

확률 신경망이론을 사용한 콘크리트 압축강도 추정 Prediction of Compressive Strength of Concrete using Probabilistic Neural Networks

김두기* 이종재** 장성규*** 임병용****

Kim, Doo Kie Lee, Jong-Jae Chang, Seong-Kyu Lim, Byung-Yong

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, and show that the present methods are very efficient and reasonable in predicting the compressive strength of concrete probabilistically.

1. 서론

콘크리트는 가장 널리 사용되는 건설재료이며, 콘크리트의 중요한 특성 인자로는 배합설계, 품질관리 및 콘크리트 강도를 들 수 있다. 콘크리트 배합요소는 주로 시멘트, 물, 잔 골재 및 굵은 골재 등이며, 콘크리트 강도는 압축강도, 인장강도, 휨강도, 전단강도, 접착강도 등이 있다. 콘크리트 압축강도는 다른 강도들 보다 훨씬 크므로, 대부분의 콘크리트 부재는 압축강도 특성을 사용하여 설계한다. 콘크리트 배합설계는 28일 압축강도를 목표로 하고, 28일 압축강도는 표준 일축압축

* 군산대학교 토목환경공학부 전임강사

** 한국과학기술원 박사과정

*** 군산대학교 토목환경공학부 연구원

**** 군산대학교 토목환경공학부 교수

시험에 기초하며, 콘크리트 강도의 일반 지침으로 사용된다. 일반적으로 콘크리트 시험 절차는 매우 복잡하고, 많은 시간이 소요되며, 실험오차를 포함하고 있다. 더욱이 28일 압축강도 시험은 콘크리트를 타설한 지 28일 후에 실시되므로, 만약 소요강도를 만족하지 않는 시험결과를 얻을 지라도 공기 등을 고려할 때, 재타설이 어려운 경우가 많다. 따라서, 콘크리트를 타설하기 전에 오차, 배합비, 운반시간 및 습도 등을 포함한 현장 조건을 고려하여 콘크리트 압축강도 특성을 확률적으로 정확히 예측하는 것이 매우 중요하다.

2. 확률신경망

확률신경망은 어떤 개체가 어떤 클래스에 속하는지를 판별하는 분류자(Classifier)이다(그림 1). 확률신경망은 두 개 이상의 훈련유형들(Training patterns)에서 학습된 알고리듬으로 모형화 되며, 어떤 입력 개체에 대해, 클래스들과의 거리를 계산하고, 그 개체가 속한 클래스를 결정한다.

유형을 분류하는 방법은 근본적으로 유형 분류에 있어서 기대위험(Expected risk)을 최소화하는 것이다. 이런 방법 중에는 "Bayesian 확률방법"이 있고, 이 방법은 다수의 클래스를 포함하는 문제에 적용할 수 있다(Mood & Graybill, 1962).

θ 가 클래스 A 와 B 중에 하나인 θ_A 혹은 θ_B 라고 가정하자. 차수가 p 인 벡터 $X^t = [X_1 \cdots X_j \cdots X_p]$ 로 나타낸 측도를 사용하여 $\theta = \theta_A$ 인지 $\theta = \theta_B$ 인지를 결정하는 Bayesian 확률방법은 다음과 같다.

$$d(X^t) \in \theta_A \text{ if } h_A l_A f_A(X) > h_B l_B f_B(X) \text{ for all } A \neq B \quad (1)$$

여기서 $f_A(X)$ 와 $f_B(X)$ 는 각각 클래스 A 와 B 에 대한 확률밀도함수이며, 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(Priori probability)이고, $h_B (= 1 - h_B)$ 는 $\theta = \theta_B$ 가 될 사전확률이다.

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, 훈련유형 만을 사용할 수 있다면, 전체 밀도함수는 훈련유형 만을 사용하여 결정하여야 한다. Parzen(1962)은 클래스들의 확률밀도함수들의 합이 연속이라면, 이것은 전체 밀도함수로 접근한다는 것을 보였다(그림 2). Gaussian 분포의 경우, 다변량 추정값은 다음과 같다 (Parzen, 1962; Cacoullos, 1966).

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

여기서 m 은 클래스 θ_A 에 속한 훈련유형의 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 훈련유형들의 위치에서 서로 완전히 구분되는 피크치(Peak)를 가지는 형상을 나타내며,

큰 σ 를 사용할수록 $f_A(X)$ 는 점차 평탄화되고, 매우 큰 값을 사용할 경우에는 Gaussian 분포로 접근한다.

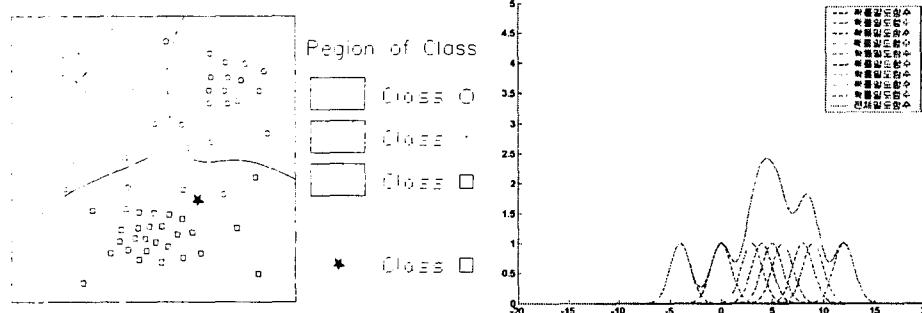


그림1. 클래스 영역과 경계에 관한 개념도 그림2. 전체 밀도함수 추정을 위한 Parzen 방법

그림 3에 입력유형 X 를 두 개의 클래스로 분류하는 확률 신경망 구조를 나타내었다. 입력층(Input layer)은 모든 훈련유형에 동일한 입력유형을 입력하는 일종의 분배층이며, 학습층(Pattern layer)은 각 훈련유형에 대해 가중치 벡터 W_i 와 입력 유형 X 의 내적($Z_i = X \cdot W_i$)을 구한 후, 비선형 활성화 함수(Activation function)에 Z_i 를 입력하여 비선형 연산을 수행한다. 또한, 합산층(Summation layer)은 학습층에서 구한 비선형 출력결과를 합산한다. 확률 신경망 이론은 기존의 신경망 이론인 Back Propagation(Rumelhart et al., 1986) 신경망에서 사용되었던 Sigmoid 활성화 함수 대신에, 비선형 연산자인 $\exp[(Z_i - 1)/\sigma^2]$ 를 사용한다. 따라서 클래스 θ_A 에 상응하는 확률밀도함수는 다음의 식 (3)과 같다. 식(3)에서 가중치 벡터 W_{Ai} 를 훈련벡터 X_{Ai} 로 선정하고 $X \cdot X = X_{Ai} \cdot X_{Ai} = 1$ 이 되도록 정규화하면 식 (2)와 같게 된다.

$$f_A(X) = \sum_{i=1}^m \exp \left[-\frac{(X \cdot W_{Ai} - 1)}{\sigma^2} \right] \quad (3)$$

3. 확률신경망을 사용한 콘크리트 압축강도 추정

공사현장에서 사용되는 콘크리트는 회사별로 여러가지 조건을 고려하여 배합설계한 것이다. 일반적으로 슬럼프(Slump)시험은 콘크리트를 타설하기 전에 행해지지만, 공시체 압축시험은 타설후 28일에 수행되므로, 공사현장에서 믿을만한 압축강도를 예측하기는 매우 어렵다. 본 논문에서는 콘크리트 압축강도를 예측하기 위해 확률신경망을 적용하였다.

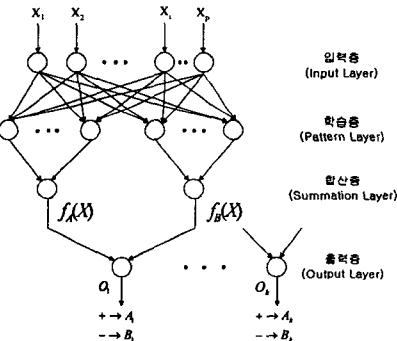


그림3. 확률 신경망의 구조

확률신경망 구성을 위해 배합설계 자료와 슬럼프 값을 훈련유형으로 사용하였고, 각각의 훈련유형에 해당하는 콘크리트 압축강도를 클래스로 정의하였다. 표 1에서는 훈련유형 및 클래스로 사용한 배합설계의 예를 나타내었다. 훈련유형을 구성하는 9종의 변수들은 표 1에 보인 슬럼프, 물-시멘트 비, 잔골재, 단위 수량, 단위 시멘트 양, 단위 잔 골재, 단위 굵은 골재, 혼화제이다. 그리고, 훈련유형에 사용된 모든 변수들을 균등한 가중치를 주기위해서 0.1과 0.9 사이 값으로 정규화 하였다. 또한, 100 ~ 400kgf/cm²까지 10kgf/cm²씩 증가하는 콘크리트 압축강도를 사용하여 31개의 클래스를 정의하고, 각 클래스 별로 5, 8, 10, 12, 15, 18 및 21cm의 슬럼프 값이 다른, 총 217개의 훈련유형을 사용하였다. 본 논문에서는 모든 훈련유형에 대해 동일한 분포를 가정 ($\sigma = \sqrt{-\log(0.5)}/0.1 = 8.326$) 하였다.

확률신경망을 구성하기 위해 사용하였던 217개의 훈련유형 중에서 14개의 검증용 훈련유형을 추출하였으며, 검증용 훈련유형을 확률신경망에 입력하여 출력된 클래스는 훈련유형의 콘크리트 압축강도값과 일치하였다(표 2). 콘크리트 압축강도 180, 210 및 240 kgf/cm²에 대해 실험결과와 비교하였으며, 편차 σ 가 0.1인 경우가 실험결과와 가장 잘 일치하였다(표 3, 그림 4).

표 1. 훈련유형 및 클래스로 사용한 배합설계의 예

Specified Strength (kgf/cm ²) (1)	Slump (cm) (2)	W/C (3)	Fine aggregate percentage (%) (4)	Unit water content (kgf/m ³) (5)	Unit cement content (kgf/m ³) (6)	Unit fine aggregate content (kgf/m ³)		Unit coarse aggregate content (kgf/m ³) (9)	Admixture (%) (10)
						Natural sand (s ₂) (7)	Crushed sand (s ₂) (8)		
160	10	64.2	46.6	179	279	335	503	987	0.84
180	18	59.5	47.3	195	328	325	487	929	0.98
210	10	53.5	44.5	176	329	314	471	1006	0.99
210	15	53.4	45.5	187	350	313	469	963	1.05
240	15	48.6	44.5	185	381	302	454	969	1.14
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
350	18	35.7	42.5	187	524	268	402	931	1.57
400	10	32.1	40.2	170	530	260	390	992	1.59

표 2. 검증용 배합설계자료와 출력결과

Specified Strength (kgf/cm ²) (1)	Slump (cm) (2)	W/C (3)	Fine aggregate percentage (%) (4)	Unit water content (kgf/m ³) (5)	Unit cement content (kgf/m ³) (6)	Unit fine aggregate content (kgf/m ³)		Unit coarse aggregate content (kgf/m ³) (9)	Admixtu re (%) (10)	OUTPUT Class (11)
						Natural sand (s ₂) (7)	Crushed sand (s ₂) (8)			
150	5	66.9	46.2	169.7	254	340.1	510.6	1018.1	0.76	150
190	5	57.3	44.3	166.7	290	322.3	483.8	1042.3	0.865	190
220	5	51.6	43.1	165	319	310.6	466.3	1052.5	0.96	220
290	5	42	41.2	162.1	386	289	433.9	1059.7	1.16	290
350	5	36	40	160.3	448	272.7	409.5	1053.2	1.34	350
290	8	42	41.8	168.3	401	288.7	433.2	1031.5	1.26	290
110	10	80.8	50	184.1	228	365.1	547.9	939.3	0.683	110
290	10	42.1	42.2	172.5	411	288.2	432.4	1013.3	1.23	290

* The numerical values in parentheses present the percentages of the differences between the specified strength by test results and the specified strength on mix proportion.

표3. 콘크리트 압축강도 실험

Experiment	Specified strength (f'_c , kgf/cm ²)	Slump (cm)	Number of tests	t	Specified strength by tests (f'_{cl} , kgf/cm ²)
Compressive Strength	180	12	447	3.0	187(3.9)
	210	12	354	3.0	208 (1.0)
	240	12	372	3.0	244 (1.7)

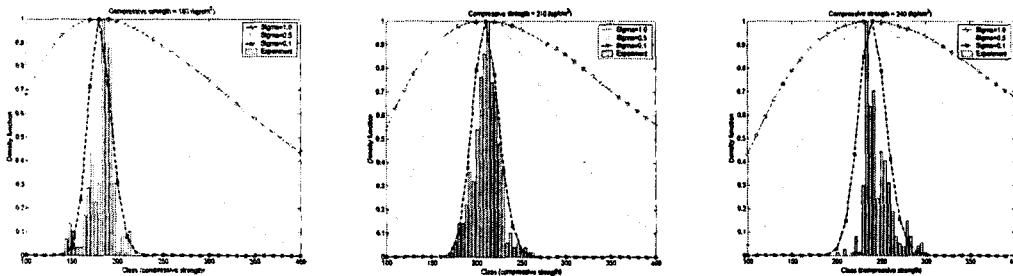


그림4. 실험결과와 비교

4. 결론

본 연구에서는 확률이론과 신경망 이론을 결합한 확률신경망을 사용하여 콘크리트 압축강도를 예측하였다. 본 연구에서 제안한 방법은 기존의 자료를 근간으로 확률론적으로 최적의 콘크리트의 압축강도를 예측하는 것이다. 만약, 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 있다. 예제해석으로는 배합설계 자료를 훈련유형으로 사용하고, 압축강도를 클래스로 정의하여, 콘크리트 압축강도를 확률적으로 추정하였다. 여기서 배합설계에 사용한 배합요소와 압축강도들은 모두 동일한 확률 분포와 가중치를 갖는 것으로 가정하였다. 출력된 클래스는 훈련유형의 콘크리트 압축강도 값과 일치하였으며, 편차 σ 가 0.1인 경우가 실험결과와 가장 잘 일치하였다.

당국에 감사드립니다.

참고문헌

1. 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,
2. Kasperkiewicz, J., Racz, J., and Dubrawski, A. (1995). "HPC Strength Prediction using Artificial Neural Network," Journal of Computing in Civil Engineering, ASCE, Vol.9, No.4, pp.279-284.
3. Oh, J. W., Lee, I.W., Kim, J. T., and Lee, G. W. (1999). "Application of Neural Networks for Proportioning of Concrete Mixes," ACI Material Journal, Vol.96, No.1, pp.61-67.
4. Yeh, I-C. (1999). "Design of High Performance Concrete Mixture using Neural Networks

- and Nonlinear Programming," Journal of Computing in Civil Engineering, ASCE, Vol.13, No.1, pp.36-42.
5. D. F. Specht, Probabilistic Neural Networks, *Neural Networks* 3, 1990, pp.109-118
 6. T. Masters, Advanced Algorithms for Neural Networks, Academic Press, New York, 1995.
 7. Schalkoff RJ. Pattern recognition: statistical, structural and neural approaches. New York: McGraw-Hill; 1997.
 8. Parzen, E. (1962). "On estimation of a probability density function and mode", *Annals of Mathematical Statistics*, 33, pp.1065-1076
 9. Cacoullos, T. "Estimation of a multivariate density", *Annals of the Institute of Statistical Mathematics (Tokyo)*, 18(2), 1966, pp.179-189.