



## Artificial intelligence applications in analyzing seismological data (Case study: Precursors data)

Mohsen Pirizadeh<sup>1</sup> & Mahboobeh Pirizadeh<sup>2</sup>

1. M.S. Department of Mathematics and Computer Science, Shahed University, Tehran, Iran. (mohsen.Pirizadeh@shahed.ac.ir)  
2. Assistant Professor Islamic Azad University, West Tehran Branch, Tehran, Iran. (pirizadeh.mahboobeh@wtiau.ac.ir)

### ABSTRACT

**Background and objective:** Systematic recording of earthquake data in the last century has developed new approaches to using innovative methods to maintain, process, and analyze this type of data in order to organize and classify them for seismic risk management purposes. Among these approaches is the use of artificial intelligence technology to discover intrinsic rules and interdependencies between data to classify seismic events or to predict continuous values of time series.

**Method:** In this research, the applications of various branches of artificial intelligence, especially machine learning and deep learning methods in the processing of earthquake-related data have been analyzed by considering the specific characteristics of this type of data, including the temporal relationships between samples and the highly skewed distribution of classes. Then, a new approach based on deep recurrent networks equipped with cost-sensitive loss function is proposed to model the relationship between seismic time series data and the probability of future earthquakes. In order to evaluate the performance of the proposed model, a case study on the classification of Peak Ground Acceleration (PGA) severity in the next time steps has been performed based on the time series related to the seismic precursor of abnormal activity of animals.

**Findings:** The use of deep recurrent networks due to their ability to memorize long-term temporal relationships among samples, was evaluated quite positively in the modeling of seismic time series. However, in seismic data classification problems, in which more serious earthquakes occur less frequently than in non-serious cases, the problem of class imbalance plays a prominent role which, if not properly controlled, can greatly affect the performance of models in favor of the majority class. So that models will tend to label all the samples as a majority one, while in such situations the correct identification of the minority class has the topmost priority.

**Results:** The results of the case study revealed that the deep learning based approach with an average balanced-accuracy of 81.2% and 59.3% on training and test data, respectively, has left a completely better performance compared to conventional recurrent neural networks in the classification of PGA values. This study also shows that by modifying the loss function of deep recurrent networks using the cost-sensitive approach, the challenge of seismic data class imbalance can be well controlled.

**Keywords:** Seismic data, Artificial intelligence, Machine learning, Deep learning, Earthquake precursors.

► **Citation (APA 6th ed.):** Pirizadeh M, Pirizadeh M. (2021, Autumn). Artificial intelligence applications in analyzing seismological data (Case study: Precursors data). *Disaster Prevention and Management Knowledge Quarterly (DPMK)*, 11(3), 299-309.

## کاربرد هوش مصنوعی در تحلیل داده‌های لرزه‌شناسی (مطالعه موردی: داده‌های پیش‌نشانگرها)

محسن پیری‌زاده<sup>۱</sup> و محبوبه پیری‌زاده<sup>۲</sup>\*

۱ کارشناس ارشد محاسبات نرم و هوش مصنوعی، دانشکده علوم پایه، دانشگاه شاهد، تهران، ایران. Mohsen.Pirizadeh@shahed.ac.ir  
۲ استادیار، گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد تهران غرب، تهران، ایران (نویسنده مسئول) pirizadeh.mahboobeh@wtiau.ac.ir

### چکیده

**زمینه و هدف:** ثبت دستگاهی داده‌های مربوط به پدیده زلزله در سده اخیر، رویکردهای جدیدی را برای استفاده از روش‌های نوین نگهداری، پردازش و تحلیل این نوع از داده‌ها به منظور سازمان‌دهی و طبقه‌بندی آن‌ها برای اهداف مرتبط با مدیریت خطرپذیری لرزه‌ای ارائه داده است. از جمله این رویکردها، استفاده از فناوری هوش مصنوعی برای کشف قوانین ذاتی و وابستگی بین داده‌ها جهت طبقه‌بندی رویدادهای لرزه‌ای یا پیش‌بینی مقادیر پیوسته سری‌های زمانی می‌باشد.

**روش:** در این تحقیق، کاربرد شاخه‌های مختلف هوش مصنوعی به خصوص روش‌های یادگیری ماشین و یادگیری عمیق در پردازش داده‌های مرتبط با زلزله با در نظر گرفتن ویژگی‌های خاص این نوع از داده‌ها اعم از وجود ارتباطات زمانی میان نمونه‌ها و توزیع به‌شدت ناموزون کلاس‌ها مورد تجزیه و تحلیل قرار گرفته است. سپس یک رویکرد جدید مبتنی بر شبکه بازگشتی عمیق تجهیز شده به تابع ضرر حساس به هزینه به منظور مدلسازی ارتباط بین داده‌های سری زمانی لرزه‌ای و احتمال وقوع زلزله‌های آتی پیشنهاد گردیده است. به منظور ارزیابی عملکرد مدل پیشنهادی، یک مطالعه موردی در زمینه طبقه‌بندی شدت شتاب بیشینه لرزه‌ای (PGA) در گام زمانی بعدی بر اساس سری زمانی مربوط به پیش‌نشانگر لرزه‌ای فعالیت غیر طبیعی حیوانات انجام شده است.

**یافته‌ها:** بهره‌گیری از شبکه‌های عمیق بازگشتی با توجه به توانایی‌های آن‌ها در به خاطر سپاری طولانی مدت ارتباطات زمانی میان نمونه‌ها، در مدلسازی سری‌های زمانی لرزه‌ای کاملاً مثبت ارزیابی گردید. با این حال، در مسائل طبقه‌بندی داده‌های لرزه‌ای که همواره لرزش‌های جدی‌تر در مقابل حالت‌های غیر جدی به‌ندرت رخ می‌دهند، مسئله عدم تعادل کلاس به طور پررنگی حضور دارد که اگر این موضوع به درستی کنترل نشود، می‌تواند عملکرد مدل‌ها را به نفع کلاس اکثریت به شدت تحت تأثیر قرار دهد، به‌طوری‌که مدل‌ها تمایل خواهند داشت همه نمونه‌ها را به عنوان کلاس اکثریت برچسب‌گذاری کنند. این درحالی است که در اینگونه از مسایل، شناسایی صحیح کلاس اقلیت، اولویت اصلی را دارد.

**نتیجه‌گیری:** نتایج مطالعه موردی نشان داد که رویکرد مبتنی بر یادگیری عمیق با میانگین دقت متعادل ۸۱٫۲٪ و ۵۹٫۳٪ به ترتیب بر روی داده‌های آموزشی و آزمون، عملکرد کاملاً بهتری را در مقایسه با شبکه‌های عصبی بازگشتی معمولی در طبقه‌بندی مقادیر PGA از خود بر جای گذاشته است. همچنین این مطالعه نشان داده است که با اصلاح کردن تابع هزینه شبکه‌های بازگشتی عمیق به کمک رویکرد حساس به هزینه، می‌توان چالش عدم تعادل کلاس داده‌های لرزه‌ای را نیز به خوبی کنترل نمود.

**واژگان کلیدی:** داده‌های لرزه‌ای، هوش مصنوعی، یادگیری ماشین، یادگیری عمیق، پیش‌نشانگر لرزه‌ای.

◀ **استناد فارسی (شیوه APA، ویرایش ششم ۲۰۱۰):** پیری‌زاده، محسن؛ پیری‌زاده، محبوبه. (پاییز، ۱۴۰۰). کاربرد هوش مصنوعی در تحلیل داده‌های لرزه‌شناسی (مطالعه موردی: داده‌های پیش‌نشانگرها). *فصلنامه دانش پیشگیری و مدیریت بحران*، ۱۱ (۳)، ۲۹۹-۳۰۹.



## مقدمه

پروژه لرزه‌نگاری، پیش‌بینی میزان آسیب احتمالی وارده به اماکن پیش از وقوع زلزله، ارائه هشدارهای خطر لرزه‌ای با پردازش و تجزیه و تحلیل انبوهی از داده‌های لرزه‌نگاری و در نهایت ارائه ابزارهای هوشمند بلادرنگ با هدف پیش‌بینی تصمیم‌های با اطمینان بالا مطرح می‌باشد. به همین لحاظ در مقاله حاضر، بررسی کاربردهای شاخه‌های مختلف هوش مصنوعی در پردازش داده‌های لرزه‌نگاری برای کاربردهای مختلف مدیریت خطرپذیری لرزه‌ای مورد توجه قرار گرفته است و سپس به بررسی نتایج پردازش اطلاعات یکی از پیش‌نشانگرهای لرزه‌ای برای تشخیص و هشدارهای لرزه‌ای با استفاده از روش‌های مختلف هوش مصنوعی پرداخته شده است.

## کاربرد هوش مصنوعی و یادگیری ماشین در پردازش داده‌های لرزه‌ای


هوش مصنوعی سعی دارد قابلیت‌های شناختی-ذهنی انسان را تقلید نماید و از این لحاظ به‌منزله راه‌حل محاسباتی برای حل مسائل مهندسی که با روش‌های قدیمی به‌سختی قابل حل هستند تلقی می‌گردد (علوی و گندمی، ۲۰۱۱). شبکه‌های عصبی الگوریتم‌های یادگیری ماشینی هستند که به‌خوبی و به‌صورت گسترده برای طبقه‌بندی داده‌ها و تشخیص رابطه بین ورودی‌ها و خروجی‌های متناظر در علوم مختلف کاربرد دارند. به‌طور خاص در سال‌های اخیر، در علم لرزه‌شناسی و تحلیل خطر لرزه‌ای، مدیریت انبوهی از داده‌های لرزه‌ای از طریق روش‌های هوش مصنوعی به‌عنوان جایگزین و یا مکمل مدل‌های توسعه‌یافته‌ای - که بر اساس قوانین فیزیکی برای تعریف روابط حاکم بر داده‌های لرزه‌ای استفاده می‌کنند- به‌شدت مورد توجه قرار گرفته است (لی و همکاران، ۲۰۱۸). در سال‌های اخیر با اتخاذ رویکردهای هوش مصنوعی مبتنی بر داده‌کاوی، پرونده‌های پردازشی، دقت و بازدهی سیستم‌های تشخیص زلزله را به‌طور قابل توجهی افزایش داده‌اند؛ زیرا در این نوع از رویکردها برخلاف روش‌های آماری قدیمی، دیگر نیازی به فرض کردن ساختارهای اولیه‌ای برای درک روابط کارکردی بین متغیرها نیست، بلکه مدل هوش مصنوعی به‌طور خودکار، هم ساختار موجود در داده و هم پارامترهای مدل ریاضی را تکامل می‌بخشد. از این رو

پدیده زلزله به‌عنوان یکی از پرچالش‌ترین سوانح طبیعی مؤثر بر زندگی بشر در کره زمین، از قرون وسطی در مرکز توجه محققان علوم مختلف از منظر برنامه‌ریزی برای استراتژی‌های پیش‌بینی، کاهش اثر، افزایش آمادگی، پاسخگویی و بازیابی و بازتوانی جامعه بوده است و به همین جهت، ثبت و پردازش داده‌های مربوط به این پدیده از اهمیت زیادی برخوردار می‌باشد. تا پیش از سال ۱۹۰۰ میلادی، نحوه ثبت اطلاعات زلزله‌های بزرگ مقیاس عمدتاً بر مبنای شواهد عینی و اعمال روش‌های پردازش کیفی بوده است و علی‌رغم پراکندگی و عدم قطعیت‌های زیادی که در ثبت این اطلاعات در منابع تاریخی وجود دارد، همچنان اطلاعات با ارزشی برای مطالعات تحلیل خطر لرزه‌ای با کاربردهای برنامه‌ریزی شهری بلندمدت برای دوره‌های ۵۰ ساله یا ۱۰۰ ساله می‌باشند. از اوایل قرن بیستم با نصب دستگاه‌های ثبت رکوردهای لرزه‌ای اعم از دستگاه‌های لرزه‌نگار و شتاب‌نگار در کشورهای لرزه‌خیز و ایجاد و گسترش شبکه‌های لرزه‌نگاری، تحول بزرگی در ثبت اطلاعات دستگاهی لرزه‌ای برای طیف وسیعی از ریز لرزه‌ها تا زلزله‌های بزرگ مقیاس در مناطق مختلف لرزه‌خیز جهان رخ داده است؛ که با ورود به قرن بیست و یکم و افزایش حجم این داده‌ها به‌مگاداده‌ها، رویکردهای جدیدی برای استفاده از روش‌های نوین برای نگهداری و پردازش این داده‌ها در بانک‌های اطلاعاتی، مورد توجه محققان قرار گرفته است (اودیاس و بافرن<sup>۱</sup>، ۲۰۱۸). در سال‌های اخیر، در علم لرزه‌نگاری، تلاش‌های زیادی معطوف به بهبود حساسیت مرحله تشخیص شده است. از طرف دیگر، مدیریت انبوهی از داده‌ها برای مدیریت خطرپذیری لرزه‌ای و مدیریت بحران پدیده زلزله در کمترین زمان ممکن با روش‌های عینی، فاقد بازدهی مناسب می‌باشد و استفاده از روش‌هایی که امکان تشخیص اطلاعات صحیح و ادغام اطلاعات از بانک‌های اطلاعاتی مختلف را به شیوه‌ای منطقی و قابل اطمینان داشته باشد، مدنظر قرار گرفته است (لاری<sup>۲</sup> و همکاران، ۲۰۱۵). استفاده از علم هوش مصنوعی به‌عنوان یکی از این رویکردها در زمینه‌های مختلفی مانند تفکیک و حذف نمونه‌های خطا دار<sup>۳</sup> و ناهنجاری از اطلاعات زلزله‌های واقعی در

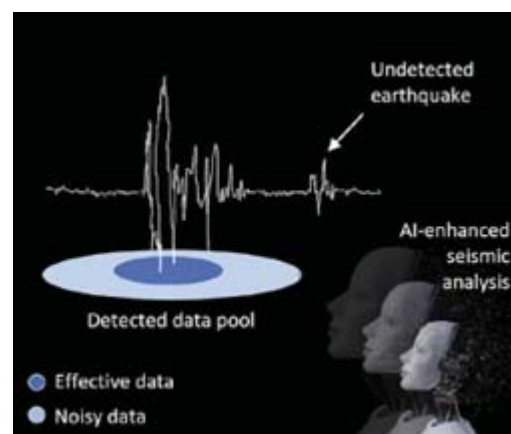
1. Udias & Buforn  
2. Lary  
3. Noise

البته فناوری هوش مصنوعی در حالت کلی یک مفهوم بسیار وسیع از توانایی‌های یک برنامه رایانه‌ای برای یادگیری و تفکر را در برمی‌گیرد. این مفهوم از یک سو می‌تواند داده محور و از طرف دیگر مبتنی بر تعامل یک عامل در محیط و یادگیری بر اساس تشویق و تنبیه‌ها باشد. در رخدادهای لرزه‌ای که به طور معمول حالت داده محور را شامل می‌شوند، استفاده از الگوریتم‌های یادگیری ماشین مانند شبکه‌های عصبی مصنوعی، برنامه‌نویسی ژنتیک، درخت تصمیم، ماشین بردار پشتیبان، جنگل تصادفی و... برای آموزش مدل‌ها جهت یافتن الگوهای بالقوه نهفته در داده، بسیار کاربردی می‌باشد (شکل ۲). به عنوان شاخه‌ای از هوش مصنوعی، یادگیری ماشین شامل سیستم‌هایی است که قادر به یادگیری خودکار از روی داده‌ها، تشخیص الگوها و تصمیم‌گیری هستند. زیبایی خاص یادگیری ماشین در این است که به رایانه این امکان را می‌دهد تا بدون برنامه‌ریزی واقعی و بدون در نظر گرفتن پیش‌فرض‌هایی درباره دیتا، فرآیند یادگیری را انجام دهند. اکثر روش‌های مبتنی بر یادگیری ماشین با الهام‌گیری از یادگیری طبیعی / زیستی طراحی شده‌اند. در لرزه‌نگاری، یادگیری ماشین از یک سری تکنیک‌ها برای کشف قوانین ذاتی و وابستگی‌های بین داده‌ها جهت طبقه‌بندی برچسب‌های خروجی و یا پیش‌بینی مقادیر پیوسته سری‌های زمانی استفاده می‌کند. علاوه بر این، یادگیری عمیق، به وفور برای طبقه‌بندی و تحلیل الگوها و ویژگی‌های ناشناخته در داده‌های گردآوری شده کاربرد دارد. این روش برخلاف منطق و شهود لرزه‌نگاران در تحلیل داده‌ها، ویژگی‌های ناشناخته و فراتر از درک انسانی پنهان در دیتا را شناسایی می‌کند (کنگ<sup>۲</sup> و همکاران، ۲۰۱۹). با یک نوع از دسته‌بندی، این تکنیک‌ها به دو دسته اصلی نظارتی و بدون نظارت تقسیم می‌گردند. روش‌های نظارتی عمدتاً شامل روش‌های رگرسیون<sup>۳</sup> و دسته‌بندی بر اساس جفت‌های ورودی-خروجی هستند. اما دسته دوم، تکنیک‌های خوشه‌بندی و کاهش ابعاد/خلاصه‌سازی را شامل می‌شود که هیچ دیدی نسبت به مقادیر خروجی ندارند. نوع دیگری با عنوان روش‌های یادگیری نیمه نظارتی نیز در این بین وجود دارد که قادر به سازمان‌دهی داده‌ها و ارائه پیش‌بینی‌ها بر اساس اطلاعاتی شامل

می‌توان انتظار یادگیری کارآمدتری از روابط پیچیده بین پارامترهای زلزله (زمان، مکان، بزرگی/شدت، آسیب بالقوه) متصور شد. یکی دیگر از مزایای این روش‌ها نسبت به روش‌های سنتی این است که با وجود کاهش نرخ خطا، بازدهی محاسباتی در خلال تصمیم‌گیری‌های لرزه‌ای را نیز افزایش می‌دهد. بدین ترتیب می‌توان گفت که با فرصت‌های جذابی برای توسعه شبکه‌های لرزه‌ای چند هدفه در حوزه‌هایی مانند حذف نویزها (شکل ۱)، تشخیص و انتخاب فاز هشدار سریع، سیستم‌های پیش‌بینی بلندمدت و میان‌مدت حرکت زمین، تشخیص پس‌لرزه‌ها و تحلیل خطر لرزه‌ای برای کاربردهای مهندسی زلزله و توسعه اشتراک اطلاعات در شبکه لرزه‌ای جهانی در پلتفرم اینترنت اشیا روبرو هستیم (جیو<sup>۱</sup> و علوی، ۲۰۲۰؛ خوشوقت سوزی و قیصری، ۱۳۹۸).



(الف)

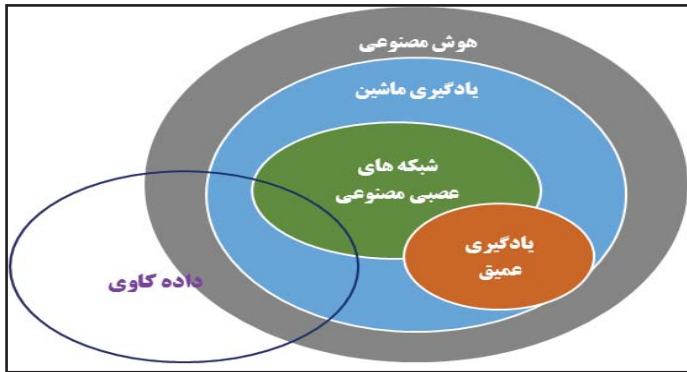


(ب)

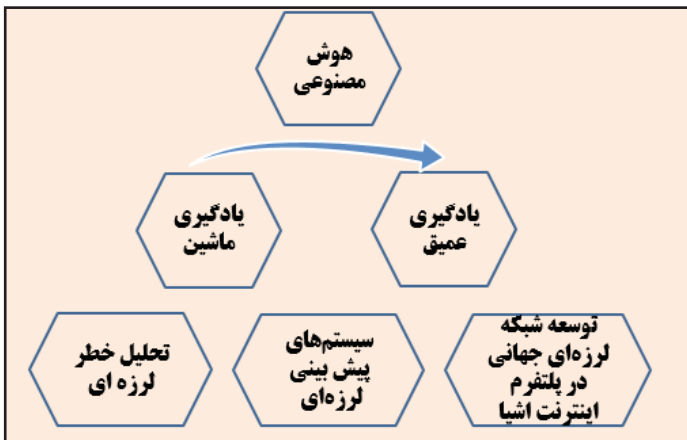
شکل ۱: (الف) مشخصات زلزله و رخدادهای لرزه‌ای به وقوع پیوسته در سال‌های ۲۰۱۳-۱۹۰۰ میلادی (ب) تحلیل لرزه‌ای بهینه‌سازی شده با هوش مصنوعی و نقش آن در تشخیص رخدادهای لرزه‌ای کوچک و حذف داده‌های خطا (جیو و علوی، ۲۰۲۰)

2. Kong  
3. Regression

1. Jiao



شکل ۲: درون بینی مفهوم هوش مصنوعی و علوم داده برای استفاده در کارکرد لرزه شناسی بر اساس (جیو و علوی، ۲۰۲۰)



شکل ۳: رویکردهای توسعه استفاده از هوش مصنوعی در لرزه شناسی از تکنیک های یادگیری ماشین به سمت یادگیری عمیق بر اساس (جیو و علوی، ۲۰۲۰)

### مدل سازی سری زمانی به کمک یادگیری عمیق

یکی از کارآمدترین روش های یادگیری ماشین برای پردازش داده های از نوع سری زمانی مانند داده های لرزه ای، تغییرات دما، ترافیک و... شبکه های عصبی بازگشتی (RNN) می باشند که مفهوم اولیه آن ها در دهه ۱۹۸۰ ارائه گردید (جردن<sup>۵</sup>، ۱۹۸۶). با این حال، استفاده گسترده از RNN در موضوعات سری زمانی بیشتر در چند سال اخیر متمرکز شده است. دلیل این استقبال در سال های اخیر را می توان در پیشرفت های جدید در طراحی شبکه های عصبی و پیشرفت های چشمگیر در قدرت محاسباتی، به ویژه کارایی واحدهای پردازش موازی کارت گرافیک جستجو کرد. در حقیقت، در گذشته، زمان اجرای زیادی که برای محاسبات سنگین شبکه های RNN در سیستم های قدیمی مورد نیاز بود، چالشی حل نشده در

تعداد کمی از نمونه های برجسب دار و تعداد زیادی از نمونه های بدون برجسب است (صالحی و بورگونو<sup>۱</sup>، ۲۰۱۸).

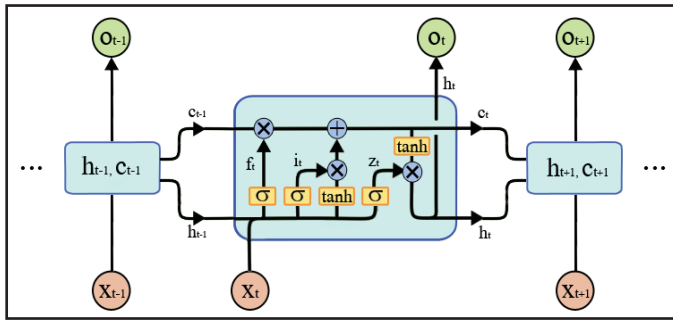
لازم به ذکر است که بخش عمده ای از مطالعات مربوط به هوش مصنوعی در لرزه نگاری طی دو دهه گذشته به استفاده از رویکردهای سنتی یادگیری ماشین همچون شبکه های عصبی مصنوعی و درخت های تصمیم اختصاص یافته اند (برگن<sup>۲</sup> و همکاران، ۲۰۱۹). این در حالی است که سیستم های لرزه ای توسعه یافته با روش های جدید یادگیری عمیق هنوز در ابتدای راه قرار دارند (شکل ۳).

یادگیری عمیق یکی از نوین ترین بخش های یادگیری ماشین می باشد که با رفع برخی محدودیت های آموزشی شبکه های عصبی کم عمق، الگوهای عمیق تری از مجموعه داده ها در حوزه های مختلف را یاد می گیرد. این مدل ها امکان تعریف روابط پیچیده و غیر خطی بین متغیرها را فراهم می سازند. توانایی های برتر یادگیری عمیق در مجموعه داده های سری زمانی، این روش را به یکی از برترین گزینه ها برای مسأله تشخیص ارتباط فاز / مراحل در لرزه نگاری تبدیل نموده است. این روش در هر بازه زمانی، یکی از مؤلفه های متوالی را برای حل مسئله ارتباط مراحل در لرزه نگاری استفاده می کند. بدین ترتیب این روش گزینه مناسبی برای کار با شبکه های لرزه ای بلادرنگ می باشد (جیو و علوی، ۲۰۲۰). از طرف دیگر، در مسائل دسته بندی<sup>۳</sup> مگاداده هایی موجود در شبکه های ثبت اطلاعات لرزه ای اعم از شبکه شتاب نگاری و لرزه نگاری برای اهدافی نظیر توسعه روابط کاهندگی، نرخ متوسط لرزه خیزی، تخمین شتاب بیشینه لرزه ای (PGA)<sup>۴</sup>، توسعه طیف های پاسخ شتاب و منحنی های شکنندگی، شرایط خاص این داده ها نظیر عدم تعادل در داده های مربوط به زلزله های بزرگ و کوچک و یا همبستگی و سری زمانی بودن اطلاعات مربوط به یک خوشه لرزه ای (زلزله اصلی و پس لرزه های مربوطه) باعث می شود که تکنیک های خاص در یادگیری عمیق بر مبنای خصوصیات این داده ها مورد توجه محققین قرار داشته باشد.

1. Burgueno  
2. Bergen  
3. Classification  
4. Peak Ground Acceleration

5. Recurrent Neural Networks  
6. Jordan

و اشمیدوبر<sup>۵</sup>، (۱۹۹۷) که با به‌کارگیری مفهومی جدید به نام حالت سلول<sup>۶</sup>، مشکل ناپدید شدن شیب را رفع نمود و تحول اساسی در مسائل سری زمانی پدید آورد. در این شبکه عمیق، هر نورون معمولی در لایه پنهان شبکه عصبی با یک سلول حافظه<sup>۷</sup> جایگزین گردیده است (شکل ۵). در واقع، هر سلول حافظه شامل گره‌ای با یک لبه بازگشتی متصل به خود با وزن ثابت است تا اطمینان حاصل شود که شیب می‌تواند از طریق چندین گام زمانی طولانی عبور کند بدون اینکه محو گردد یا از بین برود (لیپتون<sup>۸</sup> و همکاران ۲۰۱۵).



شکل ۵: ماژول تکرارشونده در یک شبکه LSTM که شامل چهار لایه است بر اساس (اولاه، ۲۰۱۵)

شکل ۵: ماژول تکرارشونده در یک شبکه LSTM که شامل چهار لایه است بر اساس (اولاه، ۲۰۱۵)

سلول‌های حافظه از دروازه‌های مختلفی تشکیل شده‌اند که می‌توانند جریان ورودی را کنترل کنند. یک سلول حافظه از حالت سلول، دروازه ورودی، دروازه فراموشی و دروازه خروجی تشکیل شده است. چهار لایه این واحد علاوه بر یک لایه تانژانت هیپربولیک شامل سه لایه سیگموئید می‌باشد. همچنین دو عمل جمع و ضرب نقطه‌ای برای تعیین این موضوع که چه میزان از اطلاعات اختیاری مجاز به عبور می‌باشد، وجود دارد. دروازه‌ها و لایه‌های مختلف شبکه عمیق LSTM، به همراه عملکردهای آن‌ها، به شرح زیر است: **حالت سلول:** در کل شبکه اجرا می‌شود و توانایی افزودن یا حذف اطلاعات با کمک دروازه‌ها را دارد.


**دروازه ورودی:** این دروازه شامل یک لایه سیگموئید می‌باشد که تصمیم می‌گیرد کدام مقادیر به روز شوند.

**دروازه فراموشی:** تصمیم می‌گیرد که چه بخشی از اطلاعات مجاز به عبور می‌باشد.

5. Hochreiter and Schmidhuber  
6. Cell State  
7. Memory Cell  
8. Lipton

جهت بهره‌گیری از ظرفیت کامل این شبکه‌ها بود.

در RNNها، برخلاف شبکه‌های عصبی معمولی، هر نورون<sup>۱</sup> (یا واحد پردازش) توانایی حفظ حالت داخلی برای به‌خاطر سپردن اطلاعات مربوط به ورودی زمان قبلی را دارد، به همین دلیل RNNها برای پردازش داده‌های سری و ترتیبی مؤثر و مفید هستند. ساختار یک شبکه RNN ساده در شکل ۴ نشان داده شده است.



شکل ۴: ماژول تکرارشونده در یک شبکه RNN ساده که شامل یک لایه است بر اساس (اولاه، ۲۰۱۵)

واحد RNN ساده فقط یک لایه دارد که شامل لایه تانژانت هیپربولیک می‌باشد که برای تعریف مقادیر واحدهای پنهانش از معادله ۱ استفاده می‌کند (سلوین<sup>۲</sup> و همکاران، ۲۰۱۷).

$$h_t = \tanh(W_{h_t} [h_{t-1}, x_t] + b_{h_t}) \quad (1)$$

که در این رابطه،  $x_t$  بردار ورودی و  $h_t$  بردار خروجی است. همچنین  $W_h$  و  $b_h$  به ترتیب ماتریس پارامتر و بردار هستند. بنابراین، در هر گام زمانی، دو ویژگی ورودی برای محاسبه خروجی  $h_t$  در لایه تانژانت هیپربولیک استفاده می‌گردد که شامل بردار ورودی فعلی  $x_t$  و بردار خروجی زمان قبلی  $h_{t-1}$  می‌باشد.

اگرچه شبکه‌های ساده RNN پیشرفت چشمگیری در مشکلات سری زمانی ایجاد کردند، اما از آنجاکه آموزش این نوع شبکه‌ها مبتنی بر شیب نزولی می‌باشد، شیب‌های خطا با افزایش تعداد بازگشت‌های زمانی، به‌سرعت ناپدید می‌گردد و بنابراین این نوع از شبکه‌ها توانایی به‌خاطر سپردن وقایع به‌صورت طولانی‌مدت را ندارند. برای رفع این مشکل، نوع جدیدی از شبکه‌های بازگشتی به نام حافظه طولانی کوتاه‌مدت (LSTM)<sup>۴</sup> معرفی گردید (هوکرایتر

1. Neuron  
2. Olah  
3. Selvin  
4. Long Short-Term Memory

از رومرکز زلزله - که امکان اقداماتی نظیر تخلیه اضطراری جمعیت را فراهم کند- همچنان به عنوان یک چالش مطرح می‌باشد. اگرچه با استفاده از اطلاعات ثبت شده از فاصله زمانی امواج فشاری و برشی لرزه‌ای در ایستگاه‌های لرزه‌نگاری، امکان هشدار سریع و آنی در چند ثانیه تا چند دقیقه قبل از وقوع یک زلزله برای کاربردهایی مانند قطع سیستم گازسانی، توقف قطارهای ریلی و کاربردهای فرماندهی حادثه با دقت تقریباً قابل قبولی در قرن اخیر فراهم گردیده است، اما همچنان چالش هشدار صحیح در فرصت زمانی کافی (پیش‌بینی کوتاه مدت و میان مدت) برای اقدامات مدیریت اضطراری قبل از زلزله باقی می‌باشد.

از قرن‌های گذشته، بررسی اطلاعات تغییرات غیرعادی در برخی متغیرهای موجود در محیط که قبل و هم‌زمان با وقوع زلزله‌های بزرگ گزارش شده است تحت عنوان پیش‌نشانگرهای لرزه‌ای مورد توجه بوده است و علی‌رغم اینکه برداشت‌های غیرعلمی از این اطلاعات توسط افراد فاقد صلاحیت باعث اختلاف‌نظرهای زیادی در نحوه اعتماد به اطلاعات این داده‌ها برای کاربردهای پیش‌بینی و هشدار لرزه‌ای شده است (ایوانس<sup>۳</sup>، ۱۹۹۷؛ وایتهد<sup>۴</sup>، ۲۰۰۴)، لیکن در قرن حاضر، رویکرد علمی در نحوه پردازش و استخراج ارتباط بین این داده‌ها با تغییرات فیزیکی کانون زلزله قبل از رخداد رویدادهای لرزه‌ای توسط مراکز تخصصی-پژوهشی پیش‌نشانگرهای لرزه‌ای در حال تکمیل است. پیش‌نشانگرهای لرزه‌ای را می‌توان مطابق شکل ۶ به دو دسته کلی لرزه‌ای و غیر لرزه‌ای تقسیم نمود که ذیل هر یک، متداول‌ترین پیش‌نشانگرهای تحقیقاتی - که سابقه بررسی آن‌ها بعد از وقوع زلزله‌های مختلف گزارش شده-، ارائه گردیده است (سایت مرکز مطالعات پیش‌نشانگرهای زلزله، ۱۴۰۰). البته تاکنون استفاده از هیچ‌یک از این پیش‌نشانگرها به پیش‌بینی قطعی زلزله قبل از وقوع آن منتهی نگردیده است و معمولاً بعد از وقوع زلزله، برحسب منطقه وقوع زلزله گزارش‌هایی از تجربه برخی موارد غیرعادی چند ساعت یا چند روز قبل از زلزله، به فرضیه وجود این پیش‌نشانگرها اشاره دارد. بر همین اساس، آزمایشگاه‌های تحقیقاتی برای بررسی این پیش‌نشانگرها قبل از وقوع زلزله‌های بزرگ در حال فعالیت

دروازه خروجی: از خروجی تولیدشده بر اساس حالت سلول تشکیل شده است و فقط اطلاعاتی را که کل واحد تصمیم گرفته است به عنوان خروجی ارائه می‌دهد.

لایه‌های سیگموئید: آن‌ها اعدادی را بین صفر تا یک تولید و توصیف می‌کنند چه مقدار از هر جزء مؤلفه باید عبور کند.

لایه تانژانت هیپربولیک: یک بردار کاندید جدید ایجاد می‌کند که می‌تواند به حالت سلول افزوده شود.

حالت سلول بر اساس خروجی دروازه‌ها به روز می‌شود. از نظر ریاضی می‌توان آن را با استفاده از ۵ معادله زیر نشان داد.

$$f_t = \sigma(W_f \cdot [h_{t-1} \ x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1} \ x_t] + b_i) \quad (3)$$

$$c_t = (f_t * c_{t-1}) + (i_t * \tanh(W_c \cdot [h_{t-1} \ x_t] + b_c)) \quad (4)$$

$$z_t = \sigma(W_z \cdot [h_{t-1} \ x_t] + b_z) \quad (5)$$

$$h_t = z_t * \tanh(c_t) \quad (6)$$

که در این روابط، xt بردار ورودی و ht بردار خروجی است. Ct بردار حالت سلول، ft بردار دروازه فراموشی، it بردار دروازه ورودی و zt بردار دروازه خروجی است. همچنین W و b به ترتیب ماتریس و بردار پارامتر هستند (اولاه<sup>۱</sup>، ۲۰۱۵).

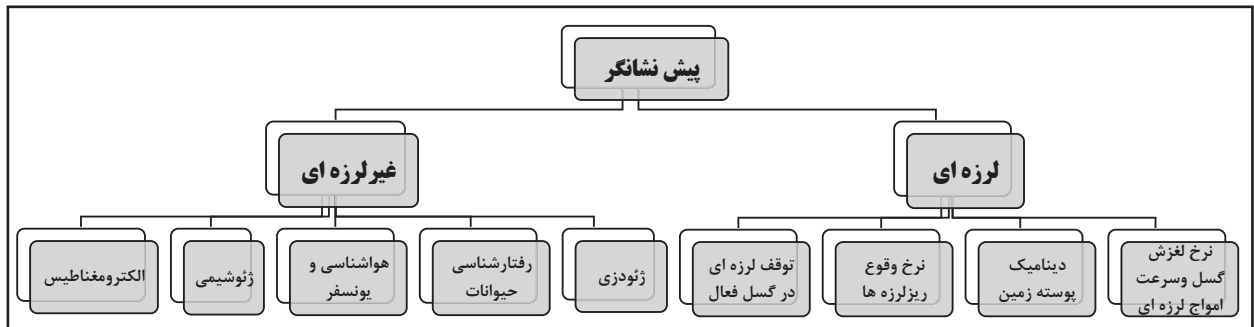
### کاربرد روش‌های یادگیری ماشین در سیستم‌های پردازش اطلاعات پیش‌نشانگرهای لرزه‌ای

پیش‌بینی زلزله به معنی شناسایی مشخصات دقیق مکان، زمان و بزرگی یک زلزله قریب‌الوقوع همواره به عنوان یک هدف غیرقابل دسترس و اجرا برای لرزه‌شناسان، مورد بحث و بررسی بوده است (اودیاس و بافرن<sup>۲</sup>، ۲۰۱۸). پیش‌بینی در بازه بلندمدت از طریق تحلیل خطر لرزه‌ای در مناطق مختلف لرزه‌خیز جهان بر مبنای داده‌های لرزه‌ای موجود اعم از داده‌های تاریخی و دستگاهی برای کاربردهای برنامه‌ریزی شهری، طراحی و مقاوم‌سازی سازه‌ها و مهندسی زلزله عملیاتی شده است، لیکن پیش‌بینی در بازه میان‌مدت و کوتاه‌مدت، در بازه‌های کوتاه چند ساعت تا چند روز قبل از وقوع یک زلزله و در بازه مکانی شعاع کمتر از یک کیلومتر

3. Evans  
4. Whitehead

1. Olah  
2. Udias & Buforn

هستند که معمولاً با رویکردهای احتمالاتی در پیش‌بینی رخداد زلزله برحسب تغییرات مشاهده شده در متغیرهای یک پیش‌نشانگر یا ترکیب چند پیش‌نشانگر در طول زمان می‌پردازند. با توجه به پیچیدگی پدیده زلزله و ارتباط غیرخطی و غیرقابل قطعی آن با داده‌هایی که از این پیش‌نشانگرها در طول زمان در حال ثبت می‌باشد، استفاده از روش‌های یادگیری ماشین به جای مدل‌های آماری سنتی با دقت پایین به عنوان یک رویکرد جدید در حال گسترش است.



شکل ۶: انواع پیش‌نشانگرهای مورد استفاده در سیستم پیش‌بینی احتمالاتی زلزله بر اساس (اودیاس و بافرن، ۲۰۱۸)

### بررسی نمونه موردی یادگیری عمیق تشخیص خطر PGA بر

#### اساس داده‌های پیش‌نشانگر رفتارشناسی حیوانات

این تحقیق انتخاب و با به‌کارگیری رویکرد یادگیری عمیق احتمال خیزش در مقادیر PGA در گام‌های زمانی آینده به کمک تغییرات میزان فعالیت حیوانات مزرعه در گام‌های زمانی پیشین برای ایجاد یک سیستم هشدار احتمالاتی مورد بررسی قرار گرفته است.

برای جمع‌آوری داده‌ها، از نتایج آزمایش‌های تجربی انجام شده در روستای کاپریگلیا<sup>۵</sup> -واقع در ایتالیا- بین سال‌های ۲۰۱۶ و ۲۰۱۷ استفاده شد (ویکلسکی<sup>۶</sup> و همکاران، ۲۰۲۰). در این سری از آزمایش‌ها، ۱۳ حیوان مزرعه‌ای از گونه‌های مختلف که در داخل یک اسطبل در وضعیت آزاد برای دویدن قرار داشتند، به منظور ثبت فعالیت، به حسگرهای شتاب‌سنج سه‌بعدی مجهز گردیدند. در واقع، دستگاه‌های ثبت شتاب نصب‌شده، شتاب کلی پویای بدن (ODBA)<sup>۷</sup> حیوانات را در هر ۱۵ دقیقه تعیین می‌کنند. داده‌های جمع‌آوری شده از فعالیت‌های حیوانات مزرعه مربوط به دو دوره اکتبر-نوامبر ۲۰۱۶ و ژانویه-آوریل ۲۰۱۷ می‌باشد. در ضمن، علاوه بر اطلاعات مربوط به تغییرات فعالیت حیوانات، داده‌های مربوط به زمین‌لرزه‌های رخ داده در این منطقه در این دو دوره زمانی نیز جمع‌آوری شده است. در واقع، برابر گام‌های زمانی ۱۵ دقیقه‌ای، اطلاعات مربوط به بزرگ‌ترین زمین‌لرزه که هر ۱۵ دقیقه

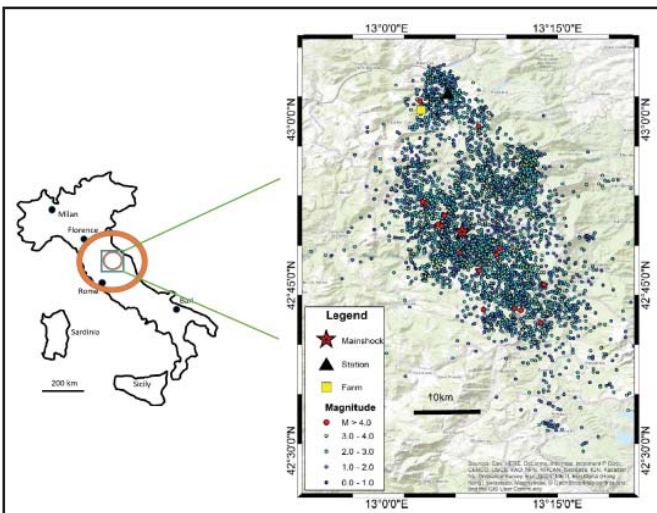
از جمله پیش‌نشانگرهایی که سابقه تاریخی توجه بشر به آن در گزارش‌های ثبت شده بعد از وقوع زلزله‌های مناطق مختلف لرزه‌خیز جهان قابل توجه می‌باشد، پیش‌نشانگر رفتار غیرعادی حیوانات در بازه زمانی نزدیک به لحظه وقوع زلزله بوده است که برحسب تنوع حیوانات موجود در منطقه لرزه‌خیز، گزارش‌هایی از رفتارهای غیرعادی در حیواناتی نظیر مارها، حیوانات مزرعه، پرندگان، موش‌ها، گربه‌ماهی‌ها، مورچه‌ها، میمون‌ها و گربه‌سانان موجود است که در توجیه آن فرضیه‌هایی مبنی بر توانایی درک پیش‌نشانگرهایی نظیر امواج و یا تغییرات محیطی نظیر تغییرات ژئوشیمی و ژئودزی محیط نزدیک به کانون زلزله توسط برخی حیوانات مطرح می‌باشد (دیویس<sup>۱</sup>، ۱۹۷۵؛ فیدانی<sup>۲</sup>، ۲۰۱۳؛ ویس<sup>۳</sup>، ۲۰۱۸). به همین لحاظ تحقیقاتی برای ثبت مستمر رفتارهای حیوانات در محیط ایزوله آزمایشگاهی و استخراج داده‌های رفتارهای غیرعادی در برخی مناطق لرزه‌خیز جهان انجام گردیده است که داده‌های ثبت‌شده از اطلاعات یکی از این تحقیقات (ویکلسکی<sup>۴</sup> و همکاران، ۲۰۲۰) -که بر روی رفتار حیوانات اهلی مزرعه‌ای در ناحیه ایتالیا انجام شده است- در

5. Capriglia  
6. Wikelski  
7. Overall Dynamic Body Acceleration

1. Davies  
2. Fidani  
3. Woith  
4. Wikelski

در مسائل طبقه‌بندی داده‌های لرزه‌ای که همواره لرزش‌های جدی‌تر در مقابل حالت‌های غیر جدی به ندرت رخ می‌دهد، مسئله عدم تعادل کلاس به طور پیرنگی حضور دارد که اگر این مانع نادیده گرفته شود و یا به‌درستی کنترل نگردد، می‌تواند عملکرد مدل‌ها را به نفع کلاس اکثریت به شدت تحت تأثیر قرار دهد، به طوری که مدل‌ها تمایل خواهند داشت تمام نمونه‌ها را به عنوان کلاس اکثریت برچسب‌گذاری کنند.

با توجه به شرایط شرح داده شده حاکم بر مسئله، برای طراحی مدل طبقه‌بندی از یک شبکه عمیق LSTM تجهیز شده به رویکرد حساس به هزینه<sup>۲</sup> بهره گرفته شده است؛ که جزئیات آن در شکل ۹ به تصویر کشیده شده است. در حقیقت، در رویکرد حساس به هزینه سعی بر این است که با افزایش توجه مدل به نمونه‌های کلاس اقلیت، روند یادگیری مدل‌ها در شرایط عدم تعادل کلاس بهبود یابد. در واقع، با تحمیل هزینه‌های بیشتر به تابع هزینه در ازای طبقه‌بندی نادرست نمونه‌های کلاس اقلیت، اهمیت کلاس‌ها به این گونه اصلاح می‌شود که پیش‌بینی اشتباه هر نمونه از کلاس اقلیت چندین برابر هر نمونه از کلاس اکثریت برای تابع هزینه ضرر به بار بیاورد تا طبقه‌بند مجبور به توجه بیشتر به نمونه‌های نادر گردد. مطابق مدل پیشنهادی، شبکه LSTM حساس به هزینه، در نهایت به یک لایه سیگموئیدی متصل گردیده است تا احتمال تعلق به کلاس‌های معرفی شده را محاسبه نماید.



شکل ۷: جزئیات مکان زمین‌لرزه‌های اکتبر-نوامبر ۲۰۱۶ در مرکز ایتالیا (ویکلسکی و همکاران، ۲۰۲۰م).


رخ داده است، شامل بزرگی<sup>۱</sup>، عمق، طول و عرض جغرافیایی رومرکز زمین‌لرزه نیز ثبت شده است. بین تاریخ ۲۹ اکتبر تا ۷ نوامبر ۲۰۱۶، در مجموع ۵۳۰۴ زمین‌لرزه با بزرگی بیشتر از ۰٫۴ ریشتر رخ داده که شوک اصلی نورسیا به قدرت ۶٫۶ ریشتر در مرکز ایتالیا و رم احساس شده است. همچنین، از ژانویه تا آوریل ۲۰۱۷، در مجموع ۱۲۹۴۸ (حداکثر بزرگی ۵٫۵) ثبت گردیده که پراکندگی رومرکز زمین‌لرزه اصلی و پس‌لرزه‌ها در شکل ۷ نشان داده شده است و فواصل رومرکز این زلزله در فواصل کمتر از یک کیلومتری تا ۱۰۰ کیلومتری مزرعه مزبور پراکنده شده است. به این ترتیب، طبق اطلاعات دو مجموعه داده، پایگاه داده اول شامل ۶۴۲ نمونه گام زمانی و پایگاه داده دوم شامل ۸۳۱۸ نمونه گام زمانی ۱۵ دقیقه‌ای است که دسته اول برای آزمایش مدل‌های یادگیری عمیق و دومی برای آموزش مدل استفاده می‌گردد. جزئیات فضای ویژگی داده‌های جمع‌آوری شده، در جدول ۱ ارائه شده است. در واقع، برای آموزش مدل‌ها، اطلاعات مربوط به تغییرات فعالیت حیوانات در ۱۲ ساعت قبل به عنوان ورودی و میزان احتمال وقوع یک زمین‌لرزه جدی به عنوان خروجی در نظر گرفته می‌شود. در این راستا، ویژگی بزرگی، قدرت زمین‌لرزه را نشان می‌دهد اما از آنجاکه فاصله مزرعه از مرکز زمین‌لرزه را در نظر نمی‌گیرد، پارامتر مناسبی برای پیش‌بینی نمی‌باشد. با این حال، شتاب بیشینه لرزه‌ای (PGA)، که نشان‌دهنده میزان لرزش تجربه‌شده در یک مکان توسط ذره‌ای روی زمین می‌باشد، می‌تواند پارامتر مفیدتری برای این مسئله باشد. بنابراین، مسأله بدین صورت فرموله شده است که مقادیر  $PGA \leq 0.005 g$  (زلزله قابل‌اعتنا) به عنوان کلاس دوم تعیین گردد (زلزله غیرقابل‌اعتنا). در حقیقت، سعی شده است که با استفاده از اطلاعات مربوط به تغییرات فعالیت حیوانات در ساعات گذشته، احتمال وقوع یک زمین‌لرزه جدی در گام‌های زمانی بعدی تعیین گردد. با این وجود، همان‌طور که در شکل ۸ نشان داده شده است، این مسئله از یک توزیع بسیار نامتعادل بین دو کلاس برخوردار می‌باشد، به طوری که در مجموعه آموزشی، نسبت حجم نمونه مربوط به کلاس هدف به کلاس نمونه کلاس دوم، مقدار ناچیز  $0.0077$  را نشان می‌دهد. می‌توان گفت به طور کلی






جدول ۲: اطلاعات مربوط به ویژگی‌های مجموعه داده

| ویژگی              | واحد              | توصیف   | میانگین | حداکثر | حداقل |
|--------------------|-------------------|---|---------|--------|-------|
| فعالیت حیوانات     | ولتاژ موجک حسگرها | میانگین فعالیت حیوانات مزرعه در هر ۱۵ دقیقه         | ۱۷۴.۰۲۱ | ۶۳۵۵۴۸ | ۴۴۶۶۱ |
| عرض جغرافیایی      | درجه              | عرض جغرافیایی قوی‌ترین زلزله در هر ۱۵ دقیقه         | ۴۲.۷۷   | ۴۳.۸۱  | ۴۲.۰۸ |
| طول جغرافیایی      | درجه              | طول جغرافیایی قوی‌ترین زلزله در هر ۱۵ دقیقه         | ۱۳.۱۶   | ۱۴.۲۳  | ۱۱.۷۶ |
| عمق                | کیلومتر           | عمق قوی‌ترین زلزله در هر ۱۵ دقیقه                   | ۱۰.۲۸   | ۶۱.۱   | ۰.۱   |
| بزرگی              | ریشتر             | حداکثر بزرگی زلزله در هر ۱۵ دقیقه                   | ۱.۴۲    | ۵.۵    | ۰.۱   |
| فاصله رومرکز زلزله | کیلومتر           | فاصله مزرعه از مرکز قوی‌ترین زمین‌لرزه هر ۱۵ دقیقه  | ۳۲.۰۶   | ۱۰۹.۴۹ | ۰.۰۹  |
| فاصله کانونی زلزله | کیلومتر           | فاصله مزرعه از کانون قوی‌ترین زمین‌لرزه هر ۱۵ دقیقه | ۳۴.۹۴   | ۱۰۹.۹۶ | ۲.۰۸  |
| PGA                | G                 | حداکثر شتاب پیشینه لرزه‌ای زلزله‌های هر ۱۵ دقیقه    | ۰.۰۰۰۱۱ | ۰.۰۲۱۳ | .     |

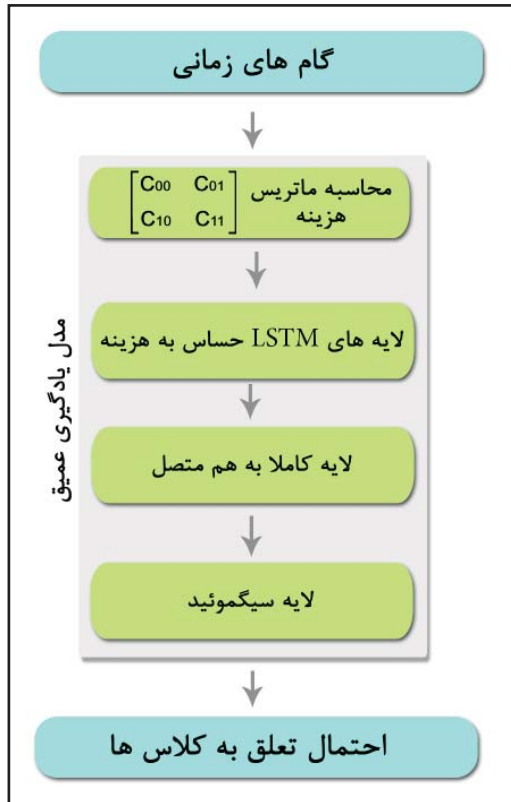


(الف)



(ب)

شکل ۸: سری زمانی مقادیر PGA در طی بازه زمانی مربوط به الف) مجموعه آموزشی ب) مجموعه آزمون (لینک داده‌ها از مرجع ویکلکسی (۲۰۲۰م.) قابل دسترسی است)



شکل ۹: مدل پیشنهادی مبتنی بر یادگیری عمیق و رویکرد حساس به هزینه برای طبقه بندی داده های لرزه ای

### نتیجه گیری

در این تحقیق، کاربرد و قابلیت های یادگیری عمیق به عنوان شاخه ای نوین از هوش مصنوعی، برای طبقه بندی داده های ثبت شده مرتبط با پدیده پیچیده زلزله و تشخیص الگو و پیدا کردن ارتباطات احتمالاتی بین ویژگی های پنهان در داده های مزبور در دو گام مورد بررسی قرار گرفته است. ابتدا، با بررسی ویژگی های خاص داده های لرزه ای، چند عامل اساسی که نادیده گرفتن آن ها مانع از دستیابی روش های یادگیری ماشین به عملکرد شایسته در این نوع از داده ها می شوند، شناسایی گردید. در این بین، وجود ارتباطات زمانی معنادار بین نمونه های لرزه ای و عدم تعادل شدید طبقاتی بین رویدادهای لرزه ای قابل اعتنا در مقابل موارد دیگر، از مهم ترین عوامل شناسایی شده هستند. سپس، با در نظر گرفتن ویژگی های ذکر شده، یک چارچوب جدید بر اساس بکارگیری شبکه های عمیق بازگشتی LSTM که به تابع ضرر حساس به هزینه مجهز گردیده اند، برای هدف طبقه بندی داده های نامتعادل لرزه ای پیشنهاد شده است. چارچوب پیشنهادی با اصلاح تابع ضرر شبکه LSTM، علاوه بر اینکه

برای ارزیابی عملکرد مدل به جای بکارگیری از معیار دقت ساده، از معیار دقت متعادل مطابق رابطه ۷ استفاده گردیده است. این معیار به خاطر آنکه برای هر دو دسته از کلاس ها - فارغ از حجم نمونه شان - اهمیت یکسانی را در نظر می گیرد، تأثیر عدم تعادل کلاس حاکم بر مسأله را بر نتایج از بین می برد و توانایی واقعی مدل ها را بازتاب می دهد.

$$Balanced\_Accuracy = \frac{\sum_i^N \frac{TP_i}{TP_i + FN_i}}{N} * 100 \quad (7)$$

در این رابطه  $N$  تعداد کلاس ها و  $TP_i$  تعداد نمونه های کلاس  $i$  است که به درستی پیش بینی شده است. همچنین،  $FN_i$  شامل تعداد نمونه های کلاس  $i$  است که به عنوان کلاس دیگری به اشتباه پیش بینی شده اند. بررسی نتایج اجرای مدل پیشنهادی با استفاده از روش اعتبارسنجی متقابل<sup>۱</sup>، میانگین دقت متعادل ۸۱٫۲ درصد بر روی داده های آموزشی و ۵۹٫۳ درصد بر روی داده های آزمون را نشان می دهد. این در حالی است که در اجرای مشابه روش اعتبارسنجی متقابل برای شبکه های عصبی بازگشتی معمولی میانگین دقت متعادل به ۶۳٫۵ درصد بر روی داده های آموزشی و ۵۰٫۶ درصد بر روی داده های آزمون کاهش می یابد. این تفاوت قابل توجه عملکرد مدل ها، نشان دهنده وجود سیگنال های مثبتی در بکارگیری یادگیری عمیق به منظور تحلیل داده های پیش نشانگرها برای چشم انداز کاربردهایی نظیر طراحی سامانه های بلادرنگ احتمالاتی پیش بینی خیزش در مقادیر PGA در بازه های کوتاه مدت (چند ساعت تا چند روز قبل از وقوع زلزله) می باشد. البته برای دستیابی به این چشم انداز، انتخاب نوع پیش نشانگر و افزایش تعداد داده های آموزشی مورد استفاده در روش یادگیری عمیق، تأثیر قابل توجهی بر دسته بندی داده ها در بازه های مؤثرتر به منظور پیش بینی زلزله های شدید برای کاربردهای تصمیم گیری و مدیریت خطر پذیری دارد، لیکن چارچوب مورد استفاده در این تحقیق می تواند در دسته بندی اطلاعات معنادار برای اهدافی نظیر طراحی سیستم های احتمالاتی هشدار و پیش بینی کوتاه مدت و میان مدت کمک کند.

1. Cross-validation

- 11(3), 2020, 739-744. doi: 10.1016/j.gsf.2019.10.004
- Jordan, M. (1986). Serial order: A parallel distributed processing approach, ICS Report 8604. Institute for Cognitive Science, UCSD.
- Kong, Q., Trugman, D.T., Ross, Z.E., Bianco, M.J., Meade, B.J., Gerstoft, P. (2019). Machine learning in seismology: turning data into insights. *Seismol. Res. Lett.*, 90 (1), 3–14. doi:10.1785/0220180259
- Lary, D.J., Alavi, A.H., Gandomi, A.H., Walker, A.L. (2015). Machine learning in geosciences and remote sensing. *Geosci. Front.* 7(1), 3–10. doi: 10.1016/j.gsf.2015.07.003
- Li, Z., Meier, M., Hauksson, E., Zhan, Z., Andrews, J. (2018). Machine learning seismic wave discrimination: application to earthquake early warning. *Geophys. Res. Lett.* 45, 4773–4779. doi: 10.1029/2018GL077870
- Lipton, Z.C., Berkowitz, J., Elkan, C. (2015). A critical review of recurrent neural networks for sequence learning. arXiv preprint arXiv:1506.00019.
- Olah C (2015) Understanding LSTM networks. <http://colah.github.io/posts/2015-08-Understanding-LSTMs>. Accessed 21 March 2021
- Salehi, H., Burgueno, R. (2018). Emerging artificial intelligence methods in structural engineering. *Eng. Struct.*, 171, 170–189. doi: 10.1016/j.engstruct.2018.05.084
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E., Menon, V. K., Soman, K. (2017) Stock price prediction using LSTM, RNN and CNN-sliding window model. International Conference on Advances in Computing, Communications and Informatics (ICACCI). doi: 10.1109/ICACCI.2017.8126078
- Udias, A., Buforn, E. (2018). Principles of seismology. Cambridge: Cambridge University Press. doi: 10.1017/9781316481615.
- Whitehead, N., Ulusoy, U., Asahara, H., Ikeya, M. (2004). Are any public-reported earthquake precursors valid?, *Natural Hazards and Earth System Sciences*, 4(3), 463–468. doi: 10.5194/nhess-4-463-2004
- Wikelski, M. (2020). Potential short-term earthquake forecasting by farm animal monitoring, Dryad, Dataset, <https://doi.org/10.5061/dryad.q2bvq83gq>
- Wikelski, M., Mueller, U., Scocco, P., Catorci, A., Desinov, L.V., Belyaev, M.Y., Keim, D., Pohlmeier, W., Fichteler, G., Martin Mai, P. (2020). Potential short-term earthquake forecasting by farm animal monitoring. *Ethology*, 126(9), 931-941. doi:10.1111/eth.13078
- Woith, H., Petersen, G. M., Hainzl, S., & Dahm, T. (2018). Can Animals Predict Earthquakes?. *Bulletin of the Seismological Society of America*, 108(3A), 1031–1045. doi:10.1785/0120170313.
- توانایی یادگیری الگوهای وابسته به زمان موجود در بین رویدادهای لرزه‌ای را دارا می‌باشد، برای کلاس‌های اکثریت و اقلیت مسأله نیز اهمیت یکسانی را قائل می‌گردد. به منظور ارزیابی عملکرد ساختار پیشنهادی، یک مطالعه موردی در مورد طبقه‌بندی مقادیر شتاب بیشینه لرزه‌ای در گام زمانی بعدی بر اساس سری زمانی اطلاعات ثبت شده از پیش‌نشانگر لرزه‌ای فعالیت غیرطبیعی حیوانات در ایتالیا در زلزله‌های سال ۲۰۱۶ و ۲۰۱۷ میلادی مورد بررسی قرار گرفته است. بررسی نتایج با استفاده از روش اعتبارسنجی متقابل نشان می‌دهد که مدل پیشنهادی در مقایسه با شبکه‌های عصبی بازگشتی معمولی، به میزان ۱۸ درصد بر روی داده‌های آموزشی و ۹ درصد بر روی داده‌های آزمایشی دقت بالاتری را در مسأله طبقه بندی مقادیر PGA کسب نموده است؛ که این موضوع حاکی از پتانسیل پنهان رویکردهای مبتنی بر یادگیری عمیق برای مدل‌سازی داده‌های سری زمانی لرزه‌ای می باشد.
- منابع**
- سایت مرکز مطالعات پیش‌نشانگرهای زلزله وابسته به موسسه ژئوفیزیک دانشگاه تهران بازیابی از: <http://rcep.ut.ac.ir/>
- خوشوقت سویری، ع، قیصری، م. (۱۳۹۸). بررسی پتانسیل اینترنت اشیا مبتنی بر رایانش مه، بر طراحی و ایجاد سامانه تشخیص، هشدار و پاسخ آنی زمین‌لرزه، نشریه دانش پیشگیری و مدیریت بحران، ۸ (۲)، ۱۷۳–۱۸۶.
- Alavi, A.H., Gandomi, A.H. (2011). Prediction of principal ground-motion parameters using a hybrid method coupling artificial neural networks and simulated annealing. *Comput. Struct.*, 89, 2176–2194. doi: 10.1016/j.compstruc.2011.08.019
- Bergen, K.J., Chen, T., Li, Z. (2019). Preface to the focus section on machine learning in seismology. *Seismol. Res. Lett.*, 90 (2A), 477–480. doi: 10.1785/0220190018
- Davies, D. (1975). Earthquake prediction in China. *Nature*, 258(5533), 286–287. doi: 10.1038/258286a0
- Evans, R. (1997). Assessment of schemes for earthquake prediction: Editor's introduction. *Geophys. J. Int.*, 131, 413–420. doi: 10.1111/j.1365-246X.1997.tb06585.x
- Fidani, C. (2013). Biological anomalies around the 2009 L'Aquila earthquake. *Animals*, 3(3), 693–721. doi: 10.3390/ani3030693
- Hochreiter S., Schmidhuber, J. (1997). Long short-term memory. *Neural Comput.*, 9 (8): 1735-1780. doi:10.1162/neco.1997.9.8.1735
- Jiao, P., Alavi, A. H. (2020). Artificial intelligence in seismology: Advent, performance and future trends, *Geoscience Frontiers*,