

콘크리트 압축강도 추정을 위한 적응적 확률신경망 기법

Adaptive Probabilistic Neural Network for Prediction of Compressive Strength of Concrete

김두기¹⁾ 이종재²⁾ 장성규³⁾
Kim, Doo Kie Lee, Jong-Jae Chang, Seong Kyu

ABSTRACT

The compressive strength of concrete is commonly used criterion in producing 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, accurate and realistic strength estimation before the placement of concrete is being highly required. In this study, the estimation of the compressive strength of concrete was performed by probabilistic neural network (PNN) on the basis of concrete mix proportions. The estimation performance of PNN was improved by considering the correlation between input data and targeted output value. Adaptive probabilistic neural network (APNN) was proposed to automatically calculate the smoothing parameter in the conventional PNN by using the scheme of dynamic decay adjustment algorithm. The conventional PNN and APNN were applied to predict the compressive strength of concrete using actual test data of a concrete company. APNN showed better results than the conventional PNN in predicting the compressive strength of concrete.

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 얻으더라도 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. 인공신경망(artificial neural networks)과 같은 소프트웨어 기법은 이와 같이 수학적으로 엄밀한 모델을

- 1) 군산대학교 토목환경공학부 전임교수
- 2) 한국과학기술원 건설 및 환경공학과 박사후 연구원
- 3) 군산대학교 토목환경공학부 석사과정

구성하기 힘든 입력력 관계를 효과적으로 다룰 수 있는 장점이 있다. 역전파 학습알고리즘을 사용한 다층 신경망을 이용하여 콘크리트의 압축강도를 추정하는 경우, 입력력 관계를 효과적으로 처리할 수 있으나 추정결과가 확정적인 값으로 나타나게 되며, 훈련패턴을 이용하여 신경망을 학습시키는데 시간이 많이 걸리는 단점이 있다^[5,7,8,10,11]. 반면, 확률신경망은 신경망을 구성하는데 훈련패턴을 직접 이용하므로, 신경망을 학습시키는 과정이 필요하지 않아 해석시간이 비교적 적게 걸리고, 해석결과도 확실적인 분포값으로 나타난다는 장점이 있다^[12-16]. 그러나, 확률신경망 기법에서도 각 클래스의 확률분포를 결정하기 위한 커널함수(kernel function)의 평활화계수(smoothing parameter)에 대한 가정이 필요한 단점이 있다.

본 연구에서는 콘크리트 배합비를 기초로하여 콘크리트 압축강도를 예측하기 위한 확률신경망 기법을 제시하였다. 배합자료와 압축강도와의 상관계수를 고려한 입력자료의 활용으로 확률신경망의 성능을 개선하고자 하였으며, dynamic decay adjustment 알고리즘^[5]의 개념을 이용하여 확률신경망에 있어서 평활화계수를 자동적으로 계산하는 적응적 확률신경망(adaptive probabilistic neural network) 기법을 제안하였다. 콘크리트 압축강도 시험결과를 활용하여 제안된 기법의 적용성을 검증하였으며, 실제 시험결과와 비교를 수행하였다.

2. 적응적 확률신경망 (Adaptive Probabilistic Neural Network)

2.1 확률신경망 (Probabilistic Neural Network)

확률신경망은 다변량 통계분석(multivariate analysis) 방법 중에 하나인 클래스 분석(class analysis)으로 N개의 개체들을 대상으로 P개의 변수를 측정했을 경우에, 관측한 P개의 변수들을 이용하여 N개 개체들 사이의 유사성(similarity)의 정도를 척도로 하여 어떤 개체가 어떤 클래스에 속하는지를 판별하는 분류자이다.

유형을 분류하는 방법은 근본적으로 유형 분류에 있어서 기대 위험(expected risk)을 최소화하는 것이다. 이런 방법 중에는 "Bayesian 결정론"이 있고, 이 방법은 다수의 클래스를 포함하는 문제에 적용할 수 있다^[13].

θ 가 클래스 A와 B중에 하나인 θ_A 혹은 θ_B 라고 가정하자. 차수가 p인 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.

$$d(X) = \theta_A \text{ if } h_A l_A f_A(X) > h_B l_B f_B(X) \quad (\text{식 1a})$$

$$d(X) = \theta_B \text{ if } h_A l_A f_A(X) < h_B l_B f_B(X) \quad (\text{식 1b})$$

여기서 $f_A(X)$ 와 $f_B(X)$ 는 각각 클래스 A와 B에 대한 확률밀도함수이며, l_A 와 l_B 는 각각 잘못된 결정과 관련된 손실계수이다. 만약 오류가 없는 정확한 결정이라면 손실계수는 0이다. 또한, h_A 는 $\theta = \theta_A$ 가 될 사전확률이고, $h_B = (1 - h_A)$ 는 $\theta = \theta_B$ 가 될 사전확률이다.

Bayesian 결정론을 사용할 경우에 사전확률 h 와 손실계수 l 을 모든 클래스에 대하여 같다고 가정하면, 식 (1)을 사용하여 유형을 분류하는 경우 각 클래스에 대한 확률밀도함수를 알아야 한다. 각각의 클래스에 대한 확률밀도함수는 미지의 값이고, 훈련패턴만을 사용할 수 있다면, 전체 밀도함수는 훈련패턴만을 사용하여 결정하여야 한다. Parzen은 클래스들의 확률밀도함수들의 합이 연속이라면, 이것은 전체 밀도함수로 접근한다는 것을 보였다^[14] 그림 1.

확률신경망의 일반적인 구조는 그림 2와 같다. 패턴층에서는 클래스 k내의 j번째 훈련패턴에 대한 확률밀도함수 f_j^k 를 다음의 식 (2)와 같이 계산한다.

$$f_j^k(X) = \frac{1}{(2\pi)^{p/2}(\sigma_j^k)^p} \exp\left(-\frac{(X - \mu_j^k)^T(X - \mu_j^k)}{2(\sigma_j^k)^2}\right) \quad (\text{식 2})$$

여기서, p는 입력벡터 X의 차원을 나타내고, μ_j^k 는 k 클래스의 j 번째 훈련유형이며 σ_j^k 는 k 클래스의 j 번째 훈련패턴에 대한 평활화계수이다. 합산층에서는 각 훈련패턴별로 계산된 확률밀도함수에 가중치를 곱하여 클래스별

확률밀도 함수를 다음의 식 (3)과 같이 구한다.

$$s_k(X) = \sum_{j=1}^{m_k} w_j^k f_j^k(X), k = 1, \dots, c \quad (\text{식 } 3)$$

여기서 w_j^k 는 클래스 k 의 j 번째 훈련유형에 대한 가중치로써 각 클래스 내의 훈련패턴들에 대하여 합계는 일정하다. 특정 훈련유형에 대한 중요도에 대한 사전정보(priori)를 사용할 수 없는 경우에는 모든 훈련패턴에 대하여 동일한 값을 사용하도록 한다 ($w_j^k = 1/m_k$). 일반적인 확률신경망 기법에서는 식 (2)의 확률밀도함수 계산에 사용하는 평활화계수 σ_j^k 에 대하여 일정한 값을 가지는 평활화계수(σ)를 사용하였다. 작은 σ 를 사용할 경우, 각 훈련패턴들의 위치에서 서로 완전히 구분되는 피크치를 가지는 형상을 나타내며, 큰 σ 를 사용할수록 점차 평탄화되고, 매우 큰 값을 사용할 경우에는 Gaussian 분포로 접근하는 특징을 보인다. 기존의 연구에서는 평활화계수(σ)의 선택에 있어서 경험적인 방법을 사용하였으나, 본 연구에서는 클래스 확률분포에 따라 자동적으로 평활화계수를 계산하는 적응적 확률신경망 기법을 제안하였다.

2.2 적응적 확률신경망 (Adaptive Probabilistic Neural Network)

패턴 분류를 위한 Bayesian 결정론과 각 클래스의 확률분포를 결정하기 위한 Parzen window 방법의 조합으로 이루어지는 확률신경망은 각 클래스의 확률분포를 결정하기 위한 커널함수의 평활화계수에 대한 가정이 필요한 단점이 있다. 본 연구에서는 dynamic decay adjustment 알고리즘^[9]의 개념을 이용하여 확률신경망에 있어서 평활화계수를 자동적으로 계산하는 적응적 확률신경망(adaptive probabilistic neural network) 기법을 제안하였다.

Dynamic decay adjustment 알고리즘은 훈련과정을 통하여 신경망의 구조를 결정하고, 필요한 뉴런의 수를 자동적으로 결정하며, 각 훈련패턴에서의 평활화계수를 상·하한의 경계치(threshold)를 활용하여 자동으로 결정하는 방법이다. θ^+ 는 정확한 클래스의 훈련유형을 위한 최소한의 클래스 확률밀도를 결정하고(식 4), θ^- 는 오분류(misclassification)를 피하기 위한 클래스 확률밀도이다(식 5)(그림 3). 즉, 클래스 k 내의 j 번째 훈련패턴에 대한 평활화계수(σ_j^k)는 식 (4)와 (5)을 만족하는 값으로 결정되며, 두 상·하한의 경계치(θ^+ , θ^-)는 평활화계수의 값을 결정하는 사용자 정의 파라메타로서 상한치(θ^+)는 0.4 하한치(θ^-)는 0.2의 값이 일반적으로 사용된다^[9].

$$f_j^k(X) = \frac{1}{(2\pi)^{p/2}(\sigma_j^k)^p} \exp\left(-\frac{(X-\mu_j^k)^T(X-\mu_j^k)}{2(\sigma_j^k)^2}\right) \geq \theta^+ \text{ if } X \in C_k \quad (\text{식 } 4)$$

$$f_j^k(X) = \frac{1}{(2\pi)^{p/2}(\sigma_j^k)^p} \exp\left(-\frac{(X-\mu_j^k)^T(X-\mu_j^k)}{2(\sigma_j^k)^2}\right) < \theta^- \text{ if } X \notin C_k \quad (\text{식 } 5)$$

여기서, $f_j^k(X)$ 는 확률밀도함수이며, k 는 클래스, j 는 훈련유형, X 는 입력데이터이고, p 는 입력유형 차원, μ_j^k 는 훈련유형, σ_j^k 는 평활화계수를 나타내고, C_k 는 k 번째 클래스공간이다.

3. 적응적 확률신경망을 사용한 콘크리트 압축강도 추정

3.1 확률신경망을 위한 훈련패턴 구성

공사현장에서 사용되는 콘크리트는 회사별로 여러 가지 조건을 고려하여 배합설계한 것이다. 일반적으로 슬럼프(slump)시험은 콘크리트를 타설하기 전에 행해지지만, 공시체 압축시험은 타설후 28일에 수행되므로, 공사현장에서 민율만한 압축강도를 예측하기는 매우 어렵다. 본 논문에서는 콘크리트 압축강도를 예측하기 위해 확률신경망을 적용하였다. 확률신경망의 훈련패턴 구성을 위해 배합설계 자료와 슬럼프 값을 입력자료로 사용하고, 각각의 입력

자료에 해당하는 콘크리트 압축강도를 클래스로 정의하였다. 배합설계에 사용된 콘크리트의 재료 물성값은 표 1에 나타난 바와 같으며, 사용된 시멘트는 보통포틀랜드 시멘트, 최대 골재크기는 25mm를 사용하였다. 훈련패턴의 입력자료를 구성하는 9종의 변수들은 표 2에 보인 슬럼프, 물-시멘트 비, 잔골재, 단위 수량, 단위 시멘트 량, 단위 잔 골재, 단위 굵은 골재, 혼화제이다. 그리고, 입력자료에 사용된 모든 변수들을 균등한 가중치를 주기 위해서 0.1과 0.9 사이 값으로 정규화 하였다. 또한, 100~400kgf/cm²까지 10 kgf/cm²씩 증가하는 콘크리트 압축강도를 31개의 클래스로 각각 정의하였다. 본 논문에서는 각 클래스 별로 5, 8, 10, 12, 15, 18 및 21cm의 슬럼프 값 7개 중에서 임의로 5개는 훈련패턴으로 사용하고, 2개는 테스트패턴으로 활용하였다. 훈련패턴의 총 수는 155개, 테스트패턴은 62개이다.

콘크리트의 압축강도는 배합설계 등의 여러 인자들에 의하여 영향을 받고 이를 수학적으로 모형화하는 것은 쉽지 않으므로, 확률신경망과 같은 소프트웨어 기법이 콘크리트 압축강도 예측에 널리 활용되어왔다. 또한 콘크리트 배합비를 기초로 한 압축강도 예측은 입·출력 사이의 사상(mapping)의 문제로 귀결되므로, 입·출력 사이의 상관성이 큰 입력자료를 활용하는 것이 추정 결과에 큰 영향을 미친다. 본 연구에서는 입력자료인 배합설계자료 및 슬럼프 값과 출력자료인 압축강도와의 상관성을 파악하기 위하여 다음의 식 (6)으로 정의되는 상관계수(correlation coefficient)를 활용하였다.

$$R_{xy} = \frac{(x - \mu_x)^T (y - \mu_y)}{\sqrt{\|x - \mu_x\| \|y - \mu_y\|}} \quad (\text{식 } 6)$$

여기서 x, y 는 각각 입·출력자료를, μ_x, μ_y 는 각각 입·출력자료의 평균값을 나타낸다. 그림 4에서는 배합설계 자료와 콘크리트 압축강도의 상관성을 나타내었으며, 0.9 이상의 큰 상관계수를 나타내는 물-시멘트 비, 잔골재율, 단위 시멘트량, 단위 잔골재(s_1, s_2), 혼화제 6개의 변수를 상관성을 고려한 입력자료로 활용하였다.

3.2 적응적 확률신경망을 이용한 패턴인식 검증

각 신경망 모델을 이용한 콘크리트 압축강도 추정의 일반화에 대한 검증을 위하여, 총 217개의 훈련패턴 중에서 각 클래스마다 임의대로 2개의 패턴을 추출하여 테스트패턴으로 활용하였다. 즉, 각 클래스마다 5개의 훈련패턴과 2개의 테스트패턴을 생성하였으며, 총 31개의 클래스에 대하여 155개의 훈련패턴과 62개의 테스트패턴을 사용하여 압축강도 추정을 수행하였다. 그림 5에서는 9개의 입력자료를 모두 확률신경망의 입력자료로 활용한 경우와 상관계수의 절대치가 0.9 이상의 상관성을 보이는 6개의 입력자료만을 이용한 경우에 대한 추정결과를 비교하여 나타내었다. σ 값이 1.0, 0.5, 0.1로 일정한 세 가지 경우에 대하여 각각 압축강도 추정을 수행하였으며, 콘크리트 압축강도 추정의 오차범위와 다음의 식 (7)와 같이 정의되는 평균제곱근오차(RMS error)를 함께 나타내었다.

$$|e_0| = \sqrt{\frac{1}{N} \sum_{i=1}^N f - \hat{f}} \quad (\text{식 } 7)$$

여기서, N 은 테스트패턴의 개수 (62개), f 는 시험 압축강도, \hat{f} 는 예측 압축강도를 각각 나타낸다. 입·출력 사이의 상관성을 고려하여 6개의 입력자료만을 이용하였을 때, 모든 경우에 있어서 오차가 줄어들며, 평균제곱근오차도 작아지는 것을 볼 수 있다. σ 는 1.0, 0.5, 0.1 세 가지 중에 0.1일 때 콘크리트 압축강도의 오차가 가장 적게 나타나는 것을 알 수 있다. 이처럼 일반적인 확률신경망 기법에서는 σ 값이 추정결과에 큰 영향을 미치게 되지만, σ 를 정하는데 있어서 경험적인 방법을 사용하므로 불확실성이 상당히 크다는 단점을 가지고 있다.

앞의 결과에서 살펴본 바와 같이, 확률신경망을 활용한 콘크리트 압축강도의 추정결과는 각 클래스의 확률분포를 결정하기위한 평활화계수에 대한 가정이 필요한 단점이 있다. 따라서 2.2절에서 제안한 적응적 확률신경망을 활용하여 평활화계수를 식 (4, 5)를 통해 계산하고 (그림 6a), 콘크리트의 압축강도 예측을 수행하였다. 적응적 확률신경망에는 상관계수를 고려한 6개의 입력자료를 활용하였다. 그림 6b는 적응적 확률신경망을 활용한 압축강도

추정의 결과를 나타내었다. 평균제곱근오차를 살펴보면 앞의 일반적인 확률신경망에 의한 결과보다 향상된 예측결과를 보이고 있음을 알 수 있다. 표 3에서는 적응적 확률신경망을 통한 압축강도 추정의 예를 나타내었다.

3.3. 시험결과와 비교검증

본 절에서는 상관계수를 고려한 일반적인 확률신경망과 적응적 확률신경망을 이용하여 예측된 콘크리트 압축강도를 실제 회사에서 수행한 압축강도 시험결과와 비교하였다. 콘크리트 압축시험 결과는 공시체 유형, 공시체 크기, 양생조건 및 strain rate 등에 의해 영향을 받는다. 또한, 포트랜드 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 12 cm이며 표 1에서 보여준 배합비에 의해 만들어진 원기둥의 공시체($\phi 100 \times 200mm$)를 이용하였다. 시험 시편은 각각의 공칭강도에 대하여 447, 354, 732개가 사용되었다. 압축강도 시험은 28일의 시기에서 KSF2405와 ASTM C39-93a의 조건을 따라서 수행되었으며, 시험의 결과는 표 4에 나타난 바와 같다.

그림 7에서는 시험결과와 상관성을 고려한 일반적인 확률신경망과 적응적 확률신경망을 이용하여 구한 예측결과를 비교하여 나타내었다. 적응적 확률신경망의 훈련패턴은 3.1 절에서 사용된 155개의 훈련패턴을 사용하였으며, 테스트 패턴은 3.2절의 콘크리트 공칭강도 180, 210, 240 kgf/cm²의 배합자료를 활용하여 구성하였다. 일반적인 확률신경망을 이용하는 경우에는 임의로 정한 σ 의 크기에 따라, 그림 7에 나타난바와 같은 확률적인 분포를 얻을 수 있었지만, 적응적 확률신경망은 식 (4, 5)에 의해 자동적으로 계산되어지는 $\sigma_{m_k}^k$ 에 의해 테스트패턴에 맞는 최적의 확률분포를 나타내었다. 확률 분포의 크기는 편의상 최대값을 1로 정규화하여 비교하였다.

5 결론

본 연구에서는 콘크리트 배합비를 기초로 하여 콘크리트 압축강도를 예측하기 위한 확률론적 방법을 제시하였다. 기존의 일반적인 확률신경망과 입력자료와의 상관계수를 고려하여 입력자료를 선택한 확률신경망에 대해서 비교 검토 하였고, 입력자료와의 상관계수 및 dynamic decay adjustment 알고리즘의 개념을 도입하여 구한 $\sigma_{m_k}^k$ 로 구성된 적응적 확률신경망을 사용하여 콘크리트 압축강도 추정을 수행하였다. 콘크리트 압축강도 시험결과를 활용하여 적응적 확률신경망의 예측 성능을 검증하였으며, 실제 시험결과와 비교를 수행하였다.

일반적인 확률신경망 기법을 활용한 비교결과에서, 배합자료와 압축강도의 상관계수를 구하여 상관성이 큰 입력자료를 활용하는 것이 콘크리트 압축강도의 예측 결과를 크게 향상시킴을 확인하였으며, $\sigma_{m_k}^k$ 를 이용한 적응적 확률신경망이 평활화계수를 자동적으로 계산하므로 불확실성을 크게 개선시키며, 콘크리트 압축강도 추정에 매우 효과적임으로 적용됨을 알 수 있었다.

감사의 글

본 논문은 교량설계핵심기술연구단의 연구비 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 학술 발표회 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., Raczy, 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. M.R. Berthold, J.Diamond, Boosting the performance of RBF networks with dynamic decay adjustment, in: G. Tesaro, D.S. Touretzky, T.K. Leen (Eds.), Advances in Neural Information Processing Systems, 7, The MIT Press, Cambridge, MA, 1995, pp. 521-528.
10. 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.
11. 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.
12. D. F. Specht, "Probabilistic Neural Networks", Neural Networks 3, 1990, pp.109-118
13. Schalkoff RJ., McGraw-Hill, Pattern recognition: statistical, structural and neural approaches, 1997.
14. Parzen, E., "On estimation of a probability density function and mode", Annals of Mathematical Statistics, 33, 1962, pp.1065-1076.
15. Cacoullos, T. "Estimation of a multivariate density", Annals of the Institute of Statistical Mathematics (Tokyo), 18(2), 1966, pp.179-189.
16. 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

표 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)

표 2. 훈련편던 및 클래스로 사용한 배합설계의 예

Specified Strength (kgf/cm ²)	Slump (cm)	Water-cement ratio**	Fine aggregate percentage (%)**	Unit water content (kgf/m ³)	Unit cement content (kgf/m ³)**	Unit fine aggregate content (kgf/m ³)**		Unit coarse aggregate content (kgf/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*	10	59.3	45.7	179	300	325	489	996	0.90
180	18	59.4	47.3	195	328	325	487	930	0.98
210*	8	53.4	44.1	172	321	314	472	1024	0.96
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*	10	48.4	43.5	175	360	303	455	1012	1.08
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
- ** 상관계수를 고려하여 확률신경망의 훈련패턴으로 활용된 자료

표 3. 적응적 확률신경망의 검증용 배합설계자료와 출력결과

Specified Strength (kgf/cm ²)	Slump (cm)	Water-cement ratio**	Fine aggregate percentage (%)**	Unit water content (kgf/m ³)	Unit cement content (kgf/m ³)**	Unit fine aggregate content (kgf/m ³)**		Unit coarse aggregate content (kgf/m ³)	Admixture (%)**	OUTPUT Class
						Natural sand (s1)	Crushed sand (s2)			
100	10	85	50.8	185	218	372	559	926	0.65	100
130	8	73.3	48.1	178	243	352	528	977	0.72	130
160	8	64.2	46.3	175	273	335	503	1001	0.82	160
180*	10	59.3	45.7	178	300	326	489	996	0.90	180
200	10	55.3	44.9	177	319	318	477	1004	0.96	200
210*	8	53.4	44.1	172	321	314	472	1024	0.96	210
220	10	51.7	44.1	175	339	310	466	1009	1.02	220
240*	10	48.4	43.5	175	360	303	455	1012	1.08	240
250	10	46.9	43.2	174	371	300	450	1013	1.12	250
280	10	43.2	42.4	173	401	291	437	1014	1.20	280
310	10	39.9	41.8	172	433	283	424	1011	1.30	310
340	8	36.9	40.8	167	454	275	413	1026	1.38	340
370	12	34.2	41	174	511	266	398	981	1.53	370
400	8	32.2	39.8	165	514	261	392	1016	1.54	390

- * 3.3절에 사용된 훈련패턴과 예측된 클래스
- ** 상관성을 고려한 적응적 확률신경망의 훈련패턴으로 활용된 자료

표 4. 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*)

* 팔호속의 값은 공칭강도와 시험결과와의 오차(%)




그림 1. 전체밀도함수 추정을 위한 Parzen window 방법




그림 3. DDA 알고리즘에 사용되는 상·하한 경계치

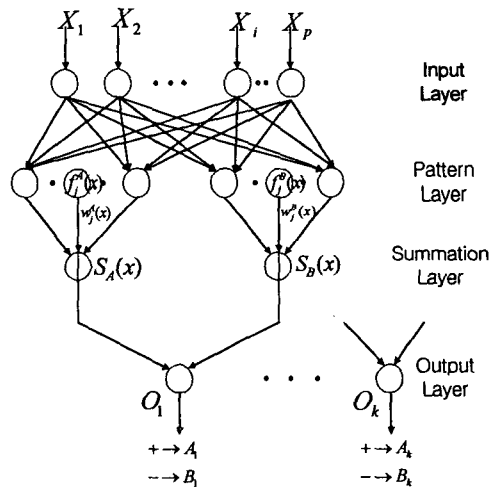


그림 2. 확률신경망의 구조

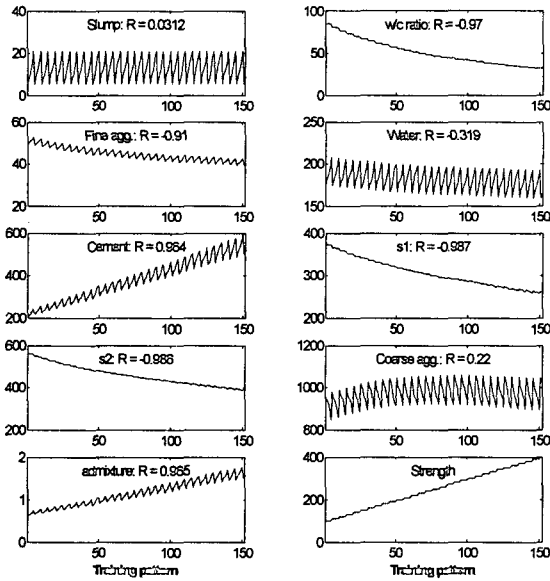


그림 4. 배합자료와 압축강도의 상관성

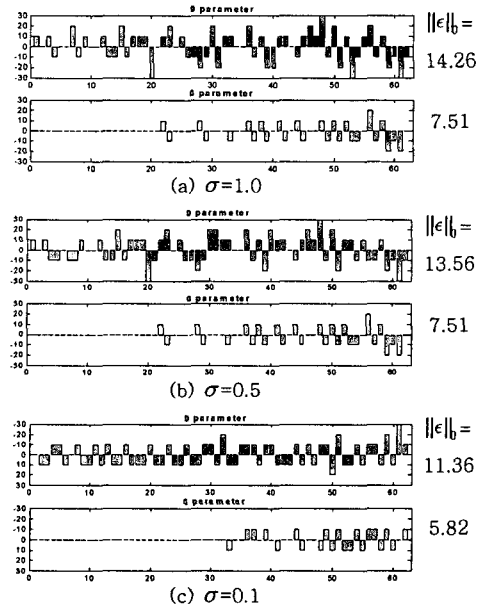




그림 5. 입력자료에 따른 확률신경망의 성능비교



(a) 계산된 평활화계수



(b) 적응적 확률신경망의 추정결과

그림 6. 적응적 확률신경망을 활용한 압축강도의 추정

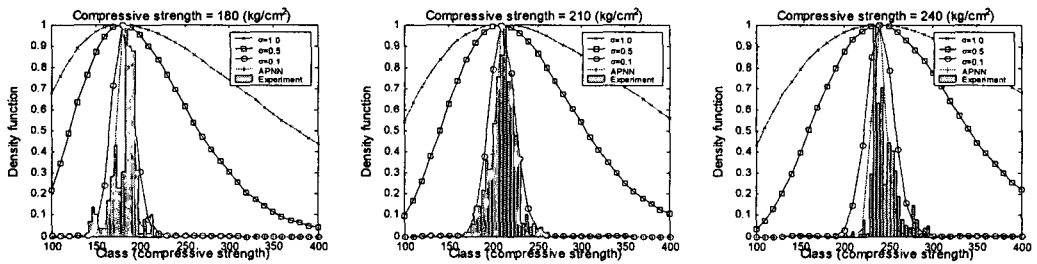


그림 7. 압축강도 분포에 대한 시험결과와 비교