

تأثیر داده‌های سطوح فوقانی جو بر دقت پیش بینی فازهای مختلف پدیده ENSO با استفاده از الگوهای ترکیبی یادگیری ماشین در استانهای جنوبی ایران

مهدی ملکیان^۱ و علی اکبر سبزی پرور^{۲*}

^۱ دانشجوی دکتری، گرایش هواشناسی کشاورزی، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران
^۲ استاد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

(دریافت: ۱۴۰۴/۰۲/۱۱، پذیرش: ۱۴۰۴/۰۶/۰۱)

چکیده

نوسانات جنوبی ال نینو (ENSO) به عنوان یکی از مهم‌ترین پدیده‌های دور پیوند جهان، تأثیرات گسترده‌ای بر الگوهای هواشناسی در مناطق مختلف دارد. این پژوهش به بررسی تأثیر داده‌های ترازهای بالاتر جو بر دقت پیش‌بینی فازهای ENSO با استفاده از مدل ترکیبی ConvLSTM2D در استان‌های جنوبی ایران پرداخته است. نتایج نشان‌دهنده نقش کلیدی داده‌های ترازهای بالای جو در بهبود پیش‌بینی فازهای ENSO است. داده‌های هواشناسی شامل ارتفاع ژئوپتانسیل، دما، رطوبت نسبی، رطوبت ویژه و مؤلفه‌های باد از مجموعه داده‌های بازتحلیل ERA5 (ECMWF Reanalysis) در چهار تراز فشار (۱۰۰۰، ۸۵۰، ۷۰۰ و ۵۰۰ هکتوپاسکال) برای بازه زمانی ۱۹۹۴ تا ۲۰۲۳ استخراج شد. مدل پیشنهادی با ترکیب لایه‌های ConvLSTM2D، LSTM و Dense طراحی گردید تا ویژگی‌های مکانی-زمانی پیچیده را استخراج کند و با استفاده از معیارهایی نظیر MAE، MSE و ارزیابی شود. نتایج نشان داد که افزودن داده‌های ترازهای بالاتر جو (۵۰۰ و ۷۰۰ هکتوپاسکال) در مقایسه با ترازهای نزدیک به زمین، دقت پیش‌بینی را به طور قابل توجهی افزایش می‌دهند. بهترین عملکرد مدل در تراز ۵۰۰ هکتوپاسکال با تأخیر زمانی سه‌ماهه مشاهده شد ($R^2 = 0.93$ و $MAE = 0.14$)، که پایداری الگوهای جوی در این تراز و تأثیر تأخیر در بروز تغییرات جوی را تأیید می‌کند. تحلیل اهمیت ویژگی‌ها (Feature Importance) نیز نقش کلیدی متغیرهای دینامیکی (ارتفاع ژئوپتانسیل و مؤلفه افقی باد) و ترمودینامیکی (دما و رطوبت ویژه) را در ترازهای میانی جو نشان داد. این پژوهش بر ضرورت استفاده از طیف گسترده داده‌های جوی و بهینه‌سازی افق زمانی در پیش‌بینی‌های اقلیمی تأکید دارد. نتایج پژوهش می‌تواند به بهبود مدیریت منابع آب و کاهش مخاطرات جوی در جنوب ایران کمک کند، هر چند چالش‌هایی مانند تفسیرپذیری مدل‌ها نیازمند تحقیقات بیشتر است. پیشنهاد می‌شود مدل‌های ترکیبی همراه با مکانیزم توجه (Attention Mechanism)، که امکان تمرکز بر ویژگی‌های مهم‌تر را فراهم می‌سازد، به منظور افزایش دقت پیش‌بینی و ارتقاء عملکرد در کاربردهای عملی توسعه یابند.

کلمه‌های کلیدی: پیش‌بینی، دور پیوند، هوش مصنوعی، مدل‌های هیبریدی، اهمیت ویژگی‌ها

۱ مقدمه

نوسانات جنوبی (ENSO) یک الگوی اقلیمی است که با نوسانات نامنظم در دمای سطح دریا (SST) در اقیانوس آرام استوایی مرکزی و شرقی مشخص می‌شود (سانتوس و همکاران، ۲۰۲۰؛ نیک‌رفتار و خانیانی، ۲۰۱۸؛ ژانگ و همکاران، ۲۰۱۶). این نوسانات تأثیرات مهم جهانی دارند و الگوهای هواشناسی و وقایع حدی را در سراسر جهان تحت تأثیر قرار می‌دهند (کائو و همکاران، ۲۰۲۰؛ نیک‌رفتار و خانیانی، ۲۰۱۸؛ تانگ و همکاران، ۲۰۱۸). پیش‌بینی دقیق فازهای ENSO برای کاهش ریسک‌های مرتبط با اقلیم، به‌ویژه در بخش‌های مختلفی از جمله کشاورزی، مدیریت منابع آب و آمادگی برای بلایا، حیاتی است (بین و همکاران، ۲۰۲۳؛ کائو و همکاران، ۲۰۲۰). پیش‌بینی دقیق ENSO برای کاهش تأثیرات اقتصادی و اجتماعی قابل توجه این پدیده اقلیمی نیز در سطح جهانی مهم است (تانگ و همکاران، ۲۰۱۸). ENSO، قوی‌ترین سیگنال میان‌سالانه در سیستم اقلیمی جهان، تأثیرات قابل توجهی بر جنبه‌های اقلیمی و اکولوژیکی در سراسر جهان دارد (تانگ و همکاران، ۲۰۱۸). تأثیرات ENSO بر تغییرات اقلیمی از دهه ۲۰ مورد توجه تحقیقات بوده است (نیک‌رفتار و خانیانی، ۲۰۱۸). فهم تعاملات جوی مرتبط با ENSO برای پیش‌بینی دقیق ضروری است (یه و همکاران، ۲۰۱۸). هرچند که دماهای سطح دریا در اقیانوس آرام استوایی محرک اصلی ENSO هستند، اما فرآیندهای جوی نقش مهمی در تکامل آن و انتقال تأثیرات آن به مناطق دوردست دارند (زیو و همکاران، ۲۰۲۲؛ یه و همکاران، ۲۰۱۸). نوسان شبه‌دوسالانه (QBO) که از مدهای غالب نوسان در استراتوسفر حاره‌ای است، بر ENSO تأثیرگذار است؛ هرچند اهمیت نسبی این تأثیر در مقایسه با دینامیک داخلی پدیده ENSO همچنان موضوع بحث‌های علمی است (زیو و همکاران، ۲۰۲۲). مطالعاتی با استفاده از مشاهدات و مدل‌های ترکیبی اقیانوس-جو-شیمی اتصالات

غیرخطی بین QBO و ENSO را بررسی کرده و پیچیدگی این روابط را برجسته می‌کنند (زیو و همکاران، ۲۰۲۲). علاوه بر این، پاسخ جو بالایی به ENSO، از جمله تغییرات الگوهای گردش جو و تغییرات مقدار بخار آب، اطلاعات ارزشمندی برای بهبود مدل‌های پیش‌بینی ارائه می‌دهد (یه و همکاران، ۲۰۱۸؛ زیو و همکاران، ۲۰۲۲). اضافه کردن این اطلاعات می‌تواند درک تعاملات جوی را بهبود بخشد و مهارت پیش‌بینی مدل‌ها را افزایش دهد (یه و همکاران، ۲۰۱۸). تأثیر ENSO محدود به اقیانوس آرام استوایی نیست و بر الگوهای هواشناسی و وقایع حدی در سراسر جهان تأثیر می‌گذارد (بین و همکاران، ۲۰۲۳؛ ژای و همکاران، ۲۰۱۶؛ ویسته-سرانو و همکاران، ۲۰۱۱). به عنوان مثال، مطالعات نشان داده‌اند که تأثیرات ENSO بر شدت خشکسالی در مقیاس جهانی اثرگذار است (ویسته-سرانو و همکاران، ۲۰۱۱). با این حال، اثرات یکنواخت نیستند و مناطقی مانند آفریقای جنوبی، استرالیا و آسیای جنوب شرقی تأثیرات بارزتری را در مقیاس‌های زمانی طولانی‌تر نشان می‌دهند (ویسته-سرانو و همکاران، ۲۰۱۱). الگوهای فضایی تأثیر ENSO پیچیده است و بسته به فاز و نوع ENSO متفاوت است (ویسته-سرانو و همکاران، ۲۰۱۱؛ فنگ و همکاران، ۲۰۱۰). برای مثال، در آسیای شرقی، درک جدیدی بر تسلط حالت ترکیبی ENSO در تأثیرگذاری بر آب و هوای منطقه‌ای تأکید دارد (ژانگ و همکاران، ۲۰۱۵). این حالت که ناشی از برهمکنش غیرخطی بین ENSO و چرخه سالانه است، نقش کلیدی در توسعه الگوهای گردش جوی ناهنجار و ناهنجاری‌های بارش در آسیای شرقی ایفا می‌کند (ژانگ و همکاران، ۲۰۱۵). تأثیر ENSO بر مناطق دیگر نیز پیچیدگی قابل توجهی را نشان می‌دهد. به عنوان مثال، در قطب شمال، تأثیر ENSO بر فراوانی وقوع رویدادهای گرمایش روزانه از اواخر دهه ۱۹۷۰، به دلیل تغییرات در شدت ENSO، به طور قابل توجهی تغییر کرده است (وانگ و همکاران،

دریا (Niño 3.4) تا ۱۸ ماه جلوتر نشان داده است (ژو و ژانگ، ۲۰۲۳). قابلیت این مدل در بازنمایی تکامل دمایی لایه‌های فوقانی اقیانوس و دینامیک‌های کوپل‌شده‌ی جو-اقیانوس، مؤید پتانسیل چشمگیر الگوریتم‌های یادگیری عمیق مبتنی بر داده برای پیش‌بینی ENSO است (ژو و ژانگ، ۲۰۲۳). با این حال، یکی از محدودیت‌های برخی از مدل‌های ML، ماهیت "جعبه سیاه" آنها است که می‌تواند مانع از تفسیر مکانیسم‌های فیزیکی زیربنایی محرک ENSO شود (ژو و ژانگ، ۲۰۲۳). استفاده از مدل‌های یادگیری ماشین برای پیش‌بینی ENSO منجر به توسعه چندین رویکرد نوآورانه شده است (کین و همکاران، ۲۰۲۴؛ گائو و همکاران، ۲۰۲۳؛ وانگ و همکاران، ۲۰۲۰). یک رویکرد ترکیبی چندمدلی (MME) که پیش‌بینی‌های حاصل از مدل‌های دینامیکی متعدد را با استفاده از روش‌های تصحیح خطای آماری مبتنی بر رگرسیون الگوی گام‌به‌گام (stepwise pattern regression) تلفیق می‌کند، ارتقاء مهارت در پیش‌بینی ENSO، به‌ویژه برای افق‌های پیش‌بینی کوتاه‌مدت (shorter lead times)، را به اثبات رسانده است (وانگ و همکاران، ۲۰۲۰). این رویکرد به طور موثری خطاها را در پیش‌بینی‌های مدل فردی کاهش می‌دهد و مهارت کلی پیش‌بینی را افزایش می‌دهد (وانگ و همکاران، ۲۰۲۰). مطالعه دیگری از استفاده داده جفت‌شده گروهی برای تخمین و تصحیح خطاهای مدل در پیش‌بینی ENSO استفاده کرده است (گائو و همکاران، ۲۰۲۳). این روش که روی مدل LDEOS اعمال شد، به طور قابل توجهی مهارت پیش‌بینی را، به‌ویژه برای زمان‌های پیشرو طولانی‌تر، بهبود بخشید (گائو و همکاران، ۲۰۲۳). علاوه بر این، یک مدل یادگیری عمیق جدید برای بررسی قابلیت پیش‌بینی رویداد ال نینو، با در نظر گرفتن تأثیر عدم قطعیت اولیه، توسعه یافته است (کین و همکاران، ۲۰۲۴). این مدل ماهرانه ویژگی‌های متنوع رویدادهای ال نینو مشاهده‌شده را

این تغییر به تغییرات در شدت ENSO نسبت داده می‌شود، به طوری که رویدادهای ENSO قوی‌تر از اواخر دهه ۱۹۷۰ منجر به پاسخ موج راسبی قوی‌تر و در نتیجه تأثیرگذاری بر کم فشار آلتوتی و الگوهای گردش جوی بر فراز اقیانوس آرام شمالی شده است (وانگ و همکاران، ۲۰۲۳). این امر بر تعاملات (Interactions) سیستم‌های آب و هوایی و پتانسیل پیامدهای پدیده دورپیوند ENSO، حتی در مناطقی که از نظر جغرافیایی از اقیانوس آرام استوایی دور هستند، تأکید می‌کند. روش‌های آماری سنتی و شبیه‌سازی‌های عددی برای دهه‌ها رکن اصلی پیش‌بینی ENSO بوده‌اند (وانگ و همکاران، ۲۰۲۰؛ تانگ و همکاران، ۲۰۱۸؛ ژانگ و همکاران، ۲۰۱۶). با این حال، پیشرفت‌های اخیر در یادگیری ماشین (ML) راه‌های جدیدی را برای بهبود دقت پیش‌بینی باز کرده است (ژو و ژانگ، ۲۰۲۳؛ کائو و همکاران، ۲۰۲۰؛ سانتوس و همکاران، ۲۰۲۰). الگوریتم‌های یادگیری ماشین (ML)، به ویژه مدل‌های یادگیری عمیق (DL)، در ثبت روابط پیچیده غیرخطی در مجموعه داده‌های بزرگ برتری دارند و به طور بالقوه از عملکرد روش‌های سنتی در پیش‌بینی ENSO فراتر می‌روند (ژو و ژانگ، ۲۰۲۳؛ کائو و همکاران، ۲۰۲۰؛ سانتوس و همکاران، ۲۰۲۰). برای مثال، شبکه‌های حافظه طولانی مدت کوتاه (LSTM) با موفقیت برای تجزیه و تحلیل داده‌های سری زمانی عناصر هواشناسی و دریایی به کار گرفته شده‌اند که منجر به بهبود دقت پیش‌بینی ENSO در مقایسه با روش‌های رگرسیون آماری مرسوم شده است (کائو و همکاران، ۲۰۲۰). مطالعات دیگری استفاده از شبکه‌های اقلیمی و تکنیک‌های یادگیری ماشین را برای طبقه‌بندی فازهای ENSO بررسی کرده‌اند و به دقت بالایی در پیش‌بینی شدت رویدادهای ENSO دست یافته‌اند (سانتوس و همکاران، ۲۰۲۰). علاوه بر این، یک شبکه عصبی مبتنی بر خود توجهی، به نام 3D-Geoformer، مهارت استثنایی در پیش‌بینی ناهنجاری‌های دمای سطح

مدل‌ها همچنان پابرجا هستند (چن و همکاران، ۲۰۲۳؛ سیفوننتس و همکاران، ۲۰۲۰؛ گائو و همکاران، ۲۰۱۶). یک مدل جامع برای پیش‌بینی ENSO باید طیف گسترده‌ای از منابع داده، از جمله داده‌های جو بالایی را برای ثبت برهم‌کنش‌ها یا تعاملات پیچیده در سیستم آب و هوا در خود جای دهد (چن و همکاران، ۲۰۲۳؛ سیفوننتس و همکاران، ۲۰۲۰؛ گائو و همکاران، ۲۰۱۶). با این حال، ادغام این مجموعه داده‌های متنوع ساده نیست و نیاز به تکنیک‌های پردازش داده پیشرفته دارد (اسلیتر و همکاران، ۲۰۲۳؛ بناویتا و لالویاکس، ۲۰۲۰؛ فنگ و همکاران، ۲۰۱۰). استفاده از یادگیری ماشین برای استنباط و تصحیح خطای مدل نیز برای بهبود دقت پیش‌بینی بسیار مهم است (گائو و همکاران، ۲۰۲۳؛ آنوچی و همکاران، ۲۰۲۱). مدل‌های یادگیری ماشین را می‌توان برای شناسایی و تصحیح خطاهای سیستماتیک مدل آموزش داد و قابلیت اطمینان پیش‌بینی‌های ENSO را افزایش داد (گائو و همکاران، ۲۰۲۳؛ آنوچی و همکاران، ۲۰۲۱). علاوه بر این، سیستم‌های پیش‌بینی ترکیبی، که مدل‌های دینامیکی را با مدل‌های هوش مصنوعی ترکیب می‌کنند، در افزایش مهارت پیش‌بینی متغیرهای مختلف هواشناسی و آب‌وهوایی نویدبخش بوده‌اند (دانلی و همکاران، ۲۰۲۳). این سیستم‌ها می‌توانند از نقاط قوت رویکردهای دینامیکی و داده‌محور بهره ببرند و منجر به پیش‌بینی‌های دقیق‌تر و قابل اعتمادتر شوند (دانلی و همکاران، ۲۰۲۳). توسعه و کاربرد این مدل‌های ترکیبی برای پیشبرد زمینه پیش‌بینی ENSO ضروری است. در حالی که پیشرفت‌های قابل توجهی در پیش‌بینی کوتاه‌مدت آب و هوا حاصل شده است، کاربرد یادگیری ماشین در پیش‌بینی اقلیم میان‌مدت تا بلندمدت، از جمله پیش‌بینی ENSO، با چالش‌هایی روبروست (چن و همکاران، ۲۰۲۳). این چالش‌ها شامل پیچیدگی متغیرهای اقلیمی، محدودیت‌های داده و نیاز به مدل‌های قابل تفسیر فیزیکی است (چن و همکاران، ۲۰۲۳).

شبه‌سازی می‌کند و سریع‌تر خطاهای اولیه در پیش‌بینی‌ها را شناسایی می‌کند (کین و همکاران، ۲۰۲۴). این پیشرفت‌ها در تکنیک‌های ML به طور مداوم دقت و قابلیت اطمینان پیش‌بینی‌های ENSO را بهبود می‌بخشند. با این حال، چالش‌ها از نظر تفسیرپذیری مدل، هزینه محاسباتی و تعمیم‌پذیری همچنان باقی است. پرداختن به محدودیت‌های مدل‌های پیش‌بینی ENSO موجود، تحقیقات را به سمت تکنیک‌های پیچیده‌تر سوق داده است (چن و همکاران، ۲۰۱۵؛ چاپمن و همکاران، ۲۰۱۵؛ چنگ و همکاران، ۲۰۱۰). این مطالعات نشان داده‌اند که گنجاندن اطلاعات زیر سطحی و تاریخچه SST چند تراز، مهارت پیش‌بینی را به طور قابل توجهی بهبود می‌بخشد (چن و همکاران، ۲۰۱۵). علاوه بر این، یک مدل خودرگرسیون برداری (VAR)، که روش معکوس خطی (LIM) را تعمیم می‌دهد، برای پیش‌بینی ENSO توسعه یافته است (چاپمن و همکاران، ۲۰۱۵). این مدل با استفاده از داده‌های ناهنجاری دمای سطح دریا (SSTA) در ماه‌های گذشته، به مهارتی بالاتر در پیش‌بینی نسبت به مدل LIM دست می‌یابد (چاپمن و همکاران، ۲۰۱۵). استراتژی‌های ساخت گروه برای بهبود پیش‌بینی‌های ENSO نیز با استفاده از مدل LDEO5 بررسی شده است (چنگ و همکاران، ۲۰۱۰). این تحقیق رویکردهای مختلفی را برای تولید گروه‌ها، از جمله آشفتگی اولیه بهینه، بادهای ناهنجرار فرکانس بالا واقعی و الگوهای تصادفی بررسی کرد (چنگ و همکاران، ۲۰۱۰). نتایج، اهمیت در نظر گرفتن استراتژی‌های مختلف ساخت گروه را برای به دست آوردن پیش‌بینی‌های ENSO قابل اعتماد و ماهرانه نشان می‌دهد (چنگ و همکاران، ۲۰۱۰). این مطالعات تلاش‌های مداوم برای بهبود دقت پیش‌بینی ENSO از طریق تکنیک‌های مدل‌سازی پیشرفته را نشان می‌دهد. علی‌رغم پیشرفت‌های چشمگیر در پیش‌بینی ENSO با رویکردهای یادگیری ماشین، چالش‌هایی نظیر ادغام داده‌های ناهمگون و متنوع و بهبود تفسیرپذیری

شاخص‌های ENSO پیش‌بینی شده و واقعی را در طول دوره آزمایش خود نشان دادند؛ یافته‌های آنها نقاط قوت مدل‌های یادگیری عمیق را در شناسایی پیش‌بینی‌کننده‌های حیاتی فازهای ENSO، نشان داد (ایبوچی و ریچمن، ۲۰۲۴). گنگ و وانگ (۲۰۲۱) نیز یک مدل حافظه طولانی مدت کانولوشنال متراکم را به طور خاص برای پیش‌بینی ENSO پیشنهاد کردند و نشان دادند که مدل فضازمانی آنها پیش‌بینی‌های قابل توجهی را ارائه می‌دهد و ادغام داده‌های شبیه‌سازی تاریخی اضافی در فرآیندهای آموزشی، روندی را در مدل‌های یادگیری عمیق منعکس می‌کند که در آن گسترش مجموعه داده، استحکام پیش‌بینی‌ها را افزایش می‌دهد (گنگ و وانگ، ۲۰۲۱). مطالعات متعددی نیز مدل‌های مختلف یادگیری عمیق را در برابر روش‌های پیش‌بینی سنتی محک زده‌اند و اظهار داشته‌اند که در حالی که مدل‌های آماری مزایای خاصی دارند، چارچوب‌های یادگیری عمیق اغلب معیارهای عملکرد بهبود یافته‌ای را در پیش‌بینی رویدادهای ENSO ارائه می‌دهند. برای مثال، مو و همکاران (۲۰۲۱) یک مدل جفت شده هوا-دریا چند متغیره توسعه دادند که به طور قابل توجهی از چندین سیستم پیش‌بینی سنتی بهتر عمل کرد (مو و همکاران، ۲۰۲۱). این نشان دهنده تغییر مهمی در روش‌های مدل‌سازی است. ENSO به طور قابل توجهی بر الگوهای آب و هوایی در ایران تأثیر می‌گذارد و روندهای بارش و دما را دستخوش تغییر می‌کند. تحقیقات نشان داده است که تغییرات دمای سطح دریا در طول فازهای ال نینو و لانینا با تغییر الگوهای بارش در مناطق مختلف ایران مرتبط است. برای نمونه در مطالعه‌ای اثرات ENSO بر بارندگی در ایران بررسی شد که افزایش قابل توجهی در بارش مرتبط با رویدادهای ال نینو در آن مشاهده گردید (قلی‌زاده، ۲۰۱۵). این همبستگی، نقش این پدیده را به عنوان یک عامل محرک آب و هوایی مهم در منطقه برجسته می‌کند. در مطالعه دیگری با استفاده از تحلیل همبستگی نشان داده شد که هم

با این حال، مزایای بالقوه استفاده از یادگیری ماشین برای پیش‌بینی اقلیم قابل توجه است و توانایی بهبود دقت و کارایی را دارد (سیفوننتس و همکاران، ۲۰۲۰؛ گائو و همکاران، ۲۰۱۶). ادغام داده‌های سنجش از دور، مشاهدات هواشناسی و مدل‌سازی هیدرولوژیکی، همراه با شاخص‌های اقلیمی، می‌تواند به طور قابل توجهی قابلیت‌های پیش‌بینی مدل‌های یادگیری ماشین را افزایش دهد (گائو و همکاران، ۲۰۱۶). علاوه بر این، استفاده از تکنیک‌های پیشرفته‌ای مانند مدل‌های ترکیبی یادگیری عمیق می‌تواند دقت پیش‌بینی فازهای پدیده ENSO را بهبود بخشد (چاتوپادیای و همکاران، ۲۰۲۰). با این حال که تکنیک‌های یادگیری ماشین پتانسیل زیادی برای بهبود دقت پیش‌بینی ENSO نشان داده‌اند، ادغام داده‌های جو بالایی هنوز مورد بررسی قرار نگرفته است. ترکیب داده‌های جو بالایی همراه با تکنیک‌های پیشرفته ML و روش‌های تجزیه و تحلیل داده‌های قوی، می‌تواند جهش چشم‌گیری در پیش‌بینی ENSO و ارتقاء قابلیت‌های پیش‌بینی اقلیمی جهانی را داشته باشد (سانتوس و همکاران، ۲۰۲۰؛ نیک‌رفتار و خانیانی، ۲۰۱۸؛ ژانگ و همکاران، ۲۰۱۶). لو و همکاران (۲۰۲۰) یک مدل پیش‌بینی آماری با استفاده از تکنیک‌های یادگیری عمیق توسعه دادند و پیش‌بینی‌های کارآمد رویدادهای ENSO را تا ۱۸ ماه جلوتر ارائه کردند. مدل شبکه عصبی کانولوشنال (CNN) آنها عملکرد بهتری را در مقایسه با سیستم‌های پیش‌بینی دینامیکی سنتی نشان داد و اثربخشی روش‌های یادگیری عمیق را در تعاملات پیچیده موجود در داده‌های آب و هوایی نشان داد (لو و همکاران، ۲۰۲۰). علاوه بر این، چارچوب‌های یادگیری عمیق در مطالعات مختلف برای تجزیه و تحلیل و پیش‌بینی ویژگی‌های ENSO استفاده شده‌اند. ایبوچی و همکاران (۲۰۲۴) شبکه‌های LSTM و خودرمزگذارها را برای پرداختن به الگوهای غیرخطی دمای سطح دریا به کار بردند و همبستگی قوی بین

بازتحلیل ERA5 و در تأخیرهای زمانی متفاوت، به عنوان ورودی بهره می‌برد. هدف اصلی این پژوهش، پاسخ به این پرسش است که آیا گنجاندن اطلاعات جو بالا می‌تواند به طور معناداری مهارت و افق پیش‌بینی (skill and lead time) پدیده ENSO را ارتقا دهد و در نهایت به سیستم‌های پیش‌بینی قابل اعتمادتری برای پشتیبانی از تصمیم‌گیری‌های مرتبط با اقلیم منجر شود.

۲ روش پژوهش

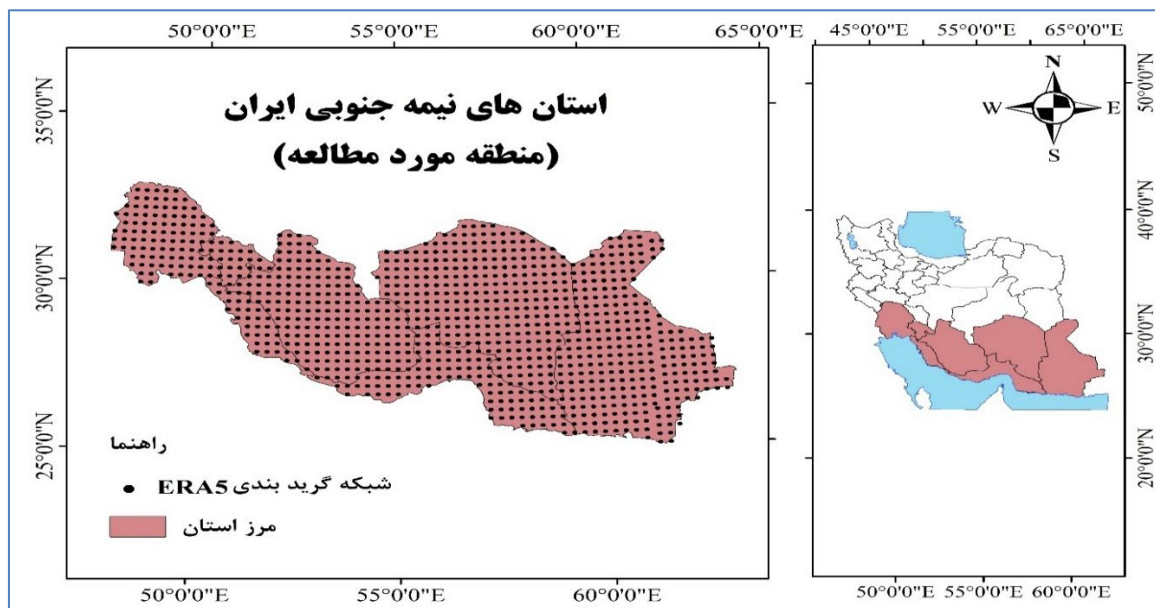
۲-۱ داده‌ها و منطقه مورد مطالعه

شاخص اقیانوسی ONI (Oceanic Niño Index)، شاخص اصلی سازمان ملی اقیانوسی و جوی آمریکا (NOAA) برای پایش بخش اقیانوسی الگوهای اقلیمی فصلی موسوم به نوسان جنوبی-ال نینو (ENSO) محسوب می‌شود؛ شاخص ONI میانگین متحرک دمای سطح دریا طی دوره‌های سه‌ماهه را در ناحیه مرکزی-شرقی اقیانوس آرام بین طول‌های جغرافیایی ۱۲۰ تا ۱۷۰ درجه غربی، دنبال می‌کند و نشان می‌دهد که آیا این دماها نسبت به مقدار میانگین بلندمدت گرم‌تر یا سردتر هستند. بر اساس تعریف NOAA، شرایط ال نینو زمانی در اقیانوس برقرار است که مقدار ONI در ناحیه نینو ۳.۴ (Niño 3.4) به میزان $+0.5$ یا بیشتر برسد، به این معنا که دمای سطحی آب در این منطقه حداقل 0.5 درجه سلسیوس (0.9 درجه فارنهایت) بالاتر از میانگین باشد. در مقابل، شرایط اقیانوسی لائینا زمانی وجود دارد که مقدار ONI برابر یا کمتر از -0.5 باشد، که نشان‌دهنده کاهش دمای سطح آب در این منطقه به میزان حداقل 0.5 درجه سلسیوس نسبت به میانگین است (سایت اقلیمی نوآ، ۲۰۰۹). در این راستا پژوهش حاضر با هدف مدل‌سازی شاخص اقیانوسی نینو (ONI) بر اساس داده‌های هواشناسی در نیمه جنوبی ایران انجام شد. داده‌ها شامل ارتفاع ژئوپتانسیل (Z)، دما (T)، رطوبت نسبی (R)، رطوبت ویژه (Q)، مؤلفه افقی باد (U) و مؤلفه عمودی باد (V) بودند که

شاخص نوسان جنوبی (SOI) و هم‌ناهنجاری‌های دمای سطح دریا (SST) مرتبط با ENSO به طور قابل توجهی با تغییرپذیری بارش در ایران مرتبط هستند (امینی و همکاران، ۲۰۲۰). در این مطالعه نشان داده شد که نوسان جنوبی می‌تواند بسته به فاز ENSO، شرایط خشکسالی را در مناطق مختلف تشدید یا بهبود بخشد (امینی و همکاران، ۲۰۲۰). این امر نشان می‌دهد که مدل‌های پیش‌بینی کننده آب و هوا در ایران باید ENSO را به عنوان یک پارامتر اساسی در تحلیل‌های خود در نظر بگیرند (قاسمی، ۲۰۱۹). با توجه به ماهیت مکانی-زمانی داده‌های ورودی (سری‌های زمانی ماهانه ERA5 با توزیع مکانی) و هدف پیش‌بینی پیوسته شاخص ONI، استفاده از مدل ConvLSTM2D توجیه‌پذیر است. این مدل با ادغام فیلترهای کانولوشنی در ساختار حافظه‌دار LSTM می‌تواند هم‌زمان ویژگی‌های مکانی و زمانی را استخراج و وابستگی‌های مکانی-زمانی را مدل کند (ناز و همکاران، ۲۰۲۴). در مقابل، معماری CNN-LSTM ابتدا کانولوشن را بر روی هر فریم مکانی اعمال کرده و سپس توالی ویژگی‌های حاصل را به LSTM می‌دهد، که منجر به تفکیک یا جداسازی پردازش مکانی و زمانی می‌شود. این جداسازی ممکن است پوشش الگوهای هم‌زمان مکانی-زمانی را ناقص کند. بنابراین، با توجه به ابعاد مکانی-زمانی و لزوم پیش‌بینی پیوسته ONI، ConvLSTM2D گزینه منطقی‌تری نسبت به CNN-LSTM محسوب می‌شود. از این رو، این پژوهش یک رویکرد جدید برای پیش‌بینی ENSO معرفی می‌کند که در آن، اطلاعات دینامیکی از پروفیل عمودی جو را با یک معماری یادگیری عمیق مکانی-زمانی (Spatiotemporal) ادغام می‌نماید؛ که قادر است به طور هم‌زمان الگوهای مکانی (از طریق CNN) و وابستگی‌های زمانی (از طریق LSTM) را از داده‌ها استخراج کند. برخلاف مطالعات پیشین که عمدتاً بر SST متمرکز بودند، این پژوهش از داده‌های متنوع و در چند تراز فشاری از مجموعه داده

بویراحمد، فارس، بوشهر، هرمزگان، کرمان و سیستان و بلوچستان است (شکل ۱). برای بررسی تأثیر تأخیر زمانی، داده‌ها در چهار حالت (بدون تأخیر، تأخیر یک‌ماهه، دوماهه و سه‌ماهه) نسبت به شاخص ONI سازمان‌دهی شدند. داده‌های خام در فایل‌های اکسل ذخیره شده، با استفاده از روش MinMaxScaler نرمال‌سازی شدند و به فرمت سه‌بعدی (تعداد نمونه‌ها، گام‌های زمانی، ویژگی‌ها) تبدیل شدند تا برای مدل‌های یادگیری عمیق مناسب شوند.

از مجموعه داده‌های بازتحلیل ERA5 با تفکیک مکانی ۰/۲۵ درجه استخراج شدند. این داده‌ها برای بازه زمانی ۱۹۹۴ تا ۲۰۲۳ و در چهار سطح فشار جوی شامل ۱۰۰۰ هکتوپاسکال (نزدیک به سطح دریا)، ۸۵۰ هکتوپاسکال (ارتفاع تقریبی ۱/۵ کیلومتر)، ۷۰۰ هکتوپاسکال (ارتفاع تقریبی ۳ کیلومتر) و ۵۰۰ هکتوپاسکال (ارتفاع تقریبی ۵/۵ کیلومتر) به صورت میانگین ماهانه جمع‌آوری شدند. منطقه مورد مطالعه شامل استان‌های خوزستان، کهگیلویه و



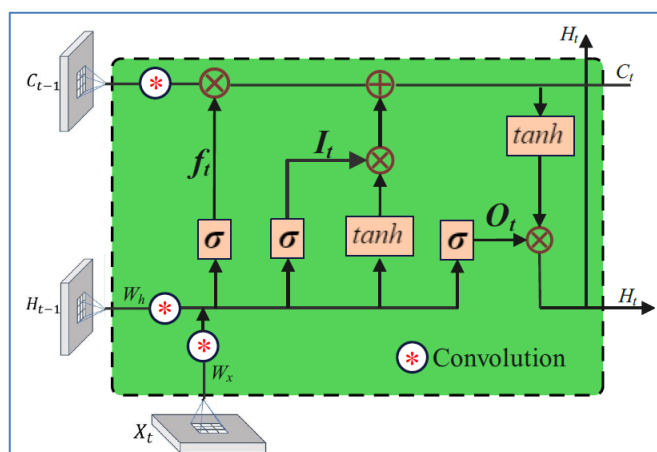
شکل ۱. نقشه منطقه مورد مطالعه شامل استان‌های خوزستان، کهگیلویه و بویراحمد، فارس، بوشهر، هرمزگان، کرمان و سیستان و بلوچستان و شبکه ۰.۲۵

درجه‌ای مجموعه داده‌های بازتحلیل ERA5

عملیات کانولوشن در ساختار داخلی گیت‌های خود (مشابه LSTM)، قادر است تکامل و دینامیک این الگوهای فضایی را در طول زمان مدل‌سازی کرده و ویژگی‌های فضا-زمانی را ثبت نماید. این مدل قادر است، هم جزئیات دقیق محلی و هم الگوهای فضایی گسترده‌تر را به طور همزمان ثبت کند. این معماری، با ترکیب لایه‌های کانولوشن برای تحلیل فضا و لایه‌های بازگشتی برای تحلیل زمان، یک راهکار جامع برای درک و پیش‌بینی سیستم‌های دینامیکی که در داده‌های توالی‌دار تصویری وجود دارند، ارائه می‌دهد (شکل ۲) (ناز و همکاران، ۲۰۲۴).

۲-۲ مدل ConvLSTM2D

مدل ConvLSTM2D، یک معماری شبکه عصبی دو جزئی است که برای تحلیل داده‌های توالی‌دار فضا-زمانی طراحی شده است. این معماری، لایه Conv2D توزیع‌شده در زمان (Time-Distributed Conv2D) را با لایه بازگشتی ConvLSTM2D ترکیب می‌کند. لایه توزیع‌شده در زمان، عملیات کانولوشن را به صورت موازی بر روی هر ورودی در دنباله اعمال کرده و به این ترتیب، الگوهای فضایی را در هر گام زمانی به طور مستقل استخراج می‌کند. خروجی این لایه که شامل ویژگی‌های فضایی است، به لایه ConvLSTM2D منتقل می‌شود. این لایه بازگشتی، با ادغام

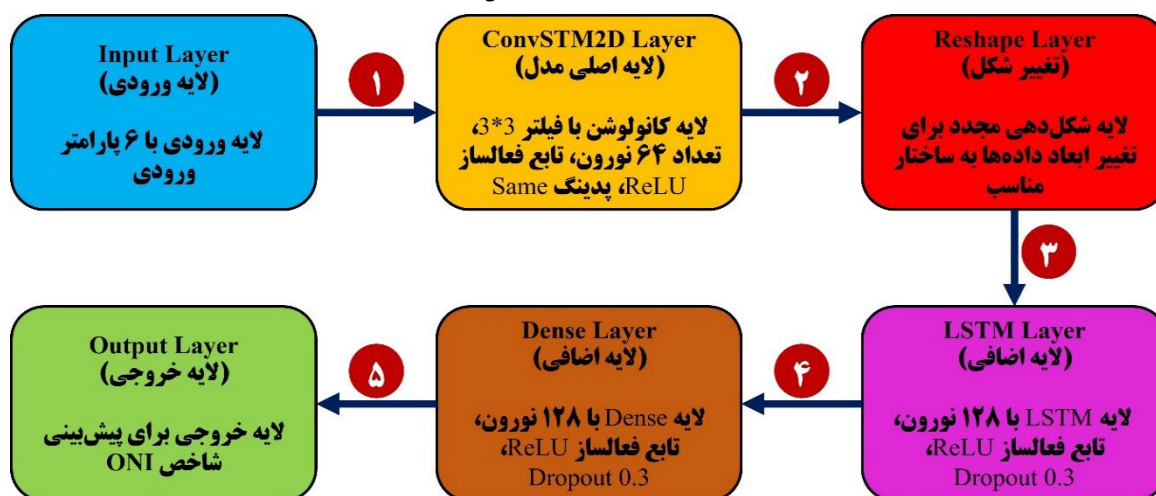


شکل ۲. ساختار کلی و پایه مدل ConvLSTM2D.

۲-۳ طراحی معماری مدل

برای پیش‌بینی نمایه ONI، یک مدل هیبریدی پیشرفته مبتنی بر یادگیری عمیق طراحی شد که ترکیبی از لایه‌های ConvLSTM2D، LSTM و Dense است. این معماری به منظور استخراج ویژگی‌های فضایی-زمانی و مدل‌سازی وابستگی‌های زمانی پیچیده توسعه یافت. این ساختار

ترکیبی به دلیل توانایی در درک هم‌زمان ویژگی‌های مکانی و زمانی نسبت به مدل‌های ساده‌تر مانند LSTM یا GRU عملکرد دقیق‌تری در پیش‌بینی سری‌های زمانی اقلیمی از خود نشان داده است (کومار و شریواستاوا، ۲۰۲۵). ساختار مدل مورد استفاده شامل موارد زیر است (شکل ۳):



شکل ۳. پیکره بندی ساختار فرآیندهای مرحله‌ای مدل ConvLSTM2D برای پیش‌بینی شاخص ONI.

لایه ConvLSTM2D با ۶۴ نورون، کرنل 3×3 ، تابع فعال‌ساز ReLU و پدینگ "same" به منظور حفظ ابعاد ورودی و استخراج الگوهای فضایی-زمانی است. خروجی این لایه با استفاده از عملیات بازآرایی (Reshape) به فرم قابل‌قبولی برای پردازش در لایه بعدی تبدیل می‌شود. در ادامه، یک لایه LSTM با ۱۲۸ نورون برای تحلیل

برای طراحی مدل مذکور از محیط کدنویسی VsCode و کتابخانه‌های از کتابخانه‌های NumPy و Pandas برای مدیریت و پردازش داده‌ها، TensorFlow و Keras برای توسعه و پیاده‌سازی مدل اصلی، Scikit-learn برای ارزیابی و پیش‌پردازش مدل و از Matplotlib و Seaborn برای بصری‌سازی نتایج استفاده شده است. این مدل شامل یک

که در آنها y_i مقدار واقعی ONI و \hat{y}_i مقدار پیش‌بینی شده و n تعداد نمونه‌ها است. این معیارها برای مجموعه‌های آموزش و اعتبارسنجی در هر دوره محاسبه شدند تا رفتار مدل در طول آموزش و احتمال بیش‌برازش بررسی شود.

$$R^2 = 1 - \left[\frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \right] \quad (۳)$$

که در آن y_i مقدار واقعی ONI، \hat{y}_i مقدار پیش‌بینی شده و \bar{y} میانگین مقادیر واقعی است و نشان‌دهنده میزان توضیح واریانس داده‌ها توسط مدل است.

۲-۴-۲ نمودار مقایسه مقادیر واقعی و پیش‌بینی شده در مرحله آموزش

برای ارزیابی بصری عملکرد مدل در بازتولید الگوهای مشاهده‌شده، مقادیر واقعی و پیش‌بینی‌شده ONI در مجموعه آزمون مقایسه شدند. این مقایسه با استفاده از اختلاف نسبی (رابطه ۴) محاسبه شد:

$$RD_i = ((y_i - \hat{y}_i) / y_i) * 100 \quad (۴)$$

که RD_i اختلاف نسبی برای نمونه i ام است و به‌صورت درصد بیان می‌شود. این معیار به تحلیل انحرافات نسبی در مقیاس‌های مختلف کمک می‌کند. نمودارها برای هر سناریو ترسیم شدند تا دقت مدل در هر تراز فشار جو و تأخیر زمانی بررسی شود.

۳-۴-۲ ماتریس درهم‌ریختگی

پیش‌بینی‌های ONI به سه فاز اقلیمی دسته‌بندی شدند: لائینا ($-0.5 < ONI < 0.5$)، خنثی ($ON I \leq -0.5$) و الینو ($ON I \geq 0.5$) و ماتریس درهم‌ریختگی برای ارزیابی دقت این طبقه‌بندی، محاسبه شد. این ماتریس به‌صورت زیر تعریف می‌شود (رابطه ۵):

$$CM = \begin{bmatrix} TP & FP & FP \\ FN & TP & FP \\ FN & FN & TP \end{bmatrix} \quad (۵)$$

که در آن TP (True Positive) تعداد پیش‌بینی‌های مثبت درست، FP (False Positive) پیش‌بینی‌های

وابستگی‌های بلندمدت در سری‌های زمانی به کار گرفته شده است. سپس یک لایه Dense با ۱۲۸ نورون و تابع فعال‌ساز ReLU، به همراه یک لایه Dropout با آهنگ ۰/۳ برای کاهش بیش‌برازش و افزایش تعمیم‌پذیری استفاده شده است. در پایان، یک لایه خروجی Dense با یک نورون برای تولید مقدار پیش‌بینی‌شده شاخص نوسان جنوبی (ONI) در نظر گرفته شده است. این مدل با استفاده از بهینه‌ساز Adam با آهنگ یادگیری ۰/۰۰۱، تابع هزینه میانگین مربعات خطا (MSE) و معیار ارزیابی میانگین خطای مطلق (MAE) کامپایل شده و به‌صورت جداگانه برای هر یک از ۱۶ سناریو (ترکیب ۴ تراز فشار با ۴ تأخیر زمانی مختلف) اجرا گردیده است (شکل ۳).

۴-۲ آموزش و اعتبارسنجی مدل

داده‌ها با استفاده از روش تقسیم تصادفی به مجموعه‌های آموزش (۸۰٪) و آزمون (۲۰٪) با مقدار ثابت (random state) ۴۲ تقسیم شدند تا نتایج قابل تکرار باشند. مدل برای هر سناریو به مدت ۵۰ دوره (epoch) با اندازه دسته (state batch) ۳۲ آموزش داده شد و از early stopping با تحمل ۵ دوره برای جلوگیری از بیش‌برازش استفاده گردید.

۱-۴-۲ ارزیابی مدل

ارزیابی مدل در هر ۱۶ سناریو (۴ تراز فشاری و ۴ تأخیر زمانی) با استفاده از معیارهای کمی انجام شد تا دقت پیش‌بینی‌ها و تناسب مدل با داده‌ها سنجیده شود. معیارهای مورد استفاده عبارتند از میانگین مربعات خطا (MSE)، میانگین خطای مطلق (MAE) و ضریب تعیین (R^2) که به ترتیب در روابط ۱، ۲، ۳، ۴ نشان داده شده است.

$$MSE = (1/n) * \sum (y_i - \hat{y}_i)^2 \quad (۱)$$

$$MAE = (1/n) * \sum |y_i - \hat{y}_i| \quad (۲)$$

۳ نتایج

۱-۳ ارزیابی مدل

نتایج ارائه شده در جدول ۱ نشان دهنده عملکرد مدل ConvLSTM2D در پیش بینی فازهای ENSO با استفاده از داده های جوی در ترازهای مختلف فشار (۱۰۰۰، ۸۵۰، ۷۰۰ و ۵۰۰ هکتوپاسکال) و در چهار حالت زمانی (بدون تأخیر و تأخیرهای یک، دو و سه ماهه) است. معیارهای ارزیابی شامل R^2 (دقت تطابق مدل)، MAE (میانگین خطای مطلق) و MSE (میانگین مجذور خطا) هستند.

بررسی این نتایج نشان می دهد که مدل در ترازهای بالاتر (۵۰۰ و ۷۰۰ هکتوپاسکال) عملکرد بهتری نسبت به ترازهای نزدیک به زمین (۱۰۰۰ و ۸۵۰ هکتوپاسکال) دارد. به عنوان مثال، در حالت بدون تأخیر، R^2 از ۰/۳۳ در تراز ۱۰۰۰ هکتوپاسکال به ۰/۹۲ در تراز ۵۰۰ هکتوپاسکال افزایش می یابد، در حالی که MAE و MSE به ترتیب از ۰/۵۳ و ۰/۵۰ به ۰/۱۵ و ۰/۰۶ کاهش می یابند. این روند در تأخیرهای زمانی دیگر نیز مشاهده می شود و حاکی از اهمیت داده های ترازهای بالاتر در بهبود دقت پیش بینی است. تأثیر تأخیر زمانی نیز بر عملکرد مدل قابل توجه است. در تراز ۵۰۰ هکتوپاسکال، بهترین نتیجه در تأخیر سه ماهه با R^2 برابر ۰/۹۳، MAE برابر ۰/۱۴ و MSE برابر ۰/۰۴ به دست آمده که از حالت بدون تأخیر (R^2 Score = ۰/۹۲) بهتر است که با مطالعه سبزی پرور و همکاران (۲۰۱۰) هماهنگی دارد (سبزی پرور و همکاران، ۲۰۱۰). این بهبود می تواند به تأخیر در انتقال سیگنال های جوی از ترازهای بالاتر به سطح زمین مرتبط باشد، که مدل با در نظر گرفتن آن، الگوهای بلندمدت را بهتر تشخیص می دهد. در مقابل، در تراز ۱۰۰۰ هکتوپاسکال، تأخیر زمانی تأثیر کمتری دارد و بهترین عملکرد در تأخیر یک ماهه با R^2 برابر ۰/۴۱ ثبت شده که همچنان پایین تر از ترازهای بالاتر است. این تفاوت نشان می دهد که داده های ترازهای نزدیک به زمین برای پیش بینی های کوتاه مدت مناسب ترند، در حالی که ترازهای

مثبت نادرست، و FN (False Negative) پیش بینی های منفی نادرست را برای فازهای لانینا (L)، خنثی (N) و ال نینو (E) نشان می دهد. این ماتریس برای هر سناریو ترسیم شد تا عملکرد طبقه بندی، تحلیل شود.

۲-۴-۴ اهمیت پارامترها

برای شناسایی نقش هر متغیر هواشناسی (Z, R, Q, T, U, V) در پیش بینی ONI، اهمیت ویژگی ها با روش جابه جایی محاسبه گردید. این روش با تغییر تصادفی ترتیب مقادیر یک متغیر و بدون تغییر در سایر متغیرها و اندازه گیری افزایش معیار MSE، تأثیر آن را تعیین می کند (رابطه ۶):

$$Feature Importance_j = (MSE_{permuted_j} - MSE_{baseline}) \quad (6)$$

که در آن $MSE_{permuted_j}$ خطای مدل پس از جابه جایی ویژگی j ام و $MSE_{baseline}$ خطای پایه است که این تحلیل نیز برای هر تراز فشاری و تأخیر زمانی انجام شده است.

۲-۵ پیش بینی آینده فازها برای سال های

۲۰۲۶-۲۰۲۷

داده های سال های ۲۰۲۶ و ۲۰۲۷ برای هر شش پارامتر ورودی از جدیدترین سناریوهای ارائه شده در چارچوب مدل های جهانی اقلیمی CMIP6 و تحت سناریوی SSP2-4.5 استخراج شدند. این داده ها با روشی مشابه داده های مرحله آموزش پیش پردازش (نرمال سازی و باز آرایشی) گردیدند. مدل آموزش دیده بر روی این داده ها، در قالب ۱۶ حالت ترکیبی (شامل چهار تراز فشار مختلف و چهار تأخیر زمانی گوناگون)، اعمال شد و نتایج پیش بینی شده در سه فاز اقلیمی لانینا (L)، خنثی (N) و ال نینو (E) دسته بندی گردیدند (جدول ۲ تا ۵). در نهایت، تحلیل توزیع مکانی و تغییرات زمانی فازها به منظور بررسی الگوهای اقلیمی آینده صورت گرفت.

جدول ۱. نتایج ارزیابی مدل ConvLSTM2D برای ۴ تراز فشاری ۱۰۰۰، ۸۵۰، ۷۰۰ و ۵۰۰ هکتوپاسکال در ۴ حالت تأخیر زمانی شامل بدون تأخیر، تأخیر یک‌ماهه، دو‌ماهه و سه‌ماهه

| بدون تأخیر زمانی | | | |
|---------------------|--------------------------|---------------------------|----------------|
| | Mean Squared Error (MSE) | Mean Absolute Error (MAE) | R ² |
| ۱۰۰۰ هکتوپاسکال | ۰/۵۰ | ۰/۵۳ | ۰/۳۳ |
| ۸۵۰ هکتوپاسکال | ۰/۳۲ | ۰/۴۱ | ۰/۵۷ |
| ۷۰۰ هکتوپاسکال | ۰/۱۶ | ۰/۲۸ | ۰/۷۸ |
| ۵۰۰ هکتوپاسکال | ۰/۰۶ | ۰/۱۵ | ۰/۹۲ |
| تأخیر زمانی یک ماهه | | | |
| | Mean Squared Error (MSE) | Mean Absolute Error (MAE) | R ² |
| ۱۰۰۰ هکتوپاسکال | ۰/۴۵ | ۰/۵۰ | ۰/۴۱ |
| ۸۵۰ هکتوپاسکال | ۰/۳۳ | ۰/۴۲ | ۰/۵۵ |
| ۷۰۰ هکتوپاسکال | ۰/۱۳ | ۰/۲۴ | ۰/۸۲ |
| ۵۰۰ هکتوپاسکال | ۰/۰۶ | ۰/۱۶ | ۰/۹۱ |
| تأخیر زمانی دو ماهه | | | |
| | Mean Squared Error (MSE) | Mean Absolute Error (MAE) | R ² |
| ۱۰۰۰ هکتوپاسکال | ۰/۴۷ | ۰/۵۲ | ۰/۳۶ |
| ۸۵۰ هکتوپاسکال | ۰/۳۰ | ۰/۳۹ | ۰/۵۹ |
| ۷۰۰ هکتوپاسکال | ۰/۱۳ | ۰/۲۴ | ۰/۸۲ |
| ۵۰۰ هکتوپاسکال | ۰/۰۵ | ۰/۱۶ | ۰/۹۲ |
| تأخیر زمانی سه ماهه | | | |
| | Mean Squared Error (MSE) | Mean Absolute Error (MAE) | R ² |
| ۱۰۰۰ هکتوپاسکال | ۰/۴۴ | ۰/۵۰ | ۰/۴۰ |
| ۸۵۰ هکتوپاسکال | ۰/۳۰ | ۰/۴۰ | ۰/۵۸ |
| ۷۰۰ هکتوپاسکال | ۰/۱۴ | ۰/۲۴ | ۰/۸۱ |
| ۵۰۰ هکتوپاسکال | ۰/۰۴ | ۰/۱۴ | ۰/۹۳ |

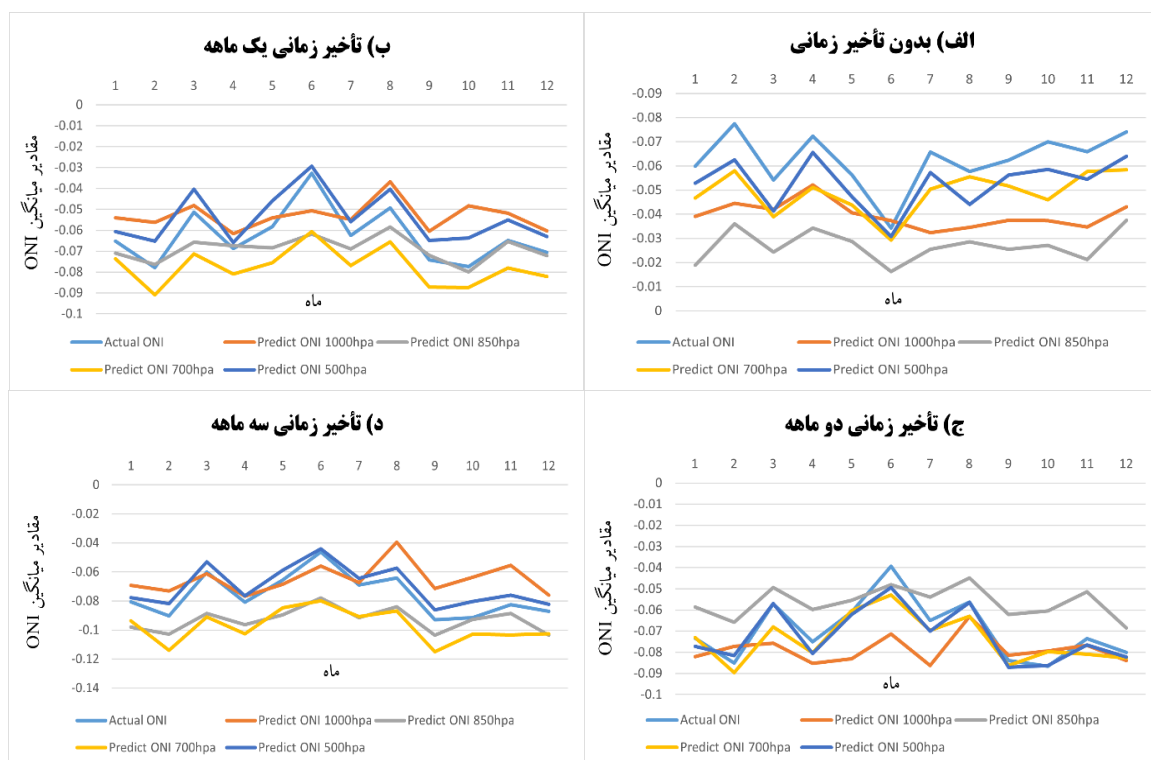
در این بخش، عملکرد مدل ConvLSTM2D در مرحله آموزش برای پیش‌بینی شاخص اقیانوسی نینو (ONI) مورد ارزیابی قرار گرفته است. این تحلیل مبتنی بر مقایسه میان میانگین ماهانه مقادیر واقعی ONI در طول دوره آموزش و مقادیر پیش‌بینی شده توسط مدل در چهار تراز فشار جوی

بالتر یا فوقانی برای پیش‌بینی‌های بلندمدت کارایی بیشتری دارند.

۲-۳ مقایسه مقادیر واقعی و پیش‌بینی شده در مرحله آموزش

افق‌های زمانی گوناگون می‌باشد. نتایج به دست آمده با معیارهای کمی مانند خطا و دقت (جدول ۱) همخوانی داشته و نمودارهای شکل ۴ به عنوان ابزار بصری پشتیبان این تحلیل‌ها محسوب می‌شوند.

مختلف (۵۰۰، ۷۰۰، ۸۵۰ و ۱۰۰۰ هکتوپاسکال) و تحت شرایط تأخیر زمانی بدون تأخیر تا سه ماهه است. هدف این ارزیابی، سنجش دقت مدل در بازنمایی داده‌های آموزشی و درک نقاط قوت و ضعف آن در ترازهای مختلف جو و



شکل ۴. مقایسه میانگین مقادیر واقعی و پیش‌بینی شده شاخص ONI در مرحله آموزش به صورت ماهانه در ۴ حالت تأخیر زمانی.

در این ترازهای (مطابق با جدول ۱) مطابقت دارد. شکل ۴-ب به سناریوی تأخیر زمانی یک‌ماهه مربوط می‌شود. در این حالت نیز تراز ۵۰۰ هکتوپاسکال دقت بالایی دارد، اما در برخی موارد مانند ماه چهارم، کم‌برآوردی جزئی مشاهده می‌شود (۰/۰۷- در مقابل ۰/۰۸- واقعی). در تراز ۷۰۰ هکتوپاسکال، مدل در بازسازی قله‌ها، مانند ماه ششم، بیش‌برآورد داشته و مقدار ۰/۰۱- را در برابر مقدار واقعی ۰/۰۲- پیش‌بینی کرده است. عملکرد مدل در تراز ۸۵۰ هکتوپاسکال کاهش یافته و نوسانات به‌درستی ثبت نمی‌شوند. تراز ۱۰۰۰ هکتوپاسکال نیز هرچند در برخی موارد انحرافات کمتری دارد، اما همچنان در بازسازی تغییرات شدید، به‌ویژه در افت‌ها و قله‌ها، ناکارآمد ظاهر

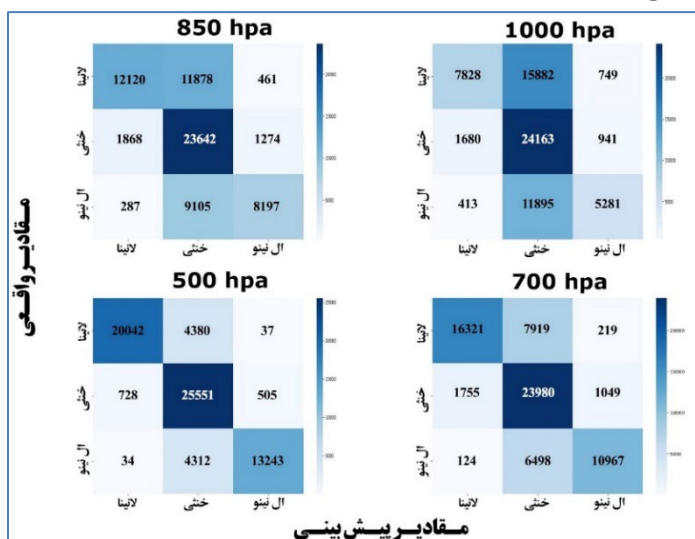
در شکل ۴-الف که مربوط به حالت بدون تأخیر زمانی است، بهترین عملکرد در تراز ۵۰۰ هکتوپاسکال مشاهده می‌شود. در این تراز، نوسانات شاخص به‌خوبی بازسازی شده‌اند و انحرافات نسبتاً کمی در مقایسه با مقادیر واقعی وجود دارد؛ به‌عنوان نمونه، مقدار پیش‌بینی شده در ماه پنجم ۰/۱۰- است، در حالی که مقدار واقعی ۰/۱۲- می‌باشد. در تراز ۷۰۰ هکتوپاسکال، مدل تمایل به بیش‌برآورد دارد، به‌خصوص در ماه‌های سوم تا هفتم، و منحنی خروجی نسبت به داده‌های واقعی صاف‌تر است. در ترازهای ۸۵۰ و ۱۰۰۰ هکتوپاسکال نیز توانایی مدل در بازسازی افت‌های شدید مانند افت ماه پنجم کاهش یافته و مدل به سمت مقادیر میانگین همگرا شده است که با افزایش میزان خطا

افق‌های زمانی طولانی‌تر، مدل در حفظ حافظه و دقت پیش‌بینی در برخی ترازها دچار ضعف می‌شود.

۳-۳ ماتریس درهم‌ریختگی

شکل ۵ تا ۸ عملکرد مدل ترکیبی ConvLSTM2D را در طبقه‌بندی فازهای ENSO در چهار وضعیت تأخیر زمانی (بدون تأخیر، یک، دو و سه‌ماهه) و در چهار تراز فشاری جو (۱۰۰۰، ۸۵۰، ۷۰۰ و ۵۰۰ هکتوپاسکال) نمایش می‌دهد. این ارزیابی امکان مقایسه دقت مدل در شرایط زمانی و ارتفاعی مختلف را فراهم می‌سازد. ماتریس‌های درهم‌ریختگی (Confusion Matrix) که در قالب نقشه‌های حرارتی (Heatmap) ترسیم شده‌اند، ارزیابی را به صورت بصری نمایش می‌دهند. در این نقشه‌ها، رنگ هر خانه بیانگر تعداد نمونه‌های طبقه‌بندی شده در آن است. بر اساس راهنمای رنگی، رنگ آبی تیره نشان‌دهنده تعداد بالا و رنگ آبی روشن (نزدیک به سفید) نشان‌دهنده تعداد پایین نمونه‌ها می‌باشد و نیز تمرکز رنگ تیره بر روی قطر اصلی ماتریس، تعداد بالای TP (پیش‌بینی مثبت درست) مدل را برای هر سه فاز (ال‌نینو، لانینا و خنثی) نشان می‌دهد.

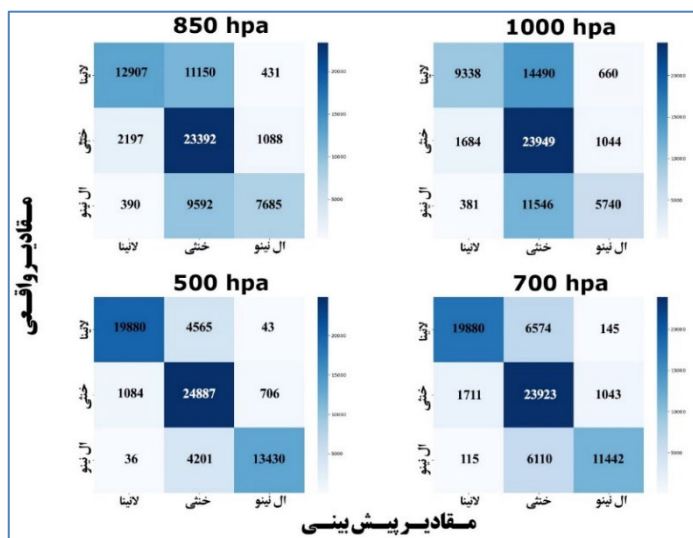
شده است. در شکل ۴-ج که به تأخیر زمانی دو ماهه مربوط است، تراز ۷۰۰ هکتوپاسکال عملکرد بهتری از سایر ترازها دارد و نوسانات پویا، به‌ویژه در بازه‌های زمانی ماه ۴ تا ۱۷م و ماه ۱۰ تا ۱۲م، با دقت خوبی بازسازی شده‌اند. این نتایج با معیارهای ارزیابی موجود در جدول ۱ نیز تأیید می‌شوند. در تراز ۵۰۰ هکتوپاسکال نیز تطابق قابل‌قبولی وجود دارد، اما نسبت به تراز ۷۰۰ در اولویت دوم قرار می‌گیرد. در مقابل، ترازهای ۸۵۰ و ۱۰۰۰ هکتوپاسکال، مشابه سناریوهای قبلی، به سمت میانگین تمایل پیدا کرده‌اند و در ثبت نوسانات شدید عملکرد ضعیف‌تری از خود نشان داده‌اند. در نهایت، شکل ۴-د مربوط به تأخیر زمانی سه‌ماهه است. در این حالت، تراز ۵۰۰ هکتوپاسکال بیشترین تطابق را با مقدار واقعی ONI داشته و در اکثر ماه‌ها توانسته است الگوهای اقیانوس-جو را به‌خوبی بازسازی کند. تراز ۱۰۰۰ هکتوپاسکال نیز به‌ویژه در نیمه اول سال عملکرد مناسبی از خود نشان داده، هرچند در نیمه دوم سال، از مقدار واقعی فاصله گرفته است. تراز ۷۰۰ هکتوپاسکال در بیشتر ماه‌ها مقادیر پیش‌بینی شده را کمتر از مقدار واقعی ارائه داده و تراز ۸۵۰ هکتوپاسکال نیز کاهش دامنه نوسانات را نشان می‌دهد. به‌طور کلی، این نتایج بیانگر آن است که در



شکل ۵. ماتریس درهم‌ریختگی مدل ConvLSTM2D برای طبقه‌بندی سه فاز پدیده ENSO (لانینا، خنثی و ال‌نینو) بر روی مجموعه داده آزمون در حالت بدون تأخیر زمانی

لاینا مشاهده می‌شود. در مقابل، در ترازهای پایین‌تر به‌خصوص ۱۰۰۰ هکتوپاسکال، به دلیل اثرگذاری اغتشاشات تراز و نوسانات کوتاه‌مدت، دقت مدل کاهش یافته و خطاهای طبقه‌بندی افزایش یافته‌اند. نتایج ارزیابی عددی این ترازهای نیز که در جدول ۱ ارائه شده‌اند، این تفاوت عملکرد را تأیید می‌کنند.

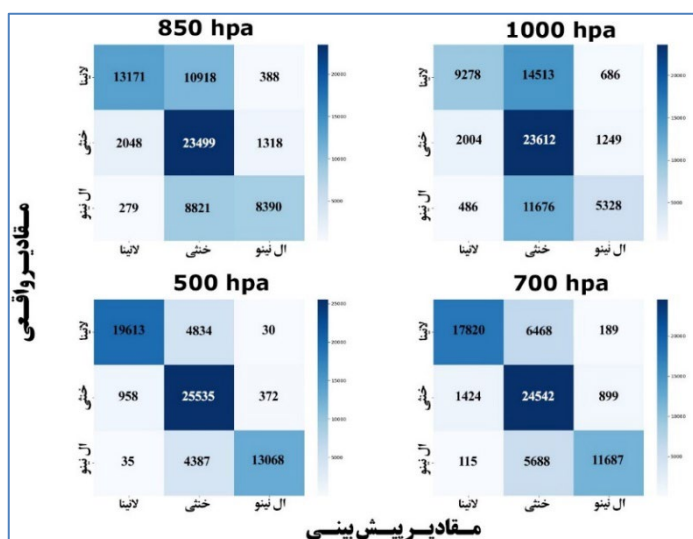
در حالت بدون تأخیر زمانی (شکل ۵)، مدل ConvLSTM2D در تراز ۵۰۰ هکتوپاسکال عملکرد بهتری نسبت به سایر ترازهای از خود نشان داده است. این موضوع با دقت بالا در طبقه‌بندی فازهای ENSO به‌ویژه فاز خنثی، مشهود است. عملکرد تراز ۷۰۰ هکتوپاسکال نیز نسبتاً مطلوب بوده، ولی اشتباهات بیشتری میان فازهای خنثی و



شکل ۶. ماتریس درهم‌ریختگی مدل ConvLSTM2D برای طبقه‌بندی سه فاز پدیده ENSO (لاینا، خنثی و ال‌نینو) بر روی مجموعه داده آزمون در حالت تأخیر زمانی یک ماهه.

دارد، اما طبقه‌بندی بین فازهای خنثی و لاینا همچنان با خطاهایی همراه است. در ترازهای پایین‌تر، افت دقت مشهود است و نتایج جدول ۱ نیز کاهش کیفیت پیش‌بینی در این ترازها را نشان می‌دهند.

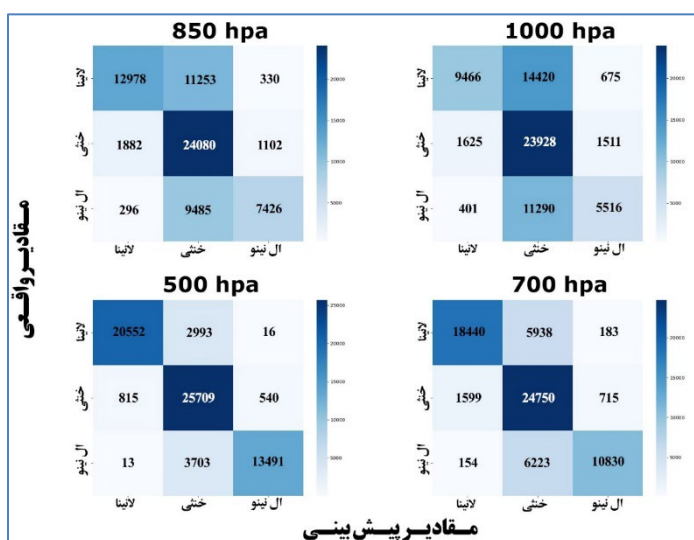
با اعمال تأخیر زمانی یک‌ماهه (شکل ۶)، تراز ۵۰۰ هکتوپاسکال همچنان عملکرد خود را حفظ کرده و توانسته فازهای لاینا و ال‌نینو را با دقت بالا تفکیک کند. در این تأخیر زمانی، تراز ۷۰۰ هکتوپاسکال نیز عملکرد قابل قبولی



شکل ۷. ماتریس درهم‌ریختگی مدل ConvLSTM2D برای طبقه‌بندی سه فاز پدیده ENSO (لاینا، خنثی و ال‌نینو) بر روی مجموعه داده آزمون در حالت تأخیر زمانی دو ماهه.

اما با افزایش تأخیر زمانی، افت جزئی در دقت آن نسبت به ماه قبل دیده می‌شود. در این مرحله، عملکرد مدل در ترازهای ۱۰۰۰ و ۸۵۰ هکتوپاسکال نیز ضعیف‌تر بوده و با خطاهای بیشتری همراه بوده است.

در تأخیر زمانی دوماهه (شکل ۷)، بار دیگر تراز ۵۰۰ هکتوپاسکال بهترین دقت طبقه‌بندی را ارائه داده و می‌توان تفکیک واضح سه فاز ENSO را در خروجی مدل مشاهده کرد. تراز ۷۰۰ هکتوپاسکال نیز عملکرد نسبتاً خوبی دارد،



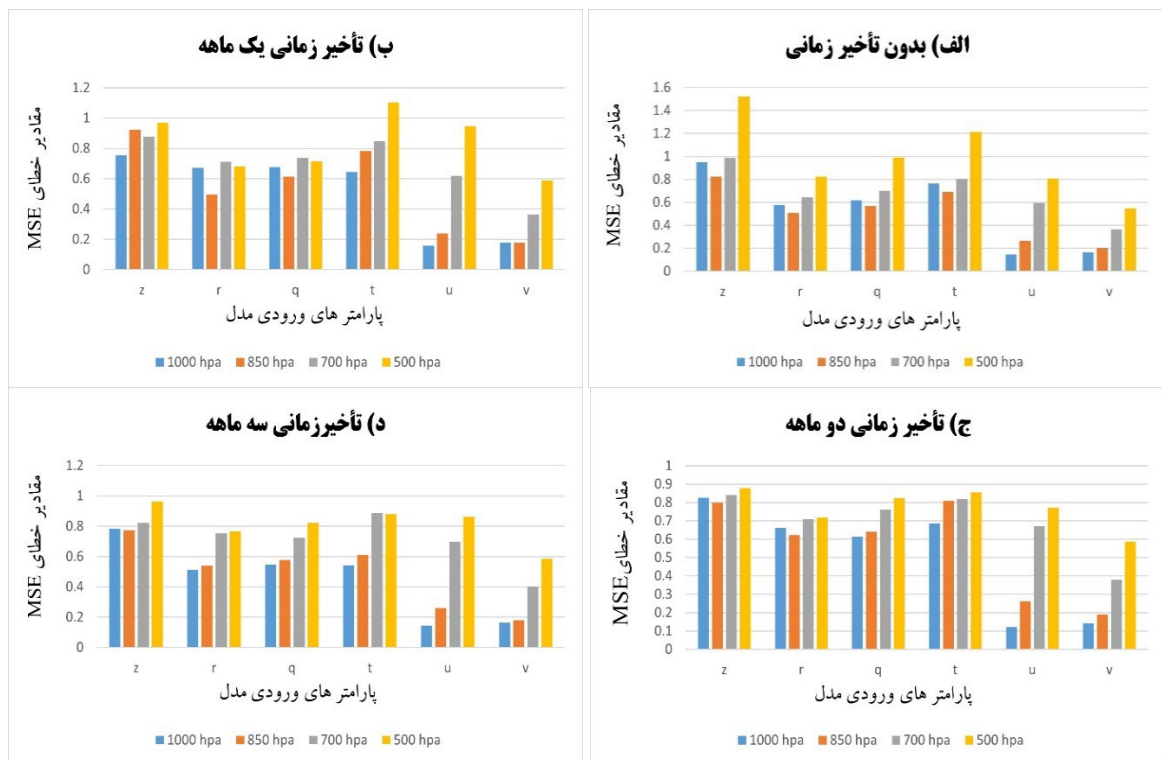
شکل ۸. ماتریس درهم‌ریختگی مدل ConvLSTM2D برای طبقه‌بندی سه فاز پدیده ENSO (لانیئا، خنثی و ال‌نینو) بر روی مجموعه داده آزمون در حالت تأخیر زمانی سه ماهه.

دقت بالاتری نسبت به سایر ترازها داشته و کمترین خطاهای طبقه‌بندی را نشان داده است.

۳-۴ اهمیت پارامترها (Feature Importance)

اهمیت استخراج ویژگی‌های مؤثر در مدل‌های پیش‌بینی اقلیمی، به‌ویژه در زمینه پدیده‌هایی همچون نوسان جنوبی ال‌نینو (ENSO)، از آن جهت حائز اهمیت است که می‌تواند دقت و کارایی مدل را به شکل چشمگیری افزایش دهد. در این راستا، تحلیل اهمیت ویژگی‌ها (Feature Importance) به عنوان یکی از ابزارهای کلیدی در درک نقش متغیرهای جوی در ترازهای مختلف جو به کار گرفته می‌شود. شکل ۹ این اهمیت را در قالب نمودارهایی برای ترازهای فشاری گوناگون و در بازه تأخیرهای زمانی مختلف نمایش می‌دهد.

در نهایت، با افزایش تأخیر زمانی به سه ماه، مدل در تراز ۵۰۰ هکتوپاسکال نه تنها دقت بالای خود را حفظ کرده بلکه نتایج خروجی در شکل ۸ نشان‌دهنده پایداری بسیار خوب مدل در این ارتفاع است. این در حالی است که عملکرد در ترازهای پایین‌تر مانند ۸۵۰ و ۱۰۰۰ هکتوپاسکال به شدت افت کرده و خطاها، به‌ویژه میان فازهای خنثی و لانیئا، افزایش یافته‌اند. ارزیابی کمی در جدول ۱ نیز برتری تراز ۵۰۰ هکتوپاسکال در این تأخیر زمانی را کاملاً مشخص می‌سازد. در مجموع، ماتریس‌های درهم‌ریختگی مبنای تحلیل دقت طبقه‌بندی مدل در تفکیک فازهای ENSO هستند که با نمایش فراوانی پیش‌بینی‌های صحیح و نادرست در هر کلاس، امکان ارزیابی مستقیم عملکرد مدل را فراهم می‌کنند؛ که بر این اساس، تراز ۵۰۰ هکتوپاسکال در تمامی تأخیرهای زمانی



شکل ۹. تحلیل اهمیت پارامترهای ورودی مدل ConvLSTM2D در پیش‌بینی ENSO برای چهار سناریوی مختلف تأخیر زمانی.

آن است که دمای ترازهای بالاتر جو نقش کلیدی در پیش‌بینی یک‌ماهه ENSO دارد. همچنین، متغیر ارتفاع ژئوپتانسیل (Z) در تراز ۷۰۰ هکتوپاسکال نیز از جایگاه بالایی برخوردار شده است. این ویژگی‌ها نمایانگر الگوهای همدیدی پایدار در لایه‌های میانی و بالاتر جو هستند که نقش تعیین‌کننده‌ای در تغییرات اقیانوس-جو دارند. در شکل ۹-ج (با تأخیر زمانی دو ماهه)، اهمیت متغیر ارتفاع ژئوپتانسیل (Z) در تراز ۷۰۰ هکتوپاسکال به اوج خود می‌رسد و به عنوان مهم‌ترین ویژگی ظاهر می‌شود. پس از آن، متغیر دما (T) در تراز ۵۰۰ هکتوپاسکال مجدداً در رتبه دوم قرار دارد. این روند بیانگر افزایش نقش ترازهای میانی جو در پیش‌بینی‌های میان‌مدت است. همچنین، اهمیت رطوبت ویژه (Q) در تراز ۷۰۰ هکتوپاسکال همچنان قابل‌توجه است که می‌تواند به الگوهای رطوبتی بلندمدت و پیوند آن با رخداد‌های ENSO اشاره داشته باشد و در نهایت در شکل ۹-د (با تأخیر زمانی سه‌ماهه)، متغیر دما (T) در تراز ۵۰۰

در شکل ۹-الف (بدون تأخیر زمانی)، متغیر ارتفاع ژئوپتانسیل (Z) در تراز ۵۰۰ هکتوپاسکال دارای بالاترین اهمیت نسبت به سایر ویژگی‌هاست. پس از آن، متغیر دما (T) در همان تراز نیز از اهمیت زیادی برخوردار است. دلیل این امر را می‌توان در پایداری بیشتر ویژگی‌های ترمودینامیکی در ترازهای بالاتر جو دانست که به‌ویژه در پیش‌بینی‌های کوتاه‌مدت اثرگذارند. همچنین، متغیر رطوبت ویژه (Q) در تراز ۷۰۰ هکتوپاسکال نیز سهم قابل توجهی دارد که به ارتباط آن با جابجایی توده‌های مرطوب و الگوهای همرفتی مرتبط است. از سوی دیگر، مولفه‌های سرعت باد (U و V) در همه ترازها، به‌ویژه در ترازهای ۱۰۰۰ و ۸۵۰ هکتوپاسکال، کمترین اهمیت را دارند که به نوسانات کوتاه‌مدت و ماهیت پرنوسان‌تر بادها نسبت به سایر متغیرها برمی‌گردد. در شکل ۹-ب (با تأخیر زمانی یک‌ماهه)، همچنان متغیر دما (T) در تراز ۵۰۰ هکتوپاسکال بیشترین اهمیت را حفظ کرده و حتی اهمیت آن نسبت به حالت بدون تأخیر افزایش یافته است. این موضوع بیانگر

در حالت بدون تأخیر زمانی (جدول ۲)، مقادیر شاخص ONI در لایه‌های مختلف جو نوساناتی نسبتاً ضعیف را نشان می‌دهند. برای مثال، در لایه ۱۰۰۰ هکتوپاسکال، شاخص ONI اغلب در محدوده‌های منفی خفیف نوسان می‌کند که نشان‌دهنده شرایط خنثی تا لاینیا خفیف در این تراز است. با صعود به لایه‌های بالاتر مانند ۵۰۰ هکتوپاسکال، مقادیر مثبت‌تری مشاهده می‌شود که می‌تواند ناشی از گرم‌تر بودن هسته تروپوسفر میانی در مقاطع خاصی از سال باشد. از دیدگاه دینامیک جو، عدم وجود تأخیر زمانی در تحلیل باعث می‌شود که مدل، مستقیماً با داده‌های هم‌زمان کار کند و فرصت کمتری برای درک الگوهای گذشته داشته باشد. همین مسئله عملکرد مدل را کاهش داده است. نتایج آماری نیز این موضوع را تأیید می‌کنند، به طوری که در این حالت، مقادیر R^2 به‌ویژه در لایه‌های پایین‌تر مانند ۱۰۰۰ و ۸۵۰ هکتوپاسکال نسبتاً ضعیف‌تر هستند (به ترتیب ۰/۳۳ و ۰/۵۷). این کاهش دقت به علت وجود نویزهای بیشتر در داده‌های نزدیک به سطح زمین و نبود دید بلندمدت نسبت به الگوهای بزرگ‌مقیاس ENSO است.

هکتوپاسکال بیشترین اهمیت را در بین تمام حالات داراست. این موضوع گویای نقش تعیین‌کننده الگوهای دمایی پایدار در ترازهای بالاتر جو برای پیش‌بینی بلندمدت پدیده‌های اقلیمی نظیر ENSO است. همچنین، متغیر ارتفاع ژئوپتانسیل (Z) در تراز ۵۰۰ هکتوپاسکال نیز همچنان از اهمیت بسیار بالایی برخوردار است، در حالی که رطوبت ویژه (Q) در تراز ۷۰۰ هکتوپاسکال همچنان جایگاه مهمی دارد. مشابه سایر حالات، مولفه‌های سرعت باد (U و V) در همه ترازها کم‌اهمیت باقی مانده‌اند، که نشان از نوسانات زیاد و پیش‌بینی‌ناپذیری این پارامترها در بازه‌های زمانی بلند دارد. در مجموع، اهمیت ویژگی‌ها در تمامی حالات نشان می‌دهد که با افزایش تأخیر زمانی، متغیرهای دما و ارتفاع ژئوپتانسیل در ترازهای بالاتر جو (به‌ویژه ۵۰۰ هکتوپاسکال) سهم بیشتری در پیش‌بینی فازهای ENSO دارند. این روند با نتایج مدل در جدول ۱ نیز همسو بوده و بر نقش اساسی لایه‌های بالاتر جو و پارامترهای پایدارتر در فرآیند پیش‌بینی تأکید می‌کند.

۳-۵ پیش‌بینی ONI و فازهای انسو تا سال ۲۰۲۸

۳-۵-۱ بدون تأخیر زمانی

جدول ۲. پیش‌بینی فازهای پدیده ENSO (لاینیا: L، خنثی: N، ال‌نینو: E) تا سال ۲۰۲۸ با استفاده از مدل ConvLSTM2D، در سناریوی بدون تأخیر زمانی

| سال | ماه‌های پیش‌بینی | ۱۰۰۰ هکتوپاسکال | ۸۵۰ هکتوپاسکال | ۷۰۰ هکتوپاسکال | ۵۰۰ هکتوپاسکال |
|--------------------|----------------------------|--------------------|-------------------|-------------------|-------------------|
| ۲۰۲۶-۰۲ تا ۲۰۲۵-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)۰/۰۶ | (N)۰/۲۴ | (N)۰/۳۸ | (E)۰/۹۵ |
| ۲۰۲۶-۰۳ تا ۲۰۲۶-۰۱ | ژانویه-فوریه-مارس (JFM) | (N)۰/۲۷ | (N)۰/۰۲ | (N)۰/۲۳ | (E)۰/۷۲ |
| ۲۰۲۶-۰۴ تا ۲۰۲۶-۰۲ | فوریه-مارس-آوریل (FMA) | (N)۰/۲۹ | (N)۰/۰۲ | (N)۰/۱۶ | (N)۰/۴۹ |
| ۲۰۲۶-۰۵ تا ۲۰۲۶-۰۳ | مارس-آوریل می (MAM) | (N)۰/۲۹ | (N)۰/۰۳ | (N)۰/۲۷ | (N)۰/۱۹ |
| ۲۰۲۶-۰۶ تا ۲۰۲۶-۰۴ | آوریل می-ژوئن (AMJ) | (N)۰/۰۳ | (N)۰/۱۸ | (N)۰/۱۱ | (N)۰/۱۳ |
| ۲۰۲۶-۰۷ تا ۲۰۲۶-۰۵ | می-ژوئن-جولای (MJJ) | (N)۰/۲۸ | (N)۰/۲۲ | (N)۰/۱۱ | (N)۰/۰۳ |
| ۲۰۲۶-۰۸ تا ۲۰۲۶-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)۰/۰۳ | (N)۰/۰۱ | (N)۰/۲۱ | (N)۰/۱۱ |
| ۲۰۲۶-۰۹ تا ۲۰۲۶-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۲۸ | (N)۰/۱۳ | (N)۰/۳۴ | (N)۰/۰۱ |
| ۲۰۲۶-۱۰ تا ۲۰۲۶-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)۰/۲۴ | (N)۰/۲۱ | (N)۰/۳۶ | (N)۰/۰۵ |
| ۲۰۲۶-۱۱ تا ۲۰۲۶-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (E)۰/۵۲ | (N)۰/۰۱ | (N)۰/۲۵ | (N)۰/۰۹ |
| ۲۰۲۶-۱۲ تا ۲۰۲۶-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (E)۰/۶۱ | (N)۰/۰۶ | (N)۰/۱۳ | (N)۰/۳۲ |

| | | | | | |
|--------------------|----------------------------|---------|---------|---------|---------|
| ۲۰۲۷-۰۱ تا ۲۰۲۶-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (E)۰/۵۶ | (N)۰/۳۱ | (N)۰/۲۲ | (E)۰/۶۵ |
| ۲۰۲۷-۰۲ تا ۲۰۲۶-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)۰/۲۷ | (N)۰/۱۶ | (N)۰/۴۴ | (E)۰/۹۸ |
| ۲۰۲۷-۰۳ تا ۲۰۲۷-۰۱ | ژانویه-فوریه-مارس (JFM) | (N)۰/۰۳ | (N)۰/۰۶ | (N)۰/۳۵ | (E)۰/۹۵ |
| ۲۰۲۷-۰۴ تا ۲۰۲۷-۰۲ | فوریه-مارس-آوریل (FMA) | (N)۰/۱۳ | (N)۰/۲۹ | (N)۰/۰۲ | (E)۰/۵۸ |
| ۲۰۲۷-۰۵ تا ۲۰۲۷-۰۳ | مارس-آوریل می (MAM) | (N)۰/۱۶ | (N)۰/۳۱ | (N)۰/۲۸ | (N)۰/۱۱ |
| ۲۰۲۷-۰۶ تا ۲۰۲۷-۰۴ | آوریل می-ژوئن (AMJ) | (N)۰/۰۶ | (N)۰/۰۲ | (N)۰/۲۴ | (N)۰/۰۳ |
| ۲۰۲۷-۰۷ تا ۲۰۲۷-۰۵ | می-ژوئن-جولای (MJJ) | (N)۰/۰۷ | (N)۰/۰۴ | (N)۰/۲۵ | (N)۰/۰۷ |
| ۲۰۲۷-۰۸ تا ۲۰۲۷-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)۰/۱۳ | (N)۰/۰۷ | (N)۰/۲۶ | (N)۰/۰۲ |
| ۲۰۲۷-۰۹ تا ۲۰۲۷-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۰۸ | (N)۰/۱۶ | (N)۰/۳۴ | (N)۰/۰۹ |
| ۲۰۲۷-۱۰ تا ۲۰۲۷-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)۰/۱۲ | (N)۰/۳۴ | (N)۰/۳۴ | (N)۰/۱۳ |
| ۲۰۲۷-۱۱ تا ۲۰۲۷-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)۰/۲۹ | (N)۰/۲۲ | (N)۰/۱۴ | (N)۰/۰۹ |
| ۲۰۲۷-۱۲ تا ۲۰۲۷-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)۰/۰۴ | (N)۰/۰۲ | (N)۰/۱۴ | (N)۰/۳۱ |
| ۲۰۲۸-۰۱ تا ۲۰۲۷-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)۰/۴۴ | (N)۰/۱۹ | (N)۰/۳۴ | (E)۰/۶۳ |

۳-۵-۲ تأخیر زمانی یک ماهه

با در نظر گرفتن تأخیر زمانی یک ماهه (جدول ۳)، الگوهای شاخص ONI در لایه‌های مختلف فشار جو به‌ویژه در نیمه اول سال، تمایل بیشتری به مقادیر منفی دارند؛ این موضوع به‌ویژه در لایه‌های میانی جو (۷۰۰ و ۸۵۰ هکتوپاسکال) مشهودتر است. برای مثال، در بازه زمانی JFM تا MAM،

شاخص ONI در اغلب لایه‌ها در محدوده لائینیا باقی می‌ماند. این رفتار بیانگر تداوم شرایط سرد در مناطق استوایی اقیانوس آرام است که می‌تواند به تقویت الگوهای واچرخندی در ترازهای پایین و کاهش انتقال گرما به ترازهای بالاتر منجر شود.

جدول ۳. پیش‌بینی فازهای پدیده ENSO (لائینیا: L، خشی: N، ال‌نینو: E) تا سال ۲۰۲۸ با استفاده از مدل ConvLSTM2D. در سناریوی تأخیر زمانی یک ماه

| سال | ماه‌های پیش‌بینی | ۱۰۰۰ هکتوپاسکال | ۸۵۰ هکتوپاسکال | ۷۰۰ هکتوپاسکال | ۵۰۰ هکتوپاسکال |
|--------------------|----------------------------|--------------------|-------------------|-------------------|-------------------|
| ۲۰۲۶-۰۲ تا ۲۰۲۵-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)۰/۲۹ | (N)۰/۳۱ | (N)۰/۱۲ | (N)۰/۰۸ |
| ۲۰۲۶-۰۳ تا ۲۰۲۶-۰۱ | ژانویه-فوریه-مارس (JFM) | (L)۰/۵۱ | (L)۰/۵۹ | (N)۰/۴۹ | (N)۰/۰۴ |
| ۲۰۲۶-۰۴ تا ۲۰۲۶-۰۲ | فوریه-مارس-آوریل (FMA) | (L)۰/۵۳ | (L)۰/۰۶ | (N)۰/۴۸ | (N)۰/۰۷ |
| ۲۰۲۶-۰۵ تا ۲۰۲۶-۰۳ | مارس-آوریل می (MAM) | (L)۰/۵۳ | (N)۰/۴۷ | (N)۰/۴۳ | (N)۰/۰۴ |
| ۲۰۲۶-۰۶ تا ۲۰۲۶-۰۴ | آوریل می-ژوئن (AMJ) | (N)۰/۲۲ | (N)۰/۲۲ | (N)۰/۲۸ | (N)۰/۰۳ |
| ۲۰۲۶-۰۷ تا ۲۰۲۶-۰۵ | می-ژوئن-جولای (MJJ) | (N)۰/۰۱ | (N)۰/۰۶ | (N)۰/۱۴ | (N)۰/۱۳ |
| ۲۰۲۶-۰۸ تا ۲۰۲۶-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)۰/۰۳ | (N)۰/۰۲ | (N)۰/۰۱ | (N)۰/۲۴ |
| ۲۰۲۶-۰۹ تا ۲۰۲۶-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۰۹ | (N)۰/۰۲ | (N)۰/۱۱ | (N)۰/۳۴ |
| ۲۰۲۶-۱۰ تا ۲۰۲۶-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)۰/۱۱ | (N)۰/۰۹ | (N)۰/۱۸ | (N)۰/۳۷ |
| ۲۰۲۶-۱۱ تا ۲۰۲۶-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)۰/۳۸ | (N)۰/۱۶ | (N)۰/۲۷ | (N)۰/۰۳ |

| | | | | | |
|--------------------|----------------------------|----------|----------|----------|----------|
| ۲۰۲۶-۱۲ تا ۲۰۲۶-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)۰/۳۷ | (N)-۰/۲ | (N)-۰/۳۸ | (N)۰/۰۱ |
| ۲۰۲۷-۰۱ تا ۲۰۲۶-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)۰/۲۷ | (N)-۰/۰۹ | (N)-۰/۳۴ | (N)۰/۱۴ |
| ۲۰۲۷-۰۲ تا ۲۰۲۶-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)-۰/۰۶ | (N)-۰/۱۹ | (N)-۰/۳ | (N)۰/۲ |
| ۲۰۲۷-۰۳ تا ۲۰۲۷-۰۱ | ژانویه-فوریه-مارس (JFM) | (N)-۰/۳۹ | (N)-۰/۳۷ | (N)-۰/۲۶ | (N)۰/۰۲ |
| ۲۰۲۷-۰۴ تا ۲۰۲۷-۰۲ | فوریه-مارس-آوریل (FMA) | (L)-۰/۵۷ | (L)-۰/۶۹ | (L)-۰/۵ | (N)-۰/۱۶ |
| ۲۰۲۷-۰۵ تا ۲۰۲۷-۰۳ | مارس-آوریل-می (MAM) | (L)-۰/۵۸ | (L)-۰/۶۹ | (L)-۰/۵۱ | (N)-۰/۳۲ |
| ۲۰۲۷-۰۶ تا ۲۰۲۷-۰۴ | آوریل-می-ژوئن (AMJ) | (N)-۰/۳۳ | (N)-۰/۴۵ | (N)-۰/۴۳ | (N)-۰/۳۵ |
| ۲۰۲۷-۰۷ تا ۲۰۲۷-۰۵ | می-ژوئن-جولای (MJJ) | (N)-۰/۱۲ | (N)-۰/۱۲ | (N)-۰/۱۹ | (N)-۰/۲۷ |
| ۲۰۲۷-۰۸ تا ۲۰۲۷-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)-۰/۰۱ | (N)-۰/۰۲ | (N)-۰/۱۴ | (N)-۰/۳ |
| ۲۰۲۷-۰۹ تا ۲۰۲۷-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۰۶ | (N)-۰/۰۲ | (N)-۰/۱۹ | (N)-۰/۴ |
| ۲۰۲۷-۱۰ تا ۲۰۲۷-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)۰/۱۵ | (N)-۰/۱۵ | (N)-۰/۲۸ | (L)-۰/۵۱ |
| ۲۰۲۷-۱۱ تا ۲۰۲۷-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)۰/۲۳ | (N)-۰/۲۷ | (N)-۰/۴۲ | (N)-۰/۴۸ |
| ۲۰۲۷-۱۲ تا ۲۰۲۷-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)۰/۱۴ | (N)-۰/۲۵ | (N)-۰/۴۳ | (N)-۰/۲۹ |
| ۲۰۲۸-۰۱ تا ۲۰۲۷-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)-۰/۰۲ | (N)-۰/۲۴ | (N)-۰/۳۳ | (N)-۰/۱۷ |

در شرایطی که دو ماه تأخیر زمانی (جدول ۴) در پیش‌بینی شاخص ONI لحاظ شده است، الگوهای دمایی در ترازهای میانی جو (۷۰۰ و ۸۵۰ هکتوپاسکال) به شکلی منسجم‌تر به سوی فاز منفی (لانییا) گرایش دارند، به‌ویژه در نیمه اول سال که فاز سرد ENSO شدت بیشتری می‌گیرد. این موضوع در ماه‌های JFM تا MAM به‌خوبی دیده می‌شود و نشان‌دهنده پایداری نسبی شرایط لانییا در این بازه زمانی است. در لایه‌های پایین‌تر جو، نظیر ۱۰۰۰ هکتوپاسکال، نوسانات بیشتری دیده می‌شود که می‌تواند تحت تأثیر فرآیندهای تراز و اثرات محلی‌تر مانند جریان‌های جوی و اثرات خشکی-اقیانوس باشد. از منظر فیزیکی، تأخیر دو ماهه باعث می‌شود مدل بتواند بازتاب تأخیر طبیعی بین تغییرات دمای سطح دریا (SST) و پاسخ جوی را به‌طور دقیق‌تر در نظر بگیرد. در واقع، پاسخ گردش عمومی جو نسبت به ناهنجاری‌های دمایی در منطقه نینو، معمولاً با تأخیر یک تا دو ماهه نمایان می‌شود؛ بنابراین این بازه زمانی به مدل فرصت می‌دهد تا سازوکارهای دینامیکی مؤثر را بهتر تشخیص دهد.

از دیدگاه هواشناسی، تأخیر یک‌ماهه به مدل اجازه می‌دهد تا تغییرات جو-اقیانوس را که معمولاً با وقفه زمانی در شاخص‌های ENSO نمایان می‌شوند، بهتر شناسایی کند. این دید زمانی به مدل کمک می‌کند تا تأثیر تغییرات پیشین دما و گردش جو را در پیش‌بینی‌های بعدی لحاظ کند. به همین دلیل، در این حالت عملکرد مدل در لایه‌های میانی مانند ۷۰۰ هکتوپاسکال بهبود چشمگیری یافته و مقدار R^2 از ۰/۷۸ به ۰/۸۲ افزایش یافته است. همچنین مقدار MAE نیز کاهش یافته که نشان‌دهنده دقت بیشتر مدل است. با این حال، در لایه ۸۵۰ هکتوپاسکال مقدار R^2 کمی کاهش یافته که می‌تواند ناشی از تغییرات ناگهانی رطوبت یا تداخل الگوهای محلی در این تراز باشد. در مجموع، تأخیر زمانی یک‌ماهه باعث پایداری بهتر سیگنال ENSO در مدل شده و به‌ویژه در ترازهای میانی تا بالای تروپوسفر (۷۰۰ و ۵۰۰ هکتوپاسکال) موجب بهبود قابل توجه نتایج پیش‌بینی شده است.

۳-۵-۳ تأخیر زمانی دو ماهه

جدول ۴. پیش‌بینی فازهای پدیده ENSO (لاتینا: L، خنثی: N، ال‌نینو: E) تا سال ۲۰۲۸ با استفاده از مدل ConvLSTM2D. در سناریوی تأخیر زمانی دو ماه.

| سال | ماه‌های پیش‌بینی | ۱۰۰۰ هکتوپاسکال | ۸۵۰ هکتوپاسکال | ۷۰۰ هکتوپاسکال | ۵۰۰ هکتوپاسکال |
|--------------------|----------------------------|--------------------|-------------------|-------------------|-------------------|
| ۲۰۲۶-۰۲ تا ۲۰۲۵-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)-۰/۳۳ | (N)۰/۱۷ | (N)-۰/۱۵ | (N)۰/۱ |
| ۲۰۲۶-۰۳ تا ۲۰۲۶-۰۱ | ژانویه-فوریه-مارس (JFM) | (L)-۰/۵۸ | (L)-۰/۵۵ | (L)-۰/۵۳ | (N)۰/۰۳ |
| ۲۰۲۶-۰۴ تا ۲۰۲۶-۰۲ | فوریه-مارس-آوریل (FMA) | (L)-۰/۵۹ | (L)-۰/۶۱ | (N)-۰/۴۱ | (N)-۰/۰۳ |
| ۲۰۲۶-۰۵ تا ۲۰۲۶-۰۳ | مارس-آوریل می (MAM) | (L)-۰/۵ | (L)-۰/۶۴ | (N)-۰/۴۴ | (N)-۰/۱۲ |
| ۲۰۲۶-۰۶ تا ۲۰۲۶-۰۴ | آوریل می-ژوئن (AMJ) | (N)-۰/۱۵ | (N)-۰/۴ | (N)-۰/۲۸ | (N)-۰/۲۳ |
| ۲۰۲۶-۰۷ تا ۲۰۲۶-۰۵ | می-ژوئن-جولای (MJJ) | (N)۰/۰۵ | (N)-۰/۱۶ | (N)-۰/۱۶ | (N)-۰/۳۲ |
| ۲۰۲۶-۰۸ تا ۲۰۲۶-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)۰/۰۸ | (N)۰/۰۶ | (N)-۰/۰۷ | (N)-۰/۰۳ |
| ۲۰۲۶-۰۹ تا ۲۰۲۶-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۱۲ | (N)۰/۱۳ | (N)-۰/۱۱ | (N)-۰/۲۴ |
| ۲۰۲۶-۱۰ تا ۲۰۲۶-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)۰/۰۹ | (N)۰/۰۳ | (N)-۰/۲ | (N)-۰/۲۷ |
| ۲۰۲۶-۱۱ تا ۲۰۲۶-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)۰/۱۸ | (N)-۰/۱۴ | (N)-۰/۳۱ | (N)-۰/۲۱ |
| ۲۰۲۶-۱۲ تا ۲۰۲۶-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)۰/۱۷ | (N)-۰/۱۵ | (N)-۰/۳۲ | (N)-۰/۰۳ |
| ۲۰۲۷-۰۱ تا ۲۰۲۶-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)۰/۱۱ | (N)-۰/۰۴ | (N)-۰/۲ | (N)۰/۱۹ |
| ۲۰۲۷-۰۲ تا ۲۰۲۶-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)-۰/۰۵ | (N)-۰/۰۸ | (N)-۰/۱ | (N)۰/۱۶ |
| ۲۰۲۷-۰۳ تا ۲۰۲۷-۰۱ | ژانویه-فوریه-مارس (JFM) | (N)-۰/۳۴ | (N)-۰/۲۹ | (N)-۰/۱۲ | (N)-۰/۰۶ |
| ۲۰۲۷-۰۴ تا ۲۰۲۷-۰۲ | فوریه-مارس-آوریل (FMA) | (L)-۰/۵ | (L)-۰/۵۶ | (N)-۰/۲۹ | (N)-۰/۱۷ |
| ۲۰۲۷-۰۵ تا ۲۰۲۷-۰۳ | مارس-آوریل می (MAM) | (L)-۰/۵۳ | (L)-۰/۵۱ | (N)-۰/۳۵ | (N)-۰/۲۶ |
| ۲۰۲۷-۰۶ تا ۲۰۲۷-۰۴ | آوریل می-ژوئن (AMJ) | (N)-۰/۳۳ | (N)-۰/۳۳ | (N)-۰/۲۹ | (N)-۰/۳۱ |
| ۲۰۲۷-۰۷ تا ۲۰۲۷-۰۵ | می-ژوئن-جولای (MJJ) | (N)-۰/۰۶ | (N)-۰/۰۴ | (N)-۰/۱۵ | (N)-۰/۳۷ |
| ۲۰۲۷-۰۸ تا ۲۰۲۷-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)۰/۰۵ | (N)۰/۰۸ | (N)-۰/۰۹ | (N)-۰/۳۲ |
| ۲۰۲۷-۰۹ تا ۲۰۲۷-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)۰/۰۶ | (N)۰/۱ | (N)-۰/۱۲ | (N)-۰/۰۳ |
| ۲۰۲۷-۱۰ تا ۲۰۲۷-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)-۰/۰۲ | (N)-۰/۱۳ | (N)-۰/۲ | (N)-۰/۳۲ |
| ۲۰۲۷-۱۱ تا ۲۰۲۷-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)۰/۰۳ | (N)-۰/۰۳ | (N)-۰/۳۹ | (N)-۰/۲۶ |
| ۲۰۲۷-۱۲ تا ۲۰۲۷-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)۰/۰۷ | (N)-۰/۳۳ | (N)-۰/۴۸ | (N)-۰/۱۴ |
| ۲۰۲۸-۰۱ تا ۲۰۲۷-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)۰/۰۸ | (N)-۰/۱۵ | (N)-۰/۴۹ | (N)۰/۰۳ |

زمانی دوماهه به‌خوبی با چرخه طبیعی واکنش اقیانوس-جو هم‌راستا بوده و موجب بهبود قابل توجه دقت مدل در پیش‌بینی شاخص ONI، به‌ویژه در ترازهای میانی و بالایی جو شده است.

۳-۵-۴ تأخیر زمانی سه ماهه

در شرایطی که تأخیر زمانی سه‌ماهه (جدول ۵) در نظر گرفته شده است، الگوی دمایی در همه ترازهای جوی

نتایج ارزیابی مدل نیز از این دیدگاه پشتیبانی می‌کند که در تراز ۵۰۰ هکتوپاسکال، که نمایانگر ترازهای بالاتر تروپوسفر است، عملکرد مدل با بیشترین دقت همراه است ($R^2 = 0.92$) و MAE نیز نسبت به تأخیرهای کمتر کاهش یافته است. همچنین در تراز ۷۰۰ هکتوپاسکال، مدل عملکرد پایداری دارد ($R^2 = 0.82$) و MAE پایین‌تر از حالت‌های بدون تأخیر و یک‌ماهه است. در مجموع، تأخیر

پاسخ جو به دمای سطح دریا را مد نظر قرار دهد، بلکه فرآیندهای پیچیده‌تری همچون انتقال انرژی، جابجایی توده‌های هوا، و همرفت‌های تروپوسفری را نیز بهتر مدل‌سازی کند. به‌ویژه در ترازهای بالاتر جو مانند ۵۰۰ هکتوپاسکال، که تحت تأثیر مستقیم امواج جوی و جت استریم‌ها قرار دارد، این تأخیر باعث می‌شود مدل بهتر بتواند ناهنجاری‌های سینوپتیکی را که به آرامی توسعه می‌یابند، شناسایی کند.

به‌ویژه ۷۰۰ و ۵۰۰ هکتوپاسکال نشان‌دهنده ناهنجاری‌های منفی نسبتاً قوی در نیمه اول سال است. این ناهنجاری‌ها (خصوصاً در بازه‌های JFM، FMA، MAM و AMJ) با پایداری و تقویت لائینیا همراه هستند. در ادامه سال، این مقادیر به تدریج کاهش می‌یابند و به سمت وضعیت خنثی یا نوسانات مثبت جزئی حرکت می‌کنند، ولی همچنان شرایط سرد غالب است. از دیدگاه فیزیکی و هواشناسی، سه ماه تأخیر زمانی به مدل اجازه می‌دهد تا نه تنها تأخیر

جدول ۵. پیش‌بینی فازهای پدیده ENSO (لائینیا: L، خنثی: N، ال‌نینو: E) تا سال ۲۰۲۸ با استفاده از مدل ConvLSTM2D. در سناریوی تأخیر زمانی سه ماه.

| سال | ماه‌های پیش‌بینی | ۱۰۰۰ هکتوپاسکال | ۸۵۰ هکتوپاسکال | ۷۰۰ هکتوپاسکال | ۵۰۰ هکتوپاسکال |
|--------------------|----------------------------|--------------------|-------------------|-------------------|-------------------|
| ۲۰۲۶-۰۲ تا ۲۰۲۵-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)-۰/۰۳ | (N)-۰/۱۴ | (N)-۰/۳۴ | (N)-۰/۱۹ |
| ۲۰۲۶-۰۳ تا ۲۰۲۶-۰۱ | ژانویه-فوریه-مارس (JFM) | (L)-۰/۵۹ | (L)-۰/۶۱ | (L)-۰/۷ | (N)-۰/۳۷ |
| ۲۰۲۶-۰۴ تا ۲۰۲۶-۰۲ | فوریه-مارس-آوریل (FMA) | (L)-۰/۶۵ | (L)-۰/۶۸ | (L)-۰/۵۶ | (N)-۰/۲۱ |
| ۲۰۲۶-۰۵ تا ۲۰۲۶-۰۳ | مارس-آوریل می (MAM) | (L)-۰/۵۹ | (L)-۰/۵۹ | (L)-۰/۵۷ | (N)-۰/۱۴ |
| ۲۰۲۶-۰۶ تا ۲۰۲۶-۰۴ | آوریل می-ژوئن (AMJ) | (N)-۰/۲۶ | (N)-۰/۳۶ | (N)-۰/۴۶ | (N)-۰/۲۴ |
| ۲۰۲۶-۰۷ تا ۲۰۲۶-۰۵ | می-ژوئن-جولای (MJJ) | (N)/۰/۰۳ | (N)-۰/۰۷ | (N)-۰/۳۵ | (N)-۰/۳۸ |
| ۲۰۲۶-۰۸ تا ۲۰۲۶-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)/۰/۱۱ | (N)/۰/۱۲ | (N)-۰/۲۷ | (N)-۰/۴۶ |
| ۲۰۲۶-۰۹ تا ۲۰۲۶-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)/۰/۰۶ | (N)/۰/۱۶ | (N)-۰/۲۲ | (L)-۰/۵۳ |
| ۲۰۲۶-۱۰ تا ۲۰۲۶-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)/۰/۰۶ | (N)/۰/۰۱ | (N)-۰/۳۱ | (L)-۰/۵۲ |
| ۲۰۲۶-۱۱ تا ۲۰۲۶-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)/۰/۱۵ | (N)-۰/۰۸ | (N)-۰/۴۱ | (N)-۰/۳۴ |
| ۲۰۲۶-۱۲ تا ۲۰۲۶-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)/۰/۱۳ | (N)-۰/۰۶ | (N)-۰/۴۶ | (N)/۰/۰۲ |
| ۲۰۲۷-۰۱ تا ۲۰۲۶-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)-۰/۰۲ | (N)/۰/۰۳ | (N)-۰/۴۱ | (N)/۰/۰۲ |
| ۲۰۲۷-۰۲ تا ۲۰۲۶-۱۲ | دسامبر-ژانویه-فوریه (DJF) | (N)-۰/۱۸ | (N)/۰/۰۲ | (N)-۰/۴ | (N)-۰/۱۵ |
| ۲۰۲۷-۰۳ تا ۲۰۲۷-۰۱ | ژانویه-فوریه-مارس (JFM) | (N)-۰/۳۹ | (N)-۰/۱۷ | (N)-۰/۴۹ | (N)-۰/۳۹ |
| ۲۰۲۷-۰۴ تا ۲۰۲۷-۰۲ | فوریه-مارس-آوریل (FMA) | (L)-۰/۵ | (N)-۰/۴۵ | (L)-۰/۵۹ | (N)-۰/۳ |
| ۲۰۲۷-۰۵ تا ۲۰۲۷-۰۳ | مارس-آوریل می (MAM) | (N)-۰/۴۶ | (L)-۰/۵۹ | (L)-۰/۵۵ | (N)-۰/۲۳ |
| ۲۰۲۷-۰۶ تا ۲۰۲۷-۰۴ | آوریل می-ژوئن (AMJ) | (N)-۰/۲۶ | (N)-۰/۴۳ | (N)-۰/۴۴ | (N)-۰/۲۵ |
| ۲۰۲۷-۰۷ تا ۲۰۲۷-۰۵ | می-ژوئن-جولای (MJJ) | (N)-۰/۰۸ | (N)-۰/۱۱ | (N)-۰/۲۸ | (N)-۰/۳۸ |
| ۲۰۲۷-۰۸ تا ۲۰۲۷-۰۶ | ژوئن-جولای-اگوست (JJA) | (N)-۰/۰۳ | (N)/۰/۱ | (N)-۰/۲۲ | (N)-۰/۴۸ |
| ۲۰۲۷-۰۹ تا ۲۰۲۷-۰۷ | جولای-اگوست-سپتامبر (JAS) | (N)/۰/۰۱ | (N)/۰/۱۱ | (N)-۰/۲۲ | (L)-۰/۶۱ |
| ۲۰۲۷-۱۰ تا ۲۰۲۷-۰۸ | اگوست-سپتامبر-اکتبر (ASO) | (N)/۰/۰۱ | (N)-۰/۰۸ | (N)-۰/۳۵ | (L)-۰/۵۶ |
| ۲۰۲۷-۱۱ تا ۲۰۲۷-۰۹ | سپتامبر-اکتبر-نوامبر (SON) | (N)/۰/۰۷ | (N)-۰/۲۳ | (N)-۰/۴۶ | (L)-۰/۵۴ |
| ۲۰۲۷-۱۲ تا ۲۰۲۷-۱۰ | اکتبر-نوامبر-دسامبر (OND) | (N)/۰/۰۳ | (N)-۰/۲۸ | (N)-۰/۴۹ | (N)-۰/۳۲ |
| ۲۰۲۸-۰۱ تا ۲۰۲۷-۱۱ | نوامبر-دسامبر-ژانویه (NDJ) | (N)/۰/۰۱ | (N)-۰/۰۸ | (N)-۰/۳۵ | (N)-۰/۲۱ |

داده است تا روابط پیچیده فضایی-زمانی را با دقت بیشتری استخراج کند. یکی از جنبه‌های برجسته این پژوهش، تأثیر تأخیر زمانی بر عملکرد مدل است. نتایج نشان می‌دهند که با افزایش تأخیر زمانی از بدون تأخیر به سه ماه، دقت پیش‌بینی به‌ویژه در تراز ۵۰۰ هکتوپاسکال بهبود می‌یابد (R^2 از ۰/۹۲ به ۰/۹۳). این امر می‌تواند به تأخیر طبیعی در انتقال سیگنال‌های جوی از ترازهای بالاتر به تراز سطح زمین و پاسخ اقیانوس-جو به ناهنجاری‌های دمای سطح دریا (SST) نسبت داده شود، که با یافته‌های تانگ و همکاران (۲۰۱۸) سازگار است. این تأخیر زمانی به مدل امکان می‌دهد تا حافظه بلندمدت سیستم اقلیمی را بهتر در نظر بگیرد، که در پیش‌بینی پدیده‌های دورپیوندی مانند ENSO حیاتی است. با این حال، در ترازهای پایین‌تر (۱۰۰۰ هکتوپاسکال)، تأخیر زمانی تأثیر کمتری داشته و دقت پیش‌بینی همچنان پایین‌تر از ترازهای بالاتر باقی مانده است، که نشان‌دهنده محدودیت داده‌های تراز در ثبت سیگنال‌های بزرگ‌مقیاس در بازه‌های زمانی طولانی‌تر است. تحلیل اهمیت ویژگی‌ها نیز نقش متغیرهای دینامیکی (مانند ارتفاع ژئوپتانسیل و مؤلفه افقی باد) و ترمودینامیکی (مانند دما و رطوبت ویژه) را در ترازهای میانی و بالایی جو برجسته می‌کند. این نتایج با مطالعات وانگ و همکاران (۲۰۲۰) هم‌خوانی دارد که نشان داده‌اند متغیرهای مرتبط با ساختار موجی و فرآیندهای همرفتی در تروپوسفر میانی، پیش‌بین‌های کلیدی برای ENSO هستند. در مقابل، متغیرهایی مانند رطوبت نسبی و مؤلفه قائم باد در ترازهای نزدیک به زمین از اهمیت کمتری برخوردارند، که احتمالاً به ناپایداری و نویز بیشتر این لایه‌ها مربوط می‌شود. این یافته‌ها بر ضرورت انتخاب دقیق متغیرهای ورودی و ترازهای جوی در طراحی مدل‌های پیش‌بینی اقلیمی تأکید دارند. از منظر روش‌شناسی، استفاده از معماری ترکیبی ConvLSTM2D، که توانایی استخراج هم‌زمان ویژگی‌های فضایی و زمانی را دارد، برتری قابل‌توجهی نسبت به مدل‌های ساده و منفرد مانند LSTM یا روش‌های آماری نشان داده است. این برتری با نتایج ژو و ژانگ

نتایج ارزیابی مدل نیز به‌خوبی با این تحلیل هم‌خوانی دارد و مدل در تراز ۵۰۰ هکتوپاسکال در حالت تأخیر زمانی سه‌ماهه عملکرد بسیار عالی از خود نشان داده ($R^2 = 0.93$) که از تمام حالت‌های دیگر بهتر است. همچنین میزان خطای میانگین مطلق ($MAE = 0.14$) و میانگین مربعات خطا ($MSE = 0.04$) در این حالت به کمترین مقدار خود رسیده‌اند. این بدان معناست که مدل توانسته با استفاده از تأخیر سه‌ماهه، بیشترین سازگاری را با واقعیت‌های فیزیکی و دینامیکی اتمسفر ایجاد کند. در تراز ۷۰۰ هکتوپاسکال نیز عملکرد مدل نسبتاً خوب باقی مانده ($R^2 = 0.81$)، ولی با کاهش اندکی نسبت به حالت دو‌ماهه، که ممکن است ناشی از تأثیرات کوتاه‌مدت‌تر سطح زمین یا عوامل منطقه‌ای باشد که در بازه‌های زمانی طولانی‌تر محو می‌شوند. در مجموع، تأخیر زمانی سه‌ماهه باعث می‌شود مدل بهتر بتواند روندهای کلان ENSO را در ترازهای بالاتر جو شناسایی کرده و در نتیجه، پیش‌بینی دقیق‌تری از شاخص ONI ارائه دهد.

۴ بحث

پژوهش حاضر به بررسی تأثیر داده‌های ترازهای بالاتر جو بر دقت پیش‌بینی فازهای مختلف نوسانات جنوبی ال‌نینو (ENSO) با استفاده از مدل‌های ترکیبی یادگیری ماشین در استان‌های جنوبی ایران پرداخته است. نتایج این مطالعه نشان‌دهنده برتری قابل‌توجه استفاده از داده‌های ترازهای میانی و بالایی جو (به‌ویژه ۵۰۰ و ۷۰۰ هکتوپاسکال) در مقایسه با ترازهای نزدیک به زمین (۱۰۰۰ و ۸۵۰ هکتوپاسکال) در بهبود مهارت پیش‌بینی فازهای ENSO است. این یافته‌ها با مطالعات پیشین نظیر لو و همکاران (۲۰۲۰) و یه و همکاران (۲۰۱۸) هم‌راستا هستند که بر نقش کلیدی فرآیندهای دینامیکی و ترمودینامیکی تروپوسفر میانی در انتقال سیگنال‌های ENSO تأکید دارند. به‌ویژه، پایداری بیشتر الگوهای جوی در این ترازها، همراه با کاهش نویزهای محلی که در لایه‌های نزدیک به سطح زمین غالب هستند، به مدل ترکیبی ConvLSTM2D اجازه

قابل توجهی دقت پیش‌بینی فازهای ENSO را برای استان‌های جنوبی ایران افزایش می‌دهد. بهترین عملکرد مدل در تراز ۵۰۰ هکتوپاسکال با تأخیر زمانی سه‌ماهه مشاهده شد، که نشان می‌دهد داده‌های لایه میانی جو به دلیل ثبات بیشتر و الگوهای منظم‌تر، نسبت به داده‌های ترازهای پایین‌تر، اطلاعات مناسب‌تری برای پیش‌بینی‌های بلندمدت فراهم می‌کنند. متغیرهای کلیدی مانند ارتفاع ژئوپتانسیل، دما و مؤلفه افقی باد در این ترازها نقش محوری در بهبود مهارت پیش‌بینی ایفا می‌کنند، در حالی که داده‌های ترازهای نزدیک به زمین به دلیل تلاطم‌های خرد مقیاس و ناپایداری محلی از کارایی کمتری برخوردارند. این یافته‌ها نه تنها درک ما از تعاملات جوی مرتبط با ENSO را تقویت می‌کنند، بلکه پتانسیل مدل‌های یادگیری عمیق را در پیش‌بینی، تأیید می‌کنند. با این حال، برای ارتقای بیشتر این مدل‌ها، پیشنهاد می‌شود که رویکردهای ترکیبی شامل مکانیزم‌های توجه (Attention Mechanisms) و تلفیق داده‌های چند ترازی مورد بررسی قرار گیرند تا هم دقت پیش‌بینی و هم تفسیرپذیری فیزیکی بهبود یابد. در نهایت، این مطالعه بر اهمیت ادغام داده‌های جوی متنوع و انتخاب بهینه افق زمانی در توسعه مدل‌های پیش‌بینی اقلیمی قابل‌اعتماد تأکید دارد، که می‌تواند به تصمیم‌گیری مؤثر در برابر تغییرپذیری‌های اقلیمی در مناطق آسیب‌پذیر مانند جنوب ایران کمک کند.

Cao, X., Yanan, G., Liu, B., Peng, K., Wang, G., & Mei, G. (2020). ENSO prediction based on long short-term memory (LSTM). None. <https://doi.org/10.1088/1757-899X/799/1/012035>

Chapman, D., Cane, M. A., Henderson, N., Lee, D. E., & Chen, C. (2015). A Vector Autoregressive ENSO Prediction Model. American Meteorological Society. <https://doi.org/10.1175/jcli-d-15-0306.1>

Chattopadhyay, A., Subel, A., & Hassanzadeh, P. (2020). Data-Driven Super-Parameterization Using Deep Learning: Experimentation With Multiscale Lorenz 96 Systems and Transfer Learning. Wiley. <https://doi.org/10.1029/2020ms002084>

Chen, C., Cane, M. A., Henderson, N., Lee, D. E., Chapman, D., Kondrashov, D., & Chekroun,

(۲۰۲۳) و کائو و همکاران (۲۰۲۰) هم‌سو است که نشان داده‌اند مدل‌های یادگیری عمیق در ثبت روابط غیرخطی پیچیده در داده‌های اقلیمی از روش‌های مرسوم پیشی می‌گیرند. با این حال، چالش‌هایی نظیر تفسیرپذیری محدود این مدل‌ها، که به ماهیت "جعبه سیاه" آن‌ها بازمی‌گردد، همچنان باقی است و نیازمند توسعه روش‌های ترکیبی است که مکانیزم‌های فیزیکی را با رویکردهای داده‌محور تلفیق کنند، همان‌طور که در اسلیتر و همکاران (۲۰۲۳) پیشنهاد شده است. در زمینه منطقه‌ای نیز، این مطالعه نشان داد که ENSO تأثیر قابل توجهی بر الگوهای بارش و دما در جنوب ایران دارد، که با نتایج آمینی و همکاران (۲۰۲۰) و نیک‌رفتار و خانیانی (۲۰۱۸) هم‌راستا است. پیش‌بینی دقیق فازهای ENSO در این منطقه می‌تواند به بهبود مدیریت منابع آب و کاهش ریسک‌های مرتبط با خشکسالی و سیل کمک کند، به‌ویژه در شرایطی که تأخیر زمانی سه‌ماهه امکان برنامه‌ریزی بلندمدت‌تر را فراهم می‌کند. این امر اهمیت کاربرد عملی این مدل‌ها را در مقیاس منطقه‌ای برجسته می‌سازد.

۵ نتیجه‌گیری

این پژوهش نشان داد که افزودن داده‌های ترازهای بالاتر جو (به‌ویژه ۵۰۰ و ۷۰۰ هکتوپاسکال) در مدل‌های ترکیبی یادگیری ماشین، مانند ConvLSTM2D، به‌طور

منابع

Amini, M., Ghadami, M. R., Fathian, F., & Modarres, R. (2020). Teleconnections between oceanic-atmospheric indices and drought over Iran using quantile regressions. Taylor & Francis. <https://doi.org/10.1080/02626667.2020.1802029>

Anochi, J. A., Almeida, V. A. D., & Velho, H. F. D. C. (2021). Machine Learning for Climate Precipitation Prediction Modeling over South America. Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs13132468>

Bonavita, M. & Laloyaux, P. (2020). Machine learning for model error inference and correction. Wiley. <https://doi.org/10.1029/2020ms002232>

- M. D. (2015). Diversity, nonlinearity, seasonality, and memory effect in ENSO simulation and prediction using empirical model reduction. American Meteorological Society. <https://doi.org/10.1175/jcli-d-15-0372.1>
- Chen, L., Han, B., Wang, X., Zhao, J., Yang, W., & Yang, Z. (2023). Machine learning methods in weather and climate applications: a survey. Applied Sciences. <https://doi.org/10.20944/preprints202309.1764.v2>
- Cheng, Y., Tang, Y., Jackson, P. L., Chen, D., & Deng, Z. (2010). Ensemble Construction and Verification of the Probabilistic ENSO Prediction in the LDEO5 Model. American Meteorological Society. <https://doi.org/10.1175/2010jcli3453.1>
- Cifuentes, J., Marulanda, G., Bello, A., & Reneses, J. (2020). Air temperature forecasting using machine learning techniques: a review. Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/en13164215>
- Donnelly, J., Daneshkhan, A., & Abolfathi, S. (2023). Forecasting global climate drivers using Gaussian processes and convolutional autoencoders. Elsevier BV. <https://doi.org/10.1016/j.engappai.2023.107536>
- Feng, J., Wang, L., Chen, W., Fong, S. K., & Leong, K. C. (2010). Different impacts of two types of pacific ocean warming on southeast Asian rainfall during boreal winter. American Geophysical Union. <https://doi.org/10.1029/2010jd014761>
- Gao, C., Wu, X., & Zhang, R. (2016). Testing a four-dimensional variational data assimilation method using an improved intermediate coupled model for ENSO analysis and prediction. Springer Science+Business Media. <https://doi.org/10.1007/s00376-016-5249-1>
- Gao, Y., Tang, Y., & Liu, T. (2023). Reducing Model Error Effects in El Niño–Southern Oscillation Prediction Using Ensemble Coupled Data Assimilation. Remote Sensing. <https://doi.org/10.3390/rs15030762>
- Geng, H. & Wang, T. (2021). Spatiotemporal Model Based on Deep Learning for ENSO Forecasts. Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/atmos12070810>
- Ghasemi, A. (2019). Influence of northwest Indian Ocean sea surface temperature and El Niño–Southern Oscillation on the winter precipitation in Iran. IWA Publishing. <https://doi.org/10.2166/wcc.2019.274>
- Gholizadeh, M. H. (2015). Evaluation of Relation between Rainfall and El Niño Phenomena in Iran. <https://doi.org/10.51611/iars.irj.v5i1.2015.42>
- Ibebuchi, C. C. & Richman, M. B. (2024). Deep learning with autoencoders and LSTM for ENSO forecasting. <https://doi.org/10.1007/s00382-024-07180-8>
- Kumar, R., & Shrivastava, A. (2025). Integrating CNN-LSTM models for improved climate change forecasting. International Journal of Sciences and Innovation Engineering, 2(6), 394–400. <https://doi.org/10.70849/IJSCI>
- Luo, J., Ling, F., Ham, Y., & Kim, J. (2020). Seasonal-to-multiyear prediction of ENSO using machine deep learning. <https://doi.org/10.5194/egusphere-egu2020-21603>
- Mu, B., Qin, B., & Yuan, S. (2021). ENSO-ASC 1.0.0: ENSO deep learning forecast model with a multivariate air–sea coupler. Copernicus Publications. <https://doi.org/10.5194/gmd-14-6977-2021>
- Naz, F., She, L., Sinan, M., & Shao, J. (2024). Enhancing radar echo extrapolation by ConvLSTM2D for Precipitation nowcasting. Sensors, 24(2), 459. <https://doi.org/10.3390/s24020459>
- Nikraftar, Z. & Khaniani, A. S. (2018). Assessing the impact of cold and warm ENSO on drought over Iran. None. <https://doi.org/10.22059/EOGE.2018.257714.1022>
- NOAA Climate.gov. (2009). Climate variability: Oceanic Niño Index. NOAA Climate.gov. <https://www.climate.gov/news-features/understanding-climate/climate-variability-oceanic-nino-index>
- Qin, B., Yang, Z., Mu, M., Wei, Y., Cui, Y., Fang, X., Dai, G., & Yuan, S. (2024). The first kind of predictability problem of El Niño predictions in a multivariate coupled data-driven model. Quarterly Journal of the Royal Meteorological Society. <https://doi.org/10.1002/qj.4882>
- Sabziparvar, A. A., Mirmasoudi, S. H., Tabari, H., Nazemosadat, M. J., & Maryanaji, Z. (2010). ENSO teleconnection impacts on reference evapotranspiration variability in some warm climates of Iran. International Journal of Climatology, 31 (1), DOI: 10.1002/joc.2187
- Santos, M. A. D. C., Vega Oliveros, D. A., Zhao, L., & Berton, L. (2020). Classifying El Niño-southern oscillation combining network science and machine learning. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/access.2020.2982035>
- Santos, M. A. D. C., Vega Oliveros, D. A., Zhao, L., & Berton, L. (2020). Classifying El Niño-

- Southern Oscillation Combining Network Science and Machine Learning. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/access.2020.2982035>
- Slater, L., Arnal, L., Boucher, M., Chang, A., Moulds, S., Murphy, C., Nearing, G., Shalev, G., Shen, C., Speight, L., Villarini, G., Wilby, R., Wood, A., & Zappa, M. (2023). Hybrid forecasting: blending climate predictions with AI models. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-27-1865-2023>
- Tang, Y., Zhang, R., Liu, T., Duan, W., Yang, D., Zheng, F., Ren, H., Lian, T., Gao, C., Chen, D., & Mu, M. (2018). Progress in ENSO prediction and predictability study. Oxford University Press. <https://doi.org/10.1093/nsr/nwy105>
- VicenteSerrano, S. M., LopezMoreno, J. I., Gimeno, L., Nieto, R., MornTejeda, E., LorenzoLacruz, J., Beguera, S., & Azorn-Molina, C. (2011). A multiscalar global evaluation of the impact of ENSO on droughts. *American Geophysical Union*. <https://doi.org/10.1029/2011jd016039>
- Wang, C., Ren, B., Li, G., Zheng, J., Jiang, L., & Zhang, Z. (2023). Why could ENSO directly affect the occurrence frequency of arctic daily warming events after the late 1970s?. *Environmental Research Letters*. <https://doi.org/10.1088/1748-9326/acb06f>
- Wang, L., Ren, H., Zhu, J., & Huang, B. (2020). Improving prediction of two ENSO types using a multi-model ensemble based on stepwise pattern projection model. <https://doi.org/10.1007/s00382-020-05160-2>
- Yeh, S., Cai, W., Min, S., McPhaden, M. J., Dommenges, D., Dewitte, B., Collins, M., Ashok, K., An, S., Yim, B., & Kug, J. (2018). ENSO atmospheric teleconnections and their response to greenhouse gas forcing. Wiley. <https://doi.org/10.1002/2017rg000568>
- Yin, Z., Zhou, B., Duan, M., Chen, H., & Wang, H. (2023). Climate Extremes become increasingly fierce in china. Elsevier BV. <https://doi.org/10.1016/j.xinn.2023.100406>
- Zhai, P., Yu, R., Guo, Y., Li, Q., Ren, X., Wang, Y., Xu, W., Liu, Y., & Ding, Y. (2016). The Strong El Nino of 2015/16 and Its Dominant Impacts on Global and China's Climate. <https://doi.org/10.1007/s13351-016-6101-3>
- Zhang, W., Li, H., Stuecker, M. F., Jin, F., & Turner, A. G. (2015). A new understanding of El Nino impact over east Asia: dominance of the ENSO combination mode. *American Meteorological Society*. <https://doi.org/10.1175/jcli-d-15-0104.1>
- Zheng, Z., Hu, Z., & LHeureux, M. (2016). Predictable components of ENSO evolution in real-time multi-model predictions. *Nature Portfolio*. <https://doi.org/10.1038/srep35909>
- Zhou, L. & Zhang, R. (2023). A self-attention-based neural network for three-dimensional multivariate modeling and its skillful ENSO predictions. *Science Advances*. <https://doi.org/10.1126/sciadv.adf2827>
- Ziv, S. Z., Garfinkel, C. I., Davis, S., & Banerjee, A. (2022). The roles of the Quasi-Biennial Oscillation and El Niño for entry stratospheric water vapor in observations and coupled chemistry–ocean CCM1 and CMIP6 models. Copernicus Publications. <https://doi.org/10.5194/acp-22-7523-2022>

Impact of upper-level atmospheric data on the accuracy of predicting different ENSO phases using hybrid machine learning models in the southern provinces of Iran

Mahdi Malekian¹ and Ali Akbar Sabziparvar^{2*}

¹ Ph.D. Candidate of Agricultural Meteorology, Department of Water Science Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

² Professor of Meteorology, Department of Water Science Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

(Received: 01 May 2025, Accepted: 23 August 2025)

Summary

The El Niño-Southern Oscillation (ENSO), as one of the world's most important Teleconnection phenomena, has widespread impacts on meteorological patterns and extreme events in various regions, including southern Iran. This study aims to enhance the predictive capabilities for ENSO phases, leveraging advanced machine learning techniques to address climate variability in vulnerable regions. This research investigates the impact of upper-air Parameters/variables on the prediction accuracy of ENSO phases using a hybrid ConvLSTM2D machine learning model in the southern provinces of Iran. The results indicate the key role of upper-level atmospheric data in improving the prediction of ENSO phases. Meteorological data including geopotential height, temperature, relative humidity, specific humidity, wind speed, and wind direction were collected from the ERA5 (ECMWF Reanalysis v5) reanalysis dataset at four pressure levels (1000, 850, 700, and 500 hPa) for the period 1994 to 2023. These atmospheric variables were meticulously processed to capture intricate Spatio-Temporal relationships critical for accurate climate forecasting. The proposed model was designed by combining ConvLSTM2D, LSTM, and Dense layers to extract complex Spatio-Temporal features, and the outcomes were evaluated using metrics such as R^2 , MAE, and MSE. Results showed that inclusion of upper-air data (500 and 700 hPa), compared to near-surface levels, could significantly increase prediction accuracy. The highest model performance was noted at the 500 hPa level with a three month lead time ($R^2 = 0.93$, MAE = 0.14). This also shows the 500 hPa level of the atmosphere does not change its behavior, which in turns suggests why there is a delay during change in the atmosphere. This finding underscores the importance of mid-tropospheric dynamics in long-term climate predictions. Feature Importance analysis also showed the key role of dynamic variables (geopotential height and horizontal wind components) and thermodynamic variables (temperature and specific humidity) in the mid-level atmosphere. Furthermore, adding the suggest hybrid model in addressing non-linear relationships also makes it more applicable to complex climate systems. This research emphasizes the necessity of using a wide range of atmospheric data and optimizing the time horizon in climate predictions. The results can contribute to improving water resource management and reducing atmospheric hazards in southern Iran, although challenges such as model interpretability require further research. Future studies could explore integrating multi-source datasets to further refine predictive accuracy. In order to enhance prediction accuracy and improve performance in practical applications, it is recommended that hybrid models which incorporate Attention Mechanisms enabling focusing on salient features be developed.

Keywords: Forecast, teleconnection, artificial intelligence, hybrid models, feature importance

*Corresponding author:

swsabzi@basu.ac.ir