



مقایسه شبکه‌های عصبی MLP و RBF در برآورد میانگین رطوبت نسبی

مطالعه موردی: خراسان جنوبی

تاریخ دریافت: ۱۴۰۳/۰۶/۱۲ تاریخ پذیرش: ۱۴۰۳/۰۸/۱۵

چکیده

رطوبت نسبی از عوامل محیطی مؤثر بر رشد و شیوع بیماری‌های گیاهی بوده و به دلیل ارتباط مستقیم آن با بارش از اهمیت ویژه‌ای برخوردار است. لذا هدف پژوهش حاضر برآورد میانگین رطوبت نسبی در استان خراسان جنوبی به‌عنوان منطقه‌ای خشک با استفاده از شبکه‌های عصبی MLP و RBF می‌باشد. برای این منظور از امکانات نرم‌افزار RStudio و متغیرهای میانگین رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی، میانگین، حداکثر و حداقل دمای هوای، میانگین سرعت باد، مجموع ساعات آفتابی در قالب ۶ سناریو و در طی دوره آماری ۲۳ ساله (۲۰۰۰-۲۰۲۳) استفاده گردید. نتایج نشان داد که مقدار همبستگی (R) بین داده‌های مشاهده‌شده و پیش‌بینی‌شده در هر دو روش برابر ۰/۹۸۰ درصد، مقدار R^2 در روش MLP برابر ۰/۹۵۳ و در روش RBF برابر ۰/۹۶۵ درصد، مقدار RMSE برای روش MLP برابر ۰/۸۴۵ و برای روش RBF برابر ۰/۷۴۰ درصد و مقدار MSE برای روش MLP برابر ۰/۷۱۴ و برای روش RBF برابر ۰/۵۴۸ درصد می‌باشد. در مجموع شبکه‌های MLP و RBF دقت نسبتاً مناسبی را در تخمین میانگین رطوبت نسبی سالانه دارا می‌باشند، ولی خطای شبکه RBF (۰/۵۶۱) کمتر از شبکه MLP (۰/۷۰۷) بوده و از عملکرد بهتری نسبت به MLP در برآورد رطوبت نسبی برخوردار است.

کلیدواژه‌ها: شبکه عصبی، MLP، RBF، رطوبت نسبی، خراسان جنوبی

مقدمه


اخیراً بسیاری از دانشمندان و محققان تلاش کرده‌اند که با بررسی برخی پارامترهای اقلیمی ثابت کنند که نوسانات و تغییراتی در اقلیم به وقوع پیوسته است (Liu, 2009: 721; Zhang et al., 2007: 155; Feidas et al., 2006: 78; Jaagus, 2011: 503; Tabari & Aghajamloo, 2012: 396; Asadi & Karami, 2022: 1035). بر همین اساس یکی از چالش‌های قرن ۲۱ میلادی موضوع نوسانات و تغییرات اقلیمی است (Hulme et al., 1999: 689) که از دلایل اصلی نوسانات، می‌توان به افزایش انرژی ورودی از خورشید و گرمایش جهانی ناشی از تشدید اثرات گلخانه‌ای اشاره نمود (Bilgili et al., 2024: 2). این تغییرات به‌نوبه‌ی خود باعث به وجود آمدن ناهنجاری‌های هیدرولوژیک، همچون خشک‌سالی‌ها و سیلاب‌ها می‌شود و محیط‌زیست و زندگی انسان را تحت تأثیر قرار می‌دهد (Gleick, 1989: 330; Arora, 2001: 144; Boer, 2001: 3336; Nijssen et al., 2001: 144). در میان متغیرهای هواشناسی در مقایسه با دما و بارش، تحقیقات اندکی در زمینه‌ی بررسی روند تغییرات زمانی رطوبت نسبی انجام شده است، درحالی‌که تأثیر مستقیم بر مقدار دید،

^۱ گروه آموزش جغرافیا، دانشگاه فرهنگیان، تهران، ایران (نویسنده مسئول) Email: Asadi.m@cfu.ac.ir

تشکیل ابر، مه و مه دود دارد (Elliott & Angell, 1997: 41). بعلاوه، رطوبت نسبی یک عامل محیطی مؤثر بر رشد گیاه و شیوع بیماری‌های گیاهی می‌باشد و به دلیل ارتباط مستقیم آن با بارش از اهمیت ویژه‌ای برخوردار است. به‌منظور آشکارسازی تغییرات روند رطوبت نسبی، در سطح جهان و ایران تحقیقاتی صورت گرفته که به چند مورد از آن‌ها اشاره می‌شود: Choi et al (2019) با استفاده از روش MLP به پیش‌بینی مقادیر دمای هوا و رطوبت نسبی در شرایط آزمایشگاهی پرداختند. در این مطالعه MLP با چهار لایه پنهان و ۱۲۸ گره برای دمای هوا و ۶۴ گره برای رطوبت نسبی بهینه شده است. با طولانی‌تر شدن زمان پیش‌بینی، دقت کاهش یافت؛ بنابراین، نتایج بیانگر این بود که جمع‌آوری داده‌های بیشتر از گلخانه‌ها در مکان‌های مختلف و اصلاح ساختار شبکه عصبی برای تعمیم ضروری است. (Shad et al (2022) با استفاده از مدل‌های SARIMA، ANN و MLP به پیش‌بینی رطوبت نسبی ماهانه در دهلی هند پرداختند. نتایج نشان داد که مدل‌های شبکه عصبی برای پیش‌بینی رطوبت نسبی از مدل SARIMA قابل‌اعتمادتر است. (Gurlek (2023) در سیواس، ترکیه با استفاده از شبکه‌های عصبی مصنوعی مانند MLP رطوبت نسبی ماهانه را پیش‌بینی نمود. نتایج نشان داد که روش‌های شبکه عصبی پیش‌بینی‌های رضایت بخشی را برای رطوبت نسبی ارائه می‌دهند. (Wang et al (2024) با استفاده از روش‌های یادگیری ماشین و داده‌های مدل آب‌وهوا ERA5 به بهبود مقادیر رطوبت نسبی تروپوسفر فوقانی پرداختند. نتایج نشان داد که مدل شبکه عصبی ANN با همبستگی ۹۳ درصد می‌تواند مقادیر رطوبت در تروپوسفر فوقانی را پیش‌بینی نماید. همچنین نتایج بیانگر این بود که می‌توان از روش ANN در سایر مدل‌های آب‌وهوا برای بهبود پیش‌بینی رطوبت و پشتیبانی از برنامه‌های کاربردی تحقیقات هواوردی و آب‌وهوا استفاده کرد. در ایران نیز Omidvar & nabavi (2015) zadeh در شهرهای کرمان، بافت و میانه جیرفت با استفاده از شبکه عصبی مصنوعی به پیش‌بینی بارش روزانه استان کرمان پرداختند. نتایج نشان داد که شبکه‌های عصبی مصنوعی تابع شعاعی از دقت بسیار بیشتر و خطای کمتری نسبت به شبکه عصبی پرسپترون، برای تخمین بارش روزانه در هر سه ایستگاه برخوردار هستند. (Hasanvand et al (2022) با استفاده از شبکه عصبی مصنوعی در شهرستان الشتر به مطالعه و ارزیابی دما پرداختند. بر اساس نتایج آن؛ دماهای متوسط؛ بیشینه و کمینه دارای روندی افزایشی بوده است. از نظر فصلی نیز زمستان شدیدترین تغییرات را در منطقه در برداشته است میزان موارد اختلاف بین بازه زمانی ۲۰ ساله و ۳۰ ساله به ترتیب ۹۵ درصد و ۸۰ درصد می‌باشد. در بازه ۲۰ ساله اخیر؛ بیشترین و کمترین روند معنی‌دار ایستگاه‌ها؛ به ترتیب در فصول تابستان و پاییز مشاهده گردید. (Iranshahi et al (2023) در ایستگاه‌های الشتر و خرم‌آباد به بررسی اثرات تغییر اقلیم بر وضعیت دما و بارش با استفاده از شبکه عصبی و گزارش ششم IPCC پرداختند. به‌طور کلی، نتایج نشان داد که این متغیرها در هر دو دوره آتی در مقیاس ماهانه دارای نوسان‌های متعددی خواهند بود، به‌طوری‌که در دو ایستگاه الشتر و خرم‌آباد طی دوره‌های آینده نزدیک و آینده دور دمای حداکثر و دمای حداقل نسبت به دوره مشاهداتی در تمام سناریوهای SSP روندی افزایشی خواهند داشت و تغییرات دمای حداقل نسبت به دمای حداکثر بیش‌تر خواهد بود. در آینده نزدیک میانگین بارش سالانه ایستگاه الشتر بین ۰/۳ تا ۱۶ درصد و ایستگاه خرم‌آباد بین ۷ تا ۱۲ درصد تحت سناریوهای SSP کاهش خواهد داشت. در آینده دور نیز میانگین بارش سالانه ایستگاه الشتر بین ۱۰ تا ۲۰ درصد و ایستگاه خرم‌آباد بین ۱۲ تا ۲۴ درصد تحت سناریوهای SSP کاهش خواهد داشت. (Asakereh et al (2024) در ایستگاه همدید یزد به ارزیابی کاربرد شبکه عصبی مصنوعی در شبیه‌سازی میانگین دمای بیشینه سده آینده پرداختند. نتایج حاکی از این بود که در هر دو دوره یادشده افزایش دمای بیشینه ایستگاه همدید یزد در فصول زمستان (۰/۴ تا ۶/۹ درجه سلسیوس)، بهار (۱/۱ تا ۵/۷ درجه سلسیوس) و تابستان (۱/۱ تا ۵/۷ درجه سلسیوس) مورد انتظار است. در فصل پاییز فقط در ماه‌های نوامبر و دسامبر و تحت سناریوهای RCP4.5 و RCP8.5 افزایش دما در دوره دوم مورد انتظار است و در ماه اکتبر دمای بیشینه کاسته (۰/۶ تا ۴/۱ درجه سلسیوس) می‌شود. همان‌طور که در پیشینه پژوهش نیز مشاهده گردید بیشتر پژوهش‌ها در ایران از رطوبت نسبی به‌عنوان عاملی برای پیش‌بینی سایر پارامترها استفاده نموده‌اند و در کمتر پژوهشی با استفاده از شبکه‌های عصبی مانند MLP و RBF به‌صورت مقایسه‌ای رطوبت نسبی را پیش‌بینی گردیده است. در منطقه مورد مطالعه نیز برای اولین بار می‌باشد که این موارد به‌عنوان نوآوری پژوهش می‌توان تلقی نمود. لذا هدف اصلی پژوهش حاضر مقایسه شبکه عصبی MLP و RBF در پیش‌بینی میانگین رطوبت نسبی در خراسان جنوبی است که به دلیل قرار گرفتن در اقلیم خشک تنش‌های رطوبتی در آن بسیار بالا است.

منطقه مورد مطالعه

استان خراسان جنوبی با مساحتی بالغ بر ۸۲۸۶۴ کیلومترمربع در شرق کشور ایران بوده و بین مختصات جغرافیایی ۵۷ درجه و ۴۶ دقیقه تا ۶۰ درجه و ۵۷ دقیقه طول شرقی و ۳۰ درجه و ۳۵ دقیقه تا ۳۴ درجه و ۱۴ دقیقه عرض شمالی واقع شده است. این استان از سمت شرق با کشور افغانستان، از غرب با استان‌های یزد، اصفهان و سمنان، از شمال با استان خراسان رضوی و از جنوب با استان‌های سیستان و بلوچستان و کرمان مرز مشترک دارد (شکل ۱). به علت پایین بودن عرض جغرافیایی و نزدیکی به مدار رأس‌السرطان و به تبعیت از گردش عمومی جو در طول دوره گرم تحت تاثیر مرکز پرفشار جنب‌حاره‌ای واقع و دارای رژیم بارندگی زمستانه است. طبق بررسی‌های آماری میانگین بارش منطقه حدود ۱۸۰ میلی‌متر در سال و میانگین سالانه رطوبت نسبی آن ۳۶ درصد می‌باشد.



شکل ۱: موقعیت قرارگیری منطقه مورد مطالعه در کشور ایران

Figure 1: Location of the study area in Iran


مواد و روش‌ها

در پژوهش حاضر، از آمار هواشناسی (میانگین رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی، میانگین، حداکثر و حداقل دمای هوای، میانگین سرعت باد، مجموع ساعات آفتابی) ایستگاه‌های سینوپتیک استان خراسان جنوبی (ایستگاه‌های بیرجند، قاین، بشرویه، فردوس، نهبندان، خور بیرجند) به صورت میانگین سالانه در بازه آماری ۲۳ ساله ۲۰۰۰ تا ۲۰۲۳ استفاده گردید. در این تحقیق از شبکه‌های عصبی MLP و RBF و از امکانات نرم‌افزار RStudio (برای اجرای مدل MLP و RBF در نرم‌افزار RStudio به ترتیب از کتابخانه‌های Neuralnet و Kernlab استفاده گردید) برای تدوین مدل برآورد میانگین رطوبت نسبی سالانه استان خراسان جنوبی استفاده شده است. مدل مذکور داده‌ها را به سه بخش مختلف با عنوان داده‌های آموزشی، داده‌های صحت سنجی و داده‌های آزمون تقسیم می‌کند. برای این منظور ابتدا از سال ۲۰۰۰ تا ۲۰۲۳ داده‌های ماهانه رطوبت شش ایستگاه بیرجند، قاین، بشرویه، فردوس، نهبندان، خور بیرجند تهیه گردید از ۱۳۸ سال (عدد)، ۱۰۴ عدد (۷۵٪) داده سالانه برای آموزش شبکه و ۲۱ عدد (۱۵٪) داده سالانه برای صحت سنجی و ۱۳ عدد (۱۰٪) داده سالانه به عنوان داده‌های آزمون استفاده گردید. به عبارت دیگر، از مجموع داده‌های تاریخی دوسوم آن‌ها به عنوان داده‌های کالیبراسیون و یک‌سوم به عنوان داده‌های آزمون در نظر گرفته شدند. پس از ورود داده‌ها، نرم‌افزار با ۷۵٪ داده‌ها شروع به

آموزش شبکه کرده و سپس با ۱۵٪ داده‌ها شبکه را آزمون کرده و با ۱۰٪ اطلاعات باقی‌مانده صحت اطلاعات خروجی برآورد می‌گردد. روند محاسبات در فرآیند آموزش به صورت جریان یک‌طرفه از لایه ورودی به ورودی لایه بعد و در نهایت به خروجی شبکه است. آموزش شبکه چگونگی تنظیم وزن‌های شبکه را بیان می‌کند. ورودی‌های شبکه، متغیرهای میانگین رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی، میانگین، حداکثر و حداقل دمای هوای، میانگین سرعت باد، مجموع ساعات آفتابی در زمان‌های قبل و خروجی شبکه نیز میانگین رطوبت نسبی سالانه است. پس از انتخاب داده‌های ورودی و خروجی شبکه و تعیین ساختار شبکه از لحاظ تابع محرک، تعداد نوروهای لایه پنهان، تعداد لایه‌های پنهان، تعداد تکرار (پاک) مقادیر پارامترهای آموزشی و تابع عملکرد، آموزش شبکه با استفاده از کتابخانه‌های مذکور برنامه RStudio، ابتدا با یک نورو پنهان و ۱۰ تکرار شروع شده و با افزایش آن تا حداکثر تعداد نورو و تکرار ادامه یافت. همچنین در تمام مراحل فوق، پس از هر بار آموزش، شبکه آزمون گردید که برای ارزیابی بهتر عملکرد و انتخاب شبکه بهینه اقدام به آنالیز رگرسیونی و تعیین ضریب همبستگی بین داده‌های ورودی و خروجی در مرحله آموزش و درصد خطا در مرحله آزمون گردید. تعداد بهینه نورو پنهان و تکرار در الگوریتم‌های آموزشی بر اساس بالاترین ضریب همبستگی و خطای کمتر از ۵ درصد مشخص گردید. پس از آزمون‌های مختلف برای آزمون شبکه، تعداد نوروهای لایه پنهان و توابع فعالیت مختلف در لایه پنهان و خروجی، سرانجام مدل نهایی با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی (برآورد رطوبت نسبی سالانه)، دارای کمترین خطا بود و به عنوان مدل نهایی مورد استفاده قرار گرفت. برای ارزیابی عملکرد شبکه‌های عصبی نیز از شاخص‌های، انحراف معیار، واریانس، ضریب همبستگی (R)، ضریب تعیین (R^2)، مجذور میانگین مربعات خطا (RMSE)، میانگین مربعات خطا (MSE)، میانگین درصد خطا (Error) استفاده شده است.

شبکه‌های پرسپترون چندلایه (MLP)

شبکه عصبی مصنوعی پرسپترون چندلایه ((Multi-Layer Perceptron (MLP) الگوریتم یادگیری ماشین است که از مغز بیولوژیکی الهام گرفته و یک مدل غیرخطی و پیش‌خور می‌باشد که بر تعیین وابستگی بین پارامترهای ورودی و خروجی با شبیه‌سازی واحدهای پردازشی کاملاً متصل (نوروها) سیستم عصبی انسان متمرکز است. شبکه‌های عصبی شامل سه لایه ورودی، پنهان و خروجی هستند و از اتصالات وزنی بین ورودی و خروجی تشکیل شده‌اند (Mfetoum et al., 2024: 3575; Zhou et al., 2024: 1; Chauhan et al., 2024: 849). در این نوع از شبکه‌ها اطلاعات تنها در یک جهت به سمت جلو حرکت می‌نماید و از طریق نوروهای ورودی به نوروهای لایه‌های مخفی و پس از آن به نوروهای لایه خروجی انتقال می‌یابند. در این ساختار تمامی نوروهای یک لایه به تمام نوروهای لایه بعد متصل‌اند. این شبکه به سادگی ساخته می‌شود، نسبت به اکثر شبکه‌ها سریع‌تر آموزش می‌بیند و بسیاری از مسائل را به درستی حل می‌کند. ابتدا برای ورود داده‌ها به شبکه عصبی نیاز است که کلیه داده‌های ورودی به شبکه نرمالیزه شوند، نرمالیزه بدان معنی است که پارامترهای ورودی شبکه بین صفر و یک قرار بگیرند (Sebghati & Abghari, 2022: 1). در این صورت میزان خطا کاهش و سرعت محاسبات شبکه نیز افزایش می‌یابد. به منظور آموزش شبکه‌های عصبی پرسپترون چندلایه با هدف تنظیم پارامترهای شبکه و نزدیکی خروجی شبکه به خروجی واقعی، معمولاً از قانون یادگیری پس انتشار خطا استفاده می‌شود که از دو مرحله تشکیل شده است: در ورودی پیش‌رو، یک بردار ورودی به شبکه ارائه می‌شود و به سمت خروجی انتشار می‌یابد. در مرحله پس انتشار، خروجی شبکه با خروجی مورد نظر مقایسه می‌شود. پس وزن شبکه مطابق با قانون تصحیح خطا تنظیم می‌شود، از این رو به آن «پس انتشار» گفته می‌شود (Ilkhani khosrowshahi et al., 2023: 22). شکل (۲) ساختار شبکه MLP را نشان می‌دهد.




شکل ۲: ساختار شبکه MLP (Kaewtapee et al., 2011: 422)

Figure 2: Structure of the MLP network (Kaewtapee et al., 2011: 422)

شبکه عصبی تابع پایه شعاعی (RBF)

بر خلاف شبکه MLP که دارای توابع تحریک سیگموئید یا تانژانت هیپربولیک می‌باشند، در شبکه‌های RBF تابع MLP تحریک، یک تابع غیرخطی گوسی است (Lin et al., 2003: 542). در این شبکه ارتباط بین نورون‌های لایه‌ی ورودی و پنهان به‌سادگی نمی‌باشد. نورون‌های لایه‌ی مخفی، واحدهای چندبعدی هستند و بعد این نورون‌ها برابر تعداد ورودی‌های شبکه است (Kuo & Cohen, 1999: 359). به‌طور ساده می‌توان گفت، به علت شکل خاص تابع گوسی، هر نورون لایه مخفی هنگامی دارای خروجی بزرگ‌تر است که بردار ورودی شبکه، به مرکز تابع گوسی آن نزدیک‌تر باشد و با افزایش فاصله بردار ورودی از مرکز این تابع غیرخطی، خروجی نورون نیز کاهش می‌یابد. این فاصله را می‌توان با معیار فاصله اقلیدسی تعریف کرد (Ajamzadeh et al., 2017: 211). شکل (۳) ساختار شبکه RBF را نشان می‌دهد.



شکل ۳: ساختار شبکه RBF (Kaewtapee et al., 2011: 422)

Figure 3: Structure of the RBF network (Kaewtapee et al., 2011: 422)

ارزیابی عملکرد شبکه‌های عصبی

برای ارزیابی عملکرد شبکه‌های در نظر گرفته شده از معیارهای ضریب تعیین، واریانس، انحراف معیار، ضریب همبستگی، مجذور میانگین مربعات خطا و میانگین مربعات خطا (روابط ۱ تا ۶) استفاده گردید.

رابطه (۱)

$$R^2 = 1 - \frac{\sum(y_{act} - y_{est})}{\sum y_{act}^2 - \sum n y_{act}^2}$$

رابطه (۲)

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2}$$

رابطه (۳)

$$\mu = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2$$

رابطه (۴)

$$R = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{est})(y_{ast} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n (y_{act} - \bar{y}_{est})^2 \sum (y_{ast} - \bar{y}_{est})^2}}$$

رابطه (۵)

$$RMSE = \sqrt{\frac{\sum_{j=0}^p \sum_{i=0}^n (y_{act_{ij}} - y_{est_{ij}})^2}{NP}}$$

رابطه (۶)

$$MSE = \frac{\sum (\hat{y}_t - y_t)^2}{N}$$

که در آن‌ها، y_{act} : مقادیر واقعی، $\bar{y}_{est}$: میانگین مقادیر واقعی، y_{ast} : مقادیر برآورد شده، $\bar{y}_{est}$: میانگین مقادیر برآورد شده، $y_{act_{ij}}$: مقادیر مشاهده شده برای نمونه i از نورون j ، $y_{est_{ij}}$: مقادیر پیش‌بینی شده برای نمونه i از نورون j ، n : تعداد داده‌ها، P : تعداد متغیرهای خروجی و N : تعداد نمونه‌ها در لایه خروجی می‌باشد (Asadi & Kamran, 2022: 230; 2023: 301).

بحث و یافته‌ها

پس از جمع‌آوری آمار و اطلاعات هواشناسی خراسان جنوبی (ایستگاه‌های بیرجند، قاین، بشرویه، فردوس، نهبندان، خور بیرجند) و کنترل کیفی آن‌ها ابتدا عناصر تأثیرگذار بر رطوبت نسبی مشخص و سپس جهت ورود به شبکه‌های عصبی پرسپترون چندلایه (MLP) و تابع پایه شعاعی (RBF) اقدام به دسته‌بندی و تشکیل ماتریس مربوطه گردید. در ادامه با استفاده از کدنویسی در نرم‌افزار Rstudio و تعریف ۶ سناریو برای پارامترهای مؤثر، شبکه‌های متعددی با ساختارها و

پارامترهای ورودی متفاوت برای برآورد رطوبت نسبی تعریف شد. تعداد نورون‌های لایه پنهان و نرخ آموزش در شبکه‌های MLP و مقادیر گستره و تعداد توابع انتقال در شبکه‌های RBF با استفاده از آزمون و خطا تعیین گردید. پس از بررسی ساختارهای متفاوت برای شبکه‌های MLP و RBF، با توجه به مقادیر توابع عملکرد، در هر سناریو یک ساختار به‌عنوان ساختار بهینه انتخاب گردید. جدول (۱) پارامترهای دخیل در هر سناریو را نمایش می‌دهد.

جدول ۱- پارامترهای دخیل در سناریوهای مورد استفاده
Table 1 - Parameters for the Scenarios Used

سناریو	پارامترهای ورودی به شبکه
۱	میانگین رطوبت نسبی، ارتفاع، میانگین دمای هوا، فشار هوا، ساعات آفتابی، سرعت باد
۲	حداکثر رطوبت نسبی، ارتفاع، حداکثر دمای هوا، فشار هوا، ساعات آفتابی، سرعت باد
۳	حداقل رطوبت نسبی، ارتفاع، حداقل دمای هوا، ساعات آفتابی، سرعت باد
۴	میانگین رطوبت نسبی، ارتفاع، حداکثر دمای هوا، سرعت باد
۵	میانگین رطوبت نسبی، ارتفاع، حداقل دمای هوا، سرعت باد
۶	میانگین رطوبت نسبی، سرعت باد

نتایج حاصل از بررسی بهترین متغیرهای ورودی به مدل شبکه عصبی نشان داد که با انتخاب متغیرهای میانگین رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی، میانگین، حداکثر و حداقل دمای هوای، میانگین سرعت باد، مجموع ساعات آفتابی در زمان‌های قبل (ورودی شبکه) یک مدل پرسپترون (MLP) سه لایه با یک لایه پنهان و تعداد نورون‌های مختلف و تابع محرک تانژانت هیپربولیک (Hyperbolic Tangent) در لایه پنهان و تابع انتقال لایه خروجی Purelin و الگوریتم آموزشی مومنتوم (Momentum)، بهترین خروجی ممکن (میانگین رطوبت نسبی) و همچنین یک تابع پایه شعاعی (RBF) سه لایه با یک لایه پنهان و تعداد نورون‌های مختلف و تابع محرک گوسی نمایی در لایه پنهان و تابع انتقال لایه خروجی تابع همانی و الگوریتم آموزشی مومنتوم (Momentum) را دارا بوده و شبکه‌ها در این حالت، بهترین نتیجه‌ی ممکن را ارائه می‌دهند. در آموزش شبکه‌های MLP ملاحظه شد که افزایش تعداد نورون‌های لایه پنهان، تاثیر معنی‌داری در افزایش عملکرد شبکه ندارد. از این رو برای اجتناب از بزرگ‌تر شدن ساختار شبکه‌ی عصبی، از ۳ یا ۶ نورون در لایه پنهان برای تمام سناریوهای آموزش استفاده شد. در نهایت پس از انتخاب ساختار بهینه‌ی MLP برای هر سناریو و محاسبه‌ی مقادیر توابع عملکرد، این سناریوها با در نظر گرفتن میزان خطای میانگین مربعات (MSE) رتبه‌بندی شده و نتایج کلی آن در جدولی در ادامه ارائه گردید.

بر اساس جدول (۲) که نشان‌دهنده نتایج کلی شبکه MLP در مرحله آموزش و آزمون است. بهترین ساختار شبکه‌های طراحی‌شده روش MLP مربوط به سناریو اول در شبکه‌ای با یک لایه ۳ نورونی پنهان و پایین‌ترین میزان خطا (۰/۰۰۰۱) در مرحله آموزش و یک لایه ۵ نورونی پنهان و پایین‌ترین میزان خطا (۰/۰۰۱۳) در مرحله آزمون است. همچنین بدترین یا به عبارتی بالاترین خطا در ساختار شبکه‌های طراحی‌شده روش MLP مربوط به سناریو ششم در شبکه‌ای با یک لایه ۵ نورونی پنهان و بالاترین میزان خطا (۰/۰۱۱۴) در مرحله آموزش و یک لایه ۴ نورونی پنهان و بالاترین میزان خطا (۰/۰۱۳۱) در مرحله آزمون است (جدول ۲). پس از تکمیل سناریوها و شبکه‌های پیشنهادی، خروجی مدل‌ها تهیه و در خصوص درستی نتیجه پیش‌بینی‌های هر شبکه اطمینان حاصل شد؛ لذا برای انجام این کار از روش‌های واریانس، انحراف معیار، محاسبه رگرسیون خطی و برآورد مقدار مجموع کمترین مربعات استفاده گردید و نتایج آن‌ها در جدول (۲) ارائه شده است.

براین اساس در روش MLP بیشترین میزان همبستگی بین داده‌های مشاهده شده و پیش‌بینی‌شده در مرحله آموزش شبکه‌ها، به ترتیب با واریانس (۰/۰۳۶۴)، انحراف معیار (۰/۰۰۶۹) و RMSE (۰/۲۸۰۳) مربوط به سناریو اول با مقدار ۰/۹۶۷ و کمترین میزان همبستگی به ترتیب با واریانس (۰/۰۵۱۴)، انحراف معیار (۰/۰۰۰۹-) و RMSE (۰/۸۴۵۶) مربوط به سناریو ششم با مقدار ۰/۸۷۲ می‌باشد. همچنین در مرحله آزمون بر اساس روش MLP بیشترین میزان همبستگی بین داده‌های

مشاهده شده و پیش‌بینی شده شبکه‌ها، به ترتیب با واریانس (۰/۰۴۸۷)، انحراف معیار (۰/۰۰۶۷) و RMSE (۰/۲۹۳۵) مربوط به سناریو اول با مقدار ۰/۹۷۳ و کمترین میزان همبستگی به ترتیب با واریانس (۰/۰۸۵۸)، انحراف معیار (۰/۰۳۴۵) و RMSE (۰/۴۱۴۷) مربوط به سناریو چهارم با مقدار ۰/۹۰۴ می‌باشد.

جدول ۲- نتایج کلی شبکه MLP در مرحله آموزش و آزمون

Table 2 - Overall results of the MLP network during training and testing phases.

سناریو	مرحله	تعداد نورون	تعداد تکرار	واریانس	انحراف معیار	R	RMSE	MSE
۱	آموزش	۳	۴۸	۰/۰۳۶۴	۰/۰۰۶۹	۰/۹۶۷	۰/۲۸۰۳	۰/۰۰۰۱
	آزمون	۵	۵۱	۰/۰۴۸۷	۰/۰۰۶۷	۰/۹۷۳	۰/۲۹۳۵	۰/۰۰۱۳
۲	آموزش	۴	۶۳	۰/۰۲۹۶	-۰/۰۰۳۲	۰/۹۶۱	۰/۳۰۲۱	۰/۰۰۲۲
	آزمون	۶	۵۷	۰/۰۳۲۴	-۰/۰۰۱۴	۰/۹۴۸	۰/۲۹۶۷	۰/۰۰۲۷
۳	آموزش	۵	۹۴	۰/۰۲۴۷	۰/۰۰۴۱	۰/۹۵۷	۰/۳۴۸۹	۰/۰۰۶۵
	آزمون	۴	۷۲	۰/۰۲۳۳	-۰/۰۰۰۷	۰/۹۲۸	۰/۳۷۴۳	۰/۰۰۶۸
۴	آموزش	۶	۵۴	۰/۰۷۶۱	۰/۰۲۰۷	۰/۸۹۷	۰/۴۱۶۹	۰/۰۰۵۹
	آزمون	۴	۳۶	۰/۰۸۵۸	۰/۰۳۴۵	۰/۹۰۴	۰/۴۱۴۷	۰/۰۰۶۳
۵	آموزش	۳	۴۵	۰/۰۴۴۱	۰/۰۰۱۲	۰/۹۵۵	۰/۴۹۷۴	۰/۰۰۳۷
	آزمون	۶	۹۹	۰/۰۶۲۳	۰/۰۰۳۶	۰/۹۵۴	۰/۵۱۱۹	۰/۰۰۴۴
۶	آموزش	۵	۸۷	۰/۰۵۱۴	-۰/۰۰۰۹	۰/۸۷۲	۰/۸۴۵۶	۰/۰۱۱۴
	آزمون	۴	۶۹	۰/۰۴۰۲	-۰/۰۰۲۱	۰/۹۱۳	۰/۸۰۲۲	۰/۰۱۳۱

همچنین بر اساس جدول (۳) که نشان‌دهنده نتایج کلی شبکه RBF در مرحله آموزش و آزمون است. بهترین ساختار شبکه‌های طراحی شده مربوط به سناریو اول در شبکه‌ای با یک لایه ۱۴ نورونی پنهان و پایین‌ترین میزان خطا (۰/۰۰۰۷) در مرحله آموزش و یک لایه ۹ نورونی پنهان و پایین‌ترین میزان خطا (۰/۰۰۱۱) در مرحله آزمون است. همچنین بدترین یا به عبارتی بالاترین خطا در ساختار شبکه‌های طراحی شده روش RBF نیز مربوط به سناریو ششم در شبکه‌ای با یک لایه ۱۲ نورونی پنهان و بالاترین میزان خطا (۰/۰۰۴۲) در مرحله آموزش و یک لایه ۱۰ نورونی پنهان و بالاترین میزان خطا (۰/۰۰۳۸) در مرحله آزمون است (جدول ۳).

در روش RBF پس از تکمیل سناریوها و شبکه‌های پیشنهادی، خروجی مدل‌ها تهیه و در خصوص درستی نتیجه پیش‌بینی‌های هر شبکه اطمینان حاصل شد؛ لذا برای انجام این کار از روش‌های واریانس، انحراف معیار، محاسبه رگرسیون خطی و برآورد مقدار مجموع کمترین مربعات استفاده گردید و نتایج آن‌ها در جدول ۳ ارائه شده است.

براین اساس در روش RBF بیشترین میزان همبستگی بین داده‌های مشاهده شده و پیش‌بینی شده در مرحله آموزش شبکه‌ها، به ترتیب با واریانس (۰/۰۵۲۱)، انحراف معیار (-۰/۰۰۹۸) و RMSE (۰/۲۷۴۳) مربوط به سناریو اول با مقدار ۰/۹۷۷ و کمترین میزان همبستگی به ترتیب با واریانس (۰/۰۴۱۲)، انحراف معیار (۰/۰۰۲۴) و RMSE (۰/۳۱۹۸) مربوط به سناریو دوم با مقدار ۰/۹۰۱ می‌باشد. همچنین در مرحله آزمون بر اساس روش RBF بیشترین میزان همبستگی بین داده‌های مشاهده شده و پیش‌بینی شده شبکه‌ها، به ترتیب با واریانس (۰/۰۵۸۳)، انحراف معیار (-۰/۰۰۳۹) و RMSE (۰/۶۱۷۳) مربوط به سناریو اول با مقدار ۰/۹۴۹ و کمترین میزان همبستگی به ترتیب با واریانس (۰/۰۳۵۱)، انحراف معیار (-۰/۰۱۱۱) و RMSE (۰/۴۱۳۶) مربوط به سناریو چهارم با مقدار ۰/۹۱۱ می‌باشد.

جدول ۳- نتایج کلی شبکه RBF در مرحله آموزش و آزمون

Table 3 - Overall results of the RBF network during training and testing phases.

سنار یو	مرحله	تعداد نورون	تعداد تکرار	واریانس	انحراف معیار	R	RMSE	MSE
۱	آموزش	۱۴	۶۷	۰/۰۵۲۱	-۰/۰۰۹۸	۰/۹۷۷	۰/۲۷۴۳	۰/۰۰۰۷
	آزمون	۹	۴۲	۰/۰۳۶۴	-۰/۰۱۰۴	۰/۹۴۸	۰/۲۹۷۸	۰/۰۰۱۱
۲	آموزش	۶	۳۵	۰/۰۴۱۲	۰/۰۰۲۴	۰/۹۰۱	۰/۳۱۹۸	۰/۰۰۳۱
	آزمون	۸	۸۴	۰/۰۳۸۹	۰/۰۰۳۹	۰/۹۱۳	۰/۳۵۴۴	۰/۰۰۳۵
۳	آموزش	۹	۹۳	۰/۰۵۳۶	-۰/۰۱۴۷	۰/۹۴۲	۰/۳۹۰۱	۰/۰۰۱۳
	آزمون	۱۷	۷۷	۰/۰۳۵۱	-۰/۰۱۱۱	۰/۹۱۱	۰/۴۱۳۶	۰/۰۰۱۵
۴	آموزش	۱۱	۵۹	۰/۰۴۱۱	۰/۰۰۲۸	۰/۹۶۳	۰/۴۳۵۸	۰/۰۰۱۷
	آزمون	۱۳	۳۳	۰/۰۴۷۷	۰/۰۰۳۶	۰/۹۳۵	۰/۴۷۲۲	۰/۰۰۱۹
۵	آموزش	۸	۶۸	۰/۰۳۱۲	-۰/۰۰۴۳	۰/۹۲۱	۰/۵۹۶۷	۰/۰۰۲۲
	آزمون	۹	۱۰۱	۰/۰۵۸۳	-۰/۰۰۳۹	۰/۹۴۹	۰/۶۱۱۷	۰/۰۰۲۷
۶	آموزش	۱۲	۳۲	۰/۰۴۳۲	۰/۰۰۷۴	۰/۹۳۶	۰/۶۷۳۳	۰/۰۰۴۲
	آزمون	۱۰	۷۵	۰/۰۵۰۷	۰/۰۰۹۷	۰/۹۲۴	۰/۷۴۴۹	۰/۰۰۳۸

در ادامه برای ارزیابی و مقایسه بهتر شبکه‌های مذکور مقادیر میانگین رطوبت نسبی (برحسب درصد) بین مقادیر اندازه‌گیری شده توسط سازمان هواشناسی با شبکه‌های عصبی MLP و RBF مورد مقایسه قرار گرفت و نتایج آن در جدولی ارائه گردید. جدول (۴) مقادیر محاسبه شده میانگین رطوبت نسبی توسط شبکه‌های MLP و RBF را در برابر مقادیر استاندارد به‌دست‌آمده توسط سازمان هواشناسی برای سال‌های ۲۰۰۰ تا ۲۰۲۳ نمایش می‌دهد. بر این اساس بیشترین مقدار رطوبت نسبی اندازه‌گیری شده و برآورد شده به ترتیب برابر با ۴۰/۹۷ درصد برای سازمان هواشناسی، ۴۱/۵۳ درصد برای روش MLP و ۴۰/۸۸ برای روش RBF بوده که بیشترین مقدار اندازه‌گیری شده در سال ۲۰۲۳ و بیشترین مقدار برآوردی در سال ۲۰۰۰ اتفاق افتاده است. همچنین کمترین مقدار رطوبت نسبی اندازه‌گیری شده و برآورد شده به ترتیب برابر با ۲۸/۲۵ درصد برای سازمان هواشناسی، ۲۹/۲۲ درصد برای روش MLP و ۲۸/۵۷ برای روش RBF بوده که کمترین مقدار اندازه‌گیری شده در سال ۲۰۱۵ و بیشترین مقدار برآوردی برای روش MLP در سال ۲۰۱۱ و برای روش RBF در سال ۲۰۱۵ اتفاق افتاده است.

جدول ۴- مقایسه مقادیر برآوردی میانگین رطوبت نسبی بین مقادیر اندازه‌گیری شده توسط سازمان هواشناسی با شبکه‌های عصبی MLP و RBF

Table 4 - Comparison of estimated average relative humidity values (in percent) between the values measured by the Meteorological Organization with MLP and RBF neural networks.

سال	مقدار اندازه‌گیری شده سازمان هواشناسی	مقادیر برآوردی شبکه MLP	مقادیر برآوردی شبکه RBF
۲۰۰۰	۴۰/۹۱	۴۱/۵۳	۴۰/۸۸
۲۰۰۱	۳۹/۸۷	۳۹/۱۴	۳۹/۴۹
۲۰۰۲	۳۳/۷۵	۳۳/۸۴	۳۴/۰۹
۲۰۰۳	۳۱/۴۱	۳۱/۷۴	۳۲/۲۷
۲۰۰۴	۳۶/۶۱	۳۷/۵۹	۳۷/۷۳
۲۰۰۵	۳۴/۸۳	۳۵/۴۱	۳۵/۸۰
۲۰۰۶	۳۵/۱۲	۳۴/۹۸	۳۵/۱۴


۴۰/۶۶	۴۰/۴۵	۳۹/۹۱	۲۰۰۷
۳۷/۳۴	۳۷/۲۹	۳۸/۲۵	۲۰۰۸
۳۹/۱۳	۳۸/۵۳	۴۰/۰۲	۲۰۰۹
۳۲/۵۷	۳۱/۴۱	۳۲/۲۶	۲۰۱۰
۲۹/۲۷	۲۹/۲۲	۲۹/۶۲	۲۰۱۱
۳۴/۱۷	۳۴/۱۴	۳۴/۸۱	۲۰۱۲
۳۵/۷۶	۳۵/۹۱	۳۶/۰۸	۲۰۱۳
۳۲/۶۴	۳۱/۴۲	۳۲/۶۷	۲۰۱۴
۲۸/۵۷	۲۹/۵۲	۲۸/۲۵	۲۰۱۵
۳۱/۱۸	۳۱/۴۹	۳۱/۱۲	۲۰۱۶
۳۶/۰۵	۳۷/۳۷	۳۶/۵۲	۲۰۱۷
۳۱/۱۱	۳۱/۰۸	۳۰/۱۸	۲۰۱۸
۳۲/۳۶	۳۲/۴۹	۳۲/۷۳	۲۰۱۹
۳۹/۸۰	۳۹/۹۹	۴۰/۵۹	۲۰۲۰
۳۴/۴۴	۳۳/۸۱	۳۴/۳۰	۲۰۲۱
۳۹/۳۶	۳۹/۴۹	۳۹/۱۳	۲۰۲۲
۳۸/۷۳	۳۸/۸۸	۴۰/۹۷	۲۰۲۳

نتایج ارزیابی عملکرد شبکه به روشی که در بالا گفته شد محاسبه و در جدول (۵) آورده شده است. همان طور که ملاحظه می گردد همبستگی بین داده های مشاهده شده و پیش بینی شده در هر دو روش برابر ۰/۹۸۰ درصد است که در سطح خطای یک درصد معنی دار شده است و ضریب تعیین نیز در روش MLP برابر ۰/۹۵۳ و در روش RBF برابر ۰/۹۶۵ در صد می باشد، مقدار RMSE برای روش MLP برابر ۰/۸۴۵ و برای روش RBF برابر ۰/۷۴۰ درصد، MSE برای روش MLP برابر ۰/۷۱۴ و برای روش RBF برابر ۰/۵۴۸ درصد می باشد. این مقادیر هر چه به صفر نزدیک تر باشند، نشان دهنده عملکرد بهتر شبکه است. با توجه به این که دیگر معیارهای ارزیابی شبکه نیز در حد قابل قبول بودند و رطوبت نسبی پیش بینی شده به مقادیر واقعی نزدیک است که شیب خط آن نیز در شکل های (۵۴) ارائه شده، می توان اظهار داشت که هر دو شبکه MLP و RBF دقت نسبتاً مناسبی را در تخمین میانگین رطوبت نسبی سالانه دارا می باشند، ولی خطای شبکه RBF (۰/۵۶۱) کمتر از شبکه MLP (۰/۷۰۷) می باشد. در مجموع با توجه به نتایج حاصل مشخص شد شبکه های RBF که یکی از متداول ترین نوع شبکه های عصبی در مدل سازی سیستم های مختلف می باشند در مدل سازی و برآورد میانگین رطوبت نسبی سالانه از عملکرد بهتری نسبت به شبکه MLP برخوردار است و تنها مزیت شبکه MLP نسبت به شبکه RBF در برآورد رطوبت نسبی سالانه، نوروها و زمان کمتر مورد نیاز برای آموزش و آزمون در این پژوهش می باشد.

جدول ۵- ارزیابی عملکرد شبکه عصبی مصنوعی


Table 5 - Performance Evaluation of the Artificial Neural Network

شیب خط	R	R2	Error	MSE	RMSE	پارامترهای ارزیابی عملکرد شبکه
$y = 0.9271x + 2.4477$	۰/۹۸۰	۰/۹۵۳	۰/۷۰۷	۰/۷۱۴	۰/۸۴۵	مقدار در شبکه عصبی مصنوعی MLP
$y = 0.9147x + 2.9636$	۰/۹۸۰	۰/۹۶۵	۰/۵۶۱	۰/۵۴۸	۰/۷۴۰	مقدار در شبکه عصبی مصنوعی RBF



شکل ۴: نمودار معادله رگرسیونی بین مقادیر میانگین رطوبت نسبی مشاهداتی و برآوردی (MLP)

Figure 4: Diagram of the regression equation for observed and estimated average relative humidity values (MLP).



شکل ۵: نمودار معادله رگرسیونی بین مقادیر میانگین رطوبت نسبی مشاهداتی و برآوردی (RBF)

Figure 5: Diagram of the regression equation for observed and estimated average relative humidity values (RBF).

نتیجه‌گیری

در پژوهش حاضر از شبکه‌های عصبی MLP و RBF برای برآورد رطوبت نسبی سالانه ایستگاه‌های استان خراسان جنوبی استفاده گردید. با در نظر گرفتن مقادیر رطوبت نسبی به‌دست‌آمده از اداره کل هواشناسی استان خراسان جنوبی به‌عنوان مقادیر هدف در آموزش شبکه‌های عصبی، ۶ سناریو با شبکه‌های مختلف ایجاد و عملکرد آن‌ها مورد بررسی قرار گرفت. با بررسی‌های صورت گرفته مشخص شد که می‌توان با استفاده از مدل‌های مذکور مقدار رطوبت نسبی را با دقت قابل قبولی برآورد نمود. بر این اساس بیشترین مقدار رطوبت نسبی اندازه‌گیری شده و برآورد شده به ترتیب برابر با ۴۰/۹۷ درصد برای سازمان هواشناسی، ۴۱/۵۳ درصد برای روش MLP و ۴۰/۸۸ برای روش RBF بوده که بیشترین مقدار اندازه‌گیری شده در سال ۲۰۲۳ و بیشترین مقدار برآوردی در سال ۲۰۰۰ اتفاق افتاده است. همچنین کمترین مقدار رطوبت نسبی اندازه‌گیری

شده و برآورد شده به ترتیب برابر با ۲۸/۲۵ درصد برای سازمان هواشناسی، ۲۹/۲۲ درصد برای روش MLP و ۲۸/۵۷ برای روش RBF بوده که کمترین مقدار اندازه‌گیری شده در سال ۲۰۱۵ و بیشترین مقدار برآوردی برای روش MLP در سال ۲۰۱۱ و برای روش RBF در سال ۲۰۱۵ اتفاق افتاده است. همبستگی بین داده‌های مشاهده‌شده و پیش‌بینی‌شده در هر دو روش برابر ۰/۹۸ درصد است که در سطح خطای یک درصد معنی‌دار شده است و ضریب تعیین نیز در روش MLP برابر ۰/۹۵۳ و در روش RBF برابر ۰/۹۶۵ در صد می‌باشد، مقدار RMSE برای روش MLP برابر ۰/۸۴۵ و برای روش RBF برابر ۰/۷۴۰ درصد، MSE برای روش MLP برابر ۰/۷۱۴ و برای روش RBF برابر ۰/۵۴۸ درصد می‌باشد. این مقادیر هر چه به صفر نزدیک‌تر باشند، نشان‌دهنده عملکرد بهتر شبکه است. نتایج نشان داد که هر دو شبکه MLP و RBF دقت نسبتاً مناسبی را در تخمین میانگین رطوبت نسبی سالانه دارا می‌باشند، ولی خطای شبکه RBF (۰/۵۶۱) کمتر از شبکه MLP (۰/۷۰۷) می‌باشد. نتایج پژوهش حاضر با پژوهش‌های زیر تطابق و همخوانی دارد که در آن Ghadiri et al (2021) با استفاده از روش‌های MLP، RBF، ANN و LSSVM به بررسی رطوبت نسبی هوا پرداخته بودند. نتایج نشان داد که روش RBF با مقدار میانگین خطا (MSE) ۰/۱۳۴ بهترین عملکرد را در برآورد میزان رطوبت نسبی در بین سایر روش‌ها داشته است. (Hanoon et al (2021) با استفاده از روش‌های یادگیری ماشین به پیش‌بینی مقدار دمای هوا و رطوبت نسبی پرداختند. نتایج بیانگر آن بودند که روش MLP در برآورد دمای هوا ($R=0.7132$) و روش RBF در برآورد رطوبت نسبی ($R=0.7113$) بهترین عملکرد را داشته‌اند. (Ghritlahre & Prasad (2018) با استفاده از ورودی‌هایی مانند رطوبت نسبی، دمای هوا و غیره به پیش‌بینی عملکرد گرم‌کننده‌های خورشیدی هوا با استفاده از مدل‌های MLP، GRNN و RBF پرداختند. نتایج نشان داد که مدل RBF بهتر از مدل‌های GRNN و MLP است چون کمترین مقدار RMSE (۰/۰۰۲۸۶) و MAE (۰/۰۰۲۸۶) و بالاترین مقدار R^2 (۰/۹۹۹۹۹) را دارد. درمجموع با توجه به نتایج حاصل مشخص شد شبکه‌های RBF که یکی از متداول‌ترین نوع شبکه‌های عصبی در مدل‌سازی سیستم‌های مختلف می‌باشند در مدل‌سازی و برآورد میانگین رطوبت نسبی سالانه از عملکرد بهتری نسبت به شبکه‌های MLP برخوردار هستند. با آن‌که شبکه‌های RBF و MLP هر دو قادرند مقادیر رطوبت نسبی سالانه را با دقت مناسبی برآورد نمایند، ولی دقت شبکه RBF در برآورد مقادیر رطوبت نسبی سالانه بیش از شبکه MLP می‌باشد.

References

- Ajamzadeh, A., Molaynia, M.R., & Kandahari, Q. (2017). "Comparison of artificial intelligence methods in predicting daily time series of minimum and maximum temperature and precipitation in Tangab Dam station (Fars Province)". *Geographic Space*, 59, 205-228. [In Persian].
- Arora, V. K., & Boer, G. J. (2001). "Effects of simulated climate change on the hydrology of major river basins". *Journal of Geophysical Research: Atmospheres*, 106(D4), 3335-3348. <https://doi.org/10.1029/2000JD900620>
- Asadi, M., & Kamran, K. V. (2022). "Comparison of SEBAL, METRIC, and ALARM algorithms for estimating actual evapotranspiration of wheat crop". *Theoretical and Applied Climatology*, 149(1), 327-337. <https://doi.org/10.1007/s00704-022-04026-3>
- Asadi, M., & Kamran, K. V. (2023). "Estimating selected cultivated crop water requirement-based surface energy balance algorithm". *Arabian Journal of Geosciences*, 16(5), 1-11. <https://doi.org/10.1007/s12517-023-11386-1>
- Asadi, M., & Karami, M. (2022). "Modeling of relative humidity trends in Iran". *Modeling Earth Systems and Environment*, 8, 1035-1045. <https://doi.org/10.1007/s40808-021-01093-9>
- Asakereh, H., Motevali Meydانشah, F., & Ahadi, L. (2024). "Application of Artificial Neural Networks (ANN) to simulate the daily maximum temperature for the coming century - A Case study of Yazd synoptic station". *Scientific- Research Quarterly of Geographical Data (SEPEHR)*, 129(33), 39-58. <https://doi.org/10.22131/sepehr.2023.1989841.2959> [In Persian].
- Bilgili, M., Tumse, S., & Nar, S. (2024). "Comprehensive overview on the present state and evolution of global warming, climate change, greenhouse gasses and renewable energy". *Arabian Journal for Science and Engineering*, 49(11), 14503-14531. <https://doi.org/10.1007/s13369-024-09390-y>
- Chauhan, D., Yadav, A., & Neri, F. (2024). "A multi-agent optimization algorithm and its application to training multilayer perceptron models". *Evolving Systems*, 15(3), 849-879. <https://doi.org/10.1007/s12530-023-09518-9>
- Choi, H., Moon, T., Jung, D. H., & Son, J. E. (2019). "Prediction of air temperature and relative humidity in greenhouse via a multilayer perceptron using environmental factors". *Journal of Bio-Environment Control*, 28(2), 95-103. <https://doi.org/10.12791/KSBEC.2019.28.2.95>
- Elliott, W. P., & Angell, J. K. (1997). "Variations of cloudiness, precipitable water, and relative humidity over the United States: 1973–1993". *Geophysical research letters*, 24(1), 41-44. <https://doi.org/10.1029/96GL03616>
- Feidas, H., Nouloupoulou, C., Makrogiannis, T., & Bora-Senta, E. (2007). "Trend analysis of precipitation time series in Greece and their relationship with circulation using surface and satellite data: 1955–2001". *Theoretical and Applied Climatology*, 87, 155-177. <https://doi.org/10.1007/s00704-006-0200-5>
- Ghadiri, M., Marjani, A., Mohammadinia, S., & Shirazian, S. (2021). "An insight into the estimation of relative humidity of air using artificial intelligence schemes". *Environment, Development and Sustainability*, 23, 10194-10222. <https://doi.org/10.1007/s10668-020-01053-w>
- Ghritlahre, H. K., & Prasad, R. K. (2018). "Exergetic performance prediction of solar air heater using MLP, GRNN and RBF models of artificial neural network technique". *Journal of Environmental Management*, 223, 566-575. <https://doi.org/10.1016/j.jenvman.2018.06.033>
- Gleick, P. H. (1989). Climate change, hydrology, and water resources. *Reviews of Geophysics*, 27(3), 329-344. <https://doi.org/10.1029/RG027i003p00329>

- Gurlek, C. (2023). "Artificial neural networks approach for forecasting of monthly relative humidity in Sivas, Turkey". *Journal of Mechanical Science and Technology*, 37(8), 4391-4400. <https://doi.org/10.1007/s12206-023-0753-6>
- Hanoon, M. S., Ahmed, A. N., Zaini, N. A., Razzaq, A., Kumar, P., Sherif, M., Sefelnasr, A., & El-Shafie, A. (2021). "Developing machine learning algorithms for meteorological temperature and humidity forecasting at Terengganu state in Malaysia". *Scientific Reports*, 11(1), 1-19. <https://doi.org/10.1038/s41598-021-96872-w>
- Hasanvand, M., Borna, R., Zohoorian Pordel, M., & Shakiba, A. (2022). "Study and Evaluation of Temperature in Aleshtar City based on Artificial Neural Network Model". *Journal of Geography and Environmental Studies*, 41 (11), 155-170. <https://dorl.net/dor/20.1001.1.20087845.1401.11.41.11.8> [In Persian].
- Hulme, M., Barrow, E. M., Arnell, N. W., Harrison, P. A., Johns, T. C., & Downing, T. E. (1999). "Relative impacts of human-induced climate change and natural climate variability". *Nature*, 6721 (397), 688-691. <https://doi.org/10.1038/17789>
- Ilkhani khosrowshahi, M., Karimi, M., & Kaffash Charandabi, N. (2023). "Spatial-temporal prediction of high-risk areas of Covid-19 disease using geographically weighted regression and multi-layer perceptron neural network". *Journal of Geomatics Science and Technology*, 12 (3), 17-38. <http://dx.doi.org/10.52547/jgst.12.3.17> [In Persian].
- Iranshahi, M., Ebrahimi, B., Yousefi, H., & Moridi, A. (2023). "Investigating the effects of climate change on temperature and precipitation using neural network and CMIP6 (Case Study: Aleshtar and Khorramabad Stations)". *Water and Irrigation Management*, 12(4), 821-845. <https://doi.org/10.22059/jwim.2022.346796.1009> [In Persian].
- Jaagus, J. (2006). "Climatic changes in Estonia during the second half of the 20th century in relationship with changes in large-scale atmospheric circulation". *Theoretical and Applied Climatology*, 83, 77-88. <https://doi.org/10.1007/s00704-005-0161-0>
- Kaewtapee, C., Khetchaturat, C., & Bunchasak, C. (2011). "Comparison of growth models between artificial neural networks and nonlinear regression analysis in Cherry Valley ducks". *Journal of Applied Poultry Research*, 20(4), 421-428. <https://doi.org/10.3382/japr.2010-00223>
- Kuo, R. J., & Cohen, P. H. (1999). "Multi-sensor integration for on-line tool wear estimation through radial basis function networks and fuzzy neural network". *Neural Networks*, 12(2), 355-370. [https://doi.org/10.1016/S0893-6080\(98\)00137-3](https://doi.org/10.1016/S0893-6080(98)00137-3)
- Lin, J. T., Bhattacharyya, D., & Kecman, V. (2003). "Multiple regression and neural networks analyses in composites machining". *Composites Science and Technology*, 63(3-4), 539-548. [https://doi.org/10.1016/S0266-3538\(02\)00232-4](https://doi.org/10.1016/S0266-3538(02)00232-4)
- Liu, X., Xu, Z., & Yu, R. (2011). "Trend of climate variability in China during the past decades". *Climatic change*, 109(3), 503-516. <https://doi.org/10.1007/s10584-011-0097-6>
- Mfetoum, I. M., Ngoh, S. K., Molu, R. J. J., Nde Kenfack, B. F., Onguene, R., Naoussi, S. R. D., & Berhanu, M. (2024). "A multilayer perceptron neural network approach for optimizing solar irradiance forecasting in Central Africa with meteorological insights". *Scientific Reports*, 14(1), 1-24. <https://doi.org/10.1038/s41598-024-54181-y>
- Nijssen, B., O'Donnell, G. M., Hamlet, A. F., & Lettenmaier, D. P. (2001). "Hydrologic sensitivity of global rivers to climate change". *Climatic change*, 50, 143-175. <https://doi.org/10.1023/A:1010616428763>
- Omidvar, K., & nabavi zadeh, M. (2015). "Daily precipitation forecasting using artificial neural networks in the province of Kerman, A case studies for stations of Kerman, Baft, Miandeh Jiroft". *Journal of Geography and Regional Development*, 12(2), 197-214. <https://doi.org/10.22067/geography.v12i23.26991>. [In Persian].

- Sebghati, M., & Abghari, H. (2022). "Simulation aquifer level Amol-Babol Plain using to by Radial basis function and Support Vector Machine", *Geographic Space*, 78, 1-14. <http://dorl.net/dor/20.1001.1.1735322.1401.22.78.1.0>. [In Persian].
- Shad, M., Sharma, Y. D., & Singh, A. (2022). "Forecasting of monthly relative humidity in Delhi, India, using SARIMA and ANN models". *Modeling Earth Systems and Environment*, 8(4), 4843-4851. <https://doi.org/10.1007/s40808-022-01385-8>
- Tabari, H., & Aghajanloo, M. B. (2012). "Temporal pattern of aridity index in Iran with considering precipitation and evapotranspiration trends". *International journal of climatology*, 33(2), 396-409. <https://doi.org/10.1002/joc.3432>
- Wang, Z., Bugliaro, L., Gierens, K., Hegglin, M. I., Rohs, S., Petzold, A., & Voigt, C. (2024). "Machine learning for improvement of upper tropospheric relative humidity in ERA5 weather model data". *EGUsphere*, 2024, 1-28. <https://doi.org/10.5194/egusphere-2024-2012>
- Zhang, Q., Xu, C. Y., Zhang, Z., & Chen, Y. D. (2009). "Changes of temperature extremes for 1960–2004 in Far-West China". *Stochastic Environmental Research and Risk Assessment*, 23, 721-735. <https://doi.org/10.1007/s00477-008-0252-4>
- Zhou, S., Liu, X., Sun, Y., Chang, X., Jia, Y., Guo, J., & Sun, H. (2024). "Predicting bathymetry using multisource differential marine geodetic data with multilayer perceptron neural network". *International Journal of Digital Earth*, 17(1), 1-16. <https://doi.org/10.1080/17538947.2024.2393255>

Comparison of MLP and RBF Neural Networks in Estimating the Average Relative Humidity Case Study: South Khorasan

Mehdi Asadi

Corresponding author, Department of Geography Education, Farhangian University, Tehran, Iran, **E-mail:** Asadi.m@cfu.ac.ir

Abstract

Relative humidity is one of the environmental factors affecting the growth and spread of plant diseases and is of particular importance due to its direct relationship with rainfall. Therefore, this research aim is to estimate the average relative humidity in South Khorasan province as a dry region using MLP and RBF neural networks. The study utilized RStudio software to analyze the following variables over 23 years (2000-2023): average relative humidity, maximum relative humidity, minimum relative humidity, average air temperature, maximum air temperature, minimum air temperature, average wind speed, and total hours of sunshine, each in six different scenarios. The results showed that the correlation value (R) between the observed and predicted data in both methods is equal to 0.98; the value R^2 in the MLP method is equal to 0.953, and in the RBF, method is equal to 0.965. The RMSE for the MLP method is equal to 0.845, and the RBF method is equal to 0.740. The MSE for the MLP method is equal to 0.714, and for the RBF method, it is equal to 0.548. In total, the MLP and RBF networks have relatively good accuracy in estimating the average annual relative humidity. Still, the error of the RBF network (0.561) is less than that of the MLP network (0.707) and performs better than the MLP in estimating relative humidity.

Keywords: Neural Network, MLP, RBF, Relative humidity, South Khorasan

Introduction

Recently, many scientists and researchers have attempted to prove that fluctuations and changes in the climate have occurred by examining some climate parameters. Accordingly, one of the challenges of the 21st century is the issue of fluctuations and climate change. The main reasons for these fluctuations are the increase in incoming energy from the sun and global warming due to the intensification of greenhouse effects. These changes, in turn, cause hydrological anomalies, such as droughts and floods, and affect the environment and human life. Among the meteorological variables, compared to temperature and precipitation, little research has been done in the field of investigating the temporal changes of relative humidity, while it has a direct effect on the amount of visibility, cloud formation, fog, and smog. In addition, relative humidity is an environmental factor affecting plant growth and the spread of plant diseases, and it is of particular importance due to its direct relationship with rainfall.

Study area

South Khorasan province, with an area of 82,864 square kilometers, is in the east of Iran and is located between the geographical coordinates of 57 degrees and 46 minutes to 60 degrees and 57 minutes of east longitude and 30 degrees and 35 minutes to 34 degrees and 14 minutes of north latitude. The mentioned province shares borders with Afghanistan to the east, Yazd, Isfahan, and Semnan provinces to the west, Khorasan Razavi province to the north, and Sistan-Baluchistan and Kerman provinces to the south. Due to its low latitude and closeness to the orbit of the Tropic of Cancer, and due to the atmosphere's general circulation during the

warm period, it is located under the influence of a tropical high-pressure center and has a winter rainfall regime. The average rainfall of the region is about 180 mm per year, and the annual average relative humidity is 36%.

Materials and Methods

This research utilized meteorological statistics (average, maximum, and minimum relative humidity; average, maximum, and minimum air temperature; average wind speed; total sunny hours) from synoptic stations in South Khorasan province (Birjand, Qain, Beshroieh, Ferdous, Nehbandan, Khor Birjand) as annual averages over 23 years from 2000 to 2023. This research utilized MLP and RBF neural networks, leveraging RStudio's Neuralnet and Kernlab libraries to model the annual average relative humidity in South Khorasan province. The model divides the data into three parts: training, validation, and test sets, using six stations from 2000 to 2023: Birjand, Qain, Beshroieh, Ferdous, Nehbandan, and Khor Birjand. From 138 data points, 104 (75%) annual data points were collected for network training, 21 (15%) data points yearly for validation, and 13 (10%) yearly data points were used as test data.

Results and discussion

Therefore, in the MLP method, the highest degree of correlation between the observed and predicted data in the network training stage is associated with variance (0.0364), standard deviation (0.0069), and RMSE (0.2803) related to the first scenario with a value of 967.0, and the lowest correlation with variance (0.0514), standard deviation (-0.0009), and RMSE (0.8456) corresponding to the sixth scenario with a value of 0.872. Also, the best structure of the designed networks is related to the first scenario in a network with a layer of 14 hidden neurons and the lowest error rate (0.0007) in the training phase, and a layer of 9 hidden neurons and the lowest error rate (0.0011) in the test phase.

Conclusion

In this study, RBF and MLP neural networks predict the annual relative humidity of stations in South Khorasan province, including Birjand, Qain, Beshroieh, Ferdous, Nehbandan, and Khor Birjand. Considering the relative humidity values obtained from the Meteorological Department of South Khorasan Province as the target values in the training of neural networks, the performance of six scenarios involving different networks was investigated. The investigations determined that the models mentioned can reliably estimate relative humidity. Based on this, the highest measured and estimated relative humidity is 40.97% for the Meteorological Organization, 41.53% for the MLP method, and 40.88% for the RBF method, which is the highest value measured in 2023, and the highest estimated value occurred in 2000. The lowest measured and estimated relative humidity values are as follows: 28.25% for the Meteorological Organization, 29.22% for the MLP method, and 28.57% for the RBF method. These values represent the lowest measured value in 2015 and the highest estimated values for the MLP method in 2011 and for the RBF method in 2015.