

신경망 입력변수에 따른 피복석 안정모델의 예측특성 Prediction Characteristics of Breakwater Stability Model according to Neural Network Inputs

김동현¹ · 박우선¹ · 한상훈¹

Dong Hyawn Kim¹, Woo Sun Park¹, and Sang Hun Han¹

1. 서 론

피복재의 중량산정을 위한 설계식으로 허드슨(1958)과 반데미어(1988)의 실험식은 그동안 널리 이용되어 왔으나 정확도에 있어 개선의 여지가 많은 것이 사실이다. 이러한 불확실성은 안전율을 증가시키는 요인이 될 뿐만 아니라 궁극적으로는 공사비의 증가를 초래한다. 따라서, 방파제의 안정식을 개선하기 위한 많은 노력이 진행되어 왔다.

피복재 안정식의 정확도 개선과 관련한 연구로는 Kaku (1990), Kaku 등(1991), Smith 등(1992)의 사례가 있으며 Hanzawa 등(1996)도 최근에 새로운 안정식을 제안한 바 있다. 또한 Mase 등(1995)은 인공신경망(artificial neural network)을 도입하여 안정식의 정확도를 개선하고자 하였으며 김동현 등(2001)은 Mase 등의 연구결과를 일반적인 실험조건에서 확장하여 검증한 바 있다.

본 연구에서는 피복재의 안정수 예측을 위해서 네 가지 형태의 인공신경망 모델을 새롭게 구성하여 비교분석을 실시하였다. 각 모델에 대하여 학습자료는 동일하지만 각각 입력자료, 신경망의 구조, 학습횟수 등을 달리하여 서로 다른 특성을 발견하였다. 특히, 그중에서 과고와 파랑의 평균주기 값을 무차원화하지 않고 사용할 경우 학습 성능은 뛰어나지만 실제설계에는 사용할 수 없음을 밝혔다.

Mase 등은 신경망 모델을 구성함에 있어 반데미어의 실험자료 중 579개만을 선별적으로 사용하였지만

본 연구에서는 641개의 모든 자료를 사용하여 개발된 안정예측모델의 일반성을 확보하도록 하였다.

2. 반데미어의 안정식

방파제 피복재의 안정성 평가용으로 반데미어(1988)의 식은 널리 이용되고 있는 설계식 중의 하나이다. 반데미어는 불규칙파랑의 조건하에서 수행한 실험결과를 이용하여 안정식을 개발하였다. 그는 우선 안정에 미치는 영향이 큰 설계변수로 유의파고(H_s), 평균주기(T_m), 상대밀도($\Delta = \rho_s / \rho_w - 1$), 공청직경(D_{n50}), 공극율(P), 내습파랑수(N), 경사각(θ), 피해율(S_d) 등을 선정하여 안정수 예측식을 다음과 같이 제시하였다.

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

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) 이용하여 다음과 같이 정의하였다.

¹ 한국해양연구원 연안항만공학연구본부 (Coastal & Harbor Engineering Laboratory, Korea Ocean Research & Development Institute, 1270, Sa-dong, Ansan, Kyonggi 425-744, Korea)

$$S_d = A/D_{n_{50}}^2 \quad (3)$$

또한, ξ_m 는 surf similarity라고 하며 다음과 같은 무차원변수로 정의 된다.

$$\xi_m = \tan \theta / \sqrt{2\pi H_s / g T_m^2} \quad (4)$$

식 (1)에서 surf similarity의 분기점이 되는 기준은 다음 식으로 정의한다.

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

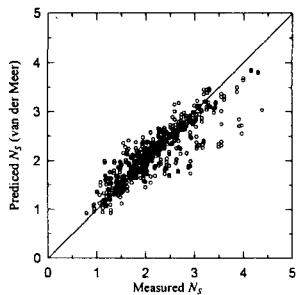


Fig. 1. Predicted Stability Numbers by van der Meer's Formula.

Fig. 1은 반데미어의 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 때문에 보다 정확한 안정수 예측식의 개발이 요구된다.

3. 안정수 예측을 위한 신경망 모델

3.1 신경망의 소개

신경 망은 크게 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer) 등 총 3개의 층으로 구성되며 각각의 층은 여러 개의 노드(node)로 구성된다. 은닉층은 1개 이상을 사용할 수 있으나 본 연구에서는 1개인 경우로만 제한하였다. 각 층의 노드갯수가 n_x, n_y, n_z 이고 입력층에서의 값이 $x (n_x \times 1)$ 로 표현될 때 은닉층에서의 출력값은 다음식으로 표현된다.

$$y = f(W_1 x + b_1) \quad (6)$$

여기서, $W_1(n_x \times n_y)$ 은 입력층과 은닉층 사이의 가중치행렬을, $b_1(n_y \times 1)$ 은 은닉층의 편차벡터를 의미하며 f 는 특정 상수 u_0 에 대한 다음과 같은 형태의 활성함수(activation function)를 의미한다.

$$f(u) = \frac{1}{2} \left\{ 1 + \tanh \left(\frac{u}{u_0} \right) \right\} \quad (7)$$

그리고, 은닉층의 값을 이용한 신경망의 최종 출력값은 다음과 같이 표현된다.

$$z = f(W_2 y + b_2) \quad (8)$$

여기서, $W_2(n_y \times n_z)$ 는 은닉층과 출력층 사이의 가중치행렬을, $b_2(n_z \times 1)$ 는 출력층의 편차벡터를 의미한다.

신경 망을 특정한 목적으로 사용하기 위해서는 가중치와 편차값들을 구해야 하는데 이러한 일련의 과정을 학습이라 한다. 학습은 일반적으로 신경망의 실제 출력값(z)과 목표값(t)과의 차이를 이용하여 식 (9)와 같이 오차함수를 정의한 후 이 값이 최소화되도록 정하는 과정이다.

$$E = \|t - z\|^2 \quad (9)$$

오차함수를 최소화시키기 위해서 잘 알려진 gradient descent rule을 은닉층과 출력층 사이의 가중치에 적용하면 가중치의 수정량은 식 (10)과 같이 표현할 수 있다.

$$\Delta W_2 = -\alpha \frac{\partial E}{\partial W_2} \quad (10)$$

이 때 α 는 학습률을 조절하는 변수이다. 이 식을 전개하여 가중치의 학습률을 구하면 최종적으로 다음과 같다.

$$\Delta W_2 = \alpha d_2 y^\top \quad (11)$$

여기서, d_2 는 출력층의 일반화된 오차로서 그 성분은 다음과 같다.

$$d_2 = (t - z) \otimes z' \quad (12)$$

이 때 사용한 연산자 \otimes 는 다음과 같은 규칙에 따

른다.

$$\begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_n \end{pmatrix} \otimes \begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_n \end{pmatrix} = \begin{pmatrix} q_1r_1 \\ q_2r_2 \\ \vdots \\ q_nr_n \end{pmatrix} \quad (13)$$

앞의 규칙을 적용하면 편차의 학습량도 쉽게 다음과 같이 유도할 수 있다.

$$\Delta b_2 = \alpha d_2 \quad (14)$$

이와 같은 규칙에 따라 온녁층과 입력층 사이의 가중치와 편차에 대한 학습량을 유도하면 다음과 같다.

$$\Delta W_1 = \alpha d_1 x \quad (15)$$

$$d_1 = [W_2^T d_2] \otimes y' \quad (16)$$

$$\Delta b_1 = \alpha d_1 \quad (17)$$

각 단계별로 구한 학습량을 이용해서 식(18a)-(18d)와 같이 (k)번째 에포크(epoch)에서의 가중치와 편차 값을 보정하면 (k+1)번째 에포크의 새로운 가중치 및 편차 값을 얻을 수 있다. 이와 같은 반복적인 작업은 오차함수가 원하는 수준으로 작아질 때까지 계속하면 최종적으로 신경망의 학습이 끝나게 된다.

$$W_2(k+1) = W_2(k) + \Delta W_2(k) \quad (18a)$$

$$b_2(k+1) = b_2(k) + \Delta b_2(k) \quad (18b)$$

$$W_1(k+1) = W_1(k) + \Delta W_1(k) \quad (18c)$$

$$b_1(k+1) = b_1(k) + \Delta b_1(k) \quad (18d)$$

3.2 Mase 등의 신경망 모델(1995)

Mase 등은 반데미어의 실험자료 641 개 중 low crested 조건의 실험자료를 제외한 571 개의 실험자료를 이용하여 신경망 모델을 개발한 바 있다. 그들은 이 중에서도 100 개의 임의 추출한 자료를 이용하여 신경망을 학습시켰으며 학습 후에는 571 개의 자료를 이용하여 성능을 평가하였다. Mase 등은 두 가지 신경망 모델을 제시하였는데 그 중 하나는 피해율 예측을 위한 것이었고 나머지 하나는 안정수 예측을 위한 것이었다. 피해율 예측을 위한 신경망 구성에 있어 사용한 입력자료로는 P , N , S_d , ξ_m 과 유의파고(H_s)에 대한 수심(h)의 비(h/H_s), 스펙트럼 종류(SS) 등이었다. 이 신경망 모델을 이용하여 예측한 피해율은

반데미어의 실험식을 이용한 예측 결과 보다 그 정확도가 매우 높게 평가 되었다. 즉, 반데미어 실험식의 예측 결과는 실험자료와의 상관계수가 0.7이었으나 신경망에 의한 예측 결과는 0.81로 높아졌다. 반면, 안정수의 예측에 있어서는 반데미어의 식보다 정확성이 개선되지 않았다. 반데미어의 식으로 예측한 안정수와 실험결과와의 상관계수는 0.92이었으나 신경망의 예측결과와 실험결과와의 상관계수는 오히려 0.91로 줄어 들었다.

3.3 신경망 모델의 제안

안정수 예측을 위한 신경망 모델을 개선하기 위해 4 가지의 모델을 새롭게 구성하였다. Table 1에 각각의 모델에서 사용한 입력변수를 나타내었다. ANN I은 Mase 등이 제안한 모델과 같은 입력변수를 사용한 모델로 새로 제안한 4 가지 모델과의 비교를 하기 위한 것이다. ANN II~ANN V는 본 연구에서 새롭게 구성한 신경망 모델이다. ANN II는 수심자료의 포함 여부에 따른 예측성능을 확인하기 위하여 ANN I에서 수심자료(h/H_s)만을 제외하여 구성하였다. ANN III은 ANN I에서 사용한 h/H_s 대신 상대수심 h/L_s 를 이용하여 그 효과를 검토하고자 하였다. 여기서, L_s 는 유의파의 파장이다. ANN IV는 무차원변수인 ξ_m (surf similarity) 대신 이를 구성하는 각 변수를 신경망의 개별입력으로 사용한 모델이다. 보통의 경우 신경망 입력의 차원이 커질수록 예측 결과의 분해능이 증가하는 원리를 적용한 사례이다. 그래서 사면경사($\cot\theta$)와 파형경사(H_s/L_s)를 입력으로 추가하였다. 마지막으로 ANN V는 유의파고(H_s)와 유의파주기(T_s)까지도 각각의 입력변수로 채택한 경우이다.

Table 1. Input Variables of Neural Networks

신경망 모델	입력변수
ANN I	P , N , S_d , ξ_m , h/H_s , SS
ANN II	P , N , S_d , ξ_m , SS
ANN III	P , N , S_d , ξ_m , h/L_s , SS
ANN IV	P , N , S_d , $\cot\theta$, H_s/L_s , h/H_s , SS
ANN V	P , N , S_d , $\cot\theta$, H_s , T_s , h/H_s , SS

본 연구에서 제시한 신경망의 성능을 합리적으로 평가하기 위하여 식(19)와 같은 일치지수(Index of

agreement)를 사용하였다. (Willmott 1981).

$$I_a = 1 - \frac{\sum_{i=1}^n (e_i - m_i)^2}{\sum_{i=1}^n [|e_i - \bar{m}| + |m_i - \bar{m}|]} \quad (19)$$

여기서 e_i 및 m_i 는 각각 예측된 안정수와 측정된 안정수를 나타내며 \bar{m} 은 측정치의 평균을 나타낸다. I_a 값이 1로 가까워질수록 예측값과 측정값은 일치함을 의미한다. 기존의 연구에서 주로 사용되어 온 상관계수는 단지 두 자료 사이에 존재하는 선형적 관계의 정도를 나타내 주기 때문에 일치지수의 사용이 보다 적합한 평가 기준이 될 것이다.

5 가지 모델 모두 반데미어의 641 개 모든 자료중에서 임의로 추출한 100 개의 자료를 동일하게 이용하여 학습시켰다. 학습후에는 641 개의 자료를 모두 예측한 후 성능을 평가하였다. Figs. 2~6는 각 모델이 학습횟수와 은닉층 노드개수를 달리 했을 때의 일치지수를 보여주고 있다. 5 가지 신경망 모델 모두 10000 회 이상의 학습에서 반데미어식 보다 일치지수가 크게 나타났으며 모델마다 일치지수가 가장 큰 경우는 학습회수와 은닉층의 노드수에 따라 다르게 나타났다. 각 모델이 최적의 안정수 예측결과를 보여주는 조건을 Table 2에 나타내었다. 표에서 알 수 있듯이 신경망 모델은 반데미어식의 예측결과보다 정확도가 높으며 특히 ANN V의 정확도가 가장 높은 것을 알 수 있다. 또한 수심자료를 사용한 ANN I이 그렇지 않은 ANN II 보다 정확성이 높게 나타났으며 수심자료를 사용함에 있어 유의과 과장으로 정규화한 ANN III 보다는 유의과고로 정규화한 ANN I이 정확도가 약간 높았다. 또한 ζ_m 을 사용한 경우(ANN I~ANN III)보다는 각 설계변수를 개별적으로 사용한 경우(ANN IV, ANN V)가 정확도가 높게 나타났다.

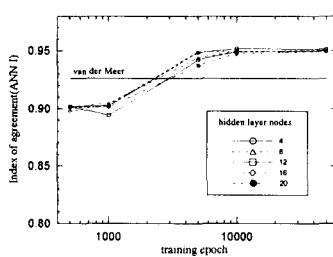


Fig. 2. Training of ANN I.

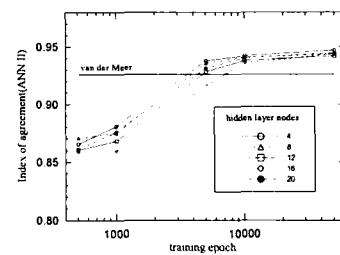


Fig. 3. Training of ANN II.

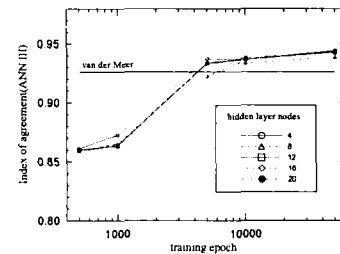


Fig. 4. Training of ANN III.

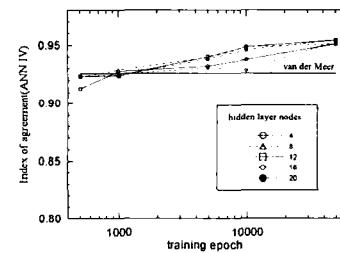


Fig. 5. Training of ANN IV.

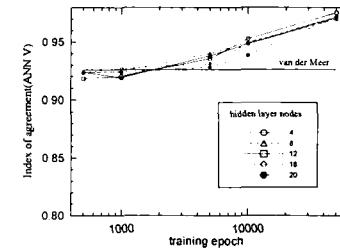


Fig. 6. Training of ANN V.

Table 2. Optimal Parameters for Neural Networks

구분	van der Meer	ANN I	ANN II	ANN III	ANN IV	ANN V
I_a	0.926	0.951	0.947	0.944	0.954	0.975
epoch	-	1×10^4	5×10^4	5×10^4	5×10^4	5×10^4
n_y	-	4	4	4	20	12

3.4 신경망 모델의 성능 평가

앞에 제시한 5가지 모델의 현장 적용 성능을 평가하기 위하여 수치실험을 수행하였다. 즉, 다음에 보인 두 가지 조건에 대하여 피해율의 변화에 따른 피복재 소요중량을 산정 비교하였다.

- Case I: $h=6m$, $H_s=3.5m$, $T_m=10.0sec$, $T_p=11sec$, $T_s=10.406sec$, $\cot\theta=3.0$, $P=0.5$, $N=1000$, $\Delta=1.63$, SS=Pierson Moscowitz Spectrum.
- Case II: $h=3m$, $H_s=2.0m$, $T_m=5.0sec$, $T_p=5.5sec$, $T_s=5.2sec$, $\cot\theta=3.0$, $P=0.5$, $N=1000$, $\Delta=1.63$, SS=Pierson Moscowitz Spectrum.

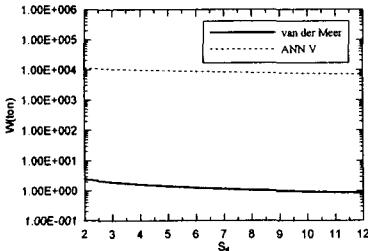


Fig. 7. Design Weight by ANN V(Case I).

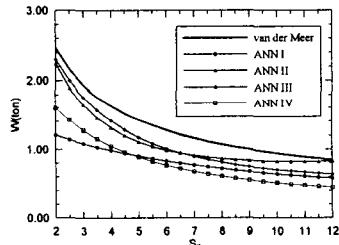


Fig. 8. Design Weight by ANN I~IV(Case I).

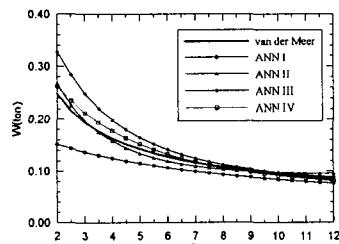


Fig. 9. Design Weight by ANN I~IV(Case II).

Fig. 7에 보인 것은 가장 일치도가 우수한 것으로 나타난 ANN V를 이용하여 Case I 조건에 대해서 예측한 피복재 소요중량과 반데미어식으로 산정한 중량을 비교한 것이다. 서로 잘 안 맞는 정도가 아니라 ANN V에 의한 결과가 현실과 동떨어져 있음을 알 수

있다. 이는 신경을 학습시킬 때 사용한 자료는 실규모 실험에서 얻은 것이 아니라 축소모형 시험에서 구한 자료라는 사실을 이해할 때 그 원인을 짐작할 수 있다. 다시 말하면, ANN V는 입력변수중 파고와 파장을 무차원화시키지 않고 그대로 입력변수로 사용하였기 때문에 신경망 모델의 일반적인 제약인 입력변수나 출력변수의 범위가 학습자료 범위내에 포함될 때만 만족스러운 성능을 보이고 그렇지 않을 경우 신뢰할 수 없는 결과를 주는 특성에 따라 나타난 현상이다. 참고로 본 논문에서 사용한 학습자료의 범위는 파고의 경우가 0.0461m에서 1.18m까지이고 평균주기는 1.24초에서 4.4초까지이다. 따라서, ANN V는 실제 문제에 적용하기에 부적합하다고 볼 수 있으며 새로 제안한 4개의 신경망 모델중 가장 성능이 뛰어난 것은 사면경사와 파형경사를 이용한 ANN IV라고 할 수 있다.

Fig. 8은 같은 설계조건하(Case I)에서 ANN I~ANN IV에 의한 중량 산정결과이다. ANN I은 상대적으로 작은 중량을 ANN II와 ANN III은 반데미어 결과와 유사한 중량을 산정하고 있다. Fig. 9은 Case II 조건에 대한 결과이다. 이 경우에는 ANN III과 ANN IV가 반데미어식의 결과보다 더 무거운 중량을 산정하였고 ANN I은 여전히 가장 가벼운 중량을 산정하였다. 첫번째 조건의 경우 반데미어의 식은 보수적인 중량 산정결과를 보여주는 반면 두번째 조건의 경우는 상대적으로 가볍게 산정하는 결과를 보였다. 즉, 반데미어의 식은 피복재의 중량산정시 항상 보수적인 결과만을 주지 않으며 때로는 상대적으로 비안전측의 가벼운 중량을 산정할 수 있다는 것을 의미하는 것이다. 따라서, 경제적이면서도 피복재의 안전한 설계를 위해서는 신경망과 같은 보다 정확도가 개선된 모델을 사용하는 것이 필요하다고 할 수 있다.

4. 안정수 예측을 위한 신경망 모델

사석방파제 피복재의 안정수 예측을 위한 신경망 모델을 제안하였다. 제안한 신경망 모델은 학습회수와 은닉층의 노드개수에 따라 각각 최적의 학습조건을 찾을 수 있었다. 학습후의 신경망 예측성능을 반데미어의 식과 비교한 결과 신경망이 더 높은 정확도를 가짐을 확인하였으며 입력자료로 파형경사와 사면경사를 포함한 모델(ANN IV)이 surf similarity를 사용한 경우(ANN I ~ III)보다 더 정확도가 높은 것으로 판명되었다. 그러나, 제안한 모델 중 파고와 주기를 무차원화시키지 않고 직접 입력변수로 사용

한 모델(ANN V)은 설계시의 파고 및 주기 값이 학습 자료의 범위를 벗어나므로 현장 적용이 부적합한 것으로 판명되었다. 또한 반데미어의 안정식은 경우에 따라서 피복재의 중량을 과다하게 또는 과소하게 산정하므로 신경망과 같이 보다 정확도가 개선된 모델을 이용하여 경제적 설계와 안전설계를 도모하는 것 이 바람직할 것으로 판단된다.

참고문헌

- 김동현, 박우선, 한상훈, 2001. 신경망을 이용한 방파제 피복재의 안정성 예측. 2001 대한토목학회 학술발표회 논문집.
- Hanzawa, M., Sato, H., Takahashi, S., Shimosako, K., Takeyama, T. and Tanimoto, K., 1996. New stability formula for wave-dissipating concrete blocks covering horizontally composite breakwaters. *Proc. 25th Coastal Engrg. Conf., ASCE*, Orlando, pp. 1665-1678.
- Hudson, R.Y., 1958. *Design of quarry stone cover layer or rubble mound breakwaters*. Res. Rep. No. 2-2, Waterways Experiment Station, Coastal Engrg. Res. Ctr., Vicksburg, Miss.
- Kaku, S., 1990. *Hydraulic stability of rock slopes under irregular wave attack*. Master thesis, Univ. 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. *Proc. 38th Japanese Conf. Coastal Engrg.* Tokyo, Japan, pp. 661-665(in Japanese)
- Mase, H., Sakamoto, M., and Sakai, T., 1995. Neural network for stability analysis of rubble-mound breakwaters. *J. Wtrwy., Port, Coast., and Oc. Engrg.*, Vol. 1 21, No. 6, pp. 294-299.
- Smith, W.G., Kobayashi, N., and Kaku, S., 1992. Profile changes of rock slopes by irregular waves. *Proc. 23th Int. Conf. Coast. Engrg.* ASCE, New York, N.Y., pp. 1559-1572.
- van der Meer, J.W., 1988. Deterministic and probabilistic design of breakwater armor layers. *J. Wtrwy. Port. Coast., and Oc. Engrg.* Vol. 114, No. 1, pp. 66-80.
- van der Meer, J.W., 1988. *Rock slopes and gravel beaches under wave attack*. PhD thesis, Delft Univ. of Tech., Delft, The Netherlands.
- Willmott, C.J., 1981. On the validation of models. *Physical Geography*, Vol. 2, No. 2, pp. 184-194.