

## کاربست شبکه عصبی هم‌آمیختی برای پارامترسازی چشمه امواج گرانی-لختی در پوشش سپهر زیرین

الهه خانلری<sup>۱</sup>، علیرضا محب‌الحجه<sup>۲</sup>، محمد میرزائی<sup>۳\*</sup> و مژگان امیرامجدی<sup>۴</sup>

<sup>۱</sup> کارشناسی ارشد، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

<sup>۲</sup> استاد، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

<sup>۳</sup> دانشیار، موسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

<sup>۴</sup> پژوهشگر، مؤسسه فناوری کارلسروهه، کارلسروهه، آلمان

(دریافت: ۱۴۰۵/۰۲/۲۶، پذیرش: ۱۴۰۵/۰۳/۱۹)

### چکیده

در چند دهه گذشته استفاده از روش‌های یادگیری ماشین برای پارامترسازی امواج گرانی-لختی در مدل‌های گردش کلی جو مورد توجه قرار گرفته است. این تحقیق به بررسی عملکرد روش شبکه عصبی هم‌آمیختی (Convolutional Neural Network; CNN) به عنوان مدلی ناپارامتری در بازسازی امواج گرانی-لختی ناکوهساری در مناطق اقیانوسی عرض‌های میانی با استفاده از داده‌های بازتحلیل ERA5 می‌پردازد. این داده‌ها با تفکیک  $2/5^\circ \times 2/5^\circ$  برای متغیرهای توضیحی و با تفکیک  $0/25^\circ \times 0/25^\circ$  برای متغیرهای هدف به منظور کمی‌سازی ویژگی‌های امواج گرانی انتخاب شدند. متغیرهای توضیحی انتخاب شده در ۱۵ تراز فشاری نماینده چشمه‌های امواج گرانی هستند. در مقابل برای بررسی فعالیت امواج گرانی در پوشش سپهر زیرین، متغیرهای هدف در تراز ۱۰۰ هکتوپاسکال تعریف شد. دو رویکرد شامل بررسی تأثیر حجم داده‌های آموزشی با ثابت نگه‌داشتن تعداد کانال‌های ورودی در ۱۵۰ کانال و بهینه‌سازی تعداد کانال‌های ورودی با ثابت نگه‌داشتن دوره آموزشی در سه سال مورد ارزیابی قرار گرفت.

نتایج حاصل از پیش‌بینی انحراف معیار سه متغیر هدف شار تکانه مطلق، واگرایی افقی باد و سرعت قائم نشان می‌دهد که افزایش حجم داده‌های آموزشی در رویکرد اول، ساختار مکانی و شدت متغیرها را بهتر حفظ می‌کند. رویکرد دوم کارایی قابل‌ملاحظه‌ای با استفاده از فقط ۱۵ کانال ورودی نشان داد که می‌تواند اهمیت متغیر باد افقی در پیش‌بینی متغیرهای هدف را بیان کند. به‌علاوه، ترکیب‌هایی با ۴۲ و ۱۵۰ کانال نتایجی نسبتاً مشابه با ۱۵ کانال نشان دادند که حکایت از توانایی ذاتی CNN در شناسایی متغیرهای کم‌اهمیت با استفاده از تابع فعال‌ساز مناسب دارد. با وجود محدودیت در پیش‌بینی رویدادهای فرین، CNN توانایی تشخیص دوره‌های فعالیت امواج گرانی را دارد. همچنین این روش قابلیت خوبی در بازسازی امواج گرانی-لختی نشان می‌دهد، با این وجود برای کاربرد CNN در مدل‌های اقلیمی آزمایش‌های گسترده‌تری باید انجام شود.

**کلمه‌های کلیدی:** امواج گرانی-لختی، شبکه عصبی هم‌آمیختی، پارامترسازی، پوشش سپهر زیرین، امواج گرانی ناکوهساری

## ۱ مقدمه

امواج گرانی-لختی که در ادامه از آنها صرفاً با نام کوتاه‌تر امواج گرانی یاد می‌شود، نوسانات آزمینگردی هستند که بر اثر دو نیروی کوریولیس و شناوری به وجود می‌آیند (هولتن، ۲۰۰۴). طول موج افقی این امواج از ده تا چند هزار کیلومتر و طول موج قائم آنها به دلیل چینش قائم باد با ارتفاع از مرتبه ۱ تا ۱۰ کیلومتر متغیر است. با توجه به اینکه در اغلب این امواج، مقیاس افقی خیلی بزرگ‌تر از مقیاس قائم بوده، می‌توان با تقریب خوبی از توازن آب‌ایستایی برای توصیف آنها استفاده کرد. بسامد ذاتی این امواج بین بسامد شناوری  $N$  و بسامد لختی  $f$  قرار دارد. از مشخصه‌های دیگر امواج گرانی می‌توان به سرعت گروه ۱۵ تا ۳۵ متر بر ثانیه، دوره تناوب ۱۲ دقیقه تا ۱۵ ساعت و دامنه ۰/۵ تا ۱۵ هکتوپاسکال اشاره کرد (هولتن و همکاران، ۲۰۰۲).

با توجه به اثرات امواج گرانی در پدیده‌های جوئی، در نظر گرفتن تأثیر آنها در مدل‌های گردش کلی جو از اهمیت بالایی برخوردار است. این امواج از طریق واداشت دینامیکی بر گردش کلی جو به‌خصوص در پوشش سپهر و میان‌سپهر اثر می‌گذارند. وقوع رخدادهایی مانند تغییر شارش در سطح زمین و سطوح زیرین وردسپهر (بوزارت و کاسن، ۱۹۷۳؛ کاک و دورین، ۱۹۸۸؛ بوزارت و همکاران، ۱۹۹۸)، انتقال قائم و افقی جرم، تکانه و انرژی (الیاسن و پالم، ۱۹۶۱)، شکل‌گیری و تعدیل تلاطم در هوای صاف (شاپیرو، ۱۹۸۱)، ایجاد ابرهای پوشش سپهر قطبی (دورنبرک و همکاران، ۱۹۹۹؛ بوس و همکاران، ۲۰۰۴؛ هیچمن و همکاران، ۱۹۹۹)، کاهش ازون محلی (کوئل و همکاران، ۲۰۰۴) با نقش مهم برای امواج گرانی در آنها به‌خوبی بیانگر اهمیت این امواج است. امواج گرانی عمدتاً در وردسپهر تولید شده و تا پوشش سپهر میانی و زیرین منتشر می‌شوند. از مهم‌ترین چشمه‌های امواج گرانی می‌توان به کوهساری، همرفت و

چینش قائم سرعت باد در وردسپهر اشاره کرد. به علاوه چشمه‌هایی که به دینامیک بزرگ‌مقیاس وابسته هستند مانند سامانه‌های جبهه‌ای، تنظیم شارش نامتوازن در مجاورت جریان جتی، واداشت همراه با اتلاف جایگزیده موج، امواج گرانی را تولید می‌کنند (کیم و همکاران، ۲۰۰۳).

با وجود پیشرفت مدل‌های پیش‌بینی وضع هوا و اقلیم در شبیه‌سازی ویژگی‌های میانگین جو، متحمل شدن حجم بالای محاسبات در مواجهه با پدیده‌هایی در مقیاس کوچک‌تر از تفکیک فضایی مدل‌ها، امکان بررسی همه حرکت‌های جوئی را با محدودیت روبرو می‌کند. تعدد در چشمه‌های امواج گرانی، پیچیدگی در نحوه انتشار آنها و همچنین کوچک‌تر بودن مقیاس این امواج نسبت به تفکیک فضایی مدل‌ها باعث درک نظری ناقص از سازوکار تولید آنها و عدم امکان نمایش صریح امواج در مدل‌های گردش کلی شده است. (وارنر، ۲۰۱۰). برای رفع این مشکل، اثر امواج گرانی یا به عبارتی، انرژی و تکانه‌ای که در محل اتلاف موج به شارش میانگین وارد می‌کنند، به کمک برخی پارامترها تقریب زده شده و در مدل‌های گردش کلی پارامترسازی می‌شود. بنابراین شناخت چشمه‌های امواج گرانی و در نظر گرفتن چگونگی تولید، انتشار و اتلاف امواج در جو امری مهم محسوب می‌شود (امیرامجدی و همکاران، ۲۰۲۰). پارامترسازی چشمه‌های امواج گرانی با روش‌های مدل‌های طیفی، پارامترسازی تجمعی امواج و روش‌های جدیدتر به کارگیری پارامترهای فیزیکی قابل اندازه‌گیری چشمه‌های انرژی امواج انجام می‌گیرد.

تحقیقات نشان دادند در بسیاری از مدل‌های مرسوم که چشمه‌های امواج گرانی را به صورت یکنواخت یا همگن در فضای طیفی مورد بررسی قرار می‌دهند، پیچیدگی واقعی امواج گرانی در جو در نظر گرفته نمی‌شود (وارنر و مک‌اینتایر، ۱۹۹۶). در مطالعه میرزائی

(۲۰۲۲) نشان داده شد که شبکه‌های عصبی با داده‌های محدود امکان تقلید پارامترسازی امواج گرانی ناکوهساری را در مدل‌های اقلیمی با دقت بالا فراهم می‌آورند و حتی به شرایط جدید مانند افزایش CO<sub>2</sub> تعمیم می‌یابند. این دستاورد بیان می‌کند که با جایگزینی طرحواره‌های فیزیکی سنتی، عدم قطعیت‌های پیش‌بینی اقلیمی کاهش می‌یابد.

در پژوهشی مشابه هاردیمن و همکاران (۲۰۲۳) نشان دادند که با جایگزینی طرحواره پارامترسازی امواج گرانی ناکوهساری در مدل اقلیمی هواشناسی Met Office با یک شبکه عصبی، دقت پیش‌بینی‌های فصلی و منطقه‌ای بهبود می‌یابد، به طوری که توانایی بالایی در شبیه‌سازی دقیق پدیده‌های پیچیده پوشش سپهر مانند نوسان شبه‌دوسالانه (QBO) و تأثیرات النینو-نوسان جنوبی (ENSO) مشاهده شده است. مطالعه گوپتا و همکاران (۲۰۲۵) به معرفی سه شبکه عصبی متفاوت که سطوح مختلفی از نامحلی بودن افقی را در معماری خود ادغام کرده‌اند، پرداخته است تا راهکاری برای پیش‌بینی دقیق شار امواج گرانی ارائه دهد. این رویکرد اثرات نامحلی نادیده گرفته شده در پارامترسازی عملیاتی فعلی را پوشش داد و موجب توسعه پارامترسازی مبتنی بر یادگیری ماشین برای فرایندهای از دست رفته میان‌مقیاس در مدل‌های اقلیمی شد.

یکی دیگر از کارهای اخیر در زمینه پارامترسازی امواج گرانی به کمک روش یادگیری ماشین، مطالعه امیرامجدی و همکاران (۲۰۲۳) است که تحقیق حاضر در ادامه آن انجام شده است. در مطالعه مذکور روش جنگل تصادفی برای برآورد بزرگی امواج گرانی-لختی در پوشش سپهر زیرین استفاده شد. این روش در برون‌یابی مقادیر خارج از مجموعه داده آموزشی با محدودیت روبرو شد (امیرامجدی و همکاران، ۲۰۲۳). اهمیت امواج گرانی و چالش‌های موجود در بررسی رفتار آنها در

و همکاران (۲۰۱۴) برای انرژی امواج گرانی-لختی روابط پارامترسازی شده به دست آمد. این روابط توسط امیرامجدی و همکاران (۲۰۲۰) با داده‌های بازتحلیل ERA5 مورد آزمون قرار گرفت و با داده‌های GRACILE که بر پایه مشاهدات ماهواره‌ای پوشش سپهر میانی هستند، مقایسه شد. نتایج نشان دادند که در تراز مورد مطالعه با وجود مطابقت خوب توزیع مکانی و زمانی امواج آشکار شده توسط مدل با مشاهدات، امواج گرانی در شبیه‌سازی عددی تا سه برابر نسبت به مشاهدات کمتر برآورد شده است. عوامل محدود کننده شامل روش تفکیک مکانی برای جداسازی امواج گرانی و عدم قطعیت در کمی‌سازی انرژی‌های فرایابی شده بوده است (امیرامجدی و همکاران، ۲۰۲۰). بنابراین به طور کلی مواردی مانند محدودیت‌های تفکیک مدل، پارامترسازی مدل‌ها و شبیه‌سازی آرمانی و روش‌های جداسازی امواج گرانی از جریان میانگین منجر به عدم قطعیت در نتایج می‌شوند (میرزائی و همکاران، ۲۰۱۴).

استفاده از الگوریتم‌های یادگیری ماشین به عنوان ابزاری در زمینه علوم جو در چند دهه گذشته متداول شده است. روش‌های یادگیری ماشین در بررسی فرایندهای جوی با مقیاسی کوچک‌تر از تفکیک فضایی مدل‌های پیش‌بینی عددی وضع هوا و اقلیم نیز کاربرد دارد. در ادامه به چند مطالعه اخیر که دستاوردهایی در زمینه پارامترسازی امواج گرانی با تکیه بر شبکه عصبی داشتند اشاره می‌شود. ماتسوکا و همکاران (۲۰۲۰) از روش مبتنی بر یادگیری عمیق برای تخمین شار تکانه امواج گرانی کوهساری در پوشش سپهر زیرین استفاده کردند. آنها نشان دادند که مدل با دقت مناسب و هزینه محاسباتی پایین می‌تواند الگوهای مشابه با واقعیت زمینی را به‌خصوص در مناطق خشکی و سواحل جنوبی تخمین بزند اما در بازتولید دامنه‌های بزرگ در مناطق دریایی به موفقیت کمتری دست یابد. در مطالعه اسپینوزا و همکاران

است، استفاده می‌شود. توان تفکیک مکانی و زمانی مطلوب ERA5 و همچنین به کارگیری طرحواره‌های پارامترسازی زیرشبکه‌ای برای مدل‌سازی اثرات فیزیکی امواج با طول موج‌های کوتاه‌تر از آستانه تفکیک‌پذیری مدل، ERA5 را به مجموعه داده‌ای مناسب برای مطالعات دینامیک جو و تحلیل امواج گرانی تبدیل کرده است (هرسباخ و همکاران، ۲۰۲۰). منطقه مورد مطالعه بخشی از اقیانوس آرام در عرض‌های میانی نیمکره شمالی انتخاب شده است تا بر روی هدف مسئله که امواج گرانی ناکوهساری است، متمرکز باشد. موقعیت دقیق این ناحیه در عرض جغرافیایی  $30^{\circ}$  تا  $60^{\circ}$  شمالی و طول جغرافیایی  $160^{\circ}$  شرقی تا  $140^{\circ}$  غربی واقع شده است.

کاربست روش CNN ایجاد دو مجموعه داده با عنوان متغیرهای توضیحی و متغیرهای هدف را ملزم می‌کند. برای انتخاب متغیرهای توضیحی از مجموعه داده‌های ERA5 در تفکیک پایین با فاصله شبکه  $2/5^{\circ} \times 2/5^{\circ}$  در راستای نصف‌النهاری و مداری استفاده شد. تفکیک مکانی کاهش یافته در این مجموعه داده، موجب قرار گرفتن عمده طیف امواج گرانی در محدوده زیرشبکه‌ای و عدم نمایش آنها در داده‌های مورد استفاده شده است. با این وجود برای حذف نشانه‌های احتمالی امواج گرانی یک پالایه طیفی پایین‌گذر با عدد موج مداری ۲۲ بر متغیرهای توضیحی اعمال شده است (ساتو و همکاران، ۲۰۱۲ و ۲۰۰۹؛ امیرامجدی و همکاران، ۲۰۲۰). متغیرهای توضیحی در ۱۵ تراز فشاری از ۱۰۰۰ تا ۱۰۰ هکتوپاسکال مشخص می‌شوند و نماینده‌ای از چشمه‌های ناکوهساری امواج گرانی در وردسپهر هستند. این متغیرها شامل تاوایی پتانسیلی  $(K m^2/kg s)$ ، بی‌هنجاری تاوایی پتانسیلی  $(K m^2/kg s)$ ، تاوایی نسبی  $(1/s)$ ، گرادیان دما  $(K)$ ، سرعت باد افقی  $(m/s)$  و سرعت قائم فشاری  $(Pa/s)$  می‌باشند.

متغیرهای هدف که مشخصه‌های امواج گرانی را

پیش‌بینی وضع هوا و همچنین تحقیقات نسبتاً کمی که برای درک بهتر در انتخاب روش‌های نوظهور یادگیری ماشین در ارتباط با امواج گرانی انجام شده است، کاربست سایر روش‌های یادگیری ماشین از جمله شبکه‌های عصبی را ضروری می‌سازد. از این رو تحقیق حاضر عملکرد روش شبکه عصبی هم‌آمیختگی (Convolutional Neural Network; CNN) را به منزله یک مدل ناپارامتری در بازسازی امواج گرانی ناکوهساری در مناطق اقیانوسی عرض‌های میانی با استفاده از مجموعه داده‌های بازتحلیل ERA5 مورد بررسی قرار می‌دهد. لازم به ذکر است که در این پژوهش، مطالعه امیرامجدی و همکاران (۲۰۲۳) عمدتاً همچون مبنایی برای زمینه‌سازی مسئله و انتخاب بخشی از کانال‌های ورودی مورد استفاده قرار گرفته است. با این حال، به دلیل تفاوت در الگوریتم، پیکربندی داده‌ها و شرایط آموزش و ارزیابی، مقایسه نتایج CNN با روش جنگل تصادفی نباید مقایسه‌ای مستقیم و کاملاً هم‌شرایط تفسیر شود، بلکه بیشتر جنبه کیفی و تکمیلی دارد. ساختار مقاله به این ترتیب است که در بخش دوم، داده‌ها و روش انجام کار بیان می‌شود. در ادامه نتایج در بخش سوم آورده می‌شود و در نهایت، بخش چهارم به جمع‌بندی نتایج و نتیجه‌گیری اختصاص داده خواهد شد.

## ۲ داده‌ها و روش انجام کار

### ۲-۱ آماده‌سازی داده‌ها

همان‌طور که در بخش قبل بیان شد، در این پژوهش روش شبکه عصبی هم‌آمیختگی (CNN) به کار گرفته می‌شود تا توانایی بازسازی امواج گرانی ناکوهساری از جریان تفکیک‌پذیر با تفکیک پایین مورد ارزیابی قرار گیرد. برای رسیدن به این هدف در چارچوب مدل جهانی از مجموعه داده‌های بازتحلیل ERA5 که از مرکز پیش‌بینی‌های میان‌مدت وضع هوای اروپا (ECMWF)

یادگیری مدل را بررسی کنند و در صورت لزوم بهینه‌سازی در ساختار معماری صورت پذیرد.

برای آماده‌سازی مجموعه داده‌ها برای سه مرحله ذکر شده، ترکیبات متنوعی از بازه‌های زمانی یک‌ساله و سه‌ساله متشکل از سال‌های ۲۰۱۷، ۲۰۱۸ و ۲۰۲۰ برای آموزش و اعتبارسنجی مدل انتخاب گردیده‌اند. بازه زمانی دسامبر ۲۰۱۸ تا نوامبر ۲۰۱۹ به مرحله آزمون اختصاص داده شد. انتخاب بازه سه‌ساله برای آموزش مدل با هدف ایجاد توازن میان پوشش تغییرپذیری زمانی امواج گرانی، امکان مقایسه با مطالعه امیرامجدی و همکاران (۲۰۲۳)، و محدودیت‌های محاسباتی انجام شد. از آنجا که هدف اصلی این پژوهش ارزیابی اولیه توانایی CNN در بازسازی الگوهای مکانی و زمانی غالب امواج گرانی ناکوهساری است، این بازه زمانی برای مقایسه پیکربندی‌های مختلف مدل مناسب در نظر گرفته شد. افزون بر این، مقایسه ترکیب‌های یک‌ساله و سه‌ساله در این پژوهش امکان بررسی مستقیم حساسیت مدل نسبت به حجم داده‌های آموزشی را فراهم می‌کند. با این حال، این بازه زمانی نمی‌تواند تمام تغییرپذیری بین‌سالی و رخداد‌های نادر یا فرین امواج گرانی را پوشش دهد و از این نظر یکی از محدودیت‌های مطالعه حاضر محسوب می‌شود.

علاوه بر این، سه پیکربندی متمایز از کانال‌های ورودی طراحی شده است. در پیکربندی اول ۱۵۰ کانال شامل تمامی متغیرهای توضیحی در همه ترازهای فشار، حالت دوم ۱۵ کانال شامل فقط متغیر باد افقی در کلیه ترازهای فشاری و حالت سوم مجموعه‌ای متشکل از ۴۲ کانال برپایه یافته‌های مطالعه امیرامجدی و همکاران (۲۰۲۳) استخراج گردیده است. این ۴۲ کانال برای هر یک از متغیرهای هدف متفاوت است و از متغیرهای موثری که با استفاده از روش میانگین کاهش ناخالصی شناسایی شده‌اند، انتخاب شد. این متغیرها در جدول‌های

توصیف می‌کنند، از مجموعه داده‌های ERA5 با تفکیک بالا ( $0.25^\circ \times 0.25^\circ$ ) انتخاب شدند. این متغیرهای دینامیکی شامل انحراف معیار سه متغیر واگرایی افقی باد، سرعت قائم و شار تکانه مطلق هستند که اطلاعات ارزشمندی درباره شدت و گستردگی فعالیت امواج گرانی در منطقه مورد نظر ارائه می‌دهند. انحراف معیار متغیرها با استفاده از روش میانگین متحرک در ۹۰۰ نقطه شبکه ( $750 \times 750$  کیلومتر مربع) به دست آمد. بر خلاف متغیرهای توضیحی، متغیرهای هدف تنها از تراز فشار ۱۰۰ هکتوپاسکال استخراج شده‌اند تا بازسازی چشمه‌های امواج گرانی در پوشش سپهر زیرین را فراهم سازد.

هم‌مقیاس بودن داده‌ها قبل از ورود به شبکه عصبی ضروری است. برای این منظور از استانداردسازی Z-Score که از رابطه (۱) محاسبه می‌شود استفاده شده است. با استفاده از این استانداردسازی پس از محاسبه میانگین‌ها و انحراف معیارها برای هر ویژگی و اعمال آنها روی هر کدام از ویژگی‌ها، این مقادیر در مجموعه داده‌هایی حفظ می‌شوند تا در شبکه طراحی شده نهایی مورد استفاده قرار گیرند.

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

که در اینجا  $x$  مقدار واقعی،  $x'$  مقدار استاندارد شده،  $\mu$  میانگین ویژگی مورد نظر و  $\sigma$  انحراف معیار آن ویژگی می‌باشد.

هنگام کار با روش‌های شبکه عصبی داده‌های معین و متفاوتی برای سه مرحله آموزش، اعتبارسنجی و آزمون انتخاب می‌شوند. یادگیری مدل شبکه عصبی با استفاده از داده‌های مربوطه در مرحله آموزش انجام می‌شود و داده‌های آزمون معیار نهایی ارزیابی عملکرد مدل را بیان می‌کنند. در این میان داده‌های اعتبارسنجی که ابزار توسعه مدل محسوب می‌شوند، نماینده‌ای از داده‌های آزمون هستند تا قبل از ورود به آن مرحله، چگونگی

۱ تا ۳ نشان داده شده‌اند.

جدول ۱. ۴۲ کانال انتخاب شده برای متغیر هدف واگرایی افقی باد از مطالعه امیرامجدی و همکاران (۲۰۲۳) (خانه‌های پرشده به معنای متغیر انتخاب شده از تراز فشار مربوطه است).

ترازهای فشار (هکتوپاسکال)														متغیرها	
۱۰۰۰	۹۵۰	۹۰۰	۸۵۰	۸۰۰	۷۵۰	۷۰۰	۶۰۰	۵۰۰	۴۰۰	۳۰۰	۲۵۰	۲۰۰	۱۵۰	۱۰۰	
															تندی باد قائم
															تندی باد افقی
															گرادیان مداری دما
															گرادیان نصف‌النهاری دما
															گرادیان افقی دما
															تاوایی
															بی‌هنجاری تاوایی پتانسیلی

جدول ۲. مشابه جدول ۱ اما برای متغیر هدف شار تکانه مطلق.

ترازهای فشار (هکتوپاسکال)														متغیرها	
۱۰۰۰	۹۵۰	۹۰۰	۸۵۰	۸۰۰	۷۵۰	۷۰۰	۶۰۰	۵۰۰	۴۰۰	۳۰۰	۲۵۰	۲۰۰	۱۵۰	۱۰۰	
															تندی باد قائم
															تندی باد افقی
															گرادیان مداری دما
															گرادیان نصف‌النهاری دما
															گرادیان افقی دما
															تاوایی
															بی‌هنجاری تاوایی پتانسیلی

جدول ۳. مشابه جدول ۱ اما برای متغیر هدف سرعت قائم.

ترازهای فشار (هکتوپاسکال)														متغیرها	
۱۰۰۰	۹۵۰	۹۰۰	۸۵۰	۸۰۰	۷۵۰	۷۰۰	۶۰۰	۵۰۰	۴۰۰	۳۰۰	۲۵۰	۲۰۰	۱۵۰	۱۰۰	
															تندی باد قائم
															تندی باد افقی
															گرادیان مداری دما
															گرادیان نصف‌النهاری دما
															گرادیان افقی دما
															تاوایی
															بی‌هنجاری تاوایی پتانسیلی

جدول ۴. ساختار ترکیب داده‌ها بر اساس مجموعه داده‌های آموزش، اعتبارسنجی و آزمون و تعداد کانال.

ترکیب‌ها	کانال‌ها	داده‌های آموزش	داده‌های اعتبارسنجی	داده‌های آزمون
Y17C150	۱۵۰	۲۰۱۷	۲۰۱۸	۲۰۱۹
Y18C150	۱۵۰	۲۰۱۸	۲۰۲۰	
Y20C150	۱۵۰	۲۰۲۰	۲۰۱۸	
Y3C150	۱۵۰	۲۰۱۷، ۲۰۱۸، ۲۰۲۰	۲۰۱۸	
Y3C15	۱۵			
Y3C42	۴۲			

برای کاهش همبستگی زمانی در داده‌ها، ۲۸ گام زمانی از انتهای مجموعه داده‌های آموزش و اعتبارسنجی حذف گردید. در ترکیب‌هایی که از سه سال داده برای آموزش استفاده می‌کردند، ۱۰ درصد پایانی داده‌های سال ۲۰۱۸ از مجموعه داده آموزش حذف و به اعتبارسنجی اضافه شد. بنابراین ساختار ترکیب داده‌ها بر اساس تعداد کانال‌ها و مراحل آموزش، اعتبارسنجی و آزمون تعیین شد. برای درک بهتر و دسترسی آسان‌تر چگونگی انتخاب این ترکیب‌ها، جدول ۴ تهیه شده است.

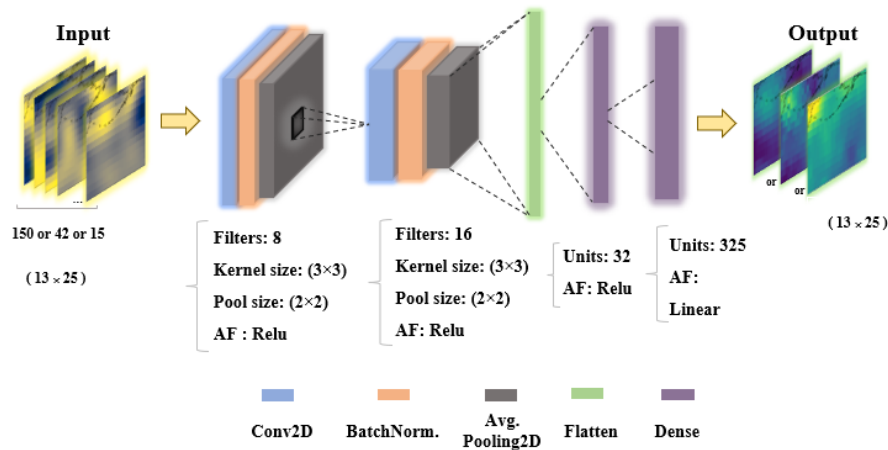
## ۲-۲ تنظیم مدل

برای پیاده‌سازی روش CNN استفاده شده در این تحقیق، مراحل انجام می‌گیرد که در این بخش به آن پرداخته می‌شود. برای تنظیم مدل ابتدا معماری مورد نیاز مسئله انتخاب و سپس هاپرپارامترهای موجود در آن برای دستیابی به بالاترین توانمندی مدل تنظیم می‌شوند. معماری CNN ساختاری چندلایه‌ای دارد که در شکل ۱ نمایش داده شده است. این لایه‌ها عبارتند از ورودی، خروجی، هم‌آمیخته، ادغام میانگین، نرمال‌سازی دسته، لایه کاملاً متصل و لایه تخت‌ساز (Flatten) می‌باشند.

در اولین لایه اول هم‌آمیخته، ۸ پالایه و در لایه دوم آن ۱۶ پالایه که در هر کدام اندازه هسته  $3 \times 3$  می‌باشد، تعیین می‌شود. بعد از هر لایه هم‌آمیخته از لایه‌های نرمال‌سازی دسته (BatchNorm.) نیز استفاده شده است. اهمیت این

لایه تسریع فرایند یادگیری، کاهش وابستگی به مقاداردهی اولیه وزن‌ها و همچنین کاهش مشکل محو شدن گرادیان و در نهایت بهبود جریان اطلاعات در شبکه می‌باشد که می‌تواند برای تشخیص الگوهای پیچیده امواج گرانی مهم باشد (سنتورکار و همکاران، ۲۰۱۸). به دنبال لایه نرمال‌سازی دسته، یک لایه ادغام میانگین با اندازه مخزن  $2 \times 2$  قرار می‌گیرد. لایه تخت‌ساز که وظیفه تبدیل داده‌های دوبعدی به یک‌بعدی را دارد، پس از لایه‌های هم‌آمیخته دوبعدی وارد عمل می‌شود که سپس به دو لایه کاملاً متصل (Dense) انتقال می‌یابد. لایه‌های تماماً متصل به ترتیب دارای ۳۲ و ۳۲۵ نورون هستند. لایه خروجی که به صورت تک کاناله تعریف شده است، بازسازی امواج گرانی را در سه نقشه ویژگی از متغیرهای هدف به صورت جداگانه نشان می‌دهد. این شبکه هم‌آمیختی ورودی‌هایی با ابعاد  $13 \times 25$  دریافت می‌کند. آخرین لایه کاملاً متصل با ۳۲۵ نورون و تابع فعال‌ساز خطی، به گونه‌ای طراحی شده که هر نورون دقیقاً با یک نقطه از شبکه مکانی  $13 \times 25$  متناظر است؛ بدین ترتیب، شبکه قادر است مقدار متغیر هدف را به‌طور هم‌زمان برای تمامی نقاط شبکه مکانی پیش‌بینی و نگاشت کامل مکانی را در یک گذر رو به جلو بازسازی کند. برخی از ابزارهایی که در طراحی معماری CNN استفاده شده است شامل تنظیم‌کننده هسته (L2)، بهینه‌ساز تخمین گشتاور تطبیقی، تابع فعال‌ساز ReLU، تابع

فعال‌ساز خطی و Early stopping می‌باشند. تابع هزینه مورد استفاده در این شبکه میانگین مربع خطا (MSE) است.



شکل ۱. معماری مدل CNN شامل لایه‌های ورودی (Input)، خروجی (Output)، هم‌آمیخته دو بعدی (Conv2D) با ۸ و ۱۶ لایه و اندازه هسته  $3 \times 3$ ، نرمال‌سازی دسته (BatchNorm.)، ادغام میانگین دو بعدی (Avg. Pooling2D) با اندازه مخزن  $2 \times 2$ ، تخت‌ساز (Flatten) و کاملاً متصل (Dense) با نوروں‌های ۳۲ و ۳۲۵.

آهنگ یادگیری، اندازه مخزن لایه ادغام و اندازه هسته به ترتیب مورد بررسی قرار گرفتند. در روند دوم، عکس این ترتیب انجام شد و در روند سوم، هایپرپارامترها به صورت تصادفی انتخاب شدند. در همه این روندها تفاوت قابل ملاحظه‌ای در نتیجه نهایی دیده نشد.

برای ارزیابی تأثیر هر یک از هایپرپارامترها در شرایط مختلف زمانی و حجمی داده‌ها، چهار سناریوی مختلف بر اساس داده‌های آموزشی انجام گرفته که شامل استفاده از (الف) داده‌های سال ۲۰۱۷، (ب) داده‌های سال ۲۰۱۸، (ج) داده‌های سال ۲۰۲۰، و (د) مجموعه ترکیبی داده‌های سه سال ۲۰۱۷، ۲۰۱۸ و ۲۰۲۰ است. به طور کلی همگرایی مشابهی در چهار سناریوی مختلف برای هایپرپارامترهای ضریب تنظیم‌کننده هسته، تابع فعال‌ساز، اندازه دسته و آهنگ یادگیری مشاهده شد. این رفتار پایدار امکان تعیین مقادیر بهینه برای این هایپرپارامترها را فراهم می‌کند. در مقابل، هایپرپارامتر اندازه هسته و اندازه مخزن در سناریوهای مختلف ناپایداری نشان دادند که

هایپرپارامترها متغیرهای کنترلی فرایند یادگیری در معماری شبکه محسوب می‌شوند که قبل از آموزش تعریف شده و در طی فرایند یادگیری ثابت باقی می‌مانند. هایپرپارامترهای استفاده شده در معماری مدل CNN در این مطالعه شامل تابع فعال‌ساز، ضریب تنظیم‌کننده هسته، اندازه دسته، آهنگ یادگیری، اندازه مخزن لایه ادغام و اندازه هسته هستند. این هایپرپارامترها و مقادیر احتمالی برای تنظیم آنها در جدول ۵ نشان داده شده است. انتخاب مقدار مناسب از میان مقادیر احتمالی با در نظر گرفتن همه متغیرهای توضیحی در همه ترازها به این صورت انجام شد که در هر مرحله تنها یک هایپرپارامتر در نظر گرفته شده و باقی آنها در مقادیر ثابت نگه‌داشته شدند و عملکرد هایپرپارامترها با معیار میانگین درصد مطلق خطا مورد ارزیابی قرار گرفت. از آنجا که ممکن است ترتیب انتخاب هایپرپارامترها بر نتیجه نهایی اثر گذار باشد، تنظیم هایپرپارامترها در سه روند متفاوت انجام شد. در روند اول، تابع فعال‌ساز، ضریب تنظیم‌کننده هسته، اندازه دسته،

نصف‌النهاری است. با هدف کمترین پیچیدگی محاسباتی در کنار بیشترین دقت تشخیص، مقایسه سناریوهای مختلف و در نظر گرفتن جنبه فیزیکی می‌توان بهترین گزینه برای اندازه دسته و اندازه مخزن را به ترتیب  $3 \times 3$  و  $2 \times 2$  تعیین کرد. در شکل‌های ۲ و ۳ دو نمونه از نمودارهای میانگین درصد مطلق خطا به ترتیب برای هایپرپارامترهای آهنگ یادگیری و اندازه مخزن ارائه شده است.

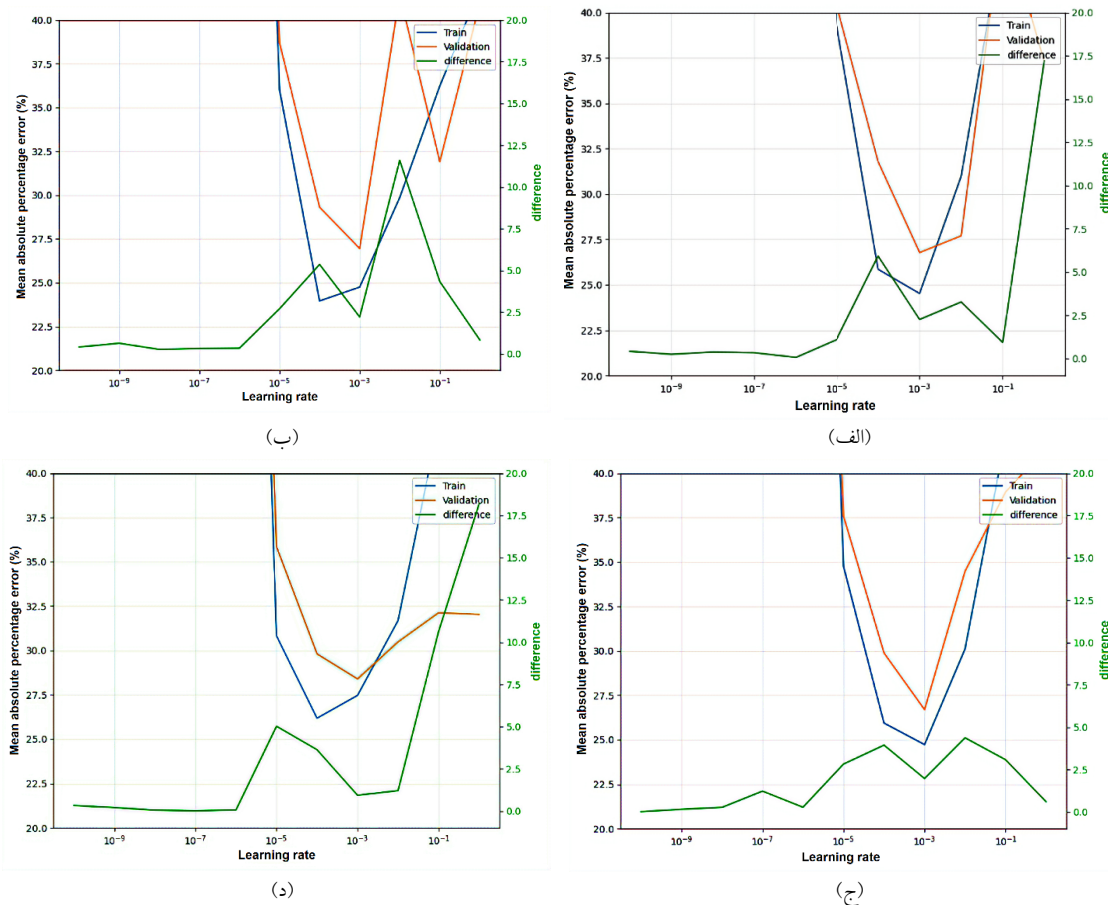
بعد از آماده‌سازی داده‌ها و تنظیم مدل، مرحله آموزش مدل انجام می‌شود. در طول آموزش، خطای مدل روی داده‌های آموزشی معمولاً به‌طور پیوسته کاهش می‌یابد، اما خطای اعتبارسنجی پس از رسیدن به یک کمینه، مجدداً افزایش می‌یابد. با پایش خطای اعتبارسنجی در هر دوره، بهترین وضعیت برای وزن‌های مدل ذخیره می‌شود و در صورتی که پس از تعداد مشخصی دوره هیچ بهبودی مشاهده نشود، آموزش با استفاده از ابزار Early stopping متوقف و وزن‌های بهینه بازیابی می‌شوند. با انجام آموزش روی ترکیب‌های مختلف مشاهده شد که مدل در بازه بین ۱۰ تا ۱۵ دوره متوقف می‌شود.

این اتفاق انتخاب مقدار مشخص برای آنها را با چالش مواجه ساخت. با مشاهده نتایج مشابه در تنظیم هایپرپارامترها برای هر سه متغیر هدف، اعمال رویکردی متفاوت برای تعیین مقادیر بهینه دو هایپرپارامتر اندازه هسته و اندازه مخزن را ضروری می‌سازد.

با توجه به ماهیت عملکرد CNN که اطلاعات مکانی را از طریق حرکت هسته‌ها و مخزن‌ها روی کانال‌ها استخراج می‌کنند، می‌توان از رویکردی فیزیکی در انتخاب مقدار قابل قبول برای این دو هایپرپارامتر استفاده کرد. به منظور شناسایی چشمه‌های امواج گرانی توسط هر هسته و استخراج ویژگی‌های ضروری، اندازه هسته باید متناسب با مقیاس مکانی این پدیده‌ها انتخاب شود. به عنوان مثال، شناسایی مؤثر جت‌ها (چشمه بزرگ مقیاس) که ابعاد نصف‌النهاری آن حدود ۵۰۰ تا ۱۰۰۰ کیلومتر است و با در نظر گرفتن تفکیک شبکه  $2/5$  درجه نیاز به پوشش حداقل ۳ تا ۵ نقطه شبکه‌ای می‌باشد. برای تعیین اندازه مخزن در نظر گرفتن دو مورد حائز اهمیت است؛ اول وظیفه این هایپرپارامتر در لایه ادغام که کاهش ابعاد نقشه ویژگی‌هاست، دوم ابعاد ناحیه مورد بررسی که ۱۳ نقطه شبکه در راستای مداری و ۲۵ نقطه شبکه در راستای

جدول ۵. هایپرپارامترها و مقادیر احتمالی آنها برای تنظیم و مقادیر انتخابی بعد از تنظیم.

مقادیر انتخابی	مقادیر احتمالی	هایپرپارامتر
ReLU	ReLU, elu, sigmoid, selu, tanh	تابع فعال‌ساز
$10^{-2}$	$10^{-10}, \dots, 10^{-9}, 10^{-10}$	ضریب تنظیم‌کننده هسته
۱۶	۱۲۸, ۶۴, ۳۲, ۱۶, ۸	اندازه دسته
$10^{-3}$	$10^{-10}, \dots, 10^{-9}, 10^{-10}$	آهنگ یادگیری
$(3 \times 3)$	$(1 \times 1), (2 \times 2), \dots, (10 \times 10)$	اندازه هسته
$(2 \times 2)$	$(1 \times 1), (2 \times 2), \dots, (10 \times 10)$	اندازه مخزن


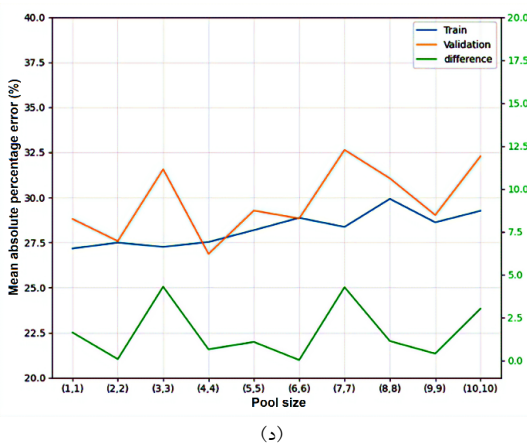

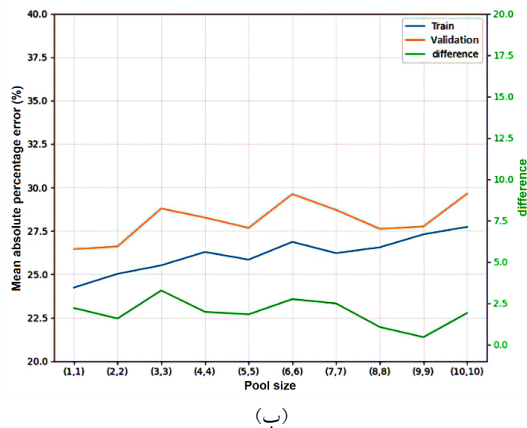


شکل ۲. نمودار تحلیل خطا با استفاده از میانگین درصد مطلق خطا برای هابپرپارامتر آهنگ یادگیری با استفاده از داده‌های سال ۲۰۱۷ (الف)، سال ۲۰۱۸ (ب)، سال ۲۰۲۰ (ج) و سال‌های ۲۰۱۷، ۲۰۱۸ و ۲۰۲۰ (د) برای آموزش. خطای داده‌های آموزش، اعتبارسنجی و اختلاف دو نمودار به ترتیب با رنگ‌های آبی، نارنجی و سبز (با مقادیر نشان داده شده روی محور قائم سمت راست) نشان داده شده‌اند.

بازسازی دامنه و ویژگی‌های طیفی امواج گرانی را تعیین می‌کند. رابطه (۴) ریشه میانگین مربع خطا را اندازه‌گیری می‌کند. این سنجح دقت عددی مدل را با کمی‌سازی میزان انحراف مطلق پیش‌بینی‌ها از مقادیر مرجع مشخص می‌سازد. لازم به ذکر است آزمون معنی‌داری آماری و تحلیل کمی عدم قطعیت، مانند محاسبه بازه اطمینان یا bootstrap، در چارچوب مطالعه حاضر انجام نشده است. بنابراین، نتایج آماری ارائه‌شده باید تنها معیاری برای ارزیابی مقایسه‌ای اولیه در نظر گرفته شوند.

## ۲-۳ چگونگی ارزیابی عملکرد مدل

برای ارزیابی عملکرد CNN یا به طور دقیق‌تر مقایسه نسبی پیکربندی‌های مختلف آن از سه سنجه آماری ضریب همبستگی پیرسون ( $R$ )، ضریب تعیین ( $R^2$ ) و ریشه میانگین مربع خطا ( $RMSE$ ) استفاده شده است. ضریب همبستگی پیرسون میزان قدرت رابطه خطی بین خروجی مدل و داده‌های واقعی را نشان داده و ابزاری است که برای سنجش توانایی مدل در حفظ الگوهای زمانی و مکانی تغییرات استفاده می‌شود. رابطه (۲) نحوه محاسبه این سنجه را نشان می‌دهد. ضریب تعیین که با استفاده از رابطه (۳) محاسبه می‌شود، عملکرد مدل در



شکل ۳. مشابه شکل ۲ اما برای هایپرپارامتر اندازه مخزن.

پیش‌بینی انحراف معیار سه متغیر هدف شار تکانه مطلق، واگرایی افقی باد و سرعت قائم به عنوان شاخص‌های کمی توصیف‌کننده خصوصیات امواج گرانی انجام می‌شود. برای مقایسه خروجی‌های مدل CNN با داده‌های مرجع ERA5، دو رویکرد ارزیابی در نظر گرفته شد. رویکرد اول تأثیر تغییرات حجم داده‌های آموزشی بر عملکرد مدل را با ثابت نگه داشتن تعداد کانال‌های ورودی در ۱۵۰ کانال مورد ارزیابی قرار می‌دهد و در مقابل رویکرد دوم با ثابت نگه داشتن دوره آموزشی در سه سال، تأثیر تغییرات تعداد کانال‌های ورودی بر دقت پیش‌بینی مدل را بررسی می‌کند. با اعمال موارد مذکور، امکان تحلیل جامع عوامل مؤثر بر عملکرد مدل و

$$R = \sum_{t=1}^N \frac{(O_t - \bar{O}_t)(P_t - \bar{P}_t)}{\sqrt{(O_t - \bar{O}_t)^2 (P_t - \bar{P}_t)^2}} \quad (۲)$$

$$R^2 = 1 - \sum_{t=1}^N \frac{(O_t - P_t)^2}{(O_t - \bar{O}_t)^2} \quad (۳)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (O_t - P_t)^2} \quad (۴)$$

در روابط بالا،  $P_t$  مقدار پیش‌بینی شده،  $O_t$  مقدار مشاهداتی در گام زمانی  $t$  و  $N$  تعداد کل گام‌های زمانی را نشان می‌دهند. ارزیابی عملکرد مدل CNN از طریق تحلیل دقت

شناسایی پیکربندی بهینه فراهم می‌آید.

### ۳ نتایج

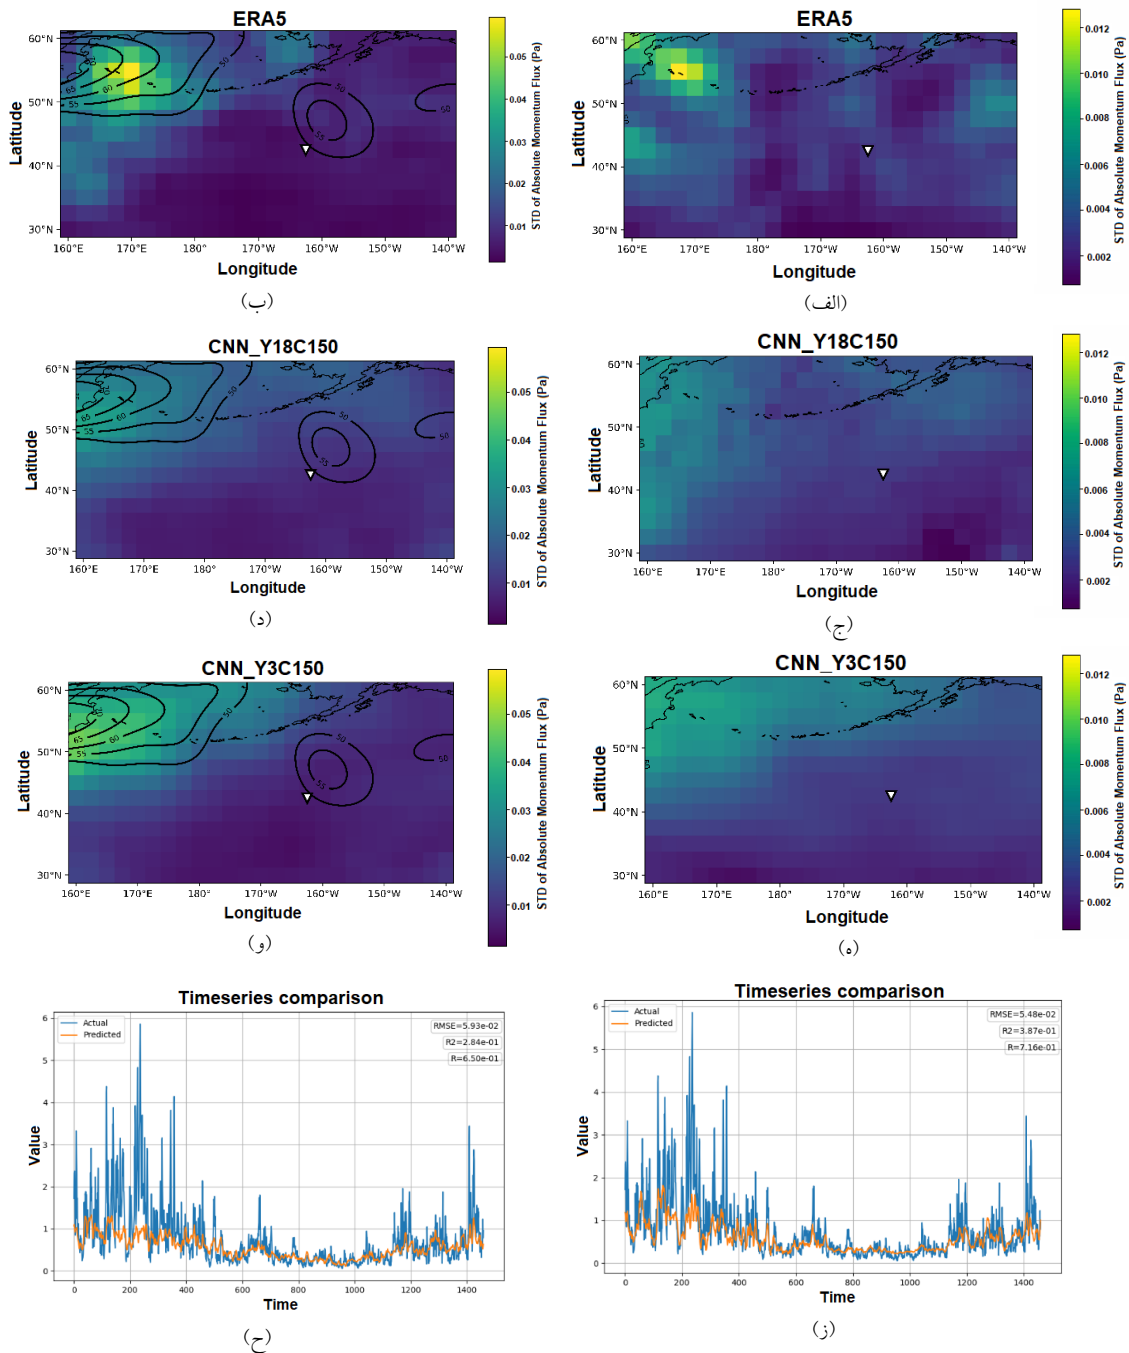
#### ۳-۱ ارزیابی عملکرد CNN در پیش‌بینی شار تکانه مطلق

برای بررسی رویکرد اول، مقایسه‌ای بین ترکیب‌های Y18C150 و Y3C150 انجام شد. شکل ۴ نتایج این مقایسه را برای ماه‌های دسامبر و ژوئن نشان می‌دهد. پربندهای باد افقی ۲۵۰ هکتوپاسکال با مقادیر بیشتر از ۵۰ متر بر ثانیه که در شکل‌ها رسم شده است، معرف فعالیت جریان جتی (ویلیامز و همکاران، ۲۰۰۳) به عنوان یکی از چشمه‌های امواج گرانی در آن ناحیه است.

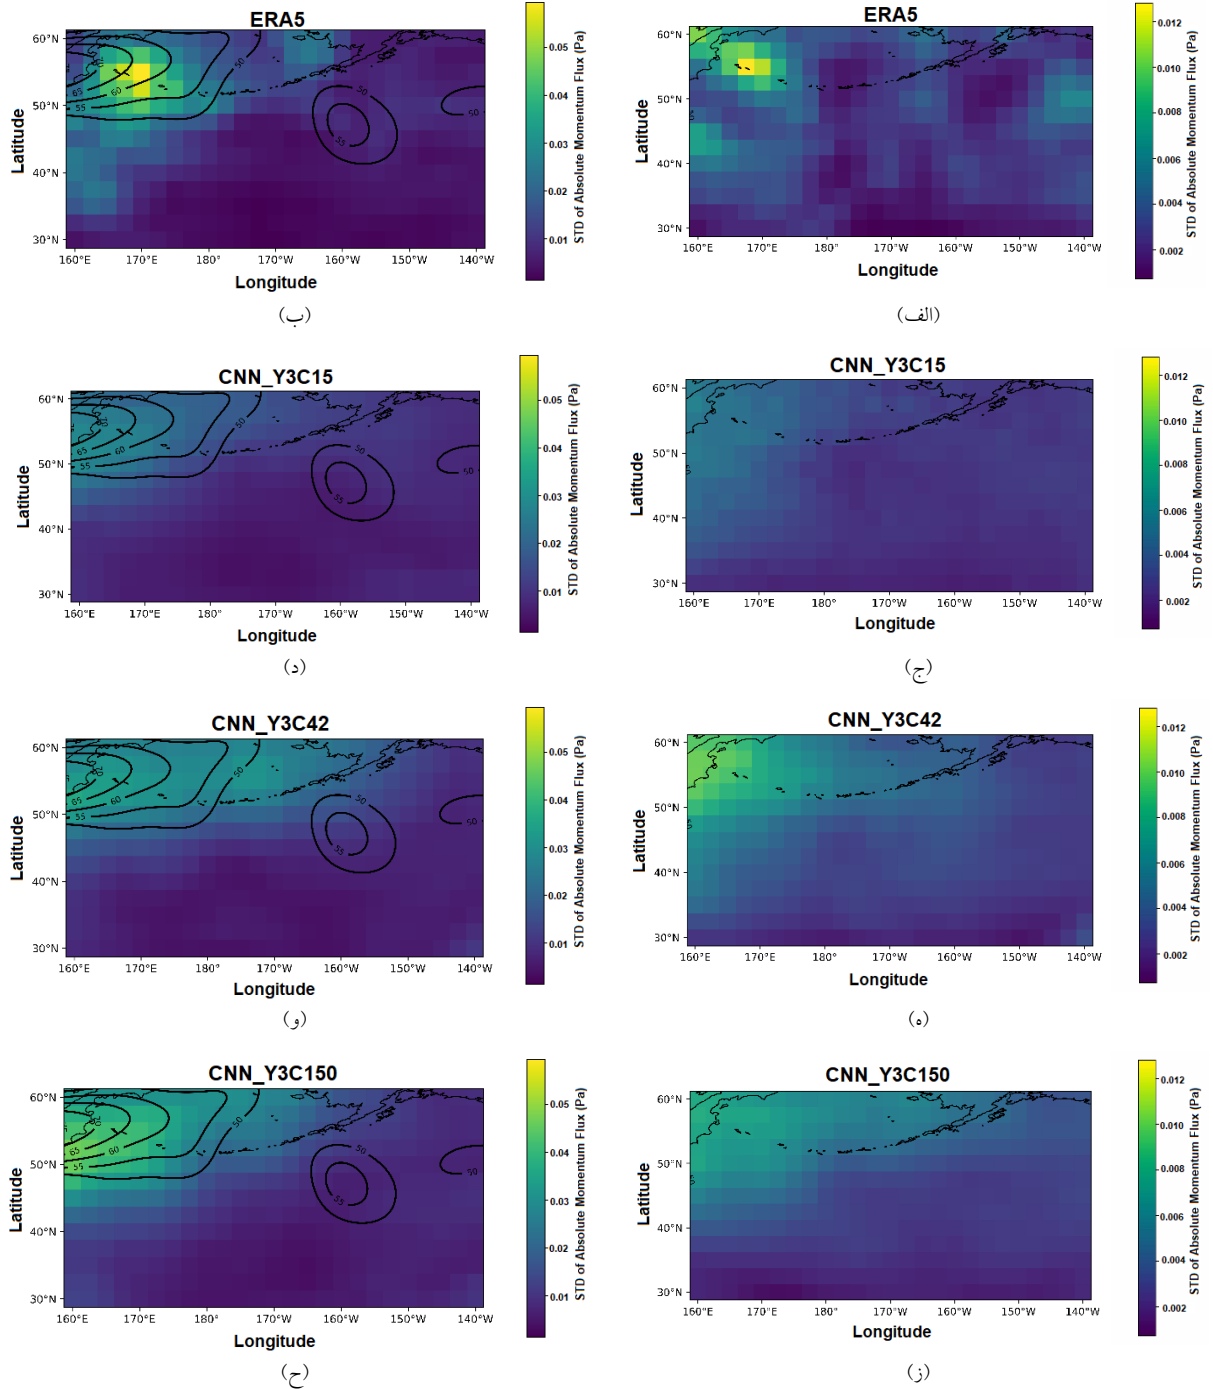
برای ارزیابی عملکرد CNN در بازسازی الگوهای مکانی ERA5 (شکل‌های ۴-الف و ۴-ب) برای انحراف معیار شار تکانه در ماه دسامبر، با تمرکز بر مناطق با فعالیت بالای موج ( $60^{\circ}$  -  $50^{\circ}$  شمالی)، مدل آموزش‌دیده با سه سال داده (شکل ۴-و) قادر است الگو را با دقت بالاتری نسبت به CNN آموزش‌دیده با یک سال داده (شکل ۴-د) به تصویر بکشد. الگوهایی بیش از حد هموار با تنوع مکانی کاهش یافته که در مدل یک‌ساله مشاهده می‌شود، می‌تواند ناشی از آموزش ناکافی برای در نظر گرفتن فعالیت‌های فرین در طول دوره زمستانی باشد. با تحلیل خروجی CNN برای ماه ژوئن مشاهده می‌شود که CNN آموزش‌دیده با یک سال داده (شکل ۴-ج) در حفظ پیوستگی مکانی با کاستی‌هایی روبرو است. این وضعیت با افزایش دوره آموزش به سه سال (شکل ۴-ه) بهبود قابل ملاحظه‌ای پیدا کرده است. با این حال، هر دو مدل در حفظ مقادیر حدی با چالش

روبرو هستند. شکل‌های ۴-ز و ۴-ح سری‌های زمانی در نقطه تصادفی مشخص شده در شکل‌های مربوط به نقشه افقی را نشان می‌دهند. روند مشاهده شده در این نمودارها بر ثبت الگوهای تغییرپذیری فصلی مدل با وجود ضعف در ثبت فعالیت‌های فرین تأکید دارند. بر اساس عملکرد بهتر مدل با سه سال داده آموزش در رویکرد اول، ترکیب‌های با سه سال داده آموزشی برای رویکرد دوم استفاده می‌شوند. شکل ۵ نقشه‌های افقی پیش‌بینی انحراف معیار شار تکانه را برای ترکیب‌های Y3C15، Y3C150 و Y3C42 در مقایسه با ERA5 (شکل‌های ۵-الف و ۵-ب) نشان می‌دهد. با مقایسه ردیف‌های دوم (شکل‌های ۵-ج و ۵-د) و سوم در این شکل می‌توان دریافت که افزایش کانال‌های ورودی از ۱۵ به ۴۲ موجب عملکرد بهتر مدل شده است به طوری که مدل ۴۲ کاناله شدت شار تکانه را در هر دو ماه دسامبر (شکل ۵-و) و ژوئن (شکل ۵-ه) نزدیک‌تر به مقدار واقعی برآورد می‌کند. با وجود عملکرد خوبی که مدل با ۱۵۰ کانال (شکل‌های ۵-ز و ۵-ح) نشان داده است، برخی از ویژگی‌ها را بیش از حد هموار می‌کند.

جدول ۶ میانگین سنج‌های آماری در همه نقاط شبکه ناحیه مورد مطالعه برای ترکیب‌های Y18C150، Y3C150، Y3C15 و Y3C42 را نشان می‌دهد. طبق مقادیر به دست آمده، مدل با ۴۲ کانال ورودی نتایج بهینه‌ای را ارائه می‌دهد به طوری که کمترین ریشه میانگین خطا و همبستگی قابل توجهی (۰/۶۹) را داراست. مقدار ضریب تعیین پایین‌تر مدل با ۱۵۰ کانال در مقایسه با ۴۲ کانال می‌تواند ناشی از اندکی بیش‌برازش باشد.



شکل ۴ مقایسه متغیر هدف انحراف معیار شار تکانه مطلق بین ترکیب‌های Y3C150 و Y18C150 با مدل مرجع ERA5؛ (الف) و (ب) نتایج ERA5، (ج) و (د) نتایج Y18C150، (ه) و (و) نتایج Y3C150 به‌ترتیب برای ماه‌های ژوئن و دسامبر بر روی نقشه افقی منطقه مورد مطالعه، (ز) و (ح) سری زمانی مقدار واقعی (آبی) و برآورد مدل (نارنجی) برای نقطه تصادفی نمایش داده شده در نقشه‌های افقی به‌ترتیب ترکیب‌های Y3C150 و Y18C150. پربندها باد افقی در تراز ۲۵۰ هکتوپاسکال با سرعت بیشتر از ۵۰ متر بر ثانیه را نمایش می‌دهند.



شکل ۵. مقایسه متغیر هدف انحراف معیار شار تکانه مطلق برای ترکیب‌های Y3C15 و Y3C42 و Y3C150 با مدل مرجع ERA5 روی نقشه افقی در ماه‌های دسامبر (ستون چپ) و ژوئن (ستون راست)؛ (الف) و (ب) نتایج ERA5، (ج) و (د) نتایج Y3C15، (و) و (ه) نتایج Y3C42 و (ز) و (ح) نتایج Y3C150.

جدول ۶. میانگین سنجه‌های آماری شامل ریشه میانگین مربع خطا، ضریب همبستگی پیرسون و ضریب تعیین در پیش‌بینی متغیر هدف انحراف معیار شار تکانه مطلق برای ترکیب‌های Y3C15، Y3C42، Y3C150 و Y18C150.

ترکیب				سنجه آماری
Y18C150	Y3C150	Y3C42	Y3C15	ریشه میانگین مربع خطا
۰/۰۷۶	۰/۰۶۹	۰/۰۶۹	۰/۰۷۷	ضریب همبستگی پیرسون
۰/۶۴	۰/۶۹	۰/۶۹	۰/۶۴	ضریب تعیین
۰/۳۴	۰/۴۰	۰/۴۴	۰/۳۳	

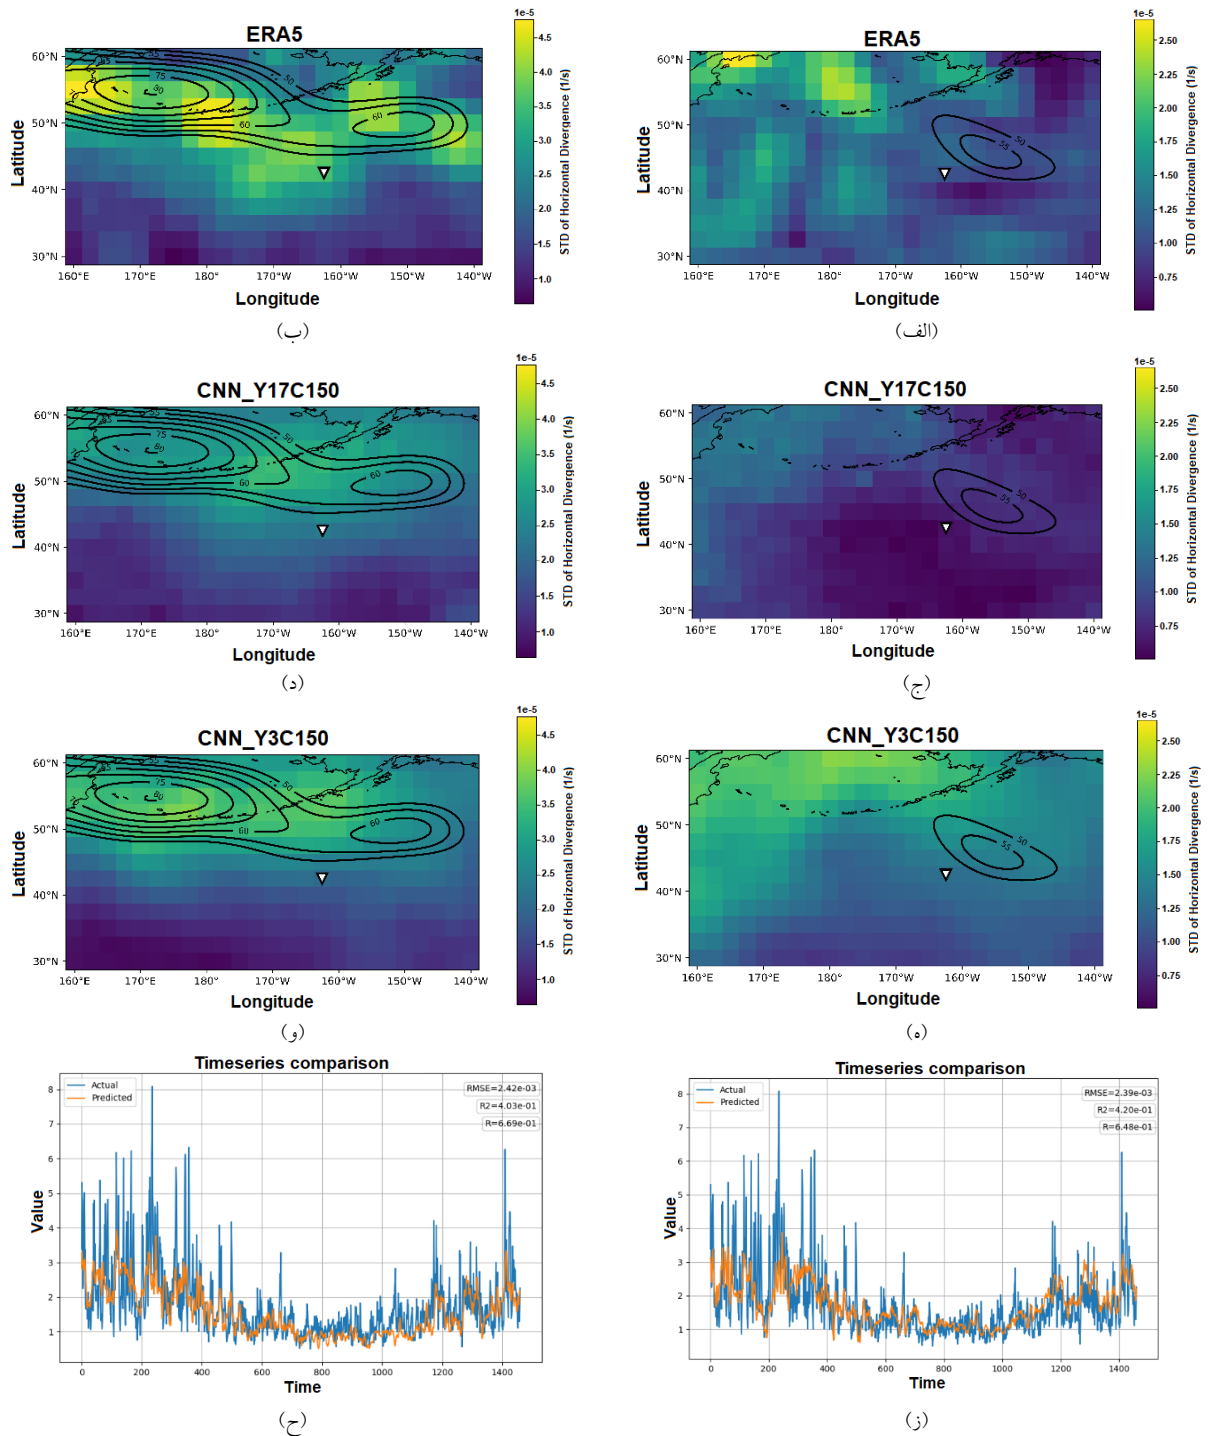
زمانی در شکل‌های ۶-ز و ۶-ح بیانگر آن هستند با این که هر دو مدل الگوهای کلی تغییرپذیری را تشخیص می‌دهند، اما در ثبت رویدادهای فرین با مشکل مواجهند. برای مقایسه عملکرد بین مدل‌های بازتحلیل ERA5 و CNN با کانال‌های ورودی مختلف (رویکرد دوم)، ترکیب‌های Y3C15، Y3C150 و Y3C42 مورد استفاده قرار گرفتند. الگوهای ماه ژانویه (شکل‌های ۷-د، ۷-و و ۷-ح) موفقیت CNN در حفظ توزیع مکانی کلی در پیش‌بینی انحراف معیار واگرایی افقی باد با وجود کم‌برآوردی مناطقی با بیشینه فعالیت را نشان می‌دهند. مدل با ترکیب Y3C150 و ترکیب Y3C15 به ترتیب بیشترین و کمترین تطابق را با الگوی ERA5 (شکل ۷-ب) نشان می‌دهند.

مدل CNN در بازتولید الگوی پراکنده موجود در ماه ژوئن (شکل ۷-الف)، با چالش‌هایی روبرو است. با وجود عملکرد نسبتاً پایین در سه ترکیب بررسی شده، ترکیب‌های Y3C150 (شکل ۷-ز) و Y3C42 (شکل ۷-ه) در بازتولید الگوی مکانی از عملکرد نسبتاً مشابه و بهتری نسبت به ترکیب Y3C15 (شکل ۷-ج) برخوردارند. مقادیر میانگین سنجه‌های آماری در جدول ۷، این نتایج به‌دست آمده را تأیید می‌کند.

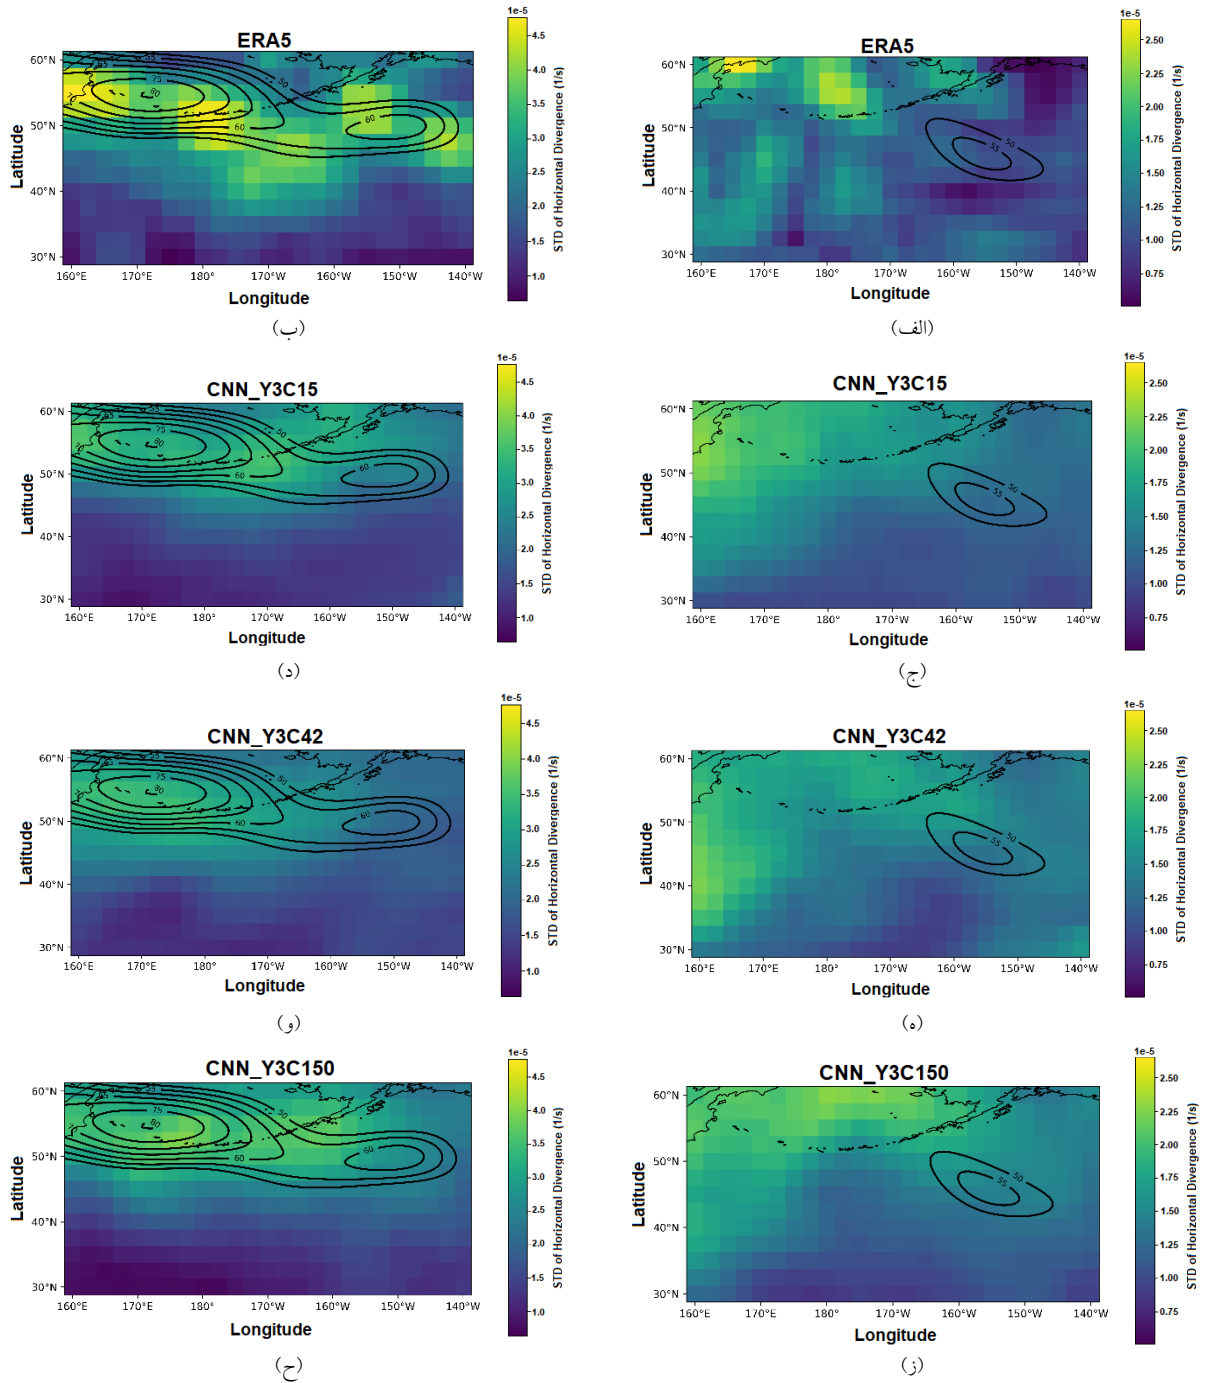
### ۳-۲ ارزیابی عملکرد CNN در پیش‌بینی واگرایی افقی باد

همانند بخش ۳-۱ برای بررسی عملکرد مدل در پیش‌بینی واگرایی افقی باد دو رویکرد در نظر گرفته می‌شود. در شکل ۶ مقایسه‌ای بین ترکیب‌های Y17C150 و Y3C150 برای ماه‌های ژانویه و ژوئن انجام شد. در شکل ۶-الف که یک گام زمانی در ماه ژوئن را نشان می‌دهد، در بخش زیادی از این نواحی واگرایی با شدت متوسط وجود دارد. مدل با یک سال داده آموزش (شکل ۶-ج) در حفظ گرادیدان‌های مکانی با شکست روبرو می‌شود و با سه سال داده آموزش (شکل ۳-ه) با وجود ثبت مقادیر بیشتر در بعضی نقاط، در برآورد مقادیر بالای انحراف معیار واگرایی افقی باد و حفظ گرادیدان مکانی بهتر عمل کرده است.

شکل ۶-ب مراکز با واگرایی زیاد در عرض‌های میانی بین  $45^{\circ}$  تا  $60^{\circ}$  را در ماه ژانویه نمایش می‌دهد. مدل آموزش دیده ۱ ساله (شکل ۶-د) مکان کلی مراکز واگرایی را با شدت کاهش یافته قابل توجهی در مقایسه با ERA5 برآورد می‌کند. در مقابل CNN آموزش دیده با سه سال داده (شکل ۶-و) شدت و ساختار مکانی مرکز واگرایی اصلی را بهتر نشان می‌دهد. نمودارهای سری



شکل ۶. مقایسه متغیر هدف انحراف معیار واگرایی افقی باد بین ترکیب‌های Y3C150 و Y17C150 با مدل مرجع ERA5؛ (الف) و (ب) نتایج ERA5. (ج) و (د) نتایج Y17C150، (ه) و (و) نتایج Y3C150 به ترتیب برای ماه‌های ژوئن و ژانویه بر روی نقشه افقی منطقه مورد مطالعه. (ز) و (ح) سری زمانی مقدار واقعی (آبی) و برآورد مدل (نارنجی) برای نقطه تصادفی نمایش داده شده در نقشه‌های افقی به ترتیب ترکیب‌های Y3C150 و Y17C150. پربندها نشان‌دهنده باد افقی در تراز ۲۵۰ هکتوپاسکال با سرعت بیشتر از ۵۰ متر بر ثانیه هستند.



شکل ۷. مقایسه متغیر هدف انحراف معیار واگرایی افقی باد برای ترکیب‌های Y3C15 و Y3C42 و Y3C150 روی نقشه افقی در ماه‌های ژانویه (ستون چپ) و ژوئن (ستون راست)؛ (الف) و (ب) نتایج ERA5، (ج) و (د) نتایج Y3C15، (و) و (ه) نتایج Y3C42 و (ز) و (ح) نتایج Y3C150.

جدول ۷. میانگین سنجه‌های آماری شامل ریشه میانگین مربع خطا، ضریب همبستگی پیرسون و ضریب تعیین در پیش‌بینی متغیر هدف انحراف معیار واگرایی افقی باد برای ترکیب‌های Y3C15، Y3C42، Y3C150 و Y17C150.

ترکیب				
Y17C150	Y3C150	Y3C42	Y3C15	سنجه آماری
۰/۰۰۲۶	۰/۰۰۲۴	۰/۰۰۲۵	۰/۰۰۲۶	ریشه میانگین مربع خطا
۰/۶۴	۰/۶۵	۰/۶۴	۰/۶۲	ضریب همبستگی پیرسون
۰/۳۲	۰/۳۹	۰/۳۸	۰/۳۲	ضریب تعیین

ترکیب Y3C42 می‌باشد که تقریباً ۹/۸ درصد با ترکیب Y3C150 اختلاف دارد. یافته‌های به‌دست آمده از میانگین سنجه‌های آماری در جدول ۸ با الگوهای نمایش داده شده در شکل ۹ مطابقت دارد. دقت بالای توزیع مقادیر بیشینه سرعت قائم در محدوده عرض جغرافیایی  $50^{\circ}$  تا  $60^{\circ}$  برای ترکیب Y3C42 گواهی بر برتری عملکرد CNN با ۴۲ کانال می‌باشد.

#### ۴-۳ مقایسه روش CNN و جنگل تصادفی

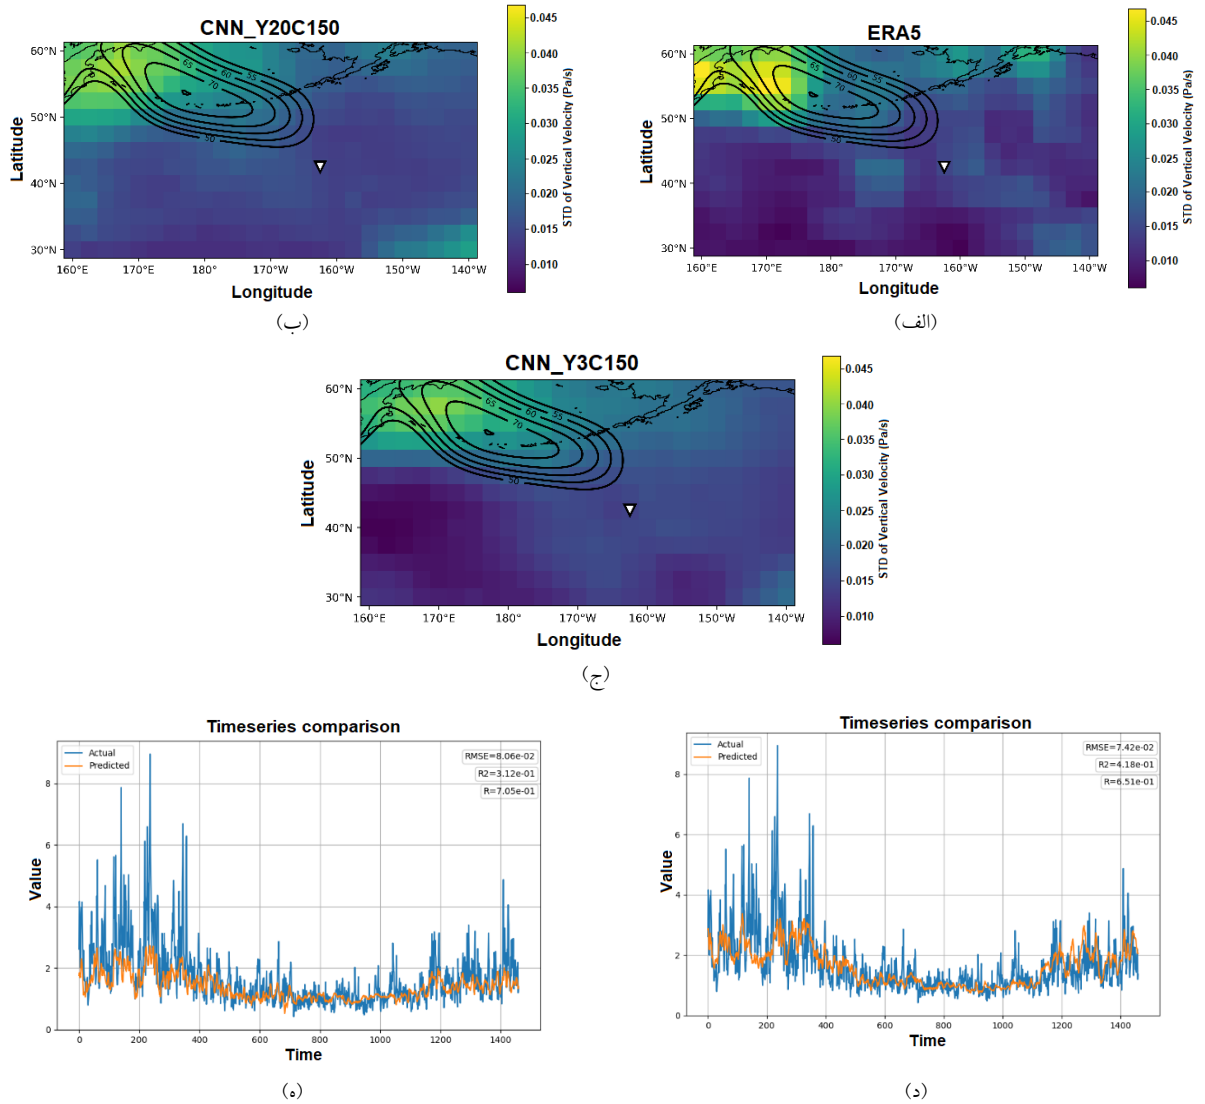
با انجام ارزیابی عملکرد CNN در بخش‌های ۳-۱ تا ۳-۳، در این بخش مقایسه کلی بین روش شبکه عصبی هم‌آمیختی و روش جنگل تصادفی استفاده شده در مطالعه امیرامجدی و همکاران (۲۰۲۳) انجام می‌گیرد. در مطالعه مذکور میزان بازسازی امواج گرانی از جریان تفکیک‌پذیر با تفکیک پایین ارزیابی شد و متغیرها برای آموزش مدل بر اساس سهم آنها در برآورد امواج گرانی رتبه‌بندی شد. به دلیل محدودیت‌های ابزاری در انجام تحقیق حاضر، شرایط یکسانی با مطالعه امیرامجدی و همکاران (۲۰۲۳) در نظر گرفته نشد. بنابراین امکان مقایسه جامع این دو روش ممکن نیست و مقایسه فعلی فقط برای سنجش توانایی CNN در حد پیاده‌شده در پژوهش فعلی است.

تحلیل سری‌های زمانی در شکل‌های ۴ تا ۶ نشان می‌دهد مدل CNN همانند مدل جنگل تصادفی توانایی مناسبی در تشخیص دوره‌های فعالیت امواج گرانی دارد

#### ۳-۳ ارزیابی عملکرد CNN در پیش‌بینی سرعت قائم

همانند بخش‌های قبل، دو رویکرد برای ارزیابی عملکرد CNN در پیش‌بینی سرعت قائم در نظر گرفته شد. شکل ۸ نتایج به‌دست آمده از رویکرد اول را برای ماه آوریل نشان می‌دهد. مقایسه نقشه‌های افقی به‌دست آمده از خروجی CNN با ERA5 (شکل ۸-الف) نشان می‌دهد که عملکرد CNN هنگامی که با سه سال داده آموزش می‌بیند (شکل ۸-ج) نسبت به آموزش با یک سال داده (شکل ۸-ب) بهبود پیدا کرده است. با مقایسه نمودارهای سری زمانی در شکل‌های ۸-د و ۸-ه، هر دو مدل Y3C150 و Y20C150 در ثبت رویدادهای فرین با چالش مواجه می‌شوند اما توانایی ثبت الگوهای کلی تغییرپذیری فصلی در آنها دیده می‌شود.

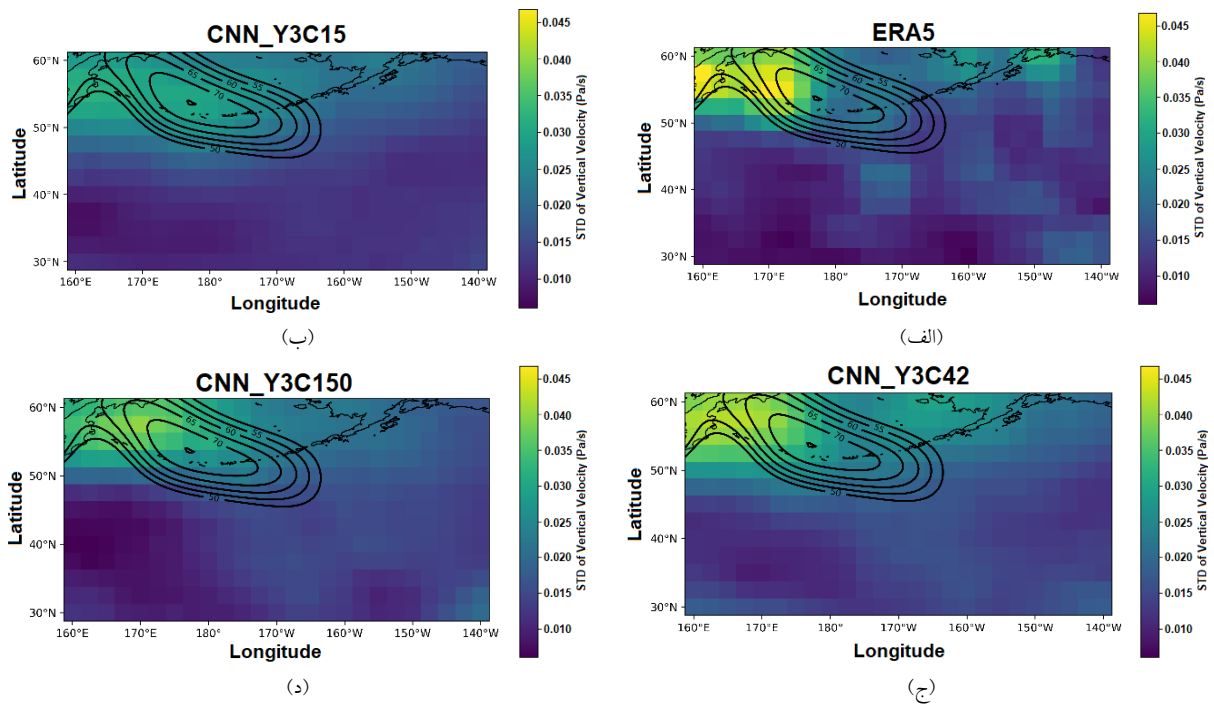
با بررسی رویکرد دوم، عملکرد مدل در پیش‌بینی انحراف معیار سرعت قائم در مواجهه با تعداد متفاوت از متغیرهای توضیحی ارزیابی شد و نتایج در شکل ۹ نشان داده شده است. با مقایسه نقشه‌های افقی، همه مدل‌های CNN با موفقیت الگوی کلی در شکل ۹-الف را ثبت می‌کنند اما مدل با ترکیب Y3C15 (شکل ۹-ب) عملکرد پایین‌تری نسبت به ترکیب‌های Y3C150 (شکل ۹-د) و Y3C42 (شکل ۹-ج) نشان داده است. برای ترکیب‌های Y3C150 و Y3C42 سنجه‌های آماری نسبتاً مشابهی به‌دست آمد. بیشترین مقدار ضریب تعیین برای



شکل ۸. مقایسه متغیر هدف انحراف معیار سرعت قائم بین ترکیب‌های Y20C150 و Y3C150 با مدل مرجع ERA5؛ (الف) نتیجه ERA5، (ب) نتیجه Y20C150، (ج) نتیجه Y3C150 برای ماه آوریل بر روی نقشه افقی منطقه مورد مطالعه. (د) و (ه) سری زمانی مقدار واقعی (آبی) و برآورد مدل (نارنجی) برای نقطه تصادفی نمایش داده شده در نقشه‌های افقی به ترتیب ترکیب‌های Y20C150 و Y3C150. پرندها نشان‌دهنده باد افقی در تراز ۲۵۰ هکتوپاسکال با سرعت بیشتر از ۵۰ متر بر ثانیه هستند.

حجم داده‌های آموزش از یک سال به سه سال است. از این رو می‌توان نتیجه گرفت که تغذیه مدل با مجموعه داده‌های گسترده‌تر در بازسازی دقیق‌تر ویژگی‌های طیفی امواج مؤثر است.

اما در بازسازی دقیق تناوب‌ها و حالت‌های فرین با چالش مواجه است. مقایسه نقشه‌های افقی در شکل‌های ۴ تا ۶ و همچنین تحلیل کمی شاخص‌های ارزیابی (جدول‌های ۶ تا ۸) حاکی از ظرفیت CNN در بهبود کارایی با افزایش



شکل ۹. مقایسه انحراف معیار سرعت قائم برای ترکیب‌های Y3C15، Y3C42 و Y3C150 روی نقشه افقی در ماه آوریل. (الف) نتیجه ERA5، (ب) نتیجه Y3C15، (ج) نتیجه Y3C42 و (د) نتیجه Y3C150.

جدول ۸. میانگین سنجه‌های آماری شامل ریشه میانگین مربع خطا، ضریب همبستگی پیرسون و ضریب تعیین در پیش‌بینی متغیر هدف انحراف معیار سرعت قائم برای ترکیب‌های Y3C15، Y3C42، Y3C150 و Y20C150.

ترکیب				سنجه آماری
Y20C150	Y3C150	Y3C42	Y3C15	ریشه میانگین مربع خطا
۰/۰۹۰	۰/۰۸۵	۰/۰۸۳	۰/۰۹۱	ضریب همبستگی پیرسون
۰/۶۸	۰/۷۱	۰/۷۱	۰/۶۷	ضریب تعیین
۰/۳۷	۰/۴۱	۰/۴۵	۰/۳۷	

داده است. هم‌سو بودن نسبی این یافته‌ها اهمیت متغیر باد افقی را نشان می‌دهد که می‌تواند اطلاعات ارزشمندی برای مدل فراهم کند.

در مدل جنگل تصادفی با افزایش متغیرهای توضیحی تا حد بهینه عملکرد مدل بهبود یافت، اما فراتر از آن تأثیر قابل ملاحظه‌ای دیده نشد. مدل CNN با ۴۲ کانال قادر به درک ارتباط‌های مؤثری برای شناسایی ویژگی‌های امواج گرانی است اما این توانایی با در نظر گرفتن ۱۵۰ کانال رشد چشم‌گیری نداشته است. نتایج نسبتاً مشابه که

در مطالعه امیرامجدی و همکاران (۲۰۲۳) با استفاده از روش‌های میانگین کاهش دقت و میانگین کاهش ناخالصی اهمیت متغیرها در سطوح جو مورد ارزیابی قرار گرفت و نشان داده شد که سرعت باد افقی در پوشش سپهر زیرین از اهمیت بالایی برخوردار است. در آموزش مدل CNN، ترکیب Y3C15 (متغیر باد افقی در ۱۵ تراز فشاری)، با وجود عملکرد پایین در همه سنجه‌های آماری، نتایج قابل مقایسه‌ای با ترکیب‌های دیگر نشان

بیشترین دقت و در عین حال کمترین پیچیدگی محاسباتی، آموزش و آزمون مدل انجام شد و در نتیجه سه متغیر کلیدی در شناسایی امواج گرانی شامل واگرایی افقی باد، شار تکانه مطلق و سرعت قائم پیش‌بینی شدند. با منظور کردن انحراف معیار این متغیرها، نوسانات و تغییرپذیری آنها برای ارزیابی شدت و گستردگی فعالیت امواج گرانی، مورد بررسی قرار گرفت. برای ارائه تصویری روشن از توانمندی CNN، سه سنجه آماری ریشه میانگین مربع خطا، ضریب تعیین و ضریب همبستگی پیرسون استفاده شدند.

نتایج به دست آمده از دو دیدگاه حجم داده‌ها و متغیرهای توضیحی قابل تحلیل است. کیفیت خروجی مدل در پیش‌بینی سه متغیر هدف با افزایش حجم داده‌ها از یک سال به سه سال بهبود می‌یابد. ترکیب‌های دارای داده‌های آموزشی بیشتر قابلیت بهتری در بازسازی الگوهای مکانی پیچیده و تشخیص فعالیت‌های موج گرانی نشان دادند. این ترکیب‌ها توانستند ساختار مکانی و شدت متغیرها را با دقت بالاتری حفظ کنند و میزان خطا در مناطق با گرادان‌های شدید را کاهش دهند. CNN با یک سال داده الگوهای بیش از حد هموار با تنوع مکانی کاهش یافته‌ای تولید می‌کند که بیانگر آموزش ناکافی مدل در ثبت الگوی امواج است. در مقابل مدل سه‌ساله با مقدار ضریب تعیین بالاتر نشان می‌دهد CNN در بازسازی دامنه و ویژگی‌های امواج گرانی عملکرد بهتری دارد. برآورد نسبتاً بهتر مقادیر حدی در مدل آموزش دیده با سه سال داده نسبت به یک سال داده، تأثیر مستقیم داده‌های آموزشی بیشتر بر عملکرد مدل را نشان می‌دهد. بنابراین گستردگی داده‌ها پایداری بالاتری در آموزش مدل ایجاد می‌کند و به CNN امکان یادگیری الگوهایی با پیچیدگی بیشتر و تعمیم بهتر به شرایط جدید را می‌دهد.

کانال‌های مختلف بر خروجی CNN نتایج قابل تأملی

در مواجهه CNN با ترکیب‌های Y3C150 و Y3C42 حاصل شد، تأیید می‌کند متغیرهای رتبه‌بندی شده بر اساس روش میانگین کاهش ناخالصی در مطالعه امیرامجدی و همکاران (۲۰۲۳) دارای بیشترین اهمیت در بازسازی سیگنال امواج گرانی هستند. این نتایج همچنین شاهدهی بر توانایی ذاتی مدل CNN در شناسایی و حذف خودکار متغیرهای کم‌اهمیت به واسطه وجود تابع فعال‌ساز مناسب می‌باشد.

#### ۴ جمع‌بندی نتایج و نتیجه‌گیری

پژوهش حاضر به ارزیابی عملکرد روش شبکه عصبی هم‌آمیختی به منزله مدلی ناپارامتری در بازسازی امواج گرانی ناکوهساری اختصاص داشته است. به دلیل تمرکز این پژوهش بر یک ناحیه اقیانوسی در عرض‌های میانی نیمکره شمالی، نتایج باید در چارچوب شرایط دینامیکی همان منطقه تفسیر شوند. انتخاب این ناحیه با هدف تمرکز بر امواج گرانی ناکوهساری و کاهش اثر چشمه‌های کوهساری انجام شد؛ بررسی قابلیت تعمیم مدل به سایر مناطق جغرافیایی، فصل‌ها و رژیم‌های دینامیکی متفاوت، نیازمند پژوهش جداگانه‌ای در تکمیل کار فعلی است.

دو مجموعه متغیر مورد استفاده در این تحقیق از داده‌های بازتحلیل ERA5 استخراج شدند. متغیرهای توضیحی که نماینده چشمه‌های امواج گرانی هستند از داده‌های با تفکیک پایین با فاصله شبکه  $2/5^\circ \times 2/5^\circ$  در ۱۵ تراز فشاری انتخاب شدند. متغیرهای هدف به منظور کمی‌سازی مشخصه‌های امواج گرانی از داده‌های با تفکیک بالا  $0/25^\circ \times 0/25^\circ$  در تراز فشاری ۱۰۰ هکتوپاسکال تعریف شدند.

برای ارزیابی کارایی روش CNN ترکیب‌هایی بر اساس دو رویکرد حجم داده‌ها و نوع کانال‌های ورودی تعیین شد. پس از آماده‌سازی مدل برای رسیدن به

نتایج ارائه شده باید صرفاً برای ارزیابی اولیه قابلیت CNN در بازسازی الگوهای غالب امواج گرانی تفسیر شوند و نه به منزله اثبات قطعی برتری این معماری نسبت به مدل‌های ساده‌تر. در این ارزیابی اولیه، روش CNN با محدودیتی روبرو بوده است. این روش ضعف‌هایی در ثبت و برآورد فعالیت‌های شدید امواج گرانی در پیش‌بینی هر سه متغیر هدف نشان داده است. در برخی موارد، به ویژه در مناطق با بیشینه فعالیت، تمایل به کم‌برآوردی دیده می‌شود که این مسئله در پیش‌بینی انحراف معیار سرعت قائم حتی با ترکیب سه‌ساله نیز قابل توجه است. همان‌طور که افزایش حجم داده از یک سال به سه سال تا حدودی به بهبود عملکرد مدل در برآورد فعالیت شدید امواج گرانی انجامید، به نظر می‌رسد گسترش بیشتر حجم داده و گنجاندن نواحی اقیانوسی متنوع‌تر بتواند مشکل کم‌برآوردی در مناطق با بیشینه فعالیت را کاهش دهد. برای عملیاتی‌سازی این روش در مدل‌های اقلیمی، انجام آزمایش‌های تکمیلی با مجموعه داده‌های گسترده‌تر، ارزیابی آماری دقیق‌تر، محاسبه بازه اطمینان سنج‌ها، استفاده از روش‌هایی مانند bootstrap و مقایسه منصفانه با مدل‌های خط‌مبنا تحت شرایط آزمایشی یکسان ضروری خواهد بود.

### مراجع

- Amiramjadi, M., Mohebalhojeh, A. R., Mirzaei, M., Zulicke, C., & Plougonven, R. (2020). The spatiotemporal variability of nonorographic gravity wave energy and relation to its source functions. *Monthly Weather Review*, 148, 4837–4857.
- Amiramjadi, M., Plougonven, R., Mohebalhojeh, A. R., & Mirzaei, M. (2023). Using machine learning to estimate nonorographic gravity wave characteristics at source levels. *Journal of the Atmospheric Sciences*, 80, 419–440.
- Bosart, L. F., & Cussen Jr., J. P. (1973). Gravity wave phenomena accompanying East Coast cyclogenesis. *Monthly Weather Review*, 101, 446–454.
- Bosart, L. F., Bracken, W. E., & Seimon, A.

را نشان دادند. با وجود عملکرد خوب مدل ۱۵۰ کاناله در بازتولید الگوهای مکانی به‌ویژه در پیش‌بینی واگرایی افقی باد، نشانه‌هایی از هموارسازی بیش از حد ویژگی‌ها نمایان شده است. CNN با ۱۵ کانال، در پیش‌بینی انحراف معیار هر سه متغیر هدف تمایل به کم‌برآوردی مقادیر را داشته است. در پیش‌بینی سرعت قائم با مدل ۴۲ کاناله، مقدار ضریب تعیین ۹/۸ درصد بیشتر از مدل ۱۵۰ کاناله به دست آمد. مدل با استفاده از ترکیب‌هایی که ۴۲ کانال داشتند، در پیش‌بینی شار تکانه مطلق بهترین سنج‌های آماری را ارائه داد. با توجه به پایداری، عدم بیش‌برازش و دقت قابل قبول در مدل با ۴۲ کانال، ترکیب‌هایی با ۴۲ کانال می‌توانند انتخابی بهینه برای پیش‌بینی متغیرهای هدف باشند.

همان‌طور که در بخش ۳-۴ اشاره شد، همسانی نتایج در ترکیب‌های Y3C42 و Y3C150، اهمیت بالای متغیرهای رتبه‌بندی شده در بازسازی سیگنال امواج گرانی در مطالعه امیرامجدی و همکاران (۲۰۲۳) را تأیید می‌کند. این نتایج نیز توانمندی مدل CNN در پالایش متغیرهای با وزن کمتر را نمایان می‌کند. بر خلاف روش‌های سنتی پارامترسازی و جنگل تصادفی که فقط اثرات انتشار قائم امواج گرانی را در نظر می‌گیرند، روش CNN انتشار افقی را نیز لحاظ می‌کند که این امر به درک جامعی از رفتار این پدیده‌ها منجر می‌شود. نتایج قابل مقایسه CNN هنگام آموزش با متغیرهای توضیحی باد افقی در تمام سطوح فشاری بیان‌کننده عملکرد بالای الگوریتم در استخراج الگوهای مهم صرفاً با این تعداد کم از داده‌های ورودی می‌باشد.

در پایان، شایان ذکر است که تعیین معنی‌داری اختلاف بین پیکربندی‌ها، تحلیل کمی عدم قطعیت و مقایسه مستقیم با مدل‌های خط‌مبنا ساده، مانند میانگین اقلیمی متغیرهای هدف یا وایزش خطی، نیازمند پژوهش‌های جامع‌تری فراتر از کار ارائه شده در اینجا است. بنابراین،

- (1998). A study of cyclone mesoscale structure with emphasis on a large-amplitude inertia-gravity wave. *Monthly Weather Review*, 126, 1497–1527.
- Buss, S., Hertzog, A., Hostettler, C., Bui, T. P., Lüthi, D., & Wernli, H. (2004). Analysis of a jet stream induced gravity wave associated with an observed ice cloud over Greenland. *Atmospheric Chemistry and Physics*, 4, 1183–1200.
- Dörnbrack, A., Leutbecher, M., Kivi, R., & Kyrö, E. (1999). Mountain-wave-induced record low stratospheric temperatures above northern Scandinavia. *Tellus A: Dynamic Meteorology and Oceanography*, 51, 951–963.
- Eliassen, A., & Palm, E. (1961). On the transfer of energy in stationary mountain waves. *Geophysics*, 22, 1–23.
- Espinosa, Z. I., Sheshadri, A., Cain, G. R., Gerber, E. P., & DallaSanta, K. J. (2022). Machine learning gravity wave parameterization generalizes to capture the QBO and response to increased CO<sub>2</sub>. *Geophysical Research Letters*, 49, e2022GL098174.
- Gupta, A., Sheshadri, A., Roy, S., & Anantharaj, V. (2025). Offline performance of a nonlocal deep learning parameterization for climate model representation of atmospheric gravity waves. *Journal of Advances in Modeling Earth Systems*, 17, e2025MS004977.
- Hardiman, S. C., Scaife, A. A., van Niekerk, A., Prudden, R., Owen, A., Adams, S. V., et al. (2023). Machine learning for nonorographic gravity waves in a climate model. *Artificial Intelligence for the Earth Systems*, 2, e220081.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146, 1999–2049.
- Hitchman, M. A., Maaskant, W., van der Plas, J., Simmons, C. J., & Stratemeier, H. (1999). Cooperative Jahn–Teller interactions in dynamic Copper (II) complexes. Temperature dependence of the crystal structure and EPR spectrum of deuterated ammonium Copper (II) sulfate hexahydrate. *Journal of the American Chemical Society*, 121, 1488–1501.
- Holton, J. (2004). *An Introduction to Dynamic Meteorology*, Elsevier Academic Press., 531 pp.
- Holton, J., Beres, J., & Zhou, X. (2002). On the vertical scale of gravity waves excited by localized thermal forcing, *Journal of the Atmospheric Sciences*, 59, 2019–2023
- Kim, Y. J., Eckermann, S. D., & Chun, H.-Y. (2003). An overview of the past, present and future of gravity-wave drag parametrization for numerical climate and weather prediction models. *Atmosphere–Ocean*, 41, 65–98.
- Koch, S. E. & Dorian, P. B. (1988). A mesoscale gravity wave event observed during CCOPE. Part III: Wave environment and probable source mechanisms. *Monthly Weather Review*, 116, 2570–2592.
- Kühl, S., Dörnbrack, A., Wilms-Grabe, W., Sinnhuber, B.M., Platt, U., & Wagner, T. (2004). Observational evidence of rapid chlorine activation by mountain waves above northern Scandinavia. *Journal of Geophysical Research: Atmospheres*, 109, D22309, doi:10.1029/2004JD004797.
- Matsuoka, D., Watanabe, S., Sato, K., Kawazoe, S., Yu, W., & Easterbrook, S. (2020). Application of deep learning to estimate atmospheric gravity wave parameters in reanalysis data sets. *Geophysical Research Letters*, 47, e2020GL089436.
- Mirzaei, M., Zülicke, C., Mohebalhojeh, A. R., Ahmadi-Givi, F., & Plougonven, R. (2014). Structure, energy, and parameterization of inertia-gravity waves in dry and moist simulations of a baroclinic wave life cycle. *Journal of the Atmospheric Sciences*, 71, 2390–2414.
- Santurkar, S., Tsipras, D., Ilyas, A., Madry, A. (2018). How does batch normalization help optimization? In: *Advances in Neural Information Processing Systems*, NeurIPS, 31, 2483–2493.
- Sato, K., Watanabe, S., Kawatani, Y., Tomikawa, Y., Miyazaki, K., & Takahashi, M. (2009). On the origins of mesospheric gravity waves. *Geophys. Res. Lett.*, 36, L19801.
- Sato, K., Tateno, S., Watanabe, S., & Kawatani, Y. (2012). Gravity wave characteristics in the Southern Hemisphere revealed by a high-resolution middle-atmosphere general circulation model. *J. Atmos. Sci.*, 69, 1378–1396.
- Shapiro, M. A. (1981). Frontogenesis and geostrophically forced secondary circulations in the vicinity of jet stream-frontal zone systems., *Atmospheric Science*, 38, 954–973.
- Warner, C. D., & McIntyre, M. E. (1996). On the propagation and dissipation of gravity wave spectra through a realistic middle atmosphere., *Journal of the Atmospheric Sciences*, 53, 3213–3235.

Warner, T. T. (2010). Numerical Weather and Climate Prediction., Cambridge University Press, 523 pp.  
Williams, P. D., Read, P. L., & Haine, T. W. N.

(2003). Spontaneous generation and impact of inertia-gravity waves in a stratified, two-layer shear flow. Geophysical Research Letters, 30, 2255, doi:10.1029/2003GL018498, 24.

## Application of convolutional neural network for source parameterization of inertia–gravity waves at lower stratosphere

Elahe Khanlari<sup>1</sup>, Ali Reza Mohebalhojeh<sup>2</sup>, Mohammad Mirzaei<sup>3\*</sup> and Mozghan Amiramjadi<sup>4</sup>

<sup>1</sup> M.Sc., Institute of geophysics, University of Tehran, Tehran, Iran

<sup>2</sup> Professor, Institute of geophysics, University of Tehran, Tehran, Iran

<sup>3</sup> Associate Professor, Institute of geophysics, University of Tehran, Tehran, Iran

<sup>4</sup> Researcher, Karlsruhe Institute of Technology, Karlsruhe, Germany

(Received: 16 May 2026, Accepted: 09 June 2026)

### Summary

Explicit representation of inertia–gravity waves in general circulation models is not yet feasible due to their small scale relative to the spatial resolution of the models. With enhancement of technology in recent decades, there has been a significant interest in applying machine learning (ML) to improve the performance of general circulation models (GCMs). This research investigates the performance of Convolutional Neural Network (CNN) as a non-parametric model in reconstructing nonorographic gravity waves in mid-latitude oceanic regions using the ERA5 reanalysis data. This data set with low-resolution of  $2.5^\circ \times 2.5^\circ$  for predictor variables and with high-resolution of  $0.25^\circ \times 0.25^\circ$  for predictand variables have been selected to quantify the characteristics of gravity waves. The explanatory variables employed at 15 pressure levels are representative of gravity waves sources. These variables include temperature gradient, potential vorticity, potential vorticity anomaly, relative vorticity, pressure vertical velocity, and horizontal wind velocity. On the other hand, for the gravity-wave activity in the lowermost stratosphere, the target variables have been chosen as the standard deviation of three key parameters: horizontal divergence, absolute momentum flux, and vertical velocity at the 100 hPa pressure level. Two approaches have been evaluated; the first approach examined the effect of training data volume while keeping the number of input channels constant at 150 channels, and the second one emphasizes optimizing the number of input channels while keeping the training period constant at three years. The second approach employed three distinct configurations characterized by varying numbers of input channels: 150 channels encompassing all explanatory variables, 15 channels restricted to horizontal wind velocity only, and 42 channels selected based on the most relevant explanatory variables in reconstructing gravity waves. Data from three years—2017, 2018, and 2020—were selected for the training and validation datasets, while data from 2019 were employed for the testing dataset.

The results obtained from predicting the standard deviation of three target variables show that increasing the volume of training data in first approach is able to preserve the spatial structure and intensity of variables more effectively. Examining the results of the second approach showed that the model has low performance using 15 input channels, yet has comparable results with 42 and 150 input channels in expressing the importance of horizontal wind variable to predict target variables. The relatively similar results in the 42- and 150-channel combinations indicate the inherent capability of CNN in identifying less-important variables using appropriate activation function. Despite limitations in predicting extreme events, CNN can detect periods of gravity waves activity properly and potentially reconstructs inertia–gravity waves well. Despite the advantages of using CNN in gravity wave reconstruction, conducting more comprehensive experiments could prepare CNN for operational implementation within climate models.

**Keywords:** Inertia–gravity waves, Convolutional Neural Network, parameterization, lower stratosphere, nonorographic gravity waves