

# 영상 인식을 위한 생리학적 퍼지 단층 학습 알고리즘

## Physiological Fuzzy Single Layer Learning Algorithm for Image Recognition

김영주 · 김광백

Young-Ju Kim and Kwang-Baek Kim

신라대학교 컴퓨터정보공학부

### 요 약

본 논문은 기존의 퍼지 단층 퍼셉트론 알고리즘의 학습 시간과 수렴성을 개선하기 위해 인간 신경계의 생리학적 뉴런 구조를 분석하여 퍼지 논리를 이용한 새로운 뉴런 구조를 제시하고, 이를 바탕으로 생리학적 퍼지 단층 퍼셉트론(P-FSLP: Physiological Fuzzy Single Layer Perceptron)에 대한 학습 모형과 학습 알고리즘을 제안한다. 제안된 학습 알고리즘의 성능을 평가하기 위해 Exclusive OR 문제, 3-bit parity 문제 그리고 차량 번호판 인식 문제 등에 적용하여 기존의 퍼지 단층 퍼셉트론 알고리즘과 성능을 비교, 분석하였다. 실험 결과에서는 제안된 학습 알고리즘(P-FSLP)이 기존의 퍼지 단층 학습 알고리즘보다 지역 최소화에 빠질 가능성이 감소하였으며 학습 시간과 수렴성도 개선되었을 뿐만 아니라, 영상 인식 등에 대한 응용 가능성도 제시되었다.

### Abstract

In this paper, a new fuzzy single layer learning algorithm is proposed, which shows more improved learning time and convergence property than that of the conventional fuzzy single layer perceptron algorithms. First, we investigate the structure of physiological neurons of the nervous system and propose new neuron structures based on fuzzy logic. And by using the proposed fuzzy neuron structures, the model and learning algorithm of Physiological Fuzzy Single Layer Perceptron(P-FSLP) are proposed. For the evaluation of performance of the P-FSLP algorithm, we applied the conventional fuzzy single layer perceptron algorithms and the P-FSLP algorithm to three experiments including Exclusive OR problem, the 3-bit parity bit problem and the recognition of car licence plates, which is an application of image recognition, and evaluated the performance of the algorithms. The experimentation results showed that the proposed P-FSLP algorithm reduces the possibility of local minima more than the conventional fuzzy single layer perceptrons do, and enhances the time and convergence for learning. Furthermore, we found that the P-FSLP algorithm has the great capability for image recognition applications.

**Key Words:** 생리학적 뉴런 구조, 생리학적 퍼지 단층 퍼셉트론, 영상 인식

### 1. 서 론

기존의 단층 퍼셉트론(SLP: Single Layer Perceptron)은 입력 패턴에 대한 분류 결정 경계선이 초기하평면(hyperplane)으로만 구성되어 있지 않으면 패턴을 분류하지 못한다. 그 대표적인 예가 Exclusive OR 문제로서 초기하평면만으로는 입력 패턴들을 두 부류로 분리하는 것이 불가능하므로 단층 구조를 가진 퍼셉트론으로는 해결할 수 없다[1, 2]. 그러나 Wang이 제안한 퍼지 단층 퍼셉트론(FSLP: Fuzzy Single Layer Perceptron)은 퍼지 귀속 함수(fuzzy membership function)를 사용하여 안전성을 보장하면서 Exclusive OR 문제와 같은 고전적인 비선형 문제를 해결하였다[3, 4].

퍼지 단층 퍼셉트론(FSLP) 알고리즘은 기존의 단층 퍼셉트론과 마찬가지로 결정 경계선이 진동하는 경우가 생기며,

초기 연결 가중치의 범위와 학습률에 따라 수렴성이 낮아지므로 영상 인식 응용 등에 적용할 경우 계산량이 증가되고 수렴성이 떨어진다. 이러한 문제점은 역치값(Threshold)을 고정하고 각 패턴들을 학습시킴으로써 부적절한 역치값에 의해 각 패턴들의 결정 경계선이 부정확하게 분류되기 때문에 발생한다. 이에 학습률과 바이어스 항을 동적으로 변화시켜 결정 경계선이 진동하는 것을 방지하고 수렴성을 향상시킨 개선된 퍼지 단층 퍼셉트론(E-FSLP: Enhanced Fuzzy Single Layer Perceptron)이 제안되었다[5]. 그러나 이 방법은 영상 인식에 적용할 경우에 입력 데이터를 정렬하는 과정에서 많은 시간이 소요되며, 정렬 과정에서 입력 벡터들의 위치가 변경되어 입력 패턴들의 크기는 같고 목표값이 다른 경우에는 특징들을 분류할 수 없게 된다[6].

본 논문에서는 기존의 퍼지 단층 퍼셉트론 알고리즘으로는 해결하기 어려웠거나 계산 부하가 많이 발생하는 영상 인식 문제 등에 대해 효과적으로 적용할 수 있는 새로운 “생리학적 퍼지 단층 퍼셉트론(P-FSLP: Physiological Fuzzy Single Layer Perceptron)” 알고리즘을 제안한다. 먼저 기존

접수일자 : 2001년 5월 21일

완료일자 : 2001년 9월 11일

의 단층 퍼셉트론과 신경계의 생리학적 뉴런에 대해 구조 및 기능을 비교, 분석하여 퍼지 논리를 적용한 새로운 뉴런 구조를 제안하는데, 제안된 뉴런 구조는 퍼지 논리합에 의한 흥분 뉴런 구조, 퍼지 논리곱에 의한 전방향 억제 뉴런 구조, 그리고 퍼지 논리 부정에 의한 역방향 억제 개재 뉴런 구조로 표현된다. 그리고 새로운 생리학적 퍼지 뉴런 구조 기반의 생리학적 퍼지 단층 학습 알고리즘을 제안하고, 고전적인 비선형 문제와 차량 번호판 인식 등의 영상 인식 문제 등에 적용하여 성능을 평가한다.

본 논문의 구성은 다음과 같다. 먼저 2장에서 기존의 퍼지 단층 퍼셉트론 알고리즘에 대해 살펴보고, 3장에서 생리학적 퍼지 뉴런 구조 및 생리학적 퍼지 단층 퍼셉트론 알고리즘을 제안한다. 그리고 4장에서 Exclusive OR 문제, 3-bit parity 문제 그리고 자동차 번호판 인식 응용 등에 기존의 퍼지 단층 퍼셉트론과 제안된 생리학적 퍼지 단층 퍼셉트론 알고리즘들을 적용하여 성능을 비교, 평가하고 5장에서 결론 및 향후 연구로 마무리한다.

## 2. 기존의 퍼지 단층 퍼셉트론

인공 신경망의 단층 퍼셉트론이 해결하지 못한 Exclusive OR와 같은 비선형 문제를 해결하기 위하여 Wang의 퍼지 단층 퍼셉트론(FSLP)[3]과 Kim의 개선된 퍼지 단층 퍼셉트론(E-FSLP)[5]가 제안되었다. 제안된 퍼지 단층 퍼셉트론 알고리즘들은 영상 인식 문제에 적용할 경우 높은 계산량과 낮은 수렴성 문제가 발생한다.

### 2.1 Wang의 퍼지 단층 퍼셉트론

Wang은 일반화된 델타 규칙에 기반한 퍼지 단층 퍼셉트론(FSLP: Fuzzy Single Layer Perceptron)을 제안하였다[3]. 퍼지 단층 퍼셉트론은 퍼지 귀속 함수를 사용하여 데이터 적용에 대해 어느 정도 수렴을 보장하지만, 영상 인식에 적용할 경우에 단층 퍼셉트론과 마찬가지로 결정 경계선이 진동하는 경우가 생기며 초기 연결 가중치의 범위와 학습률에 따라서 수렴성이 낮아지고 계산량이 많아진다. 그리고 입력 패턴의 크기가 같을 경우 학습 후에 인식 과정에서 인식이 저하된다.

### 2.2 개선된 퍼지 단층 퍼셉트론

Wang의 퍼지 단층 퍼셉트론의 문제점을 해결하기 위하여 학습률과 모멘텀 개념을 도입하여 분류의 정확성을 높이고, 바이어스 항을 적용함으로써 결정 경계선이 진동하는 것을 방지하고 수렴성을 향상시키는 개선된 퍼지 단층 퍼셉트론(E-FSLP: Enhanced Fuzzy Single Layer Perceptron)이 제안되었다[5].

개선된 퍼지 단층 퍼셉트론(E-FSLP)은 전방향 단계인 출력값을 계산할 때에 입력값을 퍼지 단층 퍼셉트론(FSLP)과 같이 정렬하여 정렬된 입력값과 가중치에 이용하여 계산한다. 그리고 제안된 선형 활성화 함수를 사용하여 수렴성을 향상시키고 바이어스 항을 추가하여 부적절한 역치값에 의해서 각 패턴들의 결정 경계선이 진동하는 것을 방지하였으며, 학습 속도가 느려지는 경우를 방지하기 위해 학습률과 모멘텀을 오류값에 따라 동적으로 변화시켰다. 그러나 영상 인식 문제에 적용할 경우 Wang의 퍼지 단층 퍼셉트론과 같이 정렬하는 과정에서 학습 시간이 많이 소요되며 서로 다른 영상들의 특징들이 중첩되는 경우가 발생할 때에 수렴이 되지 않

는 경우가 발생하거나 인식이 낮아지는 단점이 있다.

## 3. 생리학적 퍼지 단층 퍼셉트론 (P-FSLP: Physiological Fuzzy Single Layer Perceptron)

### 3.1 생리학적 뉴런 구조

인간 신경망의 생리학적 구조는 흥분 뉴런과 억제 뉴런으로 구성된다[7, 8]. 이들 뉴런들의 생리학적 특성에 대해 구체적으로 살펴보면 주동근 뉴런(antagonistic neuron)은 같은 방향으로 뉴런들을 흥분시켜서 활성화 뉴런으로 동작하게 하고, 억제 뉴런은 전방향 억제 뉴런(feed-forward inhibition neuron)과 역방향 억제 뉴런(feedback inhibition neuron)으로 구분된다. 전방향 억제 뉴런은 억제성 시냅스를 생성하여 전에 흥분된 일이 없어도 억제시키는 뉴런이며, 역방향 억제 뉴런은 자신을 활성화시킨 세포에 작용하여 억제시키는 억제성 개재 뉴런(inhibitory interneuron)을 의미한다. 흥분 뉴런과 억제 뉴런 구조는 그림 1과 같이 나타낼 수 있다[8, 9].

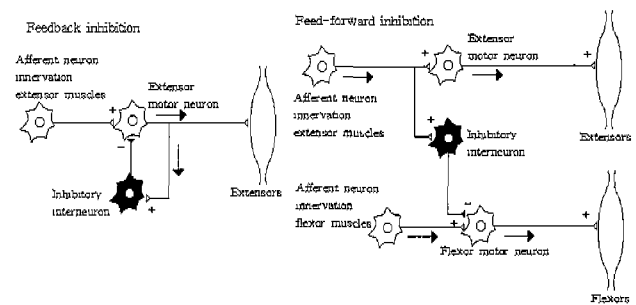


그림 1. 생리학적 뉴런 구조

Fig. 1. The structure of Physiological Neurons

기존의 인공 신경망에서는 시냅스를 흥분성 시냅스와 억제성 시냅스로 분류하고 단순히 연결 가중치 형태로 표현하는 반면, 그림 1에서 제시된 것과 같이 전방향 흥분성, 전방향 억제성, 그리고 역방향 억제성 등 시냅스의 다양한 정보 전달 기능에 대해서는 고려하지 않는다. 따라서 본 논문은 그림 1에서 제시된 시냅스의 다양한 기능에 대해 퍼지 논리 연산을 이용한 뉴런 구조로 제시하고, 이를 바탕으로 영상 인식 등에 적용할 수 있는 새로운 퍼지 단층 학습 모델을 제시한다.

### 3.2 퍼지 논리를 이용한 뉴런 구조

본 논문에서는 생리학적 뉴런의 특성을 표현하기 위해 퍼지 논리를 적용하는데 전형적인 퍼지 논리 연산자인 t-co-norm과 t-norm 중에 최대, 최소로 표현하는 퍼지 논리합과 퍼지 논리곱 등의 연산자를 사용한다[10]. 본 논문은 생리학적 뉴런의 구조 및 기능적인 특성을 분석하고 퍼지 논리를 이용하여 이를 표현한 새로운 퍼지 뉴런 구조를 제안한다.

#### 3.2.1 퍼지 논리합을 의한 흥분 뉴런 구조

흥분 뉴런에 해당하는 주동근 뉴런은 전방향으로 뉴런들을 흥분시켜 활성화 뉴런으로 동작하게 하므로 n 개의 입력 뉴런을 가진 흥분 뉴런은 그림 2와 같이  $\mu_1(x_1) \vee \dots \vee \mu_n(x_n)$

$= \text{Max}\{\mu_1(x_1), \dots, \mu_n(x_n)\}$ 인 퍼지 논리합 연산자를 이용한 뉴런 구조로 표현할 수 있다. 그림 2에서 퍼지 귀속 함수 (fuzzy membership function)  $\mu_i(x_i)$ 는 퍼지 집합에서 귀속도(membership degree)를 계산하는 함수로서 입력값과 연결 가중치의 곱,  $x_i \times w_i$  로 정의하며, 소마(입력) 값(즉,  $x_1, \dots, x_n$ )이 0과 1 사이의 실수 값이므로 소마와 시냅스 간의 관계를 나타낸다. 흥분 뉴런의 출력값은 입력된 귀속 함수값들 중에 최대값으로 주어지므로 전방향으로 계속하여 전달될수록 뉴런들이 흥분되어 활성화된다.

**3.2.2 퍼지 논리곱에 의한 전방향 억제 뉴런 구조**

흥분 뉴런과 같이 전방향 억제 뉴런도 소마(입력) 값과 연결 가중치의 곱에 의해서 출력 뉴런  $F$ 로 전달되며, 시냅스에 해당하는 연결 가중치는 억제 기능을 가지므로 1을 입력 뉴런의 개수로 나눈 값이 된다. 따라서  $n$  개의 입력 뉴런을 갖는 전방향 억제 뉴런 구조는 그림 3과 같이  $\mu_1(x_1) \wedge \dots \wedge \mu_n(x_n) = \text{Min}\{\mu_1(x_1), \dots, \mu_n(x_n)\}$ 인 퍼지 논리곱 연산자를 이용한 뉴런 구조로 표현할 수 있다. 퍼지 귀속 함수  $\mu_i(x_i)$ 은 입력값과 연결 가중치의 곱인  $x_i \times w_i$  이고, 퍼지 논리곱에 의한 전방향 억제 뉴런의 출력값은 전달되는 퍼지 귀속 함수 값들 중에 최소값으로 주어지므로 전방향으로 계속하여 전방향 억제 뉴런이 동작하면 자극이 억제되어 비활성화 된다.

**3.2.3 논리 부정에 의한 역방향 억제 개재 뉴런 구조**

$$S = \text{Max}\{\mu_1(x_1), \dots, \mu_n(x_n)\}$$




그림 2. 퍼지 논리합에 의한 흥분 뉴런 구조

Fig. 2. The structure of an excitation neuron by fuzzy logic sum operator

$$F = \text{Min}\{\mu_1(x_1), \dots, \mu_n(x_n)\}$$




그림 3. 퍼지 논리곱에 의한 전방향 억제 뉴런 구조

Fig. 3. The structure of a feed-forward inhibition neuron by fuzzy logic product operator




그림 4. 퍼지 논리 부정에 의한 역방향 억제 개재 뉴런  
Fig. 4. The structure of a feedback inhibitory interneuron by fuzzy logic negation operator

역방향 억제 뉴런은 억제성 개재 뉴런이 자신을 활성화시킨 세포에 작용하여 억제시키는 뉴런이므로 개재 뉴런 (interneuron)과 뉴런 사이의 관계에 의해 표현할 수 있고, 이들 사이의 관계를 수식으로 표현하면 식 (1)과 같이 정의할 수 있다.

$$S \times W_0 + P \times W = \bar{P} \tag{1}$$

S : 개재 뉴런,  $W_0$  : 개재 뉴런 가중치 1  
P : 뉴런,  $W$  : 뉴런 가중치 -1

식 (1)은 퍼지 논리 부정 연산자를 의미하므로 역방향 억제 개재 뉴런을 그림 4와 같이 나타낼 수 있다. 퍼지 논리 부정에 의한 뉴런 구조에서 최대값은 1 이상이 될 수 없고 최소값은 0 이하가 될 수 없으므로  $0 \leq (p + \bar{p}) \leq 1$ 이 되어야 한다. 따라서 뉴런의 출력값이 전방향으로 계속 전달되어 뉴런의 출력값이 1을 초과할 때에는 역방향 억제 뉴런이 동작하여 억제시키게 된다.

**3.3 새로운 생리학적 퍼지 단층 학습 알고리즘**

본 논문은 앞 절에서 제시한 퍼지 논리에 의한 뉴런 구조를 기반으로 새로운 생리학적 퍼지 단층 퍼셉트론(P-FSLP: Physiological Fuzzy Single Layer Perceptron) 알고리즘을 제안한다. 제안된 생리학적 퍼지 단층 퍼셉트론(P-FSLP) 알고리즘은 기존의 단층 퍼셉트론(SLP)과 Wang의 퍼지 단층 퍼셉트론(FSLP) 알고리즘 보다는 학습 수렴성과 학습 시간을 개선하고 향상된 인식률을 제공함으로써 Exclusive OR 문제, n-bit Parity 문제, 그리고 차량 번호판 인식과 같은 실세계 영상 인식 문제 등에 적용할 수 있다.

우선 생리학적 퍼지 뉴런 구조에 기반한 생리학적 퍼지 단층 퍼셉트론 모형을 제시하고, 이 모형에서 수행하는 생리학적 퍼지 단층 학습 알고리즘을 제안한다.

**3.3.1 생리학적 퍼지 단층 퍼셉트론(P-FSLP)**

본 논문에서 제안하는 생리학적 퍼지 단층 퍼셉트론(P-FSLP) 모형은 그림 5와 같이 생리학적 퍼지 뉴런 구조를 기반으로 하여 입력층, 퍼지 귀속 시냅스(Fuzzy Membership Synapse) 및 출력층으로 구성되며 지도 학습(supervised learning)으로 동작된다. 퍼지 귀속 시냅스는 퍼지 논리합에 의한 흥분 뉴런 구조로 표현되는 흥분성 시냅스, 퍼지 논리곱에 의한 전방향 억제 뉴런 구조로 표현되는 전방향 억제성 시냅스, 퍼지 논리 부정에 의한 역방향 억제 개재 뉴런 구조로 표현되는 역방향 억제성 시냅스 등으로 구성된다.

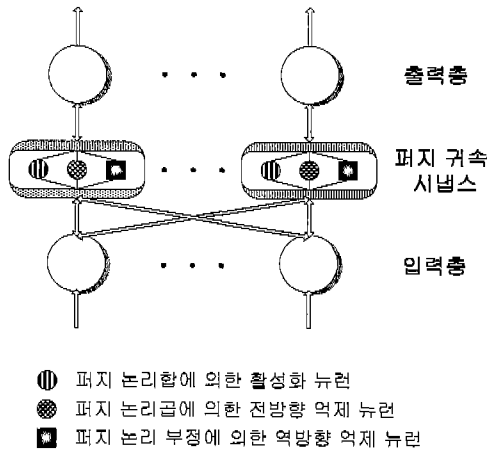


그림 5. 제안된 생리학적 퍼지 단층 퍼셉트론(P-FSLP) 모형  
Fig. 5. The model of Physiological Fuzzy Single Layer Perceptron(P-FSLP)

생리학적 퍼지 단층 퍼셉트론은 입력층에서 입력값이 전달되면 퍼지 귀속 시냅스에서 전방향 흥분성 시냅스와 전방향 억제성 시냅스가 동작하게 되며, 이 과정에서 입력층과 퍼지 귀속 시냅스간의 연결 가중치를 이용한 퍼지 귀속 함수값, 즉 퍼지 귀속 정도를 계산하고, 계산 결과가 1을 초과하는 경우에는 역방향 억제성 시냅스가 동작하게 된다. 퍼지 귀속 시냅스는 퍼지 귀속 함수값을 이용하여 목표값에 따라 출력값을 계산하며 목표값과 출력값의 차이가 있으면 입력층과 출력층 사이의 연결 가중치를 조정하게 된다.

### 3.3.2 생리학적 퍼지 단층 학습 알고리즘

생리학적 퍼지 단층 알고리즘의 학습 단계는 전방향 단계와 역방향 단계로 구분된다. 전방향 단계에서는 입력값, 퍼지 귀속 시냅스 그리고 입력층과 출력층 사이의 연결 가중치에 의해 퍼지 귀속 정도가 계산된다. 그리고 실제 출력 값은 목표값에 따라 활성화와 비활성화 뉴런 여부를 결정하여 퍼지 논리 연산자인 Max와 Min 연산자를 이용한다. 역방향 단계에서는 실제 출력값을 목표값과 비교하여 입력층과 출력층 사이의 연결 가중치를 조정한다. 새로운 생리학적 퍼지 단층 학습 알고리즘은 다음과 같다.

**알고리즘 : 생리학적 퍼지 단층 학습 알고리즘**

입력 :  $x_i^p = (x_0^p, \dots, x_{n-1}^p)$

출력 :  $o_j = (o_0, \dots, o_{m-1})$

단계 1. 입력 패턴 ( $x_i^p$ )과 목표 패턴 ( $t_j^p$ )을 제시한다.

단계 2. 입력층과 출력층 사이의 연결 가중치 ( $W_{AND_n}, W_{OR_n}, W_{NT_n}$ ), 퍼지 귀속 시냅스 내의 연결 가중치 ( $V_{AND_n}, V_{OR_n}, V_{NT_n}$ ), 그리고 목표값에 따른 뉴런의 활성화 및 비활성화 여부를 구분하는 정보 ( $ON_{AND_n}^p, ON_{OR_n}^p, ON_{NT_n}^p$ )을 다음과 같이 초기화한다.

· Logic\_weight :  $W_{AND_n} = 1, W_{OR_n} = 1, W_{NT_n} = 1$

· Fuzzy\_membership\_weight :

$$V_{AND_n} = \frac{1}{I}, V_{OR_n} = 1, V_{NT_n} = -1$$

· Logic\_mark :

$$ON_{AND_n}^p = 1, ON_{OR_n}^p = 1, ON_{NT_n}^p = 1$$

단계 3. 퍼지 귀속 시냅스를 구성하는 뉴런 ( $Synapse_{ji}$ )들을 이용하여 퍼지 귀속 정도를 계산하고 0과 1 사이의 값으로 정규화한다.

$$Synapse_{ji} = (ON_{AND_n}^p \times x_i^p \times V_{AND_n} \times W_{AND_n}) + (ON_{OR_n}^p \times x_i^p \times V_{OR_n} \times W_{OR_n})$$

$$If (Synapse_{ji} > 1.0) Synapse_{ji} = Synapse_{ji} + V_{NT_n}$$

단계 4. 목표값 ( $t_j^p$ )에 따라 퍼지 논리 연산자 Max와 Min을 사용하여 출력값 ( $o_j$ )을 계산한다.

$$If (t_j^p \geq 0.5)$$

$$o_j = (Synapse_{j0} \vee, \dots, \vee Synapse_{j_{m-1}})$$

$$If (t_j^p < 0.5)$$

$$o_j = (Synapse_{j0} \wedge, \dots, \wedge Synapse_{j_{m-1}})$$

여기서,  $p$ 는 제시되는 패턴들의 수,  $\vee$ 는 퍼지 Max 논리 연산자이며  $\wedge$ 는 퍼지 Min 논리 연산자이다.

단계 5. 입력층과 출력층 사이의 연결 가중치들 ( $W_{AND_n}, W_{OR_n}$ )들을 조정한다.

$$e_j = t_j^p - o_j$$

$$If ((W_{AND_n} \leq 1.0) \text{ and } (ON_{AND_n}^p = 1))$$

$$W_{AND_n} = W_{AND_n} + \alpha \times e_j \times \frac{(x_i^p \times W_{AND_n})}{x_i^p}, ON_{AND_n}^p = 1$$

$$If ((W_{AND_n} > 1.0)$$

$$W_{AND_n} = W_{AND_n} - 1.0, ON_{AND_n}^p = 0$$

$$If ((W_{OR_n} \leq 1.0) \text{ and } (ON_{OR_n}^p = 1))$$

$$W_{OR_n} = W_{OR_n} + \beta \times e_j \times \frac{(x_i^p \times W_{OR_n})}{x_i^p},$$

$$ON_{OR_n}^p = 0$$

$$If (W_{OR_n} > 1.0) W_{OR_n} = W_{OR_n} - 1.0, ON_{OR_n}^p = 1$$

여기서, 학습률  $\alpha$ 는 0과 1 사이의 값을 가진다.

단계 6. 한 패턴에 대한 모든 목표 패턴들이 학습될 때까지 단계 3으로 가서 반복한다.

단계 7. 모든 패턴들의 총오차 자승합이 오류 한계보다 작을 때까지 단계 2로 가서 반복한다.

## 4. 실험 및 성능 분석

제안된 생리학적 퍼지 단층 퍼셉트론(P-FSLP)에 대한 성능 분석은 인공 신경망에서 벤치마크 테스트로 많이 사용되는 Exclusive OR 문제와 n-bit Parity 문제, 그리고 실제 영상 인식 문제인 차량 번호판 인식 등에 적용하여 성능을 평가하였다.

성능 분석 실험은 IBM 호환 586 Pentium 컴퓨터에서 Delphi 5.0 언어로 구현하여 실험하였으며, 각각의 실험 문제에 대해 Wang의 퍼지 단층 퍼셉트론(FLSP), 참고 문헌 [5]에서 제안된 개선된 퍼지 단층 퍼셉트론(E-FSLP) 알고리즘, 그리고 본 논문에서 제안한 알고리즘(P-FSLP)의 학습 반복

횟수와 수렴성 등을 비교 및 분석하였다.

4.1 Exclusive OR 문제

인공 신경망에서 Exclusive OR 문제가 벤치마크로 사용되는 이유는 비선형 문제 해결을 요구하는 기본 문제로서 기존의 단층 퍼셉트론으로는 해결할 수 없기 때문이다. 이러한 Exclusive OR 문제를 해결한 단층 구조의 신경망 알고리즘인 FSLP, E-FSLP 그리고 P-FSLP에 대해 학습 반복 횟수와 수렴률을 비교한 결과는 표 1, 표 2와 같다.

표 1에서는 초기 연결 가중치의 범위를 [0, 1]에서 임의의 값으로 설정한 후의 학습 수렴성을 비교한 결과를 제시하였는데, 각각의 알고리즘에 대해 학습률을 0.5로 설정하고 모멘텀을 0.9로 설정하여 학습하였으며, 학습 반복 횟수인 Epoch 수는 10번의 학습을 통해 얻은 값들의 평균치이다.

그리고, 표 2에서는 초기 학습률의 설정에 따른 각각의 알고리즘들의 Epoch 수와 수렴률 변화를 비교하여 제시하였다. 제시된 실험 결과를 통해 기존의 단층 퍼셉트론 알고리즘보다 제안된 P-FSLP 알고리즘이 학습률 등과 같은 변수에 별로 민감하지 않는 것을 알 수 있다., 표 2에서 알 수 있듯이 Wang의 FSLP은 XOR 문제에 대해 수렴성이 어느 정도의 안정성이 있으나 학습률에 의해 크게 영향을 받는다[5]. 제안된 P-FSLP 알고리즘은 초기 연결 가중치에 따른 수렴성 저하를 방지하였기 때문에 학습 수렴성이 보장될 뿐만 아니라, 연결 가중치를 목표값에 따라 변화시켜가며 조정하므로 지역 최소화 문제를 해결할 수 있다. 그리고 Wang의 FSLP와 참고 문헌 [5]의 E-FSLP 알고리즘보다는 입력값을

표 1. XOR 문제에서 퍼지 단층 학습 알고리즘 간의 Epoch 수와 수렴률 비교

Table 1. The Comparison of the number of Epoch and the convergence rate between fuzzy single layer learning algorithms in the XOR problem

Exclusive OR 문제	Epoch 수	수렴률
Wang의 퍼지 단층 퍼셉트론(FSLP)	8	90%
참고문헌 [5]의 방법(E-FSLP)	4	99%
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	4	100%

정렬하는데 소요되는 시간이 필요 없으므로 학습 시간이 적게 소요된다.

4.2 3-bit Parity 문제

3-bit Parity 문제는 Minsky와 Papert의 연구 중에 많이 제시되는 문제 중의 하나로서, 입력 패턴이 홀수 개의 1을 가지면 출력값으로 1을, 짝수 개의 1을 가지면 출력값으로 0을 요구하는 문제이다. 이 문제는 가장 비슷한 패턴들(하나의 값만 틀린 패턴들)이 다른 출력값을 요구하기 때문에 매우 어려운 문제이다. Exclusive OR 문제에 대한 실험과 마찬가지로 3-bit Parity 문제에 대해 기존의 퍼지 단층 퍼셉트론 알고리즘들과 제안된 퍼지 단층 퍼셉트론 알고리즘 간의 학습 반복 횟수와 수렴률을 비교한 결과는 표 3, 표 4와 같다.

표 3은 초기 연결 가중치에 대한 범위, 학습률, 그리고 모멘텀 등의 실험 파라미터를 Exclusive OR 문제에서 사용했던 값으로 적용하여 나온 실험 결과를 비교한 것인데, 제안된 P-FSLP 알고리즘이 기존의 두 알고리즘보다 적은 학습

시간과 높은 학습 수렴성을 보임을 알 수 있다.

표 2. XOR 문제에서 학습률 설정에 따른 퍼지 단층 학습 알고리즘 간의 Epoch 수와 수렴률 비교

Table 2. The Comparison of the number of Epoch and the convergence rate between fuzzy single layer learning algorithms according to the range of learning rate in the XOR problem

학습 알고리즘	학습률 범위	Epoch 수	수렴성
Wang의 퍼지 단층 퍼셉트론(FSLP)	[0.0, 0.49]	11	93%
	[0.5, 1.0]	7	90%
참고문헌 [5]의 방법(E-FSLP)	[0.0, 0.49]	6	99%
	[0.5, 1.0]	4	98%
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	[0.0, 0.49]	5	100%
	[0.5, 1.0]	4	99%

표 3. 3-bit Parity 문제에서 퍼지 단층 학습 알고리즘 간의 Epoch 수와 수렴률 비교

Table 3. The Comparison of the number of Epoch and the convergence rate between fuzzy single layer learning algorithms in the 3-bit parity problem

3-bit Parity 문제	Epoch 수	수렴률
Wang의 퍼지 단층 퍼셉트론(FSLP)	13	76%
참고 문헌[5]의 방법(E-FSLP)	9	96%
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	7	99%

표 4. 3-bit Parity 문제에서 학습률 설정에 따른 퍼지 단층 학습 알고리즘 간의 Epoch 수와 수렴률 비교

Table 4. The Comparison of the number of Epoch and the convergence rate between fuzzy single layer learning algorithms according to the range of learning rate in the 3-bit parity problem

학습 알고리즘	학습률 범위	Epoch 수	수렴성
Wang의 퍼지 단층 퍼셉트론(FSLP)	[0.0, 0.49]	17	79%
	[0.5, 1.0]	13	75%
참고문헌 [5]의 방법(E-FSLP)	[0.0, 0.49]	12	97%
	[0.5, 1.0]	8	96%
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	[0.0, 0.49]	9	99%
	[0.5, 1.0]	6	98%

표 4는 초기 학습률의 설정에 따른 각각의 알고리즘들의 Epoch 수와 수렴률 변화를 비교하여 제시한 것이다. 표 4를 통해 Wang의 FSLP 알고리즘은 연결 가중치의 초기 범위에 따라 민감하게 반응하여 수렴에 대한 안정성이 낮아지는 것을 알 수 있었다. 그리고 FSLP 알고리즘은 기존의 단층 퍼셉트론(SLP) 처럼 결정 경계선이 진동하는 경우가 생겨 학습 수렴성이 낮아지는 것을 실험을 통해 알 수 있었다.

참고 문헌 [5]의 E-FSLP 알고리즘은 Wang의 FSLP처럼 학습 데이터의 정렬 과정이 필요하므로 학습 시간이 많이 소요되나 어느 정도 안정된 수렴성을 갖는 것을 표 4에서 알

수 있는데, 결정 경계선이 진동하는 것을 바이어스항 개념을 도입하여 해결하였기 때문이다. 그러나 Wang의 FSLP와 마찬가지로 학습 데이터가 큰 경우에 정렬 과정에서 서로 다른 패턴들이 크기가 같고 목표값이 다른 때에 특징들을 분류할 수 없어 지역 최소화에 빠지고 학습에 대한 수렴성이 낮아진다.

제안된 P-FSLP 알고리즘은 다른 퍼지 단층 퍼셉트론 알고리즘들보다 파라미터의 영향에 민감하지 않아 안전성이 높고 각각의 목표값에 따라 연결 가중치를 조정하기 때문에 수렴성이 높은 것을 표 4에서 알 수가 있다. 그리고 학습 데이터를 정렬하는 과정이 없기 때문에 학습시간이 적게 소요되어 크기가 큰 학습 데이터를 요구하는 영상 인식에 효율적으로 적용할 수 있다.

4.3 차량 번호판 인식

실세계 영상 인식 문제에 대한 제안된 P-FSLP 알고리즘의 성능을 분석하기 위해 최근 신경망 응용으로 많이 언급되는 차량 번호판 인식 문제에 적용하였다. 차량 번호판 인식 실험은 비사업용 차량인 자가용 차량을 대상으로 코닥 DC265 Zoom 디지털 카메라로 획득한 256 컬러의 640×480 해상도를 가진 차량 전면부 영상 50 개에 대하여 인식 실험을 하였으며, 제안된 P-FSLP 알고리즘과 기존의 퍼지 단층 퍼셉트론 알고리즘 사이의 학습 시간 및 인식률을 비교하였다.

표 5. 차량 번호판 인식에서 퍼지 단층 학습 알고리즘들간의 학습 시간 및 학습 패턴에 대한 인식을 비교

Table 5. The Comparison of the learning time and the recognition rate for learning patterns between fuzzy single layer learning algorithms in the recognition of car licence plates

차량 번호판 인식 알고리즘	학습 시간		학습된 패턴에 대한 인식 개수	
	문자	숫자	문자	숫자
Wang의 퍼지 단층 퍼셉트론(FSLP)	X	X	X	X
참고 문헌[5]의 방법(E-FSLP)	5시간 22분	4시간 32분	80/87	159/170
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	1시간 52분	1시간 29분	85/87	168/170

표 6. 차량 번호판 인식에서 퍼지 단층 학습 알고리즘들간의 인식률 비교


Table 6. The Comparison of the recognition rate for experiment data between fuzzy single layer learning algorithms in the recognition of car licence plates

차량 번호판 인식 알고리즘	인식 개수	
	문자	숫자
Wang의 퍼지 단층 퍼셉트론(FSLP)	X	X
참고 문헌[5]의 방법(E-FSLP)	45/57	91/112
생리학적 퍼지 단층 퍼셉트론(P-FSLP)	53/57	106/112

차량 번호판 인식 실험에서 차량 번호판 인식 과정은 크게 차량 번호판 영역 및 개별 문자 영역 추출 단계와 추출된 문자의 인식 단계로 이루어진다. 본 논문에서는 제안된 알고



(a) 차량 번호판 추출 화면



(b) 차량 번호판 인식 화면

그림 6. 차량 번호판 인식 실험 결과 화면

Fig. 6. the result screen of the experiment for the recognition of car licence plates

리즘에 대해 단순한 성능 평가를 하기 위해 차량 번호판 영역 및 개별 문자 추출 방법으로 참고 문헌 [11], [12]에서 제안한 방법, 즉 RGB 컬러 정보를 이용한 차량 번호판 영역 추출 방법과 히스토그램 방식을 이용한 개별 문자 영역 추출 방법을 적용하였다[11, 12].

50개의 실험 영상에 대해 RGB 컬러 정보를 이용하는 번호판 영역 추출 방법을 적용하여 50개 모두 추출하였으며, 개별 문자 영역 추출은 48개의 번호판 영역에 대해서 추출되었다. 48개의 번호판 영역 중에서 29개의 번호판 영역에서 추출된 문자 및 숫자를 학습에 적용하였으며, 학습 결과는 표 5와 같다. 나머지 19개의 번호판 영역에서 추출된 문자 및 숫자는 알고리즘 간의 인식을 비교 실험에 적용하였는데, 실험 결과는 표 6과 같다.

표 5에서 제시된 것과 같이 Wang의 FSLP 알고리즘은 학습이 전혀 되지 않았으며, 참고 문헌 [5]의 E-FSLP 알고리즘은 초기 학습률과 모멘텀을 모두 0.95로 설정할 경우 학습 시간이 가장 적게 소요되었으나, 차량 번호판의 학습 데이터를 정렬하는 과정에서 많이 시간이 소요되었으며 인식률이 낮았다. 이에 반해 제안된 P-FSLP 알고리즘은 기존의 퍼지 단층 퍼셉트론 알고리즘들보다도 학습 시간이 적게 소요되었으며 인식률도 높게 나왔다.

그림 6은 차량 번호판 인식 실험 결과를 보여주는 그림으로 차량 번호판 영역 추출 결과 화면(그림 (a))과 P-FSLP 알고리즘을 적용한 차량 번호판 인식 화면(그림 (b))을 보여준다.

### 5. 결 론

인공 신경망과 퍼지 이론에 대한 연구와 응용이 가전 제품 및 자동화 시스템 그리고 영상 인식 분야 등으로 확대됨에 따라 논리 및 추론의 이점을 갖는 퍼지 논리와 학습 능력을 갖는 인공 신경망의 융합(fusion)에 관한 연구 및 실제 응용이 활발히 이루어지고 있다.

본 논문에서는 Wang의 퍼지 단층 퍼셉트론(FSLP)과 참고 문헌 [5]의 개선된 퍼지 단층 퍼셉트론(E-FSLP)이 영상 인식 문제에 적용할 경우 지역 최소화에 빠져 학습에 대한 수렴성을 낮아지고 인식률이 저하되는 문제점과 정렬 과정으로 인하여 학습 시간이 많이 소요되는 문제점을 분석하고, 이러한 문제점을 해결할 수 있는 생리학적 퍼지 단층 퍼셉트론(P-FSLP: Physiological Fuzzy Single Layer Perceptron) 알고리즘을 제안하였다.

본 논문은 먼저 신경계(nervous system)의 생리학적 뉴런들에 대해 기능적인 특성을 분석하여 퍼지 논리에 의한 뉴런 구조로 표현하였으며, 제시된 새로운 뉴런 구조로는 퍼지 논리합에 의한 흥분 뉴런 구조, 퍼지 논리곱에 의한 전방향 억제 뉴런 구조, 그리고 퍼지 논리 부정에 의한 역방향 억제 뉴런 구조 등이 있다. 그리고 제시된 퍼지 논리에 의한 뉴런 구조를 바탕으로 비선형 문제와 실세계 영상 인식에 적용할 수 있는 새로운 생리학적 퍼지 단층 퍼셉트론(P-FSLP) 알고리즘을 제안하고 실험을 통해 성능을 평가하였다. 실험 결과를 통해 알 수 있듯이 P-FSLP 알고리즘은 기존의 단층 퍼셉트론에서 해결할 수 없는 비선형 문제를 해결할 수 있을 뿐만 아니라 실세계 영상 인식 문제인 차량 번호판 인식 등에서 적용 가능성을 보였다. 그러나 P-FSLP 알고리즘은 모든 영상 인식 문제에 적용할 경우에 인식률이 낮아질 수 있다.

향후의 연구 과제로는 영상 인식률을 향상시키기 위한 방법으로 퍼지 C-Means 클러스터링 알고리즘과 결합한 퍼지 RBF 알고리즘을 개발하여 다양한 영상 인식 문제에 적용할 것이다.

### 참 고 문 헌

[1] F. Rosenblatt, "The Perceptron : A perceiving and recognizing automaton," Cornell Univ., Ithaca, NY, Project PARA, Cornell Aeronaut. Lab. Rep., 85-460-1, 1957.  
 [2] M. Minsky and S. Papert, Preceptrons, MIT Press, 1969.  
 [3] P. Z. Wang, T. H. Goh, and H. C. Lui, "Learning Algorithm for Enhanced Fuzzy Perceptron," *Proc. of IJCNN*, vol. 2, pp. 435-440, 1992.  
 [4] J. H. Cho, M. H. Kang and E. U. Cha, "The Dynamical Threshold adjusting Method using The Fuzzy Logic Operator," *Proc. of ITC-CSCC '96*, vol. 1, pp. 338-340, 1996.

[5] K. B. Kim, C. K. Yuk and E. Y. Cha, "A New Fuzzy Supervised Learning Algorithm," *Proc. of AFSS*, pp. 399-403, 1998.  
 [6] K. B. Kim, J. H. Lee and E. Y. Cha, "The Fuzzy Neuron Learning Based on The Physiological Organization," *Proc. of ITC-CSCC'96*, vol. 2, pp. 345-348, 1996.  
 [7] D. G. Stork, "Is Backpropagation Biologically Plausible?," *Proc. of IJCNN*, vol. 2, pp. 241-246, 1989.  
 [8] Kuff S. W., Nicholls J. G., Martin A. R., From Neuron to Brain : A Cellular Approach to The Function of The Nervous System, 2nd Ed., Sunderland Mass., 1984.  
 [9] Judith E. Dayhoff, "Biological Synapse," *Neural Network Architecture*, pp. 136-162, 1989.  
 [10] L. S. Hse, P. Z. Wang, S. C. Chan and K. F. Loe, "Fuzzy Neural-Logic System," *Proc. of Neural Networks*, vol. 1, pp. 245, 1992.  
 [11] 이정란, 남미영, 김미영, 이종희, 김광백 "칼라 정보를 이용한 자동차 번호판 추출에 관한 연구," *한국정보처리학회 '98 추계 학술 발표 논문집*, 제 5 권, 제 2 호, pp. 1349-1352, 1998.  
 [12] Y. K. Lim and K. B. Kim, "Recognition System of a Car License Plate using a Fuzzy Networks," *Proc. of AFSS*, vol. 2, pp. 1003-1008, 2000.

### 저 자 소 개

#### 김영주 (Kim Young-Ju)

1988년 : 부산대학교 계산통계학과 졸업(이학사)  
 1990년 : 부산대학교 대학원 계산통계학과(이학석사)  
 1990년~1995년 : 큐닉스컴퓨터 응용 시스템 연구소  
 1999년 : 부산대학교 대학원 전자계산학과(이학박사)  
 2000년~현재 : 신라대학교 컴퓨터정보공학부 진임강사  
 관심분야 : 분산시스템, 멀티미디어, 디지털 영상 압축 및 통신

#### 김광백 (Kim Kwang-Baek)

부산대학교 전자계산학과에서 이학석사와 이학박사학위를 취득하였으며 1996년 3월부터 1997년 2월까지 동의공업전문대학 사무자동화과에서 전임 강사로 근무하였고 1997년 3월부터 현재 신라대학교(구. 부산여자대학교) 컴퓨터정보공학부 컴퓨터공학전공에서 조교수로 재직중이다.

관심분야 : 신경회로망, 디지털 영상 처리 및 의료 영상 인식, 퍼지 시스템, 기관지 편평암 및 자궁암 세포 인식 과 차량 번호판 인식 시스템