



سنجش از دور

و

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال پانزدهم، شماره اول، بهار ۱۴۰۲
Vol.15, No. 1, Spring 2023

۱۳۹-۱۳۹

مقاله پژوهشی

یک مدل شبکه عصبی پیچشی برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار

مهدیس یارمحمدی^۱، علی‌اصغر آل‌شیرازی^۲، محمد شریف^{۳*}

۱. دانشجوی کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران

۲. استاد دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران

۳. استادیار دانشکده علوم انسانی، دانشگاه هرمزگان، بندرعباس

تاریخ پذیرش مقاله: ۱۴۰۱/۰۹/۱۵

تاریخ دریافت مقاله: ۱۴۰۱/۰۷/۲۶

چکیده

طوفان‌های گردوغبار بلایایی طبیعی‌اند که در زندگی انسان و محیط‌زیست تأثیر چشمگیری گذاشته‌اند. توسعه مدل‌هایی، به‌منظور پیش‌بینی مسیر حرکت این طوفان‌ها، در پیشگیری و مدیریت طوفان‌های گردوغبار نقش بسزایی ایفا می‌کند زیرا مسیر انتقال آنها را آشکار و مناطق آسیب‌پذیر بعدی در برابر طوفان را مشخص می‌کنند. به‌لطف امکانات روش‌های یادگیری عمیق در حل مسائل مبتنی‌بر سری زمانی و یافتن الگوهای پنهان از حجم داده کلان، در این پژوهش، یک مدل ترکیبی شبکه عصبی پیچشی (CNN) به‌منظور پیش‌بینی مسیر حرکت طوفان گردوغبار، براساس داده عمق نوری هواویز (AOD) محصول MERRA-2 برای دوازده ساعت آینده، توسعه داده شده است. همچنین چهل رویداد طوفان، شامل ۲۴۸۹ ساعت طوفان در منطقه‌ای خشک در مرکز و جنوب آسیا، به‌منظور آموزش مدل به‌کار رفته است. نتایج نشان می‌دهد که مدل پیشنهادی پیش‌بینی دقیقی از مسیر حرکت طوفان به‌دست می‌دهد؛ به‌گونه‌ای که در مورد گام‌های زمانی ۳، ۶، ۹ و ۱۲ ساعت آینده، مقادیر دقت کلی به‌ترتیب برابر با ۰/۹۸۰۶، ۰/۹۸۱۰، ۰/۹۸۱۳ و ۰/۹۷۹۰، مقادیر امتیاز F1 به‌ترتیب برابر با ۰/۸۴۹۰، ۰/۸۵۲۴، ۰/۸۵۳۰ و ۰/۸۳۸۴ و مقادیر ضریب کاپا به‌ترتیب برابر با ۰/۸۳۸۷، ۰/۸۴۲۴، ۰/۸۴۳۱ و ۰/۸۲۷۳ است.

کلیدواژه‌ها: فرایند حرکتی، پیش‌بینی حرکت، یادگیری عمیق، طوفان‌های گردوغبار، MERRA-2.

* نویسنده مکاتبه‌کننده: استان هرمزگان، بندرعباس، کیلومتر ۹ جاده میناب، دانشگاه هرمزگان، کدپستی: ۷۹۱۶۱۹۳۱۴۵. تلفن: ۰۷۶۳۳۷۱۱۰۰۰

۱- مقدمه

طبق تعریف سازمان جهانی هواشناسی، طوفان گردوغبار به صورت «بادی قوی که مقادیر زیادی از ذرات گردوغبار را بلند می‌کند و دید را به کمتر از هزار متر کاهش می‌دهد» تعریف می‌شود (Goudie & Middleton, 2006). طوفان گردوغبار پدیده‌ای رایج در مناطق خشک جهان است (Liu et al., 2013). مناطق خشک حدود ۴۰٪ از سطح زمین را تشکیل می‌دهند و محل زندگی بیش از دو میلیارد نفرند (Safriel et al., 2005). طوفان گردوغبار پدیده‌ای پویاست که چهار مرحله تخریب سرزمین، فرسایش بادی، حمل (حرکت) و فرونشست را شامل می‌شود (Boloorani et al., 2021). این پدیده نتیجه فرسایش خاک بر اثر وزش باد است. طی وزش باد، فرسایش باد از فرسایش‌پذیری خاک در سطح بیشتر است و در نتیجه، باد ذرات خاک تخریب‌شده را از زمین بلند می‌کند و می‌تواند آنها را تا چندین هزار کیلومتر جابه‌جا کند. این ذرات در شرایط جوی، سلامت انسان، تولیدات کشاورزی و اکوسیستم تأثیر می‌گذارند (Rashki et al., 2021). تأثیرات طوفان‌های گردوغبار در سراسر جهان رو به افزایش است اما پنج منطقه آسیای مرکزی، شمال آفریقا، خاورمیانه، آمریکای شمالی و استرالیا تحت تأثیر شدیدترین طوفان‌ها قرار دارند (Liu et al., 2013)؛ از این رو مهم است به روش‌هایی توجه شود که بتوانند مسیر حرکت طوفان‌های گردوغبار را پیش‌بینی کنند تا مناطق آسیب‌پذیر بعدی آشکارسازی شود و اقدامات مناسب، برای کاهش تأثیر مخرب این طوفان‌ها، انجام شود.

پایش پدیده طوفان‌های گردوغبار، در بازه‌های زمانی کوتاه‌مدت، اهمیت بسیار دارد و این امکان، به لطف فناوری سنسجش از دور و تولید تصاویر ماهواره‌ای با قدرت تفکیک‌های مکانی و زمانی متفاوت، فراهم شده است. عمق نوری هواویز AOD^۱ پارامتری است که ویژگی‌های نوری ذرات گردوغبار را منعکس می‌کند و اغلب در مطالعات رویدادهای گردوغبار استفاده می‌شود (Mohammadpour et al., 2022). AOD را می‌توان با

استفاده از سنسجش دور ماهواره‌ای و مشاهدات زمین‌مبنا اندازه‌گیری کرد. مجموعه داده مادیس^۲ اطلاعات AOD ماهواره‌ای را به صورت روزانه، با قدرت تفکیک مکانی بالا و با پوشش جهانی، در اختیار قرار می‌دهد. مجموعه داده AERONET^۳ که ناسا آن را به منزله مجموعه داده AOD زمین‌مبنا معرفی کرده، موجب پیشرفت‌های شایان توجهی در زمینه شناخت تأثیرات ذرات گردوغبار شده است (Mobarak Hassan et al., 2020). این دو مجموعه داده کاربرد گسترده‌ای در پژوهش‌های پیشین داشته‌اند (Yousefi et al., 2020) اما قدرت تفکیک زمانی اندک و یک‌روزه دارند. مجموعه داده MERRA-2^۴ (Giovanni, 2022) که در این پژوهش به کار رفته است، با همانندسازی مجموعه‌ای از داده‌های AOD ماهواره‌ای و زمین‌مبنا تولید شده و دارای قدرت تفکیک زمانی یک‌ساعته است؛ این ویژگی بررسی مستمر مکان و حرکت ذرات گردوغبار را امکان‌پذیر می‌کند.

طوفان گردوغبار گونه‌ای از فرایندهای حرکتی است که برخلاف اشیای نقطه‌ای متحرک (مانند انسان و وسایل نقلیه)، اندازه آن مدام در حال تغییر است. اشیای نقطه‌ای متحرک اغلب به صورت خط‌سیر مطالعه می‌شوند اما در مورد فرایندهای حرکتی، علاوه بر مسیر حرکت، مساحتی که پوشش می‌دهند نیز مطرح می‌شود. تا کنون پژوهش‌های اندکی درباره پیش‌بینی مسیر حرکت طوفان‌های گردوغبار، در قالب فرایندهای حرکتی، انجام شده و در این پژوهش‌ها، طوفان گردوغبار اغلب به صورت پدیده‌ای نقطه‌ای در نظر گرفته شده است. برای نمونه، ال-یحیایی و چرابی^۵ (۲۰۱۴)

1. Aerosol Optical Depth
2. The Moderate Resolution Imaging Spectroradiometer (MODIS)
3. Aerosol Robotic Network
4. The Modern-Era Retrospective Analysis for Research and Applications, version 2
5. Al-Yahyai & Charabi

پژوهش رستری هستند و در پژوهش‌های پیشین، ثابت شده که عملکرد این مدل‌ها در مورد داده‌های رستری مناسباند (Mahdianpari et al., 2018).

در پژوهش‌های پیشین، پدیده طوفان گردوغبار اغلب به صورت نقطه‌ای در نظر گرفته شده و پیش‌بینی کوتاه‌مدت در مورد آن انجام شده است؛ از این‌رو هدف این پژوهش پیش‌بینی مسیر حرکت طوفان‌های گردوغبار با استفاده از روش یادگیری عمیق است. مشارکت این پژوهش طراحی مدل ترکیبی CNN و استفاده از داده‌های ساعتی AOD محصول MERRA-2، به منظور پیش‌بینی مسیر حرکت طوفان‌های گردوغبار طی دوازده ساعت آینده است. مدل یادشده روی داده‌های طوفان‌هایی واقع در منطقه‌ای خشک، در مرکز و جنوب آسیا، آموزش می‌بیند؛ این مدل ارزیابی و دقت پیش‌بینی محاسبه می‌شود.

۲- مواد و روش‌ها

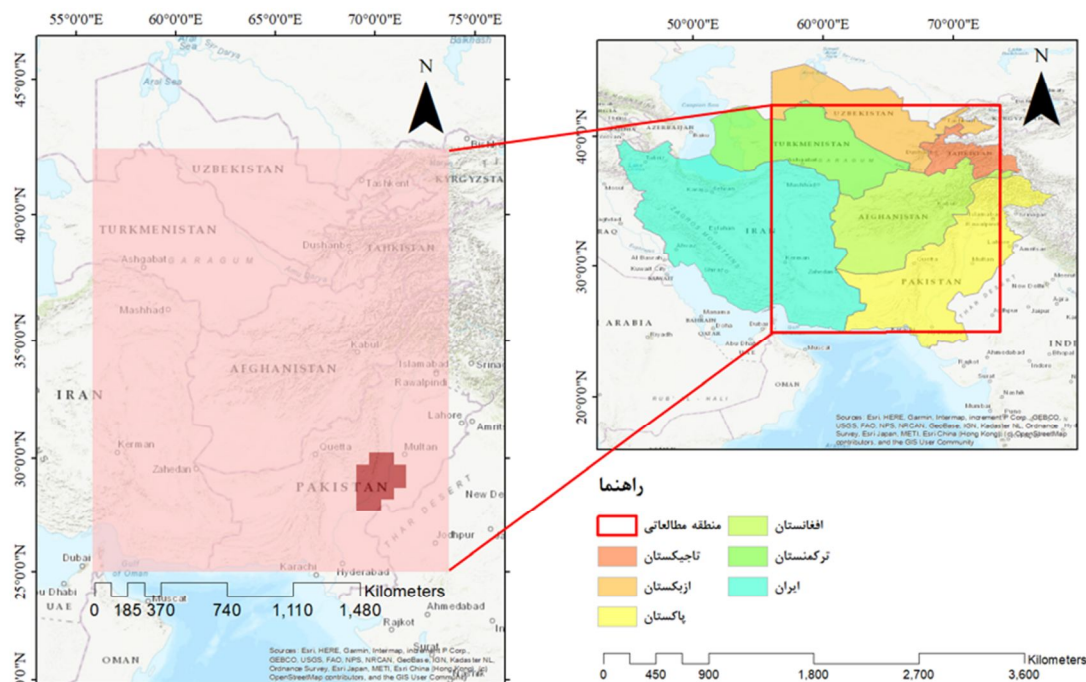
۲-۱- منطقه مطالعاتی

منطقه مورد مطالعه شامل مناطقی خشک از آسیای مرکزی و جنوبی است که بخش‌هایی از کشورهای ایران، افغانستان، پاکستان، تاجیکستان، ترکمنستان و ازبکستان را دربر می‌گیرد (شکل ۱). میانگین دمای این منطقه، در مناطق کوهستانی و ساحلی، به ترتیب بین ۴- تا ۱۹ درجه سانتی‌گراد و میانگین بارش بین ۰/۱ تا ۳ میلی‌متر در روز است. این کشورها طی سال‌های اخیر تحت تأثیر شدیدترین طوفان‌های گردوغبار بوده‌اند. بستر خشک هامون و شمال ترکمنستان و شرق پاکستان مبدأ بیشتر طوفان‌هایی‌اند که در فصل‌های بهار و تابستان در این منطقه به وقوع می‌پیوندند. در این پژوهش، طوفان‌هایی که از کشور پاکستان آغاز می‌شوند بررسی شده‌اند.

1. Numerical Weather Prediction
2. Hybrid Single Particle Trajectory Lagrangian Integrated
3. Convolutional Neural Network
4. Long-Short Term Memory
5. Gated Recurrent Units
6. Recurrent Neural Networks

با استفاده از منابع گردوغبار از پیش تعیین‌شده و پیش‌بینی عددی آب‌وهوا (NWP)^۱، مسیر حرکت طوفان‌های گردوغبار را پیش‌بینی کردند. همچنین در پژوهش‌های بسیاری، برای شناسایی منابع گردوغبار و مدل‌سازی خط‌سیرهای آنها، از مدل ریاضی HYSPLIT^۲ استفاده شده است (Stein et al., 2015). اساس ماژول HYSPLIT، الگوریتم انتشار طوفان گردوغبار PM_{۱۰} برای زمین‌های بیابانی است. این مدل به داده‌های هواشناسی هم‌نیاز دارد و دقت آن با توجه به دقت داده‌های هواشناسی تعیین می‌شود (Aili et al., 2021; Guan et al., 2019; Stein et al., 2015).

از سوی دیگر، روش‌های یادگیری عمیق که زیرمجموعه‌ای از روش‌های یادگیری ماشین هستند، به‌منزله ابزاری کارآمد در پیش‌بینی فرایندهای حرکتی به کار رفته‌اند. از ترکیب مدل‌های شبکه عصبی پیچشی (CNN)^۳ و حافظه طولانی کوتاه‌مدت (LSTM)^۴ (Burge et al., 2020) و مدل‌های واحد بازگشتی دروازه‌ای (GRU)^۵ و LSTM (Perumal & van Zyl, 2020) برای مدل‌سازی گسترش آتش‌سوزی استفاده شده و مدل‌های شبکه‌های عصبی بازگشتی (RNN)^۶ (Wang et al., 2021) و CNN (Jiao et al., 2019) نیز برای کشف و مدل‌سازی حرکت لکه‌های نفتی به کار رفته است. تا کنون از روش‌های یادگیری عمیق برای پیش‌بینی مکانی-زمانی مسیر حرکت طوفان‌های گردوغبار استفاده نشده است. از آن‌جاکه این الگوریتم‌ها تنوع بسیاری دارند، امکان ترکیب آنها با یکدیگر وجود دارد و در مسائل سری زمانی مشابه عملکردشان ثابت شده است، می‌توان از پتانسیل آنها در مطالعه پدیده طوفان‌های گردوغبار استفاده کرد و در پیش‌بینی مسیر حرکت طوفان‌ها، به دقت‌های بالاتر دست یافت. روش CNN با توجه به اینکه دارای ساختار سلسله‌مراتبی است و امکان استخراج ویژگی‌های سطح بالا را فراهم می‌کند، برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار انتخاب شده است. همچنین داده‌های به‌کاررفته در این



شکل ۱. منطقه مطالعاتی با رنگ صورتی و نمونه‌ای از یک طوفان که از پاکستان آغاز شده، با رنگ قرمز مشخص شده است

۲-۲- داده‌های پژوهش

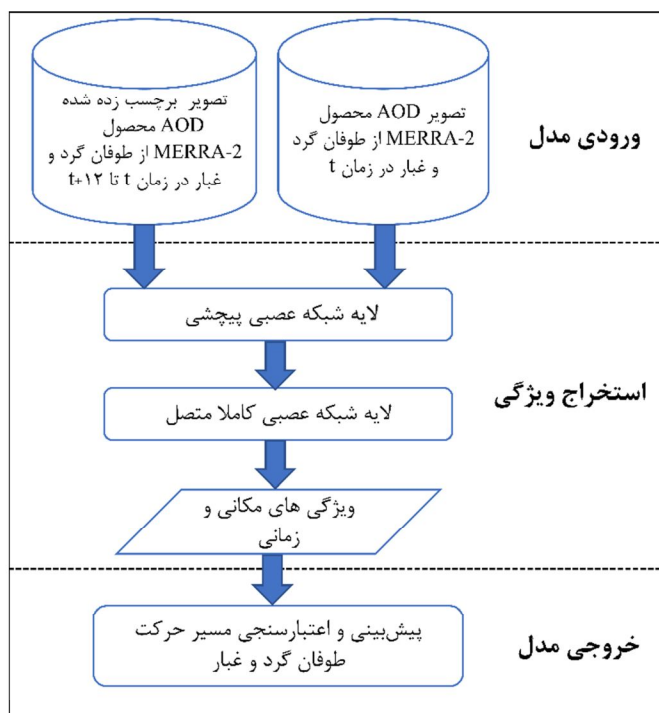
در این پژوهش، برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار از مجموعه داده AOD، محصول MERRA-2 که به صورت ساعتی و با قدرت تفکیک مکانی $0.5^\circ \times 0.625^\circ$ درجه منتشر می‌شوند و در طول موج ۵۵۰ نانومتر دریافت شده‌اند، استفاده می‌شود. این داده‌ها از سال ۱۹۸۰ تا کنون در دسترس قرار دارند (Giovanni, 2022). جدیدترین داده‌های MERRA-2 از مدل جوئی سامانه مشاهده زمین گوارد (GEOS)^۱ ایجاد شده‌اند که یک تکنیک شبیه‌سازی داده و تحلیل درون‌یابی آماری Gridpoint است و این داده‌ها غلظت گردوغبار را در هر پیکسل نشان می‌دهند. MERRA-2 نخستین مجموعه داده تحلیل مجدد ماهواره‌ای است که با همانندسازی مجموعه داده‌های AOD ماهواره‌ای AVHRR^۲، MISR^۳ و مادیس و نیز مشاهدات زمینی AERONET تولید می‌شود (Yousefi et al., 2020). چهل رویداد طوفان گردوغبار بین سال‌های ۲۰۰۰ تا ۲۰۲۱، شامل ۲۴۸۹ ساعت طوفان، از داده‌های MERRA-2 استخراج شده‌اند.

۲-۳- مدل پیش‌بینی مسیر حرکت طوفان گردوغبار

روند نمای کلی مدل پیش‌بینی پیشنهادی که شامل سه مرحله ورودی مدل، استخراج ویژگی و خروجی مدل می‌شود، در شکل ۲ نشان داده شده است. از آن‌جا که با یک مسئله سری زمانی مواجهیم، دو نوع داده به کار رفته است. تصاویر AOD مربوط به هر ساعت از طوفان با ابعاد 140×143 پیکسل، به‌منزله ورودی و تصاویر صفر و یکی برچسب‌خورده متعلق به دوازده ساعت بعدی طوفان، به‌منزله خروجی به مدل داده شده‌اند. در واقع، از داده خام نخستین ساعت طوفان استفاده شده است تا وضعیت طوفان در دوازده ساعت پیش رو پیش‌بینی شود.

1. Goddard Earth Observing System
2. Advanced Very High-Resolution Radiometer
3. Multi-Angle Imaging Spector Radiometer

یک مدل شبکه عصبی پیچشی برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار



شکل ۲. روند نمای کلی از فرایند پیش‌بینی مسیر حرکت طوفان گردوغبار

شکل ۳ ساختار یک مدل ترکیبی یادگیری عمیق را نشان می‌دهد. این مدل دارای پانزده لایه متفاوت، شامل دوازده لایه CNN، دو لایه کاملاً متصل و یک لایه مسطح‌کننده^۱ است. این لایه‌ها در چهار بلوک اصلی قرار گرفته‌اند که عبارت‌اند از بلوک استخراج ویژگی، بلوک استخراج ویژگی‌های چندمقیاسی، بلوک فیلتر ویژگی‌های چندمقیاسی و بلوک پیش‌بینی. شبکه عصبی مصنوعی نوعی ساختار ریاضی است که توانایی نشان دادن آثار غیرخطی را در مورد ارتباط ورودی و خروجی‌های هر سیستمی دارد (Ansari ghoghhar et al., 2020). مدل CNN را که نوعی شبکه عصبی مصنوعی است، اولین بار لکان^۲ و همکاران (۱۹۸۹) معرفی کردند و کریژفسکی^۳ و همکاران (۲۰۱۲) آن را توسعه دادند. مزیت اصلی این شبکه بر دیگر شبکه‌های عصبی این است که ویژگی‌های مهم را به صورت خودکار و بدون دخالت انسانی تشخیص می‌دهد (Alzubaidi et al., 2021). CNNها، همانند دیگر شبکه‌های عصبی معمول، مبتنی بر نورون‌هایی‌اند که در

لایه‌ها قرار گرفته‌اند (Kattenborn et al., 2021) و از مجموعه‌ای از شبکه‌های عصبی به هم پیوسته چندلایه تشکیل شده‌اند؛ از این رو قادرند ویژگی‌های سطح بالا، متوسط و پایین را به صورت سلسله‌مراتبی استخراج کنند (Mahdianpari et al., 2018). نورون‌های بین لایه‌ها از طریق وزن و بایاس به هم متصل‌اند (Kattenborn et al., 2021). در شبکه‌های پیچشی، باید اندازه کرنل و تعداد فیلترها مشخص شود. این پارامترها باید به گونه‌ای انتخاب شوند که ویژگی‌های استخراج‌شده، برای مشکل موجود، تعیین‌کننده باشند (Kattenborn et al., 2021).

معماری CNN از دو لایه اصلی تشکیل شده است؛ لایه کانولوشن و لایه ادغام^۴ (Chollet, 2017). لایه‌های کانولوشن ویژگی‌ها را استخراج می‌کنند، لایه‌های اولیه

1. Flatten
2. LeCun
3. Krizhevsky
4. Pooling

CNN به پارامترهایی از جمله تعداد و ویژگی‌های لایه‌های پنهان، عملیات ادغام، تکنیک‌های تنظیم^۱ و توابع هزینه نیز بازمی‌گردد. نرمال‌سازی دسته‌ای^۲ برای نرمال‌سازی ویژگی‌های استخراج‌شده پس از آخرین لایهٔ پیچشی استفاده شده است. ویژگی‌های نرمال‌شده وارد بلوک آخر با دو لایهٔ کاملاً متصل، شامل ۶۴ و ۲۸۰۲۸۰ نرون شده‌اند. به‌جز لایهٔ آخر کاملاً متصل که از تابع سیگموئید استفاده می‌کند، سایر لایه‌ها از تابع فعال‌سازی Relu بهره برده‌اند. تابع سیگموئید می‌تواند مقدار احتمال وجود طوفان گردوغبار در هر پیکسل را تعریف کند. لایه‌های پیچشی در ابتدا به‌صورت تصادفی وزن‌دهی می‌شوند. سپس تفاوت بین مقادیر پیش‌بینی‌شده، از طریق مدل و مقادیر برچسب‌خورده، محاسبه می‌شود و با استفاده از یک الگوریتم پس‌انتشار^۴، وزن‌ها پالایش می‌شوند. تابع BCE^۵ به‌منزلهٔ تابع ضرر استفاده شده است. این تابع در رابطه (۱) آمده و در آن y برچسب، $p(y)$ احتمال پیش‌بینی‌شده و N تعداد نمونه‌هاست.

$$BCE = \sum_{i=1}^N y_i \times \log(p(y_i)) + (1 - y_i) \times \log(1 - p(y_i))$$

رابطه (۱)

۲-۴- ارزیابی

سه معیار دقت کلی، ضریب کاپا و امتیاز F1 برای ارزیابی عملکرد مدل یادگیری عمیق استفاده شده‌اند. این معیارها با استفاده از ماتریس ابهام به‌دست می‌آیند. دقت کلی نشان‌دهندهٔ مقدار ناحیه‌ای از تصویر است که درست پیش‌بینی شده است. این معیار طبق رابطه (۲) حاصل می‌شود.

$$Accuracy(\%) = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \times 100\%$$

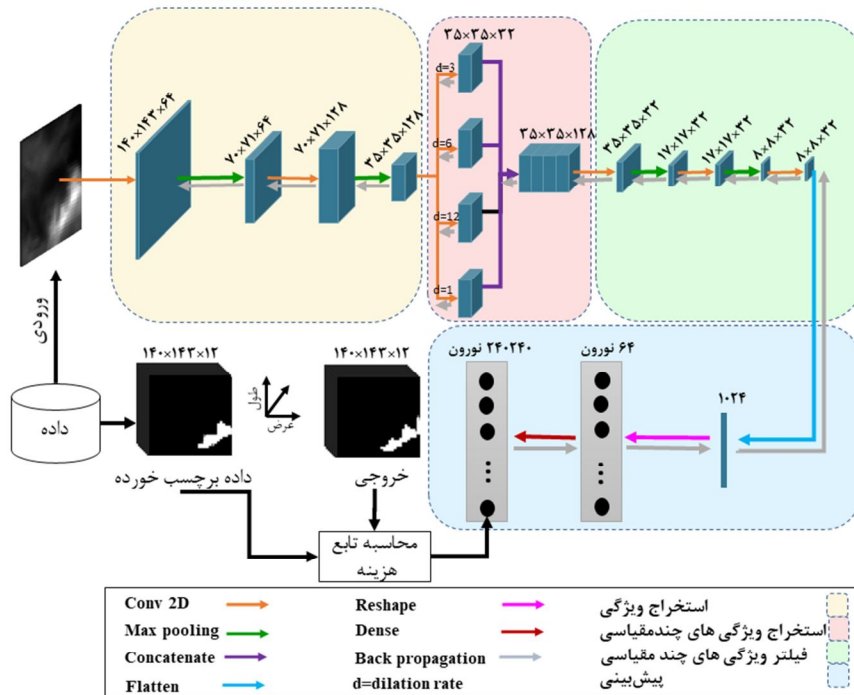
رابطه (۲)

1. Concatenate
2. Regularization
3. Batch Normalization
4. Back Propagation
5. Binary Cross-Entropy

ویژگی‌های سطح پایین مانند لبه‌ها و لایه‌های انتهایی ویژگی‌های سطح بالا مانند ساختار تصویر را استخراج می‌کنند (Mahdianpari et al., 2018). به‌این‌ترتیب نقشه‌های ویژگی با ضرب وزن هر کرنل در بخش کوچکی از تصویر ورودی به‌دست می‌آیند (Alzubaidi et al., 2021). هر نقشهٔ ویژگی، به‌منزلهٔ ورودی، وارد لایهٔ بعدی می‌شود. پس از هر لایهٔ کانولوشن می‌توان یک لایهٔ ادغام قرار داد. این لایه به کاهش پارامترهای شبکه منجر می‌شود که آموزش شبکه را تسریع و امکان رسیدگی به مشکل بیش‌برازش را فراهم می‌کند (Alzubaidi et al., 2021). ادغام با اندازهٔ فیلتر، گام (فاصلهٔ بین عملیات ادغام متوالی) و نوع عملیات ادغام تعریف می‌شود. معمول‌ترین عملیات ادغام max-pooling است. ایدهٔ max-pooling این است که ویژگی‌های قوی، مانند لبه‌ها، در شبکه حفظ شوند. عملگرهای max-pooling با اندازهٔ فیلتر ۲×۲ و گام ۲، اندازهٔ نقشهٔ ویژگی را با ضریب ۴ کاهش می‌دهد؛ درحالی‌که سلول‌های خروجی حداکثر چهار سلول ورودی در فیلتر ۲×۲ دارند. بلوک اول شامل دو لایهٔ کانولوشن، به‌ترتیب با ۶۴ و ۱۲۸ فیلتر ۳×۳ است که پس از هر لایهٔ کانولوشن، یک لایهٔ max-pooling با فیلتر ۲×۲ قرار گرفته است. ویژگی‌های چندمقیاسی با عبور خروجی بلوک اول از چهار لایهٔ پیچشی با dilation rate ۳، ۶، ۱۲ و ۱ شامل ۳۲ فیلتر با اندازهٔ ۳×۳ در هر لایه، به‌دست آمدند. در بلوک سوم، یک لایهٔ پیچشی با ۳۲ فیلتر ۱×۱ برای اعمال روی ویژگی‌های متصل شده^۱ به‌کار رفته است. سپس از دو لایهٔ پیچشی با ۳۲ فیلتر ۳×۳، برای فیلتر ویژگی‌های چندمقیاسی استفاده شده است. پس از هر لایهٔ پیچشی، یک لایهٔ max-pooling با فیلتر ۲×۲ قرار گرفته است.

لایه‌های CNN، یا همان لایه‌های کانولوشن و ادغام، می‌توانند به‌روش‌های بسیار متفاوتی ترکیب شوند که نوع ترکیب معمولاً به‌منزلهٔ معماری CNN توصیف می‌شود. معماری CNN براساس مشکل پیش‌رو تعریف می‌شود. پیچیدگی و عملکرد کلی معماری

یک مدل شبکه عصبی پیچشی برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار



شکل ۳. ساختار مدل CNN

precision که با عنوان پیش‌بینی مثبت نیز شناخته می‌شود، نشان‌دهنده میزان پیکسل‌هایی است برای هر دسته به‌درستی پیش‌بینی شده‌اند. recall که به‌منزله حساسیت نیز شناخته می‌شود، مشخص می‌کند چند پیکسل واقعی در هر دسته شناسایی شده است. امتیاز F1 طبق رابطه (۴) محاسبه می‌شود.

$$F1(\%) = \left(2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \times 100\%$$

رابطه (۴)

precision و recall نیز، به‌ترتیب براساس روابط

(۵) و (۶) محاسبه می‌شوند.

رابطه (۵)

$$\text{Precision}(\%) = \left(\frac{TP}{TP+FP} \right) \times 100\%$$

رابطه (۶)

$$\text{Recall}(\%) = \left(\frac{TP}{TP+FN} \right) \times 100\%$$

۳- نتایج و بحث

در پژوهش حاضر، داده‌ها به ۲۲۲۷ نمونه آموزشی و ۲۴۸ نمونه اعتبارسنجی تقسیم شده‌اند. به این دلیل که با مسئله سری زمانی مواجهیم، داده‌ها به دو بخش

در این معادله، مثبت صحیح (TP) نتایج مثبتی‌اند که به‌درستی پیش‌بینی شده‌اند و منفی صحیح (TN) نتایجی منفی‌اند که مدل به‌درستی آنها را پیش‌بینی کرده است. مثبت کاذب (FP) نتایج مثبتی است که مدل به‌اشتباه پیش‌بینی کرده و با عنوان خطای نوع اول هم شناخته می‌شوند. منفی کاذب (FN) نیز نتایجی منفی است که مدل به‌اشتباه پیش‌بینی کرده است. ضریب کاپا میزان توافق بین داده‌های پیش‌بینی شده و داده‌های مرجع را نشان می‌دهد. مقدار ۱ برای ضریب کاپا نشان‌دهنده توافق صددرصدی و میزان صفر نشان‌دهنده نبود توافق است. ضریب کاپا با استفاده از رابطه (۳) به‌دست می‌آید.


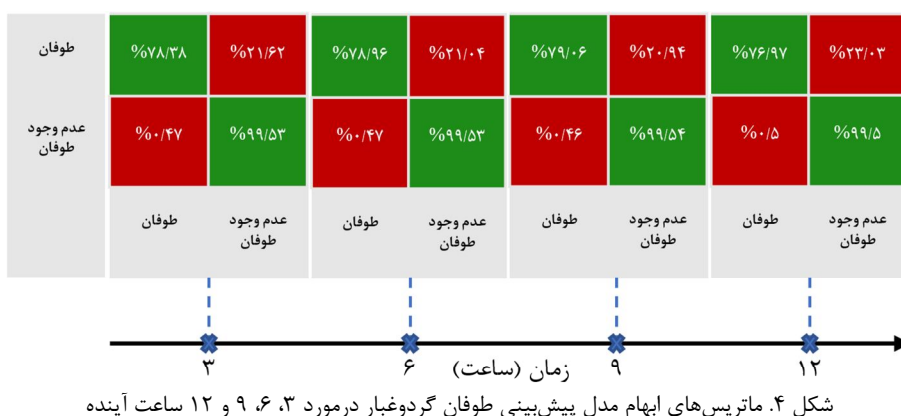
$$k = \frac{\rho_o - \rho_e}{1 - \rho_e} \quad \text{رابطه (۳)}$$

مقدار ρ_o توافق نسبی دو ارزیاب و مقدار ρ_e میزان توافق مورد انتظار را نشان می‌دهد. این مقادیر را با استفاده از ماتریس ابهام می‌توان محاسبه کرد.

امتیاز F1 معیار کمی مفیدی است که تعادل بین precision و recall را اندازه‌گیری می‌کند.

همان‌طور که مشاهده می‌شود، درصد بالایی از پیکسل‌ها در المان‌های مورب ماتریس ابهام قرار دارند. این بدان معنی است که درصد بالایی از پیکسل‌های حاوی طوفان و پیکسل‌های عاری از طوفان، طی دوازده ساعت، به‌درستی پیش‌بینی شده‌اند. دلیل دستیابی به این کارایی می‌تواند ویژگی‌های چندمقیاسی استخراج‌شده از طریق مدل باشد. از آن‌جا که طیف گسترده‌ای از اندازه‌های طوفان در داده‌ها وجود دارد، این مدل می‌تواند ویژگی‌های مرتبط را استخراج و از افزودنی ویژگی خودداری کند. شکل ۵ عملکرد مدل در پیش‌بینی دوازده ساعت طوفان را با استفاده از سه معیار ارزیابی دقت کلی، ضریب کاپا و امتیاز F1 نشان می‌دهد.

ورودی و خروجی تقسیم شده‌اند. داده ورودی شامل داده خام AOD MERRA-2 در گام زمانی t و داده خروجی شامل تصویر برجسب‌خورده در دوازده گام زمانی بعدی است. اندازه دسته ۴ در نظر گرفته شده و بهینه‌ساز Adam با نرخ یادگیری ۰/۰۰۰۵ و تعداد ۱۵۰ تکرار در حین آموزش به کار رفته است. پیش‌بینی مسیر حرکت طوفان گردوغبار با استفاده از تابع ضرر BCE آموزش داده شده و عملکرد مدل با استفاده از سه معیار دقت کلی، ضریب کاپا و امتیاز F1 ارزیابی شده است. نتایج در زمینه پیش‌بینی مسیر حرکت طوفان، طی دوازده ساعت آتی، از نظر دقت پیش‌بینی تحلیل شده‌اند. شکل ۴ ماتریس‌های ابهام مدل پیش‌بینی را برای چهار گام زمانی $t+3$ ، $t+6$ ، $t+9$ و $t+12$ نمایش می‌دهد.



شکل ۵. مقادیر دقت کلی، ضریب کاپا و امتیاز F1 در مورد ۳، ۶، ۹ و ۱۲ ساعت آینده پیش‌بینی طوفان گردوغبار

تأیید می‌کنند. در پژوهشی، از مدل CNN به‌منظور پیش‌بینی رخداد طوفان گردوغبار استفاده شده که دقت کلی ۰/۸۸۳ به‌دست آمده است (Tiancheng et al., 2019). از دیگر سو، انتخاب یک پیکسل به‌منزله گردوغبار به‌صورت بصری و باینری در تصاویر ماهواره‌ای، ممکن است در بردارنده عدم قطعیت باشد؛ از این رو به‌کارگیری حدود آستانه‌ای برای AOD، متناسب با منطقه مطالعاتی و اتخاذ سازوکاری برای مدیریت عدم قطعیت می‌تواند در برچسب‌زدن دقیق‌تر تصاویر، کارساز باشد (Kolmonen et al., 2013; Sharif et al., 2019).

۴- نتیجه‌گیری

طوفان‌های گردوغبار پدیده‌های پویایی‌اند که علاوه بر ابعاد و محدوده تحت پوشش، مسیر حرکت آنها نیز دارای اهمیت است. در این پژوهش، به پیش‌بینی ساعتی مسیر حرکت طوفان‌های گردوغبار، با استفاده از روش یادگیری عمیق پرداخته شد. داده خام AOD MERRA-2 در گام زمانی t و تصویر برچسب‌خورده طوفان در دوازده گام زمانی بعدی به‌کار رفت و یک معماری ترکیبی CNN برای پیش‌بینی مسیر حرکت طوفان تا دوازده ساعت پیش رو توسعه یافت. نتایج نشان داد که مدل پیشنهادی، با دقت کلی ۹۸ درصدی، عملکرد خوبی در پیش‌بینی دوازده‌ساعته مسیر حرکت طوفان‌های منطقه مورد مطالعه داشته است. مدل برای طوفان‌هایی با ویژگی‌های محیطی مشابه (مانند پوشش زمین و شرایط اقلیمی) عملکرد مطلوبی دارد اما، با ترکیب طوفان‌های مناطق دیگر با روندهای غیرمشابه در مجموعه داده، دقت پیش‌بینی کاهش می‌یابد. از جمله موارد تأثیرگذار در حرکت طوفان، اطلاعات زمینه‌ای است. پیشنهاد می‌شود در پژوهش‌های آتی، اطلاعات زمینه‌ای محیطی همچون سرعت باد، جهت باد، دما و رطوبت در پیش‌بینی مسیر حرکت طوفان به‌کار رود و تأثیرات این عوامل در حرکت طوفان‌ها بررسی شود. افزون‌براین با توسعه مدل‌های ترکیبی، می‌توان از مزایای روش‌های دیگر یادگیری عمیق، مانند حافظه بلندمدت، در کنار مزایای CNN در موضوع پیش‌بینی بلندمدت‌تر، بهره‌مند شد.

دقت کلی، ضریب کاپا و امتیاز F1 درمورد تمامی ساعات پیش‌بینی‌شده، مقدار قابل قبولی دارند. هرچه این مقادیر به ۱ نزدیک‌تر باشد، یعنی عملکرد مدل مطلوب بوده است. دقت کلی بیانگر درصد پیکسل‌هایی است که به‌درستی پیش‌بینی شده‌اند. درمورد گام‌های زمانی $t+3$ ، $t+6$ ، $t+9$ و $t+12$ ، دقت کلی به‌ترتیب برابر با ۰/۹۸۰۶، ۰/۹۸۱۰، ۰/۹۸۱۳ و ۰/۹۷۹۰ محاسبه شده است. امتیاز F1 میانگین هارمونیک دقت و حساسیت را نشان می‌دهد. دقت این نکته را بیان می‌کند که از بین تمامی پیش‌بینی‌های مثبت، چند مورد واقعاً مثبت‌اند و حساسیت بیانگر آن است که از بین همه موارد مثبت واقعی، چند مورد مثبت پیش‌بینی شده؛ بنابراین میانگین هارمونیک این دو معیار می‌تواند معیار مناسبی برای سنجش مدل باشد. درمورد گام‌های زمانی $t+3$ ، $t+6$ ، $t+9$ و $t+12$ به‌ترتیب برابر با ۰/۸۴۹۰، ۰/۸۵۲۴، ۰/۸۵۳۰ و ۰/۸۳۸۴ محاسبه شده است. معیار ضریب کاپا نیز میزان توافق بین داده‌های واقعی و داده‌های پیش‌بینی‌شده را نمایش می‌دهد. درمورد گام‌های زمانی $t+3$ ، $t+6$ ، $t+9$ و $t+12$ مقادیر ضریب کاپا به‌ترتیب ۰/۸۳۸۷، ۰/۸۴۲۴، ۰/۸۴۳۱ و ۰/۸۲۷۳ به‌دست آمده است. همان‌طور که مشاهده می‌شود، دقت پیش‌بینی گام $t+12$ با توجه به هر سه معیار، اندکی کاهش یافته است.

از نقاط قوت مدل پیشنهادی، پیش‌بینی ساعتی طوفان و استخراج مسیر حرکت با دقت کلی حدوداً ۰/۹۸ درمورد دوازده ساعت آینده است. این مدل برای طوفان‌هایی که روند مشابهی را طی کرده‌اند بسیار موفق عمل می‌کند اما، با ترکیب طوفان‌های مناطق دیگر با ویژگی‌های متفاوت در مجموعه داده، دقت پیش‌بینی کاهش یافت. همچنین افزایش ساعت پیش‌بینی موجب افزایش پارامترهای مدل و پیچیدگی آن می‌شود. در این پژوهش، به‌رغم اینکه فقط از یک گام زمانی قبل برای پیش‌بینی استفاده شده، پیش‌بینی دوازده ساعت آینده طوفان دقت مورد قبولی دارد. نتایج این پژوهش کارآمدی روش CNN را در مطالعه طوفان‌های گردوغبار،

۵- منابع

- Aili, A., Xu, H., Kasim, T. & Abulikemu, A., 2021, **Origin and Transport Pathway of Dust Storm and Its Contribution to Particulate Air Pollution in Northeast Edge of Taklimakan Desert, China**, *Atmosphere*, 12, P. 113.
- Al-Yahyai, S. & Charabi, Y., 2014, **Trajectory Calculation as Forecasting Support Tool for Dust Storms**, *Advances in Meteorology*, 2014.
- Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M.A., Al-Amidie, M. & Farhan, L., 2021, **Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions**, *Journal of Big Data*, 8.
- Ansari Ghojghar, M., Pourgholam-Amiji, M., Bazrafshan, J., Liaghat, A. & Araghinejad, S., 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), PP. 2051-2063.
- Boloorani, A.D., Shorabeh, S.N., Neysani Samany, N., Mousivand, A., Kazemi, Y., Jaafarzadeh, N., Zahedi, A. & Rabiei, J., 2021, **Vulnerability Mapping and Risk Analysis of Sand and Dust Storms in Ahvaz, IRAN**, *Environmental Pollution*, 279, P. 116859.
- Boroumand, F., Alesheikh, A.A., Sharif, M. & Farnaghi, M., 2022, **FLCSS: A Fuzzy-Based Longest Common Subsequence Method for Uncertainty Management in Trajectory Similarity Measures**, *Transactions in GIS*, 26, PP. 2244-2262.
- Burge, J., Bonanni, M., Ihme, M. & Hu, L., 2020, **Convolutional LSTM Neural Networks for Modeling Wildland Fire Dynamics**, *arXiv preprint arXiv:2012.06679*.
- Chollet, F., 2021, **Deep Learning with Python**, Simon and Schuster.
- Giovanni, 2022, **The Bridge Between Data and Science**. <https://giovanni.gsfc.nasa.gov/giovanni/>.
- Goudarzi, S., Sharif, M. & Karimipour, F., 2022, **A Context-Aware Dimension Reduction Framework for Trajectory and Health Signal Analyses**, *J. Ambient Intell. Humaniz. Comput.*, 13, PP. 2621-2635.
- Goudie, A.S. & Middleton, N.J., 2006, **Desert Dust in the Global System**, Springer Science & Business Media.
- Guan, Q., Yang, Y., Luo, H., Zhao, R., Pan, N., Lin, J. & Yang, L., 2019, **Transport Pathways of PM10 During the Spring in Northwest China and Its Characteristics of Potential Dust Sources**, *Journal of Cleaner Production*, 237(10), P. 117746.
- Jiao, Z., Jia, G. & Cai, Y., 2019, **A New Approach to Oil Spill Detection that Combines Deep Learning with Unmanned Aerial Vehicles**, *Comput. Ind. Eng.*, 135, PP. 1300-1311.
- Kattenborn, T., Leitloff, J., Schiefer, F. & Hinz, S., 2021, **Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing**, *ISPRS Journal of Photogrammetry and Remote Sensing*.
- Kolmonen, P., Sundström, A.M., Sogacheva, L., Rodriguez, E., Virtanen, T. & de Leeuw, G., 2013, **Uncertainty Characterization of AOD for the AATSR Dual and Single View Retrieval Algorithms**, *Atmos. Meas. Tech. Discuss.*, 6, PP. 4039-4075.
- Krizhevsky, A., Sutskever, I. & Hinton, G.E., 2012, **ImageNet Classification with Deep Convolutional Neural Networks**, *Communications of the ACM*, 60, PP. 84-90.
- LeCun, Y., Boser, B.E., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W.E. & Jackel, L.D., 1989, **Backpropagation Applied to Handwritten Zip Code Recognition**, *Neural Computation*, 1, PP. 541-551.
- Liu, S., Wang, T. & Mouat, D., 2013, **Temporal and Spatial Characteristics of Dust Storms in the Xilingol Grassland, Northern China, During 1954–2007**, *Regional Environmental Change*, 13(1), PP. 43-52.
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F. & Zhang, Y., 2018, **Very Deep Convolutional Neural Networks for Complex Land Cover Mapping Using**

- Multispectral Remote Sensing Imagery**, Remote. Sens., 10, P. 1119.
- Mobarak Hassan, E., Saadatabadi, A. & Fattahi, E., 2020, **Dust Investigation by MERRA-2 Model in Iran: (during 2007- 2017)**, Iranian Journal of Soil and Water Research, 51(9), PP. 2203-2219.
- Mohammadpour, K., Rashki, A., Sciortino, M., Kaskaoutis, D.G. & Boloorani, A.D., 2022, **A Statistical Approach for Identification of Dust-AOD Hotspots Climatology and Clustering of Dust Regimes over Southwest Asia and the Arabian Sea**, Atmospheric Pollution Research, 13(4), P. 101395.
- Perumal, R. & van Zyl, T.L., 2020, **Comparison of Recurrent Neural Network Architectures for Wildfire Spread Modelling**, 2020 International SAUPEC/ RobMech/PRASA Conference.
- Rashki, A., Middleton, N. & Goudie, A.S., 2021, **Dust Storms in Iran – Distribution, Causes, Frequencies and Impacts**, Aeolian Research, 48, P. 100655.
- Safriel, U., Adeel, Z., Niemeijer, D., Puigdefabregas, J., White, R., Lal, R., Winslow, M., Ziedler, J., Prince, S. & Archer, E., 2005, **Dryland Systems**, In Ecosystems and Human Well-being: Current State and Trends.: Findings of the Condition and Trends Working Group (PP. 623-662), Island Press.
- Sharif, M., Alesheikh, A.A. & Tashayo, B., 2019, **CaFIRST: A Context-Aware Hybrid Fuzzy Inference System for the Similarity Measure of Multivariate Trajectories**, Journal of Intelligent & Fuzzy Systems, 36(6), PP. 5383-5395.
- Stein, A.F., Draxler, R.R., Rolph, G., Stunder, B., Cohen, M.D. & Ngan, F., 2015, **NOAA's HYSPLIT Atmospheric Transport and Dispersion Modeling System**, Bulletin of the American Meteorological Society, 96, PP. 2059-2077.
- Tiancheng, L., Qing-dao-er-ji, R. & Ying, Q., 2019, **Application of Improved Naive Bayesian-CNN Classification Algorithm in Sandstorm Prediction in Inner Mongolia**, Advances in Meteorology, 2019.
- Wang, R., Zhu, Z., Zhu, W.-h., Fu, X. & Xing, S., 2021, **A Dynamic Marine Oil Spill Prediction Model Based on Deep Learning**, Journal of Coastal Research, 37, PP. 716-725.
- Yousefi, R., Wang, F., Ge, Q.-s. & Shaheen, A., 2020, **Long-Term Aerosol Optical Depth Trend over Iran and Identification of Dominant Aerosol Types**, The Science of the Total Environment, 722, P. 137906.



نخستین از دور

و

ایران GIS



سنجش از دور و GIS ایران
سال پانزدهم، شماره اول، بهار ۱۴۰۲
Vol.15, No. 1, Spring 2023 Iranian Remote Sensing & GIS

129-139

A Convolutional Neural Network Model for Predicting the Transport Pathway of Dust Storms

Yarmohamadi M.¹, Alesheikh A.A.², Sharif M.^{3*}

1. M.Sc. Student, Dep. of Geospatial Information Systems, K. N. Toosi University of Technology, Tehran
2. Professor, Dep. of Geospatial Information Systems, K. N. Toosi University of Technology, Tehran
3. Assistant Prof., Dep. of Geography, University of Hormozgan, Bandar Abbas

Abstract

Dust storms are natural disasters that have severely affected human life and the environment. The majority of research in dust storm has been dedicated to the forecasting of storm-prone areas. However, developing models to predict the movement of these storms plays a significant role in the prevention and management of dust storms, because they reveal the transport pathway and identify the next vulnerable areas against the storm. In this research, a hybrid convolutional neural network (CNN) model has been developed to predict the path of dust storms based on airborne optical depth (AOD) data of MERRA-2 product for the next 12 hours. 40 storm events including 2489 storm hours in a dry region in Central and South Asia have been used for training the model. The results show that the proposed model provides an accurate prediction of the storm's path, so that for the time steps of 3, 6, 9, and 12 hours, the overall accuracy values are 0.9806, 0.9810, 0.9813, and 0.9790, respectively, the F1 score values are 0.8490, 0.8524, 0.8530, and 0.8384, respectively, and the Kappa coefficient values are 0.8387, 0.8424, 0.8431, and 0.8273, respectively.

Keywords: Deep learning, Movement prediction, Moving process, Dust storms, MERRA-2.

* Correspondence Address: Hormozgan, Bandar Abbas, 9th km of Minab Road, University of Hormozgan, Postal Code:7916193145. Tel: +987633711000
Email: m.sharif@hormozgan.ac.ir