

선체운동을 통한 딥러닝 기반 침수구획예측

신동선(부산대학교), 노현동(부산대학교), 오상진(부산대학교),
임채옥(부산대학교), 박병철(부산대학교), 신성철(부산대학교)

Prediction of flooded compartment by ship motion using deep learning

Dong-seon Shin(Pusan National University), Hyeon-dong Roh(Pusan National University),
Sang-jin Oh (Pusan National University), Chae-og Lim(Pusan National University),
Byeong-cheol Park(Pusan National University), Sung-chul Shin(Pusan National University)

Abstract

Flooding is a major type of ship accident. When flooding is occurred, to prevent for additional flooding or capsizing, first action is very important. Because of the Reinforced rule of the ships, ship's structure is more complicated than before. Therefore, find a flooded compartment on the ship is difficult problem. Also, worker has been safety problem at finding flooded compartment moments.

This paper describes predict a flooded compartment using ship motion. Ship motions data is calculated by ANSYS hydrodynamic diffraction and by using Deep Neural Network(DNN), predict flooded compartment fast and exactly in irregular waves.

Keywords :Flooding(침수), Ship motion(선체운동), Deep learning(딥러닝), Deep Neural Network(심층 신경망)

1. 서론

실제 운용되는 선박에서 충돌, 좌초 등으로 인한 침수사고는 많은 종류의 선박사고 중에서 높은 비율을 차지한다. 침수상황이 발생했을 때 생기는 기름유출로 인한 피해와 선박의 추가적인 구획 침수 및 이로 인한 전복 또는 침몰을 막기 위해서 침수구획을 확인한 뒤 빠른 초동조치를 취하는 것은 사고 발생 시 매우 중요하다. 하지만 강화된 규정 등으로 복잡해진 선체 구조 내에서 빠른 시간 내에 정확하게 침수 구역을 찾는 것은 어려우며 작업자의 안전상의 문제 또한 존재한다. 이에 본 논문은 시뮬레이션을 통해 침수된 선박의 파랑 중 거동을 분석하여, 빠른 시간 내에 침수 구획을 예측하는데 목적을 두었다.

침수상황을 가정한 침수해석은 선박 설계 시와 사고 발생 후에도 필요하다. 선박의 설계 시에는 침수 해석을 통한 설계 검증 및 설계 개선에 도움을 줄 수 있을 것이고 사고 후에는 사고 원인 규명에 도움을 줄 수 있을 것이다(Kim J.S, 2017).

본 연구에서는 침수구획예측을 위해 구글(Google)에서 제작한 오픈소스 라이브러리 텐서플로우(Tensorflow)를 이용하였다. 딥러닝을 이용한 기술은 우리의 실생활뿐만 아니라 다양한 산업분야에서도 폭넓게 활용되고 있으며 최근 조선해양산업에서도 딥

러닝을 통한 자율주행 선박, Faster R-CNN을 이용한 해양에서의 선박 검출(Kim K.H, 2017) 기술 등의 연구들이 활발하게 이루어지고 있다.

본 연구에서는 텐서플로우로 심층 신경망을 구성해 선체의 회전운동응답으로 신경망을 학습시켜 최종적으로 학습된 신경망 모델을 이용해 침수구획을 예측했고 이에 대한 정확도를 평가하였으며 향후 연구방향을 제시하였다.

2. 모델 및 시뮬레이션 환경

본 연구에서는 선박이 침수된 상황을 가정해 박스바지의 부유체를 총 7개의 구획으로 나누어 각 구획이 침수되는 상황을 무게 중심이 변경되는 것으로 가정했다. 이 때, 구획침수로 인해 발생하는 침수구획 내 유동, 기름 유출 등의 추가적인 현상이 선체운동응답에 미치는 영향은 고려하지 않았다. 한 구획이 완전히 침수되는 상황을 가정하였으며 ANSYS hydrodynamic diffraction을 사용해 불규칙파랑에서 침수선박의 Roll, Pitch, Yaw 값을 얻었다. 해석 결과 값인 동일한 불규칙파랑 내에서 다르게 거동하는 각 침수상황 모델의 3가지 회전운동응답을 이용해 신경망을 학습시켰으며 사용된 모델의 제원은 Table 1과 같다.




Fig. 1 Compartment arrangement of the model

Table 1 Main principles of the model

Length	100m
Breath	40m
Depth	25m
Draft	14.5m
Displacement	59,450ton

또한, 모델의 구획배치는 Fig. 1과 같다. 기관실을 제외한 6개의 구획에 대해 케이스를 분류해 침수 모델을 만들었으며, 한 케이스 당 한 구획씩 완전 침수된 후의 거동을 결과 값으로 도출했고 추가적인 구획침수는 발생하지 않는다고 가정했다. Table 2는 구획별 침수된 부유체의 무게중심이다. 이 때, 케이스별로 고려된 추가 흘수는 1.61m이며 물의 무게가 추가된 모델의 총 배수량은 66055.1ton 이다.

Table 2 Center of gravity of each case

Flooded Compartment	Center of gravity		
	x(m)	y(m)	z(m)
No. 1	54	1	-5.77
No. 2	54	-1	-5.77
No. 3	52	1	-5.77
No. 4	52	-1	-5.77
No. 5	50	1	-5.77
No. 6	50	-1	-5.77

입사파는 Pierson-Moskowitz Spectrum(Pierson & Moskowitz 1964)을 이용했으며 유의파고(Significant wave)는 4m, Zero crossing period 주기는 10초로 설정했고 Beam sea를 가정했다.

ANSYS hydrodynamic diffraction에서는 유의파고와 주기를

이용해 Pierson-Moskowitz 스펙트럼을 직관적으로 계산하며 식 (1)는 Ansys hydrodynamic diffraction에서 사용하는 Pierson-Moskowitz 스펙트럼의 식이다(Ansys, 2013).

$$S_{PM}(\omega) = \frac{1}{2\pi} \frac{H_s^2}{4\pi T_z^4} \left(\frac{2\pi}{\omega} \right)^5 \exp \left\{ -\frac{1}{\pi T_z^4} \left(\frac{2\pi}{\omega} \right)^4 \right\}$$

where

H_s is Significant Wave Height.

T_z is Zero Crossing Period.

ω is Frequency(rad/sec).

(1)

본 연구에서 진행한 시뮬레이션은 3차원 포텐셜 이론을 바탕으로 유체를 비회전, 비압축성 성질을 갖는 이상유체로 가정한다. 그리고 파랑 중 물체표면에 작용하는 압력의 합인 Froude-Krylov force와 부유체가 있어 반사되어지는 힘인 Diffraction force, 물체의 움직임에 따라 방사되는 파로 인한 하중인 Radiation force를 이용해 해석을 진행한다.

Froude-Krylov force와 Diffraction force는 파동에 관련되며 Radiation force는 부가 질량(Added mass)과 감쇠력(Damping)에 연관된 힘이다. 또한 해석에 있어 점성은 고려되지 않으며 각 케이스별 침수로 인해 추가된 흘수는 1.61m로 동일하다고 가정했기 때문에 침수시킨 부유체의 체적은 모두 같다. 따라서 Froude-Krylov force의 결과 값이 동일하게 산출되므로 본 연구에서 가정한 조건으로는 각 케이스별로 병진운동에서의 차이점은 발생하지 않는다. 따라서 본 연구에서는 회전운동을 이용해 침수구획을 예측하였다.

시뮬레이션을 통해 침수 케이스별 부유체의 회전 운동을 0.1초 간격으로 도출했고, 총 150초간 진행하였다. Fig. 2~3는 2번 구획이 침수됐을 때의 시뮬레이션 모델이다. 이때, 파도의 진행 방향은 화살표로 표시된다. Fig. 4~6는 시뮬레이션의 결과 값인 회전운동응답 Roll, Pitch, Yaw이다.




Fig. 2 Simulation model




Fig. 3 Simulation model (X-coordinate view)




Fig. 4 Roll of each case




Fig. 5 Pitch of each case




Fig. 6 Yaw of each case

3. 침수구획 예측 신경망

본 연구에서는 침수구획을 예측하기 위해서 DNN(Deep Neural Network)을 사용했다. DNN은 입력층(Input layer)과 출력층(Output layer) 사이에 다층의 은닉층(Hidden layer)을 포함한 인공 신경망으로 복잡하고 다양한 비선형적 관계를 학습할 수 있다. 인공 신경망에서의 각 층은 입력된 값들을 처리하기 위한 노드로 이루어져 있고 각각의 노드들은 활성화 함수를 통해 입력된 값들을 다음 층으로 전달할 것인지 말 것인지를 결정한다(Lee, 2016).

활성화 함수는 입력 신호의 총합을 출력 신호로 변환하면서 DNN 모델의 학습 속도 및 학습률을 좌우하게 된다. 활성화 함수의 종류로는 tanh, sigmoid, Relu(Rectified Linear Unit) 등이 있으며 본 연구에서는 활성화 함수의 기울기가 점점 작아져 사라지는 vanishing gradient 문제와 연산속도 저해로 인한 극솟값 수렴 문제가 발생하지 않는 Relu를 사용하였다(Cho, 2016). 또한 식(2)를 이용해 Feature들의 각 입력 값들을 정규화시켰다.

$$\bar{d} = \frac{d - \min v}{\max v - \min v}$$

where

$\bar{d}$ is a noramlized data.

d is a data before normalize.

$\min v$ is a min value of the feature.

$\max v$ is a max value of the feature.

(2)

최적화 기법으로는 경사 하강법(Gradient descent)을 사용했다. 경사 하강법은 기울기를 이용해 함수의 최솟값을 찾는 방법으로 신경망의 오류역전파에서 오류의 최솟값을 찾는데 자주 사용되는 알고리즘이며 학습률은 경험적으로 0.001로 선정했다.

데이터의 과적합(overfitting)을 방지하고 학습의 효율을 높이기 위해서 He initialization(He, 2015)으로 초기 가중치를 설정했고 Drop-out기법을 이용했다. Drop-out은 은닉층에 존재하는 모든 노드를 학습에 포함시키지 않고 무작위로 일부만을 포함시켜 과도하게 학습이 진행되는 것을 막아주는 기법이며 본 연구에서는 Drop-out을 적용해 노드의 90%만을 학습에 사용하였다.

시뮬레이션을 통해 각 침수상황마다 150초간 세 종류의 회전 운동을 0.1초 간격으로 계산했으며, 이를 2초 간격을 하나의 데이터로 만들어 학습을 진행했다.

Feature의 개수는 60개이며, 총 445개의 data set을 200000번 학습시켰다. Table 3는 data set의 예시이다.

은닉층마다 각 100개의 노드를 구성했으며 학습을 진행하는 동안 은닉층이 6개 이상일 때 학습의 정확도가 현저히 떨어지는 것을 경험적으로 발견하였다. Fig. 7~11은 각 은닉층 별 신경망의 Train set과 Validation set의 정확도를 나타낸 그래프이다.




Fig. 7 Accuracy per step (2 layer)




Fig. 8 Accuracy per step (3 layer)

Table 3 Example of data set

Response at 0.0s (Roll, Pitch, Yaw)[deg]			Response at 0.1s (Roll, Pitch, Yaw)[deg]			...	Response at 2.0s (Roll, Pitch, Yaw)[deg]			Flooded compartment
-9.045	4.556	-0.355	-9.048	4.556	-0.355	...	-9.103	4.538	-0.358	No. 1
9.045	4.556	0.355	9.049	4.556	0.355	...	9.108	4.538	0.358	No. 2
⋮			⋮			⋮	⋮			⋮
Response at 148.0s (Roll, Pitch, Yaw)[deg]			Response at 148.1s (Roll, Pitch, Yaw)[deg]			...	Response at 150s (Roll, Pitch, Yaw)[deg]			Flooded compartment
21.043	0.147	-35.82	18.813	0.139	-36.068	...	-3.172	0.909	-37.945	No. 4
⋮			⋮			...	⋮			⋮




Fig. 9 Accuracy per step (4 layer)




Fig. 10 Accuracy per step (5 layer)




Fig. 11 Accuracy per step (6 layer)

은닉층이 6~10개의 경우에는 그래프의 양상이 Fig.11과 같이 모두 비슷했으며 은닉층이 2~5개인 경우에 비해 학습의 정확도가 현저히 떨어졌다. 그리고 Table 4는 은닉층 개수에 따른 Train set, Validation set과 전체 데이터의 정확도이다. 이 때, 은

닉층의 개수가 6개 이상인 경우에는 학습의 정확도가 떨어져 추가적으로 정확도를 평가하지 않았다.

Table 4 Accuracy of each case

Number of Hidden layer	Train set accuracy(%)	Validation set accuracy(%)	Data set accuracy(%)
2	98.82	88.46	96.04
3	99.61	94.87	96.26
4	99.61	93.59	94.72
5	91.80	84.62	87.03

4. 결 론

본 연구를 통한 결론은 다음과 같다.

- (1) ANSYS hydrodynamic diffraction을 이용해 불규칙 파랑 중 구획이 침수된 박스바지 부유체의 회전운동응답을 계산했다.
- (2) 회전운동응답을 이용해 심층 신경망을 학습시켰으며 이를 통해 침수구획을 예측하였다.
- (3) 신경망에서의 학습률, 학습 횟수, 은닉층의 개수는 경험적으로 결정했다. 0.001의 학습률과 200000번의 학습 횟수를 고정시키고 각 은닉층의 개수를 2~10개로 신경망을 만들어 각 데이터에 대한 정확도를 평가했다.
- (4) 은닉층별 정확도를 비교해 본 결과 은닉층의 개수가 3개 일 때 가장 높은 정확도를 보였으며 층의 개수를 늘릴 때 마다 낮은 정확도를 보였다.

향후 연구를 통해 데이터에 대한 알맞은 학습 횟수와 학습률, Drop-out를 등을 찾아내고 추가적인 환경요소들을 구성한다면 더 높은 정확도를 이룰 수 있을 것이다. 그리고 본 연구가 발전돼 실제 운용되는 선박에 적용된다면 입사파에 대한 정보를 바탕으로 선박의 운동응답을 분석해 침수 사고 발생 시 빠르고 정확하게 침수구획을 찾아내 구획침수로 인해 발생하는 추가적인 피해를 막을 수 있을 것으로 기대된다.

후 기

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0030013)

참 고 문 헌

Cho, Y.H. Seo, Y.D. Park, D.J. and Jeong, J.c., 2016. Study on the activation functions for efficient learning in DNN.

Conference on The institute of Electronics and Information Engineers, 800–803 november 2016.

Index of Software Ansys, 2013, Index of / Software/ Ansys/ 15.0.7/ en-us/ help/ wb_aqwa:
<https://www.sharcnet.ca/Software/Ansys/15.0.7/en-us/help/wb_aqwa>; 2013. 11

Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, 2016, Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, *arXiv:1502.01852v1* [cs.CV] 6 Feb 2015

Kim, J.S., 2017, Quasi-static flooding analysis method of a damaged ship considering oil spill and cargo load. *Seoul National University Master's Thesis*

Kim, K.H. Hong, S.J. Choi, B.H. Kim, I.H. and Kim, E.T., 2017. Ship Detection Using Faster R-CNN in Maritime Scenarios. *Conference on information and control systems 17th*, 158–159 October 2017

LEE, J.S., 2016, Development process and understanding of in-depth neural network, *The Journal of Korean Institute of Communications and Information Sciences*, 33(10), 40–48.