نشریه علمی مهندسی فناوری اطلاعات مکانی

سال دوازدهم، شماره چهارم، زمستان ۱۴۰۳

Vol.12, No.4, Winter 2025

۱۰۹ -۱۳٤

مقاله پژوهشی

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 حمل‌ونقل، دانشگاه اصفهان

۲- استادیار دانشکده مهندسی عمران و حمل‌ونقل، دانشگاه اصفهان

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

چکیده

سطح زمین به‌دلیل 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 قابل‌اعتماد درباره این جابجایی‌ها شده است. تاکنون روش‌های گوناگونی به‌منظور تخمین جابجایی سطح زمین ارائه‌شده‌اند که ازجمله مهم‌ترین منابع جهت برآورد میزان جابجایی سطح زمین در طول زمان، آنالیز سری زمانی جابجایی حاصل از تداخل‌سنجی راداری است. بااین‌حال، پس‌پردازش داده‌های سری زمانی کمتر موردتوجه قرار گرفته است. کارآمدترین روش‌های پس‌پردازش آنالیز سری زمانی، شناسایی نقاط تغییر در روند سری زمانی است. به‌نحوی‌که 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. باتوجه‌به 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 به‌عنوان یکی از ساده‌ترین و پرکاربردترین شبکه‌های عصبی در یادگیری ماشین می‌تواند جهت شناسایی الگوهای پیچیده و روابط غیرخطی مؤثر باشد. نتایج به‌دست‌آمده 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 موردبررسی قرار گرفته و نتایج حاصل با روش‌های متداول مقایسه شده است. بر اساس این مقایسه، روش پیشنهادی ازنظر دقت، عملکرد بسیار بهتری نسبت به روش‌های آماری دارد و همچنین در مقایسه با سایر روش‌های یادگیری عمیق، حدود ۹ برابر هزینه محاسباتی کاهش‌یافته است.

کلیدواژه‌ها : تداخل‌سنجی راداری، شناسایی نقطه تغییر، شبکه‌های عصبی پرسپترون چندلایه، سری‌زمانی، سامانه *EGMS*.

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

تلفن: ۰۹۱۳۱۱۵۵۳۳۷

Email: sattari@eng.ui.ac.ir

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

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[1] 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 تداخل‌سنجی 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 سری‌زمانی حاصل از تداخل‌سنجی 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 تداخل‌سنجی راداری است، صرفاً با درون‌یابی خطی بر رفتار سری زمانی جابجایی ایجاد می‌شود [۹]. بااین‌حال، 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 تداخل‌سنجی 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[2] در 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؛ به‌عبارت‌دیگر، 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

[1] *Interferometric Synthetic Aperture Radar (InSAR)*

[2] *Change Point Detection (CPD)*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

جهت شناسایی این نقاط ارائه شده است. به‌طورکلی، این روش‌ها را می‌توان به دو دسته مبتنی بر آمار و مبتنی بر یادگیری ماشین تقسیم‌بندی نمود [۱۱].

روش‌های آماری مرسوم در شناسایی نقاط تغییر، با توجه به وجود پیچیدگی‌ها و ناهنجاری‌های متعددی مانند کمبود داده‌های سری‌های زمانی به دلیل عدم برداشت تصویر در برخی از زمان‌ها، عدم یکسان بودن فاصله نمونه‌برداری، وجود رفتارهای فصلی[1] وجود پله در سری زمانی، غیرثابت بودن در زمان، وجود نویز و رفتار تلفیقی در داده‌های سری زمانی حاصل از تداخل‌سنجی راداری، کارایی خود را ازدست‌داده و غالباً در شناسایی الگوهای پیچیده و تغییرات ناگهانی از دقت کافی برخوردار نیستند [۱۳، ۱۴ و ۱۵]. همچنین این روش‌ها به دلیل وجود داده‌های بسیار زیاد (از چند ده‌هزار تا چند ده‌میلیون) حاصل از نتایج تداخل‌سنجی راداری، ازلحاظ زمان و بار محاسباتی مقرون‌به‌صرفه نیستند [۱۶]؛ بنابراین، نیاز به رویکردهای نوین و کارآمدتری جهت تحلیل و پردازش این داده‌ها احساس می‌شود.

ازاین‌رو، با توجه به پیشرفت روش‌های مبتنی بر یادگیری ماشین، می‌توان از الگوریتم‌های متعدد یادگیری ماشین و یادگیری عمیق جهت شناسایی نقاط تغییر استفاده کرد [۱۷]. این الگوریتم‌ها به‌طور خاص، به کار با داده‌های پیچیده و بزرگ می‌پردازند و قابلیت‌های بی‌نظیری در استخراج ویژگی‌ها و شناسایی الگوها دارند [۱۸]. همچنین، این روش‌ها می‌توانند به‌طور مؤثری در تحلیل داده‌های تداخل‌سنجی راداری به کار گرفته شوند و نقاط تغییر را با دقت و سرعت بالایی شناسایی نمایند [۱۹]. بااین‌حال، جهت آموزش مدل‌های مبتنی بر یادگیری، وجود داده‌های آموزشی باکیفیت که نمودی از واقعیت داشته باشند، از اهمیت بالایی برخوردار است.

در این راستا، استفاده از شبکه عصبی پرسپترون چندلایه[2] به‌عنوان یکی از ساده‌ترین و پرکاربردترین شبکه‌های عصبی در یادگیری ماشین، امکان شناسایی الگوهای پیچیده و روابط غیرخطی در داده‌ها را فراهم میاورد [۲۰]. این نوع شبکه‌ها، در مقایسه با سایر شبکه‌های عصبی عمیق، از حجم محاسبات و پارامترهای کمتری برخوردار بوده که موجب کاهش چشم‌گیر زمان محاسباتی می‌شوند [۲۱]. همچنین این مدل‌ها با توانایی یادگیری ویژگی‌های عمیق و غیرخطی، به شناسایی نقاط تغییر در داده‌های پیچیده نیز کمک کرده و باقابلیت مدل‌سازی روابط غیرخطی پیچیده در پدیده‌های طبیعی و زمین‌شناسی، موجب می‌شوند که نتایج دقیق‌تری حاصل گردد [۲۲].

هدف این مقاله، توسعه روشی جهت تشخیص نقاط تغییر در سری زمانی جابجایی‌های زمین حاصل از تداخل‌سنجی راداری بر مبنای شبکه عصبی پرسپترون چندلایه دارای لایه‌های کاملاً متصل[3] با استفاده از سری‌های زمانی جابجایی موجود در سامانه پایش حرکت سطح زمین در قاره اروپا[4] است. این داده‌ها توسط آژانس فضایی اروپا[5] و در چارچوب پروژه‌های همکاری بین‌المللی درزمینهٔ سنجش‌ازدور و ژئوفیزیک تهیه‌شده‌اند و به‌عنوان یک منبع معتبر و جامع درزمینهٔ جابجایی سطح زمین در قاره اروپا مورداستفاده قرار می‌گیرند [۲۳ و ۲۴]. همچنین این تحقیق به بررسی قابلیت‌های شبکه عصبی پرسپترون چندلایه کاملاً متصل در شناسایی و تحلیل تغییرات زمین پرداخته و نتایج حاصل را با روش‌های سنتی و پیشرفته مقایسه خواهد کرد. در این راستا، اهداف تحقیق شامل بهبود دقت شناسایی نقاط تغییر در داده‌های سری زمانی جابجایی، کاهش هزینه‌های محاسباتی مرتبط با شناسایی نقاط تغییر، و بررسی قابلیت تعمیم‌پذیری روش پیشنهادی به داده‌های دیگر است.

[1] *Seasonality*

[2] *Multi-layer Perceptron (MLP)*

[3] *Fully Connected Networks (FCNs)*

[4] *European Ground Motion Service (EGMS)*

[5] *European Space Agency (ESA)*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

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 مورداستفاده و معیارهای ارزیابی دقت ارائه می‌گردد. در بخش بعد، بحث و نتایج بررسی و تحلیل شده و درنهایت، 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 تداخل سنجی راداری موردتوجه قرارگرفته 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 مورداستفاده 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. ازجمله 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 سری‌زمانی تداخل‌سنجی بر اساس رویکرد ریاضیات ساده طراحی کردند. روش پیشنهادی به‌صورت نیمه‌خودکار بوده و نیازمند دخالت اپراتور است. در این روش، تاریخچه سری‌زمانی باید در دسترس باشد تا مدل بتواند کارایی خود را حفظ نماید. همچنین، این روش تنها قادر به شناسایی یک نقطه تغییر در سری‌زمانی 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، دوخطی و ناپیوسته است. روش مورداستفاده در این پژوهش بر اساس معیار اطلاعات بیزی-شوارتز است. ازجمله 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؛ حال‌آنکه سری‌های زمانی جابجایی تداخل‌سنجی راداری دارای پیچیدگی‌های فراوانی هستند. همچنین، پیش‌فرض اصلی این روش ایستایی سری‌زمانی 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 سری‌زمانی استفاده می‌کند. ازجمله 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 سری‌زمانی استفاده کردند. این معیار با بهره‌گیری از بی‌نظمی

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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 به‌دلیل هزینه محاسباتی پایین و عدم نیاز به تعریف مدل، به‌عنوان معیار مناسبی شناخته می‌شود. نتایج این روش بر روی داده‌های شبیه‌سازی‌شده و چند نمونه داده واقعی پیاده‌سازی شد. ازجمله 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) به‌منظور 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 به‌صورت خودکار حداقل پارامترهای موردنیاز برای مدل‌سازی سری زمانی را با سطح اطمینان از پیش تعیین‌شده به‌دست آورد. این روش اگرچه عمومی است، اما به‌طور خاص برای تقریب روندهای خطی قطعه‌مبنای استفاده می‌شود. پس از شناسایی بهترین تقریب چندجمله‌ای، نقاط تغییر به‌سادگی از مدل استخراج می‌شوند. ازجمله مشکلات این پژوهش می‌توان به استفاده صرفاً از مدل‌های چندجمله‌ای، آزمون در محیط شبیه‌سازی‌شده 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 به‌صورت برخط و بُرون‌خط پیشنهاد دادند. در این پژوهش، شناسایی نقطه تغییر به‌صورت برخط (با داده‌های آنی) و بُرون‌خط (با داده‌های پردازش‌شده پیشین) انجام شد. فرض اصلی این پژوهش در دسترس بودن حداقل پنج سال داده سنتینل-۱ برای استفاده از معیارهای آماری جهت شناسایی نقطه تغییر است. همچنین، از همبستگی مکانی جابجایی‌ها برای کاهش زمان پردازش‌ها بهره‌برداری شده است. بااین‌حال، درصورتی‌که 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 به‌صورت انحرافات و تغییرات تدریجی در سری‌زمانی تداخل‌سنجی راداری پیشنهاد می‌کند، اما دارای ضعف‌هایی است که ازجمله‌ی 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 سری‌زمانی می‌شود [۳۱].

کالشرتزه 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 مورداستفاده در این تحقیق شامل ۱۰۴ تصویر از ماهواره سنتیتل *A-1* مربوط به سال‌های ۲۰۱۵ و ۲۰۱۸ بودند که بر روی منطقه‌ای تحت تأثیر فروچاله به ابعاد ۶۳×۴۴ کیلومترمربع در ایرلند جمع‌آوری شده‌اند. نتایج نشان می‌دهند که سری‌های زمانی با روند خطی را می‌توان با دقت ۹۹٪ به‌درستی طبقه‌بندی کرد، درحالی‌که دقت طبقه‌بندی سری‌های زمانی با تغییرات غیرعادی نظیر گام‌های ناگهانی و تغییرات سرعت ناگهانی به ۶۲٪ کاهش می‌یابد.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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[1] 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. بااین‌حال، 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 شبیه‌سازی‌شده 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[2] پیشنهاد شد و با سایر روش‌های تشخیص نقطه تغییر نیز مقایسه گردید. با استفاده از مجموعه‌ای بزرگ از سری‌های زمانی شبیه‌سازی‌شده با انواع مختلف نویز، نشان داده شد که روش پیشنهادی ازنظر 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 شبیه‌سازی‌شده 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. بااین‌حال، روش‌های کلاسیک شامل آزمون‌های آماری نظیر آزمون مجموع پسماندهای عطفی انباشته[3] آزمون مک‌نیل و آزمون روند خطی به‌طور گسترده‌ای جهت شناسایی تغییرات در داده‌های سری زمانی به کار

[1] *Time-gated LSTM (TGLSTM)*

[2] *Sequential Turning Point Detection (STPD)*

[3] *Cumulative Sum (CUSUM)*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

می‌روند [۳۳]. از مزایای این روش‌ها می‌توان به‌سادگی، 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[1] 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 چالش‌برانگیز باشد [۳۵]. ازاین‌رو، 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 مورداستفاده 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 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 فشرده‌سازی ویژگی‌ها، از لایه‌های پولینگ استفاده شده است. همچنین، برای افزایش ظرفیت مدل و یادگیری روابط غیرخطی، لایه‌های کاملاً متصل به‌کار 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[2] استفاده شده است.

۳-۱- منطقه مطالعاتی

منطقهٔ 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 مورداستفاده در این تحقیق از سامانه *EGMS*[3] 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 درزمینهٔ جابجایی زمین استفاده‌شده 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

[1] *Autoregressive Integrated Moving Average (ARIMA)*

[2] *Data Augmentation*

[3] *European Ground Motion Service*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

جابجایی می‌باشند.

همان‌طور که از شکل (۱) مشاهده می‌شود، از اکثر نواحی قاره اروپا به‌طور تصادفی داده انتخاب شده و درمجموع ۱۰،۰۰۰ سری زمانی جابجایی از سامانه *EGMS* بارگیری گردید. شکل (۲) نمونه‌هایی از داده‌های سامانه *EGMS* را نشان می‌دهد.

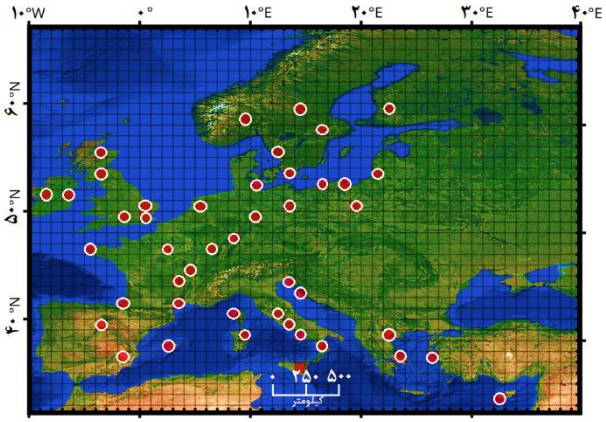

شکل ۱: منطقه مورد مطالعاتی (دایره‌های قرمز: نواحی مورد مطالعه)

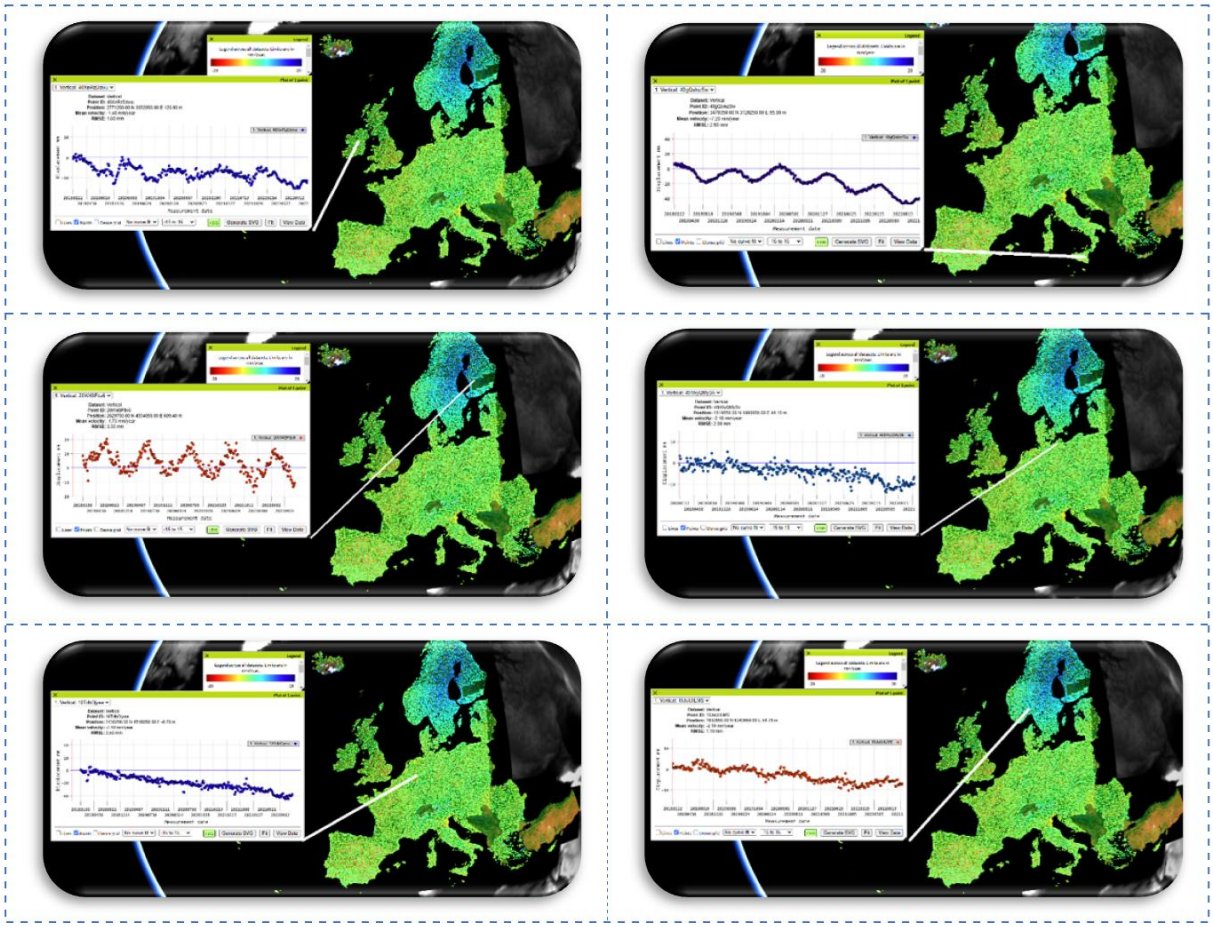

شکل ۲: چند نمونه از داده‌های سامانه *EGMS* که هر سری زمانی مربوط به یک پراکنش‌گر دائم می‌باشد.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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[1]

تقویت داده‌ها به‌منظور بهبود عملکرد مدل و کاهش خطر بیش‌برازش، امری ضروری است، به‌ویژه زمانی که تعداد داده‌های برچسب‌گذاری‌شده 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 توزیع‌شده، شامل توزیع نرمال، پوآسن 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 لایهٔ بعدی ارتباط دارد. شبکه پیشنهادی با معماری‌های قبلی شناسایی نقطه تغییر در سری زمانی جابجایی‌های حاصل از تداخل‌سنجی راداری که اخیراً موردبررسی قرارگرفته‌اند، تفاوت دارد [۱۳ و ۳۲]. به‌طورکلی، 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 فشرده‌سازی ویژگی‌ها، از لایه‌های پولینگ استفاده‌شده است. همچنین، برای افزایش ظرفیت مدل و یادگیری روابط غیرخطی، لایه‌های کاملاً متصل به‌کار گرفته‌شده‌اند. درنهایت، 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 روی‌داده‌های تداخل‌سنجی راداری اعمال‌شده 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 به‌کار 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 تداخل‌سنجی 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.

[1] *Data augmentation*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

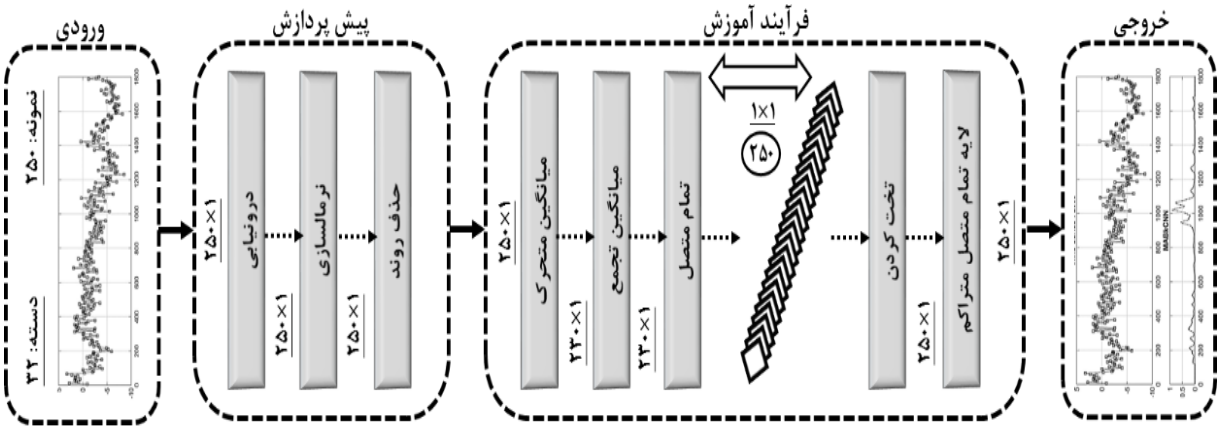

شکل ۳: روندنمای روش پیشنهادی شامل (لایه‌های ورودی، پیش‌پردازش، آموزش و خروجی)

پس از آن‌که سری زمانی با فواصل زمانی یکسان تولید شد، نیاز است تا برچسب‌هایی که قبلاً توسط کارشناسان خبره شناسایی و محل آن‌ها تأیید شده‌اند، به‌صورت تابع توزیع احتمال گاوسی تغییرات برای هر نقطه‌ی زمانی تعریف شوند [۳۸]. این رویکرد، عدم قطعیت ذاتی در تشخیص تغییرات را به‌طور مستقیم در فرآیند یادگیری مدل لحاظ می‌نماید [۳۹]. به‌طور خاص، برای هر سری زمانی با طول مشخص که در این پژوهش ۲۵۰ نمونه درنظر 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 به‌صورت دستی و بر اساس شواهد بصری موجود در داده‌های تداخل‌سنجی شناسایی کرده‌اند. سپس، پارامترهای توزیع گاوسی به‌صورت خودکار و بر اساس رابطه (۱) و با درنظر گرفتن یک پنجره‌ی زمانی ثابت قبل و بعد از مکان‌های شناسایی‌شده تخمین زده شده‌اند.

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

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 (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 بادقت 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[1] 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].

[1] *Detrending*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

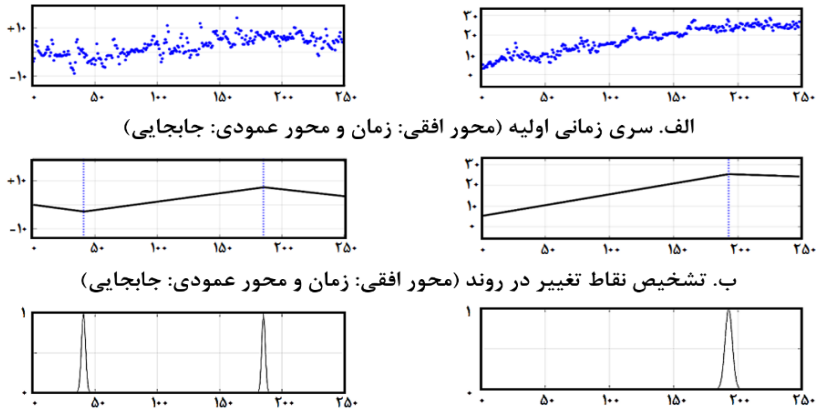

الف. سری زمانی اولیه (محور افقی: زمان و محور عمودی: جابجایی)

ب. تشخیص نقاط تغییر در روند (محور افقی: زمان و محور عمودی: جابجایی)

ج. تابع توزیع احتمال گاوسی تغییرات (محور افقی: زمان و محور عمودی: احتمال)

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

در این پژوهش، حذف روند با استفاده از رگرسیون خطی انجام می‌شود [۴۲]، به‌گونه‌ای 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 به‌دست آید. لازم به ذکر است که هدف از به‌کارگیری 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]:

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

در رابطه (۲)، $\hat{x}_t$ مقدار تخمین زده شده روند در زمان t، b عرض از مبدأ و a شیب‌خط 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 زده‌شده) است. فرمول‌های محاسبه پارامترهای a و b مطابق روابط (۳) و (۴) محاسبه می‌شود [۴۳]:

$$a = \overline{x} - b\overline{t} \qquad \text{رابطه(۳)}$$

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

در روابط (۳) و (۴)، n تعداد نمونه‌های سری زمانی، $\overline{x}$ میانگین مقادیر سری زمانی و $\overline{t}$ میانگین زمان‌ها است.

پس از محاسبه پارامترهای a و b، می‌توان روند تخمین 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 زده‌شده از سری زمانی اصلی طبق رابطه (۵) به دست می‌آید:

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

در رابطه (۵)، y_t سری زمانی بدون روند، x_t سری زمانی اصلی و $\hat{x}_t$ روند تخمین زده‌شده 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.

درنهایت، 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].

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

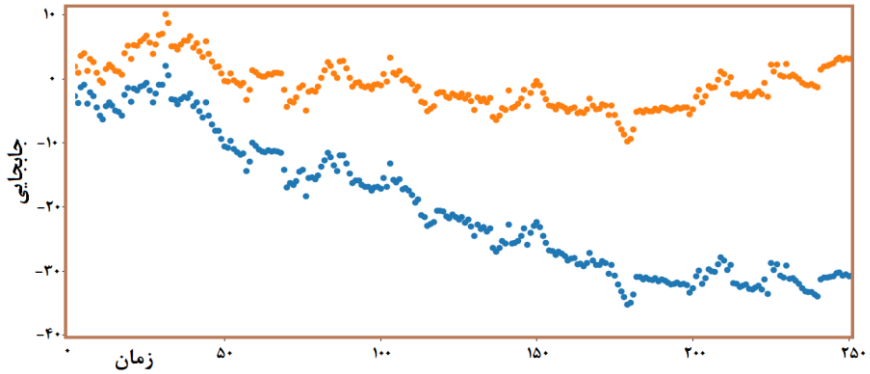

شکل ۵: حذف روند از سری زمانی جابجایی که رنگ آبی نشان‌دهنده سری زمانی دارای روند و رنگ نارنجی، سری زمانی بدون روند

جهت اعمال لایه نرمال‌سازی مبتنی بر انحراف معیار[1] به سری زمانی، فرمول مربوطه طبق رابطه (۶) اعمال می‌شود [۴۵].

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

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]:

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

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

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.

[1] *Z-Score*

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 فرایند 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.

۳-۳-۲-۱- میانگین متحرک[2]:

لایه‌ی میانگین متحرک به‌منظور هموارسازی سری‌های زمانی و کاهش نویز به‌کار می‌رود [۴۷]. با محاسبه‌ی 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

[2] *Moving Average*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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].

$$MA_t = \frac{1}{\omega}\sum_{i=0}^{\omega-1} x_{t-i} \quad \text{رابطه(۹)}$$

در رابطه(۹)، MA_t میانگین متحرک در زمان t است. 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 برروی داده‌های سری‌زمانی 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.

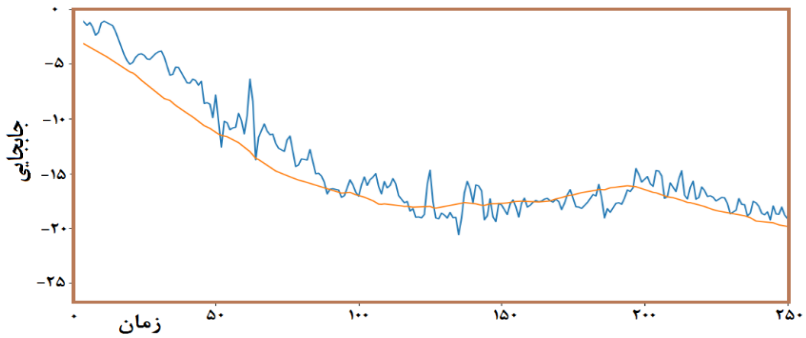

شکل ۶: روند آبی‌رنگ سری زمانی اولیه و روند قرمزرنگ خروجی لایه میانگین متحرک با ابعاد پنجره ۲۰

۳-۳-۲-۲- میانگین تجمع[1]

لایهٔ 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 تجمعی به شبکه‌ی عصبی این امکان را می‌دهد که بر الگوهای مهم تمرکز کرده و پیچیدگی محاسباتی را کاهش دهد [۵۱].

۳-۳-۲-۳- لایه کاملاً متصل

در معماری پیشنهادی، هنگامی‌که داده‌ها پس از گذر از لایه‌های قبلی (نرمال‌سازی، حذف روند، میانگین متحرک و میانگین تجمع) به لایهٔ کاملاً متصل وارد می‌شوند، شکل آن‌ها به‌صورت (۲۳۰، ۱) 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، لایهٔ کاملاً متصل دارای ۲۵۰ فیلتر و کرنلی با اندازهٔ ۲۳۰ است. نکتهٔ قابل‌توجه این است که اندازهٔ کرنل دقیقاً برابر با طول سری زمانی ورودی است. این بدان معناست که هر فیلتر یک محاسبهٔ واحد را روی کل سری زمانی انجام می‌دهد و یک مقدار خروجی تولید می‌کند. به‌عبارت‌دیگر، به‌جای 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

[1] *Average Pooling*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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

۳-۳-۲-۴- تخت کردن[1]

به‌منظور تبدیل خروجی چندبعدی لایه‌های کاملاً متصل به یک بردار یک‌بعدی، از لایهٔ تخت کردن استفاده می‌شود [۵۳]. این فرآیند جهت آماده‌سازی داده‌ها برای ورود به لایه‌ی کاملاً متصل متراکم انجام می‌گیرد. با تخت کردن داده‌ها، می‌توان ویژگی‌های استخراج‌شده توسط لایه‌های کاملاً متصل را به‌عنوان ورودی به شبکه‌ی عصبی سنتی تغذیه نمود [۵۴]. هرچند که در ساختار شبکه پیشنهادی، داده ورودی به‌صورت بردار یک‌بعدی است و این لایه تغییری در ساختار داده ایجاد نمی‌کند، اما وجود این لایه به‌منظور 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.

۳-۳-۲-۵- لایه کاملاً متصل متراکم

در معماری پیشنهادی، برچسب‌های مورداستفاده جهت آموزش شبکه، یک بردار با ابعاد (۲۵۰، ۱) هستند که هر عنصر آن احتمال وقوع تغییر در نقطهٔ متناظر از سری زمانی را نشان می‌دهد. این برچسب‌ها به‌جای بیان صرف وجود یا عدم وجود تغییر، میزان احتمال تغییر را در هر نقطه مشخص می‌کنند؛ بنابراین، هدف لایهٔ کاملاً متصل متراکم با ۲۵۰ نورون در انتهای شبکه، پیش‌بینی احتمال تغییر در هر یک از ۲۵۰ نقطهٔ 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 (۲۵۰، ۱) تبدیل می‌کند. هر عنصر در این بردار خروجی، بیانگر احتمال پیش‌بینی‌شده برای وقوع تغییر در نقطهٔ متناظر است.

استفاده از تابع فعال‌سازی سیگموئید در لایهٔ خروجی کاملاً متصل متراکم، موجب شده تا مقادیر خروجی به بازهٔ مابین ۰ و ۱ محدود شوند که این بازه، نشان‌دهنده‌ی احتمالات است [۵۵]؛ بنابراین، خروجی نهایی شبکه یک بردار با ابعاد (۲۵۰، ۱) خواهد بود که هر عنصر آن احتمال پیش‌بینی‌شده برای وقوع تغییر در نقطه‌ی متناظر از سری زمانی را نشان می‌دهد.

باتوجه‌به اینکه مسئله شناسایی نقاط تغییر در سری‌های زمانی جابجایی به‌عنوان 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 هزینهٔ باینری کراس‌انتروپی، خروجی پیش‌بینی‌شده توسط لایه‌ی کاملاً متصل متراکم را به برچسب‌های واقعی (احتمالات وقوع تغییر) نزدیک نماید [۵۶]. بنابراین تابع هزینه انتخاب‌شده به‌منظور 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 (۲۵۰، ۱) خواهند بود که هر عنصر آن احتمال پیش‌بینی‌شده برای تغییر در نقطهٔ متناظر را نشان می‌دهد. نقاطی که احتمال پیش‌بینی‌شده برای آن‌ها بالاتر است، به‌عنوان نقاط با احتمال بالاتر تغییر شناسایی می‌شوند. همچنین، برای آموزش مدل و کاهش هزینه، الگوریتم بهینه‌سازی آدام[2] استفاده گردید [۵۷].

۳-۴- معیارهای ارزیابی دقت

در این تحقیق، سه معیار صحت[3]، فراخوانی[4] و امتیاز اف[5] درنظر گرفته شده است. بسته به موضوع تحقیق، باید تصمیم گرفت که کدام معیار اهمیت بیشتری دارد

[1] *Flatten*

[2] *Adam*
[3] *Precision*
[4] *Recall*
[5] *F1_score*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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

جدول ۱: معیارهای ارزیابی

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

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 تداخل‌سنجی راداری ارائه می‌شود. این بخش به بررسی بهینه‌سازی ابرپارامترها[1]، 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 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 طراحی‌شده‌اند. 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.

[1] *Hyperparameter Optimization*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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

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

۴-۲- دقت مدل

جهت محاسبه دقت و کیفیت مدل، لازم است تعریف مناسبی برای آن ارائه دهیم. باتوجه‌به 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 پیش‌بینی‌نشده باشد، این به معنای آن است که مدل نتوانسته است این تغییر را پیش‌بینی نماید. باتوجه‌به بررسی‌های صورت‌گرفته، بازهٔ 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[1]، مثبت کاذب[2] و منفی کاذب[3] را به‌صورت زیر تعریف نمود:

مثبت صحیح: زمانی که پیش‌بینی و واقعیت کمتر از 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، مجموعه‌داده‌های برچسب‌گذاری شده توسط کارشناسان خبره، پس از اعمال عملیات تقویت داده‌ها، به ۱۴،۷۶۴ نمونه سری زمانی جابجایی حاصل از تداخل‌سنجی 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 مورداستفاده 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 نشان‌دهنده‌ی کارایی بالای مدل در تشخیص تغییرات معنادار می‌باشد. همچنین، پس از بررسی دقت، می‌توان نمودار زیان[4] را بر روی داده‌های

[1] *True Positive*
[2] *False Positive*
[3] *False Negative*
[4] *loss*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

آموزشی و آزمایشی که یکی از جنبه‌های مؤثر در تحلیل و ارزیابی مدل پیشنهادی است، موردبررسی قرار داد. شکل (۷)، نمودار زیان مدل پیشنهادی را پس از ۲۰۰ تکرار نشان می‌دهد.

جدول ۳: دقت روش پیشنهادی

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

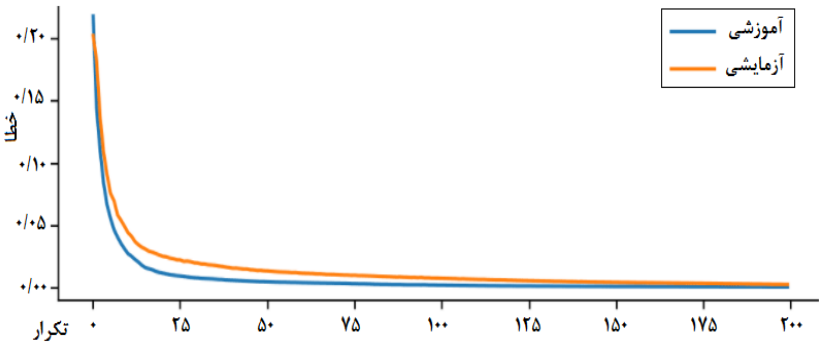

شکل ۷: نمودار تغییرات زیان بر روی داده‌های آموزشی و آزمایشی

با تحلیل نمودار موجود در شکل (۷) مشخص می‌شود که مدل با سرعت قابل قبولی به‌سوی مقدار بهینه همگرا شده است و این امر نشان‌دهنده بهترین حالت دقت در مدل پیشنهادی است. عملکرد مدل بر روی مجموعه‌داده‌های آموزشی و آزمایشی تقریباً برابر بوده و می‌توان نتیجه گرفت که مدل در تعمیم به داده‌های جدید توانایی بالایی دارد. همچنین، عملکرد مدل و نحوه‌ی 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:

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 معرفی‌شده‌اند 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 به‌صورت تصادفی انتخاب‌شده‌اند، ارائه می‌گردد.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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

۲- مقایسه عملکرد مدل پیشنهادی با سایر روش‌های عصبی عمیق: پس از پیاده‌سازی مدل‌های *TGLSTM* [۱۳] و *LSTM* [۳۲] برروی داده‌های فوق، مشخص گردید که این روش‌ها، به‌دلیل طراحی خاصشان برای داده‌های توالی‌دار و سری زمانی، معمولاً در شناسایی نقاط تغییر عملکرد مناسبی دارند. بااین‌حال، هزینه محاسباتی این مدل‌ها به‌طور قابل‌توجهی بیشتر از روش پیشنهادی است؛ بنابراین، می‌توان نتیجه گرفت 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 به‌دلیل 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 به‌صورت تصادفی ارائه شده‌است.

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

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

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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 تداخل‌سنجی راداری پرداخته می‌شود. ارزیابی مدل به‌منظور سنجش دقت و کارایی آن بر روی داده‌های 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 قابل‌مشاهده 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.

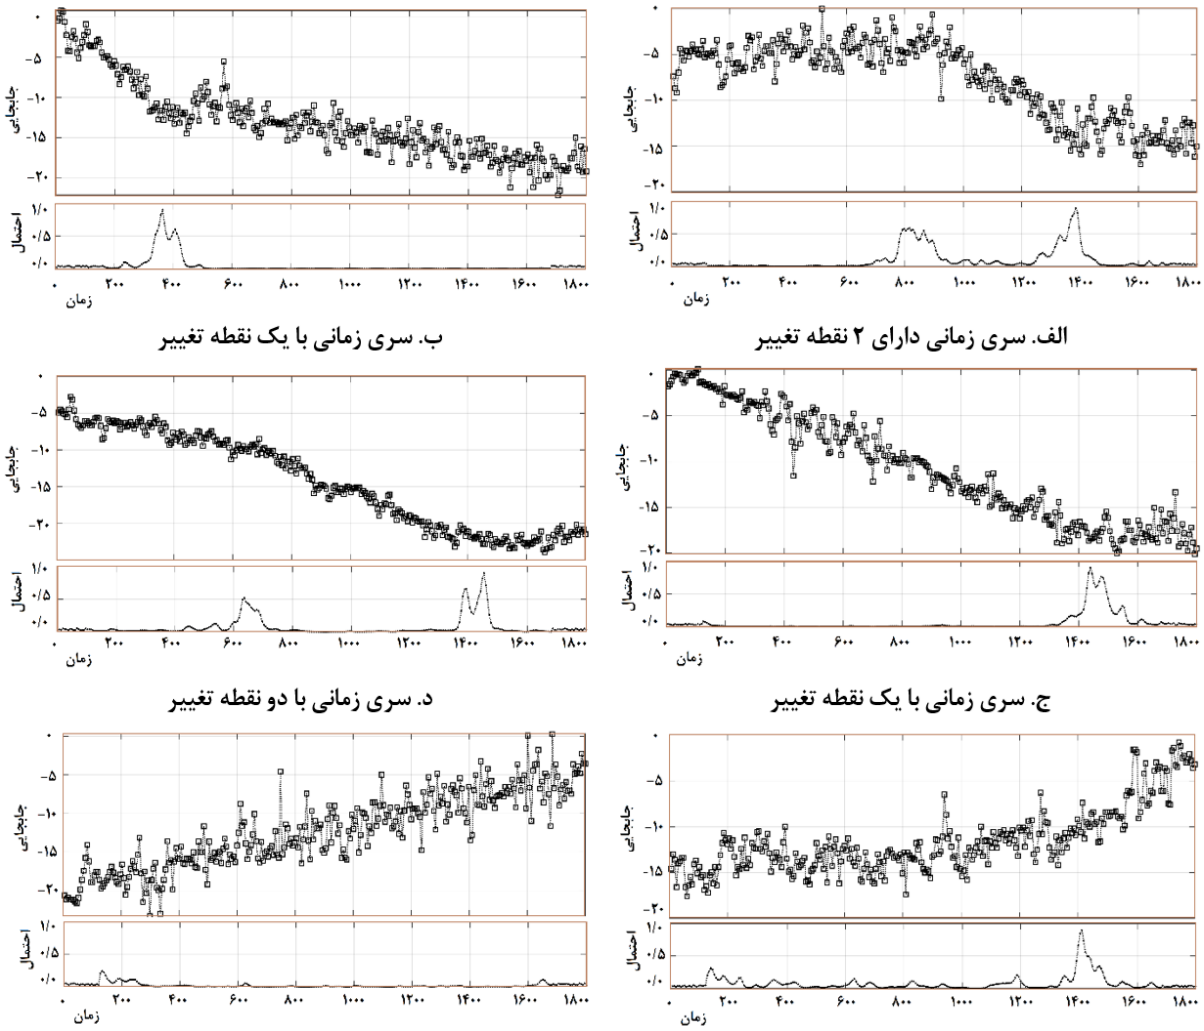

الف. سری زمانی دارای ۲ نقطه تغییر

ب. سری زمانی با یک نقطه تغییر

ج. سری زمانی با یک نقطه تغییر

د. سری زمانی با دو نقطه تغییر

ه. سری زمانی با یک نقطه تغییر

ی. سری زمانی بدون نقطه تغییر

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

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

همان‌طور که از شکل (۸) مشاهده می‌شود، مدل شبکه عصبی پرسپترون چندلایه توانسته است الگوهای پیچیده را به‌خوبی 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 جزیره بزرگ گالاپاگوس و دورترین جزیره غربی آن است. مساحت این جزیره ۶۴۲ کیلومترمربع (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. به‌این‌ترتیب، داده‌های سری‌زمانی این منطقه با استفاده از تصاویر ماهواره‌ای سنتینل-۱ از شهریور ۲۰۱۴ تا خرداد ۲۰۱۸ در نرم‌افزار مِنت‌پای 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.

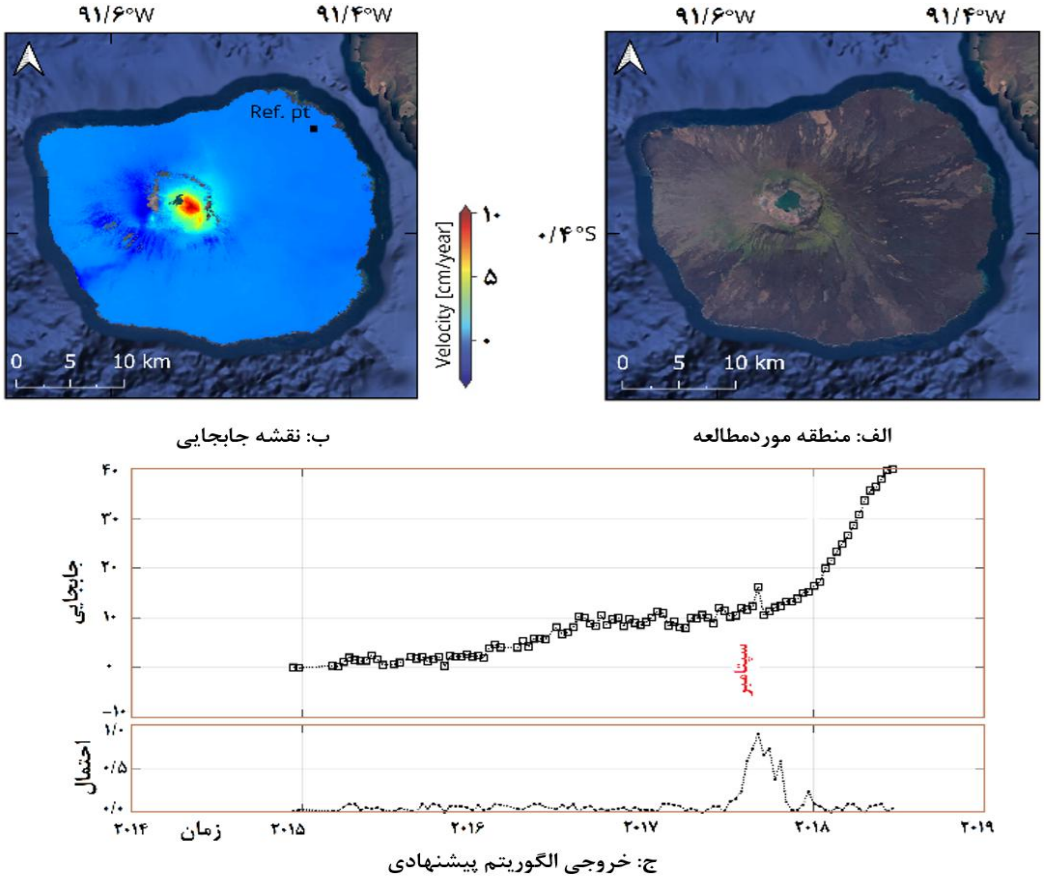

شکل ۹: منطقه موردمطالعه و خروجی الگوریتم پیشنهادی تشخیص نقطه تغییر

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

همان‌طور که در شکل (۹) مشاهده می‌شود، الگوریتم پیشنهادی به‌درستی نقطه تغییر را که در سپتامبر ۲۰۱۷ اتفاق افتاده و مربوط به فعالیت آتش‌فشان است، تشخیص داده است.

۴-۶- تحلیل خطاها و چالش‌ها

در این بخش، خطاها و چالش‌های مربوط به خروجی نتایج شبکه عصبی پیشنهادی در شناسایی نقاط تغییر جابجایی حاصل از تداخل‌سنجی راداری موردبررسی و تحلیل قرار می‌گیرند. به‌طورکلی، شبکه عصبی پیشنهادی توانسته است عملکرد مناسبی در شناسایی نقاط تغییر عمده از خود نشان دهد، اما در برخی موارد نتایج به‌طور دقیق با واقعیت هم‌خوانی نداشته است. در شکل (۱۰)، برخی از نمونه‌ها نشان داده شده‌اند.

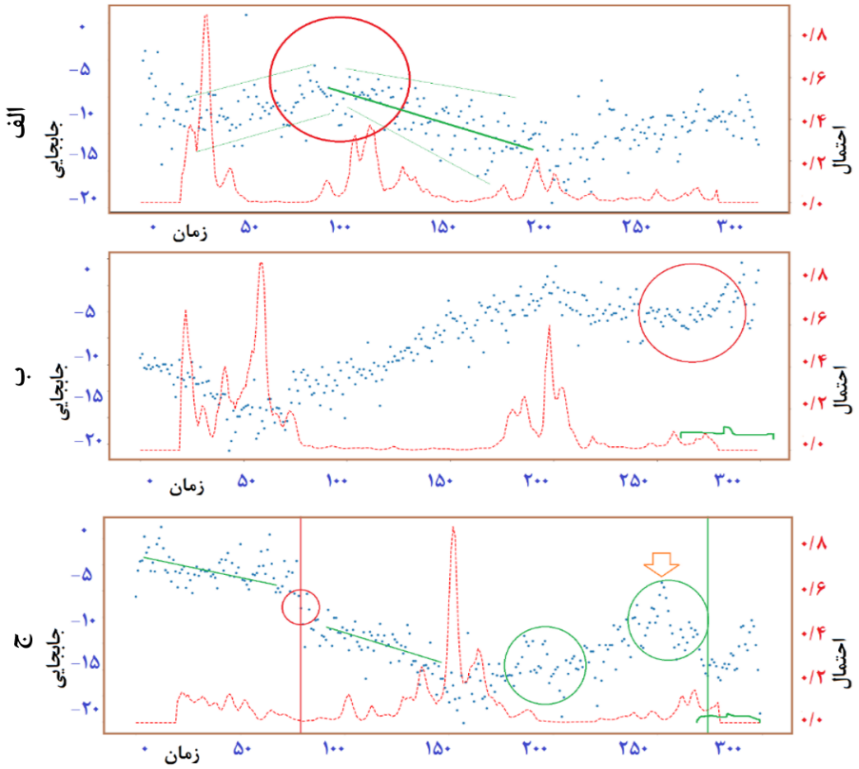

شکل ۱۰: چند نمونه از خروجی شبکه عصبی پیشنهادی که دارای خطا است

در شکل(۱۰) و در نمونهٔ (الف)، از جایی که مشخص شده است، تغییرات هرچند باعث ایجاد واکنش در پیش‌بینی مدل شده‌اند، اما درنهایت مدل با اعتماد بالایی قادر به تشخیص این تغییرات نبوده است. دلیل این رخداد در روندی است که لایهٔ میانگین متحرک شناسایی کرده است. همان‌طور که در تصویر مشخص است، واریانس تغییرات داده‌ها (واگرایی از خط رگرسیون فرضی) باعث ایجاد خطا در تشخیص روند شده است. درواقع، میانگین متحرک در این نقطه به‌دلیل واگرایی، تغییرات کمتری نسبت به خط رگرسیون فرضی که نمایندهٔ روند است، نشان می‌دهد و این مسئله موجب کاهش اعتماد مدل در حین پیش‌بینی شده است. همچنین، در نمونه (ب)، تغییرات انتهای روند به‌خوبی شناسایی نشده‌اند. دلیل این موضوع سایز پنجرهٔ میانگین متحرک است. همان‌طور که در بخش‌های قبلی ذکر شد، سایز پنجرهٔ لایهٔ میانگین متحرک برابر با ۲۰ در نظر گرفته شده بود؛ اما تغییرات در فاصله‌ای کمتر از ۲۰ واحد به وقوع

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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. باتوجه‌به اینکه در مدل ارائه‌شده، تغییرات پله‌ای لحاظ نشده‌اند و روند پیش و پس‌ازاین 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 نکتهٔ مهم وجود دارد:

- اولاً به‌سبب محدودیت اندازهٔ پنجره، مدل تا خط عمودی رسم‌شده قادر به تشخیص تغییرات به‌طور مؤثر است (همانند نمونهٔ قبل) و پس‌ازآن تغییرات با اعتماد کمتری تشخیص داده می‌شوند.
- ثانیاً الگوی تغییر رخ‌داده تا پیش از خط عمودی سبز، همان الگویی است که از پیش‌تر تکرار شده است (دو دایرهٔ سبز یک الگوی مشترک دارند). به همین دلیل، نقطهٔ علامت‌گذاری شده به‌عنوان یک نوسان تکراری (فصلی) در نظر گرفته‌شده، نه یک تغییر در روند. هرچند، اگر امکان لحاظ‌کردن بخش پایانی نمودار وجود داشت، این تغییر با اعتماد بیشتری شناسایی می‌شد.

باوجود 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 عدم‌تغییر شناسایی شدند و همچنین، برخی از نقاط غیرتغییر به‌اشتباه به‌عنوان تغییر شناسایی شدند. این موارد به‌ویژه در شرایطی با نوسانات طبیعی و تغییرات جزئی، قابل‌توجه 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 تداخل‌سنجی 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. بااین‌حال، 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 یادگیری‌ماشین، کمک‌های شایانی به شکل‌گیری این پژوهش داشته‌اند. نویسندگان مقاله از ایشان کمال قدردانی را به‌عمل می‌آورند.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]
[DOI: 10.61882/jgit.12.4.109]

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. S. B. S. M. Wang, "Automatic change-point detection in time

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

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

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

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. Pujianto, 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.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

[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.

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]

K. N. TOOSI UNIVERSITY OF TECHNOLOGY
FACULTY OF GEODESY AND GEOMATICS ENGINEERING

Journal of Geospatial Information Technology
Vol.12, No.4, Winter 2025

Research Paper

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.*

Correspondence Address *: Department of Geomatics Engineering, Faculty of Civil Engineering and Transportation, University of Isfahan, Isfahan, Iran.*
Tel*: +98-31-37935332*
Email*: sattari@eng.ui.ac.ir*

[Downloaded from jgit.kntu.ac.ir on 2026-01-29]

[DOI: 10.61882/jgit.12.4.109]