

---

 論 文
 

---

大韓造船學會論文集  
 第 33 卷 第 2 號 1996年 5月  
 Transactions of the Society of  
 Naval Architecture of Korea  
 Vol. 33, No. 2, May 1996

## 뉴럴 네트워크에 의한 선체 중앙단면 최적구조설계

양영순\*, 문상훈\*\*\*, 김신형\*\*

### Optimum Design of Midship Section by Artificial Neural Network

by

Y. S. Yang\*, S. H. Moon\*\*\* and S. H. Kim\*\*

#### 요 약

1960년대 중반 전산기를 이용한 선체 구조설계가 최초로 시도된 후 국내에서도 1980년부터 중앙단면 최적설계에 관한 많은 연구가 이루어져 왔다. 선급규정에 의한 선체 중앙단면 최적설계를 할 경우, 야기되는 문제로서는 부재 치수, 부재 개수와 같은 이산변수를 다루어야 하는 어려움이 있어, 이러한 문제를 해결하고자 유전자 알고리즘이나 인공신경망 등의 새로운 최적화 기법의 개발에 관한 연구 등이 진행되고 있다. 이와 같은 관점에서 본 연구에서는 선체 구조설계 문제에 효율적인 최적화 방법을 개발함에 있어, 홉필드 네트워크 모델과 시뮬레이티드 어닐링을 결합하여 Neuro-Optimizer를 개발하고, 이를 토대로 구조공학 문제의 하나인 간단한 트러스 구조물의 최적설계와 선체의 중앙단면 최적설계에 적용하여, 새로운 최적화 기법으로서 가능성이 있음을 확인하였다.

#### Abstract

Since the use of computer for the ship structural design around mid 1960's, specially many researches on the midship section optimum design were carried out from 1980. For a rule-based optimum design case, there has been a problem of handling a discrete design variable such as plate thickness for a practical use. To deal with the discrete design variable problems and to develop an effective new method using artificial neural network for the ship structural design applications, Neuro-Optimizer combining Hopfield Neural Network and other Simulated Annealing is proposed as a new optimization method and then applied to the

---

접수일자 : 1995년 12월 26일, 재접수일자 : 1996년 3월 11일

\* 정회원, 서울대학교 조선해양공학과

\*\* 서울대학교 조선해양공학과

\*\*\* 대우중공업(주) 거제조선소

fundamental skeletal structures and Midship section of Tanker. From the numerical results, it is confirmed that Neuro-Optimizer could be used effectively as a new optimization method for the structural design.

### 1. 서 론

기존의 컴퓨터 시스템은 빠른 계산 능력을 이용하여 복잡한 문제를 짧은 시간 내에 풀 수 있는 방법을 제공하지만, 사람의 두뇌와 같이 패턴 인식이나 연상 등과 같은 지적 기능을 수행하는데 미흡한 점이 있다. 그래서 이러한 지적 능력을 컴퓨터로 하여금 수행토록 하는 인공지능 연구가 관심을 끌어 왔다. 그 중에서도 전문가 시스템은 지식의 표현과 처리방법에 관한 매크로적 입장의 연구라 하면, 뉴럴 네트워크는 주로 신경학적 연구로서 사람의 두뇌의 구성요소인 뉴런이 어떻게 작동하는가에 대한 마이크로적 접근방법의 연구라 할 수 있다.

뉴럴 네트워크 모델에서 대표적인 것은 다층구조를 갖는 역전파(Back-Propagation) 네트워크 모델로서 많은 연구가 이 모델의 이용을 기반으로 하여 이루어 졌으나, 이 모델을 사용하려면 네트워크를 학습시키는 입출력 자료가 사전에 준비되어 네트워크를 훈련시켜야 되는 문제점이 있어, 기존의 충분한 데이터 베이스가 없는 문제에 적용할 경우 입출력 자료 준비에 어려움이 있다. 그래서 Hopfield는 네트워크의 에너지 상태를 최소화시킨다는 개념을 도입하여 입출력의 자료로 네트워크를 학습시키는 방법 대신에, 계산 수행과정에서 네트워크의 에너지를 감소시키는 방향으로 각 뉴런의 상태를 변화되도록 하는 Network Model 을 Tank 와 더불어 제안한 바 있다[1].

합리적 구조물이란 주어진 기능과 필요한 성능을 만족시키고, 안전하며 저가의 가벼운 구조물을 의미한다. 이러한 구조물의 설계를 위해서는 정확한 해석방법과 최적 설계방법의 활용이 필요하다. 해석방법으로선 유한요소법의 발전으로 그

응용 범위와 해석 정도가 매우 좋아지고 있는 상태이며, 이러한 해석결과를 바탕으로 최적해를 구하는 설계방법도 또한 많이 연구되어 있다.

공학설계의 최적화 문제는 일반적으로 국부 최적점들이 다수 존재하고 있어, 기존의 최적화 방법에서는 전체 최적점을 찾기 위해 서로 다른 초기점들을 이용하여 얻은 다수의 국부 최적해 중에서 최상의 결과를 선택하는 방법을 사용하여 왔다. 이러한 방법은 다수의 초기점에 대한 반복 계산과 설계 가능영역 전구간에 대한 검토가 요구되어, 설계변수가 많고 제한조건이 복잡한 경우 초기점의 선정에 어려움이 있어 왔다.

1960년대 중반 전산기를 이용한 선체 구조설계가 최초로 시도된 후 국내에서도 1980년부터 중앙단면 최적설계에 관한 많은 연구가 이루어져 왔다[2]. 선급규정에 의한 선체 중앙단면 최적설계를 할 경우, 야기되는 문제로서는 부재 치수, 부재 개수와 같은 이산변수를 다루어야 하는 어려움이 있어, 이러한 문제를 해결하고자 유전자 알고리즘이나 인공지능망 등의 새로운 최적화 기법의 개발에 관한 연구가 진행되고 있다[3][4][5].

이와 같은 관점에서 본 연구에서는 선체 구조설계 문제에 효율적인 최적화 방법을 개발함에 있어, 홉필드 네트워크 모델과 시뮬레이티드 어닐링을 결합하여 최적화 과정의 문제인 국부적 최적해를 구하는 대신, 주어진 문제에 대해 전역적 최적해를 찾는 방법으로서, 우선 이론적인 측면에서 몇 가지의 수학 모델에 대해 인공지능망을 이용한 최적화 기법[6]을 개발하고, 이를 토대로 구조공학 문제의 하나인 간단한 기본 구조물의 최적설계에 적용하여 그 가능성을 확인하며, 끝으로 이 Neuro-Optimizer 를 선체의 중앙단면 설계 문제

에 적용하여, 새로운 최적 구조설계 방법의 가능성을 검토하고자 한다.

## 2. 뉴럴 네트워크의 개요

### 2.1 뉴럴 네트워크의 구조

생물학적 신경망은 수많은 뉴런들의 연결 구조로 이루어져 있다. 인공 신경망은 생물학적 신경망의 복잡한 구조를 간략하게 단순화시킨 형태를 취하고 있다. Fig. 1 은 생물학적 뉴런의 구조를 보이고 있고, Fig. 2 는 인공 뉴런의 구조를 보이고 있다.




Fig. 1 Structure of biological neuron

생물학적 뉴런은 수지상 돌기(Dendrite)를 통해서 다른 뉴런들로부터 입력을 받고, 자신이 만들어 낸 출력을 축색 돌기(Axon)을 통해서 다른 뉴런에 전달한다. 이때 축색 돌기는 다른 뉴런의 수지상 돌기와 연결 되어지는데 이를 연결부(Synapse)라 하고, 그 강도를 연결강도라 한다.




Fig. 2 Structure of artificial neuron

인공 뉴런은 자신과 연결된 다른 뉴런들로부터 입력벡터  $X$  를 받고, 자신의 함수 기능  $f$  를 수행하여 다른 뉴런에 그 출력  $y$  를 전달한다. 이 때 각 입력  $x_j$  는 연결 강도  $w_{ij}$  와 곱해져서 입력

된다. 따라서, 하나의 뉴런은 외부의 입력을 받아들여 자신의 출력을 만들어 내는 (1)식과 같은 함수로 생각할 수 있다.

$$y_i = f(\sum w_{ij} x_j + \theta_i) \quad (1)$$

where  $y_i$ : 뉴런  $i$ 의 출력

$x_j$ : 뉴런  $j$ 의 입력

$w_{ij}$ : 뉴런  $i$ 와  $j$ 의 연결 강도

$\theta_i$ : 뉴런  $i$ 의 바이어스(Bias)

$f$ : 전이 함수(Transfer Function)

전이함수는 일반적으로 Sigmoid Function 을 사용하였다.

$$\text{Sigmoid Function : } y = \frac{1}{1 + e^{-x}} \quad (2)$$

### 2.2 뉴럴 네트워크를 이용한 최적화

1982년 John Hopfield는 연상기억 특성을 갖는 새로운 개념의 인공신경망 모델을 제안하였다. Hopfield는 네트워크의 상태를 에너지로 나타냈는데, 홉필드 네트워크는 에너지가 항상 감소하여 최소 에너지 상태로 수렴하는 성질을 갖고 있다. 이러한 성질은 최적화 기법과 상당히 유사하기 때문에, 홉필드 네트워크를 이용하여 최적화 문제를 풀려는 시도가 일찍부터 이루어졌다.

#### 1) 홉필드 네트워크의 구조

홉필드 네트워크에는 백-프로퍼게이션 모델에서 보이는 다층 구조가 존재하지 않고, Fig. 3에 보이는 바와 같이 피드백 구조를 갖고 있다.




Fig. 3 Structure of hopfield network

2) 네트워크의 상태 변화

홉필드 네트워크의 각 뉴런은 상태  $V_i$  와 바이어스  $I_i$  를 갖고, 각 뉴런들은 연결 강도  $T_{ij}$ 에 의해 연결되어 있다. 뉴런 상태  $V_i$  는 0, 1의 바이너리 값만 가능하다. 각 뉴런의 입력값  $U_i$  는 (3)식에 의해 계산되며 이에 따른 뉴런의 상태 변화는 (4)식에 따른다.

$$U_i = \sum T_{ij} V_j + I_i \quad (3)$$

$$V_i = \begin{cases} 1 & \text{if } U_i \geq 0 \\ 0 & \text{if } U_i < 0 \end{cases} \quad (4)$$

3) 에너지 함수와 안정성

Hopfield는 홉필드 네트워크의 상태를 에너지라는 개념으로 표현하였고 (5)식과 같이 에너지 함수를 정의하였다.

$$E = -\frac{1}{2} \sum \sum T_{ij} V_i V_j - \sum V_i I_i \quad (5)$$

(3), (4), (5)식을 이용하여, 하나의 뉴런이 상태를 바꿀 때 발생하는 에너지의 변화를 계산해 보면 (6)식과 같다.

$$\Delta E = -\Delta V_i (\sum T_{ij} V_j + I_i) \quad (6)$$

어느 한 뉴런의 상태  $V_i$  가 입력값  $U_i$  에 따라 상태를 바꿀 때 일어날 수 있는 경우는 Table 1 과 같은 4 가지 경우이다.

Table 1에서 보듯이 4가지 경우 모두 에너지는 감소하거나 변하지 않는다. 따라서, 에너지는 항상 감소한다고 생각할 수 있다.

Table 1 Energy change of hopfield network

$V_i(t)$	$U_i = \sum T_{ij} V_j + I_i$	$V_i(t+1)$	$\Delta V_i$	$\Delta E$
0	+	1	1	-
0	-	0	0	0
1	+	1	0	0
1	-	0	-1	-

4) 홉필드 네트워크를 이용한 최적화 방법

1. 최적화 문제의 홉필드 신경망의 적용과정

최소에너지 상태로 수렴하는 신경망의 특성을 이용해서 다음의 방법으로 최적화를 수행한다.

(1) 목적함수와 제한조건을 포함한 최적화 문제를 홉필드 신경망으로 근사한다.

이산간격이  $d_i$  인 설계변수  $X_i$  를  $N_i$  개의 뉴런으로 표현하면 다음의 식(7) 과 같다.

$$X_i = d_i \sum_{j=1}^{N_i} V_j \quad (7)$$

(2) 홉필드 신경망을 규칙에 따라 작동시켜 수렴시킨다.

(3) 수렴된 홉필드 신경망으로부터 문제의 해를 구한다.

2. 연결강도 구하기[7]

한 번의 연결강도 결정으로 최적화 문제 전체를 모사하는 기존의 방법에서 단계를 나누어서 각 단계별로 Taylor 전개를 통하여 2 차로 근사하여 연결강도를 구하고 그 다음 단계로 진행할 설계변수를 구하는 점진적인 방법을 적용하였다.

(1) 목적함수의 2 차 근사

에너지 함수가 2 차 식이므로 목적함수를 주어진 점에서 Taylor 전개를 이용하여 2 차 함수로 근사한다.

$$\begin{aligned}
 f(X, X^k) &= Q_E(X, X^k) + Q_C(X^k) \\
 Q_E(X, X^k) &= \frac{1}{2} X^T \nabla^2 f(X^k) X \\
 &\quad + [\nabla f^T(X^k) - (X^k)^T \nabla^2 f(X^k)] X \\
 Q_C(X^k) &= f(X^k) - \nabla f(X^k) X^k \\
 &\quad + \frac{1}{2} (X^T)^T \nabla^2 f(X^k) X^k
 \end{aligned} \tag{8}$$

목적함수  $f$  는  $X^k$  에서 변수를 포함한  $Q_E$  와 상수인  $Q_C$  로 전개가 되며 증감의 방향은  $Q_E$  와 같아진다.

(2) 연결강도와 바이어스 구하기

2 차로 근사된 목적함수는 다음 식(9)와 같다.

$$\begin{aligned}
 Q_E(X, X^k) &= -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \left\{ -\frac{\partial^2 f(X^k)}{\partial x_i \partial x_j} x_i x_j \right\} \\
 &\quad - \sum_{i=1}^n \left\{ \sum_{j=1}^n \frac{\partial^2 f(X^k)}{\partial x_i \partial x_j} x_j^k - \frac{\partial f(X^k)}{\partial x_i} \right\} x_i
 \end{aligned} \tag{9}$$

신경망의 에너지 함수는 다음 식(10)과 같다.

$$\begin{aligned}
 E(V, V^k) &= -\frac{1}{2} \sum_{i=1}^n \sum_{p=1}^{N_i} \sum_{j=1}^n \sum_{q=1}^{N_j} T_{ip, jq}^k V_{ip} V_{jq} \\
 &\quad - \sum_{i=1}^n \sum_{p=1}^{N_i} I_{ip}^k V_{ip}
 \end{aligned} \tag{10}$$

위의 두 식을 등치하고 식(7) 의 변수 표현식을 이용하면 다음 식 (11) 과 같이 연결강도와 바이어스가 구해진다.

$$T_{ip, jq}^k = -d_i d_j \frac{\partial f(X^k)}{\partial x_i \partial x_j} \tag{11}$$

$$I_{ip}^k = d_i \left\{ \sum_{j=1}^n \frac{\partial^2 f(X^k)}{\partial x_i \partial x_j} x_j^k - \frac{\partial f(X^k)}{\partial x_i} \right\}$$

위의 식으로 설계변수  $X^k$  에서의 연결강도와 바이어스를 구할 수 있다. 구해진 연결강도와 바이어스로 신경망을 작동시키고 수렴된 상태에서부터 설계변수  $X^{k+1}$  을 구하여 반복계산을 한다.

3. 제한조건 및 미계수 처리

식(12) 와 같은 라그랑지 멀티플라이어 방법으로 제한조건을 처리하였다.

$$\begin{aligned}
 L(X, \lambda, \gamma_p) &= F(X) + \sum_{j=1}^m \{ \lambda_j \psi_j + \gamma_p \phi_j^2 \} \\
 \phi_j &= \max \left[ g_j(X), \frac{-\lambda_j}{2\gamma_p} \right]
 \end{aligned} \tag{12}$$

$$\lambda_j^{p+1} = \lambda_j^p + 2\gamma_p \phi_j(X)$$

$$j = 1, 2, \dots, m$$

뉴런의 갱신에 필요한 목적함수의 미계수는 수치미분을 통해서 구하였다. 미계수를 구할 때의 스텝간격은 설계변수가 이산변수인 경우는 이산간격을 이용하였고, 설계변수가 정수인 경우는 1 을 취해서 제한조건의 급격한 단절에 의한 불연속의 문제를 어느 정도 피해 가도록 하였다.

2.3 최적화 문제로의 적용 결과

1) Goldstein-Price Function

$$\begin{aligned}
 F(x_1, x_2) &= \{1 + (x_1 + x_2 + 1)^2(19 - 14x_1 \\
 &\quad + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)\} \\
 &\quad \times \{30 + (2x_1 - 3x_2)^2\} \\
 &\quad \times \{18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2\} \\
 &\quad - 2 \leq x_i \leq 2
 \end{aligned}$$

$$X^* = \{0, -1\} \quad F = 3 \tag{13}$$

Table 2 Initial point and optimum results

X <sub>init</sub>		X*		F	Remark
0.5	1	1.2	0.8	840	Local
1.5	0	1.8	0.2	84	Local
0	0	-1.4	-1.6	30	Local
-1	1	0	-1	3	Global

초기점에 따라서 3 개의 국부해와 1 개의 전역 해를 구하였다.

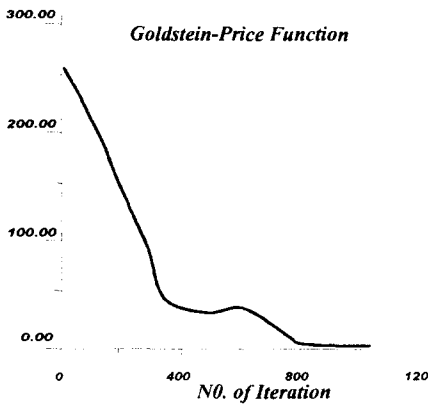


Fig. 4 Energy state of G-P function

2) 3-Bar Truss (이산 변수의 경우)

이산변수를 가지는 3-Bar Truss 문제에 대해 최적해를 구하였다.




Fig.5 3-Bar truss

Minimize  $F = 2x_1 + x_2 + \sqrt{2}x_3$

Subject to

$$g_1 = -1 + \frac{\sqrt{3}x_1 + 1.932x_2}{1.5x_1x_2 + \sqrt{2}x_1x_2 + 1.319x_1x_3} \leq 0$$

$$g_2 = -1 + \frac{0.634x_1 + 2.828x_2}{1.5x_1x_2 + \sqrt{2}x_1x_2 + 1.319x_1x_3} \leq 0$$

$$g_3 = -1 + \frac{0.5x_1 + 2x_2}{1.5x_1x_2 + \sqrt{2}x_1x_2 + 1.319x_1x_3} \leq 0$$

$$g_4 = -1 - \frac{0.5x_1 + 2x_2}{1.5x_1x_2 + \sqrt{2}x_1x_2 + 1.319x_1x_3} \leq 0 \quad (14)$$

$$x_i = \{0.1, 0.2, 0.3, 0.5, 0.8, 1.0, 1.2\}$$

위의 3-Bar Truss 문제에서 다음과 같은 이산 전역 최적해를 구하였다.

$$X = \{1.2, 0.5, 0.1\} \quad F(X^*) = 3.0414$$

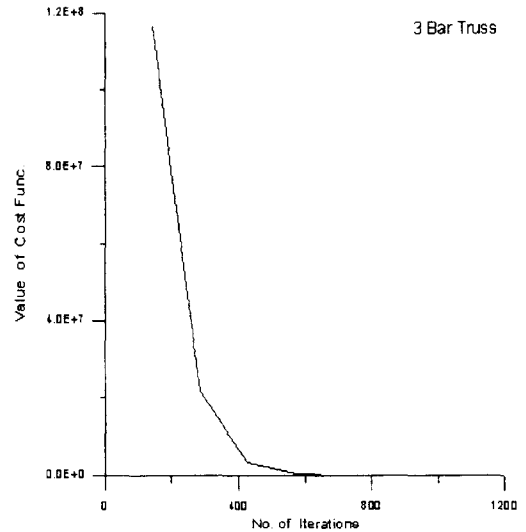


Fig. 6 Energy state of 3 bar truss

3) 4-Bar Truss (연속 변수)

Fig. 7 과 같이 연속변수를 갖는 4 Bar Truss 에 대해 최적해를 구해 보았는데, 이를 최적화 문제로 정식화하면 식(15)와 같이 표현된다.

$$\text{Minimize } F = \sum_{i=1}^4 \rho L_i x_i$$

$$L_i = \{1000, 1000, 1000, 1414\}$$

Subject to

$$g_i = \frac{N(x)}{x_i} - \sigma_{cr} \leq 0$$

$$\text{where } \sigma_{cr} = 25 \text{ N/mm}^2 \cdot \rho = 86.343 \text{ N/mm}^3$$

(15)

위의 4-bar Truss 역시 다음과 같은 최적해를 구하였다.

Optimum point

$$X = \{34.66, 20.1, 5.4, 56.6\}$$

$$F(X^*) = 12104686$$




Fig. 7 4 Bar truss

### 3. 뉴로-옵티마이저

뉴로-옵티마이저[6]는 홉필드 네트워크의 단점을 보완한 모델로서, Fig. 9 에 나타난 바와 같이

홉필드 네트워크와 라그랑지 멀티플라이어 방법, 확률적 노이즈 등 3 가지 요소로 구성된 하이브리드 모델이다.

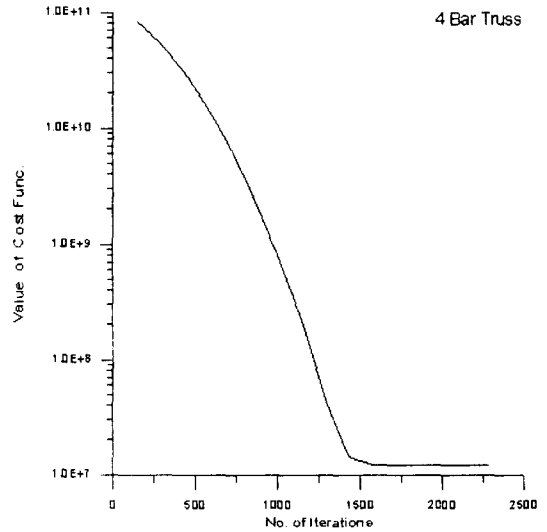


Fig. 8 Energy state of 4 bar truss

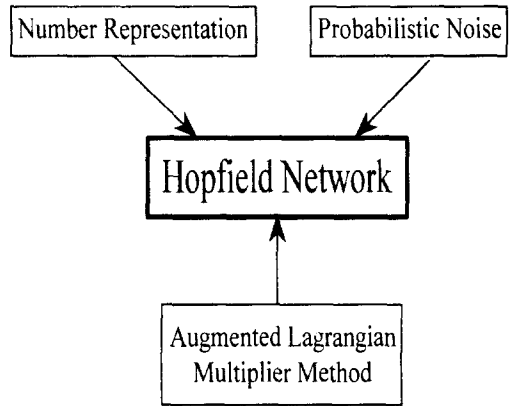


Fig. 9 Structure of neuro-optimizer

#### 3.1 Neuro-Optimizer 네트워크

전 절에서 살펴본 바와 같이 일반적인 홉필드 네트워크는 그대로 구조 최적화 문제에 적용하기 어려운 몇 가지 단점을 갖고 있기 때문에, 홉필드

모델을 다음과 같이 개선하였다.

1) 연속 모델

전 절에서 살펴본 홉필드 네트워크는 뉴런 상태로써 0, 1의 바이너리 값만을 취할 수 있었으나, 연속적 변수를 다루는 구조 최적화 문제에도 사용하도록 Sigmoid 함수를 전이함수로 택하였다. 연속 모델은 뉴런 입력  $U_i$ 를 (16)식과 같이 계산하며, 이에 따른 뉴런의 상태변화는 식(17)를 따른다.

$$U_i(t+1) = U_i(t) + \frac{dU_i}{dt} \quad (16)$$

$$V_i(t+1) = f(U_i(t+1)) \quad (17)$$

2) 뉴런의 동시적인 상태 변화

홉필드 네트워크는 네트워크의 상태 변화시 한 순간에 하나의 뉴런만이 상태를 바꾸도록 되어 있다. 이러한 비동시적인 상태 변화는 뉴런의 상태가 바뀔 때마다 항상 네트워크의 에너지가 감소하는 것을 보장하지만, 안정 상태로 수렴하는 속도가 느리게 하는 원인이 된다. Neuro-Optimizer 네트워크는 동시에 전체 뉴런의 상태를 변화시키기 때문에 수렴 속도의 증가를 가져온다. 동시적인 상태 변화로 인해 네트워크의 에너지가 증가하는 것을 허용하게 되지만, 확률적 노이즈와 더불어 전역적 최적해를 찾는 데 도움을 주는 역할도 한다.

3) 일반적인 비선형 최적화 문제

홉필드 네트워크는 에너지 함수가 뉴런 상태들의 2 차식으로 표현되기 때문에, 2 차 최적화 문제까지만 풀 수 있다. 2 차식만으로도 순회 외판원 문제와 같은 NP-Complete 문제를 해결할 수 있지만, 일반적인 비선형 최적화 문제에 적용하기에는 적합하지 않다.

따라서, 홉필드 네트워크의 에너지 함수를 변형시켜서 일반적인 비선형 문제(3차 이상의 비선형 문제)에 적용할 수 있도록 하였다. (18), (19)식에 나타난 바와 같이 뉴런의 입력  $U_i$ 를 (3) 식으로

부터 구하지 않고 최적화 문제의 목적함수로부터 직접 구한다.

$$\frac{dU_i}{dt} = -\frac{\partial L}{\partial V_i} \quad (18)$$

$$U_i(t+1) = U_i(t) + \frac{dU_i}{dt} \quad (19)$$

$$U_i(t+1) = U_i(t) - \frac{\partial L}{\partial V_i}$$

3.2 설계변수 표현

설계변수 표현은 라그랑지 멀티플라이어 방법과 홉필드 네트워크를 서로 연결시켜 주는 역할을 맡고 있다. 홉필드 네트워크의 뉴런 상태는 0, 1 사이의 값을 갖기 때문에 설계변수를 분산 표현법을 사용하여 뉴런 상태로 표현할 수 있다. 연속 모델은 설계변수 한 개를 뉴런 한 개로 표현할 수 있지만, 보통 하나의 설계변수를 여러 개의 뉴런으로 표현한다. 이는 여러 개의 뉴런을 사용하여 병렬 처리 효과를 거둘 수 있기 때문이다. (20)식은 설계 변수  $x_j$ 를  $N_j$  개의 뉴런을 사용하여 표현한 것이다.[6]

$$x_j = c + d \sum_{i=1}^{N_j} V_i \quad (20)$$

3.3 확률적 노이즈

홉필드 네트워크는 기본적으로 국부적 탐색 기법이기에 전역적 최적해를 찾기 위해서는 시뮬레이티드 어닐링과 같은 방법을 함께 사용해야 한다. 그러나, 홉필드 네트워크의 구조적 특성 때문에 시뮬레이티드 어닐링을 직접 이용하기가 힘들다. 뉴로-옵티마이저는 확률적 노이즈를 이용하여 시뮬레이티드 어닐링을 구현하고 있다. 홉필드 네트워크의 뉴런에 들어오는 입력값  $U_i$ 에 가상 온도에 비례하는 노이즈  $u_i$ 를 더해 주어, 결과적으로 출력값이 어느 정도 랜덤한 성질을 갖도록 만들어서, 목적 함수값이 증가하는 것을 허용하도록 하였다.

$$U_i' = U_i + u_i \quad (21)$$



이때 노이즈는 Zero-Mean 정규 분포로부터 랜덤하게 발생시켰고, 표준편차는 시간에 비례하도록 만들었다. 또한, 온도의 감소는 일반적인 시뮬레이티드 어닐링의 쿨링 스케줄을 따랐다.

$$\sigma_{it}^2 = \alpha T^2 \quad (22)$$

$$T(t+1) = \frac{T_{init}}{\log(10+t)} \quad (23)$$

### 3.4 최적화 문제로의 적용 결과

2 절의 홉필드 신경망과 같은 예제를 뉴로 옵티마이저를 사용하여 풀어 보았다. 모든 예에서 전역적 최적해를 구하였고, 이산변수를 가진 3 Bar Truss 문제는 스텝 함수를 전이함수로 하여 이산해를 구하였고, 다른 문제에서는 시그모이드 함수를 도입하여 연속 변수의 최적해를 구하였다. 표에서 보는 바와 같이 얻어진 최적해는 서로 같은 결과를 보여 주고 있음을 확인하였다.

Table 3 Comparison of optimum results

	Goldstein	3 Bar Truss	4 Bar Truss
Hopfield	3.000	3.0141	12104686
Neuro-Opt	3.000	3.0141	12101780

#### 1. 계산시간

홉필드 신경망에 비해서 뉴로옵티마이저는 뉴런의 갱신이 목적함수의 1 차 미분으로 이루어지므로 계산시간이 단축되었음을 알수 있었다.

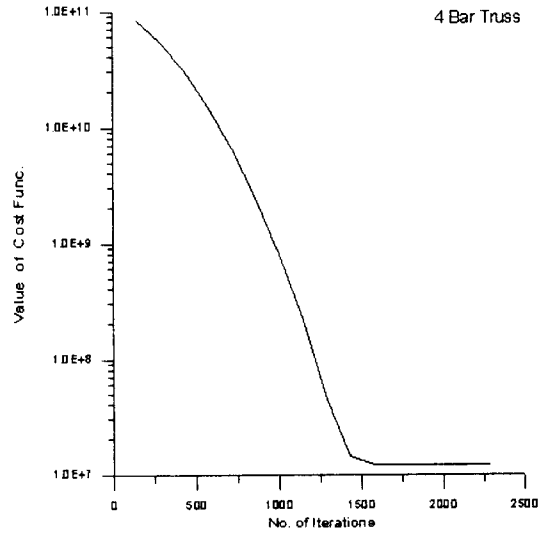
Table 4 Comparison of calculation time (sec)

	Goldstein	3 Bar Truss	4 Bar Truss
Hopfield	250	190	290
Neuro-Opt	7	5	15


#### 2. 전역해로의 수렴여부

앞의 예제에서 3-Bar Truss, 4-Bar Truss는 전역해를 찾았고, Goldstein-Price 함수는 초기점에 따라 국부해와 전역해를 구하였으나, 뉴로 옵

티마이저에서는 시뮬레이티드 어닐링에 의한 노이즈를 추가하여 항상 전역해를 구하였다.



(a) Hopfield Network



(b) Neuro-Optimizer

Fig. 10 Comparison of Energy State

Fig. 10 을 보면 홉필드 신경망은 기본적으로 국부적 최적해를 찾는 방법으로서 노이즈가 없으므로 단조 감소하는 경향을 보인 반면, Neuro-

Optimizer 는 확률적 노이즈를 첨가해서 많은 진동 후에 최적해에 수렴하여 전역적 최적해를 찾게 된다.

위의 비교로 볼 때 Neuro-Optimizer 는 선체 중앙단면 최적화 문제와 같이 설계변수가 많고 제한조건이 복잡하고 2 차 미분치를 구하기 어려운 문제를 해결하는데는 실용적인 측면에서 원래의 홉필드 신경망보다 훨씬 효율적이라 할 수 있다.

### 4. 뉴럴 네트워크에 의한 선체 중앙단면 설계

#### 4.1 선체 중앙단면 최적화

기존의 선체 중앙단면 최적화는 주로 Hooke and Jeeves 법에 의한 SUMT 방법을 적용해 왔으나, 본 연구에서는 인공신경망을 이용한 선체구조 최적화 방법을 개발하고 그 응용 가능성을 검토하고자 하였다.

특히 중앙단면의 최적화 시에 판 두께와 같은 설계변수가 갖는 이산적 변수의 특성과 보강재의 개수가 갖는 정수문제를 함께 고려하는 조합 최적화 문제를 효율적으로 다룰 수 있도록 뉴런의 상태를 binary 상태로 취급토록 하였으며, 최적시에 이산적 설계변수들의 특성이 중립축에서 멀리 떨어져 있는 부재 치수들의 증가를 어떻게 효율적으로 고려하는가를 살펴보았다.

#### 4.2 설계 문제의 정식화

대상 선박은 논문[8]에서 취급한 Tanker 의 중앙단면을 사용하였다. DNV rule 에 의한 부재의 최소치수와 중앙단면의 이차 단면계수 그리고 deck, bottom part 의 Plate buckling 을 제한 조건으로 하여 다음과 같이 정식화하였다.

$$Find : X_i \quad i = 1, 2, 3, \dots, 19$$

$$Such \ that : \text{Minimize } F(X) = A X$$

$$F : \text{midship area}$$

$$A : \text{geometric coefficient vector}$$

$$X : \text{design variable vector}$$

Subject to :

$$G_i = x_i - t_i \geq 0 \quad \text{Plate Thickness : } i = 1, \dots, 13$$

$$G_j = Z_{cal} - Z_{req} \geq 0$$

$$G_k = \sigma_k - \frac{\sigma_{cal}}{\eta} \geq 0 \quad \text{BucklingConstraint}$$

$$\text{where : } \text{outer, inner bottom : } \eta = 0.9$$

$$\text{deck : } \eta = 1.0$$

예제로 사용한 선체는 아래와 같은 형상(Fig. 11) 및, Basic Parameter 부재 치수를 가지는 Tanker Type 1 이다. X[1]-X[13]은 이산간격 0.5 mm 의 판두께 부재 치수이고, X[14]-X[19]는 보강재의 개수를 설계변수로 잡았다(Table 5, 6, 7).

Table 5 Basic parameter of ship (m)

Part	Value
Length	171.50
Breadth	32.20
Depth	18.60
Inner Bottom Breadth	25.16
Double Bottom Height	2.10
Hopper Tank Breadth	3.52
Hopper Tanker Height	4.60
Topside Tank Breadth	3.52
TopSide Tank Height	2.80
SideShell Breadth	2.00
Bilge Radius	1.70




Fig. 11 Midship section

Table 6 Stiffener specification (mm)

Spec	A	B	C	D	E
Web Depth	150	200	250	250	300
Web thickness	8	9	10	12	11
Flange Width	90	90	90	90	90
Flange thickness	13	14	15	16	16

Table 7 Design variable of midship section

X[1]	Bottom Plate	X[11]	Hopper Side Bulkhead Plate
X[2]	Inner Bottom Plate	X[12]	Deck Plate
X[3]	Center Girder Plate	X[13]	Deck Girder Plate
X[4]	Side Girder Plate	X[14]	Outer & Inner
X[5]	Biige Plate	X[15]	Deck
X[6]	SideShell Plate	X[16]	Side Shell
X[7]	Stringer 1 Plate	X[17]	Longi Bulkhead
X[8]	Stringer 2 Plate	X[18]	TopSide Bulkhead
X[9]	Side Bulkhead Plate	X[19]	Hopper Bulkhead
X[10]	TopSide Bulkhead Plate		

### 4.3 계산 결과 및 평가

Neuro-Optimizer 네트워크를 이용하여 최적화 과정을 수행한 계산 결과는 Table 8과 같다.

선급 Rule 에서 요구된 단면계수와 계산된 단면계수 값이 약 4% 정도로 근접해 있고 많은 설계변수가 제한조건 경계에 거의 닿아 있고 실적선과 비교할 때, 변수의 감소폭이 전체적으로 큰 편차가 없이 비슷한 경향을 보이는 것으로 보아 최적해를 구한 것을 알 수 있다.

X[10] 의 부재가 비교적 제한조건에 덜 근접해 있으나 한 단위를 내려서 즉 12 mm 값을 주면 X[10] 은 7% 정도로 제한조건에 더욱 근접해 가지만 Bucking 제한조건을 1% 정도 위반하게 되어서 해가 되지 못한다. 대부분의 부재의 값이 선급 규정에 의한 제한조건의 경계에 있는 것으로 보아 갑판 부재와 선저부재를 제외한 다른 부재 값을 선급규정에 의한 값으로 고정하고 단면계수를 만족하는 갑판 부재와 선저 부재를 최적화하는 기존의 방법이 어느 정도 타당하다고 생각된다.

실적선은 실제 건조 경험이 있는 배이므로 중량의 관점 외에 작업성, 공수, 건조기간 등이 같이 고려된 결과이므로 중앙단면 면적만으로 비교를 하기엔 다소 무리가 있지만 실적선과 유전자 알고

Table 8 Optimum results obtained by neuro optimizer and GA

	X[1]	X[2]	X[3]	X[4]	X[5]	X[6]	X[7]	X[8]	X[9]	X[10]	X[11]	X[12]	X[13]
Exist	14.5	13.5	13.5	11	14.5	13.5	11	11	11.5	14	10	14	13
GA	12	12	17	12	17	13	9.5	14	12	16.5	13.5	9.5	18
N.O.	12.5	11	12.5	10.5	13	13	10	9.5	11.5	12.5	12.5	10	9.5
$G_i$	0.033	0.040	0.027	0.005	0.009	0.009	0.056	0.006	0.029	0.107	0.005	0.046	0.006
	X[14]	X[15]	X[16]	X[17]	X[18]	X[19]		Zd	Zb	Zr		Area	
Exist	18E	13D	25B	22C	14C	3C	3E	7.0832	10.05	6.7331		1.610	
GA	19A	30A	24A	9C	9A	8B		7.2398	9.388	6.7331		1.445	
N.O.	20A	29a	23a	7C	10a	4B		6.990	9.048	6.7331		1.376	

리즘[8]의 값들과 비교를 할 때, 인공 신경망을 이용한 선체 중앙단면 최적화도 비교적 좋은 결과를 주는 것을 알 수 있다.

### 5. 결 론

네트워크의 상태 에너지가 감소하는 방향으로 수렴하는 홉필드 신경망의 특성을 최적화 문제에 적용해 보고 국부적 최적화 기법인 홉필드 신경망에 확률과정을 더하고 뉴런의 갱신 규칙을 개선하여 수렴 속도를 증가시키고 2 차 미계수를 사용하지 않는 Neuro-Optimizer로 선체 중앙단면 최적 설계를 수행하여 보았다.

선체 중앙단면의 부재치수와 보강재 개수를 이산변수로 하여서 신경망을 이용한 최적화의 장점의 하나인 이산변수 적용의 가능성을 확인할 수 있었고, 1 차 미계수만을 이용하여서도 비교적 좋은 최적해를 구할 수 있었다.

인공신경망을 이용한 최적화 기법은 전역적 최적화 기법으로서 이산변수를 다루기 용이하고 수렴 속도도 비교적 뛰어나, 새로운 최적화 기법으로서 가능성이 있음을 확인하였다.

### 후 기

이 논문은 1994년도 학술진흥재단의 자유공모과제의 연구비에 의해 연구되었으며, 차제에 관계자

여러분께 깊은 감사를 드립니다.

### 참 고 문 헌

- [1] Hopfield, J.J. and Tank, D.W., "Neural Computation of Decisions in Optimization Problems," *Biological Cybernetics*, Vol. 52, 1985
- [2] 나승수, 김외현, 엄형섭, 윤장호, "선체 구조설계 분야의 최적화 기술 적용현황 및 전망," *대한조선학회지*, 제31권 1호, 1994. 3.
- [3] Kishi, M. and Hidaka, Y., *Discrete Optimization Technique with Neural Network and its Application to Structural Design*, Mechanical System, 1989
- [4] Vanluchene, R.D. and Roufei, S., "Neural Networks in Structural Engineering," *Microcomputers in Civil Engineering*, Vol. 15, No. 3, 1990
- [5] Dhingra, A.K. and Rao, S.S., "A Neural Network based Approach to Mechanical Design Optimization," *Engineering Optimization*, Vol. 20, 1992
- [6] Kishi, M., "Neuro-Optimizer," *PRADS'92*, Newcastle upon Tyne, England, 1992
- [7] Yang, J.B. and Sen, P., "An artificial Neural Network Approach for Nonlinear Optimization with Discrete Design Variables," *IFIP-TC7 Conf.*, France, July 1993.
- [8] 양영순, 김기화, 유원선, "유전적 알고리즘에 의한 선체구조물의 이산적 최적 설계," *대한조선학회 논문집*, 제31권 4호, 1994. 11.