

پیش بینی دیدافقی با آموزش شبکه پیشخور توسط الگوریتم یادگیری پس انتشار ارتجاعی

فریده حبیبی^{*۱}

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

(تاریخ دریافت: ۱۳۹۶/۰۸/۲۱، تاریخ پذیرش: ۱۳۹۶/۱۱/۰۳)

چکیده

پدیده‌های هواشناسی حاصل سامانه‌های پیچیده‌ای هستند که بخش‌های مختلفی در تماس با هم و محیط اطراف دارند. هدف این تحقیق نمایش کارایی شبکه‌های عصبی در پیش‌بینی متغیرهای هواشناسی است. برای این منظور پیش‌بینی دید افقی که کاربرد فراوان در هواشناسی و هواوردی به‌ویژه در فرودگاه‌ها دارد برای بررسی انتخاب شده‌است. داده‌های این بررسی، تلفیقی از گزارش‌های متار و سینوپ ایستگاه بندرعباس در بازه ۱ تا ۳۰ مارس ۲۰۱۴ است. برای پیاده‌سازی شبکه، ابتدا داده‌های آموزش، آزمون و اعتبارسنجی شبکه به‌صورت تصادفی با نسبت‌های ۷۰، ۱۵ و ۱۵ درصد استخراج و ذخیره شد تا برای مقایسه حالت‌های مختلف اجرای شبکه از داده یکسان استفاده شود. ترکیب‌های مختلف هفت متغیر دما، دمای نقطه‌شبنم، هوای حاضر، فشار، میزان پوشش ابر آسمان، سمت و سرعت باد، به‌عنوان ورودی به شبکه پیش‌خور داده‌شد که خروجی آن دیدافقی است. در مجموع همبستگی و جذر میانگین مربعات خطا برای ۲۸ حالت بررسی شده‌است. نتایج نشان می‌دهند که ترکیب‌های حاوی پدیده هوای حاضر بیشترین همبستگی را با دیدافقی دارند و کمیت‌های دمای نقطه‌شبنم، فشار و میزان پوشش ابر به تنهایی تأثیری روی آن ندارند. بعد از پردازش‌های اولیه، از شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی با هشت نرون و تابع سیگموئید در لایه پنهان، تابع خطی در لایه خروجی برای پیش‌بینی استفاده شد. این شبکه با دو سری داده‌های استاندارد شده بین بازه‌های صفر و یک، ۰/۱ و ۰/۹، نمونه‌های افزایش و کاهش متفاوت برای بایاس‌ها و وزن‌ها، و همچنین نرخ‌های یادگیری متفاوت اجرا شده‌است. مقدارهای مناسب برای این کمیت‌ها به‌ترتیب ۱/۲، ۰/۳۵ و ۰/۰۰۱ هستند و استانداردسازی داده‌ها در حد فاصل بین صفر و یک مناسب نیست. مقادیر ضریب کسر مطلق از واریانس برای داده‌های آموزش، آزمون و اعتبارسنجی به‌ترتیب ۰/۹۹۷۲، ۰/۹۸۵۶ و ۰/۹۸۳۹ به‌دست آمد که نشان می‌دهد نزدیک به ۹۸ درصد مقدار دیدافقی تحت تأثیر این متغیرهای مستقل بوده و مابقی تغییرات آن وابسته به سایر عوامل است.

واژه‌های کلیدی: پیش‌بینی، دید افقی، شبکه پیشخور، نرخ یادگیری، پس‌انتشار ارتجاعی

۱ مقدمه

پدیده‌های هواشناسی حاصل سامانه‌های پیچیده‌ای هستند که دارای بخش‌های مختلف مرتبط با یکدیگر بوده و در ضمن با محیط پیرامون خود نیز در کنش و واکنش می‌باشند. بنابراین پیش‌بینی آنها با استفاده از مدل‌های عددی پیشرفته به دشواری صورت می‌گیرد. برای شناخت این پدیده‌ها از روش‌های تجربی یا آماری نیز کمک گرفته شده است که این روش‌های مورد استفاده در هواشناسی را به چهار دسته می‌توان تقسیم کرد. دسته اول که در سال ۱۸۸۵ توسط گالتون معرفی شده است متکی بر وایازش (رگرسیون) و تحلیل آماری است و در آن رابطه خطی بین یک جفت متغیر (x و y) بررسی می‌شود. زمانی که تعداد متغیرها افزایش می‌یابد استفاده از دسته دوم پیشنهاد می‌شود که در ۱۹۰۱ توسط پیرسن معرفی شده است و معروف به تحلیل مولفه اصلی (principal component analysis=PCA) و یا تابع متعامد تجربی (empirical orthogonal function) است. در این دسته الگوهای همبسته موجود در مجموعه‌ای از متغیرها تعیین می‌شود و از نیمه قرن بیستم به بعد در هواشناسی رونق بیشتری داشته است. دسته سوم ارتباط خطی بین مجموعه‌ای از متغیرها با مجموعه دیگری از متغیرها را بررسی می‌کند و معروف به تحلیل همبستگی بنیادی (the canonical correlation analysis) است که توسط هاتلینگ در ۱۹۳۶ ابداع شده ولی از سال ۱۹۸۷ توسط بارنت و پریندورفر در هواشناسی استفاده شده است. دسته چهارم که شبکه‌های عصبی را در بردارد در واقع شکل تعمیم‌یافته دسته سوم است که از مغز انسان الگوبرداری شده و می‌تواند رابطه غیرخطی موجود بین دو مجموعه متفاوت از متغیرها را بیابد. شبکه‌های عصبی ابتدا توسط مک‌کلوج و پیتز در دهه ۱۹۴۰ با استفاده از توابع حسابی و پردازش منطقی شروع شد. سپس آنها در سال ۱۹۴۹ یک مدل خطی ساده از شبکه‌های عصبی مصنوعی

را مطرح کردند که معروف به مدل مک‌کلو-پیتز است و به‌دنبال آن پرسپترون الگوریتم‌های یادگیری را ارائه کردند.

در دهه ۸۰ بود که با رشد فناوری ریزپردازها دانشمندان توانستند با معرفی شبکه‌های چندلایه و الگوریتم‌های یادگیری با روش پس‌خور، شبکه‌های عصبی بازگشتی خودسازمانده راه حلی برای حل مسائل غیرخطی ارائه دهند و توانایی‌های واقعی شبکه‌های عصبی را به نمایش گذارند.

امروزه شبکه‌های عصبی در مسائل مختلف مانند بازشناسی الگو (Pattern Recognition)، دسته‌بندی (Classification) و مدل‌سازی سامانه‌هایی که ساختار داخلی بسیار پیچیده‌ای دارند مثل سامانه‌های هواشناسی، حمل و نقل، اقتصاد، پزشکی به‌طور گسترده به کار می‌روند.

شبکه‌های عصبی به‌طور جدی از سال ۱۹۹۱ در نوشته‌های هواشناسی وارد شدند و خیلی زود نیز به‌عنوان یک فن استاندارد پذیرفته شدند. امروزه در بسیاری از مراکز پیش‌بینی از آنها در پیش‌بینی دمای کمینه، مه، برآورد بارش از تصاویر ماهواره‌ای، پیش‌بینی ریزش برف و باران از تصاویر رادار هواشناسی، پیش‌بینی آذرخش، پیش‌بینی پیچند (تورنادو)، ردیابی توفند (هاریکن)، تشخیص ابر با حسگرهای زمینی، طبقه‌بندی ابر با سنجش از دور، شناسایی پوشش یخ روی سطح دریا و ردیابی حرکت آن با استفاده از سنجش از دور، پیش‌بینی ال‌نینو استفاده می‌شود. از پیوند شبکه عصبی با منطق فازی نیز در تشخیص جابه‌جایی الگوها، تخریب الگوها و همچنین پیش‌بینی ازون استفاده می‌شود (هانسن، ۱۹۹۷). در اینجا برای نمونه به برخی از کارهای سال‌های اخیر اشاره می‌شود.

عامری و هادی‌پور (۱۳۹۳) با استفاده از شبکه پرسپترون سه‌لایه با آموزش پس‌انتشار، با توابع انتقال

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 و رطوبت نسبی روزانه و دیرش (مدت زمان) تابش آفتابی متوسط را در لایه ورودی ب‌آکار برده و بعد از پیش‌بینی فشار آن را همراه با متغیرهای قبلی به شبکه دوم داده و مقدار تابش خورشیدی را پیش‌بینی کردند. البته آنها در این تحقیق ابتدا داده‌ها را بین صفر و یک بهنجار کرده و با استفاده از تابع سیگموئید لگاریتمی در لایه پنهان و الگوریتم پس‌انتشار، لونیبرگ-مارکوآت (Levenberg-Marquardt(LM)) و الگوریتم یادگیری گرادیان توأم مدرج/مقیاس شده توانستند الگوریتم‌های بهینه برای شبکه اول و دوم را به ترتیب LM با ۷ نرون و ۸ به‌دست آوردند (اردیل و ارکک اوغلی، ۲۰۱۳).

شانک و همکاران (۲۰۰۸) دمای نقطه شبنم یا همان بخار آب موجود در هوا که به آب مایع تبدیل می‌شود و در تخمین شبنم، مه، برف، تبخیر و متغیرهای دیگری هواشناسی مفید است را با استفاده از شبکه عصبی پس‌انتشار با سه لایه توانستند برای یک تا ۱۲ ساعت آینده پیش‌بینی دهند. داده‌های ورودی شبکه شامل رطوبت نسبی، تابش خورشید، دما، سرعت باد و فشار بخار است که از ۴۰ ایستگاه مختلف در طی ۳ سال جمع‌آوری شدند. داده‌های ۲۰ ایستگاه برای آموزش و بقیه برای اعتبارسنجی به کار رفتند. مدل بهینه آنها ۶۰ نرون در لایه پنهان، محدوده اولیه وزن‌های شبکه $\pm 0/15$ و نرخ یادگیری $0/35$ بوده و خطای شبکه برای پیش‌بینی ۱، ۴، ۸ و ۱۲ ساعت آینده به ترتیب $0/55$ ، $1/234$ ، $1/799$ و $1/280$ درجه سلسیوس است.

خطی و تانژانت سیگموئید و استفاده از داده‌های ماهیانه ۱۰ ساله (۱۹۹۱-۲۰۰۰ میلادی) پارامترهای طول و عرض جغرافیایی، ارتفاع جغرافیایی، ماه، دمای میانگین ماهانه، رطوبت نسبی و ساعت آفتابی موجود ۳۹ ایستگاه همدیدی هواشناسی ایران به عنوان ورودی شبکه توانستند تابش خورشیدی کل را در منطقه ایران شبیه‌سازی کرده و خروجی شبکه را با استفاده از نرم‌افزار ArcGIS در رسم نقشه پتانسیل تابش خورشیدی سالیانه ایران استفاده کنند. سازین و ارکک اوغلی (۲۰۰۵) اثر رطوبت نسبی بر پتانسیل تابش خورشیدی را با استفاده از شبکه‌های عصبی مصنوعی بررسی و دریافتند که در پیش‌بینی پتانسیل تابش خورشیدی با استفاده از شبکه‌های عصبی مصنوعی، اثر رطوبت ناچیز است. بیالوبرزوسکی پیش‌بینی رطوبت نسبی را با استفاده از شبکه عصبی مصنوعی در نرم‌افزارهای MATLAB و STATISTICA بررسی کرده است. پیش‌بینی کوتاه‌مدت سرعت باد با استفاده از داده‌های سری زمانی ساعتی و فن شبکه عصبی مصنوعی را کادناز و ریورا (۲۰۰۹) مطالعه کرده‌اند. مدل توسعه‌یافته‌ای برای پیش‌بینی کوتاه‌مدت سرعت باد در مرکز کنترل خدمات برق در اوآچاکا (Oaxaca) برای تامین انرژی استفاده می‌شود که از دقت بسیار خوبی برخوردار است. هوانگ و همکاران برای مدل‌سازی و پیش‌بینی وقوع توفان خاک در شمال غربی چین از میانگین اندازه‌گیری‌های هواشناسی روزانه و وقوع توفان خاک در شبکه عصبی مصنوعی استفاده کردند. رحمان و مهندس (۲۰۰۸) پیش‌بینی برآورد تابش خورشیدی جهانی را با استفاده از مدل شبکه عصبی مصنوعی مورد مطالعه قرار دادند. سانتانام و ساب-حاجینی (۲۰۱۱) با استفاده از شبکه عصبی تابع پایه شعاعی یک سامانه پیش‌بینی کارآمد وضع هوا را مورد بررسی قرار دادند و از نتایج حاصل دریافتند که این شبکه بهتر از شبکه عصبی پس‌انتشار است (اردیل و ارکک اوغلی، ۲۰۱۳).

مدل آنها در ابتدا دارای تعداد ۷ نرون در لایه ورودی، یک نرون در لایه خروجی است ولی تعداد نرون‌های لایه میانی را با آزمون و خطا تعیین کردند. آنها نتیجه گرفتند که مدل وایزش خطی دقت خوبی در برآورد هدایت هیدرولیکی اشباع خاک ندارد ولی یک شبکه بهینه با شش نرون در لایه ورودی، سه نرون در لایه پنهان با تابع هدف تانژانت سیگموئید و یک نرون در لایه خروجی با تابع هدف خطی و با تعداد ۵۰۰ تکرار به خوبی می‌تواند هدایت هیدرولیکی اشباع خاک را با استفاده از ویژگی‌های زودیافت خاک برآورد کند.

یوسفی و پورشرعیاتی (۱۳۹۴) با استفاده از شبکه عصبی پیش‌خور پس‌انتشار خطا توانستند میزان تولید رسوب در حوزه آبخیز لرستان را ارزیابی و برآورد کنند. آنها برای برآورد رسوب، از داده‌های دبی، بارش و رسوب رودخانه‌های کاکارضا، دهنو، چم انجیر استان لرستان به صورت ماهانه استفاده کردند و ۱۳ الگوریتم مختلف آموزشی را روی آنها پیدا و با هم مقایسه و شبکه برازش (fitting) با الگوریتم یادگیری LM را به عنوان بهترین شبکه معرفی کردند.

هدف این تحقیق نمایش کارایی شبکه‌های عصبی در پیش‌بینی متغیرهای هواشناسی با استفاده از یک شبکه عصبی پیش‌خور است. برای این منظور پیش‌بینی دیدافقی که کاربرد فراوان در هواشناسی و هوانوردی به ویژه در فرودگاه‌ها دارد انتخاب شده است. البته پیش‌بینی دقیق آن حتی برای دوره‌های کوتاه مدت تا ۶ ساعت چالش برانگیز است و امروزه در اکثر مدل‌های پیش‌بینی عددی وضع هوا این کمیت به طور ضمنی با استفاده از پیش‌بینی کمیت‌های دیگر مانند محتوای آب ابر، رطوبت نسبی و بارش انجام می‌شود. در دهه‌های اخیر نیز محققین سعی در توسعه روش‌های پیش‌بینی دیدافقی داشتند و بیشتر این تلاش‌ها روی استفاده از روش‌های آماری مثل وایزش آمادی (لجستیکی)، میانگین‌گیری مدل بیزی، توابع احتمالات

لیتا و همکاران (۲۰۱۳) تأثیری که توفان تندری در سوم، یازدهم و پانزدهم مه ۲۰۰۹ روی پارامترهای هواشناسی در کلکته گذاشته بود را با استفاده از شبکه عصبی مصنوعی بررسی کردند. آنها از شش الگوریتم آموزشی گام به گام، تکانه، گرادیان توام، پیشروی سریع، لونبرگ-مارکوات و دلتا بار دلتا (Delta-Bar-Delta) برای پیش‌بینی استفاده کردند. آنها نتایج را با داده‌های دیده‌بانی مقایسه کردند و نشان دادند که در بین الگوریتم‌های انتخابی، لونبرگ-مارکوات در پیش‌بینی یک تا سه ساعت آینده به خوبی توانسته افت و خیز ناگهانی دما و رطوبت نسبی را تشخیص دهد ولی در پیش‌بینی شش تا ۲۴ ساعت آینده از دقت خوبی برخوردار نیست.

امینی (۲۰۰۸) با استفاده از شبکه عصبی پس‌انتشار و داده‌های سنجش از دور زمین برای تصاویر ماهواره از نظر پوشش خشکی و گیاهی طبقه‌بندی ارائه کرده و به این نتیجه رسیده است که در بین الگوریتم‌های مختلف یادگیری، نرخ یادگیری متغیر سریعترین است. ایشان روی داده‌های مورد تحقیق شبکه‌های مختلف را با شرایط یکسان به کار برده و نتیجه گرفته است که شبکه دارای یک لایه مخفی با ۲۰ نرون برای این نوع طبقه بندی مناسب است. طبق نتایج حاصل نرخ یادگیری بهینه برای آموزش الگوریتم نرخ یادگیری متغیر در محدوده ۰/۰۰۶ - ۰/۰۰۱ قرار دارد و این محدوده برای الگوریتم‌های آموزشی که نرخ یادگیری آنها ثابت باشد می‌تواند به کار برده شود.

رضایی ارشد و همکاران (۱۳۹۱) برای پیش‌بینی هدایت هیدرولیکی اشباع خاک‌های استان خوزستان از شبکه عصبی پرسپترون چند لایه (MLP) با الگوریتم آموزشی بیزی (Bayesian) استفاده کردند. بخش شبکه عصبی با نرم‌افزار MATLAB و بخش وایزش آماری چند متغیره خطی به کمک نرم‌افزار SPSS انجام شده است.

کیلومتر را برای نواحی ساحلی و دره ندارند. در نتیجه برای غلبه بر این مشکلات استفاده از میانگین گیری مدل بیزی را که یک روش پس پردازش آماری است را برای تولید تابع چگالی احتمال برای پیش بینی دیدافقی معرفی کردند. مدل بیزی برای استفاده در پیش بینی احتمالاتی وضع هوا به منظور واسنجی سامانه همادی پیش بینی و ایجاد توابع چگالی احتمال پیشگویانه که ترکیبی از توده نقاط گسسته و مولفه های توزیع بتا است، معرفی شد. آنها این توابع را با سه رویکرد توسعه دادند. در اولین رویکرد، هماد با یک الگوریتم انتقالی تولید می شود که در آن غلظت های پیش بینی شده متغیرهای آب و هواشناختی به دید تبدیل می شود. در رویکرد دوم، پیش بینی های دید همادی خام به مدل پیش بینی های رطوبت نسبی و بارش کمی افزوده می شود. در رویکرد سوم نیز اعضای همادی تنها از رطوبت نسبی و بارش تولید می شوند. سپس این روش ها را برای پیش بینی های همادی ۱۲ ساعته از سال ۲۰۰۷ تا ۲۰۰۸ پیاده سازی کرده و نتایج را با مشاهدات ثبت شده در ایستگاه های خودکار سطحی در شمال غربی اقیانوس آرام مقایسه کردند و نتیجه گرفتند که این توابع چگالی احتمال نسبت به همادی خام و اقلیمی واسنجی و دقیق هستند و بخشی از ضعف های پیش بینی های همادی مثل پراکندگی و اختلاف در مقیاس بین پیش بینی ها و مشاهدات را از بین می برد.

۲ داده ها و روش تحقیق

داده های این تحقیق تلفیقی از گزارش های متار و سینوپ مربوط به ایستگاه همدیدی بندرعباس در بازه زمانی ۳۰-۱ ماه مارس ۲۰۱۴ است. این بازه زمانی به این علت انتخاب شد که تغییرات بسیار شدید در میزان دیدافقی به لحاظ وقوع پدیده های هواشناختی مختلف رخ داده است. زمان گزارش ها به ساعت تبدیل شده و به صورت یک سری زمانی در فایل اکسل ذخیره شده اند. این فایل دربرگیرنده

شرطی متمرکز است. از شبکه های عصبی به خصوص پرسپترون چندلایه ای (MLP) نیز بیشتر برای پیش بینی مه در نواحی ساحلی و فرودگاه ها استفاده شده است. برای نمونه می توان به کارهای زیر اشاره کرد.

چادووری و همکاران (۲۰۱۵) معتقدند مقدار دید افقی در طول وقوع مه به طور قابل توجهی کاهش می یابد و علیرغم پیشرفت های حاصل در مدل های پیش بینی عددی وضع هوا هنوز مشکل پیش بینی مه پابرجاست. آنها با استفاده از داده های سطحی سه ایستگاه فرودگاهی هند (دهلی، کلکته و بنگالور) نتیجه گرفتند که خطای MLP در قیاس با شبکه تابع پایه شعاعی، شبکه عصبی وایزش عمومی و یا شبکه عصبی خطی به طور قابل ملاحظه ای کمتر است. آنها برای مدل MLP حالت های مختلف با ورودی های دما، دمای نقطه شبنم، فشار سطحی، رطوبت، سمت و سرعت باد، و خروجی شبکه دیدافقی در طی وقوع مه را بررسی کردند و سه حالت: چهار نرون در لایه ورودی با سه لایه پنهان هر یک با سه نرون و یک خروجی، چهار نرون در لایه ورودی با دو لایه پنهان با لایه اول فقط یک نرون و لایه دوم با دو نرون و یک خروجی، چهار نرون در لایه ورودی با دو لایه پنهان هر یک با دو نرون و یک خروجی را مناسب تشخیص دادند. ولی معتقدند که شبکه آنها به ارتفاع ایستگاه حساس است. جمیلاکی و آدریان (۲۰۱۱) معتقدند که پیش بینی احتمالاتی وقوع مه در مکان های دور از دسترس که فاقد بانک داده مشاهدات قبلی هستند در مدل پیش بینی و پژوهش وضع هوا (WRF) با ۱۰ عضو دارای خطا است و این خطا از سه منبع مجزا یعنی اعمال شرایط اولیه، پارامترسازی فرآیندهای در مقیاس جنب فاصله شبکه ای و در پارامترسازی دید در هنگام تبدیل متغیرهای خروجی مدل پیش بینی عددی وضع هوا به دیدافقی ناشی شده است. همچنین پیش بینی های خام WRF معمولاً مهارت لازم را در پیش بینی مه با دیدافقی ۱/۶ تا ۱۱/۳

جدول ۱ مخابره می‌شوند. وضعیت جوئی که در گزارش سینوپ با استفاده از اعداد ۱ تا ۱۰۰ گزارش می‌شود در گزارش متار با استفاده از حروف اختصاری مطابق جدول ۲ مخابره می‌شوند. دیدافتی بالای ۱۰ کیلومتر در گزارش متار به صورت ۹۹۹۹ متر گزارش می‌شود، ولی در گزارش سینوپ مقدار آن با استفاده از کدهای ۰۰ (برای کمتر از ۱۰۰ متر) تا کد ۸۹ (برای بیش از ۷۰ کیلومتر) مخابره می‌شوند.

با توجه به محتویات گزارش متار برای تلفیق و همسان‌سازی آن با گزارش سینوپ لازم بود که پیش‌پردازش‌هایی روی این داده‌ها اعمال شود. به منظور بالا بردن دقت داده‌ها نیز در ساعت‌هایی که گزارش سینوپ موجود بود آنها جایگزین گزارش‌های متار شده است. داده‌های پوشش ابر و وضعیت جوئی نیز با استفاده از مقادیر متناظر آنها در گزارش‌های سینوپ که

داده‌های سمت وزش باد (DD)، سرعت باد (FF)، دیدافتی (VV)، دما (T)، دمای نقطه شبنم (Td)، هوای حاضر (WW)، فشار (P)، میزان پوشش ابر آسمان (N) و زمان دیدبانی به شکل یک ماتریس [۸×۱۳۱۴] است.

گزارش‌های سینوپ به فاصله‌های زمانی سه ساعته و با استفاده از اعداد در دسته‌های پنج‌رقمی مخابره شده‌اند. گزارش‌های متار با فاصله زمانی ۳۰ دقیقه هستند، البته به استثنای بازه زمانی ساعت‌های ۲۲ تا ۲ بامداد روز بعد که گزارش‌ها به فاصله‌های زمانی یک ساعته مخابره شده‌اند. کمیت‌های هواشناختی دما، دمای شبنم و فشار در گزارش متار به نزدیکترین عدد گرد شده و سپس گزارش می‌شوند ولی در گزارش‌های سینوپ با یک رقم اعشار مخابره می‌شوند. میزان پوشش ابر آسمان در گزارش سینوپ برحسب یک‌هشتم پوشش آسمان گزارش می‌شود ولی در گزارش‌های متار با استفاده از حروف اختصاری مطابق

جدول ۱. کدهای مربوط به پوشش ابر آسمان در گزارش متار.

معنی	مقدار مجموع میزان ابرناکی لایه	قابل گزارش اختصار
صاف	0	SKC (در ایستگاه دستی) یا CLR (در ایستگاه خودکار)
ابر اندک	<1/8 - 2/8	FEW
ابره‌های پراکنده	3/8 - 4/8	SCT
ابره‌های شکسته	5/8 - 7/8	BKN
پوشیده از ابر	8/8	OVC

جدول ۲. بخشی از کدهای مربوط به وضعیت جوئی در گزارش متار و معادل آنها در گزارش سینوپ.

معنی	گزارش اختصاری	کد سینوپ	معنی	گزارش اختصاری	کد سینوپ
-	شدت پدیده سبک		غبار	HZ	05
بدون علامت	متوسط		توفان خاک	DS	07
+	شدت پدیده سنگین		توفان شن	SA	08
باران	-RA	60	تنگ‌مه	BR	10
باران متوسط	RA	62	توفان تندری	TS	17
باران شدید	+RA	65	تندوزه	SQ	18
توفان تندری همراه با باران متوسط	TSRA	91	مه	FG	44
توفان تندری همراه با رگبار باران شدید	+TSSHRA	95	رگبار	SH	80

است که معمولاً به تعداد متغیرهای ورودی انتخاب می‌شود و یک یا چندین لایه در لایه‌های پنهان و یک لایه خروجی است. البته تعداد نرون در لایه خروجی مطابق با تعداد خروجی شبکه است. در این شبکه نرون‌های هر لایه با نرون‌های لایه قبلی خود در ارتباط است ولی این ارتباط لزوماً تحت شرایط یکسان نیست بلکه با وزن‌های متفاوت است. ورودی به این شبکه از لایه‌ای به لایه دیگر عبور می‌کند تا به لایه خروجی برسد و چون هیچگونه پس‌انتشاری در آن رخ نمی‌دهد به شبکه پیشخور شناخته شده است. مهم‌ترین مسئله در طراحی شبکه‌های عصبی مصنوعی تعیین تعداد لایه‌های پنهان و تعداد نرون در آنها است. تعداد نرون‌ها به‌طور مستقیم روی توانایی آموزش و القای شبکه‌های عصبی تاثیر دارد به‌طوری که اگر تعداد کمتر منظور شود هرچند زمان آموزش کوتاه‌تر می‌شود ولی شبکه آموزش کافی ندیده و امکان اینکه با همه حالت‌ها آشنا شود وجود ندارد. ولی اگر این تعداد بزرگ انتخاب شود زمان محاسبات طولانی و به ظرفیت ذخیره‌ای بزرگتر نیاز است ولی در عوض توانایی آموزشی تقویت خواهد شد. هنوز قاعده علمی برای تعیین تعداد لایه‌های پنهان و تعداد نرون‌های آنها وجود ندارد و بیشتر از قانون آزمون و خطا استفاده می‌شود (وانگ و زو، ۲۰۱۳).

توسط سازمان جهانی هواشناسی تعیین شده‌اند جانشانی شد. از آنجا که کمیت‌های اندازه‌گیری شده از مرتبه یکسان نیستند برای افزودن دقت محاسبات و حصول نتایج بهتر از فن استانداردسازی یا بهنجارسازی min-max استفاده شد. مزیت این کار در این است که تمام روابط بین داده‌ها را حفظ کرده و نیاز به معرفی بایاس نیست، استانداردسازی داده‌ها در این فن از رابطه زیر به دست می‌آید.

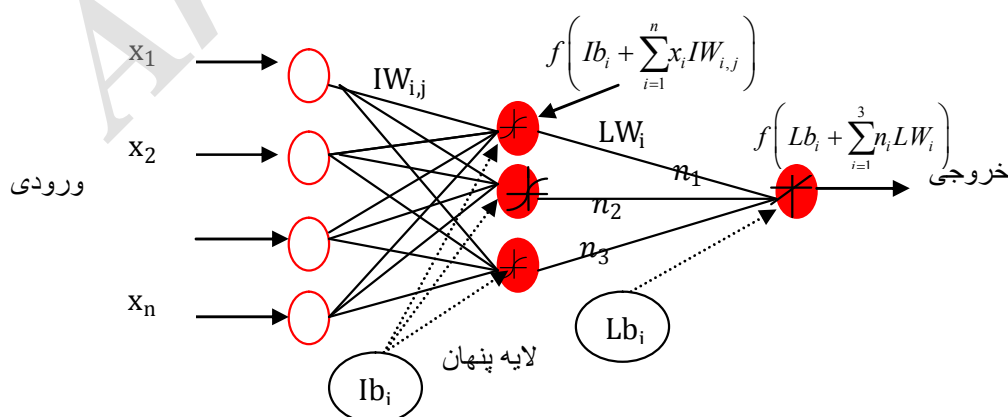
$$x_{i,a \text{ to } b} = a + \frac{(x_i - x_{\text{Min}})(b - a)}{(x_{\text{Max}} - x_{\text{Min}})}, \quad (1)$$

که 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. $x_{i,a \text{ to } b}$ داده نام بهنجار شده در فاصله a تا b است.

برای بررسی حساسیت شبکه به نحوه استانداردسازی داده‌ها، این کار در دو بازه صفر و یک و $0/9-0/1$ انجام و نتایج با هم مقایسه شد.

۳ شبکه عصبی پیشخور

شبکه عصبی پیشخور که در شکل ۱ طرحواره‌ای از آن ارائه شده است، شامل یک سری نرون در لایه ورودی



شکل ۱. شبکه عصبی پیشخور ساده با سه لایه ورودی، پنهان و خروجی؛ $IW_{i,j}$ وزن‌ها و Ib_i بایاس در لایه ورودی؛ $LW_{i,j}$ وزن‌ها و Lb_i بایاس در لایه پنهان؛ توابع تحریک نیز در داخل نرون با نماد؛ عملیات ریاضی لایه‌های پنهان در داخل کمانک نشان داده شده است.

خیلی کوچک نیز به زیاد شدن زمان همگرایی منجر می‌شود. $\frac{\partial E(x)}{\partial b_i}$ و $\frac{\partial E(x)}{\partial W_1}$ مشتقات جزئی هستند.

۴ معیارهای ارزیابی

هدف هر الگوریتم آموزش به حداقل رساندن سطح خطای کل است که با یکی از معیارهای زیر سنجیده می‌شود. مقدار ریشه میانگین مربعات (RMS) که بیانگر میزان انحراف پیش‌بینی از مشاهده واقعی است. میانگین در صد خطای مطلق (mean absolute percentage error یا (MAPE)) (mean absolute percentage deviation) (MAPD)) که در آن مقادیر منفی و مثبت به ترتیب حاکی از بیش‌برآورد و کم‌برآورد مقادیر توسط مدل هستند. شرط استفاده از این روش این است که هیچ داده واقعی صفر نباشد چون در مخرج کسر قرار گرفته و حاصل مبهم خواهد شد (مکریداکیز، ۱۹۹۳). کسر مطلق از واریانس = Absolute Fraction of Variance (R^2) بخش واریانس متغیر وابسته که از متغیرهای مستقل قابل پیش‌بینی است. (R^2) نیز میزان انحراف داده‌های خروجی شبکه از داده‌های هدف را نشان می‌دهد که هر چه به عدد یک نزدیک باشد خطا کمتر است.

$$RMSE = \left((1/n) \sum_{i=1}^n |t_i - o_i|^2 \right)^{1/2}, \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (t_i - o_i)^2}{\sum_{i=1}^n (t_i - \bar{t})^2}; \quad \bar{t} = \frac{1}{n} \sum_{i=1}^n t_i, \quad (4)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left(\frac{t_i - o_i}{t_i} \right), \quad (5)$$


که t_i مقدار واقعی، o_i مقدار پیش‌بینی و n تعداد نمونه‌ها است.

پس‌انتشار ارتجاعی در شبکه‌های عصبی مصنوعی پیشخور یک نوع روش یادگیری اکتشافی تحت نظارت است که توسط مارتین رایدمیلر (Riedmiller Martin) و هاینریش براون (Heinrich Braun) در سال ۱۹۹۲ ایجاد شد. در این روش برای به حداقل رساندن تابع خطای کل در زمان به‌روز رسانی وزن‌ها فقط به علامت مشتق جزئی (و نه اندازه آن) در تمام الگوها توجه می‌کنند. روش کار به این صورت است که اگر علامت مشتق جزئی در دو تکرار متوالی تغییر نکند بایاس و وزن‌ها افزایش می‌یابد یعنی آنها در ضریبی که در برنامه تعیین شده ضرب می‌شوند ولی اگر علامت تغییر کرده باشد باید وزن‌ها کاهش یابند یعنی در ضریب دیگری ضرب می‌شوند و اگر چنانچه مشتق جزئی صفر باشد به‌روز رسانی وزن‌ها و بایاس انجام نمی‌شود. مقدار تجربی برای ضریب افزایش و ضریب کاهش وزن‌ها به ترتیب $1/2$ و $1/5$ هستند. در این روش نمو وزن‌ها ($\bar{W}_1 = \overline{W_{1+1}}$) و بایاس‌ها ($\Delta b = b_{i+1} + b_i$) از قانون دلتا محاسبه می‌شوند که حالت خاصی از پس‌انتشار برای پرسپترون تک‌لایه‌ای است که از قانون زنجیره‌ای برای مشتقات جزئی به صورت زیر استفاده می‌شود.


$$\overline{W_{1+1}} = \bar{W}_1 \propto \frac{\partial E(x)}{\partial W_1}, \quad (2)$$

$$b_{i+1} = b_i \propto \frac{\partial E(x)}{\partial b_i},$$

که b_i و \bar{W}_1 مقدارهای وزن و بایاس در i امین تکرار گردیدان نزولی هستند. \propto نرخ یادگیری است که اندازه گام نزول گردیدان که در هر تکرار رخ می‌دهد را کنترل می‌کند و معمولاً کوچک ($0/01$) انتخاب می‌شود چون مقدار خیلی بزرگ آن منجر به عدم همگرایی و مقدار

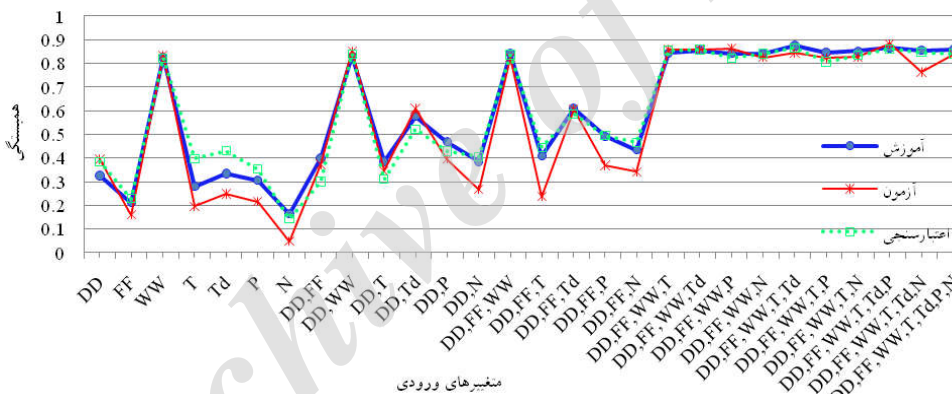


(الف)




(ب)

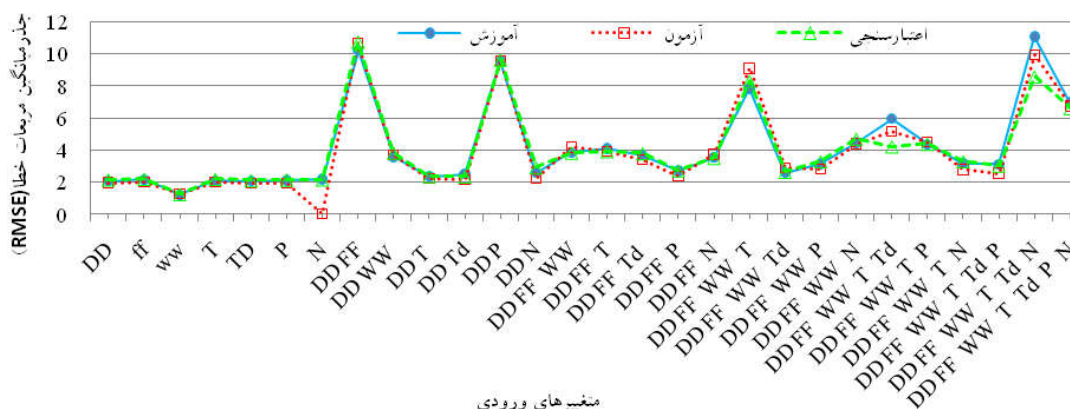
شکل ۲. مقدارهای همبستگی و ریشه میانگین مربعات خطا برای حالت تعداد نرون های مختلف در لایه پنهان.



شکل ۳. مقدارهای همبستگی برای متغیرهای ورودی مختلف.



شکل ۴. میانگین درصد خطای مطلق برای ورودی های مختلف در شبکه پیشخور با هشت نرون در لایه پنهان.



شکل ۵. ریشه میانگین مربعات خطا برای ورودی‌های مختلف در شبکه پیشخور با هشت نرون در لایه پنهان.

۵ پیاده‌سازی شبکه عصبی


ابتدا یک شبکه عصبی پیشخور ساده با سه لایه ورودی، پنهان و خروجی در نظر گرفته شد. برای مقایسه حالت‌های مختلف اجرا لازم است که ورودی‌ها و خروجی‌های شبکه در تمامی حالت‌ها یکسان باشد بنابراین داده‌های لازم برای آموزش (۷۰٪)، آزمون (۱۵٪) و اعتبارسنجی (۱۵٪) به صورت تصادفی از بین کل داده‌ها تعیین و در فایل جداگانه‌ای ذخیره شدند. برای اینکه شبکه روابط خطی و غیرخطی بین ورودی و خروجی را یاد بگیرد از تابع سیگموئید در لایه پنهان و از تابع خطی نیز در لایه خروجی استفاده شد تا خروجی محدود به بازه بین ۱ و -۱ نباشد. سپس شبکه تحت این شرایط برای تعداد نرون‌های مختلف در لایه پنهان اجرا و مقادیرهای همبستگی و ریشه میانگین مربعات خطا (شکل‌های ۲-الف و ۲-ب) محاسبه شده است. شبکه‌ای که هشت نرون در لایه پنهان دارد کمینه خطا و بیشینه همبستگی را نشان می‌دهد.

شبکه انتخابی در مرحله بعد در معرض ورودی‌های مختلف قرار گرفت تا میزان کارایی شبکه در پیش‌بینی دیدافقی مشخص شود. برای این منظور ترکیب هفت متغیر موجود (جهت باد (DD)، سرعت باد (FF)، دما (T)، دمای نقطه شبنم (Td)، هوای حاضر (WW)، فشار (P) و میزان پوشش ابر آسمان (N)) انتخاب شد که در کل ۲۸ حالت را

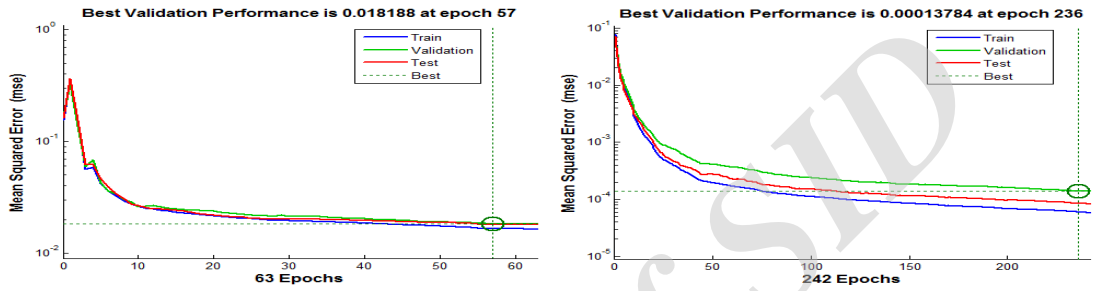
در بر گرفته است. نتایج این بررسی برای همبستگی بین متغیرها در شکل ۳ دیده می‌شود. بیشترین همبستگی‌ها زمانی است که پدیده‌های هوای حاضر در ترکیب متغیرها دیده می‌شود.

برای ارزیابی نتایج مدل از معیارهای میانگین در صد خطای مطلق (شکل ۴)، ریشه میانگین مربعات (شکل ۵) و ضریب همبستگی نیز استفاده شد. بررسی شکل‌های ۴ و ۵ نشان می‌دهد بجز حالتی که ورودی فشار همراه با جهت باد است در بقیه حالت‌ها مدل مقدار دیدافقی را بیشتر پیش‌بینی کرده است و کمینه خطای مدل زمانی است که پدیده‌های هوای حاضر به عنوان ورودی شبکه انتخاب شدند.


در مرحله بعد مدل شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی با استفاده از دو حالت استانداردسازی داده‌ها که بین بازه‌های صفر - یک و ۰/۹ - ۰/۱ انجام و با نرخ‌های یادگیری متفاوت نیز اجرا شد که در اینجا به طور نمونه ۰/۰۰۰۱ و ۰/۰۵ در شکل‌های ۶ و ۷ ارائه شده است. نمودارهای ارائه شده در سمت راست این دو شکل مربوط به حالت استانداردسازی داده‌ها بین بازه ۰/۱ و ۰/۹ و نمودارهای سمت چپ برای حالت استانداردسازی بین بازه صفر و یک هستند. مقایسه بخش-های مختلف این دو شکل نشان می‌دهد که در بخش



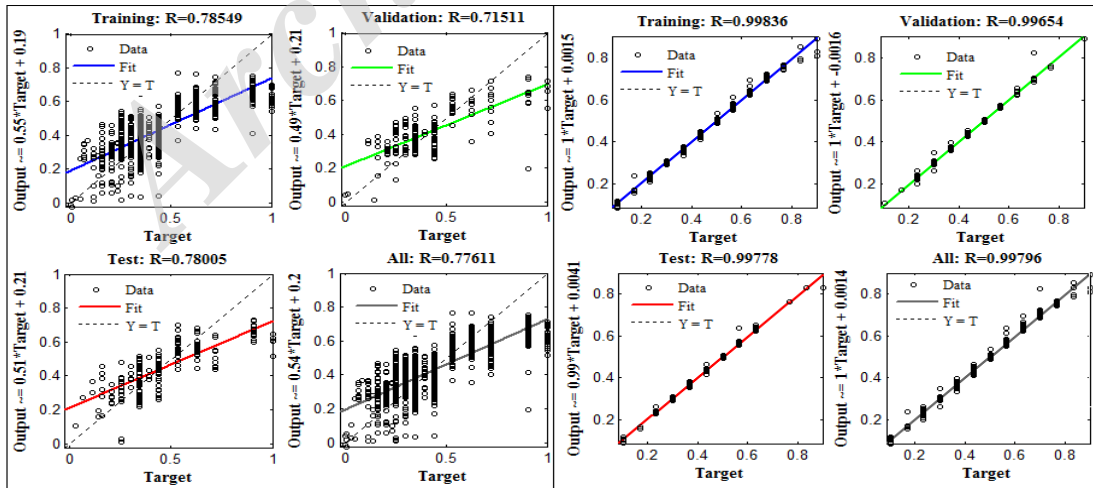
(الف)



(ب)




(ج)

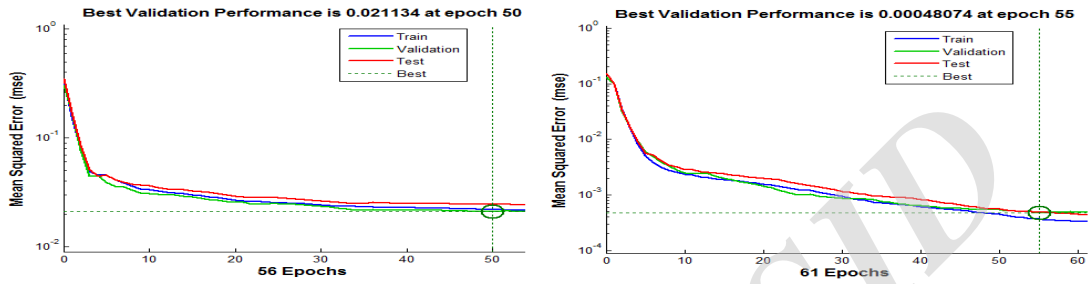


(د)

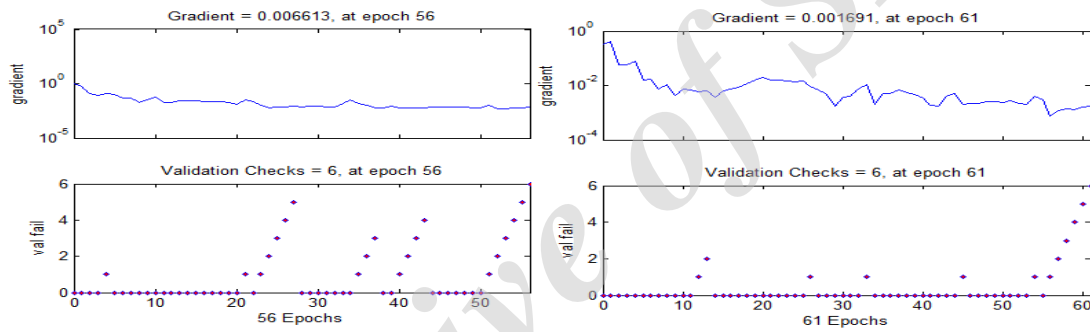
شکل ۶. نتایج حاصل از مدل شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی با نرخ یادگیری ۰/۰۰۰۱، نمودارهای سمت راست برای حالت استانداردسازی داده‌ها بین بازه ۰/۱ و ۰/۹ و نمودارهای سمت چپ برای حالت استانداردسازی بین بازه صفر و یک است.



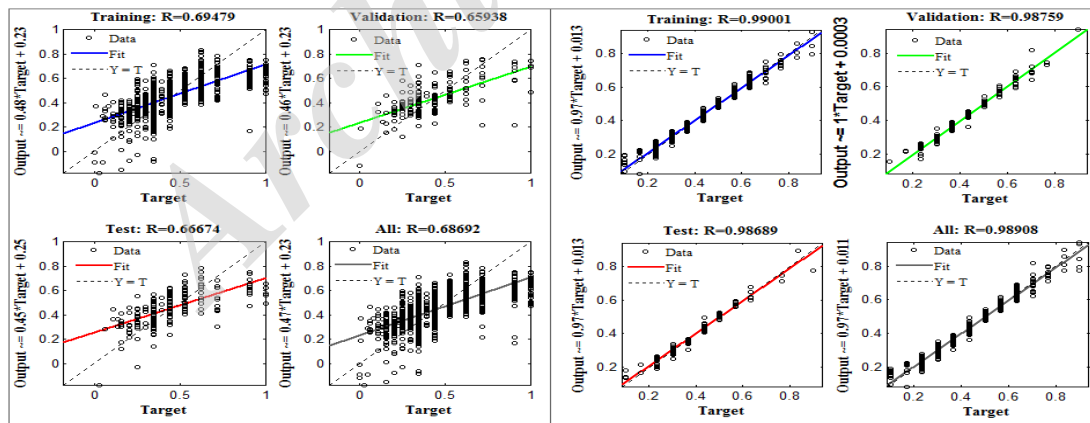
(الف)



(ب)



(ج)



(د)



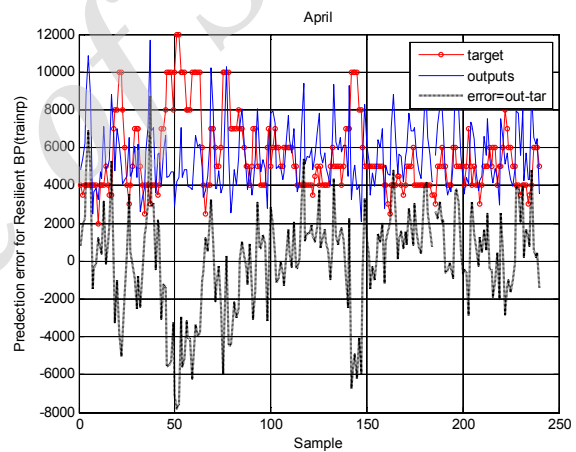



شکل ۷. نتایج حاصل از مدل شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی با نرخ یادگیری ۰/۰۵. نمودارهای سمت راست برای حالت استانداردسازی داده‌ها بین بازه ۰/۱ و ۰/۹ و نمودارهای سمت چپ برای حالت استانداردسازی بین بازه صفر و یک است.

راست تقریباً یک‌دهم میزان سمت چپ است. در بخش (ب) شکل‌ها که مربوط به یادگیری شبکه هستند در

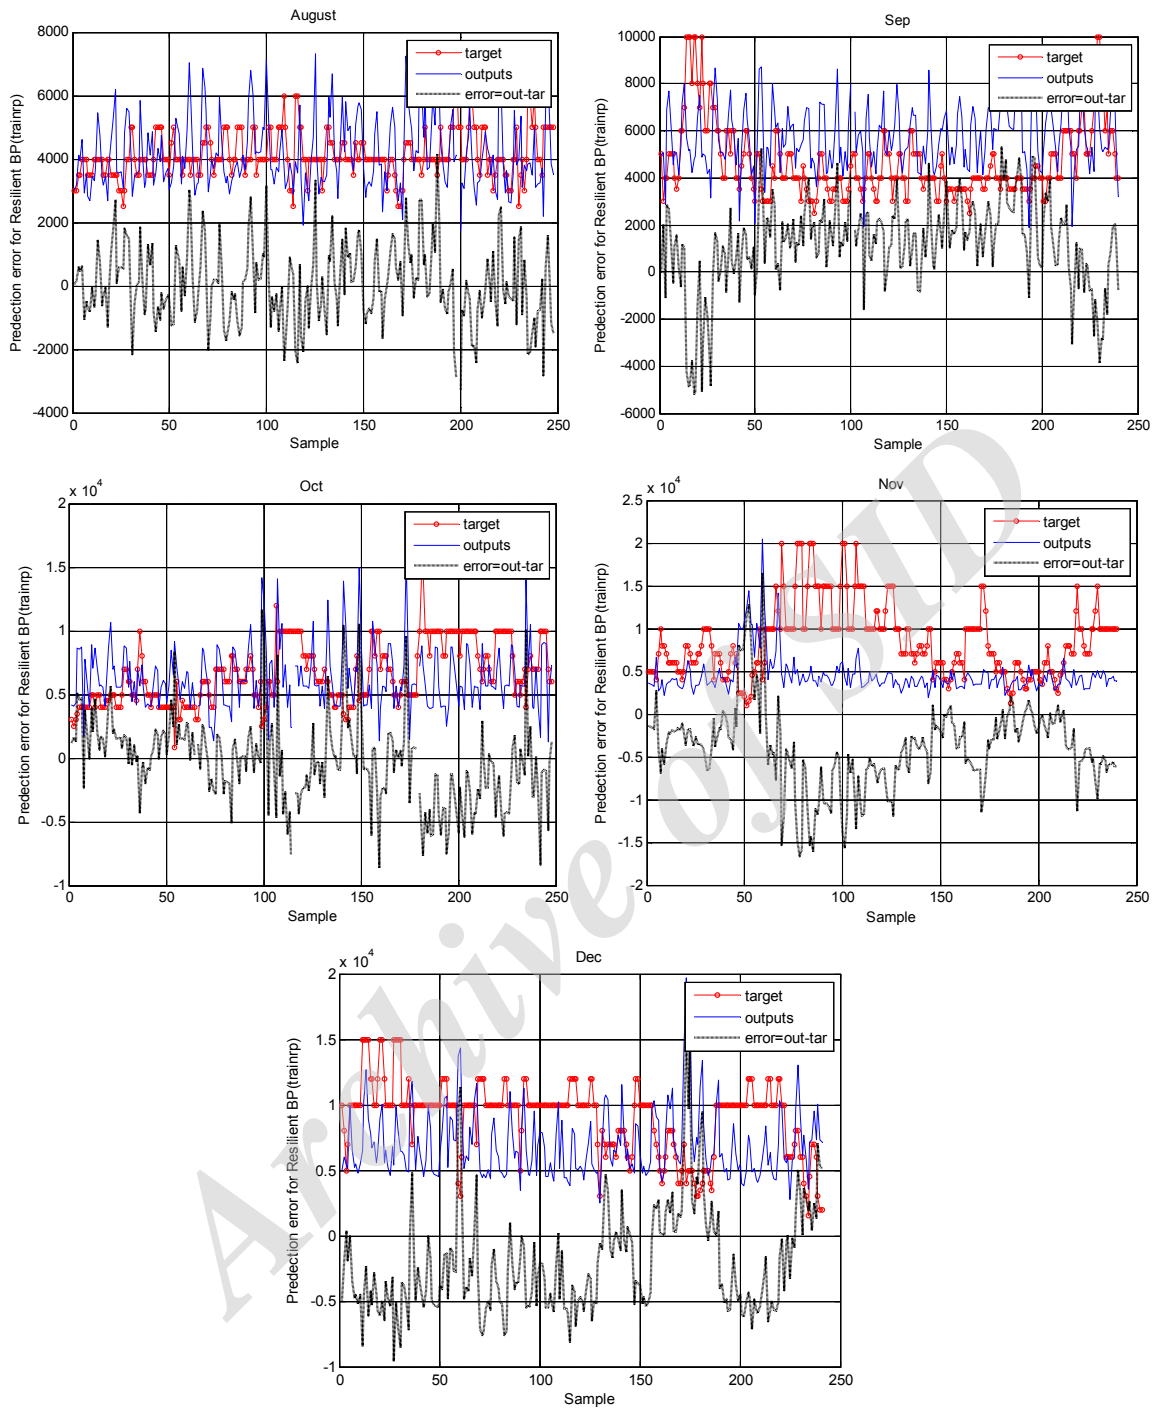
(الف) شکل که میزان خطای پیش‌بینی دیدافقی توسط شبکه ارائه شده است در هر دو شکل میزان خطا در سمت

به‌خوبی آموزش دیده است که در قیاس با سمت راست از حالت خوب برخوردار نیست. در بخش (ج) میزان گرادیان و روند شکست آموزش شبکه را نشان می‌دهد.

نمودار سمت راست شکل ۶، شبکه تا تکرار آموزشی ۲۳۶ به‌خوبی آموزش دیده در حالی که در سمت چپ در ابتدا مقدار MSE افزایش و سپس تا تکرار آموزشی ۵۶



شکل ۸ نتایج حاصل از آزمایش شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی بر روی داده‌های سینوپ ایسنگاه بندرعباس در دیگر ماه‌های سال ۲۰۱۴؛ در این نمودارها رنگ آبی مربوط به خروجی شبکه، قرمز با نماد دایره نشان‌دهنده مقادیر واقعی دید افقی (هدف) و خط چین مشکی نشان‌دهنده مقدار خطا در پیش‌بینی است.



ادامه شکل ۸

از شبکه دیده می‌شود. در هر دو شکل نمودارهای سمت چپ مناسب نیستند، ولی میزان همبستگی در سمت راست بالای ۹۸ درصد است.

اگر شش شکست متوالی رخ دهد و یا گرادیان به حد مقدار تعیین شده برسد، آموزش شبکه متوقف می‌شود. در قسمت (د) شکل نیز خط وایزش و همبستگی‌های حاصل

تحت تاثیر این متغیرهای مستقل بوده و مابقی تغییرات آن وابسته به سایر عوامل است.

مقادیر میانگین درصد خطای مطلق برای داده‌های آموزش، آزمون و اعتبارسنجی برای شبکه با ۸ نرون در لایه پنهان به ترتیب ۰/۰۴۲۲، ۰/۱۸۱۹ و ۰/۱۸۳۰ شدند. این وضعیت نشان می‌دهد که مقادیر پیش‌بینی دیدافقی توسط شبکه در کل به این میزان درصد کمتر از مشاهدات به‌دست آمده است.

در کل مدلی برای برآورد دیدافقی مناسب‌تر است که از میزان ضریب همبستگی بالاتر، میانگین مربعات خطا و میانگین قدر مطلق کوچکتر برخوردار باشد.

اعمال شبکه آموزش داده بر روی داده‌های سینوپ ماه‌های دیگر ایستگاه بندرعباس نشان می‌دهد که شبکه با این آموزش کم‌قادر به پیش‌بینی مقدار دیدافقی در ماه‌های آوریل، مه، ژوئیه، اوت و سپتامبر با خطایی در بازه ± 2000 متر است. البته مقدار خطا برای ماه اوت از این مقدار هم کمتر است.

منابع

رضایی ارشد، ر.، صیاد، غ.، مظلوم، م.، شرفا، م.، و جعفرنژادی، ع.، ۱۳۹۱، مقایسه روش‌های شبکه عصبی مصنوعی و رگرسیونی برای پیش‌بینی هدایت هیدرولیکی اشباع خاک‌های استان خوزستان: مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۶۰، ۱۱۸-۱۰۷.

یوسفی، م. و پورشرعیاتی، ر.، ۱۳۹۳، برآورد رسوب معلق با استفاده از شبکه عصبی و ارزیابی توابع آموزشی (مطالعه موردی: استان لرستان): پژوهشنامه مدیریت حوزه آبخیز، ۱۰، ۹۷-۸۵.

عامری، م. و هادی پور، م.، پاییز ۱۳۹۳، ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تابش

نتایج شبکه آموزش‌دیده با داده‌های استانداردسازی شده بین بازه‌های ۰/۱-۰/۹ با نرخ یادگیری ۰/۰۰۰۱ بر روی داده‌های سینوپ ماه‌های دیگر ۲۰۱۴ همان ایستگاه آزمایش و نتایج در شکل ۸ ارائه شده است. در این شکل نمودارهای به رنگ آبی مربوط به خروجی شبکه، قرمز با نماد دایره نشان‌دهنده مقادیر واقعی دیدافقی (هدف) و خط چین مشکی نشان‌دهنده مقدار خطا در پیش‌بینی است. بررسی این شکل نشان می‌دهد که شبکه توانسته است مقدار دیدافقی در ماه‌های آوریل، مه، ژوئیه، اوت و سپتامبر را با خطای کمتری نسبت به ماه‌های دیگر پیش‌بینی کند. این خطا در بازه ± 2000 متر است و در بین این ماه‌ها نیز بهترین حالت را ماه اوت دارد که بیشترین تمرکز حول صفر است.

۶ نتیجه‌گیری

نتایج این پژوهش نشان می‌دهد که کمیت‌های دما، نقطه شبنم، فشار و میزان پوشش ابر آسمان برخلاف پدیده هوای حاضر به تنهایی تاثیر چندانی بر دیدافقی ندارند. در تمام ترکیب‌هایی که پدیده هوای حاضر وجود داشته تاثیر آنها بر میزان دیدافقی افزایش یافته است. در ارتباط با نحوه استانداردسازی داده‌ها نیز نتایج حاصل از مدل شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی به‌وضوح نشان می‌دهد که استانداردسازی بین بازه ۰/۱ و ۰/۹ به‌مراتب بهتر است. اما در بررسی تاثیر نرخ یادگیری در میزان خطای شبکه در پیش‌بینی دیدافقی نتایج نشان می‌دهند که نرخ یادگیری کوچکتر از دقت بیشتری برخوردار است.

زمانی که همه متغیرها به‌عنوان ورودی به شبکه داده شد مقادیر ضریب کسر مطلق از واریانس برای داده‌های آموزش، آزمون و اعتبارسنجی برای شبکه با ۸ نرون در لایه پنهان به ترتیب ۰/۹۹۷۲، ۰/۹۸۵۶ و ۰/۹۸۳۹ به‌دست آمد که نشان می‌دهد نزدیک به ۹۸ درصد مقدار دیدافقی

- for Neural Networks Course at the Technical University of Nova Scotia.
- Hotelling, H., 1936, Relations between two sets of variates: *Biometrika*, **28**, 321–377.
- Litta, A. J., Idicula, S. M., and Mohanty, U. C., 2013, Artificial neural network model in prediction of meteorological parameters during premonsoon thunderstorms: *International Journal of Atmospheric Sciences*, **2013**, Article ID 525383, 14 pp, <http://dx.doi.org/10.1155/2013/525383>
- Makridakis, S., 1993, Accuracy measures: Theoretical and practical concerns: *International Journal of Forecasting*, **9**(4), 527-529.
- Pearson, K., 1901, On lines and planes of closest fit to system of points in space: *Philosophical Magazine*, **6**(2), 559–572.
- Rehman, S., Mohandes, M., 2008, Artificial neural network estimation of global solar radiation using air temperature and relative humidity: *Journal of Energy Policy*, **36**, 571–576.
- Santhanam, T., Subhajini, A. C., 2011, An efficient weather forecasting system using radial basis function neural network: *Journal of Computer Science*, **7**, 962–966.
- Shank, D. B., Hoogenboom, G., McClendon, R. W., 2008, Dewpoint temperature prediction using artificial neural networks: *Journal of Applied Meteorology and Climatology*, **47**, 1757–1769.
- Sozen, A., Arcaklioglu, E., 2005, Effect of relative humidity on solar potential. *Journal of Applied Energy*, **82**, 345–367.
- خورشیدی روزانه کشور ایران: نشریه علمی پژوهشی مهندسی و مدیریت انرژی، **۳**، ۴۷–۳۷.
- Amini, J., 2008, Optimum Learning Rate in BP Network: *Scientia Iranica*, **15**(6), 558-567.
- Barnett, T. P., and Preisendorfer, R., 1987, Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis: *Monthly Weather Review*, **115**, 1825–1850.
- Cadenas, E., Rivera, W., 2009, Short term wind speed forecasting in La Venta, Oaxaca, Mexico, using artificial neural networks. *Journal of Renew Energy*, **34**, 274–278.
- Chaudhuri, S., Das, D., Sarkar, I., and Goswami, S., 2015, Multilayer perceptron model for nowcasting visibility from surface observations: Results and sensitivity to dissimilar station altitudes: *Pure and Applied Geophysics*, **172**, 2813–2829. DOI 10.1007/s00024-015-1065-2.
- Chmielecki, R. M., and Adrian, E. R., 2011, Probabilistic visibility forecasting using Bayesian model averaging: *Monthly Weather Review*, **139**, 1626-1636.
- Erdil, A., Arcaklioglu, E., 2013, The prediction of meteorological variables using artificial neural network: *Neural Computing and Applications*, **22**, 1677–1683.
- Galton, F. J., 1885, Regression towards mediocrity in hereditary stature: *The Journal of the Anthropological Institute of Great Britain and Ireland*, **15**, 246–263.
- Hansen, B., 1997, State of the Art of Neural Networks in Meteorology: Mid-term Paper

Prediction of horizontal visibility by training feedforward network with resilient backpropagation algorithm

Farideh Habibi^{1*}

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

(Received: 12 November 2017, Accepted: 23 January 2018)

Summary

Meteorological phenomena are complex systems with different parts that are in contact with each other as well as their surroundings. The purpose of this research is to demonstrate the efficiency of neural networks in predicting meteorological variables. For this purpose, the prediction of horizontal visibility that is widely used in meteorology and aviation especially at airports has been selected for analysis. The data of this study are a compilation of Metar and Synop reports of Bandar Abbas synoptic station in the period from 1 to 30 March 2014.

To implement this network, at first, the whole data were randomly divided into three categories with proportions of 75, 15 and 15 percent for learning, testing and validation of network and saved in other files. The seven variables for inputs (temperature, dew point temperature, atmospheric pressure, sky cloud coverage, wind speed and wind direction) of the network with 28 various composites tested with a feedforward network and their correlation with the output and amount of root mean square (RMS) error of network have been studied. The results show, the compositions that containing the present air phenomena are most correlated with the horizontal visibility. Besides, the dew point temperature, atmospheric pressure and the amount of cloud cover are variables that alone do not have an affect on the horizontal visibility.

In this research, a network which works with training neural networks by resilient backpropagation algorithm is used. This is a learning heuristic for supervised learning in feedforward artificial neural networks, which only the sign of the partial derivative is used to determine the direction of the bias and weight updates and the magnitude of their derivative has no effect on their updates. Of course, the size of their change (increment and reduce rates) is determined by a separate update value. This network with eight neurons and sigmoid transfer function in the hidden layer and the linear transfer function in the output layer is used for predicting of horizontal visibility. This network was performed with two standardization data sets between intervals 0.0-1.0 and 0.1-0.9; also, different learning rates, incremental and reduced rates for weights and biases. The results show that the normalization is not appropriate between zero and one. The appropriate amounts of learning rate, incremental and reduced rates for this network are 0.0001, 1.2 and 0.35, respectively.

The values of the coefficient of determination for training, test and validation data for a running network with all variables were 0.9972, 0.9866 and 0.9839, respectively. These values show that nearly 99 percent of the measured horizontal visibility is affected by these independent variables and the rest of its variations are dependent on other factors.

Keywords: prediction, horizontal visibility, feedforward network, learning rate, resilient backpropagation algorithm

*Corresponding author:

fhabibi@ut.ac.ir