

공학석사 학위논문

잡음 패턴 인식을 위한 양방향 연산 메모리
기반 퍼지 지도 학습 방법



2025년 02월

부경대학교 산업대학원

컴퓨터공학과

오 준 철

공학석사 학위논문

잡음 패턴 인식을 위한 양방향 연산 메모리 기반 퍼지 지도 학습 방법



2025년 02월

부경대학교 산업대학원

컴퓨터공학과

오 준 철

이 논문을 오준철의 공학석사
학위논문으로 인준함

2025년 02월 21일



주 심 공학박사 신 봉 기 (인)

위 원 공학박사 정 목 동 (인)

위 원 공학박사 장 원 두 (인)

목 차

ABSTRACT	iii
I. 서 론	01
II. 관련연구	03
2.1 양방향 연상 메모리	03
2.2 퍼지 지도 학습 알고리즘	07
2.3 잡음 제거 및 생성 방법	10
III. 양방향 연상 메모리기반 퍼지 지도 학습방법을 위한 설계	12
3.1 양방향 연상 메모리기반 퍼지 지도 학습방법을 위한 설계	12
IV. 양방향 연상 메모리기반 퍼지 지도 학습 결과분석	18
4.1 제안된 학습방법의 개발환경	18
4.2 실험결과 분석	19
4.3 실험 고찰	25
V. 결론 및 향후 연구	26
참고문헌	28

Bidirectional computational memory-based Fuzzy Supervised Learning Method for Noise Pattern Recognition

Juncheol Oh

Directed by Professor Mokdong Chung

*Department of Computer Engineering, The Graduate School
Pukyong National University*

ABSTRACT

Recently, deep learning techniques have been applied to image analysis and recognition fields with various features. In particular, CNN (Convolution Neural Networks) is a deep neural network that has excellent performance in image processing and recognition performance among various deep learning models. However, in order to have excellent performance in recognition of patterns or images with a lot of noise or severe damage, many learning patterns are required and the labeling work for the learning patterns must be accurate. In general, it is efficient to apply CNN, a deep learning technique, to images with quantified features. However, when applying CNN to images with noise or severe damage, a lot of learning data is required. Therefore, it is efficient to select a supervised learning algorithm based on data analysis.

In general, supervised learning methods in deep neural networks or deep learning require many training data pairs to improve the recognition performance of patterns. However, when learning patterns that are noisy or

severely damaged, the classification performance of learning deteriorates or learning does not occur. Therefore, in this paper, we propose a fuzzy supervised learning method based on bidirectional associative memory that can improve the classification performance of learning and enhance the recognition performance with a small number of training pattern pairs even when there is noise or some features are damaged.

In the proposed learning method, the fuzzy supervised learning structure based on the bidirectional associative memory is a complete research structure. In the proposed learning structure, the learning of the input layer and the associative memory layer is performed using a recurrent learning structure. And supervised learning is applied between the associative memory layer and the output layer to adjust the connection weights and bias terms.

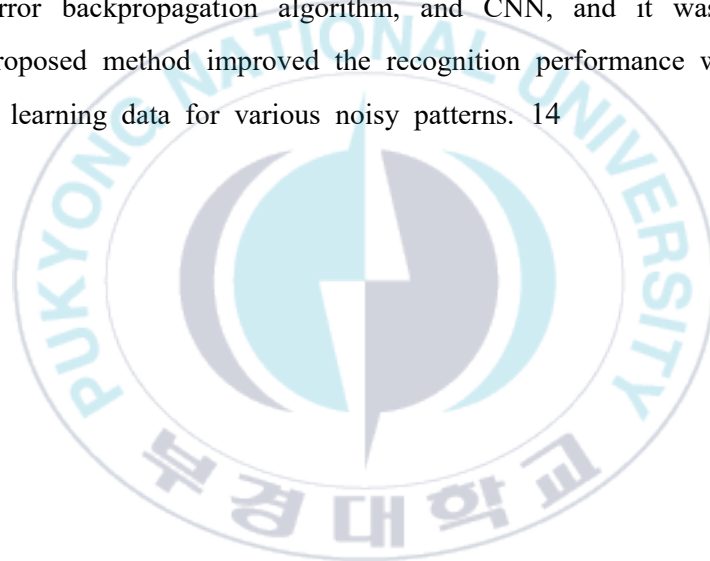
And in the input layer and associative memory layer, BAM is applied to restore damaged features or remove noise from noisy features to form quantified data as input to the output layer. And the quantified data is transferred to the output layer to apply fuzzy map learning.

In this paper, we implemented and experimented with Visual Studio C# on a PC equipped with an Intel(R) Core(TM) i7-8400 CPU and 16GB RAM. In this paper, we compared and analyzed the recognition performance of the proposed learning method with the existing fuzzy supervised learning method, error backpropagation algorithm, and CNN among deep learning techniques.

In order to analyze the recognition performance of the proposed method, this paper conducted recognition experiments on patterns with noise. Noise is generally referred to as noise. Representative methods for experimenting with noise include salt-and-pepper noise and Gaussian noise.

When the features of numeric or English letter patterns are normalized but

there is a lot of noise in the patterns, the image processing process is performed to remove the noise and then the learning pattern is constructed. However, in the process of removing the noise, the features are lost or the learning patterns containing noise are constructed, so when applied to machine learning or deep learning techniques, the classification performance is sometimes degraded. Therefore, in this paper, we propose a fuzzy supervised learning algorithm based on homogeneous associative memory that can effectively classify and recognize features with a small amount of learning data even when noise is included. In order to analyze the performance of the proposed learning method, the recognition performance was compared and analyzed with the existing fuzzy supervised learning method, error backpropagation algorithm, and CNN, and it was confirmed that the proposed method improved the recognition performance with a small amount of learning data for various noisy patterns. 14



I. 서론

최근에는 다양한 특징이 있는 영상 분석 및 인식 분야에 딥러닝 기법들이 적용되고 있다. 특히 CNN (Convolution Neural Networks)은 여러 딥러닝 모델 중에서 영상 처리 및 인식 성능에서 우수한 성능을 가지는 딥러닝 기법이다. 그러나 잡음이 많거나 훼손이 심한 패턴이나 영상 인식에서 우수한 성능을 가지기 위해서는 많은 학습 패턴이 필요하고 학습 패턴을 위한 라벨링 작업이 정확해야 한다[1]. 일반적으로 숫자나 영문자들과 같이 패턴들의 특징이 정형화 되어 있으나 이 패턴들에 잡음이 많이 존재하는 경우에는 영상 처리 과정을 수행하여 잡음을 제거한 후에 학습 패턴을 구성한다. 그러나 잡음을 제거하는 과정에서 특징이 손실되거나 잡음이 포함된 학습 패턴들을 구성하기 때문에 기계 학습이나 딥러닝 기법에 적용할 경우에는 분류 성능이 저하되는 경우가 발생한다. 기존에는 패턴에 다양한 잡음이 존재할 경우 영상 처리 과정을 수행한 후에 많은 패턴들을 학습 패턴으로 구성하여 기계 학습이나 딥러닝 기법에 적용하였다. 그러나 영상 처리 과정을 수행하여도 학습 패턴들의 특징이 손실되거나 잡음이 포함되는 경우가 발생하여 학습 성능을 저하시켜 인식이 낮아지는 문제점이 발생하였다.

일반적으로 정량화된 특징을 가지는 영상데이터에서는 딥러닝 기법인 CNN을 적용하는 것은 효율적이다. 그러나 잡음이나 훼손 정도가 심한 영상이 존재하는 영상의 경우에 CNN을 적용할 경우에는 많은 학습 데이터가 요구된다[1][2]. 따라서 데이터 분석을 기반으로 지도 학습 알고리즘을 선택하는 것이 효율적이다.

데이터의 특징들이 훼손되거나 잡음이 있는 경우에 기존의 학습 기법을 적용할 경우에는 다양한 학습 데이터 쌍이 필요하며 효과적으로 특징을 분류할 수 없기 때문에 이질 연산 메모리를 적용하여 학습 데이터 쌍들을 정량화 한 후에 특징을 분류하는 것이 효과적이다[3]. 퍼지 지도 학습 알고리즘은 퍼지의 기본 연산자를 사용하여 입력 데이터 값이 0과 1사이의 값으로 받아들여 학습하는 알고리즘이고 이 알고리즘의 장점은 기존의 신경망 지도 알고리즘이 이진 데이터를 학습하는 데 중점을 둔 반면에 퍼지 값인 0과 1사이의 값을 효과적으로 학습 할 수 있도록 퍼지 논리 연산자를 이용한 것이 큰 장점이다. 그러나 이 알고리즘은 잡음이 있거나 훼손된 패턴 또는 영상 인식과 같은 실제 세계 문제에 현실적으로 적용할 경우에는 학습 성능이 저하되거나 인식 성능이 낮아지는 문제점이 있다[4].

인공 신경망이나 심층 신경망 학습 모델 중에서는 훼손된 특징들을 복구할 수 있는 학습 알고리즘으로 연상 메모리 기법이 널리 적용되고 있다[4]. 특히 이질 연상 메모리 기법은 훼손된 특징을 효과적으로 복원할 수 있는 이질 연상 메모리 기법으로 양방향 연상 메모리(BAM : Bidirectional Associative Memory) 기법이 널리 적용되고 있다[5].

본 논문에서는 숫자나 영문자들과 같이 정량화된 특징을 갖는 영상에서 잡음이 많이 존재하거나 일부 특징들이 훼손된 경우에 대해서 적은 학습 데이터로 특징을 분류하고 효과적으로 인식할 수 있는 이질 연상 메모리와 퍼지 지도 학습을 결합한 모델과 학습 방법을 제안한다.



II. 관련 연구

2.1 양방향 연상 메모리

연상 메모리에는 두 가지 유형이 있다. 자동 연상 메모리 (Autoassociative memory) 와 이종 연상 메모리 (Heteroassociative memory) 이다. Autoassociative memory는 하나의 기억을 완벽히 구성 또는 교정 할 수 있지만, 기억된 데이터로 다른 기억을 연상할 수 없다는 점이 큰 특징이다.

Heteroassociative memory(Bidirectional Associative Memory(BAM))는 위의 자동 연상메모리와 달리 서로 다른 기억을 연상할 수 있다. Noise가 섞인 입력에 대해 올바른 출력을 생성, 즉 noise를 제거하여 특징을 추출할 수 있다는 점이 큰 특징이다. BAM(Bidirectional Associative Memory)은 1985년에 B.Kosko가 제안하였으며, 양방향의 연상 작용이 가능한 양방향 연상 메모리이다[5][6].

BAM은 그림 1과 같이 단층 구조이지만 입출력층으로 명확히 구분되지 않은 X층과 Y층으로 구성된다. 그림 1과 같이 X층에서 p 번째 $x_i(p)$ 가 입력되면 Y층에서 p 번째 $y_j(p)$ 가 출력이 되고 반대로 Y층에서 $y_j(p)$ 가 입력되면 X층에서 $p+1$ 번째 $x_i(p+1)$ 가 출력이 나오는 형태를 가진 이질 연상 메모리이다.

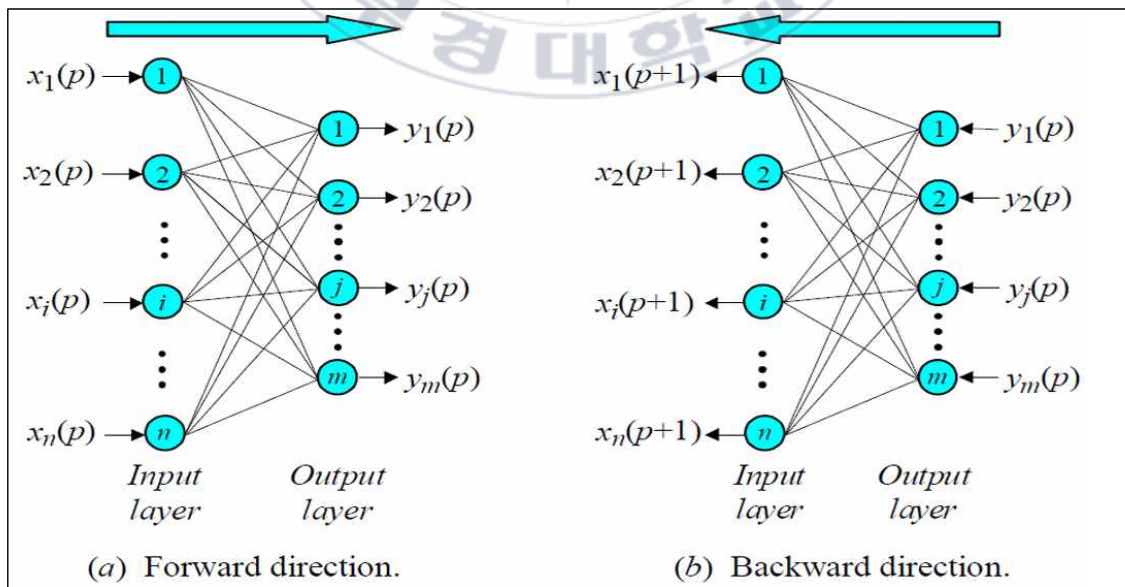


그림 1. BAM의 학습 구조

연상 패턴쌍 (x, y)를 저장하는 연결 강도 W는 단방향 연상 메모리와 동일한 방법으로 구할 수 있으나 반드시 양극성 데이터 형태로 처리하여야 한다.

BAM에서는 다음과 같이 기억시킬 X층 패턴 x와 연상되는 Y층 패턴 y의 외적을 연결 강도 W로 사용한다.

<p>기억시킬 X층 패턴 : $x = [x_1 x_2 \dots x_n]$</p> <p>연상되는 Y층 패턴 : $y = [y_1 y_2 \dots y_m]$</p> <p>연결 강도 : $W = x^T y$</p> $= \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} [y_1 y_2 \dots y_m]$

만약, p개의 패턴쌍들을 저장할 경우의 연결 강도 W는 식(1)과 같다.

(1)	$W = W_1 + W_2 + \dots + W_p$ $= \sum_{i=1}^p x^T(i)y(i)$ $= x^T(1)y(1) + x^T(2)y(2) + \dots + x^T(p)y(p)$
-----	--

BAM 학습 알고리즘은 다음과 같다.

Step 1 : p개의 패턴 쌍을 저장할 연결 강도 W를 식 (2)와 같이 계산한다.

(2)	$W = \sum_{i=1}^p x^T(i)y(i)$
-----	-------------------------------

Step 2 : 입력 패턴 X를 X층에 입력한다. 양방향 연상 메모리이므로 입력 패턴 Y를 Y 층에 입력하는 경우에는 연상되는 패턴 X가 X층에서 출력된다.

Step 3 : 식 (3)과 같이 Y 층의 입력 가중합 NET_y와 출력 값 양극성 활성화 함수를 적용하여 출력 값 y를 구한다.

(3)	$NET_y = XW$
-----	--------------

Step 4 : 양극성 활성화 함수를 적용하여 Y층의 첫 번째 출력 Y을 구한다.

$Y = \begin{cases} 1 & : T_y > 0 \\ y & : T_y = 0 \\ -1 & : T_y < 0 \end{cases}$
--

Step 5 : Y 층의 출력 Y을 입력하여 X층의 입력 가중합 NET_x를 식(4)와 같이 계산 W^T 하고 역방향 연산을 위해 연결 강도 W의 전치행렬 W^T 를 적용한다.

(4)	$NET_x = XW^T$
-----	----------------

Step 6 : X층의 첫 번째 출력 X을 구한다.

$X = \begin{cases} 1 & : T_x > 0 \\ x & : T_x = 0 \\ -1 & : T_x < 0 \end{cases}$
--

Step 7 : X층의 출력 X를 입력하여 X층의 두 번째 출력 Y를 구한다. 그리고 Y를 입력하여 X를 구하는

과정을 반복하여 출력이 변하지 않고 특정 패턴에 수렴 할 때까지 학습을 반복한다.

BAM은 양방향 연상 작용을 하는 메모리이므로 저장할 수 있는 용량에 한계가 있다. 일반적으로 X층과 Y층의 뉴런수가 각각 n과 m일 경우 BAM에 저장할 수 있는 패턴의 수는 $\sqrt{\min(m,n)}$ 정도이다.

BAM의 저장 용량을 확장하기 위해서는 저장되는 패턴들 간에 유사도가 낮아지게 할 필요가 있다. 예를 들어, F.Wang이 시도한 방법으로 잡음이 없는 정확한 패턴쌍을 별도로 더 기억시킴으로써 연상 효과를 높인다든지 기억시킬 패턴쌍들을 여러 번 반복하여 기억시킴으로써 BAM의 성능을 향상할 수 있다.



2.2 퍼지 지도 학습 알고리즘

퍼지 지도 학습 알고리즘은 신경망의 퍼셉트론에 퍼지의 곱 연산자와 합 연산자를 사용하고, 입력 데이터는 0과 1 사이의 값을 받아서 학습하는 알고리즘이다[7][8]. 이 알고리즘의 장점은 기존 신경망의 단층 알고리즘이 이진 데이터를 학습하는 데 중점을 둔 것과 달리 퍼지 수인 0과 1 사이의 값을 효과적으로 학습 할 수 있도록 퍼지 논리 연산자를 이용한다. 표 1은 신경망의 퍼셉트론과 퍼지 지도의 학습 방법을 비교하여 나타낸 것이다.

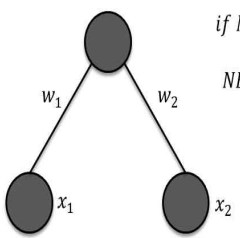
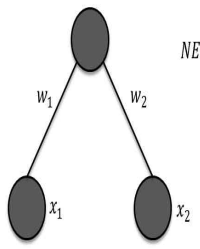
각 학습 구조 차이점	단층 퍼셉트론	퍼지 지도 학습 방법
초기 가중치 설정	$-1 \leq w_{ji} \leq 1$	$0 \leq w_{ji} \leq 1$
초기 바이어스 설정	없음	$0 \leq \theta_j \leq 1$
학습률(α) 설정	$0 < \alpha \leq 1$	$0 < \alpha \leq 1$
모멘텀(β) 설정	없음	$0 < \beta \leq 1$
NET값 계산	$NET = \sum_{j=1}^h \sum_{i=1}^q x_i \times w_{ji}$	$NET = \bigvee_{j=1}^h \{ \bigwedge_{i=1}^q (x_i, w_{ji}) \}$
출력(o_j^p)값 계산	$NET \geq T \quad o_j^p = 1$ $NET < T \quad o_j^p = 0$	$o_j^p = NET \vee \theta_j$
가중치(w_{ji}) 조정	$w_{ji}(n+1) = w_{ji}(n) + \alpha \Delta w_{ji}$	$w_{ji}(n+1) = w_{ji}(n) + \alpha \Delta w_{ji}(n) + \beta \Delta w_{ji}(n-1)$
바이어스(θ_j)조정	없음	$\theta_j(n+1) = \theta_j(n) + \alpha \Delta \theta_j(n) + \beta \Delta \theta_j(n-1)$
학습 구조	 <p>if $NET \geq 1$ Then Y else $Y = 0$ $NET = x_1 w_1 + x_2 w_2$ $= \sum_{i=1}^2 x_i y_i$</p>	 <p>$Y = NET \vee \theta_j$ $NET = (x_1 \wedge w_1) \vee (x_2 \wedge w_2)$ $= \bigvee_{i=1}^2 (x_i, w_i)$</p>

표 1. 단층 퍼셉트론과 퍼지 지도 학습 방법 비교

퍼지 지도 학습 알고리즘은 패턴 인식 등에 다양하게 적용할 수 있으나 학습률과 모멘텀에 따라 학습 성능이 좌우되는 경우가 발생하고 특징이 훼손된 패턴들에 대해서는 학습의 수렴성이 보장되지 않거나 인식 성능이 낮아지는 문제점이 발생한다[9][10]. 그러나 퍼지 지도 학습 알고리즘은 학습 과정에서 가중치와 바이어스항을 조정하므로 정량화된 패턴 인식 등에 효과적으로 적용되고 있다[11][12]. 따라서 퍼지 지도 학습 알고리즘은 다음과 같다.

Step 1 : 학습 패턴쌍인 입력 값(x_i)과 목표 값(t_j^p)을 설정한다.

Step 2 : 연결 가중치 (w_{ji})과 바이어스(θ_j)를 0과 1사이의 임의의 값으로 설정한다.

$$0 \leq w_{ij} \leq 1, 0 \leq \theta_j \leq 1$$

Step 3 : 출력 값(o_j^p)을 식 (5)와 같이 계산한다.

(5)	$NET = \bigvee_{j=1}^h \left\{ \bigwedge_{i=1}^g (x_i, w_{ji}) \right\}$ $o_j^p = NET \bigvee \theta_j$
-----	---

Step 4 : 총 오차 자승합(TSS)을 식 (6)과 같이 계산한다.

(6)	$TSS = \sum_{p=1}^l \sum_{j=1}^h \frac{1}{2} (t_j^p - o_j^p)^2$
-----	---

Step 5 : 출력 값과 목표 값이 같지 않은 경우에만 가중치 값과 바이어스 값을 조정한다. α 와 β 는 각각 학습률과 모멘텀이다.

(7)	$w_{ji}(n+1) = w_{ji}(n) + \alpha \Delta w_{ji}(n) + \beta \Delta w_{ji}(n-1)$
(8)	$\theta_j(n+1) = \theta_j(n) + \alpha \Delta \theta_j(n) + \beta \Delta \theta_j(n-1)$

Step 6 : TSS가 오차 한계(E_{\max})보다 작으면 학습을 종료하고 그렇지 않으면 Step 3으로 가서 학습을 반복 한다.

$TSS \leq E_{\max}$

2.3 잡음 제거 및 생성 방법

최근에 정보 기술의 발전에 따라 디스플레이 등 다양한 영상 관련 장비들에 대한 수요가 증가하고 있다. 일반적으로 디지털 영상을 획득하고 처리한 후에 전송하는 과정에서 다양한 외부 요소들에 의해 잡음이 추가되어서 영상의 화질이 저하되어 경우가 발생한다. 이에 따라서 영상에 포함된 잡음의 영향을 최소화 하기 위한 연구가 활발히 진행되고 있다[13].

영상에 포함되는 잡음은 원인들에 따라 다양하다. 일반적으로 임펄스 잡음, 가우시안 잡음, 유니폼 잡음이 있다. 잡음을 제거하기 위한 대표적인 공간 영역 기법으로는 CWMF(center weighted median filter), A-TMF(alpha-trimmed mean filter), AWMF(adaptive weighted median filter) 등이 있다. 그러나 이러한 방법들은 가우시안 잡음 및 임펄스 잡음이 혼합된 환경에서는 잡음을 효과적으로 제거할 수 없고 잡음을 제거하더라도 잡음 제거의 효율성이 다소 미흡하다[14].

일반적으로 잡음을 노이즈(noise)라고 한다. 대표적인 잡음을 실험하는 방법으로 소금-후추 잡음, 가우시안 잡음 등이 있다[15][16]. 소금과 후추 잡음(salt-and-pepper noise)은 영상에 마치 소금과 후추를 뿌려 놓은 것처럼 검거나 흰 픽셀이 나타나는 잡음을 의미한다. 소금에 해당하는 것으로는 가장 밝은 명암도와 가장 어두운 명암도가 해당된다. 잡음을 제거하는 영상 처리 기법으로 평균 마스크와 중간값 필터링 등이 널리 적용되고 있다.

가우시안 잡음(Gaussian noise)은 잡음의 확률 분포가 가우시안 분포(Gaussian distribution)를 따르는 잡음이다[17]. 1차원에서의 가우시안 분포는 곡선 형태를 분포이며 가우시안 분포 곡선은 식 (9)와 같다.

(9)	$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}}$
-----	---

식 (9)에서 σ 는 표준 편차이다.

2차원에서의 가우스 마스크는 식 (10)과 같다.

(10)	$G(x,y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}}$
------	---

식 (10)에서 x 와 y 는 마스크 중심을 원점으로 정의한 후의 가로와 세로를 의미한다.



Ⅲ. 제안된 양방향 연상 메모리 기반 퍼지 지도 학습방법을 위한 설계

3.1 양방향 연산 메모리 기반 퍼지 지도 학습방법을 위한 설계

일반적으로 심층 신경망이나 딥러닝에서 지도 학습 방법들은 패턴들의 인식 성능을 높이기 위하여 많은 학습 데이터 쌍이 필요하다. 그러나 잡음이나 훼손이 심한 패턴들을 학습 할 경우에는 학습의 분류 성능이 저하되거나 학습이 되지 않는 경우가 발생한다. 그리고 학습이 된 경우에도 인식 성능이 저하되는 경우가 발생한다. 일반적으로 영상의 인식에 적용할 경우에 잡음이나 훼손이 많이 존재할 경우에는 영상의 전처리 과정에서 잡음을 제거하는 과정을 수행한다[18]. 그러나 잡음을 제거하는 과정에서 특징들이 손실되는 경우가 발생하므로 학습의 분류 성능을 저하시키는 원인이 된다[19]. 그리고 영상에서 특징들이 훼손된 경우에는 다양한 형태를 가진 많은 학습 패턴 쌍을 학습시키므로 학습 시간이 많이 소요되고 학습의 수렴성이 낮아지는 문제점이 발생한다. 따라서 본 논문에서는 잡음이 있거나 특징이 일부 훼손된 경우에도 적은 학습 패턴쌍으로 학습의 분류 성능을 개선시키고 인식 성능을 향상시킬 수 있는 양방향 연상 메모리 기반의 퍼지 지도 학습 방법을 제안한다.

제안된 그림 2. 제안된 양방향 연상 메모리 기반의 퍼지 지도 학습 모형은 그림 2와 같다.

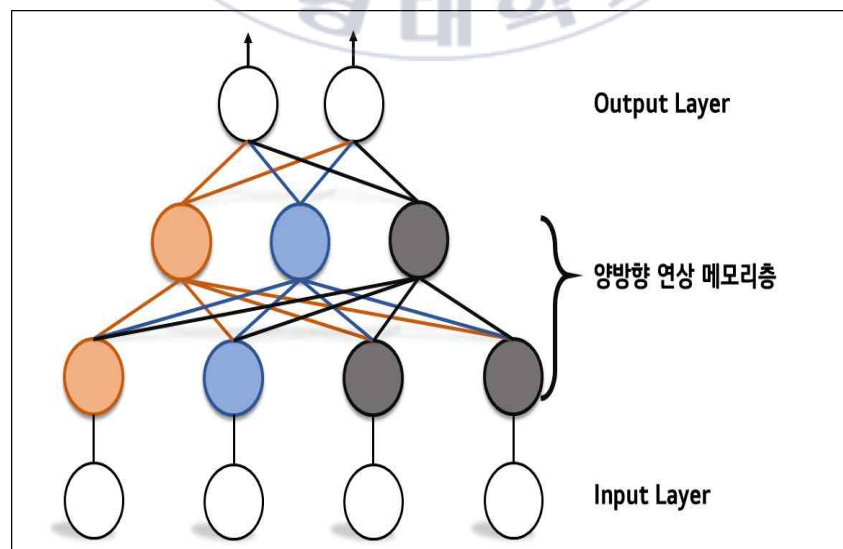


그림 2. 제안된 양방향 연상 메모리 기반의 퍼지 지도 학습 모형

그림 2에서와 같이 양방향 연상 메모리 기반의 퍼지 지도 학습 방법은 입력층과 연상 메모리층 및 출력층으로 구성된다. 연상 메모리층에서는 훼손된 데이터나 잡음이 있는 데이터를 정량화하고 출력층의 입력으로 적용하여 지도 학습 방법으로 연상 메모리층과 출력층 사이의 연결 가중치와 바이어스항을 조정한다.

(1) 양방향 연상 메모리 기반의 퍼지 지도 학습 구조는 완결 연구 구조이다. 제안된 학습 구조에서 입력층과 연상 메모리 층의 학습은 순환 학습 구조로 학습이 이루어진다. 그리고 연상 메모리 층과 출력층 사이는 지도 학습이 적용되어 연결 가중치와 바이어스 항이 조정된다.

(2) 입력층과 연상 메모리 층에서는 BAM을 적용하여 훼손된 특징을 복원하거나 잡음이 있는 특징에서 잡음을 제거하여 출력층의 입력으로 정량화된 데이터를 구성한다. 그리고 정량화된 데이터를 출력층에 전달하여 지도 학습을 적용한다.

제안된 양방향 연상 메모리 기반 퍼지 지도 학습 알고리즘은 다음과 같다.

Step 1 : p개의 패턴 쌍을 저장할 연결 가중치 (w_{ba})를 식 (11)과 같이 계산한다.

(11)	$G(x,y) = -\frac{x^2}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}}$
------	--

식 (11)에서 a는 입력층의 입력 노드 수이고 b는 연상 메모리 층의 노드 수이다. 그리고 p 는 패턴의 수이다.

Step 2 : 입력 패턴 s_a^p 를 입력층에 입력한다.

Step 3 : 연상 메모리 층의 입력 가중합 NET_b 을 식 (12)와 같이 구한다.

(12)	$NET_b = s_a^p \times w_{ba}$
------	-------------------------------

Step 4 : 양극성 활성화 함수를 적용하여 연상 메모리층의 첫 번째 출력 y_b^p 을 구한다.

$y_b = \begin{cases} 1 & : T_y > 0 \\ y_b & : T_y = 0 \\ -1 & : T_y < 0 \end{cases}$
--

Step 5 : 연상 메모리 층의 출력 y_b^p 을 입력하여 입력층의 가중합 NET_a 를 식(13)과 같이 계산하고 역방향 연산을 위해 연결 가중치 w_{ab} 를 적용한다.

(13)	$NET_a = y_b^p \times w_{ab}$
------	-------------------------------

Step 6 : 입력층의 s_a^p 을 구한다.

$s_a^p = \begin{cases} 1 & : T_s > 0 \\ s_a & : T_s = 0 \\ -1 & : T_s < 0 \end{cases}$
--

Step 7 : 입력층의 s_a^p 을 입력하여 연상 메모리 층의 두 번째 출력 y_b^p 를 구한다. 그리고 y_b^p 를 입력하여 s_a^p 를

구하는 과정을 반복하여 출력이 변하지 않고 특정 패턴에 수렴할 때까지 학습을 반복한다. 학습이

종료된 후에는 출력층의 입력 값으로 적용하기 위해 y_b^p 이 0보다 적으면 0으로 변환하고 0보다 크면

1로 변환하여 출력층의 입력 데이터를 구성한다.

Step 8 : 출력층의 출력 값(o_k^p)을 식 (14)와 같이 계산한다.

(14)	$NET_k = \bigvee_{k=0}^{h-1} \left\{ \bigwedge_{b=0}^{g-1} (y_b^p, w_{kb}) \right\}$ $o_k^p = NET_k \bigvee \theta_k$
------	---

Step 9 : 총 오차 자승합(TSS)을 식 (15)과 같이 계산한다.

(15)	$TSS = \sum_{p=1}^l \sum_{k=1}^h \frac{1}{2} (t_k^p - o_k^p)^2$
------	---

Step 10 : 출력 값과 목표 값이 같지 않은 경우에만 가중치 값과 바이어스 값을 식 (16)과 (17)와 같이 조정

한다. α 와 β 는 각각 학습률과 모멘텀이다.

(16)	$w_{kb}(n+1) = w_{kb}(n) + \alpha \Delta w_{kb}(n) + \beta \Delta w_{kb}(n-1)$
(17)	$\theta_k(n+1) = \theta_k(n) + \alpha \Delta \theta_k(n) + \beta \Delta \theta_k(n-1)$

Step 11. 총 오차 자승합인 TSS가 오류 한계(E_{\max})보다 적거나 같으면 학습을 종료 하고 그렇지 않으면 Step 8로 가서 학습을 반복한다.

$TSS \leq E_{\max}, \quad \text{Where } E_{\max} < 0.1$

제안된 양방향 연산 메모리 기반 지도 학습 과정의 처리 구성도는 그림 3과 같다.

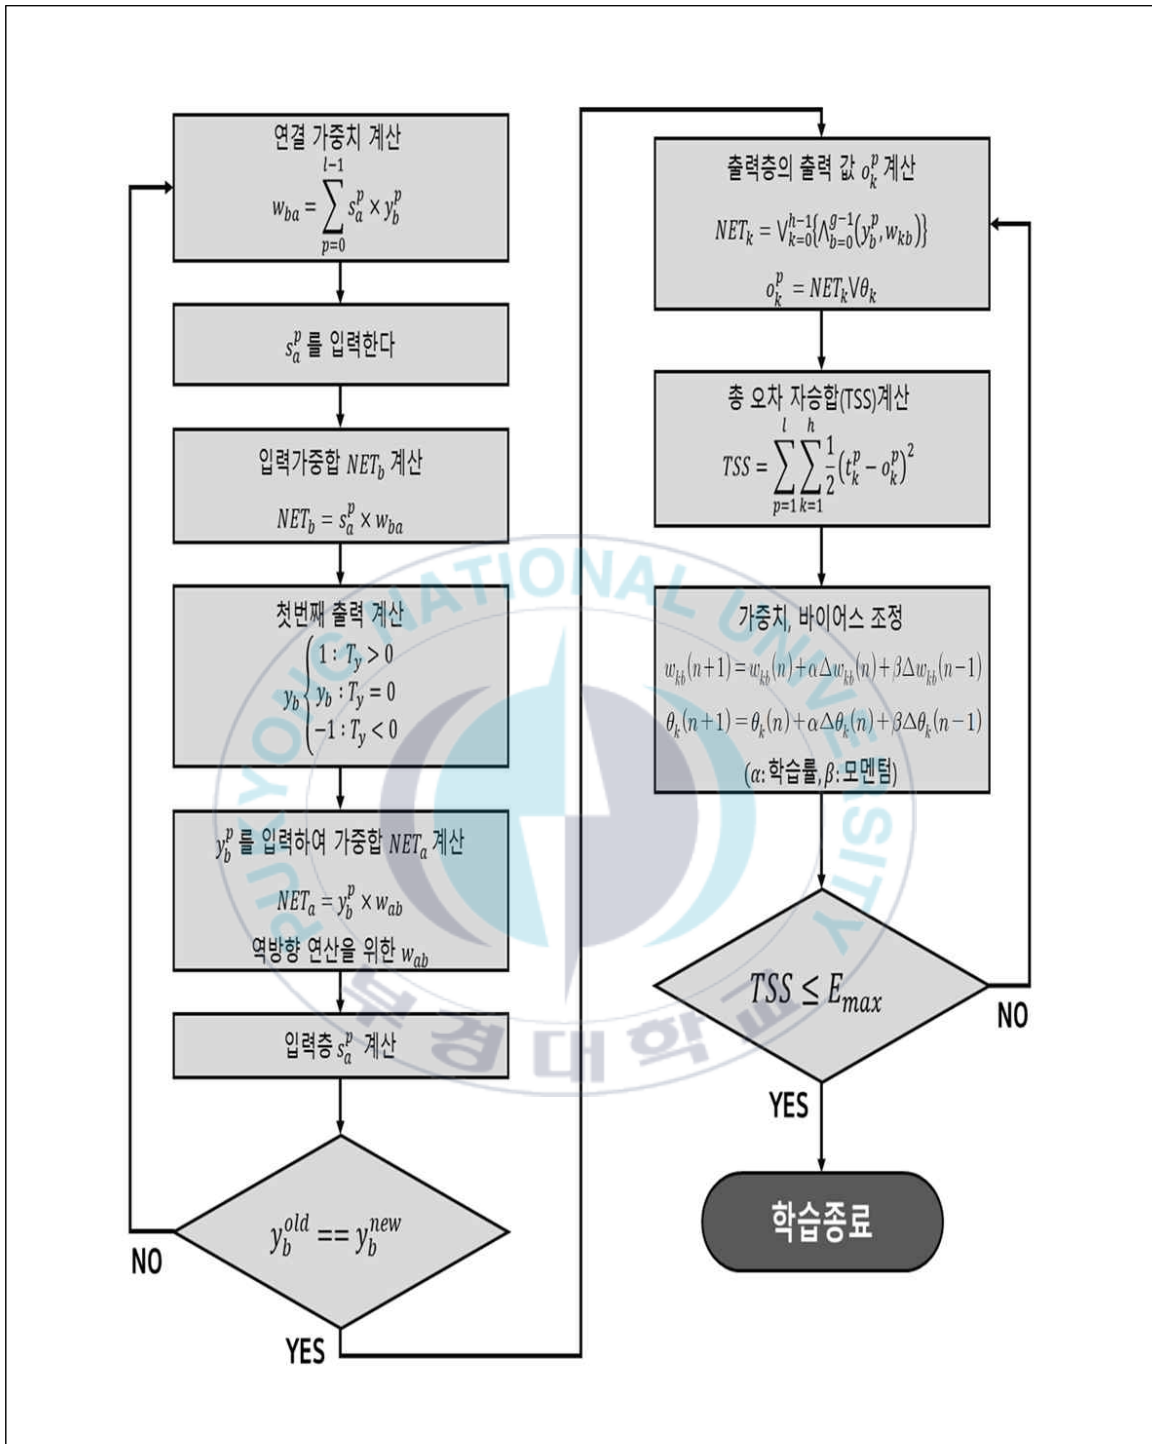


그림 3. 제안된 양방향 연산 메모리 기반 퍼지 지도 학습 과정 처리 구성도

IV. 실험 및 결과분석

4.1 제안된 학습방법의 개발환경

본 논문에서는 Intel(R) Core(TM) i7-8400의 CPU와 16GB RAM이 장착된 PC상에서 Visual Studio C#으로 구현하여 실험하였다. 본 논문에서는 제안된 학습 방법과 기존의 퍼지 지도 학습 방법 및 오류 역전파(Error Backpropagation) 알고리즘, 그리고 딥러닝 기법 중의 CNN과 인식 성능을 비교 분석하였다. 실험에서 사용된 패턴 영상은 그림 4와 같다. 제안된 학습 방법을 실험하기 위하여 구현한 화면은 그림 5와 같다.



그림 4. 원본 패턴 영상

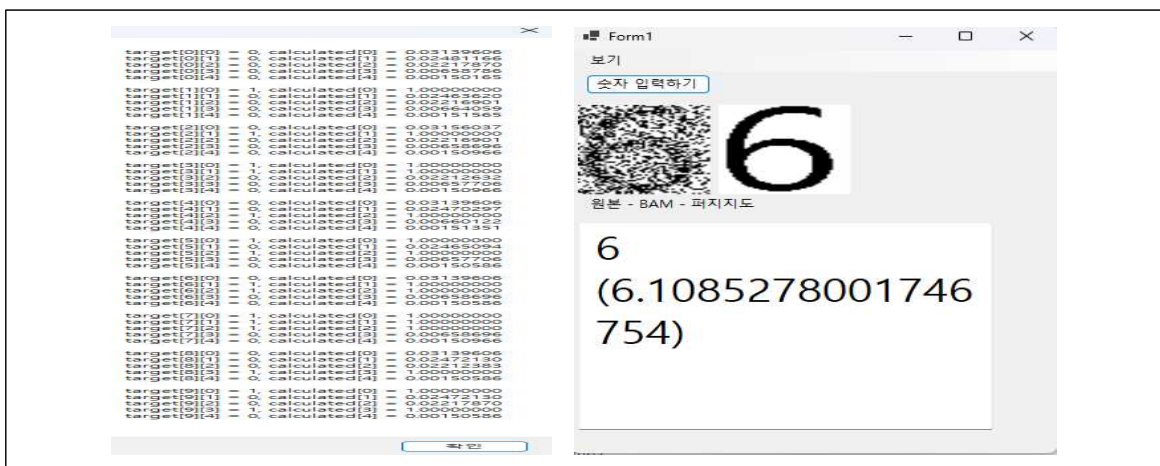


그림 5. 제안된 학습 방법을 구현한 학습 및 인식 화면

4.2 실험 결과 분석

그림 5와 같은 패턴 영상을 1과 -1로 학습 패턴을 구성하기 위하여 평균 이진화 기법을 적용하여 패턴 영상을 이진화 하였다. 표 2는 그림 4와 같은 패턴 영상을 각 학습 알고리즘에 적용하여 학습에 대한 반복 횟수와 총 오차 자승합을 나타낸 것이다.

학습 방법	Epoch 수	총 오차 자승합(TSS)
퍼지 지도 학습 알고리즘	128	0.009571
BP	14,989	0.004327
CNN	18,236	0.002793
제안된 학습 방법	392	0.001257

표 2. 각 학습 알고리즘에 대한 Epoch 수 및 TSS

표 2의 모든 학습 알고리즘에 대해서 오류 한계 값을 0.04로 설정하였다. 역전파 (BP: Backpropagation) 알고리즘에서는 은닉층의 노드 수를 3에서부터 5개로 각 설정하여 실험한 결과, 은닉층의 노드 수를 4개로 설정하는 것이 Epoch 수와 TSS가 적게 나타나서 표 1의 실험에서는 은닉층의 노드 수를 4개로 설정한 학습 결과이다. 표 3의 CNN에서는 학습 층의 수를 4개에서 6개로 설정하여 실험한 결과 학습 층에 따라 총 오차 자승합의 값이 거의 차이가 크지 않아 학습의 층의 수를 4개로 설정하여 실험한 결과이다.

제안된 학습 방법에서는 학습 층은 입력층, 연상 메모리층, 출력층과 같이 4개의 층으로 구성된다. 표 1에 알 수 있듯이 제안된 학습 방법이 학습 반복 횟수인 Epoch 수가 적고 총 오차 자승합 값도 적어서 학습에 대한 분류 성능이 우수한 것을 알 수 있다. 그 이유는 다른 학습 알고리즘과는 다르게 연상 메모리 층에서 각 패턴들의 특징을 복원하여 학습 패턴들을 정량화한 후에 출력층으로 전달되어 연결 가중치와 바이어스 항을 조정하므로 각 특징에 대한 분류 성능이 개선되어 총 오차 자승합이 다른 학습 알고리즘보다 적고 학습의 수렴성도 우수한 것을 표 2에서 확인할 수 있다.

원본 패턴 영상에서 소금과 후추 잡음을 임의적으로 전체 픽셀 중에서 10%을 적용한 결과 패턴은 그림 6과 같다.



그림 6. 소금과 후추 잡음

그림 6과 같이 임의적으로 전체 픽셀 중에서 10%와 20%를 소금 및 후추 잡음을 적용하여 10개의 패턴에 대해 각 5번씩 실험한 50개에 대한 각 알고리즘의 인식 결과는 표 2와 같다.

학습 방법	인식 결과(50개)	
	10% 잡음	20% 잡음
퍼지 지도 학습 알고리즘	50	48
BP	50	50
CNN	50	50
제안된 학습 방법	50	50

표 3. 소금과 후추 잡음 패턴에 대한 각 학습 알고리즘 인식 결과

표 3에서와 같이 소금과 후추 잡음을 10%와 20%를 적용하여 인식 실험에 적용한

결과이다. 표 3에서와 같이 퍼지 지도 학습 알고리즘만이 20% 잡음을 적용한 8패턴이 0 패턴으로 인식한 경우가 2번 발생하였다. 그 이유는 퍼지 지도 학습 알고리즘은 단층 학습 구조를 가지고 있기 때문이다. 20%의 잡음을 적용한 경우에는 0과 8의 특징이 중복되는 경우가 발생하고 단층 구조로 학습하기 때문에 결정 경계선을 기준으로 8의 특징이 손실되고 0의 특징이 추가적으로 발생하였기 때문이다. 그림 7은 가우시안 잡음을 수행한 패턴이다. 그림 7에서 알 수 있듯이 각 패턴들의 특징들이 많이 손실된 것을 알 수 있다.




그림 7. 가우시안 잡음 패턴

그림 4와 같은 10개의 원본 패턴에 그림 10과 같이 가우시안 잡음을 임의적으로 적용하여 각 5번씩 실험한 50개에 대한 각 알고리즘의 인식 결과는 표 3과 같다.

학습 방법	인식 결과 (50개)
퍼지 지도 학습 알고리즘	22
BP	42
CNN	47
제안된 학습 방법	50

표 4. 가우시안 잡음 패턴에 대한 각 학습 알고리즘 인식 결과

표 4에서 알 수 있듯이 제안된 방법이 가우시안 잡음을 임의로 5번 수행한 인식 실험에서 모두 인식하였다. 그러나 퍼지 지도 학습 알고리즘은 50개의 실험에서 22개만 인식하여 다른 학습 방법보다 인식 성능이 낮았다. 특히 가우시안 잡음을 적용한 1,2,3,8,5,6,9와 같은 패턴의 경우에는 각 패턴들의 특징들이 많이 손실되어 다른 패턴으로 인식하는 경우가 많았다. BP 알고리즘에서는 1,3,8,5,6,9의 패턴들이 다른 패턴으로 인식하는 경우가 발생하였다. 그 이유는 BP의 학습 구조는 완전 연결 구조를 가지고 있으므로 학습 과정에서 정체 현상이 발생하기 때문에 일부 패턴들의 특징이 다른 패턴들에 비해 특징이 부정확하게 분류되었기 때문이다.

또한 딥러닝 기법 중의 CNN은 패턴 이미지 데이터들의 특징을 추출하는 합성곱 계층(Convolution Layer)과 추출한 특징을 Sub-Sampling하는 풀링 계층으로 구성되고 합성곱 계층의 주요 역할은 이미지에 필터링 기법을 적용하여 이미지 분류를 보다 정확하게 할 수 있게 한다. 여기서 필터링 기법은 이미지의 테두리 부분을 추출과 영상의 명암 비를 처리한다. 본 논문에서는 풀링 계층에 적용되는 방법으로 Max Pooling 알고리즘을 적용하였다. 표 3에서와 같이 CNN이 오인식한 4개의 잡음이 있는 패턴은 5와 9이다.

그 원인은 CNN을 적용한 경우에는 학습을 진행하면서 특징 이미지의 크기가 줄어들어 특징 손실이 발생하였기 때문이다. 이렇게 학습된 상태에서 가우시안 잡음 패턴들을 인식할 경우에는 잡음이 있는 5와 9의 패턴에서 특징들 뿐만 아니라 잡음도 다수 포함되어 최종 출력층으로 출력 값을 계산하기 때문에 오인식되는 경우가 발생하였다.

기존의 영상 처리 기반 잡음을 제거하기 위한 방법으로 평균 마스크 기법과 중간값 필터링 기법이 있다[20][21]. 평균 마스크 기법은 가우시안 노이즈를 줄이는데 효과적이지만 임펄스 잡음에는 비효과적 영상의 대비를 약화시킨다. 중간값 필터링 기법은 임펄스 잡음을 제거하기에는 효과적이지만 경계선을 선명하게 할 수 없다. 따라서 비정량화된 패턴 영상에서 명암 대비가 낮거나 특징과 그 외의 영역 간의 명암도 차이가 적은 경우에는 평균 마스크 기법이나 중간값 필터링 기법을 적용할 경우에는 특징이 손실되는 경우가 발생한다.

따라서 특징이 손실된 상태에서 학습 알고리즘의 입력 패턴으로 적용할 경우에는 학습의 분류 성능이 낮아지거나 인식 과정에 인식률을 저하시키는 원인이 된다. 본 논문에서는 제안된 학습 방법의 우수성을 검증하기 위하여 제안된 학습 방법과 소금 및 후추 잡음을 수행한 패턴에 평균 마스크 기법 및 중간 값 필터링 기법을 각각 적용하여 잡음을 제거한 그림 9와 같은 패턴에 대해 퍼지 지도 학습 알고리즘, 오류 역전파 알고리즘, CNN을 적용한 인식 결과와 비교하여 표 5로 나타내었다.




그림 8. 소금 및 후추 잡음이 적용된 패턴에 대한 잡음이 제거된 패턴

학습 방법	인식 결과 (30개)	
	평균 마스크 기법	중간값 필터링 기법
퍼지 지도 학습 알고리즘	21	20
BP	27	26
CNN	27	27
제안된 학습 방법	30	30

표 5. 소금 및 후추 잡음 패턴에서 잡음을 제거한 후의 인식 결과

표 5에서와 같이 평균 마스크를 적용하여 잡음을 제거한 테스트 패턴에 대해서 퍼지 지도 학습 알고리즘은 그림 8(A)와 같이 9 패턴을 8 패턴으로 오인식하였다. 그리고 BP와 CNN에서도 6패턴을 8패턴으로 오인식 하였다. 중간값 필터링 기법을 적용하는 경우에는 퍼지 지도 학습 알고리즘에서는 9를 8로 오인식하였고 6을 0으로 오인식하였다. BP에서는 9를 8로 오인식하고 6도 8로 오인식하였다. CNN에서는 9를 8로 오인식하는 경우가 발생하였다.

그러나 제안된 방법에서는 평균 마스크와 중간값 필터링 기법을 각각 적용하여 패턴들의 일부 특징이 손실되어도 연상 메모리 층에서 복원되기 때문에 각 패턴들이 모두 인식되는 것을 표 5에서 확인할 수 있다. 따라서 제안된 방법은 잡음이나 일부 특징이 손실되는 경우에도 학습 패턴을 복원하여 학습에 적용하기 때문에 효율적으로 인식하는 것을 알 수 있다.

4.3 실험 고찰

패턴 인식이나 데이터 예측 문제에서 데이터 분석 기반의 인공지능 알고리즘을 적용하는 것이 중요하다. 그러나 대부분 국내 연구에서는 최신 발표된 딥러닝 기법만을 적용하기 때문에 데이터 특성에 적합하지 않은 인공지능 기술이 적용되는 경우가 대부분이다. 따라서 본 연구에서는 다양한 잡음이 존재하는 패턴들에서 잡음을 제거하고 패턴들의 특성을 복원하여 학습 하는 방법으로 양방향 연산 메모리 기반의 퍼지 지도 학습 방법을 제안하여 다양한 잡음이 있는 숫자 패턴 인식 실험에서 제안된 학습 방법이 오류 역전파, CNN등보다 우수한 인식 성능을 보였다. 일반적으로 잡음이 있는 패턴들을 잡음을 제거한 후에 정규화하여 학습 패턴으로 적용하고 있다. 그러나 잡음을 제거하는 과정에서 중요한 특징 일부분이 손실된 상태에서 정규화되기 때문에 패턴들 간의 특징들을 정확히 분류할 수 없는 문제점이 있다. 또한 딥러닝 기법 중에서 CNN 기법은 잡음이 많은 경우에는 학습 성능이 저하되는 경우가 발생하기 때문에 다양한 잡음이 있는 많은 패턴들을 학습 패턴으로 적용하는 경우가 대부분이다. 그러나 이 과정에서 오버피팅 (overfitting)이 발생하여 학습 패턴이 아닌 실제 테스트 패턴 인식 문제에서는 인식 성능이 저하되는 문제점이 발생한다. 따라서 본 논문에서는 잡음 패턴들을 정량화된 패턴으로 복원할 수 있는 방법으로 BAM 기법을 적용하여 다양한 잡음이 존재하여도 정량화된 패턴으로 모두 복원한 후에 퍼지 지도 학습 방법으로 정량화된 패턴들의 특징을 분류하도록 하였다. 따라서 정량화된 패턴만을 학습 패턴으로 적용하여 학습 하여도 인식 단계에서 다양한 잡음이 있어도 인식할 수 있는 장점이 있기 때문에 기존의 학습 방법보다 인식 성능이 우수하였다.

V. 결론 및 향후 연구

본 논문에서는 잡음이 포함되어 있어도 적은 학습 데이터로 효과적으로 특징을 분류하고 인식할 수 있는 양방향 연상 메모리 기반 퍼지 지도 학습 알고리즘을 제안하였다. 제안된 학습 구조에서는 입력층, 양방향 연상 메모리 2층과 출력층과 같이 4개의 층으로 구성하였다. 양방향 연상 메모리 층에서는 잡음이 있는 패턴들을 연상 메모리 학습 과정에서 잡음을 제거하고 특징을 복원하여 정량화 하였다. 정량화된 데이터를 출력층으로 전달하여 퍼지 지도 학습 알고리즘으로 학습하였다, 따라서 제안된 학습 방법에서는 적은 학습 데이터로 효율적으로 특징을 분류하였다, 제안된 학습 방법의 성능을 분석하기 위하여 기존의 퍼지 지도 학습 방법 및 오류 역전파(Error Backpropagation) 알고리즘, CNN과 인식 성능을 비교 분석하였다.

50개의 가우시안 잡음 패턴에 대해서 퍼지 지도 학습 알고리즘만 28개가 인식에 실패하였으며 오류 역전파 알고리즘에서는 8개, CNN에서는 3개가 인식에 실패하였으나 제안된 학습 방법에서는 모두 인식에 성공하였다. 30개의 소금 및 후추 잡음 패턴에 대해서도 기존의 학습 방법에서는 영상 처리 과정을 수행하여 잡음을 제거한 후에 학습 알고리즘에 적용하였고 제안된 학습 방법에서는 잡음 제거에 대한 영상 처리를 수행하지 않았다. 그 이유는 이질 연상 메모리 층에서 특징을 복원하는 과정에서 잡음 제거도 수행되었다. 이 실험에서도 CNN과 BP에서는 각각 3개와 4개 정도의 잡음이 있는 패턴들이 인식에 실패하였으나 제안된 학습 방법은 모두 인식에 성공하였다.

따라서 제안된 방법은 스마트 팩토리 분야 중에서 부품의 일련번호가 훼손된 경우 이거나 도로 표지판 등의 문자나 특징이 훼손된 경우 그리고 열악한 환경에서의 레미콘제조업체와 같이 덤프트럭 차량번호 단위 별 실물 입출력 중량을 자동계근을 해야 할 경우 흙탕물로 인해서 상당부분 뚜렷하지 않는 차량번호 인식 등에 효과적으로 특징을 복원하여 인식하는데 효율적으로 적용할 수 있다.

그러나 제안된 학습 방법은 숫자나 영문자와 같이 특징이 정량화 되어 있고 패턴의 종류가 적은 경우에는 효과적이지만 패턴의 종류가 많은 경우에는 이질 연상 메모리 층에서 특징을 복원할 수 없어 학습이 되지 않는 문제점이 발생한다.

따라서 향후 연구 방향은 특징이 비정량화되어 있고 특징들이 훼손된 경우에도 효과적으로 복원하여 인식할 수 있는 다층 구조 기반 퍼지 이질 연상 메모리 기법을 연구하여 다양하고 종류가 많은 객체들을 효과적으로 복원하여 인식할 수 있도록 할 계획이다.



참고문헌

- [1] K. B. Kim, "Damaged Traffic Sign Recognition using Hopfield Networks and Fuzzy Max-Min Neural Network", *Journal of the Korea Institute of Information and Communication Engineering*, Vol. 26, No.11, pp.1630~1636, Nov. 2022.
- [2] G. Kim, H. G. Jung, J. K. Suhr, "Improvement of Vehicle Position Estimation Using CNN-based Vehicle Bottom Face Center Detection", *Transactions of the Korean Society of Automotive Engineers*, Vol.30, No.7, pp.599-607, Jul. 2022.
- [3] N. Upasani and H. Om, "Optimized fuzzy min-max neural network: an efficient approach for supervised outlier detection", *Neural Network World*, Vol. 28, No. 4, pp. 285-303, Jan. 2018.
- [4] C. C. Guest, R. TeKolste, "Designs and devices for optical bidirectional associative memories", *Applied Optics*, Vol.26, pp.5055-5060, 1987.
- [5] A. Barra, G. Catania, A. Decelle, B. Seoane, "Thermodynamics of bidirectional associative memories", *Journal of Physics A: Mathematical and Theoretical*, Vol.56, No.20, pp.2050~2055, May, 2023.
- [6] T. Tanakay, S. Kakiyay, Y. Kabashima, "Capacity Analysis of Bidirectional Associative Memory",
Proceedings of Seventh Int. Conf. Neural Information Processing, vol.59, pp.17-20, Jun. 2002.
- [7] P.Singh, "Correlation coefficients for picture fuzzy sets" *Journal of Intelligent & Fuzzy Systems*,
Vol.28, No.2, pp.591-604, 2015.
- [8] S. Ashraf, S. Abdullah, T. Mahmood, F. Ghani, T. Mahmood, "Spherical fuzzy sets and their applications in multi-attribute decision making problems", *Journal of Intelligent & Fuzzy Systems*, Vol.36, No.3, pp.2829-2844, 2019.

[9] D. M. Rafi, C. R. Bharathi, “Optimal Fuzzy Min-Max Neural Network (FMMNN) for Medical Data

Classification Using Modified Group Search Optimizer Algorithm”, *International Journal of Intelligent*

Engineering and Systems, Vol.9, No.3, 2016.

[10] L. Li, Z. Qiao, Y. Liu, Y. Chen, “A convergent smoothing algorithm for training max - min fuzzy

neural networks”, *Neurocomputing*, Vol. 260, No.18 pp.404-410, October 2017.

[11] M. K. Bhuyan, D. P. Mohapatra, S. Sethi, “ Software Reliability Prediction using Fuzzy Min-Max

Algorithm and Recurrent Neural Network Approach”, *International Journal of Electrical and Computer*

Engineering, pp. 1929 - 1938 Vol.6, No.4, August 2016.

[12] S. Liu, W. Zhang, “Application of the Fuzzy Neural Network Algorithm in the Exploration of the

Agricultural Products E-Commerce Path”, *Intelligent Automation And Soft Computing*, Vol. 26, No.3,

pp.569 - 575, 2020.

[13] R. C. Gonzalez and R. E. Woods, “Digital Image Processing, 3rd ed”, *Upper Saddle River, NJ: Prentice Hall*, 2008.

[14] S. I. Kwon and N. H. Kim, “A Study on Modified Spatial Weighted Filter in Mixed Noise

Environments”, *Journal of Information and Communication Convergence Engineering*, vol. 19, no. 1, pp.

237-243, Jan. 2015.

[15] J. -H. Baek, N. -H. Kim, “ Noise Removal Method using Entropy in

High-Density Noise

Environments”, *Journal of the Korea Institute of Information and Communication Engineering*, Vol.24,

No.10, pp.1255-1261, Oct. 2020.

[16] L. Fiedler, S. A. Tirdad, G. Carina, A. Emina; L. Thomas, W. Dorothea, “Hearing Aid Noise

Reduction Lowers the Sustained Listening Effort During Continuous Speech in Noise– A Combined

Pupillometry and EEG Study”, *Ear and Hearing* Vol.42, No.6, pp.1590-1601, November/December, 2021.

[17] A. Lekbir, H. Aissam, L. Amine, N. Mourad, “A non-convex denoising model for impulse and Gaussian noise mixture removing using bi-level parameter identification,” *Inverse Problems and Imaging*, Vol.16, Issue 4, pp.827-870, 2022.

[18] H. Chen, D. L. Fan, L. Fang, W. Huang, J. Huang, C. Cao, L. Yang, Y. He, L. Zeng, “Particle Swarm

Optimization Algorithm with Mutation Operator for Particle Filter Noise Reduction in Mechanical Fault Diagnosis”, *International Journal of Pattern Recognition and Artificial Intelligence*, Vol.34, No.10,

2058012, 2020.

[19] Z. Hou, T. Xu, Z. Zhang, K. Sun, “Case study: Numerical study of the noise reduction characteristics

of corrugated perforated pipe mufflers”, *Noise Control Engineering Journal*, Vol.70, No.1, pp. 16-36, January 2022.

[20] P. V. C. Souza, “Regularized Fuzzy Neural Networks for Pattern Classification Problems”,

International Journal of Applied Engineering Research, Vol.13, No.5 pp. pp.2985-2991, 2018.

[21] Q. Liu, M. Zeng, “Network security situation detection of internet of things for smart city based on

fuzzy neural network”, *International Journal of Reasoning-based Intelligent Systems*, Vol.12, No.3,

pp222-227, September, 2020.

