

مقایسه عملکرد شبکه عصبی پرسپترون چندلایه و مدل رگرسیونی لیناگر در پیش‌بینی کمینه دمای روز بعد (مطالعه موردی: کرمان، شیراز، رشت و همدان)

علی اکبر سبزی‌پرور^{۱*}، و فاطمه خوشحال جهرمی^۲

^۱استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی‌سینا، همدان، ایران
^۲دانشجوی دکتری، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی‌سینا، همدان، ایران

(تاریخ دریافت: ۱۳۹۶/۰۶/۱۴، تاریخ پذیرش: ۱۳۹۷/۰۷/۱۷)

چکیده

سرمازدگی یکی از مهم‌ترین مخاطرات جوی است که خسارات زیادی را به محصولات کشاورزی وارد می‌کند. یکی از راه‌های مدیریت و کاهش خسارت‌های ناشی از سرمازدگی، پیش‌بینی دمای کمینه است. به‌این‌منظور، با استفاده از آمار روزانه پارامترهای کمینه دما، بیشینه دما و دمای نقطه شبنم در دوره آماری ۲۰۰۹-۲۰۰۵، کمینه دمای روز بعد در چهار ایستگاه با اقلیم‌های متفاوت توسط مدل رگرسیونی لیناگر و شبکه عصبی مصنوعی پرسپترون چندلایه (MLP)، در کل سال، دوره سرد و دوره گرم پیش‌بینی شد. در این پژوهش برای ارزیابی عملکرد مدل‌ها از معیارهای آماری NRMSE، RMSE و R^2 استفاده شد. نتایج نشان داد که از چهار ایستگاه، بهترین برآورد، با شبکه عصبی MLP با دو ورودی برای ایستگاه رشت به‌دست‌آمد که ریشه میانگین مربعات خطای آن برای کل سال، دوره سرد و دوره گرم به‌ترتیب ۱/۵۷، ۱/۶۱ و ۱/۲۱ است. برای بررسی نقش رطوبت نسبی در جهت بهبود مدل شبکه عصبی، این پارامتر به‌عنوان ورودی سوم به شبکه پرسپترون چندلایه افزوده شد که در نتیجه آن، RMSE در دوره سرد سال برای ایستگاه‌های کرمان، شیراز، همدان (فرودگاه) و رشت به‌ترتیب ۳/۰۴، ۲/۸۶، ۹/۴۸ و ۱۵/۸۳ درصد بهبود یافت. این مقادیر برای دوره گرم سال ۶، ۱۳/۳۳، ۲/۸۶ و ۱۸/۶۳ درصد بود؛ بنابراین اضافه کردن رطوبت نسبی به‌عنوان ورودی سوم به مدل شبکه عصبی، تنها در ایستگاه همدان - که براساس طبقه‌بندی یونسکو، اقلیم آن SA-K-W است - سبب بهبود بیشتر RMSE در دوره سرد سال نسبت به دوره گرم سال شده است. درحالی‌که در سایر ایستگاه‌ها، اضافه کردن رطوبت نسبی در دوره گرم سال، منجر به کاهش بیشتر خطا شده است. در جمع‌بندی می‌توان گفت که برای همه اقلیم‌های مورد مطالعه، شبکه‌های عصبی مصنوعی منتخب، کارایی بهتری را نسبت به مدل رگرسیونی لیناگر در پیش‌بینی دمای کمینه روز بعد از خود نشان می‌دهند.

واژه‌های کلیدی: پیش‌بینی، دمای کمینه، شبکه عصبی مصنوعی، رگرسیون

۱ مقدمه

یخبندان و سرمازدگی اثر مستقیم و غیر قابل انکاری بر تولیدات گیاهی و محصولات زراعی دارد و علاوه بر از بین بردن محصولات کشاورزی، با اثرگذاری بر فعالیت‌های حیاتی و بیولوژیک گیاه، ممکن است محصول سال‌های بعد آن را نیز تحت تأثیر قرار دهد یا حتی در مواردی مانند یخبندان‌های شدید، به کلی سرمایه کشاورز را از دستش خارج سازد (مهدویان، ۱۳۷۸).

سرمازدگی به شرایطی از آب و هوا گفته می‌شود که دمای محیط برای یک زمان معین، کمتر از مقدار دمای بهینه برای رشد گیاهان باشد (لویت، ۱۹۸۰). در این شرایط، کاهش سریع دمای محیطی باعث اختلال در فعالیت‌های متابولیکی و سلولی گیاهان می‌شود که پیامد آن، آفت چشمگیر بازده محصولات زراعی و باغی است (دیکی، ۱۹۶۰). امروزه بسیاری از فعالیت‌های بشر تحت تأثیر عوامل جوی قرار می‌گیرد. بارندگی و دمای کمینه جزء مهم‌ترین پارامترهایی هستند که در بسیاری از کشورها برای استفاده عموم پیش‌بینی می‌شوند. پیش‌بینی دمای کمینه در بخش‌های صنعت، آب و برق، تأمین سوخت مصرفی جهت گرمایش محیط زندگی، راه و ترابری، ساختمان‌سازی و بسیاری از بخش‌های دیگر کاربرد وسیعی دارد (ساک کالی، ۲۰۰۸).

کشاورزان، یکی از مهم‌ترین استفاده‌کنندگان پیش‌بینی دمای کمینه روزانه هستند (ورستری و همکاران، ۲۰۰۸). همه ساله بخش عظیمی از منابع اقتصادی کشاورزان به‌علت آسیب‌های ناشی از سرما و یخبندان از بین می‌رود. در تمام فعالیت‌های کشاورزی از مرحله کاشت تا برداشت، انبارداری و حمل‌ونقل محصولات، دمای محیط می‌تواند نقش عمده‌ای ایفا کند. با پیش‌بینی دمای کمینه شبانه‌روزی می‌توان ضمن جلوگیری از خسارت‌های احتمالی، سایر فعالیت‌های این بخش را نیز برنامه‌ریزی کرد (کارلسون، ۲۰۰۱ و امانویل و گالانیس، ۲۰۰۶).

روش‌های پیش‌بینی دمای کمینه (برای یک فاصله زمانی حداکثر ۲۴ ساعته)، برحسب نوع داده اولیه و روش به‌کاررفته، عبارت‌اند از: روش‌های همدیدی که فقط مراکز پیش‌بینی هوا آنها را به‌کار می‌برند؛ روش‌های محلی (آماري-تجربی) که بیشتر شامل قواعدی هستند که می‌توان به‌وسیله آنها تغییرات آینده بعضی از عوامل جوی را براساس مقادیر به‌دست‌آمده از دوازده تا بیست‌و‌چهار ساعت قبل با توجه به ویژگی‌های ناحیه مورد پیش‌بینی، برآورد کرد؛ روش‌های عددی وضع هوا که در کنار سایر امکانات، مانند تصاویر ماهواره‌ای و داده‌های راداری، در ارتقاء کیفیت پیش‌بینی‌ها نقش بسزایی دارند. باین‌حال، این مدل‌ها به دلایل متعددی خطا دارند. مقادیر این خطاها به‌ویژه در پیش‌بینی کمیت‌های سطح زمین مانند دمای دو متری و بارش، قابل توجه است (تقوی و همکاران، ۱۳۹۲). نتایج مدل‌هایی که در اختیار پیش‌بین‌گذاشته می‌شود، با روش‌های پس‌پردازش تصحیح می‌شود. از آنجایی‌که عوامل محلی، نقش اساسی در مقدار دمای کمینه شبانه‌روزی دارند و این عوامل در روش‌های همدیدی به‌علت مقیاس نقشه‌ها قابل رؤیت نیستند، بسیاری از محققین سعی کرده‌اند با گزینش برخی از پارامترهای دیدبانی شده هواشناسی و با کمک روش‌های آماری، اثر این عوامل را روی تغییر دمای یک محل منظور کنند (انصاری و همکاران، ۱۳۹۱). در بخش کشاورزی، از میان انواع یخبندان‌ها، یخبندان تابشی به لحاظ فراوانی وقوع و امکان حفاظت مؤثر توسط روش‌های فعال، از اهمیت زیادی برخوردار است (پاشاییان و همکاران، ۱۳۹۴). برای پیش‌بینی سرمازدگی تابشی، روش‌های مختلفی وجود دارند؛ ولی کاربرد نقطه شبنم برای تخمین دمای کمینه روز بعد می‌تواند بیان دقیق‌تری از وقوع سرمازدگی یا یخ‌زدگی در یک منطقه باشد (شهاب‌فر و همکاران، ۱۳۸۳).

شهاب‌فر و همکاران (۱۳۸۳)، رابطه همبستگی معنی‌داری را بین پارامترهای رطوبت نسبی و تفاضل دمای کمینه و نقطه شبنم با ضریب همبستگی ۰/۷۰٪ در شهر مشهد به‌دست آوردند. آنها نتیجه گرفتند در روزهایی که مقدار رطوبت نسبی در هنگام عصر کمتر از ۰/۷۵٪ است، احتمال وقوع سرمازدگی کم است و برای تعیین مقدار دقیق کمینه دمای فردای آن روز، می‌توان از رابطه استخراج شده استفاده کرد؛ اما در روزهایی که مقدار این پارامتر بین ۷۵ تا ۱۰۰ درصد باشد، احتمال بروز سرمازدگی بسیار جدی است و بایستی با اعلام پیش‌آگاهی‌های لازم به کشاورزان منطقه، در حد امکان از بروز خسارت بیشتر جلوگیری کرد. حسینی (۱۳۸۸) با استفاده از مدل شبکه عصبی مصنوعی به برآورد و تحلیل دماهای بیشینه شهرستان اردبیل پرداخت و دمای بیشینه برای سال‌های ۲۰۰۴ تا ۲۰۰۶ میلادی را با اختلاف ۰/۸۳ درجه سلسیوس و همبستگی ۰/۹۹ با دمای واقعی برآورد کرد. اسفندیاری و همکاران (۱۳۸۹) به پیش‌بینی میانگین دمای ماهانه ایستگاه همدیدی سنج با استفاده از مدل شبکه عصبی مصنوعی (پرسپترون چندلایه) پرداختند. نتایج، نشان‌دهنده کارایی مناسب و دقت قابل‌قبول شبکه‌های عصبی مصنوعی در پیش‌بینی دما است. هوشیار و همکاران (۱۳۹۱) امکان مدل‌سازی و پیش‌بینی دماهای کمینه شهرستان ارومیه را با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی بررسی کردند. در آن پژوهش، از متغیرهای میانگین بیشینه رطوبت نسبی، میانگین سرعت باد، میانگین مجموع بارش، میانگین کمینه و بیشینه دمای دوره آماری ۲۶ ساله (۲۰۰۰-۱۹۷۵) جهت پیش‌بینی دمای کمینه پنج ساله (۲۰۰۵-۲۰۰۱) استفاده شد. نتایج نشان داد خطای بیشینه مدل‌های شبکه عصبی مصنوعی، رگرسیون خطی و غیرخطی با داده‌های واقعی به ترتیب برابر ۰/۸۵، ۳/۰۶ و ۳/۲۶ درجه سلسیوس است که توانایی قابل‌توجه شبکه عصبی مصنوعی را در پیش‌بینی دماهای کمینه در مقایسه با

آلن (۱۹۵۷)، معادله ساده‌ای برای برآورد دمای کمینه به کمک نقطه شبنم و دمای هوای اندازه‌گیری شده در حدود ساعت پنج بعدازظهر ارائه کرد. اسمیت (۱۹۷۳) نیز معادله دیگری برای برآورد دمای کمینه با استفاده از دمای نقطه شبنم و دمای هوای اندازه‌گیری شده در حدود ساعت سه بعدازظهر پیشنهاد داد. موران و مورگان (۱۹۹۵) طی تحقیقی دریافتند که نقطه شبنم در عصر یک روز، عاملی مناسب برای پیش‌بینی کمینه دما در روز بعد به‌شمار می‌رود. آنها نتیجه‌گیری کردند که برای شب‌های طولانی زمستان و هنگامی که کاهش دما در اثر تابش برگشتی از زمین باشد، می‌توان با این رابطه، سرمازدگی را مدتی پیش از وقوع، پیش‌بینی کرد و به کشاورزان هشدارهای لازم را داد. ناظم‌السادات و همکاران (۱۳۸۰) با استفاده از رابطه دمای نقطه شبنم روزانه و دمای کمینه روز بعد، در منطقه جهرم استان فارس، سرمازدگی را پیش‌بینی کردند. آنها ضمن این پژوهش نتیجه گرفتند هنگامی که رطوبت نسبی عصر یک روز، در محدوده ۴۵ تا ۵۵ درصد باشد، تفاوت کمینه دما در روز بعد و نقطه شبنم آن روز، به کمترین مقدار خود می‌رسد. در حالتی که رطوبت نسبی بیشتر (کمتر) از این مقدار باشد، معمولاً مقدار کمینه دما در روز بعد کمتر (بیشتر) از نقطه شبنم آن روز است. جین (۲۰۰۳)، دمای هوا را برای هشدار درباره یخبندان در منطقه جنوب جورجیا با استفاده از شبکه عصبی مصنوعی برای یک تا دوازده ساعت آینده پیش‌بینی کرد. هدف وی توسعه سامانه‌ای برای هشدار درباره یخبندان با استفاده از شبکه عصبی مصنوعی جهت کاهش خسارت در تولیدات کشاورزی بود. هامفریز (۲۰۰۳) اظهار می‌دارد که دمای کمینه به‌طور معنی‌داری از دمای نقطه شبنم اندازه‌گیری شده در ابتدای شب پایین‌تر نمی‌رود؛ دلیل آن، آزاد شدن گرمای نهان در موقع رسیدن دما به نقطه شبنم است. قانون وی در شکل ساده‌اش بیشتر در اقلیم‌های خیلی مرطوب و یا در دوره‌های به‌خصوصی از سال برای تعیین دمای کمینه به‌کار می‌رود.

شبیانه - که باعث انتقال گرما از عمق به سطح خاک می‌شود - و توربین‌های بادی - که با به حرکت درآوردن هوا در سطح مزرعه و باغ، لایه وارونگی دما را به هم زده و باعث اختلاط هوای سرد مجاور با هوای گرم لایه بالاتر می‌شود و دمای هوا را در سطح باغ و مزرعه تعدیل می‌کند - اتخاذ کنند (شهاب‌فر و همکاران، ۱۳۸۳). بنابراین، به مدلی کاربردی نیاز است که دسترسی آسان به متغیرهای ورودی آن وجود داشته باشد و عوامل هواشناسی محلی و داده‌های اقلیمی خاص محل را به کار بگیرد. در این مطالعه با توجه به تعداد کم ورودی‌های مورد نیاز در مدل تجربی لیناگر، به بررسی و صحت‌سنجی مدل شبکه عصبی مصنوعی می‌پردازیم تا دریابیم با ورودی‌های مدل لیناگر می‌توان در اقلیم‌های دیگری به جز موارد بررسی شده در پژوهش قره‌خانی و همکاران (۱۳۹۲)، نتایج بهتری ارائه داد یا خیر.

۲ روش تحقیق

۱-۲ داده‌های استفاده شده

در این پژوهش برای پیش‌بینی دمای کمینه در روز آینده از داده‌های روزانه، دمای بیشینه و دمای نقطه شبنم چهار ایستگاه همدیدی کرمان، رشت، همدان و شیراز در دوره آماری ۲۰۰۹-۲۰۰۵ استفاده شد. مشخصات جغرافیایی و اقلیمی این ایستگاه‌ها، طبق طبقه‌بندی اقلیمی یونسکو (غفاری و همکاران، ۱۳۹۴) در جدول ۱ آورده شده است. روش یونسکو مبتنی بر سه شاخص رژیم رطوبتی، تیپ زمستان و تیپ تابستان است؛ به عنوان مثال، طبق طبقه‌بندی یونسکو، اقلیم کرمان A-C-VW است که نشان‌دهنده رژیم رطوبتی خشک، تیپ زمستانه خنک و تیپ تابستانی خیلی گرم است. جهت برآورد کمینه دمای روزانه از روش تجربی لیناگر (۱۹۹۲) و مدل شبکه عصبی پرسپترون چندلایه (MLP) استفاده شد. به منظور ارزیابی نتایج مدل‌ها، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد بقیه

مدل‌های رگرسیونی نشان می‌دهد. انصاری و همکاران (۱۳۹۱) وقوع یخبندان‌های تابشی در شهرستان مشهد با استفاده از حداقل داده‌های هواشناسی را بررسی کردند. آنها دمای کمینه را با استفاده از یک مدل ساده رگرسیونی، پیش‌بینی و روند تغییرات دما را در شب‌هایی با رخداد یخبندان تابشی برآورد کردند. ایشان یخبندان‌های تابشی را از فرارفتی تفکیک و با استفاده از دمای نقطه شبنم، دمای خشک دو ساعت بعد از غروب خورشید و دمای کمینه روز بعد، مدل پیش‌بینی دمای کمینه را ارائه کردند. مقدار ضریب همبستگی ۰/۹۳ مربوط به داده‌های دمای کمینه مشاهده شده و پیش‌بینی شده توسط مدل، حاکی از اطمینان معنی‌دار در سطح ۹۹٪ بود. همچنین مقدار ریشه دوم میانگین مربعات خطا (RMSE) برای مدل ارائه شده، ۱/۶۳ درجه سانتی‌گراد به دست آمد. قره‌خانی و همکاران (۱۳۹۲) با استفاده از مدل تجربی لیناگر و شبکه عصبی مصنوعی به پیش‌بینی دمای کمینه (مطالعه موردی: استان فارس) پرداختند. آنها از اطلاعات روزانه دمای کمینه، دمای بیشینه و دمای نقطه شبنم در بازه زمانی ۲۰۰۲-۱۹۹۵ استفاده کردند. در آن پژوهش، هر دو مدل تجربی و شبکه عصبی مصنوعی (پرسپترون چندلایه) بهترین نتیجه را در ایستگاه‌های شیراز و درودزن داشتند. نتایج، نشان‌دهنده عملکرد بهتر مدل شبکه عصبی مصنوعی نسبت به مدل تجربی لیناگر بود.

پیش‌بینی کوتاه‌مدت سرمازدگی می‌تواند نقش مهمی در کاهش خسارت به کشاورزان و باغداران داشته باشد. پیش‌آگاهی از سرمازدگی به کشاورزان و باغداران امکان استفاده از روش‌های معمول مبارزه با سرمازدگی گیاهان را می‌دهد. با آگاهی از وقوع سرمازدگی، کشاورزان و باغداران می‌توانند تمهیداتی نظیر نصب بخاری در سطح باغ و بین درختان، استفاده از سوخت‌های جامد (مثل موم نفتی یا لاستیک) در زیر درختان، ریختن فضولات حیوانی بین ردیف‌های کاشت درختان در سطح خاک، آبیاری

جدول ۱. مشخصات جغرافیایی و رژیم‌های اقلیمی ایستگاه‌های مورد مطالعه.

ایستگاه	طول جغرافیایی (درجه)	عرض جغرافیایی (درجه)	ارتفاع (متر)	اقلیم (طبقه‌بندی یونسکو)	رژیم تابستان	رژیم زمستان	رژیم رطوبتی
کرمان	۵۶/۹۷	۳۰/۲۵	۱۷۵۳/۸	A-C-VW	خیلی گرم	خنک	خشک
شیراز	۵۲/۶۰	۲۹/۵۳	۱۴۸۴	SA-C-W	گرم	خنک	نیمه خشک
همدان (فرودگاه)	۴۸/۵۳	۳۴/۸۷	۱۷۴۱/۵	SA-K-W	گرم	سرد	نیمه خشک
رشت	۴۹/۶۲	۳۷/۳۲	-۸/۶	PH-C-W	گرم	خنک	خیلی مرطوب

غیرخطی و نامشخص باشد سپس با استفاده از این ارتباط منطقی، کار شبیه‌سازی برای مورد احتمالی مشابه انجام می‌شود (کوچک‌زاده و بهمنی، ۱۳۸۴).

ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است. لایه ورودی، یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه است؛ بنابراین خروجی مدل را معرفی می‌کند. لایه پنهان که از یاخته‌های پردازشگر تشکیل شده است، محل پردازش داده‌هاست. شمار لایه‌ها و یاخته‌ها در هر لایه پنهان با روش آزمون و خطا مشخص می‌شود (اصغری مقدم و همکاران، ۱۳۸۷). شبکه عصبی متشکل از سه مؤلفه وزن (W)، اریب ($Bias$) (b) و تابع انتقال (F) است. این سه جزء برای هر یاخته ($Neuron$) منحصربه‌فرد است (علیقلی‌نیا و همکاران، ۱۳۹۵). شکل ۱ ساختار کلی شبکه عصبی را نشان می‌دهد. در این شکل، a و p ورودی و خروجی هستند. پارامتر n ورودی خالص است که وارد f می‌شود تا خروجی ایجاد شود. نمایش ریاضی شبکه عصبی مصنوعی به صورت روابط زیر است (منهاج و سیفی‌پور، ۱۳۷۷):

$$n = wp + b, \quad (2)$$

$$a = f(n) = f(wp + b), \quad (3)$$

در فرایند آموزش شبکه‌های عصبی، پارامترهای W و b تا زمان به‌دست آمدن بهترین تقریب برای عضو خروجی

جهت آزمون در این دو مدل اختصاص یافت. برای بررسی توانایی پیش‌بینی مدل‌ها در دوره‌های گرم و سرد سال، علاوه بر در نظر گرفتن داده‌ها در طول سال، دوره‌ای از اوایل مهر تا اوایل فروردین (به‌عنوان دوره سرد) و از اوایل فروردین تا اوایل مهر (به‌عنوان دوره گرم) در نظر گرفته شد.

۲-۲ مدل تجربی لیناگر

بر اساس مدل ارائه شده توسط لیناگر (۱۹۹۲)، می‌توان با استفاده از رابطه (۱) مقدار دمای کمینه را برای روز آینده پیش‌بینی کرد:

$$T_{min} = a + bT_{max} + cT_{dew}, \quad (1)$$

که T_{min} ، T_{max} و T_{dew} به ترتیب کمینه دما در روز بعد، بیشینه دمای امروز و میانگین دمای نقطه شبنم امروز در ایستگاه مورد بررسی هستند. a ، b و c ضرایب رگرسیونی هستند.

۲-۳ شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی، شاخه‌ای از هوش مصنوعی است که با پردازش داده‌های تجربی، قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند. به همین خاطر، به این سیستم‌ها هوشمند می‌گویند (منهاج، ۱۳۸۷). شبکه، با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آنها، ارتباطی منطقی بین داده‌ها برقرار می‌کند که ممکن است

قادر به برآورد هر پارامتر پیچیده‌ای است به شرطی که تعداد گره‌های لایه مخفی به درستی انتخاب شود (تکرار و مارکوس، ۲۰۰۰). در این تحقیق، تابع محرک هلالی برای لایه پنهان و یک تابع انتقال خطی در لایه خروجی به کار گرفته شد (سبزی پرور و علیانی، ۱۳۹۰؛ کنانی و همکاران، ۲۰۰۸ و امیرمرادی و بهمنی، ۱۳۹۳).

مهم‌ترین شرط‌ها برای خاتمه الگوریتم شبکه، توقف بعد از دفعات معین تکرار و توقف هنگام کمتر شدن خطا از مقدار تعیین شده یا به عبارت دیگر، توقف هنگام کمینه شدن مربع خطا بین خروجی‌های شبکه و تابع هدف است. اگر دفعات تکرار کم باشد، خطا وجود خواهد داشت و اگر زیاد باشد، مسئله بیش‌برازش (over-fitting) رخ می‌دهد (امیرمرادی و بهمنی، ۱۳۹۳). در این پژوهش، تعداد مناسب تکرار و خطای معیار به ترتیب ۱۰۰۰ و 10^{-7} در نظر گرفته شد.


۲-۳-۲ آماده‌سازی داده‌های ورودی به مدل

تمامی شبکه‌های عصبی، ورودی عددی را دریافت و خروجی عددی تولید می‌کنند. تابع انتقال یک واحد معمولاً طوری انتخاب می‌شود که تنها به ورودی‌های موجود در یک محدوده خاص حساس باشد؛ بنابراین ابتدا داده‌های ورودی اصطلاحاً نرمال شده و در یک محدوده خاص قرار می‌گیرند. اگر پیش‌پردازش روی داده‌های ورودی و مقادیر هدف انجام شود، آموزش شبکه عصبی به‌طور مؤثرتری انجام خواهد شد (خوشحال جهرمی، ۱۳۹۲).

در این تحقیق برای نرمال کردن داده‌ها از رابطه MapMinMax (لیدی و همکاران، ۲۰۱۷) تعریف شده در نرم‌افزار متلب استفاده شد. الگوریتم این رابطه که داده‌ها را در محدوده +۱ و -۱ نرمال می‌کند، به صورت زیر است:

$$y = \frac{(y_{max}-y_{min})(x-x_{min})}{(x_{max}-x_{min}) + y_{min}}, \quad (6)$$

مربوط به ورودی موردنظر، تغییر می‌کنند (منهاج و سیفی‌پور، ۱۳۷۷).



شکل ۱. طرح کلی شبکه عصبی مصنوعی.

۲-۳-۱ شبکه عصبی پرسپترون چندلایه

در ساختار پرسپترون چندلایه، علاوه بر لایه‌های ورودی و خروجی، چند لایه بین این لایه‌ها وجود دارد که لایه‌های پنهان نامیده می‌شوند. این لایه‌ها جدا از محیط هستند و خروجی نیز تولید نمی‌کنند (علیقلی‌نیا و همکاران، ۱۳۹۵). مقایسه خروجی واقعی و خروجی مطلوب باعث می‌شود ضرایب وزنی و اریب شبکه تغییر یابند به طوری که در دفعات بعد، خروجی درست‌تری حاصل شود (منهاج و سیفی‌پور، ۱۳۷۷). عملکرد این شبکه با معادلات (۴) و (۵) مشخص می‌شود:

$$1 \leq j \leq S_1 \quad a_j^1(t) = F[\sum_{i=1}^R W_{ji}^1 P_i(t) + b_j^2], \quad (4)$$

$$1 \leq k \leq S_2 \quad a_k^2(t) = G[\sum_{i=1}^{S_1} W_{ki}^2 a_j^1(t) + b_k^2]. \quad (5)$$

که در این معادلات، R تعداد سیگنال ورودی، P بردار ورودی، W^1 و W^2 ماتریس وزن در لایه‌های پنهان و خروجی، S_1 و S_2 تعداد یاخته، b_1 و b_2 بردار اریب در لایه‌های پنهان و خروجی، a_1 و a_2 بردارهای خروجی لایه‌های متناظر و F و G توابع انتقال عصبی در لایه‌های پنهان و خروجی هستند (علیقلی‌نیا و همکاران، ۱۳۹۵). با تقریب جهانی، هر MLP با تابع انتقال هلالی (sigmoid) برای لایه مخفی و یک لایه خروجی با تابع انتقال خطی،

مقدار کمینه دمای اندازه‌گیری شده در روز آینده و n تعداد مشاهدات است. معیار دیگر خطاسنجی، مجذور میانگین مربعات خطای نرمال شده (Normalized Root Mean Square Error) یا NRMSE است:

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (T_{Obs} - T_{Sim})^2}{\sum_{i=1}^n T_{Obs}^2}} \times 100, \quad (8)$$

NRMSE زیر ده درصد (بین صفر و یک‌دهم) نشان‌دهنده دقیق بودن مدل، ده تا بیست درصد نشانه مناسب بودن مدل، بیست تا سی درصد نشانه دقت متوسط و بیش از سی درصد بیانگر ضعیف بودن مدل است (ده‌بزرگی و سپاسخواه، ۱۳۸۷). معیار سوم، ضریب تعیین R^2 است؛ معیاری بدون بعد که بهترین مقدار آن برابر یک است. رابطه (۹) نحوه محاسبه این معیار را نشان می‌دهد:

$$R^2 = \frac{\sum_{i=1}^n T_{Obs} T_{Sim}}{\sqrt{\sum_{i=1}^n T_{Obs}^2 \sum_{i=1}^n T_{Sim}^2}} \quad (9)$$

که در آن x داده مشاهده‌ای، y داده مشاهده‌ای نرمال شده، X_{min} و X_{max} به ترتیب کمترین و بیشترین مقدار داده‌ها و Y_{min} و Y_{max} به ترتیب کمترین و بیشترین مقدار موردنظر برای داده‌های نرمال شده هستند.

۲-۴ معیارهای خطاسنجی

یکی از معیارهای خطاسنجی، ریشه میانگین مربعات خطا (Root Mean Square Error) یا RMSE است. هرچه این مقدار به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد مناسب‌تر مدل است. رابطه (۷) نحوه محاسبه آن را بیان می‌کند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (T_{Sim} - T_{Obs})^2}, \quad (7)$$

که در این رابطه، T_{sim} مقدار شبیه‌سازی شده کمینه دمای روز آینده به کمک شبکه عصبی مصنوعی است. T_{obs}

جدول ۲. معادلات رگرسیونی برآورد دمای کمینه در روز آتی طبق فرمول لیناگر (۱۹۹۲) برای دوره سالانه در سال‌های ۲۰۰۹-۲۰۰۵.

ایستگاه	معادله رگرسیونی طبق فرمول لیناگر (۱۹۹۲)			آموزش			آزمون		
	T_{min}	T_{max}	T_{dew}	R^2	RMSE (°C)	NRMSE (%)	R^2	RMSE (°C)	NRMSE (%)
کرمان	$T_{min} = -7.78 + 0.67 T_{max} + 0.58 T_{dew}$			۰/۸۷	۳/۰۰	۲۶	۰/۸۷	۲/۷۸	۲۴
شیراز	$T_{min} = -7.18 + 0.61 T_{max} + 0.45 T_{dew}$			۰/۹۰	۲/۳۹	۲۲	۰/۹۲	۲/۴۴	۲۱
همدان (فرودگاه)	$T_{min} = -3.51 + 0.39 T_{max} + 0.59 T_{dew}$			۰/۷۶	۴/۷۰	۴۱	۰/۸۶	۲/۷۷	۲۴
رشت	$T_{min} = -2.32 + 0.19 T_{max} + 0.84 T_{dew}$			۰/۹۴	۱/۹۵	۱۳	۰/۹۴	۱/۷۰	۱۵

جدول ۳. معادلات رگرسیونی برآورد دمای کمینه در روز آتی طبق فرمول لیناگر (۱۹۹۲) برای دوره سرد در سال‌های ۲۰۰۹-۲۰۰۵.

ایستگاه	معادله رگرسیونی طبق فرمول لیناگر (۱۹۹۲)			آموزش			آزمون		
	T_{min}	T_{max}	T_{dew}	R^2	RMSE (°C)	NRMSE (%)	R^2	RMSE (°C)	NRMSE (%)
کرمان	$T_{min} = -7.10 + 0.59 T_{max} + 0.49 T_{dew}$			۰/۷۱	۳/۱	۵۳	۰/۷۳	۲/۶۸	۴۱
شیراز	$T_{min} = -4.77 + 0.46 T_{max} + 0.52 T_{dew}$			۰/۷۵	۲/۴	۴۰	۰/۷۹	۲/۳۲	۳۰
همدان (فرودگاه)	$T_{min} = -4.78 + 0.45 T_{max} + 0.70 T_{dew}$			۰/۸۴	۳/۳	۳۷	۰/۷۱	۲/۶۳	۳۲
رشت	$T_{min} = -2.01 + 0.20 T_{max} + 0.74 T_{dew}$			۰/۸۲	۲/۳۲	۲۸	۰/۸۳	۲/۰۱	۲۱

۳ نتایج و بحث

نتایج معادلات رگرسیونی و پارامترهای آماری جهت ارزیابی براساس مدل لیناگر (۱۹۹۲)، به صورت سالانه، دوره سرد و دوره گرم به ترتیب در جدول‌های ۲، ۳ و ۴ درج شده است. همان‌طور که قبلاً گفته شد، جهت به دست آوردن معادله رگرسیونی، از هفتاد درصد داده‌ها و جهت آزمون روابط، از سی درصد داده‌های سال‌های مورد بررسی استفاده شد.

نمودار مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده دمای کمینه توسط مدل رگرسیونی لیناگر که در جدول ۲ معرفی شدند، در شکل ۲ آورده شده است. مشخص است که رابطه لیناگر جهت برآورد کمینه دما در روز آینده در

هر سه دوره در نظر گرفته شده، برای دو ایستگاه رشت و شیراز نتایج بهتری را نسبت به ایستگاه‌های همدان و کرمان از خود نشان داده است. با توجه به اینکه میزان رطوبت موجود در جو یک عامل مهم در تعدیل دمای هوا است، در رابطه لیناگر از دمای نقطه شبنم استفاده می‌شود (ناظم‌السادات و همکاران، ۱۳۸۰). مهم‌ترین پارامتر معنی‌دار مؤثر بر ارتباط نقطه شبنم و کمینه دما در روز آتی، رطوبت نسبی است؛ بنابراین به نظر می‌رسد رژیم رطوبتی، نقش اساسی در کارایی این رابطه ایفا می‌کند به طوری که بهترین نتیجه از این رابطه، در ایستگاه رشت با رژیم رطوبتی خیلی مرطوب حاصل شده است. این نتایج با مطالعه قره‌خانی و همکاران (۱۳۹۲) همخوانی دارد.

جدول ۴. معادلات رگرسیونی برآورد دمای کمینه در روز آتی طبق فرمول لیناگر (۱۹۹۲) برای دوره گرم در سال‌های ۲۰۰۹-۲۰۰۵.

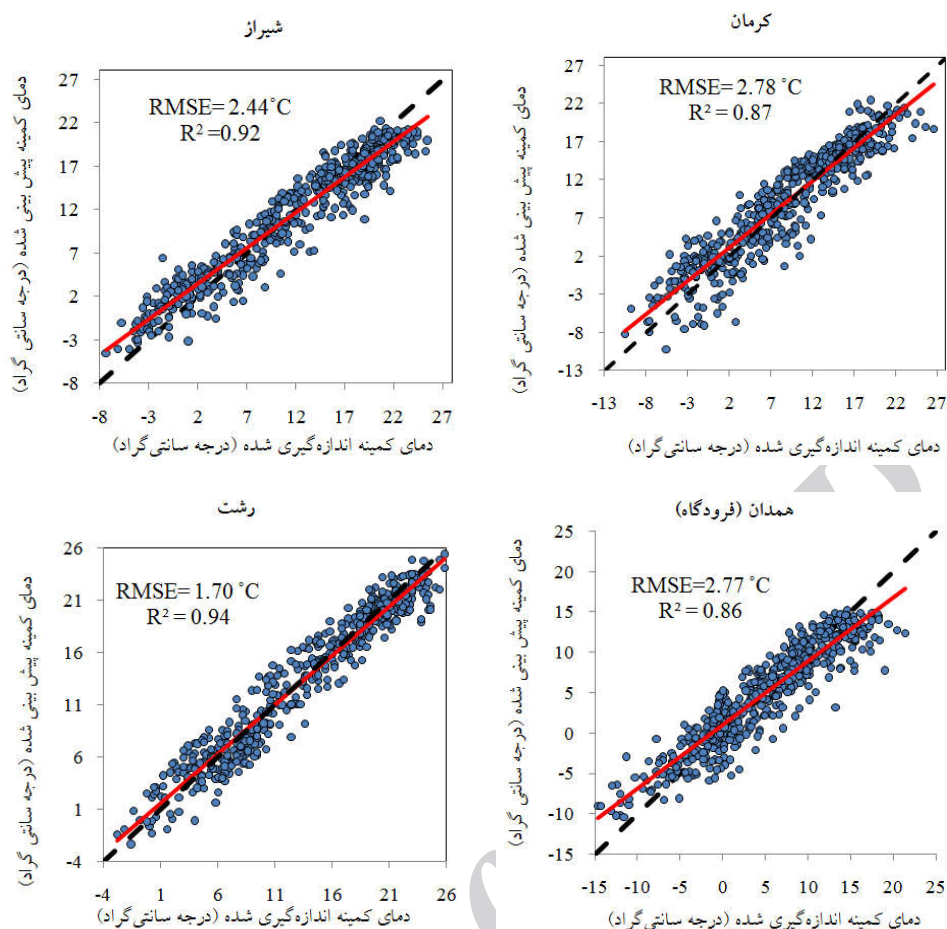
ایستگاه	معادله رگرسیونی طبق فرمول لیناگر (۱۹۹۲)			آموزش			آزمون		
	T_{\min}	T_{\max}	T_{dew}	R^2	RMSE (°C)	NRMSE (%)	R^2	RMSE (°C)	NRMSE (%)
کرمان	$T_{\min} = -10.97 + 0.78 T_{\max} + 0.42 T_{\text{dew}}$			۰/۱۶	۲/۳۸	۱۶	۷۶/۰۸	۲/۲۵	۱۴
شیراز	$T_{\min} = -8.17 + 0.68 T_{\max} + 0.25 T_{\text{dew}}$			۷۳/۰۹	۲/۲۴	۱۲	۷۹/۲۹	۲/۲۴	۱۲
همدان (فرودگاه)	$T_{\min} = -4.66 + 0.48 T_{\max} + 0.27 T_{\text{dew}}$			۷۰/۰۳	۲/۴۷	۲۱	۷۷/۰۷	۲/۴۷	۲۱
رشت	$T_{\min} = -1.32 + 0.20 T_{\max} + 0.79 T_{\text{dew}}$			۸۹/۵۲	۱/۵۱	۸	۸۸/۵۶	۱/۵۱	۸

جدول ۵. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با دو ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره سالانه در سال‌های ۲۰۰۹-۲۰۰۵.

ایستگاه	تعداد یاخته	آموزش			آزمون		
		R^2	RMSE (°C)	NRMSE (%)	R^2	RMSE (°C)	NRMSE (%)
کرمان	۲-۹-۱	۰/۸۸	۲/۸۱	۲۵	۰/۹۱	۲/۳۵	۲۰
شیراز	۲-۵-۱	۰/۹۱	۲/۲۵	۲۱	۰/۹۴	۱/۹۳	۱۸
همدان (فرودگاه)	۲-۵-۱	۰/۷۹	۳/۴۶	۳۳	۰/۸۸	۲/۶۳	۲۴
رشت	۲-۸-۱	۰/۹۴	۱/۷۳	۱۶	۰/۹۵	۱/۵۷	۱۰

جدول ۶. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با دو ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره سرد در سال‌های ۲۰۰۹-۲۰۰۵.

ایستگاه	تعداد یاخته	آموزش			آزمون		
		R^2	RMSE (°C)	NRMSE (%)	R^2	RMSE (°C)	NRMSE (%)
کرمان	۲-۷-۱	۷۹/۰۳	۲/۹۸	۴۰	۷۹/۳۸	۲/۳۷	۳۳
شیراز	۲-۱۰-۱	۷۷/۷۹	۲/۱۵	۳۸	۸۳/۱۷	۱/۸	۲۴
همدان (فرودگاه)	۲-۵-۱	۸۶/۴۹	۲/۸۱	۳۱	۹۰/۲۵	۲/۳۱	۲۶
رشت	۲-۵-۱	۸۶/۱۲	۲/۰۶	۲۵	۸۶/۶۸	۱/۶۱	۱۹



شکل ۲. مقایسه برازش مقادیر اندازه‌گیری شده و پیش‌بینی شده دمای کمینه در روز آتی توسط مدل رگرسیونی لینا کر در دوره سالانه.

جدول ۷. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با دو ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره گرم در سال‌های ۲۰۰۵-۲۰۰۹.

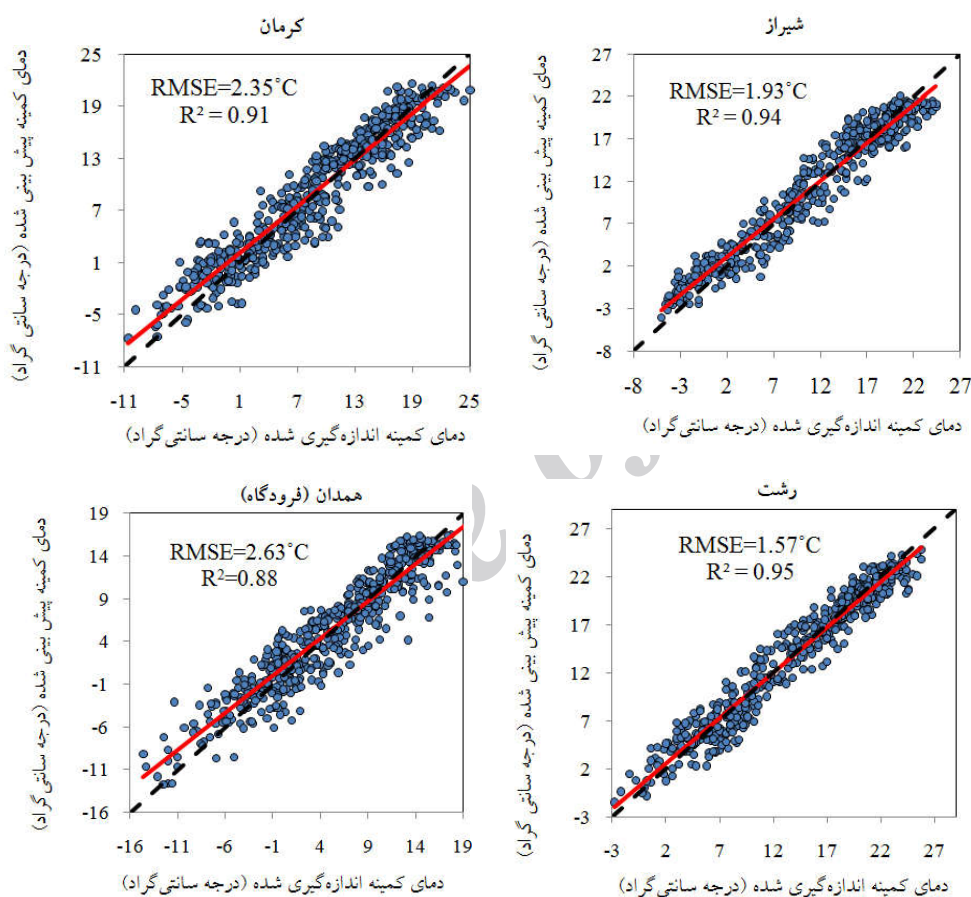
ایستگاه	تعداد یاخته	آموزش		آزمون	
		RMSE (°C)	NRMSE (%)	RMSE (°C)	NRMSE (%)
کرمان	۲-۱۰-۱	۲/۳۳	۱۵	۷۶/۵۶	۱۴
شیراز	۲-۱۰-۱	۲/۱۵	۱۲	۷۸/۵	۱۳
همدان (فرودگاه)	۲-۸-۱	۲	۱۷	۷۷/۵	۲۱
رشت	۲-۵-۱	۱/۴۸	۸	۸۹/۳	۸

۶ و ۷ آورده شده است. با توجه به جدول‌های ۵ و ۶، بهترین نتایج با استفاده از شبکه MLP برای کل سال و دوره سرد، برای رشت و شیراز به‌دست آمده است و ساختارهای به‌دست آمده برای ایستگاه‌های همدان و

در مرحله بعد جهت بررسی رابطه لینا کر برای پیش‌بینی دمای کمینه در روز آتی، از ابزار شبکه عصبی در دوره‌های سالانه، سرد و گرم بهره گرفته شد. نتایج شبیه‌سازی‌های شبکه‌های عصبی منتخب در جدول‌های ۵،

نمودار مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده به کمک شبکه‌های عصبی معرفی شده در جدول ۵، در شکل ۳ آورده شده است. طبق این نمودار، ایستگاه‌های رشت و شیراز به ترتیب با ضریب تعیین ۹۵ و ۹۴ درصد، بهترین برازش را نشان می‌دهند.

کرمان، خطای بیشتری را نشان داده‌اند. در دوره گرم سال طبق جدول ۷، بهترین نتایج برای رشت و همدان حاصل شده است و ساختارهای به‌دست آمده برای شیراز و کرمان خطای بیشتری را نشان داده‌اند. همان‌طور که مشخص است، برای پیش‌بینی دمای کمینه در روز آتی، شبکه‌های عصبی نسبت به مدل تجربی لیناگر کارایی بهتری داشته‌اند.



شکل ۳. مقایسه برازش مقادیر اندازه‌گیری شده و پیش‌بینی شده دمای کمینه در روز آتی توسط شبکه‌های عصبی مصنوعی منتخب (با دو ورودی) در دوره سالانه.

جدول ۸. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با سه ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره سالانه در سال‌های ۲۰۰۹-۲۰۰۵.

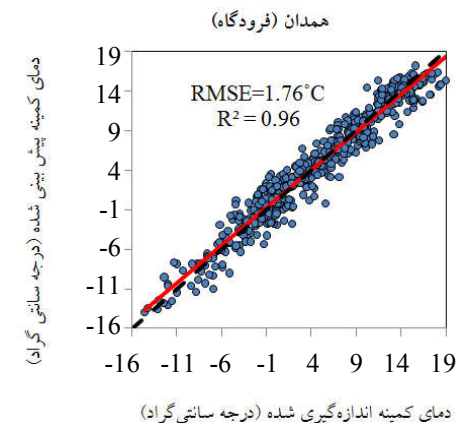
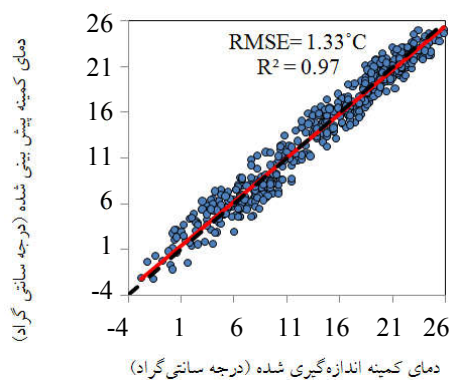
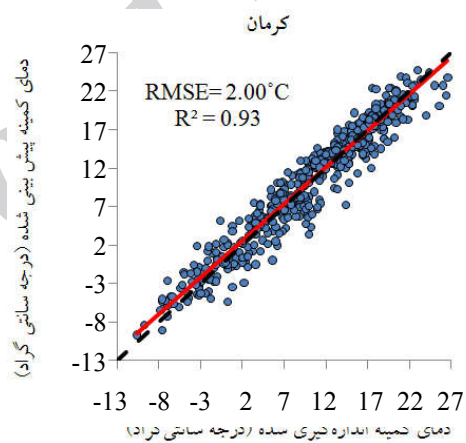

آزمون			آموزش			تعداد یاخته	ایستگاه
R ²	RMSE (°C)	NRMSE (%)	R ²	RMSE (°C)	NRMSE (%)		
۰/۹۳	۲/۰۰	۱۹	۰/۹۱	۲/۳۷	۲۲	۳-۱۰-۱	کرمان
۰/۹۴	۱/۷۶	۱۶	۰/۹۵	۱/۹۶	۱۳	۳-۱۱-۱	شیراز
۰/۹۶	۱/۷۶	۱۶	۰/۹۵	۲/۰۳	۱۹	۳-۵-۱	همدان (فرودگاه)
۰/۹۷	۱/۳۳	۹	۰/۹۶	۱/۵۶	۱۱	۳-۱۵-۱	رشت

جدول ۹. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با سه ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره سرد در سال‌های ۲۰۰۵-۲۰۰۹.

آزمون			آموزش			تعداد یاخته	ایستگاه
R ²	RMSE (°C)	NRMSE (%)	R ²	RMSE (°C)	NRMSE (%)		
۸۰/۸۲	۲/۳۰	۳۵	۷۷/۶۱	۲/۷۳	۳۹	۳-۵-۱	کرمان
۸۷/۰۴	۱/۷۵	۲۷	۸۰/۱	۲/۲۱	۳۵	۳-۷-۱	شیراز
۹۲/۹۳	۲/۱۱	۲۹	۸۷/۶۱	۲/۶۳	۳۱	۳-۷-۱	همدان (فرودگاه)
۹۴/۰۲	۱/۳۹	۱۷	۸۷/۶۱	۱/۹۰	۲۴	۳-۱۰-۱	رشت

جدول ۱۰. نتایج آماری مراحل آموزش و آزمون شبکه عصبی پرسپترون چندلایه (با سه ورودی) جهت برآورد دمای کمینه در روز آتی برای دوره گرم در سال‌های ۲۰۰۵-۲۰۰۹.

آزمون			آموزش			تعداد یاخته	ایستگاه
R ²	RMSE (°C)	NRMSE (%)	R ²	RMSE (°C)	NRMSE (%)		
۸۶/۳	۱/۶۷	۱۳	۸۱/۵۴	۲/۰۲	۱۴	۳-۵-۱	کرمان
۹۲/۰۰	۱/۵۰	۱۲	۰/۸۳	۱/۹۱	۱۴	۳-۵-۱	شیراز
۸۸/۵۵	۱/۴۰	۱۱	۸۲/۸۱	۱/۷۶	۱۵	۳-۹-۱	همدان (فرودگاه)
۹۱/۰۰	۱/۰۲	۶	۸۶/۸۶	۱/۹۹	۷	۳-۴-۱	رشت



شکل ۴. مقایسه برازش مقادیر اندازه‌گیری شده و پیش‌بینی شده دمای کمینه در روز آتی توسط شبکه‌های عصبی مصنوعی منتخب با سه ورودی (دمای نقطه شبنم، بیشینه دما و رطوبت نسبی) در دوره سالانه.

قره‌خانی و همکاران (۱۳۹۲) همخوانی دارد. گفتنی است در پژوهش ذکر شده، بهترین نتایج جهت پیش‌بینی دمای کمینه در روز آتی توسط مدل لیناگر، برای ایستگاه‌هایی با رژیم معتدل (که رطوبت بیشتری نسبت به سایر ایستگاه‌های مورد مطالعه داشتند) به دست آمده است.

بهترین نتایج شبکه‌های عصبی MLP، با الگوریتم لونبرگ-مارکوات، تابع انتقال لوگ سیگموئید در لایه پنهان، تابع انتقال خطی در لایه خروجی و دو پارامتر ورودی دمای نقطه شبنم و بیشینه دما، برای ایستگاه‌های رشت و شیراز در دوره سالانه با RMSE برابر با ۱/۵۷ و ۱/۹۳ درجه سانتی‌گراد به دست آمد. ایستگاه‌های کرمان و همدان با RMSE برابر با ۲/۳۵ و ۲/۶۳ درجه سانتی‌گراد، خطای بیشتری نشان دادند. این نتایج نیز با نتایج مطالعه قره‌خانی و همکاران (۱۳۹۲) همخوانی دارد. نتایج شبکه عصبی با سه ورودی (اضافه کردن پارامتر رطوبت نسبی) نشان داد که ریشه میانگین مربعات خطا در مرحله آزمون، در ایستگاه‌های کرمان، شیراز، همدان (فرودگاه) و رشت به ترتیب ۱۷/۴، ۱۲/۹، ۴۹/۴ و ۱۸/۳ درصد بهبود یافته است. همان‌گونه که مشهود است، در ایستگاه همدان (با اقلیم SA-K-W) اضافه کردن پارامتر رطوبت نسبی به مدل لیناگر و استفاده از شبکه عصبی مصنوعی در دوره سالانه می‌تواند به‌طور چشمگیری نتایج برآورد دمای کمینه در روز آتی را بهبود بخشد. این بهبود، با نتایج جرعه‌نوش و سپاسخواه (۱۳۹۴) همخوانی دارد که اثر رطوبت نسبی در ارتباط بین نقطه شبنم و کمینه دما را بررسی کرده بودند.

نتایج بررسی انجام شده در رابطه با توانایی مدل‌ها در دوره گرم و سرد نشان می‌دهد که برآوردهای کمینه دما در طول دوره سرد سال با شبکه عصبی مصنوعی با دو ورودی باعث ۱۳/۰۸، ۱۲/۸۹، ۱۳/۸۵ و ۲۹/۸۴ درصد کاهش خطا نسبت به مدل لیناگر در شهرهای کرمان، شیراز، همدان و رشت می‌شود که این بهبود در دوره گرم سال برای شهرهای ذکر شده به ترتیب برابر ۲۷/۱۲، ۳۱/۷۶، ۷۱/۵۳ و ۷۹/۲۴ درصد است.

در مرحله بعد، جهت بررسی نقش رطوبت نسبی برای بهبود مدل شبکه عصبی، این پارامتر به عنوان ورودی سوم به شبکه پرسپترون چندلایه افزوده شد. نتایج در جدول‌های ۸، ۹ و ۱۰ آورده شده است. با توجه به این نتایج، کمترین و بیشترین خطا برای هر سه دوره سالانه، سرد و گرم به ترتیب متعلق به رشت و کرمان است. با این حال، تنها در ایستگاه شیراز، در طول دوره سرد، خطای کمتری ($RMSE=1/75^{\circ}C$) نسبت به دوره سالانه سالانه ($RMSE=1/76^{\circ}C$) به دست آمد. در سایر ایستگاه‌ها، میزان خطا در دوره سرد نسبت به دوره سالانه مقادیر بیشتری داشت. نمودار مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده توسط شبکه‌های عصبی معرفی شده در جدول ۸ در شکل ۴ آورده شده است. طبق این شکل نیز مقادیر پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی با سه ورودی برای دوره سالانه برای ایستگاه رشت با ضریب تعیین ۰/۹۷ بهترین برازش را نشان می‌دهد. به علت محدودیت حجم مقاله، شکل‌های مربوط به دوره گرم و سرد سال در مقاله درج نشده‌اند.

۴ نتیجه‌گیری

ریشه میانگین مربعات خطای نتایج مدل رگرسیونی لیناگر برای ایستگاه رشت با اقلیم PH-C-W و ایستگاه شیراز با اقلیم PH-C-WC-W، به ترتیب ۱/۷۰ و ۲/۴۴ درجه سانتی‌گراد به دست آمد. خطای RMSE دو ایستگاه همدان و کرمان نیز به ترتیب با اقلیم‌های سرد نیمه‌خشک و گرم و خشک، برابر ۲/۷۷ و ۲/۷۸ درجه سانتی‌گراد محاسبه شد. طبق طبقه‌بندی یونسکو، ایستگاه رشت و کرمان به ترتیب رژیم رطوبتی خیلی مرطوب و خشک دارند و از آنجا که پارامتر رطوبت نسبی، مهم‌ترین عامل در ارتباط بین دمای نقطه شبنم و کمینه دما در روز آینده است، می‌توان گفت مدل لیناگر در ایستگاهی با رژیم مرطوب، کارایی بهتری جهت پیش‌بینی کمینه دمای هوا در روز بعد داشته است. این نتیجه با نتایج پژوهش

انصاری، ح.، کوهی، م. و صالح‌نیا، ن.، ۱۳۹۱، پیش‌بینی یخبندان‌های تابشی با استفاده از حداقل داده‌های هواشناسی: نشریه آب و خاک (علوم و صنایع کشاورزی)، ۲۶(۱)، ۱۱۴-۱۲۶.

پاشائیان، م.، قلی‌زاده، ب.، سلطانی، س. ب.، بهزادی، ه. و شعبانپور، م. ر.، ۱۳۹۴، پیش‌بینی دمای حداقل با استفاده از مدل‌های چندجمله‌ای (مطالعه موردی: ایستگاه شاهرود)، پنجمین کنفرانس منطقه‌ای تغییر اقلیم، تهران، ۵ و ۶ بهمن ۱۳۹۴.

تقوی، ف.، نیستانی، ا. و قادر، س.، ۱۳۹۲، ارزیابی پیش‌بینی‌های کوتاه مدت بارش مدل عددی WRF در منطقه ایران در دوره یک ماهه: مجله فیزیک زمین و فضا، ۳۹(۲)، ۱۴۵-۱۷۰.

جرعه‌نوش، م. ه. و سپاسخواه، ع. ر.، ۱۳۹۴، پیش‌بینی سرمازدگی با تخمین دمای حداقل در دشت باجگاه و کوشکک: کنگره ملی آبیاری و زهکشی ایران، پردیس دانشگاه فردوسی مشهد، ۲۳ و ۲۴ اردیبهشت ۱۳۹۴.

حسینی، س. ا.، ۱۳۸۸، برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی: پایان‌نامه کارشناسی ارشد جغرافیای طبیعی (اقلیم‌شناسی)، دانشکده ادبیات و علوم انسانی، دانشگاه محقق اردبیلی، ص ۹۵.

خوشحال جهرمی، ف.، زندپارسا، ش. و ده‌بزرگی، ف.، ۱۳۹۴، مقایسه شبکه عصبی مصنوعی و رگرسیون چند متغیره خطی در برآورد دمای سطح خاک در منطقه نیمه خشک: اولین کنگره بین‌المللی کشاورزی سالم، تغذیه سالم، جامعه سالم، تهران، مرداد ماه ۱۳۹۴.

ده بزرگی، ف. و سپاسخواه، ع. ر.، ۱۳۸۷، تخمین تبخیر-تعرق سطوح گیاهی مرجع با روش شبکه‌های عصبی مصنوعی: دومین همایش ملی مدیریت

مقایسه نتایج مدل شبکه عصبی مصنوعی با سه ورودی و دو ورودی، نشان داد که در دوره سرد سال، با اضافه کردن پارامتر رطوبت نسبی، خطا به میزان ۳/۰۴، ۲/۸۶، ۹/۴۸ و ۱۵/۸۳ درصد در شهرهای کرمان، شیراز، همدان و رشت بهبود یافت که این مقادیر برای دوره گرم سال به ترتیب ۶، ۱۳/۳۳، ۲/۸۶ و ۱۸/۶۳ درصد بودند. این اعداد نشان می‌دهند که اضافه کردن رطوبت نسبی به‌عنوان ورودی سوم به مدل شبکه عصبی در طول دوره سرد سال، تنها در ایستگاه همدان بهبود بیشتری را نسبت به دوره گرم سال ایجاد کرده است درحالی‌که در سایر ایستگاه‌ها، اضافه کردن رطوبت نسبی در دوره گرم سال، منجر به کاهش خطای بیشتری شده است. به‌طور کلی، نتایج این مطالعه هم‌راستا با پژوهش‌های امیرمردادی و بهمنی (۱۳۹۳)، هوشیار و همکاران (۱۳۹۱) و خوشحال جهرمی و همکاران (۱۳۹۴)، نشان‌دهنده کارایی بهتر شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیونی خطی است.

منابع

اسفندیاری، ف.، حسینی، س. ا.، آزادی مبارکی، م. و حجاری‌زاده، ز.، ۱۳۸۹، پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چندلایه (MLP): فصلنامه جغرافیا، انجمن جغرافیایی ایران، ۸(۲۷)، ۴۵-۶۵.

اصغری مقدم، ا.، نورانی، و. و ندیری، ع.، ۱۳۸۷، مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی: مجله دانش کشاورزی دانشگاه تبریز، ۱۸(۱)، ۱-۱۵.

امیرمردادی، ک. و بهمنی، ا.، ۱۳۹۳، برآورد دمای روزانه خاک با استفاده از شبکه عصبی مصنوعی: نشریه پژوهش‌های خاک (علوم خاک و آب) الف، ۲۸(۳)، ۵۴۳-۵۵۶.

- منهاج، م. ب. و سیفی پور، ن.، ۱۳۷۷، کاربرد هوش محاسباتی در کنترل: مرکز نشر پروفیسور حسابی، تهران.
- منهاج، م. ب.، ۱۳۸۷، مبانی شبکه‌های عصبی هوش محاسباتی: انتشارات دانشگاه صنعتی امیرکبیر، جلد اول، چاپ پنجم، تهران.
- مهدویان، ع.، ۱۳۷۸، پیش‌بینی محلی دمای حداقل شبانه‌روزی در منطقه کرج: پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه تهران.
- ناظم‌السادات، س. ج.، سپاسخواه، ع. ر. و محمدی، ش.، ۱۳۸۰، بررسی رابطه دمای نقطه شبنم روزانه و دمای کمینه روز بعد در منطقه جهرم فارس (مطالعه موردی): علوم و فنون کشاورزی و منابع طبیعی، (۳)۵، ۹-۱۶.
- هوشیار، م.، حسینی، س. ا. و مسگری، ا.، ۱۳۹۱، مدل‌سازی دماهای حداقل شهرستان ارومیه با استفاده از مدل‌های رگرسیونی خطی و غیرخطی چندگانه و شبکه‌های عصبی مصنوعی: اندیشه جغرافیایی، (۱۲)۶، ۱-۳۳.
- Allen, C. C., 1957, A simplified equation for minimum temperature prediction: Monthly Weather Review, **85**(4), 119-120.
- Dickey, W. W., 1960, Forecasting of Maximum and Minimum Temperature: U.S. Weather Bureau, Washington, D. C.
- Emmanouil, G., Galanis, G., and Kallos, G., 2006, Statistical methods for the prediction of night-time cooling and minimum temperature: Meteorological Applications, **13**(2), 169-178.
- Humphreys, C. E., 2003, Physics of The Air, second edition, M. C. Graw-Hill Book Company, INC.
- Jain, A., 2003, Predicting air temperature for frost warning using artificial neural network, a thesis submitted to the graduate faculty of the university of Georgia in partial fulfillment of the requirements for the degree master of science, Athens, Georgia, 92.
- شبکه‌های آبیاری و زهکشی، اهواز، دانشگاه چمران، بهمن ۱۳۸۷.
- سبزی‌پرور، ع. ا. و علیانی، ا.، ۱۳۹۰، ارزیابی عملکرد شبکه‌های عصبی مصنوعی در برآورد تابش خورشیدی کل روزانه و مقایسه آن با نتایج مدل انگستروم (مطالعه موردی: ایستگاه همدیدی تبریز): مجله ژئوفیزیک ایران، (۳)۵، ۳۰-۴۱.
- شهاب‌فر، ع. ر.، احترامیان، ک. و معتمدی، م.، ۱۳۸۳، پیش‌بینی کوتاه مدت سرمازدگی محصولات کشاورزی با استفاده از رابطه دمای نقطه شبنم و دمای حداقل در شهر مشهد: فصلنامه جغرافیایی سرزمین، (۲)۱، ۹۷-۱۰۵.
- علیقلی‌نیا، ت.، رسولی‌مجد، ن.، رضایی، ح. و جباری، آ.، ۱۳۹۵، کاربرد شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق با حداقل داده‌های هواشناسی (مطالعه موردی: شهر ارومیه): محیط زیست و مهندسی آب، (۲)۲، ۱۲۲-۱۳۵.
- غفاری، ع.، قاسمی، و. و دپائو، ا.، ۱۳۹۴، پهنه‌بندی اقلیم کشاورزی ایران با استفاده از روش یونسکو: نشریه علمی-پژوهشی زراعت دیم ایران، (۱)۴، ۶۳-۷۴.
- قره‌خانی، ا.، قهرمان، ن. و بختیاری، ب.، ۱۳۹۲، پیش‌بینی دمای حداقل (سرمازدگی) با استفاده از مدل‌های تجربی و هوش مصنوعی (مطالعه موردی: استان فارس): دومین کنفرانس بین‌المللی مدل‌سازی گیاه، آب، خاک و هوا، کرمان، ۱۸ و ۱۹ اردیبهشت ۱۳۹۲.
- کوچک‌زاده، م.، بهمنی، ع.، ۱۳۸۴، ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز جهت برآورد تبخیر و تعرق مرجع: مجله علوم کشاورزی، (۴)۱۱، ۸۷-۹۷.

- Sakcali, M. S., 2008, Eco-physiology of *Capparis spinosa* L.: A plant suitable for combating Desertification: *Pakistan Journal of Botany*, **40**(4), 1481-1486.
- Smith, R. M., 1973, Frost Forecasting for Christchurch: New Zealand Meteorological Service, Tech. Note, **217**, 1-5.
- Tokar, A. S., and Markus, M., 2000, Precipitation runoff modeling using artificial neural network and conceptual models: *Journal of Hydrologic Engineering, ASCE*, **5**, 156-161.
- Verstrate, M., Brink, A., Scholles, R., Beniston, M., and Stafford, S., 2008, Climate change and desertification: Where do we stand, where should we go?: *Global and planetary change*, **64**(3-4), 105-110.
- Kanani, S., Asadollahfardi, G. and Ghanbari, A., 2008, Application of artificial neural network to predict total dissolved solid in Achechay River Basin: *World Applied Sciences Journal*, **4**(5), 646-654.
- Karlsson, M., 2001, Prediction of hoar-frost by use of a road weather information system: *Meteorological Applications*, **8**(1), 95-105.
- Levitt, J., 1980, Responses of Plant to Environmental Stress, **1**, Chilling, Freezing and High Temperature Stresses: Academic Press, New York.
- Linacre, E., 1992, Climate data and resources: Routledge, London.
- Moran, J., and Morgan, M. D., 1995, Essential of Weather: Prentice Hall, New York.

Archive of SID

Comparison of Multi-Layer Perceptron artificial neural network and Linacre regression model performance for predicting daily minimum temperature (Case study: Kerman, Shiraz, Rasht and Hamedan)

Ali Akbar Sabziparvar^{1*}, and Fatemeh Khoshhal Jahromi²

¹Professor, Water Engineering Department, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

²Ph. D. student, Water Engineering Department, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

(Received: 05 September 2017, Accepted: 09 October 2018)

Summary

The prediction of the minimum temperature is one of the main approaches to manage and reduce the risk damage caused by frostbite. For this purpose, using daily statistics of minimum, maximum and dew point temperatures during the period of 2005 to 2009, the minimum temperature of the next day was predicted for four stations (Rasht, Kerman, Shiraz and Hamedan) with different climate types by applying the Linacre regression model and the Multi-Layer Perceptron artificial neural network (MLP) in the whole year, the cold period (from October to late March) and the warm period (from April to late September). For this aim, the Matlab-2015 and IBM SPSS-20 software were used and statistical criteria RMSE, NRMSE and R^2 were applied to evaluate the performance of the models. The results of this study, in all three periods, demonstrated that the best estimate of the Linacre regression model was obtained with root mean square error of 1.70 and 2.44°C for the whole year, 2.01 and 2.32°C for the cold period and 1.51 and 2.24°C for the warm period for Rasht and Shiraz stations with the PH-C-W and SA-C-W, respectively. The best results from MLP neural networks with Levenberg-Marquardt algorithm, logic sigmoid transfer function in the hidden layer, the linear transfer function in the output layer and two inputs (dew point and maximum temperature), like the Linacre regression model, were obtained with RMSE of 1.57 and 1.93°C for the whole year and 1.61 and 1.8 for the cold period for Rasht and Shiraz stations, respectively. The RMSE of the best results from MLP neural networks in the warm period was 1.21 and 1.44°C for Rasht and Hamedan stations, respectively. To evaluate the role of relative humidity on model results, this parameter was added as a third input to the multi-layer Perceptron network. The improved RMSE for the whole year was 17.4, 12.9, 49.4 and 18.3 percent and for the cold period of the year was 3.4, 2.86, 9.48 and 15.83 percent at Kerman, Shiraz, Hamedan and Rasht stations, respectively. These values for the warm period were 6, 13.33, 2.86 and 18.63 percent for the above mentioned stations. These improved errors indicate that only at Hamedan station, the cold period of the year produces more improvement in error reduction than the warm period of the year by adding relative humidity as the third input to the neural network model. In other stations, adding relative humidity in the warm year has led to a reduction in the error rate. In general, it can be said that selected MLP networks had better performance than the Linacre regression model in predicting the minimum daily temperature.

Keywords: forecasting, minimum temperature, artificial neural network, regression method

*Corresponding author: