

GAN을 이용한 슬로싱 충격압력 데이터 생성 방법 연구

A Study on Generation Method of Sloshing Impact Pressure Data Using Generative Adversarial Networks

강보경¹, 오상진¹, 이상범², 정준형², 신성철^{1*}

Bo-gyeong Kang¹, Sang-jin Oh¹, Sang-Beom Lee²,
Jun-Hyung Jung², Sung-chul Shin^{1*}

〈Abstract〉

A model test is performed to measure the sloshing impact pressure in the liquid tank. A preprocessing is performed to learn the model test results applied with various environmental conditions. In this study, we propose a method for generating data similar to the total pressure data using Generative Adversarial Networks. In addition, after approximating the generated result to the three parameter Weibull distribution, the difference of the three parameters was compared through the RMSE and SMAPE calculation results. As a result, the distribution of the generated data showed similar results to the total pressure data distribution.

Keywords : Sloshing, Impact Pressure, Generative Adversarial Networks

1* 교신저자, 부산대학교 조선해양공학과, 교수
E-mail: scshin@pusan.ac.kr

1 부산대학교 조선해양공학과

2 대우조선해양 유체연구부

1* Corresponding Author, Dept. of Naval Architecture and
Ocean Engineering, Pusan National University

1 Dept. of Naval Architecture and Ocean Engineering, Pusan
National University

2 Fluid Dynamics R&D Department, Daewoo Shipbuilding &
Marine Engineering Co., Ltd

1. 서 론

슬로싱(sloshing) 현상은 구조물의 운동으로 발생하는 구조물 내부 유체의 움직임을 말하며, 내부 액체의 공명 주기에 가까워질수록 슬로싱의 흐름은 더욱 격렬해지고 강한 액체 충격을 초래한다 [1]. 슬로싱은 액체가 담긴 탱크 내벽에 충격을 가하고, 구조물의 손상을 일으킬 수 있다. LNG 등 의 액체를 적재한 선박과 해양구조물 등의 부유체에서는 파랑 환경 하중에 의한 부유체의 움직임에 의해 슬로싱이 발생한다. 따라서 액체를 적재하는 선박, 해양구조물 등의 부유체 설계단계에서 슬로싱과 관련한 문제들을 고려해야 한다[2]. 최근 환경규제가 강화됨에 따라 액화천연가스(LNG)의 물동량 증가와 LNG 운반선의 시장 확장으로 슬로싱 하중을 추정하기 위한 많은 연구가 수행되고 있다[3]. 슬로싱 충격압력을 예측은 크게 모형시험 방법과 수치적 방법으로 나뉘는데, 이상치를 정의하기 힘들고, 비선형적인 특성 때문에 정확한 하중을 산정하기 어렵다[4]. 선급에서는 상대적으로 신뢰성이 높은 모형시험 방법을 선호하지만[5-6], 모형시험을 시행함에 따라 시간과 비용의 소모가 크기 때문에 적은 수의 시험 결과를 바탕으로 신뢰성 있는 슬로싱 충격하중 예측 방법이 필요하다. 또한, 비선형성이 반영된 보유 데이터를 기반으로 데이터를 생성하여 모형시험에서 소모되는 비용과 시간을 절약해야 한다.

문제를 개선하기 위해 CFD를 이용한 수치해석 기법[7-9], 기계학습법[10-12]과 같은 다른 방법들의 지속적인 연구가 진행되어 오고 있다. 수치해석기법을 사용한 관련 연구로서 슬로싱 하중을 오픈소스 CFD 해석 프로그램인 OpenFOAM을 이용해 VOF기법(Volume Of Fluid) 기반의 해석 솔버를 사용하여 슬로싱 수치해석을 검증하였다. 또한, isosurface 개념의 상 경계면 해석기법을 적용

하여 슬로싱 유동 해석의 정확도를 개선하는 연구가 진행되었다. 최대하중이 주로 발생하는 높은 적재율에서의 정확도는 높았지만, 낮은 적재율에서는 비교적 큰 오차를 보였고, 압축성을 고려한 경계면 알고리즘의 검증이 이루어져야 한다[13]. 기계학습은 계산 비용 관점에서도 큰 이점이 있고, 신경망은 비선형 함수를 근사할 수 있는 데이터 기반 알고리즘으로서, 상대적으로 제약이 적고, 빠른 대응이 가능하다. 이러한 기계학습을 활용한 슬로싱의 충격압력을 예측한 관련 연구로서, 자료집합 분석(data mining)을 통해 모형시험 결과의 심각도를 판별할 수 있는 기준을 정하고, 실험 인자와 실험 결과를 지도학습하는 인공신경망을 구성해 실험 결과를 예측하는 연구가 진행되었다. 예측 정도를 높이기 위해 양상을 기법을 적용하였고, 실험 결과와 비교할 때 매우 높은 정확도를 보였다. 하지만 발생하는 위치에 따른 정보나 국부적으로 발생하는 슬로싱 현상의 동적 특성 등을 예측할 수 없다[10].

본 연구에서는 기계학습인 GAN을 이용해 슬로싱 모형시험 데이터를 학습시켜 실제와 비슷한 충격압력을 생성하는 데 초점을 두었다. 슬로싱 모형시험 결과 데이터를 센서가 배치된 위치별로 그룹화하여 1부터 16까지 구획을 선정했다. 또한, 전처리 과정을 통해 다양한 환경이 적용된 모형시험 데이터를 구획 및 충격압력 데이터와 함께 학습/평가 데이터로 구성하였으며, 정규화를 통해 학습이 가능한 형태로 변환하였다. 본 연구에서는 단계별로 네트워크를 구성하고, 분석을 통해 네트워크를 개선하여 최종적인 충격하중 데이터 생성 방법을 제시한다. 1단계로 2차원 데이터를 활용한 dense layer로 구성된 네트워크를 이용하여 데이터 성능을 확인하였으나, 1회 1개 데이터 생성 구조로, 판별자의 학습 신뢰도가 낮다는 단점이 있었다. 따라서 3차원 데이터를 활용한 데이터 분포

를 따르는 convolutional layer에 Weibull 분포 3 변수를 손실함수로써 사용하였고, 생성된 데이터와 비교해 손실이 줄어들도록 학습에 적용하는 데 이터 생성모델을 구축하여 개선하였다. 또한, GAN을 통해 생성한 결과를 극치분포함수인 3 변수 Weibull 분포를 통해 생성한 압력값이 학습에 사용된 실제 모형시험 압력값과 비슷한 분포를 띠고 있는지 확인해 보고, 평가지표로서 RMSE와 SMAPE를 계산하여 결과값을 비교하였다.

2. 이론적 배경

2.1 Weibull distribution

슬로싱 모형시험의 결과와 같이 이산 통계 데이터의 피팅(fitting)은 Weibull 분포 또는 Pareto 분포와 같은 극치분포함수를 사용하여 수행할 수 있다. 같은 조건에 대해 슬로싱 모형시험을 수행할 때, 그 결과는 하나의 긴 실험으로 간주하여야 하며 전체 실험 시간을 기반으로 하나의 확률 함수가 설정되어야 하고, 실험 시간이 길수록 더 신뢰할 수 있는 통계 분포가 제공된다. 슬로싱의 충격압력 분포를 나타내기 위해서 3 변수 Weibull 분포함수를 선택하는 이유는 경험에 따르면 이 분포가 tail에 있는 데이터를 비교적 피팅하기 적합하다고 판단하여 통상적으로 쓰이고 있다[14]. 슬로싱 충격압력 예측에 사용되는 분포를 비교한 연구 사례로서 모형시험을 통해 얻은 데이터를 기반으로 통계적 분석 방법인 3 변수 Weibull 분포, generalized Pareto 분포, log-logistic 분포를 활용하여 비교한 결과, 최대우도 추정보다 모멘트 방법이 적합했으며, 3 변수 분포가 가장 높은 적합도를 보이므로 peak 압력에 대한 모델로 적합하다는 점을 확인하였다[15].

Weibull 분포의 3가지 변수를 추정하는 방법에서 모멘트 법(method of moment)은 실험으로부터 얻은 관측값, 즉 global peak의 샘플의 압력값의 평균($\hat{\mu}$), 분산($\hat{\sigma}^2$), 왜도($\hat{\gamma}_1$)의 세 가지 모멘트를 모델의 평균(μ), 분산(σ^2), 왜도(γ_1)와 일치시키는 방법으로 모수들을 추정한다. 모델의 평균, 분산, 왜도는 식 (1), (2), (3)과 같은 방법으로 구할 수 있다.

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n p_i \quad (1)$$

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (p_i - \hat{\mu})^2 \quad (2)$$

$$\hat{\gamma}_1 = \frac{1}{n} \sum_{i=1}^n \left(\frac{p_i - \hat{\mu}}{\hat{\sigma}} \right)^2 \quad (3)$$

여기서, p_i 는 개의 표본 중 i번째 크기의 관측값을 의미하고 Weibull 누적분포함수 모델의 μ , σ^2 , γ_1 는 식 (4), (5), (6)과 같다. $\Gamma(x)$ 는 감마 함수, 형상 모수인 γ 는 표본의 왜도 $\hat{\gamma}_1$ 와 모델의 왜도 γ_1 을 일치시킴으로써 얻을 수 있다. β 는 $\hat{\sigma}^2$ 와 σ^2 을 일치시켜 얻고, δ 는 $\hat{\mu}$ 와 μ 를 일치시켜 얻을 수 있다[16].

$$\mu = \beta \Gamma\left(1 + \frac{1}{\gamma}\right) + \delta \quad (4)$$

$$\sigma^2 = \beta^2 \left[\Gamma\left(1 + \frac{2}{\gamma}\right) - \Gamma^2\left(1 + \frac{1}{\gamma}\right) \right] \quad (5)$$

$$\gamma_1 = \frac{\Gamma\left(1 + \frac{3}{\gamma}\right) - 3\Gamma\left(1 + \frac{1}{\gamma}\right)\Gamma\left(1 + \frac{2}{\gamma}\right) + 2\Gamma^3\left(1 + \frac{1}{\gamma}\right)}{\Gamma\left(1 + \frac{3}{\gamma}\right) - 3\Gamma\left(1 + \frac{1}{\gamma}\right)\Gamma\left(1 + \frac{2}{\gamma}\right)} \quad (6)$$

따라서 본 연구에서는 GAN을 통해 생성한 데이터를 실제 모형시험 데이터와 비교해보기 위해 Weibull 분포를 적용하였다. Weibull 분포는 슬로싱 모형시험 결과를 해석할 때 가장 많이 사용되

는 극치분포함수로, 최대 충격압력의 누적확률분포를 근사한다. 불규칙 운동의 해석에서 근사에 사용되는 대표적인 극치분포함수는 3 변수 Weibull 분포함수이다. 3 변수 Weibull 분포의 확률밀도함수는 식 (7), 누적분포함수는 식 (8)과 같다. δ 는 위치 모수(location parameter), β 는 척도 모수(scale parameter), γ 는 형상 모수(shape parameter)이다. 그리고 각각의 범위는 $\delta \leq x < \infty$, $0 < \beta$, $0 \leq \delta$, $0 < \gamma$ 이다.

$$f(x) = \frac{\gamma}{\beta} \left(\frac{x-\delta}{\beta} \right) \exp \left\{ - \left(\frac{x-\delta}{\beta} \right)^\gamma \right\} \quad (7)$$

$$F(x) = 1 - \exp \left\{ - \left(\frac{x-\delta}{\beta} \right)^\gamma \right\} \quad (8)$$

2.2 Generative Adversarial Networks

적대적 생성신경망이라고도 하는 GAN은 2014년에 발표된 논문 Generative Adversarial Networks에서 처음 소개되었다. GAN은 한 개의 인공신경망을 학습시켜서 활용하는 기존의 방법과는 다르게 두 개의 인공신경망을 활용하고, 생성자(generator)와 판별자(discriminator)의 상호 적대적인 학습을 통해 딥러닝 네트워크를 최적화시킨다[17]. GAN의 구조는 Fig. 1에서 볼 수 있고, 생성자는 데이터를 생성하고 판별자는 생성된 데이터가 실제 데이터에 상응하는 데이터로 판별될 수 있는지 구분하는 역할을 한다[18]. 준 지도학습(semi-supervised learning)을 기반으로 적은 양의 데이터로도 그 패턴을 학습해 유사한 다양한 데이터 모사가 가능하므로 이미지 프로세싱(image processing) 분야에서 두각을 나타내고 있다.

GAN을 활용하여 데이터 생성 연구 사례로서 항공기 엔진 평가의 신뢰성 향상을 위해 충분하지 않은 데이터를 GAN을 통해 확보하여 문제를 해

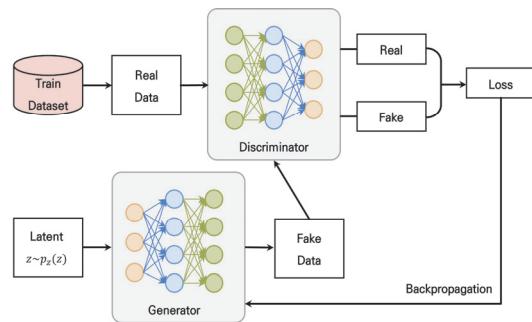


Fig. 1 The architecture of the Generative Adversarial Networks. Discriminator is trained by processing both real and generated examples with corresponding labels as training input. The goal of the training process is that the generator learns to create examples that are so realistic that the discriminator can not distinguish them from real ones

결하는 연구가 진행되었다. GAN을 통해 생성된 데이터가 실험데이터의 규칙성을 반영하도록 학습하고, Weibull 분포를 통해 항공기 엔진의 신뢰도를 측정하였다. 항공기 엔진의 신뢰도는 확률적으로 가동 시간에 따라 감소하는 추세를 보이며, 데이터는 Weibull 분포가 통계적 분석을 통해 근사화할 수 있다는 점을 확인하였다. 실제 30개 엔진을 모니터링한 데이터를 학습한 결과 생성된 데이터의 분포가 기존 Weibull 분포와 유사한 결과를 보였다. 결과적으로 GAN의 유효성을 확인했으며, Weibull 분포를 따르는 데이터 생성에서 샘플 데이터 부족 문제를 효과적으로 해결할 수 있다는 점을 확인하였다[19].

또한, 관련 연구들을 통해 슬로싱 충격압력 예측과 같은 데이터 추정을 위한 딥러닝 모델의 학습에도 유효하다는 점을 확인하였고, 이에 관한 연구로서 GAN을 이용하여 가속도 데이터를 생성하는 연구가 진행되었다. 교량과 비슷한 시뮬레이션 모델을 먼저 구축하여 GAN에 이용될 기초 가속도 데이터를 확보하고, 이를 통해 다양한 동적

하중이 적용된 가속도 데이터를 생성하도록 하였다. 시뮬레이션을 통해 생성된 가속도 데이터를 통해 학습된 GAN 모델의 생성자를 이용하여 실제와 비슷한 가속도를 생성하는 데 초점을 두었다. 시뮬레이션을 통해 생성된 가속도와 매우 유사한 패턴을 가지고 있음을 확인하였으며, 거시적 데이터의 패턴뿐만 아니라 가속도 데이터가 가진 주파수의 분포까지 재현해 낼 수 있음을 알 수 있었다. 하지만 실제 가속도 데이터는 가속도계가 가진 기계 오차, 환경의 변화에 따른 다양한 오차 등이 학습을 방해하는 요소로 작용할 수 있고, 학습에 필요한 적절한 생성데이터의 양을 결정해야 한다[20].

3. 데이터 구성

본 연구에서 사용하는 데이터는 탱크의 형상 변화가 없고, 환경 조건만 변화한다. 속도는 5 knots로 모두 일정하며, 95% filling rate에서 12 시간씩 실험한 데이터로 구성되어 있다. Hs(유의파고), Tz(평균파주기), heading(선수각)을 조합하여 총 16개의 환경을 구성하였고, Exp.는 실험이 진행된 횟수를 의미하며, Table 1에서 볼 수 있다. 모형시험 결과 데이터는 sensor ID, peak pressure, time index, rise time, duration time 값으로 구성되어 있고, dat 파일로 출력된다.

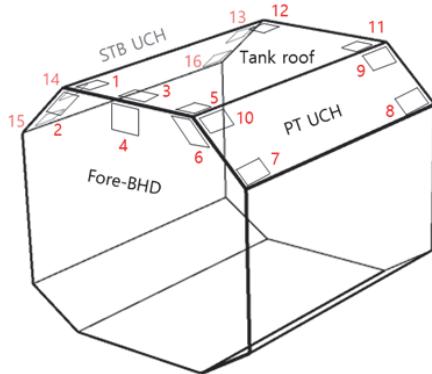
모형시험은 총 16개의 환경을 통해 조건별로 한 번의 실험당 3시간씩 4번의 실험을 하여 총 12시간에 해당하는 screening test가 진행되었다. Screening test의 결과에 따라 maximum peak 값이 큰 상위 3가지의 case를 선정하여 추가로 6 번의 실험을 더 수행하는 critical test가 진행되었다. 그리고 critical test 결과 중에서도 가장 압력 값이 컸던 case를 하나 선정하여 5번의 실험이

Table 1. Experimental cases according to the combination of conditions. exp No. means the number of experiments, Hs is the significant wave and Tz is mean zero-crossing period

	Exp.	Hs (m)	Tz (sec)	Heading (deg)
1	4	5.9	6.5	120
2	4	7.2	6.5	135
3	4	8.1	7.5	120
4	4	8.4	6.5	150
5	4	8.4	6.5	165
6	4	9.5	7.5	135
7	4	9.8	8.5	120
8	4	10.9	7.5	150
9	4	10.9	7.5	165
10	4	11.1	9.5	120
11	4	11.3	8.5	135
12	4	12.7	9.5	135
13	4	14.2	9.5	165
14	15	12.8	8.5	150
15	10	12.8	8.5	165
16	10	14.2	9.5	150

추가로 진행되었다. Table 1에서 1~13번 case는 총 4번의 실험만 진행된 screening test에 대한 환경들을 나타낸 것이고, 14, 15, 16 case는 4번의 실험 후 추가로 6~11번 critical test를 진행한 모형시험의 데이터 구성을 나타낸다. 여기서, critical test는 일반적으로 screening test를 진행한 후 각 센서의 최대 압력값이 큰 상위 case들에 대한 추가적인 모형시험을 의미한다.

충격압력을 검출하는 압력 센서의 개수는 144 개이고, 탱크의 upper chamfer의 starboard, port 부분과 tank roof, fore-BHD 부분에 압력 센서가 설치되었다. 탱크에 설치된 압력 센서의 배치는 Fig. 2에서 볼 수 있으며, 위치별로 16개의 구획으로 구분하여 1~16의 인덱스 번호를 부여하였고, 한 구획 당 총 9개의 압력 센서가 부착되어



**Fig. 2 Sensor location of sloshing model test tank.
The sensors were installed on the tank roof, starboard upper chamfer, port upper chamfer and forward bulkhead**

있다. 8, 9, 14, 15번 구획에서는 실제 슬로싱 모형시험을 진행하는 동안 발생한 충격압력 데이터가 매우 적거나, 없는 것도 있으므로 4개의 해당 구획을 제외하여 학습에 사용할 데이터를 구성하였고, 학습에 활용한 샘플의 개수는 390만 개다.

4. 연구 방법

4.1 Model with 2D latent vector

속도 개선 및 코드를 효율적으로 구현하기 위해 데이터 전처리를 진행하였고, 범위가 0에서 1 사이가 되도록 최대최소 정규화 방법을 사용했으며, 식 (9)와 같이 나타낼 수 있다. 데이터 학습에 사용한 샘플의 개수는 390만 개이고 epoch는 100, batch 크기는 256, latent vector는 16, 학습률(learning rate)은 0.0001을 사용하였다. 입력 값으로 사용된 파라미터들은 Hs, Tz, heading, speed, 압력 센서의 위치이며, 출력값은 pressure이다. 생성자와 판별자는 서로 구분되는 두 개의

최적화 함수를 구성하여 모두 Adam을 사용하였다. 또한, 생성자의 입력값으로는 다양한 입력값을 만들어 내기 위해 가우시안 분포에서 무작위로 추출한 난수(latent vector)로 구성하였다.

$$X_{new} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

GAN에서는 손실함수로서 크로스 엔트로피 가치함수(cross entropy value function)를 활용하고, 판별자가 구별한 데이터가 실제 데이터와 유사하면 1로, 그렇지 않다면 0으로 나타내도록 구성되어 있다. 식 (10)에서 V 는 가치함수, G 는 생성자, D 는 판별자, P_x 는 실제 데이터 분포, P_z 는 생성자가 생성한 데이터의 분포에 해당하며, E 는 예상되는 출력 내용이다. 최대한 1에 근접하도록 판별자는 학습하게 되고, 생성자는 실제 데이터와 가장 유사한 데이터를 만들어 판별자가 실제 데이터라고 착각하게 한다. 판별자의 입력 데이터로는 실제 모형시험 데이터와 생성자가 생성한 가짜 데이터가 모두 이용되며, 상반된 목적을 가진 판별자와 생성자의 대립 관계를 통해 학습이 진행되게 된다[21].

$$\begin{aligned} \min_{G} \max_{D} V(D, G) = & E_{x \sim P_{data(x)}} [\log D(x)] \\ & + E_{z \sim P_{z(z)}} [\log (1 - D(G(z)))] \end{aligned} \quad (10)$$

4.2 Model with 3D latent vector

속도 개선 다수의 실험데이터 분포와 생성된 데이터 분포를 비교하여 생성데이터가 실험데이터 분포를 따라갈 수 있도록 CNN(Convolutional Neural Networks)를 적용하여 데이터 구성 방식을 설계하였다[22]. 3차원으로 구축하여 임재공간의 크기를 늘리고, 환경 변수의 차원을 높여 채널로 병합하였다. Input 크기는 [B, H, W, C] =

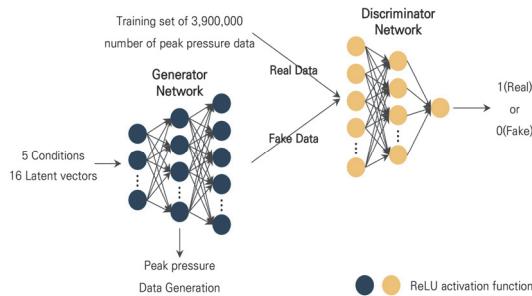


Fig. 3 The architecture of the proposed GAN for generation peak pressure data. Pressure is generated in the generator network(left). Real data and fake data are used as input to the discriminator network(right), and learning while discriminating as 1 if real and 0 if fake

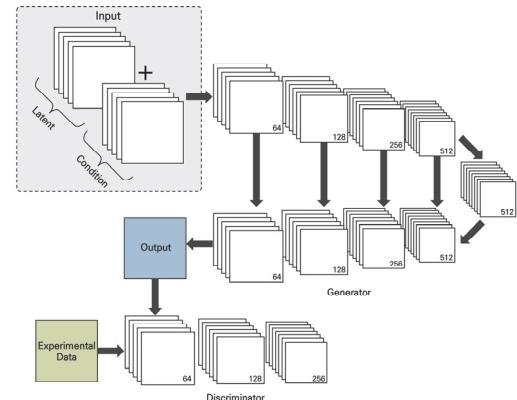


Fig. 4 The architecture of the proposed GAN using convolutional layer model. The generator consists of 9 hidden layers. Pressure is generated through the process of down-sampling and up-sampling

[16, 16, 16, 21(condition:5, latent:16)], Output 크기는 [B, H, W, C] = [16, 16, 16, 1]로 구성되어 있다. 입력값으로 사용된 condition은 Hs, Tz, heading, speed, 압력 센서의 위치별 구획 번호로 구성하였다. 생성자는 9개의 은닉층을 이루고 있으며, down sampling에서 up sampling으로 특징맵을 전달하는 연결 구간을 통해 기존 정보를 유지할 수 있는 형태로 구성되어 있다. 판별자는 3차원 데이터로 구성된 데이터를 처리할 수 있도록 3개의 층으로 이루어진 합성곱 층(convolutional layer)으로 설정했다. 층마다 instance normalization을 적용해 배치 및 채널의 크기와 무관하게 각 데이터에 대해서만 정규화할 수 있도록 하여 학습 데이터에 치중된 정규화가 아닌 모든 데이터에 적용 가능한 모델로 설계하였다.

GAN의 손실함수인 크로스 엔트로피 가치함수 뿐만 아니라 슬로싱 충격압력 데이터의 특성을 반영하기 위해 실험데이터의 Weibull 분포 3 변수를 계산하고, 생성데이터의 3 변수와 비교해 L2 손실이 줄어드는 방향으로 학습에 적용했다. 지금까지의 방법에서는 슬로싱 충격압력 데이터 생성에 적합한 정규화 방법과 손실함수를 적용해 기존

데이터 분포에 근접한 결과를 도출함으로써 모델의 구성 요소에 따른 생성 성능을 확인하였다. 식 (11)에서 D_{adv} 는 기존의 판별자 손실로 0에 수렴하도록 학습하고 D_{shape} , $D_{location}$, D_{scale} 은 Weibull 분포 3 변수 손실로 0으로 수렴하도록 학습한다.

$$D_{total} = D_{adv} + D_{shape} + D_{location} + D_{scale} \quad (11)$$

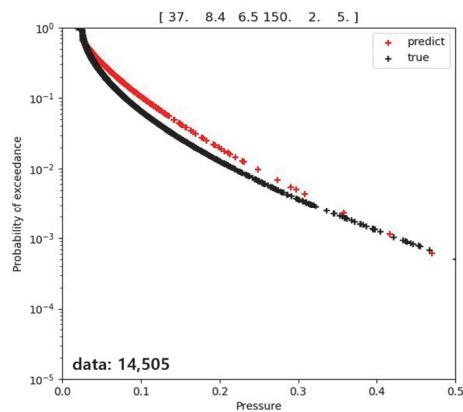
5. 생성결과 및 비교

2차원 데이터를 활용한 데이터 생성결과 모형 시험 압력값이 10,000개 이상일 때 실제값과 비슷한 분포의 유효한 결과가 생성되었고, 이는 압력값이 잘 생성되고 있다는 점을 알 수 있다. Fig. 5는 실제 데이터와 매우 유사한 패턴을 보이는 생성결과 중 3개 (a), (b), (c)와 분포를 잘 따라가지 못하는 1개의 경우(d)를 Weibull 분포로 나타낸 것이다. 여기서 빨간색은 GAN의 생성결과, 검은색은 모형시험 결과값을 나타내며, 상단의 제목을

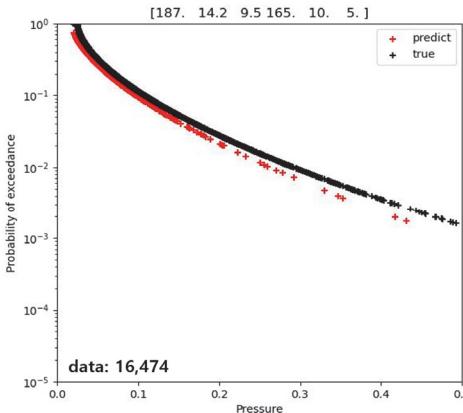
통해 환경 조건을 알 수 있다. Critical test를 통해 모형시험이 screening test만 진행된 다른 조건보다 더 많이 실행된 H_s 가 14.2, T_z 가 9.5 heading이 165인 환경의 결과를 Fig. 5의 (c)에서 살펴보면, 상당수 구획에서 해당 그림과 같이 결과가 양호하게 생성되었다. 이처럼 학습 데이터의 양이 생성결과에 영향을 미쳤고, 충격압력 값이 작은 조건에서도 상대적으로 결과가 좋지 않았다. 압력값이 0.3 이하의 값을 위주로 분포되어 있는 Fig. 5(d)의 경우 제대로 생성되고 있지 못한 점을

확인할 수 있었다.

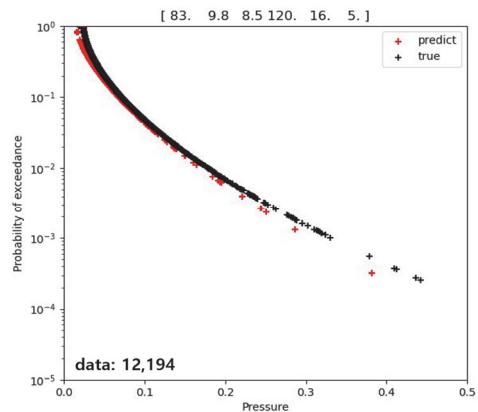
2차원 모델을 통해 구성 요소에 따른 생성 성능을 확인할 수 있었지만, 입/출력 데이터가 2차원이고, 1회에 1개의 데이터를 생성하는 구조로 이루어져 있어서 판별자가 생성/실험데이터에 대해 1개만 구별하므로 판별자의 학습 신뢰도가 낮았다. 이 점을 개선해 보고자 3차원 모델을 구축하였고, 정규화 방법과 슬로싱 충격압력 데이터 생성에 적합한 손실함수를 적용하여 Fig. 6의 (a), (b), (c)와 같이 기존 데이터 분포에 근접한 데이



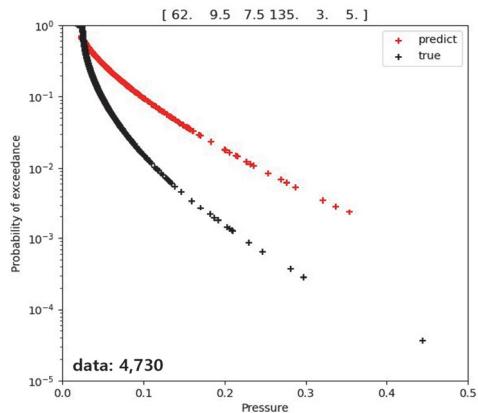
(a) H_s : 8.4 m, T_z : 6.5 sec, heading:150°, sensor location: 2, speed: 5 knots



(b) H_s : 9.8 m, T_z : 8.5 sec, heading:120°, sensor location: 16, speed: 5 knots



(c) H_s : 14.2 m, T_z : 9.5 sec, heading:165°, sensor location: 10, speed: 5 knots



(d) H_s : 9.5 m, T_z : 7.5 sec, heading:135°, sensor location: 3, speed: 5 knots

Fig. 5 Comparison of impact pressure between model test and generator results by model with 2D latent vector

터를 생성하였다. Fig. 6은 전체 실험데이터와 첫 번째 실험데이터, 생성된 데이터 분포를 비교한 것이다. 데이터 생성은 환경에 따라 분포가 변화 하지만, 실험데이터와 비교하였을 때 표준편차가 작아 Fig. 6의 (d)처럼 전체 데이터에 대해 평균값을 따라가는 경향을 보인다. 생성된 데이터는 0.3 이상의 압력 데이터가 모든 환경에서 생성되었다. 하지만 기존 실험데이터에서 0.2 이하 압력 데이터만 존재하더라도 0.3 이상의 압력 데이터가 생성되므로 데이터 분포가 일정하며, 오차가 크게

발생한다. 따라서 환경에 따라 생성되는 데이터의 크기와 확률을 조절하여 실제 데이터 분포와 유사하도록 모델을 개선할 필요가 있다.

본 연구에서는 3 변수 Weibull 분포를 통해 실험데이터와 생성데이터를 비교하였고, 모델 평가지표 중 하나인 RMSE(Root Mean Square Error)와 SMAPE(Symmetric Mean Absolute Percentage Error)를 평가지표로 사용하였으며, 식 (12)와 (13)을 통해 구할 수 있다. \hat{y}_i 는 예측값을 뜻하며 N 은 데이터의 개수를 나타낸다. MAPE(Mean Absolute

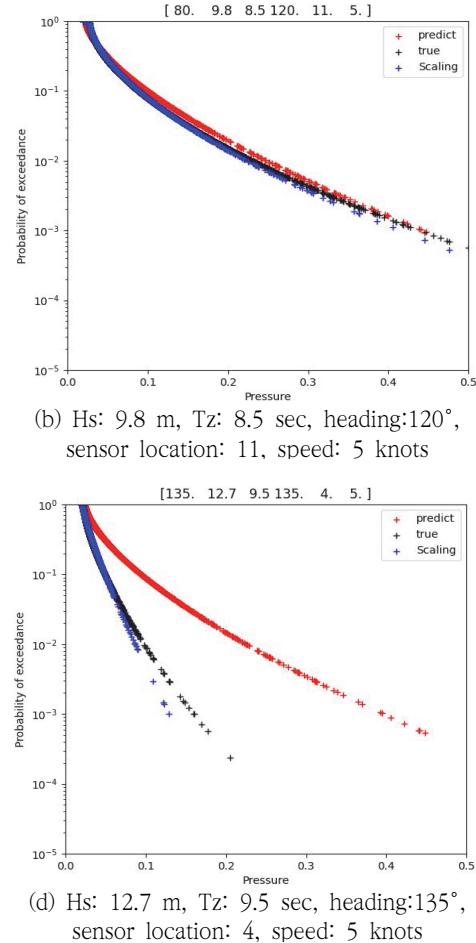
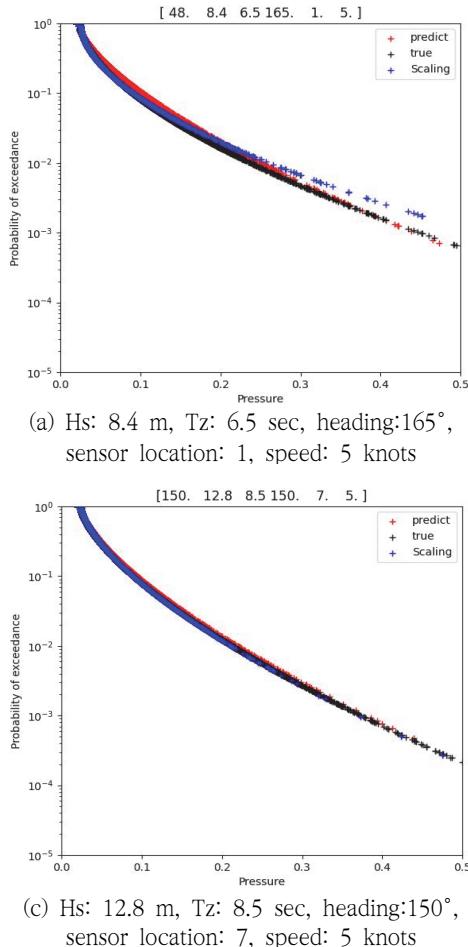


Fig. 6 Comparison of impact pressure between total model test, initial model test and generator results by model with 3D latent vector

Table 2. Comparison of RMSE and SMAPE results between 2D latent vector model and 3D latent vector model. The values of the shape parameter, scale parameter, and location parameter, which are three parameters of Weibull distribution, are compared

	2D Latent vector model		3D Latent vector model	
	RMSE	SMAPE(%)	RMSE	SMAPE(%)
Shape	0.099609	6.09	0.088630	5.86
Scale	0.009352	21.77	0.009926	24.52
Location	0.039986	45.63	0.003169	5.08

Percentage Error)는 실제값에 의존성이 높아 분자가 같더라도 분모가 더 작지면 오차가 커지게 되므로 이를 보완한 SMAPE를 사용했다. RMSE는 평균제곱오차로 값이 작을수록 정밀도가 높고, SMAPE는 백분율로 값을 나타내며 작을수록 오차가 적다[23]. Weibull 분포의 3 변수인 형상 모수, 위치 모수, 척도 모수에 대해 각각의 RMSE와 SMAPE 값을 구하여 Table 2에 나타냈다. 192개의 평가 데이터를 확인한 결과, RMSE의 관점에서는 두 방법 모두 양호한 결과를 보여주고 있다. 하지만 SMAPE 기준에서는 척도 모수에서 2.8% 오차가 커지면서 두 방법에서 모두 좋지 않은 결과를 보여주고 있다. 척도 모수는 분포의 축소 및 확장에 영향을 미치는데, 실험데이터의 척도 모수가 약 0.01 미만으로 작아도 그 값을 따라가지 못하고 제시된 두 모델의 척도 모수 평균값인 0.02 근처에 치우쳐져 있어 오차가 발생하였다. 여기서, 실험데이터의 척도 모수 평균은 0.015215이며 2 차원 모델에서는 0.006064, 3차원 모델에서는 0.007277로 더 큰 차이를 보이면서 RMSE와 SMAPE 결과에 영향을 미쳐 3차원 모델에서 척도 모수의 오차가 상대적으로 더 증가하였다. 위치 모수 값은 40.6%만큼 오차가 대폭 줄어든 것을 확인할 수 있었고, 위치 모수의 SMAPE 값을 통해 결과가 더 개선되었다는 점을 확인할 수 있었다. 하지만 여전히 압력값이 작은 조건에서는 생성된 데이터 분포가 실제 데이터 분포를 잘 따라가지 못

하고 있고, 3가지 변수가 학습에 미치는 영향을 고려하여 모델에 반영해야 한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (12)$$

$$SMAPE = \frac{100}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i|} \quad (13)$$

6. 결 론

본 연구에서는 슬로싱을 분석하기 위해 실행되는 모형시험을 대체할 방법을 모색해보고자 GAN을 이용하여 충격압력 데이터를 생성하였다. 환경 조건과 센서의 위치를 고려해 총 192가지 조건에 대한 데이터를 생성하였고, 3 변수 Weibull 분포에 근사하여 데이터 생성결과를 실제 데이터와 비교해보았다.

초기 연구를 진행한 결과 모형시험 데이터가 충분하고, 높은 압력까지 고르게 있는 조건에서는 생성결과가 양호하다는 점을 알 수 있었다. 슬로싱 모형시험에서는 충격압력이 자주 발생하고, 탱크에 영향을 끼칠 수 있는 최대 압력에 관심이 있으므로 제시된 GAN 모델이 비선형적이고 복잡한 슬로싱 현상을 분석할 수 있다는 점을 확인하였다.

그리고, 2차원 모델의 문제점을 개선하기 위해 3차원 모델을 구축하여 생성된 데이터 분포가 실험데이터의 분포를 따라갈 수 있도록 변경하였다.

그 결과, 초기 방법보다 오차가 줄어드는 것을 확인할 수 있었다. 그러나 실험데이터와 비교하여 표준편차가 작아 전체 데이터의 평균값을 따라가고, 분포가 전체적으로 비슷한 경향을 보였다.

슬로싱 모형시험의 수집된 데이터를 분류하는 과정에서 결과 데이터가 적은 경우, 해당 구획은 제외하는 과정을 거쳤고, 이에 따라 일부 한정된 데이터로 학습하여 출력 데이터가 다소 일반화되지 않은 현상을 확인하였다. 따라서 추후 연구로서 환경에 따라 생성되는 데이터의 크기와 확률을 조절하여 실제 데이터 분포와 유사하도록 모델을 개선하고, 일부 데이터만 활용해 데이터를 생성하는 방안을 모색해야 한다.

감사의 글

본 연구는 한국에너지기술평가원의 지원(No. 20224000000090) 및 산업통상자원부 주관 조선 해양산업기술개발 사업인 “인공지능 기반의 일원화된 선박의 선형, 구획, 기본계산, 적하지침 설계 시스템 기술 개발[20018667]”의 지원을 받아 수행한 연구 과제입니다.

참고문헌

- [1] Oh, M. H., Kim, J. M., Moon, J. S., Sim, W. S., & Shin, H. S. (2015). Sloshing assessment of FLNG cargo containment system due to sloshing loads in bimodal seas: effect of wave intensity. International Journal of Offshore and Polar Engineering, 25(03), 170-177.
- [2] Xue, M. A., Chen, Y., Zheng, J., Qian, L., & Yuan, X. (2019). Fluid dynamics analysis of sloshing pressure distribution in storage vessels of different shapes. Ocean Engineering, 192, 106582.
- [3] British Petroleum (BP) 2020. BP Statistical Review of World Energy. 69th edition.
- [4] Malenica, S., Diebold, L., Kwon, S. H., & Cho, D. S. (2017). Sloshing assessment of the LNG floating units with membrane type containment system where we are?. Marine Structures, 56, 99-116.
- [5] Bureau Veritas (BV) (2011). Design Sloshing Loads for LNG Membrane Tanks. Guidance Note NI 544.
- [6] Lloyd's Register (LR) (2009). Sloshing Assessment Guidance Document for Membrane Tank LNG Operations, ShipRight.
- [7] Kim, Y. (2001). Numerical simulation of sloshing flows with impact load. Applied Ocean Research, 23(1), 53-62.
- [8] Mitra, S., Wang, C. Z., Reddy, J. N., & Khoo, B. C. (2012). A 3D fully coupled analysis of nonlinear sloshing and ship motion. Ocean Engineering, 39, 1-13.
- [9] Jiang, S. C., Teng, B., Bai, W., & Gou, Y. (2015). Numerical simulation of coupling effect between ship motion and liquid sloshing under wave action. Ocean Engineering, 108, 140-154.
- [10] Ahn, Y., Lee, J., Kim, J., & Kim, Y. (2020, October). Application of Neural Network Scheme for Prediction of Extreme Sloshing Loads in LNG Cargo. In The 30th International Ocean and Polar Engineering Conference. OnePetro.
- [11] Chegini, H. G., & Zarepour, G. (2021). Utilizing artificial neural network for load prediction caused by fluid sloshing in tanks. Geofluids, 2021.
- [12] Wei, Z., Zhai, G., Wang, Z., Wang, W., & Ji, S. (2021). An artificial intelligence segmentation method for recognizing the free surface in a sloshing tank. Ocean Engineering, 220, 108488.
- [13] Choi, J.W., 2019. Numerical Study of Sloshing Flow using VOF Method based on Isosurface in OpenFOAM. Ph.D. University of Ulsan: Department of Convergence Technology for

Heavy Industries.

- [14] Det Norske Veritas and Germanischer Lloyd (DNV-GL) (2016). Sloshing Analysis of LNG Membrane Tanks. DNVGL-CG-0158.
- [15] Cetin, E. C., Lee, J., Kim, S., & Kim, Y. (2018). Prediction of extreme sloshing pressure using different statistical models. *Journal of Advanced Research in Ocean Engineering*, 4(4), 185-194.
- [16] Kim, S. Y., Kim, Y., & Ahn, Y. J. (2022). Outlier analysis of sloshing impact loads on liquid ship cargo. *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 14750902211069548.
- [17] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
- [18] Cohen, G., & Giryes, R. (2022). Generative Adversarial Networks. arXiv preprint arXiv: 2203.00667.
- [19] Fu, Q., Wang, H., & Yan, X. (2019). Evaluation of the aeroengine performance reliability based on generative adversarial networks and Weibull distribution. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 233(15), 5717-5728.
- [20] Lee, K., & Shin, D. H. (2019). Generative model of acceleration data for deep learning-based damage detection for bridges using generative adversarial network. *Journal of KIBIM*, 9(1), 42-51.
- [21] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative Adversarial Nets. *stat*, 1050, 10.
- [22] Siva Teja, G., Saurav Vara Prasad C., Venkatesham, B., & Sri Rama Murty, K., 2021. Identification of sloshing noises using convolutional neural network. *The Journal of Acoustical Society of America*, 149(5), 3027-3041.
- [23] Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623.

(접수: 2022.12.12. 수정: 2023.01.09. 게재확정: 2023.01.16.)