

Detection of pulse-type earthquakes using machine learning algorithms: A novel approach to improve detection and accuracy

Hossein Zanganaeh¹, Hamid Saffari²

¹ M.Sc., Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

² Associate Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

ABSTRACT

Pulse liked accelerograms, characterized by large amplitude and short duration pulses, significantly affect the dynamic response of structures. Accurate simulation of these types of earthquakes and analysis of their effects on structures and infrastructure are key requirements in earthquake engineering. In assessing the seismic hazards of a region, pulsed liked accelerograms are considered an important indicator because they can significantly increase the seismic hazard level. Modern methods such as wavelet transform can be used to accurately identify velocity pulses and extract key features from the earthquake time history. Also, recent advances in the field of machine learning have enabled more accurate classification of earthquake accelerograms. Machine learning algorithms, with their continuous learning and automatic updating capabilities, are effective tools for accurate detection and classification of seismic events. In this study, in order to identify pulse-type earthquakes, 60 seismic records from Iran with high acceleration and velocity were selected and analyzed. Using an approach that combines wavelet analysis to extract key signal features with the random forest machine learning algorithm, 11 events were classified as pulse-type earthquakes. This combined wavelet transform and machine learning method showed a high ability to recognize the distinctive features of pulse-type earthquakes. Performance evaluation of the algorithms used showed that the random forest, classification boosting, and extreme gradient boosting methods have very favorable performance in classifying pulse-type accelerograms with an accuracy of 0.94. These results indicate the high potential of machine learning in analyzing and classifying seismic data, which can play an effective role in risk management and structural retrofitting design.

ARTICLE INFO

Receive Date: 28 February 2025

Revise Date: 11 June 2025

Accept Date: 09 July 2025

Keywords:

Pulse liked accelerograms;
Wavelet transform; Machine
learning;
Random forest algorithm,
Classification boosting
algorithm,
Extreme gradient boosting
algorithm

All rights reserved to Iranian Society of Structural Engineering.

doi: 10.22065/jsce.2025.500882.3632

*Corresponding author: Hamid Saffari
Email address: h_saffari@sbu.ac.ir

تشخیص زلزله‌های پالس‌گونه با بهره‌گیری از الگوریتم‌های یادگیری ماشین:

رویکردی نوین برای بهبود دقت شناسایی و ارزیابی

حسین زنگنه^۱، حمید صفاری^{۲*}

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهیدبهشتی، تهران، ایران.

۲- دانشیار، دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران.

چکیده

شتاب‌نگاشت‌های پالس‌گونه، با ویژگی پالس‌هایی با دامنه بزرگ و مدت‌زمان کوتاه، به‌طور چشمگیری بر پاسخ دینامیکی سازه‌ها تأثیر می‌گذارند. شبیه‌سازی دقیق این نوع زلزله‌ها و تحلیل اثرات آن‌ها بر سازه‌ها و زیرساخت‌ها، از جمله الزامات کلیدی در مهندسی زلزله به شمار می‌رود. در ارزیابی خطرات لرزه‌ای یک منطقه، شتاب‌نگاشت‌های پالس‌گونه به‌عنوان یک شاخص مهم مدنظر قرار می‌گیرند، زیرا می‌توانند به‌طور قابل‌توجهی سطح خطر لرزه‌ای را افزایش دهند. از روش‌های نوین مانند تبدیل موجک می‌توان برای شناسایی دقیق پالس‌های سرعت و استخراج ویژگی‌های کلیدی از تاریخچه زمانی زلزله بهره برد. همچنین، با پیشرفت‌های اخیر در حوزه یادگیری ماشین، امکان طبقه‌بندی دقیق‌تر شتاب‌نگاشت‌های زلزله فراهم شده است. الگوریتم‌های یادگیری ماشین، با قابلیت یادگیری مستمر و به‌روزرسانی خودکار، ابزارهای مؤثری برای تشخیص و طبقه‌بندی دقیق رویدادهای لرزه‌ای محسوب می‌شوند. در این پژوهش، به‌منظور شناسایی زلزله‌های پالس‌گونه، ۶۰ رکورد لرزه‌ای از ایران که دارای شتاب و سرعت بالا بودند، انتخاب و تحلیل شدند. با استفاده از رویکردی که تحلیل موجک را برای استخراج ویژگی‌های کلیدی سیگنال با الگوریتم یادگیری ماشین جنگل تصادفی ترکیب می‌کند، ۱۱ رویداد به‌عنوان زلزله‌های پالس‌گونه طبقه‌بندی شدند. این روش تلفیقی تبدیل موجک و یادگیری ماشین توانایی بالایی در تشخیص ویژگی‌های متمایز زلزله‌های پالس‌گونه از خود نشان داد. ارزیابی عملکرد الگوریتم‌های مورد استفاده حاکی از آن است که روش‌های جنگل تصادفی، تقویت طبقه‌بندی و تقویت گرادیان شدید با دقت بالای ۰/۹۴ عملکرد بسیار مطلوبی در طبقه‌بندی شتاب‌نگاشت‌های پالس‌گونه دارند. این نتایج نشان‌دهنده پتانسیل بالای یادگیری ماشین در تحلیل و طبقه‌بندی داده‌های لرزه‌ای است که می‌تواند نقش مؤثری در مدیریت ریسک و طراحی مقاوم‌سازی سازه‌ها ایفا کند.

کلمات کلیدی: شتاب‌نگاشت پالس‌گونه؛ تبدیل موجک؛ یادگیری ماشین؛ الگوریتم جنگل تصادفی؛ الگوریتم تقویت طبقه‌بندی؛ الگوریتم تقویت گرادیان شدید.

شناسه دیجیتال:		سابقه مقاله:				
doi:	10.22065/jsce.2025.500882.3632	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	10.22065/jsce.2025.500882.3632	۱۴۰۴/۱۲/۲۹	۱۴۰۴/۰۴/۱۸	۱۴۰۴/۰۴/۱۸	۱۴۰۴/۰۳/۲۱	۱۴۰۳/۱۲/۱۰
حمید صفاری h_saffari@sbu.ac.ir					*نویسنده مسئول: پست الکترونیکی:	

۱- مقدمه

حرکات زمین در حوزه نزدیک گسل چالشی قابل توجه برای پژوهشگران به شمار می‌آید زیرا باعث افزایش پارامترهای پاسخ سازه شامل برش پایه، جابه‌جایی طبقات و تقاضای انعطاف‌پذیری را می‌شود [۱]. ویژگی این حرکات شامل حداکثر شتاب زمین (PGV) بالا، پیوندهای بلند، نسبت بالای حداکثر شتاب زمین به حداکثر سرعت زمین (PGV/PGA)، دوام کوتاه و مقادیر بالا در طیف پاسخ برای پیوندهای بزرگ‌تر، به حرکات زمین پالس گونه شناخته می‌شود [۲، ۳]. حرکات زمین پالس گونه توسط دو عامل اصلی اثر جهت‌پذیری گسل و اثر پرتاب زمین در حوزه نزدیک گسل ایجاد می‌شوند و تحت تأثیر مکانیسم منبع، ویژگی محیط و موقعیت ایستگاه‌های شتاب‌نگاری قرار دارند [۴، ۵]. زمانی که شکست گسل با سرعتی نزدیک به سرعت موج‌برشی به سمت یک سایت امتداد پیدا کند اثر داپلر لرزه‌ای منجر به انباشت انرژی آزادشده در طول شکست گسل می‌شود [۶]. به همین علت پالس‌های دوطرفه با مقدار پیک زیاد و انرژی متمرکز در ابتدای تاریخچه زمانی سرعت دیده می‌شود. این پالس‌ها معمولاً با جابه‌جایی غیردائمی بزرگ در نداشت تغییر مکان زلزله همراه هستند. از سوی دیگر، پالس‌های ایجادشده بر اثر پرتاب زمین به صورت یک‌طرفه بوده و در نداشت تغییر مکان، جابه‌جایی فراوان و ماندگاری را نشان می‌دهند [۷، ۸].

ویژگی پالس‌های سرعت از دیدگاه‌های مختلف در مطالعات بررسی شده است [۹، ۱۰]. در یک زلزله واقعی دامنه حرکات عمودی ممکن است به طور قابل توجهی از دامنه افقی قوی‌تر باشد. بررسی‌ها بیانگر آن است که جابه‌جایی یا تاقان‌های الاستومری تحت حرکات زمین پالس گونه افقی که با پالس در مؤلفه‌ی عمودی همراه است به طور معقولی تقویت می‌شود [۱۱-۱۳]. در تحلیل آسیب‌های لرزه‌ای سازه‌ها لازم است اثرات مشترک هر سه مؤلفه زمین در نظر گرفته شود.

با ادامه ثبت حرکات زمین پالس گونه، توجه به درک این پدیده افزایش یافته است. این در حالی است که تمایز روشن بین حرکات پالس گونه و غیر پالس گونه چالش‌برانگیز می‌باشد. به همین علت شناسایی این دسته از حرکات زمین یک گام حیاتی برای تحقیقات بیشتر در این حوزه می‌باشد [۱۴]. به‌طور کلی روش‌های متعددی در این زمینه ارائه شده است. پر مطالعه‌ترین آن‌ها شامل تکنیک‌هایی می‌باشد که هدف دارند اجزای فرکانس پایین را از سیگنال اصلی استخراج کنند. از جمله تکنیک‌هایی که در این زمینه مورد استفاده قرار می‌گیرند، می‌توان به تبدیل موجک^۱، تبدیل بسته‌های موجک^۲، تبدیل S^۳، تبدیل هیلبرت-هنگ^۴، تجزیه مد تجربی^۵ و تجزیه مد تجربی ترکیبی^۶ اشاره کرد. با توجه به اینکه اجزای فرکانس پایین در حرکات زمین نقش اساسی در شکل‌دهی به پالس دارند. این اجزای پالس با بخش باقی‌مانده سیگنال مقایسه شده و در نهایت معیار مشخص برای شناسایی حرکات پالس گونه تعیین می‌شود [۹، ۱۵-۲۲].

در برخی روش‌های دیگر از استخراج پالس سرعت صرف‌نظر کرده و به‌طور مستقیم از ویژگی‌ها و پارامترهای خاص در حرکات زمین برای تعیین معیار تشخیص حرکات زمین پالس گونه استفاده می‌شود. این پارامترها شامل PGV، PGA، طول توسعه تاریخچه زمانی^۷ (DLVTH)، پارامترهای مرتبط با طیف پاسخ و پارامترهای مرتبط به تحلیل زمان-فرکانس می‌باشند. استفاده از این پارامترها و تلفیق آن با مدل‌های یادگیری ماشین توجه پژوهشگران زیادی را به خود جلب کرده است [۱، ۲۳-۲۶].

یادگیری ماشین شاخه‌ای از هوش مصنوعی است که بر ایجاد الگوریتم‌ها و مدل‌هایی متمرکز است که رایانه‌ها را قادر می‌سازد از داده‌ها بیاموزد و بدون برنامه‌ریزی صریح، پیش‌بینی یا تصمیم‌گیری کنند. یادگیری ماشین به دو گروه یادگیری ماشین تحت نظارت^۸ و یادگیری ماشین بدون نظارت^۹ تقسیم می‌شود [۲۷]. داده‌ها در یادگیری تحت نظارت دارای برچسب هستند. در این گروه الگوریتم بر روی یک

1 Wavelet Transform

2 Wavelet Packet Transform

3 S-Transform

4 Hilbert-Huang Transform

5 Empirical Mode Decomposition

6 Ensemble Empirical Mode Decomposition

7 Developed Length of Vibration Time History

8 Supervised Machine Learning

9 Unsupervised Machine Learning

مجموعه داده با ورودی‌های شناخته شده و خروجی‌های مربوطه آموزش داده می‌شود و یاد می‌گیرد که این روابط را تعمیم دهد تا پیش‌بینی‌های مربوط به داده‌های جدید انجام شود. از طرف دیگر، یادگیری بدون نظارت با داده‌های بدون برچسب سروکار دارد [۲۸]. الگوریتم‌های موجود در یادگیری بدون نظارت باهدف کشف الگوهای پنهان، ساختارها یا روابط درون داده‌ها، بدون هیچ‌گونه خروجی از پیش تعریف شده برای هدایت فرایند یادگیری استفاده می‌شوند. استفاده از تکنیک‌های یادگیری ماشین و مدل‌های داده محور به‌عنوان یک رویکرد ارزشمند برای شناسایی حرکات زمین پالس گونه به‌کار گرفته شده است. مدل شبکه عصبی بر اساس هشت ویژگی اصلی شامل مدت زمان دوام، PGV، حداکثر سرعت طیف پاسخ (SV)، مدت زمانی که شدت آریاس^{۱۰} به ۵، ۷۵ و ۹۵ درصد می‌رسد، مدت زمان تغییر شدت آریاس از ۵ درصد به ۷۵ درصد، و مدت زمان تغییر شدت آریاس از ۵ درصد به ۹۵ درصد، که از ۱۶۰۰ مؤلفه واقعی ۵۰۰ حرکت زمین استخراج شده‌اند، با دقت حدود ۹۴ درصد توانسته است عملکرد مناسبی در طبقه‌بندی حرکات زمین پالس گونه ارائه دهد [۲۹]. الگوریتم‌های یادگیری ماشین با استفاده از چهار ویژگی که شامل دو پارامتر مستقیم بزرگای زلزله (MW) و فاصله جونر-بُور^{۱۱} (Rjb) و دو پارامتر غیرمستقیم PGV و شاخص ضربه‌ای (IP) که از ۲۰۰ حرکت زمین غیر همگن استخراج شده است. با دقت ۸۶/۲ درصد از دیگر مدل‌های یادگیری برتری دارد [۱].

در تعیین آستانه طبقه‌بندی ثابت احتمال از دست رفتن حرکات زمین پالس گونه با توجه به شدت زلزله و شرایط ساختگاهی متعدد وجود دارد. مدل‌های یادگیری ماشین با بررسی ویژگی‌های پنهان برای شناسایی و طبقه‌بندی حرکات زمین پالس مانند عملکرد مناسبی از خود نشان داده‌اند. مدل‌های یادگیری ماشین در پژوهش‌های پیشین برای طبقه‌بندی حرکات زمین پالس گونه عمدتاً بر روی ویژگی‌های استخراج شده از تاریخچه زمانی سرعت اصلی تمرکز کرده‌اند. همچنین با بررسی‌های انجام شده، مشخص گردیده است که استفاده از پارامترهای ورودی مانند بزرگای زلزله (Mw)، فاصله جونر-بُور (Rjb) و سرعت موج برشی خاک (Vs30) تأثیر قابل توجهی بر مدل‌های یادگیری برای طبقه‌بندی حرکات زمین پالس گونه ندارد. این امر به این دلیل است که برای هر دودسته حرکات زمین پالس گونه و غیرپالس گونه که در نواحی نزدیک گسل قرار دارند، این پارامترها ممکن است یکسان باشند. در این پژوهش برای بهبود طبقه‌بندی با استفاده از الگوریتم یادگیری ماشین از ویژگی‌های تاریخچه زمانی سرعت اصلی و پالس استخراج شده با استفاده از تبدیل موجک پرداخته شد.

برای این کار ابتدا، مجموعه‌ای از ۳۶۹ شتاب‌نگاشت دومؤلفه‌ای شامل ۱۷۵ شتاب‌نگاشت پالس گونه و ۱۹۴ شتاب‌نگاشت غیرپالس گونه در مناطق نزدیک به گسل از وبسایت مرکز تحقیقات مهندسی زلزله اقیانوس آرام^{۱۲} جمع‌آوری شد. سپس با استفاده از تبدیل موجک پالس سرعت اصلی استخراج شده و ویژگی‌های کلیدی این داده‌ها محاسبه گردید. این ویژگی‌ها شامل پارامترهای مختلفی نظیر حداکثر شتاب، حداکثر سرعت و ویژگی‌های آماری مانند واریانس^{۱۳} و کشیدگی^{۱۴} بودند. پس از بررسی همبستگی بین پارامترها، داده‌ها به دو دسته آموزشی و آزمایشی تقسیم شدند. سپس پنج الگوریتم یادگیری ماشین از جمله جنگل تصادفی^{۱۵}، تقویت گرادیان شدید^{۱۶}، تقویت طبقه‌بندی^{۱۷}، ماشین بردار پشتیبان^{۱۸} (SVM) و نزدیک‌ترین همسایه^{۱۹} (KNN) برای ایجاد مدل‌های طبقه‌بندی حرکات زمین پالس گونه استفاده شدند. شکل ۱ به‌طور کامل نمای کلی فرآیندهای انجام شده در این پژوهش از جمع‌آوری و استخراج ویژگی‌ها تا اعمال الگوریتم‌های یادگیری ماشین و ارزیابی نتایج را نمایش می‌دهد. این شکل به تفصیل مراحل مختلف کار را به صورت تصویری نشان می‌دهد و به درک بهتر روند تحلیل و مدل‌سازی کمک می‌کند.

10 Arias Intensity

11 Joyner-Boore Distance

12 Pacific Earthquake Engineering Research Center

13 Variance

14 Skewness

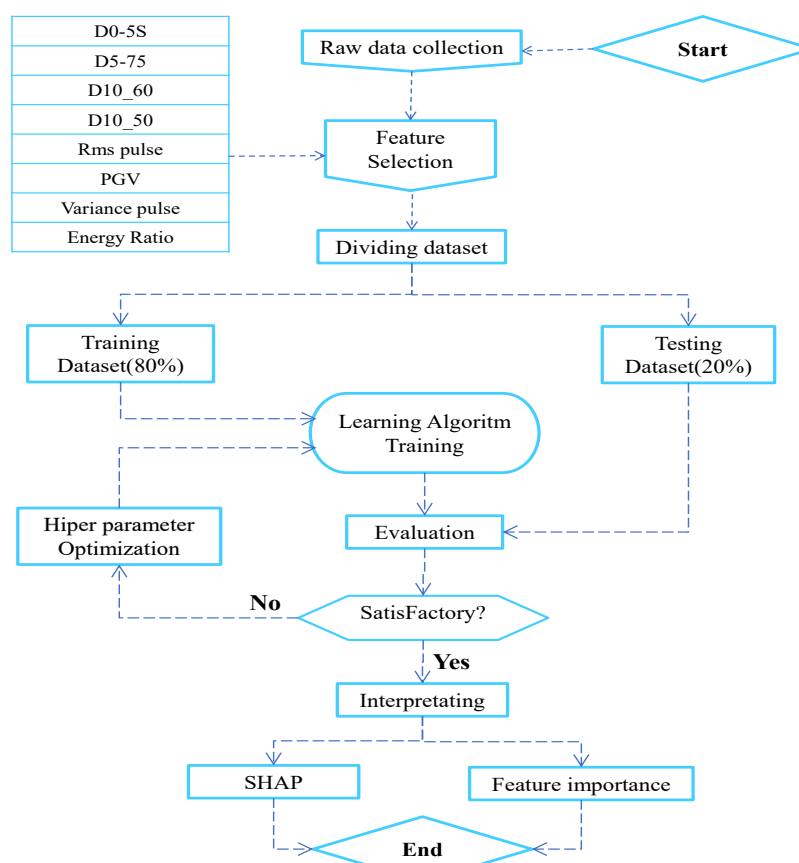
15 Random forest

16 XGBoost

17 CatBoost

18 Support Vector Machine

19 K-Nearest Neighbors

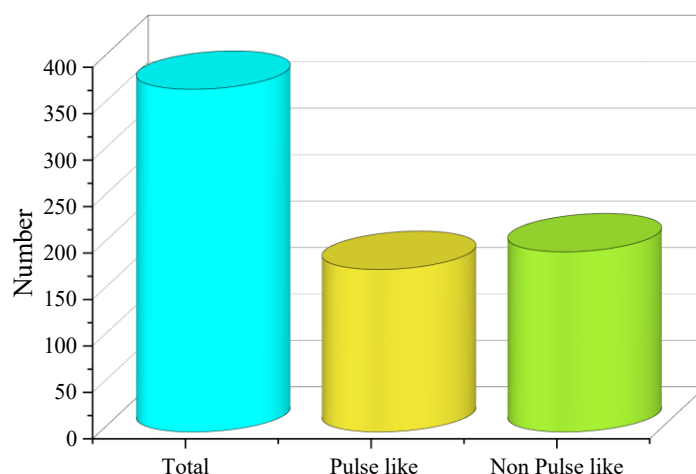


شکل ۱: نمای کلی روند استفاده از یادگیری ماشین در طبقه‌بندی شتاب‌نگاشت‌های پالس‌گونه

۲- روش‌ها

۲-۱- جمع‌آوری پایگاه داده

برای این پژوهش، از یک روش طبقه‌بندی دقیق برای تفکیک شتاب‌نگاشت‌های پالس‌گونه (۱۷۵ مورد) و غیرپالس‌گونه (۱۹۴ مورد) استفاده شد. این طبقه‌بندی بر اساس ویژگی‌های مشخصه هر نوع شتاب‌نگاشت و باهدف بررسی دقیق‌تر رفتار لرزه‌ای انجام شده است. برای شناسایی و جداسازی شتاب‌نگاشت‌های پالس‌گونه، از مطالعات پیشین و معیارهای پذیرفته‌شده در حوزه تشخیص پالس‌های زمین‌لرزه‌ای استفاده شده است [۱۵، ۲۰، ۲۴، ۳۰-۳۲]. به‌منظور افزایش دقت در شناسایی شتاب‌نگاشت‌های غیرپالس‌گونه، عمدتاً از شتاب‌نگاشت‌های حاصل از زلزله‌های نزدیک گسل با بزرگای بیش از ۶.۵ استفاده شده است. انتخاب این نوع شتاب‌نگاشت‌ها به دلیل احتمال بالای وقوع پالس‌های سرعت در زلزله‌های نزدیک گسل و با بزرگی بالا بوده است. با این کار، می‌توان اطمینان حاصل کرد که مجموعه داده‌های غیرپالس‌گونه نیز دارای تنوع کافی و نماینده خوبی از شتاب‌نگاشت‌های غیرپالس‌گونه در شرایط مختلف زمین‌شناسی و لرزه‌ای باشند.



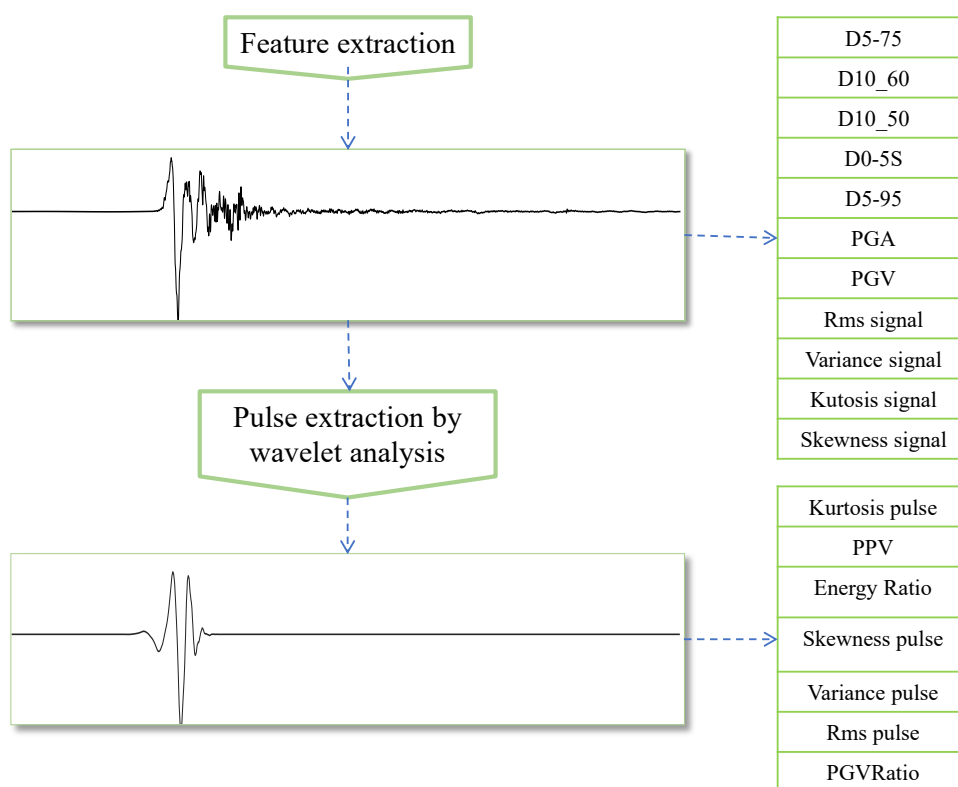
شکل ۲: نسبت توزیع داده‌های پالس گونه و غیر پالس گونه در پایگاه داده‌ها

۲-۲- استخراج ویژگی از نگاشت زلزله‌ها

تحلیل موجک اخیراً به‌عنوان یکی از روش‌های برجسته و کارآمد در مهندسی زلزله و لرزه‌شناسی مورد توجه گسترده قرار گرفته است. روش مبتنی بر موجک برای شناسایی و توصیف ویژگی‌های کلیدی حرکات زمین پالس مانند که عمدتاً در مناطق نزدیک به گسل رخ می‌دهند، به‌کار گرفته شده است [۳۳]. با توجه به ثبت تعداد زیادی از این جنبش‌های نیرومند در سال‌های اخیر، این روش امکان استخراج اطلاعات نوین و ارزشمندی از ویژگی‌های حرکات زمین در نواحی نزدیک به گسل را فراهم می‌کند. برای دستیابی به ویژگی‌ها، در این مطالعه از دو مؤلفه افقی تاریخچه زمانی سرعت برای یافتن بزرگ‌ترین پالس در جهت‌های مختلف بهره گرفته شده و تحلیل موجک با استفاده از نرم‌افزار متلب بر روی این داده‌ها اعمال شد. این تحلیل به‌منظور شناسایی و استخراج ویژگی‌های بزرگ‌ترین پالس‌های سرعت در تاریخچه زمانی سرعت صورت گرفت. پس از استخراج پالس، مطابق شکل ۳، اقدام به محاسبه طیف گسترده‌ای از ویژگی‌های زمانی و آماری شد. ویژگی‌ها شامل مدت‌زمان دوام زلزله در بازه‌های زمانی مختلف، PGA و PGV است. این ویژگی‌ها اطلاعات ارزشمندی در خصوص شدت و مدت‌زمان اعمال نیرو بر سازه‌ها ارائه می‌دهند. از سوی دیگر، برای بررسی دقیق‌تر مشخصات پالس‌ها، ویژگی‌های آماری همچون واریانس، میانگین مربعات ریشه²⁰ (RMS)، کشیدگی و چولگی²¹ نیز محاسبه گردید. واریانس نشان‌دهنده پراکندگی داده‌ها حول میانگین است و به‌عنوان معیاری برای ارزیابی شدت لرزش مورد استفاده قرار می‌گیرد. میانگین مربعات ریشه نیز یک شاخص جامع از بزرگی پالس محسوب می‌شود. کشیدگی و چولگی به ترتیب تیزی یا پهن بودن توزیع داده‌ها و میزان عدم تقارن آن را نشان می‌دهند. این ویژگی‌ها اطلاعات مفیدی در مورد شکل و ماهیت پالس‌ها ارائه می‌دهند. با محاسبه این مجموعه از ویژگی‌ها، درک عمیق‌تری از خصوصیات پالس‌های تاریخچه زمانی و تأثیر آن‌ها بر سازه‌ها حاصل می‌شود.

²⁰ Root Mean Squared

²¹ Kurtosis



شکل ۳: فرآیند استخراج ویژگی‌ها از تاریخچه زمانی سرعت

همان‌طور که در شکل ۳ دیده می‌شود، در ابتدا ویژگی‌های کلی سیگنال مانند PGA، PGV، RMS، واریانس، چولگی و کشیدگی محاسبه شد و سپس، با استفاده از تحلیل موجک، پالس‌های موجود در تاریخچه زمانی سرعت استخراج شده و ویژگی‌های آن‌ها مانند دامنه پیک پالس (PPV)، نسبت انرژی، چولگی پالس، واریانس پالس، RMS پالس و نسبت PGV پالس به PGV تاریخچه زمانی سرعت اصلی محاسبه شده است.

جدول ۱: ویژگی‌های استخراج شده از تاریخچه زمانی سرعت و شتاب زلزله‌ها

نام پارامتر	شرح پارامتر
PGA	حداکثر شتاب زمین
PGV	حداکثر سرعت زمین
PPV	حداکثر سرعت بزرگ‌ترین پالس
PGV Ratio	نسبت حداکثر سرعت پالس به حداکثر سرعت زمین
Energy Ratio	نسبت انرژی پالس سرعت به انرژی سرعت زمین
Variance Pulse	واریانس تاریخچه زمانی پالس
RMS Pulse	میانگین مربعات ریشه تاریخچه زمانی پالس
RMS Signal	میانگین مربعات ریشه تاریخچه زمانی سرعت

کشیدگی تاریخچه زمانی پالس	Kortusis Pulse
کشیدگی تاریخچه زمانی سرعت زمین	Kortusis Signal
چولیدگی تاریخچه زمانی پالس	Skewness Pulse
چولیدگی تاریخچه زمانی سرعت زمین	Skewness Signal
شدت آریاس	AriasIntensity
مدت زمان بین ۵ تا ۷۵ درصد از شدت آریاس	D5-75
مدت زمان بین ۱۰ تا ۶۰ درصد از شدت آریاس	D10_60
مدت زمان بین ۱۰ تا ۵۰ درصد از شدت آریاس	D10_50
مدت زمان بین ۰ تا ۵ درصد از شدت آریاس	D0_5S
مدت زمان بین ۵ تا ۹۵ درصد از شدت آریاس	D5-95

۲-۳- بررسی ویژگی‌های پایگاه داده


ضریب همبستگی پیرسون^{۲۲} یک شاخص آماری است که برای سنجش قدرت و جهت رابطه خطی بین دو متغیر کمی استفاده می‌شود. ضریب همبستگی پیرسون بین ۱- و ۱ برای اندازه‌گیری همبستگی خطی بین دو متغیر استفاده می‌شود. ضریب بین ۰ تا ۱ نشان‌دهنده رابطه مستقیم خطی است؛ یعنی با افزایش یک متغیر، متغیر دیگر نیز افزایش می‌یابد. هرچه این ضریب به ۱ نزدیک‌تر باشد، رابطه قوی‌تر است. ضریب بین ۱- تا ۰ نشان‌دهنده رابطه معکوس خطی است. به این صورت که با افزایش یک متغیر، متغیر دیگر کاهش می‌یابد. هرچه این ضریب به ۱- نزدیک‌تر باشد، رابطه معکوس قوی‌تر است. ضریب ۰ نشان می‌دهد که بین دو متغیر هیچ رابطه خطی وجود ندارد. به عبارت دیگر، تغییرات در یک متغیر هیچ تأثیری بر تغییرات متغیر دیگر ندارد. توزیع گاوسی^{۲۳} متغیرها شرط لازم برای دقیق بودن ضریب همبستگی پیرسون است [۳۴]. ضریب همبستگی پیرسون بین متغیر X_i و Y_i را می‌توان به صورت رابطه ۱ محاسبه کرد:

$$\text{Corr}_{\text{pearson}} = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \text{Var}(Y)}} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

که در آن $\text{Cov}(X, Y)$ کواریانس X و Y است. $\text{Var}(X)$ و $\text{Var}(Y)$ به ترتیب واریانس X و Y هستند. \bar{X} و \bar{Y} به ترتیب میانگین X و Y هستند. تحلیل شکل ۴ نشان می‌دهد که بین پارامترهای PGA و PGV یک همبستگی مثبت بسیار قوی وجود دارد. این نتیجه با مطالعات قبلی نیز مطابقت دارد و به‌طور فیزیکی حاکی از آن است که افزایش PGA معمولاً با افزایش جابه‌جایی حداکثر زمین (PGV) همراه است. این همبستگی به دلیل ماهیت فیزیکی پدیده زلزله است، زیرا افزایش شدت لرزش منجر به افزایش جابه‌جایی ذرات خاک می‌شود. همچنین، این تحلیل آشکار ساخت که بین پارامترهای تاریخچه زمانی سرعت و تاریخچه زمانی پالس نیز همبستگی قابل توجهی وجود دارد. این همبستگی نشان‌دهنده ارتباط تنگاتنگ بین ویژگی‌های مختلف تاریخچه زمانی زلزله است.

²² Pearson Correlation Coefficient

²³ Gaussian Distribution



شکل ۴: ماتریس همبستگی پیرسون ویژگی‌های استخراج‌شده از تاریخچه زمانی سرعت.

شکل ۴ ماتریس همبستگی پیرسون را برای ویژگی‌های استخراج‌شده از تاریخچه زمانی سرعت نشان می‌دهد. هر سلول در این ماتریس ضریب همبستگی بین دو ویژگی را نشان می‌دهد. رنگ‌های گرم‌تر (قرمز) نشان‌دهنده همبستگی مثبت قوی‌تر و رنگ‌های سردتر (آبی) نشان‌دهنده همبستگی منفی قوی‌تر هستند.

۲-۴- تقسیم داده‌ها به داده‌های آموزشی و آزمایشی

در یادگیری ماشین، تقسیم داده‌ها به دو مجموعه آموزشی و آزمایشی یک گام حیاتی است. این کار به منظور آموزش و ارزیابی دقیق مدل‌های یادگیری ماشین انجام می‌شود. مجموعه داده آموزشی شامل داده‌هایی است که برای آموزش مدل استفاده می‌شود. الگوریتم یادگیری ماشین با استفاده از این داده‌ها الگوها و روابط بین ویژگی‌ها و برچسب‌ها را شناسایی می‌کند. مجموعه داده آزمایشی شامل داده‌هایی است که برای ارزیابی عملکرد مدل آموزش‌دیده مورد استفاده قرار می‌گیرد. به عبارت دیگر، مدل بر روی داده‌های آموزشی آموزش‌دیده و سپس با استفاده از داده‌های آزمایشی، توانایی آن در پیش‌بینی یا طبقه‌بندی داده‌های جدید و دیده نشده ارزیابی می‌شود. در

این پژوهش پایگاه داده به صورت تصادفی به دو دسته با نسبت ۸۰ درصد آموزشی و ۲۰ درصد آزمایشی تقسیم شد.

۲-۵- انتخاب الگوریتم طبقه بندی

۲-۵-۱- الگوریتم جنگل تصادفی

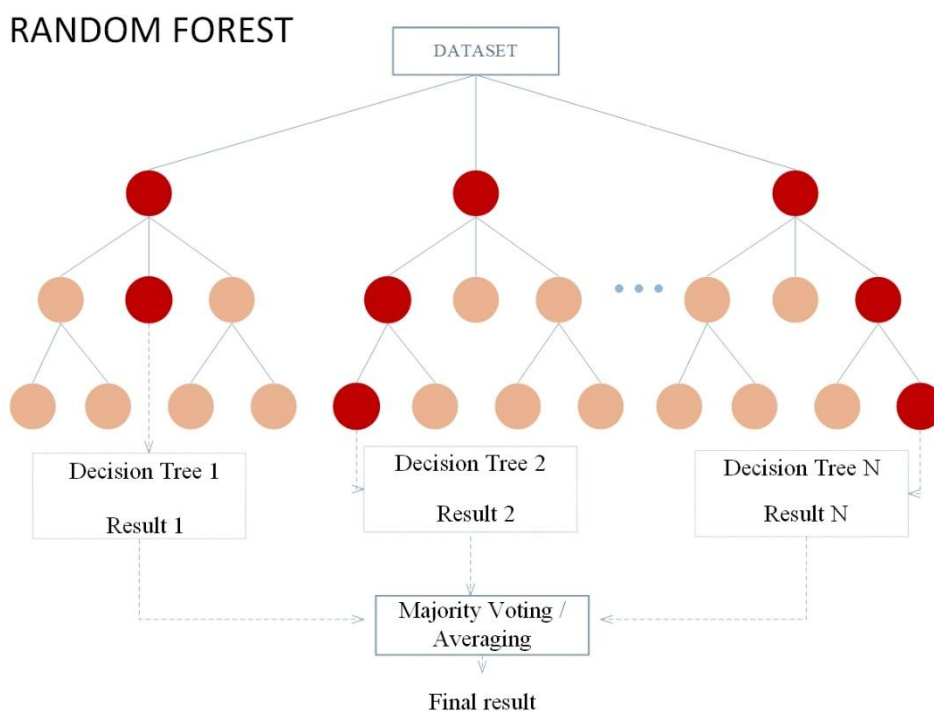
الگوریتم جنگل تصادفی نمونه‌ای از یادگیری گروهی^{۲۴} در یادگیری ماشین است. مطابق شکل ۵ این الگوریتم از خرد جمعی با ترکیب چندین پیش‌بینی کننده، مانند درخت‌های تصمیم^{۲۵} برای پیش‌بینی دقیق‌تر برای مجموعه داده‌های پیچیده بهره می‌برد. الگوریتم جنگل تصادفی به جای تکیه بر یک پیش‌بینی کننده، از پیش‌بینی‌های ترکیبی بسیاری از درختان تصمیم استفاده می‌کند. در طبقه‌بندی، پیش‌بینی نهایی با رأی اکثریت مشخص می‌شود. برای ایجاد یک جنگل تصادفی، چندین درخت تصمیم با استفاده از بوت استرپ^{۲۶} آموزش داده می‌شوند. بگینگ^{۲۷} یک تکنیک یادگیری جمعی است که برای به حداقل رساندن واریانس مدل استفاده می‌شود. در این تکنیک، هر مدل با استفاده از یک بخش به‌طور تصادفی از داده‌ها از طریق بوت استرپ آموزش داده می‌شود. الگوریتم جنگل تصادفی پیش‌بینی‌های درختان تصمیم‌گیری فردی را با در نظر گرفتن میانگین خروجی‌های آن‌ها جمع‌آوری می‌کند. با افزایش تعداد درختان می‌توان دقت پیش‌بینی‌ها را بهبود بخشید. این رویکرد به غلبه بر محدودیت‌های یک درخت تصمیم منفرد، کاهش بیش‌ازحد برازش و افزایش دقت کلی کمک می‌کند. درختان تصمیم اجزای اساسی یک جنگل تصادفی هستند. آن‌ها ساختار درخت ماندی را تشکیل می‌دهند که از گره‌های تصمیم‌گیری، گره‌های برگ و یک گره ریشه تشکیل شده است. مجموعه داده‌های آموزشی به شاخه‌هایی در هر گره تصمیم‌گیری تقسیم می‌شوند و دنباله‌ای از شاخه‌ها را تشکیل می‌دهند تا زمانی که به یک گره برگ برسند که در آن جداسازی بیشتر امکان‌پذیر نیست. تفاوت اصلی بین الگوریتم درخت تصمیم و الگوریتم جنگل تصادفی این است که جنگل‌های تصادفی هر درخت را بر روی یک نمونه تصادفی آموزش می‌دهند و مجموعه‌ای تصادفی از ویژگی‌ها را در هر گره برای پارتیشن‌بندی در نظر می‌گیرند. الگوریتم جنگل تصادفی این درختان آموزش دیده را با استفاده از میانگین‌گیری قطعی ترکیب می‌کند و از مدل‌های پایه همگن استفاده می‌کند که به‌طور مستقل و موازی آموزش داده می‌شوند.

²⁴ Ensemble Learning

²⁵ Decision Trees

²⁶ Bootstrap aggregating

²⁷ Bagging



شکل ۵: ساختار کلی الگوریتم تصادفی جنگل.

۲-۵-۲- تقویت طبقه بندی

تقویت طبقه بندی یک الگوریتم پیشرفته در یادگیری ماشین است که به طور ویژه برای کار با داده های دسته بندی شده²⁸ طراحی شده است [۳۵]. این الگوریتم با مقداردهی اولیه مدل به یک مقدار پیش بینی اولیه، که معمولاً میانگین مقدار هدف تبدیل شده است، کار خود را آغاز می کند. فرمولاسیون ریاضی تقویت طبقه بندی با اولیه سازی مطابق رابطه ذیل آغاز می شود:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma) \quad (2)$$

در این رابطه $F_0(x)$ مدل اولیه است، γ یک مقدار ثابت است، n تعداد نقاط داده است y_i مقدار هدف است و L تابع ضرر است.

۲-۵-۳- تقویت گرادیان شدید

تقویت گرادیان شدید یکی از قدرتمندترین و پرکاربردترین الگوریتم های یادگیری ماشین است که به دلیل دقت بالا، سرعت و قابلیت تعمیم پذیری بالا شناخته شده است. این الگوریتم با مقداردهی اولیه مدل به یک مقدار ثابت، که معمولاً میانگین مقدار هدف در مسائل رگرسیون یا احتمال پیش فرض در مسائل طبقه بندی است، کار خود را آغاز می کند. الگوریتم تقویت گرادیان شدید برای جلوگیری از بیش برآزسازی²⁹ و بهبود توانایی تعمیم مدل به داده های جدید، از تکنیک های منظم سازی استفاده می کند. این الگوریتم در هر تکرار از محاسبات گرادیان (مشتق اول) و (مشتق دوم) تابع هزینه برای ساخت درختان تصمیم جدید بهره می برد. با افزودن هر درخت جدید به مدل، خطای پیش بینی کاهش یافته و عملکرد کلی مدل بهبود می یابد.

²⁸ Categorical Data

²⁹ Overfitting

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta \cdot f_t(x_i) \quad (3)$$

در این رابطه $\hat{y}_i^{(t)}$ پیش‌بینی برای نقطه داده‌ی i در تکرار t است، $\hat{y}_i^{(t-1)}$ پیش‌بینی از تکرار قبلی است، η نرخ یادگیری و f_t درخت تازه اضافه شده است.

۲-۵-۴- الگوریتم ماشین پشتیبان

ماشین بردار پشتیبان (SVM) یکی از الگوریتم‌های قدرتمند در حوزه یادگیری ماشین است که توسط ولادیمیر واپنیک در سال ۱۹۹۷ معرفی شد. SVM به‌طور گسترده برای مسائل طبقه‌بندی و رگرسیون به‌کار می‌رود. هدف اصلی SVM یافتن بهترین مرز تصمیم‌گیری^{۳۰} است که بتواند داده‌های مختلف را با حداکثر فاصله از این مرز از یکدیگر جدا کند. این حاشیه حداکثری، باعث می‌شود مدل SVM در برابر نویز داده‌ها مقاوم‌تر باشد و دقت تعمیم‌پذیری بالاتری داشته باشد. در مسائل طبقه‌بندی خطی، SVM به دنبال یافتن یک خط (در فضای دوبعدی) یا یک ابر صفحه (در فضاهای با ابعاد بالاتر) است که داده‌های هر کلاس را از کلاس دیگر جدا کند. حاشیه حداکثری فاصله بین نزدیک‌ترین نقاط داده‌ها به ابر صفحه است. SVM تلاش می‌کند تا ابر صفحه‌ای را پیدا کند که حاشیه حداکثری را بهینه کند. برای مسائل طبقه‌بندی غیرخطی، SVM از توابع هسته استفاده می‌کند تا داده‌ها را به یک فضای با ابعاد بالاتر نگاشت کند و در این فضای جدید، یک ابر صفحه خطی برای جداسازی داده‌ها پیدا کند.

۲-۵-۵- الگوریتم KNN

الگوریتم KNN یکی دیگر از الگوریتم‌های پرکاربرد در یادگیری ماشین است که به‌سادگی و کارایی شناخته می‌شود. KNN بر اساس اصل اشیا مشابه به هم نزدیک، عمل می‌کند. برای پیش‌بینی برچسب یک نقطه داده جدید، KNN به نزدیک‌ترین همسایه‌های آن نقطه نگاه می‌کند. ابتدا تعداد همسایگان K را تعیین می‌شود سپس فاصله بین نقطه جدید و تمام نقاط داده موجود را محاسبه و K نقطه‌ای که کمترین فاصله را با نقطه جدید دارند، به‌عنوان K همسایه نزدیک انتخاب می‌شوند. برچسب نقطه جدید بر اساس رأی‌گیری اکثریت در بین K همسایه نزدیک تعیین می‌شود.


۲-۶- تجزیه و تحلیل عملکرد مدل

۲-۶-۱- تفسیر عملکرد مدل با استفاده از شپ

مدل‌های یادگیری ماشین به‌طور ذاتی مانند برخی دیگر از تکنیک‌های یادگیری ماشین، اندازه‌گیری صریحی از اهمیت ویژگی‌ها ارائه نمی‌دهند که این موضوع ارزیابی نقش ویژگی‌های مختلف را برای تشخیص زلزله‌های پالس‌گونه را تسهیل نمی‌کند. این محدودیت باعث می‌شود که نحوه عملکرد مدل یادگیری ماشین برای پیش‌بینی نهایی نیاز لرزه‌ای با توجه به شدت زلزله به‌طور واضح مشخص نشود [۳۶]. با این حال، ابزارهایی وجود دارند که می‌توانند به روشن‌سازی عملکرد درونی مدل‌های یادگیری ماشین کمک کنند. از جمله روش پرکاربرد در این زمینه می‌توان به شپ [۳۷] اشاره کرد که بر اساس تئوری ارزش شاپلی عمل می‌کنند. شپ می‌تواند تأثیر متغیرهای توضیحی در هر مقدار ویژگی را نشان دهد و همچنین تأثیرات مثبت و منفی متغیرهای ورودی را آشکار کند، که این امکان را فراهم می‌آورد تا صحت مدل‌های پیش‌بینی نهایی بررسی شود. هدف اصلی شپ افزایش شفافیت و قابلیت تفسیر مدل‌های پیچیده یادگیری ماشین است. این روش با تخصیص یک مقدار اهمیت به هر ویژگی، کمک می‌کند تا تأثیر هر ویژگی بر پیش‌بینی نهایی مدل درک شود. به‌طور ساده‌تر، زمانی که یک مدل یادگیری ماشین بر روی مجموعه‌ای از ویژگی‌ها آموزش می‌بیند، می‌توان آن را به‌عنوان یک بازی در نظر گرفت که در آن هر ویژگی نقش یک بازیکن را ایفا می‌کند. مقدار شاپلی به هر ویژگی یک امتیاز اختصاص می‌دهد که نشان‌دهنده سهم آن ویژگی در نتیجه نهایی مدل است. این امتیاز به مشخص می‌کند که اگر این ویژگی وجود نداشت، پیش‌بینی مدل چقدر متفاوت می‌شد.

³⁰ Hyperplane

اهمیت ویژگی معمولاً برای غربالگری و حذف ویژگی‌های کم تأثیر به منظور کاهش ابعاد و بهبود استحکام مدل به کار می‌رود [۳۷]. ساده‌ترین راه برای درک کلی تأثیر هر ویژگی بر پیش‌بینی‌های مدل با استفاده از شپ، محاسبه میانگین قدر مطلق مقادیر شاپلی برای هر ویژگی در کل داده‌ها است. این مقدار به‌طور متوسط نشان می‌دهد که هر ویژگی به چه میزان (چه مثبت و چه منفی) بر پیش‌بینی شده تأثیر می‌گذارد. ویژگی‌هایی که میانگین قدر مطلق مقدار شاپلی بالاتری دارند، تأثیر بیشتری بر نتیجه نهایی دارند. در این پژوهش، با توجه به عملکرد مطلوب مدل جنگل تصادفی، از روش شاپلی برای ارزیابی اهمیت ویژگی‌ها در این الگوریتم استفاده شد. در ابتدا، مقدار شاپلی برای همه ۱۸ ویژگی اولیه محاسبه گردید. سپس، بر اساس نمودار میله‌ای شکل ۶، ۸ ویژگی با بالاترین مقدار شاپلی به‌عنوان مهم‌ترین ویژگی‌ها انتخاب شدند.



شکل ۶: اهمیت ویژگی‌ها در مدل طبقه‌بندی بر اساس روش شپ.

در شکل ۶، هر ویژگی به‌صورت یک نوار افقی نمایش داده شده است. طول بخش آبی‌رنگ هر نوار نشان‌دهنده تأثیر مثبت آن ویژگی بر کلاس ۱ (زلزله‌های پالس گونه) و طول بخش قرمز رنگ نشان‌دهنده تأثیر مثبت آن ویژگی بر کلاس ۰ (زلزله‌های غیر پالس گونه) است. هرچه مقدار شپ برای یک ویژگی بیشتر باشد، به معنای تأثیرگذاری بیشتر آن ویژگی بر آن کلاس خاص است. با توجه به نمودار میله‌ای شپ مشخص شد که به ترتیب چهار ویژگی Variance pulse، PGV، Rms Pulse و Energy Ratio بیشترین اهمیت را برای تشخیص زلزله‌های پالس گونه از غیر پالس گونه دارند. همچنین مدت دوام بین ۱۰ تا ۵۰ و ۱۰ تا ۶۰ درصد از شدت آریاس هم از اهمیت متوسط برای عملکرد درست مدل تشخیص پالس دارند.


۲-۶-۱-۱- نمودار خوشه‌ای ۳۱

نمودار خوشه‌ای که به نمودار خلاصه^{۳۲} معروف است، اهمیت ویژگی‌ها را با اثرات آن‌ها ترکیب می‌کند. هر نقطه در این نمودار نشان‌دهنده مقدار شاپلی یک ویژگی برای یک نمونه داده است. موقعیت روی محور y توسط ویژگی و روی محور x توسط مقدار شاپلی تعیین می‌شود. رنگ نشان‌دهنده مقدار ویژگی از کم به زیاد است. نقاط همپوشان در جهت محور y جابه‌جا می‌شوند تا بتوانیم توزیع مقادیر

³¹ BeesWarm plot


³² Summary plot

شاپلی برای هر ویژگی را مشاهده کنیم. ویژگی‌ها بر اساس اهمیت آن‌ها مرتب شده‌اند. با محاسبه نمودارهای (۷ و ۸) اهمیت و تأثیر هر کدام از ویژگی‌ها برای تشخیص هر کدام از دسته زلزله‌های پالس گونه و غیر پالس گونه مشخص گردیده است.



شکل ۷: نمودار خلاصه شپ برای ویژگی‌های مختلف برای کلاس زلزله‌های غیر پالس گونه

در شکل ۷ خلاصه‌ای از تأثیر هر یک از ویژگی‌ها بر خروجی مدل را نشان می‌دهد. روش شپ با تخصیص مقادیر به هر ویژگی، میزان تأثیرگذاری هر ویژگی بر خروجی مدل را مشخص می‌کند. در این نمودار، برای هر ویژگی، چندین نقطه وجود دارد که هر نقطه نشان‌دهنده تأثیر آن ویژگی بر طبقه‌بندی زلزله‌های غیر پالس گونه است. رنگ نقاط نشان‌دهنده مقدار ویژگی و موقعیت آن‌ها روی محور افقی نشان‌دهنده تأثیر آن ویژگی بر خروجی مدل است.



شکل ۸: نمودار خلاصه شپ برای ویژگی‌های مختلف مدل برای کلاس زلزله‌های پالس گونه

در شکل ۸ رنگ نقاط نشان‌دهنده مقدار ویژگی و موقعیت آن‌ها روی محور افقی نشان‌دهنده تأثیر آن ویژگی بر خروجی مدل است.

نمودار خلاصه مقادیر شپ برای دو دسته زلزله‌های پالس گونه و غیر پالس گونه محاسبه شد. این نمودارها نشان می‌دهد که افزایش مقادیر ویژگی‌های واریانس پالس، PGV و RMS پالس تأثیر منفی بر طبقه‌بندی داده‌ها به‌عنوان زلزله‌های غیر پالس گونه داشته است. به‌عبارت‌دیگر، هر چه این ویژگی‌ها در یک رکورد لرزه‌ای بیشتر باشند، احتمال اینکه آن رکورد به‌عنوان زلزله پالس گونه طبقه‌بندی شود، بیشتر خواهد بود. از سوی دیگر، افزایش مقادیر ویژگی‌های Energy Ratio، D10_60، D10_50، D5_75 و D0_5 تأثیر مثبتی بر طبقه‌بندی داده‌ها به‌عنوان زلزله‌های غیر پالس گونه داشته است. این نتایج با یافته‌های پیشین در حوزه زلزله‌شناسی نیز همخوانی دارد. همان‌طور که انتظار می‌رود، زلزله‌های پالسی عموماً دارای مقادیر بالای واریانس، PGV و RMS پالس هستند. این ویژگی‌ها به‌طور مستقیم با وجود پالس‌های قوی در سیگنال لرزه‌ای مرتبط هستند که از مشخصه‌های بارز زلزله‌های پالس گونه محسوب می‌شود.

۲-۶-۲- تنظیم هایپر پارامترها، اعتبارسنجی و صحت سنجی

مدل‌های یادگیری ماشین را می‌توان به‌عنوان مدل‌های ریاضی تصور کرد که با مجموعه‌ای از پارامترها تعریف می‌شوند. این پارامترها در طی فرآیند آموزش از روی داده‌ها یاد گرفته می‌شوند و به مدل اجازه می‌دهند تا الگوها و روابط پیچیده نهفته در داده‌ها را کشف کند. برای مثال، در یک شبکه عصبی، وزن‌های نورون‌ها به‌عنوان پارامترهای مدل محسوب می‌شوند. باین‌حال، علاوه بر پارامترهای مدل، مفهومی به نام هایپر پارامترها نیز وجود دارد که نقش بسیار مهمی در عملکرد مدل ایفا می‌کنند. هایپر پارامترها، برخلاف پارامترهای مدل، به‌صورت مستقیم از داده‌ها یاد گرفته نمی‌شوند، بلکه قبل از شروع فرآیند آموزش توسط مهندس یادگیری ماشین تعیین می‌شوند. این پارامترها ویژگی‌های کلی مدل را کنترل می‌کنند و بر نحوه یادگیری مدل تأثیر می‌گذارند در این پژوهش‌ها از هایپر پارامترهای پیش‌فرض الگوریتم‌های به دلیل دقت بالای نتایج استفاده شد.

۲-۶-۳- معیارهای ارزیابی عملکرد مدل طبقه بندی

در مدل‌های طبقه‌بندی یادگیری ماشین برای افزایش درک از عملکرد مدل از ماتریس درهم‌ریختگی^{۳۳} مطابق شکل ۹ استفاده می‌شود. ماتریس درهم‌ریختگی یک ابزار قدرتمند برای ارزیابی عملکرد مدل‌های یادگیری ماشینی در مسائل طبقه‌بندی است. این ماتریس، به‌طور خلاصه، مقایسه‌ای بین برجسب‌های پیش‌بینی‌شده توسط مدل و برجسب‌های واقعی کلاس‌ها ارائه می‌دهد. در یک ماتریس درهم‌ریختگی، هر سطر نشان‌دهنده نمونه‌های متعلق به یک کلاس واقعی و هر ستون نشان‌دهنده نمونه‌هایی است که مدل آن‌ها را به یک کلاس خاص نسبت داده است. سلول‌های داخل ماتریس حاوی تعداد نمونه‌هایی هستند که به‌اشتباه یا به‌درستی طبقه‌بندی شده‌اند. سلول مثبت واقعی نشان می‌دهد که چند نمونه هم در واقع به کلاس مثبت تعلق داشته‌اند و هم توسط مدل به‌عنوان مثبت پیش‌بینی شده‌اند. به همین ترتیب، سلول منفی کاذب نشان می‌دهد که چند نمونه در واقع به کلاس منفی تعلق داشته‌اند اما توسط مدل به‌عنوان مثبت اشتباه گرفته شده‌اند. در ماتریس درهم‌ریختگی، دقت کلی به‌صورت نسبت تعداد نمونه‌هایی که به‌درستی طبقه‌بندی شده‌اند به کل نمونه‌ها تعریف می‌شود. به عبارت ساده‌تر، برای محاسبه دقت، مجموع عناصر روی قطر اصلی ماتریس (نمایانگر نمونه‌های درست طبقه‌بندی‌شده) را بر مجموع تمام عناصر ماتریس تقسیم می‌کنیم. دقت زمانی یک معیار مناسب است که توزیع کلاس‌ها در داده‌ها متعادل باشد. به این معنی که تعداد نمونه‌های هر کلاس تقریباً برابر باشد. در چنین شرایطی، دقت به‌خوبی توانایی مدل در تشخیص صحیح همه کلاس‌ها را نشان می‌دهد؛ اما در مواردی که توزیع کلاس‌ها نامتعادل است، دقت می‌تواند گمراه‌کننده باشد. فرض کنید در یک مجموعه داده، کلاسی اکثریت و کلاسی اقلیت وجود داشته باشد. اگر مدلی همیشه نمونه‌ها را به کلاس اکثریت نسبت دهد، دقت بالایی خواهد داشت، اما در تشخیص کلاس اقلیت کاملاً شکست خورده است. در چنین حالتی، دقت به‌تنهایی نمی‌تواند عملکرد واقعی مدل را نشان دهد؛ بنابراین، در مواردی که توزیع کلاس‌ها نامتعادل است، علاوه بر دقت، باید از معیارهای دیگری مانند حساسیت^{۳۴}، صحت^{۳۵} و FI-score نیز استفاده کرد. این

³³ Confusion Matrix

³⁴ Recall

³⁵ Precision

معیارها به ما کمک می‌کنند تا عملکرد مدل را در تشخیص هر یک از کلاس‌ها به‌طور جداگانه ارزیابی کنیم. جدول ۲ خلاصه‌ای از معیارهای ارزیابی عملکرد مدل طبقه‌بندی زلزله‌های پالس گونه را ارائه می‌دهد.

		Predicted as Positive	Predicted as Negative
Actual	positive	True positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

شکل ۹: ماتریس درهم‌ریختگی برای ارزیابی عملکرد یک مدل طبقه‌بندی

جدول ۲: معیارهای ارزیابی عملکرد مدل یادگیری ماشین

نوع معیار ارزیابی	رابطه معیار ارزیابی	توضیح معیار ارزیابی
Accuracy	$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$	دقت کل، معیاری برای سنجش صحت کلی پیش‌بینی‌های یک مدل است
Precision	$Precision = \frac{TP}{TP + FP}$	(Precision) نشان‌دهنده‌ی درستی پیش‌بینی‌های مثبت مدل است
Recall	$Recall = \frac{TP}{TP + FN}$	حساسیت (Recall) نشان می‌دهد که از کل نمونه‌های مثبت واقعی، چند مورد توسط مدل به‌درستی شناسایی شده‌اند
F1-score	$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$	امتیاز F1 یک معیار عملکرد رایج در طبقه‌بندی باینری است که هم دقت و هم بازخوانی را در یک مقدار واحد ترکیب می‌کند.

۳- بحث و نتایج

۳-۱- نتایج مدل‌های طبقه‌بندی زلزله‌های پالس گونه و غیر پالس گونه

در این پژوهش، برای تشخیص و تفکیک زلزله‌های پالس گونه از زلزله‌های غیر پالس گونه، از پنج الگوریتم یادگیری ماشین قدرتمند استفاده شده است. این الگوریتم‌ها شامل جنگل تصادفی، تقویت گرادیان شدید، تقویت طبقه‌بندی، SVM و KNN هستند که همگی به‌عنوان روش‌های پیشرفته طبقه‌بندی شناخته می‌شوند. با بهره‌گیری از این الگوریتم‌ها، مدل‌های مختلفی برای طبقه‌بندی داده‌های زلزله آموزش داده شده‌اند. برای ارزیابی عملکرد هر یک از این مدل‌ها، از ماتریس درهم‌ریختگی مطابق شکل‌های ۱۰ تا ۱۴ برای داده‌های آموزشی و آزمایشی استفاده شده است. این ماتریس، به‌صورت دقیق تعداد نمونه‌هایی که به‌درستی و نادرستی طبقه‌بندی شده‌اند را نشان

می دهد. علاوه بر ماتریس درهم ریختگی، معیارهای ارزیابی دیگری مانند دقت، حساسیت، صحت و امتیاز F1 نیز محاسبه شده اند تا ارزیابی جامع تری از عملکرد مدل ها ارائه شود.

		مجموعه آموزشی		
		مجموعه آزمایشی		
		Prediction Class		
		Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	32	3	0.914
	Non-Pulse like	8	31	0.795
Precision		0.800	0.883	0.851
accuracy				

		مجموعه آموزشی		
		مجموعه آزمایشی		
		Prediction Class		
		Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	145	14	0.912
	Non-Pulse like	30	106	0.779
Precision		0.829	0.883	0.851
accuracy				

شکل ۱۰: ماتریس درهم ریختگی طبقه بندی با الگوریتم SVM برای داده های آموزشی (سمت راست) و آزمایشی (سمت چپ)

		مجموعه آموزشی		
		مجموعه آزمایشی		
		Prediction Class		
		Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	31	4	0.886
	Non-Pulse like	0	39	1.000
Precision		1.000	0.907	0.946
accuracy				

		مجموعه آموزشی		
		مجموعه آزمایشی		
		Prediction Class		
		Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	156	1	0.994
	Non-Pulse like	0	136	1.000
Precision		1.000	0.993	0.997
accuracy				

شکل ۱۱: ماتریس درهم ریختگی طبقه بندی با الگوریتم جنگل تصادفی برای داده های آموزشی (سمت راست) و آزمایشی (سمت چپ)

		مجموعه آموزشی			مجموعه آزمایشی		
		Prediction Class			Prediction Class		
		Pulse like	Non-Pulse like	Recall	Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	133	26	0.836	28	7	0.800
	Non-Pulse like	22	114	0.838	5	34	0.872
	Precision	0.858	0.814	0.837	0.848	0.829	0.838
		accuracy			accuracy		

شکل ۱۲: ماتریس درهم‌ریختگی طبقه‌بندی با الگوریتم KNN برای داده‌های آموزشی (سمت راست) و آزمایشی (سمت چپ)

		مجموعه آموزشی			مجموعه آزمایشی		
		Prediction Class			Prediction Class		
		Pulse like	Non-Pulse like	Recall	Pulse like	Non-Pulse like	Recall
Actual Class	Pulse like	158	1	0.994	31	4	0.886
	Non-Pulse like	0	136	1.000	1	38	0.974
	Precision	1.000	0.993	0.997	0.969	0.905	0.932
		accuracy			accuracy		

شکل ۱۳: ماتریس درهم‌ریختگی طبقه‌بندی با الگوریتم تقویت گرادیان شدید برای داده‌های آموزشی (سمت راست) و آزمایشی (سمت چپ)

		مجموعه آموزشی			مجموعه آزمایشی				
		Prediction Class			Prediction Class				
		Pulse like	Non-Pulse like	Recall	Pulse like	Non-Pulse like	Recall		
Actual Class	Pulse like	31	4	0.886	158	1	0.994		
	Non-Pulse like	0	39	1.000	0	136	1.000		
	Precision	1.000	0.907	0.946	1.000	0.993	0.997		
				accuracy			accuracy		

شکل ۱۴: ماتریس درهم‌ریختگی طبقه‌بندی با الگوریتم تقویت طبقه‌بندی برای داده‌های آموزشی (سمت راست) و آزمایشی (سمت چپ)

شکل‌های ۱۰ تا ۱۴ ماتریس‌های درهم‌ریختگی مقایسه‌ای عملکرد مدل‌های طبقه‌بندی پالس مانند و غیر پالس مانند برای الگوریتم‌های SVM، جنگل تصادفی، KNN، تقویت گرادیان شدید و تقویت طبقه‌بندی به همراه معیارهای ارزیابی صحت، بازخوانی و دقت را نمایش می‌دهند.

نتایج بررسی ماتریس‌های آشفتگی نشان می‌دهد که مدل‌های جنگل تصادفی و تقویت طبقه‌بندی در شناسایی نمونه‌های کلاس غیر پالس گونه بسیار دقیق عمل کرده‌اند، به گونه‌ای که هیچ نمونه‌ای را به اشتباه به عنوان پالس گونه پیش‌بینی نکرده‌اند ($FP = 0$). با این حال، در مجموعه آزمایشی چهار نمونه از کلاس پالس گونه به اشتباه غیر پالس گونه پیش‌بینی شده است ($FN = 4$)، که این موضوع بیانگر تمایل این مدل‌ها به کاهش هشدارهای کاذب به قیمت از دست دادن برخی نمونه‌های مثبت واقعی است. در مجموعه آموزشی نیز تنها یک مورد خطای نوع دوم مشاهده شد ($FN = 1$). عملکرد مدل تقویت گرادیان شدید نیز بسیار مشابه مدل‌های فوق بود، به طوری که در مجموعه آزمایشی تنها یک مورد مثبت کاذب ($FP = 1$) و چهار مورد منفی کاذب ($FN = 4$) ثبت شد و در مجموعه آموزشی عملکرد تقریباً بی‌نقصی داشت ($FN = 0$ و $FP = 1$). در مقابل، مدل SVM در مقایسه با مدل‌های فوق تعداد بیشتری مثبت کاذب در مجموعه آزمایشی تولید کرده است ($FP = 8$)، به این معنی که نسبت به جنگل تصادفی و تقویت طبقه‌بندی، نمونه‌های بیشتری از غیر پالس گونه را به اشتباه پالس گونه پیش‌بینی نموده است. همچنین تعداد منفی کاذب‌های مدل SVM نسبت به KNN کمتر است ($FN = 3$ در آزمایش و $FN = 14$ در آموزش). مدل KNN نیز بیشترین میزان خطاهای نوع اول و دوم را در میان مدل‌ها داشت؛ به گونه‌ای که در مجموعه آزمایشی پنج نمونه مثبت کاذب ($FP = 5$) و هفت نمونه منفی کاذب ($FN = 7$) و در مجموعه آموزشی به ترتیب ۲۲ و ۲۶ مورد از این خطاها ثبت شده است که نشان‌دهنده حساسیت کمتر این مدل در جداسازی دقیق کلاس‌ها می‌باشد. در مجموع، این نتایج نشان می‌دهد که مدل‌های جنگل تصادفی، تقویت گرادیان شدید و تقویت طبقه‌بندی، نسبت به مدل‌های KNN و SVM، خطاهای نوع اول (False Positive) بسیار کمتری تولید کرده و توانایی بالاتری در تفکیک صحیح کلاس‌ها داشته‌اند. این مدل‌ها با به حداقل رساندن هشدارهای کاذب، عملکرد قابل‌اعتمادتری ارائه داده‌اند. در مقابل، مدل KNN در هر دو نوع خطا ضعیف‌تر عمل کرده و SVM نیز تا حدی تمایل به تولید مثبت کاذب دارد. بنابراین، می‌توان نتیجه گرفت که مدل‌های مبتنی بر درخت با کنترل بهتر خطاهای نوع اول و دوم، برای داده‌های لرزه‌ای در این پژوهش عملکرد برتری از خود نشان داده‌اند.

جدول ۳: نتایج عملکرد پنج مدل یادگیری ماشین را بر روی مجموعه‌های آموزشی و آزمایشی در چهار معیار کلیدی (دقت، صحت، حساسیت و امتیاز F1)

مدل	تقسیم داده	دقت	صحت	حساسیت	امتیاز F1
ماشین بردار پشتیبان	مجموعه آموزشی	۰/۸۵۱	۰/۸۲۹	۰/۹۱۲	۰/۸۶۹
	مجموعه آزمایشی	۰/۸۵۱	۰/۸۰۰	۰/۹۱۴	۰/۸۵۴
جنگل تصادفی	مجموعه آموزشی	۰/۹۹۷	۱/۰۰	۰/۹۴۴	۰/۹۹۷
	مجموعه آزمایشی	۰/۹۶۴	۱/۰۰	۰/۸۸۶	۰/۹۴۰
KNN	مجموعه آموزشی	۰/۸۳۸	۰/۸۴۸	۰/۸۰۰	۰/۸۲۴
	مجموعه آزمایشی	۰/۸۳۷	۰/۸۵۸	۰/۸۳۶	۰/۸۴۷
تقویت گرادیان شدید	مجموعه آموزشی	۰/۹۹۷	۱/۰۰	۰/۹۹۴	۰/۹۹۶
	مجموعه آزمایشی	۰/۹۳۲	۰/۹۶۹	۰/۸۸۶	۰/۹۲۶
تقویت طبقه‌بندی	مجموعه آموزشی	۰/۹۹۷	۱/۰۰	۰/۹۹۴	۰/۹۹۶
	مجموعه آزمایشی	۰/۹۴۶	۱/۰۰	۰/۸۸۶	۰/۹۴۰

جدول ۳ نتایج عملکرد پنج مدل یادگیری ماشین (ماشین بردار پشتیبان، جنگل تصادفی، KNN، تقویت گرادیان شدید و تقویت طبقه‌بندی) را در چهار معیار کلیدی دقت، صحت، حساسیت و امتیاز F1 بر روی مجموعه‌های آموزشی و آزمایشی ارائه می‌دهد. بررسی این جدول، امکان مقایسه جامع و دقیق نقاط قوت و ضعف هر مدل را در شرایط آموزش و تعمیم به داده‌های جدید فراهم می‌کند. در بین مدل‌ها، مدل‌های مبتنی بر درخت و تقویتی (جنگل تصادفی، تقویت گرادیان شدید و تقویت طبقه‌بندی)، بالاترین عملکرد را در تمامی معیارها، به‌ویژه روی داده‌های آموزشی، از خود نشان داده‌اند. دقت این مدل‌ها روی داده‌های آموزشی تقریباً کامل (۰/۹۹۷) است و صحت آن‌ها به عدد ۱ رسیده است، که نشان‌دهنده یادگیری عالی مدل از داده‌های آموزش می‌باشد. همچنین حساسیت و امتیاز F1 این مدل‌ها نیز بسیار بالا و نزدیک به مقدار کامل است. بررسی عملکرد این مدل‌ها روی داده‌های آزمایشی نشان می‌دهد که دقت و امتیاز F1 کمتر شده است. برای مثال دقت جنگل تصادفی و تقویت طبقه‌بندی ۰/۹۴۶ و ۰/۹۴۰ و برای تقویت گرادیان شدید ۰/۹۳۲ ثبت شده است. با توجه به اختلاف دقت و امتیاز F1 در داده‌های آموزشی و آزمایشی احتمال بیش‌برازش^{۳۶} در این مدل‌ها وجود دارد. مدل SVM عملکرد متوسطی داشته و به‌ویژه در معیار صحت و امتیاز F1 روی داده‌های آزمایشی، مقادیر پایین‌تری نسبت به مدل‌های مبتنی بر درخت کسب کرده است (دقت ۰/۸۵۱، صحت ۰/۸۰۰ و F1 برابر با ۰/۸۵۴). این موضوع نشان می‌دهد SVM نسبت به مدل‌های تقویتی و جنگل تصادفی توانایی کمتری در تفکیک دقیق کلاس‌ها در داده‌های جدید دارد. مدل KNN نیز پایین‌ترین عملکرد را در اکثر معیارها نشان داده است، به‌ویژه در داده‌های آزمایشی که دقت و F1 به ترتیب ۰/۸۳۷ و ۰/۸۴۷ ثبت شده است. صحت و حساسیت این مدل نیز در هر دو مجموعه نسبت به سایر مدل‌ها پایین‌تر است که حاکی از حساسیت کمتر KNN به جداسازی کلاس‌ها و احتمال بالاتر خطاهای نوع اول و دوم در این مدل می‌باشد. در مجموع، می‌توان نتیجه گرفت که مدل‌های جنگل تصادفی و مدل‌های مبتنی بر تقویت بالاترین عملکرد را در داده‌های لرزه‌ای ارائه داده‌اند و علاوه بر دقت بالا، از پایداری مناسب در تعمیم به داده‌های آزمایشی نیز برخوردارند. مدل‌های SVM و KNN نسبت به این مدل‌ها عملکرد ضعیف‌تری داشته و خطای بیشتری در پیش‌بینی دارند. این نتایج اهمیت استفاده از مدل‌های ترکیبی و تقویتی را برای مسائل پیچیده و داده‌های واقعی مانند داده‌های لرزه‌ای تأیید می‌کند.

۳-۲- تحلیل دقت و پایداری مدل‌های یادگیری ماشین در طبقه‌بندی داده‌های لرزه‌ای

با توجه به احتمال وجود بیش‌برازش در مدل‌های یادگیری گروهی از اعتبارسنجی متقابل^{۳۷} استفاده شد. این روش برای افزایش دقت ارزیابی و جلوگیری از بیش‌برازش به کار می‌رود. در این روش، داده‌ها به چند بخش^{۳۸} تقسیم می‌شوند. مدل روی برخی از این بخش‌ها آموزش می‌بیند و روی بخش دیگر تست می‌شود. این فرآیند چند بار با تقسیم‌بندی‌های متفاوت تکرار می‌شود و در نهایت میانگین نتایج به‌عنوان معیار عملکرد مدل گزارش می‌شود. با توجه به مشاهده اختلاف دقت بین داده‌های آموزشی و آزمایشی در الگوریتم‌های یادگیری گروهی، به‌منظور بررسی بیش‌برازش و ارزیابی دقیق عملکرد مدل‌ها، از روش اعتبارسنجی متقابل استفاده شد. نتایج حاصل که در جدول ۴ ارائه شده است نشان می‌دهد که الگوریتم‌های جنگل تصادفی، تقویت طبقه‌بندی و تقویت گرادیان شدید به ترتیب با دقت‌های ۰/۹۱۱، ۰/۹۱۶ و ۰/۹۰۳ بهترین عملکرد را داشته‌اند. در مقابل، الگوریتم‌های KNN و SVM به ترتیب با دقت‌های ۰/۸۴۸ و ۰/۸۵۴ عملکرد متوسطی از خود نشان داده‌اند. همچنین، اختلاف اندک دقت در بین بخش‌های مختلف هر مدل، بیانگر پایداری و قابلیت اطمینان مناسب مدل‌ها می‌باشد. همچنین کمترین انحراف در معیار دقت مربوط به مدل تقویت طبقه‌بندی با مقدار ۰/۰۱۷۴ و بیشترین مقدار مربوط به مدل تقویت گرادیان شدید با ۰/۰۳۶۳ است. همچنین در معیار F1، مدل جنگل تصادفی پایین‌ترین انحراف معیار (۰/۰۲۵۷) و مدل تقویت طبقه‌بندی بالاترین مقدار (۰/۰۴۵۰) را دارد. به‌طور کلی، مدل‌هایی که انحراف معیار کمتری دارند، عملکردی پایدارتر و قابل‌اعتمادتر در طول اعتبارسنجی متقابل داشته‌اند، درحالی‌که مقادیر بالاتر بیانگر نوسان بیشتر عملکرد مدل‌ها است.

جدول ۴: مقایسه عملکرد مدل‌های مختلف یادگیری ماشین بر اساس اعتبارسنجی متقابل پنج بخشی

نام مدل	معیار	بخش ۱	بخش ۲	بخش ۳	بخش ۴	بخش ۵	میانگین دقت	انحراف معیار
جنگل تصادفی	Accuracy	۰/۸۷۸	۰/۹۳۲	۰/۹۱۹	۰/۸۹۲	۰/۹۳۲	۰/۹۱۱	۰/۰۲۴۵
	F1	۰/۸۸۰	۰/۸۹۶	۰/۹۴۳	۰/۹۱۲	۰/۹۳۲	۰/۹۱۲	۰/۰۲۵۷
KNN	Accuracy	۰/۸۵۱	۰/۸۶۵	۰/۸۱۱	۰/۸۷۸	۰/۸۳۶	۰/۸۴۸	۰/۰۲۶۰
	F1	۰/۸۴۶	۰/۷۸۴	۰/۸۷۰	۰/۸۲۲	۰/۸۷۳	۰/۸۳۹	۰/۰۳۷۰
ماشین بردار پشتیبان	Accuracy	۰/۸۶۵	۰/۸۷۸	۰/۸۵۱	۰/۸۲۴	۰/۸۴۹	۰/۸۵۴	۰/۰۲۰۲
	F1	۰/۸۵۷	۰/۸۱۳	۰/۸۷۵	۰/۷۸۱	۰/۸۵۳	۰/۸۳۶	۰/۰۳۸۱
تقویت طبقه بندی	Accuracy	۰/۹۰۵	۰/۹۱۹	۰/۹۰۵	۰/۹۰۵	۰/۹۴۵	۰/۹۱۶	۰/۰۱۷۴
	F1	۰/۸۳۱	۰/۹۱۲	۰/۹۴۱	۰/۹۳۰	۰/۹۳۲	۰/۹۰۹	۰/۰۴۵۰
تقویت گرادیان شدید	Accuracy	۰/۸۵۱	۰/۹۳۲	۰/۹۱۹	۰/۸۷۸	۰/۹۳۲	۰/۹۰۳	۰/۰۳۶۳
	F1	۰/۸۵۳	۰/۸۹۶	۰/۹۴۳	۰/۹۲۸	۰/۹۱۹	۰/۹۰۸	۰/۰۳۵۱

با توجه به اختلاف معنادار بین دقت داده‌های آموزشی و آزمایشی در میان الگوریتم‌های یادگیری گروهی مورد استفاده، الگوریتم جنگل تصادفی به‌عنوان مدل منتخب جهت بررسی‌های بیشتر انتخاب شد. به‌منظور پیشگیری از بروز بیش‌برازش، تنظیمات بهینه‌ای برای هایپرپارامترهای این مدل اعمال گردید. مقادیر هایپرپارامترهای مدل جنگل تصادفی مطابق جدول ۵ و با رویکرد کنترل بیش‌برازش، بر پایه روش سعی و خطا و با استناد به تجربیات علمی و استانداردهای مطرح در ادبیات تخصصی انتخاب شدند. در این جدول، علاوه بر ارائه مقدار بهینه هر هایپرپارامتر، دلایل انتخاب آن نیز بر اساس منابع علمی و تجربه‌های پیشین ذکر شده است.

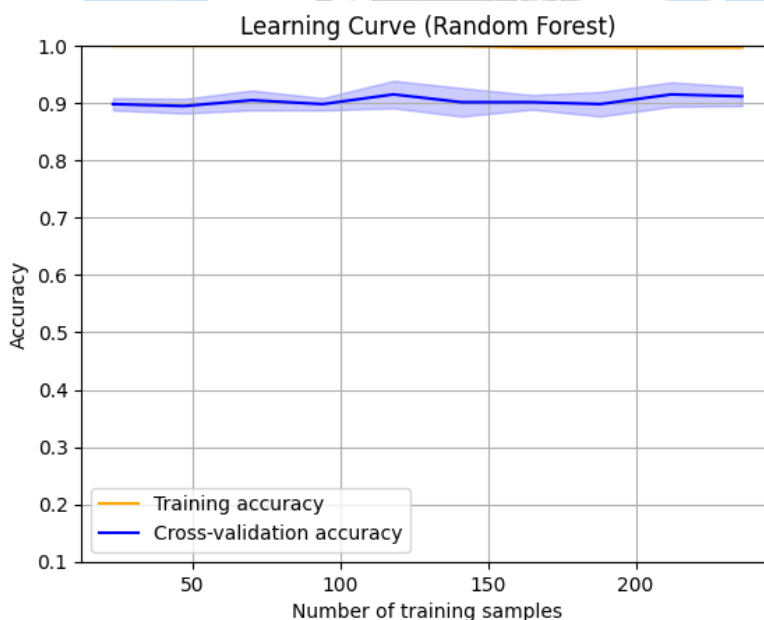
³⁷ Cross-Validation

³⁸ fold

جدول ۵: جدول تنظیمات هایپر پارامترهای مدل جنگل تصادفی


نام هایپر پارامتر	مقدار در حالت پیش فرض	مقدار اصلاح شده	دلیل تنظیم
max_depth	(None) بدون محدودیت	۱۰	جلوگیری از حفظ جزئیات غیر ضروری داده آموزش و افزایش تعمیم پذیری مدل
min_samples_leaf	۲	۵	کاهش احتمال یادگیری بر اساس نمونه‌های خاص و اطمینان از استفاده از اطلاعات بیشتر در هر برگ
min_samples_split	۲	۵	جلوگیری از تقسیم‌های بیش از حد و غیر ضروری در درخت
max_features	sqrt	Log2	افزایش تنوع درخت‌ها و کاهش وابستگی به ویژگی‌های خاص
n_estimators	۱۰۰	۱۰۰	تضمین پایداری مدل و جلوگیری از حساسیت مدل به نویز در صورت زیاد بودن عمق درخت‌ها

برای کنترل بیش برآزش مدل از منحنی‌های یادگیری^{۳۹} استفاده شد. منحنی یادگیری یکی از ابزارهای مهم برای ارزیابی عملکرد مدل‌های یادگیری ماشین است که نشان می‌دهد مدل با افزایش حجم داده‌های آموزشی چگونه فرآیند یادگیری را طی می‌کند. این منحنی به صورت نموداری ترسیم می‌شود که در آن معمولاً دقت، خطا یا سایر معیارهای ارزیابی مدل بر حسب تعداد نمونه‌های آموزشی نمایش داده می‌شود. در این نمودار، دو منحنی مجزا برای داده‌های آموزش و داده‌های تست رسم می‌شود تا روند عملکرد مدل در هر دو مجموعه قابل مشاهده باشد. استفاده از منحنی یادگیری چندین هدف کلیدی را دنبال می‌کند؛ از جمله تشخیص بیش برآزش یا کم برآزش^{۴۰} مدل، ارزیابی این موضوع که آیا با افزایش تعداد نمونه‌های آموزشی مدل بهبود می‌یابد یا خیر، و همچنین به تصمیم‌گیری درباره نحوه تنظیم بهینه هایپر پارامترهای مدل کمک می‌کند.



شکل ۱۵: منحنی یادگیری مدل جنگل تصادفی بر اساس دقت آموزش و اعتبارسنجی متقابل با هایپر پارامترهای پیش فرض

^{۳۹} Learning Curve^{۴۰} Underfitting



شکل ۱۶: منحنی یادگیری مدل جنگل تصادفی بر اساس دقت آموزش و اعتبارسنجی متقابل با هایپرپارامترهای اصلاح شده

با مقایسه منحنی‌های یادگیری مدل جنگل تصادفی پیش و پس از تنظیم هایپرپارامترها مطابق شکل‌های ۱۵ و ۱۶، مشخص شد که در حالت اولیه، مدل دچار بیش‌برازش بود، به گونه‌ای که دقت داده‌های آموزشی به‌طور قابل ملاحظه‌ای بالاتر از دقت اعتبارسنجی متقابل قرار داشت. با تنظیم هایپرپارامترها و اعمال محدودیت بر پیچیدگی مدل، فاصله بین این دو منحنی کاهش یافته و مقادیر هر دو دقت به یکدیگر نزدیک شد. این موضوع نشان‌دهنده بهبود قابلیت تعمیم مدل و کاهش بیش‌برازش است؛ به عبارتی، مدل پس از تنظیم نه‌تنها بر داده‌های آموزش، بلکه بر داده‌های جدید نیز عملکرد مطلوبی ارائه می‌دهد. همچنین مطابق جدول ۶، دقت مدل با استفاده از اعتبارسنجی متقابل ارزیابی شد. نتایج به دست آمده نشان داد که در این حالت، میانگین دقت مدل حدود ۰/۰۰۵ افزایش یافته است.

جدول ۶: مقایسه دقت مدل جنگل تصادفی با هایپرپارامترهای پیش فرض و بهینه‌شده در اعتبارسنجی متقابل پنج‌بخشی

نام مدل	بخش ۱	بخش ۲	بخش ۳	بخش ۴	بخش ۵	میانگین دقت
دقت با هایپرپارامترهای پیش فرض	۰/۸۷۸	۰/۹۳۲	۰/۹۱۹	۰/۸۹۲	۰/۹۳۲	۰/۹۱۱
دقت با هایپرپارامترهای اصلاح شده	۰/۸۵۱	۰/۹۰۵	۰/۹۰۹	۰/۹۱۹	۰/۹۴۵	۰/۹۱۶

طبق پژوهش‌های پیشین الگوریتم جنگل تصادفی یک دسته درونیاب است و عملکرد بالایی دارد. این بدان معنا می‌باشد که مدل روی داده‌های آموزش تقریباً بدون خطا برازش داده می‌شود. همچنین تأکید شده است که این درونیابی نباید با بیش‌برازش اشتباه گرفته شود حتی اگر درخت منفرد دچار بیش‌برازش شود. در این الگوریتم هر نمونه از داده‌ها در حدود ۳۷ درصد از درخت‌ها شرکت نمی‌کند. بنابراین میانگین‌گیری روی درخت‌ها تا حدی بیش‌برازش را حل می‌کند [۳۸، ۳۹].

۳-۳- بررسی آماری عملکرد مدل‌های پیشنهادی در طبقه‌بندی

در جدول ۷، برای مقایسه عملکرد مدل‌های مختلف، از آزمون آماری t استفاده شده است. آمار t بیانگر میزان اختلاف میان عملکرد دو مدل است. اگر مقدار t مثبت و بزرگ باشد، نشان‌دهنده آن است که مدل ردیف نسبت به مدل ستون عملکرد بهتری داشته است. در مقابل، مقدار t منفی بیانگر عملکرد ضعیف‌تر مدل ردیف نسبت به مدل ستون است. به‌طور کلی، هرچه قدر مطلق آمار t بزرگ‌تر باشد، اختلاف عملکرد میان دو مدل برجسته‌تر خواهد بود. مقدار p -value نمایانگر احتمال رخ دادن اختلاف مشاهده شده به‌طور تصادفی است. چنانچه مقدار p کمتر از 0.05 باشد (که در اغلب مطالعات معیار رایج معناداری آماری است)، می‌توان نتیجه گرفت که اختلاف عملکرد میان دو مدل از نظر آماری معنادار بوده و صرفاً ناشی از تصادف نیست. در غیر این صورت، تفاوت مشاهده شده فاقد معناداری آماری تلقی می‌شود.

جدول ۷: مقایسه آماری عملکرد مدل‌های یادگیری ماشین بر اساس آزمون t و مقدار p

	مدل یادگیری	جنگل تصادفی	KNN	ماشین بردار پشتیبان	تقویت طبقه‌بندی	تقویت گرادیان شدید
t	جنگل تصادفی	-	۳/۳۶۶	۴/۸۵۲	-۰/۶۷۱	۱/۵۰۰
	KNN	۰/۰۲۸	-	-۰/۳۴۵	-۴/۵۲۲	-۲/۳۴۸
	ماشین بردار پشتیبان	۰/۰۰۸	۰/۷۴۷	-	-۵/۵۸۸	-۲/۹۷۳
	تقویت طبقه‌بندی	۰/۵۳۹	۰/۰۱۱	۰/۰۰۵	-	۱/۰۵۷
	تقویت گرادیان شدید	۰/۲۰۸	۰/۰۷۹	۰/۰۴۱	۰/۳۵۰	-
	مقدار P					

بر اساس نتایج آزمون t جفتی و مقادیر p به‌دست‌آمده، می‌توان نتیجه‌گیری کرد که مدل جنگل تصادفی نسبت به مدل $t = 3.366, p = 0.028$ و ماشین بردار پشتیبان ($p = 0.008, t = 4.852$) به‌طور معناداری عملکرد بهتری داشته است، زیرا مقادیر p در این مقایسه‌ها کمتر از 0.05 بوده است. با این حال، اختلاف عملکرد جنگل تصادفی با مدل تقویت طبقه‌بندی ($p = 0.539, t = -0.671$) و همچنین با مدل تقویت گرادیان شدید ($p = 0.208, t = 1.500$) از نظر آماری معنادار نبوده و نمی‌توان یکی را برتر از دیگری دانست. همچنین، مدل تقویت طبقه‌بندی نسبت به مدل KNN ($p = 0.011, t = -4.522$) و ماشین بردار پشتیبان ($p = 0.005, t = -5.588$) به‌طور معناداری برتری داشته است. علاوه بر این، مدل تقویت گرادیان شدید نیز در مقایسه با ماشین بردار پشتیبان ($p = 0.041, t = -2.973$) عملکرد بهتری داشته است. در مجموع، می‌توان گفت مدل‌های جنگل تصادفی و تقویت طبقه‌بندی نسبت به مدل‌های KNN و SVC از نظر آماری عملکرد بهتری داشته‌اند، اما اختلاف بین مدل‌های جنگل تصادفی، تقویت طبقه‌بندی و تقویت گرادیان شدید معنادار نبوده است و عملکرد آن‌ها تقریباً مشابه می‌باشد.

۳-۴- ارزیابی عملکرد مدل یادگیری ماشین در طبقه‌بندی داده‌های جدید

با توجه به بررسی‌های انجام‌شده، الگوریتم‌های یادگیری گروهی مبتنی بر درخت تصمیم، بهترین عملکرد را در طبقه‌بندی زلزله‌های پالس‌گونه و غیر پالس‌گونه از خود نشان داده‌اند. در این میان، الگوریتم جنگل تصادفی به‌عنوان مدل نهایی و اصلی برای طبقه‌بندی انتخاب شد. در این تحلیل، مدل ابتدا با استفاده از ۲۹۶ نمونه داده آموزشی آموزش‌دیده و سپس بر روی ۷۳ نمونه داده آزمایشی مورد ارزیابی قرار گرفت. جهت بررسی توانایی تعمیم مدل به داده‌های جدید، ۶۰ رکورد زلزله از ایران که همگی از نوع زلزله‌های

حوزه نزدیک گسل با بیشترین شتاب ثبت شده در میان سایر رخدادها بودند، انتخاب و توسط مدل جنگل تصادفی طبقه بندی شدند. با توجه به فقدان یک معیار قطعی و جامع برای شناسایی ۱۰۰ درصدی زلزله های پالس گونه، در این پژوهش از معیار شاهی و بیکر (۲۰۱۴) به عنوان معیار مرجع استفاده شد. این معیار در پایگاه داده زلزله های حوزه اقیانوس آرام شرقی به عنوان یکی از ملاک های معتبر در طبقه بندی زلزله های پالس گونه شناخته می شود و در این مطالعه برای ارزیابی نتایج مدل یادگیری ماشین به کار گرفته شد. بر اساس نتایج مطابق جدول ۸، از میان ۶۰ رکورد تحلیل شده، معیار بیکر تنها ۸ مورد را به عنوان زلزله پالس گونه شناسایی کرد، در حالی که مدل یادگیری ماشین ۱۲ مورد را به این دسته اختصاص داد. به عنوان نمونه، زلزله های چای کندی (۲۰۱۲) و موسیان (۲۰۰۸) با وجود قرارگیری در مجاورت گسل و وجود پالس مشخص در ابتدای تاریخچه زمانی سرعت، توسط معیار بیکر در دسته پالس گونه قرار نگرفتند؛ اما مدل یادگیری ماشین این زلزله ها را به درستی به عنوان پالس گونه شناسایی کرده است.

جدول ۸: طبقه بندی زلزله های ایران با استفاده از مدل یادگیری ماشین (الگوریتم جنگل تصادفی)

مدل یادگیری ماشین برای طبقه بندی	معیار بیکر برای طبقه بندی	Vs30 (m/s)	MW	تاریخ وقوع	شاخص پالس بیکر	PGV (cm/s)	معیار پالس های دیررس	نام ایستگاه
غیر پالس گونه	غیر پالس گونه	۸۵۷	۴/۷	۲۰۰۰-۱۰-۱۳	-۲/۹۰	۲۰/۴۶	۷/۵۷	آقاجاری
غیر پالس گونه	غیر پالس گونه	۵۶۲	۵/۲	۱۹۹۹-۱۱-۲۶	-۳/۵۱	۱۸/۹۴	۱۱/۱۴	علی آباد
پالس گونه	پالس گونه	۴۹۹	۶/۵	۲۰۰۳-۱۲-۲۶	۲۵/۶۹	۱۱۱/۷۰	۰/۸۱	بم
پالس گونه	پالس گونه	۴۲۸	۵/۲	۲۰۰۶-۰۳-۳۰	۵/۸۴	۳۹/۶۶	۰/۲۷	چالان چولان
پالس گونه	پالس گونه	۴۲۸	۵/۹	۲۰۰۶-۰۳-۳۱	۱/۴۰	۵۴/۸۴	۸/۹۳	چالان چولان ۱
پالس گونه	غیر پالس گونه	-	۵/۵	۲۰۱۲-۰۸-۱۴	-۲/۵۹	۱۹/۰۰	۲۱/۱۵	چای کندی
غیر پالس گونه	غیر پالس گونه	۳۰۸	۵/۲	۱۹۹۸-۱۱-۱۳	-۹/۵۹	۱۸/۳۰	۶۴/۸۰	کنج
پالس گونه	غیر پالس گونه	۴۷۲	۵/۸	۲۰۰۸-۰۸-۲۷	-۰/۰۱	۲۷/۹۰	۱/۰۶	موسیان
پالس گونه	پالس گونه	-	۵/۳	۲۰۱۲-۱۱-۰۷	۴/۷۰	۴۵/۲۵	۱۱/۷۹	شیخ ملو
پالس گونه	غیر پالس گونه	-	۶/۲	۱۹۹۸-۰۳-۱۴	-۱۳/۵۹	۹۱/۵۱	۸/۹۵	سیرج
پالس گونه	پالس گونه	-	۵/۶	۲۰۲۱-۰۲-۱۷	۰/۰۳	۲۲/۷۲	۰/۹۳	سی سخت
پالس گونه	پالس گونه	-	۷/۸	۱۹۷۸-۰۹-۱۶	۲۲/۸۶	۱۲۹/۶۸	۴/۹۵	طیس
پالس گونه	غیر پالس گونه	۲۸۱	۶/۰	۲۰۱۸-۰۸-۲۵	-۱۳/۵۹	۳۴/۳۸	۲۴/۸۵	تازه آباد ۱
پالس گونه	پالس گونه	۷۷۸	۶/۰	۲۰۰۸-۰۹-۱۰	۵/۹۶	۵۰/۹۲	۰/۲۰	تمبان
پالس گونه	پالس گونه	۷۷۸	۵/۷	۲۰۰۶-۰۶-۲۸	۱/۵۱۵	۳۸/۵۱۸۱	۰/۳۲۷۷	تمبان ۱
غیر پالس گونه	غیر پالس گونه	۳۰۶	۵/۹	۲۰۱۰-۰۷-۳۰	۱/۷۰	۱۹/۴۲	۵/۶۴	ترت حیدریه

۴- نتیجه گیری

این پژوهش با هدف توسعه رویکردهای مبتنی بر یادگیری ماشین به منظور بهبود طبقه بندی خودکار زلزله های پالس گونه و غیر پالس گونه صورت گرفت. برای دستیابی به این هدف، مجموعه ای از ویژگی های ترکیبی طراحی شد که همزمان دربرگیرنده ی مشخصه های استخراج شده از مؤلفه ی پالس در تاریخچه زمانی سرعت (با استفاده از روش های جداسازی پالس)، و نیز ویژگی های وابسته به تاریخچه زمانی اصلی بدون نیاز به استخراج پالس است. در این فرآیند، تمرکز صرفاً بر تحلیل سیگنال های شتاب نگاری بود و از پارامترهای مربوط به ساختگاه محلی مانند بزرگای زمین لرزه یا فاصله گسل صرف نظر شد تا قابلیت تعمیم مدل به حوزه های لرزه ای مختلف افزایش یابد. پس از استخراج ویژگی ها، پنج الگوریتم یادگیری ماشین شامل جنگل تصادفی، تقویت گرادیان شدید، تقویت طبقه بندی، SVM و KNN برای ساخت مدل طبقه بندی دودویی به کار گرفته شدند. ارزیابی عملکرد مدل ها با استفاده از معیارهای آماری مختلف نشان داد که الگوریتم جنگل تصادفی نسبت به سایر مدل ها از دقت، پایداری و تعمیم پذیری بالاتری برخوردار است؛ از این رو، به عنوان مدل منتخب برای تحلیل نهایی در نظر گرفته شد. در ادامه، به منظور بررسی توانایی مدل در شناسایی صحیح

رکوردهای جدید، تعداد ۶۰ رکورد زلزله ثبت شده در ایران که دارای بیشترین مقادیر شتاب و سرعت در میان سایر رکوردها بودند، با استفاده از مدل جنگل تصادفی طبقه‌بندی شدند. همچنین جهت اعتبارسنجی نتایج مدل، از معیار شناخته شده بیکر و شاهی (۲۰۱۴) به عنوان مرجع مقایسه استفاده شد. نتایج حاصل، بیانگر توان بالای مدل یادگیری ماشین در شناسایی دقیق زلزله‌های پالس گونه، حتی در مواردی بود که توسط روش‌های سنتی از جمله معیار بیکر شناسایی نشده بودند. این امر گویای پتانسیل روش‌های داده محور در تقویت فرآیند شناسایی و تصمیم‌گیری در مطالعات لرزه‌ای است. از منظر هزینه‌ی محاسباتی، روش پیشنهادی در مقایسه با سایر رویکردها تفاوت قابل توجهی ندارد. اگرچه فرآیند استخراج پالس از تاریخچه زمانی سرعت و محاسبه‌ی ویژگی‌های وابسته به پالس و سیگنال اصلی می‌تواند زمان‌بر به نظر برسد، اما با توسعه کدهای اختصاصی در محیط نرم‌افزار MATLAB، تمامی مراحل پردازش و استخراج ویژگی‌ها به صورت خودکار و بدون دخالت کاربر قابل انجام است. بدین ترتیب، با دریافت شتاب‌نگاشت خام به عنوان ورودی، مجموعه ویژگی‌های مورد نیاز جهت آموزش و طبقه‌بندی در مدل یادگیری ماشین استخراج می‌شود. بنابراین، در عمل، روش پیشنهادی از نظر هزینه‌ی زمانی و محاسباتی، هم‌تراز با روش‌های متداولی است که صرفاً بر ویژگی‌های سیگنال اصلی تکیه دارند، اما در عین حال دقت و جامعیت بیشتری در شناسایی زلزله‌های پالس گونه فراهم می‌آورد.

۱- از میان ۱۸ ویژگی استخراج شده از تاریخچه زمانی سرعت زلزله‌ها، چهار ویژگی که شامل Variance pulse، PGV، Rms Pulse و Energy Ratio دارای بیشترین اهمیت و چهار ویژگی شامل D0_5، D5_75، D10_50، D10_60 دارای اهمیت متوسط برای طبقه‌بندی زلزله‌های متوسط بودند. با بررسی مقادیر شپ مشخص شد که افزایش مقادیر ویژگی‌های Energy Ratio، D10_60، D10_50، D5_75 و D0_5 تأثیر مثبت بر روی طبقه‌بندی زلزله‌های غیر پالس گونه و افزایش ویژگی‌های Variance pulse، Rms Pulse، PGV تأثیر مثبت بر روی طبقه‌بندی زلزله‌های پالس گونه می‌گذارد.

۲- تحلیل ماتریس درهم‌ریختگی نشان داد که مدل‌های جنگل تصادفی و تقویت طبقه‌بندی هیچ‌کدام از زلزله‌های غیر پالس گونه را به اشتباه پالس گونه تشخیص ندادند (۰ مورد اشتباه)، و تنها در ۴ مورد، زلزله‌های پالس گونه را شناسایی نکردند. مدل تقویت گرادیان شدید عملکرد بسیار نزدیکی داشت و فقط ۱ مورد زلزله غیر پالس گونه را اشتباه پالس گونه تشخیص داد و مانند مدل‌های قبلی در ۴ مورد زلزله پالس گونه را از قلم انداخت. در مقابل، مدل SVM، ۸ زلزله غیر پالس گونه را به اشتباه پالس گونه شناسایی کرد و ۳ زلزله پالس گونه را تشخیص نداد. ضعیف‌ترین عملکرد متعلق به KNN بود که ۵ زلزله غیر پالس گونه را اشتباه به عنوان پالس گونه و ۷ زلزله پالس گونه را تشخیص نداد. این نتایج نشان می‌دهد مدل‌های یادگیری گروهی مانند جنگل تصادفی، دقت بالاتری در جداسازی زلزله‌های پالس گونه از سایر زلزله‌ها دارند و در مقایسه با مدل‌های کلاسیک، خطاهای کمتری مرتکب می‌شوند.

۳- الگوریتم جنگل تصادفی با دقت ۰/۹۶۴ و امتیاز F1 برابر ۰/۹۴۰ در داده‌های آزمایشی، و دقت ۰/۹۹۷ در داده‌های آموزشی، نشان داد که مدل بسیار قدرتمندی در تشخیص زلزله‌های پالس گونه است. تقویت طبقه‌بندی نیز با دقت ۰/۹۴۶ و F1 برابر ۰/۹۴۰ روی داده‌های تست، و مقادیر تقریباً کامل در آموزش (دقت و صحت ۱/۰۰)، عملکردی مشابه جنگل تصادفی داشت. همچنین تقویت گرادیان شدید با دقت ۰/۹۳۲ و F1 برابر ۰/۹۲۶ در داده‌های آزمایشی، تنها اندکی پایین‌تر از دو مدل قبلی عمل کرد. در مقابل،

مدل SVM دقتی برابر با ۰/۸۵۱، صحت ۰/۸۰۰ و F1 حدود ۰/۸۵۴ روی داده‌های آزمایشی داشت که نسبت به مدل‌های تقویتی عملکرد ضعیف‌تری نشان داد. مدل KNN نیز پایین‌ترین عملکرد را ثبت کرد؛ به‌گونه‌ای که دقت آن برابر با ۰/۸۳۷ و F1 معادل ۰/۸۴۷ بود و در سایر معیارها نیز مقادیر پایین‌تری نسبت به سایر مدل‌ها داشت. این نتایج به‌روشنی مشخص ساخت که مدل‌های جنگل تصادفی و تقویتی، به‌ویژه با دقت بالای ۰/۹۴۰ و مقادیر قابل‌توجه در معیارهای دیگر، در طبقه‌بندی داده‌های لرزه‌ای پالس‌گونه بسیار کارآمدتر از روش‌های کلاسیکی مانند KNN و SVM عمل کرده‌اند.

۴- با ارزیابی اعتبار سنجی متقابل ۵ بخشی، مدل‌های جنگل تصادفی، تقویت طبقه‌بندی و تقویت گرادیان شدید به ترتیب با میانگین دقت‌های ۰/۹۱۱، ۰/۹۱۶ و ۰/۹۰۳ بهترین عملکرد را در بین مدل‌ها ارائه دادند. در مقابل، KNN و ماشین بردار پشتیبان با دقت‌های ۰/۸۴۸ و ۰/۸۵۴ عملکرد ضعیف‌تری داشتند. بررسی انحراف معیار نیز نشان داد که مدل تقویت طبقه‌بندی پایدارترین عملکرد را در دقت (انحراف معیار ۰/۰۱۷۴) داشته و مدل جنگل تصادفی در معیار F1 با انحراف معیار ۰/۰۲۵۷ کمترین نوسان را نشان داده است.

۵- با توجه به اینکه اختلاف معنادار در معیارهای ارزیابی، خصوصاً در معیار دقت و امتیاز F1 بین مجموعه آزمایشی و آموزشی در مدل‌های یادگیری جنگل، تقویت طبقه‌بندی و تقویت گرادیان شدید مشاهده شد. برای ارزیابی دقیق عملکرد مدل‌ها از روش اعتبارسنجی متقابل استفاده شد. نتایج نشان داد که مدل‌های یادگیری گروهی، به‌ویژه جنگل تصادفی (دقت ۰/۹۱۱)، تقویت طبقه‌بندی (۰/۹۱۶) و تقویت گرادیان شدید (۰/۹۰۳)، عملکرد بهتری نسبت به مدل‌های KNN (۰/۸۴۸) و SVM (۰/۸۵۴) دارند. همچنین، مدل‌هایی با انحراف معیار کمتر در معیارهای دقت و F1، از جمله جنگل تصادفی و تقویت طبقه‌بندی، ثبات و پایداری بیشتری در پیش‌بینی از خود نشان دادند. همچنین به تنظیم هایپر پارامترهای الگوریتم جنگل تصادفی به‌عنوان مدل منتخب و اعمال محدودیت بر پیچیدگی مدل اختلاف دقت و امتیاز F1 در مجموعه آموزشی و آزمایشی کاهش یافته و بیش‌براز کم شد.

۶- برای ارزیابی و انتخاب بهترین مدل طبقه‌بندی نتایج آزمون آماری t تأیید می‌کند که مدل جنگل تصادفی به‌طور معناداری بهتر از KNN ($t = 3.366, p = 0.028$) و SVM ($t = 4.852, p = 0.008$) عمل کرده است. همچنین، مدل تقویت طبقه‌بندی نیز نسبت به KNN ($p = 0.011$) و SVM ($p = 0.005$) عملکرد برتری داشته است. در مقابل، اختلاف عملکرد میان مدل‌های جنگل تصادفی، تقویت طبقه‌بندی و تقویت گرادیان شدید از نظر آماری معنادار نبود ($p > 0.05$)، که نشان‌دهنده عملکرد تقریباً مشابه این مدل‌های تقویتی است. این تحلیل آماری برتری کلی مدل‌های یادگیری گروهی بر پایه درخت را نسبت به روش‌های کلاسیک تأیید کرد.

۴- منابع

1. Wani, F.M., et al., *Investigating the efficiency of machine learning algorithms in classifying pulse-like ground motions*. Journal of Seismology, 2023. **27**(5): p. 875-899.
2. Yazdani, A., et al., *Near-field probabilistic seismic hazard analysis of metropolitan Tehran using region-specific directivity models*. Pure and Applied Geophysics, 2017. **174**: p. 117-132.
3. Kohrangi, M., D. Vamvatsikos, and P. Bazzurro, *Pulse-like versus non-pulse-like ground motion records: spectral shape comparisons and record selection strategies*. Earthquake Engineering & Structural Dynamics, 2019. **48**(1): p. 46-64.
4. Fayjaloun, R., et al., *Spatial variability of the directivity pulse periods observed during an earthquake*. Bulletin of the Seismological Society of America, 2017. **107**(1): p. 308-318.
5. Scala, A., G. Festa, and S. Del Gaudio, *Relation between near-fault ground motion impulsive signals and source parameters*. Journal of Geophysical Research: Solid Earth, 2018. **123**(9): p. 7707-7721.
6. Hayden, C.P., J.D. Bray, and N.A. Abrahamson, *Selection of near-fault pulse motions*. Journal of Geotechnical and Geoenvironmental Engineering, 2014. **140**(7): p. 04014030.
7. Qifang, L., Y. Yifan, and J. Xing, *Basic characteristics of near-fault ground motion*. EARTHQUAKE ENGINEERING AND ENGINEERING VIBRATION-CHINESE EDITION-, 2006. **26**(1): p. 1.
8. Somerville, P.G., et al., *Modification of empirical strong ground motion attenuation relations to include the amplitude and duration effects of rupture directivity*. Seismological research letters, 1997. **68**(1): p. 199-222.
9. Liu, Z., X. Li, and Z. Zhang, *Quantitative identification of near-fault ground motions based on ensemble empirical mode decomposition*. KSCE Journal of Civil Engineering, 2020. **24**(3): p. 922-930.
10. Luo, Q., et al., *Seismic performance assessment of velocity pulse-like ground motions under near-field earthquakes*. Rock Mechanics and Rock Engineering, 2021. **54**(8): p. 3799-3816.
11. Erdik, M., et al. *Near-fault earthquake ground motion and seismic isolation design*. in *World Conference on Seismic Isolation*. 2022. Springer.
12. Quaranta, G., G. Angelucci, and F. Mollaioli, *Near-fault earthquakes with pulse-like horizontal and vertical seismic ground motion components: Analysis and effects on elastomeric bearings*. Soil Dynamics and Earthquake Engineering, 2022. **160**: p. 107361.
13. Aoi, S., T. Kunugi, and H. Fujiwara, *Trampoline effect in extreme ground motion*. Science, 2008. **322**(5902): p. 727-730.
14. Peng, Y. and R. Han, *A comprehensive categorization method for identifying near-fault pulse-like ground motions*. Earthquake Engineering & Structural Dynamics, 2024. **53**(14): p. 4404-4431.
15. Shahi, S.K. and J.W. Baker, *An efficient algorithm to identify strong-velocity pulses in multicomponent ground motions*. Bulletin of the Seismological Society of America, 2014. **104**(5): p. 2456-2466.
16. Yaghmaei-Sabegh, S., *Detection of pulse-like ground motions based on continuous wavelet transform*. Journal of seismology, 2010. **14**: p. 715-726.
17. Peng, Y., et al., *Stochastic simulation of velocity pulses of near-fault ground motions based on multivariate copula modeling*. Probabilistic Engineering Mechanics, 2023. **72**: p. 103434.
18. Zhao, D., et al. *Quantitative classification of near-fault ground motions selected by energy indicators*. in *Structures*. 2022. Elsevier.
19. Chang, Z., F. De Luca, and K. Goda, *Automated classification of near-fault acceleration pulses using wavelet packets*. Computer-Aided Civil and Infrastructure Engineering, 2019. **34**(7): p. 569-585.
20. Ghaffarzadeh, H., *A classification method for pulse-like ground motions based on S-transform*. Natural Hazards, 2016. **84**: p. 335-350.
21. Liu, Z., *Quantitative Identification of Pulse-Like Ground Motions Based on Hilbert–Huang Transform*. Shock and Vibration, 2021. **2021**(1): p. 9915362.
22. Chen, X., D. Wang, and R. Zhang, *Identification of pulse periods in near-fault ground motions using the HHT method*. Bulletin of the Seismological Society of America, 2019. **109**(6): p. 2384-2398.
23. Panella, D.S., M.E. Tornello, and C.D. Frau, *A simple and intuitive procedure to identify pulse-like ground motions*. Soil Dynamics and Earthquake Engineering, 2017. **94**: p. 234-243.

24. Zhao, G., et al., *An easy-to-update pulse-like ground motion identification method based on Siamese convolutional neural networks*. Journal of Earthquake Engineering, 2024. **28**(1): p. 1-19.
25. Kardoutsou, V., I. Taflampas, and I. Psycharis. *A new method for the classification of ground motions as pulse-like or non pulse-like*. in *Proceedings of 2nd European conference on earthquake engineering and seismology, Istanbul, Turkey*. 2014.
26. Wang, Y., *PCA-LSTM: An Impulsive Ground-Shaking Identification Method Based on Combined Deep Learning*. CMES-Computer Modeling in Engineering & Sciences, 2024. **139**(3).
27. Alloghani, M., et al., *A systematic review on supervised and unsupervised machine learning algorithms for data science*. Supervised and unsupervised learning for data science, 2020: p. 3-21.
28. Mahesh, B., *Machine learning algorithms-a review*. International Journal of Science and Research (IJSR).[Internet], 2020. **9**(1): p. 381-386.
29. Habib, A., I. Youssefi, and M.M. Kunt, *Identification of pulse-like ground motions using artificial neural network*. Earthquake Engineering and Engineering Vibration, 2022. **21**(4): p. 899-912.
30. Baker, J.W., *Quantitative classification of near-fault ground motions using wavelet analysis*. Bulletin of the seismological society of America, 2007. **97**(5): p. 1486-1501.
31. Baker, J.W., *Identification of near-fault velocity pulses and prediction of resulting response spectra*, in *Geotechnical earthquake engineering and soil dynamics IV*. 2008. p. 1-10.
32. Zhai, C., et al., *Quantitative identification of near-fault pulse-like ground motions based on energy*. Bulletin of the Seismological Society of America, 2013. **103**(5): p. 2591-2603.
33. De Roeck, G., et al., *Application of wavelet transform for identification of pulse-like ground motions effects on response spectra*.
34. Pearson, K., *Notes on the history of correlation*. Biometrika, 1920. **13**(1): p. 25-45.
35. Asgarkhani, N., et al., *Seismic response and performance prediction of steel buckling-restrained braced frames using machine-learning methods*. Engineering Applications of Artificial Intelligence, 2024. **128**: p. 107388.
36. Angelucci, G., et al., *Interpretable machine learning models for displacement demand prediction in reinforced concrete buildings under pulse-like earthquakes*. Journal of Building Engineering, 2024. **95**: p. 110124.
37. Mosca, E., et al. *SHAP-based explanation methods: a review for NLP interpretability*. in *Proceedings of the 29th international conference on computational linguistics*. 2022.
38. Barreñada, L., et al., *Understanding overfitting in random forest for probability estimation: a visualization and simulation study*. Diagnostic and Prognostic Research, 2024. **8**(1): p. 14.
39. Wyner, A.J., et al., *Explaining the success of adaboost and random forests as interpolating classifiers*. Journal of Machine Learning Research, 2017. **18**(48): p. 1-33.