

콘크리트 압축강도 추정을 위한 확률 신경망

Probabilistic Neural Network for Prediction of Compressive Strength of Concrete

김 두 기* 이 종 재** 장 성 규***
Kim, Doo-Kie Lee, Jong-Jae Chang, Seong-Kyu

Abstract

The compressive strength of concrete is a criterion to produce concrete. However, the tests on the compressive strength are complicated and time-consuming. More importantly, it is too late to make improvement even if the test result does not satisfy the required strength, since the test is usually performed at the 28th day after the placement of concrete at the construction site. Therefore, strength prediction before the placement of concrete is highly desirable. This study presents the probabilistic technique for predicting the compressive strength of concrete on the basis of concrete mix proportions. The estimation of the strength is based on the probabilistic neural network which is an effective tool for pattern classification problem and gives a probabilistic result, not a deterministic value. In this study, verifications for the applicability of the probabilistic neural networks were performed using the test results of concrete compressive strength. The estimated strengths are also compared with the results of the actual compression tests. It has been found that the present methods are very efficient and reasonable in predicting the compressive strength of concrete probabilistically.

요 지

콘크리트의 압축강도는 콘크리트를 생산하는 기준으로 사용된다. 콘크리트 압축강도 시험은 복잡하고 시간이 걸리는 일이고, 보통 건설현장에서 타설 후 28일 후에 실행되기 때문에, 시험결과가 필요강도를 만족하지 않을 경우에 구조물의 시공에 문제를 초래할 수도 있다. 따라서, 콘크리트 타설 전에 강도를 예측하는 것이 요구되고 있다. 본 연구에서는 콘크리트 배합비를 기초로 하여 콘크리트 압축강도를 예측하기 위한 확률론적 방법을 제시하였다. 패턴인식 분야에서 많이 활용되어온 확률신경망 기법을 활용하여 콘크리트 압축강도 추정을 수행하였다. 콘크리트 압축강도 시험결과를 활용하여 확률신경망 기법의 적용성을 검증하였으며, 실제 시험결과와 비교를 수행하였다. 비교결과, 본 연구에서 제시된 확률신경망을 활용한 콘크리트 압축강도 추정 기법이 콘크리트의 압축강도를 확률적으로 추정하는데 매우 효과적으로 적용될 수 있음을 확인하였다.

Keywords : Concrete Compressive Strength, Probabilistic Neural Network, Pattern Classification, Concrete Mix Proportions

핵심 용어 : 콘크리트 압축강도, 확률신경망, 유형 분류, 콘크리트 배합비

* 군산대학교 토목환경공학부 전임교수

** 한국과학기술원 박사과정

*** 군산대학교 토목환경공학부 연구원

E-mail : kim2kie@chol.com 063-469-4770

• 본 논문에 대한 토의를 2004년 3월 31일까지 학회로 보내 주시면 2004년 7월호에 토론결과를 게재하겠습니다.

1. 서 론

콘크리트는 가장 널리 사용되는 건설재료이며, 콘크리트 배합요소는 주로 시멘트, 물, 잔골재 및 굵은 골재 등이다. 콘크리트의 중요한 특성 인자로는 배합설계, 품질관리 및 콘크리트 강도 등이 있고, 콘크리트 강도에는 압축강도, 인장강도, 휨강도, 전단강도 및 접착강도 등이 있으며, 콘크리트를 생산하기 위한 가장 중요한 특성은 콘크리트의 압축강도이다. 콘크리트 배합설계는 28일 압축강도를 목표로 한다. 28일 압축강도는 표준 일축압축 시험에 기초하고, 콘크리트 강도의 일반 지침으로 사용한다. 콘크리트 압축강도 시험은 매우 복잡하고, 많은 시간이 소요되며, 시험오차를 포함하고 있어, 소요강도를 만족하지 않는 시험결과를 얻을지라도 공기 등을 고려할 때, 재 타설이 어려운 경우가 많다. 따라서 콘크리트를 타설하기 전에 배합비와 운반시간, 습도 등을 포함한 현장 조건을 고려하여 콘크리트 압축강도를 정확히 예측하는 것은 매우 중요하다.^{(3),(4),(6)}

콘크리트의 압축강도는 배합설계 등의 여러 인자들에 의하여 영향을 받고 이를 수학적으로 모형화하는 것은 쉽지 않다. 인공지능망과 같은 소프트웨어 기법은 이와 같이 수학적으로 엄밀한 모델을 구성하기 힘든 입출력 관계를 효과적으로 다룰 수 있는 장점이 있다. 역전파 학습알고리즘을 사용한 다층 신경망을 이용하여 콘크리트의 압축강도를 추정하는 경우, 다중 입출력을 효과적으로 처리할 수 있으나, 추정결과가 확정적인 값으로 나타나게 되며, 훈련패턴을 이용하여 신경망을 학습시키는 시간이 많이 걸리는 단점이 있다.^{(5),(7)~(10)} 그러나, 확률신경망을 사용할 경우 신경망을 구성하는데 훈련패턴을 직접 이용하므로, 신경망을 학습시키는 과정이 필요하지 않아 해석시간이 비교적 적게 걸리고, 해석결과도 확률적인 분포값으로 나타난다는 장점이 있다.^{(11)~(15)} 또한, 콘크리트 압축강도에 영향을 주는 새로운 유형의 자료가 추가될 경우에 기존의 신경망 이론은 재학습을 통해 신경망을 새로이 구성해야 하나, 확률신경망 이론은 새로운 유형을 독립된 별개의 유형으로 쉽게 고려할 수 있다는 장점이 있다.

본 연구에서는 확률이론과 신경망 이론을 결합한 확률신경망을 사용하여 확률적으로 최확(最確, The most probable)의 콘크리트 압축강도를 예측하고, 시험으로부터 얻어진 압축강도 데이터와 비교 분석을 수행하였다.

2. 확률신경망

2.1 기초

실험의 결과나 표본 등에서 얻은 자료들을 어떤 성질에 따라 동질적인 몇 개의 클래스로 나누어 분류할 경우가 있다. 다변량 통계분석 방법 중에 하나인 클래스 분석이란 N개의 개체들을 대상으로 P개의 변수를 측정했을 경우에, 관측한 P개의 변수들을 이용하여 N개 개체들 사이의 유사성의 정도를 거리로 나타내어, 개체들을 거리가 가까운 순서대로 군집화하는 통계적 분석 방법이다. 클래스 분석의 과정은 통상 다음과 같다.

- (1) N개의 개체에 대하여 P개의 변수를 설정하여 측정한다.
- (2) 모든 개체들간의 유사성을 나타내는 거리를 계산하여 거리행렬을 구한다.
- (3) 거리행렬에 근거하여 개체들을 클래스로 분류한다.

일반적으로 두 개의 벡터 x_1 과 x_2 에 대한 거리를 나타내는 주요 측도로는 유클리드 거리(Euclidean distance), 체비셰프 거리(Chebyshev distance), 시가 거리(City-block 또는 Manhattan distance) 등이 있으며, 거리는 두 개체간의 유사성이 클수록 작고, 적을수록 크게 나타난다.

확률신경망은 어떤 개체가 어떤 클래스에 속하는지를 판별하는 분류자이다(Fig. 1).

확률신경망은 두개 이상의 훈련패턴들에서 학습된 알고리즘으로 모형화되며, 어떤 입력 개체에 대해, 클래스들과의 거리를 계산하고, 그 개체가 속한 클래스를 결정한다.




Fig. 1 클래스 영역과 경계에 관한 개념도

2.3 유형분류를 위한 Bayesian 확률방법

유형을 분류하는 방법은 근본적으로 유형 분류에 있어서 기대 위험을 최소화하는 것이다. 이런 방법 중에는 “Bayesian 확률 방법”이 있고, 이 방법은 다수의 클래스를 포함하는 문제에 적용할 수 있다.(12) θ 가 클래스 A 와 B 중에 하나인 θ_A 혹은 θ_B 라고 가정하자. 차수가 p 인 벡터 $X^t = [X_1 \dots X_j \dots X_p]$ 로 나타낸 측도를 사용하여 $\theta = \theta_A$ 인지 $\theta = \theta_B$ 인지를 결정하는 Bayesian 확률방법은 다음과 같다.

(1) $h_A l_A f_A(X) > h_B l_B f_B(X)$ 인 경우:

$$d(X) = \theta_A \tag{1a}$$

(2) $h_A l_A f_A(X) < h_B l_B f_B(X)$ 인 경우:

$$d(X) = \theta_B \tag{1b}$$

여기서 $f_A(X)$ 와 $f_B(X)$ 는 각각 클래스 A 와 B 에 대한 확률밀도함수(PDF: Probabilistic Density Function)이며, l_A 와 l_B 는 각각 잘못된 결정과 관련된 손실계수 (Loss coefficient)이다. 만약 오류가 없는 정확한 결정이라면 손실계수는 0이다. 또한, h_A 는 $\theta = \theta_A$ 가 될 사전확률(Prior probability)이고, $h_B = (1 - h_A)$ 는 $\theta = \theta_B$ 가 될 사전확률이다.

Bayesian 확률방법을 사용할 경우에 $d(X) = \theta_A$ 인 영역과 $d(X) = \theta_B$ 인 영역 사이의 경계는 다음과 같다.

$$f_A(X) = K f_B(X) \tag{2}$$

여기서 K 는 다음과 같다.

$$K = h_B l_B / h_A l_A \tag{3}$$

모든 확률밀도함수는 항상 양이고, 적분가능하고, 전체 면적은 1이라는 제한조건 이외에 어떠한 제약도 없으므로, 식 (2)로 정의한 2개 클래스의 영역경계는 매우 복잡할 수 있다.

식 (2)를 사용하는데 있어서 중요한 것은 훈련패턴에 기초한 확률밀도함수를 추정하는 것이다.

2.3 밀도함수 추정을 위한 Parzen 방법

Bayesian 확률방법을 사용할 경우에 사전확률 h 와 손실계수 l 을 모든 클래스에 대하여 같다고 가정하면, 식 (1)을 사용하여 유형을 분류하는 경우 확률밀도함수를 알아야 한다. 각각의 클래스에 대한 확률밀도함수는 미지의 값이고, 훈련패턴만을 사용할 수 있다면, 전체 밀도함수는 훈련패턴만을 사용하여 결정하여야 한다.

Parzen⁽¹³⁾은 클래스들의 확률밀도함수들의 합이 연속이라면, 이것은 전체 밀도함수로 점근(漸近, Asymptotical)한다는 것을 보였다(Fig. 2). Gaussian 분포의 경우, 다변량 추정값은 다음과 같다.^{(13)~(14)}




Fig. 2 전체밀도함수 추정을 위한 Parzen 방법

$$f_A(X) = \frac{1}{(2\pi)^{p/2} \sigma^p} \frac{1}{m} \sum_{i=1}^m \exp\left(-\frac{|X - X_{Ai}|^2}{2\sigma^2}\right) \quad (4)$$

여기서 m 은 클래스 θ_A 에 속한 훈련패턴의 수, X_{Ai} 는 클래스 θ_A 에서 i 번째 훈련 유형, σ 는 편차, 그리고 p 는 훈련벡터의 차원이다.

$f_A(X)$ 는 Gaussian 다변량 분포들의 단순한 합이지만, 반드시 Gaussian일 필요는 없으며, 어떠한 밀도함수로 접근할 수도 있다. 작은 σ 를 사용할 경우, $f_A(X)$ 는 훈련패턴들의 위치에서 서로 완전히 구분되는 피크치를 가지는 형상을 나타내며, 큰 σ 를 사용할수록 $f_A(X)$ 는 점차 평탄화되고, 매우 큰 값을 사용할 경우에는 Gaussian 분포로 접근한다.

2.4 확률신경망구성

Fig. 3에 입력유형 X 를 두 개의 클래스로 분류하는 확률 신경망 구조를 나타냈다. 입력층(Input layer)은 모든 훈련 유형에 동일한 입력유형을 입력하는 일종의 분배하는 층이며, 학습층(Pattern layer)은 각 훈련패턴에 대해 가중치 벡터 W_i 와 입력 유형 X




Fig. 3 확률 신경망의 구조

의 내적 ($Z_i = X \cdot W_i$)을 구한 후, 비선형 활성화 함수(Activation function)에 Z_i 를 입력하여 비선형 연산을 수행한다(Fig. 4). 또한, 합산층(Summation layer)은 학습층에서 구한 비선형 출력결과를 합산한다(Fig. 5). Fig. 4에 보인 바와 같이 확률신경망 이론은 기존의 신경망 이론인 Back Propagation




Fig. 4 학습층 구조




Fig. 5 출력층 구조

(Rumelhart et al., 1986) 신경망에서 사용되었던 Sigmoid 활성화 함수 대신에, 비선형 연산자인 $\exp[(Z_i - 1)/\sigma^2]$ 를 사용한다. X 와 W_i 를 단위 크기로 정규화하면, 식 (4)는 다음과 같다.

$$\exp[-(W_i - X)^T (W_i - X)/2\sigma^2] \quad (5)$$

합산층은 식 (5)로 구한 결과들을 클래스 별로 각각 단순히 합하는 역할을 한다. 출력층은 Fig. 5에 보인 바와 같이 2개의 입력 신경을 갖고, 하나의 가중치 C 를 갖고 있으며, 0과 1로 구성된 2진수를 출력한다. k 번째 출력 절점에서 가중치 C_k 는 다음과 같다.

$$C_k = -\frac{h_{Bk}}{h_{A1}} \cdot \frac{n_A}{n_B} \quad (6)$$

여기서, n_A 는 클래스 A_k 에 대한 훈련유형의 수이고, n_B 는 클래스 B_k 에 대한 훈련유형의 수이며, 절정을 특별히 한 쪽으로 치우치게 할 이유가 없다면, C_k 는 -1로 놓을 수 있다. 또한, Fig. 2에 보인 바와 같이, 훈련 유형이 많을 경우에 학습층을 균집으로 분류할 수도 있다.

3. 확률신경망을 사용한 콘크리트 압축강도 추정

3.1 확률신경망을 위한 훈련패턴 구성

공사현장에서 사용되는 콘크리트는 회사별로 여러가지 조건을 고려하여 배합설계한 것이다. 일반적으로 슬럼프시험은 콘크리트를 타설하기 전에 행해지지만, 공시체 압축시험은 타설후 28일에 수행되므로, 공사현장에서 믿음직한 압축강도를 예측하기는 매우 어렵다. 본 논문에서는 콘크리트 압축강도를 예측하기 위해 확률신경망을 적용하였다. 확률신경망의 훈련패턴 구성을 위해 배합설계 자료와 슬럼프 값을 입력자료로 사

Table 1 콘크리트 재료의 물성값

Properties of material		Experiment data from Company A
Specific gravity	Cement	3.14
	Natural sand (s1)	2.59
	Crushed sand (s2)	2.51
	Coarse aggregate	2.64
Fineness modulus	Natural sand (s1)	3.30
	Crushed sand (s2)	2.25
	Coarse aggregate	6.53
Admixtures	Air-entraining admixtures	AE water-reducing (Standard)

용하고, 각각의 입력자료에 해당하는 콘크리트 압축강도를 클래스로 정의하였다. 배합설계에 사용된 콘크리트의 재료 물성값은 Table 1에 나타난 바와 같으며, 사용된 시멘트는 보통포틀랜드 시멘트, 최대 골재크기는 25mm를 사용하였다. 훈련패턴의 입력자료를 구성하는 9종의 변수들은 Table 2에 보인 슬럼프, 물-시멘트 비, 잔골재, 단위 수량, 단위 시멘트량, 단위 잔골재, 단위 굵은 골재, 혼화제이다. 그리고, 입력 자료에 사용된 모든 변수들을 균등한 가중치를 주기 위해서 0.1과 0.9 사이 값으로 정규화 하였다. 또한, 100 ~ 400kgf/cm²까지 10kgf/cm²씩 증가하는 콘크리트 압축강도를 31개의 클래스로 각각 정의하였다. 본 논문에서는 각 클래스 별로 5, 8, 10, 12, 15, 18 및 21cm의 슬럼프 값을 가지는 7개의 다른 훈련패턴이 있으므로, 총 217개의 훈련패턴을 사용하였다. 본 논문에서는 모든 훈련패턴에 대해 동일한 분포를 가정하였다. ($b = \sqrt{-\log(0.5)}/0.1 = 8.326$).

3.2 확률신경망을 이용한 패턴인식 검증

첫 번째 검증으로는 본 연구에서 제시한 확률신경망이 콘크리트 압축강도로 정의된 클래스를 분류하는데 적용성이 있는가를 검증하였다. 확률신경망을 구성하기 앞 절에서 설명한 217개의 훈련패턴을 사용하였으며, 이 중에서 14개의 검증용 테스트패턴을 추출하였다. 추정결과, Table 3에 보인 바와 같이 확률신경망을 통하여 출력된 클래스는 테스트패턴의 콘크리트 압축강도 값과 일치하는 것을 알 수 있으므로, 본 연구에서 구성한 확률신경망의 유용성을 검증할 수 있었다.

Table 2 혼련패턴 및 클래스로 사용한 배합설계의 예

Specified Strength (kgf/cm ²)	Slump (cm)	Water-cement ratio	Fine aggregate percentage (%)	Unit water content (kg/m ³)	Unit cement content (kg/m ³)	Unit fine aggregate content (kg/m ³)		Unit coarse aggregate content (kg/m ³)	Admixture (%)
						Natural sand (s1)	Crushed sand (s2)		
100	8	84.9	50.4	181	213	372	558	941	0.62
120	10	76.9	49.2	183	238	358	538	951	0.72
140	12	69.9	48.2	185	266	346	518	954	0.80
140	21	69.9	50.0	204	293	344	517	885	0.88
160	10	64.2	46.6	179	279	335	503	987	0.84
160	15	64.2	47.6	190	296	334	502	945	0.89
180	5	59.4	44.7	167	281	326	490	1038	0.84
180*	12	59.4	46.1	182	306	326	489	979	0.92
180	18	59.4	47.3	195	328	325	487	930	0.98
210*	12	53.5	44.9	180	336	314	471	990	1.01
210	18	53.5	46.1	193	361	313	469	938	1.08
240	8	48.6	43.1	170	350	304	456	1030	1.05
240*	12	48.5	43.9	179	368	303	455	995	1.10
270	10	44.2	42.7	173	391	294	441	1014	1.17
270	18	44.3	44.3	190	429	292	438	942	1.29
300	10	40.9	42	172	421	286	428	1013	1.26
300	15	40.9	43	183	447	284	426	966	1.34
350	10	35.7	40.9	171	479	271	406	1005	1.44
350	18	35.7	42.5	187	524	268	402	931	1.57
380	18	33.4	42.1	187	557	261	392	922	1.67
400	15	32.1	41.2	180	561	258	387	945	1.68

* 3.3절에서 시험결과와의 비교를 위한 테스트 패턴으로 활용된 자료

Table 3 검증용 배합설계자료와 출력결과

Specified Strength (kgf/cm ²)	Slump (cm)	Water-cement ratio	Fine aggregate percentage (%)	Unit water content (kg/m ³)	Unit cement content (kg/m ³)	Unit fine aggregate content (kg/m ³)		Unit coarse aggregate content (kg/m ³)	Admixture (%)	OUTPUT Class
						Natural sand (s1)	Crushed sand (s2)			
150	5	66.9	46.2	170	254	340	511	1018	0.76	150
190	5	57.3	44.3	167	290	322	484	1042	0.87	190
220	5	51.6	43.1	165	319	311	466	1053	0.96	220
290	5	42.0	41.2	162	386	289	434	1060	1.16	290
350	5	36.0	40.0	160	448	273	410	1053	1.34	350
290	8	42.0	41.8	168	401	289	433	1032	1.26	290
380	8	33.6	40.1	166	495	265	398	1019	1.49	380
110	10	80.8	50.0	184	228	365	548	939	0.68	110
290	10	42.1	42.2	173	411	288	432	1013	1.23	290
330	10	37.8	41.3	171	456	277	415	1008	1.38	330
180	12	59.4	46.1	182	306	326	489	979	0.92	180
210	12	53.5	44.9	180	336	314	471	990	1.01	210
240	12	48.5	43.9	179	368	303	455	995	1.10	240
300	15	41.0	43.0	183	447	284	426	967	1.34	300

두 번째 검증으로는 확률신경망을 이용한 콘크리트 압축강도 추정치의 일반화에 대한 검증을 위하여, 총 217개의 훈련패턴 중에서 각 클래스마다 임의대로 2개의 패턴을 추출하여 테스트 패턴으로만 활용하였다. 즉, 각 클래스마다 5개의 훈련패턴과 2개의 테스트 패턴을 생성하였으며, 총 31개의 클래스에 대하여 155개의 훈련패턴과 62개의 테스트 패턴을 사용하여 압축강도 추정을 수행하였다. 클래스 추정은 3단계로 반복연산을 통하여 수행되었다. 즉, 첫 단계에서는 각 테스트패턴에 대하여 31개의 모든 클래스 범위를 대상으로 추정을 수행하고, 이 결과를 바탕으로 클래스 범위를 축소시키며 2단계, 3단계 추정을 수행하였다. 2단계에서는 각 테스트패턴별로 1단계에서 추정된 클래스를 기준으로 상·하로 4개씩 총 9개 클래스를 범위로 하여 추정을 수행하였으며, 마지막 3단계에서는 2단계의 추정결과를 바탕으로 상·하로 2개씩 총 5개의 클래스 범위에 대하여 추정을 수행하였다. 이는 각 클래스를 구성하는 훈련패턴의 개수는 5개로 비교적 작은 반면, 추정하고자 하는 클래스의 범위(개수)는 31개로서 각 훈련패턴이 클래스를 구분하는데 있어서 중요도가 낮게 작용하는 것을 방지하기 위해서이다. 반복적인 과정을 통한 압축강도 클래스의 추정과정에 대한 예는 Table 4에 나타난 바와 같다.

추정결과를 살펴보면, Table 4 및 Fig. 6에 나타난 바와 같이 전 클래스 범위를 대상으로 한 첫 단계의 경우에는 오분류가 전반적으로 나타나고 있으며, 오분류된 경우에 있어서 오차의 크기도 다소 크게 나타나고 있음

을 알 수 있다. 대상 클래스의 범위를 축소시킨 2단계의 경우에는 오분류의 빈도 및 크기가 점점 작아지고 있으며, 3단계에 이르면 모든 테스트 패턴에 대해서 분류가 정확히 이루어졌음을 알 수 있다. 다중 분류의 문제에 있어서 각 클래스를 결정하는데 사용되는 훈련패턴의 개수가 많을수록 각 클래스의 추정결과는 안정적으로 나타날 것으로 예상되며, 이러한 많은 훈련패턴을 확보하기 힘든 경우에는 탐색하고자 하는 대상클래스를 순차적으로 축소시키는 것이 활용 가능한 훈련패턴의 중요도를 유지하면서, 다중 분류의 문제를 효과적으로 처리할 수 있는 방법으로 판단된다.

3.3 시험결과와의 비교 검증

본 절에서는 확률신경망을 이용하여 예측된 콘크리트 압축강도를 실제 회사에서 수행한 강도시험의 결과와 비교하였다. 콘크리트 압축시험 결과는 공시체 유형, 공시체 크기, 양생조건 및 재하속도 등에 의해 영향을 받는다. 또한, 포틀랜드 시멘트의 유형, 혼화재, 골재 재료, 혼합비, 배합 그리고 운반 등도 콘크리트 압축강도에 큰 영향을 미치는 요소이다. 본 연구에서 비교대상으로 한 콘크리트 시편은 3가지 공칭강도(180, 210, 240kgf/cm²)에 대해서 슬럼프 값은 12cm이며 Table 2에서 보여준 배합비에 의해 만들어진 원기둥의 공시체 ($\phi 100 \times 200mm$)를 이용하였다. 시험 시편은 각각의 공칭강도에 대하여 447, 354, 732개가 사용되었다.

Table 4 반복적인 분류를 통한 압축강도 클래스의 추정결과 예

Specified Strength (kgf/cm ²)	Slump (cm)		1st iteration	2nd iteration	3rd iteration
140	12	Range	100~400	110~190	120~160
		Est. Value	150	140	140
200	18	Range	100~400	140~220	180~220
		Est. Value	180	200	200
290	15	Range	100~400	240~320	260~320
		Est. Value	280	280	290
350	8	Range	100~400	300~380	320~360
		Est. Value	340	340	350
400	18	Range	100~400	330~400	380~400
		Est. Value	370	400	400

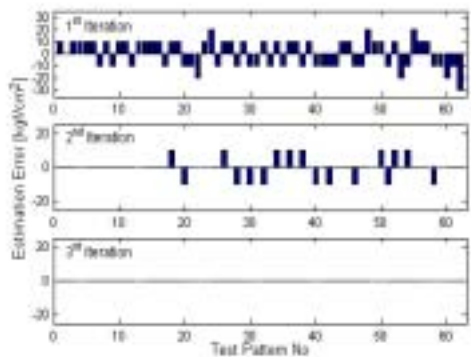


Fig. 6 반복적 분류에서 오차의 수렴과정




Fig. 7 시험결과와 비교

Table 5 콘크리트 압축강도 시험

Specified strength (f_c , kgf/cm ²)	Slump (cm)	Number of tests	Specified strength by test (f_{c1} , kgf/cm ²)
180	12	447	187(3.9)
210	12	354	208(1.0)
240	12	732	244(1.7)

* 괄호속의 값은 공칭강도와 시험결과와의 오차(%)

압축강도 시험은 28일의 시기에서 KSF2405와 ASTM C39-93a의 조건을 따라서 수행되었으며, 시험의 결과는 Table 5에 나타난 바와 같다.

Fig. 7에서는 시험결과와 확률신경망을 이용하여 구한 예측결과를 비교하여 나타내었다. 확률신경망의 훈련패턴은 3.1 절에서 사용된 217개의 훈련패턴을 사용하였으며, 테스트 패턴은 콘크리트 공칭강도 180, 210, 240 kgf/cm² 각각에 대하여 슬럼프 값 12에 해당하는 배합자료를 활용하여 구성하였다. 확률신경망을 이용하는 경우에는 기존의 역전파 학습 알고리즘을 활용한 신경망의 경우와는 달리, 하나의 테스트 패턴을 활용하는 경우에도 확정적인 추정값을 얻는 것이 아니라, 추정결과에 대한 확률적인 분포를 Fig. 7과 같이 얻을 수 있다. 확률 분포의 크기는 편의상 최대 값을 1로 정규화하여 비교하였다. 본 연구에서는 편차 σ 가 1.0, 0.5, 0.1인 경우에 대해서 각각 압축강도를 추정하였으며, 편차 σ 가 0.1인 경우에 시험결과와 가장 잘 일치하는 분포를 나타내었다.

4. 결론

콘크리트 배합설계를 통하여 실제 발견되는 콘크리트의 압축강도는 확정적이고, 일괄적인 값으로 나타나는 것이 아니라, 여러 불확실성에 의하여 어떠한 분포를 가지게 된다. 따라서 본 연구에서는 콘크리트 배합비를 기초로 하여 콘크리트 압축강도를 예측하기 위한 확률론적 방법을 제시하였다. 콘크리트 압축강도 시험결과를 확률신경망의 훈련패턴 및 테스트패턴으로 활용하여 확률신경망 기법의 적용성을 검증하였으며, 실제 시험결과와 비교를 수행하였다. 연구결과를 정리하면 다음과 같다.

- 1) 콘크리트 배합자료 및 슬럼프 값을 확률신경망의 입력자료로 사용하고, 콘크리트의 압축강도를 클래스로 정의하여 콘크리트의 압축강도를 성공적으로 추정하였다.
- 2) 추정하고자 하는 클래스의 개수가 각 클래스의 훈련패턴의 개수에 비하여 많은 경우, 추정결과를 개선시키기 위하여 단계적인 반복을 통한 클래스 추정이 효과적으로 활용될 수 있음을 확인하였다.
- 3) 추정결과와 시험결과와의 비교결과, 본 연구에서 제시된 확률신경망을 활용한 콘크리트 압축강도 추정기법이 콘크리트의 압축강도를 확률적으로 추정하는데 매우 효과적으로 적용될 수 있음을 확인하였다.

배합자료를 근간으로 확률신경망을 적용하여 콘크리트의 압축강도를 추정하는데 있어서, 배합비,

공칭강도 및 시험강도의 실제 데이터가 축적됨에 따라, 이 데이터베이스에 의해 훈련된 신경망은 더욱 신뢰성 있는 예측결과를 줄 것으로 기대된다. 추후 콘크리트 강도에 영향을 미치는 다른 중요한 데이터 즉, 콘크리트의 불확실성과 환경조건 및 그들의 상호관계에 대한 추가적인 정보를 분석하고 활용하는 연구가 필요하다.

감사의 글

이 논문은 2003년도 군산대학교 자체 학술연구비 지원에 의하여 연구되었으며, 이에 감사드립니다.

참고문헌

1. 김두기, 김종인, 김두훈, "신경망 이론을 이용한 교량의 동특성 추정," 대한토목학회, 2001년도 학술발표회 논문집, 구조분과 VIII, B8-001, 2001.11.3.
2. 김종인, 김두기, 이종현, 김인수, "신경망 이론을 이용한 콘크리트 압축강도 추정," 대한토목학회, 2001년도 학술발표회 논문집, 구조분과 V, P2-032, 2001.11.3.
3. 오병환, 양인환, "콘크리트 구조물의 합리적인 압축강도 추정기법 연구", 콘크리트학회지, 1999, v. 11, no. 2, pp. 242-249.
4. 오병환, 엄주용, "양질의 콘크리트 생성을 위한 배합설계 최적화", 콘크리트학회지, 1991, v. 3, no. 4, pp. 3-15.
5. 오주원, 이종원, 이인원, "콘크리트 배합설계에 있어서 신경망의 이용", 콘크리트학회지, 제9권, 2호, 1997, pp. 145-151.
6. 조홍범, 윤상천, 지남용, "콘크리트 배합표에 의한 현장 콘크리트의 압축강도 추정에 관한 연구", 한국콘크리트학회 가을 학술발표회 논문집, 2001, pp. 257-262.
7. J.I. Kim and D.K. Kim, "Application of Neural Networks for Estimation of Concrete Strength," KSCE Journal of Civil Engineering, Vol.6, No.4, December, 2002, pp.429-438.
8. Kasperkiewicz, J., Racz, J., and Dubrawski, A., "HPC Strength Prediction using Artificial Neural Network," Journal of Computing in Civil Engineering, ASCE, Vol.9, No.4, 1995, pp.279-284.
9. Oh, J. W., Lee, I.W., Kim, J. T., and Lee, G. W., "Application of Neural Networks for Proportioning of Concrete Mixes," ACI Material Journal, Vol.96, No.1, 1999, pp.61-67.
10. Yeh, I-C., "Design of High Performance Concrete Mixture using Neural Networks and Nonlinear Programming," Journal of Computing in Civil Engineering, ASCE, Vol.13, No.1, 1999, pp.36-42.
11. D. F. Specht, "Probabilistic Neural Networks", Neural Networks 3, 1990, pp.109-118
12. Schalkoff RJ., McGraw-Hill, Pattern recognition: statistical, structural and neural approaches, 1997.
13. Parzen, E., "On estimation of a probability density function and mode", Annals of Mathematical Statistics, 33, 1962, pp.1065-1076.
14. Cacoullos, T. "Estimation of a multivariate density", Annals of the Institute of Statistical Mathematics (Tokyo), 18(2), 1966, pp.179-189.
15. M. I. Glavinovic, "Comparison of Parzen density and frequency histogram as estimators of probability density functions", European journal of physiology, v. 433, no. 1, 1996, pp. 174-179

(접수일자 : 2003년 10월 13일)