

# 신경망기법을 사용한 콘크리트의 배합요소 추정 Prediction on the Proportioning of Concrete Mixes Using Neural Network

김종인\*, 최영화\*\*, 김인수\*\*\*  
Jong-In Kim\*, Young-Wha Choi\*\*, In-Soo Kim\*\*\*

### <Abstract>

Concrete mix proportioning is a process of selecting the right combination of many materials such as cement, fine aggregates, coarse aggregates, water, and admixtures to make concrete satisfying for specification and cost. In determining proportioning of concrete mixes, code information, specification, and the experience of experts are needed. However, all factors regarding mix proportioning factor cannot be considered. Therefore, the final acceptance depends on concrete quality control test results. The proportioning of concrete mixes and the adjustments are somewhat complicated, time-consuming, and uncertain tasks. In this paper, as a tool to predict the factor of the proportioning of concrete mixes, an artificial neural network is used. To consider the varieties of material properties, the standard mixed table of two companies of ready mixed concrete are used. The results show that neural networks is successfully applied to the prediction of concrete mix proportioning factor.

**Key Words** : *mix proportioning factor, neural network, concrete quality control, standard mixed tables*

## 1. 서론

콘크리트는 복합재료로 구성되어 있으나 그  
은 간단한 물성시험만으로 알 수 있지만 배합  
설계<sup>1)</sup>는 요소들의 다양성으로 인해 정확성이나  
기준 값의 설정에 많은 어려움을 내포하고 있  
다. 또한 검정에 있어서도 표준압축강도의 설정

을 재령 28일 강도로 하고 있으므로 많은 시간  
이 필요하고, 배합설계를 실시하는 과정에서도  
각 재료의 특성에 따라 다양한 변수들이 작용  
하므로 콘크리트에서 배합설계를 정확히 계산  
한다는 것은 쉬운 일이 아니다.

콘크리트의 정확한 배합설계와 압축강도의  
평가는 실제 구조물의 해석, 설계, 품질관리 등

\* 정회원, 대구대학교 건설환경공학부 교수, 工博  
E-mail : Jikim@taegu.ac.kr  
\*\* 정회원, 대구대학교 건설환경공학부 교수, 工博  
E-mail : Ywchoi@taegu.ac.kr  
\*\*\* 정회원, 안동정보대학 겸임교수, 工博

\* prof., Dept. of Construction & Environmental Engineering,  
Taegu University  
\*\* prof., Dept. of Construction & Environmental Engineering,  
Taegu University  
\*\*\* Part-time Lecturer, Dept. of Civil Engineering, Andong  
Institute of Information Technology

에 일관성을 가져올 수 있는 가장 기본적인 자료로 사용되나, 지금까지는 이를 위한 시험방법이나 규정들이 대부분 다른 물성의 재료를 사용하더라도 보통콘크리트<sup>3)</sup>에 적용되는 방법을 그대로 사용하고 있어 실질적으로 콘크리트의 정확한 배합요소의 결정은 어려울 뿐만 아니라 실험자료도 매우 부족한 실정이다.

신경망은 컴퓨터공학이나 기계공학에 주로 사용되어 왔으나 건설분야에 적용한 예는 1990년대 이후에 비교적 활발히 진행되어 강우-유출과정에 대한 신경망 모형, 신경망을 이용한 해양파의 추정, 신경망을 이용한 구조물의 손상평가<sup>4)</sup> 등이 있으며 특히 콘크리트의 배합설계에 관해서는 콘크리트의 강도 특성을 추정할 수 있는 시스템 개발<sup>6)</sup>, 신경회로망을 이용한 고강도 콘크리트의 강도추정 및 신경회로망을 이용한 고성능 콘크리트의 배합설계 시스템을 개발<sup>7)</sup>하였다.

본 논문은 콘크리트의 배합요소 추정에 병렬처리 및 분산통제할 수 있는 신경망기법을 이용하여 컴퓨터에 의한 학습 및 시뮬레이션을 수행하였고 검증하고자 하는 자료들을 제외시켜 학습한 후 각각의 추정값을 예측하였다. 또한 그 값을 시방배합표와 비교·분석함으로써 콘크리트의 배합설계에서 신경망기법을 사용하여 배합요소를 추정하는데 그 신뢰성을 확인함은 물론 적합성을 입증하였다.

연구대상은 대량의 콘크리트를 제작하는 경북지방 레미콘회사 중에 A, B 두 회사에 대하여 적용하였으며 추정 배합요소로는 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량 등을 설정하여 추정하였다. 그리고 추정 배합요소의 검증에 사용된 규격으로는 설계기준강도 180~300 kgf/cm<sup>2</sup>, 목표슬럼프 값 8, 15cm를 각각 사용하였다.

## 2. 신경망을 적용한 학습 알고리즘

신경망에 대한 연구는 우수한 인간의 두뇌작용을 모방하기 위한 동기에서 발달한 것으로 컴퓨터를 통하여 패턴인식, 음성분석, 의사결정 등에서 간단한 인공지능 문제를 다루고자 하는

것이 신경망이다. 특히 신경망은 문자인식, 통신, 영상처리, 기계 및 로봇의 제어와 같은 과학기술의 여러분야와 최근 관심이 되고 있는 게놈프로젝트의 생명과학 분야에서도 지목을 받고 있다. 따라서 각 분야의 목적에 부합되는 여러 신경망 모델의 개발이 많은 연구자들에 의해 활발히 이루어지고 있다.

본 연구도 콘크리트의 배합설계에서 신경망기법을 사용하여 실험을 통하지 않고도 콘크리트의 보다 정확한 배합요소를 추정하고자 한다.

### 2.1 신경망

신경망(Artificial Neural Network)은 전술한 바와 같이 인간의 두뇌와 신경세포 모델에 대한 연구에서 시작된 것으로 신경 시스템에서 가장 기본적인 뉴우런(Neuron)이다. 인간의 두뇌는 신경세포인 10<sup>10</sup>개의 뉴우런과 이들 뉴우런들 간의 연결은 10<sup>14</sup>개에 이르는 것으로 통상의 컴퓨터에서는 메모리에 상당한다.

최초의 신경망 모델은 1943년 McCulloch-Pitts가 제안한 것으로 단순한 논리 구현과 헵의 시냅스(Hebbian Synapses)라고 알려진 연결강도 조절을 위한 생리학적 학습 규칙으로부터 시작되어 그 이론은 1957년 Rosenblatt에 의해 퍼셉트론(Perceptron)모델에서 최초로 소개되었다.<sup>11)</sup> 다층 퍼셉트론(Multi-layer Perceptron)은 입력층과 출력층 사이에 한 개 이상의 중간층인 은닉층이 존재하는 것으로 Fig. 1과 같은 계층 구조를 갖는다. 네트워크는 입력층, 은닉층, 출력층의 방향으로 연결되어 있으며 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향 네트워크(Feed Forward Network)이다. 또한 다층 퍼셉트론은 다입력/다출력의 사상관계를 표현할 수 있는 일종의 비선형 함수로 간주하고, 두 인접한 층의 뉴우런은 연결강도(Weight)로 표현되며 연결강도가 바뀌면 신경망의 입·출력관계가 바뀌게 된다. 이러한 연결강도를 주어진 학습 패턴으로 학습시키는 일련의 과정을 학습(Learning)이라 하고, 본 논문에서는 일반적으로 많이 사용하는 역전파(Back propagation)학습 알고리즘을 사용하였다.

따라서 콘크리트의 배합설계시 실험을 통하지

않고도 각각의 배합요소를 정확하게 추정하는 신경망기법의 기본 개념은 기존의 콘크리트 시방배합표를 입력층으로 제시되었을 때 학습을 통하여 배합요소를 추정하도록 하는 것이다.




Fig. 1 다층 퍼셉트론의 구조

### 2.2 역전파 학습 알고리즘

역전파 학습 알고리즘은 Fig. 1에서 보는 바와 같이 입력층의 각 유니트에 입력 패턴을 주면 이 신호를 각 유니트에서 변환되어 중간층으로 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값을 목표 출력값과 비교하여 차이를 줄여 나가는 방향으로 연결강도를 조절하고, 상위층은 역전파하여 하위층에서 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 역전파 학습 훈련은 반복 과정으로 수행되고, 각 반복 사이클(Cycle)은 에포크(Epoch)로 일컬어지는데 다음과 같은 단계별 학습훈련에 따라 진행된다.

단계 1 : 가중치( $W_{kj}$ ,  $W_{ji}$ ), 바이어스( $\theta_j$ ,  $\theta_i$ ), 학습률( $\eta$ ) 및 모멘텀( $\alpha$ )값의 초기값을 설정한다.

단계 2 : 출력층에서의 일반화된 오차( $\delta_k$ )를 계산한다.

$$\delta_k = z_k(1 - z_k)(d_k - z_k)$$

단계 3 : 은닉층과 출력층 사이의 가중값을 다음의 식에 의해 학습한다.

$$\Delta W_{kj}(k+1) = \eta \delta_k y_j + \alpha W_{kj}(k)$$

(여기서,  $k$ 는 반복단계,  $\eta$ 는 학습율,  $\alpha$ 는 모멘텀을 의미하며  $y_j$ 는 은닉층의 출력값을 의미한다.)

단계 4 : 은닉층에서의 일반화된 오차( $\delta_j$ )를 계산한다.

$$\delta_j = y_j(1 - y_j) \sum_k \delta_k W_{kj}$$

단계 5 : 출력층과 은닉층 사이의 가중값을 학습한다.

$$\Delta W_{ji}(k+1) = \eta \delta_j x_i + \alpha W_{ji}(k)$$

단계 6 : 오차함수를 체크하여 주어진 목표값에 미달하면 단계1~5를 반복한다.

### 3. 신경망을 이용한 배합요소의 추정

콘크리트를 제조하는 대부분의 레미콘사에는 콘크리트 배합설계를 위하여 사용재료의 특성에 따른 시방배합표를 회사별로 보유하고 있으며, 이들 재료의 특성에 따라 보정계수( $\alpha$ )를 사용하여 보정한 후 실제 배합설계에 사용하고 있다.

본 연구에는 신경망기법을 사용한 콘크리트의 배합설계를 실험을 거치지 않고 효율적으로 수행하기 위하여 목표오차값을 각각 0.10(10%), 0.05(5%)로 두고 연구 수행을 위해 표본 조사된 A,B 두 레미콘 회사의 시방배합표를 학습시켜 콘크리트의 배합요소인 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량 등을 추정하고, 시방배합표와 추정결과를 비교·분석함으로써 이를 검증하였다.

#### 3.1 시방배합의 학습 및 검증

학습에 사용된 시방배합표는 경상북도에 소재하고 있는 A, B 두 레미콘사에서 사용하고

있는 것으로 굵은골재 최대치수 25mm, 설계압축강도 100~400kgf/cm<sup>2</sup>, 목표슬럼프값 5, 8, 10, 12, 15, 18, 21cm인 실제 시방배합표를 입력 자료로 학습하였고, 조립률 및 비중은 각 회사마다 다르게 표시되고 있으므로 학습자료로는 활용하지 않았다. 이들 레미콘사에 현재 사용하고 있는 시방배합표의 학습된 자료를 검정하기 위하여 앞에서 학습시키지 않은 무작위의 규격 180-15, 210-15, 240-8, 240-15, 270-15, 300-15에 대하여 검정자료로 사용하였다. 또한 재료의 특성 중 굵은골재는 두 회사 모두 25mm 쇄석을 사용하였고, 잔골재로는 A사에는 강모래(S1)와 부순모래(S2)를 혼합하여 사용하였으며, B사에서는 강모래만을 사용하였다.

신경망 학습에 있어 먼저 배합요소를 추정하기 위해 목표오차량 0.10을 설정하여 학습을 시킨 후 출력으로 각각의 배합요소를 추정하게 하였다. 그리고 순차적인 학습을 하는데 걸리는 시간을 알 수 없으므로 수 많은 시행착오를 거쳐 최소의 목표오차량 0.05를 수행하게 하였다. 학습횟수는 최대 500,000번을 학습하여 목표오차에 만족하도록 프로그램을 수행하였다. 시방배합에 사용된 회사별 재료의 물성은 Table 1.에 나타내었다.

Table 1. 회사별 재료의 물성

회사	A사	B사
잔골재 비중	2.59	2.58
굵은골재 비중	2.64	2.63
잔골재율	2.80	2.80
혼화제	AE감수제	AE감수제

### 3.2 A사의 배합요소 추정 및 분석

A사에서는 시방배합의 요소 중 잔골재로 강모래(S1)와 부순모래(S2)를 혼합하여 사용하였다. 목표오차량이 0.10 및 0.05인 경우 A사의 신경망 학습에 의한 검정결과를 시방배합표와 비교한 값을 Table 2.에 나타내었다. Fig. 2는 목표오차량이 0.10일 때 학습의 수렴 상태를 나타낸 곡선이며 Fig. 3는 목표오차량 0.05일 때의 경우이다.

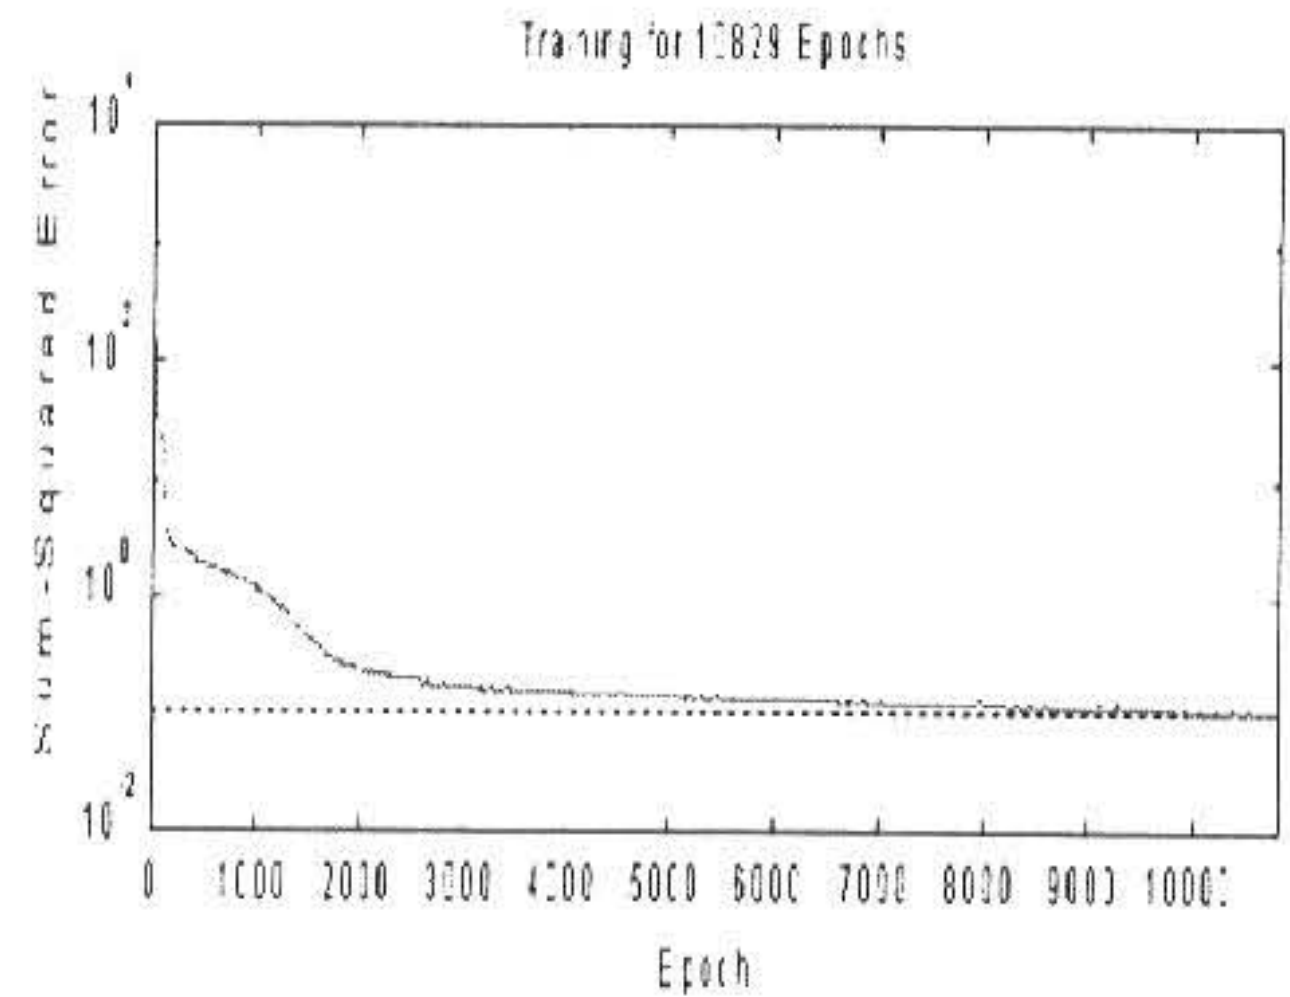


Fig. 2 A사의 학습 수렴곡선(목표오차량 0.10)

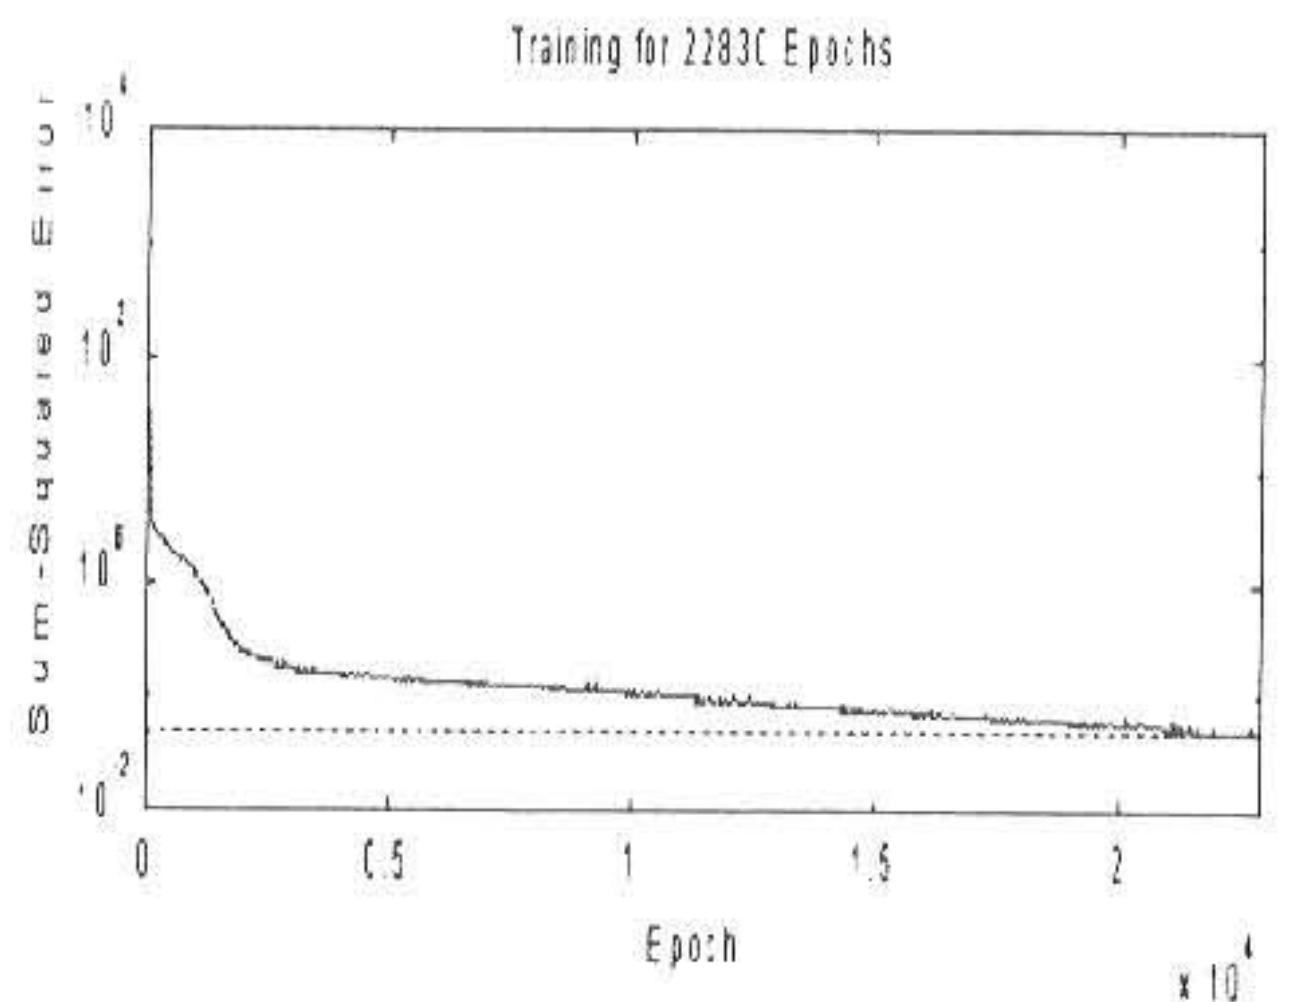


Fig. 3 A사의 학습 수렴곡선(목표오차량 0.05)

신경망 학습을 통하여 배합요소를 추정하는데는 목표오차량 0.10 대하여 그 수렴 값은 비교적 쉽게 얻을 수 있었지만 목표오차량 0.05에 수렴하는 값을 찾는다는 상당히 많은 시간이 소요됨을 알 수 있다.

A사의 경우에 배합요소의 추정시 목표오차값 0.10로 수렴하는데 10,829회(Epoch)의 학습이 소요되었으며, 목표오차량 0.05로 수렴하는데는 22,830회의 학습이 소요되고 있으나 목표오차값 0.10일 경우에도 충분히 시방배합값에 수렴됨을 알 수 있었다.

### 3.3 B사의 배합요소 추정 및 분석

B사는 잔골재로 강모래(S1)만을 사용하여, A사와 동일한 설계조건에 따라 작성된 시방배합표에서 각각의 배합요소를 추정하기 위해 목표오차량이 0.10일 때와 0.05일 때의 추정값을 구하였다.

Table 2. A사의 신경망학습에 의한 김정결과

규격	배 합		W/C (%)	S/A (%)	중량배합(kg/m <sup>3</sup> )					AE/C (%)
					W	C	S1	S2	G	
180-15	시방배합		59.5	46.7	188.0	316.0	326.0	489.0	955.0	0.95
	추정배합	0.10	59.1	46.8	189.5	320.8	324.8	487.1	950.4	1.00
		0.05	59.1	46.7	188.7	319.3	324.9	487.3	953.5	1.00
210-15	시방배합		53.4	45.5	187.0	350.0	313.0	469.0	963.0	1.05
	추정배합	0.10	53.3	45.5	187.2	349.1	313.0	469.4	962.9	1.10
		0.05	53.3	45.5	186.7	348.1	313.2	469.7	964.8	1.00
240-8	시방배합		48.6	43.0	170.0	350.0	304.0	456.0	1031.0	1.05
	추정배합	0.10	48.6	43.0	168.9	347.1	304.0	456.4	1035.3	1.00
		0.05	48.6	43.1	169.7	348.7	303.9	456.1	1032.3	1.00
240-12	시방배합		48.6	43.9	179.0	368.0	303.0	454.0	994.0	1.10
	추정배합	0.10	48.6	43.9	178.9	368.2	303.2	454.7	994.0	1.10
		0.05	48.6	43.9	178.6	367.9	303.2	454.8	994.9	1.10
270-15	시방배합		44.3	43.7	184.0	415.0	293.0	439.0	968.0	1.25
	추정배합	0.10	44.6	43.7	183.5	412.9	292.9	439.4	970.3	1.20
		0.05	44.7	43.7	183.7	413.4	293.0	439.5	969.2	1.20
300-15	시방배합		40.9	43.0	183.0	447.0	284.0	426.0	966.0	1.34
	추정배합	0.10	40.9	42.9	182.1	449.5	283.3	424.9	968.1	1.40
		0.05	41.1	43.0	182.6	450.3	283.4	425.2	965.5	1.40

Table 3. B사의 신경망 학습에 의한 김정결과

규격	배 합		W/C (%)	S/A (%)	중량배합(kg/m <sup>3</sup> )				AE/C (%)
					W	C	S1	G	
180-15	시방배합		58.5	49.5	179.0	306.0	892.0	928.0	1.53
	추정배합	0.10	57.8	49.3	179.2	308.7	887.1	930.2	1.55
		0.05	58.3	49.4	179.0	305.9	890.3	929.8	1.53
210-15	시방배합		52.7	48.3	178.0	338.0	859.0	937.0	1.69
	추정배합	0.10	53.0	48.4	177.6	335.3	861.7	938.1	1.68
		0.05	53.2	48.4	177.8	331.6	863.2	939.0	1.66
240-8	시방배합		48.7	48.2	165.0	339.0	873.0	956.0	1.70
	추정배합	0.10	48.6	48.2	165.0	337.0	874.0	957.3	1.69
		0.05	48.5	48.2	165.1	340.3	872.1	956.2	1.70
240-12	시방배합		48.7	47.8	172.0	353.0	852.0	948.0	1.77
	추정배합	0.10	48.7	47.9	171.4	352.0	853.5	948.6	1.76
		0.05	48.9	47.9	171.8	350.3	853.4	949.2	1.75
270-15	시방배합		45.3	46.5	181.0	400.0	800.0	938.0	2.00
	추정배합	0.10	45.5	46.9	175.2	394.4	816.3	941.1	1.98
		0.05	45.5	46.9	176.1	388.1	816.2	944.1	1.94
300-15	시방배합		41.7	46.1	175.0	420.0	792.0	944.0	2.10
	추정배합	0.10	42.2	46.3	174.6	426.0	793.5	939.4	2.13
		0.05	42.1	46.2	175.5	420.2	793.2	942.2	2.10

목표오차량의 결정에 따라 학습시간의 차이가 많이 나지만 한번 학습한 후에는 그 추정값을 쉽게 찾을 수가 있었다.

Table 3.은 목표오차량이 0.10과 0.05일 경우에 B사의 시방배합표와 신경망 학습에 의한 배합요소 추정값을 비교한 것이다.

Fig. 4 및 Fig. 5는 목표오차량이 0.10, 0.05일 경우의 학습의 수렴 상태를 나타낸 것이다. 그

림에서 알 수 있는 바와 같이 B사의 경우에는 배합요소의 추정시 목표오차량 0.10에는 12,782회의 학습으로 시방배합값에 수렴하고 있으며, 목표오차량 0.05에서는 48,851회의 학습이 소요되고 있어 비교적 시간이 많이 소요됨을 알 수 있었다.




Fig. 4 B사의 학습 수렴곡선 (목표오차량 0.10)

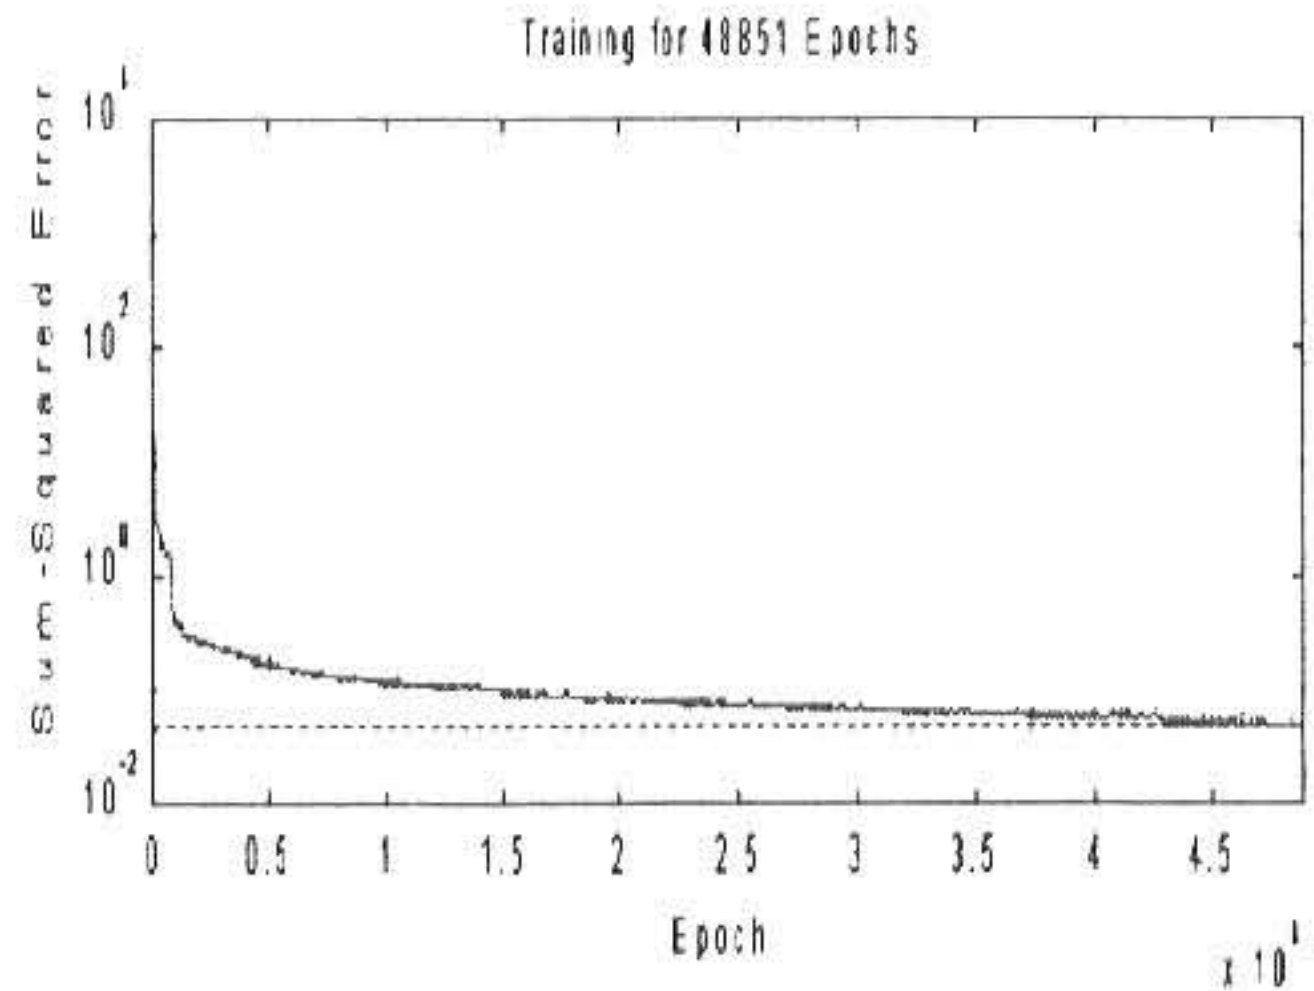


Fig. 5 B사의 학습 수렴곡선(목표오차량 0.05)

Table 4. 시방배합표에 대한 A사 추정값의 오차량

배합요소	목표오차량	규격						
		180-15	210-15	240-8	240-12	270-15	300-15	
물시멘트비	0.05	0.67	0.19	0.00	0.00	0.90	0.49	
	0.10	0.67	0.19	0.00	0.00	0.68	0.00	
잔골재율	0.05	0.00	0.00	0.00	0.00	0.00	0.00	
	0.10	0.21	0.00	0.23	0.00	0.00	0.23	
단위수량	0.05	0.37	0.16	0.18	0.22	0.16	0.22	
	0.10	0.80	0.11	0.65	0.06	0.27	0.49	
단위시멘트량	0.05	1.04	0.54	0.37	0.03	0.39	0.74	
	0.10	1.52	0.26	0.83	0.05	0.51	0.56	
단위 잔골재량	S1	0.05	0.34	0.06	0.03	0.07	0.00	0.21
		0.10	0.37	0.06	0.00	0.07	0.03	0.25
	S2	0.05	0.35	0.15	0.02	0.18	0.11	0.19
		0.10	0.39	0.09	0.09	0.15	0.09	0.26
단위굵은골재량	0.05	0.16	0.19	0.10	0.09	0.12	0.05	
	0.10	0.48	0.01	0.39	0.00	0.24	0.22	
혼화제량	0.05	5.25	4.76	4.76	0.00	4.00	4.48	
	0.10	5.25	4.76	4.76	0.00	4.00	4.48	

Table 5. 시방배합표에 대한 B사 추정값의 오차량

배합요소	목표오차량	규격					
		180-15	210-15	240-8	240-12	270-15	300-15
물시멘트비	0.05	0.43	0.95	0.51	0.32	0.35	1.01
	0.10	1.26	0.48	0.29	0.05	0.39	1.07
잔골재율	0.05	0.14	0.25	0.05	0.12	0.80	0.21
	0.10	0.38	0.17	0.02	0.10	0.92	0.35
단위수량	0.05	0.01	0.10	0.05	0.10	2.70	0.27
	0.10	0.11	0.22	0.00	0.35	3.20	0.23
단위시멘트량	0.05	0.03	1.89	0.38	0.76	2.97	0.05
	0.10	0.88	0.80	0.59	0.28	1.40	1.43
단위잔골재량	0.05	0.19	0.49	0.10	0.16	2.03	0.15
	0.10	0.55	0.31	0.11	0.18	2.04	0.19
단위굵은골재량	0.05	0.19	0.21	0.02	0.13	0.65	0.19
	0.10	0.24	0.12	0.14	0.06	0.33	0.49
혼화제량	0.05	0.20	1.72	0.24	0.90	2.85	0.19
	0.10	1.05	0.59	0.76	0.40	1.25	1.57

### 3.4 오차량

A사의 시방배합표에 대한 배합요소의 추정오차

량을 Table 4.에 나타내었으며 혼화제를 제외한 배합요소의 오차량을 목표 오차량이 0.10과 0.05일

때, 상호 비교한 값은 규격 270-15, 300-15에서 약간 크게 나타나고 있으나 모두 오차량이 1% 미만으로 신경망에 의한 학습효과가 매우 정확한 것임을 알 수 있었다.

또한 B사의 시방배합표와의 추정오차량에서 시방배합표를 이용하여 신경망 학습을 통하여 얻은 각 배합요소의 추정값을 가지고 오차량을 산출한 결과는 Table 5와 같다.

표에서 보는 바와 같이 시방배합표에 비교하여 오차량이 배합요소별 다소의 차이는 있으나 최대 3.2%로 나타나고 있으므로 콘크리트 배합설계를 신경망으로 적용함에 있어 매우 만족스러운 결과를 얻을 수 있었다. 또한 추정 물시멘트비의 목표오차량 0.10과 0.05에서 오차발생이 최대 1.26~1.01%로 나타나 목표오차량 0.10로 학습을 시켜도 시방배합표상의 값을 근사적으로 얻을 수 있음을 알 수 있었다.

#### 4. 결론

본 연구에서는 신경망 이론을 배합설계에 적용하여 컴퓨터에 의한 학습 및 시뮬레이션을 수행한 후에 콘크리트의 배합요소들을 예측하였으며 그 결과는 다음과 같다.

- 1) 목표오차량을 0.10으로 했을 경우 A사의 학습횟수는 10,829회, B사의 학습횟수는 12,782회 소요되었고, 목표오차량을 0.05로 했을 경우 A사의 학습횟수는 22,830회, B사의 학습횟수는 48,851회가 소요되어 목표오차량의 감소에 따라 학습에 걸리는 시간이 현저히 늘어남을 알 수 있었다.
- 2) 학습결과 배합요소의 추정값인 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량 등은 A, B회사 모두 목표오차량 0.10, 0.05에서 배합요소별 다소 차이는 있으나 시방배합표와 거의 일치되었으며, 목표오차량을 줄일 경우에는 보다 정확한 값으로 수렴되고 있음을 알 수 있었다.
- 3) 추정된 혼화제량의 시방배합표에 대한 오차량이 A사의 경우 최대 5.25%, B사의 경우 최대 2.85%로 다소 크게 나타났는데, 이것은 혼

화제 사용량이 극히 소량인데다 잔골재인 부순모래에 미립분이 많이 포함되었기 때문이라 판단된다.

- 4) 추정값의 오차량을 비교·분석한 결과 혼화제량을 제외한 배합요소별 목표오차량 0.10에서 시방배합표의 값에 대한 오차량의 범위가 A사는 단위시멘트량에서 최대 1.52%, B사는 단위수량에서 3.2%로 나타났으나 목표오차량 0.05일 경우는 이들 오차량의 범위를 각각 1.04, 2.70%로 줄일 수 있어 목표오차량을 적게 할 경우에는 시방배합표의 값에 더욱 수렴시킬 수 있음을 알 수 있었다.

#### 참고문헌

- 1) 건설교통부 : 콘크리트 표준 시방서, 한국콘크리트학회,(1999)
- 2) 김대수 : 무지도 패턴인식을 위한 자기조직화 신경회로망의 성질과 특성, 한국정보과학회 학위논문 발표집,(1991)
- 3) 文翰英 : 建設材料學, 동명사,(1998)
- 4) 정환진 : 신경망을 이용한 구조물의 손상평가, 석사학위논문, 한국과학기술원,(1996)
- 5) D. E. Rumehart, G. E. Hinton, and R. J. Williams : *Learning Internal Representation by Error Propagation*, in *Parallel Distributed Processing*, The MIT Press, Vol. 1,(1986)
- 6) I-Cheng Yeh : *Design of High Performance Concrete Mixture Using Neural Networks and Nonlinear Programming*, Vol. 13, No. 1, January, pp.36-42,(1999)
- 7) J. E. Bolander : *Spring network model of fiber-reinforced cement composites*, In *High Performance Fiber Reinforced Cement Composites (HPFRCC 3)*, eds. H.W. Reinhardt and A.E. Naaman, RILEM, pp.341-50,(1999)
- 8) J. J. Hopfield : *Neurons With graded response have collective computational properties like those of two-state neurons*, Proc. of the National Academy Science 81, pp. 3088-3092,(1984)
- 9) Simon Haykin : *Neural Network*, Macmillan, (1994)

- 10) McCulloch, W.S and Pitts, W.H : *A Logical Calaulus of the Ideas Immanent*, Bulletin of Mathematical Biophysiss 5, pp. 115-133,(1943)
- 11) Rosenblatt : *The Perceptron, A theory of Statistical Separability in Cognitive System*, Buffalo, Cornell Aeronautic Lab. Inc, Rep. No. VG-1196-G-1,(1958)
- 12) Webos. P. J. : *Generalization of Backpropagation with Application to Recurrent Gas Market Model*, Neural Network, Vol.1, pp. 339-356,(1988)

---

(2001년 7월 25일 접수, 2001년 11월 22일 채택)

본 논문은 2001학년도 대구대학교 학술연구비 지원에 의한 논문임.