

شبکه های عصبی کانولوشنی و پیش بینی زلزله: مروری بر مطالعات اخیر

مریم هدهدی^{*1}

1 گروه فیزیک، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران، hodhodi1355@pel.iaun.ac.ir

^{*} نویسنده مسئول: مریم هدهدی

چکیده فارسی

در سالهای اخیر، با پیشرفتهای چشمگیر در زمینه یادگیری عمیق و به ویژه شبکه های عصبی کانولوشنی (Convolutional Neural Networks; CNN)، روشهای جدیدی برای تحلیل داده های لرزه ای و بهبود دقت پیش بینی زلزله ارائه شده است. در این پژوهش مروری بر کاربردهای مختلف CNN در تحلیل داده های لرزه ای در طی یک دهه گذشته شده است؛ نتایج حاکی از آن است که روشهای مبتنی بر شبکه های عصبی کانولوشنی، با وجود پاره ای از محدودیتهای اما به دلیل دقت بالای خود نسبت به سایر روشها، افقهای جدیدی در جهت بهبود پیش بینی زلزله و کاهش چشمگیر خسارات ناشی از آن، ایجاد کرده است؛ CNNها با استفاده از داده های ماهواره ای و تصاویر هوایی، قادر به تحلیل تغییر شکلهای پوسته و شناسایی مناطق مستعد زلزله هستند. همچنین، توانایی این روشها در پردازش داده های پیچیده و شناسایی الگوها باعث می شود که در پیش بینی و مدیریت بحرانها مؤثرتر باشند. با این حال، پیش بینی دقیق زلزله همچنان یکی از چالشهای بزرگ در علم زلزله شناسی است و نیازمند تحقیقات بیشتر در زمینه جمع اوری داده های با کیفیت و توسعه مدلهای پیچیده تر است.

واژه های کلیدی: شبکه های عصبی کانولوشنی، پیش بینی زلزله، یادگیری عمیق.

Recent Advances in Earthquake Prediction Using Convolutional Neural Networks: A Comprehensive Review

Maryam Hodhodi^{1*}

¹Department of Physics, Najafabad Branch, Islamic Azad University, Najafabad, Iran ; hodhodi1355@pel.iaun.ac.ir

^{*} Corresponding author: Maryam Hodhodi

ABSTRACT

In recent years, with significant advances in the field of deep learning and especially convolutional neural networks (CNN), new methods have been presented to analyze seismic data and improve the accuracy of earthquake prediction. The results indicate that methods based on convolutional neural networks, despite some limitations, but due to their high accuracy compared to other methods, have created new horizons in the direction of improving earthquake forecasting and significantly reducing the damages caused by it; Using satellite data and aerial images, CNNs are able to analyze crust deformations and identify earthquake-prone areas. Also, the ability of these methods to process complex data and identify patterns makes them more effective in predicting and managing disasters. However, accurate earthquake prediction is still one of the major challenges in seismology and requires more research in the field of quality data collection and development of more complex models.

Keywords: Convolutional neural networks, earthquake prediction, deep learning.

1- مقدمه

بطور کلی، شبکه عصبی مصنوعی و یادگیری عمیق دو مفهوم کلیدی در حوزه هوش مصنوعی و یادگیری ماشین هستند. شبکه های عصبی مصنوعی ابزارهای اصلی یادگیری عمیق هستند و این یادگیری امکان استفاده از این شبکه ها برای حل مسائل پیچیده ای نظیر زلزله را فراهم می کند. از جمله ابزارهای نوین در حوزه یادگیری عمیق، شبکه های عصبی کانولوشنی می باشند که به دلیل توانایی شناسایی و استخراج ویژگی های فضایی به ویژه در پردازش داده های تصویری و سیگنال های پیچیده مانند داده های لرزه ای، پیشرفت روز افزونی در حوزه پیش بینی زلزله داشته اند؛ این شبکه ها می توانند برای تحلیل داده های لرزه نگاری، داده های ماهواره ای و سایر داده های مرتبط با زلزله استفاده شوند [1]. در این مقاله، به بررسی داده های

علمی و نتایج تحقیقات پیشین در زمینه کاربردهای مختلف شبکه های عصبی کانولوشنی در زمینه پیش بینی زلزله ها پرداخته شده است؛ ابتدا عملکرد CNNها بطور خلاصه معرفی و توصیف می شود، سپس با مرور جامع بر مطالعات اخیر و پس از مقایسه CNNها با سایر روشهای یادگیری عمیق، نقاط قوت و ضعف این مدلها و چالشهای موجود، بویژه در تحلیل سیگنالهای لرزه ای بحث می شود. در نهایت، راهکارهایی در خصوص بهبود مدلهای CNN ارائه می شود.

2- شبکه های عصبی کانولوشنی

CNNها به طور خاص برای پردازش داده های غیرخطی طراحی شده اند و می توانند با کاهش ابعاد داده ها از طریق لایه های کانولوشن و تجمیع ، ویژگی های مهم را حفظ کنند. همچنین، عمق یادگیری در CNNها این امکان را فراهم می آورد که ویژگی های سطح بالا از داده های ورودی استخراج شوند، که به شناسایی دقیق تر الگوها کمک می کند. این روشها به دلیل مزایای متعدد خود در پردازش داده ها به طور گسترده ای مورد استفاده قرار می گیرند؛ یکی از این مزایا، توانایی آن ها در استخراج خودکار ویژگی ها از داده ها است، که نیاز به طراحی دستی ویژگی ها را کاهش می دهد. همچنین، با اشتراک گذاری وزن ها در لایه های کانولوشن، تعداد پارامترهای شبکه به طور قابل توجهی کاهش می یابد، که باعث بهینه تر شدن مدل می شود. علاوه بر این، CNNها نسبت به تغییرات کوچک در تصاویر مانند چرخش، تغییر اندازه و نویز مقاوم هستند، که این ویژگی ها آن ها را به عنوان ابزاری مفید در بینایی ماشین و یادگیری مطرح کرده است. در نهایت، کارایی بالای این روش در مقایسه با سایر روش های یادگیری ماشین، آن را به ابزارهای مؤثری برای پیش بینی زلزله و تحلیل داده های لرزه ای تبدیل می کند [2]. این شبکه ها انواع مختلفی دارند که هر کدام برای کاربردهای خاصی طراحی شده اند. این مدل ها هر کدام ویژگی ها و مزایای خاص خود را دارند و بسته به نوع داده و کاربرد، ممکن است یکی از آن ها مناسب تر باشد [3]. در جدول 1 برخی از مهم ترین انواع CNNها به همراه ویژگی ها و کاربردهای اصلی آن ها آورده شده است.

جدول 1: مقایسه انواع شبکه های CNN

نوع شبکه عصبی کانولوشنی	ویژگی های اصلی	کاربردهای اصلی
شبکه های CNN معمولی	ساختار ساده، لایه های کانولوشن و پولینگ، مناسب برای وظایف طبقه بندی و تشخیص اشیا	تشخیص اشیا در تصاویر، طبقه بندی تصاویر، تشخیص چهره
شبکه های CNN عمیق	تعداد زیادی لایه، توانایی یادگیری ویژگی های پیچیده، مناسب برای وظایف پیچیده بینایی ماشین	تشخیص اشیا در ویدیو، تشخیص اجزای تصویر، تولید تصویر
شبکه های CNN با اتصالات کوتاه (Residual Networks)	اتصالات کوتاه برای بهبود جریان اطلاعات، مناسب برای شبکه های عمیق	تشخیص اشیا در تصاویر با وضوح بالا، طبقه بندی تصاویر با دقت بالا
شبکه های CNN با هسته های قابل یادگیری (Inception Networks)	استفاده از هسته های با اندازه های مختلف، افزایش توانایی استخراج ویژگی ها	تشخیص اشیا در تصاویر با اندازه های مختلف، طبقه بندی تصاویر با دقت بالا
شبکه های CNN با مکانیزم توجه (Attention Networks)	تمرکز بر نواحی مهم تصویر، بهبود دقت در تشخیص اشیا	تشخیص اشیا کوچک، تشخیص اشیا در تصاویر شلوغ
شبکه های CNN با ساختار U-Net	ساختار متقارن برای وظایف سگمانتاسیون تصویر، حفظ جزئیات تصویر	سگمانتاسیون تصویر پزشکی، سگمانتاسیون تصاویر ماهواره ای
شبکه های CNN سه بعدی	پردازش داده های سه بعدی مانند ویدیو و تصاویر پزشکی	تشخیص اشیا در ویدیو، تحلیل تصاویر پزشکی

در پیش بینی زلزله، معمولاً از مدل های شبکه های عصبی کانولوشنی نظیر ResNet و DenseNet استفاده می شود. ResNet و DenseNet جزو دسته بندی شبکه های عصبی کانولوشنی عمیق هستند. این مدل ها به دلیل توانایی در استخراج ویژگی های پیچیده از داده های زمان-سری و تصاویر، مناسب هستند [4]. همچنین، شبکه عصبی حافظه بلند مدت کوتاه مدت (Long Short-Term Memory; LSTM) که نوعی شبکه عصبی بازگشتی است، به طور گسترده ای در ترکیب با CNN برای تحلیل داده های زمانی و پیش بینی زلزله به کار می رود. تحقیقات نشان داده اند که ترکیب این مدل ها می تواند به بهبود دقت پیش بینی کمک کند؛ این دو مدل به دلیل معماری های خاص خود، در بین شبکه های عصبی کانولوشنی عمیق بسیار محبوب و مؤثر هستند [5]. آموزش شبکه های عصبی کانولوشنی معمولاً شامل چند مرحله کلیدی است. ابتدا، داده های آموزشی باید جمع آوری و پیش پردازش شوند، که شامل نرمال سازی، تغییر اندازه و تقسیم بندی داده ها به مجموعه های آموزش، اعتبارسنجی و آزمون است. سپس، معماری

شبکه طراحی می‌شود که شامل انتخاب تعداد لایه‌ها، نوع لایه‌ها (مانند لایه‌های کانولوشنی، لایه‌های حداکثر تجمع، و لایه‌های کاملاً متصل) و پارامترهای دیگر است. پس از طراحی، شبکه با استفاده از داده‌های آموزشی آموزش داده می‌شود. این مرحله شامل محاسبه تابع هزینه و به‌روزرسانی وزن‌ها با استفاده از الگوریتم‌های بهینه‌سازی مانند Adam یا Stochastic Gradient Descent (SGD) است. در طول آموزش، عملکرد شبکه با استفاده از داده‌های اعتبارسنجی ارزیابی می‌شود تا از بیش‌برازش جلوگیری شود. در نهایت، پس از اتمام آموزش، مدل بر روی داده‌های آزمون آزمایش می‌شود تا دقت و کارایی آن ارزیابی شود. این مراحل به تدریج به بهبود عملکرد شبکه کمک می‌کند و آن را برای کاربردهای مختلف نظیر پیش‌بینی وقوع زلزله در مناطق مختلف آماده می‌سازد [6].

3- مرور مطالعات اخیر

هوانگ و همکاران [7] برای پیش‌بینی بزرگای زلزله‌های بزرگ در تایوان، از شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های ضمنی از تصاویر جغرافیایی همراه با اطلاعات لرزه‌ای استفاده کردند. نتایج مطالعه آن‌ها نشان داد که با در نظر گرفتن حوادث شکست زمین در 120 روز قبل، می‌توان به پیش‌بینی دقیقی از حداکثر شدت زلزله‌ای که ممکن است در 30 روز آینده در تایوان رخ دهد، دست یافت. به گفته کریژفسکی و همکاران [8]، شبکه‌های عصبی کانولوشنی قادرند ویژگی‌های قوی را به صورت لایه به لایه محاسبه کنند و این کار را با اعمال انواع فیلترها بر روی ویژگی‌های پاسخگوی محلی انجام می‌دهند. به گفته آن‌ها CNNها قادر به محاسبه ویژگی‌های قدرتمند لایه به لایه، با اعمال انواع فیلترها بر روی ویژگی‌های پاسخگوی محلی هستند. نگوین و همکاران [9] نیز نشان دادند که CNN در شناسایی شدت آسیب از طریق تصاویری که در رسانه‌های اجتماعی پس از یک رویداد فاجعه‌آمیز منتشر شده‌اند، عملکرد بهتری نسبت به روش (Bag-of-Visual-Words; BoVW) دارد. همچنین نتیجه گرفتند که CNN در شناسایی میزان آسیب از طریق تصاویر یافت شده در رسانه‌های اجتماعی پس از یک رویداد فاجعه‌آمیز، عملکرد بهتری نسبت به BoVW داشت. احمد و همکاران [10] از شبکه‌های عصبی کانولوشنی و شبکه‌های متخاصم مولد (Generative Adversarial Network; GAN) مبتنی بر داده‌های ماهواره‌ای و رسانه‌های اجتماعی برای شناسایی فاجعه استفاده کردند. آمیت و همکاران [11] نیز به بررسی تشخیص فاجعه از تصاویر هوایی ماهواره‌ای با استفاده از CNN پرداختند. نگوین و همکاران [12] با استفاده از CNN به این نتیجه رسیدند که می‌توان رویداد زلزله را با استخراج داده‌های توییتری از طریق Steaming API و با کلمات کلیدی "زلزله"، "سونامی" و "زلزله" پیش‌بینی کرد. باو و همکاران [13] در مطالعه خود از CNN برای طبقه‌بندی مقیاس فعالیت‌های لرزه‌ای بهره بردند. جی و همکاران [14] با استفاده از شبکه‌های عصبی کانولوشنی تلاش کردند تا مکان‌های تخریب شده پس از زلزله هائیتی در سال 2010 را با تصاویر با وضوح بسیار بالا از ماهواره شناسایی کنند. همچنین، پرول و همکاران [15] مدلی به نام "ConvNetQuake" را با استفاده از CNN پیشنهاد کردند که از شکل موج‌ها برای پیش‌بینی زلزله در اوکلاهما، ایالات متحده بهره می‌برد. کانگ و همکاران [16] با استفاده از شبکه‌های عصبی کانولوشن زمانی عمیق به معضل وابستگی طولانی مدت تاریخی به پیش‌بینی سری‌های زمانی لرزه‌ای پرداختند، آن‌ها به بررسی نقاط دقیق متصل به سنسورهای واقع‌گرایانه در سیستم مکانیکی میکرو الکترومکانیکی پرداختند و به طور مؤثر این موضوع را مورد توجه قرار دادند. همچنین، یک سیستم جدید برای مشاهده لرزش زمین توسعه دادند که از داده‌های حس شده (Multi Trace CNN; MTCNN) با استفاده از CNN عمیق بهره می‌برد. لومکس و همکاران [17] مدلی مبتنی بر ConvNetQuake_INGV با استفاده از شبکه عصبی کانولوشن عمیق برای تشخیص محلی زلزله و طبقه‌بندی کانونی با استفاده از شکل موج‌های تک ایستگاهی کوتاه ایجاد کردند که قابلیت توصیف زمین لرزه‌ها در هر فاصله و بزرگی‌ای را داشت. موسوی و همکاران [18] شبکه‌ای ساختند که از لایه‌های کانولوشنی و تکراری برای ارزیابی بزرگی زلزله ساخته شده بود. برای تشخیص فعالیت موازی لرزه‌ای و انتخاب بخش، موسوی و همکاران [19] یک مدل یادگیری عمیق جهانی ارائه کردند. این مطالعه نشان داد که این مدل از مدل‌های گذشته بهتر عمل می‌کند. ژو و همکاران [20] از یک الگوریتم ترکیبی، با ترکیب CNN و (Recurrent Neural Network; RNN) از شکل موج‌های ثابت ذخیره شده از طریق سیگنال‌های لرزه نگاری برای شناسایی زلزله استفاده کردند. با استفاده از داده‌های زلزله تاریخی، ژو و همکاران [21] ویژگی‌های اضافی تنظیم شده در کاتالوگ فعالیت لرزه‌ای را از طریق یک مدل قوی بررسی کردند؛ آن‌ها مطالعه کردند که با استفاده از مدل‌های آماری یادگیری ماشین، مانند ماشین بردار پشتیبان (Supportive Vector Machine; SVM)، می‌توان هشدار اولیه زلزله را پیش‌بینی کرد. ادرش و همکاران [22] CNN را برای پیش‌بینی مقیاس لرزش‌های کوچک پنهان شده در نویز پس‌زمینه استفاده کردند. جنا و همکاران [23] از CNN برای ارزیابی احتمالات فعالیت‌های لرزه‌ای در هند استفاده کردند. همچنین، برای پیش‌بینی شدت حرکات زمین، جوزینویک و همکاران [24] از یک مدل CNN برای پیش‌بینی شدت حرکات زمین بهره بردند. لی و همکاران [25] یک مدل یادگیری عمیق برای پیش‌بینی فعالیت‌های لرزه‌ای پیشنهاد کردند. آن‌ها برای پیش‌بینی دقیق زلزله از ادغام ویژگی‌های ضمنی و صریح استفاده کردند. از آنجایی که ویژگی صریح DLEP از هشت شاخص مبتنی بر الگوی پیش‌فرض استفاده می‌کند، برای

استخراج ویژگی‌های ضمنی، از CNN استفاده شده است. تیان و همکاران [26] معماری (Multi Trace CNN; MTCNN) را طراحی کردند که منجر به خطاهای پیش‌بینی کمتر و دقت بالا برای فعالیت‌های لرزه‌ای کوچک شد. نیکولیس و همکاران [27] از حافظه کوتاه مدت بلند مدت (LSTM) و CNN برای پیش‌بینی فعالیت‌های لرزه‌ای در شیلی استفاده کردند. پو و همکاران [28] یک مدل اصلاح شده با استفاده از CNN و RNN ساختند و این مدل را بر روی سیگنال‌های انتشار صوتی (AE) آموزش دادند.

4- چالش‌های موجود در استفاده از شبکه‌های عصبی کانولوشنی در پیش‌بینی زلزله

استفاده از CNN‌ها در پیش‌بینی زلزله با چالش‌های متعددی مواجه است. یکی از این چالش‌ها، محدودیت داده‌های تاریخی است که معمولاً ناپایدار و کم هستند، و این موضوع می‌تواند به آموزش مدل‌های دقیق آسیب برساند. همچنین، پیچیدگی داده‌های جغرافیایی و زمانی که ممکن است الگوهای غیرخطی و غیرقابل پیش‌بینی داشته باشند، کار پیش‌بینی را دشوار می‌کند. بیش‌برازش نیز یکی دیگر از مشکلات است؛ به دلیل کمبود داده، مدل‌ها ممکن است به راحتی به داده‌های آموزشی اُورفیت کنند و در نتیجه عملکرد ضعیفی در داده‌های جدید داشته باشند. علاوه بر این، استخراج ویژگی‌های مهم از داده‌ها نیاز به دانش تخصصی دارد و تفسیر نتایج مدل‌های CNN نیز می‌تواند چالش‌برانگیز باشد، به‌ویژه در شرایطی که نیاز به تصمیم‌گیری‌های فوری و دقیق وجود دارد. این چالش‌ها نشان‌دهنده نیاز به تحقیق و توسعه بیشتر در این زمینه برای بهبود دقت و قابلیت اطمینان پیش‌بینی‌ها هستند. با وجود چالش‌ها، این روش دارای پتانسیل بالایی برای بهبود دقت و قابلیت اطمینان پیش‌بینی زلزله است. با توسعه بیشتر این فناوری و ترکیب آن با سایر روش‌های پیش‌بینی، می‌توان به پیشرفت‌های قابل توجهی در این زمینه دست یافت. هر چند آنها به‌خوبی برای تحلیل داده‌های تصویری و فضایی عمل می‌کنند و می‌توانند الگوهای پیچیده را شناسایی کنند، اما در برابر داده‌های غیرساختاریافته آسیب‌پذیرند [29]. در مقابل، شبکه‌های عصبی بازگشتی (RNN) برای پردازش داده‌های توالی‌دار مناسب‌تر هستند و قادرند الگوهای زمانی را بهتر شناسایی کنند، اگرچه با مشکلاتی مانند ناپایداری یادگیری مواجه‌اند. شبکه‌های عصبی عمیق (Deep Neural Network; DNN) قدرت تعمیم بالایی دارند، اما نیاز به داده‌های آموزشی زیادی دارند. همچنین، روش‌های یادگیری ماشین سنتی مانند درخت تصمیم (Decision Tree) و ماشین بردار پشتیبان (SVM) معمولاً دقت کمتری نسبت به شبکه‌های عصبی کانولوشنی دارند. در نهایت، انتخاب بهترین روش به نوع داده‌ها و نیاز به دقت بستگی دارد و ترکیب این روش‌ها می‌تواند نتایج بهتری ارائه دهد [30]. در جدول 2 چالش‌های موجود و راهکارهای مرتبط، در جهت بهبود عملکرد پیش‌بینی زلزله بطور خلاصه نشان داده شده است.

5- روش‌های بهبود عملکرد شبکه‌های عصبی کانولوشنی

بطور خلاصه، برای بهبود عملکرد CNN‌ها در حوزه پیش‌بینی زلزله (شکل 1) می‌توان مراحل زیر را طرح کرد [31]:

افزایش حجم و تنوع داده‌ها:

برای افزایش حجم و تنوع داده‌ها در پیش‌بینی زلزله، می‌توان به جمع‌آوری داده‌های لرزه‌نگاری از ایستگاه‌های مختلف در مناطق گوناگون پرداخت تا یک پایگاه داده غنی از اطلاعات درباره انواع زلزله‌ها ایجاد شود. همچنین، استفاده از تصاویر ماهواره‌ای به شناسایی تغییرات سطح زمین و فعالیت‌های تکتونیکی کمک می‌کند و این تصاویر می‌توانند به عنوان ورودی برای شبکه‌های عصبی مورد استفاده قرار گیرند. افزون بر این، داده‌های زمین‌شناسی نظیر نوع سنگ‌ها، گسل‌ها و تاریخچه لرزه‌خیزی نیز به مدل کمک می‌کنند تا مناطق با خطر بالای زلزله بهتر شناسایی شوند.

تنظیم دقیق پارامترهای شبکه:

تعداد فیلترها در لایه‌های کانولوشنی تعیین می‌کند که شبکه عصبی چه تعداد ویژگی را از داده‌های ورودی استخراج کند؛ تعداد فیلتر بیشتر به معنای استخراج ویژگی‌های پیچیده‌تر است، اما ممکن است منجر به افزایش پارامترهای شبکه و بیش‌برازسازی شود. همچنین، اندازه هسته فیلترها مشخص می‌کند که شبکه در هر مرحله چه ناحیه‌ای از تصویر ورودی را بررسی کند؛ هسته‌های بزرگ‌تر قادر به تشخیص ویژگی‌های بزرگ‌مقیاس هستند، در حالی که هسته‌های کوچک‌تر به ویژگی‌های محلی حساس‌ترند. در نهایت، تعداد لایه‌های کانولوشنی در شبکه عصبی تعیین‌کننده عمق یادگیری ویژگی‌های انتزاعی است؛ شبکه‌های عمیق‌تر معمولاً قابلیت یادگیری ویژگی‌های پیچیده‌تر را دارند، اما به حجم داده بیشتری نیاز دارند.

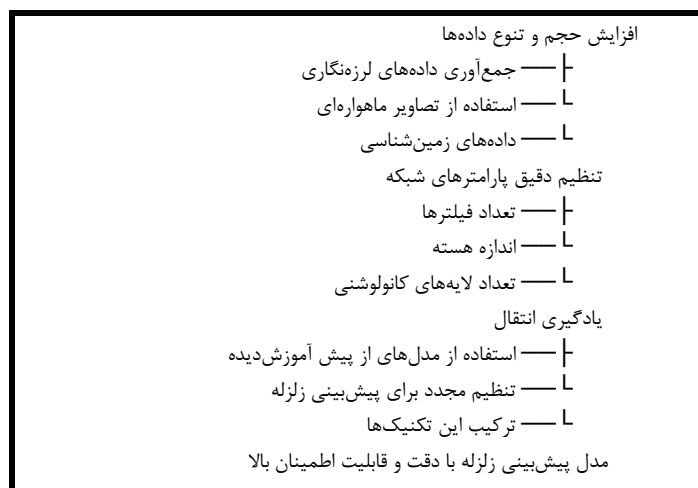
یادگیری انتقال:

استفاده از مدل‌های از پیش آموزش‌دیده بر روی مجموعه داده‌های بزرگ تصاویر ماهواره‌ای، به استخراج ویژگی‌های کلی زمین‌شناسی مانند ساختار زمین، پوشش گیاهی و تغییرات سطح زمین کمک می‌کند. با تنظیم مجدد لایه‌های نهایی این مدل‌ها، می‌توان آن‌ها را برای شناسایی الگوهای مرتبط

با زلزله در داده‌های لرزه‌نگاری و سایر داده‌ها آموزش داد. این فرآیند به مدل اجازه می‌دهد تا از دانش قبلی خود بهره‌برداری کند و عملکرد خود را در پیش‌بینی زلزله بهبود بخشد. در نهایت، با ترکیب این تکنیک‌ها، می‌توان به یک مدل پیش‌بینی زلزله با دقت و قابلیت اطمینان بالا دست یافت. فلوچارت مراحل بهبود عملکرد CNN‌ها در پیش‌بینی زلزله در شکل 1 نشان داده شده است.

جدول 2: چالش‌های پیش‌بینی زلزله با استفاده از CNN و راهکارهای پیشنهاد شده [31]

چالش	توضیحات	راهکارهای پیشنهادی
محدودیت داده‌های تاریخی	داده‌های تاریخی معمولاً ناپایدار و کم هستند	جمع‌آوری داده‌های بیشتر و استفاده از روش‌های تقویت داده
بیش برآزش (اورفیتینگ)	مدل‌ها به جزئیات و نویزهای موجود در داده‌های آموزشی توجه می‌کنند	استفاده از روش‌های منظم‌سازی و اعتبارسنجی متقابل
پیچیدگی داده‌های جغرافیایی	الگوهای غیرخطی و غیرقابل پیش‌بینی	استفاده از مدل‌های ترکیبی (CNN , RNN)
تفسیر نتایج	تفسیر نتایج مدل‌های CNN می‌تواند دشوار باشد	توسعه ابزارهای تفسیر و بصری‌سازی



شکل 1: فلوچارت مراحل بهبود عملکرد CNN‌ها در پیش‌بینی زلزله

6- نتیجه‌گیری و جمع‌بندی

شبکه‌های عصبی کانولوشنی به عنوان ابزاری قدرتمند در پیش‌بینی زلزله ظهور کرده‌اند. این مدل‌ها با توانایی استخراج ویژگی‌های پیچیده از داده‌های لرزه‌ای، دقت پیش‌بینی را به طور قابل توجهی بهبود بخشیده‌اند. CNN‌ها با شناسایی الگوهای پنهان در داده‌ها، امکان پیش‌بینی زود هنگام زلزله و کاهش خسارات ناشی از آن را فراهم می‌کنند. با این حال، این فناوری هنوز در مراحل اولیه توسعه است و چالش‌هایی مانند نیاز به داده‌های با کیفیت و حجم بالا، پیچیدگی محاسباتی و تفسیر نتایج، نیازمند تحقیقات بیشتر است. با وجود این محدودیت‌ها، آینده استفاده از CNN در لرزه‌شناسی بسیار امیدوارکننده است. ترکیب CNN با سایر روش‌های یادگیری ماشین و استفاده از داده‌های چندجانبه، می‌تواند به توسعه سیستم‌های پیش‌بینی زلزله با دقت و قابلیت اطمینان بالاتر منجر شود. در کل، CNN‌ها پتانسیل بالایی برای کاهش خطر ناشی از زلزله و بهبود ایمنی جوامع دارند.

مراجع

- [1] Jiao P. & Alavi A.H., Artificial intelligence in seismology: advent, performance and future trends, Geoscience Frontiers, 11(3), 739-744, 2020.
- [2] Gurjeet S. Earthquake Prediction using Convolutional Neural Network, Disaster Advances, 16(6):45-52, 2023.
- [3] Krizhevsky A., Sutskever I. and Hinton G.E., Imagenet classification with deep convolutional neural networks, Advances in Neural

Information Processing Systems, 25, 1106-1114, 2012.

- [4] Kriegerowski M., Petersen G.M., Vasyura-Bathke H. and Ohrnberger M., A deep convolutional neural network for localization of clustered earthquakes based on multistation full waveforms, *Seismological Research Letters*, 90(2A), 510-516, 2019.
- [5] Mousavi S.M., Zhu W., Sheng Y. and Beroza G.C., CRED: A deep residual network of convolutional and recurrent units for earthquake signal detection, *Scientific Reports*, 9(1), 1-14, 2019.
- [6] Hassen L., Slim B., Ali L., Chih CH, Lamjed BS . Deep convolutional neural network architecture design as a bi-level optimization problem. *J Neuro Comput* 439:44-62, 2021.
- [7] Huang J.P., Wang X.A., Zhao Y., Xin C. and Xiang H. Large earthquake magnitude prediction in Taiwan based on deep learning neural network, *Neural Network World*, 28(2), 149-160, 2018.
- [8] Krizhevsky A., Sutskever I. and Hinton G.E. Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 25, 1106-1114, 2012.
- [9] Nguyen D.T., Ofli F., Imran M. and Mitra P. Damage Assessment from Social Media Imagery Data During Disasters, 569-576, 2017.
- [10] Ahmad K., Konstantin P., Riegler M., Conci N. and Holversen P. CNN and GAN based satellite and social media data fusion for disaster detection, *CEUR Workshop Proc.*, 1984, 15-18, 2017.
- [11] Amit S.N.K.B. and Aoki Y. Disaster detection from aerial imagery with convolutional neural network, *Proc. - Int. Electron. Symp. Knowl. Creat. Intell. Comput. IES-KCIC 2017*, 239-245, 2017.
- [12] Nguyen V.Q., Yang H.J., Kim K. and Oh A.R. Real-Time Earthquake Detection Using Convolutional Neural Network and Social Data, 154-157, 2017.
- [13] Bao Z., Zhao J., Huang P., Yong S. and Wang X.A. A deep learning-based electromagnetic signal for earthquake magnitude prediction, *Sensors*, 21(13), 4434, 2021.
- [14] Ji M., Liu L. and Buchroithner M. Identifying collapsed buildings using post-earthquake satellite imagery and convolutional neural networks: A case study of the 2010 Haiti earthquake, *Remote Sensing*, 10(11), 1689, 2018.
- [15] Perol T., Gharbi M., Denolle M. Convolutional neural network for earthquake detection and location. *Sci Adv*. Feb 14;4(2), 2018.
- [16] Kang J.M., Kim I.M., Lee S., Ryu D.W. and Kwon J. A deep CNN-based ground vibration monitoring scheme for MEMS sensed data, *IEEE Geoscience and Remote Sensing Letters*, 17(2), 347-351, 2019.
- [17] Lomax A., Michelini A. and Jozinović D. An investigation of rapid earthquake characterization using single-station waveforms and a convolutional neural network, *Seismological Research Letters*, 90(2A), 517-529, 2019.
- [18] Mousavi S.M. et al. Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking, *Nature Communications*, 11(1), 1-12, 2020.
- [19] Mousavi S.M., Zhu W., Sheng Y. and Beroza G.C., CRED: A deep residual network of convolutional and recurrent units for earthquake signal detection, *Scientific Reports*, 9(1), 1-14, 2019.
- [20] Zhou Y., Yue H., Kong Q. and Zhou S. Hybrid event detection and phase-picking algorithm using convolutional and recurrent neural networks, *Seismological Research Letters*, 90(3), 1079- 1087, 2019.
- [21] Zhou W., Dong H. and Liang Y. The deterministic dendritic cell algorithm with Haskell in earthquake magnitude prediction, *Earth Science Informatics*, 13(2), 447-457, 2020.
- [22] Audretsch J. Earthquake Detection using Deep Learning Based Approaches (Doctoral dissertation), 2020.
- [23] Jena R., Pradhan B., Al-Amri A., Lee C.W. and Park H.J. Earthquake probability assessment for the Indian subcontinent using deep learning, *Sensors*, 20(16), 4369, 2020.
- [24] Jozinović D., Lomax A., Štajduhar I. and Michelini A. Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network, *Geophysical Journal International*, 222(2), 1379-1389, 2020.
- [25] Li R., Lu X., Li S., Yang H., Qiu J. and Zhang L. DLEP: A deep learning model for earthquake prediction, In 2020 International Joint Conference on Neural Networks, 1-8, IEEE, 2020.
- [26] Tian X., Zhang W., Zhang X., Zhang J., Zhang Q. Wang X. and Guo Q. Comparison of single-trace and multiple-trace polarity determination for surface microseismic data using deep learning, *Seismological Research Letters*, 91(3), 1794-1803, 2020.
- [27] Nicolis O., Plaza F. and Salas R. Prediction of intensity and location of seismic events using deep learning, *Spatial Statistics*, 42, 100442, 2021.
- [28] Pu Y., Chen J. and Apel D.B. Deep and confident prediction for a laboratory earthquake, *Neural Computing and Applications*, 33(18), 11691-11701, 2021.
- [29] Mignan A. and Broccardo M. Neural network applications in earthquake prediction (1994-2019): Meta-analytic and statistical insights on their limitations, *Seismological Research Letters*, 91(4), 2330-2342, 2020.
- [30] Xie Y., Ebad Sichani M., Padgett JE, DesRoches R. The promise of implementing machine learning in earthquake engineering: A state-of-the-art review. *Earthquake Spectra* , 36(4): 1769-1801, 2020.
- [31] Banna M. H. A. et al. Application of Artificial Intelligence in Predicting Earthquakes: State-of-the-Art and Future Challenges. in *IEEE Access*, vol. 8, 192880-192923, 2020.