

فصلنامه علمی-پژوهشی تحقیقات مرتع و بیابان ایران
جلد ۱۷، شماره ۲، صفحه ۲۲۰-۲۰۵ (۱۳۸۹)

پیش‌بینی وقوع طوفان گرد و خاک با استفاده از روش شبکه‌های عصبی مصنوعی (مطالعه‌ی موردی: شهر زابل)

محمد رضا جمالیزاده تاج‌آبادی^{۱*}، علیرضا مقدم نیا^۲، جمشید پیری^۳ و محمدرضا اختصاصی^۴

*- نویسنده مسئول، دانشجوی کارشناسی ارشد بیابان‌زدایی، دانشکده منابع طبیعی، دانشگاه زابل

پست الکترونیک: jamalizadeh81@yahoo.com

۲- استادیار، گروه مرتع و آبخیزداری دانشکده منابع طبیعی، دانشگاه زابل

۳- کارشناس ارشد، اداره‌ی جهاد کشاورزی زابل

۴- دانشیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه یزد

تاریخ پذیرش: ۸۷/۱۰/۳۰

تاریخ دریافت: ۸۶/۱۲/۰۵

چکیده

طوفان‌های گرد و خاک یکی از انواع رایج حوادث و فرایندهای اقلیمی در مناطق خشک، نیمه‌خشک و بیابانی دنیا هستند. این طوفان‌ها هر ساله خسارتهای مالی زیادی را بر منابع انسانی وارد می‌سازند. پیش‌بینی زمان وقوع این پدیده می‌تواند برای اتخاذ تدابیر پیشگیرانه در مقابل خسارتهای بهداشتی، ترابری، نظامی و غیره مؤثر واقع شود. شبکه‌های عصبی مصنوعی روشی است که می‌تواند برای پیش‌بینی روندهای غیرخطی و فرایندهایی که درک کاملی از نحوه‌ی وقوع آنها وجود ندارد، مورد استفاده قرار گیرد. در مقاله‌ی حاضر سعی شده است تا با استفاده از این روش به پیش‌بینی وقوع طوفان گرد و خاک و نیز میزان دید حداقل روزانه در شهر زابل با استفاده از داده‌های هواشناسی پرداخته شود. نتایج بدست‌آمده در پیش‌بینی کوتاه‌مدت وقوع طوفان‌ها موفقیت بیشتری نشان می‌دهند ($d=0/96$)، اگرچه با بیشتر شدن زمان پیش‌بینی، از دقت نتایج کاسته می‌شود ($d=0/95$). در حالی که در پیش‌بینی میزان دید موفقیت کمتری به دست‌آمد ($d=0/88$). بنابراین به نظر می‌رسد با شناخت بهتر فرایند این طوفان‌ها بتوان پیش‌بینی‌های دقیق‌تری را با استفاده از این شبکه‌ها انجام داد.

واژه‌های کلیدی: طوفان گرد و خاک، دید حداقل، شبکه عصبی مصنوعی، پیش‌بینی، زابل.

مقدمه

گرد و غبار و ذراتی که این طوفان‌ها از مناطق خشک دنیا وارد جو می‌کنند، شده است (Wetphal, 2002). پیش‌بینی موفق این رخدادهای می‌تواند کمک زیادی به بهبود زندگی در این مناطق باشد. با هشدارهای لازم قبل از وقوع یک طوفان گرد و خاک می‌توان شهروندان را از خطرات بهداشتی وارده از طرف این طوفان‌ها از قبیل تنگی نفس

طوفان‌های گرد و خاک حوادث طبیعی هستند که در مناطق خشک، نیمه‌خشک و بیابانی دنیا به فراوانی رخ می‌دهند (Song, 2004). اما این طوفان‌ها فقط در مناطق منشأ رخ نمی‌دهند بلکه تا فواصل بسیار دورتر نیز حمل می‌شوند. در سال‌های اخیر توجه فزاینده‌ای به طوفان‌های

پیش‌بینی وقوع طوفان گرد و خاک با استفاده از...

پیش‌بینی فرایندهایی که روندی غیرخطی داشته و شناخت کاملی از چگونگی رخداد آنها وجود ندارد، در کلیه‌ی زمینه‌های علمی گسترده شده است. شبکه‌های عصبی مصنوعی یکی از زیرشاخه‌های هوش مصنوعی می‌باشد که بتدریج جایگاه ویژه‌ای در بین علوم مختلف پیدا کرده است و در زمینه‌های گوناگون منابع طبیعی اعم از اقلیم و علوم آب و نیز مدیریت استفاده‌های زیادی از این روش‌ها شده است.

استفاده از این روش برای پیش‌بینی طوفان گرد و خاک در شمال‌غرب چین توسط هوانگ و همکاران گزارش شده است که توانسته‌اند به‌طور متوسط ۷۱/۶٪ و ۶۸/۲ درصد طوفان‌ها را پیش‌بینی نمایند (Huang et al., 2006). این روش برای پیش‌بینی متغیرهای دیگر اقلیمی از جمله برای برآورد میزان تبخیر و تعرق به فراوانی مورد استفاده قرار گرفته است و نتایج بسیار خوبی بدست آمده است (Sudheer et al., 2003; Trajkovic et al., 2003; Benne et al., 2000). در ارتباط با بارش، رواناب و درجه حرارت نیز موارد فراوانی وجود دارند که از این روش استفاده کرده‌اند (Hessami, Trigo & Palutikof, 1999; De Vos & Rientjes, 2005; et al., 2004). همچنین در زمینه‌ی منابع آب و هیدرولوژی نیز استفاده‌های زیادی از این روش شده است (Salehi, Maier & Dandy, 2000; Amin & Soltani, 2003; et al., 2000).

طوفان گرد و خاک در منابع مختلف تعاریف متعدد و تا حدودی نامشخص دارد. اما مهمترین متغیر در تشخیص وقوع طوفان گرد و خاک وجود غبار و ذرات گرد و خاک در هواست. براساس طبقات مختلف دید، طوفان گرد و خاک نیز به انواع مختلف و با تعاریف و اسامی مختلفی

آگاه ساخت. همچنین در بخش ترابری هوایی و زمینی کاهش دید ناشی از وقوع این طوفان‌ها خسارت‌آفرین است که مقابله با این خسارت‌ها نیازمند پیش‌بینی این رخدادها می‌باشد.

از آن‌جا که این روش‌ها در موارد متعدد کارآیی مناسبی در پیش‌بینی فرایندهای طبیعی داشته‌اند انتظار می‌رود تا در این زمینه نیز موفق باشند. موفقیت در مدل‌سازی یک فرایند در گرو شناخت کامل اجزاء و مراحل تشکیل‌دهنده‌ی آن فرایند است. اما قابلیت ویژه‌ی روش شبکه‌های عصبی مصنوعی ما را قادر می‌سازد تا یک فرایند نه‌چندان شناخته شده را پیش‌بینی کنیم.

به‌طورکلی برای شبیه‌سازی و پیش‌بینی این طوفان‌ها تاکنون راه‌های مختلفی تجربه و آزمایش شده است. بیشتر این روش‌ها براساس مطالعات و اندازه‌گیریهای گسترده‌ی جوی، استفاده از ماهواره‌های هواشناسی و نیز برخی مدل‌ها می‌باشند که بسیار پرهزینه هستند و نیز نیاز به یک شبکه‌ی گسترده از ایستگاه‌های مشاهداتی و اندازه‌گیری دارند (Lu, 1999; Song, 2003; Lasserre et al., 2005; Yoo, 2006; Zhang, 2006; Cheng et al., 2007). در این میان مدل‌های شبکه عصبی مصنوعی که با الهام از عصب‌های بیولوژیکی عمل می‌نمایند، به‌عنوان گزینه‌ای برتر مورد تحقیق و بررسی قرار می‌گیرند. این مدل‌ها می‌توانند با حداقل متغیرهای اندازه‌گیری شده و با دقت قابل قبولی تغییرات متغیر موردنظر را پیش‌بینی نمایند. جذابیت مدل‌های شبکه‌ی عصبی مصنوعی به‌دلیل توانایی آنها در حل مسائل غیرخطی، حجیم و دارای خطا، می‌باشد. همچنین این مدل‌ها توانایی یادگیری حل مسائل فازی و تشخیص الگوها را نیز دارا می‌باشند (Hsu et al., 1995). استفاده از روش‌های مختلف هوش مصنوعی در

عصبی مصنوعی که پرسپترون چندلایه نامیده می‌شود شامل سه واحد گروهی یا لایه‌ای می‌شود: یک لایه ورودی که به یک لایه پنهان متصل است و این لایه نیز به نوبه‌ی خود به لایه‌ای که لایه‌ی خروجی نامیده می‌شود متصل می‌گردد. پژوهشگران معمولاً شبکه‌های عصبی را با یک یا دو لایه‌ی پنهان طراحی می‌کنند (قدیمی و مشیری، ۱۳۸۱)، زیرا شبکه‌های عصبی با لایه‌های پنهان دارای توانایی بیشتری نسبت به شبکه‌های عصبی دو لایه هستند (منهاج، ۱۳۷۷). اما به طور کلی هیچ روش سیستماتیک پذیرفته‌شده‌ای برای تعیین تعداد ورودی بهینه وجود ندارد (Zhang et al., 1998). مجموع ورودی‌های هر نورون پس از ضرب در وزن‌های متناظر در یک تابع موسوم به تابع محرک اعمال می‌شوند و براساس نیاز خاص مسئله‌ای که قرار است به وسیله‌ی شبکه‌ی عصبی حل شود، می‌تواند خطی یا غیرخطی انتخاب شود. در حقیقت تابع محرک ارتباط بین ورودی و خروجی گره‌ها و شبکه را برآورد می‌نماید (منهاج، ۱۳۷۷).

هدف از این مطالعه بررسی قابلیت شبکه‌های عصبی مصنوعی در پیش‌بینی وقوع طوفان گرد و خاک در ایستگاه سینوپتیک زابل بود، اما به علت ساختار داده‌ها و وجود ابهام در تعاریف، حداقل دید روزانه نیز با همین روش پیش‌بینی شد تا بتوان این قابلیت را در این مورد نیز سنجید.

مواد و روشها

منطقه‌ی مورد مطالعه

ناحیه‌ی سیستان ۱۵۱۹۷ کیلومتر مربع وسعت دارد و در قسمت شمالی استان سیستان و بلوچستان واقع شده است. این ناحیه حوزه مسطح و مسدودی است که از

تقسیم می‌شود. در هنگام ثبت داده‌ها در ایستگاه‌های هواشناسی سینوپتیک، هوایی که غبار داشته یا طوفان شن یا گرد و خاک رخ داده باشد به چند دسته تقسیم می‌شود که مبنای این تقسیم‌بندی نیز بیشتر مقدار دید افقی است (Westwell, 1999) و البته برگرداندن این اصطلاحات به فارسی نیز چندان آسان نیست. در این تحقیق به پیش‌بینی مواردی از این طوفان‌ها پرداخته‌ایم که دید افقی در آنها به کمتر از ۱۰۰۰ متر می‌رسد. این میزان دید در بسیاری از موارد تحقیقی طوفان گرد و خاک نامیده می‌شوند (Engelstaedter, 2001). اما از آن‌جا که مدل در اجراهای اولیه نتایج خوبی نشان نداد، کدهای مربوط به طوفان از داده‌ها استخراج شده و دید افقی به‌عنوان یک متغیر به مدل معرفی گردید. در این مطالعه رخدادهایی که دید در آنها به کمتر از ۱۰۰۰ متر رسیده است و نیز در داده‌های هواشناسی با کدهای ۳۳، ۳۴ و ۳۵ ثبت شده بودند، به عنوان رخداد طوفان گرد و خاک ثبت و وارد مدل شدند.

شبکه‌های عصبی مصنوعی

این مدل‌ها توانایی استخراج روابط نهفته بین ورودی‌ها و خروجی‌های مدل را دارند. این ساختار از تعداد بسیار زیادی عناصر پردازشی یا نورون‌ها تشکیل شده است که برای حل مسائل پیچیده مورد استفاده قرار می‌گیرد. این شبکه‌ها مانند کسب تجربه در انسان، از موارد نمونه یاد می‌گیرند و برای کاربردهای خاص از قبیل تشخیص الگو یا طبقه‌بندی داده‌ها طی روند یادگیری، سازمان‌دهی شده‌اند و این شرح ساده‌ای از شبکه‌های عصبی مصنوعی است (پیری، ۱۳۸۵). انواع بسیار متفاوتی از شبکه‌های عصبی با گستره‌ی کاربردی ویژه وجود دارند (Haykin, 1994؛ Hetch-Nielsen, 1990). معمولترین نوع شبکه‌ی

است. این منطقه در روش طبقه‌بندی اقلیمی دومارتن دارای اقلیم خشک و در روش ایوانف دارای اقلیم صحرائی ارزیابی شده است (سازمان جنگل‌ها، مراتع و آبخیزداری کشور، ۱۳۸۴). بیشینه‌ها، کمینه‌ها، میانگین‌ها و دیگر متغیرهای آماری اقلیمی در جدول ۱ درج شده است.

آبرفت‌های دلتای قدیمی و فعلی رود هیرمند تشکیل شده است. مطالعات انجام شده در جنوب غرب آسیا (ایران، افغانستان، پاکستان و هند) نشان می‌دهند که بیشترین میانگین روزهای طوفان گرد و خاک مربوط به شهر زابل در سیستان ایران با ۸۰/۷ روز است (Middleton, 1986). دشت سیستان جزو بیابان‌های گرم با زمستان‌های سرد

جدول ۱- خلاصه‌ی متغیرهای هواشناسی اندازه‌گیری شده در ایستگاه سینوپتیک زابل در یک دوره‌ی ۳۵ ساله (۱۹۸۰-۲۰۰۵)

| مقدار | حدود | متغیر اندازه‌گیری شده |
|------------------------|----------------|-----------------------|
| ۸/۷ میلی‌متر | کمینه | بارش |
| ۱۲۸/۷ میلی‌متر | بیشینه | |
| ۶۴ میلی‌متر | میانگین | |
| ۸/۴ درجه‌ی سانتی‌گراد | کمینه | دما |
| ۳۴/۴ درجه‌ی سانتی‌گراد | بیشینه | |
| ۲۹/۳ درجه‌ی سانتی‌گراد | میانگین | |
| ۳۵۸۴ میلی‌متر | از سطح آزاد آب | تبخیر و تعرق |
| ۴۷۴۷ میلی‌متر | از تشتک تبخیر | |
| ۰ متر بر ثانیه | کمینه | سرعت باد |
| ۴۰ متر بر ثانیه | بیشینه | |
| ۱۱/۷۲ متر بر ثانیه | میانگین | |
| ۲۴ درصد | کمینه | رطوبت نسبی ماهانه |
| ۵۵ درصد | بیشینه | |

ماهانه سرعت باد در دسامبر سال ۱۹۷۰ معادل ۰/۷ متر با ثانیه (برابر با ۲/۵۲ کیلومتر بر ساعت) ثبت شده است. همچنین متوسط ماهانه سرعت باد در طول ۳۶ سال حدود ۹/۶ متر بر ثانیه که معادل ۳۲/۴ کیلومتر بر ساعت است.

بررسی‌های اولیه منابع آماری بادها و طوفان‌های سیستان در محل ایستگاه سینوپتیک زابل در طول دوره ۳۶ ساله ۱۹۹۵-۱۹۶۲ نشان می‌دهد که حداکثر متوسط ماهانه سرعت باد در ماه ژوئن سال ۱۹۸۴ معادل ۴۱/۶ متر بر ثانیه (برابر با ۱۴۹/۷ کیلومتر بر ساعت) و حداقل متوسط



شکل ۱- تصویر ماهواره‌ی MODIS از طوفان گرد و خاک رخ داده در منطقه (موقعیت ایستگاه با نقطه، مرز کشورها با خط چین و بستر دریاچه‌های خشک با خطوط ساده نشان داده شده است؛ اول سپتامبر ۲۰۰۴)

داده‌های مورد استفاده

در این مطالعه از داده‌های بلندمدت هواشناسی ایستگاه سینوپتیک زابل از سال ۱۹۸۰ تا ۲۰۰۵ استفاده شد. داده‌ها پس از اخذ از سازمان هواشناسی کشور، مورد پردازش قرار گرفته و داده‌های ناقص بازسازی شدند. برای تعیین رخداد طوفان از شاخص دید اسکوارز (Squires, 2001) و از بین وقایع طوفان گرد و خاک، موارد مربوطه جداسازی شدند. برخی از متغیرها از جمله رطوبت نسبی و ساعات تابش آفتابی به‌علت این که در کل دوره‌ی آماری اندازه‌گیری و ثبت نشده بودند و با توجه به اینکه در ساختار و ماهیت روش شبکه‌های عصبی مصنوعی،

امکان بازسازی دوره‌های ناقص وجود نداشت از مدل کنار گذاشته شدند.

تجزیه و تحلیل داده‌ها و آماده‌سازی آنها

در روش‌های هوش مصنوعی و از جمله در روش شبکه‌های عصبی مصنوعی هر چه تعداد داده‌ها بیشتر باشد کارکرد شبکه بهتر می‌شود، اما از طرف دیگر این افزایش حجم داده‌ها باعث می‌شود سرعت یادگیری و نیز اجرای مدل کند شود و همچنین امکان ایجاد اختلال نیز در کار شبکه وجود دارد. به‌طوری‌که برای تعیین بهترین و مناسبترین متغیرهای ورودی به شبکه، با استفاده از

عصبی، با استفاده از بسته نرم‌افزاری شبکه عصبی MATLAB انجام گردید. تعداد لایه‌های پنهان در این شبکه به صورت آزمون و خطا به شکلی تصادفی انتخاب شد و از ۳ لایه شروع شد. تعداد تکرار برابر ۱۰۰ در نظر گرفته شد. مبنای انتخاب تعداد گره‌های لایه‌ی پنهان نیز، میزان ریشه‌ی میانگین مربعات خطا می‌باشد که خود نرم‌افزار پس از اجرای مدل هر بار نمایش داده و مقدار آن را اعلام می‌نماید. کوچکترین مقدار ریشه‌ی میانگین مربعات خطا که توسط مناسبترین تعداد گره‌ی لایه پنهان بدست‌آمده باشد به‌عنوان تعداد گره مطلوب لایه پنهان انتخاب می‌شود. تابع محرک نیز از نوع تانژانت سیگموئیدی انتخاب گردید. به‌طوری‌که برای ساخت و استفاده از شبکه‌ی عصبی مصنوعی نیز از کدنویسی در محیط نرم‌افزار MATLAB استفاده شد (Nørgaard, 2000). شبکه‌ی عصبی مورد استفاده در این مطالعه پرسپترون چند لایه بود. در این کد از خوارزمیک لونیبرگ-مارکواردت بهره برده شد. این خوارزمیک یک روش تکرارپذیر می‌باشد که نقطه‌ی کمینه‌ی یک تابع چندمتغیره را می‌یابد که به‌صورت مجموع مربعات توابع غیرخطی واقعی-مقدار بیان می‌شود (Levenberg, 1944; Marquardt, 1963) و به‌عنوان روشی استاندارد برای مسائل حداقل مربعات غیرخطی بیان شده است (Mittelmann, 2004). استفاده از این خوارزمیک و نیز ساختار NNARX که ترکیبی از روش‌های آماری و روش شبکه‌ی عصبی می‌باشد و یک پیش‌بینی‌کننده‌ی بدون بازخورد می‌باشد می‌تواند در عملکرد بهتر شبکه مؤثر باشد.

مقدار ضریب شتاب برابر با صفر انتخاب شد. با توجه به این که از خوارزمیک آموزشی لونیبرگ-مارکواردت استفاده شد، که یک خوارزمیک آموزشی دسته‌ایست،

نرم‌افزار SPSS آزمون همبستگی بین داده‌ها انجام شد. داده‌هایی که همبستگی بالاتری با خروجی هر مدل نشان دادند به‌عنوان ورودی انتخاب شده و در صورت عدم کارایی مناسب از مدل حذف شده و متغیر بعدی جایگزین آن گردید. در ساخت مدل همواره سعی شد تا با کمترین تعداد ورودی‌ها کار پیش‌بینی انجام شود که در نهایت متغیرهای حداکثر سرعت باد، میزان بارش، حداقل دید روزانه و یک روز قبل برای پیش‌بینی دید حداقل و سرعت حداکثر باد، میزان بارش، وقوع یا عدم وقوع طوفان گرد و خاک روزانه و روز قبل به‌عنوان ورودی‌های مدل انتخاب شدند. خروجی مدل نیز براساس هدف انتخاب گردید. متغیرهای ورودی به مدل دارای واحدهای مختلف بودند و این باعث می‌شد تا اعداد در مورد برخی متغیرها بزرگ، در برخی کوچک و در برخی دیگر مقادیر مثبت و منفی داشته باشند. این مسئله باعث می‌شود تأثیر متغیرهای با مقادیر بیشتر بر مدل زیادتر بوده و جواب‌های بدست‌آمده با واقعیت همخوانی نداشته باشند. به همین دلیل در این روش‌ها همواره سعی در نرمال‌سازی داده‌ها می‌شود. به‌طوری‌که روش‌های نرمال‌سازی متفاوتند و باتوجه به هر مورد می‌توان نوع متفاوتی از آنها را برگزید. نرمال‌سازی بین بیشینه و کمینه‌ی داده‌ها، بین صفر و یک، بین ۰/۱ و ۰/۹ از معمولترین روش‌ها هستند (Hsu, 2004). در این مطالعه داده‌ها به‌نحوی نرمال‌سازی شدند که دارای مقدار کمینه‌ی صفر و بیشینه‌ی یک باشند. تعیین سایر مشخصات شبکه، مانند تعداد لایه‌های پنهان، تعداد نورون‌های موجود در هر لایه پنهان، تابع فعالیت و خوارزمیک آموزش شبکه نیز جزء مواردیست که در معماری شبکه عصبی مصنوعی اهمیت زیادی دارد. تمامی مراحل طراحی شبکه‌های

بنابراین نیازی به استفاده از یک میزان یادگیری ثابت نیست (Sarle, 2002). از این رو، داده‌ها در دو دسته‌ی موسوم به آموزش، برای ساخت و آموزش مدل و آزمون برای سنجش توانایی مدل ساخته شده و میزان یادگیری آن تنظیم گردیدند.

سنجش میزان کارایی مدل

از تجزیه و تحلیل خطاهای باقیمانده و تفاوت‌های بین مقادیر اندازه‌گیری شده و برآورد شده می‌توان در ارزیابی کارایی مدل بهره برد. شمار زیادی از ملاک‌ها برای ارزیابی کارایی مدل وجود دارند (خداوردی‌لو و

همکاران، ۱۳۸۳). در پایان، نتایج حاصل از مدل‌ها (خروجی‌ها) و رخدادهای واقعی طوفان با همدیگر مقایسه شده و از معیارهای مربعات خطا (R^2)، شاخص تطابق (d)، (Willmott, 1982)، ریشه‌ی میانگین مربعات خطا (RMSE) و متوسط قدرمطلق خطا (MAE) که نشان‌دهنده‌ی میزان خطای مدل با بعد متغیرها می‌باشند، برای نشان‌دادن عملکرد مدل‌ها استفاده شده است. این چهار معیار به صورتی که در جدول ۲ نشان داده شده است محاسبه می‌شوند.

جدول ۲- معیارهای اندازه‌گیری کارایی مدل

| | |
|--|---------------------------|
| $RMSE = \sqrt{\frac{\sum_{k=1}^k (X_k - Y_k)^2}{K}}$ | ریشه‌ی میانگین مربعات خطا |
| $R^2 = \frac{\sum_{k=1}^k X_k Y_k}{\sqrt{\sum_{k=1}^k X_k^2 \sum_{k=1}^k Y_k^2}}$ | مربعات خطا |
| $MAE = \frac{\sum_{k=1}^k X_k - Y_k }{K}$ | متوسط قدرمطلق خطا |
| $d = 1 - \frac{\sum_{i=1}^n (p_i - o_i)^2}{\sum_{i=1}^n (p'_i + o'_i)^2}$ $p'_i = p_i - \bar{o} \quad o'_i = o_i - \bar{o}$ | شاخص تطابق |

بطوری‌که در این روابط X_k مقدار مشاهداتی، Y_k مقدار برآورد شده و o و p به ترتیب مقادیر مشاهده شده و شبیه‌سازی شده، \bar{o} و \bar{p} به ترتیب میانگین مقادیر مشاهده شده و شبیه‌سازی شده، K و n تعداد نمونه‌ها می‌باشد.

نتایج

نتایج بدست‌آمده از مدل‌های مختلف در دو بخش آموزش و آزمون شبکه به تفکیک هدف در جدول ۳ نشان داده شده است. همچنین نمودار پیش‌بینی‌های انجام شده برای ۹۰ روز به صورت تصادفی در بین سال‌های انتهایی دوره آورده شده‌اند تا بتوان تصور بهتری از انجام کار پیش‌بینی داشت. بدلیل حجم زیاد مطالب و از آن‌جا


که در تعیین کارایی مدل‌ها، جواب‌های بدست‌آمده در بخش ارزیابی مدل بیشتر مورد توجه است، در بخش نمودارها فقط جواب‌های مربوط به ارزیابی مدل (آزمون) آورده شده‌اند. تعداد لایه‌های پنهان اثر قابل ملاحظه‌ای بر بهبود کارکرد مدل‌ها نداشت و افزایش تعداد لایه‌ها باعث افزایش زمان اجرای مدل می‌شد.

جدول ۳- مقادیر محاسبه‌شده R^2 ، d ، $RMSE$ و MAE برای هر مدل شبکه عصبی نهایی


| نام مدل براساس هدف | مربعیات خطا (R^2) | | شاخص تطابق (d) | | ریشه‌ی میانگین مربعات خطا ($RMSE$) | | قدر مطلق میانگین خطا (MAE) | |
|--------------------|-----------------------|-------|--------------------|-------|--------------------------------------|--------|--------------------------------|-------|
| | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون | آموزش | آزمون |
| طوفان ۲۴ ساعته | ۰/۸۸ | ۰/۹۱ | ۰/۹۸ | ۰/۹۶ | ۴۰۹/۶۲ | ۳۸۳/۳۰ | ۰/۰۴۴ | ۰/۰۵۶ |
| طوفان ۴۸ ساعته | ۰/۸۲ | ۰/۸۶ | ۰/۹۸ | ۰/۹۵ | ۴۱۱/۰۴ | ۲۳۶/۶۸ | ۰/۰۴۴ | ۰/۰۸۲ |
| طوفان ۷۲ ساعته | ۰/۸۱ | ۰/۸۲ | ۰/۹۸ | ۰/۹۵ | ۴۱۲/۵۹ | ۲۴۱/۶۵ | ۰/۰۴۵ | ۰/۰۸۴ |
| طوفان ۲۴۰ ساعته | ۰/۸۰ | ۰/۸۲ | ۰/۹۸ | ۰/۹۵ | ۴۱۰/۸۳ | ۲۳۲/۱۵ | ۰/۰۴۵ | ۰/۰۸۰ |
| دید ۲۴ ساعته | ۰/۹۱ | ۰/۹۲ | ۰/۸۷ | ۰/۸۸ | ۲۳/۲۹ | ۲۴/۰۶ | ۰/۸۷ | ۰/۸۸ |
| دید ۴۸ ساعته | ۰/۸۰ | ۰/۸۷ | ۰/۸۶ | ۰/۸۸ | ۲۴/۶۹ | ۲۸/۴۴ | ۰/۲۲ | ۰/۱۰ |
| دید ۷۲ ساعته | ۰/۸۴ | ۰/۸۶ | ۰/۸۶ | ۰/۸۸ | ۲۴/۱۸ | ۲۸/۴۱ | ۰/۰۹۶ | ۰/۱۰۷ |
| دید ۲۴۰ ساعته | ۰/۸۳ | ۰/۸۶ | ۰/۸۶ | ۰/۸۸ | ۲۴/۳۹ | ۲۸/۵۵ | ۰/۰۹۶ | ۰/۱۰۸ |

همان‌گونه که در شکل ۲ مشاهده می‌شود خروجی مدل هیچ‌گاه به مقدار یک که نشان‌دهنده‌ی طوفان می‌باشد نرسیده است، اما می‌توان حدی را مشخص کرد که بیش از آن به‌عنوان طوفان در نظر گرفته شود. در واقع خروجی مدل دو حالت بیشتر ندارد. بنابراین برای این مدل به‌نظر می‌رسد حد ۰/۲ مناسب باشد. در جدول ۳ مشاهده می‌شود که همبستگی در این مدل بیشترین حد و قدر مطلق خطا در پایین‌ترین مقدار قرار دارد.


برای پیش‌بینی طوفان در دو روز آینده، مقدار قدر مطلق خطا همان‌طور که در جدول ۳ مشخص است افزایش می‌یابد و همبستگی نیز کاهش نشان می‌دهد. از طرفی تعیین یک حد مشخص برای اعلام طوفان چندان قابل اطمینان نیست.



شکل ۲- پیش بینی ۲۴ ساعته وقوع طوفان گردوخاک (آزمون)




شکل ۳- پیش بینی ۴۸ ساعته وقوع طوفان گردوخاک (آزمون).



شکل ۴- پیش‌بینی ۷۲ ساعته‌ی وقوع طوفان گردو خاک (آزمون)

بالاست. همان‌گونه که از شکل‌های ۴ و ۵ پیداست مدل رخدادهایی را در بعضی روزهای بدون طوفان نشان می‌دهد.


در مورد پیش‌بینی طوفان‌های ۳ و ۱۰ روز بعد دقت به مراتب کمتر می‌شود. اگرچه می‌توان از هشدار در مورد وقوع طوفان مطمئن بود، اما احتمال هشدار غلط نیز



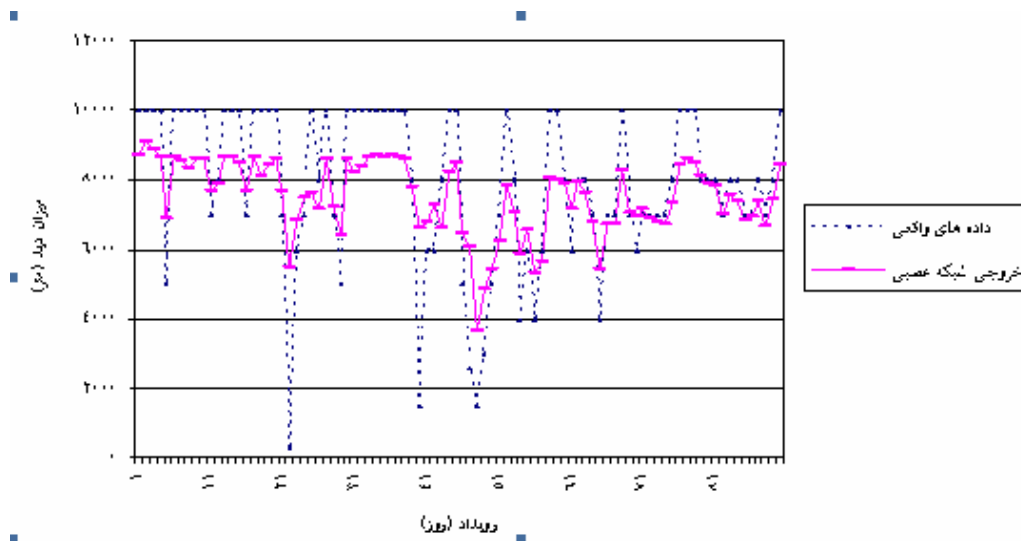
شکل ۵- پیش‌بینی ۲۴۰ ساعته‌ی وقوع طوفان گردو خاک (آزمون)

برداشت نمی‌باشد. همان‌طور که از شاخص‌های ارائه‌شده در جدول ۳ آشکار است، کارایی مدل‌ها با بیشتر شدن مدت زمان پیش‌رو برای پیش‌بینی، کمتر می‌شود.


شکل‌های ۶ تا ۹ پیش‌بینی میزان دید را نشان می‌دهند. از آن‌جا که تعیین حد آستانه مانند مرحله‌ی قبل ممکن نیست و پیش‌بینی مقدار فاصله‌ی دید در این مدل‌ها انتظار می‌رود، مقصود نهایی که وقوع طوفان است از آنها قابل




شکل ۶- پیش بینی ۲۴ ساعته‌ی میزان دبی (آزمون)



شکل ۷- پیش بینی ۴۸ ساعته‌ی میزان دبی (آزمون)



شکل ۸- پیش‌بینی ۷۲ ساعته‌ی میزان دید (آزمون)



شکل ۹- پیش‌بینی ۲۴۰ ساعته‌ی میزان دید (آزمون)

بحث

طوفان ثبت می‌گردد و هنگامی که این نوسان از مقدار صفر تجاوز زیادی نداشته باشد یک رخداد بدون طوفان را انتظار داریم. در مطالعه‌ای مشابه که در چین انجام شده است، این روند مشاهده شده است (Huang et al., 2006)، اگرچه نتایج بدست‌آمده در این تحقیق مقداری بهتر از مورد مشابه می‌باشد، اما در مورد دید حداقل، قدر

با توجه به خلاصه‌ی نتایج و نمودارهای مربوطه، می‌توان نتیجه گرفت که انتخاب مناسب چگونگی ثبت خروجی مدل تا چه اندازه می‌تواند در بهبود عملکرد مدل نقش داشته باشد. در مورد رخداد طوفان هنگامی که مقدار بدست‌آمده از شبکه به مقدار یک نزدیک می‌شود وقوع

طبقات آن به صورت مشخص بیان شود تا در هنگام ثبت داده‌ها فرایندهای مشابه با همدیگر اشتباه گرفته نشوند.

سپاسگزاری

در پایان از آقایان، دکتر داوید از دانشگاه بریستول، دکتر انگلستان‌تر از دانشگاه کارنل، پروفیسور وارنر از دانشگاه نبراسکا، دکتر سروشیان از دانشگاه آریزونا، مهندس دلور از دانشگاه تربیت مدرس و مهندس دیانته از ایستگاه سینوپتیک زابل که ما را در انجام این مطالعه یاری دادند، صمیمانه تشکر می‌شود.

منابع مورد استفاده

- پیری، ج، ۱۳۸۵. شبیه‌سازی تخیل چاه‌نیمه‌های زابل با استفاده از شبکه‌های عصبی مصنوعی. پایان‌نامه‌ی کارشناسی ارشد. دانشگاه شیراز.
- خداوردی‌لو، ح، فتحی، پ. و همایی، م، ۱۳۸۳. تخمین هوشمند منحنی رطوبتی خاک با استفاده از شبکه عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک. دانشگاه شیراز.
- دلور، م، ۱۳۸۴. بررسی تغییرات تراز آب دریاچه‌ی ارومیه. پایان‌نامه‌ی کارشناسی ارشد رشته‌ی آبیاری، دانشگاه تربیت مدرس، تهران.
- سازمان جنگل‌ها و مراتع کشور، ۱۳۸۴. مطالعات جامع بیابان‌زدایی دشت سیستان. مهندسين مشاور جامع ایران. بخش اقلیم.
- شایان‌نژاد، م، ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن-مانتیس در محاسبه تخیل و تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی. دانشگاه شهید چمران اهواز.
- قدیمی، م. و مشیری، س، ۱۳۸۱. مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی، فصلنامه‌ی پژوهش‌های اقتصادی ایران، ۱۲: ۹۷ - ۱۲۵.
- منهای، م، ۱۳۷۷. مبانی شبکه‌های عصبی (هوش محاسباتی)، نشر دکتر حسابی، تهران.

مطلق خطا در مرحله‌ی آزمون سریعاً افزایش می‌یابد و نمی‌توان جواب درستی را ثبت کرد. البته نتایج بهتری که در استفاده از این روش در سایر زمینه‌ها بدست آمده است، می‌توان بدین علت دانست که فرایند موردنظر بخوبی مشخص شده است. بنابراین به نظر می‌رسد درباره‌ی طوفان‌های گرد و خاک، عدم تفکیک صحیح وقایع، تداخل رخدادهای طوفان نزدیک به هم و از این رو، اشتباه در ثبت رخدادهای باعث ایجاد مشکل در تهیه‌ی یک مدل پیش‌بینی با استفاده از این روش می‌گردد. بنابراین می‌توان با طبقه‌بندی مناسب داده‌های خروجی در این روش‌ها به نتایج قابل قبول‌تری دست یافت.

پیشنهادها

با توجه به مطالعات انجام شده و آشکار شدن قدرت این روش در پیش‌بینی‌های مختلف، پیشنهاد می‌گردد که در مناطق دیگر که ساختار تشکیل و گسترش طوفان و متغیرهای مؤثر در آنها می‌تواند متفاوت باشد، این روش مورد مطالعه قرار گیرد تا بتوان به تدریج یک راه‌حل عملی را برای گسترش این پیش‌بینی‌ها بوجد آورد. به نظر می‌رسد که افزایش تعداد لایه‌های پنهان و نیز افزایش تعداد نورون‌ها در این لایه کمک چندان زیادی در جهت بهبود عملکرد شبکه نمی‌کند، بلکه سرعت همگرایی آن را کم می‌کند. در عوض پیشنهاد می‌شود تا در کارهای مشابه بیشتر بر انتخاب مناسب متغیرهای ورودی و نیز انتخاب متغیر خروجی به شکلی صحیح تکیه شود تا بتوان نتایج خوبی بدست آورد. لازم است تا برای تفکیک دقیق‌تر این رخدادهای تعاریف واضح‌تری از فرایند طوفان گرد و خاک شده و

- Lim, J.Y. and Chun, Y., 2006. The characteristics of Asian dust events in Northeast Asia during the springtime from 1993 to 2004. *Journal of Global and Planetary Change*, 52: 231-247.
- Lu, H., 1999. An Integrated Wind Erosion Modeling System with Emphasis on Dust Emission and Transport. Doctor of philosophy thesis. The University of New South Wales, Sydney, Australia.
- Maier, H.R. and Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modeling & Software*, 15: 101-124.
- Marquardt, D.W., 1963. An algorithm for the least-squares estimation of nonlinear parameters. *SIAM Journal of Applied Mathematics*, 11(2):431-441.
- Middleton, N.J., 1986. A geography of dust storms in South-West Asia. *Journal of Climatology*, 6: 183 – 196.
- Mittelman, H.D., 2004. The Least Squares Problem. [web page] <http://plato.asu.edu/topics/problems/nlolsq.html>, Jul. [Accessed on 4 Aug. 2004].
- Nørgaard, M., 2000. Neural Network Based System Identification Toolbox. Technical Report 00-E-891, Department of Automation. Technical University of Denmark. 108 p.
- Salehi, F., Prasher, S.O., Amin, S., Madani, A., Jebelli, S.J., Ramaswamy, H.S., Tan, C. and Drury, C.F., 2000. Prediction of annual nitrate-N losses in drain outflows with artificial neural networks. *Transactions of the ASAE*, 45(5):1137-1143.
- S.Sarle, W., 2002. ai-faq/neural-nets/part2. <ftp://ftp.sas.com/pub/neural/FAQ2.html>. Last-modified: 2002-10-11.
- Song, Z., 2004. A numerical simulation of dust storms in China. *Journal of Environmental Modelling & Software* 19: 141-151.
- Squires, R.V., 2001. Dust and sand storms: An early warning of impending disasters: 15-28. In: Youlin, Y., Squires, R. V., Qi, L., (Ed). *Global alarm: Dust and storms from the world's dryland*. United Nations. 343 p.
- Sudheer, K.P., Gosain, A.K. and Ramasastri, K.S., 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of Irrigation and Drainage Engineering*, (129): 214-218.
- Trajkovic, S., Todorovic, B. and Stankovic, M., 2003. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of Irrigation and Drainage Engineering*, (129): 454-457.
- Trigo, R.M. and Palutikof, J.P., 1999. Simulation of daily temperatures for climate change scenarios over Portugal: a neural network model approach. *Journal of Climate Research*, 13: 45-59.
- Amin, S. and Soltani, A.R., 2003. Using Artificial Neural Networks in Prediction Runoff and Sediment. *Water Saving Agriculture and Sustainable use of Water and Land Resources*, (2): 821-832.
- Benne, M., Grondin-Perez, B., Chabriat, J.P. and Herve, P., 2000. Artificial neural networks for modeling and predictive control of an industrial evaporation process. *Journal Of Food Engineering*, (46): 227-234.
- Cheng, T., Peng, Y., Feichter, J. and Tegen, I., 2007. An improvement on the dust emission scheme in the global aerosol-climate model ECHAM5-HAM. *Journal of Atmospheric Chemistry and Physics Discussions*, 13959-13987.
- De Vos, N.J. and Rientjes, T.H.M., 2005. Objective functions in artificial neural network training for rainfall-runoff modeling. *Journal of Geophysical Research Abstracts*, 7.
- Engelstaedter, S., 2001. *Dust Storm Frequencies and Their Relationship to Land Surface Conditions*. Friedrich-Schiller University. Berlin.
- Haykin, S., 1994. *Neural Networks, a comprehensive Foundation*. 1st ed. Macmillan college publishing company, New York, NY.
- Hessami, M., Ancil, F. and A. Viau, A., 2004. Selection of an artificial neural network model for the post-calibration of eather radar rainfall estimation. *Journal of Data Science* 2: 107-124.
- Hetch-Nielsen, R., 1990. *Neurocomputing*. Addison-Wesley publishing company, reading, MA.
- Hsu, K.L. Gupta, H.V. and Sorooshian, S., 1995. Artificial neural network modeling of the rainfall-runoff process. *Journal of Water Resources Research*, 31(10): 2517 - 2530.
- Hsu, C., Chang, C. and Lin, C., 2007. *A Practical Guide to Support Vector Classification*. Department of Computer Science National Taiwan University, Taipei 106, Taiwan. Available on <http://www.csie.ntu.edu.tw/~cjlin>. Last updated: July 18, 2007.
- Huang, M., Peng, G., Zhang, J. and Zhang, S., 2006. Application of artificial neural networks to the prediction of dust storms in Northwest China. *Journal of Global and Planetary Change* 52: 216-224.
- Lasserre, F., Cautenet, G., Alfaro, S.C., Gomes, Rajot, J.L., Lafon, S., Gaudichet, A., Chatenet, B., Maille, M., Cachier, H., Chazette, P. and Zhang, X.Y., 2005. Development and validation of a simple mineral dust source inventory suitable for modeling in North Central China. *Journal of Atmospheric Environment*, 39: 3831-3841.
- Levenberg, K., 1944. A method for the solution of certain non-linear problems in least squares. *quarterly of applied mathematics*, 2(2):164-168.

- international joint workshop on sand and dust storms, KOICA.
- Zhang, G., Patuwo, B.E. and Hu, M.Y., 1998. Forecasting with artificial neural network: The State of Art, International Journal of Forecasting, 14: 35-62.
 - Zhang, X.Y., 2006. Development of a regional sand and dust storm early warning system (SDS-EWS) in north east Asia. ECW III.
 - Westwell, I., 1999. Fact Finder Guide Weather. PRC Publishing. 57-58 p.
 - Wetphal, D.L., 2002. Status and Future of Dust Storm Forecasting. Available in naval research laboratory.
 - Willmott, C.J., 1982. Some comments on the evaluation of model performance. Bulletin American Meteorological Society. 63:1309-1313.
 - Yoo, H.D., 2006. Korea Meteorological Administration (KMA) Sand and Dust Storm (SDS) operational forecasting system. The 2nd

Application of artificial neural networks in dust storm prediction (case study: Zabol city)

Jamalizadeh Tajabadi, M.R.^{1*}, Moghaddamnia, A.R.², Piri, J.³ and Ekhtesasi, M.R.⁴

1*- Corresponding Author, MSc. Student of Desertification, Faculty of Natural Resources, University of Zabol, Zabol, Iran,
Email: jamalizadeh81@yahoo.com

2- Assistant Professor, Group of Range and Watershed, Faculty of Natural Resources, University of Zabol, Zabol, Iran.

3-Senior Research Expert, Office of Jihad- e- Agriculture, Zabol, Iran.

4- Associate Professor, Group of Range and Watershed, Faculty of Natural Resources, University of Yazd, Yazd, Iran.

Received: 24.02.2008

Accepted: 19.01.2009

Abstract

Dust storms are common climatic events in arid, semi arid and desert regions of the world. These events impact human resources by foundation losses, every year. Accurate prediction of these events can be effective for decision support in environmental, health, army, and other related fields. An artificial neural network is a method which can predict nonlinear problems. In this study we attempted to predict dust storms and low visibility in Zabol city using synoptic data. Result indicates that this method is somewhat successful and appears that via identification of much more dust storm occurrence process, we can do more accurate prediction.

Key word: dust storm, minimum visibility, artificial neural network, prediction, Zabol.