

Đánh giá an toàn động đất của giàn thép phi tuyến sử dụng các thuật toán học máy phân loại

Hà Mạnh Hùng¹, Trương Việt Hùng^{2*}

¹ Khoa Xây dựng dân dụng và công nghiệp, Trường Đại học Xây dựng Hà Nội

² Khoa Công trình, Trường Đại học Thủy lợi

TỪ KHOÁ

Phân loại an toàn
 Học máy
 Giàn thép phi tuyến
 Động đất
 LightGBM

TÓM TẮT

Phân tích lịch sử thời gian phi tuyến đánh giá kháng chấn giàn thép có độ chính xác cao nhưng tốn kém khối lượng tính toán. Nghiên cứu này đề xuất dùng các mô hình học máy phân loại trạng thái giới hạn (An toàn/Nguy hiểm) để dự báo nhanh chuyển vị động đất của giàn phẳng 39 thanh. Hiệu suất của năm thuật toán (hồi quy Logistic, máy véc-tơ hỗ trợ, rừng ngẫu nhiên, LightGBM, mạng học sâu) được đánh giá toàn diện. Kết quả cho thấy ranh giới an toàn phi tuyến cực mạnh của hệ kết cấu đã làm vô hiệu hóa các mô hình tuyến tính. Nhằm hạn chế tối đa Lỗi loại II (bỏ sót thiết kế nguy hiểm), LightGBM và Random Forest thể hiện sự vượt trội với chỉ số Độ nhạy (Recall) và F1-Score cao nhất. Đáng chú ý, LightGBM có tốc độ huấn luyện siêu việt, khắc phục triệt để nhược điểm thất cổ chai tính toán của SVM và MLP. Sự cân bằng hoàn hảo giữa khả năng nhận diện rủi ro chính xác và tốc độ cực nhanh khẳng định LightGBM là mô hình thay thế lý tưởng cho bài toán tối ưu hóa độ tin cậy kết cấu quy mô lớn.

KEYWORDS

Safety classification
 Machine learning
 Nonlinear steel truss
 Seismic
 LightGBM

ABSTRACT

Nonlinear time-history analysis for the seismic evaluation of steel trusses is highly accurate but computationally expensive. This study proposes the use of machine learning classification models to rapidly predict the seismic limit state (Safe/Unsafe) of a 39-bar planar truss. The performance of five algorithms (Logistic Regression, SVM, Random Forest, LightGBM, and MLP) is comprehensively evaluated. The results demonstrate that the highly nonlinear safety boundary of the structural system renders linear models ineffective. To strictly minimize Type II errors (failing to detect dangerous designs), LightGBM and Random Forest exhibit clear superiority by maintaining the highest Recall and F1-Scores. Notably, LightGBM possesses an exceptional training speed, thoroughly overcoming the computational bottlenecks associated with SVM and MLP. The perfect balance between accurate risk identification and ultra-fast computational speed confirms LightGBM as an ideal surrogate model for large-scale structural reliability optimization problems.

1. Giới thiệu

Động đất là một trong những thảm họa thiên nhiên gây hậu quả nghiêm trọng nhất đối với tính toàn vẹn cấu trúc và khả năng vận hành của các công trình xây dựng [1, 2]. Do đó, việc thiết kế kết cấu kháng chấn là một yêu cầu thiết yếu, trong đó quá trình kiểm soát chuyển vị ngang (lateral deflection) và độ lệch tầng (inter-story drift) đóng vai trò cốt lõi nhằm đảm bảo an toàn sinh mạng và giới hạn mức độ hư hỏng [3]. Các phương pháp phân tích kháng chấn truyền thống thường dựa trên giả thiết đàn hồi tuyến tính, dẫn đến việc không phản ánh đầy đủ ứng xử thực tế của kết cấu dưới các chấn động mạnh. Mặc dù phương pháp phân tích động lực học phi tuyến theo lịch sử thời gian (nonlinear time-history analysis - NTHA) mang lại độ chính xác cao nhất thông qua việc mô phỏng chi tiết các đặc tính phi tuyến vật liệu và hình học, phương pháp này lại đòi hỏi khối lượng tính toán khổng lồ và tiêu tốn rất nhiều thời gian [4].

Nhằm khắc phục những rào cản về mặt chi phí tính toán, các thuật toán Học máy (Machine Learning - ML) đang trở thành một phương pháp tiếp cận đầy hứa hẹn nhờ khả năng nắm bắt và mô hình hóa các mối quan hệ phi tuyến phức tạp [5-7]. Bằng cách xây dựng các mô hình toán học xấp xỉ (metamodels), thuật toán học máy đã được ứng dụng thành công trong nhiều bài toán kỹ thuật kết cấu, tiêu biểu như: dự đoán phổ công suất tải trọng gió trên nhà cao tầng [8], đánh giá biến dạng dọc trục của bê tông cốt sợi FRP [9], ước tính ứng suất bám dính [10], dự đoán sức kháng cắt của dầm [11], độ bền kéo của bê tông tái chế [12], cũng như đánh giá khả năng chịu tải của các kết cấu thép [13, 14].

Đối với cấu kiện giàn, học máy đã chứng minh được hiệu quả vượt trội trong công tác nhận dạng hư hỏng [15-22] và đóng vai trò như một mô hình thay thế (surrogate model) giúp giải quyết các bài toán tối ưu hóa một cách nhanh chóng [23-25]. Dưới tác động của tải trọng động đất, các công cụ phân tích dữ liệu như Mạng nơ-ron nhân

*Liên hệ tác giả: truongviethung@tlu.edu.vn

Nhận ngày 28/05/2026, sửa xong ngày 18/06/2026, chấp nhận đăng ngày 28/06/2026

Link DOI: <https://doi.org/10.54772/jomc.03.2026.1424>

tạo (ANN) hay học tập kết hợp (ensemble learning) cũng đang được quan tâm sâu rộng nhằm dự báo phản ứng cấu trúc [26-28]. Đáng chú ý, thay vì sử dụng mô hình hồi quy (regression) để dự báo giá trị liên tục, một số nghiên cứu gần đây đã bắt đầu áp dụng các mô hình phân loại (classification models) để nhận dạng phương thức phá hoại kháng chấn [29] hoặc đánh giá nhanh cấp độ hư hỏng của khung thép [30].

Mặc dù vậy, các nghiên cứu ứng dụng mô hình học máy trên kết cấu giàn hiện nay chủ yếu tập trung vào tải trọng tĩnh hoặc sử dụng mô hình hồi quy để dự báo giá trị chuyển vị. Việc chuyển đổi bài toán từ hồi quy sang phân loại (An toàn/Nguy hiểm) không chỉ giúp loại bỏ các nhiễu dự báo không cần thiết mà còn cung cấp cơ sở ra quyết định trực tiếp, phục vụ hiệu quả cho các hệ thống cảnh báo sớm và phân tích độ tin cậy. Để lấp đầy khoảng trống tri thức này, nghiên cứu được thực hiện nhằm đánh giá và so sánh toàn diện hiệu suất của năm thuật toán học máy phân loại tiên tiến (bao gồm Hồi quy Logistic, máy véc-tơ hỗ trợ, rừng ngẫu nhiên, LightGBM và mạng học sâu) trong việc nhận dạng trạng thái an toàn chuyển vị của giàn thép phi tuyến chịu tải trọng động đất. Kết quả của nghiên cứu kỳ vọng sẽ cung cấp cho người đọc thông tin chi tiết về hiệu suất các thuật toán học máy trong lớp bài toán này, qua đó có cơ sở lựa chọn phù hợp trong thực tiễn công việc, cân bằng giữa độ chính xác phân loại và hiệu quả chi phí tính toán.

2. Phương pháp nghiên cứu

2.1. Mô hình phân tích động lực học phi tuyến

Dữ liệu của nghiên cứu được tạo ra thông qua phương pháp phân tích lịch sử thời gian phi tuyến (nonlinear time-history analysis) của các kết cấu giàn thép dưới tác dụng của gia tốc nền động đất. Phương trình chuyển động gia số tại mỗi bước thời gian t được thiết lập dựa trên nguyên lý công ảo và phương pháp Lagrangian cập nhật, có dạng:

$$[M]\{\Delta \ddot{\mathbf{u}}\} + [C]\{\Delta \dot{\mathbf{u}}\} + [K_t]\{\Delta \mathbf{u}\} = \{\Delta \mathbf{P}\} \quad (1)$$

Trong đó, $\{\Delta \ddot{\mathbf{u}}\}$, $\{\Delta \dot{\mathbf{u}}\}$ và $\{\Delta \mathbf{u}\}$ lần lượt là các véc-tơ gia số gia tốc, vận tốc và chuyển vị của các nút kết cấu. Các ma trận $[M]$ và $[C]$ là ma trận khối lượng và ma trận cản. Ma trận độ cứng tiếp tuyến $[K_t] = [K_E] + [K_G] + [K_P]$ bao hàm ma trận độ cứng đàn hồi, độ cứng hình học và các thành phần ma trận thể hiện ứng xử phi tuyến vật liệu (chảy dẻo, mất ổn định đàn dẻo sau tới hạn). Ma trận cản $[C]$ được thiết lập theo mô hình cản Rayleigh:

$$[C] = \alpha_M [M] + \beta_K [K_t] \quad (2)$$

Trong đó, α_M và β_K là hệ số cản tỷ lệ với khối lượng và độ cứng. Hai hệ số này thường được xác định bằng cách giải hệ phương trình liên hệ với tỷ số cản thiết kế (thường lấy $\xi = 5\%$ đối với kết cấu thép) và hai tần số góc tự nhiên bậc thấp của kết cấu (ω_i và ω_j) như sau:

$$\begin{cases} \alpha_M = \xi \frac{2\omega_i \omega_j}{\omega_i + \omega_j} \\ \beta_K = \xi \frac{2}{\omega_i + \omega_j} \end{cases} \quad (3)$$

Phương trình chuyển động được giải quyết thông qua phương pháp tích phân trực tiếp Newmark kết hợp với thuật toán lặp Newton-Raphson để cân bằng lực dư tại mỗi gia số thời gian.

2.2. Xây dựng và tiền xử lý dữ liệu

Cơ sở dữ liệu được tạo ra từ chương trình phân tích kết cấu giàn thép sử dụng NTHA được trình bày ở phần trên thông qua phần mềm PAAP [16]. Các dữ liệu này được tạo ngẫu nhiên trong miền giá trị của các biến số là tiết diện của các thanh giàn và được tách thành 2 tập độc lập: tập huấn luyện và à tập kiểm tra. Ma trận dữ liệu thô bao gồm các biến độc lập \mathbf{X} (diện tích tiết diện của các phần tử giàn), và biến mục tiêu y_{cont} (là tỷ số giữa chuyển vị ngang cực đại và giới hạn cho phép).

Để chuyển đổi bài toán từ phân tích hồi quy sang phân loại, một hàm bước nhảy được áp dụng trực tiếp lên biến mục tiêu liên tục $y_{cont,i}$ của mẫu thứ i . Trạng thái của kết cấu được gán nhãn nhị phân dựa trên ngưỡng an toàn 1.0:

$$y_i = \begin{cases} 0 & \text{khi } y_{cont,i} \leq 1.0 \text{ (An toàn)} \\ 1 & \text{khi } y_{cont,i} > 1.0 \text{ (Nguy hiểm)} \end{cases} \quad (4)$$

Do các biến diện tích tiết diện có biên độ dao động và phân bố khác nhau, việc chuẩn hóa dữ liệu là bắt buộc nhằm đảm bảo sự hội tụ của các thuật toán nhạy cảm với khoảng cách (như SVM hay MLP). Đặc biệt, để ngăn chặn triệt để hiện tượng rò rỉ dữ liệu (Data Leakage) từ tập kiểm tra vào quá trình huấn luyện mô hình, phương pháp chuẩn hóa Z-score (StandardScaler) được áp dụng. Cụ thể, giá trị trung bình $\mu_{train,j}$ và độ lệch chuẩn $\sigma_{train,j}$ của đặc trưng thứ j chỉ được trích xuất duy nhất từ tập huấn luyện. Sau đó, các thông số này được sử dụng để chuẩn hóa cả tập huấn luyện và tập kiểm tra theo hệ phương trình sau:

$$\begin{cases} x'_{train,ij} = \frac{x_{train,ij} - \mu_{train,j}}{\sigma_{train,j}} \\ x'_{test,ij} = \frac{x_{test,ij} - \mu_{train,j}}{\sigma_{train,j}} \end{cases} \quad (5)$$

Việc thiết lập và tiền xử lý dữ liệu một chiều như trên đảm bảo rằng mô hình học máy không được tiếp xúc với bất kỳ thông tin thống kê nào của tập dữ liệu kiểm tra, qua đó phản ánh chính xác khả năng tổng quát hóa của thuật toán đối với dữ liệu chưa từng thấy trong thực tế.

2.3. Cơ sở toán học của các thuật toán học máy

Để thiết lập mô hình thay thế (surrogate model) dự đoán trạng thái an toàn của giàn thép, nghiên cứu lựa chọn năm thuật toán đại diện cho phổ cấu trúc học máy từ đơn giản đến phức tạp: từ mô hình tuyến tính cơ sở (Logistic Regression), mô hình phân chia không gian bằng siêu mặt phẳng (SVM), các mô hình học tập kết hợp dạng cây (Random Forest, LightGBM), cho đến mô hình xấp xỉ phi tuyến phổ quát (MLP). Sự đa dạng này cho phép đánh giá toàn diện sự đánh đổi (trade-off) giữa độ chính xác khi nắm bắt ứng xử phi tuyến của kết cấu và chi phí tính toán.

2.3.1. Hồi quy Logistic (Logistic Regression - LR)

LR được sử dụng như một mô hình cơ sở (baseline model). Việc áp dụng LR nhằm mục đích kiểm chứng mức độ phức tạp của bài toán. Nếu LR cho kết quả kém, điều này minh chứng bằng toán học rằng ranh giới trạng thái an toàn/nguy hiểm của giàn thép dưới động đất có tính phi tuyến cực kỳ cao, bắt buộc phải sử dụng các thuật toán AI phức tạp hơn. LR ước lượng xác suất kết cấu rơi vào trạng thái nguy hiểm ($y_i = 1$) thông qua việc ánh xạ tổ hợp tuyến tính của các biến đầu vào \mathbf{x}_i qua hàm kích hoạt Sigmoid:

$$P(y_i = 1 | \mathbf{x}_i) = \frac{1}{1 + \exp(-(\mathbf{w}^T \mathbf{x}_i + b))} \quad (6)$$

Mục tiêu của quá trình huấn luyện là tìm kiếm véc-tơ trọng số \mathbf{w} và hệ số chệch b nhằm cực tiểu hóa hàm mất mát (Log-loss):

$$L(\mathbf{w}, b) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (7)$$

2.3.2. Máy véc-tơ hỗ trợ (Support Vector Machine - SVM)

Khi phân tích lịch sử thời gian phi tuyến cho thấy ứng xử dẻo của kết cấu là phi tuyến mạnh, SVM là một thuật toán nổi bật nhờ khả năng ánh xạ dữ liệu vào không gian nhiều chiều thông qua thủ thuật hàm nhân (Kernel trick), giúp thiết lập ranh giới phân lớp rõ ràng ngay cả khi dữ liệu có kích thước vừa và nhỏ. Thay vì tối ưu hóa xác suất, SVM tìm kiếm một siêu mặt phẳng (hyperplane) giúp tối đa hóa khoảng cách biên (margin) giữa hai lớp an toàn và nguy hiểm. Bài toán được phát biểu dưới dạng tối ưu hóa đối ngẫu kết hợp với các biến lỏng (slack variables, ξ_i) nhằm cho phép một tỷ lệ sai số nhất định.

$$\min_{\mathbf{w}, b, \xi} \left(\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \right) \quad (8)$$

Với điều kiện ràng buộc: $y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \forall i$. Để xử lý tính phi tuyến của giàn thép, hàm nhân cơ sở xuyên tâm (RBF Kernel) được áp dụng:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (9)$$

với γ là siêu tham số kiểm soát tầm ảnh hưởng của các điểm dữ liệu hỗ trợ.

2.3.3. Rừng ngẫu nhiên (Random Forest - RF)

Đặc thù dữ liệu sinh ra từ phân tích động đất thường chứa độ nhiễu cao do tính chất ngẫu nhiên của gia tốc nền. RF thuộc họ học tập kết hợp (Ensemble learning) dựa trên kỹ thuật Bagging, có khả năng giảm phương sai (variance) xuất sắc, giúp mô hình miễn nhiễm với hiện tượng quá khớp (overfitting) và xử lý tốt các nhiễu động học. RF xây dựng một tập hợp gồm K cây quyết định độc lập $\{h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_K(\mathbf{x})\}$. Mỗi cây được huấn luyện trên một tập dữ liệu con lấy mẫu ngẫu nhiên có hoàn lại (bootstrap sample). Tại mỗi nút phân nhánh, một tập con ngẫu nhiên các đặc trưng được lựa chọn để tìm điểm chia tối ưu dựa trên việc cực tiểu hóa chỉ số Gini Impurity:

$$G = 1 - \sum_{c=0}^1 p_c^2 \quad (10)$$

(trong đó p_c là tỷ lệ mẫu thuộc lớp c tại nút đó). Kết quả dự đoán cuối cùng được xác định thông qua cơ chế bầu chọn đa số (majority voting):

$$\hat{y}_i = \text{mode}\{h_1(\mathbf{x}_i), h_2(\mathbf{x}_i), \dots, h_K(\mathbf{x}_i)\} \quad (11)$$

2.3.4. LightGBM (Light Gradient Boosting Machine)

Trong các phân tích độ tin cậy ngẫu nhiên (như mô phỏng Monte Carlo), mô hình ML cần dự đoán hàng triệu kịch bản. Các thuật toán như SVM hay MLP thường gặp khó khăn về thời gian tính toán. LightGBM giải quyết triệt để rào cản này bằng cách tối ưu hóa tốc độ học với bộ nhớ thấp nhất, trở thành công cụ mạnh mẽ nhất cho các hệ thống cảnh báo an toàn thời gian thực. Kế thừa nguyên lý tăng cường độ dốc (Gradient Boosting), LightGBM xây dựng các cây quyết định tuần tự, trong đó cây sau tập trung sửa lỗi của cây trước bằng cách khớp với sai số dư (pseudo-residuals). Hàm mục tiêu tích lũy sau M bước lặp có dạng:

$$F_M(\mathbf{x}) = \sum_{m=1}^M \gamma_m h_m(\mathbf{x}) \quad (12)$$

Sự đột phá của LightGBM nằm ở kỹ thuật lấy mẫu một phía dựa trên gradient (GOSS - Gradient-based One-Side Sampling) và chiến lược phát triển cây theo chiều sâu của lá (Leaf-wise tree growth). Thuật toán ưu tiên rẽ nhánh ở chiếc lá có lượng hao hụt (loss) lớn nhất, giúp hội tụ cực nhanh so với chiến lược rẽ nhánh theo mức (level-wise) truyền thống.

2.3.5. Mạng nơ-ron nhân tạo đa lớp (Multilayer Perceptron - MLP)

Dựa trên định lý xấp xỉ phổ quát (Universal Approximation Theorem), MLP có khả năng biểu diễn mọi hàm toán học phi tuyến phức tạp nhất. Nó được chọn để đánh giá xem liệu cấu trúc học sâu (Deep Learning) có mang lại sự đột phá về độ chính xác so với các thuật toán dạng cây khi kích thước dữ liệu tăng lên hay không. Cấu trúc của MLP bao gồm một lớp đầu vào, các lớp ẩn (hidden layers) và một lớp đầu ra. Sự biến đổi phi tuyến của tín hiệu đi qua lớp ẩn thứ l được biểu diễn qua phương trình ma trận:

$$\mathbf{h}^{(l)} = f(\mathbf{W}^{(l)} \mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}) \quad (13)$$

Trong đó, $\mathbf{W}^{(l)}$ và $\mathbf{b}^{(l)}$ là ma trận trọng số và véc-tơ chệch, $f(\cdot)$ là hàm kích hoạt phi tuyến (như ReLU: $f(z) = \max(0, z)$). Tại lớp đầu ra, hàm Sigmoid được áp dụng để tính toán xác suất phân loại. Quá trình cập nhật trọng số được thực hiện tự động thông qua thuật toán lan truyền ngược (Backpropagation) kết hợp với các bộ tối ưu hóa theo gradient (như Adam hoặc SGD) nhằm cực tiểu hóa hàm mất mát.

2.4. Tối ưu hóa siêu tham số

Hiệu suất của các mô hình học máy phụ thuộc rất lớn vào việc thiết lập các siêu tham số (hyperparameters). Thay vì sử dụng các giá trị mặc định, nghiên cứu này áp dụng chiến lược tìm kiếm ngẫu nhiên

(Randomized Search Cross-Validation - RandomizedSearchCV) để quét qua không gian siêu tham số của từng thuật toán. Phương pháp này được chứng minh là hiệu quả hơn về mặt tính toán so với Grid Search, đặc biệt trong không gian tham số có số chiều lớn.

Quá trình tối ưu hóa được thực hiện với cơ chế kiểm chéo 3 nếp gấp (3-fold cross-validation) nhằm tránh hiện tượng quá khớp (overfitting) ngay từ giai đoạn huấn luyện. Để khắc phục sự ảnh hưởng của việc mất cân bằng dữ liệu (nếu có) và nhấn mạnh vào mục tiêu an toàn, hàm mục tiêu dùng để đánh giá trong quá trình tìm kiếm được thiết lập là chỉ số F1-Score thay vì độ chính xác (Accuracy) thông thường. Các bộ tham số tối ưu (ví dụ: tham số điều chuẩn C của LR và SVM; độ sâu tối đa max_depth và tốc độ học learning_rate của LightGBM; hay cấu trúc lớp ẩn hidden_layer_sizes của MLP) sẽ được trích xuất và sử dụng cho các bước đánh giá tiếp theo.

2.5. Tiêu chí đánh giá hiệu suất

Để lượng hóa khả năng nhận diện rủi ro động đất của các thuật toán, một ma trận nhầm lẫn (Confusion Matrix) được thiết lập. Trong bài toán kỹ thuật này, trạng thái “Nguy hiểm” (chuyển vị vượt ngưỡng) được định nghĩa là lớp Tích cực (Positive - Nhân 1), và trạng thái “An toàn” là lớp Tiêu cực (Negative - Nhân 0). Bốn thành phần cơ bản bao gồm: TP (True Positive): Số mẫu thực tế Nguy hiểm và dự đoán đúng là Nguy hiểm. TN (True Negative): Số mẫu thực tế An toàn và dự đoán đúng là An toàn. FP (False Positive - Lỗi loại I): Số mẫu thực tế An toàn nhưng dự báo nhầm là Nguy hiểm. FN (False Negative - Lỗi loại II): Số mẫu thực tế Nguy hiểm nhưng dự báo sai là An toàn. Dựa trên ma trận này, bốn chỉ số thống kê được sử dụng để đánh giá toàn diện mô hình:

Độ chính xác tổng thể (Accuracy): Đo lường tỷ lệ dự đoán đúng trên toàn bộ tập dữ liệu:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

Độ chính xác (Precision): Tỷ lệ kết cấu thực sự nguy hiểm trong số các kết cấu bị hệ thống cảnh báo:

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

Độ nhạy (Recall): Tỷ lệ phát hiện thành công các trường hợp kết cấu bị hư hỏng:

$$Recall = \frac{TP}{TP + FN} \quad (16)$$

Chỉ số F1 (F1-Score): Là trung bình điều hòa giữa Precision và Recall:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (17)$$

Về mặt Kỹ thuật công trình, trong thiết kế kháng chấn, hậu quả của việc xảy ra Lỗi loại II (FN - bỏ sót một kết cấu nguy hiểm dẫn đến sụp đổ) là thảm khốc và tốn kém hơn rất nhiều so với Lỗi loại I (FP - cảnh báo nhầm dẫn đến thiết kế thiên về an toàn và tốn thêm vật liệu). Do đó, chỉ số Recall và F1-Score được coi là các tiêu chí quyết định trong nghiên cứu này. Bên cạnh đó, Thời gian huấn luyện cũng được ghi nhận để so sánh tính khả thi khi áp dụng thuật toán vào các bài toán tối ưu hóa quy mô lớn.


2.6. Thiết lập thực nghiệm

Để kiểm chứng tính ổn định và khả năng tổng quát hóa của các mô hình khi khối lượng dữ liệu thay đổi, nghiên cứu thiết lập một quy trình đánh giá lặp. Tập kiểm tra được giữ cố định ở mức 2000 mẫu để tạo thước đo công bằng. Trong khi đó, kích thước tập huấn luyện được khảo sát ở ba mức độ khác nhau: 1000, 2000 và 5000 mẫu.


Để loại bỏ các sai số hệ thống do việc chia tách dữ liệu ngẫu nhiên, tại mỗi kích thước tập huấn luyện, quy trình đánh giá được lặp lại 10 lần độc lập. Trong mỗi lần chạy, các mẫu huấn luyện khác nhau được lựa chọn ngẫu nhiên trong tập dữ liệu huấn luyện lớn. Kết quả cuối cùng của các chỉ số hiệu suất (Accuracy, Precision, Recall, F1-Score, và Thời gian) là giá trị trung bình thống kê của 10 lần chạy lặp lại này. Cách tiếp cận này đảm bảo các kết luận rút ra về sức mạnh của từng thuật toán là khách quan và có độ tin cậy toán học cao nhất.

3. Trường hợp nghiên cứu

Để kiểm chứng hiệu suất của các thuật toán phân loại, nghiên cứu tiến hành khảo sát trường hợp kết cấu giàn thép phẳng 39 thanh với sơ đồ kết cấu như trong Hình 1 gồm 39 thanh chia thành 39 nhóm biến thiết kế là diện tích tiết diện thanh lấy trong miền giá trị [645.16, 3225.8] (mm²). Giàn chịu tác động của tĩnh tải DL = 150 (kN) tại các nút giàn, và gia tốc nền động đất El Centro (PGA=0.319g) như trong Hình 2 với các khối lượng tập trung lấy bằng 5 (tấn) tại nút. Dữ liệu đầu vào của mô hình học máy là diện tích tiết diện của các nhóm thanh được phân chia theo cấu trúc hình học, đóng vai trò là các biến thiết kế. Mục tiêu của bài toán là dự đoán trạng thái an toàn của kết cấu dựa trên giới hạn chuyển vị ngang cực đại cho phép của kết cấu giàn khi chịu động đất (lấy bằng 0.02h với h là chiều cao tầng giàn). Lúc này, nếu tỷ số giữa chuyển vị ngang đo được và giới hạn cho phép nhỏ hơn hoặc bằng 1.0, kết cấu được gán nhãn “An toàn” (Nhân 0); ngược lại, được gán nhãn “Nguy hiểm” (Nhân 1).




Hình 1. Sơ đồ giàn phẳng 39 thanh.



Hình 2. Sơ đồ giàn phẳng 39 thanh.

Hình 3 thể hiện sự phân bố độ võng ngang tối đa khi giàn chịu động đất của 20000 mẫu. Có thể thấy tỷ số chuyển vị (đã chuẩn hóa) tuân theo một phân bố xấp xỉ phân bố chuẩn nhưng có phần đuôi lệch phải (right-skewed). Đa số các thiết kế ngẫu nhiên tập trung quanh dải giá trị từ 0.6 đến 0.9. Đường ranh giới đứt nét tại vị trí 1.0 chính là ngưỡng an toàn tối hạn. Các điểm dữ liệu nằm bên phải ngưỡng này đại diện cho các trạng thái kết cấu bị phá hoại hoặc vượt quá giới hạn dẻo dưới tác dụng của tải trọng động đất. Dữ liệu phân loại tồn tại sự mất cân bằng giữa hai lớp, trong đó số lượng kết cấu đạt trạng thái "An toàn" chiếm tỷ trọng lớn hơn đáng kể so với các kịch bản "Nguy hiểm". Trong kỹ thuật công trình, đặc tính mất cân bằng này là hoàn toàn hợp lý với thực tiễn thiết kế; tuy nhiên, dưới góc độ học máy, nó tiềm ẩn nguy cơ mô hình dự đoán thiên vị về lớp đa số. Trong những trường hợp như thế này, việc sử dụng F1-Score và Recall là phù hợp để đánh giá chính xác năng lực của các thuật toán.



Hình 3. Phân bố của tỷ số giữa chuyển vị ngang đo được và giới hạn cho phép của giàn.


Để đảm bảo các mô hình phát huy tối đa năng lực nhận dạng ranh giới phi tuyến, kỹ thuật RandomizedSearchCV (kiểm chéo 3-fold) đã được áp dụng để tối ưu hóa siêu tham số dựa trên việc cực đại hóa chỉ số F1-Score. Bảng 1 trình bày bộ siêu tham số tối ưu cho năm thuật toán sau quá trình tìm kiếm.

Bảng 1. Tham số tối ưu của các thuật toán.


| Thuật toán | Cấu hình siêu tham số tối ưu |
|-----------------------|--|
| Hồi quy Logistic (LR) | Tham số điều chuẩn: $C = 0.1$ |
| SVM (RBF) | Tham số điều chuẩn: $C = 10$; Hệ số kernel: $\gamma = 0.01$ |

| | |
|---------------------|--|
| Random Forest (RF) | Số mẫu tối thiểu ở nút lá: $min_samples_leaf = 2$ Tỷ lệ mẫu tối đa: $max_samples = 0.9$ Độ sâu tối đa của cây: $max_depth = 20$ |
| LightGBM | Tốc độ học: $learning_rate = 0.1$ Độ sâu tối đa: $max_depth = 15$; Số lượng lá: $num_leaves = 31$ Điều chuẩn L1: $reg_alpha = 0.1$; Điều chuẩn L2: $reg_lambda = 0.0$ |
| MLP (Deep Learning) | Cấu trúc lớp ẩn: $hidden_layer_sizes = (128, 64, 32)$ Tham số phạt (L2 penalty): $\alpha = 0.1$ |

Hình 4 thể hiện giá trị F1-Score của các thuật toán. Quan sát Hình 4 cho thấy, Hồi quy Logistic (LR) cho hiệu suất kém nhất và gần như không cải thiện khi tăng kích thước dữ liệu, chứng minh bằng toán học rằng ứng xử của giàn 39 thanh dưới động đất là phi tuyến cực mạnh, vượt quá khả năng phân chia của mặt phẳng tuyến tính. Mạng nơ-ron (MLP) cho thấy sự gia tăng hiệu suất mạnh mẽ khi lượng dữ liệu tăng từ 1000 lên 5000 mẫu, minh chứng cho đặc tính đòi hỏi dữ liệu lớn của học sâu. Tuy nhiên, hai mô hình Ensemble dạng cây là RF và LightGBM duy trì vị thế dẫn đầu tuyệt đối ở mọi kích thước tập huấn luyện, cho thấy khả năng chống nhiễu và trích xuất ranh giới an toàn cực kỳ ổn định.



Hình 4. So sánh F1-Score của các thuật toán cho tập kiểm tra.




Hình 5. So sánh Recall của các thuật toán cho tập kiểm tra.

Hình 5 thể hiện chỉ số Recall của các thuật toán. Chỉ số Recall thể hiện khả năng hệ thống “không bỏ sót” các thiết kế nguy hiểm (tránh Lỗi loại II). Hình 5 cho thấy một xu hướng tương đồng với F1-Score, nhưng làm nổi bật hơn nữa sự chênh lệch giữa các mô hình. LightGBM và RF đều đạt mức Recall tiệm cận 0.9 khi $N = 5000$, đồng nghĩa với việc chúng phát hiện được 90% các kịch bản sụp đổ tiềm năng. Việc

SVM và MLP có chỉ số Recall không ổn định ở tập dữ liệu nhỏ ($N = 1000$) cho thấy rủi ro khi ứng dụng chúng cho các hệ thống cảnh báo sớm nếu dữ liệu mô phỏng bị hạn chế.

Hình 6 trình bày biểu đồ thời gian huấn luyện bộc lộ rõ ràng cản ứng dụng của các thuật toán. MLP và đặc biệt là SVM tiêu tốn thời gian tính toán tăng theo cấp số nhân khi kích thước dữ liệu mở rộng. Với $N = 5000$, thời gian huấn luyện của SVM đã cao hơn LightGBM hàng chục lần. Ngược lại, nhờ chiến lược phát triển cây theo chiều sâu của lá (leaf-wise) và kỹ thuật GOSS, đường biểu diễn thời gian của LightGBM gần như nằm ngang ở mức sát đáy của biểu đồ. Nó cho tốc độ học cực kỳ ấn tượng (chỉ mất vài phần phân số của giây) bất chấp lượng dữ liệu tăng lên.



Hình 6. So sánh thời gian huấn luyện mô hình của các thuật toán.

Từ các phân tích hình ảnh và dữ liệu thực nghiệm trên trường hợp giàn 39 thanh, có thể khẳng định rằng LightGBM mang lại sự đánh đổi tốt nhất trong các thuật toán được xem xét. Nó sở hữu độ chính xác và độ nhạy (Recall) sánh ngang với Rừng ngẫu nhiên và Mạng học sâu, nhưng lại vượt trội hoàn toàn về tốc độ tính toán, biến nó trở thành mô hình thay thế lý tưởng nhất cho phân tích độ tin cậy kết cấu kháng chấn.

4. Kết luận

Bài báo đã đề xuất sử dụng các mô hình học máy phân loại để đánh giá nhanh trạng thái an toàn kháng chấn của kết cấu giàn thép phi tuyến, nhằm khắc phục vấn đề chi phí tính toán của phương pháp phân tích lịch sử thời gian. Kết quả kiểm chứng trên giàn 39 thanh chịu động đất El Centro cho thấy ranh giới an toàn kết cấu có tính phi tuyến mạnh, khiến mô hình cơ sở (Hồi quy Logistic) hoàn toàn kém hiệu quả. Nhằm kiểm soát nghiêm ngặt Lỗi loại II (bỏ sót thiết kế nguy hiểm), các thuật toán học tập kết hợp dạng cây như LightGBM và Rừng ngẫu nhiên (RF) đã thể hiện sức mạnh vượt trội khi duy trì chỉ số Độ nhạy (Recall) và F1-Score cao nhất. Đặc biệt, khác với sự gia tăng thời gian tính toán theo cấp số nhân của SVM và Mạng nơ-ron (MLP) theo cỡ tập huấn luyện, LightGBM có tốc độ hội tụ cực nhanh nhờ chiến lược phát triển cây hướng lá và kỹ thuật lấy mẫu GOSS. Tóm lại, sự cân bằng hoàn hảo giữa năng lực nhận diện rủi ro chính xác và tốc độ tính toán siêu việt khẳng định LightGBM là mô hình thay thế lý tưởng nhất, hỗ trợ đắc lực cho các hệ thống cảnh báo sớm và tối ưu hóa độ tin cậy kết cấu quy mô lớn.

Lời cảm ơn

Nghiên cứu này được tài trợ bởi Trường Đại học Xây dựng Hà Nội (HUCE) trong đề tài mã số 01-2025/NNCM-ĐHXDHN.

Tài liệu tham khảo

- [1]. Y. N. Du, D. C. Feng, G. Wu, "InSAR-based rapid damage assessment of urban building portfolios following the 2023 Turkey earthquake", *International Journal of Disaster Risk Reduction*, 103, 104317 (2024).
- [2]. N. Li, B. Zhu, L. Zhang, S. Kishiki, "Damage analysis of a pseudoclastic reinforced concrete frame structure under the action of the Ms 6.8 Luding earthquake in China", *Structures*, 60, 105887 (2024).
- [3]. X. Lai, Z. He, Y. Wu, "Elastic inter-story drift seismic demand estimate of super high-rise buildings using coupled flexural-shear model with mass and stiffness non-uniformities", *Engineering Structures*, 226, 111378 (2021).
- [4]. P. Zakian, A. Kaveh, "Seismic design optimization of engineering structures: a comprehensive review", *Acta Mechanica*, 234(4), 1305-1330 (2023).
- [5]. V. H. Truong, S. Tangaramvong, G. Papazafeiropoulos, "An efficient LightGBM-based differential evolution method for nonlinear inelastic truss optimization", *Expert Syst. Appl.*, 237(Part B), 121530 (2024).
- [6]. V. H. Truong, C.T. Son, S. Tangaramvong, "A robust machine learning-based framework for handling time-consuming constraints for bi-objective optimization of nonlinear steel structures", *Structures*, 62, 106226 (2024).
- [7]. I. T. Yang, Y. H. Hsieh, "Reliability-based design optimization with cooperation between support vector machine and particle swarm optimization", *Engineering with Computers*, 29, 151-163 (2013).
- [8]. Y. Li, P. K. Yin, F. B. Chen, "Prediction of wind load power spectrum on high-rise buildings by various machine learning algorithms", *Structures*, 67, 107015968 (2024).
- [9]. W. Chen, J. Xu, M. Dong, Y. Yu, M. Elchalakani, F. Zhang, "Data-driven analysis on ultimate axial strain of FRP-confined concrete cylinders based on explicit and implicit algorithms", *Composite Structures*, 268, 113904 (2021).
- [10]. S. Zhang, J. Xu, T. Lai, Y. Yu, W. Xiong, "Bond stress estimation of profiled steel-concrete in steel reinforced concrete composite structures using ensemble machine learning approaches", *Engineering Structures*, 294, 116725 (2023).
- [11]. Y. Yu, X. Zhao, J. Xu, C. Chen, S. T. Deresa, J. Zhang, "Machine Learning-Based Evaluation of Shear Capacity of Recycled Aggregate Concrete Beams", *Materials*, 13(20), 4552 (2020).
- [12]. S. Zhang, W. Chen, J. Zu, T. Xie, "Use of interpretable machine learning approaches for quantitatively understanding the performance of steel fiber-reinforced recycled aggregate concrete: From the perspective of compressive strength and splitting tensile strength", *Engineering Applications of Artificial Intelligence*, 137, 109170 (2024).
- [13]. V. H. Truong, H. A. Pham, "Support vector machine for regression of ultimate strength of trusses: A comparative study", *Engineering Journal*, 25(7), 157-166 (2021).
- [14]. V. H. Truong, H. A. Pham, T. H. Van, S. Tangaramvong, "Evaluation of machine learning models for load-carrying capacity assessment of semi-rigid steel structures", *Engineering Structures*, 273, 115001 (2022).
- [15]. R. Machavaram, K. Shankar, "Structural damage identification using improved RBF neural networks in frequency domain", *Advances in Structural Engineering*, 15, 1689-1703 (2012).

- [16]. H.H. Nguyen, V.H. Truong, "Machine Learning-based prediction of seismic lateral deflection of steel trusses using nonlinear time-history analysis", *Structures*, 69, 107369 (2024).
- [17]. J. P. Shu, C. G. Zhang, X. Chen, Y. Niu, "Model-informed deep learning strategy with vision measurement for damage identification of truss structures", *Mechanical Systems and Signal Processing*, 196, 110327 (2023).
- [18]. T.D. Toan, V.H. Truong, "Support vector machine for short-term traffic flow prediction and improvement of its model training using nearest neighbor approach", *Transportation research record*, 2675 (4), 362-373 (2021).
- [19]. V.H. Truong, H.A. Pham, T.H. Van, S. Tangaramvong, "Evaluation of machine learning models for load-carrying capacity assessment of semi-rigid steel structures", *Engineering Structures*, 273, 115001 (2022).
- [20]. V.H. Truong, G. Papazafeiropoulos, Q.V. Vu, V.T. Pham, Z. Kong, "Predicting the patch load resistance of stiffened plate girders using machine learning algorithms", *Ocean Engineering*, 240, 109886 (2021).
- [21]. M. Farhadi, R. Ghiasi, P. Torkzadeh, "Damage detection of truss structures using meta-heuristic algorithms and optimized group method of data handling surrogate model", *Structures*, 65, 106736 (2024).
- [22]. B. Barros, B. Conde, M. Cabaleiro, B. Riveiro, "Design and testing of a decision tree algorithm for early failure detection in steel truss bridges", *Engineering Structures*, 289, 116243 (2023).
- [23]. E. Krempser, H. S. Bernardino, H. J. Barbosa, A. C. Lemonge, "Performance evaluation of local surrogate models in differential evolution-based optimum design of truss structures", *Engineering Computations*, 34(2), 499-547 (2017).
- [24]. T. H. Nguyen, A. T. Vu, "Speeding up Composite Differential Evolution for structural optimization using neural networks", *Journal of Information and Telecommunication*, 6(2), 101-120 (2022).
- [25]. H. Wu, Y. C. Wu, P. Zhi, X. Wu, T. Zhu, "Structural optimization of single-layer domes using surrogate-based physics-informed neural networks", *Heliyon*, 9, 10 (2023).
- [26]. R. Falcone, A. Ciaramella, F. Carrabs, N. Strisciuglio, E. Martinelli, "Artificial neural network for technical feasibility prediction of seismic retrofitting in existing RC structures", *Structures*, 41, 1220-1234 (2022).
- [27]. Z. Xu, J. Chen, J. Shen, M. Xiang, "Recursive long short-term memory network for predicting nonlinear structural seismic response", *Engineering Structures*, 250, 113406 (2022).
- [28]. S. Wang, J. Xu, Y. Wang, C. Pan, "Machine learning-based prediction of shear strength of steel reinforced concrete columns subjected to axial compressive load and seismic lateral load", *Structures*, 56, 104968 (2023).
- [29]. S. Mangalathu, H. Jang, S. H. Hwang, J. S. Jeon, "Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls", *Engineering Structures*, 208, 110331 (2020).
- [30]. H. D. Nguyen, J. M. LaFave, Y. J. Lee, M. Shin, "Rapid seismic damage-state assessment of steel moment frames using machine learning", *Engineering Structures*, 252, 113737 (2022).