

Evaluation of Accuracy of Neural Network Method for Late Spring Frost Estimating in Pistachio Growing Areas of Kerman

M. Abdollahi Fuzi¹, B. Bakhtiari^{2*}, K. Qaderi²

1 and 2- Ph.D. Student in Water Structural Engineering and Associate Professor, Water Engineering Department, Faculty of Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran, respectively.

(*- Corresponding Author Email: drbakhtiari@uk.ac.ir)

Received: 27-02-2024	How to cite this article:
Revised: 24-04-2024	Abdollahi Fuzi, M., Bakhtiari, B., & Qaderi, K. (2024). Evaluation of accuracy of neural network method for late spring frost estimating in pistachio growing areas of Kerman. <i>Journal of Water and Soil</i> , 38(3), 321-336. (In Persian with English abstract). https://doi.org/10.22067/jsw.2024.87064.1392
Accepted: 08-05-2024	
Available Online: 08-05-2024	

Introduction

Spring frost is considered an important threat to agricultural products in high and middle latitudes. The damage caused by Late Spring Frosts (LSFs) significantly impacts vulnerable plant organs. This event has caused more economic losses to agriculture than any other climatic hazard in Asia, North America, and Europe. Also, these phenomena have contributed to low crop yields in Iran. The latest statistics released by the Food and Agriculture Organization of the United Nations (FAO) show that Iran is one of the largest producers of agricultural products and the world's second-biggest producer of pistachios. Kerman province is one of the significant areas of pistachio production. This province has a large share of the pistachio word area plantation. Spring frost damage to pistachio crops has led to low yields in recent years. A key aspect of studying frost is the ability to accurately estimate its occurrence. In this study, artificial neural network methods have been used to estimate late spring frost in the pistachio crop of Kerman city.

Materials and Methods

In this study, the efficiency of this method was investigated in the estimation of minimum temperature. For this purpose, the daily data of the synoptic station of Kerman city were obtained from Iran Meteorological Organization from 2000 to 2020. Meteorological data including mean, maximum, and minimum temperatures, relative humidity, wind speed, saturated vapor pressure, and sunshine hours were used. Five different combinations of these variables was considered as input variables in artificial neural network method for minimum temperatures modeling. After entering data into network and modeling with each combination, RMSE and R^2 values were calculated. Finally, the combination of 8 variables including average and maximum temperature, the minimum temperature the previous day and two days prior, relative humidity, wind speed, saturated vapor pressure, and sunny hours were selected as the most suitable combination of variables. Subsequently, a simulation of minimum temperature values was conducted using 10% of the data. The performance of the methods was evaluated using statistical indices of coefficient of determination (R^2), mean square of error (RMSE), Mean Bias Error (MBE), and Coefficient of Nash-Sutcliffe (NSE).

Results and Discussion



©2024 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).

<https://doi.org/10.22067/jsw.2024.87064.1392>

The accuracy of an analytical method is the degree of agreement between the test results generated by the method and the true value. Upon examining the models, the M1 model was identified as the best due to its lowest RMSE and higher R^2 . ANN model results were evaluated using various performance measure indicators. The simulated outcome of the model indicated a strong association with actual data, where the correlation coefficient was above 0.95, and the MBE index was zero. Also, the RMSE value was positive and close to zero, and the N_{SE} value was above 0.75. Therefore artificial neural network method had high accuracy. In this study, mean annual minimum temperature was estimated using artificial neural network models (from March 10 to May 20). Comparison between the observed and calculated data showed that these data were in good agreement. Also, the results showed that temperature fluctuations were high between March 10 and March 31. From 2011 to 2017, an almost uniform temperature trend has been observed between March 10 and March 31. However, the years 2000, 2006, and 2020 showed a noticeable decrease in temperature. From 2018 to 2020, this trend of temperature reduction continued. In April, the temperature values were between 7 and 10 degrees Celsius. The years 2001, 2005, 2006, 2009, 2016, and 2019 had a noticeable decrease in temperature. In May, the mean minimum temperature was between 10 and 14 degrees Celsius. Therefore, the probability of frost occurrence in early-flowering cultivars was higher in late March than in April and May. The years 2000, 2004, 2005, 2012, 2015, 2019 and 2020 had the highest number of frost days in the last two decades.

Conclusion

The results showed that the artificial neural network method had a high performance in estimating the minimum temperature. The values of the statistical indicators were $R^2=0.963$, $RMSE=0.027^\circ C$, $MBE= 0$ and $NSE=0.966$ respectively. In addition, the ANN method performed well in estimating the number of critical frost days for pistachio crops. The results showed that, although reducing the amount of input data in models decreases their output precision, data-driven methods can still be useful tools for minimum temperature estimation.

Keywords: Abundance of frost, ANN, Critical temperature, Pistachio, Spring frost

مقاله پژوهشی

جلد ۳۸، شماره ۳، مرداد-شهریور ۱۴۰۳، ص. ۳۳۶-۳۲۱

ارزیابی دقت روش شبکه عصبی در برآورد سرمای دیررس بهاره در مناطق پسته کاری شهر کرمان

مبینا عبدالهی فوزی^۱ - بهرام بختیاری^{۲*} - کورش قادری^۲

تاریخ دریافت: ۱۴۰۲/۱۲/۰۸

تاریخ پذیرش: ۱۴۰۳/۰۲/۱۹

چکیده

سرمای دیررس بهاره تأثیر قابل توجهی بر اندام‌های آسیب‌پذیر گیاهان می‌گذارد. این رویداد در آسیا، آمریکای شمالی و اروپا بیش از سایر مخاطرات مرتبط با آب‌وهوا باعث زیان اقتصادی به کشاورزی شده است. همچنین این پدیده باعث کاهش عملکرد محصول در ایران شده است. آخرین آمار منتشر شده از سوی سازمان خواربار و کشاورزی ملل متحد (فائو) نشان می‌دهد که ایران یکی از بزرگ‌ترین تولیدکنندگان محصول پسته در جهان می‌باشد. استان کرمان سهم زیادی از سطح زیر کشت محصول پسته را به خود اختصاص داده است. خسارت سرمازدگی بهاره در پسته باعث کاهش عملکرد محصول در چند سال اخیر شده است. یک اصل مهم در مطالعه سرمازدگی، برآورد این پدیده است. در این تحقیق از روش شبکه عصبی مصنوعی مدل FFBP برای برآورد سرمای دیررس بهاره در محصول پسته شهرستان کرمان استفاده شد. بدین‌منظور داده‌های روزانه ایستگاه سینوپتیک شهر کرمان از سازمان هواشناسی کشور در بازه زمانی ۲۰۰۰-۲۰۲۰ اخذ شد. این داده‌ها شامل میانگین، بیشینه و کمینه دما، رطوبت نسبی، سرعت باد، فشار بخار اشباع و ساعات آفتابی می‌باشد. پنج ترکیب مختلف از این متغیرها به‌عنوان ورودی در روش شبکه عصبی برای مدل‌سازی دماهای کمینه در نظر گرفته شد. در نهایت ترکیب ۸ متغیره‌ای از بین مدل‌ها انتخاب گردید و شبیه‌سازی مقادیر دمای کمینه و محاسبه ویژگی‌های سرمای دیررس بهاره با آن انجام شد. عملکرد این روش با استفاده از شاخص‌های آماری ضریب تعیین، ریشه میانگین مربعات خطا، میانگین خطای انحراف و ضریب نش‌ساتکلیف ارزیابی شد. بررسی نتایج مدل‌سازی نشان داد با کاهش تعداد متغیرها دقت مدل‌ها کاهش می‌یابد. مدل M_1 با کمترین مقدار RMSE و بیشترین مقدار R^2 در بین سایر مدل‌ها عملکرد بهتری داشت. پس از شبیه‌سازی با روش شبکه عصبی مقادیر شاخص‌های $R^2=0.963$ و $MBE=0$ حاصل شد که نشان‌دهنده ارتباط قوی با داده‌های واقعی بود. علاوه بر آن، مقدار شاخص‌های $RMSE=0.027$ و $NSE=0.966$ کارایی بالای مدل را در برآورد نشان داد. بررسی میانگین دمای سالانه نشان داد نوسانات دما در بازه زمانی ۱۰-۳۱ مارس در مقایسه با ماه‌های آوریل و می زیاد می‌باشد. کاهش محسوس میانگین دمای سالانه در سال‌های ۲۰۰۰، ۲۰۰۶ و ۲۰۲۰ در این بازه نسبت به دیگر سال‌ها بیشتر بود. در ماه آوریل نیز سال‌های ۲۰۰۱، ۲۰۰۵، ۲۰۰۶، ۲۰۰۹، ۲۰۱۶ و ۲۰۱۹ کاهش دمای محسوسی داشتند. در ماه می باتوجه به میانگین دمای کمینه بین ۱۰ تا ۱۴ درجه سلسیوس احتمال سرمازدگی کمتری نسبت به ماه مارس و آوریل وجود داشت. نتایج نشان داد تعداد روزهای یخبندان بهاره مشاهداتی و برآوردی حاصل از روش شبکه عصبی انطباق خوبی با یکدیگر داشتند. این روش در برآورد تعداد روزهای بحرانی (دماهای کمینه کمتر و مساوی ۲ درجه سلسیوس) نیز دقت قابل قبولی داشت. همچنین سال‌های ۲۰۰۰، ۲۰۰۴، ۲۰۰۵، ۲۰۱۲، ۲۰۱۵، ۲۰۱۹ و ۲۰۲۰ بیشترین تعداد روزهای یخبندان بهاره و سال‌های ۲۰۰۶، ۲۰۱۶ و ۲۰۱۹ بیشترین تعداد روزهای بحرانی را در دو دهه‌ی اخیر دارا بودند. با بررسی نتایج می‌توان گفت روش شبکه عصبی مصنوعی در برآورد دمای کمینه و ویژگی‌های مرتبط با سرمای دیررس بهاره از دقت بالایی برخوردار است.

واژه‌های کلیدی: پسته، دمای بحرانی، سرمازدگی بهاره، شبکه عصبی مصنوعی، فراوانی یخبندان

۱ و ۲- به‌ترتیب دانشجوی دکتری مهندسی سازه‌های آبی و دانشیار بخش علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران
(^۳- نویسنده مسئول: Email: drbakhtiari@uk.ac.ir)

مقدمه

سرمازدگی بهاره معمولاً در دمای نزدیک به صفر اتفاق می‌افتد و اگر با گلدھی و مراحل ابتدایی تشکیل میوه همزمان شود خسارات جبران‌ناپذیری ایجاد می‌کند. کاهش دمای ناگهانی در این مراحل باعث از بین رفتن جوانه‌های در حال رشد (گل‌ها و میوه‌ها) و در نهایت موجب کاهش عملکرد یا نابودی محصول می‌شود. سرمای دیررس بهاره روی اندام‌های زایشی گل اثر می‌گذارد و موجب کاهش دانه‌گرده و عدم تشکیل میوه می‌شود (Graczyk & Szwed, 2020). دماهای پایین به‌ویژه سرمازدگی، بسته به عوامل مختلف مانند گونه، رقم، وضعیت فنولوژیک، شدت و مدت زمان سرما خسارات متعددی به محصولات باغی و زراعی وارد می‌کند (Larcher, 1981; Larcher & Bauer, 1981; Woodward, 1987). کاهش دمای ناگهانی و خارج از فصل سرما می‌تواند خسارات فراوانی به تولیدات بخش کشاورزی وارد کند و کمیت و کیفیت محصولات را تحت تأثیر قرار دهد (Abdollahi Fuzi et al., 2023). اشنایدر و دی‌ملو-آبرو (Snyder & de Melo-Abreu, 2005) نشان دادند که در اروپا خسارات ناشی از سرما و یخبندان بیشتر از سایر پدیده‌های اقلیمی است. همچنین سرمازدگی بهاره در چند سال اخیر خسارات فراوانی به بخش کشاورزی وارد کرده است. بسیاری از محققین خسارات ناشی از سرمازدگی را در قاره‌های مختلف گزارش کردند به‌عنوان مثال Gu et al., 2008; Hufkens et al., (Augspurger, 2009; 2012; Ningre & Colin, 2007; Kreyling et al., 2012) در قاره‌های آمریکا و اروپا. همچنین کاهش دمای شبانه در آوریل ۲۰۱۷ در اروپا موجب خسارت و کاهش عملکرد محصول سیب (۷۸ درصد) در مقایسه با هفت سال گذشته شده است (Drepper, 2022). در ایران نیز در سال‌های ۱۳۷۶، ۱۳۸۳ و ۱۳۸۴ بیش از ۶۰ درصد محصول پسته در مناطق پسته‌کاری استان کرمان در اثر سرمازدگی نابود شد (Tajabadipour et al., 2018). در بیشتر موارد، این سرمازدگی‌ها پس از طی یک دوره گرم که گیاه چرخه فنولوژیک خود را آغاز کرده رخ می‌دهد و موضوع باعث خسارات غیر قابل جبران می‌شود (Vitasse et al., 2018). بر اساس آمار سازمان غذا و کشاورزی ملل متحد (فائو) سالانه ۵ الی ۱۵ درصد از تولیدات کشاورزی در اثر سرمازدگی و یخبندان از بین می‌روند. پسته یکی از مهم‌ترین اقلام صادراتی ایران است که سهم زیادی از ارزش کل صادرات غیرنفتی ایران را به خود اختصاص داده است. کشور ایران بعد از ایالات متحده دومین تولیدکننده پسته جهان می‌باشد (Khatami et al., 2016). استان کرمان بزرگ‌ترین استان پسته‌خیز ایران محسوب می‌شود. بر اساس تحقیقات صورت‌گرفته، تحمل دمایی اندام‌های هوایی درخت پسته در هر یک از مراحل رشد خود متفاوت

است. دمای بحرانی جوانه باز شده ۲- درجه سلسیوس، جوانه باز نشده ۴- درجه سلسیوس، گل‌های باز شده ۲+ درجه سلسیوس و میوه‌ها ۲- درجه سلسیوس می‌باشد. این دماها نشانگر میزان حساسیت و مقاومت درخت در هر یک از مراحل رشد خود است. باتوجه به دماهای ذکر شده جوانه‌های باز نشده به دمای ۴- درجه سلسیوس مقاوم‌ترین و گل‌های باز شده با دمای ۲+ درجه سلسیوس حساس‌ترین اندام در مقابل کاهش دما می‌باشد (Gholipour, 2007). در ادامه به بررسی پیشینه تحقیق در ایران و سایر نقاط دنیا پرداخته شده است.

انتظاری و همکاران (Entezari et al., 2011) به بررسی شبکه عصبی MLP در برآورد یخبندان‌های دیررس و زودرس در کرمانشاه پرداختند. نتایج نشان داد شبکه عصبی MLP دقت بالایی در برآورد یخبندان‌ها دارد. ذوالفقاری و همکاران (Zolfghari et al., 2012) برآورد تاریخ آخرین یخبندان‌های بهاری در غرب و شمال غرب ایران را با استفاده از روش شبکه‌ی عصبی مصنوعی انجام دادند. نتایج آنها نشان داد شبکه عصبی پس‌انتشار در برآورد آخرین روز یخبندان بهاری دقت بالایی دارد. آشکار شدن تأثیر عامل ارتفاع و توپوگرافی با وضوح بالا در طول فصل یخبندان از دیگر نتایج این پژوهش بود. تقوی و امیدزاده (Taghavi & Omidzade, 2015) برآورد سرمای دیررس بهاره را با استفاده از شبکه عصبی MLP در خرم‌آباد انجام داده و نتایج آنها نشان داد که استفاده از برخی توابع موجود در نرم‌افزار MATLAB جهت برآورد سرمای دیررس بهاره و دمای کمینه کارایی بالایی دارند. مسگری و همکاران (Mesgari et al., 2020) به ارزیابی برخی توابع انتقال در شبکه‌های عصبی مصنوعی جهت برآورد دمای کوتاه‌مدت کمینه در سنندج پرداختند. نتایج نشان داد توابع انتقال عملکرد بالایی در برآورد دمای کمینه و سرما دارند.

آناندھی و همکاران (Anandhi et al., 2013) برآورد دمای ۱۲ ساعت آینده را با روش‌های شبکه عصبی، جهت حفاظت از محصولات کشاورزی ضروری دانستند. فونتس و همکاران (Fuentes et al., 2018) به تعیین دمای کمینه با مدل شبکه عصبی از نوع پس‌انتشار در شیلی پرداختند. نتایج آنها نشانگر عملکرد خوب شبکه عصبی در تعیین دمای کمینه جهت تشخیص یخبندان بود. هرناندز و همکاران (Hernandez et al., 2019) از مدل‌های هوشمند جهت تخمین دمای کمینه در آرژانتین استفاده کردند. نتایج نشان داد این مدل‌ها توانایی بالایی در تخمین دماهای کمینه دارند. نوه و همکاران (Noh et al., 2021) با بررسی دقت مدل طبقه‌بندی سرما به این نتیجه رسیدند که استفاده از الگوریتم‌های یادگیری ماشین (ML) (روش‌های جنگل تصادفی، ماشین‌بردار پشتیبان و

شده در زمینه سرمای دیررس بهاره به این نتیجه رسیدند که در برآورد سرمای دیررس بهاره روش‌های داده‌محور کمتر موردتوجه قرار گرفته است. این روش‌ها به دلیل سرعت و دقت بالا می‌توانند نتایج قابل‌قبولی را ارائه دهند. بنابراین هدف از انجام این مطالعه، مدل‌سازی مقادیر دمای کمینه مؤثر در وقوع سرمای دیررس بهاره با استفاده از روش شبکه عصبی است تا بتوان با ارائه مدل‌هایی، گامی در راستای بهبود برنامه ریزی‌های مدیریتی در مواجهه با کاهش دما برداشت.

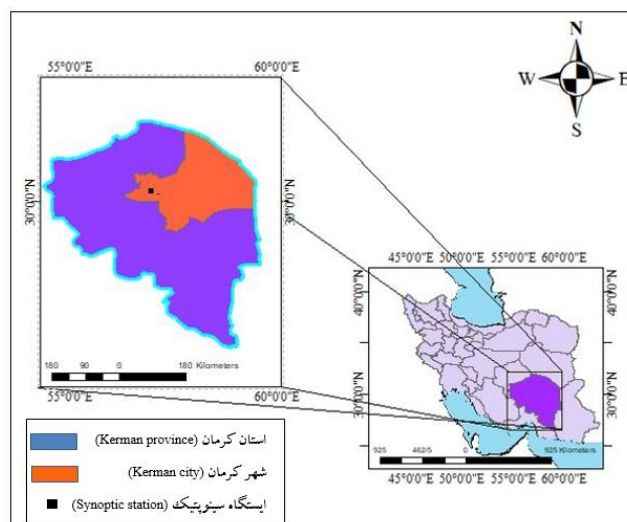
مواد و روش‌ها

منطقه مطالعاتی

شهرستان کرمان با مساحت ۲۴۰ کیلومتر مربع با طول و عرض جغرافیایی ۵۷/۰۷۲ درجه شرقی و ۳۰/۲۸ درجه شمالی واقع شده است (شکل ۱). ایستگاه مورد مطالعه در محدوده طول و عرض جغرافیایی ۵۶/۹۶ درجه شرقی و ۳۰/۲۶ درجه شمالی واقع شده است. ارتفاع ایستگاه از سطح دریاهای آزاد ۱۷۵۴ متر می‌باشد. اقلیم استان کرمان بر اساس طبقه‌بندی دمارتن خشک می‌باشد (Khalili et al., 2022). پسته یکی از محصولات عمده این شهرستان می‌باشد. این محصول جایگاه ویژه‌ای در صادرات کشور ایفا می‌کند. شرایط اقلیمی ایجاد شده در چند سال اخیر شامل کاهش بارندگی، افزایش دما، تبخیر و کاهش رطوبت نسبی باعث تأثیر مستقیم و غیرمستقیم بر عملکرد این محصول شده است.

درخت تصمیم) در تعیین یخبندان‌ها در باغداری در کره‌جنوبی می‌تواند به کاهش آسیب ناشی از آن کمک کند. تران و همکاران (Tran et al., 2021) به برآورد دما با استفاده از شبکه‌های عصبی و ماشین بردار در کره پرداختند که نتایج گویای عملکرد خوب این روش‌ها در برآورد دما بود.

با توجه به اینکه سرمازدگی تأثیر اکولوژیکی و اقتصادی فراوانی بر کشاورزی و جنگل‌داری دارد و آسیب ناشی از آن بر رشد، توانایی رقابتی و توزیع گیاهان زیاد است (Zohner et al., 2020)، انجام تحقیقات مرتبط با این مسئله ضرورت دارد. علاوه بر خسارت وارده به کشاورزان در زمینه سرمازدگی محصولات کشاورزی، می‌توان گفت ارزیابی خسارت ناشی از این پدیده توسط صندوق بیمه کشاورزی نیز از اهمیت زیادی برخوردار است. تحلیل غرامت‌های پرداخت شده توسط صندوق بیمه کشاورزی نشان می‌دهد در بین ۱۲ محصول استراتژیکی که تحت پوشش بیمه بوده‌اند، بیشترین خسارت در بین حوادث طبیعی مربوط به سرمازدگی بوده است؛ بنابراین هر اقدامی در بعد پژوهشی، حمایتی و حفاظتی در این مورد می‌تواند کمکی بزرگی به اقتصاد زراعی کشور و معیشت کشاورزان باشد (Khalili, 2014). همچنین آسیب گسترده ناشی از این پدیده علاوه بر پیامدهای منفی در کشاورزی و جنگل‌داری به افزایش سطح CO₂ موجود در جو و کاهش فتوسنتز کمک می‌کند (Bascietto et al., 2018). بنابراین بررسی مقدار و شدت سرمای دیررس بهاره و مدل‌سازی و برآورد آن امری ضروری است (Vitasse et al., Hufkens et al., 2012). همچنین در مطالعه‌ای عبدالهی فوزی و همکاران (Abdollahi Fuzi et al., 2023) با تحلیل سیستماتیک آثار منتشر



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه (ترسیم توسط پژوهشگر)

Figure 1- The geographical location of the study area (Source: own elaboration)

جدول ۱- آمار توصیفی داده‌های هواشناسی شهر کرمان طی سال‌های ۲۰۲۰-۲۰۰۰

Table 1- Descriptive statistics of meteorological data of Kerman during the years 2000-2020

متغیرها Variables	u ₂ (m s ⁻¹)	RH (%)	T _{max} (°C)	T _{min} (°C)	T _m (°C)	n (h)	e _s (hpa)
میانگین Mean	2.93	29.62	25.78	7.98	17.39	9.29	23.76
انحراف معیار SD	1.93	17.74	8.86	8.21	8.79	3	23.76
کمینه MIN	0	4.25	-2.8	-20.8	-8.4	0	23.76
بیشینه MAX	11.63	97.38	41.6	26.6	32.9	13.5	23.76

داده‌های مورد استفاده

در این مطالعه از داده‌های روزانه ۲۱ ساله ایستگاه سینوپتیک کرمان (از سال ۲۰۰۰ تا ۲۰۲۰) استفاده شد. داده‌های خام اولیه مشتمل بر ۶۹۰۳۹ داده از تاریخ ۲۰۰۰/۱/۱ الی ۲۰۲۰/۱۲/۳۰ بوده است. این داده‌ها از سایت سازمان هواشناسی اخذ شد. ارتفاع استاندارد برای اندازه‌گیری سرعت باد، ارتفاع ۲ متری است. باتوجه به اینکه داده‌های اولیه سرعت باد در ارتفاع ۱۰ متری اندازه‌گیری شده است جهت استفاده در پژوهش حاضر به ارتفاع ۲ متری تبدیل شده است (Allen et al., 1998). داده‌های مورد استفاده شامل: مقادیر میانگین سرعت باد در ارتفاع ۲ متری (u₂)، میانگین رطوبت نسبی (RH)، بیشینه دما (T_{max})، کمینه دما (T_{min})، میانگین دما (T_m)، ساعات آفتابی (n) و میانگین فشار بخار اشباع (e_s) بوده است. این داده‌ها جهت برآورد دمای کمینه استفاده شد. ابتدا متغیرهای T_{max}، T_m، RH، u₂، n و دماهای کمینه یک روز قبل و دو روز قبل به‌عنوان ورودی و دمای کمینه به‌عنوان خروجی به مدل شبکه عصبی وارد شد. پس از برآورد دمای کمینه دیگر ویژگی‌های مرتبط با سرمای دیررس بهاره شامل میانگین سالانه دما، تعداد روزهای یخبندان بهاره و روزهای بحرانی نیز محاسبه شد.

ارزیابی کیفی متغیرهای هواشناسی از مهم‌ترین شروط انجام تحلیل‌های آماری در پژوهش‌های هواشناسی و سایر علوم می‌باشد (Shonwiese, 1977). در این پژوهش بازسازی داده‌های مقفود با استفاده از روش محاسبه میانگین داده‌های قبل و بعد در نرم‌افزار IBM SPSS Statistics 26 انجام شده است. پس از بازسازی داده‌های گمشده به اعتبارسنجی داده‌ها پرداخته شد. به این منظور از آزمون همگنی استفاده شد. تحلیل همگنی از جمله چالش‌های مهم تشخیص روند در سری داده‌های اقلیمی است. اگر علل اصلی ناهمگنی داده‌های مورد بررسی نامعلوم باشد نتایج حاصل از تحلیل‌ها انحراف زیادی از واقعیت خواهد داشت؛ بنابراین بررسی همگنی داده‌ها

در مطالعات اقلیمی امری ضروری است. آزمون همگنی پیشنهاد در یافتن ناهمگنی‌های نقاط میانی سری زمانی توانایی بیشتری داشته و از جمله آزمون‌هایی است که زمان بروز ناهمگنی را نیز گزارش می‌کند (Buishand, 1982).

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات است که به‌صورت موازی قرار گرفته و عملکردی شبیه به مغز انسان دارد. شبکه‌های عصبی ابزارهای جدیدی هستند که در سیستم‌های غیرخطی تحلیل و شبیه‌سازی انجام می‌دهند (Hopfield, 1982). یک شبکه عصبی مصنوعی از نورون‌های مصنوعی تشکیل شده است. نورون یا گره کوچک‌ترین واحد پردازش اطلاعات می‌باشد که اساس کار شبکه عصبی است (Chen et al., 2017). هریک از این نورون‌ها، ورودی‌ها را دریافت می‌کند و پس از پردازش روی آنها یک خروجی تولید می‌کند (Sadorsky, 2006). شبکه‌های عصبی مصنوعی از نظر نوع شبکه به دو گروه شبکه عصبی پیش‌خور (Feedforward Neural Network) و شبکه عصبی پس‌خور (Feedback Neural Network) تقسیم می‌شوند. شبکه عصبی پیش‌خور نوعی شبکه‌ی عصبی است که به آن پرسپترون چندلایه هم گفته می‌شود؛ در واقع چندین لایه پرسپترون که به هم متصل هستند یک شبکه‌ی عصبی پیش‌خور را تشکیل می‌دهند (Cybenko, 1989). یک شبکه‌ی عصبی پیش‌خور لایه‌ی ورودی، لایه‌های میانی یا نهان و لایه‌ی خروجی دارد که به هم متصل هستند. این لایه‌ها از چندین پرسپترون یا نورون تشکیل شده‌اند. خروجی این شبکه به‌صورت معادله (۱) مدل می‌شود.

$$Y_i = \sum_{j=1}^n W_{ij} X_{ij} + \theta_i \quad (1)$$

که در آن، X_{ij} سیگنال ورودی از j امین نورون (در لایه ورودی) متغیر ورودی، W_{ij} وزن اتصال نورون j به نورون i (در لایه مخفی)

$$MBE = \frac{\sum_i^n (P_i - O_i)}{n} \quad (5)$$

MBE به مقایسه انحراف واقعی بین مقادیر مشاهده‌ای و مدل سازی شده می‌پردازد. واحد MBE همان واحد متغیر مشاهده‌ای است که توسط مدل سازی می‌شود. مقدار ایده‌آل این شاخص صفر می‌باشد.

ریشه میانگین مربعات خطا (RMSE) باتوجه به معادله (۶) محاسبه می‌شود (Moustris et al., 2010).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (6)$$

تفاوت بین مقادیر مشاهده‌ای و مدل سازی شده در یک مدل با RMSE تعیین می‌شود. دلیل استفاده از RMSE یکسان بودن بعد و مقیاس آن با متغیر مشاهده‌ای است که توسط مدل سازی می‌شود. مقدار RMSE همواره مثبت است و در حالت ایده‌آل صفر است و هر چه به صفر نزدیک تر باشد نشان‌دهنده قدرت بالای مدل در برآوردها می‌باشد (Gunhan et al., 2005). ضریب نش ساتکلیف (NSE) از معادله (۷) محاسبه می‌شود (Nash & Sutcliffe, 1970).

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (P_i - P_{ave})^2} \quad (7)$$

ضریب نش ساتکلیف از $-\infty$ تا $+1$ متغیر است. اگر مقدار آن برابر یک باشد تناسب کامل بین داده‌های مشاهده‌شده و مدل سازی شده وجود دارد (Moriasi et al., 2007). اگر این مقدار بیشتر از 0.75 باشد نشان‌دهنده مدل سازی خیلی خوب، بین 0.65 تا 0.75 مدل سازی خوب، بین 0.5 تا 0.65 مدل سازی رضایت‌بخش، بین 0.4 تا 0.5 مدل سازی قابل قبول و کمتر از 0.4 مدل سازی نامطلوب است (Motovilov et al., 1999). هر چه این ضریب به 1 نزدیک تر باشد کارایی مدل بالاتر است (Littlewood et al., 2007).

پس از مقایسه شاخص‌های عملکرد شبکه، به بررسی یخبندان و وقوع سرمازدگی پرداخته شد. با توجه به اینکه درختان پسته بسته به ارقام مختلف (زودگل، متوسط گل و دیرگل) مراحل رشد و جوانه‌زنی متفاوتی دارند، جهت اطمینان بازه 20 اسفند تا 20 اردیبهشت به‌عنوان مرحله حساس فنولوژیکی در شهر کرمان در نظر گرفته شده است. در این بازه زمانی اگر درخت پسته در هر کدام از مراحل توسعه گل باشد با کاهش دما دچار آسیب سرمازدگی بهاره خواهد شد. برای این منظور دمای مشاهداتی و برآوردی حاصل از روش شبکه عصبی مصنوعی جداسازی شد. پس از آن تغییرات دمای میانگین سالانه، تعداد روزهای یخبندان (دمای صفر و زیر صفر درجه سلسیوس)، روزهای بحرانی (دمای زیر 2 درجه سلسیوس که در مراحل توسعه گل به

است، θ_i نیز آرببی (bias) نورون i خواهد بود.

در این مطالعه از شبکه عصبی مدل پیش‌رونده با آموزش پس-انتشار (FFBP) به دلیل کاربرد بیشتر در مسائل هوا و اقلیم‌شناسی و برآورد متغیرهای اقلیمی استفاده شده است. همچنین در این شبکه از الگوریتم آموزشی لونبرگ مارکوارت و توابع فعال‌سازی سیگموئید شامل تابع لجستیک معادله (۲) و تانژانت سیگموئید معادله (۳) استفاده شده است.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

معیارهای ارزیابی عملکرد شبکه

ارزیابی یک مدل با قیاس بین مقادیر مشاهده‌ای و مدل سازی شده انجام می‌گیرد. شاخص‌های مختلفی برای ارزیابی و اعتبارسنجی مدل‌ها وجود دارد (Shcherbakov et al., 2013). در این پژوهش جهت ارزیابی عملکرد و اعتبارسنجی مدل‌ها از ضریب تعیین (R^2)، میانگین انحراف خطا (MBE)، جذر میانگین مربعات خطا ($RMSE$)، و ضریب نش-ساتکلیف (NSE) استفاده شده است. در ادامه معادلات مربوط به شاخص‌های عملکرد شبکه تشریح شده است. در این روابط، P_i مقدار شبیه‌سازی شده، O_i مقدار اندازه‌گیری شده، \bar{P} میانگین مقادیر شبیه‌سازی شده، \bar{O} میانگین مقادیر اندازه‌گیری شده و N برابر تعداد داده‌ها می‌باشد. ضریب تعیین باتوجه به معادله (۴) تعیین می‌شود (Krause et al., 2005).

$$R^2 = \frac{\left(\sum (P_i - \bar{P})(O_i - \bar{O})\right)^2}{\sum (P_i - \bar{P})^2 \sum (O_i - \bar{O})^2} \quad (4)$$

کمیت R^2 نسبتی از واریانس بر حسب متغیر وابسته است که از متغیرهای مستقل قابل پیش‌بینی است. ضریب تعیین بین 0 و 1 است و اگر بیشتر از 0.6 باشد نشان می‌دهد متغیرهای مستقل تا حد زیادی توانسته‌اند تغییرات متغیر وابسته را تبیین کنند. میانگین انحراف خطا (MBE) باتوجه به معادله (۵) محاسبه می‌شود

- 1- Feed –Forward Backpropagation
- 2- Coefficient of Determination
- 3- Mean Bias Error
- 4- Root Mean Square Error
- 5- Coefficient of Nash - Sutcliffe

نتایج و بحث

پسته آسیب جدی وارد می‌کند) محاسبه شد.

برآورد دمای کمینه با روش شبکه عصبی

روش مورد استفاده در این پژوهش، روش شبکه عصبی پیش‌رونده با آموزش پس‌انتشار (FFBP) می‌باشد. در این روش ۸ متغیر هواشناسی شامل T_m ، T_{max} ، $T_{min(t-1)}$ ، $T_{min(t-2)}$ ، RH ، n ، u_2 و e_s به‌عنوان ورودی مدل‌ها و متغیر دمای کمینه به‌عنوان خروجی مدل در نظر گرفته شده است. برای مقایسه بهتر چند مدل از ترکیبات مختلف با متغیرهای ورودی متفاوت در نظر گرفته شده است. در جدول ۲ نام-گذاری مدل‌های مختلف (ترکیب متغیرها) نشان داده شده است. در همه مدل‌های مورد بررسی دمای کمینه به‌عنوان خروجی مدل در نظر گرفته شده است. تقسیم‌بندی داده‌ها جهت استفاده در مراحل آموزش، واسنجی و آزمایش به‌صورت تصادفی توسط شبکه انجام شد. ۷۰ درصد داده‌ها جهت استفاده در مرحله آموزش، ۱۰ درصد داده‌ها جهت استفاده در مرحله صحت‌سنجی، ۱۰ درصد جهت استفاده در مرحله آزمایش و ۱۰ درصد جهت شبیه‌سازی مورد استفاده قرار گرفته است.

نتایج حاصل از مدل‌سازی شبکه عصبی مصنوعی

برای مقایسه و انتخاب بهترین حالت مدل‌سازی در شبکه عصبی مصنوعی با مدل FFBP، توابع محرک تانزانت سیگموئید (tan-sig) و لوگ سیگموئید (log-sig) و الگوریتم آموزشی لونیگ مارکواریت (LM) انتخاب شدند. سپس تعداد لایه‌ها و نورون‌های هر حالت متغیر در نظر گرفته شد. مقادیر R^2 و RMSE در هر حالت، در دو مرحله آموزش و آزمون محاسبه گردید. در نهایت مدلی که کمترین مقدار RMSE و بیشترین مقدار R^2 را دارا بود به‌عنوان بهترین حالت انتخاب شد و به‌عنوان روش برتر جهت شبیه‌سازی دمای کمینه استفاده شد. در جدول ۳ مدل‌های تعیین شده در دو مرحله آموزش و آزمون با روش شبکه عصبی مدل FFBP مورد بررسی قرار گرفتند. بر اساس نتایج به‌دست آمده از جدول ۳ و بررسی مدل‌های تعیین شده در روش شبکه عصبی مدل FFBP، مقادیر R^2 با کاهش تعداد متغیرها کاهش و مقدار RMSE، تعداد نورون‌ها و لایه‌های پنهان افزایش یافته است.

جدول ۲- نام‌گذاری مدل‌های مورد استفاده در شبکه عصبی مصنوعی

Table 2- Nomenclature of the models used in the neural network method


ترکیب مدل‌ها Combining models	نام اختصاری مدل Name of the model
$e_s, u_2, n, RH, T_{min(t-2)}, T_{min(t-1)}, T_{max}, T_m$	M ₁
$RH, T_{min(t-2)}, T_{min(t-1)}, T_{max}, T_m$	M ₂
e_s, u_2, n, RH	M ₃
T_{max}, m	M ₄
$T_{min(t-2)}, T_{min(t-1)}$	M ₅

جدول ۳- مقایسه مقادیر R^2 و RMSE در مراحل آموزش و آزمون با استفاده از روش FFBPTable 3- Comparison of R^2 and RMSE values in the training and testing phases using the FFBP method

مدل Model	الگوریتم آموزشی Training algorithm	تابع فعال‌سازی Activation function	تعداد لایه‌ها Number of layers	تعداد نورون‌ها Number of neurons	آموزش Training		آزمون Testing	
					R^2	RMSE (°C)	R^2	RMSE (°C)
M1	LM	tan-sig	2	4	0.985	0.029	0.985	0.029
M1	LM	log-sig	2	4	0.982	0.032	0.985	0.029
M2	LM	tan-sig	2	4	0.982	0.032	0.982	0.029
M2	LM	log-sig	3	10	0.973	0.030	0.972	0.032
M3	LM	tan-sig	2	4	0.963	0.048	0.962	0.047
M3	LM	log-sig	5	10	0.957	0.050	0.957	0.050
M4	LM	tan-sig	5	10	0.952	0.053	0.953	0.053
M4	LM	log-sig	6	10	0.932	0.057	0.932	0.057
M5	LM	tan-sig	4	10	0.947	0.065	0.947	0.065
M5	LM	log-sig	5	10	0.920	0.083	0.920	0.083

*تعداد لایه‌ها و نورون‌های هر مدل با سعی و خطا انتخاب شد.


*The number of layers and neurons of each model is selected by trial and error




شکل ۲- ساختار شبکه FFBP مورد استفاده برای مدل سازی با مدل M1 (توسط پژوهشگر)
 Figure 2- FFBP network structure used for modeling with M1 model (Source: own elaboration)

مقادیر خطایی که به صفر نزدیک شده است، بیشترین مقدار فراوانی را دارا بوده و این مطلب نشان دهنده عملکرد خوب شبکه عصبی با مدل FFBP است (شکل ۳).
 مقادیر R^2 در مرحله آموزش، آزمون و مرحله کل برابر 0.985 و 0.982 است. مقادیر خطای بین مقادیر برآوردی و مشاهداتی نیز بین 0.017 تا 0.02 است (شکل ۴).
 به اینکه مقادیر R^2 بسیار نزدیک به ۱ و مقادیر خطا نیز نزدیک به صفر است می توان نتیجه گرفت که روش ارائه شده از عملکرد بالایی جهت برآورد دمای کمینه برخوردار است.

همچنین تابع محرک tan-sig مقادیر R^2 و RMSE بهتری را نسبت به تابع محرک log-sig ارائه داده است. مدل M_1 با ترکیب ۸ متغیر، با تابع محرک tan-sig، تعداد ۲ نورون و چهارلایه پنهان بالاترین مقدار R^2 و کمترین مقدار RMSE را دارد؛ بنابراین مدل M_1 به عنوان بهترین مدل انتخاب و مبنای مدل سازی در شبکه عصبی قرار گرفت. در شکل ۲ ساختار شبکه FFBP برای مدل سازی با مدل M_1 نشان داده شده است.
 نمودار مربوط به مقادیر و فراوانی خطا در سه مرحله آموزش، صحت سنجی و آزمون پس از مدل سازی شبکه با مدل M_1 نشان داد،



شکل ۳- نمایش مقادیر فراوانی خطای شبکه FFBP در مراحل آموزش، صحت سنجی و آزمون (ترسیم توسط پژوهشگر)
 Figure 3- Error display of FFBP network in the phases of training, validation and testing (Source: own elaboration)



شکل ۴- نمودار: دمای کمینه برآوردی و دمای کمینه مشاهداتی، (الف) در مرحله آموزش، (ب) مرحله صحت‌سنجی، (پ) مرحله آزمون، (ت) مرحله کل (ترسیم توسط پژوهشگر)

Figure 4- Graph: Estimated and observed minimum temperatures, (a):Training, (b):Validation, (c):Test, (d): All (Source: own elaboration)

حالت مدل‌سازی و شبیه‌سازی نزدیک به صفر بوده است. همچنین در هر دو مرحله، در روش شبکه عصبی مصنوعی مقدار ضریب نش-ساتکلیف بین ۰/۹۶۶ تا ۰/۹۶۸ است. با توجه به اینکه مقدار این ضریب بالاتر از ۰/۷۵ است؛ بنابراین مدل‌سازی و شبیه‌سازی توسط روش شبکه عصبی مصنوعی خیلی خوب ارزیابی می‌شود. بنابراین تناسب بسیار خوبی بین داده‌های مشاهداتی و مدل‌سازی شده وجود دارد.

بررسی شاخص‌های عملکرد شبکه

مقادیر R^2 در جدول ۴ در مراحل مدل‌سازی و شبیه‌سازی بالای ۰/۹۵ است بنابراین دقت این روش در برآورد دمای کمینه بسیار خوب ارزیابی شد. مقدار شاخص MBE در حالت ایده‌آل صفر است. این مقدار نیز بر اساس جدول ۴ در مراحل مدل‌سازی و شبیه‌سازی صفر می‌باشد؛ بنابراین می‌توان عملکرد این روش را بالا ارزیابی کرد. مقدار RMSE نیز مثبت و در حالت ایده‌آل صفر است. مقدار این شاخص در

جدول ۴- شاخص‌های عملکرد شبکه در مرحله مدل‌سازی و شبیه‌سازی
 Table 4- Network performance indicators in the modeling and simulation phases

شاخص عملکرد Performance index	مقادیر Values	
	مدل‌سازی Modeling	شبیه‌سازی Simulation
R ²	0.985	0.963
MBE (OC)	0.000	0.000
RMSE (OC)	0.029	0.027
NSE	0.968	0.966

(شکل ۶). این روش در برآورد تعداد روزهای یخبندان بهاره طی ۲۱ سال گذشته عملکرد خوبی داشت و تعداد روزهای یخبندان بهاره برآورد شده حاصل از این روش با تعداد روزهای یخبندان بهاره حاصل از داده‌های مشاهده‌ای اختلاف چندانی ندارد. تعداد روزهای یخبندان بهاره در سال‌های ۲۰۰۲، ۲۰۰۳، ۲۰۰۵، ۲۰۰۶، ۲۰۰۷، ۲۰۱۲، ۲۰۱۳، ۲۰۱۵، ۲۰۱۷، ۲۰۱۸، ۲۰۱۹ و ۲۰۲۰ دقیقاً با تعداد روزهای یخبندان بهاره در داده‌های مشاهده‌ای برابر بود. در دیگر سال‌ها اختلاف یک روزه مشاهده شد. جهت تعیین تعداد روزهای یخبندان بهاره دماهای صفر و زیر صفر درجه سلسیوس لحاظ شده است. این دماها در مرحله توسعه گل در پسته باعث تغییر رنگ یا قهوه‌ای شدن و تنش یخ‌زدگی می‌شود. در این شرایط شیره درون آوندی درخت یخ می‌زند و باعث کاهش یا عدم رسیدن مواد غذایی و درنهایت از بین رفتن محصول می‌شود. این دماها در ارقام زودگل مثل کله‌قوچی می‌تواند باعث خسارات جبران‌ناپذیری شود.

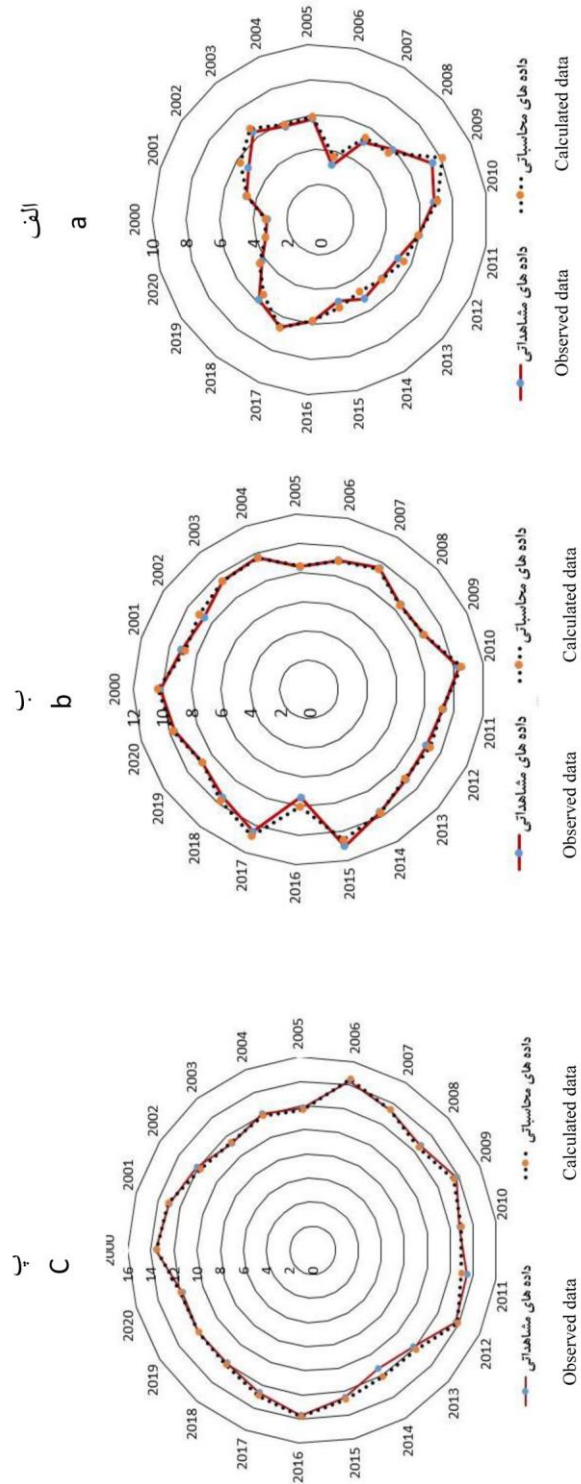
بررسی تعداد روزهای بحرانی

تعداد روزهای بحرانی (دماهای کمینه کمتر و مساوی ۲ درجه سلسیوس) بر اساس داده‌های مشاهده‌ای و محاسباتی حاصل از روش شبکه عصبی نشان داد که این روش در برآورد تعداد روزهای بحرانی دقت قابل قبولی داشته است (شکل ۷). تعداد روزهای بحرانی بر اساس داده‌های مشاهده‌ای و محاسباتی در سال‌های ۲۰۰۵، ۲۰۰۶، ۲۰۰۷، ۲۰۱۰، ۲۰۱۱، ۲۰۱۴، ۲۰۱۵، ۲۰۱۷ و ۲۰۲۰ یکسان بود. در دیگر سال‌ها اختلاف یک یا دو روزه مشاهده شد.

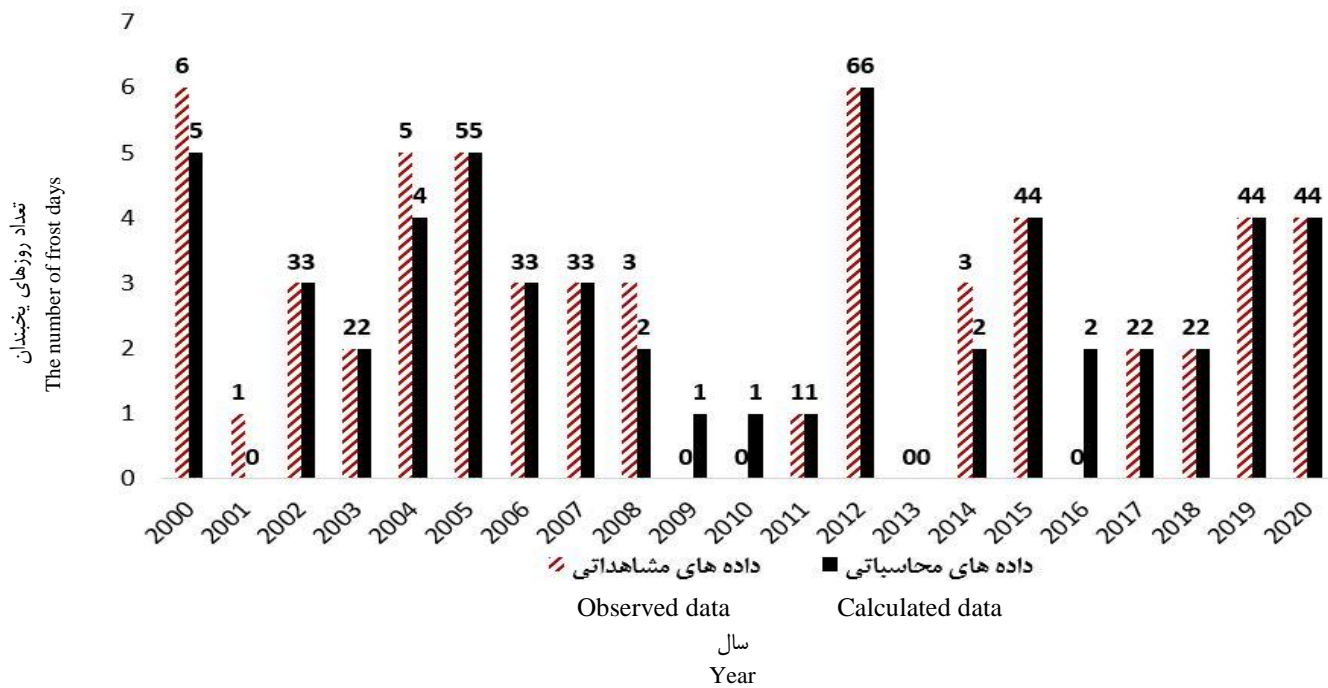
مقادیر میانگین دمای کمینه سالانه داده‌های مشاهده‌ای و محاسباتی حاصل از روش شبکه عصبی مصنوعی که منجر به بروز سرمازدگی بهاره در محصول پسته می‌شود، نشان داد که این داده‌ها تا حد زیادی بر هم منطبق‌اند (شکل ۵). اما در ماه‌های آوریل و می این انطباق بیشتر است. نوسانات دمایی در بازه زمانی ۱۰ مارس تا ۳۱ مارس نسبت به ماه‌های آوریل و می بیشتر است. سال ۲۰۱۱ تا ۲۰۱۷ روند تقریباً یکنواختی در بازه زمانی ۱۰ تا ۳۱ مارس مشاهده شد. اما سال‌های ۲۰۰۰، ۲۰۰۶ و ۲۰۲۰ روند کاهش میانگین دمای کمینه بسیار زیاد بود. از سال ۲۰۱۸ تا ۲۰۲۰ این روند کاهش دمایی همچنان ادامه داشت. باتوجه به اینکه دمای بحرانی محصول پسته در مراحل مختلف توسعه گل از ۶- تا ۲ درجه سلسیوس است؛ بنابراین در این بازه زمانی احتمال وقوع سرمازدگی‌های بهاره برای ارقامی که در مراحل مختلف توسعه گل بوده‌اند، بیشتر بوده است. در ماه آوریل (ب) مقادیر دمایی بین ۷ تا ۱۰ درجه سلسیوس بود و سال‌های ۲۰۰۱، ۲۰۰۵، ۲۰۰۶، ۲۰۰۹، ۲۰۱۶ و ۲۰۱۹ کاهش دمای محسوسی داشت. در ماه می (پ) مقادیر میانگین دمای کمینه بین ۱۰ تا ۱۴ درجه سلسیوس بود که احتمال سرمازدگی کمتر در ماه آوریل نسبت به مارس است.

بررسی تعداد روزهای یخبندان بهاره

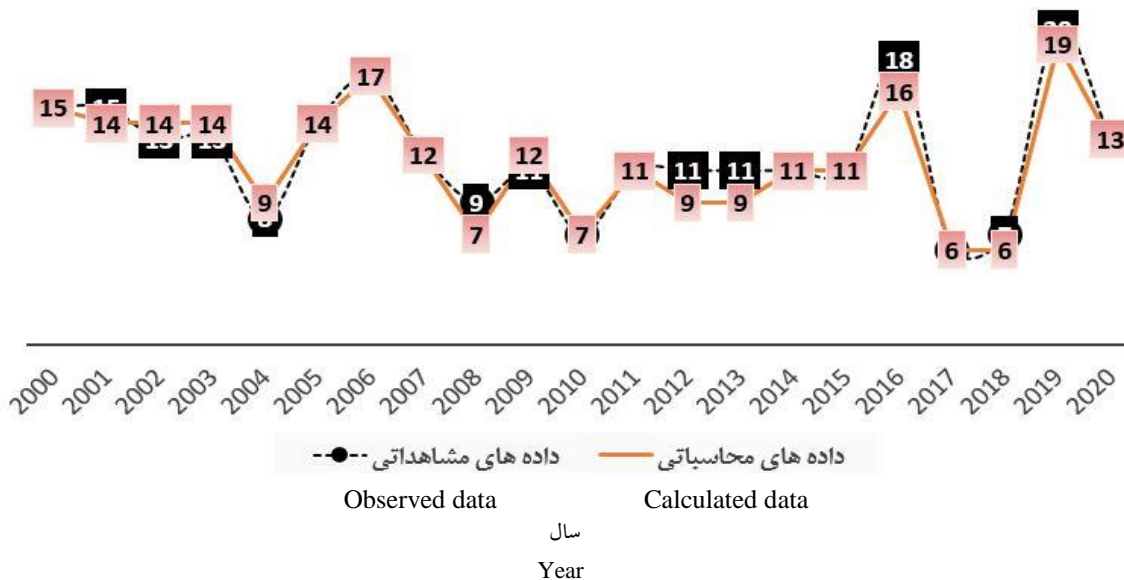
بررسی تعداد روزهای یخبندان بهاره در بازه زمانی ۱۰ مارس تا ۲۰ می (از ۷۰ امین تا ۱۴۱ امین روز ژولینوسی) با داده‌های مشاهده‌ای و داده‌های محاسباتی حاصل از روش شبکه عصبی مصنوعی نشان داد سال‌های ۲۰۰۰، ۲۰۰۴، ۲۰۰۵، ۲۰۱۲، ۲۰۱۵، ۲۰۱۹ و ۲۰۲۰ بیشترین تعداد روزهای یخبندان بهاره در دو دهه‌ی اخیر را داشتند



شکل ۵- میانگین سالانه دمای کمینه شهر کرمان، (الف) از ۱۰ مارس تا ۳۱ مارس، (ب) ماه آوریل، (پ) از اول تا ۲۰ می (ترسیم توسط پژوهشگر)
 Figure 5- Annual mean minimum temperature of Kerman city, (a) from May 1 to 20 (Source: own elaboration)



شکل ۶- تعداد روزهای یخبندان بهاره در طی سال‌های ۲۰۲۰-۲۰۰۰ (ترسیم توسط پژوهشگر)
 Figure 6- Calculation of the number of frost days during the years 2000 to 2020 (Source: own elaboration)



شکل ۷- تعداد روزهای بحرانی در طی سال‌های ۲۰۲۰-۲۰۰۰ (ترسیم توسط پژوهشگر)
 Figure 7- Calculation the number of critical days during the years 2000-2020 (Created by the author)

روش شبکه عصبی مصنوعی و محاسبه مقادیر شاخص‌های عملکرد شبکه می‌توان نتیجه گرفت که این روش در برآورد دمای کمینه

نتیجه گیری

با بررسی مقادیر دمای کمینه مشاهداتی و محاسباتی حاصل از

زمانی ۲۰ اسفند تا ۱۰ فروردین و احتمال خسارت به ارقام زودگل که در مراحل ابتدایی توسعه گل (جوانه زنی و باز شدن جوانه درخت پسته) زیاد است. همچنین با برآورد تعداد روزهای یخبندان و روزهای بحرانی مشخص شد که تعداد روزهای یخبندان و روزهای بحرانی در چند سال اخیر در بازه زمانی ۱۰ مارس تا ۲۰ می افزایش داشته است. بنابراین پیشنهاد می شود از دیگر روش های داده محور مانند نروفازی، روش های عصبی بازگشتی و یا الگوریتم های فرایتناری جهت پیش آگاهی رخدادهای سرمازدگی بهاره استفاده شود و نتایج آن با نتایج دیگر تحقیقات مرتبط مقایسه شود.

عملکرد خوبی داشته است. مقادیر شاخص های R^2 ، MBE، RMSE و NSE در مرحله مدل سازی به ترتیب ۰/۹۸۵، ۰، درجه سلسیوس، ۰/۰۲۹ درجه سلسیوس و ۰/۹۶۸ و در مرحله شبیه سازی ۰/۹۶۳، ۰، درجه سلسیوس، ۰/۰۲۷ درجه سلسیوس و ۰/۹۶۶ بود. همچنین نتایج نشان داد این روش دقت قابل قبولی در برآورد تعداد روزهای یخبندان و بحرانی داشته است. مقادیر دمای کمینه طی سال های ۲۰۰۰ تا ۲۰۲۰ در بازه زمانی ۱۰ مارس تا ۲۰ می (مراحل مختلف توسعه گل در درخت پسته) که در سرمازدگی بهاره محصول پسته مؤثر است بررسی نتایج نشان داد که نوسان دمایی و تغییرات ناگهانی در بازه

References

1. Abdollahi Fuzi, M., Bakhtiari, B., & Qaderi, K. (2023). A systematic review of research on late spring frost and its estimation methods. *Nivar*, 47(120-121), 105-126. (In Persian with English abstract). <https://doi.org/10.30467/nivar.2023.379316.1235>
2. Abdollahi Fuzi, M., Bakhtiari, B., & Qaderi, K. (2023). A review of research on frost and chilling from 1954 to 2020 (Bibliometric Analysis). *Water Management in Agriculture*, 10(1), 131-146. (In Persian with English abstract). <https://doi.org/20.1001.1.24764531.1402.10.1.9.7>
3. Allen, R.G., Pereira, L.S., & Raes, D. (1998). Crop evapotranspiration-guidelines for computing crop water requirements-FAO Irrigation and Drainage Paper 56. *FAO, Rome*, 300(9), D05109.
4. Anandhi, A., Zion, M.S., Gowda, P.H., Pierson, D.C., Lounsbury, D., & Frei, A. (2013). Past and future changes in frost day indices in Catskill Mountain region of New York. *Hydrological Processes*, 27(21), 3094-3104. <https://doi.org/10.1002/hyp.9937>
5. Augspurger, C.K. (2009). Spring 2007 warmth and frost: Phenology, damage and refoliation in a temperate deciduous forest. *Functional Ecology*, 23, 1031-1039. <https://doi.org/10.1111/j.1365-2435.2009.01587.x>
6. Bascietto, M., Bajocco, S., Mazzenga, F., & Matteucci, G. (2018). Assessing spring frost effects on beech forests in Central Apennines from remotely-sensed data. *Agricultural and Forest Meteorology*, 250, 240-248. <https://doi.org/10.1016/j.agrformet.2017.10.007>
7. Buishand, T.A. (1982). Some methods for testing the homogeneity of rainfall records. *Journal of Hydrology*, 58, 11-27. [https://doi.org/10.1016/0022-1694\(82\)90066-X](https://doi.org/10.1016/0022-1694(82)90066-X)
8. Chen, W., Liu, W., Huang, W., & Liu, H. (2017). Prediction of salinity variations in a Tidal Estuary using artificial neural network and three-dimensional hydrodynamic models. *Computational Water, Energy, and Environmental Engineering*, 6, 107-128. <https://doi.org/10.4236/cweee.2017.61009>
9. Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, 2(4), 303-314. <https://doi.org/10.1007/BF02551274>
10. Drepper, B., Bamps, B., & Gobin, A. (2022). Strategies for managing spring frost risks in orchards: effectiveness and conditionality-a systematic review. *Environmental Evidence*, 11(1), 29. doi.org/10.1186/s13750-022-00281-z.
11. Entezari, A., Haddad Niya, J., Jafar Zade, M., & Korvandi, E. (2011). A MLP neural network which predict frosts in kermanshah province. *Journal of Arid Regions Geographic Studies*, 2(3), 59-71.
12. Fuentes, M., Campos, C., & García-Loyola, S. (2018). Application of artificial neural networks to frost detection in central Chile using the next day minimum air temperature forecast. *Chilean Journal of Agricultural Research*, 77, 327-338. <https://doi.org/10.4067/S0718-58392018000300327>
13. Gholipour, Y. (2007). Low temperature threshold and growth degree day (GDD) for two pistachio cultivars. *Journal of Applied Horticulture*, 9(2), 150-152. <https://doi.org/10.37855/jah.2007.v09i02.33>
14. Gu, L., Hanson, P.J., Post, W.M., Kaiser, D.P., Yang, B., Nemani, R., Pallardy, S.G., & Meyers, T. (2008). The 2007 Eastern US spring freeze: Increased cold damage in a warming world? *BioScience*, 58, 253-262. <https://doi.org/10.1641/b580311>
15. Graczyk, D., & Szwed, M., (2020). Changes in the occurrence of late spring frost in Poland. *Agronomy*, 10(11), 1835. <https://doi.org/10.3390/agronomy10111835>
16. Gunhan, T., Demir, V., Hancioglu, E., & Hepbasli, A. (2005). Mathematical modeling of drying of bay leaves. *Energy Conversion and Management*, 46, 1667-1679.
17. Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554-2558. <https://doi.org/10.1073/pnas.79.8.2554>
18. Hernandez, G., Müller, G., Villacampa, Y., Navarro-Gonzalez, F., & Luis, A. (2019). Predictive models of minimum temperatures for the south of Buenos Aires province. *Science of The Total Environment*, 699, 134280.

<https://doi.org/10.1016/j.scitotenv.2019.134280>

19. Khalili, A. (2014). Quantitative evaluation of spring frost risk to agricultural crops in Iran and modeling. *Journal of Agricultural Meteorology*, 2(1), 17-31.
20. Khalili, A., Bazrafshan, J., & Cheraghizadeh, M. (2022). A Comparative study on climate maps of Iran in extended de Martonne classification and application of the method for world climate zoning. *Journal of Agricultural Meteorology*, 10(1), 3-16. (In Persian with English abstract). <https://doi.org/10.22125/agmj.2022.156309>
21. Khatami Firouzabadi, S.M.A., Dehdashti Shahrokh, Z., Roshani, A., & Akhgari, A. (2016). A hybrid fuzzy approach using AHP and Topsis methods to prioritize the export target markets of pistachio in Iran, Yazd. *Iranian Journal of Trade Studies*, 20(79), 121-154.
22. Hufkens, K., Friedl, M.A., Keenan, T.F., Sonnentag, O., Bailey, A., O'Keefe, J., & Richardson, A.D. (2012). Ecological impacts of a widespread frost event following early spring leaf-out. *Global Change Biology*, 18, 2365–2377. <https://doi.org/10.1111/j.1365-2486.2012.02712.x>
23. Kreyling, J., Thiel, D., Nagy, L., Jentsch, A., Huber, G., Konner, M., Beierkuhnlein, C. (2012). Late frost sensitivity of juvenile *Fagus sylvatica* L. differs between Southern Germany and Bulgaria and depends on preceding air temperature. *European Journal of Forest Research*, 131, 717–725. <https://doi.org/10.1007/s10342-011-0544-y>
24. Krause, P., Boyle, D.P., & Bäsler, F. (2005). Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5, 89–97. <https://doi.org/10.5194/adgeo-5-89-2005>
25. Larcher, W., & Bauer, H. (1981). *Ecological significance of resistance to low temperature*. In *Physiological Plant Ecology I: Responses to the Physical Environment*; Lange, O.L., Nobel, P.S., Osmond, C.B., Ziegler, H., Eds.; Springer: Berlin/Heidelberg, Germany, pp. 403–437.
26. Larcher, W. (1981). *Effects of low temperature stress and frost injury on plant productivity*. In *Physiological Processes Limiting Plant Productivity*; Johnson, C.B., Ed.; Butterworth: London, UK, pp. 253–269.
27. Littlewood, L.G., Clarke, R.T., Collischonn, W., Croke, B.F.W. (2007). Predicting daily streamflow using rainfall forecasts, a simple loss module and unit hydrographs: Two Brazilian catchments. *Environmental Modelling and Software*, 22, 1229-1239. <https://doi.org/10.1016/j.envsoft.2006.07.004>
28. Mesgari, E., Tavousi, T., Mahmoudi, P., & Jahanshahi, S.M.A. (2020). Evaluation of selected transfer functions of artificial neural network model for prediction of minimum temperature (Case Study: Sanandaj Station). *Journal of Agricultural Meteorology*, 8(1), 40-50. (In Persian with English abstract). <https://doi.org/10.22125/agmj.2020.191817.1066>
29. Moustris, K.P., Ziomas, I.C., & Paliatsos, A.G. (2010). 3-day-ahead forecasting of regional pollution index for the pollutants NO₂, CO, SO₂ and O₃ using artificial neural networks in Athens, Greece. *Water Air Soil Pollut*, 209, 29–43. <https://doi.org/10.1007/s11270-009-0179-5>
30. Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel R.D., & Veith, T.L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50, 885-900. <https://doi.org/10.13031/2013.23153>
31. Motovilov, Y.G., Gottschalk, L., England, K., & Rodhe, A. (1999). Validation of distributed hydrological model against observations. *Agricultural and Forest Meteorology*, 99, 257-277. <https://doi.org/10.1016/S0168-1923%2899%2900102-1>
32. Nash, J.E., & Sutcliffe, J.V. (1970). River flow forecasting through conceptual models; Part I – a discussion of principles. *Journal of Hydrology*, 10, 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
33. Ningre, F., & Colin, F. (2007). Frost damage on the terminal shoot as a risk factor of fork incidence on common beech (*Fagus sylvatica* L.). *Annals of Forest Science*, 64, 79–86. <https://doi.org/10.1051/forest:2006091>
34. Noh, I., Doh, H.W., Kim, S.O.S.H., Kim, S., & Shin, Lee, S.J. (2021). Machine learning-based hourly frost-prediction system optimized for orchards using automatic weather station and digital camera image data. *Atmosphere*, 12(7), 846. <https://doi.org/10.3390/atmos12070846>
35. Sadorsky, P. (2006). Modeling and forecasting petroleum futures volatility. *Energy Economics*, 28, 467-488. <https://doi.org/10.1016/j.eneco.2006.04.005>
36. Shcherbakov, M.V., Brebels, A., Shcherbakov, N.L., Tuukov, A.P., Janovsky, T.A., & Kamaev, V.A. (2013). A survey of forecast error measures. *World Applied Sciences Journal*, 24, 171-176. <https://doi.org/10.5829/idosi.wasj.2013.24.itmies.80032>
37. Shonwiese, C.D. (1997). *Statistical analysis of observed climate trends and statistical signal detection analysis*, WMO Publ., No. 834, Geneva.
38. Snyder, R.L., & de Melo-Abreu, J.P. (2005). *Frost Protection: Fundamentals, Practice and Economics*.
39. Taghavi, S., & Omidzade, H. (2015). Spring frost prediction using neural network multilayer prediction (MLP) and its impact on the public transportation in Khorramabad City. *Environmental Based Territorial Planning (Amayesh)*, 8(28), 111-124. (In Persian)
40. Tajabadipour, A., Fattahi Moghadam, M.R., Zamani, Z., Nasibi, F., & Hokmabadi, H. (2018). Evaluation of physiological and biochemical changes of pistachio (*Pistacia vera* L. cv. Ahmad-Aghaii) on cold tolerant and sensitive rootstocks under freezing stress conditions. *Journal of Horticultural Science*, 32(3), 471-484. (In Persian)

41. Tran, T., Bateni, M., Jin Ki, S., & Vosoughifar, H. (2021). A review of neural networks for air temperature forecasting. *Water*, 13(9), 1294. <https://doi.org/10.3390/w13091294>
42. Vitasse, Y., Schneider, L., Rixen, C., Christen, D., & Rebetez, M. (2018). Increase in the risk of exposure of forest and fruit trees to spring frosts at higher elevations in Switzerland over the last four decades. *Agricultural and Forest Meteorology*, 248, 60–69. <https://doi.org/10.1016/j.agrformet.2017.09.005>
43. Woodward, F.I., & Williams, B.G. (1987). Climate and plant distribution at global and local scales. *Vegetatio*, 69, 189–197. <https://doi.org/10.1007/BF00038700>
44. Zohner, C.M., Mo, L., Renner, S.S., Svenning, J.C., Vitasse, Y., Benito, B.M., Ordonez, A., Baumgarten, F., Bastin, J.F., Sebold, V., Reich, P.B., Liang, J., Nabuurs, G.J., De-Miguel, S., Alberti, G., Antón-Fernández, C., Balazy, R., Brändli, U.B., Chen, H.Y.H., & Crowther, T.W. (2020). Late-spring frost risk between 1959 and 2017 decreased in North America but increased in Europe and Asia. *Proceedings of the National Academy of Sciences of the United States of America*, 117(22). <https://doi.org/10.1111/geb.13088>
45. Zolfaghari, H., Zahedi, G.H., & Sajjadifar, T. (2012). Predicting last spring freezing day in West Northwest of Iran. *Geography and Environmental Sustainability*, 2(4), 59-74. (In Persian with English abstract)