

자기회귀 모델과 신경망 모델을 이용한 복잡한 지형 내 항만에서의 파고 및 하역중단 예측

Wave Height and Downtime Event Forecasting in Harbour with Complex Topography Using Auto-Regressive and Artificial Neural Networks Models

이진학* · 류경호* · 백원대* · 정원무*

Jin-Hak Yi*, Kyong-Ho Ryu*, Won-Dae Back* and Weon-Mu Jeong*

요지 : 최근에 기후변화로 인해 너울성 고파 등 이상고파의 출현빈도가 높아지고 항만에서의 하역중단이 증가할 가능성이 커지고 있다. 하역중단을 최소화할 수 있도록 방파제(breakwater) 등을 추가적으로 건설하여 정온도(tranquility)를 향상시키는 것도 매우 중요하지만, 하역중단시점을 미리 예보함으로써 항만 운영을 효율적으로 하는 것도 또한 중요하다. 본 연구에서는 효율적인 항만 운영을 위하여 하역중단시점을 사전에 예보할 수 있도록 바람 예보자료를 이용하여 항외 주요 지점에서의 파랑자료를 추산하고, 복잡한 지형을 가진 항내 주요 지점에 대해서는 장기 관측을 실시하여 파랑자료를 수집한 후, 광역 계산지점에서의 파고와 항내 관측지점에서의 파고 사이의 관계를 자기회귀모델(auto-regressive model)과 인공신경망(artificial neural networks) 모델을 이용하여 바람예보자료를 이용한 수치실험 결과만으로 항내 파고를 예측하고, 하역중단시점을 예보할 수 있는 방법을 제안하였다. 제안방법의 적용성을 평가하기 위하여 포켓(pocket) 형상의 비교적 복잡한 지형 조건을 가진 포항신항 내 파랑관측지점에서의 파고 예측 및 하역중단시점을 예측하였으며, 그 결과를 관측자료와 비교하여 제안 방법의 성능을 검증하였다. 인공신경망 모델의 파고 예측결과를 자기회귀모델에 의한 파고 예측결과와 비교할 때, 인공신경망 모델의 예측결과가 관측자료와의 상관계수가 높고 RMS 오차가 작음을 알 수 있었고, 하역중단시점의 예측에 있어서도 인공신경망의 결과가 자기회귀모델의 결과보다 상대적으로 우수함을 알 수 있었다.

핵심용어 : 자기회귀모델, 인공신경망, 파고예측, 하역중단, 수치실험, 관측

Abstract : Recently, as the strength of winds and waves increases due to the climate change, abnormal waves such as swells have been also increased, which results in the increase of downtime events of loading/unloading in a harbour. To reduce the downtime events, breakwaters were constructed in a harbour to improve the tranquility. However, it is also important and useful for efficient port operation by predicting accurately and also quickly the downtime events when the harbour operation is in a limiting condition. In this study, numerical simulations were carried out to calculate the wave conditions based on the forecasted wind data in offshore area/outside harbour and also the long-term observation was carried out to obtain the wave data in a harbour. A forecasting method was designed using an auto-regressive (AR) and artificial neural networks (ANN) models in order to establish the relationship between the wave conditions calculated by wave model (SWAN) in offshore area and observed ones in a harbour. To evaluate the applicability of the proposed method, this method was applied to predict wave heights in a harbour and to forecast the downtime events in Pohang New Harbour with highly complex topography were compared. From the verification study, it was observed that the ANN model was more accurate than the AR model.

Keywords : auto-regressive model, artificial neural networks, wave height estimation, downtime event, numerical simulation, observation

1. 서 론

최근 기후변화에 따라 이상고파의 출현 가능성이 높아지고 실제로 일부 지역에서는 항만 내에서의 하역 작업이 중단되는 사례가 증가하고 있다. 이와 같은 하역중단의 문제를 근

본적으로 해결하기 위해서는 방파제 등을 추가적으로 건설하여 항내 정온도(tranquility)를 향상시키는 것이 필요하지만, 또한 하역중단시점을 사전에 예보함으로써 항만 운영을 효율적으로 하는 것도 또한 중요하다고 할 수 있다. 항만에서의 하역중단시점을 예보하는 방법으로는 (1) 복잡한 지형을 가진

*한국해양과학기술원 연안공학연구본부(Corresponding author: Weon-Mu Jeong, Coastal Engineering Division, Korea Institute of Ocean Science and Technology, 787, Haeam-ro, Sangnok-gu, Ansan, Gyeonggi-do 15627, Korea, Tel: +82-31-400-6326, Fax: +82-31-408-5823, wmjeong@kiost.ac.kr)

항만 내를 포함하여 광역-세부역 수치실험을 수행하는 방법, (2) 광역-세부역 주요 지점에서의 장기 관측자료를 이용한 비모수 예측모델(non-parametric estimation model)을 이용한 경험적 방법, 그리고 (3) 정확한 계산이 가능한 광역에 대한 수치실험과 복잡한 지형으로 인하여 수치실험이 어려운 항내 세부역에 대해서는 관측을 통한 수치실험-관측 연계방법 등이 연구되고 있다.

본 연구에서는 세 번째 방법으로 제시한 광역에 대한 수치실험과 항만 내 관측 결과를 연계한 방법에 대한 연구를 수행하였다. 기상청의 72시간 바람 예보자료를 이용하여 역추산 파랑자료 산정을 위한 수치실험을 수행하고, 항내 주요지점에서의 장기 파랑관측 결과를 이용하여 바람 예보자료만으로 항내 주요 지점에서의 파랑을 예측할 수 있다. 이때 장기 파랑관측 자료와 수치실험 결과를 연계하기 위하여 인공신경망(artificial neural networks) 또는 자기회귀(auto-regressive) 모델 등을 이용할 수 있다. 이와 같은 방법의 경우 항외 역추산 파랑자료 산정 수치실험 결과의 정확성을 충분히 확보하여야 하며, 또한 항내에서 관측된 파랑관측 자료가 충분히 확보되어 있어야 한다.

신경망을 이용하여 하역중단 시점을 예측하고자 하는 본 연구와 유사한 기존 연구로는 Lopez and Iglesias(2013)의 연구와 Lopez et al.(2015)의 연구가 있다. Lopez and Iglesias(2013)는 항내에서의 외중력과 에너지를 예측하기 위하여 신경망 기법을 이용한 바 있으며, 이후 Lopez et al.(2015)은 항만운영성능 평가를 위하여 신경망 기법을 이용한 바 있다. 외중력과 에너지 예측을 위한 연구에서는 항외에서 관측한 자료를 이용하여 직접 항내 파고를 예측하는 방법과 중간에 위치한 방파제 부근에서의 파고를 이용하여 두 단계로 구성하는 방법을 적용하였으며, 두 방법에 의한 결과를 비교하여 중간 단계를 거치지 않고 바로 항외자료로부터 항내 파고를 예측하는 것이 더 정확한 결과를 제공할 수 제시하였다.

한편, Lopez et al.(2015)의 연구에서는 스페인 북부의 Ferrol 외항(Exterior Port of Ferrol)의 작업성을 평가하기 위하여 대서양 연안에 설치된 Estaca de Bares buoy와 Vilan-Sisargas buoy의 관측자료를 이용하여 항내 파고를 예측하고, 이로부터 월별 하역 중단시간을 평가하였다. 이들을 Ferrol 외항 개발 이후 관측자료가 확보된 2007년부터 2012년까지의 자료를 이용하여 신경망을 훈련시키고, 연안 관측자료만 확보되어 있는 1998년부터 2007년 사이에는 학습된 신경망을 이용하여 관측자료가 없는 항내에서의 파고를 예측하여, 1998년부터 2012년까지 총 14년 동안의 항만 운영성능을 평가하였다. 이들은 신경망의 입력자료로 Estaca de Bares buoy와 Vilan-Sisargas buoy에서 관측된 유의파고, 주기, 파향, 조류 유속, 유향, 그리고 조위자료를 사용하였으며, 신경망의 출력자료로는 Ferrol 외항의 파고를 사용하였다.

한편 국내에서는 Jeong et al.(2011)이 장기간 파랑과 바람 관측을 통하여 포항신항의 하역중단 원인을 분석한 바 있다.

이들은 항내, 항외 다수 정점에서의 파랑관측과 기상청의 기상자료, 포항신항의 하역중단 기록 등을 이용하여 하역중단의 분석하여, 하역중단의 주요 원인을 너울, 풍파 등으로 제시한 바 있다. 한편 Yi et al.(2014)은 Lopez et al.(2015)의 연구와 유사하게 항내 파고 예측을 위하여 항외에서 관측된 자료를 사용하여 신경망을 훈련시키고, 이를 통하여 구성된 신경망을 이용하여 검증한 결과를 AR 모델의 결과와 비교한 바 있다.

본 연구에서는 포항신항이 위치하고 있는 영일만을 포함한 해역에서 SWAN(Simulating WAVes Nearshore) 모델을 이용하여 광역 파랑수치실험을 수행하고, 그 결과를 항내에서 장기 관측한 파랑자료와 연계하였다. 이를 위하여 다중선형회귀 분석모델의 하나인 자기회귀(auto-regressive) 모델(AR 모델)과 비선형 모델인 인공신경망(artificial neural networks) 모델(ANN 모델)을 사용하였으며, 2013년 10월부터 2014년 3월까지의 6개월 자료를 이용하여 AR 모델 및 ANN 모델을 학습(training)시키고, 2014년 4월부터 12월까지의 9개월 자료를 이용하여 각각 모델의 결과를 검증(validation)하였다. 파고 예측결과로부터 하역한계파고를 초과하는 시점을 예측하여 하역중단시점을 예보할 수 있도록 하였다.

2. 이론적 배경

2.1 자기회귀모델(auto-regressive model, AR 모델)

i 번째 시간에서의 임의의 지점에서의 유의파고($H_{s,i}$)는 이전 시간에서 관측 또는 해석된 N_m 개의 과거자료를 이용하여 다음과 같이 자기회귀모델(auto-regressive model, AR 모델)을 이용하여 추정할 수 있다.

$$H_{s,i} = a_0 + a_1 H_{s,i-1} + a_2 H_{s,i-2} + \dots + a_{N_m} H_{s,i-N_m} = a_0 + \sum_{j=1}^{N_m} a_j H_{s,i-j} \quad (1)$$

여기서, a_j 는 AR계수(auto-regressive coefficient)이고, $H_{s,i}$ 는 i 번째 시간에서의 유의파고이다. 총 N 개의 관측자료 혹은 해석된 자료를 훈련자료로 사용하는 경우, 다음과 같이 $N - N_m$ 개의 관계식을 구성할 수 있다.

$$\begin{Bmatrix} H_{s,N_m+1} \\ H_{s,N_m+2} \\ \vdots \\ H_{s,N} \end{Bmatrix} = \begin{bmatrix} 1 & H_{s,N_m} & H_{s,N_m-1} & \cdots & H_{s,1} \\ 1 & H_{s,N_m+1} & H_{s,N_m} & \cdots & H_{s,2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & H_{s,N-1} & H_{s,N-2} & \cdots & H_{s,N-N_m} \end{bmatrix} \begin{Bmatrix} a_0 \\ a_1 \\ \vdots \\ a_{N_m} \end{Bmatrix} \quad (2)$$

위의 관계에서 좌항의 열벡터를 y , 우항의 행렬 및 열벡터를 각각 A , x 라 두면, AR계수로 구성된 열벡터 x 는 다음과 같이 A 의 의사역행렬(pseudo inversion)을 이용하여 구할 수 있다(Sohn et al., 1999).

$$x = (A^T A)^{-1} A^T y \quad (3)$$




Fig. 1. Architecture of multi-perceptrons artificial neural networks.

2.2 인공신경망 모델(artificial neural networks model, ANN 모델)

입력자료와 출력자료 사이의 관계를 다중회귀식을 이용하여 선형적으로 구성하는 AR 모델과 함께 복잡한 형상을 가진 항내 파고 예측을 위하여 다층 퍼셉트론즈(multi-perceptrons) 신경망을 적용하여 그 성능을 AR 모델의 성능과 비교하였다. 인공신경망 기법은 1990년대 중반 이후 기계, 토목, 전기전자, 회계분석 등 여러 분야에서 활발하게 응용된 바 있으며 최근 GPU 및 멀티코어 프로세서 등 하드웨어 성능의 획기적인 개선과 함께 다시 많은 관심을 받고 있는 모델이다(Haykins, 1994). 다층퍼셉트론즈 신경망은 Fig. 1과 같이 하나의 입력층(input layer), 여러 개의 은닉층(hidden layer), 그리고 하나의 출력층(output layer)으로 구성되어 있다. 입력층을 통하여 이전 시간에서 관측 또는 해석을 통하여 알고 있는 유의파고 등의 파랑자료가 입력되고, 출력층에서는 예측하고자 하는 시간에서의 파랑자료가 출력되는 구조로 되어있다. 훈련과정(training process)에서는 기존 확보되어 있는 파랑자료를 이용하여 신경망의 시냅스 강도(synaptic weight) 등을 구하는데, 이를 위하여 일반적으로 역전파학습 알고리즘(back-propagation learning algorithm)을 가장 널리 사용하고 있다.

2.3 파랑변형 수치실험 모델, SWAN(Simulating Waves Nearshore)

본 연구에서 사용한 범용 파랑변형 수치모형 SWAN은 파랑에너지의 천수, 굴절, 회절, 흐름, 바람에 의한 에너지 생성, 백파, 쇄파 등에 의한 에너지감쇠, 파랑간의 4차 비선형 현상, 바닥마찰 등을 모의할 수 있어 주어진 바람과 해저면 및 해류 조건으로부터 연안역, 호수 및 하구 등에서의 파랑을 모사할 수 있다(Booij, 1981; Booij et al., 1999). 한편 SWAN 모형에 사용되는 원천항(source term)에 따라 제1 세대, 제2 세대 및 제3 세대 모형으로 분류되며 이 연구에서는 제3 세대 모형을 사용하였다(The SWAN team, 2008). SWAN 모형의 기본방정식은 파동 평형방정식(wave action balance equation)이며 다음 식에 의하여 표현된다.

$$\frac{\partial N}{\partial t} + \frac{\partial c_x N}{\partial x} + \frac{\partial c_y N}{\partial y} + \frac{\partial c_\sigma N}{\partial \sigma} + \frac{\partial c_\theta N}{\partial \theta} = \frac{S}{\sigma} \quad (4)$$

여기서, N 은 각각 파작용 스펙트럼(wave action spectrum)을 $c_x, c_y, c_\sigma, c_\theta$ 는 각각 x, y, θ, σ 에 대한 선형파이론에 의한 전파속도를 나타낸다. 위 식에서 좌변의 제1 항은 파동 밀도의 시간 변화량, 제2 항과 제3 항은 지리적 공간에서의 파동의 전파, 제4 항은 수심과 흐름의 변화에 의한 상대주파수의 천이, 그리고 제5 항은 수심과 흐름에 의한 굴절을 나타낸다. 평형방정식의 우변 $S[=S(\sigma, \theta)]$ 는 파랑의 생성, 감쇠 및 비선형 상호작용 등에 의한 에너지 밀도를 나타내는 항을 포함한다.

$$S = S_{in} + S_{ds} + S_{nl} \quad (5)$$

여기서, S_{in} 은 바람에 의한 에너지 유입을, S_{ds} 는 백파와 저면마찰 및 쇄파 등에 의한 에너지 소산을 나타내며, S_{nl} 은 성분파간의 비선형 상호작용을 나타낸다. SWAN은 천해역에서의 파랑수치실험을 위하여 많이 이용되고 있으며 보다 자세한 내용은 다른 문헌을 참조할 수 있다(The SWAN Team, 2008; Kim et al., 2007; Jeong et al., 2012; Eum et al., 2016).

3. 항내파고 및 하역중단 예측 모델의 적용 및 분석

3.1 대상 항만 개요 및 관측 위치

본 연구에서 대상항만으로 고려한 포항신항은 영일만 내에 위치하고 있으며, 건설 초기부터 하역중단이 빈번하게 발생하여 부진동 등의 장주기파 영향을 하역중단의 원인에 대한 연구가 진행된 바 있다. 우선 포항신항 내에서의 하역중단에 대한 기록을 간략하게 살펴보면, 겨울철을 포함한 10월에서 3월까지 총 40.1일(75.7%)의 하역중단이 발생하였고, 여름철을 포함한 4월에서 9월까지 총 12.9일(24.3%)의 하역중단이 발생하여, 하역중단은 주로 동계에 발생하는 것을 알 수 있다. 이와 같은 포항신항에서의 하역중단과 관련하여 Jeong et al.(1997)은 1994년 2월 17일부터 3월 31일까지 포항신항 내 외에서 파랑을 동시관측하고, 선석별 하역중단기록(1987~1994년)을 분석하여 항만정온도 불량원인이 풍파와 너울임을 제시한 바 있으며, 또한 Jeong et al.(2011)은 2008년 9월부터 2009년 8월까지 1년 이상 파랑을 관측하고, 관측 파랑 자료와 기상청 기상자료, 선석별 하역중단기록을 분석하여 포항신항에서의 하역중단의 주요 원인이 풍파와 너울임을 재차 확인한 바 있다.

포항신항은 Fig. 2에서 제시한 바와 같이 영일만 내에 위치하며, 포켓형상의 항내는 지형이 매우 복잡하고 또한 정온도 확보를 위하여 외곽 방파제인 북방파제 외에도 항내에 제1, 제2파제체가 설치되어 있어 수치실험을 통하여 파랑을 분석하기 매우 어려운 조건에 있다. 따라서 본 연구에서는 파




Fig. 2. Location of Pohang New Harbour and Observation Stations.

랑예측 모델을 구성하기 위한 항내 파랑자료로 장기 파랑관측 자료를 사용하고자 하였다. 포항신항 내 다수의 정점에서 수압식 파고계(WTG, wave and tide gauge)를 설치하여 2008년부터 현재까지 파랑 관측을 실시하고 있으며, 2013년 10월부터 2014년 12월까지 15개월의 연속 관측자료가 확보되어 있는 W03, W04, W05, W10, W11 등 총 5개 파고계 자료를 이용하여 AR 모델 및 ANN 모델에 의한 파고예측 모델을 구성하고 그 결과를 분석하였다.

3.2 광역 수치실험

일본기상청(JMA, Japan Meteorological Agency)의 바람 예보자료와 SWAN 모형을 사용하여 외해역에서의 역추산 파랑자료를 산정하고, 이를 이용하여 AR 모델 및 ANN 모델의 입력자료로 사용하였다. 바람자료의 공간 범위는 위도 22.4~47.6°N, 경도 120.0~150.0°E이며, 공간해상도는 경도와 위도에 따라 각각 1/16°, 1/20°이다. 한편, 바람자료의 시간 해상도는 6시간 간격의 자료를 사용하였다. 다방향 불규칙과 파랑 수치모형인 SWAN으로 계산한 영역은 117.0~147.0°E, 20.0~50.0°N이며, 계산영역의 공간해상도는 경도, 위도 모두 1/20°로 설정하였다. 한편 매 10분 간격으로 계산 결과를 출력하였으며, 방향 스펙트럼은 0~360°에서 72분할, 주파수는 1/25~1/2.5 Hz에서 21분할하여 적용하였다. 한편, AR 모델 및 ANN 모델을 구성하기 위하여 Fig. 3과 같은 총 5개 지점에서의 계산결과를 이용하였다.

3.3 AR 모델을 이용한 항내 파고 예측

2.1절에서 간략하게 소개한 AR 모델의 경우 하나의 지점




Fig. 3. Locations of calculation points for input data in AR and ANN models.

에서 계산된 과거 파고자료를 이용하는 것으로 실제 적용의 경우 i 번째 항내 위치에 대한 t_i 시점에서의 파고예측을 위하여 항외의 여러 지점에서의 과거자료를 활용할 수 있도록 모델을 구성할 수 있다. 구체적으로 항내에 설치된 파고계 중 2013년 10월 1일부터 2014년 12월 31일까지의 15개월 동안 연속 관측자료가 확보된 W03, W04, W05, W10, W11의 다섯 개 위치에서의 파고를 AR 모델로 추정하기 위하여 수치실험 결과 중 계산 정확성을 확보할 수 있으면서 영일만 내의 파고와 연관성이 높은 C₁ 지점에서부터 C₅ 지점까지의 파고자료를 이용하여 다음의 Table 1에 제시되어 있는 조건과 같이 AR 모델을 구성하였다.

한편, 각 Case별로 사용된 과거자료의 수를 1개에서 30개까지 증가시켜가며 훈련자료를 이용하여 AR 계수를 결정하고, 시험자료를 이용하여 결과를 검증하였다. 훈련자료로는 2013년 10월 1일부터 2014년 3월 31일까지의 6개월 자료를 사용하였으며, 시험자료로는 2014년 4월 1일부터 2014년 12월 31일까지의 9개월 자료를 사용하였다. Fig. 4는 AR 모델에 의한 결과의 한 사례로, C1부터 C3 지점에서의 과거 계산자료 30개를 이용하여 W03 위치에서의 파고를 예측한 결

Table 1. Input information for AR model

Cases	Input information
1	Calculated wave heights at C1
2	Calculated wave heights at C1, C2
3	Calculated wave heights at C1, C2, C3
4	Calculated wave heights at C1, C2, C3, C4
5	Calculated wave heights at C1, C2, C3, C4, C5

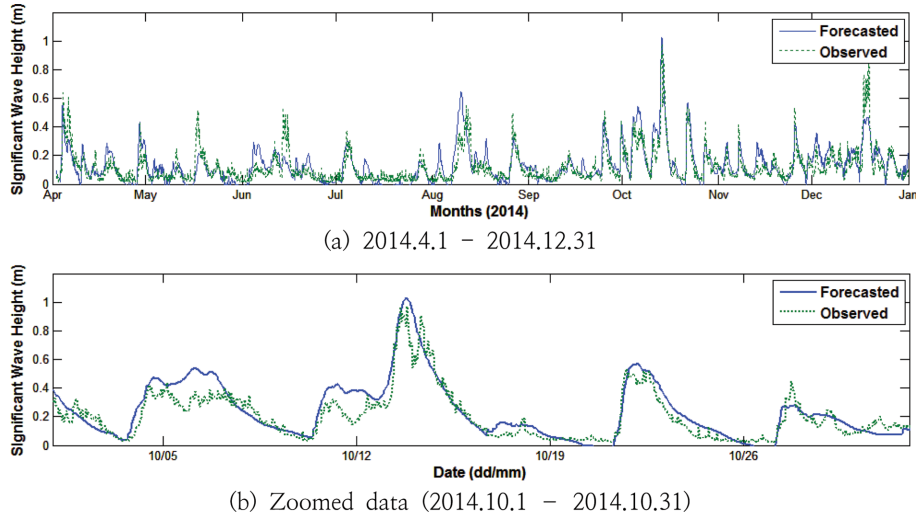


Fig. 4. Comparison between wave heights observed and forecasted by AR model at W03 station.

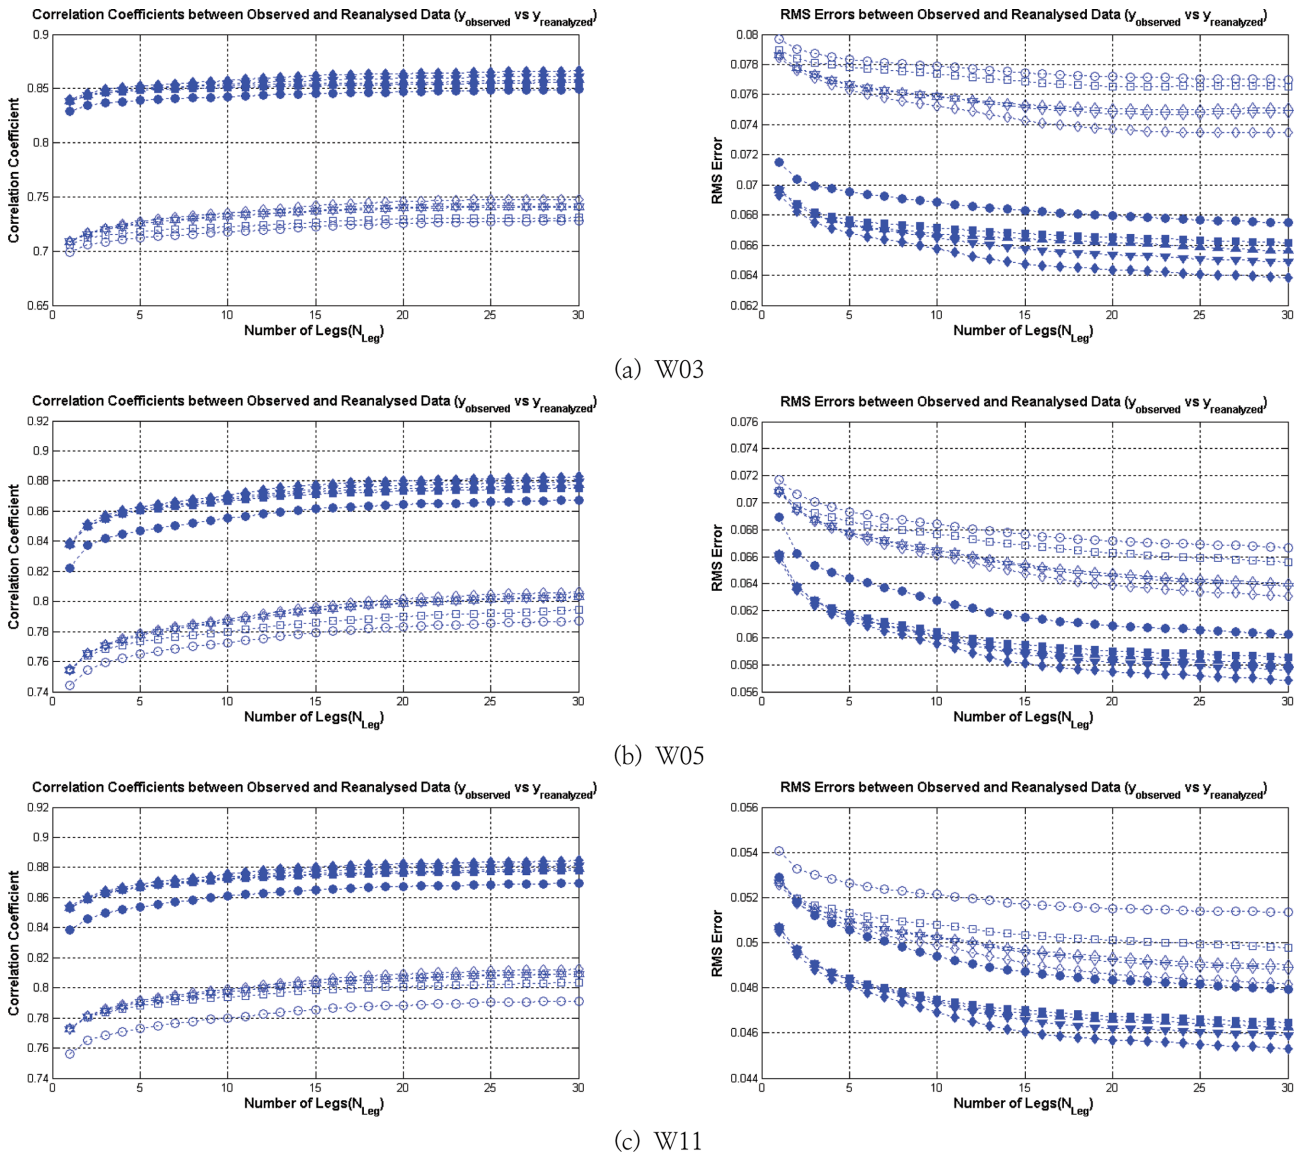


Fig. 5. Correlation coefficients and RMS errors between observed and reanalyzed wave heights (Symbols \circ , \square , \triangle , ∇ and \diamond are for the Case 1, Case 2, Case 3, Case 4, and Case 5 with training data set and symbols \bullet , \blacksquare , \blacktriangle , \blacktriangledown and \blacklozenge are the same cases with testing data set).

과이다. C1부터 C3 지점에서의 과거 계산자료 30개를 사용한 W03 위치에 대한 파고 예측의 경우, 훈련자료에 대한 상관계수 및 RMS 오차는 각각 0.8581, 0.0656 m이며, 시험자료에 대한 상관계수 및 RMS 오차는 각각 0.7406, 0.0751 m이다.

한편, Fig. 5는 W03, W05, W11 등 항내 파고계 3개 위치에서의 Case 1에서부터 Case 5까지 상관계수 및 RMS 오차를 과거 자료의 개수에 대하여 분석한 결과이다. 과거 계산자료의 개수가 증가할 경우 상관계수가 증가하고, RMS 오차가 감소하는 경향을 가지고 있으며, 특히 계산자료의 수가 10개까지 증가하는 경우 그 개선효과가 더욱 뚜렷함을 알 수 있다. 과거 계산자료가 30개라는 것의 의미는 30시간 이전의 파고와 현재의 파고가 어느 정도 관계가 있다는 의미로 분석할 수 있으나, 물리적으로 볼 때 30시간 이전의 파고가 현재 파고에 미치는 영향은 거의 없을 것으로 보이며, 따라서 과거 계산자료의 수가 증가할 때 예측 정확도가 높아지는 것은 일종의 통제(regulation) 효과라 판단하는 것이 바람직할 것으로 판단된다.


한편 계산지점을 증가시킬 경우 상관계수 및 RMS 오차를 살펴보면, W11의 결과와 같이 Case 1에 비하여 Case 2의 결과가 크게 개선되거나 혹은 W05의 결과와 같이 Case 2에 비하여 Case 3의 결과가 크게 개선되는 경향이 있지만, Case 4와 Case 5는 Case 3에 비하여 개선되는 효과가 크지 않음을 알 수 있다. 따라서 Case 3에서와 같이 C1, C2, C3 계산지점에서의 결과를 이용하는 것이 효과적이라는 결과를 도출할 수 있다.

3.4 ANN 모델을 이용한 항내 파고 예측


ANN 모델의 경우 파고만을 사용한 AR 모델과는 달리 주기, 파향 등 다양한 입력정보를 처리할 수 있다. 그러나 과도하게 많은 정보를 입력자료로 사용할 경우 신경망의 훈련

을 통하여 추정하여야 변수, 즉 시냅스 강도(synaptic weight)의 수가 과도하게 증가하여 필요한 훈련패턴의 수도 증가하게 되며, 또한 신경망의 전체적인 성능 또한 오히려 악화될 수 있다. 따라서 추정하고자하는 물리량과 관련성이 높은 정보를 이용하여 입력자료를 구성하는 것이 필요하다. AR 모델에 의하여 항내 파고를 예측한 결과 C1, C2, C3의 세 지점에서의 계산결과를 사용할 때 가장 효과적이었다는 사실을 고려하여, ANN 모델에서도 C1에서의 계산결과만 이용하는 경우, C1, C2에서의 계산결과를 이용하는 경우, 그리고 C1, C2, C3에서의 계산결과를 이용하는 경우로 구분하여 신경망을 구성하고 그 결과를 비교하였다. 또한 ANN 모델의 경우에는 파고와 함께 주기, 그리고 파향 정보를 함께 사용하였다. 파향의 경우 Lopez et al.(2015)의 연구에서와 유사하게 파향에 대한 cosine값과 sine값을 사용하였다. 그리고 AR 모델에서 시간지연효과를 고려할수록 예측결과가 향상된 사실을 고려하여 최대한 많은 과거자료를 사용하고자 하였으나, 너무 많은 과거자료를 사용할 경우 입력자료의 수가 과도하게 증가하므로, 과거 계산자료는 10개까지 사용하였다. 따라서 입력자료의 수는, C1에서의 계산자료만을 사용할 경우, 파고자료 10개, 주기자료 10개, 파향의 cosine값과 sine값 10개 등 총 40개이며, C1, C2를 사용하는 경우에는 총 80개, 그리고 C1, C2, C3에서의 계산결과를 사용하는 경우에는 총 120개가 된다. 한편 은닉층(hidden layer)의 뉴런 수도 경험적, 또는 프루닝(pruning)을 이용하여 결정할 수 있는데, 이 연구에서는 입력자료의 수와 출력자료의 수를 고려하여 경험적으로 첫 번째 은닉층과 두 번째 은닉층의 뉴런 수를 각각 10개로 고려하였다. 출력층은 AR 모델에서 고려한 것과 같이 W03, W04, W05, W10, W11 등 다섯 개 파고계 위치에서의 파고를 사용하였다.

한편 아래의 Fig. 6는 C1, C2, C3에서의 계산결과를 이용하여 ANN 모델에 의하여 예측된 W03 파고계 위치에서의



(a) 2014.4.1 - 2014.12.31



(b) Zoomed data (2014.10.1 - 2014.10.31)

Fig. 6. Comparison between wave heights observed and forecasted by ANN model at W03 station.

과고 결과이다. 이 경우 훈련패턴에 대한 상관계수와 RMS 오차는 각각 0.9169, 0.0622 m이며, 시험패턴에 대한 상관계수와 RMS 오차는 각각 0.8493, 0.0644 m이다. 이는 30개의 과거자료를 이용한 AR 모델의 결과, 즉 훈련자료에 대한 상관계수(0.8581) 및 RMS 오차(0.0656 m) 그리고 시험패턴에 대한 상관계수(0.7406) 및 RMS 오차(0.0751 m)와 비교할 때 AR 모델의 예측결과보다는 관측자료에 더 가까운 결과를 보여줄 수 있다. AR 모델과 ANN 모델을 비교할 때, AR 모델은 선형예측모델(linear estimation model)로 입력정보로 사용된 계산지점에서의 과고와 실제 관측한 지점에서의 과고 사이의 관계를 선형관계로 고려한 것인데 비하여, ANN 모델은 비선형 시그모이드 함수(nonlinear sigmoid function)를 사용함으로써 이 두 정보 사이의 관계를 비선형모델로 고려할 수 있다는 차이가 있다. 결국 ANN 모델이 AR 모델보다 예측 정확도가 높은 것은 항내에서의 복잡한 지형 및 파제제 등에 의한 비선형 파랑변형 효과를 ANN 모델이 더 잘 모사할 수 있기 때문인 것으로 판단할 수 있다.


추가적인 분석을 위하여 Fig. 7에서 AR 모델과 ANN 모델을 사용할 경우 상관계수 및 RMS 오차를 비교하였다. 이 결과에서 AR 모델은 30개의 과거 계산자료를 이용한 것이며, ANN 모델은 10개의 과거 계산자료를 이용한 것이다. 또한 AR 모델은 과고자료만을 이용하고, ANN 모델은 과고와 함께 주기, 파향을 함께 고려한 자료이다. AR 모델과 ANN

모델 모두 C1에서의 계산자료를 사용한 결과보다는 C1, C2, C3에서의 계산결과를 사용할 때 상관계수가 증가하고, RMS 오차가 감소됨을 알 수 있다. 또한 ANN 모델의 경우 AR 모델보다 모든 과고계 위치에서의 예측성능이 더욱 우수함을 알 수 있다. 이는 전술한 바와 같이 복잡한 지형 및 파제제 등에 의한 비선형 파랑변형의 효과를 더 잘 모사하였기 때문인 것으로 판단된다. 한편 W03 과고계 위치에서의 상관계수가 상대적으로 작고, RMS 오차가 큰 것을 알 수 있으며, W11 과고계 위치에서의 상관계수가 상대적으로 가장 크고, RMS 오차가 가장 작은 것을 알 수 있다. 이는 W03 과고계가 안벽 내에 위치하고 있고, W11은 상대적으로 안벽 바깥에 위치하고 있어 지형적인 복잡도가 W03이 상대적으로 높는데 따른 결과라 판단된다.


3.5 AR 모델과 ANN 모델을 이용한 하역중단시점 예측 결과

하역한계파고(limiting operational wave height)는 컨테이너선 또는 일반 화물선 등과 같이 선박 종류 및 크기에 따라 달리 제시될 수 있으나(Lopez et al., 2015), 이 연구에서는 하역중단시점을 Lopez et al.(2015)의 연구에서 컨테이너선, RO-RO 선박 등에 대하여 적용한 하역한계파고 기준인 0.5 m를 고려하였다. 하역작업은 주야간 동일한 조건으로 작업이 가능한 것으로 가정하였으며, 하역한계파고 기준으로만 하역중단시점을 분석하였다. 또한 하역중단시점을 결정하기 위한 AR 모델은 30개의 과거자료를 이용한 경우에 대해서만 분석하였고, AR 모델과 ANN 모델 모두 C1, C2, C3에서의 계산결과를 이용한 모델을 적용하였다.

Fig. 8은 항내 설치된 W05 과고계 위치에서 관측된 과고자료로부터 안벽에서의 하역중단시점을 결정한 결과와 AR 모델 및 ANN 모델을 이용하여 하역중단시점을 예측한 결과를 비교한 것이다. 결과를 보면 2014년 10월 발생한 2번의 하역중단시점 중 첫 번째 하역중단시점의 경우 AR 모델 및 ANN 모델이 모두 정확하게 예측하였지만, 두 번째 하역중단시점은 두 모델 모두 정보하지 못하는 오류, 즉 정보누락오류(downtime event missing error, DME)가 발생하였음을 알



(a) Correlation coefficients



(a) RMS errors

Fig. 7. Comparisons of correlation coefficients and RMS errors of the forecasted wave heights obtained from AR and ANN models.




Fig. 8. Comparison of downtime events forecasted by AR and ANN models in 2014.

Table 2. DME and FAE in AR and ANN models

		Stations					Total
		W03	W04	W05	W10	W11	
Number of downtime events decided by observed data		3	9	4	5	2	23
AR model	DM ¹⁾	2	4	3	3	1	13
	FA ²⁾	1	1	1	0	0	3
ANN model	DM	1	1	2	1	0	5
	FA	1	0	0	2	0	3

¹⁾ DM denotes the downtime event missing.

²⁾ FA denotes the false alarming.

수 있다. 한편, 2014년 8월의 경우 하역중단이 발생하는 파고가 없었음에도 불구하고 AR 모델의 경우 오경보하는 오류(false alarming error, FAE)가 발생하였다. W05 파고계 위치에서의 경우 AR 모델은 총 3회의 경보누락 오류가 발생하고, 1회의 오경보 오류가 발생하였으며, ANN 모델의 경우 총 2회의 경보누락 오류가 발생하였음을 알 수 있다.

한편, Table 2는 연구에서 사용된 5개 파고계에서의 관측 파고와 AR 및 ANN 모델을 이용하여 예측한 파고로부터 하역중단시점을 예측한 결과로, 파고가 0.5 m를 초과한 총 23개 시점에 대하여, AR 모델의 경우 13개 하역중단시점을 누락하는 오류가 발생하였고, ANN 모델의 경우 5개 하역중단시점을 누락하는 오류가 발생하였음을 알 수 있다. 한편 오경보 오류는 두 모델 모두 3개 시점으로 분석되었다. 이와 같이 오경보 및 경보누락과 같은 오류는 AR 모델, ANN 모델에 모두 발생하고 있으나, 전체적으로 볼 때 AR 모델보다는 ANN 모델이 비교적 하역중단 시점을 정확하게 예측하고 있음을 알 수 있다.

ANN 모델과 AR 모델 모두 하역중단 시점을 예측하는데 어느 정도의 오류가 있는 것은 이 연구에서 입력정보로 사용하고 있는 파랑추산자료는 일본기상청의 바람예보자료를 바탕으로 수치실험모델인 SWAN을 이용하여 계산한 것으로, 첫째, 바람예보자료에 포함될 수 있는 오류와 둘째, 수치실험모델인 SWAN에 포함되어 있는 지형정보 및 수심정보 등에 포함되어 있는 오류 및 SWAN 모델이 고려하지 못하는 실제 물리현상 등에 의한 오류 때문인 것으로 판단된다. 따라서 보다 정확한 하역중단 시점 예측을 위해서는 이와 같은 오류를 줄이도록 하는 추가 연구가 필요하리라 판단된다.

4. 결 론

이 연구에서는 바람장을 이용한 광역에서의 항외 정점에 대한 역추산 파랑자료 산정 수치실험 결과와 항만 내 관측 결과를 자기회귀(auto-regressive) 모델 및 인공신경망 모델로 바람예보 자료만을 가지고 파고를 예측하고, 하역중단시점을 예보할 수 있는 기법을 제안하였으며, 제안기법을 검증하기 위하여 하역중단 발생빈도가 높은 포항신항에 대하여 2013년 10월부터 2014년 12월까지의 15개월 동안의 항내 관측자료

와 광역의 항외 파랑자료 산정 수치실험 결과를 사용하였다. AR 모델과 ANN 모델의 파고예측 정확성과 이를 바탕으로 하역중단시점을 예측하였으며, 다음과 같은 결론을 도출할 수 있었다.

(1) AR 모델의 경우 과거 계산자료의 개수를 증가할 경우 파고 예측성능이 향상됨을 알 수 있었고, 특히 계산자료의 수가 10개까지 증가하는 경우 그 개선효과가 더욱 뚜렷하였다. 한편, 과거 계산자료를 10개 이상사용하는 경우 개선효과가 어느 정도 있었으나 이는 일종의 통제(regulation) 효과라 판단된다.

(2) AR 모델의 경우 계산지점을 증가시킬수록 예측성능이 향상되었으며, 특히 C1, C2, C3에서의 계산결과를 사용하는 경우 입력자료의 수에 비하여 개선효과가 가장 큼을 알 수 있었다.

(3) ANN 모델의 파고 예측결과를 AR 모델에 의한 파고 예측결과와 비교할 때, ANN 모델의 예측결과가 관측자료와의 상관계수가 높고 RMS 오차가 작음을 알 수 있었다. 이와 같이 ANN 모델의 성능이 상대적으로 우수한 것은 항내에서의 복잡한 지형 및 파제제 등에 의한 비선형 파랑변형 효과를 ANN 모델이 더 잘 모사할 수 있기 때문인 것으로 판단된다.

(4) AR 모델과 ANN 모델을 이용하여 예측한 파고로부터 하역중단시점을 예측한 결과, 하역중단시점 누락 오류의 횟수가 AR 모델의 경우 총 13회, ANN 모델의 경우 총 5회로 ANN 모델의 예측성능이 AR 모델보다 우수함을 알 수 있다. 그러나 ANN 모델의 경우에도 5회의 하역중단시점 누락 오류와 3회의 오경보 오류가 발생하여 추가적인 연구를 통하여 ANN 모델의 성능을 개선할 필요가 있음을 알 수 있다. 이를 위하여 광역 수치실험을 위한 격자를 개선하여 수치실험의 정확성을 향상시키고, ANN 모델의 훈련 시 더욱 장기간의 항내 관측자료를 활용함으로써 ANN 모델의 예측성능을 향상시킴으로써 항만의 하역중단시점을 더 정확하게 예측할 수 있을 것으로 사료된다.

이 연구에서는 하역한계파고를 0.5 m로 고려하였으나 향후 파고뿐만 아니라 파주기 및 실제 대상선박의 규모, 특성 등을 반영하여 보다 실제적인 하역한계파고에 대한 연구를 수행할 필요가 있으리라 판단된다.

감사의 글

본 연구는 한국해양과학기술원의 “연안침식저감 원천기술 개발(PE99523)”의 연구비 지원에 의해 수행되었으며, 이에 감사드립니다.

References

- Booij, N. (1981). Gravity waves on water with non-uniform depth and current. Report No. 81-1, Dept. of Civil Eng., Delft Univ. of Technology.
- Booij, N., Ris, R.C. and Holthuijsen, L.H. (1999). A third-generation wave model for coastal regions 1. Model description and validation. *J. of Geophysical Research*, 103(C4), 7649-7666.
- Eum, H.-S., Kang, T.-S., Nam, S.-Y. and Jeong, W.-M. (2016). Wave modeling considering water level changes and currents effects. *Journal of Korean Society of Coastal and Ocean Engineers*, 28(6), 383-396 (in Korean).
- Haykin, S., *Neural networks-a comprehensive foundation*, Macmillan, New York, USA, 1994.
- Jeong, W.M., Oh, S.B., Chae, J.W. and Kim, S.I. (1997). Analysis of the wave induced downtimes in Pohang New Harbor. *Journal of Korean Society of Coastal and Ocean Engineers*, 9(1), 24-34 (in Korean).
- Jeong, W.M., Jun, K.C., Kim, G., Oh, S.-H. and Ryu, K.-H. (2012). Shallow-water design waves at Gangreung Beach through the analysis of long-term measured wave data and numerical simulation using deepwater wave conditions. *Journal of Korean Society of Coastal and Ocean Engineers*, 24(5), 343-351 (in Korean).
- Jeong, W.M., Ryu, K.H., Baek, W.D. and Choi, H.J. (2011). Downtime analysis for Pohang New Harbor through long-term investigation of waves and winds. *Journal of Korean Society of Coastal and Ocean Engineers*, 23(3), 226-235 (in Korean).
- Kim, J.M., Hur, D.S., Kim, C.H. and Kim, D.S. (2007). Shallow water wave hindcasting by the combination of MASCON and SWAN models. *Journal of Korean Society of Coastal and Ocean Engineers*, 19(1), 57-65 (in Korean).
- Lopez, M. and Iglesias, G. (2013). Artificial intelligence for estimating infra gravity energy in a harbour. *Ocean Engineering*, 57, 56-63.
- Lopez, I., Lopez, M. and Iglesias, G. (2015). Artificial neural networks applied to port operability assessment. *Ocean Engineering*, 109, 298-308.
- Sohn, H., Dzwonczyk, M., Straser, E.G., Kiremidjian, A.S., Law, K.H. and Meng, T. (1999). An experimental study of temperature effect on modal parameters of the Alamosa Canyon Bridge. *Earthquake Engineering Structural Dynamics*, 28, 879-897.
- The SWAN team (2008). SWAN Cycle III version 40.72 Technical Documentation.
- Yi, J.-H., Ryu, K.-H., Jeong, W.-M. and Baek, W.-D. (2014). Downtime forecasting technique in harbour using artificial neural networks model, *Proceedings of International Conference on Coastal Engineering*, Seoul, Korea.

Received 16 August, 2017

Revised 21 August, 2017

Accepted 25 August, 2017