

# ỨNG DỤNG HỆ THỐNG MẠNG NƠ RON THÍCH NGHI MỜ ĐỂ DỰ ĐOÁN ĐỘ NHÁM BỀ MẶT KHI TIỆN THÉP AISI 304

## APPLICATION OF ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM FOR PREDICTING SURFACE ROUGHNESS IN TURNING AISI 304 STEEL

Trần Công Chi\*

*Trường Đại học Lâm nghiệp, Việt Nam<sup>1</sup>*

\*Tác giả liên hệ / Corresponding author: trancongchi\_bk@yahoo.com

(Nhận bài / Received: 20/12/2024; Sửa bài / Revised: 09/01/2025; Chấp nhận đăng / Accepted: 04/02/2025)

DOI: 10.31130/ud-jst.2025.573

**Tóm tắt** - Nghiên cứu này xem xét ảnh hưởng của ba thông số khi tiện là chiều sâu cắt ( $t$ ), lượng chạy dao ( $f$ ) và tốc độ cắt ( $n$ ) đối với độ nhám bề mặt ( $R_a$ ), đồng thời phát triển một mô hình dự báo khi gia công thép AISI 304 bằng hệ thống mạng nơ ron thích nghi mờ (ANFIS). Kết quả phân tích ANOVA cho thấy, cả ba thông số cắt đều có tác động đáng kể đến  $R_a$ , trong đó tham số  $f$  có ảnh hưởng mạnh nhất, nhân mạnh vai trò của nó trong việc kiểm soát độ nhám bề mặt. Mô hình dự đoán ANFIS được phát triển thông qua hai phương pháp đào tạo Hybrid và Backpropagation tương ứng với tám hàm thuộc khác nhau. Kết quả cho thấy, mô hình đào tạo Hybrid sử dụng hàm thuộc Gaussmf đạt hệ số xác định  $R^2$  cao nhất là 0,986081 và căn bậc hai của sai số bình phương trung bình (RMSE) thấp nhất là 0,013055. Những kết quả này chứng minh rằng, mô hình ANFIS có khả năng dự đoán  $R_a$  một cách tương đối chính xác dựa trên các thông số gia công.

**Từ khóa** - Độ nhám bề mặt; mạng nơ ron thích nghi mờ (ANFIS); mô hình dự báo; tiện; thép AISI 304

### 1. Đặt vấn đề

Trong lĩnh vực gia công kim loại, độ nhám bề mặt là một trong những yếu tố quan trọng ảnh hưởng đến chất lượng sản phẩm [1]. Đặc biệt, trong quá trình tiện, độ nhám bề mặt không chỉ quyết định tính năng kỹ thuật của chi tiết mà còn ảnh hưởng đến tuổi thọ và hiệu suất của các linh kiện máy móc. Do đó, việc dự đoán chính xác độ nhám bề mặt cho phép các nhà sản xuất tối ưu hóa các thông số gia công như tốc độ cắt, tốc độ chạy dao, chiều sâu cắt, v.v. để đạt được chất lượng bề mặt mong muốn.

Hiện nay, ngoài các phương pháp truyền thống được sử dụng để dự báo độ nhám bề mặt thì nhiều kỹ thuật tối ưu hóa và trí tuệ nhân tạo đã được sử dụng nhằm nâng cao độ chính xác và khả năng thích nghi của mô hình dự báo. Misak và cộng sự đã tích hợp một mô hình để phân tích về độ nhám bề mặt và đo lường dữ liệu khi gia công trên máy tiện CNC nhằm phát triển một phương pháp mô hình hóa không phụ thuộc quá nhiều vào dữ liệu dựa trên phương pháp Co-Kriging [2]. Zain và cộng sự đã nghiên cứu khả năng của mạng nơ ron (ANN) trong việc dự đoán cho độ nhám bề mặt dựa trên thí nghiệm gia công phay thực tế. Họ kết luận rằng mô hình cho độ nhám bề mặt có thể được cải thiện bằng cách sửa đổi số lớp và nút trong các lớp ẩn của cấu trúc mạng ANN, đặc biệt là để dự đoán giá trị của phép đo hiệu suất độ

**Abstract** - This study examines the influence of three turning parameters: cutting depth ( $t$ ), feed rate ( $f$ ), and cutting speed ( $n$ ) on  $R_a$ , while also developing a predictive model for machining AISI 304 steel using Adaptive Neuro-Fuzzy Inference System (ANFIS). The results of the ANOVA analysis indicate that, all three cutting parameters have a significant impact on  $R_a$ , with the feed rate ( $f$ ) having the most effective influence, emphasizing the role of  $f$  in controlling surface roughness. The ANFIS predictive model was developed using two training methods, Hybrid and Backpropagation, corresponding to eight different membership functions. The results show that the Hybrid training model using the Gaussmf membership function achieved the highest coefficient of determination ( $R^2$ ) of 0.986081 and the lowest root mean square error (RMSE) of 0.013055. These results demonstrate that, the ANFIS model can predict  $R_a$  with relatively high accuracy based on the machining parameters.

**Key words** - Surface roughness; Adaptive Neuro-Fuzzy Inference System (ANFIS); predicting model; turning; AISI 304 steel

nhám bề mặt [3]. Wang và cộng sự đã giới thiệu kết quả nghiên cứu khi xây dựng mô hình dự báo độ nhám bề mặt sử dụng mạng nơ ron dựa trên kiến thức (knowledge-based neural networks- KBaNN) và mạng hàm cơ sở bán kính (Radial Basis Functions networks - RBF). Kết quả thực nghiệm cho thấy, KBaNN-RBF có hiệu quả cao trong việc cải thiện độ chính xác dự đoán và so sánh cho thấy hiệu quả của KBaNN\_RBF vượt trội hơn nhiều so với các phương pháp truyền thống như mạng nơ ron lan truyền ngược (BPNN) và máy vector hỗ trợ (SVM) [4]. Nhiều nghiên cứu khác ứng dụng ANN cũng như kết hợp các thuật toán khác cũng đã được công bố [5-11]. Các nghiên cứu này đã chứng minh được hiệu quả vượt trội trong dự báo độ nhám bề mặt. Tuy nhiên, ANN thường yêu cầu một lượng dữ liệu lớn để đạt được hiệu suất tối ưu và thời gian đào tạo có thể kéo dài. Hơn nữa, ANN vẫn gặp khó khăn trong việc xử lý các tình huống bất định và phi tuyến mạnh, đặc biệt khi dữ liệu không đầy đủ hoặc có tính chất phức tạp.

Một bước tiến quan trọng trong lĩnh vực này là sự kết hợp giữa mạng nơ ron và hệ mờ, cụ thể là mạng nơ ron thích nghi mờ (Adaptive Neuro-Fuzzy Inference System - ANFIS). ANFIS có khả năng xử lý tính phi tuyến phức tạp và tính bất định trong mối quan hệ giữa các thông số gia công và độ nhám bề mặt. Kannadasan và cộng sự đã phát triển

<sup>1</sup> Vietnam National University of Forestry, Vietnam (Tran Cong Chi)

một mô hình dự đoán thông minh dựa trên phương pháp ANFIS, mô hình này có khả năng dự đoán các thông số hiệu suất như độ nhám bề mặt và dung sai hình học trong gia công CNC [12]. Stephen và cộng sự đã ứng dụng ANFIS để mô hình hóa các thông số chất lượng gia công chính là độ nhám bề mặt, tốc độ bóc tách vật liệu và lực cắt khi gia công hợp kim titan bằng cách sử dụng đá mài ống nano carbon tiên tiến [13]. ANFIS cũng đã được kết hợp với nhiều thuật toán khác như ANN, giải thuật bầy đàn (PSO), giải thuật di truyền (GA), ... nhằm nâng cao hiệu quả xây dựng mô hình [14-16]. Tuy nhiên, việc ứng dụng ANFIS trong việc xây dựng mô hình dự báo độ nhám bề mặt tại Việt Nam còn hạn chế, đặc biệt là các nghiên cứu trong việc xác định chính xác các hàm thuộc và phương pháp đào tạo khi xây dựng mô hình.

AISI 304 là một loại thép không gỉ phổ biến, thường được sử dụng trong các ứng dụng yêu cầu độ bền cao và khả năng chống ăn mòn tốt [17, 18]. Tuy nhiên, việc gia công loại thép này lại gặp nhiều thách thức do tính chất cơ học của nó [16, 19]. Do đó, nghiên cứu này tập trung vào việc ứng dụng ANFIS để xây dựng mô hình dự báo độ nhám bề mặt khi tiện thép AISI 304. Các mục tiêu chính bao gồm: (1) thu thập và phân tích dữ liệu thực nghiệm từ quá trình tiện thép AISI 304; (2) phát triển mô hình ANFIS với các thông số đầu vào là chiều sâu cắt ( $t$ ), lượng chạy dao ( $f$ ), và tốc độ cắt ( $n$ ); và (3) đánh giá hiệu suất của các mô hình ANFIS thông qua việc phân tích 8 hàm thuộc và 2 phương pháp đào tạo khác nhau, từ đó lựa chọn được mô hình tối ưu nhất cho việc dự báo chính xác độ nhám bề mặt.

## 2. Phương pháp nghiên cứu

### 2.1. Thiết kế thí nghiệm

Vật liệu sử dụng trong nghiên cứu này là thép AISI 304. Thành phần hóa học và tính chất cơ học theo nhà sản xuất giới thiệu trong Bảng 1.

Nghiên cứu trước đây đã tiến hành tối ưu hóa đa mục tiêu các thông số gia công để giảm thiểu độ nhám bề mặt trong khi tối đa hóa tốc độ bóc tách vật liệu trong quá trình tiện tinh bề mặt ngoài sản phẩm chi tiết khớp nối chuyên dùng làm từ thép AISI 304 bằng phương pháp Taguchi, RSM và NSGA-II [20]. Trong nghiên cứu này bộ thông số chế độ gia công được sử dụng lại với 3 thông số chế độ cắt ( $t$ ,  $f$ ,  $n$ ) dựa trên mảng trực giao  $L_{25}(5^3)$ . Các mức cụ thể được chỉ định cho từng thông số và các giá trị tương ứng của chúng được lựa chọn dựa trên dữ liệu gia công sản phẩm trước đó được giới thiệu trong Bảng 2.

**Bảng 1.** Thành phần hóa học và tính chất cơ học chính của thép AISI 304

TT	Thành phần/ tính chất	Giá trị
1	C (%)	0,0 - 0,07
2	Mn (%)	0,0 - 2,0
3	Si (%)	0,0 - 1,00
4	P (%)	0,0 - 0,05
5	S (%)	0,0 - 0,03
6	Cr (%)	17,50 - 19,50
7	Ni (%)	8,00 - 10,50
8	N (%)	0,0-0,11
9	Độ bền kéo (Mpa)	500 - 700
10	Giới hạn chảy (MPa)	190
11	Độ giãn dài A50 (mm)	Nhỏ nhất 45 %
12	Độ cứng lớn nhất (HB)	215

**Bảng 2.** Chế độ cắt theo mảng trực giao  $L_{25}(5^3)$

STT	$t$ (mm)	$f$ (mm/vòng)	$n$ (vòng/phút)
1	0,2	0,1	600
2	0,2	0,15	650
3	0,2	0,2	700
4	0,2	0,25	750
5	0,2	0,3	800
6	0,4	0,1	650
7	0,4	0,15	700
8	0,4	0,2	750
9	0,4	0,25	800
10	0,4	0,3	600
11	0,6	0,1	700
12	0,6	0,15	750
13	0,6	0,2	800
14	0,6	0,25	600
15	0,6	0,3	650
16	0,8	0,1	750
17	0,8	0,15	800
18	0,8	0,2	600
19	0,8	0,25	650
20	0,8	0,3	700
21	1,2	0,1	800
22	1,2	0,15	600
23	1,2	0,2	650
24	1,2	0,25	700
25	1,2	0,3	750

Máy tiện được sử dụng trong nghiên cứu này là máy tiện CNC EL 550TM (Hình 2) với dụng cụ cắt là dao tiện ngoài mảnh hợp kim cứng CNMG 120408–MG với chiều dài cạnh ngoài là 12,9mm, độ dày là 4,76mm và bán kính mũi là 0,8mm. Tất cả các thí nghiệm đều sử dụng mảnh cắt mới hoặc độ mòn của mặt bên nhỏ hơn 0,10 mm. Ngoài ra, dung dịch trơn nguội PV được sử dụng trong quá trình tiện. Giá trị độ nhám của bề mặt sau khi gia công ( $R_a$ ) được đo bằng máy đo độ nhám tiếp xúc loại đầu dò SV3100 của Mitutoyo, Nhật Bản. Chi tiết được đặt trên khối V và được đo dọc theo đường tâm của phôi [20].



**Hình 1.** Máy tiện CNC EL 550TM và sản phẩm được sử dụng để thực nghiệm [20]

### 2.2. Xây dựng mô hình dự báo bằng ANFIS

Mạng nơ ron thích nghi mờ (ANFIS) là một mô hình học máy mạnh mẽ kết hợp giữa mạng nơ ron và lý thuyết tập mờ. ANFIS được thiết kế nhằm tận dụng những ưu điểm của cả hai phương pháp, cho phép nó xử lý các vấn đề phức tạp và không chắc chắn trong nhiều lĩnh vực, bao gồm dự đoán, phân loại và điều khiển. Cụ thể, các hệ thống suy diễn mờ rất hiệu quả trong việc biểu diễn kiến thức chuyên gia, nhưng lại thiếu khả năng tự động học. Ngược lại, mạng nơ ron có khả năng học hỏi tốt từ dữ liệu mẫu, đặc biệt khi kiến thức chuyên môn hạn chế, nhưng không có khả năng biểu diễn kiến thức.

Trong nghiên cứu này, mô hình ANFIS bao gồm ba đầu vào là chiều sâu cắt ( $t$ ), lượng chạy dao ( $f$ ) và tốc độ cắt ( $n$ ) cùng với một đầu ra là độ nhám bề mặt ( $Ra$ ) được giới thiệu trên Hình 2. Mô hình ANFIS được cấu thành từ năm lớp khác nhau, mỗi lớp thực hiện một nhiệm vụ cụ thể trong quá trình xử lý dữ liệu. Cụ thể, lớp đầu tiên là các nút đầu vào còn được gọi là lớp mờ hóa. Mỗi quan hệ thành viên giữa các hàm đầu vào và đầu ra của lớp này có thể được định nghĩa theo (1):

$$\begin{aligned} O_{1,r} &= \mu_{1i}(t) \\ O_{1,r} &= \mu_{2i}(f) \\ O_{1,r} &= \mu_{3i}(n) \end{aligned} \quad (1)$$

Trong đó,  $\mu_{1i}(t)$ ,  $\mu_{2i}(f)$ ,  $\mu_{3i}(n)$  là các hàm thuộc ( $i=1, 2, 3$ ).

Lớp thứ hai trong mô hình ANFIS là lớp nút quy tắc. Lớp này bao gồm hai nút cố định được gắn nhãn  $\Pi$  và tạo ra đầu ra  $w$ , biểu diễn các trọng số của lớp thứ ba được định nghĩa theo (2):

$$O_{2,r} = w_r = \mu_{1i}(t) \times \mu_{2j}(f) \times \mu_{3k}(n) \quad (2)$$

với  $i, j, k=1, 2, 3$ .

Lớp thứ ba trong mô hình ANFIS là lớp nút trung bình chịu trách nhiệm tính toán giá trị trung bình từ các đầu ra của các quy tắc được gắn nhãn  $N$ . Đầu ra của lớp thứ 3 có thể được tính theo (3):

$$O_{3,r} = \bar{w}_r = \frac{w_r}{\sum_{r=1}^3 w_r} \quad \text{với } r=1, 2, 3. \quad (3)$$

Lớp thứ 4 thực hiện phép toán cộng cho các giá trị đầu ra từ lớp trung bình, giúp tạo ra một giá trị tổng hợp.

$$O_{4,r} = \bar{w}_r \times y_r = \bar{w}_r (p_r t + q_r f + r_r n + s_r) \quad (4)$$

với  $r=1, 2, 3$ .

Lớp đầu ra thứ 5 cung cấp kết quả cuối cùng của mô hình. Cấu trúc này cho phép ANFIS xử lý hiệu quả các mối quan hệ phức tạp giữa các biến đầu vào và đầu ra, từ đó nâng cao độ chính xác trong dự đoán.

$$O_{5,r} = Ra = \sum_{r=1}^3 (\bar{w}_r \times y_r) \quad (5)$$

Các quy tắc suy diễn mờ nếu-thì được trình bày như sau [21]:


Nếu  $t$  là  $\mu_{11}(t)$ ,  $f$  là  $\mu_{21}(f)$ , và  $n$  là  $\mu_{31}(n)$ , thì  $y_1 = p_1 \times t + q_1 \times f + r_1 \times n + s_1$ .

Nếu  $t$  là  $\mu_{21}(t)$ ,  $f$  là  $\mu_{22}(f)$ , và  $n$  là  $\mu_{32}(n)$ , thì  $y_2 = p_2 \times t + q_2 \times f + r_2 \times n + s_2$ .

Nếu  $t$  là  $\mu_{31}(t)$ ,  $f$  là  $\mu_{32}(f)$ , và  $n$  là  $\mu_{33}(n)$ , thì  $y_3 = p_3 \times t + q_3 \times f + r_3 \times n + s_3$ .

Trong đó,  $y_i$  là tập đầu ra nằm trong vùng mờ được xác định bởi quy tắc mờ. Các tham số  $p_i$ ,  $q_i$ ,  $r_i$  và  $s_i$  ( $i$  là các biến từ 1 đến 3) được xác định trong quá trình đào tạo mô hình. Để lựa chọn mô hình dự báo, nghiên cứu này lựa chọn quá trình đào tạo hệ thống suy luận mờ bằng hai phương pháp học lai (hybrid learning) và lan truyền ngược (backpropagation) tương ứng với 8 hàm thuộc là hình tam giác (TrimF), hình thang (trapmf), hình chuông (gbellmf), hàm Gaussian có hai tham số (gaussmf), hàm Gaussian hai

chiều (gauss2mf), dạng pi (pimf), hiệu hàm sigmoid (dsigmf), tích hàm sigmoid (psigmf).



Hình 2. Sơ đồ ANFIS với ba đầu vào ( $t, f, n$ ) và một đầu ra ( $Ra$ )

Để đánh giá mô hình ANFIS, hai chỉ số quan trọng được lựa chọn là hệ số xác định  $R^2$  (Coefficient of Determination) và căn bậc 2 của trung bình bình phương sai số RMSE (Root Mean Square Error) để đo lường mức độ phù hợp của mô hình và ý nghĩa của sự biến đổi tổng thể trong biến phụ thuộc [22, 23]. Nếu chỉ sử dụng  $R^2$  thì không thể hiện hoặc xác định quy mô thực tế của sai số dự đoán. Do đó, chỉ số RMSE được áp dụng để kiểm tra tính chính xác của kết quả khi cho phép đo lường trực tiếp sai số dự đoán trung bình và có cùng đơn vị với biên mục tiêu. Một giá trị RMSE nhỏ cho thấy, các dự đoán của mô hình gần giống với giá trị thực tế hơn. Việc kết hợp  $R^2$  và RMSE mang lại sự cân bằng giữa quy mô tổng thể của mô hình và độ chính xác trong các dự đoán, giúp đánh giá một cách toàn diện chất lượng và hiệu quả của mô hình ANFIS. Công thức tính  $R^2$  và RMSE được trình bày trong (6) và (7).

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{Ra} - Ra)^2}{\sum_{i=1}^n (Ra - \bar{Ra})^2} \quad 0 \leq R^2 \leq 1 \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Ra} - Ra)^2} \quad 0 \leq RMSE \leq +\infty \quad (7)$$

Trong đó,  $n$  là số dữ liệu,  $Ra$  là giá trị thực nghiệm,  $\hat{Ra}$  là giá trị của dự đoán,  $\bar{Ra}$  là giá trị trung bình thực nghiệm.

### 3. Kết quả và thảo luận

#### 3.1. Phân tích ANOVA

Phân tích ANOVA (Phân tích Phương sai) được thực hiện để đánh giá tác động của các yếu tố  $t, f$  và  $n$  đến  $Ra$  trong quá trình tiện thép AISI 304. Kết quả phân tích ANOVA với mức ý nghĩa  $\alpha = 0,05$  được trình bày trong Bảng 3.

Bảng 3. Phân tích ANOVA cho  $Ra$

Nguồn	DF	Adj SS	Adj MS	F	P
$t$	4	0,933	0,233	9,360	0,000
$f$	4	71,565	17,891	717,890	0,000
$n$	4	0,601	0,150	6,030	0,000
Sai số	62	1,545	0,025		
LOF	12	0,485	0,040	1,910	0,056
Sai số thuần	50	1,060	0,021		
Tổng	74	74,644			

Bảng 3 cho thấy, các yếu tố  $t$ ,  $f$  và  $n$  đều có ảnh hưởng đáng kể đến Ra. Cụ thể, yếu tố  $f$  có ảnh hưởng lớn nhất ( $F(4, 62) = 717,89$ ;  $p < 0,05$ ), tiếp theo là yếu tố  $t$  ( $F(4, 62) = 9,36$ ;  $p < 0,05$ ) và yếu tố  $n$  ( $F(4, 62) = 6,03$ ;  $p < 0,05$ ). Phân tích lỗi cho thấy, phương sai không thể giải thích được là 2,07%, với giá trị P cho LOF là 0,056 ( $F(12, 50) = 1,91$ ;  $p = 0,056$ ). Kết quả này cho thấy, mô hình phù hợp với dữ liệu thực nghiệm và nhấn mạnh vai trò của  $f$  trong việc kiểm soát độ nhám bề mặt.

**3.2. Mô hình dự báo**

Trong nghiên cứu này, Fuzzy Logic Toolbox của phần mềm Matlab R2018b (MathWorks, Natick, Massachusetts) đã được sử dụng để phát triển một mô hình dự báo. Mô hình ANFIS được thiết kế với ba đầu vào và đưa chúng vào mạng (3\*3\*3) với các hàm thuộc khác nhau. Ngoài ra, đào tạo mô hình ANFIS được thiết lập với 1000 kỷ nguyên.

Tuy nhiên, với 25 bộ số liệu thí nghiệm có thể không đảm bảo độ tin cậy cho quá trình đào tạo. Để tăng độ tin cậy cho phương pháp đề xuất, mỗi mẫu thí nghiệm sẽ được đo 3 lần trên 3 vị trí cách nhau 120°. Do đó, tổng số bộ số liệu thí nghiệm là 75 và được chia ngẫu nhiên thành bộ dữ liệu đào tạo (75%) và bộ dữ liệu kiểm tra (25%). Đây là một trong những tỉ lệ đã được áp dụng rộng rãi trong các nghiên cứu trước đó, cho thấy tính hiệu quả và có thể được coi là tiêu chuẩn trong lĩnh vực học máy [24]. Bộ dữ liệu đào tạo được sử dụng để đào tạo mô hình ANFIS và bộ dữ liệu kiểm tra được sử dụng để đánh giá độ chính xác và hiệu quả của mô hình ANFIS đã đào tạo trong việc điều chỉnh nội dung đào tạo.

**Bảng 3.** Kết quả ANFIS sau quá trình đào tạo

TT	Thông số	Giá trị
1	Số lượng nút	78
2	Số lượng tham số tuyến tính	27
3	Số lượng tham số phi tuyến tính	18
4	Tổng số tham số	45
5	Số cặp dữ liệu đào tạo	56
6	Số lượng cặp dữ liệu kiểm tra	0
7	Số lượng quy tắc mờ	27

**Bảng 4.** Kết quả khi đào tạo bằng phương pháp Hybrid

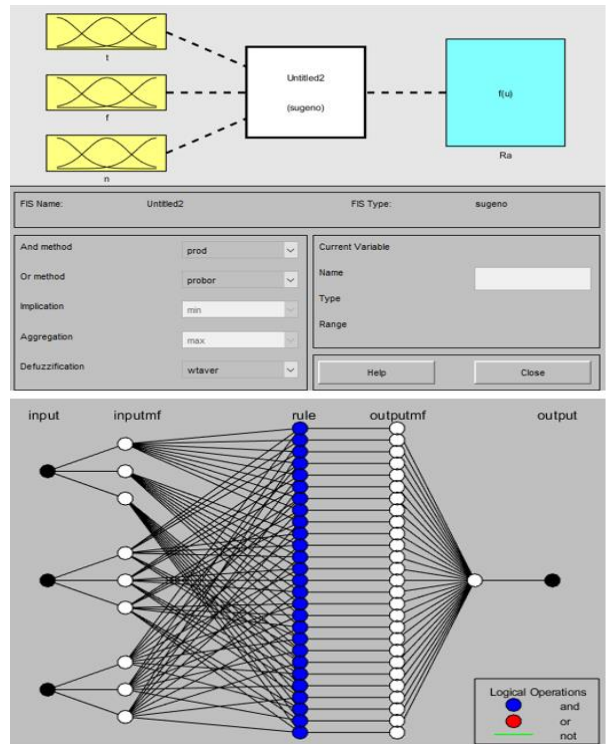
Hàm thuộc	R <sup>2</sup>	RMSE
TrimF	0,986075	0,013058
Trapmf	0,985990	0,013098
Gbellmf	0,986066	0,013062
Gaussmf	0,986081	0,013055
Gauss2mf	0,985275	0,013428
Pimf	0,985353	0,013393
Dsigmf	0,985766	0,013203
Psigmf	0,985766	0,013203

**Bảng 5.** Kết quả khi đào tạo bằng phương pháp Backpropagation

Hàm thuộc	R <sup>2</sup>	RMSE
TrimF	0,849174	0,042977
Trapmf	0,941650	0,026731
Gbellmf	0,771027	0,052953
Gaussmf	0,305152	0,092245
Gauss2mf	0,934836	0,028249
Pimf	0,966112	0,020371
Dsigmf	0,861123	0,041239
Psigmf	0,863393	0,040901

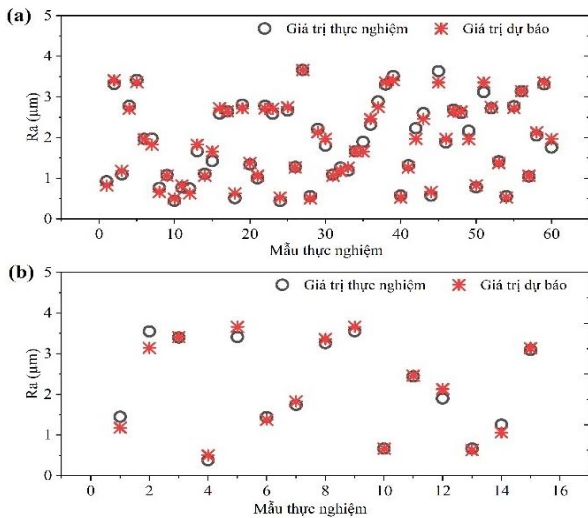
Kết quả phân tích từ Bảng 4 và Bảng 5 cho thấy,

phương pháp đào tạo Hybrid với hàm thuộc Gaussmf là lựa chọn tối ưu nhất trong dự báo độ nhám bề mặt. Cụ thể, R<sup>2</sup> đạt giá trị cao nhất (0,986081) phản ánh khả năng giải thích sự biến thiên dữ liệu thực nghiệm một cách chính xác. Đồng thời, RMSE thấp nhất (0,013055) chứng tỏ chênh lệch giữa giá trị dự đoán và giá trị thực tế được giảm thiểu đáng kể. Phương pháp đào tạo Backpropagation thuần túy với hàm thuộc Pimf cũng cho kết quả tốt (với R<sup>2</sup>=0,966112 và RMSE = 0,020371) nhưng vẫn kém hơn so với Hybrid. Sự vượt trội của phương pháp đào tạo Hybrid có thể là do sự kết hợp giữa phương pháp ước lượng bình phương nhỏ nhất (LSE) để tối ưu các thông số kết quả và Backpropagation để điều chỉnh các tham số đầu vào. Trong khi đó nếu phương pháp đào tạo Backpropagation thuần túy mô hình có thể dễ dàng bị quá khớp (overfitting) do học quá nhiều từ dữ liệu huấn luyện. Hàm thuộc Gaussmf có khả năng mô tả tốt mối quan hệ phi tuyến, được tối ưu hóa hiệu quả hơn trong phương pháp Hybrid giúp tăng cường độ chính xác và độ ổn định của mô hình. Do đó, trong nghiên cứu này phương pháp đào tạo Hybrid với hàm thuộc Gaussmf là lựa chọn tối ưu cho bài toán dự báo độ nhám bề mặt, vừa đảm bảo hiệu suất cao vừa phù hợp với tính chất phức tạp của dữ liệu (Hình 3).



**Hình 3.** Mô hình ANFIS dự đoán Ra với hàm thuộc Gaussmf

Hình 4-a giới thiệu kết quả khi so sánh các giá trị dự báo từ mô hình ANFIS với các giá trị thực tế của Ra trong tập dữ liệu đào tạo. Các giá trị dự báo gần với các giá trị thực tế, điều này cho thấy các mô hình ANFIS được đào tạo có độ tin cậy cao. Hình 4-b cũng cho thấy, kết quả so sánh của tập dữ liệu kiểm tra. Để đánh giá mức độ phù hợp của mô hình ANFIS, kiểm định thống kê t-Test đã được thực hiện trên bộ dữ liệu này. Kết quả cho thấy, không có sự khác biệt đáng kể giữa kết quả thực nghiệm và kết quả dự đoán từ mô hình ( $F = 0,954$ ;  $p = 0,465$ ). Do đó, mô hình ANFIS trong nghiên cứu này được xem là phù hợp về mặt thống kê từ quan điểm mô hình hóa.



**Hình 4.** So sánh kết quả thực nghiệm và dự báo.  
(a): Tập dữ liệu đào tạo, (b) Tập dữ liệu kiểm tra

#### 4. Kết luận

Nghiên cứu đã chứng minh hiệu quả của hệ thống suy luận thần kinh mờ thích ứng (ANFIS) trong việc dự đoán độ nhám bề mặt ( $R_a$ ) khi tiện thép AISI 304. Kết quả phân tích ANOVA cho thấy, cả ba thông số gia công  $t$ ,  $f$  và  $n$  đều ảnh hưởng đáng kể đến  $R_a$ , trong đó  $f$  là yếu tố quan trọng nhất. Mô hình ANFIS được xây dựng thông qua hai phương pháp đào tạo, Hybrid và Backpropagation với tám hàm thuộc khác nhau cho thấy, phương pháp đào tạo Hybrid kết hợp hàm thuộc Gaussmf thu được kết quả tốt nhất. Kết quả này không chỉ khẳng định tính chính xác của mô hình ANFIS trong việc dự đoán  $R_a$  mà còn mở ra khả năng ứng dụng rộng rãi trong các quy trình sản xuất cơ khí.

Mặc dù kết quả này khẳng định tính chính xác của mô hình ANFIS và mở ra khả năng ứng dụng rộng rãi trong sản xuất cơ khí, nghiên cứu vẫn còn một số hạn chế như mô hình hiện tại chỉ xem xét ba thông số cắt với cấu trúc cụ thể. Do đó, các nghiên cứu trong tương lai cần mở rộng bằng cách xem xét tác động của nhiều yếu tố hơn và thử nghiệm các cấu trúc khác nhau cho mô hình ANFIS. Đồng thời có thể tích hợp dữ liệu trong thời gian thực nhằm cải thiện hơn nữa hiệu quả dự báo trong quá trình sản xuất.

**Lời cảm ơn:** Tác giả xin gửi lời cảm ơn tới các chuyên gia đã phân biện và có những nhận xét, góp ý rất có giá trị để bản thảo được chỉnh sửa đảm bảo chất lượng theo yêu cầu.

#### TÀI LIỆU THAM KHẢO

- [1] N. H. Tran, X. T. Tran, and T. L. Nguyen, "Research on samples' surface roughness of turning lathes when spindle driven by a hydraulic motor", *The University of Danang - Journal of Science and Technology*, vol. 11, no. 120, pp. 22-25, 2017.
- [2] T. Misaka *et al.*, "Prediction of surface roughness in CNC turning by model-assisted response surface method", *Precision Engineering*, vol. 62, pp. 196-203, 2020.
- [3] A. M. Zain, H. Haron, and S. Sharif, "Prediction of surface roughness in the end milling machining using Artificial Neural Network", *Expert Systems with Applications*, vol. 37, no. 2, pp. 1755-1768, 2010.
- [4] J. Wang, T. Chen, and D. Kong, "Knowledge-based neural network for surface roughness prediction of ball-end milling", *Mechanical Systems and Signal Processing*, vol. 194, p. 110282, 2023.
- [5] A. Yeganefar, S. A. Niknam, and R. Asadi, "The use of support vector machine, neural network, and regression analysis to predict and optimize surface roughness and cutting forces in milling", *The International Journal*

- of Advanced Manufacturing Technology*, vol. 105, pp. 951-965, 2019.
- [6] T. Wu and K. Lei, "Prediction of surface roughness in milling process using vibration signal analysis and artificial neural network", *The International Journal of Advanced Manufacturing Technology*, vol. 102, pp. 305-314, 2019.
- [7] S. A. Rizvi and W. Ali, "An artificial neural network approach to prediction of surface roughness and material removal rate in CNC turning of C40 steel", *International Journal of Industrial Engineering & Production Research*, vol. 32, no. 3, pp. 1-10, 2021.
- [8] M. R. Phate and S. B. Toney, "Modeling and prediction of WEDM performance parameters for Al/SiCp MMC using dimensional analysis and artificial neural network", *Engineering Science and Technology, an International Journal*, vol. 22, no. 2, pp. 468-476, 2019.
- [9] M. Ficko, D. Begic-Hajdarevic, M. Cohodar Husic, L. Berus, A. Cekic, and S. Klancnik, "Prediction of surface roughness of an abrasive water jet cut using an artificial neural network", *Materials*, vol. 14, no. 11, p. 3108, 2021.
- [10] C. C. Tran, V. T. Nguyen, and C. L. Tran, "Prediction Model and Optimization of Machining Parameters Using Integrated ANN-GA Method on CNC Milling Machine", (in Vietnam), *TNU Journal of Science and Technology*, vol. 226, no. 11, pp. 20-29, 2021.
- [11] C. C. Tran, "Modelling and Optimization of Surface Roughness and Material Removal Rate in Milling SKD11 Using GMDH and NSGA-II", *International Journal of Mechanical Engineering and Robotics Research*, vol. 13, no. 6, pp. 618-627, 2024.
- [12] K. Kannadasan, D. R. Edla, M. H. Yadav, and A. Bablani, "Intelligent-ANFIS model for predicting measurement of surface roughness and geometric tolerances in three-axis CNC milling", *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 10, pp. 7683-7694, 2020.
- [13] D. S. Stephen and P. Sethuramalingam, "ANFIS prediction modeling of surface roughness and cutting force of titanium alloy ground with carbon nanotube grinding wheel", *Multiscale and Multidisciplinary Modeling, Experiments and Design*, vol. 7, pp. 3285-3300, 2024.
- [14] M. S. Alajmi and A. M. Almeshal, "Prediction and optimization of surface roughness in a turning process using the ANFIS-QPSO method", *Materials*, vol. 13, no. 13, p. 2986, 2020.
- [15] U. Natarajan, S. Palani, and B. Anandampilai, "Prediction of surface roughness in milling by machine vision using ANFIS", *Computer-Aided Design and Applications*, vol. 9, no. 3, pp. 269-288, 2012.
- [16] R. Kumar and N. R. J. Hynes, "Prediction and optimization of surface roughness in thermal drilling using integrated ANFIS and GA approach", *Engineering Science and Technology, an International Journal*, vol. 23, no. 1, pp. 30-41, 2020.
- [17] T. Chaudhary, A. N. Siddiquee, and A. K. Chanda, "Effect of wire tension on different output responses during wire electric discharge machining on AISI 304 stainless steel", *Defence Technology*, vol. 15, no. 4, pp. 541-544, 2019.
- [18] M. Sarikaya and V. Yilmaz, "Optimization and predictive modeling using S/N, RSM, RA and ANNs for micro-electrical discharge drilling of AISI 304 stainless steel", *Neural Computing and Applications*, vol. 30, pp. 1503-1517, 2018.
- [19] T. Akasawa, H. Sakurai, M. Nakamura, T. Tanaka, and K. Takano, "Effects of free-cutting additives on the machinability of austenitic stainless steels", *Journal of Materials Processing Technology*, vol. 143, pp. 66-71, 2003.
- [20] C. C. Tran, T. T. Nguyen, and V. T. Nguyen, "Multi-Objective Optimization in Turning AISI 304 Stainless Steel: An Integration of The Taguchi Method, Response Surface Methodology, and NSGA-II", *International Journal of Industrial and Systems Engineering*, vol. 1, no. 1, 2025.
- [21] T. Takagi and M. Sugeno, "Derivation of fuzzy control rules from human operator's control actions", *IFAC proceedings volumes*, vol. 16, no. 13, pp. 55-60, 1983.
- [22] C. C. Tran and V. T. Nguyen, "Surface roughness prediction for CNC-turned C45 steel utilising adaptive neuro-fuzzy inference systems", *Journal of Mechanical Engineering and Sciences*, vol. 18, no. 4, pp. 10222-10232, 2024.
- [23] N. Senthilkumar, J. Sudha, and V. Muthukumar, "A grey-fuzzy approach for optimizing machining parameters and the approach angle in turning AISI 1045 steel", *Advances in Production Engineering & Management*, vol. 10, no. 4, pp. 195-208, 2015.
- [24] G. Zhang, B. E. Patuwo, and M. Y. Hu, "Forecasting with artificial neural networks: The state of the art", *International journal of forecasting*, vol. 14, no. 1, pp. 35-62, 1998.