



ارزیابی برخی توابع انتقال در شبکه‌های عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت دمای کمینه (مطالعه موردی: ایستگاه همدیدی سندج)

ابراهیم مسگری^۱، تقی طاووسی^{۲*}، پیمان محمودی^۳، سید مهدی امیرجهانشاهی^۴

تاریخ دریافت: ۱۳۹۸/۰۶/۲۰

تاریخ پذیرش: ۱۳۹۹/۰۵/۰۸

چکیده

پیش‌بینی کوتاه‌مدت دمای کمینه به منظور تعدیل اثرات سوء ناشی از سرمادگی و یخبندان در بخش کشاورزی از اهمیت زیادی برخوردار است. در این پژوهش ابتدا فراوانی وقوع یخبندان‌های زودرس پاییزه و دیررس بهاره در ایستگاه همدیدی سندج طی دوره آماری موجود استخراج شد. سپس با استفاده از داده‌های سینوپ شش متغیر دمای خشک، دمای تر، رطوبت نسبی، سرعت باد، جهت باد و پوشش ابر به عنوان ورودی‌های یک مدل شبکه عصبی از نوع پرسپترون چند لایه مبتنی بر الگوریتم یادگیری لوینبرگ - مارکوارت، میزان دمای کمینه در ۹، ۶، ۱۲ و ۱۶ ساعت آتی پیش‌بینی گردید. به این منظور از تابع انتقال موجود در نرم‌افزار MATLAB شامل آماری RMSD، MAD و R استفاده شد. نتایج نشان داد، تابع poslin و tansig در ماه آوریل به ترتیب با مقدار خطای ۱/۱۷، ۱/۶۱ و ۱/۸۸ و ۲/۰۰ (C°) و ضریب همبستگی بیش از ۰/۸ و تابع poslin و radbas در ماه اکتبر با مقدار خطای ۱/۶۰، ۱/۹۶، ۱/۹۹ و ۱/۳۶ درجه سلسیوس و ضریب همبستگی بالای ۰/۷ جهت پیش‌بینی دمای کمینه در ساعات ۲۱:۳۰، ۰۰:۳۰ و ۰۶:۳۰ محلی، بیشترین دقت و کارایی را دارند. همچنین در بین تابع poslin و tansig با بیشترین فراوانی دارای بهترین عملکرد در پیش‌بینی یخبندان‌های شبانه در سندج می‌باشد. نتایج حاصل بیان گر کارآیی و دقت بالای شبکه عصبی مصنوعی در پیش‌بینی کوتاه‌مدت دمای کمینه در منطقه مورد مطالعه می‌باشد.

واژه‌های کلیدی: تابع انتقال، پرسپترون چند لایه، پیش‌بینی، سندج، دمای حداقل

در بخش کشاورزی وقوع یخبندان در فصول پاییز و بهار برای گیاهان بیشتر از موضع دیگر زیان‌آور می‌باشد. وقوع یخبندان زودتر از موعد یا نرمال (یخبندان زودرس) به رشد شاخه‌های درختان آسیب می‌زند، همچنین محصولات کشاورزی از جمله درختان میوه با شروع فصل گرما و افزایش دما شروع به گلدهی کرده و افت دما و وقوع یخبندان دیرتر از موعد (دیررس بهاره) و بعد از گلدهی باعث از بین رفتن شکوفه‌ها شده و خسارت قابل توجهی به کشاورزان وارد می‌کند. پیش‌بینی زمانی و مکانی دمای هوا جهت جلوگیری و کاهش شدت خسارت بسیار ضروری می‌نماید، چون کشاورزان می‌توانند با آگاهی از اطلاعات دقیق هوای محلی و پیش‌بینی کوتاه مدت دمای هوا اقدامات حفاظتی (نصب ماشین‌های بادی، نصب بخاری، ایجاد دود، پوشاندن گیاه و

مقدمه

دما بر روی بسیاری از فرآیندهای سوخت و ساز گیاهان (تنفس، فتوسنتر و رشد) اثرگذار است و یکی از عوامل مهم محیطی در رشد و بازده محصولات کشاورزی به شمار می‌رود.

^۱دانشجوی دکترای اقلیم‌شناسی، گروه جغرافیای طبیعی، دانشکده جغرافیا و برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان، زاهدان، ایران

^۲آستان اقلیم‌شناسی، گروه جغرافیای طبیعی، دانشکده جغرافیا و برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان، زاهدان، ایران
(*)نویسنده مسئول: t.tavousi@gep.usb.ac.ir

^۳آستان دیار اقلیم‌شناسی، دانشکده جغرافیا و برنامه‌ریزی محیطی، دانشگاه سیستان و بلوچستان، زاهدان، ایران
^۴آستان دیار اقلیم‌شناسی، گروه آمار، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران

نحوه ارجاع مقاله:

مسگری، ا.، طاووسی، ت.، محمودی، پ.، امیرجهانشاهی، س.م. ۱۳۹۹. ارزیابی برخی توابع انتقال در شبکه‌های عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت دمای کمینه (مطالعه موردی: ایستگاه همدیدی سندج). نشریه هواشناسی کشاورزی، ۸(۱)، ۴۰-۵۰.

DOI: 10.22125/agmj.2020.191817.1066
Mesgari, E., Tavousi, T., Mahmoudi, P., Amir Jahanshahi, S. M. 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. DOI: 10.22125/agmj.2020.191817.1066

که نتایج دال بر تأیید شبکه عصبی می‌باشد. Shank et al., (2008) بر اساس داده‌های ورودی برخط دمای تر، پیش‌بینی ۱ تا ۱۲ ساعته دمای تر را، با روش شبکه‌های عصبی در بیست ایستگاه در ایالت جورجیای آمریکا، انجام دادند و نتایج ارزیابی مدل خطای کمی را نشان داد. Hayati et al., (2007) برای پیش‌بینی دمای شهر کرمان برای روز آینده، از شبکه‌های عصبی^۴ (MLP) و داده‌های سرعت باد، دمای خشک، دمای تر، رطوبت، فشار، ساعت آفتابی و تابش به منزله ورودی شبکه در دوره ده ساله ۱996-2006 استفاده کردند. نتایج کار آن‌ها بیان می‌کرد استفاده از این شبکه روش خوبی برای پیش‌بینی دماست. Houshyar et al., (2012) با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی به برآورد دماهای حداقل در شهرستان ارومیه پرداختند و برتری شبکه‌های عصبی Zolfaghari et al., (2012) با استفاده از شبکه‌های عصبی مصنوعی به برآورد آخرین روزهای یخ‌بندان در شمال غرب و غرب ایران پرداختند. نتایج دقت بالای شبکه‌های عصبی در پیش‌بینی آخرین روزهای یخ‌بندان را نشان دادند. Jamei et al., (2015) استفاده از روش شبکه‌های عصبی و الگوریتم مارکوآرت-لونبرگ را برای پیش‌بینی دماهای حداقل، با توجه به تعیین خطای آموزشی و شاخص‌های عملکرد شبکه از جمله ضریب تعیین، مجدور میانگین مربعات خطای میانگین مربعات خطای میانگین مطلق خطای درصد نسبی خطای و ضریب همبستگی را گزینه‌ای سودمند ارزیابی کردند. Shiravand et al., (2017) به پیش‌بینی بارش در تهران با استفاده از شبکه‌های عصبی پرداختند. نتایج نشان داد که یک مدل پرسپترون سه لایه با ۵ نرون در لایه پنهان و الگوریتم لونبرگ-مارکوارت^۵ و توابع محرک تائزانت هایپربولیک و خطی دارای بهترین عملکرد می‌باشد. Hernandez et al., (2019) از مدل‌های عددی غیرخطی مبتنی بر شبکه‌های عصبی مصنوعی جهت پیش‌بینی دماهای حداقل شهر باییا بلانکا^۶ واقع در جنوب استان بوئوس آیرس^۷ در آرژانتین استفاده کردند. نتایج

آبیاری) را در برابر سرمازدگی و یخ‌بندان فراهم نمایند. پیش‌بینی‌های دقیق و هرچند کوتاه‌مدت می‌تواند میزان خسارات یخ‌بندان را کاهش دهد (Figuerola and Mazzeo, 1997). Baboo and Shereef (2010) ضرورت استفاده از تکنیک‌های جدید مبتنی بر روش‌های غیرخطی و سیستم‌های هوشمند را در پیش‌بینی وضع هوا، به سبب ماهیت بی‌نظم جو و ساختار غیرخطی معادلات حاکم بر آن یادآور شدند. Mort and Robinson (1996) از شبکه‌های عصبی برای پیش‌بینی رخداد یخ‌بندان‌های شبانه در سیسیل ایتالیا بهره گرفتند و متغیرهای ورودی دمای کمینه و بیشینه روز گذشته، پوشش ابر، جهت و سرعت باد بیشینه، رطوبت، سرعت و جهت باد را در طراحی شبکه استفاده کردند. Figuerola and Mazzeo (1997) از یک مدل تحلیلی برای پیش‌بینی دماهای شبانه تحت شرایط آسمان صاف و هوای آرام طراحی کردند و باور داشتند که پیش‌بینی‌های دقیق و هرچند کوتاه‌مدت، میزان خسارت یخ‌بندان را کاهش می‌دهد. در پژوهشی دیگر نیز از شبکه‌های عصبی برای پیش‌بینی دما هوا در مقیاس ساعتی برای Alma^۸، فورتوالی^۹ و بلیرزویل ایالت جورجیا^{۱۰} استفاده شد و متغیرهای ورودی دمای هوا، رطوبت نسبی، تابش خورشیدی و سرعت باد مهمترین پارامترها برای پیش‌بینی تشخیص داده شد (Jain et al., 2003). Maqsood et al., (2004) از مدل‌های شبکه‌های عصبی و تکنیک‌های رگرسیونی برای پیش‌بینی دمای ۲۴ ساعت آینده در کانادا استفاده و شبکه‌های عصبی را نسبت به مدل‌های رگرسیونی بهتر ارزیابی کردند. Ghielmi and Eccel (2006) برای پیش‌بینی یخ‌بندان‌های بهاره در ناحیه کشاورزی و کوهستانی در ایتالیا استفاده کردند و برای این کار از متغیرهای ورودی رطوبت جوی، باد، دمای خاک و طول مدت شب بهره گرفتند و از پیامک به کشاورزان برای اطلاع و انجام اقدامات حفاظتی از محصولات در برابر یخ‌بندان استفاده کردند. Smith et al., (2006) روش شبکه‌های عصبی را برای برآورد ۱۲ ساعت آینده دمای هوا در راستای حفاظت از محصولات کشاورزی تأیید کرد. Shank (2006) از شبکه‌های عصبی مصنوعی برای پیش‌بینی نقطه شبنم ۱۲ ساعت آینده استفاده کردند

⁴ Multilayer perceptron⁵ Levenberg-Marquardt⁶ Bahia Blanca⁷ Buenos Aires¹ Alma² Fort Valley³ Blairsville in Georgia

مواد و روش‌ها

شهرستان سندنج با مساحت ۲۹۰۶ کیلومتر مربع در ۳۵ درجه و ۲۰ دقیقه عرض شمالی و ۲۷ درجه طول شرقی در ارتفاع ۱۵۳۸ متری از سطح دریا قرار گرفته که جزء مناطق کوهستانی با خصوصیات اقلیمی تابستان‌های معتدل و زمستان‌های سرد به شمار می‌آید. قسمت‌های کم ارتفاع این منطقه جزء نقاط گرمسیری و قسمت‌های مرتفع آن جزو نقاط سرد است که با توجه به طبقه‌بندی اقلیمی کوپن در محدوده آب و هوای مدیترانه‌ای قرار می‌گیرد (Khorshidoust et al., 2020). این شهرستان بخشی از مناطق کوهستانی غرب و جنوب غربی زاگرس است. در این پژوهش از دو سری داده با دو مقیاس زمانی متفاوت استفاده شد. سری اول داده‌های دمای حداقل روزانه و سری دوم داده‌های سه ساعت به سه ساعت (سینوپ) شش متغیر دمای خشک، دمای تر، رطوبت نسبی، سرعت باد، جهت باد و پوشش ابری متعلق به ایستگاه سندنج است که برای دوره آماری (۲۰۰۰-۲۰۱۹) از سازمان هواشناسی اخذ گردید.

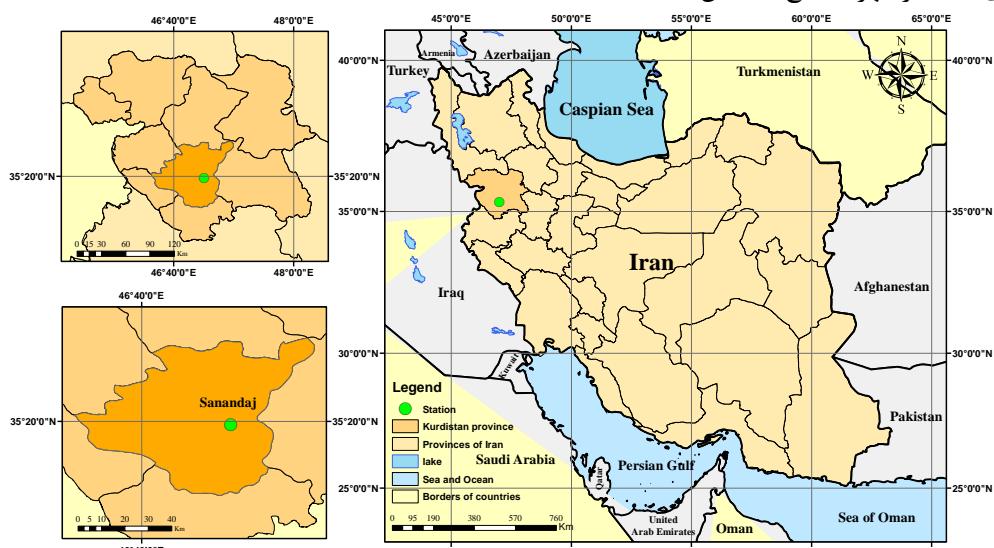


Figure 1- Geographical location of case study

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

گردید که در ایستگاه سندنج در ماه اکتبر (ماه مهر) اولین یخندهان شروع می‌شوند، به همین علت تاریخ اول اکتبر ۹ مهر) به عنوان تاریخ مبدأ انتخاب و ماقبی روزها به ترتیب، نسبت به این مبدأ شمارش شدند، برای مثال اگر در این ایستگاه اولین دمای صفر درجه سانتی‌گراد در روز

نشان داد که مدل‌های استفاده شده از توانایی بسیار بالای در پیش‌بینی دمای‌های حداقل برخوردار هستند. شبکه‌های عصبی به طور گسترده برای مدل‌سازی فرآیندهای هیدرولوژیکی غیرخطی همچون بارش - رواناب (Hsu et al., 1995; Shamseldin, 1997 et al., 1999; Campolo and Soldati, 1999 زیرزمینی (Rogers and Dowla, 1994) و ارزیابی کیفیت Maier and Dandy, 1996; Maier and Dandy, 2015) کاربرد وسیعی دارد. با توجه به بررسی پیشینه تحقیق و مطالعاتی که در زمینه پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی انجام شده، هدف بیشتر مطالعات صورت گرفته استفاده از یک تابع انتقال در شبکه عصبی جهت پیش‌بینی متغیرهای اقلیمی و هیدرولوژیکی بوده است و کمتر مطالعه‌ای به مقایسه انواع تابع انتقال آن پرداخته‌اند. لذا این پژوهش با هدف انجام یک مطالعه جامع، تابع انتقال شبکه عصبی مصنوعی را در یک مطالعه تطبیقی مورد مقایسه قرار داده تا بر اساس آن بتوان بهترین تابع انتقال را برای پیش‌بینی یخندهان شبانه در شهر سندنج مشخص نماید.

بعد از اخذ داده‌ها و تشکیل بانک اطلاعاتی آن، از داده‌های دمای حداقل روزانه ایستگاه همدیدی سندنج جهت استخراج یخندهان زودرس و دیررس استفاده شد. با بررسی زمان وقوع اولین روز یخندهان و آخرین روز یخندهان بر روی داده‌های دمای حداقل روزانه مشاهده

وابسته برقرار گردد (Hosseini et al., 2016)، به عبارت دیگر شبکه‌های عصبی می‌توانند نظم و هماهنگی موجود در داخل داده‌ها را پیدا کرده و بر اساس یک سری شواهد (بردارهای ورودی) موقع و بزرگی یک پدیده را پیش‌بینی نماید (Conrads and Roehle, 1999). شبکه عصبی مصنوعی متشکل از سه نوع لایه می‌باشد، لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان^۲ که مسئول پردازش داده‌ها بوده و لایه خروجی که نتایج را بر اساس ورودی مشخص استخراج می‌کند. تعداد لایه‌ها و تعداد نرون‌های موجود در لایه پنهان با نظر طراح و به وسیله سعی و خطای مشخص می‌شود (Solaimani, 2009). در شبکه عصبی پرسپترون چندلایه، لایه اول بردار ورودی لایه دوم بوده و خروجی لایه دوم؛ ورودی لایه سوم را تشکیل می‌دهد (Chelani, et al., 2002). الگوریتم لونبرگ- مارکوارت یک نوع خاص از روش نیوتن است که برای حداقل‌سازی تابعی از مجموع مربعات سایر توابع غیرخطی مورد استفاده قرار می‌گیرد. این روش در راستای آموزش شبکه‌های عصبی بسیار مناسب می‌باشد. زیرا شاخص کارآیی در شبکه‌های Hagan et al., (2014) لذا در این مطالعه نیز به عنوان الگوریتم مبنا تعیین گردید و از نه تابع انتقال جهت برآورد کوتاه‌مدت دمای حداقل در ایستگاه همدیدی سندج بهره گرفته شد (جدول ۲)، تابع انتقال یک تابع خطی و یا غیر خطی از n می‌باشد. از تابع انتقال برای تعیین خصوصیات نورون در راستای حل مسائل مختلف استفاده می‌شود (Hagan et al., 2014).

Table 2- Transfer functions used in this study
جدول ۲- توابع انتقال مورد استفاده در این مطالعه

Abbreviation	Description
hardlims	Symmetric hard limit transfer function
logsig	Log sigmoid transfer function
poslin	Positive linear transfer function
radbas	Radial basis transfer function
satlims	Symmetric saturating linear transfer function
satlin	Saturating linear transfer function
softmax	Soft max transfer function
tansig	Hyperbolic tangent sigmoid transfer function
tribas	Triangular basis transfer function

² Hidden layer

³ Multilayer perceptron

۶۳ رخ داده باشد با توجه به مبنای ما که روز اول اکتبر سال ۲۰۰۰ (۱۰ مهر) است معادل با ۲ دسامبر سال ۲۰۰۰ (۱۲ آذر) خواهد بود و به همین ترتیب اگر آخرین دمای زیر صفر درجه سانتی‌گراد در روز ۲۰۲ رخ داده باشد برابر ۲۰ آوریل (۳۱ فوریه) است. بعد از تنظیم داده‌ها بر اساس روز ژولیوسی، پنج شاخص یخبدان‌ها شامل متوسط روز آغاز یخبدان، متوسط روز خاتمه یخبدان، متوسط تعداد سالانه روزهای یخبدان، متوسط طول فصل یخبدان و متوسط طول فصل رشد برای این ایستگاه مستخرج گردیدند (Mesgari et al., 2020). بعد از مستخرج شاخص‌های مختلف یخبدان و به دست آوردن دانش مناسبی در این خصوص، از سری دوم داده‌ها در این مرحله استفاده شد. در این مرحله داده‌ها به صورت تصادفی به دو بخش آموزش و آزمون تقسیم شدند. برای آموزش مدل‌ها داده‌های مربوط به ساعت ۱۵ به وقت گرینویچ (۰۱:۳۰) به وقت محلی) ایستگاه سندج به عنوان ورودی مدل‌ها انتخاب شدند تا براساس آن بتوان پیش‌بینی یخبدان برای ساعت ۱۸، ۲۱، ۰۰ و ۰۳ به وقت گرینویچ انجام گیرد. در واقع مدل دارای شش ورودی و چهار خروجی است. در اینجا لازم به اشاره است که منظور از یخبدان، کاهش دمای خشک به صفر و زیر صفر درجه سانتی‌گراد در یکی از ساعت‌های ۱۸، ۲۱، ۰۰ و ۰۳ می‌باشد. بعد از تشریح داده‌ها و نوع چیدمان و تفکیک داده‌ها، روش کار مورد استفاده در این پژوهش به تفکیک تشریح خواهد شد.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی که به اختصار (ANNs)^۱ نامیده می‌شوند در واقع یک ابزار ریاضی قدرتمند هستند که با تقلید ساده از سیستم عصبی بیولوژیک ساخته شده‌اند (Fulop et al., 1998). شبکه‌های عصبی به عنوان یک مدل تشخیص روندهای ناپارامتری و غیرخطی؛ می‌تواند با دقت بیشتری نسبت به روش‌های آماری از جمله روش رگرسیونی؛ روابط غیرخطی پیچیده بین متغیرهای وابسته و مستقل را پیدا کنند (Cross et al., 1995). در این روش سعی می‌شود بر اساس روابط ذاتی مابین داده‌ها، نگاشتی غیرخطی مابین متغیرهای مستقل و

¹ Artificial neural networks

$$MAE = \left[\frac{\sum_{i=1}^n |Q_i^{Obs} - Q_i^{Sim}|}{N} \right] \quad (5)$$

$$R = \frac{\sum_{i=1}^n (Q_i^{Obs} + Q_{Mean}^{Obs})(Q_i^{Sim} - Q_{Mean}^{Sim})}{\sqrt{\sum_{i=1}^n (Q_i^{Obs} + Q_{Mean}^{Obs})^2(Q_i^{Sim} - Q_{Mean}^{Sim})^2}} Q_i^{Obs} \quad (6)$$

Q_i^{Obs} و Q_i^{Sim} مقادیر مشاهده شده شبیه‌سازی شده دمای حداقل، Q_{Mean}^{Obs} و Q_{Mean}^{Sim} مقادیر متوسط مشاهده شده و شبیه‌سازی شده دمای حداقل و N تعداد مشاهدات می‌باشد.

نتایج و بحث

بعد از تجزیه و تحلیل داده‌ها مشخص گردید که بیشترین فراوانی وقوع اولین یخنیان‌های زودرس پاییزه در ماه اکتبر و نوامبر و بیشترین فراوانی وقوع آخرین یخنیان‌های دیررس بهاره در ماه مارس و آوریل به وقوع می‌پیونددند (جدول ۳). لذا در این پژوهش ماههای اکتبر و آوریل به عنوان ماههای مبنا جهت برآورد حداقل دمای شبانه در ساعات ۲۱:۳۰، ۰۰:۳۰، ۳:۳۰ و ۶:۳۰ دقیقه با مدداد (به وقت محلی) انتخاب گردیدند. مدل شبکه عصبی با دو لایه پنهان و تعداد ۱۰ نرون برای هر لایه پنهان hardlims ساختاربندی شد و سپس عملکرد توابع یادگیری tansig، softmax، satlin، satlins، radbas، poslin، logsig و tribas در ساختار فوق جهت برآورد دمای‌های حداقل شبانه برای ۹، ۶، ۱۲ ساعت آینده و سه حالت تفکیک داده‌ها در بخش آموزش و آزمون مورد بررسی قرار گرفت. به عبارت دیگر ۱۰۸۰۰ خروجی یا پیش‌بینی $10 \times 10 \times 3 \times 4 \times 9 \times 10$ (تعداد حالات تفکیک داده‌ها، تعداد ساعت، تعداد توابع انتقال، تعداد نرون لایه پنهان اول، تعداد نرون لایه پنهان دوم) برای هر ماه و یا در مجموع ۲۱۶۰۰ پیش‌بینی دمای حداقل برای ماههای آوریل و اکتبر محاسبه گردید. در نهایت با مقایسه RMSE ثبت شده حاصل از اجرای مدل در هر یک از نرون‌ها، تعداد بهینه نرون‌ها برای ساختار شبکه با کمترین مقدار خطای برای هریک از توابع نه‌گانه مورد استفاده در ماههای اکتبر و آوریل مشخص و انتخاب گردید (جداول ۴ و ۵). در عملکرد تفکیک داده‌ها در حالات ۷۵-۲۵، ۸۰-۲۰ و ۹۰-۱۰ مشخص گردید که مقدار RMSE در کلیه حالات آموزش تقریباً برابر، ولی در بخش آزمون مقدار خطای در حالت ۹۰ درصد برای آموزش و ۱۰ درصد داده‌ها برای آزمون خطای کمتری را از خود نشان می‌دهد (شکل ۲).

استاندارد سازی داده‌ها

با توجه به ماهیت شبکه عصبی که به ترتیب داده‌ها واپس‌نمایست، داده‌های مفقود از ماتریس داده‌ها حذف و باقی داده‌ها در هم آمیخته شدن. وارد کردن داده‌ها به صورت خام سبب کاهش دقت و کاهش سرعت شبکه می‌شود به همین منظور برای یکسان کردن ارزش داده‌ها برای شبکه، ابتدا داده‌ها بین دو عدد $0/1$ و $0/9$ استاندارد شدند (معادله ۱)، این کار مانع کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نورون‌ها می‌شود، داده‌های نرمال شده بعد از استفاده در شبیه‌سازی، به مقدار واقعی برگشتند (Hosseini et al., 2016).

$$X_{Norm} = 0.8 \times \left(\frac{X_i - X_{Min}}{X_{Max} - X_{Min}} \right) + 0.1 \quad (1)$$

X_{Norm} مقدار استاندارد شده، X_i مقدار غیرنرمال و X_{Min} X_{Max} به ترتیب مقادیر کمینه و بیشینه داده‌ها غیرنرمال می‌باشند. برای معکوس کردن داده‌های نرمال شده به داده‌های غیرنرمال جهت مقایسه و نمایش بهتر از معادله ۲ استفاده می‌شود.

$$X_i = \left(\frac{X_{Max} - X_{Min}}{0.8} \right) \times (X_{Norm} - 0.1) + X_{Min} \quad (2)$$

داده‌ها ۸۴۴ داده ساعتی در ماه آوریل و ۸۶۵ داده ساعتی در ماه اکتبر با استفاده از تابع Dividerand و حالت Sample کاتورهای گردیدند، داده‌ها در سه حالت بررسی گردیدند در حالت اول ۹۰ درصد و در حالت دوم ۸۰ درصد و در حالت سوم ۷۵ درصد از این داده‌ها برای آموزش مدل و به ترتیب ۱۰ درصد، ۲۰ درصد و ۲۵ درصد باقیمانده نیز برای آزمون دقت مدل‌ها اختصاص داده شدند.

ارزیابی عملکرد شبکه

به منظور ارزیابی کارآیی مدل‌های استفاده شده، از میانگین مربعات خطای^۱ و ریشه میانگین مربعات خطای^۲، میانگین قدرمطلق خطای^۳، ضریب همبستگی^۴ استفاده شد (معادلات ۳ الی ۶).

$$MSE = \left[\frac{\sum_{i=1}^n (Q_i^{Obs} - Q_i^{Sim})^2}{N} \right] \quad (3)$$

$$RMSE = \sqrt{\left[\frac{\sum_{i=1}^n (Q_i^{Obs} - Q_i^{Sim})^2}{N} \right]} \quad (4)$$

¹ Mean Square Error

² Root Mean Square Error

³ Mean Absolute Error

⁴ Correlation Coefficient

Table 3- Calculation of frost indicators at the studied station

جدول ۳- محاسبه شاخص‌های یخبندان در ایستگاه مورد مطالعه

Year	FF	Mon	LF	Mon	DF	DR	F
2000	42	Nov	198	Apr	156	209	82
2001-2002	20	Oct	182	Mar	162	203	82
2002-2003	49	Nov	183	Apr	134	231	68
2003-2004	35	Nov	200	Apr	165	200	84
2004-2005	51	Nov	190	Apr	139	226	89
2005-2006	21	Oct	174	Mar	153	212	78
2006-2007	39	Nov	187	Apr	148	217	84
2007-2008	33	Nov	169	Mar	136	229	93
2008-2009	47	Nov	202	Apr	155	210	75
2009-2010	20	Oct	173	Mar	153	212	49
2010-2011	43	Nov	196	Apr	153	212	100
2011-2012	23	Oct	183	Apr	160	205	110
2012-2013	48	Nov	178	Mar	130	235	78
2013-2014	7	Oct	183	Apr	176	189	93
2014-2015	36	Nov	206	Apr	170	195	90
2015-2016	34	Nov	185	Apr	151	214	81
2016-2017	35	Nov	183	Apr	148	217	93
2017-2018	19	Oct	206	Apr	187	178	90
2018-2019	49	Nov	185	Apr	136	229	81
2019-2020	39	Nov	185	Apr	146	219	81
Avg.	34.50	Nov	187.40	Apr	152.90	212.10	84.05
Max	51.00	Nov	206.00	Apr	187.00	235.00	110.00
Min	7.00	Oct	169.00	Mar	130.00	178.00	49.00

Y= Year, Mon=Month, FF= the occurrence of the first frost day, LF= the occurrence of the last frost day, DF= Duration of the frost season, DR= Duration of the growing season, F= annual number of frost days, Apr=April, Oct=October, Nov=November, Mar=March,

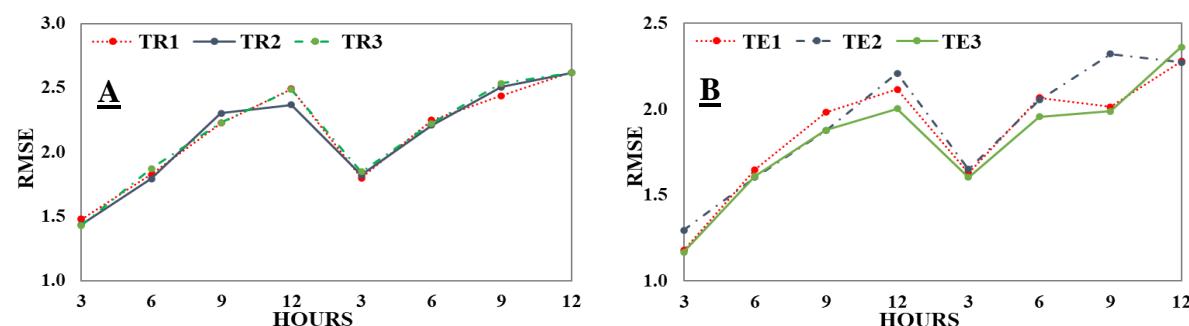


Figure 2- The RMSE of models in the training (A) and testing (B) stages

شکل ۲- مجدد میانگین مربعات خطأ در تفکیک داده‌ها در مراحل آموزش (A) و آزمون (B)

Table 4- The best RMSE for transfer functions in April and October
جدول ۴- بهترین مقدار RMSE در مرحله آزمون برای توابع مختلف در ماه‌های آوریل و اکتبر

Mon	Hr	Hardlims	Logsig	Poslin	Radbas	Satlims	Satlin	Softmax	Tansig	Tribas
Apr.	3	2.02	1.17	1.38	1.40	1.30	1.28	1.18	1.52	1.42
Apr.	6	2.42	1.90	1.75	1.79	2.13	1.78	1.81	1.61	1.81
Apr.	9	2.45	1.92	1.88	2.09	2.36	1.94	2.39	2.06	1.90
Apr.	12	2.66	2.35	2.41	2.57	2.00	2.06	2.08	2.38	2.12
Oct.	3	2.19	1.87	1.79	1.60	1.94	2.08	1.77	1.84	1.89
Oct.	6	2.44	2.06	1.96	2.05	2.41	2.28	2.09	2.04	2.12
Oct.	9	3.00	2.17	1.99	2.03	2.37	2.43	2.59	2.65	2.43
Oct.	12	2.89	2.87	2.72	2.92	2.48	2.53	2.77	2.67	2.36

Mon=Month, Hr= Hour, Apr = April, Oct = October

Table 5- Choose the best number of hidden neurons for different functions in April and October
جدول ۵- انتخاب بهترین تعداد نرون در لایه‌های پنهان در مرحله آزمون برای توابع مختلف در ماههای آوریل و اکتبر

Mon	Hr	Hardlims		Logsig		Poslin		Radbas		Satlins		Satlin		Softmax		Tansig		Tribas	
		L1	L2	L1	L2	L1	L2	L1	L2	L1	L2	L1	L2	L1	L2	L1	L2	L1	L2
Apr.	3	10	3	9	5	9	4	10	5	10	1	10	1	6	1	9	5	8	5
Apr.	6	9	6	9	3	7	6	10	8	9	3	8	4	10	8	10	8	9	8
Apr.	9	9	2	7	4	7	8	10	5	8	9	10	7	10	10	8	5	7	6
Apr.	12	9	10	8	10	8	10	8	5	7	9	10	4	8	5	9	3	10	1
Oct.	3	9	8	9	8	8	3	8	7	9	7	9	2	10	2	10	2	10	2
Oct.	6	7	5	9	1	10	9	6	7	9	4	10	1	10	10	10	2	9	7
Oct.	9	10	4	9	4	6	1	10	7	10	4	9	7	10	10	9	5	10	6
Oct.	12	10	7	6	2	8	8	10	2	7	1	9	6	9	3	7	7	8	8

Mon=Month, Hr= Hour, Apr = April, Oct = October, L: hidden layer

۴، تابع انتقال hardlims با مقدار RMSE در مرحله آزمون، ۲/۴۱۸۷ در ماه آوریل و ۲/۴۴۳۹ در ماه اکتبر ضعیفترین و توابع انتقال poslin و tansig با مقدار ۱/۹۵۸۸ و ۱/۶۱۱ جهت برآورد دمای ۶ ساعت آتی در ماه آوریل و اکتبر، به عنوان بهترین تابع انتقال تعیین شدند. مقدار RMSE در حالت آموزش در ماه آوریل و اکتبر نیز برابر با ۱/۸۷۰۶ و ۲/۲۲۲۲ و مقدار همبستگی ۰/۸۳ و ۰/۷۶ می‌باشد.

انتخاب نوع تابع انتقال در شبکه‌های عصبی مصنوعی اهمیت بسزایی دارد. در شکل ۳ تابع انتقال logsig و radbas به ترتیب با مقدار ۱/۳۶۱۵ و ۲/۵۷۴۸ MSE همچنین مقدار RMSE ۱/۱۶۶۸ و ۱/۶۰۴۶ تابع انتقال hardlims با مقدار ۴/۰۸۳۷ و ۴/۷۸۲۳ MSE در ۲/۰۲۰۸ و ۲/۱۸۶۹ RMSE عنوان کم‌دقیق‌ترین تابع انتقال مشخص گردیدند. در شکل

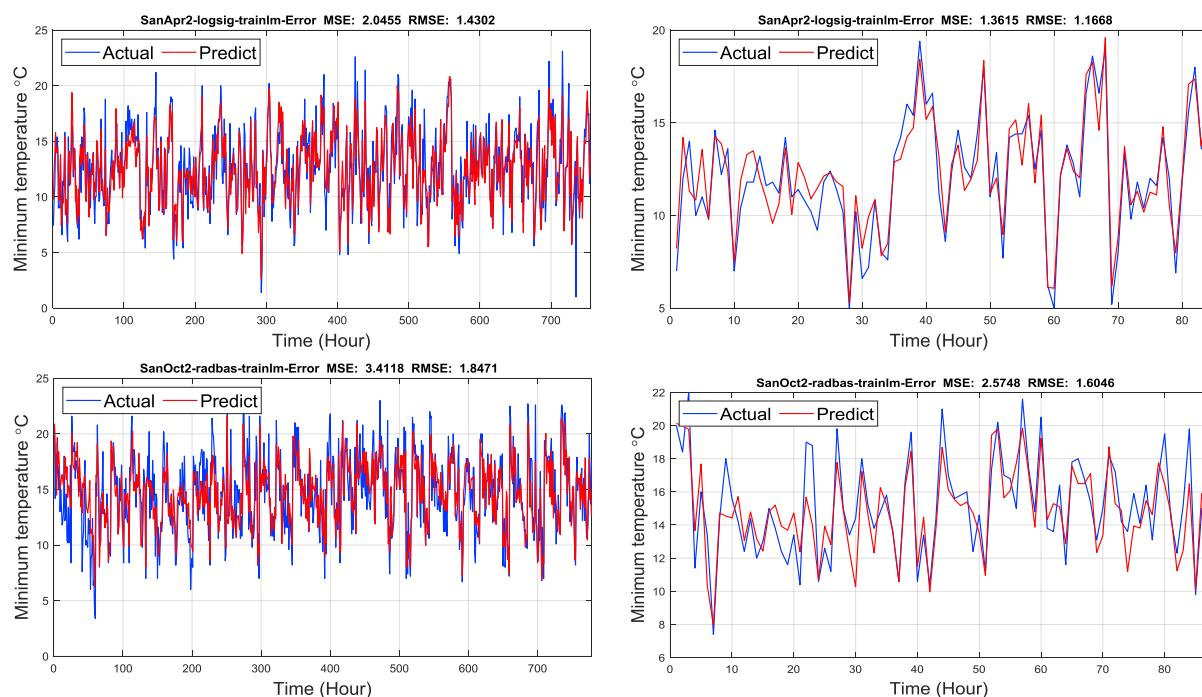


Figure 3- Evaluation of predict data with actual data in the training and testing stages in April and October at 21:30
شکل ۳- ارزیابی داده‌های برآورده شده با داده‌های واقعی در مراحل آموزش و آزمون در ماههای آوریل و اکتبر در ساعت ۲۱:۳۰

بهترین و بدترین تابع انتقال مشخص گردیدند. هر چقدر فاصله زمانی داده‌های برآورده شده بیشتر می‌شود مقدار خطأ افزایش پیدا کرده و مقدار همبستگی نیز کاهش پیدا می‌کند، بر این اساس تابع انتقال hardlims و radbas با

در ارزیابی داده‌های برآورده شده با داده‌های واقعی جهت برآورد حداقل دمای ۹ ساعت آینده (شکل ۵)، تابع انتقال poslin و hardlims در هر دو ماه آوریل و اکتبر با مقدار ۱/۸۷۷۶، ۱/۹۸۸۶، ۲/۴۵۴۰ و ۲/۹۵۲۹ RMSE

آوریل و Tribas در ماه اکتبر جهت برآورد حداقل دما برای ۱۲ ساعت آتی با کمترین مقدار خطا، ۰/۳۶ بهینه‌ترینتابع تشخیص داده شدند.

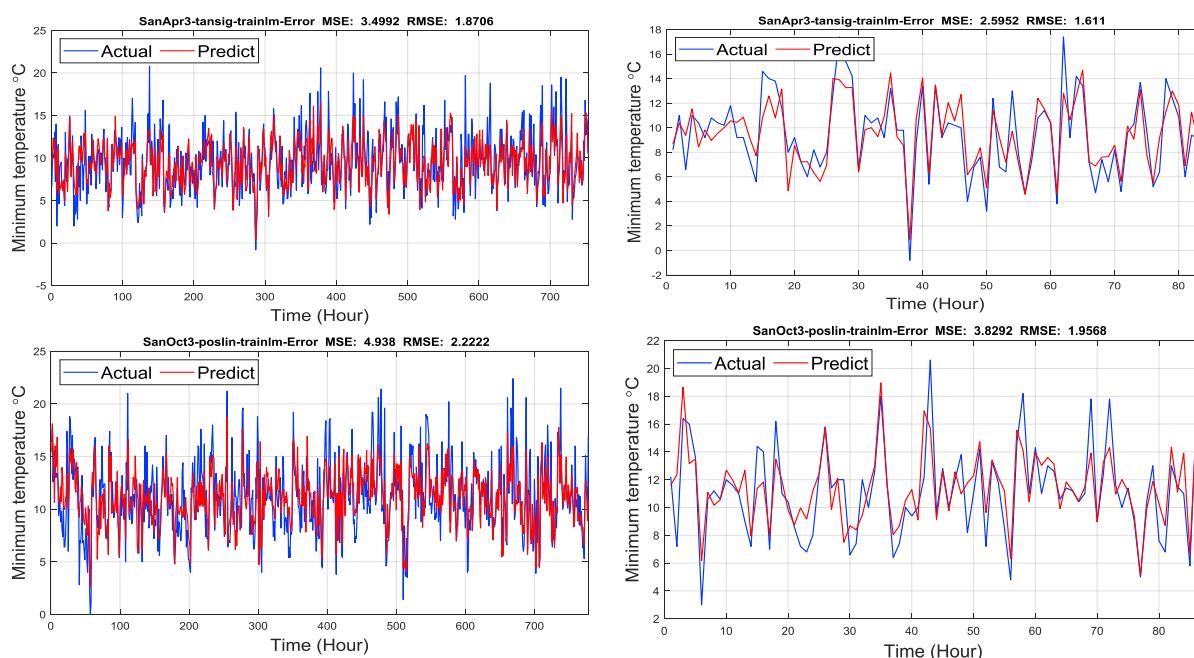


Figure 4- Evaluation of predict data with actual data in the training and testing stages in April and October at 00:30
شکل ۴- ارزیابی داده‌های برآورده شده با داده‌های واقعی در مراحل آموزش و آزمون در ماه‌های آوریل و اکتبر در ساعت ۰۰:۳۰

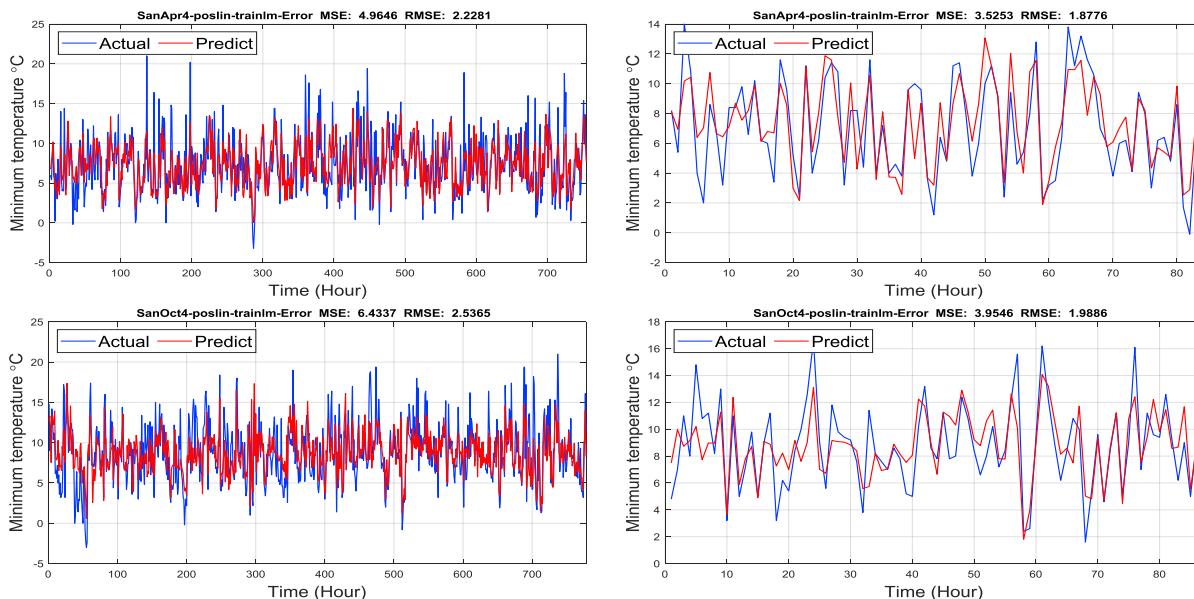
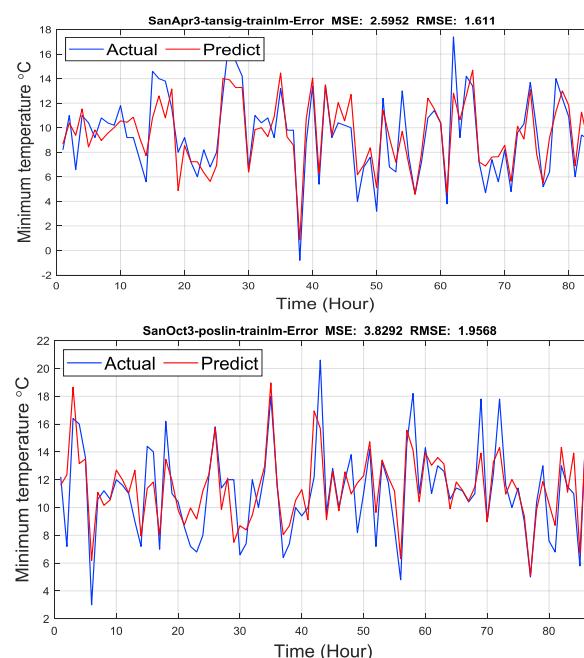


Figure 5- Evaluation of predict data with actual data in the training and testing stages in April and October at 03:30
شکل ۵- ارزیابی داده‌های برآورده شده با داده‌های واقعی در مراحل آموزش و آزمون در ماه‌های آوریل و اکتبر در ساعت ۰۳:۳۰

همبستگی ۰/۸۵، ۰/۸۱، ۰/۷۷ و ۰/۷۴ بهترین توابع با کمترین خطا ممکن را کسب کرده و بهترین توابع برای برآورد حداقل دما در ساعت فوق در ایستگاه همدیدی سنجنگ می‌باشند (جدول ۵).

مقدار خطای ۲/۶۶ و ۲/۹۲ به ترتیب برای ماه‌های آوریل و اکتبر با کسب بیشترین مقدار خطا نسبت به توابع دیگر ضعیف‌ترین تابع و Satlin با مقدار خطا ۰/۰ در ماه



در ساعت ۰۶:۳۰، ۰۰:۳۰، ۰۰:۰۳:۳۰ و ۰۰:۰۶:۳۰ در ماه آوریل به ترتیب توابع tansig، logsig و poslin با مقدار همبستگی ۰/۹۳، ۰/۸۷، ۰/۸۳ و ۰/۸۱ و در ماه اکتبر نیز توابع poslin، radbas و tribas با مقدار

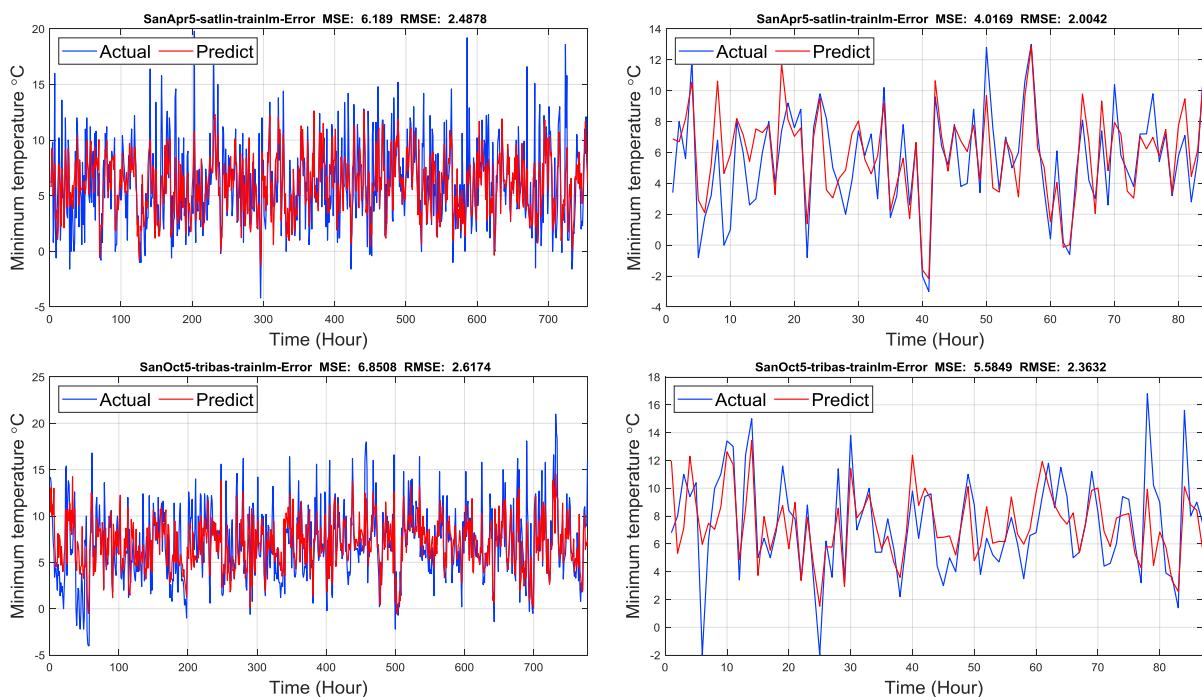


Figure 6- Evaluation of predict data with actual data in the training and testing stages in April and October at 06:30

شکل ۶- ارزیابی داده‌های برآورد شده با داده‌های واقعی در مراحل آموزش و آزمون در ماه‌های آوریل و اکتبر در ساعت ۰۶:۳۰

Table 5- Choose the best transfer function and amount of error in the months of April and October

جدول ۵- انتخاب بهترین تابع انتقال و مقدار خطأ در مراحل آموزش و آزمون در ماه‌های آوریل و اکتبر

	Month	Hour	TF	L1	L2	MAE (°C)	MSE (°C)	RMSE (°C)	N	Corel	Sig
Train 90%	Apr.	21:30	logsig	9	5	0.95	1.36	1.17	84	0.93	0.00
	Apr.	00:30	tansig	10	8	1.29	2.60	1.61	84	0.87	0.00
	Apr.	03:30	poslin	7	8	1.45	3.53	1.88	84	0.83	0.00
	Apr.	06:30	satlin	7	9	1.56	4.02	2.00	84	0.81	0.00
	Oct.	21:30	radbas	8	7	1.28	2.57	1.60	87	0.85	0.00
	Oct.	00:30	poslin	10	9	1.44	3.83	1.96	87	0.81	0.00
	Oct.	03:30	poslin	6	1	1.54	3.95	1.99	87	0.77	0.00
	Oct.	06:30	tribas	8	8	1.82	5.58	2.36	87	0.74	0.00
	Apr.	21:30	logsig	9	5	1.08	2.05	1.43	755	0.91	0.00
	Apr.	00:30	tansig	10	8	1.45	3.50	1.87	754	0.83	0.00
Test 10%	Apr.	03:30	poslin	7	8	1.70	4.96	2.23	755	0.77	0.00
	Apr.	06:30	satlin	7	9	1.86	6.19	2.49	755	0.74	0.00
	Oct.	21:30	radbas	8	7	1.42	3.41	1.85	778	0.85	0.00
	Oct.	00:30	poslin	10	9	1.71	4.94	2.22	778	0.76	0.00
	Oct.	03:30	poslin	6	1	1.93	6.43	2.54	778	0.72	0.00
	Oct.	06:30	tribas	8	8	2.00	6.85	2.62	778	0.73	0.00

شدید یا بسیار شدید باشد که با پیش‌بینی بهنگام و دقیق می‌توان میزان خسارت وارد را به مراتب کاهش داد. لذا به توجه به اهمیت این موضوع در پژوهش حاضر برای اولین بار در زمینه پیش‌بینی دمای حداقل به ارزیابی نه تابع انتقال در دقت مدل شبکه‌های عصبی در سندنج پرداخته شد آزمون مدل‌های مختلف نشان داد که بهترین مدل شبکه عصبی مصنوعی جهت پیش‌بینی دماهای حداقل در این بررسی یک مدل پرسپترون چند لایه و الگوریتم آموزشی لونبرگ-مارکوارت می‌باشد. ارزیابی توابع انتقال

نتیجه‌گیری

تنش دماهای پایین عامل اصلی محدود کننده بسیاری از فعالیت‌های کشاورزی اعم از زراعت و باغداری است، که هرساله خسارات زیادی را به محصولات کشاورزی وارد می‌سازد. آگاهی از احتمال وقوع این دماها برای جلوگیری از خسارات وارد بر محصولات و حتی خدمات بیمه محصولات کشاورزی دارای اهمیت بسزایی است. در مراحل مختلف رویشی برای محصولات کشاورزی و باغی وقوع یخنده و سرمزدگی بسیار مهم بوده و خسارت وارد می‌تواند

به عنوان گزینه‌ای ارزشمند مورد توجه و بررسی قرار گیرد که طبیعتاً با گذشت زمان در سال‌های آتی و افزایش اطلاعات در دسترس، دقت این مدل‌ها نیز افزایش یافته و برای پیش‌بینی‌های بلندمدت نیز کاربرد خواهد داشت، که از نتایج آن نه تنها در بخش کشاورزی بلکه در مدیریت منابع، صنایع، شیوع بیماری‌ها، حمل و نقل و تصادفات جاده‌ای، آبرسانی و غیره می‌تواند مؤثر باشد و ما را در به کارگیری تمامی امکانات موجود و اجرای روش‌های مقابله با یخ‌بندان و جلوگیری از خسارات ناشی از آن یاری نماید.

سپاسگزاری

از سازمان هواشناسی کشور به خاطر در اختیار قرار دادن داده‌های مورد نیاز پژوهش بسیار سپاسگزاریم.

منابع

- Campolo, M., Soldati, A., Andreussi, P. 1999. Forecasting river flow rate during low-flow periods using neural networks. *Water resources research*, 35(11): 3547–3552.
- Chelani, A. B., Rao, C. C., Phadke, K. M., Hasan, M. Z. 2002. Prediction of sulphur dioxide concentration using artificial neural networks. *Environmental Modelling and Software*, 17(2): 159–166.
- Conrads, P. A., Roehle, E. A. 1999. Comparing Physics- Based and Neural Network Mo Simulating Salinity, Temperature and Dissolved in a Complex, Tidally Affected River Basin. Proceeding of the South Carolina Environmentnental Conférence, 1–15.
- Cross, S. S., Harrison, R. F., Kennedy, R. L. 1995, Introduction to neural networks. *Lancet*, 346: 1075–9.
- Figuerola, P.I., Mazzeo, N. A. 1997. An analytical model for the prediction of nocturnal and dawn surface temperatures under calm, clear sky conditions. *Agricultural and forest meteorology*, 85(3–4): 229–237.
- Fulop, I. A., Jozsa, J., Karamer, T. 1998. A neural network application in estimating wind induced shallow lake motion. *Hydro Informatics*, 98(2) : 753–757.
- Ghielmi, L., Eccel, E. 2006. Descriptive models and artificial neural networks for spring frost prediction in an agricultural mountain area. *Computers and electronics in agriculture*, 54(2): 101–114.
- Hagan, M. T., Dcmuth, H. B., Bale, M. 2014. Neural Network Design (Translate by Seyed Mostafa Kia), Kian Publication of Rayaneh
- Mختلف نیز حاکی از آن است که برای ساعت‌های مختلف باید از توابع مختلفی استفاده کرد و نمی‌توان به یک تابع خاص در کل شباهنگی روز اکتفا کرد. ولی در مجموع تابع Poslin عملکرد بهتری را در بیشتر موارد از خود نشان داد. همچنین بررسی میزان همبستگی و مقدار خطاهای نشان داد که هر چقدر بر زمان پیش‌بینی افروده می‌شود همبستگی کاهش و میزان خطاهای افزایش پیدا می‌کند و این مسئله بر میزان حساسیت و اهمیت پیش‌بینی‌های کوتاه‌مدت می‌افزاید. در نهایت با توجه به نتایج تحقیق و ارزیابی توابع مختلف می‌توان اظهار داشت که استفاده از مدل پرسپترون چندلایه و توابع مختلف در پیش‌بینی دماهای حداقل به منظور تعیین یخ‌بندان‌های شباهنگی با توجه به تعیین خطای آموزشی و ساختارهای مختلف می‌تواند
- Sabz, Tehran, 543. (in Farsi)
- Hayati, M., Mohebi, Z. 2007. Application of artificial neural networks for temperature forecasting. *World Academy of Science, Engineering and Technology*, 28(2): 275–279.
- Hernandez, G., Müller, G. V., Villacampa, Y., Navarro-Gonzalez, F. J., Aragonés, L. 2020. Predictive models of minimum temperatures for the south of Buenos Aires province. *Science of The Total Environment*, 699: 134280.
- Hosseini, A., Mesgari, E., SalariFanodi M. R. 2016. Artificial Neural Networks in Climatology. AzarKelk, Zanjan, 146. (in Farsi)
- Houshyar, M., Hosseini, A., Mesgari, E. 2012. Modeling of Oroomieh Township Minimum Temperatures through Linear and Nonlinear Multiple Regression and Artificial Neural Networks Models. *Geographic Thought*, 6(12): 1–33. (in Farsi)
- Hsu, K. L., Gupta, H. V., Sorooshian, S. 1995. Artificial neural network modeling of the rainfall-runoff process. *Water resources research*, 31(10): 2517–2530.
- Jain, A., McClendon, R. W., Hoogenboom, G. 2003. Frost prediction using artificial neural networks: a temperature prediction approach. ASAE Paper no. 033075, ASAE, St. Joseph, MI.
- Jamei, J., Mesgari, E., Asheri, E. 2015. Predicting Late Spring Frost in the Zab Catchment Using Multilayer Perceptron (MLP) Model. *Journal of Geography and Regional Development*, 12(23):157–174. (in Farsi)
- Khorshidoost, A. M., Mohammadpour, K., Hosseini, S. A. 2020. Comparison of Logit and

- Artificial Neural Network Models in Prediction of Asthma Admissions Related to Climatic Parameters in Sanandaj City. *Journal of Geography and Planning*, 24(71): 45-66.
- Maier, H. R., Dandy, G. C. 1996. The use of artificial neural networks for the prediction of water quality parameters. *Water resources research*, 32(4): 1013–1022.
- Maier, H. R., Dandy, G. C. 1999. Empirical comparison of various methods for training feed-Forward neural networks for salinity forecasting. *Water Resources Research*, 35(8): 2591–2596.
- Maqsood, I., Khan, M. R., Abraham, A. 2004. An ensemble of neural networks for weather forecasting. *Neural Computing and Applications*, 13(2):112–122.
- Mesgari, E., Asheri, E., Hooshyar, M., Hemmesy, M. S. 2015. Rainfall Modeling and Forecasting using Neural Networks: A Case Study of Zab Watershed. *International Bulletin of Water Resources and Development*, 3(2), S.N(10).
- Mesgari, E., Tavousi, T., Mahmoudi, P. 2020. Modelling Topo-Climatology and Zoning Frost Statistical Indices in Kurdistan Province. *Geography and Planning*, 24(72), 357–383. (in Farsi)
- Robinson, C., Mort, N. 1997. A neural network system for the protection of citrus crops from frost damage. *Computers and Electronics in Agriculture*, 16(3): 177–187.
- Rogers, L. L., Dowla, F. U. 1994. Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Water Resources Research*, 30(2): 457–481.
- Shamseldin, A. Y. 1997. Application of a neural network technique to rainfall-runoff modelling. *Journal of hydrology*, 199(3–4): 272–294.
- Shank, D. 2006. Dew point temperature prediction using artificial neural networks. M.S. thesis, Artificial Intelligence Center, University of Georgia, Athens, GA.
- Shank, D. B., Hoogenboom, G., McClendon, R. W. 2008. Dewpoint temperature prediction using artificial neural networks. *Journal of applied meteorology and climatology*, 47(6): 1757–1769.
- Shiravand, H., Hosseini, S. A., Masoudi, H. 2017. Modeling of precipitation prediction in Tehran using Multilayer Perceptron Model (MLP). First International Conference on Numerical Forecasting, Climate Meteorological Organization, Tehran, Iran. 10 p
- Smith, B. A., McClendon, R. W., Hoogenboom, G. 2006. Improving air temperature prediction with artificial neural networks. *International Journal of Computational Intelligence*, 3(3): 179–186.
- Solaimani, K. 2009. Rainfall-runoff prediction based on artificial neural network (a case study: Jarahi watershed). *American-Eurasian Journal of Agricultural and Environmental Science*, 5(6): 856–865.
- Zealand, C. M., Burn, D. H., Simonovic, S. P. 1999. Short term streamflow forecasting using artificial neural networks. *Journal of hydrology*, 214(1–4): 32–48.
- Zolfaghari, H., Zahedi, G., Sajjadifar, T. 2012. Predicting Last Spring Freezing Day in West and Northwest of Iran. *Geography and Sustainability of Environment*, 2(4): 59–74. (in Farsi)



Evaluation of selected transfer functions of artificial neural network model for prediction of minimum temperature (Case Study: Sanandaj Station)

E. Mesgari¹, T. Tavousi^{2*}, P. Mahmoudi³, S. M. A. Jahanshahi⁴

Received: 11/09/2019

Accepted: 29/07/2020

Abstract

Short-term prediction of minimum temperature is important in mitigation chilling and frost injury in agriculture. In current study, the frequency of early autumn and late spring frosts in Sanandaj synoptic station, Iran were worked out. Then, using six variables, i.e. dry and wet bulb temperature, relative humidity, wind speed, wind direction, and cloud cover as the inputs, a multilayer perceptron artificial neural network model (MLP/ANN) based on the Levenberg-Marquardt training algorithm of MATLAB software package was applied for prediction of the minimum temperature for the next 3, 6, 9 and 12 hours ahead. The selected Transfer Functions were hardlims, logsig, polsin, radbas, satlins, softmax, tansig, and tribas. The statistical measures of MAD, MSD, RMSD, and R were used for comparisons. The results showed that in case of late spring frost, the poslin, logsig, tansig, and satlin functions in April with a correlation coefficient greater than 0.8 and error values of 1.17, 1.61, 1.88 and 2.00 ($^{\circ}\text{C}$) for the different times steps, respectively are the best options. Similarly, in October, the radbas, poslin, poslin, and tribas functions with a correlation more than 0.7 and error values of 1.60, 1.96, 1.99, and 1.36, were found to be the most suitable ones for prediction of the minimum temperature at 21:30, 00:30, 03:30 and 06:30 local time. Also, among the selected functions, the poslin with the highest frequency has the best performance in predicting nocturnal frosts in Sanandaj. The results confirmed the good performance of the ANN approach in short-term prediction of minimum temperature and frost occurrence in study region.

Keywords: Transfer Functions, Multilayer Perceptron, Prediction, Sanandaj, Minimum Temperature



¹ Ph. D. Student of Climatology, Department of Physical Geography, Geography and Regional Planning Faculty, University of Sistan and Baluchestan, Zahedan, Iran

² Professor in Climatology, Department of Physical Geography, Geography and Regional Planning Faculty, University of Sistan and Baluchestan, Zahedan, Iran

(*Corresponding Author Email Address: t.tavousi@gep.usb.ac.ir)

³ Assistant Professor in Climatology Department of Physical Geography, Geography and Regional Planning Faculty, University of Sistan and Baluchestan, Zahedan, Iran

⁴ Assistant Professor in Statistics, Department of Statistics, Faculty of Mathematics, Statistics and Computer Science, University of Sistan and Baluchestan, Zahedan, Iran

نحوه ارجاع مقاله:

مسگری، ا.، طاووسی، ت.، محمودی، پ.، امیرجهانشاهی، س.م. ۱۳۹۹. ارزیابی برخی توابع انتقال در شبکه‌های عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت دمای کمینه (مطالعه موردی: ایستگاه همدیدی سنندج). نشریه هواشناسی کشاورزی، ۸(۱)، ۴۰-۵۰.

DOI: 10.22125/agmj.2020.191817.1066

Mesgari, E., Tavousi, T., Mahmoudi, P., Amir Jahanshahi, S. M. 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. DOI: 10.22125/agmj.2020.191817.1066