

## مدلسازی پتانسیل ایجاد کانون‌های گردوغبار با استفاده از سری زمانی داده‌های سنجش ازدور، منطق فازی و شبکه عصبی مصنوعی (مطالعه موردی: حوضه فرات)

رامین پاپی<sup>۱</sup>، میثم ارگانی<sup>۲\*</sup>، شهاب مرادی پور<sup>۳</sup>، مسعود سلیمانی<sup>۱</sup>

۱- دانشجوی دکتری سنجش‌ازدور و سیستم اطلاعات جغرافیایی- دانشکده جغرافیا- دانشگاه تهران

۲- استادیار گروه سنجش‌ازدور و سیستم اطلاعات جغرافیایی- دانشکده جغرافیا- دانشگاه تهران

۳- دانش‌آموخته کارشناسی ارشد سنجش‌ازدور و سیستم اطلاعات جغرافیایی- دانشکده جغرافیا- دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۸/۱۰/۱۳ تاریخ پذیرش مقاله: ۱۳۹۹/۰۹/۲۶

### چکیده

طوفان‌های گردوغبار به عنوان یکی از معضلات زیست‌محیطی شایع در مناطق خشک و نیمه‌خشک جهان به شمار می‌روند که هم برای سلامت انسان و هم به لحاظ اقتصادی زیان‌بار هستند. این طوفان‌ها از حدود دو دهه گذشته تاکنون در مقیاس‌های محلی، منطقه‌ای و حتی جهانی در حال افزایش هستند. حوضه رودخانه فرات به عنوان یکی از فعال‌ترین کانون‌های گردوغبار در سطح جهانی شناخته شده است. شناسایی کانون‌های طوفان گردوغبار اولین گام در برنامه‌ریزی هدفمند جهت مبارزه با این پدیده زیست‌محیطی به حساب می‌آید. هدف از پژوهش حاضر، تهیه نقشه پتانسیل کانون‌های گردوغبار در حوضه رودخانه فرات با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه است. در گام نخست سری زمانی بلندمدت داده‌های مربوط به پارامترهای محیطی کلیدی و موثر بر رخداد طوفان‌های گردوغبار شامل رطوبت، دما و بافت خاک، دمای سطح زمین، سرعت باد، بارش، تبخیر-تعرق، ماه‌های دارای گردوغبار، کاربری اراضی، فشار ناشی از جمعیت، ارتفاع و شیب شناسایی شده و به عنوان ورودی‌های شبکه عصبی به کار گرفته شدند. از طریق بررسی ۲۵۰۰ تصویر رنگی طبیعی سنجنده مادیس، تعداد ۱۹۰ کانون رخداد طوفان گردوغبار به صورت بصری شناسایی و به عنوان نقاط آموزشی به شبکه عصبی معرفی شدند. ۷۰ درصد نقاط (۱۳۳ نقطه) برای آموزش و ۳۰ درصد نقاط (۵۷ نقطه) برای تست و اعتبارسنجی مدل مورد استفاده قرار گرفتند. پس از اجرای مدل، مقدار خطای میانگین مربعات معادل ۰/۱ به دست آمد که حاکی از صحت قابل قبول شبکه عصبی در شناسایی کانون‌های بالقوه گردوغبار است. نتایج نشان می‌دهد که ۱۴۷ هزار کیلومتر مربع از مساحت کل حوضه، مستعد شکل‌گیری کانون طوفان‌های گردوغبار است که عمدتاً نواحی کم بارش، خشک و بایر حوضه را شامل می‌شوند.

کلید واژه‌ها: طوفان گردوغبار، سنجش‌ازدور، سری زمانی، شبکه عصبی مصنوعی، حوضه فرات.

\* نویسنده مکاتبه کننده: تهران، خیابان انقلاب، خیابان قدس، کوچه آذین، دانشکده جغرافیا، گروه سنجش از دور و سیستم اطلاعات جغرافیا، دانشگاه تهران..

تلفن: ۰۹۱۲-۳۲۴-۶۰۸۷

## ۱- مقدمه

طوفان‌های گردوغبار<sup>۱</sup> پدیده‌ای شایع در مناطق خشک و نیمه‌خشک به‌شمار می‌رود و معمولاً در بیابان‌ها بیشتر از سایر مناطق اتفاق می‌افتند [۱ و ۲]. ذرات گردوغبار با پخش تابش خورشیدی مستقیماً بر روی بیلان تابشی جو و زمین تأثیر می‌گذارند [۳]. گردوغبار همچنین می‌تواند با تغییر آلبیدوی<sup>۲</sup> ابرها و همچنین به عنوان هستک‌های تراکمی<sup>۳</sup> بر بیلان انرژی اتمسفر تأثیرگذار واقع گردد [۴]. علاوه بر این گردوغبار بر چرخه آب، فرآیندهای بیولوژیکی، چرخه کربن و پایداری اتمسفر نیز تأثیر بسزایی دارد. ضمن اینکه وقوع این پدیده سبب آسیب مستقیم به سلامت انسان و افزایش مرگ‌ومیر می‌شود [۵، ۶ و ۷]. مطالعات قبلی نشان می‌دهند که منطقه خاورمیانه یکی از کانون‌های اصلی گردوغبار در جهان است [۸]. عواملی همچون پروژه‌های احداث سد بر روی رودخانه فرات، شهرنشینی و رشد جمعیت و کمبود آب جزء علل اصلی تشدید فعالیت گردوغبار حوضه فرات، در طی سال‌های اخیر به‌شمار می‌رود [۹]. دشت‌ها، بیابان‌ها، مراتع تخریب‌یافته، زمین‌های کشاورزی، خشک‌رودها و بسیاری از مناطق فرسایش‌پذیر واقع در جنوب غرب آسیا خصوصاً در کشورهای ایران، عراق و سوریه سبب ایجاد وضعیت بحرانی از نظر تولید گردوغبار در چند سال اخیر شده‌اند [۱۰]. بهره‌گیری از اقدامات مناسب جهت کنترل و پیشگیری از طوفان‌های گردوغبار، در گام نخست مستلزم حصول شناخت کامل از عوامل پدیدآورنده و تشدیدکننده آن و همچنین شناسایی کانون‌های تولیدکننده گردوغبار است. پارامترهای محیطی مانند رطوبت خاک<sup>۴</sup>، دمای هوا<sup>۵</sup>، بافت خاک<sup>۶</sup>،

میزان بارش<sup>۷</sup> و کاربری زمین<sup>۸</sup> جزء مهم‌ترین عوامل مؤثر بر ایجاد کانون طوفان‌های گردوغبار به‌شمار می‌رود [۹]. مفیدی و جعفری در سال ۲۰۱۱ نقش گردش اتمسفری خاورمیانه، در وقوع طوفان‌های گردوغبار تابستانه در جنوب غرب ایران را مورد مطالعه و بررسی قرار دادند. آن‌ها با استفاده از داده‌های گردیدندی ان. سی. ای. آر (NCAR)<sup>۹</sup> و شاخص آئروسول ماهواره تامس (TOMS)<sup>۱۰</sup> ویژگی‌های دینامیک هر یک از طوفان‌های گردوغبار را دو روز قبل از وقوع طوفان تا زمان اوج آن در بازه‌های زمانی ۶ ساعته بررسی کردند. تعیین منابع اصلی گردوغبار برای هر یک از طوفان‌های گردوغبار با بهره‌گیری از مدل لاگرانژیتهی های اسپلیت (HYSPLIT)<sup>۱۱</sup> انجام شد. نتایج بیانگر آن بود که زبانه پسرگرد کم‌فشار زاگرس و پرفشار عربستان بیش از هر مؤلفه گردشی دیگری در شکل‌گیری طوفان‌های با مقیاس منطقه-ای در ناحیه جنوب غرب ایران نقش دارند [۱۱]. هوی کائو و همکاران در سال ۲۰۱۵ با استفاده از همپوشانی وزنی مجموعه داده‌های زیست‌محیطی مانند رویدادهای خشکسالی، دما، بارش، نوع خاک، فراوانی وقوع گردوغبار، تخریب فیزیکی و شیمیایی خاک، شاخص نفوذ انسان شامل میزان دسترسی و تراکم جمعیت، شاخص باران مؤثر<sup>۱۲</sup>، تولید اولیه خالص<sup>۱۳</sup> طی یک دوره ۱۴ ساله، شش کانون عمده گردوغبار را در سطح خاورمیانه مشخص کردند که دو کانون آن در دشت‌های حوضه فرات قرار دارند [۱۲]. تان و همکاران در سال ۲۰۱۷، رخداد طوفان‌های گردوغبار منطقه

<sup>۶</sup> Soil Texture<sup>۷</sup> Precipitation<sup>۸</sup> Land-use<sup>۹</sup> National Center for Atmospheric Research<sup>۱۰</sup> Total Ozone Mapping Spectrometer<sup>۱۱</sup> Hybrid Single Particle Integrated Trajectory Model<sup>۱۲</sup> Effective Rainfall<sup>۱۳</sup> Net Primary Production<sup>۱</sup> Dust Storms<sup>۲</sup> Albedo<sup>۳</sup> Condensation Nucleus<sup>۴</sup> Soil Moisture<sup>۵</sup> Air Temperature

مربوط به فعالیت های گردوغبار کانون های جنوب (صحرای ربع الخالی) و بخش شرقی شبه جزیره عربستان (کشور عمان) است. نتایج این پژوهش حاکی از آن است که گردوغبار ثبت شده در فلات ایران، به وسیله بادهای غربی از کانون گردوغبار موجود در حوضه دجله و فرات برخاسته و به فلات ایران انتقال پیدا کرده است. در نهایت نتایج نشان داد، قطر ذرات گردوغبار کانون حوضه فرات، دارای اندازه بسیار کوچکی هستند و تمام کانون های گردوغبار شناسایی شده در طی فصول بهار و تابستان فعال هستند [۱۵]. در چند دهه اخیر مطالعات زیادی در خصوص حمل و انتقال ذرات گردوغبار و مسیرهای عبور آن ها در منطقه غرب آسیا انجام شده است [۱۶]. نظر به قابلیت های مدل های مبتنی بر هوش مصنوعی و یادگیری ماشینی و کاربرد گسترده آن ها در علوم محیطی، با این حال توجه چندانی به بکارگیری اینگونه مدل ها در زمینه تهیه نقشه پتانسیل کانون های شکل گیری طوفان های گردوغبار خصوصاً در حوضه رودخانه فرات مبذول نگردیده است [۱۷]. معدود مطالعاتی پیرامون تهیه نقشه پتانسیل گردوغبار با استفاده از مدل تصمیم گیری چندمعیاره در این منطقه صورت گرفته است [۱۸]. دخالت و سهم بالای دانش انسانی در مدل های تصمیم گیری چندمعیاره به نوبه خود سبب وارد شدن عدم قطعیت به نتایج می شود. مدل های مبتنی بر هوش مصنوعی می توانند میزان عدم قطعیت مزبور را تا حد قابل توجهی کاهش دهند و بدین ترتیب از کارایی بالایی جهت پایش مسائل زیست محیطی برخوردار هستند [۱۹]. در پژوهش حاضر برای اولین بار با بهره گیری از شبکه عصبی مصنوعی پرسپترون چند لایه (ML-ANN) و استفاده از سری زمانی داده ها و محصولات سنجنش از دوری، اقدام به شناسایی و تعیین کانون های گردوغبار در حوضه رودخانه فرات شده است.

شرق آسیا را در سال ۲۰۱۰ مورد بررسی قرار دادند. آن ها با استفاده از مدل های شبیه سازی، HYSPLIT و داده های مربوط به ماهواره کالیپسو (CALIPSO)<sup>۱</sup>، منشأ طوفان های گردوغبار در غرب چین و بیابان گبی را مشخص کردند [۱۳]. ادیب و همکاران در سال ۲۰۱۸ با استفاده از داده های زمینی و هواشناسی، تالاب هورالعظیم واقع در استان خوزستان را به عنوان کانون ایجاد گردوغبار بررسی کردند. نتایج حاکی از آن بود که خشک شدن تدریجی تالاب، سرعت باد و اندازه ریز ذرات خاک در ایجاد کانون گردوغبار نقش ویژه ای دارند [۱۴]. معصومی و همکاران در سال ۲۰۱۹ به بررسی میزان گسترش گردوغبار در خاورمیانه پرداختند. آن ها با استفاده از سری زمانی داده های عمق نوری آئروسول (AOD)<sup>۲</sup> در طول موج های مختلف، شاخص انکسار آئروسول (ADI)<sup>۳</sup> و شاخص توان آنگستروم (AEI)<sup>۴</sup> به دست آمده از داده های سنجنده مادیس (MODIS)<sup>۵</sup> در بازه زمانی ۲۰۱۰ تا ۲۰۱۷، منطقه را مورد بررسی قرار دادند. در این پژوهش منطقه بین النهرین در عراق و شرق سوریه، قسمت شمالی شبه جزیره عربستان، صحرای ربع الخالی در بخش جنوبی شبه جزیره عربستان و کانون های گردوغبار شرقی شبه جزیره عربستان واقع در کشور عمان، به عنوان چهار کانون اصلی گردوغبار در خاورمیانه مشخص شدند. همچنین داده های ماهانه میانگین سرعت باد نشان داد که رخداد گردوغبار در بخش شمالی شبه جزیره عربستان عمدتاً از منابع شمالی شبه جزیره عربستان (حوضه دجله و فرات) و در فصول بهار و تابستان آغاز می شود. در شرق شبه جزیره عربستان، شرایط گردوغبار تا اواخر تابستان ادامه دارد و

<sup>۱</sup> Cloud-Aerosol Lidar and Infrared Pathfinder Satellite Observations

<sup>۲</sup> Aerosol Optical Depth

<sup>۳</sup> Aerosol Deflection Index

<sup>۴</sup> Angstrom Exponent Index

<sup>۵</sup> Moderate Resolution Imaging Spectroradiometer

<sup>۶</sup> Multilayer Perceptron Artificial Neural Network

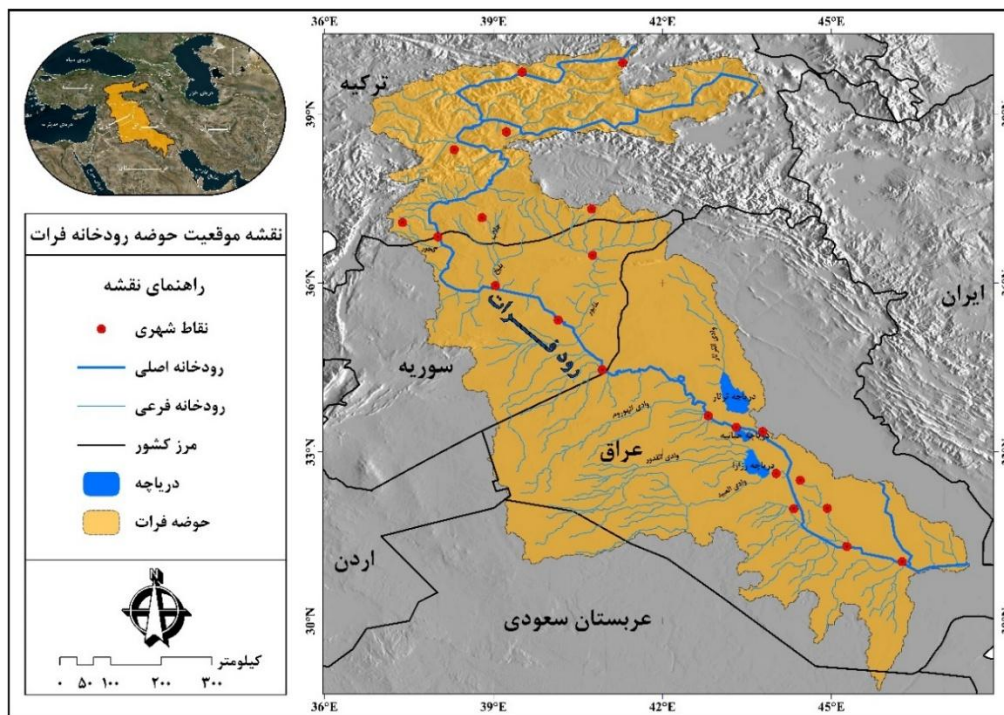
## ۲- مواد و روش‌ها

در این مطالعه پس از بررسی پژوهش‌های صورت گرفته و شناخت قابلیت‌های شبکه عصبی مصنوعی در تعیین کانون‌های گردوغبار، ابتدا به معرفی منطقه مورد مطالعه و سپس آماده‌سازی داده‌های پژوهش و در ادامه به تشریح مراحل پیاده‌سازی شبکه عصبی پرداخته خواهد شد.

### ۲-۱- منطقه مورد مطالعه

مطابق با شکل (۱) حوضه رودخانه فرات در عرض جغرافیایی بین ۲۸ تا ۴۱ درجه شرقی و طول جغرافیایی بین ۳۶ تا ۴۸ درجه شمالی واقع شده و مساحت آن حدود ۴۸۵ هزار کیلومترمربع است. این حوضه آبریز در محدوده چهار کشور ترکیه، سوریه،

عراق و قسمت کوچکی از آن در عربستان قرار دارد. ارتفاع حوضه از هشت متر پایین‌تر از سطح آب‌های آزاد تا ۳۴۸۷ متر متغیر است. مناطق شمالی حوضه برخلاف مناطق جنوبی، دارای ارتفاعات بلندتر، شیب‌های تندتر و بارش بیشتری هستند. پوشش بخش شمالی حوضه عمدتاً جنگل و علفزار ولی بخش مرکزی و جنوبی حوضه عمدتاً شامل زمین‌های بایر است. کانون‌های جمعیتی مهم غالباً در حوالی رودخانه فرات گسترش یافته‌اند. حوضه فرات به علت دارا بودن میانگین دمای بالا و بارش کم، زمین لخت و عاری از پوشش و بطورکلی قرار گرفتن در کمربند خشک و نیمه‌خشک کره زمین، دارای فعالیت‌های گردوغباری فراوانی است [۲۰].



شکل ۱: منطقه مورد مطالعه - حوضه رودخانه فرات

### ۲-۲- داده‌های مورد استفاده

عوامل موثر در رخداد طوفان گردوغبار به چهار دسته خصوصیات خاک، خصوصیات اقلیمی، تاثیرات انسان منشاء، پوشش و توپوگرافی زمین قابل تفکیک می-

باشند [۲۱]. مجموعه داده‌های رطوبت خاک، دمای سطح خاک، سرعت باد در سطح زمین، بارش و تبخیرتقرق برای یک دوره زمانی ۳۷ ساله از سال ۱۹۸۲ تا ۲۰۱۹ میلادی که شامل بیش از ۲۲۰۰

[۸]. فراوانی رخداد گردوغبار به عنوان تعداد روزهایی که عمق نوری آئروسول از یک حد آستانه مشخص بالاتر باشد، تعریف شده است. این آستانه غالباً از طریق سعی و خطا و به صورت تجربی با استفاده از داده‌های زمینی تعیین می‌شود [۲۴]. در پژوهش حاضر فراوانی رخداد گردوغبار به عنوان یک پارامتر محیطی کارآمد جهت شناسایی مناطق دارای پتانسیل گردوغبار موردنظر قرار گرفت. پس از بررسی سری زمانی داده‌های عمق نوری سنجنده MODIS (با مشخصات مندرج در جدول (۱)) برای منطقه مورد مطالعه و رویدادهای گردوغباری ثبت شده در تاریخ‌های متناظر با آن توسط ایستگاه‌های هواشناسی واقع در مناطق مختلف حوضه، مقدار عددی ۰/۳ به صورت تجربی به عنوان آستانه تفکیک گردوغبار در نظر گرفته شد. با استفاده از سری زمانی محصول عمق نوری آئروسول سنجنده MODIS (بازه زمانی ۲۰۰۰ تا ۲۰۱۹)، تعداد ماه‌هایی که میانگین عمق نوری آئروسول آن‌ها بیشتر از آستانه موردنظر بود مشخص گردید. سپس با تجمع داده‌های مربوط به سری زمانی ۲۰ ساله، فراوانی رخداد ماهانه گردوغبار به صورت پیکسل‌مبنا در کل منطقه مورد مطالعه محاسبه شد.

تصویر هستند، از مجموعه داده‌های اف. ال. دس (FLDAS)<sup>۱</sup> پردازش و برای هر پارامتر میانگین سالانه آن محاسبه گردید [۲۲]. همچنین به منظور بررسی اثرات پوشش زمین از محصول پوشش زمین سنجنده MODIS استفاده شد. بافت خاک به عنوان عاملی مؤثر در شکل‌گیری کانون گردوغبار به شمار می‌رود. بطوری که هر چه اندازه ذرات خاک ریزتر باشد، حمل آن توسط باد ساده‌تر است. بدین منظور از داده‌های بافت خاک (درصد رس، سیلت و شن) مرکز داده جهانی آی. اس. آر. آی. سی (ISRIC)<sup>۲</sup> استفاده شد. جهت لحاظ نمودن فشار ناشی از جمعیت بر محیط، از نقشه تراکم جمعیت پایگاه داده جهانی وردپاپ (WorldPop)<sup>۳</sup> استفاده شد. فهرست تمامی داده‌های مورد استفاده در این پژوهش در قالب جدول (۱) ارائه شده است.

## ۲-۳- روش تحقیق

مراحل کلی انجام پژوهش حاضر در شکل (۲) نمایش داده شده است.

### ۲-۳-۱- فراوانی رخداد گردوغبار

محصول عمق نوری آئروسول سنجنده مادیس، نشاندهنده میزان تضعیف تابش خورشیدی ناشی از پخش و پراکنش و جذب توسط ذرات آئروسول موجود در جو است که می‌تواند به عنوان شاخصی از میزان کدورت، تیرگی و مه آلودی هوا باشد [۲۳]. در مناطقی که کانون‌های گردوغبار قرار دارند، اتمسفر همان موقعیت جغرافیایی نیز دارای آئروسول بیشتری نسبت به سایر مناطق در سری زمانی خواهد بود. بر همین اساس عمق نوری آئروسول در طول سری زمانی، مرتبط با موقعیت شکل‌گیری کانون‌های گردوغبار خواهد بود

<sup>۱</sup> *Famine Early Warning Systems Network (FEWS NET) Land Data Assimilation System*

<sup>۲</sup> *Data hub of ISRIC (<https://data.isric.org/>)*

<sup>۳</sup> *<https://www.worldpop.org/>*

جدول ۱: لیست داده‌های مورد استفاده در پژوهش و مشخصات آن‌ها

تعداد	مقیاس	دوره زمانی	واحد	پارامتر
۴۴۴	درجه ۰/۱	۱۹۸۲ تا ۲۰۱۹	مترمکعب بر مترمکعب	رطوبت حجمی خاک تا عمق ۱۰ سانتی متری
۴۴۴	درجه ۰/۱	۱۹۸۲ تا ۲۰۱۹	درجه سانتی‌گراد	دمای سطح خاک
۴۴۴	درجه ۰/۱	۱۹۸۲ تا ۲۰۱۹	متر بر ثانیه	سرعت باد در سطح زمین
۴۴۴	درجه ۰/۱	۱۹۸۲ تا ۲۰۱۹	میلی‌متر	بارش
۴۴۴	درجه ۰/۱	۱۹۸۲ تا ۲۰۱۹	میلی‌متر	تبخیر و تعرق
-	متر ۵۰۰	۲۰۱۷	-	محصول پوشش زمین سنجنده مادیس
-	-	-	-	خطوط ارتباطی (راه و راه‌آهن)
-	متر ۱۰۰۰	۲۰۱۹	نفر در کیلومترمربع	تراکم جمعیت
-	متر ۲۵۰	-	درصد	میزان رس
-	متر ۲۵۰	-	درصد	میزان سیلت
-	متر ۲۵۰	-	درصد	میزان شن
۲۲۸	درجه ۱	۲۰۰۰ تا ۲۰۱۹	-	محصول عمق نوری آئروسول سنجنده مادیس
۲۵۰۰	متر ۲۵۰	۲۰۰۸ تا ۲۰۱۹	-	تصاویر سنجنده مادیس
-	متر ۳۰	-	متر	مدل ارتفاعی رقومی سنجنده استر (ASTER)

### ۲-۳-۲- فاز ی سازی

منطق فاز ی<sup>۱</sup>، یک سیستم مبتنی بر قواعد منطقی "شرط- نتیجه" است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فاز ی، فضای متغیرهای ورودی را به فضای متغیرهای خروجی تصویر می‌کند [۲۵]. ترکیب سیستم فاز ی (مبتنی بر قواعد منطقی) و روش شبکه‌های عصبی مصنوعی (که توان استخراج دانش از اطلاعات عددی را دارند)، منجر به ارائه سیستم استنتاج تطبیقی عصبی شده است [۲۶]. برای نرمال‌سازی ورودی‌های سیستم از توابع فاز ی- سازی استفاده می‌شود. توابع فاز ی به بهبود مقیاس و توزیع داده‌ها کمک می‌کنند.

۲-۳-۳- شبکه عصبی مصنوعی پرسپترون چند لایه شبکه عصبی مصنوعی<sup>۲</sup> با الهام‌گیری از شبکه عصبی زیستی و از واحدهای ساده محاسباتی متصل به هم به

نام نورون<sup>۳</sup> ساخته شده است [۲۷ و ۲۸]. عموماً هر شبکه عصبی از سه لایه تشکیل شده است که عبارت اند از: لایه ورودی<sup>۴</sup>؛ شامل چند نورون است که در این پژوهش، پارامترهای ورودی به مدل را دریافت می‌کند. لایه پنهان<sup>۵</sup>؛ شامل تعدادی نورون متغیر است که تعداد بهینه آن‌ها برای حداقل شدن خطا از طریق آزمون و خطا تعیین می‌گردد. در لایه خروجی<sup>۶</sup> نیز پاسخ‌های شبکه ساخته می‌شوند [۲۹]. در شکل (۳)، ساختار سه‌لایه شبکه عصبی پرسپترون نمایش داده شده است.

<sup>۳</sup> Neurons

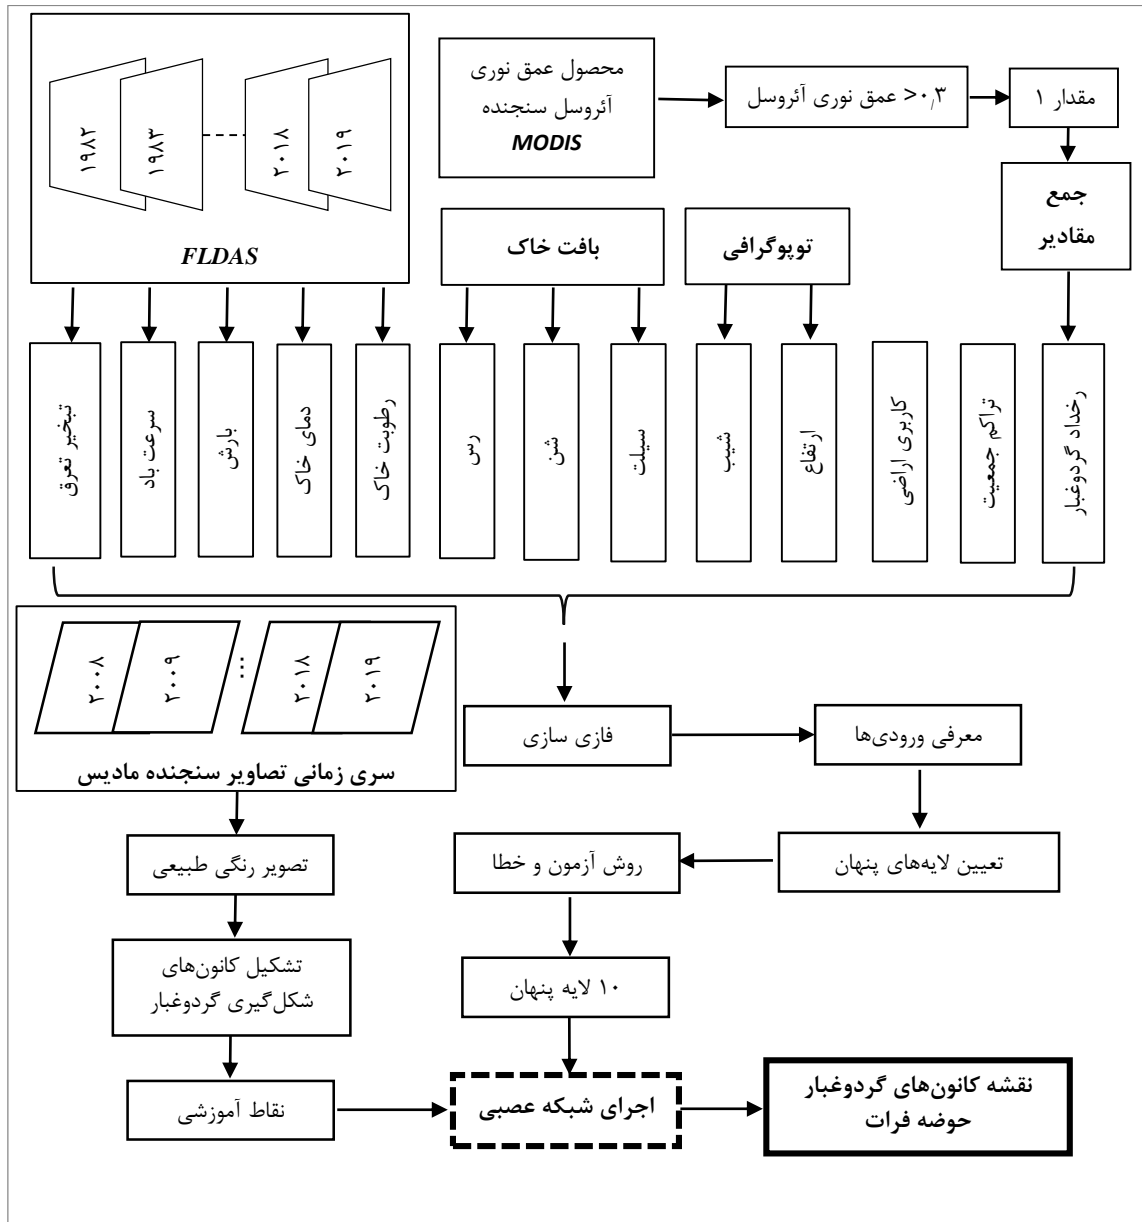
<sup>۴</sup> Input Layer

<sup>۵</sup> Hidden Layer

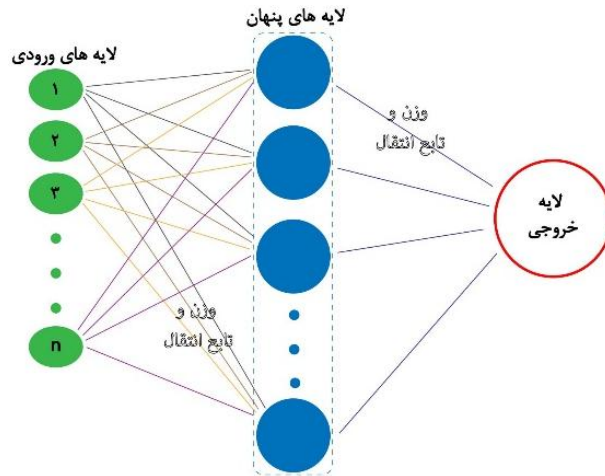
<sup>۶</sup> Output Layer

<sup>۱</sup> Fuzzy Logic

<sup>۲</sup> Artificial Neural Network



شکل ۲: اینفوگرافی روند کلی انجام پژوهش



شکل ۳: معماری شبکه عصبی پرسپترون چند لایه

مرسوم در شبکه پرسپترون چند لایه تابع سیگموئید<sup>۳</sup> و تانژانت سیگموئید<sup>۴</sup> می‌باشد. معمولاً یک نورون تنها برای حل مسائلی که تعداد ورودی زیادی دارند کافی نیست. به همین سبب در حل این‌گونه مسائل از شبکه‌های عصبی که متشکل از چندین نورون یا چندین لایه هستند استفاده می‌شود [۳۱]. شبکه‌های چندلایه بسیار قدرتمند هستند، به عنوان نمونه یک شبکه دو لایه با لایه اول سیگموئید و لایه دوم خطی می‌تواند هر تابع دلخواهی را با تعداد نقاط نامحدود تخمین بزند [۳۲].

عملکرد شبکه عصبی توسعه داده‌شده با استفاده از روش‌های ریاضی و آماری سنجیده می‌شود. در این پژوهش به منظور بررسی عملکرد شبکه، از خطای میانگین مربعات (MSE)<sup>۵</sup> به عنوان معیاری برای سنجش صحت نتایج شبکه عصبی، طبق رابطه (۳) استفاده شد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad \text{رابطه (۳)}$$

که در آن،  $n$  نشان‌دهنده تعداد مشاهدات،  $y_i$  بیانگر

نقش هر نورون محاسبه وزن اختصاص داده شده به ورودی‌ها و سپس گذراندن این وزن از یک تابع، به نام تابع انتقال<sup>۱</sup> است. تابع انتقال می‌تواند یک تابع خطی یا غیرخطی باشد. طبق رابطه (۱) در شبکه‌های عصبی مصنوعی، پس از اجرای فرآیند یادگیری شبکه، تاثیر هریک از پارامترهای ورودی با اختصاص یک وزن به ورودی‌ها مشخص می‌شود.

$$X_{k+1} = X_k - [J^T \times J + \mu \times I]^{-1} J^T + e \quad \text{رابطه (۱)}$$

در رابطه (۱)،  $x$  بیانگر وزن‌های شبکه عصبی،  $J$  ژاکوبین ماتریس معیار اجرای شبکه است که باید حداقل شود،  $\mu$  عددی است که فرآیند آموزش را کنترل می‌کند و  $e$  بردار خطای باقیمانده<sup>۲</sup> است. بر اساس رابطه (۲)، در مرحله بعد مقدار  $x_{k+1}$  وارد تابع انتقال  $f$  شده و در نهایت مقدار  $a$  را به خود اختصاص می‌دهد که این مقدار خروجی نهایی نورون است [۳۰].

$$a = f(W_{1,1} \cdot P_1 + W_{1,2} \cdot P_2 + \dots + W_{1,R} \cdot P_R + b) \quad \text{رابطه (۲)}$$

در رابطه (۲)،  $P$  بیانگر بردار مقادیر پارامترهای ورودی،  $W$  بردار وزن پارامترها و  $b$  بردار انحراف است. دو نوع

<sup>۳</sup> Sigmoid (Logsig)

<sup>۴</sup> Hyperbolic Tangent (Tansig)

<sup>۵</sup> Mean Squared Error

<sup>۱</sup> Transfer Function

<sup>۲</sup> Bias

[۳۷]. قانون پس انتشار خطا شامل دو مسیر اصلی یعنی مسیر رفت و مسیر برگشت می‌شود. در مسیر رفت، الگویی آموزشی به شبکه اعمال می‌شود و به وسیله لایه‌های پنهان میانی به لایه خروجی انتشار می‌یابد تا اینکه در نهایت خروجی واقعی شبکه محاسبه شود. در این مسیر، پارامترهای شبکه شامل بردارهای باقیمانده خطا و وزن‌ها، ثابت در نظر گرفته می‌شوند. اما در مسیر برگشت پارامترهای شبکه تغییر و مجدداً تنظیم می‌شوند. این تغییرات بر پایه قانون یادگیری اصلاح و خطا انجام می‌پذیرد. بردار خطا معادل تفاوت بین پاسخ مطلوب و پاسخ واقعی شبکه است. مقدار خطا، در مسیر برگشت از لایه خروجی و از طریق لایه‌ها در کل شبکه توزیع می‌شود. در این مسیر وزن‌های شبکه به شکلی تغییر می‌کنند تا مجموع مربعات خطای شبکه کمینه گردد. الگوریتم پس انتشار تا زمانی ادامه می‌یابد که اولاً خطای میانگین مربعات در هر سیکل کمتر از مقدار از پیش تعیین شده باشد و یا اینکه میزان تغییرات در پارامترهای شبکه پس از هر سیکل خیلی ناچیز باشد؛ دوماً گرادینان خطا از یک مقدار از پیش تعیین شده کوچک‌تر شود [۳۸]. الگوریتم پس انتشار خطا دارای سه الگوریتم یادگیری است؛ شبکه با ضریب یادگیری ساده<sup>۴</sup>، شبکه با ضریب یادگیری متغیر<sup>۵</sup> و شبکه‌ای که از روش لوبنبرگ-مارکواریت<sup>۶</sup> استفاده می‌کند [۳۹]. در این پژوهش از روش لوبنبرگ - مارکواریت به‌منظور آموزش شبکه عصبی پرسپترون چند لایه استفاده شده است. وارد کردن مقادیر نقاط آموزشی به صورت خام، سبب کاهش سرعت و دقت شبکه می‌شود، در همین راستا به‌منظور تسهیل در همگرایی شبکه عصبی، ارزش

مقادیر اندازه‌گیری شده و  $\bar{y}_i$  نشان‌دهنده مقادیر پیش‌بینی شده است. معمولاً هرچه مدل دقیق‌تر و قوی‌تر باشد مقدار خطای میانگین مربعات کمتر می‌شود [۳۳].

## ۲-۳-۱- آموزش شبکه

توانایی آموزش یکی از قابلیت‌های بسیار مهم شبکه عصبی مصنوعی است. در هر شبکه عصبی مقادیری تحت عنوان پارامترهای آزاد وجود دارند که به دو دسته وزن‌ها و خطاها تقسیم می‌شوند. پارامترهای آزاد قابلیت تغییر دارند. دقت نمودن در تعیین ارزش صحیح این مقادیر سبب عملکرد بهینه شبکه در حل مسئله می‌شود؛ بنابراین آموزش یک شبکه عصبی پرسپترون چندلایه به این مفهوم است که پارامترهای آزاد شبکه توسط الگوریتم‌های آموزش و بر اساس داده‌های آموزشی به گونه‌ای بهینه شوند که مقدار خطای بین خروجی شبکه و پارامتر هدف به حداقل مقدار ممکن برسد [۳۴]. به‌طور کلی دو نوع آموزش شامل آموزش با ناظر<sup>۱</sup> و آموزش بدون ناظر<sup>۲</sup> در شبکه عصبی وجود دارد. معمولاً برای آموزش شبکه‌های عصبی با ناظر، یک تابع هزینه تعریف می‌شود و از مجموعه‌ای از داده‌های تجربی به نام داده‌های آموزشی برای تعیین وزن‌ها استفاده می‌شود. در آموزش با ناظر، وزن‌های شبکه به شکلی برآورد می‌شوند که تابع هزینه بر اساس داده‌های آموزشی کمینه شود [۳۵]. روش یادگیری پس انتشار خطا<sup>۳</sup> یک روش آموزش با ناظر و مبتنی بر قانون آزمون و خطاست که برای آموزش شبکه‌های پرسپترون چندلایه مورد استفاده قرار می‌گیرد. الگوریتم یادگیری پس انتشار خطا متداول‌ترین و بهترین الگوریتم یادگیری در شبکه‌های عصبی چندلایه است [۳۶] و

<sup>۴</sup> Trainbp

<sup>۵</sup> Trainbpx

<sup>۶</sup> Levenberg - Marquardt

<sup>۱</sup> Supervised

<sup>۲</sup> Unsupervised

<sup>۳</sup> Back-Propagation

نقاط آموزشی با استفاده از رابطه (۴) به مقیاس بین صفر و یک نرمال گردید [۴۰].

$$x_y = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad \text{رابطه (۴)}$$

که در آن،  $x_y$  بیانگر ارزش نرمال شده نقطه آموزشی،  $x_i$  ارزش ورودی نقطه آموزشی،  $x_{\min}$  مقدار کمینه نقاط آموزشی و  $x_{\max}$  مقدار بیشینه نقاط آموزشی است.

در شبکه مصنوعی جلوگیری از یادگیری بیش از حد شبکه بسیار مهم است؛ زیرا در این حالت شبکه به جای یادگیری روابط بین پارامترهای ورودی به منظور ایجاد پاسخ در لایه خروجی، روابط بین پارامترها را حفظ می کند [۴۱]. به منظور دستیابی به این مهم، داده های آموزشی به سه دسته تقسیم بندی می شوند. دسته اول مربوط به آموزش شبکه و ایجاد پاسخ در لایه خروجی است. دسته دوم یا داده های تست، در طی فرآیند یادگیری میزان خطای شبکه را کنترل و از یادگیری بیش از حد شبکه عصبی جلوگیری می کنند. داده های اعتبارسنجی نیز بعد از اجرای فرآیند یادگیری، راستی-آزمایی شبکه را مورد سنجش قرار می دهند [۴۲] و [۴۳].

روند تکوین طوفان گردوغبار، چهار مرحله دارد که به ترتیب عبارتند از: شروع طوفان، بلوغ، جداسدگی طوفان از منشأ، و مرحله چهارم جابه جایی و پخش شدگی طوفان [۴۴]. در مراحل اول و دوم پیدایش طوفان گردوغبار می توان با تفسیر بصری سری های زمانی تصاویر ماهواره ای با قدرت تفکیک مکانی و زمانی مطلوب نظیر سنجنده MODIS نقطه شروع طوفان گردوغبار را به منظور تعیین نقاط آموزشی شبکه عصبی، شناسایی کرد [۱۸ و ۴۵]. طوفان های گردوغبار شکل گرفته معمولا بر روی تصاویر ماهواره ای در ترکیب رنگی طبیعی با تن متمایل

به خاکستری ظاهر می شوند که سایر عوارض مکانی واقع در محدوده گردوغبار را نیز از طریق الگوهای خاکستری رنگ پوشش می دهد. بدین طریق الگوهای گردوغبار از سایر منابع در تصویر نظیر ابر که تن سفید رنگ دارد قابل تمیز دادن می باشد. البته گردوغبارهایی در بیابان های با زمینه روشن وجود دارند که به علت تن و رنگ مشابه، تفکیک آن ها مشکل است. در این مواقع با استفاده از ترکیب رنگی کاذب تصاویر می توان در تفسیر گردوغبار بهتر عمل نمود. در این پژوهش از تصویر رنگی طبیعی و کاذب (بر حسب مورد) برای شناسایی نقاط شکل گیری کانون های گردوغبار در حوضه رودخانه فرات استفاده شد.

#### ۲-۳-۳-۲- لایه های پنهان شبکه عصبی

پس از انتخاب لایه های ورودی و مشخص کردن نقاط آموزشی، تعیین تعداد لایه های پنهان شبکه، پیش نیاز اجرای شبکه عصبی پرسپترون است. به طور کلی هرچه تعداد لایه ها بیشتر باشد، سیستم توانمندی بیشتری درک پیچیدگی ها دارد، ولی از سوی دیگر افزایش تعداد لایه ها دقت پیش گویی سیستم را کاهش داده و ممکن است مانع همگرایی شبکه گردد. عامل مهم دیگر در طراحی شبکه، تعداد نورون ها در هر لایه است. نورون های لایه های میانی در شبکه به عنوان تشخیص دهنده الگو عمل می کنند [۳۳]. در همین راستا تعداد نورون ها در لایه پنهان نقش مهمی در قدرت شبکه دارد. کم بودن تعداد نورون ها سبب افت قدرت تجزیه و تحلیل، و دقت عددی پیش بینی را کاهش می دهد و شبکه نمی تواند نداشت غیرخطی بین ورودی و خروجی را با دقت لازم برقرار نماید. از طرفی ازدیاد بیش از حد تعداد نورون های لایه های میانی منجر به تولید نگاهی غیرخطی و پیچیده شده که در این وضعیت سیستم داده های آموزشی را به جای تجزیه و تحلیل، حفظ می کند، و در نتیجه برای داده های جدید عملکرد بهینه ای

استفاده شد. از طرفی کاهش مقادیر پارامترهای بارش، ارتفاع، شیب، رطوبت خاک و تبخیرتعرق در شکل‌گیری کانون‌های گردوغبار اثر مستقیمی دارد، لذا برای این دسته از پارامترها از توابع *Small* و *MSSmall* جهت فازی‌سازی استفاده شد. در مناطقی که تراکم جمعیت آن‌ها بسیار محدود و متفرق است، عامل فشار انسان بر محیط کاهش می‌یابد و در مقابل تراکم بسیار بالای جمعیت نشان‌دهنده محیط شهری است که در هر دو مورد سبب تشدید یا شکل‌گیری کانون گردوغبار نمی‌شود، در نتیجه مقادیر میانی تراکم جمعیت از ارزش بالاتری برخوردارند و به همین سبب از تابع گوسین برای فازی‌سازی این پارامتر بهره گرفته شد.

جهت تعیین نقاط آموزشی شبکه، سری زمانی تصاویر سنجنده *MODIS* از سال ۲۰۰۸ تا ۲۰۱۹ مورد بررسی و تفسیر قرار گرفتند و کانون‌های شکل‌گیری طوفان‌های بزرگ گردوغبار با استفاده از تفسیر چشمی تصاویر ماهواره‌ای تعیین شدند. بدین طریق تعداد ۱۹۰ کانون گردوغبار به عنوان نقاط آموزشی شبکه عصبی در نظر گرفته شد. پراکندگی نقاط آموزشی در شکل (۶) نمایش داده شده است. از میان ۱۹۰ نقطه آموزشی، ۷۰ درصد نقاط (۱۳۳ نقطه) به منظور آموزش شبکه، ۱۵ درصد (۲۸ نقطه) به منظور متوقف کردن محاسبات هنگام افزایش خطا و کالیبره کردن مدل و ۱۵ درصد باقیمانده نیز به منظور راستی‌آزمایی شبکه مورد استفاده قرار گرفتند.

در این پژوهش تعداد مناسب نورون‌های لایه پنهان، برای دستیابی به بهترین پیش‌بینی‌ها و کم‌ترین میزان خطا در شبکه بر مبنای روش آزمون و خطا برابر ۱۰ نورون تعیین شد. شبکه عصبی پرسپترون با ساختار ۱۶ لایه ورودی (عوامل موثر در تعیین کانون‌های گردوغبار)، ۱۰ لایه میانی (روش آزمون و خطا) و ۱ نورون در لایه خروجی که پاسخ‌های شبکه را ایجاد می‌کند (نقشه کانون‌های شکل‌گیری گردوغبار) و الگوریتم یادگیری لونیگ - مارکوارت اجرا شد و شبکه، آموزش‌های لازم برای تصمیم‌گیری در مورد

نداشته و در واقع قدرت تعمیم شبکه کاهش می‌یابد [۳۴ و ۴۶]. برای حل این مشکل می‌بایست تعداد نورون‌ها به شکلی انتخاب شود که شبکه قدرت کافی و نه بیش از حد برای تولید نگاشت بین ورودی و خروجی را داشته باشد و شبکه در حالت بهینه باشد.

### ۳- نتایج و بحث

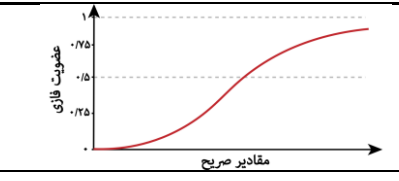

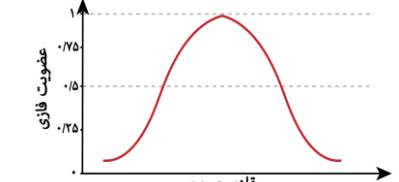
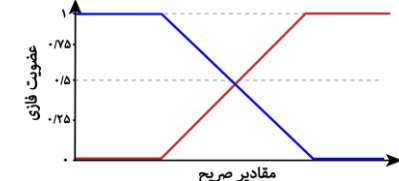
نخستین مرحله در اجرای شبکه عصبی تعیین داده‌های ورودی و هدف است. مطابق با شکل (۴)، در این پژوهش پارامترهای ارتفاع از سطح دریا، شیب، تراکم جمعیت، بارش، سرعت باد، تبخیرتعرق، درصد شن، درصد سیلت، درصد رس، فراوانی رخداد گردوغبار، رطوبت خاک، دمای خاک و کاربری زمین ورودی مدل، و تابع هدف پیش‌بینی مناطق دارای پتانسیل ایجاد گردوغبار است. پارامترهای ذکرشده به عنوان ورودی در چهار گروه مستقل شامل خصوصیات خاک، خصوصیات اقلیمی، تاثیرات انسان منشاء و پوشش و توپوگرافی زمین قرار گرفتند.

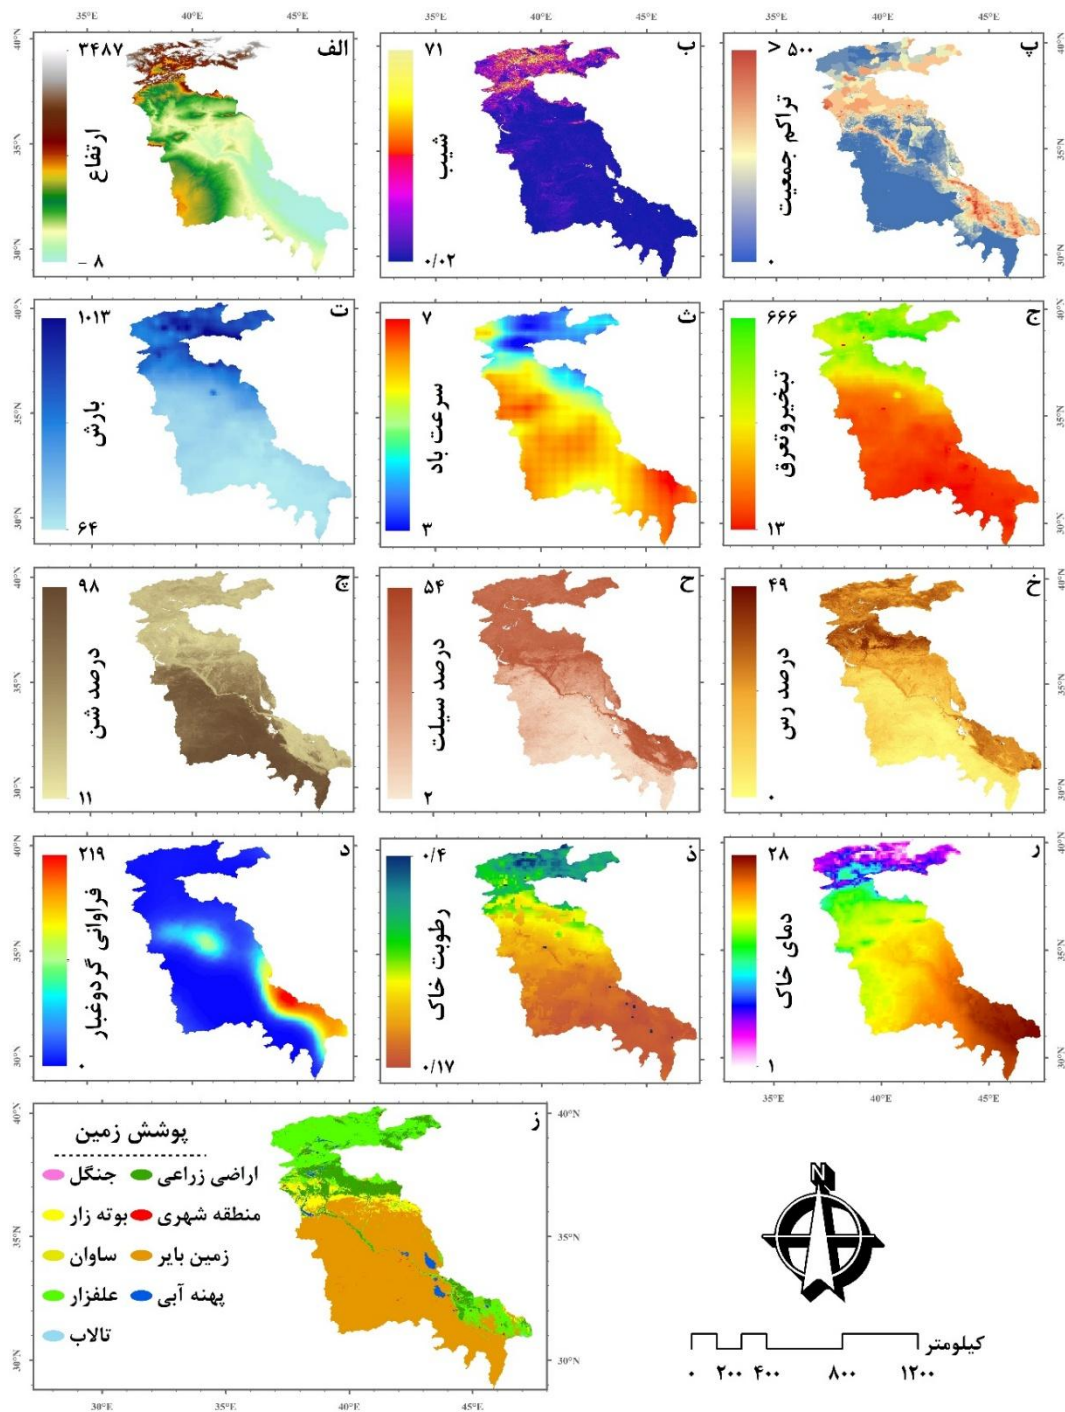
از آنجاکه عوامل محیطی مختلف طبیعتا دارای تاثیرات متفاوتی بر سازوکار رخداد طوفان گردوغبار هستند؛ لذا همانطور که در بخش ۲-۳-۲ نیز اشاره شد؛ نرمالسازی و به نوعی تعریف نوع تاثیر پارامتر بر رخداد گردوغبار برای شبکه عصبی، سبب بهبود قابلیت آموزش شبکه و درک بهتر روابط بین پارامترهای ورودی برای شبکه می‌شود. بر همین اساس پس از تهیه پارامترهای ورودی لازم است برای ورود آن‌ها به شبکه عصبی به مقیاس عددی بین صفر و یک نرمال شوند؛ به همین منظور با استفاده از توابع فازی ذکرشده در جدول (۲)، تمامی پارامترهای ورودی شکل (۴)، مطابق با شکل (۵) به مقیاس بین صفر و یک نرمال‌سازی شدند. فازی‌سازی هریک از پارامترها متناسب با هدف پژوهش صورت گرفت. به همین منظور جهت فازی‌سازی پارامترهای عمق نوری آئروسول، دمای سطح خاک و سرعت باد به سبب اینکه افزایش مقدار آن‌ها تاثیر فزاینده‌ای در هدف پژوهش دارد از تابع *MSLarge*

در شکل (۸) نمودار برازش و ضرایب رگرسیون مراحل آموزش، صحت‌سنجی و آزمون نهایی شبکه عصبی مشاهده می‌شود که بیانگر مقادیر عددی مطلوبی است که برای این مراحل به‌دست آمده است.

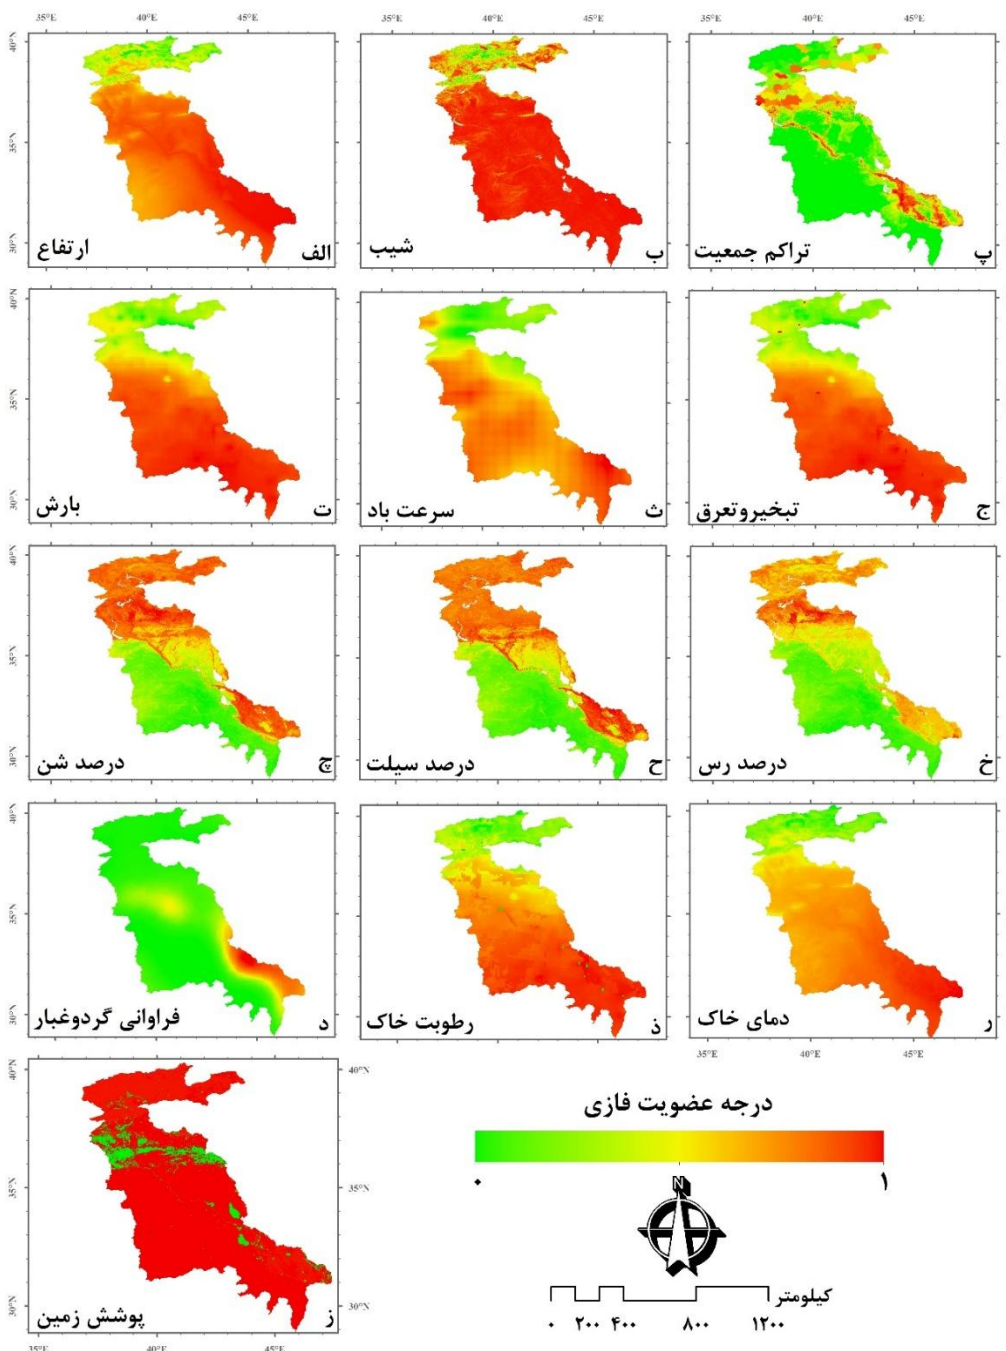
نمونه‌های جدید را کسب کرد. با توجه به شکل (۷)، شبکه پس از ۱۴ بار تکرار متوقف گردید و به آموزش‌های لازم دست پیدا کرد. همچنین شبکه در تکرار ۸ به حالت بهینه، یعنی بیشترین میزان همبستگی و کمترین میزان خطا رسیده است.

جدول ۲: توابع فازی مورد استفاده جهت نرمال‌سازی پارامترها

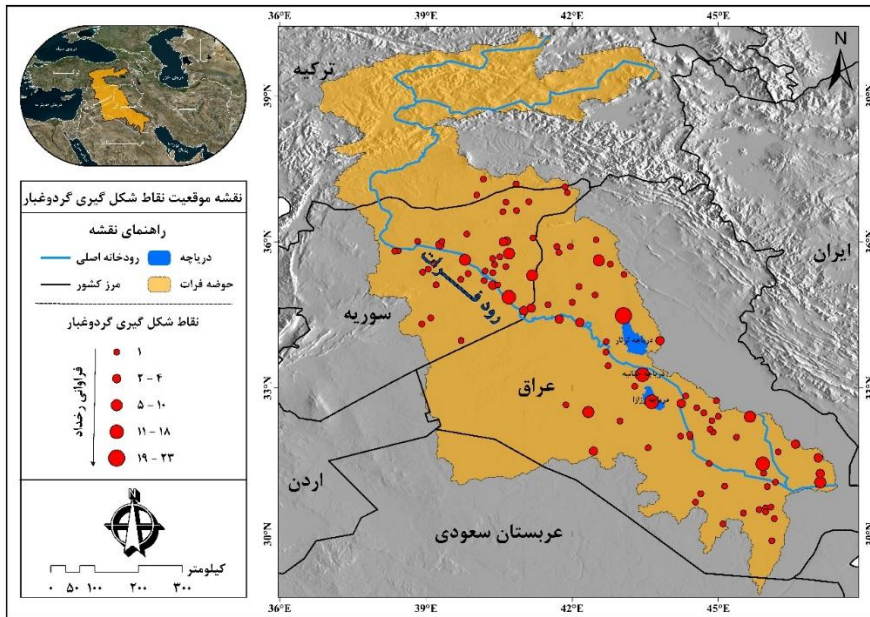
شکل تابع فازی	تابع فازی	پارامتر
	<i>MSLarge</i>	عمق نوری آئروسول
	<i>MSLarge</i>	دمای سطح خاک
	<i>MSLarge</i>	سرعت باد در سطح زمین
	<i>MSSmall</i>	بارش
	<i>MSSmall</i>	ارتفاع
	<i>MSSmall</i>	شیب
	<i>Small</i>	رطوبت حجمی خاک تا عمق ۱۰ سانتی‌متری
	<i>Small</i>	تبخیر و تعرق
	<i>Gaussian</i>	تراکم جمعیت
	<i>Linear</i>	پوشش زمین
	<i>Linear</i>	میزان رس
	<i>Linear</i>	میزان سیلت
	<i>Linear</i>	میزان شن




شکل ۴: پارامترهای ورودی مدل شبکه عصبی مصنوعی پرسپترون چندلایه جهت مدلسازی پتانسیل ایجاد کانون های گردوغبار در حوضه رودخانه فرات - الف: ارتفاع از سطح دریا (متر)، ب: شیب (درجه)، پ: تراکم جمعیت (نفر در کیلومتر مربع)، ت: بارش (میلی متر)، ث: سرعت باد (متر بر ثانیه)، ج: تبخیر و تعرق (میلی متر بر سال)، چ: درصد شن، ح: درصد سیلت، خ: درصد رس، د: فراوانی گردوغبار (تعداد رخداد ماهانه در سری زمانی)، ذ: رطوبت حجمی خاک (متر مکعب بر متر مکعب)، ز: دمای خاک (درجه سانتی گراد)، ز: پوشش اراضی



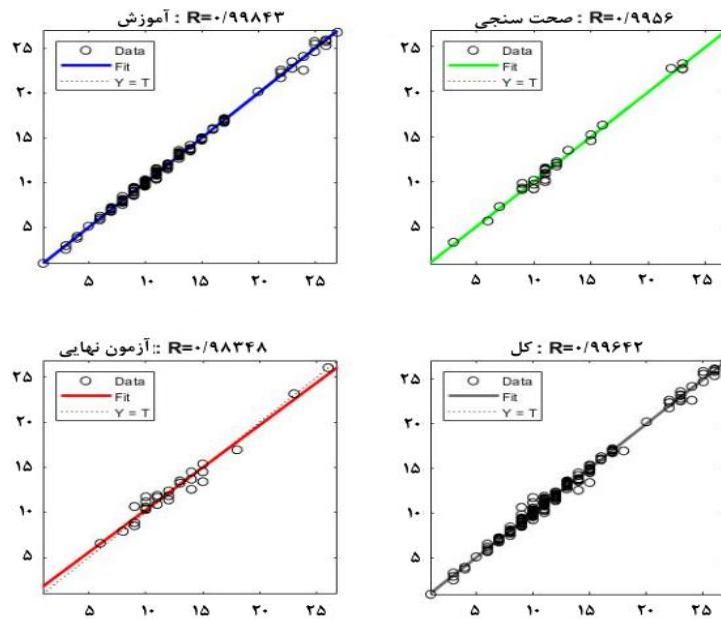
شکل ۵: فازی سازی پارامترهای ورودی مدل شبکه عصبی مصنوعی پرسپترون چندلایه جهت مدلسازی پتانسیل ایجاد کانون های گردوغبار در حوضه رودخانه فرات - هرچه مقادیر پارامترها به سمت بیشینه مقدار عضویت فازی (مقدار ۱) میل نمایند؛ طبیعتاً پتانسیل و استعداد شکل گیری گردوغبار بالاتر می رود و بالعکس.



شکل ۶: پراکندگی نقاط شکل گیری گردوغبار تهیه شده از طریق تفسیر چشمی تصاویر MODIS (نقاط آموزشی شبکه)



شکل ۷: دفعات تکرار در اجرای شبکه عصبی برای رسیدن به آموزش بهینه



شکل ۸: نمودار برازش و ضریب همبستگی در مراحل مختلف اجرای شبکه

تحلیل همبستگی به عمل آمد. بدین صورت مطابق با جدول (۳) میزان ضریب همبستگی هر یک از لایه‌های رستری مربوط به پارامترهای ورودی مدل نسبت به لایه خروجی به صورت مجزا محاسبه گردید. بر اساس جدول (۳)؛ اعداد مثبت بیانگر همبستگی مستقیم بین دو پارامتر مورد تحلیل و در مقابل اعداد منفی بیانگر همبستگی معکوس و غیرمستقیم هستند. به این ترتیب هر چه مقدار قدرمطلق ضریب همبستگی (صرف نظر از نوع علامت) بیشتر باشد، نشان‌دهنده وابستگی بیشتر بین دو پارامتر خواهد بود. بر این اساس پارامترهای فراوانی گردوغبار، تبخیر و تعرق، بارش، دمای خاک و سرعت باد با مقادیر همبستگی ۰/۹، ۰/۷۷، ۰/۷۵، ۰/۷۱ و ۰/۶۹ به ترتیب دارای بیشترین میزان همبستگی با نقشه خروجی در قیاس با سایرین می‌باشند. در مقابل کمترین میزان ضریب همبستگی به دست آمده مربوط به نقشه پوشش زمین است. شایان ذکر است، از آنجاکه پارامتر پوشش زمین دارای کلاس‌های توصیفی است لذا به منظور آنالیز همبستگی از نقشه فازی‌سازی شده این پارامتر استفاده گردید. در حالت کلی، طبیعتاً پارامترهای با ضریب همبستگی بالاتر از میزان

با توجه به ضریب ۰/۹۹۵۶ مرحله اعتبارسنجی<sup>۱</sup> در شکل (۸)، می‌توان مطمئن شد که شبکه به سطح یادگیری قابل قبول و مطلوبی رسیده است. در نهایت ضریب رگرسیون کلی شبکه که حاصل شرکت دادن تمامی داده‌ها در شبکه است، ۰/۹۹۶۴۲ برآورد شد. پس از اتمام مراحل یادگیری، شبکه توانست مناطق جدید را بر اساس آن چه آموخته است ارزش‌دهی کند. در گام نهایی کل حوضه فرات در اختیار شبکه آموزش دیده قرار گرفت و شبکه بر اساس وزن‌هایی که برای پارامترهای ورودی در مرحله یادگیری کسب کرده است، کل منطقه مورد مطالعه را به منظور تعیین کانون‌های گردوغبار ارزش‌دهی کرد. با توجه به شکل (۹) خروجی این مرحله نقشه‌ای فازی با درجات عضویت فازی متغیر بین صفر تا یک است؛ به طوری که درجه عضویت بالاتر نشان‌دهنده پتانسیل و استعداد بالاتر در ارتباط با طوفان گردوغبار است.

در ادامه جهت تعیین میزان تاثیرپذیری نقشه عضویت فازی تولیدی نسبت به پارامترهای ورودی، یک عملیات

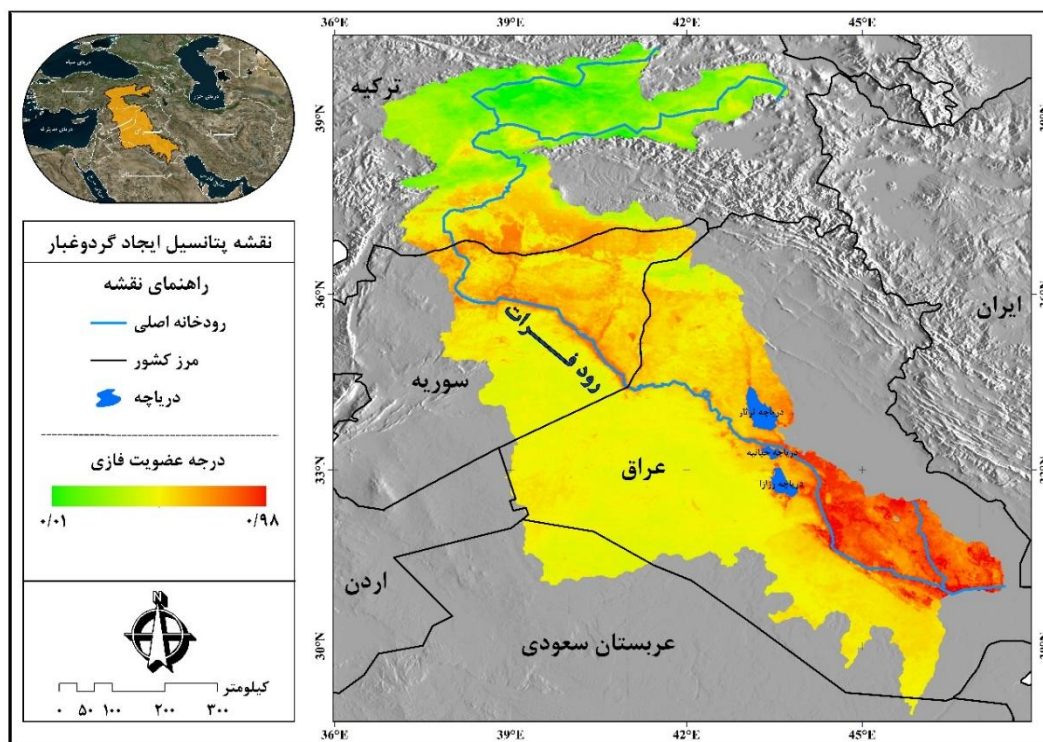
<sup>۱</sup> Validation

کمترین تاثیر بر نقشه خروجی را پارامترهای فراوانی گردوغبار و پوشش زمین سبب شده‌اند.

تاثیرگذاری بیشتری نیز بر الگوی مکانی شکل گرفته در نقشه خروجی برخوردار هستند. بر همین اساس می-توان اینگونه اظهار نمود که به ترتیب بیشترین و

جدول ۳: تحلیل همبستگی بین پارامترهای ورودی مدل شبکه عصبی (عوامل موثر بر گردوغبار) و نقشه پتانسیل گردوغبار

نوع پارامتر	ضریب همبستگی با خروجی مدل	نوع پارامتر	ضریب همبستگی با خروجی مدل
ارتفاع	-۰/۶۱	درصد سیلت	-۰/۶۵
شیب	-۰/۴۷	درصد رس	-۰/۵۳
تراکم جمعیت	۰/۵۷	فراوانی گردوغبار	۰/۹
بارش	-۰/۷۵	رطوبت خاک	-۰/۶۷
سرعت باد	۰/۶۹	دمای خاک	۰/۷۱
تبخیر و تعرق	-۰/۷۷	پوشش زمین	۰/۲۳
درصد شن	۰/۶		



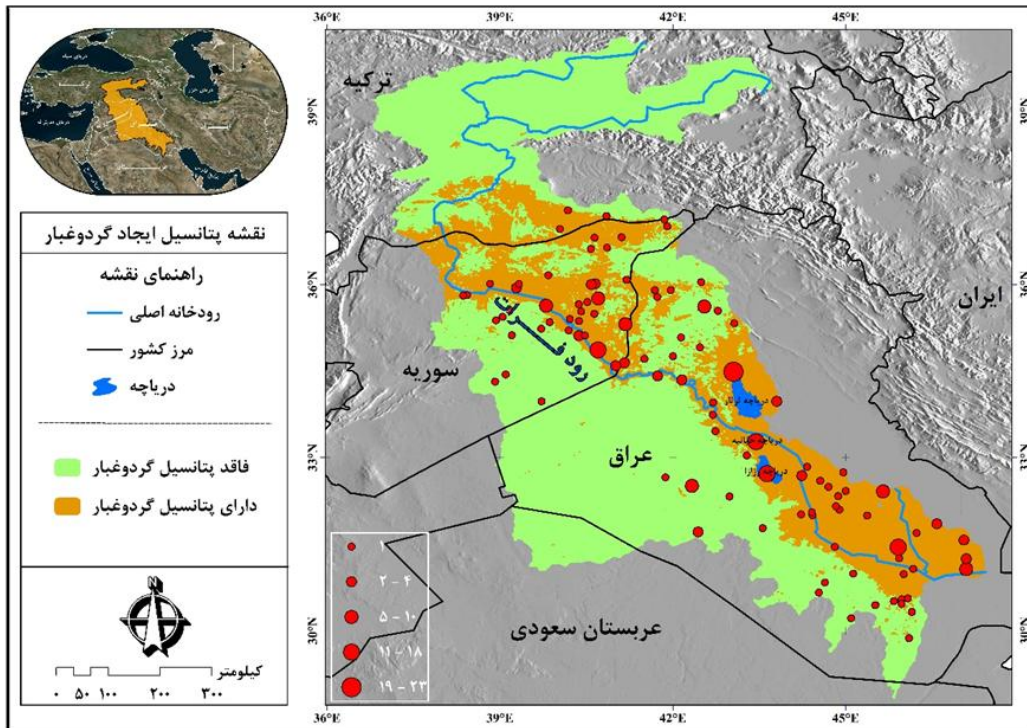
شکل ۹: نقشه درجات عضویت فازی تولید شده با استفاده از قابلیت‌های شبکه عصبی مصنوعی، که بیانگر میزان پتانسیل شکل-گیری طوفان گردوغبار نواحی مختلف از گستره مکانی حوضه رودخانه فرات است. درجات عضویت فازی بالاتر در این نقشه، بر پتانسیل بالاتر گردوغبار دلالت دارد.

آستانه ۰/۶ انتخاب شد. و بر این اساس خروجی حاصل از اجرای شبکه آموزش دیده، به دو کلاس مناطق فاقد

با در نظر گرفتن توزیع نقاط شکل‌گیری طوفان گردوغبار و پارامترهای ورودی به صورت تجربی حد

هزار کیلومتر مربع معادل حدود ۴۴ درصد از مساحت کل حوضه فرات، مستعد شکل‌گیری کانون‌های گردوغبار می‌باشد.

پتانسیل گردوغبار و مناطق دارای پتانسیل گردوغبار تقسیم و بدین ترتیب نقشه نهایی پتانسیل ایجاد کانون‌های گردوغبار در حوضه رودخانه فرات استخراج گردید (شکل ۱۰). نتایج به‌دست‌آمده نشان می‌دهد که ۱۴۷



شکل ۱۰: نقشه پتانسیل ایجاد کانون‌های گردوغبار در حوضه رودخانه فرات - نقاط قرمز رنگ مختلف‌الاندازه کانون‌های بالفعل شکل‌گیری گردوغبار هستند که به عنوان نقاط آموزشی شبکه استفاده شده‌اند.

مورد مقایسه قرار گرفت. نقشه پتانسیل گردوغبار تولیدشده توسط حمیدی و همکاران (۲۰۱۳) مناطق مستعد انتخاب‌شده در مطالعه حاضر را پوشش می‌دهد. که این مناطق مستعد (شکل ۱۰) در نقشه تولیدی توسط آن‌ها غالباً در کلاس پتانسیل سه و در برخی نواحی نیز (نظیر شمال شرق سوریه) در کلاس یک قرار گرفته‌اند [۴۷]. همچنین نتایج مطالعه حاضر انطباق نسبتاً خوبی با نقشه کانون‌های گردوغبار تهیه‌شده توسط درویشی بلورانی و همکاران (۲۰۱۴) نشان می‌دهد. این انطباق نسبتاً خوب بین مناطق دارای پتانسیل گردوغبار (شکل ۱۰) و کانون‌های شماره یک و چهار شناسایی شده توسط آن‌ها مشهود است [۴۸]. برخی از کانون‌های شناسایی شده توسط کائو و

در دو دهه اخیر برخی مطالعات در منطقه غرب آسیا و خاورمیانه در راستای ردیابی طوفان‌های گردوغبار و نقشه‌برداری کانون‌های گردوغبار با استفاده از داده‌های هواشناسی و سنجش‌ازدوری و مدل‌های مختلف صورت گرفته است. بر اساس شکل (۱۰)، مناطق مستعد گردوغبار شناسایی شده در مطالعه حاضر بطور کامل واقع در محدوده کانون‌های گردوغبار معرفی شده توسط جینوکس و همکاران (۲۰۱۲) می‌باشند. که مطابق با یافته‌های جینوکس و همکاران (۲۰۱۲)، کانون‌های گردوغبار واقع در این ناحیه غالباً دارای منشاء انسانی و به میزان کمتر طبیعی هستند [۸]. مناطق دارای پتانسیل بالقوه گردوغبار شناسایی شده در مطالعه حاضر، با نتایج کار حمیدی و همکاران (۲۰۱۳) نیز

همچنین در مناطق مستعد گردوغبار؛ فشار ناشی از تاثیرات انسانی بر محیط و خاک مشهود است. کاربری و پوشش غالب زمین در این مناطق شامل اراضی بایر، کشاورزی و بوته‌زارها هستند و به ندرت در مناطق دارای پوشش گیاهی متراکم، فعالیت گردوغباری مشاهده شده است.

طبق بررسی الگوهای مکانی - زمانی بلندمدت پارامترهای محیطی موثر بر گردوغبار؛ نواحی جنوبی و جنوب‌غربی حوضه با پوشش غالب بایر و شن‌زار علی-رغم برخورداری از میانگین بارش سالیانه کمتر از ۱۵۰ میلی‌متر، دمای بالاتر از ۲۳ درجه سانتی‌گراد، میانگین سرعت باد بالاتر از ۵ متر بر ثانیه و بطورکلی برقراری بسیاری از شرایط محیطی در رابطه با شکل‌گیری گردوغبار، اما این نواحی جزء کلاس فاقد پتانسیل گردوغبار قرار گرفته‌اند. در بررسی و تفسیر چشمی تصاویر MODIS نیز این نواحی رخدادهای گردوغباری بالفعل قابل توجهی را نشان نمی‌دهند. این مسأله می‌تواند ناشی از چند عامل باشد. نخست اینکه ذرات خاک این نواحی غالباً درشت‌دانه و از نوع شن می‌باشند که این مهم در رابطه با رخداد گردوغبار یک عامل بازدارنده به حساب می‌آید. از طرفی طبق نقشه فراوانی رخداد گردوغبار تولیدی با استفاده از محصول عمق نوری آئروسول MODIS، نواحی نامبرده در طول بازه زمانی ۲۰ ساله کمتر از ۲۱ روز با رخداد گردوغبار را داشته‌اند. از طرفی این پارامتر بالاترین میزان همبستگی و بالطبع بیشترین تاثیرگذاری را بر الگوی مکانی نقشه پتانسیل گردوغبار نهایی داشته است. از دیگر منظر نیز شایان ذکر است که در مناطق جنوبی و جنوب‌غربی حوضه، تراکم جمعیت انسانی کمتر از ۱۰۰ نفر در هر کیلومتر مربع یا ۱۰۰ هکتار است. که این موضوع به نوعی می‌تواند بر فشار و تاثیر کمتر جمعیت بر محیط‌زیست و تبعات مشتق‌شده از آن، نظیر

همکاران (۲۰۱۵) و درویشی بلورانی و همکاران (۲۰۲۰) نیز در محدوده‌های مستعد گردوغبار مطالعه حاضر قرار گرفته‌اند. مناطق معرفی‌شده توسط آن‌ها مساحت‌های به مراتب بسیار کمتری را در قیاس با مساحت مناطق مستعد معرفی‌شده توسط پژوهش حاضر شامل شده است [۱۶ و ۱۸]. این موضوع ناشی از واگرایی نتایج نیست چرا که با توجه روش اتخاذی از سوی آن‌ها، مناطق نامبرده در واقع به عنوان کانون بالفعل گردوغبار معرفی شده‌اند. در صورتی‌که مناطق شناسایی‌شده در مطالعه حاضر در واقع کانون بالقوه گردوغبار هستند و این موضوع توجیه‌کننده مساحت بیشتر این کانون‌ها است.

#### ۴- نتیجه‌گیری و پیشنهادها

استنباط کلی از پژوهش حاضر، حاکی از آن است که استفاده توأم از قابلیت‌های شبکه عصبی مصنوعی و داده‌ها و محصولات سنجنش‌ازدوری رویکردی کارآمد در شناسایی کانون‌های بالقوه و بالفعل گردوغبار است و نتایج حاصل از این روش قابل اتکا بوده، ضمناً می‌توان از این روش در شناسایی و پتانسیل‌یابی کانون‌های گردوغبار در حوضه‌های مشابه دیگر نیز بهره گرفت. بررسی نقشه پتانسیل گردوغبار استخراج‌شده از این روش نشان‌دهنده وابستگی کانون‌های فعال رخداد گردوغبار به پارامترهای محیطی و عوامل انسانی است. عمده مناطقی که به عنوان کانون‌های بالقوه گردوغبار شناخته شده‌اند (حدود ۸۵ درصد از مناطق دارای پتانسیل گردوغبار) دارای مقادیر بارش بسیار کم (کمتر از ۲۵۰ میلی‌متر) و دمای خاک بالا (۲۰ تا ۲۸ درجه سانتی‌گراد) هستند و از نظر اقلیمی نیز در مرز بیابانی قرار می‌گیرند. کما اینکه مناطق نامبرده به صورت بالفعل نیز دارای فعالیت گردوغباری می‌باشند (انطباق نسبتاً بالای نقاط شکل‌گیری گردوغبار با مناطق دارای پتانسیل گردوغبار). که این مهم از طریق بررسی و تفسیر چشمی تصاویر ماهواره‌ای حاصل شده است.

غیرطبیعی و انسان‌منشاء نیز در فعالیت‌های گردوغباری و متعاقباً شکل‌گیری کانون‌های گردوغبار در این حوضه باشد. این موضوع می‌تواند در مطالعات آینده بررسی گردد. بطورکلی نیز جهت انجام مطالعات آینده پیرامون شناسایی و نقشه‌برداری کانون‌های گردوغبار در حوضه فرات، می‌توان بر اساس نتایج حاصل از این پژوهش بر روی پهنه‌هایی که به عنوان مناطق مستعد تولید گردوغبار شناسایی شده‌اند، تمرکز کرد. بدین طریق با در نظر گرفتن شدت فعالیت‌های گردوغباری و معیارهای دیگر می‌توان اقدام به اولویت‌بندی آن‌ها نمود.

گردوغبار دلالت داشته باشد. مناطق با پتانسیل و مستعد گردوغبار غالباً در حوالی رودخانه و پهنه‌های آبی قرار گرفته‌اند، که این موضوع را به نوعی می‌توان به تأثیرات ناشی از فرسایش آبی و خشک شدن بستر رودخانه‌ها و دریاچه‌ها نسبت داد. عواملی همچون سرعت بالای باد، رطوبت کم خاک و عناصر ریزدانه خاک نیز در شکل‌گیری کانون‌های گردوغبار موثرند و عمدتاً کانون‌های گردوغبار در مناطق پست با شیب بسیار کم شکل می‌گیرند. بالاترین تراکم جمعیت را در این حوضه آبریز در حواشی پهنه‌های آبی شاهد هستیم که این مهم به عنوان یک فرضیه نیازمند مطالعه و بررسی دقیق‌تر، تا حدی می‌تواند بیانگر تاثیر عوامل

#### مراجع

- [1] M. Samadi, A. Darvishi Bolorani, S. Alavipannah, H. Mohamadi, and M. Najafi, "Global dust Detection Index (GDDI); a new remotely sensed methodology for dust storms detection," *J. Environ. Heal. Sci. Eng.*, vol. 12, no. 1, p. 20, 2014.
- [2] M. Rezazadeh, P. Irannejad, and Y. Shao, "Climatology of the Middle East dust events," *Aeolian Res.*, vol. 10, pp. 103–109, 2013.
- [3] L. Natsagdorj, D. Jugder, and Y. S. Chung, "Analysis of dust storms observed in Mongolia during 1937–1999," *Atmos. Environ.*, vol. 37, no. 9–10, pp. 1401–1411, 2003.
- [4] L.-S. Chang and S.-U. Park, "Direct radiative forcing due to anthropogenic aerosols in East Asia during April 2001," *Atmos. Environ.*, vol. 38, no. 27, pp. 4467–4482, 2004.
- [5] K. Lau and K. Kim, "Observational relationships between aerosol and Asian monsoon rainfall, and circulation," *Geophys. Res. Lett.*, vol. 33, no. 21, 2006.
- [6] I. Y. Fung, S. K. Meyn, I. Tegen, S. C. Doney, J. G. John, and J. K. B. Bishop, "Iron supply and demand in the upper ocean," *Global Biogeochem. Cycles*, vol. 14, no. 1, pp. 281–295, 2000.
- [7] H. Lee, H. Kim, Y. Honda, Y.-H. Lim, and S. Yi, "Effect of Asian dust storms on daily mortality in seven metropolitan cities of Korea," *Atmos. Environ.*, vol. 79, pp. 510–517, 2013.
- [8] P. Ginoux, J. M. Prospero, T. E. Gill, N. C. Hsu, and M. Zhao, "Global-scale attribution of anthropogenic and natural dust sources and their emission rates based on MODIS Deep Blue aerosol products," *Rev. Geophys.*, vol. 50, no. 3, 2012.
- [9] V. Sissakian, N. Al-Ansari, and S. Knutsson, "Sand and dust storm events in Iraq," *J. Nat. Sci.*, vol. 5, no. 10, pp. 1084–1094, 2013.
- [10] M. S. Najafi, F. Khoshakhllagh, S. M. Zamanzadeh, M. H. Shirazi, M. Samadi, and S. Hajikhani, "Characteristics of TSP loads during the Middle East springtime dust storm (MESDS) in Western Iran," *Arab. J. Geosci.*, vol. 7, no. 12, pp. 5367–5381, 2014.
- [11] A. Mofidi and J. Jafari, "Examining the role of regional atmospheric circulation on the Middle East in the summer dust storms

- in the South West of Iran," *J. Arid Reg. Geogr. Stud.*, no. 5, pp. 17–45, 2011.
- [12] H. Cao, J. Liu, G. Wang, G. Yang, and L. Luo, "Identification of sand and dust storm source areas in Iran," *J. Arid Land*, vol. 7, no. 5, pp. 567–578, Oct. 2015.
- [13] S.-C. Tan, J. Li, H. Che, B. Chen, and H. Wang, "Transport of East Asian dust storms to the marginal seas of China and the southern North Pacific in spring 2010," *Atmos. Environ.*, vol. 148, pp. 316–328, 2017.
- [14] A. Adib, M. Oulapour, and A. Chatroze, "Effects of wind velocity and soil characteristics on dust storm generation in Hawr-al-Azim Wetland, Southwest Iran," *Casp. J. Environ. Sci.*, vol. 16, no. 4, pp. 333–347, 2018.
- [15] A. Masoumi, E. Laleh, and A. Bayat, "Optical and physical properties, time-period, and severity of dust activities as a function of source for the main dust sources of the Middle East," *J. Atmos. Solar-Terrestrial Phys.*, vol. 185, pp. 68–79, 2019.
- [16] H. Cao, F. Amiraslani, J. Liu, and N. Zhou, "Identification of dust storm source areas in West Asia using multiple environmental datasets," *Sci. Total Environ.*, vol. 502, pp. 224–235, 2015.
- [17] O. Rahmati et al., "Land subsidence modelling using tree-based machine learning algorithms," *Sci. Total Environ.*, vol. 672, pp. 239–252, 2019.
- [18] A. Darvishi Boloorani, Y. Kazemi, A. Sadeghi, S. Nadizadeh Shorabeh, and M. Argany, "Identification of dust sources using long term satellite and climatic data: A case study of Tigris and Euphrates basin," *Atmos. Environ.*, p. 117299, 2020.
- [19] M. S. Wong et al., "A multi-scale hybrid neural network retrieval model for dust storm detection, a study in Asia," *Atmos. Res.*, vol. 158, pp. 89–106, 2015.
- [20] A. S. Goudie, "Dust storms: Recent developments," *J. Environ. Manage.*, vol. 90, no. 1, pp. 89–94, 2009.
- [21] G. Shepherd et al., "Global assessment of sand and dust storms," *United Nations Environment Programme (UNEP)*, 2016. <http://hdl.handle.net/20.500.11765/4495>.
- [22] A. McNally et al., "A land data assimilation system for sub-Saharan Africa food and water security applications," *Sci. data*, vol. 4, no. 1, pp. 1–19, 2017.
- [23] S. Namdari, K. K. Valizade, A. A. Rasuly, and B. S. Sarraf, "Spatio-temporal analysis of MODIS AOD over western part of Iran," *Arab. J. Geosci.*, vol. 9, no. 3, p. 191, 2016.
- [24] O. Rahmati et al., "Identifying sources of dust aerosol using a new framework based on remote sensing and modelling," *Sci. Total Environ.*, vol. 737, p. 139508, 2020.
- [25] J. Yen and R. Langari, *Fuzzy logic: intelligence, control, and information*, vol. 1. Prentice hall Upper Saddle River, NJ, 1999.
- [26] F. Logic, "Fuzzy logic and neural network handbook," 1996.
- [27] J. A. Anderson, A. Pellionisz, and E. Rosenfeld, "Neurocomputing: directions for research, vol. 2." MIT Press, Cambridge, MA, 1990.
- [28] B. C. Hewitson and R. G. Crane, *Neural nets: applications in geography: applications for geography*, vol. 29. Springer Science & Business Media, 1994.
- [29] R. Noori, A. R. Karbassi, H. Mehdizadeh, M. Vesali-Naseh, and M. S. Sabahi, "A framework development for predicting the longitudinal dispersion coefficient in natural streams using an artificial neural network," *Environ. Prog. Sustain. Energy*, vol. 30, no. 3, pp. 439–449, 2011.
- [30] I. Kuzmanovski and S. Aleksovska, "Optimization of artificial neural networks for prediction of the unit cell parameters in orthorhombic perovskites. Comparison with multiple linear regression," *Chemom. Intell. Lab. Syst.*, vol. 67, no. 2, pp. 167–174, 2003.
- [31] M. T. Hagan, H. B. Demuth, and M. Beale,

- Neural network design.* PWS Publishing Co., 1997.
- [32] H. Demuth, M. Beale, and M. Hagan, "Neural network toolbox," Use with MATLAB. MathWorks Inc, vol. 2000, 1992.
- [33] H. Raman and N. Sunilkumar, "Multivariate modelling of water resources time series using artificial neural networks," *Hydrol. Sci. J.*, vol. 40, no. 2, pp. 145–163, 1995.
- [34] S. Haykin and N. Network, "A comprehensive foundation," *Neural networks*, vol. 2, no. 2004, p. 41, 2004.
- [35] J. R. Benjamin and C. A. Cornell, *Probability, statistics, and decision for civil engineers.* Courier Corporation, 2014.
- [36] A. P. Engelbrecht, *Computational intelligence: an introduction.* John Wiley & Sons, 2007.
- [37] G. Onwubolu, "Hybrid Computational Intelligence and GMDH Systems," in *Hybrid Self-Organizing Modeling Systems*, Springer, 2009, pp. 1–26.
- [38] M. H. Beale, M. T. Hagan, and H. B. Demuth, "Neural network toolbox," *User's Guid.* MathWorks, vol. 2, pp. 77–81, 2010.
- [39] R. Noori, A. Khakpour, B. Omidvar, and A. Farokhnia, "Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistic," *Expert Syst. Appl.*, vol. 37, no. 8, pp. 5856–5862, 2010.
- [40] I. Yilmaz, "Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: a case study from Kat landslides (Tokat—Turkey)," *Comput. Geosci.*, vol. 35, no. 6, pp. 1125–1138, 2009.
- [41] H. Gomez and T. Kavzoglu, "Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela," *Eng. Geol.*, vol. 78, no. 1–2, pp. 11–27, 2005.
- [42] H.-C. Huang, R.-C. Hwang, and J.-G. Hsieh, "A new artificial intelligent peak power load forecaster based on non-fixed neural networks," *Int. J. Electr. power energy Syst.*, vol. 24, no. 3, pp. 245–250, 2002.
- [43] G. Z. M. JALALI and R. E. NOURI, "Prediction of municipal solid waste generation by use of artificial neural network: A case study of Mashhad," 2008.
- [44] N. Jalali, F. Iranmanesh, and M. H. Davoodi, "Identification on dust storm sources and their affecting areas in south-west provinces of Iran, using MODIS image", *Journal of Watershed Engineering and Management*, Vol. 9(3), pp. 318-331, 2017 (Persian).
- [45] J. R. Von Holdt, F. D. Eckardt, and G. F. S. Wiggs, "Landsat identifies aeolian dust emission dynamics at the landform scale," *Remote Sens. Environ.*, vol. 198, pp. 229–243, 2017.
- [46] S. Karsoliya, "Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture," *Int. J. Eng. Trends Technol.*, vol. 3, no. 6, pp. 714–717, 2012.
- [47] M. Hamidi, M. R. Kavianpour, and Y. Shao, "Synoptic analysis of dust storms in the Middle East," *Asia-Pacific J. Atmos. Sci.*, vol. 49, no. 3, pp. 279–286, 2013.
- [48] A. Darvishi Bolorani, S.O. Nabavi, H.A. Bahrami, F. Mirzapour, M. Kavosi, E. Abasi, and R. Azizi, "Investigation of dust storms entering Western Iran using remotely sensed data and synoptic analysis," *J. Environ. Heal. Sci. Eng.*, vol. 12, no. 1, p. 124, 2014.



## ***Modeling the potential of Sand and Dust Storm sources formation using time series of remote sensing data, fuzzy logic and artificial neural network (A Case study of Euphrates basin)***

Ramin Papi<sup>1</sup>, Meysam Argany<sup>2\*</sup>, Shahab Moradipour<sup>3</sup>, Masoud Soleimani<sup>1</sup>

1- PhD Student in Remote Sensing and GIS, Faculty of Geography, University of Tehran.

2- Assistant Professor, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

3- Graduated Master Student of Remote Sensing and GIS, Faculty of Geography, University of Tehran

### **Abstract**

Sand and Dust Storms (SDS) are known as one of the most common environmental problems in arid and semi-arid regions of the world. This phenomenon is harmful to human health as well as to economy. Over the past two decades, SDS have been increasing on a local, regional and even global scale. The Euphrates Basin is recognized as one of the most active SDS sources in the world. The first step in managing this environmental phenomenon, is to identify dust storm sources. The aim of this study is mapping the potential sources of SDS in the Euphrates basin by using Multi-Layer Perceptron Neural Network. In the first step, the long-term time series of which is data, related to key environmental parameters affecting the occurrence of SDS including: soil moisture, soil temperature, soil texture, land surface temperature, wind speed, precipitation, evapotranspiration, dusty months, land use population, pressure, the identified elevation and slope were used as artificial neural network model inputs. Using the visual interpretation of 2500 MODIS images in natural color composite, 190 SDS centers were identified visually and introduced to the neural network as training points. 70% of the points (133 points) and 30% of them (57 points) were used for training, testing and validation of model, respectively. After running the model, the estimated mean squared error (MSE) was equal to 0.1, which indicates acceptable accuracy of the neural network model in mapping the potential SDS sources. The results show that, 147000 km<sup>2</sup> of the basin is prone to the formation of SDS sources, which mainly include low rainfall, dry and barren areas of the basin.

**Key words:** Sand and Dust Storm (SDS), Remote Sensing, Time Series, Artificial Neural Network, Euphrates Basin