

연산회로 신경망

Computational Neural Networks

강민재

Min-Je Kang

요약

아날로그 합산과 선형방정식을 풀 수 있는 신경망구조가 제안되었다. 계산에너지함수에 근거하여 가중치를 구하는 Hopfield 신경망모델을 사용하였다. 아날로그 합산과 선형방정식은 각각 Hopfield의 A/D컨버터와 선형프로그래밍회로망을 이용하여 설계되었다. 시뮬레이션은 Pspice 프로그램을 이용하였으며, 그 결과들은 대부분 전체극소점으로 수렴함을 보였다.

ABSTRACT

A neural network structure which is able to perform the operations of analog addition and linear equation is proposed. The network employs Hopfield's model of a neuron with the connection elements specified on the basis of an analysis of the energy function. The analog addition network and linear equation network are designed by using Hopfield's A/D converter and linear programming respectively. Simulation using Pspice has shown convergence predominantly to the correct global minima.

Key Words : Analog additon, Linear equation, Hopfield, Neural Networks, Energy function, Convergence, Global minima.

I. 서론

시그모이дал 전압특성곡선을 갖는 뉴런들이 연결된 회로망이 계산에너지, 즉 회로망의 Lyapunov 함수의 극소점으로 수렴한다는 내용이 발표되었으며[1], 이 개념을 이용한 다양한 응용회로들, 다시 말하면, 아날로그 최적화회로망들이 제안되었다[2]. Tank과 Hopfield의 논문들에서 알려진 바와 같이 회로망은 뉴런, 연결강도, 그리고 외부입력으로 구성이 된다. 뉴런은 단일 프로세서로서 보통 연산증폭기를 사용하며, 뉴런의 입출력 전압특성곡선은 응용회로에 따라 시그모이드함수 이외의 다른 형태가 사용될 수 있다. 연결강도는 즉, 생물학적 용어로 시냅스라 부르며, 이 곳을 통해 뉴런들이 연결되며, 뉴런간의 정보가 교환된다. 연결강도의 값에 따라 전하는 정보의 양이 결정된다. 그리고 전기적으로는 컨디턴스로 표현되는데, 실제로는 저항이 사용되며, 그 값은 컨디턴스의 역수가 된다. 외부에서 유입되는 정보는 인과의 감지시스템에서 받아들여지는 신호로 비유될 수 있는데,

전기적으로 구성할 때는 전류원을 사용한다. 회로망은 시간이 흐름에 따라 계산에너지함수의 극소점으로 수렴하는 데, 이는 내린 빗물이 높은 곳에서 위치에너지가 낮은 쪽을 따라 흘러내리며 안정된 곳에 이르는 이치와 같다. 연결강도와 외부입력의 값들이 바뀌면 회로망의 수렴점이 바뀌는 데, 이는 계산에너지함수의 형태가 바뀌어서 수렴하는 경로가 바뀐다.

이 논문에서는 계산에너지함수를 분석하고, Hopfield 신경망의 최적화 개념을 확장하여 아날로그 합산 및 선형방정식을 풀 수 있는 신경망을 제시한다. 이날로그 합산회로는 계획성을 갖는 Hopfield 신경망을 이용하였고, 선형방정식회로는 Hopfield의 선형프로그래밍 신경망을 이용하였다. 그리고 시뮬레이션은 Pspice를 이용하였으며, 시뮬레이션결과들은 시간이 흐름에 따라 회로망이 안정된 곳으로 수렴함을 보였다.

II. Hopfield 신경망

그림1은 Hopfield 모델에서 I 번째 뉴런의 입력단을 보여준다. 연결강도 w_{ij} 은 다른 뉴런의 출력 Y_j 와 i번째 뉴런의 입력 u_i 를 연결하며 전기적 모델에서는 컨덕턴스로 표현되며, 전기적 소자로는 저항이 사용되며 그 값은 컨덕턴스의 역수가 된다. 인간의 감지시스템에서 들어오는 정보는 Hopfield 신경망에서는 외부의 입력전류 I_i 로 간주된다. 입력단에 부수적으로 연결된 저항 r 과 케페시터 c 는 회로의 안정화 수립에 중요한 역할을 한다[2]. 그리고 뉴런은 출력력 특성곡선은 함수 g 로 매핑된다[4].

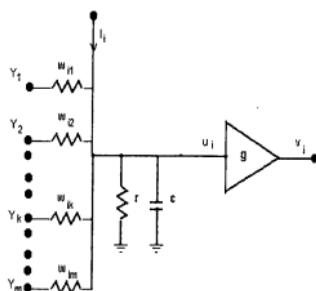


그림 1. I 번째 뉴런의 입력단.

Fig. 1. Input node of i-th neuron.

뉴런의 입력 단에서 세운 KCL(Kirchhoff Current Law)을 이용하여 다음의 공식이 유도된다[2]

$$c_i \left(\frac{du_i}{dt} \right) = i_i + \sum_{j \neq i} w_{ij} Y_j - u_i \left(\sum_j w_{ij} + \frac{1}{r_i} \right) \quad (1)$$

식(1)의 우변은 케페시터 c_i 로 유입되는 전류의 총량을 나타내며, 노드 I 번째 뉴런의 입력에 연결된 전체 컨덕턴스를 G_i 로 다음과 같이 나타내면

$$G_i \triangleq \sum_j w_{ij} + \frac{1}{r_i} \quad (2)$$

식(1)은 다음과 같이 간략히 나타내어진다.

$$c_i \left(\frac{du_i}{dt} \right) = i_i + \sum_{j \neq i} w_{ij} Y_j - G_i u_i \quad (3)$$

Hopfield 신경망은 Lyapunov 형태의 계산에너지함수를 갖고 있는 데, 이런 계산에너지함수를 다음과 같이 음방향으로 미분한

값이 I 번째 뉴런 입력단의 케페시터 c_i 로 유입되는 전류량과 같고,

$$-\frac{dE}{dv_i} = c_i \frac{du_i}{dt} \quad (4)$$

또한, 뉴런의 입력력 매핑함수 g 가 만약 다음과 같이 단조증가함수이면(주로 뉴런의 매핑함수로는 시그모이드함수가 사용하지만, 응용회로에 따라 다를 수 있다.),

$$g'(u) = \frac{dg(u)}{du} \geq 0 \quad (5)$$

신경망은 시간이 흐름에 따라 이 계산에너지가 감소하는 방향으로 수렴해 가는 안정된 시스템임을 다음과 같이 쉽게 알 수 있다.

$$\begin{aligned} \frac{dE}{dt} &= \frac{dE}{dv} \frac{dv}{dt} = -c_i \frac{du}{dt} \frac{du}{dt} \\ &= -c_i \left(\frac{du}{dt} \right)^2 g'(u) \leq 0 \end{aligned} \quad (6)$$

III. 연산회로의 설계

Hofield 신경망은 시간이 흐름에 따라 계산에너지함수를 최소화시키면서 수렴해 가는 회로로서 최적화 문제를 푸는 데 사용된다. Hofield 신경망이 발표된 이후로 최적화 개념을 이용한 많은 응용회로들이 소개되었다는 데, 그 회로들은 TSP(Traveling Sales man's Problem), Associative Memory, 선형프로그램밍, A/D컨버터, 신호변환 등 많은 분야에서 응용되었다.

이 논문에서는 Hopfield 신경망을 이용하여 아날로그 합산과 선형방정식을 풀 수 있는 회로를 설계하려 한다. 아날로그 합산 회로는 계획성을 갖는 Hopfield 신경망의 최적화개념을 이용하고, 선형방정식 회로는 Hopfield 선형프로그램밍 회로의 개념을 확장하여 설계하려 한다.

3.1 아날로그 합산회로의 설계

그림 2는 계획성을 갖는 Hopfield 신경망의 전기적 모델을 보여주며, 이 회로는 다음과 같은 계산에너지함수를 갖는다고 알려져 있다.

$$E(v) = -\frac{1}{2} \sum_i \sum_j w_{ij} v_i v_j - \sum_i i_i v_i + \sum_i G_i \int_0^{v_i} g_i^{-1}(z) dz \quad (7)$$

이 식을 음방향으로 미분하면

$$-\frac{dE}{dv_i} = \sum_j w_{ij} v_j + i_j - G_i u_i \quad (8)$$

뉴런의 입력단에 연결된 캐페시터 C 로 입력되는 전류와 같고, 또한 뉴런의 입출력 특성곡선 함수로 다음과 같은 단조증가 함수인 시그모이드 함수를 사용하면

$$v_i = g_i(u) = \frac{1}{1 + \exp(-\alpha u_i)} \quad (9)$$

여기서, α 는 양의 상수이다.

이 계산에너지함수는 Lyapunov함수가 될 모든 조건을 만족할 수 있다. 고로, 궤환성을 갖는 Hopfield 신경망은 시간이 흐름에 따라 계산에너지함수를 감소하면서 안정되게 수렴하는

함수의 형태로 바꾸면 된다. 고로, 합산회로의 비용함수를 LMS 형식으로 표현하면 다음과 같다.

$$E = -\frac{1}{2} (\sum_k a_k x_k - \sum_i v_i 2^i)^2 \quad (10)$$

여기서 x_k 들은 합산할 값이며 a_k 는 계수들이다. 식(10)을 최소화하면 $\sum_k a_k x_k$ 와 $\sum_i v_i 2^i$ 의 값이 같게 되지만 v_i 의 값이 이진값을 보장하지 않는다. 그래서, 뉴론 출력 v_i 의 값이 이진수가 되도록 도와주는 항이 부수적으로 첨가되어야 하는데 다음과 같다[2].

$$E_c = -\frac{1}{2} \sum_i 2^{2i} v_i (v_i - 1) \quad (11)$$

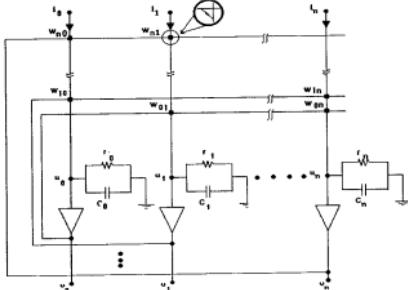


그림 2. 궤환성을 갖는 Hopfield 신경회로망의 전기적 모델

Fig. 2. Electrical model of Hopfield Neural Networks with feedback.

시스템임을 알 수 있다. 즉, 뉴런의 입출력함수는 식(9)의 시그모이드함수를 사용하므로 뉴런의 출력들은 0과 1사이의 값에 서 변하다가 계산에너지함수가 극소점에 이르게되면 뉴런의 출력들도 변화가 없어지게되고 일정한 값에 수렴하게 된다. 궤환성을 갖는 Hopfield 신경망은 외부에서 입력되는 전류와 뉴런간을 연결하는 연결강도의 값에 따라 수렴하는 값이 결정된다. 새로운 용융회로를 설계한다는 뜻은 새로운 계산에너지함수를 만들어 내는 것인 데, 다시 말하면 새로운 연결강도와 외부입력전류를 결정하는 것이다.

이 논문에서는 궤환성을 갖는 Hopfield 신경망을 이용하여 아날로그값들을 합산하여 출력은 디지털 값으로 표현하는 용융회로를 만들려고 한다. 아날로그값들을 합한 값을 가장 극값한 디지털 출력값으로 최적화시키기 위하여 LMS 형식으로 비용함수를 표현하고, 이 비용함수를 Hopfield 신경회로망의 계산에너지

v_i 가 0, 또는 1이면 E_c 는 영이 되고 그 외의 v_i 값에서는 양의 값을 지니게 되므로 즉, v_i 가 이진값 0 또는 1일 때 가장 낮은 에너지 값을 갖도록 함으로써, 식 (11)은 v_i 가 이진 값을 갖도록 도와준다. 고로, 총 비용함수는 다음과 같이 표현된다.

$$E_t = \frac{1}{2} (\sum_k a_k x_k - \sum_i v_i 2^i)^2 - \frac{1}{2} \sum_i 2^{2i} v_i (v_i - 1) \quad (12)$$

Hopfield 계산에너지함수 형태로 표현하면

$$E_t = -\frac{1}{2} \sum_{i,j} \sum_j (-2^{i+j} v_i v_j) - \sum_i (-2^{2i-1} + 2^i \sum_k a_k x_k) v_i + \frac{1}{2} (\sum_k a_k x_k)^2 \quad (13)$$

시스템의 연결강도 w 외부입력 i 를 구하기 위해 식(7)과 식(13)을 비교하면 다음과 같다.

$$w_{ij} = -2^{i+j} \quad (14)$$

$$i_i = -2^{2i-1} + 2^i \sum_k a_k x_k \quad (15)$$

그림 3은 n 개의 전압 x_k 들을 합산하는 회로이며, a_k 는 계수들이다. 합산결과는 뉴론의 출력에 이진수 형태, v_i ($i=0, 1, \dots, n-1$)로 표현된다.

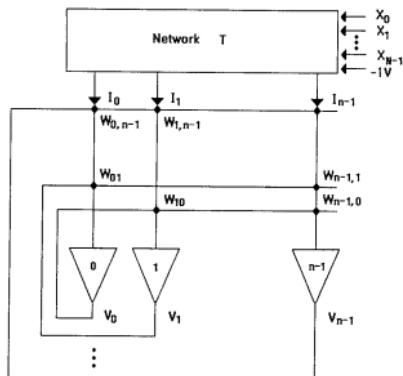


그림 3a. 합산 신경망의 블록도

Fig. 3a. Block diagram of addition neural network.

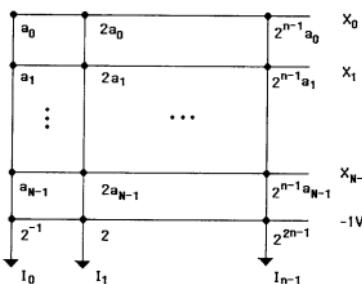


그림 3b. 합산신경망의 네트워크 T.

Fig. 3b. Network T of addition neural network.

3.2. 선형 방정식 신경망의 설계

그림 4는 Hopfield가 제안한 선형프로그래밍을 위한 신경망이다. 신경망은 두 부분으로 크게 나눌 수 있는 데, 비용함수와 제한조건을 표현하는 부분이다. 그래서 두 종류의 뉴런 입력력 특성작선을 사용한다. 그림 4에서 보면, g 로 표시된 뉴런들은 비용함수와 관련된 것이고, f 로 표시된 뉴런들은 제한조건과 관계된 것이다. 고로 바이어스 전류 a_i 는 비용함수에 따라 결정되는 것이고, D_{ij} 와 바이어스전류 b_i 는 제한조건함수에 따라 결정되는 값들이다. Hopfield는 이 회로에 대해 다음과 같은 Lyapunov 형태의 계산에너지함수를 소개하였다[1,4]

$$E = \sum_i a_i v_i + \sum_j F(\sum_i D_{ij} v_i - b_j) + \sum_l G_l \int_0^{v_l} g_l^{(-1)}(z) dz \quad (16)$$

여기서, 함수 f, g 는 각각 f 와 g 로 표시된 뉴런들의 매핑함수를 말하며, F 는 f 의 적분값을 뜻한다. Hopfield가 선형프로그래밍회로에서 제한조건을 만족시키기 위해 사용한 매핑함수 f 는 다음과 같다.

$$f(z) = \begin{cases} 0, & z \geq 0 \\ z, & z < 0 \end{cases} \quad (17)$$

식(16)을 음방향으로 미분하면, 즉 에너지가 감소하는 방향으로 미분하고, f 로 표시된 뉴런의 출력력이 Y 임을 이용하면 다음과 같은 방정식을 얻는다.

$$\begin{aligned} -\frac{dE}{dv_i} &= -a_i - \sum_j D_{ji} f(D_{ji} v_i - b_j) - G_i u_i \\ &= -a_i - \sum_j D_{ji} Y_j - G_i u_i. \end{aligned} \quad (18)$$

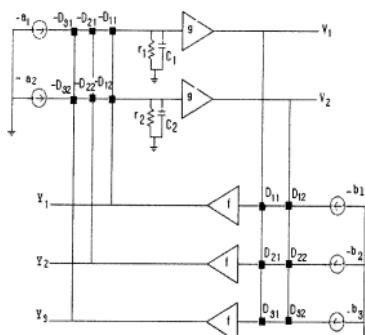


그림 4. 선형프로그래밍 신경망

Fig. 4. Linear programming Neural Networks.

역시, 식(18)을 보면, 뉴런 입력단에 연결된 케페시터 C 로 유입되는 전류량과 같음을 알 수 있고, 또한 변수를 위한 연산증폭기의 입력력함수로 다음과 같은 단조증가함수를 사용하면,

$$g(u) = \beta u \quad \text{여기서, } \beta \text{는 상수} \quad (19)$$

이 에너지함수 또한, 시간의 흐름에 따라 에너지가 감소하는 방향으로 수렴하는 Lyapunov 함수임을 알 수 있다. 식(16)의 첫째 항은 비용함수를 표현하고, 둘째 항은 제한조건들을 표현하기 위한 항이며, 셋째 항은 뉴런의 입출력특성곡선을 조절하여 아주 작게 만들어야 하는 항이다. 여기서 선형방정식을 풀기 위하여 우리가 관심을 갖는 항은 둘째 항이다. 즉, 벡터 $Dv - b$ 의 norm인 데, 이 회로망은 이 벡터의 norm을 가능한 영에 가깝게 최소화하도록 노력하면서 다음의 행렬식을 푼다.

$$Dv = b \quad (20)$$

그래서 만약 D^{-1} 가 존재하면 유일한 해가 존재한다. 이는 우리가 만약 나머지 두 항, 즉, 첫째 항과 셋째 항을 영으로 또는 무시할 수 있을 정도로 작게 만들 수 있으면 신경망은 선형방정식을 풀 수 있음을 뜻한다. 벡터 $Dv - b$ 의 norm이 영에서 최소값을 갖고 이 벡터의 norm이 클수록 더욱 더 큰 값으로 표현되는 계산에너지함수는 다음과 같이 표현될 수 있다.

$$\sum F(u(v)) = \sum \int_0^v f(w) dw = \begin{cases} 0, & w(v) = 0 \\ \text{양의 값}, & w(v) \neq 0 \end{cases} \quad (21)$$

여기서, $u(v) = Dv - b$

그리고, 식(21)을 만족하는 제한조건 연산증폭기의 입출력함수 f 를 찾아야 한다. 이런 조건을 만족하는 함수 중의 하나는 다음과 같고,

$$f(z) = kz \quad (22)$$

그 적분값은 다음과 같다.

$$F(z) = \int_0^z kz dz = \frac{k}{2} z^2 \quad (23)$$

고로, 우리의 목표가 식(20) 형태의 선형방정식을 푸는 것이다. 벡터 b 를 제한조건을 위한 연산증폭기의 입력전류로 사용하고 식(16)의 첫째 항을 영으로 만들기 위해 a 를 영으로 정하면, 식(16)은 다음과 같이 표현된다.

$$E = \sum_j F(\sum_i D_{ji}v - b_j) + \sum_i G_i \int_0^{v_i} g_i^{(-1)}(z) dz \quad (24)$$

식(19)과 식(23)를 이용하여 식(24)를 다음과 같이 정리 할 수 있다.

$$\begin{aligned} E &= \sum_j \frac{k}{2} (\sum_i D_{ji}v - b_j)^2 + \sum_i G_i \int_0^{v_i} \frac{1}{\beta} v dv \\ &= \frac{k}{2} \|Dv - b\|^2 + \frac{G}{\beta} \|v\|^2 \end{aligned} \quad (25)$$

신경망은 시간의 흐름에 따라 계산에너지함수를 최소화하는 방향으로 수렴해 간다. 즉, 식(25)의 첫째 항이 최소화 되면서 연산증폭기의 출력 v 는 선형방정식의 해인 $Dv = b$ 에 접근하게 된다. 그런데, 둘째 항도 최소화 되면서 출력 v 가 선형방정식의

해와 관계없이 영에 가까운 값으로 변하므로 이 것이 문제가 된다. 이를 해결하기 위해 보통의 방법은 식(25)에서 알 수 있듯이 뉴런의 입출력함수에서 기울기 β 를 아주 큰 값으로 선택하거나 입력단위의 콘센더턴스를 작게하여 출력 v 와 무관하게 그 값을 최소화 한다.

IV. 시뮬레이션 및 결과

4.1 아날로그 합산회로

합산회로의 시뮬레이션은 Pspice를 사용했고, 시스템의 전력소모를 감소시키기 위하여 계산에너지함수에 전체적으로 10^{-3} 을 곱하여 연결강도를 10^{-3} 로 축소하였고, 연결강도 w 를

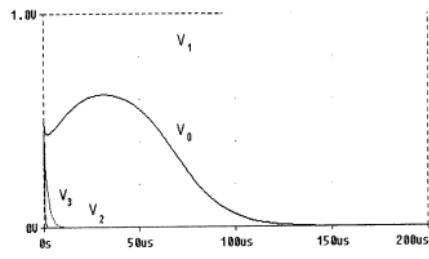


그림 5a. $\sum_k a_x x_k = 1.8$ 의 Pspice transient 결과.

Fig. 5a. Pspice transient result for $\sum_k a_x x_k = 1.8$.

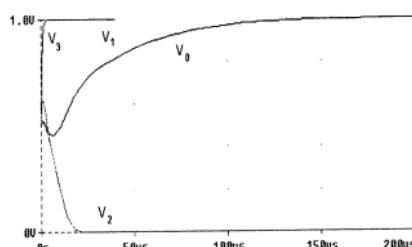


그림 5b. $\sum_k a_x x_k = 10.8$ 의 Pspice transient 결과.

Fig. 5b. Pspice transient result for $\sum_k a_x x_k = 10.8$.

표현하기 위해서 전기적 모델에서는 저항을 사용하였다. 즉, 저항 값은 컨센더턴스의 역수 값을 위해서 구했기 때문에 연결강도 값에서 역수를 취하고 10^3 을 곱한 값이다. 그림 5들은 아날로그

합산된 값이 각각 1.8과 10.8에 대한 Pspice의 transient 시뮬레이션 결과를 보여주고 있다. 이 둘 아날로그 입력 값에 대응하는 디지털 값 2와 11로 즉, 옳은 곳으로 수렴함을 보여주고 있다. 테이블 1은 아날로그의 합을 [0, 15.5]의 영역에서 0.1씩 증가시키면서 4비트 아날로그 합산회로에서 테스트한 결과를 보여 주고 있다. 155경우에서 145 경우 전체최소점으로 수렴하였으며, 지역극소점으로 수렴한 경우 일자라도 good 해답이라 할 수 있는 전체최소점과 매우 가까운 값을 나타내고 있다.

표 1. 4-비트 합산기 시뮬레이션 결과: 입력 [0,15.5].

Table 1. Simulation results for a four-bits adder: input [0, 15.5].

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	0.5	1	1	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	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	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	9	10	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	12.5	13	13	13	13	13
13	13	13	13	14	14	14	14	14	14	14
14	14	14	14	14	14.5	15	15	15	15	15
15	15	15	15	15						

4.2. 선형방정식 회로

선형방정식을 위한 신경망회로를 위해 다음과 같은 방정식을 예로서 선택하였다.

$$\begin{bmatrix} 2 & 6 & 1 \\ 1 & 2 & -1 \\ 5 & 7 & -4 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} = \begin{bmatrix} 7 \\ -1 \\ 9 \end{bmatrix} \quad (26)$$

고로, 연결강도 D는 다음과 같고,

$$D = \begin{bmatrix} 2 & 6 & 1 \\ 1 & 2 & -1 \\ 5 & 7 & -4 \end{bmatrix} \quad (27)$$

제한조건 연산증폭기의 외부입력 b는 다음과 같다.

$$b = \begin{bmatrix} 7 \\ -1 \\ 9 \end{bmatrix} \quad (28)$$

그림 6은 Pspice 시뮬레이션 결과들을 보여주고 있으며, 약 5us에서 오차의 범위가 0.001V미만이며, 시간이 지남에 따라 오차는 점점 줄어서 해석적인 해와 거의 일치함을 보여 주고 있다. 처음에는 뉴런의 출력들이 진동하다가 시간이 지남에 따라 선형방정식의 해($v_1=10$, $v_2=-3$, $v_3=5$)로 수렴함을 알 수 있다.

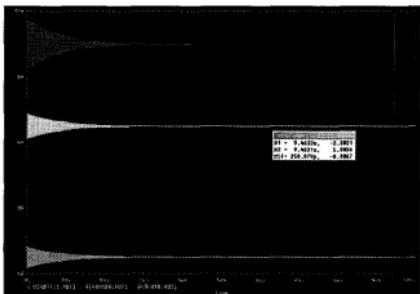


그림 6. 예제를 위한 시뮬레이션 결과
Fig. 6. Simulation Result of case study.

V. 결론

이 논문에서는 아날로그 합산회로와 일관적인 선형방정식 문제를 풀 수 있는 신경망을 제안하였다. 궤환성을 갖는 Hopfield 신경망을 이용하여 아날로그 합산회로와, Hopfield의 선형프로그램회로를 이용하여 선형방정식을 풀 수 있는 회로를 제안하였다.

아날로그 합산회로는 아날로그 값들을 합한 값을 가장 근접한 디지털 출력 값으로 최적화 시키기 위하여 LMS 형식으로 비용함수를 표현하고, 이 비용함수를 Hopfield 신경회로망의 계산에너지함수의 형태로 바꾸었다. 즉, 시간이 흐름에 따라 계산에너지함수가 최소화됨에 따라 아날로그 합한 값은 디지털 출력 값과 근사하게 된다. 디지털 출력을 위해 뉴런의 입출력 특성곡선은 시그모이드함수를 사용하였다.

선형방정식회로는 Hopfield의 선형프로그램회로를 사용하

였다. Hopfield의 선형프로그램밍회로는 비용함수와 제한조건을 위한 두 부분으로 나눌 수 있는 데, 이 논문에서는 이 제한조건 부분을 이용하여 선형방정식을 풀 수 있는 신경망을 설계하였다. 즉, 행렬식 $Dv = b$ 를 풀기 위해, 이 행렬식을 선형프로그램밍의 제한조건으로 바꾸었다. 그래서, 시간이 흐름에 따라 신경망은 계산에너지함수를 최소화하면서 이 행렬식을 풀게 하였다. 그리고 출력은 실수의 진구간에서 적용되므로, 뉴런의 입출력함수는 선형함수를 사용하였다.

이 논문에서는 우선 확장된 신경망이 항상 안정되게 수렴함을 증명하기 위하여 회로레벨의 시뮬레이션 프로그램 Pspice를 이용하였다. 시뮬레이션결과는 해석적인 해와 거의 일치함을 보였다. 가끔, 시스템이 전체 극소점으로 수렴하지 못하고, 지역극소점으로 빠지는 경우가 있으으나, 이 경우도 전체극소점과 비슷함을 나타내었다. 종종 지역극소점으로 수렴하는 것이 Hopfield 신경망이 갖고 있는 문제이며, 이 문제를 해결하기 위한 방법으로 많은 방법들이 사용되고 있다. 향후 연구에서는 이런 문제를 해결하기 위한 노력이 필요할 것 같다.

접수일자 : 2001. 12. 8

수정완료 : 2002. 1. 4

참고문헌

[1] Hopfield, J. J., and D. W. Tank, "Neural Computation of Decisions in Optimization Problems," *Biolog. Cybern.* 52: 141-154, 1985

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

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

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

[5] Anthony N. Michel, Jay A. Farrel and Wolfgang Porod, 1989, "Qualitative Analysis of Neural Networks." *IEEE Trans. Circuits Syst.*, vol 36, pp. 229-243, February 1989.

[6] Mengkang Peng, Narebda K. Gupta and Alistair F. Armitage, " An investigation into the Improvement of Local Minima of the Hopfield Network" *Neural Networks* ,Vol. 9, pp. 1241-1253, 1996.

[7] Anthony N. Michel, Jay A. Farrel and Wolfgang Porod, 1989, "Qualitative Analysis of Neural Networks." *IEEE Trans. Circuits Syst.*, vol 36, pp. 229-243, February 1989.

[8] Takeshi Kamio, Hiroshi Ninomiya and Hideki Asai, "A Neural Net Approach to Discrete Walsh Transformation," *IEICE Trans. Fundamentals*, vol. E77-A, No.994.

[9] Mengkang Peng, Narebda K. Gupta and Alistair F. Armitage, " An investigation into the Improvement of Local Minima of the Hopfield Network" *Neural Networks* ,Vol. 9, pp. 1241-1253, 1996.

[10] Naoki Kurita and Ken-ichi Funahashi, "On the Hopfield Neural Networks and Mean Field Theory" *Neural Networks*, Vol. 9, pp. 1531-1540, 1996.

[11] L. O. Chua and G. N. Lin, "Nonlinear programming without computation," *IEEE Trans. Circuits Syst.*, vol. CAS-32, p. 736, July 1985.



강민제(Min-Je Kang)

正会員

1982년 서울대 전기공학과 졸업.

1991년 Univ. of Louisville

전기공학과 졸업(공학박사)

1992년~현재 세주대 전기, 전자공학부
부교수