

Ứng dụng kỹ thuật học sâu dự đoán hư hỏng cho kết cấu công trình ngoài khơi

Predicting damage to Offshore Jacket Platform using deep learning technique

Nguyễn Xuân Phương¹, Hồ Lê Anh Hoàng^{2,3}, Trần Tiến Đạt², Huỳnh Kiên Phát², Đặng Xuân Kiên^{2,*}

¹Nhóm nghiên cứu Kỹ thuật và Công nghệ ứng dụng trong giao thông vận tải (PATET), Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh

²Nhóm nghiên cứu Trí tuệ nhân tạo trong giao thông vận tải (AIT), Trường Đại học Giao thông vận tải Thành phố Hồ Chí Minh

³Trường Đại học Văn Hiến

*Email liên hệ: kien.dang@ut.edu.vn

Tóm tắt:

Kết cấu công trình ngoài khơi (Offshore Jacket Platform - OJP) thường bị hư hỏng do nhiều yếu tố tác động như động đất, sóng thần và ảnh hưởng của môi trường biển. Do đó, rất cần thiết theo dõi tình trạng kỹ thuật công trình sớm ngăn chặn sự xuống cấp, tránh thiệt hại về tài sản và con người. Trong bài báo này, nhóm tác giả phát triển một hệ thống thu thập và xử lý dữ liệu sử dụng mạng cảm biến đa điểm kết hợp với mạng nơ-ron học sâu để xác định các trường hợp bất thường cho OJP do các tác động trực tiếp của môi trường như sóng, gió và các tác động trực tiếp khác tạo nên trong quá trình khai thác. Dữ liệu được lọc nhiễu và dựng ảnh phổ hai chiều thông qua bộ biến đổi wavelet được sử dụng làm đầu vào để huấn luyện và kiểm tra hệ thống được thiết kế. Bộ xử lý trung tâm STM32 Nucleo-F411RE đã xem xét thuật toán học sâu trên một mô hình nhúng trong MATLAB và kết quả thử nghiệm đã chứng minh hiệu quả của phương pháp đề xuất.

Từ khóa: Ảnh phổ hai chiều; Bộ biến đổi wavelet liên tục; Chẩn đoán hư hỏng kết cấu của OJP; Mạng GoogLeNet; Mạng nơ-ron tích chập.

Abstract:

Offshore Jacket Platform (OJP) constructions are often damaged by many factors such as earthquakes, tsunamis, and the effect of marine environment. Therefore, it is necessary to keep regard on the health of the construction to prevent deterioration and avoid damage to property and people. In this paper, we develop a data acquisition and processing system that uses a multi-sensor network combined with a deep learning neural network to identify anomalies for OJP due to the direct effects of environment such as waves, wind, and other direct impacts during mining. Noise-filtered data and two-dimensional scalogram rendering through a wavelet transform are used as input to train and test the designed system. The central processor STM32 Nucleo-F411RE considered the deep learning algorithm on an embedded model in MATLAB and the test results proved the effectiveness of the proposed method.

Keywords: Two-dimensional scalogram; Continuous wavelet transform; Structural damage diagnosis of OJP; GoogLeNet; Convolutional neural networks.

1. Giới thiệu

Giám sát sức khỏe kết cấu của công trình ngoài khơi (Offshore Jacket Platform - OJP) đã được phát triển như một giải pháp tự động theo dõi tình trạng thực tế của OJP [1], [2]. Hoạt động này có tầm quan

trọng lớn đối với các công trình biển vốn dễ bị tích tụ các hư hỏng trong suốt thời gian sử dụng do môi trường biển khắc nghiệt và phức tạp tác động. Việc sớm chẩn đoán hư hỏng kết cấu của OJP kịp thời là cần thiết để tránh các thiệt hại có thể xảy ra và đảm

bảo an toàn cho công trình biển. Mặt khác, việc phát triển các giải thuật học sâu cho OJP để xác định các hư hỏng chính của kết cấu hiện nay là xu thế trong việc phát hiện sớm sự xuống cấp của kết cấu, cả trên phương diện nghiên cứu lý thuyết lẫn ứng dụng thực nghiệm. Đặc biệt với sự phát triển của trí tuệ nhân tạo hiện nay, các nghiên cứu hướng tới khả năng phán đoán tình huống bằng máy móc thay cho con người.

Trong những năm gần đây, các phương pháp giám sát sức khỏe kết cấu công trình dựa trên rung động đã được áp dụng rộng rãi trong việc phát hiện hư hỏng của công trình [3], [4]. Trong đó, giải thuật học sâu được đề cập như một công cụ để chọn các tính năng đánh giá tình trạng kết cấu của công trình. Một trong những lợi ích của việc sử dụng máy học là nó học được các sự cố hư hỏng và phức tạp, tự cập nhật và bổ sung lưu trữ dữ liệu quá khứ đã thu thập, trong khi các phương pháp khác không thực hiện được. Trong đó, mạng thần kinh nhân tạo (Artificial neural network - ANN) là một tập hợp các thuật toán được sử dụng trong học máy để mô hình hóa dữ liệu [5], [6], việc sử dụng thuật toán ANN để xác định hư hỏng cấu trúc cho OJP [7] với kết quả cho độ chính xác cao. Nhiều kiến trúc mạng học sâu khác nhau, như mạng nơ-ron tích chập (Convolutional neural network - CNN) ngày càng được nghiên cứu, phát triển và ứng dụng trong nhiều lĩnh vực để giảm kích thước của dữ liệu đầu vào, trích xuất các tính năng đặc trưng theo dõi sức khỏe công trình hiệu quả [8]-[10]. Về khía cạnh thực nghiệm, kết quả thực nghiệm cho thấy kỹ thuật CNN có khả năng đạt độ chính xác cao [11]. Gần đây, Xingxian Bao và các cộng sự [12] đã đề xuất phương pháp CNN một chiều cho kết cấu để xác định hư hỏng của OJP dựa trên rung động, kết quả cho thấy phương pháp này có hiệu suất cao, chính xác và phù hợp. Như vậy có thể thấy, mạng học sâu CNN [13]-[19] nằm trong xu thế phát triển của các hệ thống chẩn đoán dựa trên cơ sở dữ liệu đã thu thập, có khả năng huấn luyện và tự cập nhật, thông

minh, đặc biệt hơn là có thể kết hợp với các kỹ thuật khác trong thiết kế, cũng chính là phương pháp áp dụng trong nghiên cứu thực nghiệm của bài báo này, lựa chọn mạng GoogLeNet để phân tích hình ảnh nhiễu rung động từ ảnh phổ.

Bài báo này đề xuất một phương pháp chẩn đoán hư hỏng sử dụng mạng học sâu CNN của Google là GoogLeNet kết hợp với kỹ thuật lọc nhiễu, tạo ảnh phổ hai chiều bằng phép biến đổi wavelet [13]-[15] nhằm phát hiện sớm hư hỏng của kết cấu cho OJP. Qua thực nghiệm trên mô hình, phương pháp đề xuất đã được thử nghiệm bằng cách thu thập và xử lý dữ liệu từ các cảm biến, tập dữ liệu được chia thành hai phần, 70% cho tập dữ liệu huấn luyện và 30% cho tập dữ liệu đánh giá. Kết quả thực nghiệm tại phòng thí nghiệm cho thấy các tình huống chẩn đoán đúng với độ chính xác của huấn luyện khi kiểm tra là 97,98%. Vấn đề nghiên cứu hứa hẹn có thể mở rộng trong thực tế với số lượng cảm biến nhiều và đa chủng loại.

Bài báo được bố cục như sau: Phần giới thiệu nêu tầm quan trọng của việc phát hiện sớm hư hỏng kết cấu của OJP và hướng nghiên cứu, kết quả dự kiến đạt được. Phần 2 trình bày phương pháp thực nghiệm trong đó thu thập dữ liệu, lọc nhiễu bằng biến đổi wavelet với các trường hợp khác nhau. Phần 3 đề xuất dùng máy tính giao tiếp với STM32 Nucleo-F411RE, giao diện thực nghiệm trên thiết kế GUI của MATLAB. Các kết quả cơ bản được nêu trong phần 4 và phần 5 là các kết luận về điểm đạt được cùng với hướng nghiên cứu tiếp theo.

2. Thu thập và xử lý dữ liệu

2.1. Thu thập dữ liệu mạng cảm biến

Phần cứng mô hình kết cấu cho OJP được thiết kế bằng thép với bốn trục chính nối với nhau qua các thanh ngang và thanh chéo. Tổng chiều cao của mô hình là 2,0195 m, có hai bộ đỡ kích thước 70x70 cm như hình 1.



Hình 1. Kết nối phần cứng mô hình OJP với máy tính trong phòng thí nghiệm.


Về sơ đồ bố trí chung của mô hình thực nghiệm, số lượng tám cảm biến, trong đó mỗi sàn được gắn bốn cảm biến gia tốc để thu thập tín hiệu rung động từ hai động cơ tạo rung được đặt trên mô hình OJP, thực tế số lượng cảm biến có thể lên tới hàng trăm hệ thống vẫn đảm bảo khả năng kết nối và xử lý dữ liệu thông qua thiết kế dạng mạng cảm biến. Cụ thể, hình 2 thể hiện sơ đồ kết nối thiết bị với phần cứng kết cấu cho OJP. Các cảm biến này được kết nối với bộ điều khiển trung tâm STM32 Nucleo-F411RE

để thu thập tín hiệu và lưu trữ trên máy tính. Tín hiệu rung động trong 1000 s với tần số lấy mẫu là 0,2 s/mẫu, kết quả thu được 20.000 mẫu được lưu trên tập dữ liệu. Bảng 1 thể hiện giá trị của 15 mẫu đầu tiên trong 20.000 mẫu thu thập được. Phương thức lọc nhiễu sử dụng phép biến đổi wavelet trên phần mềm MATLAB, lọc nhiễu và dựng ảnh phổ hai chiều, kết quả ảnh phổ dùng làm đầu vào cho mạng CNN để chẩn đoán hư hỏng kết cấu của OJP.

Bảng 1. Bộ 15 dữ liệu được thu thập từ tín hiệu rung động của các cảm biến gia tốc (Analog Accelerometer ADXL335).

Số thứ tự mẫu	Thời gian (giây)	Gia tốc rung (mm/s ² - G)							
		Cảm biến 1	Cảm biến 2	Cảm biến 3	Cảm biến 4	Cảm biến 5	Cảm biến 6	Cảm biến 7	Cảm biến 8
1	0	-0.07411	-0.13028	-0.13174	-0.19426	-0.05384	-0.01159	0.01013	-0.03040
2	0.2	-0.07020	-0.11855	-0.13443	-0.19792	-0.05189	-0.01013	0.02087	-0.02649
3	0.4	-0.03162	-0.12442	-0.13443	-0.18742	-0.05116	-0.01404	0.01282	-0.01965
4	0.6	-0.04456	-0.11587	-0.18376	-0.20573	-0.05726	-0.00158	0.00915	-0.06898
5	0.8	-0.07387	-0.12149	-0.16544	-0.20915	-0.05384	-0.01037	0.01306	-0.05409
6	1	-0.06752	-0.10488	-0.15738	-0.20354	-0.06654	-0.01501	0.01697	-0.01721
7	1.2	-0.04285	-0.12002	-0.14664	-0.19035	-0.06483	-0.00989	0.00744	-0.03260
8	1.4	-0.04823	-0.11294	-0.15909	-0.19670	-0.05360	-0.01086	0.03772	-0.03992
9	1.6	-0.06703	-0.11196	-0.12393	-0.20134	-0.04603	-0.01233	0.02258	-0.00476

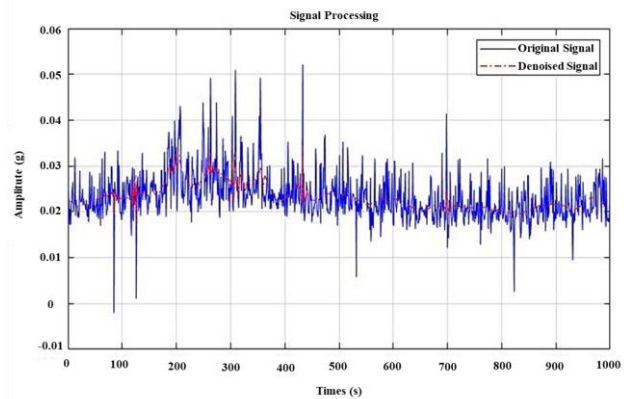
Số thứ tự mẫu	Thời gian (giây)	Gia tốc rung (mm/s ² - G)							
		Cảm biến 1	Cảm biến 2	Cảm biến 3	Cảm biến 4	Cảm biến 5	Cảm biến 6	Cảm biến 7	Cảm biến 8
10	1.8	-0.04383	-0.11636	-0.13614	-0.20842	-0.05018	-0.00940	0.01160	-0.00280
11	2	-0.03772	-0.09194	-0.15079	-0.21159	-0.06507	-0.01233	0.01477	-0.02136
12	2.2	-0.05335	-0.12124	-0.13736	-0.20573	-0.05653	-0.01111	0.01306	-0.03089
13	2.4	-0.08608	-0.11953	-0.15054	-0.21013	-0.04676	-0.00793	0.01111	-0.04725
14	2.6	-0.06410	-0.11929	-0.14053	-0.20134	-0.06361	-0.00940	0.02332	-0.03797
15	2.8	-0.04114	-0.12271	-0.13492	-0.20989	-0.06459	-0.00085	0.01453	-0.02429



Hình 2. Sơ đồ kết nối thiết bị với phần cứng mô hình OJP.

2.2. Xử lý dữ liệu và lọc nhiễu

Dữ liệu rung động tại kết cấu OJP khi được bộ điều khiển trung tâm STM32 Nucleo-F411RE đọc vào thường bị nhiễu. Vì vậy, tín hiệu đầu vào cần lọc nhiễu trước khi đưa vào biến đổi sang miền tần số. Như đã phân tích ở trên, trong nghiên cứu này lọc nhiễu tín hiệu bằng phép biến đổi wavelet, phương pháp được phát triển mạnh mẽ trong xử lý tín hiệu [15], tín hiệu gốc và sau lọc nhiễu khi qua bộ biến đổi wavelet đo được như hình 3.




Hình 3. Khử nhiễu dùng biến đổi wavelet.

Tiếp theo, tiến hành chuyển tín hiệu một chiều thành ảnh phổ hai chiều bằng cách trích xuất các tính năng của tín hiệu OJP xuất hiện trong một dải tần số nhất định sử dụng bộ biến đổi wavelet liên tục (continuous wavelet transform – CWT). Hàm CWT được định nghĩa như sau:


$$CWT(s, \omega) = \left(\frac{1}{\sqrt{s}}\right) * \int x(t) * \psi\left(\frac{t-\omega}{s}\right) * dt \quad (1)$$

Với s là tham số tỷ lệ, ω là tham số dịch chuyển vị trí và ψ hàm wavelet, trong đó *Symlets 5 wavelet* là phép biến đổi được sử dụng trong công trình này [16]. Để đánh giá độ chính xác của giải thuật CNN, sử dụng 700 tập dữ liệu (được mô tả như hình 4-7) về phân bố dạng sóng ở trạng thái bình thường và các trường hợp bất thường, từ đó, dự đoán dựa trên hình ảnh và màu sắc phổ. Số lượng tập dữ liệu không hạn chế, độ chắc chắn và chính xác càng tăng khi số mẫu càng nhiều, và thử nghiệm trong một số trường hợp.

Trường hợp không bất thường: Trạng thái bình thường của OJP được mô tả là trạng thái mà các tác động từ môi trường ở mức ổn định, thời tiết tốt cho quá trình hoạt động, các hoạt động khoan và sinh hoạt của thủy thủ đoàn hoạt động ổn định bình thường, không có tác động từ quá trình hạ trực thăng hay neo đậu của các tàu từ bên ngoài tác động lên OJP. Ảnh phổ của trường hợp bình thường màu xanh chiếm diện tích lớn, chỉ xuất hiện 1 số vệt vàng như hình 4b.




(a) Tín hiệu OJP trường hợp bình thường.




(b) Ảnh phổ của tín hiệu bình thường dùng CWT.

Hình 4. Dạng sóng tín hiệu và ảnh phổ hai chiều của tín hiệu OJP trạng thái bình thường sử dụng CWT.

Trường hợp bất thường 1: Sóng mạnh bất thường tác động lên khung chân OJP theo một tần số nhất định. Đỉnh sóng có thể thay đổi nhưng quy định cho quá trình mô phỏng là sóng mạnh, hoặc những rung chấn từ lòng biển tác động lên OJP. Hình 5b thể hiện ảnh phổ hai vệt màu vàng khi sóng đánh hay rung chấn tạo ra



(a) Tín hiệu OJP trường hợp bất thường 1.




(b) Ảnh phổ của tín hiệu

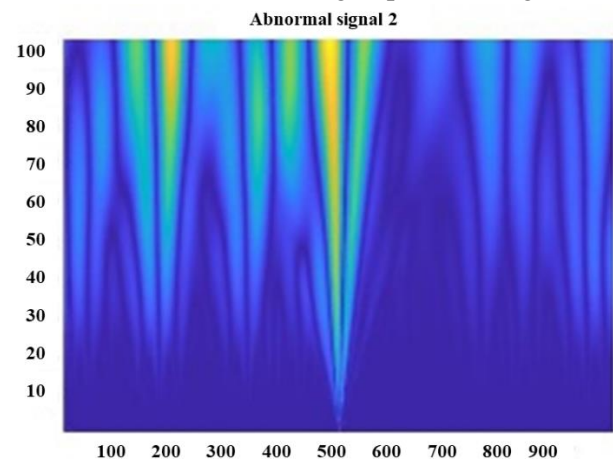
trường hợp bất thường 1 dùng CWT.

Hình 5. Dạng sóng tín hiệu và ảnh phổ 2 chiều của tín hiệu OJP trạng thái bất thường 1 sử dụng CWT.

Trường hợp bất thường 2: Các máy móc hoạt động trên OJP cộng hưởng với tác động từ tính môi của công trình làm cho bề mặt hoạt động phát sinh những “điểm bất thường” có mức độ rung chấn cao. Quá trình mô phỏng sẽ tạo ra những rung chấn ngẫu nhiên trên mọi vị trí ở bề mặt hoạt động của OJP. Ảnh phổ xuất hiện nhiều vệt vàng xen kẽ màu cam khi có điểm bất thường xảy ra như hình 6b.



(a) Tín hiệu OJP trường hợp bất thường 2.




(b) Ảnh phổ của tín hiệu

trường hợp bất thường 2 dùng CWT.


Hình 6. Dạng sóng tín hiệu và ảnh phổ 2 chiều của tín hiệu OJP trạng thái bất thường 2 sử dụng CWT.

Trường hợp bất thường 3: Lực tác động của các cơn bão trên biển lên kết cấu OJP bao gồm sóng biển mạnh và gió to tác động trực tiếp. Quá trình mô

phỏng, hệ thống OJP chịu nhiều tác động rung chấn một lúc và đa chiều. Kết quả xuất hiện rất nhiều gai nhọn màu xanh và vàng trên ảnh phổ như hình 7b.



(a) Tín hiệu OJP trường hợp bất thường 3.



(b) Ảnh phổ của tín hiệu trường hợp bất thường 3 dùng CWT.

Hình 7. Dạng sóng tín hiệu và ảnh phổ hai chiều của tín hiệu OJP trạng thái bất thường 3 sử dụng CWT.

3. Thiết kế mạng nơ-ron tích chập

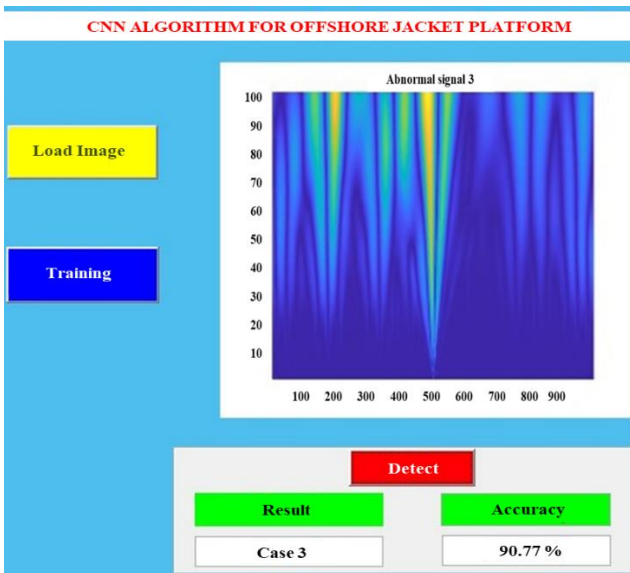
3.1. Thiết kế hệ nhúng trên MATLAB

Trong công trình này, thuật toán GoogLeNet được sử dụng để chẩn đoán hư hỏng kết cấu của OJP [13] với hình ảnh được thay đổi kích thước thành 224 x 224 x 3 điểm ảnh để giảm tải tính toán. Kiến trúc của GoogLeNet bao gồm 144 lớp. Trên hình 8 thể hiện sơ đồ khối của thuật toán CNN để chẩn đoán hư hỏng kết cấu của OJP sử dụng mạng cảm biến

đa điểm. Kết nối phần cứng như trên hình 2, hệ thống tám cảm biến rung được kết nối với bộ điều khiển trung tâm STM32 Nucleo-F411RE để thu thập tín hiệu và lưu trữ trên máy tính. Tín hiệu rung động được lọc nhiễu bằng phép biến đổi wavelet trên phần mềm MATLAB, lọc nhiễu và dựng ảnh phổ hai chiều, giao diện GUI dùng trong thực nghiệm và hiển thị kết quả được thiết kế cơ bản như trên hình 9.



Hình 8. Sơ đồ khối của thuật toán CNN để chẩn đoán hư hỏng kết cấu cho OJP.



Hình 9. Giao diện GUI để hiển thị các chẩn đoán hư hỏng kết cấu cho OJP.

3.2. Các bước triển khai thực nghiệm

Bước 1: Tín hiệu được bộ điều khiển trung tâm STM32 Nucleo-F411RE thu thập và lưu trữ trên

máy tính thành nhiều bộ dữ liệu khác nhau tương ứng với các trường hợp OJP hoạt động bình thường và bất thường.

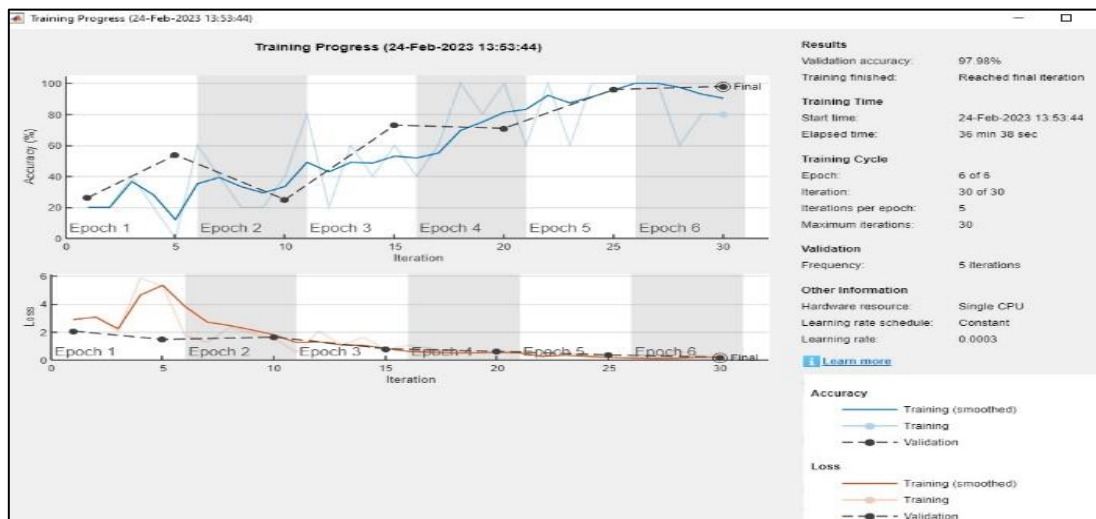
Bước 2: Dữ liệu nhận được sẽ chia thành nhiều tập dữ liệu nhỏ hơn để tiến hành lọc nhiễu thông qua phép biến đổi wavelet.

Bước 3: Chuyển đổi tín hiệu từ miền thời gian sang miền tần số và tạo bộ dữ liệu ảnh phổ hai chiều.

Bước 4: Sử dụng mạng CNN để tự động chẩn đoán các trạng thái bình thường và bất thường trên OJP với đầu vào là ảnh phổ hai chiều.

4. Kết quả thực nghiệm

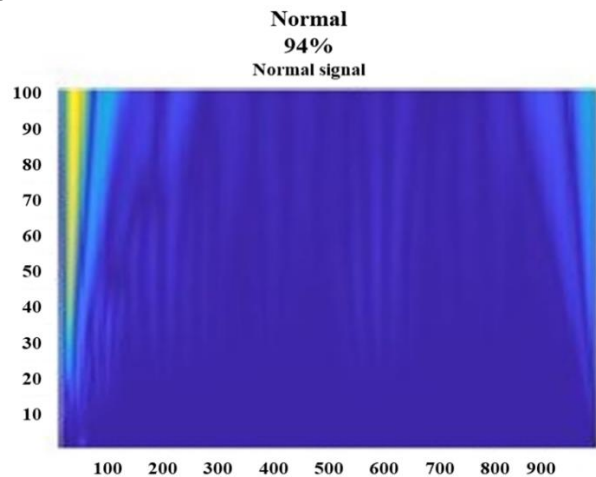
Trong nghiên cứu này, nhóm đã tiến hành đánh giá mô hình đề xuất. Đầu tiên, tập dữ liệu được chia thành hai phần, 70% cho tập dữ liệu huấn luyện và 30% cho tập dữ liệu đánh giá.



Hình 10. Huấn luyện mạng GoogLeNet cho kết cấu của OJP.

Thông số cài đặt để huấn luyện mạng gồm: miniBatchSize = 5 và MaxEpochs = 6. Quá trình huấn luyện mạng được minh họa trên hình 10 với thời gian huấn luyện là 36 phút 38 giây và độ chính xác của huấn luyện khi kiểm tra là 97,98%.


Kết quả chẩn đoán hư hỏng kết cấu OJP ở trạng thái bình thường khi các tác động từ môi trường, hoạt động khoan ổn định, không có tác động từ quá trình hạ trực thẳng lên OJP với độ chính xác 94% như hình 11.



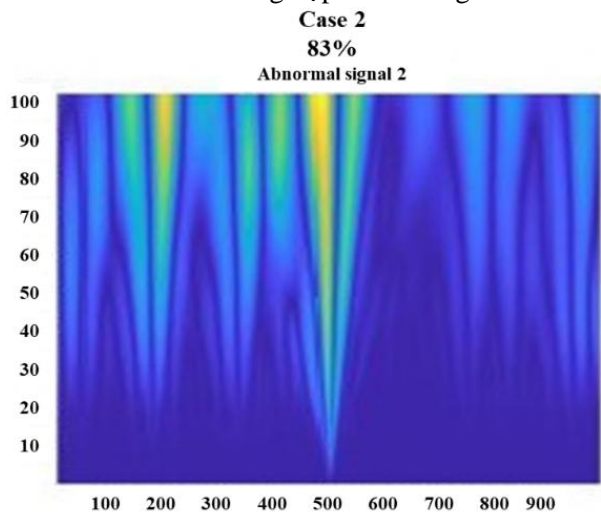
Hình 11. Kết quả chẩn đoán hư hỏng kết cấu của OJP ở trường hợp bình thường.

Các trường hợp bất thường như sóng mạnh đột ngột tác động lên khung chân OJP theo một tần số nhất định, rung chấn từ các máy móc hoạt động trên OJP, lực tác động của các cơn bão trên biển lên cấu trúc OJP bao gồm sóng biển mạnh và gió to tác động trực tiếp. Kết quả chẩn đoán hư hỏng kết cấu của OJP với độ chính xác trên 83% trong các trường hợp bất thường như hình 12-14.


Thuật toán GoogLeNet kết hợp với bộ biến đổi wavelet để lọc nhiễu và dựng ảnh phổ hai chiều đã được thử nghiệm đạt độ chính xác cao trong việc chẩn đoán hư hỏng kết cấu OJP.



Hình 12. Kết quả chẩn đoán hư hỏng kết cấu của OJP ở trường hợp bất thường 1.



Hình 13. Kết quả chẩn đoán hư hỏng kết cấu của OJP ở trường hợp bất thường 2.



Hình 14. Kết quả chẩn đoán hư hỏng kết cấu của OJP ở trường hợp bất thường 3.

5. Kết luận

Trong nghiên cứu này, nhóm đã đề xuất một mô hình chẩn đoán hư hỏng cho kết cấu OJP dựa trên bộ biến đổi wavelet liên tục và mạng nơ-ron tích chập CNN có thể phân loại tín hiệu thành các trường hợp bình thường và bất thường. Tín hiệu được xử lý lọc nhiễu và dựng ảnh phổ hai chiều bằng bộ biến đổi wavelet. Kết quả chẩn đoán các tình trạng bình thường, bất thường của kết cấu OJP bằng cách thực nghiệm trên mô hình với giải thuật đề xuất. Kết quả bước đầu cho thấy độ chính xác cao trong dự đoán định tính. Việc kết nối các cảm biến dưới dạng mạng hỗ trợ quá trình thu thập dữ liệu nhằm mở rộng số lượng cảm biến, không cần thay đổi phương thức thu thập dữ liệu. Trong các nghiên cứu tiếp theo, cần phải thu thập nhiều tập dữ liệu sự cố bất thường trên OJP để đưa vào huấn luyện cho kết quả chẩn đoán tốt hơn và đánh giá định lượng các kết quả cuối cùng.

Lời cảm ơn

Nghiên cứu được tài trợ bởi Bộ Giao thông vận tải, thông qua đề tài mã số “DT223014”: Thiết kế chế tạo hệ thống thu thập và xử lý dữ liệu ứng dụng mạng cảm biến đa điểm (Multi-point sensor network) kết hợp giải thuật học sâu (Deep learning) nhằm kiểm soát các tiêu chí về tính đều đặn trên mặt phẳng của kết cấu công trình ngoài khơi.

Tài liệu tham khảo

- [1] X. K. Dang, T. D. Tran, V. D. Do, L. A. H. Ho, V. V. Le; “Self-Adaptive fuzzy control approach for jack-up rig jacking system based on particle swarm optimization”. *IEEE Access*. 2022; 10:86064-86077. DOI:10.1109/ACCESS.2022.3197835.
- [2] V. D. Do, X. K. Dang, T. D. Tran, T. D. A. Pham; “Jacking and energy consumption control over network for jack-up rig: simulation and experiment”. *Polish Maritime Research*. 2022; 29(3):89-98. DOI: 10.2478/pomr-2022-0029.
- [3] N. A. Spanos, J. S. Sakellariou, S. D. Fassois; “Vibration-response-only statistical time series structural health monitoring methods: A comprehensive assessment via a scale jacket structure”. *Structural Health Monitoring*. 2020; 19(3):736-750. DOI:10.1177/1475921719862487.
- [4] M. H. Heari, A. Lotfi, K. M. Dolatshahi, A. A. Golafshani; “Inverse vibration technique for structural health monitoring of offshore jacket platforms”. *Applied Ocean Research*. 2017; 19:180-198. DOI: 10.1016/j.apor.2016.11.010.
- [5] X. W. Ye, T. Jin, C. B. Yun; “A review on deep learning-based structural health monitoring of civil infrastructures”. *Smart Structures and Systems*. 2019; 24(5):567-586. DOI:10.12989/sss.2019.24.5.567.
- [6] Y. Z. Lin, Z. H. Nie; “Structural damage detection with automatic feature-extraction through deep learning”. *Computer-Aided Civil and Infrastructure Engineering*. 2017; 32(6):1-22. DOI:10.1111/mice.12313.
- [7] J. Guo, J. Wu, J. Guo, Z. Jiang; “A damage identification approach for offshore jacket platforms using partial modal results and artificial neural networks”. *Applied Sciences*. 2018; 8(11). DOI:10.3390/app8112173.
- [8] O. Avci, O. Abdeljaber, S. Kiranyac, M. Hussein, M. Gabbouj, D. J. Inman; “A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications”. *Mechanical Systems and Signal Processing*. 2017; vol.147. DOI:10.1016/j.ymssp.2020.107077.
- [9] X. K. Dang, H. N. Truong, V. C. Nguyen, T. D. A. Pham; “Applying convolutional neural networks for limited-memory application”. *Telecommunication Computing Electronics and Control*. 2021; 19(1):244-251. DOI:10.12928/telkomnika.v19i1.16232.
- [10] X. K. Dang, L. A. H. Ho, X. P. Nguyen, B. L. Mai; “Applying artificial intelligence for the application of bridges deterioration detection system”. *Telecommunication Computing Electronics and Control*. 2022; 20(1):149-157. DOI: 10.12928/telkomnika.v20i1.20783.
- [11] O. Abdeljaber, O. Avci, M. S. Kiranyaz, B. Boashash, H. Sodano, D. J. Inman; “1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data”. *Neurocomputing*. 2018; 275:1308-1317. DOI: 10.1016/j.neucom.2017.09.069.
- [12] X. Bao, T. Fan, C. Shi, G. Yang; “One-dimensional convolutional neural network for damage detection of jacket-type offshore platforms”. *Ocean Engineering*. 2021; 219. DOI:10.1016/j.oceaneng.2020.108293.
- [13] J. Y. Chou, Y. Fu, S. K. Huang, C. M. Chang; “SHM data anomaly classification using machine learning strategies: A comparative study”. *Smart Structures and Systems*. 2022; 29(1):77-91. DOI:10.12989/sss.2022.29.1.077.
- [14] Y. Y. Liu, Y. F. Ju, C. D. Duan, X. F. Zhao; “Structure damage diagnosis using neural network and feature fusion”. *Engineering Applications of Artificial Intelligence*. 2011; 24(1):87-92. DOI: 10.1016/j.engappai.2010.08.011.
- [15] R. F. Olanrewaju, S. N. Ibrahim, A. L. Asnawi, H. Altaf; “Classification of ECG signals for detection of arrhythmia and congestive heart failure based on continuous wavelet transform and deep neural networks”. *Indonesian Journal of Electrical Engineering and Computer Science*. 2021; 22(3):1520-1528. DOI: 10.11591/ijeecs.v22.i3.pp1520-1528.
- [16] I. Sornsen, C. Suppitaksakul, P. Toonkum; “Mother wavelet performance evaluation for

- noise removal in partial discharge signals”. ECTI Transactions on Electrical Engineering, electronics, and communications. 2022; 20(3):450-459. DOI: 10.37936/ecti-eec.2022203.247521.
- [17] X. Wu, X. Liu; “Building crack identification and total quality management method based on deep learning”. Pattern Recognition Letters. 2021; 145:225-231. DOI:10.1016/j.patrec.2021.01.034.
- [18] H. S. Munawar, A. W. A. Hammad, S. T. Waller, M. R. Islam; “Modern Crack Detection for Bridge Infrastructure Maintenance Using Machine Learning”. Human-Centric Intelligent Systems. 2022; 2:95–112. DOI:10.1007/s44230-022-00009-9.
- [19] K. Liu, G. Yang, J. Zhang, Z. Zhao, X. Chen, B. M. Chen; “Datasets and methods for boosting infrastructure inspection: a survey on defect classification”; in Proc. 2022 IEEE 17th international conference on control & automation (ICCA); 27-30 June 2022; Naples, Italy. IEEE; 2022; pp.15–22.