

경사식 호안 배후 포장체 파력 추정을 위한 인공신경망 모델 구축 및 성능 평가 Development and Performance Evaluation of an Artificial Neural Network Model for Estimating Wave Forces on the Pavement behind a Sloping Seawall

김태완* · 박성준** · 오상호***

Tae-Wan Kim*, Sung-Joon Park** and Sang-Ho Oh***

요 지 : 본 논문에서는 Ko et al.(2022)과 Lee et al.(2022)의 실험 계측 자료를 기반으로 인공신경망 모델을 구축하고 호안 배후면 포장체에 작용하는 파력을 추정하였다. 차원 및 무차원으로 구성된 다양한 입력변수 조합과 은닉층의 노드 수를 변화시키며 인공신경망 모델을 구축하였다. 구축된 인공신경망 모델은 매우 좋은 파력 예측 성능을 나타내었다. 특히, 서로 이질적인 두 개의 실험 자료 조합에 대해 수립된 인공신경망 모델도 Ko et al.(2022) 및 Lee et al.(2022)에 각각 제시된 경험식에 비해 훨씬 더 나은 예측 성능을 나타내었다.

핵심용어 : 인공신경망, 경사식호안, 포장체, 파력, 수리실험

Abstract : In this study, an artificial neural network (ANN) model was developed based on the experimental data obtained from Ko et al. (2022) and Lee et al. (2022) to predict the wave forces acting on the pavement behind a sloping seawall. The ANN models were constructed by varying the number of nodes in the hidden layer and testing various combinations of input variables, both in dimensional and dimensionless forms. The developed neural network models demonstrated excellent wave force prediction performance. In particular, the models established using two heterogeneous sets of experimental data showed significantly better prediction performance than the empirical formulas suggested by Ko et al. (2022) and Lee et al. (2022), respectively.

Keywords : artificial neural network, sloping seawall, pavement, wave force, physical experiment

1. 서 론

해안 및 항만구조물 중 호안은 해안 침식 및 배후 육지의 침수 피해를 방지하기 위한 목적으로 시공된다. 최근에는 지구온난화 영향으로 해수면이 상승하고 태풍의 빈도와 강도가 증가함에 따라 연안 재해 발생이 잦아지면서 그 중요성이 더욱 강조되고 있다.

항만 및 어항 설계기준(Ministry of Oceans and Fisheries, 2024)에 제시된 바와 같이 호안 설계 시 다양한 설계 인자를 검토해야 하며, 특히 허용 월파랑의 충족과 파랑 작용에 대한 구조적 안정성 확보가 중요하다. 허용 월파랑 산정 시 우리나라에서는 Goda et al.(1975)의 월파랑 산정 도표가 기본적으로 활용되며, 유럽에서는 다양한 구조물 형식과 파랑 조건에 따른 산정식을 제시하고 있는 EurOtop(2018) 공식이 폭넓게 활용되고 있다. 또한 호안의 구조적 안정성 평가는 Goda(2010)가 제안한 직립벽 파압 공식을 바탕으로 수행되

고 있다. 이와 같이 허용 월파랑과 파랑 작용에 대한 구조물의 안정성에 대한 산정식은 다수의 선행 연구를 통해 비교적 잘 정립되어 있다. 그러나 호안 배후면 포장체에 작용하는 파력에 대해서는 아직 연구가 불충분한 실정이다. 호안 배후면의 포장체는 호안 상부구조물에 비해 파랑의 직접적인 영향을 적게 받아 파력이 상대적으로 작을 수 있으나, 태풍과 같은 조건 하에 큰 규모의 월파가 발생할 경우 포장체가 손상될 가능성이 있다. 포장체는 도로 및 인도로 활용되어 사람들의 생활과 밀접하게 연관된 공간이므로, 안정성을 평가할 수 있는 산정식 개발에 관련된 연구의 수행이 필요하다.

한편, 방파제나 제방 배후에 위치한 구조물에 작용하는 월파 하중에 대해서는 일부 연구가 수행된 바 있다. Chen et al.(2012)은 제방 배후에 위치한 건물에 작용하는 월파 하중을 분석하고 건물의 위치에 따라 작용 압력이 크게 달라질 수 있음을 확인하였다. Watson et al.(2018)은 사석 방파제의 상치콘크리트 뒤에 위치한 배후 구조물에 작용하는 월파 파

*국립창원대학교 토목공학과 석사과정(Master's Student, Department of Civil Engineering, Changwon National University)

**국립창원대학교 토목공학과 석사과정(Master's Student, Department of Civil Engineering, Changwon National University)

***국립창원대학교 스마트그린공학부 건설시스템공학전공 교수(Corresponding author: Sang-Ho Oh, Professor, Department of Civil Engineering, School of Smart and Green Technology, Changwon National University, 20 Changwondaehak-ro, Uichang-gu, Changwon 51140 Korea, Tel: +82-55-213-3779, coast.oh@gmail.com)

압의 공간적 분포를 수리모형실험을 통해 분석하였으며, 분석결과, 월파가 증가할 경우 상치콘크리트 인접부와 구조물 하부에서 상대적으로 큰 압력이 발생하는 것으로 나타났다. 그러나 이러한 연구들은 주로 건물이나 직립벽과 같은 배후 구조물을 대상으로 수행된 것으로, 호안 배후면에 설치되는 포장체에 작용하는 파력에 대해서는 직접적으로 다루지 않았다.

호안 배후면 포장체에 대한 연구로 Ko et al.(2022)은 경사식 호안 배후면의 포장체 상·하부에 작용하는 파력 추정을 위해 수리모형실험을 수행하였고 주요 영향 인자를 고려하여 파력 산정 경험식을 제안한 바 있다. Lee et al.(2022)은 배후면 포장체 전체에 작용하는 파력이 아닌 호안의 상부구조물과 포장체 사이의 이격 거리에 따른 월파압을 고려하기 위해 수리모형실험을 수행하였으며, 이를 기반으로 상부구조물 선단으로부터의 이격 거리별 포장체 상부에 작용하는 파압 산정 경험식을 제안하였다. 또한 최근 Kim et al.(2025)은 경사제를 대상으로 2차원 수리모형실험을 진행하며 차수벽을 포장체 배후면 하부에 설치하여 근입 깊이와 설치 위치에 따른 양압력의 분포 특성을 계측하고 분석하였다. 그러나 Kim et al.(2025)의 연구는 실험 결과의 물리적인 해석 및 경향성 분석에만 집중하였으며, 다양한 파랑 조건과 구조 형상에 적용 가능한 예측 모델은 제시하지 못하였다.

선행 연구에서 수행된 수리모형실험 기반 연구들은 주로 특정 조건에서 계측된 실험 결과를 바탕으로 경험식을 제안하는 형태로 이루어져 다양한 파랑 조건과 구조물 형상에 적용하기에는 한계가 있다. 실제 해안 구조물 설계에서는 파고, 주기, 수심, 상대여유고 등 다양한 인자가 복합적으로 작용하며, 이러한 인자 간 상호작용에 의해 하중 특성이 비선형적으로 변화한다. 따라서 이러한 비선형적 하중 특성을 경험식 기반 접근만으로 정확하게 예측하는 것은 쉽지 않다. 한편 수치모델링 기법은 복잡한 물리 현상을 비교적 정밀하게 재현할 수 있으나, 초기 조건 설정 및 격자 구성에 따라 결과가 큰 영향을 받으며 계산에 많은 시간적 비용이 소요된다. 따라서 다양한 인자 간의 복잡한 관계를 효과적으로 반영하면서도 계산 효율성을 확보할 수 있는 새로운 예측 기법의 개발이 요구된다.

이러한 관점에서 최근 해안공학 분야에서도 머신러닝 등 데이터 기반 예측 방법의 활용이 증가하고 있다. 특히 인공지능망은 충분한 데이터가 확보되면, 입력·출력 변수 간의 비선형 관계를 스스로 학습하고, 학습 이후에는 예측 결과를 즉각적으로 산출할 수 있는 효율성을 가진다.

최근 연구 사례로 Mares-Nasarre et al.(2021)은 사석방파제를 대상으로 인공지능망 모델을 구축하여 월파층의 두께와 월파 유속을 예측하였으며, 그 결과 기존의 경험식에 비해 더 높은 정밀도를 나타냈다. 국내에서는 Oh and Oh(2022, 2024)가 조파기 입력파고 예측 모델을 수립하기 위해 인공지능망(ANN, Artificial Neural Network)과 가우시안 과정 회귀(GPR,

Gaussian Process Regression)를 사용한 연구를 수행하였다. Oh and Oh(2022)는 규칙파 실험 자료를 활용하여 모델을 구축하고, 쇄파 발생 여부에 따라 자료를 분류함으로써 예측 정확도가 크게 향상됨을 확인하였다. Oh and Oh(2024)는 불규칙파 조건으로 확장하여 다양한 수심, 파고 및 주기 조건의 실험 데이터를 이용하여 ANN과 GPR 모델을 구축하고 그 성능을 검증하였다. 두 연구 모두 조파기 입력파고를 높은 정확도로 예측할 수 있음을 보였으며, 실험 시 준비 시간을 단축하여 효율성을 높일 수 있는 가능성을 입증하였다.

본 연구에서는 Ko et al.(2022)과 Lee et al.(2022)의 경사식 호안 배후면 포장체에 작용하는 파력 및 파압 계측 실험 자료를 이용하여 인공지능망 모델을 구축하고 호안 배후면 포장체 상부면 작용 파력(F_{vo}) 및 하부면 작용 파력(F_{vu})을 추정하였다. 또한 구축된 인공지능망 모델을 기존 경험식과 비교하여 그 성능을 검증하였다.

2. 기존 연구의 실험 자료

2.1 Ko et al.(2022) 실험 자료

Ko et al.(2022)의 수리모형실험은 길이 50 m, 너비 1.2 m, 높이 1.6 m인 2차원 조파수조에서 수행되었으며, 경사식 호안 모형은 조파수조 한쪽 벽면으로부터 33.3 m 떨어진 위치에 설치되었다. Ko et al.(2022)의 실험에서 정의된 매개변수는 Fig. 1과 같으며, 본 연구에서는 이 중에서 여유고(R_c), 정수면에서 피복재 상단까지 높이(A_c), 피복재 어깨폭(G_w), 배후면 포장체의 두께(h), 주 피복층의 두께(A_d), 수심(h) 및 파랑 제원에 관련된 매개변수인 유의파고(H_s)와 유의파장(L_s)을 인공지능망 모델 구축에 활용하였다. Table 1에는 Ko et al.(2022)의 실험 Case별로 주요 매개변수의 값을 제시하였다. 이때 A_d 가 0.89 m 및 0.178 m인 조건은 각각 호안 전면 사면부에 피복재로 거치된 TTP의 배치 열수가 각각 2열 및 4열인 경우에 해당한다. 피복재 배치 열수가 증가함에 따라 상치콘크리트 전면 피복재 어깨폭 G_w 의 값도 커지게 된다.

경사식 호안의 상부구조물과 배후 포장체는 아크릴 재질로 제작되어 사석 마운드 위에 설치되었다. Table 1에 제시된 것처럼 테트라포드 2열로 피복된 조건에서는 높이 4 cm의 파라펫 유무에 따라 각각 실험이 수행되었다. 파라펫이 설치되지 않는 조건에서는 R_c 와 A_c 의 값이 같고, 파라펫이 설치되면 두 매개변수의 값이 달라지게 된다. 한편, Fig. 1에 붉은 색 점으로 표시된 위치에 파압계(pressure transducer)가 설치되어 계측이 이루어졌다.

실험파는 첨두중대계수(γ)가 3.3인 JONSWAP 스펙트럼을 사용하여 생성되었으며, 유의파고 및 유의주기 조건은 Table 2에 제시되어 있다. 수심(h)이 0.20 m 및 0.25 m인 조건에서는 유의파고(H_s) 0.08 m 및 0.10 m인 경우만 실험이 수행되었고, 수심(h)이 0.40 m 및 0.45 m인 조건에서는 0.12 m 및 0.14 m인 경우까지 포함하여 총 네 가지 서로 다른 유의




Fig. 1. Schematic diagram and definitions of the geometrical parameters of the seawall model used in Ko et al.(2022).

Table 1. Values of the geometrical parameters of the model used in Ko et al.(2022)

Case ID	No. of TTP layers	h [m]	A_c [m]	R_c [m]	G_w [m]	A_t [m]
D40L02C01	2	0.40	0.15	0.15	0.11	0.089
D40L02C02				0.19		
D45L02C01		0.45	0.10	0.10		
D45L02C02				0.14		
D20L02C01		0.20	0.12	0.12		
D20L02C02				0.16		
D25L02C01	4	0.25	0.07	0.07	0.22	0.178
D25L02C02				0.11		
D40L04C01		0.40	0.15	0.15		
D45L04C01				0.10		
D20L04C01		0.20	0.12	0.12		
D25L04C01				0.07		

Table 2. Incident wave conditions used in the experiments of Ko et al.(2022)

T_s [sec]	H_s [m]			
1.4	0.08	0.10	0.12*	0.14*
1.8				
2.2				

*only when $h = 0.40$ m and 0.45 m

파고 조건에서 실험이 수행되었다.

2.2 Lee et al.(2022) 실험 자료

Lee et al.(2022)은 길이 100 m, 너비 2 m, 높이 3 m인

2차원 조파수조에서 수리모형실험을 수행하였다. 경사식 호안은 조파수조 상류부로부터 68.2 m 떨어진 위치에 설치되었으며, Fig. 2에는 실험 단면의 개략도 및 주요 매개변수의 정의를 나타내었다. 본 연구에서는 이 중에서 여유고(R_c), 정수면에서 피복재 상단까지 높이(A_c), 피복재 어깨폭(G_w), 주 피복층의 두께(A_t), 수심(d_t) 및 파랑 제원에 관련된 매개변수인 유의파고(H_s)와 유의파장(L_s)을 인공신경망 모델 구축에 활용하였다. Table 3에는 Lee et al.(2022)의 실험 단면에 대한 주요 매개변수의 값을 제시하였다.

상부구조물 뒤쪽에 설치된 포장체는 Fig. 2에 보인 것처럼 총 20개의 패널로 구성되어 있으며, 각 패널에는 2대의 하중




Fig. 2. Schematic diagram and definitions of the geometrical parameters of the seawall model used in Lee et al.(2022).

Table 3. Values of the geometrical parameters of the test model in Lee et al.(2022)

Case ID	R_c [m]	A_c [m]	G_w [m]	A_T [m]	d_t [m]	$\cot\alpha$
C11	0.30					
C12	0.34	0.3	0.22	0.192	0.8	1.5
C13	0.38					

Table 4. Incident wave conditions used in the experiments of Lee et al.(2022)

T_s [sec]	H_s [m]	d_t [m]
2.0~3.2 ($\Delta T_s = 0.4$)	0.2~0.3 ($\Delta H_s = 0.02$)	0.8

계(load cell)가 부착되어 파력이 계측되었다. 본 연구에서는 Ko et al.(2022)의 실험 범위($0.073 \leq D_w/L_{m0} \leq 0.199$)에 해당하는 P01에서 P08까지 총 8개 패널의 계측 데이터를 활용하여 인공지능망 모델을 구축하였다. 위 실험 범위에서 D_w 은 호안 배후면 포장체의 폭, L_{m0} 는 스펙트럼 평균주기로부터 구한 심해파 조건의 파장을 의미한다. Ko et al.(2022)의 연구에서는 파장에 관련된 변수로 L_{m0} 를 사용하였으나 본 연구에서는 인공지능망 모델 구축 시 L_s 를 사용하였다. Bretschneider-Mitsuyasu 스펙트럼을 따르는 불규칙파를 이용하여 실험이 수행되었으며, 파랑 조건은 Table 4에 제시된 바와 같다.

3. 기존 연구에 제시된 경험식의 성능 평가

3.1 Ko et al.(2022)의 파력 예측식



Ko et al.(2022)은 경사식 호안 구조물 배후면 포장체에 작용하는 월파력에 영향을 미치는 주요 인자를 분석하였으며, 이를 기반으로 배후면 포장체에 작용하는 최대파력을 예측하는 경험식을 제안하였다. 식(1)은 포장체 상부면에 작용하는 파력 F_{vo} 를 산정하는 식으로, $R_c/A_c > 1$ 은 파라펫이 설치된 조건, $R_c/A_c = 1$ 은 파라펫이 설치되지 않은 조건을 의미한다.

$$F_{vo} = \begin{cases} 0.5024 \rho g R_c D_w W \cdot \exp \left\{ -3.504 \frac{R_c}{H_s} \right\} \frac{L_{m0}}{G_w} \frac{h}{H_s}, & \text{if } \frac{R_c}{A_c} > 1 \\ 0.0659 \rho g R_c D_w W \cdot \exp \left\{ -3.266 \frac{R_c}{H_s} \right\} \frac{L_{m0}}{G_w} \frac{h}{H_s}, & \text{if } \frac{R_c}{A_c} = 1 \end{cases} \quad (1)$$

여기서 W 는 구조물의 폭을 의미한다. 한편, 포장체 하부면에 연직 방향으로 작용하는 파력인 F_{vu} 에 대해서도 식(2)와 같은 경험식이 제안되었다.

$$F_{vu} = 1.297 \rho g (A_c - h_t) D_w W \cdot \exp \left\{ -10.33 \frac{A_c - h_t}{H_s} \right\} \frac{L_{m0}}{G_w} \frac{h}{H_s} \quad (2)$$

경험식에 의한 파력 추정값이 실험 자료와 얼마나 잘 일치하는지 여부를 평가하기 위해 본 연구에서는 IOA(Index of Agreement)와 NRMSE(Normalized Root Mean Square Error)를 계산하였다. IOA는 Willmott(1981)에 의해 제안된

**Fig. 3.** Comparison of the experimental data and empirical formula for the overtopping forces on the pavement presented by Ko et al.(2022).**Fig. 4.** Comparison of the experimental data and empirical formula for the uplift forces on the pavement presented by Ko et al.(2022).

지표로 실험값과 예측값 간의 상대적 일치도를 나타내는 지표로서 0에서 1 사이의 값을 가지며, 1에 가까울수록 예측값이 실험값을 잘 재현함을 의미한다. NRMSE는 평균제곱근오차(RMSE)를 실험값의 평균으로 나누어 정규화한 값으로, 예측 오차의 상대적 크기를 나타내며 값이 작을수록 높은 예측 정확도를 의미한다.

한편, Ko et al.(2022) 및 Lee et al.(2022)의 실험시설 및 조건이 상이하여 파력값의 범위 및 편차가 크게 다를 수 있다. 이러한 점을 고려하여 각 실험 데이터의 일관된 비교를 위하여 계측된 파력값을 $\rho g H_s^2$ 으로 나누어 무차원화한 값을 분석에 사용하였다. Fig. 3은 Ko et al.(2022)의 F_{vo} 에 대한 실험값과 식(1)에 의한 추정값을, Fig. 4는 F_{vu} 에 대한 실험값과 식(2)의 추정값을 각각 무차원화하여 비교한 결과이며, 각 그래프에는 IOA와 NRMSE의 값을 함께 제시하였다. F_{vo} 에

대한 IOA는 0.84로 나타나 경험식이 실험값을 비교적 잘 재현하는 것으로 확인되었다. 그러나 실험값에 비해 식(1)에 의한 예측 결과가 전반적으로 다소 크게 나타났다. 한편 F_{vu} 에 대한 계산 결과, IOA는 0.76으로 나타나 경험식이 실험값을 일정 부분 재현하고 있으나, 전반적으로 과소평가하는 경향을 보였다.

3.2 Lee et al.(2022)의 파압 예측식

Lee et al.(2022)은 경사식 호안 상부구조물 배후면에 작용하는 월파압을 수리모형실험을 통해 측정하고, 그 결과를 바탕으로 경험식을 제안하였다. Ko et al.(2022)의 연구가 배후면 포장체 전체에 작용하는 파력을 대상으로 한 반면, Lee et al.(2022)은 상부구조물 끝으로부터의 이격 거리에 따른 파압을 산정하는 경험식을 아래와 같은 형태로 제시하였다.

$$p_{\max}^* = \left(\frac{p_{\max}}{\gamma H_s} \right) \left(\frac{R_c}{H_s} \right) \left(\frac{A_c}{H_s} \right) \left(\frac{H_s}{L_s} \right) = a \left(\frac{x}{L_s} \right)^b \quad (3)$$

여기에서 $p_{\max}^*$ 는 상부구조물로부터의 거리에 따른 무차원 최대 낙하파압이며, 계수 a 와 b 는 단면 형상에 따라 다르게 주어진다.

$R_c/A_c = 1$ 인 조건에서는 식(4)와 같이 표현되며, 최대 낙하파압은 $x/L_s \approx 0.05$ 에서 발생 후 상부구조물의 선단으로부터의 거리(x)를 유의파장(L_s)로 나눈 상대 거리(x/L_s)에 따라 지수적으로 감소한다.

$$p_{\max}^* = \begin{cases} 0.016 & \text{for } \frac{R_c}{A_c} = 1 \text{ and } \frac{x}{L_s} \leq 0.05 \\ 0.00150 \left(\frac{x}{L_s} \right)^{-0.79} & \text{for } \frac{R_c}{A_c} = 1 \text{ and } \frac{x}{L_s} \geq 0.05 \end{cases} \quad (4)$$

식(5)는 $R_c/A_c = 1.13$ 인 조건이며 최대 낙하파압은 $x/L_s \approx 0.06$ 에서 발생 후 x/L_s 에 따라 지수적으로 감소한다.

$$p_{\max}^* = \begin{cases} 0.04 & \text{for } \frac{R_c}{A_c} = 1.13 \text{ and } \frac{x}{L_s} \leq 0.06 \\ 0.000750 \left(\frac{x}{L_s} \right)^{-1.41} & \text{for } \frac{R_c}{A_c} = 1.13 \text{ and } \frac{x}{L_s} \geq 0.06 \end{cases} \quad (5)$$

식(6)은 $R_c/A_c = 1.27$ 인 조건이며 최대 낙하파압은 $x/L_s \approx 0.1$ 에서 발생하며 또한 x/L_s 의 증가에 따라 지수적으로 감소한다.

$$p_{\max}^* = \begin{cases} 0.071 & \text{for } \frac{R_c}{A_c} = 1.27 \text{ and } \frac{x}{L_s} \leq 0.1 \\ 0.00038 \left(\frac{x}{L_s} \right)^{-2.27} & \text{for } \frac{R_c}{A_c} = 1.27 \text{ and } \frac{x}{L_s} \geq 0.1 \end{cases} \quad (6)$$

본 연구에서는 Lee et al.(2022)의 실험에서 측정된 월파압과 식(4)~(6)에 의해 추정된 파압을 P01~P08 구간에 대해 적분하여 F_{vo} 를 산정하였다. 이후 이를 $\rho g H_s^2$ 로 나누어 무차원




Fig. 5. Comparison of the experimental data and empirical formula for the overtopping forces on the pavement presented by Lee et al.(2022).

화하여 비교한 결과를 Fig. 5에 제시하였다.

Lee et al.(2022)의 경험식을 적용한 계산 결과, IOA는 0.94로 나타나 경험식이 실험값을 잘 재현하는 것으로 확인되었다. 또한 NRMSE는 0.39로, 오차의 크기가 비교적 작아 높은 예측 정확성을 보였다. Lee et al.(2022)의 경험식은 Ko et al.(2022)에 비해 향상된 IOA 및 NRMSE 지표를 나타내었으며, 이를 통해 상부구조물로부터의 거리 변화에 따른 무차원 최대파력의 전반적인 경향을 더욱 잘 재현할 수 있는 것으로 확인된다.

3.3 두 연구에 제시된 경험식의 상호 비교

일반적으로 경험식은 도출 과정에서 사용된 실험 데이터에 잘 부합하지만, 서로 다른 데이터에 적용할 경우 예측 성능이 저하되는 경향이 있다. 이러한 점을 고려하여 서로 다른 조건에서 수행된 두 연구의 실험 데이터를 개별 경험식에 함께 적용하여, 각 경험식이 도출된 자체 데이터뿐만 아니라 타 연구의 데이터에 대해서도 어느 정도의 예측 성능을 확보하는지 검토해 보았다.

Fig. 6은 Ko et al.(2022)의 경험식과 Ko et al.(2022) 및 Lee et al.(2022)의 실험값을 비교한 결과이며, Fig. 7은 Lee et al.(2022)의 경험식과 두 연구의 실험값을 비교한 그래프이다. 이때 IOA 및 NRMSE는 두 연구의 실험 데이터를 통합하여 산정한 결과이다. 두 경험식 모두 자체 실험 데이터에 대해서는 비교적 높은 일치도를 보였으나, 다른 데이터를 적용했을 때에는 예측 정확도가 현저히 낮아지는 경향을 보였다. 이러한 차이는 두 연구가 서로 다른 구조 형상과 파랑 조건에서 수행되었기 때문이며, 각 경험식은 해당 실험 조건에는 적합하지만 다른 조건에 적용할 경우 예측 정확도가 저하될 수 있다. 따라서 다양한 조건에서 비선형 상관관계를 반영할 수 있는 데이터 기반 예측 방법이 요구된다.




Fig. 6. Comparison of the empirical formula proposed by Ko et al. (2022) with measured data from Ko et al.(2022) and Lee et al.(2022).




Fig. 7. Comparison of the empirical formula proposed by Lee et al. (2022) with measured data from Ko et al.(2022) and Lee et al.(2022).

4. 포장체 상부면 작용 파력 F_{vo} 예측

4.1 F_{vo} 예측을 위한 인공지능경망 모델 구성

인공지능경망은 인간의 뇌 신경망 구조를 모사한 알고리즘으로, 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된다. 각 층은 노드로 연결되어 있으며, 노드들은 계층적으로 입력 데이터를 전달하고 변화시킴으로써 복잡한 비선형 패턴을 학습할 수 있다. 입력층은 외부 데이터를 수용하고, 은닉층은 입력된 정보를 바탕으로 복잡한 패턴을 학습하는 역할을 한다. 출력층은 은닉층에서 학습된 정보를 기반으로 최종값을 예측한다(Jordan and Mitchell, 2015).

본 연구에서는 F_{vo} 예측을 위한 최적의 인공지능경망 모델을 구축하기 위하여 입력변수 조합과 은닉층의 노드 수를 변화시키며 성능을 비교하였다. 입력변수 조합은 Table 5에 보인

Table 5. Combinations of dimensional and non-dimensional input and output variables for predicting F_{vo}

Case	Input variables	Output variables
A1	$\frac{H_s}{h}, \frac{L_s}{G_w}, \frac{R_c}{H_s}, \frac{R_c}{A_c}$	$\frac{F_{vo}}{\rho g H_s^2}$
A2	$\frac{H_s}{h}, \frac{L_s}{G_w}, \frac{R_c}{H_s}, \frac{R_c}{A_c}, \frac{A_l}{H_s}$	
A3	$h, H_s, T_s, A_c, R_c, G_w, A_l$	F_{vo}




Fig. 8. Architecture of the artificial neural network for Case A1.

것처럼 세 가지로 다르게 적용하였고, 은닉층의 수는 1개로 구성하되 노드 수를 8개에서 15개 범위에서 8가지로 다르게 설정하였다. Fig. 8은 Case A1에 해당하는 인공지능경망의 계층 구조를 나타내는 모식도이다.

활성함수로는 인공지능경망에 자주 사용하며 미분식이 간단한 시그모이드(sigmoid) 함수를 적용하였다. 모델 구축에 사용된 데이터는 학습(training) 70%, 검증(validation) 15%, 평가(testing) 15%로 분할하였다. 이에 따라 Ko et al.(2022)의 데이터 107개는 각각 75개, 16개, 16개로, Lee et al.(2022)의 데이터 72개는 각각 50개, 11개, 11개로 나누어 각각 학습, 검증, 평가에 사용하였다. 학습 데이터는 인공지능경망이 입력변수와 출력변수 간의 관계를 학습하는 데 사용되며, 검증 데이터는 과적합(overfitting)을 방지하기 위해 사용되어 학습 과정에서 모델의 성능을 평가하여 조기 종료 여부 등을 판단하는데 활용한다. 마지막으로 평가 데이터는 학습이 완료된 이후 모델의 최종 예측 성능을 객관적으로 평가하기 위해 독립적으로 사용된다.

Bouthillier et al.(2021)은 학습에 사용되는 데이터 세트에 따라 인공지능경망의 성능이 달라질 수 있으므로, 무작위로 분할한 다양한 데이터 세트에서 성능을 측정하고 모델을 평가하는 것이 바람직하다고 제안하였다. 또한 Alwosheel et al. (2018)은 ANN이 학습해야 하는 파라미터 수가 증가할수록

신뢰성 있는 학습에 요구되는 데이터 수도 증가하며, 자료 수에 비해 모델 복잡도가 과도할 경우 학습 데이터에서는 높은 적합도를 보이더라도 평가 데이터에 대한 일반화 성능이 저하될 수 있음을 제시하였다. 따라서 제한된 자료를 이용한 ANN 모델링에서는 데이터 규모와 검증 성능을 함께 고려하여 모델 복잡도를 조절할 필요가 있다. 이에 본 연구에서는 제한된 수리모형실험 자료를 고려하여 은닉층 수를 증가시키기보다 단일 은닉층 구조를 적용하고, 은닉노드 수를 변화시켜 모델 복잡도를 조절하였다. 또한 학습에 사용되는 데이터를 무작위로 분할하여 총 200개의 데이터 세트를 생성하고 이를 “시드(seed)”라고 정의하였으며, 이렇게 생성된 200개의 시드에 대해 인공신경망 모델의 성능을 측정하고 서로 비교하였다.

인공신경망의 모델 선정 과정은 다음과 같다. 먼저 Table 5에 제시된 각각의 Case별로 은닉층의 노드 수가 8개에서 15개까지 서로 다른 인공신경망을 구성하고, 200개의 시드에 대해 모델 결과를 평가하여 IOA와 NRMSE를 산출하였다. 이후 각 노드 별로 200개 시드로부터 계산된 IOA와 NRMSE의 평균값을 비교하여 각 Case별로 최적의 노드 수를 결정하였다. 이때 각 Case별 최적의 노드 수는 IOA와 NRMSE를 함께 고려하여 선정하였다. 만일 어떤 노드 수에서 IOA가 가장 높고 동시에 NRMSE가 가장 낮은 경우에는 그 노드 수를 최적 노드 수로 선정하였다. 만일 그렇지 않은 경우에는 IOA 및 NRMSE 차이의 크기를 비교하여 다른 노드 수에 비해 상대적으로 더 우수한 성능을 보인 노드 수를 최적 노드 수로 선정하였다. 이때 각 Case별 노드 수에 따른 IOA 및 NRMSE 계산 결과를 엄밀하게 평가하기 위해 평균뿐만 아니라 표준편차를 함께 고려하였다. 즉, 평균값을 기준으로 인공신경망 모델 성능을 평가하되 표준편차가 상대적으로 더 크게 나타나는지 여부를 확인함으로써 시드에 따른 모델링 결과의 민감도를 검토하였다.

Fig. 9는 Lee et al.(2022)의 Case A1 조건에서 노드 수가 8개부터 15개인 인공신경망 모델에 대해 200개 시드로부터 산정된 IOA 및 NRMSE 값을 계산한 결과를 보여준다. 중심선은 평균값을 의미하며, 막대 영역은 평균 $\pm$ 표준편차의 범위를 나타낸다. IOA 그래프에서 일부 막대 영역의 최대값이 1보다 크게 나타나는 것은 평균에 표준편차가 더해졌기 때문에 나타나는 결과이며, 실제로 계산된 IOA 값이 이론적 범위인 0과 1 사이를 벗어남을 의미하는 것은 아니다. Fig. 9로부터 은닉층의 노드 수가 8~15개 범위에서 서로 다른 값을 가질 때 IOA와 NRMSE 값의 차이가 비교적 크지 않음을 알 수 있고, 이는 구축된 ANN 모델이 노드 수에 따라 민감하게 변화하지 않는다는 점을 시사하는 결과이다. 노드 수가 9개일 때의 모델이 가장 좋은 결과를 제시하는 것으로 나타났다으므로 이 경우에는 은닉층의 노드 수를 9개로 최종 선정하였다.

이와 같은 과정을 통해 배후 포장체에 작용하는 월파력 F_w




Fig. 9. Mean and standard deviation of IOA and NRMSE for Case A1 from Lee et al.(2022).

를 예측하는 총 아홉 가지 인공신경망 모델이 최종적으로 구축되었다. 즉, Ko et al.(2022)의 F_w 실험 데이터를 학습하여 구축된 A1~A3 모델, Lee et al.(2022)의 F_w 실험 데이터를 학습하여 구축된 A1~A3 모델 및 두 연구의 F_w 실험 데이터를 모두 학습하여 구축된 A1~A3 모델이 각각 개별적으로 구축되었다.

한편, 서로 다른 실험 자료를 통합하여 분석할 때 데이터가 특정 범위에 편중되어 있지 않은지 확인해 볼 필요가 있다. 그런데, Ko et al.(2022)와 Lee et al.(2022)의 실험은 모형 축적, 구조물의 세부 형상 및 파랑 조건이 서로 상이하므로 차원 변수의 경우 분포 범위가 완전히 다르다. 무차원 변수의 경우에는 Table 5에서 Case A1과 A2에 공통적으로 사용된 입력변수인 H_s/h , L_s/G_w , R_c/H_s 및 R_c/A_c 를 대상으로 두 실험 자료의 분포 범위를 Fig. 10에 제시하였다. 상대적으로 Ko et al.(2022)의 자료가 Lee et al.(2022)의 자료에 비해 더 넓은 범위에 분포함을 확인할 수 있다. 두 실험 자료의 무차원 변수 분포 범위가 상이하고 일부 범위에 상대적으로 더 많은 데이터가 존재하긴 하지만 매우 좁은 특정 범위에 데이터가 몰려 있는 경향은 나타나지 않았다.

4.2 인공신경망 모델의 F_w 예측결과

이렇게 구축된 아홉 가지 인공신경망 모델에 의한 F_w 예측 결과는 Table 6 및 Figs. 11~13에 나타내었다. Table 6에는 각 모델의 IOA 및 NRMSE 값을 제시하였으며, 이 값들은 학습 및 검증에 사용되지 않은 평가(testing) 데이터에 대한 예




Fig. 10. Histogram of dimensionless variables from the experimental data of Ko et al.(2022) and Lee et al.(2022).

측 성능을 제시한 것이다. Table 6에 제시된 IOA 및 NRMSE 지표로부터 아홉 가지 인공지능망 모델의 예측 성능이 매우 좋음을 확인할 수 있다. 한편, Figs. 11~13에는 각 모델에 의한 F_{vo} 예측 결과를 실험에서 계측된 값과 비교하는 그림을 제시하였으며, 그림에서 x축은 계측된 파력을, y축은 모델에 의해 예측된 파력을 나타낸다. IOA 및 NRMSE 값은 평가 데이터로부터 계산되었지만 Figs. 11~13에서는 모든 데이터에 대한 결과를 제시하였다. 즉, 학습 및 검증 데이터에 대한 비교 결과는 파란색 또는 보라색으로, 평가 데이터에 대한 비교 결과는 초록색 또는 오렌지색으로 나타내었다.

Fig. 11에는 Ko et al.(2022)의 F_{vo} 계측 데이터를 이용하여 구축된 세 가지 인공지능망 모델의 결과를 제시하였다. 이 경우에는 A1 및 A2 모델에 비해서 A3 모델의 예측 성능이 훨씬 우수하여 최종 모델로 선정되었으며, 선정된 A3 모델

의 은닉층 노드 수는 11개였다. 한편, A3 모델보다는 예측 성능이 다소 낮지만 무차원 입력 및 출력 변수로 구성된 인공지능망 모델인 A1과 A2의 예측 결과도 Fig. 3에 보인 Ko et al.(2022)의 경험식에 의한 결과와 비교해보면 더 나은 성능을 보임을 확인할 수 있다. A1과 A2 모델에 의한 실험값과 예측값의 전반적인 일치도는 물론 IOA 및 NRMSE 값도 모두 인공지능망 모델이 식(1)에 의한 결과보다 개선된 성능을 보였다.

Fig. 12에는 Lee et al.(2022)의 F_{vo} 계측 데이터를 이용하여 구축된 인공지능망 모델 A1~A3의 결과를 제시하였다. Table 6에 보인 것처럼 이 경우에는 세 모델의 IOA 값이 모두 1.0으로 나타날 정도로 모든 모델이 우수한 성능을 나타내었다. NRMSE 값은 A1과 A3 모델이 0.07, A2 모델이 0.09로 계산되어 근소한 차이를 보였다. 다만, 세 모델의 예측 정확도가 워낙 좋기 때문에 이 중 어떤 모델을 선택하더라도 적합한 것으로 판단된다. Ko et al.(2022) 실험의 경우 압력계를 이용하여 계측된 파압을 적분하여 월파에 의해 배후 포장체에 작용하는 파력을 계산한 반면, Lee et al.(2022) 실험에서는 하중계를 이용하여 포장체 작용 파력을 직접 측정하였기 때문에 계측 데이터의 산포도가 훨씬 작았으며, 이로 인해 인공지능망 모델들의 성능이 Fig. 12에 보인 것처럼 매우 우수하게 나타난 것으로 분석된다. 한편, Fig. 12의 결과를 Fig. 5에 제시된 Lee et al.(2022)의 경험식에 의한 예측 결과와 비교해 보면 본 연구에서 구축된 인공지능망 모델들이 식(4)~(6)에 의한 결과보다 훨씬 우수한 성능을 보임을 확인할 수 있다.

Table 6. IOA and NRMSE values estimated from the nine ANN models, each built using different model setups and data-sets

Dataset	Case	IOA	NRMSE
Ko et al.(2022)	A1	0.97	0.40
	A2	0.98	0.36
	A3	0.99	0.26
Lee et al.(2022)	A1	1.00	0.07
	A2	1.00	0.09
	A3	1.00	0.07
Ko et al.(2022) + Lee et al.(2022)	A1	0.95	0.48
	A2	0.98	0.27
	A3	1.00	0.14




Fig. 11. Comparison of measured and predicted overtopping forces F_{vo} for the three ANN models (Case A1~A3) trained using data from Ko et al.(2022).




Fig. 12. Comparison of measured and predicted overtopping forces F_{vo} for the three ANN models (Case A1~A3) trained using data from Lee et al.(2022).




Fig. 13. Comparison of measured and predicted overtopping forces F_{vo} for the three ANN models (Case A1~A3) trained using data from both Ko et al.(2022) and Lee et al.(2022).

Fig. 13에는 Ko et al.(2022)과 Lee et al.(2022)의 두 실험 데이터를 함께 예측하는 모델의 결과가 제시되었다. 이 경우에는 A3 모델의 성능이 가장 우수한 것으로 나타났으며, 이때 은닉층의 노드 수는 15개였다. 주목할 점은 무차원 입력 및 출력 변수로 구축된 A1 및 A2 모델의 경우에는 Figs. 11~12에 제시된 결과에 비해서 전반적으로 성능이 저하된 반면, 차원 입력 및 출력 변수를 이용하여 구축된 A3 모델은 그러한 경향이 나타나지 않고 여전히 우수한 예측 성능을 보였다. 통상적으로 무차원 변수를 사용함으로써 축적 효과를 제거할 수 있기 때문에 인공신경망 모델 구축 과정에서 무차원 변수를 활용하는 것이 일반적으로 더 선호되는 것으로 알려져 있다(예: Massoudi and Schiffmann, 2025; Qin et al., 2025). 그러나 본 연구에서는 Figs. 11~13에 보인 것처럼 차원을 가지는 변수 조합으로 구성된 인공신경망 모델의 성능이 더 우수한 것으로 나타났다.

일반적으로 무차원 변수를 입력변수로 사용할 경우 차원 변수를 직접 활용할 때보다 데이터의 분포 범위를 줄이기 때문에 인공신경망 모델이 학습해야 할 파라미터 공간이 작아져서 비교적 적은 데이터로도 우수한 모델 성능을 도출할 수 있으며, 축적 차이로 인해 특정 변수가 학습을 지배하는 문제를 완화시킬 수 있다. 그러나 데이터의 개수가 어느 정도 확보되어 있을 경우 무차원화 과정에서 오히려 정보 손실을 일으켜 예측 성능이 저하될 가능성도 존재한다. 본 연구의 경

우 Table 6에 제시된 것처럼 9개 모델의 성능이 정량적으로 모두 우수한 편이었으며, 모델의 성능 차이는 비교적 근소한 편이라고 할 수 있다.

다만, 무차원 입·출력 변수로 구성된 A1 및 A2 모델도 Figs. 6~7에 제시된 Ko et al.(2022) 또는 Lee et al.(2022)의 경험식에 의한 결과보다는 더 좋은 성능을 나타냈다. 기존 연구에서 제시된 경험식들은 개별 실험 조건에 특화되어 있기 때문에 그 외의 실험 데이터에 대해서는 적용하기에 한계가 있는 반면, 인공신경망 모델은 서로 다른 특성을 가지고 있는 실험 데이터가 혼재되어 있는 경우에도 훨씬 더 나은 예측 적합도를 보인다고 할 수 있다.

5. 포장체 하부면 작용 파력 F_{vu} 예측

5.1 F_{vu} 예측을 위한 인공신경망 모델 구성

포장체 하부면에 연직 방향으로 작용하는 파력 F_{vu} 예측을 위한 입력변수 조합은 Table 7에 보인 것처럼 B1~B3의 세 가지 조건으로 다르게 적용하였다. 인공신경망의 기본 구조와 학습 조건은 F_{vo} 예측 모델과 동일하게 적용하였으며, F_{vu} 의 물리적 특성을 반영하여 입력변수 조합을 구성하였다. 한편, Lee et al.(2022)의 연구에서는 F_{vu} 에 대한 계측이 수행되지 않았기 때문에, Ko et al.(2022)의 실험 데이터만 이용하여 인공신경망 모델을 구축하였다.

Table 7. Combinations of dimensional and non-dimensional input and output variables for predicting F_{vu}

Case	Input variables	Output variables
B1	$\frac{H_s}{h}, \frac{L_s}{G_w}, \frac{(A_c - h_l)}{H_s}$	$\frac{F_{vu}}{\rho g H_s^2}$
B2	$\frac{H_s}{h}, \frac{L_s}{G_w}, \frac{(A_c - h_l)}{H_s}, \frac{A_l}{H_s}$	$\frac{F_{vu}}{\rho g H_s^2}$
B3	$h, H_s, T_s, A_c, G_w, A_l$	F_{vu}

5.2 인공신경망 모델의 F_{vu} 예측결과

Fig. 14에는 B1~B3 인공신경망 모델의 예측 결과를 나타내었다. F_{vu} 를 예측하는 세 가지 모델의 IOA는 0.95~0.96 범위로 나타났으며, NRMSE도 0.43~0.46으로 나타나 전반적으로 유사한 성능을 보였다. 이는 B1~B3 모델 간 예측 성능에 차이가 크지 않으며, 세 가지 입력변수 조합 모두 F_{vu} 예측 성능이 비슷한 수준임을 의미한다. 또한, 세 모델 모두 Fig. 4에 제시된 Ko et al.(2022)의 경험식에 따른 비교 결과보다 더 우수한 예측 성능을 보였다. 기존 경험식은 상대적으로 계측값이 큰 범위에서 연직 과력을 과소평가하는 경향을 보였으나, 본 연구에서 수립된 인공신경망 모델들은 Fig. 14에 보인 것처럼 전체 데이터 범위에 대해서 계측값을 상당히 잘 예측하는 것으로 나타났다. 그러므로 B1~B3 모델 모두 F_{vu} 예

측에 적합한 것으로 판단된다.

6. 결 론

본 연구에서는 Ko et al.(2022)과 Lee et al.(2022)의 수리 모형실험 계측 자료를 활용하여 경사식 호안 배후면 포장체에 작용하는 과력을 추정하기 위한 인공신경망 모델을 구축하였다. 월파에 의해 포장체 상부면에 작용하는 과력 F_w 와 포장체 하부면에 작용하는 과력 F_{vu} 를 각각 예측하는 모델을 수립하였으며, 차원 및 무차원 입력변수 조합을 다르게 하여 각 모델의 예측 성능을 서로 비교하였다. 은닉층의 노드 수를 8개에서 15개까지 변화시키고, 무작위로 분할된 200개의 데이터 세트를 이용하여 시드에 따른 모델링 결과의 민감도를 검토함으로써 인공신경망 모델의 과적합 여부를 검토하고 견고하게 작동하는 인공신경망 모델을 수립하였다.

기존 경험식의 적용성을 검토한 결과, Ko et al.(2022) 및 Lee et al.(2022)의 경험식은 각 경험식이 도출된 실험 데이터에 대해서는 일정 수준 이상의 예측 성능을 보였으나, 서로 다른 실험 자료에 대해서는 예측 정확도가 확연히 저하되는 경향을 나타냈다. 이는 기존 경험식이 특정 구조물의 형상 및 파랑 조건에 기반하여 도출되었기 때문에 그와 다른 조건에서 나타나는 수리 특성을 충분히 반영하는 데 한계가 있음을 시사한다.




Fig. 14. Comparison of measured and predicted uplift forces F_{vu} for the three ANN models (Case B1~B3) trained using data from Ko et al. (2022).

월파에 의한 포장체 상부면 작용 파력 F_w 를 예측하는 9개의 인공신경망 모델들은 전반적으로 Ko et al.(2022) 및 Lee et al.(2022)에 제시된 경험식보다 개선된 예측 성능을 보였다. 특히, 두 연구의 실험 자료를 함께 학습한 통합 모델에서도 높은 예측 정확도를 나타내었고, 이를 통해 인공신경망 모델이 서로 다른 실험 환경에서 취득된 자료의 통합 분석 시 매우 효과적임을 확인하였다. 포장체 하부면에 작용하는 연직 파력 F_v 를 예측하기 위해 수립된 3개의 모델도 전반적으로 Ko et al.(2022)에 제시된 경험식보다 향상된 결과를 나타내었다. 따라서 본 연구에서 제시한 인공신경망 모델들은 경사식 호안 배후 포장체에 작용하는 월파력 및 연직 파력 예측 시 활용 가능할 것으로 판단된다.

감사의 글

본 연구는 한국연구재단의 “딥러닝 기반 해안구조물 작용 파력 평가기술 개발” 및 “2025~2026년도 국립창원대학교 자율연구과제” 연구비 지원으로 수행되었으며, 이에 감사드립니다.

References

- Alwosheel, A., Van Cranenburgh, S. and Chorus, C.G. (2018). Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis. *Journal of Choice Modelling*, 28, 167-182.
- Bouthillier, X., Delaunay, P., Bronzi, M., Trofimov, A., Nichyporuk, B., Szeto, J., Sepah, N., Raff, E., Madan, K., Voleti, V., Kahou, S.E., Michalski, V., Serdyuk, D., Arbel, T., Pal, C., Varoquaux, G. and Vincent, P. (2021). Accounting for variance in machine learning benchmarks. *Proceedings of the 3rd MLSys Conference*, Austin, TX, USA.
- Chen, X., Hassan, W., Uijttewaalt, W., Vervaest, T., Verhagen, H.J., Suzuki, T. and Jonkman, S.N. (2012). Hydrodynamic load on the building caused by overtopping waves. *Coastal Engineering Proceedings*, 1(33), structures.59.
- EurOtop (2018). Manual on wave overtopping of sea defences and related structures. An overtopping manual largely based on European research, but for worldwide application. www.overtopping-manual.com.
- Goda, Y., Kishira, Y. and Kamiyama, Y. (1975). Laboratory investigation on the overtopping rate of seawalls by irregular waves. *Technical Report of Port and Airport Research Institute*, 14(4), 3-44.
- Goda, Y. (2010). *Random seas and design of maritime structures*. World Scientific Publishing Co., Singapore.
- Jordan, M.I. and Mitchell, T.M. (2015). *Machine learning: Trends, perspectives, and prospects*. *Science*, 349(6245), 255-260.
- Kim, J.-Y., Wi, H.-C., Kim, D.-S. and Lee, K.-H. (2025). An experimental investigation of uplift pressure in the backfill behind coastal revetments. *Journal of Korean Navigation and Port Research*, 49(6), 702-709 (in Korean).
- Ko, H.S., Lee, J.Y., Jang, S.-C. and Oh, S.-H. (2022). Experimental investigation of wave force on the pavement behind crown wall of rubble mound seawall. *Journal of Korean Society of Coastal and Ocean Engineers*, 34(1), 19-25 (in Korean).
- Lee, J.-I., Moon, G.I. and Kim, Y.I. (2022). Experimental study for downfall pressure on the floor behind rubble-mound structure by wave overtopping: Non-breaking condition. *Journal of Korean Society of Coastal and Ocean Engineers*, 34(2), 27-36 (in Korean).
- Mares-Nasarre, P., Molines, J., Gómez-Martín, M.E. and Medina, J.R. (2021). Explicit neural network-derived formula for overtopping flow on mound breakwaters in depth-limited breaking wave conditions. *Coastal Engineering*, 164, 103810.
- Ministry of Oceans and Fisheries (2024). *Design standards for harbours and fishing ports* (in Korean).
- Massoudi, S. and Schiffmann, J. (2025). Dimensionless group-driven ensemble neural networks for robust design optimization in engineering. *Journal of Computational Design and Engineering*, 12(7), 61-95.
- Oh, J.-E. and Oh, S.-H. (2022). Estimation of the input wave height of the wave generator for regular waves by using artificial neural networks and Gaussian process regression. *Journal of Korean Society of Coastal and Ocean Engineers*, 34(6), 315-324 (in Korean).
- Oh, J.-E. and Oh, S.-H. (2024). Estimation of the input height of irregular waves generated at a wave maker by using Gaussian process regression and artificial neural networks. *Journal of Korean Society of Coastal and Ocean Engineers*, 36(6), 225-232 (in Korean).
- Qin, P., Zhu, H., Jin, F., Lu, W., Meng, Z., Ding, C., Liu, X. and Cheng, C. (2025). Wave run-up distance prediction combined data-driven method and physical experiments. *Journal of Marine Science and Engineering*, 13(7), 1298.
- Watson, P.J., Nuyts, S., Murphy, J., Lizondo, S. and Avgeris, I. (2018). Wave overtopping pressures and spatial distribution behind rubble mound breakwaters. In *Proceedings of the 3rd International Conference on Protection against Overtopping*.
- Willmott, C.J. (1981). On the validation of models. *Physical Geography*, 2(2), 184-194.

Received 19 May, 2026

Revised 30 July, 2026

Accepted 30 July, 2026