

شناسایی نقاط تغییر در سری زمانی جابجایی ناشی از تداخل سنجی راداری با استفاده از شبکه عصبی پرسپترون چندلایه: (مطالعه موردی قاره اروپا)

سید آریا فخری^۱، مهران ستاری^{۲*}

۱- دانشجوی دکتری فتوگرامتری، دانشکده مهندسی عمران و حمل و نقل، دانشگاه اصفهان

۲- استادیار دانشکده مهندسی عمران و حمل و نقل، دانشگاه اصفهان

تاریخ دریافت مقاله: ۱۴۰۳/۰۹/۱۳ تاریخ پذیرش مقاله: ۱۴۰۳/۱۱/۰۶

چکیده

سطح زمین به دلیل وقوع پدیده‌های طبیعی مانند زلزله و آتش‌فشان و همچنین فعالیت‌های انسانی نظیر استخراج آب‌های زیرزمینی و معادن، همواره در حال تغییر و جابجایی است. در سال‌های اخیر، افزایش آگاهی از خطرات ناشی از حرکات زمین، منجر به تقاضای بیشتر جهت دستیابی به اطلاعات جامع و قابل اعتماد درباره این جابجایی‌ها شده است. تاکنون روش‌های گوناگونی به منظور تخمین جابجایی سطح زمین ارائه شده‌اند که از جمله مهم‌ترین منابع جهت برآورد میزان جابجایی سطح زمین در طول زمان، آنالیز سری زمانی جابجایی حاصل از تداخل‌سنجی راداری است. با این حال، پس‌پردازش داده‌های سری زمانی کمتر مورد توجه قرار گرفته است. کارآمدترین روش‌های پس‌پردازش آنالیز سری زمانی، شناسایی نقاط تغییر در روند سری زمانی است. به نحوی که با شناسایی نقطه تغییر در سری زمانی می‌توان علاوه بر استخراج اطلاعات مکانی، نتایج حاصل را نیز در بعد زمان تحلیل نمود. این پژوهش به بررسی روشی جهت شناسایی نقاط تغییر سری زمانی جابجایی‌های زمین ناشی از فعالیت‌های زمین‌شناسی و انسانی در قاره اروپا می‌پردازد و از داده‌های سامانه پایش حرکت سطح‌زمین در قاره اروپا (EGMS) بهره می‌برد. با توجه به چالش‌های موجود در تشخیص نقاط تغییر در سری زمانی جابجایی حاصل از تداخل‌سنجی از قبیل نویز و رفتارهای فصلی، استفاده از شبکه عصبی پرسپترون چندلایه به عنوان یکی از ساده‌ترین و پرکاربردترین شبکه‌های عصبی در یادگیری ماشین می‌تواند جهت شناسایی الگوهای پیچیده و روابط غیرخطی مؤثر باشد. نتایج به دست آمده نشان‌دهنده دقت بالای ۹۷ درصد در شناسایی نقاط تغییر و توانایی مدل در تشخیص تغییرات با دقت مناسب است که می‌تواند به درک بهتر تغییرات زمین کمک کند. همچنین قابلیت‌های مدل پیشنهادی در تحلیل داده‌های جابجایی و شناسایی تغییرات مورد بررسی قرار گرفته و نتایج حاصل با روش‌های متداول مقایسه شده است. بر اساس این مقایسه، روش پیشنهادی از نظر دقت، عملکرد بسیار بهتری نسبت به روش‌های آماری دارد و همچنین در مقایسه با سایر روش‌های یادگیری عمیق، حدود ۹ برابر هزینه محاسباتی کاهش یافته است.

کلیدواژه‌ها: تداخل‌سنجی راداری، شناسایی نقطه تغییر، شبکه‌های عصبی پرسپترون چندلایه، سری زمانی، سامانه EGMS.

* نویسنده مکاتبه‌کننده: اصفهان، دانشگاه اصفهان، دانشکده عمران و حمل و نقل، گروه مهندسی نقشه‌برداری.

تلفن: ۰۹۱۳۱۵۵۳۳۷

۱- مقدمه

در دهه‌های اخیر، سنجش‌ازدور راداری به‌عنوان یک ابزار قدرتمند و نوین در مطالعه و پایش تغییرات سطح زمین، به‌ویژه در حوزه‌های زمین‌ساخت، محیط‌زیست و مدیریت بلایا شناخته شده و به دلیل قابلیت اندازه‌گیری دقیق و مکرر جابجایی‌های سطح زمین، به‌ویژه در نواحی وسیع، دورافتاده و غیرقابل‌دسترس، از اهمیت ویژه‌ای برخوردار است [۱]. یکی از تکنیک‌های مؤثر در این زمینه، تداخل سنجی راداری است که قادر است جابجایی‌ها و تغییرات سطح زمین را با دقت بالا و در مقیاس‌های وسیع شناسایی نماید [۲]. این تکنیک با تحلیل داده‌های راداری، اطلاعاتی جامع را با دقت بالا درباره تغییرات زمین ارائه داده و به‌ویژه در شناسایی حرکات زمین ناشی از فعالیت‌های طبیعی مانند زلزله‌ها، لغزش‌های زمین و همچنین تغییرات ناشی از فعالیت‌های انسانی، مفید است [۳].

فاز تداخل سنجی راداری شامل مؤلفه‌های مختلفی از قبیل جابجایی، نویز، توپوگرافی، اتمسفر و انحنای زمین است که جهت دستیابی به مقدار دقیق جابجایی، باید اثر هر یک از این مؤلفه‌ها حذف شوند [۴]؛ اما به دلیل محدودیت‌هایی مانند عدم همبستگی مکانی و زمانی، باقی ماندن اثرات اتمسفری و توپوگرافی، امکان حذف کامل اثر مؤلفه‌ها در تعیین مقدار جابجایی وجود ندارد [۵]. به همین دلیل، محققان آنالیز سری زمانی را به‌عنوان روشی مناسب جهت تعیین میزان دقیق جابجایی زمین پیشنهاد کرده‌اند [۶].

بدین منظور در سال ۲۰۰۰ برای اولین بار، میزان جابجایی ناشی از فرونشست در بخشی از سطح زمین براساس آنالیز سری زمانی حاصل از تداخل سنجی راداری تخمین زده شد و اولین سری زمانی جابجایی سطح زمین به‌منظور نظارت و تحلیل تغییرات در طول زمان تولید گردید [۷]. همچنین، با پرتاب ماهواره

سنتینل-۱ در اواخر سال ۲۰۱۴ به‌منظور پایش مکرر سطح زمین (با قدرت تفکیک زمانی ۶ و ۱۲ روزه) و پوشش حداکثری از زمین با المان مداری دقیق (اختلافات کمتر از ۲۵۰ متر در گذرهای مکرر)، علاقه محققان به پایش جابجایی سطح زمین افزایش یافت و با روش‌های متنوع، سعی در شناسایی جابجایی زمین در طول زمان، به‌منظور بهبود دقت و صحت نتایج داشتند [۸].

در این بین، نقشه سرعت جابجایی سطح زمین که یکی از محصولات مهم در بحث تداخل سنجی راداری است، صرفاً با درونیابی خطی بر رفتار سری زمانی جابجایی ایجاد می‌شود [۹]. با این حال، اگر نمودار سری زمانی رفتار خطی نداشته باشد، نقشه سرعت جابجایی حاصل از آن نمودی از واقعیت نخواهد بود و تحلیل‌ها و تفسیرهای بعدی را تحت‌الشعاع قرار خواهد داد؛ بنابراین، برازش خط به سری زمانی تداخل سنجی راداری، معیار مناسبی جهت نمایش رفتار جابجایی سطح زمین در سال‌های متوالی نیست و نمی‌توان از آن به‌عنوان روشی مناسب جهت مطالعه تغییرات سطح زمین در طول زمان استفاده کرد [۱۰].

در این راستا، یکی از بهترین روش‌های تحلیل سری زمانی جهت مقابله با این محدودیت، تشخیص نقطه تغییر آذر روند جابجایی است [۱۱]. تشخیص نقطه تغییر مفهومی است که با کمک روش‌های مختلف، به شناسایی نقاطی می‌پردازد که روند سری زمانی در آن‌ها تغییر کرده است؛ به عبارت دیگر، در این نقاط، نرخ سرعت جابجایی قبل و بعد از آن تغییر می‌کند [۱۲]. با شناسایی دقیق این نقاط، امکان مدیریت علت تغییرات فراهم می‌گردد. هرچند تشخیص نقاط تغییر به دلیل پیچیدگی‌های موجود در سری‌های زمانی جابجایی، به‌عنوان یک چالش مهم در تحلیل داده‌های سری زمانی شناخته می‌شود و نیازمند استفاده از روش‌های پیشرفته و دقیق است، تاکنون روش‌های متعددی

² Change Point Detection (CPD)¹ Interferometric Synthetic Aperture Radar (InSAR)

چندلایه به عنوان یکی از ساده ترین و پرکاربردترین شبکه های عصبی در یادگیری ماشین، امکان شناسایی الگوهای پیچیده و روابط غیرخطی در داده ها را فراهم می آورد [۲۰]. این نوع شبکه ها، در مقایسه با سایر شبکه های عصبی عمیق، از حجم محاسبات و پارامترهای کمتری برخوردار بوده که موجب کاهش چشم گیر زمان محاسباتی می شوند [۲۱]. همچنین این مدل ها با توانایی یادگیری ویژگی های عمیق و غیرخطی، به شناسایی نقاط تغییر در داده های پیچیده نیز کمک کرده و با قابلیت مدل سازی روابط غیرخطی پیچیده در پدیده های طبیعی و زمین شناسی، موجب می شوند که نتایج دقیق تری حاصل گردد [۲۲].

هدف این مقاله، توسعه روشی جهت تشخیص نقاط تغییر در سری زمانی جابجایی های زمین حاصل از تداخل سنجی راداری بر مبنای شبکه عصبی پرسپترون چندلایه دارای لایه های کاملاً متصل با استفاده از سری های زمانی جابجایی موجود در سامانه پایش حرکت سطح زمین در قاره اروپا^۲ است. این داده ها توسط آژانس فضایی اروپا^۳ در چارچوب پروژه های همکاری بین المللی در زمینه سنجش از دور و ژئوفیزیک تهیه شده اند و به عنوان یک منبع معتبر و جامع در زمینه جابجایی سطح زمین در قاره اروپا مورد استفاده قرار می گیرند [۲۳ و ۲۴]. همچنین این تحقیق به بررسی قابلیت های شبکه عصبی پرسپترون چندلایه کاملاً متصل در شناسایی و تحلیل تغییرات زمین پرداخته و نتایج حاصل را با روش های سنتی و پیشرفته مقایسه خواهد کرد. در این راستا، اهداف تحقیق شامل بهبود دقت شناسایی نقاط تغییر در داده های سری زمانی جابجایی، کاهش هزینه های محاسباتی مرتبط با شناسایی نقاط تغییر، و بررسی قابلیت تعمیم پذیری روش پیشنهادی به داده های دیگر است.

جهت شناسایی این نقاط ارائه شده است. به طور کلی، این روش ها را می توان به دو دسته مبتنی بر آمار و مبتنی بر یادگیری ماشین تقسیم بندی نمود [۱۱]. روش های آماری مرسوم در شناسایی نقاط تغییر، با توجه به وجود پیچیدگی ها و ناهنجاری های متعددی مانند کمبود داده های سری های زمانی به دلیل عدم برداشت تصویر در برخی از زمان ها، عدم یکسان بودن فاصله نمونه برداری، وجود رفتارهای فصلی^۱ وجود پله در سری زمانی، غیرثابت بودن در زمان، وجود نویز و رفتار تلفیقی در داده های سری زمانی حاصل از تداخل سنجی راداری، کارایی خود را از دست داده و غالباً در شناسایی الگوهای پیچیده و تغییرات ناگهانی از دقت کافی برخوردار نیستند [۱۳، ۱۴ و ۱۵]. همچنین این روش ها به دلیل وجود داده های بسیار زیاد (از چند ده هزار تا چند ده میلیون) حاصل از نتایج تداخل سنجی راداری، از لحاظ زمان و بار محاسباتی مقرون به صرفه نیستند [۱۶]؛ بنابراین، نیاز به رویکردهای نوین و کارآمدتری جهت تحلیل و پردازش این داده ها احساس می شود.

از این رو، با توجه به پیشرفت روش های مبتنی بر یادگیری ماشین، می توان از الگوریتم های متعدد یادگیری ماشین و یادگیری عمیق جهت شناسایی نقاط تغییر استفاده کرد [۱۷]. این الگوریتم ها به طور خاص، به کار با داده های پیچیده و بزرگ می پردازند و قابلیت های بی نظیری در استخراج ویژگی ها و شناسایی الگوها دارند [۱۸]. همچنین، این روش ها می توانند به طور مؤثری در تحلیل داده های تداخل سنجی راداری به کار گرفته شوند و نقاط تغییر را با دقت و سرعت بالایی شناسایی نمایند [۱۹]. با این حال، جهت آموزش مدل های مبتنی بر یادگیری، وجود داده های آموزشی باکیفیت که نمودی از واقعیت داشته باشند، از اهمیت بالایی برخوردار است.

در این راستا، استفاده از شبکه عصبی پرسپترون

^۲ Multi-layer Perceptron (MLP)

^۳ Fully Connected Networks (FCNs)

^۴ European Ground Motion Service (EGMS)

^۵ European Space Agency (ESA)

^۱ Seasonality

در ادامه، ادبیات پژوهش مرتبط با تشخیص نقاط تغییر و کاربردهای تداخل‌سنجی راداری مرور می‌شود. سپس، جزئیات مواد و روش‌های تحقیق شامل فرایند جمع‌آوری داده‌ها، الگوریتم مورد استفاده و معیارهای ارزیابی دقت ارائه می‌گردد. در بخش بعد، بحث و نتایج بررسی و تحلیل شده و در نهایت، نتیجه‌گیری بیان خواهد شد.

۲- پیشینه پژوهش

در سال‌های اخیر، تشخیص نقاط تغییر به‌عنوان یکی از موضوعات کلیدی در تحلیل داده‌های سری زمانی جابجایی حاصل از تداخل‌سنجی راداری مورد توجه قرار گرفته است. این تکنیک به شناسایی نقاطی می‌پردازد که در آن‌ها توزیع داده‌ها یا روند آن‌ها به‌طور معناداری دستخوش تغییر می‌شود. در این بخش، به بررسی مهم‌ترین روش‌ها و تکنیک‌های مورد استفاده در تحقیقات پیشین پرداخته‌شده و مزایا و معایب هر یک مورد تحلیل قرار می‌گیرد.

سیگنا و همکاران (۲۰۱۱) روشی را جهت پس‌پردازش نتایج حاصل از تداخل‌سنجی راداری پیشنهاد کردند که قادر است تغییرات بالقوه روند را در طول زمان شناسایی نماید. در این پژوهش، سری زمانی به‌طور ساده به چندین زیربخش تقسیم می‌شود تا روند بخش‌های مختلف با یکدیگر مقایسه شده و در دسته‌بندی‌های متفاوت قرار گیرد. از جمله معایب این روش می‌توان به تعیین دستی نقطه جداسازی اشاره کرد که کارایی مدل را به‌طور قابل‌توجهی کاهش می‌دهد. همچنین، رفتارهای غیرخطی و تغییرات فصلی در این روش در نظر گرفته نمی‌شوند [۲۵].

سیگنا و همکاران (۲۰۱۲) مجدد دو شاخص را جهت شناسایی انحرافات از روند سری زمانی تداخل‌سنجی بر اساس رویکرد ریاضیات ساده طراحی کردند. روش پیشنهادی به‌صورت نیمه‌خودکار بوده و نیازمند دخالت اپراتور است. در این روش، تاریخچه سری زمانی باید در دسترس باشد تا مدل بتواند کارایی خود را حفظ نماید. همچنین، این روش تنها قادر به شناسایی یک نقطه

تغییر در سری زمانی است که در صورت وجود رفتارهای پیچیده و غیرخطی، کارایی مدل کاهش خواهد یافت. علاوه بر این، کمبود داده‌ها در طول زمان می‌تواند موجب کاهش کارایی شاخص‌های پیشنهادی در این پژوهش شود [۲۶].

برتی و همکاران (۲۰۱۳) روشی را جهت کلاس‌بندی خودکار سری‌های زمانی جابجایی، مبتنی بر دنباله‌های شرطی از آزمون‌های آماری ارائه کردند. این کلاس‌بندی شامل دسته‌هایی از پیش تعیین‌شده نظیر رفتار غیر همبسته، خطی، درجه دوم، دوطبی و ناپیوسته است. روش مورد استفاده در این پژوهش بر اساس معیار اطلاعات بیزی-شوارتز است. از جمله ضعف‌های این پژوهش می‌توان به این نکته اشاره کرد که بایاسی کوچک ممکن است منجر به تفاوت در نتایج کلاس‌بندی شود. علاوه بر این، روش پیشنهادی وابسته به فرضیات اولیه است و مدل آن ساده بوده و از پارامترهای مشخص تبعیت می‌کند؛ حال آنکه سری‌های زمانی جابجایی تداخل‌سنجی راداری دارای پیچیدگی‌های فراوانی هستند. همچنین، پیش‌فرض اصلی این روش ایستایی سری زمانی است، درحالی‌که سری‌های زمانی جابجایی تداخل‌سنجی راداری معمولاً رفتار غیرایستا دارند [۲۷].

راسپینی و همکاران (۲۰۱۸) بر اساس الگوریتم انتخاب متغیر و رویکرد بیزین، روشی را جهت شناسایی تغییرات در الگوی جابجایی پیشنهاد دادند. روش پیشنهادی به‌صورت نیمه‌خودکار عمل کرده و از حد آستانه‌گذاری در بخش نهایی سری زمانی استفاده می‌کند. از جمله ضعف‌های این روش می‌توان به استفاده از حد آستانه‌گذاری غیرخودکار، فرض خطی بودن تغییرات و عدم کارایی مدل در سری‌های زمانی با بیش از یک نقطه تغییر اشاره نمود [۲۸].

رفیک و همکاران (۲۰۲۰) به‌منظور تشخیص روندهایی که پیش‌تر مدل‌سازی نشده‌اند، از آنتروپی فازی به‌عنوان معیاری جهت تعیین ویژگی‌های سری زمانی استفاده کردند. این معیار با بهره‌گیری از بی‌نظمی

در این پژوهش، شناسایی نقطه تغییر به صورت برخط (با داده‌های آنی) و بُرون خط (با داده‌های پردازش‌شده پیشین) انجام شد. فرض اصلی این پژوهش در دسترس بودن حداقل پنج سال داده سنیتیل-۱ برای استفاده از معیارهای آماری جهت شناسایی نقطه تغییر است. همچنین، از همبستگی مکانی جابجایی‌ها برای کاهش زمان پردازش‌ها بهره‌برداری شده است. با این حال، در صورتی که نیاز به پردازش دقیق در مناطق شهری باشد، آنالیز تک‌تک نقاط ضروری است و ممکن است باعث کاهش کارایی مدل شود. این پژوهش روشی ساده جهت شناسایی نقطه تغییر به صورت انحرافات و تغییرات تدریجی در سری زمانی تداخل‌سنجی راداری پیشنهاد می‌کند، اما دارای ضعف‌هایی است که از جمله-ی آن‌ها می‌توان به استفاده از پنجره پیچشی اشاره کرد که در صورت بزرگ بودن ابعاد پنجره، منجر به حذف اطلاعات مفید می‌شود. علاوه بر این، در صورت کمبود داده در سری زمانی، مدل پیشنهادی کارایی خود را از دست خواهد داد. همچنین، استفاده از فیلتر گوسین برای آشکارسازی نقطه تغییر باعث حذف برخی اطلاعات از سری زمانی می‌شود [۳۱].

کالشرتره و همکاران (۲۰۲۲) جهت شناسایی رفتار غیرعادی در سری‌های زمانی جابجایی، الگوریتمی مبتنی بر یادگیری عمیق و طبقه‌بندی نظارت‌شده پیشنهاد دادند. رفتار غیرعادی شامل گام‌های ناگهانی و تغییرات سرعت ناگهانی است. در این پژوهش، از مدل طبقه‌بندی حافظه طولانی کوتاه‌مدت دولایه استفاده شد. داده‌های مورد استفاده در این تحقیق شامل ۱۰۴ تصویر از ماهواره سنیتیل A-1 مربوط به سال‌های ۲۰۱۵ و ۲۰۱۸ بودند که بر روی منطقه‌ای تحت تأثیر فروچاله به ابعاد 44×63 کیلومتر مربع در ایرلند جمع‌آوری شده‌اند. نتایج نشان می‌دهند که سری‌های زمانی با روند خطی را می‌توان با دقت ۹۹٪ به درستی طبقه‌بندی کرد، در حالی که دقت طبقه‌بندی سری‌های زمانی با تغییرات غیرعادی نظیر گام‌های ناگهانی و تغییرات سرعت ناگهانی به ۶۲٪ کاهش می‌یابد.

آنتروپی فازی برای سیگنال‌های فصلی، سهموی یا تکه‌ای مقادیر پایین و برای روندهایی که آشفته‌تر هستند (که در آن‌ها نویز غالب است) مقادیر بالاتری را می‌گیرد. آن‌ها بر اساس این فرضیه، معیاری برای جداسازی رفتارهای معنادار ایجاد کردند. آنتروپی فازی به دلیل هزینه محاسباتی پایین و عدم نیاز به تعریف مدل، به عنوان معیار مناسبی شناخته می‌شود. نتایج این روش بر روی داده‌های شبیه‌سازی شده و چند نمونه داده واقعی پیاده‌سازی شد. از جمله ضعف‌های این پژوهش می‌توان به عدم کارایی روش پیشنهادی در سری‌های زمانی با تعداد نمونه‌برداری کم، انتخاب دستی حد آستانه، عدم توانایی در شناسایی روندهای پیچیده و ترکیبی و همچنین تنظیم دستی پارامترهای مختلف اشاره نمود [۲۹].

بوونگا و همکاران (۲۰۲۱) به منظور شناسایی جنبش‌های غیرخطی در سری‌های زمانی جابجایی، روشی را جهت کلاس‌بندی خودکار این سری‌های زمانی پیشنهاد دادند. بدین منظور، آن‌ها شاخصی مبتنی بر توزیع فیشر ارائه کردند که مشخصات سری زمانی جابجایی را توصیف می‌نماید. روش پیشنهادی قادر است به صورت خودکار حداقل پارامترهای مورد نیاز برای مدل‌سازی سری زمانی را با سطح اطمینان از پیش تعیین‌شده به دست آورد. این روش اگرچه عمومی است، اما به طور خاص برای تقریب روندهای خطی قطعه‌مبنای استفاده می‌شود. پس از شناسایی بهترین تقریب چندجمله‌ای، نقاط تغییر به سادگی از مدل استخراج می‌شوند. از جمله مشکلات این پژوهش می‌توان به استفاده صرفاً از مدل‌های چندجمله‌ای، آزمون در محیط شبیه‌سازی شده و مشکلات مربوط به آزمون‌های آماری مانند آزمون فیشر در صورت کمبود داده اشاره کرد [۳۰].

حسین و همکاران (۲۰۲۱) جهت آشکارسازی انحرافات و تغییرات تدریجی جابجایی در سری‌های زمانی تداخل‌سنجی راداری، روشی آماری با رویکرد شناسایی نقطه تغییر به صورت برخط و بُرون خط پیشنهاد دادند.

پیاده‌سازی روش پیشنهادی تنها برای منطقه تحت تأثیر فروچاله، وجود جابجایی‌های منحصربه‌فرد در سری‌های زمانی را تضمین می‌کند. این در حالی است که برای شناسایی گام‌های ناگهانی و تغییرات سرعت ناگهانی در روندهای کندتر، نظیر لغزش‌های تدریجی یا فرونشست‌های تدریجی با شتاب متغیر، روش پیشنهادی کارایی خود را از دست می‌دهد [۳۲].

لاتاری و همکاران (۲۰۲۲) با استفاده از مدل‌های یادگیری عمیق، به شناسایی نقاط تغییر در سری‌های زمانی جابجایی حاصل از نتایج تداخل‌سنجی راداری پرداختند. آن‌ها تغییرات تدریجی و همچنین حالت‌های پله‌ای در سری‌های زمانی جابجایی را مدنظر قراردادند که جهت مدل‌سازی همبستگی زمانی داده‌ها از سلول‌های حافظه طولانی کوتاه‌مدت دوطرفه و همچنین جهت در نظر گرفتن نرخ نمونه‌برداری داده‌ها و کمبود داده با اضافه کردن ورودی اختلاف‌زمان به سلول‌های حافظه زمانی، اقدام به شناسایی نقاط تغییر کردند. در این پژوهش به‌منظور تولید داده‌های آموزشی، روش خودکاری پیشنهاد شد که در آن تنها نقاط تغییر در روند جابجایی وجود دارد و هیچ‌گونه تغییری در رفتار فصلی ایجاد نمی‌شود. داده‌های آموزشی در این پژوهش توسط افراد خبره مورد تأیید قرار گرفت. با این حال، استفاده از روش حافظه کوتاه‌مدت و بلندمدت به دلیل تحلیل روابط بین هر داده در سری زمانی که به تحلیل روابط میان داده‌ها نیز منجر می‌شود، هزینه محاسباتی بالایی دارد. علاوه بر این، در این پژوهش داده‌های شبیه‌سازی شده صرفاً توسط متخصصان به‌صورت بصری بازبینی شده است که این امر احتمال وجود داده‌های آموزشی ناکارآمد را نیز افزایش می‌دهد [۱۳].

قادرپور و همکاران (۲۰۲۴) به‌منظور تخمین مکان و جهت چرخش روند در سری‌های زمانی جابجایی، به‌عنوان شاخص تغییر شکل زمین، اقدام کردند. در این

پژوهش، روشی به نام تشخیص نقطه عطف متوالی^۲ پیشنهاد شد و با سایر روش‌های تشخیص نقطه تغییر نیز مقایسه گردید. با استفاده از مجموعه‌ای بزرگ از سری‌های زمانی شبیه‌سازی شده با انواع مختلف نویز، نشان داده شد که روش پیشنهادی از نظر دقت کلی و ریشه میانگین مربعات خطا جهت تخمین مکان و جهت چرخش روند، عملکرد بهتری نسبت به روش‌های دیگر موردبررسی در این پژوهش دارند. به‌عنوان یک مطالعه موردی، از روش پیشنهادی جهت شناسایی نقاط عطف در سری‌های زمانی حاصل از تداخل‌سنجی راداری در استان فروزینون ایتالیا استفاده شد که با استفاده از توپوگرافی و پوشش کاربری زمین، طبقه‌بندی انجام گرفت. همچنین در این تحقیق نشان داده شد که نقاط عطف در سری زمانی بارش محلی همبستگی بالایی با نقاط عطف در سری زمانی جابجایی حاصل از تداخل-سنجی راداری دارند که نشان‌دهنده این است، بارش عامل محرک اصلی جابجایی‌ها در منطقه به‌شمار می‌رود. لازم به ذکر است که روش پیشنهادی نیازمند تاریخچه داده‌های در دسترس باکیفیت بالا است و همچنین در صورت وجود تغییرات، ابتدا و انتهای سری زمانی قابل‌شناسایی نمی‌باشد. عدم بررسی کیفیت داده‌های تولیدشده و وابستگی شدید مدل آموزش‌دیده به مجموعه داده‌های شبیه‌سازی شده از دیگر ضعف‌های این روش به‌شمار می‌رود [۱۲].

با توجه به تنوع روش‌ها و تکنیک‌های موجود در پیشینه پژوهش، می‌توان بیان کرد که انتخاب روش مناسب جهت تشخیص نقاط تغییر به ویژگی‌های خاص داده‌ها، اهداف تحقیق و شرایط محیطی بستگی دارد. با این حال، روش‌های کلاسیک شامل آزمون‌های آماری نظیر آزمون مجموع پسماندهای عطفی انباشته^۳، آزمون مک‌نیل و آزمون روند خطی به‌طور گسترده‌ای جهت شناسایی تغییرات در داده‌های سری زمانی به کار

^۲ Sequential Turning Point Detection (STPD)

^۳ Cumulative Sum (CUSUM)

^۱ Time-gated LSTM (TGLSTM)

گرفته‌اند، تفاوت دارد. به‌طور کلی، مهم‌ترین ویژگی‌های شبکه پیشنهادی عبارتند از: یک شبکه عصبی کاملاً متصل چندمقیاسی که قادر به استخراج ویژگی‌های سطح پایین و بالا از داده‌های ورودی دارد. این معماری شامل چندین لایه با اندازه‌های هسته مختلف است که امکان تحلیل داده‌ها در مقیاس‌های متفاوت را فراهم می‌کند. به‌منظور کاهش ابعاد و فشردن ویژگی‌ها، از لایه‌های پولینگ استفاده شده است. همچنین، برای افزایش ظرفیت مدل و یادگیری روابط غیرخطی، لایه‌های کاملاً متصل به کار گرفته شده‌اند. در نهایت، یک لایه خروجی با تابع فعال‌سازی سیگموئید، احتمال وقوع نقطه تغییر در هر زمان را تخمین می‌زند. علاوه بر این، به‌منظور مقاوم‌سازی شبکه در برابر نقاط تغییر با زوایا و جهت‌های مختلف، از تکنیک‌های متنوع افزایش داده‌ها^۲ استفاده شده است.

۳-۱- منطقه مطالعاتی

منطقه مطالعاتی این تحقیق شامل نواحی خاصی از قاره اروپا مطابق شکل (۱) است که به دلیل فعالیت‌های زمین‌شناسی و انسانی از اهمیت زیادی برخوردار می‌باشند. این نواحی به‌ویژه تحت تأثیر پدیده‌هایی نظیر زلزله‌ها، لغزش‌های زمین و تغییرات ناشی از فعالیت‌های عمرانی قرار دارند. داده‌های مورد استفاده در این تحقیق از سامانه^۳ EGMS^۳ بارگیری شده‌اند که شامل سری‌های زمانی جابجایی ثبت‌شده در نقاط مختلف اروپا است و از تداخل‌سنجی راداری به‌دست آمده‌اند [۲۳ و ۲۴]. این داده‌ها به‌عنوان یک منبع معتبر و جامع در زمینه جابجایی زمین استفاده شده و به‌صورت بردارهای زمانی-مکانی سازمان‌دهی شده‌اند. به‌منظور افزایش تعمیم‌پذیری شبکه عصبی پیشنهادی، قاره اروپا به چندین ناحیه تقسیم‌بندی شده است و از هر ناحیه به‌طور تصادفی تعدادی داده انتخاب شده‌اند که هر یک شامل نمونه‌های مختلفی از سری‌های زمانی

می‌روند [۳۳]. از مزایای این روش‌ها می‌توان به سادگی، قابلیت تفسیرپذیری و محاسبه سریع اشاره کرد، اما این روش‌ها معمولاً فرضیات خطی و نرمال بودن داده‌ها را مدنظر قرار می‌دهند که ممکن است در دنیای واقعی برآورده نشوند و به همین دلیل دقت آن‌ها کاهش یابد [۱۱]. همچنین مدل‌های خودهمبسته‌ی میانگین-متحرک نیز جهت مدل‌سازی و پیش‌بینی سری‌های زمانی به‌کار می‌روند و با توجه به تغییرات در پارامترهای مدل، می‌توانند به شناسایی نقاط تغییر کمک کنند [۳۴]. این مدل‌ها توانایی مدل‌سازی سری‌های زمانی پیچیده و قابلیت پیش‌بینی دارند، اما نیاز به تعیین دقیق پارامترها و فرضیات ایستایی داده‌ها دارند که می‌تواند چالش برانگیز باشد [۳۵]. از این‌رو، استفاده از روش‌های نوین مانند شبکه‌های عصبی و الگوریتم‌های ترکیبی به دلیل توانایی یادگیری ویژگی‌های پیچیده و کارایی بالا در تحلیل داده‌های بزرگ، می‌تواند دقت و کارایی تحلیل‌ها را به طرز چشمگیری افزایش دهد؛ هرچند که این روش‌ها نیاز به حجم بالایی از داده‌ها جهت آموزش و پیچیدگی در تنظیم پارامترها دارند که از معایب آن‌ها به شمار می‌رود. در این تحقیق، تمرکز ما بر روی استفاده از شبکه‌های عصبی پرسپترون چندلایه خواهد بود و در ادامه به روش پیشنهادی در تشخیص نقاط تغییر سری‌های زمانی جابجایی خواهیم پرداخت.

۳- مواد و روش

این بخش به توصیف دقیق مواد و روش‌های مورد استفاده در این تحقیق می‌پردازد. هدف اصلی تحقیق، شناسایی نقاط تغییر در سری زمانی جابجایی‌های سطح زمین با استفاده از تداخل‌سنجی راداری و شبکه‌های عصبی کاملاً متصل است. شبکه پیشنهادی با معماری‌های قبلی شناسایی نقطه تغییر در سری زمانی جابجایی‌های حاصل از تداخل‌سنجی راداری که اخیراً مورد بررسی قرار


^۲ Data Augmentation

^۳ European Ground Motion Service


^۱ Autoregressive Integrated Moving Average (ARIMA)

درمجموع ۱۰,۰۰۰ سری زمانی جابجایی از سامانه EGMS بارگیری گردید. شکل (۲) نمونه‌هایی از داده‌های سامانه EGMS را نشان می‌دهد.

جابجایی می‌باشند. همان‌طور که از شکل (۱) مشاهده می‌شود، از اکثر نواحی قاره اروپا به‌طور تصادفی داده انتخاب شده و



شکل ۱: منطقه مورد مطالعاتی (دایره‌های قرمز: نواحی مورد مطالعه)



شکل ۲: چند نمونه از داده‌های سامانه EGMS که هر سری زمانی مربوط به یک پراکنش گر دائم می‌باشد.

بعدی ارتباط دارد. شبکه پیشنهادی با معماری‌های قبلی شناسایی نقطه تغییر در سری زمانی جابجایی‌های حاصل از تداخل سنجی راداری که اخیراً مورد بررسی قرار گرفته‌اند، تفاوت دارد [۱۳ و ۳۲]. به‌طور کلی، مهم‌ترین ویژگی‌های شبکه پیشنهادی عبارت‌اند از: یک شبکه عصبی کاملاً متصل چندمقیاسی که قادر به استخراج ویژگی‌های سطح پایین و بالا از داده‌های ورودی است. این معماری شامل چندین لایه با اندازه‌های هسته مختلف است که امکان تحلیل داده‌ها در مقیاس‌های متفاوت را فراهم می‌کند. به‌منظور کاهش ابعاد و فشردگی و ویژگی‌ها، از لایه‌های پولینگ استفاده شده است. همچنین، برای افزایش ظرفیت مدل و یادگیری روابط غیرخطی، لایه‌های کاملاً متصل به کار گرفته شده‌اند. در نهایت، یک لایه خروجی با تابع فعال‌سازی سیگموئید، احتمال وقوع نقطه تغییر در هر زمان را تخمین می‌زند. شکل (۳) روندنمای شبکه پیشنهادی را نشان می‌دهد.

۳-۳-۱- پیش‌پردازش داده‌ها

در این پژوهش، پیش‌پردازش‌هایی نظیر درون‌یابی، نرمال‌سازی داده‌ها و حذف روند بر روی داده‌های تداخل سنجی راداری اعمال شده است تا مدل شبکه عصبی پیشنهادی بتواند تمرکز بهتری بر روی تغییرات حقیقی و مهم داشته باشد. این مراحل که در بسیاری از مطالعات مشابه در حوزه یادگیری ماشین نیز به کار می‌روند، به مدل کمک می‌کنند تا با داده‌های کمتر و کیفیت بالاتر، عملکرد بهتری از خود نشان داده و در مدت‌زمان کمتری به همگرایی برسند. در ابتدا، به‌دلیل آن‌که اغلب داده‌های سری زمانی تداخل سنجی راداری دارای فواصل زمانی یکسانی نیستند، نیاز است که کل سری زمانی به فواصل یکسان تقسیم‌بندی شوند. بدین منظور، سری زمانی به‌صورت پیوسته در نظر گرفته می‌شود و سپس عملیات درون‌یابی بین فواصل زمانی مختلف انجام خواهد شد. بدین منظور، برای هر نقطه زمانی جدید، مقدار جابجایی بر اساس نقاط قبل و بعد محاسبه می‌گردد.

پس از جمع‌آوری داده‌های مناسب، نیاز به تولید برچسب‌های تغییرات جهت آموزش شبکه عصبی وجود دارد. بدین منظور، ابتدا نقاط تغییر، شامل تغییرات ناگهانی یا تدریجی در جابجایی‌ها که به‌طور بصری توسط کارشناسان خبره شناسایی و تأیید شده‌اند، به‌صورت بردارهای صفر و یک مشخص می‌شوند؛ به‌طوری‌که مقدار ۱ نشان‌دهنده وجود تغییر در روند می‌باشد. این نقاط ممکن است نشان‌دهنده وقوع رویدادهای زمین‌شناسی یا ساختاری باشند.


۳-۲- تقویت داده‌ها^۱

تقویت داده‌ها به‌منظور بهبود عملکرد مدل و کاهش خطر بیش‌برازش، امری ضروری است، به‌ویژه زمانی که تعداد داده‌های برچسب‌گذاری شده محدود باشند [۳۶]. این روش همچنین یک راه‌حل مناسب جهت مقاوم‌سازی مدل در برابر نوسانات به شمار می‌رود [۱۸]. روش‌های مختلفی برای تقویت داده‌ها وجود دارد که شامل افزودن نویز، تغییر مقیاس، تغییرات زمانی، ترکیب، و تغییرات لگاریتمی است [۳۷]. در این پژوهش، از روش‌های مختلفی برای تقویت داده‌ها استفاده شد. ابتدا، با افزودن نویزهای توزیع شده، شامل توزیع نرمال، پواسن و یکنواخت، تنوع داده‌ها افزایش یافت تا مدل نسبت به نوسانات مقاوم‌تر شود. سپس، با تغییر مقیاس و ترکیب سری‌های زمانی، داده‌های جدیدی تولید شد. این عملیات تقویت داده‌ها منجر به افزایش تقریباً ۵ برابری تعداد سری‌های زمانی آموزشی شد.

۳-۳- روش پیشنهادی

در این پژوهش به‌منظور شناسایی نقاط تغییر در داده‌های سری زمانی جابجایی، از شبکه‌های عصبی پرسپترون چندلایه استفاده شده است. شبکه‌های عصبی پرسپترون چندلایه که از لایه‌های کاملاً متصل بهره می‌برند، نوعی از شبکه‌های عصبی هستند که در آن‌ها هر نورون در یک لایه با تمامی نورون‌های لایه

^۱ Data augmentation



شکل ۳: روندنمای روش پیشنهادی شامل (لایه‌های ورودی، پیش پردازش، آموزش و خروجی)

(مربع انحراف معیار) می‌باشد. بیشترین مقدار $\omega^{(i)}$ بر اساس رابطه (۱) در نقطه تغییر رخ می‌دهد. این روش برچسب‌گذاری، امکان مدل‌سازی دقیق‌تر و پویاتر تغییرات را فراهم می‌آورد و به مدل اجازه می‌دهد تا الگوهای تغییر تدریجی و ناگهانی را با دقت بیشتری تشخیص دهد. همچنین، این رویکرد با ماهیت پیوسته و غیرقطعی تغییرات در داده‌های تداخل‌سنجی سازگاری بیشتری داشته و می‌تواند به بهبود قابل‌توجهی در عملکرد مدل جهت تشخیص و پیش‌بینی تغییرات منجر شود [۴۰].


شکل (۴) دو نمونه از برچسب‌های تولیدشده بر اساس تابع توزیع گاوسی را نشان می‌دهد. در مرحله بعد، حذف روند از سری زمانی صورت می‌گیرد. روند معمولاً به تغییرات میانگین در طول زمان اطلاق می‌شود و حذف آن می‌تواند به کاهش نویز و اعوجاجات در داده‌ها کمک کرده و همچنین مدل قادر خواهد بود تا به تغییرات مرتبط با روند (چه صعودی و چه نزولی) بیشتر توجه کرده و دیگر نیازی به در نظر گرفتن تغییرات میانگین در کل سری زمانی نخواهد بود [۴۱].

پس از آن که سری زمانی با فواصل زمانی یکسان تولید شد، نیاز است تا برچسب‌هایی که قبلاً توسط کارشناسان خبره شناسایی و محل آن‌ها تأیید شده‌اند، به صورت تابع توزیع احتمال گاوسی تغییرات برای هر نقطه‌ی زمانی تعریف شوند [۳۸]. این رویکرد، عدم قطعیت ذاتی در تشخیص تغییرات را به طور مستقیم در فرآیند یادگیری مدل لحاظ می‌نماید [۳۹]. به طور خاص، برای هر سری زمانی با طول مشخص که در این پژوهش ۲۵۰ نمونه در نظر گرفته شده است، یک بردار برچسب متناظر با همان طول ایجاد می‌شود. هر عنصر این بردار، احتمال وقوع تغییر در نقطه‌ی زمانی متناظر را نشان می‌دهد که این احتمالات از یک توزیع گاوسی استخراج شده‌اند. همچنین، کارشناسان خبره مکان وقوع تغییرات را به صورت دستی و بر اساس شواهد بصری موجود در داده‌های تداخل‌سنجی شناسایی کرده‌اند. سپس، پارامترهای توزیع گاوسی به صورت خودکار و بر اساس رابطه (۱) و با در نظر گرفتن یک پنجره‌ی زمانی ثابت قبل و بعد از مکان‌های شناسایی‌شده تخمین زده شده‌اند.

$$\omega^{(i)} = \exp\left(-\frac{(x^{(i)} - x^{(cp)})^2}{2\sigma^2}\right) \quad \text{رابطه (۱)}$$

در رابطه (۱)، مقدار وزن احتمال محل رخداد تغییر $\omega^{(i)}$ در محل تغییر $x^{(cp)}$ نسبت به همسایگی‌های $x^{(i)}$ است و σ^2 نشان‌دهنده واریانس

^۱ Detrending



شکل ۴: دو نمونه از داده‌های سری زمانی جابجایی دارای برچسب تغییرات روند و توزیع احتمال گاوسی

زده شده برای هر نقطه زمانی را با استفاده از فرمول رابطه (۲) محاسبه نمود. سپس، سری زمانی بدون روند با کم کردن روند تخمین زده شده از سری زمانی اصلی طبق رابطه (۵) به دست می‌آید:

$$y_t = x_t - \hat{x}_t \quad \text{رابطه (۵)}$$

در رابطه (۵)، y_t سری زمانی بدون روند، x_t سری زمانی اصلی و $\hat{x}_t$ روند تخمین زده شده با استفاده از رگرسیون خطی است. پس از حذف روند با استفاده از رگرسیون خطی، سری زمانی بدون روند به دست می‌آید که تغییرات حول صفر را نشان می‌دهد. این فرآیند به مدل کمک می‌کند تا بر تغییرات واقعی تمرکز کرده و از تأثیر روند کلی (صعودی یا نزولی) جلوگیری نماید. شکل (۵) نمونه‌ای از سری زمانی دارای روند (رنگ آبی) و سری زمانی بدون روند (رنگ نارنجی) را نشان می‌دهد.

در نهایت، عملیات نرمال‌سازی بر روی داده‌ها انجام خواهد شد. باتوجه به اینکه مقادیر جابجایی در داده‌های سری زمانی، دارای مقیاس‌های متفاوتی بوده و چون هدف ما شناسایی تغییرات، بدون توجه به مقیاس مقادیر است؛ بنابراین، جهت تغییرات در مدل بسیار مهم است تا بر اساس مقیاس مقادیر، تمایزی قائل نشود [۴۴].

در این پژوهش، حذف روند با استفاده از رگرسیون خطی انجام می‌شود [۴۲]، به گونه‌ای که هدف یافتن بهترین خط مستقیم است که روند کلی داده‌ها را توصیف نماید. سپس، این خط از داده‌های اصلی کسر می‌شود تا سری زمانی بدون روند به دست آید. لازم به ذکر است که هدف از به کارگیری این روش، حذف روندهای خطی است، درحالی‌که تغییرات فصلی، در صورت وجود، در سری زمانی حفظ خواهند شد. معادله رگرسیون خطی طبق رابطه (۲) بیان می‌شود [۴۳]:


$$\hat{x}_t = a + bt \quad \text{رابطه (۲)}$$

در رابطه (۲)، $\hat{x}_t$ مقدار تخمین زده شده روند در زمان t ، b عرض از مبدأ و a شیب خط می‌باشد. جهت یافتن پارامترهای a و b ، از روش حداقل مربعات استفاده می‌شود. هدف این روش، به حداقل رساندن مجموع مربعات باقیمانده‌ها (تفاوت بین مقادیر واقعی و مقادیر تخمین زده شده) است. فرمول‌های محاسبه پارامترهای a و b مطابق روابط (۳) و (۴) محاسبه می‌شود [۴۳]:

$$a = \bar{x} - b\bar{t} \quad \text{رابطه (۳)}$$

$$b = \frac{\sum_{t=1}^n (t-\bar{t})(x_t - \bar{x})}{\sum_{t=1}^n (t-\bar{t})^2} \quad \text{رابطه (۴)}$$

در روابط (۳) و (۴)، n تعداد نمونه‌های سری زمانی، $\bar{x}$ میانگین مقادیر سری زمانی و $\bar{t}$ میانگین زمان‌ها است. پس از محاسبه پارامترهای a و b ، می‌توان روند تخمین



شکل ۵: حذف روند از سری زمانی جابجایی که رنگ آبی نشان‌دهنده سری زمانی دارای روند و رنگ نارنجی، سری زمانی بدون روند

۳-۳-۲- فرآیند یادگیری مدل

فرآیند یادگیری در شبکه‌های عصبی پرسپترون چندلایه به شرح زیر است [۴۶]:

آموزش: مدل با استفاده از داده‌های آموزشی و تابع هزینه، وزن‌ها و بایاس‌های خود را تنظیم می‌کند. این فرآیند معمولاً با بهره‌گیری از الگوریتم‌های بهینه‌سازی انجام می‌شود.

اعتبارسنجی: مدل با استفاده از مجموعه‌ای جداگانه از داده‌ها ارزیابی می‌شود تا از تعمیم‌پذیری آن اطمینان حاصل گردد.

پیش‌بینی: پس از مراحل آموزش و اعتبارسنجی، مدل قادر خواهد بود نقاط تغییر در داده‌های جدید را پیش‌بینی نماید.

بنابراین، ابتدا داده‌ها را به مجموعه‌های آموزشی و آزمایشی تقسیم کرده و سپس مدل را طبق معماری پیشنهادی آموزش می‌دهیم.

۳-۳-۱- میانگین متحرک^۲

لایه میانگین متحرک به منظور هموارسازی سری‌های زمانی و کاهش نویز به کار می‌رود [۴۷]. با محاسبه میانگین مقادیر در یک پنجره‌ی زمانی متحرک، نوسانات کوتاه‌مدت و تغییرات ناگهانی در داده‌ها کاهش می‌یابد [۴۸]. این فرآیند به شبکه‌ی عصبی کمک می‌کند تا روندهای کلی و الگوهای پایدارتر را بهتر

جهت اعمال لایه نرمال‌سازی مبتنی بر انحراف معیار^۱ به سری زمانی، فرمول مربوطه طبق رابطه (۶) اعمال می‌شود [۴۵].

$$z_t = \frac{y_t - \mu}{\sigma} \quad \text{رابطه (۶)}$$

در رابطه (۶)، z_t سری زمانی نرمال شده، y_t سری زمانی بدون روند، μ میانگین مجموعه سری زمانی بدون روند و σ انحراف معیار سری زمانی بدون روند است. میانگین (μ) و انحراف معیار (σ) را می‌توان با استفاده از روابط (۷) و (۸) محاسبه نمود [۴۵]:

$$\mu = \frac{1}{n} \sum_{t=1}^n y_t \quad \text{رابطه (۷)}$$

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (y_t - \mu)^2} \quad \text{رابطه (۸)}$$


در این روش، داده‌ها معمولاً به بازه خاصی منتقل نمی‌شوند، اما به یک مقیاس استاندارد که برای مدل‌های آماری و یادگیری ماشین مناسب است، تغییر پیدا می‌کنند.

با اعمال لایه حذف روند، شیب سری زمانی به صفر نزدیک می‌شود و با اعمال لایه نرمال‌سازی، مقیاس سری زمانی به مقیاس استاندارد (با میانگین صفر و انحراف معیار یک) تبدیل می‌گردد. این پیش‌پردازش‌ها به مدل کمک کرده تا بر تغییرات روند تمرکز کند و اطلاعات را بر اساس تغییرات در مقادیر استخراج نماید.

^۲ Moving Average

^۱ Z-Score

ω طول پنجره متحرک (تعداد نقاط داده در هر پنجره) و x_{t-i} مقدار سری زمانی در زمان i است. مطابق با شکل (۶)، نمونه‌ای از خروجی میانگین متحرک بر روی داده‌های سری زمانی نشان داده شده است. همان‌طور که در شکل (۶) مشاهده می‌شود، عبور سری زمانی از این لایه موجب حذف نوسانات محلی شده و مدل توانسته است توجه خود را بیشتر بر روند اصلی متمرکز نماید تا از تأثیر این نوسانات گمراه‌کننده جلوگیری شود.



شکل ۶: روند آبی‌رنگ سری زمانی اولیه و روند قرمز رنگ خروجی لایه میانگین متحرک با ابعاد پنجره ۲۰

می‌شوند، شکل آن‌ها به صورت (۱، ۲۳۰) خواهد بود. این بدین معناست که سری زمانی پیش‌پردازش شده، یک بردار با طول ۲۳۰ است و تنها یک ویژگی (مقادیر سری زمانی) را شامل می‌شود. در این معماری، لایه کاملاً متصل دارای ۲۵۰ فیلتر و کرنلی با اندازه ۲۳۰ است. نکته قابل توجه این است که اندازه کرنل دقیقاً برابر با طول سری زمانی ورودی است. این بدان معناست که هر فیلتر یک محاسبه واحد را روی کل سری زمانی انجام می‌دهد و یک مقدار خروجی تولید می‌کند. به عبارت دیگر، به جای آنکه کرنلی با اندازه‌ای کوچک‌تر روی سری زمانی حرکت کرده و ویژگی‌های محلی را استخراج نماید، کل سری زمانی را پوشش داده و یک ویژگی سراسری را محاسبه می‌کند. این رویکرد نگاهی کلی به سری زمانی دارد و ویژگی‌های عمومی و سطح بالا را استخراج می‌کند. این ویژگی‌های استخراج‌شده، حاوی اطلاعات مهمی در مورد رفتار کلی

شبیه‌سازی کرده و از حساسیت بیش‌ازحد به نویزهای موقتی جلوگیری نماید. در معماری پیشنهادی، پس از عملیات پیش‌پردازش، از لایه‌ی میانگین متحرک به‌عنوان یکی از لایه‌های آموزش‌دیده جهت برجسته‌سازی روندهای کلی و کاهش نویزهای کوتاه‌مدت استفاده می‌شود. فرمول محاسبه‌ی میانگین متحرک ساده طبق رابطه (۹) می‌باشد [۴۹].

رابطه (۹) $MA_t = \frac{1}{\omega} \sum_{i=0}^{\omega-1} x_{t-i}$ میانگین متحرک در زمان t است.

۳-۲-۲-۳- میانگین تجمع^۱

لایه میانگین تجمع به‌منظور کاهش ابعاد داده‌ها و خلاصه‌سازی اطلاعات به‌کار می‌رود [۵۰]. در این لایه، پنجره‌ای با اندازه‌ی مشخص روی داده‌ها حرکت کرده و میانگین مقادیر داخل هر پنجره محاسبه می‌شود. این فرآیند باعث می‌شود که ویژگی‌های کلیدی حفظ شوند و جزئیات غیرضروری و نویز کاهش یابد. استفاده از میانگین تجمع به شبکه‌ی عصبی این امکان را می‌دهد که بر الگوهای مهم تمرکز کرده و پیچیدگی محاسباتی را کاهش دهد [۵۱].

۳-۲-۳-۳- لایه کاملاً متصل

در معماری پیشنهادی، هنگامی که داده‌ها پس از گذر از لایه‌های قبلی (نرمال‌سازی، حذف روند، میانگین متحرک و میانگین تجمع) به لایه کاملاً متصل وارد

^۱ Average Pooling

سری زمانی و الگوهای سراسری موجود در آن هستند که می‌توانند در شناسایی نقاط تغییر مفید باشند [۵۲].

۳-۲-۴- تخت کردن^۱

به منظور تبدیل خروجی چندبعدی لایه‌های کاملاً متصل به یک بردار یک‌بعدی، از لایه تخت کردن استفاده می‌شود [۵۳]. این فرآیند جهت آماده‌سازی داده‌ها برای ورود به لایه کاملاً متصل متراکم انجام می‌گیرد. با تخت کردن داده‌ها، می‌توان ویژگی‌های استخراج‌شده توسط لایه‌های کاملاً متصل را به عنوان ورودی به شبکه‌ی عصبی سنتی تغذیه نمود [۵۴]. هرچند که در ساختار شبکه پیشنهادی، داده ورودی به صورت بردار یک‌بعدی است و این لایه تغییری در ساختار داده ایجاد نمی‌کند، اما وجود این لایه به منظور حفظ انعطاف‌پذیری طراحی شبکه در مواجهه با داده‌های چندبعدی (مانند داده‌های خروجی از لایه‌های کانولوشنی در مطالعات آینده) در نظر گرفته شده است. این امر به استانداردسازی ساختار شبکه و تطابق بهتر با کاربردهای مختلف کمک می‌کند.

۳-۲-۵- لایه کاملاً متصل متراکم

در معماری پیشنهادی، برچسب‌های مورد استفاده جهت آموزش شبکه، یک بردار با ابعاد (۱، ۲۵۰) هستند که هر عنصر آن احتمال وقوع تغییر در نقطه متناظر از سری زمانی را نشان می‌دهد. این برچسب‌ها به جای بیان صرف وجود یا عدم وجود تغییر، میزان احتمال تغییر را در هر نقطه مشخص می‌کنند؛ بنابراین، هدف لایه کاملاً متصل متراکم با ۲۵۰ نورون در انتهای شبکه، پیش‌بینی احتمال تغییر در هر یک از ۲۵۰ نقطه سری زمانی است. این لایه، ویژگی‌های استخراج‌شده از لایه‌های قبلی را دریافت کرده و با استفاده از وزن‌های قابل‌یادگیری، آن‌ها را به یک بردار با ابعاد (۱، ۲۵۰) تبدیل می‌کند. هر عنصر در این بردار خروجی، بیانگر احتمال پیش‌بینی شده برای وقوع تغییر در نقطه متناظر است.

استفاده از تابع فعال‌سازی سیگموئید در لایه خروجی کاملاً متصل متراکم، موجب شده تا مقادیر خروجی به بازه مابین ۰ و ۱ محدود شوند که این بازه، نشان‌دهنده‌ی

احتمالات است [۵۵]؛ بنابراین، خروجی نهایی شبکه یک بردار با ابعاد (۱، ۲۵۰) خواهد بود که هر عنصر آن احتمال پیش‌بینی شده برای وقوع تغییر در نقطه‌ی متناظر از سری زمانی را نشان می‌دهد.

باتوجه به اینکه مسئله شناسایی نقاط تغییر در سری‌های زمانی جابجایی به عنوان یک مسئله طبقه‌بندی چندکلاسه مدل‌سازی شده است. در این مدل، هر بازه زمانی به یکی از کلاس‌های تعریف‌شده (بر اساس تغییرات جابجایی) تعلق می‌گیرد که در طول فرایند آموزش شبکه، مدل سعی می‌کند با استفاده از تابع هزینه باینری کراس انتروپی، خروجی پیش‌بینی‌شده توسط لایه کاملاً متصل متراکم را به برچسب‌های واقعی (احتمالات وقوع تغییر) نزدیک نماید [۵۶]. بنابراین تابع هزینه انتخاب‌شده به منظور محاسبه میزان اختلاف بین توزیع احتمالات پیش‌بینی‌شده و توزیع واقعی برچسب‌ها طراحی شده است. سپس با به‌روزرسانی وزن‌های شبکه در طول آموزش، شبکه یاد می‌گیرد که چگونه ویژگی‌های استخراج‌شده را به احتمالات وقوع تغییر در هر نقطه نگاشت نماید.

پس از آموزش، شبکه قادر خواهد بود تا با دریافت یک سری زمانی جدید، احتمال وقوع تغییر را برای هر یک از ۲۵۰ نقطه پیش‌بینی نماید. این پیش‌بینی‌ها در قالب یک بردار با ابعاد (۱، ۲۵۰) خواهند بود که هر عنصر آن احتمال پیش‌بینی‌شده برای تغییر در نقطه متناظر را نشان می‌دهد. نقاطی که احتمال پیش‌بینی‌شده برای آن‌ها بالاتر است، به عنوان نقاط با احتمال بالاتر تغییر شناسایی می‌شوند. همچنین، برای آموزش مدل و کاهش هزینه، الگوریتم بهینه‌سازی آدام استفاده گردید [۵۷].

۳-۴- معیارهای ارزیابی دقت

در این تحقیق، سه معیار صحت^۲، فراخوانی^۳ و امتیاز اف^۴ در نظر گرفته شده است. بسته به موضوع تحقیق، باید تصمیم گرفت که کدام معیار اهمیت بیشتری دارد

^۲ Adam

^۳ Precision

^۴ Recall

^۵ F1_score

^۱ Flatten

می‌دهد، درحالی‌که معیار صحت نسبت پیش‌بینی‌های مثبت صحیح به کل پیش‌بینی‌های مثبت پیش‌بینی‌شده را نشان می‌دهد. معیارهای شرح داده‌شده، در جدول (۱) آمده‌اند [۱۸].

و پارامترها بر اساس آن تنظیم شوند [۵۸]. معیار امتیاز اف به‌عنوان میانگین هماهنگ دقت و حساسیت تعریف می‌شود و بهینه بودن آن نشان‌دهنده تعادل بین دقت و حساسیت است. معیار فراخوانی نسبت پیش‌بینی‌های مثبت صحیح به کل پیش‌بینی‌های مثبت را نشان

جدول ۱: معیارهای ارزیابی

فرمول	معیار
$Precision = \frac{TP}{TP + FP}$	صحت
$Recall = \frac{TP}{TP + FN}$	فراخوانی
$F1 - score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)}$	امتیاز اف

پژوهش، جهت دستیابی به مقادیر بهینه برای ابرپارامترهای فوق، از روش جستجوی گرید استفاده گردید [۶۰]. این روش با ثابت نگه‌داشتن تمامی پارامترها به‌جز یک پارامتر، سعی می‌کند مقدار مناسب برای آن پارامتر را از طریق درونیابی به دست آورد. این فرآیند برای تمامی ابرپارامترها به‌طور مشابه اجرا می‌شود. جدول (۲) خروجی آزمایش‌های مختلف را جهت دستیابی به ابرپارامترهای مناسب نشان می‌دهد.

همچنین در لایه تجمیع از شبکه پیشنهادی، گام برابر با ۱ و پدینگ در نظر گرفته شده است. این تنظیمات به‌منظور حفظ جزئیات داده‌های حساس و جلوگیری از کاهش قابل‌توجه اطلاعات ورودی در خروجی لایه طراحی شده‌اند. این طراحی منجر به کاهش محدود در ابعاد خروجی (به‌اندازه ورودی منهای اندازه پنجره) می‌شود و به اهداف پژوهش در تحلیل دقیق‌تر تغییرات جابجایی کمک می‌کند.

۴- بحث و نتایج

در این بخش، نتایج حاصل از اجرای مدل شبکه عصبی کاملاً متصل جهت تشخیص نقاط تغییر در سری زمانی جابجایی‌های سطح زمین، حاصل از تداخل سنجی راداری ارائه می‌شود. این بخش به بررسی بهینه‌سازی ابرپارامترها، دقت مدل، مقایسه با روش‌های موجود و تعمیم‌پذیری روش پیشنهادی می‌پردازد.

۴-۱- بهینه‌سازی ابرپارامترها

در یادگیری ماشین، هدف از بهینه‌سازی ابرپارامترها، یافتن مجموعه‌ای بهینه از پارامترهایی است که فرایند آموزش یک الگوریتم یادگیری را کنترل می‌کنند [۵۹]. در مقابل، سایر مقادیر پارامترها (معمولاً وزن‌های گره‌ها) از طریق فرآیند آموزش به دست می‌آیند. ابرپارامترهایی که می‌توان جهت بهینه‌سازی مدل پیشنهادی تنظیم کرد، شامل اندازه پنجره لایه میانگین متحرک، تعداد بخش‌های کانولوشن همراه با لایه‌های پولینگ، تعداد هسته‌های لایه‌های کاملاً متصل و توابع فعال‌سازی لایه‌های کاملاً متصل است. همچنین در این

^۱ Hyperparameter Optimization

جدول ۲: خروجی روش جستجوی گرید جهت دستیابی به ابرپارامترهای بهینه

۶	۵	۴	۳	۲	۱	ابریارامتر
۲۰	۲۰	۱۵	۱۵	۱۰	۱۰	اندازه پنجره لایه میانگین متحرک
۱	۱	۱	۳	۳	۳	تعداد بخش‌های تمام متصل، همراه با لایه‌های پولینگ
۲۵۰	۲۵۰	۲۵۰	۲۰۰	۱۵۰	۱۰۰	ابعاد پنجره استخراج ویژگی
<i>tanh</i>	<i>relu</i>	-	-	-	-	توابع فعال‌سازی
۹۹/۱۳	۹۵/۴۱	۹۲/۰۹	۹۲/۰۱	۹۱/۲۴	۸۶/۲۱	امتیاز اف

۴-۲- دقت مدل

جهت محاسبه دقت و کیفیت مدل، لازم است تعریف مناسبی برای آن ارائه دهیم. باتوجه به اینکه نقطه تغییر درواقع یک بازه تغییر است، عملکرد استنتاجی مدل نباید تنها بر اساس این ارزیابی شود که اگر مدل به‌طور دقیق نقطه تغییر را شناسایی کرد، پیش‌بینی صحیح و در غیر این صورت پیش‌بینی اشتباه است. بلکه باید فاصله بین پیش‌بینی تغییر و واقعیت تغییر به‌عنوان معیار ارزیابی قرار گیرد. به این صورت، یک بازه مبنا در نظر گرفته می‌شود و اگر فاصله بین پیش‌بینی تغییر و واقعیت تغییر کمتر از این بازه مبنا باشد، پیش‌بینی صحیح در نظر گرفته می‌شود و در غیر این صورت، پیش‌بینی اشتباه تلقی می‌شود. همچنین، اگر در یک بازه مبنا قبل و بعد از نقطه تغییر واقعی، هیچ تغییری پیش‌بینی نشده باشد، این به معنای آن است که مدل نتوانسته است این تغییر را پیش‌بینی نماید. باتوجه به بررسی‌های صورت گرفته، بازه تغییر معادل ۶۰ درصد از تابع توزیع گاوسی در نظر گرفته شده است که بر اساس شیب روند در نقاط تغییر متفاوت خواهد بود [۱۳]. با در نظر گرفتن تعریف فوق، می‌توان شاخص‌های مثبت صحیح^۱، مثبت کاذب^۲ و منفی کاذب^۳ را به‌صورت زیر تعریف نمود:

مثبت صحیح: زمانی که پیش‌بینی و واقعیت کمتر از

^۱ True Positive^۲ False Positive^۳ False Negative

۶۰ درصد تابع توزیع گاوسی فاصله داشته باشد.

مثبت کاذب: زمانی که ۶۰ درصد قبل و ۶۰ درصد بعد از تابع توزیع گاوسی پیش‌بینی، هیچ تغییر واقعی وجود نداشته باشد.

منفی کاذب: زمانی که ۶۰ درصد قبل و ۶۰ درصد بعد از تابع توزیع گاوسی تغییر واقعی، هیچ پیش‌بینی وجود نداشته باشد.

در این پژوهش، مجموعه داده‌های برجسب‌گذاری شده توسط کارشناسان خبره، پس از اعمال عملیات تقویت داده‌ها، به ۱۴،۷۶۴ نمونه سری زمانی جابجایی حاصل از تداخل سنجی راداری افزایش یافت. از این تعداد، حدود ۷۰ درصد (۱۰،۳۳۵ نمونه) برای آموزش شبکه و ۱۵ درصد (۲،۲۱۴ نمونه) برای ارزیابی و ۱۵ درصد دیگر (۲،۲۱۴ نمونه) برای آزمایش مورد استفاده قرار گرفتند.

در ادامه، نتایج دقت اجرای مدل شبکه عصبی کاملاً متصل پیشنهادی پس از آموزش و بهینه‌سازی، بر روی داده‌های آزمایشی در جدول (۳) نشان داده می‌شود.

بر اساس نتایج جدول (۳)، مشاهده می‌شود که دقت کلی مدل جهت شناسایی نقاط تغییر در مجموعه داده‌های آزمایشی به‌طور متوسط برابر با ۹۷٪ بوده است. این امر نشان‌دهنده کارایی بالای مدل در تشخیص تغییرات معنادار می‌باشد. همچنین، پس از بررسی دقت، می‌توان نمودار زبان^۴ را بر روی داده‌های


^۴ loss

داد. شکل (۷)، نمودار زیان مدل پیشنهادی را پس از ۲۰۰ تکرار نشان می‌دهد.

آموزشی و آزمایشی که یکی از جنبه‌های مؤثر در تحلیل و ارزیابی مدل پیشنهادی است، مورد بررسی قرار

جدول ۳: دقت روش پیشنهادی

روش	امتیاز اف (%)	صحت (%)	فراخوانی (%)
روش پیشنهادی	۹۸٫۱۲	۹۹٫۱۱	۹۷٫۰۴



شکل ۷: نمودار تغییرات زیان بر روی داده‌های آموزشی و آزمایشی

۱- مقایسه عملکرد مدل پیشنهادی با روش‌های سنتی و آماری: پس از پیاده‌سازی برخی از روش‌های سنتی که توسط پژوهشگران مختلفی از قبیل سیگنا [۲۶]، پتیت [۶۱]، حسین [۳۱] و قادرپور [۱۲] که قبلاً در بخش پیشینه پژوهش معرفی شده‌اند و همچنین پیاده‌سازی آزمون‌های آماری مانند *CUSUM* [۶۲] و مدل *ARIMA* [۶۳]، مشخص گردید که روش‌های کلاسیک فوق در شناسایی نقاط تغییر سری‌های زمانی که دارای نویز، رفتار فصلی شدید و تغییرات ناگهانی و پیچیده هستند، عملکرد مناسبی ندارند و از دقت کمتری در شناسایی نقاط تغییر برخوردار می‌باشند. در جدول (۴)، نتایج روش پیشنهادی با سایر روش‌های کلاسیک بر روی حدود ۱۰۰ نمونه سری زمانی که به صورت تصادفی انتخاب شده‌اند، ارائه می‌گردد.

با تحلیل نمودار موجود در شکل (۷) مشخص می‌شود که مدل با سرعت قابل قبولی به سوی مقدار بهینه همگرا شده است و این امر نشان‌دهنده بهترین حالت دقت در مدل پیشنهادی است. عملکرد مدل بر روی مجموعه داده‌های آموزشی و آزمایشی تقریباً برابر بوده و می‌توان نتیجه گرفت که مدل در تعمیم به داده‌های جدید توانایی بالایی دارد. همچنین، عملکرد مدل و نحوه همگرایی آن نشان می‌دهد که استفاده از باینری کراس آنتروپی برای شبکه‌ی پیشنهادی گزینه‌ای مناسب است.

۴-۳- مقایسه با روش‌های موجود

جهت ارزیابی بهتر، نتایج مدل پیشنهادی با سایر روش‌های سنتی و تکنیک‌های دیگر یادگیری ماشین مقایسه شده است. برخی از این مقایسه‌ها به شرح زیر است:

جدول ۴: مقایسه روش پیشنهادی با برخی از روش‌های کلاسیک

روش	امتیاز اف (%)	صحت (%)	فراخوانی (%)	زمان (ثانیه)
ایندکس تفاضل شیب [۲۶]	۳۰/۲۳	۳۰/۶۴	۳۱/۳۲	۴
معادله غیرپارامتریک [۶۱]	۳۳/۱۵	۳۳/۰۶	۳۳/۴۳	۵
گرادیان [۳۱]	۳۲/۱۷	۳۲/۴۴	۳۱/۹۶	۵
(STPD) شناسایی نقاط عطف متوالی [۱۲]	۶۲/۲۱	۶۵/۷۳	۶۵/۷۷	۸
CUSUM	۵۹/۳۲	۶۰/۱۱	۵۹/۸۳	۶
ARIMA	۶۱/۳۲	۶۳/۰۲	۶۲/۷۵	۴
روش پیشنهادی	۹۷/۶۴	۹۹/۱۵	۹۶/۱۸	۶

که در پژوهش فوق، با توجه به اینکه پارامترهای بسیار کمتری نسبت به شبکه‌های فوق داریم و دقت‌ها نیز در یک بازه‌ی مشابه هستند، استفاده از شبکه پیشنهادی به دلیل هزینه محاسباتی کمتر، منطقی و بهینه‌تر است.

در جدول (۵)، مقایسه روش پیشنهادی با سایر روش‌های عصبی عمیق بر روی حدود ۱۰۰ نمونه سری زمانی به صورت تصادفی ارائه شده است.

۲- مقایسه عملکرد مدل پیشنهادی با سایر روش‌های عصبی عمیق: پس از پیاده‌سازی مدل‌های *TGLSTM* [۱۳] و *LSTM* [۳۲] بر روی داده‌های فوق، مشخص گردید که این روش‌ها، به دلیل طراحی خاصشان برای داده‌های توالی‌دار و سری زمانی، معمولاً در شناسایی نقاط تغییر عملکرد مناسبی دارند. با این حال، هزینه محاسباتی این مدل‌ها به طور قابل توجهی بیشتر از روش پیشنهادی است؛ بنابراین، می‌توان نتیجه گرفت

جدول ۵: مقایسه روش پیشنهادی با برخی از روش‌های عصبی عمیق

روش	امتیاز اف (%)	صحت (%)	فراخوانی (%)	زمان (ثانیه)
TG-LSTM	۹۶/۳۴	۹۹/۰۲	۹۵/۹۶	۵۲
LSTM	۹۵/۲۵	۹۳/۲۴	۹۱/۱۲	۴۵
روش پیشنهادی	۹۷/۶۴	۹۹/۱۵	۹۶/۱۸	۶

گرافیک *NVIDIA GTX 1660 Super* محاسبه شده است. نرم‌افزار مورد استفاده شامل سیستم عامل *Ubuntu 20.04 LTS* و زبان *Python 3.9* بوده و از


تمام زمان‌های گزارش شده در جداول (۴) و (۵) با استفاده از سیستم سخت‌افزاری شامل پردازنده *Intel Core i7-10700K*، حافظه ۱۶ گیگابایت *RAM* و کارت

آزمون انجام می‌گیرد که نتایج شناسایی نقاط تغییر در برخی از نمونه‌های به‌دست‌آمده از مدل پیشنهادی نمایش داده می‌شود. با تحلیل این خروجی‌ها، توانایی مدل در شناسایی تغییرات معنادار و پیچیده قابل مشاهده است که در آن‌ها نقاط تغییر به‌طور دقیق مشخص شده‌اند. شکل (۸)، چند نمونه از خروجی مدل پیشنهادی در شناسایی نقاط تغییر در سری زمانی جابجایی‌های حاصل از تداخل سنجی راداری را نشان می‌دهد.


کتابخانه‌های *TensorFlow 2.8* و *Scikit-learn 1.1* برای پیاده‌سازی مدل‌ها بهره گرفته شده است. زمان اجرا با استفاده از ابزار *time* در *Python* اندازه‌گیری شده است. مقادیر زمان‌ها به‌صورت عدد صحیح رند شده‌اند تا ارائه جداول ساده‌تر و خواناتر باشد.

۴-۴ نتایج شناسایی نقاط تغییر


در این بخش، به ارزیابی بصری عملکرد مدل پیشنهادی جهت تشخیص نقاط تغییر در داده‌های جابجایی حاصل از تداخل سنجی راداری پرداخته می‌شود. ارزیابی مدل به‌منظور سنجش دقت و کارایی آن بر روی داده‌های




ب. سری زمانی با یک نقطه تغییر




الف. سری زمانی دارای ۲ نقطه تغییر




د. سری زمانی با دو نقطه تغییر



ج. سری زمانی با یک نقطه تغییر



ی. سری زمانی بدون نقطه تغییر



ه. سری زمانی با یک نقطه تغییر


شکل ۸: خروجی مدل پیشنهادی شناسایی نقاط تغییر به‌صورت تابع توزیع گاوسی

جزیره بزرگ گالاپاگوس و دورترین جزیره غربی آن است. مساحت این جزیره ۶۴۲ کیلومتر مربع (معادل ۲۴۸ مایل مربع) و ارتفاع آن ۱۴۷۶ متر (۴۸۴۳ فوت) از سطح دریا است. دهانه قله آن حدود ۶٫۵ کیلومتر (معادل ۴٫۰ مایل) عرض دارد و آخرین فوران‌ها در امتداد شکاف‌های شعاعی یا محیطی اطراف دهانه قله اتفاق افتاده است [۶۴]. این منطقه آتش‌فشانی به دلیل تغییرات معنادار در سرعت روند سری‌زمانی انتخاب‌شده، اهمیت ویژه‌ای دارد. به این ترتیب، داده‌های سری‌زمانی این منطقه با استفاده از تصاویر ماهواره‌ای سنتینل-۱ از شهریور ۲۰۱۴ تا خرداد ۲۰۱۸ در نرم‌افزار منت‌پای پردازش شده است. این بازه زمانی شامل تاریخ فوران آتش‌فشانی در شهریور ۲۰۱۷ نیز می‌باشد. شکل (۹) خروجی الگوریتم پیشنهادی بر روی سری‌زمانی منطقه موردنظر را نشان می‌دهد.

همان‌طور که از شکل (۸) مشاهده می‌شود، مدل شبکه عصبی پرسپترون چندلایه توانسته است الگوهای پیچیده را به خوبی شناسایی کند، درحالی‌که شناسایی چنین الگوهایی با روش‌های کلاسیک به‌سختی امکان‌پذیر است.


۴-۵- بررسی قابلیت تعمیم

جهت بررسی و تحلیل قابلیت تعمیم‌پذیری مدل به داده‌های جابجایی و نقاط جغرافیایی مختلف، لازم است که الگوریتم پیشنهادی شناسایی نقطه تغییر پیاده‌سازی و دقت آن بر روی داده‌های دیگر ارزیابی شود. بدین منظور، منطقه‌ای آتش‌فشانی به نام فرناندینا از جزایر گالاپاگوس انتخاب شد. این جزیره در حدود ۱۰۰۰ کیلومتری غرب ساحل سرزمین اصلی اکوادور واقع است و از سال ۱۸۰۰ تاکنون تقریباً ۳۰ فوران آتش‌فشانی در آن ثبت شده است. فرناندینا سومین



ب: نقشه جابجایی

الف: منطقه مورد مطالعه



ج: خروجی الگوریتم پیشنهادی


شکل ۹: منطقه مورد مطالعه و خروجی الگوریتم پیشنهادی تشخیص نقطه تغییر

جابجایی حاصل از تداخل سنجی راداری مورد بررسی و تحلیل قرار می گیرند. به طور کلی، شبکه عصبی پیشنهادی توانسته است عملکرد مناسبی در شناسایی نقاط تغییر عمده از خود نشان دهد، اما در برخی موارد نتایج به طور دقیق با واقعیت هم خوانی نداشته است. در شکل (۱۰)، برخی از نمونه ها نشان داده شده اند.

همان طور که در شکل (۹) مشاهده می شود، الگوریتم پیشنهادی به درستی نقطه تغییر را که در سپتامبر ۲۰۱۷ اتفاق افتاده و مربوط به فعالیت آتش فشان است، تشخیص داده است.

۴-۶- تحلیل خطاها و چالش ها

در این بخش، خطاها و چالش های مربوط به خروجی نتایج شبکه عصبی پیشنهادی در شناسایی نقاط تغییر



شکل ۱۰: چند نمونه از خروجی شبکه عصبی پیشنهادی که دارای خطا است

به دلیل واگرایی، تغییرات کمتری نسبت به خط رگرسیون فرضی که نماینده روند است، نشان می دهد و این مسئله موجب کاهش اعتماد مدل در حین پیش بینی شده است. همچنین، در نمونه (ب)، تغییرات انتهای روند به خوبی شناسایی نشده اند. دلیل این موضوع سایز پنجره میانگین متحرک است. همان طور که در بخش های قبلی ذکر شد، سایز پنجره لایه میانگین متحرک برابر با ۲۰ در نظر گرفته شده بود؛ اما تغییرات در فاصله ای کمتر از ۲۰ واحد به وقوع

در شکل (۱۰) و در نمونه (الف)، از جایی که مشخص شده است، تغییرات هر چند باعث ایجاد واکنش در پیش بینی مدل شده اند، اما در نهایت مدل با اعتماد بالایی قادر به تشخیص این تغییرات نبوده است. دلیل این رخداد در روندی است که لایه میانگین متحرک شناسایی کرده است. همان طور که در تصویر مشخص است، واریانس تغییرات داده ها (واگرایی از خط رگرسیون فرضی) باعث ایجاد خطا در تشخیص روند شده است. در واقع، میانگین متحرک در این نقطه

پیوسته‌اند و بنابراین مدل قادر به تشخیص این تغییر نبوده است. در نمونه آخر یعنی (ج)، نیز دو تغییر که به‌ظاهر در روند وجود داشته‌اند، توسط مدل شناسایی نشده‌اند. تغییر اول که در ابتدای نمودار است، شامل یک تغییر پله‌ای می‌باشد. با توجه به اینکه در مدل ارائه‌شده، تغییرات پله‌ای لحاظ نشده‌اند و روند پیش و پس‌از این تغییر یکسان بوده است، این تغییر شناسایی نشده است؛ اما در انتهای روند نیز یک تغییر مشاهده می‌شود که مدل با اعتماد کمی واکنش نشان داده است. در این چالش، دو نکته مهم وجود دارد:

■ اولاً به سبب محدودیت اندازه پنجره، مدل تا خط عمودی رسم‌شده قادر به تشخیص تغییرات به‌طور مؤثر است (همانند نمونه قبل) و پس‌از آن تغییرات با اعتماد کمتری تشخیص داده می‌شوند.

■ ثانیاً الگوی تغییر رخ داده تا پیش از خط عمودی سبز، همان الگویی است که از پیش‌تر تکرار شده است (دو دایره سبز یک الگوی مشترک دارند). به همین دلیل، نقطه علامت‌گذاری شده به‌عنوان یک نوسان تکراری (فصلی) در نظر گرفته شده، نه یک تغییر در روند. هرچند، اگر امکان لحاظ کردن بخش پایانی نمودار وجود داشت، این تغییر با اعتماد بیشتری شناسایی می‌شد.

با وجود عملکرد مطلوب شبکه عصبی پیشنهادی، تحلیل خطاها نشان داد که مدل در برخی موارد، به‌ویژه در شناسایی تغییرات کوچک و ناگهانی، دچار چالش‌هایی است. تعدادی از نقاط تغییر واقعی به‌عنوان عدم تغییر شناسایی شدند و همچنین، برخی از نقاط غیرتغییر به‌اشتباه به‌عنوان تغییر شناسایی شدند. این موارد به‌ویژه در شرایطی با نوسانات طبیعی و تغییرات جزئی، قابل توجه بود. این تحلیل خطاها می‌تواند راهگشای بهبودهای آتی باشد.

۵- نتیجه‌گیری

این تحقیق به بررسی و تحلیل روش‌های تشخیص نقاط تغییر در سری زمانی جابجایی‌های حاصل از تداخل سنجی راداری با تمرکز بر استفاده از شبکه‌های

عصبی پرسپترون چندلایه پرداخته است. نتایج حاصل از این مطالعه نشان‌دهنده توانایی بالای مدل پیشنهادی در شناسایی الگوهای پیچیده و تحلیل تغییرات جابجایی بر اساس داده‌های سری زمانی تداخل‌سنجی راداری در مطالعات زمین‌شناسی، مدیریت منابع طبیعی و برنامه‌ریزی‌های شهری است. همچنین، دقت بالا و قابلیت شناسایی دقیق نقاط تغییر به محققان و تصمیم‌گیرندگان کمک می‌کند تا ارزیابی‌های بهتری از تغییرات سطح زمین داشته باشند. مدل پیشنهادی در مقایسه با روش‌های کلاسیک، دقت و کارایی بالاتری در شناسایی نقاط تغییر از خود نشان می‌دهد. این امر به دلیل توانایی شبکه‌های عصبی در یادگیری الگوهای پیچیده و روابط غیرخطی در داده‌ها است. علاوه بر این، روش پیشنهادی به دلیل هزینه محاسباتی کمتر نسبت به سایر روش‌های موجود در یادگیری عمیق، موجب کاهش معنادار زمان پردازش می‌شود. با این حال، استفاده از این شبکه‌ها محدودیت‌ها و چالش‌هایی از قبیل نیاز به داده‌های بزرگ جهت آموزش مدل، انتخاب بهینه پارامترهای مدل و حساسیت به نویز دارند. همچنین، به‌منظور ارتقای بیشتر دقت و کارایی، پیشنهاد می‌شود که از داده‌های شبیه‌سازی‌شده برای آموزش مدل استفاده شود تا نیازی به کارشناسان خبره جهت تشخیص نقاط تغییر نباشد. علاوه بر این، برای درک بهتر الگوهای تغییر و ارائه راهکارهای مدیریتی مؤثرتر، بهتر است که تغییرات در زمان و مکان نیز به‌طور هم‌زمان بررسی شوند.

۶- قدردانی

قابل ذکر است، جناب آقای مهندس مهدی خوش‌لهجه آذر با مشاوره‌های ارزشمند همه‌جانبه و همچنین جناب آقای مهندس حسین کریمی با توصیه‌های دقیق و سازنده در زمینه معماری پیشنهادی و الگوریتم‌های یادگیری ماشین، کمک‌های شایانی به شکل‌گیری این پژوهش داشته‌اند. نویسندگان مقاله از ایشان کمال قدردانی را به‌عمل می‌آورند.

مراجع

- [1] A. Ibrahim, A. Wayayok, H. Z. M. Shafri, and N. M. J. J. o. H. X. Toridi, "Remote Sensing Technologies for Unlocking New Groundwater Insights: A Comprehensive Review," vol. 23, pp. 100175, 2024.
- [2] O. Sarychikhina, D. G. Palacios, L. A. D. Argote, and A. G. J. J. o. S. A. E. S. Ortega, "Application of satellite SAR interferometry for the detection and monitoring of landslides along the Tijuana-Ensenada Scenic Highway, Baja California, Mexico," vol. 107, pp. 103030, 2021.
- [3] R. Bokhari, H. Shu, A. Tariq, N. Al-Ansari, R. Guluzade, T. Chen, A. Jamil, and M. J. H. Aslam, "Land subsidence analysis using synthetic aperture radar data," vol. 9, no. 3, 2023.
- [4] A. Pepe, and F. J. A. S. Calò, "A review of interferometric synthetic aperture RADAR (InSAR) multi-track approaches for the retrieval of Earth's surface displacements," vol. 7, no. 12, pp. 1264, 2017.
- [5] Y. Xia, "Synthetic aperture radar interferometry," Sciences of geodesy-I: Advances and future directions, pp. 415-474: Springer, 2010.
- [6] S. Li, W. Xu, and Z. J. G. Li, "Review of the SBAS InSAR Time-series algorithms, applications, and challenges," vol. 13, no. 2, pp. 114-126, 2022.
- [7] A. Ferretti, C. Prati, and F. J. I. T. o. g. Rocca, "Permanent scatterers in SAR interferometry," vol. 39, no. 1, pp. 8-20, 2001.
- [8] O. Oktar, H. Erdoğan, F. Poyraz, and İ. J. A. J. o. G. Tiryakioğlu, "Investigation of deformations with the GNSS and PSInSAR methods," vol. 14, pp. 1-16, 2021.
- [9] A. Ferretti, F. Novali, R. Bürgmann, G. Hilley, and C. J. E. Prati, Transactions American Geophysical Union, "InSAR permanent scatterer analysis reveals ups and downs in San Francisco Bay area," vol. 85, no. 34, pp. 317-324, 2004.
- [10] S. Xiong, C. Wang, X. Qin, B. Zhang, and Q. J. R. S. Li, "Time-series analysis on persistent scatter-interferometric synthetic aperture radar (PS-InSAR) derived displacements of the Hong Kong-Zhuhai-Macao Bridge (HZMB) from Sentinel-1A observations," vol. 13, no. 4, pp. 546, 2021.
- [11] S. Aminikhanghahi, and D. J. J. K. Cook, "A survey of methods for time series change point detection," vol. 51, no. 2, pp. 339-367, 2017.
- [12] E. Ghaderpour, B. Antonielli, F. Bozzano, G. ScarasciaMugnozza, and P. J. C. Mazzanti, "A fast and robust method for detecting trend turning points in InSAR displacement time series," pp. 105546, 2024.
- [13] F. Lattari, A. Rucci, and M. J. I. T. o. G. Matteucci, "A deep learning approach for change points detection in InSAR time series," vol. 60, pp. 1-16, 2022.
- [14] M. Khoshlahjeh Azar, A. Hamedpour, and Y. Maghsoudi, "Analysis of the deformation behavior and sinkhole risk in Kerdabad, Iran using the PS-InSAR method," vol. 13, no. 14, pp. 2696, 2021.
- [15] S. Shami, M. K. Azar, F. Nilfouroushan, M. Salimi, and M. A. M. J. I. J. o. A. E. O. Reshadi, "Assessments of ground subsidence along the railway in the Kashan plain, Iran, using Sentinel-1 data and NSBAS algorithm," vol. 112, pp. 102898, 2022.
- [16] M. Zhu, X. Wan, B. Fei, Z. Qiao, C. Ge, F. Minati, F. Vecchioli, J. Li, and M. J. R. S. Costantini, "Detection of building and infrastructure instabilities by automatic spatiotemporal analysis of satellite SAR interferometry measurements," vol. 10, no. 11, pp. 1816, 2018.
- [17] J. Li, P. Fearnhead, P. Fryzlewicz, and T. J. J. o. t. R. S. S. B. S. M. Wang, "Automatic change-point detection in time

- series via deep learning*," vol. 86, no. 2, pp. 273-285, 2024.
- [18] S. A. Fakhri, M. Satari Abrovi, H. Zakeri, A. Safdarinezhad, and A. J. I. J. o. P. E. Fakhri, "Pavement crack detection through a deep-learned asymmetric encoder-decoder convolutional neural network," vol. 24, no. 1, pp. 2255359, 2023.
- [19] D. Amr, X.-l. Ding, and R. J. T. E. J. o. R. S. Fekry, "A machine learning-based method for multi-satellite SAR data integration," vol. 27, no. 1, pp. 1-9, 2024.
- [20] R. Kruse, S. Mostaghim, C. Borgelt, C. Braune, and M. Steinbrecher, "Multi-layer perceptrons," *Computational intelligence: a methodological introduction*, pp. 53-124: Springer, 2022.
- [21] A. H. Abd-elaziem, and T. H. J. I. J. o. A. i. A. C. I. Soliman, "A Multi-Layer Perceptron (MLP) Neural Networks for Stellar Classification: A Review of Methods and Results," vol. 3, no. 10.54216, 2023.
- [22] S. Liu, L. Wang, W. Zhang, Y. He, and S. J. G. J. Pijush, "A comprehensive review of machine learning - based methods in landslide susceptibility mapping," vol. 58, no. 6, pp. 2283-2301, 2023.
- [23] A. Ferretti, E. Passera, and R. Capes, *End-to-End Implementation and Operation of the European Ground Motion Service (EGMS): Algorithm Theoretical Basis Document, Technical Report EGMS-D3-ALG-SC1-2.0-006*. 2021. Available online: <https://...>, 2021.
- [24] M. Costantini, F. Minati, F. Trillo, A. Ferretti, E. Passera, A. Rucci, J. Dehls, Y. Larsen, P. Marinkovic, and M. Eineder, "EGMS: Europe-wide ground motion monitoring based on full resolution InSAR processing of all Sentinel-1 acquisitions," pp. 5093-5096, 2022.
- [25] F. Cigna, C. Del Ventisette, V. Liguori, and N. J. N. H. Casagli, "Advanced radar-interpretation of InSAR time series for mapping and characterization of geological processes," vol. 11, no. 3, pp. 865-881, 2011.
- [26] F. Cigna, D. Tapete, and N. J. N. p. i. g. Casagli, "Semi-automated extraction of Deviation Indexes (DI) from satellite Persistent Scatterers time series: tests on sedimentary volcanism and tectonically-induced motions," vol. 19, no. 6, pp. 643-655, 2012.
- [27] M. Berti, A. Corsini, S. Franceschini, J. J. N. H. Iannacone, and E. S. Sciences, "Automated classification of Persistent Scatterers Interferometry time series," vol. 13, no. 8, pp. 1945-1958, 2013.
- [28] F. Raspini, S. Bianchini, A. Ciampalini, M. Del Soldato, L. Solari, F. Novali, S. Del Conte, A. Rucci, A. Ferretti, and N. J. S. r. Casagli, "Continuous, semi-automatic monitoring of ground deformation using Sentinel-1 satellites," vol. 8, no. 1, pp. 7253, 2018.
- [29] A. Refice, G. Pasquariello, F. J. I. G. Bovenga, and R. S. Letters, "Model-free characterization of SAR MTI time series," vol. 19, pp. 1-5, 2020.
- [30] F. Bovenga, G. Pasquariello, and A. J. R. S. Refice, "Statistically-based trend analysis of MTInSAR displacement time series," vol. 13, no. 12, pp. 2302, 2021.
- [31] E. Hussain, A. Novellino, C. Jordan, and L. J. R. S. Bateson, "Offline-online change detection for Sentinel-1 InSAR time series," vol. 13, no. 9, pp. 1656, 2021.
- [32] A. Kulshrestha, L. Chang, and A. J. I. J. o. S. T. i. A. E. O. Stein, "Use of LSTM for sinkhole-related anomaly detection and classification of InSAR deformation time series," vol. 15, pp. 4559-4570, 2022.
- [33] X. Shao, and X. J. J. o. t. A. S. A. Zhang, "Testing for change points in time series," vol. 105, no. 491, pp. 1228-1240, 2010.
- [34] J. C. J. C. E. Valderrama Balaguera, "Precipitation forecast estimation applying the change point method and ARIMA," vol. 11, no. 1, pp. 2340191, 2024.
- [35] T. C. Mills, *Applied time series analysis: A*

- practical guide to modeling and forecasting: Academic press, 2019.
- [36] T. Islam, M. S. Hafiz, J. R. Jim, M. M. Kabir, and M. J. H. A. Mridha, "A systematic review of deep learning data augmentation in medical imaging: Recent advances and future research directions," pp. 100340, 2024.
- [37] K. Alomar, H. I. Aysel, and X. J. J. o. I. Cai, "Data augmentation in classification and segmentation: A survey and new strategies," vol. 9, no. 2, pp. 46, 2023.
- [38] H. Jalali, and G. J. a. p. a. Kasneci, "Expert Selection in Distributed Gaussian Processes: A Multi-label Classification Approach," 2022.
- [39] Y. Li, E. Jiang, Z. Ni, W. Li, M. Huang, F. Zhao, F. Liu, Y. Ye, and S. J. C. M. S. Bai, "A study of the role of data and model uncertainty in active learning," vol. 247, pp. 113512, 2025.
- [40] X. J. J. o. E. Jiang, and E. Research, "Gaussian Distributions in Machine Learning," vol. 9, no. 3, pp. 184-186, 2024.
- [41] T. Ye, J. Nie, J. Wang, P. Shi, and Z. J. S. e. r. Wang, "Performance of detrending models of crop yield risk assessment: evaluation on real and hypothetical yield data," vol. 29, pp. 109-117, 2015.
- [42] A. Kumar, A. Kumar, R. P. Singh, P. Kumar, and P. V. J. A. R. J. o. A. Singh, "A Comparative Study of Detrending Methods on Crop Yield Time Series for Drought Studies," vol. 17, no. 3, pp. 191-204, 2024.
- [43] X. Su, X. Yan, and C. L. J. W. I. R. C. S. Tsai, "Linear regression," vol. 4, no. 3, pp. 275-294, 2012.
- [44] S. D. Walton, and K. R. J. F. i. A. Murphy, "Superposed epoch analysis using time-normalization: A Python tool for statistical event analysis," vol. 9, pp. 1000.145, 2022.
- [45] S. Bhanja, and A. J. a. p. a. Das, "Impact of data normalization on deep neural network for time series forecasting," 2018.
- [46] D. Agliz, and A. J. I. J. o. C. A. Atmani, "Seismic signal classification using multi-layer perceptron neural network," vol. 79, no. 15, 2013.
- [47] A. P. Wibawa, A. B. P. Utama, H. Elmunsyah, U. Pujiyanto, F. A. Dwiyanto, and L. J. J. o. b. D. Hernandez, "Time-series analysis with smoothed Convolutional Neural Network," vol. 9, no. 1, pp. 44, 2022.
- [48] B.-S. Kim, Y.-S. Moon, M.-J. Choi, and J. J. M. T. Kim, "Interactive noise-controlled boundary image matching using the time-series moving average transform," vol. 72, pp. 2543-2571, 2014.
- [49] S. Hansun, "A new approach of moving average method in time series analysis", in 2013 conference on new media studies (CoNMedia), IEEE, pp. 1-4, 2013.
- [50] L. Zhao, and Z. J. S. R. Zhang, "A improved pooling method for convolutional neural networks," vol. 14, no. 1, pp. 1589, 2024.
- [51] C. J. E. S. w. A. Özdemir, "Avg-topk: A new pooling method for convolutional neural networks," vol. 223, pp. 119892, 2023.
- [52] A. Borovykh, C. W. Oosterlee, and S. M. J. J. o. C. S. Bohté, "Generalization in fully-connected neural networks for time series forecasting," vol. 36, pp. 101020, 2019.
- [53] J. Jin, A. Dundar, and E. J. a. p. a. Culurciello, "Flattened convolutional neural networks for feedforward acceleration," 2014.
- [54] S. S. Basha, S. R. Dubey, V. Pulabaigari, and S. J. N. Mukherjee, "Impact of fully connected layers on performance of convolutional neural networks for image classification," vol. 378, pp. 112-119, 2020.
- [55] S. Kiliçarslan, and M. J. E. S. w. A. Celik, "RSigELU: A nonlinear activation function for deep neural networks," vol. 174, pp. 114805, 2021.

- [56] A. Creswell, K. Arulkumaran, and A. A. J. a. p. a. Bharath, "On denoising autoencoders trained to minimise binary cross-entropy," 2017.
- [57] O. Hospodarskyy, V. Martsenyuk, N. Kukharska, A. Hospodarskyy, and S. Sverstiuk, "Understanding the Adam Optimization Algorithm in Machine Learning," 2024.
- [58] S. A. Fakhri, S. Motayyeb, M. Saadatseresht, H. Zakeri, and V. Mousavi, "COMPARISON OF UAV IMAGE SPATIAL RESOLUTION BASED ON THE SIEMENS STAR TARGET," *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. X-4/W1-2022, pp. 143-150, 2023.
- [59] L. Yang, and A. J. N. Shami, "On hyperparameter optimization of machine learning algorithms: Theory and practice," vol. 415, pp. 295-316, 2020.
- [60] D. M. Belete, M. D. J. I. J. o. C. Huchaiah, and Applications, "Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results," vol. 44, no. 9, pp. 875-886, 2022.
- [61] A. Pettitt, "A non - parametric approach to the change - point problem," vol. 28, no. 2, pp. 126-135, 1979.
- [62] S. Lee, S. Lee, and M. J. A. S. C. Moon, "Hybrid change point detection for time series via support vector regression and CUSUM method," vol. 89, pp. 106101, 2020.
- [63] B. Basnayake, N. J. S. Chandrasekara, and Applications, "Use of change point analysis in seasonal ARIMA models for forecasting tourist arrivals in Sri Lanka," vol. 20, no. 2, pp. 103-121, 2022.
- [64] Z. Yunjun, H. Fattahi, F. J. C. Amelung, and Geosciences, "Small baseline InSAR time series analysis: Unwrapping error correction and noise reduction," vol. 133, pp. 10.4331, 2019.



Change Point Detection (CPD) in InSAR Time Series using MLP: (Case study: Europe Continent)

Seyed Arya Fakhri ¹, Mehran Sattari ^{2*}

1- Ph.D. Candidate of Photogrammetry in Department of Geomatics Engineering, Faculty of Civil Engineering and Transportation, University of Isfahan

2- Assistant professor in Department of Geomatics Engineering, Faculty of Civil Engineering and Transportation, University of Isfahan

Abstract

The Earth's surface is constantly changing due to natural phenomena such as earthquakes and volcanoes, as well as human activities like groundwater extraction and mining. In recent years, the increased awareness of the risks associated with ground movements has led to a higher demand for comprehensive and reliable information regarding these displacements. Various methods have been proposed to estimate land surface displacement, among which time-series analysis of displacement derived from InSAR is one of the most important sources for assessing the extent of surface displacements over time. However, the post-processing of time-series data has received less attention. The most efficient post-processing techniques for time-series analysis involve identifying the change points in the time series. By detecting these change points, it is possible not only to extract spatial information but also to analyze the temporal aspect of the results. This study explores a method for identifying the change points in the time series of land displacements caused by geological and human activities in Europe, utilizing data from the EGMS system. Given the challenges in detecting the change points in displacement time series derived from interferometry, such as noise and seasonal behaviors, the use of a multilayer perceptron neural network can be effective in recognizing complex patterns and nonlinear relationships. The results demonstrate an accuracy of over 97% in detecting the change points, highlighting the model's ability to identify the changes with appropriate precision, which can aid in a better understanding of Earth's dynamics. Furthermore, the capabilities of the proposed model in analyzing the displacement data and identifying the changes were evaluated, and the results were compared with the conventional methods. Based on this comparison, the proposed method outperforms the statistical approaches in terms of accuracy and exhibits approximately 9 times lower computational cost compared to the other deep learning methods.

Key words: InSAR, Change point detection (CPD), Time series, MLP, EGMS.