

بررسی مقایسه عملکرد مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن به منظور مدل‌سازی طوفان‌های گردوغبار (مطالعه موردی: استان کرمانشاه)

محمد انصاری قوجقار^۱

تاریخ دریافت: ۱۴۰۳/۱۰/۲۰

تاریخ پذیرش: ۱۴۰۴/۰۲/۰۷

چکیده

شناخت عوامل مؤثر بر وقوع طوفان‌های گردوغبار و آگاهی از زمان و مکان وقوع این طوفان‌ها، نقش بسزایی در مدیریت و کاهش خسارات ناشی از آن‌ها دارد؛ اما اغلب، محدودیت‌هایی مانند کمبود منابع، هزینه‌های زیاد و صرف زمان زیاد پایش و بررسی مانع از مدیریت صحیح می‌شود. لذا استفاده از مدل‌های یادگیری عمیق، الگوریتم‌های هوش مصنوعی و شبکه‌های عصبی، گام مهمی در راستای پیش‌بینی و مدیریت یکپارچه این پدیده اقلیمی مخرب به شمار می‌رود. بدین ترتیب، این پژوهش به بررسی نتایج مدل‌سازی طوفان‌های گردوغبار با استفاده از مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن در نه ایستگاه هواشناسی سینوپتیک استان کرمانشاه شامل قصر شیرین، گیلان غرب، سرپل ذهاب، اسلام‌آباد غرب، جوانرود، سرارود، روانسر، هرسین و کنگاور، در طول دوره آماری ۴۰ ساله پرداخته است. در این راستا، دو مدل محاسباتی یادگیری عمیق و شبکه عصبی کانولوشن به منظور پیش‌بینی شاخص FDSD توسعه یافته و مورد مقایسه قرار گرفتند. نتایج حاکی از وجود تفاوت قابل ملاحظه‌ای در دقت روش‌های مورد بررسی بود. مدل DL با کمترین مقدار معیارهای خطای MAE و RMSE، عملکرد بهتری را نسبت به مدل CNN نشان داد؛ به‌طوری‌که ضرایب نش-ساتکیلِف و همبستگی آن به ترتیب از ۰/۹۳۹ و ۰/۹۲۸ تا ۰/۹۷۱ و ۰/۹۵۳ متغیر بود. هر دو مدل بهترین عملکرد خود را در گام‌های اول و دوم نشان دادند. ایستگاه قصر شیرین با بیشترین مقدار متوسط روزهای همراه با طوفان‌های گردوغبار، بیشترین دقت را نشان داد. نتایج این مطالعه می‌تواند نقش مهمی در زمینه مدل‌سازی طوفان‌های گردوغبار و اتخاذ تصمیم‌های مدیریتی لازم به منظور کاهش خسارات این پدیده داشته باشد.

کلیدواژه‌ها: پیش‌بینی، الگوریتم‌های فراکاوشی، طوفان‌های گردوغبار، DL، شاخص FDSD.

۱. استادیار، گروه مهندسی احیای مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران. Ansari.ghojghar@ut.ac.ir

مقدمه

گردوغبار به عنوان یکی از پدیده‌های رایج در اکوسیستم‌های بیابانی، یکی از چالش‌های جدی محیط‌زیستی محسوب می‌شود. این پدیده سالانه اثرات مخربی بر سلامت و معیشت ساکنان این مناطق به جا می‌گذارد و خسارت‌های قابل توجهی به بخش‌های مختلف اقتصادی، اجتماعی و زیست‌محیطی وارد می‌کند (نیر و همکاران، ۲۰۲۳) و زمانی رخ می‌دهد که سرعت باد در این اکوسیستم‌ها از حد آستانه فراتر رود و در نتیجه، ذرات شن و غبار از سطح خشک زمین جدا شده و به حرکت درمی‌آیند. در اکوسیستم‌های بیابانی، طوفان‌های شن و گردوغبار معمولاً به دلیل جریان‌های بادی ناشی از طوفان‌های تندری یا به واسطه گرادیان‌های شدید فشاری که باعث افزایش سرعت باد در محدوده‌های گسترده می‌شوند، شکل می‌گیرند. عوامل متعددی نظیر خشکی سطح زمین، شدت وزش باد، و شرایط سینوپتیکی در شکل‌گیری و گسترش این پدیده نقش دارند (خسروی و همکاران، ۲۰۲۰). طبق تعریف سازمان هواشناسی جهانی (لویی^۱ و همکاران، ۲۰۱۷)، طوفان‌های گردوغبار اغلب بر اثر وزش بادهای شدید و متلاطم رخ می‌دهند که موجب انتقال حجم قابل توجهی از ذرات گردوغبار از سطوح بیابانی به هوا می‌شوند. این پدیده با گسترش گردوغبار در مناطق وسیع، دید افقی را به کمتر از ۱۰۰۰ متر کاهش می‌دهد. به طور مشخص، هرگاه سرعت باد در یک ایستگاه از ۲۱ متر بر ثانیه فراتر رود و کاهش دید افقی ناشی از گردوغبار به زیر یک کیلومتر برسد، وقوع طوفان گردوغبار گزارش می‌شود (امیدوار، ۲۰۲۲). طوفان‌های گردوغبار به عنوان یکی از پدیده‌های جوی با اثرات گسترده زیست‌محیطی و بهداشتی، چالشی جدی در مدیریت منابع طبیعی و سلامت عمومی به شمار می‌روند (گودی و میدلتون، ۲۰۰۶). ایران به دلیل قرارگیری در کمربند بیابانی جهان و موقعیت جغرافیایی خود در مناطق خشک و نیمه‌خشک، همچنین هم‌جواری با منابع عمده گردوغبار مانند بیابان‌های عراق، عربستان و سوریه، با این چالش مواجه است (انصاری قوجقار و همکاران، ۲۰۲۱). افزون بر اثرات محلی، طوفان‌های گردوغبار با انتقال ذرات به

مقیاس‌های منطقه‌ای و جهانی، چرخه‌های محیط‌زیستی و اقلیمی را مختل می‌کنند. این ذرات با تأثیر بر تعادل تابشی میان سطح زمین و جو، نقش مهمی در تشدید گرمایش جهانی و تغییرات اقلیمی ایفا می‌کنند. پدیده گردوغبار در ایران پیامدهای گسترده‌ای دارد که شامل افزایش بیماری‌های ریوی، اختلال در فعالیت‌های روزمره، کاهش بهره‌وری اقتصادی و تخریب محیط‌زیست است. یکی از رویکردهای اساسی در مدیریت بحران‌های ناشی از گردوغبار، پیش‌بینی دقیق وقوع طوفان‌های گردوغبار است. از این رو، مدل‌سازی و پیش‌بینی دقیق آن‌ها می‌تواند نقش بسزایی در کاهش اثرات مخرب داشته باشد. مدل‌سازی این طوفان‌ها به مدیران و سیاست‌گذاران این امکان را می‌دهد که پیش از بروز بحران، اقداماتی همچون صدور هشدارهای بموقع، تخصیص منابع مناسب و اجرای اقدامات کاهش اثرات را به طور مؤثر انجام دهند. با توجه به پیچیدگی و عدم قطعیت‌های موجود در رخداد طوفان‌های گردوغبار، استفاده از روش‌های مدل‌سازی پیشرفته، ابزاری ضروری برای بهبود مدیریت و کاهش پیامدهای این پدیده است (بسال‌پور و همکاران، ۲۰۱۳). ارجمندی و همکاران (۲۰۲۴) به پیش‌بینی غلظت گردوغبار در مقیاس آزمایشگاهی با استفاده از فناوری‌های پردازش تصویر و هوش مصنوعی پرداختند. در مطالعه آنان مدل‌های مختلف شبکه عصبی مصنوعی پرسپترون چندلایه بررسی و مشخص شد که مدل با ساختار ۸-۱۰-۱ با تابع فعال‌سازی تنسیگ در لایه‌های پنهان و خروجی دارای بیشترین دقت (۸۱/۹۳ درصد) است. یافته‌های تحقیق حاضر قابلیت فناوری‌های پردازش تصویر و هوش مصنوعی در پیش‌بینی غلظت گردوغبار با دقت زیاد و هزینه کم را نشان می‌دهد. یارمحمدی و همکاران (۲۰۲۳) به پیش‌بینی مسیرهای انتقال طوفان‌های گردوغبار با استفاده از شبکه عصبی کانولوشن و زمینه جغرافیایی برای سازگاری و کاهش اثرات در مناطق شهری پرداختند. نتایج نشان داد که مدل شبکه عصبی کانولوشن توانایی بالایی در پیش‌بینی مسیر انتقال طوفان‌های گردوغبار دارد. سبحانی و همکاران (۲۰۲۰) به مدل‌سازی و پیش‌بینی گردوغبار در غرب ایران پرداختند. براساس نتایج خروجی مدل شبکه عصبی - مصنوعی RBF در پیش‌بینی گردوغبار برای

1. Lu

2. Goudie & Middleton

استخراج الگوهای پیچیده و غیرخطی، و دقت بالا در پیش‌بینی، یک تحول قابل توجه در علوم زیست‌محیطی محسوب می‌شود. این فناوری با تحلیل هم‌زمان داده‌های مکانی و زمانی، روابط پنهان میان عوامل مؤثر بر طوفان‌ها را کشف کرده و پیش‌بینی دقیق شدت، مسیر و گسترش این پدیده‌ها را ممکن می‌سازد. همچنین، یادگیری عمیق با قابلیت انطباق با داده‌های متنوع مانند تصاویر ماهواره‌ای و سنجش از دور، ابزار قدرتمندی برای مدل‌سازی و مدیریت ریسک‌های مرتبط با طوفان‌های گردوغبار فراهم می‌کند. مدل‌سازی طوفان‌های گردوغبار با استفاده از شبکه عصبی کانولوشن به دلیل توانایی برجسته در تحلیل داده‌های مکانی و تصویری، یک رویکرد پیشرفته و کارآمد محسوب می‌شود. این الگوریتم با معماری سلسله‌مراتبی خود قادر است ویژگی‌های کلیدی را در سطوح مختلف داده‌ها، از جزئی‌ترین الگوها تا ساختارهای پیچیده‌تر شناسایی کند. با استفاده از داده‌های ماهواره‌ای و نقشه‌های سنجش از دور، CNN می‌تواند توزیع مکانی طوفان‌ها، شدت و مسیر حرکت آن‌ها را با دقت بالایی پیش‌بینی کند. یکی از مزایای مهم این روش، کاهش نیاز به پیش‌پردازش دستی داده‌ها از طریق یادگیری خودکار ویژگی‌ها است که منجر به ساده‌تر شدن فرایند مدل‌سازی و افزایش سرعت و دقت آن می‌شود. توانایی شبکه عصبی کانولوشن در پردازش داده‌های حجیم و استخراج الگوهای غیرخطی، آن را به ابزاری مؤثر برای مدیریت ریسک و طراحی سیستم‌های هشدار طوفان‌های گردوغبار تبدیل کرده است.

مواد و روش‌ها

منطقه مورد مطالعه


در این پژوهش به مقایسه عملکرد مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن به منظور مدل‌سازی طوفان‌های گردوغبار در نه ایستگاه هواشناسی استان کرمانشاه (قصر شیرین، گیلان غرب، سرپل ذهاب، اسلام‌آباد غرب، جوانرود، سرارود، روانسر، هرسین و کنگاور)، در طول دوره آماری ۴۰ ساله (۱۹۸۱-۲۰۲۰) پرداخته شده است. بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی استفاده شده است. مشاهده‌های پدیده‌های

سال‌های آتی ایستگاه‌های مورد مطالعه، در هر دو مقیاس میانگین و حداکثر فراوانی گردوغبار، ایستگاه‌های غربی و جنوب غربی منطقه مورد پژوهش، بیشتر در معرض گردوغبار در سال‌های آینده قرار گرفتند. در دهه‌های اخیر، توسعه روش‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشن، فرصت‌های جدیدی را برای مدل‌سازی پدیده‌های پیچیده جوی فراهم کرده است. این روش‌ها با بهره‌گیری از قابلیت‌های پردازش داده‌های حجیم و شناسایی الگوهای نهفته در آن‌ها، به‌طور گسترده‌ای در مدل‌سازی پدیده‌های هواشناسی به کار گرفته شده‌اند (شی^۱ و همکاران، ۲۰۱۵). شبکه‌های عصبی کانولوشن، به دلیل ساختار خاص خود در استخراج ویژگی‌های مکانی و زمانی، ابزار مناسبی برای تحلیل داده‌های چندبعدی و پیچیده مانند داده‌های مربوط به طوفان‌های گردوغبار به شمار می‌روند (لوکن^۲ و همکاران، ۲۰۱۵؛ بولانژه^۳ و همکاران، ۲۰۲۱). از بررسی پژوهش‌های مختلف چنین برمی‌آید که برای مدل‌سازی دقیق شاخص فراوانی روزهای همراه با طوفان‌های گردوغبار که یکی از مهم‌ترین چالش‌های مدیریت محیط‌زیست محسوب می‌شود، روش‌های چندانی وجود نداشته و همین روش‌های اندک نیز با دارا بودن معایبی، از دقت بالایی برای پیش‌بینی شاخص FDSO برخوردار نیستند. ازسوی دیگر، بیشتر مطالعات به مدل‌سازی شاخص فراوانی طوفان‌های گردوغبار با استفاده از مدل‌های یادگیری ماشین پرداخته‌اند و از یادگیری عمیق کمتر مورد استفاده قرار گرفته است. شبکه عصبی کانولوشن اغلب به‌منظور پردازش تصویر و مدل‌سازی تصاویر استفاده شده، اما در پژوهش حاضر، از مدل CNN برای مدل‌سازی طوفان‌های گردوغبار استفاده شده و نتایج آن با مدل یادگیری عمیق تحت مقایسه قرار گرفته است. لذا در پژوهش حاضر، برای رفع چالش‌ها و کمبودهای موجود، به بررسی عملکرد مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن برای مدل‌سازی طوفان‌های گردوغبار پرداخته شده است. مدل‌سازی طوفان‌های گردوغبار با استفاده از یادگیری عمیق (DL) به دلیل توانایی پردازش داده‌های حجیم و چندبعدی،

1. Shi
2. LeCun
3. Boulanger

گردوغبار روزی است که در آن، حداقل در یکی از هشت سینوپ، یکی از کدهای مرتبط با گردوغبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰، ۳۱، ۳۲، ۳۳، ۳۴، ۳۵ و ۹۸) در بخش گزارش هوای حاضر اعلام شده باشد. مشروط بر اینکه داده‌های قدرت دید افقی متناظر با کد اعلام شده، در کمتر از ۱۰۰۰ متر ثبت شده باشد (گودی و همکاران، ۲۰۰۶). لذا در این مطالعه، به‌منظور تشخیص طوفان‌های گردوغبار، از مؤلفه دید افقی کمتر از ۱۰۰۰ متر برای تمامی کدهای گردوغبار استفاده شده است.

هواشناسی هر سه ساعت یک بار و در مجموع در هشت سینوپ در طول شبانه‌روز ثبت می‌شوند. در این مشاهدات، پدیده‌های بصری آب‌وهوا طبق دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد از ۰۰ تا ۹۹ تعریف شده‌اند. از مجموع این ۱۰۰ کد، به‌طور کلی ۱۱ کد (جدول ۱)، برای ثبت و گزارش پدیده گردوغبار در ایستگاه‌های مختلف هواشناسی استفاده می‌شود (اولوینگسای^۱ و همکاران، ۲۰۱۴). براساس تعریف سازمان جهانی هواشناسی، روز همراه با طوفان‌های



شکل (۱): معرفی ایستگاه‌های مورد مطالعه در پژوهش حاضر

Figure (1): Introduction of the studied stations in the present study

جدول (۱): کدهای سازمان جهانی هواشناسی مرتبط با فرسایش بادی و پدیده‌های گردوغبار (اولوینگسای و همکاران، ۲۰۱۴)

Table (1): Word Meteorological Organization (WMO) codes related to wind erosion and dust phenomena (O'Loingsigh et al., 2014)

کد	توضیحات
۰۶	رخداد طوفان گرد و خاک گسترده در خارج از ایستگاه هواشناسی
۰۷	خاک یا شن برخاسته از زمین در محدوده ایستگاه هواشناسی
۰۸	مشاهده گردباد در محدوده ایستگاه هواشناسی یا خارج از آن طی ساعت‌های دیدبانی یا ساعت گذشته
۰۹	طوفان شن یا خاک در زمان دیدبانی در خارج از ایستگاه یا طی ساعت گذشته در محدوده ایستگاه هواشناسی
۳۰	طوفان خفیف یا متوسط شن یا خاک با روند کاهشی طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش میدان دید به کمتر از ۱۰۰۰ ولی بیشتر از ۲۰۰ متر
۳۱	طوفان خفیف یا متوسط شن یا خاک بدون تغییر شدت طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش میدان دید به کمتر از ۱۰۰۰ ولی بیشتر از ۲۰۰ متر
۳۲	طوفان خفیف یا متوسط شن یا خاک با افزایش شدت طی ساعت گذشته- با سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش میدان دید به کمتر از ۱۰۰۰ ولی بیشتر از ۲۰۰ متر
۳۳	طوفان شدید شن یا خاک همراه با روند کاهشی طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش دید کمتر از ۲۰۰ متر
۳۴	طوفان شدید شن یا خاک همراه بدون تغییر شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش دید کمتر از ۲۰۰ متر
۳۵	طوفان شدید شن یا خاک همراه با افزایش شدت طی ساعت گذشته- سرعت باد ۱۵ متر بر ثانیه یا بیشتر- کاهش دید کمتر از ۲۰۰ متر
۹۸	رعد و برق- بدون بارش- همراه با طوفان شن یا خاک (هیوب)

یادگیری عمیق^۱ (DL)

یادگیری عمیق یکی از شاخه‌های تخصصی یادگیری ماشین^۲ است و در حل مسائل پیچیده از طریق استفاده از شبکه‌های عصبی^۳ بسیار مؤثر است. هدف آن استفاده از ساختارهای سلسله‌مراتبی برای استخراج ویژگی‌ها و انتزاعات پیچیده از داده‌هاست. این حوزه به‌عنوان یک رویکرد نوظهور در سال‌های اخیر مورد توجه قرار گرفته و در زمینه‌های مختلفی از هوش مصنوعی^۴ به‌طور گسترده‌ای مورد استفاده قرار می‌گیرد (نیر و همکاران، ۲۰۲۳). این روش با به‌کارگیری مدل‌های محاسباتی چندلایه که قادر به پردازش داده‌ها در سطوح مختلف هستند، فرایند یادگیری را به‌طور چشمگیری ارتقا می‌دهد (لوکن و همکاران، ۲۰۱۵؛ شی و همکاران، ۲۰۱۵). مدل‌های یادگیری عمیق، نظیر شبکه‌های عصبی مصنوعی عمیق، به‌دلیل توانایی بالای خود در شناسایی الگوها و ساختارهای پنهان در داده‌های وسیع، از سایر روش‌ها متمایز می‌شوند. در این شبکه‌ها، هر لایه مفهومی را یاد می‌گیرد که در لایه‌های بعدی اصلاح و گسترش می‌یابد و این فرایند به‌تدریج مفاهیم ابتدایی را به مفاهیم انتزاعی پیچیده‌تر تبدیل می‌کند (روسک، ۲۰۱۶؛ لویی و همکاران، ۲۰۱۷). ساختار شبکه‌های یادگیری عمیق متشکل از چندین لایه از گره‌های متصل به یکدیگر است که هر لایه پیچیدگی پیش‌بینی‌ها و طبقه‌بندی‌ها را افزایش می‌دهد. به‌طور کلی، اجزای اصلی یادگیری عمیق شامل شبکه‌های عصبی، لایه‌ها، گره‌ها، توابع فعال‌سازی، وزن‌ها، بایاس‌ها، روش‌های بهینه‌سازی و شبکه‌های عصبی عمیق هستند. توابع فعال‌سازی با معرفی ویژگی غیرخطی بودن، به شبکه عصبی این امکان را می‌دهند که الگوها و روابط پیچیده موجود در داده‌ها را یاد بگیرد. یکی از مزایای کلیدی یادگیری عمیق، استقلال آن از پردازش‌های پیشین داده‌هاست، چراکه این مدل به‌طور خودکار ویژگی‌ها را مستقیماً از داده‌ها استخراج کرده و می‌آموزد (روسک، ۲۰۱۶؛ کریژفسکی^۵ و همکاران، ۲۰۱۷).

شبکه عصبی کانولوشن (CNN)

این مدل که نوعی شبکه عصبی مصنوعی محسوب می‌شود، برای نخستین بار توسط لوکن و همکاران (۱۹۸۹) معرفی و سپس در سال ۲۰۱۲ توسط کریژفسکی و همکاران توسعه داده شد. این مدل در پردازش تصاویر عملکرد بسیار موفقی داشته (کریژفسکی و همکاران، ۲۰۱۲) و همچنین برای تحلیل داده‌های سری‌زمانی نیز کاربرد مناسبی دارد (دو^۶ و همکاران، ۲۰۱۹). یکی از مهم‌ترین مزایای این شبکه عصبی، توانایی آن در شناسایی خودکار ویژگی‌های کلیدی بدون نیاز به دخالت انسانی است (الزوبیدی^۷ و همکاران، ۲۰۲۱). شبکه‌های عصبی کانولوشن به‌دلیل توانایی در کاهش پارامترها، استخراج خودکار ویژگی‌های معنادار و تعمیم‌پذیری بالا، از سایر روش‌های یادگیری عمیق متمایزند. این روش‌ها به‌طور گسترده در حوزه‌هایی مانند بینایی ماشین^۸، پردازش تصاویر^۹ و تحلیل داده‌های پیچیده به کار گرفته می‌شوند و با بهره‌گیری از ساختار سلسله‌مراتبی^{۱۱}، امکان شناسایی دقیق‌تر و کارآمدتر ویژگی‌ها را فراهم می‌کنند. ساختار طراحی‌شده برای CNN شامل لایه ورودی^{۱۲}، چندلایه پنهان^{۱۳} (لایه کانولوشن)^{۱۴} (آهلاوات و همکاران، ۲۰۲۰)، لایه ادغام^{۱۵} (لیو^{۱۶} و همکاران، ۲۰۲۰) و لایه اتصال کامل (آلبای و همکاران، ۲۰۱۷) و لایه خروجی^{۱۷} است (فن^{۱۸} و همکاران، ۲۰۲۰). نحوه عملکرد هر لایه کانولوشن بدین صورت است که خروجی ماتریس داده‌های لایه قبلی در ماتریس ضرایب وزنی ضرب می‌شود، سپس ماتریس بایاس به آن اضافه می‌گردد و در نهایت، تابع فعال‌سازی^{۱۹} بر آن اعمال می‌شود.

مدل‌های پیش‌بینی

به‌منظور پیش‌بینی کمی فراوانی روزهای همراه با طوفان

7. Du

8. Alzubaidi

9. Machine Vision

10. Image Processing

11. Hierarchical Structure

12. Input Layer

13. Hidden Layer

14. Convolutional Layer

15. Pooling Layer- Subsampling

16. Liao

17. Output Layer

18. Fan

19. Activation Function

1. Deep Learning

2. Machine learning

3. Neural Network

4. Artificial Intelligence

5. Rusk

6. Krizhevsky

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (۳)$$

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (۴)$$

در رابطه‌های ۱ تا ۴، O_i مقادیر مشاهده شده در زمان f_i مقادیر پیش‌بینی شده در زمان $\bar{f}$ میانگین مقادیر پیش‌بینی شده، $\bar{O}$ میانگین مقادیر مشاهده شده و n تعداد داده‌هاست. بر این اساس، مدلی که $RMSE$ و MAE کمتری و همچنین R و NS نزدیک به واحد داشته باشد، کارایی و مطلوبیت بیشتری در حوزه مد نظر پژوهشگر دارد.

۳. نتایج و بحث

شاخص‌های ارزیابی R ، $RMSE$ ، NS و MAE به منظور بررسی و مقایسه عملکرد مدل یادگیری عمیق و الگوریتم شبکه عصبی کانولوشن به منظور مدل‌سازی طوفان‌های گردوغبار در استان کرمانشاه در طول دوره آماری ۴۰ ساله (۱۹۸۰-۲۰۲۰) استفاده شده است. در جداول ۲ و ۳، به ترتیب، مقادیر معیارهای ارزیابی مرتبط با مراحل آموزش و آزمون الگوریتم شبکه عصبی کانولوشن و مدل یادگیری عمیق برای پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گردوغبار در نه ایستگاه هواشناسی سینوپتیک قصر شیرین، گیلان غرب، سرپل ذهاب، اسلام‌آباد غرب، جوانرود، سرارود، روانسر، هرسین و کنگاور، نشان داده شده است. در این جداول، معیارهای ارزیابی در ۴ ترکیب برای هریک از مدل‌های یادشده مورد بررسی قرار گرفته است. با توجه به جدول ۲ و شاخص‌های ارزیابی استفاده شده، می‌توان به این نتیجه رسید که تمامی ایستگاه‌های مورد بررسی، در ترکیب‌های اول و دوم عملکرد بهتری را نسبت به سایر ترکیب‌ها نشان می‌دهند. لذا به کارگیری یک و نهایتاً دو فصل قبل برای مدل‌سازی طوفان‌های گردوغبار در تمامی ایستگاه سبب بهبود عملکرد مدل‌سازی می‌شود. در این میان، ترکیب شماره یک به عنوان ترکیب بهینه برای مدل‌سازی شاخص $FDSD$ با الگوریتم شبکه عصبی کانولوشن انتخاب شده است. با توجه به نتایج مدل‌سازی طوفان‌های گردوغبار در ایستگاه قصر شیرین (با بیشترین فراوانی روزهای همراه با طوفان گردوغبار در مقیاس فصلی) با ایستگاه کنگاور (با کمترین فراوانی فصلی)، می‌توان نتیجه گرفت که هرچه از تعداد روزهای گردوغباری در ایستگاه‌های مورد بررسی کاسته می‌شود، پیشروی از ایستگاه

گردوغبار، از مدل‌های یادگیری عمیق و الگوریتم شبکه عصبی کانولوشن استفاده شده است. نتایج مدل‌سازی با معیارهای R ، $RMSE$ ، MAE و NS مورد ارزیابی قرار گرفته است. متغیر مد نظر در پژوهش حاضر، تعداد فصل یا فصل‌های گذشته برای مدل‌سازی فصل‌های آتی است. تعداد فصول قابل پیش‌بینی می‌تواند شامل یک، دو، سه و چهار فصل قبل‌تر از متغیر $FDSD$ باشد. برای پیش‌بینی شاخص $FDSD$ در مدل شماره یک در فصل بعدی، از سری زمانی فراوانی روزهای همراه با طوفان گردوغبار با یک گام تأخیر استفاده شده است. به عبارت دیگر، برای پیش‌بینی در زمان $t+1$ ، از مقدار آن در زمان t استفاده شده است. در مدل شماره دو، پیش‌بینی در فصل بعدی با استفاده از مقادیر $FDSD$ تا دو فصل قبلی آن صورت گرفته است. در مدل‌های ۳ و ۴ نیز پیش‌بینی‌ها براساس مقادیر $FDSD$ در سه و چهار فصل قبل انجام شده است. روابط زیر، پیش‌بینی‌های انجام شده در مدل‌های یک تا چهار را نمایش می‌دهد. همچنین به منظور مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد نیز به منظور تست مورد استفاده قرار گرفت.

$$FDSD_{(t+1)} = f(FDSD_{(t)}) \quad (۱)$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}) \quad (۲)$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}) \quad (۳)$$

$$FDSD_{(t+1)} = f(FDSD_{(t)}, FDSD_{(t-1)}, FDSD_{(t-2)}, FDSD_{(t-3)}) \quad (۴)$$

معیارهای ارزیابی

در پژوهش حاضر، به منظور ارزیابی دقت و کارایی مدل‌ها، از ضریب همبستگی^۱ (R)، ریشه میانگین مربعات خطا^۲ ($RMSE$)، میانگین قدر مطلق خطا^۳ (MAE) و ضریب نش-ساتکلِف^۴ (NS) براساس روابط زیر استفاده شده است. بهترین مقدار برای این چهار نمایه، به ترتیب، یک، صفر، صفر و یک است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (۱)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۲)$$

1. Correlation
2. Root Mean Square Error
3. Mean Absolute Error
4. Nash- Sutcliffe

قصر شیرین به سمت کنگاور، دقت مدل‌سازی شاخص FDSD افزایش می‌یابد. همچنین با توجه به شرایط آب‌وهوایی در منطقه مورد مطالعه، تأثیر شاخص فراوانی روزهای همراه با طوفان گردوغبار در فصل‌های گذشته، ترکیب‌های سوم و چهارم در جدول ۲، آن‌چنان قابل قبول نیست. برای مثال در ایستگاه قصر شیرین، مقدار ضریب همبستگی و خطای نش-ساتکلیف به ترتیب از ۰/۷۶۵ و ۰/۷۸۳ روز در گام چهارم، به ۰/۷۶۸ و ۰/۷۸۴ روز در گام اول افزایش یافته است. در ایستگاه‌های سرپل ذهاب، اسلام‌آباد غرب و جوانرود نیز مقدار معیارهای خطا پس از پیش‌بینی طوفان‌های گردوغبار با استفاده از فصل اول به جای فصل چهارم، به ترتیب از ۰/۳۵۳، ۰/۳۵۷ و ۰/۳۵۹ روز به ۰/۳۴۹، ۰/۳۵۴ و ۰/۳۵۸ روز کاهش یافته است. نتایج این قسمت با نتایج یارمحمدی و همکاران (۲۰۲۳) و خسروی و همکاران (۲۰۲۰) مطابقت دارد.

جدول (۲): نتایج آماری داده‌های ورودی الگوریتم شبکه عصبی کانولوشن به منظور پیش‌بینی شاخص FDSD

Table (2): Statistical results of CNN model input patterns in predicting FDSD index

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
قصر شیرین	۱	۰/۷۹۷	۰/۳۲۱	۰/۲۸۷	۰/۷۹۱	۰/۷۸۴	۰/۳۴۳	۰/۳۰۳	۰/۷۶۸
	۲	۰/۷۹۸	۰/۳۱۹	۰/۲۸۷	۰/۷۹۱	۰/۷۷۹	۰/۳۴۱	۰/۳۰۲	۰/۷۶۶
	۳	۰/۷۹۷	۰/۳۱۸	۰/۲۸۸	۰/۷۸۹	۰/۷۸۳	۰/۳۴۱	۰/۳۰۴	۰/۷۶۹
	۴	۰/۷۹۶	۰/۳۲۲	۰/۲۸۴	۰/۷۸۸	۰/۷۸۳	۰/۳۴۴	۰/۳۰۵	۰/۷۶۵
گیلان غرب	۱	۰/۷۹۵	۰/۳۲۳	۰/۲۸۳	۰/۷۸۷	۰/۷۸۳	۰/۳۴۵	۰/۳۰۶	۰/۷۶۴
	۲	۰/۷۹۴	۰/۳۲۴	۰/۲۸۹	۰/۷۸۶	۰/۷۷۹	۰/۳۴۶	۰/۳۰۷	۰/۷۶۳
	۳	۰/۷۹۳	۰/۳۲۵	۰/۲۸۹	۰/۷۸۵	۰/۷۸۲	۰/۳۴۷	۰/۳۰۲	۰/۷۶۳
	۴	۰/۷۹۲	۰/۳۲۶	۰/۲۸۹	۰/۷۸۴	۰/۷۸۱	۰/۳۴۸	۰/۲۹۹	۰/۷۶۲
سرپل ذهاب	۱	۰/۷۹۱	۰/۳۲۷	۰/۲۹۱	۰/۷۸۷	۰/۷۷۹	۰/۳۴۹	۰/۲۹۷	۰/۷۶۲
	۲	۰/۷۹۰	۰/۳۲۸	۰/۲۹۳	۰/۷۸۶	۰/۷۷۸	۰/۳۵۱	۰/۳۰۴	۰/۷۶۴
	۳	۰/۷۸۹	۰/۳۲۹	۰/۲۸۵	۰/۷۸۳	۰/۷۷۸	۰/۳۵۲	۰/۳۰۵	۰/۷۶۵
	۴	۰/۷۹۱	۰/۳۲۹	۰/۲۹۵	۰/۷۸۲	۰/۷۷۹	۰/۳۵۳	۰/۳۰۵	۰/۷۶۱
اسلام‌آباد غرب	۱	۰/۷۹۳	۰/۳۲۹	۰/۲۹۷	۰/۷۸۱	۰/۷۸۱	۰/۳۵۴	۰/۳۰۸	۰/۷۶۱
	۲	۰/۷۸۹	۰/۳۳۱	۰/۲۹۸	۰/۷۸۱	۰/۷۸۲	۰/۳۵۵	۰/۳۰۹	۰/۷۵۹
	۳	۰/۷۸۹	۰/۳۲۸	۰/۲۹۹	۰/۷۷۹	۰/۷۷۶	۰/۳۵۶	۰/۳۰۹	۰/۷۵۹
	۴	۰/۷۸۸	۰/۳۲۶	۰/۳۰۱	۰/۷۷۸	۰/۷۷۵	۰/۳۵۷	۰/۳۰۹	۰/۷۵۸
جوانرود	۱	۰/۷۹۲	۰/۳۳۲	۰/۳۰۲	۰/۷۷۶	۰/۷۷۴	۰/۳۵۸	۰/۳۱۱	۰/۷۵۷
	۲	۰/۷۹۴	۰/۳۳۴	۰/۲۹۴	۰/۷۷۵	۰/۷۷۳	۰/۳۵۹	۰/۳۱۲	۰/۷۵۶
	۳	۰/۷۸۹	۰/۳۳۳	۰/۲۹۹	۰/۷۷۴	۰/۷۷۳	۰/۳۵۹	۰/۳۱۳	۰/۷۵۵
	۴	۰/۷۸۷	۰/۳۳۵	۰/۳۰۴	۰/۷۷۳	۰/۷۷۳	۰/۳۵۹	۰/۳۱۳	۰/۷۵۴
سرارود	۱	۰/۷۸۶	۰/۳۳۷	۰/۳۰۵	۰/۷۷۲	۰/۷۷۲	۰/۳۶۱	۰/۳۱۴	۰/۷۵۴
	۲	۰/۷۸۵	۰/۳۳۹	۰/۳۰۶	۰/۷۷۱	۰/۷۷۴	۰/۳۶۲	۰/۳۱۴	۰/۷۵۳
	۳	۰/۷۸۵	۰/۳۴۱	۰/۳۰۷	۰/۷۷۰	۰/۷۷۵	۰/۳۶۳	۰/۳۱۶	۰/۷۵۲
	۴	۰/۷۸۴	۰/۳۴۲	۰/۳۰۸	۰/۷۶۹	۰/۷۸۱	۰/۳۶۴	۰/۳۱۷	۰/۷۵۵
روانسر	۱	۰/۷۸۴	۰/۳۴۳	۰/۳۰۹	۰/۷۷۱	۰/۷۷۳	۰/۳۶۵	۰/۳۱۸	۰/۷۵۱
	۲	۰/۷۸۷	۰/۳۴۴	۰/۳۱۱	۰/۷۷۳	۰/۷۷۲	۰/۳۶۶	۰/۳۱۹	۰/۷۴۹
	۳	۰/۷۸۸	۰/۳۴۵	۰/۳۱۲	۰/۷۷۲	۰/۷۷۱	۰/۳۶۷	۰/۳۲۱	۰/۷۵۰
	۴	۰/۷۸۶	۰/۳۴۶	۰/۳۱۴	۰/۷۶۸	۰/۷۷۱	۰/۳۶۸	۰/۳۲۲	۰/۷۴۸
هرسین	۱	۰/۷۸۶	۰/۳۴۷	۰/۳۱۷	۰/۷۶۸	۰/۷۶۹	۰/۳۶۹	۰/۳۲۳	۰/۷۴۷
	۲	۰/۷۸۵	۰/۳۴۸	۰/۳۱۹	۰/۷۶۸	۰/۷۶۸	۰/۳۷۱	۰/۳۲۴	۰/۷۴۷
	۳	۰/۷۸۵	۰/۳۴۹	۰/۳۲۱	۰/۷۶۷	۰/۷۷۰	۰/۳۷۲	۰/۳۲۵	۰/۷۴۷
	۴	۰/۷۸۴	۰/۳۵۱	۰/۳۲۲	۰/۷۶۷	۰/۷۶۷	۰/۳۷۳	۰/۳۲۱	۰/۷۴۶
کنگاور	۱	۰/۷۸۳	۰/۳۵۲	۰/۳۲۳	۰/۷۶۶	۰/۷۶۶	۰/۳۷۴	۰/۳۲۶	۰/۷۴۵
	۲	۰/۷۸۳	۰/۳۵۳	۰/۳۲۴	۰/۷۶۵	۰/۷۶۵	۰/۳۷۴	۰/۳۲۷	۰/۷۴۴
	۳	۰/۷۸۴	۰/۳۵۴	۰/۳۲۵	۰/۷۶۵	۰/۷۶۴	۰/۳۷۵	۰/۳۲۸	۰/۷۴۳
	۴	۰/۷۸۲	۰/۳۵۵	۰/۳۲۷	۰/۷۶۴	۰/۷۶۳	۰/۳۷۶	۰/۳۲۹	۰/۷۴۱

جدول (۳): نتایج آماری داده‌های ورودی مدل یادگیری عمیق به منظور پیش‌بینی شاخص FDSD

Table (2): Statistical results of DL model input patterns in predicting FDSD index

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
قصر شیرین	۱	-۰/۹۸۹	-۰/۱۵۹	-۰/۱۴۳	-۰/۹۷۸	-۰/۹۶۷	-۰/۱۹۴	-۰/۱۷۵	-۰/۹۵۳
	۲	-۰/۹۸۸	-۰/۱۵۵	-۰/۱۴۴	-۰/۹۸۱	-۰/۹۶۶	-۰/۱۹۴	-۰/۱۷۶	-۰/۹۵۲
	۳	-۰/۹۹۱	-۰/۱۵۴	-۰/۱۴۵	-۰/۹۷۸	-۰/۹۶۹	-۰/۱۹۵	-۰/۱۷۷	-۰/۹۵۱
	۴	-۰/۹۹۳	-۰/۱۵۶	-۰/۱۴۶	-۰/۹۷۹	-۰/۹۷۱	-۰/۱۹۶	-۰/۱۷۸	-۰/۹۵۱
گیلان غرب	۱	-۰/۹۸۷	-۰/۱۵۶	-۰/۱۴۶	-۰/۹۷۹	-۰/۹۶۶	-۰/۱۹۶	-۰/۱۷۸	-۰/۹۴۹
	۲	-۰/۹۸۷	-۰/۱۵۶	-۰/۱۴۶	-۰/۹۸۱	-۰/۹۶۶	-۰/۱۹۷	-۰/۱۸۱	-۰/۹۵۲
	۳	-۰/۹۸۶	-۰/۱۵۷	-۰/۱۴۳	-۰/۹۸۲	-۰/۹۶۶	-۰/۱۹۵	-۰/۱۷۹	-۰/۹۴۸
	۴	-۰/۹۸۵	-۰/۱۶۱	-۰/۱۴۱	-۰/۹۷۶	-۰/۹۶۵	-۰/۱۹۶	-۰/۱۷۹	-۰/۹۴۷
سر پل ذهاب	۱	-۰/۹۸۴	-۰/۱۶۱	-۰/۱۴۶	-۰/۹۷۶	-۰/۹۶۵	-۰/۱۹۷	-۰/۱۷۸	-۰/۹۴۶
	۲	-۰/۹۸۳	-۰/۱۶۲	-۰/۱۴۷	-۰/۹۷۶	-۰/۹۶۴	-۰/۱۹۷	-۰/۱۸۲	-۰/۹۴۵
	۳	-۰/۹۸۳	-۰/۱۶۳	-۰/۱۴۸	-۰/۹۷۵	-۰/۹۶۴	-۰/۱۹۸	-۰/۱۸۳	-۰/۹۴۴
	۴	-۰/۹۸۳	-۰/۱۶۴	-۰/۱۴۹	-۰/۹۷۹	-۰/۹۶۴	-۰/۱۹۹	-۰/۱۸۴	-۰/۹۴۳
اسلام‌آباد غرب	۱	-۰/۹۷۹	-۰/۱۶۵	-۰/۱۴۹	-۰/۹۸۱	-۰/۹۶۶	-۰/۱۹۴	-۰/۱۸۵	-۰/۹۴۲
	۲	-۰/۹۷۴	-۰/۱۶۶	-۰/۱۴۹	-۰/۹۷۵	-۰/۹۶۳	-۰/۱۹۹	-۰/۱۸۶	-۰/۹۴۱
	۳	-۰/۹۷۹	-۰/۱۶۷	-۰/۱۵۱	-۰/۹۷۴	-۰/۹۶۲	-۰/۱۹۷	-۰/۱۷۹	-۰/۹۵۲
	۴	-۰/۹۷۸	-۰/۱۶۸	-۰/۱۵۳	-۰/۹۷۳	-۰/۹۶۱	-۰/۱۹۹	-۰/۱۷۹	-۰/۹۵۷
جوانرود	۱	-۰/۹۷۸	-۰/۱۶۹	-۰/۱۴۸	-۰/۹۷۳	-۰/۹۶۷	-۰/۱۹۹	-۰/۱۸۵	-۰/۹۵۳
	۲	-۰/۹۷۷	-۰/۱۷۱	-۰/۱۵۴	-۰/۹۷۲	-۰/۹۵۹	-۰/۲۰۱	-۰/۱۸۷	-۰/۹۴۱
	۳	-۰/۹۷۳	-۰/۱۷۲	-۰/۱۵۵	-۰/۹۷۱	-۰/۹۵۸	-۰/۲۰۱	-۰/۱۸۸	-۰/۹۴۱
	۴	-۰/۹۷۲	-۰/۱۷۲	-۰/۱۵۶	-۰/۹۶۹	-۰/۹۵۷	-۰/۲۰۳	-۰/۱۸۹	-۰/۹۴۱
سرارود	۱	-۰/۹۷۵	-۰/۱۷۳	-۰/۱۵۷	-۰/۹۶۸	-۰/۹۵۶	-۰/۲۰۴	-۰/۱۹۱	-۰/۹۳۹
	۲	-۰/۹۷۵	-۰/۱۶۸	-۰/۱۵۷	-۰/۹۶۷	-۰/۹۵۵	-۰/۲۰۵	-۰/۱۹۱	-۰/۹۴۶
	۳	-۰/۹۷۵	-۰/۱۷۴	-۰/۱۵۷	-۰/۹۶۶	-۰/۹۵۴	-۰/۱۹۸	-۰/۱۹۲	-۰/۹۳۸
	۴	-۰/۹۷۳	-۰/۱۶۹	-۰/۱۵۹	-۰/۹۶۵	-۰/۹۵۳	-۰/۱۹۹	-۰/۱۸۹	-۰/۹۳۷
روانسر	۱	-۰/۹۷۲	-۰/۱۷۵	-۰/۱۵۹	-۰/۹۶۴	-۰/۹۵۲	-۰/۱۹۴	-۰/۱۹۳	-۰/۹۳۶
	۲	-۰/۹۶۹	-۰/۱۷۶	-۰/۱۶۱	-۰/۹۶۳	-۰/۹۵۱	-۰/۲۰۵	-۰/۱۹۳	-۰/۹۳۵
	۳	-۰/۹۷۱	-۰/۱۷۷	-۰/۱۶۳	-۰/۹۶۲	-۰/۹۴۹	-۰/۲۰۶	-۰/۱۹۳	-۰/۹۳۴
	۴	-۰/۹۷۱	-۰/۱۷۸	-۰/۱۵۶	-۰/۹۶۱	-۰/۹۴۸	-۰/۲۰۷	-۰/۱۹۴	-۰/۹۳۳
هرسین	۱	-۰/۹۷۱	-۰/۱۷۹	-۰/۱۶۴	-۰/۹۶۱	-۰/۹۴۷	-۰/۲۰۸	-۰/۱۹۵	-۰/۹۳۲
	۲	-۰/۹۶۸	-۰/۱۸۱	-۰/۱۶۵	-۰/۹۵۹	-۰/۹۴۶	-۰/۲۰۹	-۰/۱۸۹	-۰/۹۴۴
	۳	-۰/۹۶۷	-۰/۱۸۱	-۰/۱۶۶	-۰/۹۵۸	-۰/۹۴۵	-۰/۲۰۹	-۰/۱۸۸	-۰/۹۴۲
	۴	-۰/۹۶۶	-۰/۱۸۱	-۰/۱۶۷	-۰/۹۵۷	-۰/۹۴۴	-۰/۲۰۹	-۰/۱۹۴	-۰/۹۴۲
کنگاور	۱	-۰/۹۶۵	-۰/۱۸۲	-۰/۱۶۸	-۰/۹۵۶	-۰/۹۴۳	-۰/۲۱۱	-۰/۱۹۵	-۰/۹۴۱
	۲	-۰/۹۶۴	-۰/۱۸۳	-۰/۱۶۹	-۰/۹۵۵	-۰/۹۴۲	-۰/۲۱۳	-۰/۱۹۵	-۰/۹۳۰
	۳	-۰/۹۶۳	-۰/۱۸۴	-۰/۱۷۱	-۰/۹۵۴	-۰/۹۴۱	-۰/۲۱۳	-۰/۱۸۹	-۰/۹۲۹
	۴	-۰/۹۶۳	-۰/۱۸۵	-۰/۱۷۳	-۰/۹۵۴	-۰/۹۳۹	-۰/۲۱۷	-۰/۱۹۷	-۰/۹۲۸

فصل‌های بیشتر، مقادیر خطای RMSE و MAE روند افزایشی داشتند. برای مثال در ایستگاه‌های هرسین و کنگاور، مقدار مجذور مربعات خطا از ۰/۲۰۹ و ۰/۲۱۷ در ترکیب فصلی چهارم، به ۰/۲۰۹ و ۰/۲۱۳ روز در نتیجه اعمال دو فصل گذشته برای مدل‌سازی طوفان‌های گردوغبار، به‌طور نسبی کاهش پیدا کرده است. با اعمال یک فصل گذشته، مقدار

جدول ۳ نمایانگر نتایج پیش‌بینی طوفان‌های گردوغبار در دوره زمانی ۴۰ ساله (۱۹۸۰-۲۰۲۰) در استان کرمانشاه است. با بررسی نتایج مدل‌سازی شاخص FDSD با DL می‌توان نتیجه گرفت که در این روش نیز مانند روش قبلی در همه ایستگاه‌های مورد بررسی، نتایج مدل‌سازی این طوفان‌ها با به‌کارگیری یک یا دو فصل قبلی بهبود یافته و با به‌کارگیری

عمیق، به دلیل توانایی قابل توجه در استخراج ویژگی‌های پیچیده و شناسایی الگوهای نهفته در داده‌های حجیم، ابزاری قدرتمند برای مدل‌سازی پدیده‌های غیرخطی و پیچیده نظیر طوفان‌های گردوغبار محسوب می‌شوند. با این حال، این مدل‌ها به دلیل نیاز به منابع محاسباتی پیشرفته و زمان آموزش طولانی، معمولاً با هزینه‌های اجرایی بالا همراه‌اند. در مقابل، شبکه‌های عصبی کانولوشن، که ساختار آن‌ها برای مدل‌سازی داده‌های سری زمانی بهینه شده است، گزینه‌ای مؤثرتر و مقرون به صرفه‌تر برای تحلیل این پدیده‌ها ارائه می‌دهند. انتخاب میان این دو مدل باید براساس تعادل میان دقت مورد نیاز، هزینه‌های اجرایی و محدودیت‌های زمانی و محاسباتی صورت گیرد. از سوی دیگر، اختلاف نتایج مدل‌ها در سطح اطمینان ۹۵ و ۹۹ درصد معنادار است. با وجود فاصله قابل توجه در نتایج مدل‌سازی طوفان‌های گردوغبار با استفاده از دو مدل یادگیری عمیق و شبکه عصبی کانولوشن، و برای دستیابی به نتایج دقیق‌تر و افزایش بازدهی مدل‌سازی، می‌توان از مدل DL استفاده کرد. مقایسه میانگین مقادیر مشاهده‌شده و پیش‌بینی‌شده با استفاده از آزمون t ، نمایانگر قبول فرض صفر مبتنی بر برابری میانگین سری‌های زمانی مشاهداتی و پیش‌بینی‌شده شاخص فراوانی روزهای همراه با طوفان گردوغبار در استان کرمانشاه است (جدول ۴). بدین ترتیب می‌توان نتیجه گرفت که هر دو مدل یادگیری عمیق و CNN، میانگین سری زمانی مشاهداتی را برای پیش‌بینی شاخص FDSO حفظ کرده‌اند.

RMSE به ۰/۲۰۸ و ۰/۲۱۱ روز کاهش یافته است. لذا می‌توان نتیجه گرفت که استفاده از یک فصل گذشته برای پیش‌بینی شاخص FDSO در فصول آتی بهترین نتایج را ارائه می‌دهد. با توجه به اینکه در جدول ۳، ترتیب ایستگاه‌ها با توجه به شاخص FDSO از ایستگاه قصر شیرین تا کنگاور نزولی است، می‌توان نتیجه گرفت که عملکرد و دقت DL برای مدل‌سازی طوفان‌های گردوغبار با افزایش تعداد روزهای همراه با طوفان گردوغبار رابطه مستقیمی دارد. به عبارت دیگر، افزایش شاخص FDSO سبب بهبود نتایج مدل‌سازی می‌شود. همان‌طور که در این جدول مشهود است، مقدار خطا در همه ایستگاه‌های مورد مطالعه به‌ازای تمامی ترکیب‌ها، نسبت به الگوریتم شبکه عصبی کانولوشن، تغییر محسوسی داشته است. همچنین ضرایب همبستگی و نش-سانکلیف نیز نسبت به نتایج مدل‌سازی با CNN، به صورت قابل ملاحظه‌ای افزایش یافته است. برای مثال در ایستگاه سرارود، مقدار RMSE و MAE در مرحله آزمون در ترکیب فصلی شماره چهار، از ۰/۳۶۱ و ۰/۳۱۴ در روش DL، به ۰/۲۰۴ و ۰/۱۹۱ در روش CNN کاهش یافته است. بدین ترتیب می‌توان نتیجه گرفت که دقت روش DL در مدل‌سازی طوفان‌های گردوغبار از CNN بیشتر است. نتایج این بخش با نتایج الشامری^۱ و همکاران (۲۰۲۲) و باندارا^۲ و همکاران (۲۰۲۲) مطابقت دارد.

هزینه و پیچیدگی مدل‌سازی طوفان‌های گردوغبار به‌طور مستقیم با انتخاب مدل یادگیری مرتبط است. مدل‌های یادگیری

جدول (۴): آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش‌بینی‌شده شاخص FDSO


Table (4): Comparison of the average measured and predicted time series of FDSO index

میانگین		آماره t			
مشاهداتی	DL	CNN	DL	CNN	
قصر شیرین	۰/۹۷۴	۰/۹۵۶	۰/۷۹۶	۲/۳۳۵	۱/۷۹۴
گیلان غرب	۰/۹۴۷	۰/۹۳۹	۰/۷۸۴	۲/۳۲۱	۱/۷۵۶
سرپل ذهاب	۰/۹۳۲	۰/۹۲۸	۰/۷۷۳	۲/۲۲۵	۱/۷۴۳
اسلام‌آباد غرب	۰/۹۲۳	۰/۹۱۹	۰/۷۶۴	۲/۲۲۱	۱/۷۲۳
جوانرود	۰/۹۱۴	۰/۹۱۲	۰/۷۵۷	۲/۱۹۷	۱/۶۹۵
سرارود	۰/۹۰۷	۰/۹۰۴	۰/۷۴۷	۲/۱۵۶	۱/۶۸۵
روانسر	۰/۹۰۲	۰/۸۹۹	۰/۷۳۶	۲/۱۲۴	۱/۶۷۳
هرسین	۰/۸۹۴	۰/۸۹۳	۰/۷۲۵	۲/۱۱۷	۱/۶۲۶
کنگاور	۰/۸۸۵	۰/۸۸۲	۰/۷۱۴	۲/۰۵۶	۱/۶۱۷

1. Alshammari
2. Bandara


شکل ۲ مقادیر مشاهده شده و پیش‌بینی شده شاخص فراوانی روزهای همراه با طوفان گردوغبار را برای داده‌های ارزیابی مدل نشان می‌دهد. روند مدل‌سازی طوفان‌های گردوغبار در همه ایستگاه‌ها، با به‌کارگیری مدل‌های یادگیری عمیق بهبود می‌یابد. بدین ترتیب در تمامی ایستگاه‌های مورد بررسی، مدل DL، بیشترین تطابق را با نیم‌ساز ربع اول (خط $y = x$) دارد. همان‌طور که در شکل ۲ مشخص است، با کاهش تعداد روزهای همراه با طوفان گردوغبار در ایستگاه‌های مورد بررسی، مطابقت موجود میان مقادیر مشاهده شده و پیش‌بینی شده کاهش می‌یابد. نتایج این قسمت با مطالعات انصاری قوجقار و همکاران (۲۰۲۱)، گودی و میدلتون (۲۰۰۶) و خسروی و همکاران (۲۰۲۰) مطابقت دارد.

شکل ۲ مقادیر مشاهده شده و پیش‌بینی شده شاخص فراوانی روزهای همراه با طوفان گردوغبار را برای داده‌های ارزیابی مدل نشان می‌دهد. روند مدل‌سازی طوفان‌های گردوغبار در همه ایستگاه‌ها، با به‌کارگیری مدل‌های یادگیری عمیق بهبود می‌یابد. بدین ترتیب در تمامی ایستگاه‌های مورد بررسی، مدل DL، بیشترین تطابق را با نیم‌ساز ربع اول (خط



شکل (۲): مقایسه مقادیر مشاهده شده و پیش‌بینی شده شاخص FDSD در استان کرمانشاه

Figure (2): Comparison of observed and predicted values of FDSD index in Kermanshah Province



شکل (۳): مقایسه شاخص‌های ارزیابی مدل بهینه برای مدل‌سازی طوفان‌های گردوغبار

Figure (3): Comparison of Evaluation Indices for Optimal Model Selection in Dust Storm Modeling

۴. نتیجه‌گیری

نظیر شبکه‌های عصبی مصنوعی عمیق، به دلیل توانایی بالای خود در شناسایی الگوها و ساختارهای پنهان در داده‌های وسیع، از سایر روش‌ها متمایز می‌شوند. در این شبکه‌ها، هر لایه، مفهومی را یاد می‌گیرد که در لایه‌های بعدی اصلاح و گسترش می‌یابد و این فرایند به تدریج مفاهیم ابتدایی را به مفاهیم انتزاعی پیچیده‌تر تبدیل می‌کند. در این راستا، هدف از انجام این پژوهش، مقایسه عملکرد مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن به منظور مدل‌سازی طوفان‌های گردوغبار در نه ایستگاه هواشناسی استان کرمانشاه (قصر شیرین، گیلان غرب، سرپل ذهاب، اسلام‌آباد غرب، جوانرود، سرارود، روانسر، هرسین و کنگاور)، در طول دوره آماری ۴۰ ساله (۱۹۸۱-۲۰۲۰) بود. نتایج نشان داد که ترکیب فصلی شماره یک در نتیجه پیش‌بینی شاخص FDS با مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن، به عنوان ترکیب بهینه انتخاب شده است. همچنین، هر دو مدل از دقت و عملکرد قابل قبولی در

مدل‌سازی طوفان‌های گردوغبار به مدیران و سیاست‌گذاران کمک می‌کند تا با اعمال تدابیر پیشگیرانه، مانند هشدارهای بموقع و تخصیص منابع، از اثرات منفی آن‌ها بکاهند. با توجه به پیچیدگی و عدم قطعیت‌های موجود در این طوفان‌ها، استفاده از مدل‌سازی دقیق برای پیش‌بینی و کاهش ریسک‌های ناشی از آن‌ها ضروری است. این پدیده تأثیرات گسترده‌ای بر سلامت انسان، کشاورزی، زیرساخت‌ها، کیفیت زندگی و تعادل اکوسیستم‌های طبیعی برجای می‌گذارد. لذا مقابله با این چالش نیازمند بهره‌گیری از رویکردهای جامع و چندبعدی است. شبکه‌های عصبی مصنوعی سستی در تحلیل شبکه‌های پیچیده با چالش‌هایی مانند کاهش سرعت یادگیری مواجه بودند. این مشکل در سال ۱۹۹۵ با پیشنهاد Bengio مبنی بر استفاده از شبکه‌های عصبی کانولوشن که قادر به شناسایی ارتباطات محلی بین لایه‌هاست، برطرف شد. مدل‌های یادگیری عمیق،

برنامه‌ریزی منطقه‌ای به کار رود. علاوه بر این، نتایج حاصل از مدل‌سازی می‌توانند در طراحی و توسعه سیستم‌های هشدار زودهنگام نقش مهمی داشته باشند و با اطلاع‌رسانی بموقع به جوامع، اقدامات پیشگیرانه و واکنش سریع را تسهیل کنند. این ابزارها همچنین بستری مناسب برای تدوین سیاست‌های کارآمد در حوزه مدیریت محیط‌زیست، ارتقای تاب‌آوری جوامع در برابر مخاطرات طبیعی و سازگاری بهتر با تغییرات اقلیمی فراهم می‌کنند. از این رو، بهره‌گیری از این رویکرد در کاهش مخاطرات گردوغبار و ارتقای کیفیت زندگی در مناطق آسیب‌پذیر از اهمیت بالایی برخوردار است.

شبیه‌سازی فراوانی روزهای همراه با طوفان‌های گردوغبار برخوردارند. در این بین نیز، مدل DL با بیشترین مقدار ضرایب همبستگی و NS و کمترین مقدار معیارهای برآورد خطای RMSE و MAE، نسبت به مدل CNN، به‌عنوان مدل بهینه برای مدل‌سازی طوفان‌های گردوغبار در استان کرمانشاه انتخاب شده است. این فناوری پیشرفته امکان پیش‌بینی دقیق‌تر زمان، شدت، و مسیر طوفان‌های گردوغبار را فراهم می‌آورد و نقشی اساسی در کاهش خسارات انسانی، اقتصادی و زیست‌محیطی ایفا می‌کند. همچنین، نتایج این مدل‌ها می‌تواند به‌عنوان ابزاری کارآمد در مدیریت منابع طبیعی، از جمله آب، خاک و پوشش گیاهی، به‌منظور کاهش اثرات مخرب طوفان‌ها و بهبود

References

1. Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology (ICET)*, 1-6. IEEE.
2. Alshammari, R. K., Alrwais, O., & Aksoy, M. S. (2022). Machine learning applications to dust storms: A meta-analysis. *Aerosol and Air Quality Research*, 22(12), 220183.
3. 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, 53.
4. Ansari Ghojghar, M., Irani Nejad, S., Bezarafshan, J., Zahraei, B., & Parsi, E. (2021). Evaluation of the performance of the GRU-LSTM hybrid model in dust storm prediction (Case study: Khuzestan province). *Iranian Journal of Water Resources Research*, 17(1), 16-32. [In persian]
5. Arjomandi, H. R., Kheir Ali Pour, K., & Ammarlouei, A. (2024). Prediction of dust concentration in a laboratory scale using image processing and artificial intelligence technologies. *Research in Agricultural Machinery Engineering*, 13(2), 1-9. <https://doi.org/10.22034/jrmam.2024.14177.642>
6. Bandara, N. S. (2022, September). Ensemble deep learning for automated dust storm detection using satellite images. In *2022 International Research Conference on Smart Computing and Systems Engineering (SCSE)* (Vol. 5, pp. 178-183). IEEE.
7. Basalat Pour, A. A., Ramazani, Z., & Hosseini, H. (2013). Modeling and determining the parameters affecting dust storm formation in Rafsanjan County using support vector machines. In *Proceedings of the Third National Conference on Wind Erosion and Dust Storms*, Yazd, Iran. [In persian]
8. Bengio, Y., Simard, P., & Frasconi, P. (1995). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166.
9. Boulanger, M., Nunes, J. C., Chourak, H., Largent, A., Tahri, S., Acosta, O., ... & Barateau, A. (2021). Deep learning methods to generate synthetic CT from MRI in radiotherapy: A literature review. *Physica Medica*, 89, 265-281.
10. Du, S., Li, T., Yang, Y., & Horng, S.-J. (2019). Deep air quality forecasting using hybrid deep learning framework. *IEEE Transactions on Knowledge and Data Engineering*, 33, 2412-2424.
11. Fan, W., Zhang, Q., Wu, Y., & Shi, Z. (2020). Review of convolutional neural network-based action recognition. *Pattern Recognition Letters*, 140, 1-10.
12. Goudie, A. S., & Middleton, N. J. (2006). *Desert dust in the global system*. Springer Science & Business Media.
13. Khosravi, M., Haghshenas, S. S., & Bahadori, M. (2020). Spatial analysis using convolutional neural networks. *Journal of Machine Learning Applications*, 12(4), 45-56. [In persian]
14. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 84-90.
15. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
16. 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, 541-551.

17. Liao, Q., Zhu, M., Wu, L., Pan, X., Tang, X., & Wang, Z. (2020). Deep learning for air quality forecasts: A review. *Current Pollution Reports*, 6, 399-409.
18. Lu, Y., Zheng, C., Zhang, Q., & Xie, Y. (2017). Deep learning for image classification: A review. *Computer Vision and Pattern Recognition Journal*, 56(3), 12-24.
19. Nair, V., Radhakrishnan, A., Chithra, R., & James, A. (2023). Memristive pixel-CNN loop generate for CNN generalisations. *IEEE Transactions on Nanotechnology*, 22, 120-125.
20. O'Loingsigh, T., McTainsh, G. H., Tews, E. K., Strong, C. L., Leys, J. F., Shinkfield, P., & Tapper, N. J. (2014). The Dust Storm Index (DSI): a method for monitoring broadscale wind erosion using meteorological records. *Aeolian Research*, 12, 29-40.
21. Omidvar, K., Dehghan, M., & Khosravi, Y. (2022). Assessment of relationship between aerosol optical depth (AOD) index, wind speed, and visibility in dust storms using genetic algorithm in central Iran (case study: Yazd Province). *Air Quality, Atmosphere & Health*, 15(10), 1745-1753.
22. Pourmaafi Esfahani, E., Almodarresi, S. A., Mousavi Sanjareei, M., & Haqparast, H. (2023). Assessment of dust emission using artificial neural network model in Kashan County. *Environmental Sciences Quarterly*, 21(2), 69-80. <https://doi.org/10.48308/envs.2023.1177>. [In persian]
23. Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
24. Shi, X., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems*, 28.
25. Sobhani, B., Safarian Zangir, V., & Feizollahzadeh, S. (2020). Dust modeling and prediction in western Iran. *Journal of Natural Geography Research*, 52(1), 17-35. [In persian]
26. Yarmohamadi, M., Alesheikh, A. A., Sharif, M., & Vahidi, H. (2023). Predicting dust-storm transport pathways using a convolutional neural network and geographic context for impact adaptation and mitigation in urban areas. *Remote Sensing*, 15(9), 2468.

A Comparative Analysis of the Performance of Deep Learning Models and Convolutional Neural Networks for Dust Storm Modeling (Case Study: Kermanshah Province)

Mohammad Ansari Ghojghar¹

Received: 09/01/2025

Accepted: 27/04/2024

Extended abstract

Introduction: Understanding the factors contributing to the occurrence of dust storms, along with awareness of their timing and location, is crucial for managing and mitigating the damage they cause. However, limitations such as scarce resources, high costs, and the time needed for monitoring and analysis often impede effective management. Consequently, the application of deep learning models, artificial intelligence algorithms, and neural networks represents a significant advancement towards the forecasting and integrated management of this destructive climatic phenomenon. This study investigates the results of dust storm modeling using deep learning models and convolutional neural networks across nine synoptic meteorological stations in Kermanshah Province (Qasr-e Shirin, Gilan-e Gharb, Sarpol-e Zahab, Eslamabad-e Gharb, Javanrud, Sararud, Ravansar, Harsin, and Kangavar) over a 40-year statistical period (1981–2020). In this context, two computational models—deep learning and convolutional neural networks—were developed and their performance in predicting the FDSD index was compared. While most studies have focused on modeling the frequency index of dust storms using machine learning models, deep learning approaches have been less commonly utilized. Convolutional Neural

1. Assistant Professor, Department of Rehabilitation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran Ansari.ghojghar@ut.ac.ir

Networks, typically employed for image processing and modeling, have been adapted in this research to model dust storms. Furthermore, their performance has been benchmarked against a deep learning model. Accordingly, this research aims to address existing challenges and gaps by examining the performance of deep learning models and Convolutional Neural Networks in dust storm modeling.

Materials and Methods: This study investigates the performance of deep learning models and convolutional neural networks in modeling dust storms across nine meteorological stations in Kermanshah Province (Qasr-e Shirin, Gilan-e Gharb, Sarpol-e Zahab, Eslamabad-e Gharb, Javanrud, Sararud, Ravansar, Harsin, and Kangavar) over a 40-year statistical period (1981–2020). For this purpose, hourly horizontal visibility data and the World Meteorological Organization (WMO) present weather codes were utilized. Meteorological phenomena observations are recorded every three hours, totaling eight synoptic reports per day. In these observations, visual weather phenomena are defined according to the WMO's guidelines using 100 codes ranging from 00 to 99. From these 100 codes, 11 specific codes are commonly used to record and report dust storm events at various meteorological stations. Following the WMO definition, a dust storm day is defined as a day when at least one of the eight synoptic reports includes one of the dust-related codes (06, 07, 08, 09, 30, 31, 32, 33, 34, 35, or 98) in the present weather report, provided that the corresponding horizontal visibility is recorded as less than 1000 meters. In this study, a horizontal visibility of less than 1000 meters was consistently used as the criterion for identifying dust storms for all dust-related codes. This approach ensures the accurate detection and classification of dust storm events throughout the study period.

Results and Discussion: The evaluation metrics R (Pearson correlation coefficient), RMSE (Root Mean Square Error), NS (Nash-Sutcliffe efficiency coefficient), and MAE (Mean Absolute Error) were used to assess and compare the performance of the deep learning model and the convolutional neural network algorithm for dust storm modeling in Kermanshah Province over a 40-year statistical period (1980–2020). The findings from dust storm modeling indicate that at Qasr-e Shirin station, which records the highest seasonal frequency of dust storm days, and Kangavar station, characterized by the lowest seasonal frequency, a clear trend emerges: as the frequency of dusty days' decreases across the studied stations—from Qasr-e Shirin to Kangavar—the accuracy of FDSI index modeling significantly improves. The results reveal statistically significant differences between the models at the 95% and 99% confidence levels. While substantial discrepancies are observed between the outputs of the deep learning (DL) model and the convolutional neural network (CNN), the DL model proves to be the more reliable choice for achieving higher accuracy and enhancing modeling efficiency. Additionally, a t-test comparison of the observed and predicted mean values supports the null hypothesis, validating the equivalence of the observed and predicted time series means for the frequency of dust storm days in Kermanshah Province.

Conclusion: Deep learning models, such as deep artificial neural networks, stand out from other methods due to their superior ability to identify patterns and hidden structures within large datasets. In these networks, each layer learns a concept that is refined and expanded upon in subsequent layers, progressively transforming basic concepts into more complex abstract ones. This study aimed to compare the performance of deep learning models and convolutional neural networks for modeling dust storms at nine meteorological stations in Kermanshah Province (Qasr-e Shirin, Gilan-e Gharb, Sarpol-e Zahab, Eslamabad-e Gharb, Javanrud, Sararud, Ravansar, Harsin, and Kangavar) over a 40-year statistical period. The results indicated that the first seasonal combination was selected as the optimal configuration for predicting the FDSI index using both deep learning and CNN models. Both models demonstrated acceptable accuracy and performance in simulating the frequency of dust storm days. However, the DL model, exhibiting higher correlation coefficients and NS values, along with lower RMSE and MAE error estimation metrics, was identified as the optimal model for dust storm modeling in Kermanshah Province. This advanced technology enables more accurate predictions of the timing, intensity, and path of dust storms, playing a fundamental role in reducing human, economic, and environmental damages. Furthermore, the results from these models can serve as an efficient tool in natural resource management—including water, soil, and vegetation—to mitigate the destructive impacts of storms and improve regional planning.

Keywords: Forecasting, meta-exploration algorithms, dust storms, DL, FDSI index.