

۱ مقدمه

تأثیر رویدادهای حدی جوئی و اقیانوسی در وارد آوردن خسارت به اموال و زندگی بشر، موضوعی شناخته شده است. کسب آگاهی و شناخت این گونه پدیده‌ها و تلاش برای پیش‌بینی آنها، همواره از مهم‌ترین وظایف مراکز هواشناسی در سراسر جهان بوده است. در فهرست مخرب‌ترین رویدادهای جوئی به‌وقوع پیوسته در سالیان گذشته در مناطق مختلف جهان، نام جست‌باد (wind gust) به دفعات به چشم می‌خورد. جست‌باد، افزایش ناگهانی و کوتاه‌مدت تندی باد است. بنا بر تعریف، جست‌باد زمانی گزارش می‌شود که بیشینه تندی باد به بیش از ۸ متر بر ثانیه برسد و اختلاف بیشینه تندی باد با باد میانگین، دست‌کم ۵ متر بر ثانیه باشد. مدت زمان این پدیده معمولاً کمتر از ۲۰ ثانیه است (انجمن هواشناسی آمریکا، ۲۰۱۸).

با وجود پیشرفت‌های فناوری، جست‌باد هنوز تهدیدی جدی برای زندگی انسان و برخی صنایع از جمله صنعت هوانوردی محسوب می‌شود. در هوانوردی این تهدید تنها مربوط به زمان نشست و برخاست هواپیما نمی‌شود بلکه در زمان پرواز نیز بسیار حائز اهمیت است (چان، ۲۰۱۲). در کشتیرانی، این تهدید اغلب مربوط به منطقه بندرگاه می‌شود. بادهای ناگهانی شدید ممکن است باعث کاهش بازده یا حتی توقف فعالیت بندرگاه شوند (سولاری و همکاران، ۲۰۱۲). در حوزه بهره‌برداری از انرژی باد، اطلاعات باد از چندین جهت حائز اهمیت است. در مرحله برنامه‌ریزی، طراحان توربین‌های بادی نیاز دارند از ماهیت بادها و شرایط تلاطم‌های جوئی منطقه آگاهی داشته و همچنین چشم‌اندازی از دوره‌های زمانی جست‌باد شدید داشته باشند تا از عملکرد و استحکام ساختار توربین مطمئن شوند (برتون و همکاران، ۲۰۱۱). برای برنامه‌ریزی ساخت سازه‌های عظیم یا مرتفع، تخمین دوره‌های زمانی وقوع بیشینه تندی جست‌باد در مقیاس دهه‌ها یا حتی قرن‌ها

مورد نیاز است. در حوزه تهدیدات و تلفات انسانی، می‌توان به جشنواره موسیقی در بلژیک در تابستان سال ۲۰۱۱ اشاره کرد که جست‌باد با تندی بین ۲۹ تا ۳۷ متر بر ثانیه، باعث مرگ ۵ نفر و مجروح شدن بیش از ۱۴۰ نفر شد (دی میوتر و همکاران، ۲۰۱۵). نمونه دیگری از این پدیده در تاریخ ۹ ژوئن ۲۰۱۴ در غرب اروپا به‌وقوع پیوست که بیشینه سرعت جست‌باد تا ۴۰ متر بر ثانیه اندازه‌گیری شد و طی آن ۶ نفر فوت کردند و حدود ۶۵۰ میلیون یورو خسارت وارد شد (موهر و همکاران، ۲۰۱۷). گزارش‌های ثبت‌شده جست‌باد معمولاً پراکنده و محدود هستند، اما تهدیدها و خسارات ناشی از آن، شناخت و پیش‌بینی این پدیده را بسیار حائز اهمیت کرده است. مطالعات زیادی در سراسر جهان در خصوص پیش‌بینی پارامترهای جوئی با استفاده از مدل‌های پیش‌بینی عددی جوئی صورت گرفته است. همچنین برای پس‌پردازش آماری نیز روش‌های گوناگونی ارائه و استفاده شده است که از آن میان می‌توان به روش‌های فیلتر کالمن (Kalman filter)، میانگین لغزان (moving average)، شبکه عصبی مصنوعی (artificial neural network) و روش رگرسیون (regression) اشاره کرد. هدف از این مطالعه ارزیابی دو روش پیش‌بینی تندی جست‌باد در ایران و پس‌پردازش نتایج با بهره‌گیری از شبکه عصبی مصنوعی است. از آنجا که پارامتر تندی جست‌باد، خروجی مستقیم اغلب مدل‌های منطقه‌ای از جمله مدل WRF (Weather Research and Forecasting Model) نیست، نیاز است تا پیش‌بینی این پدیده با استفاده از روش‌های فیزیکی، تجربی یا آماری صورت پذیرد. در این مقاله، دو روش تجربی پیش‌بینی تندی جست‌باد غیرهمرفتی مطالعه و پارامترهای مورد نیاز جهت جاگذاری در این روش‌ها، از خروجی مدل WRF استخراج و در نهایت، نتایج در چندین تاریخ انتخابی ارزیابی شد. در ادامه، مقادیر پیش-

متری، فشار سطح دریا، رطوبت نسبی، سمت و تندی باد بود. نتایج دمای دو متری سطح زمین که با مدل WRF پیش‌بینی شده بود، با نتایج شبکه عصبی مصنوعی پس‌پردازش شده مقایسه شد. بررسی‌های آماری نشان داد خطای مدل با توجه به فصل و نیز موقعیت جغرافیایی هر ایستگاه متفاوت است. برای بیشتر ایستگاه‌ها پیش‌بینی مدل با مقداری خطا همراه بود ولی پس از اعمال شبکه عصبی مصنوعی، این مقدار کاهش یافت.

عرب عامری و همکاران (۱۳۹۳) از سری زمانی داده‌های متار (METAR) ایستگاه مهرآباد در بازه زمانی ۲۰۰۵ تا ۲۰۱۳ استفاده و روش‌های مختلف انتخاب ویژگی مانند معیار اطلاعات متقابل، روش‌های انتخاب پیشرو، پسرو و گام به گام را اعمال کردند و در نهایت، به این نتیجه رسیدند که انتخاب ویژگی پسرو بهترین روش است و اگر ورودی شبکه عصبی پرسپترون چندلایه شامل تندی باد، دما، دمای نقطه شبنم، فشار و بایاس باشد، شبکه می‌تواند تندی باد را برای یک ساعت آینده پیش‌بینی کند.

حیبی (۱۳۹۷) کارایی شبکه‌های عصبی را در پیش‌بینی جست‌باد بررسی کرد و داده‌های مربوط به ۲۷ کمیت اندازه‌گیری شده در ایستگاه مهرآباد را در بازه زمانی مارس تا اوت ۲۰۱۳ به صورت تصادفی با نسبت‌های ۷۰، ۱۵ و ۱۵ درصد به ترتیب برای آموزش، آزمون و اعتبارسنجی شبکه در نظر گرفت. بیست و پنج کمیت ورودی به شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی، تابع سیگموئید و هشت نرون در لایه پنهان و تابع خطی در لایه خروجی داده شد. خروجی شبکه سمت و تندی جست‌باد بود. طبق آن مطالعه، نزدیک به ۱۰۰ درصد مقدار تندی جست‌باد تحت تأثیر متغیرهای مستقل و نزدیک به ۸۵ درصد مقدار جهت باد تحت تأثیر این متغیرهای مستقل هستند و مابقی تغییرات آن به سایر عوامل وابسته است.

بینی حاصل از هر دو روش، با استفاده از شبکه عصبی مصنوعی پس‌پردازش و خروجی شبکه ارزیابی شد.

مطالعات مشابه دیگری در ایران و سایر نقاط جهان در خصوص ارزیابی پیش‌بینی پارامترهای جوی و روش‌های مختلف پس‌پردازش آنها صورت گرفته است که به چندین نمونه از آنها اشاره می‌شود.

سلکوک نوگی و همکاران (۲۰۱۲) در مطالعه‌ای به پیش‌بینی کوتاه‌مدت تندی باد با استفاده از شبکه عصبی مصنوعی در شهر ماردین ترکیه پرداختند. آنها از داده‌های ده سال اداره هواشناسی کشور استفاده کردند و پس از بررسی مدل‌های مختلف شبکه عصبی مصنوعی به این نتیجه رسیدند که مدل با ۶۰ نرون دقیق‌ترین روش برای پیش‌بینی کوتاه‌مدت تندی باد است. مربع میانگین خطا و ضریب همبستگی برای آموزش مدل به ترتیب برابر ۰/۳۷ و ۰/۹۷ به دست آمد و مدل نتایجی پذیرفتنی تولید کرد.

کورباتوا و همکاران (۲۰۱۸)، هفت روش مختلف را برای پیش‌بینی تندی جست‌باد در کشور روسیه بررسی کردند. پارامترهای موجود در این روش‌ها از برون‌داد مدل WRF استخراج شدند. نتایج با اندازه‌گیری‌های بادنسج صوتی در همان نقطه در شهر مسکو مقایسه شد. داده‌های جمع‌آوری شده از شبکه ایستگاهی سینوپتیک در بخش اروپایی روسیه نیز برای افزایش آمار در تجزیه و تحلیل گنجانده شد. در روش پیشنهادی هیبریدی (hybrid) توازن خوبی بین احتمال تشخیص (POD) و برآورد نسبت هشدار نادرست (FAR) برقرار بود، اما در مجموع هیچ‌یک از روش‌های برآورد جست‌باد، نتیجه ایدئالی را در همه پارامترهای ارزیابی نشان نداد. نیاز علیزاده و همکاران (۱۳۸۸) پس‌پردازش برون‌داد مدل میان‌مقیاس WRF را برای دمای دو متری سطح زمین با استفاده از شبکه عصبی مصنوعی بررسی کردند. آنها از شبکه عصبی مصنوعی پیشرو با توانایی بازگشت به عقب استفاده کردند. ورودی شبکه شامل پنج کمیت دمای سطح دو

۲ داده‌ها و روش پژوهش

۱-۲ داده‌ها، منطقه و بازه زمانی مورد مطالعه

این مطالعه به بررسی داده‌های جست‌باد در ارتفاع استاندارد ۱۰ متر از سطح زمین می‌پردازد که از مجموع گزارش‌های متار و گزارش‌های ویژه (SPECI) ۳۲ ایستگاه همدیدی کشور ایران بین سال‌های ۲۰۱۳ تا ۲۰۱۸ میلادی استخراج شده است. معمولاً اطلاعات باد میانگین و جست‌باد مربوط به ۱۰ دقیقه قبل از زمان ارائه گزارش‌های متار، برابر شیوه‌نامه ثبت و گزارش می‌شود. البته اگر بین ساعات دیده‌بانی نیز تغییر شدید و کوتاه‌مدت

در تندی باد میانگین ایجاد شود، جداگانه و در قالب گزارش‌های ویژه ثبت خواهد شد. داده‌ها از بانک داده سازمان هواشناسی ایران دریافت شدند. جهت افزایش اطمینان از صحت داده‌های در دسترس، سعی شد تا حد امکان از اطلاعات ایستگاه‌های فرودگاهی استفاده شود که دقت بیشتری دارند و اغلب از نوع ایستگاه‌های خودکار هستند. همچنین سعی شد انتخاب ایستگاه‌ها به گونه‌ای باشد که کل منطقه ایران را پوشش دهد. شکل ۱، موقعیت ایستگاه‌ها را نشان می‌دهد.



شکل ۱. پراکنندگی ایستگاه‌های همدیدی مورد استفاده در مطالعه.

۲-۲ روش‌های پیش‌بینی تندی جست‌باد

تفکیک جست‌بادهای غیرهمرفتی از همرفتی موضوعی اساسی است و آگاهی از تفاوت آنها در نوع شکل‌گیری، می‌تواند به شناخت بیشتر این پدیده جوی منجر شود. از آنجاکه ماهیت شکل‌گیری جست‌بادهای همرفتی کاملاً متفاوت از جست‌بادهای غیرهمرفتی است، تفکیک نکردن آنها در این مرحله ممکن است بر آمارهای استخراج‌شده و تحلیل‌های بعدی تأثیر بگذارد. جست‌بادها می‌توانند به سه دلیل اصلی ایجاد شوند (کُلِنْدُوِیچ و همکاران، ۲۰۱۶). دلیل اول، گردش‌های جوی چرخندی و گردایان افقی فشار همراه با این گردش‌ها است. دلیل دوم، وجود ابرهای توفان‌زا مانند ابرهای کومه‌ای باران (cumulonimbus) است که شرایط ایجاد جریان‌های شدید پایین‌سو (downburst)

را در زیر خود به وجود می‌آورند. برخورد این جریانات با سطح زمین سبب می‌شود سطح، هوای شامل این جریانات نزولی را منحرف کند و باعث افزایش لحظه‌ای تندی باد افقی و ایجاد جست‌باد شود (جست‌بادهای همرفتی). دلیل سوم، ایجاد تلاطم ناشی از اصطکاک، چینش باد یا گرمای سطح زمین است که این سه سازوکار می‌توانند باد را به تغییر تندی و همچنین تغییر جهت وادار کنند (جست‌بادهای غیرهمرفتی). روش‌های مختلفی برای تفکیک جست‌بادهای همرفتی از غیرهمرفتی ارائه شده است که از جمله آنها می‌توان به تفکیک بر اساس تصاویر راداری/ماهواره‌ای در زمان وقوع جست‌باد یا جدا کردن آنها با استفاده از جستجوی توفان‌های همراه با رعد و برق (توفان‌های تندی) در زمان ثبت گزارش‌های جوی اشاره

(RUC20، ۲۰۰۷؛ شریدن، ۲۰۱۱ و استوکی و همکاران، ۲۰۱۶):

$$Ug_{10} = U_{10} + (U_{PBL} - U_{10}) \times \left(1 - \frac{h_{PBL}}{2000}\right) \quad (1)$$

که در این رابطه، U_{10} تندی باد در ارتفاع ۱۰ متری و U_{PBL} تندی باد در تارک لایه مرزی (h_{PBL}) است. رابطه (۱)، رابطه‌ای تجربی است که در آن بیشینه ارتفاع لایه مرزی عمیق ($h_{PBL} > 1000m$) ۱۰۰۰ متر فرض شده است؛ بنابراین مقدار $\frac{h_{PBL}}{2000}$ در رابطه پیش‌گفته همواره کمتر از ۰/۵ خواهد بود.

روش دیگر، رابطه (۲) است که در پروژه NIMROD و همچنین سامانه پس‌پردازش اداره هواشناسی انگلستان (Met Office) از آن استفاده می‌شود و از این پس با عنوان (Met Office Algorithm of wind gust prediction) از آن یاد می‌شود و بیانگر روش ساده جستجوی به سمت بالا، شامل اولین لایه پایدار و سقف لایه مرزی (که اغلب مشابه هم هستند) یا برخی ترازهای مشخص برای اندازه‌گیری ارتفاعاتی است که تکانه ممکن است از آنجا به سطح منتقل شود. این روش بر پایه این استدلال است که زیر این ارتفاعات، در اصل هیچ مانعی برای آمیختگی رو به پایین تکانه وجود ندارد (برای مثال: شریدن، ۲۰۱۱):

$$Ug_{10} = (0.89 - 0.002U_{max}) \times U_{max} \quad (2)$$

Ug_{10} تندی جست‌باد و U_{max} بیشینه تندی باد افقی از سطح زمین تا ارتفاع ۱ کیلومتری از سطح زمین است.


۲-۳ مدل WRF

در این پژوهش از مدل WRF نسخه ۳/۹ برای شبیه‌سازی و برآورد مقادیر پارامترهای مورد نیاز در روابط (۱) و (۲) استفاده شد. تعداد آشیانه‌های انتخابی، دو آشیانه و نسبت تفکیک افقی آشیانه‌ها ۱ به ۳ در نظر گرفته شد؛ بنابراین مدل با تفکیک افقی ۲۷ کیلومتر برای آشیانه اول و ۹ کیلومتر برای آشیانه دوم تنظیم شد. شکل ۲ آشیانه‌ها را

کرد. در این مطالعه از نتایج تحقیقات چوی و هدایت (۲۰۰۲) و کوک و همکاران (۲۰۰۳) استفاده شد. آنها آن دسته از گزارش‌های جست‌باد را که همراه با توفان تندی بودند، جست‌بادهای همرفتی و سایر گزارش‌ها را جست‌بادهای غیرهمرفتی فرض کردند. بر اساس نتایج مطالعه محمدی و همکاران (۱۳۹۹)، تعداد گزارش‌های جست‌باد غیرهمرفتی نسبت به نوع همرفتی در کشور ایران به مراتب بیشتر است؛ لذا برای توجه به اهمیت وقوع پدیده‌های حدی و شدید جوی تأثیرگذار و پرتکرار در کشور ایران، این مطالعه تنها بر جست‌بادهای نوع غیرهمرفتی متمرکز شد.

مدل‌های پیش‌بینی جست‌باد غیرهمرفتی بر پایه تخمین یا محاسبه تلاطم در لایه مرزی و انتقال قائم تکانه استوار هستند. تأثیر این محاسبات در مدل‌های مختلف، با روش‌های مختلف تشریح می‌شود. این روش‌ها می‌توانند حاصل روابط فیزیکی مانند رابطه تخمین جست‌باد (WGE) (برسر، ۲۰۰۱) یا روابط تجربی مانند الگوریتم استفاده‌شده در پروژه NIMROD یا رابطه استفاده‌شده در سامانه پس‌پردازش یکپارچه مدل WRF (UPP) باشند.

در این مطالعه به منظور پیش‌بینی تندی جست‌باد، از میان روش‌های پیش‌بینی تندی جست‌باد غیرهمرفتی مورد استفاده در مدل‌های پیش‌بینی عددی جو که مراکز هواشناسی در کشورهای مختلف استفاده می‌کنند، دو روش انتخاب شد. یکی از آنها رابطه (۱) است که در سامانه پس‌پردازش یکپارچه مدل WRF (UPP) استفاده می‌شود و از این پس با WRF post-process (diagnostic of wind gusts) از آن نام برده می‌شود. این رابطه با برآورد بیشترین تکانه بالقوه که می‌تواند از بالای لایه مرزی تا سطح منتقل شود، تندی جست‌باد را پیش‌بینی می‌کند. کدنویسی اولیه (NCO، ۱۹۹۷) و مستندات پراکنده موجود حاکی از اقتباس رابطه (۱) از الگوریتم مورد استفاده در فرایند پس‌پردازش مدل RUC20 است



شکل ۲. دو آشیانه مفروض جهت اجرای مدل WRF.

جدول ۱. طرح‌واره‌های فیزیکی استفاده شده جهت اجرای مدل WRF.

عنوان طرح‌واره	طرح‌واره استفاده شده
mp_physics (خرد فیزیک)	Lin
ra_lw_physics (تابش موج بلند)	RRTM
ra_sw_physics (تابش موج کوتاه)	Goddard
sf_sfclay_physics (لایه سطحی)	Revised MM5
sf_surface_physics (سطح زمین)	Noah
bl_pbl_physics (لایه مرزی سیاره‌ای)	YSU
cu_physics (همرفت)	Kain-Fritsch

نتایجی پذیرفتنی دارد (قادر و همکاران، ۱۳۹۸).

۲-۴ مدل شبکه عصبی مصنوعی

سامانه‌های آماری، بر اساس آموزش مدل‌هایی با نمونه داده‌های واقعی مشخص در یک منطقه اجرا می‌شوند. تفاوت بین خروجی پیش‌بینی شده و خروجی واقعی (خطا)، با تنظیم دقیق آن به سطحی که بتواند برای حال حاضر یا پیش‌بینی آینده استفاده شود، کمینه می‌شود. یکی از جدیدترین رویکردهای آماری، شبکه عصبی مصنوعی است که در این مطالعه برای پس‌پردازش و بهبود دقت نتایج پیش‌بینی تندی جست‌باد حاصل از روابط اشاره شده در بخش (۲-۲) از آن استفاده شده است.

شبکه عصبی مصنوعی (Artificial Neural Network) که به اختصار ANN نامیده می‌شود، در واقع یک ابزار ریاضی قدرتمند است که با تقلید ساده از سامانه عصبی

جهت اجرای مدل نشان می‌دهد. آشیانه‌ها تودرتو هستند و با اندیس‌های ۱ و ۲ مشخص شده‌اند.

در این مدل از نگاهت لامبرت استفاده شد. ورودی مدل، داده‌های GFS با تفکیک ۰/۵ درجه با گام‌های زمانی سه‌ساعته بود. تعداد ترازهای قائم برابر با ۴۹ تراز فرض شد. گام زمانی برای هر اجرای مدل ۹۰ ثانیه و زمان اجرای هر شبیه‌سازی از ساعت UTC ۰۰ و برای یک روز کامل (۲۴ ساعت) در نظر گرفته شد که شش ساعت اول، زمان تطبیق (spin up) و هجده ساعت باقیمانده زمان تحلیل بود. طرح‌واره‌های فیزیکی مورد استفاده برای سنجش فرایندهای فیزیکی، همرفت، لایه مرزی، سطح زمین و تابش در جدول ۱ ارائه شده‌اند. فیزیک مدل انتخابی، مشابه فیزیک یک عضو از اعضای سامانه همادی مدل پیش‌بینی جو و اقیانوس است. این سامانه و هر یک از اعضای آن بیش از دو سال ارزیابی عملیاتی شده است و

(آموزش) برقرار می‌شود. مقایسه خروجی واقعی و خروجی مطلوب باعث می‌شود ضرایب وزنی و اریبی شبکه تغییر یابند تا در دفعات بعد، خروجی درست‌تری حاصل شود (منهاج و سیفی‌پور، ۱۳۷۷). عملکرد این شبکه با معادلات (۵) و (۶) مشخص می‌شود:

$$1 \leq j \leq S_1 \quad a_j^1(t) = F[\sum_{i=1}^R W_{j,i}^1 P_i(t) + b_j^1] \quad (5)$$


$$1 \leq k \leq S_2 \quad a_k^2(t) = G[\sum_{i=1}^{S_1} W_{k,i}^2 a_i^1(t) + b_k^2] \quad (6)$$

که R تعداد سیگنال ورودی، P بردار ورودی، W_1 و W_2 ماتریس‌های وزن در لایه‌های پنهان و خروجی، S_1 و S_2 تعداد نرون‌ها، b_1 و b_2 بردارهای اریبی در لایه‌های مخفی و خروجی، a_1 و a_2 بردارهای خروجی لایه‌های متناظر F و G توابع فعال‌سازی (activation function) در لایه‌های مخفی و خروجی هستند (علیقلی‌نیا و همکاران، ۱۳۹۵). با تقریب جهانی، هر پرسپترون چندلایه با تابع فعال‌سازی سیگموئید (sigmoid) برای لایه مخفی و یک لایه خروجی با تابع فعال‌سازی خطی (linear)، قادر به برآورد هر پارامتر پیچیده‌ای است اگر تعداد نرون‌های لایه مخفی درست انتخاب شود (تکار و مارکوس، ۲۰۰۰).

در این مطالعه از شبکه عصبی مصنوعی پرسپترون چندلایه پیش‌خور (Feed Forward Multilayer Perceptron) استفاده شد. شبکه عصبی پرسپترون چندلایه یکی از متداول‌ترین شبکه‌های مورد استفاده در علوم مختلف از جمله هواشناسی است (حسینی، ۱۳۸۸). حسن این نوع شبکه در تسریع عملیات برآورد پارامترها و نوع یادگیری و آموزش شبکه است. شبکه طراحی شده در این مطالعه ساختار هیبریدی با تابع فعال‌ساز سیگموئید برای لایه مخفی و یک تابع فعال‌سازی خطی در لایه خروجی دارد (سبزی پرور و علیائی، ۱۳۹۰؛ کنانی و همکاران، ۲۰۰۸ و امیرمرادی و بهمنی، ۱۳۹۳). در این مطالعه از سه روش مختلف آموزش در اجرای مدل استفاده شد که شامل الگوریتم لونیبرگ-مارکورات (Levenberg-Marquardt)، الگوریتم بی‌زین (Bayesian

زیست‌شناختی ساخته شده است. ایده اصلی شبکه عصبی بر مبنای شبیه‌سازی عملکرد مغز انسان است و در مقیاس خیلی کوچک، می‌تواند مانند شبکه‌ای زیستی قدرت یادگیری داشته باشد و این یادگیری را تعمیم هم بدهد. شبکه عصبی مصنوعی روشی عملی برای یادگیری توابع گوناگون نظیر توابع با مقادیر حقیقی، توابع با مقادیر گسسته و توابع با مقادیر برداری است.

شکل ۳ ساختار کلی شبکه عصبی را نشان می‌دهد. در این شکل، p و a ورودی و خروجی هستند و 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):



شکل ۳. طرح کلی شبکه عصبی مصنوعی.

$$n = wp + b \quad (3)$$

$$a = f(n) = f(wp + b) \quad (4)$$

در فرایند آموزش شبکه‌های عصبی، پارامترهای w (weight) و b (bias) تا زمان به دست آمدن بهترین تقریب برای عضو خروجی مربوط به ورودی مورد نظر تغییر می‌کنند (منهاج و سیفی‌پور، ۱۳۷۷).

در ساختار پرسپترون چندلایه (Multilayer Perceptron)، علاوه بر لایه‌های ورودی و خروجی، چند لایه بین این لایه‌ها وجود دارد که لایه‌های مخفی (hidden layer) نامیده می‌شوند. لایه میانی یا مخفی که از نرون‌های (neuron) پردازشگر تشکیل شده است، محل پردازش داده‌ها است. نرون‌های لایه‌های مجاور در شبکه به‌طور کامل با هم در ارتباط هستند. این ارتباط با بهره‌گیری از رابطه‌های پیچیده غیرخطی بین لایه‌های ورودی و خروجی و با آموزش و فرایند یادگیری

دما، رطوبت نسبی، فشار سطح دریا و تندی باد حاصل از خروجی مدل WRF و همچنین تندی جست‌باد محاسبه‌شده از روابط (۱) و (۲) در نظر گرفته‌شد. تابع هدف نیز تندی جست‌باد دیده‌بانی‌شده (مشاهداتی) انتخاب شد.

۲-۵ سنج‌های آماری جهت ارزیابی نتایج

راستی‌آزمایی یک پیش‌بینی، فرایندی است که کیفیت آن پیش‌بینی را تعیین می‌کند و می‌توان با کمک آن، نتایج پیش‌بینی را ارزیابی کرد. در این تحقیق از سنج‌های آماری ضریب همبستگی پیرسون (R)، خطای مطلق میانگین (MAE)، میانگین مربع خطا (MSE) و جذر میانگین مربع خطا (RMSE) برای ارزیابی نتایج پیش‌بینی حاصل از روابط مورد مطالعه (روش‌های WPD و MOA) و همچنین ارزیابی عملکرد مدل شبکه عصبی مصنوعی استفاده شد که روابط آنها به شرح ذیل است (جولیف و استنفسون، ۲۰۰۳):

الف) خطای مطلق میانگین (MAE)

مقدار این سنج از رابطه (۷) محاسبه می‌شود:

$$MAE = \frac{1}{N} \sum_{i=1}^N |F_i - O_i| \quad (7)$$

که F_i مقدار پیش‌بینی‌شده متغیر مورد نظر و O_i مقدار دیده‌بانی‌شده متناظر با آن و N تعداد کل داده‌ها است.

ب) میانگین مربع خطا (MSE)

میانگین مربع خطا سنج‌ای از مناسب بودن خط رگرسیون برازش داده شده است. این سنج میزان نزدیک بودن این خط را به داده‌ها تعیین می‌کند. مربع‌سازی خطاها برای حذف علامت منفی فاصله بین مقدار واقعی و مقدار حاصل از رگرسیون لازم است. این عمل، به خطاهای بزرگ‌تر وزن بیشتری می‌دهد. هرچه این سنج به صفر نزدیک‌تر باشد، خطا کمتر است. مقدار این سنج از رابطه (۸) محاسبه می‌شود:

$$MSE = \frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2 \quad (8)$$

Regularization) و الگوریتم شیب توأم مقیاس‌شده (Scaled Conjugate Gradient) بود. روش‌های مختلفی برای تشخیص تعداد بهینه نرون‌های لایه مخفی پیشنهاد شده است. راه تجربی و معمول برای تعیین تعداد نرون‌های لایه مخفی این است که برای یک شبکه عصبی با چندین ورودی، تعداد نرون‌های مخفی، نسبت کوچکی از تعداد ورودی‌ها باشد. اگر شبکه MLP به جواب مطلوب همگرا نشود، تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا شود و از قدرت تعمیم خوبی هم برخوردار باشد، در صورت امکان تعداد نرون‌های مخفی کمتری را آزمایش می‌کنند و در نهایت روی یک اندازه مناسب بر اساس عملکرد کلی سامانه توافق می‌شود (منهاج، ۱۳۸۱).

مهم‌ترین شرط‌ها برای خاتمه الگوریتم شبکه، توقف بعد از دفعات معین تکرار و توقف هنگام کمتر شدن خطا از مقدار تعیین‌شده یا به عبارت دیگر، توقف هنگام کمینه شدن میانگین مربع خطا (MSE) 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 (امیرمادی و بهمنی، ۱۳۹۳). در این پژوهش، تعداد مناسب دفعات تکرار و خطای معیار به ترتیب ۱۰۰۰ و $1E-07$ در نظر گرفته‌شد. همچنین شبکه طوری برنامه‌ریزی شد که اگر مدل در شش تکرار متوالی قادر به بهبود میزان خطا نباشد، متوقف شود. هفتاد درصد داده‌ها برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد باقیمانده برای اعتبارسنجی مدل به صورت تصادفی انتخاب و استفاده شدند.

با توجه به اینکه از کمیت‌های هواشناسی مختلفی برای ورودی شبکه عصبی می‌توان استفاده کرد، ترکیب‌های گوناگونی از ورودی‌ها انتخاب شد تا به بررسی تأثیر بهینه هر گروه از کمیت‌ها پرداخته شود. ورودی جهت آموزش شبکه، ترکیب‌های مختلفی از متغیرهای نرمال‌شده شامل

۳ یافته‌های پژوهش

برای پیش‌بینی تندی جست‌باد در کشور ایران، مدل WRF با شرایط اولیه و فیزیک اشاره شده در بخش (۲-۳) برای ۵۷ تاریخ منتخب (که تعداد گزارش‌های روزانه در آنها نسبت به سایر روزها بیشتر بود) به صورت ۲۴ ساعته اجرا شد. این تاریخ‌ها از سال‌ها و ماه‌های مختلف در طول دوره مورد مطالعه انتخاب شدند تا تأثیر عوامل فصلی و سالیانه در آنها به حداقل برسد. داده‌های دیده‌بانی شده و همچنین داده‌های خروجی مدل پیش‌پردازش شدند و پس از ارزیابی اولیه، تعداد ۱۸۸۰ مورد گزارش جست‌باد طی این ۵۷ روز از ایستگاه‌های مختلف به دست آمد. در ادامه، داده‌های مورد نیاز از فایل‌های خروجی مدل استخراج و همچنین مقادیر تندی افقی باد در ترازهای مختلف جو درونیابی شد تا تندی باد در تارک لایه مرزی جهت استفاده در رابطه (۱) و بیشینه تندی باد از سطح زمین تا ارتفاع ۱ کیلومتری جهت استفاده در رابطه (۲) به دست بیاید. پس از آن، تندی جست‌باد در ارتفاع ۱۰ متری از سطح زمین بر اساس هر دو روش مورد مطالعه (WPD و MOA)، در زمان‌های مورد نظر پیش‌بینی شد. کلیه کدنویسی‌ها با استفاده از نرم‌افزار NCL نسخه ۶/۵ صورت پذیرفت. در نهایت، نتایج با استفاده از داده‌های دیده‌بانی شده ارزیابی شد.

جدول ۲، نتایج راستی‌آزمایی پیش‌بینی تندی جست‌باد را بر اساس دو روش WPD (Vg.WPD) و MOA (Vg.MOA) نشان می‌دهد. حالت بهینه برای سنجه خطای مطلق میانگین (MAE)، سنجه میانگین مربع خطا (MSE) و سنجه جذر میانگین مربع خطا (RMSE)، مقادیر کمتر و نزدیک به صفر است و حالت بهینه برای سنجه ضریب همبستگی پیرسون (R) مقادیری است که بزرگ‌تر هستند و به سمت عدد یک میل می‌کنند. همان‌گونه که از جدول مشخص است، مقدار سنجه MAE برای روش MOA برابر با ۳/۴۳ و برای روش WPD برابر با ۳/۰۷

(ج) جذر میانگین مربع خطا (RMSE)

جذر میانگین مربع خطا، انحراف معیار باقیمانده‌ها (خطاهای پیش‌بینی) است. باقیمانده‌ها سنجه‌ای از فاصله داده‌ها از خط برازش داده شده هستند و جذر میانگین مربع خطا سنجه‌ای از پراکندگی این باقیمانده‌ها است. به عبارت دیگر، این سنجه چگونگی تراکم داده‌ها در اطراف بهترین خط برازش داده شده را تعیین می‌کند. معمولاً از این سنجه در اقلیم‌شناسی، پیش‌بینی و تحلیل رگرسیون برای تأیید نتایج تجربی استفاده می‌شود. مقدار این سنجه از رابطه (۹) محاسبه می‌شود:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2} \quad (9)$$

این سنجه محدوده‌ای از صفر تا $+\infty$ دارد و مقدار مطلوب آن صفر است.

(د) ضریب همبستگی پیرسون (R)

این سنجه بیان‌کننده میزان همبستگی بین نتایج برآورد شده مدل و داده‌های واقعی است. به عبارت دیگر، سنجه‌ای از استحکام رابطه بین دو متغیر است. بدیهی است که هر قدر میزان آن به یک نزدیک‌تر باشد، ارتباطی مستحکم‌تر بین دو متغیر (در اینجا مقادیر برآورد شده و مقادیر واقعی) وجود دارد. ضریب همبستگی ساده‌ترین سنجه برای بررسی ارتباط خطی بین دو متغیر است که با استفاده از رابطه (۱۰) محاسبه می‌شود (استوکی و همکاران، ۲۰۱۶؛ بختیاری و همکاران، ۱۳۹۲ و عزیزی و منتظری، ۱۳۹۴):

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O}) \times (F_i - \bar{F})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \times \sum_{i=1}^N (F_i - \bar{F})^2}} \quad (10)$$

\bar{O} و \bar{F} به ترتیب میانگین مقادیر پیش‌بینی شده و دیده‌بانی شده متغیر مورد نظر هستند. مقدار این ضریب بین -۱ تا ۱ تغییر می‌کند که «۱» به معنای همبستگی مثبت کامل، «۰» به معنی نبود همبستگی، و «-۱» به معنی همبستگی منفی کامل است.

دست‌یابی به نتایج بهتر، از روش نرمال‌سازی کمینه-بیشینه استفاده شد. مزیت روش پیش‌گفته در این است که تمام روابط بین داده‌ها را حفظ می‌کند و نیاز به معرفی سوگیری نیست (حیسی، ۱۳۹۸). این کار باعث می‌شود اثر مقیاس واقعی (absolute scale) کمینه شود و همه ورودی‌ها تقریباً در یک دامنه باشند. نرمال‌سازی داده‌ها در این روش از رابطه زیر محاسبه می‌شود (هان و همکاران، ۲۰۱۲):

$$x_{i,a \text{ to } b} = a + \frac{(x_i - x_{\min})(b - a)}{(x_{\max} - x_{\min})} \quad (۶)$$

که x_i ، x_{\min} و x_{\max} به ترتیب داده‌های ورودی واقعی، کمینه و بیشینه است. a و b مقادیر کمینه و بیشینه هدف هستند که در اینجا به ترتیب ۰ و ۱ انتخاب شدند. $x_{i,a \text{ to } b}$ داده نام نرمال‌سازی شده در فاصله a تا b است؛ بنابراین تمامی داده‌های ورودی با این رابطه به بازه ۰ تا ۱ آورده شدند (سینگ، ۲۰۱۶ و آنتوناکس، ۲۰۱۶).

در ادامه، ترکیب‌های مختلف ورودی برای هر مدل به صورت زیر انتخاب شد:

۱- مدل **MOA1 (WPD1)**: $Vg-MOA$ و $Vg-WPD$ ؛

۲- مدل **MOA2 (WPD2)**: $Vg-MOA$ و $Vg-WPD$ و دما؛

۳- مدل **MOA3 (WPD3)**: $Vg-MOA$ و $Vg-WPD$ و فشار سطح دریا؛

۴- مدل **MOA4 (WPD4)**: $Vg-MOA$ و $Vg-WPD$ و رطوبت نسبی؛

۵- مدل **MOA5 (WPD5)**: $Vg-MOA$ و $Vg-WPD$ ، تندی باد میانگین؛

۶- مدل **MOA6 (WPD6)**: $Vg-MOA$ و $Vg-WPD$ ، تندی باد میانگین، دما و رطوبت نسبی؛

۷- مدل **MOA7 (WPD7)**: $Vg-MOA$ و $Vg-WPD$ ، تندی باد میانگین، دما و فشار سطح دریا؛

۸- مدل **MOA8 (WPD8)**: $Vg-MOA$ و $Vg-WPD$ ، تندی باد میانگین، فشار سطح دریا و رطوبت نسبی؛

به دست آمد. مقدار سنجه MSE برای روش MOA برابر با ۱۹/۱ و برای روش WPD برابر با ۱۵/۲ است. مقدار سنجه RMSE برای روش MOA برابر با ۴/۳۷ و برای روش WPD برابر با ۳/۸۹ به دست آمد. مقدار سنجه R نیز برای روش MOA برابر با ۰/۵۵ و برای روش WPD برابر با ۰/۶۶ است. بر اساس مقادیر محاسبه شده، هر چهار سنجه عملکرد مطلوب‌تری را برای روش WPD نسبت به روش MOA در پیش‌بینی تندی جست‌باد نشان دادند. البته اختلاف در درصد تولید نتایج مقرون به صحت بین دو روش چندان فاحش نبود.

جدول ۲. نتایج راستی‌آزمایی پیش‌بینی تندی جست‌باد حاصل از هر دو

روش $Vg-MOA$ و $Vg-WPD$	MAE	MSE	RMSE	R
$Vg-MOA$	۳/۴۳	۱۹/۱	۴/۳۷	۰/۵۵
$Vg-WPD$	۳/۰۷	۱۵/۲	۳/۸۹	۰/۶۶

در ادامه، ساختار شبکه عصبی مصنوعی مطابق با الگوی اشاره شده در بخش (۲-۴) طراحی و با استفاده از ترکیب‌های مختلف کمیت‌های ورودی و الگوریتم‌های آموزشی مختلف، نتایج پیش‌بینی تندی جست‌باد حاصل از هر دو روش WPD و MOA، پس‌پردازش شد. برای این منظور مقادیر پیش‌بینی شده تندی جست‌باد حاصل از روش‌های WPD و MOA به همراه ترکیبی از سایر کمیت‌های خروجی مدل WRF به عنوان ورودی به شبکه عصبی داده شد و خروجی شبکه عصبی مصنوعی، تندی جست‌باد دیده‌بانی شده بود. انتخاب ترکیب‌های مختلف ورودی به علت دست‌یابی به بهینه‌ترین حالت ممکن بود. در این مطالعه کلیه محاسبات مربوط به شبکه عصبی مصنوعی با نرم‌افزار متلب (MATLAB) نسخه ۲۰۱۸ انجام پذیرفت.

از آنجاکه کمیت‌های اندازه‌گیری شده ورودی شبکه مرتبه یکسانی ندارند، برای افزایش دقت محاسبات و

بیزین (BR) و شیب توأم مقیاس‌شده (SCG)، در جدول‌های ۳ و ۴ ارائه شده است. در این جدول‌ها، حالت بهینه برای سنجه میانگین مربع خطا (MSE) مقادیر کمتر و نزدیک به صفر است و حالت بهینه برای سنجه ضریب همبستگی پیرسون (R) مقادیری است که بزرگ‌تر هستند و به سمت عدد یک میل می‌کنند.

۹- مدل MOA9 (WPD9): Vg_{MOA} (Vg.WPD)، تندی باد میانگین، دما، فشار سطح دریا و رطوبت نسبی. ارزیابی پس‌پردازش نتایج پیش‌بینی تندی جست‌باد حاصل از دو روش WPD و MOA با شبکه عصبی مصنوعی با توجه به انتخاب ترکیب‌های مختلف کمیت‌های ورودی و بر اساس سه الگوریتم یادگیری مختلف شامل الگوریتم‌های لونیگ-مارکورات (LM)،

جدول ۳. مقادیر سنجه‌های ارزیابی حاصل از پس‌پردازش نتایج با استفاده از مدل شبکه عصبی مصنوعی بر اساس ترکیب کمیت‌های ورودی و الگوریتم‌های

یادگیری مختلف برای روش MOA

نام مدل	الگوریتم یادگیری	MSE	R (آموزش)	R (آزمون)	R (اعتبارسنجی)
MOA1	LM	۷/۴۶	۰/۵۸	۰/۵۷	۰/۶۲
	BR	۷/۷۷	۰/۵۶	۰/۵۸	۰/۶۰
	SCG	۸/۷۱	۰/۵۶	۰/۵۹	۰/۴۱
MOA2	LM	۷/۱۵	۰/۶۳	۰/۶۹	۰/۵۹
	BR	۷/۶۸	۰/۶۱	۰/۶۴	۰/۶۵
	SCG	۷/۳۴	۰/۵۶	۰/۶۵	۰/۵۹
MOA3	LM	۶/۵۳	۰/۶۷	۰/۷۶	۰/۶۶
	BR	۷/۸۹	۰/۶۰	۰/۶۶	۰/۶۸
	SCG	۷/۱۵	۰/۵۵	۰/۶۰	۰/۵۸
MOA4	LM	۶/۵۸	۰/۶۹	۰/۶۳	۰/۶۴
	BR	۶/۹۶	۰/۶۷	۰/۶۲	۰/۷۱
	SCG	۵/۶	۰/۶۱	۰/۷۲	۰/۵۵
MOA5	LM	۵/۳۸	۰/۷۲	۰/۶۹	۰/۷۰
	BR	۵/۷۹	۰/۷۱	۰/۷۲	۰/۷۶
	SCG	۷/۱۳	۰/۵۹	۰/۶۳	۰/۵۱
MOA6	LM	۵/۸۴	۰/۷۱	۰/۷۴	۰/۶۸
	BR	۵/۹۱	۰/۷۵	۰/۶۹	۰/۶۷
	SCG	۷/۵۶	۰/۵۸	۰/۵۹	۰/۶۲
MOA7	LM	۵/۷۹	۰/۷۲	۰/۶۴	۰/۷۰
	BR	۴/۹۸	۰/۷۴	۰/۷۰	۰/۶۹
	SCG	۸/۰۸	۰/۵۴	۰/۵۱	۰/۶۱
MOA8	LM	۵/۶	۰/۷۸	۰/۷۲	۰/۶۷
	BR	۴/۷۲	۰/۷۶	۰/۷۴	۰/۷۷
	SCG	۶/۸۵	۰/۵۹	۰/۶۱	۰/۶۲
MOA9	LM	۵/۲	۰/۷۹	۰/۷۵	۰/۷۷
	BR	۵/۶	۰/۷۴	۰/۷۱	۰/۶۹
	SCG	۶/۸	۰/۶۳	۰/۶۸	۰/۶۶

جدول ۴. مقادیر سنجه‌های ارزیابی حاصل از پس‌پردازش نتایج با استفاده از مدل شبکه عصبی مصنوعی بر اساس ترکیب کمیت‌های ورودی و الگوریتم‌های یادگیری مختلف برای روش WPD.

نام مدل	الگوریتم یادگیری	MSE	R (آموزش)	R (آزمون)	R (اعتبارسنجی)
WPD1	LM	۷/۳۴	۰/۷۱	۰/۶۶	۰/۷۲
	BR	۸/۵۷	۰/۶۳	۰/۶۵	۰/۷۱
	SCG	۷/۷۵	۰/۶۸	۰/۶۴	۰/۷۶
WPD2	LM	۷/۳۵	۰/۷۲	۰/۷۲	۰/۶۸
	BR	۷/۴۵	۰/۷۰	۰/۶۴	۰/۷۰
	SCG	۸/۶	۰/۶۴	۰/۶۴	۰/۶۵
WPD3	LM	۶/۹	۰/۷۳	۰/۷۰	۰/۷۱
	BR	۶/۹۵	۰/۷۴	۰/۷۱	۰/۶۶
	SCG	۸/۹۸	۰/۶۵	۰/۶۱	۰/۶۲
WPD4	LM	۷/۲۳	۰/۷۱	۰/۷۳	۰/۷۶
	BR	۷/۷۸	۰/۶۹	۰/۶۷	۰/۷۳
	SCG	۷/۸۹	۰/۷۰	۰/۶۷	۰/۶۸
WPD5	LM	۶/۸۷	۰/۷۶	۰/۶۹	۰/۷۵
	BR	۷/۷۱	۰/۷۳	۰/۷۵	۰/۷۹
	SCG	۷/۴۵	۰/۷۰	۰/۶۶	۰/۷۱
WPD6	LM	۷/۲۵	۰/۷۴	۰/۷۲	۰/۷۵
	BR	۷/۹۴	۰/۷۸	۰/۷۱	۰/۶۹
	SCG	۸/۵۷	۰/۶۸	۰/۶۳	۰/۷۵
WPD7	LM	۶/۸۴	۰/۷۳	۰/۶۹	۰/۷۶
	BR	۶/۵۳	۰/۷۸	۰/۷۴	۰/۷۶
	SCG	۷/۳۸	۰/۷۳	۰/۷۰	۰/۶۴
WPD8	LM	۴/۹	۰/۸۰	۰/۸۳	۰/۷۷
	BR	۵/۳	۰/۸۰	۰/۷۹	۰/۷۵
	SCG	۸/۱۶	۰/۶۳	۰/۷۴	۰/۷۲
WPD9	LM	۴/۲	۰/۸۳	۰/۸۷	۰/۷۳
	BR	۴/۴	۰/۸۰	۰/۸۲	۰/۷۵
	SCG	۵/۳	۰/۷۴	۰/۷۹	۰/۷۱

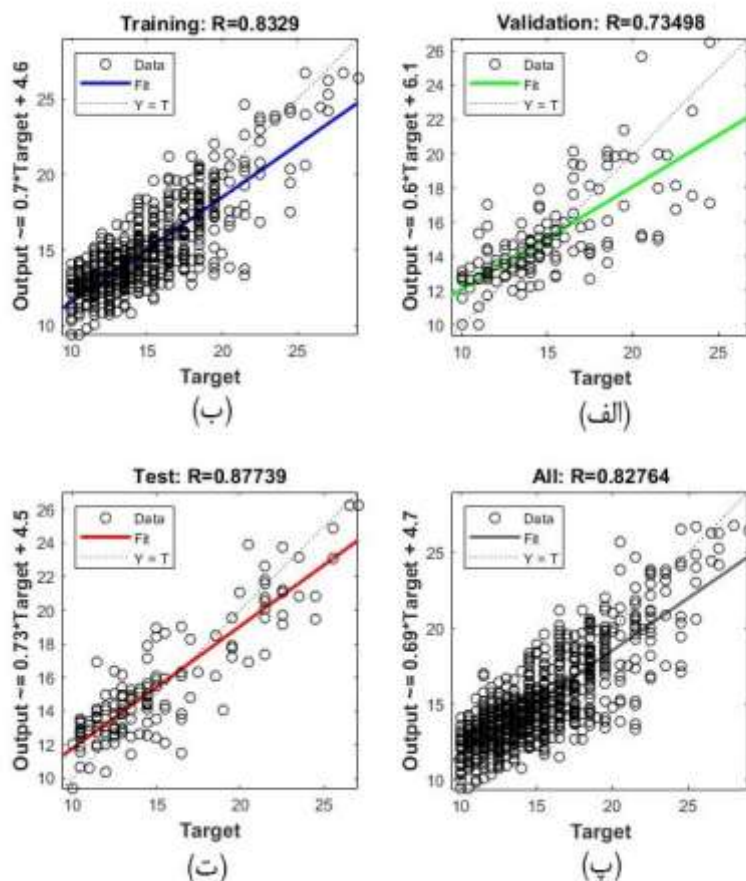
دریا، دما و رطوبت نسبی حاصل از خروجی مدل WRF و تندی جست‌باد حاصل از روابط محاسباتی بود (مدل MOA9 و WPD9). همچنین بهترین الگوریتم برای آموزش شبکه عصبی به صورت کلی از میان سه الگوریتم انتخابی، الگوریتم LM بود. البته الگوریتم BR نیز در مواردی نتایج تقریباً نزدیکی با الگوریتم LM داشت و

گفتنی است تعداد بهینه نرون‌های لایه مخفی با استفاده از روش سعی و خطا، نه عدد در نظر گرفته شد که تقریباً برای تمامی مدل‌ها نتایج بهتری را حاصل کرد. بررسی مقادیر سنجه‌های MSE و R در جدول‌های ۳ و ۴ نشان می‌دهد بهترین حالت برای ترکیب پارامترهای ورودی، استفاده از هر پنج کمیت تندی باد میانگین، فشار سطح


(شکل ۴-ب)، همه داده‌ها (شکل ۴-ج) و داده‌های آزمون (شکل ۴-د) نشان می‌دهد. همان‌گونه که از شکل مشخص است، مقدار سنجه R حاصل از این مدل برای کل داده‌ها برابر ۰/۸ به دست آمد که در مقایسه با مقدار R حاصل از روش WPD (۰/۶۶) به میزان چشمگیری افزایش داشته است. این موضوع نشان از بهبود دقت پیش‌بینی تندی جست‌باد حاصل از روش WPD پس از اعمال پس‌پردازش با شبکه عصبی مصنوعی WPD9-LM داشت.

حتی در بعضی موارد، نتایج مطلوب‌تری برای برخی مدل‌ها به همراه داشت (برای نمونه مقدار سنجه MSE برای مدل MOA8-BR یا MOA7-BR). در بهترین حالت و برای مدل‌های WPD9-LM و MOA9-LM، مقدار سنجه MSE به ترتیب برابر با ۴/۲ و ۵/۲ و مقدار سنجه R برای داده‌های آزمون، به ترتیب برابر با ۰/۸۷ و ۰/۷۵ به دست آمد.

شکل ۴، مقادیر ضریب همبستگی پیرسون (R) مدل شبکه عصبی مصنوعی بهینه (WPD9-LM) را برای داده‌های اعتبارسنجی (شکل ۴-الف)، داده‌های آموزش



شکل ۴. نمودار ضریب همبستگی (R) نتایج مدل شبکه عصبی مصنوعی بهینه (WPD9-LM) برای (الف) داده‌های اعتبارسنجی (ب) داده‌های آموزش (ج) همه داده‌ها (د) داده‌های آزمون



شکل ۵. نمودار کمترین مقدار سنجه MSE (بهترین عملکرد) برای داده‌های اعتبارسنجی مدل شبکه عصبی مصنوعی بهینه (WPD9-LM) پس از ۱۹ تکرار.

جدول ۵. مقادیر سنجه‌های ارزیابی نتایج پیش‌بینی تندی جست‌باد حاصل از هر دو روش پیش‌بینی تندی جست‌باد مورد مطالعه (Vg.WPD و Vg.MOA) و پس از پس‌پردازش نتایج با استفاده از مدل شبکه عصبی (Vg.ANN (WPD9-LM) و Vg.ANN (MOA9-LM)).

	MAE	MSE	RMSE	R
Vg.MOA	۳/۴۳	۱۹/۱	۴/۳۷	۰/۵۵
Vg.ANN (MOA9-LM)	۱/۸۶	۵/۲	۲/۳۷	۰/۷۷
Vg.WPD	۳/۰۷	۱۵/۲	۳/۸۹	۰/۶۶
Vg.ANN (WPD9-LM)	۱/۶	۴/۲۱	۲/۰۵	۰/۸۳

لونبرگ-مارکورات جهت آموزش شبکه و نُه نرون در لایه مخفی و ساختار اشاره‌شده در بخش (۲-۴)، در جدول ۵ آورده شده است. ردیف‌های ۱ و ۲ به ترتیب اشاره به مقادیر سنجه‌های ارزیابی نتایج پیش‌بینی تندی جست‌باد حاصل از روش MOA و مدل شبکه عصبی مصنوعی MOA9-LM دارند. ردیف‌های ۳ و ۴ به ترتیب اشاره به مقادیر سنجه‌های ارزیابی نتایج پیش‌بینی تندی جست‌باد حاصل از روش WPD و مدل شبکه عصبی مصنوعی بهینه (WPD9-LM) دارند. همان‌گونه که از جدول ۵ مشخص است، پس‌پردازش با استفاده از شبکه عصبی مصنوعی توانست نتایج هر دو روش پیش‌بینی تندی جست‌باد را بهبود دهد؛ برای مثال مقدار سنجه MAE برای نتایج پیش‌بینی تندی جست‌باد با استفاده از روش MOA برابر با ۳/۴۳ به دست‌آمد که پس از پس‌پردازش با استفاده از مدل شبکه عصبی مصنوعی

شکل ۵، تعداد دفعات تکرار مدل و همچنین مقدار سنجه میانگین مربع خطا (MSE) را برای شبکه عصبی مصنوعی بهینه (WPD9-LM) نشان می‌دهد. همان‌گونه که از شکل مشخص است، این مدل پس از ۱۹ بار تکرار در ۶ تکرار بعدی خود موفق به بهبود مقدار سنجه MSE نمی‌شود و در نهایت، پس از ۲۵ بار تکرار، ادامه روند متوقف می‌شود. کمترین مقدار سنجه MSE (بهترین عملکرد) برای داده‌های اعتبارسنجی شبکه عصبی مصنوعی WPD9-LM در این حالت برابر ۵/۸۶ به دست‌آمد.

مقایسه سنجه‌های ارزیابی نتایج دو روش پیش‌بینی تندی جست‌باد غیرهمرفتی با استفاده از پرونداد مدل WRF (روش‌های WPD و MOA) و نتایج پس از پس‌پردازش با مدل شبکه عصبی مصنوعی WPD9-LM و MOA9-LM با پنج کمیت به‌عنوان ورودی و الگوریتم

با روش WPD نسبت به روش MOA، عملکرد به‌نسبت بهتری در کشور ایران دارد. البته اختلاف در درصد تولید نتایج مقرون به صحت بین دو روش چندان فاحش نبود (نتایج مندرج در جدول ۲).

در بخش دوم تلاش شد تا با پس‌پردازش نتایج مدل شبکه عصبی مصنوعی، نتایج پیش‌بینی تندی جست‌باد حاصل از هر دو روش گفته‌شده بهبود یابد. مدل استفاده‌شده در این مطالعه، شبکه عصبی مصنوعی با الگوریتم پرسپترون چندلایه پیش‌خور با الگوریتم پس‌انتشار خطا و یک لایه مخفی بود. شبکه ساختار هیبریدی با تابع فعال‌سازی سیگموئید و θ نرون برای لایه مخفی و یک تابع فعال‌سازی خطی در لایه خروجی داشت. از سه روش آموزش در اجرای مدل استفاده شد که شامل الگوریتم‌های لوبنرگ-مارکورات، بیزین و شیب توأم مقیاس‌شده بود. ترکیب‌های مختلفی از متغیرهای نرمال‌شده شامل تندی باد میانگین، دما، رطوبت نسبی و فشار سطح دریا حاصل از برون‌داد مدل WRF و همچنین تندی جست‌باد حاصل از روابط مورد مطالعه، به‌عنوان ورودی جهت آموزش شبکه در نظر گرفته شد. هدف نیز تندی جست‌باد دیده‌بانی شده (مشاهداتی) فرض شد. نتایج نشان داد بهترین عملکرد شبکه عصبی مصنوعی با انتخاب θ نرون برای لایه مخفی و استفاده هم‌زمان از هر پنج پارامتر تندی باد میانگین، فشار سطح دریا، دما و رطوبت نسبی حاصل از برون‌داد مدل WRF و تندی جست‌باد حاصل از روابط محاسباتی به‌دست‌آمد. همچنین مناسب‌ترین الگوریتم برای آموزش شبکه عصبی از میان سه الگوریتم انتخابی، الگوریتم لوبنرگ-مارکورات بود. البته الگوریتم بیزین نیز نتایج تقریباً مشابهی با الگوریتم لوبنرگ-مارکورات داشت. در نهایت، شبکه عصبی مصنوعی اجراشده قادر به کاهش خطا و بهبود نتایج هر دو روش پیش‌بینی تندی جست‌باد (WPD و MOA) در ایران بود. به دلیل دقت به‌نسبت بیشتر روش WPD در پیش‌بینی

MOA9-LM، مقدار آن به $1/86$ کاهش پیدا کرد. همچنین مقدار این سنجه برای نتایج پیش‌بینی تندی جست‌باد با استفاده از روش WPD برابر با $3/07$ به‌دست‌آمد که پس از پس‌پردازش با استفاده از مدل شبکه عصبی مصنوعی بهینه (WPD9-LM)، مقدار آن به $1/6$ کاهش پیدا کرد. بررسی مقادیر سایر سنجه‌ها نیز حاکی از کاهش خطا و بهبود نتایج پیش‌بینی‌ها پس از پس‌پردازش با استفاده از مدل شبکه عصبی مصنوعی طراحی‌شده بود. به دلیل دقت به‌نسبت بیشتر روش WPD در پیش‌بینی تندی جست‌باد (جدول ۲)، نتایج پس‌پردازش با مدل شبکه عصبی مصنوعی که پیش‌بینی حاصل از این روش را به‌عنوان ورودی خود داشت (WPD9-LM) نیز از دقت به‌نسبت بیشتری نسبت به مدل دیگر (MOA9-LM) برخوردار بود.

۴ بحث و نتیجه‌گیری

هدف اصلی از این مطالعه، ارزیابی نتایج پیش‌بینی تندی جست‌باد غیرهمرفتی حاصل از دو رابطه عملیاتی و کاربردی مورد استفاده در مراکز پیش‌بینی هواشناسی و پس‌پردازش نتایج با بهره‌گیری از یک مدل شبکه عصبی مصنوعی برای کاهش خطا و بهبود دقت پیش‌بینی در کشور ایران بود.

در بخش اول این مطالعه، مدل WRF با شرایط اولیه و فیزیک مورد نظر برای ۵۷ تاریخ انتخابی و به‌صورت ۲۴ ساعته اجرا شد. تندی جست‌باد در ارتفاع ۱۰ متری از سطح زمین بر اساس دو روش مورد استفاده در اداره هواشناسی انگلستان (MOA) و روش مورد استفاده در پس‌پردازش یکپارچه مدل WRF (WPD) در زمان‌های مورد نظر محاسبه شد. نتایج بررسی سنجه‌های ارزیابی خطای مطلق میانگین (MAE)، میانگین مربع خطا (MSE)، جذر میانگین مربع خطا (RMSE) و ضریب همبستگی پیرسون (R) نشان داد پیش‌بینی تندی جست‌باد

تندی جست‌باد در کشور ایران، نتایج پس‌پردازش با استفاده از مدل شبکه عصبی مصنوعی که پیش‌بینی حاصل از این روش را به‌عنوان ورودی داشت، از دقت به‌نسبت بیشتری برخوردار بود (نتایج مندرج در جدول ۵).

تشکر و قدردانی

نگارندگان این مقاله از سازمان هواشناسی ایران برای همکاری سازنده و در اختیار قرار دادن داده‌های مورد نیاز ایستگاه‌های هواشناسی کمال تشکر را دارند.

منابع

امیرمردادی، ک.، 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.

بختیاری، ب.، قهرمان، ن.، رحیمی، ا.، ۱۳۹۲، استفاده از رویکرد شبکه عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت سرعت باد (مطالعه موردی: ایستگاه هواشناسی جیرفت): مجله تحقیقات آب و خاک ایران، ۴۴(۱)، ۱۱-۲۰.

حبیبی، ف.، ۱۳۹۷، پیش‌بینی باد جستی با شبکه پیش‌خور توسط الگوریتم یادگیری پسانتشار ارتجاعی: مجموعه مقالات هجدهمین کنفرانس ژئوفیزیک ایران، ۳۶۷-۳۷۱.

حبیبی، ف.، ۱۳۹۸، انتخاب ویژگی و پیش‌بینی باد گاستی با شبکه عصبی پرسپترون چندلایه‌ای در ایستگاه خودکار فرودگاهی: مجله ژئوفیزیک ایران، ۱۳(۳)، ۳۳-۵۲.

حسینی، س. ا.، ۱۳۸۸، برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تئوری‌های شبکه عصبی مصنوعی: پایان‌نامه کارشناسی ارشد: دانشگاه محقق اردبیلی، گروه جغرافیای طبیعی.

سبزی‌پرور، ع. ا.، علیائی، 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، ۵(۳)، ۳۰-۴۱.

عرب عامری، م.، حبیبی، ف.، کلهر، ا.، ۱۳۹۳، پیش‌بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چندلایه در فرودگاه مهرآباد: مجموعه مقالات شانزدهمین کنفرانس ژئوفیزیک ایران، ۱۱۷-۱۲۲.

عزیزی، ح. ر.، منتظری، م.، ۱۳۹۴، پیش‌بینی دماهای ماهانه ایستگاه‌های همدید منتخب استان اصفهان با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه: فصلنامه تحقیقات جغرافیایی، ۳۰(۳)، ۲۴۱-۲۵۸.

علیقلی‌نیا، ت.، رسولی مجد، ن.، رضایی، ح.، 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.

قادر، س.، صفر، م.، جوان‌نژاد، ر.، ۱۳۹۷، پیش‌بینی برخی میدان‌های هواشناسی با استفاده از یک سامانه همادی توسعه داده شده برای مدل WRF: مطالعه موردی: اولین کنفرانس بین‌المللی پیش‌بینی عددی وضع هوا و اقلیم، تهران، ۲۸ تا ۲۹ آبان ۱۳۹۷.

محمدی، م. ح.، مشکوتی، ا. ح.، قادر، س.، آزادی، م.، ۱۳۹۹، بررسی آماری جست‌بادهای همرفتی و غیرهمرفتی در محدوده ایران: مجموعه مقالات نوزدهمین کنفرانس ژئوفیزیک ایران، آبان ۱۳۹۹، ۸۸-۹۱.

منهاج، م. ب.، ۱۳۸۱، مبانی شبکه‌های عصبی: دانشگاه صنعتی امیرکبیر (پلی‌تکنیک تهران)، ۱۳۸۱.

منهاج، م. ب.، سیفی‌پور، ن.، ۱۳۷۷، کاربرد هوش محاسباتی در کنترل: مرکز نشر پروفیسور حسابی،

- to predict total dissolved solid in Achechay River Basin: *World Applied Sciences Journal*, **4**(5), 646-654.
- Kolendowicz, L., Taszarek, M., and Czerniecki, B., 2016, Convective and non-convective wind gusts in Poland, 2001-2015: *Meteorology Hydrology and Water Management*, **4**(2), 15-21.
- Kurbatova, M., Konstantin, R., Gubenko, I., and Kurbatov, G., 2018, Comparison of seven wind gust parameterizations over the European part of Russia: *Advances in Science and Research*, **15**, 251-255, 10.5194/asr-15-251-2018.
- Mohr, S., Kunz, M., Richter, A., and Ruck, B., 2017, Statistical characteristics of convective wind gusts in Germany: *Natural Hazards and Earth System Sciences*, **17**(6), 957-969.
- NCO, 1997, Subroutine calgust, Available from the National Weather Service, NCO Production, source code: www.nco.ncep.noaa.gov/pmb/codes/nwprod/global_shared.v14.1.7/sorc/ncep_post.fd/CALGUST.f.
- RUC20, 2007, diagnostic output fields for the Rapid Refresh and HRRR, Available from the National Oceanic and Atmospheric Administration website: https://rapidrefresh.noaa.gov/RAP_var_diagnosis.html.
- Selcuk Nogay, H., Cetin Akinci, T., and Eidgeviciute, M., 2012, Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey: *Journal of Energy in Southern Africa*, **23**(4).
- Sheridan, P., 2011, Review of Techniques and Research for Gust Forecasting and Parameterisation: Forecasting Research Technical Report 570, Met Office, Exeter.
- Singh, V., 2016, Application of artificial neural networks for predicting generated wind power: *International Journal of Advanced Computer Science and Applications*, **7**(3).
- Solari, G., Repetto, M. P., Burlando, M., De Gaetano, P., Pizzo, M., Tizzi, M., and Parodi, M., 2012, The wind forecast for safety management of port areas: *Journal of Wind Engineering and Industrial Aerodynamics*, **104**, 266-277.
- Stucki, P., Dierer, S., Welker, C., Navarro, J. J. G., Raible, C. C., Martius, O., and Brönnimann, S., 2016, Evaluation of downscaled wind speeds and parameterised gusts for recent and historical windstorms in Switzerland: *Tellus A, Dynamic Meteorology* تهران.
- نیاز علیزاده، ع.، وکیلی، غ.، صحرائیان، ف.، ۱۳۸۸، پس‌پردازش برونداد مدل میان‌مقیاس WRF برای دمای دو متری سطح زمین با استفاده از شبکه عصبی مصنوعی: هشتمین همایش پیش‌بینی عددی وضع هوا، تهران، ۲ دی ۱۳۸۸.
- AMS wind gust definition, 2018, <https://glossary.ametsoc.org/wiki/Gust>; Retrieved November 15.
- Antonakis, A., Lone, M., and Cooke, A., 2016, Neural network based dynamic model and gust identification system for the jetstream G-NFLA, Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, **231**(6), 1138-1153.
- Brasseur, O., 2001, Development and application of a physical approach to estimating wind gusts: *Monthly Weather Review*, **129**(1), 5-25.
- Burton, T., Sharpe, D., Jenkins, N., and Bossanyi, E., 2011, *Wind Energy Handbook*: John Wiley and Chichester, S., UK, 742 PP, edition 2.
- Chan, P., 2012, An event of tail strike of an aircraft due to terrain-induced wind shear at the Hong Kong International Airport: *Meteorological Applications*, **19**(3), 325-333.
- Choi, E. C. C., and Hidayat, F. A., 2002, Gust factors for thunderstorm and non-thunderstorm winds: *Journal of Wind Engineering and Industrial Aerodynamics*, **90**(12), 1683-1696.
- Cook, N. J., Harris, R. I., and Whiting, R., 2003, Extreme wind speeds in mixed climates revisited: *Journal of Wind Engineering and Industrial Aerodynamics*, **91**(3), 403-422.
- de Meutter, P., Gerard, L., Smet, G., Hamid, K., Hamdi, R., Degrauwe, D., and Termonia, P., 2015, Predicting small-scale, short-lived downbursts: case study with the NWP limited-area ALARO model for the Pukkelpop thunderstorm: *Monthly Weather Review*, **143**(3), 742-756.
- Han Jiawei, J. P., and Kamber, M., 2012, *Data Mining: Concepts and Techniques*, 3rd edition: Morgan Kaufmann Publishers, ISBN 978-0-12-381479-1.
- Jolliffe, I. T., and Stephenson, D. B., 2003: *Forecast Verification: A Practitioner's Guide in Atmospheric Science*: John Wiley and Sons, 240pp.
- Kanani, S., Asadollahfardi, G., and Ghanbari, A., 2008, Application of artificial neural network

and Oceanography, **68**(1).
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.

Evaluation of two methods of forecasting wind gust speed in Iran and post-processing of results using artificial neural network

Mohammad Hesam Mohammadi¹, Amir Hussain Meshkatee^{2*}, Sarmad Ghader³ and Majid Azadi⁴

¹ Ph.D. Candidate, Department of Earth Sciences, Science and Research branch, Islamic Azad University, Tehran, Iran

² Associate Professor, Department of Earth Sciences, Science and Research branch, Islamic Azad University, Tehran, Iran

³ Associate Professor, Department of Space Physics, Institute of Geophysics, University of Tehran, Tehran, Iran

⁴ Associate Professor, Atmospheric Science and Meteorological Research Center (ASMEC), Tehran, Iran

(Received: 18 November 2021, Accepted: 19 May 2022)

Summary

Atmospheric currents, known as winds, are among the most important fields of study in different disciplines of science. One of the most important characteristics of wind is gustiness. Wind gust, among many other characteristics of the wind field, is studied extensively due to severe impacts that it may have on many aspects of human socio-economic activities. There are several models to predict wind gust speed. The results of these models always contain random and systematic errors that reduce the accuracy of predictions due to the lack of topographic resolution as well as the deficiencies of different physical schemes in the models. Consequently, post-processing is the most important process in the course of simulation and prediction using different types of models. Artificial neural network is one of the available tools that may be used to reduce errors of models by matching their outputs and observations.

The aim of this study was to evaluate the performance of two models and artificial neural network in forecasting wind gust in Iran. First, a study was designed to examine two methods of the non-convective wind gusts forecasting, i.e., the UK Meteorological Office (MOA) and WRF post-process diagnostic of wind gusts (WPD) performances. To investigate the performance of two methods, 1880 cases of non-convective wind gust observations of 32 synoptic stations in Iran, between 2013 and 2018, were studied. Four RMSE, MAE, MSE and R were used to measure the performance of those two methods. The results for WPD and MOA were 3.89, 3.07, 15.2, 0.66 and 4.37, 3.43, 19.1, 0.55, respectively. The results showed that the WPD method performed better than the MOA method. To post-process the wind gust forecasts with an artificial neural network, a feedforward multilayer perceptron with the back-propagation learning algorithm was designed. The model had a hybrid structure with a sigmoid activation function for the hidden layer and a linear transfer function in the output layer. Three training algorithms were used in the implementation of the model. Various combinations of normalized output variables of the WRF were used as input for network training and the target was observational wind gust speed. Seventy percent of the data were used for training, fifteen percent for testing and fifteen percent for validation.

The results showed that the best way to combine the input parameters is to use 10m wind, sea level pressure, temperature and relative humidity resulting from the output of the WRF model and the wind gust speed resulting from both methods mentioned above. Also, the best algorithm for neural network training was the Levenberg-Marquardt algorithm. Finally, the implemented artificial neural network was able to improve the results of both wind gust speed prediction methods (WPD and MOA). Due to the relatively higher accuracy of the WPD method compared with MOA method in predicting the wind gust speed in Iran, the artificial neural network that assumed the prediction of this method as input, was more accurate than MOA method (RMSE, MAE, MSE and R were 2.05, 1.6, 4.21, 0.83 and 2.37, 1.86, 5.2, 0.77, respectively).

Keywords: Artificial neural network, numerical model, post processing, wind gust, WRF

*Corresponding author:

ameshkatee@yahoo.com