

# 합성곱 신경망 기반 선체 표면 압력 분포의 픽셀 수준 예측

김다연\* · 서정범\*\* · 이인원†

## Pixel level prediction of dynamic pressure distribution on hull surface based on convolutional neural network

Dayeon Kim\*, Jeongbeom Seo\*\*, Inwon Lee†

**Abstract** In these days, the rapid development in prediction technology using artificial intelligent is being applied in a variety of engineering fields. Especially, dimensionality reduction technologies such as autoencoder and convolutional neural network have enabled the classification and regression of high-dimensional data. In particular, pixel level prediction technology enables semantic segmentation (fine-grained classification), or physical value prediction for each pixel such as depth or surface normal estimation. In this study, the pressure distribution of the ship's surface was estimated at the pixel level based on the artificial neural network. First, a potential flow analysis was performed on the hull form data generated by transforming the baseline hull form data to construct 429 datasets for learning. Thereafter, a neural network with a U-shape structure was configured to learn the pressure value at the node position of the pretreated hull form. As a result, for the hull form included in training set, it was confirmed that the neural network can make a good prediction for pressure distribution. But in case of container ship, which is not included and have different characteristics, the network couldn't give a reasonable result.

**Key Words** : Pixel level prediction, Artificial intelligence, Flow around a ship hull, Pressure distribution prediction, Unet

### 1. 서론

오늘날 인공지능을 활용한 예측 기술은 컴퓨터 연산 성능의 비약적 발전과 더불어 급격하게 성장하여 다양한 공학분야에서 응용되고 있다. 특히 컴퓨터 비전사이언스를 주축으로 활발하게 발전한 다양한 인공지능 기술은 합성곱 신경망의 활용을 기점으로 사진이나 영상

데이터 등의 고차원 데이터에 대한 분류 및 회귀 등에서 탁월한 성능을 보여주고 있다.

특히 역합성곱(deconvolution)을 비롯한 다양한 업샘플링 기법의 응용은 차원을 축소해 분류 등의 문제를 해결하는 것에서 한 걸음 나아가 고차원적인 데이터를 생성할 수 있는 기술적 밑바탕이 되었다. Long et al.<sup>(1)</sup>은 역합성곱을 포함한 신경망을 이용하여 사진 속의 대상체들을 찾아내어 분류하는 의미론적 분할(semantic segmentation)을 수행하여 높은 학습 정도를 보이는 것을 확인하였으며, Eigen et al.<sup>(2)</sup>는 전역적인 수준과 국소적인 수준의 특성

---

† Pusan National University, Professor  
E-mail: inwon@pusan.ac.kr

\* Pusan National University, M.S. Candidate

\*\* Pusan National University, Ph.D. Candidate

---

추출을 수행하는 두 CNN을 적층하여 하나의 카메라로 측정한 시각데이터에서 픽셀별로 카메라로부터 거리 정보를 높은 정도로 학습 가능한 신경망 구조를 제안하였다.

컴퓨터 비전 사이언스에서 시작된 이러한 연구는 다양한 분야로 확장되었으며, 특히 전산 유체 역학의 경우 날개 주변 유동을 픽셀 수준에서 예측할 수 있도록 학습하고자 하는 연구가 진행되었다. Thurey et al.<sup>(3)</sup>은 RANS 방정식을 이용하여 서로 다른 유속과 받음각을 가지는 총 1505 개의 날개 단면(UIUC)에 대한 유동장 데이터를 해석한 후, 스킵 커넥션(skip connection)을 포함한 Unet을 이용하여 유동장을 학습하였다. 해당 연구에서는 유속(Re)에 대한 정보를 포함하는 경계조건을 3채널 이미지 데이터로 입력하고 2차원 유속과 압력데이터의 분포를 추정하도록 신경망을 구성하여 높은 학습정도를 보여주었다.

본 연구는 Unet을 이용하여 선체 표면의 압력 분포를 학습하는 기법에 대한 기초연구를 수행하였다. 우선 Kim et al.<sup>(8)</sup> 이 정의한 모수적 변환 함수 (Parametric modification function)를 활용하여 7개의 기본 선형을 변환하였으며, 해당 선박 데이터에 대하여 포텐셜 해석을 수행하여 총 429개의 서로 다른 선박에 대한 표면 압력 분포 데이터를 얻어내었다. 이후 합성곱 신경망에 입력하기 위하여 선체의 표면을 이산화 하여 배열 형태의 입력데이터로 구성하였으며, 선체 표면 형상의 복잡도를 고려하여 전체 영역을 총 5개의 영역으로 분할하여 병렬적으로 합성곱을 수행하도록 하였다.

## 2. Background

### 2.1 선체의 형상과 표면 압력 분포

선박의 형상은 선체 주변 유동에 관한 심도 깊은 이해가 가능해지면서 오늘날의 복잡한 형태를 가지게 되었다. 특히 파도 저항을 최소화하기 위하여 파도의 상쇄 효과를 고려한 구상 선수<sup>(4,5)</sup>가 고안되었으며, 점성에 의한 압력저항을 최소화하며 추진효율을 극대화하기 위한 벌

브형 선미<sup>(6,7)</sup>가 개발되었다(Fig. 1). 앞서 언급한 선형의 국소적 특징과 함께 전역적인 특징을 나타낼 수 있는 여러 가지 선형 매개변수들이 있으며 대표적으로 선박의 비대환 정도를 나타내는 방형계수와 배수량의 분포를 나타낼 수 있는 Cp 곡선 등이 있다.

항주 상태에서의 선체 주변 유동에 의한 표면의 압력 분포는 앞서 설명한 선체의 형상과 밀접하게 관련이 있다. Fig. 2는 포텐셜 유동 해석을 통해 자유수면을 포함한 이상유동에 의한 표면압력 분포를 보여준다. 수선면 하부에서 주 선체에 의한 과도와 반대 위상의 수면파를 생성하여 과도 저항을 감소시키는 선수 벌브에서는 강한 정체압이 발생하며, 선수 어깨에서의 압력이 최대로 떨어지고 중앙부를 기점으로 대칭적으로 압력이 회복됨을 확인할 수 있다. 이때 Cp 커브의 형상은 해당 압력 강하의 기하학적 분포에 큰 영향을 줄 수 있으며, 선종별로 매우 다른 성격을 보인다. 선미부의 경우 압력의 회복이 관측되나 Fig. 2의 예시는 비점성 이상유체에 대한 해석결과 이므로 실제 경우 보다 더욱 강한 압력 회복을 보인다.

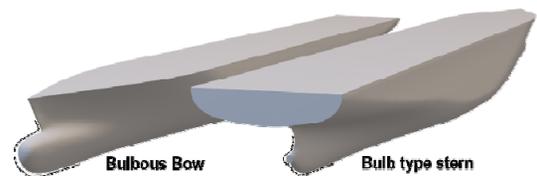


Fig. 1. 3-D model of bulbous bow and bulb-type stern of KCS

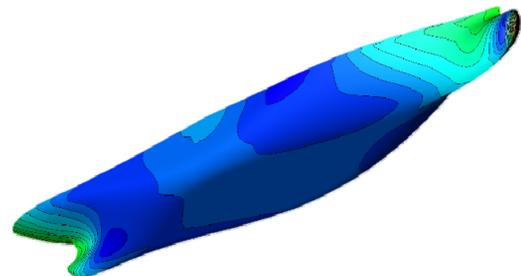


Fig. 2. Dynamic pressure distribution on the surface of hull simulated with potential solver (common example)

### 2.2 선체주위의 포텐셜 유동해석

선체 주변 유동을 비점성, 비압축, 비회전으로 가정하여 선박 주위의 파형해석과 파도에 의한 표면 압력 분포를 분석하는 기법을 포텐셜 유동해석이라 한다. 포텐셜 유동해석은 점성으로 인한 선미부 유동을 제대로 모사할 수 없기 때문에 오늘날의 설계 목적에서 적합하지 않지만 매우 짧은 시간 내에 점성 유동해석 결과와 동일한 형식을 가지는 표면 압력 데이터를 얻을 수 있기 때문에 본 연구에서 활용하였다.

포텐셜 유동에 대한 지배방정식으로 속도 포텐셜에 대한 라플라스 방정식을 풀게 된다 (Eq. (1)). 이때 타원형 방정식의 모든 경계면에 대하여 Eq. (2) 부터 Eq. (4)까지의 경계조건을 부여하며 순서대로 선체 표면 경계 조건(비침투조건), 운동학적 자유수면 경계 조건(KFBC), 동역학적 자유수면 경계 조건(DFBC)이 그것이다.

$$\nabla^2 \phi = 0 \tag{1}$$

$$\nabla \phi \cdot \vec{n} = 0 \tag{2}$$

$$\nabla \phi \cdot \nabla \zeta - \phi_z = 0 \text{ on } z = \zeta(x, y) \tag{3}$$

$$\frac{1}{2} F_N^2 (1 - \nabla \phi \cdot \nabla \phi) = \zeta \text{ on } z = \zeta(x, y) \tag{4}$$

### 2.3 합성곱 신경망과 Unet

합성곱 신경망(Convolutional neural network, CNN)이란 배열의 형태로 존재하는 데이터에 대하여 높은 학습 정도를 보여주는 특수한 형태의 인공신경망이다. CNN은 완전 연결 신경망과 달리 배열내의 인접한 데이터에 제한된 연결관계를 가진다. 이때 일정한 영역내의 데이터를 커버하며 컨볼루션 연산은 커널(Kernel)을 단위로 연산을 수행한다(Fig. 3). 일반적으로 서로 다른 커널에 대하여 반복적으로 컨볼루션을 수행하여 중첩된 특성맵(Feature map)을 얻게

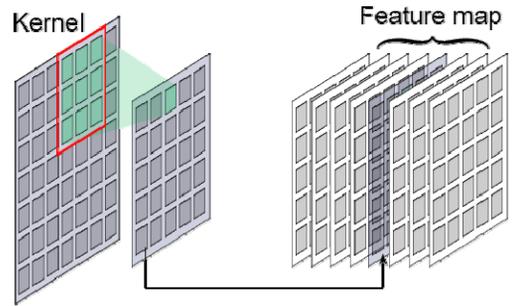


Fig. 3. Convolution layer and feature map

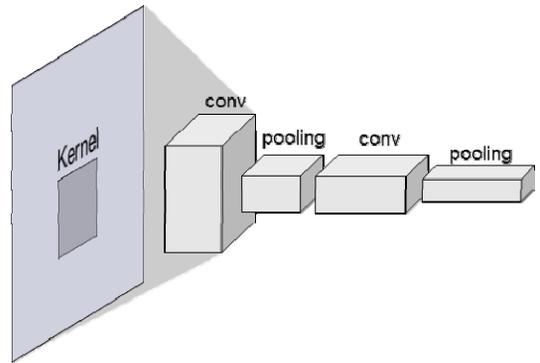


Fig. 4. Convolutional neural network

되며, 해상도를 낮추는 풀링과 함께 동일한 과정을 수차례 반복하여 데이터를 처리하게 된다.

Unet은 Fig. 5와 같이 알파벳 U형태를 갖춘 신경망으로 앞서 살펴본 합성곱 신경망과 업샘플링을 포함한 역합성곱 신경망을 순차적으로 적층하여 고차원 데이터에 대한 픽셀 수준의 예측을 가능하게 하는 신경망 구조이다<sup>9)</sup>.

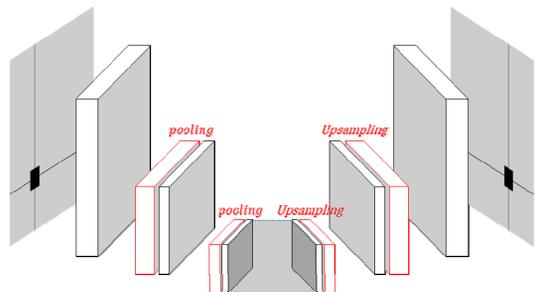


Fig. 5. Common structure of Unet

### 3. Methodology

#### 3.1 선형 데이터의 구성

본 연구에서는 LNG 운반선과 LPG 운반선 그리고 소형 화학운반선 등 7척의 기본 선형 데이터를 준비하였다. 기본선형의 채원과 구상 선수의 치수는 Table 1 과 같다. 이후 모수적 변환함수 기법<sup>(8)</sup>을 이용하여 구상 선수의 높이, 길이, 폭, Cp 곡선과 주요요목을 변형하여 143 개의 서로 다른 선형을 생성하였다. 이때 각 선형의 변형 범위는 기존 선형의 주요 요목에 따라 상대적으로 결정했으며 변형량에 대한 자세한 정의는 Kim et al.<sup>(8)</sup>과 같고 그 범위는 Table 2에 표기하였다.

**Table 1.** Main particular and size of bulb of baseline hull form data

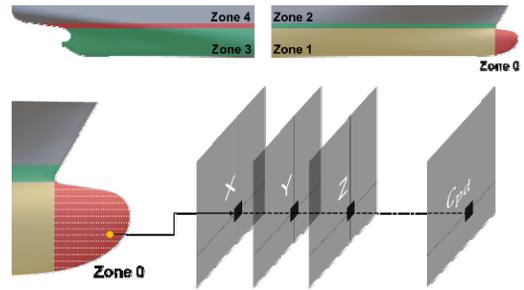
	LBP	B	T	Speed	L <sub>bulb</sub>	B <sub>bulb</sub>	h <sub>bulb</sub>
unit	m	m	m	knot	m	m	m
1	133.0	21.4	7.4	16.0	3.76	1.49	3.14
2	122.5	20.8	3.8	13.5	4.51	1.75	3.91
3	152.2	25.6	8.3	16.0	3.76	1.80	3.52
4	165.0	28.0	9.5	16.0	4.76	1.11	2.09
5	219.0	32.2	11.0	18.5	6.51	2.29	4.71
6	272.0	43.4	11.7	19.5	8.27	3.37	5.00
7	282.0	45.6	11.5	19.5	8.52	4.92	3.18

**Table 2.** Range of variation parameters of parametric modification function

Type	Variation range
LBP	-LBP/20, 0, LBP/20
B	-B/10, 0, B/10
h <sub>bulb</sub>	-T/10, -T/30, T/30
B <sub>bulb</sub>	-B <sub>bulb</sub> /10, 0, B <sub>bulb</sub> /10
L <sub>bulb</sub>	-L <sub>bulb</sub> /8, 0, L <sub>bulb</sub> /8
Cp curve	-LBP/100, 0, LBP/100
Speed	0.8×V <sub>s</sub> , V <sub>s</sub> , 1.2×V <sub>s</sub>

#### 3.2 표면 압력장 데이터 구성

3.1의 과정을 통하여 변형된 선형에 대한 포텐셜 유동 해석을 수행하여 선체 표면의 압력장 데이터를 구성하였다. 입력 데이터의 전처



**Fig. 6.** Hull surface zone division and pre-processing of input hull and pressure

리를 쉽게 하기 위하여 자유수면 형태 변화에 따른 선체 표면 격자의 재생성 과정을 생략하였다.

선체 표면에서 위치에 따른 압력 값을 배열 형태로 나타내기 위하여 우선 선체 표면을 총 5개의 하부 구역으로 나누었다. 특히 압력이 길이방향으로 큰 변화를 보이며, 구상 선수에서 복잡한 압력 변화를 보이는 것을 고려하여 구역을 세분화하였다. 이후 Z 방향 단면에 존재하는 점을 일정 간격으로 분할하여 정렬된 격자형태의 데이터로 전 처리하였다. (Fig. 6) 각 영역은 모두 높이 방향으로 64개 길이방향으로 64개의 점으로 구성하여 표면 정보 데이터와 압력데이터는 각각 64×64×3와 64×64×1의 배열의 형태로 처리하였다.

#### 3.3 Unet의 구성 및 학습

본 연구에서 사용한 Unet의 전체적인 모습은 Fig. 7에 단순화하여 나타내었으며 실제 구조는 Table 3에 정리한 것과 같다. 신경망의 구조는 그 역할에 따라 크게 고차원적인 데이터의 표현형(data representation)을 저차원 표현형으로 만드는 인코더와 이를 다시 고차원적인 형태로 복구시키는 디코더로 나눌 수 있다. 일반적으로 깊은 신경망이 높은 학습 정도를 보여주기 때문에<sup>(10)</sup> 총 변수의 개수를 줄이며 깊은 신경망 생성을 위해서 해상도를 줄여가며 연결한 신경망을 사용하였다.

3.2에서 살펴본 분할된 선체 표면 위치데이터는 병렬적으로 CNN을 거쳐 중앙의 완전연결

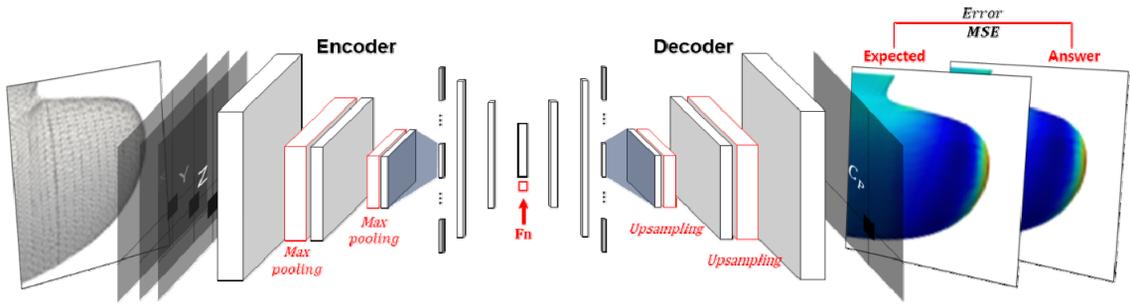


Fig. 7. Overall structure of Unet showing CNN layer for one zone

신경망으로 이어지도록 설계하였다. 이때 각 부분별로 적용된 CNN은 모두 동일한 구조를 가지게 하였으며 합성곱과 풀링 혹은 업샘플링 (pool or upsampling)을 교차하여 총 4회 반복적으로 수행하였다. 또한 중앙에 가까울수록 더 깊은 특성맵을 가지도록 하였다. 커널의 크기와 개수, 그리고 활성화함수 등에 대한 상세한 정보는 Table 3에 순서대로 정리하였으며 디코더의 경우 완전히 대칭적이기 때문에 표에서는 생략하였다. 마지막으로 완전 연결 신경망에 대한 정보는 Table 4에 정리하였다. 특히 서로 다른 선속에 대한 정보를 입력하기 위하여 중앙의 완전 연결 신경망에 하나의 노드를 삽입

하여 프루드 수를 입력할 수 있도록 하였다.

신경망의 학습은 미니배치의 크기를 100으로 하여 총 500 epoch의 학습을 진행하였다.

#### 4. Results

인공신경망의 예측 정도를 비교하기 위해 각 구역 및 전체 평균 제곱 오차 (Mean Square Error, MSE)를 사용하였다. 각 구역의 평균 제곱 오차는 아래와 같이 각 점의 압력에 대한 오차 제곱의 평균을 사용하였다.

$$MSE_{ZONE} = \frac{\sum(\text{Predicted} - \text{Answer})^2}{\text{Number of points}}$$

또한 각 구역에서의 평균 제곱 오차를 모두 더한 것을 전체 평균 제곱오차로 정의하여 예측 정확도를 비교하였다.

##### 4.1 선형에 따른 표면 압력의 예측 결과

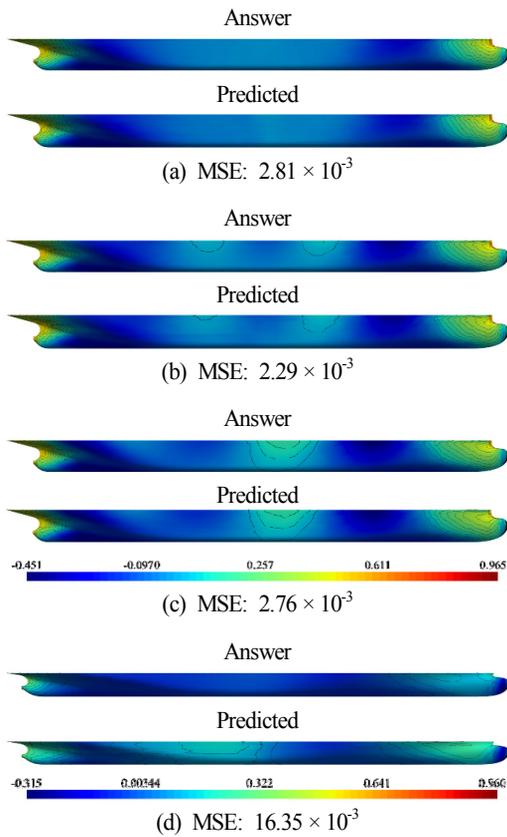
학습이 완료된 인공신경망의 선체의 표면 압력 예측 성능을 평가하기 위하여 학습에 사용한 선박과 그렇지 않은 선박에 대한 압력 분포 추정 정도를 분석하였다. Fig. 8 은 학습에 사용된 13K PC 및 학습에 사용되지 않은 KCS의 포텐셜 해석 결과와 AI를 이용한 예측결과를 비교하여 보여준다. 13K PC선의 경우 학습에 사용된 모든 선속에 대하여 포텐셜 유동과 높은 정도의 일치율을 보여줌을 확인할 수 있었으며

Table 3. Parameters of Encoder

	size	number	padding	activation
Conv1	3 × 3	8	Same	relu
Pool1	2 × 2	-		relu
Conv2	3 × 3	16		relu
Pool2	2 × 2	-		relu
Conv3	3 × 3	32		relu
Pool3	2 × 2	-		relu
Conv4	3 × 3	64		relu
Pool4	2 × 2	-		relu

Table 4. Parameters of Fully Connected Layers

	number of nodes	activation
FC1 FC7	5120	Leakyrelu (alpha = 0.2)
FC2 FC6	1280	
FC3 FC5	320	
FC4	80	



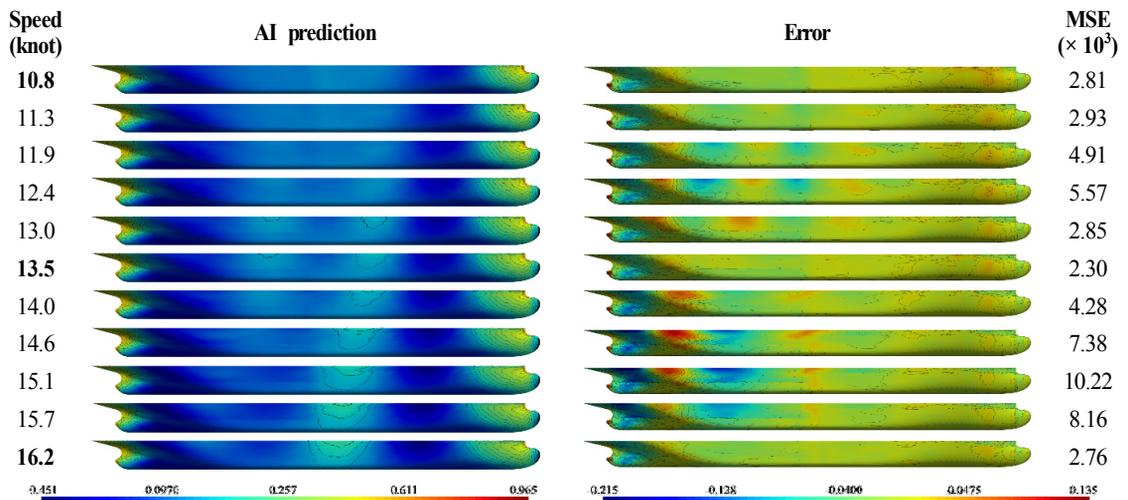
**Fig. 8.** Comparison between potential simulation and AI prediction of 13k PC(a,b,c) and KCS(d); 10.8knot (a), 13.5knot (b), 16.2knot (c), and 24.0knot (d)

2.1 절에서 살펴보았던 압력 분포의 양상과 높은 일치성을 보여줌을 확인했다. 반면에 Fig. 8 (d)의 KCS에 대한 예측결과는 그 분포 경향은 유사하나 압력의 절대적인 값은 큰 차이를 보여주었다. 이는 학습에 사용한 중속 선박과 고속의 컨테이너 선박이 서로 다른 형태와 운항 속도를 가진 것에서 기인한 것으로 보인다. 먼저 형태적인 차이의 경우 선수부 입사각이 상대적으로 큰 중속선이 Fig. 10 (a)와 같이 19 station에서 고속 선박(b)보다 상대적으로 높은 압력을 보인다. 이는 Fig. 11의 KCS에 대한 예측 오차 분포에서 해당 위치의 오차가 그 더 큰 이유를 설명할 수 있다.

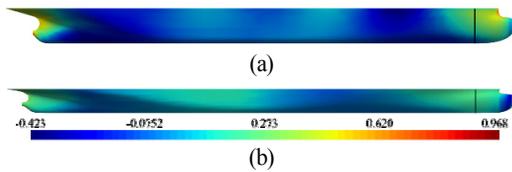
두 번째 선속의 차이의 경우, KCS가 학습데이터 보다 월등히 큰 선속을 가지는데 이는 곧 KCS에 대한 예측 결과가 기존 데이터의 프루드 수를 크게 웃도는 선속에 대한 외삽 결과임을 의미한다. 즉 선미부의 큰 오차는 Fig. 9에서 선속이 커짐에 따라 중앙의 높은 압력이 선미부로 밀리는 현상을 AI가 과도하게 외삽하여 발생한 것으로 사료된다.

#### 4.2 선속에 따른 표면 압력의 예측 결과

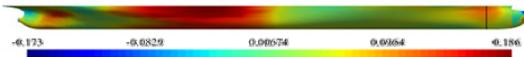
Fig. 9는 연속적으로 선속을 변화시켜가며 압력분포 변화를 관측한 결과이며 오차와 함께



**Fig. 9.** AI prediction results of pressure distribution, error and MSE with consecutive varying speed condition



**Fig. 10.** Pressure distribution of 13k PC (a) and KCS (b); solid line: 19.0 station



**Fig. 11.** Error of KCS 24.0 knots; solid line: 19.0 station

나타내었다, 이때 볼드체로 표기한 선속은 학습데이터에 포함된 선속이고 나머지는 포함되지 않은 선속이다. 선박이 항주할 때 생성되는 수면파는 선속이 증가할 때 그 파장이 길어지는데 이에 따라 선수부의 압력 분포는 길이방향으로 연장되는 경향이 있다. 선속에 따라 예측된 결과를 살펴볼 때 이러한 현상이 잘 반영되어 예측됨을 알 수 있었으며, 구상선수를 포함한 선수부 전 구역에서 낮은 수준의 오차를 보임을 확인할 수 있었다.

그러나 선미부의 경우 상대적으로 큰 오차를 보임을 확인할 수 있었으며, 이는 학습데이터 생성 과정에 사용된 국소적 변환이 선수부에 집중되어 선미 형상에 대한 데이터가 충분하지 못하였기 때문으로 생각된다. 즉 선미부 형상의 데이터의 부족이 서로 다른 선속과 선미부 형상이 만드는 비선형적인 압력분포변화의 예측에 악영향을 준 것으로 사료된다.

## 5. Conclusion

본 연구는 인공지능망을 이용하여 선체 표면 압력을 예측하기 위하여 픽셀 기반 예측에 많이 활용되는 Unet 신경망을 활용한 신경망을 설계하였다.

학습 데이터를 구성하기 위하여 선형 변환 기법과 포텐셜 유동해석 기법을 활용하였으며 선체 표면을 이산화 시켜 배열의 형태로 표현하는 전처리 과정을 수행하였다. 이후 설계한

인공신경망을 이용하여 선체 표면 데이터를 입력하였을 때 각 지점에 대한 압력을 학습시켜 결과를 확인하였다.

그 결과 학습 데이터 세트에 포함된 선형에 대하여 높은 예측 정도를 보여줌을 확인하였다. 특히 학습데이터에 포함되지 않은 선속에 대하여 표면 압력분포의 비선형적인 변화가 높은 정도로 모사됨을 확인할 수 있었다. 그러나 데이터 세트에 포함된 선박과 주변 유동의 관점에서 상이한 컨테이너 선박의 경우 예측 정도가 크게 떨어지는 것을 확인할 수 있었다.

## 후 기

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 한국 연구재단의 지원을 받아 수행된 연구임(No. 2022R1A2C2010821).

## REFERENCE

- 1) Long, J., Shelhamer, E., & Darrell, T., 2015, Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition, 3431-3440.
- 2) Eigen, D., Puhrsch, C., & Fergus, R., 2014, Depth map prediction from a single image using a multi-scale deep network. Advances in neural information processing systems, 27.
- 3) Thuerey, N., Weissenow, K., Prantl, L., Hu, X., 2020, Deep Learning Methods for Reynolds-Averaged Navier-Stokes Simulations of Airfoil Flows, AIAA
- 4) Hoyle, J. W., Cheng, B. H., Hays, B., 1986, A Bulbous Bow Design Methodology for High-Speed Ships. Transactions of Society of Naval Architects and Marine Engineers. 94, 31-56.
- 5) Wigley, W.C.S., 1936, The theory of the bulbous bow and its practical application. Transactions of the North East Coast Institution of Engineers

- and Shipbuilders. 52.
- 6) Thomson, G. R., White, G. P., 1969, Model experiments with stern variations of a 0.65 block coefficient form. Transactions of the Royal Institution of Naval Architects. 111, 299-316.
  - 7) Dawson, J., Thomson, G. R., 1969, Model Experiments with Stern Variations of a 0.80 Block Coefficient Form. Transactions of the Royal Institution of Naval Architects. 111, 507-524.
  - 8) Kim, H. J., Choi, H. J., Chun, H. H., 2007, A Practical Hull Form Optimization Method Using the Parametric Modification Function. Journal of the Society of Naval Architects of Korea. 44(5), 542-550.
  - 9) Ronneberger, O., Fischer, P., & Brox, T., 2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention, 234-241. Springer, Cham.
  - 10) Goodfellow, I. J., Bulatov, Y., Ibarz, J., Arnoud, S., Shet, V., 2014, Multi-digit number recognition from Street View imagery using deep convolutional neural networks. In International Conference on Representations