

論文97-34C-12-7

계산 에너지 함수 분석을 통한 궤환성을 갖는 단층신경회로망의 성능개선

(Performance Improvement of Single-layer Neural Network with Feedback by Analyzing the Computational Energy Function)

高景希*, 康珉齊*

(Kyung Hee Ko and Min Je Kang)

요 약

궤환성을 갖는 단층신경회로망이 지역최소점으로 수렴하는 요인 중 하나인 계산에너지함수에서 제 3항^[1]에 존재하는 에너지 항을 무시할 수 있는 새로운 방법을 제시한다. 궤환성을 갖는 단층신경회로망이 전체최소점으로 수렴하지 못하고 지역최소점으로 수렴해 버리는 원인은 최적화 시킬 비용함수와 신경회로망의 계산에너지함수가 정확히 일치되지 않았기 때문이다. 이런 요인들중 하나는 제 3항의 값을 미세하다고 간주하여 시스템을 설계할 때 이 값을 무시하기 때문이다.^{[1] [2]} 그러나, 시스템이 커질수록 제 3항의 값은 증가하여 점점 최적화 시킬 비용함수와 다르게 되며, 이 결과로 시스템은 지역최소점으로 빠지는 수가 증가하게 되는데, 이 논문에서는 제 3항의 값을 보상하여, 시스템이 지역최소점으로 수렴하는 경우의 수를 줄임으로써 시스템의 성능을 개선시킬 수 있는 새로운 방안을 제시한다.

Abstract

A new method to neglect the third term of the computational energy expression in the single-layer neural network with feedback is introduced. The system often converges to local minima instead of to global minima, because the computational energy is not matched exactly with the cost function being optimized. One of the factors causing these two functions different is the third term of computational energy expression. Regarding this third term energy very small, it is always ignored in designing the system.^{[1] [2]} However, as the system growing, this third term energy is also growing and this grown term makes the computational energy function much different from the cost function. In results of differency between two functions, system converges to local minima more than before. In this paper, a new method to neglect the third term energy is introduced, so that the system with this new method has been improved.

I. 서 론

최적화 문제에 응용되는 궤환성을 갖는 신경회로망¹

* 正會員, 濟州大學校 電子工學科

(Dept. of Electronic Engineering, Cheju National University)

接受日字:1996年12月4日, 수정완료일:1997年11月14日

¹⁻³⁾ 이 지역최소점으로 수렴하는 주요 원인중의 하나는 시스템 계산에너지의 제 3항에 의한 것이고, 다른 하나는 이진출력을 위해 부수적으로 첨가된 항이다. 이진 출력을 위해 부수적으로 첨가된 항은 제 3항이 무시된 계산에너지함수의 Hessian 행렬식 W에서 대각행렬들을 모두 0으로 만들며, 즉 행렬식의 trace를 0으로 만든다. 즉, 계산에너지함수의 Hessian을 in-

definite로 만든다. 고로 이진출력을 위해 부수적으로 첨가된 항은 시스템을 지역최소점으로 수렴하게 하는 요인 중의 하나가 된다^[4]. 따라서 시스템을 개선시키려면 이 두 요소를 없애야 되겠지만, 이진출력을 필요로 하는 시스템에서는 두 번째 요소를 제거하는 것은 불가능하므로, 첫 번째 요소를 조절할 수밖에 없다. 본 논문에서는 계산에너지의 제 3항을 최적화하여 시스템의 성능을 개선하는 새로운 방안을 제시한다. 2장에서는 쾌환성을 갖는 단층신경회로망의 구성과 동작에 대해서 서술하고, 3장에서는 계산에너지함수의 제 3항을 제거할 수 있는 방법에 대해서 설명하며, 4장에서는 Spice transient simulation을 통하여 제안된 모델의 성능이 개선되었음을 확인하고 5장에서 결론을 맺는다.

II. 쾌환성을 갖는 단층신경회로망의 구성과 동작

그림 1은 쾌환성을 갖는 단층신경회로망의 전기적 모델을 보여준다. 이런 형태의 신경망은 쾌환성을 가지며 뉴런의 출력들은 다시 다른 뉴런의 입력에 연결 강도(W_{ij})들을 통하여 연결된다. j 번째 뉴런의 출력(V_j)과 i 번째 뉴런의 입력(u_i)을 연결하는 연결강도(W_{ij})들은 전기적 모델에서는 컨덕턴스를 사용하며, 뉴런의 출력 값은 입력 단의 값에 매핑되는 함수로써 주로 시그모이드 함수가 쓰인다.

신경회로망의 전기적 모델에서 뉴런의 입력 단에서 세운 KCL(Kirchhoff Current Law)을 이용하여 다음의 공식이 유도된다.^[2]

$$C_i \left(\frac{du_i}{dt} \right) = i_i + \sum_{j=1, j \neq i} w_{ij} v_j - u_i \left(\sum_{j=1, j \neq i} w_{ij} + g_i \right) \quad (1)$$

식(1)의 우변은 캐패시터 C_i 로 유입되는 전류의 총량을 나타내며, 노드 i 뉴런의 입력에 연결된 전체 컨덕턴스를 G_i 로 다음과 같이 나타내면

$$G_i \triangleq \sum_{j=1, j \neq i} w_{ij} + g_i$$

식(1)은 다음과 같이 간략히 나타내어진다.

$$C_i \left(\frac{du_i}{dt} \right) = i_i + \sum_{j=1, j \neq i} w_{ij} v_j - u_i G_i \quad (2)$$

벡터형식으로 상태방정식과 출력방정식을 다음과 같이

표현 가능하다.

$$C \left(\frac{du}{dt} \right) = Wv(t) - Gu(t) + i(t) \quad (3)$$

$$v(t) = f(u(t)) \quad (4)$$

n 차원의 상태방정식으로 표현되는 시스템이 어떤 계산에너지함수의 값을 따라 점근적으로 안정되게 수렴하여 간다면 그 어떤 계산에너지함수를 그 시스템의 Lyapunov 함수라 한다. 그림1에서 신경회로망의 Lyapunov 함수는 다음과 같이 알려져 있다.^[11]

$$E(v) = -\frac{1}{2} v^t W v - i^t v + \sum_{i=1}^n G_i \int_{\frac{1}{2}}^{v_i} f_i^{-1}(z) dz \quad (5)$$

그림 1의 시스템에서 뉴런의 출력 v 는 이 계산에너지함수가 감소하는 방향으로 변하면서 안정되게 수렴해 간다.

식(5)의 세 번째 항은 뉴런 매핑함수의 역함수를 적분한 것으로 이것을 미분하면 다음의 관계가 성립한다.


$$\frac{d}{dv_i} \left(G_i \int_{\frac{1}{2}}^{v_i} f_i^{-1}(z) dz \right) = G_i u_i \quad (6)$$

연결강도 행렬이 대칭인 점을 고려하여 식(5)을 chain rule를 이용하여 시간에 관해 미분해보면 다음과 같다.

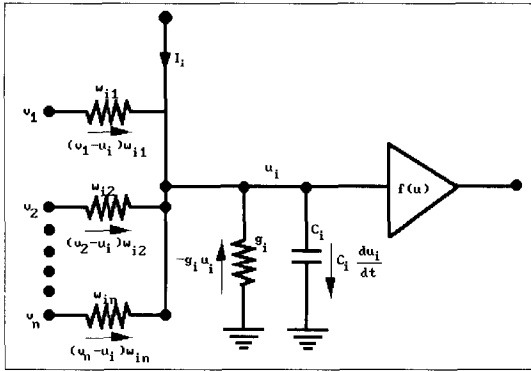
$$\begin{aligned} \frac{dE}{dt} &= \frac{dE}{dv} \frac{dv}{dt} \\ &= (-Wv - i + Gu)^t \frac{dv}{dt} \end{aligned} \quad (7)$$

식(3)을 이용하여 식(7)을 재정리하면 다음과 같다.

$$\frac{dE}{dt} = - \left(C \frac{du}{dt} \right) \frac{dv}{dt} \quad (8)$$



(a)



(b)

그림 1. (a) 궤환성을 갖는 단층신경회로망의 전기적 모델 (b) i번째 뉴런의 입력 노드

Fig. 1. (a) The electrical model of Single layer neural network with feedback (b) The input node of neuron i.

그런데 뉴런의 출력 v 는 입력 u 의 함수이므로 chain rule을 사용하면 식(8)을 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \frac{dE}{dt} &= -C \frac{du}{dt} \frac{du}{dt} f'(u) \\ &= -C \left(\frac{du}{dt} \right)^2 f'(u) \end{aligned} \quad (9)$$

$f(u)$ 는 시그모이드 함수이므로 항상 증가 함수이고 미분 값은 양이다. 따라서, 식(9)의 우변은 항상 음이므로 이 시스템은 시간의 흐름에 따라 에너지가 감소하는 방향으로 수렴하는 시스템임을 알 수 있다.^[3]

III. 에너지함수의 분석을 통한 궤환성을 갖는 단층신경회로망의 성능개선

Hopfield 신경회로망은 종종 지역최저점으로 수렴하여 원하지 않는 결과를 발생하는 문제가 있다. 이러한 현상은 디지털 출력을 위하여 계산에너지함수에 부수적으로 첨가된 항과 식(5)의 계산에너지함수에 존재하는 제 3항 때문이다.^[4] 제 3항 에너지를 최소화하기 위하여 다음의 뉴런 입출력 함수 $f(u) = \frac{1}{1+e^{-\lambda u}}$ 에서 시그모이드 이득률 λ 를 크게 하는 방법을 사용하고 있으나 λ 를 너무 크게 하게 되면 함수 $f(u)$ 는 $u=0$ 근처에서 급히 상승하게되어 단위함수에 가까워지고 시스템이 안정되게 수렴하는데 문제가 된다.

이장에서는 임의의 λ 값을 사용하여서 시스템이 안

정되게 수렴하는데 문제가 없으면서, 제 3항 에너지를 제거하는 새로운 방법을 제안한다.

제 3항 에너지는 각 뉴런에서 입력 u_i 의 초기치들이 0이므로 출력 $f(u)$ 의 초기치들은 0.5이며, 다음과 같이 표현된다.^[5]

$$E_3 \triangleq \sum_{i=1}^n G_i \int_{\frac{1}{2}}^{v_i} f(\lambda, z)^{-1} dz \quad (10)$$

여기서

$$f(\lambda, z)^{-1} = \frac{1}{\lambda} \ln \left(\frac{z}{1-z} \right) \quad (11)$$

그러면, 제 3항 에너지를 자세히 표현하면

$$E_3 = \sum_{i=1}^n \frac{G_i}{\lambda_i} \int_{\frac{1}{2}}^{v_i} \ln \left(\frac{z}{1-z} \right) dz \quad (12a)$$

적분한 계산 결과는 다음과 같다.

$$E_3 = \sum_{i=1}^n \frac{G_i}{\lambda_i} (v_i \ln v_i + (1-v_i) \ln(1-v_i) + \ln 2) \quad (12b)$$

식(12b)에서 제 3항의 에너지는 $v=1/2$ 에서 즉 $u=0$ 에서 0이며, v 가 0 또는 1로 수렴하여 감에 따라 식(13)과 같이 수렴함을 알 수 있다.

$$\lim_{v_i \rightarrow 0,1} E_3 = \sum_{i=1}^n \frac{G_i}{\lambda_i} \ln 2 \quad (13)$$

그림 2는 2비트 A/D 변환기의 제 3항의 에너지 분포도를 나타낸다. 시스템에서 n 이 증가할수록 연결강도(W_{ij})는 증가하게 되며, 따라서 G_i 도 증가하며 제 3항의 에너지는 더욱더 커지게 된다.




그림 2. 2 bit A/D 변환기의 제 3항의 에너지 분포도, $\lambda=2, G_i=2 \sigma$

Fig. 2. Energy distribution chart of third term for two-bit A/D converter, $\lambda=2, G_i=2 \sigma$.

에너지 함수를 자세히 고찰하기 위하여 식(5)을 출력전압 v 에 관해서 미분하면 다음 식을 얻는다.

$$\frac{dE}{dv} = (-Wv - i + Gu) \quad (14a)$$

식(5)과 식(14a)을 비교해보면, 식(14a)의 우변에서 제 3항이 제거되면 식(5)의 방정식에서도 제 3항이 제거됨을 알게 된다.

식(14a)을 그림1b와 비교하기 위해 재정리하면

$$\frac{dE}{dv} = (-Wv - u) - i + gu \quad (14b)$$

식(14b)과 그림1b를 비교해보면 i_i 는 node i 로 입력되는 바이어스 전류를 표현하고, $W(v-u)$ 는 각 뉴런의 출력들에서 연결강도 W 들을 통해서 node i 로 입력되는 전류를 나타내고, gu 는 node i 에 연결된 g 를 통해서 접지로 흘러나가는 전류임을 알 수 있다. 따라서, 식(14a)에서 제 3항을 제거하려면 G 즉, $g+W$ 값이 0이 되어야하므로 $-W$ 값에 해당하는 g 를 사용하여 제 3항을 제거하면 된다. 하지만 현실적으로 음의 값을 갖는 컨덕턴스를 제조하기란 쉽지 않으므로 즉, 컨덕턴스 g 대신에 node i 의 전압 u_i 에 의해 조정되는 중속전류원 $K_i u_i$ 를 연결하고 node i 로 전류를 유입시키면 제 3항의 에너지를 완전히 제거할 수 있다. K_i 값은 그 뉴런의 해당 연결강도의 합과 같으며 다음 식으로 표현된다.

$$K_i = \sum_{j=1}^n W_{ij} \quad i=1, 2, \dots, n \quad (15)$$

여기서, W_{ij} 는 i 번째 뉴런의 입력과 j 번째 뉴런의 출력을 연결하는 연결강도이다.

IV. 시뮬레이션 및 결과

실험을 위해서 사용된 A/D 컨버터는 최적화 문제의 특별한 예로써 Hopfield가 그의 논문^[2]에서 사용한 이후로, Hopfield 신경회로망의 성능분석을 위하여 많은 논문에서 사용되고 있다. 신경회로망의 입력은 아날로그 값 x 이며, 출력은 디지털 값이다. 즉, 아날로그 값 x 를 가장 근접한 디지털 출력값으로 최적화시키기 위하여 LMS 형식으로 표현된 비용함수와 Hopfield 신경회로망의 계산 에너지 함수를 일치시켜서 시간이 경과함에 따라 계산 에너지 함수를 최소화

하려는 Hopfield 신경회로망의 성질을 이용하여 입력 값 x 에 가장 근접한 디지털 출력을 얻는 시스템이다. 그림 3은 제안된 방법으로 에너지 함수의 제 3항을 제거한 폐환성을 갖는 단층신경회로망의 4비트A/D 컨버터의 전기적 모델이다. 4비트 A/D 컨버터의 비용함수를 LMS(Least Mean Squared)형식으로 표현하면 다음과 같이 된다^[2].

$$E_c = \frac{1}{2} (x - \sum_{i=0}^3 v_i 2^i)^2 \quad (16)$$

식(16)을 최소화하면 아날로그 입력 x 와 $\sum_{i=0}^3 v_i 2^i$ 의 값이 같아지지만, v_i 의 값이 이진 값을 보장하지는 않는다. 그래서, 뉴런 출력 v_i 의 값이 이진수가 되도록 도와주는 항이 부수적으로 첨가되어야 하는 데 다음과 같다^[2].

$$E_a = -\frac{1}{2} \sum_{i=0}^3 2^{2i} v_i (v_i - 1) \quad (17)$$

v_i 가 0, 또는 1이면, E_a 의 값은 0이고 v_i 가 이진수 이외의 값이면 E_a 는 양의 값을 지니게 되므로 v_i 가 이진값 즉, 0 또는 1일 때 가장 낮은 에너지 값을 갖도록 함으로써, 식(17)은 v_i 가 이진 값을 갖도록 도와준다.

시스템의 연결강도 u 와 외부입력 i 를 구하기 위하여, 식(16)과 식(17)을 합한 후, 식(5)의 신경회로망 계산 에너지함수에서 제 3항이 제거된 식과 비교하면 다음과 같다.

$$\frac{1}{2} (x - \sum_{i=0}^3 v_i 2^i)^2 - \frac{1}{2} \sum_{i=0}^3 2^{2i} v_i (v_i - 1) = -\frac{1}{2} v^t W i - i^t v \quad (18)$$

위 식의 좌변을 확장하여 우변과 비교하면 연결강도와 외부입력은 다음과 같이 구할 수 있다.

$$w_{ij} = -2^{i+j} \quad (19a)$$

$$i_i = -2^{2i-1} + 2^i x \quad (19b)$$

4비트 A/D컨버터인 경우에 매트릭스 형태로 다시 표현을 하면 다음과 같다.

$$W = - \begin{bmatrix} 0 & 2 & 4 & 8 \\ 2 & 0 & 8 & 16 \\ 4 & 8 & 0 & 32 \\ 8 & 16 & 32 & 0 \end{bmatrix} \quad i = - \begin{bmatrix} \frac{1}{2} - x \\ 2 - 2x \\ 8 - 4x \\ 32 - 8x \end{bmatrix} \quad (19c)$$

식(19)에서 알 수 있듯이 연결강도들이 음의 값으로

표현되어 있으나 음의 값을 갖는 컨덕턴스를 만들기가 용이하지 않아서, 음수 값을 갖는 뉴론을 사용하고, 양의 연결강도를 사용하였다.

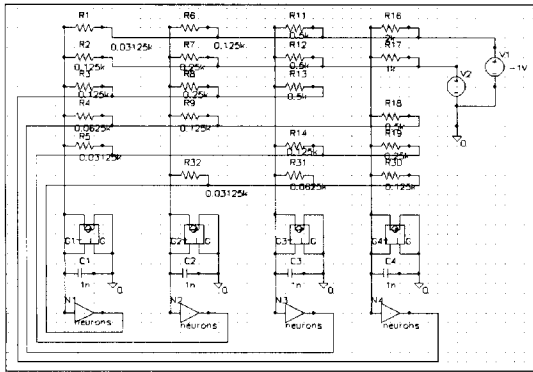


그림 3. 에너지 함수의 제 3항이 제거된 케환성을 갖는 단층신경회로망의 전기적 모델

Fig. 3. The electrical model of the eliminated the third term for Single Layer neural network with feedback.






그림 4. 뉴론의 입력력 함수
Fig. 4. Input and output functions of neuron.

시스템의 전력소모를 감소시키기 위하여 계산에너지 함수에 전체적으로 10^{-3} 을 곱하여 연결강도를 10^{-3} 으로 축소하였고, 연결강도(W)의 값인 컨덕턴스를 표현하기 위해서 전기적 모델에서는 저항을 사용하였다. 그래서, 종속전류원(G_i)들의 이득률 K의 값은 식(15)에 의해서 $K_1 = 56 \times 10^{-3}$, $K_2 = 44 \times 10^{-3}$, $K_3 = 26 \times 10^{-3}$, $K_4 = 14 \times 10^{-3}$ 이다. 즉, 저항 값은 컨덕턴스의 역수 값을 취해서 구했기 때문에 Hopfield의 논문^[11]에 나타난 연결강도 값에서 역수를 취하고 10^3 을 곱한 값이다. 시뮬레이션은 Microsim사의 Spice 6.3 버전이 사용되었고, 그림 5a는 제 3항이 있는 시스템에서 입력전압이 2.3V, $\lambda = 2$, 그리고 $g_i = 10$ 였을 때

Transient 시뮬레이션 결과를 보여주고, 그림 5b는 새로 제안된 방법에서 임의의 입력전압이 2.3V이고 $\lambda = 2$ 일 때 Transient 시뮬레이션 결과를 보여준다. 양의 연결강도를 사용하기 위하여 음수값을 갖는 뉴론을 사용했으므로 뉴론들에서 입력 u의 초기치들이 0이므로 출력v의 초기치들은 -1/2에서 시작하며 시간이 지나면서 수렴해감을 보여준다. 제 3항이 있는 경우(그림 5a)에서는 V_0 (LSB)가 디지털 값으로 수렴하지 못하고, 제안된 방법(그림 5b)에서는 디지털 값으로 수렴해 감을 보여주고 있다.



(a)



(b)

그림 5. (a) 에너지 함수에서 제 3항이 있는 시스템에서 입력전압이 2.3V, $\lambda = 2$, $g_i = 10$ 였을 때 시뮬레이션 결과 (b) 에너지 함수에서 제 3항이 제거된 시스템에서 입력전압이 2.3V, $\lambda = 2$ 일 때 시뮬레이션 결과

Fig. 5. (a) The electrical model of single layer neural network with feedback where the third term third exists. input voltage=2.3V, $\lambda = 2$, $g_i = 10$ 였 (b) The electrical model of single layer neural network with feedback where the third term is eliminated. input voltage = 2.3V, $\lambda = 2$.

제안된 방법과 제3의 에너지 항이 존재하는 방법의 결과를 비교해보기 위해 아날로그 입력 x 는 $[0, 15.5]$ 의 영역을 0.1씩 증가하면서 4bit A/D 변환기에 적용하여 Transient 시뮬레이션 하였다. 뉴런의 입력단에 연결된 g_i 의 값에 따른 영향을 보기 위하여 다음과 같은 g_i 의 값 즉, 100, 10, 1, 0.01를 그리고 $\lambda=10$ 으로 선택하여 시뮬레이션한 결과 155 경우의 수에서 각각 115, 121, 135, 135의 정확한 값으로 수렴하였다. 결과에서 알 수 있듯이 g_i 값이 증가할수록 오류가 발생하는 수가 증가하였으며, 이것은 g_i 의 값이 증가하면 제 3항 에너지가 증가하므로 예상된 결과이다. 그러나 제 3항 에너지가 존재하는 모델에서 g_i 의 값이 1 이하로 감소시켜도 더 이상의 에러를 줄이지 못하고 155 경우의 수 중 135 경우들이 정확한 값으로 수렴함을 나타내었다. 그리고 λ 의 값이 감소함에 따라 뉴런의 출력 V_i 들이 0 또는 1의 디지털 값에 수렴하지 못하는 경우가 발생하는 반면 제안된 모델에서는 λ 값의 변화(2, 5, 10)에도 항상 디지털 값으로 수렴하였고 155 경우의 수중 145의 정확한 값으로 수렴함을 보였다.

표 1. 에너지 함수의 제 3항이 존재하는 시스템의 시뮬레이션 결과, $g_i = 0.1$, $\lambda=10$

Table 1. The electrical model of Hopfield neural network with the third term, $g_i = 0.1$, $\lambda=10$.

입력 (정수부)	소수부									
	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
0	0	0	0	0	0	0	0.4			1
1	1	1	1	1	1	1	2	2	2	2
2	2	2	2	2	2	2.5	3	3	3	3
3	3	3	3	3	3	3	3	4	4	4
4	4	4	4	4	4	4.4	5	5		
5	5	5	5	5	5	6	6	6	6	6
6	6	6	6	6	6	7	7	7	7	7
7	7	7	7	7	7	7	8	8	8	8
8	8	8	8	8	8	8				9
9	9	9	9	9	9	9	10	10	10	10
10	10	10	10			10.5	11	11	11	11
11	11	11	11	11		12	12	12	12	12
12	12	12	12	12	12	12.4	13	13		
13	13	13	13	13	13	14	14	14	14	14
14	14				15	15	15	15	15	15
15	15	15	15	15						

표 2. 에너지 함수에서 제 3항이 제거된 시스템의 시뮬레이션 결과, $\lambda=10$

Table 2. The electrical model of Hopfield neural network where the third term is eliminated, $\lambda=10$.

입력 (정수부)	소수부									
	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
0	0	0	0	0	0	0.5	1	1	1	1
1	1	1	1	1	1	1			2	2
2	2	2	2	2	2	2.5	3	3	3	3
3	3	3	3	3	3	3			4	4
4	4	4	4	4	4	4.5	5	5	5	5
5	5	5	5	5		6	6	6	6	6
6	6	6	6	6	6	6.5	7	7	7	7
7	7	7	7	7	7	7	8	8	8	8
8	8	8	8	8	8	8.5	9	9	9	9
9	9	9	9	9	9	9		10	10	10
10	10	10	10	10	10	10.5	11	11	11	11
11	11	11	11			12	12	12	12	12
12	12	12	12	12	12	12.5	13	13	13	13
13	13	13	13			14	14	14	14	14
14	14	14	14	14	14	14.5	15	15	15	15
15	15	15	15	15	15					

표 1, 2에서는 $\lambda=10$ 일 때 시뮬레이션 결과를 보여 주며 표에서 오류가 발생한 부분은 음영으로 표시하였다. 오류가 발생한 부분을 관찰해 보면 표 1, 2에서 모두 대칭적으로 발생하는 것을 알 수 있었다. 즉, 표 1에서 6.2, 6.3, 6.4에서 오류가 생겼다면 7.5를 중심으로 4비트 시스템의 역학적으로 대칭인 8.8, 8.7, 8.6에서 오류가 역시 생겼음을 발견할 수 있었다. 표 2에서도 역시 7.5를 중심으로 하여 대칭적으로 성능이 향상되었고, 그래서 잔류된 오류들도 대칭적으로 발견되었다.

V. 결론

본 논문에서는 궤환성을 갖는 단층신경회로망의 계산에너지함수를 고찰하여서 계산에너지함수에 존재하는 제 3항을 제거하는 새로운 방법을 제안하였다. 종전의 경우 시그모이드 이득률을 작게 하였을 경우 제 3항의 에너지가 급증하여 그에 따라 시스템이 오류를 범하는 경우가 급증하게 되며, 시그모이드 이득률을 큰 값으로 하였을 경우 뉴런의 출력 값이 너무 급히 변하여 단위함수에 가깝게 되어, 시스템이 수렴하는

데 불안해지는 문제점이 있다. 본 논문에서는 뉴론의 입력 단계 중속전류원을 연결하여 시스템의 계산에너지함수에서 제 3항을 제거하였다. 그리하여, 시스템의 에너지함수를 최적화 하려는 비용함수에 보다 근접하게 함으로써, 시스템의 성능을 개선시켰다. 시뮬레이션 결과를 보면 성능이 향상되었음을 알 수 있으며, 또한 흥미 있는 발견은 오류가 발생한 부분이 역학적으로 시스템의 중심에서 대칭적으로 발생하는 것을 알 수 있었고, 즉 성능의 향상도 대칭적으로 됨을 알 수 있었다. 케환성을 갖는 단층신경회로망의 성능을 보다 향상시키려면, 시스템의 출력을 이진으로 보장할 수 있으면서, 최적화하려는 비용함수에 근접한 계산에너지함수를 구하는 연구와 더불어 대칭적으로 발생하는 오류현상의 해석을 위한 연구가 필요하다고 본다.

참 고 문 헌

[1] Hopfield, J. J. 1984. "Neurons with Graded Response Have Collective Computational Properties Like Those of Two State Neurons," Proc. National Academy of Sciences 81: 3088-3092.

[2] Hopfield, J. J., and D. W. Tank. 1985.

"Neural" Computation of Decisions in Optimization Problems, *Biolog. Cybern.* 52: 141-154.

[3] Hopfield, J. J., and D. W. Tank. 1986. "Computing with Neural Circuits: A Model," *Science* 233: 625-633.

[4] Park, S. 1989. "Signal Space Interpretation of Hopfield Circuit and a Linear Programming Circuit," *IEEE Trans. Circuits and Systems CAS-33*(5): 533-541.

[5] Bernard C, Levy 1987 "Global optimization with Stochastic Neural Networks", *IEEE, Int. Conf. on NN. Sandiego, CA. USA.*

[6] Zurada, J. M., and M. J. Kang. 1988. "Summing Networks Using Neural Optimization Concept," *Electron. Lett.* 24(10): 616-617.

[7] Zurada, J. M., and M. J. Kang. 1988. "Computational Circuits Using Neural Optimization Concept," *Int. J. Electron.* 67 (3): 311-320.

[8] 고경희, 강민제, 1996 "계산에너지함수 분석을 통한 Hopfield 신경회로망의 최적화" 제 5회 인공지능, 신경망 및 퍼지시스템 학술대회

저 자 소 개



高 景 希(正會員)
1972년 8월 1일생. 1995년 2월 제주대학교 전자공학과 학사. 1996년 3월 ~ 현재 제주대학교 전자공학과 석사과정 재학중. 주관심분야는 신경회로망, ASIC설계



康 珉 齊(正會員)
1958년 4월 27일생. 1982년 서울대학교 전기공학과 학사. 1989년 루이빌주립대학교 전기, 전자공학과 석사. 1991년 루이빌주립대학교 전기, 전자공학과 박사. 1992년 ~ 현재 제주대학교 전자공학과 조교수. 주관심분야는 신경회로망, ASIC설계