



# سنجش از دور

و

## GIS ایران



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

۱۲۹-۱۳۹

مقاله پژوهشی

### یک مدل شبکه عصبی پیچشی برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار

مهدیس یارمحمدی<sup>۱</sup>، علی‌اصغر آل‌شیخ<sup>۲\*</sup>، محمد شریف<sup>۳</sup>

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 بلایابی 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 مبتنی بر 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 هوایز (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 درمورد گام‌های زمانی ۳، ۶، ۹ و ۱۲ ساعت آینده، مقادیر دقت کلی بهترتیب برابر با ۰/۹۸۰۶، ۰/۹۸۱۰، ۰/۹۸۱۳ و ۰/۹۷۹۰ است. مقادیر امتیاز F1 بهترتیب برابر با ۰/۸۴۹۰، ۰/۸۵۲۴، ۰/۸۵۳۰ و ۰/۸۳۸۴ و مقادیر ضریب کاپا بهترتیب برابر با ۰/۸۴۲۴، ۰/۸۳۸۷، ۰/۸۴۳۱ و ۰/۸۴۷۳ است.

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

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

Email: m.sharif@hormozgan.ac.ir

## ۱- مقدمه

استفاده از سنجش دور ماهواره‌ای و مشاهدات زمین مبنا اندازه‌گیری کرد. مجموعه داده مادیس<sup>۱</sup> اطلاعات AOD ماهواره‌ای را به صورت روزانه، با قدرت تفکیک مکانی بالا و با پوشش جهانی، در اختیار قرار می‌دهد. مجموعه داده AERONET<sup>۲</sup> که ناسا آن را به منزله مجموعه داده AOD زمین مبنا معرفی کرده، موجب پیشرفت‌های شایان توجهی در زمینه شناخت Mobarak Hassan (et al., 2020) در پژوهش‌های پیشین داشته‌اند (Yousefi et al., 2020) اما قدرت تفکیک زمانی اندک و یک‌روزه دارند. مجموعه داده MERRA-2<sup>۳</sup> (Giovanni, 2022) که در این پژوهش به کار رفته است، با همانندسازی مجموعه‌ای از داده‌های AOD ماهواره‌ای و زمین مبنا تولید شده و دارای قدرت تفکیک زمانی یک‌ساعتی 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 (Boroumand et al., 2022; Goudarzi et al., 2022) 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، Al-Yahyai و Charabi<sup>۴</sup> (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

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 Goudie & Middleton, 2006» تعریف می‌شود (Liu et al., 2013). مناطق خشک 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 فرونشتی 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 تخریب شده 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 اکوسيستم تأثیر می‌گذارند (Rashki et al., 2021). تأثیرات طوفان‌های گردوغبار در سراسر جهان رو به افزایش است اما پنج منطقه آسیای مرکزی، شمال افریقا، خاورمیانه، امریکای شمالی و استرالیا تحت تأثیر شدیدترین طوفان‌ها قرار دارند (Liu et al., 2013)؛ از این‌رو 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 سنجش از دور و تولید تصاویر ماهواره‌ای با قدرت تفکیک‌های مکانی و زمانی متفاوت، فراهم شده است. عمق نوری هوایی<sup>۵</sup> AOD<sup>۶</sup> پارامتری است که ویژگی‌های نوری ذرات گردوغبار را منعکس می‌کند و اغلب در مطالعات رویدادهای گردوغبار استفاده می‌شود (Mohammadpour et al., 2022).

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

در پژوهش‌های پیشین، پدیده طوفان گردوغبار اغلب به صورت نقطه‌ای در نظر گرفته شده و پیش‌بینی کوتاه‌مدت درمورد 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 MERRA- استفاده از داده‌های ساعتی AOD محصول ۲، به‌منظور 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 دقیق پیش‌بینی محاسبه می‌شود.

## ۲- مواد و روش‌ها

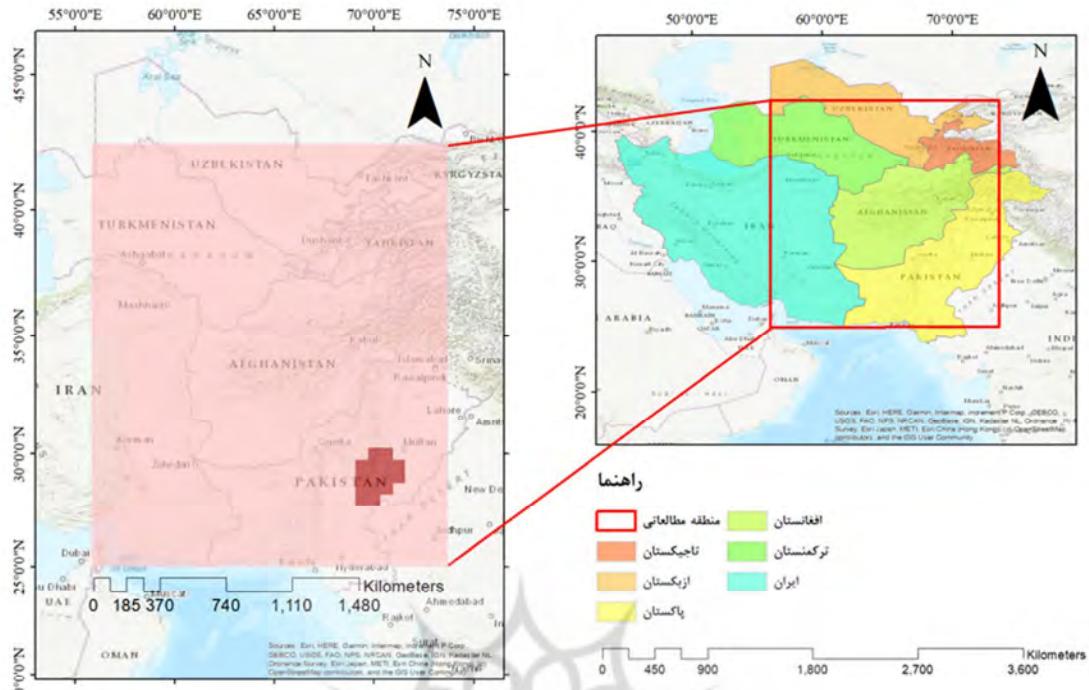
### ۱- منطقه مطالعاتی

منطقه مورد مطالعه شامل مناطقی خشک از آسیا 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 به‌وقوع 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)<sup>۱</sup>، مسیر حرکت طوفان‌های گردوغبار را پیش‌بینی کردند. همچنین در پژوهش‌های بسیاری، برای شناسایی منابع گردوغبار و مدل‌سازی خط‌سیرهای آنها، از مدل ریاضی HYSPLIT<sup>۲</sup> استفاده شده است (Stein et al., 2015). اساس مازول HYSPLIT، الگوریتم انتشار طوفان گردوغبار PM<sub>۱۰</sub> برای زمین‌های بیابانی است. این مدل به داده‌های هواشناسی هم نیاز دارد و دقت آن با توجه به دقت Aili et al., 2021; Guan et al., 2019; Stein et al., 2015 داده‌های هواشناسی تعیین می‌شود.

از سوی دیگر، روش‌های یادگیری عمیق که زیرمجموعه‌ای از روش‌های یادگیری ماشین هستند، به منزله ابزاری کارآمد در پیش‌بینی فرایندهای حرکتی به کار رفته‌اند. از ترکیب مدل‌های شبکه عصبی پیچشی (CNN)<sup>۳</sup> و حافظه طولانی کوتاه‌مدت (LSTM)<sup>۴</sup> (Burge et al., 2020) و مدل‌های واحد بازگشتی Perumal & van Zyl (GRU)<sup>۵</sup> (2020) برای مدل‌سازی گسترش آتش‌سوزی استفاده شده و مدل‌های شبکه‌های عصبی بازگشتی (RNN) (Jiao et al., 2019; Wang et al., 2021) 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. ازان‌جاکه 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 به کاررفته در این

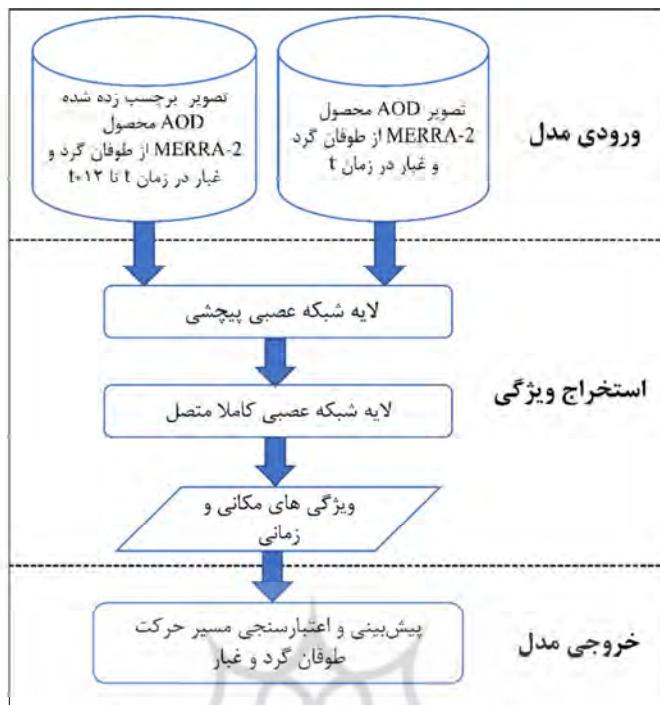


شکل ۱. منطقه مطالعاتی با رنگ صورتی و نمونه‌ای از یک طوفان که از پاکستان آغاز شده، با رنگ قرمز مشخص شده است

**۲-۳- مدل پیش‌بینی مسیر حرکت طوفان گردوغبار**  
رونند 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 آنجاکه با یک مسئله سری زمانی مواجهیم، دو نوع داده به کار رفته است. تصاویر AOD مربوط به هر ساعت از طوفان با ابعاد  $140 \times 140$  پیکسل، بهمنزله ورودی و تصاویر صفر و یکی برچسب خورده 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

**۲-۲- داده‌های پژوهش**  
در این پژوهش، برای پیش‌بینی مسیر حرکت طوفان‌های گردوغبار از مجموعه داده MERRA-2، محصول  $\text{AOD}_{\text{MERRA-2}}$  که به صورت ساعتی و با قدرت تفکیک مکانی  $0.5 \times 0.5^{\circ}$  درجه منتشر می‌شوند و در طول موج  $550 \text{ nm}$  دریافت شده‌اند، استفاده می‌شود. این داده‌ها از سال ۱۹۸۰ تا کنون در دسترس قرار دارند (Giovanni, 2022). جدیدترین داده‌های MERRA-2 از مدل جویی SAMANNE مشاهده زمین گودارد (GEOS)<sup>۱</sup> ایجاد شده‌اند که یک تکنیک شبیه‌سازی داده و تحلیل درون‌یابی آماری Gridpoint است و این داده‌ها غالباً غلظت گردوغبار را در هر پیکسل نشان می‌دهند. MERRA-2 نخستین مجموعه داده تحلیل مجدد ماهواره‌ای است که با همانندسازی MISR<sup>۲</sup>، AVHRR<sup>۳</sup>، AERONET 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.



شکل ۲. روند نمای کلی از فرایند پیش‌بینی مسیر حرکت طوفان گرد و غبار

لایه‌ها قرار گرفته‌اند (Kattenborn et al., 2021) و از مجموعه‌ای از شبکه‌های عصبی به هم‌پیوستهٔ چندلایه تشکیل شده‌اند؛ از این‌رو قادرند ویژگی‌های سطح بالا، متوسط و پایین را به صورت سلسه‌مراتبی 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 اندازهٔ کرنل و تعداد فیلترها مشخص شود. این پارامترها باید به گونه‌ای انتخاب شوند که ویژگی‌های استخراج شده، برای مشکل موجود، تعیین‌کننده باشند (Kattenborn et al., 2021).

معماری CNN از دو لایهٔ اصلی تشکیل شده است؛ لایهٔ کانولوشن و لایهٔ ادغام<sup>۳</sup> (Chollet, 2017). لایه‌های کانولوشن ویژگی‌ها را استخراج می‌کنند، لایه‌های اولیه

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

شکل ۳ ساختار یک مدل ترکیبی یادگیری عمیق را نشان می‌دهد. این مدل دارای پانزده لایهٔ متفاوت، شامل دوازده لایهٔ CNN، دو لایهٔ کاملاً متصل و یک لایهٔ مسطح‌کننده<sup>۱</sup> 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 نشان‌دادن آثار غیرخطی را در مورد ارتباط ورودی و خروجی‌های هر سیستمی دارد (Ansari ghojghar et al., 2020). مدل CNN را که نوعی شبکه عصبی مصنوعی است، اولین بار لکان<sup>۲</sup> و همکاران (۱۹۸۹) معرفی کردند و کریزفسکی<sup>۳</sup> 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). همانند دیگر شبکه‌های عصبی معمول، مبتنی بر نورون‌هایی‌اند که در

CNN به پارامترهایی از جمله تعداد و ویژگی‌های لایه‌های پنهان، عملیات ادغام، تکنیک‌های تنظیم<sup>۱</sup> و توابع هزینه نیز بازمی‌گردد. نرمال‌سازی دسته‌ای<sup>۲</sup> برای نرمال‌سازی ویژگی‌های استخراج شده پس از آخرین لایه پیچشی استفاده شده است. ویژگی‌های نرمال‌شده وارد بلوک آخر با دو لایه کاملاً متصل، شامل ۶۴ و ۲۸۰۲۸۰ نورون شده‌اند. به‌جز لایه 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 به صورت تصادفی وزن‌دهی می‌شوند. سپس تفاوت بین مقادیر پیش‌بینی شده، از طریق مدل و مقادیر برچسب‌خورده، محاسبه می‌شود و با استفاده از یک الگوریتم پسانشار<sup>۳</sup>، وزن‌ها پالایش می‌شوند. تابع BCE<sup>۴</sup> به‌منزله تابع ضرر استفاده شده است. این تابع در رابطه (۱) آمده و در آن  $y$  برچسب،  $p(y)$  احتمال پیش‌بینی شده و  $N$  تعداد نمونه‌هاست.

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

#### ۴-۲- ارزیابی

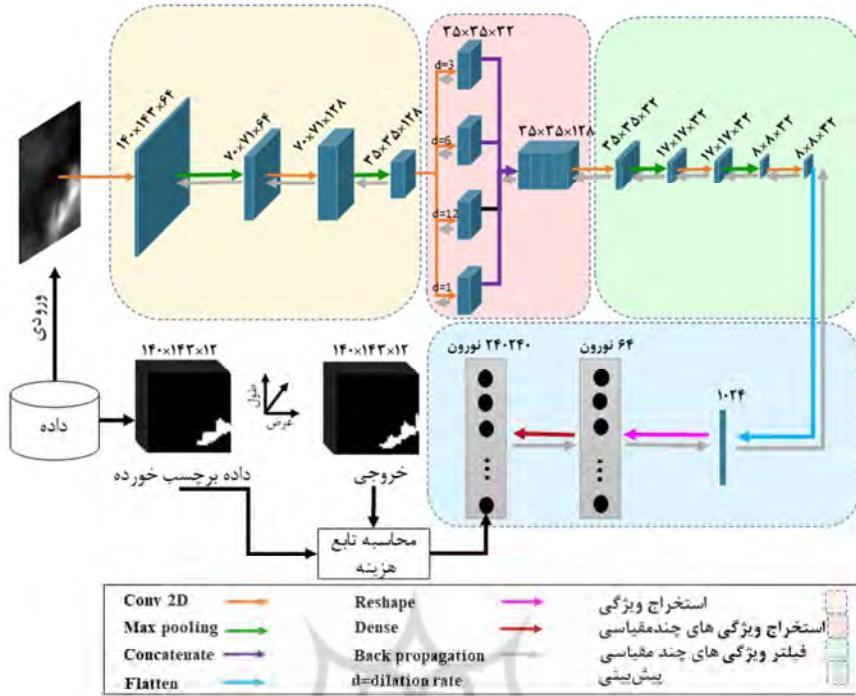
سه معیار دقت کلی، ضریب کاپا و امتیاز F1 برای ارزیابی عملکرد مدل یادگیری عمیق استفاده شده‌اند. این معیارها با استفاده از ماتریس ابهام به‌دست می‌آینند. دقت کلی نشان‌دهنده مقدار ناحیه‌ای از تصویر است که درست پیش‌بینی شده است. این معیار طبق رابطه (۲) حاصل می‌شود.

$$Accuracy(\%) = \frac{TP+TN}{TP+FP+FN+TN} \times 100\% \quad (2)$$

- 
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). به‌این ترتیب نقشه‌های ویژگی با ضرب وزن هر کرنل در بخش کوچکی از تصویر ورودی به‌دست می‌آیند (Alzubaidi et al., 2021). هر نقشه ویژگی، به‌منزله ورودی، وارد لایه بعدی می‌شود. پس از هر لایه کانولوشن می‌توان یک لایه ادغام قرار داد. این لایه به کاهش پارامترهای شبکه منجر می‌شود که آموزش شبکه را تسريع و امکان رسیدگی به مشکل بیش‌برازش را فراهم می‌کند (Alzubaidi et al., 2021). ادغام با اندازه فیلتر، گام (فاصله بین عملیات ادغام متوالی) و نوع عملیات ادغام max-pooling می‌شود. معمول‌ترین عملیات ادغام در حالی که سلول‌های خروجی حداکثر چهار سلول ورودی در فیلتر  $2 \times 2$  دارند. بلوک اول شامل دو لایه کانولوشن، به‌ترتیب با  $4 \times 4$  و  $2 \times 2$  فیلتر است که پس از هر لایه کانولوشن، یک لایه max-pooling با فیلتر  $2 \times 2$  قرار گرفته است. ویژگی‌های چندمقیاسی با عبور خروجی بلوک اول از چهار لایه پیچشی با  $3 \times 3$  dilation rate  $1, 2, 3, 6$  و  $1$  شامل  $3 \times 3$  فیلتر با اندازه  $3 \times 3$  در هر لایه، به‌دست آمدند. در بلوک سوم، یک لایه پیچشی با  $1 \times 1$  فیلتر برای اعمال روی ویژگی‌های متصل شده<sup>۵</sup> به‌کار رفته است. سپس از دو لایه پیچشی با  $3 \times 3$  فیلتر، برای فیلتر ویژگی‌های چندمقیاسی استفاده شده است. پس از هر لایه پیچشی، یک لایه max-pooling با فیلتر  $2 \times 2$  قرار گرفته است.

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



شکل ۳. ساختار مدل CNN

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

$$F1(\%) = \left( 2 \times \frac{Precision \times Recall}{Precision + Recall} \right) \times 100\% \quad \text{رابطه (۴)}$$

precision و recall نیز، به ترتیب براساس روابط (۵) و (۶) محاسبه می‌شوند.

$$\text{رابطه (۵)}$$

$$Precision(\%) = \left( \frac{TP}{TP+FP} \right) \times 100\% \quad \text{رابطه (۶)}$$

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

### ۳- نتایج و بحث

در پژوهش حاضر، داده‌ها به ۲۲۷ نمونه آموزشی و ۲۴۸ نمونه اعتبارسنجی تقسیم شده‌اند. به این دلیل که با مسئله سری زمانی مواجهیم، داده‌ها به دو بخش

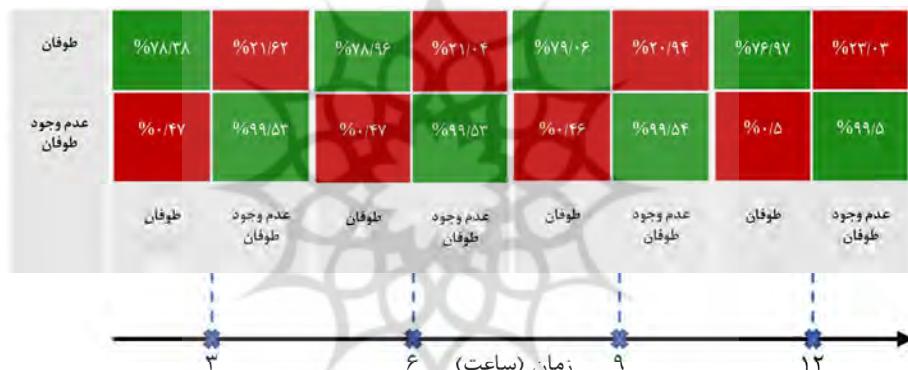
در این معادله، مثبت صحیح (TP) نتایج مثبتی‌اند که بهدرسی پیش‌بینی شده‌اند و منفی صحیح (TN) نتایجی منفی‌اند که مدل بهدرسی آنها را پیش‌بینی کرده است. مثبت کاذب (FP) نتایج مثبتی است که مدل به اشتباه پیش‌بینی کرده و با عنوان خطای نوع اول هم شناخته می‌شوند. منفی کاذب (FN) نیز نتایجی منفی است که مدل به اشتباه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

$$k = \frac{\rho_0 - \rho_e}{1 - \rho_e} \quad \text{رابطه (۳)}$$

مقدار  $\rho_0$  توافق نسبی دو ارزیاب و مقدار  $\rho_e$  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 recall و precision را اندازه‌گیری می‌کند.

همان طور که مشاهده می شود، درصد بالایی از پیکسل ها در المان های مورب ماتریس ابهام قرار دارند. این بدان معنی است که درصد بالایی از پیکسل های حاوی طوفان و پیکسل های عاری از طوفان، طی دوازده ساعت، به درستی پیش بینی شده اند. دلیل دستیابی به این کارآیی می تواند ویژگی های چند مقیاسی استخراج شده از طریق مدل باشد. از آن جا که طیف گسترده ای از اندازه طوفان در داده ها وجود دارد، این مدل می تواند ویژگی های مرتبط را استخراج و از افزونگی ویژگی خودداری کند. شکل ۵ عملکرد مدل در پیش بینی دوازده ساعت طوفان را با استفاده از سه معیار ارزیابی دقت کلی، ضریب کاپا و امتیاز F1 نشان می دهد.

وروودی و خروجی تقسیم شده اند. داده ورودی شامل داده خام AOD در گام زمانی  $t$  و داده خروجی شامل تصویر بر چسب خورده در دوازده گام زمانی بعدی است. اندازه دسته ۴ در نظر گرفته شده و بهینه ساز Adam با نرخ یادگیری  $0.0005$  و تعداد  $150$  تکرار در حین آموزش به کار رفته است. پیش بینی مسیر حرکت طوفان گردوغبار با استفاده ازتابع 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 پیش بینی مسیر حرکت طوفان، طی دوازده ساعت آتی، از نظر دقت پیش بینی تحلیل شده اند. شکل ۴ ماتریس های ابهام مدل پیش بینی را برای چهار گام زمانی  $t+3$ ,  $t+6$ ,  $t+9$  و  $t+12$  نمایش می دهد.



شکل ۴. ماتریس های ابهام مدل پیش بینی طوفان گردوغبار در موردها ۳، ۶، ۹ و ۱۲ ساعت آینده



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

تأثید می‌کنند. در پژوهشی، از مدل CNN بهمنظور پیش‌بینی رخداد طوفان گردوغبار استفاده شده که دقต کلی  $0.883^+$  به دست آمده است (Tiancheng et al., 2019). از دیگرسو، انتخاب یک پیکسل بهمنزله گردوغبار به صورت بصری و باینری در تصاویر ماهواره‌ای، ممکن است در بردارنده عدم قطعیت باشد؛ از این‌رو به کارگیری 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 علاوه‌بر 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 در گام MERRA-2 در زمانی  $t+6$  و تصویر برچسب‌خورده طوفان در دوازده گام زمانی بعدی به کار 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 دقیقی کلی  $0.98$  درصدی، عملکرد خوبی در پیش‌بینی دوازده ساعتی 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، دقیقی 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 به کار رود و تأثیرات این عوامل در حرکت طوفان‌ها بررسی شود. افزون‌برایان 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 در مورد تمامی ساعت پیش‌بینی شده، مقدار قابل قبولی دارند. هرچه این مقادیر به  $1$  نزدیک‌تر باشد، یعنی عملکرد مدل مطلوب بوده است. دقیقی کلی بیانگر درصد پیکسل‌هایی است که به درستی پیش‌بینی شده‌اند. در مورد گام‌هایی زمانی  $t+3$ ،  $t+6$  و  $t+9$ ، دقیقی به ترتیب برابر با  $0.9810^+$ ،  $0.9813^+$  و  $0.9790^+$  محاسبه شده است. امتیاز F1 میانگین هارمونیک دقیقی و حساسیت را نشان می‌دهد. دقیقی 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. در مورد گام‌هایی زمانی  $t+3$ ،  $t+6$  و  $t+9$  مقادیر امتیاز F1 به ترتیب برابر با  $0.8490^+$ ،  $0.8524^+$  و  $0.8530^+$  و  $0.8384^+$  محاسبه شده است. معیار ضریب کاپا نیز میزان توافق بین داده‌های واقعی و داده‌های پیش‌بینی شده را نمایش می‌دهد. در مورد گام‌هایی زمانی  $t+3$ ،  $t+6$  و  $t+9$  مقادیر ضریب کاپا به ترتیب  $F1 = 0.8431^+$ ،  $0.8424^+$  و  $0.8431^+$  و  $0.8273^+$  به دست آمده است. همان‌طور که مشاهده می‌شود، دقیقی 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 دقیقی کلی حدوداً  $0.98$  در مورد 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، دقیقی پیش‌بینی کاهش یافت. همچنین افزایش ساعت پیش‌بینی موجب افزایش پارامترهای مدل و پیچیدگی آن می‌شود. در این پژوهش، به رغم اینکه فقط از یک گام زمانی قبل برای پیش‌بینی استفاده شده، پیش‌بینی دوازده ساعت آینده طوفان دقیقی مورد قبولی دارد. نتایج این پژوهش کارآمدی روش CNN را در مطالعه طوفان‌های گردوغبار،

-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., Aldujaili, 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, in Sandstorm Prediction in Inner Mongolia, Advances in Meteorology, 2019.**
- Remote. Sens., 10, P. 1119.
- 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.**
- 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**



# سنجش از دور

## ، ایران GIS



سنجش از دور و GIS ایران  
Vol.15, No. 1, Spring 2023

129-139

Iranian Remote Sensing & GIS

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

Yarmohamadi M.<sup>1</sup>, Alesheikh A.A.<sup>2</sup>, Sharif M.<sup>3\*</sup>

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