

بررسی شبکه عصبی فوریه مبتنی بر ترانسفورمرها به منظور پیش‌بینی شاخص FSD (مطالعه موردی: استان ایلام)

رامتین طاوسی راد^۱، محمد انصاری قوجقار^{۲*}، حسن خسروی^۳

تاریخ دریافت: ۱۴۰۵/۰۱/۲۳

تاریخ پذیرش: ۱۴۰۵/۰۲/۱۴

چکیده

طوفان‌های گردوغبار به‌عنوان یکی از انواع اصلی پدیده‌های حدی اقلیمی شدید به‌ویژه در مناطق خشک و نیمه‌خشک محسوب می‌شوند و تأثیرات قابل توجهی بر سلامت، محیط‌زیست و مدیریت منابع طبیعی دارند. پیش‌بینی دقیق این پدیده همچنان با دشواری‌های جدی مواجه است. مطالعه حاضر قابلیت مدل‌های یادگیری عمیق مدرن برای پیش‌بینی طوفان‌های گردوغبار را با مقایسه عملکرد دو مدل انفرادی، Autoformer، FNO و یک چارچوب هیبریدی بر اساس ترکیب دو مدل برای مقیاس‌های زمانی مختلف بررسی کرد. با توجه به نتایج به‌دست‌آمده، مدل هیبریدی FNO-AutoFormer بالاترین دقت پیش‌بینی را در تمامی شاخص‌های ارزیابی ارائه داد. مقادیر شاخص NS بالای ۰/۹۳۲، مقدار همبستگی بیش از ۰/۹۱۴ و همچنین کاهش قابل توجه خطاهای RMSE و MAE و ثبت مقادیر خطای ۰/۲۶۵ و ۰/۱۷۹ به ترتیب برای شاخص‌ها، عملکرد بهتر مدل‌های ترکیبی به نسبت مدل‌های انفرادی در پیش‌بینی پدیده‌های حدی اقلیمی نشان داد. همچنین یافته‌های پژوهش حاضر ثابت کرد که به‌منظور پیش‌بینی طوفان‌های گردوغبار برای نقاطی که عامل خارجی باعث گردوغبار می‌شود، ترکیب‌های زمانی کوتاه‌مدت به‌ویژه ترکیب پیش‌بینی با یک فصل تأخیر، بهترین عملکرد دارند و دقت پیش‌بینی با افزایش تأخیر زمانی کاهش می‌یابد.

واژگان کلیدی: گردوغبار، مدل‌های داده‌محور، مدل‌های هیبریدی، FNO.

۱. دانشجوی کارشناسی ارشد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

رایانامه: ramintavosirad@ut.ac.ir

۲. نویسنده مسئول، استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، (۰۹۱۲۹۶۷۵۵۴۲). ایران.

رایانامه: ansari.ghojghar@ut.ac.ir

۳. استاد، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

رایانامه: hakhosravi@ut.ac.ir

مقدمه

و همکاران، ۲۰۲۵). الگوریتم‌های هوش مصنوعی و شبکه‌های عصبی گوناگونی نظیر شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)^۴، شبکه‌های کانولوشن موقت (TCN)^۵، مدل (XGBoost)^۶، شبکه‌های عصبی واحد بازگشتی دروازه‌دار (GRU)^۷، ماشین بردار پشتیبان (SVM)^۸ و ... و همچنین ترکیب این مدل‌ها با یکدیگر در مطالعات اقلیمی مورد استفاده قرار گرفته‌اند. برای مثال الشاماری^۹ و همکاران (۲۰۲۴) در پژوهشی به مقایسه مدل‌های LSTM و TCN به منظور پیش‌بینی طوفان‌های گردوغبار کشور عربستان پرداختند. نتایج پژوهش نشان داد شبکه‌های بازگشتی عمیق نظیر LSTM به دلیل توانایی در مدل‌سازی وابستگی‌های زمانی بلندمدت، ابزار مناسبی برای پیش‌بینی فراوانی طوفان‌های گردوغبار در مقیاس زمانی روزانه تا فصلی هستند. همچنین یارمحمدی^{۱۰} و همکاران (۲۰۲۵) در مطالعه‌ای به بررسی مدل هیبریدی CNN-LSTM به منظور پیش‌بینی مسیر حرکت طوفان‌های گردوغبار و مقایسه آن با مدل (ConvLSTM)^{۱۱} پرداختند. نتایج نشان داد مدل هیبریدی (CNN-LSTM) عملکرد بهتری در پیش‌بینی ۲۴ ساعته به ثبت رساند. این مطالعه تأیید می‌کند که مدل‌های یادگیری عمیق مکانی زمانی برای شبیه‌سازی حرکت و گسترش طوفان‌های گردوغبار بسیار کارآمد هستند. همچنین چوبین^{۱۲} و همکاران (۲۰۲۳) به مقایسه مدل‌های جنگل تصادفی زیرفضای وزن‌دار (WSRF)^{۱۳}، مدل خطی عمومی (GLM)^{۱۴}، درخت رگرسیون تقویت شده (BRT)^{۱۵} و ماشین بردار پشتیبان (SVM) به منظور پیش‌بینی حساسیت منطقه مورد مطالعه به گردوغبار و مهمترین عوامل دخیل پرداختند. نتایج نشان داد مدل WRSF عملکرد بهتری به نسبت سایر مدل‌ها به ثبت رساند.

اخیراً دسته جدیدی از مدل‌های داده‌محور که به عنوان اپراتورهای عصبی شناخته می‌شوند، با هدف یادگیری مستقیم

پدیده گردوغبار از مهم‌ترین مخاطرات طبیعی در مناطق خشک بیابانی است. گردوغبار آثار و پیامدهای زیست‌محیطی نامطلوبی بر روی سلامت انسان، اقتصاد جامعه و اقلیم دارد (انصاری قوجقار^۱ و همکاران، ۲۰۲۵). گردوغبار همچنین تأثیرات منفی بر چرخه آب، فرآیندهای بیولوژیکی، چرخه کربن و پایداری اتمسفر دارد (پاپی و همکاران، ۲۰۲۱).

قرار گرفتن کشور ایران در کمربند بیابانی سبب افزایش رخدادهای طبیعی در جهت ایجاد گردوغبار شده است. مدیریت کارآمد این رویدادهای مخرب به شناخت ویژگی‌ها و میزان گستردگی آن‌ها نیاز دارد. منشأ ۷۰٪ از گردوغبارهای موجود در غرب ایران کشور عراق است. به‌طورکلی چهار کانون اصلی در عراق و دو کانون در شمال شرق سوریه و شرق عربستان شناسایی شده است. در سال‌های اخیر با افزایش فراوانی طوفان‌های گردوغبار، شناسایی، پایش و پیش‌بینی تکامل آن‌ها امری ضروری گردیده است (انصاری قوجقار و همکاران، ۲۰۲۲).

شناخت روند طوفان‌های گردوغبار در کشور و میزان ارتباط آن با نوسانات اقلیمی یکی از مهمترین راهکارهای کاهش خسارات ناشی از این پدیده است؛ زیرا می‌توان علاوه بر مشخص نمودن سهم هر یک از متغیرهای اقلیمی در تشدید این وضعیت، اولویت‌ها و سیاست‌های کلان مدیریتی را مشخص نمود (پورغلام آمیجی و همکاران، ۲۰۲۱). اغلب مطالعات گردوغبار از نظر پایش و مدل‌سازی این‌گونه طوفان‌ها با استفاده از مدل‌های عددی، داده‌های سنجش از دور و GIS انجام شده است (بهرامی و همکاران، ۲۰۱۴). در سال‌های اخیر، روش‌های هوش مصنوعی^۲ و شبکه‌های عصبی^۳ که به‌صورت بسته سیاه عمل می‌کنند در مباحث هیدرولوژی و اقلیمی استفاده شده‌اند (وطن‌پرست قلعه جوق

9. Alshammari
10. Yarmohamadi
11. Convolutional Long Short-Term Memory
12. Choubin
13. weighted subspace random forest
14. general linear model
15. boosted regression tree

1. Ansari ghoghhar
2. Artificial Inteligence
3. Neural Networks
4. Long Short-Term Memory
5. Temporal Convolutional Network
6. Extreme Gradient Boosting
7. Gated Recurrent Unit
8. Support Vector Machine

تمرکز داشته‌اند یا از معماری‌هایی بهره گرفته‌اند که تنها یکی از جنبه‌های زمانی یا مکانی پدیده گردوغبار را مدنظر قرار داده‌اند. در این میان، مدل‌های مبتنی بر ترانسفورمر نظیر Autoformer عمدتاً برای استخراج وابستگی‌های زمانی بلندمدت توسعه‌یافته‌اند درحالی‌که اپراتورهای عصبی مانند FNO بر یادگیری الگوهای مکانی-طیفی و اپراتورهای حاکم بر سیستم‌های فیزیکی متمرکز هستند. همچنین مدل‌های مورد پژوهش به‌ندرت در پیش‌بینی وقایع حدی اقلیمی مانند طوفان‌های گردوغبار مورد استفاده قرار گرفته‌اند. با این حال تاکنون ادغام این دو مدل داده‌محور به‌منظور بهره‌گیری هم‌زمان از مزایای آن‌ها در مدل‌سازی طوفان‌های گردوغبار انجام نشده است. از سوی دیگر اغلب پژوهش‌های موجود، عملکرد مدل‌ها را در یک تأخیر زمانی مشخص بررسی کرده‌اند و نقش ترکیب‌های زمانی مختلف در پیش‌بینی طوفان‌های گردوغبار به‌ویژه در مناطق با منشأ متفاوت گردوغبار، کمتر مورد توجه قرار گرفته است. عدم توجه به تفاوت‌های مکانی-زمانی سبب شده است که مدل‌های پیشنهادی در بسیاری از مطالعات، عملکرد متوسط داشته و موفق به بازنمایی کامل رفتار واقعی پدیده نباشند. بر این اساس، پژوهش حاضر با هدف پر کردن این خلأ علمی، یک چارچوب نوین مدل‌سازی مبتنی بر ترکیب مدل‌های Autoformer و FNO ارائه می‌دهد و عملکرد آن را در پیش‌بینی طوفان‌های گردوغبار در ترکیب‌های زمانی مختلف ارزیابی می‌کند. تلفیق توان Autoformer در یادگیری وابستگی‌های زمانی بلندمدت و ساختارهای دوره‌ای سری‌های زمانی با قابلیت FNO در استخراج الگوهای مکانی-طیفی و تقریب اپراتورهای حاکم بر سیستم‌های پیچیده نهفته است. این ترکیب امکان مدل‌سازی هم‌زمان دینامیک‌های زمانی و مکانی پدیده گردوغبار را فراهم می‌سازد و محدودیت‌های مدل‌های انفرادی را به‌طور معناداری کاهش می‌دهد.

حل معادلات دیفرانسیل با مشتقات جزئی (PDE)^۱ معرفی شدند (لی و همکاران، ۲۰۲۴). برخلاف شبکه‌های عصبی سنتی، مدل (FNO)^۲ اپراتور حل را مدل‌سازی می‌کند و به آن امکان می‌دهد تا چندین نمونه را به‌طور هم‌زمان پیش‌بینی کند. این ویژگی باعث می‌شود FNO بسیار فراگیر شده و قادر به گرفتن طیف گسترده‌تری از پاسخ‌ها باشد زیرا به یک نمونه یا شرایط خاص محدود نمی‌شود (کاستا روچا^۳، ۲۰۲۵). ماهش^۴ و همکاران (۲۰۲۵) در مطالعه‌ای از مدل FNO کروی به‌منظور پیش‌بینی پدیده‌های حدی اقلیمی و رویدادهای حدی با احتمال وقوع کم پرداخته شد. نتایج نشان داد که FNO کروی می‌تواند در یک سیستم بزرگ استفاده شود تا به‌صورت احتمالاتی رویدادهای حدی را مدل‌سازی کند. این مقاله یکی از معدود نمونه‌های علمی است که FNO را به‌طور مستقیم برای شبیه‌سازی و تحلیل رویداد حدی با احتمالات به‌کاربرده است.

مدل‌های ترانسفورمر^۵ متعارف با مکانیسم‌های خود-توجه^۶ از نظر محاسباتی برای پیش‌بینی بلندمدت به دلیل پیچیدگی درجه دوم طول دنباله، بازدارنده هستند. به‌منظور پیش‌بینی سری‌های زمانی بلندمدت، Autoformer اصلی را جایگزین ترانسفورمرها می‌کند. مدل Autoformer همچنان ساختار باقی‌مانده و رمزگذار^۷-رمزگشا^۸ را دنبال می‌کند اما ترانسفورمر را به یک معماری پیش‌بینی تجزیه‌ای نوسازی می‌کند. Autoformer با الهام از نظریه فرایند تصادفی یک مکانیسم خود-همبستگی^۹ را به‌جای خود-توجه معرفی می‌کند که شباهت زیر سری را بر اساس تناوب سری کشف می‌کند (وو^{۱۰} و همکاران، ۲۰۲۱).

باوجود پیشرفت‌های قابل توجه در مدل‌سازی طوفان‌های گردوغبار، مرور پژوهش‌ها نشان می‌دهد که همچنان خلأهای مهمی در این حوزه وجود دارد. بخش عمده‌ای از مطالعات پیشین بر مدل‌های انفرادی یادگیری ماشین و شبکه‌های عصبی

۶. Self-Attention

۷. Encoder

۸. Decoder

۹. Auto-Correlation

۱۰. Wu

۱. Partial Differential Equations

۲. Fourier neural operator

۳. Costa Rocha

۴. Mahesh

۵. Transformer

روش‌شناسی پژوهش

منطقه مورد مطالعه

که در شکل ۱ مشخص گردیده، پرداخته شده است. بر اساس تعریف ارائه شده توسط سازمان جهانی هواشناسی (WMO^۱)، وقوع طوفان گردوغبار به روزی اطلاق می‌شود که در آن، حداقل در یکی از هشت نوبت گزارش‌های سینوپتیکی یکی از کدهای مرتبط با پدیده گردوغبار شامل ۰۶، ۰۷، ۰۸، ۰۹، ۳۰، ۳۱، ۳۲، ۳۳، ۳۴، ۳۵ یا ۹۸ در بخش وضعیت هوای حاضر ثبت شده باشد. علاوه بر این، برای تأیید وقوع طوفان گردوغبار، لازم است مقدار دید افقی متناظر با کد گزارش شده کمتر از ۱۰۰۰ متر باشد (اولوسینگ^۲ و همکاران، ۲۰۱۴). بر این اساس، در پژوهش حاضر از داده‌های ساعتی دید افقی با آستانه کمتر از ۱۰۰۰ متر به عنوان معیار تشخیص رخداد طوفان‌های گردوغبار استفاده شده است.

در پژوهش حاضر به بررسی مقایسه مدل‌سازی فراوانی روزهای همراه با طوفان گردوغبار با استفاده از مدل یادگیری عمیق FNO و مدل ترانسفورمر AutoFormer به منظور پیش‌بینی شاخص FDSO (فراوانی روزهای همراه با طوفان‌های گردوغبار) در هشت ایستگاه هواشناسی استان ایلام (مهران، دهلران، دویرج، ایلام، ایوان غرب، ارکواز ملک، چم‌گز و کهره هلیان) با طول دوره آماری ۴۰ سال (۲۰۲۰-۱۹۸۱)

جدول (۱): کدهای سازمان جهانی هواشناسی مرتبط با فرسایش بادی و پدیده‌های گردوغبار (O'Loingsigh et al. 2014).

کد	توضیحات
۰۶	رخداد طوفان گردوخاک گسترده در خارج از ایستگاه هواشناسی
۰۷	خاک یا شن برخواسته 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	رعدوبرق- بدون بارش- همراه با طوفان شن یا خاک




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

مدل عملگر عصبی فوریه (FNO)

عملیات کانولوشن طیفی قابل یادگیری حفظ می‌شوند. حد نایکوئیست^۲ نشان می‌دهد که هرگز نباید مدهایی را که مربوط به فرکانس‌های بالاتر از $N/2$ هستند وارد کرد جایی که N وضوح سیگنال است (دوروسیکس^۳ و همکاران، ۲۰۲۵). چارچوب مدل FNO در شکل ۳ ارائه شده است:

در میان مدل‌های عملگر عصبی به‌ویژه عملگرهای عصبی فوریه (FNO)، کاربرد موفق در محاسبات علمی برای وظیفه یادگیری اپراتور حل معادلات دیفرانسیل با مشتقات جزئی داشته‌اند. (کاسایف^۱ و همکاران، ۲۰۲۳). در معماری FNO تنها تعداد محدودی از مدهای فوریه برای



شکل (۲): شبکه FNO: پارامتر PDE ورودی \mathbf{a} از \mathbf{P} به $V_0(X)$ منتقل می‌شود سپس در فضای فوریه تکرار می‌شود تا $V_t(X)$ به دست آید و در نهایت از \mathbf{Q} عبور می‌کند تا به بعد فضایی حل \mathbf{u} برسد (گو و لی، ۲۰۲۵).

ساختار پایه FNO از سه قسمت تشکیل شده است. بلند

$$(K(a; \phi) * v_t)(x) = \int_D k(a(x, y), x, y; \phi) v_t(y) dy, \forall x \in D$$

کردن (lifting) ورودی به فضای ویژگی، اعمال چند فوریه و سپس پروژه کردن خروجی به فضای تابعی هدف (لی^۵ و همکاران، ۲۰۲۱). لایه شبکه عملگر عصبی FNO در رابطه ۱ و ۲ مشخص شده است: رابطه (۱)

$$v_0(x) = P(A(x)), \quad v_{t+1} = \sigma(W_{v_t}(x) + (K(a; \phi) * v_t)(x)), \quad u(x) = Q_{v_T}(x)$$

۴. Gou & Li

۵. Li

۱. Kossaiifi

۲. Nyquist

۳. Duruisseaux

مدل (AutoFormer)

Autoformer یک معماری نوین بر پایه ساختار ترانسفورمر است که به طور خاص برای پیش‌بینی بلندمدت سری‌های زمانی طراحی شده است. مدل‌های مبتنی بر ترانسفورمر کلاسیک به دلیل بهره‌گیری از مکانیزم خود توجه در یادگیری وابستگی‌های بلندبرد دچار محدودیت‌های محاسباتی و کاهش کارایی در دنباله‌های طولانی می‌شوند. Autoformer این چالش‌ها را با دو نوآوری اساسی معماری تجزیه^۱ و مکانیزم خود-همبستگی برطرف می‌کند و وابستگی‌ها را در سطح زیرسری‌های هم‌فاز ادغام می‌کند (وو و همکاران، ۲۰۲۱)

باتوجه به شکل ۲ در مدل Autoformer هر لایه از مدل هم‌زمان با فرایند پیش‌بینی، سیگنال ورودی را به دو مؤلفه مجزا روند^۲ و فصل‌گرایی^۳ تجزیه می‌کند. این کار با استفاده از یک بلوک تجزیه سری^۴ انجام می‌شود که از عملیات میانگین متحرک^۵ برای جداسازی قسمت روند از مابقی اطلاعات استفاده می‌کند. در هر لایه‌ی رمزگذار، روند از داده بازمی‌ماند و بخش فصلی به‌طور متمرکز مدل‌سازی می‌شود. در بخش رمزگشا این دو مؤلفه پس از اعمال مکانیزم خود-همبستگی و لایه‌های پیش‌ران^۶ با هم ترکیب می‌شوند تا پیش‌بینی نهایی تولید شود (کاتانو^۷ و همکاران، ۲۰۲۵).

می‌دهد. در ادامه، $v_t(x)$ نمایش نهفته در گام تکرار t ام شبکه بوده و $v_{t+1}(x)$ از طریق ترکیب یک عملگر خطی موضعی و یک عملگر کانولوشن انتگرالی غیرموضعی به‌روزرسانی می‌شود. در این رابطه، $W_{v_t}(x)$ یک تبدیل خطی قابل‌آموزش است که وابستگی‌های موضعی ویژگی‌ها را در هر گام زمانی مدل‌سازی می‌کند و $\sigma()$ تابع فعال‌ساز غیرخطی است که معمولاً به‌صورت توابعی نظیر ReLU یا GELU تعریف می‌شود و نقش کلیدی در افزایش توان بازنمایی شبکه دارد. عبارت $(K(a; \phi) * v_t)(x)$ بیان‌گر عملگر انتگرالی غیرموضعی بوده که تعاملات مکانی-طیفی بلندبرد را در سراسر دامنه D در نظر می‌گیرد. در این عبارت، $K(a; \phi)$ کرنل انتگرالی پارامتردهی شده است که به‌وسیله پارامترهای قابل‌آموزش ϕ مشخص می‌شود و به‌طور صریح به ویژگی‌های ورودی (x, y) و مختصات مکانی x و y وابسته است. انتگرال تعریف‌شده بر روی دامنه D نشان‌دهنده تجمع اطلاعات از تمامی نقاط $y \in D$ برای به‌روزرسانی مقدار ویژگی در نقطه x است که امکان یادگیری الگوهای غیرموضعی و وابستگی‌های فضایی پیچیده را برای مدل فراهم می‌سازد. پس از T لایه تکراری از این نگاهت، نمایش نهایی ویژگی‌ها به‌صورت $v_t(x)$ حاصل می‌شود. در نهایت، عملگر $Q()$ به‌عنوان نگاهت کاهنده (Projection Operator) عمل کرده و خروجی شبکه (x) را از فضای ویژگی نهفته به فضای خروجی مورد نظر منتقل می‌کند که بیان‌گر پیش‌بینی نهایی مدل است (گو و لی، ۲۰۲۰).

۵. Moving Average

۶. Feed-Forward

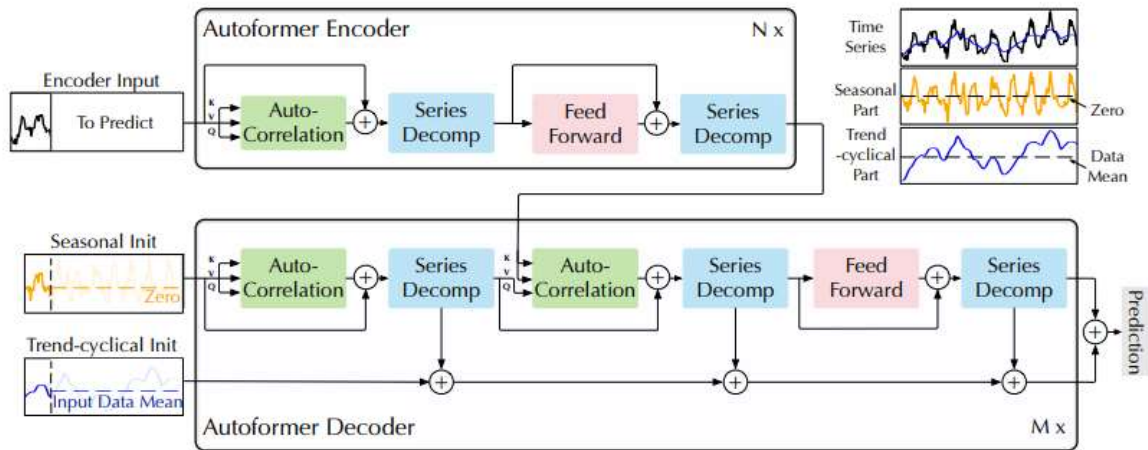
۷. Caetano

۱. Decomposition Architecture

۲. trend-cyclical

۳. Seasonal

۴. Series Decomposition



شکل (۳): معماری **Autoformer**. رمزگذار با حذف بخش روند- چرخه‌ای بلندمدت توسط بلوک‌های تجزیه سری (بلوک‌های آبی) بر مدل‌سازی الگوهای فصلی تمرکز می‌کند. رمزگشا به تدریج بخش روند استخراج‌شده از متغیرهای پنهان را جمع می‌کند. اطلاعات فصلی گذشته از رمزگذار توسط خود-همبستگی رمزگذار-رمزگشا (بلوک سبز مرکزی در رمزگشا) استفاده می‌شود (وو و همکاران، ۲۰۲۱).

همان‌طور که در شکل ۲ نشان داده شده است، لایه رمزگذار بر مدل‌سازی بخش فصلی تمرکز دارد. خروجی رمزگذار شامل اطلاعات فصلی گذشته است و به‌عنوان اطلاعات متقابل برای کمک به رمزگشا در پاک‌سازی نتایج

پیش‌بینی استفاده خواهد شد. با فرض اینکه N لایه رمزگذار وجود دارد. معادلات کلی برای لایه l ام رمزگذار به صورت $X_{en}^l = Encoder(X_{en}^{l-1})$ خلاصه می‌شوند و در رابطه ۳ و ۴ نشان داده است:

$$S_{en,-}^{l,1} = SeriesDecomp(Auto - Correlation(X_{en}^{l-1}) + X_{en}^{l-1}) \quad \text{رابطه (۳)}$$

$$S_{en,-}^{l,2} = SeriesDecomp(FeedForward(S_{en}^{l-1}) + S_{en}^{l-1}) \quad \text{رابطه (۴)}$$

که در آن $X_{en}^l = S_{en}^{l,2}$ بخش حذف شده روند است. $l \in \{1, \dots, N\}$ نشان‌دهنده خروجی لایه l ام رمزگذار و X_{en}^0 تعبیه شده است. $X_{en}^l, S_{en}^{l,i}, l \in \{1, 2\}$ به ترتیب نشان‌دهنده مؤلفه فصلی پس از l امین بلوک تجزیه سری در لایه l ام است. لایه رمزگشا شامل ساختار انباشت برای مؤلفه‌های روند- چرخه‌ای و مکانیزم خود-همبستگی پشته‌ای برای مؤلفه‌های فصلی می‌باشد (شکل ۱). هر لایه رمزگشا شامل خود-

همبستگی داخلی و خود-همبستگی رمزگذار-رمزگشا است که به ترتیب می‌تواند پیش‌بینی را پاک‌سازی کند و از اطلاعات فصلی گذشته استفاده کند. اگر M لایه رمزگشا وجود داشته باشد با متغیر پنهان X_{en}^N از رمزگذار، معادلات لایه l ام رمزگشا را می‌توان به صورت $X_{de}^{l-1} = Decoder(X_{de}^{l-1}, X_{en}^N)$ خلاصه کرد. لایه رمزگشا به صورت روابط ۵ تا ۸ تعریف می‌شود:

$$S_{de}^{l,1}, T_{de}^{l,1} = SeriesDecomp(Auto - Correlation(X_{de}^{l-1}) + X_{de}^{l-1}) \quad \text{رابطه (۵)}$$

$$S_{de}^{l,2}, T_{de}^{l,2} = SeriesDecomp(Auto - Correlation(S_{de}^{l-1}) + X_{en}^N) + S_{de}^{l,1} \quad \text{رابطه (۶)}$$

$$S_{de}^{l,3}, T_{de}^{l,3} = SeriesDecomp(FeedForward(S_{de}^{l,2}) + S_{de}^{l,2}) \quad \text{رابطه (۷)}$$

$$T_{de}^l = T_{de}^{l-1} + W_{l,1} * T_{de}^{l,1} + W_{l,2} * T_{de}^{l,2} + W_{l,3} * T_{de}^{l,3} \quad \text{رابطه (۸)}$$

معیارهای ارزیابی مدل

در پژوهش حاضر به منظور سنجش عملکرد و دقت پیش‌بینی مدل‌ها از مجموعه‌ای از شاخص‌های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب نش-ساتکلیف (NS) مطابق با روابط (۸) تا (۱۱) استفاده شده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - f_i)^2} \quad \text{رابطه (۸)}$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |\hat{o}_i - f_i| \quad \text{رابطه (۹)}$$

$$NS = 1 - \frac{\sum_{i=1}^n (o_i - f_i)^2}{\sum_{i=1}^n (\bar{o} - o_i)^2} \quad \text{رابطه (۱۰)}$$

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\sum_{i=1}^n (f_i - \bar{f})^2}} \quad \text{رابطه (۱۱)}$$

استفاده قرار گرفت. به منظور ترکیب دو مدل مورد مطالعه، داده‌های ورودی پس از مرتب‌سازی، حذف داده‌های پرت و آماده‌سازی داده‌ها تقسیم‌بندی می‌شوند. ۸۰٪ داده‌ها برای آموزش مدل استفاده شده و ۲۰٪ به منظور آزمون و ارزیابی مدل‌ها مورد استفاده قرار می‌گیرد. پس از آموزش مدل اول خروجی به دست آمده از مدل اول به عنوان ورودی مدل دوم به کار گرفته می‌شود. به منظور پیش‌بینی مقدار شاخص FDSD در فصل آینده از مقادیر گذشته این شاخص به عنوان متغیرهای تأخیری بهره گرفته شد. به منظور بررسی تأثیر طول حافظه زمانی سیستم و نقش اطلاعات گذشته بر دقت پیش‌بینی، چهار سناریوی مختلف تأخیری طراحی گردید. در هر یک از این سناریوها، هدف مدل‌ها برآورد مقدار شاخص FDSD در فصل آینده $FDSD_{(t+1)}$ بر اساس مقادیر مشاهده شده این شاخص

که در آن $X_{de}^{l-1} = S_{de}^{l,3}, l \in \{1, \dots, M\}$ نشان‌دهنده خروجی لایه l رمزگشا است. $X_{des}^0 | X_{de}^0$ تعبیه شده است برای تبدیل عمیق و $T_{de}^0 = X_{det}$ برای انباشت است. $S_{de}^{l,i}, T_{de}^{l,i}, i \in \{1,2,3\}$ به ترتیب نشان‌دهنده مؤلفه فصلی و مؤلفه روند چرخه‌ای پس از i امین بلوک تجزیه سری در لایه l ام است. $W_{l,i}, i \in \{1,2,3\}$ نشان‌دهنده پروژکتور برای i امین روند استخراج شده $T_{de}^{l,i}$ است (وو و همکاران، ۲۰۲۱).

در روابط ۸ تا ۱۱، f_i مقادیر پیش‌بینی شده در گام زمانی t ام، o_i مقادیر مشاهداتی در گام زمانی t ام، \bar{f} میانگین مقادیر پیش‌بینی شده، n تعداد داده‌ها و \bar{o} میانگین مقادیر مشاهداتی می‌باشد.

مدل‌های پیش‌بینی

در پژوهش حاضر، به منظور پیش‌بینی شاخص فراوانی و شدت طوفان‌های گردوغبار (FDSD)، عملکرد دو مدل انفرادی یادگیری عمیق شامل مدل‌های FNO، AutoFormer و ترکیب این دو مدل مورد ارزیابی قرار گرفت. داده‌های ورودی مدل‌ها مبتنی بر سری زمانی فصلی شاخص FDSD استخراج شده از ۸ ایستگاه منتخب بوده و پس از پردازش اولیه، مقادیر فصلی این شاخص به عنوان متغیر هدف در فرآیند پیش‌بینی و مدل‌سازی زمانی بر اساس فصول گذشته مورد

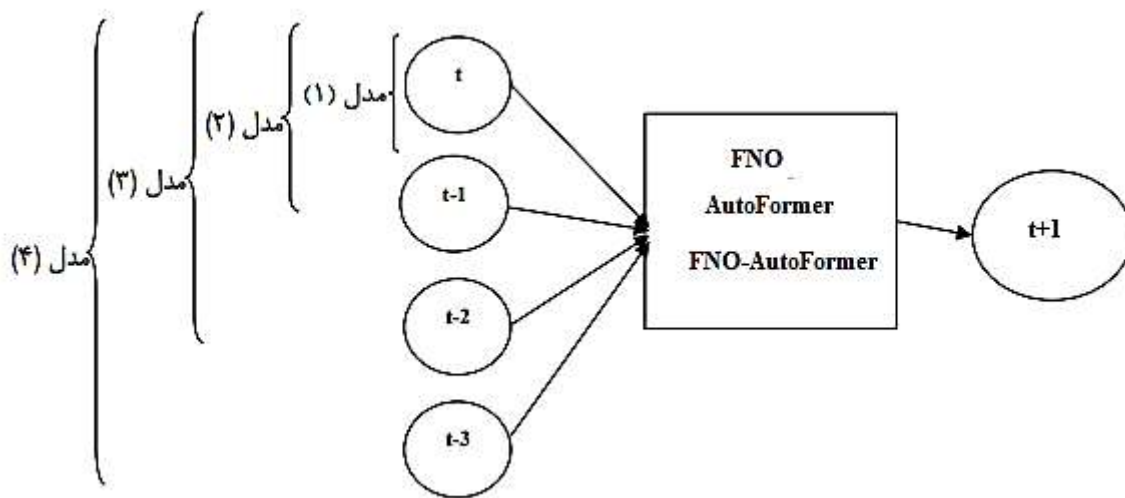
در فصل‌های پیشین است. ساختار ترکیب‌های ورودی مدل‌ها بین‌ی در سال آتی و نمودار جریانی پژوهش در شکل ۵ نمایش به‌صورت ترکیب ۱ تا ۴ تعریف می‌شود. همچنین در شکل ۴ داده شده است. مدل‌های مورد استفاده در انتخاب فصول گذشته برای پیش

$$FDS_{D(t+1)} \hat{=} FDS_{D(t)} \tag{۱} \text{ ترکیب}$$

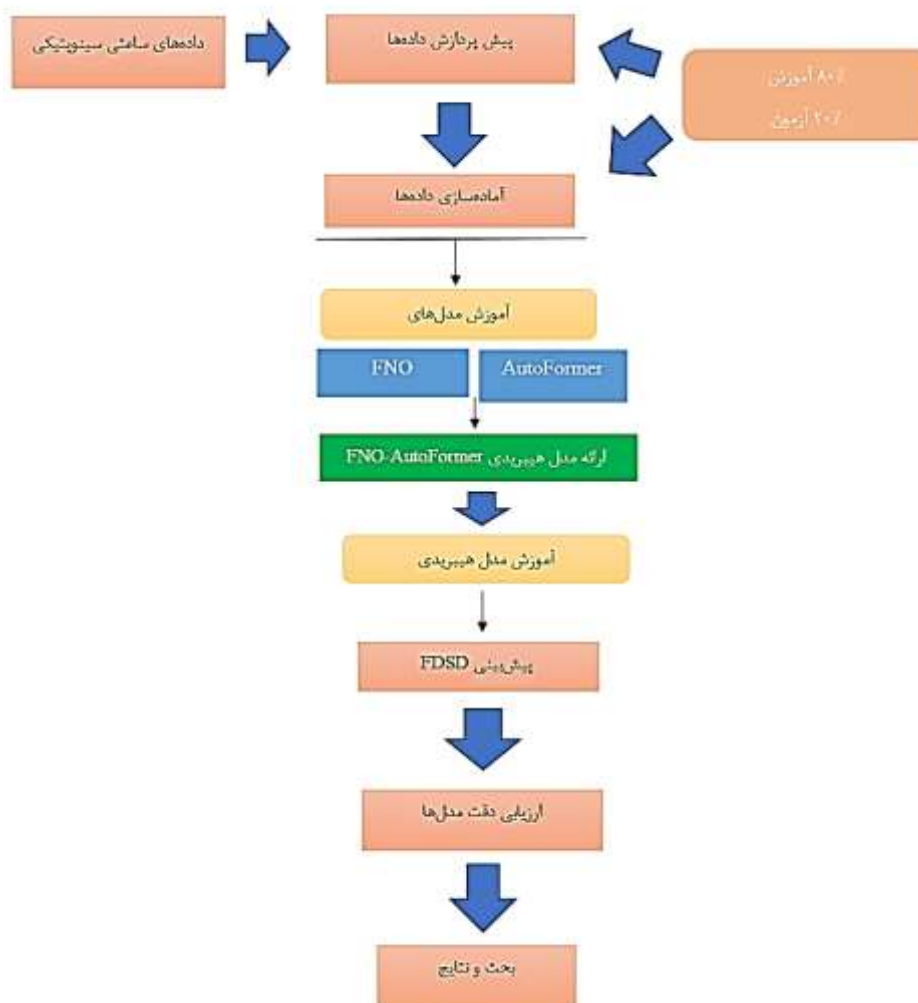
$$FDS_{D(t+1)} \hat{=} (FDS_{D(t)} \cdot FDS_{D(t-1)}) \tag{۲} \text{ ترکیب}$$

$$FDS_{D(t+1)} \hat{=} (FDS_{D(t)} \cdot FDS_{D(t-1)} \cdot FDS_{D(t-2)}) \tag{۳} \text{ ترکیب}$$

$$FDS_{D(t+1)} \hat{=} (FDS_{D(t)} \cdot FDS_{D(t-1)} \cdot FDS_{D(t-2)} \cdot FDS_{D(t-3)}) \tag{۴} \text{ ترکیب}$$



شکل (۴): ساختارهای مورد استفاده در پیش‌بینی شاخص FDS



شکل (۵): فلوچارت مراحل انجام پژوهش

بحث و نتایج

بوده و مدل در برآورد دقیق شدت پدیده موفق عمل نکرده است. مقادیر ضریب همبستگی (R) نیز که بین ۰/۵۱۴ تا ۰/۵۵۳ به دست آمد که حاکی از ضعف این مدل در شناسایی روابط خطی بین داده‌های مشاهده‌ای و مقادیر شبیه‌سازی شده است. پس از مدل Autoformer، مدل FNO در رتبه بعدی قرار گرفت. اگرچه عملکرد مدل FNO نسبت به مدل Autoformer بهبود نسبی نشان داد اما اختلاف آن از نظر آماری چندان معنادار نبود. مقادیر NS برای FNO در بازه ۰/۶۷۳ تا ۰/۷۰۵ محاسبه شد که نشان‌دهنده توان متوسط مدل در بازنمایی زمانی گردوغبار است. همچنین مقادیر RMSE بین ۰/۴۰۴ تا ۰/۴۶۲ و MAE در بازه ۰/۳۲۷ تا ۰/۳۹۶ بیان‌گر کاهش خطا نسبت به مدل Autoformer است. هرچند این بهبود برای دستیابی به یک مدل دقیق و قابل اتکا کافی به نظر

باتوجه به جداول ۲ تا ۴، نتایج حاصل از ارزیابی عملکرد مدل‌های FNO، Autoformer و مدل هیبریدی FNO-Autoformer نشان داد که تفاوت معناداری میان توان پیش‌بینی مدل‌های مورد مطالعه در مدل‌سازی طوفان‌های گردوغبار و پیش‌بینی شاخص FDSF وجود دارد. بر اساس شاخص‌های آماری مورد استفاده، مدل Autoformer ضعیف‌ترین عملکرد را در میان مدل‌های بررسی شده از خود نشان داد. مقادیر شاخص کارایی NS برای این مدل در بازه ۰/۵۹۶ تا ۰/۶۳۶ قرار داشت که بیان‌گر توان محدود آن در بازتولید تغییرات مشاهداتی گردوغبار است. همچنین مقادیر RMSE بین ۰/۴۷۱ تا ۰/۵۳۵ و MAE در بازه ۰/۳۷۶ تا ۰/۴۳۴ نشان می‌دهد که خطای پیش‌بینی مدل Autoformer نسبتاً بالا

مکانی، نتایج به‌دست‌آمده نشان می‌دهد که در مناطق غربی کشور که بخش قابل‌توجهی از طوفان‌های گردوغبار منشأ خارجی دارند، الگوهای زمانی ساده‌تر و قابل‌پیش‌بینی‌تری حاکم است. در این مناطق، ترکیب‌های زمانی کوتاه‌مدت عملکرد بهتری داشته‌اند که می‌تواند ناشی از تأثیر مستقیم و سریع منابع فرامرزی گردوغبار باشد. این یافته با نتایج گزارش‌شده انصاری فوجقار و پورمحمد (۱۴۰۴) در مطالعات انجام‌شده استان ایلام هم‌راستاست. در این پژوهش نشان دادند گردوغبار این مناطق عمدتاً تحت تأثیر سامانه‌های ورودی سریع از عراق و سوریه قرار دارد و پیچیدگی زمانی کمتری دارد. در مقابل، در مناطق شرقی کشور که گردوغبار بیشتر تحت تأثیر عوامل محلی، شرایط سطح زمین و فرآیندهای پیچیده‌تر جوی قرار دارد، رفتار پدیده پیچیده‌تر بوده و نیازمند مدل‌هایی با توان بالاتر در یادگیری هم‌زمان وابستگی‌های زمانی و مکانی است (طاوسی راد و همکاران، ۱۴۰۴). برتری مدل هیبریدی FNO-Autoformer در چنین شرایطی نشان می‌دهد که ترکیب قابلیت Autoformer در استخراج الگوهای زمانی و دوره‌ای با توان FNO در یادگیری نگاشت‌های غیرمحلی و پیوسته می‌تواند راهکاری مؤثر برای مدل‌سازی دقیق‌تر طوفان‌های گردوغبار در مقیاس‌های مختلف زمانی و مکانی باشد.

نتایج حاصل از این پژوهش نشان داد که عملکرد مدل‌های انفرادی Autoformer و FNO در پیش‌بینی طوفان‌های گردوغبار پیش‌بینی فاصله‌ی معناداری با مدل هیبریدی پیشنهادی دارند. مدل Autoformer ضعیف‌ترین عملکرد را در تمامی ترکیب‌های زمانی از خود نشان داد. اگرچه مدل FNO نسبت به Autoformer عملکرد بهتری داشت اما همچنان به‌عنوان یک مدل انفرادی دقت قابل‌قبولی را ثبت نکرد. نتایج نشان داد مدل FNO برای توصیف وابستگی‌های زمانی چندبعدی مرتبط با شکل‌گیری طوفان‌های گردوغبار محدودیت دارد. این موضوع با نتایج مطالعات اخیر در حوضه کاربرد FNO در پیش‌بینی پدیده‌های اقلیمی حدی هم‌راستاست؛ نتایج مطالعات سینها و همکاران (۲۰۲۵) نشان می‌دهد عملگرهای عصبی مانند مدل FNO به‌صورت انفرادی در مدل‌سازی سیستم‌های

نمی‌رسد. ضریب همبستگی R نیز در محدوده ۰/۵۹۴ تا ۰/۶۳۸ قرار گرفت که نسبت به Autoformer بهتر بود اما همچنان ضعف مدل در استخراج کامل الگوهای پیچیده مکانی زمانی پدیده گردوغبار را نشان می‌دهد. این موضوع می‌تواند ناشی از آن باشد که مدل FNO به‌تنهایی علی‌رغم توانایی در یادگیری الگوهای تابعی و ساختارهای غیرمحلی در مواجهه با سری‌های زمانی ناپایدار و شدیداً غیرخطی گردوغبار، نیازمند اطلاعات زمانی تکمیلی است. در مقابل، مدل هیبریدی حاصل از ترکیب Autoformer و FNO به‌عنوان قوی‌ترین و کاراترین مدل شناسایی شد و به‌طور معناداری تمامی مدل‌های پایه را پشت سر گذاشت. مقادیر NS برای مدل هیبریدی در بازه بسیار مطلوب ۰/۹۳۲ تا ۰/۹۷۶ قرار داشت که بیان‌گر بازتولید بسیار دقیق تغییرات مشاهده‌ای و عملکرد عالی مدل در مدل‌سازی طوفان‌های گردوغبار است. همچنین کاهش چشمگیر خطا در این مدل هیبریدی مشهود بود. به‌طوری‌که RMSE بین ۰/۱۹۶ تا ۰/۲۶۵ و MAE در بازه ۰/۱۰۵ تا ۰/۱۷۹ محاسبه شد. مقادیر به‌دست‌آمده از مدل هیبریدی، کاهش قابل‌توجهی را نسبت به Autoformer و FNO به‌صورت انفرادی نشان می‌دهد که بیان‌گر توان بالای مدل هیبریدی در پیش‌بینی شدت و نوسانات گردوغبار است. ضریب همبستگی R نیز که بین ۰/۹۱۴ تا ۰/۹۵۸ به‌دست آمد، نشان‌دهنده تطابق بسیار قوی بین داده‌های شبیه‌سازی‌شده و مشاهداتی و موفقیت مدل در استخراج روابط زمانی حاکم بر پدیده است. بررسی اثر ترکیب‌های زمانی مختلف نیز نتایج قابل‌توجهی را آشکار کرد. در این مطالعه، چهار ترکیب زمانی به‌منظور بررسی اثر حافظه زمانی سیستم بر مدل‌سازی گردوغبار مورد استفاده قرار گرفت. نتایج نشان داد که در تمامی مدل‌ها، بهترین عملکرد مربوط به ترکیب اول بوده است و با افزایش طول بازه زمانی ورودی، دقت مدل‌ها به‌تدریج کاهش یافته است؛ به‌طوری‌که ترکیب دوم عملکرد بهتری نسبت به ترکیب سوم و ترکیب سوم نیز بهتر از ترکیب چهارم عمل کرده است. این الگو نشان می‌دهد که پدیده گردوغبار دارای حافظه زمانی کوتاه‌مدت‌تری است و اطلاعات نزدیک‌تر به زمان پیش‌بینی، نقش تعیین‌کننده‌تری در بازتولید رفتار آن دارند. از دیدگاه اقلیمی و

پیچیده دقت کافی را نداشته و به منظور افزایش دقت پیش‌بینی‌ها نیاز به ترکیب با چارچوب‌های زمانی یا شبکه‌های مکمل است. در مقابل، مدل هیبریدی FNO-AutoFormer به‌عنوان کارآمدترین چارچوب مدل‌سازی در این پژوهش شناخته شد و در تمامی ترکیب‌های زمانی عملکردی برتر ارائه داد. نتایج نشان می‌دهد که ادغام قابلیت مدل Autoformer در استخراج وابستگی‌های زمانی بلندمدت با توان مدل FNO در مدل‌سازی الگوهای مکانی و طیفی، منجر به بازنمایی دقیق‌تر سازوکارهای فیزیکی و آماری مؤثر بر طوفان‌های گردوغبار شده است. این نتیجه کاملاً با یافته‌های یارمحمدی و همکاران (۲۰۲۵) همسو است که نشان داده‌اند مدل‌های هیبریدی در مقایسه با مدل‌های انفرادی، توان پیش‌بینی پدیده‌های گردوغباری را به‌طور قابل‌توجهی بهبود می‌دهند. در مجموع، نتایج این پژوهش به‌وضوح نشان می‌دهد که استفاده از مدل‌های انفرادی به‌ویژه برای پدیده‌های اقلیمی پیچیده‌ای مانند طوفان‌های گردوغبار با محدودیت‌های جدی همراه است و توسعه رویکردهای ترکیبی می‌تواند با بهره‌گیری هم‌زمان از مزایای معماری‌های مختلف، دقت و پایداری پیش‌بینی را به‌طور معناداری افزایش دهد.

جدول (۲): نتایج آماری داده‌های ورودی مدل FNO به‌منظور پیش‌بینی شاخص FDS

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		NS	RMSE	MAE	R	NS	RMSE	MAE	R
مهران	۱	۰/۷۲۴	۰/۳۸۷	۰/۳۰۴	۰/۶۶۳	۰/۷۰۵	۰/۴۰۴	۰/۳۲۷	۰/۶۳۸
	۲	۰/۷۱۹	۰/۳۹۲	۰/۳۰۷	۰/۶۵۴	۰/۶۹۷	۰/۴۰۷	۰/۳۳۱	۰/۶۲۹
	۳	۰/۷۱۳	۰/۳۹۵	۰/۳۰۹	۰/۶۴۴	۰/۶۹۳	۰/۴۰۸	۰/۳۳۴	۰/۶۱۸
	۴	۰/۷۰۷	۰/۳۹۷	۰/۳۱۲	۰/۶۳۳	۰/۶۸۷	۰/۴۱۲	۰/۳۳۶	۰/۶۰۷
دهلران	۱	۰/۷۲۳	۰/۳۸۹	۰/۳۱۴	۰/۶۶۲	۰/۷۰۴	۰/۴۰۵	۰/۳۳۸	۰/۶۳۷
	۲	۰/۷۱۸	۰/۳۹۳	۰/۳۱۶	۰/۶۵۳	۰/۶۹۶	۰/۴۰۸	۰/۳۴۱	۰/۶۲۵
	۳	۰/۷۱۲	۰/۳۹۶	۰/۳۱۷	۰/۶۴۲	۰/۶۹۲	۰/۴۰۹	۰/۳۴۴	۰/۶۱۷
	۴	۰/۷۰۵	۰/۴۰۱	۰/۳۱۹	۰/۶۳۱	۰/۶۸۶	۰/۴۱۳	۰/۳۴۸	۰/۶۰۴
دویرج	۱	۰/۷۲۱	۰/۳۹۱	۰/۳۲۱	۰/۶۶۱	۰/۷۰۲	۰/۴۰۶	۰/۳۵۱	۰/۶۳۶
	۲	۰/۷۱۷	۰/۳۹۵	۰/۳۲۲	۰/۶۵۲	۰/۶۹۵	۰/۴۰۹	۰/۳۵۴	۰/۶۲۴
	۳	۰/۷۱۱	۰/۳۹۷	۰/۳۲۴	۰/۶۴۱	۰/۶۹۱	۰/۴۱۱	۰/۳۵۷	۰/۶۱۵
	۴	۰/۷۰۴	۰/۴۰۳	۰/۳۲۵	۰/۶۳۱	۰/۶۸۵	۰/۴۱۵	۰/۳۵۹	۰/۶۰۳
ایلام	۱	۰/۷۱۹	۰/۳۹۳	۰/۳۲۷	۰/۶۵۹	۰/۷۰۱	۰/۴۱۷	۰/۳۶۱	۰/۶۳۴
	۲	۰/۷۱۶	۰/۳۹۷	۰/۳۲۹	۰/۶۵۱	۰/۶۹۴	۰/۴۱۹	۰/۳۶۳	۰/۶۲۳
	۳	۰/۷۰۹	۰/۳۹۹	۰/۳۴۱	۰/۶۳۹	۰/۶۸۹	۰/۴۲۱	۰/۳۶۴	۰/۶۱۴
	۴	۰/۷۰۳	۰/۴۰۴	۰/۳۴۲	۰/۶۲۸	۰/۶۸۳	۰/۴۲۲	۰/۳۶۵	۰/۶۰۲
ایوان غرب	۱	۰/۷۱۷	۰/۴۰۶	۰/۳۳۸	۰/۶۵۸	۰/۶۹۹	۰/۴۲۴	۰/۳۶۷	۰/۶۳۱
	۲	۰/۷۱۶	۰/۴۰۷	۰/۳۴۴	۰/۶۴۹	۰/۶۹۳	۰/۴۲۷	۰/۳۶۹	۰/۶۲۲
	۳	۰/۷۰۸	۰/۴۰۹	۰/۳۴۵	۰/۶۳۸	۰/۶۸۸	۰/۴۳۱	۰/۳۷۱	۰/۶۱۳
	۴	۰/۷۰۳	۰/۴۱۱	۰/۳۴۸	۰/۶۲۷	۰/۶۸۱	۰/۴۳۴	۰/۳۷۳	۰/۶۰۱
آرکواز ملک	۱	۰/۷۱۶	۰/۴۱۱	۰/۳۵۱	۰/۶۵۷	۰/۶۹۷	۰/۴۳۵	۰/۳۷۴	۰/۶۲۸
	۲	۰/۷۱۴	۰/۴۱۳	۰/۳۵۶	۰/۶۴۸	۰/۶۹۲	۰/۴۳۷	۰/۳۷۷	۰/۶۲۱

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
چم‌گز	۳	۰/۷۰۷	۰/۴۱۵	۰/۳۵۹	۰/۶۳۷	۰/۳۸۱	۰/۴۳۹	۰/۶۸۷	۰/۶۱۱
	۴	۰/۷۰۲	۰/۴۱۷	۰/۳۵۹	۰/۶۲۶	۰/۳۸۳	۰/۴۴۲	۰/۶۷۹	۰/۵۹۸
	۱	۰/۷۱۵	۰/۴۱۸	۰/۳۶۱	۰/۶۵۵	۰/۳۸۵	۰/۴۴۴	۰/۶۹۶	۰/۶۲۷
	۲	۰/۷۱۳	۰/۴۲۱	۰/۳۶۳	۰/۶۴۷	۰/۳۸۸	۰/۴۴۷	۰/۶۹۱	۰/۶۱۹
کهره هلیان	۳	۰/۷۰۷	۰/۴۲۳	۰/۳۶۴	۰/۶۳۶	۰/۳۸۹	۰/۴۵۱	۰/۶۸۶	۰/۶۰۸
	۴	۰/۷۰۱	۰/۴۲۴	۰/۳۶۶	۰/۶۲۵	۰/۳۹۱	۰/۴۵۲	۰/۶۷۷	۰/۵۹۵
	۱	۰/۷۱۴	۰/۴۲۷	۰/۳۶۷	۰/۶۵۳	۰/۳۹۱	۰/۴۵۴	۰/۶۹۵	۰/۶۲۵
	۲	۰/۷۱۲	۰/۴۲۹	۰/۳۶۸	۰/۶۴۵	۰/۳۹۳	۰/۴۵۷	۰/۶۸۹	۰/۶۱۸
	۳	۰/۷۰۶	۰/۴۳۱	۰/۳۶۹	۰/۶۳۴	۰/۳۹۵	۰/۴۶۱	۰/۶۷۶	۰/۶۰۶
	۴	۰/۶۹۹	۰/۴۳۳	۰/۳۷۱	۰/۶۲۲	۰/۳۹۶	۰/۴۶۲	۰/۶۷۳	۰/۵۹۴

جدول (۳): نتایج آماری داده‌های ورودی مدل AutoFormer به منظور پیش‌بینی شاخص FSD

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
مهران	۱	۰/۶۵۷	۰/۴۵۳	۰/۳۶۳	۰/۵۸۴	۰/۳۷۶	۰/۴۷۱	۰/۶۳۶	۰/۵۵۳
	۲	۰/۶۵۱	۰/۴۵۴	۰/۳۶۶	۰/۵۷۳	۰/۳۷۸	۰/۴۷۳	۰/۶۲۱	۰/۵۴۴
	۳	۰/۶۴۳	۰/۴۵۷	۰/۳۶۸	۰/۵۶۱	۰/۳۸۱	۰/۴۷۴	۰/۶۱۳	۰/۵۳۱
	۴	۰/۶۳۶	۰/۴۵۹	۰/۳۶۹	۰/۵۵۲	۰/۳۸۴	۰/۴۸۱	۰/۶۰۶	۰/۵۲۵
دهلران	۱	۰/۶۵۶	۰/۴۶۱	۰/۳۷۱	۰/۵۸۳	۰/۳۸۵	۰/۴۸۳	۰/۶۳۵	۰/۵۵۱
	۲	۰/۶۴۹	۰/۴۵۸	۰/۳۷۲	۰/۵۷۲	۰/۳۸۶	۰/۴۸۵	۰/۶۱۹	۰/۵۴۲
	۳	۰/۶۴۱	۰/۴۶۳	۰/۳۷۴	۰/۵۶۱	۰/۳۸۶	۰/۴۸۷	۰/۶۱۲	۰/۵۲۹
	۴	۰/۶۳۳	۰/۴۵۹	۰/۲۷۵	۰/۵۵۱	۰/۳۸۷	۰/۴۸۹	۰/۶۰۴	۰/۵۲۳
دوبرج	۱	۰/۶۵۵	۰/۴۶۴	۰/۲۷۸	۰/۵۸۲	۰/۳۸۹	۰/۴۹۳	۰/۶۳۳	۰/۵۴۹
	۲	۰/۶۴۸	۰/۴۶۵	۰/۳۷۹	۰/۵۷۱	۰/۳۸۴	۰/۴۹۴	۰/۶۱۷	۰/۵۴۱
	۳	۰/۶۳۹	۰/۴۶۶	۰/۳۸۱	۰/۵۵۹	۰/۳۹۱	۰/۴۹۴	۰/۶۱۱	۰/۵۲۸
	۴	۰/۶۳۱	۰/۴۶۷	۰/۳۸۲	۰/۵۴۸	۰/۳۹۱	۰/۴۹۷	۰/۶۰۳	۰/۵۲۱
ایلام	۱	۰/۶۵۴	۰/۴۶۹	۰/۳۸۴	۰/۵۸۱	۰/۳۹۴	۰/۴۹۹	۰/۶۳۱	۰/۵۴۸
	۲	۰/۶۴۷	۰/۴۷۱	۰/۳۸۴	۰/۵۶۹	۰/۳۹۵	۰/۴۹۶	۰/۶۱۵	۰/۵۳۹
	۳	۰/۶۳۸	۰/۴۷۲	۰/۳۸۱	۰/۵۵۸	۰/۳۹۶	۰/۴۹۵	۰/۶۰۲	۰/۵۲۶
	۴	۰/۶۲۹	۰/۴۷۴	۰/۳۷۸	۰/۵۴۶	۰/۳۹۷	۰/۴۹۸	۰/۶۰۲	۰/۵۱۹
ایوان غرب	۱	۰/۶۵۳	۰/۴۷۹	۰/۳۸۵	۰/۵۷۹	۰/۳۹۸	۰/۵۰۱	۰/۶۲۸	۰/۵۴۷
	۲	۰/۶۴۶	۰/۴۸۱	۰/۳۸۹	۰/۵۶۶	۰/۴۰۱	۰/۵۰۳	۰/۶۱۴	۰/۵۳۸
	۳	۰/۶۳۷	۰/۴۸۳	۰/۳۹۱	۰/۵۵۷	۰/۴۰۲	۰/۵۰۸	۰/۶۰۸	۰/۵۲۴

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
آرکواز ملک	۴	۰/۶۲۸	۰/۴۸۳	۰/۳۹۲	۰/۵۴۴	۰/۵۱۷	۰/۴۰۵	۰/۵۱۲	۰/۶۰۱
	۱	۰/۶۵۲	۰/۴۸۶	۰/۳۹۲	۰/۵۷۸	۰/۵۴۶	۰/۴۰۸	۰/۵۱۴	۰/۶۲۷
	۲	۰/۶۴۳	۰/۴۸۸	۰/۳۹۴	۰/۵۶۵	۰/۵۳۵	۰/۴۰۹	۰/۵۰۶	۰/۶۱۲
	۳	۰/۶۳۵	۰/۴۸۹	۰/۳۹۵	۰/۵۵۶	۰/۵۲۳	۰/۴۱۲	۰/۵۱۵	۰/۶۰۶
	۴	۰/۶۲۷	۰/۴۹۱	۰/۳۹۷	۰/۵۴۳	۰/۵۱۶	۰/۴۱۳	۰/۵۱۸	۰/۵۹۸
چم گز	۱	۰/۶۵۱	۰/۴۹۳	۰/۳۹۸	۰/۵۷۷	۰/۵۴۵	۰/۴۱۸	۰/۵۰۵	۰/۶۲۵
	۲	۰/۶۴۲	۰/۴۹۴	۰/۳۹۸	۰/۵۶۴	۰/۵۳۴	۰/۴۲۱	۰/۵۲۱	۰/۶۱۱
	۳	۰/۶۳۴	۰/۴۹۷	۰/۳۹۹	۰/۵۵۳	۰/۵۲۲	۰/۴۲۴	۰/۵۲۳	۰/۶۰۵
	۴	۰/۶۲۵	۰/۵۰۱	۰/۴۰۱	۰/۵۴۱	۰/۵۱۵	۰/۴۲۵	۰/۵۲۴	۰/۵۹۷
کهره هلیان	۱	۰/۶۴۹	۰/۵۰۲	۰/۴۰۳	۰/۵۷۵	۰/۵۴۳	۰/۴۲۸	۰/۵۲۸	۰/۶۲۴
	۲	۰/۶۴۱	۰/۵۰۴	۰/۴۰۷	۰/۵۶۳	۰/۵۳۱	۰/۴۳۱	۰/۵۳۱	۰/۶۰۹
	۳	۰/۶۳۳	۰/۵۰۷	۰/۴۱۲	۰/۵۵۲	۰/۵۲۱	۰/۴۳۲	۰/۵۳۴	۰/۶۰۴
	۴	۰/۶۲۲	۰/۵۰۹	۰/۴۱۳	۰/۵۳۸	۰/۵۱۴	۰/۴۳۴	۰/۵۳۵	۰/۵۹۶

جدول (۴): نتایج آماری داده‌های ورودی مدل هیبریدی FNO-AutoFormer به منظور پیش‌بینی شاخص FSD

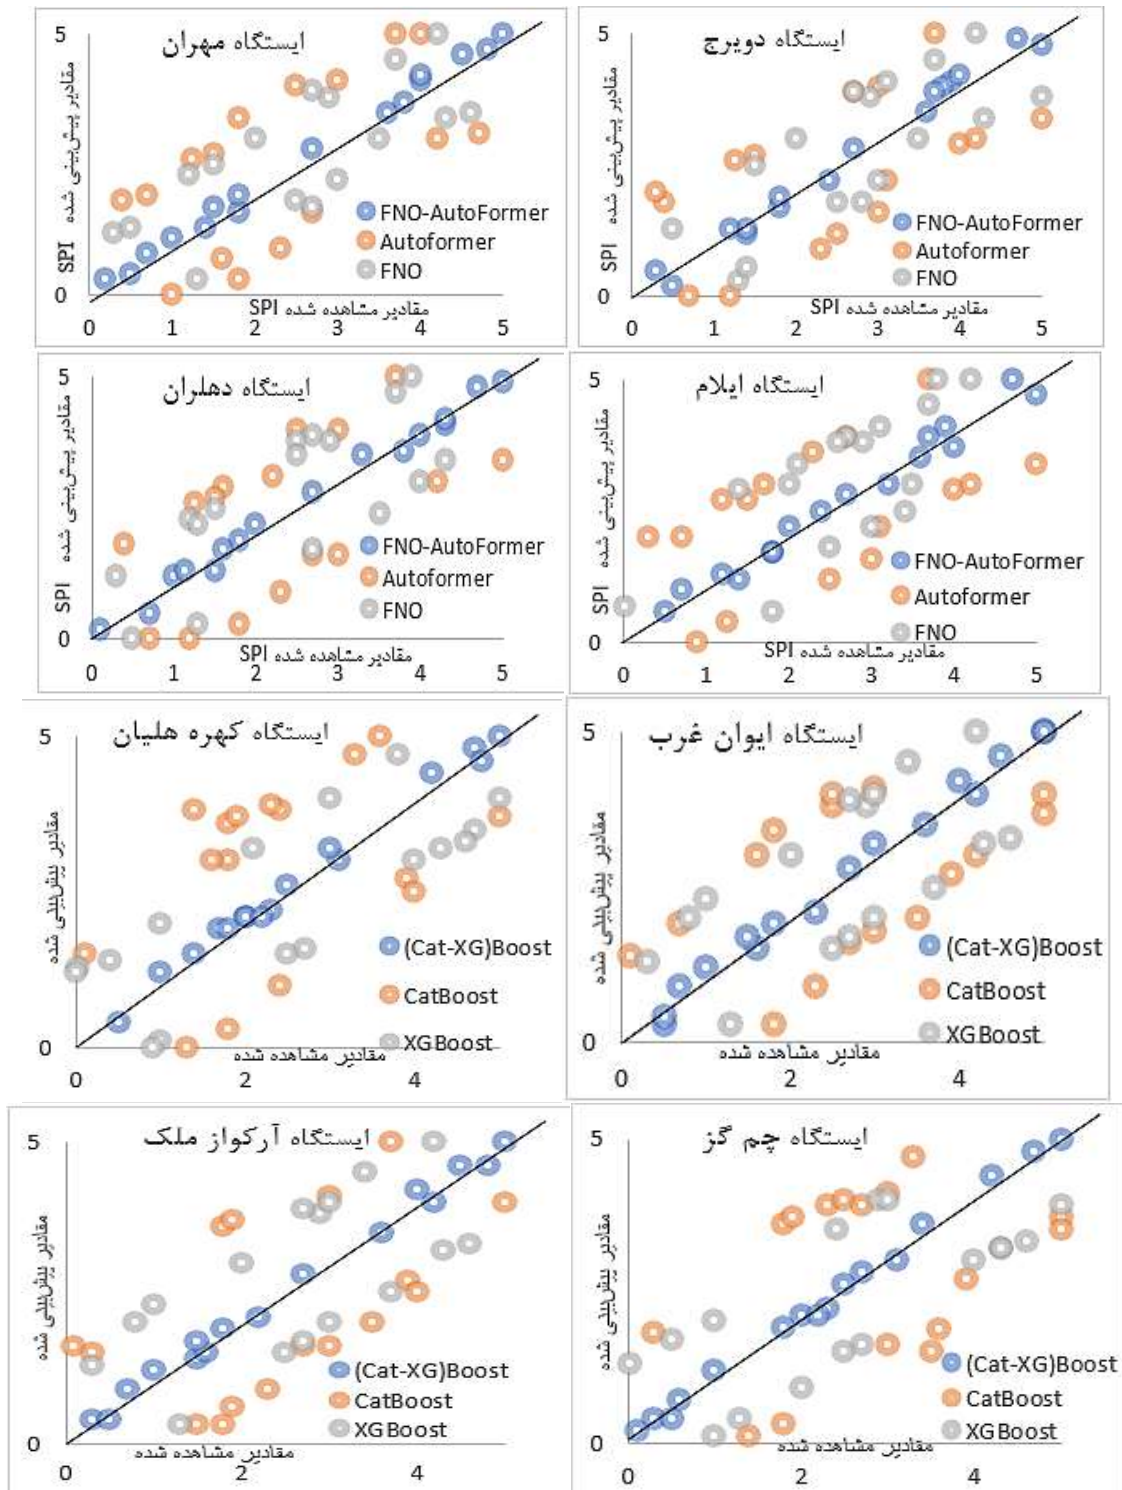
ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
مهران	۱	۰/۹۸۸	۰/۱۸۸	۰/۰۹۳	۰/۹۶۵	۰/۹۵۸	۰/۱۰۵	۰/۱۹۶	۰/۹۷۸
	۲	۰/۹۸۱	۰/۱۸۹	۰/۰۹۷	۰/۹۵۱	۰/۹۴۱	۰/۱۰۸	۰/۲۰۱	۰/۹۶۶
	۳	۰/۹۷۳	۰/۱۹۱	۰/۰۹۸	۰/۹۴۳	۰/۹۳۴	۰/۱۱۲	۰/۲۰۴	۰/۹۵۳
	۴	۰/۸۶۴	۰/۱۹۳	۰/۰۹۸	۰/۹۳۵	۰/۹۲۶	۰/۱۱۴	۰/۲۰۶	۰/۹۴۴
دهلران	۱	۰/۹۸۷	۰/۱۹۳	۰/۱۰۱	۰/۹۶۴	۰/۹۵۷	۰/۱۲۳	۰/۲۰۷	۰/۹۷۷
	۲	۰/۹۷۹	۰/۱۹۴	۰/۱۰۲	۰/۹۵۱	۰/۹۳۹	۰/۱۲۸	۰/۲۰۹	۰/۹۶۵
	۳	۰/۹۷۲	۰/۱۹۵	۰/۱۰۴	۰/۹۴۲	۰/۹۳۳	۰/۱۳۱	۰/۲۱۲	۰/۹۵۱
	۴	۰/۹۶۴	۰/۱۹۷	۰/۱۰۵	۰/۹۳۴	۰/۹۲۴	۰/۱۳۳	۰/۲۱۴	۰/۹۴۳
دوبرج	۱	۰/۹۸۶	۰/۱۹۳	۰/۱۰۱	۰/۹۶۳	۰/۹۵۶	۰/۱۳۷	۰/۲۰۳	۰/۹۷۴
	۲	۰/۹۷۷	۰/۱۹۴	۰/۱۰۷	۰/۹۵۱	۰/۹۳۸	۰/۱۴۱	۰/۲۰۹	۰/۹۶۵
	۳	۰/۹۷۱	۰/۱۹۶	۰/۱۰۹	۰/۹۴۱	۰/۹۳۲	۰/۱۴۳	۰/۲۱۵	۰/۹۵۱
	۴	۰/۹۶۳	۰/۱۹۷	۰/۱۰۹	۰/۹۳۳	۰/۹۲۴	۰/۱۴۴	۰/۲۱۷	۰/۹۴۱
ایلام	۱	۰/۹۸۵	۰/۱۹۹	۰/۱۱۱	۰/۹۶۲	۰/۹۵۵	۰/۱۴۵	۰/۲۱۸	۰/۹۷۳
	۲	۰/۹۷۶	۰/۲۰۱	۰/۱۱۲	۰/۹۴۹	۰/۹۳۷	۰/۱۴۷	۰/۲۲۱	۰/۹۶۴
	۳	۰/۹۷۱	۰/۲۰۳	۰/۱۱۴	۰/۹۳۸	۰/۹۳۱	۰/۱۵۱	۰/۲۲۳	۰/۹۴۹
	۴	۰/۹۶۲	۰/۱۹۸	۰/۱۱۷	۰/۹۳۲	۰/۹۲۳	۰/۱۵۲	۰/۲۳۱	۰/۹۳۸
۱	۰/۹۸۴	۰/۲۰۴	۰/۱۱۸	۰/۹۶۱	۰/۹۵۴	۰/۱۵۴	۰/۲۳۴	۰/۹۷۲	

ایستگاه	شماره ترکیب	مجموعه داده آموزش				مجموعه داده آزمون			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
ایوان غرب	۲	۰/۹۷۵	۰/۱۹۶	۰/۱۲۱	۰/۹۴۸	۰/۱۵۷	۰/۲۳۸	۰/۹۶۳	۰/۹۳۶
	۳	۰/۹۶۹	۰/۲۰۷	۰/۱۲۱	۰/۹۳۷	۰/۱۶۱	۰/۲۴۱	۰/۹۴۸	۰/۹۲۹
	۴	۰/۹۶۱	۰/۲۰۸	۰/۱۲۴	۰/۹۳۱	۰/۱۶۴	۰/۲۴۲	۰/۹۳۷	۰/۹۲۱
	۱	۰/۹۸۳	۰/۱۹۳	۰/۱۲۵	۰/۹۶۱	۰/۱۶۵	۰/۲۴۳	۰/۹۷۱	۰/۹۵۳
آرکواز ملک	۲	۰/۹۷۴	۰/۲۱۲	۰/۱۲۷	۰/۹۴۷	۰/۱۶۸	۰/۲۴۴	۰/۹۶۲	۰/۹۳۵
	۳	۰/۹۶۸	۰/۲۱۷	۰/۱۳۱	۰/۹۳۶	۰/۱۶۹	۰/۲۴۵	۰/۹۴۷	۰/۹۲۸
	۴	۰/۹۵۹	۰/۲۱۸	۰/۱۳۲	۰/۹۲۹	۰/۱۷۱	۰/۲۴۸	۰/۹۳۶	۰/۹۱۹
	۱	۰/۹۸۲	۰/۲۲۱	۰/۱۳۳	۰/۹۵۹	۰/۱۷۲	۰/۲۵۱	۰/۹۶۹	۰/۹۵۲
چم‌گز	۲	۰/۹۷۳	۰/۲۲۲	۰/۱۳۴	۰/۹۴۶	۰/۱۷۳	۰/۲۵۲	۰/۹۶۱	۰/۹۳۴
	۳	۰/۹۶۶	۰/۲۲۴	۰/۱۳۵	۰/۹۳۴	۰/۱۷۴	۰/۲۵۴	۰/۹۴۵	۰/۹۲۷
	۴	۰/۹۵۸	۰/۲۲۵	۰/۱۳۸	۰/۹۲۸	۰/۱۷۵	۰/۲۵۷	۰/۹۳۴	۰/۹۱۸
	۱	۰/۹۸۱	۰/۲۲۷	۰/۱۴۱	۰/۹۵۸	۰/۱۷۶	۰/۲۶۱	۰/۹۶۸	۰/۹۵۱
کهره هلیان	۲	۰/۹۷۲	۰/۲۲۸	۰/۱۴۲	۰/۹۴۵	۰/۱۷۷	۰/۲۶۳	۰/۹۵۹	۰/۹۳۳
	۳	۰/۹۶۵	۰/۲۳۱	۰/۱۴۳	۰/۹۳۳	۰/۱۷۸	۰/۲۶۴	۰/۹۴۳	۰/۹۲۶
	۴	۰/۹۵۷	۰/۲۳۴	۰/۱۴۷	۰/۹۲۷	۰/۱۷۹	۰/۲۶۵	۰/۹۳۲	۰/۹۱۴
	۱	۰/۹۸۱	۰/۲۲۷	۰/۱۴۱	۰/۹۵۸	۰/۱۷۶	۰/۲۶۱	۰/۹۶۸	۰/۹۵۱

بررسی نمودارهای خط

همبستگی بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده در شکل ۴ نشان می‌دهد که مدل هیبریدی FNO-AutoFormer دارای بالاترین میزان انطباق با داده‌های واقعی است. در این مدل، پراکنش نقاط به‌طور محسوسی در امتداد خط نیمساز متمرکز شده و انحراف از خط مرجع حداقل است که با مقادیر بالای ضریب همبستگی ۰/۹۱۴ تا ۰/۹۵۸ هم‌خوانی کامل دارد. این امر بیان‌گر توان بالای مدل هیبریدی در بازنمایی دامنه نوسانات، شدت رخدادها و رفتار کلی سری زمانی طوفان‌های گردوغبار است. در مقابل، نمودارهای همبستگی مربوط به مدل‌های انفرادی FNO و Autoformer پراکنش گسترده‌تری نسبت به خط نیمساز نشان می‌دهند. به‌گونه‌ای که نقاط پیش‌بینی شده فاصله بیشتری از مقادیر

مشاهده‌ای دارند. مقایسه بین این دو مدل نشان می‌دهد که عملکرد آن‌ها از نظر همبستگی بسیار نزدیک به یکدیگر است و اختلاف محسوسی در الگوی پراکنش نقاط مشاهده نمی‌شود. اگرچه مدل FNO اندکی عملکرد بهتری نسبت به Autoformer ارائه کرده است و در برخی بازه‌ها همبستگی بالاتری نشان می‌دهد اما این تفاوت از نظر آماری معنادار نبوده و نمی‌تواند به‌عنوان یک برتری قطعی در نظر گرفته شود. نزدیکی عملکرد دو مدل انفرادی در نمودارهای همبستگی کنار مقادیر نسبتاً مشابه ضریب همبستگی بین ۰/۵۱۴ تا ۰/۶۳۸ برای مدل Autoformer و ۰/۵۹۴ تا ۰/۶۳۸ برای مدل FNO، نشان می‌دهد که هر دو مدل در استخراج روابط کلی بین متغیرهای ورودی و خروجی نسبتاً موفق بوده‌اند اما در بازنمایی دقیق نوسانات شدید و رفتارهای حدی طوفان‌های گردوغبار با محدودیت مواجه‌اند.



شکل (۵): نمودار همبستگی ایستگاه‌های مورد مطالعه

نتایج نشان داد مدل هیبریدی FNO-Autoformer به‌طور قابل توجهی بهترین عملکرد را در تمامی شاخص‌های ارزیابی نسبت به مدل‌های انفرادی ارائه داد. همبستگی بالا بین داده‌های آموزش و آزمون، مقادیر بالای شاخص NS و کاهش چشمگیر خطاهای RMSE و MAE نشان داد که با ترکیب قابلیت‌های زمانی مدل Autoformer به همراه مکانی -

نتیجه‌گیری

پژوهش حاضر به‌منظور بهبود دقت پیش‌بینی طوفان‌های گردوغبار به ارزیابی و مقایسه عملکرد مدل‌های انفرادی Autoformer، FNO و مدل هیبریدی پیشنهادی FNO-Autoformer در ترکیب‌های زمانی مختلف پرداخت.

4. Alshammari, R. K., Alrwais, O., Aksoy, M. S. 2024. Machine Learning Forecast of Dust Storm Frequency in Saudi Arabia Using Multiple Features. *Atmosphere* 15(5), 520. <https://doi.org/10.3390/atmos15050520>
5. Bahrami, H.A., Jalali, M., Darvishi Boloorani, A., Azizi, R., 2014. Spatial-temporal modeling of dust storms in Khuzestan Province. *Iranian Journal of Remote Sensing and GIS* 5(2), 95-114(in persian).
6. Caetano, R., Oliveira, J. M., Ramos, P., 2025. Transformer-Based Models for Probabilistic Time Series Forecasting with Explanatory Variables. *Mathematics* 13(5), 814. <https://doi.org/10.3390/math13050814>
7. Choubin, B., Hosseini, F. S., Rahmati, O., Youshanloei, M. M., & Jalali, M. (2023). Mapping of salty aeolian dust-source potential areas: Ensemble model or benchmark models?. *Science of The Total Environment*, 877, 163419. <http://dx.doi.org/10.1016/j.scitotenv.2023.163419>
8. Costa Rocha, P. A., Thé, J. V. G., Oliveira Santos, V., Gharabaghi, B., 2025. Deep Learning for Atmospheric Modeling: A Proof of Concept Using a Fourier Neural Operator on WRF Data to Accelerate Transient Wind Forecasting at Multiple Altitudes. *Atmosphere* 16(4), 394. <https://doi.org/10.3390/atmos16040394>
9. Duruisseaux, V., Kossaiifi, J., Anandkumar, A. 2025. Fourier Neural Operators Explained: A Practical Perspective. <https://doi.org/10.48550/arXiv.2512.01421>
10. Gou, Z.H., Li, H.B., 2025. MgFNO: Multi-grid Architecture Fourier Neural Operator for Parametric Partial Differential Equations. [arXiv:2407.08615v3](https://arxiv.org/abs/2407.08615v3)
11. Kossaiifi, J., Kovachki, N., Azizzadenesheli, K., Anandkumar, A., 2023. Multi-Grid Tensorized Fourier Neural Operator for HighResolution PDEs. <https://doi.org/10.48550/arXiv.2310.00120>
12. Li, Z., Kovachki, N., Azizzadenesheli, K., Liu, B., Bhattacharya, K., Stuart, A., Anandkumar, A., 2021. Fourier Neural Operator for Parametric Partial Differential Equations. <https://doi.org/10.48550/arXiv.2010.08895>
13. Li, Z., Zhengyu Huang, D., Liu, B., Anandkumar, A., 2024. Fourier Neural Operator with Learned Deformations for PDEs on General Geometries. <https://doi.org/10.48550/arXiv.2207.05209>
14. Mahesh, A., D.Collins, W., Bonev, B et al. 2025. Huge ensembles – Part 1: Design of ensemble weather forecasts using spherical Fourier neural operators. *GMD*, 18(17), 5575–5603. <https://doi.org/10.5194/gmd-18-5575-2025>
15. 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.

طیفی مدل FNO می‌توان ضعف‌های ساختاری هر یک از این مدل‌ها را جبران کرد و عملکرد بهتری در پیش‌بینی‌ها نشان داد. نتایج به‌دست‌آمده تأیید می‌کند که به دلیل ماهیت مکانی-زمانی و چندبعدی پدیده گردوغبار، مدل‌سازی آن مستلزم استفاده از چارچوب‌های ترکیبی و چندبعدی است. بررسی ترکیب‌های زمانی مختلف نیز نشان داد که تأخیرهای پیش‌بینی کوتاه‌مدت به‌ویژه ترکیب یک فصل، بالاترین دقت پیش‌بینی را فراهم می‌کنند و با افزایش تأخیر زمانی، عدم قطعیت و خطا افزایش می‌یابد. در مجموع، نتایج این پژوهش نشان می‌دهد که با استفاده از مدل‌های هیبریدی داده‌محور، می‌توان گامی مؤثر در جهت ارتقاء دقت و پایداری سامانه‌های پیش‌بینی طوفان‌های گردوغبار برداشت و زمینه را برای توسعه ابزارهای پیش‌بینی دقیق‌تر به‌منظور مدیریت مخاطرات زیست‌محیطی فراهم ساخت. پیشنهاد می‌شود در پژوهش‌های آینده از داده‌های مکانی با تفکیک‌پذیری بالاتر و داده‌های سنجش از دور استفاده شود تا توان مدل‌ها در بازنمایی فرآیندهای فیزیکی تقویت گردد. همچنین توسعه نسخه‌های پیشرفته‌تر عملگرهای عصبی نظیر FNOهای اصلاح‌شده یا ترکیب آن‌ها با مدل‌های احتمالاتی می‌تواند به کاهش عدم قطعیت پیش‌بینی رویدادهای حدی کمک کند.

منابع

1. Ansari ghoghghar, M., Piri, S., Rad, R.T., Malekian, A. 2025. Predicting the dust storms using three-hybrid metamodels for integrated dust storm management (case study: Khuzestan Province, Iran). *International Journal of Environmental Science and Technology* 23:81. <https://doi.org/10.1007/s13762-25-06944-x>
2. Ansari ghoghghar, M., Pourmohammad, P., 2025. Comparative Analysis of Dust Storm Frequency Modeling Using the XGBoost Machine Learning Model and the Element-Free Galerkin Method (Case study: Ilam Province). *Iranian Journal of Soil and Water Research* 56(6), 1421-1436(in persian). [doi:10.22059/ijswr.2025.392122.669904](https://doi.org/10.22059/ijswr.2025.392122.669904)
3. Ansari ghoghghar, M., bazrafshan, J., Araghinejad, S., 2022. Evaluating the Efficiency of Hybrid Metamodels of Machine Learning and Box Jenkins in Order to Model Dust Storms (Case Study: Khuzestan Province). *Iranian Journal of Soil and Water Research* 53(8), 1695-1714(in persian). [doi:10.22059/ijswr.2022.346694.669335](https://doi.org/10.22059/ijswr.2022.346694.669335)

16. Papi, R., Argany, M., Moradipour, S., Soleimani, M., 2021. Modeling the potential of Sand and Dust Storm sources formation using time series of remote sensing data, fuzzy logic and artificial neural network (A Case study of Euphrates basin). *jgit8(3)*, 61-82(in persian).
17. Pourgholam-Amiji, M., ansarighojghar, M., Araghinejad, S., Babaeian, I., 2021. Modeling the Relationship between Dust Storms and Extreme and Average Temperature Variables in the Western Half of Iran. *Journal of Climate Research* 1400(45), 113-126(in persian).
18. Sinha, S., Benton, B., Emami, P., 2025. On the effectiveness of neural operators at zero-shot weather downscaling. *Environmental Data Science*, 4, 21. doi:10.1017/eds.2025.11
19. Tavoosi Rad, R., Piri, S., Ansari ghoghghar, M., Azarnivand, H., 2025. Evaluating the performance of metaheuristic algorithms for optimizing input data to model dust storms (A case study of Sistan and Baluchestan province). *Climate Change Research* 6 (24), 73-88 (in persian). doi: 10.30488 /ccr.2025.552548.1307
20. Vatanparast Galeh Juq, F., Salahi, B., Zeinali, B., 2025. Forecasting the Occurrence of Dust Storms using the Accuracy Assessment of Artificial Neural Networks in Selected Stations in the Western Half of Iran. *Geography* 23(84), 21-39(in persian). doi:10.22034/jiga.2025.2046840.1356
21. Yarmohamadi, M., Alesheikh, A. A., Sharif, M. 2025. Using Hybrid Deep Learning Models to Predict Dust Storm Pathways with Enhanced Accuracy. *Climate*, 13(1), 16. <https://doi.org/10.3390/cli13010016>
22. Wu, H., Xu, J., Wang, J., Long, M., 2021. Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting. 35th Conference on Neural Information Processing Systems. <https://doi.org/10.48550/arXiv.2106.13008>.

Investigation of a Transformer-Based Fourier Neural Network for FDSI Index Prediction in Ilam Province

Ramtin Tavosiri Rad¹  | Mohammad Ansari ghoghari^{2*}  | Hassan Khosravi³ 

Receive: 2026/04/12

Accept: 2026/05/04

Extended Abstract

Introduction: Dust storms are considered one of the most significant extreme climate phenomena in arid and semi-arid regions, with widespread consequences for health, the environment, and natural resource management. Despite extensive research efforts, accurately predicting the occurrence and intensity of dust storms remains a substantial scientific challenge due to the nonlinear, multiscale, and highly dynamic interactions among atmospheric, land surface, and climatic factors. Traditional numerical and statistical models often struggle to capture such complex relationships, leading to considerable uncertainties in forecasts. In this context, recent advances in deep learning have opened new avenues for modeling complex environmental phenomena. Deep learning models, particularly those capable of learning long-term temporal dependencies and spatial patterns, offer promising tools for improving dust storm prediction. This research, which aims to evaluate the capabilities of novel deep learning models for predicting dust storms, investigated the performance of two individual models—Autoformer and Fourier Neural Operator (FNO)—as well as a hybrid framework based on the combination of these two models across several temporal configurations.

Materials and Methods: This research aims to improve the accuracy of dust storm forecasting by evaluating the predictive performance of advanced deep learning models under different temporal input structures. Two modern architectures were selected for this purpose: the Autoformer model, known for its ability to capture long-term temporal dependencies in time series data, and the Fourier Neural Operator (FNO), which is specifically designed to learn complex spatial-spectral patterns through frequency-domain representations. In addition to assessing these models individually, a hybrid FNO-Autoformer framework was developed to combine their complementary strengths. The dust storm intensity index, representing the severity and frequency of dust events, was selected as the target variable. Ilam Province was chosen as the case study area due to its high exposure to dust storm activity and its climatic vulnerability. To investigate the influence of temporal input structure on model performance, four distinct temporal configurations were designed, ranging from short-term to long-term forecasting horizons. These configurations included time lags from one season up to one year, enabling a comprehensive analysis of how prediction horizon affects model accuracy. Following appropriate pre-processing, the data were divided into training (80%) and testing (20%) sets. Model performance was evaluated using the following statistical metrics: Nash–Sutcliffe efficiency (NS), root mean square error (RMSE), mean absolute error (MAE), and correlation coefficient (R).

Results: The results of this study revealed that the Autoformer model exhibited the weakest performance in predicting the FDSI index across all temporal configurations and was associated with relatively high error in reproducing extreme variations in dust storms. Although the FNO model performed better than Autoformer in extracting spatio-temporal patterns, as a standalone model it still did not achieve acceptable forecasting accuracy and showed no significant difference from Autoformer. In contrast, the hybrid FNO-Autoformer model, by integrating the strengths of FNO in learning spatio-spectral patterns and the capability of Autoformer in modeling long-term temporal dependencies, demonstrably provided the best performance across all evaluation metrics. High values of the NS index, a significant reduction in RMSE and MAE errors, and an increase in the correlation coefficient confirmed the clear superiority of this hybrid framework over the individual models. The results also indicated that short-term temporal configurations, particularly forecasts with a one-season lag, achieved the highest accuracy, and that the models' forecasting accuracy decreased with increasing time lag. This finding highlights the

1. Master Candidate, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. Email: ramtintavosirad@ut.ac.ir

2. Corresponding Author, Assistant Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. Email: ansari.ghoghari@ut.ac.ir

3. Professor, Department of Reclamation of Arid and Mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. E-mail: hakhosravi@ut.ac.ir

sensitivity of data-driven models to the temporal structure of inputs and the importance of selecting an optimal prediction horizon in dust storm modeling.

Discussion and conclusion: Overall, the findings of this research emphasize the crucial role of hybrid spatio-temporal frameworks in predicting extreme climate events and demonstrate that integrating Fourier Neural Operators with transformer-based models can represent an effective step toward developing more accurate forecasting systems and reducing uncertainty in dust hazard management. The study also highlights the strong influence of temporal input configuration on forecasting outcomes, suggesting that careful consideration of time lag selection is essential for optimizing model performance. From a practical perspective, improved dust storm prediction can contribute to more effective early warning systems, risk mitigation strategies, and sustainable environmental management. Moreover, the successful integration of spectral neural operators with transformer-based architectures represents a promising direction for future research in climate hazard modeling. Such hybrid approaches have the potential to reduce predictive uncertainty, support decision-making processes, and enhance resilience to extreme climatic events in vulnerable regions.

Keywords: Dust, Data-driven models, Hybrid models, FNO.