

영상 인식을 위한 생리학적 퍼지 신경망

김광백

신라대학교 컴퓨터공학과
(gbkim@silla.ac.kr)

문용은

신라대학교 경영정보학과
(yemoon@silla.ac.kr)

박충식

영동대학교 컴퓨터공학과
(leciel@youngdong.ac.kr)

신경계의 뉴런 구조는 홍분 뉴런과 억제 뉴런으로 구성되며 각각의 홍분 뉴런과 억제 뉴런은 주동근 뉴런(agonistic neuron)에 의해 활성화되며 길항근 뉴런(antagonist neuron)에 의해 비활성화 된다. 본 논문에서는 인간 신경계의 생리학적 뉴런 구조를 분석하여 퍼지 논리를 이용한 생리학적 퍼지 신경망을 제안한다. 제안된 구조는 주동근 뉴런에 의해 홍분 뉴런이 될 수 있는 뉴런들을 선택하여 홍분시켜 출력층으로 전달하고 나머지 뉴런들을 억제시켜 출력층에 전달시키지 않는다. 신경계를 기반으로 한 제안된 생리학적 퍼지 신경망의 학습구조는 입력층, 학습 데이터의 특징을 분류하는 중간층, 그리고 출력층으로 구성된다. 제안된 퍼지 신경망의 학습 및 인식 성능을 평가하기 위해 정확성이 요구되는 의학의 한 분야인 기관지 평평암 영상 인식과 영상 인식의 주요 응용 분야인 차량 번호판 인식에 적용하여 기존의 신경망과 성능을 비교 분석하였다. 실험 결과에서는 제안된 생리학적 퍼지 신경망이 기존의 신경망보다 학습 시간과 수렴성이 개선되었을 뿐만 아니라, 인식에 있어서도 우수한 성능이 있음을 확인하였다.

논문접수일 : 2005년 5월

게재 확정일 : 2005년 6월

교신저자 : 김광백

1. 서론

인공 신경망은 간단한 기능을 갖는 다수의 처리 기들이 인접한 처리기들과 정보를 주고받으면서 동작하는 형태로 이루어져므로, 병렬 하드웨어를 구현하기에 적합하다. 이러한 특성은 영상 처리 및 인식 분야에서 광대한 양의 영상 데이터를 처리함에 있어 연산을 분산 병렬 처리할 수 있게 함으로써 처리 시간을 단축시킬 수 있다(Lippman, 1987). 두 번째 유용한 특성으로 인공 신경망의 적응력 학습 능력(adaptive learning capability)을 들 수 있다. 다시 말해서 사람이 직접 문제의 해법을 구체적으로 프로그램 하는 것이 아니고 시스템으로 하여금 주어진 문제로부터 연결선의 가중치를 조

정함으로써 스스로 문제의 해법을 발견하게 한다 (Philip and Wasserman, 1989). 이러한 학습 특성은 영상 처리 및 인식에서 효율성을 제공한다. 다음으로 결함 극복 능력을 들 수 있는데, 인공 신경망은 가중치나 처리기의 출력값이 어떤 고장에 의해 변경되거나 손실되더라도 전체 성능이 급격히 저하되지 않는다는 특징을 갖는다(Dayhoff and Judith, 1990). 그러나 인공 신경망은 학습 기능과 대량 병렬성을 보유하고 자기 조정(auto tuning) 기능을 갖는 유연성이 뛰어난 계산 모델이지만 지식 표현이 구조적으로 분명하지 않고 전문가의 이해한 지식을 반영하기가 힘들며 학습 시간이 많이 걸리고 정확한 분류를 요구하는 문제에 대해서는 적용하기 힘든 단점이 있다(Lin, 1994).

1965년 미국 캘리포니아 대학의 Zadeh교수에 의해 제안된 퍼지 이론(fuzzy Theory)은 애매한 정보로부터 유용한 정보를 추출해 낼 수 있는, 즉 인간의 애매한 표현을 처리할 수 있는 이론적 바탕을 제공해 주고 있다. 이 퍼지 이론은 논리 및 추론(inference)의 이점을 갖고 있으며 퍼지 집합론(fuzzy set theory), 퍼지 논리(fuzzy logic), 퍼지 측도(fuzzy measure)등의 개념이 수학적으로 비교적 잘 정립되어 있다(Kruse, Gebhardt, and Klawonn, 1995). 일반적으로, 영상의 특징을 인식하는 경우에는 다양한 원인에 의하여 불확실성이 존재한다. 또한 영상 인식 대상으로 입력 영상의 특징이 컴퓨터에 저장되어 있는 어떠한 특징과도 완전히 일치하지 않을 수 있고, 혹은 입력 자체가 잡음 등에 의하여 훼손될 수 있다. 따라서 입력 영상에 대하여 가장 근사하다고 판단되는 것(혹은 이와 더불어, 두 번째 등의 후보들)을 인식 결과로 제시하기 위해서는 불확실성을 처리하여야 한다. 이러한 불확실성을 처리하기 위해서는, 경험적인 방법(heuristic method)으로서 경험적 수치 자료를 이용하는 방법도 있으나, 퍼지 이론을 이용한 방법이 효율적이다. 그 이유는 영상 인식에서의 불확실성에 대한 원천은 분류 할당(class labeling)과 관련되기 때문이다. 기존의 영상 인식에서는 분류 귀속 정도(class membership degree)에 흑백 논리를 적용하는 것이 일반적이었다. 그래서 한 영상의 특징이 어느 부류에 속한다는 것은 그 영상의 특징이 주어진 부류에 포함되면 참, 그렇지 않으면 거짓이라는 것을 의미한다. 그러나 때로는 이러한 영상의 특징을 매우 엄격히 분류하는 것이 불가능한 경우가 있으므로 흑백 논리식 분류 할당 방식은 그 제한성을 갖는다. 이러한 제한성을 퍼지이론을 이용하여 적절히 해결할 수 있다(Grabisch and Nicolas, 1994). 또한 분류 할당에서 일어나는 문제

는 어떤 부류를 정하는데 있어 귀속함수(class membership function)를 도입하는 것으로 처리할 수 있다. 이러한 퍼지 명시법(fuzzy labeling)은 흑백 논리식에 입각한 단순 명시법(hard labeling)에 비해 분류 결과를 편리한 형태로 해석할 수 있기 때문에 높은 융통성을 갖는다.

그러나 퍼지 이론은 학습 능력이 없고 귀속 함수와 규칙에 대한 조정 능력이 없어 변화하는 영상 인식 문제에 대해 적응성이 떨어지고 계산하는 시간이 많이 걸리는 단점이 있다. 그러므로 인공 신경망의 장점과 퍼지 이론의 장점을 결합시킨 퍼지 신경망(fuzzy neural networks)이 매우 유용하다. 퍼지 신경망이란 퍼지 이론과 인공 신경망 이론을 어떤 형태로든 함께 사용하여 우수한 성능을 갖는 시스템을 만들려는 모든 이론과 방법론을 일컫는 말로 사용한다(Gupta and Qi, 1990; Takagi, 1990) 퍼지 이론과 인공 신경망을 접목하려는 본격적인 연구는 1980년대 말부터 시작되었으며 현재도 계속 많은 사람들이 이 분야에 대해 관심을 기울이고 있다. 현재까지는 퍼지 이론과 인공 신경망을 접목하기 위한 두 가지 방법이 있다.

첫째 접근 방법으로는 두 이론의 장점을 결합시키는 것이다. 여기에는 규칙 형태로 논리를 표현하는 퍼지 논리의 특성과 학습에 의해 패턴을 분류하는 인공 신경망의 특징을 이용한다(Hsu, et al., 1992; Halgamuge and Glesner, 1994). 개괄적으로 생각해 본다면 퍼지 이론의 입장에서 퍼지 논리에 학습 기능을 부여하는 것과, 그리고 인공 신경망 입장에서 인공 신경회로망 구조에 퍼지이론을 적용하는 것 등을 생각해 볼 수 있다. 그러나 이 접근 방법은 실제 영상 인식 분야에 적용할 경우 일반화된 학습 알고리즘을 나타내기 어렵고 응용문제에 따라 특징을 정확히 분류할 수는 없는 문제가 발생한다.

두 번째 접근 방법은 두 이론의 유사한 특징을 중첩시키는 것이다. 퍼지 이론과 인공 신경망의 외형적인 유사성은 다음과 같다. 첫째, 퍼지 추론 규칙의 조건부(IF부분)의 퍼지 변수와 입력간의 Min 연산은, 뉴런의 입력과 연결선에 부여된 가중치의 곱셈 연산에 대응된다. 둘째, 여러 추론 규칙의 결론부분(THEN 부분)에 대한 Max연산은 뉴런의 입력과 가중치를 곱한 것을 합하는 연산과 대응된다(Caminhas and Tavares, and Gomide, 1994; Kim, Joo, and Cho, 2004). 그러나 이러한 외형적인 유사성들은 퍼지 이론과 신경망 이론을 접목하는데 그다지 큰 기여를 못하고 있다.

그러므로 영상을 인식하는데 새로운 퍼지 신경망 접근 방법이 필요하다. 근본적으로 영상의 인식률을 향상시키는 데는 영상의 특징을 정확히 추출하는 방법과 이 특징들을 정확히 분류하여 인식하는 방법이 필요하다.

영상 인식에 대해서 새로운 퍼지 신경망 학습 알고리즘을 제안하기 위해 퍼지 이론과 인공 신경망을 인간의 뇌 구조와 기능을 비교 분석한다. 인간의 뇌에 들어 있는 지식을 뇌의 기능에 의거하여 지능을 구현하려는 기호 처리 인공 지능은 퍼지 논리로 정의되며, 뇌를 분석함으로써 얻은 뇌의 구조를 이용하여 지능을 구현하려는 인공지능은 인공 신경망으로 정의된다. 즉 인간의 지능을 모방하여 지능적인 학습 알고리즘을 구현하려면 뇌의 신경 구조를 바탕으로 하여 그 신경들이 뇌의 기능을 할 수 있는 생리학적 퍼지 신경망 학습 알고리즘이 필요하다. 그러므로 본 논문에서는 영상에 대한 인식률을 향상시키기 위하여 신경계를 기반으로 한 새로운 생리학적 퍼지 신경망 학습 알고리즘들을 제안한다.

2. 관련 연구

영상 인식에 있어 처리 속도의 개선과 잡음에 대한 저항성은 필연적으로 해결해야 할 주요 연구 과제라 할 수 있다. 따라서 영상을 인식하기 위한 기존의 신경망 학습 모델들을 살펴보고 인공 신경망과 인식에 관련된 기존의 연구 방법을 분석한다.

2.1 오류 역전파 알고리즘

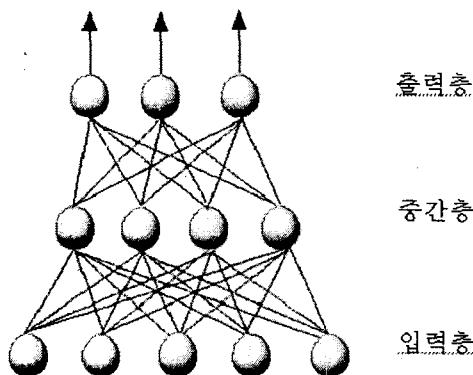
오류 역전파 알고리즘(Error Backpropagation Algorithm)은 비선형 판별 문제를 해결할 수 있어 최근에 가장 보편적으로 사용되고 있다. 그리고 일부 생리학자(physiologist)들은 이 학습 알고리즘을 인간의 두뇌 및 중추 신경 시스템으로까지 여겼다. 그러나 오류 역전파 학습 알고리즘에서 학습 시간이 많이 걸리고 연결 가중치들이 지역 최소화(local minima)에 위치하게 되는 원인을 분석해 보면 은닉층의 노드수 설정문제, 오류 한계 설정 문제, 초기 연결 가중치 설정 문제, 학습률 설정 문제, 모멘텀 설정 문제, 뉴런 활성화 기울기 조정 문제 등이 있다(Kim, Kang, and Cha, 1997).

Cheung 등은 학습 단계를 다음과 같이 구분하였다. 학습 초기에 오류(error)가 급격히 줄어드는 오류 수렴 단계, 특정 학습 패턴에 대한 연결 가중치의 변화가 다른 패턴에 의한 연결 가중치의 변화와 상치되기 때문에 오류의 변화가 거의 없는 경쟁 단계, 학습이 안 된 패턴이 갑자기 학습되면서 오류가 급격히 줄어드는 우세 단계로 구분하였다 (Cheung, 1990). 이 3단계 중 경쟁 단계에 의해 학습 시간이 많이 걸리며 초기 포화 현상(premature saturation)이 발생한다. 초기 포화 현상이란 신경 회로망이 학습 도중 일정한 기간동안 오류가 일정하게 유지되면서 학습이 진전되지 않는 것을 말한

다. 따라서 영상과 같이 학습 패턴이 큰 경우 학습에 대한 수렴성이 저하되고 인식률이 낮아지는 원인이 된다(Kothari, Madnani, and Segal, 1997).

2.2 RBF 네트워크

RBF(Radial Basis Function) 네트워크는 빠른 학습시간, 일반화(generality), 단순화(simplicity)의 특징으로 학습 데이터를 분류하는 작업과 비선형 시스템 모델링 등에 적용되고 있다(Kim, Kim, and Oh, 2004). 기존의 오류 역전파 학습 알고리즘과 같은 다층 퍼셉트론(Multilayer Perceptron)의 연결 가중치들이 지역 최소화에 위치하여 학습 패턴들이 잘 분류되지 않은 경우를 방지할 수 있으며 학습 시간을 단축시킬 수 있다. 전형적인 RBF 네트워크의 학습 모형은 [그림 1]과 같다.



[그림 1] RBF 네트워크 모형

여기서 입력층과 중간층간에는 클러스터링하는 역할을 수행하게 된다. 중간층에 있는 노드는 그 자신의 중심(centroid)을 가지고, 입력 $X = \{x_1, \dots, x_n\}$ 에 대하여 자신과의 중심간의 거리 벡터를 구한다. 이 노드의 출력은 거리 벡터에 대한 일정 형태의 비선형 함수로 얻어진다. 입력이 중간

층의 노드에 가까울수록 그 출력값은 커지게 된다. 중간층의 노드를 구하는 것은 식 1과 같다. 여기서 c_k 는 각 클러스터의 중심값이고 σ 는 중심에 대한 넓이 값이 된다.

$$\rho_k = \exp\left(\frac{-\|X - c_k\|^2}{\sigma_k^2}\right) \quad (1)$$

중간층과 출력층간에는 일반적인 학습 과정을 수행한다. RBF의 출력노드는 각 중간층 노드의 출력값에 학습 과정중 가변인 연결 가중치(weight)를 곱한 후 이들을 더한 값을 그 출력값으로 갖는다. 그리고 $o_i = \sum_{k=1}^n \rho_k w_{ki}$ 와 같이 일반적인 학습 방법인 최소자승(least mean square)방법으로 목표값과 출력값 간의 오차를 최소화하는 방향으로 학습한다.

RBF 네트워크에서 중간층은 학습 패턴들을 클러스터링 하는 층이다. 이 중간층의 목적은 주어진 학습 패턴들을 유사한 클러스터들(homogeneous clusters)로 분류하는 것이다. 여기서 유사하다는 것은 학습 벡터들에 대한 특정 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터에 속하고 정해진 반경 내에 존재하지 않으면 다른 클러스터에 속하게 된다. 그러나 정해진 반경 내에서 클러스터링 하는 것은 잘못된 클러스터를 선택하여 출력층의 입력값을 구성하므로 인식률을 저하시키는 원인이 된다(Takechi and Murakami, 1993). 그러므로 암세포 영상과 같이 세포들의 특징들이 서로 중복되는 경우가 발생하면 잘못된 중간층의 클러스터링으로 인하여 분류 및 인식률을 저하시키는 원인이 된다.

2.3 ART(Adaptive Resonance Theory)

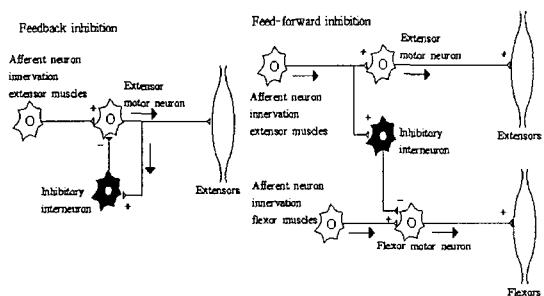
Crossberg와 Carpenter에 의해 제안된 ART(Adaptive Resonance Theory) 신경망 모델은 뉴런들 간에 경쟁 학습(competitive learning)에 의하여 자율적으로 패턴들을 분류하는 네트워크 구조이다. 임의의 패턴을 학습할 수 있는 안정성(stability)과 적응성(plasticity)을 갖는 신경망의 학습 모델이다(Grossberg, Grossberg, and Reynolds, 1991). 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima) 문제가 발생하지 않는다. ART 신경망 모델 중에서 ART1 알고리즘은 자동 학습 시스템(autonomous learning system) 구축에 널리 사용되고 있다. 그러나 ART1 알고리즘은 이진수 형태의 입력 벡터만을 입력으로 받아 학습하기 때문에 주어진 입력 데이터를 이진 벡터로 전처리하는 과정이 필요하다. ART1 알고리즘은 첫 번째 입력을 첫 번째 클러스터의 대표 패턴으로 선택하고 다음 입력이 들어오면 첫 번째 대표 패턴과의 유사성을 측정한다. 즉 유사성 검증에서 경계 변수보다 크거나 같으면 첫 번째 클러스터로 분류하고, 그렇지 않으면 새로운 클러스터를 생성한다. 이러한 과정이 모든 입력 패턴들에 적용되면 클러스터의 개수는 시간에 따라 점점 증가하게 된다. ART1 알고리즘은 경계 변수 설정에 따라 유사한 패턴이 다른 클러스터로 생성되는 경우와 서로 다른 패턴이 같은 클러스터로 분류되는 경우가 발생한다. 따라서 ART1 알고리즘을 영상 인식에 적용할 경우, 입력 벡터와 클러스터의 대표 벡터간의 유사성 측정 방법과 경계 변수에 따라 인식률이 낮아지는 문제점이 있다(김광백, 김철기, 김정원, 2002). ART2 알고리즘은 이진 입력 패턴과 아날로그 입력 패턴에 대해서도 학습이 가능하다

(Pandya and Macy, 1995). ART2의 연결 가중치 변화는 모든 입력 패턴의 평균값을 취함으로써 클러스터 생성에 고르게 반응하게 된다. 그러나 ART2의 연결 가중치는 입력 패턴이 들어오는 경우 특징이 서로 다른 유사한 기준의 클러스터가 생성되는 경우가 발생한다. 그 원인은 입력 벡터가 연결 가중치 벡터와의 평균에 의해 가중치의 특징을 감소시키기 때문이다(Kim and Kim, 2004). 따라서 영상 인식 분야에 적용할 경우 서로 다른 유사한 패턴들이 같은 클러스터로 분류하여 인식률을 저하시킨다. 이러한 문제점을 해결하기 위해 퍼지 논리 연산자를 이용한 퍼지 ART 알고리즘이 제안되었다(Grossberg and Grossberg, 1992). 퍼지 ART 알고리즘에서 경계 변수는 패턴들을 클러스터링하는데 있어서 반지름 값이 되며 임의의 패턴과 저장된 패턴과의 불일치(mismatch) 허용도를 결정한다. 이 경계 변수가 크면 입력 벡터와 기대 벡터 사이에 약간의 차이가 있어도 새로운 카테고리(category)로 분류하게 된다. 반대로 경계 변수가 작으면 입력 벡터와 기대 벡터 사이에 많은 차이가 있더라도 유사성이 인정되어 입력 벡터들을 대략적으로 분류한다(Kim and Kim, 2004). 따라서 영상 인식에 적용하기 위해서는 경험적으로 경계 변수를 설정해야 단점이 있다. 그리고 연결 가중치를 조정하는 과정에서 저장된 패턴들의 정보들이 손실되는 경우가 발생하여 인식률을 저하시킨다.

2.4 생리학적 뉴런 구조

신경계의 생리학적 구조는 활성화 뉴런과 억제 뉴런으로 구성된다(Kuffer, Nicholas, Martin, 1984; Kim, Kang, Cha, 1997). 활성화 뉴런에 대해 살펴보면 주동근 뉴런(antagonistic neuron)이 활

성화 뉴런이다. 주동근 뉴런은 같은 방향으로 뉴런을 움직이도록 작동하여 활성화시키는 동작을 말한다. 반면에 억제 뉴런은 전방향 억제 뉴런(feed forward inhibition neuron)과 역방향 억제 뉴런(backward inhibition neuron)으로 구분된다. 전방향 억제 뉴런은 억제성 시냅스를 생성하여 전에 흥분된 일이 없어도 억제시키는 뉴런이며 역방향 억제 뉴런은 억제성 개재 뉴런이 자신을 활성화 시킨 세포에 작용하여 억제시키는 뉴런을 말한다. 활성화 뉴런과 억제 뉴런 구조를 [그림 2]로 나타낼 수 있다.



[그림 2] 생리학적 뉴런 구조

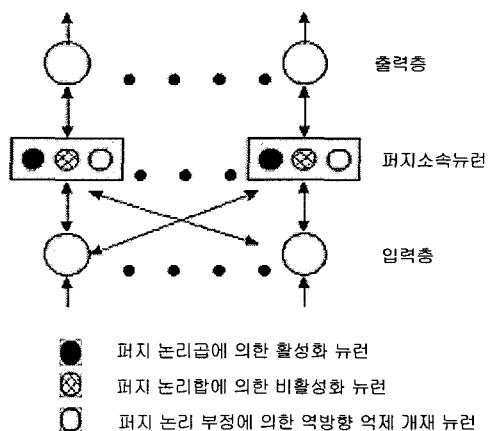
3. 생리학적 퍼지 신경망

제안된 생리학적 퍼지 신경망은 주동근 뉴런에 의해 흥분 뉴런이 될 수 있는 후보들을 선택하여 흥분시켜 출력층으로 전달하고 나머지 뉴런들을 억제시켜 출력층에 전달시키지 않는다. 신경계를 기반으로 한 제안된 생리학적 퍼지 신경망의 학습 구조는 입력층, 학습 데이터의 특징을 분류하는 중간층, 그리고 출력층으로 구성된다. 입력층과 중간층의 학습은 퍼지 ART 알고리즘을 개선하여 적용하고 중간층과 출력층간의 학습은 생리학적 퍼지 지도 학습 알고리즘을 제안하여 적용한다.

3.1 생리학적 퍼지 지도 학습 알고리즘

제안된 퍼지 지도 학습 구조는 생리학적 뉴런 구조를 기반으로 하여 입력층, 퍼지 귀속 뉴런들(fuzzy membership neurons) 및 출력층으로 구성된다. 퍼지 귀속 뉴런들은 퍼지 논리합에 의한 활성화 뉴런, 퍼지 논리곱에 의한 비활성화 뉴런, 퍼지 논리 부정에 의한 역방향 억제 개재 뉴런(interneuron)으로 구성된다. 생리학적 퍼지 지도 학습 모형은 [그림 3]과 같다.

생리학적 퍼지 지도 학습 알고리즘의 학습 단계는 전방향 단계와 역방향 단계로 구분된다. 생리학적 뉴런의 전달 과정을 분석해 보면 흥분 뉴런과 전방향 억제 뉴런과 역방향 억제 개재 뉴런에 의해서 동작된다. 따라서 전방향 단계에서는 출력층의 실제 출력값은 목표값에 따라 퍼지 귀속 뉴런들에 의해서 계산되고 출력값을 정규화시키는 전이 함수(transfer function)로는 목표 값에 따라 퍼지 기본 논리 연산자인 Max와 Min 연산자를 사용한다. 역 방향에서는 실제 출력값을 목표값과 비교하여 퍼지 귀속 뉴런들의 가중치를 조정한다.



[그림 3] 생리학적 퍼지 지도 학습 모형

본 논문에서 제안된 새로운 생리학적 퍼지 지도 학습 알고리즘은 다음과 같다.

단계 1. 입력 패턴 (x_i^p)과 목표 패턴 (t_i^p)을 제시 한다.

단계 2. 입력총과 출력총사이의 연결 가중치들 ($W_{AND_g}, W_{OR_g}, W_{NT_g}$)들, 퍼지귀속 뉴런의 가중치들 ($V_{AND_g}, V_{OR_g}, V_{NT_g}$) 그리고 목표값에 따른 활성화 및 비활성화를 구분하는 정 보들 ($ON_{AND_g^p}, ON_{OR_g^p}, ON_{NT_g^p}$)을 다음과 같이 초기화한다.

- Logic_weight : $W_{AND_g} = 1, W_{OR_g} = 1, W_{NT_g} = 1$

- Logic_value :

$$V_{AND_g} = \frac{1}{I}, V_{OR_g} = 1, V_{NT_g} = -1$$

- Logic_mark :

$$ON_{AND_g^p} = 1, ON_{OR_g^p} = 1, ON_{NT_g^p} = 1$$

여기서 W_{AND_g} 는 전방향 억제 뉴런 가중치, W_{OR_g} 는 전방향 흥분 뉴런 가중치 그리고 W_{NT_g} 는 역방향 억제 개재뉴런 가중치이다.

단계 3. 퍼지 귀속 뉴런 ($Synapse_{ij}$)들을 0과 1값으로 정규화 한다.

$$\begin{aligned} Synapse_{ij} &= Synapse_{ij} + (ON_{AND_g^p} \times x_i^p \times V_{AND_g} \times W_{AND_g}) \\ &\quad + (ON_{OR_g^p} \times x_i^p \times V_{OR_g} \times W_{OR_g}) \end{aligned}$$

If ($Synapse_{ij} > 1.0$) $Synapse_{ij} = Synapse_{ij} + V_{NT_g}$

단계 4. 목표값 (t_j^p)에 따라 퍼지 기본 논리 연산자를 사용하여 출력값 (o_j)을 계산한다.

If ($t_j^p \geq 0.5$) $o_j = \vee(Synapse_{ij})$;

If ($t_j^p < 0.0$) $o_j = \wedge(Synapse_{ij})$;

여기서 p 는 제시되는 패턴들의 수, \vee 는 퍼지

Max 논리 연산자이며 \wedge 는 Min 논리 연산자이다.

단계 5. 입력총과 출력총사이의 연결 가중치들 (W_{AND_g}, W_{OR_g})들을 조정한다.

$$e_j = t_j^p - o_j^p$$

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

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

$$ON_{AND_g} = 1$$

If (($W_{AND_g} > 1.0$)and($ON_{AND_g^p} = 1$))

$$W_{AND_g} = W_{AND_g} - 1.0, ON_{AND_g} = 0$$

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

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

$$ON_{OR_g} = 1$$

If ($W_{OR_g} > 1.0$) $W_{OR_g} = W_{OR_g} - 1.0, ON_{OR_g} = 1$

여기서 a 는 0과 1사이의 학습률이다.

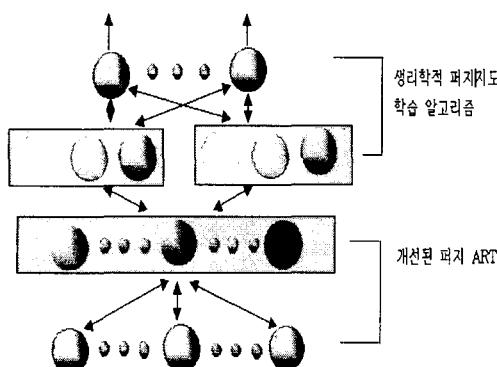
단계 6. 한 패턴에 대한 모든 목표 비트들이 학습 될 때까지 단계 3으로 가서 반복한다.

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

3.2 생리학적 퍼지 신경망

신경계의 뉴런 구조는 흥분 뉴런과 억제 뉴런으로 구성되며 각각의 흥분 뉴런과 억제 뉴런은 주동근 뉴런(agonistic neuron)에 의해 활성화되며 길항근 뉴런(antagonist neuron)에 의해 비활성화 된다. 제안된 구조는 주동근 뉴런에 의해 흥분 뉴

런이 될 수 있는 후보들을 선택하여 흥분시켜 출력층으로 전달하고 나머지 뉴런들은 억제시켜 출력층에 전달시키지 않는다. 본 논문에서 제안하는 생리학적 퍼지 신경망의 학습 모형은 [그림 4]와 같다. 제안된 학습 구조는 입력층(input layer), 중간층, 출력층으로 구분된다.



[그림 4] 생리학적 퍼지 신경망

제안된 학습구조는 다음과 같이 요약할 수 있다.

1. 입력층과 중간층 간의 연결 구조는 제안된 Fuzzy ART의 구조와 같고, Fuzzy ART의 출력층이 제안된 구조의 중간층이 된다.
2. 중간층의 소마(soma)는 각 클래스(class)를 의미한다. 따라서 전체적으로 완전 연결(fully-connected)구조이나 목표값과 실제 출력값을 비교해서 역전파시킬 때는 대표 클래스와 연결된 시냅스의 가중치만 역전파하는 승자우선 방식을 채택한다.
3. 출력층에서 중간층으로의 시냅스의 가중치 조정 방법은 제안된 생리학적 퍼지 지도 학습 방법을 적용한다.
4. zero로 구성된 학습 데이터만은 승자 선택없이 모든 중간층의 소마에 영향을 주게 한다.

생리학적 퍼지 신경망의 학습은 크게 두 단계로 구분된다. 첫 번째 단계는 입력층과 중간층 사이에 경쟁학습이 수행되고, 두 번째 단계는 중간층과 출력층 사이에는 지도학습이 수행된다. 생리학적 퍼지 신경망에서 입력층과 중간층 사이의 출력 벡터는 식 2와 같다. 중간층의 출력 벡터는 입력패턴과 클러스터들과의 수렴 정도를 식 2와 같이 계산한다. 그리고 식3과 같이 가장 큰 출력 벡터를 가진 소마가 승자 노드로 선택된다.

$$O_j = \frac{\|x_i^p \wedge w_{ij*}\|}{a + w_{ij*}} \quad (2)$$

$$O_{j'} = \vee(O_j) \quad (3)$$

\wedge 과 \vee 는 최소값과 최대값을 계산하는 퍼지 논리 연산자이고, w_{ij*} 는 입력층과 승자 소마로 선택된 중간층 사이의 연결 가중치이다.

생리학적 퍼지 신경망에서 중간층의 승자 소마는 입력 벡터와 중간층의 수렴 정도가 큰 값들이 승자 소마로 선정되어 출력층으로 전달된다. 여기서 O_j 는 출력값이고 $O_{j'}$ 는 j 번째가 승자로 선택된 뉴런을 의미한다. 그리고 a 는 0과 1사이의 상수이다. 기존의 퍼지 ART에서 경계 변수(vigilance parameter)는 패턴들을 클러스터링하는 반지를 값이 되며 임의의 패턴과 저장된 패턴과의 불일치(mismatch) 허용도를 결정한다. 이 경계 변수가 크면 입력 패턴과 기대 패턴 사이에 약간의 차이만 있어도 새로운 카테고리(category)로 분류하게 된다. 반대로 경계 변수가 적으면 입력 패턴과 기대 패턴 사이에 많은 차이가 있더라도 유사성이 인정되어 입력 패턴들을 대략적으로 분류한다. 그러므로 기존의 퍼지 ART 알고리즘을 이용하여 실세계의 영상 인식 문제에 적용할 경우

에는 경험적으로 경계 변수를 설정하므로 유사한 패턴들이 서로 다른 클러스터로 분류되거나 서로 다른 패턴들이 같은 클러스터 분류되는 경우가 발생한다. 따라서 본 논문에서는 퍼지 논리 접속 연산자를 이용하여 경계 변수를 유사성을 가지는 특징에 따라 동적으로 조정한다. 그리고 저장 패턴들과 학습 패턴간의 유사성과 경계 변수의 차이를 이용하여 가중치 조정에 적용한다. 개선된 퍼지 ART 알고리즘에서 경계 변수 (ρ)는 Yager의 교연산자를 이용하여 동적으로 조정한다. 경계 변수 조정은 유사성이 경계 변수 보다 크거나 같은 경우에만 경계 변수를 동적으로 조정한다. 유사성이 인정되는 학습 패턴에 대해서 학습 패턴의 목표값과 저장패턴의 목표값과 비교하여 같은 경우에는 경계 변수를 감소시키고 입력층과 중간층 사이의 연결 강도를 조정한다. 만약 학습 패턴의 목표값 (T_{j*}^*)과 저장패턴의 목표값 (T_{j*}^t)이 같지 않은 경우에는 경계 변수를 증가시키고 다음의 승자 소마를 선택한다. 경계 변수를 동적으로 조정하는 알고리즘은 다음과 같다.

$$\text{if } (T_{j*}^t \neq T_{j*}^*) \text{ then } \rho(t+1) = 1 - \wedge(1, ((1-\rho(t))^{-2} + (1-\rho(t-1))^{-2})^{-1/2}) \\ \text{else } \rho(t+1) = 1 - \wedge(1, \sqrt((1-\rho(t))^2 + (1-\rho(t-1))^2))$$

선정된 승자 소마에 대한 유사성의 검증은 식 (4)와 같다.

$$\frac{\|w_{ij*} \wedge x_i^\rho\|}{\|x_i^\rho\|} < \rho \quad (4)$$

ρ 는 제안된 알고리즘의 경계 변수이고, 승자소마의 출력 벡터가 경계변수보다 크면 같은 패턴으로 분류하고 아니면 다른 패턴으로 분류한다. 같은 패턴으로 분류되면, 입력 패턴의 유사한 특징을 연

결 강도에 반영하기 위해 연결 강도를 조정한다. 생리학적 퍼지 신경망에서 중간층의 연결강도의 조정은 식 (5)와 같다.

$$w_{ij*}(t+1) = \beta(x_i^\rho \wedge w_{ij*}(t)) + (1 - \beta)w_{ij*}(t) \quad (5)$$

여기서 β 는 0과 1이의 값을 가지는 파라미터다.

기존의 퍼지 ART 알고리즘에서 가중치를 조정할 때 β 는 경험적인 값으로 설정한다. 기존의 퍼지 ART에서 β 값을 크게 설정하면 인식률이 낮아진다. 그 원인은 클러스터의 개신된 횟수가 증가하게 될 경우에는 이전에 저장된 패턴의 정보가 손실되어 인식률이 낮아지게 된다. 반대로 β 값을 작게 설정하여 학습하게 되면 현재의 학습 패턴의 정보가 저장 패턴에 반영되는 정도가 낮아지게되어 클러스터의 수가 증가하게 된다(김광백, 2004). 따라서 본 논문에서는 저장 패턴들과 학습 패턴간의 유사성과 경계 변수의 차이를 이용하여 β 값에 적용한다. 개선된 퍼지 ART 알고리즘에서 β 값의 조정은 식 6과 같이 계산한다.

$$\beta = \frac{\frac{\|w_{ij*} \wedge x_i^\rho\|}{\|x_i^\rho\|} - \rho}{1 - \rho} \quad (6)$$

중간층에서 승자 소마로 선택된 소마와 출력층 사이의 연결가중치 ($W_{AND_{jk}}, W_{OR_{jk}}, W_{NT_{jk}}$)들, 퍼지 규칙 뉴런의 연결 가중치 ($V_{AND_{jk}}, V_{OR_{jk}}, V_{NT_{jk}}$)들 그리고 목표값에 따른 활성화 및 비활성화를 구분하는 정보들 ($ON_{AND_{jk}}, ON_{OR_{jk}}, ON_{NT_{jk}}$)을 다음과 같이 초기화한다.

· Logic_weight :

$$W_{AND_{jk}} = 1, W_{OR_{jk}} = 1, W_{NT_{jk}} = 1$$

· Logic_value :

$$V_{AND_{j,k}} = \frac{1}{J}, V_{OR_{j,k}} = 1, V_{NT_{j,k}} = 1$$

· Logic_mark :

$$ON_{AND_{j,k}^p} = 1, ON_{OR_{j,k}^p} = 1, ON_{NT_{j,k}^p} = 1$$

여기서 $W_{AND_{j,k}}$ 는 전방향 억제 뉴런 가중치, $W_{OR_{j,k}}$ 는 전방향 흥분 뉴런 가중치 그리고 $W_{NT_{j,k}}$ 는 역방향 억제 개재뉴런 가중치이다. 그리고 중간층과 출력층의 퍼지 규칙 뉴런($Synapse_{j,k}$)들을 0과 1값으로 정규화 한다.

$$\begin{aligned} Synapse_{j,k} &= Synapse_{j,k} + \\ &(ON_{AND_{j,k}^p} \times o_{j^*}^p \times V_{AND_{j,k}} \times W_{AND_{j,k}}) \\ &+ (ON_{OR_{j,k}^p} \times o_{j^*}^p \times V_{OR_{j,k}} \times W_{OR_{j,k}}) \end{aligned}$$

$$If (Synapse_{j,k} > 1.0) Synapse_{j,k} = Synapse_{j,k} + V_{NT_{j,k}}$$

출력층의 목표 값에(t_k^p)에 따라 퍼지 기본 논리 연산자를 사용하여 출력층의 출력값(o_k)을 계산한다.

$$If (t_k^p \geq 0.5) o_k = \vee(Synapse_{j,k})$$

$$If (t_k^p < 0.0) o_k = \wedge(Synapse_{j,k});$$

중간층에서 승자 소마로 선정된 소마와 출력층 소마사이의 연결 가중치들($W_{AND_{i,j}}, W_{OR_{i,j}}$)들을 조정한다.

$$e_k = t_k^p - o_k$$

$$If ((W_{AND_{j,k}} \leq 1.0) \text{and}(ON_{AND_{j,k}^p} = 1))$$

$$W_{AND_{j,k}} = W_{AND_{j,k}} + \gamma \times e_k \times \frac{(o_{j^*}^p \times W_{AND_{j,k}})}{o_{j^*}^p},$$

$$ON_{AND_{j,k}^p} = 1$$

$$If ((W_{AND_{j,k}} > 1.0) \text{and}(ON_{AND_{j,k}^p} = 1))$$

$$W_{AND_{j,k}} = W_{AND_{j,k}} - 1.0, ON_{AND_{j,k}^p} = 0$$

$$If ((W_{OR_{j,k}} \leq 1.0) \text{and}(ON_{OR_{j,k}^p} = 1))$$

$$W_{OR_{j,k}} = W_{OR_{j,k}} + \gamma \times e_k \times \frac{(o_{j^*}^p \times W_{OR_{j,k}})}{o_{j^*}^p},$$

$$ON_{OR_{j,k}^p} = 1$$

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

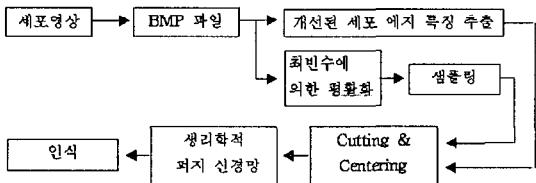
여기서 γ 는 중간층과 출력층에서 적용되는 학습률이고 0과 1 사이의 값이다.

4. 실험 및 결과

본 논문에서 제안된 알고리즘의 성능을 분석하기 위하여 Intel Pentium-IV 2.8GHz CPU와 512MB RAM이 장착된 IBM 호환 PC상에서 C++ 빌더 6.0으로 실험하였다. 실험 대상 분야로는 기관지 편평암(bronchogenic cancer cell)인식과 차량 번호판 인식에 적용하였다. 각각의 실험 문제에 대해서 오류역전파 알고리즘, ART1 기반 자가 생성 지도 학습 알고리즘(김광백, 2003), ART2 기반 RBF 네트워크(김광백, 김영주, 2001) 그리고 본 논문에서 제안한 생리학적 퍼지 신경망의 학습 반복회수, 수렴성과 인식률을 비교 분석하였다.

4.1 기관지 편평암 영상 인식

기관지 편평 세포들을 전처리 하는 과정으로 기존의 영상 처리 방법을 개선하여 학습 데이터를 구성하였다. 기관지 편평암 세포 영상 인식에 대한 처리 과정은 [그림 5]와 같다.



[그림 5] 기관지 편평암 영상의 전처리 및 인식 과정

일반적으로 정상 편평 세포는 다음과 같은 특징을 가진다(이중달, 1989; Kim and Yun, 1999).

- ① 핵 크기나 세포의 크기가 각각의 세포마다 거의 유사하다.
- ② 핵의 위치가 세포의 중간에서 거의 벗어나지 않는다.
- ③ 핵 크기가 세포질의 크기에 비해 매우 낮은 비율을 차지한다.

기관지 편평암 세포는 크게 6가지의 형태를 가지며, 기관지 편평 세포 다음 6가지 중에 포함되면 암세포로 판명한다.

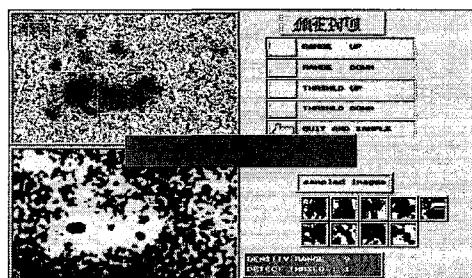
- ① 암종 세포 1 : 등근 핵의 핵막은 두껍고 농염되고, 염색질이 엉켜서 불규칙하고 굽은 과립상이다.
- ② 암종 세포 2 : 올챙이 세포핵 - 핵은 항상 올챙이의 머리 부분에 위치한다.
- ③ 암종 세포 3 : 다형성 세포이다. 크고 작은, 동글고 길쭉한 암세포들이 매우 농염된 핵을 가진다. 세포질의 염색성도 다양하다.
- ④ 암종 세포 4 : 암세포들이 2개 이상 모여서 암진주를 형성한다.
- ⑤ 암종 세포 5 : 무핵성 세포질을 가진다.
- ⑥ 암종 세포 6 : 무핵성 세포질로 변해가는 도중의 암세포는 핵이 농축되고 한쪽으로 편재한다.

위의 모든 경우에서 암세포의 세포핵은 정상 세포보다 크다는 특징을 가진다. 그리고 위에서 살펴

본 바와 같이 암종 세포는 핵과 세포질의 변화에 따라 달라진다. 비정형 편평 암종 영상은 [그림 6]과 같다.



[그림 6] 비정형 편평암 영상



[그림 7] 기관지 편평암 세포처리 과정

기준의 학습 알고리즘들과 제안된 알고리즘들 간의 수렴성과 인식률을 비교하기 위해서는 기관지 편평암 영상에 대한 전처리 과정이 필요하다. 전처리 단계로는 BMP 파일 생성, 평활화 단계, 샘플링 단계, 그리고 학습 데이터 구성 등으로 이루어진다.

본 논문에서는 256칼라 영상을 입력으로 사용한다. 기관지 편평암 세포를 전처리하는 과정에서 잡음과 같은 불필요한 신호가 섞이게 된다. 따라서 평활화(smoothing)기법을 적용한다.

최빈수 방법에 의해 처리된 영상을 사용하여 샘플링한다. 평활화된 영상은 0에서 255까지의 값을 가지게 되는데 이 값을 이용하여 세포를 샘플

링한다. 샘플링 임계치만을 조정하여 샘플링한다. 그리고 하나의 각 픽셀을 이용하여 영상내의 픽셀 밀도를 구한다. 이 픽셀 밀도에서 특정 임계치를 넘는 값들만 화면에 출력하고 가장 밀도가 높은 곳을 세포의 중심으로 판단한다. 그리고 이 세포의 중심에서 임계치를 넘는 밀도를 가진 픽셀들만을 찾아내어 세포의 크기를 결정하여 이 크기만큼을 샘플링 한다. 이 크기의 영상을 추출하고 정규화하여 학습 데이터를 구성한다. [그림 7]은 기관지 편평 암세포를 전처리하여 세포들을 추출하는 전처리 과정을 나타내었다.

전처리 단계에 의해서 생성된 각각의 50개의 정상 세포들과 암세포들을 기준의 학습 알고리즘들과 제안된 생리학적 퍼지 신경망 간의 학습에 대한 수렴성과 학습 시간 및 인식률에 대해 실험하여 실험 결과를 분석하였다.

전처리 단계에서 추출한 기관지 편평 암세포들과 정상 세포들의 학습 데이터의 크기를 50×50 배열로 구성하였다. 학습에 필요한 가중치의 범위를 $[-1.0, 1.0]$ 에서 임의의 값으로 설정하였다.

오류 역전파 학습 알고리즘에서는 은닉층의 소마수에 따라 학습에 대한 수렴성이 결정된다. 그러므로 이 은닉층의 소마수를 결정하는 방법을 (김광백, 2003)의 방법에 의해서 최적의 수렴성과 적은 학습 시간이 요구되는 은닉층의 노드수를 결정하였다. 실험한 결과, 오류 역전파의 은닉층의 소마수를 30개로 설정하는 것이 최적으로 나타났다. 여기에 학습률은 0.55로 설정하였고 모멘텀은 0.75로 설정하였다. ART1 기반 자가 생성 지도 학습 방법에서는 초기 은닉층의 소마수를 1개로 시작하여 학습 후 중간층 소마수는 87개가 생성되어, 중간층의 클래스를 87개로 분류하였다. 그리고 학습률과 모멘텀을 각각 0.5와 0.75로 설정하였다. ART2 기반 RBF 네트워크에서는 학습률과 모멘

텀값을 각각 0.75로 설정하였고 경계 변수 (vigilance parameter)값에 따라 분류의 정확성이 결정되기 때문에 경험적인 실험을 통해 경계 변수를 0.15로 설정했다. ART2 기반 RBF 네트워크에서는 62개의 중간층의 소마가 생성되었다. 제안된 퍼지 신경망에서는 중간층의 소마수를 1개 설정하여 학습한 결과, 생성된 소마수는 50개이며 경계 변수는 0.95로 설정하여 동적으로 변화시켰다. 각 학습 알고리즘간의 학습 시간을 비교하면 <표 1>과 같다.

<표 1> 각 학습 알고리즘간의 최적의 학습 시간 및 중간층 소마 개수 비교

기관지 편평암 적용 알고리즘	최적의 학습 시간	중간층의 소마수
오류 역전파 학습 알고리즘	19(min) 12(sec)	30
ART1 기반 자가 생성 지도 학습 알고리즘	9(min) 42(sec)	87
ART2 기반 RBF 네트워크	7(min) 2(sec)	55
제안된 생리학적 퍼지 신경망	5(min) 13(sec)	50

<표 1>에서와 같이 제안된 생리학적 퍼지 신경망이 다른 학습 알고리즘보다 학습 시간이 적게 소요되는 것을 실험을 통해서 알 수 있다. 인공 신경망의 학습 알고리즘들은 학습 시간의 단축과 수렴성에 대해서 많은 연구를 하였다. 그러나 학습에 대한 수렴성만으로는 입력 데이터들의 특징들이 정확히 분류되었다고 할 수 없다. 수렴성은 최소한의 특징들이 분류되어서 학습될 수도 있기 때문에 인식률의 저하를 가져온다. 영상 인식 문제 중에서 기관지 편평암 세포를 인식하는 것은 정확한 전처리, 학습에 대한 수렴성 그리고 인식률이 중요하

다. 그리고 암세포 인식 문제는 학습 시간의 단축이 중요시 되지 않는다. 암세포 인식 및 진단은 인간의 생명에 직접적으로 영향을 주기 때문에 의사들도 직접 광학 현미경을 통하여 경험적으로 여러 의사들에 의해서 진단되고 있다. 따라서 학습 시간보다는 인식률이 중요시된다. 기관지 편평암 세포들의 인식률을 실험은 학습을 통한 알고리즘들 간의 인식률을 비교하였다. 기존의 학습 알고리즘과 제안된 학습 알고리즘간의 기관지 편평 세포와 암세포들에 대한 인식률을 <표 2>로 나타내었다. 표 2를 분석하면 기존의 ART2기반 RBF 신경망은 오류 역전파의 수렴성 문제를 해결하기 위해 제안된 것으로 영상 인식에 이용되고 있지만 암세포와 같이 정확성을 요구하는 영상 인식 분야에는 적합하지 않은 것으로 실험에서 나타났다.

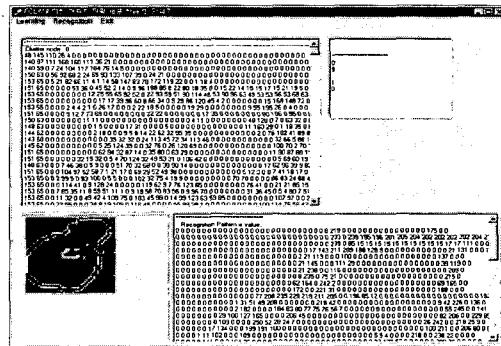
<표 2> 각 학습 알고리즘간의 기관지 편평암 세포 인식률 비교

기관지 편평 세포 분류 및 인식	정상 세포 (50)	암세포 (50)
오류 역전파 학습 알고리즘	43	40
ART1 기반 자가 생성 지도 학습 알고리즘	43	41
ART2 기반 RBF 네트워크	48	45
제안된 생리학적 퍼지 신경망	50	49

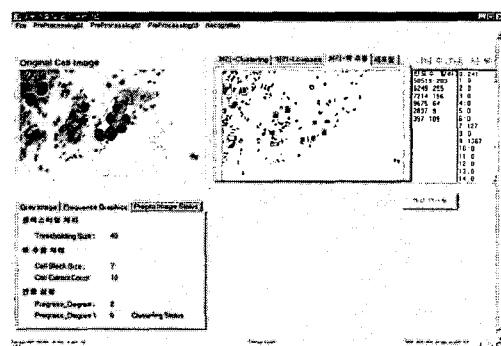
그리고 오류 역전파 학습 알고리즘은 학습에 대한 수렴성과 인식률이 낮은 것을 알 수 있다.

<표 2>에서 알 수 있듯이 제안된 생리학적 퍼지 신경망은 학습 시간, 수렴성 그리고 인식률이 기존의 학습 알고리즘보다 정확성이 요구되는 영상 인식 분야에 있어서 효율적이라는 것을 알 수

있다. [그림 8]은 세포 학습과 암세포 추출 결과를 나타내었다.



(a) 암 세포 학습화면

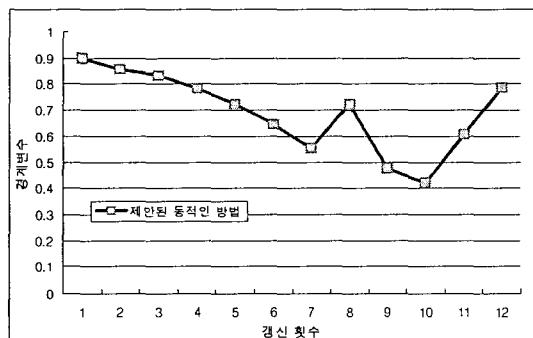


(b) 암 세포 추출 결과 화면

[그림 8] 암 세포 학습 및 추출 결과

[그림 9]는 제안된 생리학적 퍼지 신경망에서 동적으로 조정되는 경계 변수의 변화 과정을 나타내었다. 제안된 생리학적 퍼지 신경망에서는 서로 다른 패턴들이 유사성이 인정되어도 학습 패턴의 목표값과 저장패턴의 목표값과 비교하여 같은 경우에는 경계 변수를 감소시키고 다른 경우에는 경계 변수를 증가시키므로 서로 다른 패턴들이 같은 클러스터로 분류되지 않았고 유사한 패턴들은 같은 클러스터로 분류되었다. 그리고 퍼지 신경망에서 학습 파라미터를 정적으로 설정하는 것 보다

저장 패턴들과 학습 패턴간의 유사성과 경계 변수의 차이를 이용하여 학습 파라미터를 동적으로 설정하는 것이 기관지 편평암 세포 인식에 효율적인 것을 확인하였다.



[그림 9] 경계 변수 변화 과정

4.2 차량 번호판 인식

일반적으로 차량 영상의 번호판 추출 및 인식에 있어서 번호판의 특징은 알고리즘의 구성에 있어서 중요한 요소이다. 차량 영상 및 번호판 영역의 구조적인 특징은 다음과 같다(Kim ad Jang, and Kim, 2003).

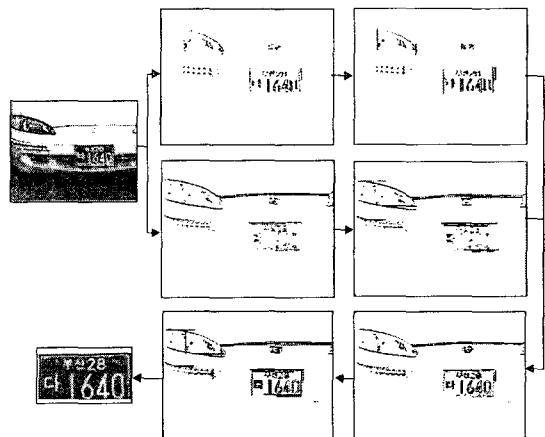
[조건 1] 번호판의 종횡 비율은 2 : 1이고 직사각형의 형태를 갖는다.

[조건 2] 번호판 영역은 문자와 숫자의 표현으로 다른 영역에 비해 밀도가 높다.

[조건 3] 번호판 내의 문자와 숫자는 일정한 위치 정보와 간격을 가진다.

차량 번호판 인식에서는 원 차량 영상을 그레이 영상으로 변환하고, 1차 미분을 이용하여 수평과 수직 에지를 추출하는 마스크로 수평 및 수직 에지를 추출한다. 그리고 이 수평과 수직 에지를 이

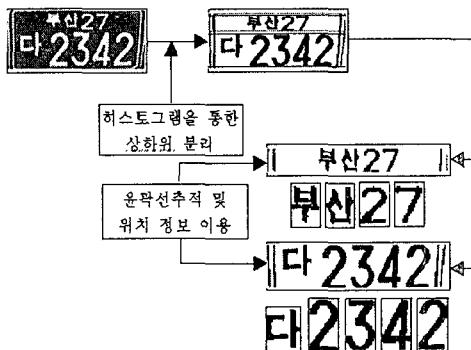
용하여 형태학적인 분석으로 직사각형의 형태가 나타나면 번호판의 후보 영역으로 설정한다. 여기서 직사각형 모양을 찾기 위해서 수평과 수직 에지가 만나는 점을 탐지하고, 이 점이 가지는 방향으로 에지를 연결하여 직사각형 모양을 탐지한다. 탐지된 직사각형들 중 크기가 하한 임계치보다 작은 경우에는 주위의 직사각형과 병합하고, 직사각형의 크기가 상한 임계치보다 큰 경우에는 밀도 비율을 조사하여 일정하지 않으면 직사각형을 분리한다. 이 방식에서 탐지된 직사각형들을 후보 영역으로 설정하고, 조건1과 조건2의 특징을 만족하는 후보 영역을 번호판 영역으로 추출하였다. 차량 번호판을 추출하는 과정은 [그림 10]과 같다.



[그림 10] 차량 번호판 추출 과정

추출된 번호판에서 개별 문자를 추출하기 위해서 히스토그램을 이용한 방법, 위치 정보를 이용하는 방법, 그리고 윤곽선 추적 알고리즘을 이용하는 방법 등을 병합하여 개별 문자를 추출하였다. [그림 11]은 개별 문자의 추출 과정을 나타내었다. 추출된 번호판 영역을 이진화할 때, 문자와 배경의 비율이 약 3 : 7의 비율을 가진다. 번호판 영역에

대한 색상 히스토그램을 약 3 : 7 정도의 분리 지점을 임계치로 설정하여 이진화 하였다. 이진화된 영상에 대해 히스토그램을 이용하여 상위와 하위 영역으로 분리하였다. 분리된 영역에 대해서 위치 정보에 따라 추출하고, 추출된 영역을 윤곽선 추적과 잡음을 제거해주는 알고리즘을 적용하여 개별 문자를 추출하였다.

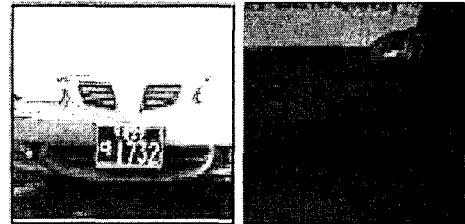


[그림 11] 차량 개별 문자 추출 과정

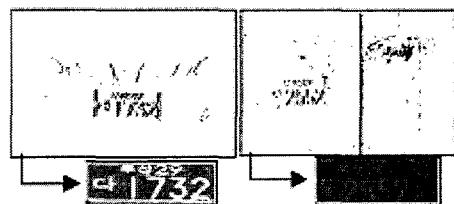
차량 번호판 인식 실험에서는 트루 컬라의 차량 영상 155개와 그레이 차량 영상 100개를 대상으로 실험하였다. 여기서 트루 컬라 영상 중 5개는 컨테이너 차량 영상이고 그레이 차량 영상은 시청의 전용차선 감시 카메라에서 촬영한 영상이다. 차량 번호판의 추출 개수를 <표 3>으로 나타내었고 추출 결과는 [그림 12]와 같다.

<표 3> 번호판 추출 개수

영상종류		제안된 차량 번호판 추출 결과
추출 갯수	트루 컬러 영상 (155)	155
	그레이 영상 (100)	100



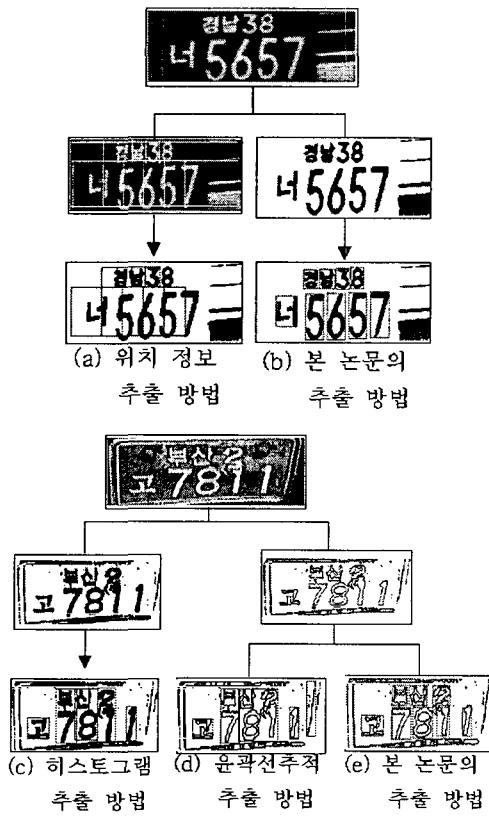
(a) 원본 차량



(b) 번호판 추출 결과

[그림 12] 차량 번호판 추출 결과

[그림 13]은 추출된 번호판 영역에서 개별 문자를 추출하는 과정을 나타내었다. 두 개의 추출된 번호판 영역에 대해서 하나는 위치 정보를 이용한 문자 추출을 적용하여 개별 문자 추출에 실패한 경우이다. 다른 하나는 히스토그램을 이용한 문자 추출과 윤곽선 추적 알고리즘을 이용한 문자 추출 방법을 각각 적용하여 개별 문자의 추출에 실패한 경우이다. [그림 13]에서 첫 번째의 번호판 영역은 번호판의 주변 영역이 같이 추출되어 번호판 고유의 위치정보만으로는 제대로 추출할 수가 없다. 그리고 두 번째의 번호판 영역의 경우는 번호판 영역이 심하게 훼손되었을 뿐만 아니라, 추출된 번호판이 기울어져서 잡음이 많이 발생하여 히스토그램을 이용한 방법과 윤곽선 추적을 이용한 방법으로는 개별 문자의 추출에 실패한 경우이다. 그러나 본 논문에서 적용된 개별 문자 추출 방법은 기존의 개별 문자 추출 방법들의 단점을 서로 보완하면서 두 개의 번호판 영역에서 개별 문자가 모두 추출되었다.



[그림 13] 개별 문자 추출 결과

<표 4>는 개별 문자의 추출 개수를 나타내었다. <표 4>에서 총 개별 문자 개수는 추출된 번호판에서의 총 개별 문자의 개수이다.

<표 4> 개별 문자 추출 결과

	추출된 번호판의 총 문자 개수	개별 문자 추출 개수
관찰관청 기호	510	500
차종별 기호	453	446
용도별 기호	255	255
등록번호	1020	1020
총 계	2238	2221

추출된 개별 문자 2221개를 16×16 크기로 정규화하여 기존의 학습 알고리즘들과 제안된 학습 알고리즘간의 학습 시간을 비교 분석하였다. 기존의 학습 알고리즘들과 제안된 학습 알고리즘간의 학습 시간을 비교하여 <표 5>로 나타내었다.

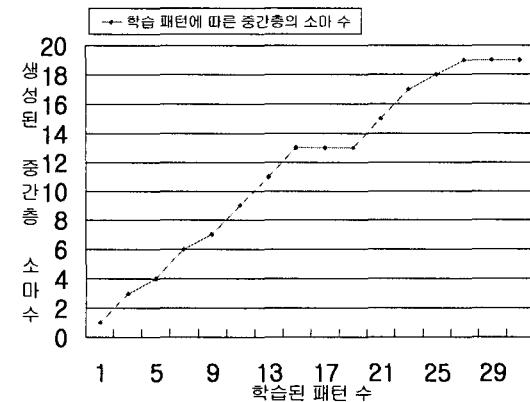
<표 5> 각 학습 알고리즘간의 최적의 학습 시간 및 중간층 소마 개수 비교

구분 알고리즘	학습 시간	중간층의 소마 수
오류 역전파 알고리즘(BP)	관찰관청 기호 25(min) 23(sec)	44
	차종별 기호 13(min) 11(sec)	35
	용도별 기호 34(min) 32(sec)	27
	등록번호 24(min) 22(sec)	67
ART1 기반 자기 생성 지도 학습 알고리즘 (ASSLLA)	관찰관청 기호 12(min) 10(sec)	115
	차종별 기호 25(min) 23(sec)	91
	용도별 기호 47(min) 45(sec)	51
	등록번호 38(min) 36(sec)	149
ART2 기반 RBF 네트워크 (ARBFN)	관찰관청 기호 23(min) 21(sec)	78
	차종별 기호 11(min) 9(sec)	63
	용도별 기호 27(min) 25(sec)	38
	등록번호 8(sec) 7(min)	84
제안된 생리학적 퍼지 신경망 (PFNN)	관찰관청 기호 48(sec) 18(min)	53
	차종별 기호 13(sec) 10(min)	39
	용도별 기호 49(sec) 5(min)	19
	등록번호 18(sec) 23(min)	61

오류 역전파 알고리즘에서는 초기 연결 가중치의 범위를 -1과 1사이의 범위로 설정하였으며, 학습률과 모멘텀을 각각 0.5로 설정하였다. 그리고 은닉층의 소마수를 관찰 관청 기호에서는 44개, 차종별 기호에서는 35개, 용도별 기호에서는 27개 등록번호에서는 67개로 설정하는 것이 최적의 학습 결과로 나타났다. ART1 기반 자가 생성 지도 학습 알고리즘에서는 입력층과 은닉층 사이의 학습 구조로 ART1 알고리즘을 사용하므로 은닉층과 출력층 사이의 연결 가중치만 -1과 1사이의 임의의 값으로 초기화하였다. 그리고 학습률과 모멘텀은 0.5와 0.6으로 설정하였다. 그리고 중간층의 소마를 생성 또는 개신하는데 사용되는 경계 변수는 경험적으로 실험하여 관찰관청 기호에서는 0.8, 차종별 기호에서는 0.90, 용도별 기호에서는 0.8 그리고 등록 번호에서는 0.85로 설정하는 것이 최적으로 나타났다. ART2 기반 RBF 네트워크에서의 경계 변수는 관찰관청 기호에서는 0.2, 차종별 기호에서는 0.1 용도별 기호에서는 0.2 그리고 등록 번호에서는 0.15로 설정하는 것이 최적으로 나타났다. 제안된 생리학적 퍼지 신경망에서는 초기 경계 변수를 경험적으로 실험하여 관찰관청기호와 용도별 기호에서는 0.8로 설정하였고, 차종별 기호와 등록번호에서는 0.9로 설정하였다. 표 5에서 학습 판정은 모든 패턴들의 실제 출력 벡터와 목표 벡터의 차이의 절대값이 0.1보다 적거나 같으면 학습을 종료하도록 하였다. 표 5에서 알 수 있듯이 제안된 생리학적 퍼지 신경망이 기존의 ART1 기반 자가 생성 지도 학습 알고리즘과 ART2 기반 RBF 네트워크 보다 중간층이 적게 생성되었고 학습 시간도 적게 소요되는 것을 확인할 수 있다. ART1 기반 자가 생성 지도 학습 알고리즘은 중간층을 생성하는 과정에서 입력 패턴과 클러스터의 대표 패턴간의 유사성 측정 방법과 경계 변수 설정

에 따라 서로 다른 패턴이 같은 클러스터로 분류되거나 같은 패턴들이 서로 다른 클러스터로 분류되어 중간층의 소마 수가 많이 생성되었고 제안된 퍼지 신경망과 ART2 기반 RBF 네트워크보다 학습 시간이 많이 소요되었다. ART2 기반 RBF 네트워크는 중간을 생성하는 방법으로 ART2 알고리즘을 적용한다. 그러나 ART2 알고리즘을 중간층으로 적용할 경우에는 입력 벡터와 연결 가중치 벡터간의 평균에 의해 가중치를 조정하므로 입력 패턴들의 특징이 감소하여 제안된 생리학적 퍼지 신경망보다 중간층의 소마수가 많이 생성되었다.

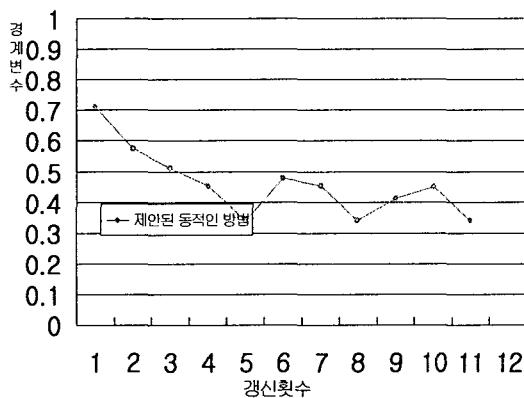
제안된 생리학적 퍼지 신경망에서 용도별 학습 패턴 수에 따른 중간층에서 생성되는 소마 수를 [그림 14]로 나타내었다.



[그림 14] 용도별 학습 패턴 수에 따른 생성된 중간층 소마수

[그림 15]는 제안된 생리학적 퍼지 신경망에서 동적으로 조정되는 경계 변수의 변화 과정을 나타내었다. 제안된 생리학적 퍼지 신경망에서는 서로 다른 패턴들이 유사성이 인정되어도 학습 패턴의 목표값과 저장패턴의 목표값과 비교하여 같은 경우에는 경계 변수를 감소시키고 다른 경우에는 경

계 변수를 증가시키므로 서로 다른 패턴들이 같은 클러스터로 분류되지 않았고 유사한 패턴들은 같은 클러스터로 분류되어 기존의 학습 방법 보다 학습 시간이 적게 소요되었다.



[그림 15] 경계 변수 변화 과정

개별 문자 추출 방법에 의해 추출된 개별 문자들에 대해 기존의 학습 알고리즘과 제안된 생리학적 페지 신경망으로 인식한 결과를 <표 6>으로 나타내었다. <표 6>에서 기존의 신경망 보다 제안된 생리학적 페지 신경망의 인식률이 개선된 것을 알 수 있다.

<표 6> 학습 알고리즘간의 인식률 비교

인식개수 패턴종류	BP	(ASSLLA)	(ARBFN)	PFNN
관할공청 기호(500)	489	495	497	499
용도별기호 (255)	253	255	255	255
차종별기호 (446)	438	440	444	445
등록번호 (1020)	1019	1020	1020	1020

4. 결론 및 향후 연구 방향

본 논문에서는 신경계(nervous system)의 생리학적 뉴런들에 대해 기능적인 특성을 분석하여 페지 논리에 의한 뉴런 구조를 표현하였으며, 제시된 새로운 뉴런 구조로는 페지 논리합에 의한 흥분 뉴런 구조, 페지 논리곱에 의한 전방향 억제 뉴런 구조, 그리고 페지 논리 부정에 의한 역방향 억제 개재 뉴런 구조 등이 있다. 제시된 페지 논리에 의한 뉴런 구조를 바탕으로 생리학적 페지 지도 학습 알고리즘을 제안하여 생리학적 페지 신경망에 적용하였다. 제안된 생리학적 페지 신경망의 학습 구조는 입력층, 학습 데이터의 특징을 분류하는 중간층, 그리고 출력층으로 구성된다. 제안된 생리학적 페지 신경망은 입력층과 중간층 사이의 학습 구조로 경계 변수를 동적으로 조정하는 페지 ART 알고리즘을 적용하였고 중간층과 출력층 사이의 학습 구조로 생리학적 페지 지도 학습 알고리즘을 적용하였다.

제안된 생리학적 페지 신경망의 학습 및 인식 성능을 분석하기 위하여 기관지 편평암 인식과 차량 번호판 인식에 적용하였다. 기관지 편평암 세포 인식에서는 정상 세포와 암세포 각각 50개를 추출하여 학습한 결과, 오류역전파 알고리즘, ART1 기반 알고리즘 그리고 ART2 기반 RBF 네트워크 보다 학습 시간이 적게 소요되었다 ART2기반 RBF 네트워크는 오류 역전파의 수렴성 문제를 해결하기 위해 제안된 것으로 영상 인식에 이용되고 있지만 암세포와 같이 정확성을 요구하는 영상 인식 분야에는 적합하지 않은 것으로 실험에서 확인하였다. 그러나 제안된 생리학적 페지 신경망은 학습 시간, 수렴성 그리고 인식률이 기존의 학습 알고리즘보다 정확성이 요구되는 영상 인식 분야에 있어서 효율적이라는 것을 확인하였다.

차량 번호판 인식에서는 자가용 차량, 승합용 차량, 컨테이너 차량을 대상으로 학습 및 인식 성능을 실험하였다. 255대의 차량 영상에 대해서 255 대의 번호판 영역이 추출되었고 2238개의 개별 문자 중에서 2221개의 개별 문자가 추출되었다. 추출된 2221개의 개별 문자는 관찰 관청 기호 500개, 용도별 기호 255개, 차종별 기호 446 그리고 등록번호 1020개이다. 추출된 2221개의 문자를 각 알고리즘에 적용하여 학습 및 인식률을 비교하였다. ART1 기반 자가 생성 지도 학습 알고리즘은 중간 층을 생성하는 과정에서 입력 패턴과 클러스터의 대표 패턴간의 유사성 측정 방법과 경계 변수 설정에 따라 서로 다른 패턴이 같은 클러스터로 분류되거나 같은 패턴들이 서로 다른 클러스터로 분류되어 중간층의 소마 수가 많이 생성되었고 제안된 퍼지 신경망과 ART2 기반 RBF 네트워크보다 학습 시간이 많이 소요되었다. ART2 기반 RBF 네트워크는 입력 벡터와 연결 가중치 벡터간의 평균에 의해 가중치를 조정하므로 입력 패턴들의 특징이 감소하여 제안된 생리학적 퍼지 신경망보다 중간층의 소마수가 많이 생성되었다. 제안된 생리학적 퍼지 신경망에서는 서로 다른 패턴들이 유사성이 인정되어도 학습 패턴의 목표값과 저장패턴의 목표값과 비교하여 같은 경우에는 경계 변수를 감소시키고 다른 경우에는 경계 변수를 증가시키므로 서로 다른 패턴들이 같은 클러스터로 분류되지 않았고 유사한 패턴들은 같은 클러스터로 분류되어 기존의 학습 방법 보다 학습 시간이 적게 소요되었다. 인식 성능에서도 기존의 신경망보다 제안된 퍼지 신경망의 인식률이 향상된 것을 확인하였다.

향후 연구 방향은 신경계의 뇌 구조와 신경 구조를 체계적으로 연구한 후에 뉴런의 동작 과정을 수학적으로 증명하여 안정성 있는 학습 및 분

류성이 뛰어난 지능적인 알고리즘을 연구할 것이다. 그리고 퍼지 신경망과 밀접한 관련이 있는 의학 분야의 적용은 거의 없었다. 그러므로 본 논문에서 연구한 내용들을 기반으로 조기 위암의 내시경 영상 분석에 적용할 수 있는 조기 위암 내시경 분석 및 진단 시스템을 개발하는 것이 궁극적인 과제이다.

참고문헌

- [1] Lippmann, R. O. "An Introduction to Computing with Neural Nets," IEEE, ASSP Magazine (1987), 2-22.
- [2] Philip, D. and Wasserman, Neural Computing, V. N. Reinhold (1989), 1-10.
- [3] Dayhoff and Judith E.. Neural Network Architectures : An Introduction, V. N. Reinhold, N. Y. 1990
- [4] Lin, C. T., Neural Fuzzy Control Systems with Structure and Parameter Learning, World Scientific (1994), 1-10,
- [5] Kruse, R., Gebhardt, J. and Klawonn, F., Foundations of Fuzzy Systems, John Wiley & Sons. 1995
- [6] Grabisch M. and Nicolas, J. M., "Classification by fuzzy integral: Performance and tests," Fuzzy Sets and Systems an International Journal, Vol.65, No1-3 (1994), 255-271.
- [7] Gupta, M. M. and Qi, J. "Fuzzy Neuron Models," in Proc. IJCNN, Vol.2(1991), 431-435.
- [8] Takagi, H. "Fusion Technology of Fuzzy Theory and Neural Networks-Survey and Future Direction," in Proc. IIZUKA, 1990.

- [9] Hsu, L. S. et als, "Fuzzy Neural-Logic System," in Proc. IJCNN, Vol.1(1992), 245-250.
- [10] Halgamuge S. K. and Glesner, M. " Neural networks in designing fuzzy systems for real world application," Fuzzy Sets and Systems an International Journal, Vol.65(1994), No1-3, 1-18.
- [11] Caminhas, W. M., Tavares, H. and Gomide, F. "Competitive Learning of Fuzzy, Logical Neural Networks," in Proc. IFSA, Vol.2 (1994), 639-642.
- [12] Kim, K. B., Joo, Y. H. and Cho, J. H. "An Enhanced Fuzzy Neural Network," Lecture Notes in Computer Science, LNCS 3320(2004), 176-179.
- [13] Kim, K. B., Kang, M. H. and Cha, E. Y. "A Fuzzy Competitive Backpropagation using Nervous System," in Proc. WCSS'97 (1997), 188-193.
- [14] Cheung, et al., "Relative Effectiveness of Training Set Patterns for Backpropagation," in Proc. IJCNN, Vol.1(1990), 673-678.
- [15] Takechi, H. and Murakami, K. "Some Properties of Multilayer Neural Networks with Different Learning Coefficients for Each Layer," in Proc. IJCNN, Vol.2(1993), 545-548.
- [16] 김광백, 김영주, "동적인 임계화 방법과 개선된 학습 알고리즘의 신경망을 이용한 차량 번호판 인식," 정보처리학회논문지B, Vol.9-B, No.1(2002), 119-128.
- [17] Kothari, M. L., Madnani, S. and Segal, R. "Orthogonal Least Square Learning Algorithm Based Radial Basis Function(RBF) Network Adaptive Power System Stabilizer," in Proc. IEEE SMC, Vol.1 (1997), 542-547.
- [18] Kim, K. B., Kim, Y. J. and Oh, A. S. . "An Intelligent System for Passport Recognition Using Enhanced RBF Network," Lecture Notes in Computer Science, LNCS 3314, Springer-Verlag (2004), 762-767.
- [19] Grossberg, G. A., Grossberg, S. and Reynolds, J. H., "ARTMAP: Supervised Real-time Learning and Classification of Nonstationary Data by a Self-organizing Neural Network," Neural Networks, Vol.4(1991), 565-588.
- [20] 김광백, 김철기, 김정원 (2002). "윤곽선 추적 알고리즘과 개선된 ART1을 이용한 영문 명함 인식에 관한 연구," 한국지능정보시스템 학회논문지, 제8권, 2호, pp.105-116.
- [21] Pandya A. S. and Macy R. B. Neural Networks for Pattern Recognition using C++, IEEE Press and CRC Press. 1995.
- [22] Kim, K. B. and Kim, C. K.. "Performance Improvement of RBF Network using ART2 Algorithm and Fuzzy Logic System," Lecture Notes in Artificial Intelligence, LNAI 3339 (2004), 853-860.
- [23] Grossberg, C. and Grossberg, S., Neural Networks for Vision and Image Processing, Massachusetts Institute of Technology(1992), 46-91.
- [24] Kim, K. B. and Kim, Y. J., "Recognition of English Calling Cards by Using Enhanced Fuzzy Radial Basis Function Neural Networks," IEICE Trans. Fundamentals of Electronics, Communications and Computer Sciences, Vol.E87-A, No.6(2004), 1355-1362.
- [25] Kuffer, S. W., Nicholls, J. G. and Martin, A. R. From Neuron to Brain : A Celluar Approach to the Function of the Nervous System, 2nd ed. Sunderland, Mass. : Sinauer. 1984.
- [26] Kim, K. B., Kang, M. H. and Cha, E. U., "A

- Fuzzy Self-Organized Backpropagation using Nervous System," in Proc. IEEE SMC, Vol.5(1997), 1457-1462.
- [27] 김광백. "Passport Recognition using Fuzzy Binarization and Enhanced Fuzzy RBF Network," 퍼지 및 지능 시스템학회 논문지, 제14권, 제2호 (2004), 222-227.
- [28] 김광백. "윤곽선 추적과 개선된 ART1 기반 자가 생성 지도 학습 알고리즘을 이용한 운송 컨테이너 영상의 식별자 인식," 한국지능정보시스템학회논문지, 제9권, 3호 (2003), 49-64.
- [29] 김광백, 김영주, "Recognition of Car Plate using Gray Brightness Variation, HIS Information and Enhanced ART2 Algorithm," 퍼지 및 지능 시스템학회 논문지, 제11권, 5호(2001), 379-387.
- [30] 이중달, "Diagnostic Cytology," 고려 의학. 1989.
- [31] Kim, K. B. and Yun, H. W., "A Study on Recognition of Bronchogenic Cancer Cell Image Using a New Physiological Fuzzy Neural Networks," Japanese Journal of Medical Electronics and Biological Engineering, Vol.13, No.5(1999), 39-43.
- [32] 김광백. "Self-generation을 이용한 퍼지 지도 학습 알고리즘," 멀티미디어학회논문지, 제6권, 7호(2003), 1312-1320.
- [33] Kim, K. B., Jang, S. W. and Kim, C. K., "Recognition of Car License Plate by Using Dynamical Thresholding Method and Enhanced Neural Networks," Lecture Notes in Computer Science, LNCS 2756 (2003), 309-319.

Abstract

Physiological Fuzzy Neural Networks for Image Recognition

Kwang-Baek Kim* · Yong-Eun Moon** · Choong-Shik Park***

The Neuron structure in a nervous system consists of inhibitory neurons and excitatory neurons. Both neurons are activated by agonistic neurons and inactivated by antagonist neurons. In this paper, we proposed a physiological fuzzy neural network by analyzing the physiological neuron structure in the nervous system. The proposed structure selectively activates the neurons which go through a state of excitement caused by agonistic neurons and also transmit the signal of these neurons to the output layers. The proposed physiological fuzzy neural networks based on the nervous system consists of a input player, and the hidden layer which classifies features of learning data, and output layer. The proposed fuzzy neural network is applied to recognize bronchial squamous cell carcinoma images and car plate images. The result of the experiments shows that the learning time, the convergence, and the recognition rate of the proposed physiological fuzzy neural networks outperform the conventional neural networks.

Key words : Nervous System, Agonistic Neuron, Antagonist Neurons, Physiological Fuzzy Neural Network, Bronchial Squamous Cell Carcinoma Images, Car Plate Images

* Dept. Computer Engineering, Silla University

** Dept. of MIS, Silla University

*** Dept. of Computer Engineering, Yongdong University

