

확률신경망을 이용한 방파제 피복재 설계

김두기* · 김동현** · 장성규* · 장상길*

*군산대학교 토목환경공학부

**군산대학교 해양시스템공학과

Estimation of the Stability Number of Breakwater Armor Blocks Using Probabilistic Neural Networks

DOO-KIE KIM*, DONG-HYAWN KIM**, SEONG-KYU CHANG* AND SANG-KIL CHANG*

*Department of Civil and Environmental Engineering, Kunsan National University, Kunsan, Jeonbuk, Korea

**Department of Ocean System Engineering, Kunsan National University, Kunsan, Jeonbuk, Korea

KEY WORDS: Breakwater 방파제, Armor block 피복재, Stability number 안정수, Probabilistic neural network 확률신경망, Training pattern 학습유형

ABSTRACT: A Probabilistic neural network (PNN) technique for predicting the stability number for the armor blocks of breakwaters is presented. A PNN is prepared using the experimental data of van der Meer and is then compared with the empirical formula and previous artificial neural network (ANN) model. This comparison shows that a PNN can effectively predict the stability numbers in spite of data complexity, incompleteness, and incoherence, and can be an effective tool for the designers of rubble mound breakwaters to support their decision process and to improve design efficiency.

1. 서 론

방파제의 피복재는 반복되는 파랑하중에 대해 본체의 파괴를 방지하기 위해 사용한다. 이러한 피복재의 설계시 피복재의 안정수는 피복재의 안정질량을 산정하는데 쓰이는 중요한 변수이다. 안정수는 유의파고를 상대밀도와 공칭직경으로 나눈 수로 정의하며, 통상 Hudson(1958)과 van der Meer(1988a)의 실험식으로 안정수를 예측하고 그 수를 이용하여 상대밀도와 공칭직경을 구해서 설계에 사용한다. 그러나 Hudson(1958)과 van der Meer(1988a)의 식은 모델실험을 통해 도출한 실험식이므로, 식 자체의 불확실성이 내포되어 있으며, 이러한 불확실성은 안전율을 증가시키는 요인이 되고, 궁극적으로 공사비의 증가를 초래한다. 따라서 방파제의 안정식을 개선하기 위한 많은 노력이 진행되었다.

Kaku(1990)와 Kaku et al. (1991)은 van der Meer 실험결과를 이용해서 피해를 예측하는 실험식을 개발한 바 있고, Smith et al. (1992)은 그들의 실험식과 Kaku(1991)의 실험식과 비교한 바 있다. Hanzawa et al. (1996)이 새로운 실험결과에 근거한 안정식들을 새롭게 제안하였지만, 그 정확성은 현저하게 개선되지 않았다. 최근 Mase et al. (1995)은 인공신경망(Artificial neural network)을 방파제 피복재의 설계에 도입하여 실제로 피해를 예측의 정확도를 기존의 van der Meer 실험식보다 향상시

킨 바 있다. Kim et al., (2005)은 5가지 개선된 인공신경망 모델을 통하여 안정수를 예측 하고, Level III 신뢰성 해석법의 하나인 Monte Carlo모사법을 접목시켜 파괴확률값을 산정하였으며, 그 결과 안정수 예측성능이 우수한 신경망 모델을 사용할수록 파괴확률 값이 낮게 산정된 다는 것을 밝히며 있다. 일반적으로 인공신경망을 사용할 경우 추정결과가 확정적인 값으로 나타나게 되며, 훈련패턴을 이용하여 신경망을 학습시키는데 많은 시간이 걸리는 단점이 있다. 반면 확률신경망을 사용할 경우 신경망을 구성하는데 훈련패턴을 직접 이용하므로, 신경망을 학습시키는 과정이 필요하지 않아 해석시간이 비교적 적게 걸리고, 해석 결과도 확률적인 분포 값으로 나타난다는 장점이 있다. 또한 안정수 예측에 영향을 주는 새로운 유형의 자료가 추가 될 경우에 기존의 신경망 이론은 재학습을 통해 신경망을 새로이 구성해야 하나, 확률신경망 이론은 새로운 유형을 독립된 별개의 유형으로 쉽게 고려할 수 있다는 장점이 있다(Kim and Park, 2005).

본 연구에서는 확률이론과 신경망 이론을 결합한 확률신경망을 사용하여 방파제 피복재의 안정수를 예측 하였고, van der Meer의 실험식과 인공신경망의 결과와 비교하였다.

2. van der Meer의 실험식

van der Meer(1988b)는 불규칙파랑의 조건하에서 수행한 실험결과를 이용하여 안정식을 개발하였으며, 이 식은 방파제 피복재의 안정성 평가용으로 널리 이용된다. van der Meer는 우

교신저자 김동현: 전북 군산시 군산대학교 해양시스템공학과
063-463-9493 eastlite@nate.com

선 안정에 크게 영향을 미치는 설계변수로 유의 파고(H_s), 평균 주기(T_m), 상대밀도($D = \rho_s/\rho_w - 1$), 공칭직경(D_{n50}), 공극율(P), 내습파랑수(N_w), 경사각(α), 피해율(S_d) 등을 선정하여 안정수 예측식을 다음과 같이 제시하였다.

$$N_s = \begin{cases} 6.2P^{0.18} \left(\frac{S_d}{\sqrt{N_w}}\right)^{0.2} \frac{1}{\sqrt{\xi_m}} & \xi_m < \xi_c \\ 1.0P^{-0.13} \left(\frac{S_d}{\sqrt{N_w}}\right)^{0.2} \sqrt{\cot\alpha \xi_m^P} & \xi_m \geq \xi_c \end{cases} \quad (1)$$

여기서 N_s 는 다음과 같이 정의된 안정수이다.

$$N_s = H_s / \Delta D_{n50} \quad (2)$$

그리고 피해율(S_d)은 방파제의 피해단면(A)을 이용하여 다음과 같이 정의된다.

$$S_d = A / D_{n50}^2 \quad (3)$$

또한 ξ_m 은 Surf similarity parameter라고 하며 다음과 같은 무차원변수로 정의된다.

$$\xi_m = \frac{\tan\alpha}{\sqrt{2\pi H_s/gT_m^2}} \quad (4)$$

$$\xi_c = (6.2P^{0.31} \sqrt{\tan\alpha})^{(1/(P+0.5))} \quad (5)$$

Fig. 1은 van der Meer의 641회 실험에서 구한 결과를 실험식 결과와 비교하여 나타낸 것이다. 그림으로부터 실험결과와 예측결과 사이에는 무시할 수 없을 정도의 오차가 발생할 수 있음을 알 수 있다. 이러한 오차는 설계시 안전계수의 증가를 유발시키며 궁극적으로는 공사비의 증가로 이어질 수 있기 때

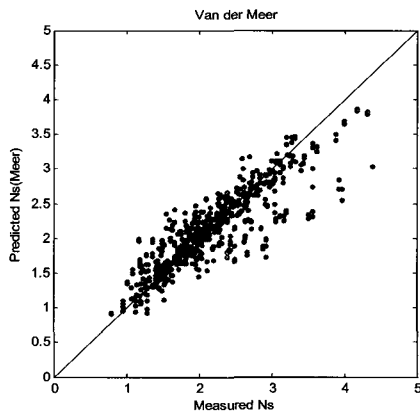


Fig. 1 Stability numbers predicted by van der Meer

문에 보다 정확한 안정수 예측식의 개발이 요구된다.

3. 확률신경망

실험의 결과나 표본 등에서 얻은 자료들을 어떤 성질에 따라 동질적인 몇 개의 클래스로 나누어 분류할 경우가 있다. 다변량 통계분석 방법중에 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 통계분석 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(Chebychev distance), 시가 거리(City-block 또는 Manhattan distance)등이 있으며, 거리는 두 개체간의 유사성이 클수록 작고, 작을수록 크게 나타난다.

확률신경망은 어떤 개체가 어떤 클래스(Class)에 속하는지를 판별하는 분류자이다(Specht, 1990). 확률신경망은 두 개 이상의 훈련패턴들에서 학습된 알고리즘으로 모형화되며, 어떤 입력 개체에 대해, 클래스들과의 거리를 계산하고, 그 개체가 속한 클래스를 결정한다.

3.1 Bayesian decision 이론

유형을 분류하는 방법은 근본적으로 유형 분류에 있어서 기대 위험을 최소화 하는 것이다. 이런 방법 중에는 "Bayesian 확률 방법"이 있고 이 방법은 다수의 클래스를 포함하는 문제에 적용할 수 있다. 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.




Fig. 2 Pattern classification by PNN

$$h_{A'} l_A f_A(X) > h_{B'} l_B f_B(X) \text{ 인 경우 } d(X) = \theta_A \quad (6a)$$

$$h_{A'} l_A f_A(X) < h_{B'} l_B f_B(X) \text{ 인 경우 } d(X) = \theta_B \quad (6b)$$

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

$$f_A(X) = K f_B(X) \quad (7)$$

여기서 K 는 다음과 같다.

$$K = h_{B'} l_B / h_{A'} l_A \quad (8)$$

모든 확률밀도함수는 항상 양이고, 적분가능하고, 전체 면적은 1이라는 제한조건 이외에 어떠한 제약도 없으므로, 식 (8)로 정의 한 2개 클래스의 영역경계는 매우 복잡할 수 있다. 식 (7)를 사용하는데 있어서 중요한 것은 훈련패턴에 기초한 확률밀도 함수를 추정하는 것이다.

3.2 밀도함수 추정을 위한 Parzen window

Bayesian 확률방법을 사용할 경우에 사전확률 h 와 손실계수 l 을 모든 클래스에 대하여 같다고 가정하면, 식 (7)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(1962)은 클래스들의 확률밀도함수들의 합이 연속이라면, 이것은 전체 밀도함수로 점근(Asymptotical)한다는 것을 보였다(Fig. 3). Gaussian 분포의 경우, 다변량 추정값은 다음과 같다.(Cacoullos, 1966)

$$f_A(X) = \frac{1}{(2\pi)^{p/2} \sigma^p} \frac{1}{m} \sum_{i=1}^m \exp\left(-\frac{|X - X_{Ai}|}{2\sigma^2}\right) \quad (9)$$

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 점근할 수도 있다. 작은 σ 를 사용할 경우, $f_A(X)$ 는 훈련패턴들의 위치에서 서로 완전히 구분되는 피크값을 가지는 형상을 나타내




Fig. 3 Parzen's density estimation

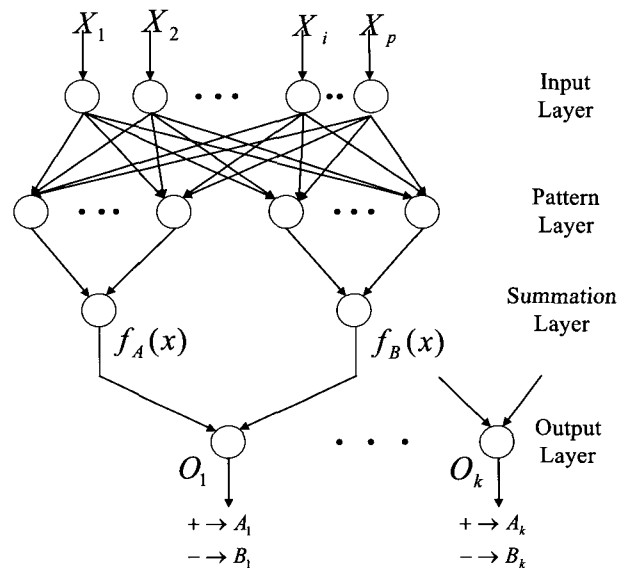


Fig. 4 Structure of PNN

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

3.3 확률신경망의 구조

Fig. 4에 입력유형 X 를 두개의 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 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 Fig. 5. 또한, 합산층 (Summation layer)은 학습층에서 구한 비선형 출력결과를 합산한다(Fig. 6).

Fig. 5에 보인 바와 같이 확률신경망 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. X 와 W_i 를 단위 크기로 정규화하면, 식 (9)는 다음과 같다.

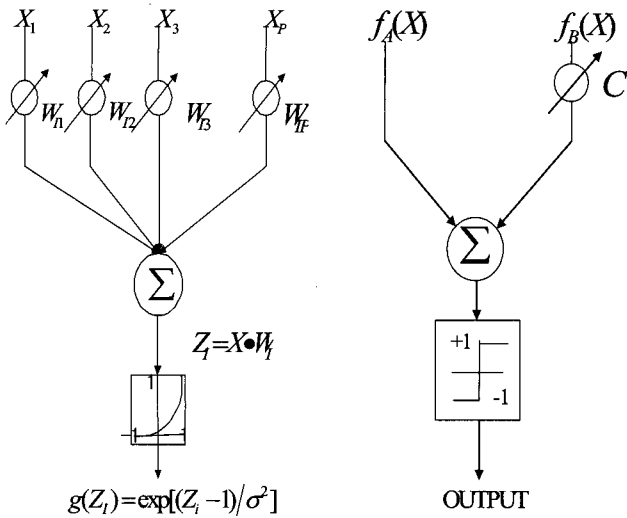


Fig. 5 Structure of pattern layer Fig. 6 Structure of output layer

$$\exp[-(W_i - X)^T(W_i - X)/2\sigma^2] \quad (10)$$

합산층은 식 (10)으로 구한 결과들을 클래스 별로 각각 단순히 합하는 역할을 한다.

출력층은 Fig. 6에 보인 바와 같이 2개의 입력 신경을 갖고, 하나의 가중치 C를 가지고 있으며, 0과 1로 구성된 2진수를 출력한다. k번째 출력 절점에서 가중치 C_k는 다음과 같다.

$$C_k = -\frac{h_B l_B}{h_A l_A} \cdot \frac{n_A}{n_B} \quad (11)$$

여기서 n_A는 클래스 A_k에 대한 훈련유형의 수이고, n_B는 클래스 B_k에 대한 훈련유형의 수이며, 결정을 특별히 한쪽으로 치우치게 할 이유가 없다면 C_k는 -1로 놓을 수 있다. 또한 Fig. 3에 보인 바와 같이, 훈련 유형이 많을 경우에 학습층을 균집으로 분류할 수도 있다

4. 확률신경망을 사용한 피복재 안정수 예측

4.1 훈련패턴 구성

본 연구에서 van der Meer의 실험 자료 641개를 파랑수가 1000개와 3000개의 두 경우로 나누어 각각에 대해서 확률신경망 이론을 적용하였다. 파랑수가 1000개일 때의 확률신경망을 PNN₁, 파랑수가 3000개일 때의 확률신경망을 PNN₂로 구성했으며, 각각의 실험 자료는 326개와 315개이다. 확률신경망의 훈련 패턴 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 하였으며, 출력자료인 피복재의 안정수는 1~130까지의 Class로 정의 하였다. 확률신경망의 패턴

인식 검증을 위해서 PNN₁과 PNN₂의 실험자료 326, 315개 중 각각 130개를 훈련패턴으로 사용하고, 모든 실험자료를 테스트 패턴으로 이용하였다. 또한 확률신경망의 검증 성능을 위해서 훈련패턴에 사용되지 않은 실험자료를 테스트패턴으로 사용하였다.

4.2 결과

본 절에서는 확률신경망 PNN₁과 PNN₂를 이용하여 예측된 피복재의 안정수와 측정된 안정수를 비교하였다. 또한 van der Meer의 실험식(VM)과 Mase의 인공신경망(ANN)을 이용하여 예측된 피복재의 안정수도 비교해 보았다. 확률신경망과 동일한 조건하에서의 비교를 위해 van der Meer의 실험식과 Mase의 인공신경망도 파랑수가 1000과 3000으로 구분하여 비교하였다. 그림에서 사용된 아래첨자 1은 파랑수가 1000, 2는 3000을 나타내며, Fig. 7~Fig. 12는 모든 실험자료를 테스트패턴으로 사용한 경우 안정수의 예측 결과를 나타낸다. 그림에서 가로축은 측정된 안정수, 세로축은 예측된 안정수를 나타내며 예측된 안정수가 실선에 근접 할수록 안정수의 예측성능 정확함을 나타낸다.

Fig. 13~Fig. 16은 훈련패턴에 사용되지 않은 실험자료를 테스트패턴으로 사용한 경우이다. 또한 확률신경망의 훈련패턴의 수에 따른 안정수 예측 성능을 분석하기 위하여 Fig. 17~Fig. 18과 같이 훈련패턴의 수에 따른 안정수 예측성능경향을 나타내며 일반적으로 훈련패턴 수의 증가에 따라 일치지수가 점차 증가함을 알 수 있다. 이 때 사용된 테스트패턴은 훈련패턴에 사용되지 않은 것이다.

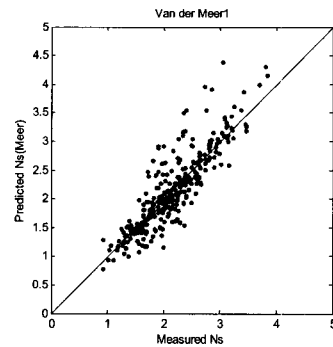


Fig. 7 Stability numbers predicted by van der Meer₁




Fig. 8 Stability numbers predicted by van der Meer₂




Fig. 9 Stability numbers predicted by ANN₁ with all patterns including training patterns




Fig. 13 Stability numbers predicted by ANN₁ with only untrained patterns




Fig. 10 Stability numbers predicted by ANN₂ with all patterns including training patterns.

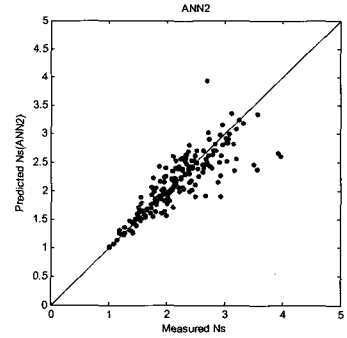


Fig. 14 Stability numbers predicted by ANN₂ with only untrained patterns




Fig. 11 Stability numbers predicted by PNN₁ with all patterns including training patterns

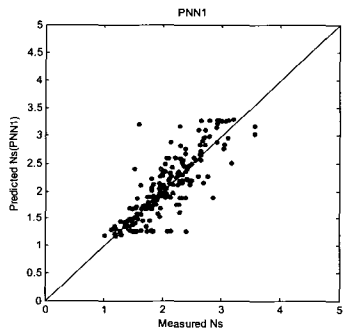


Fig. 15 Stability numbers predicted by PNN₁ with only untrained patterns

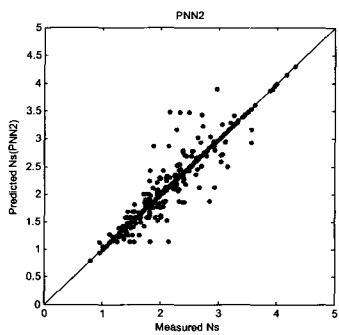


Fig. 12 Stability numbers predicted by PNN₂ with all patterns including training patterns




Fig. 16 Stability numbers predicted by PNN₂ with only untrained patterns




Fig. 17 I_a of PNN₁ according to the number of trained patterns




Fig. 18 I_a of PNN₂ according to the number of trained patterns

본 연구에서 제시한 확률신경망의 성능을 합리적으로 평가하기 위하여 일치지수(I_a)와 상관계수(C_a)를 사용하였다(Willmott, 1981).

$$I_A = 1 - \frac{\sum_{i=1}^n (P_i - m_i)^2}{\sum_{i=1}^n (|P_i - \bar{m}| + |m_i - \bar{m}|)^2} \quad (12)$$

$$C_a = \frac{(x - \mu_x)^T (x - \mu_y)}{\sqrt{\|x - \mu_x\| \|y - \mu_y\|}} \quad (13)$$

식 (12)에서 e_i 및 m_i 는 각각 예측된 안정수와 측정된 안정수를 나타내며 \bar{m} 는 측정치의 평균을 나타낸다. I_a 값이 1에 가까워질수록 예측값과 측정값은 일치함을 의미한다. 식 (13)에서 x 와 y 는 각각 예측, 측정된 안정수를 나타내며 μ_x, μ_y 는 각각의 평균값을 나타낸다.

본 논문에서는 확률신경망의 유용성을 검증하기 위하여 모든 실험자료를 테스트패턴으로 이용한 경우에 대해서 안정수를 예측하였다. 위의 결과를 Table 1에 나타냈으며, 기존에 van der Meer식과 인공신경망의 결과와 비교하여 확률신경망의 일치지수와 상관계수가 높은 것으로 나타났으며, 확률신경망의 유용성을 검증할 수 있었다. 확률신경망이 방파제 피복재의 안정수 예측에 대한 일반화를 검증하기 위해 훈련패턴에 사용되

지 않은 실험자료를 테스트패턴으로 이용하여 방파제 피복재의 안정수를 예측하였다(Table 2). 훈련패턴의 수에 따른 안정수의 예측 정확성을 일치지수와 상관계수를 통하여 비교 하였고 Table 3에 나타냈다.

Table 1 Performance of stability models tested by all the experimental data

	Models					
	VM ₁	VM ₂	ANN ₁	ANN ₂	PNN ₁	PNN ₂
Ia	0.927	0.927	0.956	0.961	0.965	0.962
Ca	0.875	0.877	0.924	0.925	0.934	0.928

Table 2 Performance of stability models tested by untrained patterns

	Models			
	ANN ₁	ANN ₂	PNN ₁	PNN ₂
Ia	0.944	0.913	0.907	0.904
Ca	0.908	0.845	0.832	0.832

Table 3 Performance of models according to the number of training patterns

	Training patterns	Test patterns	I_a	C_a
	PNN ₁	207	119	0.955
182		144	0.937	0.880
146		180	0.931	0.872
PNN ₂	201	114	0.954	0.913
	178	137	0.944	0.896
	140	195	0.935	0.883

4. 결 론

본 연구에서는 확률이론과 신경망이론을 결합한 확률신경망 모델을 이용하여 방파제 피복재의 안정수를 예측하였고, van der Meer의 실험식과 인공신경망 그리고 확률신경망에 의한 결과를 비교하였다. 수치해석을 통하여 안정수 예측 결과 모든 실험자료를 사용한 경우 확률신경망모델은 van der Meer의 실험식과 인공신경망 모델 보다 높은 정확도를 보였다. 반면 훈련패턴에 사용되지 않은 실험자료만을 테스트패턴으로 이용한 경우 확률신경망의 예측 정확도가 다소 낮게 나타났지만, 훈련패턴 수의 구성에 따라 확률신경망의 안정수 예측 성능은 크게 향상됨을 알 수 있었다. 또한 확률신경망은 방파제의 피복재 설계에서 불확실성을 고려하는 확률론적인 관점을 제공한다는 이점이 있다.

후 기

본 연구는 한국과학재단 특정기초연구(R01-2006-000-10610-0) 지원으로 수행되었으며, 연구비 지원에 감사드립니다.

참 고 문 헌

- Cacoullos, T. (1966). "Estimation of a multivariate density", *Annals of the Institute of Statistical Mathematics (Tokyo)*, Vol 18, No 2, pp 179-189.
- Hanzawa, M., Sato, H., Takahashi, S., Shimosako, K., Takayama, T. and Tanimoto, K. (1996). "New stability formula for wave-dissipating concrete blocks covering horizontally composite breakwaters", *Proceedings of 25th Coastal Engineering Conference, ASCE, Orlando*, pp 1665-1678.
- Hudson, R.Y. (1958). "Design of Quarry Stone Cover Layer For Rubble Mound Breakwaters, Research Report No. 2-2. Waterways Experiment Station", *Coastal Engineering Research Centre, Vicksburg, Miss.*
- Kaku, S. (1990). "Hydraulic stability of rock slopes under irregular wave attack", *Master Thesis, University of Delaware, Newark, Del.*
- KaKu, S., Kobayashi, N. and Ryu, C.R. (1991). "Design formulas for hydraulic stability of rock slopes under irregular wave attack", *Proceedings of 38th Japanese Conference Coastal Engineering, Tokyo, Japan*, pp 661-665
- Kim, D.K., Lee, J.J., Lee, J.H. and Chang, S.K. (2005). "Application of Prediction of Probabilistic Neural Networks of Concrete Strength", *Journal of Materials in Civil Engineering, ASCE, Vol 17, No 3*, pp 353-362.
- Kim, D.H., and Park, W.S. (2005). "Neural network for design and reliability analysis of rubble mound breakwaters, *Ocean engineering*", Vol 32, No 11/12, pp 1332-1349.
- Mase, H., Sakamoto, M. and Sakai, T. (1995). "Neural network for stability analysis of rubble-mound breakwater", *ASCE Journal of waterway, port, coastal, and ocean Engineering*, Vol 121, No 6, pp 294-299.
- Parzen, E. (1962). "On estimation of a probability density function and mode", *Annals of Mathematical Statistics*, Vol 33, pp 1065-1076.
- Rumelhart, D. E., McClelland, J. L. and the PDP Research Group. (1986). "Parallel distributed processing", *The MIT Press, Cambridge, MA*, Vol 1.
- Smith, W.G., Kobayashi, N. and KaKu, S. (1992). "Profile changes of rock slopes by irregular waves", *Proceedings of 23th International Conference Coast Engineering ASCE, New York, NY*, pp 1559-1572.
- Specht, D.F. (1990). "Probabilistic Neural Networks", *Neural Networks* 3, pp 109-118.
- van der Meer, J.W. (1988a). "Deterministic and probabilistic design of breakwater armor layers", *J. Wtrwy. Port Coast, Ocean Engineering*, Vol 114, No 1, pp 66-80.
- van der Meer, J.W. (1988b). "Rock slopes and gravel beaches under wave attack", *PhD Thesis, Delft Univ. of Technol., Delft, The Netherlands.*
- Willmott, C.J. (1981). On the validation of models. *Phys. Geogr. Vol 2, No 2*, pp 184-194.

2006년 6월 7일 원고 접수

2006년 9월 11일 최종 수정본 채택