PHƯƠNG PHÁP ĐA NHIỆM XÁC ĐỊNH HƯ HỎNG TRONG KẾT CÂU GIÀN SỬ DỤNG DỮ LIỆU ĐỊNH HƯỚNG

Hà Mạnh Hùng^{a,*}, Đặng Việt Hưng^a

^aKhoa Xây dựng dân dụng và công nghiệp, Trường Đại học Xây dựng, 55 đường Giải Phóng, quận Hai Bà Trưng, Hà Nội, Việt Nam

Nhận ngày 21/04/2021, Sửa xong 16/05/2021, Chấp nhận đăng 17/05/2021

Tóm tắt

Giàn không gian là một dạng kết cấu đặc biệt, thường có kích thước lớn và cấu tạo từ rất nhiều các bộ phận khác nhau, do đó việc theo dõi sức khỏe của kết cấu giàn là một nhiệm vụ khó và nhiều thách thức. Nghiên cứu này đề xuất một phương pháp dữ liệu định hướng có khả năng thực hiện đa nhiệm, gồm xác định sự tồn tại của hư hỏng trong kết cấu, vị trí và mức độ nghiêm trọng của hư hỏng. Phương pháp đề xuất có ba bước chính: i) chuyển đổi tín hiệu dao động sang dữ liệu 2 chiều dạng ảnh sử dụng kĩ thuật biến đổi Fourier thời gian ngắn, ii) sử dụng thuật toán học sâu ResNet 18 để trích xuất các đặc trưng từ ảnh nhận được từ bước 1, iii) thiết kế một hàm mất mát phức hợp cho việc thực hiện đa nhiệm. Hiệu quả và độ chính xác của phương pháp đề xuất được thể hiện thông qua một ví dụ với giàn mái vòm gồm 120 thanh, với độ chính xác hơn 90% đồng thời cho cả sự tồn tại, vị trí và mức độ hư hỏng.

Từ khoá: kết cấu giàn; học máy; tính toán số; hư hỏng kết cấu; dữ liệu định hướng.

MULTI-TASKING DATA-DRIVEN APPROACH FOR DAMAGE DETECTION IN TRUSS STRUCTURE

Abstract

The spatial truss is a special kind of three-dimensional structure, monitoring truss structures' health is an exhausting task due to its huge size and a large number of members. This study extends this line of research by elaborating a data-driven approach that can perform multi-tasks ranging from detecting damage, localizing damage, and quantifying damage severity. The main steps of the proposed approach are: i) leveraging the Short Time Fourier Transform technique for converting vibration signals into images containing information from both time and frequency domain, ii) using the powerful deep neural network ResNet 18 for feature extraction, and iii) elaborating a compound loss function for multi-tasking learning. The efficiency and efficacy of the proposed approach are demonstrated via a 3D dome truss structure with 120 bars, for which detection accuracies for all tasks of interest are higher than 90%.

Keywords: truss structure; deep learning; numerical simulation; damage detection; data-driven.

https://doi.org/10.31814/stce.nuce2021-15(2V)-02 © 2021 Trường Đại học Xây dựng (NUCE)

1. Giới thiệu

Kết cấu giàn không gian là một dạng kết cấu có tỉ số độ cứng trên khối lượng cao, đồng thời có tính thẩm mĩ cao, do đó được sử dụng nhiều cho các kết cấu mái có không gian lớn, ví dụ như sân bay Changi ở Singapore, sân vận động Arena ở Đức, hay xưởng sản xuất máy bay Boeing ở Mĩ ... Các kết cấu giàn không gian thường bao gồm nhiều phần tử với kích thước, hình dạng và vật liệu giống nhau. Do đó để theo dõi sức khỏe và phát hiện sớm các hư hỏng của công trình là một nhiệm vụ khó

^{*}Tác giả đại diện. Địa chỉ e-mail: hunghm@nuce.edu.vn (Hùng, H. M.)

khăn và thách thức. Gần đây phương pháp phân tích dữ liệu dao động đo từ các cảm biến gắn trên kết cấu mang lại nhiều kết quả hứa hẹn, có khả năng giảm đáng kể thời gian và công sức khi so với phương pháp thủ công, sử dụng nhân công quan sát trực tiếp. Ngoài ra với sự phát triển của các công nghệ mới như cảm biến không dây, internet vạn vật và dữ liệu lớn, dữ liệu đo có thể được thu thập một cách liên tục trong thời gian dài [1]. Tuy nhiên để chuyển các dữ liệu đo thành các thông tin hữu ích liên quan đến trạng thái làm việc của kết cấu gặp nhiều khó khăn, không chỉ bởi dung lượng rất lớn của dữ liệu, mà còn bởi các sai số, tín hiệu nhiễu, hay các tác động của môi trường.

Thông thường, dựa vào dữ liệu đo, các thuật toán tối ưu có thể được sử dụng để xác định các đặc trưng của kết cấu ở thời điểm hiện tại. Sau đó, so sánh với các giá trị tương ứng ở thời điểm kết cấu ở trạng thái toàn vẹn, các hư hỏng có thể được xác định. Chi tiết áp dụng các thuật toán tối ưu có thể tìm thấy ở trong các công bố của Mishra và cs. [2], Kaveh và Zolghadr [3], Ding và cs. [4]. Tuy nhiên, các phương pháp này có điểm chung là cần một bước tiền xử lý để trích xuất các đặc trưng dao động gồm tần số dao động và dạng dao động. Kết quả của bước tiền xử lý này lại nhạy cảm với các tác động của môi trường và các tín hiệu nhiễu, yêu cầu một quy trình nghiêm ngặt từ đo đạc, số lượng và vị trí cảm biến, các kĩ thuật lọc nhiễu, do đó khó có thể áp dụng một cách liên tục để theo dõi sức khỏe của kết cấu theo thời gian thực.

Gần đây, các nhà khoa học Việt Nam và nhóm tác giả tập trung rất nhiều vào các bài toán tối ưu hay tính toán độ tin cậy của công trình thép [5–7], đặc biệt tập trung vào các nghiên cứu ứng dụng thuật toán máy học nói chung và thuật toán học sâu (Deep Learning - DL) nói riêng trong các thiết kế công trình khung, giàn bằng thép [8–12]. Đồng thời phương pháp sử dụng dữ liệu định hướng gần đây cũng đã thu hút được sự quan tâm của nhiều nhà khoa học và kĩ sư trong và ngoài nước nhờ khả năng tự động trích xuất các đặc trưng liên quan đến trạng thái của kết cấu từ dữ liệu ban đầu. Ngoài ra các phương pháp này có thể được nâng cấp mở rộng, tự động xử lý được lượng lớn dữ liệu, một khi các mô hình học máy được huấn luyện. Avci và cs. [13] đã đề xuất một phương pháp sử dụng mạng tích chập kết hợp với cảm biến không dây để xác định mức độ giảm độ cứng của liên kết. Zhang và cs. [14] sử dụng kiến trúc học sâu để phân tích trạng thái của một kết cấu cầu thép sử dụng dữ liệu dao động là đầu vào. Yuan và cs. [15] sử dụng mô hình học sâu hồi quy để xác định các hư hỏng của kết cấu tua bin gió, và đạt được các kết quả chính xác hơn so với một số phương pháp xác suất thống kế hay dùng.

Phát triển theo hướng nghiên cứu trên, bài báo này đề xuất một phương pháp dữ liệu định hướng có khả năng thực hiện đa nhiệm, gồm xác định sự tồn tại của hư hỏng trong kết cấu, vị trí và mức độ nghiêm trọng của hư hỏng. Phương pháp đề xuất có ba bước chính: i) chuyển đổi tín hiệu dao động sang dữ liệu 2 chiều dạng ảnh sử dụng kĩ thuật biến đổi Fourier thời gian ngắn (Short Time Fourier Transform), ii) sử dụng thuật toán học sâu ResNet 18 để trích xuất các đặc trưng từ ảnh nhận được từ bước 1, iii) thiết kế một hàm mất mát phức hợp cho việc thực hiện đa nhiệm. Hiệu quả và độ chính xác của phương pháp đề xuất được thể hiện thông qua một ví dụ với giàn mái vòm gồm 120 thanh, với độ chính xác hơn 90% đồng thời cho cả sự tồn tại, vị trí và mức độ hư hỏng.

Phương pháp xác định hư hỏng của kết cấu giàn sử dụng tín hiệu dao động và thuật toán học sâu

2.1. Kĩ thuật biến đổi Fourier thời gian ngắn

Dao động của kết cấu được ghi lại dưới dạng dữ liệu gồm một chuỗi các giá trị thay đổi theo thời gian. Dựa vào dữ liệu trên miền thời gian này ta có thể trích xuất ra các đặc trưng ở miền tần số dựa vào phương pháp biến đổi Fourier, mà ở đó các giá trị cực trị tương ứng với các tần số dao động riêng

Hùng, H. M., Hưng, Đ. V. / Tạp chí Khoa học Công nghệ Xây dựng

của hệ kết cấu đang xét. Để quan sát đồng thời các đặc trưng dao động của kết cấu trên miền thời gian và miền tần số, kĩ thuật biến đổi Fourier thời gian ngắn (STFT) [16] được phát triển và sử dụng rộng rãi trên nhiều lĩnh vực. Ý tưởng của STFT là chia dữ liệu dao động ban đầu thành nhiều đoạn dữ liệu nhỏ hơn, có thể trùng lặp một phần. Sau đó áp dụng biến đổi Fourier lên từng đoạn dữ liệu để nhận được các đặc trưng trên miền tần số. Cuối cùng các đặc trưng này được ghép lại trên trục thời gian tương ứng, tạo thành một ảnh hai chiều với trục tung là thời gian và trục hoành là tần số với màu sắc, mức độ đậm nhạt của từng điểm ảnh thể hiện giá trị của biên độ lớn/nhỏ tương ứng như trên Hình 1. Công thức của STFT được viết như sau:

$$STFT(\tau, f) = \int_{-\infty}^{\infty} x(t)\psi(t-\tau)e^{-2\pi i f t}dt$$
(1)

Tiến hành rời rạc hóa theo thời gian, tức là, chia đoạn thời gian [0, T] thành các thời điểm $[0, t_1, t_2, ..., t_N]$ với bước thời gian không đổi dt = T/N, công thức (1) được viết lại như sau:

$$STFT_{n,f} = \sum_{k=n}^{n+N-1} x_k \psi_{k-n} e^{-2\pi i f k}$$
(2)

trong đó x(t) là dữ liệu dao động của kết cấu, ψ là một hàm cửa sổ trượt, f là tần số và N là chiều dài của phân đoạn dữ liệu được chia nhỏ ra. Ngoài ra, ảnh hai chiều nhận được từ biến đổi STFT được gọi là quang phổ của tín hiệu dao động.



Hình 1. Ví dụ về tín hiệu dao động kết cấu và ảnh quang phổ tương ứng nhận được bằng kĩ thuật STFT

Về mặt thực hiện, quá trình trên được tiến hành với sự trợ giúp của thư viện khoa học Scipy [17] của ngôn ngữ lập trình Python, cụ thể là hàm 'scipy.signal.stft'. Các thông số chính của hàm bao gồm chiều dài của phân đoạn tín hiệu, phần trăm trùng lặp của các phân đoạn và tần số lấy mẫu. Dựa theo hệ quả Nyquist, đặc trưng tần số lớn nhất có thể trích xuất được từ dữ liệu đo, không vượt quá 50% của tần số lấy mẫu. Ngoài ra, phần trăm trùng lặp cũng có thể ảnh hưởng đến độ phân giải của ảnh quang phổ nhận được. Nếu phần trăm trùng lặp thấp, dẫn đến độ phân giải thấp, phần trăm trùng lặp cao độ phân giải sẽ cao, nhưng đồng thời kích thước ảnh cũng tăng lên, dẫn đến tốn nhiều bộ nhớ và chậm quá trình tính toán. Thông thường giá trị trùng lặp 50% được coi như giá trị mặc định.

2.2. Kiến trúc học sâu ResNet và học chuyển tiếp

Sau khi chuyển dữ liệu dao động 1 chiều sang dạng ảnh quang phổ 2 chiều, ảnh này sẽ được đưa vào một mô hình học sâu để xác định trạng thái kết cấu tương ứng, tức là cho biết kết cấu có xuất hiện hư hỏng hay không. Mô hình học sâu được sử dụng ở đây là mạng ResNet-18 như thể hiện trên Hình 2, do kết cấu này có đã được chứng minh đạt độ chính xác cao trong việc phân loại ảnh [18, 19], ngoài ra kiến trúc của mạng rõ ràng dễ hiểu. Mạng Resnet-18 bao gồm 18 lớp mạng tích chập, được chia thành 4 khối, ngoài ra có thêm các liên kết giữa hai lớp tích chập bất kì. Tuy nhiên toàn bộ mạng ResNet-18 có hơn 11 triệu tham số cần xác định, do đó huấn luyện mạng này ngay từ đầu là không khả thi, do yêu cầu rất cao về thời gian tính toán, lượng dữ liệu có sẵn cũng như nền tảng máy tính. Do đó, ở đây tác giả đã sử dụng phương pháp học chuyển tiếp để tiến hành tinh chỉnh mạng ResNet-18 cho việc xác định hư hỏng trong kết cấu giàn. Cụ thể, các tham số của mạng ResNet-18 ở đây được kế thừa từ việc huấn luyện trước với hàng triệu hình ảnh từ bộ dữ liệu ImageNet của Google [20]. Sau đấy, các tác giả sẽ cố định hầu hết các lớp của mạng ResNet, ngoại trừ hai lớp cuối cùng sẽ được huấn luyện lại với bộ dữ liệu về sự làm việc của kết cấu giàn.



Hình 2. Kiến trúc học sâu ResNet-18

Thông thường, sử dụng tín hiệu đo từ duy nhất một cảm biến khó có thể cung cấp được kết quả chính xác về vị trí hư hỏng, đặc biệt là khi hư hỏng xuất hiện ở gần nơi đặt cảm biến. Trong khi việc sử dụng nhiều cảm biến sẽ mang lại nhiều thông tin hơn và có thể nâng cao độ chính xác của mô hình dự đoán. Hình 3 thể hiện chu trình làm việc sử dụng đồng thời dữ liệu từ nhiều cảm biến, trong đó dữ liệu từ mỗi cảm biến sẽ đi vào một mạng ResNet riêng rẽ, đầu ra của mỗi mạng ResNet sẽ đi qua một



Hình 3. Chu trình làm việc kết hợp đồng thời tín hiệu dao động từ nhiều cảm biến

lớp trung bình trọng số, rồi đi qua một lớp phân loại để xác định trạng thái tương ứng của kết cấu. Về mặt logic, nếu cảm biến nào ở xa vị trí hư hỏng thì ảnh hưởng của nó lên kết quả sẽ nhỏ, do đó trọng số tương ứng sẽ không đáng kể. Ngược lại, với những cảm biến ở gần vị trí hư hỏng, trọng số tương ứng sẽ lớn. Về mặt thực hiện, thư viện học sâu Pytorch được sử dụng để xây dựng các khối ResNet, lớp trung bình trọng số và lớp phân loại. Trong giai đoạn huấn luyện, thuật toán tối ưu hóa để xác định các tham số của kĩ thuật học chuyển tiếp là Adam [21], bước học tập ban đầu là 0,001, sau đó được giảm 50% nếu hàm mất mát không giảm qua các bước lặp và sau 10 bước lặp liên tiếp không có sự cải tiến thì quá trình huấn luyện sẽ được dừng sớm.

2.3. Hàm mất mát phức hợp cho việc học đa nhiệm

Phương pháp xác định hư hỏng truyền thống thực hiện riêng rẽ các nhiệm vụ: xác định tồn tại của hư hỏng, xác định vị trí hư hỏng và đánh giá mức độ hư hỏng, tuy nhiên vẫn sử dụng một dữ liệu đầu vào giống nhau. Mặt khác, các nghiên cứu về khoa học dữ liệu đã đề xuất xây dựng mô hình học máy đa nhiệm cho phép thực hiện đồng thời các tác vụ. Ngoài ra, nhiều tác giả đã quan sát thấy rằng mô hình đa nhiệm có thể tăng khả năng dự đoán chính xác cho từng nhiệm vụ, tuy nhiên không làm tăng thời gian huấn luyện đáng kể khi so với mô hình đơn nhiệm. Lợi thế của mô hình đa nhiệm được giải thích là do khi huấn luyện với các tác vụ khác nhau thì các đặc trưng được trích xuất sẽ đa dạng hơn, tránh bị chú trọng quá mức vào việc tối ưu cho một nhiệm vụ, do đó mô hình học máy có thể đạt được kết quả cao hơn, ngay cả khi áp dụng cho các dữ liệu mới. Dựa vào phát hiện trên, bài báo này đề xuất một hàm đa nhiệm phức hợp để đánh giá khả năng của mô hình học máy, dựa vào đồng thời ba tác vụ: xác định tồn tại hư hỏng, xác định vị trí hư hỏng và mức độ hư hỏng, như thể hiện ở công thức (3):

$$\Omega(X) = \lambda_D L_D(X) + \lambda_L L_L(X) + \lambda_S L_S(X)$$
(3)

trong đó $\Omega(X)$ là hàm mất mát phức hợp, X là ảnh quang phổ đầu vào nhận được từ STFT, L_D , L_L và L_S là hàm mất mát dạng cross-entropy [22] cho từng tác vụ tồn tại hư hỏng, xác định vị trí hư hỏng và mức độ hư hỏng. λ_D , λ_L và λ_S là trọng số tương ứng với các tác vụ. Giá trị của các trọng số này được xác định dựa vào nhận xét sau: việc xác định sự tồn tại của hư hỏng cũng có ảnh hưởng lớn đến việc xác định vị trí và mức độ hư hỏng. Tức là nếu hư hỏng không tồn tại thì không cần thiết thực hiện hai tác vụ còn lại. Do đó trọng số cho L_D nên có giá trị lớn hơn so với L_L và L_S . Trong nghiên cứu này, các tác giả thấy với $\lambda_D = 0.5$, và $\lambda_L = \lambda_S = 0.25$, các kết quả nhận được có độ chính xác đáp ứng với kì vọng.

3. Ví dụ áp dụng

3.1. Dàn vòm 120 thanh và mô hình phần tử hữu hạn

Trong phần này, phương pháp đề xuất được áp dụng cho một kết cấu giàn vòm không gian gồm 120 thanh thép. Nhịp của giàn là 3178 cm, chiều cao tổng cộng là 700 cm như được thể hiện trên Hình 4. Các đặc trưng của vật liệu: mô đun đàn hồi E = 210 GPa, hệ số Poisson 0,3, khối lượng riêng 7850 kg/m³. Các thanh giàn được chia thành 7 nhóm, các thanh trong 1 nhóm có cùng tiết diện như được liệt kê trong Bảng 1. Trên Hình 4, các thanh cùng nhóm được thể hiện với màu sắc và chiều dày tương ứng tiết diện của thanh. Giàn được đỡ bởi 12 gối đơn giản bị ngăn cản các chuyển vị thẳng theo ba phương *X*, *Y*, *Z*. Giàn không gian chịu tải trọng tập trung, theo phương thẳng đứng đặt tại đỉnh vòm. Tải trọng này có giá trị ngẫu nhiên thay đổi theo thời gian. Kết cấu giàn được lựa chọn trong ví dụ này có độ phức tạp vừa đủ để có thể thực hiện các kịch bản hư hỏng khác nhau, đồng thời có thể trình bày

cụ thể các bước thực hiện của phương pháp đề xuất mà không yêu cầu quá nhiều các tính toán phức tạp và nhiều thời gian mô phỏng.

Mô hình phần tử hữu hạn của giàn được thực hiện trên phần mềm Abaqus [23], mỗi thanh giàn được mô phỏng bằng phần tử giàn loại T3D2 [24], phản ứng động của kết cấu được phân tích theo phương pháp chồng chất dạng dao động (modal analysis). Các hư hỏng được đưa vào kết cấu dưới dạng giảm tiết diện của thanh giàn với mức độ giảm trong khoảng [0, 30, 60, 90]% và vị trí giảm là một thanh bất kì trong giàn. Thời gian mô phỏng là 30 giây với bước thời gian là 0,001 giây. Các thanh dàn được chia nhỏ thành các phần tử với kích thước không vượt quá 0,5 m.



Hình 4. Ví dụ áp dụng kết cấu giàn vòm không gian 120 thanh

Thông số	E (MPa)	F(kN)	Vị trí hư hỏng	Mức độ hư hỏng
Phân bố	Gaussian	Gaussian	Đều	Đều
Miền giá trị	N(210, 21)	<i>N</i> (1, 0,1)	[1-8]	[0, 30, 60, 90]

Bảng 1. Các giá trị ngẫu nhiên và dạng phân bố tương ứng

3.2. Tập dữ liệu cho mô hình học máy

Phương pháp mô phỏng Monte Carlo với các thông số ngẫu nhiên liệt kê trong Bảng 1 được sử dụng để tạo ra một cơ sở dữ liệu cho huấn luyện mô hình học máy. Có tất cả 10.000 mô phỏng được thực hiện, với mỗi mô phỏng chuyển vị động tại tất cả các nút giàn được ghi lại, chuyển thành ảnh quang phổ và gán nhãn tương ứng với vị trí hư hỏng và mức độ hư hỏng theo dữ liệu đầu vào. Ở đây số lượng các nhãn cùng vị trí hư hỏng được phân bố đều (10000/8, với nhãn 0 là không hư hỏng) và mức độ hư hỏng cũng được phân bố đều (10000/4). Sau đó cơ sở dữ liệu trên được chia thành 3 tập dữ liệu nhỏ không trùng nhau với tỉ lệ 8:1:1 để huấn luyện, kiểm chứng và kiểm tra.

Hình 5 trình bày ví dụ về tín hiệu dao động đo tại nút 5 (vị trí theo Hình 4), cho ba trường hợp của mức độ hư hại 0%, 30% và 90%. Đồng thời, ảnh quang phổ FFT tương ứng được thể hiện ở bên

phải. Dựa vào quan sát nhận thấy mức độ hư hại dẫn đến sự khác nhau trên ảnh quang phổ, nhất là vùng tần số từ 20-30 Hz, do đó tác giả tin rằng phương pháp áp dụng các thuật toán học máy trong thị giác máy tính có thể tự động nhận ra được sự khác nhau này, thậm chí mở rộng cho các trường hợp mắt thường khó nhận ra. Ngoài ra, ở ví dụ này ảnh quang phổ tại tất cả 37 nút của dàn, tương tự như Hình 5 sẽ được trích xuất và sử dụng đồng thời để xác định mức độ và vị trí hư hại trong dàn.



Hình 5. Ví dụ tín hiệu dao động thu tại nút 5 và ảnh quang phổ tương ứng cho ba trường hợp mức độ hư hại 0%, 30% và 90%

Các thông số cho quá trình huấn luyện bao gồm: các thông số của mô hình được khởi tạo bằng phương pháp Kaiming [25], tức là được khởi tạo ngẫu nhiên theo phân bố Gauss với kì vọng bằng 0, phương pháp tối ưu Adam với tốc độ học bằng 0,001 được sử dụng để xác định các thông số của mô hình, tốc độ học được giảm đi xuống còn 0,0001 nếu như độ chính xác của mô hình không được cải thiện. Ngoài ra, nếu sau 10 vòng lặp liền nhau, độ chính xác vẫn không được cải thiện thì quá trình huấn luyện kết thúc, kết quả cao nhất trong quá trình học sẽ được lưu lại và các thông số của mô hình tương ứng với thời điểm đạt kết quả cao nhất sẽ được sử dung cho mô hình cuối cùng.



Hình 6. Đường học tập của mô hình học máy, từ trái sang phải, gồm: giá trị hàm mất mát phức hợp trên tập huấn luyện, độ chính xác trên tập kiểm chứng cho tác vụ xác định tồn tại của hư hỏng, vị trí hư hỏng và mức độ hư hỏng

Tiếp theo, tập dữ liệu huấn luyện và kiểm chứng được sử dụng để huấn luyện mô hình đề xuất để thực hiện các tác vụ đánh giá hư hỏng của kết cấu. Hình 6 thể hiện đường học tập của mô hình gồm

giá trị của hàm mất mát phức hợp biến đổi theo số vòng lặp của quá trình huấn luyện, độ chính xác trên tập dữ liệu kiểm chứng với các tác vụ: xác định tồn tại hư hỏng, vị trí và mức độ hư hỏng, theo thứ tự từ trái qua phải.

Hình 6 cho thấy hàm mất mát giảm nhanh từ đầu đến khoảng vòng lặp thứ 15, sau đấy tốc độ giảm chậm lại và đạt đến giá trị hội tụ ở khoảng vòng lặp 25. Tương tự, độ chính xác của các tác vụ cũng tăng nhanh trong khoảng 20 vòng lặp đầu tiên, sau đấy chậm lại và hội tụ ở khoảng vòng lặp 25. Đặc biệt độ chính xác cuối cùng ở cả 3 tác vụ trên tập kiểm chứng đều lớn hơn khoảng 90%.

3.3. Kết quả tính toán của mô hình học máy

Hình 7 thể hiện một ví dụ kết quả nhận được từ đầu ra của mô hình học máy,mô hình sẽ đưa ra phần trăm xác suất cho tất cả các trường hợp với tổng của tất cả các trường hợp là 100%, sau đó trường hợp có phần trăm cao nhất sẽ được chọn như là kết quả của quá trình đánh giá kết cấu, còn các trường hợp khác sẽ có phần trăm xác suất thấp hơn đáng kể.



Hình 7. Ví dụ về kết quả đầu ra của mô hình học máy: xác suất tương ứng với mỗi trường hợp (nhãn) của tình trạng kết cấu

Để đánh giá khả năng của mô hình học máy một cách toàn diện trên cả tập dữ liệu kiểm tra, kết quả đánh giá kết cấu được biểu diễn qua một ma trận nhầm lẫn (confusion matrix) như trên Hình 8. Với ma trận nhầm lẫn, các kết quả đánh giá đúng được biểu diễn trên đường chéo, còn các số liệu ở ngoài đường chéo là các kết quả đánh giá nhầm lẫn. Bằng cách cộng tất cả các giá trị trên đường chéo, ta nhận được độ chính xác cho việc xác định tồn tại hư hỏng là 978/1000 = 97,8%. Thực hiện tương tự, độ chính xác cho việc xác định vị trí hư hỏng và mức độ hư hỏng lần lượt là 95,6% và 95,4%.



Hình 8. Kết quả ma trận nhầm lẫn nhận được trên tập kiểm tra cho các tác vụ: tồn tại hư hỏng, vị trí hư hỏng và mức độ hư hỏng

Mặt khác, về thời gian huấn luyện cho mô hình đa nhiệm là 73 phút với bộ dữ liệu gồm 8000 mẫu, so sánh với mô hình đơn nhiệm (nhận được bằng cách gán các trọng số tương ứng bằng 0) là 62 phút.

Như vậy, thời gian tính toán của mô hình đa nhiệm chỉ cao hơn khoảng 14% so với 1 mô hình đơn nhiệm, nhưng có thể cùng lúc thực hiện được 3 tác vụ, nói các khác chỉ bằng 40% so với tổng thời gian của cả 3 mô hình đơn nhiệm. Ngoài ra khi áp dụng cho tập dữ liệu kiểm tra, hầu như không có sự khác biệt về thời gian tính toán giữa hai mô hình (26,6s với 24,3s).

4. Kết luận

Trong nghiên cứu này, một phương pháp dữ liệu định hướng cho việc xác định hư hỏng có khả năng thực hiện đa nhiệm được đề xuất, thực hiện và áp dụng cho một kết cấu giàn vòm không gian. Ý tưởng chính của phương pháp đề xuấtlà cùng sử dụng một dữ liệu đầu vào, nhưng huấn luyện đồng thời cho các tác vụ khác nhau, sẽ hướng dẫn mô hình học máy trích xuất ra các đặc trưng khác nhau, tránh bị quá tập trung vào một số đặc trưng nhất định, do đó có khả năng tổng quát hóa tốt hơn. Các thành phần chính của phương pháp bao gồm ảnh quang phổ của tín hiệu dao động, mạng thần kinh tích chập, kĩ thuật học chuyển tiếp và một hàm mất mát phức hợp. Kết quả áp dụng trên một ví dụ giàn vòm không gian cho thấy phương pháp đề xuất đạt kết quả đánh giá hư hỏng kết cấu cao (lớn hơn 90%) cho tất cả các tác vụ và thời gian tính toán nhanh bằng khoảng 40% so với tổng thời gian của từng tác vụ riêng lẻ.

Lời cảm ơn

Tác giả xin cảm ơn sự hỗ trợ tài chính của Bộ giáo dục và Đào tạo cho đề tài mã số CT.2019.03.01.

Tài liệu tham khảo

- Sun, L., Shang, Z., Xia, Y., Bhowmick, S., Nagarajaiah, S. (2020). Review of Bridge Structural Health Monitoring Aided by Big Data and Artificial Intelligence: From Condition Assessment to Damage Detection. *Journal of Structural Engineering*, 146(5):04020073.
- [2] Mishra, M., Barman, S. K., Maity, D., Maiti, D. K. (2020). Performance Studies of 10 Metaheuristic Techniques in Determination of Damages for Large-Scale Spatial Trusses from Changes in Vibration Responses. *Journal of Computing in Civil Engineering*, 34(2):04019052.
- [3] Kaveh, A., Ghazaan, M. I. (2015). Optimal design of dome truss structures with dynamic frequency constraints. *Structural and Multidisciplinary Optimization*, 53(3):605–621.
- [4] Ding, Z. H., Huang, M., Lu, Z. R. (2016). Structural damage detection using artificial bee colony algorithm with hybrid search strategy. *Swarm and Evolutionary Computation*, 28:1–13.
- [5] Ha, M.-H., Vu, Q.-V., Truong, V.-H. (2020). Optimization of nonlinear inelastic steel frames considering panel zones. *Advances in Engineering Software*, 142:102771.
- [6] Ha, M.-H., Vu, Q.-A., Truong, V.-H. (2018). Optimum Design of Stay Cables of Steel Cable-stayed Bridges Using Nonlinear Inelastic Analysis and Genetic Algorithm. *Structures*, 16:288–302.
- [7] Kim, S.-E., Truong, V.-H. (2020). Reliability Evaluation of Semirigid Steel Frames Using Advanced Analysis. *Journal of Structural Engineering*, 146(5):04020064.
- [8] Truong, V.-H., Vu, Q.-V., Thai, H.-T., Ha, M.-H. (2020). A robust method for safety evaluation of steel trusses using Gradient Tree Boosting algorithm. *Advances in Engineering Software*, 147:102825.
- [9] Hung, T. V., Viet, V. Q., Thuat, D. V. (2019). A deep learning-based procedure for estimation of ultimate load carrying of steel trusses using advanced analysis. *Journal of Science and Technology in Civil Engineering (STCE) - NUCE*, 13(3):113–123.
- [10] Hùng, H. M., Hùng, T. V., Thuật, Đ. V., Việt, V. Q. (2020). Phương pháp xử lý hiện tượng mô hình quá khớp trong xây dựng mô hình học sâu để ước lượng khả năng chịu tải của giàn phi tuyến. Tạp chí Khoa học Công nghệ Xây dựng (KHCNXD) ĐHXD, 14(1V):12–20.

Hùng, H. M., Hưng, Đ. V. / Tạp chí Khoa học Công nghệ Xây dựng

- [11] Hung, D. V., Hung, H. M., Anh, P. H., Thang, N. T. (2020). Structural damage detection using hybrid deep learning algorithm. *Journal of Science and Technology in Civil Engineering (STCE) - NUCE*, 14 (2):53–64.
- [12] Ha, M.-H., Vu, Q.-V., Truong, V.-H. (2019). A Deep Learning-Based Procedure for Safety Evaluation of Steel Frames Using Advanced Analysis. *Lecture Notes in Civil Engineering*, Springer Singapore, 1137– 1142.
- [13] Avci, O., Abdeljaber, O., Kiranyaz, S., Hussein, M., Inman, D. J. (2018). Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks. *Journal of Sound and Vibration*, 424:158–172.
- [14] Zhang, Y., Miyamori, Y., Mikami, S., Saito, T. (2019). Vibration-based structural state identification by a 1-dimensional convolutional neural network. *Computer-Aided Civil and Infrastructure Engineering*, 34 (9):822–839.
- [15] Yuan, M., Wu, Y., Lin, L. (2016). Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. 2016 IEEE International Conference on Aircraft Utility Systems (AUS), IEEE.
- [16] Durak, L., Arikan, O. (2003). Short-time fourier transform: two fundamental properties and an optimal implementation. *IEEE Transactions on Signal Processing*, 51(5):1231–1242.
- [17] Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., Burovski, E., Peterson, P., Weckesser, W., Bright, J., van der Walt, S. J., Brett, M., Wilson, J., Millman, K. J., Mayorov, N., Nelson, A. R. J., Jones, E., Kern, R., Larson, E., Carey, C. J., Polat, İ., Feng, Y., Moore, E. W., VanderPlas, J., Laxalde, D., Perktold, J., Cimrman, R., Henriksen, I., Quintero, E. A., Harris, C. R., Archibald, A. M., Ribeiro, A. H., Pedregosa, F., van Mulbregt, P. (2020). SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature Methods*, 17(3):261–272.
- [18] Kolesnikov, A., Beyer, L., Zhai, X., Puigcerver, J., Yung, J., Gelly, S., Houlsby, N. (2019). Big transfer (bit): General visual representation learning. arXiv preprint arXiv:1912.11370, 6(2):8.
- [19] Xie, Q., Luong, M.-T., Hovy, E., Le, Q. V. (2020). Self-Training With Noisy Student Improves ImageNet Classification. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.
- [20] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition, IEEE.
- [21] Kingma, D. P., Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980.*
- [22] de Boer, P.-T., Kroese, D. P., Mannor, S., Rubinstein, R. Y. (2005). A Tutorial on the Cross-Entropy Method. Annals of Operations Research, 134(1):19–67.
- [23] Dassault, S. (2016). ABAQUS analysis user's manual.
- [24] Dassault, S. (2016). Abaqus theory guide.
- [25] He, K., Zhang, X., Ren, S., Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. 2015 IEEE International Conference on Computer Vision (ICCV), IEEE.