

파고계산 인공신경망을 이용한 방파제 기대피해도 산정 Calculating Expected Damage of Breakwater Using Artificial Neural Network for Wave Height Calculation

김동현* · 김영진** · 허동수*** · 전호성*** · 이창훈****

Dong Hyawn Kim*, Young Jin Kim**, Dong Soo Hur***, Ho Sung Jeon*** and Changhoon Lee****

요 지 : 천해파 예측 인공신경망을 이용한 방파제 기대피해도 산정방법을 개발하였다. 극치분포를 따르는 심해파고를 이용하여 방파제 위치에서의 유의파고를 얻기 위해 인공신경망을 이용하였다. 조위와 심해파를 입력받은 인공신경망이 천해유의파를 예측할 수 있도록 학습시켰으며 파랑변형 해석에 사용되는 수치모델(SWAN)의 예측결과와 대등한 성능을 보였다. 천해파 예측 인공신경망을 이용함으로써 다수의 천해파를 매우 손쉽게 빠르게 얻을 수 있었으며 결과적으로 기대피해도 해석에 사용되는 시간을 단축할 수 있었다. 또한, 파고예측 시 방파제 위치에서의 조위 변동성에 따른 기대피해도를 상호비교함으로써 조위변동성을 고려하지 않을 경우 기대피해도를 과다 또는 과소 평가할 수 있음을 확인하였다.

핵심용어 : 방파제, 기대피해도, 신뢰성, 인공신경망, 조위, 파랑변형

Abstract : An approach to calculating expected damage of breakwater assisted by artificial neural network was developed. Wave height in front of a breakwater was predicted by a trained artificial neural network with inputs of wave height in deep ocean and tidal level. Prediction results by the neural network can be comparable to that by professional numerical model for wave transformation. Using the wave prediction neural network, it was very easy and fast to obtain a number of significant waves at breakwater and finally analysis time for expected damage can be shortened. In addition, the effect of considering tidal level in the calculation of expected damage was revealed by comparing the expected damages with and without tidal variation. Therefore, it was pointed out that tidal variation should be considered to improve prediction accuracy.

Keywords : breakwater, expected damage, reliability, neural network, tide, wave transformation

1. 서 론

경사식방파제의 성능평가 지표로 기대피해도가 이용되고 있다. 기대피해도는 파고의 불확실성과 방파제의 물리적 불확실성을 모두 고려하여 내용년한 동안에 발생할 수 있는 방파제의 수리적 이탈과피에 의한 피해도의 기댓값을 신뢰성해석 기법에 의해 정량화한 것이다. 연간 유의파에 의하여 발생하는 피해도를 누적시켜 총 생애주기 동안의 기댓값을 구하는 것이다(Hanzawa 등, 1996). 기대피해도는 피복불력의 단순한 과피여부만을 판단하는 기존방법과 달리 피해의 규모를 예측할 수 있어 성능설계의 가능성을 열어주었다. 그 후 파향의 변동성이 기대피해도에 영향을 줄 수 있음이 입증되었으며(Suh 등, 2002; 서경덕 등, 2003) 국내에서도 이에 관한 다양한 연구(이철웅, 2000)가 진행된 바 있다. 기대피해도는 단

순히 피복력의 피해가 허용치를 초과하는지의 여부를 판단하지 않고 정량적으로 피해를 예측하기 때문에 경제성분석을 통한 최적화 설계를 가능하게 한다.

파고의 불확실성에 의한 피해도 예측을 위해서 확률분포 함수로 정의된 심해파고를 이용한다. 심해파는 해당 해역의 수심, 경계조건 등의 영향에 의해 방파제 위치까지 변형하며 방파제에 피해를 유발한다. 피해도 계산은 이와 같이 심해에서 정의된 확률파를 천해로 전파시키는 과정을 수반하게 되며 그 기댓값을 얻기 위해서는 상당수의 전파된 천해파고를 구해야 한다. 이 과정에서 파랑해석에 소요되는 시간은 실로 적지 않아 대부분 천해에서 새롭게 파고의 확률분포를 구한 후 피해를 예측하게 된다. 그러나, 이와 같이 천해에서 파고의 확률분포를 이용하면 조위의 고저에 의한 파랑변형에 미치는 효과가 고려되지 못하는 단점을 갖게 된다. 조위를 고려하기 위

*군산대학교 해양건설공학과(Corresponding Author: Dong Hyawn Kim, Department of Coastal Construction Engineering, Kunsan National University, Miryong, Kunsan, Jeonbuk 573-701, Korea, welcomed@naver.com)

**군산대학교 해양산업공학과(Department of Ocean Industrial Engineering, Kunsan National University)

***경상대학교 해양토목공학과(Department of Ocean Civil Engineering (Institute of Marine Industry), Gyeongsang National University)

****세종대학교 토목환경공학과(Department of Civil & Environmental Engineering, Sejong University)

해서 서경덕 등(2003)은 기대피해도계산과 파랑변형이 하나의 프레임 내에서 작동하도록 하는 수치모델을 개발한 바 있다. 그러나, 이 방법은 특정 수치모델을 이용해야 하는 단점을 가지고 있어 일반설계자들이 쉽게 접근할 수 없으며 범용 수치모델을 이용할 수 있는 방법의 개발이 필요해졌다. 따라서, 범용 수치모델을 이용하여 기대피해도를 산정할 수 있도록 하기 위하여 천해파 예측과정에 인공지능망을 적용하였다. 인공지능망은 학습된 자료의 범위 내에서 매우 정확하고 신속하게 결과를 예측할 수 있는 도구로서 해안공학 분야에서도 다양한 응용연구가 보고되고 있다. 특히, 조위(Lee 등, 2002), 파고(Deo 등, 2001; Agrawal, 2002), 처오름(Medina, 2000) 등의 문제에 적용하여 그 가능성을 확인하였으며 방파제에 관하여는 수리학적 안정성 및 파괴 예측에도 사용된 바 있다 (Kim 등, 2005; Yacgi 등, 2005).

본 논문에서는 인공지능망을 통해 심해파와 천해파 사이의 파랑변형을 예측하는 방법을 제안하였으며 예측된 방파제 전면파에 의한 경사제 피복석의 기대피해도를 산정하였다. 제안 방법은 천해파 예측의 정밀도를 확보하면서도 예측시간을 감소시켜 효율적인 기대피해도 산정을 가능하게 하였다. 또한, 파고 예측 시 조위변동성의 영향을 고려하므로 보다 현실적인 피해도 예측이 가능하였다. 수치해석에서 조위변동성에 따른 기대피해도를 비교함으로써 그 영향을 정량적으로 제시하였다.

2. 인공지능망

인공지능망은 생물체의 학습 기능을 수학적 모델로 구현한 것으로 명시적 관계식 없이도 특정한 상관관계를 보이는 두 가지 자료 즉, 입력과 출력 자료 사이의 묵시적 관계성을 학습한 후 그대로 재현할 수 있는 특성을 가지고 있어 다양한 공학분야에 활용되고 있다. 인공지능망의 구조는 Fig. 1과 같이 입력자료를 받는 입력층(input layer), 결과를 제공하는 출력층(output layer) 그리고 두 층 사이를 연결하는 한 개 이상의 은닉층(hidden layer)으로 구성되어 있다. 각 층에는 자료를 처리하는 단위인 여러 개의 노드(node)가 있으며 한 층의 노드에서 다른 층의 노드로 자료가 전달되면서 가중치(weight)가 곱해지며 이 가중치는 학습을 통해 스스로 최적




Fig. 1. A typical layout of neural network.

의 값을 갖게 된다. 우리가 어떤 운동을 배울 때 꾸준한 연습을 통해 뇌와 근육에서 익히게 되는 감각이 인공지능망에서는 가중치로 구현되는 것이다.

Fig. 1과 같이 각 층의 노드수가 L, M, N 이고 입력층에서 $I_i(i=1,2,\dots,L)$ 의 값을 가질 때 은닉층에서의 출력값은 식 (1)과 같이 표현한다.

$$H_j = f(\text{net}_j) \quad (j=1,2,\dots,M) \quad (1)$$

식 (1)에서 $f(\cdot)$ 은 은닉층의 활성화함수(activation function)를 나타내고 net_j 는 은닉층의 j 번째 노드에서의 입력값으로 식 (2)로 표현된다.

$$\text{net}_j = \sum_{i=1}^L W_{ji}I_i + b_j \quad (2)$$

식 (2)에서 W_{ji} 은 입력층과 은닉층 사이의 가중치를 나타내고 b_j 은 은닉층의 편차(bias) 값을 의미한다. 식 (1)과 식 (2)의 계산과 같은 방법으로 출력층의 값은 식 (3)으로 표현한다.

$$O_k = f(\text{net}_k) \quad (j=1,2,\dots,M) \quad (3)$$

식 (3)에서 출력층의 k 번째 입력값은 식 (4)와 같이 표현한다.

$$\text{net}_k = \sum_{j=1}^M W_{kj}H_j + b_k \quad (4)$$

여기서 W_{kj} 은 은닉층과 출력층 사이의 가중치를 의미하며 b_k 는 출력층의 편차이다. 인공지능망이 원하는 예측 기능을 온전하게 수행하기 위해서는 학습(learning or training)의 과정이 필요하다. 학습의 궁극적 목적은 특정 패턴 τ 에 대하여 목표값(T_k^τ)과 인공지능망의 실제 출력값(O_k^τ)으로 다음과 같이 정의되는 오차함수를 최소화하는 가중치를 찾는 것이다. 식에서 N 는 학습에 사용하는 모든 패턴의 수이다.

$$E = \sum_{\tau=1}^P \sum_{k=1}^N (T_k^\tau - O_k^\tau)^2 \quad (5)$$

3. 인공지능망을 이용한 기대피해도

3.1 심해파고

방파제 피복석의 피해는 설계파에 상응하는 큰 파랑에 의해 발생되기 때문에 년최대심해파고를 계산에 고려한다. 일반적으로 심해파고는 관측에 의한 극치파랑자료를 이용하여 얻어지는 극치파고분포에 따라 결정된다. 한국해양연구원은 국내연안의 심해파고를 극치분포형태로 제공하여 방파제 설계에 이용하도록 하고 있다(2005, 한국해양연구원). 심해파 극치분포의 누적확률분포함수는 다음과 같은 Weibull 분포함수로 정의하였다.

$$F(x) = 1 - \exp\left[-\left\{\frac{x-C}{B}\right\}^k\right] \quad (6)$$

여기서, x 는 년최대 유의파고를 의미하며 B, C, k 는 각각 척도, 위치, 형상 모수를 나타낸다.

3.2 인공신경망을 이용한 유의파 예측

방파제 위치에서의 유의파고는 심해파의 파고, 주기, 천해역의 수심, 조위, 반사파, 경계조건 등 다양한 인자들의 영향을 받는다. 그러나, 많은 자료를 이용하여 인공신경망을 학습시키기 위해서는 다양한 학습자료를 필요로 하기 때문에 우리가 이용 가능한 최소의 자료만을 가지고 천해파를 예측하는 것이 효율적이다. 학습자료로 이용할 최소의 물리량이 선정이 되었다면 학습자료를 구하기 위하여 심해의 파고를 이용하여 해당 해역에서 수치모델을 이용한 파랑변형 해석을 수행한다. 파랑변형 해석은 격자의 크기와 개수에 따라서 상당량의 시간이 소요된다. 따라서 기대피해도 해석에 사용되는 모든 파랑변형을 수치모델에만 의존하는 것은 현실적으로 불가능하다. 인공신경망을 학습시켜 천해파를 예측한다면 학습자료를 만드는 데 필요한 최소한의 파랑변형 해석만이 필요하므로 효율적 해석이 가능하다. 인공신경망은 비록 학습자료가 제공된 국소 위치에서만 예측성능을 발휘하므로 다른 해역에서는 또 다른 학습을 수행해야 한다. 그러나, 일단 학습이 수행된 후에는 다른 해역조건(심해파고 및 조위)이 주어져도 매우 신속하게 천해파고 등을 예측할 수 있으므로 기대피해도와 같이 다량의 파고를 예측해야 하는 공학적 문제에 매우 효과적으로 사용할 수 있다.

인공신경망으로 예측된 천해파의 통계적인 변동성을 고려하기 위하여 정규분포를 따르는 확률변수로 고려하여 다음과 같은 변동성을 부여한다.

$$H_{1/3} = (1 + \alpha_{H_{1/3}})H_{1/3e} \tag{7}$$

$$\sigma_{H_{1/3}} = \gamma_{H_{1/3}}H_{1/3e} \tag{8}$$

여기서, $H_{1/3}$ 은 방파제에 전달되는 유의파고이며 $H_{1/3e}$ 는 인공신경망에 의해 예측한 유의파고, $\alpha_{H_{1/3}}$ 와 $\gamma_{H_{1/3}}$ 는 유의파고의 편의와 편차계수를 나타낸다(서경덕 등, 2003).

3.3 기대피해도

Fig. 2는 인공신경망으로 천해파를 예측하여 방파제의 기대피해도를 계산하는 순서를 보여주고 있다. 심해파의 확률분포를 이용하여 개별 심해파고를 추산한 후 인공신경망을 이용하여 천해파를 생성한다. 유의파고 생성 시 확률분포에 따른 변동성을 고려하기 위해 유의파고의 편의($\alpha_{H_{1/3}}$)와 변동계수($\gamma_{H_{1/3}}$)를 부여한다. 피복석에 대해서도 편의와 변동계수를 부여한다. 생성된 유의파고를 임계파고와 비교하여 피해도를 계산하면 1년 동안 방파제의 피해도를 알 수 있으며 50회 누적시키면 50년간의 피해도를 확인할 수 있다. 이러한 과정을 반복하게 되면 피해도가 특정 값으로 수렴하게 되며 최종적으로 기대피해도를 얻게 된다.

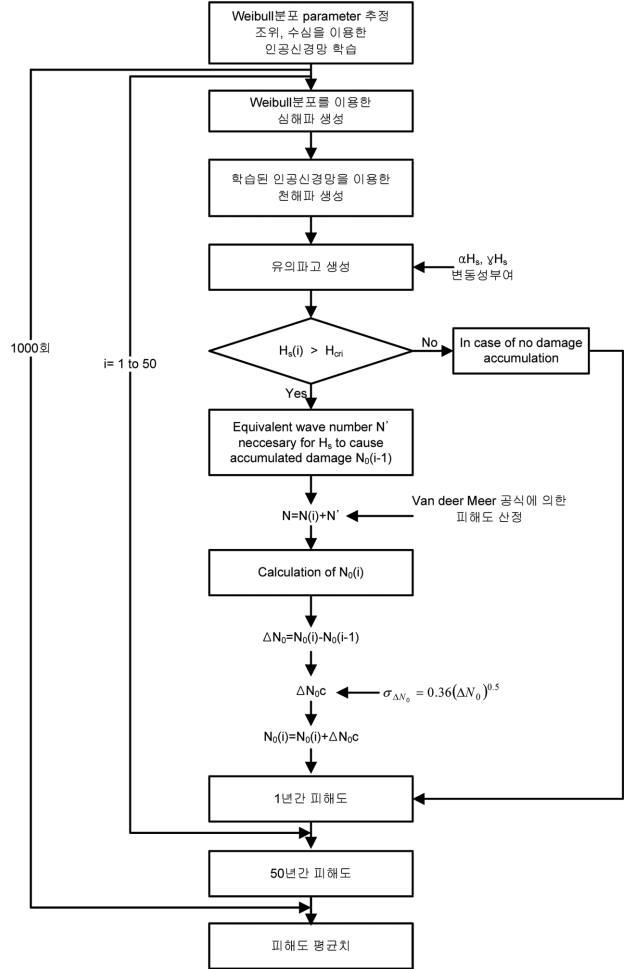


Fig. 2. Flowchart of Expected damage.

피해도를 계산하기 위해 van der Meer(1988)의 안정공식을 변형하면 식 (9)와 같이표현할 수 있다.

$$N_0 = \left[\frac{1}{3.75} \left\{ \frac{H_{1/3}}{\Delta D_n} \left(\frac{H_{1/3}}{L_0} \right)^{0.2} - 0.85 \right\} \right] N^{0.5} \tag{9}$$

여기서 Δ 는 S_v-1 , D_n 는 공칭평균지름, N_0 는 van der Meer(1988)에 의해 정의된 피해율의 하나로 방파제 법선방향의 폭 D_n 의 범위 내에서 이동한 블록의 개수, N 은 작용하는 파의 수, L_0 는 파장을 나타낸다.

소파블록의 피해는 임계파고(피해가 발생하지 않는 최대파고)보다 파고가 큰 폭풍파 조건 하에서만 방파제의 수명 동안 누가적으로 발생한다고 가정한다. 우선 i 번째 해에 작용하는 파고를 $H_{1/3}(i)$, $(i-1)$ 번째 해까지 발생한 총 피해를 $N_0(i-1)$ 로 두고 이들을 van der Meer(1988)의 안정 공식에 대입하여 $(i-1)$ 번째 해까지 방파제에 작용한 파의 총 수(N)를 구한다. 즉, 식 (10)을 이용하여 구한다.

$$N' = \frac{N_0^2}{\left[\frac{1}{3.75} \left\{ \frac{H_{1/3}}{\Delta D_n} \left(\frac{H_{1/3}}{L_0} \right)^{0.2} - 0.85 \right\} \right]} \tag{10}$$

다음으로 여기에 번째 해의 파의 수, $N(i)$ 를 더한 파의 수, $N = N' + N(i)$ 와 $H_{1/3}(i)$ 를 식 (9)에 대입하여 번째 해까지 발생한 총 피해, $N_0(i)$ 를 구한다.

이제 $(i-1)$ 번째 해와 i 번째 해 사이의 피해 증가는 $\Delta N_0 = N_0(i) - N_0(i-1)$ 로 계산된다. 초과블록의 피해에 대한 불확실성을 나타내기 위해서는 Hanzawa 등(1996)이 제시한 피해 증가의 통계적인 편차에 대한 식 (11)을 사용한다.

$$\sigma_{\Delta N_0} = 0.36\Delta N_0^{0.5} \quad (11)$$

이렇게 통계적인 불확실성을 고려한 피해 증가를 에 더하여 i 번째 해까지의 최종적인 피해, 를 구한다. 이와 같은 과정을 방파제의 수명 동안 반복 적용하여 방파제 수명 동안의 총 피해를 계산한다.

4. 수치해석

4.1 인공신경망 학습

인공신경망의 학습자료를 산정하기 위해 부산 신항 동방파제에서 28.2 km 떨어진 심해에서의 파고와 방파제 위치에서의 조위를 이용하여 해양수치모델 프로그램(SWAN)으로 천해파고를 추정하였다. Fig. 3은 동방파제 주변 해역의 수심도를 보여주고 있다. 주파향은 SSE로서 50년빈도 심해설계파는 12.47 m이고 주기는 15.54 sec이다. 기대피해도 산정시 발생 가능한 심해파에 대하여 인공신경망 학습자료를 만들기 위해서 심해파의 크기를 최저 8.0 m, 최고 20 m로 설정하여 극단적으로 높은 파고에 대해서도 인공신경망이 학습하도록 하였으며 조위를 평균수면을 기준으로 ± 0.9 m로 설정하여 고조위 및 저조위 시에도 예측이 가능하도록 하였다. 심해설계파의 유의주기는 Goda(2003)가 제안한 유의파와 유의주기의 관계




Fig. 3. Water depth around Busan Newport East Breakwater.




Fig. 4. Wave prediction neural network.

인 다음 식을 이용하였다. 다만 해역 조건에 따라 이를 따르지 않는 곳에서는 해당위치에서의 유의주기-파고 관계를 구하여 적용해야 한다.

$$T_{1/3} = 3.3H_{1/3}^{0.63} \quad (12)$$

인공신경망의 구조는 Fig. 4와 같이 두 개의 입력노드와 한 개의 출력노드를 가지며 은닉층은 3개의 노드를 이용하였다. 입력자료 중 한개는 극치분포로 생성한 심해파고이며 다른 하나는 방파제 전면에서의 조위이다. 조위는 평균해수면을 기준점(0.0)으로 하였다. 인공신경망 출력값은 방파제 위치에서의 유의파고이다. 은닉층의 개수와 은닉층의 노드 개수 등 인공신경망의 구조는 학습자료의 특성에 영향을 받기 때문에 어느 특정 학습자료에 맞게 최적화 된 것을 다른 문제에도 일반화시킬 수 없으며 다만 학습 시 다양한 조건에 의해 최적의 구조를 찾아야 한다.

Fig. 4의 인공신경망은 단지 매우 제약된 자료만을 가지고 유의파를 예측하기 때문에 보다 정밀한 예측을 위해서는 파향, 풍향, 풍속 등의 자료를 동시에 입력으로 사용하는 것이 필요하다.

Table 1은 인공신경망을 학습시키기 위해 SWAN 입력으로 사용한 조위, 심해파고 조건과 그에 따른 천해파 결과이다. 인공신경망으로 천해파를 산정할 때 조위와 심해파 이외에도 파향, 풍속, 풍향 등의 다양한 조건들이 영향을 미친다. 그러나 본 연구에서는 학습자료의 용이성을 감안하여 파향은 일정하다고 가정하였다. 또한 학습자료는 예측시 사용하는 자료의 범위를 충분히 포함할 수 있어야 한다. 만일 학습자료의 범위를 벗어난 것을 예측한다면 그 예측한 값은 신뢰성을 보장할 수 없는 것이 일반적이다. 한편, Fig. 5는 오차 목표치인 1.0×10^{-4} 이하까지 수렴한 인공신경망으로 예측한 천해파고와 그 오차를 보여주고 있다. 예측의 최대오차는 0.5%이었다.

4.2 인공신경망의 검증

인공신경망으로 예측한 천해파고의 정확성을 확인하기 위해 앞에서 언급한 바와 같이 SWAN 모델로 예측한 천해파고를 기준값으로 설정하여 인공신경망 은닉층을 3개로 해서 학습한 결과와 다중회귀분석에 의한 2차, 3차 회귀식의 계산값과 비교하였다. 다중회귀분석의 2차, 3차 회귀식은 식 (12)와 식 (13)으로 심해파고(X_1)와 조위(X_2)를 변수로 하여 정의

Table 1. Training data of neural network

| 침해파고 | 조 위 | | | | | | |
|------|--------|--------|--------|--------|--------|--------|--------|
| | -0.9 m | -0.6 m | -0.3 m | M.S.L | 0.3 m | 0.6 m | 0.9 m |
| 8 m | 4.62 m | 4.71 m | 4.76 m | 4.88 m | 4.92 m | 4.96 m | 5.00 m |
| 10 m | 4.93 m | 5.04 m | 5.13 m | 5.22 m | 5.34 m | 5.43 m | 5.53 m |
| 12 m | 5.09 m | 5.20 m | 5.31 m | 5.41 m | 5.53 m | 5.64 m | 5.75 m |
| 14 m | 5.15 m | 5.26 m | 5.37 m | 5.47 m | 5.58 m | 5.70 m | 5.81 m |
| 16 m | 5.15 m | 5.27 m | 5.38 m | 5.49 m | 5.60 m | 5.72 m | 5.84 m |
| 18 m | 5.12 m | 5.24 m | 5.35 m | 5.46 m | 5.58 m | 5.69 m | 5.80 m |
| 20 m | 5.07 m | 5.19 m | 5.30 m | 5.42 m | 5.54 m | 5.65 m | 5.77 m |

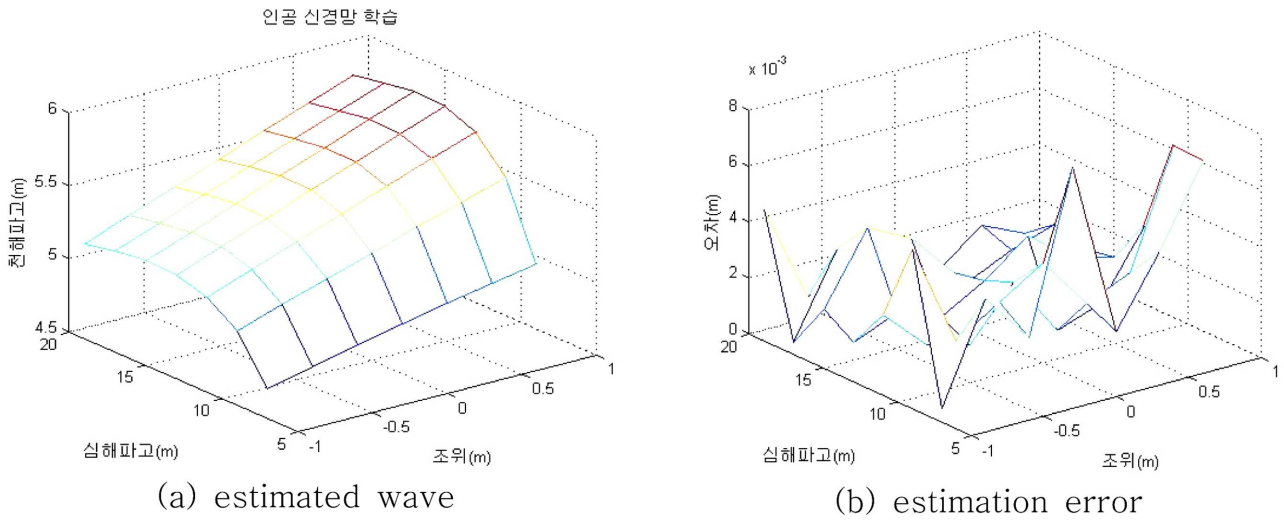


Fig. 5. Estimated wave error by neural network.

하였다.

$$y_{2nd} = C_1 + C_2X_1 + C_3X_2 + C_4X_1X_2 + C_5X_1^2 + C_6X_2^2 \quad (12)$$

$$y_{3rd} = C_1 + C_2X_1 + C_3X_2 + C_4X_1X_2 + C_5X_1^2 + C_6X_2^2 + C_7X_1^2X_2 + C_8X_1X_2^2 + C_9X_1^3 + C_{10}X_2^3 \quad (13)$$

여기서, $C_1 \sim C_{10}$ 은 회귀분석계수이다. Table 2는 인공신경망과 회귀식의 각 방법에서 사용한 총 미지수 개수와 최종오차를 비교하고 있다. 인공신경망은 더 적은 미지수를 이용하고도 가장 오차가 적은 예측방법임을 알 수 있다.

피해도 산정에 인공신경망을 사용하는 것이 타당한지를 검증하기 위하여 인공신경망으로 예측한 49개의 천해파고와 해양수치모델(SWAN)로 계산한 49개의 천해파고를 이용하여 각각의 파고에 대한 피해를 산출하고 100.0 ton의 피복석이 개별 파고에 의해 발생한 피해를 Fig. 6에 비교하였다. 산출된 피해도의 최대오차는 3%로써 인공신경망을 피해도 산정에 사용하는 것이 공학적 기준으로 판단할 때 가능함을 보였다.

Table 2. Error of regression model and neural network

| method | rms error | unknown |
|----------------------|-----------|---------|
| 2nd order regression | 0.1209 | 6개 |
| 3rd order regression | 0.0154 | 10개 |
| neural network | 0.0049 | 9개 |

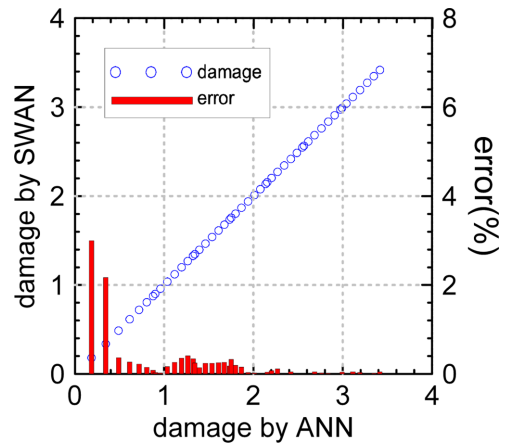


Fig. 6. Comparison of expected damage.

4.3 기대피해도의 추정

학습완료된 천해파 추정 인공신경망을 Fig. 2의 해석순서도와 같이 사용하여 기대피해도를 산정하였다. 사용한 침해파의 확률분포는 Weibull 극치분포 함수로 척도모수(B), 위치모수(C), 형상모수(k)는 각각 1.8009, 2.0385, 0.7766이며 전면조위는 정규분포를 따르고 평균해수면 기준의 평균이 0, 표준편차가 0.2이었다. 유의파고의 편의 및 편차는 각각 -0.06과 0.09를 적용하였고 피복석은 평균 100.0 ton에 편의 및 편차를 각각 0.0과 0.05로 설정하였다.

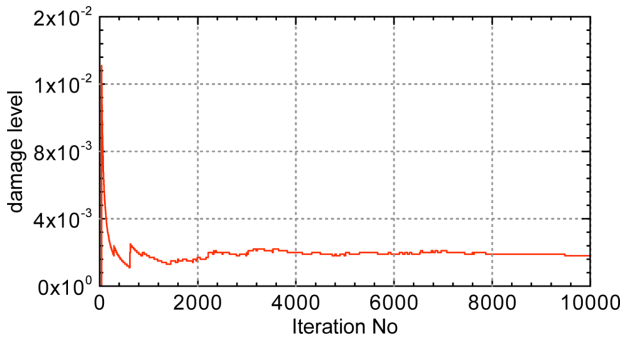


Fig. 7. Expected damage with water level variation.

Table 3. Comparison of calculation time

| method | mean calculation time | number of analysis | total time for analysis |
|----------------|-----------------------|--------------------|-------------------------|
| SWAN | 56 min 10 sec | 50 | 168,500 sec |
| neural network | 0.016 sec | 50 | 0.8 sec |

Fig. 7은 인공지능망을 이용하여 방파제 전면 유의파를 예측한 후 기대피해도를 계산한 사례이다. 4000회 이상에서 피해도가 수렴되는 것을 알 수 있다. 최종 기대피해도는 0.002로 나타났다.

인공지능망으로 천해파를 예측함에 있어 장점 중 하나는 해석에 소요되는 총 시간이다. Table 3에 1개의 심해파로 1개의 천해파를 추정하는데 있어 각각 인공지능망과 SWAN 모델을 이용했을 때 소요되는 시간을 비교하였다. 해석에 사용한 컴퓨터는 intel Core 2 Duo(2.86 GHz)모델이다. 인공지능망은 학습이 완료된 후에는 간단한 산술적 계산을 통하여 출력값(유의파고)을 예측하므로 피해도 예측도 신속하게 수행할 수 있도록 한다. 기대피해도는 50년간 피해도 예측을 수 천회 이상 반복계산해야 하므로 이러한 효율성은 더욱 극대화 된다.

방파제 위치에서의 유의파 극치분포를 사용하는 기대피해도 산정방법은 조위변동에 따른 파고의 변화를 고려하지 못하므로 기대피해도 결과에 오차가 포함될 수 있다. Fig. 8은 인공지능망의 두 번째 입력값에 조위의 변동치가 아닌 고정치를 넣은 후 기대피해도를 산정한 결과이다. 조위값을 -1.0 m에서 1.0 m까지 변화시킨 결과 조위가 증가할수록 피해도가

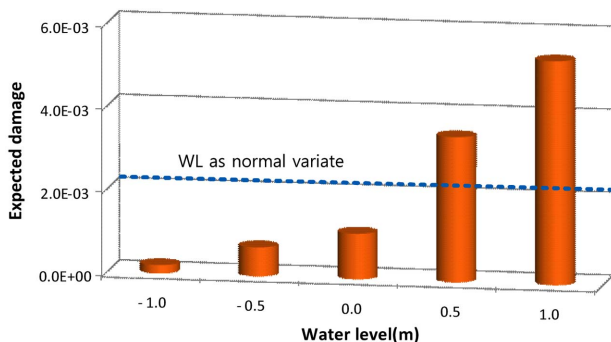


Fig. 8. Expected damage with water level variation.

증가하였다. 이것은 Table 1에서 보듯이 조위 증가시 파고가 증가하기 때문이다. 또한, 이 결과는 조위 고정값을 너무 크거나 작게 적용하면 정규분포를 따르는 것으로 가정한 경우 (WL as normal variate)보다 기대피해도를 과대 또는 과소평가하게 될 것을 의미한다. 따라서 기대피해도 산정시에는 조위의 변동성을 고려해야 정확한 결과를 얻을 수 있다.

5. 결 과

본 연구에서는 인공지능망을 이용한 경사식 방파제의 기대피해도 산정방법을 제안하였다. SWAN 모델을 이용하여 계산한 49개의 심해파고 및 천해파고를 이용하여 인공지능망을 학습시켰으며 기대피해도 산정과정에 필요로 하는 다량의 천해파는 학습한 인공지능망으로 예측하여 사용하기 때문에 해석 시간을 획기적으로 단축시킬 수 있었다. 또한, 예측한 천해파는 전면조위의 변동성을 고려하기 때문에 단순히 전면조위를 고정시킨 후 계산한 기대피해도에 비해서 매우 높은 정확성을 가진다. 또한, 제안방법은 심해파와 천해파 자료를 얻을 수 있는 모든 수치모델과 연동해서 사용할 수 있기 때문에 실무 기술자들이 쉽게 기대피해도를 산정할 수 있다.

감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구이다(No.2009-0083920).

참고문헌

서경덕, 권혁민, 윤현덕 (2003). 파향의 변동성을 고려한 방파제 피복 블록의 기대피해 계산. 한국해양·해양공학회지, 제 15권, 제1호, pp. 21-32.

이철웅 (2000). 경사제 피복재의 안정성과 피해율에 대한 확률론적 해석. 한국해양·해양공학회지, 제20권, 제1-B호, pp. 73-84.

한국해양연구원 (2005). 전해역 심해설계과 추정보고서 II. Agrawal, J.D., Deo, M.C. (2002) On-line wave prediction, Marine Structures, 15, pp. 57-74.

Deo, M.C., Jha, A., Chaphekar, A.S., Ravikant, K. (2001). Neural networks for wave forecasting. Ocean Engineering, 28, pp. 889-898.

Goda, Y. (2003). Revisiting Wilson's Formulas for Simplified Wind-Wave Prediction. J. Waterway, Port, Coastal, and Ocean Engineering, Vol. 129, No. 2, pp. 93-95.

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 International Conference on Coastal Engineering, ASCE, Orlando, pp. 1665-1678.

Kim, D. H., Park, W. S. (2005). Neural network for design and reliability analysis of rubble mound breakwaters. Ocean Engineer-

- ing, 32, pp. 1332-1349.
- Lee, T.L., Jeng, D.D. (2002). Application of artificial neural networks in tidal forecasting. *Ocean Engineering*, 29, pp. 1003-1022.
- Medina, J.R. (2000). Neural network modeling of runup and overtopping. *Coastal structures 99*, Losada(ed), Rotterdam.
- Suh, K.D., Kweon, H.M., Yoon, H.D. (2002). Reliability design of breakwater armor blocks considering wave direction in computation of wave transformation. *Coastal engineering journal*, 44(4), pp. 321-341.
- van der Meer, J.W. (1988). Rock slopes and gravel beaches under wave attack. PhD Thesis, Delft University of Technology, Delft, The Netherlands.
- van der Meer, J.W. (1988). Rock slopes and gravel beaches under wave attack. PhD Thesis, Delft University of Technology, Delft, The Netherlands.
- Yagci, O., Mercan, D.E., Gigizoglu, H.K., Kabdasli, M.S. (2005). Artificial intelligence methods in breakwater damage ratio estimation. *Ocean Engineering*, 32, pp. 2088-2106.

원고접수일: 2010년 3월 17일

수정본채택: 2010년 4월 2일

게재확정일: 2010년 4월 25일