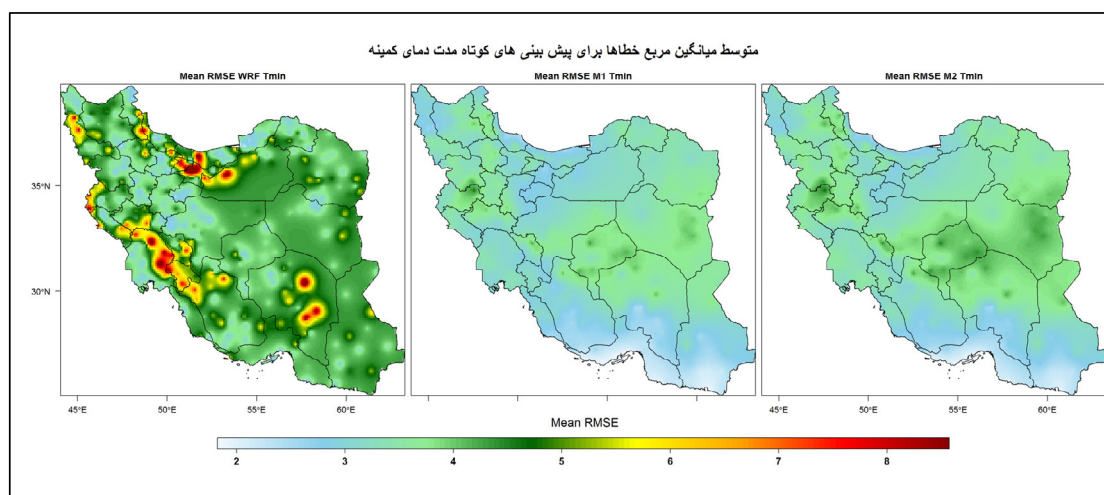
نشان داد بسته به نوع الگوریتم یادگیری RMSE پیش بینی روزانه از ۱/۱ تا ۷ درجه در نوسان است. در مطالعات انجام شده معمولاً برای پیش بینی دما چندین متغیر کمکی در الگوریتم یادگیری ماشین وارد می شوند (مانند سرعت باد، رطوبت و غیره) اما در این مطالعه فقط سری زمانی داده های دمای به عنوان متغیر ورودی به ماشین وارد شده است و میانگین RMSE پیش بینی ها در محدوده ۲ تا ۳ درجه است که با مطالعات ذکر شده تطابق دارد.

شکل ۷ توزیع مکانی میانگین RMSE پیش بینی های کوتاه مدت دمای بیشینه (پیش بینی های ۲۴، ۴۸ و ۷۲) برای مدل WRF و روش های M1 و M2 را نشان می دهد. ملاحظه می شود خطای RMSE مدل WRF در پهنه زاگرس جنوبی (جنوب غربی ایران)، جنوب رشته کوه البرز و محدوده کوه هزار و لاله زار در جنوب شرقی با متوسط بیشتر از ۱۰ درجه همراه بوده است این در حالی است که هر دو روش M1 و M2 در این نواحی با عملکرد خوبی همراه بوده است و میانگین RMSE پیش بینی های کوتاه مدت دمای بیشینه کمتر از ۴ درجه است. از دلایل دینامیکی می تواند آن باشد که تغییرات ارتفاع و ناهمواری های جغرافیایی در نواحی مورد نظر به دلیل مجاورت ناحیه پست با ناحیه کوهستانی سبب اختلال در محاسبات دینامیکی مربوط به مدل بوده است. البته دقت ماشین تعقیب کننده به کیفیت و پیوستگی زمانی داده ها نیز وابسته است که یکی از نقاط ضعف داده های بازه زمانی مورد مطالعه عدم پیوستگی طول گام زمانی مشاهدات بوده است. این نقیصه با اصلاحات آماری و ریاضی تا حدودی قابل رفع

M1 و M2 بیش از ۰/۷ و در حد قابل قبول بوده است. جدول ۲ میانگین و میانه RMSE پیش بینی های ۲۴، ۴۸ و ۷۲ ساعته دمای کمینه و بیشینه را برای کل دوره آماری نشان داده شده است. مقادیر میانگین RMSE نشان می دهد، میانگین RMSE مدل WRF برای پیش بینی های کوتاه مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای کمینه بیش از ۴/۷ درجه سلسیوس و برای دمای بیشینه بیش ۶ درجه سلسیوس است در حالی که برای روش اول و دوم M1 و M2 میانگین RMSE برای دمای کمینه حدوداً ۳ درجه سلسیوس و برای دمای بیشینه تقریباً ۳/۲ درجه سلسیوس است (جدول ۲). بنابراین می توان گفت ماشین تعقیب کننده در پیش بینی های کوتاه مدت (۲۴، ۴۸ و ۷۲ ساعته) دمای کمینه و بیشینه نسبت به مدل WRF با خطای کمتری همراه بوده است. کاروان و همکاران (۲۰۱۵) با استفاده از الگوریتم یادگیری ماشین بردار پشتیبان، پیش بینی های ۶ روزه دمای متوسط، دمای بیشینه و کمینه را برای ۷۰ ایستگاه در سراسر دنیا ارائه دادند. نتایج آنها نشان داد میانگین خطای مطلق MAE (Mean Absolute Error) پیش بینی دما از یک تا سه درجه سلسیوس متغیر است. پانیاگوا-تینئو و همکاران (۲۰۱۱) با استفاده از الگوریتم یادگیری ماشین پیش بینی ۲۴ ساعته دمای بیشینه را برای ۱۰ ایستگاه در نقاط مختلف اروپا ارائه دادند. نتایج آنها نشان داد RMSE پیش بینی از ۱/۵ تا ۲/۹ درجه در بین ایستگاه ها متغیر است. آذری و همکاران (۲۰۲۲) با استفاده از چندین روش یادگیری ماشین به پیش بینی دمای روزانه در فرودگاه بین المللی ممفیس آمریکا کردند. نتایج آنها



شکل ۷. پهنه بندی میانگین RMSE پیش بینی های کوتاه مدت دمای بیشینه (پیش بینی های ۲۴، ۴۸ و ۷۲) برای مدل WRF و روش های M1 و M2

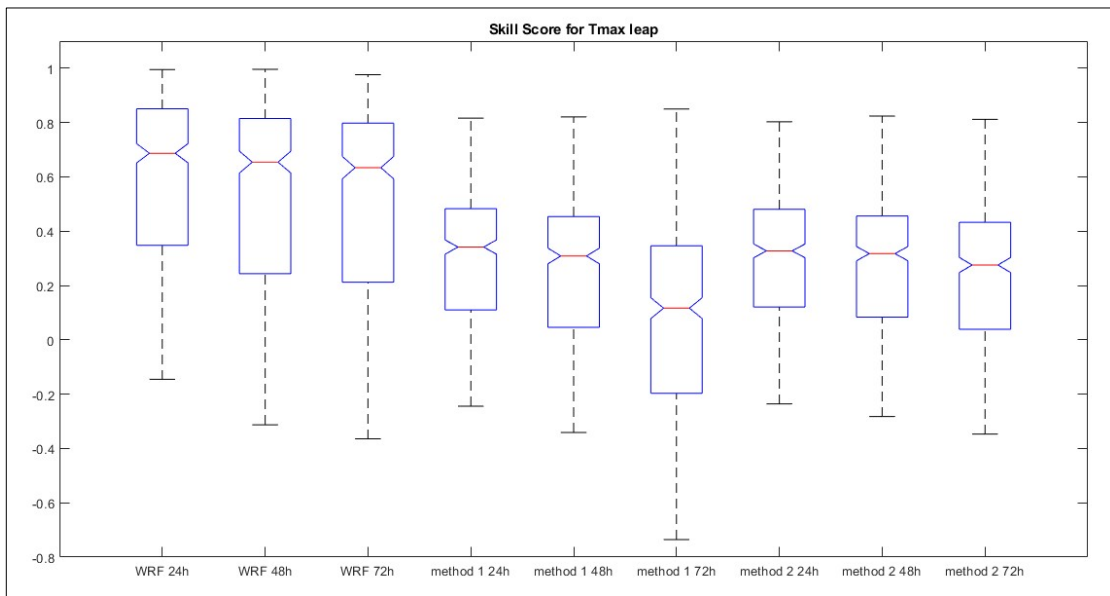


شکل ۸. پهنه بندی میانگین RMSE پیش بینی های کوتاه مدت دمای کمینه (پیش بینی های ۲۴، ۴۸ و ۷۲) برای مدل WRF و روش های M1, M2

هزار و لاله زار در جنوب شرقی دارای بیشترین میانگین خطا هستند. هر چند توزیع میانگین خطای RMSE روش اول و دوم نسبت به مدل یکنواخت‌تر (تغییرپذیری کمتر نسبت به مدل WRF) است اما در مقایسه با توزیع میانگین خطای دمای بیشینه در شکل ۷ از تغییرپذیری بیشتری برخوردار است. در نواحی شرقی و مرکزی ایران دلیل این اختلاف می‌تواند به تاثیر جریان‌ات موسمی (نفوذ رطوبت) و وجود دشت کویر و بیابان لوت (نوسانات شدید دمایی) اشاره کرد. به طور

است که در این پژوهش صرفاً جهت معرفی ماشین تعقیب کننده بوده است و به این روش‌ها اشاره نشده است.

شکل ۸ توزیع مکانی میانگین RMSE پیش بینی های کوتاه مدت دمای کمینه (پیش بینی های ۲۴، ۴۸ و ۷۲) برای مدل WRF و روش های M1 و M2 را نشان می‌دهد. ملاحظه می‌شود میانگین خطای RMSE مدل در پهنه زاگرس جنوبی (جنوب غربی ایران)، جنوب و مرکز رشته کوه البرز، تالش، استان آذربایجان غربی، غرب استان کرمانشاه و محدوده کوه



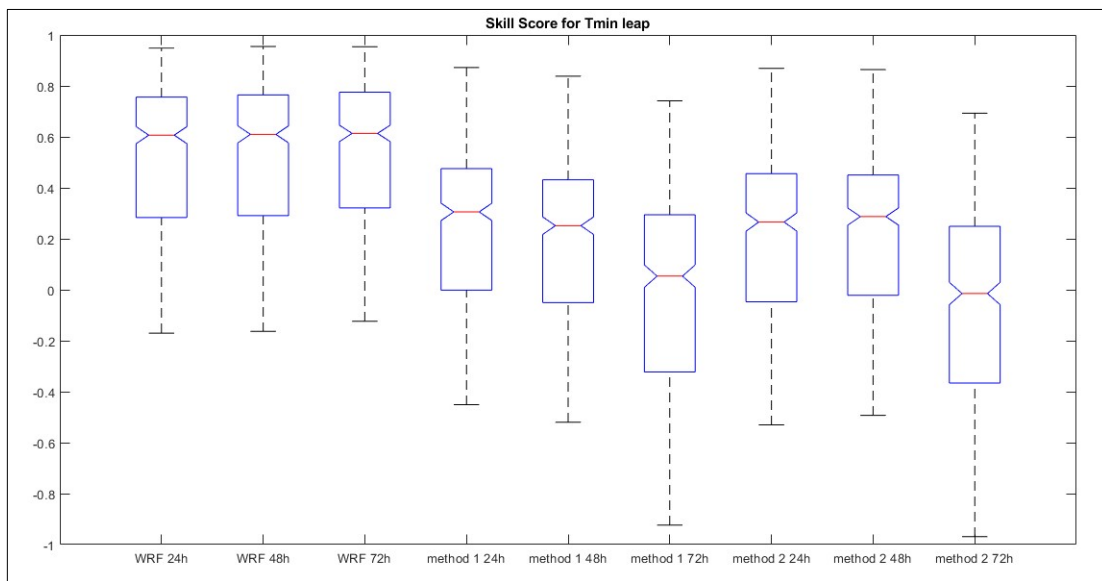
شکل ۹. نمودار جعبه‌ای نمره مهارت (SS) پیش‌بینی (۲۴.۴۸ و ۷۲ ساعته) دمای بیشینه برای روزهای که قدرمطلق جهش‌های دمایی بیش از ۶ درجه سلسیوس با استفاده از پیش‌بینی‌های مدل WRF و روش‌های اول (method 1) و دوم (method 2).

پیش‌بینی‌های ۴۸، ۷۲ و ۲۴ ساعته، برای جهش دمایی بیشینه (شکل ۹) و کمینه (شکل ۱۰) برای مدل WRF و روش‌های اول و دوم نشان داده شده است. در روزهای که جهش دمایی رخ داده، نمره مهارت (SS) مدل WRF برای پیش‌بینی‌های کوتاه مدت نسبت به روش‌های اول و دوم بهتر است. پیش‌بینی مدل بر اساس محاسبات ریاضی دینامیکی و جوی انجام می‌شود و از اینرو برای روزهای که جهش دمایی رخ داده مدل نسبت به روش‌های اول و دوم عملکرد بهتری دارد (شکل ۹ و ۱۰). درصد روزهای جهش دمایی در ایستگاه‌ها نسبت به دوره آماری مورد مطالعه برای کمینه (شکل سمت راست) و بیشینه دما (شکل سمت چپ) در شکل ۱۱ نشان داده شده است. میانگین درصد روزهای جهش دمایی در ایستگاه‌ها، برای دمای کمینه و بیشینه به ترتیب ۳ و ۳/۵ درصد، میان به ترتیب ۳/۲ و ۲/۳ درصد است (شکل ۱۱). بنابراین می‌توان گفت میزان روزهایی که جهش دمایی در آنها رخ داده، نسبت به کل دوره آماری قابل توجه نیست و از این رو می‌توان گفت، روش ماشین تعقیب کننده پیش‌بینی قابل قبولی از دمای کمینه و بیشینه روزانه ارائه داده است.


کلی هر دو روش M1 و M2 در پیش‌بینی‌های کوتاه مدت دمای کمینه در سراسر کشور نسبت به مدل WRF با مقدار کمتری RMSE همراه بوده است. و در نواحی اشاره شده که مدل WRF با خطای بیش از ۷ درجه همراه است خروجی هر دو روش M1 و M2 در محدوده ۲ تا ۳ درجه قرار می‌گیرد (شکل ۸).

به طوری کلی می‌توان گفت در پهنه کشور، پیش‌بینی‌های کوتاه مدت دمای بیشینه و کمینه در روش‌های M1 و M2 نسبت به برونداد مدل WRF با خطا و تغییرپذیری کمتری همراه است (شکل ۷ و ۸). در مناطقی از کشور که مدل WRF پیش‌بینی‌هایی با خطای بسیار بالا ارائه می‌دهد، روش‌های M1 و M2 توانسته‌اند پیش‌بینی‌هایی با خطا و تغییرپذیری بسیار کمتر تولید نمایند (شکل ۷ و ۸).

جهش دمایی روزانه به معنی افزونگی اندازه قدرمطلق اختلاف دمایی بین یک روز با روز قبل است. در این پژوهش جهش دمایی روزانه ۶ درجه سلسیوس در نظر گرفته شد. توانایی پیش‌بینی جهش دمایی روزانه یکی از ویژگی‌های اساسی مدل یا روش پیش‌بینی است. نمره مهارت (SS)



شکل ۱۰. نمودار جعبه‌ای نمره مهارت (SS) پیش‌بینی (۲۴،۴۸ و ۷۲ ساعته) دمای کمینه برای روزهای که قدرمطلق جهش‌های دمایی بیش از ۶ درجه سلسیوس باشد با استفاده از پیش‌بینی‌های مدل WRF و روش‌های اول (method ۱) و دوم (method ۲).



شکل ۱۱. نمودار جعبه‌ای درصد روزهایی که طی دوره آماری در آن، قدرمطلق جهش دمای کمینه (شکل سمت راست) و بیشینه (شکل سمت چپ) روزانه بیش از ۶ درجه سلسیوس است.

جمع‌بندی

هواشناسی، از دقت بیشتری در اکثریت روزهای دوره مورد مطالعه برخوردار است. در اکثر مناطق کشور، پیش‌بینی‌های کوتاه مدت دمای بیشینه و کمینه با ماشین تعقیب کننده نسبت به برونداد مدل WRF با خطا و تغییرپذیری کمتری همراه است. در مناطقی از کشور که مدل WRF پیش‌بینی‌هایی

نتایج نشان داد، پیش‌بینی‌های کوتاه مدت دمای بیشینه و کمینه با ماشین تعقیب کننده با استفاده از کمترین مربعات طیفی شبه فوریه-سری زمانی نسبت به مدل WRF با وجود هزینه محاسباتی بسیار کمتر و به کارگیری فقط یک پارامتر

Comparison of spatial interpolation methods for gridded bias removal in surface temperature forecasts. *Meteorological Research*.31.761-799.

Azari, B., Hassan, K., Pierce, J., & Ebrahimi, S. (2022). Evaluation of machine learning methods application in temperature prediction. *Environ Eng*, 8, 1-12.

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.

Gordon. I., Lupo. W. J., Sands-Lincoln. C., George. M., Jackson. J., and Ganguli. D. W..2020. Machine learning and the pursuit of high-value health care. *NEJM Catalyst Innovations in Care Delivery*.

Karevan, Z., Mehrkanon, S., & Suykens, J. A. K. (2015). Black-box modeling for temperature prediction in weather forecasting. 2015 International Joint Conference on Neural Networks (IJCNN), 1-8.

Lanza. P.A.G., Cosme J.M.Z..2001. A short-term temperature forecaster based on a novel radial basis functions neural network. *Int. J. Neural Syst*.6.71-76.

Lee.J., Jeong S.-J..2018. A Statistical Parameter Correction Technique for WRF Medium-Range Prediction of Near-Surface Temperature and Wind Speed Using Generalized Linear Model. *Atmosphere*. <https://doi.org/10.3390/atmos9080291>.

Mellit. A. , Pava, A., M and Benghanem M., 2011, Least squares support vector machine for short-term prediction of meteorological time series. *Theor. Appl. Climato*.111.297-307.

Miyano. T. , Girosi. F..1994. Forecasting Global Temperature Variations by Neural Networks. Technical Report.50-62.

Murphy. A.H., 1988, Skill Scores Based on the Mean Square Error and Their Relationships to the Correlation Coefficient. *Monthly Weather Review*116.. 2417-2424.

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-Figueras J..2012. Accurate local very short-term temperature prediction based on synoptic situation Support Vector Regression banks. *Atmos*. 107. 1-8.

Paniagua-Tineo, A., Salcedo-Sanz, S., Casanova-Mateo, C., Ortiz-García, E. G., Cony, M. A., & Hernández-Martín, E. (2011). Prediction of daily maximum temperature using a support vector regression algorithm. *Renewable Energy*, 36(11), 3054-3060.

Roebber.P.J..1998. The Regime Dependence of Degree

با خطای بسیار بالا ارائه می دهد، روش ماشین تعقیب کننده تواسه پیش بینی هایی با خطا و تغییرپذیری بسیار کمتر تولید نماید. نتایج نشان می دهد روزهایی که قدر مطلق جهش دمایی کمتر از ۶ درجه سلسیوس باشد، ماشین تعقیب کننده با داده های ۱۰۰ روزه در پیش بینی دمای کمینه و بیشینه روزانه عملکرد خوبی داشته است. ماشین یادگیری استفاده شده در این پژوهش یک ماشین بدون حافظه است و شرایط اقلیمی هر ایستگاه و رخ دادهای جوی گذشته درصودر پیش بینی موثر نیستند. همچنین نقاطی که در همسایگی هم قرار دارند مستقل از هم در نظر گرفته شده است. ویژگی دیگر این ماشین استفاده از کمیت دمایی به عنوان تنها کمیتی که در یادگیری آن به کار می رود. طول گام زمانی برای اجرای این ماشین بر خلاف روش سری زمانی الزاما یکنواخت نیست، و به عنوان یک متغیر تصادفی در طول فرآیند یادگیری ماشین در نظر گرفته می شود. زمانی که قدرمطلق جهش دمایی بیش از ۶ درجه سلسیوس باشد، ماشین تعقیب کننده به دلیل مفروض بودن استقلال دادهای نقاط ایستگاهی و دوره بازگشت طولانی رخداد جهش، کارایی آن در پیش بینی کاسته شده است. بهبود پیش بینی در جهش دمایی به وسیله ماشین تعقیب کننده می تواند به عنوان یک موضوع در کارهای آتی مورد مطالعه قرار گیرد.

مراجع

آزادی، م. ، محمدی، س. ع.، ۱۳۹۸، پیش بینی احتمالاتی دمای کمینه و بیشینه روزانه روی ایران با استفاده از سامانه همدادی دو عضوی، نیوار، ۴۳، ۶۲-۵۴.

آزادی، م.، شیرغلامی، م.، حجام، س.، صحراييان، ف. ، ۱۳۹۰، پس پردازش برون داد مدل WRF برای بارندگی روزانه در ایران، مجله تحقیقات منابع آب، ۷، ۸۱-۷۱.

شکوهی، م.، اسکویی، ا.ا.، محمدپور پنجاه، م.ر.، ۱۴۰۱، پس پردازش خروجی مدل WRF به روش کوکریجینگ، برای کمیت های دمای کمینه و بیشینه بر روی ایران، فضا و زمین و فیزیک، ۴۸، ۲۴۲-۲۲۷.

عساکره، ح. ح.، ۱۳۹۸، مبانی پژوهش در آب و اقلیم شناسی، دانشگاه زنجان.

Abhishek. K. , Singh. M. , Ghosh. S. and 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.

Azadi. M. , Rahmani. S. and Mohammadi. M..2017.

- Taylor. K. E.2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*.10.7183-7192.
- Taylor. X., Meng. J.W.2022. Comparing Probabilistic Forecasts of the Daily Minimum and Maximum Temperature. *International Journal of Forecasting*.58.267-281.
- Temimi. V. K., Weston. M., Fonseca. M., Nelli. R., Thota. N. R., Kumar. M. and Valappil. K. N..2020. Assessing Bias correction methods in support of operational weather forecast in arid environment. *Asia-Pacific Journal of Atmospheric Sciences*.56.333-343.
- 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.
- Vincent.P., Bengio. Y..2002. Kernel Matching Pursuit. *Machine Learning*.65.165-187.
- Day Forecast Technique, Skill, and Value. *Weather and Forecastin*.4. 783-794.
- Smith. B.A., McClendon. R.W. and Hoogenboom. G.. 2006. Improving air temperature prediction with artificial neural networks. *Int. J. Comput. Intell*.3.176-184.
- Stull. D. and McCollor R..2020. Hydrometeorological accuracy enhancement via postprocessing of numerical weather forecasts in complex terrain. *Weather and forecasting*. 23. 133-144.
- Tasadduq. I ,Rehman. S., Bubshait. K..2002. Application of neural networks for the prediction of hourly mean surface temperatures in Saudi Arabia. *Renew. Energy*.25.545-554.
- Taylor. J. and Hamilton. S..1972. Some tests of the Vaníček Method of spectral analysis. *Astrophysics and Space Science*.17.357-367.

Daily Minimum and Maximum Temperature Forecast using Pursuit Machine

Mojtaba Shokouhi¹, Mehdi Mesrizadeh², Ebrahim Asadi Oskouei^{1*}, Yashar Falamarzi¹

¹ Assistant Professor of Research Institute of Meteorology and Atmospheric Science (RIMAS), Tehran, Iran.

² Research Expert, Research Institute of Meteorology and Atmospheric Science (RIMAS), Tehran, Iran.

*Corresponding Author Email: e.asadi.o@gmail.com

Received: 02 March 2022, accepted: 31 May 2022

ABSTRACT

Forecasting the minimum and maximum temperature as accurately as possible is significant to reduce damage in the fields of agriculture, water, and livestock. In this research, daily maximum and minimum temperatures were forecasted using machine learning, with a training period of 100 days using the least squares of the pseudo-Fourier spectral error-time series. In this regard, the data from a two-year period were used for more than 540 synoptic stations in Iran. The forecasts of the machine learning method with the output of the WRF model were compared with each other and with the observations, and their abilities were evaluated with the skill score. The results showed that the implementation of the machine learning algorithm was successful in daily forecasts, and the average skill score was more than 0.6. While the average skill score for the WRF model is approximately 0.01. The main advantage of this method compared to the WRF model is that it is less computationally complex, and only the data from the last 100 days are used in the calculations. Another advantage of this method is the use of a machine learning algorithm with short-term memory, which reduces the adverse effect of the long-term lack of data in the training period's time series on the output of forecasts. In this method, short-term forecasts (24, 48, and 72 hours) of the minimum and maximum temperature for all Iran's stations can be provided with appropriate accuracy, with less computational cost, and in a very short time.

Keywords: Machine Learning, Skill Score, Spectral error, Time series, WRF model.

HOW TO CITE THIS ARTICLE

Shokouhi, M.; Mesrizadeh, M.; Asadi Oskouei, E.; Falamarzi, Y. (2022). Daily Minimum and Maximum Temperature Forecast using Pursuit Machine. *J. Meteorol. Atmos. Sci.*, 5(2): 142-140

COPYRIGHTS

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

