

پیش‌بینی پارامترهای بهینه میراگر جرمی مایع تنظیم‌شده با استفاده از مدل‌های دسته‌بندی یادگیری ماشین

حسین غفارزاده*^۱، علیرضا آران^۲ و علیرضا بینوایان^۳

^۱ استاد، دانشکده مهندسی عمران، دانشگاه تبریز

^۲ دانشجوی مقطع دکتری رشته مهندسی عمران گرایش زلزله، دانشکده مهندسی عمران، دانشگاه تبریز

^۳ دانشجوی مقطع دکتری رشته مهندسی عمران گرایش سازه، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر تهران

ghaffar@tabrizu.ac.ir

چکیده

در این پژوهش، یک چارچوب یکپارچه مبتنی بر مدل‌سازی دینامیکی، بهینه‌سازی عددی و یادگیری ماشین برای پیش‌بینی پارامترهای بهینه میراگر جرمی مایع تنظیم‌شونده (Tuned Liquid Mass Damper – TLMD) ارائه می‌شود. دو پارامتر کلیدی طراحی شامل نسبت فرکانسی بهینه و نسبت میرایی بهینه، با استفاده از شش الگوریتم یادگیری ماشین شامل رگرسیون لجستیک (Logistic Regression)، درخت تصمیم (Decision Tree)، جنگل تصادفی (Random Forest)، الگوریتم k نزدیک‌ترین همسایه (k-Nearest Neighbors)، ماشین بردار پشتیبان (Support Vector Machine) و بیز ساده (Naive Bayes) مورد بررسی قرار گرفته‌اند. این مطالعه برای دو سازه برشی یک طبقه و پنج طبقه مجهز به TLMD نصب‌شده بر روی بالشتک‌های الاستومری انجام شده است. پاسخ دینامیکی سازه‌ها تحت اثر شش رکورد زلزله با استفاده از تحلیل تاریخچه زمانی شبیه‌سازی شده و رفتار نوسانی مایع درون مخزن بر اساس مدل هازنر مدل‌سازی گردیده است. پارامترهای بهینه سیستم با استفاده از الگوریتم جستجوی الگو (Pattern Search) استخراج شده و پس از تقسیم‌بندی داده‌ها به سه کلاس عملکردی، به‌عنوان ورودی مدل‌های یادگیری ماشین به کار رفته‌اند. نتایج نشان می‌دهد که در پیش‌بینی نسبت فرکانسی بهینه، الگوریتم‌های k نزدیک‌ترین همسایه و جنگل تصادفی برای سازه یک طبقه بهترین عملکرد را با F1-score حدود ۷۳٪ ارائه می‌دهند، در حالی که در سازه پنج طبقه، به‌دلیل افزایش پیچیدگی رفتاری، الگوریتم بیز ساده با F1-score حدود ۶۸٪ عملکرد مناسب‌تری دارد. همچنین، بیز ساده در پیش‌بینی نسبت میرایی بهینه برای هر دو سازه عملکردی پایدار نشان داده و در سازه پنج طبقه دقتی در حدود ۸۴٪ به‌دست آمده است که کارایی چارچوب پیشنهادی را تأیید می‌کند.

کلمات کلیدی

میراگر جرمی مایع تنظیم‌شده، الگوریتم‌های یادگیری ماشین، پیش‌بینی، دسته‌بندی، بهینه‌سازی

مهار ارتعاشات در سازه‌ها به‌ویژه در برابر زلزله و باد، چالشی مهم در مهندسی سازه است. میراگرهای جرمی تنظیم‌شده^۱ (TMDs)، به عنوان راهکاری پرکاربرد، با ایجاد ارتعاشات غیرهم‌فاز انرژی خارجی را مستهلک می‌کنند. با این حال، مطالعاتی نظیر تحقیق گرکو^۲ و مورگا^۳ (۲۰۱۹) نشان دادند که حساسیت این میراگرها نسبت به تغییرات پارامترهای سازه و زلزله زیاد است [۱]. میراگرهای مایع تنظیم‌شده^۴ (TLDS) به عنوان جایگزینی جذاب، با هدف بهره‌گیری از خواص سیال و کاهش نسبت جرمی در مقایسه با میراگرهای TMD مطرح شدند. همچنین در شرایطی که فضای کافی برای نصب TMD وجود ندارد، میراگرهای TLD راه‌حل ایده‌آل هستند. تحقیقات مودی^۵ و ولت^۶ (۱۹۸۸) و تامورا^۷ و همکاران (۱۹۹۵) نشان دادند که میراگرهای TLD برای سازه‌های نرم با دوره‌های تناوب طولانی که در معرض ارتعاشات باد قرار دارند، بسیار مؤثر هستند [۲، ۳]. عملکرد میراگرهای TLD در کاهش ارتعاش سازه‌های بلند تحت تحریک زلزله نیز به طور گسترده مورد مطالعه قرار گرفته است [۴]. میراگرهای مایع تنظیم‌شده با فرکانس بالا^۸ (HF-TLD) برای سازه‌های با فرکانس بالا معرفی شدند. نتایج تجربی تحت بارگذاری لرزه‌ای نشان داد که در صورت استفاده از ۵٪ جرم سازه برای میراگر، پاسخ بیشینه جابه‌جایی سازه با فرکانس ۳ هرتز می‌تواند بطور متوسط ۲۰٪ کاهش پیدا کند [۵].

به منظور دستیابی به عملکرد بهینه میراگرهای TLD، تنظیم دقیق فرکانس امواج مایع متناسب با فرکانس سازه که به طول مخزن در جهت ارتعاش وابسته است، از اهمیت بسزایی برخوردار است. نسبت عمق (نسبت عمق مایع به طول مخزن) نیز به عنوان پارامتری کلیدی در طراحی این میراگرها نقش مؤثری ایفا می‌کند. از این رو، هندسه مخزن تأثیر قابل‌توجهی بر فرکانس ارتعاش مایع و عملکرد کلی میراگر دارد. لاو^۹ و تیات^{۱۰} (۲۰۱۳) تأثیر زاویه چرخش مخزن میراگرهای TLD را بررسی کردند [۶]. همچنین تیات و دنگ^{۱۱} (۲۰۱۰) با بررسی اشکال مختلف مخزن، به میرایی مؤثر مخازن دایره‌ای نسبت به مستطیلی پی بردند [۷]. در راستای یافتن پیکربندی‌های بهینه، بررسی مخازن آب نصب‌شده بر بام ساختمان‌ها منجر به شناسایی اشکالی از مخزن شده است که در آن‌ها فرکانس ارتعاش مایع تا حدودی مستقل از عمق آب است [۸].

یو^{۱۲} و همکاران (۱۹۹۹) با در نظر گرفتن رفتار غیرخطی امواج، یک میراگر جرمی تنظیم‌شده با رفتار غیرخطی معادل را جایگزین TLD کردند [۹]. در این پژوهش، معادل‌سازی رفتار غیرخطی با فرض سختی و میرایی غیرخطی و از طریق تطبیق انرژی در سیستم مجهز به TMD و TLD انجام شد. به منظور لحاظ نمودن سهم مودهای بالاتر در ارتعاش سازه، استفاده از میراگرهای TLD چندگانه نیز پیشنهاد شده است [۱۰]. در راستای بهبود کارایی امواج مایع در میراگرهای TLD، رویکردهای گوناگون مانند استفاده از TMD در داخل مخزن TLD معرفی شده است [۱۱، ۱۲]. همچنین بررسی ترکیبی از میراگرهای تنظیم‌شده که در آن TMD و TLD به صورت سری به یکدیگر متصل شده‌اند، مورد توجه پژوهشگران قرار گرفته است [۱۳، ۱۴].

عملکرد میراگر TLD به منظور کاهش ارتعاشات سازه‌ها با دوره تناوب کوتاه توسط بانرجی^{۱۳} و همکاران (۲۰۰۰) مورد بررسی قرار گرفت [۴]. کارایی این میراگر در چنین شرایطی به دلیل عدم تنظیم صحیح و تأخیر در شکست موج‌های سطحی با مشکلاتی روبرو می‌گردد. برای رفع این نقص، گوش^{۱۴} و باسو^{۱۵} (۲۰۰۴) پیشنهاد کردند که از میراگر ستون مایع تنظیم‌شده^{۱۶} (TLCD) استفاده شود [۱۵]. [۱۵] در این سیستم، به جای یک مخزن، از لوله‌ها و ستون‌های مایع استفاده می‌شود که از طریق مکانیزم‌هایی نظیر فنر، به سازه متصل می‌شوند. مشابه مخازن، شکل لوله‌ها در این میراگرها بر کاهش پاسخ سازه مؤثر هستند. آیدمیر^{۱۷} و همکاران (۲۰۲۴) نشان دادند که استفاده از زاویه ۴۵ درجه در محل اتصال لوله‌های افقی و عمودی می‌تواند تا ۲۵٪ بر کاهش پاسخ‌های سازه تأثیر داشته باشد [۱۶]. مین^{۱۸} و پارک^{۱۹} (۲۰۰۹) با بررسی عددی و آزمایشگاهی این میراگرها نشان دادند که پارامترهای بهینه میراگر به نسبت طول افقی و

11 Deng

12 Yu

13 Banerji

14 Ghosh

15 Basu

16 Tuned liquid column damper

17 Aydemir

18 Min

19 Park

1 Tuned mass dampers

2 Greco

3 Morga

4 Tuned liquid dampers

5 Modi

6 Welt

77 Tamura

8 High-frequency tuned liquid damper

9 Love

10 Tiat

عمودی ستون مایع بستگی دارد [۱۷]. کارایی این میراگرها بصورت سنتی فقط در یک جهت ارتعاش است، اما ارتعاشاتی مانند زلزله در جهات مختلف بر سازه وارد می‌شود. بنابراین جهت رفع این مشکل، میراگرهای ستون مایع تنظیم‌شده حلقوی^۱ (TTLCD) معرفی شدند [۱۸].

تحقیقات نشان‌دهنده این نکته است که میراگرهای TLD در شرایطی که شتاب پایه افزایش می‌یابد، کارایی بیشتری دارند. بر همین اساس، پیکربندی میراگر مایع جرمی ترکیبی^۲ (HMLD) پیشنهاد شده است که در آن میراگر TLD به صورت ثابت بر روی میراگر TMD نصب می‌شود [۱۹]. یکی از الزامات اساسی در طراحی میراگرهای TLD این است که نسبت عمق مخزن به بُعد آن باید کمتر از ۰/۳ باشد [۲۰]. با این حال، برای تنظیم بهینه این میراگرها در سازه‌هایی با دوره تناوب کوتاه، طول مخزن به مقادیر غیرعملی می‌رسد. به‌طور خاص، برای سازه‌ای با دوره تناوب اصلی ۰/۵ ثانیه و نسبت عمق مخزن برابر با ۰/۳، طول بهینه مورد نیاز برای مخزن ۱۴۴ میلی متر محاسبه می‌شود که تحقق آن غیرممکن است [۲۱، ۲۲]. بنابراین در این شرایط جرم مؤثر در حرکت امواج مایع و شکست امواج کاهش می‌یابد و کارایی میراگر مختل می‌شود.

مخازن ذخیره آب که معمولاً بر فراز سازه‌ها نصب می‌گردند، به دلیل عمق بالای سیال و عدم انطباق با الزامات هندسی میراگرهای TLD، قابلیت مدل‌سازی به عنوان این نوع میراگرها را ندارند. به منظور غلبه بر این محدودیت، مدل هازنر^۳ به عنوان یک رویکرد ساده و کارآمد برای تحلیل رفتار دینامیکی این مخازن عمیق پیشنهاد شده است. تحلیل‌های ارائه شده توسط هازنر [۲۱]، ویژگی‌های ارتعاشی سیال درون این مخازن را به دقت توصیف نموده و نتایج تجربی نیز صحت این مدل را تأیید نموده‌اند [۲۳]. در چارچوب مدل هازنر، رفتار ارتعاشی توده سیال درون مخزن به صورت یک سیستم شامل دو جرم مجزا، یعنی جرم سخت^۴ و جرم موج^۵، در نظر گرفته می‌شود که به صورت سری به سازه متصل شده‌اند. این مدل، با فرض رفتار خطی برای دینامیک امواج سطحی و شکست آن‌ها زمانی معتبر خواهد بود که حدود ۲۰ درصد از کل حجم سیال در فرآیند ارتعاش مشارکت داشته باشند. بنابراین، استفاده از این مدل برای مخازن عمیق با نسبت عمق بیش از ۰/۳ توجیه‌پذیر است. با توجه به استفاده گسترده از بتن در ساخت این مخازن، فرض صلب بودن دیواره‌ها که یکی از ارکان مدل هازنر است، برای اغلب این سازه‌ها قابل قبول است. لازم به ذکر است که مدل‌های تحلیلی برای مخازن با دیواره‌های انعطاف‌پذیر نیز توسط هاشمی و همکاران مورد بررسی قرار گرفته است [۲۴].

پاندی^۶ و همکاران (۲۰۲۲) با بهره‌گیری از مدل هازنر، به ارزیابی کارایی میراگر جرمی مایع تنظیم‌شده^۷ (TLMD) در مخازن عمیق پرداخته و عملکرد آن را در مقایسه با میراگر TMD مورد سنجش قرار دادند [۲۲]. پارامترهای بهینه و ویژگی‌های کنترلی این دسته از میراگرها بر مبنای معیارهای مرتبط با انحراف فاز^۸ تعیین گردیده است [۲۵]. در سیستم TLMD، به واسطه بهره‌گیری از رفتار دوگانه سیال درون مخزن، نیازی به استفاده از جرم تنظیم‌شده اضافی وجود ندارد. در واقع، جرم سخت سیال به همراه جرم مخزن، نقش TMD را ایفا می‌کنند، درحالی‌که جرم موج سیال، عملکردی مشابه میراگر TLD دارد. این هم‌افزایی باعث می‌شود که میراگر TLMD ضمن بهره‌مندی از مزایای هر دو نوع میراگر TMD و TLD، معایب مربوط به آن‌ها را نیز به نحو مؤثری کاهش دهد. میراگرهای TLMD در کاهش پاسخ سازه‌های با فرکانس پایین تحت ارتعاش قائم مؤثر واقع شده و بصورت آزمایشگاهی و عملی ارزیابی شده‌اند [۲۶]. این میراگرها در سازه‌ها با پلان نامنظم و منظم مورد ارزیابی قرار گرفته‌اند و نتایج نشان دادند که با افزایش تعداد میراگرها، برش پایه افزایش ولی جابه‌جایی سازه کاهش می‌یابد [۲۷]. همچنین در سازه‌های دارای پلان نامنظم، تأثیر میراگر TLMD بر کاهش پاسخ‌های جهت محور ضعیف پلان بیشتر است [۲۸].

به منظور دستیابی به حداکثر کارایی میراگرهای مایع، بهینه‌سازی پارامترهای میراگرها مورد توجه قرار گرفته است. این بهینه‌سازی شامل تنظیم دقیق نسبت جرمی، نسبت فرکانسی، عمق مایع و ضرایب میرایی است. غفارزاده و همکاران (۲۰۲۴) پارامترهای نسبت فرکانسی و نسبت میرایی استخر آب را که به صورت یک میراگر TLMD مدل‌سازی شده است، بدست آوردند [۲۹]. با آنالیز اثر اندرکنش بین میراگر TLMD و سازه اصلی، فرمول انحراف فاز بین سرعت نسبی میراگر و جابه‌جایی سازه اولیه به‌دست آمده است. همچنین نتایج

6 Pandey
7 Tuned liquid mass damper
8 Phase deviation

1 Toroidal tuned liquid column damper
2 Hybrid mass liquid damper
3 Housner model
4 Impulsive mass
5 Convective mass

نشان داده‌اند که نسبت فرکانسی و نسبت عمق مایع بر اندازه و محل بیشینه پیک^۱ تشدید و نسبت جرم و میرایی بر عرض باند فرکانس تأثیر دارند [۲۵]. بهینه‌سازی پارامترهای میراگر TLD به کمک الگوریتم جایا^۲، الگوریتم گرده‌افشانی گل^۳ (FPA)، الگوریتم جستجوی هارمونی^۴ (HS) و الگوریتم بهینه‌سازی مبتنی بر آموزش یادگیری^۵ (TLBO) انجام شده است. نتایج حاصل نشان داده‌اند که از میان الگوریتم‌های مذکور، الگوریتم جایا نتایج بهتری در کاهش پاسخ‌های سازه ارائه کرده است [۳۰]. به منظور بهبود عملکرد الگوریتم جستجوی هارمونی، الگوریتم جستجوی هارمونی تطبیقی^۶ (AHS) برای بهینه‌سازی پارامترهای میراگرهای مایع استفاده شد. نتایج نشان دادند که عملکرد الگوریتم AHS در مقایسه با الگوریتم HS، انحراف معیار کمتری بدست می‌دهد و با افزایش جرم سازه، بهینه‌سازی چگالی مایع بکار رفته در میراگر نقش مهمتری پیدا می‌کند [۳۱، ۳۲].

مطالعات اخیر نقش پررنگ الگوریتم‌های یادگیری ماشین^۷ در مدل‌سازی و بهینه‌سازی سامانه‌های کنترل ارتعاش را نشان داده‌اند. در پژوهشی، پیش‌بینی پاسخ جابه‌جایی یک مخزن آب مرتفع فولادی تحت زلزله با استفاده از مدل عددی اندرکنش سیال-سازه و آموزش دو الگوریتم شبکه عصبی مصنوعی (ANN)^۸ و اسپلاین‌های رگرسیون تطبیقی چندمتغیره^۹ (MARS) انجام شد که مدل ANN دقت بالاتری داشت [۳۳]. همچنین، چارچوبی ترکیبی از ناظر فازی تاکاگی-سوگنو^{۱۰} (TS) و ماشین بردار پشتیبان^{۱۱} (SVM) برای تشخیص خطا در میراگرهای مغناطیسی توسعه یافت که نرخ پیش‌بینی و شناسایی صحیح بسیار بالایی ارائه کرد [۳۴]. در رویکردی دیگر، الگوریتم‌های کلاسه‌بندی^{۱۲} مانند بیز ساده^{۱۳} و ماشین بردار پشتیبان برای پیش‌بینی نیاز به میرایی و تعیین پارامترهای بهینه TMD به‌کار گرفته شدند و کارایی بالایی در تفکیک سطوح مختلف میرایی تحت تحریک لرزه‌ای از خود نشان دادند [۳۵].

در این پژوهش، رفتار دینامیکی سازه‌های یک طبقه و پنج طبقه مجهز به میراگر جرمی مایع تنظیم‌شده که بر روی بالشتک‌های الاستومری در پشت‌بام نصب شده‌اند، با استفاده از تحلیل تاریخچه زمانی مورد بررسی قرار گرفته است. ارتعاش مایع درون میراگر براساس مدل هازنر شبیه‌سازی شده و پارامترهای بهینه بالشتک‌های الاستومری برای شرایط مختلف هندسی و ارتفاع مایع با استفاده از الگوریتم جستجوی الگو استخراج شده است. با توجه به تعدد و تنوع حالت‌های هندسی و عملکردی ممکن برای مخازن بامی که تحلیل عددی دقیق آن‌ها بسیار زمان‌بر و محاسباتی سنگین است، این مطالعه رویکردی نوین را در پیش گرفته است. نوآوری اصلی این پژوهش در بهره‌گیری هم‌زمان از مدل‌سازی دینامیکی، بهینه‌سازی عددی و الگوریتم‌های یادگیری ماشین برای پیش‌بینی پارامترهای کلیدی طراحی میراگرهای TLMD نهفته است. این رویکرد داده‌محور با هدف کاهش زمان طراحی، تسهیل فرآیند تصمیم‌گیری و حفظ دقت عملکرد پیشنهاد شده و به‌ویژه برای شرایطی که انجام تحلیل‌های سنتی به‌دلیل پیچیدگی مدل و تنوع ورودی‌ها عملی نیست، بسیار کارآمد است. چارچوب ارائه‌شده، گامی مؤثر در جهت توسعه ابزارهای هوشمند طراحی و تحلیل سازه‌های محسوب می‌شود و می‌تواند به شکل قابل توجهی هزینه‌های محاسباتی را کاهش داده و قابلیت اطمینان مدل‌های پیش‌بینی را افزایش دهد.

۲- روش انجام کار

در این قسمت، با توجه به بهره‌گیری از مخزن پشت‌بام و سازه برشی، معادلات حرکت سیستم تنظیم می‌شوند. سپس فرایند بهینه‌سازی و پیش‌بینی پارامترهای بهینه بالشتک‌های الاستومری شرح داده می‌شود.

8 Artificial Neural Network
9 Multivariate Adaptive Regression Splines
10 Takagi-Sugeno Fuzzy Observer
11 Support Vector Machine
12 Classification
13 Naive Bayes

1 Peak
2 Jaya algorithm
3 Flower pollination algorithm
4 Harmony search
5 Teaching-learning-based optimization
6 Adaptive harmony search algorithms
7 Machine Learning Algorithms

۲-۱- معادله حرکت سازه مجهز به مخزن پشت‌بام

در ساخت مدل‌های مخزنی به عنوان میراگر جرمی مایع تنظیم‌شده، فرض بر این است که این مخازن و مایعات موجود درون آن‌ها از سه جزء اصلی تشکیل شده‌اند: جرم بدنه مخزن، جرم سخت مایع و جرم موج مایع. به منظور ایجاد یک سازگاری بهینه میان جرم مایع سخت و بدنه مخزن، استفاده از بالشتک‌های الاستومری به عنوان راهکاری مؤثر برای بهبود عملکرد میراگرهای جرمی مایع تنظیم‌شده، پیشنهاد می‌شود. این در حالی است که روش متداول اتصال مستقیم مخزن به سازه ممکن است نتایج مطلوبی به همراه نداشته باشد [۳۶].

معادله حرکت سازه مجهز به مخزن به صورت زیر است:

$$M\ddot{u}(t) + C\dot{u}(t) + Ku(t) = -M\delta\ddot{u}_g(t) \quad (1)$$

که در آن ماتریس‌های $[M]$ ، $[K]$ و $[C]$ ماتریس‌های جرم، سختی و میرایی سازه هستند و در ادامه تعریف می‌شوند. جابه‌جایی و مشتقات آن یعنی سرعت و شتاب مطابق بردار $\{u\} = \{u_c \quad u_b \quad u_s\}^T$ در نظر گرفته می‌شوند که در آن، u_s بردار مربوط به سازه است. $\delta = \{0 \quad 0 \quad 1\}^T$ بردار تأثیر زلزله می‌باشد که نحوه اعمال تحریک وارد بر سازه را معین می‌سازد و \ddot{u}_g بیانگر شتاب زلزله است.

$$M = \begin{bmatrix} m_c & m_c & m_c \\ m_c & m_b & m_b \\ m_c & m_b & m_s + m_b \end{bmatrix} \quad (2)$$

$$K = \begin{bmatrix} k_c & 0 & 0 \\ 0 & k_b & 0 \\ 0 & 0 & k_s \end{bmatrix} \quad (3)$$

$$C = \begin{bmatrix} c_c & 0 & 0 \\ 0 & c_b & 0 \\ 0 & 0 & c_s \end{bmatrix} \quad (4)$$

C_b و K_b میرایی معادل ویسکوز و سختی بالشتک‌های الاستومری هستند. m_b برابر با مجموع جرم بدنه مخزن (m_0)، جرم سخت (m_i) و جرم موج (m_c) مایع در نظر گرفته می‌شود. در نتیجه، برای C_b و m_b می‌توان نوشت:

$$m_b = m_0 + m_i + m_c \quad (5)$$

$$c_b = 2\xi_b m_b \sqrt{\frac{k_b}{m_b}} \quad (6)$$

برای مدل‌سازی دینامیکی دقیق اثرات اندرکنش مایع و سازه، جرم مایع درون مخزن به دو مؤلفه جرم سخت (m_i) و جرم موج (m_c) تفکیک می‌شود. این دو مؤلفه با استفاده از روابط زیر و بر مبنای جرم کل مایع (m_l) محاسبه می‌گردند:

$$m_i = \alpha_i m_l \quad (7)$$


$$m_c = \alpha_c m_l \quad (8)$$

در این روابط، α_i و α_c به ترتیب نشان دهنده نسبت جرم سخت و نسبت جرم موج به جرم کل مایع هستند. محاسبه این ضرایب بدون بُعد با توجه به ابعاد هندسی مخزن و شرایط ارتعاشی آن صورت می‌گیرد:

$$\alpha_i = \beta \frac{\tanh\left(\frac{0,866}{\beta}\right)}{0,866} \quad (9)$$

$$\alpha_c = 0,264 \frac{\tanh(3,16\beta)}{\beta} \quad (10)$$

که در آن، β به عنوان نسبت عمق^۱ مایع به طول مخزن (در راستای تحریک) تعریف می‌شود. تحلیل پارامتریک نشان می‌دهد که با افزایش مقدار β ، سهم جرم سخت نسبت به جرم کل افزایش یافته، در حالی که سهم جرم موج کاهش می‌یابد. این رفتار فیزیکی به این دلیل است که در عمق‌های بیشتر، نوسانات سطحی مایع محدودتر شده و سهم انرژی مستهلک شده در نوسانات بخش عمیق مایع بیشتر می‌گردد. این تغییرات به صورت گرافیکی در شکل ۱ ارائه شده‌اند. همچنین این شکل نشان می‌دهد اگر طول مخزن در جهت ارتعاش حدوداً ۲/۱۵ برابر ارتفاع مایع (یعنی نسبت عمق حدوداً برابر با ۰/۴۶۵) باشد، جرم سخت و موج مایع نسبت مساوی از جرم مایع خواهند داشت.



شکل ۱- درصد نسبی جرم سخت و موج مایع استخر براساس تغییر نسبت عمق

Fig.1 - Relative percentage of rigid and sloshing mass of the tank liquid as a function of depth ratio

برای بخش موج مایع، که بیانگر اثرات دینامیکی سطح آزاد و نوسانات موضعی است، از مدل پیشنهادی هازنر استفاده شده است. در این مدل، سه پارامتر اصلی شامل فرکانس طبیعی (ω_c)، سختی معادل (k_c) و میرایی ویسکوز معادل (C_c) قسمت موج مایع مطابق روابط زیر قابل محاسبه هستند:

$$\omega_c = \sqrt{\frac{3,16g}{L} \tanh(3,16\beta)} \quad (11)$$

$$k_c = m_c \omega_c^2 \quad (12)$$

$$c_c = 2\xi_c m_c \omega_c \quad (13)$$

مطالعات تجربی و شبیه‌سازی‌های عددی نشان داده‌اند که برای نسبت عمق بیشتر از ۰/۲، نسبت میرایی (ξ_c) معمولاً بسیار کم و در حدود ۱ درصد یا کمتر می‌باشد. در این پژوهش نیز مقدار ۰/۱ در نظر گرفته شده است که بازتاب‌دهنده رفتار متداول جریان‌های نوسانی در مرزهای آزاد مایع می‌باشد [۳۷].

۲-۲- پارامترهای بهینه مخزن

به منظور سازگاری ارتعاشی بین جرم سخت، مایع و بدنه مخزن، از بالشتک‌های الاستومری به عنوان واسط مکانیکی بین مخزن حاوی مایع و سازه اصلی استفاده می‌شود. این بالشتک‌ها که در زیر مخزن به صورت موازی نصب می‌گردند، نقش کلیدی در تنظیم ویژگی‌های دینامیکی سیستم ایفا می‌کنند. فرکانس تنظیم‌شده سیستم ترکیبی مخزن، جرم سخت و مایع با استفاده از رابطه زیر به دست می‌آید:

$$\omega_e = \sqrt{\frac{\sum_{j=1}^{n_p} K_h}{m_i + m}} \quad (14)$$

که در آن ω_e فرکانس مؤثر سیستم ترکیبی، n_p تعداد بالشتک‌های الاستومری و K_h سختی برشی هر بالشتک الاستومری است. برای تحلیل پاسخ دینامیکی سیستم و تعیین کارایی کنترل ارتعاش، نسبت فرکانسی به صورت نسبت فرکانس سیستم مخزن به فرکانس اصلی سازه تعریف می‌شود:

$$\gamma_b = \frac{\omega_e}{\omega_1} \quad (15)$$

که در آن ω_1 فرکانس طبیعی اصلی سازه است. مطالعات پیشین و تحلیل‌های عددی متعدد نشان داده‌اند که نسبت فرکانسی بهینه معمولاً نزدیک به مقدار یک می‌باشد؛ بدین معنا که بیشینه‌سازی میرایی و کاهش پاسخ‌های ارتعاشی زمانی اتفاق می‌افتد که فرکانس سیستم مخزن هماهنگ با فرکانس اصلی سازه تنظیم گردد.

در این پژوهش، بهینه‌سازی هم‌زمان نسبت فرکانسی (γ_b) و نسبت میرایی بالشتک‌های الاستومری (ξ_b) با هدف کمینه‌سازی پاسخ شتاب سازه انجام شده است. بنابراین، تابع هدف بهینه‌سازی به صورت زیر تعریف می‌شود:

$$\text{بست آوردن } \{\xi_b \text{ و } \gamma_b\} \text{ برای کمینه‌سازی } \ddot{X}_s \quad (16)$$

که در آن \ddot{X}_s نسبت ریشه میانگین مربعات^۱ (RMS) شتاب طبقات در سازه کنترل‌شده به مقدار متناظر در سازه کنترل‌نشده است. انتخاب RMS به عنوان معیار اصلی ارزیابی عملکرد سازه، از آن رو صورت گرفته است که این شاخص بازتاب‌دهنده انرژی کل منتقل شده

1 Root mean square

به سازه در طول زمان بارگذاری دینامیکی می‌باشد. برخلاف بیشینه^۱ پاسخ که تنها نمایانگر شدت یک لحظه از ارتعاش است و ممکن است متأثر از نویز یا پدیده‌های گذرا باشد، شاخص RMS میانگین تأثیرات ارتعاشات را در طول کل زمان پاسخ‌گویی منعکس می‌کند. این رویکرد به‌ویژه در بررسی کارایی سیستم‌های کنترل غیرفعال یا نیمه‌فعال در بارگذاری لرزه‌ای با ماهیت تصادفی و ترکیبی، از دقت و اعتبار بالاتری برخوردار است. از منظر طراحی سیستم‌های کنترل سازه‌ای، بهینه‌سازی پارامترهای سیستم به‌منظور دستیابی به حداقل پاسخ RMS، معادل با افزایش کارایی سیستم در کاهش انرژی ورودی و ارتعاشات مزاحم تلقی می‌شود. با توجه به اینکه در سازه‌های سخت با دوره تناوب پایین، پاسخ شتاب بیش از سایر پاسخ‌ها مانند جابه‌جایی یا سرعت بحرانی‌تر تلقی می‌گردد، هدف این پژوهش، به حداقل رساندن شتاب طبقات به‌عنوان شاخص اصلی عملکرد سیستم کنترل می‌باشد.

برای حل مسئله بهینه‌سازی، از الگوریتم جستجوی الگو^۲ به‌عنوان یک روش بهینه‌سازی سراسری^۳ مقاوم^۴ استفاده شده است. این الگوریتم مبتنی بر ارزیابی گام‌به‌گام نقاط کاندید اطراف محل فعلی جستجو بوده و نیازی به مشتقات تابع هدف ندارد که مزیت مهمی در مسائل غیرخطی و دارای چندین کمینه محلی محسوب می‌شود. در هر تکرار، الگوریتم مجموعه‌ای از نقاط موسوم به مش^۵ را در فضای پارامترها تولید و ارزیابی می‌کند. در صورت بهبود تابع هدف، نقطه جدید به‌عنوان مبنای تکرار بعدی انتخاب شده و ابعاد مش افزایش می‌یابد؛ در غیر این صورت ابعاد مش کاهش یافته و فرایند به‌صورت محلی‌سازی شده ادامه می‌یابد. پیاده‌سازی الگوریتم فوق در این مطالعه با استفاده از تولباکس بهینه‌سازی نرم‌افزار MATLAB انجام شده است.

۳-۲- مدل‌های یادگیری ماشین برای پیش‌بینی پارامترهای بهینه مخزن

بر پایه اهداف این مطالعه، برای دسته‌بندی هم‌زمان پارامترهای میراگر شامل نسبت فرکانسی و نسبت میرایی بهینه، شش الگوریتم یادگیری ماشین متنوع شامل رگرسیون لجستیک^۶، درخت تصمیم^۷، جنگل تصادفی^۸، الگوریتم-K نزدیک‌ترین همسایگی^۹ (KNN)، ماشین بردار پشتیبان^{۱۰} (SVM) و بیز ساده^{۱۱} مورد ارزیابی قرار گرفتند. انتخاب این مدل‌ها با در نظر گرفتن تنوع ساختاری، توانایی در مواجهه با داده‌های غیرخطی، کلاس‌های نامتوازن و نویز بالا انجام گرفت. داده‌های خروجی بر اساس چارک‌های آماری^{۱۲} به سه کلاس تقسیم و به‌صورت استاندارد نرمال شدند. ارزیابی عملکرد بر اساس شاخص F1-score (بصورت میانگین‌وزنی بین کلاس‌ها) و تحلیل ماتریس درهم‌ریختگی^{۱۳} انجام شد.

شش الگوریتم انتخاب شده، خواص متنوعی دارند که در این پژوهش بطور هم‌زمان مورد بررسی و ارزیابی قرار گرفته‌اند. رگرسیون لجستیک در ساختارهای ساده دقت بالایی دارد ولی در داده‌های غیرخطی عملکرد کمتری دارد. درخت تصمیم با تفسیرپذیری بالا، حساسیت بیشتری به نویز نشان می‌دهد. جنگل تصادفی و SVM در داده‌های پیچیده و غیرخطی عملکرد مناسبی دارند، هرچند SVM تنظیمات دقیق و زمان پردازش بیشتری می‌طلبد. KNN پیاده‌سازی ساده‌ای دارد ولی در داده‌های حجیم پرهزینه است. بیز ساده در داده‌های حجیم سریع و دقیق عمل کرده اما در شرایط وابستگی قوی ویژگی‌ها دچار افت دقت می‌شود.

فرمول‌های کلیدی مدل‌های بکار گرفته‌شده در جدول ۱ ارائه شده است:

8 Random Forest
99 K-Nearest Neighbors
10 Support Vector Machine
11 Naive Bayes
12 Statistical Quartiles
13 Confusion Matrix

1 Peak
2 Pattern search algorithm
3 Global
4 Robust
5 Mesh
6 Logistic Regression
7 Decision Tree

جدول ۱: مجموعه روابط بکارگرفته شده در الگوریتم‌های یادگیری ماشین برای بخش پیش‌بینی پارامترهای تاثیرگذار
Table. 1: Set of relationships employed in machine learning algorithms for predicting influential parameters

فرمول اصلی	مدل
$\hat{y} = \frac{1}{1+e^{-(\beta_0+\sum_{i=1}^n \beta_i x_i)}} (*)$	رگرسیون لجستیک
$\hat{y} = \frac{1}{n_i} \sum_{j=1}^{n_i} y_j (**)$	درخت تصمیم
$\hat{y} = \frac{1}{T} \sum_{t=1}^T y_t(x) (***)$	جنگل تصادفی
$\hat{y} = \frac{1}{K} \sum_{i=1}^K y_i(x) (****)$	الگوریتم K- نزدیک‌ترین همسایگی
$\min_{w,b,\xi} \frac{1}{2} \ w\ ^2 + C \sum_{i=1}^n \xi_i$ بطوریکه $y_i(w^T x_i + b) \geq 1 - \xi_i (*****)$	ماشین بردار پشتیبان
$\hat{y} = \operatorname{argmax}_{c \in C} P(c) \prod_{i=1}^n P(x_i c) (*****)$	طبقه‌بند بیز ساده

(*) β_0 عرض از مبدا یا بایاس مدل، β_i ضرایب وزن‌دهی به ویژگی‌ها (پارامترهای قابل یادگیری)، x_i ویژگی‌های ورودی. هدف: یافتن ضرایب β به گونه‌ای که احتمال پیش‌بینی کلاس‌ها بیشینه شود.

(**) n_i تعداد نمونه‌های قرار گرفته در گره نهایی (leaf)، y_j مقدار پاسخ واقعی برای نمونه‌ی j. بر اساس ویژگی‌های ورودی، فضای تصمیم‌گیری به صورت سلسله‌مراتبی (شاخه‌ای) تقسیم می‌شود.

(***) T تعداد درخت‌های تصمیمی که در مدل وجود دارند، $y_t(x)$ پیش‌بینی هر درخت برای ورودی x .

(****) K تعداد همسایگان انتخابی برای رای‌گیری یا میانگین‌گیری، $y_i(x)$ مقدار خروجی یا کلاس نمونه‌ی i ام که نزدیک‌ترین به ورودی است.

(*****) w بردار وزن (مشخص‌کننده مرز تصمیم)، b بایاس یا فاصله از مبدا، ξ_i متغیر خطا برای نمونه i (نشان‌دهنده نقض مرز تصمیم)، C ضریب منظم‌سازی (کنترل‌کننده تعادل بین حداکثر margin و خطای آموزشی)

(*****) c کلاس‌های ممکن، $P(c)$ احتمال اولیه برای کلاس c ، $P(x_i | c)$ احتمال شرطی ویژگی i تحت کلاس c .

با توجه به نظارت‌شده بودن الگوریتم‌های مورد استفاده در این پژوهش، داده‌های شبیه‌سازی شده پس از برچسب‌گذاری به صورت تصادفی به دو مجموعه آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. به منظور کاهش وابستگی نتایج به یک تقسیم‌بندی تصادفی خاص و افزایش قابلیت تعمیم‌پذیری، فرآیند آموزش مدل‌ها با استفاده از اعتبارسنجی متقابل k -بخشی با $k = 10$ انجام شد، به طوری که در هر تکرار بخشی از داده‌های آموزش به عنوان مجموعه اعتبارسنجی در نظر گرفته شد و عملکرد نهایی بر اساس میانگین معیارهای ارزیابی گزارش گردید.

از منظر صحت‌سنجی فیزیکی و آماری، داده‌های مورد استفاده از تحلیل‌های تاریخیچه زمانی و بهینه‌سازی عددی مبتنی بر مدل هازنر استخراج شده‌اند که اعتبار آن برای مخازن عمیق و میراگرهای TLMD در مطالعات پیشین تأیید شده است [۲۲]. همچنین، مقادیر و روند تغییرات پارامترهای بهینه پیش‌بینی شده، به‌ویژه نسبت فرکانسی نزدیک به واحد و بازه نسبت میرایی بهینه، هم‌خوانی مناسبی با

نتایج گزارش شده در پژوهش‌های پیشین در زمینه بهینه‌سازی TLD و TLMD دارد [۲۹, ۲۵]. پایداری و قابلیت تعمیم مدل‌ها نیز از طریق ارزیابی عملکرد آن‌ها بر روی مجموعه آزمون مستقل، مطابق نتایج ارائه شده در جداول ۴ و ۵، مورد بررسی قرار گرفته است.

به منظور تضمین بازتولیدپذیری نتایج، تنظیمات هایپرپارامترهای تمامی مدل‌های یادگیری ماشین به صورت عددی و مشخص گزارش شده‌اند. در الگوریتم KNN تعداد همسایه‌ها برابر با ۵ و معیار فاصله اقلیدسی در نظر گرفته شد. در مدل SVM از کرنل RBF با پارامترهای $C = 1$ و $\gamma = 0/1$ استفاده گردید. مدل جنگل تصادفی شامل ۱۰۰ درخت با عمق حداکثر ۱۰ و معیار جینی بود و درخت تصمیم منفرد نیز با همان معیار و عمق حداکثر ۶ آموزش داده شد. در رگرسیون لجستیک، منظم‌سازی L2 با ضریب $\lambda = 0/01$ به کار گرفته شد و طبقه‌بند بیز ساده به صورت Gaussian Naïve Bayes پیاده‌سازی گردید. تمامی مدل‌ها بر اساس داده‌های استاندارد شده آموزش یافته و اعتبارسنجی آن‌ها با استفاده از اعتبارسنجی متقابل ۱۰-بخشی انجام شده است. علاوه بر معیارهای نهایی F1 و ROC و همچنین ماتریس‌های پیچیدگی، جزئیات کامل فرآیند آموزش شامل نحوه تقسیم داده‌ها، روش اعتبارسنجی، تنظیمات هایپرپارامترها و ارزیابی عملکرد مدل‌ها بر روی داده‌های آزمون مستقل در جداول ۴ و ۵ ارائه شده است تا امکان بازتولید دقیق نتایج فراهم شود.

۳- مثال عددی

به منظور ارزیابی کارایی مدل‌های یادگیری ماشین در پیش‌بینی پارامترهای بهینه میراگر جرمی مایع تنظیم‌شده، دو سازه با تعداد طبقات مختلف یعنی یک و پنج طبقه در نظر گرفته شد (جدول ۲). باتوجه به محتوای فرکانسی متفاوت زمین‌لرزه‌های مختلف، پارامترهای بهینه سازه‌های یک و پنج طبقه مجهز به میراگر TLMD تحت ارتعاش شش رکورد زلزله بم، دوزچه، معدن هکتور، کوبه، نورث‌ریج و لوما پریتا که مشخصات آن‌ها در جدول ۳ نشان داده شده است، بدست آمد تا مقاومت مدل‌های پیش‌بینی در برابر تغییرات محیطی و اتفاقی زمین‌لرزه‌ها لحاظ شود.

جدول ۲- مشخصات سازه برشی

Table. 2: Shear Structure Specifications

سازه برشی	طبقه	جرم (ton)	سختی (kN/m)	میرایی (kN.s/m)
۱ طبقه	۱	۱۰۰	۱۵۷۹۱	۲۵/۱
۵ طبقه	۵-۱	۱۰۰	۱۶۰۰۰۰	۸۰۰

جدول ۳- مشخصات رکوردهای زلزله


Table. 3: Specifications of Earthquake Records

زلزله	سال	PGA (g)
بم	۲۰۰۳	۰/۶۲۹
دوزچه	۱۹۹۹	۰/۸۰۶
معدن هکتور	۱۹۹۹	۰/۳۲۸
کوبه	۱۹۹۵	۰/۸۳۴
نورث‌ریج	۱۹۹۴	۰/۴۵۹
لوما پریتا	۱۹۸۹	۰/۳۲۶

۳-۱- مجموعه داده‌ها و معیارهای ارزیابی مدل‌های دسته‌بندی یادگیری ماشین برای پیش‌بینی


در این پژوهش، داده‌های مربوط به پارامترهای بهینه میراگر TLMD شامل دو مجموعه مجزا است؛ یکی برای سازه یک‌طبقه و دیگری برای سازه پنج‌طبقه که هر یک از آن‌ها از ۹۰۰ نمونه عددی تشکیل شدند. ارتفاع مایع و طول مخازن بکار رفته به ترتیب بین ۲۰ تا ۲۰۰ سانتی‌متر و بین ۲۰ تا ۵۸۰ سانتی‌متر در نظر گرفته شدند. نتایج بهینه‌سازی پارامترهای میراگر TLMD برای سازه یک‌طبقه، توزیع مقادیر نسبت فرکانسی را بین عدد ۰/۵۹ و ۱/۰۹ و توزیع نسبت میرایی را بین ۱/۸۵٪ و ۱۹/۶٪ نشان داد. همچنین برای سازه پنج‌طبقه، توزیع مقادیر نسبت فرکانسی بین عدد ۰/۸۶ و ۱/۰۸ و توزیع نسبت میرایی بین ۰/۵٪ و ۱۳/۰٪ به دست آمد.

به منظور بهره‌گیری از روش‌های دسته‌بندی یادگیری ماشین برای پیش‌بینی پارامترهای بهینه میراگر TLMD، سه دسته Class 0، Class 1 و Class 2 طوری در نظر گرفته شدند که به ترتیب ۰ تا ۷۵٪، ۷۵٪ تا ۹۰٪ داده‌ها و ۹۰٪ تا ۱۰۰٪ داده‌ها را شامل شوند. دلیل این نوع تقسیم‌بندی آن است که بخش عمده‌ای از داده‌ها در بازه‌های متداول (Class 0) قرار می‌گیرند و تمرکز اصلی مدل بر روی پیش‌بینی صحیح این محدوده است، در حالی که Class 1 و Class 2 نواحی کم‌فرآوانی اما بحرانی داده‌ها را پوشش می‌دهند که برای تحلیل عملکرد سیستم در شرایط خاص اهمیت دارند. به این ترتیب، مدل علاوه بر یادگیری رفتار غالب، توانایی تمایز و شناسایی شرایط مختلف را نیز پیدا می‌کند. توزیع داده‌ها به همراه نحوه دسته‌بندی آن‌ها در شکل‌های ۲ و ۳ نمایش داده شده‌اند.



شکل ۲: هیستوگرام داده‌های دسته‌بندی شده نسبت فرکانسی و نسبت میرایی بهینه در سازه یک‌طبقه بر اساس کلاس‌های عملکردی

Fig.2 : Histogram of classified optimal frequency ratio and damping ratio data in a one-story structure based on performance classes



شکل ۳: هیستوگرام داده‌های دسته‌بندی شده نسبت فرکانسی و نسبت میرایی بهینه در سازه پنج‌طبقه بر اساس کلاس‌های عملکردی

Fig.3 : Histogram of classified optimal frequency ratio and damping ratio data in a five-story structure based on performance classes

۳-۲- نتایج حاصله از الگوریتم‌های یادگیری ماشین برای پیش‌بینی

با بررسی ۳۰ داده تست^۱ جهت ارزیابی عملکرد شش الگوریتم یادگیری ماشین برای پیش‌بینی خروجی‌های نسبت فرکانسی و نسبت میرایی، نتایج نشان دادند که معیارهای دقت^۲، بازخوانی^۳، F1-score و نیز سطح زیر منحنی ROC^۴ تحت تأثیر نوع سازه و ماهیت خروجی به‌طور معناداری تغییر می‌کنند. مطابق جدول ۴ برای سازه یک‌طبقه، الگوریتم‌های KNN و جنگل تصادفی بهترین F1-score (حدود ۰/۷۳) را برای پیش‌بینی نسبت فرکانسی بهینه داشتند، در حالی که الگوریتم‌های رگرسیون لجستیک و بیز ساده بیشترین مساحت زیر منحنی ROC (حدود ۰/۷۹) را ثبت کردند.

با افزایش پیچیدگی سازه در مدل پنج‌طبقه، دقت پیش‌بینی نسبت فرکانسی کاهش یافت و مطابق جدول ۵ الگوریتم بیز ساده با F1-score در حدود ۰/۶۸ و مساحت زیر منحنی ROC حدود ۰/۷۲ بهترین عملکرد را داشت. در مقابل، پیش‌بینی نسبت میرایی در این سازه با دقت بالایی انجام شد و الگوریتم‌های بیز ساده، ماشین بردار پشتیبان و رگرسیون لجستیک با F1-score بیشتر از ۰/۸ و مساحت زیر منحنی ROC بیشتر از ۰/۸۹ توانستند میرایی را با دقت بالا شناسایی کنند. این نتایج نشان می‌دهد که انتخاب مدل یادگیری ماشین باید همزمان با توجه به ویژگی‌های سازه، ماهیت خروجی و نحوه توزیع کلاس‌ها انجام شود تا تعمیم‌پذیری نتایج در مسائل واقعی تضمین شود.

جدول ۴: نتایج معیارهای سنجش عملکرد الگوریتم‌های یادگیری ماشین برای داده‌های تست در سازه یک‌طبقه

Table. 4: Performance metric results of machine learning algorithms for the test data in a one-story structure

نتایج بدست آمده برای نسبت میرایی					نتایج بدست آمده برای نسبت فرکانسی				
Weighted ROC AUC	F1-score	Recall	Precision	الگوریتم	Weighted ROC AUC ^۵	F1-score	Recall	Precision	الگوریتم
۰/۷۲۰۴۳۷	۰/۶۳	۰/۵۹	۰/۷۱	Logistic Regression	۰/۷۹۵۲۹۳	۰/۶۸	۰/۶۴	۰/۷۷	Logistic Regression
۰/۵۷۷۶۱۰	۰/۶۵	۰/۷۳	۰/۶۱	K-Nearest Neighbors	۰/۶۹۹۶۲۸	۰/۷۳	۰/۷۶	۰/۷۳	K-Nearest Neighbors
۰/۵۲۳۱۹۰	۰/۶۳	۰/۷	۰/۵۸	Decision Tree	۰/۶۸۶۶۸۹	۰/۷۲	۰/۷۵	۰/۷۱	Decision Tree
۰/۵۶۴۷۱۱	۰/۶۵	۰/۷	۰/۶۲	Random Forest	۰/۷۲۵۹۴۰	۰/۷۳	۰/۷۶	۰/۷۳	Random Forest
۰/۷۱۵۱۴۷	۰/۶۵	۰/۷۵	۰/۵۷	Support Vector Machine	۰/۶۷۵۲۱۴	۰/۷۰	۰/۷۸	۰/۶۵	Support Vector Machine
۰/۷۱۸۸۵۲	۰/۶۷	۰/۷	۰/۶۶	Naive Bayes	۰/۷۹۱۸۱۹	۰/۶۹	۰/۷۷	۰/۶۵	Naive Bayes

جدول ۵: نتایج معیارهای سنجش عملکرد الگوریتم‌های یادگیری ماشین برای داده‌های تست در سازه پنج‌طبقه

Table. 5: Performance metric results of machine learning algorithms for the test data in a five-story structure

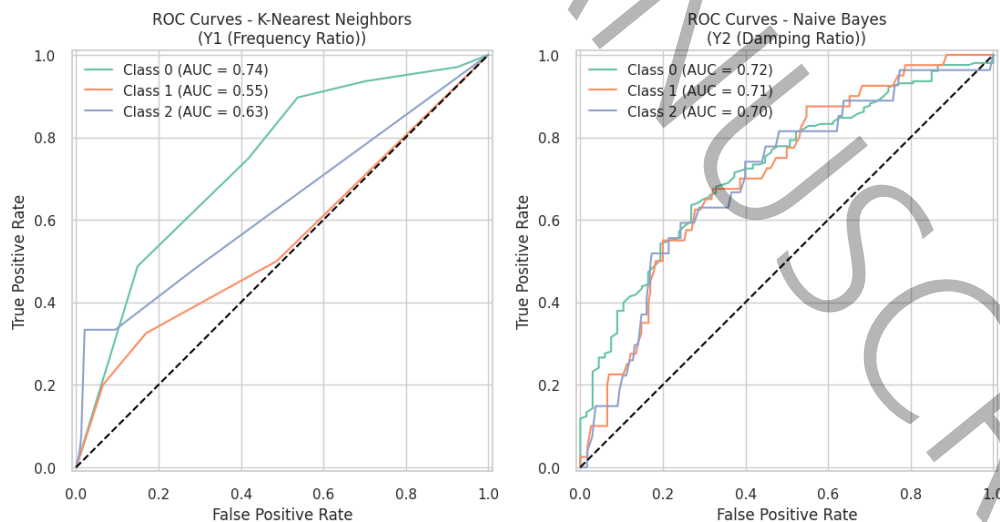
نتایج بدست آمده برای نسبت میرایی					نتایج بدست آمده برای نسبت فرکانسی				
Weighted ROC AUC	F1-score	Recall	Precision	الگوریتم	Weighted ROC AUC	F1-score	Recall	Precision	الگوریتم
۰/۹۳۹۶۳۸	۰/۸۲	۰/۸۰	۰/۸۵	Logistic Regression	۰/۷۰۵۳۹۳	۰/۵۵	۰/۵۱	۰/۷۲	Logistic Regression

4 Receiver Operating Characteristic
5 Area Under the Curve

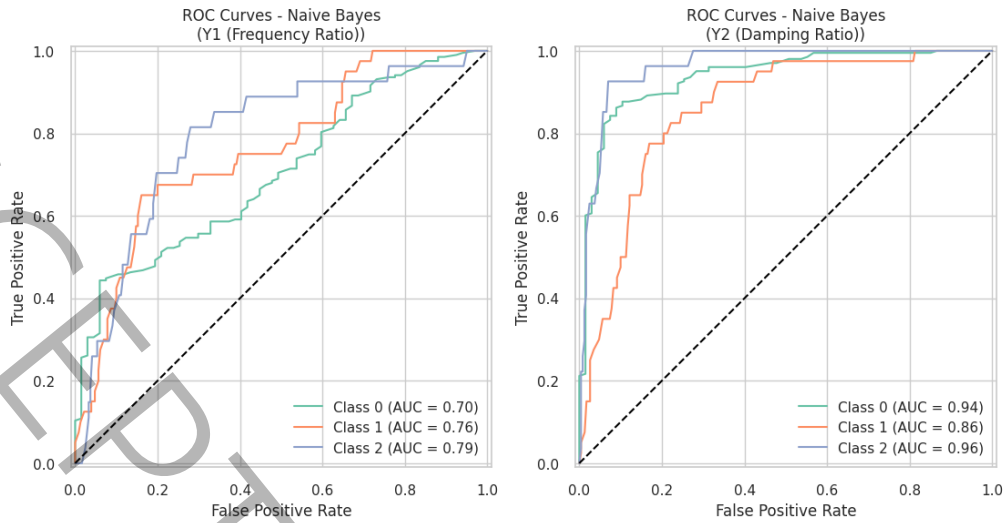
1 Test data
2 Precision
3 Recall

۰/۸۸۵۷۵۳	۰/۷۸	۰/۷۹	۰/۷۸	K-Nearest Neighbors	۰/۵۲۸۹۴۱	۰/۶۳	۰/۶۹	۰/۵۹	K-Nearest Neighbors
۰/۸۳۳۷۷۸	۰/۷۷	۰/۷۹	۰/۷۶	Decision Tree	۰/۴۹۵۲۸۴	۰/۶۵	۰/۷۱	۰/۶۰	Decision Tree
۰/۸۸۹۸۸۱	۰/۷۹	۰/۸۰	۰/۷۸	Random Forest	۰/۵۱۹۱۹۰	۰/۶۳	۰/۶۷	۰/۶۰	Random Forest
۰/۸۹۰۲۵۰	۰/۸۲	۰/۸۳	۰/۸۱	Support Vector Machine	۰/۶۶۲۸۱۳	۰/۶۶	۰/۷۵	۰/۶۲	Support Vector Machine
۰/۹۲۸۴۶۳	۰/۸۴	۰/۸۲	۰/۸۷	Naive Bayes	۰/۷۲۱۱۲۷	۰/۶۸	۰/۷۵	۰/۶۵	Naive Bayes

در شکل‌های ۴ و ۵ نمودارهای ROC برای سازه یک طبقه و سازه پنج طبقه نمایش داده شده است. این نمودارها در تکمیل تحلیل‌های عددی جداول ۵ و ۶، دید دقیق‌تری را از توان تفکیک مدل‌های یادگیری ماشین در شناسایی دسته‌های مختلف پارامترهای نسبت فرکانسی و نسبت میرایی فراهم می‌کنند. در سازه یک طبقه، الگوریتم K-Nearest Neighbors برای نسبت فرکانسی موفق به دسته‌بندی نسبتاً دقیق کلاس ۰ شده است (AUC برابر با ۰/۷۴)، اما عملکرد آن در شناسایی کلاس‌های ۱ و ۲ ضعیف‌تر بوده (AUC به ترتیب برابر با ۰/۵۵ و ۰/۶۳) که این موضوع با ضعف مدل در مرزهای بین کلاس‌ها در ماتریس‌های پیچیدگی نیز هم‌راستا است. در مقابل، الگوریتم بیز ساده برای نسبت میرایی در همان سازه، عملکرد یکنواخت‌تری ارائه داده و AUC برای هر سه کلاس تقریباً در محدوده ۰/۷۰ تا ۰/۷۲ باقی مانده است. در سازه پنج طبقه مطابق شکل ۵، الگوریتم Naive Bayes برای نسبت فرکانسی بهبود محسوسی نسبت به سازه یک طبقه داشته و توانسته است سه کلاس ۰، ۱ و ۲ را با AUC به ترتیب ۰/۷۰، ۰/۷۶ و ۰/۷۹ از یکدیگر تفکیک کند که نشان‌دهنده توان بالاتر این مدل در مواجهه با توزیع پیچیده‌تر ویژگی‌هاست. با این حال، دقت مدل در نسبت میرایی بسیار چشمگیرتر است، به طوری که برای کلاس‌های ۰، ۱ و ۲ به ترتیب AUC برابر با ۰/۹۴، ۰/۸۶ و ۰/۹۶ به دست آمده که بیانگر توانایی مدل در تشخیص دقیق کلاس‌های میرایی برای سازه‌های بلندتر می‌باشد. این نمودارها علاوه بر تأیید روند نتایج جدول ۴ و ۵ گزارش شده، نشان می‌دهند که خروجی نسبت میرایی دارای ساختار آماری خوش‌تعریف‌تر و کلاس‌بندی بهتری در مقایسه با نسبت فرکانسی است.



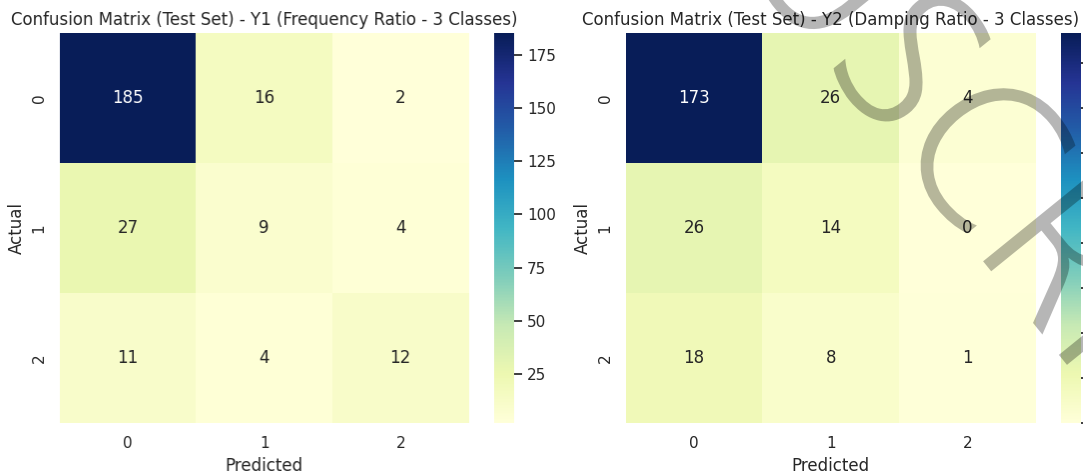
شکل ۴: نمودارهای ROC مربوط به بهترین الگوریتم‌های دسته‌بندی برای سازه یک طبقه
Fig.4 : ROC curves of the best classification algorithms for a one-story structure



شکل ۵: نمودارهای ROC مربوط به بهترین الگوریتم‌های دسته‌بندی برای سازه پنج طبقه

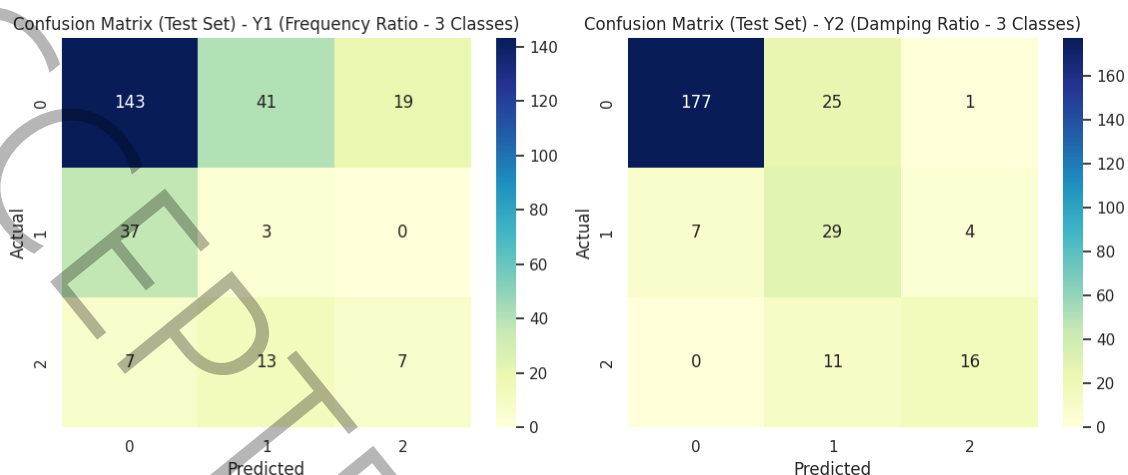
Fig.5 : ROC curves of the best classification algorithms for a five-story structure

ماتریس‌های پیچیدگی برای سازه‌های یک طبقه (شکل ۶) و پنج طبقه (شکل ۷) با نتایج F1-score هم‌خوانی دارند و رفتار مدل‌ها را در برابر کلاس‌ها روشن‌تر می‌کنند. در هر دو سازه، بیشترین خطاها در کلاس ۱ رخ داده که اغلب با کلاس‌های همسایه (۰ یا ۲) اشتباه گرفته شده‌اند؛ این امر ناشی از هم‌پوشانی ویژگی‌ها، نزدیکی عددی نمونه‌ها و تقسیم‌بندی مصنوعی براساس دسته‌بندی ۱۰، ۱۵ و ۷۵ درصدی نمونه‌ها است. در سازه پنج طبقه، خطای پیش‌بینی کلاس ۱ برای نسبت فرکانسی شدیدتر بوده و مدل در تفکیک آن ناکارآمد عمل کرده است که با افت F1-score هم‌راستا است و به پیچیدگی دینامیکی بالاتر سازه‌های بلند، درهم‌ریختگی توزیع ویژگی‌ها و کاهش مرزبندی کلاس‌ها ربط دارد. در مقابل، برای نسبت میرایی (به‌ویژه در سازه پنج طبقه)، مدل‌ها با خطای کمتر کلاس‌ها را تفکیک کرده و ماتریس‌ها توزیع متعادلی از پیش‌بینی‌های صحیح نشان می‌دهند، که نشان‌دهنده ساختار منظم‌تر داده‌ها و تفکیک‌پذیری بالای کلاس‌های میرایی است. بنابراین، ضعف پیش‌بینی کلاس‌های خاص نه تنها به مدل، بلکه به ساختار آماری و فیزیکی داده‌ها نیز وابسته است. با وجود نتایج قابل قبول، این پژوهش فقط مربوط به سازه‌های برشی ساده است. در پژوهش‌های آینده، تعمیم مدل به سازه‌های پیچیده‌تر و استفاده از روش‌های یادگیری عمیق پیشنهاد می‌شود.



شکل ۶: ماتریس پیچیدگی برای نسبت فرکانسی و نسبت میرایی بهینه براساس بهترین الگوریتم کلاسه‌بندی در داده‌های test (سازه یک طبقه)

Fig.6 : Confusion matrices for the optimal frequency ratio and damping ratio based on the best classification algorithm on the test data (one-story structure)



شکل ۷: ماتریس پیچیدگی برای نسبت فرکانسی و نسبت میرایی بهینه براساس بهترین الگوریتم کلاسه‌بندی در داده‌های test (سازه پنج طبقه)

Fig.7 : Confusion matrices for the optimal frequency ratio and damping ratio based on the best classification algorithm on the test data (five-story structure)

۴- بحث و نتیجه‌گیری

این پژوهش با ترکیب مدل‌سازی دینامیکی دقیق، بهینه‌سازی عددی و الگوریتم‌های یادگیری ماشین، چارچوبی کارآمد برای پیش‌بینی پارامترهای کلیدی طراحی میراگر TLMD ارائه داد. رویکرد پیشنهادی با کاهش زمان و هزینه محاسبات، مسیر تصمیم‌گیری در طراحی سازه‌ها را بهینه می‌کند. کارایی این چارچوب در پیش‌بینی نسبت فرکانسی و نسبت میرایی بهینه میراگر جرمی مایع تنظیم‌شده در سازه‌های یک طبقه و پنج طبقه ارزیابی شد و نتایج نشان داد که عملکرد مدل‌ها به پیچیدگی سازه و نوع خروجی وابسته است. در سازه یک طبقه، الگوریتم KNN توانست نسبت فرکانسی بهینه را با دقت مناسب در کلاس‌های ۰، ۱ و ۲ پیش‌بینی کند. اما در سازه پنج طبقه، دقت این پیش‌بینی کاهش یافت و تنها الگوریتم بیز ساده با دقت ۶۸ درصد موفق بود. برای نسبت میرایی بهینه، حتی در سازه پنج طبقه نیز مدل بیز ساده بهترین عملکرد را با FI-score معادل ۸۴ درصد ثبت کرد. بررسی ماتریس‌های پیچیدگی نشان داد بیشترین اشتباه مربوط به کلاس ۱ است که ناشی از هم‌پوشانی داده‌ها و مرزبندی دشوار میان کلاس‌ها می‌باشد.

۵- منابع و مراجع

- [۱] R. Greco, M. Morga, Optimum design of tuned mass dampers for different earthquake ground motion parameters and models, *The Structural Design of Tall and Special Buildings*, 28 (2019) p.e1672.
- [۲] V.J. Modi, F. Welt, Damping of wind induced oscillations through liquid sloshing, *Journal of Wind Engineering and Industrial Aerodynamics*, 30 (1998) 85-94.
- [۳] Y. Tamura, K. Fujii, T. Ohtsuki, T. Wakahara, R. Kohsaka, Effectiveness of tuned liquid dampers under wind excitation, *Engineering Structures*, 17 (1995) 609-621.
- [۴] P. Banerji, M. Murudi, A.H. Shah, N. Popplewell, Tuned liquid dampers for controlling earthquake response of structures, *Earthquake Engineering & Structural Dynamics*, 29 (2000) 587-602.
- [۵] M. Domizio, D. Ambrosini, A. Campi, A novel tuned liquid damper for vibration control in high-frequency structures, *Engineering Structures*, 301 (2024) p.117350.

- [۶] J.S. Love, M.J. Tait, The influence of tank orientation angle on a 2D structure-tuned liquid damper system, *Journal of Vibration and Acoustics*, 135 (2013) p.011010.
- [۷] M.J. Tait, X. Deng, The performance of structure-tuned liquid damper systems with different tank geometries, *Structural Control and Health Monitoring*, 17 (2013) 254-277.
- [۸] R. Bandyopadhyay, S. Maiti, A. Ghosh, A. Chatterjee, Overhead water tank shapes with depth-independent sloshing frequencies for use as TLDs in buildings, *Structural Control and Health Monitoring*, 25 (2018) p.e2049.
- [۹] J.K. Yu, T. Wakahara, D.A. Reed, A non-linear numerical model of the tuned liquid damper, *Earthquake Engineering & Structural Dynamics*, 28 (1999) 671-686.
- [۱۰] H.N. Li, Y. Jia, S.Y. Wang, Theoretical and experimental studies on reduction for multi-modal seismic responses of high-rise structures by tuned liquid dampers, *Journal of Vibration and Control*, 10 (2004) 1041-1056.
- [۱۱] X. Xu, T. Guo, G. Li, G. Sun, B. Shang, Guan, A combined system of tuned immersion mass and sloshing liquid for vibration suppression: Optimization and characterization, *Journal of Fluids and Structures*, 76 (2018) 396-410.
- [۱۲] L. Fu, T. Guo, G. Li, Investigation on damping performance of new type oscillator-liquid combined damper, *International Journal of Mechanical Sciences*, 135 (2018) 53-62.
- [۱۳] J.S. Love, C.S. Lee, Nonlinear series-type tuned mass damper-tuned sloshing damper for improved structural control, *Journal of Vibration and Acoustics*, 141 (2019) p.021006.
- [۱۴] J.S. Love, K.P. McNamara, M.J. Tait, T.C. Haskett, Series-type pendulum tuned mass damper-tuned sloshing damper, *Journal of Vibration and Acoustics*, 142 (2020) p.011003.
- [۱۵] A. Ghosh, B. Basu, Seismic vibration control of short period structures using the liquid column damper, *Engineering Structures*, 26 (2004) 1905-1913.
- [۱۶] M.C. Aydemir, E. Damcı, Y. Taşkın, Ç. ekerci, Comparison of the Dynamic Characteristics of Tuned Liquid Column Dampers with Different Elbow Forms, *Turkish Journal of Civil Engineering*, 35 (2024).
- [۱۷] K.W. Min, E.C. Park, Dynamic characteristics of tuned liquid column dampers using shaking table test, *Transactions of the Korean Society for Noise and Vibration Engineering*, 19 (2009) 620-627.
- [۱۸] H. Ding, J.T. Wang, L.Q. Lu, F. Zhu, A toroidal tuned liquid column damper for multidirectional ground motion-induced vibration control, *Structural Control and Health Monitoring*, 27 (2020) p.e2558.
- [۱۹] P. Banerji, A. Samanta, Earthquake vibration control of structures using hybrid mass liquid damper, *Engineering Structures*, 33 (2011) 1291-1301.
- [۲۰] D.K. Pandey, M.K. Sharma, S.K. Mishra, A compliant tuned liquid damper for controlling seismic vibration of short period structures, *Mechanical Systems and Signal Processing*, 132 (2019) 405-428.
- [۲۱] G.W. Housner, The dynamic behavior of water tanks, *Bulletin of the Seismological Society of America*, 53 (1963) 381-387.
- [۲۲] D.K. Pandey, S.K. Mishra, S. Chakraborty, A tuned liquid mass damper implemented in a deep liquid storage tank for seismic vibration control of short period structures, *The Structural Design of Tall and Special Buildings*, 31 (2022) p.e1928.
- [۲۳] M.A. Haroun, G.W. Housner, Dynamic characteristics of liquid storage tanks, *Journal of the Engineering Mechanics Division*, 108 (1982) 783-800.
- [۲۴] S. Hashemi, M.M. Saadatpour, M.R. Kianoush, Dynamic analysis of flexible rectangular fluid containers subjected to horizontal ground motion, *Earthquake Engineering & Structural Dynamics*, 42 (2013) 1637-1656.
- [۲۵] J. Hu, J. Xu, Parameter Optimization and Control Characteristics Analysis of TLMD System Based on Phase Deviation, *Journal of Shanghai Jiaotong University (Science)*, 25 (2020) 372-383.

- [۲۶]Z. Wang, X. Chai, S. Peng, B. Wang, L. Zhang, A novel tuned liquid mass damper for low-frequency vertical vibration control: Model experiments and field tests, *Mechanical Systems and Signal Processing*, 220 (2024) p.111702.
- [۲۷]M. Mahesh, N.M.K.M. Krishna, Role of Multiple Liquid Tuned Mass Dampers in Tall Buildings, *CVR Journal of Science and Technology*, 20 (2021) 8-16.
- [۲۸]A. Shruthi, N.M. Krishna, Role of Liquid Tuned Mass Dampers in Improving Torsional Competence of Asymmetric Buildings, *CVR Journal of Science and Technology*, 17 (2019) 13-19.
- [۲۹]H. Ghaffarzadeh, A. Aran, M. Hosseini, Optimal parameters of rooftop pools as the structural control system, *Journal of Structural and Construction Engineering*, (2024).
- [۳۰]A. Ocak, G. Bekdaş, S.M. Nigdeli, A metaheuristic-based optimum tuning approach for tuned liquid dampers for structures, *The Structural Design of Tall and Special Buildings*, 31 (2022) p.e1907.
- [۳۱]A. Ocak, S.M. Nigdeli, G. Bekdaş, S. Kim, Z.W. Geem, Adaptive harmony search for tuned liquid damper optimization under seismic excitation, *Applied Sciences*, 12 (2022) p.2645.
- [۳۲]A. Ocak, G. Bekdaş, S.M. Nigdeli, S. Kim, Z.W. Geem, Optimization of tuned liquid damper including different liquids for lateral displacement control of single and multi-story structures, *Buildings*, 12 (2022) p.377.
- [۳۳]U. Tahera, N, K.S. Raj, R. Kumar, H. Soundalgekar, T. Deepa, M.A. Shah, Comparative analysis of sloshing effects on elevated water tanks' dynamic response using ANN and MARS, *Discover Materials*, 5 (2025) p.9.
- [۳۴]K. Jeong, S.B. Choi, Takagi–Sugeno fuzzy observer-based magnetorheological damper fault diagnosis using a support vector machine, *IEEE Transactions on Control Systems Technology*, 30 (2021) 1723-1735.
- [۳۵]A. Ocak, Ü. Işıkdag, G. Bekdaş, S.M. Nigdeli, Prediction of Damping Capacity Demand in Seismic Base Isolators via Machine Learning, *CMES-Computer Modeling in Engineering & Sciences*, 138 (2024).
- [۳۶]S. Ghaemi, A. Aran, M. Mansoury, J. Katebi, Designing a fuzzy-based hybrid control system to reduce structure vibration using rooftop tank and MR damper, *Journal of Civil and Environmental Engineering*, (2025).
- [۳۷]Y. Li, Q. Di, Y. Gong, Equivalent mechanical models of sloshing fluid in arbitrary-section aqueducts, *Earthquake Engineering & Structural Dynamics*, 41 (2012) 1069-1087.