

## 고성능 콘크리트의 활용을 위한 신경망의 적용

Applications of Artificial Neural Networks for  
Using High Performance Concrete

양 승 일\* / 윤 영 수\*\* / 이 승 훈\*\*\* / 김 규 동\*\*\*\*

Yang, Seung Il / Yoon, Young Soo / Lee, Seung Hoon / Kim, Gyu Dong

## Abstract

Concrete and steel are essential structural materials in the construction. But, concrete, different from steel, consists of many materials and is affected by many factors such as properties of materials, site environmental situations, and skill of constructors. Concrete have two kinds of properties, immediately knowing properties such as slump, air contents and time dependent one like strength. Therefore, concrete mixes depend on experiences of experts. However, at point of time using High Performance Concrete, new method is wanted because of more ingredients like mineral and chemical admixtures and lack of data. Artificial Neural Networks(ANN) are a mimic models of human brain to solve a complex nonlinear problem. They are powerful pattern recognizers and classifiers, also their computing abilities have been proven in the fields of prediction, estimation and pattern recognition. Here, among them, the back propagation network and radial basis function network are used. Compositions of high-performance concrete mixes are eight components(water, cement, fine aggregate, coarse aggregate, fly ash, silica fume, superplasticizer and air-entrainer). Compressive strength, slump, and air contents are measured. The results show that neural networks are proper tools to minimize the uncertainties of the design of concrete mixtures.

## 요 지

콘크리트와 철은 건설에서 필수적인 구조 재료이다. 그러나, 철과 달리 콘크리트는 하나의 재료가 아니라 많은 물질들로 구성된 복합재료이며, 구성 재료, 현장 환경, 그리고 기술자의 숙련도 등에 의해 많은 영향을 받는다.

그리고 유동성과 공기량 등 즉시 알 수 있는 물성도 있지만 강도나 내구성 같이 시간이 지나야 알 수 있는 특성도 존재하므로 콘크리트의 배합은 전문가의 경험에 많이 의존해 왔다. 하지만, 콘크리트도 고성능화 되는 시점에서 첨가 재료도 늘어나고 기존의 자료도 부족하기 때문에 새로운 기법이 필요한 때이다. 신경망은 복잡한 비선형 문제를 처리하는 인간의 두뇌를 모방한 모델로 패턴 인식 및 분류, 예측 등의 분야에서 많이 사용되고 있다. 여기서는 그 중에서 역전파 알고리즘과 광선형 기저

\* (주)한석엔지니어링 사원

\*\* 고려대학교 토목환경공학과 교수

\*\*\* 삼성물산(주) 건설부문 기술연구소 선임연구원

\*\*\*\* 삼성물산(주) 건설부문 기술연구소 선임연구원

함수망 모형이 사용되었다. 여덟가지 재료(물, 시멘트, 잔골재, 굵은 골재, 플라이 애쉬, 실리카 흙, 유동화제, 그리고 공기연행제)가 배합에 사용되었으며, 압축강도와 슬럼프, 공기량을 물성으로 사용하였다. 결과적으로 신경망은 고성능 콘크리트의 배합 및 물성 예측 등 활용에 유용하게 사용될 수 있음을 알 수 있었다.

## 1. 서론

콘크리트는 교량, 항만, 도로 등의 사회간접자본의 건설부터 개인주택 같은 작은 공사에까지 널리 사용되는 재료이다. 이처럼 흔한 재료지만 실제로 콘크리트는 물, 시멘트, 굵은 골재와 잔골재가 섞여서 이루어진 복합재료이다. 또한 요즘은 토목의 역할이 예전에 생각지 못했던 구조물의 거대화나 미관의 문제 등 단순한 기능성에서 벗어나 일반인들의 욕구를 충족시켜 주어야 하는 위치까지 이르게 되면서 고성능 콘크리트의 사용이 늘고 있다. 콘크리트의 배합시 시멘트, 골재, 물의 혼합과정은 많은 요소들에 의해 영향을 받으며, 또한 그 요소들이 서로 영향을 주기 때문에 콘크리트의 배합은 주로 경험에 의한 시험배합을 통해 행해졌다. 따라서, 콘크리트 배합은 복잡하고, 시간 소비적이며 불확실성을 갖는 작업이다. 고성능 콘크리트는 일반콘크리트보다 더 많은 혼화재료가 첨가되며, 첨가되는 재료가 늘어날수록 배합과정은 더욱 어려워진다. 특히, 국내에서는 아직 활발히 사용되고 있지 않고 있기 때문에 앞으로 증가할 수요를 위해서도 합리적인 고성능 콘크리트의 배합설계 방법이 필요하다. 게다가 이미 많은 콘크리트 구조물들

이 있기 때문에 기존 구조물의 안전한 사용을 위해서라도 배합을 포함한 여러 자료를 통한 정확한 물성 예측 방법 또한 있어야 한다. 신경망은 인간 두뇌를 모방하여 만든 모델로 패턴 인식 및 분류, 최적화, 예측 및 평가등에 널리 사용되고 있다. 신경망에 관한 연구는 1943년에 Warren S. McCulloch와 Walter H.Pitts에 의해 시작되었으며, 현재 많은 종류의 알고리즘이 개발되었고 다양한 분야에서 널리 사용되고 있다. 본 연구에서는 고성능 콘크리트의 배합 및 물성 예측을 위해 역전파 알고리즘(Back Propagation Algorithm)과 광선형 기저함수망(Radial Basis Function Network)가 사용되었으며, 각각에 대해 비교하였다. 신경망에 적용된 자료들은 배합 실험 조건들의 차이에 의한 편차의 영향을 최소화하기 위해 실험을 통해 얻은 결과를 사용하였다.

## 2. 신경망

신경망은 인간 두뇌의 생물학적 구조를 컴퓨터를 통해 모방한 시스템이다. 그림 2.1은 보통 M-P 뉴런이라 불리는 위에서 언급한 McCulloch와 Pitts에 의해 제안된 생물학적 뉴런의 단순한 수학적 모

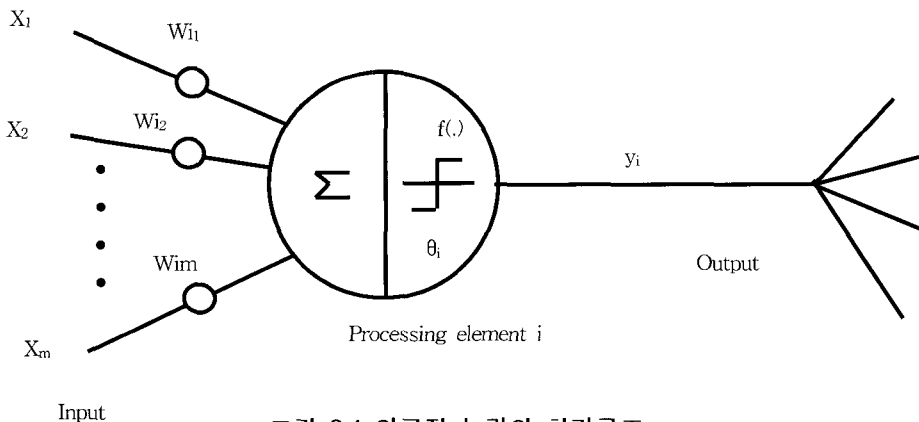


그림 2.1 인공적 뉴런의 처리구조

델을 보여준다. 이 인공적 뉴런은 수상돌기를 통해 전달받는 입력이 시냅스에서 연결강도의 변화를 겪는 것을 모의하기 위해서 가중치(weight)를 고려하였으며, 이들의 가중합을 세포체에서 해석하여 값을 축색돌기로 내보내는 형상을 보여주고 있다. 축색돌기를 통하여 전달하는 출력값을 모의하기 위해 전달함수(transfer function)가 사용된다. 이를 수학적으로 표현하면 다음과 같다

$$y_i(t+1) = f\left(\sum_{j=1}^m w_{ij} x_{j(t)} - \theta_i\right) \quad (2.1)$$

여기서  $x_i$ 는 입력값이고  $w_{ij}$ 는  $j$ 번째 뉴런에서  $i$ 번째 뉴런으로의 연결 강도를 나타내며,  $\theta_i$ 는 각 뉴런이 가지는 고유값이다. 또한  $f(\cdot)$ 는 전달함수이고  $y_i$ 는 뉴런에서의 출력값이다.

신경망은 뉴런과 그 연결방법, 사용하는 학습규칙, 전달함수 등에 따라 종류가 다양한데, 이 중에서 가장 많이 사용되는 것으로 역전과 알고리즘이 있다. 역전과 알고리즘은 목적함수의 최소화를 위해 고안된 최적화 기법으로 입력층과 출력층 사이에 하나 이상의 중간층(은닉층)으로 구성된 다층 네트워크이며, 미분의 반복규칙을 여러번 반복적으로 적용하여 확률 근사치 작업을 통해 유도할 수 있다. 그림 2.5은 주로 사용되는 전달함수인 sigmoid함수를 보여준다. 알고리즘은 적용은 입력값을 가중합을 통해 중간층의 결과값으로 변환한 후 출력층의 결과값을 도출하며 시작된다. 이후 출력층의 결과값과 실제값을 비교하여 그 오차를 다음과 같은 식으로 계산한다.

$$E_i = \frac{1}{2} \sum_k (t_k - o_k)^2 \quad (2.2)$$

여기서  $t$ 는 실제값이고,  $o$ 는 알고리즘을 통해 나온 출력층의 결과값이다. 그리고 이 오차를 최소화하도록 델타 규칙을 이용하여 가중치를 수정하는 작업을 수행한다. 델타규칙을 통한 가중치의 수정은 다음 식과 같다.

$$w_{ji}^{N+1} = w_{ji}^N + \Delta w_{ji}^N \quad (2.3)$$

$$\Delta w_{ji}^N = \eta \delta \frac{dw_{ji}}{d} \quad (2.4)$$

$\eta$ 는 알고리즘의 학습율이며, 이러한 작업은 가중치가 수렴하거나 오차의 제곱이 목표하는 만큼 감소할 때까지 계속된다.

광선형 기저함수망(Radial Basis Function Network)는 역전과 알고리즘과 비슷한 시기에 개발되었지만, 아직 널리 사용되지는 않고 있다. 구조는 그림에서 보는 것과 같이 역전과 알고리즘과 같은 다층구조이지만, 그 구조와 기능은 차이를 보인다. 우선 구조적으로 중간층이 지역적인 사영을 나타내고, 이 층은 광선형 기저함수 뉴런들을 포함하며, 전달함수로는 가우스 분포를 사용한다. 전역적인 사영을 하는 역전과 알고리즘의 경우 모든 입력이 하나의 출력을 나타내도록 하는데 반해, 지역적인 사영은 기저함수가 근처의 입력값에만 반응을 하게 된다. 이로 인해 입력값이 훈련집단의 근처에 있거나 훈련되지 않는 영역에 있음을 인지할 수 있으므로 훈련영역 외의 값이 있을 경우 부적절한 값을 출력하여 신뢰할 수 있는가를 파악할 수 있도록 한다. 또한 지역적인 사영을 하면, 훈련 및 학습 시간을 단축할 수 있는 장점이 있다. 그러므로, 안정성을 추구하는 문제나 경제적인 측면이 요구되는 문제에 유용하다. 광선형 기저함수망은 최소자승법을 사용하여 오차를 줄이며 그 식은 다음과 같다.

$$\begin{aligned} H &= d_1^2 + d_2^2 + \dots + d_n^2 = \sum_{i=1}^n d_i^2 \\ &= \sum (y_i - f(x_i))^2 = \min. \end{aligned} \quad (2.5)$$

### 3. Data Preprocessing

몇 종류의 전달 함수는 한정된 범위로 출력값을 생산하고(예를 들면, logsigmoid 함수의 경우 0에서 1) 함수는 중심에서 가까운 지역에서 기울기가 급격한 반면 멀어질수록 기울기가 작아진다. 그러므로, 좀 더 정확한 결과를 얻기 위해 신경망을 훈련시키기 전에 자료(입력과 출력 모두)를 전처리해야 한다. 현재 다양한 방법이 쓰이고 있지만, 본 연구에서는 간단한 두 종류의 전처리 방법을 사용하며 비교한다. 다음 표현은 자료의 일반화를 위해 사용된다.

$$X_{nor} = \frac{X_{act}}{X_{max}} \quad (3.1)$$




그림 2.2 역전파 알고리즘의 구조




그림 2.3 Radial Basis Function Network의 구조

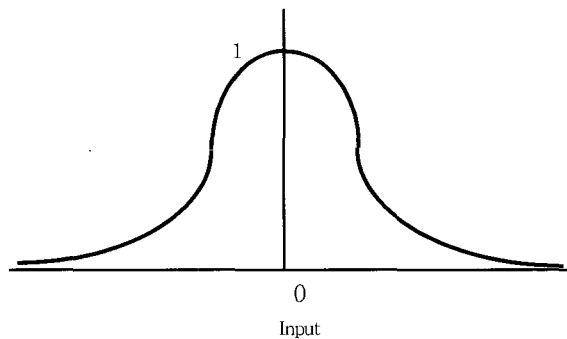


그림 2.4 광선형 기저함수(Radial Basis Function)의 그래프




그림 2.5 Sigmoid함수의 종류

$$X_{nor} = \frac{X_{act} - X_{min}}{X_{max} - X_{min}} \quad (3.2)$$

여기서,  $x_{nor}$  = 일반화된 입력값  
 $x_{act}$  = 실제 입력값  
 $x_{max}$  = 입력값 중 최대값  
 $x_{min}$  = 입력값 중 최소값

출력값도 위와 같이 일반화를 시키며, 식 (3.1)을 data-max, 식 (3.2)를 data-min이라 사용한다.

#### 4. 적용

##### 4.1 Back-propagation Algorithm(BP)의 적용

본 연구에서, 고성능 콘크리트에 대한 신경망의 적용은 두 단계로 나누어진다. 첫 단계는 플라이 애쉬를 첨가한 배합에 대한 적용이다. 콘크리트 배합은 108배치로 각 배치당 3단계의 유동화제 첨가량을 가진다. 그러므로, 324개의 배합 자료가 사용되었으며, 이는 316개의 훈련자료와 6개의 시험자료로 분류된다. 그것은 각기 7개의 재료요소(물, 시멘트, 플라이 애쉬, 잔골재, 굵은골재, 유동화제, 그리고 공기 연행제)와 3개의 물성요소(압축강도, 슬럼프, 그리고 공기량)로 구성되며 배합을 구할 때는 물성이 입력요소, 재료가 출력요소이며, 물성 예측에는 재료가 입력요소, 물성이 출력요소로 적용된다. 훈련은 1000번 학습에 대해 은닉층의 뉴런 개수와 학습율, 그리고 모멘텀 계수를 변화시키며 수행되었다.

신경망의 두 번째 적용은 실리카 흙을 첨가한 배합에 대해 시행되었다. 81배치의 배합 자료가 실험을 통해 얻어졌다. 훈련 자료는 76개이고, 5개의

배합이 시험을 위해 사용되었다. 그것들은 9개의 변수, 6개의 재료요소(시멘트, 물, 실리카 흙, 잔골재, 굵은 골재, 그리고 유동화제)와 3개의 물성요소(압축강도, 슬럼프, 그리고 시멘트),를 가진다.

단위량의 예측은 실제값과 다소 차이를 보였고, 그 중에서 혼화제료가 좀 더 큰 오차를 보였다. 플라이 애쉬가 첨가된 배합의 경우 물이 가장 적은 3~4%의 오차를 보였고 굵은 골재도 4% 정도의 오차를 보이고 있으며 그 뒤를 시멘트와 잔골재가 약 8%의 정도의 오차를 나타냈다. 하지만, 혼화재료의 경우는 심한 경우 수십 %까지 차이가 있음을 알 수 있다. 이것은 다른 재료에 비해 상대적으로 적은 양이 들어가기 때문에 작은 차이에도 큰 오차를 보이는 것으로 생각된다. 실리카 흙이 들어간 배합은 좀 더 정확한 값을 보이는데 가장 정확한 수량의 경우 평균 2%대의 오차가 있었으며 나머지 재료들도 상대적으로 정확하게 예측하였다. 또 하나 특이한 것은 물/결합재의 비를 살펴보면 각각의 재료의 오차가 서로 보완되어서 대체로 유지되는 모습을 보였다. 예를 들어, 시멘트량이 감소하면 단위수량이 같이 감소하거나 플라이 애쉬 또는 실리카 흙이 늘어나는 형태를 보이기도 한다. 이것은 재료가 서로 상호 영향을 주기 때문이라 생각된다. 실제로 시험 결과 중에서 다른 배합설계에도 같은 물성을 가지는 경우도 있었다. 이로 인해 배합자료가 많은 400~800kg/cm<sup>2</sup> 범위의 재료 예측에서 더 큰 오차가 생긴 이유이기도 하다.

콘크리트의 물성에 관한 예측은 실제 배합한 자료와 위의 BP학습에 의해 나온 결과를 이용하여 실제 물성과 비교하였다. 그림 4.1과 그림 4.2는 각

경우에 대한 물성 예측의 평균 오차를 보여 주고 있다. 슬럼프와 공기량, 그리고 압축강도의 오차범위는 각각 4.8%~6%, 7%~15%, 그리고 1.4%~2.7%였다. 혼화재료의 영향을 많이 받는 슬럼프와 공기량의 오차가 비교적 크게 나온 것이 특징이었으며, 혼화재료의 영향이 비교적 적으며 시간이 지나야 알 수 있는 강도의 예측이 정확한 것이 주목할 만 하였다.

#### 4.2 Radial basis function Network(RBF)의 적용

Radial basis function 네트워크는 Back Propagation 알고리즘과 비교하기 위해 사용되었다. 그러므로, 네트워크는 back propagation 알고리즘과 같은 오차에 도달할 때까지 훈련되었다. RBF 네트워크의 구조는 시간을 최소로 소모하는 신경망을 선택하였다. 훈련시간은 Back propagation 알

고리즘의 약 1/400이 소요되었다. 그림 4.3은 한 경우의 기저 함수의 폭과 사용 뉴런의 수에 오차의 변화를 나타내는 그래프이다.

시험자료는 BP 네트워크에서와 동일한 자료를 사용하였다. 표4.9와 4.10은 배합재료의 예측을 보여주는데, BP 알고리즘처럼, 단위량의 예측은 실제 자료와 다소 차이가 있었으며, 역시 혼화재료의 차이가 다른 재료보다 조금 크게 나타났다. 또한 물/결합재비를 비교하였을 때도 배합재료의 적은 오차를 보였고, 압축강도, 슬럼프, 그리고 공기량은 재료보다 정확하게 예측하였다. 그림 4.4, 그림 4.5는 RBF 네트워크를 적용하였을 때의 물성의 예측 오차를 보여준다.

물성 예측과 재료 예측 모두에서 RBF는 BP와 동일한 결과를 보여주며, 반대로 훨씬 빠른 학습능력을 보여주는 것으로 나타났으며, 자료가 많으면

표 4.1 시험자료(400~800kg/cm<sup>2</sup>)

Num	Slump (cm)	Air Content(%)	fck (kg/cm <sup>2</sup> )	Unit Weight (kg/m <sup>3</sup> )						
				Water	Cement	Fine Agg.	Coarse Agg.	Fly Ash	AE	SP
1	23	5.2	644	170	510	731	845	57	0.074	11.33
2	17.5	4	621	160	457	816	898	0	0.059	5.71
3	9	3	475	180	411	628	950	103	0.067	2.57
4	22	7.2	485	160	320	834	898	80	0.04	4
5	24.5	6.1	436	180	405	805	845	45	0.045	4.5
6	9	8.1	418	170	378	803	950	0	0.038	0

표 4.2 시험자료(800~1200kg/cm<sup>2</sup>)

Num	Slump (cm)	Air Content(%)	fck (kg/cm <sup>2</sup> )	Unit Weight (kg/m <sup>3</sup> )						
				Water	Cement	Fine Agg.	Coarse Agg.	Fly Ash	AE	SP
1	23	5.2	644	170	510	731	845	57	0.074	11.33
2	17.5	4	621	160	457	816	898	0	0.059	5.71
3	9	3	475	180	411	628	950	103	0.067	2.57
4	22	7.2	485	160	320	834	898	80	0.04	4
5	24.5	6.1	436	180	405	805	845	45	0.045	4.5
6	9	8.1	418	170	378	803	950	0	0.038	0

표 4.3 배합 예측 결과(400~800kg/cm<sup>2</sup>,BP,data-max)

Num	Unit Weight (kg/m <sup>3</sup> )						
	Water	Cement	Fine Agg.	Coarse Agg.	Fly Ash	AE	SP
1	164	514	762	868	21	0.07	9.12
2	172	507	701	894	39	0.071	6.48
3	170	374	793	894	57	0.053	1.92
4	165	384	867	871	16.3	0.041	4.82
5	168	370	816	897	42	0.04	3.98
6	167	370	872	880	14	0.039	0.99

표 4.4 배합 예측 결과(400~800kg/cm<sup>2</sup>,BP,data-min)

Num	Unit Weight (kg/m <sup>3</sup> )						
	Water	Cement	Fine Agg.	Coarse Agg.	Fly Ash	AE	SP
1	166	523	742	893	7	0.07	9.16
2	169	490	720	893	45	0.07	6.35
3	169	352	806	891	67	0.052	1.64
4	157	369	911	862	16	0.038	5.66
5	174	385	808	897	26	0.041	4.26
6	176	400	813	889	13	0.043	0.8

표 4.5 배합 예측 결과(800~1200kg/cm<sup>2</sup>,BP,data-max)

Num	Unit Weight (kg/m <sup>3</sup> )					
	Water	Cement	Fine Agg.	Coarse Agg.	Silica Fume	SP
1	144	533	512	979	191	29.04
2	147	574	555	992	124	18.34
3	145	562	515	970	195	29.81
4	151	567	584	1002	96	16.16
5	155	487	615	1013	87	13.75

표 4.6 배합 예측 결과(800~1200kg/cm<sup>2</sup>,BP,data-min)

Num	Unit Weight (kg/m <sup>3</sup> )					
	Water	Cement	Fine Agg.	Coarse Agg.	Silica Fume	SP
1	146	536	519	973	189	27.56
2	152	641	539	934	128	20.71
3	139	480	567	1046	156	24.48
4	153	591	565	977	109	19.2
5	153	443	593	1017	131	12.49




그림 4.1 BP에 의한 특성 예측의 평균 오차 (400~800kg/cm<sup>2</sup>)

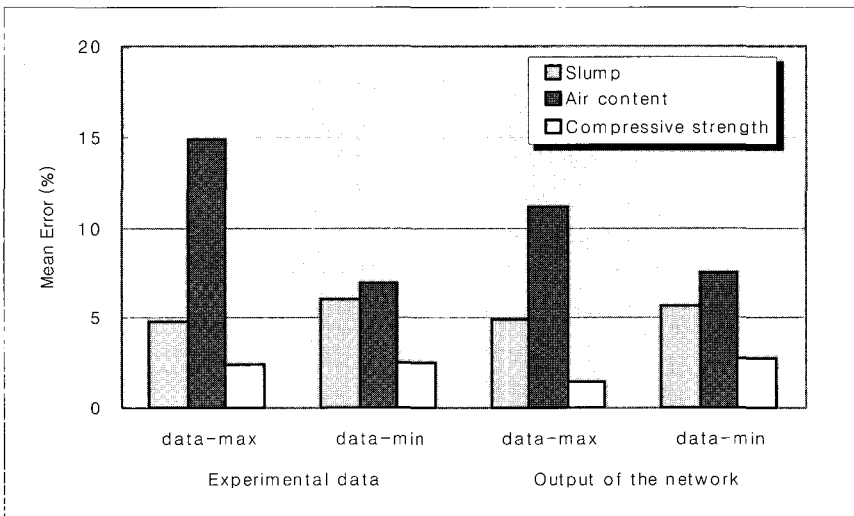


그림 4.2 BP에 의한 특성 예측의 평균 오차 (800~1200kg/cm<sup>2</sup>)

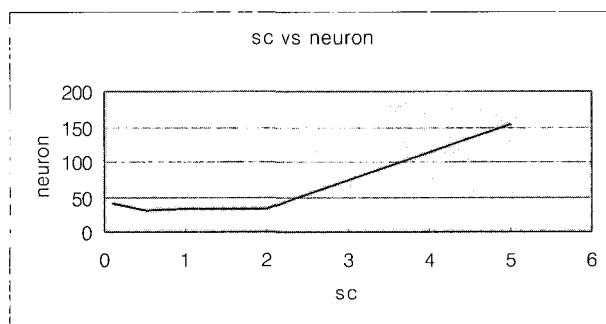


그림 4.3 함수 폭과 뉴런 수에 따른 오차 제곱 합



표 4.9 배합 예측 결과(800~1200kg/cm<sup>2</sup>,RBF,data-max)

Num	Unit Weight (kg/m <sup>3</sup> )					
	Water	Cement	Fine Agg.	Coarse Agg.	Silica Fume	SP
1	145	529	492	966	224	29.65
2	178	597	562	981	111	18.99
3	142	582	529	988	159	28.8
4	150	571	577	1000	97	17.28
5	157	491	627	1029	69	12.89

표 4.10 배합 예측 결과(800~1200kg/cm<sup>2</sup>,RBF,data-min)

Num	Unit Weight (kg/m <sup>3</sup> )					
	Water	Cement	Fine Agg.	Coarse Agg.	Silica Fume	SP
1	145	533	539	993	175	25.49
2	151	642	560	945	107	17.49
3	145	553	550	990	154	25.45
4	149	570	582	1000	94	15.72
5	153	516	588	1003	119	14.21

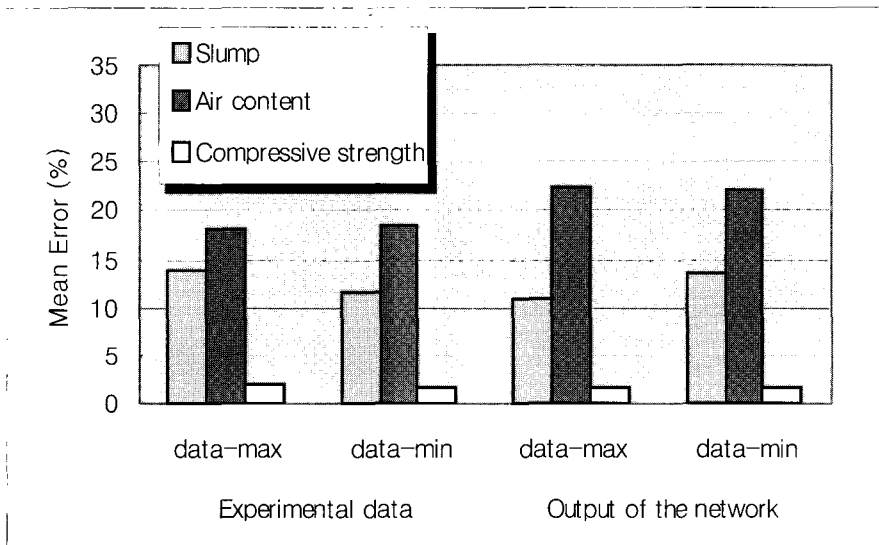


그림 4.4 RBF에 의한 특성 예측의 평균 오차 (400~800kg/cm<sup>2</sup>)

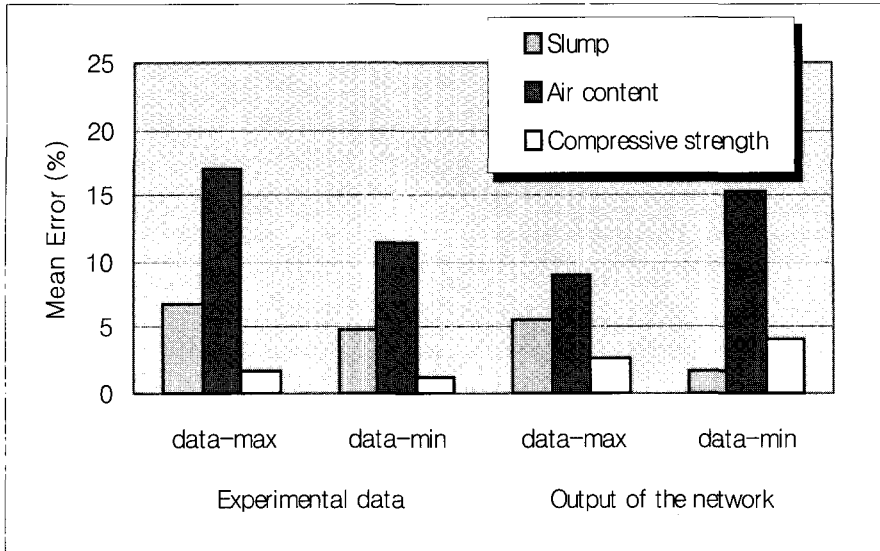


그림 4.5 RBF에 의한 특성 예측 평균 오차 (800~1200kg/cm<sup>2</sup>)

많을수록 더 유용할 것으로 판단된다. 하지만 빠른 학습 능력 대신 RBF는 과도한 학습을 시킬 경우 오히려 더 부정확한 모습을 보였다. 표 4.10은 400~800kg/cm<sup>2</sup> 경우의 data-max에서 학습을 과도하게 시켰을 경우의 배합 재료 예측 결과값이다. 시험 자료와의 오차가 크다는 것을 알 수 있으며 심지어 음수의 값이 나오는 것으로 보아 RBF는 과도한 학습의 경우 오히려 결과가 좋지 않음을 보여주는 것이라 할 수 있다. 이것은 기저 함수의 폭이 넓어져서 서로 함수간에 중복 현상이 일어나고 상관성이 적은 곳의 자료까지 예측에 영향을 주기 때문에 지역적인 학습을 하는 RBF의 특성이 사라지기 때문이라 생각된다.

### 5. 결 론

이 논문에서는 고성능 콘크리트를 활용을 돕기 위한 하나의 도구로써 신경망을 검토해보았다. 인간의 두뇌 조직을 모방한 신경망은 현재 경험에 많이 의존하고 있는 콘크리트의 활용에서 인간을 대신한 컴퓨터의 학습을 통해 배합량의 예측에서 압축강도같은 물성의 예측까지 충분히 사용될 수 있음을 알 수 있었으며, 더욱이 아직 많이 사용되지 않고 있는 고성능 콘크리트 분야에서도 유용할 것으로 생각된다. 논문에서 사용된 두 가지의 알고리즘, Back propagation network와 radial basis function network, 모두 활용하기에 충분함을 보여

주었으며, 다음과 같이 결론을 얻을 수 있었다.

1. 자료의 전처리는 신경망의 적용결과에 큰 영향이 없었다.
2. 단위량의 예측에서 신경망의 출력값은 혼화 재료를 제외하고 실험자료와 비슷하였다.
3. 특성의 예측에서, 실험자료와 신경망의 예측 자료를 통한 배합의 적용은 측정값과 비슷한 결과를 보여주었다. 특히, 압축강도의 경우 매우 정확하였다.
4. Back propagation algorithm은 학습에 긴 시간이 소요되지만, 정확한 결과를 도출하였다.
5. Radial basis function network는 back propagation algorithm과 비교하여 짧은 시간 동안 학습이 가능하지만, 과도한 학습을 할 경우 결과의 정확도는 떨어졌다.
6. Back propagation algorithm과 radial basis function network 모두 고성능 콘크리트분야의 활용에 적합하였다.
7. 신경망의 적용을 개선하기 위해, 배합 조건을 고려한 자료의 수집 등 추가적인 연구가 필요하다.

### 감사의 글

이 논문은 국가지정연구실(National Research Laboratory, NRL)의 연구비 지원으로 수행되었으며, 이에 깊은 감사를 드립니다.

## 참 고 문 헌

1. 오주원, 이종원, 이인원(1997) 콘크리트의 배합설계에 있어서 신경망의 이용, 콘크리트학회지, 제 9권, 2호, , 145-151.
2. Anthony T.C. Goh(1995) Prediction of Ultimate Shear Strength of Deep Beams Using Neural Networks, ACI Structural Journal, January-February, pp28-32.
3. Christopher M. Bishop(1995), Neural networks for Pattern Recognition, Clarendon Press. Oxford, pp116-193.
4. Janusz Kasperkiewicz, et al.(1995), HPC Strength Prediction Using Artificial Neural Network, Journal of Computing in Civil engineering, October, pp279-284.
5. J.J. Myers and R.L. Carrasquillo(1999), Mixture Proportioning for High-Strength High-Performance Concrete Bridge Beams, ACI SP-189, pp37-56.
6. I-Cheng Yeh(1998), Modeling Concrete Strength with Augment Neuron Networks, Journal of Materials in Civil Engineering, November, pp263-268.
7. I-Cheng Yeh(1999), Design of High Performance concrete Mixture Using Neural networks and Nonlinear Programming, Journal of computing in Civil Engineering, January, pp36-42.
8. Simon Haykin(1999), "Neural networks; A comprehensive Foundation", Prentice Hall International, Inc., New Jersey, pp156-317.
9. W. Dehuai, C. Zhaoyuan, and Q. Weizu(1997), Computerized Mix Proportioning for HPC, Concrete International, September, pp42-45.