

# 신경망을 이용한 콘크리트의 배합설계

## Concrete Mix Design using Neural Networks

오주원\*

Oh, Ju Won

### Abstract

Concrete mix design and adjustments are somewhat complicated and time-consuming tasks in which various uncertainties and errors are involved and depend on the quality control test results. 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 from the results of design and adjustments following the concrete standard specifications of Korea. The results show that neural networks have a strong potential as a tool for concrete mix design.

### 1. 서 론

콘크리트 배합이란 콘크리를 만들 때 소요되는 각 재료의 비율 또는 사용량을 말하며 배합설계란 경제성과 시방서의 요구조건을 균형있게 만족시키는 배합의 선택과정을 말한다. 배합설계시 고려해야 되는 소요강도, 내구성, 수밀성, 위커빌리티, 물-시멘트 비, 굽은골재 최대치수, 슬립프, 잔골재율 등에 대한 대개의 배합원칙들은 건설교통부 제정 콘크리트 표준시방서의 시공편에 나타나 있다. 그러나 콘크리트 표준시방서의 규정은 콘크리트 배합설계에 관한 모든 문제를 해결해 주지는 못한다. 콘크리트 배합에 영향을 미치는 요소들의 수가 많을 뿐 아니라 그 요소들 간의 상호작용에 의한 영향들을 정확하게 규명하여 수학적 모델을 만들어 내는 것은 거의 불가능하기 때문이다. 따라서 실제 배합설계시에는 한 번에 설계를 끝낼 수 없고, 시험이나 많은 연구 결과로부터 얻어진 정보, 경험 많은 숙련된 전문가의 판단등에 의하여 보정하는 경우가 대부분이다. 그러나 이러한 보정을 거친 시험결과도 오차를 포

\* 정회원, 한남대 토목공학과 교수

함하는 불확정량으로 통계적 자료에 지나지 않는다.

합리적인 배합설계의 계산과 보정은 자칫 복잡하고 지루한 일로 치부되어 소홀하기 쉽고 또 항상 숙련된 전문가의 확보도 어렵기 때문에 때로는 전문가 시스템을 구축하여 설계자를 돋고자하는 노력이 있기도하다.<sup>(1)(2)(3)</sup> 그러나 여전히 각재료, 시험환경, 시공환경 등의 불확실성과 설계의 전 과정에서 발생하는 인적, 물적, 기계적 오차등을 피할 수 없고 그 영향도 크다. 본 연구에서는 이러한 콘크리트의 배합설계가 가지고 있는 불확실성과 오차등을 보다 합리적으로 최소화할 수 있는 설계도구로서 신경망의 적용가능성을 파악한다.

## 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<sup>(4)</sup>에 의하여 개발되었으며 현재도 대다수 인공신경망의 중심을 이루고 있다. 그 뒤 1962년 Rosenblatt<sup>(5)</sup>에 의하여 단순 2개층의 망이긴 하지만 학습할 수 있는 망이 개발 되었다. 그리하여 부정확하고 불완전한 자료(자극)에 대해서도 거의 정확한 판단(반응)을 할 수 있으며 어느정도 제한적이긴 하나 일반화 시킬 수 있게 되었다.

신경망에서는 뉴런과 그 연결의 수, 학습형태, 변환함수의 종류등이 모두 변수가 되므로 신경망의 종류는 매우 많아서 정확히 그 수를 파악할 수 없을 정도다. Rumelhart(1986) 등<sup>(6)</sup>에 의하면 잘 알려진 신경망으로는 competitive learning<sup>(7)(8)</sup>, the Boltzman machine, the Hopfield network, the Kohonen network, the back-propagation network<sup>(9)</sup> 등이 있다. 본 연구에서는 the back-propagation network(역전파 신경망)을 이용한다.

간단한 신경망의 기본구조는 그림1에서 보는바와 같고 역전파 신경망의 계산 및 학습과정은 the generalized delta rule에 따른다.

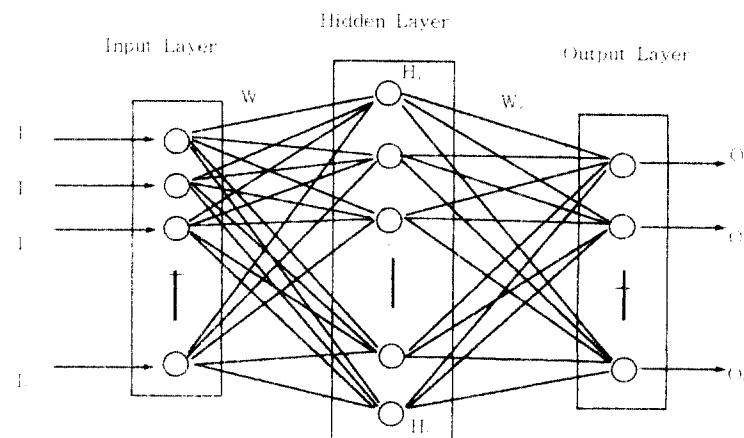


Fig. 1 A Simple Neural Network

Table 1 Some samples produced in 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
270	15	12.5	4.0	2.5	46.5	46.1	205	441	736	879
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( $\text{kg}/\text{m}^3$ )

(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( $\text{kg}/\text{m}^3$ )(9) : unit cement content( $\text{kg}/\text{m}^3$ )(10) : unit fine aggregate content( $\text{kg}/\text{m}^3$ )(11) : unit coarse aggregate content( $\text{kg}/\text{m}^3$ )

### 3. 콘크리트의 배합설계

본 연구에서는 건설교통부제정 콘크리트 표준시방서(1996)에 따라 배합설계가 계산되고 보정된다.

보통 포틀랜트 시멘트, 콘크리트의 비중 3.16, 잔골재의 비중 2.60, 굵은골재의 비중 2.65, 공기량 4%로 가정하고 소요강도는 현장의 예상변동계수에 따른 증가계수를 고려한 배합강도를 취하여 배합강도, 굵은골재 최대치수, 슬럼프, 모래의 조립율 등을 변화시켜 가면서 물-시멘트비, 잔골재율, 단위수량, 단위 시멘트량, 단위 잔골재량, 단위 굵은골재량 등을 구하는 전산프로그램을 작성하여 192조의 자료들을 얻었으며 그 일부를 표 1에 나타내었다.

### 4. 신경망 학습 및 검증

본 연구에서 콘크리트의 배합설계를 위하여 적용된 신경망의 구조는 다음과 같다.

입력층의 뉴런수는 6개로 배합 강도, 굵은골재 최대치수, 슬럼프, 조립률, 물-시멘트비, 잔골재율 등이며, 출력층의 뉴런수는 4개로 단위수량, 단위시멘트량, 단위잔골재량, 단위굵은골재량 등이다. 그리하여 본 신경망은 배합강도와 여러 가지 고려해야 될 설계요소들의 특성이 파악되면 바로 각 재료의 단위중량들이 구하여 질 수 있는 구조로 하였다.

한편 은익층은 10개 뉴런을 가진 한 개 층으로 구성하였다.

이러한 신경망을 이용하여 표 2와 표 3과 같은 4 가지 경우에 대한 학습 및 검증을 수행하였다.

학습결과를 요약하면 표 4 및 그림 2과 같다.

각 경우에 학습된 신경망을 검증하기 위하여 공히 앞에서 미리 선택한 12 조의 자료를 이용하였으며 이들의 단위 재료량들에 대한 목표값은 표 5에서 보는 바와 같다. 이들을 이용하여 검증한 결과는 표 6에 나타내었다.

## 5. 결론 및 제언

콘크리트 배합설계에 신경망을 적용하여 학습시키고 검증한 결과는 매우 적용 가능성이 컸다. 신경망의 학습시진동현상등이 발생하지 않고 잘 수렴하였으며 검증결과도 오차가 0 ~ 1.7%정도를 보여 허용 오차 이내로 단위재료량들의 선택이 가능하였다. 앞으로 현장에서 시행되는 콘크리트 배합설계시 품질 관리를 위하여 강도시험을 실시하는바 그 결과를 모아 데이터 베이스화 하면 이 자료를 곧바로 신경망의 학습자료로 이용할 수

Table 2 Cases Of learning and testing

cases	28-day compressive strengths	error goals	num. of learning data set	num. of testing data set
1	required	0.01	180	12
2	required	0.005	180	12
3	actual	0.01	180	12
4	actual	0.01	372	12

Table 3 28-day compressive strength(kg/cm<sup>2</sup>)

case1,2	180	210	240	270	300	330
case3,4	170	198	226	254	282	310
-	188	219	250	281	312	343

Table 4 Convergence in learning

cases	error goals	sse	epochs
1	0.01	0.00999998	27,264
2	0.005	0.00499999	157,808
3	0.01	0.00999993	234,428
4	0.01	0.00999999	340,375

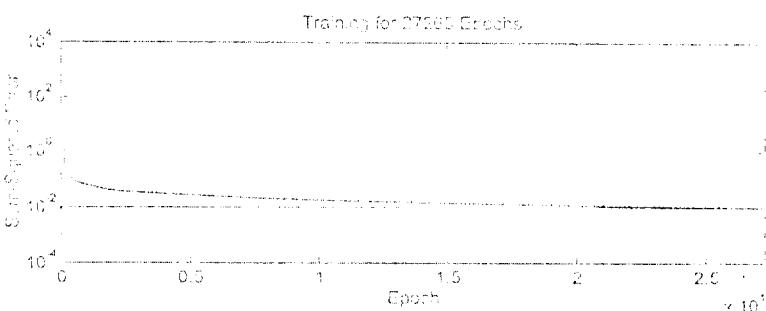


Fig.2 Convergence curve in learning

Table 5 target values in testing sets

testing sets	target values			
	water	cement	sand	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	171	374	730	1025
10	193	373	773	932
11	212	372	830	824
12	181	283	755	1056

있으며 그 자료수가 많을  
수록 더욱 바람직하다.

## 감사의 글

본 연구는 한남대학교  
교비연구비 지원에 의하여  
이루어진 결과의 일부입니다.  
이에 감사 드립니다.

## ● 참고문헌 ●

- Bai,Y., Amirkhanian,S.N. (1994). "Knowledge-Based Expert-System for Concrete Mix Design." Journal of Construction Engineering and Management, ASCE, 120(2), 357-373.
- Celik,T., Thorpe,A., and McCaffer,R. ( 1 9 8 9 ) . "Development of an expert system." Concrete Int. Des. and Const., 11(8), 37-41.
- Clifton,J.R., and Kaetzel,L.J., (1988). "Expert systems for concrete construction." Concrete Int. Des. and Const., 10(11), 19-24.

Table 6 Calculated values and errors in testing

(a) case 1

testing sets	calculated values			
	water	cement	sand	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)	793(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(0.5)	466(0.2)	766(0.1)	852(0.4)
9	174(0.0)	375(0.3)	731(0.1)	1022(0.3)
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)

(b) case 2

testing sets	calculated values			
	water	cement	sand	gravel
1	186(0.5)	483(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)

(c) case 3

testing sets	calculated values			
	water	cement	sand	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(0.0)	372(0.0)	828(0.2)	827(0.4)
12	181(0.0)	285(0.4)	750(0.7)	1061(0.5)

4. McCulloch,W.S., and Pitts,W. (1943). "A logical calculus of the ideas immanent in nervous activity." Bull.Math.Biophys., 5, 115-133.

5. Rosenblatt,F. (1962). Principles of neurodynamics. Spartan, New York, N.Y.

6. Rumelhart,D.E.,

McClelland,J.L., and the PDP Rearch Group. (1986). Parallel distributed processing -Volume 1 : Foundations. MIT Press, Cambridge, Mass.

7. Grossberg,S. (1976). "Adaptive pattern classification and universal recording : Part 1. Parallel development and coding of natural features detectors." Biolig. Cybernet., 23, 121-134.

8. Rumelhart,D.E., and Zipser,D. (1985). "Feature discovery by competitive learning." Cognitive Sci., 9, 75-112.

9. Ghaboussi,J., Garrett,Jr.J.H., Wu,X., (1991), "Knowledge-Based Modeling of Material Behavior with Neural Networks." J. Engrg. Mech., 117(1), 132-153.

(d) case 4

testing sets	calculated values			
	water	cement	sand	gravel
1	185(0.0)	486(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)

\* Numerical values in ( ) indicate the percentage of errors  
of calculated values with respect to the target values