

---

# 퍼셉트론형 신경회로망에 의한 패리티판별

최재승\*

Parity Discrimination by Perceptron Neural Network

Jae Seung Choi\*

## 요 약

본 논문에서는 퍼셉트론형 신경회로망에 오차역전파 알고리즘을 사용하여 학습을 실시하여, N비트의 패리티판별에 필요한 최소의 중간유닛수의 해석에 관한 연구이다. 따라서 본 논문은 제안한 퍼셉트론형 신경회로망의 중간유닛의 수를 변화시켜 N 비트의 패리티 판별 실험을 실시하였다. 본 시스템은 패리티 판별의 실험을 통하여 N 비트 패리티 판별이 가능하다는 것을 실험으로 확인한다.

## ABSTRACT

This paper proposes a parity discrimination algorithm which discriminates N bit parity using a perceptron neural network and back propagation algorithm. This algorithm decides minimum hidden unit numbers when discriminates N bit parity. Therefore, this paper implements parity discrimination experiments for N bit by changing hidden unit numbers of the proposed perceptron neural network. Experiments confirm that the proposed algorithm is possible to discriminates N bit parity.

## 키워드

패리티판별, 오차역전파 알고리즘, 중간 유닛수, 신경회로망

## Key word

Parity discrimination, back propagation algorithm, hidden unit number, neural network

---

\* 신라대학교 전자공학과

접수일자 : 2009. 09. 17  
심사완료일자 : 2009. 10. 31

## I. 서 론

다층 퍼셉트론형 신경회로망은 입출력총 및 중간총의 선택에 의해서 다양한 정보를 처리하는게 가능하다[1, 2, 3]. 그러나 처리하는 대상에 대해서 필요 이상의 규모의 네트워크를 구성하는 것은 계산량을 많게 하는 것뿐만 아니라 계산기 자원의 낭비와 연관된다. 이러한 이유에 의해서 주어진 정보를 처리하기 위해서 최소 규모의 네트워크의 연구가 필요하다고 생각되어 진다.

최근의 신경회로망의 연구에 있어서, XOR(Exclusive OR) 회로 및 패리티 판별회로는 제안된 이론을 뒷받침하는 회로의 연구로서 자주 사용되어지고 있다[4, 5, 6]. 이것은 다른 어려운 문제가 하나의 부분 문제로서 이러한 것들을 많이 포함하고 있기 때문이다. 이 경우에, N비트 패리티 판별에는 중간총수는 활성 합수로서 비선형 합수를 사용한 경우, 최저 N비트가 필요하다는 암묵의 법칙이 있다고 할 수 있다[7]. 이 원인은 Rumelhart 등에 의해서 쓰여진 저서 “PDP(Parallel Distributed Processing) 모델[8]”에 의한 한 가지 설이 믿어지기 때문이다.

본 논문에서는 실험에 의한 N비트 패리티 판별에는 중간 유닛의 수가 N개보다도 적은 네트워크를 사용함으로써 문제해결을 실시하고 있지만, 일반적으로는 중간 유닛수가 최소  $(N+1)/2$ 개로 패리티 판별이 가능하다. 따라서 본 논문에서는 최소 유닛수로서 패리티 판별 문제를 쉽게 해결하기 위하여 네트워크의 초기값의 부여 방법을 제안하여, 최소 유닛수에 대한 패리티 판별 신경회로망의 각 파라미터의 최적해에의 조건을 사용하여 실험을 실시한다.

## II. 오차역전파 알고리즘의 기초이론

본 장에서는 오차역전파 알고리즘[4, 9]으로 불리우는 다층 퍼셉트론의 가중치 학습 알고리즘에 대해서 기술한다. 오차역전파 알고리즘은 1986년 Rumelhart 등이 논문을 발표한 것이 단서가 되어 다층 퍼셉트론의 가중치 학습 알고리즘[1, 2]이 광범위하게 연구자의 사이에서 논의되었다.

제  $m$ 층 ( $m = 1, \dots, M$ )  $i$ 번째의 신경유닛의 입력  $x_i^{(m)}$ 는 다음 식과 같이 이 유닛의 입력의 총합으로 나타낸다.

$$x_i^{(m)} = \sum_j w_{ij}^{(m)} y_j^{(m-1)} \quad (1)$$

여기에서,  $w_{ij}^{(m)}$ ,  $y_j^{(m-1)}$ 는 각각  $m-1$ 층의  $j$ 번째의 유닛으로부터  $m$ 층의  $i$ 번째의 유닛에의 가중치 계수,  $m-1$ 층의  $j$ 번째의 유닛의 출력을 나타낸다.  $y_i^{(m)}$ 과  $x_i^{(m)}$ 은 비선형 변환  $F$ 에 의하여 다음 식과 같이 나타낸다.

$$y_i^{(m)} = F[x_i^{(m)}] \quad (2)$$

여기에서  $y_i^{(m)}$ 는 제  $m$ 층  $i$ 번째의 신경유닛의 출력을 나타낸다. 식 (1)과 식 (2)는  $m$ 층의 유닛의 출력이 하나 아래의  $m-1$ 층의 유닛 출력에 의하여 결정된 것을 나타내며, 입력총에 입력신호가 주어지면 이 식들을 사용하여 순차적으로 출력총에 향하여 각 층의 유닛 출력이 계산된다.

학습 패턴으로서는 일련의 입력 및 기대출력의 쌍이 준비되어 있다고 가정하여, 네트워크의 출력이 기대출력에 가까워지게 네트워크의 가중치 계수를 순차 학습하여 가는 것과 같은 알고리즘을 부여한다. 먼저, 학습패턴으로서 한조의 입력  $y_i^{(0)}$  ( $i = 1, \dots, N_0$ )와 기대출력  $d_i$  ( $i = 1, \dots, N_M$ )이 주어진다. 여기에서,  $N_m$  ( $m = 0, \dots, M$ )은  $m$ 층의 신경유닛수를 나타낸다. 가중치 계수는 가중치의 초기치에 대한 식 (1), (2)를 사용하여 네트워크의 출력  $y_i^{(M)}$  ( $i = 1, \dots, N_M$ )가 정해진다. 기대출력과 네트워크의 실제의 출력의 2승오차의 총합  $E$ 를 다음 식과 같이 정의한다.

$$E = \frac{1}{2} \sum_{i=1}^{N_M} (y_i^{(M)} - d_i)^2 \quad (3)$$

여기에서  $E$ 를 평가함수로 생각하여 이 평가함수를 최소로 하는 것과 같은 가중치의 수정법칙을 고려한다. 본 논문에서 제안한 가중치 수정 알고리즘을 다음과 같이 요약한다.

**Step 1.** 가중치 계수의 초기치는 아주 작은 실수의 랜덤 수를 사용하여 정한다.

**Step 2.** 학습입력 패턴  $y_i^{(0)} (i=1, \dots, N_0)$ 를 네트워크에 입력하여, 입력층으로부터 출력층으로 향하는 순방향으로 각종의 유닛 출력을 계산한다. 이 계산에는 식 (1), (2)를 사용한다. 즉,

$$y_i^{(m)} = F \left[ \sum_{j=0}^{N_{m-1}} w_{ij}^{(m)} y_j^{(m-1)} \right] \quad (4)$$

$m = 1, \dots, M ; i = 1, \dots, N_m$

**Step 3.** 평가함수 E의 가중치  $w_{ij}^{(m)}$

$(m=1, \dots, M ; i=1, \dots, N_m ; j=0, \dots, N_{m-1})$ 에

관한 편미분  $\frac{\partial E}{\partial w_{ij}^{(m)}}$ 를 구한다.

**Step 4.** 가중치 계수의 개선을 식 (4)에 따라서 실시한다.

**Step 5.** E가 충분히 적게 될 때까지 Step 2에서 Step 4까지를 반복한다.

이상과 같이 오차역전파 알고리즘은 일반성이 높은 뛰어난 알고리즘이며 많은 문제해결에 응용되고 있다. 또한, 오차역전파 알고리즘은 극치탐색수법이며, 평가함수 E가 극소치를 많이 포함하는 경우에 이것들에 떨어지기 때문에 대역적인 최소값에 수렴하지 않을 가능성이 있다. 이 문제를 피하는 결정적인 수법은 현재는 알려져 있지 않지만, 복수의 초기값으로부터 극소탐색을 시험하는 방법, 중간층의 유닛수를 증가시키는 방법, 확률적으로 가끔 에너지를 증대하는 방향으로 의도적으로 가중치 수정을 실시하는 등의 방법이 일반적으로 시험되고 있다.

### III. 패리티 판별 실험 결과 및 고찰

패리티 판별은 입력 패턴의 패리티를 조사하는 문제이며, 입력 패턴이 기수개의 1을 포함한 경우에만 1을 출력하는 문제이다. 이 문제는 거의 비슷한 입력에 대해서 다른 출력을 나타내지 않으면 안되기 때문에, 네트워크에 있어서는 어려운 문제이다 [6, 7]. 또한 XOR 문제는 입력 유닛의 수가 2개의 패리티 문제이란 것을 말할 수

있다. Rumelhart [9]등의 실험에 의하면 입력 유닛으로부터 출력 유닛에의 직접적인 결합이 없는 계층형의 네트워크를 사용하는 경우, 입력의 크기 N의 패리티 문제를 해결하기 위해서는, 적어도 N개의 은닉 유닛이 필요하다고 알려져 있다.

본 장에서는 오차역전파 알고리즘을 사용하여 패리티 판별을 위한 신경회로망의 시뮬레이션의 결과 및 N비트의 패리티 판별에 필요한 최소 중간 유닛수의 도출, 최소 중간 유닛수에서의 최적해의 조건, 초기값을 조작하는 것에 의한 학습상황이 어떻게 변화하는 것 등을 나타낸다.

#### 1. 중간 유닛수와 수렴횟수 및 학습횟수의 관계

3층 퍼셉트론형 신경회로망의 중간 유닛의 수를 변화시켜 2비트에서 5비트까지의 패리티 판별을 실시하였다. 학습에 사용한 파라미터는  $\eta$ (학습계수): 0.2,  $\alpha$ (관성계수): 0.9, 수렴판정오차:  $1.0 \times 10^{-4}$ , 최대학습횟수: 30,000회이다. 또한 하나의 네트워크에 대하여 1,000회의 시행을 실시하여 이 결과를 표 1에 정리하였다. 또한 표 중에 있어서 “(분리가)”는 학습횟수가 30,000회에 도달한 것으로 평가함수의 값이 수렴판정오차보다도 크지만, 출력이 0.5보다 작은 경우에는 0, 큰 경우에는 1로 써 보면 목표 패턴과 일치하는 것도 수렴횟수에 포함시킨다. 표 1로부터 중간 유닛을 증가시킬 수록 수렴횟수는 많게 되며 평균학습횟수는 적게 되는 것을 알 수 있다. 또한 평균학습횟수에 대한 표준편차가 적게 되어가므로 보다 네트워크의 안정성이 증가되는 것을 알 수 있다. 결론적으로 3, 4, 5 비트의 입력에 대해서, 수렴횟수는 적지만 N비트의 입력에 대해서 N개 이하의 중간 유닛수로도 패리티를 판별하는 것이 가능하다는 것을 알 수 있다.

표 1. 중간유닛수와 수렴 및 평균학습횟수와의 관계

Table 1. Relation for hidden unit numbers, convergence iterations and average training iterations.

네트워크	수렴횟수 (분리가)	평균 학습횟수	학습횟수의 표준편차
2-2-1	823(823)	3935.4	938.3
2-3-1	988(989)	3483.6	659.2
2-4-1	1,000	3073.9	464.3
2-5-1	1,000	2789.8	355.9

3-2-1	818(853)	22422.6	3919.1
3-3-1	995(1,000)	2975.9	2021.9
3-4-1	1,000	2061.9	564.6
3-5-1	1,000	1777.8	420.4
4-2-1	48(141)	23439.0	3941.1
4-3-1	429(495)	6866.4	8011.2
4-4-1	763(799)	4774.0	6018.5
4-5-1	910(916)	3383.4	4079.9
5-2-1	1(33)	27953.0	0.0
5-3-1	269(327)	20423.9	5107.7
5-4-1	535(557)	9221.6	8002.2
5-5-1	751(758)	5271.1	5979.6

## 2. 입력 유닛수보다 적은 중간유닛수로 패리티 판별이 가능한 네트워크

본 절에서는 표 1의 5-3-1 네트워크에 대해서 고찰한다. 입력이 5비트의 경우,  $x_i$ 를  $i$ 번째의 입력 유닛의 값,  $i$ 번째의 입력 유닛으로부터  $j$ 번째의 중간 유닛에 향하는 결합의 가중치 계수를  $w_{ji}$ 로 두면 다음 식과 같이 된다.

$$w_{j1} = w_j; (w_j \text{는 정수}) \quad (5)$$

부호가 음수가 되는  $w_{jl}$  ( $2 \leq l \leq 5$ )에 대해서는, 입력 비트가 반전한 것으로 생각하여  $w_{1l} = -w_j$ 로 두고 이  $l$  번째의 입력 유닛의 값을  $(1-x_i)$ 로 한다. 이와 같이 두면  $j$  번째의 중간유닛의 활성화값  $f_{aj}(x_1, x_2, x_3, x_4, x_5)$ 은 다음 식과 같다.

$$\begin{aligned} f_{aj}(x_1, x_2, x_3, x_4, x_5) &= w_{j1}x_1 + w_{j2}x_2 + w_{j3}x_3 + w_{j4}x_4 + w_{j5}x_5 \\ &= w_jx_1 - w_j(1-x_2) - w_j(1-x_3) \\ &\quad - w_j(1-x_4) - w_j(1-x_5) \\ &= w_j(x_1 + x_2 + x_3 + x_4 + x_5) - 4w_j \end{aligned} \quad (6)$$

여기에서  $X_a = (x_1 + x_2 + x_3 + x_4 + x_5); (0 \leq X_a \leq 5)$ 로 두면, 중간 유닛의 출력  $f_{aj}$ 는 다음 식과 같이 입력 비트의 1의 수  $X_a$ 의 함수로 나타낼 수 있다.

$$f_{aj}(X_a) = w_j(X_a - 4) \quad (7)$$

$j$  번째의 중간유닛의 문턱치를  $\theta_{aj}$ ,  $j$  번째의 중간 유닛으로부터 출력유닛에의 가중치계수를  $w_{oj}$ , 출력유닛의 문턱치를  $\theta_{ak}$ 로 하면, 출력층의 활성화값  $g_a(X_a)$ 를 다음 식과 같이 구할 수 있다.

$$g_a(X_a) = \sum_{j=1}^3 \left( w_{oj} \times \frac{1}{1 + \exp[-f_{aj}(X_a) + \theta_{aj}]} \right) + \theta_{ak} \quad (8)$$

즉 출력층의 활성화값은  $X_a$ 의 이산적인 정수값인 1 변수 함수로서 나타낼 수 있다. 따라서 출력 유닛의 출력  $z_a(X_a)$ 는 다음 식과 같이 나타낼 수 있다.

$$z_a(X_a) = \frac{1}{1 + \exp[-g_a(X_a)]} \quad (9)$$

이러한 관계를 그림 1과 그림 2에 나타낸다. 그림 2에서  $X_a$ 가 우수인 경우  $z_a(X_a)$ 는 0에 가까워지고,  $X_a$ 가 기수일 때에는 1에 근접해지고 있다. 이것은 패리티 판별이 가능하다는 것을 나타낸다.

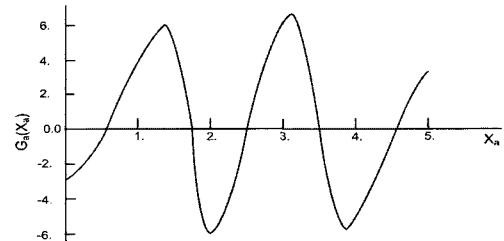


그림 1. 입력 유닛의 1의 비트수와 출력 유닛의 활성화치와의 관계

Fig 1. Relation between number of "1" bits of input unit and activation value of output unit.

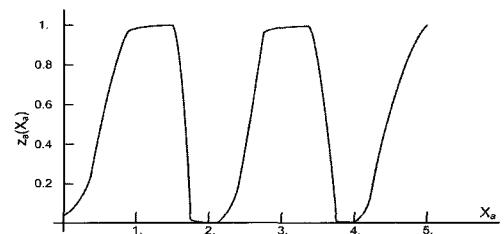


그림 2. 입력유닛의 1의 비트수와 출력과의 관계

Fig 2. Relation between number of "1" bits of input unit and output.

### 3. N비트 패리티 판별에 필요한 중간 유닛수

본 절에서는 각 입력 유닛으로부터 어떤 중간 유닛에 향하는 값이 거의 동일한 가중치 계수를 가진 형태의 III.2절과 동일한 5-3-1 네트워크에 대해서 고찰한다. III.2절에서도 기술한바와 같이, 이 형태의 네트워크의 출력은 입력의 1번수 함수로서 취급할 수 있다. 또한, 출력 유닛의 활성화치는 각 중간 유닛의 출력인 비선형 함수에 가중치 계수를 곱한 것의 합이 된다. 지금 이 출력 유닛의 활성화치를  $z(X)$ 로 한다. 단, 여기에서  $X$ 는 입력 유닛에 들어가는 1의 비트수이다. N비트 패리티를 판별하기 위해서는 이  $z(X)$ 가 ( $0 \leq X \leq N$ )의 범위에서  $X$ 가 우수일 때 음수, 기수일 때 양수가 되도록 교대로 진동하여야 한다. 왜냐하면, 출력 유닛의 출력을  $zout(X)$ 라고 하면

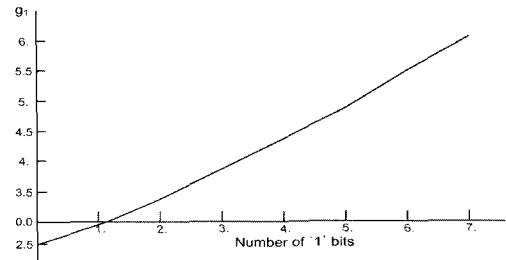
$$zout(X) = \frac{1}{1 + \exp(-z(X))} \quad (10)$$

로서 나타내어져,  $z(X)$ 가 양수일 때  $zout(X)$ 은 0.5 보다 크게 되어, 역으로  $z(X)$ 가 음수일 때에는  $zout(X)$ 은 0.5보다 적게 된다. 문턱치를 0.5로 하여, 이것보다 큰 값을 1, 적은 값을 0으로 본다면 패리티 판별이 가능하기 때문이다.

다음으로 7비트의 패리티 판별회로를 사용하여 교대로 진동되도록 하기 위한 조건에 대하여 고찰한다. 여기에서 중간 유닛수는 4로 하여 실험을 실시하고 있다. III.2절과 동일하게,  $x_i$ ,  $w_{ji}$  ( $1 \leq i \leq 7, 1 \leq j \leq 4$ )로 정하여, 새로운 제  $j$  번째 중간 유닛의 문턱치  $\theta_j$ , 활성화치  $g_j$ , 출력 유닛의 문턱치  $\theta_o$ , 제  $j$  번째 중간 유닛으로부터 출력 유닛에의 가중치 계수를  $w_{oj}$ 로 한다. 제 1번 째 중간 유닛으로부터 출력 유닛에 들어오는 값  $g_1$ 은 다음과 식으로 나타낸다.

$$g_1 = w_{o1} \times \frac{1}{1 + \exp\left(-\left(\sum_{i=1}^7 w_{1i}x_i + \theta_1\right)\right)} \quad (11)$$

여기에서  $w_{1i}$ 를 작게 ( $w_{1i} = 0.18$ ),  $w_{o1}$ 을 크게 ( $w_{o1} = 13.80$ ) 설정하면  $g_1$ 의 개형은 그림 3과 같이 된다. 여기에서  $\theta_1 = -1.50$ 이다.

그림 3.  $g_1$ 에 대한 그래프Fig. 3. Graph for  $g_1$ 

$g_1$  이외의 중간 유닛으로부터 출력 유닛에 입력되는 값의 합  $g_{234}$ 는 다음 식과 같이 나타낸다.

$$g_{234} = \sum_{k=2}^4 \left( w_{ok} \times \frac{1}{1 + \exp\left(-\left(\sum_{i=1}^7 w_{ki}x_i + \theta_k\right)\right)} \right) \quad (12)$$

여기에서,  $w_{ki}$  ( $2 \leq k \leq 4$ )를 모두 동일한 크기의 큰 값 ( $w_{ki} = -100.00$ )으로 하여 동일한 간격으로 문턱치를 설정한다면 ( $\theta_2 = 150.00$ ,  $\theta_3 = 350.00$ ,  $\theta_4 = 550.00$ ) 그림 4와 같은 계단형태의 함수로 된다. 또한,  $w_{ok}$ 는 모두 1.00으로 한다.

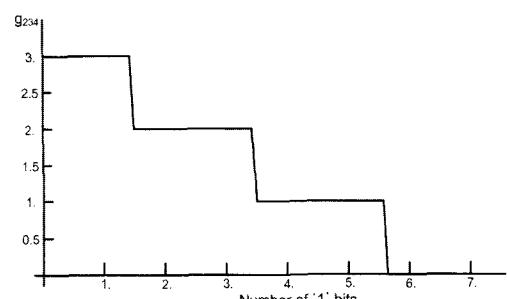
그림 4.  $g_{234}$ 에 대한 그래프Fig. 4. Graph for  $g_{234}$ 

그림 3에서 함수의 최대값으로부터 최소값으로 크게 변화하는 부분을 정수의 기울기를 가진 1차 함수로서 보고, 이 부분에 그림 4의 계단 형태의 함수를 중복시키면 (즉 2개의 함수의 합을 취한다) 어떤 값을 중심으로 진동하는 함수가 된다. 단, 서로 겹쳐진 2개의 함수는 어느 한

쪽이 단순한 증가함수라 할지라도 다른 한쪽 방향은 단순한 감소함수여야 한다. 여기에 적당한 출력 유닛의 문턱치  $\theta_0$  ( $\theta_0 = -5.70$ )를 더하여 조정함으로써 그림 5와 같은 0을 중심으로 진동하는 함수가 된다. 그림 6은 0을 중심으로 진동하는 출력 유닛의 활성화치를 가진 네트워크의 출력을 나타낸다.

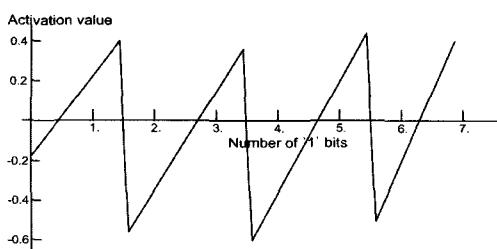


그림 5. 출력 유닛의 활성화치  
Fig 5. Activation value of output unit.

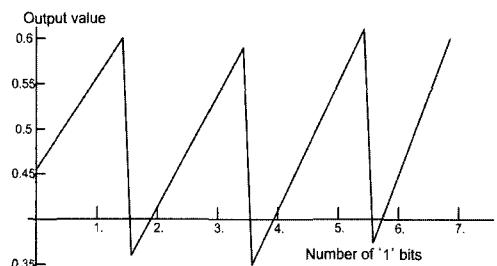


그림 6. 출력 유닛의 활성화치를 가진 네트워크의 출력  
Fig 6. Output of network with activation value of output unit.

지금까지 1차 함수와 계단 형태의 함수를 서로 겹쳐서 일정한 값을 중심으로 진동하는 함수를 검토하였다. 표 1의 결과로부터 2비트 패리티와 3비트 패리티가 최소 2개의 중간 유닛로 판별 가능하다는 사실을 이용하면, N 비트 패리티를 판별하기 위해서는 최소  $(N+1)/2$ (소수점 이하는 반올림)개의 중간 유닛이 필요하다는 것을 알 수 있다.

#### 4. 초기값의 조작 및 실험결과

본 절에서는 입력층에서 중간층까지의 가중치 계수를 조작하는 방법으로 네트워크를 학습시켰을 때와 일반적인 방법으로 학습시켰을 때의 초기값의 조작에 대한 결과를 비교한다. 본 논문에서는 초기치의 조작에

다음의 2종류의 방법을 실험하였다.

- 1. 전절과 동일한 방법. 즉,

$w_{ij} = w_j$  ( $1 \leq i \leq 5, 1 \leq j \leq 3$ )로 하고,  $w_j$ 는 -1부터 1까지의 램덤값을 취한다.

- 2. 입력 유닛의 비트의 반전도 고려한다. 위와 동일한 방법으로 초기치를 설정한 후, 이 가중치 계수 행렬의 열 벡터  $w_i$ 를 램덤하게 선택하여 각 요소에 -1을 곱한다.

단, 초기치를 조작하는 이외의 방법은 일반적인 학습 방법과 동일하게 실험을 하였다. 학습에 사용한 파라미터 ( $\eta, \alpha$ ), 수렴판정오차, 최대 학습횟수는 III.1절과 동일하게 적용하여 실험을 하였다. 표 2와 같이 3-2-1 네트워크에 대하여 비교하였다.

표 2. 3-2-1 네트워크에 대한 일반적인 방법과 초기치의 조작방법 1, 2와의 비교  
Table 2. Comparison of the conventional method and proposed method for 3-2-1 network.

실험방법	수렴횟수	평균 학습횟수	학습횟수의 표준편차
일반적인 방법	818	22422.6	3919.1
1의 방법	743	23709.1	3615.0
2의 방법	921	22413.5	3864.4

표 2의 결과로부터 2의 방법이 가장 양호하다는 것을 알 수 있다. 1의 방법은 일반적인 방법보다 수렴 횟수가 적게 되어 있지만, "(분리가)"가 상당히 많이 있기 때문에 비교적 양호한 결과라고 말할 수 있다. 표 3은 5-3-1 네트워크에 대하여 비교하였다.

표 3. 5-3-1 네트워크에 대한 일반적인 방법과 초기치의 조작방법 1, 2와의 비교  
Table 3. Comparison of the conventional method and proposed method for 5-3-1 network.

실험방법	수렴횟수 (분리가)	평균 학습횟수	학습횟수의 표준편차
일반적인 방법	1(33)	27953.0	0.0
1의 방법	4(31)	24704.0	3281.7
2의 방법	1(67)	29391.0	0.0

표 3을 “(분리가)”의 수로 평가하면, 2의 방법이 가장 양호한 결과를 내고 있다고 말할 수 있다. 이 3비트 패리티 판별과 5비트 패리티 판별에 대한 비교로부터 초기치의 조작을 하는 쪽이 수렴하기 쉬운 결과가 나왔다. 이 결과로부터, 초기치의 조작이 각 파라미터를 초기치의 단계에서 해집합에 근접하는 위치에 이동한다고 생각한다면, 이 해집합과 입력층에서 중간층으로 향하는 결합의 가중치 계수가 갖추어진 것의 집합은 서로 밀접한 관계가 있다고 생각되어진다. 또한 이러한 것은 전절에서 기술한 최적해의 조건을 증명하는 것이라고 생각한다.

#### IV. 결론

본 논문에서는 오차역전파 알고리즘을 사용한 3층 퍼셉트론형의 신경회로망의 시뮬레이션을 실시하였다. 실험 결과로부터 N비트의 패리티 판별에 필요한 최소 중간 유닛수를 도출하여 최소 중간 유닛수에서의 최적해의 조건 등에 대해서 고찰하였다. 또한, 초기치를 조작하는 것에 의하여 학습상황이 어떻게 변화하는가를 나타냈다. 이상, 본 실험으로부터 구해진 결과를 정리하면 다음과 같다.

1. 중간 유닛수를 증가시키면 수렴횟수가 많게 되어, 평균학습 횟수와 표준편차가 적게 된다.
2. N비트 패리티는 최소  $(N+1)/2$ 개의 중간 유닛수로 판별 가능하다.
3. “최소중간 유닛수로 패리티를 판별할 때, 평가함수를 최소로 하는 각 파라미터의 최적해는 각 입력 유닛으로부터 어떤 중간 유닛에 향하는 결합의 가중치 계수가 갖추어지는 것이다”라는 가능성성이 높다.

향후의 연구과제로서는 평가함수를 변경하는 등의 개선책 및 엄밀한 최적해의 조건의 해결 등을 검토할 필요가 있다.

#### 참고문헌

- [1] F. Rosendblatt, "Principles of Neurodynamics," Spartan, Washington.

- [2] S. Amari, "A theory of adaptive pattern classifier," IEEE Trans. EC-16, pp. 279-307, 1967.
- [3] 고보연, “학습 패턴의 분포 특징을 고려한 다층퍼셉트론 신경회로망의 개선”, 한국정보과학회논문지 (B) 제23권 제9호, pp. 963-971, 1996.
- [4] Ooyen A. V. and Nienhuis B. "Improving the convergence of the back-propagation algorithm," Neural Networks 5, 3, pp. 465-471, 1992.
- [5] Romaniuk S. G. and Hall L. O., "Divide and conquer Neural Network," Neural Networks 6, 8, pp. 1105-1116, 1993.
- [6] J. M. Minor, "Parity with two layer feedforward nets," Neural Networks 6, 5, 1993.
- [7] Stork D. G. and Allen J. D., "How to solve the N-bit parity problem with two hidden units," Neural Networks, 5, 6, pp. 923-926, 1992.
- [8] Rumelhart D. E. and McClelland J. L. (Eds.), "Parallel Distributed Processing : Explorations in the Microstructure of Cognition," Chap. 8, MIT Press, London, pp. 334-335, 1986.
- [9] D. Rumelhart, G. Hinton and R. Williams, "Learning representations by back-propagation errors," Nature323, pp. 533-536, 1986.

#### 저자소개

최재승 (Jae Seung Choi)



1989년 조선대 전자공학과 공학사

1995년 일본 오사카시립대학

전자정보공학부 공학석사

1999년 일본 오사카시립대학

전자정보공학부 공학박사

2000년~2001년 일본 마쓰시타 전기산업주식회사

AVC사 연구원

2002년~2007년 경북대 디지털기술연구소 책임연구원

2007년~현재 신라대학교 전자공학과 교수

※관심분야 : 디지털통신, 음성신호처리, 신경회로망, 적응필터와 잡음제거, 디지털 TV 및 멀티미디어 등