



## DAMAGE DETECTION OF TRUSS BRIDGE USING IMPROVED RNN BASED ON MODEL UPDATING USING DATA OBTAINED FROM FIBER BRAGG GRATING SENSORS

Pham Hong Quan<sup>1\*</sup>, Ho Xuan Nam<sup>2</sup>, Mai Duc Anh<sup>2</sup>, Nguyen Thi Cam Nhung<sup>2\*</sup>

<sup>1</sup>University of Transport Technology, No 54 Trieu Khuc, Ha Noi, Vietnam

<sup>2</sup>University of Transportation and Communications, No 3 Cau Giay, Ha Noi, Vietnam

### ARTICLE INFO

TYPE: Research Article

Received: 21/04/2024

Revised: 26/7/2024

Accepted: 08/08/2024

Published online: 15/08/2024

<https://doi.org/10.47869/tcsj.75.6.6>

\* Corresponding author

Email: ncnhung@utc.edu.vn, quanph22@utt.edu.vn

**Abstract.** Structure health monitoring using enhancing variants of Recurrent Neural Networks (RNNs) to handle sequential data problems has become a topic of significant interest within the scientific community. This paper proposes the use of Gated Recurrent Unit (GRU), an improved variant of RNN, to detect and locate damage in bridge structures through time series data from virtual sensors. This data is extracted from a numerical model of the D2 bridge, which has been updated based on fiber optic measurement data. The dataset is fed into a GRU model, specifically designed to classify labels for each damage case corresponding to the input data. The performance of the GRU model is compared with the RNN network. Results indicate that both RNN and GRU can work on the dataset considered; however, GRU significantly outperforms the RNN network, achieving accuracy rates of 81.8% and 84.3% on the test and validation sets, respectively. That demonstrates the proposed GRU model's capability to quickly diagnose potential damage cases in the structure.

**Keywords:** GRU, damage detection, time-series data, truss bridge, RNN.

@ 2024 University of Transport and Communications



# CHẨN ĐOÁN HƯ HỎNG CẦU GIÀN THÉP SỬ DỤNG MẠNG HỒI QUY CẢI TIẾN DỰA TRÊN MÔ HÌNH SỐ ĐƯỢC CẬP NHẬT TỪ DỮ LIỆU THU ĐƯỢC TỪ CẢM BIẾN QUANG

Phạm Hồng Quân<sup>1\*</sup>, Hồ Xuân Nam<sup>2</sup>, Mai Đức Anh<sup>2</sup>, Nguyễn Thị Cẩm Nhung<sup>2\*</sup>

<sup>1</sup>Trường Đại học Công nghệ Giao thông vận tải, Số 54 Triều Khúc, Hà Nội, Việt Nam

<sup>2</sup>Trường Đại học Giao thông vận tải, Số 3 Cầu Giấy, Hà Nội, Việt Nam

## THÔNG TIN BÀI BÁO

CHUYÊN MỤC: Công trình khoa học

Ngày nhận bài: 21/04/2024

Ngày nhận bài sửa: 26/07/2024

Ngày chấp nhận đăng: 08/08/2024

Ngày xuất bản Online: 15/08/2024

<https://doi.org/10.47869/tcsj.75.6.6>

\* Tác giả liên hệ

Email: ncnhung@utc.edu.vn, quanph22@utt.edu.vn

**Tóm tắt.** Giám sát sức khỏe công trình cầu bằng các biến thể nâng cấp của mạng hồi quy RNN (Recurrent Neural Network) trong xử lý dữ liệu chuỗi đã thu hút sự quan tâm lớn từ cộng đồng quốc tế. Bài báo này đề xuất sử dụng GRU (Gated Recurrent Unit), một biến thể cải tiến của RNN, để phát hiện và xác định vị trí hư hỏng trong kết cấu cầu thông qua dữ liệu chuỗi thời gian từ các cảm biến ảo. Dữ liệu này được trích xuất từ một mô hình số của cầu D2, được cập nhật dựa trên dữ liệu đo bằng cáp quang. Bộ dữ liệu được đưa vào mô hình GRU, được thiết kế đặc biệt để phân loại các nhãn hư hỏng tương ứng với dữ liệu đầu vào. Hiệu suất của mô hình GRU được so sánh với RNN truyền thống. Kết quả cho thấy cả RNN và GRU đều có khả năng làm việc trên tập dữ liệu, tuy nhiên GRU vượt trội hơn với độ chính xác trên tập kiểm tra và kiểm thử lần lượt là 81,8% và 84,3%. Điều này chứng minh rằng mô hình GRU đề xuất có khả năng chẩn đoán nhanh chóng và chính xác các trường hợp hư hỏng có thể xảy ra trong kết cấu cầu.

**Từ khóa:** Mạng GRU, chẩn đoán hư hỏng, dữ liệu theo thời gian, cầu giàn thép, Mạng RNN.

@ 2024 Trường Đại học Giao thông vận tải

## 1. ĐẶT VẤN ĐỀ

Trong những thập kỷ gần đây, giám sát sức khỏe kết cấu công trình (SHM) là một chủ đề được các nhà khoa học trên thế giới đặc biệt quan tâm. Theo đó các công nghệ tiên tiến đã và đang được áp dụng trong việc triển khai giám sát sức khỏe cho kết cấu công trình, đặc biệt là

công trình cầu. Cùng với đó, việc bùng nổ của cách mạng 4.0 đã tạo ra bước phát triển nhảy vọt cho kỹ thuật trí tuệ nhân tạo (AI) ứng dụng vào đời sống xã hội và SHM cũng không phải là ngoại lệ. Giám sát kết cấu công trình kết hợp AI hoặc các thuật toán tiên tiến được ứng dụng trong rất nhiều nghiên cứu [1,2].

Trong lĩnh vực giám sát sức khỏe công trình hiện nay, xu hướng chính là theo dõi tổng thể công trình thay vì tập trung vào một số điểm trọng yếu, lượng dữ liệu thu thập được đang gia tăng đáng kể. Do đó, xuất hiện những thách thức lớn cho các kỹ thuật phân tích và thu thập dữ liệu. Ví dụ, cầu Vincent Thomas ở San Pedro, California lượng dữ liệu sinh ra khi sử dụng 26 cảm biến khoảng 3 Terabyte dữ liệu trong một năm; dự án giám sát cầu ở Nga thu thập khoảng 7 gigabyte mỗi ngày; hệ thống kiểm tra đường ray tự động ở Brockton, Massachusetts tạo ra hơn 20 gigabyte dữ liệu; hơn 300 gigabyte trong 6 tháng thu được từ việc giám sát tuabin gió ở Bỉ. Do vậy, điều cấp thiết là cần phát triển và sử dụng những công cụ phù hợp và có hiệu năng cao có khả năng xử lý nhiều loại dữ liệu khác nhau. Điều này sẽ giúp nâng cao hiệu quả và độ chính xác trong quá trình thu thập và phân tích dữ liệu.

Những năm gần đây, với sự phát triển của các hệ thống tính toán cũng như các thuật toán học máy, các mô hình học sâu (Deep Learning - DL) đã được áp dụng rộng rãi trên thế giới, đặc biệt trong những ngành công nghiệp như chế tạo máy, dầu khí, công trình, ..., và nhận được nhiều sự quan tâm của các nhà nghiên cứu. Trong số đó, RNN nổi lên là mô hình học sâu có thể làm việc tốt với dạng dữ liệu theo thời gian. Thành và cộng sự đã [3] đề xuất một mô hình lai Mạng nơ ron tích chập (CNN) và RNN nhằm trích xuất tính năng không gian từ CNN với việc học tương quan theo thời gian của RNN để phát hiện thiệt hại chính xác. Nghiên cứu này đã thử nghiệm trên các bộ dữ liệu dao động cầu Z24 cho thấy khả năng tự động học hỏi các đặc điểm phân biệt và phân loại chính xác hư hỏng cấu trúc bằng cách khai thác cả đặc điểm dữ liệu không gian và thời gian. Lee và cộng sự [4] đã nghiên cứu phát triển một phương pháp học sâu sử dụng Mạng thần kinh hồi quy để phát hiện thiệt hại chính xác trong các dây xích neo. RNN được đào tạo về dữ liệu mô phỏng chuỗi thời gian của các ứng xử của các công trình nổi ngoài khơi nắm bắt các yếu tố phụ thuộc theo thời gian và xác định thiệt hại do neo cục bộ với độ chính xác 99,99% cả trong trường hợp nhiễu. Fathnejat và cộng sự [5] đề xuất một mô hình học sâu mới kết hợp Mạng nơ ron tích chập 1 chiều (1DCNN) và RNN để xác định hư hỏng kết cấu. Mô hình này tận dụng 1DCNN để trích xuất các đặc trưng từ dữ liệu thô, RNN để nắm bắt các mối phụ thuộc tuần tự và chú ý để tập trung vào các bước thời gian cung cấp thông tin. Điều này cải thiện độ bền và độ chính xác của việc xác định thiệt hại dưới các biến đổi của môi trường. Yang và cộng sự [6] đã nghiên cứu một khung CNN phân cấp và GRU, mô hình hoá mối quan hệ không gian và thời gian để phát hiện hư hỏng cấu trúc. Các thử nghiệm trên bộ dữ liệu chuẩn cho thấy hiệu suất vượt trội so với các phương pháp hiện có. Thắng và cộng sự [7] đã tận dụng sức mạnh của mạng dư (Residual Network hay ResNet) để đề xuất mạng học sâu kết hợp, kết quả chỉ ra rằng phương pháp đề xuất hoàn toàn vượt trội so với các phương pháp truyền thống cũng như là mạng học sâu kết hợp trên bộ dữ liệu cầu Z24.


Dù RNN đã cho thấy khả năng xử lý tín hiệu tuần tự đáng kinh ngạc, nhưng chúng cũng gặp phải vấn đề như quá trình tuần tự của RNN là một đường thẳng khiến cho độ dốc của quá trình dễ dàng bị biến mất trong quá trình học, hơn nữa vì là một quá trình tuần tự nên các kiến thức từ trước đó có thể dễ dàng bị lãng quên khi cửa sổ học tập được thiết lập không hợp lý. Điều này dẫn đến sự ra đời của mạng bộ nhớ ngắn dài hạn (Long-Short Term Memory - LSTM) bởi Hochreiter & Schmidhuber (1997) [8]. Với những cải tiến đáng kể, LSTM không chỉ giải quyết vấn đề của RNN mà còn có khả năng học hiệu quả cả mô hình ngắn hạn và dài hạn. Tuy

nhiên, LSTM khá phức tạp và nhiều tham số, chính vì vậy Cho và cộng sự [9] đã đề xuất ra mạng GRU (Gated Recurrent Unit). So với LSTM, GRU có cấu trúc đơn giản hơn nhưng vẫn rất hiệu quả. Từ đó, trong nghiên cứu này, GRU được áp dụng để chẩn đoán hư hỏng trong kết cấu cầu giàn thép trong phòng thí nghiệm D2 dựa trên bộ dữ liệu theo thời gian. Ngoài phần đặt vấn đề, cấu trúc của bài báo được trình bày như sau: phần 2 trình bày về phương pháp học sâu, trong đó các lý thuyết về mạng RNN truyền thống và mạng cải tiến GRU; tiếp theo phần 3 mô tả thí nghiệm, bộ dữ liệu sử dụng trong nghiên cứu và kết quả sau khi ứng dụng GRU để xác định hư hỏng; cuối cùng là kết luận.

## 2. PHƯƠNG PHÁP

### 2.1. Mạng hồi quy truyền thống (Recurrent Neural Network - RNN)

RNN là một loại mạng nơ-ron nhân tạo (Artificial Neural Network-ANN) được thiết kế để nhận và xử lý dữ liệu chuỗi. Như đã biết thì mạng ANN bao gồm 3 phần chính là lớp đầu vào, lớp ẩn và lớp đầu ra, có thể thấy là đầu vào và đầu ra của mạng này là độc lập với nhau, cho nên mô hình này không phù hợp với những bài toán dạng chuỗi. Vì vậy mạng RNN ra đời với ý tưởng chính là sử dụng một bộ nhớ để lưu lại thông tin từ những bước tính toán xử lý trước để dựa vào nó có thể đưa ra dự đoán chính xác nhất cho bước dự đoán hiện tại. Mô hình mạng RNN được biểu diễn như Hình 1.



Hình 1. Mô hình mạng RNN.

Mô hình toán học của mạng RNN có thể được biểu diễn bởi công thức (1):

$$\begin{aligned} s_t &= f(W_{in}x_t + W_{rec}s_{t-1} + b_s) \\ \hat{y}_t &= g(Us_t + b_y) \end{aligned} \quad (1)$$

Trong đó,  $x_t$  là giá trị đầu vào tại thời điểm  $t$ ,  $s_{t-1}$  là trạng thái ẩn tại thời điểm  $t - 1$ ,  $s_t$  là trạng thái ẩn tại thời điểm  $t$ ,  $W_{in}$  là ma trận trọng số cho các kết nối đầu vào đến lớp ẩn,  $W_{rec}$  là ma trận trọng số cho các kết nối giữa các lớp ẩn,  $b_s$  là giá trị thiên vị của trạng thái ẩn,  $b_y$  là giá trị thiên vị của đầu ra,  $f$  biểu thị hàm kích hoạt của trạng thái ẩn, thường dùng hàm  $\tanh, ReLU, sigmoid$ ,  $g$  là hàm dự đoán.

### 2.2. Mạng Gated Recurrent Unit (GRU)

GRU là một biến thể nổi bật của mạng RNN, rất phổ biến để xử lý thông tin tạm thời. Trong những năm gần đây, GRU đã trở thành kỹ thuật hiện đại nhất cho các vấn đề học máy khác nhau, như thị giác máy tính, dự đoán dữ liệu chuỗi thời gian và xử lý ngôn ngữ tự nhiên. GRU

được đề xuất bởi Cho và các cộng sự [9] vào năm 2014, với kiến trúc đơn giản và dễ dàng thực hiện tính toán. Một số lý do chính để mạng GRU được đề xuất cho mô hình xử lý chuỗi dữ liệu:

- GRU là một kiến trúc mạng RNN, thiết kế đặc biệt để xử lý dữ liệu tuần tự. Điều này làm cho nó trở nên lý tưởng cho bất kỳ loại dữ liệu nào mà mối liên hệ thời gian giữa các điểm dữ liệu là quan trọng.
- Trong quá trình học sâu của các chuỗi dữ liệu dài, các mô hình RNN truyền thống thường gặp phải vấn đề biến mất gradient, khiến cho việc học các phụ thuộc dài hạn trở nên khó khăn. GRU giải quyết vấn đề này thông qua cơ chế cổng, giúp duy trì độ dốc trong quá trình học và cho phép mô hình học được các phụ thuộc xa.
- GRU có thể thích nghi tốt với cả các bài toán có độ phức tạp thấp và cao, từ dự đoán chuỗi thời gian đơn giản đến nhận dạng giọng nói hoặc dịch máy, làm cho nó trở thành một công cụ linh hoạt và mạnh mẽ trong bộ công cụ của nhà khoa học dữ liệu.

Cấu tạo điển hình của các tế bào GRU được thể hiện trong Hình 2.

Một tế bào GRU điển hình bao gồm hai cổng: cổng đặt lại  $r$  và cổng cập nhật  $z$ . Đầu ra trạng thái ẩn tại thời điểm  $t$  được tính bằng cách sử dụng trạng thái ẩn của thời gian  $t - 1$  và giá trị chuỗi thời gian đầu vào tại thời điểm  $t$ , được trình bày trong phương trình (2).

$$\mathbf{h}_t = f(\mathbf{h}_{t-1}, \mathbf{x}_t) \quad (2)$$

Mô tả cách tính toán kích hoạt đơn vị ẩn thứ  $j$ .

Đầu tiên, cổng đặt lại  $r_j$  được tính bằng:

$$r_j = \sigma([\mathbf{W}_r \mathbf{x}]_j + [\mathbf{U}_r \mathbf{h}_{(t-1)}]_j) \quad (3)$$

Trong đó  $\sigma$  là hàm sigmoid logistic và  $[\cdot]_j$  biểu thị phần tử thứ  $j$  của vector  $\mathbf{x}$  và  $\mathbf{h}_{t-1}$  lần lượt là đầu vào và trạng thái ẩn trước đó  $\mathbf{W}_r$  và  $\mathbf{U}_r$  là các ma trận trọng số được học.

Tương tự, cổng cập nhật  $z_j$  được tính toán theo phương trình (4).

$$z_j = \sigma([\mathbf{W}_z \mathbf{x}]_j + [\mathbf{U}_z \mathbf{h}_{(t-1)}]_j) \quad (4)$$

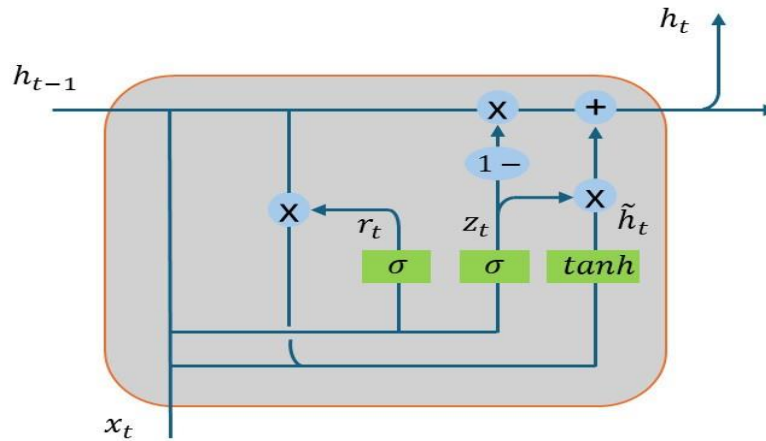
Hoạt động thực tế của đơn vị đề xuất  $\mathbf{h}_j$  sau đó được tính toán theo phương trình (5)

$$\mathbf{h}_j^{(t)} = z_j \mathbf{h}_j^{(t-1)} + (1 - z_j) \tilde{\mathbf{h}}_j^{(t)} \quad (5)$$

Trong đó  $\tilde{\mathbf{h}}_j^{(t)}$  được biểu diễn bằng phương trình (6)

$$\tilde{\mathbf{h}}_j^{(t)} = \phi([\mathbf{W} \mathbf{x}]_j + [\mathbf{U}(\mathbf{r} \odot \mathbf{h}_{(t-1)})]_j) \quad (6)$$

Khi cổng đặt lại gần bằng 0, trạng thái ẩn bị ép buộc phải bỏ qua trạng thái ẩn trước đó và chỉ đặt lại với đầu vào hiện tại. Điều này cho phép trạng thái ẩn loại bỏ bất kỳ thông tin nào được tìm thấy là không liên quan về sau trong tương lai, do đó, cho phép một biểu diễn nhỏ gọn hơn. Mặt khác, cổng cập nhật kiểm soát lượng thông tin từ trạng thái ẩn trước được mang sang trạng thái ẩn hiện tại. Điều này hoạt động giúp GRU ghi nhớ thông tin dài hạn.



Hình 2. Mô hình GRU.

### 3. THÍ NGHIỆM VÀ PHÂN TÍCH

#### 3.1. Mô tả thí nghiệm

Cầu giàn thép phòng thí nghiệm (D2) là cầu giàn thép được thiết kế dựa theo tỷ lệ của cầu giàn thép thực tế, cầu được đặt tại phòng thí nghiệm nhà A3 thuộc trường Đại học Giao thông Vận tải (Hình 3). Cầu có kết cấu nhịp dạng tam giác đều với chiều dài toàn cầu là 2000 mm, chiều cao cầu là 250 mm, chiều rộng cầu là 250 mm, cầu được chia làm 8 khoang, mỗi khoang có kích thước 250 mm mỗi cạnh. Các thanh thép được sử dụng trong mô hình là thép dạng hộp được mạ kẽm, mặt cắt ngang của mỗi thanh thép là  $25 \times 25 \times 1.4$  (mm), các thanh thép được liên kết với nhau tại các điểm nút bằng các bu lông, các bu lông này được bắt vào các tấm thép được hàn tại các vị trí điểm nút trên các thanh.



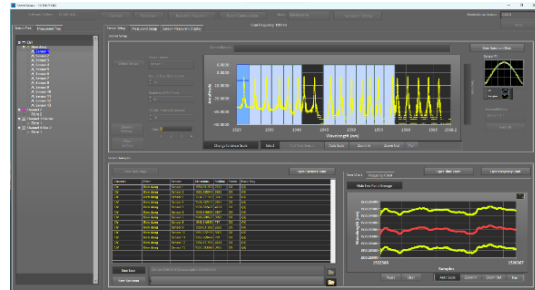
Hình 3. Mô hình cầu giàn thép.

#### 3.2. Đo đạc, xử lý và kết quả đo đạc

Thí nghiệm đo biến dạng động của kết cấu cầu giàn thép được thực hiện bằng cảm biến quang FBG với 13 cảm biến có bước sóng Bragg danh nghĩa cách đều từ 1530nm đến 1566,1nm, được lắp đặt dọc theo chiều dài kết cấu với khoảng cách đều nhau 25cm. Các cảm biến được gắn vào kết cấu thông qua các bộ kẹp cáp như trong Hình 4a và được căng trước để đảm bảo hoạt động suốt quá trình thí nghiệm. Mỗi lần đo kéo dài 2 phút, với tần số lấy mẫu  $f = 1000$  Hz. Dữ liệu đo được thu thập và xử lý bằng phần mềm MACEC để xác định các đặc trưng biến dạng động của kết cấu, bao gồm tần số và hình dạng dao động. Quá trình đo được kiểm soát bởi phần mềm Fentosense như mô tả trong Hình 4b.



(a)

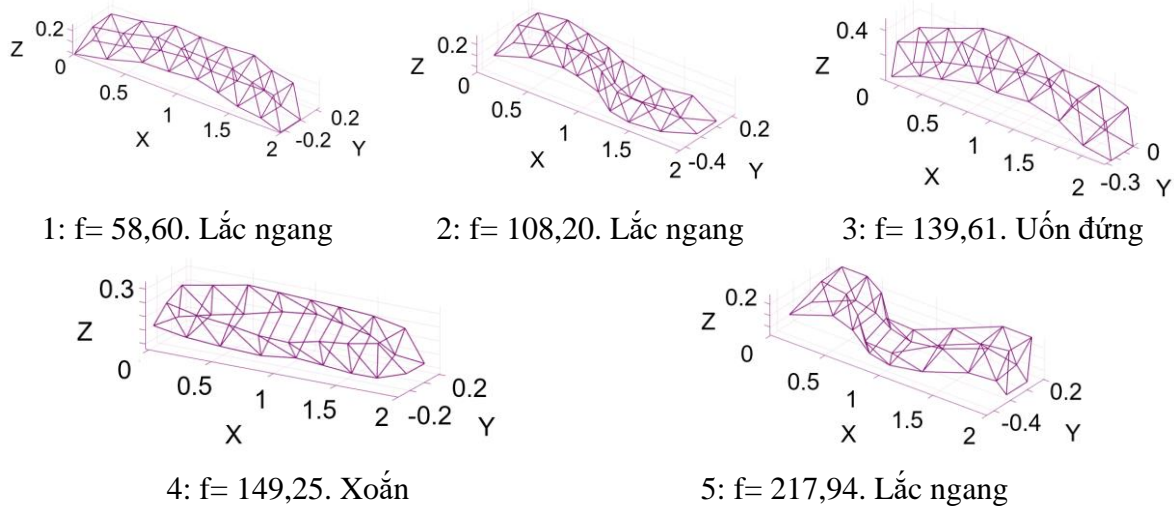


(b)

Hình 4. (a) Bố trí lắp đặt cảm biến quang trên cầu, (b) Phần mềm Fentosense quản lý thu thập dữ liệu.


Kết quả của bộ dữ liệu sau khi được xử lý bởi phần mềm MACEC được phát triển bởi trường đại học Leuven trích xuất được các đặc trưng động tương ứng tần số và hình thái dao động được liệt kê trong Bảng 1.

Bảng 1. Kết quả xử lý dữ liệu thu được từ cảm biến quang



### 3.3. Cập nhật mô hình

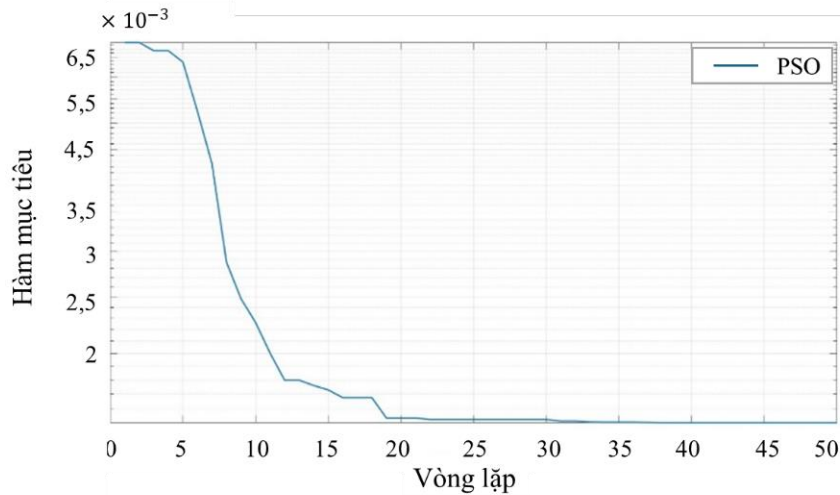
Một mô phần tử hữu hạn (PTHH) của cầu D2 được xây dựng bằng Stabil toolbox [10] trong môi trường của phần mềm MATLAB. Phần tử dầm được sử dụng làm phần tử chính để mô hình hoá kết cấu cầu. Cầu được phân bổ thành 05 bộ phận bao gồm: thanh mạ hạ, thanh mạ thượng, thanh xiên, thanh liên kết dọc trên, thanh liên kết dọc dưới. Toàn bộ các thành đều được giả định với mô đun đàn hồi là  $2E11 \left(\frac{N}{m^2}\right)$ , hệ số poisson là 0,3 và khối lượng riêng là  $7850 \left(\frac{kg}{m^3}\right)$ . Điều kiện biên của mô hình được thiết lập theo điều kiện thực tế của cầu, với một đầu cố định (nút 101 và 201) và một đầu di động (nút 109 và 209). Ngoài ra, tất cả các liên kết trong cầu đều là các liên kết cứng. Các tham số được lựa chọn trước và sau khi cập nhật trong mô hình, như được mô tả chi tiết trong Bảng 2. Giá trị dự đoán ban đầu của các tham số bất định quan đến kết cấu được tính toán dựa trên thông tin tham khảo từ các mô hình tương tự [11–13].



Hình 5. Mô hình PTHH cầu thí nghiệm.

Để cập nhật mô hình và xác định các tham số bất định của kết cấu, thuật toán tối ưu PSO [14] được sử dụng. Kết quả quá trình cập nhật được thống kê và biểu diễn trong Hình 6, Bảng 2 và

Bảng 3.



Hình 6. Kết quả hội tụ sau khi cập nhật mô hình.

Bảng 2. Các đặc trưng vật liệu trước và sau khi cập nhật.

Tham số	Kết cấu	Kí hiệu	Trước cập nhật	Sau cập nhật	Đơn vị
Mô đun đàn hồi	Thanh mạ hạ	E1	2	2,09	E+11 N/m <sup>2</sup>
	Thanh mạ thượng	E2	2	2,09	E+11 N/m <sup>2</sup>
	Thanh xiên	E3	2	2,09	E+11 N/m <sup>2</sup>
	Liên kết dọc trên	E4	2	2,05	E+11 N/m <sup>2</sup>
	Liên kết dọc dưới	E5	2	2,09	E+11 N/m <sup>2</sup>
Liên kết lò xo	Liên kết lò xo 1	K1	1	1,35	E+4 N/m <sup>2</sup>
	Liên kết lò xo 2	K2	1	1,36	E+4 N/m <sup>2</sup>
	Liên kết lò xo 3	K3	1	1,37	E+4 N/m <sup>2</sup>
	Liên kết lò xo 4	K4	1	1,33	E+4 N/m <sup>2</sup>
	Liên kết lò xo 5	K5	1	1,36	E+4 N/m <sup>2</sup>



	Liên kết lò xo 6	K6	1	1,36	E+4 N/m <sup>2</sup>
--	------------------	----	---	------	----------------------

Bảng 3: Kết quả so sánh giữa tần số đo được và kết quả cập nhật.

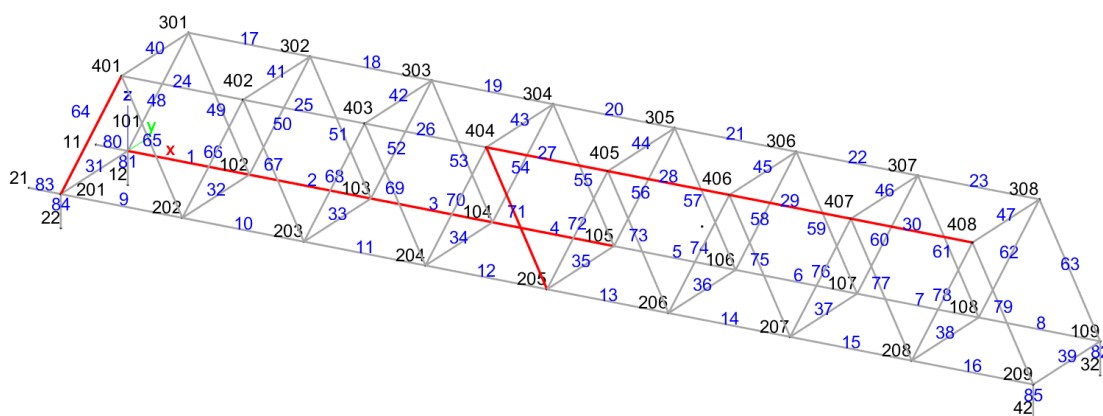
STT	Tần số đo được (Hz)	Tần số mô hình (Hz)	Tần số cập nhật (Hz)	Sai số (%)	
				Trước cập nhật	Sau cập nhật
1	58,60	56,69	59,91	3,40%	2,24%
2	108,20	121,80	118,36	11,20%	9,39%
3	139,61	134,13	140,15	4,10%	0,39%
4	149,25	141,67	150,68	5,40%	0,96%
5	217,94	198,54	210,42	9,80%	3,45%
<b>Giá trị trung bình</b>				<b>6,75%</b>	<b>3,28%</b>

### 3.4. Dữ liệu hư hỏng

Trong nghiên cứu này, chúng tôi đã xây dựng và mô tả chi tiết 11 kịch bản thiệt hại trong Bảng 4, với việc gán nhãn cụ thể cho từng phần tử và tỉ lệ thiệt hại của mỗi kịch bản, chi tiết phần tử hư hỏng trong kết cấu và vị trí hư hỏng được trình bày chi tiết tại Hình 7. Dữ liệu được thu thập thông qua việc mô phỏng kích thích bằng cách kích thích một lực vào nút 402 ở hướng Z trong một khoảng thời gian xác định.

Bảng 4. Kịch bản hư hỏng xảy ra.


Nhãn	0	1	2	3	4	5	6	7	8	9	10
Phần tử	0	1	2	3	4	27	28	29	30	64	71
Phần trăm hư hỏng(%)	0	10	20	30	40	50	10	20	10	30	10



Hình 7. Các phần tử trong kịch bản hư hỏng xảy ra.

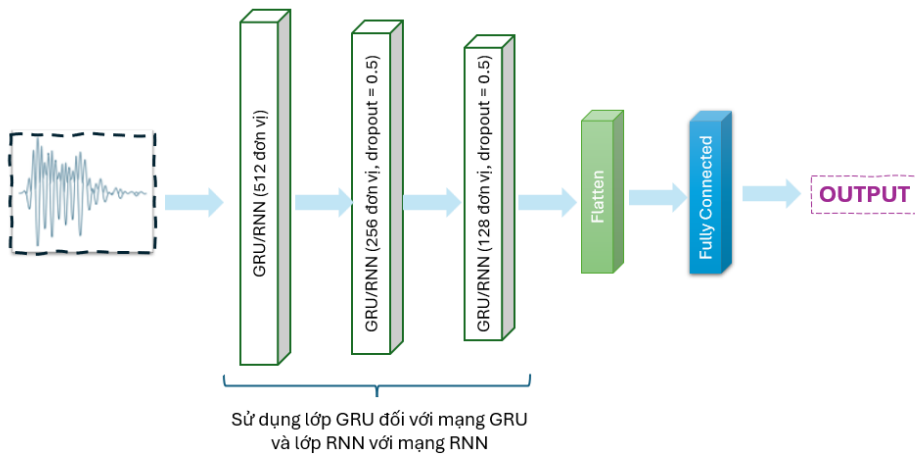
Để tạo điều kiện thí nghiệm gần với thực tế nhất, chúng tôi đã ngẫu nhiên đưa vào nhiều loại nhiễu khác nhau vào toàn bộ kết cấu. Dữ liệu thu được từ 14 nút thuộc phần giàn dưới, bao gồm cả dầm chính trong giàn với các nút từ 102 đến 108 và từ 202 đến 208. Từ mỗi nút, dữ liệu được thu thập theo hai hướng: trục Y (di chuyển ngang) và trục Z (di chuyển dọc). Với tần số lấy mẫu là 1000 Hz trong vòng 10 giây, chúng tôi thu được 10.000 điểm dữ liệu từ mỗi mẫu. Dữ liệu sau đó được tổng hợp thành một tập dữ liệu với kích thước là (11, 28, 10000), trong đó 11 là cho số lượng kịch bản thiệt hại được phân tích, 28 là số cảm biến ảo được trích xuất, và

10000 là số điểm dữ liệu cho mỗi mẫu. Ví dụ về một phần dữ liệu được trình bày như trong Hình 8.



Hình 8. Dữ liệu cầu D2.

Để làm phong phú thêm tập dữ liệu, nhiều kỹ thuật tăng cường dữ liệu đã được sử dụng, mỗi kỹ thuật được thiết kế để mô phỏng các điều kiện vận hành và môi trường khác nhau mà cây cầu có thể gặp phải. Các phương pháp này bao gồm thêm nhiễu ngẫu nhiên vào dữ liệu, đảo ngược chuỗi thời gian để mô phỏng các kiểu chuyển động ngược lại và cắt xén, sau đó đệm các chuỗi để phản ánh các biến thể trong thời lượng hoạt động hoặc các phân đoạn dữ liệu bị thiếu. Sau quá trình tăng cường này, kích thước tập dữ liệu đã mở rộng lên (989, 28, 10000), tăng đáng kể khối lượng dữ liệu có sẵn để huấn luyện mô hình DL, từ đó cải thiện độ chính xác và độ tin cậy dự đoán của nó. Dữ liệu của mạng sẽ được chia lần lượt cho các tập huấn luyện, kiểm thử và kiểm tra lần lượt là 70%, 15%, 15%.



Hình 9. Kiến trúc của mạng GRU và RNN.

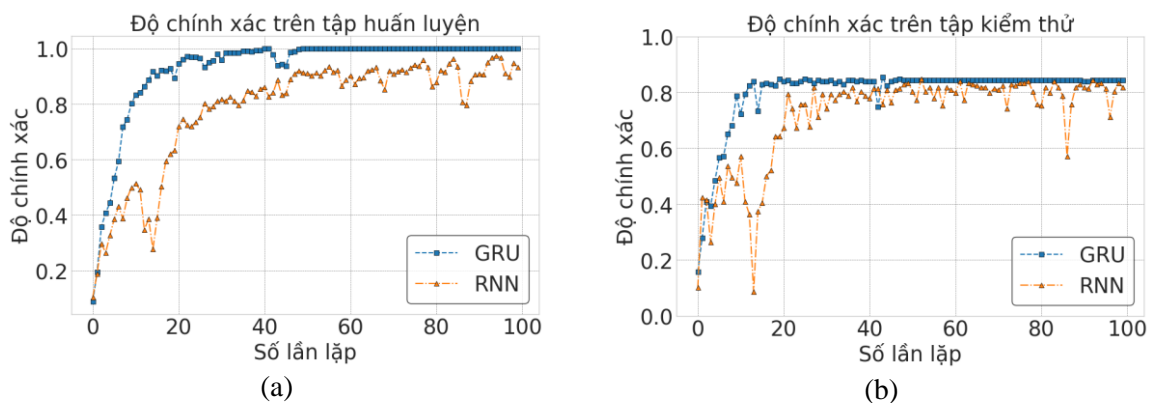
### 3.5. Kiến trúc mạng RNN và GRU

Mạng GRU được xây dựng bằng cách sử dụng thư viện Keras trong mô hình tuần tự (Sequential). Lớp đầu tiên của mạng GRU có 512 đơn vị GRU nhận dữ liệu đầu vào. Lớp GRU thứ hai có 256 đơn vị GRU và lớp thứ ba với 128 đơn vị cũng được cấu hình để trả về chuỗi kết quả. Lớp chuyển đổi dữ liệu từ dạng chuỗi thành dạng phẳng (flatten), chuẩn bị cho các lớp fully connected sau này. Lớp tiếp theo là lớp fully connected với 128 nút. Lớp cuối cùng có số nút bằng số nhãn và sử dụng hàm kích hoạt softmax để thực hiện phân loại đa lớp. Mô hình áp dụng với hàm mất mát tối ưu hóa bằng "adam," và đánh giá theo chỉ số "accuracy". Mô hình được huấn luyện bằng cách sử dụng dữ liệu huấn luyện trong 100 epochs.

Để xác thực tính hiệu quả của kiến trúc GRU, một mạng RNN được thiết kế tương tự dùng để so sánh. Mạng RNN cũng có kiến trúc tương đồng. Trong môi trường tensorflow, lớp simpleRNN sẽ được sử dụng cho mỗi lớp RNN được thiết lập. Theo đó, kiến trúc mạng của RNN bao gồm: lớp đầu tiên của RNN có 512 đơn vị, lớp thứ hai 256 đơn vị, lớp thứ ba với 128 đơn vị. Các lớp còn lại cũng được thiết kế giống với GRU như flatten, fully-connected và softmax.

### 3.6. Kết quả và thảo luận

Kết quả định tính của cả hai mạng sẽ được ghi lại bằng biểu đồ hội tụ thông qua Hình 10. Về tổng thể, ta có thể dễ dàng nhận ra rằng mạng GRU đang làm rất tốt trên cả 2 tập huấn luyện và tập kiểm thử, khi tốc độ, độ ổn định và mức độ hội tụ là cao hơn mạng RNN. Xét trên tập huấn luyện, GRU đã nhanh chóng đạt được giá trị tối ưu sau khoảng 30 đến 40 lần lặp và ổn định trong suốt quá trình huấn luyện phía sau, trong khi đó RNN liên tục gặp khó khăn trong suốt quá trình huấn luyện, thậm chí có những thời điểm độ chính xác của mạng này còn rất thấp. Điều tương tự xảy ra trên tập kiểm thử khi độ chính xác của mạng GRU nhanh chóng gia tăng chỉ sau 20 lần lặp và giữ ổn định ở mức hơn 80% chính xác. Đối với mạng RNN trên tập kiểm thử, tuy vẫn đạt được độ chính xác gần với GRU nhưng quá trình đi lên của biểu đồ có thể dễ dàng thấy rằng RNN đã gặp khó khăn rất nhiều khi liên tục dao động, thay đổi độ dốc chứ không ổn định như mạng GRU.



Hình 10. Biểu đồ hội tụ của mạng GRU và RNN trên tập huấn luyện (a) và kiểm thử (b).

Tuy ở kết quả định tính đã cho thấy kết quả của mạng GRU là tốt hơn RNN trên cả tập huấn luyện và tập kiểm thử, nhưng vẫn chưa thể chắc chắn rằng liệu mạng có thực sự tìm ra được chính xác các nhãn hư hỏng hay không. Chính vì vậy, kết quả định lượng cần phải được tiến hành. Theo đó, trong nghiên cứu này kết quả định lượng sẽ được tính toán, thu thập dựa trên ma trận dự đoán và độ chính xác được đề cập đến trong tài liệu [7]. Trong đó, các chỉ số

xét đến bao gồm độ nhớ (*recall*), độ chính xác (*precision*), chỉ số f1 (*f1 – score*) và độ chính xác tổng thể (*acc*). Chi tiết công thức được biểu diễn theo phương trình (7)-(10):


$$recall = \frac{(TP)}{(TP + FN)} \tag{7}$$

$$precision = \frac{(TP)}{(TP + FP)} \tag{8}$$

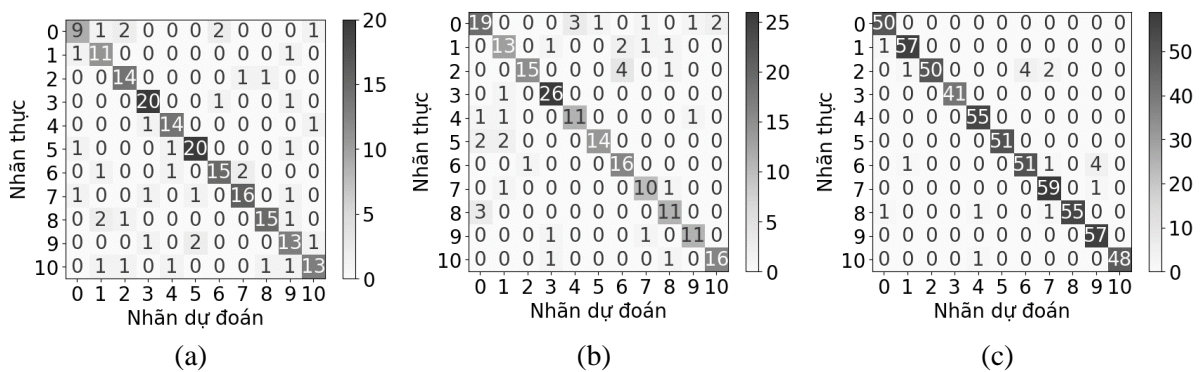
$$f1 - score = \frac{2 * recall * precision}{recall + precision} \tag{9}$$

$$acc = \frac{(TP + TN)}{(TP + TN + FP + FN)} \tag{10}$$

Trong đó TP, TN, FP và FN lần lượt là số lượng dự đoán chính xác dương, số lượng dự đoán chính xác âm, số dự đoán sai dương và số lượng dự đoán sai âm. Theo đó, recall để chỉ ra rằng trong các trường hợp dự đoán chính xác dương và sai lệch âm (TP+FN) thì có bao nhiêu trường hợp đã dự đoán chính xác dương (TP). Precision chỉ ra rằng trong các trường hợp dự đoán dương (TP+FP) thì có bao nhiêu trường hợp dự đoán chính xác dương. Để đánh giá độ tin cậy chung của mô hình, người ta đã kết hợp 2 chỉ số Precision và Recall thành một chỉ số duy nhất: f1-score, được tính theo công thức (9). Và cuối cùng là độ chính xác tổng thể được tính bằng tổng số dự đoán chính xác chia cho tổng các dự đoán, được trình bày trong phương trình (10).



Hình 11. Ma trận dự đoán của mạng GRU trên tập (a) kiểm tra, (b) kiểm thử và (c) huấn luyện.



Hình 12. Ma trận dự đoán của mạng RNN trên các tập (a) kiểm tra, (b) kiểm thử và (c) huấn luyện.

Kết quả định lượng được trình bày trong Hình 11, Hình 12, Bảng 5 và Bảng 6. Trong đó, thông qua Hình 11 có thể thấy được rằng mạng GRU đang làm rất tốt khi trên đường chéo chính, số lượng lớn các nhãn tập trung và có màu đậm so với khu vực ngoài đường chéo chính trên cả 3 tập, đặc biệt đối với trên tập huấn luyện, độ chính xác là 100. Ngược lại với GRU, Hình 12 là kết quả dự đoán của RNN trên cả 3 tập dữ liệu lại cho thấy kết quả không tốt khi trên đường chéo chính, số lượng thấp và màu sắc khá nhạt so với Hình 10 của mạng GRU. Như vậy, có thể thấy được tính hiệu quả của GRU là tốt hơn so với RNN. Kết quả từ Bảng 5 và Bảng 6 cho thấy sự khác biệt về hiệu suất giữa mạng RNN và GRU trong việc xử lý dữ liệu. Với mạng GRU, độ chính xác tổng thể đạt 0,818 trên tập kiểm tra và 0,843 trên tập kiểm thử, vượt trội so với mạng RNN với độ chính xác tương ứng là 0,808 và 0,818. Đáng chú ý, GRU đạt độ chính xác tuyệt đối 1,000 trên tập huấn luyện, trong khi RNN chỉ đạt 0,968. Về các nhãn cụ thể, GRU thể hiện tốt hơn, đặc biệt trên nhãn 2 và 3 với f1-score cao nhất lần lượt là 1,000 và 0,897, so với RNN đạt 0,833 và 0,929 trên các nhãn tương tự. Về khả năng học tập từ dữ liệu, GRU hoàn toàn học được từ dữ liệu huấn luyện với tất cả các giá trị precision, recall, và f1-score đều đạt 1.000, trong khi RNN cũng có kết quả rất cao nhưng không đạt đến mức tuyệt đối. Điều này cho thấy GRU không chỉ học tốt từ dữ liệu huấn luyện mà còn tổng quát hóa tốt hơn trên các tập kiểm tra và kiểm thử. Tóm lại, mạng GRU hoàn toàn vượt trội hơn mạng RNN trong bài toán chẩn đoán kết cấu dựa trên dữ liệu dạng chuỗi, đặc biệt là trong khả năng học tập và tổng quát hóa, làm cho GRU trở thành lựa chọn tốt hơn cho các bài toán yêu cầu phân loại chính xác và hiệu quả cao.

Bảng 5. Bảng kết quả huấn luyện của mạng GRU.

Nhãn	Tập kiểm tra			Tập kiểm thử			Tập huấn luyện		
	precision	recall	f1-score	precision	recall	f1-score	precision	recall	f1-score
0	0,733	0,733	0,733	0,792	0,704	0,745	1,000	1,000	1,000
1	0,688	0,846	0,759	0,778	0,778	0,778	1,000	1,000	1,000
2	0,800	0,750	0,774	1,000	1,000	1,000	1,000	1,000	1,000
3	0,913	0,955	0,933	0,839	0,963	0,897	1,000	1,000	1,000
4	0,824	0,875	0,848	0,733	0,786	0,759	1,000	1,000	1,000
5	0,909	0,870	0,889	0,875	0,778	0,824	1,000	1,000	1,000
6	0,800	0,842	0,821	0,938	0,882	0,909	1,000	1,000	1,000
7	0,762	0,800	0,780	1,000	0,833	0,909	1,000	1,000	1,000
8	0,882	0,789	0,833	0,917	0,786	0,846	1,000	1,000	1,000
9	0,929	0,765	0,839	0,647	0,846	0,733	1,000	1,000	1,000
10	0,722	0,722	0,722	0,842	0,889	0,865	1,000	1,000	1,000
<b>acc</b>	<b>0,818</b>			<b>0,843</b>			<b>1,000</b>		

#### 4. KẾT LUẬN

Bài viết đề xuất ứng dụng một phương pháp học sâu GRU được sử dụng để chẩn đoán hư hỏng kết cấu dựa trên dữ liệu chuỗi thời gian của cầu D2. Kết quả đã chứng minh rằng phương pháp GRU vượt trội hơn đáng kể so với các phương pháp RNN truyền thống được thiết kế cho

dữ liệu chuỗi thời gian. Cụ thể, với cùng bộ dữ liệu, phương pháp GRU đạt kết quả lần lượt là 81,8%, 84,3% và 100% trên tập kiểm tra, kiểm thử và huấn luyện, trong khi đó phương pháp RNN chỉ đạt 80,8%, 81,8% và 96,8%. Dựa trên những kết quả này, một số kết luận quan trọng có thể được rút ra như sau:

- Cả hai phương pháp RNN và GRU đều có thể xác định, chẩn đoán hư hỏng trên tập dữ liệu theo thời gian cho kết cấu cầu.
- Mạng GRU có độ chính xác cao trong việc xác định trạng thái hư hỏng của kết cấu từ dữ liệu chuỗi thời gian.
- Kết quả thực nghiệm chứng minh sức mạnh của phương pháp GRU so với phương pháp RNN truyền thống.

Phương pháp được GRU có tiềm năng đáng kể cho các ứng dụng trong công trình thực trong lĩnh vực SHM vì nó hoạt động hiệu quả với dữ liệu chuỗi thời gian, đây là loại dữ liệu phổ biến cho SHM hiện tại.

Bảng 6. Bảng kết quả huấn luyện của mạng RNN

Nhãn	Tập kiểm tra			Tập kiểm thử			Tập huấn luyện		
	precision	recall	f1-score	precision	recall	f1-score	precision	recall	f1-score
0	0,733	0,733	0,733	0,760	0,704	0,731	0,962	1,000	0,980
1	0,688	0,846	0,759	0,722	0,722	0,722	0,966	0,983	0,974
2	0,800	0,750	0,774	0,938	0,750	0,833	1,000	0,877	0,935
3	0,913	0,955	0,933	0,897	0,963	0,929	1,000	1,000	1,000
4	0,824	0,875	0,848	0,786	0,786	0,786	0,965	1,000	0,982
5	0,909	0,870	0,889	0,933	0,778	0,848	1,000	1,000	1,000
6	0,800	0,842	0,821	0,727	0,941	0,821	0,927	0,895	0,911
7	0,762	0,800	0,780	0,769	0,833	0,800	0,937	0,983	0,959
8	0,882	0,789	0,833	0,733	0,786	0,759	1,000	0,948	0,973
9	0,929	0,765	0,839	0,846	0,846	0,846	0,919	1,000	0,958
10	0,722	0,722	0,722	0,889	0,889	0,889	1,000	0,980	0,990
<b>acc</b>	<b>0,808</b>			<b>0,818</b>			<b>0,968</b>		

## LỜI CẢM ƠN

Chúng tôi xin cảm ơn trường Đại học công nghệ GTVT đã tạo điều kiện để chúng tôi thực hiện các nghiên cứu này. Bài báo được tài trợ bởi Trường Đại học Công nghệ Giao thông vận tải, 54 Triều Khúc, Thanh Xuân, Hà Nội, Việt Nam (UTT), mã đề tài ĐTTĐ2023-07.

## TÀI LIỆU THAM KHẢO

- [1]. B.T. Thanh , N.C. Thanh, L.X. Thang, T.N. Hoa, Enhancing bridge damage assessment: Adaptive cell and deep learning approaches in time-series analysis, *Construction and Building Materials*, 439 (2024) 137240. <https://doi.org/10.1016/j.conbuildmat.2024.137240>
- [2]. T.V. Hung, N.C. Thanh, L.X. Thang, N.T.C. Nhung, N.V. Thuc, T.N. Hoa, Enhancing salp swarm optimization with orthogonal diagonalization transformation for damage detection in truss bridge,

- KSCE J Civ Eng, 28 (2024) 2355–2365. <https://doi.org/10.1007/s12205-024-2048-6>
- [3]. B.T. Thanh, B.N. Dung, N.T. Hieu, N.N. Long, T.N. Hoa, T.V. Hung, Damage detection in structural health monitoring using hybrid convolution neural network and recurrent neural network, *Frattura Ed Integrità Strutturale*, 16 (2022) 461–470. <https://doi.org/10.3221/IGF-ESIS.59.30>
- [4]. K. Lee, M. Chung, S. Kim, D.H. Shin, Damage detection of catenary mooring line based on recurrent neural networks, *Ocean Engineering*, 227 (2021) 108898. <https://doi.org/10.1016/j.oceaneng.2021.108898>
- [5]. H. Fathnejat, B. Ahmadi-Nedushan, S. Hosseinijad, M. Noori, W.A. Altabey, A data-driven structural damage identification approach using deep convolutional-attention-recurrent neural architecture under temperature variations, *Engineering Structures*, 276 (2023) 115311. <https://doi.org/10.1016/j.engstruct.2022.115311>
- [6]. J. Yang, L. Zhang, C. Chen, Y. Li, R. Li, G. Wang, S. Jiang, Z. Zeng, A hierarchical deep convolutional neural network and gated recurrent unit framework for structural damage detection, *Information Sciences*, 540 (2020) 117–130. <https://doi.org/10.1016/j.ins.2020.05.090>
- [7]. L.X. Thang, B.T. Thanh, T.N. Hoa, A novel approach model design for signal data using 1DCNN combing with LSTM and ResNet for damaged detection problem, *Structures*, 59 (2024) 105784. <https://doi.org/10.1016/j.istruc.2023.105784>
- [8]. S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Computation* 9 (1997) 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [9]. K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, Learning phrase representations using rnn encoder-decoder for statistical machine translation, *arXiv preprint arXiv*, 1406.1078 (2014). <https://doi.org/10.48550/arXiv.1406.1078>
- [10]. S.François, M.Schevenels, D.Dooms, M.Jansen, J.Wambacq, G.Lombaert, G.De Roeck, Stabil: An educational Matlab toolbox for static and dynamic structural analysis, *Computer Applications in Engineering Education*, 29 (2021) 1372-1389. <https://doi.org/10.1002/cae.22391>
- [11]. S. Qin, Y.-L. Zhou, H. Cao, M.A. Wahab, Model updating in complex bridge structures using kriging model ensemble with genetic algorithm, *KSCE J Civ Eng*, 22 (2018) 3567–3578. <https://doi.org/10.1007/s12205-017-1107-7>
- [12]. T. Liu, Q. Zhang, T. Zordan, B. Briseghella, Finite element model updating of canonica bridge using experimental modal data and genetic algorithm, *Structural Engineering International*, 26 (2016) 27–36. <https://doi.org/10.2749/101686616X14480232444405>
- [13]. K. Lin, Y.-L. Xu, X. Lu, Z. Guan, J. Li, Cluster computing-aided model updating for a high-fidelity finite element model of a long-span cable-stayed bridge, *Earthquake Engineering & Structural Dynamics*, 49 (2020) 904–923. <https://doi.org/10.1002/eqe.3270>
- [14]. J. Kennedy, R. Eberhart, Particle swarm optimization, in: *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4 (1995) 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>