

انتخاب ویژگی و پیش‌بینی باد گاستی با شبکه عصبی پرسپترون چندلایه‌ای در ایستگاه خودکار فرودگاهی

فریده حبیبی^{*۱}

^۱ استادیار، گروه فیزیک فضا، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

(تاریخ دریافت: ۱۳۹۸/۰۶/۲۸، تاریخ پذیرش: ۱۳۹۸/۰۹/۱۳)

چکیده

در این مقاله ابتدا با بررسی هوای حاضر گزارش‌های متار، بازه زمانی بیشترین وقوع ناپایداری ایجادکننده باد گاستی (جستی) شناسایی شد. سپس با استانداردسازی داده‌ها به بازه ۰/۱ تا ۰/۹، ویژگی‌های مرتبط با جهت و سرعت باد جستی انتخاب شد. روش‌های انتخاب ویژگی در این پژوهش، اطلاعات متقابل و جستجوی پی‌درپی پیشرو شناور با الگوریتم طبقه‌بندی k نزدیک‌ترین همسایگان هستند. ویژگی‌های انتخابی برای پیش‌بینی سرعت باد با روش اول، متغیرهای سرعت باد لحظه‌ای شامل کمینه، میانگین و بیشینه سرعت باد در دو دقیقه و میانگین و بیشینه سرعت باد در ده دقیقه در همان باند هستند. ویژگی‌های انتخابی برای جهت باد با روش اول، متغیرهای جهت باد لحظه‌ای یعنی کمینه، میانگین و بیشینه جهت باد در دو دقیقه و کمینه، میانگین و بیشینه جهت باد در ده دقیقه در همان باند هستند. ویژگی‌های انتخابی با روش دوم برای سرعت باد شامل انحراف جهت باد در ده دقیقه گذشته در باند میانی و فشار لحظه‌ای در هر سه باند است. انحراف جهت باد در ده دقیقه گذشته در باند ۱۱، در باندهای ۲۹ و میانی مشترک هستند. ویژگی چهارم در باندهای ۲۹ و میانی، متغیر بیشینه سرعت باد در ده دقیقه مربوط به همان باند است. در باند ۱۱ علاوه بر ویژگی‌های مشترک، متغیرهای بیشینه سرعت باد در ده دقیقه در باند ۱۱ و انحراف جهت باد در ده دقیقه گذشته در باند ۲۹ دیده می‌شود. ویژگی‌های انتخابی برای جهت باد از تنوع بیشتری برخوردار هستند.

در مرحله نهایی، ویژگی‌های انتخابی به شبکه عصبی پرسپترون چندلایه در حالت‌های مختلف داده شد. نتایج خروجی مدل برای پیش‌بینی جهت و سرعت باد جستی مقایسه و بهترین مدل برای پیش‌بینی سرعت باد جستی، شبکه با همبندی ۱-۲-۴، نرخ یادگیری ۰/۱ و آستانه آغازین ۰/۵ برای وزن هر نرون انتخاب شد. برای جهت باد، شبکه با همبندی ۱-۳-۶، نرخ یادگیری ۰/۱ و آستانه آغازین ۰/۵ مناسب است. عملکرد شبکه عصبی پرسپترون چندلایه‌ای در پیش‌بینی سرعت باد بهتر است.

واژه‌های کلیدی: باد گاستی، انتخاب ویژگی، اطلاعات متقابل، جستجوی پی‌درپی پیشرو شناور، شبکه عصبی پرسپترون چندلایه، ایستگاه خودکار فرودگاهی

۱ مقدمه

پیشرفت‌های به‌وجودآمده در ابزار و ادوات اندازه‌گیری کمیت‌های هواشناسی، جمع‌آوری و ذخیره‌سازی آنها طی دهه‌های اخیر باعث شده است با حجم عظیمی از اطلاعات سروکار داشته باشیم. همه روزه در هر ایستگاه هواشناسی دستی یا خودکار، تعداد زیادی از متغیرها اندازه‌گیری و ذخیره‌سازی می‌شود. تعداد متغیرهایی که در هر دیده‌بانی ایستگاه اندازه‌گیری می‌شود «ابعاد داده» آن ایستگاه نامیده می‌شود. عبارت «متغیر» بیشتر در آمار استفاده می‌شود در حالی که در علوم کامپیوتر و یادگیری ماشین، بیشتر از عبارت «ویژگی» استفاده می‌شود. با توجه به اینکه پدیده‌های جوی پیچیدگی خاصی دارند و در ایجاد آنها چندین ویژگی دخالت دارد، تحلیل آنها با استفاده از روش‌های آماری سنتی به‌سختی انجام می‌شود؛ بنابراین لازم است برای جلوگیری از تحمیل بار محاسباتی زیاد و افزودن دقت محاسبات، فقط ویژگی‌های مرتبط با پدیده مورد بررسی استخراج یا انتخاب شوند. البته در استخراج ویژگی، ترکیبی از ویژگی‌ها به‌عنوان یک ویژگی جدید در نظر گرفته می‌شود (برای مثال، تحلیل مؤلفه‌های اساسی)، اما در انتخاب ویژگی، آنها بدون تغییر انتخاب می‌شوند؛ بنابراین بررسی و مدل‌سازی صحیح پدیده‌های جوی مستلزم شناخت کامل کمیت‌های تأثیرگذار است. البته استفاده از دانش افراد باتجربه تا حدودی کمک می‌کند ولی این دانش در افراد با تجربه نیز متفاوت است. برای گریز از این معضل، امروزه از روش‌های آماری و روش‌های هوش مصنوعی کمک می‌گیرند که انجام این کار نیز مستلزم انتخاب متغیرهای ورودی مناسب برای مدل‌سازی آن پدیده است. در اینجا می‌توان به چند نمونه از کاربردهای انتخاب ویژگی در هواشناسی اشاره کرد.

اشرفی و همکاران (۱۳۹۰) پیش‌بینی روزانه غلظت منوکسید کربن برای تهران را با استفاده از مدل انتخاب

پیشرو عصبی-فازی انجام دادند. آنها با دو نگرش مختلف، سرعت باد را در حکم شاخص تلاطم مکانیکی و تابش خورشید را در حکم شاخص تلاطم همرفتی در نظر گرفتند و در نگرش دیگر، مقیاس سرعت اصطکاکی را به‌عنوان شاخص تلاطم مکانیکی و گرادیان دما را به منزله شاخص تلاطم همرفتی در نظر گرفتند و دو مجموعه عصبی-فازی را برای پیش‌بینی غلظت روزانه منوکسید کربن در جو تهران توسعه دادند. پس از مقایسه نتایج پیش‌بینی مدل‌ها مشخص شده است که اعمال روش پیشرو با کاهش تعداد ورودی‌ها و کاهش حجم محاسبات، دقت مدل را افزایش داده و مدل توسعه داده شده براساس گرادیان باد و گرادیان دما در حکم مدل برتر معرفی شده است.

اردیل و ارکک اوغلی (۲۰۱۳) برای پیش‌بینی کمینه و بیشینه فشار هوا و تابش خورشید از دو شبکه عصبی پی‌درپی استفاده کردند. در شبکه اول که برای پیش‌بینی کمینه و بیشینه فشار هوا استفاده می‌شود، متغیرهای عرض جغرافیایی، طول جغرافیایی، ارتفاع، ماه، کمینه و بیشینه دما، رطوبت نسبی روزانه و مدت زمان تابش آفتابی متوسط در لایه ورودی استفاده شد و فشار پیش‌بینی شده را همراه با متغیرهای قبلی به شبکه دوم دادند و مقدار تابش خورشیدی را پیش‌بینی کردند. البته در این تحقیق ابتدا داده‌ها بین صفر و یک بهنجار شد و با استفاده از تابع سیگموئید لگاریتمی در لایه پنهان و الگوریتم پس‌انتشار لوبنرگ-مارکوآت (Levenberg-Marquardt, LM) و الگوریتم یادگیری گرادیان توأم مدرج/مقیاس‌شده توانستند الگوریتم‌های بهینه را برای شبکه اول و دوم به ترتیب LM با هفت نرون و هشت نرون به‌دست آورند.

حیبی و همکاران (۱۳۹۰) از بین داده‌های GFS مربوط به فعالیت طوفان حاره‌ای گونو که در اوایل ماه ژوئن ۲۰۰۷ در منطقه دریای عرب، دریای عمان و خلیج فارس رخ داده بود، ابتدا از بین ۲۸۶ متغیر متفاوت ثبت

لوکا و همکاران (۲۰۱۰) برای پیش‌بینی کیفیت هوا از اطلاعات متقابل جزئی برای انتخاب ویژگی‌های مناسب استفاده کردند. آنها ابتدا از بین متغیرهای دما، رطوبت نسبی، سرعت و جهت باد، فشار جوی، تابش خورشیدی و باران بیست‌وچهار ساعته و همچنین غلظت آلاینده‌های اصلی هوا مثل SO_2 ، NO_2 ، NO_x ، CO ، O_3 و ذرات با قطر تا $10\mu m$ (معروف به PM_{10})، متغیرهای کمینه، بیشینه و میانگین مقدار روز قبل PM_{10} و همچنین میانگین مقدار دو روز قبل و سه روز قبل PM_{10} ؛ بیشینه روز قبل دما، غلظت آلاینده‌های NO_2 ، O_3 و بیشینه دو روز قبل O_3 و میانگین مقدار فشار روز قبل را به‌عنوان متغیرهای بهینه برای پیش‌بینی PM_{10} انتخاب کردند. سپس از شبکه عصبی پیشرو با یک لایه مخفی با هشت نرون و تابع تحریک تانژانت هیپربولیک توانستند نتایج خوبی به‌دست آورند.

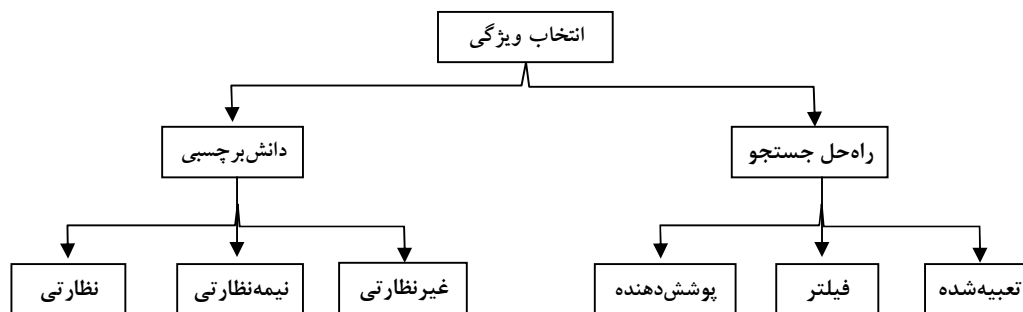
۲ روش‌های انتخاب ویژگی

برای تحلیل هر پدیده‌ای با استفاده از داده‌های جمع‌آوری‌شده، ابتدا باید بُعد مشاهدات را طوری کاهش داد که با از دست دادن کمترین اطلاعات همراه باشد؛ به‌عبارت‌دیگر، بررسی به متغیرهایی اختصاص یابد که از مشاهده‌ای به مشاهده دیگر زیاد تغییر نکنند تا بتوان آنها را به‌عنوان ثابت‌های مسئله در نظر گرفت. الگوریتم‌های انتخاب ویژگی در داده‌کاوی پیشگویانه برای مسائل طبقه‌بندی طوری طرح‌ریزی می‌شوند که تنها ویژگی‌هایی انتخاب شوند که به مسئله طبقه‌بندی مرتبط باشند و تکراری و بی‌ربط نباشند. منظور از مرتبط بودن، وجود همبستگی قوی بین آن ویژگی با تابع هدف یا با ویژگی‌های دیگر است (لوتو و انگلبرکت، ۲۰۱۰). ویژگی‌های مرتبط را کوه‌اوی و جان (۱۹۹۷) به سه سطح

شده با استفاده از داده‌کاوی، ۴۵ متغیر را انتخاب و سپس با استفاده از روش‌های استخراج ویژگی جستجوی بی‌درپی پیشرو، پسرو، معیار همبستگی متقابل، تحلیل مؤلفه‌های اصلی و تحلیل عامل‌های اصلی، کمیت‌های مرتبط با سرعت باد در ارتفاع ۱۰ متری از سطح زمین را در زمان وقوع پدیده طوفان حاره‌ای استخراج کردند. این کمیت‌ها به‌عنوان ورودی به شبکه استنباط فازی-عصبی تطبیقی (ANFIS) داده شد تا سرعت باد در ارتفاع ۱۰ متری از سطح زمین پیش‌بینی شود.

انتظاری و همکاران (۱۳۹۰) با استفاده از شبکه عصبی MLP توانستند وقوع یخبندان‌های زودرس و دیررس را در استان کرمانشاه پیش‌بینی کنند. در این بررسی، از داده‌های آماری دمای روزانه شهرهای اسلام‌آباد غرب، کنگاور، کرمانشاه، روانسر و سرپل ذهاب در سال‌های ۱۹۸۷ تا ۲۰۰۷ (فقط اول نوامبر تا پایان ماه آوریل) برای یک شبکه پیشرو با یک لایه پنهان، با تعداد نرون‌های متغیر برای هر ایستگاه و یادگیری شبکه به شکل پس‌انتشار با آموزش دسته‌ای و توابع انتقال: سیگموئید لگاریتمی (Log-sigmoid) و اشباع خطی (Saturating Symmetric) و اشباع خطی متقارن (Satlin (linear استفاده شد.

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



شکل ۱. نحوه انتخاب ویژگی.

الگوریتم‌های یادگیری و طبقه‌بندی است. این روش به مقیاس‌های متعدد از مشخصه‌های کلی داده‌های آموزشی مانند فاصله، اطلاعات، وابستگی و سازگاری متکی است (چاندرا و کارتیکیان، ۲۰۱۳). هدف، یافتن زیرمجموعه‌ای از ویژگی‌ها است که نه تنها کمترین تعداد عضو را داشته باشد، بلکه اطلاعات موجود در کل مجموعه ویژگی‌ها را درباره یک کلاس ارائه دهد. این مسئله نیز معمولاً با یافتن ویژگی‌های مرتبط و حذف ویژگی‌های تکراری و بی‌ربط حل می‌شود (ورگارا و ایستویز، ۲۰۱۴). از آنجاکه این روش براساس فاصله ویژگی‌ها از هم تعیین می‌شود، دقت کمی دارد، اما سرعت محاسبات در آن زیاد است و برای داده‌های با ابعاد زیاد مناسب است. این روش به عملکرد واقعی طبقه‌بندی دسترسی مستقیم ندارد؛ بنابراین برهم‌کنش بین ویژگی‌های انتخاب‌شده و طبقه‌بندی مورد استفاده را نمی‌تواند در نظر بگیرد. روش اطلاعات متقابل (MI) و امتیاز فیشر (F-score) نمونه‌هایی از این نوع هستند (مقصودی و قزوینی، ۱۳۹۷).

۲-۲ روش پوشش‌دهنده

در روش پوشش‌دهنده، از پیشگویی‌کننده به شکل یک جعبه سیاه و از تابع هدف، هنگام اجرا برای ارزیابی زیرمجموعه استفاده می‌شود (چاندراشکار و فرات، ۲۰۱۴). در این روش، هم‌زمان با به‌کارگیری قوانین، عمل

قوی (strongly relevant)، ضعیف (weakly relevant) و بی‌ربط (features irrelevant) تقسیم کردند. آنهایی که در سطح قوی قرار دارند، اطلاعات بی‌نظیری درباره کمیت مورد بررسی ارائه می‌دهند؛ بنابراین، نمی‌توان آنها را با ویژگی‌های دیگر جایگزین کرد. ویژگی‌های نسبت‌داده‌شده به سطح دوم (ضعیف)، اطلاعات مربوط به کمیت مورد بررسی را ارائه می‌دهند، اما می‌توان بدون اینکه اطلاعاتی از بین برود، آنها را با ویژگی‌های دیگر جایگزین کرد. سطح آخر، شامل ویژگی‌های بی‌ربط و نامناسب است که هیچ‌گونه اطلاعاتی درباره کمیت هدف ارائه نمی‌دهند و می‌توان آنها را راحت کنار گذاشت.

روش‌های زیادی برای انتخاب ویژگی وجود دارد که به‌طور کلی براساس معیارهای ارزیابی به سه گروه اصلی فیلتر (filter)، پوشش‌دهنده (wrapper) و تعبیه‌شده (embedded) تقسیم شده‌اند (گویان و الیسف، ۲۰۰۳). این روش‌ها براساس دانش برچسبی به نظارتی، نیمه‌نظارتی و غیرنظارتی تقسیم شده‌اند (جیانی و لینگفنگ، ۲۰۱۶). در شکل ۱ طرح‌واره طبقه‌بندی روش‌های انتخاب ویژگی ارائه شده است.

۱-۲ روش فیلتر

روش فیلتر ساده‌ترین نوع انتخاب ویژگی است که در آن انتخاب ویژگی براساس ایده ارتباط است و مستقل از

۲-۴ روش ترکیبی (Hybrid)

با توجه به رویکرد روش‌های فیلتر و پوشش‌دهنده که مکمل هم هستند، از ترکیب آنها روش ترکیبی ابداع شده است. این روش با استفاده از مزایای دو روش قبلی می‌تواند جواب‌های بهتری ارائه دهد. روش‌های ترکیبی شامل دو مرحله هستند. در مرحله اول، از روش‌های مبتنی بر فیلتر برای کاهش ابعاد داده استفاده می‌شود. در مرحله بعد، روش‌های پوشش‌دهنده برای انتخاب بهترین زیرمجموعه ویژگی‌ها به کار می‌رود (روحی و نظام آبادی پور، ۱۳۹۶). روش‌های ترکیبی انتخاب ویژگی، بدون کاهش سرعت و افزایش نه چندان زیاد پیچیدگی محاسباتی، سبب حذف ویژگی‌های نامرتب و افزونه می‌شوند. ویژگی‌های افزونه، آن ویژگی‌هایی هستند که مستقیماً بی‌ربط نیستند، بلکه با سایر ویژگی‌ها ارتباط دارند و با استفاده از آنها می‌توان ویژگی‌های دیگر را محاسبه کرد (مقصودی و قزوینی، ۱۳۹۷).

۳ داده‌ها و ضرورت پژوهش

داده‌های استفاده‌شده در این پژوهش، متعلق به ایستگاه خودکار مهرآباد در بازه زمانی ژانویه تا آوریل ۲۰۱۳ است. این بازه زمانی براساس بررسی هوای حاضر گزارش‌های متار مربوط به ایستگاه همدیدی مهرآباد انتخاب شده است که بیشترین وقوع ناپایداری و تشکیل ابر کومه‌ای باران در تهران را در این بازه نشان می‌دهد. گفتنی است ابر کومه‌ای باران، جبهه گاستی یا جستی را ایجاد می‌کند. طبق تعریف سازمان جهانی هواشناسی، باد گاستی زمانی گزارش می‌شود که بیشینه سرعت باد در بازه زمانی ۱۰ دقیقه، ۵ متر بر ثانیه یا ۱۰ نات افزایش یابد. این ایستگاه کمیت‌ها را به‌طور هم‌زمان و در فاصله زمانی یک دقیقه با سه سنجنده مختلف اندازه‌گیری می‌کند. باند فرودگاه مهرآباد به طول ۴۰۰۰ متر و عرض ۴۵ متر در

طبقه‌بندی داده‌ها نیز انجام می‌شود و هر بار که زیرمجموعه‌ای انتخاب می‌شود، برای ارزیابی آن باید مدل طبقه‌بندی‌کننده فراخوانی شود؛ به عبارت دیگر، بر پایه میزان دقت طبقه‌بندی‌کننده طرح‌ریزی شده است. در اینجا ذکر این نکته ضروری است که روش‌های طبقه‌بندی نظارت‌شده به دو گونه پارامتریک (مثل کمترین فاصله که در آن نمونه به کلاسی تعلق دارد که کمترین فاصله اقلیدسی را از بردار میانگین آن کلاس داشته‌باشد) و غیرپارامتریک (مثل k نزدیک‌ترین همسایه و شبکه‌های عصبی) تقسیم شده‌اند. البته در روش‌های طبقه‌بندی پارامتریک باید فرضی از توزیع داده‌ها وجود داشته‌باشد درحالی‌که در روش غیرپارامتریک (مثل ماشین بردار پشتیبان) به هیچ فرضی نیاز نیست (قوامی و همکاران، ۱۳۹۶). سرعت محاسبات این روش نسبت به روش فیلتر کم است، اما دقت آن بیشتر است و معمولاً عملکرد خوبی دارد. اگر مجموعه داده‌ها بزرگ باشد، پردازش آنها پرهزینه و انعطاف‌ناپذیر است. روش‌های انتخاب ویژگی متوالی پیشرو (Sequential Forward Selection, SFS)، پسرو (Sequential Backward Selection, SBS) و جستجوی پیشرو شناور (Floating Sequential, SFFS) Forward Selection) نمونه‌هایی از این روش هستند.

۲-۳ روش تعبیه‌شده

در این روش انتخاب ویژگی با سازوکارهای درونی الگوریتم طبقه‌بندی انجام می‌شود (پوهیالاین و همکاران، ۲۰۱۵)؛ یعنی انتخاب ویژگی هم‌زمان با ساخت طبقه‌بندی‌کننده انجام می‌شود. درخت‌های تصمیم‌گیری نمونه‌ای از این روش هستند. در روش‌های پوشش‌دهنده، زمان محاسبات برای طبقه‌بندی زیرمجموعه‌های مختلف طولانی است، اما چون در روش تعبیه‌شده انتخاب ویژگی به‌عنوان بخشی از فرایند آموزش در نظر گرفته می‌شود، این زمان کاهش می‌یابد.

(در مجموع، ۴۳ نمونه) از مجموعه داده‌ها کنار گذاشته شدند و بقیه داده‌های استفاده‌شده، در یک ماتریس با ابعاد 64×128557 قرار داده شدند. پنج ستون نخست این ماتریس، مربوط به زمان اندازه‌گیری کمیت‌ها است که به ترتیب شامل سال، ماه، روز، ساعت و دقیقه است. شش ستون آخر ماتریس نیز دربرگیرنده جهت و سرعت باد جستی اندازه‌گیری‌شده با سه سنجنده است. شصت درصد داده‌ها جهت آموزش، بیست درصد جهت آزمون و بیست درصد نیز جهت اعتبارسنجی شبکه در نظر گرفته شدند.

از آنجا که کمیت‌های اندازه‌گیری‌شده مرتبه یکسانی ندارند، برای افزایش دادن دقت محاسبات و دستیابی به نتایج بهتر، ابتدا از روش استانداردسازی (بهنجارسازی) min-max استفاده شد. مزیت روش گفته‌شده این است که تمام روابط بین داده‌ها را حفظ می‌کند و نیاز به معرفی سوگیری نیست. استانداردسازی داده‌ها در این روش از رابطه زیر محاسبه شده است (هان و همکاران، ۲۰۱۲):

$$X_{i,a \text{ to } b} = a + \frac{(x_i - x_{Min})(b - a)}{(x_{Max} - x_{Min})} \quad (1)$$

در رابطه فوق x_i ، x_{Min} و x_{Max} به ترتیب داده‌های ورودی واقعی، کمینه و بیشینه آنها است. a و b مقادیر کمینه و بیشینه هدف هستند که در اینجا به ترتیب $0/1$ و $0/9$ انتخاب شدند. $X_{i,a \text{ to } b}$ داده i ام استانداردسازی‌شده در فاصله a تا b است؛ بنابراین تمامی داده‌ها با این رابطه به بازه $0/1$ تا $0/9$ آورده شدند. در مرحله آخر، با استفاده از روش‌های رایج در انتخاب ویژگی مانند روش جستجوی پی‌درپی پیشرو، روش جستجوی پی‌درپی پسرو و معیار اطلاعات متقابل سعی شد تا ویژگی‌هایی انتخاب شوند که بیشترین تأثیر را در تعیین مقدار کمیت مورد بررسی دارند.

راستای شرق به غرب قرار دارد و سنجنده شماره ۲۹ در منتهی‌الیه شرقی باند، سنجنده شماره ۱۱ در منتهی‌الیه غربی باند و سنجنده میانی به فاصله ۶۰۰ متری وسط باند در جهت شمال آن قرار دارد. فهرست کمیت‌های اندازه‌گیری‌شده در این ایستگاه در جدول ۱ ارائه شده است. برای سهولت کار، اعداد ۱ تا ۶۴ که در این پژوهش به متغیرهای (ویژگی‌های) اندازه‌گیری‌شده نسبت داده شده است، در ستون یک و چهار جدول ۱ و نام اختصاص‌یافته به ویژگی از طرف سازمان جهانی هواشناسی نیز در ستون دو و پنج گنجانده شده است. تفسیر این ویژگی‌ها نیز در جدول آورده شده است. در این جدول به جز متغیرهای ردیف ۵۸ تا ۶۴ که سنجنده میانی آنها را اندازه‌گیری می‌کند، بقیه شامل کمیت‌های اندازه‌گیری‌شده از سه سنجنده مختلف هستند که داده‌های آنها در این پژوهش در یک ماتریس 64×128588 قرار داده شده است. ویژگی‌های مربوط به سرعت باد برحسب متربرثانه هستند. جهت باد برحسب درجه است که بین صفر تا ۳۶۰ درجه متغیر است. اگر جهت باد صفر یا ۳۶۰ درجه باشد، به منزله باد شمالی است و اگر ۹۰ درجه باشد، باد شرقی محسوب می‌شود. جهت باد ۱۸۰ درجه، باد جنوبی و جهت ۲۷۰ درجه، باد غربی را نشان می‌دهد. ویژگی‌های مربوط به فشار نیز برحسب هکتوپاسکال یا میلی‌بار هستند. هدف این تحقیق، یافتن متغیرهای تأثیرگذار بر باد گاستی در ایستگاه فرودگاهی مهرآباد و به‌کارگیری آنها در پیش‌بینی این باد با استفاده از شبکه عصبی پرسپترون چندلایه است.

۴ اجرای مدل برای انتخاب ویژگی‌های مرتبط با جهت و سرعت باد جستی

برای اجرا کردن مدل، ابتدا داده‌ها پیش‌پردازش شدند و نمونه‌هایی که اطلاعات آنها تصحیح‌شدنی نبود

جدول ۱. کمیت‌های اندازه‌گیری‌شده در یک ایستگاه خودکار فرودگاهی، کمیت‌های مربوط به سرعت باد برحسب متربرثانیه و جهت باد برحسب درجه (بین صفر تا ۳۶۰ درجه) هستند.

شماره ویژگی	عنوان ویژگی	تفسیر	شماره ویژگی	عنوان ویژگی	تفسیر
۱	WSINS29	سرعت باد لحظه‌ای	۳۳	CW2A_Mid	مؤلفه‌های جهت باد در راستای باند پروازی
۲	WS2M29	کمینه سرعت باد در دو دقیقه	۳۴	HW2A_Mid	مؤلفه‌های سرعت باد در راستای باند پروازی
۳	WS2A29	متوسط سرعت باد در دو دقیقه	۳۵	WSINS11	سرعت باد لحظه‌ای
۴	WS2X29	بیشینه سرعت باد در دو دقیقه	۳۶	WS2M11	کمینه سرعت باد در دو دقیقه
۵	WS10M29	کمینه سرعت باد در ده دقیقه	۳۷	WS2A11	متوسط سرعت باد در دو دقیقه
۶	WS10A29	متوسط سرعت باد در ده دقیقه	۳۸	WS2X11	بیشینه سرعت باد در دو دقیقه
۷	WS10X29	بیشینه سرعت باد در ده دقیقه	۳۹	WS10M11	کمینه سرعت باد در ده دقیقه
۸	WDINS29	جهت باد لحظه‌ای	۴۰	WS10A11	متوسط سرعت باد در ده دقیقه
۹	WD2M29	کمینه جهت باد در دو دقیقه	۴۱	WS10X11	بیشینه سرعت باد در ده دقیقه
۱۰	WD2A29	متوسط جهت باد در دو دقیقه	۴۲	WDINS11	جهت باد لحظه‌ای
۱۱	WD2X29	بیشینه جهت باد در دو دقیقه	۴۳	WD2M11	کمینه جهت باد در دو دقیقه
۱۲	WD10M29	کمینه جهت باد در ده دقیقه	۴۴	WD2A11	متوسط جهت باد در دو دقیقه
۱۳	WD10A29	متوسط جهت باد در ده دقیقه	۴۵	WD2X11	بیشینه جهت باد در دو دقیقه
۱۴	WD10X29	بیشینه جهت باد در ده دقیقه	۴۶	WD10M11	کمینه جهت باد در ده دقیقه
۱۵	WDVAR29	انحراف جهت باد در ده دقیقه گذشته	۴۷	WD10A11	متوسط جهت باد در ده دقیقه
۱۶	CW2A29	مؤلفه‌های جهت باد در راستای باند پرواز	۴۸	WD10X11	بیشینه جهت باد در ده دقیقه
۱۷	HW2A29	مؤلفه‌های سرعت باد در راستای باند پرواز	۴۹	WDVAR11	انحراف جهت باد در ده دقیقه گذشته
۱۸	WSINS_Mid	سرعت باد لحظه‌ای	۵۰	CW2A11	مؤلفه‌های جهت باد در راستای باند پروازی
۱۹	WS2M_Mid	کمینه سرعت باد در دو دقیقه	۵۱	HW2A11	مؤلفه‌های سرعت باد در راستای باند پروازی
۲۰	WS2A_Mid	متوسط سرعت باد در دو دقیقه	۵۲	P0	فشار لحظه‌ای
۲۱	WS2X_Mid	بیشینه سرعت باد در دو دقیقه	۵۳	QNH	فشار ایستگاه نسبت به سطح دریای آزاد
۲۲	WS10M_Mid	کمینه سرعت باد در ده دقیقه	۵۴	QFF3H	تغییرات سه‌ساعته فشار ایستگاه (هکتوپاسکال)
۲۳	WS10A_Mid	متوسط سرعت باد در ده دقیقه	۵۵	QFFT	مقدار چشمداشتی QFF در سه ساعت آینده
۲۴	WS10X_Mid	بیشینه سرعت باد در ده دقیقه	۵۶	TEMP	دما (برحسب درجه سلسیوس)
۲۵	WDINS_Mid	جهت باد لحظه‌ای	۵۷	RH	رطوبت نسبی (برحسب درصد)
۲۶	WD2M_Mid	کمینه جهت باد در دو دقیقه	۵۸	DEWPOINT	دمای نقطه شبنم (برحسب درجه سلسیوس)
۲۷	WD2A_Mid	متوسط جهت باد در دو دقیقه	۵۹	GUST_SPEED29	سرعت باد جستی
۲۸	WD2X_Mid	بیشینه جهت باد در دو دقیقه	۶۰	GUST_DIR29	جهت باد جستی
۲۹	WD10M_Mid	کمینه جهت باد در ده دقیقه	۶۱	GUST_SPEED_Mid	سرعت باد جستی
۳۰	WD10A_Mid	متوسط جهت باد در ده دقیقه	۶۲	GUST_DIR_Mid	جهت باد جستی
۳۱	WD10X_Mid	بیشینه جهت باد در ده دقیقه	۶۳	GUST_SPEED11	سرعت باد جستی
۳۲	WDVAR_Mid	انحراف جهت باد در ده دقیقه گذشته	۶۴	GUST_DIR11	جهت باد جستی


۴-۱ انتخاب ویژگی با استفاده از روش معیار اطلاعات متقابل

الگوریتم‌های انتخاب ویژگی را می‌توان در حالت‌های مختلف اجرا کرد. در این پژوهش از دو روش مختلف استفاده شده است. ابتدا روش فیلتر با استفاده از معیار اطلاعات متقابل به شکل کمینه افزونگی و بیشینه ارتباط اجرا شده است که در آن، اطلاعات متقابل بین ویژگی‌ها و برجسب‌های کلاس مرتبط با آن با استفاده از فضای ویژگی کوانتیده (quantized) تخمین زده می‌شود. به این منظور، ابتدا ویژگی‌ها در ماتریس $N \times F$ قرار داده شدند که F تعداد ویژگی‌ها و N تعداد نمونه‌گیری‌ها است. البته داده‌های ویژگی به دوازده تراز نیز طبقه‌بندی شدند. جهت‌های باد از ۰ تا ۳۶۰ درجه به هشت دسته

تقسیم و برجسب زده شدند. سرعت‌های باد نیز به هفده دسته با فاصله ۱/۵ متربرثانه تقسیم و سرعت‌های بیش از ۲۴ متربرثانه نیز در یک دسته قرار داده شدند. نتایج این عملیات برای هر سه سنجنده در جدول ۲ و به صورت نموداری نیز در شکل ۲ ارائه شده است. ویژگی‌هایی که وزن بیشتری را به خود اختصاص دادند، بیشترین ارتباط را با کمیت پیش‌بینی‌شونده دارند؛ بنابراین ویژگی‌های انتخابی با استفاده از این روش در باند شماره ۲۹ برای سرعت باد به ترتیب ویژگی‌های شماره ۷، ۴، ۶، ۳ و ۱ و برای جهت باد نیز به ترتیب ویژگی‌های شماره ۱۳، ۱۰، ۹، ۱۲، ۸ و ۱۱ از جدول ۱ برگزیده شدند.

جدول ۲. وزن ویژگی‌های انتخابی در ارتباط با جهت و سرعت باد در معیار اطلاعات متقابل برای هر سه باند.

باند	داده‌های آموزش				داده‌های آزمون				داده‌های اعتبارسنجی				
	سرعت باد		جهت باد		سرعت باد		جهت باد		سرعت باد		جهت باد		
	وزن	ویژگی	وزن	ویژگی	وزن	ویژگی	وزن	ویژگی	وزن	ویژگی	وزن	ویژگی	
شماره ۲۹	۷	۱/۷۵۶۲۵	۱۳	-۰/۹۹۳۰۳	۷	۱/۵۳۳۶۹	۱۳	۱/۰۸۳۶۶	۷	۱/۳۹۷۵۹	۱۳	۱/۴۳۳۲۹	
	۴	۰/۷۸۹۴۴	۱۲	-۰/۸۶۰۰۲	۴	۱/۰۲۲۹۴	۱۰	۰/۹۰۳۳۴	۴	۰/۹۹۱۹۵	۱۰	۱/۲۳۰۹۸	
	۶	۰/۶۶۷۴۹	۱۰	-۰/۸۵۶۰۴	۶	۰/۹۹۳۰۳	۱۲	۰/۹۰۱۲۷	۶	۰/۹۰۶۱۶	۹	۱/۱۴۵۰۷	
	۳	۰/۵۹۵۳	۹	-۰/۸۱۹۹۹	۳	۰/۹۳۹۰۹	۹	۰/۸۷۳۵۷	۳	-۰/۸۵۰۲	۱۱	۱/۰۹۶۳۸	
	۱	۰/۵۳۱۷۷	۸	-۰/۷۴۹۴۷	۱	۰/۸۸۲۷۲	۸	۰/۷۷۹۴۴	۱	-۰/۸۰۲۸۹	۸	۱/۰۹۵۵۱	
	۵۶	۰/۵۰۱۵۵	۱۱	-۰/۷۰۲۸۷	۱۱	۰/۸۵۱۱	۱۱	۰/۷۶۷۲۴	۲	-۰/۷۰۰۹۶	۱۲	۱/۰۸۷۳۹	
	۱۵	۰/۴۳۳۴۶	۱۴	-۰/۶۳۳۲۴	۲	۰/۸۱۶۶۷	۱۴	۰/۷۲۳۷۴	۵	-۰/۶۵۸۸۸	۱۴	۱/۰۰۸۲۲	
	۲	۰/۴۲۹۰۵	۳۰	-۰/۴۶۶۷۷	۵	۰/۷۸۰۹۸	۱۷	۰/۴۵۰۱۲	۱۷	-۰/۶۴۵۲۳	۱۷	-۰/۵۵۱۳	
	۵۰	۰/۴۲۶۸۲	۲۷	-۰/۴۲۲۰۸	۴۱	۰/۵۱۶۵۹	۱۶	۰/۳۶۱۰۴					
	میان	۲۴	۱/۶۳۴۰۸	۳۰	۱/۵۵۹۴۶	۲۴	۱/۲۸۶۰۸	۳۰	۱/۲۰۹۵۹	۲۴	۱/۲۵۰۰۸	۳۰	۱/۶۳۰۹۵
۲۱		۱/۱۷۹۷۵	۲۷	۱/۴۱۲۱۴	۲۱	۱/۰۱۶۵۳	۲۷	۱/۰۸۳۱۱	۲۱	۱/۰۱۶۴۶	۲۷	۱/۴۰۹۴۴	
۲۳		۱/۰۷۷۹۵	۲۶	۱/۳۱۸۲۵	۲۳	۰/۹۱۶۴۶	۲۶	۱/۰۳۳۶۷	۲۳	۰/۹۱۹۱۷	۲۸	۱/۳۱۶۲۶	
۲۰		۱/۰۰۳۵۹	۲۹	۱/۳۰۵۸۷	۲۰	۰/۸۷۲۰۳	۲۹	۱/۰۲۱۸۲	۲۰	۰/۸۶۷۳۹	۲۶	۱/۳۱۴۲۲	
۱۸		۰/۹۴۱۴۸	۲۵	۱/۲۹۶۸۴	۱۸	۰/۸۲۰۳۵	۲۵	۰/۹۶۰۹۱	۱۸	۰/۸۱۸۴۲	۲۹	۱/۲۷۱۸۸	
۱۹		۰/۸۰۴۱۲	۲۸	۱/۲۷۶۳۵	۳۴	۰/۷۳۶۶۲	۲۸	۰/۹۳۹۵۳	۳۴	-۰/۷۴۳۱۶	۳۱	۱/۲۶۱۳۱	
۴۱		۰/۷۲۴۴۸	۳۱	۱/۲۴۷۲۲	۱۹	۰/۶۸۷۲۵	۳۱	۰/۸۹۷۹	۱۹	-۰/۶۹۳۹۹	۲۵	۱/۲۶۰۹۶	
۲۲		۰/۷۲۱۱۶	۲۷	-۰/۸۹۷۹۴	۲۲	۰/۶۳۰۰۴	۲۲	۰/۵۳۵۹۷	۲۲	-۰/۶۴۷۵۳	۳۴	۰/۶۵۴۲۲	
شماره ۱۱		۴۱	۱/۷۲۹۸۹	۴۷	۱/۴۵۵۰۳	۴۷	۱/۸۷۹۵۷	۴۷	۱/۳۹۷۶۴	۴۱	۱/۶۱۵۸۱	۴۷	۱/۷۲۵۲۳
		۳۸	۱/۲۸۴۳۳	۴۴	۱/۲۵۹۰۶	۳۸	۱/۵۲۹۹۲	۴۴	۱/۲۲۴۱۱	۳۸	۱/۳۰۴۷۵	۴۴	۱/۵۲۶۳۰
	۴۰	۱/۱۹۶۰۰	۴۸	۱/۲۱۶۰۲	۴۰	۱/۵۰۹۰۸	۴۳	۱/۱۷۳۲۲	۴۰	۱/۲۴۹۰۹	۴۳	۱/۴۵۳۰۹	
	۳۷	۱/۱۱۵۸۹	۴۶	۱/۲۱۰۵۷	۳۷	۱/۳۹۱۱۸	۴۶	۱/۱۷۰۲۴	۳۷	۱/۱۶۳۱۳	۴۶	۱/۴۱۸۰۷	
	۳۵	۱/۰۶۳۳۰	۴۳	۱/۲۰۳۰۱	۳۵	۱/۳۵۰۵۲	۴۵	۱/۱۱۷۶۸	۳۵	۱/۱۰۶۸۲	۴۵	۱/۴۰۸۷۵	
	۳۶	۰/۹۲۶۲۸	۴۵	۱/۱۶۳۳۰	۳۶	۱/۳۲۲۰۰	۴۲	۱/۱۱۰۵۳	۳۶	۱/۰۲۰۹۴	۴۲	۱/۴۰۱۰۶	
	۵۰	۰/۷۹۸۹۰	۴۲	۱/۱۴۶۹۴	۳۹	۱/۲۱۶۹۶	۴۸	۱/۰۶۴۶۷	۳۹	-۰/۹۸۶۰۲	۴۸	۱/۳۷۸۲۷	
	۳۹	۰/۷۸۸۰۵	۳۰	-۰/۸۱۶۴۷	۴۹	۱/۰۶۷۶۲	۵۰	۰/۶۳۴۲۸	۱۵	-۰/۶۶۳۹۵	۵۱	۰/۷۷۱۵۷	
	۲۴	۰/۷۲۴۲۸	۲۷	-۰/۷۳۶۰۷	۵۲	۱/۰۴۶۴۹	۵۱	۰/۵۳۶۳۲	۳۲	-۰/۶۶۲۸۸	۵۰	۰/۶۴۴۲۳	
	۲۳	۰/۷۰۲۱۹	۲۹	-۰/۷۳۲۴۸	۱۵	۱/۰۳۴۱۷	۳۹	۰/۵۲۵۹۵	۴۹	-۰/۶۶۰۶۴	۱۷	۰/۴۰۸۳	



شکل ۲. ویژگی‌های انتخابی (از جدول شماره ۱) با روش اطلاعات متقابل برای جهت و سرعت باد در هر سه باند.

به صورت پوشش‌دهنده انجام می‌شود، مانند جستجوی پی‌درپی پیشرو (SFS) در گام اول، بهترین ویژگی ارضاکننده تابع معیار را در یک مجموعه خالی قرار می‌دهد و یک گام پیش می‌رود. با افزودن یک ویژگی دیگر به این زیرمجموعه، مجموعه جدید دوباره ارزیابی می‌شود (شعبانی، ۱۳۹۳). ویژگی‌هایی که پیش از این در روش انتخاب شناور انتخاب شده‌اند، می‌توانند در مراحل بعدی حذف شوند و این عمل به طور دینامیکی تا زمانی تکرار می‌شود که تابع معیار ارضا شود.

در این تحقیق، از الگوریتم k نزدیک‌ترین همسایگان k (Nearest Neighbors, k NN) به عنوان قانون طبقه‌بندی در اجرای این روش استفاده شده است. در این الگوریتم


برای سرعت باد در باند میانی، به ترتیب ویژگی‌های شماره ۲۴، ۲۱، ۲۳، ۲۰، ۱۸ و ۱۹ برای جهت باد نیز ویژگی‌های شماره ۳۰، ۲۷، ۲۶، ۲۹، ۲۵، ۲۸ و ۳۱ انتخاب شدند. در باند شماره ۱۱ نیز برای سرعت باد ویژگی‌های شماره ۴۱، ۳۸، ۴۰، ۳۷، ۳۵ و ۳۶ برای جهت باد ویژگی‌های شماره ۴۷، ۴۴، ۴۳، ۴۶، ۴۵، ۴۲ و ۴۸ انتخاب شدند.

۲-۴ انتخاب ویژگی با روش جستجوی پی‌درپی پیشرو شناور

روش جستجوی پی‌درپی پیشرو شناور (Sequential Floating Forward Selection SFFS) که

ویژگی‌های انتخاب شده برای جهت و سرعت باد در هر سه باند در شکل ۳ با علامت ستاره نشان داده شده‌اند. محور عمودی شکل، وزن اختصاص یافته به ویژگی-محور افقی دو ردیف دارد که ردیف اول، شماره ویژگی-های انتخابی (معرفی شده در جدول ۱) و ردیف دوم، شماره دسته‌ای است که طبقه‌بندی کننده به آن ویژگی اختصاص داده است.

برچسب دسته فرض شده برای هر نمونه آزمایشی براساس فاصله اقلیدسی نزدیک‌ترین نمونه است. این الگوریتم مفهومی ساده و اجرایی آسان دارد، اما بازده محاسباتی مسائل آن محدود است. با وجود این، همچنان یک روش طبقه‌بندی قدرتمند است که اگر داده‌های کافی برای آموزش موجود باشد، می‌تواند مرزهای پیچیده غیرخطی تصمیم‌گیری را در فضای ویژگی مدل کند (تئودوریدیس و کورتوروبا، ۲۰۰۳).



شکل ۳. ویژگی‌های انتخاب شده براساس وزن از روش جستجوی بی‌دری پیشرو شناور با طبقه‌بندی کننده kNN. محور عمودی، وزن اختصاص یافته به ویژگی است. در محور افقی، ردیف اول شماره ویژگی‌های انتخابی معرفی شده در جدول ۱ و ردیف دوم، شماره دسته‌ای است که ویژگی به آن اختصاص دارد. ویژگی‌های انتخابی با علامت ستاره نشان داده شده‌اند.

کمینه موضعی، فرایند یادگیری مختل می‌شود و به‌علت قرار گرفتن جواب در قسمت‌های هموار توابع آستانه دچار وقفه می‌شود. مراحل آموزش در این الگوریتم به شرح زیر است:

۱. اختصاص ماتریس وزن تصادفی به هر یک از اتصالات؛
۲. انتخاب بردار ورودی و خروجی متناسب با آن؛
۳. محاسبه خروجی نرون در هر لایه و در نتیجه، محاسبه خروجی نرون‌ها در لایه خروجی؛
۴. به‌هنگام‌سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل (خطای یاد شده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است)؛
۵. ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص‌های تعریف شده مانند جذر میانگین مربعات خطا (MSE)؛
۶. برگشت به قسمت ۳ یا پایان آموزش.

در شبکه‌های پیش‌خور چندلایه‌ای، خروجی هر لایه، ورودی لایه بعدی است که به‌صورت ریاضی با معادله زیر می‌توان آن را نمایش داد (کیلر و همکاران، ۲۰۱۶):

$$y_k(l+1) = F_k(\sum_j W_{jk}(l) y_j(l) + \theta_k(l)) \quad (2)$$

که در آن l معرف شماره لایه، $y_j(l)$ بیانگر زامین ورودی به نرون k ام است ($j = 1, \dots, N$). W_{jk} بیانگر وزنی است که نرون k ام به ورودی زام تخصیص داده است و $\theta_k(l)$ مقدار ثابتی است که به این نرون وارد می‌شود و سوگیری نامیده می‌شود. F_k تابع تحریکی است که نرون k ام بر ورودی‌های خود اعمال می‌کند. اگر شبکه فقط یک لایه مخفی داشته باشد، از تابع سیگموئید استفاده می‌شود و اگر چندین لایه مخفی داشته باشد، در لایه اول از سیگموئید و

در بررسی نمودارهای مربوط به سرعت باد، ویژگی‌های شماره ۳۲ و ۵۲ به ترتیب انحراف جهت باد در ده دقیقه گذشته در باند میانی و فشار لحظه‌ای در هر سه باند انتخاب شدند. ویژگی شماره ۴۹ (انحراف جهت باد در ده دقیقه گذشته در باند ۱۱) در باندهای ۲۹ و میانی انتخاب شد. در باند ۲۹ علاوه بر این ویژگی‌ها، ویژگی شماره ۷ (بیشینه سرعت باد ده دقیقه‌ای در باند ۲۹) نیز انتخاب شده است. در باند میانی ویژگی شماره ۲۴ (بیشینه سرعت باد در ده دقیقه در باند میانی) نیز انتخاب شده است. در باند ۱۱، ویژگی شماره ۴۱ (بیشینه سرعت باد ده دقیقه‌ای در باند ۱۱) انتخاب شده است. در بررسی نمودارهای مربوط به جهت باد، ویژگی مشترکی بین باندها مشاهده نمی‌شود.

۵ شبکه عصبی پرسپترون چندلایه (MLP)

شبکه پرسپترون چندلایه‌ای شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. در این شبکه عصبی تعداد نرون‌های ورودی متناسب با ویژگی‌های مستقل و تعداد نرون‌های خروجی نیز متناسب با ویژگی‌های وابسته است. محاسبه خروجی، لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود. برای آموزش شبکه معمولاً از الگوریتم پس‌انتشار (Back Propagation, BP) استفاده می‌شود. در این الگوریتم، ابتدا لایه‌های خروجی تعدیل می‌شود؛ زیرا برای هر یک از نرون‌های لایه خروجی، مقدار مطلوبی وجود دارد و می‌توان به کمک آنها و قاعده‌های به‌هنگام‌سازی، وزن‌ها را تعدیل کرد. الگوریتم پس‌انتشار خطا، نتایج بسیار خوبی در حل مسائل ارائه داده است، اما در حل برخی از مسائل ضعیف عمل می‌کند که می‌تواند ناشی از طولانی بودن یا مشخص نبودن زمان یادگیری، انتخاب نامناسب ضریب یادگیری یا توزیع تصادفی وزن‌های اولیه باشد. در برخی موارد نیز به دلیل وجود

و در ۱۰۰ دوره آموزشی (اپیک) اعمال شدند. تعداد نرون‌های لایه ورودی نیز به تعداد ویژگی‌های انتخابی است. در اینجا نتایج سرعت باند شماره ۲۹ ارائه شده است. نتایج پیش‌بینی سرعت باد با استفاده از ویژگی‌های انتخابی از روش پیشرو شناور در جدول ۳ (بهترین حالت شبکه با رنگ قرمز مشخص شده است) و شکل ۴ نشان داده شده است. نتایج پیش‌بینی سمت و سرعت باد با استفاده از ویژگی‌های انتخابی از روش اطلاعات متقابل در شکل ۵ ارائه شده است. حساسیت مدل به پارامترهای انتخابی در حالت‌های مختلف اجرا نیز در شکل ۶ نمایش داده شده است.


در لایه‌های بعدی می‌توان از توابع غیرخطی نیز استفاده کرد.

۵-۱ اجرای شبکه عصبی پرسپترون چندلایه


برای اجرای شبکه عصبی، از برنامه‌نویسی در فضای متلب (MATLAB) و برای آموزش شبکه نیز از الگوریتم پس‌انتشار استفاده شده است. بعد از اینکه ویژگی‌های مرتبط با سمت و سرعت باد انتخاب شدند، برای هر باند به‌طور جداگانه ویژگی‌های انتخابی به شبکه در حالت‌های مختلف لایه پنهان (یک و دو لایه‌ای)، نرخ‌های یادگیری مختلف، آستانه‌های آغازین مختلف برای وزن هر نرون

جدول ۳. نتایج خروجی مدل برای پیش‌بینی سرعت باد جستی در حالت‌های مختلف شبکه عصبی MLP با ویژگی‌های انتخابی از روش پیشرو شناور.

ردیف	سرعت باد				ردیف	سرعت باد					
	نرخ یادگیری_آستانه برای شروع وزن‌ها_ نرون‌های هر لایه_تعداد لایه‌های پنهان	RMSE				زمان مصرف محاسبات (ثانیه)	نرخ یادگیری_آستانه برای شروع وزن- ها_نرون‌های هر لایه_ تعداد لایه‌های پنهان	RMSE			زمان مصرف محاسبات (ثانیه)
		آموزش	آزمون	اعتبار سنجی				آموزش	آزمون	اعتبار سنجی	
۱	۰/۰۰۵_۰/۵_۲,۴_۲	۰/۶۸۱۳	۰/۵۵۵۶	۱/۰۹۰۸	۹۰/۲	۱۱	۰/۰۱_۰/۵_۸,۴_۲	۰/۵۹۸۲	۰/۴۷۳۳	۰/۸۹۵۶	۹۳/۲
۲	۰/۰۰۵_۰/۵_۴,۴_۲	۰/۸۰۷۲	۰/۸۷۵۷	۱/۳۰۷۶	۹۲/۷	۱۲	۰/۰۱_۰/۵_۱۲,۴_۲	۰/۶۸۳۶	۰/۴۶۳۱	۰/۹۸۵۷	۹۴/۲
۳	۰/۰۰۵_۰/۵_۸,۴_۲	۰/۷۴۰۷	۰/۵۰۸۶	۱/۱۰۵۳	۹۴/۲	۱۳	۰/۱_۰/۵_۱۲,۴_۲	۰/۴۹۹۵	۰/۳۳۱۷	۰/۴۱۱۷	۹۴/۴
۴	۰/۰۰۵_۰/۱_۱۲,۴_۲	۰/۹۵۱۴	۰/۵۸۰۸	۱/۳۰۱۷	۹۲/۵	۱۴	۰/۱_۰/۵_۸,۴_۲	۰/۴۹۴۵	۰/۲۹۷۷	۰/۳۶۷۲	۹۲/۱
۵	۰/۰۰۵_۰/۱_۱۲,۴_۲	۰/۸۸۱۶	۰/۵۹۹۶	۱/۲۵۷۵	۹۶/۰	۱۵	۰/۱_۰/۵_۴,۴_۲	۰/۴۹۷۲	۰/۲۹۵۶	۰/۳۳۷۴	۹۱/۵
۶	۰/۰۰۵_۰/۵_۱۲,۴_۲	۰/۸۰۴۱	۰/۵۷	۱/۲۲۱۴	۹۴/۰	۱۶	۰/۱_۰/۵_۲,۴_۲	۰/۴۸۵۳	۰/۳۱۶۰	۰/۳۳۲۱	۸۷/۲
۷	۰/۰۰۵_۰/۶_۱۲,۴_۲	۰/۸۸۳۸	۰/۹۷۳۳	۱/۳۲۶۳	۹۲/۷	۱۷	۰/۱_۰/۵_۴_۱	۰/۵۶۰۷	۰/۳۸۸۳	۰/۶۶۵۸	۸۹/۴
۸	۰/۰۱_۰/۵_۱۲,۴_۲	۰/۶۴۳۳	۰/۴۳۰۷	۰/۹۴۳۴	۹۳/۷	۱۸	۰/۰۱_۰/۵_۴_۱	۰/۷۵۴۹	۰/۵۸۹۵	۱/۲۱۸۷	۷۰/۲
۹	۰/۰۱_۰/۵_۲,۴_۲	۰/۵۴۰۱	۱/۲۱۷۱	۱/۳۳۳۵	۸۸/۸	۱۹	۰/۰۰۱_۰/۵_۴_۱	۳/۵۹۵۲	۲/۸۵۹	۵/۱۵۳۲	۷۲/۴
۱۰	۰/۰۱_۰/۵_۴,۴_۲	۰/۴۸۶۶	۰/۳۶۸۱	۰/۷۲۰۷	۹۳/۶						



شکل ۴. نتایج اجرای شبکه عصبی پرسپترون چندلایه برای پیش‌بینی سرعت باد جستی، با ویژگی‌های انتخابی از روش پیشرو شناور و مقادیر مختلف نرخ یادگیری، آستانه برای شروع وزن‌ها، تعداد لایه‌ها و نرون‌های مختلف در هر لایه پنهان به همراه مدت زمان محاسبه برای هر آزمایش.



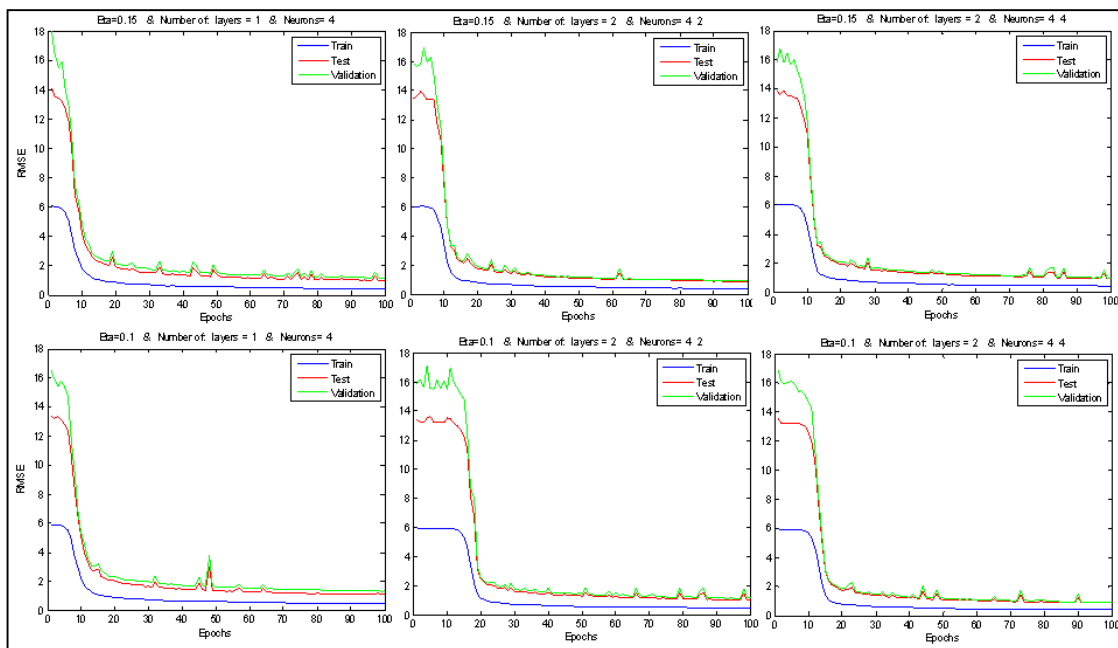
شکل ۵. نتایج اجرای شبکه عصبی پرسپترون چندلایه برای ویژگی‌های انتخابی از روش اطلاعات متقابل با مقادیر مختلف نرخ یادگیری، آستانه برای شروع وزن‌ها، تعداد لایه‌های پنهان و نرون‌های مختلف در هر لایه پنهان به همراه مدت زمان محاسبه برای هر آزمایش.

نمودارهای بخش بالا مربوط به باند ۲۹ است که از اجرای یک شبکه پنهان دو لایه‌ای با ۱۳ نرون در لایه اول و ۱۰ نرون در لایه دوم و یک نرون در لایه خروجی - که در آن همبندی (Topology) یا نحوه اتصال فیزیکی عناصر

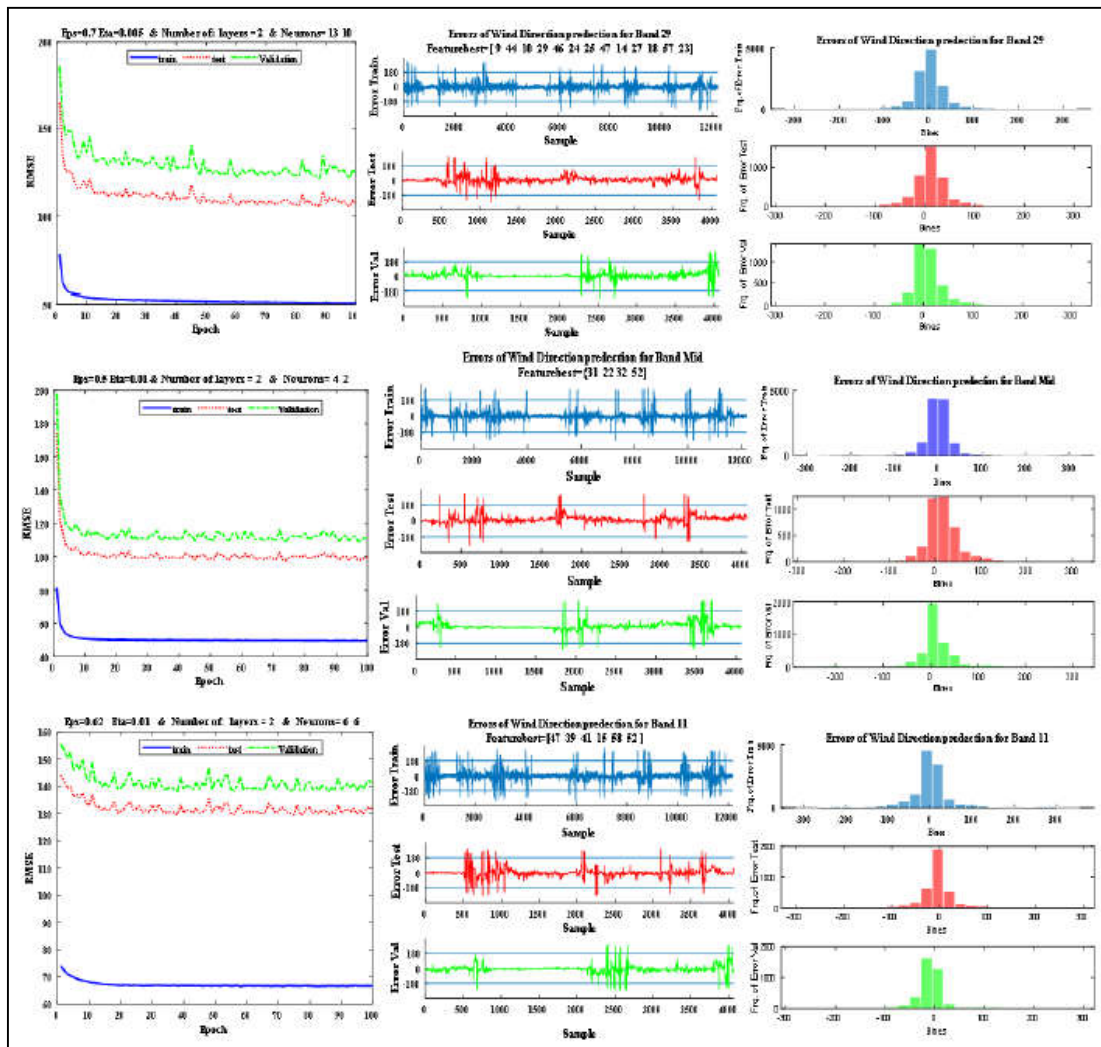
مدل‌های بهینه حاصل از اجرای شبکه عصبی پرسپترون، با ویژگی‌های انتخابی از روش پیشرو شناور و تابع تحریک سیگموئید $(\tanh(z) = \frac{\sinh(z)}{\cosh(z)})$ برای پیش‌بینی جهت باد در هر سه باند در شکل ۷ ارائه شده‌اند. در این شکل،

مشاهده می‌شود، خطاها بیشتر در محدوده ± 10 درجه متمرکز هستند. شکل ۷-ج نیز مربوط به مقدار جذر میانگین مربعات خطا (RMSE) است. در این شکل منحنی آبی‌رنگ مربوط به آموزش مدل است که RMSE به تدریج کاهش می‌یابد و نشان می‌دهد که شبکه به خوبی آموزش می‌بیند. البته شبکه در اپیک ۲۵ به بهترین حالت آموزش خود رسیده است. منحنی‌های قرمز رنگ و سبز رنگ، که مربوط به آزمون و اعتبارسنجی هستند، افت و خیز دارند که ناشی از متخصص شدن (over fitting) مدل در داده‌های آموزش است؛ لذا آزمون و اعتبارسنجی رفتار منظمی ندارند و به طور تصادفی خوب و بد شده‌اند که نشان از برون‌یابی ضعیف مدل دارد، اما اگر از دو نوسان نخست آنها چشم‌پوشی شود، برای باند ۲۹ در اپیک ۱۵، برای باند ۱۱ در اپیک ۱۰ و برای باند میانی در اپیک ۲۰ به بهترین حالت خود رسیده‌اند.

شبکه به یکدیگر به صورت ۱-۱۰-۱۳-۱۳ است - و نرخ یادگیری ۰/۰۰۵ و آستانه آغازین ۰/۷ به دست آمده است. بخش وسط مربوط به باند ۱۱ است که از اجرای شبکه با همبندی ۱-۶-۶ و نرخ یادگیری ۰/۰۱ و آستانه آغازین ۰/۶۲ حاصل شده است. نمودارهای بخش پایین نیز مربوط به باند میانی است که در آن همبندی شبکه ۱-۳-۳، نرخ یادگیری ۰/۰۱ و آستانه آغازین ۰/۶۲ است. در نمودارهای بافت‌نگار مربوط به فراوانی خطاهای پیش‌بینی (شکل ۷-الف) محور افقی، دسته‌ها و محور قائم، تعداد خطاها است. بررسی این نمودارها نشان می‌دهد بیشینه این خطاها در دسته بین ± 25 درجه متمرکز است و چون بازه تغییرات جهت باد بین صفر تا ۳۶۰ درجه متغیر است؛ بنابراین عملکرد شبکه می‌تواند پذیرفتنی باشد. اختلاف بین هدف و مقداری که شبکه برای هدف پیش‌بینی کرده است، در شکل ۷-ب نشان داده شده است. همان‌گونه که



شکل ۶. حساسیت مدل شبکه عصبی پرسپترون به پارامترهای انتخابی (نرخ یادگیری، آستانه برای شروع وزن‌ها، تعداد لایه‌ها و نرون‌های مختلف در هر لایه) در حالت پیش‌بینی سرعت باد با ویژگی‌های انتخابی از روش پیش‌رو شناور.



(ج)

(ب)

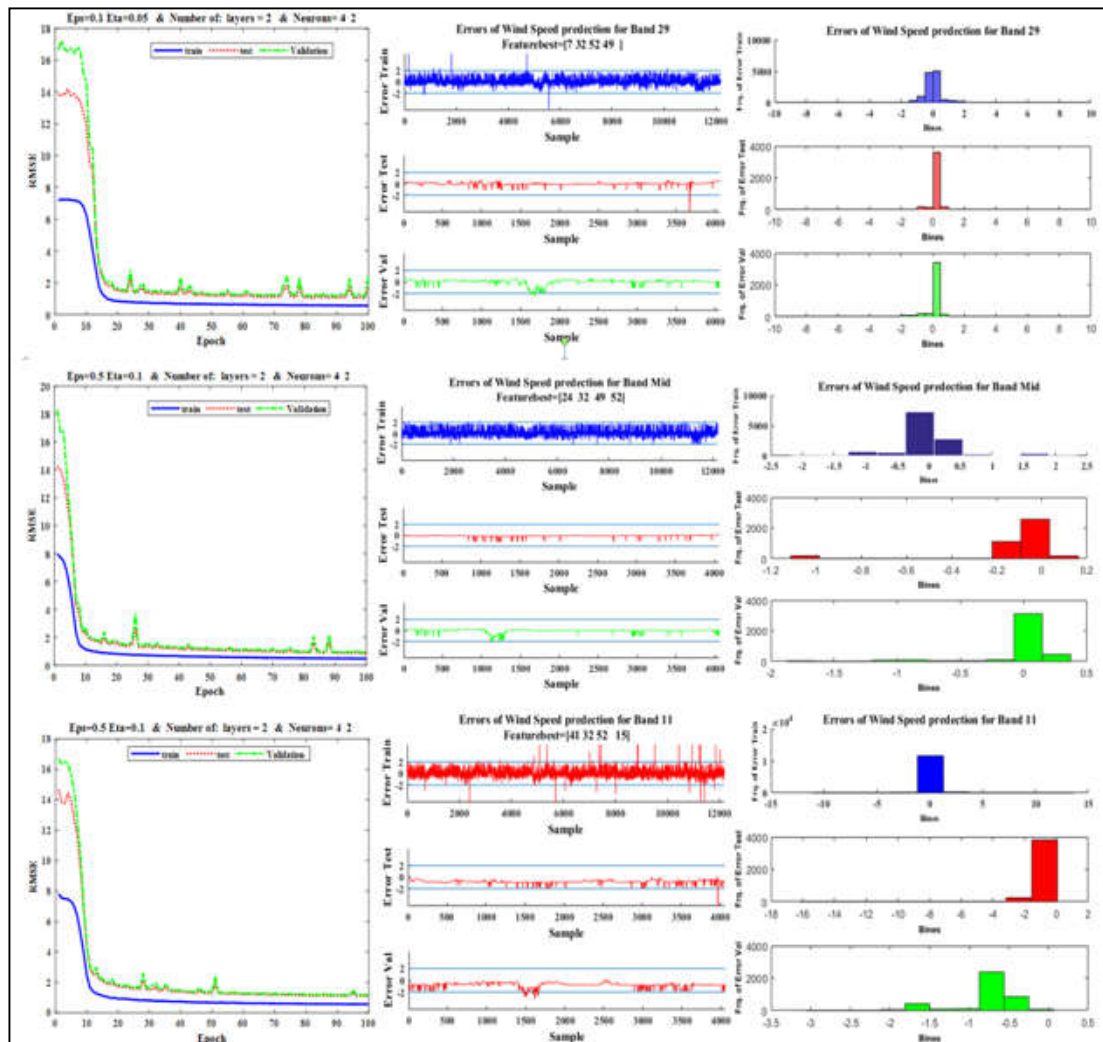
(الف)

شکل ۷. نتایج اجرای شبکه عصبی پرسپترون چندلایه برای پیش‌بینی جهت باد با ویژگی‌های انتخابی از روش پیشرو شناور (الف) بافت‌نگار فراوانی خطاها (ب) خطای پیش‌بینی که همان اختلاف مقدار حاصل از پیش‌بینی با مقدار اندازه‌گیری شده است و (ج) مقدار جذر میانگین مربعات خطا. بخش بالا مربوط به باند ۲۹ است که همبندی شبکه به صورت ۱-۱۳-۱۳، نرخ یادگیری ۰/۰۰۵ و آستانه آغازین ۰/۷ است. بخش وسط مربوط به باند ۱۱ با همبندی شبکه ۶-۶-۶، نرخ یادگیری ۰/۰۱ و آستانه آغازین ۰/۶۲ و بخش پایین نیز مربوط به باند میانی با همبندی شبکه ۳-۳-۳، نرخ یادگیری ۰/۰۱ و آستانه آغازین ۰/۶۲ است.

که در اینجا فاصله دسته‌ها ۰/۵ متربرثانه است.

در شکل‌های ۹ و ۱۰ مدل‌های بهینه حاصل از اجرای شبکه عصبی پرسپترون با ویژگی‌های انتخابی از روش MI برای پیش‌بینی جهت و سرعت باد جستی در هر سه باند ارائه شده است.

پیش‌بینی جهت باد جستی (کمینه، متوسط و بیشینه جهت مدل‌های بهینه حاصل از اجرای شبکه عصبی پرسپترون، با ویژگی‌های انتخابی از روش پیشرو شناور برای پیش‌بینی سرعت باد در هر سه باند در شکل ۸ ارائه شده است. نمودارها همانند شکل ۷ هستند با این تفاوت



(ج)

(ب)

(الف)

شکل ۸ همانند شکل ۷ اما برای پیش‌بینی سرعت باد با ویژگی‌های انتخابی از روش پیش‌رو شناور. نمودارهای بالا مربوط به باند ۲۹، بخش وسط مربوط به باند میانی و بخش پایین نیز مربوط به باند ۱۱ هستند. همبندی شبکه‌های هر سه باند ۱-۲-۴-۵ و نرخ یادگیری ۰/۰۵ و آستانه آغازین ۰/۱ است.

انتخاب شدند. با این روش، ویژگی‌های انتخابی برای باد در دو دقیقه؛ کمینه، متوسط و بیشینه جهت باد در ده دقیقه (جهت باد لحظه‌ای اندازه‌گیری شده در همان باند هستند. بررسی ویژگی‌های انتخابی برای پیش‌بینی سرعت باد جستی با روش پیش‌روی شناور نشان می‌دهد انحراف جهت باد در ده دقیقه گذشته در باند میانی و فشار لحظه‌ای


۶ بحث و نتیجه‌گیری

بررسی ویژگی‌های انتخابی برای پیش‌بینی سرعت باد جستی با روش MI نشان می‌دهد برای هر باند، ویژگی‌های سرعت باد لحظه‌ای یعنی کمینه و متوسط سرعت باد در دو دقیقه، متوسط و بیشینه سرعت باد در ده دقیقه و بیشینه سرعت باد در دو دقیقه (به جز در باند ۲۹) همان باند

تنوع بیشتری برخوردار است؛ برای مثال، در باند ۲۹ که در انتهای شرقی باند قرار دارد، تعداد ویژگی‌ها خیلی بیشتر است و این به لحاظ وجود جریانات غربی حاکم بر ایستگاه، دور از انتظار نیست.

نتایج بررسی خروجی‌های شبکه عصبی پرسپترون چندلایه نشان می‌دهد برای سرعت باد در هر سه باند، عملکرد ورودی‌های انتخابی از روش پیشرو شناور بهتر از ورودی‌های انتخابی از روش MI است. در روش پیشرو

در هر سه باند انتخاب شده‌اند. انحراف جهت باد در ده دقیقه گذشته در باند ۱۱ در باندهای ۲۹ و میانی مشترک هستند. ویژگی چهارم در باندهای ۲۹ و میانی متغیر بیشینه سرعت باد در ده دقیقه مربوط به همان باند است. در باند ۱۱ علاوه بر ویژگی‌های مشترک، متغیرهای بیشینه سرعت باد در ده دقیقه در باند ۱۱ و انحراف جهت باد در ده دقیقه گذشته در باند ۲۹ دیده می‌شوند. بررسی ویژگی‌های انتخابی برای پیش‌بینی جهت باد جستی در هر سه باند از

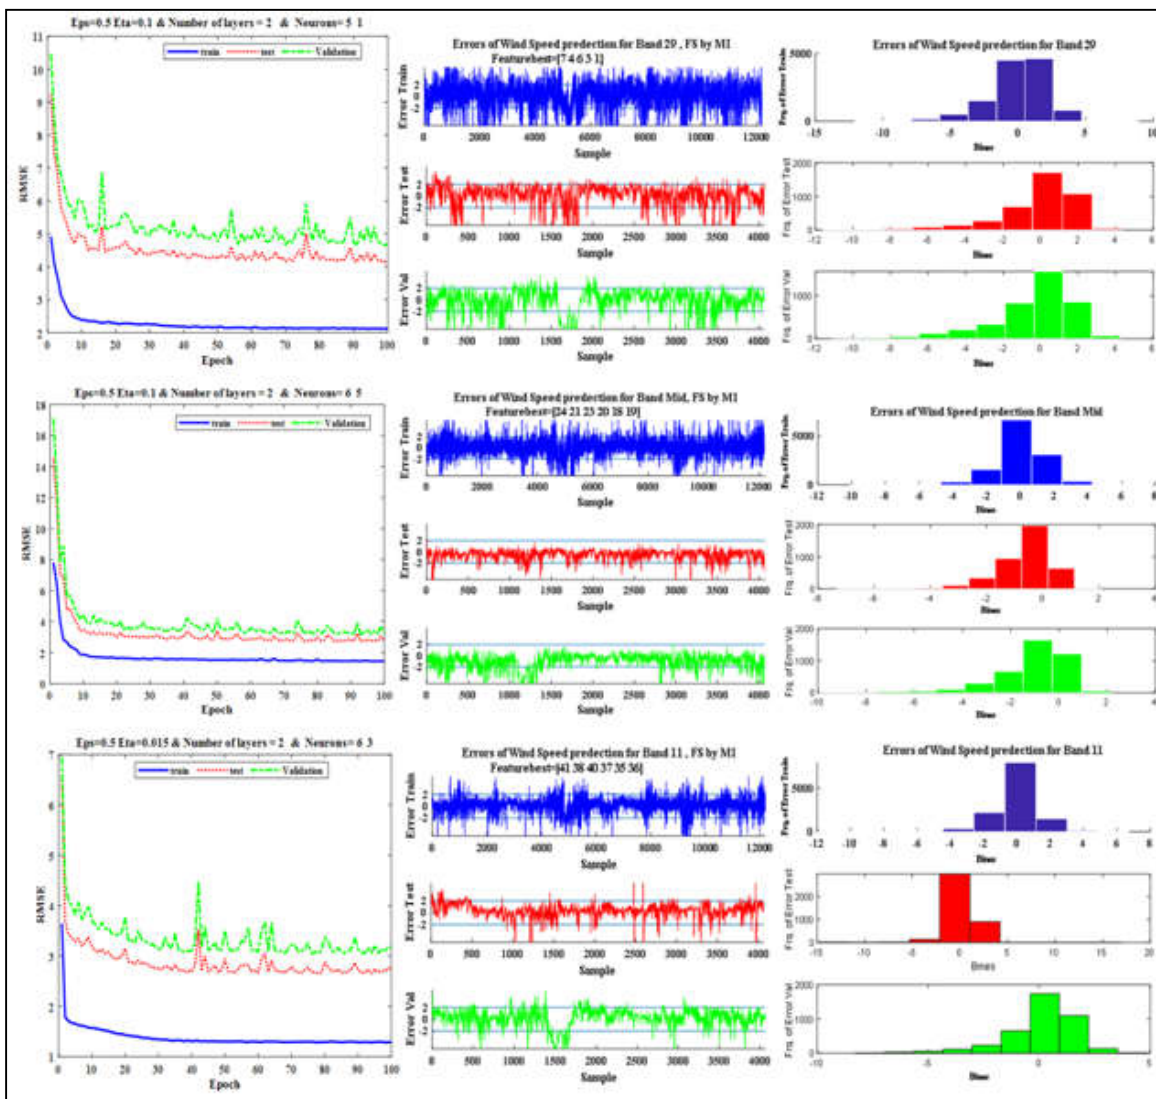


(ج)

(ب)

(الف)

شکل ۹. همانند شکل ۷ اما برای پیش‌بینی جهت باد با ویژگی‌های انتخابی از روش MI. بخش بالا مربوط به باند ۲۹ با همبندی شبکه به صورت ۷-۵-۱، بخش وسط مربوط به باند میانی با همبندی شبکه به صورت ۷-۱-۱ و بخش پایین نیز مربوط به باند ۱۱ با همبندی شبکه ۷-۷-۱ است. نرخ یادگیری (۰/۰۱) و آستانه آغازین (۰/۵) نیز در هر سه یکسان است.



(ج)

(ب)

(الف)

شکل ۱۰. همانند شکل ۷ اما برای پیش‌بینی سرعت باد با ویژگی‌های انتخابی از روش MI. بخش بالا مربوط به باند ۲۹ با همبندی شبکه به صورت ۱-۱-۵، نرخ یادگیری ۰/۱ و آستانه آغازین ۰/۵ است. بخش وسط مربوط به باند میانی با همبندی شبکه به صورت ۱-۵-۶، نرخ یادگیری ۰/۱ و آستانه آغازین ۰/۵ و بخش پایین نیز مربوط به باند ۱۱ با همبندی شبکه ۱-۳-۶، نرخ یادگیری ۰/۰۱۵ و آستانه آغازین ۰/۵ است.

باد با روش پیشرو شناور در دسته ± 25 درجه در هر سه باند قرار دارد ولی در روش MI، این فراوانی در دسته ± 50 درجه قرار دارد. به‌طور کلی، بررسی‌ها نشان می‌دهد که این شبکه، سرعت باد جستی را نسبت به جهت آن با دقت بیشتری پیش‌بینی می‌کند.

شناور، فراوانی خطاها در دسته $\pm 0/5$ متربرثانیه و روش MI، در دسته $\pm 2/0$ متربرثانیه متمرکز است. مقایسه نمودارهای مربوط به پیش‌بینی جهت باد نیز برتری روش پیشرو شناور را در انتخاب ویژگی‌های مناسب نسبت به روش MI نشان می‌دهد. فراوانی خطاهای پیش‌بینی سرعت

منابع

- پیش‌بینی یخبندان در استان کرمانشاه: مطالعات جغرافیایی مناطق خشک، ۱(۳)، ۵۹-۷۱.
- مقصودی، م.، قزوینی، م.، ۱۳۹۷، کاربرد الگوریتم‌های فرا ابتکاری در کاهش ابعاد و انتخاب ویژگی: سومین کنفرانس بین‌المللی ترکیبات، رمزنگاری و محاسبات، دانشگاه علم و صنعت ایران، <http://i4c.iust.ac.ir>
- Chandra Blessie, E., and Karthikeyan, E., 2012, Sigmis: A feature selection algorithm using correlation based method: Journal of Algorithms and Computational Technology, 6(3), 385-394.
- Chandrashekar, G., and Ferat, S., 2014, A survey on feature selection methods: Computers and Electrical Engineering, 40, 16-28.
- Erdil, A., and Arcaklioglu, E., 2013, The prediction of meteorological variables using artificial neural network: Neural Computing and Applications, 22(7-8), 1677-1683.
- Guyon, I. and Elisseeff A., An introduction to variable and feature selection, Journal of Machine Learning Research, 2003, (3), 1157-1182.
- Han Jiawei, J. P., and Kamber, M., 2012, Data Mining: Concepts and Techniques, 3rd edition: Morgan Kaufmann Publishers, ISBN 978-0-12-381479-1.
- Jianyu, M., and Niu, L., 2016, A Survey on Feature Selection: Procedia Computer Science, 91, 919-926.
- Keller, J. M., Liu, D., Fogel, D. B., 2016, Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems and Evolutionary Computation, Wiley, 2016, 1-366
- Kohavi, R., and John, G. H., 1997, Wrappers for feature subset selection: Artificial Intelligence, 97(1-2), 273-324.
- Luca, M., Orione, F., Taormina, R., and Pasero, E., 2010, A feature selection method for air quality forecasting: ICANN (3), 489-494.
- Lutu, P., and Engelbrecht, A. P., 2010, A decision rule-based method for feature selection in predictive data mining: Expert Systems with Applications, 37(1), 602-609.
- Pohjalainen, J., Räsänen, O., and Kadiogluba, S., 2015, Feature selection methods and their combinations in high dimensional classification of speaker likability, intelligibility and personality traits: Computer, Speech and Language, 29(1), 145-171.
- اشرفی، خ.، هشیاری پور، غ. ع.، نجار اعرابی، ب.، کشاورزی شیرازی، ه.، ۱۳۸۸، پیش‌بینی روزانه غلظت کربن‌مونواکسید با استفاده از مدل تلفیقی انتخاب پیشرو عصبی فازی براساس تحلیل پایداری جو: مجله فیزیک زمین و فضا، ۳۸(۲)، ۱۸۳-۲۰۱.
- حبیبی ف.، مزرعه فراهانی، م.، مشیری، ب.، نوحه‌گر، ا.، کلهر، ا.، ۱۳۹۰، اصلاح پیش‌بینی فرایند طوفان حاره‌ای با انتخاب ویژگی‌های مؤثر: مجله ژئوفیزیک ایران، ۵(۳)، ۶۷-۸۲.
- روحی، ا. ر.، نظام‌آبادی پور، ح.، ۱۳۹۶، یک روش انتخاب ویژگی ترکیبی برای داده‌های با بعد بالا مبتنی بر خرد جمعی: نشریه مهندسی برق و مهندسی کامپیوتر ایران، ب-مهندسی کامپیوتر، سال ۱۵(شماره ۴)، ۲۸۳-۲۹۴.
- 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.
- قوامی، ز.، عارفی، ح.، بیگدلی، ب.، جانعلی پور، م.، ۱۳۹۶، بررسی جامع بر روی روش‌های طبقه‌بندی غیرپارامتریک به منظور تفکیک عوارض شهری با استفاده از تلفیق داده‌های لایدار و تصویر هوایی با توان تفکیک مکانی بسیار بالا: نشریه مهندسی فناوری اطلاعات مکانی، ۵(۳)، ۹۷-۷۷.
- شعبانی، ر.، ۱۳۹۳، مروری بر الگوریتم‌های تکاملی برای حل مسئله انتخاب ویژگی: سومین کنفرانس ملی ایده‌های نو در مهندسی برق، ۶ و ۷ دی ماه ۱۳۹۳، دانشگاه آزاد واحد اصفهان (خوراسگان)، ۷۴۹-۷۴۱.
- انتظاری، ع. ر.، حدادنیا، ج.، جعفرزاده، م.، کوروندی، ا.، ۱۳۹۰، ارائه یک شبکه عصبی MLP به منظور

Theodoridis, S., and Koutroumbas, K., 2003, Pattern Recognition, 2nd ed.: Academic Press.
Vergara, J. R., and Pablo, E., 2014, A review of feature selection methods based on mutual

information: Neural Computing and Applications, **24**(1), 175–186, DOI 10.1007/s00521-013-1368-0.

Feature selection and prediction of Gusty wind with multilayer perceptron neural network (MLP) at the airport auto station

Farideh Habibi ^{1*}

¹ Assistant Professor, Space Physics Department, Institute of Geophysics, University of Tehran

(Received: 19 September 2019, Accepted: 04 December 2019)

Summary

In this paper, in the first step, the present weather of METAR reports of the year 2013 in Mehrabad synoptic station was studied and the period with most occurrences of the instability producing the Gusty wind was identified. This period is from January to June of every year. Then, all data of selected period, except the data of Gusty wind direction and speed, were normalized to interval 0.1–0.9. The considered data for training, testing and validation were 60%, 20% and 20%, respectively. The related features of Gusty wind direction and speed were selected from 58 features recorded by 3 sensors located on the runway. The Mehrabad runway direction is from the east to the west with 4000 meters long and 45 meters wide. The sensor No. 29 was on the east end of band, the sensor No. 11 was on the west edge of the band, and location of the mid sensor was on the middle of band which its distance from the band is 600 meters to the north direction.

The feature selection methods in this study are mutual information (MI) with the Maximum-Relevance Minimum-Redundancy criterion (filter type) and Sequential Floating Forward Selection (SFFS) (wrapper type) with the k Nearest Neighbors (kNN) algorithm. Selected features for Gusty wind speed at each band are the maximum and mean wind speed in 2 and 10 minutes, and the momentary wind speed by the MI method. The selected feature by SFFS method is the wind direction deviation in past 10 minutes on band No. 11 and mid band, momentary pressure on mid band and maximum wind speed in 10 minutes on band No. 29. For Gusty wind direction by first method, the selected features are minimum, mean and maximum wind direction in 2 minutes, minimum and mean wind direction in 10 minutes and momentary wind direction on band No. 29. Selected features with second method are the wind direction deviations in past 10 minutes on the band No. 29 and mid band, and the mean sea level pressure and mean wind direction in 10 minutes on band No. 29.

In the final step, these selected features were used as inputs of the multilayer perceptron neural network in different modes such as: layer number, neuron number, learning rate and threshold value for weight of neuron. The model output results were compared to predict the Gusty wind direction and speed and the best model was selected. The results show that to predict the wind speed, the best model is a multilayer perceptron neural network with four layers: input layer with 4 neurons, two hidden layers with 4 neurons in the first layer and 2 neurons in the second layer and 1 neuron in the output layer; learning rate of 0.1 and initial weight neurons of 0.5. For predicting the wind direction, the best model has four layers, 6 neurons in the first and second layers and 3 neurons at the third layer and one neuron at the fourth layer with the same learning rate and initial threshold. The MLP performance is better in predicting the Gusty wind speed.

Keywords: Gusty wind, feature selection, mutual information, sequential floating forward selection, multilayer perceptron neural network, the airport auto station

*Corresponding author:

fhabibi@ut.ac.ir