

콘크리트의 배합설계에 있어서 신경망의 이용

Use of Neural Networks on Concrete Mix Design



오주원*

Oh, Ju-Won



이종원**

Lee, Jong-Hun



이인원***

Lee, In-Won

요 약

콘크리트의 배합설계를 위해서는 각종 콘크리트 표준 시방서의 내용에 대하여 잘 알아야 할 뿐 아니라 현장 경험이 많은 전문가의 경험을 필요로 한다. 그러나 배합 설계에 관련된 모든 인자들과 그 인자들간의 상호작용에 대하여 모두 고려할 수는 없다. 따라서 적절한 배합설계에 관한 판단은 품질관리를 위한 재료시험을 통하여 판단할 수 밖에 없고 그 결과에 따라 보정하는 과정을 거치게 된다. 이렇듯 콘크리트의 배합설계는 재료, 온도, 현장조건, 기술자의 숙련도 등에 대하여 불확실성이 존재하고 계산과 시험과정에 존재하는 오차로 인하여 엄격한 품질관리를 하여야만 하기 때문에 자칫 지루하며 복잡하고 힘든 일이 될 수밖에 없다.

본 연구에서는 이렇듯 콘크리트의 배합설계 과정에서 나타나는 피할 수 없는 불확실성과 오차들을 최소화 하기 위하여 신경망을 적용하였다. 신경망의 학습과 검증을 위한 자료는 콘크리트 표준시방서에 따라 설계기준 강도, 굵은골재 최대치수, 슬럼프, 골재의 조립율 등을 변화시켜 가면서 이론적으로 물-시멘트비, 잔골재율, 단위 수량, 단위 시멘트량, 단위 잔골재량, 단위 굵은골재량 등을 구하여 사용하였다. 특히 콘크리트의 실제강도는 동일한 조건하에서 강도시험을 실시하여도 결과가 서로 다르게 나타나는 확율변수인 짐도 고려하였다. 콘크리트의 배합설계에 신경망을 적용한 결과는 그 적용성이 매우 컸다.

* 정희원, 한남대학교 공과대학 토목환경공학과 교수

** 정희원, 경일대학교 공과대학 토목공학과 교수

*** 정희원, 한국과학기술원 토목공학과 교수

• 본 논문에 대한 토의를 1997년 6월 30일까지 학회로 보내주시면 1997년 8월호에 토의회답을 게재하겠습니다.

Abstract

In concrete mix design we need the informations of the codes, the specifications, and the experiences of experts. However we can't consider all factors regarding concrete mix design. The final acceptance depends on concrete quality control test results. In this process, we meet the uncertainties of materials, temperature, site environmental situations, personal skillfulness, and errors in calculations and testing process. Then the mix design adjustments must be made. Concrete mix design and adjustments are somewhat complicated, time-consuming, and uncertain tasks.

In this paper, as a tool to minimize the uncertainties and errors the neural network is applied to the concrete mix design. Input data to train and test the neural network are obtained numerically from the results of design following the concrete standard specifications of Korea. The 28-days compressive strengths which are variate according to the uncertainties and errors are considered. The results show that neural networks have a strong potential as a tool for concrete mix design.

Keywords : concrete mix design, neural networks, backpropagation, mix proportioning

1. 서 론

콘크리트의 배합이란 콘크리트를 만들 때 소요되는 각 재료의 비율 또는 사용량을 말하며 배합설계란 경제성과 시방서의 요구조건을 균형있게 만족시키는 배합의 선택과정을 말한다. 배합설계시 고려해야 되는 소요강도, 내구성, 수밀성, 위커밸리티, 물-시멘트비, 굳은골재 최대치수, 슬립프, 잔골재율 등에 대한 대개의 배합원칙들은 우리나라의 경우 건설교통부 제정 콘크리트 표준시방서¹⁾의 시공편에 나타나 있으며 미국의 경우에는 ACI manual 211(1989)^{2),3)}, 영국의 경우에는 CP110(1972)⁴⁾에 나타나 있다. 그러나 콘크리트 표준시방서의 규정은 콘크리트 배합설계에 관한 모든 문제를 해결해 주지는 못한다. 콘크리트 배합에 영향을 미치는 요소들의 수가 많을 뿐 아니라 그 요소들간의 상호작용에 의한 영향들을 정확하게 규명하여 수학적 모델을 만들어 내는 것은 거의 불가능하기 때문이다. 따라서 실제 배합설계시에는 한 번에 설계를 끝낼 수 없고, 시험이나 많은 연구결과로 부터 얻어진 정보, 경험많은 숙련된 전문가의

판단 등에 의하여 보정하는 경우가 대부분이다. 그러나 이러한 보정을 거친 시험결과도 오차를 포함하는 불확정량으로 통계적 자료에 지나지 않는다.

합리적인 배합설계의 계산과 보정은 자칫 복잡하고 지루한 일로 치부되어 소홀하기 쉽고 또 항상 숙련된 전문가의 확보도 어렵기 때문에 때로는 전문가시스템을 구축하여 설계자를 돋고자 하는 연구와 노력이 있기도 하였다^{5),6),7),8),9)}. 그러나 여전히 각 재료, 시험환경, 시공환경 등의 불확실성과 설계의 전 과정에서 발생하는 인적, 물적, 기계적 오차 등을 피할 수 없고 그 영향도 크다. 본 연구에서는 이러한 콘크리트의 배합설계가 가지고 있는 불확실성과 오차 등을 보다 합리적으로 최소화할 수 있는 설계도구로서 신경망의 적용가능성을 파악한다. 특히 이론적인 소요강도 뿐만이 아니라 현장에서 시험을 통하여 얻어지는 최종적인 콘크리트 압축강도가 이론적인 소요강도와 일치하지 않는 통계량인 점을 고려하여 불확실성이 큰 현장여건에서도 콘크리트 배합설계에 신경망의 적용가능성을 파악하기 위한 목적으로 연구를 수행하였다.

2. 신경망

신경망은 인간두뇌의 구조와 작용에 관한 연구로부터 비롯되었다. 자극과 반응의 정보처리과정의 한 단위인 개별 뉴런(neuron)에 관한 기본 모형이 1943년 Warren McCulloch와 Walter Pitts⁽⁸⁾에 의하여 개발되었으며 현재도 대다수 인공신경망의 중심을 이루고 있다. 그 뒤 1962년 Rosenblatt⁽⁹⁾에 의하여 단순 2개층의 망이긴 하지만 학습할 수 있는 망이 개발되었다. 그리하여 부정확하고 불완전한 자료(자극)에 대해서도 거의 정확한 판단(반응)을 할 수 있으며 어느정도 제한적이긴 하나 일반화 시킬 수 있게 되었다.

물론 학습초기에는 뉴런간의 연결강도가 아직 충분히 학습되지 않아 미숙한 값들을 가지므로 신경망의 최종반응(계산값)은 기대(기대값)와 차이가 많다. 이러한 계산값과 기대값과의 차이가 오차가 되며 학습이 점점 진행되어 감에 따라 이 오차는 줄어들어 어느 오차한도 이내로 수렴하게 되면 학습은 완료하게 된다.

신경망에서는 뉴런과 그 연결의 수, 학습형태, 변환함수의 종류등이 모두 변수가 되므로 신경망의 종류는 매우 많아서 정확히 그 수를 파악할 수 없을 정도다. Rumelhart(1986)⁽¹⁰⁾등에 의하면 잘 알려진 신경망으로는 competitive learning⁽¹¹⁾⁽¹²⁾, the Boltzman machine⁽¹³⁾, the Hopfield network⁽¹⁴⁾, the Kohonen network⁽¹⁵⁾, the back-propagation network⁽¹⁶⁾등이 있다. 본 연구에서는 the back-propagation network(역전파 신경망)을 이용한다.

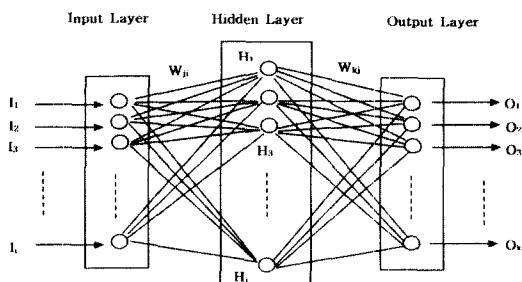


Fig. 1 A simple neural network

간단한 신경망의 기본구조는 그림 1에서 보는 바와 같고 역전파 신경망의 계산 및 학습과정을 살펴보면 다음과 같다.

(1) 신경망의 입력값이 입력층(input layer)에 있는 뉴런들의 활성값이 된다.

(2) 은익층(hidden layer)의 활성값 H_i 를 구하면

$$N_i = \sum W_{ji} I_j$$

$$H_i = F(N_i + B_i)$$

여기서,

I_j : the input values

W_{ji} : the weights or
the connection strengths

F : the activation function
(대개 sigmoid function)

B_i : the biases

(3) 출력층(output layer)의 활성값 O_k 는 다음과 같으며 신경망의 출력값이 된다.

$$O_k = F(\sum W_{kj} H_j + B_k)$$

(4) 역전파 신경망에서는 GDR(generalized delta rule)에 따라 학습이 이루어진다. 목표값의 벡터를 T 라 하면 오차 벡터 E 는 다음과 같이 정의한다.

$$E = \frac{1}{2} \sum_{k=1}^n (O_k - T_k)^2$$

이 오차가 최소가 되도록 출력층 뉴런들로 부터 역방향으로 가중치(weights)를 수정해 간다. 이 가중치들의 수정값들은

$$\Delta W_{kj} = \eta \delta_k H_j \quad \text{and} \quad \Delta B_k = \eta \delta_k$$

$$\text{Where } \delta_k = (T_k - O_k) f'(N_k)$$

$$\Delta W_{ji} = \eta \delta_j I_i \quad \text{and} \quad \Delta B_j = \eta \delta_j$$

$$\text{Where } \delta_j = (W_{kj} \delta_k) f'(N_j)$$

δ_j = gradient of the total error

η = the learning rate

(5) 가중치들의 수정이 끝나면 신경망은 다시 처음부터 계산과 가중치 수정의 과정을 계속 되풀이 하여 오차의 제곱값을 모두 합한 총계(sum squared error, sse)가 어느 한계값 이내로 수렴하면 학습을 끝낸다. 이때 계산을 시작하여 가중치들의 오차수정이 이루어지는 되풀이 과정 중 한 과정을 epoch라 한다.

3. 콘크리트의 배합설계

건설교통부제정 콘크리트 표준시방서(1996)에 따르면 시방배합은 그림 2와 같은 과정을 통하여 계산되고 보정된다.

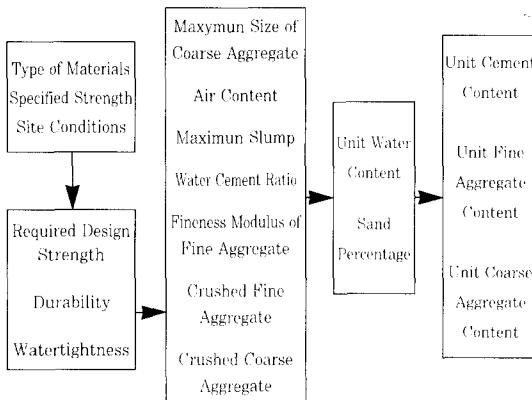


Fig. 2 A process of concrete mix design

그러나 그 계산과정과 보정과정은 각 인자들의 상호작용이 너무 복잡하고 인적, 물적, 환경적 요인에 따른 필연적 오차들로 인하여 정형화된 공식이 존재하는 것이 아니라 그간의 많은 시험과 경험을 토대로 한 대체적 원칙에 따르고 있으며 그것 조차도 직접시험을 통하여 계속 보정하면서 설계하도록 되어있다.

본 연구에서는 보통 포틀랜트 시멘트를 사용하며 시멘트의 비중 3.16, 잔골재의 비중 2.60, 굽은골재의 비중 2.65, 공기량 4%로 가정하고 소요강도는 현장의 예상변동계수에 따른 증가계수를 고려한 배합강도를 취하여 그림 2의 과정에 따라 배합강도, 굽은골재 최대치수, 슬럼프, 모래의 조립률 등을 변화시켜 가면서 물-시멘트 비, 잔골재율, 단위 수량, 단위 시멘트량, 단위 잔골재량, 단위 굽은골재량 등을 구하는 전산프로그램을 작성하여 195조의 자료들을 얻었으며 그 일부를 표 1에 나타내었다. 이를 자료중 고르게 분포되도록 임의로 15조의 자료를 선택하여 신경망 학습시 그 결과에 대한 검증자료로 사용하고 나머지 180조의 자료는 학습자료로 사용하였다.

4. 신경망 학습 및 검증

Table 1 Some result samples of concrete mix design

(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
180	15	5.0	4.0	2.5	63.8	49.5	193	302	864	898
210	20	5.0	4.0	2.5	57.0	44.4	179	315	786	1003
240	25	5.0	4.0	2.5	51.6	40.6	167	323	729	1088
270	40	5.0	4.0	2.5	46.5	36.2	157	338	655	1177
300	15	7.5	4.0	2.5	42.1	45.2	192	456	732	906
330	20	7.5	4.0	2.5	38.5	40.7	179	466	670	995
180	40	7.5	4.0	2.5	63.8	39.6	167	262	731	1135
210	15	10.0	4.0	2.5	57.0	48.2	203	355	808	886
240	20	10.0	4.0	2.5	51.6	43.3	189	366	738	984
270	25	10.0	4.0	2.5	46.5	39.6	176	377	684	1065
300	40	10.0	4.0	2.5	42.1	35.3	166	394	614	1148
330	15	12.5	4.0	2.5	38.5	44.5	203	527	682	869
180	20	5.0	4.0	3.0	68.3	48.3	185	290	857	936
210	25	5.0	4.0	3.0	57.0	44.2	172	302	795	1025
240	40	5.0	4.0	3.0	51.6	39.7	162	315	720	1115
270	15	7.5	4.0	3.0	46.5	48.6	197	424	793	857
300	20	7.5	4.0	3.0	42.1	43.9	184	437	728	947
330	20	10.0	4.0	3.0	38.5	43.2	189	490	692	927

(1) required strength(kg/m^3)

(2) maximum size of coarse aggregate(mm)

(3) maximum slump(cm)

(4) air content(%)

(5) fineness modulus of fine aggregate

(6) water-cement ratio(%)

(7) sand percentage(%)

(8) unit water content(kg/m^3)

(9) unit cement content(kg/m^3)

(10) unit fine aggregate content(kg/m^3)

(11) unit coarse aggregate content(kg/m^3)

본 연구에서 콘크리트의 배합설계를 위하여 적용된 신경망의 구조는 다음과 같다.

입력층의 뉴런수는 6개로 배합강도, 굽은골재 최대치수, 슬럼프, 조립률, 물-시멘트비, 잔골재율 등이며, 출력층의 뉴런수는 4개로 단위 수량, 단위 시멘트량, 단위 잔골재량, 단위 굽은골재량 등이다. 그리하여 본 신경망은 배합강도와 여러 가지 고려해야 될 설계요소들의 특성이 파악되면 바로 각 재료의 단위 중량들이 구하여 질 수 있는 구조로 하였다. 한편 익층은 10개 뉴런을 가진 한 개 층으로 구성하였다.

이러한 신경망을 이용하여 표 2와 같은 4가지 경우에 대한 학습 및 검증을 수행하였다. 신경망 학습시 수렴의 기준은 오차의 제곱값의 총합(sse)이 오차의 목표치(error goal) 이하가 되도록 하였다. Case 1과 case 2 에서는 앞의 배합설계에서 얻은 195개조의 자료중 180개조의 자료를 신경망학습을 위하여 사용하였으며 나머지 15개조의 자료는 검증을 위하

여 사용하였다. 다만, error goal은 case 1에서는 0.01로 하였으며 case 2에서는 보다 오차를 줄이기 위하여 0.005로 취하여 비교하였다. 배합에 사용되는 소요강도는 배합설계에서 가정된 값을 그대로 사용하였다.

그러나 실제로 시험한 결과로 부터 얻어진 실제강도를 사용하고자 하는 경우에는 그 강도값이 소요강도와 꼭 일치하는 것이 아니고 소요강도를 중심으로 어느정도 분포하는 통계값을 가지게 될 것이다. 이러한 경우를 가정하여 case 3과 case 4에서는 시험결과 측정된 실제강도를 표 3과 같이 소요강도의 10%를 벗어나지 않는 범위에서 오차를 가지고 분포한다고 가정하여 그 범위내에서 임으로 배합강도들을 다르게 정하여 학습시키고 검증하였다. 다만 case 4의 경우에는 학습시킬 자료의 수를 192개조 더 증가시킨 372개조를 학습자료로 사용하여 학습자료 증가에 따른 영향을 고찰하였다.

Table 2 Cases of training and testing

cases	28-day compressive strengths	error goals	num. of learning date set	num. of testing date set
1	required	0.01	180	15
2	required	0.005	180	15
3	actual	0.01	180	15
4	actual	0.01	372	15

Table 3 Actual compressive strengths(kg/m²)

case 1,2	180	210	240	270	300	330
case 3,4	170	198	226	254	282	310
	-180	-219	-250	-281	-312	-343

학습결과를 요약하면 표 4 및 그림 3과 같다. 이들을 살펴보면 모든 경우에 콘크리트 배합설계에 적용된 신경망은 매우 만족스럽게 잘 수렴하였다. 일반적으로 수렴속도는 초기에는 빠르나 epoch가 증가할수록 급격하게 떨어진다. 따라서 case 1에 비하여 error goal이 2배로 강화된 case 2에서 epoch는 5배 정도로 증가하였다. 좀더 정밀한 결과를 얻으려면 그 계산량이 기하급수적으로 증가함을 알 수 있다. Case 1과 case 3을 비교하면 기대되는 소요강도 대신 시험결과로 부터 측정되는 실제강도를 이용하여 신경망을 학습하는 경우에는 계산량이 급격히 증가함을 알 수 있다. 또한 case 3과 case 4를 비교

할 때 입력자료의 수가 많으면 그 만큼 실제에 근접한 결과를 얻을 수 있을 것으로 예상되나 계산량이 많아짐을 알 수 있다.

Table 4 Results of training

cases	error goals	sse	epochs
1	0.01	0.0099998	27,265
2	0.005	0.0049999	157,808
3	0.01	0.0099993	234,428
4	0.01	0.0099999	340,375

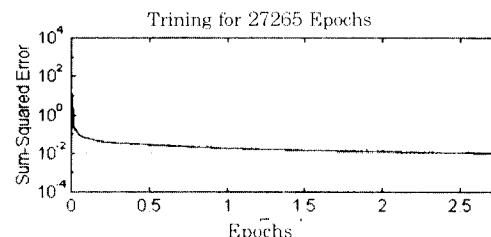


Fig. 3 Convergence curve in training

각 경우에 학습된 신경망을 검증하기 위하여 공히 앞에서 미리 선택한 15조의 자료를 이용하였으며 이들의 단위 재료량들에 대한 목표값은 표 5에서 보는 바와 같다. 이들을 이용하여 검증한 결과는 표 6에 나타내었다. 여기서 ()내는 오차를 표시하였으며 학습된 신경망을 이용하여 계산된 계산값과 목표값과의 차이를 목표값에 대한 백분율(%)로 나타낸 것이다.

이 백분율의 최소치와 최대치와의 범위를 표 7에

Table 5 Target values of testing sets

testing sets	target values			
	water	cement	send	gravel
1	185	481	719	916
2	156	370	631	1178
3	170	366	693	1079
4	189	366	738	984
5	209	366	796	873
6	177	278	716	1111
7	178	461	715	958
8	196	465	765	855
9	174	374	730	1025
10	193	373	773	932
11	212	372	830	824
12	181	284	755	1056
13	204	332	830	879
14	199	443	738	893
15	166	405	607	1146

나타내었다. case 1의 경우 오차는 0~1.3%로 0~1.1%인 case 2에 비해서도 만족스럽게 허용 가능한 오차수준을 나타내었으나 계산량은 훨씬 적었다. 따라서 어느정도의 목표오차를 만족시키게 되면 목표오차를 너무 강화시키는 것은 계산량의 증가에 비하여 오차는 큰 변동이 없기 때문에 오히려 바람직스럽지 못함을 알 수 있다.

case 3의 경우에도 오차는 0~1.7%로 나타났다.

Table 6 Calculated values and errors in testing
(a) case 1

testing sets	Calculated values			
	water	cement	send	gravel
1	187(1.1)	486(1.0)	724(0.7)	904(1.3)
2	156(0.0)	369(0.3)	631(0.0)	1177(0.1)
3	171(0.6)	368(0.5)	685(1.2)	1085(0.6)
4	187(1.1)	364(0.5)	737(0.1)	992(0.8)
5	210(0.5)	370(1.1)	739(0.4)	870(0.3)
6	179(1.1)	278(0.0)	720(0.6)	1102(0.8)
7	176(1.1)	459(0.4)	710(0.7)	969(1.1)
8	197(1.1)	466(0.2)	766(0.1)	852(1.3)
9	174(0.0)	375(0.3)	731(0.1)	1022(0.8)
10	192(0.5)	371(0.5)	779(0.8)	930(0.2)
11	211(0.5)	372(0.0)	823(0.8)	835(1.3)
12	180(0.6)	283(0.4)	751(0.5)	1063(0.7)
13	205(0.5)	333(0.3)	828(0.2)	877(0.2)
14	200(0.5)	445(0.5)	738(0.0)	889(0.4)
15	116(0.0)	406(0.2)	610(0.5)	1143(0.3)

* Numerical values in () indicate the percent of errors of calculated values with respect to the target values.

(b) case 2

testing sets	target values			
	water	cement	send	gravel
1	186(0.5)	482(0.4)	717(0.3)	914(0.2)
2	156(0.0)	371(0.3)	629(0.3)	1179(0.1)
3	171(0.6)	368(0.5)	691(0.3)	1078(0.1)
4	188(0.5)	364(0.5)	741(0.4)	985(0.1)
5	208(0.5)	364(0.5)	796(0.0)	875(0.2)
6	177(0.0)	278(0.0)	711(0.7)	1116(0.5)
7	176(1.1)	458(0.7)	714(0.1)	964(0.6)
8	197(0.5)	469(0.9)	761(0.5)	852(0.4)
9	174(0.0)	375(0.3)	729(0.1)	1024(0.1)
10	192(0.5)	371(0.5)	774(0.1)	935(0.3)
11	211(0.5)	372(0.0)	828(0.2)	828(0.5)
12	181(0.0)	284(0.0)	756(0.1)	1055(0.1)
13	204(0.0)	331(0.3)	830(0.0)	878(0.1)
14	199(0.0)	445(0.5)	738(0.0)	890(0.3)
15	166(0.0)	406(0.2)	609(0.3)	1144(0.3)

따라서 시험결과로 부터 얻어지면서 어떤 분포를 이루는 실제강도들의 자료를 이용하여 신경망을 학습시켜야 하는 실제적인 경우에도 매우 만족스러운 허용가능한 오차수준을 얻을 수 있었다. 또한 case 4의 경우 오차는 0~1.1%로 case 3과 비교할 때 자료수를 늘릴수록 오차수준은 더 만족스럽게 나타났다.

(c) case 3

testing sets	calculated values			
	water	cement	send	gravel
1	186(0.0)	482(1.0)	716(0.4)	918(0.2)
2	156(0.0)	365(1.4)	633(0.3)	1180(0.2)
3	172(1.2)	367(0.3)	691(0.3)	1077(0.2)
4	188(0.5)	363(0.8)	736(0.3)	991(0.7)
5	209(0.0)	368(0.5)	800(0.5)	865(0.9)
6	175(1.1)	280(0.7)	715(0.1)	1115(0.4)
7	175(1.7)	456(1.1)	715(0.0)	969(1.1)
8	196(0.0)	469(0.9)	763(0.3)	853(0.2)
9	176(1.1)	376(0.5)	732(0.3)	1017(0.8)
10	191(1.0)	369(1.1)	774(0.1)	938(0.6)
11	212(0.0)	376(1.1)	832(0.2)	819(0.6)
12	178(1.7)	287(1.1)	747(1.1)	1070(1.3)
13	206(1.0)	332(0.0)	830(0.0)	874(0.6)
14	199(0.0)	443(0.0)	736(0.3)	895(0.2)
15	165(0.6)	404(0.2)	604(0.5)	1153(0.5)

(d) case 4

testing sets	target values			
	water	cement	send	gravel
1	187(1.1)	486(1.0)	718(0.1)	910(0.7)
2	156(0.0)	367(0.8)	629(0.3)	1182(0.3)
3	171(0.6)	368(0.5)	690(0.4)	1080(0.1)
4	188(0.5)	365(0.3)	739(0.1)	987(0.3)
5	209(0.0)	366(0.0)	796(0.0)	872(0.1)
6	179(1.1)	277(0.4)	714(0.3)	1111(0.0)
7	176(1.1)	458(0.7)	713(0.3)	966(0.8)
8	197(0.5)	467(0.4)	764(0.1)	853(0.2)
9	175(0.6)	375(0.3)	730(0.0)	1022(0.3)
10	192(0.5)	370(0.8)	777(0.5)	933(0.1)
11	212(0.5)	372(0.0)	828(0.2)	827(0.4)
12	181(0.0)	285(0.4)	750(0.7)	1061(0.5)
13	204(0.0)	331(0.3)	828(0.2)	882(0.3)
14	200(0.5)	445(0.5)	738(0.0)	890(0.3)
15	165(0.6)	405(0.0)	608(0.2)	1146(0.1)

Table 7 Error ranges(%) in each cases

cases	1	2	3	4
rang(%)	0~1.3	0~1.1	0~1.7	0~1.1

5. 결론 및 제언

콘크리트 배합설계에 신경망을 적용하여 학습시키고 검증한 결과는 매우 적용 가능성이 컸다. 신경망의 학습시 진동현상등이 발생하지 않고 잘 수렴하였으며 검증결과도 오차가 0~1.7% 정도를 보여 허용오차 이내로 단위재료량들의 선택이 가능하였다. 앞으로 현장에서 시행되는 콘크리트 배합설계시 품질관리를 위하여 강도시험을 실시하는 바 그 결과를 모아 데이터 베이스화 하면 이 자료를 곧바로 신경망의 학습자료로 이용할 수 있으며 그 자료의 수가 많을수록 더욱 바람직하다.

감사의 글

본 연구는 한남대학교 교비연구비 지원에 의하여 이루어진 연구결과입니다. 이에 감사드립니다.

참 고 문 헌

1. 건설부, "콘크리트 표준시방서", 1996.
2. ACI 211.1-81 standard practice for selecting proportions for normal, heavyweight, and mass concrete, ACI manual of concrete practice, Part 1, 1989, American Concrete Institute, Detroit, Mich.
3. Mehta, P. K., and Monteiro, P. J. M., CONCRETE, Structure, Properties, and Materials, Prentice-Hall, Inc., New Jersey, 1993.
4. Neville, A. M., Properties of Concrete, Pitman Publishing, Inc., Marshfield, Mass, 1981.
5. Bai, Y., Amirkhanian, S. N. "Knowledge -Based Expert-System for Concrete Mix Design", Journal of Construction Engineering and Management, ASCE, 120(2), 1994, pp.357-373.
6. Celik, T., Thorpe, A., and McCaffer, R., "Development of an expert system", Concrete Int. Des. and Const., 11(8), 1989, pp.37-41.
7. Clifton, J. R., and Kaetzel, L. J., "Expert systems for concrete construction", Concrete Int. Des. and Const., 10(11), 1988, pp.19-24.
8. McCulloch, W. S., and Pitts, W. "A logical calculus of the ideas immanent in nervous activity", Bull. Math. Biophys., 5, 1943, pp.115-133.
9. Rosenblatt, F., Principles of neurodynamics, Spartan, New York, N.Y., 1962.
10. Rumelhart, D. E., McClelland, J. L., and the PDP Research Group, Parallel distributed processing - Volume 1 : Foundations, MIT Press, Cambridge, Mass, 1986.
11. Grossberg, S., "Adaptive pattern classification and universal recording : Part 1. Parallel development and coding of natural features detectors", Biol. Cybernet., 23, 1976, pp. 121-134.
12. Rumelhart, D. E., and Zipser, D., "Feature discovery by competitive learning", Cognitive Sci., 9, 1985, pp. 75-112.
13. Hinton, G. E., Sejnowski, T. J., and Ackley, D. H., "Boltzman machines : Constraint satisfaction networks that learn", Tech. Rep. No. CMU-CS-84-119, Department of Computer Science, Carnegie Mellon University, Pittsburgh, Pa., 1984.
14. Hopfield, J. J., "Neural Networks and physical systems with emergent collective computational abilities", Proc. Nat. Acad. Sci., 79, 1982, pp. 2554-2558.
15. Kohonen, T., Self-organization and associative memory, Springer-Verlag, Berlin, West Germany, 1984.
16. Rumelhart, D. E., Hinton, G. E., and Williams, R. J., "Learning internal representations by error propagation", Parallel distributed processing, Vol. 1 : Foundations, D. E. Rumelhart and J. L. McClelland, eds., the MIT Press, Cambridge, Mass, 1986.

(접수 일자 : 1997. 1. 22)