

와렌 트러스 설계에의 신경망 적용에 관한 연구

A Study on Adaptation of Neural Network to Warren Truss Design

신동철¹⁾

이승창²⁾

조영상³⁾

Shin, Dong Cheol Lee, Seung Chang Cho, Young Sang

요약: 구조 설계를 위해 초기 부재를 가정할 때나 건축 실무에서 개산 견적을 계산할 때 기술자의 직관이나 비슷한 조건의 기존 설계 평균값을 사용하고 있으나 설계 조건은 모두 다르기 때문에 큰 오차가 발생할 수밖에 없다. 이러한 문제점을 해결하기 위해서 확률론적인 절차가 내재되어 있어 불확실성을 다룰 수 있는 인공 신경 회로망의 이용하여 와렌 트러스를 설계하므로써 적용성을 평가하였다. 제안된 신경망 설계변수값과 구조설계 단계에 따라 다양한 와렌 트러스를 설계하여 MIDAS 프로그램 설계결과의 10% 오차 이내로 근사 설계를 하므로써 모델의 타당성을 검증하였다. 제안된 모델은 약간의 오차를 포함하지만 적은 시간과 노력으로 신뢰할 수 있는 설계 결과를 얻을 수 있으며, 부재 테이블을 사용하는 비선형 관계의 구조설계에도 적용 가능한 특성을 가지고 있다.

ABSTRACT : Most engineers tend to rely on their intuition or existing data in formulating structural design or preliminary estimate of various conditions. Because of these variations, the artificial neural network is used as an alternative design model of the warren truss since it can handle uncertainty through the probability method. This research validated the approximate structural design model of the warren truss, with its proper parameter values of the neural network and design process falling within 10 percent torrence of the different designs that resulted between this model and the MIDAS program. The suggested model for the process was adapted for the truss design using the member section table, while time saving and efficiency are based on the allowed range of torrence.

핵심 용어 : 인공 신경 회로망, 근사 구조 설계, 와렌 트러스

KEYWORDS : artificial neural network, approximate structural design, warren truss

1. 서 론

최근 공학적인 문제를 이해하고 해결한다는 것에서 가장 중요한 일 중의 하나는 어떠한 상황에도 적용 가능하다는 보편성과 새로운 조건에도 적용 가능하다는 적용성을 갖추고 있는 공학적인 모델(이승창 등, 1997)을 개발하는 것이다.

구조 설계를 위한 구조 해석에서 초기 부재를 가정할 때나 건축 실무에서 개산 견적을 계산할 때 기술자의 직관이나 기존의 구조물과 비슷한 조건의 구조설계 평균값을 사용하고 있으나 설계 조건은 모두 다르기 때문에 큰 오차가 발생할 수밖에 없는 일이다.

이러한 문제점을 해결하기 위해서는 약간의 오차를 포함하지만 적은 시간과 노력으로 신뢰할 수 있는 설계 결과를 얻을

수 있는 설계 모델이 요구된다. 이런 점에서 확률론적인 절차가 내재되어 있어 불확실성을 다룰 수 있고, 대량의 복잡한 비선형적인 관계도 단순화의 과정 없이 연관 관계를 자기 조직화할 수 있는 인간의 뇌와 가장 유사한 병렬 연산 모델인 인공 신경 회로망(artificial neural network)의 적용은 매우 효율적이다.

따라서 본 연구에서는 인공 신경 회로망을 이용해 와렌 트러스를 설계하므로써 적용성을 평가하였다. 제안된 신경망 설계변수와 구조설계 단계에 따라 다양한 와렌 트러스를 설계한 결과는 10% 오차 이내로 근사 설계로써 모델의 타당성을 검증하였다.

1) 경원전문대학 부교수, 현양대 박사수료
(Tel:031-750-8635, Fax:031-750-8639, E-mail:sdc@kwc.ac.kr)
2) 현대산업개발 기술연구소 과장, 공학박사(sclee88@unitel.co.kr)
3) 현양대 조교수, 공학박사(ycho@hanyang.ac.kr)

본 논문에 대한 토의를 2004년 2월 28일까지 학회로 보내주시면 토의 회답을 게재하겠습니다.

2. 신경망 이론

신경망 모델 연구의 대상인 신경망 설계변수를 중심으로 사용된 알고리즘을 고찰하면 다음과 같다.

실험 구조설계를 위해 사용한 신경망 알고리즘은 다변수 비선형 문제에 가장 적합한 대표적인 신경망인 오류 역전파 학습 알고리즘(error back-propagation training algorithm) (Freeman 등, 1992; Veelenturf, 1995)으로 그림 1과 같이 다층 퍼셉트론(multi-layered perceptron)의 구조를 갖고 있다.

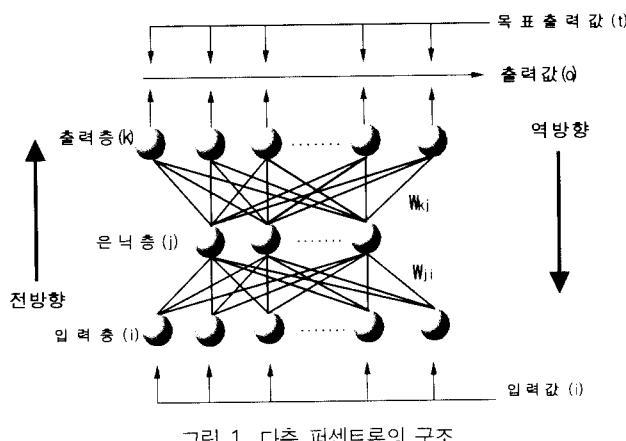


그림 1. 다층 퍼셉트론의 구조

학습(training) 단계에서는 기대값과 출력값의 차이를 줄이는 방향으로 연결 강도를 조정하는 반복 계산과정을 통해 최적의 연결 강도를 구한 후 회상(recall) 단계에서는 입력만 주어지면 반복 계산 없이 연결 강도와의 계산에 의해 적절한 출력이 즉시 계산된다. 여기서 학습 단계의 1회의 계산과정은 전방향 진행과 역방향 진행을 수행한다.

2.1 전방향 진행

입력층에 하나의 입력 패턴이 주어지면, 은닉층에 있는 뉴런으로 들어가는 입력은 j 층과 i 층을 연결하는 연결 강도 W_{ji} 와 i 층에서 나오는 출력 O_i 의 곱의 합으로 식 (1)과 같이 계산된다. net_j 는 활성화 함수 f_j 로 입력된 후 식 (2)와 같이 계산되어 j 층 뉴런의 출력 O_j 가 된다.

$$\text{net}_j = \sum_i W_{ji} O_i \quad (1)$$

$$O_j = f_j(\text{net}_j) \quad \left(\because O_j = \frac{1}{1 + e^{-(\text{net}_j + T_j)}} \right) \quad (2)$$

여기서, T_j : j 층 뉴런들의 임계값

O_j 는 다시 식 (3)과 같이 출력층으로 입력되고, 활성화 함수 f_k 에 의해 식 (4)와 같이 계산되어 k 층 뉴런의 출력 O_k 가 된다.

$$\text{net}_k = \sum_j W_{kj} O_j \quad (3)$$

$$O_k = f_k(\text{net}_k) \quad (4)$$

일반적으로 출력값 O_k 는 기대값 d_k 와 일치하지 않으므로 하나의 패턴에 대한 패턴 오차(pattern error) E_p 를 식 (5)와 같이 정의하며 전체 패턴에 대한 오차의 합 E_t 는 E_p 를 모두 합하여 식 (6)과 같이 구한다.

$$E_p = \frac{1}{2} \sum_k (d_{pk} - O_{pk})^2 \quad (5)$$

$$E_t = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (d_{pk} - O_{pk})^2 \quad (6)$$

2.2 역방향 진행

역방향 진행은 최종 출력층에서 계산된 패턴 오차를 역방향으로 입력층까지 전파하여 연결 강도를 수정함으로써 오차를 최소화하는 과정을 의미한다. 출력층에서의 연결 강도의 미소 변화량은 식 (7)로 정의된다.

$$\begin{aligned} \Delta W_{ki} &= -\eta \frac{\partial E_p}{\partial W_{ki}} = -\eta \frac{\partial E_p}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial W_{ki}} \\ &= \eta (d_{pk} - O_{pk}) f'_k(\text{net}_k) O_i \\ &= \eta \delta_k O_i \end{aligned} \quad (7)$$

여기서, η : 학습 상수(learning constant)

$$\delta_k = -\frac{\partial E_p}{\partial \text{net}_k} \quad (8)$$

은닉층 연결 강도의 미소 변화량도 식 (7)과 같은 과정으로 전개하며 그 결과는 식 (9)와 같이 구해진다.

$$\begin{aligned} \Delta W_{ji} &= -\eta \frac{\partial E_p}{\partial W_{ji}} = -\eta \frac{\partial E_p}{\partial O_i} \frac{\partial O_i}{\partial \text{net}_j} \frac{\partial \text{net}_j}{\partial W_{ji}} \\ &= \eta f'_i \text{net}_j O_i \sum_k \delta_k W_{ki} \\ &= \eta \delta_i O_i \end{aligned} \quad (9)$$

$$\text{여기서, } \delta_i = -\frac{\partial E_p}{\partial \text{net}_j} \quad (10)$$

결국, 학습 과정에서 필요한 연결 강도의 변화량은 식 (11)과 식 (12)로 계산되며, 위와 같은 학습 과정은 반복적

으로 이루어진다.

$$W_{kj} = W_{kj} + \eta(\delta_k O_j) \quad (11)$$

$$W_{ji} = W_{ji} + \eta(\delta_j O_i) \quad (12)$$

마지막으로 연결 강도의 변화량에 수렴속도를 증가하기 위해서 전항의 변화량을 고려하는 모멘텀 항(momentum term) α 를 추가하면 식 (13)과 식 (14)가 되며 (n+1) 단계에서 출력 층과 은닉층의 최종적인 연결 강도의 수정량이 된다.

$$\Delta W_{kj(n+1)} = \eta(\delta_k O_j) + \alpha \Delta W_{kj(n)} \quad (13)$$

$$\Delta W_{ji(n+1)} = \eta(\delta_j O_i) + \alpha \Delta W_{ji(n)} \quad (14)$$

이러한 과정이 반복되면서 학습이 진행되며, 정해진 반복 횟수에 도달하거나 오차가 정해진 범위인 최대 에러 E_{max} 이내로 줄어들면 학습이 완료된다.

3. 와렌 트러스 설계를 위한 신경망 모델

신경망 학습단계에서 반복 계산 횟수를 줄이면서 정확도를 향상시키기 위한 신경망의 설계변수 즉, 식 (1)~(14)에서 사용된 상수변수를 결정하는 것은 문제 유형에 따라 다르며, 이 장에서는 신경망을 이용하여 와렌 트러스 부재를 설계하기 위한 적절한 신경망 설계변수를 결정한다.

3.1 신경망 학습을 위한 패턴 데이터 축적

먼저 신경망 학습의 패턴 데이터로 사용될 데이터를 확보하기 위한 대상 구조물로 그림 2와 같은 와렌 트러스 보를 대상으로 하였다.

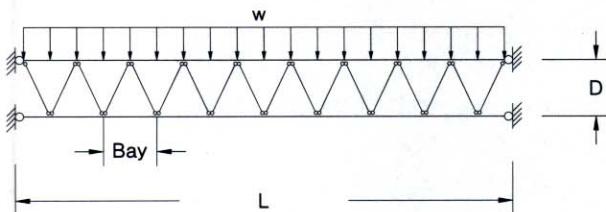


그림 2. 와렌 트러스 보의 구조 모델

구조설계의 조건은 표 1과 같으며, 학습패턴을 축적하기 위해서 보의 길이 L, 보의 춤 D와 등분포하중 w를 설계 범위 내에서 변경하면서 여러 경우의 구조설계를 수행하였다.

구조설계에 사용된 부재는 표 2와 같으며 SPS41 재질의

원형 강관으로 단면적이 비슷한 인접 강관 간에는 평균 2.49 cm²의 단면적 차이를 갖고 있다.

구조해석 및 부재설계 프로그램으로는 MIDAS((주)포스마 이다스, 2002)을 사용하였으며, 부재설계는 KS 강구조 설계 규준(1983년)을 적용하였다. 자중은 부재의 변경을 고려하였으며, 최적의 부재단면을 찾기 위해 7번 정도의 부재단면 변경과 재설계의 반복계산을 수행하였다.

표 1. 구조 설계의 조건

항 목	설계 범위	비 고
Bay	2m	
부재 단면 그룹		3개 그룹(상현재, 하현재, 사재) 원형 강관 테이블을 사용함
보 길이 (L)	12~24m	
보 춤/보 길이 (D/L)	0.05~0.25	
등분포 하중 (w)	1.2~2.4 t/m	자중도 고려함

표 2. 와렌트러스 보 설계에 사용된 원형 강관 테이블

순번	부재명	단면적 (cm ²)	전항과 면적차 (cm ²)
1	P60.5*3.2	5.76	
2	P76.3*2.8	6.18	0.42
3	P76.3*3.2	7.02	0.84
:	:	:	:
17	P318.5*8	78.04	8.91
18	P355.6*8	87.36	9.32
38	P355.6*9	98.00	10.64
평균			2.49

그림 3은 설계기준에 의한 최종 선택 부재의 조합응력을 검토한 MIDAS 설계 결과 예이며 최종 선택된 부재의 조합응력은 부재그룹 중 최대 부재력을 기준해서 0.75~0.95정도의 범위에서 설계가 이루어졌다. 다른 여러 경우의 부재설계 결과는 표 3~4와 그림 12~14에 나타나있다.

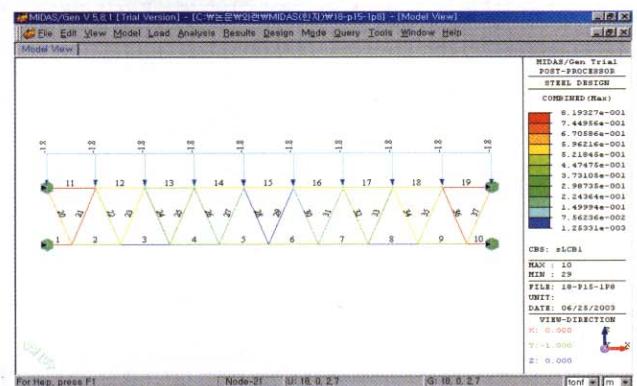


그림 3. MIDAS의 부재설계 K.S기준 검토 예

(L=18, D/L=0.15, w=1.8t/m)

3.2 신경망의 설계변수 선정

3.2.1 학습 패턴의 선정

학습 패턴을 선정하는 방법으로 그림 4와 같이 Rogers (Rogers, 1994)가 적용한 Hypercube 방법, Linear 방법과 비교 목적으로 Hexahedron-I, II, III, IV의 총 6가지 방법을 적용하였다. 그림에 나타나는 한 점은 설계 변수의 한 세트를 나타내고, 각 점에 대한 학습 패턴을 획득하기 위하여 설계가 수행되어져야 한다. 설계 공간의 좌측 하단의 전방향 코너는 모든 설계 변수의 하한값 경계를 나타내고, 우측 상단의 후방향 코너는 상한값 경계를 나타낸다.

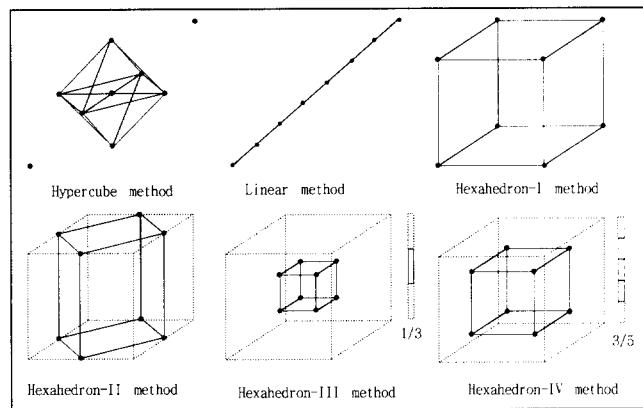


그림 4. 학습 패턴의 선정 방법

Hypercube 방법은 면의 중앙점($2 \times 3 = 6$ 개)과 설계공간의 중앙점(1개)의 총 7개의 학습 패턴으로 Cube-7을 생성하였으며, 같은 방법으로 각 코너, 각 면의 중앙점, 설계 공간의 중앙점을 선정하는 갯수에 따라 Cube-8, Cube-9, Cube-15를 생성하였다. Linear 방법은 각 설계 변수의 하한값에서 시작하여 상한값에 도달할 때까지 총 7개의 학습 패턴으로 Lin을 생성하였고, Hexahedron 방법은 설계 변수의 하한과 상한값 내에서 6면체의 크기에 따라 각 8개의 학습 패턴으로 Hex-I, II, III, IV를 생성하였다.

신경망 구조의 다른 변수는 다음과 같이 동일하게 가정하여 각 패턴에 대하여 학습하였다. [온도층 뉴런의 수=4, 온도층의 수=1, 초기 연결강도값=일정한 값, 최대 에러=0.01, 활성함수=1.0, 학습 상수=0.5, 모멘텀 항=0.5]

학습 패턴의 실제 데이터 값은 신경망 학습을 위해서 0~1의 사이의 값으로 스케일링(scaling)하며, 학습 후 회상한 값은 디스케일링(descaling)하였다.

학습이 완료된 후에는 학습 에러를 관정할 목적으로 6종류의 학습에 사용된 총 39개의 패턴에 대해서 테스트를 실시하였으며, 학습에 사용된 학습패턴과 나머지 패턴을 테스트 패

턴으로 구성하여 회상하였다. 표 3과 표 4는 Cube-9에 대한 회상 에리를 예로 보여주고 있다.

표 3. Cube-9에 대한 학습 패턴의 회상 에리

패턴 번호	L (m)	D/L	w (t/m)	사재 단면적(cm ²)		에리 (%)
				MIDAS	신경망	
Cube	1	18	0.15	1.2	12.52	11.99
	2	18	0.15	1.8	15.40	15.72
	3	18	0.15	2.4	22.72	22.82
	4	18	0.05	1.8	19.12	18.82
	5	18	0.25	1.8	22.72	22.77
	6	12	0.15	1.8	9.89	8.70
	7	24	0.15	1.8	22.72	23.11
	8	24	0.25	2.4	39.64	38.28
	9	12	0.05	1.2	9.89	10.93
평균						4.02

표 4. Cube-9에 대한 테스트 패턴의 회상 에리

패턴 번호	L (m)	D/L	w (t/m)	사재 단면적(cm ²)		에리 (%)
				MIDAS	신경망	
Cube	10	24	0.05	1.2	15.40	17.35
	11	24	0.25	1.2	25.16	22.45
	12	12	0.25	1.2	9.89	7.85
	13	12	0.05	2.4	22.72	18.57
	14	24	0.05	2.4	34.79	23.23
	15	12	0.25	2.4	15.40	27.08
	⋮	⋮	⋮	⋮	⋮	⋮
	1	14	0.08	1.4	10.69	12.72
	2	22	0.08	1.4	17.07	18.57
Hex-IV	3	22	0.22	1.4	22.72	16.63
	4	14	0.22	1.4	15.40	9.19
	5	14	0.08	2.2	15.40	17.98
	6	22	0.08	2.2	25.16	20.41
	7	22	0.22	2.2	26.32	33.97
	8	14	0.22	2.2	15.40	12.60
평균						27.04

모든 학습방법들에 대한 적용 결과는 표 5와 같다. 기존의 학습방법의 평가에서 학습에 사용된 학습패턴에 대해서는 2.70~6.23%의 에러로 아주 좋은 결과를 보이고 있으나, 테스트 패턴에 대해서는 21.08~37.14%, 심지어 Linear방법은 64.58%까지 에러를 보이고 있어 학습방법으로 채택하는데 문제가 있었다.

이와 같이 신경망에 의한 설계 오차가 큰 것은 설계 규준의 폭 두께비 제한, 이산화 부재 단면 테이블을 사용 등의 불연속성뿐 아니라 구조물 형상의 기하학적인 원인으로 형상 변화가 커서 기대값이 매우 불규칙하므로 학습 패턴에서 멀리 떨어진 테스트 패턴에 대해서는 예측이 부정확하기 때문인 것으로 생각된다.

표 5. 학습 패턴에 따른 회상에러

방법	패턴 구분	패턴 수	반복회수	에러(%)
Cube-7	학습	7	13,507	2.75
	테스트	32		23.07
Cube-8	학습	8	43,008	3.86
	테스트	31		28.67
Cube-9	학습	9	145,080	4.02
	테스트	30		27.04
Cube-15	학습	15	137,483	4.75
	테스트	24		21.08
Lin-7	학습	7	592,028	6.23
	테스트	32		64.58
Hex-1	학습	8	98,408	4.55
	테스트	31		23.85
Hex-2	학습	8	95,566	3.83
	테스트	31		27.29
Hex-3	학습	8	357,041	3.95
	테스트	31		37.14
Hex-4	학습	8	88,906	2.70
	테스트	31		25.94
평균	학습	9		4.07
	테스트	30		30.96
혼합 방법	학습	39	667,043	6.83
	테스트	63		8.96

이러한 문제점을 해결하기 위해서 본 연구에서는 Hypercube방법과 Hexahedron방법을 합한 혼합 방법으로 39개 패턴을 학습패턴으로 사용한 Com-39를 제안하여 평가하였다.

회상결과 혼합방법은 6~8% 정도의 에러로 본 연구의 목표로 하는 근사 해석설계 수준인 10% 에러 이내의 좋은 결과를 얻어 학습방법으로 선정하였다.

3.2.2 은닉층의 수 및 은닉층의 뉴런수

다층 피드포워드 네트워크(multilayer feedforward networks)를 사용하는 경우, 실제적인 문제를 푸는데 있어서 은닉층의 크기인 뉴런 수를 어느 정도 고려할 것인가는 매우 중요한 고려 사항 중 하나이나 그 수를 정확히 판단할 결론적인 방법은 없다. 따라서 본 연구에서는 현재까지 제시된 방법과 시뮬레이션 중 관찰된 새로운 방법을 적용하여 결과를 비교하고자 한다.

와렌 트러스 문제에서 은닉층의 수를 조절하면서 시뮬레이션 한 결과는 그림 5 및 그림 6과 같다.

은닉층 뉴런의 수가 1개와 60개 이상에서는 학습에 실패한 것을 고려하면 2~10개의 은닉층 뉴런 수를 가진 경우가 안정적이라고 볼 수 있고 근사화 정도에는 영향이 적은 것으로 나타났다.

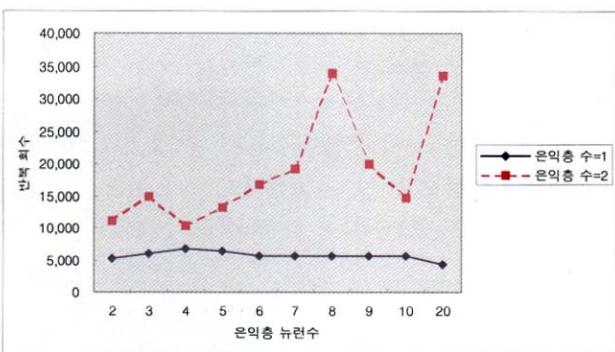
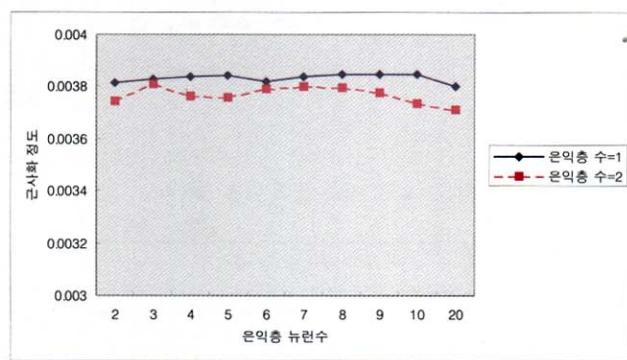


그림 5. 은닉층 수 및 은닉층 뉴런수에 따른 반복회수



따라서 Mirchandini(Zurada, 1992)의 가정(4개 이상 또는 4개 내외), Berke(Berke 등, 1991)의 가정(2~4개), Rogers의 가정(4개)은 시뮬레이션 결과와 잘 일치하였으나, Carpenter (Carpenter 등, 1992)의 가정(1개)은 부적절함을 알 수 있다. 그러므로 본 연구에서는 Berke와 Rogers의 가정인 입력과 출력층 뉴런 수의 합을 은닉층 뉴런 수의 최소값으로 한다.

은닉층을 2개로 확장하여 시뮬레이션을 한 결과는 1개의 은닉층에 동일한 은닉층 뉴런 수를 가진 신경망 보다 학습 속도나 근사화 정도가 매우 불리하였으며, 이는 본 문제가 단순한 연속함수 형태의 문제이기 때문으로 생각된다.

따라서 본 모델에서는 은닉층의 수를 1개로 선정한다.

3.2.3 초기 연결 강도 값

신경망의 연결 강도값은 작은 랜덤 수로 초기화되어야 한다. 동일한 초기 연결 강도값을 갖는다면 학습을 보장할 수 없으며, 선택된 연결 강도값에 따라 학습에 걸리는 반복회수가 달라지고 수렴하지 못하는 경우도 발생할 수 있다. (Carpenter 등, 1992)

0.1 미만의 랜덤 수로 학습한 결과는 그림 7 및 그림 8과 같으며, 반복회수가 최소 1,693번에서 76.5%가 증가된 최

대 2,989번까지 차이를 보였으나 모두 수렴하였으며, 본 연구에서 초기연결강도로 인해 수렴하지 않는 경우는 발생하지 않았다. 이것은 학습패턴이 단일 곡률의 연속함수 성격을 갖고 있기 때문이다. 근사화 정도에서도 수렴 목표치 이내로 학습이 잘 이루어진 것을 알 수 있었다.

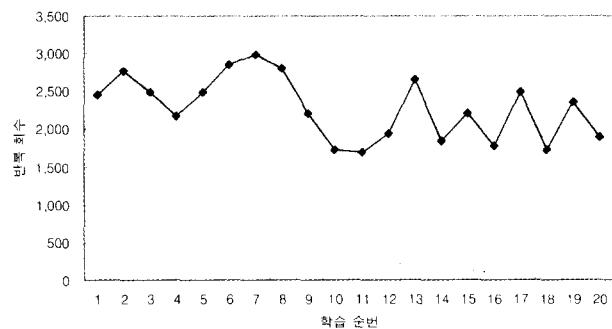


그림 7. 초기 연결강도에 따른 반복회수

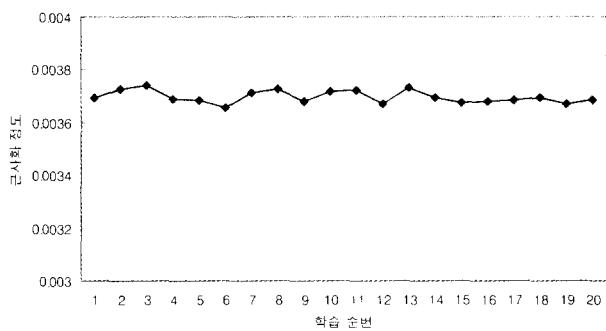


그림 8. 초기 연결강도에 따른 근사화정도

따라서 본 연구에서는 다른 신경망 설계변수의 반복회수나 근사화 정도의 비교를 위해서는 일정한 작은 수(0.1 미만)의 초기 연결강도를 사용하였고, 다른 경우에는 랜덤한 작은 수를 초기 연결 강도값으로 하였다.

3.2.4 학습 에러

학습 단계에서 연결 강도의 적응도를 측정할 목적으로 학습 패턴 수 P와 출력총 뉴런 수 K일 때의 최대 에러 Emax는 식 (15)와 같으며, 이 값과 비교를 통해서 학습 종료 시점을 판정한다. 이 시뮬레이션에서는 Emax=0.01로 하였으므로 식(16)으로 전개할 수 있다.

$$E_{\max} = \frac{1}{2} \sum_{p=1}^P \sum_{k=1}^K (d_{pk} - O_{pk})^2 = 0.01 \quad (15)$$

$$(d_{pk} - O_{pk}) = \sqrt{0.02/PK} \quad (16)$$

식 (16)에서, 학습 패턴 중 하나의 패턴($PK=1$)에서 일어날 수 있는 출력값과 기대값 사이의 최대 에러($d-O$)는 0.141이다. 따라서 학습 패턴의 기대값이 0.141보다 작을 경우에는 학습의 정확도를 보장할 수가 없으며, 일반적으로 큰 에러가 발생한다. 그러므로 최대 에러는 하나의 패턴에서 일어날 수 있는 출력값과 기대값 사이의 최대 에러($d-O$)보다 큰 값으로 스케일링 되도록 패턴 범위를 선정하여야 한다.

따라서 표 3에서 Cube-9에 대한 학습패턴에서 스케일링 된 기대값 중에 가장 최소값은 패턴 6의 0.249 ($=9.89/39.64$)이므로 적합한 최대 에러는 식(3)과 같이 표현할 수 있다.

$$\begin{aligned} E_{\max} &= \frac{1}{2} (\text{기대값 중 최소값})^2 \\ &= \frac{1}{2} (0.249)^2 = 0.031 \end{aligned} \quad (17)$$

본 연구에서는 출력값의 근사화 정도를 판정할 목적으로 테스트 패턴에 2차 에러를 도입하여 에러가 상대적으로 높은 것은 근사화 정도가 좋지 않고 상대적으로 낮은 것은 근사화 정도가 좋은 것으로 판정하였다. 이러한 기준으로 최대 에러를 0.6에서 0.01까지 변화시키며 시뮬레이션을 한 결과는 그림 9와 같다.

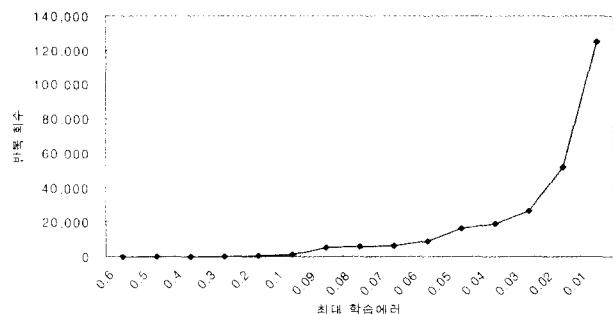


그림 9. 최대 에러에 따른 반복회수

또한, 최대 에러 0.01에서 반복회수 1.190번을 기점으로 급격히 증가하기 시작하여 최대 에러 0.01에서는 12만번 이상이 소요되었다. 근사화 정도는 최대 에러가 커짐에 따라 나빠지는 경향을 보였으며, 0.1까지는 급격히 근사화 정도가 좋아졌으나 그 이후로는 $7.17E-3 \sim 9.90E-5$ 의 범위로 근사화 정도는 약간 상승하였다.

그러므로 본 문제에서 가장 적절한 최대 에러는 0.1~0.01의 범위에서 결정되어야 함을 알 수 있었으며, 전술한 식 (17)에 의한 최대 에러값의 가정 0.031가 타당함을 알 수 있었다.

3.2.5 활성 함수

입력 벡터(X_i)와 연결 강도(W_i)의 스칼라 곱의 총합 ($net_i = \sum X_i W_i$)을 입력으로 받아 출력값으로 하는 활성함수 $f(net)$ 는 식 (18)과 같은 유니폴라 시그모이드(unipolar sigmoid) 함수를 사용하였으며, 신경망 학습의 속도는 활성 함수의 선택과 형상에 따라 많은 영향을 받는다.

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} \quad (18)$$

따라서 이 함수에서 중요한 인자인 경사도 계수(λ)의 변화에 따른 반복회수와 근사화 정도를 관찰하였으며 그 결과는 그림 9와 비슷하였다.

경사도 계수를 0.1에서 7까지 변경한 결과 경사도 계수 0.1~1.0까지는 6천~9천번 이내의 반복학습을 보였으나 경사도 계수 1.0 이상에서는 반복회수가 급격히 상승하였다. 물론 근사화 정도는 경사도 계수와 관계 없이 수렴 목표치인 이내로 근접해서 모두 정상적으로 학습이 이루어졌다.

따라서 와렌트러스 보 문제에서는 경사도 계수가 0.1~5.0에서 적은 반복 회수에 적절한 근사화를 얻을 수 있었다.

3.2.6 학습 상수

오류 역전파 학습 알고리즘의 효율성과 수렴성은 주로 학습 상수(η)에 의해 좌우되며, 일반적으로 최적값은 풀고자 하는 문제나 학습 형태에 따라 크게 다르다.

경사도 계수의 변화에 의한 학습 속도를 세어하기 위해서 경사도 계수는 1.0으로 하고 학습상수를 0.1에서 9.0까지 변화시킨 결과는 그림 10과 같다.

반복회수는 12,551에서 291번으로 크게 감소하는 반면, 근사화 정도는 학습상수 0.1~7.0까지는 수렴 목표값 0.004 이내의 0.0024~0.0039까지 안정적으로 학습을 완료했으나, 학습상수 8.0부터는 근사화 정도가 크게 증가하면서 원하는 근사화 목표값을 얻는데 실패하였다.

학습상수가 패턴오차에 대한 연결강도의 보정 크기를 결정하고 있음을 고려할 때 학습상수가 커지면서 반복회수가 크게 감소하는 것은 와렌 트러스 문제는 학습패턴의 연관관계가 곡선의 형태이지만 비교적 작은 곡률의 선형 형태 경향을 갖고 있기 때문인 것으로 판단된다.

그러나 학습상수가 어떤 한계를 넘는 큰 값을 연결강도의 보정값을 과대계산하기 되어 오차를 줄이지 못하고 발산하였다. 따라서 와렌 트러스 문제에서의 학습상수는 0.3~7.0이 적절하였다.

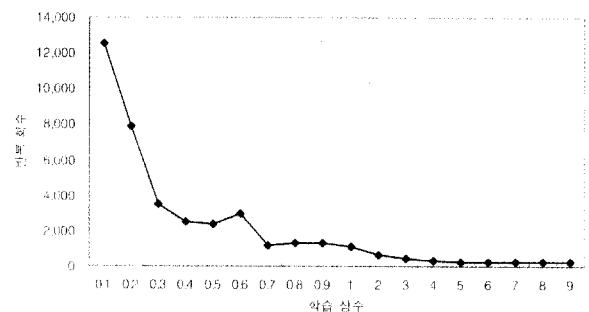


그림 10. 학습 상수의 변화에 따른 반복회수

3.2.7 모멘텀 항

반복계산에서 가장 최근의 연결 강도 변화량에 모멘텀 항(a)을 곱한 값을 현재의 연결 강도 값의 변화량에 첨가하여 수렴속도를 증가시키는 역할을 한다.

본 문제에 대해서는 0.0~20.0까지 변화시키며 시뮬레이션 결과 반복회수는 그림 10과 비슷하였다.

근사화 정도는 $a=0.1$ 에서 수렴 목표값 0.004 이내인 0.003967로부터 $a=20.0$ 에서 0.00232의 안정적인 수렴을 얻었으며, 반복회수도 $a=0.1$ 에서 33,213번의 많은 반복 계산을 수행했으나 $a=20.0$ 에서 360번의 반복 계산으로 수렴률이 모멘텀 항 증가에 비례하여 향상되었다. 그러나 $a=30$ 부터는 발산하여 수렴하지 못하는 결과를 얻었고 이런 결과는 앞의 학습상수에서와 마찬가지로 어떤 임계값 이상의 큰 모멘텀 항 값은 이전 연결강도 변화량의 과대 반영으로 인한 발산인 것으로 판단된다.

따라서 본 연구에서는 반복회수는 많을지 모르나 반복회수와 근사화 정도에서 안정적인 경향을 보이고 있는 구간인 $a=0.2 \sim 1.0$ 을 사용하는 것이 바람직하다고 판단된다.

3.3 신경망을 이용한 와렌 트러스의 설계 단계

전술한 시뮬레이션 결과를 바탕으로 신경망을 이용한 와렌 트러스 설계 단계를 설명하면 다음과 같다.

3.3.1 학습 패턴의 선정

와렌트러스 보와 같이 사용 단면의 간격이 크고, 기하학적인 구조형상에 의한 급격한 변화 등이 있는 불연속 조건이 많은 구조물인 경우에는 Hypercube와 Hexahedron 방법을 합한 혼합방법을 사용한다. 즉 학습패턴의 개수는 Hypercube에서 $(2n+2n+1)$ 개와 Hexahedron-II, III, IV에서 $(2n \times 3)$ 개를 더한 개수 이상의 학습 패턴으로 사용한다.

3.3.2 학습 패턴의 기대값 생성

선정된 학습 패턴에 해당되는 변수값으로 구조설계를 수행 하던지 기존의 설계 사례를 수집하여 기대값을 결정한다.

3.3.3 은닉층 뉴런 수

은닉층의 수는 1로, 은닉층 뉴런수는 입력과 출력층 뉴런 수의 합을 최소값으로 초기 가정한다.

3.3.4 최대 허용 에러

스케일링한 기대값 중 최소값으로부터 다음과 같은 산정식으로 최대 허용 에러를 선정한다. 단, 학습패턴 간의 연계성이 떨어지는 경우에는 학습패턴의 수가 증가함에 따라 최대 허용 에러 값을 증가해야 수렴이 가능하다.

$$E_{\max} < \frac{1}{2} (\text{기대값 중 최소값})^2$$

3.3.5 활성 함수(λ), 학습 상수(η), 모멘텀 항(a)

학습의 반복회수는 활성함수의 경사도 계수(λ), 학습 상수(η), 모멘텀 항(a)에 좌우된다. 본 모델에서는 일반적인 문제에 적용 가능하도록 $\lambda=1.0$, $\eta=0.5$, $a=0.5$ 로 한다.

3.3.6 학습 수행

단계 1~5로 결정된 신경망 구조로 학습이 되지 않고 발산한다면, 은닉층 뉴런 수, 학습 상수(η), 활성 함수(λ), 은닉층 수의 순서로 변수 값을 변화시킨다.

3.3.7 테스트

학습된 신경망을 테스트 패턴으로 테스트한다.

4. 와렌 트러스 설계 예

신경망을 이용하여 와렌 트러스를 설계할 수 있음을 검증하기 위하여 모델 개발 단계에서 사용한 그림 1의 와렌 트러스 보에 대하여 트러스 부재를 설계하였다.

3.3절의 설계 단계에 따라 총 39개의 학습 패턴(Cube-39)으로 그림 14와 같이 입력층 뉴런 수는 3개, 출력층 뉴런 수는 1개, 은익층 뉴런수는 4개로 신경망 모델을 생성하였다.

최대 허용 에러는 0.017로 하였으며 학습에는 255만번의 반복 계산이 필요했다.

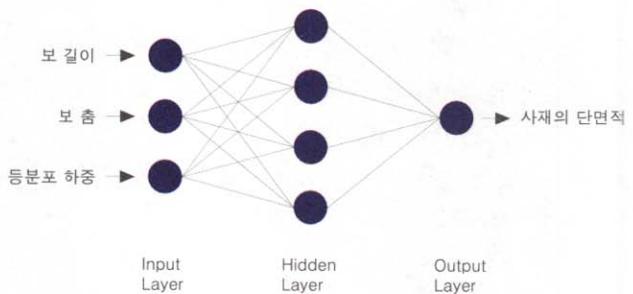


그림 11. 와렌트러스 보의 사재 설계 신경망 모델

학습 후 MIDAS의 부재설계 결과와 비교하기 위하여 학습되지 않았던 총 63개의 설계 조건에 대해 부재설계를 한 결과가 그림 12~14와 같다. 설계 조건은 보의 길이는 중간(18m)이고 등분포 하중도 중간(1.8t/m)인 경우, 보의 길이는 짧고(14m) 등분포 하중은 큰(2.4t/m) 경우 그리고 보의 길이는 길고(22m) 등분포 하중은 작은(1.4t/m) 경우에 대해서 각각 21개의 보 춤을 변경한 설계조건이다.

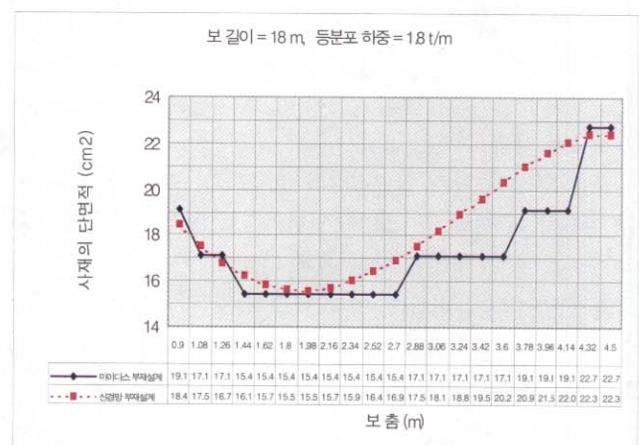


그림 12. 보 길이 18m, 하중 1.8t/m인 경우의 사재 설계

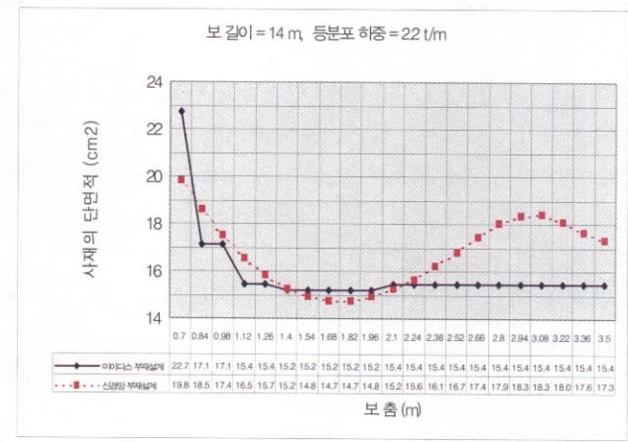


그림 13. 보 길이 14m, 하중 2.2t/m인 경우의 사재 설계

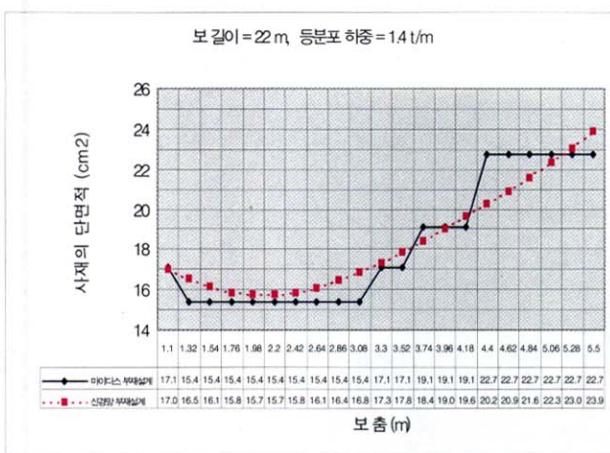


그림 14. 보 길이 22m, 하중 1.4t/m인 경우의 사재 설계

설계 결과를 보면 외부 등분포 하중과 자중의 상대적인 영향도에 따라 보 춤에 따른 사재 단면적의 변화가 다르게 나타나고 있다.

또한, 실선의 MIDAS 설계 결과는 이산화 부재 단면 테이블을 사용하기 때문에 보 춤의 변화에 따라 계단 형태로 나타났으며, 점선의 신경망 근사 설계 결과는 MIDAS 설계의 경향을 충분히 반영하는 스플라인 곡선 형태로 예측하고 있다.

표 6은 이상의 결과를 종합한 표이며, MIDAS에서 사용한 형강 테이블의 단면적 차이 2.49cm^2 (표 2 참조)는 최종 설계된 부재들의 평균 단면적 약 20cm^2 의 12.45%인 점과 그림 12~14의 설계조건이 학습패턴의 설계조건과 멀리 떨어져 있기 때문에 신경망을 이용한 근사 설계의 정확도가 낮을 수 있다는 점을 고려하면 근사 설계로는 좋은 결과로 평가된다.

표 6. 신경망에 의한 사재의 근사설계 결과

설계 조건	근사설계의 평균 오차	비 고
L=18m, w=1.8t/m	6.38 %	21개의 설계조건
L=14m, w=2.2t/m	8.24 %	"
L=22m, w=1.4t/m	4.27 %	"
평균	6.30 %	

5. 결 론

본 연구에서 제안된 신경망 설계변수와 설계 단계에 따라 신경망을 이용하여 다양한 와렌 트러스를 설계한 결과 10% 오차 이내의 구조설계가 가능한 하였으며 다음과 같은 결론을 얻을 수 있었다.

(1) 8가지 신경망 설계 변수 중 근사 설계의 정확도에 가

장 크게 영향을 주는 변수는 학습 패턴과 최대 에러의 선정으로 나타났다. 설계변수의 변화에 따른 설계결과가 불규칙한 구조물의 근사 설계 모델에서 학습 패턴은 Hypercube 방법과 Hexahedron 방법을 합한 혼합방법이 적합하다.

(2) 최대 에러의 초기 가정식을 제안하였다.

$$E_{\max} < \frac{1}{2} (\text{기대값 } \text{중 } \text{최소값})^2$$

(3) 학습의 수렴성은 은닉층 뉴런 수와 초기 연결 강도값에 따라 결정되며, 제안된 근사 해석 모델에서는 은닉층 뉴런 수를 입력과 출력층 뉴런 수의 합을 최소값으로 하는 초기 가정이 적합하다.

(4) 수렴성과 수렴 속도를 고려할 때 활성 함수(λ)는 0.1~5.0, 학습 상수(η)는 0.3~7.0, 모멘텀 항(a)은 0.2~1.0에서 결정하는 것이 적합하다.

참 고 문 헌

이승창, 박승권, 이병해, “신경망을 이용한 근사해석 모델의 원형 개발”, 한국전산구조공학회 논문집, 제10권 제2호, 1997. 6, pp. 273~281.

(주)포스마이다스, MIDAS/Gen User's Manual, 2002.

Berke, L. and Hajela, P., “Applications of neural nets in structural optimization,” NATO/AGARD Advanced Study Institute, Vol. 23(I-II), Germany, 1991, pp. 731~745.

Carpenter, W. C. and Barthelemy, J. F. M., “Comparison of polynomial approximations and artificial neural nets for response surfaces in engineering optimization,” 33rd SDM Conf., AIAA, 1992, pp. 2474~2482.

Freeman, J. A. and Skapura, D. M., Neural Networks : Algorithms, Applications, and Programming Techniques, Addison-Wesley Publishing Company, Inc., 1992.

Neural networks in structural analysis and design : an overview, P. Hajela and L. Berke, Computing systems in engineering Vol. 3, 1992.

Rogers, J. L., “Simulating Structural Analysis with Neural Network,” J. of Computing in Civil Engineering, ASCE, Vol. 8, No. 2, 1994, pp. 252~265.

Veelenturf, L. P. J., Analysis and Applications of Artificial Neural Networks, Prentice Hall International Ltd., 1995.

신동철 · 이승창 · 조영상

Zurada, J. M., Introduction to Artificial Neural Systems, Info Access Distribution Pte Ltd., 1992.

(접수일자 : 2003. 2. 7 / 심사일 2003. 2. 17 /
심사완료일 2003. 7. 15)