

# MỞ ĐẦU

## 1. Tính cấp thiết của đề tài

Mạng nơ-ron nhân tạo (ANN - *Artificial Neural Network*) là tập hợp các đơn vị xử lý thông tin mô phỏng dựa trên hoạt động của hệ thống nơ-ron sinh học. Mỗi ANN có hai quá trình chính gồm quá trình học và quá trình xử lý. Trong quá trình học, ANN thực hiện học và lưu trữ thông tin các dữ liệu mẫu. Trong quá trình xử lý, ANN dùng thông tin học được từ quá trình học để đưa ra tín hiệu ra từ các tín hiệu vào mới. Do đó, chất lượng của quá trình học ảnh hưởng lớn đến chất lượng của quá trình xử lý.

Ba mô hình lý thuyết điển hình trong số các ANN ghi nhớ gồm (i) Bộ nhớ liên kết hai chiều (BAM – *Bidirectional Associative Memory*), (ii) Bộ nhớ liên kết mờ (FAM – *Fuzzy Associative Memory*), và (iii) Lý thuyết cộng hưởng thích nghi mờ (Fuzzy ART – *Fuzzy Adaptive Resonance Theory*) được cải tiến quá trình học để nâng cao chất lượng xử lý. Lý do đề xuất các cải tiến cho các mô hình gồm việc gán trọng số cho các mẫu trong tập huấn luyện còn chưa hiệu quả và luật học chưa học hiệu quả các mẫu huấn luyện.

## 2. Các đóng góp của luận án

1. Đề xuất cách xác định giá trị thích hợp cho trọng số của các cặp mẫu huấn luyện của BAM
2. Cải tiến luật học và tìm giá trị thích hợp cho tham số học của Fuzzy ART.
3. Cải tiến luật học để FAM học và lưu trữ hiệu quả đồng thời cả nội dung và sự liên kết giữa các cặp mẫu.

Các kết quả của luận án gồm: 2 bài báo công bố ở Tạp chí quốc tế có chỉ số ISI, 7 báo cáo được công bố trong kỷ yếu của các hội nghị quốc tế có phản biện (trong đó, 6 báo cáo được xuất bản bởi IEEE và Springer), và 2 bài báo ở tạp chí trong nước .

## 3. Bố cục của luận án

Ngoài các phần mở đầu, mục lục, kết luận, tài liệu tham khảo cũng được viết ở phần đầu và cuối của luận án. Nội dung của từng chương được trình bày như sau:

**Chương 1** trình bày các kiến thức quan trọng về ANN gồm nơ-ron sinh học, mô hình nơ-ron nhân tạo, mạng nơ-ron, các luật học, ưu-nhược điểm, và ứng dụng. Các kiến thức này giúp hiểu chủ đề nghiên cứu của luận án.

**Chương 2** cung cấp các kiến thức cơ bản về các khái niệm, thao tác của logic mờ và toán học hình thái. Tiếp theo, mô hình và hoạt động của BAM, FAM, và Fuzzy ART được trình bày chi tiết hơn giúp phân biệt điểm mới trong các đề xuất cải tiến đối với từng mô hình.

**Chương 3** đề xuất một thuật toán xác định trọng số thích hợp cho mỗi cặp mẫu huấn luyện của BAM học nhiều lần. BAM cải tiến được thử nghiệm với ứng dụng nhận dạng mẫu. Kết quả thực nghiệm cho thấy có khả năng nhớ lại được cải thiện hơn các BAM khác. Thuật toán học cải tiến giúp BAM học nhanh và linh động hơn nhưng vẫn đảm bảo về khả năng phục hồi mẫu.

**Chương 4** thể hiện hai luật học và một thủ tục tìm giá trị thích hợp cho tham số tốc độ học của Fuzzy ART. Các thực nghiệm phân cụm trên 14 bộ dữ liệu chuẩn cho thấy Fuzzy ART với các luật học đề xuất nhớ lại các cụm tốt hơn. Trong chương, cả luật học và tham số mô hình đều được cải tiến để nâng cao chất lượng phân cụm Fuzzy ART.

**Chương 5** trình bày luật học cho FAM. Các thử nghiệm với nhiệm vụ nhận dạng mẫu cho thấy FAM với luật học cải tiến nhớ lại tốt hơn các FAM khác. Luật học đề xuất đã giúp nâng cao khả năng phục hồi mẫu từ các mẫu vào có dạng nhiễu phức tạp.

# CHƯƠNG 1. MẠNG NƠ-RON NHÂN TẠO

## 1.1 Mạng nơ-ron nhân tạo

Mạng nơ-ron nhân tạo là một cấu trúc được hình thành do các nơ-ron nhân tạo liên kết với nhau. Mỗi nơ-ron có các tín hiệu vào, tín hiệu ra và thực hiện một chức năng tính toán cục bộ.

Các đặc điểm nổi bật của ANN gồm:

- Là mô hình toán học dựa trên bản chất hoạt động của nơ-ron sinh học
- Cấu tạo từ một số các nơ-ron có liên kết với nhau
- Có khả năng học và tổng quát hóa tập dữ liệu thông qua việc gán và hiệu chỉnh trọng số liên kết giữa các nơ-ron
- Xử lý song song các thông tin phân tán nên có khả năng tính toán lớn

Các ANN có thể chia theo nhiều cách dựa vào cấu trúc (một tầng và nhiều tầng), cách truyền tín hiệu (truyền thẳng và lan truyền ngược), và bản chất của việc học (học giám sát, học không giám sát, học lai giữa 2 cách)

## 1.2 Các luật học của ANN

Các luật học đóng vai trò quan trọng trong việc xác định một ANN. Quá trình học của ANN là cập nhật trọng số dựa vào các mẫu huấn luyện. Theo nghĩa rộng thì học có thể chia làm hai loại: Học tham số và học cấu trúc.

**Học tham số:** Các thủ tục học này tìm kiếm ma trận trọng số sao cho mạng có khả năng đưa ra các dự báo sát với thực tế. Dạng chung của luật học tham số cho nơ-ron  $i$  được mô tả như sau:

$$\Delta W_{ij} = \eta r x_j, \text{ với } j = 1..n \quad (1.7)$$

**Luật học Hebb:** dựa trên hiện tượng sinh học: Giữa hai nơ-ron có quan hệ và có thay đổi thế năng màng thì giữa chúng có sự thay đổi trọng số liên kết. Nói cách khác, trọng số được điều chỉnh theo mối tương quan giữa tín hiệu vào và tín hiệu ra.

$$\Delta W_{ij} = \eta y_i x_j, \text{ với } j = 1..n \quad (1.8)$$

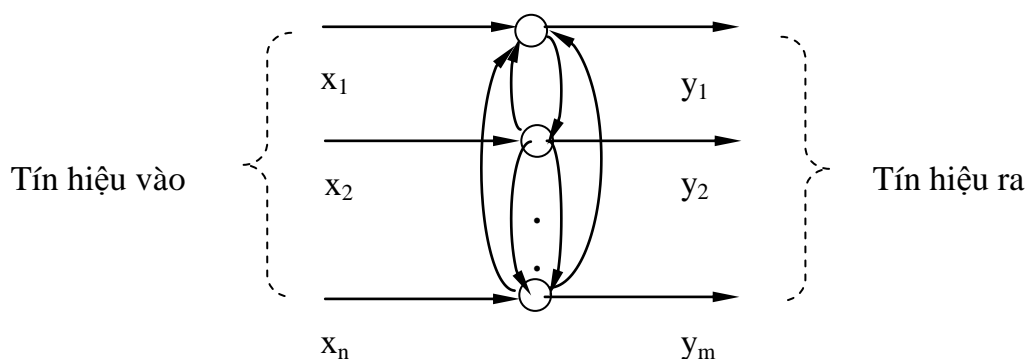
Luật Hebb giải thích việc điều chỉnh trọng số trong phạm vi cục bộ của mạng khi không cần tín hiệu chỉ đạo từ bên ngoài. Hopfield cũng cải tiến luật Hebb cho các mạng tự liên kết thành 16 dạng khác nhau theo kiểu luật Hebb, luật đối Hebb, luật Hopfield.

## CHƯƠNG 2. CƠ SỞ LÝ THUYẾT

### 2.1 Mô hình BAM

#### 2.1.1 Mạng Hopfield

Mạng Hopfield là mô hình tiêu biểu của lớp mạng lan truyền ngược. Mạng Hopfield là mạng một lớp có rất nhiều ứng dụng, đặc biệt trong bộ nhớ liên kết và trong các bài toán tối ưu. Hình 2.3 mô tả mô hình mạng Hopfield.



Hình 2.1: Mô hình mạng Hopfield

Tín hiệu ra của nơ-ron thứ  $j$  nào đó được truyền ngược lại làm tín hiệu vào cho các nơ-ron thông qua các trọng số tương ứng.

Ký hiệu  $w_{ij}$  là trọng số liên kết giữa hai nơ-ron  $i$  và  $j$  ( $w_{ij} = w_{ji}$ ),  $y_i$  là đầu ra của nơ-ron  $i$ . Khi đó, véc tơ  $(y_1, y_2, \dots, y_n)$  là trạng thái của mạng. Tại mỗi thời điểm  $t$  mỗi nơ-ron  $i$  tổng hợp các tín hiệu  $x_j$  từ các nơ-ron khác và tín hiệu từ bên ngoài  $I_i$

$$input_i = \sum_{j=1}^n w_{ij}x_j + I_i \quad (2.17)$$

Tùy theo hàm kích hoạt  $f_i$ , nơ-ron  $i$  cho tín hiệu ra.

$$y_i(t+1) = f_i(y_i(t)) \quad (2.18)$$

Mạng đạt trạng thái cân bằng nếu  $y_i(t+1) = y_i(t), \forall i$


Hàm năng lượng của mạng được tính bằng:

$$E = E(y_1, \dots, y_n) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i y_j - \sum_{i=1}^n I_i y_i \quad (2.19)$$

Tùy theo phương thức hoạt động, có thể chia thành mạng Hopfield rời rạc và mạng Hopfield liên tục.

### 2.1.2 Khái niệm về BAM

BAM là một AM thể hiện cấu trúc bộ nhớ liên kết với khả năng nhớ lại theo cả hai hướng. BAM được cấu tạo từ hai mạng Hopfield để thực hiện liên kết giữa hai mẫu. Hình 2.4 mô tả cấu trúc tổng quát của mô hình BAM.



Hình 2.2: Cấu trúc tổng quát của mô hình BAM

### 2.1.3 Quá trình học của BAM

Quá trình học được thực hiện như sau:

Đầu tiên, ma trận trọng số  $\mathbf{W}^k$  lưu liên kết của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính theo công thức sau:

$$\mathbf{W}^k = \mathbf{A}^k \mathbf{B}^{kT} \quad (2.24)$$

với  $\mathbf{A}^k$  là ma trận cấp  $1 \times n$ ,  $\mathbf{B}^k$  là ma trận cấp  $1 \times m$ , và  $\mathbf{W}^k$  là ma trận cấp  $n \times m$ .

Sau đó, tổng quát hóa sự liên kết của  $p$  cặp mẫu và lưu trong ma trận trọng số chung,  $\mathbf{W}$  – Ma trận trọng số gốc.

$$\mathbf{W} = \sum_{k=1}^p \mathbf{W}^k \quad (2.25)$$

#### 2.1.4 Quá trình nhớ lại của BAM

Đầu tiên, tổng hợp tín hiệu vào của mỗi nơ-ron theo công thức sau:

$$Input_j = \sum_{i=1}^n X_i W_{ij} \quad (2.26)$$

Sau đó, xác định tín hiệu ra cho nơ-ron bằng cách dùng hàm đầu ra:

$$Y_j = \begin{cases} 1, & \text{if } Input_j \geq 0 \\ -1, & \text{if } Input_j < 0 \end{cases} \quad (2.27)$$

#### 2.1.5 Hàm năng lượng của BAM

Hàm năng lượng  $E^k$  với cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$ .

$$E^k(\mathbf{A}^k, \mathbf{B}^k) = -\mathbf{A}^k \mathbf{W} \mathbf{B}^{kT} \quad (2.28)$$

## 2.2 Mô hình FAM

### 2.2.1 Khái niệm FAM

Cho một tập các liên kết  $(\mathbf{A}^k, \mathbf{B}^k)$ ,  $k=1, \dots, p$  xác định một ánh xạ  $\mathbf{G}$  sao cho  $\mathbf{G}(\mathbf{A}^k) = \mathbf{B}^k$  với mọi  $k=1, \dots, p$ . Hơn nữa, ánh xạ  $\mathbf{G}$  cần có khả năng chịu nhiễu. Nghĩa là,  $\mathbf{G}(\mathbf{A}'^k)$  nên bằng  $\mathbf{B}^k$  đối với các bản nhiễu hay không đầy đủ  $\mathbf{A}'^k$  của  $\mathbf{A}^k$ . Quá trình xác định  $\mathbf{G}$  được gọi là quá trình học và ánh xạ  $\mathbf{G}$  thực hiện nhớ lại các liên kết. Bộ nhớ liên kết mờ là bộ nhớ liên kết với các mẫu  $\mathbf{A}^k$  và  $\mathbf{B}^k$  là các tập mờ với mọi  $k=1, \dots, p$ .

### 2.2.2 Các FAM của Kosko và sự tổng quát hóa

Giả sử, FAM lưu  $p$  cặp mẫu. Cho  $\mathbf{X} = [\mathbf{X}^1, \dots, \mathbf{X}^p] \in [0,1]^{n \times p}$  và  $\mathbf{Y} = [\mathbf{Y}^1, \dots, \mathbf{Y}^p] \in [0,1]^{m \times p}$

## FAM tổng quát

Mô hình tổng dùng nơ-ron max-C nên có thể dùng một phép nối mờ như  $C_M, C_P, C_L$ . Quá trình học thực hiện theo công thức sau:

$$W_{ij} = \bigvee_{k=1}^p C(W_{ik}, x_{kj}), i = 1..m, j = 1..n \quad (2.37)$$

Với  $\mathbf{x}$  là mẫu vào, mẫu ra  $\mathbf{y}$  được tính như sau:

$$\mathbf{y} = \left[ \bigvee_{j=1}^n C(\mathbf{W}_j, \mathbf{x}_j) \right] \quad (2.38)$$

## 2.3 Mô hình Fuzzy ART

### 2.3.1 Thuật toán Fuzzy ART

Ba tham số sau thể hiện tính động của mô hình Fuzzy ART:

- Tham số chọn  $\alpha > 0$ ;
- Tham số tốc độ học  $\beta \in [0, 1]$
- Tham số ngưỡng  $\rho \in [0, 1]$ ;

Nội dung của thuật toán được trình bày như sau:

#### **Bước 1: Khởi tạo véc tơ trọng số của các cụm tiềm năng.**

Mỗi cụm  $j$  có một véc tơ trọng số  $\mathbf{W}_j = (W_{j1}, \dots, W_{jM})$ . Số các cụm tiềm năng  $N$  là bất kỳ. Khởi tạo

$$W_{j1} = \dots = W_{jM} = 1 \quad (2.43)$$

và mỗi cụm được coi là chưa hình thành. Sau khi một cụm được chọn để mã hóa, cụm được hình thành.  $W_{ji}$  là không tăng dần theo thời gian nên các  $W_{ji}$  hội tụ tới một giới hạn.

#### **Bước 2: Lựa chọn một cụm chiến thắng.**

Với mỗi mẫu vào  $\mathbf{I}$  và cụm  $j$ , hàm chọn  $T_j$  được định nghĩa bởi

$$T_j(\mathbf{I}) = \frac{\|\mathbf{I} \wedge \mathbf{W}_j\|}{\alpha + \|\mathbf{W}_j\|} \quad (2.44)$$

với phép toán giao,  $\wedge$ , trong logic mờ được định nghĩa:

$$(x \wedge y)_i = \min\{x_i, y_i\} \quad (2.45)$$

và với chuẩn  $\|\cdot\|$  được định nghĩa như trong Công thức 2.40.

Để đơn giản,  $T_j(\mathbf{I})$  được viết là  $T_j$  khi mẫu vào  $\mathbf{I}$  cố định. Sự chọn cụm được gắn chỉ số bằng  $J$ , với

$$T_j = \max\{T_j, j = 1..N\} \quad (2.46)$$

Nếu có nhiều hơn một  $T_j$  là cực đại thì cụm  $j$  với chỉ số nhỏ nhất được chọn.

### **Bước 3: Kiểm tra trạng thái của mạng là cộng hưởng hay thiết lập lại.**

*Cộng hưởng* xuất hiện nếu hàm đối chiều của cụm được chọn đạt điều kiện về ngưỡng:

$$\frac{\|\mathbf{I} \wedge \mathbf{W}_j\|}{\|\mathbf{I}\|} \geq \rho \quad (2.47)$$

Sau đó, việc học sẽ diễn ra.

*Thiết lập lại* xuất hiện nếu

$$\frac{\|\mathbf{I} \wedge \mathbf{W}_j\|}{\|\mathbf{I}\|} \geq \rho \quad (2.48)$$

Sau đó, giá trị của hàm chọn  $T_j$  được thiết lập -1 để ngăn sự chọn lại cụm  $J$  trong quá trình tìm kiếm. Một chỉ số mới  $J$  được chọn bởi Công thức (2.46). Quá trình tìm kiếm tiếp tục cho đến khi  $J$  được chọn thỏa mãn Công thức (2.47). Nếu không có cụm đang tồn tại nào thỏa mãn điều kiện trong Công thức (2.47) thì một cụm mới  $J$  được sinh ra và đặt  $\mathbf{W}_J^{\text{new}} = \mathbf{I}$ .

### **Bước 4: Học dữ liệu huấn luyện.**

Véc tơ trọng số của cụm thứ  $J$ ,  $\mathbf{W}_J$  được cập nhật theo công thức sau:

$$\mathbf{W}_J^{\text{new}} = \beta (\mathbf{I} \wedge \mathbf{W}_J^{\text{old}}) + (1 - \beta) \mathbf{W}_J^{\text{old}} \quad (2.49)$$



### 2.3.2 Thước đo chất lượng phân cụm

Hai thước đo cơ bản được dùng phổ biến cho phân cụm gồm

#### **Davies–Bouldin index**

Giá trị của chỉ số này được tính như sau:

$$DB = \frac{1}{n} \sum_{i=1}^n \max_{i \neq j} \left( \frac{\sigma_i + \sigma_j}{d(c_i, c_j)} \right) \quad (2.55)$$

Thuật toán có chỉ số Davies-Bouldin càng bé càng tốt.

#### **Dunn index**

Công thức tính chỉ số này được trình bày như sau:

$$D = \min_{1 \leq i \leq n} \left\{ \min_{1 \leq j \leq n, i \neq j} \left\{ \frac{d(i, j)}{\max_{1 \leq k \leq n} d'(k)} \right\} \right\} \quad (2.56)$$

Thuật toán có chỉ số Dunn càng lớn càng tốt.

## **CHƯƠNG 3. THUẬT TOÁN HỌC CẢI TIẾN CHO BỘ NHỚ LIÊN KẾT HAI CHIỀU**

### **3.1 Các nghiên cứu về học nhiều lần của BAM**

#### **Mô hình của Y.F Wang, Cruz, và Mulligan**

Mô hình này học lần lượt các mẫu trong một lần lặp nhưng thể hiện chiến lược học nhiều lần do sử dụng MNTTP. Luật học được thể hiện bởi công thức sau:

$$W_{ij} = \sum_{k=1}^p q^k A_i^k (B_j^k)^T \quad (3.1)$$

$$q^k \geq \max \left( 1, \frac{\epsilon_{0k}^A}{2m} + 1, \frac{\epsilon_{0k}^B}{2n} + 1 \right) \quad (3.2)$$

#### **Mô hình của T. Wang và Zhuang**

Mô hình BAM này học lần lượt các mẫu trong nhiều lần lặp của quá trình học. Luật học của mô hình được thể hiện bởi công thức sau:

$$W_{ij}(t + 1) = W_{ij}(t) + \Delta W_{ij} \quad (3.3)$$

với số gia trọng số  $\Delta W_{ij}$  được tính bởi công thức sau:

$$\Delta W_{ij} = \sum_{k=1}^p A_i^k B_j^k [S(\alpha_i^k) + S(\beta_j^k)] \quad (3.4)$$

với  $S(x)=0$  nếu  $x>0$  và  $S(x)=1$  nếu  $x\leq 0$ .

Hai công thức sau được dùng để tính  $\alpha_i^k$  và  $\beta_j^k$

$$\alpha_i^k = \left( \sum_{j=1}^n W_{ij} B_j^k \right) A_i^k$$

$$\beta_j^k = \left( \sum_{i=1}^m W_{ij} A_i^k \right) B_j^k$$

Quá trình này lặp lại cho đến khi các giá trị của ma trận trọng số  $\mathbf{W}$  ổn định

### Mô hình của Zhuang, Huang, và Chen

Mô hình BAM này học lần lượt các mẫu trong nhiều lần lặp của quá trình học. Ban đầu,  $W_{ij}^{(0)}$  là bất kỳ. Khi  $t>0$  thì luật học của nơ-ron  $i$  ở vùng A được thể hiện bởi công thức sau:

$$W_{ij}(t + 1) = \begin{cases} W_{ij}(t), & \text{if } \mathbf{A}_i \sum_{l=1}^n W_{il}(t) \mathbf{B}_l > 0 \\ W_{ij}(t) + \mathbf{B}_j \mathbf{A}_i, & \text{otherwise} \end{cases} \quad (3.7)$$

với  $j = 1, \dots, n$ .

Luật học của của nơ-ron  $j$  ở vùng B được thể hiện bởi công thức sau:

$$W_{ij}(t+1) = \begin{cases} W_{ij}(t), & \text{if } \mathbf{B}_j \sum_{l=1}^m W_{lj}(t) \mathbf{A}_l > 0 \\ W_{ij}(t) + \mathbf{B}_j \mathbf{A}_i, & \text{otherwise} \end{cases} \quad (3.8)$$

với  $i = 1, \dots, m$ .

Quá trình này lặp lại cho đến khi các giá trị của ma trận trọng số  $\mathbf{W}$  ổn định

### 3.2 Thuật toán học mới cho BAM

#### 3.2.1 Phân tích mối quan hệ giữa MNTP và hàm năng lượng

Giả sử, BAM học  $p$  cặp mẫu. Cặp mẫu  $(\mathbf{A}^i, \mathbf{B}^i)$  được trình bày như sau:  $\mathbf{A}^i = (A_1^i, \dots, A_n^i)$  và  $\mathbf{B}^i = (B_1^i, \dots, B_m^i)$ . Mối quan hệ giữa MNTP và hàm năng lượng được thiết lập từ công thức (2.28) và (2.29) có dạng như sau:

$$E^i = - \sum_{s=1}^m B_s^i \sum_{t=1}^n A_t^i \sum_{k=1}^p q^k A_t^k (B_s^k)^T \quad (3.13)$$

Công thức (3.13) thể hiện giá trị tuyệt đối của  $E^i$  tỷ lệ thuận với mọi  $q^k$  của  $p$  cặp mẫu (với  $k=1, \dots, p$ ). Từ đó, suy ra được giá trị tuyệt đối của  $E^i$  sẽ giảm mạnh khi các  $q^k$  cùng giảm.

#### 3.2.2 Nội dung thuật toán học mới

##### Một số ký hiệu trong thuật toán

- $q^i$  là MNTP của cặp mẫu thứ  $i$ .
- $\mathbf{W}$  là ma trận trọng số chung
- $E^i$  là năng lượng ứng với trạng thái  $(\mathbf{A}^i, \mathbf{B}^i)$ .
- $\varepsilon$  là ngưỡng để dừng việc điều chỉnh  $q^i$ .

##### Thuật toán 3.1: Thuật toán học nhanh và linh động cho BAM

**Input:**  $p$  cặp mẫu  $(\mathbf{A}^i, \mathbf{B}^i)$  được thể hiện thành hai véc tơ chứa các giá trị ở dạng hai cực gồm +1 và -1.

**Output:** Ma trận trọng số  $\mathbf{W}$  lưu sự liên kết của các cặp mẫu

### Nội dung thuật toán :

- **Bước 1:** Khởi tạo giá trị MNTP bằng cách đặt mọi  $q^i=1$  với  $i=1, \dots, p$  để thu được ma trận trọng số gốc. Chọn giá trị cho  $\varepsilon$  nguyên dương, đủ nhỏ.
- **Bước 2:** Thực hiện lặp các bước sau cho đến khi  $|E^i| \leq \varepsilon$  với mọi  $i=1, \dots, p$  và  $|x|$  là giá trị tuyệt đối của  $x$ .

*Bước 2.1:* Tính **W** theo công thức (3.11)

*Bước 2.2:* Tính  $E^i$  theo công thức (3.13) với  $i=1, \dots, p$ .

*Bước 2.3:* Dựa vào giá trị của  $E^i$  để cập nhật  $q^i$  theo hai luật sau:

*Luật 1:* Nếu  $|E^i| \leq \varepsilon$  thì không thay đổi  $q^i$

*Luật 2:* Nếu  $|E^i| > \varepsilon$  thì giảm  $q^i$  xuống  $h$  lần với  $h$  là phần nguyên của phép chia  $|E^i|$  cho  $\varepsilon$ .

- **Bước 3:** Trả về ma trận trọng số **W**

### 3.3 Kết quả thực nghiệm

Do mô hình BAM gắn với thuật toán học mới thực hiện học nhiều lần các mẫu nên tác giả chỉ so sánh với các BAM học nhiều lần. Các BAM được dùng trong các thực nghiệm gồm BAM của Y.F.Wang (WBAM), BAM của Zhuang (ZBAM), BAM của Tao Wang (TBAM) và FFBAM.

#### 3.3.1 Thử nghiệm với nhận dạng vân tay

10 ảnh huấn luyện được chọn từ tập mẫu của cuộc thi Olympic về công nghệ thông tin tổ chức tại ĐH Công nghệ năm 2010.

Bảng 3.1: Thời gian học và kết quả nhớ lại các vân tay

Mô hình được so sánh	WBAM	ZBAM	TBAM	FFBAM
Tỷ lệ nhớ lại đúng (%)	83.370	85.906	85.906	<b>88.007</b>
Thời gian học (s)	0.054	6.927	161.164	0.648

Bảng 3.1 cho thấy FFBAM là mô hình tốt nhất. Khả năng nhớ của FFBAM cao hơn WBAM khoảng 4.6% nhưng học chậm hơn khoảng 0.6s. Đối với hai mô hình còn lại, việc học thực hiện nhanh hơn khoảng 6s và nhớ lại tốt hơn khoảng 2%.

### 3.3.2 Thử nghiệm với nhận dạng chữ viết tay

52 ảnh huấn luyện được chọn từ tập mẫu UJIPenchars từ cơ sở dữ liệu UCI gồm 26 chữ thường và 26 chữ hoa. Tương tự, Bảng 3.2 cho thấy khả năng nhớ của FFBAM là cao nhất và chỉ học chậm hơn WBAM 0.02s.

Bảng 3.2: Thời gian học và kết quả nhớ lại các chữ viết tay

Mô hình được so sánh	WBAM	ZBAM	TBAM	FFBAM
Tỷ lệ nhớ lại đúng (%)	75.463	72.964	75.681	<b>75.89</b>
Thời gian học (s)	0.195	153.546	198.955	0.212

### 3.3.3 Thử nghiệm với các ứng dụng nhận dạng khác

20 ảnh về biển hiệu giao thông, 20 ảnh về tiền xu của Mỹ và 10 ảnh về phương tiện giao thông được chọn từ kết quả tìm kiếm ảnh trên Google.

Bảng 3.3: Thời gian học và kết quả nhớ lại các biển hiệu giao thông

Mô hình được so sánh	WBAM	ZBAM	TBAM	FFBAM
Tỷ lệ nhớ lại đúng (%)	77.98	28.303	78.303	<b>78.348</b>
Thời gian học (s)	0.057	59.751	17.020	0.409

Bảng 3.4: Thời gian học và kết quả nhớ lại các tiền xu của Mỹ

Mô hình được so sánh	WBAM	ZBAM	TBAM	FFBAM
Tỷ lệ nhớ lại đúng (%)	85.066	45.992	84.896	<b>85.109</b>
Thời gian học (s)	0.332	55.291	100.520	0.815

Bảng 3.5: Thời gian học và kết quả nhớ lại các phương tiện giao thông

Mô hình được so sánh	WBAM	ZBAM	TBAM	FFBAM
Tỷ lệ nhớ lại đúng (%)	88.11	18.96	90.076	<b>90.076</b>
Thời gian học (s)	0.134	55.755	6.008	3.414

Tương tự, Bảng 3.3, 3.4, và 3.5 cho thấy khả năng nhớ của FFBAM là cao nhất và học chậm hơn WBAM trong cả ba thử nghiệm.

## CHƯƠNG 4. HAI LUẬT HỌC CẢI TIẾN CHO LÝ THUYẾT CỘNG HƯỞNG THÍCH NGHI MỜ

### 4.1 Các luật học điển hình của ART và Fuzzy ART

Các mô hình sử dụng một số biến sau:  $\mathbf{I}$  là mẫu vào hiện tại,  $\mathbf{W}_j$  là trọng số của cụm  $j$ , và  $\beta$  là tham số học nằm trong khoảng  $[0, 1]$ .

Capenter và đồng nghiệp [Error! Reference source not found.] đưa ra mô hình Fuzzy ART gốc với luật học cập nhật trọng số cho cụm được chọn  $j$  như sau:

$$\mathbf{W}_j^{\text{new}} = \beta(\mathbf{I} \wedge \mathbf{W}_j^{\text{old}}) + (1 - \beta)\mathbf{W}_j^{\text{old}} \quad (4.1)$$

với  $\wedge$  là phép giao của hai tập mờ.

Kenaya và Cheok [Error! Reference source not found.] đưa ra Euclidean ART để học với các dữ liệu nhiễu với luật học như sau:

$$\mathbf{W}_j^{\text{new}} = \frac{\sum_{k=1}^L X_{jk}}{L} \quad (4.2)$$

với  $X_{jk}$  là mẫu thứ  $k$  trong cụm  $j$  và  $L$  là số các cụm.

Yousuf and Murphey [Error! Reference source not found.] cập nhật nhiều cụm thỏa mãn điều kiện về ngưỡng theo luật học sau:

$$\mathbf{W}_j^{\text{new}} = \beta(\mathbf{Y}_j(\mathbf{I}) \wedge \mathbf{W}_j^{\text{old}}) + (1 - \beta)\mathbf{W}_j^{\text{old}} \quad (4.3)$$

với  $\mathbf{Y}_j(\mathbf{I}) = \frac{\|\mathbf{I} \wedge \mathbf{W}_j\|}{\alpha + \|\mathbf{W}_j\|}$

### 4.2 Hai luật học đề xuất cho Fuzzy ART

#### 4.2.1 Nội dung của hai luật học

Sau khi Fuzzy ART chọn được một cụm chiến thắng, việc học mẫu huấn luyện hiện tại diễn ra. Giả sử, cụm chiến thắng là cụm  $j$ .

#### Luật học thứ nhất

Thực hiện cập nhật trọng số cho cụm  $j$  theo công thức dưới đây:

$$W_{ji}^{new} = W_{ji}^{old} - \delta |I_i - W_{ji}^{old}|, i = 1, \dots, M \quad (4.4)$$

với  $\delta$  là tham số học tốc độ học và  $|y|$  là giá trị tuyệt đối của  $y$ .

Sau khi cập nhật có thể điều chỉnh  $W_{ij}$  theo luật sau: Do  $W_{ij}$  luôn giảm nên khi  $W_{ij} < 0$  thì đặt  $W_{ij} = 0$ .

### Luật học thứ hai

Trước tiên, tính sự tăng giá trị bé nhất (MDI- *the Minimum Difference of Increase*) và sự giảm giá trị bé nhất (MDD - *the Minimum Difference of Decrease*) của mẫu vào hiện tại so với trọng số của cụm chiến thắng theo các công thức sau:

$$MDD = \min_{I_i \leq W_{ji}^{old}, i=1, \dots, M} W_{ji}^{old} - I_i \quad (4.5)$$

$$MDI = \min_{I_i > W_{ji}^{old}, i=1, \dots, M} I_i - W_{ji}^{old} \quad (4.6)$$

Khi đó, luật học thứ hai được trình bày như sau:

$$W_{ji}^{new} = \begin{cases} W_{ji}^{old} - \delta * MDD, I_i < W_{ji}^{old} \\ W_{ji}^{old}, I_i = W_{ji}^{old} \\ W_{ji}^{old} + \delta * MDI, I_i > W_{ji}^{old} \end{cases} \quad (4.7)$$

#### 4.2.2 Thuật toán tìm giá trị cho tham số tốc độ học

*Thuật toán 4.1: Tìm giá trị thích hợp cho tham số tốc độ học của Fuzzy ART*

**Input:** Một tập mẫu con ngẫu nhiên từ tập dữ liệu ban đầu.

**Output:** Giá trị thích hợp của tham số tốc độ học.

#### Nội dung thuật toán

**Bước 1:** Khởi tạo giá trị cho các biến

*Bước 1.1:* Thiết lập giá trị cho tham số tốc độ học dựa vào kích thước của tập dữ liệu và miền giá trị của các phần tử thể hiện mẫu.

*Bước 1.2:* Thiết lập giá trị cho biến  $\varepsilon$  nguyên dương đủ nhỏ.

**Bước 2:** Lập lại các bước sau:

*Bước 2.1:* Tính kết quả phân cụm của tập mẫu.

*Bước 2.2:* Kiểm tra chỉ số Davies–Bouldin về chất lượng phân cụm:

- Nếu chỉ số Davies–Bouldin index lớn hơn  $\varepsilon$  thì làm Bước 2.3.
- Nếu chỉ số Davies–Bouldin index nhỏ hơn  $\varepsilon$  thì dừng thuật toán và đưa ra giá trị của tham số tốc độ học

*Bước 2.3:* Thay đổi giá trị của tham số tốc độ số học theo các bước nhảy nhỏ như sau: ở lần thay đổi đầu tiên, giảm giá trị của tham số. Với các lần thay đổi sau, có 4 trường hợp:

- Lần thay đổi trước thực hiện giảm giá trị và chất lượng phân cụm tăng thì tiếp tục giảm giá trị.
- Lần thay đổi trước thực hiện giảm giá trị và chất lượng phân cụm giảm thì tăng giá trị.
- Lần thay đổi trước thực hiện tăng giá trị và chất lượng phân cụm tăng thì tiếp tục tăng giá trị.
- Lần thay đổi trước thực hiện tăng giá trị và chất lượng phân cụm giảm thì giảm giá trị.

(Theo kinh nghiệm thu được từ các thực nghiệm nên chọn bước nhảy là 5% giá trị của tham số tốc độ số học hiện tại).

### 4.3 Kết quả thực nghiệm

Các tập dữ liệu chuẩn từ cơ sở dữ liệu UCI<sup>1</sup> và Shape<sup>2</sup> được dùng trong các thử nghiệm. Tác giả sử dụng các mô hình sau trong các thực nghiệm: Original EFART (OriEFART), Complement EFART (ComEFART), Original Fuzzy ART (OriFART), Complement Fuzzy ART (ComFART), K-mean, và Euclidean ART (EucART).

---

<sup>1</sup> Dữ liệu có tại địa chỉ <http://archive.ics.uci.edu/ml/datasets>

<sup>2</sup> Dữ liệu có tại địa chỉ <http://cs.joensuu.fi/sipu/datasets/>



#### 4.3.1 Thử nghiệm 1: Dùng luật học thứ nhất

9 tập dữ liệu chuẩn được chọn từ cơ sở dữ liệu UCI và Shape bao gồm Iris, Wine, Jain, Flame, R15, Glass, Blance-Scale, Aggregation, và Spiral.

Kết quả từ các kiểm tra con của 9 thử nghiệm được tổng hợp trong Bảng 4.1. Các số liệu cho thấy sự cải thiện khả năng phân lớp của EFART so với mô hình tốt nhất thứ hai.

Bảng 4.1: Sự cải thiện khả năng phân lớp của EFART với luật học thứ nhất so với mô hình tốt nhất thứ hai

Kiểu tập dữ liệu	Sự phân bố số mẫu trong các cụm	Số mẫu	Số cụm	Số thuộc tính	Mức độ cải thiện (%)
1	Không đều với độ lệch cao	200-400	2 & 3	2	21-32.6
2	Không đều với độ lệch trung bình	150	3	9	15.3
3	Không đều với độ lệch trung bình	200-214	7	9	12.6-13.5
4	Không đều với độ lệch cao	500	3	2	9.8
5	Không đều với độ lệch cao	788	7	7	4.8
6	Không đều với độ lệch thấp	120-200	2 & 3	2 & 4	2.5-5.3
7	Đều với mọi phân cụm	90-201	2	3 & 4	1.5-5
8	Không đều với độ lệch trung bình	250	3	2	0.8

Dữ liệu của Bảng 4.1 thể hiện rằng EFART thích hợp cho các tập dữ liệu nhỏ, phức tạp. EFART phân lớp tốt nhất với tập dữ liệu có các đặc trưng sau: sự phân bố số mẫu tại các cụm là không đều với độ lệch cao, số lượng lớp là nhỏ/trung bình, số lượng thuộc tính là nhỏ/trung bình, và số lượng mẫu là nhỏ/trung bình.

#### 4.3.2 Thử nghiệm 2: Dùng luật học thứ hai

7 tập dữ liệu chuẩn được chọn từ cơ sở dữ liệu UCI bao gồm MONKS, BALANCE-SCALE, D31, R35, WDBC (Wisconsin Diagnostic Breast Cancer), WINE-RED (Wine Quality of Red wine), and WINE-WHITE (Wine Quality of White wine).

Kết quả từ các thử nghiệm con của 7 thử nghiệm được tổng hợp trong Bảng 4.20. Các dữ liệu thể hiện sự cải thiện khả năng phân lớp của EFART so với mô hình tốt nhất thứ hai.

Bảng 4.2: Sự cải thiện khả năng phân lớp của EFART so với mô hình tốt nhất thứ hai trong thử nghiệm 2

Kiểu tập dữ liệu	Sự phân bố số mẫu trong các cụm	Số mẫu	Số cụm	Số thuộc tính	Mức độ cải thiện (%)
1	Không đều với độ lệch cao	600-1200	3,4	11	15.2-30.2
2	Không đều với độ lệch cao	1000-3000	3,4	11	11.1-30.1
3	Không đều với độ lệch cao	300-625	2,3	4	18-20.8
4	Không đều với độ lệch cao	400-569	2	30	15.6-16.3
5	Không đều với độ lệch cao	4000-4898	5,6	11	2.5-5.7
6	Không đều với độ lệch trung bình	400-459	2	7	2.5-2.6
7	Đều với mọi phân cụm	500-1500	5,10,15	2	2.3-3.8
8	Đều với mọi phân cụm	2000-3100	20,25,31	2	1.5-2.4

Bảng 4.2 cho thấy khả năng của phân lớp của Fuzzy ART với luật học thứ hai cải thiện đáng kể đối với các tập dữ liệu nhỏ có độ phức tạp cao (nhiều thuộc tính, phân phối số mẫu không đồng đều với độ lệch cao). Đặc biệt, kết quả phân lớp là cao khi tập dữ liệu có chứa nhiều mẫu.

## CHƯƠNG 5. LUẬT HỌC CẢI TIẾN CHO BỘ NHỚ LIÊN KẾT MỜ

### 5.1 Một số mô hình FAM

Giả sử các FAM lưu  $p$  cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  với  $\mathbf{A}^k$  có  $n$  phần tử và  $\mathbf{B}^k$  có  $m$  phần tử.

#### Mô hình của Kosko và Kong

Các ma trận trọng số kết nối  $\mathbf{W}^k$  của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính bằng công thức:

$$W_{ij}^k = \min(A_i^k, B_j^k) \quad (5.1)$$

Ma trận trọng số kết nối  $\mathbf{W}$  lưu tất cả các cặp mẫu được tính bằng công thức:

$$W_{ij} = \bigvee_{k=1}^p W_{ij}^k \quad (5.2)$$

Với mẫu vào  $\mathbf{X}$ , mẫu ra  $\mathbf{Y}$  được tính bằng hàm đầu ra:

$$Y_j = \max \left\{ \bigwedge_{i=1}^m (X_i, W_{ij}) \right\} \quad (5.3)$$

### Mô hình của Junbo, Fan, và Yan

Các ma trận trọng số kết nối  $\mathbf{W}^k$  của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính bằng công thức:

$$W_{ij}^k = I_M(A_i^k, B_j^k) \quad (5.4)$$

Ma trận trọng số kết nối  $\mathbf{W}$  lưu tất cả các cặp mẫu được tính bằng công thức:

$$W_{ij} = \bigwedge_{k=1}^p W_{ij}^k \quad (5.5)$$

Với mẫu vào  $\mathbf{X}$ , mẫu ra  $\mathbf{Y}$  được tính bằng hàm đầu ra:

$$Y_j = \max \left\{ \bigwedge_{i=1}^m (X_i, W_{ij}) \right\} \quad (5.6)$$

### Mô hình của Chung và Lee

Các ma trận trọng số kết nối  $\mathbf{W}^k$  của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính bằng công thức:

$$W_{ij}^k = I_M(A_i^k, B_j^k) \quad (5.7)$$

Ma trận trọng số kết nối  $\mathbf{W}$  lưu tất cả các cặp mẫu được tính bằng công thức:

$$W_{ij} = \bigwedge_{k=1}^p W_{ij}^k \quad (5.8)$$

Với mẫu vào  $\mathbf{X}$ , mẫu ra  $\mathbf{Y}$  được tính bằng hàm đầu ra:

$$Y_j = \bigvee_{i=1}^m \varphi(X_i, W_{ij}) \quad (5.9)$$

với  $\varphi$  là một *t-norm*

### Mô hình của Xiao, Yang, và Yu

Các ma trận trọng số kết nối  $\mathbf{W}^k$  của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính bằng công thức:

$$W_{ij}^k = \varphi(A_i^k, B_j^k) \quad (5.10)$$

với  $\varphi$  được tính như sau:

$$\varphi(x, y) = \begin{cases} 1, x = y \\ \frac{\min(A_i^k, B_j^k)}{\max(A_i^k, B_j^k)}, x \neq y \end{cases} \quad (5.11)$$

Ma trận trọng số kết nối  $\mathbf{W}$  lưu tất cả các cặp mẫu được tính bằng công thức:

$$W_{ij} = \bigwedge_{k=1}^p W_{ij}^k \quad (5.12)$$

Với mẫu vào  $\mathbf{X}$ , mẫu ra  $\mathbf{Y}$  được tính bằng hàm đầu ra:

$$Y_j = \bigvee_{i=1}^m X_i \cdot W_{ij} \quad (5.13)$$

### Họ các FAM gợi ý của Sussner và Valle

Các ma trận trọng số kết nối  $\mathbf{W}^k$  của cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  được tính bằng công thức:

$$W_{ij}^k = \varphi(A_i^k, B_j^k) \quad (5.19)$$

với  $\varphi$  là thao tác  $I_M, I_P, I_L$

Ma trận trọng số kết nối  $\mathbf{W}$  lưu tất cả các cặp mẫu được tính bằng công thức:

$$W_{ij} = \bigwedge_{k=1}^p W_{ij}^k \quad (5.20)$$

hoặc

$$W_{ij} = \bigvee_{k=1}^p W_{ij}^k \quad (5.21)$$

Với mẫu vào  $\mathbf{X}$ , mẫu ra  $\mathbf{Y}$  được tính bằng hàm đầu ra:

$$Y_j = \psi(X_i, W_{ij}) \vee \theta_j \quad (5.22)$$

với  $\psi$  là thao tác  $D_M, D_P, D_L$  và  $\theta$  được tính bằng công thức:

$$\theta_j = \bigwedge_{k=1}^p B_j^k \quad (5.23)$$

## 5.2 Luật học cải tiến

### 5.2.1 Mô hình FAM với luật học cải tiến

Mô hình FAM với luật học cải tiến (ACAM - *Association-Content Associative Memory*) được xây dựng dựa trên các bộ nhớ liên kết mờ gợi ý (IFAM).

## Quá trình học các cặp mẫu

Việc học và lưu trữ  $p$  cặp mẫu trong FAM được thực hiện qua hai bước sau:

**Bước 1:** Học và lưu trữ cặp mẫu  $(\mathbf{A}^k, \mathbf{B}^k)$  trong ma trận trọng số  $\mathbf{W}^k$  theo cách sau:

$$W_{ij}^k = \eta(B_j^k - A_i^k) + (1 - \eta)B_j^k = B_j^k - \eta A_i^k \quad (5.24)$$

với  $\eta$  là nhân tố điều khiển tỷ lệ giữa nội dung và sự liên kết được lưu. Do dùng nhân tố  $\eta$  nên khi mẫu vào bị nhiễu thì nhiễu sẽ ít ảnh hưởng hơn đến mẫu được nhớ lại.

**Bước 2:** Tổng quát hóa sự liên kết của các cặp mẫu và lưu trữ trong ma trận trọng số chung theo công thức sau:

$$W_{ij} = \bigwedge_{k=1}^p W_{ij}^k = \bigwedge_{k=1}^p (B_j^k - \eta A_i^k) \quad (5.25)$$

## Quá trình nhớ lại

Việc nhớ lại mẫu ra  $\mathbf{Y}$  từ mẫu vào  $\mathbf{X}$  và ma trận trọng số chung  $\mathbf{W}$  được thực hiện như sau: Mẫu ra được nhớ lại thông qua sự tổng hợp của ma trận trọng số chung và mẫu vào như trong công thức dưới đây:

$$Y_j = \bigvee_{i=1}^m (\eta X_i + W_{ij}) \quad (5.26)$$

## Điều chỉnh ACAM cho chế độ tự liên kết

Để đảm bảo khả năng lưu trữ không giới hạn các cặp mẫu ở chế độ tự liên kết, tác giả tính  $W_{ii}$  giống như trong MAM.

$$W_{ij} = \begin{cases} \bigwedge_{k=1}^p (B_j^k - A_i^k) & \text{if } i = j \\ \bigwedge_{k=1}^p (B_j^k - \eta A_i^k) & \text{if } i \neq j \end{cases} \quad (5.27)$$

Khi đó, công thức dùng cho việc nhớ lại được điều chỉnh như sau:

$$Y_j = \bigvee_{i \neq j} (\eta X_i + W_{ij}) \vee (X_i + W_{ij}) \quad (5.28)$$

### 5.2.2 Hai định lý về khả năng nhớ lại hoàn hảo của FAM cải tiến

*Định lý 5.1: (Khả năng nhớ lại các cặp mẫu trong chế độ liên kết khác loại)*

**W** trong công thức (5.27) nhớ lại hoàn hảo mọi cặp mẫu ( $\mathbf{A}^k, \mathbf{B}^k$ ) nếu và chỉ nếu với mỗi  $k=1, \dots, p$ , mỗi cột của ma trận  $\mathbf{W}^k - \mathbf{W}$  có chứa một số 0.

*Hệ quả 5.1: (Khả năng nhớ lại các cặp mẫu trong chế độ tự liên kết)*

**W** trong công thức (5.27) nhớ lại hoàn hảo mọi cặp mẫu ( $\mathbf{A}^k, \mathbf{A}^k$ ).

## 5.3 Kết quả thực nghiệm

Năm mô hình được thực thi gồm các mô hình được đưa ra bởi Junbo, Kosko, Xiao, Ritter (MAM), Susners và Valle (IFAMs).

### 5.3.1 Thử nghiệm với tập dữ liệu về các số

Bộ dữ liệu này bao gồm 5 hình ảnh của số 0-4 với kích thước  $5 \times 5$ .

Bảng 5.1: Kết quả của thử nghiệm bộ nhớ tự liên kết với tập dữ liệu về con số

	Junbo	Kosko	Xiao	IFAM	MAM	ACAM
Lỗi	0.434	0.914	0.418	0.434	0.434	<b>0.346</b>

Số liệu từ bảng cho thấy ACAM có tổng lỗi ít nhất

Bảng 5.2: Kết quả thử nghiệm của bộ nhớ liên kết khác loại với tập dữ liệu về con số

	Junbo	Kosko	Xiao	IFAM	MAM	ACAM
Lỗi	0.675	0.893	0.793	0.675	0.675	<b>0.652</b>

Trong chế độ liên kết khác loại, các cặp ảnh cần lưu trữ là ảnh của 0 và 1, 1 và 2, ...  
Từ bảng cho thấy ACAM cũng tạo ra tổng lỗi ít nhất.

### 5.3.2 Thử nghiệm với tập dữ liệu của Corel

Bộ dữ liệu này bao gồm các hình ảnh được lựa chọn từ cơ sở dữ liệu Corel Các mẫu thử nghiệm được tạo ra từ các mẫu vào bằng cách tạo ra nhiễu muối tiêu ở mức 25% số lượng điểm ảnh.

Trong chế độ tự liên kết, 10 ảnh được sử dụng. Kết quả trong chế độ tự liên kết cho thấy ACAM hiệu quả trong việc xử lý với nhiễu muối tiêu..

Chế độ liên kết khác loại được thử nghiệm với 10 cặp ảnh, trong đó các ảnh vào khác với ảnh ra. Bảng 5.4 cũng cho thấy ACAM thực hiện tốt hơn so với các mô hình khác.

Bảng 5.3: Kết quả của thử nghiệm bộ nhớ tự liên kết với tập dữ liệu của Corel

	Junbo	Kosko	Xiao	IFAM	MAM	ACAM
Lỗi	0.742	0.867	0.694	0.664	0.664	<b>0.531</b>

Bảng 5.4: Kết quả của thử nghiệm bộ nhớ liên kết khác loại với tập dữ liệu của Corel

	Junbo	Kosko	Xiao	IFAM	MAM	ACAM
Lỗi	0.795	1.018	0.702	0.624	00.624	<b>0.548</b>

## KẾT LUẬN

Các nội dung nghiên cứu của luận án đã hoàn thành và đạt được các kết quả sau:

Đề xuất một thuật toán học cho BAM để học nhanh và linh động hơn. Hơn nữa, BAM gắn với thuật toán học cải tiến còn lưu trữ và nhớ lại tốt với các cặp mẫu không trực giao. Năm thử nghiệm trong ứng dụng nhận dạng mẫu cho thấy BAM đề xuất có khả năng nhớ lại tốt hơn các BAM khác trong chế độ tự liên kết.

Đưa ra hai luật học hiệu quả của Fuzzy ART để học tốt hơn mọi mẫu huấn luyện đồng thời giảm sự ảnh hưởng của các mẫu huấn luyện dị thường. 16 tập dữ liệu chuẩn được chọn từ cơ sở dữ liệu UCI và Shape được thực nghiệm cho thấy khả năng phân cụm của Fuzzy ART cải tiến cao hơn với các tập dữ liệu nhỏ, phức tạp.

Trình bày luật học cải tiến cho FAM để lưu trữ hiệu quả cả nội dung và sự liên kết giữa các cặp mẫu. Hơn nữa, FAM gắn với luật học cải tiến còn giảm sự ảnh hưởng của các mẫu vào nhiễu trong quá trình nhớ lại để chịu nhiễu tốt hơn với các nhiễu ở cả hai dạng co rút và giãn nở. Kết quả thử nghiệm với ứng dụng nhận dạng mẫu cho thấy FAM với luật học cải tiến có khả năng nhớ lại tốt hơn các FAM khác trong cả hai chế độ.