

فروردین، اردیبهشت، خرداد، تیر، مرداد و شهریور از دقت بالاتری برخوردار می‌باشد. در مقایسه میان مدل‌های شبکه عصبی پیشخور پس انتشار خطا با توابع آموزشی لورنبرگ مارکوات و درخت تصمیم با توابع آموزشی کارت (CART)، شبکه عصبی با ضریب همبستگی ۰/۸۷ و مجذور میانگین مربعات خطای ۰/۸۶ نسبت به روش درخت تصمیم با ضریب همبستگی ۰/۸۶ و مجذور میانگین مربعات خطای ۰/۰۶ از دقت بالاتری به منظور شبیه‌سازی طوفان گرد و خاک برخوردار است.

واژه‌های کلیدی: طوفان گرد و غبار، شبکه عصبی، درخت تصمیم، الگوریتم کارت، ضریب گاما، استان یزد

مقدمه

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 هوا است. براساس طبقات مختلف دید، طوفان گرد و خاک نیز به انواع مختلف و با تعاریف و اسامی مختلفی 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. [۲۸].

طوفان‌های گرد و خاک حوادث طبیعی هستند که در مناطق خشک، نیمه خشک و بیابانی دنیا به فراوانی رخ می‌دهند [۲۵].

استان یزد ۱۹ درصد بیابان‌های ایران را در خود جای داده و دومین استان بیابانی کشور ایران محسوب می‌شود. وقوع طوفان‌های گرد و خاک و هجوم ماسه‌های روان از پدیده‌های شایع و در عین حال نامنظم طبیعی در استان به شمار می‌رود. هر چند که وقوع طوفان‌ها در بعضی از فصول و یا ماه‌های سال بیشتر لیکن شناسایی و پیش‌بینی آنها نیاز به مطالعات دقیق آماری دارد [۸].

بیش از ۷۷ درصد بادهای شدید حاکم بر دشت یزد از سمت ۲۵۰ تا ۳۳۰ درجه می‌وزد که سرعت آنها بین ۱۵-۲۹ متر بر ثانیه در نوسان است. ساعات وقوع طوفان‌های گرد و خاک که بعضاً شهر یزد را در تاریکی مطلق فرو می‌برد عموماً بعد از ظهرها می‌باشد. تغییرات سریع فشار و دمای هوا در این موقع از روز علت اصلی وقوع این پدیده می‌باشد [۹].

در حدود ۵۰ درصد از بادهای شدید و طوفانی استان یزد در ماه‌های اردیبهشت و فروردین رخ می‌دهند. ناپایداری‌های جوی در ماه‌های

مقایسه مناسب‌ترین ترکیب ورودی در روش‌های شبکه عصبی مصنوعی و درخت تصمیم به منظور شناسایی عوامل تأثیرگذار بر پدیده گرد و غبار (مطالعه موردی: استان یزد)

محمدرضا اختصاصی^۱، محسن یوسفی^۲ و محمود توکلی^۳
تاریخ دریافت: ۱۳۹۱/۱۱/۲۰ تاریخ پذیرش: ۱۳۹۳/۰۳/۲۷

چکیده

یکی از بلاهای طبیعی که هر ساله موجب خسارت‌های زیادی در نواحی خشک و بیابانی جهان از جمله ایران و منطقه یزد می‌شود، بادهای شدید و شکل‌گیری طوفان گرد و خاک است که هر ساله چندین مرتبه به وقوع می‌پیوندد. در این مطالعه از داده‌های هواشناسی ایستگاه یزد (طوفان تندر، بزرگی باد (اندازه، مقدار)، تداوم باد (پیوستگی باد)، دید افقی، سریع‌ترین سرعت باد، میانگین سرعت باد، سرعت باد غالب و تعداد وقوع طوفان گرد و خاک ثبت شده توسط اداره هواشناسی (اعم از طوفان‌های با منشاء داخلی و خارجی)) در بازه زمانی ۱۹۵۳-۲۰۰۵ به صورت ماهانه استفاده شد. به منظور تعیین مناسب‌ترین ترکیب ورودی مدل شبکه عصبی و تعداد پارامترهای (ورودی) تأثیرگذار بر پدیده طوفان گرد و خاک از روش‌های کاهش متغیر تحلیل عاملی (حداکثر احتمال، مؤلفه اصلی)، تجزیه مؤلفه‌های اصلی، آزمون تست گاما و رگرسیون گام به گام پیش رونده استفاده شد. هر کدام از روش‌های مذکور ترکیب متفاوتی را ارائه نمودند که هر کدام از این ترکیب‌ها در مدل شبکه عصبی پیش‌خور پس انتشار با توابع آموزشی لورنبرگ مارکوات استفاده شد. نتایج به‌دست آمده نشان داد که رگرسیون گام به گام پیش رونده با $R^2=0/87$ و $RMSE=0/04$ مناسب‌ترین ترکیب را برای مدل شبکه عصبی ایجاد می‌کند. مقایسه شبیه‌سازی پدیده طوفان گرد و خاک در فصول و ماه‌های مختلف سال نشان داد که شبیه‌سازی پدیده گرد و غبار فصل‌های تابستان و بهار و همچنین ماه‌های

۱- استاد دانشکده منابع طبیعی، دانشگاه یزد

۲- کارشناس ارشد آبخیزداری، دانشگاه یزد

Mohsenyosefi67@gmail.com

۳- کارشناس ارشد آبخیزداری، اداره هواشناسی استان یزد

اعتدال بهاری را می‌توان مهم‌ترین عامل وقوع این پدیده دانست [۹]. بیش از ۶۵۹ هزار هکتار از عرصه‌های بیابانی در ۱۹ نقطه از استان یزد به عنوان کانون‌های بحرانی حساس به فرسایش بادی مورد شناسایی قرار گرفته که با وقوع هر طوفان، مقادیر زیادی ذرات خاک از این کانون‌ها بلند شده و بر سر شهرها و نقاط سکونتگاهی استان فرو می‌ریزد [۹].

پیش‌بینی دقیق مکانی و زمانی این رخداد‌های طبیعی از جمله طوفان می‌تواند کمک زیادی به بهبود زندگی در این مناطق باشد. با هشدارهای لازم قبل از وقوع طوفان گرد و خاک می‌توان شهروندان را از خطرات بهداشتی آگاه ساخت. همچنین در بخش ترابری هوایی و زمینی کاهش دید ناشی از وقوع این طوفان‌ها خسارت آفرین است که مقابله با این خسارت‌ها نیازمند پیش‌بینی این رخداد‌ها می‌باشد [۱۵]. در سطح جهان بررسی‌های زیادی در مورد روز طوفانی و طوفان‌های گرد و خاک انجام شده است. چنونین و همکاران [۶] در این مورد مطالعاتی را در شمال چین انجام داده و بیان کردند که با افزایش رطوبت خاک میزان طوفان‌های شدید و فرسایش بادی کاهش پیدا می‌کند. فنگ و همکاران [۱۰] در زمینه تأثیر طوفان‌های خاک را بر روی سلامتی و تنفس بررسی کردند و تغییرات تمرکز غبار در طول طوفان‌های خاک در تایوان را مورد مطالعه قرار داده و نشان دادند رابطه معنیداری بین آنها وجود دارد. اورلوسکی و همکاران [۱۹] طوفان‌های خاک را در ترکمنستان مورد مطالعه قرار دادند و توزیع فضایی، فراوانی و تغییرات فصلی این طوفان‌ها را بررسی کرده و بیان کردند که بیشترین تعداد روز طوفانی در فصل بهار و در منطقه بیابانی قره‌قوم وجود دارد. جمالی زاده تاج آبادی و همکاران [۱۵] در مطالعه‌ای به پیش‌بینی وقوع طوفان گرد و خاک با استفاده از روش شبکه‌های عصبی مصنوعی پرداختند. نتایج حاکی از دقت بالای پیش‌بینی کوتاه مدت وقوع طوفان‌ها نسبت به دوره‌های بلند مدت است. در حالی که پیش‌بینی میزان دید افقی در دوره‌های کوتاه‌مدت از موفقیت کمتری برخوردار بوده است. بنابراین به نظر می‌رسد با شناخت بهتر عوامل تأثیرگذار بر این طوفان‌ها بتوان پیش‌بینی‌های دقیقتری را با استفاده از این شبکه‌ها انجام داد.

هوانگ و همکاران [۱۳] از روش شبکه عصبی مصنوعی برای پیش‌بینی طوفان گرد و خاک در شمال غرب چین استفاده کردند و به این نتایج رسیدند که به طور متوسط ۷۱/۶ و ۶۸/۲ درصد طوفان‌ها را پیش‌بینی نمایند. راشکی و همکاران [۲۱] در مطالعه‌ای تحت عنوان طوفان‌های گرد و خاک و بارگذاری افقی گرد و خاک در منطقه سیستان به این نتایج دست یافتند که آنالیز AQI نشان می‌دهد ۶۱٪ روزها با ریسک بالای سلامتی، در صورتی که حتی ۳۰،۱٪ دارای خطر شناسایی شده‌اند. روش شبکه عصبی مصنوعی بر ای 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 [۲۷]، [۲۴]، [۴]. در ارتباط با بارش، رواناب و درجه حرارت نیز موارد فراوانی وجود دارند که از این روش استفاده کرده‌اند [۲۶].

[۱۲]، [۷]. همچنین در زمینه‌ی منابع آب و هیدرولوژی نیز استفاده‌های زیادی از این روش شده است [۲۲]، [۱۷]؛ [۲].

طوفان گردوخاک در منابع مختلف تعاریف متعدد و تا حدودی نامشخص دارد. اما مهم‌ترین متغیر در تشخیص وقوع طوفان گردوخاک وجود غبار و ذرات گرد و خاک در هواست. در هنگام ثبت داده‌ها در ایستگاه‌های هواشناسی سینوپتیک، هوایی که غبار داشته یا طوفان شن یا گردوخاک رخ داده باشد به چند دسته تقسیم می‌شود که مبنای این تقسیم‌بندی نیز بیشتر مقدار دید افقی است [۲۸]. در این تحقیق به پیش‌بینی مواردی از تعداد وقوع طوفان‌های گردوخاک پرداخته شده است که دید افقی در آنها به کمتر از ۱۰۰۰ متر می‌رسد. بر اساس اسناد علمی سازمان جهانی هواشناسی، دید افقی کمتر از ۱۰۰۰ متر همراه با پدیده گرد و خاک، طوفان تعریف می‌شود که در این مطالعه از این تعریف استفاده شده است [۱۵].

هدف از این مطالعه به دست آوردن یک روش مناسب برای تعیین مناسب‌ترین ترکیب ورودی برای مدل شبکه عصبی مصنوعی و تعیین

جدول ۱- تعداد طوفان‌ها در فصول و ماههای مختلف

Table 1. Number of storms in the different seasons and months

فصول سال Seasons year	ماههای سال Months year	تعداد طوفان اتفاق افتاده Number of storm happened
بهار Spring	فروردین April	358
	اردیبهشت May	473
	خرداد June	553
تابستان Summer	تیر July	438
	مرداد August	394
	شهریور September	261
پاییز Autumn	مهر October	177
	آبان November	171
	آذر December	93
زمستان Winter	دی January	102
	بهمن February	107
	اسفند March	215
جمع Sum	-	3342

جدول ۲- مشخصات پارامترهای ورودی و خروجی داده‌ها

Table 2. Characteristic parameters data input and output

نحوه تهیه	واحد داده	نوع داده	نام پارامتر
Purvey style	Data unite	Data type	Paramater
یزد	تعداد وقوع	کمی-ورودی	طوفان تندر
Yazd	Number	Quantitative-	Thunder
	happened	input	storms
یزد	نات	کمی-ورودی	بزرگی
Yazd	Not	Quantitative-	wind
		input	magnitude
یزد	نات	کمی-ورودی	تداوم باد
Yazd	Not	Quantitative-	wind
		input	duration
یزد	متر	کمی-ورودی	دید افقی
Yazd	Meter	Quantitative-	Visibility
		input	
یزد	نات	کمی-ورودی	سریعترین
Yazd	Not	Quantitative-	سرعت باد
		input	fastest wind
			speed
یزد	نات	کمی-ورودی	میانگین
Yazd	Not	Quantitative-	سرعت باد
		input	average
			wind speed
یزد	نات	کمی-ورودی	سرعت باد
Yazd	Not	Quantitative-	غالب
		input	prevailing
			winds
یزد	تعداد وقوع	کمی-خروجی	تعداد وقوع
Yazd	Number	Quantitative-	طوفان
	happened	output	Number
			dust storms

درخت تصمیم یکی از روش‌های داده‌کاوی و از ابزارهای قوی و متداول برای دسته‌بندی و پیش‌بینی می‌باشد و همچنین می‌توان از داده‌های غیر عددی نیز استفاده نمود. درخت تصمیم در ابتدا مقدار یک ویژگی را در نظر می‌گیرد و از آن تفکیک (شاخه‌ها) انجام می‌شود. هر شاخه‌ی حاصل از درخت سرانجام به یک نتیجه (برگ) منجر می‌شود. به همین ترتیب برای ساخت درخت تصمیم با استفاده از الگوریتم CART نیز، از مجموعه‌ای از داده‌ها با کلاس‌های از قبل تعیین شده برای همه نمونه‌ها استفاده می‌شود. درخت تصمیم با مجموعه سؤالاتی که نمونه‌های آموزشی را به قسمت‌های کوچک‌تری می‌شکند نمایش داده می‌شود [۱]. ساختار این درخت بر سه اصل استوار است:

عوامل تأثیرگذار بر پدیده طوفان گرد و خاک است. بعد از تعیین مناسب‌ترین ترکیب، مدل شبکه عصبی با درخت تصمیم مقایسه شد و فصل‌ها و ماه‌هایی که در آنها وقوع طوفان‌های گرد و خاک شبیه‌سازی مناسب‌تری انجام شده است، شناسایی و معرفی خواهد شد.

مواد و روش‌ها

در این مطالعه، داده‌های بازه زمانی حدود ۵۰ سال ایستگاه سینوپتیک شهرستان یزد طی دوره آماری ۱۹۵۳-۲۰۰۵ میلادی به صورت ماهانه مورد استفاده قرار گرفت. داده‌ها پس از اخذ، ابتدا مورد بازنگری و رفع نقص قرار گرفت و بعضاً بازسازی لازم بر اساس روش‌های همبستگی و یا جرم مضاعف مهدوی [۲۱] انجام شد. تعداد کل طوفان‌های اتفاق افتاده در منطقه مورد مطالعه در جدول ۱ ارائه شده است.

داده‌های ورودی روش‌های آماری مذکور، تعداد وقوع طوفان تندی، بزرگی باد (اندازه، مقدار)، تداوم باد، دید افقی، سریع‌ترین سرعت باد، میانگین سرعت باد، سرعت باد غالب است و همچنین اتفاق افتادن پدیده (وجود) طوفان گرد و خاک به عنوان پارامتر خروجی روش‌ها معرفی شد. طوفان تندر و طوفان گرد و خاک به صورت تعداد دفعات اتفاق افتاده، به صورت کمی استفاده شده است. البته در تحقیق حاضر از متغیرهای بیشتری به عنوان ورودی استفاده گردید که به دلیل نامناسب بودن برای مدل‌های مورد استفاده از جمله مدل شبکه عصبی مصنوعی در ادامه محاسبات مورد استفاده قرار نگرفت. داده‌های فصل‌های پاییز و زمستان نیز به دلیل اینکه طوفان گرد و خاک در ماه‌های مذکور کمتر اتفاق افتاده و اکثر داده‌ها صفر می‌باشد در جواب مدل تأثیر منفی می‌گذارند. به منظور جلوگیری از این مشکل داده‌های فصول مذکور حذف شدند. به عبارتی دیگر از داده‌های تعداد وقوع طوفان گرد و خاک استفاده شد و داده‌های عدم وقوع (صفر) از مدل حذف شد.

در این مطالعه علاوه بر مدل شبکه عصبی مصنوعی از مدل درخت تصمیم نیز استفاده گردید. در مدل شبکه عصبی در مرحله آموزشی لورنبرگ مارکوآت با تابع انتقال سیگموئید [۱۴] (این تابع انتقال در شبکه‌های پس انتشار) استفاده گردید. این تابع انتقال مقادیر ورودی را در محدوده $-\infty$ تا $+\infty$ دریافت کرده و خروجی بین ۰ و ۱ را تولید می‌نماید. این تابع متداول‌ترین تابع انتقال بوده و شکلی مانند S دارد که رفتار اغلب پدیده‌های طبیعی را در بر می‌گیرد [۱۴]. در مدل درخت تصمیم نیز از الگوریتم کارت اکبری و همکاران [۱] استفاده شد.

الگوریتم لورنبرگ مارکوآت

این روش نیز سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس هیسین دارد. بسیار سریعتر از بقیه الگوریتم‌ها عمل می‌کند. اشکال عمده روش لورنبرگ مارکوآت نیاز آن به نگهداری ماتریس‌های حجیم در حافظه است و این مسئله نیاز به فضای زیادی دارد [۵].

مدل درخت تصمیم

۱- تعیین مجموعه‌ای از پرسش‌ها به شکل $x \leq d$? که در آن d یک متغیر مستقل و x مقدار ثابت است و جواب هر پرسش آری/نه است.
 ۲- بهترین معیار شکاف برای انتخاب بهترین متغیر مستقل برای شکاف
 ۳- ایجاد آمار خلاصه برای گره پایانی برایمین و همکاران [۳].
 در درختان طبقه‌بندی، برای انتخاب بهترین متغیر ورودی و ایجاد شاخه از شاخص Gini استفاده می‌شود.

$$gini(D) = 1 - \sum_{j=1}^n p_j^2 \quad (1)$$

که در آن p_j فراوانی نسبی کلاس j در مجموعه D و n تعداد کلاس‌های این مجموعه می‌باشد.

حال بهترین انتخاب برای مجموعه D به دو مجموعه D_1 و D_2 از معیار زیر تبعیت می‌کند:

$$gini_{split}(D) = \frac{|D_1|}{|D|} gini(D_1) + \frac{|D_2|}{|D|} gini(D_2) \quad (2)$$

که در آن D_1 و D_2 به معنای تعداد اعضای هر مجموعه می‌باشد. این معیار را برای همه متغیرها در گره امتحان کرده و آن متغیری که مقدار رابطه ۲ برای آن از همه کوچک‌تر باشد، برای ایجاد شاخه انتخاب می‌شود [۱۸].

الگوریتم کارت

درخت تصمیم در ابتدا مقدار یک ویژگی را در نظر می‌گیرد و از آن تفکیک (شاخه‌ها) انجام می‌شود. هر شاخه‌ی حاصل از درخت سرانجام به یک نتیجه (برگ) منجر می‌شود راندی و ولف [۲۰]. به همین ترتیب برای ساخت درخت تصمیم با استفاده از الگوریتم کارت نیز، از مجموعه‌ای از داده‌ها با کلاس‌های از قبل تعیین شده برای همه نمونه‌ها استفاده می‌شود.

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. در پایان، نتایج حاصل از مدل‌ها (خروجی‌ها) و رخدادهای واقعی طوفان با همدیگر مقایسه شده و از شاخص معیارهای ضریب همبستگی، ریشه‌ی میانگین مربعات خطا (RMSE) برای نشان دادن عملکرد مدل‌ها استفاده شده است.

رگرسیون گام به گام

وقتی که تعداد پارامترهای ورودی افزایش می‌یابد ارزیابی کلیه‌ی رگرسیون‌های ممکن به حجم محاسبات زیادی نیاز دارد. در این مطالعه سطح معینداری α سطح ۰/۰۵ انتخاب شده است. اولین متغیر مستقل که برای ورود به معادله انتخاب می‌شود آن است که بزرگترین همبستگی ساده را با متغیر وابسته‌ی طوفان گرد و خاک دارد. به همین ترتیب سرعت باد غالب به عنوان اولین پارامتر انتخاب شد. سرانجام مجموعه‌ای که با افزودن پارامتر مستقل دیگر در سطح α افزایش معینداری در آمارهی F ایجاد نشود، به عنوان بهترین ترکیب ورودی برای مدل‌سازی انتخاب می‌گردد [۱۱].

آزمون تست گاما

با استفاده از روش آزمون گاما برای پیش پردازش پارامترها می‌توان ترتیب میزان اهمیت پارامترهای ورودی، بهترین ترکیب از میان تمام ترکیب‌های ممکن برای ایجاد یک مدل هموار، برای ورود به شبکه‌ی عصبی مصنوعی را بدست آورد. در این روش ترکیب تمام پارامترهای ورودی به نرم‌افزار Wingamma معرفی شده و مقدار گاما تعیین شد. سپس به ترتیب هر کدام از پارامترها از ترکیب حذف می‌شود. در صورتی که گاما از گامای به دست آمده در ترکیب تمام پارامترهای ورودی کمتر باشد، پارامتر حذف شده در مدل‌سازی اثر منفی دارد و در صورتی که بزرگتر باشد، پارامتر حذف شده در مدل‌سازی اثر مثبت دارد. البته به این نکته باید توجه داشت که شاید یک پارامتر به تنهایی اثر منفی داشته باشد ولی ممکن است در ترکیب با پارامترهای دیگر اثرش مثبت شود. بر عکس این امر نیز صادق است.

نکته قابل توجه در استفاده از نرم‌افزار WinGamma این است که این نرم‌افزار داده‌ها را تنها با فرمت CSV می‌خواند. برای تبدیل داده‌های با فرمت اکسل به این فرمت از نرم‌افزار xls-converter همچنین با کدنویسی در نرم‌افزار متلب می‌توان داده‌ها را تبدیل نمود. در نرم‌افزار WinGamma پارامترهای ورودی به ترتیب با ۱ تعیین می‌شود. به‌طور مثال اگر چهار پارامتر ورودی داشته باشیم، در نرم‌افزار ۱۱۱۱ نمایش داده می‌شود. اگر هر کدام از ۱ها تبدیل به ۰ شود یعنی پارامتر مناظر با آن در ترکیب ورودی وجود ندارد [۲۳]. با استفاده از نرم‌افزار Wingamma ضریب گاما، شاخص ضریب استاندارد (SE) و V_{ratio} به دست آمد.

تحلیل عاملی (FA) و تجزیه مؤلفه‌های اصلی (PCA)

برای استفاده از روش‌های تحلیل عاملی و تجزیه مؤلفه‌های اصلی در گام اول باید داده‌ها استاندارد شود. از آنجا که متغیرهای مختلف در این مطالعه دارای مقیاس‌های اندازه‌گیری متفاوتی می‌باشند لذا به دست آوردن نمره Z و استاندارد نمودن آنها ضروری می‌باشد. بدین منظور مقدار میانگین و انحراف معیار متغیرها در هر یک از ماه‌ها و برای هر یک از ایستگاه‌ها تعیین گردیده و سپس استاندارد شده‌اند. در تحلیل عاملی از دو روش حداکثر احتمال (Maximum likelihood) و مؤلفه اصلی (principle component) استفاده شد که در هر ستون بالاترین مقدار به عنوان تأثیرگذارترین عوامل انتخاب شد. در این روش منفی بودن پارامتر در انتخاب عوامل تأثیرگذار نبوده و از منفی پارامتر چشم پوشی می‌شود. در روش تجزیه مؤلفه‌های اصلی از شاخص کوواریانس استفاده شد که نشان‌دهنده تغییرات بین دو متغیر است. در تجزیه مؤلفه‌های اصلی کلیه متغیرها به طور مساوی در نظر گرفته می‌شوند. در این روش بر خلاف روش رگرسیون چندگانه متغیرها به دو گروه متغیرهای مستقل و وابسته تقسیم نمی‌شوند بلکه هر مؤلفه اصلی مقداری از واریانس کل را تبیین می‌کند. بنابراین اولین مؤلفه اصلی حاوی بیشترین اطلاعات و دارای بالاترین واریانس است و آخرین مؤلفه دارای کمترین مقدار واریانس می‌باشد. در این روش پارامترهایی با اعداد منفی در نظر گرفته نشد به این دلیل که نشان‌دهنده تأثیر منفی بر روی متغیر می‌باشد به این

ترتیب پارامتر ورودی منفی از مدل کنار گذارده می‌شود. کلیه محاسبات روش‌های آماری نامبرده شده به جزء آزمون گاما با استفاده از نرم‌افزار Minitab انجام شد.

بعد از تعیین مناسب‌ترین روش تعیین ترکیب ورودی از میان چهار روش مذکور، رگرسیون گام به گام به عنوان مناسب‌ترین روش برای تعیین ترکیب ورودی تعیین شد. سپس با استفاده از ترکیب ورودی منتخب توسط روش رگرسیون گام به گام، شبکه عصبی به منظور شبیه‌سازی طوفان گرد و خاک مدل‌سازی شد و مدل شبکه عصبی با مدل درخت تصمیم مورد مقایسه قرار گرفته شد. درخت تصمیم به عنوان یکی از روش‌های هوش مصنوعی، مدل توانایی تعیین ترکیب ورودی را داراست و نیازی به تعیین ترکیب ورودی با استفاده از روش‌های مذکور نیست.

نتایج و بحث

اگر فرض شود a پارامتر ورودی بر وقوع پدیده‌های مؤثر باشند تعداد $2^a - 1$ ترکیب معیندار از پارامترهای ورودی وجود می‌آید که برای مدل‌سازی این پدیده با استفاده از ANN بررسی تکتک ترکیبات ایجاد شده برای یافتن بهترین ترکیب کاری بسیار وقت‌گیر و خسته‌کننده است. بنابراین هنگامی که عوامل مؤثر بر پدیده‌های بطور قابل ملاحظه‌ای زیاد باشد با استفاده از روش‌های مختلف می‌توان ترتیب میزان اهمیت پارامترهای ورودی و بهترین ترکیب از میان تمام ترکیب‌های ممکن را بدست آورد.

آزمون رگرسیون گام به گام

بر اساس نتایج آزمون رگرسیون گام به گام در مرحله‌ی نخست، سرعت باد غالب مهم‌ترین پارامتری است که برای ورود به مدل انتخاب می‌شود. پارامتر سرعت باد غالب دارای بیشترین مقدار ضریب همبستگی با تعداد وقوع طوفان گرد و خاک (روز طوفانی) به مقدار $0/86$ می‌باشد. بنابراین وقتی به مدل اضافه می‌شود مقدار ضریب تبیین را به $73/47$ می‌رساند. در گام بعدی پارامتر دید افقی با بیشترین مقدار F نسبت به سایر پارامترهای مستقل باقی مانده، به مدل اضافه می‌شود که باعث افزایش این ضریب به عدد $80/31$ می‌شود. سپس از میان مجموعه پارامترهای باقی مانده پارامتری که می‌تواند با بیشترین مقدار F و معینداری به مدل اضافه شود، تداوم باد (پیوستگی باد) است که ضریب تبیین مدل را به $80/27$ ارتقاء می‌دهد و به همین ترتیب پارامترهایی که در گام‌های بعدی می‌توانند در سطح α باعث ایجاد معناداری در مقدار F شوند، پارامتر میانگین سرعت می‌باشد و در نهایت اضافه نمودن پارامترهای طوفان تندر، بزرگی باد، سریعترین سرعت باد نمی‌تواند در سطح $0/05$ سبب ایجاد معینداری در مقدار آماره‌ی F شود. بنابراین مدل حاصل از روش رگرسیون گام به گام به روش پیشرو از پارامترهای ورودی به جز پارامترهای طوفان تندر، بزرگی باد، سریعترین سرعت باد برای مدل‌سازی طوفان گرد و خاک استفاده می‌نماید.

آزمون گاما

جدول ۳- نمونه‌ای از نتایج آزمون گاما و انتخاب مناسب‌ترین ترکیب ورودی

Table 3. Sample from Gamma Test result and select most appropriate combinations

V_{Ratio}	SE	Gamma	ترکیب پارامترها Parameter combinations
0/63889	0/015401	0/15972	1111111
<u>0/5632</u>	<u>0/019399</u>	<u>0/1408</u>	<u>0110101</u>
0/6824	0/012978	0/1706	0111001
0/75682	0/0090948	0/1892	0110011
0/7548	0/012961	0/1887	1011100
0/66201	0/013152	0/1655	1100011

در آزمون گاما بعد از تبدیل داده‌ها به فرمت CSV، داده‌ها به مدل وارد شده و با استفاده از شاخص‌های مختلف موجود در نرم‌افزار، ترکیب ورودی مناسب انتخاب شد. در این آزمون ترکیب‌های ورودی مختلف به صورت تصادفی از سوی نرم‌افزار تعیین می‌شود و تا جایی ادامه می‌یابد که اشتباه استاندارد بزرگترین مقدار، ضریب گاما و معیار بدون بعد V_{ratio} که دارای مقادیری بین 0 و 1 می‌باشند و هر چه این مقدار به صفر نزدیکتر باشد نمایانگر دقت بالای مدل برای یافتن خروجی‌های مطلوب از ورودی‌هاست شریفی و همکاران [۲۳]. که در این صورت ترکیب $0/110101$ شامل بزرگی باد، پیوستگی باد، سریعترین باد و سرعت باد غالب انتخاب شد و دید افقی، میانگین سرعت و طوفان تندر از ترکیب کنار گذاشته شد. در این مطالعه آزمون گاما با 100 دور تکرار انجام شد و در این میان، مناسب‌ترین ترکیب ورودی شبکه عصبی انتخاب شد. نتایج به طور خلاصه در جدول ۳ نشان داده شده است.

تحلیل عاملی و تجزیه مؤلفه‌های اصلی

داده‌ها بعد از نرمال شدن به نرم‌افزار Minitab ارائه شد و آزمون تحلیل عاملی و تجزیه مؤلفه‌های اصلی انجام شد. در روش تجزیه مؤلفه اصلی پیوستگی باد، سریعترین باد، سرعت باد غالب و دید افقی به عنوان ترکیب مناسب معرفی شد. در روش آماری تجزیه عاملی با استفاده از بخش حداکثر احتمال، ترکیب سریعترین باد، میانگین سرعت، بزرگی باد، پیوستگی باد و در بخش مؤلفه اصلی ترکیب سریعترین باد، سرعت باد غالب، میانگین سرعت، بزرگی باد، پیوستگی باد انتخاب شد. در هر دو روش آماری طوفان تندر به عنوان عامل نامؤثر بر پدیده طوفان گرد و خاک از ترکیب ورودی کنار گذاشته شده است. انتخاب ترکیب‌های متفاوت به وسیله روش‌های مذکور به دلیل استفاده از پارامترها و رابطه‌های مختلف در روش‌ها می‌باشد. بعد از انتخاب ترکیب ورودی با استفاده از روش‌های آماری آزمون گاما تست، رگرسیون گام به گام پیشرونده، تحلیل عاملی، تجزیه مؤلفه‌های اصلی، ترکیب انتخاب شده به مدل شبکه عصبی وارد شد و با استفاده

جدول ۴- نتایج روش‌های مختلف به منظور تعیین مناسب‌ترین ترکیب ورودی شبکه عصبی

Table 4. Result different styles sake select most appropriate input combinations neural network

RMSE	R ²	ترکیب ورودی input combination	روش آماری Statistic Style
0/078	0/84	پیوستگی باد (wind duration) سریعترین باد (wind fastest) سرعت باد غالب (prevailing wind) دید افقی (visibility)	تجزیه مؤلفه‌های اصلی (Principal Components Analysis)
0/04	0/87	سرعت باد غالب (prevailing wind) دید افقی (visibility) پیوستگی باد (wind duration) میانگین سرعت (average speed)	رگرسیون گام به گام پیشرونده (Stepwise Regression)
0/195	0/73	سریعترین باد (wind fastest) میانگین سرعت (average speed) بزرگی باد (wind magnitue) پیوستگی باد (wind duration)	تجزیه عاملی (Maximum likelihood)
0/098	0/78	سریعترین باد (wind fastest) ، سرعت باد غالب (prevailing speed) ، میانگین سرعت (average speed) ، بزرگی باد (wind magnitue)	تجزیه عاملی (Principal Components)
0/065	0/85	بزرگی باد (wind magnitue) ، پیوستگی باد (wind duration) ، سریعترین باد (wind fastest) ، سرعت باد غالب (prevailing wind)	آزمون گاما

جدول ۵- مقایسه شبکه عصبی با اعمال مناسب‌ترین ترکیب ورودی و درخت تصمیم

Table 5. Result different styles sake select most appropriate input combinations neural network

RMSE	R ²	ترکیب ورودی input combination	روش هوش مصنوعی Artificial intelligence style
0/04	0/87	سرعت باد غالب (prevailing speed) ، دید افقی (visibility) ، پیوستگی باد (wind duration) ، میانگین سرعت (average speed)	شبکه عصبی Neural network
0/064	0/86	سرعت باد غالب (prevailing speed) ، دید افقی (visibility) ، میانگین سرعت (average speed) ، پیوستگی باد (wind duration)	درخت تصمیم Decision tree

ماه اردیبهشت با ضریب همبستگی ۰/۹۷ و مجذور میانگین مربعات خطای ۰/۰۴ و در ماه فروردین با ضریب همبستگی ۰/۹۶ و مجذور میانگین مربعات خطای ۰/۰۰۹ و خرداد، تیر و شهریور با ضریب همبستگی ۰/۹۵ و مجذور میانگین مربعات خطای به ترتیب ۰/۰۴، ۰/۱۴، ۰/۰۴ می باشد. نتایج در جدول ۶ ارائه شده است. تمام جداول بالا نشان‌دهنده توانایی و قابلیت بالای مدل‌های هوش مصنوعی (شبکه عصبی و درخت تصمیم) در شبیه‌سازی طوفان گرد و خاک است. که دلیل این امر مربوط به ساختار (نرون، تعداد لایه‌های پنهان، تعداد گره، دور تکرار و ...) و معادلات استفاده شده در مدل می‌باشد. همچنین انتخاب بعضی از پارامترها برای شبیه‌سازی و پیش‌بینی پدیده‌های طبیعی نشان از تأثیرگذاری بیشتر آن متغیر بر خروجی مدل (طوفان گرد و خاک) دارد.

نتیجه‌گیری

انتخاب ترکیب مناسب از پارامترهای ورودی یکی از مهمترین مراحل ساخت و طراحی هرگونه مدل ریاضی و هوشمند است. در این تحقیق از روش رگرسیون گام به گام، تحلیل عاملی، تجزیه مؤلفه‌های اصلی و گام‌تست برای پیش‌پردازش پارامترهای ورودی و انتخاب ترکیب بهینه از پارامترهای ورودی جهت شبیه‌سازی طوفان گرد و خاک به کمک شبکه عصبی پیشخور پس انتشار با توابع آموزشی لورنبرگ

از دو شاخص ضریب همبستگی و میانگین مربعات خطا مدل مورد ارزیابی قرار گرفته شد. برای تعیین مناسب‌ترین روش برای انتخاب ترکیب ورودی به مدل شبکه عصبی از روش‌های مذکور استفاده شد که در جدول ۴ نتایج روش‌ها به طور خلاصه ارائه شده است.

بعد از تعیین مناسب‌ترین روش آماری برای تعیین ترکیب ورودی در مدل شبکه عصبی، نتایج مدل شبکه عصبی با مدل درخت تصمیم مورد مقایسه قرار گرفت. مدل شبکه عصبی در صورت استفاده از روش آماری مناسب برای تعیین ترکیب ورودی از مدل درخت تصمیم با استفاده از شاخص‌های آماری ضریب همبستگی و مجذور میانگین مربعات خطا، نتایج مناسبتری ارائه شد. نتایج مقایسه مدل‌ها در جدول ۵ ارائه شده است.

بعد از مقایسه مدل‌ها، با استفاده از مناسب‌ترین مدل (شبکه عصبی) انتخاب شده، عوامل تأثیرگذار در ماه‌ها و فصل‌های مختلف مورد بررسی قرار گرفت. سپس داده‌ها در هر فصل و ماه‌های مختلف به طور جداگانه مرتب شد و عوامل تأثیرگذار در هر ماه و فصل به دست آمد تا مهمترین فصل‌ها و ماه‌ها در برآورد طوفان گرد و خاک انتخاب گردد. فصل تابستان با ضریب همبستگی ۰/۹۰ و مجذور میانگین مربعات خطای ۰/۱۷ و فصل بهار با ضریب همبستگی ۰/۸۸ و مجذور میانگین مربعات خطای ۰/۲۲ شبیه‌سازی با اطمینان بیشتری حاصل می‌شود. همچنین در ماه‌های مختلف مدل شبکه عصبی در

جدول ۶- روابط فصول و ماه‌های مختلف در شبیه‌سازی پدیده طوفان گرد و خاک

Table 6. Relation different seasons and months in simulation dust storm phenomenal

RMSE	R ^۲	ماه‌ها Months	فصول Seasons
0/0094	0/96	April فروردین	
0/041	0/97	May اردیبهشت	بهار
0/048	0/95	June خرداد	String
0/145	0/95	July تیر	
0/208	0/94	August مرداد	تابستان
0/049	0/95	September شهریور	Summer
0/076	0/91	October مهر	
0/038	0/93	November آبان	پاییز
0/135	0/87	December آذر	Autumn
0/119	0/86	January دی	
0/060	0/85	February بهمن	زمستان
0/140	0/92	March اسفند	Winter

1. Akbari, Z. Talebi, A. and Mahjubi, J. 2010. Performance of the decision tree and regression model to estimate the amount of sediment in the dam area of Ilam. Master's thesis, Department of Natural Resources desert Studies, Yazd University. 165p. (in Persian)
2. Amin, S. and Soltani, A.R. 2003. Using Artificial Neural Networks in Prediction Runoff and Sediment. Water Saving Ariculture and Sustainable use of Water and Land Resources. (2): 821-832. (in Persian)
3. Breiman, L. Friedman, J. Olshen, R. and Stone, C. 1984. Classification and Regression Trees. Chapman & Hall/CRC Press. Boca Raton. 485p.
4. 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.
5. Bauer, P. Nouak, S. Winkler, R. 2007. Fuzzy Matemathical Methods for soil survey and Land Evaluation. Journal of soil science. 40:477-492.
6. Chen, W. Grondin-Perez, B. Chabriat, J.P. and Herve, P. 1996. Wind tunnel lest of the influence of moisture on the Erodibility of loessial sandy loam soil by wind. Journal of Arid Environments, Vol.34, 346-358.
7. DeVos, N.J. and Rientjes, T.H.M. 2005. Objective

مارکوات استفاده شد. هر کدام از روش‌های مورد استفاده در این مطالعه به منظور تعیین ترکیب ورودی، نتایج و متغیرهای متفاوتی را به عنوان ورودی معرفی نمودند. مناسب‌ترین روش برای تعیین ترکیب ورودی به ترتیب رگرسیون گام به گام پیش‌رونده (با متغیرهای سرعت باد غالب، دید افقی، پیوستگی باد و میانگین سرعت باد با $R=0/87$ و $RMSE=0/04$) توسط شبکه عصبی انتخاب شد و آزمون تست گاما در رتبه دوم (با متغیرهای بزرگی باد، تداوم باد، سریع‌ترین سرعت باد و سرعت باد غالب با $R^2=0/85$ و $RMSE=0/065$) به عنوان ورودی شبکه معرفی نمود. در گام بعدی شبکه عصبی با مناسب‌ترین روش تعیین ترکیب ورودی (رگرسیون گام به گام پیش‌رونده) با درخت تصمیم مقایسه شد که نتایج مدل شبکه عصبی پیشخور پس انتشار خطا با توابع آموزشی لورنبرگ مارکوات در برآورد و شبیه‌سازی طوفان گرد و خاک در منطقه مورد مطالعه مناسبتر است. همچنین نتایج نشان داد مدل درخت تصمیم‌گیری نیازی به استفاده از روش‌های تعیین ترکیب ورودی ندارد و مدل با ترسیم درخت نشان می‌دهد که از چه ترکیب ورودی برای مدل‌سازی استفاده نموده است و بدون استفاده از روش‌های تعیین ترکیب ورودی مدل‌سازی قابل قبولی را ارائه داده است. همچنین مدل‌سازی در فصول بهار و تابستان به دلیل پراکنش مناسب داده‌ها، از دقت قابل قبول تری برخوردار است. لذا مدل‌سازی در فصول نامبرده شده در مدیریت طوفان گرد و خاک قابل اطمینان‌تر است. از لحاظ کاربردی بودن این نتایج می‌توان بیان نمود که اگر پیش‌بینی با دقت و قابل اطمینان انجام شود، در مدیریت طوفان گرد و خاک در استان مورد مطالعه به کاربرد. به این صورت که در فصول و ماه‌های پیش‌بینی شده هشدار و اقدامات لازم برای کاهش خسارات و جلوگیری از تلفات انجام شود. همچنین با استفاده از نتایج شبیه‌سازی، در گام بعدی می‌توان پیش‌بینی ماه‌های آینده را با استفاده از داده‌های ماه‌های قبلی پیش‌بینی نمود. پایه مدل‌های هوش مصنوعی بر این اساس نهاده شده است که با آموزش مدل با داده‌های گذشته، بتوان ماه‌های آینده را پیش‌بینی نمود. همچنین نتایج نشان‌دهنده آن است که هر چه بازه زمانی در مطالعات شبیه‌سازی با استفاده از شبکه عصبی کوچکتر باشد، مدل از دقت بالاتری برخوردار می‌باشد. نتایج کلی در این مطالعه حاکی از مناسب بودن شبکه عصبی پیشخور پس انتشار با توابع آموزشی لورنبرگ مارکوات در صورت تعیین ترکیب ورودی با روش‌های مذکور در مواردی که متغیرهای ورودی زیاد می‌باشد، با دقت بالاتری نسبت به مدل درخت تصمیم است. برتری شبکه عصبی مصنوعی نسبت به درخت تصمیم در این مطالعه را می‌توان به ساختار و معادلات پیچیده‌تری که در مدل استفاده شده است، نسبت داد. در مدل درخت تصمیم از معادلات و ساختار ساده‌تری استفاده شده است. همچنین مدل شبکه عصبی آموزش پذیرتر از مدل درخت تصمیم است و برازش مناسب‌تری به داده‌های مورد استفاده در مدل ایجاد می‌نماید.

منابع

Environmental Modeling & Software,15: 101-124.

18. Mahjobi, J. 2008. Precipitation parameters wave Due Wind with use from Decision Tree and comparison the with neural network, Iran university of science and Teclonology , Omran Collegiate, 120p. (in Persian)

19. Orlovsky, L. Orlovsky, N. and Durdyev, A. 2005. Dust storms in Turkmenistan. Journal of Arid Environments 60: 83–97.

20. Rodeny, J. Woolf, A. 2005. Data mining using matlab. bachelore of engineering. University of Southern Queensland Faculty of Engineering & Surveying . 345p.

21. Rashki, A. Kaskaoutis, D.G.deW. Rautenbach, C.J.Eriksson, P.G. Qiang, M.and Gupta, P. 2012. Dust storms and their horizontal dust loading in the Sistan region, Iran. Aeolian Research 5. 51–62.

22. 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.

23. Sharifi, A. Talebi, A. and Mahjub, J. 2008. Performance of the Anfis and to neural network estimate the Runoff in the Esfahan. Master's thesis, Department of Natural Resources watershed managment Studies, Yazd University.187p. (in Persian)

24. 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.

25. Song, Z. 2004. A numerical simulation of dust storms in China. Journal of Environmental Modelling & Software 19: 141–151.

26. 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.

27. Trajkovic, S. Todorovic, B. and Stankovic, M. 2003. Forecasting of reference evapotranspiration by artificial neural networks. Journal of Irrigation and Drainage Engineering, (129): 445-457.

28. Westwell, I. 1999. Fact Finder Guide Weather.

functions in artificial neural network training for rainfall-runoff modeling. Journal of Geophysical Research Abstracts, 7. 435-447.

8. Ekhtesasi, M. Ahmadi, H. Baghestani, N. KHalili, E. Feyzniya, S. 1997. Visibility Source Sandy Hilis Yazd-Ardakan Plain. Institution Reserch Forest and Range Iran. 260. (in Persian)

9. Ekhtesasi, M. 2005. Scrutiny Morphometer and Morphodynamic Wind Erosion Yazd-Ardakan Plain. PHD Thesis. Tehran University. 389. (in Persian)

10. Feng, Q. and Cheng, K.N. 2002. Dust storm in China: A case study of dust storm Variation and dust characteristics, Bull Eng Geol Env 61. 234-249.

11. Ghabaei Sough, M. Mosaedi, A. Hesam, M. Hezarjaribi, A. 2010. Evaluation Effect of Input Parameters Preprocessing in Artificial Neural Networks (Anns) by Using Stepwise Regression and Gamma Test Techniques for Fast Estimation of Daily Evapotranspiration, Journal of Water and Soil, Vol. 24, No. 3, July-Aug 2010, p. 610-624. (in Persian)

12. Hessami, M. Anctil, F. and 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. (in Persian)

13. 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.

14. Keya, M. 2010., Instruction Artificial Neural Network in MATLAB., chichester Tehran university. 280p. (in Persian)

15. Jamalizadeh, M.R. Moghaddamnia, A. Piri, J. Arbabi, V. Homayounifar, M. and Shahryari, A. 2008. Dust Storm Prediction Using ANNs Technique (A Case Study: Zabol City). World Academy of Science, Engineering and Technology 19. 435-452.

16. Mahdavi, M. 2001 and 2004. Application hydrology, cover 1 and 2, Issue Tehran university. 450p. (in Persian)

17. 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.

Abstract

Comparing the Best Input Combining Artificial Neural Networks and Decision Tree Method to Identify Factors that Influence the Phenomenon of Dust Storm (Case Study: Yazd Province)

M. R. Ekhtesasi¹, M. Yousefi² and M. Tavakoli³

Received: 2013. 02. 08 Accepted: 2014. 06. 17

One of the major natural disasters that caused tremendous damages each year in many areas of the country is desert, especially in Yazd, Iran. Strong winds and the formation of dust storms will take place several times each year. In this study, data from meteorological stations in Yazd (thunder storms, wind magnitude (size, amount), wind duration, visibility, fastest wind speed, average wind speed, prevailing winds and dust storms) in the period 1953-2005 were used on a monthly basis. In order to determine the most appropriate combination of neural network and input parameters (inputs) that influence the phenomenon of dust storms from Variable reduction technique of factor analysis (maximum likelihood, principal component), principal component analysis, stepwise progressive and gamma test were used. Each of the methods presented, each with a different combination of these compounds neural network feed Forward back propagation with the algorithm of Levenberg-Marquardt have been used. The results showed that the stepwise progressive $R^2 = 0.87$ and $RMSE = 0.04$ provides the most suitable combination for a neural network. Comparison of simulated dust storm phenomenon in seasons and months in different years showed that the phenomenon of dust storm in summer and spring seasons and months of April, May, June, July, August and September are different. In comparing the neural network feed forward back propagation models with algorithm of Levenberg-Marquardt and decision tree with algorithm CART, Neural networks with a correlation coefficient of 0.87 and the root mean square error of 0.04, the decision tree method with a correlation coefficient of 0.86 and the root mean square error of 0.06 has more carefully in order to simulate dust storm.

Keywords: *Dust storm, Neural network, Decision tree, Algorithm CART, Yazd Province*

1- Assistant professor, Faculty of Natural Resources, Yazd University

2- M.Sc., Watershed Management, Faculty of Natural Resources, Yazd University Corresponding Author Email: Mohsenyosefi67@gmail.com

3- M.Sc., Watershed Management, Meteorological Office of Yazd Province