

보로노이 공간분류를 이용한 오류 역전파 신경망의 설계 방법

A Design Method for Error Backpropagation neural networks using Voronoi Diagram

백주현* · 김홍기

Ju-Hyun Back* and Hong-Gi Kim

*군산대학교 경영전산학부, 충북대학교 컴퓨터 과학과

요 약

본 논문에서는 보로노이 다이아그램을 이용하여 오류 역전파 신경망의 초기값을 결정할 수 있는 VoD_EBP를 제안하였다. VoD_EBP는 초기 연결 가중치와 임계값을 공학적 계산방법으로 결정함으로써 기존의 EBP에서 자주 발생하는 학습 마비 현상을 피할 수 있고, 초기부터 빠른 속도로 학습이 진행되므로 학습횟수를 단축시킬 수 있다. 또한 VoD_EBP는 은닉층의 노드 수를 보로노이 다각형으로 구분된 클러스터들의 개수로 정할 수 있어 신경망 설계에 신뢰성을 향상시켰다. 제시된 VoD_EBP의 효율성을 입증하기 위해 간단한 실험으로 2차원 입력벡터를 갖는 XOR 문제와 3차원 패리티 코드 검출 문제에 대하여 적용하여 보았다. 그 결과 임의의 초기값으로 설정하였던 EBP보다 훨씬 빠르게 학습이 종료되었고, 지역 최소치에 빠져 학습이 진행되지 못하는 현상이 발생하지 않았다.

ABSTRACT

In this paper, a learning method VoD_EBP for neural networks is proposed, which learn patterns by error back propagation. Based on Voronoi diagram, the method initializes the weights of the neural networks systematically, which results in faster learning speed and alleviated local optimum problem. The method also shows better the reliability of the design of neural network because proper number of hidden nodes are determined from the analysis of Voronoi diagram. For testing the performance, this paper shows the results of solving the XOR problem and the parity problem. The results were showed faster learning speed than ordinary error back propagation algorithm. In solving the problem, local optimum problems have not been observed.

1. 서 론

신경망은 전문가의 지식, 경험 등이 위상적인 특성에 따라 불안정한 초기 상태의 네트워크 형태로 저장된 후 샘플이나 외부 입력으로부터 시간이 경과함에 따라 유니트의 출력과 상호 연결 가중치가 변하는 동적인 시스템이다. 여기에는 위상적인 특성, 유니트의 특성, 그리고 학습시키는 전략등에 따라 다양한 구조가 존재한다. 따라서 응용 분야에 신경망을 적용하기 위해서는 적합한 모델과 학습규칙을 선정하는 것이 무엇보다 중요한데 다중 퍼셉트론의 구조를 갖는 오류 역전파 신경망(Error BackPropagation Network, 이하 EBP)은 일반화된 델타 학습 규칙을 적용하여 제어에 관련된 문제 해결과 정제된 데이터의 인식 문제에 있어 매우 훌륭한 성능을 나타내는 모델이다[1-3].

그러나 이 방법은 입력노드와 출력노드의 수를 문제의 특성에 따라 결정하는 것이 가능하지만, 은닉층 노드의 수는 전적으로 설계자의 경험에 의존한다. 또

한 초기 연결 가중치 및 임계값은 일정 영역의 실수에서 임의로 선택하게 되어, 잘못된 초기 설정에 의해 학습속도가 현저히 멀어지거나 지역 최소치(Local Minima)에 빠질 가능성으로 인해 학습에 실패할 수 있다는 것은 이미 잘 알려진 사실이다. 이를 해결하기 위하여 경험적 지식에 의한 방법으로 경사치의 재사용, 동적 학습률 적용, 또는 학습 순서 및 입력 자료 표현의 재조정, 학습규칙인 델타규칙의 수정등의 많은 연구가 진행되어 왔다[2-8].

한편 1993년 Bose와 Garga는 표준 패턴간의 거리를 유클리드 거리로 가정하여 보로노이(Voronoi) 공간 분류를 이용하여 초기 가중치를 결정하는 방법과 은닉층의 노드 수를 정할 수 있는 새로운 신경망 설계 방법을 제안하였는데[9], 주어진 패턴 부류에 대한 클래스를 보로노이 다각형으로 분할하여 이들의 경계선 방정식으로부터 초기 연결 가중치와 은닉층의 정보를 획득한다. 그러나 이 방법으로 설계된 신경망은 이미 결정된 구조에서 역치함수로 네트워크의 정보를 전달

하므로 새로운 데이터에 대한 학습 능력이 부여되지 않는 문제점이 있다. 따라서 본 연구에서는 시그모이드 함수를 사용하여 학습 가능한 EBP 신경망 설계를 보로노이 다이아그램(Voronoi Diagram, 이하 VoD)을 통해 얻은 초기값으로 결정하는 VoD_EBP를 제시하고자 한다[10].

VoD_EBP는 Bose가 제안한 신경망 설계기법에 따라 초기 연결가중치와 임계값을 VoD의 경계선에 대한 방정식의 계수로, 은닉층의 존재 여부와 노드의 수는 보로노이 다각형으로 구분된 클러스터들에 의해 정해 준다. 이와 같이 공학적 방법으로 초기값을 설정하여 줌으로써 지역최소치에 빠질 가능성이 많은 EBP의 단점을 보완할 수 있다.

2. 보로노이 다이아그램을 이용한 신경망 설계 방법

보로노이 다각형이란 집합 S 에서 어떠한 다른 점보다도 P 에 근접한 점 (x, y) 의 자취를 말하며, d 차원에 주어진 n 개의 점에 대해 보로노이 다각형으로 분할한 것을 VoD라 한다. 평면상에 주어진 n 개의 점으로부터 VoD를 구하는 방법은 Grahams Scan, Jarvis's march, Divide & Conquer Algorithm, Dynamic Convex hull Algorithm 등을 이용할 수 있다[11-14].

d 차원 특징공간에서 k 개의 서로 다른 클래스에 속하는 패턴집합이 있을 때 Bose와 Garga는 보로노이 다각형이 각각의 패턴을 나타내는 것으로 표현하여 신경망을 구성하는 방법을 제시하였는데, VoD를 이용한 신경망 구성은 크게 다음의 3단계로 구분할 수 있다.

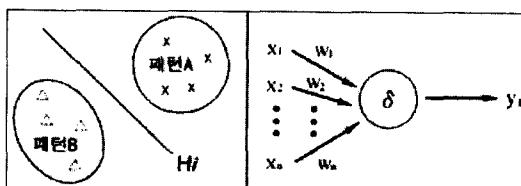


그림 1. 초평면 $H_i = \omega_1\chi_1 + \omega_2\chi_2 + \dots + \omega_n\chi_n + \delta = 0$ 으로 분할하는 경우

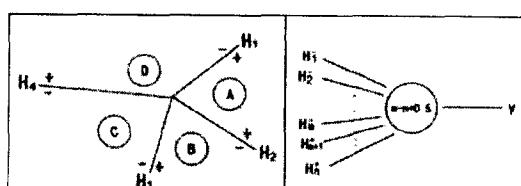


그림 2. 모든 패턴이 선형분리 가능한 경우

단계 1. 임의의 입력패턴이 A, B 두 클래스중 어느 것에 속하는지를 판정할 수 있는 단층 퍼셉트론의 경우에 이를 선형 분리하는 초평면의 방정식을 $H_i = \omega_1\chi_1 + \omega_2\chi_2 + \dots + \omega_n\chi_n + \delta = 0$ 이라 하자. 방정식으로부터 신경망을 구성하는 뉴런의 연결 가중치는 방정식의 계수인 $\omega_1, \omega_2, \dots, \omega_n$ 으로 결정하고, 임계값은 δ 를 이용하여 그림 1과 같이 결정한다.

단계 2. 분류할 패턴이 여러 개이고 이들이 모두 선형 분리가 가능하다면 보로노이 경계선을 나타내는 몇 개의 초평면의 방정식을 통하여 단계 1에서와 같이 입력층의 뉴런에 대한 연결 가중치 및 임계값을 결정하고, 각각의 클러스터는 둘러싸인 경계선을 기준으로 그림 2와 같이 양의 영역, 음의 영역으로 구분한다.

입력층에서 관련된 경계선의 영역에 의해 논리적 AND 연산으로 결합하여 출력층으로 정보를 전달하는데 초평면의 반폐구간에 따라 $H > 0$ 인 양의 영역에서의 뉴런 연결은 1, $H < 0$ 인 음의 영역에서의 뉴런 연결은 -1로 결정하고 출력층 뉴런의 임계값은 $m - n + 0.5$ 의 계산값으로 결정한다. 여기서 m 은 $H < 0$ 에 속하는 경우의 뉴런 수이고 n 은 전체 연결 뉴런 수이다.

단계 3. 하나의 패턴이 두개 이상의 클러스터들로 표현되는 경우 즉, 각 클래스들의 구분이 선형적으로 분리가 불가능한 경우 은닉층이 존재하는 3층의 신경망으로 구성한다. 입력층으로부터 은닉층으로의 정보는 단계 1, 2에 따르고, 은닉층에서 출력층으로의 정보는 논리적 OR 연산으로 결합하여 계산한다.

그림 3에서와 같이 2차원 입력벡터에 대한 배타적 논리합을 구하는 경우 클래스 S_1 은 $(0, 0)$ 과 $(1, 1)$ 의 영역을 갖는 클러스터의 합집합과 $(1, 0)$ 과 $(0, 1)$ 의 영역을 갖는 클러스터의 합집합을 갖는 S_2 로 구분된다. 따라서 이를 영역을 구분하는 경계선의 방정식 $H_1 = \chi_1 - 0.5$, $H_2 = \chi_2 - 0.5$ 으로부터 단계 1, 2에서와 같이 입력층과 은닉층까지의 초기값을 결정한다. 즉 각각의 반폐구간 영역으로부터 클래스 $S_1 = (H_1^+ \cap H_2^-) \cup (H_1^- \cap H_2^+)$ 와 $S_2 = (H_1^- \cap H_2^+) \cup (H_1^+ \cap H_2^-)$ 으로 서로 떨어진 영역의 합집합으로 분류한 후 은닉층으로부터 출력층으로의 연결 가중치는 논리적 OR

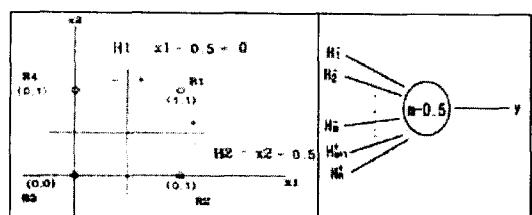


그림 3. 선형분리가 불가능한 경우

연산을 행한다. 이때 양의 영역으로 참여하는 연결에 대해서는 1, 음의 영역으로 참여하는 연결에 대해서는 -1로 정해주며 임계값은 $m = 0.5$ 로 계산한다. 여기서 m 은 1의 연결 가중치를 갖는 은닉 층의 뉴런 수이다. 또한 각 층에서의 뉴런의 활성화 함수로는 역치함수 즉,

$$i_0 = f(\text{net})$$

$$f(\text{net}) = \begin{cases} 1, & \text{net} \geq 0 \\ 0, & \text{net} < 0 \end{cases}$$

을 이용하였다.

이 방법은 초기 연결 가중치와 임계값을 미리 결정하여 줄 뿐만 아니라 은닉층의 뉴런 개수를 공학적인 방법에 의하여 정할 수 있다는 면에서 기존의 신경망 설계에 많은 장점을 제공하고 있다[9].

3. VoD_EBP의 구성 및 특징

VoD_EBP에서는 시그모이드 함수를 정보 전달 함수로 사용한다. 시그모이드 함수 $y = \frac{1}{1 + e^{-(ax+b)}}$ 는 오류 역전파 신경망 모델에서 자주 적용되는 정보 전달 함수로써 계수 a, b 값에 의해 역치함수의 특성을 갖는 비선형 함수이다. VoD_EBP에서 시그모이드 함수를 정보 전달 함수로 사용한 이유는 다음과 같은 함수특성을 갖고 있기 때문이다. 첫째 계수 a 의 값을 무한히 크게 하면 기울기가 커져 역치함수와 유사한 형태가 되고, 계수 b 는 함수를 좌우로 평행 이동시키는 역치함수의 역치 효과를 갖기 때문이다. 따라서 Bose가 제안한 신경망에서 사용한 역치함수를 대체할 수 있다. 둘째 선형분리가 불가능한 다층 신경망에서는 뉴런의 활성 함수가 비선형일 필요가 있다. 왜냐하면 다층의 신경회로망에서 정보 전달 함수로 선형함수를 적용하면 연결 가중치의 조작을 통해 동일한 효과를 갖는 단층 신경회로망으로 변환할 수 있기 때문이다. 셋째 VoD_EBP에 학습 능력을 부여하기 위하여 미분과정이 요구되는 일반화된 텔타 학습 규칙을 적용하는데 시그모이드 함수는 미분 가능하고, 함수의 출력값이 아무리 크거나 작더라도 0~1범위이므로 신

경망의 어느 한 신경세포가 전체의 동작을 지배하게 되는 문제를 해결해 준다. 즉 연결된 여러 신경 세포들이 서로 비슷한 정도로 신경망의 동작을 결정하게 됨으로써 다수결의 원칙이 반영될 수 있다. 이와 같은 장점으로 시그모이드 함수를 VoD_EBP에 사용하고, 불안정한 초기값 설정으로 지역 최소치에 빠지기 쉬운 EBP의 단점을 보완하기 위해 Bose가 제안한 신경망의 설계 방법을 통해 초기 값을 정하여 네트워크를 안정화시킨다.

한편 EBP에서는 모든 노드를 완전 연결(Full connection)로 구성하였는데, VoD_EBP에서는 은닉층에서 출력층으로의 연결 가중치를 0으로 초기 값을 설정하여 줌으로써 출력에 관여하지 않는 불필요한 노드 정보를 미리 차단한다.

제안한 VoD_EBP의 전체 구조는 그림 4와 같으며 2장에서 기술한 바와 같이 초기의 입력층의 노드수 및 가중치, 은닉층의 노드수 및 가중치를 보로노이 경계 방정식에 의해 결정해 준다.

VoD_EBP를 Bose가 제안한 신경망, 기존의 EBP와 간략하게 비교하면 표 1과 같다.

4. 성능 비교 실험 및 결과

VoD_EBP의 성능 및 효율성을 기존의 EBP와 비교하기 위해 2차원 입력벡터에서의 XOR 문제와 3차원에서의 패리티 코드 검출 문제에 적용하였는데, VoD_EBP의 전체 신경망 구성과 실험 결과는 다음과 같다.

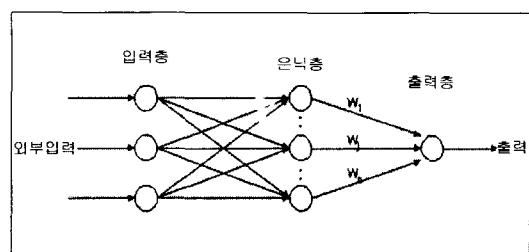


그림 4. 제안된 VoD_EBP의 전체 구조

표 1. VoD_EBP의 특징 비교

구분	Bose의 신경망	EBP	VoD_EBP
초기 연결 가중치 결정	체계적, "	임의의 값	체계적, "
초기 임계값 결정	"	"	"
은닉층 유니트 개수 결정	"	설계자 경험에 의존	"
정보 전달 방법	Step Function	Sigmoid Function	Sigmoid Function
학습능력	불가능	가능	가능

4.1.2 차원 입력벡터의 XOR 문제

XOR은 $S_1 = \{(0, 0), (4, 4)\}$ 인 경우에는 0, $S_2 = \{(4, 0), (0, 4)\}$ 인 경우 1로 출력하는 경우로, 선형적으로 분리가 불가능하기 때문에 VoD_EBP는 Bose가 제안한 단계 3의 과정에 의해 은닉층이 존재하는 신경망으로 구성한다. VoD에서의 경계선의 방정식은 각각 $H_1 = \chi_1 - 2$, $H_2 = \chi_2 - 2$ 이다. 따라서 각각의 클래스는 반폐구간 영역으로부터 $S_1 = (H_1^+ \cap H_2^-) \cup (H_1^- \cap H_2)$ 와 $S_2 = (H_1^- \cap H_2^+) \cup (H_1^+ \cap H_2^-)$ 으로 서로 떨어진 영역의 합집합으로 분류할 수 있다. 따라서 방정식의 계수와 임계값의 계산 방법에 의해 VoD_EBP의 전체 신경망은 다음 그림 5와 같이 구성된다.

한편 같은 조건의 성능 비교를 위해 기존의 EBP에

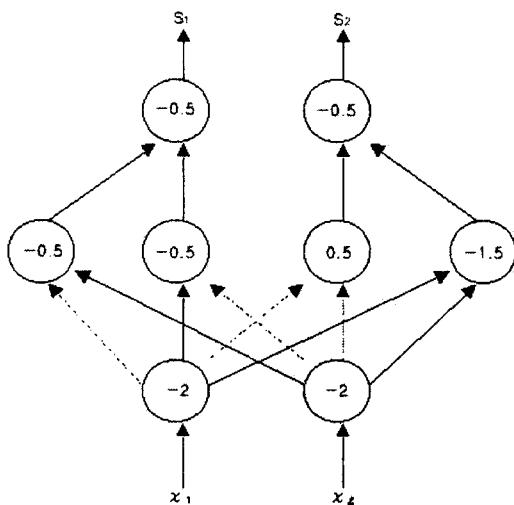


그림 5. XOR 문제에서의 VoD_EBP의 전체 구조

표 2. 학습횟수 비교표(허용오차 0.05)

학습률	0.3	0.5	0.7
VoD_EBP	1175	704	502
EBP 실행 (1)	15783	3082	5947
" (2)	7038	16374	2568
" (3)	5485	4376	3551
" (4)	5084	6573	2793
" (5)	8590	3375	3308
" (6)	4473	3065	2739
" (7)	8339	4186	3273
" (8)	11252	9343	3021
" (9)	9562	4905	2339
" (10)	14511	8538	2749
평균횟수	9011.7	6381.7	3228.8
편차	3864.4	4153.4	1023.7
성능비교	7.7 배 빠름	9.1 배 빠름	6.4 배 빠름

서도 마찬가지로 은닉층의 노드 수를 4개로 하였으며 초기 연결 가중치 및 임계값을 Turbo C++ 3.0에서 제공하는 난수 발생 함수를 이용하여 -1.0~1.0 사이의 값으로 설정하였다. 여러 경우의 결과를 비교하기 위해 학습 속도를 좌우하는 학습률(η)을 각각 0.3, 0.5, 0.7 등으로 변화를 주었고, 학습 종료 조건인 허용오차는 0.05 수준으로 하였다. 실험 결과 기존의 EBP는 임의로 설정된 초기 연결 가중치 및 임계값으로 인하여 몇 번의 학습 실패가 있었다.

표 2의 결과처럼 VoD_EBP는 기존의 EBP보다 매우 빠르게 학습이 종료되었고, 결정된 초기값을 이용하므로 학습횟수가 일정하지만 EBP는 상대적으로 매우 편차가 크다.

허용오차 0.05 이하가 될 때까지 학습진행 과정을 통하여 VoD_EBP와 EBP의 효율성을 비교하고자 출력오차의 평균제곱 합의 변화량을 그래프로 나타내면 그림 6와 같다.

4.2 3 차원 입력벡터의 패리티 코드검출 문제

$S_1 = \{(0, 0, 0), (1, 1, 0), (1, 0, 1), (0, 1, 1)\}$ 을 0, $S_2 = \{(1, 0, 0), (0, 1, 0), (0, 0, 1), (1, 1, 1)\}$ 을 1로 출력하는 짝수 패리티 코드 검출문제에 대해서도 같은 방법으로 실험을 하였다. VoD_EBP의 연결 가중치와 임계값은 경계면을 이루는 방정식 $H_1 = \chi_1 - 0.5$, $H_2 = \chi_2 - 0.5$ 와 $H_3 = \chi_3 - 0.5$ 의 계수로 정한다. 마찬가지로 각각의 클래스는 반폐구간 영역으로부터 $S_1 = (H_1^+ \cap H_2^- \cap H_3^-) \cup (H_1^- \cap H_2^+ \cap H_3^-) \cup (H_1^- \cap H_2^- \cap H_3^+) \cup (H_1^+ \cap H_2^+ \cap H_3^+)$ 과 $S_2 = (H_1^+ \cap H_2^+ \cap H_3^-) \cup (H_1^+ \cap H_2^- \cap H_3^+) \cup (H_1^- \cap H_2^+ \cap H_3^+) \cup (H_1^- \cap H_2^- \cap H_3^+)$ 으로 분류할 수 있다. 따라서 은닉층에 노드는 반폐구간 개수만큼 8개로 결정한다.

XOR 문제와 마찬가지로 방정식의 계수와 임계값의 계산방법에 의해 VoD_EBP의 전체 신경망의 구조는 그림 7과 같이 구성된다.

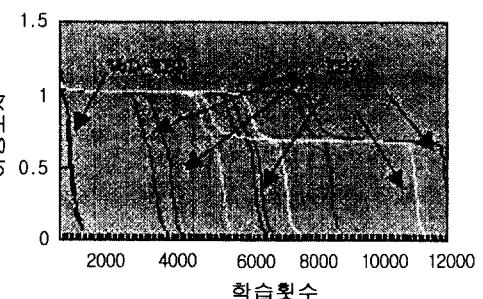


그림 6. XOR 문제에서의 학습 진행 과정

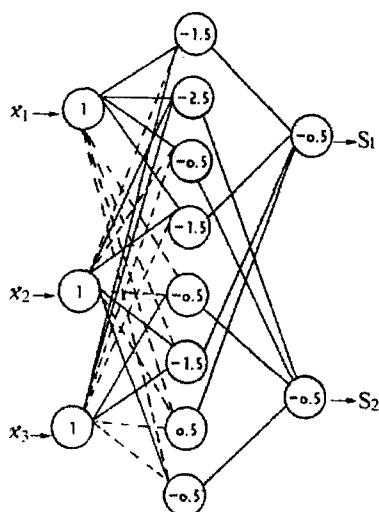


그림 7. 패리티 검출문제에서의 VoD_EBP의 전체 구조

표 3. 학습횟수 비교표(허용오차 0.1)

학습률	0.3	0.5	0.7
VoD_EBP	244	146	104
EBP 실행 (1)	16506	7289	15995
" (2)	17891	25367	12734
" (3)	20176	23666	11767
" (4)	18438	6289	25878
" (5)	8197	9579	28856
" (6)	18465	17312	7304
" (7)	18353	18280	8358
" (8)	5530	22558	5738
" (9)	14605	16475	12471
" (10)	4220	15329	8952
평균횟수	14238.1	16214.4	13805.3
편차	5953.6	6733.5	7779.8
성능비교	58 배	111 배	133 배

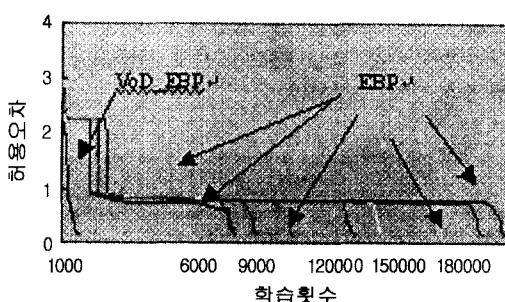


그림 8. 패리티 검출 문제의 학습 진행 과정

학습횟수에 따른 성능을 비교하기 위하여 VoD_EBP와 마찬가지로 EBP에서도 은닉층의 노드 수를 8 개로 구성하였고, 허용오차 수준을 0.1로 하였을 때

결과는 표 3과 같다.

한편, 허용오차 0.1 이하가 될때까지 출력오차의 평균제곱 합의 변화량을 그래프로 나타내면 그림 8과 같다.

5. 결 론

본 연구에서는 보로노이 공간 분류에 의하여 학습 횟수를 줄이고, 학습 마비 현상이 발생하지 않는 VoD_EBP를 제시하였다. 특히 응용하고자 하는 문제에 대한 EBP의 설계과정에서 여러 번의 시행착오를 겪은 경험에 의해 결정하였던 은닉층의 노드 수를 VoD_EBP에서는 보로노이 다각형 개수로 결정하므로 전반적인 신경망 구성에 신뢰성을 향상시켰다. VoD_EBP의 성능 및 효율성을 EBP와 비교하기 위하여 XOR 문제와 짝수 패리티 코드 검출 실험한 결과 EBP에서는 임의로 설정된 초기값 때문에 많은 양의 학습횟수가 요구되었으나 VoD_EBP에서는 처음부터 빠른 속도로 학습이 이루어졌다. 이는 VoD_EBP의 설계가 초기 설정에 있어 VoD의 경계선 방정식으로부터 패턴분류에 대한 정보를 반영하였기 때문이다. 또한 두가지 실험 모두에서 VoD_EBP는 지역 최소치에 빠져 학습이 진행되지 않는 현상이 전혀 나타나지 않았다.

그러나 아직은 VoD_EBP를 적용하기 위한 선결 과제인 경계를 구분하는 초평면의 방정식을 구하기가 쉽지 않다. 특히 다차원의 공간 분류일 경우 아직 초평면의 방정식을 구할 수 있는 알고리즘이 개발되지 않은 상황이며, VoD_EBP가 기존의 EBP 보다 항상 효율적일 것이라는 이론적인 근거가 없으므로 향후 이에 대한 지속적인 연구가 필요하다.

참고문헌

- [1] M. L. Minsky and S. A. Papert, *Perceptrons* Cambridge, MA : MIT Press, 1988.
- [2] Ali A. Minai and Ronald D. Williams, "Backpropagation Heuristics : A study of the Extended Delta-Bar-Delta Algorithm", *International Joint Conference on Neural Networks In proc*, Vol. 1, pp. 595-600, 90.
- [3] Hedong Yang and Clark C. Guest, "Linear Discriminants, Logic Functions, Backpropagation, and Improved Convergence", *International Joint Conference on Neural Networks In proc*, Vol. 3, pp. 287-292, 90, Jun.
- [4] Norio Bada, "A Hybrid Algorithm for Finding the Global Minimum of Error function of Neural Networks" *International Joint Conference on Neural Networks In proc*, Vol. 1, pp. 585-588, 90, Jan.

- [5] P. Burrascano and P. Lucci, "Smoothing backpropagation cost function by Delta Constraining", *International Joint Conference on Neural Networks In proc.*, Vol. 3, pp. 75-80, 90. Jun.
- [6] Tariq Samad, "Backpropagation Improvements Based on Heuristic Arguments", *International Joint Conference on Neural Networks In proc.*, Vol. 1, pp. 565-568, 90. Jan.
- [7] 조성배, 김진형, "오류 역전파 학습 알고리즘의 속도 개선방법: 분류 및 비교", *한국 정보과학회 논문지*, 91.11 Vol. 18, No. 6 November, pp. 649-660.
- [8] 권희용 외 4, 바람직하지 않은 포화상태 방지에 의한 역전파 학습의 개선, *한국 정보과학회 논문지*, 93.5 Vol. 20, No. 5 May, pp. 656-661.
- [9] N. K. Bose "Neural Network Design Using Voronoi Diagrams", *IEEE Transaction on Neural Networks* Vol. 4, No 5, September 1993.
- [10] 백주현, 김홍기 "정체된 데이터를 이용한 신경망의 설계자동화에 관한 연구", *한국 퍼지 시스템 학회, 98춘계학술대회 논문집*, pp. 189-192, 1998.
- [11] D. T. Lee and F. P. Preparata, "The All Nearest Neighbor Problems for convex polygon", *Information Processing Lett.*, vol. 7, pp. 189-192, June 1978.
- [12] D. McCallum and D. Avis, "A Linear Algorithm for finding the convex hull of a Simple polygon", *Information Processing lett.*, vol. 9, pp. 201-206, Dec. 1979.
- [13] Godfried T. Toussaint, "Pattern Recognition and Geometrical Complexity", *IEEE, 5-th International Conference on Pattern recognition*, pp. 1324-1347, 1980.
- [14] J. A. Hartigan, "Clustering Algorithms", John Wiley & Sons, 1975.



백주현 (Ju-Hyun Back) (종신회원)

1989년 : 성균관대학교 수학과 졸업
 1992년 : 서강대학교 정보통신대학원 정보처리학과 졸업(이학석사)
 1996년 : 충북대학교 전자계산학과 박사수료
 1996년 ~현재 : 군장대학 경영전산학부 조교수



김홍기 (Hong-Gi Kim) (종신회원)

1961년 : 연세대학교 수학과 졸업
 1975년 : 연세대학교 대학원 졸업 (이학석사)
 1985년 : 중앙대학교 대학원 졸업 (이학박사)
 1980년~현재 : 충북대학교 컴퓨터 과학과 교수