

# Nghiên cứu ứng dụng mô hình mạng nơ-ron nhân tạo để dự đoán sức chịu tải tới hạn của cấu kiện thép chữ Y

■ TS. LÝ HẢI BẮNG; TS. NGUYỄN THỦY ANH

Trường Đại học Công nghệ Giao thông vận tải

**TÓM TẮT:** Cấu kiện thép chữ Y đang ngày càng được sử dụng rộng rãi trong các công trình cơ sở hạ tầng, giao thông. Tuy nhiên, đối với cấu kiện chịu lực như vậy, sự mất ổn định là nguyên nhân quan trọng nhất dẫn tới hư hỏng của cấu kiện và toàn bộ kết cấu. Việc dự đoán cũng như đánh giá sự mất ổn định của cấu kiện phức tạp bởi nhiều yếu tố như khuyết điểm khuyết hinh học, cơ tính của vật liệu, quá trình thi công lắp ráp, lực tác động và liên kết. Nghiên cứu này tập trung vào việc ứng dụng trí tuệ nhân tạo (Artificial Intelligence) để xây dựng mô hình dự báo sức chịu tải tới hạn của cấu kiện thép chữ Y, được tạo thành từ việc hàn giữa thép góc đều cạnh và thép tấm. Mô hình được sử dụng là mô hình mạng nơ-ron nhân tạo lan truyền ngược (ANN) với thuật toán Levenberg Marquart. Kết quả cho thấy mô hình ANN dự báo rất tốt sức chịu tải tới hạn, với độ chính xác cao và sai số thấp.

**TỪ KHÓA:** Trí tuệ nhân tạo (AI), mạng nơ-ron nhân tạo, cấu kiện thép chữ Y, sức chịu tải tới hạn

**ABSTRACT:** The use of Y-section steel column has gained many attention and widely used in civil engineering. However, instability is the most important cause of deterioration of structural elements under compression. The prediction as well as the evaluation of instability for such type of structural member is a complex problem because of various reasons such as the defects in the section, mechanical or material properties, manufacturing process, boundary conditions and applied force. The objective of this research consists in the modeling and predicting the instability of structural elements under compression using Artificial Neural Network (ANN) with the Levenberg Marquart algorithm. The considered Y-section columns are made by welding steel of equal angles and a steel plate. The results show that the ANN model has a strong capability to model the critical buckling load of Y-section steel columns, with a high correlation coefficient and low error.

**KEYWORDS:** Artificial Intelligence (AI), Artificial Neural Network, Y-section steel column, critical buckling load

## 1. ĐẶT VẤN ĐỀ

Trong lĩnh vực xây dựng hiện đại ngày nay, vật liệu thép được sử dụng cho hầu hết các công trình bao gồm các công trình cơ sở hạ tầng, cầu, tháp, sân bay... nhờ những ưu điểm của nó so với các loại vật liệu khác. Ứng dụng phổ biến của vật liệu thép cho các bộ phận của công trình là sử dụng làm các cấu kiện chịu lực như thân vòm, trụ cầu, các thanh giàn, cột chống bê tông cốt thép hoặc các loại cọc trong móng. Cùng với sự phát triển và nhu cầu xây dựng trong lĩnh vực GTVT, yêu cầu của vật liệu thép trong các kết cấu đang được quan tâm hơn bao giờ hết, trong đó thép cường độ cao được sử dụng rộng rãi vì nhiều ưu điểm so với thép cường độ thông thường. Tuy nhiên, các ứng dụng hiện nay chỉ giới hạn ở một số dạng cột có mặt cắt truyền thống như thép ống, thép góc và thép hình chữ tháp. Ngoài các dạng cột truyền thống trên, hiện nay một loại cột hình chữ Y đã được đề xuất sử dụng cho cấu kiện chịu lực.

Đối với cấu kiện chịu lực, sự mất ổn định là nguyên nhân quan trọng nhất dẫn tới sự hư hỏng của cấu kiện và cả kết cấu. Ổn định là một khái niệm thường hay gặp trong lĩnh vực khoa học xây dựng. Khi bị mất ổn định, biến dạng của công trình tăng lên đột biến và khiến cho công trình bị sụp đổ hoàn toàn, gây thiệt hại lớn về người và tài sản. Vì vậy, tính toán ổn định cho các loại cấu kiện đã có lịch sử phát triển tương đối lâu trên thế giới. Trong thế kỷ 19, những nghiên cứu đầu tiên về sự mất ổn định của cấu kiện chịu lực đã được Euler đề xuất. Tuy nhiên, công thức Euler chỉ phù hợp cho những cấu kiện có độ mảnh lớn. Sau này, các nghiên cứu thực nghiệm của Lasinski cũng như các đề xuất của Johnson đã cho phép tìm được lực tới hạn mất ổn định cho những cấu kiện có độ mảnh vừa và nhỏ. Nhưng các công thức này được thiết lập chỉ đang áp dụng cho vật liệu dẻo hướng, đồng nhất và còn có rất nhiều giả thiết về sự hoàn hảo của cấu kiện.

Trên thực tế, sự mất ổn định của cột còn phụ thuộc vào nhiều yếu tố: cơ tính vật liệu; dạng hình học mặt cắt ngang, chiều dài của cấu kiện; liên kết, điều kiện biên hoặc tải trọng... Do đó cho đến nay, nhiều phương pháp tiếp cận thực nghiệm và số đã được các nhà nghiên cứu phát triển. Ví dụ, trong nghiên cứu của Shi [1,2] đã chỉ ra rằng, điều kiện ổn định của ống thép đã bị giảm xuống so với các thiết kế tiêu chuẩn.

Trong nhiều nghiên cứu thử nghiệm khác về sự mất ổn định của cột, chẳng hạn như cột hình hộp, cột tiết diện I và tiết diện rộng, kết quả thử nghiệm đã chứng minh rằng mất ổn định của cột xuất hiện sớm hơn so với ước tính được cung cấp bởi các tiêu chuẩn thiết kế hiện có. Tuy nhiên, tất cả các thử nghiệm trong phòng thí nghiệm này thường phức tạp, tốn kém và mất thời gian, không phải lúc nào cũng có thể xét đến ảnh hưởng của tất cả các biến như chiều dài cột, hình học của mặt cắt ngang và tính chất cơ học của vật liệu, cũng như các điều kiện biên đến sự mất ổn định của cột [3,4]. Kết quả từ các nghiên cứu thử nghiệm trên thấy rằng, khi cột mất ổn định thì quan hệ giữa tải trọng tác dụng và biến dạng là phi tuyến, làm cho việc phân tích ứng xử của cấu kiện trở nên phức tạp hơn.

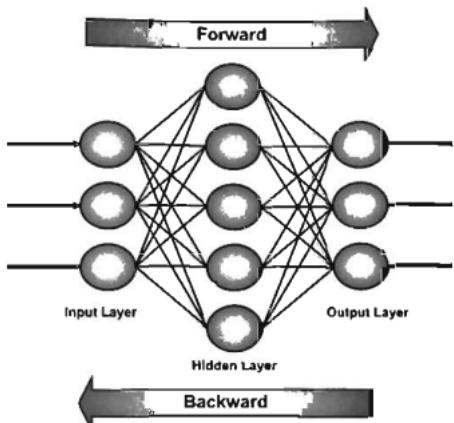
Những năm gần đây, trí tuệ nhân tạo (AI) dựa trên khoa học máy tính đã dần trở nên phổ biến và được áp dụng trong nhiều lĩnh vực khác nhau. Mạng nơ-ron nhân tạo (ANN) - một nhánh phát triển của AI đã và đang được sử dụng rộng rãi bởi nhiều nhà khoa học áp dụng cho ngành kỹ thuật xây dựng. Rất nhiều công trình nghiên cứu đã được công bố chứng minh tiềm năng của mô hình này trong việc dự đoán khả năng ứng xử của các cấu kiện cũng như vật liệu khác nhau trong lĩnh vực cơ học kỹ thuật.

Đo đó, mục đích chính của bài báo này là nghiên cứu ứng dụng mô hình ANN trong việc dự đoán khả năng mất ổn định của cột thép cường độ cao tiết diện chữ Y.

## 2. THIẾT LẬP MÔ HÌNH DỰ BÁO

### 2.1. Mạng nơ-ron lan truyền ngược (Backpropagation Neural Network - BPNN)

Mạng nơ-ron lan truyền ngược (BPNN) là một trong những kiến trúc mạng nơ-ron phổ biến nhất, đã được sử dụng trong rất nhiều các ứng dụng học máy. Cấu trúc của BPNN được minh họa trong Hình 2.1, bao gồm ba hoặc nhiều lớp tế bào thần kinh được liên kết với nhau: lớp biến đầu vào, một hoặc nhiều lớp ẩn ở giữa và lớp biến đầu ra. Mỗi lớp trong mạng có một số nút (nơ-ron) cố định. Lớp biến đầu vào nhận dữ liệu đầu vào từ nguồn bên ngoài, lớp đầu ra truyền kết quả xử lý của mạng nơ-ron và lớp ẩn cung cấp, xử lý các mối quan hệ giữa lớp đầu vào và đầu ra. Quá trình hoạt động của BPNN có thể được mô tả trong hai bước. Đầu tiên, tín hiệu đầu vào được truyền về phía trước từ lớp đầu vào, thông qua lớp ẩn, đến lớp đầu ra. Trong quá trình này, giá trị trọng số và giá trị bù của mạng được duy trì không đổi và trạng thái của từng lớp tế bào thần kinh sẽ chỉ ảnh hưởng đến lớp tế bào thần kinh tiếp theo. Sự khác biệt giữa đầu ra dự đoán và đầu ra dự kiến của mạng được xác định là tín hiệu lỗi. Thứ hai, tín hiệu lỗi được truyền ngược từ lớp đầu ra sang lớp đầu vào theo từng lớp. Trong quá trình này, giá trị trọng lượng của mạng được điều chỉnh bởi phản hồi lỗi để làm cho đầu ra dự đoán của mạng gần hơn với dự kiến.



Hình 2.1: Cấu trúc của mạng nơ-ron lan truyền ngược

### 2.2. Thuật toán Levenberg Marquart

Thuật toán Levenberg Marquart (LM) về cơ bản là một sự tiến hóa của thuật toán tối ưu suy giảm độ dốc và thuật toán Newton, có khả năng tăng tốc độ hội tụ của việc tìm nghiệm bằng cách giảm quá trình lặp và sau đó tạo ra các dữ liệu chính xác hơn. So với những nhược điểm của BPNN truyền thống như tốc độ hội tụ chậm và các vấn đề tối thiểu cục bộ, tốc độ hội tụ của thuật toán LM là nhanh nhất trong tất cả các mạng truyền thống hoặc được cải thiện. Các BPNN cải tiến với thuật toán LM đã được chứng minh là đạt được kết quả tuyệt vời, đặc biệt là khi áp dụng để đánh giá và dự đoán. Vì những lý do này, thuật toán LM được sử dụng trong nghiên cứu này. Thuật toán LM cung cấp một giải pháp được gọi là bình phương tối thiểu có dạng như sau:

$$f(x) = \frac{1}{2} \sum_{j=1}^m r_j^2(x) \quad (1)$$

Trong đó:  $x = (x_1, x_2, \dots, x_n)$  là vector;  $r_j$  là hàm từ  $\mathbb{R}^n \rightarrow \mathbb{R}$ . Các  $r_j$  được gọi là phần dư khi  $m \geq n$ . Để đơn giản,  $f$  được biểu diễn dưới dạng vector dữ liệu:  $r: \mathbb{R}^n \rightarrow \mathbb{R}^m$  và được biểu diễn như sau:

$$r(x) = (r_1(x), r_2(x), \dots, r_m(x)) \quad (2)$$

Khi đó,  $f$  có thể được viết lại thành  $f(x) = \frac{1}{2} \|r(x)\|^2$ . Các đạo hàm của  $f$  có thể được viết bằng ma trận Jacobи và được định nghĩa như sau:

$$J(x) = \frac{\partial r_i}{\partial x_i}; 1 \leq i \leq m; 1 \leq j \leq n. \quad (3)$$

Trước tiên, xét trường hợp mọi hàm  $r_i$  là tuyến tính. Ở đây, Jacobian là hằng số và do đó  $f$  được cho bởi bậc hai như sau:

$$f(x) = \frac{1}{2} \|Jx + r(0)\|^2 \quad (4)$$

Ta nhận được:

$$\nabla f(x) = J^T (Jx + r) \quad (5)$$

$\nabla^2 f(x) = J^T J$  (6)  
 Giải quyết tối thiểu bằng cách đặt  $\nabla f(x) = 0$  để đạt được  $x_{\text{min}} = -(J^T J)^{-1} J^T r$ . Đây là kết quả của phương trình bình thường. Quay trở lại trường hợp chung, trường hợp phi tuyến, ta có:

$$\nabla f(x) = \sum_{j=1}^m r_j(x) \nabla r_j(x) = J(x)^T r(x) \quad (7)$$

$$\nabla^2 f(x) = J(x)^T J(x) + \sum_{j=1}^m r_j(x) \nabla^2 r_j(x) \quad (8)$$

Thuộc tính đặc biệt của các bài toán bình phương tối thiểu là với ma trận Jacobi  $J$ , về cơ bản có thể nhận được ngay ma trận Hessian ( $\nabla^2 f(x)$ ) nếu có thể xấp xỉ  $r$  bằng các hàm tuyến tính ( $\nabla^2 r_j(x)$ ) là nhỏ hoặc phần dư ( $r(x)$ ) nhỏ. Ma trận Hessian trường hợp này đơn giản trớ trêu:

$$\nabla^2 f(x) = J(x)^T J(x) \quad (9)$$

Kết quả tương tự như đối với trường hợp tuyến tính.

### 2.3. Đánh giá khả năng dự báo của mô hình

Trong nghiên cứu này, hai tiêu chí được sử dụng là hệ số tương quan ( $R$ ) (correlation coefficient) và sai số RMSE (Root Mean Square Error) để đánh giá độ chính xác của mô hình AI đã phát triển [5]:

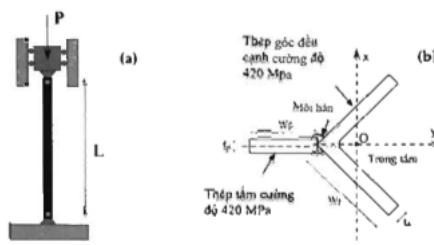
$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (p_{e,j} - \bar{p}_e)^2} \quad (10)$$

$$R = \frac{\sum_{j=1}^N (p_{e,j} - \bar{p}_e)(p_{d,j} - \bar{p}_d)}{\sqrt{\sum_{j=1}^N (p_{e,j} - \bar{p}_e)^2 \sum_{j=1}^N (p_d - \bar{p}_d)^2}} \quad (11)$$

Trong đó:  $N$  - Số lượng bộ dữ liệu,  $p_e$  và  $\bar{p}_e$  - Giá trị thí nghiệm thực tế và giá trị thí nghiệm thực tế trung bình,  $p_d$  và  $\bar{p}_d$  là giá trị dự đoán và giá trị dự đoán trung bình, được tính theo mô hình dự báo.

## 3. DỮ LIỆU THÍ NGHIỆM

Trong nghiên cứu này, sử dụng các cột tiết diện chữ Y được tạo thành từ thép góc đều cạnh và thép tấm liên kết với nhau bằng liên kết hàn, cả hai đều được chế tạo từ thép kết cấu 420MPa. Các mối hàn được chế tạo bằng điện cực E5515-1CM. Số liệu bao gồm 57 kết quả thử nghiệm trong nghiên cứu của Yu [6] với các biến đầu vào (chiều dài cột, kích thước hình học của mặt cắt (chiều dày, chiều rộng của thép tấm và thép góc), độ lệch hình học ban đầu theo cả hai hướng x và y) và một biến đầu ra (tài trọng của cột thép hình chữ Y cường độ cao 420MPa với tỷ lệ độ mảnh thay đổi từ 30 đến 80) đã được sử dụng để tạo các tập dữ liệu huấn luyện và thử nghiệm. Bộ dữ liệu thí nghiệm được chia thành hai phần: phần thử nhát (70% số liệu) dùng để huấn luyện mạng ANN và được gọi là phần huấn luyện; phần thử hai (30% số liệu) dùng để kiểm chứng mô hình, sẽ được gọi tắt là phần kiểm chứng. Với cách chia trên, bộ dữ liệu gồm 57 số liệu sẽ có 40 số liệu dùng để huấn luyện và 17 số liệu dùng để đánh giá khả năng dự báo mất ổn định cấu kiện của mạng ANN. Hình 3.1 mô tả sơ đồ thí nghiệm sức chịu tải tới hạn của cấu kiện thép chữ Y và tiết diện mảnh cắt ngang của thép.



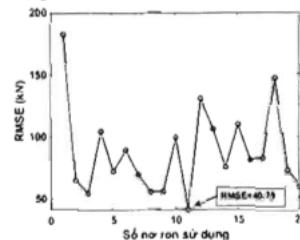
Hình 3.1: a) Mô tả sơ đồ thí nghiệm  
và b) - Mảnh cắt của thép chữ Y

## 4. KẾT QUẢ

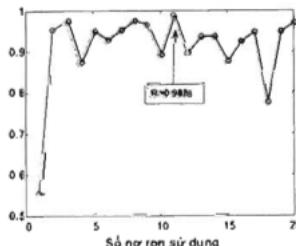
Trong nghiên cứu này sử dụng cấu trúc BPNN gồm 3 lớp: 01 lớp đầu vào gồm 7 nơron tương ứng với 7 thông số đầu vào, 01 lớp ẩn với số nơron thay đổi để nghiên cứu ảnh hưởng của số nơron đến khả năng dự báo và một lớp đầu ra gồm 01 nơron là giá trị Pu thể hiện tải trọng tới hạn của cột.

### 4.1. Nghiên cứu ảnh hưởng của số nơron

Thực tế, năng lực dự báo của mô hình không bị ảnh hưởng bởi số nơron trong lớp ẩn, có nghĩa không phải số nơron càng nhiều thì khả năng dự báo càng cao hoặc ngược lại. Vì vậy, để lựa chọn số nơron cho lớp ẩn để khả năng dự báo của mô hình để xuất là tốt nhất. Trong nghiên cứu này, xét trường hợp số nơron của lớp ẩn thay đổi từ 1 - 20 để từ đó lựa chọn số nơron hợp lý nhất cho lớp ẩn để tính toán cho các phần tiếp theo. Sử dụng phần mềm MATLAB ta có kết quả của hai tiêu chí đánh giá RMSE và R được thể hiện trên Hình 4.1 và 4.2 trên nguyên tắc RMSE càng nhỏ và R càng cao thì mô hình càng tốt.



Hình 4.1: Quan hệ giữa RMSE và số nơron sử dụng trong mô hình ANN cho phần kiểm chứng

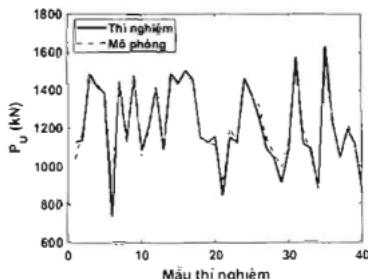


Hình 4.2: Quan hệ giữa R và số nơron sử dụng trong mô hình ANN cho phần kiểm chứng

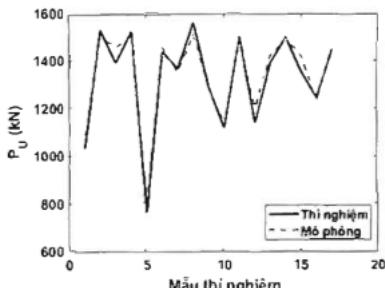
Dựa vào kết quả thể hiện trên Hình 4.1 và 4.2 thấy rằng, khi số nơ-ron của lớp ẩn là 11 thì kết quả đạt được là tốt nhất. Khi số nơ-ron là 1 thì năng lực dự báo của mô hình là không tốt. Ngoài ra, khi mô hình sử dụng 2 nơ-ron trở lên thì năng lực dự báo dao động trong khoảng RMSE = 80 và xung quanh giá trị  $R = 0.9$ . Riêng trường hợp số nơ-ron là 18 thì năng lực dự báo của ANN cũng bị sụt giảm hẳn, khi các giá trị của  $R$ , RMSE tương ứng là 0,77 và 149. Do đó, 11 nơ-ron là số thích hợp và cho kết quả dự báo tốt nhất để có thể tiếp tục nghiên cứu cho phần tiếp theo.

#### 4.2. Nghiên cứu khả năng dự báo của mô hình

Theo phần 4.1, sử dụng 11 nơ-ron cho lớp ẩn là số tốt nhất để tiếp tục nghiên cứu. Sử dụng phần mềm MATLAB cho kết quả huấn luyện và kiểm chứng về dự báo tải trọng tới hạn của cột được thể hiện ở Hình 4.3 và 4.4. Qua đây, thấy rằng kết quả huấn luyện mang ANN cho phần thí nghiệm và mô phỏng là gần như trùng nhau, điều này cho thấy năng lực dự báo của mô hình ANN là rất tốt.

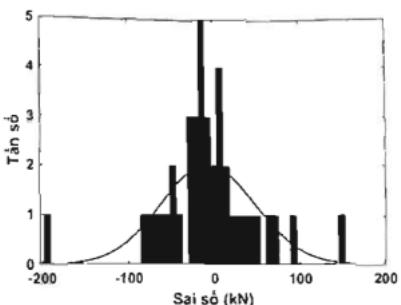


Hình 4.3: Kết quả huấn luyện mạng ANN cho phần huấn luyện

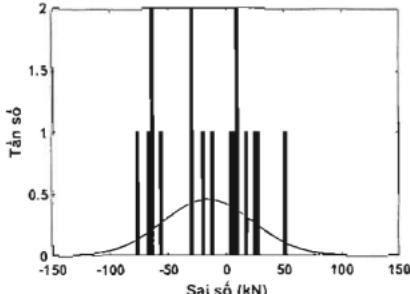


Hình 4.4: Kết quả huấn luyện mạng ANN cho phần kiểm chứng

Hình 4.5 và 4.6 biểu thi dưới dạng biểu đồ thể hiện kết quả sai số huấn luyện mang cho phần huấn luyện và phần kiểm chứng. Trong phần huấn luyện, chỉ có 01 mẫu có sai số lên đến 200kN, 01 mẫu có sai số 150kN, một số mẫu sai số trong khoảng  $\pm 100$ kN, còn lại sai số của các mẫu đều trong khoảng 80kN. Trong phần kiểm chứng, sai số của các mẫu ít hơn, chỉ lên đến khoảng 80kN và tập trung nằm trong khoảng  $\pm 50$ kN. Điều này cho thấy khả năng dự báo của mô hình ANN đã xuất là tốt.

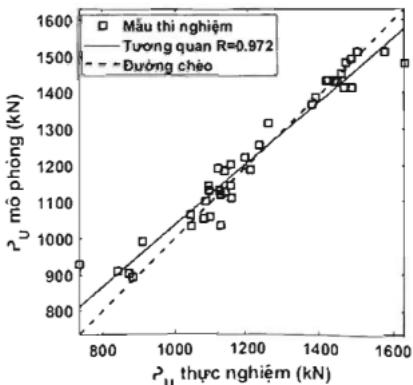


Hình 4.5: Kết quả sai số huấn luyện mạng ANN cho phần huấn luyện

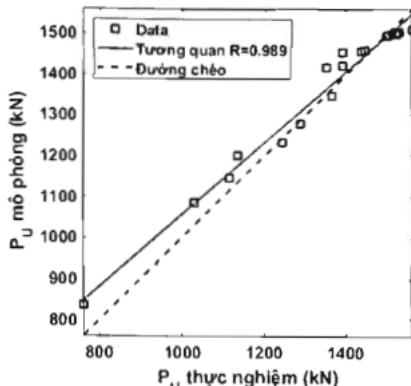


Hình 4.6: Kết quả sai số huấn luyện mạng ANN cho phần kiểm chứng

Mô hình hồi quy cho hai phần huấn luyện và kiểm chứng được thể hiện ở Hình 4.7 và Hình 4.8. Từ hình trên ta thấy khả năng dự báo của mô hình là khá sát với khả năng chịu lực thực tế, tuy nhiên vẫn có sự sai số với các cột chịu lực nhỏ. Giá trị tương quan  $R$  thu được cho phần huấn luyện là  $R = 0,972$ , còn phần kiểm chứng là  $R = 0,989$ . Điều này cho thấy, việc áp dụng mô hình ANN cho việc dự báo tải trọng tới hạn của cấu kiện cột là rất khả thi do tính chính xác cao và sai số thấp.



Hình 4.7: Kết quả hồi quy mạng ANN cho phần huấn luyện



Hình 4.8: Kết quả hồi quy mạng ANN cho phần kiểm chứng

## 5. KẾT LUẬN VÀ KIẾN NGHỊ

Từ kết quả nghiên cứu, nhóm tác giả có những kết luận, kiến nghị sau:

- Từ việc sử dụng 57 số liệu từ các thí nghiệm cho cột thép tiết diện Y cường độ 420MPa, một mô hình ANN đã được xây dựng để dự đoán khả năng chịu tải của cột và được xác nhận bằng các tiêu chí RMSE và R. Kết quả thu được cho thấy mô hình có độ tin cậy cao để dự báo khả năng chịu lực của cột thép ( $R = 0,988$ ;  $RMSE = 40,79$ ).

- Tuy nhiên, số lượng dữ liệu dùng cho nghiên cứu này còn ít và một số thông số vẫn còn chưa được đề cập đến như sự tồn tại của ứng suất dư, điều kiện biên... nên nhóm tác giả có kiến nghị trong các nghiên cứu tiếp theo, cần sử dụng số lượng dữ liệu lớn và để xuất thêm một số các thông số ảnh hưởng đến khả năng chịu lực của cột để đảm bảo được độ chính xác hơn nữa.

### Tài liệu tham khảo

- [1]. G. Shi, W. J. Zhou, Y. Bai, and C. C. Lin (2014), *Local buckling of 460 MPa high strength steel welded section stub columns under axial compression*, Journal of Constructional Steel Research, vol.100, pp.60-70, doi: 10.1016/j.jcsr.2014.04.027.
- [2]. G. Shi, K. Xu, H. Ban and C. Lin (2016), *Local buckling behavior of welded stub columns with normal and high strength steels*, Journal of Constructional Steel Research, vol.119, pp.144-153, doi: <https://doi.org/10.1016/j.jcsr.2015.12.020>.
- [3]. G. Prathap and T. K. Varadan (1976), *The Inelastic Large Deformation of Beams*, J. Appl. Mech, vol.43, no.4, pp.689-690, Dec., doi: 10.1115/1.3423957.
- [4]. J. T. Oden and S. B. Childs, *Finite Deflections of a Nonlinearly Elastic Bar*, J. Appl. Mech, vol.37, no.1, pp.48-52, Mar. 1970, doi: 10.1115/1.3408488.
- [5]. H.-B. Ly et al. (2019), *Hybrid Artificial Intelligence Approaches for Predicting Critical Buckling Load of Structural Members under Compression Considering the*

Influence of Initial Geometric Imperfections, Applied Sciences, vol.9, no.11, p.2258, Jan., doi: 10.3390/app9112258.

[6]. X. Yu, H. Deng, D. Zhang and L. Cui (2017), *Buckling behavior of 420MPa HSSY columns: Test investigation and design approach*, Engineering Structures, vol.148, pp.793-812, Oct., doi: 10.1016/j.engstruct.2017.07.016.

Ngày nhận bài: 20/01/2020

Ngày chấp nhận đăng: 15/02/2020

Người phản biện: TS. Phạm Thái Bình

TS. Trần Văn Quân