



Optimal Parameter Prediction in Tuned Liquid Mass Dampers Using Machine Learning Classification Models

Hossein Ghaffarzadeh¹, Alireza Aran¹, Alireza Binavayan²

¹ Department of Civil Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

² Department of Civil Engineering, Faculty of Civil Engineering, University of Amirkabir, Tehran, Iran.

ABSTRACT: This study proposes an integrated framework that combines dynamic modeling, numerical optimization, and machine learning classification to predict the optimal design parameters of Tuned Liquid Mass Dampers (TLMDs). Two primary outputs—the optimal frequency ratio and optimal damping ratio—were analyzed using six classification models: Logistic Regression, Decision Tree, Random Forest, K Nearest Neighbors (KNN), Support Vector Machine (SVM), and Naive Bayes. Two structural configurations were examined: a single-story and a five-story shear building, each equipped with rooftop TLMDs mounted on elastomeric pads. Dynamic responses were obtained for six earthquake records using time history analysis, with liquid motion modeled by the Housner model. Optimal elastomeric pad parameters for various tank configurations were determined via the Pattern Search algorithm. The results revealed that for the optimal frequency ratio in the single-story structure, KNN and Random Forest achieved the highest F1 score (~0.73), whereas in the five-story building, prediction accuracy declined and Naive Bayes performed best (~0.68). Regarding the optimal damping ratio, Naive Bayes excelled in both structures, particularly in the five-story model. Confusion matrix analysis indicated that most errors occurred in the intermediate class, primarily due to feature overlap. By significantly reducing computational time and eliminating the need for exhaustive numerical simulations, the proposed data-driven methodology supports reliable decision-making in both preliminary and detailed stages of TLMD design. Moreover, the framework is extendable to other passive vibration control devices and more complex structural systems, advancing the concept of intelligent, efficient, and precise design tools in structural engineering.

Review History:

Received: Sep. 21, 2025

Revised: Feb. 10, 2026

Accepted: Feb. 21, 2026

Available Online: Apr. 21, 2024

Keywords:

Tuned Liquid Mass Damper

Machine Learning Algorithms

Prediction

Classification

Optimization

1- Introduction

Vibration mitigation of structures subjected to dynamic loads such as earthquakes and wind is a fundamental concern in structural engineering. Tuned mass dampers (TMDs) are widely used passive control devices; however, their performance is highly sensitive to variations in structural properties and seismic characteristics, which may significantly reduce their effectiveness under uncertain loading conditions [1].

Tuned liquid dampers (TLDs) have been proposed as an efficient alternative to TMDs by exploiting liquid sloshing and wave-breaking mechanisms, offering advantages such as reduced added mass and ease of installation. Previous studies have demonstrated that TLDs are particularly effective for flexible, long-period structures and can noticeably reduce seismic and wind-induced responses of tall buildings [2-4]. Nevertheless, the performance of conventional TLDs strongly depends on accurate frequency tuning, which is governed by tank geometry and liquid depth, limiting their applicability to

short-period structures.

To overcome this limitation, deep liquid tanks commonly available as rooftop water reservoirs have been modeled using the Housner approach, in which the liquid mass is decomposed into rigid and sloshing components [5]. This concept has led to the development of tuned liquid mass dampers (TLMDs), which utilize the inherent dynamic behavior of deep liquid tanks without requiring additional tuned masses. However, determining optimal TLMD parameters remains computationally demanding, motivating the use of machine learning-based classification models for fast and reliable prediction of optimal damper properties.

2- Methodology

2- 1- Dynamic and Optimization Modeling

Two shear buildings—a one-story and five-story configuration—were modeled (see Table 1). Rooftop TLMDs were installed on elastomeric pads that govern system stiffness and damping. The liquid behavior followed Housner's model,

*Corresponding author's email: ghaffar@tabrizu.ac.ir



Table 1. Shear Structure Specifications.

Structure	Stories	Mass (ton)	Stiffness (KN/m)	Damping (KN.s/m)
One-story	1	100	15791	1/25
Five-story	1-5	100	160000	800

Table 2. Performance metrics for Frequency Ratio on a one-story structure.

Algorithm	F1-Score	Weighted ROC AUC
Logistic Regression	0/68	0/795293
K-Nearest Neighbors	0/73	0/699628
Decision Tree	0/72	0/686689
Random Forest	0/73	0/72594
Support Vector Machine	0/7	0/675214
Naive Bayes	0/69	0/791819

where the rigid mass and sloshing mass vary as functions of the liquid depth ratio β .

Optimal system parameters were determined to minimize the root-mean-square (RMS) acceleration responses using the Pattern Search algorithm, a derivative-free global optimizer suitable for nonlinear systems.

2- 2- Data Generation and ML Framework

Time-history analyses under six earthquake records (Bam, Duzce, Hector Mine, Kobe, Northridge, Loma Prieta) produced optimized parameter datasets (900 samples per structure).

Values were divided into three performance classes (Class 0: 0-75%, Class 1: 75-90%, Class 2: 90-100%) to reflect typical and critical operating ranges.

Six supervised learning algorithms—Logistic Regression, Decision Tree, Random Forest, KNN, SVM, and Naive Bayes—were trained with 70/30 train-test splitting and 10-fold cross-validation. Performance was assessed using Precision, Recall, F1-score, and ROC-AUC. Hyper-parameters were optimized (e.g., KNN = 5, SVM-RBF kernel C=1, $\gamma = 0.1$).

Table 3. Performance metrics for Frequency Ratio on a five-story structure.

Algorithm	F1-Score	Weighted ROC AUC
Logistic Regression	0/55	0/705393
K-Nearest Neighbors	0/63	0/528941
Decision Tree	0/65	0/495284
Random Forest	0/63	0/519190
Support Vector Machine	0/66	0/662813
Naive Bayes	0/68	0/721127

3- Results and Discussion

The ML models demonstrated clear differentiation between the prediction tasks for frequency ratio and damping ratio.

For the **single-story structure**, KNN and Random Forest achieved F1 ≈ 0.73 for frequency ratio, while Logistic Regression and Naive Bayes obtained the highest ROC-AUC (≈ 0.79).

For the **five-story structure**, Naive Bayes outperformed others with F1 ≈ 0.68 and ROC-AUC ≈ 0.72 for frequency ratio, and F1 ≈ 0.84 and ROC-AUC ≈ 0.93 for damping ratio (see Fig 1 and Table 2,3).

It is observed that ROC-AUC values improved for damping ratio prediction, reflecting clearer statistical separability of the data (see Fig 1 and Table 2,3).

These highlight that misclassification mainly occurs in Class 1, where overlapping physical parameters hinder boundary definition among classes.

Overall, ML models captured complex interrelations between structural dynamic responses and TLMD parameters effectively, providing stable generalization on unseen data.


4- Conclusion

An integrated data-driven framework was developed to efficiently predict optimal parameters of TLMDs using machine learning classification.


By coupling Housner-based dynamic modeling with statistical learning, the study demonstrated accurate and physically consistent predictions with substantial reduction in computational effort.

Naive Bayes showed the best overall balance between precision, interpretability, and training stability, confirming the feasibility of ML-assisted TLMD design.

The methodology can be readily extended to multi-directional damping systems and tall buildings, promoting intelligent automated structural design practice.



(a)



(b)

Fig. 1. Performance metrics for Frequency Ratio on a (a) one-story structure (b) five-story structure.

References

- [1] R. Greco, M. Morga, Optimum design of tuned mass dampers under earthquake excitations, *The Structural Design of Tall and Special Buildings*, 28 (2019) e1672.
- [2] P. Banerji, Tuned liquid dampers for controlling earthquake response of structures, *Earthquake Engineering & Structural Dynamics*, 29 (2000) 587-602.
- [3] V.J. Modi, F. Welt, Damping of wind-induced oscillations through liquid sloshing, *Journal of Wind Engineering and Industrial Aerodynamics*, 30 (1998) 85-94.
- [4] Y. Tamura, Effectiveness of tuned liquid dampers under wind excitation, *Engineering Structures*, 17 (1995) 609-621.
- [5] G.W. Housner, The dynamic behavior of water tanks, *Bulletin of the Seismological Society of America*, 53 (1963) 381-387.



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

حسین غفارزاده^{۱*}، علیرضا آران^۱، علیرضا بینوایان^۲

۱- گروه مهندسی عمران، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران.

۲- گروه مهندسی عمران، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

تاریخچه داوری:

دریافت: ۱۴۰۴/۰۶/۳۰

بازنگری: ۱۴۰۴/۱۱/۲۱

پذیرش: ۱۴۰۴/۱۲/۰۲

ارائه آنلاین: ۱۴۰۵/۰۲/۰۱

کلمات کلیدی:

میراگر جرمی مایع تنظیم‌شده

الگوریتم‌های یادگیری ماشین

پیش‌بینی

دسته‌بندی

بهینه‌سازی

خلاصه: 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 یک‌طبقه و پنج‌طبقه 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 یک‌طبقه بهترین عملکرد را با score-FI حدود ۷۳٪ ارائه می‌دهند، در حالی که در سازه پنج‌طبقه، به‌دلیل افزایش پیچیدگی رفتاری، الگوریتم بیز ساده با score-FI حدود ۶۸٪ عملکرد مناسب‌تری دارد. همچنین، بیز ساده در پیش‌بینی نسبت میرایی بهینه برای هر دو سازه عملکردی پایدار نشان داده و در سازه پنج‌طبقه دقتی در حدود ۸۴٪ به‌دست آمده است که کارایی چارچوب پیشنهادی را تأیید می‌کند.

۱- مقدمه

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٪

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

1. Tuned mass dampers
2. Greco
3. Morga
4. Tuned liquid dampers

* نویسنده عهده‌دار مکاتبات: ghaffar@tabrizu.ac.i

5. Modi

6. Welt

7. Tamura

8. High-frequency tuned liquid damper



استفاده شود [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^۹ 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^{۱۰} و پارک^{۱۱} (۲۰۰۹) با بررسی عددی و آزمایشگاهی این میراگرها نشان دادند که پارامترهای بهینه میراگر به نسبت طول افقی و 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^{۱۲} (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^{۱۳} (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 بعد 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 میلی‌متر 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، مدل‌هازن^{۱۴} 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

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 قابل توجهی بر فرکانس ارتعاش مایع و عملکرد کلی میراگر دارد. لاو^۱ و تیات^۲ (۲۰۱۳) تأثیر زاویه چرخش مخزن میراگرهای TLD را بررسی کردند [۶]. همچنین تیات و دنگ^۳ (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^۴ 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 موده‌های 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]. 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^۵ 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^۶ و باسو^۷ (۲۰۰۴) پیشنهاد کردند که از میراگر ستون مایع تنظیم‌شده^۸ (TLCD)

1. Love
2. Tiat
3. Deng
4. Yu
5. Banerji
6. Ghosh
7. Basu
8. Tuned liquid column damper

9. Aydemir

10. Min

11. Park

12. Toroidal tuned liquid column damper

13. Hybrid mass liquid damper

14. Housner model

میرایی استخراج آب را که به صورت یک میراگر TLMD مدل سازی شده است، بدست آوردند [۲۹]. با آنالیز اثر اندرکنش بین میراگر TLMD و سازه اصلی، فرمول انحراف فاز بین سرعت نسبی میراگر و جابه جایی سازه اولیه به دست آمده است. همچنین نتایج نشان داده اند که نسبت فرکانسی و نسبت عمق مایع بر اندازه و محل بیشینه پیک^۶ تشدید و نسبت جرم و میرایی بر عرض باند فرکانس تأثیر دارند [۲۵]. بهینه سازی پارامترهای میراگر TLD به کمک الگوریتم جایا^۷، الگوریتم گرده افشانی گل^۸ (FPA)، الگوریتم جستجوی هارمونی^۹ (HS) و الگوریتم بهینه سازی مبتنی بر آموزش یادگیری^{۱۰} (TLBO) انجام شده است. نتایج حاصل نشان داده اند که از میان الگوریتم های مذکور، الگوریتم جایا نتایج بهتری در کاهش پاسخ های سازه ارائه کرده است [۳۰]. به منظور بهبود عملکرد الگوریتم جستجوی هارمونی، الگوریتم جستجوی هارمونی تطبیقی^{۱۱} (AHS) برای بهینه سازی پارامترهای میراگرهای مایع استفاده شد. نتایج نشان دادند که عملکرد الگوریتم AHS در مقایسه با الگوریتم HS، انحراف معیار کمتری بدست می دهد و با افزایش جرم سازه، بهینه سازی چگالی مایع بکار رفته در میراگر نقش مهمتری پیدا می کند [۳۱، ۳۲].

مطالعات اخیر نقش پررنگ الگوریتم های یادگیری ماشین^{۱۲} در مدل سازی و بهینه سازی سامانه های کنترل ارتعاش را نشان داده اند. در پژوهشی، پیش بینی پاسخ جابه جایی یک مخزن آب مرتفع فولادی تحت زلزله با استفاده از مدل عددی اندرکنش سیال-سازه و آموزش دو الگوریتم شبکه عصبی مصنوعی (ANN)^{۱۳} و اسپلاین های رگرسیون تطبیقی چندمتغیره^{۱۴} (MARS) انجام شد که مدل ANN دقت بالاتری داشت [۳۳]. همچنین، چارچوبی ترکیبی از ناظر فازی تاکاگی-سوگنو^{۱۵} (TS) و ماشین بردار پشتیبان^{۱۶} (SVM) برای تشخیص خطا در میراگرهای مغناطیسی توسعه یافت که نرخ پیش بینی و شناسایی صحیح بسیار بالایی ارائه کرد [۳۴]. در رویکردی دیگر، الگوریتم های کلاسه بندی^{۱۷} مانند بیز ساده^{۱۸} و ماشین بردار پشتیبان برای پیش بینی نیاز به میرایی و تعیین پارامترهای بهینه TMD

6. Peak

7. Jaya algorithm

8. Flower pollination algorithm

9. Harmony search

10. Teaching-learning-based optimization

11. Adaptive harmony search algorithms

12. Machine Learning Algorithms

13. Artificial Neural Network

14. Multivariate Adaptive Regression Splines

15. Takagi-Sugeno Fuzzy Observer

16. Support Vector Machine

17. Classification

18. Naive Bayes

سیستم شامل دو جرم مجزا، یعنی جرم سخت^۱ و جرم موج^۲، در نظر گرفته می شود که به صورت سری به سازه متصل شده اند. این مدل، با فرض رفتار خطی برای دینامیک امواج سطحی و شکست آن ها 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 ۰/۳^۳ توجیه پذیر است. با توجه به استفاده گسترده از بتن در ساخت این مخازن، فرض صلب بودن دیواره ها که یکی از ارکان مدل هازنر است، برای اغلب این سازه ها قابل قبول است. لازم به ذکر است که مدل های تحلیلی برای مخازن با دیواره های انعطاف پذیر نیز توسط هاشمی و همکاران مورد بررسی قرار گرفته است [۲۴].

پاندی^۲ و همکاران (۲۰۲۲) با بهره گیری از مدل هازنر، به ارزیابی کارایی میراگر جرمی مایع تنظیم شده^۴ (TLMD) در مخازن عمیق پرداخته و عملکرد آن را در مقایسه با میراگر TMD مورد سنجش قرار دادند [۲۲]. پارامترهای بهینه و ویژگی های کنترلی این دسته از میراگرها بر مبنای معیارهای مرتبط با انحراف فاز^۵ تعیین گردیده است [۲۵]. در سیستم TLMD، به واسطه بهره گیری از رفتار دوگانه سیال درون مخزن، نیازی به استفاده از جرم تنظیم شده اضافی وجود ندارد. در واقع، جرم سخت سیال به همراه جرم مخزن، نقش TMD را ایفا می کنند، درحالی که جرم موج سیال، عملکردی مشابه میراگر TLD دارد. این هم افزایی باعث می شود که میراگر TLMD ضمن بهره مندی از مزایای هر دو نوع میراگر TMD و TLD، معایب مربوط به آن ها را نیز به نحو مؤثری کاهش دهد. میراگرهای TLMD در کاهش پاسخ سازه های با فرکانس پایین تحت ارتعاش قائم مؤثر واقع شده و بصورت آزمایشگاهی و عملی ارزیابی شده اند [۲۶]. این میراگرها در سازه ها با پلان نامنظم و منظم مورد ارزیابی قرار گرفته اند و نتایج نشان دادند که با افزایش تعداد میراگرها، برش پایه افزایش ولی جابه جایی سازه کاهش می یابد [۲۷]. همچنین در سازه های دارای پلان نامنظم، تأثیر میراگر TLMD بر کاهش پاسخ های جهت محور ضعیف پلان بیشتر است [۲۸].

به منظور دستیابی به حداکثر کارایی میراگرهای مایع، بهینه سازی پارامترهای میراگرها مورد توجه قرار گرفته است. این بهینه سازی شامل تنظیم دقیق نسبت جرمی، نسبت فرکانسی، عمق مایع و ضرایب میرایی است. غفارزاده و همکاران (۲۰۲۴) پارامترهای نسبت فرکانسی و نسبت

1. Impulsive mass

2. Convective mass

3. Pandey

4. Tuned liquid mass damper

5. Phase deviation

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، بردار u_s 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 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:

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

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

به کار 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 تنظیم شده 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 به دلیل پیچیدگی مدل و تنوع ورودی‌ها عملی نیست، بسیار کارآمد است. چارچوب ارائه شده، گامی مؤثر در جهت توسعه ابزارهای هوشمند طراحی و تحلیل سازه‌ای 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 فرآیند بهینه‌سازی و پیش‌بینی پارامترهای بهینه بالشتک‌های الاستومری شرح داده می‌شود.

۲-۱- معادله حرکت سازه مجهز به مخزن پشت‌بام

در ساخت مدل‌های مخزنی به عنوان میراگر جرمی مایع تنظیم شده، 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 تنظیم شده، پیشنهاد می‌شود. این در حالی است که روش متداول اتصال مستقیم مخزن به سازه ممکن است نتایج مطلوبی به همراه نداشته باشد [۳۶].

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:

$$\omega_c = \sqrt{\frac{\sum_{j=1}^{n_p} K_{h_j}}{m_i + m}} \quad (14)$$

که در آن ω_c فرکانس مؤثر سیستم ترکیبی، n_p تعداد بالشتک‌های الاستومری و K_{h_j} 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:

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 نشان‌دهنده 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 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، درحالی 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.

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



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.

که در آن \ddot{X}_s نسبت ریشه میانگین مربعات^۱ (RMS) شتاب طبقات در سازه کنترل شده به مقدار متناظر در سازه کنترل نشده است. انتخاب RMS به عنوان معیار اصلی ارزیابی عملکرد سازه، از آن رو صورت گرفته است که این شاخص بازتاب دهنده انرژی کل منتقل شده به سازه در طول زمان بارگذاری دینامیکی می باشد. برخلاف بیشینه^۲ پاسخ که تنها نمایانگر شدت یک لحظه از ارتعاش است و ممکن است متأثر از نویز یا پدیده های گذرا باشد، شاخص RMS میانگین تأثیرات ارتعاشات را در طول کل زمان پاسخ گویی منعکس می کند. این رویکرد به ویژه در بررسی کارایی سیستم های کنترل غیرفعال یا نیمه فعال در بارگذاری لرزه ای با ماهیت تصادفی و ترکیبی، از دقت و اعتبار بالاتری برخوردار است. از منظر طراحی سیستم های کنترل سازه ای، بهینه سازی پارامترهای سیستم به منظور دستیابی به حداقل پاسخ RMS، معادل با افزایش کارایی سیستم در کاهش انرژی ورودی و ارتعاشات مزاحم تلقی می شود. با توجه به اینکه در سازه های سخت با دوره تناوب پایین، پاسخ شتاب بیش از سایر پاسخ ها مانند جابه جایی یا سرعت بحرانی تر تلقی می گردد، هدف این پژوهش، به حداقل رساندن شتاب طبقات به عنوان

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

که در آن ω_1 فرکانس طبیعی اصلی سازه است. مطالعات پیشین و تحلیل های عددی متعدد نشان داده اند که نسبت فرکانسی بهینه معمولاً نزدیک به مقدار یک می باشد؛ بدین معنا که بهینه سازی میرایی و کاهش پاسخ های ارتعاشی زمانی اتفاق می افتد که فرکانس سیستم مخزن هماهنگ با فرکانس اصلی سازه تنظیم گردد. در این پژوهش، بهینه سازی هم زمان نسبت فرکانسی (γ_b) و نسبت میرایی بالشتک های الاستومری (ξ_b) با هدف کمیته سازی پاسخ شتاب سازه انجام شده است. بنابراین، تابع هدف بهینه سازی به صورت زیر تعریف می شود:

$$\text{بدست آوردن } \{\xi_b \text{ و } \gamma_b\} \text{ برای کمیته سازی } \ddot{X}_s \quad (16)$$

1. Root mean square
2. Peak

شاخص اصلی عملکرد سیستم کنترل می‌باشد.

برای حل مسئله بهینه‌سازی، از الگوریتم جستجوی الگو^۱ به‌عنوان یک روش بهینه‌سازی سراسری^۲ مقاوم^۳ 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^۴ 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 توبلاکس بهینه‌سازی نرم‌افزار MATLAB انجام شده است.

۲-۳- 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^۵، درخت تصمیم^۶، جنگل تصادفی^۷، الگوریتم K-نزدیک‌ترین همسایگی^۸ (KNN)، ماشین بردار پشتیبان^۹ (SVM) و بیز ساده^{۱۰} 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^{۱۱} به سه کلاس تقسیم و به‌صورت استاندارد نرمال شدند. ارزیابی عملکرد بر اساس شاخص F1-score (بصورت میانگین وزنی بین کلاس‌ها) و تحلیل ماتریس درهم‌ریختگی^{۱۲} 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

1. Pattern search algorithm
2. Global
3. Robust
4. Mesh
5. Logistic Regression
6. Decision Tree
7. Random Forest
8. K-Nearest Neighbors
9. Support Vector Machine
10. Naive Bayes
11. Statistical Quartiles
12. Confusion Matrix

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: با توجه به نظارت‌شده بودن الگوریتم‌های مورد استفاده در این پژوهش، داده‌های شبیه‌سازی شده پس از برچسب‌گذاری به‌صورت تصادفی به دو مجموعه آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. به‌منظور 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، به‌طوری‌که در هر تکرار بخشی از داده‌های آموزش به‌عنوان 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 تاریخچه 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 [۲۵، ۲۹]. پایداری و قابلیت تعمیم مدل‌ها نیز از طریق ارزیابی عملکرد آن‌ها بر روی مجموعه آزمون مستقل، مطابق نتایج ارائه‌شده در جداول ۴ و ۵، مورد بررسی قرار گرفته است.

به‌منظور تضمین بازتولیدپذیری نتایج، تنظیمات هاپیرپارامترهای تمامی مدل‌های یادگیری ماشین به‌صورت 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 $\lambda=0.01$ به‌کار گرفته شد و طبقه‌بند بیز ساده به‌صورت Gauss-ian Naïve Bayes پیاده‌سازی گردید. تمامی مدل‌ها بر اساس داده‌های استانداردشده آموزش یافته و اعتبارسنجی آن‌ها با استفاده از اعتبارسنجی

جدول ۱. مجموعه روابط بکار گرفته شده در الگوریتم‌های یادگیری ماشین برای بخش پیش‌بینی پارامترهای تاثیرگذار.

Table 1. Set of relationships employed in machine learning algorithms for predicting influential parameters.

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

(*) β_0 عرض از مبدا یا بایاس مدل، β_i ضرایب وزن دهی 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 مقدار پاسخ واقعی برای نمونه‌ی i . 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 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 .

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

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.

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

و توزیع نسبت میرایی را بین ۱/۸۵٪ و ۱۹/۶٪ نشان داد. همچنین برای سازه پنج طبقه، 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٪ داده‌ها، 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 کم‌فراوانی 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.

مجهاز به میراگر TLMD تحت ارتعاش شش رکورد زلزله بم، دوزچه، معدن هکتور، کوبه، نورث‌ریج و لوما پربتا 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.

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 یک طبقه و دیگری برای سازه پنج طبقه 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 یک طبقه، توزیع مقادیر نسبت فرکانسی را بین عدد ۰/۵۹ و ۱/۰۹

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 پربتا	۱۹۸۹	۰/۳۲۶

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 یک طبقه، الگوریتم‌های KNN و جنگل تصادفی بهترین F1-score (حدود ۰/۷۳) را برای پیش‌بینی نسبت

1. Test data
2. Precision
3. Recall
4. Receiver Operating Characteristic



شکل ۲. هیستوگرام داده‌های دسته‌بندی شده نسبت فرکانسی و نسبت میرایی بهینه در سازه یک طبقه 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 پنج طبقه 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.

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.

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

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 پنج طبقه، 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

جدول ۴. نتایج معیارهای سنجش عملکرد الگوریتم‌های یادگیری ماشین برای داده‌های تست در سازه یک طبقه.

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

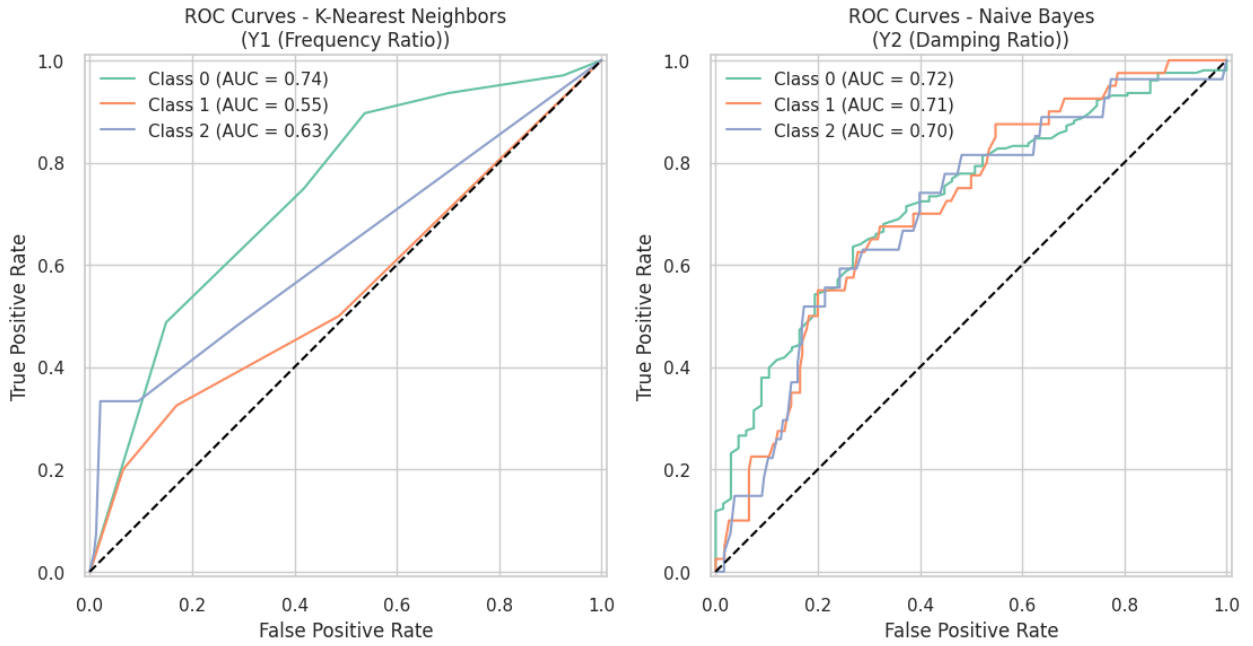
نتایج بدست آمده برای نسبت میرایی					نتایج بدست آمده برای نسبت فرکانسی				
Weighted ROC AUC	F1-score	Recall	Precision	الگوریتم	Weighted ROC AUC ¹	F1-score	Recall	Precision	الگوریتم
۰/۷۲۰۴۳۷	۰/۶۳	۰/۵۹	۰/۷۱	Logistic Regression	۰/۷۹۵۲۹۳	۰/۶۸	۰/۶۴	۰/۷۷	Logistic Regression
۰/۵۷۷۶۱۰	۰/۶۵	۰/۷۳	۰/۶۱	K-Nearest 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

1 Area Under the Curve

جدول ۵. نتایج معیارهای سنجش عملکرد الگوریتم‌های یادگیری ماشین برای داده‌های تست در سازه پنج طبقه.

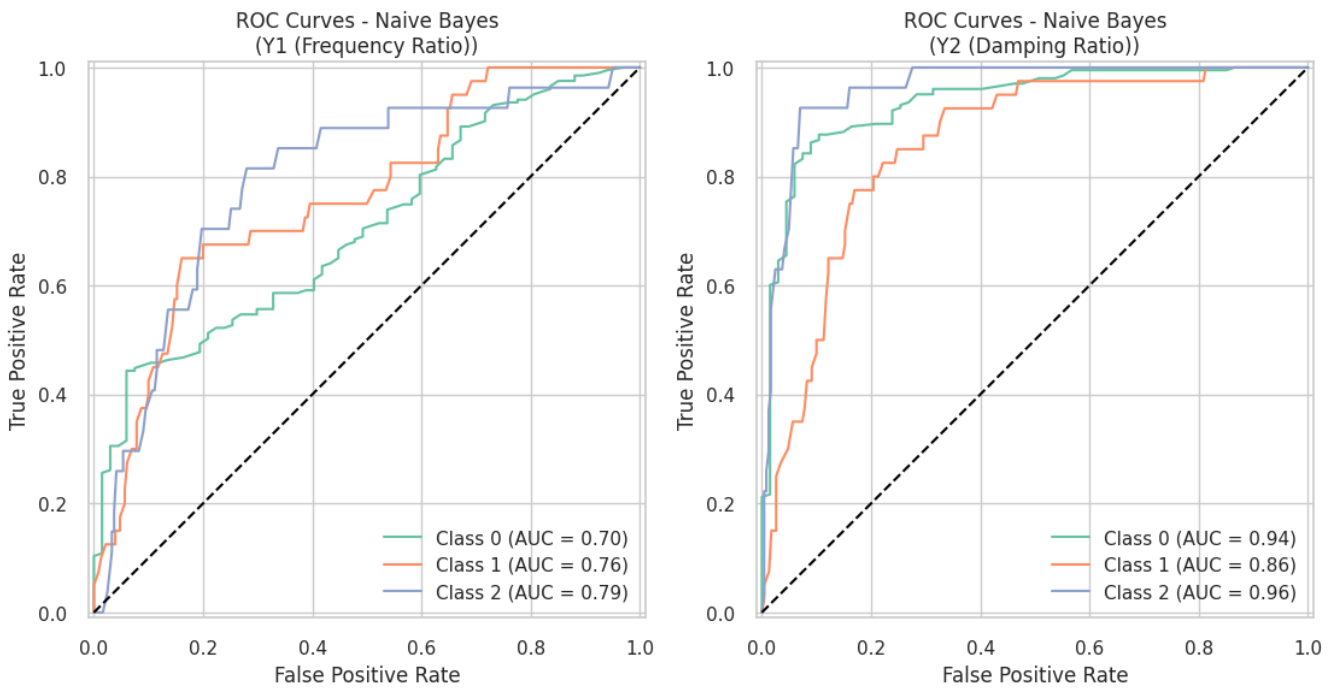
Table 5. Performance metric results of machine learning algorithms for the test data in a five-story structure.

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
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




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.

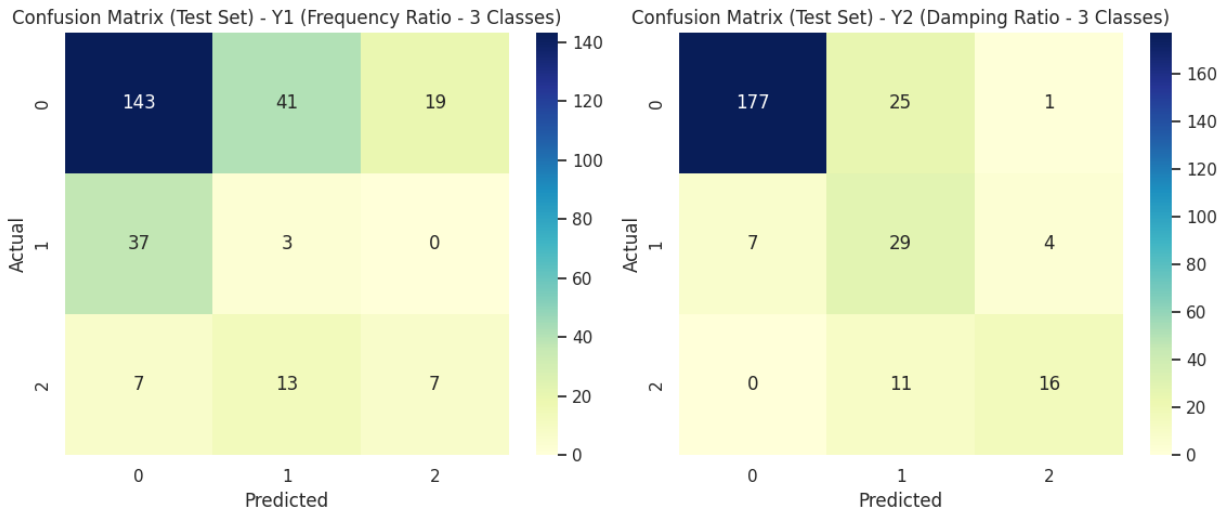


شکل ۶. ماتریس پیچیدگی برای نسبت فرکانسی و نسبت میرایی بهینه براساس بهترین الگوریتم کلاسه‌بندی در داده‌های test (سازه یک طبقه).

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).

نشان می‌دهند که خروجی نسبت میرایی دارای ساختار آماری خوش‌تعریف‌تر و کلاسه‌بندی بهتری در مقایسه با نسبت فرکانسی است. 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 کلاسه‌ها روشن‌تر می‌کنند. در هر دو سازه، بیشترین خطاها در کلاس ۱ رخ داده که اغلب با کلاسه‌های 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 کلاسه‌ها ربط دارد. در مقابل، برای نسبت میرایی (به‌ویژه در سازه پنج طبقه)، مدل‌ها با خطای کمتر کلاسه‌ها را تفکیک کرده و ماتریس‌ها توزیع متعادلی از پیش‌بینی‌های صحیح نشان می‌دهند، که نشان‌دهنده ساختار منظم‌تر داده‌ها و تفکیک‌پذیری بالای کلاسه‌های میرایی است. بنابراین، ضعف پیش‌بینی کلاسه‌های 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

جدول 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 کلاسه‌های ۱ و ۲ ضعیف‌تر بوده (AUC به ترتیب برابر با ۰/۵۵ و ۰/۶۳) که این موضوع با ضعف مدل در مرزهای بین کلاسه‌ها 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 کلاسه 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 محسوس 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 کلاسه‌های 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 کلاسه‌های میرایی برای سازه‌های بلندتر می‌باشد. این نمودارها علاوه بر تأیید روند نتایج جدول ۴ و ۵ گزارش شده،



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).

منابع

- [1] 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.
- [2] V.J. Modi, F. Welt, Damping of wind induced oscillations through liquid sloshing, *Journal of Wind Engineering and Industrial Aerodynamics*, 30 (1998) 85-94.
- [3] Y. Tamura, K. Fujii, T. Ohtsuki, T. Wakahara, R. Kohsaka, Effectiveness of tuned liquid dampers under wind excitation, *Engineering Structures*, 17 (1995) 609-621.
- [4] 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.
- [5] M. Domizio, D. Ambrosini, A. Campi, A novel tuned liquid damper for vibration control in high-frequency structures, *Engineering Structures*, 301 (2024) p.117350.
- [6] J.S. Love, M.J. Tait, The influence of tank orientation angle on a 2D structure-tuned liquid damper system,

آینده، تعمیم مدل به سازه‌های پیچیده‌تر و استفاده از روش‌های یادگیری عمیق پیشنهاد می‌شود.

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.

- Liquid Column Dampers with Different Elbow Forms, Turkish Journal of Civil Engineering, 35 (2024).
- [17] 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.
- [18] 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.
- [19] P. Banerji, A. Samanta, Earthquake vibration control of structures using hybrid mass liquid damper, Engineering Structures, 33 (2011) 1291-1301.
- [20] 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.
- [21] G.W. Housner, The dynamic behavior of water tanks, Bulletin of the Seismological Society of America, 53 (1963) 381-387.
- [22] 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.
- [23] M.A. Haroun, G.W. Housner, Dynamic characteristics of liquid storage tanks, Journal of the Engineering Mechanics Division, 108 (1982) 783-800.
- [24] 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.
- [25] 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.
- [26] 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, Journal of Vibration and Acoustics, 135 (2013) p.011010.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] A. Ghosh, B. Basu, Seismic vibration control of short period structures using the liquid column damper, Engineering Structures, 26 (2004) 1905-1913.
- [16] M.C. Aydemir, E. Damcı, Y. Taşkın, Ç. ekerçi, Comparison of the Dynamic Characteristics of Tuned

- liquids for lateral displacement control of single and multi-story structures, *Buildings*, 12 (2022) p.377.
- [33] 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.
- [34] 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.
- [35] 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).
- [36] 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).
- [37] Y. Li, Q. Di, Y. Gong, Equivalent mechanical models of sloshing fluid in arbitrary-section aqueducts, *Earthquake Engineering & Structural Dynamics*, 41 (2012) 1069-1087.
- Mechanical Systems and Signal Processing, 220 (2024) p.111702.
- [27] 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.
- [28] 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.
- [29] H. Ghaffarzadeh, A. Aran, M. Hosseinlou, Optimal parameters of rooftop pools as the structural control system, *Journal of Structural and Construction Engineering*, (2024).
- [30] 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.
- [31] 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.
- [32] A. Ocak, G. Bekdaş, S.M. Nigdeli, S. Kim, Z.W. Geem, Optimization of tuned liquid damper including different

چگونه به این مقاله ارجاع دهیم

H. Ghaffarzadeh, A. R. Aran, A. R. Binavayan, *Optimal Parameter Prediction in Tuned Liquid Mass Dampers Using Machine Learning Classification Models*, *Amirkabir J. Civil Eng.*, 58(1) (2026) 23-42.

DOI: [10.22060/ceej.2026.24783.8348](https://doi.org/10.22060/ceej.2026.24783.8348)



