

순환 신경망 모델을 이용한 소형어선의 운동응답 예측 연구

서장훈* · 박동우** · 남동***

* 동명대학교 조선해양시뮬레이션센터 연구원, ** 동명대학교 해양모빌리티학과 교수,

*** 한국해양교통안전공단 교통연구본부장

Study on the Prediction of Motion Response of Fishing Vessels using Recurrent Neural Networks

Janghoon Seo* · Dong-Woo Park** · Dong Nam***

* Researcher, Shipbuilding & Marine Simulation Center, Tongmyong University, Busan 48520, Korea

** Professor, Department of Marine Mobility, Tongmyong University, Busan 48520, Korea

*** Executive Director, Department of Marine Mobility, Korea Maritime Transportation Safety Authority, Sejong-si, 30100, Korea

요약 : 본 논문에서는 소형어선의 운동 응답을 예측하기 위해 딥러닝 모델을 구축하였다. 크기가 다른 두 소형어선을 대상으로 유체 동역학 성능을 평가하여 데이터셋을 확보하였다. 딥러닝 모델은 순환 신경망 기법의 하나인 장단기 메모리 기법(LSTM, Long Short-Term Memory)을 사용하였다. 딥러닝 모델의 입력 데이터는 6 자유도 운동 및 파고의 시계열 데이터를 사용하였으며, 출력 라벨로는 6 자유도 운동의 시계열 데이터로 선정하였다. 최적 LSTM 모델 구축을 위해 hyperparameter 및 입력창 길이의 영향을 평가하였다. 구축된 LSTM 모델을 통해 입사파 방향에 따른 시계열 운동 응답을 예측하였다. 예측된 시계열 운동 응답은 해석 결과와 전반적으로 잘 일치함을 확인할 수 있었다. 시계열의 길이가 길어짐에 따라서 예측값과 해석 결과의 차이가 발생하는데, 이는 장기 데이터에 따른 훈련 영향도가 감소됨에 따라 나타난 것으로 확인할 수 있다. 전체 예측 데이터의 오차는 약 85% 이상의 데이터가 10% 이내의 오차를 보였으며, 소형어선의 시계열 운동 응답을 잘 예측함을 확인하였다. 구축된 LSTM 모델은 소형어선의 모니터링 및 경보 시스템에 활용될 수 있을 것으로 기대한다.

핵심용어 : 딥러닝, 순환 신경망, 장단기 메모리, 소형어선, 운동성능

Abstract : In the present study, a deep learning model was established to predict the motion response of small fishing vessels. Hydrodynamic performances were evaluated for two small fishing vessels for the dataset of deep learning model. The deep learning model of the Long Short-Term Memory (LSTM) which is one of the recurrent neural network was utilized. The input data of LSTM model consisted of time series of six(6) degrees of freedom motions and wave height and the output label was selected as the time series data of six(6) degrees of freedom motions. The hyperparameter and input window length studies were performed to optimize LSTM model. The time series motion response according to different wave direction was predicted by established LSTM. The predicted time series motion response showed good overall agreement with the analysis results. As the length of the time series increased, differences between the predicted values and analysis results were increased, which is due to the reduced influence of long-term data in the training process. The overall error of the predicted data indicated that more than 85% of the data showed an error within 10%. The established LSTM model is expected to be utilized in monitoring and alarm systems for small fishing vessels.

Key Words : Deep learning, Recurrent neural network, Long short-term memory, Fishing vessel, Hydrodynamic performance

1. 서론

어선의 해양 안전사고는 연평균 약 10% 증가하는 추세이

다(Choi et al., 2021). 특히 소형어선의 해양사고 척수는 전체 중 큰 비중을 차지하고 있으며, 이는 인명피해와 직결된다(Korean Maritime Safety Tribunal, 2021). 어선의 해양 안전사고는 기관손상, 충돌, 기타사고 등 다양한 유형을 가지고 있으나, 전복, 침몰 및 운항저해에 의한 사고는 어선의 파랑 중

* First Author : janghoon.seo@tu.ac.kr, 051-629-3664

† Corresponding Author : namdong9@gmail.com, 044-330-2205

운동성능과 관련이 있다. 파랑 하중에 의한 어선의 해양 안전사고는 운동성능 정보 또는 예측 시스템을 이용해 예방할 수 있으므로 이에 관한 연구와 개발이 필요하다.

어선의 파랑 중 운동성능 특성을 평가하기 위한 선행연구는 다양한 어선의 크기, 환경조건 및 선속 등을 고려한 연구가 진행되었다(Hwang and Rhee, 1980; Kang et al., 2007; Park et al., 2011; Im and Lee, 2021). 특히 Yang and Kwon(2017)은 실험을 통해 얻은 시계열 횡동요 데이터를 바탕으로 전복 경보 시스템 알고리즘을 검증하였다. Abankwa et al.(2015)는 Inertial Measurement Unit(IMU)를 이용하여 어선의 roll, pitch와 heave를 계측하였다.

선행연구에서 수행한 어선의 운동성능 특성 평가는 수치해석 시간 및 모델의 작성이 필요해 실시간 예측에 한계가 있으며 계측 시스템은 운용 및 설치나 시스템 구축에 부담이 발생한다. 이를 극복하고자, 최근 인공지능 모델을 활용하여 선박의 운동성능을 예측하는 연구가 수행되었다. Kim et al.(2018)은 기계학습모델을 이용하여 선박의 횡동요를 예측하였으며, Guo et al.(2021)은 반잠수식 구조물의 heave와 surge 운동을 딥러닝 모델(deep learning)을 이용하여 예측하였다. Ferrandis et al.(2021)은 순환 신경망(Recurrent Neural Network, RNN)을 이용하여 극한 환경조건 시 쌍동선의 시계열 운동성능을 예측하였으며, Xu et al.(2021)은 합성곱 신경망(Convolutional Neural Network)과 장단기 메모리 기법(Long Short-Term Memory, LSTM)을 조합하여 선박의 운동성능을 예측하였다. Zhang et al.(2023)은 장단기 메모리 기법을 이용하여 선박의 운동성능을 예측하고 이를 전산유체역학(Computational Fluid Dynamics, CFD) 해석 결과와 비교하였다.

이러한 인공지능을 통한 선박의 운동성능 예측 선행 연구는 대부분 일반 상선 및 해양 구조물을 대상으로 수행됐으며, 해양 안전사고의 큰 비중을 차지하는 소형어선에 대한 시계열 운동성능의 예측은 수행된 바 없다. 이에 본 연구에서는 소형어선의 운동성능을 예측하기 위한 딥러닝 모델을 구축하고자 한다. 두 척의 어선에 대한 운동성능 해석을 수행하여 딥러닝 모델의 데이터베이스를 생성하고, 순환 신경망 기반의 딥러닝 모델을 학습한다. 학습된 모델을 이용하여 소형어선의 운동성능을 예측하고, 해석 결과를 비교하여 구축된 딥러닝 모델을 확립하고자 한다.

2. 운동성능 데이터세트 구축

2.1 대상선박

본 연구에 사용된 대상 선박은 9.77톤(FV1) 및 3톤(FV2) 크기의 소형어선으로서 주요 제원과 선형은 Table 1 및 Fig. 1에 각각 나타나 있다.

Table 1. Main particulars of fishing vessels

Main particulars	Symbol [unit]	FV1 (9.77 Ton)	FV2 (3 Ton)
Length between Perpendiculars	L _{BP} (m)	14.520	9.460
Breadth	B(m)	3.800	2.870
Depth	D(m)	1.180	0.860
Draft at midship	d(m)	0.629	0.440
Displacement	▽(Ton)	30.951	10.968
Longitudinal Center of gravity	LCG(m)	-1.592	-1.306
Vertical center of gravity	VCG(m)	1.269	1.210
Metacenter	GM(m)	0.877	0.589




Fig. 1. Perspective view of fishing vessels: (a) FV1 and (b) FV2.

2.2 운동성능 평가

소형어선의 운동성능 데이터세트를 구축하기 위해 3 차원 radiation-diffraction 기반의 유체동역학 해석을 수행하였다. 유체동역학 해석은 상용 프로그램인 Ansys AQWA를 사용하였다. 시간 영역을 바탕으로 한 선박의 6 자유도 운동방정식은 식(1)과 같다.

$$(M+A)\ddot{X}(t)+C\dot{X}(t)+KX(t)+\int_0^t R(t-\tau)\dot{X}(\tau)d\tau=F(t) \quad (1)$$

여기서 t , X , R 와 F 는 각각 시간, 운동 응답, 지연함수 및 외력을 나타낸다. 그리고 M , A , C 와 K 는 질량, 부가질량, 선형 감쇄 계수 및 강성계수를 나타낸다.

해석에 사용되는 좌표계 및 환경조건 방향을 Fig. 2에 나타내었다. 환경조건 방향은 선수(180°), 선측(90°) 및 선수와 선측 사이(135°)를 고려하였으며, 환경조건은 어선의 운용 조건인 유의파고 1.5 m와 피크 주기 8초를 반영하였다. 파 스펙트럼은 JONSWAP(JOint North Sea WAve Project)를 사용하였으며 피크 증폭 계수 γ 는 3.3으로 선정하였다. 해석에




Fig. 2. Coordinate system in hydrodynamic analysis.




Fig. 3. Panel meshes used in hydrodynamic analysis: (a) FV1 and (b) FV2.

사용된 비선형 감쇄 계수는 자유 감쇄 모형실험 결과를 이용하였다. 딥러닝 모델에 사용되는 시계열 데이터의 길이는 총 10,800초이며, 0.1초 간격으로 구성되어 있다.

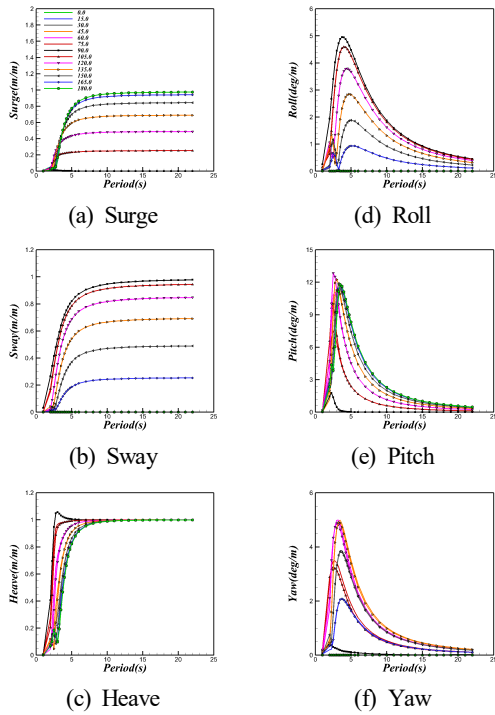


Fig. 4. Motion RAOs for FV1.

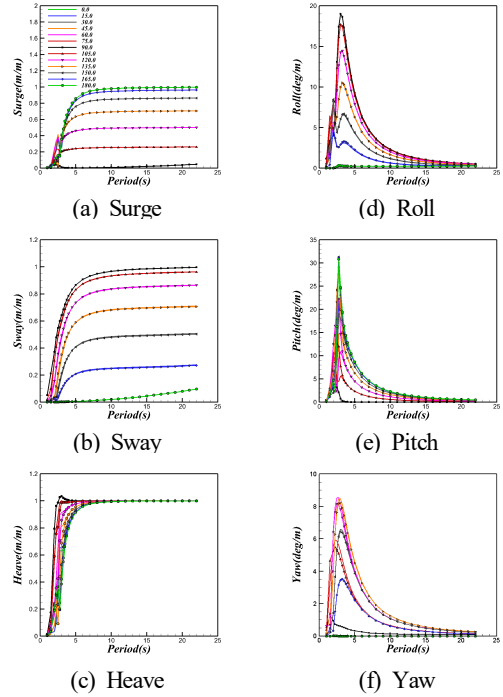


Fig. 5. Motion RAOs for FV2.

유체동역학 해석에 사용된 두 소형어선의 3차원 패널을 Fig. 3에 나타내었다. 수면 아래 소형어선의 3차원 패널 수는 약 2,500개를 사용하였다. 유체동역학 해석 결과로서 FV1과 FV2의 단위 파고 별 운동 응답인 RAO(Response Amplitude Operator)를 Fig. 4와 5에 각각 나타내었다.

3. 딥러닝 모델 구축

어선의 시계열 운동성능을 예측을 위한 딥러닝 모델은 LSTM 기법을 사용하였다. 이는 변형된 RNN 모델로서 장기 시계열 데이터를 예측하는 데 효과적으로 알려져 있다(Son et al., 2020). 장단기 메모리 기법의 내부는 Fig. 6과 같이 망각게이트(Forget gate), 입력 게이트(Input gate)와 출력 게이트(Output gate)로 구성되어 있으며, 각 게이트는 sigmoid 함수 및 tanh 함수를 통해 이전 시점의 cell state (c), hidden state (h_{t-1})와 현재 시점의 입력 데이터(x_t)를 이용하여 다음 시점 (h_t)의 예측을 수행한다. LSTM 모델 내부의 연산은 식(2)~(7)에 나타냈다.

$$f_t = \sigma(W_{xh_f}x_t + W_{hh_f}h_{t-1} + b_{h_f}) \quad (2)$$

$$i_t = \sigma(W_{xh_i}x_t + W_{hh_i}h_{t-1} + b_{h_i}) \quad (3)$$

$$o_t = \sigma(W_{xh_o}x_t + W_{hh_o}h_{t-1} + b_{h_o}) \quad (4)$$




Fig. 6. A diagram of LSTM layer.




Fig. 7. Schematic architecture of LSTM model.

$$g_t = \tanh(W_{xh_g}x_t + W_{hh_g}h_{t-1} + b_{h_g}) \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (6)$$

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

여기서 W , b , σ 와 \odot 는 각각 weight, bias, sigmoid function과 element-wise product 나타낸다.

소형어선의 운동성능을 예측하기 위한 모델의 구조를 Fig. 7에 나타내었다. 입력 데이터는 6 자유도 시계열 운동 응답과 어선 위치에서의 파고 높이로 구성된다. 특정 t 시점에서의 운동 응답 및 파고 높이에서 창(window)의 길이 ($t + \Delta t_I$)만큼으로 나누어 입력 데이터를 구성한다. 출력 라벨은 입력 데이터 창의 길이 후 $t + \Delta t_I + \Delta t_O$ 시간까지의 6 자유도 시계열 운동 응답이며 본 연구에서는 Δt_O 를 10초로 선정하였다.

LSTM의 비선형 효과를 고려하기 위한 activation function은 ReLU(Rectified Linear Unit)을 사용하였다. 입력 데이터 및 출력 라벨은 0에서 1로 정규화(normalization) 되어 훈련 및 테스트에 사용되었다. 최적화 기법으로는 ADAM(ADaptive Moment estimation) 기법을 사용하였으며, 손실함수는 평균 제곱근 오차(Mean Squared Error, MSE)를 적용하였다.

4. 결과 및 고찰

4.1 LSTM 모델 훈련

최적의 LSTM 모델을 선정을 위한 hyperparameter 변수 및

window 길이의 영향을 확인하였다. 먼저 hyperparameter 변수의 영향을 확인하기 위해 FV1 선박을 이용하여 Table 2에 나타낸 바와 같이 LSTM 층의 개수를 1과 2로 주었으며, LSTM 층의 뉴런 수를 100, 200과 300개로 변경하며 예측 결과를 비교하였다. Hyperparameter 변화에 따른 예측 결과를 비교하기 위해 선수 환경하중 조건에서 FV1 선박의 손실함수 수렴도를 Fig. 8에 나타내었다. LSTM 층의 개수가 2인 경우, 모델의 복잡도가 상승함에 따라 동일한 epoch에서 손실함수의 수렴 정도가 크다. 뉴런 수가 증가할 시 훈련이 최종 진행될 때 손실함수가 일정한 수렴에 도달하며 모델 간의 큰 차이를 보이지 않는다. 전반적으로 L2N100을 제외한 나머지 모델의 손실함수 수렴도가 마지막 epoch에서 큰 차이를 보이지 않는다. 이에 따라 L1N200을 최종 모델을 선정하였으며 향후 운동성능 예측에 사용하였다.

선정된 LSTM 모델을 이용하여 입력 데이터의 창(t_I)의 길이를 10초, 40초와 90초로 변화시켜 가며 예측의 정확도를 확인하였다. 입력 데이터 창의 길이 변화에 따른 FV1 선박의 선수 환경하중 조건에서 주요 예측 결과를 Fig. 9에 나타내었다. 입력 데이터 창의 길이가 짧은 경우, 예측의 정도가 감소함을 확인할 수 있으며, t_I 가 40초와 90초인 경우 해석 결과와 유사한 값을 예측한다. 이에 따라 t_I 는 40초로 선정하여 모델을 구축하였다.

Table 2. Hyperparameter study with variable number of layers and neurons

Case	Number of LSTM layer	Number of neurons in LSTM layer
L1N100	1	100
L1N200	1	200
L1N300	1	300
L2N100	2	100
L2N200	2	200
L2N300	2	300




Fig. 8. Convergences of loss values.

순환 신경망 모델을 이용한 소형어선의 운동응답 예측 연구




Fig. 9. Predicted motions for FV1 with different length of input window at head sea condition.

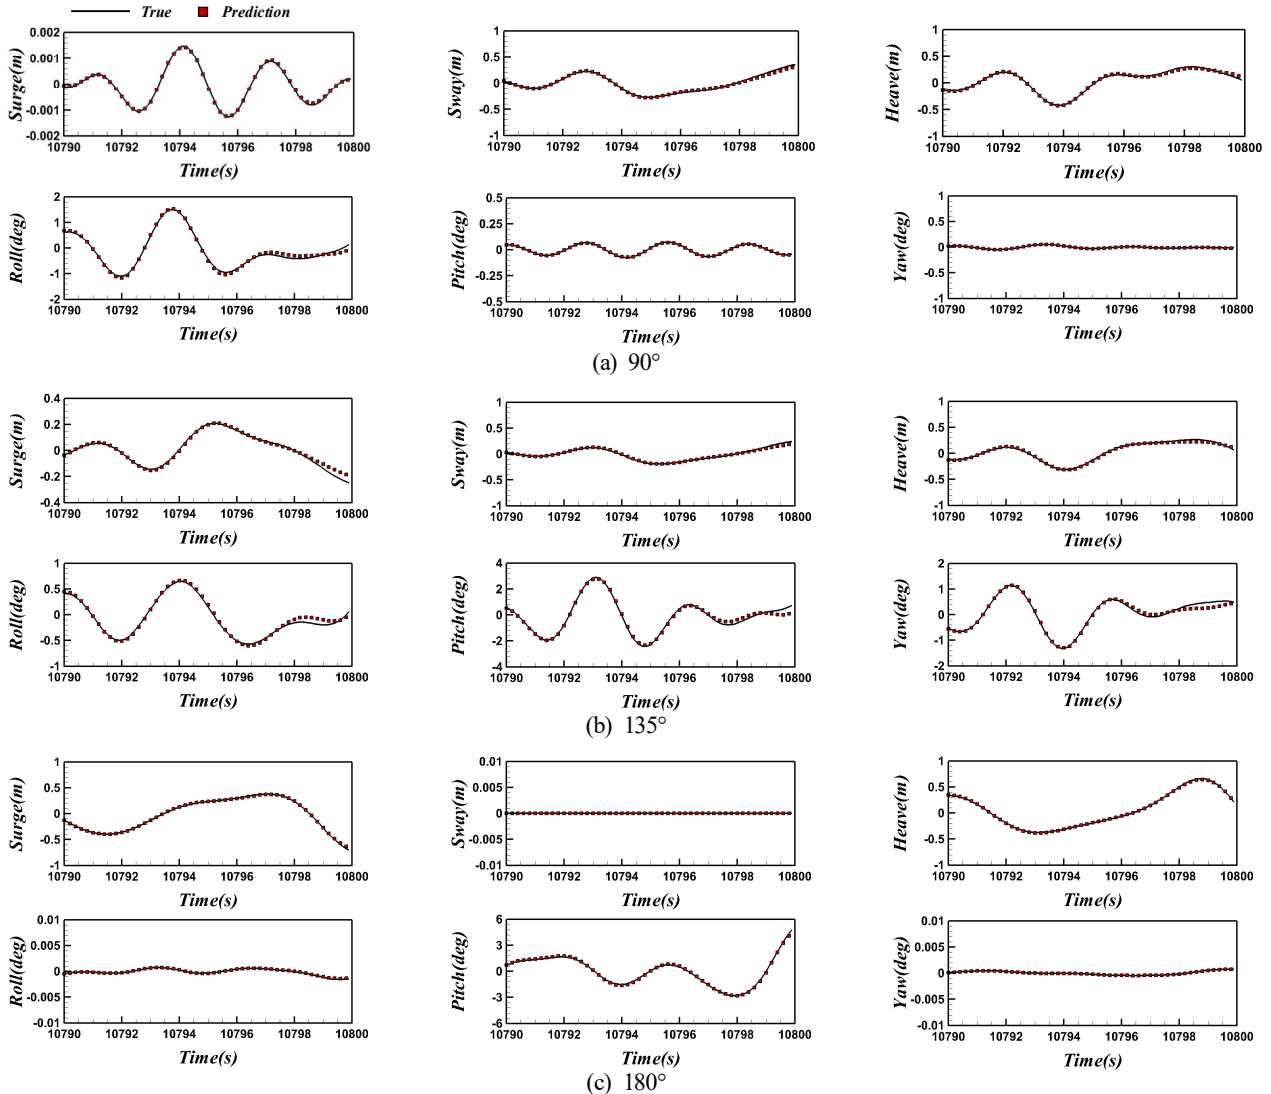


Fig. 10. Comparison of time series for motion responses between true values and predicted values for FV1.

4.2 운동 응답 예측 결과

구축된 모델을 사용하여 FV1과 FV2 선박의 시계열에 따른 운동 응답을 예측하였다. FV1의 시계열 운동 응답 예측 결과를 Fig. 10에 나타내었다. 여기서 “True”는 해석을 통해 얻은 결과이며 “Prediction”은 구축된 LSTM 모델을 통해 예측된 결과이다. 각 환경조건의 방향에 따른 예측된 운동 응답

인 Prediction 값은 True 값과 유사함을 확인할 수 있다. 예측 시작 시점부터 약 6초까지는 True 값과 매우 잘 일치하는 것을 확인할 수 있으나, 시계열의 길이가 길어짐에 따라 예측의 정도가 낮아짐을 확인할 수 있다. 병진운동에 해당하는 surge, sway 및 heave 운동은 예측의 정도가 회전운동에 해당하는 roll 및 pitch에 비해 상대적으로 높다.

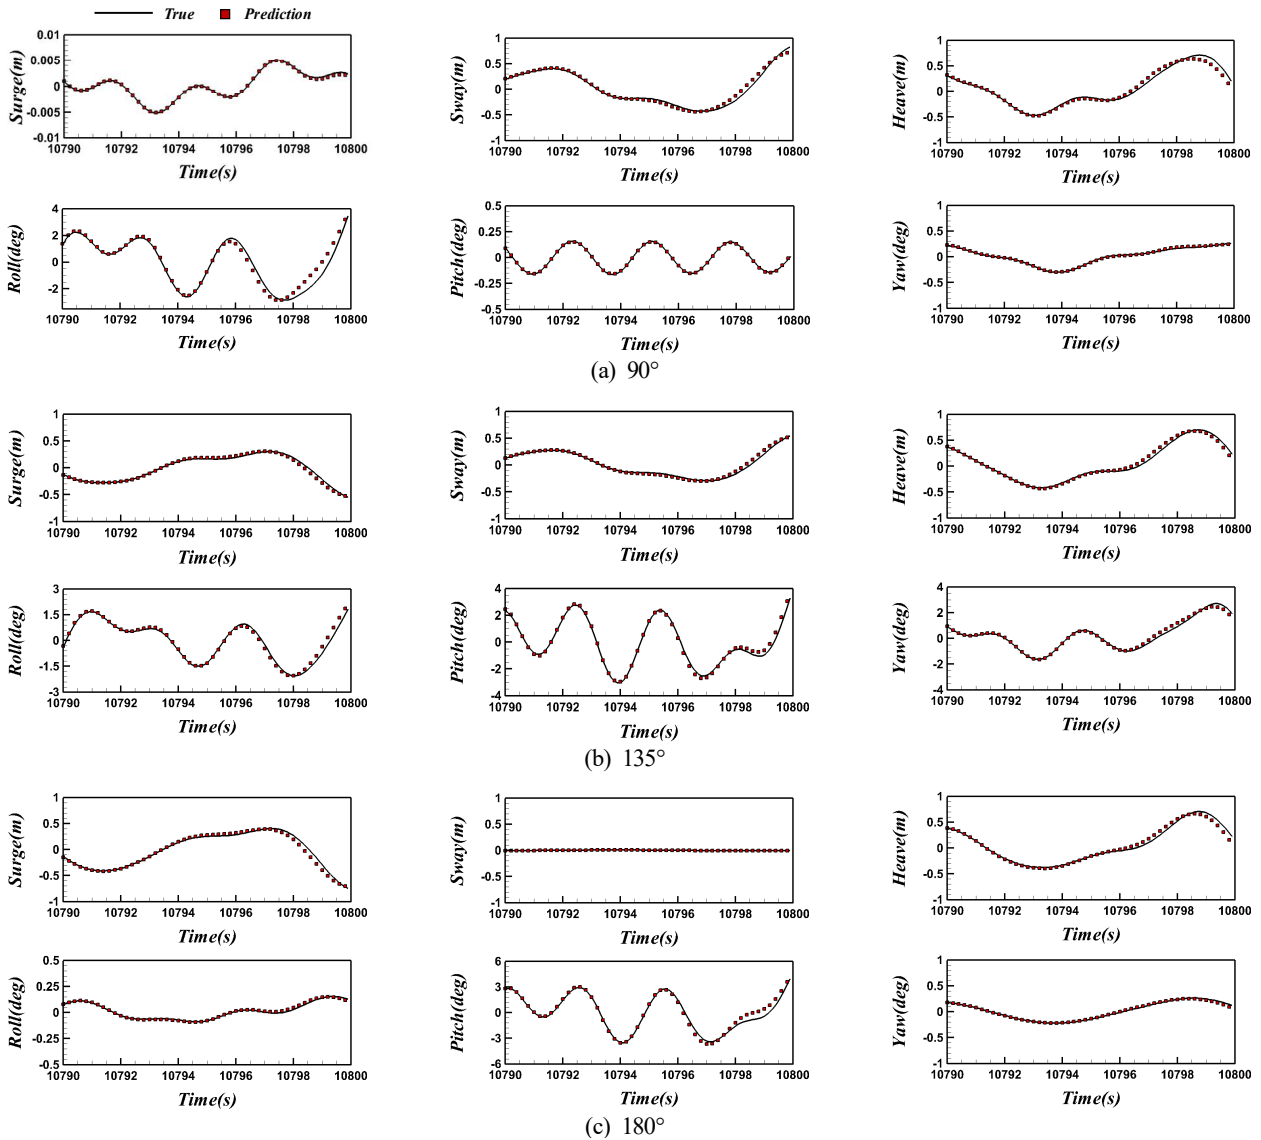


Fig. 11. Comparison of time series for motion responses between true values and predicted values for FV2.

FV2 선박의 시계열 운동 응답 예측 결과는 FV1 선박과 유사함을 Fig. 11에서 확인할 수 있다. 전반적으로 True 값과 유사한 결과를 확인할 수 있으며, 시계열이 길이가 길어짐에 따라 True 값과 Prediction 값의 차이가 증가함을 확인할 수 있다.

구축된 모델의 예측 정도를 정량적으로 평가하기 위해 모 전 환경조건 방향 및 시계열에서 해석 결과와 예측 결과의 절대 오차를 산정하였으며 이에 대한 누적 분포를 Fig. 12에 나타내었다. 약 3%의 데이터는 100% 이상의 오차를 가지고 있으며, 이는 이상치로 간주한다. 결과적으로 약 85% 이상의 데이터가 10% 오차 이내에 분포하고 있음을 확인할 수 있으며, 상대적으로 높은 오차는 시계열의 길이가 긴 위치

의 데이터에서 발생한다. 결과적으로 구축된 LSTM 모델은 어선의 운동 응답을 잘 예측함을 확인하였다.




Fig. 12. Distributions of data points with cumulative percentage of absolute error for LSTM model.

5. 결론

소형어선의 시계열 운동 응답을 예측하기 위해 딥러닝 기반 LSTM 모델을 구축하였다. 모델 구축을 위해 크기가 다른 두 어선을 고려하였으며, LSTM 모델의 데이터셋을 구축하기 위해 유체동역학 성능 평가를 수행하였다. 최적의 모델을 선정하기 위해서 LSTM 모델 층과 뉴런의 개수를 변경하며 그 영향을 확인하였다. 또한 입력 데이터의 길이에 대한 영향을 확인하였다. 구축된 모델을 통해 두 어선의 시계열 운동성능을 예측하였다. 전반적인 예측 결과는 해석 결과와 잘 일치하였으나, 시계열의 길이가 길어짐에 따라 해석 결과와 차이를 보였다. 해석 결과와 예측값의 오차를 정량적으로 평가하였다. LSTM 모델을 이용한 운동 응답 예측 시간은 유체동역학 해석 시간에 비해 약 95% 이상 감소하였다. 구축된 LSTM 모델은 향후 어선의 운동 응답 해석 시간을 절감시킬 수 있을 것으로 기대한다. 또한 복잡한 시스템 또는 고가의 계측 장비 구축 없이 비교적 단순한 운동 계측 장비와 결합하여 미래의 운동 응답 예측이 가능함에 따라 향후 소형어선의 실시간 경보 시스템을 구축할 수 있을 것으로 기대한다. 본 연구에서는 2척의 소형어선만으로 LSTM 모델을 구축하였기 때문에 운동 응답 데이터의 확장 및 다른 어선의 적용 가능성에 관한 확인이 필요하다. 이에 향후 다양한 형상 및 크기를 가진 어선에 대한 운동 응답 데이터를 활용하여 구축된 LSTM 모델의 정확도 및 활용도를 넓히고자 한다.

후 기

본 연구는 한국해양교통안전공단의 자체연구개발과제인 “D.N.A. 기반 어선의 횡동요 및 안정성능 예측 프로그램 개발” 과제의 지원을 받아 수행되었습니다.

References

- [1] Abankwa, N. O., S. J. Johnston, M. Scott, and S. J. Cox (2015), Ship motion measurement using an inertial measurement unit. In 2015 IEEE 2nd World Forum on Internet of Things (WF-IoT), pp. 375-380.
- [2] Choi, C. W., Y. Noh, D. S. Shin, H. M. Kim, and H. C. Park(2021), Identifying Risk Factors of Marine Accidents in Coastal Area by Marine Accident Types, Korean Society of Transportation, 39(4), pp. 540-554.
- [3] del Águila Ferrandis, J., M. S. Triantafyllou, C. Chrysostomidis, and G. E. Karniadakis(2021), Learning functionals via LSTM neural networks for predicting vessel dynamics in extreme sea states. Proceedings of the Royal Society A, 477(2245), 20190897.
- [4] Guo, X., X. Zhang, X. Tian, X. Li, and W. Lu(2021), Predicting heave and surge motions of a semi-submersible with neural networks. Applied Ocean Research, 112, 102708.
- [5] Hwang, J. H. and K. P. Rhee(1980), On a Computer Program to Calculate the Responses of a Ship in Lateral Regular Waves, Journal of the Society of Naval Architects of Korea, 17(4), pp. 39-45.
- [6] Im, N. K. and S. M. Lee(2021), A Study on Motion Response of Small Fishing Vessels According to Various Tonnage in Regular Waves. Journal of the Korean Society of Marine Environment & Safety, 27(6), pp. 832-838. [2] Korea Maritime Safety Tribunal(2021), Maritime accidents statistical yearbook.
- [7] Kang, I. K., H. S. Kim, M. S. Kim, Y. W. Lee, J. C. Kim, H. J. Jo, and C. K. Lee(2007), Characteristics on the rolling response of a small fishing boat according to the waves and the ship's speed, J. Kor. Soc. Fish. Tech., 43(1), pp. 62-70.
- [8] Kim, Y. R., J. B. Park, and S. B. Moon(2018), Prediction of Ship Roll Motion using Machine Learning-based Surrogate Model. J. Navig. Port Res, 42(6), pp. 395-405.
- [9] Park, R. S., S. G. Kim, and J. B. Lee(2011), Study on Motion Response Characteristics for Large Inclined State of Small Fishing Vessel in Beam Sea Condition, Journal of Ocean Engineering and Technology, 25(6), pp. 17-22.
- [10] Son, G. B., H. J. Choi, J. H. Lee, Y. B. Ro, and P. S. Kang (2020), Significant Wave Height Regression from a Raw Ocean Image with Convolutional LSTM and 3D Convolutional Networks. Journal of The Korean Operations Research and Management Science Society, 45(1), 11-24.
- [11] Xu, W., K. J. Maki, and K. M. Silva(2021), A data-driven model for nonlinear marine dynamics. Ocean Engineering, 236, 109469.
- [12] Yang, Y. J. and S. Y. Kwon(2017), Rolling Motion Simulation in the Time Domain and Ship Motion Experiment for Algorithm Verification for Fishing Vessel Capsizing Alarm Systems. Journal of the Korean Society of Marine Environment & Safety, 23(7), pp. 956-964.
- [13] Zhang, D., X. Zhou, Z. H. Wang, Y. Peng, and S. R. Xie (2023), A data driven method for multi-step prediction of ship roll motion in high sea states. Ocean Engineering, 276, 114230.

Received : 2023. 07. 20.

Revised : 2023. 08. 16.

Accepted : 2023. 08. 29.