

# 구조공학에서의 확률신경망이론의 응용

## Applications of Probabilistic Neural Networks in Structural Engineering



김 두 기\*



이 종 재\*\*



장 성 규\*\*\*



장 상 길\*\*\*\*

\*군산대학교 토목환경공학부 조교수

\*\*한국과학기술원 스마트 사회기반시설연구센터 연구조교수

\*\*\*군산대학교 토목환경공학부 박사과정

\*\*\*\*군산대학교 토목환경공학부 석사과정

### 1. 서 론

실험의 결과나 표본 등에서 얻은 자료들을 어떤 성질에 따라 동질적인 몇 개의 클래스(class 또는 cluster)로 나누어 분류해야 할 경우, 클래스 분석(class analysis)을 사용할 수 있다. 다변량 통계분석(multivariate analysis) 방법 중에 하나인 클래스 분석이란 N개의 개체들을 대상으로 P개의 변수를 측정했을 경우에, 관측한 P개의 변수들을 이용하여 N개 개체들 사이의 유사성(similarity)의 정도를 거리(distance)로 나타내어(또는 정량화하여), 개체들 거리가 가까운 순서대로 분류하는 통계적 분석 방법이다. 통상적인 클래스 분석의 과정은 다음과 같다.

(1) N개의 개체에 대하여 P개의 변수를 설정하여 측정한다. (2) 모든 개체들간의 거리를 계산하여 거리행렬을 구한다. 여기서 개체간의 거리가 가까울수록 개체간의 유사성이 크다. (3) 거리행렬에 근거하여 개체들을 클래스로 분류한다.

일반적으로 두 개의 벡터  $X_1$ 과  $X_2$ 에 대한 거리를 나타내는 주요 측도로는 Euclidean 거리, Chebychev 거리, City-block(또는 Manhattan) 거리 등이 있으며, 거리는 두 개체간의 유사성이 클수록 가깝고, 적을수록 멀게 나타난다.




그림 1 클래스 영역과 경계에 관한 개념도

확률신경망(Probabilistic Neural Network: PNN)은 Bayesian 의사결정론과 확률밀도함수 추정을 위한 Parzen Window 방법을 조합하여, 어떤 개체가 어떤 클래스에 속하는지를 판별하는 분류자(classifier)이다(그림 1). 확률신경망은 두개 이상의 훈련패턴들에서 학습된 알고리즘으로 모형화하며, 어떤 입력 개체에 대해 클래스들과의 거리를 계산하여 그 개체가 속한 클래스를 결정한다.

확률신경망은 입력층, 학습층, 합산층, 출력층의 4개의 층으로 구성된다. 그러나 역전파(back-propagation) 학습 알고리즘을 이용한 다층퍼셉트론 신경망과는 달리, 입력 패턴을 이용하여 신경망의 연결강도를 학습하는 훈련

과정을 거치지 않는다. 확률신경망은 radial-basis function network 또는 kernel regression의 한 분류로 볼 수 있으며, 다차원 공간에서의 보간(interpolation) 문제에 대하여 radial-basis function을 활용하는 의사결정 방법의 하나로 설명할 수 있다(Haykin, 1994). 확률신경망 기법은 문자인식(Touretzky 등, 1997; Raghu와 Yegnanarayana, 1998), 영상인식(Lin 등, 1997; Chtioui 등, 1997), 의학 및 생명분야(Wang 등, 1998; Holmes 등, 2001), 신호처리(Zaknich, 1998), 금융(Yang 등, 1999), 토목공학(Goh, 2002; Aoki 등, 2002; Sinha와 Pandey, 2002) 등 다양한 분야에 적용되어 왔다. 확률신경망은 기존 신경망에 비하여 뉴런 간의 연결강도를 결정하는 별도의 학습과정이 없으므로, 계산시간이 빠르고, 각 클래스에 대한 확률분포를 먼저 결정하므로 신뢰구간을 생성할 수 있다는 장점이 있다. 그러나 Bayesian 의사결정론에 따라서 출력값을 클래스의 형태로 결정하므로, 패턴분류의 문제에는 적용성이 크나, radial-basis function network 또는 kernel regression과는 달리 regression 문제에는 적용성이 떨어진다.

본 논문에서는 확률신경망의 기본이론에 대한 소개와 함께, 구조공학 문제에 확률신경망 기법을 활용한 예제들을 저자들이 수행해 온 연구를 중심으로 소개하고자 한다.

## 2. 확률신경망 이론

패턴인식을 위한 확률신경망은 유형분류를 위한 Bayesian 의사결정론과 밀도함수 추정을 위한 Parzen이론에 근거한다.

### 2.1 Bayesian 의사결정론

유형을 분류하는 방법은 근본적으로 유형 분류에 있어서 기대위험을 최소화 하는 것이며, Bayesian 의사결정론은 이러한 방법 중에 하나이며, 다수의 클래스를 포함하는 문제에 적용할 수 있다(Cacoullos, 1966). 예를 들어  $\theta$ 가 클래스 A와 B중에 하나인  $\theta_A$  혹은  $\theta_B$ 라고 가정하자. 차수가 p인 벡터  $\mathbf{X} = [X_1, \dots, X_p]^T$ 로 나타낸 측도를 사용하여  $\theta = \theta_A$ 인지  $\theta = \theta_B$ 인지를 결정하는 Bayesian 의사결정론은 다음과 같다.

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

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

여기서  $f_A(\mathbf{X})$ 와  $f_B(\mathbf{X})$ 는 각각 클래스 A와 B에 대한

확률밀도함수(probabilistic density function, PDF)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(priori probability)이고,  $h_B = (1 - h_A)$ 는  $\theta = \theta_B$ 가 될 사전확률이다.

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

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

여기서 K는 다음과 같다.

$$K = h_B l_B / h_A l_A \quad (3)$$

### 2.2 Parzen 이론

Bayesian 의사결정론을 사용할 경우에 사전확률 h와 손실계수 l을 모든 클래스에 대하여 같다고 가정하면, 식 (1a)와 (1b)를 사용하여 유형을 분류하는 경우 확률밀도함수만으로 클래스를 결정한다. Parzen(1962)은 클래스들의 확률밀도함수들의 합이 연속이라면, 이것은 전체 밀도함수로 점근(漸近, asymptotical)한다는 것을 보였다(그림 2).

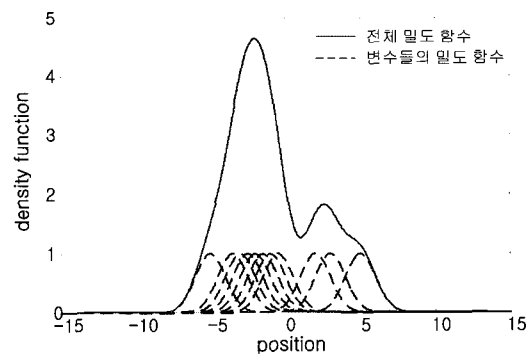


그림 2 전체 밀도함수 추정을 위한 Parzen 방법

그림 2와 같이 각 변수들의 확률밀도함수가 동일한 Gaussian 분포를 가질 경우 Parzen window에 의하여 다음식과 같이 하나의 확률밀도함수로 추정할 수 있다.

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

여기서 m은 모든 훈련패턴의 수,  $\mathbf{X}_{Ai}$ 는 클래스  $\theta_A$ 에서 i번째 훈련 유형,  $\sigma$ 는 편차, 그리고 p는 훈련벡터의 차원

이다.  $f_A(X)$ 는 Gaussian 다변량 분포들의 단순한 합이지만, 반드시 Gaussian일 필요는 없다. 작은  $\sigma$ 를 사용할 경우,  $f_A(X)$ 는 훈련패턴들의 위치에서 서로 완전히 구분되는 극대값(peak)을 갖는 현상을 나타내며, 큰  $\sigma$ 를 사용할수록  $f_A(X)$ 는 점차 평탄화 된다.  $m = \infty$  경우 확률밀도함수는  $\sigma$ 에 상관없이 Gaussian분포로 접근한다.

### 2.3 확률신경망의 구조

그림 3에 입력유형  $X$ 를 두개의 클래스로 분류하는 확률 신경망 구조를 나타냈다. 입력층(input layer)은 모든 훈련 유형에 동일한 입력유형을 입력하는 일종의 분배층이며, 학습층(pattern layer)은 각 훈련패턴에 대해 가중치 벡터  $W_i$ 와 입력유형  $X$ 의 내적( $Z_i = X \cdot W_i$ )을 구한 후, 비선형 활성화 함수(Activation function)에  $Z_i$ 를 입력하여 비선형연산을 수행한다(그림 4).




그림 3 확률신경망의 구조

그림 4에 보인 바와 같이 확률신경망 이론은 기존의 신경망 이론인 역전파 신경망(Rumelhart 등, 1986)에서 사용되었던 sigmoid 활성화 함수 대신에, 비선형 연산자인  $\exp((Z_i - 1)/\sigma^2)$ 를 사용한다.  $X$ 와  $W_i$ 를 단위 크기로 정규화하면, 비선형 연산자는 다음과 같은 형태를 갖는다.





그림 4 학습층의 구조

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

합산층(summation layer)은 앞 식으로 구한 결과들을 클래스 별로 각각 단순히 합하는 역할을 한다. 출력층(output layer)은 합산층에서의 합한 결과가 가장 큰 클래스를 1 나머지는 0으로 출력하여, 최종 클래스를 선택한다.

### 2.4 확률신경망 알고리즘

확률신경망의 학습 알고리즘은 다음 그림과 같다. 입력(P)이 들어왔을 때, 첫 번째 층에서는 훈련패턴과 입력과의 유사도를 나타내는 거리(distance)를 계산한다. 두 번



정의	거리 계산	radbas 함수	compet 함수
P : 테스트 패턴	$IW_{1,1}$ : 입력 가중치 벡터	$a^1 = \text{radbas}(n^1)$	$LW_{2,1}$ : 클래스 가중치 벡터
R : 변수의 수	$b_1$ : 분산에 의한 벡터량	$= e^{-n^1}$	$n^2 = LW_{2,1}$ 과 $a^1$ 행렬 곱
Q : 훈련 패턴 수	dist = Euclidean distance	$n^1$ 값이 작을수록 $a^1$	$a^2 = \text{compet}(n^2)$ : $n^2$ 의 최대값은 1, 나머지는 0으로 출력 함
K : 클래스의 수	$n^1 = \text{dist}$ 와 $b_1$ 내적	1에 근접하게 나타남	

그림 5 확률신경망의 학습 알고리즘

제 층에서는 입력과 훈련유형과의 거리값들의 기여도를 합산하고, 그 값들의 최고 확률값을 뽑아낸다.

위의 과정을 자세하게 설명하면, 훈련패턴이면서 첫 번째 층의 입력가중치인  $W_{1,1}$ 에 확률신경망의 입력이 들어왔을 때 각각의 훈련패턴에 대해서 거리( $\|dist\|$ )를 구한다. 이 값과 평활화 계수 또는 분산( $b1$ )의 내적을 구한 후, radial basis 형태의 전달함수를 통과하여 훈련패턴과 입력패턴의 유사성을 계산한다. 두 번째 층에서는 입력 자료의 각 훈련패턴과의 유사성( $a1$ )과 목표 출력(클래스) 행렬  $LW_{2,1}$  을 곱하여, 입력 자료에 해당하는 출력 클래스 값 ( $n2$ )을 계산하고, 마지막으로 경쟁함수(*compete*)를 통해서 가장 큰 값을 나타내는 클래스에 1을 나머지를 0을 할당하여 출력한다.

### 3. 확률신경망이론의 응용

#### 3.1 콘크리트 압축강도 예측

공사현장에서 사용되는 콘크리트는 회사별로 여러 가지 조건을 고려하여 배합설계 한 것이다. 일반적으로 슬럼프 시험은 콘크리트를 타설 하기 전에 행해지지만 공시체 압축강도 시험은 타설 후 28일에 수행되므로, 공사현장에서 믿을 만한 압축강도를 예측하기는 매우 어렵다. 본 절에서는 A와 B의 두 회사의 실제 배합설계자료를 이용하여 콘

크리트 압축강도를 예측하기 위한 확률신경망을 적용하였다(김두기 등, 2004). 확률신경망의 훈련패턴 구성을 위해 배합설계 자료와 슬럼프 값을 입력자료로 사용하고, 각각의 입력자료에 해당하는 콘크리트 압축강도를 클래스로 정의하였다. 시멘트는 보통포틀랜드 시멘트, 최대 골재크기는 25mm를 사용하였다. 훈련패턴의 입력자료를 구성하는 9종(A회사)과 8종(B회사)의 변수들은 표 1에 보인 슬럼프, 물-시멘트 비, 잔골재, 단위 수량, 단위 시멘트량, 단위 잔골재, 단위 굵은 골재, 혼화제이다. 그리고 입력자료에 사용된 모든 변수들은 균등한 가중치를 주기 위해서 0.1과 0.9 사이 값으로 정규화 하였다. 또한 9.8~39.2MPa 까지 0.98MPa씩 증가하는 콘크리트 압축강도를 31개의 클래스로 각각 정의하였다.

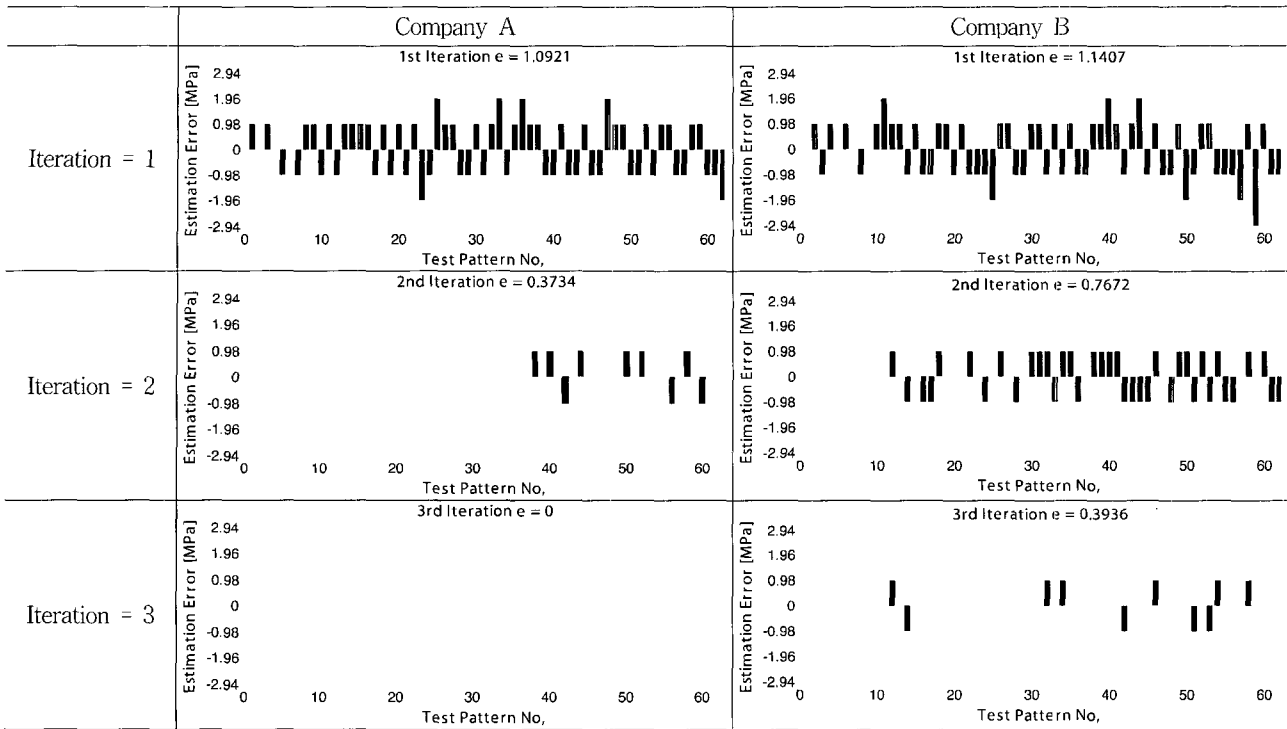
확률신경망을 이용한 콘크리트 압축강도 추정의 일반화에 대한 검증을 위하여, 각 회사의 총 217개의 훈련패턴 중에서 각 클래스마다 임의대로 2개의 패턴을 추출하여 테스트 패턴으로만 활용하였다. 즉, 각 클래스마다 5개의 훈련패턴과 2개의 테스트 패턴을 생성하였으며, 총 31개의 클래스에 대하여 155개의 훈련패턴과 62개의 테스트 패턴을 사용하여 압축강도 추정을 수행하였다. 클래스 추정은 반복연산을 통하여 수행하였다.

표 2는 반복수행을 통한 5결과는 확률신경망의 일반적인 성능뿐만 아니라 수치적인 클래스와 훈련패턴에 대해서 확률신경망의 반복연산 방법이 매우 효과적이라는 것

표 1 훈련패턴 및 클래스로 사용한 배합설계 예

Specified Strength (MPa)	Slump (cm)	W/C weight ratio(%)	Fine aggregate percentage(%)	Unit water content (kN/m <sup>3</sup> )	Unit cement content (kN/m <sup>3</sup> )	Unit fine aggregate content (kN/m <sup>3</sup> )		Unit coarse aggregate content (kN/m <sup>3</sup> )	Admixture (%)	
						Natural sand (s <sub>1</sub> )	Crushed sand (s <sub>2</sub> )			
A	9.8	8	84.9	50.4	1.77	2.09	3.65	5.47	9.22	0.64
	15.68	10	64.2	46.6	1.75	2.73	3.28	4.93	9.67	0.84
	17.64	12	59.4	46.1	1.78	3.00	3.19	4.79	9.59	0.92
	20.58	12	53.5	44.9	1.76	3.29	3.08	4.62	9.70	1.01
	23.52	12	48.5	43.9	1.75	3.61	2.97	4.46	9.75	1.10
	26.46	18	44.3	44.3	1.86	4.20	2.86	4.29	9.23	1.29
	29.4	15	40.9	43.0	1.79	4.38	2.78	4.17	9.47	1.34
	34.3	18	35.7	42.5	1.83	5.14	2.63	3.94	9.12	1.57
	39.2	15	32.1	41.2	1.76	5.50	2.53	3.79	9.26	1.68
B	9.8	8	82.0	54.8	1.69	2.07	10.19	-	8.58	1.06
	15.68	15	63.0	50.4	1.76	2.79	8.98	-	9.01	1.43
	17.64	12	59.0	49.8	1.71	2.91	8.90	-	9.14	1.49
	20.58	12	53.0	48.6	1.70	3.22	8.57	-	9.24	1.65
	23.52	12	49.0	47.8	1.69	3.46	8.35	-	9.29	1.77
	26.46	10	45.0	47.3	1.65	3.65	8.23	-	9.35	1.86
	29.4	15	42.0	46.1	1.72	4.12	7.76	-	9.25	2.10
	34.3	18	37.0	44.9	1.75	4.74	7.29	-	9.11	2.42
	39.2	15	33.0	44.4	1.71	5.14	7.11	-	9.08	2.62

표 2 반복적 분류방법에 의한 오차의 수렴과정



을 보여주고 있다. 즉, 다중 분류의 문제에 있어서 각 클래스를 결정하는 데 사용되는 훈련패턴의 수가 많을수록 각 클래스의 추정결과는 안정적으로 나타날 것으로 예상되며, 이러한 많은 훈련패턴을 확보하기 힘든 경우에는 탐색하고자 하는 대상클래스를 순차적으로 축소시키는 것이 활용 가능하고, 훈련패턴의 중요도를 유지하면서, 다중 분류의 문제를 효과적으로 처리할 수 있는 방법으로 판단된다.

### 3.2 방과제 피복재의 안정수 예측

방과제의 피복재는 반복되는 파랑하중에 대해 본체의 파괴를 방지하기 위해 사용되며, 안정수는 피복재의 안정 질량을 산정하는데 쓰이는 중요한 변수이다. 안정수는 유의파고를 상대밀도와 공칭직경으로 나눈 수로 정의하며, 통상 Hudson(1958)과 van der Meer(1988)의 실험식으로 안정수를 예측하고 그 수를 이용하여 상대밀도와 공칭직경을 구해서 설계에 사용한다. 그러나 Hudson(1958)과 van der Meer(1988)의 식은 모델실험을 통해 도출한 실험 식이므로, 식 자체의 불확실성이 내포되어 있으며, 이러한 불확실성은 안전율을 증가시키는 요인이 되고, 궁극적으로 공사비의 증가를 초래한다. 따라서 방과제의 안정성을 개선하기 위한 많은 노력이 진행되었다. 본 절에서는 van der Meer의 실험 자료 641개를 파랑수가 1000개와 3000

개의 두 경우로 나누어 각각에 대해서 확률신경망 이론을 적용한 경우를 보였다(김두기 등, 2006). 파랑수가 1000개 일 때의 확률신경망을 PNN1, 파랑수가 3000개일 때의 확률신경망을 PNN2로 구성했으며, 각각의 실험 자료는 326개와 315개이다. 확률신경망의 훈련패턴 구성을 위해 Mase 등이 제안한 신경망에서 사용된 투과율, 쇄파상사계수, 피해율, 유의파고에 대한 수심의 비, 스펙트럼 등을 입력자료로, 피복재의 안정수를 출력자료로 사용했으며, 입력자료에 사용되는 모든 변수들은 균등한 가중치를 주기 위해 0.1과 0.9사이의 값으로 정규화 하였다. 출력자료인 피복재의 안정수는 PNN1에서는 1~207까지의 클래스로 정의 하였고, PNN2에서는 1~201까지의 클래스로 정의 하였다. 확률신경망의 패턴인식 검증을 위해서 PNN1과 PNN2의 실험자료 326, 315개 중 각각 207개와 201개를 훈련패턴으로 사용하고, 훈련패턴에 사용되지 않은 실험 자료를 테스트패턴으로 사용하였다.

확률신경망 PNN1과 PNN2를 이용하여 예측된 피복재의 안정수와 van der Meer의 실험식(VM)과 Mase의 인공신경망(ANN)을 이용한 피복재의 안정수를 비교하였다. 그림 6~7은 모든 실험자료를 테스트 패턴으로 사용한 경우 안정수의 예측 결과이다(표 2). 그림 8~9은 훈련패턴에 사용되지 않은 실험자료를 테스트패턴으로 사용한 경우의 안정수 예측 결과를 나타낸다(표 3). 그림에서 가로축은 측정된 안정수, 세로축은 예측된 안정수를 나타내며




그림 6 훈련패턴을 포함한 PNN<sub>1</sub>의 안정수 예측




그림 7 훈련패턴을 포함한 PNN<sub>2</sub>의 안정수 예측




그림 8 테스트유형 만을 사용한 PNN<sub>1</sub>의 안정수 예측




그림 9 테스트유형 만을 사용한 PNN<sub>2</sub>의 안정수 예측

예측된 안정수가 실선에 근접 할수록 안정수 예측성능의 정확함을 나타낸다.

확률신경망의 성능을 합리적으로 평가하기 위하여 일치 지수( $I_a$ )를 사용하였다(Willmott, 1981).

$$I_A = 1 - \frac{\sum_{i=1}^n (P_i - m_i)^2}{\sum_{i=1}^n [ |P_i - \bar{m}| + |m_i - \bar{m}| ]^2} \quad (6)$$

표 3 훈련유형을 포함한 안정수 예측 성능

	VM <sub>1</sub>	VM <sub>2</sub>	ANN <sub>1</sub>	ANN <sub>2</sub>	PNN <sub>1</sub>	PNN <sub>2</sub>
Ia	0.926	0.927	0.959	0.963	0.991	0.990
CC	0.875	0.877	0.925	0.930	0.982	0.981

표 4 테스트유형 만을 사용한 안정수 예측

	ANN <sub>1</sub>	ANN <sub>2</sub>	PNN <sub>1</sub>	PNN <sub>2</sub>
Ia	0.928	0.926	0.955	0.954
CC	0.904	0.896	0.913	0.913

여기서  $P_i$  및  $m_i$ 는 각각 예측된 안정수와 측정된 안정수를 나타내며  $\bar{m}$ 는 측정치의 평균을 나타낸다.  $L_e$  값이 1에 가까워질수록 예측값과 측정값이 일치하는 것을 의미한다.

### 3.3 구조물의 능동제어

확률신경망 이론을 구조물의 능동제어에 적용한 예를 보였다(김두기 등, 2007). 지진하중과 제어력을 받는  $n$ 자유도의 구조물의 운동방정식은 다음과 같다.

$$[M]\{\ddot{u}\} + [C]\{\dot{u}\} + [K]\{u\} = [\overline{L}_c]\{f_c\} + [\overline{L}_e]\{f_e\} \quad (7)$$

여기서  $[M]$  및  $[C]$ ,  $[K]$ 는 각각 구조물의 질량, 감쇠 및 강성행렬;  $\{u\}$ 는 구조물의 상대변위;  $\{f_c\}$ 는 제어력,  $\{f_e\}$ 는 지진하중으로 다음과 같으며,  $[\overline{L}_c]$  행렬과  $[\overline{L}_e]$  행렬은 각각 제어력과 외력의 작용 위치를 나타내고 있는 위치 행렬이다. 이 운동방정식은 다음의 상태-공간 방정식으로 나타낼 수 있다.

$$\{\dot{z}\} = [A]\{z\} + [L_c]\{f_c\} + [L_e]\{f_e\} \quad (8)$$

$$\{z\} = \begin{Bmatrix} u \\ \dot{u} \end{Bmatrix} \quad (9)$$

$$[A] = \begin{bmatrix} 0 & 1 \\ -M^{-1}K & -M^{-1}C \end{bmatrix} \quad (10)$$

$$[L_e] = \begin{bmatrix} 0 \\ M^{-1}\overline{L}_e \end{bmatrix} \quad (11)$$

$$[L_c] = \begin{bmatrix} 0 \\ M^{-1}\overline{L}_c \end{bmatrix} \quad (12)$$

여기서  $\{z\}$ 는 상태벡터,  $[A]$ 는 시스템 행렬,  $[L_c]$  행렬과  $[L_e]$  행렬은 상태공간에서 제어기와 외력의 위치행렬을 나타낸다.

확률신경망의 훈련패턴을 구성하기 위하여 LQR 제어 알고리즘을 사용하였다. LQR제어 방법에 따라, 제어력  $\{f_c\}$ 는 다음의 성능지수(performance index)  $J$ 에 의해 선택된다.

$$J(f_c) = \int_0^t (\{Z\}^T [Q] \{Z\} + \{f_c\}^T [R] \{f_c\}) dt \quad (13)$$

식 (13)에서,  $[Q]$  과  $[R]$ 는 각각  $2n \times 2n$ ,  $m \times m$ 의 가중치 행렬이며, 다음 식에 의해 최적의 제어력을 구할 수 있다.

$$\{f_c\} = -[G]\{Z\} = -[R]^{-1}[L_c^T][S]\{z\} \quad (14)$$

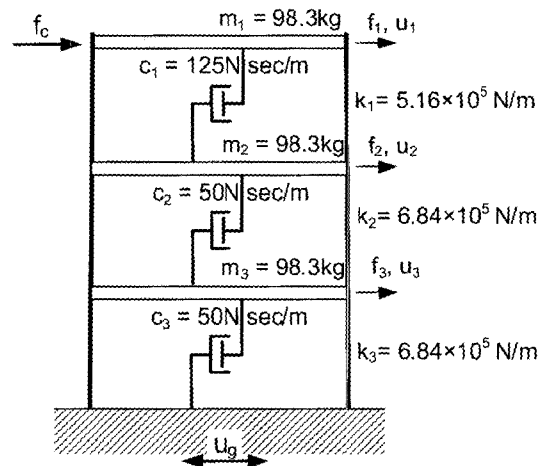


그림 10 ATS가 설치된 3층 전단건물

여기서  $[G]$ 는 제어이득(control gain)으로, 다음 식에서 얻어지는 리카티 방정식(Riccati equation)의 해인  $[S]$ 에 의해 구할 수 있다.

$$[A^T][S] + [S][A] - [S][L_c][R]^{-1}[L_c^T][S] + [Q] = 0 \quad (15)$$

따라서 제어력  $\{f_c\}$ 는 시스템의 상태벡터  $\{z\}$ 와 제어이득  $[G]$ 의 곱으로 계산된다.

확률신경망 기법으로 구조물의 능동제어를 수행하기 위하여 그림 10의 능동텐던시스템(Active Tendon System, ATS)이 설치된 3층 전단건물을 사용하였다.

질량 및 감쇠, 강성은 각각  $M = [98.3 \ 98.3 \ 98.3]$ (kg),  $C = [125 \ 50 \ 50]$ (N sec/m),  $K = [5.16 \ 6.84 \ 6.84] \times 10^5$ (N/m)이며, 질량, 감쇠, 강성 행렬은 다음과 같다.

$$[M] = \begin{bmatrix} 98.3 & 0 & 0 \\ 0 & 98.3 & 0 \\ 0 & 0 & 98.3 \end{bmatrix}$$

$$[C] = \begin{bmatrix} 175 & -50 & 0 \\ -50 & 100 & -50 \\ 0 & -50 & 50 \end{bmatrix}$$

$$[K] = \begin{bmatrix} 12.0 & -6.84 & 0 \\ -6.84 & 13.68 & -6.84 \\ 0 & -6.84 & 6.84 \end{bmatrix} \times 10^5$$






그림 11 PNN 제어의 블록 다이어그램



(a) 3층에서의 변위



(b) 3층에서의 속도

그림 12 PNN 제어 전·후의 그래프

El Centro 및 Hachinohe, California, KS 인공지진에 대해서 LQR 제어 알고리즘을 이용하여 구조물의 상태벡터와 제어력을 구하고, 이를 확률신경망의 훈련패턴으로 사용하였다. 확률신경망을 이용한 구조물의 제어를 검증하기 위하여 새로운 Northridge 지진을 사용하였다. 그림 11은 구조물의 능동제어를 Matlab Simulink의 블록 다이어그램으로 나타내었다.

Northridge 지진에 대한 변위와 속도의 제어전과 제어후의 결과를 그림 12에 나타내었으며, 3층의 변위와 속도의 감소율은 54.5% 및 49.2%로 나타났다.

### 3.4 구조물의 손상진단

확률신경망 기법은 여러 연구자들에 의하여 토목구조물의 손상진단 및 예측에 활용이 되어왔다. Ni 등(2000)은 수치모의실험을 통하여 Ting Kau 사장교의 손상유형과 손상위치를 찾는 연구를 수행하였으며, 조효남 등(2002)은 교량의 손상위치와 손상정도를 추정하기 위한 이단계 접근법을 수치모의 실험을 통하여 검증하였다. Aoki 등(2002)은 지진약도 분석을 위하여 화학공장의 파괴메카니즘을 PNN기법을 활용하여 분석하였으며, 이창용 등(2000)은 확률신경망 기법을 활용하여 노후된 상수도 관의 교체와 갱생의 우선 순위를 판단할 수 있는 모형을 수립하였다. 이와 같이 확률신경망 기법을 활용하여 구조물의 상태를 예측하는 시스템의 개발은 실제 데이터를 중심으로 많은 연구가 되어졌으나, 구조물의 손상추정과 관련하여 실제 구조물의 손상에 적용된 예는 극히 드물다. Lee와 Yun(2006)은 실제 강교량에 대한 손상실험을 수행하고 손





그림 13 현장 실험 교량

	Class 1		Class 2			Class 3		Class 4		
G1	1	2	3	4	5	6	7	8	9	10
G2	Class 5		Class 6			Class 7		Class 8		
	11	12	13	14	15	16	17	18	19	20
G3	Class 9		Class 10			Class 11		Class 12		
	21	22	23	24	25	26	27	28	29	30
G4	Class 13		Class 14			Class 15		Class 16		
	31	32	33	34	35	36	37	38	39	40
G5	Class 17		Class 18			Class 19		Class 20		
	41	42	43	44	45	46	47	48	49	50
G6	Class 21		Class 22			Class 23		Class 24		
	51	52	53	54	55	56	57	58	59	60
G7	Class 25		Class 26			Class 27		Class 28		
	61	62	63	64	65	66	67	68	69	70
G8										
G9										


그림 14 손상위치에 따라 분류된 클래스

상의 위치를 추정하기 위한 이 단계 접근법을 제안하면서 확률신경망 기법을 적용하여 손상의 위치를 추정하였다. 손상의 위치를 부재의 위치에 따라서 그룹화하고 클래스로 정의하였으며, 손상 진후에 상시진동 데이터로부터 구한 모드형상의 차이를 입력자료로 활용하였다. 부재 수가 많은 경우, 즉 추정할 클래스의 수가 많은 경우를 효율적으로 처리하기 위하여 손상의 발생에 따른 손상위치를 단계적으로 추정하는 기법을 활용하였다.






(a) Damage Case I



(b) Damage Case II



(c) Damage Case III



(d) Inflicted Damage by Torch

그림 15 손상시나리오




그림 16 확률신경망 기법을 이용한 손상위치 추정결과

#### 4. 참고문헌

1. Aoki, T., Ceravolo, R., De Stefano, A., Genovese, C. and Sabia, D. (2002) Seismic vulnerability assessment of chemical plants through probabilistic neural networks, *Reliability engineering & system safety*, 77(3), pp. 263~268.
2. Cacoullos, T. (1966) Estimation of a multivariate density, *Annals of the Institute of Statistical Mathematics (Tokyo)*, 18(2), pp. 179~189.
3. Chtioui, Y., Bertrand, D., Devaux, M.F. and Barba, D. (1997) Comparison of multilayer perceptron and

probabilistic neural networks in artificial vision. Application to the discrimination of seeds, *Journal of chemometrics*, 11(2), pp.111~129.

4. Goh, A. T. C. (2002) Probabilistic neural network for evaluating seismic liquefaction potential, *Canadian geotechnical journal: Revue canadienne de géotechnique*, 39(1), pp. 219~232.
5. Haykin, S. (1994) *Neural networks—a comprehensive foundation*, New York: Macmillan.
6. Holmes, E., Nicholson, J. K., and Tranter, G. (2001) Metabonomic characterization of genetic variations in toxicological and metabolic responses using probabilistic neural networks, *Chemical research in toxicology*, 14(2), pp. 182~191.
7. Hudson, R.Y. (1958) Design of Quarry Stone Cover Layer For Rubble Mound Breakwaters. Research Report (2-2). Waterways Experiment Station, Coastal Engineering Research Centre, Vicksburg, Miss.
8. Lee, J.J. and Yun, C.B. (2006) Two-Step Approaches for Effective Bridge Health Monitoring, *Structural Engineering and Mechanics*: 23(1), pp. 75~95.
9. Lin, S. H., Kung, S. Y. and Lin, L. J. (1997) Face recognition/detection by probabilistic decision-based neural network, *IEEE transactions on neural networks*, 8(1), pp. 114~132.
10. Ni, Y.Q., Zhou, X.T., Ko, J.M. and Wang, B.S. (2000) Vibration-based damage localization in Ting Kau Bridge using probabilistic neural network,

- Advances in Structural Dynamics, J.M. Ko and Y.L. Xu (eds.), Elsevier Science Ltd., Oxford, UK, 2, pp. 1069~1076.
11. Parzen, E. (1962) On estimation of a probability density function and mode, *Annals of Mathematical Statistics*, 33, pp 1065~1076.
  12. Raghu, P.P. and Yegnanarayana, B. (1998) Supervised texture classification using a probabilistic neural network and constraint satisfaction model, *IEEE transactions on neural networks*, 9(3), pp. 516~522.
  13. Rumelhart, D. E., McClelland, J. L. and the PDP Research Group. (1986) *Parallel distributed processing*, The MIT Press, Cambridge, MA, 1.
  14. Sinha, S. K. and Pandey, M. D. (2002) Probabilistic neural network for reliability assessment of oil and gas pipelines, *Computer-aided civil and infrastructure engineering*, 17(5), pp. 320~329.
  15. Touretzky, D.S., Thibadeau, R.H. and Romero, R.D. (1997) Optical Chinese character recognition using probabilistic neural networks, *Pattern recognition*, 30(8), pp. 1279~1292.
  16. van der Meer, J.W. (1988) Deterministic and probabilistic design of breakwater armor layers, *J. Wtrwy. Port Coast., Ocean Eng.*, 114(1), pp. 66~80.
  17. Wang, Y., Adali, T., Kung, S. Y. and Szabo, Z. (1998) Quantification and segmentation of brain tissues from MR images: a probabilistic neural network approach, *IEEE transactions on image processing*, 7(8), pp. 1165~1181.
  18. Willmott, C.J. (1981) On the validation of models, *Phys. Geogr.*, 2(2), pp. 184~194.
  19. Yang, Z. R., Platt, M. B. and Platt, H. D. (1999) Probabilistic neural networks in bankruptcy prediction, *Journal of business research*, 44(2), pp. 67~74.
  20. Zaknich, A. (1990) Introduction to the modified probabilistic neural network for general signal processing applications, *IEEE transactions on signal processing : a publication of the IEEE Signal Processing Society*, 46(7), pp. 1980~1990.
  21. 김두기, 김동현, 장성규, 장상길 (2006) 확률신경망을 이용한 방파제 피복재 설계, *한국해양공학회지 논문집*, 20(5).
  22. 김두기, 이종재, 장성규 (2004) 콘크리트 압축강도 추정을 위한 확률 신경망, *한국구조물진단학회지 논문집*, 8(2), p. 159~167.
  23. 김두기, 이종재, 장성규, 최인정 (2007) 지진하중을 받는 구조물의 능동제어를 위한 확률신경망 이론, *한국구조물진단학회지 논문집*, 11(1).
  24. 이창용, 김용석, 신현석, 김중훈 (2000) 확률적 신경망을 이용한 상수도관 노후도 추정에 관한 연구, *대한토목학회 논문집*, 20(2-B), p. 197~210.
  25. 조효남, 강경구, 이성철, 허춘근 (2002) 확률신경망에 기초한 교량구조물의 손상평가, *한국구조물진단학회 논문집*, 6(4), p. 169~179. 