

신경망을 이용한 콘크리트의 압축강도 및 슬럼프값 추정 The Prediction of Compressive Strength and Slump Value of Concrete Using Neural Networks

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

<Abstract>

An artificial neural network is applied to the prediction of compressive strength, slump value of concrete. Standard mixed tables are trained and estimated, and the results are compared with those of experiments. To consider the varieties of material properties, the standard mixed tables of two companies of Ready Mixed Concrete are used. And they are trained with the neural network. In this paper, standard back propagation network is used. For the arrangement on the approval of prediction of compressive strength and slump value, the standard compressive strength of 210, 240kgf/cm² and target slump value of 12, 15cm are used because the amount of production of that range are the most at ordinary companies. In results, in the prediction of compressive strength and slump value, the predicted values are converged well to those of standard mixed tables at the target error of 0.10, 0.05, 0.001 regardless of two companies.

Key Words : *neural network, standard mixed tables, slump value, back propagation, compressive strength, target error*

1. 서 론

콘크리트 표준압축강도의 설정을 재령 28일 강도로 하고 있으므로 이를 검정하는데는 많은 시간이 필요하고, 또한 각 재료의 특성 및 실험

에 의한 다양한 변수들이 요인으로 작용하므로 콘크리트에서 설계기준강도¹⁾를 추정하는 것은 쉬운 일이 아니며 추정한 강도도 실제강도와는 차이가 있기 마련이다. 신경망 이론은 컴퓨터 공학이나 기계공학에 이미 오래 전에 사용되어

* 정회원, 대구대학교 건설환경공학부 교수, 工博

E-mail : Ywchoi@taegu.ac.kr

** 정회원, 대구대학교 건설환경공학부 교수, 工博

E-mail : Jikim@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

왔지만 인공지능 시스템을 토목분야에 적용한 예는 1990년대 이후에 비로소 비교적 활발히 진행되고 있다.

다양한 배합요소를 가지고 있는 콘크리트의 배합설계에서 신경망에 의한 강도를 예측할 때 신경망의 학습에 소요되는 시간은 컴퓨터 성능 및 학습횟수(Epoch)에 따라 다르게 된다.

본 연구는 여러 가지 물성의 변화를 갖고 있는 콘크리트용 재료에서 실제 레미콘 회사의 배합에 사용되고 있는 시방배합표에 따라 신경망 이론을 이용하여 컴퓨터에 의한 학습 및 시뮬레이션을 통하여 콘크리트의 압축강도 및 슬럼프값을 추정하였으며, 그 결과값과 실험값을 비교함으로써 실험을 통하지 않고도 콘크리트의 압축강도 및 슬럼프값을 추정하는데 그 목적이 있다.

압축강도 및 슬럼프값 추정에 사용된 규격으로는 회사별 최근 생산량이 가장 많은 설계기준강도 $210, 240 \text{ kgf/cm}^2$, 그리고 목표슬럼프값 $12, 15 \text{ cm}$ 를 각각 사용하였다. 신경망에 의한 학습은 학습횟수를 최고 백만회까지 반복하도록 하였으며, 학습종료조건으로 최소자승법에 의해 목표오차량이 $0.10 \sim 0.001$ 사이가 될 때까지 시행하였다.

2. 신경망에 대한 이론적 고찰

인간의 두뇌와 신경세포 모델에 대한 연구가 시작되면서 컴퓨터를 통하여 패턴인식, 음성분석, 의사결정 등에서 간단한 인공지능문제를 다루고자 하는 것이 신경망이다.

뉴우런을 구성하는 요소로는 축색(Axon), 수상돌기(Dendrites), 시냅스(Synapses) 등이 있다. 이러한 구조를 가진 신경세포들이 서로 얹혀 있으면서 상호간에 신호를 전달하는 것이 신경세포의 기능이다.

2.1 신경망의 이론적 배경

Fig. 1에 나타낸 생물학적 신경망은 신경세포가 복잡하게 얹힌 비선형 시스템으로 구성된 네트워크이며 이 뉴우런은 중앙 신경계의 구성단위로서 전반적인 상호 정보통신을 수행하여 수많은 학습을 통하여 그 성능이 증진될 수 있다.

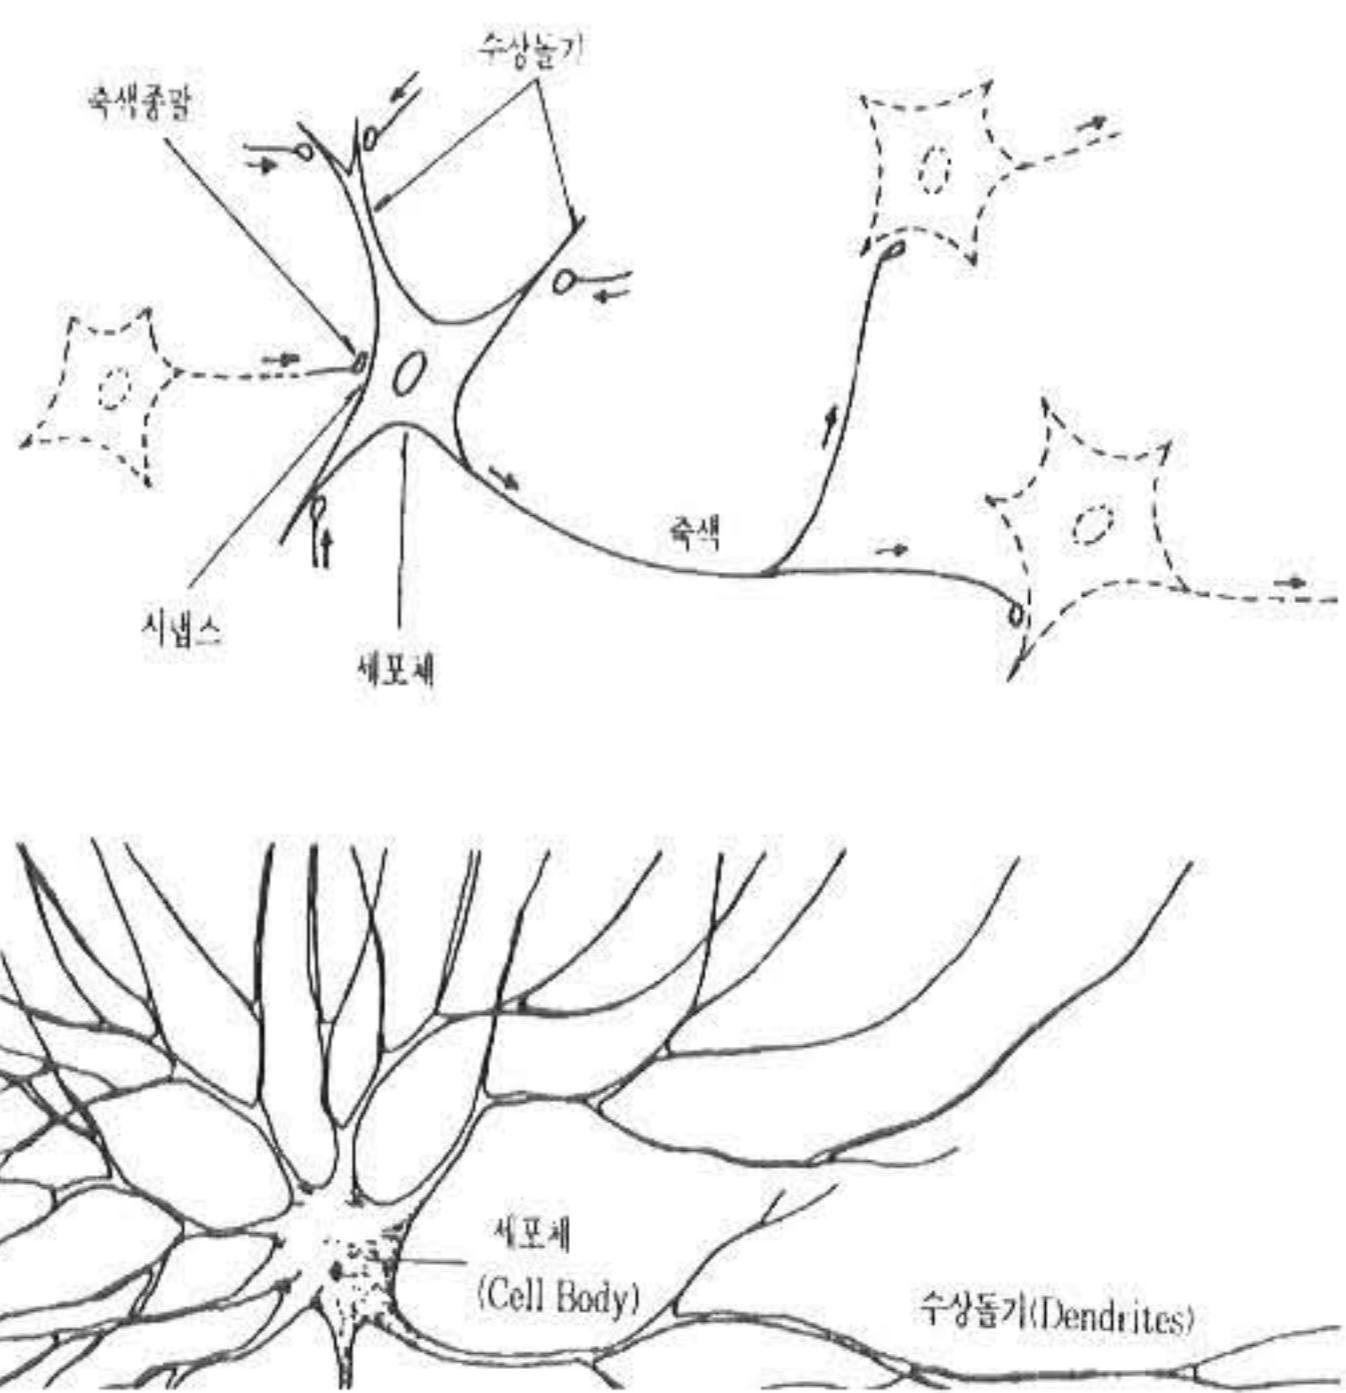


Fig. 1 Basic Structure of Neuron

공학용 신경망 모델의 시초는 McCulloch과 Pitts²⁾이며 Fig. 2와 같다.

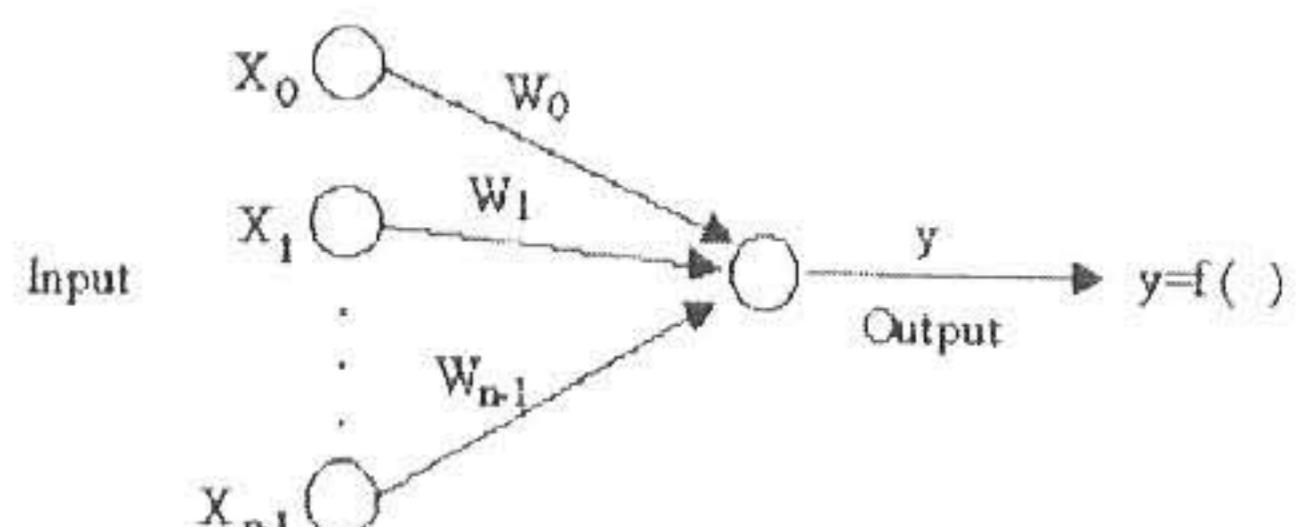


Fig. 2 Neuron of McCulloch-Pitts

또한 1984년에 발표한 Hopfield모델³⁾도 신경망에서 매우 중요한 모델이다.

신경망과 심볼릭(Symbolic) 처리를 하는 인공지능은 어떤 주어진 문제에 대하여 서로가 전혀 다른 접근 방법을 쓴다.

다층퍼셉트론을 학습시킬 수 있는 역전파 학습 알고리즘이 Webos⁴⁾에 의해 개발되었다. 이 방법은 1980년대 중반 Rumehart, Hinton 및 Williams 등⁵⁾에 의해 널리 알려져 신경회로망의 응용분야^{6~10)}도 패턴분류나 연상기억장치의 범주에서 빛이나 최적화 문제, 로봇제어, 문자인식, 음성인식, 신호처리, 머신비전 및 경영분야에 까지 많이 응용되고 있으며, 기존의 컴퓨터

에 의해 풀기 어려웠던 문제들에 대해 쉬운 해결책을 제시함으로써 차세대 컴퓨터의 중요한 기술로 평가받고 있다.

신경망의 처리에는 외부에서 오는 신호(x_0, x_1, x_2)를 받아들여 각 신호에 가중치(W_0, W_1, W_2)를 곱하여 더한 값을 액티베이션 함수를 거쳐 다른 신경망으로 보낸다. 이 과정을 수식으로 나타내면 식 (1), 식 (2)와 같다.

$$y = f(\text{net}) \quad (1)$$

$$\text{net} = \sum_i W_i x_i + \theta \quad (2)$$

여기서 x_i, y, θ, W_i 는 각각 입력값, 출력값, 바이어스값 및 가중치이다.

신경망의 액티베이션 함수 $f(\cdot)$ 는 여러 가지가 있을 수 있겠으나 최근 신경회로망에서 전이함수로는 비선형 함수 특히 시그모이드(Sigmoid)함수가 많이 사용되며 주로 0과 1 사이의 출력값을 제공하는 시그모이드함수는 다음 식 (3)과 같다.

$$f(x) = \frac{1}{1 + \exp(-\lambda x)} \quad (3)$$

신경망의 동적 반응을 결정하는 액티베이션 함수의 종류는 시그모이드함수 외에도 로그함수나 선형함수가 있고, 특별한 경우에는 가우스함수를 쓰기도 한다.

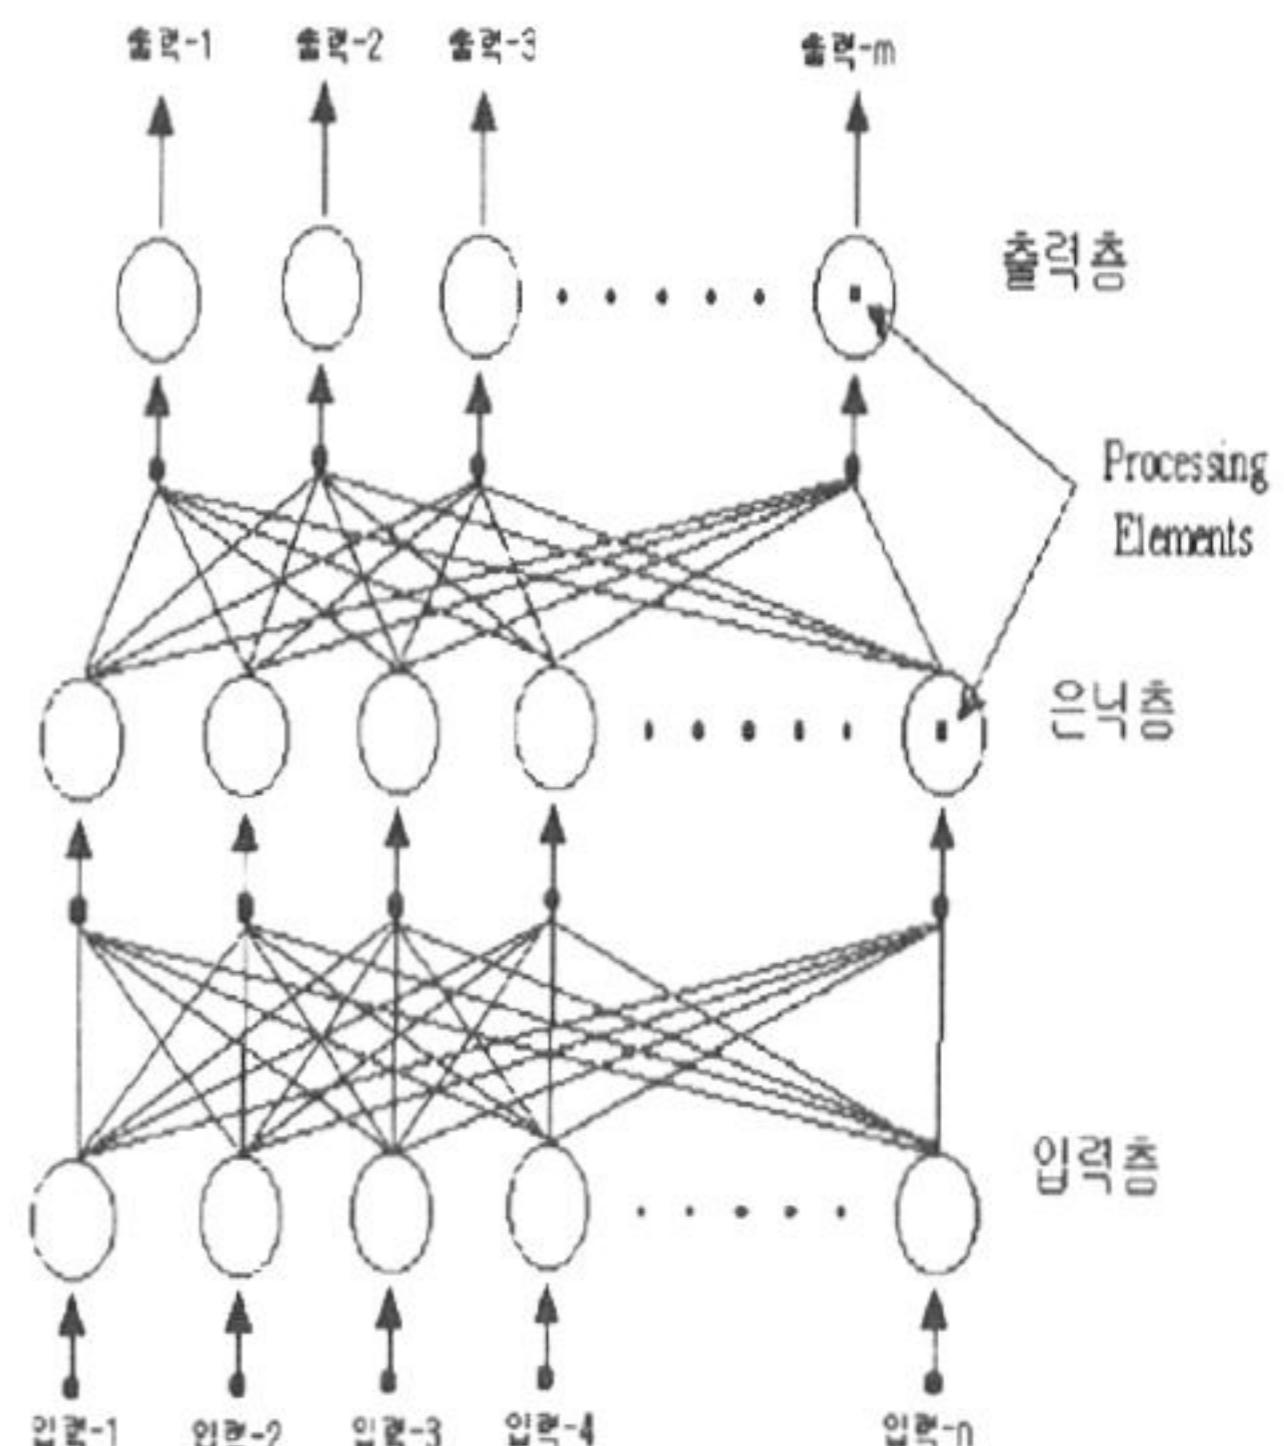
2.2 다층퍼셉트론

신경망 이론의 용용에서 신경망의 구조는 하나의 뉴우런을 몇 개의 층 구조로 배열하여 각각의 뉴우런을 연결해 놓은 것으로 이것을 다층퍼셉트론이라 한다.

다층퍼셉트론은 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 인공신경망으로 공학에서 널리 쓰이는 인공신경망을 쉽게 나타낸 것이 Fig. 3이며, Fig. 2의 뉴우런을 몇 개의 층구조로 배열하여 각각의 뉴우런을 연결해 놓은 것이다. Rosenblatt(1958)의 단층퍼셉트론¹¹⁾의 경우 학습 가능한 층이 하나만 존재하기 때문에 선형분리 가능한 문제에만 적용 가능하다

는 한계가 있었는데, 이러한 한계를 벗어나기 위하여 다층 퍼셉트론을 이용하게 된다.

네트워크는 입력층, 은닉층 및 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향(Feedforward)의 네트워크이다.



m : 출력층의 수 n : 입력층의 수

Fig. 3 Multi-layer Perceptron for Engineering

다층퍼셉트론은 단층퍼셉트론과 유사한 구조를 가지고 있지만 은닉층과 각 유니트의 입출력 특성을 비선형으로 함으로써 네트워크의 능력을 향상시켜 단층퍼셉트론의 여러 가지 단점을 극복하게 된다.

3개의 층으로 이루어진 다층퍼셉트론에서 주어진 입력에 대한 계산은 다음과 같다. 먼저 식 (4) 및 식 (5)와 같은 연산을 은닉층의 뉴우런에서 수행한다.

$$y_i = f(\text{net}_j) \quad (4)$$

$$\text{net}_j = \sum_i W_{ji} x_i + \theta_j \quad (5)$$

여기서 x_i, y_i 는 입력값과 은닉층의 출력값이

고, W_{ji} , θ_j 는 입력층과 은닉층 사이의 가중치 및 바이어스값이다. 은닉층의 출력값 y_i 를 이용한 출력층의 연산은 식 (6) 및 식 (7)과 같다.

$$z_k = f(\text{net}_k) \quad (6)$$

$$\text{net}_k = \sum_k W_{kj}y_j + \theta_k \quad (7)$$

여기서, z_k 는 신경망의 출력값이고, W_{kj} , θ_k 는 은닉층과 출력층 사이의 가중치 및 바이어스값이다. 이 때 식 (4)와 식 (6)의 액티베이션 함수는 반드시 일치할 필요는 없다.

이와 같이 신경망은 단순한 연산과정을 통해 출력값을 만들고 또한 병렬처리가 가능하기 때문에 실제로 매우 빠르게 작동할 수 있다. 다중 퍼셉트론의 신경망을 학습시킨다는 것은 주어진 입력에 대해 미리 정해진 출력값을 만들도록 뉴우런 사이의 연결강도를 적절히 조절한다는 것이다. 학습을 위해서는 식 (8)과 같은 오차함수를 정의한다.

$$E = \frac{1}{2} \sum_k (d_k - z_k)^2 \quad (8)$$

여기서 d_k , z_k 는 각각 신경망의 목표값과 신경망의 출력값이다. 오차함수 E 는 신경망에서 직접나오는 출력값과 미리 정해진 목표값 사이의 차이를 출력층에서 모두 더한 값이다. 이러한 오차함수가 최소가 되도록 신경망의 연결강도 즉, 가중값을 조정한다.

2.3 학습 알고리즘

입력에 대해 처리요소의 출력값을 결정하는 가장 중요한 요소는 연결강도이며, 각 처리요소들의 출력값들은 결국 신경망의 출력결과를 결정하게 되므로 신경망을 이용하여 원하는 출력값을 얻기 위해서는 연결강도를 조정하여야 한다. 모든 신경망은 주어진 사례들을 이용하여 처리요소들 사이의 연결강도를 스스로 조정하게 되는데 이 과정을 학습이라고 한다.

신경망을 학습시키기 위한 알고리즘도 여러 가지가 있다. 그 중에서도 가장 간단하고 가장

널리 쓰이는 것이 역전파 학습법이다.

역전파라 함은 학습신호가 출력층에서 은닉층으로, 은닉층에서 다시 입력층으로 전파하기 때문에 붙은 이름이다. 입력층, 은닉층 및 출력층으로 구성된 신경망에 대한 역전파학습법의 단계별 알고리즘을 정리하면 다음과 같다.

단계 1 : 가중치(W_{kj} , W_{ji}), 바이어스(θ_j , θ_i), 학습률(η) 및 모멘텀(α)값의 초기값을 설정한다.

단계 2 : 출력층에서의 일반화된 오차(δ_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, η 는 학습율, α 는 모멘텀을 의미하며 y_j 는 은닉층의 출력값을 의미한다.)

단계 4 : 은닉층에서의 일반화된 오차(δ_j)를 계산한다.

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

단계 5 : 출력층과 은닉층 사이의 가중값을 학습한다.

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

단계 6 : 오차함수를 체크하여 주어진 목표값에 미달하면 단계 1~5를 반복한다.

3. 신경망을 이용한 압축강도 및 슬럼프값의 추정

신경망 학습을 통한 콘크리트의 압축강도를 추정하기 위하여 표본추출한 A, B 두 레미콘 회사에서 사용하는 시방배합표를 선택하여 배

합요소와 압축강도를 학습시켜 배합요소가 주어졌을 경우 압축강도와 슬럼프값을 출력시켜 시방배합표상의 규격값과 비교하였다.

또한 실제 실험을 통하여 얻은 압축강도 및 슬럼프값과 비교하여 검정함으로써 추정값에 대한 정확성을 입증하였다. 이를 위해 목표 오차량이 0.10, 0.05 및 0.001의 세 가지의 경우에 대해 학습을 하였다.

3.1 압축강도 및 슬럼프값의 학습 및 검정

시방배합표에서 정해진 학습요소들 즉 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 단위잔골재량(S1, S2), 단위굵은골재량, 혼화제량을 입력자료로 활용하고, 출력값으로 압축강도와 슬럼프값을 목표값으로 하여 추정하였다.

학습을 위해 시방배합표의 배합요소, 압축강도 및 슬럼프값을 최대 100만회를 학습하여 목표오차에 만족하도록 프로그램을 수행하고, 압축강도 및 슬럼프값을 추정하였다. 또한 추정값에 대한 검정을 위해 압축강도 및 슬럼프의 실험값을 이용하여 추정값과 비교·분석하였다.

3.2 압축강도 및 슬럼프시험

현재 각 레미콘 회사는 증가계수를 감안한 압축강도를 배합강도로 사용하고 있으므로 본 연구에서는 추정값과 실험값의 비교는 실험값을 보정계수의 역수로 곱하여 얻어진 값을 이용하였다.

콘크리트의 압축강도는 시험체 제작방법, 캡핑, 하중의 재하속도, 다짐 및 기계적 특성에 따라 많은 실험적 오차가 발생하게 된다.

이러한 실험적 오차를 줄이기 위하여 각 회사마다 콘크리트 공시체를 규격(180-12, 210-12, 240-12)에 따라 100개 이상을 제작하여 슬럼프 및 압축강도시험을 통하여 얻은 값의 평균값을 이용하였다.

3.2.1 재료의 물성

콘크리트 재료의 물성값은 기초 물성실험을 통하여 얻은 것으로 회사별 그 값을 Table 1.에 나타내었다.

Table 1. Physical Properties of Materials

	물 성	A 사	B 사
비중	시멘트	3.14	3.15
	강모래(S1)	2.59	2.58
	부순모래(S2)	2.51	-
	굵은골재	2.64	2.63
조립율	강모래(S1)	3.30	2.70
	부순모래(S2)	2.25	-
	굵은골재	6.53	6.6
혼화제	(표준)	AE감수제 표준형	AE감수제 표준형

3.2.2 시험방법

회사별로 레미콘의 압축강도 및 슬럼프시험을 실시하였고 실제 배합설계에는 보정계수를 회사마다 다르게 적용하고 있으므로 배합강도의 설정을 위한 보정계수를 Table 2.에 나타내었다.

Table 2. Calibration Coefficient

압축강도(kgf/cm ²)	A사	B사
100~161	1.21	1.26
161~181	1.22	1.19
181~211	1.22	1.17
211~241	1.23	1.13
241~401	1.25	1.12

그리고 시험방법으로 슬럼프시험은 KS F 2402에 준하여 행하였고, 공시체의 규격은 압축강도 시험용 $\phi 10 \times 20\text{cm}$ 의 강제몰드를 사용하였으며, 제작 및 양생방법은 KS F 2403의 규정에 따라 실시하였다. 또한 압축강도시험은 KS F 2405에 준하여 실시하였다.

3.2.3 압축강도의 시험결과

회사별로 규격 180-12, 210-12, 240-12에 대한 실험용 공시체를 제작하여 압축강도 및 슬럼프 시험을 행하였으며, 압축강도의 결과를 Table 3.에 나타내었다.

Table 3. Results of Compressive Strength

회사명	A사	B사
규격	180-12	180-12
	210-12	210-12
	240-12	240-12
시험횟수	150	115
	118	145
	124	121
평균강도 (kgf/cm ²)	224	234
	264	266
	297	303
보정계수	1.22	1.19
	1.22	1.17
	1.23	1.13
보정강도 (kgf/cm ²)	184	196
	216	227
	242	268

3.3 추정값과 실험값의 비교·분석

일반적으로 레미콘회사의 시방배합표에는 압축강도의 규격이 목표 슬럼프값을 동반하여 기록되고 있으며 현장에서 슬럼프값의 변화는 작업성에 큰 영향을 미치므로 본 연구에서는 압축강도와 슬럼프값의 추정을 동시에 수행하였다.

3.3.1 A사의 압축강도 및 슬럼프값

Table 4는 신경망 학습에 의한 A사의 압축강도와 슬럼프값의 추정결과를 나타낸 것이다.

압축강도 및 슬럼프의 추정값이 시방배합표의 규격값과 비교할 때 목표오차량을 줄일 경우 규격값에 더 가깝게 수렴되고 있음을 알 수 있다.

즉, 목표오차량 0.001에서 목표오차량 0.10이나 0.05보다 시방배합표에 매우 근접하고 있으며 목표오차량을 더 줄일 경우에는 보다 정확한 값을 얻을 수 있을 것으로 판단되어 신경망에 의한 학습이 매우 효과적인 것으로 본다.

그러나 추정값을 실험값에 비교하면 다소 차이가 있으며 실험값이 크게 나타남을 알 수 있다. 이는 실험값이 실험조건 및 환경에 따라 실험오차를 수반하기 때문인 것으로 본다.

Table 4. Prediction of Compressive Strength and Slump Value for A Company

시험		압축강도 (kgf/cm ²)	슬럼프값 (cm)
방법	규격		
추정값 (0.10)	180-12	179.5	11.7
	210-12	209.0	11.7
	240-12	240.1	12.6
추정값 (0.05)	180-12	179.3	11.9
	210-12	208.6	11.9
	240-12	238.6	12.2
추정값 (0.001)	180-12	180.2	12.0
	210-12	209.6	11.9
	240-12	239.9	12.1
실험값	180-12	184.0	12.0
	210-12	216.0	12.0
	240-12	242.0	12.5

1) 압축강도

Fig. 4는 규격 180-12, 210-12, 240-12에 대한 압축강도를 목표오차량에 따른 추정값과 실험값을 규격별로 비교하여 나타낸 것이다.

Table 4와 Fig. 4에서 알 수 있는 바와 같이 실험에 의한 압축강도는 시방배합표의 규격값보다 각각 4kgf/cm², 6kgf/cm², 2kgf/cm²으로 크게 나타났고 추정값은 목표오차량을 적게 할 수록 규격값에 수렴되고 있음을 알 수 있다.

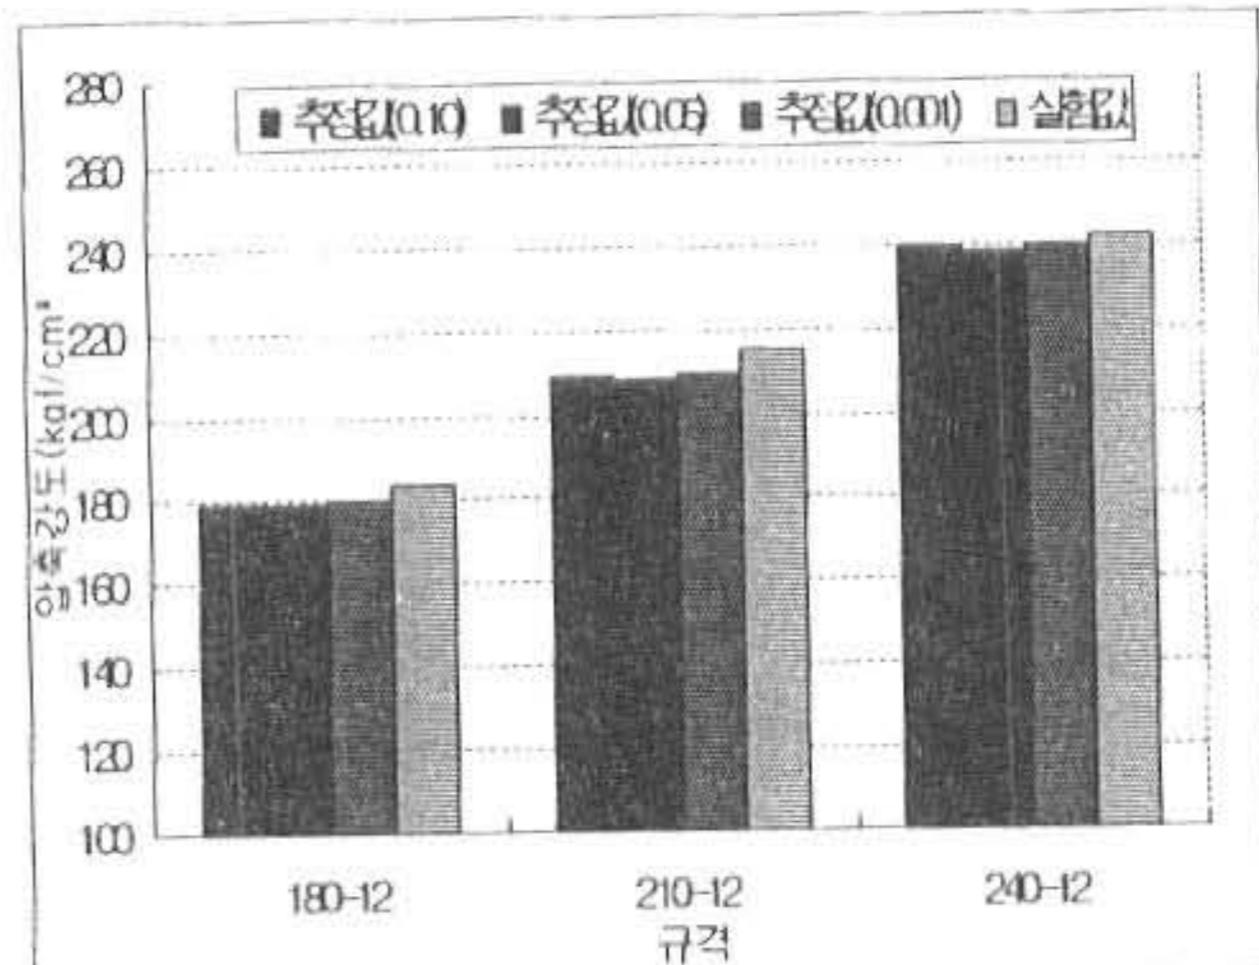


Fig. 4 Compressive Strength for A Company

2) 슬럼프값

A사의 신경망 학습에 의한 슬럼프값의 추정을 실험값과 비교한 것이 Fig. 5에 나타나 있

다. A사의 결과에서 알 수 있는 바와 같이 슬럼프의 추정값을 비교하면 목표오차량을 작게 할수록 시방규격에 근접하고 있으며 목표오차량 0.001에서는 거의 일치함을 알 수 있다. 그러나 실험값은 규격 240-12에서 0.5cm 크게 나타나고 있으나 이는 실험의 오차라고 판단된다.

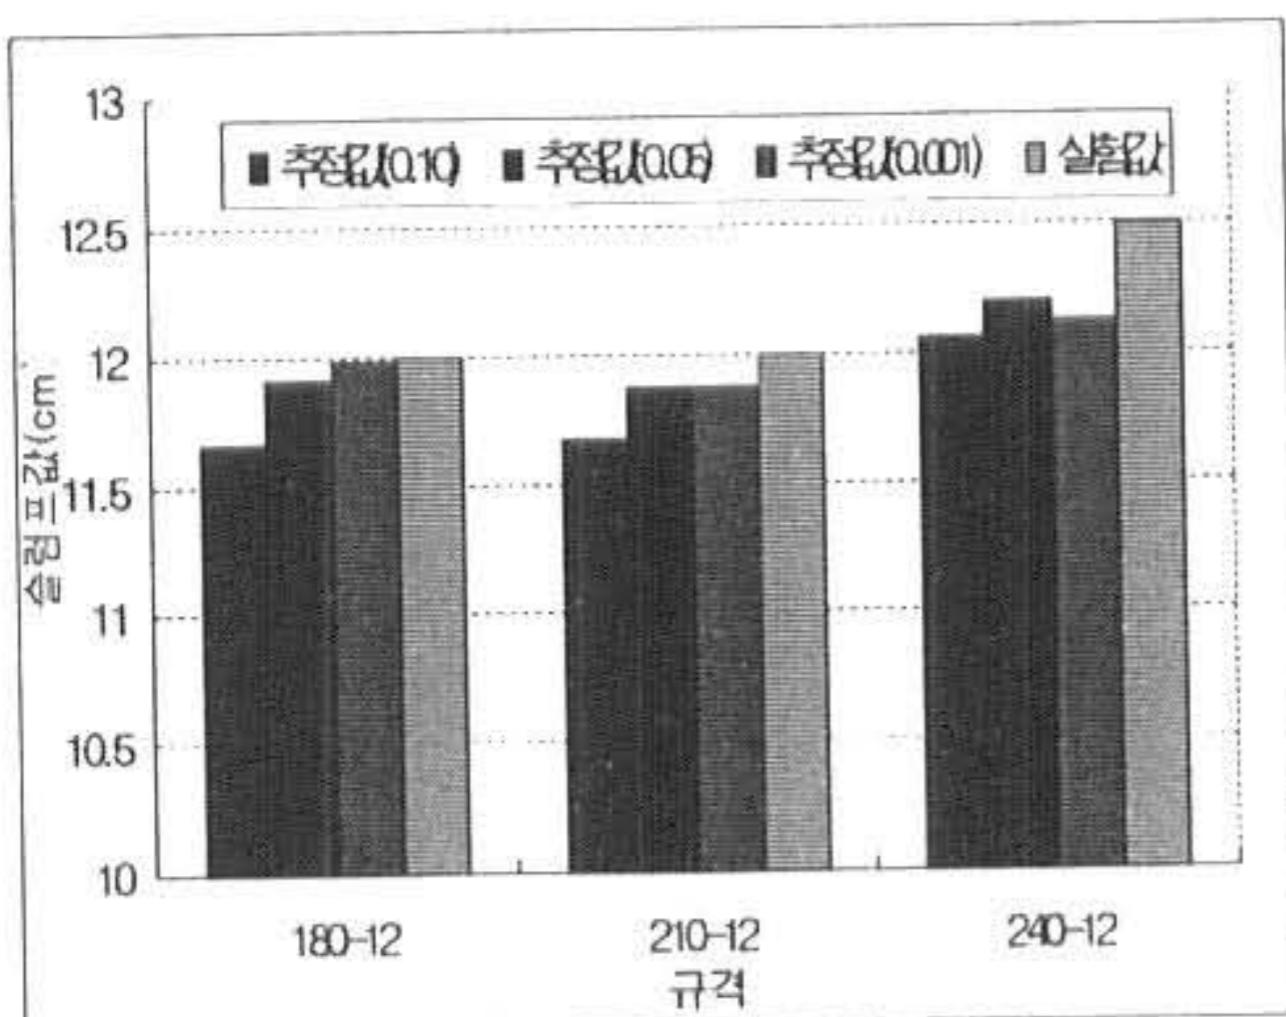


Fig. 5 Slump Value for A Company

3.3.2 B사의 압축강도 및 슬럼프값

Table 5.에서 보는 바와 같이 B사의 신경망 학습에 의한 압축강도 및 슬럼프의 추정값은 비교적 시방배합의 규격에 근사한 값을 나타내지만 실험값은 시방규격에 비해 다소 크게 나타나고 있다.

Table 5. Prediction of Compressive Strength and Slump Value for B Company

시험		압축강도 (kgf/cm ²)	슬럼프값 (cm)
방법	규격		
추정값 (0.10)	180-12	179.5	12.5
	210-12	209.1	11.8
	240-12	239.6	12.2
추정값 (0.05)	180-12	180.1	12.2
	210-12	209.6	11.9
	240-12	240.1	12.1
추정값 (0.001)	180-12	180.2	11.9
	210-12	209.8	12.0
	240-12	240.1	12.1
실험값	180-12	196.6	12.5
	210-12	227.7	12.0
	240-12	268.1	12.0

1) 압축강도

Fig. 6은 B사의 신경망학습 결과 압축강도의 추정값 및 실제 실험값을 시방배합표의 시방규격 180-12, 210-12, 240-12와 비교한 것이다.

Table 5. 및 Fig. 6에서 보는 바와 같이 추정값이 목표오차량을 줄일 경우 시방배합의 규격값에 수렴하고 있음을 알 수 있다. 그러나 실험값은 추정값에 비해 압축강도가 크게 나타나고 있다. 이는 실험값이 실험조건 및 환경에 따른 실험오차가 있는 것으로 판단된다.

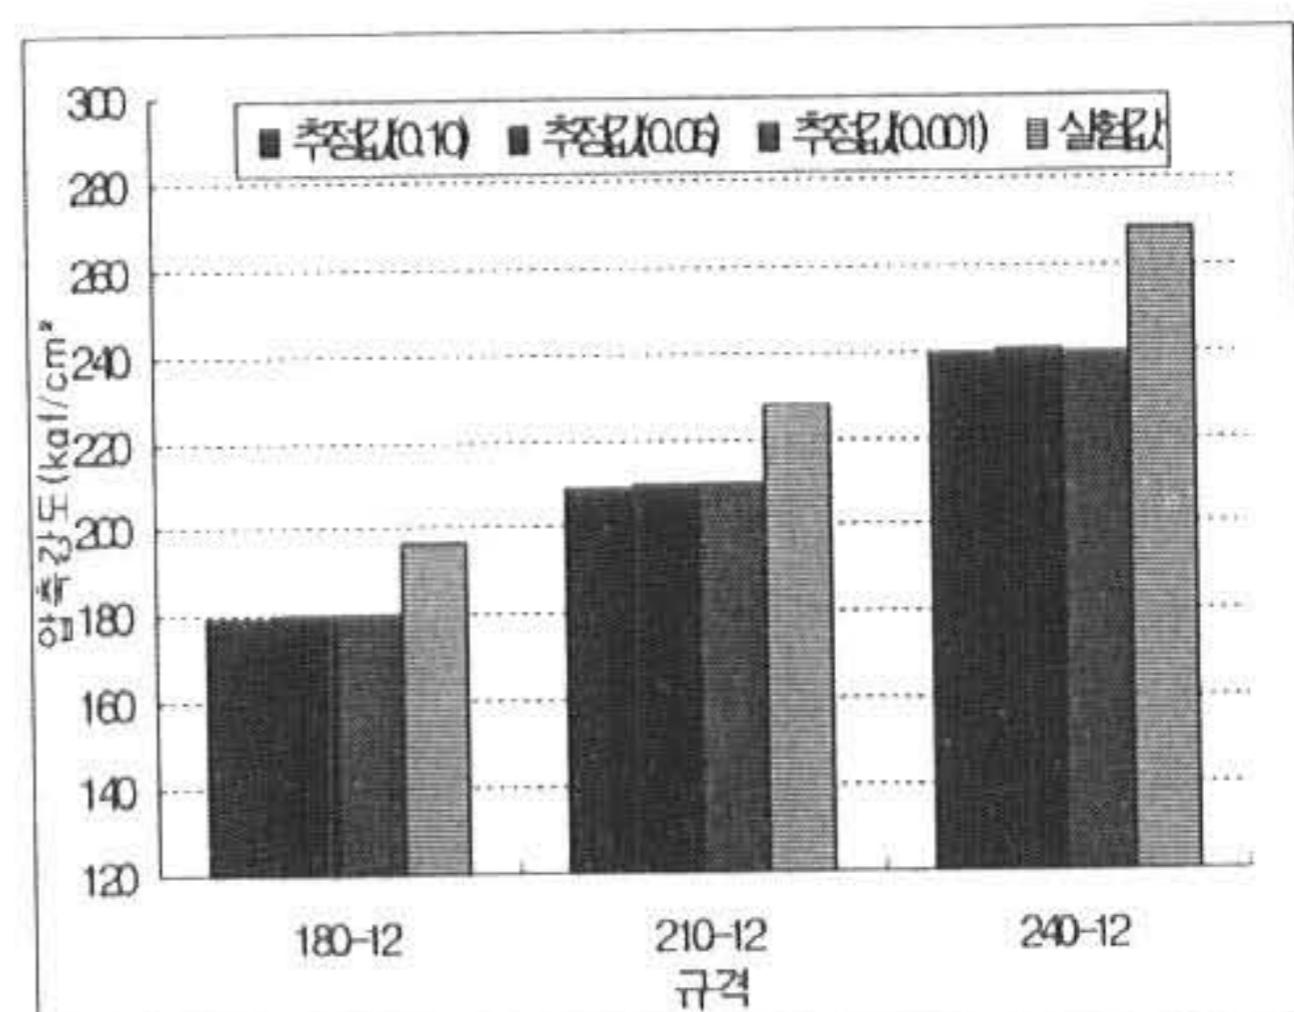


Fig. 6 Compressive Strength for B Company

2) 슬럼프값

B사의 신경망학습에 의한 슬럼프의 추정값과 실험값을 시방배합의 규격값에 비교한 것을 Fig. 7에 나타내었다.

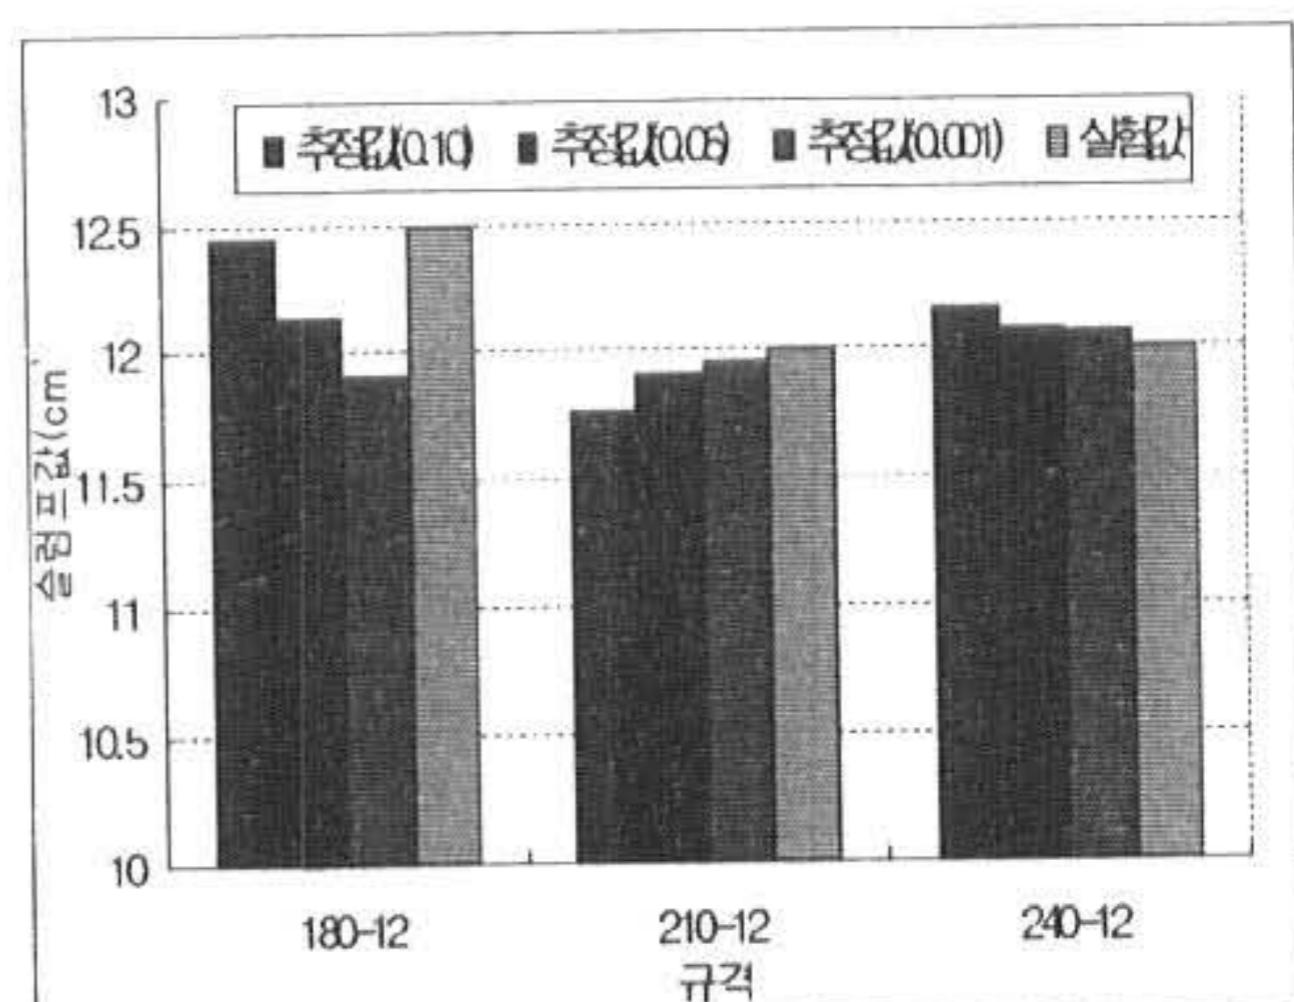


Fig. 7 Slump Value for B Company

Fig. 7에서 보는 바와 같이 목표오차량 0.10에서 추정 슬럼프값이 다소 크게 나타났으나

목표오차량을 0.05, 0.001로 줄일 경우에는 시방 배합표의 규격에 거의 수렴되고 있음을 알 수 있다. 그러나 실험값은 규격 180-12에서 0.5cm 크게 나타나 있으나 이는 실험오차라 판단된다.

4. 결 론

A, B사의 시방배합표의 규격에 따라 신경망에 의한 압축강도 및 슬럼프의 추정을 위해 목표오차량을 0.10, 0.05 및 0.001의 세 가지의 경우에 대해 학습을 하고, 압축강도와 슬럼프 추정값을 구하였다. 또한 실험을 통하여 얻은 실험값과 이들 추정값을 비교·분석한 결과 다음과 같은 결론을 얻을 수 있었다.

- 1) 압축강도 및 슬럼프의 추정값은 A, B사 모두 목표오차량을 줄일 경우 배합규격에 양호하게 수렴함을 알 수 있었다.
- 2) 압축강도 및 슬럼프의 실험값은 A, B사 모두 배합규격 및 추정값에 비해 다소 크게 나타나고 있으나 이는 실험오차에 기인하는 것으로 판단된다.
- 3) 배합규격별 오차량을 비교한 결과 목표오차량을 줄일 경우 오차량이 줄어듦을 알 수 있었고, A, B사 모두 압축강도의 추정값이 시방배합규격에 양호하게 수렴하였다.
- 4) 압축강도 및 슬럼프값의 추정에는 학습자료의 수가 작았으므로 목표오차량의 설정은 0.001로 하여야만 보다 신뢰할 수 있는 값을 추정할 수 있었다.

이상의 결과를 종합할 때 콘크리트의 배합설계시 신경망을 이용한 압축강도 및 슬럼프값을 추정하는 것은 매우 타당성이 있었으며 목표오차량을 줄일 경우 보다 신뢰할 수 있는 값을 얻을 수 있다고 판단된다.

참고문헌

- 1) 건설교통부 : 콘크리트표준시방서, 한국콘크리트학회, (1999)
- 2) McCulloch, W. and Pitts, W., "A Logical Calculus of the Ideas Immanent", Bulletin of Mathematical Biophysics 5, pp.115-133, (1943)

- 3) 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)
- 4) Webos, P. J., "Generalization of Back-propagation with Application to Recurrent Gas Market Model", Neural Network, Vol. 1, pp. 339-356, (1988)
- 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) Simon Haykin, "Neural Network", Macmillan, (1994)
- 7) S. V. Barai and P. C. Pandey, "Vibration Signature Analysis Using Artificial Neural Networks", Volume 9, Number 4, (1998)
- 8) Howard, B. Rao and Louis, H. Turcotte, "Advanced Mathematics and Mechanics Applications using MATLAB", CRC Press, (1994)
- 9) I-Cheng. Yeh, "Design of High Performance Concrete Mixture Using Neural Networks and Nonlinear Programming", Volume 13, Number 1, pp.36-42, (1999)
- 10) Kuo-lin H. Hoshin V. G and S. Soroosh, Artificial Neural Network Modeling of the Rainfall-Runoff Process, Water Resources Research, Vol. 31, No. 10, pp.2517-2539, (1995)
- 11) Rosenblatt, "A theory of Statistical Separability in Cognitive System", Buffalo, Cornell Aeronautic Lab. Inc, Rep. No. VG-1196-G-1, (1958)

(2001년 7월 25일 접수, 2002년 4월 20일 채택)