پیش‌بینی بادجستی با شبکه پیشخور توسط الگوریتم یادگیری پس‌انتشار ارتجاعی

فریده حبیبی

استادیار ، موسسه ژئوفیزیک دانشگاه تهران ، fhabibi@ut.ac.ir

چکیده

این تحقیق کارایی شبکه‌های عصبی را در پیش‌بینی بادجستی نشان می‌دهد. داده‌ها مربوط به ۲۷ کمیت اندازه‌گیری شده در ایستگاه مهرآباد در بازه زمانی مارس تا اوت ۲۰۱۳ است که بین بازه ۰/۱ و ۰/۹ نرمال‌سازی سپس به‌صورت تصادفی با نسبت های۷۰، ۱۵ و ۱۵ درصد بترتیب برای آموزش، آزمون و اعتبارسنجی شبکه اختصاص داده‌شدند. ۲۵ کمیت به‌عنوان ورودی به‌شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی، تابع سیگموئید و هشت نرون در لایه پنهان، و تابع خطی در لایه خروجی داده‌شد، خروجی شبکه سمت و سرعت بادجستی بود. مقادیر ضریب‌تعیین در پیش‌بینی سرعت‌باد برای داده‌های آموزش، ... بترتیب۰/۹۹۹۳، ۰/۹۹۹۱ و ۰/۹۹۹۱ شد که نشان می‌دهند نزدیک به ۱۰۰ در صد مقدار سرعت‌باد تحت‌تاثیر متغیرهای مستقل بوده‌است. اما در پیش‌بینی جهت‌باد بترتیب ۰/۸۵۹۸، ۰/۸۵۸۶ و ۰/۸۴۷۱ شد که نشان می‌دهند نزدیک به ۸۵ در صد مقدار جهت‌باد تحت‌تاثیر این متغیرهای مستقل بوده و مابقی تغییرات آن وابسته به سایر عوامل است.

واژه‌های کلیدی: ایستگاه مهرآباد، بادجستی، پس‌انتشار ارتجاعی، پیش‌بینی جهت‌باد، سرعت‌باد، شبکه پیش‌خور

Prediction gust wind by feedworward network with resilient backpropagation algorithm

Farideh Habibi

Assistant Prof., Space Physics Department, Institute of Geophysics, University of Tehran, Iran

Abstract

Meteorological phenomena are complex systems with different parts that are in contact with each other and also with 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 the gust wind and direction which is widely used in meteorology and aviation especially at airports was been selected for analysis. The data is related to the 27 measured quantities at Mehrabad Auto station during the period from March to August 2013. Initially, the data were normalized between 0.1 and 0.9, and then randomly assigned with 70, 15 and 15 percent ratios for training, testing and validation data of the network. After the initial processing, 25 quantities were fitted as inputs to the feed forward network with resilient back propagation learning algorithm, 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 works with eight neurons and sigmoid function in the hidden layer, the linear function in the output layer, and the outputs of network are also the wind speed and direction. The results show that the appropriate amounts of learning rate, incremental and reduced rates for this network are respectively 0.001, 1.2 and 0.35. The values of the coefficient of determination for training, test and validation data for gust speed prediction were respectively 0.9993, 0.9991 and 0.9991. These values are shown that nearly 100 percent of measured gust speed is affected by these independent variables. But about the gust direction, these values are 0.8598, 0.8586 and 0.8471 and the rest of its variations are dependent on other factors.

Keywords: Mehrabad Autostation, gust wind, resilient backpropagation, gusty direction prediction, feedforward network

۱ مقدمه

پدیده‌های هواشناسی سیستم‌های پیچیده‌ای هستند که در تماس با هم و محیط اطراف هستند. برخی از آنها در یک بازه زمانی کوتاه مدت؛ و در یک ناحیه خاص و با یک دوره تناوب خاص خود شکل گرفته و از بین می‌روند برای مثال می‌توان به توفان‌های تندری اشاره کرد که در میان مقیاس با ابعاد افقی یک تا ۱۰۰۰ کیلومتر و در بازه زمانی یک ساعت تا یک روز رخ

می‌دهد. این پدیده توسط ابر کومه‌ای‌بارا ایجاد می‌شود. در داخل این ابر فراهنج و فروهنج‌های قوی شکل می‌گیرد که در برخورد فروهنج با سطح زمین جبهه گاستی(Gust front) شکل گرفته و سمت و سرعت باد بطور ناگهانی تغییر می‌یابد. فعالیت این پدیده از نظر هوانوردی بویژه در فرودگاه‌ها در هنگام نشست و بلند شدن هواپیما حائز اهمیت است. هدف این تحقیق نمایش کارایی شبکه‌های عصبی در پیش‌بینی متغیرهای هواشناسی است. برای این منظور پیش‌بینی سمت و سرعت باد جستی در یک ایستگاه خودکار برای بررسی انتخاب شده‌است.

شبکه‌های عصبی که از مغز انسان الگوبرداری شده و می‌تواند رابطه غیرخطی موجود بین دو مجموعه متفاوت از متغیرها را بیابد نخستین بار توسط مک‌کلوچ و پیتز در دهه ۱۹۴۰ با استفاده از توابع حسابی و پردازش منطقی معرفی 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. اما شبکه‌های عصبی به‌طور جدی از سال ۱۹۹۱ در ادبیات هواشناسی وارد شدند و خیلی زود نیز به‌عنوان یک تکنیک استاندارد پذیرفته شدند. امروزه در بسیاری از مراکز پیش‌بینی از آنها در پیش‌بینی دمای حداقل، مه، تخمین بارش از تصاویر ماهواره‌ای، پیش‌بینی ریزش برف و باران از تصاویر رادار هواشناسی، پیش‌بینی رعد و برق، پیش‌بینی تورنادو، تعقیب هاریکن، تشخیص ابر با حسگرهای زمینی، طبقه‌بندی ابر با سنجش از دور، شناسایی پوشش یخ روی سطح دریا و تعقیب حرکت آن با استفاده از سنجش از دور، پیش‌بینی ال نینو و ... استفاده می‌شود. از پیوند شبکه عصبی با منطق فازی نیز در تشخیص جابه جایی الگوها و تخریب الگوها و همچنین پیش‌بینی ازن استفاده می‌شود(هانسن ۱۹۹۷). در اینجا برای نمونه به برخی از کارهای سال‌های اخیر اشاره می‌شود.

شانک و همکاران در ۲۰۰۸، دمای نقطه‌شبنم 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 بکار رفتند. مدل بهینه آنها ۶۰ نرون در لایه پنهان، محدوده اولیه وزن‌های شبکه ۰/۱۵± و نرخ یادگیری ۰/۳۵ بوده و خطای شبکه برای پیش‌بینی ۱، ۴، ۸ و ۱۲ ساعت آینده بترتیب ۰/۵۵۰، ۱/۲۳۴ ، ۱/۷۹۹ و ۱/۲۸۰ درجه سلسیوس است.

لیتا و همکاران در ۲۰۱۳ تاثیری که توفان تندری در سوم، ۱۱ام و ۱۵ام می 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-مارکوآت و دلتا بار دلتا (Delta-Bar-Delta) برای پیش‌بینی استفاده کردند. و نتایج را با داده‌های دیده‌بانی مقایسه کردند و نشان دادند که در بین الگوریتم‌های انتخابی، لونبرگ-مارکوآت در پیش‌بینی یک تا سه ساعت آینده بخوبی توانسته افت وخیز ناگهانی دما و رطوبت نسبی ساعتی را تشخیص دهد ولی در پیش‌بینی شش تا ۲۴ ساعت آینده از دقت خوبی برخوردار نیست.

عرب عامری و همکاران (۱۳۹۳) از سری زمانی داده های متار ایستگاه مهراباد در بازه زمانی ۲۰۰۵ تا ۲۰۱۳ و اعمال روشهای مختلف انتخاب ویژگی مانند معیار اطلاعات متقابل، روشهای انتخاب پیشرو، پسرو و گام به گام استفاده کرده و در نهایت به این نتیجه رسیدند که انتخاب ویژگی پسرو بهترین روش است. و اگر سرعت باد، دما، دمای نقطه شبنم، فشار و بایاس به عنوان ورودی به شبکه عصبی پرسپترون چند لایه داده شود شبکه میتواند سرعت باد را برای یکساعت آینده پیش بینی کند.

یوسفی و پورشرعیاتی (۱۳۹۳) 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 fitting با الگوریتم یادگیری LM را به‌عنوان بهترین شبکه معرفی کردند.

۲ روش تحقیق

داده‌های مورد استفاده در این تحقیق متعلق به ایستگاه خودکار مهرآباد و در بازه زمانی مارس تا آگوست ۲۰۱۳ است. این ایستگاه کمیت‌ها را بطور همزمان و بفواصل زمانی یک دقیقه توسط سه سنجنده مختلف اندازه‌گیری می‌کند. در این بررسی

فقط اطلاعات سنجنده میانی در فاصله ۶۰۰ متری وسط باند، و در جهت شمال باند قرار دارد، ارائه شده است. فهرست کمیت های اندازه‌گیری شده توسط این سنجنده در جدول ۱ ارائه شده‌است.

از آنجا که کمیت‌های اندازه‌گیری شده از مرتبه یکسان نیستند برای اینکه دقت محاسبات را بالا برده و نتایج بهتری حاصل شود از تکنیک استانداردسازی min-max استفاده شد. مزیت تکنیک در این است که تمام روابط بین داده‌ها را حفظ کرده و نیاز به معرفی بایاس نیست، استانداردسازی داده‌ها در این تکنیک از رابطه زیر بدست می‌آید.

$$x_{i,a\ to\ b} = a + \frac{(x_i - x_{Min})(b-a)}{(x_{Max} - x_{Min})} \qquad (۱)$$

در رابطه فوق x_i ، x_{Min} و x_{Max} بترتیب داده‌های ورودی واقعی، کمینه و بیشینه آنها است. a و b مقادیر کمینه و بیشینه هدف هستند. $x_{i,a\ to\ b}$ داده iام نرمالیز شده در فاصله a تا b است. بازه استانداردسازی داده‌ها در این تحقیق بین ۰/۹-۰/۱ است. برای تهیه داده‌های آزمون و اعتبارسنجی، داده‌های ورودی به شبکه ۸۴۴۷۲ نمونه بودند که بترتیب با نسبت‌های ۷۰، ۱۵ و ۱۵ درصد و بصورت تصادفی تقسیم شدند. اما برای اعتبارسنجی شبکه طراحی شده از داده‌های ماه اوت که ۴۴۱۲۸ نمونه را شامل بود استفاده شده‌است.

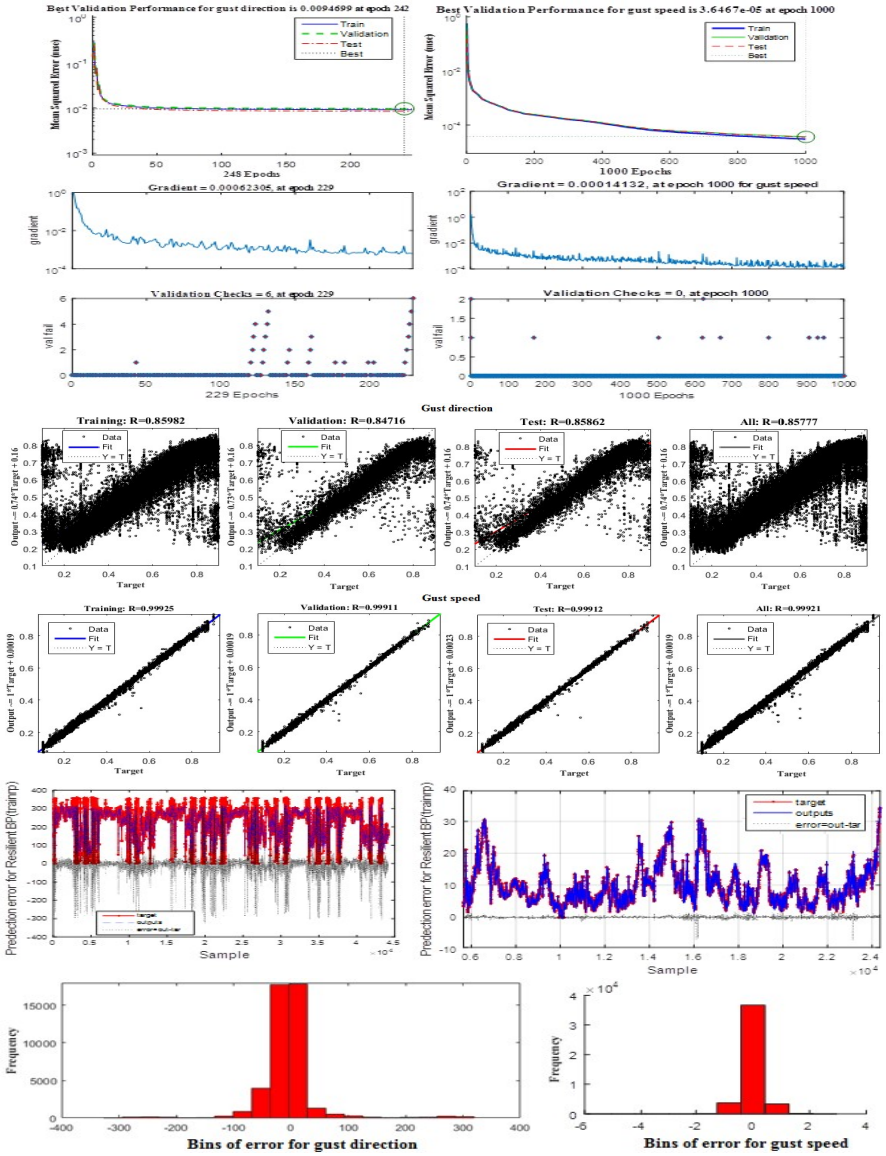

شکل ۱. نتایج حاصل از آزمایش شبکه پیش‌خور با الگوریتم یادگیری پس‌انتشار ارتجاعی بر روی داده‌های ایستگاه خودکار مهرآباد در بازه زمانی مارس تا اوت سال ۲۰۱۳؛ در نمودارهای سمت راست مربوط به پیش‌بینی سرعت باد گاستی و سمت چپ مربوط جهت باد گاستی است.

سطح خطای شبکه نیز توسط معیار جذر میانگین مربعاتخطا(RMSE) که بیانگر میزان انحراف پیش‌بینی از مشاهده واقعی است از رابطه ۲ و ضریب تعیین که میزان انحراف داده‌های خروجی شبکه از داده‌های هدف را نشان می‌دهد (هر چه به عدد یک نزدیک باشد خطا کمتر است) از رابطه ۳ سنجیده شده‌است.

$$\mathrm{RMSE} = \left((1/n)\sum_{i=1}^{n}|t_i - o_i|^2\right)^{1/2} \qquad (۲)$$

$$\mathrm{R}^2 = 1 - \frac{\sum_{i=1}^{n}(t_i - o_i)^2}{\sum_{i=1}^{n}(t_i - \bar{t})^2} \quad ; \quad \bar{t} = \frac{1}{n}\sum_{i=1}^{n} t_i \qquad (۳)$$

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

نتایج خروجی این شبکه در شکل ۱ ارائه شده است. نمودارهای ارائه شده در سمت راست این شکل مربوط به پیش‌بینی سرعت و سمت چپ مربوط به پیش‌بینی جهت باد است. مقایسه این دو نشان می‌دهد که در سمت چپ بعد از ۲۴۲ تکرار آموزش متوقف شده، حالت‌های شکست در سمت چپ خیلی بیشتر از سمت راست، مقادیر R مربوط به جهت باد کمتر از سرعت باد است، مقایسه نمودارهای مربوط به خطا نیز نشان می‌دهد که بیشینه خطا در مورد سرعت بین منفی یک تا یک است، ولی جهت تقریبا بین ۵۰- تا ۵۰+ است.

جدول۱. کمیت‌های اندازه‌گیری شده توسط سنجنده ایستگاه خودکار.

	کد	تفسیر		کد	تفسیر
1	WSINS	سرعت باد لحظه ای	14	WD10X	حداکثر جهت باد در ده دقیقه
2	WS2M	حداقل سرعت باد در دو دقیقه	15	GUST_SPEED	سرعت باد جستی
3	WS2A	متوسط سرعت باد در دو دقیقه	16	GUST_DIR	جهت باد جستی
4	WS2X	حداکثر سرعت باد در دو دقیقه	17	WDVAR	انحراف جهت بادد‌ر ده دقیقه گذشته
5	WS10M	حداقل سرعت باد در ده دقیقه	18	CW2A	مولفه های جهت باد در راستای باند پروازی
6	WS10A	متوسط سرعت باد در ده دقیقه	19	HW2A	مولفه های سرعت باد در راستای باند پروازی
7	WS10X	حداکثر سرعت باد در ده دقیقه	20	P0	فشار لحظه ای
8	WDINS	جهت باد لحظه ای	21	QNH	فشار ایستگاه نسبت به سطح دریاهای آزاد
9	WD2M	حداقل جهت باد در دو دقیقه	22	QFF3H	تغییرات سه ساعته فشار ایستگاه
10	WD2A	متوسط جهت باد در دو دقیقه	23	QFFT	مقدار مورد انتظار QFF در سه ساعت آینده
11	WD2X	حداکثر جهت باد در دو دقیقه	24	TEMP	دما
12	WD10M	حداقل جهت باد در ده دقیقه	25	RH	رطوبت نسبی
13	WD10A	متوسط جهت باد در ده دقیقه	26	DEW POINT	دمای نقطه شبنم

۳ نتیجه‌گیری

نتایج این تحقیق نشان می‌دهد که سمت و سرعت باد گاستی با این شبکه قابل پیش‌بینی است. مقادیر ضریب تعیین در حالت پیش‌بینی سرعت باد گاستی برای داده‌های آموزش، آزمون و اعتبارسنجی برای شبکه با ۸ نرون در لایه پنهان و نرخ یادگیری ۰/۰۰۱ بترتیب۰/۹۹۹۳، ۰/۹۹۹۱ و ۰/۹۹۹۱ بدست آمد که نشان می‌دهند نزدیک به ۱۰۰ در صد مقدار سرعت‌باد تحت‌تاثیر متغیرهای مستقل بوده‌است. اما در پیش‌بینی جهت‌باد گاستی بترتیب ۰/۸۵۹۸، ۰/۸۵۸۶ و ۰/۸۴۷۱ شد که نشان می‌دهند نزدیک به ۸۵ در صد مقدار جهت‌باد تحت‌تاثیر این متغیرهای مستقل بوده و مابقی تغییرات آن وابسته به سایر عوامل است. بنابراین می‌توان نتیجه گرفت که دقت شبکه طراحی شده در پیش‌بینی سرعت باد گاستی بیشتر از جهت باد گاستی است.

منابع

عرب عامری، م.، حبیبی، ف.، کلهر، ا.، ۱۳۹۳، پیش بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چند لایه در فرودگاه مهراباد، مجموعه مقالات شانزدهمین کنفرانس ژئوفیزیک ایران، ص ۱۲۲-۱۱۷

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

Hansen, B., 1997, State of the Art of Neural Networks in Meteorology. Mid-term Paper for Neural Networks course at the, Technical University of Nova Scotia, March 10, Neural Networks in University of Nova Scotia, March 10, 1997

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 Vol. 2013, Article ID 525383, 14 pages, http://dx.doi.org/10.1155/2013/525383

Shank, D. B., Hoogenboom, G., Mcclendon, R. W., 2008, Dewpoint Temperature Prediction Using Artificial Neural Networks. J. Appl. Meteor.and Climat, 47, 1757–1769.