

신경망을 이용한 콘크리트 배합요소 및 압축강도 추정

김인수¹⁾ · 이종현¹⁾ · 양동석^{2)*} · 박선규²⁾

¹⁾경일대학교 토목공학과 ²⁾성균관대학교 토목환경공학과

(2001년 7월 23일 원고접수, 2002년 5월 28일 심사완료)

Prediction on Mix Proportion Factor and Strength of Concrete Using Neural Network

In-Soo Kim¹⁾, Jong-Heon Lee¹⁾, Dong-Suk Yang^{2)*}, and Sun-Kyu Park²⁾

¹⁾ Dept. of Civil Engineering, Kyungil University, Daegu, 712 701, Korea

²⁾ Dept. of Civil and Environmental Engineering, Sungkyunkwan University, Suwon, 440 746, Korea

(Received July 23, 2001, Accepted May 28, 2002)

ABSTRACT

An artificial neural network was applied to predict compressive strength, slump value and mix proportion of a concrete. Standard mixed tables were trained and estimated, and the results were compared with those of the experiments. To consider variabilities of material properties, the standard mixed tables from two companies of Ready Mixed Concrete were used. And they were trained with the neural network. In this paper, standard back propagation network was used. The mix proportion factors such as water cement ratio, sand aggregate ratio, unit water, unit cement, unit weight of sand, unit weight of crushed sand, unit coarse aggregate and air entraining admixture were used. For the arrangement on the approval of prediction of mix proportion factor, the standard compressive strength of 180 kgf/cm²~300 kgf/cm², and target slump value of 8 cm, 15 cm were used. For the arrangement on the approval of prediction of compressive strength and slump value, the standard compressive strength of 210 kgf/cm²~240 kgf/cm², and target slump value of 12 cm and 15 cm were used because these ranges are most frequently used.

In results, in the prediction of mix proportion factor, for all of the water cement ratio, sand aggregate ratio, unit water, unit cement, unit weight of sand, unit weight of crushed sand, unit coarse aggregate, air entraining admixture, the predicted values and the values of standard mixed tables were almost the same within the target error of 0.10 and 0.05, regardless of two companies. And in the prediction of compressive strength and slump value, the predicted values were converged well to the values of standard mixed tables within the target error of 0.10, 0.05, 0.001. Finally artificial neural network is successfully applied to the prediction of concrete mixture and compressive strength.

Keywords : neural network, compressive strength, slump, water cement ratio, sand aggregate ratio

1. 서 론

현대사회에서 건설전반에 보편화되어 있는 레미콘은 다양한 사용재료의 물리·화학적 성분이 생산지 및 조성광물에 따라 다르므로 구해지는 결과값 또한 무수한 변수가 있기 마련이다. 또한 콘크리트의 배합설계는 배합요소의 다변화로 인해 정확한 검정은 그리 간단하지가 않다¹⁾.

콘크리트의 배합설계와 압축강도의 평가는 실제 구조물의 해석, 설계, 품질관리 등에 일관성을 가져올 수 있는 가장 기본적인 자료로 사용되나, 지금까지는 이를 위한 시험방법이나 규정들이 대부분 다른 물성의 재료를 사용하

더라도 보통콘크리트에 적용되는 방법을 그대로 사용하고 있어 실질적으로 콘크리트의 정확한 압축강도추정이 어려울 뿐만 아니라 실험자료도 매우 부족한 실정이다.

신경망 이론은 컴퓨터 공학이나 기계공학에 이미 오래 전에 사용되어왔지만 인공지능 시스템을 토목분야에 적용한 예는 1990년대 이후에 비교적 활발히 진행되고 있다. 신경망을 이용한 해석으로는 강우 유출과정에 대한 신경망 모형²⁾, 신경망을 이용한 해양파의 추정, 신경망을 이용한 구조물의 손상평가³⁾ 등이 있으며 특히 콘크리트의 배합설계에 관해서는 콘크리트의 강도 특성을 추정할 수 있는 시스템 개발, 신경회로망을 이용한 고강도 콘크리트의 강도추정 및 신경회로망을 이용한 고성능 콘크리트의 배합설계 시스템을 개발하였다.

* Corresponding author

Tel : 031-290-7530 Fax : 031-290-7549

E-mail : yds0619@dreamwiz.com

이들의 제안은 대부분 역전파알고리즘(back-propagation algorithm)을 사용하여 비선형 뉴우런으로 구성된 다층 뉴럴네트워크에도 적용 가능한 알고리즘을 명확히 나타내었다.

신경망의 학습에 소요되는 시간은 컴퓨터의 성능 및 학습횟수(epoch)에 따라 다르고, 학습시 학습횟수를 최고 백만번까지 반복하도록 하였으며 학습 종료조건으로 최소자승법에 의해 목표 오차량이 0.10~0.001 사이가 될 때까지 하였다. 신경망의 적용에는 현재 경북지방에 위치한 레미콘 회사중 A, B사에서 사용하는 콘크리트 시방배합표를 가지고 신경망 이론에 따라 학습시킨 후에 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량을 추정하였고, 다음으로 압축강도 및 슬럼프값을 각각 추정하였다.

배합요소 추정의 검정에 사용된 규격으로는 호칭강도 180 kgf/cm²~300 kgf/cm², 목표슬럼프값 8 cm, 15 cm를 사용하였고, 압축강도 및 슬럼프값 추정에 사용된 규격으로는 회사별 최근 생산량이 가장 많은 호칭강도 210~240 kgf/cm², 목표 슬럼프값 12, 15 cm를 각각 사용하였다.

본 논문에서는 컴퓨터에 의한 학습 및 시뮬레이션을 통해 콘크리트의 배합요소, 압축강도 및 슬럼프값을 추정하여 직접 실험값과 비교함으로써 실험을 통하지 않고도 콘크리트의 배합요소 및 강도를 추정하는데 목적이 있다.

2. 신경망에 대한 이론적 고찰

인간의 두뇌와 신경세포 모델에 대한 연구가 시작되면서 컴퓨터를 통하여 패턴인식, 음성분석, 의사결정 등에서 간단한 인공지능 문제를 다루고자 하는 것이 신경망이다. 인간의 두뇌는 10¹⁰개의 뉴우런(neuron)이 있고, 뉴우런들 간의 연결은 10¹⁴개에 이르는 것으로 추정된다.

2.1 신경망 이론

2.1.1 신경망의 이론적 배경

신경망 모델의 시초는 McCulloch와 Pitts가 인간의 두뇌는 무수히 많은 신경세포들로 이루어진 잘 정의된 컴퓨터라고 하는 논문에서 찾을 수 있다. Rosenblatt은 1957년 퍼셉트론(perceptron)이란 최초의 신경망 모델을 발표하였는데⁶⁾, 여기서는 학습 프로세스에 알파강화 규칙을 사용하였고, 단순한 비선형문제는 해결하지 못하였다. Hopfield 모델과 Boltzmann Machine 등³⁾도 역시 신경망에서 매우 중요한 모델들이다.

Fig. 1에서 나타낸 신경망은 신경세포가 복잡하게 얽힌 비선형 시스템으로 구성된 네트워크이며 이 뉴우런은 중앙신경계의 구성단위로서 전반적인 상호 정보통신을 수행하고 수많은 학습을 통하여 그 성능이 증진될 수 있다.

신경망과 심볼릭(symbolic) 처리를 하는 인공지능은 어

떤 주어진 문제에 대하여 서로가 전혀 다른 접근 방법을 쓴다. 다층 퍼셉트론을 학습시킬 수 있는 역전파(back-propagation)학습 알고리즘이 Werbos⁴⁾ 등에 의해 개발되었다. 이 방법은 1980년대 중반 Rumelhart, Hinton 및 Sejnowski 등⁵⁾에 의해 널리 알려져 신경회로망의 응용분야도 패턴분류나 연상기억장치의 범주에서 벗어나 최적화 문제, 로봇 제어, 문자인식, 음성인식, 신호처리, 머신비전 및 경영분야까지 많이 응용되고 있으며, 기존의 컴퓨터에 의해 풀기 어려웠던 문제들에 대해 쉬운 해결책을 제시함으로써 차세대 컴퓨터의 중요한 기술로 평가받고 있다. 신경망은 생물학적인 시스템에서 영감을 얻어 정보처리 시스템의 구조화에 관심이 있는 반면, 인공지능은 어려운 문제를 풀기 위해 여러 가지 형태의 지식을 표현하고 유추하는데 많은 관심을 가지고 있다. 지능정보처리 분야 중 신경망, 퍼지이론 및 인공지능(artificial intelligence)의 특징⁷⁾을 Table 1에 나타내었다.

이러한 신경망의 학습기능을 공학적인 문제에 이용하기 위해 1943년에 McCulloch와 Pitts는 수학적인 모델을 제안했다. 공학용 뉴우런모델은 Fig. 2에 나타내었다.

신경망의 처리에는 외부에서 오는 신호(x₀, x₁, x₂)를 받아들여 각 신호에 가중치(W₀, W₁, W₂)를 곱하여 더한 값을 액티베이션 함수를 거쳐 다른 신경망으로 보낸다. 이 과정을 수식으로 나타내면 식 (1), 식 (2)와 같다.

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

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

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

신경망의 액티베이션 함수 f()는 여러 가지가 있을 수 있겠으나 최근 신경회로망에서 전이함수로는 비선형 함수들이 사용되고, 특히 시그모이드(sigmoid)함수가 많이 사

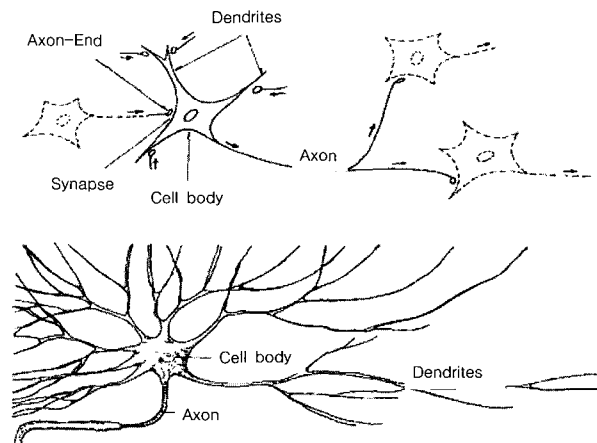


Fig. 1 Shape of neuron

Table 1 Disposal of intelligence information

	Advantage	Disadvantage
Neural network	<ul style="list-style-type: none"> • Unnecessity of the knowledge acquisition • Possibility of parallel processing • Powerfulness against a noise and a difficulty 	<ul style="list-style-type: none"> • Difficulty of the reasoning result • Difficulty in deciding a training example • Tardy of learning processing
Fuzzy theory	<ul style="list-style-type: none"> • Between the Neural Network and the Artificial intelligence • Possibility of parallel processing • Potentiality to use a field knowledge 	<ul style="list-style-type: none"> • Increase of in vague • Weakness in explaining • Difficulty of the knowledge acquisition
Artificial intelligence	<ul style="list-style-type: none"> • Propriety of the reasoning result • Transparency of the reasoning processing • Easiness of the maintenance and extension 	<ul style="list-style-type: none"> • Difficulty of the knowledge acquisition • Saturation of the control • Retardation of the successive processing




Fig. 2 Neuron of McCulloch-Pitts

용되며 주로 0과 1 사이의 출력값을 제공하는 시그모이드 함수는 다음 식 (3)과 같다.

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

신경망의 동적반응을 결정하는 액티베이션함수의 종류는 시그모이드함수 외에도 로그함수나 선형함수가 있고, 특별한 경우에는 가우스함수를 쓰기도 한다.

2.1.2 다층퍼셉트론

신경망 이론의 응용에서 신경망의 구조는 하나의 뉴런을 몇 개의 층 구조로 배열하여 각각의 뉴런을 연결해 놓은 것으로 이것을 다층퍼셉트론이라 한다. 다층퍼셉트론은 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 인공신경망으로 공학에서 널리 쓰이는 인공신경망을 쉽게 나타낸 것이며, Fig. 3은 뉴런을 몇 개의 층 구조로 배열하여 각각의 뉴런을 연결해 놓은 것이다. Rosenblatt(1958)의 단층퍼셉트론의 경우 학습 가능한 층이 하나만 존재하기 때문에 선형분리 가능한 문제에만 적용 가능하다는 한계가 있었는데, 이러한 한계를 벗어나기 위하여 다층퍼셉트론을 이용하게 된다. 네트워크는 입력층, 은닉층 및 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향(feedforward)의 네트워크이다. 다층퍼셉트론은 단층퍼셉트론과 유사한 구조를 가지고 있지만 은닉층과 각 유닛의 입출력 특성을 비선형으로 함으로써 네트워크의 능력을 향상시켜 다층퍼셉트론의 여러 가지

단점들을 극복했다⁸⁾.

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

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

$$\text{net}_i = \sum W_{ji}x_j + \theta_i \quad (5)$$

여기서, x_i , y_i 는 입력값과 은닉층의 출력값이고, W_{ji} , θ_i 는 입력층과 은닉층 사이의 가중치 및 바이어스값이다. 은닉층의 출력값 y_i 를 이용한 출력층의 연산은 식 (6) 및 식 (7)과 같다.

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

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

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. 다층퍼셉트론의 신경망을 학습시




Fig. 3 Multi-Layer perceptron

킨다는 것은 주어진 입력에 대해 미리 정해진 출력값을 만들도록 뉴우런 사이의 연결강도를 적절히 조절한다는 것이다. 학습을 위해서는 식 (8)과 같은 오차 함수를 정의한다.

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

여기서, d_k , z_k 는 각각 신경망의 목표값과 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.

2.2 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 간단하고 가장 널리 쓰이는 것이 역전파 학습법이다. 역전파는 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_k), 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 배합요소의 추정

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

본 연구에는 신경망을 이용한 배합설계를 위하여 레미콘회사별 목표오차값을 각각 0.10(10%), 0.05(5%)로 두고 시방배합표를 학습시켜 직접실험을 통하지 않고도 배합요소를 추정하고, 시방배합표와 추정결과를 비교·분석함으로써 이를 검증하였다.

3.1 시방배합의 학습 및 검증

학습에 사용된 시방배합표는 경북에 소재하고 있는 A, B 두 레미콘사에서 사용하고 있는 굵은골재 최대치수 25 mm, 설계압축강도 100~400 kgf/cm², 목표슬럼프값 5, 8, 10, 12, 15, 18, 21 cm인 실제 시방배합표를 입력자료로 학습하였고, 조립률 및 비중은 각 회사마다 다르게 표시되고 있으므로 학습자료로는 활용하지 않았다. 이들 레미콘사에 현재 사용하고 있는 시방배합표의 학습된 자료를 검증하기 위하여 앞에서 학습시키지 않은 무작위의 규격 180-15, 210-15, 240-8, 240-15, 270-15, 300-15에 대하여 검증자료로 사용하였다. 또한 재료의 특성 중 굵은골재는 두 회사 모두 25 mm 채석을 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 각각의 배합요소를 추정하게 된다. 그리고 순차적인 학습을 하는데 걸리는 시간을 알 수 없으므로 시행착오를 거쳐 최소의 목표오차량 0.05를 수행하게 하였다. 학습횟수는 최대 500,000번을 학습하여 목표오차에 만족하도록 프로그램을 수행하였다. 시방배합에 사용된 회사별 재료의 물성은 Table 2에 나타내었다.

3.2 A사의 배합요소 추정 및 분석

A사에서는 배합의 요소중 잔골재로 강모래(S1)와 부순모래(S2)를 혼합하여 사용하였다. 목표오차량이 0.10 및 0.05인 경우 A사의 신경망 학습에 의한 검증결과를 시방배합표와 비교한 값을 Table 3에 나타내었다. Fig. 4는 목

표오차량이 0.10일 때 학습횟수를 나타낸 것이고, Fig. 5는 목표오차량 0.05일 때의 경우이다.

신경망 학습을 통하여 배합요소를 추정하는데는 목표오차량 0.10 대하여 수렴 값은 비교적 쉽게 얻을 수 있었지만 목표오차량 0.05에 수렴하는 값을 찾는 데는 상당히 시간이 많이 소요됨을 알 수 있다. A사의 경우에 배합요소의 추정시 목표오차값 0.10로 수렴하는데 10,829회의 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

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

목표오차량의 결정에 따라 학습시간의 차이가 많이 나지만 한번 학습한 후에는 그 추정값을 쉽게 찾을 수가 있었다. Table 4는 목표오차량이 0.10과 0.05일 경우에 B사의 시방배합표와 신경망 학습에 의한 배합요소 추정값을 비교한 것이다. Fig. 6~7은 목표오차량이 0.10, 0.05일 경우의 학습횟수를 나타낸 것이다. B사의 경우에는 배합요소의

Table 2 Material properties

		Company	
		A	B
Specific gravity			
Sand aggregate		2.59	2.58
Coarse aggregate		2.64	2.63

Table 3 Official certification of neural network(A company)

Type	Mixture proportions		W/C (%)	S/A (%)	Unit weight(kg/m ³)					AE/C (%)
					W	C	S1	S2	G	
180-15	Standard-proportions		59.5	46.7	188.0	316.0	326.0	489.0	955.0	0.95
	Assumption-proportions	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	Standard-proportions		53.4	45.5	187.0	350.0	313.0	469.0	963.0	1.05
	Assumption-proportions	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	Standard-proportions		48.6	43.0	170.0	350.0	304.0	456.0	1031.0	1.05
	Assumption-proportions	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	Standard-proportions		48.6	43.9	179.0	368.0	303.0	454.0	994.0	1.10
	Assumption-proportions	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	Standard-proportions		44.3	43.7	184.0	415.0	293.0	439.0	968.0	1.25
	Assumption-proportions	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	Standard-proportions		40.9	43.0	183.0	447.0	284.0	426.0	966.0	1.34
	Assumption-proportions	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

추정시 목표오차량 0.10에는 12,782회의 학습이 소요되어 시방배합값에 만족하고 있으며, 목표오차량 0.05에서는 48,851회의 학습이 소요되고 있어 비교적 시간이 많이 소요됨을 알 수 있었다.

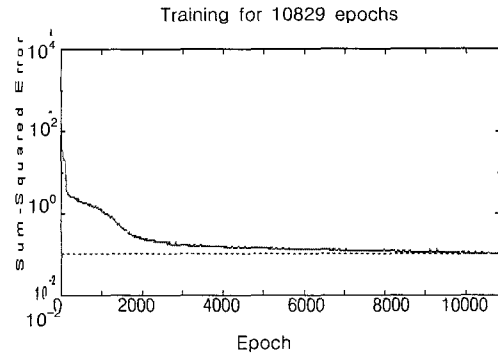


Fig. 4 Total error of training(A company) : target error = 0.10

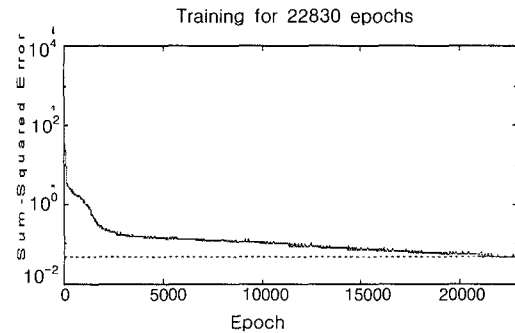


Fig. 5 Total error of training(A company) : target error = 0.05

3.4 오차량

A사의 추정오차량을 Table 5에 나타내었으며 혼화제를 제외한 배합요소의 시방배합표에 대한 오차량을 목표오차량이 0.10과 0.05일 때, 상호 비교한 값은 규격 270-15, 300-15에서 약간 크게 나타나고 있으나 오차량이 1% 미만으로 학습효과가 매우 정확한 것을 알 수 있었다.

B사의 추정오차량에서 시방배합표를 이용하여 신경망학습을 통하여 얻은 추정값을 가지고 각 배합요소에 대한 오차량을 산출한 결과는 Table 6과 같다. 시방배합표에 비교하여 오차량이 배합요소별 다소의 차이는 있으나 최대 3.2%로

나타나고 있으므로 신경망에 의한 배합설계를 적용함에 있어 매우 만족스러운 결과를 얻을 수 있었다. 추정 물시멘트비의 목표오차량 0.10과 0.05에서 오차발생률이 최대 1.26~1.01%로 나타나 목표오차량 0.10로 학습을 시켜도 시방배합표상의 값을 근사적으로 얻을 수 있음을 알 수 있었다.

4. 신경망을 이용한 압축강도 및 슬럼프값의 추정

신경망 학습을 통한 콘크리트의 압축강도를 추정하기 위하여 먼저 레미콘 회사에서 사용하는 시방배합표를 선

Table 4 Official certification of neuron-network(B company)

Type	Mixture proportions		W/C (%)	S/A (%)	Unit weight(kg/m ³)				AE/C (%)
					W	C	S1	G	
180-15	Standard-proportions		58.5	49.5	179.0	306.0	892.0	928.0	1.53
	Assumption -proportions	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	Standard-proportions		52.7	48.3	178.0	338.0	859.0	937.0	1.69
	Assumption -proportions	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	Standard-proportions		48.7	48.2	165.0	339.0	873.0	956.0	1.70
	Assumption -proportions	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	Standard-proportions		48.7	47.8	172.0	353.0	852.0	948.0	1.77
	Assumption -proportions	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	Standard-proportions		45.3	46.5	181.0	400.0	800.0	938.0	2.00
	Assumption -proportions	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	Standard-proportions		41.7	46.1	175.0	420.0	792.0	944.0	2.10
	Assumption -proportions	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

Table 5 Error of expectation value in concrete mixing (A company)

	Target of error	Size						
		180-15	210-15	240-8	240-12	270-15	300-15	
W/C	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	
S/a	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	
Water	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	
Cement	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	
Fine aggregate	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
Coarse aggregate	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	
Mineral admixture	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	

택하여 배합요소와 압축강도를 학습시켜 배합요소가 주어졌을 경우 압축강도와 슬럼프값을 출력시켜 시방배합표상의 규격값과 비교하였다. 또한 실제 실험을 통하여 얻은 압축강도 및 슬럼프값과 비교하여 검증함으로써 추정값에 대한 정확성을 입증하였다. 이를 위해 목표 오차량이 0.10, 0.05 및 0.001의 세 가지의 경우에 대해 학습을 하였다.

4.1 압축강도 및 슬럼프값의 학습 및 검증

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.

4.2 레미콘의 압축강도 및 슬럼프 시험




Fig. 6 Total error of training(B company)
: target error = 0.10

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

콘크리트의 압축강도는 시험체 제작방법, 캠핑, 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 슬럼프시험 및 압축강도시험을 통하여 얻은 값의 평균값을 이용하였다.

4.2.1 재료의 물성

콘크리트 재료의 물성값은 기초 물성실험을 통하여 얻은 것으로 회사별 그 값을 Table 7에 나타내었다.

4.2.2 시험방법

회사별로 레미콘의 압축강도 및 슬럼프시험을 실시하였고 실제 배합설계에는 보정계수를 회사마다 다르게 적용하고 있으므로 배합강도의 설정을 위한 보정계수를 Table 8에 나타내었다.

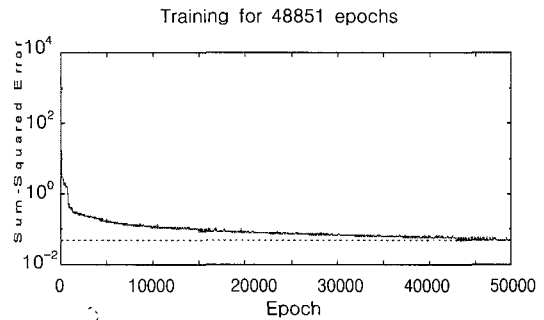


Fig. 7 Total error of training(B company)
: target error = 0.05

Table 6 Error of expectation value in concrete mixing (B company)

	Target of error	Size					
		180-15	210-15	240-8	240-12	270-15	300-15
W/C	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
S/a	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
Water	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
Cement	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
Fine aggregate	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
Coarse aggregate	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
Mineral admixture	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

슬럼프시험은 KS F 2402에 준하여 행하였고, 공시체의 규격은 압축강도 시험용 $\phi 10 \times 20$ cm의 강제물드를 사용하였으며, 제작 및 양생방법은 KS F 2403의 규정에 따라 실시하였다. 또한 압축강도시험은 KS F 2405에 준하여 실시하였다.

4.2.3 압축강도 시험결과

회사별로 규격 180-12, 210-12, 240-12에 대한 실험용 공시체를 제작하여 압축강도 및 슬럼프 시험을 행하였으며, 압축강도의 결과를 Table 9에 나타내었다.

4.3 압축강도 및 슬럼프의 추정값과 실험값의 고찰

일반적으로 레미콘회사의 시방배합표에는 압축강도의 규격이 목표 슬럼프값을 동반하여 기록되고 있으며 현장에서 슬럼프값의 변화는 작업성에 큰 영향을 미치므로 그 값은 중요하지 않을 수 없다. 그러므로 본 연구에서는 압축강도의 추정치는 물론 슬럼프값의 추정치도 동시에 수행하였다.

4.3.1 A사의 압축강도 및 슬럼프값

Table 10은 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.

1) 압축강도

Fig. 8은 A사의 규격 180-12, 210-12, 240-12에 대한 압축강도를 목표오차량에 따른 추정값과 실험값을 규격별로 비교하여 나타낸 것이다.

Fig. 8에서 알 수 있는 바와 같이 실험에 의한 압축강도는 시방배합표의 규격값보다 각각 4 kgf/cm^2 , 6 kgf/cm^2 , 2 kgf/cm^2 으로 크게 나타났고 추정값은 목표오차량을 적게 할수록 규격값에 수렴되고 있음을 알 수 있다.

2) 슬럼프값

A사의 신경망 학습에 의한 슬럼프값의 추정을 실험값과 비교한 것이 Fig. 9에 나타나 있다. A사의 결과에서 알 수 있는 바와 같이 슬럼프의 추정값을 비교하면 목표

Table 7 Mechanical properties of materials

Properties		A	B
Specific gravity	Cement	3.14	3.15
	S1	2.59	2.58
	S2	2.51	-
Fineness modulus	Coarse aggregate	2.64	2.63
	S1	3.30	2.70
	S2	2.25	-
Mineral admixture	Coarse aggregate	6.53	6.6
	-	AE -admixture	AE -admixture

Table 8 Coefficient of modification

Compressive strength(kgf/cm ²)	A	B
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

Table 9 Compressive strength

Company	A	B
Size	180-12	180-12
	210-12	210-12
	240-12	240-12
Test number	150	115
	118	145
	124	121
Average compressive strength (kgf/cm ²)	224	234
	264	266
	297	303
Modification coefficient	1.22	1.19
	1.22	1.17
	1.23	1.13
Modified compressive strength (kgf/cm ²)	184	196
	216	227
	242	268

Table 10 Expectation of compressive strength and slump(A company)

Test		Compressive strength (kgf/cm ²)	Slump (cm)
Method	Size		
Expectation value(0.10)	180-12	179.47	11.66
	210-12	208.98	11.67
	240-12	240.10	12.6
Expectation value(0.05)	180-12	179.25	11.91
	210-12	208.63	11.88
	240-12	238.60	12.20
Expectation value(0.001)	180-12	180.21	11.97
	210-12	209.59	11.88
	240-12	239.89	12.11
Test value	180-12	184	12
	210-12	216	12
	240-12	242	12.5

오차량을 작게 할수록 시방규격에 근접하고 있으며 목표 오차량 0.001에서는 거의 일치함을 알 수 있다. 그러나 실험값은 규격 240-12에서 0.5 cm 크게 나타나고 있으나 이는 실험의 오차라고 판단된다.

4.3.2 B사의 압축강도 및 슬럼프값

Table 11에서 보는 바와 같이 B사의 신경망학습에 의한 압축강도 및 슬럼프의 추정값은 비교적 시방배합의 규격에 근사한 값을 나타내지만 실험값은 시방규격에 비해 다소 크게 나타나고 있다.

1) 압축강도

Fig. 10은 B사의 신경망학습 결과 압축강도의 추정값 및 실제 실험값을 시방배합표의 시방규격 180-12, 210-12, 240-12와 비교한 것이다. Fig. 10에서 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.

2) 슬럼프값

B사의 신경망학습에 의한 슬럼프의 추정값과 실험값을 시방배합의 규격값에 비교한 것을 Fig. 11에 나타내었다.

Fig. 11에서 보는 바와 같이 목표오차량 0.10에서 추정 슬럼프값이 다소 크게 나타났으나 목표오차량을 0.05, 0.001로 줄일 경우에는 시방배합표의 규격에 거의 수렴되고 있음을 알 수 있다. 그러나 실험값은 규격 180-12에서 0.5 cm 크게 나타나 있으나 이는 실험오차라 판단된다.

Table 11 Expectation of compressive strength and slump(B company)

Test		Compressive strength (kgf/cm ²)	Slump (cm)
Method	Size		
Expectation value(0.10)	180-12	179.47	12.45
	210-12	209.13	11.76
	240-12	239.6	12.16
Expectation value(0.05)	180-12	180.05	12.14
	210-12	209.58	11.91
	240-12	240.12	12.08
Expectation value(0.001)	180-12	180.19	11.91
	210-12	209.79	11.96
	240-12	240.07	12.06
Test value	180-12	196.64	12.50
	210-12	227.73	12.00
	240-12	268.14	12.00

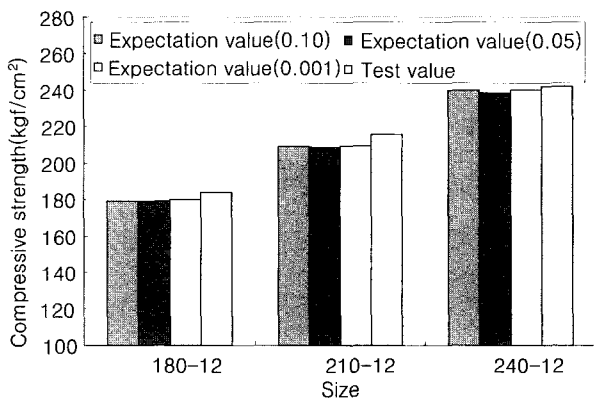


Fig. 8 Compressive strength(A company)




Fig. 10 Compressive strength(B company)




Fig. 9 Value of slump(A company)




Fig. 11 Value of slump(B company)

본 연구는 레미콘에서 물성이 다른 배합요소를 사용하여 배합설계를 실시한 후 직접 실험하였고 또한 신경망 이론을 이용하여 자료들을 학습시켜 배합요소, 압축강도 및 슬럼프값을 추정하여 다음과 같은 결론을 얻었다.

1) 신경망 학습에 필요한 배합요소를 물-시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량, 압축강도, 슬럼프값을 입력층으로 하여 출력층인 배합요소 및 압축강도, 슬럼프값을 추정할 수가 있었다.

2) 배합요소를 추정할 경우 목표 오차량의 감소에 따라 학습에 걸리는 시간이 현저히 늘어남을 알 수 있었다.

3) 배합요소의 추정값으로 물-시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량은 A, B사 모두 목표 오차량 0.10, 0.05에서 배합요소별 다소 차이는 있으나 시방배합표와 거의 비슷한 값을 얻을 수 있었다.

4) 압축강도의 추정값은 A, B사 모두 목표 오차량을 줄 경우 시방배합표의 규격에 양호하게 수렴하였다.

5) 슬럼프의 추정값은 목표 오차량 0.10인 경우 규격 180-12에서 최대 오차량이 3.75%가 발생하였으나 목표오차량 0.001에서는 0.75%로 안정된 값으로 나타났다.

1. 建設部 제정, 콘크리트표준시방서, 대한토목학회, 1996.
2. McCulloch, W. and Pitts, W., "A Logical Calaulus of the Ideas Immanent," *Bulletin of Mathematical Biophysiss* 5, pp.115~133, 1943.
3. Hopfield, J. J., "Neurons With Graded Response Have Collective Computational Croperties Like Those of Two-state Neurons," *Proc. of the National Academy Science* 81, pp.3088-3092, 1984.
4. Webos, P. J., "Generalization of Back Pro- pagation with Application to Recurrent Gas Market Model," *Neural Network*, Vol. 1, pp.339~356, 1988.
5. Rumehart, D. E., Hinton, G. E., and Willams, R. J., "Learning Internal Representation by Error Propagation in Parallel Distributed Processing," The MIT Press, Vol. 1, 1986.
6. Rosenblatt, "A theory of Statistical Separability in Cognitive System," Buffalo, Cornell Aeronautic Lab. Inc, Rep. No. VG-1196-G-1, 1958.
7. Zadeh, L. A., "Fuzzy Sets," *Information and Control*, 8, pp.33~353, 1965.
8. Barai, S. V. and Pandey, P. C., "Vibration Signature Analysis Using Artificial Neural Networks," Vol. 9, No.4.
9. 정환진, "신경망을 이용한 구조물의 손상평가," 석사학위논문, 한국과학기술원, 1996.

요 약

현대사회에서 건설전반에 보편화되어 있는 레미콘은 다양한 사용재료의 물리·화학적 성분이 생산지 및 조성광물에 따라 다르므로 구해지는 결과값 또한 무수한 변수가 있기 마련이다. 또한 콘크리트의 배합설계는 배합요소의 다변화로 인해 정확한 검정은 그리 간단하지가 않다.신경망의 학습에 소요되는 시간은 컴퓨터의 성능 및 학습횟수(epoch)에 따라 다르고, 학습시 학습횟수를 최고 백만번까지 반복하도록 하였으며 학습 종료조건으로 최소자승법에 의해 목표 오차량이 0.10~0.001 사이가 될 때까지 하였다. 신경망의 적용에는 현재 경북지방에 위치한 레미콘 회사중 A, B사에서 사용하는 콘크리트 시방배합표를 가지고 신경망 이론에 따라 학습시킨 후에 물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량을 추정하였고, 다음으로 압축강도 및 슬럼프값을 각각 추정하였다.

배합요소 추정의 검정에 사용된 규격으로는 호칭강도 180~300 kgf/cm², 목표슬럼프값 8cm, 15cm를 사용하였고, 압축강도 및 슬럼프값 추정에 사용된 규격으로는 회사별 최근 생산량이 가장 많은 호칭강도 210~240 kgf/cm², 목표 슬럼프값 12, 15 cm를 각각 사용하였다. 본 논문에서는 컴퓨터에 의한 학습 및 시뮬레이션을 통해 콘크리트의 배합요소, 압축강도 및 슬럼프값을 추정하여 직접 실험값과 비교함으로써 실험을 통하지 않고도 콘크리트의 배합요소 및 강도를 추정하는데 목적이 있다. 결과적으로 압축강도 및 슬럼프의 추정은 회사에 관계없이 오차량에 만족하여 수렴하는 것으로 나타나 인공신경망이론이 압축강도 및 슬럼프를 예측하는데 효율적인 것으로 판명되었다.

핵심내용 : 네트워크, 압축강도, 슬럼프, 물-시멘트 비, 잔골재율