

پیش‌بینی طوفان‌های گردوغبار در استان خوزستان با استفاده از شبکه‌های عصبی مصنوعی

مسعود پورغلام آمیجی^۱، محمد انصاری قوجقار^۱، خالد احمدالی^{۲*}

^۱ دانشجوی دکتری گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

^۲ استادیار گروه احیاء مناطق خشک و کوهستانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

دریافت: ۹۹/۰۶/۰۷ پذیرش: ۱۴۰۰/۰۹/۲۲

چکیده

تغییرات اقلیمی و به دنبال آن وقوع وقایع حدی نظیر طوفان‌های گردوغبار علاوه بر اختلال در روند طبیعی زندگی حیات‌وحش و محیط‌زیست، تأثیر مستقیمی بر زندگی مردم داشته و در سال‌های اخیر بر بخش کشاورزی اثرات نامطلوبی بر جای گذاشته است. استان خوزستان، مثال بارز و روشنی از این پدیده است که ساکنان آن منطقه، با مشکلات متعددی به واسطه وقوع طوفان‌های گردوغبار مواجه هستند. در این پژوهش برای پیش‌بینی طوفان‌های گردوغبار، داده‌های ساعتی گردوغبار و داده‌های ماهانه دمای بیشینه، کمینه، میانگین، سرعت بیشینه باد و مجموع بارش در سه ایستگاه همدیدی آبادان، اهواز و بستان با طول دوره آماری ۲۵ ساله (۱۹۹۰-۲۰۱۴) گردآوری شد. برای بررسی تأثیرپذیری طوفان‌های گردوغبار از نوسانات اقلیمی علاوه بر متغیرهای مذکور، شاخص خشک‌سالی استاندارد شده بارش-تبخیر و تعرق (SPEI) نیز در پنجره زمانی فصلی محاسبه گردید. پیش‌بینی تعداد روزهای همراه با طوفان-های گردوغبار در مقیاس فصلی با استفاده از چهار روش هوش مصنوعی شامل شبکه عصبی پرسپترون چندلایه (MLP)، سیستم استنتاج تطبیقی فازی-عصبی (ANFIS)، شبکه عصبی تابع پایه شعاعی (RBF) و شبکه عصبی وایزش تعمیم‌یافته (GRNN) انجام شد. نتایج نشان داد که در تمامی ایستگاه‌ها، استفاده از همه ویژگی‌ها باعث بهبود پیش‌بینی گردوغبار شده است و مقدار شاخص میانگین قدر مطلق خطا (MAE) برای ایستگاه‌های آبادان، اهواز و بستان به ترتیب برابر با ۱/۱۵، ۱/۶۶ و ۰/۶۶ به دست آمد که همگی مربوط به فصل پاییز بودند. همچنین نتایج نشان داد که در ایستگاه بستان، با فرض ثابت بودن داده‌های چهار فصل گذشته و استفاده از تمام ویژگی‌های ورودی، مدل ANFIS باعث می‌شود که خطای پیش‌بینی کمتر شده و نتیجه بهتری حاصل شود. در ایستگاه آبادان استفاده از مدل MLP چنین نتیجه‌ای را به دست می‌دهد. ضمن اینکه در ایستگاه اهواز مدل RBF بهترین مدل شناخته شد. در یک جمع‌بندی کلی می‌توان گفت که مدل‌های به کار گرفته شده، منشأ خارجی گردوغبار (فصل پاییز و زمستان) را بهتر از منبع داخلی آن (فصل بهار و تابستان) پیش‌بینی می‌کنند. نتایج این مطالعه می‌تواند در شناخت اثرات نوسانات اقلیمی بر فراوانی طوفان گردوغبار و مهار بیابان‌زایی ایران مفید باشد.

کلمات کلیدی: پارامترهای اقلیمی، شبکه‌های عصبی، طوفان‌های گردوغبار، SPEI، هوش مصنوعی

۱ مقدمه

اراضی وارد جو می‌شوند. (Pourgholam-Amiji et al., 2020)

هوای پاک و عاری از آلودگی یکی از حیاتی‌ترین نیازهای انسان است و گردوغبار یکی از منابع آلوده‌کننده آن به شمار می‌رود (Abdolshahnejad et al., 2020). ذرات ریز گردوغبار تحت تأثیر عوامل گوناگونی از جمله شرایط جوئی مانند باد، بارش و دما، مشخصات سطح زمین نظیر توپوگرافی، رطوبت سطح، طول زبری و پوشش گیاهی و ویژگی‌های خاک همانند بافت، تراکم، ترکیب و کاربری

جواب‌ها را داده است، توصیه شده که در مطالعات دیگر نیز قابلیت‌های این روش‌ها مورد بررسی قرار گیرد. Jamalizadeh Tajabadi et al. (2010) در مطالعه‌ای دیگر به پیش‌بینی وقوع طوفان گردوغبار و میزان دید حداقل روزانه در شهر زابل با استفاده از روش شبکه‌های عصبی مصنوعی پرداخته و به این نتیجه رسیدند که روش مورد استفاده، در پیش‌بینی کوتاه‌مدت وقوع طوفان‌ها، موفقیت بیشتری نشان می‌دهد. سوابق پژوهش نشان می‌دهد که دمای هوا در مناطق مختلف جهان به طور مرتب مورد مطالعه بوده و روش‌های مختلفی برای بررسی تغییرات و پیش‌بینی گردوغبار به کار رفته است. همچنین مدل سیستم استنتاج فازی-عصبی تطبیقی کارایی قابل قبولی در پیش‌بینی‌های مختلف نشان می‌دهد.

Aliyari et al. (2008) به پیش‌بینی کوتاه‌مدت آلودگی هوا به کمک شبکه‌های عصبی پرسپترون چندلایه (MLP-Multi-Layer Perceptron)، خط حافظه‌دار تأخیر (DLM- Delay Line Memory)، گاما و سیستم استنتاج تطبیقی فازی-عصبی (ANFIS- Adaptive Neuro Fuzzy Inference System) همراه روشی ترکیبی و نوین در آموزش آن بر اساس الگوریتم بهینه‌سازی گروهی ذرات که روشی آزاد از گرادیان می‌باشد، پرداختند. برای پیش‌بینی داده‌ها، ابتدا به آنالیز پیش‌بینی‌پذیری داده‌ها پرداخته شد و با کمک شبکه‌های بیان‌شده اقدام به پیش‌بینی آلودگی هوا کردند و در نهایت این روش‌های هوشمند با هم مقایسه شدند. نتیجه نشان داد که روش پیشنهادی ترکیبی بر اساس الگوریتم بهینه‌سازی ازدحام ذرات (PSO- Particle Swarm Optimization) و پالایه کالمن (Kalman Filter) برای آموزش شبکه ANFIS توانایی مناسبی در بهبود عملکرد پیش‌بینی دارد. همچنین Ibarra-Berastegi et al. (2008) در مطالعه‌ای به پیش‌بینی آلودگی هوای بیلانو با استفاده از شبکه‌های عصبی پرداختند. آن‌ها در این مطالعه، از سه شبکه MLP، RBF و شبکه عصبی رگرسیون تعمیم‌یافته (Neural Network GRNN- Generalized Regression) برای پیش‌بینی آلودگی هوا و طراحی سنجنده‌های هشداردهنده

شود. از سوی دیگر نزدیک بودن با کشورهای هم‌چون عربستان، عراق و سوریه که دارای سطح وسیعی از بیابان به دلیل عامل‌های مختلفی مانند کمبود پوشش گیاهی، بارش اندک و دمای بالا هستند، بی‌تأثیر نیست (Ansari et al., 2022; Osman et al., 2020). البته وقوع خشک‌سالی در یک منطقه با تأمین آب در آن منطقه رابطه تنگاتنگی دارد و هر چه اقلیم منطقه خشک‌تر باشد، احتمال وقوع خشکی و خشک‌سالی بیشتر شده و رخداد پدیده گردوغبار محتمل‌تر است (Pourgholam-Amiji et al., 2021).

تغییر اقلیم و بررسی اثرات آن بر منابع آب از موضوعات مهمی به شمار می‌رود که پژوهشگران زیادی هدف تحقیق خود را در این زمینه تعریف نموده‌اند. بنابراین اهمیت پیش‌بینی وقوع پدیده‌های جوی نظیر گردوغبار که بسیار حائز اهمیت می‌باشد، بیش از پیش حس می‌شود. شبکه‌های عصبی مصنوعی نوعی ساختار ریاضی است که توانایی نشان دادن فرایندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را دارد. این شبکه با داده‌های موجود طی فرایند یادگیری، آموزش دیده و برای پیش‌بینی در آینده استفاده می‌شود که دارای ویژگی‌های قابلیت یادگیری، قابلیت تعمیم و پردازش موازی است (Dahiya et al., 2007). از جمله پیش‌بینی‌هایی که با این روش صورت گرفته، پیش‌بینی گردوغبار شمال غرب چین بود که نشان داد، حداکثر اطمینان حاصل از این روش در پیش‌بینی گردوغبار، ۷۱/۶ درصد می‌باشد (Huang et al., 2006).

Jamalizadeh Tajabadi et al. (2008) توانایی دو روش شبکه‌های عصبی مصنوعی (ANN-Artificial Neural Network) و ماشین‌های بردار پشتیبان (SVM- Support Vector Machine) در پیش‌بینی طوفان‌های گردوغبار شهر زابل را با دوره آماری ۲۶ ساله (۲۰۰۵-۱۹۸۰) بررسی کردند. از آنجا که استفاده از نوع وایزش بردار پشتیبان (SVR- Support Vector Regression) و تابع کرنل پایه شعاعی (RBF- Radial Basis Function) بهترین

نشان داد که میزان اطمینان حاصل از مدل‌های خطاسنجی یعنی شبکه عصبی هیبرید-پانل نسبت به ANFIS بیشتر می‌باشد. بر اساس مدل‌های پیش‌بینی، بیشترین احتمال رخداد گردوغبار پیش‌بینی شده در ۲۳ سال آینده (سال شروع پیش‌بینی ۲۰۱۷) را در ایستگاه سرپل ذهاب با ۱۲۸/۹۱۷ درصد و آبادان با ۱۲۰/۷۰۹ درصد برآورد کردند. مدل SAW بیشترین احتمال رخداد گردوغبار پیش‌بینی شده در ۲۳ سال آینده را در ایستگاه آبادان با ۰/۹۹ درصد و مدل TOPSIS در ایستگاه اسلام‌آباد غرب با مقدار ۰/۹۷ درصد به خود اختصاص دادند. Hassanzadeh et al. (2012) نیز برای پیش‌بینی خشک‌سالی‌های آتی، از تلفیق الگوریتم ژنتیک (GA- Genetic Algorithm) و مدل ترکیبی شبکه عصبی-موجکی (Conjoined Model of Neural Network-Wavelet) در تحلیل شاخص بارندگی استاندارد شده، استفاده کردند و در نهایت نشان دادند که به‌کارگیری روش تلفیقی مذکور در مقایسه با تلفیق الگوریتم ژنتیک و شبکه عصبی، نتایج مطلوبی را ارائه داد. Hosseini-Moghari & Araghinejad (2016) کاربرد شبکه‌های عصبی آماری، فازی و پرسپترون در پیش‌بینی خشک‌سالی ایستگاه گنبد کاووس را بررسی کردند. بدین منظور از شاخص استاندارد شده بارندگی (SPI- Standardized Precipitation Index) در مقیاس زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه و آمار ماهانه بارندگی در طی سال‌های آبی ۵۲-۱۳۵۱ تا ۸۶-۱۳۸۵ استفاده کردند. پس از پایان خشک‌سالی و بر اساس سری زمانی SPI، با استفاده از چهار روش شبکه هوش مصنوعی شامل ANFIS، MLP، RBF و GRNN اقدام به پیش‌بینی خشک‌سالی کردند. نتایج مربوط به پایش نشان داد که چهار دوره طولانی مدت خشک‌سالی مربوط به سال‌های ۵۸-۵۳، ۶۲-۶۰، ۷۰-۶۸ و ۷۳-۷۶ در طول دوره آماری وجود دارد. در قسمت پیش‌بینی‌ها، نتایج حاکی از افزایش دقت پیش‌بینی‌ها با افزایش مقیاس محاسبه SPI بود. با توجه به نتایج مدل‌های ANFIS، MLP، RBF و GRNN برای تعیین همبستگی بین

آلودگی استفاده کردند. نتایج نشان داد استفاده از این مدل‌ها می‌تواند شبکه آلودگی هوای یلبائو را که در ابتدا برای اهداف تشخیصی طراحی شده است، با قابلیت‌های پیش‌بینی کوتاه‌مدت و در زمان واقعی طراحی کند. عملکرد این مدل‌ها در سنجنده‌های مختلف در این منطقه از حداکثر مقدار ضریب همبستگی ۰/۸۸ برای پیش‌بینی تا حداقل ۰/۱۵ بوده است. Sobhani et al. (2015) به بررسی گردوغبار و ارزیابی امکان پیش‌بینی آن بر اساس روش‌های آماری و مدل ANFIS در زابل با آمار ۴۱ ساله (۲۰۰۵-۱۹۶۵) پرداختند. نتایج نشان داد در طول دوره آماری مورد مطالعه، ماه‌های جولای و اوت گردوغباری‌ترین ماه‌های سال می‌باشند. بر اساس تحلیل خوشه‌ای انجام شده، ماه‌های ژوئیه و اوت با بیشترین روزهای گردوغباری در یک خوشه‌ی مجزا قرار گرفتند. روند سری ماهانه، فصلی و سالانه‌ی گردوغبار در این ایستگاه، افزایشی می‌باشد. نتایج پیش‌بینی گردوغبار با مدل ANFIS، حکایت از قابلیت بالای آن در پیش‌بینی گردوغبار در این ایستگاه دارد. ساختار سیستم استنتاج فازی (FIS- Fuzzy Inference System) تعیین شده با چهار تابع عضویت به شکل قوسی با روش آموزش ترکیبی، با اطمینان حدود ۹۳ درصد گردوغبار ایستگاه زابل را پیش‌بینی کرد. در مطالعه دیگری Sobhani et al. (2020) به واکاوی و پیش‌بینی پدیده گردوغبار در جنوب غرب ایران پرداختند. بدین منظور از داده‌های ۲۷ ساله گردوغبار در ۱۴ ایستگاه همدیدی در جنوب غرب ایران در بازه زمانی ۲۰۱۷-۱۹۹۰ استفاده کردند. با استفاده از مدل‌های شبکه عصبی (PDH- Panel Data Hybrid) و سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) در نرم‌افزار MATLAB اقدام به پیش‌بینی شد. در نهایت آن‌ها برای اولویت‌سنجی ایستگاه‌های در معرض گردوغبار از مدل‌های تصمیم‌گیری چند متغیره فن ترجیح سفارش بر اساس شباهت با راه‌حل ایده‌آل (TOPSIS- Technique for Order Preference by Similarity to Solution Ideal) و وزن اضافی ساده (SAW- Simple Additive Weighting) بهره بردند. نتیجه پژوهش ایشان

مسجدسلیمان و زابل به ترتیب ۰/۸ و ۰/۹۷ بوده است. همچنین با توجه به نتیجه مدل‌های ANFIS، RBF و GRNN به ترتیب ضریب همبستگی محاسبه شده برای پیش‌بینی در ایستگاه‌های مسجدسلیمان و زابل از ۰/۴۱ تا ۰/۹۵، ۰/۳۵ تا ۰/۹۲ و ۰/۲۲ تا ۰/۹۸ متغیر بود. در مجموع با مقایسه نتیجه مدل‌های مورد استفاده، ANFIS بهترین عملکرد و بعد از آن GRNN بهترین نتیجه را ارائه نموده است.

بیشتر مطالعات داخلی مربوط به روند پدیده‌های گردوغبار در محدوده‌های کوچک، مطالعات سینوپتیکی و بررسی‌های ماهواره‌های می‌باشد. از طرفی دیگر با توجه به اینکه این پدیده اثرات نامطلوب و پیامدهای منفی در زمینه‌های اجتماعی، اقتصادی و سلامت مردم داشته است، مطالعه و پیش‌بینی و بررسی ارتباط آن با نوسانات اقلیمی ضروری است. در این مطالعه به مقایسه کارایی روش‌های هوش مصنوعی در پیش‌بینی طوفان‌های گردوغبار پرداخته شد. مدل‌های مورد استفاده در پیش‌بینی عبارت‌اند از: MLP، ANFIS، RBF و GRNN. برخی از این مدل‌های عصبی مصنوعی برای اولین بار است که به منظور پیش‌بینی فراوانی روزهای همراه با طوفان‌های گردوغبار مورد استفاده قرار می‌گیرد. لذا این پژوهش با اهدافی نظیر بررسی تأثیر افزودن ویژگی‌های کمکی بر روی پیش‌بینی‌ها، بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی‌ها و تعیین بهترین مدل از بین MLP، RBF، GRNN و ANFIS در پیش‌بینی طوفان‌های گردوغبار در استان خوزستان می‌باشد.

۲ مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

در این پژوهش به بررسی پیش‌بینی طوفان گردوغبار در سه ایستگاه هواشناسی همدیدی کشور (آبادان، اهواز و بستان) که بیشترین فراوانی روزهای همراه با طوفان گردوغبار (FDSD- Frequency of Dust Stormy Days) در استان خوزستان را شامل می‌شوند (Araghinejad et al., 2019) ، با جامعه آماری بلند مدت ۲۵ ساله (۱۹۹۰-۲۰۱۴)

مقادیر مشاهداتی و پیش‌بینی شده SPI1 تا SPI24 به ترتیب ضریب همبستگی از ۰/۰۰۹ تا ۰/۹۴۹، ۰/۰۲۱ تا ۰/۹۲۵، ۰/۲۶۳ تا ۰/۹۵۳ و ۰/۲۱۰ تا ۰/۹۵۵ متغیر بود.

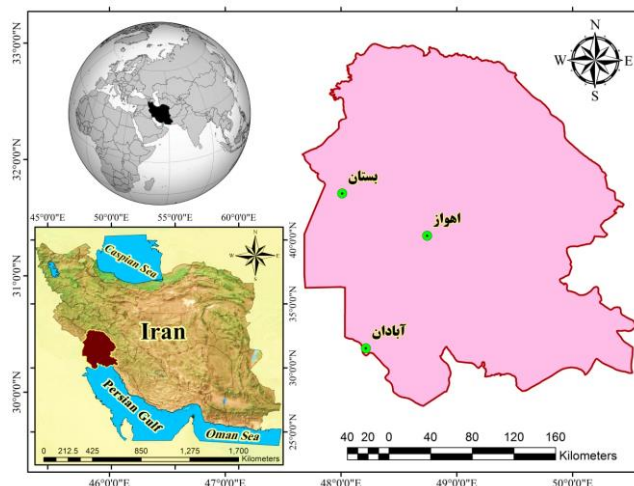
در مجموع، مدل ANFIS بهترین نتیجه و بعد از آن GRNN بهترین عملکرد را ارائه نمود. Pourgholam-Amiji et al. (2020) به مقایسه عملکرد مدل‌های سری زمانی SARIMA و Holt-Winters با روش‌های هوش مصنوعی (ANFIS و RBF) در پیش‌بینی طوفان‌های گردوغبار با طول دوره آماری ۲۵ ساله (۲۰۱۴-۱۹۹۰) در استان سیستان و بلوچستان پرداختند. نتایج نشان داد که روش ANFIS، نسبت به سایر روش‌ها، بهترین عملکرد را داشت و معیارهای ارزیابی R (ضریب تبیین)، RMSE، MAE و NS (ضریب نش-ساتکلیف) آن به ترتیب از ۰/۷۲، ۰/۵۷، ۰/۴۲ و ۰/۷۱ تا ۰/۹۵، ۰/۵۱، ۰/۴۰ و ۰/۹۶ متغیر بود. همچنین، با افزایش شاخص متوسط فراوانی روزهای همراه با طوفان‌های گردوغبار در ایستگاه‌ها (از ۱/۰۶ تا ۷/۱۱)، دقت پیش‌بینی همه روش‌ها افزایش داشت. در مجموع، با مقایسه روش‌های مورد استفاده، روش هوش مصنوعی ANFIS بهترین و مدل‌های سری زمانی SARIMA و Holt-Winters بدترین عملکرد را داشتند. در همین رابطه، Ansari Ghojghar et al. (2020) به مقایسه کارایی شبکه‌های عصبی آماری، فازی و پرسپترون در پیش‌بینی طوفان‌های گردوغبار در نواحی بحرانی کشور (زابل، آبادان، اهواز، زاهدان، بستان و مسجدسلیمان) پرداختند. در این مطالعه از داده‌های ۲۵ ساله (۱۹۹۰-۲۰۱۴) استفاده شد. پس از محاسبه فراوانی تعداد روزهای همراه با طوفان‌های گردوغبار و تشکیل سری‌های زمانی فصلی، با استفاده از چهار روش هوش مصنوعی شامل MLP، ANFIS، RBF و GRNN اقدام به پیش‌بینی فراوانی روزهای همراه با طوفان‌های گردوغبار در یک فصل بعد شد. نتایج حاکی از افزایش دقت پیش‌بینی‌ها در فصول همراه با تعداد بیشتر روزهای همراه با طوفان گردوغبار بود؛ به نحوی که بر اساس نتایج حاصل از مدل MLP، ضریب همبستگی بین مقادیر مشاهداتی و پیش‌بینی شده فراوانی روزهای همراه با طوفان گردوغبار برای ایستگاه

همدیدی جدا شد. براساس تعریف سازمان جهانی هواشناسی، روزهای همراه با طوفان‌های گردوغبار به روزی گفته می‌شود که حداقل در یکی از هشت سینوپ (گزارش‌های سه‌ساعته دیده‌بانی)، یکی از کدهای مربوط به گردوغبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰ تا ۳۵ و ۹۸) در بخش هوای حاضر گزارش شده باشد. البته به شرط اینکه داده‌های دید افقی متناظر با آن کد گردوغبار کمتر از ۱۰۰۰ متر به ثبت رسیده باشد. در این مطالعه برای تشخیص طوفان‌های گردوغباری از فاکتور دید افقی ≤ 1000 متر برای همه کدهای هواشناسی گردوغبار استفاده شده است. در شکل ۱، موقعیت جغرافیایی ایستگاه‌های همدیدی مورد مطالعه در استان خوزستان نشان داده شده است.

پرداخته شده است. بلندمدت ۲۵ ساله (۱۹۹۰-۲۰۱۴) برداشته شده است. بدین منظور از داده‌های ساعتی دید افقی، کدهای سازمان جهانی هواشناسی (WMO- World Meteorological Organization) و همچنین داده‌های اقلیمی شامل دمای بیشینه، دمای کمینه، دمای متوسط، سرعت بیشینه باد، مجموع بارش و شاخص SPEI (Standardized Precipitation Evapotranspiration Index) در بازه زمانی فصلی استفاده شد. کدهای مربوط به طوفان‌های گردوغبار در جدول ۱، ارائه شده است. با توجه به اینکه داده‌های گردوغبار به صورت تفکیک نشده از سایر پدیده‌های هواشناسی از سازمان هواشناسی در اختیار قرار می‌گیرد، بنابراین در گام نخست کدهای مربوط به گردوغبار از سایر پدیده‌های اقلیمی در ساعات مختلف

جدول ۱. کدهای سازمان جهانی هواشناسی مرتبط با پدیده‌های گردوغبار (O'Loingsigh et al., 2014)

ردیف	توضیحات
۱	رخداد طوفان گردوخاک گسترده در خارج از ایستگاه هواشناسی
۲	خاک یا شن برخاسته از زمین در محدوده ایستگاه هواشناسی
۳	مشاهده گردباد در محدوده ایستگاه هواشناسی یا خارج از آن در زمان دیدبانی یا طی ساعت گذشته
۴	طوفان شن یا خاک در زمان دیدبانی در خارج از ایستگاه یا طی ساعت گذشته در محدوده ایستگاه هواشناسی
۵	طوفان خفیف یا متوسط شن یا خاک با روند کاهشی طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر، همراه با کاهش میدان دید به کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر
۶	طوفان خفیف یا متوسط شن یا خاک بی تغییر شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش میدان دید به کمتر از ۱۰۰۰ ولی بیش از ۲۰۰ متر
۷	طوفان خفیف یا متوسط شن یا خاک با افزایش شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر همراه با کاهش میدان دید کمتر از ۱۰۰۰ متر اما بیشتر از ۲۰۰ متر
۸	طوفان شدید شن یا خاک همراه با روند کاهشی طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش دید کمتر از ۲۰۰ متر
۹	طوفان شدید شن یا خاک بی تغییر شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر همراه با کاهش دید به کمتر از ۲۰۰ متر
۱۰	طوفان شدید شن یا خاک با افزایش شدت طی ساعت گذشته و با سرعت باد ۱۵ متر بر ثانیه یا بیشتر و کاهش دید به کمتر از ۲۰۰ متر
۱۱	رعدوبرق بدون بارش همراه با طوفان شن یا خاک (هبوب)




شکل ۱. منطقه مورد مطالعه

برای آموزش استفاده می‌کند (Araghinejad, 2013). شکل ۲، شمایی از یک MLP را نشان می‌دهد. در این تحقیق برای آموزش MLP از الگوریتم آموزشی پس‌انتشار خطا (BP-Back Propagation) استفاده شد. هم‌چنین توابع محرک سیگموئید برای لایه مخفی و تابع محرک خطی برای لایه خروجی در نظر گرفته شده است. تعیین خروجی در روش MLP به صورت رابطه (۱) می‌باشد که در آن n ورودی خالص، w وزن، p ورودی، b بایاس و f تابع محرک است (Ahmadaali et al., 2013).

۲-۲- سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) سیستم استنتاج تطبیقی فازی-عصبی (ANFIS) توسط جانگ در سال ۱۹۹۳ معرفی گردید (Jang, 1993). ANFIS شبیه یک شبکه عصبی چندلایه است با این تفاوت که علاوه بر الگوریتم‌های یادگیری شبکه عصبی از منطق فازی نیز بهره می‌گیرد. یک مدل ANFIS از پنج لایه تشکیل شده است؛ این پنج لایه به ترتیب عبارت‌اند از: لایه ورود اطلاعات، لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی وزن‌های قوانین به‌دست آمده، لایه محاسبه قوانین، لایه جمع‌بندی و خروجی شبکه. در این تحقیق تابع عضویت مورد نظر، تابع عضویت ذوزنقه‌ای بوده و الگوریتم

۲-۴- شبکه عصبی پرسپترون چندلایه (MLP) شبکه عصبی پرسپترون چندلایه (MLP) یکی از پرکاربردترین شبکه‌های عصبی می‌باشد که در آن، وزن‌ها و بایاس‌ها برای تولید یک هدف مشخص آموزش داده می‌شوند. MLP از آن جهت که عملکرد مناسبی از خود نشان داده است؛ بسیار شایان توجه است. این شبکه، مجموعه‌ای از نورون‌ها است که در لایه‌های مختلفی پشت سر هم قرار گرفته‌اند. نورون یک واحد ریاضی با یک دستگاه غیرخطی است. بنابراین یک شبکه عصبی MLP که از اجتماع این نورون‌ها تشکیل می‌شود، یک سامانه پیچیده و غیرخطی خواهد بود (Raudkivi, 2013). MLP از یادگیری نظارت-شده که شامل ارائه ورودی‌ها و خروجی‌ها به شبکه و به حداقل رساندن خطای تخمین است،



شکل ۲. شماتیک MLP

$$n = wp + b \gg a = f(n) = f(wp + b) \quad (1)$$


این تابع گوسی از رابطه ۲، استفاده می کند (Ahmadaali et al., 2013):

$$f(X_r, b) = e^{-\left(\frac{\|X_r - X_b\| \times 0.9226}{h}\right)^2} \quad (2)$$

در این رابطه X_r ورودی شبکه با خروجی نامعلوم، X_b ورودی مشاهداتی در زمان یا مکان b و h پارامتری است که پهنای تابع گوسی را کنترل می کند. خروجی این تابع بین صفر تا یک متغیر است. محاسبه خروجی Y_r بر اساس متغیر مستقل X_r به صورت رابطه ۳، است:

$$Y_r = LW \times f(X_r, b) + Bias \quad (3)$$

در این رابطه LW و $Bias$ به ترتیب وزن ماتریس ارتباطات بین لایه مخفی و لایه خروجی و ماتریس اربابی لایه خروجی است (Ahmadaali et al., 2013).




شکل ۴. شماتیک RBF

۲-۶- شبکه عصبی رگرسیون تعمیم یافته (GRNN)
 شبکه عصبی رگرسیون تعمیم یافته (GRNN) یک شبکه برای حل مسائل رگرسیونی بر پایه آمار است. این شبکه نوع دیگری از شبکه های RBF است. GRNN در سال ۱۹۹۱ توسط اسپکت معرفی گردید (Specht, 1991). این شبکه دارای آموزش سریع بوده و می تواند توابع غیرخطی را به خوبی مدل نماید. GRNN یک شبکه سه لایه است که تعداد نورون های آن در مقایسه با MLP بسیار آسان تر انتخاب می شود، زیرا برابر تعداد مشاهدات در نظر گرفته می شوند. شکل ۵، یک شبکه GRNN را نشان می دهد. این شبکه همانند RBF، در لایه میانی از تابع گوسی استفاده می کند اما در لایه خروجی

آموزش شبکه، روش ترکیبی در نظر گرفته شد. شکل ۳، شماتیک از ANFIS را نشان می دهد.


۲-۳- شبکه عصبی تابع پایه شعاعی (RBF)

شبکه عصبی تابع پایه شعاعی (RBF)، دارای پایه ریاضیاتی بسیار قوی بر مبنای فرضیه منظم سازی برای حل مسائل مشکل می باشد.



شکل ۵. شماتیک GRNN

به طور کلی این شبکه از سه لایه شامل لایه ورودی، مخفی و خروجی تشکیل شده است (Chen et al., 1991). در این شبکه، تابع انتقال گوسی در لایه مخفی استفاده می گردد و در لایه خروجی تابع انتقال، خطی است.



شکل ۳. شماتیک سیستم استنتاج تطبیقی فازی-عصبی (ANFIS)

RBF پایه و اساس نوع خاصی از شبکه های عصبی به نام شبکه های عصبی آماری است. در شکل ۴، یک شبکه RBF نشان داده شده است. همان طور که در شکل مشخص است، نورون RBF یک تابع گوسی است. ورودی این تابع، فاصله اقلیدسی بین هر ورودی به نورون با بردار مشخص شده هم اندازه بردار ورودی است.

$$W = [-2 \ln(P)]^{1/2} \quad \forall P \leq \frac{1}{2} \quad (۸)$$

در رابطه ۷، P مقدار احتمال تجاوز از مقدار D تعیین شده می‌باشد، به عبارتی $P = 1 - F(x)$ اگر مقدار P بزرگتر از ۰/۵ باشد، آنگاه مقدار P با $1-P$ جایگزین شده و علامت SPEI عوض می‌شود. مقادیر ضرایب ثابت C_0, C_1, C_2, d_1, d_2 و d_3 به ترتیب برابر با ۲/۵۱۵۵۲، ۰/۸۲۲۸۵، ۰/۱۰۳۳، ۰/۱۸۹۲۷، ۱/۴۳۲۷۹ و ۰/۱۰۳۳ می‌باشد.

در شاخص SPEI هرچه پنجره زمانی کوتاه‌تر در نظر گرفته شود، به تغییرات بارندگی و دمای ماهانه سریع‌تر واکنش نشان داده و نوسانات خشک‌سالی را بهتر نشان می‌دهد. برای اینکه دوره‌های نرمال، ترسالی و خشک‌سالی در دوره آماری مشترک ۲۵ ساله (۲۰۱۴-۱۹۹۰) برای سه ایستگاه همدیدی استان خوزستان بهتر به نمایش گذشته شود، از شاخص SPEI استفاده شده است. دوره خشک‌سالی هنگامی اتفاق می‌افتد که SPEI به طور مستمر منفی و به مقدار ۱- یا کمتر برسد و هنگامی پایان می‌یابد که SPEI مثبت گردد (Hosseini Pazhouh et al., 2019). از آنجا که در توسعه شاخص SPEI از مفاهیم شاخص SPI استفاده شده است، لذا حدود طبقات مختلف شدت خشک‌سالی (یا ترسالی) مطابق با حدود طبقات ارائه‌شده توسط McKee et al. (1993) و مطابق جدول ۲، است.

جدول ۲. طبقه‌بندی خشک‌سالی بر اساس شاخص SPEI

شاخص SPEI	طبقه‌بندی خشک‌سالی
$SPEI \geq 2$	ترسالی بسیار شدید
$1.5 \leq SPEI \leq 1.99$	ترسالی شدید
$1 \leq SPEI \leq 1.49$	ترسالی متوسط
$-0.99 \leq SPEI \leq 0.99$	نزدیک به نرمال
$-1 \leq SPEI \leq -1.49$	خشک‌سالی متوسط
$-1.5 \leq SPEI \leq -1.99$	خشک‌سالی شدید
$SPEI \leq -2$	خشک‌سالی بسیار شدید

۲-۷- مدل‌های پیش‌بینی

مدل‌های پیش‌بینی، بر استفاده از متغیر تعداد فصل‌های گذشته در پیش‌بینی‌های آتی استوار است. به همین منظور،

یک بخش اضافه‌تر از RBF وارد محاسبات می‌شود. رابطه (۴) برای محاسبه مقدار خروجی در این شبکه مورد استفاده قرار می‌گیرد (Ahmadaali et al., 2013).

$$Y_r = \frac{1}{\sum_{b=1}^n f(X_r, b)} + \sum_{b=1}^n [f(X_r, b) \times T_b] \quad (۴)$$

که در آن T_b هدف مربوط به b امین مشاهده و n تعداد مشاهدات است.

۲-۵- شاخص خشک‌سالی استاندارد شده بارش-تبخیر و تعرق

محاسبه شاخص خشک‌سالی استاندارد شده بارش-تبخیر و تعرق (SPEI) همانند روش ارائه‌شده برای محاسبه شاخص استاندارد شده بارندگی (SPI)، نیازمند برآورد مقادیر احتمال تجمعی مقادیر D_i از طریق برازش یک تابع چگالی احتمال می‌باشد. با توجه به آنکه مقادیر D_i از کران پائین به مقادیر منفی منتهی می‌شوند، توابع احتمال دو پارامتری مثل توزیع گاما نمی‌توانند انتخاب مناسبی باشند. Vicente-Serrano et al. (2010) با بررسی توابع مختلف سه پارامتری، تابع چگالی احتمال لوگ-لوگستیک (Log-Logistic) سه پارامتری را دارای بهترین برازش بر مقادیر D_i تشخیص دادند. فرم کلی تابع چگالی احتمال این تابع به صورت رابطه ۵، می‌باشد:

$$f(x) = \frac{\beta}{\alpha} \left(\frac{x-\gamma}{\alpha} \right)^{\beta-1} \left(1 + \left(\frac{x-\gamma}{\alpha} \right)^{\beta} \right)^{-2} \quad (۵)$$

که در آن پارامترها α, β و γ به ترتیب پارامترهای مقیاس، شکل و اصلی برای مقادیر D_i در دامنه $\gamma > D < \infty$ می‌باشند. فرم تابع احتمال تجمعی لوگ-لوگستیک سه پارامتری سری‌های D مطابق رابطه ۶، است:


$$F(x) = \left[1 + \left(\frac{\alpha}{x-\gamma} \right)^{\beta} \right]^{-1} \quad (۶)$$

مقادیر احتمال تجمعی برای مقادیر D_i با استفاده از رابطه ۷، به تابع نرمال استاندارد شده با میانگین صفر و انحراف معیار یک تبدیل می‌شوند که برابر مقادیر شاخص SPEI می‌باشند.

$$SPEI = W - \frac{C_0 + C_1 W + C_2 W^2}{1 + d_1 W + d_2 W^2 + d_3 W^3} \quad (۷)$$

که در آن W از رابطه (۸) محاسبه می‌شود:

گردید؛ بدین صورت که برای پیش‌بینی در زمان $t+1$ ، از ویژگی‌های مذکور در زمان t استفاده شد. در مدل (۲) پیش‌بینی گردوغبار در فصل بعد با استفاده از دو فصل ماقبل صورت پذیرفت و به‌طور مشابه در مدل (۳) و (۴)، پیش‌بینی بر اساس ویژگی (ها) تا سه و چهار فصل قبل انجام شد



شکل ۶. ساختارهای مورد استفاده در پیش‌بینی گردوغبار

Scipy، Neupy 0.6.4، Scikit-learn 1.19.1، 1.14.0، 1.1.0، و Deap 1.2.2 بودند. پس از بررسی و کنترل کیفی آمار ایستگاه‌ها و رفع نواقص آماری، همگنی داده‌ها با استفاده از آزمون Run Test ارزیابی شده و تصادفی بودن داده‌ها در سطح اطمینان ۹۵ درصد پذیرفته شد.

۳ نتایج و بحث

۳-۱- بررسی تأثیر ویژگی‌های کمکی

ویژگی اصلی که در این پژوهش برای پیش‌بینی تعداد روزهای گردوغبار مورد استفاده قرار گرفت، ویژگی تعداد روزهای گردوغبار در فصل‌های ماقبل است. در آزمایش مربوط به پرسش اول به بررسی تأثیر استفاده از ویژگی‌های کمکی فصل‌های گذشته در پیش‌بینی تعداد روزهای گردوغبار پرداخته شد. این ویژگی‌ها به عنوان پارامترهای دخیل در آزمایش شناخته می‌شوند. در این قسمت به مقایسه حالت پیش‌بینی تنها با ویژگی تعداد روزهای گردوغبار و

متغیر تعداد فصل‌های گذشته جهت پیش‌بینی فصل آتی، می‌تواند شامل یک، دو، سه و چهار فصل قبل از بین متغیرهای گردوغبار و داده‌های اقلیمی باشد. شکل ۶، مدل‌های مورد استفاده در انتخاب فصل (های) گذشته جهت پیش‌بینی فراوانی گردوغبار در فصل آتی را نشان می‌دهد. در مدل (۱)، از سری زمانی با یک گام تأخیر استفاده

۸-۲- معیار ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج، از شاخص آماری میانگین قدر مطلق خطا (MAE- Mean Absolute Error) استفاده گردید. این معیار به‌صورت زیر تعریف می‌شود (Gauch et al., 2003):

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (9)$$


در رابطه فوق؛ O_i مقادیر مشاهداتی در گام زمانی t ام، P_i مقادیر پیش‌بینی‌شده در گام زمانی t ام و n تعداد داده‌ها می‌باشد. این شاخص برای مشخص کردن قدرت پیش‌بینی مدل و تعیین مقادیر خطای برآوردشده، به کار برده می‌شود. هر مدل که دارای MAE کمتر باشد، از مطلوبیت بیشتری برخوردار می‌باشد.

همچنین در این پژوهش هنگام یادگیری از روش اعتبارسنجی ضربدری یا صحت‌سنجی متقابل (3FCV-3) اعتبارسنجی استفاده شد. برای پیش‌بینی طوفان-های گردوغبار از محیط نرم‌افزار Python 2.7.17 استفاده شد که اصلی‌ترین ماژول‌های استفاده‌شده شامل Numpy

در پیش‌بینی گردوغبار بیشترین مقدار را داشته و در صورت استفاده از تمام ویژگی‌ها به‌عنوان ورودی، خروجی مدنظر خطای کمتری داشته و نزدیک به یک واحد کمتر از حالت دوم است. فصل تابستان، مقدار خطای مدل تقریباً مشابه با فصل زمستان است و توضیحات فوق برای این بخش نیز صادق است. مطابق شکل ۷، در فصل پاییز نیز، مقدار خطای مدل در پیش‌بینی تعداد روزهای گردوغباری نسبت به فصول دیگر کمتر بوده و در صورت استفاده از همه ویژگی‌ها یا عدم استفاده از ویژگی‌های کمکی به‌عنوان ورودی، خطای خروجی تقریباً یکسان می‌باشد. در مجموع، با توجه به نتایج و خطای حاصل شده (MAE) در پیش‌بینی روزهای همراه با طوفان گردوغبار می‌توان گفت که در ایستگاه آبادان، عدم استفاده از ویژگی‌های کمکی به‌جز یک مورد (فصل بهار)، نتایج بهتری داشته و خطای کمتری رخ می‌دهد.

حالت استفاده از ویژگی‌های کمکی پرداخته شد. جهت تسهیل آزمایش در این بخش، متغیر تعداد فصل‌های گذشته چهار انتخاب گردید و کلیه پیش‌بینی‌ها با استفاده از الگوریتم MLP صورت گرفته است و همه ویژگی‌ها از چهار فصل گذشته برای پیش‌بینی گردوغبار استفاده شده است. همچنین از معیار ارزیابی MAE برای اندازه‌گیری خطا استفاده گردید.

شکل ۷، بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه آبادان را نشان می‌دهد. مطابق شکل ۷، مشخص است، پیش‌بینی گردوغبار در پاییز کمترین خطا و فصل بهار بیشترین خطا (MAE) را داشته است. در فصل زمستان در صورتی که از همه ویژگی‌ها (داده گردوغبار به همراه شش پارامتر اقلیمی دیگر) در پیش‌بینی استفاده شود، خروجی مدنظر یعنی روزهای همراه با طوفان گردوغبار خطای بیشتری را نشان می‌دهد. در فصل بهار خطای MAE




شکل ۷. بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه آبادان

ورودی، خطای مدل افزایش می‌یابد. فصل تابستان، مقدار خطای مدل نسبت به فصل بهار و زمستان کمتر است اما از نظر نوع متغیر ورودی به مدل، همانند فصل زمستان می‌باشد. مطابق شکل ۸، در فصل پاییز نیز، مقدار خطای مدل در پیش‌بینی تعداد روزهای گردوغباری نسبت به فصول دیگر کمتر بوده و در صورت استفاده از همه ویژگی‌ها یا عدم استفاده از

در فصل زمستان در صورتی که از همه ویژگی‌ها (داده گردوغبار به همراه داده شش پارامتر اقلیمی دیگر) در پیش‌بینی استفاده شود، خروجی مدنظر یعنی روزهای همراه با طوفان گردوغبار خطای کمتری دارد. همان‌طور که اشاره شد، در فصل بهار خطای مدل در پیش‌بینی گردوغبار بیشترین مقدار را داشته و در صورت استفاده از همه ویژگی‌ها به‌عنوان

ویژگی‌های کمکی به‌عنوان ورودی، خطای خروجی تقریباً یکسان می‌باشد. در مجموع، با توجه به نتایج و خطای حاصل‌شده (MAE) در پیش‌بینی روزهای همراه با طوفان گردوغبار می‌توان گفت که در ایستگاه اهواز، اگر از تمام ویژگی‌ها به‌جز یک مورد (فصل بهار) به‌عنوان ورودی مدل استفاده شود، نتیجه پیش‌بینی بهتر بوده و خطای کمتری رخ می‌دهد.




شکل ۸. بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه اهواز

شکل ۹، بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه بستان را نشان می‌دهد. همان‌گونه که در شکل ۹، مشخص است، پیش‌بینی گردوغبار در پاییز با اختلاف زیاد کمترین خطا را داشته و خطای پیش‌بینی در سه فصل دیگر تقریباً مشابه است. در فصل زمستان در صورتی که از همه ویژگی‌ها در پیش‌بینی استفاده شود، خروجی مدنظر یعنی روزهای همراه با طوفان گردوغبار خطای بیشتری را حاصل می‌کند. در فصل بهار و تابستان مقدار خطا تقریباً مشابه بوده و در صورت استفاده از ویژگی‌های کمکی، خطا در پیش‌بینی گردوغبار کمتر است و عکس فصل زمستان می‌باشد. مطابق شکل ۹، در فصل پاییز نیز، مقدار خطای مدل در پیش‌بینی تعداد روزهای گردوغباری کم بوده و نوع متغیر ورودی تفاوتی در نتیجه ایجاد نمی‌کند. در مجموع، با توجه به نتایج و خطای حاصل‌شده در پیش‌بینی روزهای همراه با طوفان گردوغبار می‌توان گفت که در ایستگاه بستان، در صورتی که از تمام ویژگی‌ها به‌جز یک مورد (فصل

زمستان) به‌عنوان ورودی مدل استفاده شود، نتیجه پیش‌بینی بهتر بوده و خطای کمتری رخ می‌دهد به‌عنوان جمع‌بندی می‌توان گفت که در ایستگاه‌های اهواز و بستان استفاده از تمام ویژگی‌ها به‌عنوان ورودی باعث می‌شود که خطای مدل در پیش‌بینی کمتر شده و نتیجه بهتری حاصل شود. در ایستگاه آبادان عدم استفاده از ویژگی‌های کمکی، چنین نتیجه‌ای را به دست می‌دهد. در تمامی شکل‌های ۷ تا ۹، تغییرات معیار خطا در صورت استفاده از ویژگی‌های کمکی در پیش‌بینی گرد و غبار در بازه اطمینان ۹۵ درصد معنی‌دار نشد که نکته حائز اهمیت است.

نکته بعدی مقایسه پیش‌بینی در فصل‌های سال می‌باشد. نتایج مربوط به فصل پاییز همیشه جزو دقیق‌ترین بوده و تقریباً در تمامی ایستگاه‌ها، پیش‌بینی مربوط به این فصل بهترین نتیجه را داشته است. در نقطه مقابل نیز، پیش‌بینی‌های روزهای همراه با طوفان گردوغبار در فصل بهار خطای بیشتری را نسبت به دیگر فصل‌ها داشته است.

شکل ۹، بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه بستان را نشان می‌دهد. همان‌گونه که در شکل ۹، مشخص است، پیش‌بینی گردوغبار در پاییز با اختلاف زیاد کمترین خطا را داشته و خطای پیش‌بینی در سه فصل دیگر تقریباً مشابه است. در فصل زمستان در صورتی که از همه ویژگی‌ها در پیش‌بینی استفاده شود، خروجی مدنظر یعنی روزهای همراه با طوفان گردوغبار خطای بیشتری را حاصل می‌کند. در فصل بهار و تابستان مقدار خطا تقریباً مشابه بوده و در صورت استفاده از ویژگی‌های کمکی، خطا در پیش‌بینی گردوغبار کمتر است و عکس فصل زمستان می‌باشد. مطابق شکل ۹، در فصل پاییز نیز، مقدار خطای مدل در پیش‌بینی تعداد روزهای گردوغباری کم بوده و نوع متغیر ورودی تفاوتی در نتیجه ایجاد نمی‌کند. در مجموع، با توجه به نتایج و خطای حاصل‌شده در پیش‌بینی روزهای همراه با طوفان گردوغبار می‌توان گفت که در ایستگاه بستان، در صورتی که از تمام ویژگی‌ها به‌جز یک مورد (فصل




شکل ۹. بررسی تأثیر ویژگی‌های کمکی در پیش‌بینی گردوغبار ایستگاه بستان

استفاده از داده‌های چهار فصل، مقدار خطا در پیش‌بینی گردوغبار بیشترین مقدار می‌باشد. در مجموع و با توجه شکل ۱۰، نتایج و خطای حاصل شده (MAE) در پیش‌بینی روزهای همراه با طوفان گردوغبار در ایستگاه آبادان نشان می‌دهد در صورتی که از سه فصل گذشته، به‌عنوان ورودی مدل استفاده شود، نتیجه پیش‌بینی بهتر بوده و خطای کمتری رخ می‌دهد. شکل ۱۱، بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی گردوغبار ایستگاه اهواز را نشان می‌دهد. اگر از اطلاعات یک، دو، سه و یا چهار فصل گذشته در پیش‌بینی گردوغبار استفاده شود، در تمامی این چهار حالت مشاهده می‌شود شکب ۱۱، که فصل پاییز کمترین خطا، و به ترتیب تابستان، زمستان و بهار رتبه‌های بعدی در میزان خطا (MAE) را داشته‌اند و روند آن همانند ایستگاه آبادان است. در بین استفاده از تعداد فصل‌های گذشته در پیش‌بینی گردوغبار، مشخص است که به‌طور نسبی در حالت استفاده از داده‌های سه فصل گذشته، میزان خطا در خروجی کمترین و استفاده از داده‌های یک فصل، مقدار خطا در پیش‌بینی گردوغبار بیشترین بوده است. در مجموع و با توجه شکل ۱۱، نتایج و خطای حاصل شده (MAE) در پیش‌بینی روزهای همراه با طوفان گردوغبار در ایستگاه اهواز نشان می‌دهد در صورتی که از اطلاعات سه فصل گذشته، به‌عنوان ورودی مدل استفاده شود، نتیجه پیش‌بینی بهتر بوده و خطای کمتری رخ می‌دهد.

۳-۲- بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی


عامل دیگری که در انتخاب ویژگی‌های مورد نیاز برای پیش‌بینی تعداد روزهای گردوغبار در ایستگاه‌ها تأثیر دارد، استفاده از ویژگی‌های (اعم از تعداد روزهای گردوغبار و کمکی) فصل‌های قبل است. تعداد این فصول که برای پیش‌بینی مورد استفاده قرار می‌گیرند، عاملی است که انتخاب آن در کیفیت کارایی مدل به‌دست آمده تأثیر دارد. در آزمایش دوم به بررسی تعداد فصل‌های ماقبل که ویژگی‌های آن‌ها برای پیش‌بینی مورد استفاده قرار گرفت، پرداخته شد. در این بخش، مدل استفاده و تفسیر شده MLP بوده و همه ویژگی‌ها اعم از متغیر گردوغبار و شش متغیر دیگر به‌عنوان ورودی در نظر گرفته شدند. تنها عاملی که باعث انتخاب برترین ویژگی می‌شود، استفاده از داده‌های فصول قبل که از یک تا چهار است، می‌باشد. شکل ۱۰، بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی گردوغبار ایستگاه آبادان را نشان می‌دهد. با توجه به شکل ۱۰، اگر از اطلاعات یک، دو، سه و یا چهار فصل گذشته در پیش‌بینی گردوغبار استفاده شود، مشاهده می‌شود که فصل پاییز کمترین خطا، و به ترتیب تابستان، زمستان و بهار رتبه‌های بعدی در میزان خطا (MAE) را داشته‌اند. در بین استفاده از تعداد فصل‌های گذشته در پیش‌بینی گردوغبار، مشخص است که به‌طور نسبی در حالت استفاده از داده‌های سه فصل گذشته، میزان خطا در خروجی کمترین و در حالت مقابل،




شکل ۱۰. بررسی تأثیر تعداد فصل های گذشته در پیش بینی گردوغبار ایستگاه آبادان

میزان خطا مشاهده نشد. اما در حالت کلی و با توجه شکل ۱۲، نتایج و خطای حاصل شده (MAE) در پیش بینی روزهای همراه با طوفان گردوغبار در ایستگاه بستان نشان می دهد در صورتی که از اطلاعات سه فصل گذشته، به عنوان ورودی مدل استفاده شود، نتیجه پیش بینی بهتر از حالت های استفاده از اطلاعات دیگر فصل های گذشته است. به عنوان جمع بندی می توان گفت که استفاده از داده های سه فصل گذشته باعث می شود که خطای مدل MLP در پیش بینی کمتر شده و نتیجه بهتری حاصل شود. در بین فصول سال، بهترین پیش بینی وقوع گردوغبار با اختلاف در فصل پاییز رخ داده و کمترین خطا را بین این سه ایستگاه داشته است.

شکل ۱۲، بررسی تأثیر تعداد فصل های گذشته در پیش بینی گردوغبار ایستگاه بستان را نشان می دهد. اگر از اطلاعات یک، دو، سه و یا چهار فصل گذشته در پیش بینی گردوغبار استفاده شود، در تمامی این چهار حالت مشاهده می شود (شکل ۱۲). فصل پاییز با اختلاف کمترین خطا (MAE) و زمستان، تابستان و بهار رتبه های بعدی خطا در پیش بینی گردوغبار را به خود اختصاص داده اند. در بین استفاده از تعداد فصل های گذشته در پیش بینی گردوغبار، در حالت استفاده از داده های سه فصل گذشته، میزان خطا در پاییز و زمستان نسبت به تعداد فصول دیگر کمترین بوده و فصل تابستان و بهار آن بیشترین خطا را دارد و در فصل گرم، روند یکنواختی در



شکل ۱۱. بررسی تأثیر تعداد فصل های گذشته در پیش بینی گردوغبار ایستگاه اهواز



شکل ۱۲. بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی گردوغبار ایستگاه بستان


یک نگاه کلی و بدون در نظر گرفتن شبکه عصبی مصنوعی می‌توان یافت که پیش‌بینی‌ها در فصل پاییز در ایستگاه آبادان خطای کمتری دارد و در نقطه مقابل، پیش‌بینی در فصل بهار خطای بیشتری را حاصل کرده است. همچنین در فصل زمستان، دقت چهار مدل به کار گرفته شده تقریباً یکسان است.

در فصل بهار مدل RBF کمترین و مدل ANFIS بیشترین دقت را دارد. در فصل تابستان عکس حالت قبل بوده و مدل ANFIS کمترین و مدل RBF بیشترین دقت را دارد. همین نتیجه در فصل پاییز صادق است. بررسی بهترین مدل در ایستگاه مربوطه (شکل ۱۳) نشان می‌دهد که مدل RBF و GRNN و در برخی موارد مدل ANFIS دقت مشابهی را در شکل ۱۴، بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه اهواز را نشان می‌دهد. پیش‌بینی‌ها در فصل پاییز در ایستگاه اهواز خطای کمتری دارد و در نقطه مقابل، پیش‌بینی در فصل بهار خطای بیشتری را حاصل کرده است. همچنین در فصل زمستان خطای به کارگیری مدل RBF کمتر از بقیه مدل‌ها است. در فصل بهار عکس این مطلب صادق است. در فصل بهار مدل RBF کمترین و مدل ANFIS بیشترین دقت را دارد. در فصل تابستان مدل MLP کمترین و مدل GRNN بیشترین خطا را دارد.

در نقطه مقابل نیز، پیش‌بینی‌های روزهای همراه با طوفان گردوغبار در فصل بهار و تابستان خطای بیشتری را نسبت به دیگر فصل‌ها داشته است. زیرا منشا گردوغبار در این فصل‌ها بیشتر خارجی بوده و علت آن خشک شدن ذرات خاک به دلیل افزایش دما و انتقال آن توسط باد می‌باشد که در دو فصل قبلی، کمتر چنین چیزی رخ می‌دهد. لذا دقت مدل در دو فصل بهار و تابستان، به همین دلیل کاهش یافته است. نکته مهم اینکه میزان تغییرات معیار خطا در صورت استفاده از تعداد فصل‌های گذشته در پیش‌بینی گردوغبار، در بازه اطمینان ۹۵ درصد معنی‌دار نشد که نشان از دقت پیش‌بینی‌ها دارد.

۳-۳- انتخاب بهترین مدل


همان‌گونه که گفته شد از چهار روش MLP، RBF، GRNN و ANFIS برای ساخت مدل پیش‌بینی تعداد روزهای گردوغبار هوا استفاده می‌شود. در این قسمت به مقایسه این مدل‌ها پرداخته شد. پارامترهای تعداد فصل گذشته برابر چهار، ثابت در نظر گرفته شده و کل ویژگی‌ها به‌عنوان ورودی محسوب شدند. لذا نتیجه نشان می‌دهد که کدام مدل کمترین خطا (MAE) را حاصل کرده و در چه فصلی پیش‌بینی بهتری خواهد داشت. شکل ۱۳، بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه آبادان را نشان می‌دهد. در



شکل ۱۳. بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه آبادان

گردوغبار می‌توان گفت که در ایستگاه آبادان (شکل ۱۳)، استفاده از مدل‌های MLP و RBF منجر به کاهش خطا شده است. به‌عنوان جمع‌بندی می‌توان گفت که در ایستگاه بستان در صورت استفاده از تمام ویژگی‌ها و داده‌های چهار فصل گذشته، مدل ANFIS به‌عنوان ورودی باعث می‌شود که خطای پیش‌بینی کمتر شده و نتیجه بهتری حاصل شود. در ایستگاه آبادان استفاده از مدل MLP چنین نتیجه‌ای را به دست می‌دهد. ضمن اینکه در ایستگاه اهواز مدل RBF بهترین مدل شناخته شد. نکته بعدی مقایسه پیش‌بینی در فصل‌های سال می‌باشد. فصل پاییز بیشترین فراوانی را در بین این هفت ایستگاه داشته و تقریباً در تمامی ایستگاه‌ها، پیش‌بینی مربوط به این فصل بهترین نتیجه را داشته است. در نقطه مقابل نیز، پیش‌بینی‌های روزهای همراه با طوفان گردوغبار در فصل بهار خطای بیشتری را نسبت به دیگر فصل‌ها داشته است. به عبارت دیگر مدل‌های به کار گرفته شده، منشأ خارجی گردوغبار (فصل پاییز و زمستان) را بهتر از منبع داخلی آن (فصل بهار و تابستان) پیش‌بینی می‌کند. نکته قابل توجه اینکه در هنگام استفاده از بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار، تغییرات معیار خطا در بازه اطمینان ۹۵ درصد معنی‌دار نشد.

در فصل پاییز نیز مدل RBF و GRNN کمترین خطا را دارد. بررسی بهترین مدل در ایستگاه مربوطه شکل ۱۴، نشان می‌دهد که مدل ANFIS و GRNN بیشترین و مدل RBF و MLP کمترین خطا را در بین فصل‌ها ثبت کرده‌اند. در مجموع، با توجه به نتایج و خطای حاصل شده (MAE) در پیش‌بینی روزهای همراه با طوفان گردوغبار می‌توان گفت که در ایستگاه اهواز (شکل ۱۴)، به ترتیب مدل RBF کمترین و مدل ANFIS بیشترین خطا را دارند. شکل ۱۵، بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه بستان را نشان می‌دهد. پیش‌بینی‌ها در فصل پاییز در ایستگاه بستان نیز خطای کمتری دارد و در نقطه مقابل، پیش‌بینی در فصل بهار و زمستان خطای بیشتری را حاصل کرده است. در فصل زمستان خطای به‌کارگیری مدل ANFIS با اختلاف قابل توجهی کمتر از بقیه مدل‌ها بوده و در تمام فصول این روند تکرار شده است. در فصل بهار و تابستان مدل GRNN و در فصل پاییز مدل MLP بیشترین خطا را دارد. بررسی بهترین مدل در ایستگاه مربوطه شکل ۱۵، نشان می‌دهد که به‌کارگیری مدل ANFIS کمترین خطا را حاصل می‌کند. سه فصل ثبت کرده‌اند. در مجموع، با توجه به نتایج و خطای حاصل شده (MAE) در پیش‌بینی روزهای همراه با طوفان




شکل ۱۴. بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه اهواز

آماري ۲۵ ساله، شاخص خشک‌سالی استاندارد شده بارش - تبخیر و تعرق (SPEI) نیز در پنجره زمانی فصلی محاسبه گردید. پیش‌بینی تعداد روزهای همراه با طوفان‌های گردوغبار در مقیاس فصلی با استفاده از چهار روش هوش مصنوعی انجام شد که در غالب سه آزمایش شامل بررسی تأثیر افزودن ویژگی‌های کمکی بر روی پیش‌بینی، بررسی تأثیر تعداد فصل‌های گذشته در پیش‌بینی و بررسی بهترین الگوریتم یادگیری شامل MLP، RBF، GRNN و ANFIS مورد ارزیابی قرار گرفت. آنچه در بخش پیش‌بینی مورد بررسی قرار گرفت، طراحی آزمایش‌هایی برای پاسخ به سه پرسش اصلی بود که در ابتدای تحقیق به آن‌ها پرداخته شد و شاکله این مطالعه می‌باشند.

۴ جمع‌بندی

این پژوهش با هدف کاربرد شبکه‌های عصبی مصنوعی شامل شبکه عصبی پرسپترون چندلایه (MLP)، سیستم استنتاج تطبیقی فازی-عصبی (ANFIS)، شبکه عصبی تابع پایه شعاعی (RBF) و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) به منظور پیش‌بینی طوفان گردوغبار در استان خوزستان انجام شد.

در این مطالعه برای بررسی تأثیرپذیری طوفان‌های گردوغبار از نوسانات اقلیمی علاوه بر داده‌های ساعتی گردوغبار و داده‌های ماهانه، فصلی هواشناسی و اقلیمی شامل دمای بیشینه، کمینه، میانگین، سرعت بیشینه باد و مجموع بارش در سه ایستگاه همدیدی آبادان، اهواز و بستان با طول دوره



شکل ۱۵. بررسی بهترین الگوریتم یادگیری در پیش‌بینی گردوغبار ایستگاه بستان

- neural networks, delayed memory line, gamma and ANFIS with PSO-based educational methods. *Control journal*, 2(1), 1-19.
- Ansari Ghojghar, M., Pourgholam-Amiji, M., Bazrafshan, J., Liaghat, A., & Araghinejad, Sh. (2020). Performance Comparison of Statistical, Fuzzy and Perceptron Neural Network Models in Forecasting Dust Storms in Critical Regions in Iran. *Iranian Journal of Soil and Water Research*, 51(8), 2051-2063. (In Persian)
- Araghinejad, S. (2013). *Data-driven modeling: using MATLAB® in water resources and environmental engineering* (Vol. 67). Springer Science & Business Media.
- Araghinejad, Sh., Ansari Ghojghar, MPourgholam-Amiji, M., Liaghat, A & Bazrafshan, J. (2019). The Effect of Climate Fluctuation on Frequency of Dust Storms in Iran. *Desert Ecosystem Engineering Journal*, 7(21), 13-32. (In Persian)
- Chen, S., Cowan, C. F. N. & Grant, P. M., (1991). Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks. *IEEE Transactions on Neural Networks*, 2(2), 302-309.
- Dahiya, S., Singh, B., Gaur, S., Garg, V. K., & Kushwaha, H. S. (2007). Analysis of groundwater quality using fuzzy synthetic evaluation. *Journal of Hazardous Materials*, 147(3), 938-946.
- Gauch, H. G., Hwang, J. G., & Fick, G. W. (2003). Model evaluation by comparison of model-based predictions and measured values. *Agronomy Journal*, 95(6), 1442-1446.
- Hassanzadeh, Y., Abdi Kordani, A. & Fakheri Fard, A. (2012). Drought Forecasting Using Genetic Algorithm and Conjoined Model of Neural Network-Wavelet. *Journal of Water and Wastewater*, 23(3), 48-59. (In Persian)
- Hosseini Pazhouh, N., Ahmadaali, K., & Shokoohi, A. (2019). Assessment of standardized precipitation and standardized precipitation-evapotranspiration indices for wet period detection. *Journal of Water and Soil Conservation*, 25(6), 207-221. (In Persian)
- Hosseini-Moghari, S. M., & Araghinejad, Sh. (2016). Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e-Kavous Station). *Water and Soil*, 30(1), 247-259. (In Persian)
- Huang, M., Peng, G., Zhang, J., & Zhang, S. (2006). Application of artificial neural networks to the prediction of dust storms in Northwest China. *Global and Planetary change*, 52(1-4), 216-224.
- Ibarra-Berastegi, G., Elias, A., Barona, A., Saenz, J., Ezcurra, A., & de Argandoña, J. D. (2008). From diagnosis to prognosis for forecasting air pollution using neural networks: Air pollution monitoring in Bilbao. *Environmental Modelling & Software*, 23(5), 622-637.
- Jamalzadeh Tajabadi, M. R., Moghaddamnia, A. R. در این قسمت به تحلیل خروجی هر یک از این آزمایش‌ها به‌طور جداگانه پرداخته می‌شود.
- در بخش اول به بررسی تأثیر ویژگی‌های کمکی پرداخته شد. همان‌گونه که نتایج نشان داد، استفاده از ویژگی‌های کمکی به‌خصوص در پیش‌بینی فراوانی روزهای همراه با طوفان گردوغبار فصل تابستان، تأثیر مهمی داشته و باعث کاهش میزان میانگین مطلق خطا شده‌اند.
- در بخش دوم، به بررسی تعداد فصل‌های گذشته در پیش‌بینی پرداخته شد. در این پژوهش مشاهده شد که کمینه مطلق خطا در اکثر ایستگاه‌ها، به‌خصوص در هنگام پیش‌بینی فصل زمستان، مربوط به حالتی است که ویژگی‌های سه فصل ماقبل در پیش‌بینی مورد استفاده قرار گیرند.
- در نهایت در بخش سوم، به بررسی مدل‌های یادگیری پرداخته شد. در اکثر ایستگاه‌های مورد بررسی، مدل ANFIS و بعد از آن MLP از کمترین میانگین مطلق خطا و بیشترین دقت برای پیش‌بینی گردوغبار در اکثر فصل‌ها برخوردار بودند.

۵. قدردانی

بدین وسیله از گروه مهندسی آبیاری و آبادانی دانشگاه تهران و سازمان هواشناسی کشور به دلیل تأمین امکانات لازم برای انجام این پژوهش و تهیه مقالات مربوطه تشکر و قدردانی می‌شود.

۶. منابع

- Abdolshahnejad, M., Khosravi, H., Nazari Samani, A. A., Zehtabian, G. R. & Alambaigi, M. (2020). Determining the Conceptual Framework of Dust Risk Based on Evaluating Resilience (Case Study: Southwest of Iran). *Strategic Research Journal of Agricultural Sciences and Natural Resources*, 5(1), 33-44. (In Persian)
- Ahmadaali, K., Liaghat, A., Heydari, N., & Bozorg-Haddad, O. (2013). Application of artificial neural network and adaptive neural-based fuzzy inference system techniques in estimating of virtual water. *International Journal of Computer Application*, 76, 12-19.
- Aliyari, M., Teshnehlal, M. & Khaki Sedigh, A. (2008). Short-term forecast of air pollution by

- the Relationship between Dust Storms and Extreme and Average Temperature Variables in the Western Half of Iran. *Journal of Climate Research*, 12(45), 113-126. (In Persian)
- Pourgholam-Amiji, M., Ansari Ghojghar, M., Bazrafshan, J., Liaghat, A., & Araghinejad, Sh. (2020). Comparing the Performance of SARIMA and Holt-Winters Time Series Models With Artificial Intelligence Methods in Dust Storms Forecasting (Case Study: Sistan and Baluchestan Province). *Physical Geography Research Quarterly*, 52(4), 567-587. (In Persian)
- Raudkivi, A. J. (2013). *Hydrology: An advanced introduction to hydrological processes and modelling*. Elsevier.
- Sobhani, B., Safarian Zengir, V., & faizollahzadeh, S. (2020). Modeling and prediction of dust in western Iran. *Physical Geography Research Quarterly*, 52(1), 17-35. (In Persian)
- Sobhani, B., Salahi, B. & Goldust, A. (2015). Study the dust and evaluation of its possibility prediction based on statistical methods and ANFIS model in Zabol University. *Geography and Development Iranian journal*, 13(38), 123-138. (In Persian)
- Specht, D. F. (1991). A general regression neural network. *IEEE transactions on neural networks*, 2(6), 568-576.
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *Journal of climate*, 23(7), 1696-171.
- & Piri, J. (2008). Investigating the ability of both artificial neural networks and supporting vector machines to predict dust storms in Zabol city. 4th National Conference on Watershed Management Sciences and Engineering, Management of watersheds. (In Persian).
- Jamalizadeh Tajabadi, M. R., Moghaddamnia, A. R., Piri, J. & Ekhtesasi, M. R. (2010). Application of artificial neural networks in dust storm prediction (case study: Zabol city). *Iranian journal of Range and Desert Research*, 17(2), 205-220. (In Persian)
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* (Vol. 17, No. 22, pp. 179-183).
- O'Loingsigh, T., McTainsh, G. H., Tews, E. K., Strong, C. L., Leys, J. F., Shinkfield, P., & Tapper, N. J. (2014). The Dust Storm Index (DSI): a method for monitoring broadscale wind erosion using meteorological records. *Aeolian Research*, 12, 29-40.
- Osman, N., Jamlos, M. F., Dzaharudin, F., Khan, A. R., Yeow, Y. K., & Khairi, K. A. (2022). Real-Time and Predictive Analytics of Air Quality with IoT System: A Review. *Recent Trends in Mechatronics Towards Industry 4.0*, 107-116.
- Pourgholam-Amiji, M., Ansari Ghojghar, M., Araghinejad, Sh., & Babaeian, I. (2021). Modeling