

합성곱 신경망 기반 선체 표면 유동 속도의 픽셀 수준 예측

서정범* · 김다연* · 이인원†

Pixel-level prediction of velocity vectors on hull surface based on convolutional neural network

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

Abstract In these days, high dimensional data prediction technology based on neural network shows compelling results in many different kind of field including engineering. Especially, a lot of variants of convolution neural network are widely utilized to develop pixel level prediction model for high dimensional data such as picture, or physical field value from the sensors. In this study, velocity vector field of ideal flow on ship surface is estimated on pixel level by Unet. First, potential flow analysis was conducted for the set of hull form data which are generated by hull form transformation method. Thereafter, four different neural network with a U-shape structure were conFig.d to train velocity vectors at the node position of pre-processed hull form data. As a result, for the test hull forms, it was confirmed that the network with short skip-connection gives the most accurate prediction results of streamlines and velocity magnitude. And the results also have a good agreement with potential flow analysis results. However, in some cases which don't have nothing in common with training data in terms of speed or shape, the network has relatively high error at the region of large curvature.

Key Words : Artificial intelligence; Flow around a ship hull; Velocity prediction; Unet; Pixel level prediction

1. 서론

오늘날 인공 신경망을 활용한 고차원 데이터의 예측 기술은 분야를 막론하고 탁월한 성능을 보여주고 있다. 특히 다차원 배열로 표현되는 다양한 데이터에 대한 예측기술은 합성곱 신경망과 그것의 다양한 변형 기술이 활발하게 연구

됨에 따라서 비약적으로 발전하였다.

특히 합성곱 신경망과 역합성곱 신경망을 순차적으로 연결하여 고차원 데이터에 대한 픽셀 수준 예측을 수행하도록 제안된 Unet(Olaf Ronneberger et al. ⁽¹⁾)은 사진 속 대상체들을 분류하는 의미론적 분할(semantic segmentation) 문제에서 탁월한 성능을 보였다.

또한 분류 문제 뿐만 아니라 회귀 문제에서도 Unet은 높은 성능을 보여준다. Thurey et al.⁽²⁾은 서로 다른 유속과 받음각을 가지는 날개 주변 유동을 Unet 으로 학습하여 높은 정도로 예측

† Pusan National University, Professor

E-mail: inwon@pusan.ac.kr

* Pusan National University, Ph.D. Candidate

** Pusan National University, M.S. Candidate

가능함을 확인하였다. 해당 연구에는 학습용 데이터 구축을 위하여 1505 개의 익형 주변 유동을 RANS(Reynolds Averaged Navier Stokes) 방정식으로 해석하였다. 입력 데이터는 유속 정보(레이놀즈 수)를 포함한 날개의 형상 정보를 포함한 3채널 데이터로 정의하였으며, 출력 데이터는 이산화된 도매인의 위치 별 압력과 3방향의 속도로 하였다.

본 연구는 Unet을 활용하여 선체 표면의 속도 분포를 학습하는 기법에 대한 연구를 수행하였다. 우선 모수적 변환 함수 기법(Kim et al. ⁽³⁾)을 활용하여 7개의 기본 선형을 변환한 후 포텐셜 해석을 수행하여 366개의 서로 다른 유동장 데이터를 확보하였다. 이후 선체 표면을 정렬된 형태로 이산화 하여 노드 지점의 위치정보(X,Y,Z)로 구성된 배열과 각 위치 별 속도(U,V,W) 정보로 구성된 배열을 생성한 후 Unet을 학습하였다. 또한 심층 신경망의 학습 정도에 영향을 줄 수 있는 스킵 커넥션의 유무에 따른 학습 정도를 비교하여 분석하였다.

2. Background

2.1 선체의 형상과 포텐셜 유동의 속도 분포

선박의 수선 하부 형상은 일반적으로 날렵한 형상을 가지며, 선박의 속도와 배수량등의 기본적인 조건에 따라서 다양하다. 특히 선체의 형상은 저항 성능과 추진 성능을 극대화 시키기 위한 연구를 통하여 오늘날과 같은 독특한 형상을 가지게 되었다. 예를 들어 선수의 끝단 수선면 아래 위치하는 구상선수^(4,5)는 선체가 생성하는 수면파와 반대되는 위상의 파를 생성하여 과도 저항을 최소화 시키고자 하는 목적으로 개발된 대표적인 선수 형태이다. 또한 벌브형 선미^(6,7)는 점성 저항을 감소 시키고 동시에 프로펠러 면의 균일한 반류 분포를 형성하기 위하여 고안된 대표적인 선미 형상이다.

선체 표면에서의 유동의 속도 벡터는 전술한 선체의 형상을 3차원적으로 따라 흐르게 되며, 그 방향은 일반적으로 선체 표면에서의 유선




Fig. 1. Streamlines on the surface of a hull simulated with potential solver

(streamline)으로 나타낸다. Fig. 1의 경우 포텐셜 유동 해석 결과로 얻은 선체 표면에서의 유선을 나타낸다. 먼저 선수부의 경우 벌브 상단을 통과한 유선이 매끄럽게 연결되어 선측면과 선저면을 타고 흐르게 됨을 알 수 있다. 또한 선미부의 경우 선저면에서 올라오는 유동이 선미 벌브를 돌아 프로펠러면 상단으로 입사되는 복잡한 유동을 보임을 알 수 있다. 이는 실제 점성 유동에 대한 벽 전단 응력의 유선보다는 단순하지만 선체의 형태에 따른 유동 방향 변화를 확실하게 나타낼 수 있기 때문에 학습데이터로 사용하기에 적합하다고 판단하였다.

2.2 선체 주위의 포텐셜 유동 해석

선체 주변의 유동을 비점성, 비회전, 그리고 비압축으로 가정하여 자유 표면을 포함한 선박 주변 유동을 해석하는 기법을 포텐셜 유동 해석이라고 한다. 포텐셜 유동해석은 특히 점성이 유동에 영향을 많이 줄 수 있는 선미부의 유동 현상을 실제적으로 모사할 수 없지만, 해석 속도가 매우 빠르고 선체 형상의 변화에 따른 표면 압력 및 유선의 변화를 일관성 있게 해석할 수 있어 인공지능의 초기연구에 사용할 데이터를 체계적으로 마련하기 위한 방법으로 적절하다.

전술한 포텐셜 유동의 해석은 지배방정식으로 속도 포텐셜(ϕ)에 대한 라플라스 방정식(Eq. (1))을 풀게 되며, 모든 경계면에 대하여 적절한 경계조건을 부여하게 된다. 아래 기술된 식들은 순서대로 선체 표면에 대한 비 침투조건 (Eq (2)), 운동학적 자유수면 경계조건 (Eq (3)), 동역학적 자유수면 경계조건 (Eq (4)) 이다. 이때 \vec{n} , ζ 그리고 Fr 는 각각 선체 표면의 법선 벡터, 자

유 수면의 높이, 그리고 선박의 무 차원 속도 인 프루드수를 의미한다.

$$\nabla^2 \phi = 0 \quad \text{Eq (1)}$$

$$\nabla \phi \cdot \vec{n} = 0 \quad \text{Eq (2)}$$

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

$$\frac{1}{2} Fr^2 (1 - \nabla \phi \cdot \nabla \phi) = \zeta \quad \text{Eq (4)}$$

$$\text{on } z = \zeta(x, y)$$

2.3 합성곱 신경망과 Unet

합성곱 신경망(convolution neural network, CNN, LeCun et al. ⁽⁸⁾)은 배열의 형태로 표현되는 데이터의 특성을 추출하여 학습 정도를 높이는 데에 효과적인 인공지능망의 종류이다. 특히 특정 데이터와 인접한 데이터의 연관 관계가 데이터를 이해하는 데에 중요한 역할을 하는 경우 효과적인 특성 추출을 수행할 수 있다. 예를 들어 합성곱 신경망은 시각적 데이터에 적용되어 높은 정도를 보여 주며, 또한 변형된 다양한 형태의 합성곱 신경망이 적극적으로 활용되고 있다(Alzubaidi et al. ⁽⁹⁾).

합성곱 신경망은 배열의 인접한 요소 사이에 제한된 연결을 구현하기 위하여 커널(kernel)을 단위로 신경망의 연산을 수행하게 된다. 이때 일반적으로 여러 개의 서로 다른 커널을 사용하여 깊은 차원의 특성맵을 구축한다.(Fig. 3). 또한 경우에 따라 특성맵의 해상도를 조절하기 위한 풀링 혹은 업샘플링과 함께 교차적으로 연결되어 각각 합성곱층과 역합성곱 층으로 활용된다.




Fig. 3. Convolution layer and feature map




Fig. 4. Common architecture of Unet with skip connection

Unet은 전술한 합성곱층과 역합성곱층을 순차적으로 배열하여 고차원 배열의 입출력을 수행할 수 있는 인공지능망을 일컫는다. 일반적인 Unet의 형태는 Fig. 4와 같으며, 많은 경우 인코더와 디코더 사이를 연결하는 스킵 커넥션이 존재한다. 이때 스킵 커넥션은 신경망내에 순차적인 연결구조를 몇 단계 뛰어 넘는 연결을 일컫으며, 특히 Unet에서는 연결된 길이에 따라서 짧은 스킵 커넥션(short skip connection)과 긴 스킵 커넥션(long skip connection)으로 나뉘는 두 가지 서로 다른 스킵 커넥션을 포함하고 있다.

전술한 두 가지 종류의 스킵 커넥션은 Unet에서 서로 다른 목적을 가지고 활용된다. 먼저 짧은 스킵 커넥션의 경우 심층 신경망에서 발생하는 기울기 소실 문제를 효과적으로 해결할 수 있는 기법이다. 구체적으로 전단의 합성곱 연산 결과를 뒤쪽 연산 과정에 요소별로 합하는 방식으로 수행된다(ResNet, Kaiming He et al. ⁽¹⁰⁾). 반면 긴 스킵 커넥션의 경우 특성을 추출하는 전단의 합성곱층의 데이터를 역 합성곱 층으로 이어 붙임으로써 높은 해상도의 데이터를 직접적으로 전달하여 예측정도를 높이고자 하는 목적으로 제안되었다.

3. Methodology

3.1 선체 형상 및 포텐셜 유동 데이터 구축

학습 데이터로 사용할 선체의 형상 데이터셋은 선형 변환 기법을 활용하여 생성하였다. 즉 변형의 시작점이 되는 7척의 기본 선박을 선

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

	LBP	B	L_{bulb}	B_{bulb}	H_{bulb}	V_s
No.	m	m	m	m	m	knot
(1)	133.0	21.4	3.76	1.49	3.14	16.0
(2)	122.5	20.8	4.51	1.75	3.91	13.5
(3)	152.2	25.6	3.76	1.80	3.52	16.0
(4)	165.0	28.0	4.76	1.11	2.09	16.0
(5)	219.0	32.2	6.51	2.29	4.71	18.5
(6)	272.0	43.4	8.27	3.37	5.00	19.5
(7)	282.0	45.6	8.52	4.92	3.18	19.5

정하였으며 이를 변형 함으로서 대량의 학습 데이터를 구성하였다. 이때 기본 선박은 액화 천연가스운반선 및 소형 석유화학제품 운반선으로 구성하였다. 선박의 기본 제원으로서 LBP (Length Between Perpendicular)와 폭(Breadth, B)에 대한 정보를 Table 1에 기입하였으며, 선수부의 구체적인 형상을 나타낼 수 있는 구상 선수의 높이(H_{bulb})와 길이(L_{bulb}) 그리고 폭(B_{bulb}) 또한 함께 표기하였다. 마지막으로 선박 주변 유체의 특성에 큰 영향을 미치는 설계 선속(V_s)을 표기하였다.

선형 변환 기법은 모수적 변환 함수 기법을 활용하였으며, 앞서 서술한 선박의 제원과 배수량 분포 곡선을 변화시켰다. 배수량 분포 곡선의 변화는 선박의 횡단면 형상을 유지하며 길이 방향으로 이동시키는 방식으로 수행하였으며, 단면의 X 방향 최대 이동량(ΔX_{max})을 매개변수로 하였다.⁽³⁾

포텐셜 해석 조건의 경우 선속에 변화를 주어 서로 다른 속도 조건에 대한 유동장 데이터를 포함하였다. 그리고 선형 변환시에는 과도하게 변형되어 선형이 지나치게 왜곡되는 것을 막기 위하여 변형량의 범위는 Table 2 와 같이 제한하였다. 그 결과 총 366개의 서로 다른 유동장 데이터를 수집하였다.

전술한 과정으로 생성된 데이터는 학습 데이터와 검증(validation) 데이터, 그리고 테스트 데이터로 8 : 1 : 1의 비율로 나누어 사용하였다. 그리고 전술한 기본 선형들로부터 변형된 선형들이

Table 2. Range of variation parameters of parametric modification function and velocity

Type	Variation range
LBP	$[-LBP/20, LBP/20]$
B	$[-B/10, B/10]$
H_{bulb}	$[-T/10, T/30]$
B_{bulb}	$[-/10, /10]$
L_{bulb}	$[-L_{bulb}/8, L_{bulb}/8]$
ΔX_{max}	$[-LBP/100, LBP/100]$
V_s	$[-0.2, 0.2]$

각각의 데이터 세트에 골고루 포함되도록 분배하였다. 즉 학습 데이터 세트와 나머지 데이터 세트는 서로 다른 선형이나 선속 조건을 가지게 되며, 유사한 선형 데이터로 치우쳐지지 않도록 구성하였다.

3.2 학습 데이터 전처리

전술한 선체의 형상 데이터와 유동 해석 데이터는 배열의 형태로 전 처리하여 학습할 수 있도록 하였다. 특히 선수나 선미로 갈수록 선체의 형상이 복잡해지기 때문에 길이 방향으로 코사인 분할(cosine spacing)하여 이산화 하였으며, 높이 방향 및 길이 방향을 모두 64개로 분할하여 노드점의 위치정보와 속도 정보를 각각의 배열로 나타내었다. (Fig. 5)




Fig. 5. Pre-processing of input hull and output velocity distribution data

3.3 인공 신경망의 구성 및 학습

본 연구에서 사용한 Unet의 전체적인 모습은 Fig. 6와 같으며 일반적인Unet의 형태를 가진다. 중앙을 기준으로 데이터의 차원을 축소시키는

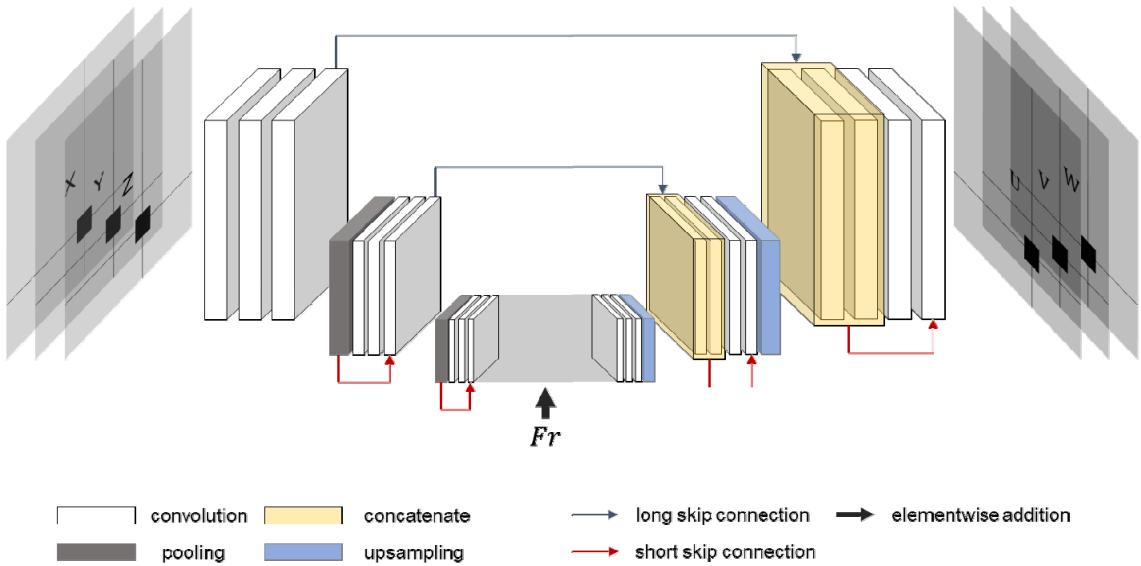


Fig. 6. Overall structure of the Unet with skip connections

인코더의 경우 3개의 합성곱층과 1개의 맥스풀링층을 반복적으로 3회 수행하였으며, 디코더의 경우 동일한 구조를 3회 반복하되 풀링 대신 해상도를 늘리는 이중선형보간(bilinear interpolation) 업샘플링층을 사용하였다. 또한 가장 마지막 합성곱 층의 경우 출력층의 속도 데이터가 하나의 부호로 편중된 값을 가지지 않음을 고려하여 항등 함수(identity function)를 활성화함수로 사용하였으며, 나머지 은닉층의 경우 ReLU(Rectified linear unit)를 사용하였다.

선박의 속도 정보를 입력하기 위하여 전단부 신경망에서 추출된 특성맵에 각 학습 케이스의 무 차원 속도인 프루드수를 요소별로 덧셈하기 위한 입력층을 추가하였다. 이는 축소된 차원에서 입력된 선속 정보가 후단의 합성곱층을 통과하며 선체 표면의 국소적인 속도 값의 예측에 고루 반영되며 학습되도록 하기 위함이다.

스킵 커넥션의 경우 연결 유무에 따라서 총 4 가지 서로 다른 신경망을 준비하였으며, 순서대로 긴 스킵 커넥션과 짧은 스킵 커넥션 모두 연결한 경우, 각각 한가지 씩만 연결한 경우, 그리고 스킵 커넥션을 연결하지 않은 경우 등이 그것이다.

신경망 학습 시 미니 배치의 크기는 일반적으

로 그 크기가 커질수록 학습에 소요되는 시간이 짧아지는 대신 검증 오차가 커지는 경향이 있기 때문에 세심하게 선정할 필요가 있다. 본 연구에서는 검증 오차가 소폭 증가하지만 학습에 소요되는 시간이 적은 미니 배치의 크기(200)를 선정하여 사용하였다. 또한 모든 해석케이스에서 오차가 충분히 수렴되는 epochs(1000)까지 학습을 수행하고 그 결과를 비교하였다. 연산에 활용한 하드웨어의 경우 GeForce RTX 3080을 활용하였다.

4. Results

4.1 신경망 구조에 따른 테스트 오차 비교

전술한 스킵 커넥션에 따른 네 가지 인공 신




Fig. 7. MSE of four different types of structure

경망의 학습 정도는 MSE(Mean squared error)를 이용하여 정량적으로 비교하였으며, 학습 데이터에 대한 오차와 테스트 데이터에 대한 오차는 Fig. 7에 비교하여 도시하였다.

특히 스킵 커넥션을 연결한 모든 경우에 대하여 학습정도에 개선이 있음을 확인할 수 있었다. 특히 가장 큰 오차 감소율을 보인 짧은 스킵 커넥션만 연결한 신경망의 경우 스킵 커넥션이 없는 신경망에 비하여 약 39%의 오차 감소율을 보임을 확인할 수 있었다. 긴 스킵 커넥션만을 사용한 경우 또한 오차가 감소함을 확인할 수 있었다. 그러나 두 가지 스킵 커넥션을 모두 사용한 경우에는 오히려 짧은 스킵 커넥션만 연결한 경우보다 소폭 오차가 증가하였다. 이는 긴

스킵 커넥션이 연결된 후 곧바로 출력층으로 이어지는 구조가 데이터 예측을 수행하기에 충분히 깊지 않기 때문으로 사료된다.

테스트 오차와 학습 오차 사이의 편차의 경우 네 가지 신경망 모두 크지 않으며, 이로 부터 주어진 학습 데이터 세트에 대하여 과적합(overfitting)된 상태가 아님을 알 수 있었다.

4.2 속도 벡터 예측 결과

학습이 완료된 인공지능 모델의 성능을 정성적으로 확인하기 위하여 테스트 데이터에 대해 예측된 결과와 포텐셜 해석 결과를 비교하였다 (Fig. 8).

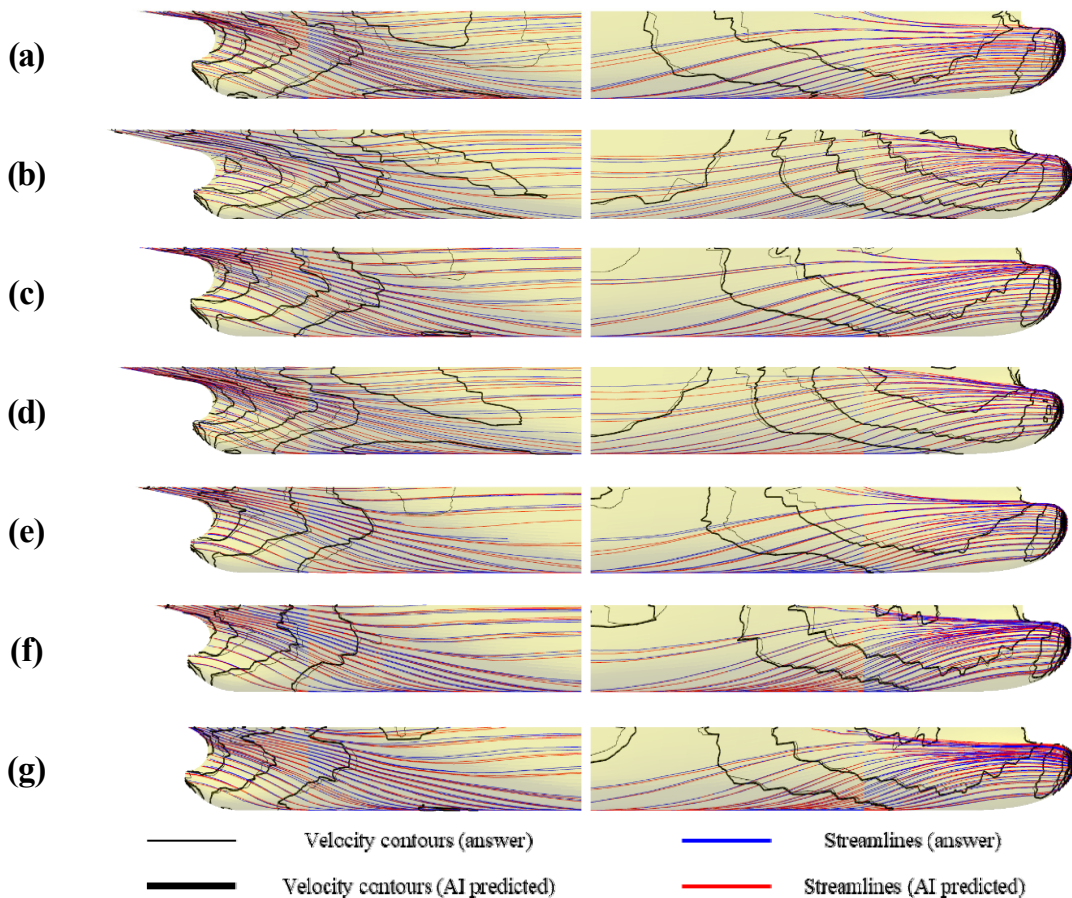


Fig. 8. Comparison of velocity magnitude contours and streamlines on hull surface, (a) to (g) are prediction results of the test hull forms whose baseline hull forms are (1) to (7) in Table 1 respectively

비교에 사용한 인공 신경망은 짧은 스킵 커넥션만 연결한 신경망이며, (a) 에서 (g)는 각각 Table 1의 (1)에서 (7)번 기본 선형으로부터 변형된 테스트 선형이다.

예측된 속도의 방향과 크기를 모두 비교하기 위하여 표면 유선 및 속도 크기 등고선을 표기하였다. 또한 동일한 위치를 지나는 유선을 그려내기 위하여 선수미의 특정 단면을 이루는 점들을 유선을 계산하기 위한 시드(seed)로 지정하였다. 즉 선미의 경우 선미 수선에서 0.1LBP 전방 단면의 점들을 시드로 지정하였으며, 선수의 경우 선수 수선에서 0.1LBP 후방 단면의 점들을 시드로 지정하였다.

그 결과 인공 지능 예측 유선은 포텐셜 해석 유선과 완전히 동일하지는 않으나, 전 영역에서 평행하며 교차하지 않는 모습을 보여주었다, 반면 속도의 크기는 (a) 나 (b), 그리고 (d)와 같이 유의미한 차이를 보이는 경우를 확인할 수 있었다. 특히 단면의 크기가 급격하게 줄어드는 선수미의 굴곡이 심한 부분에서 차이가 발생함을 확인할 수 있었다.

전술한 차이를 보인 세 선형과 학습데이터를 분석한 결과 선속이나 선형 변환의 종류가 학습 데이터에 전혀 포함되지 않았음을 확인할 수 있었다.

즉 국부적인 형태에 대한 다양한 데이터가 보장 되지 않는 경우, 해당 영역에서 유동장의 예측 오한 또한 커짐을 확인할 수 있었다.

5. Conclusion

본 연구는 선체의 형상에 따라 변화하는 선체 표면에서의 유동 정보를 학습하기 위하여 선형 및 유동장 데이터의 생성 및 전처리와 인공신경망의 구조에 따른 케이스 스터디를 진행하였다. 우선 학습 데이터를 구축하기 위하여 포텐셜 유동 해석 기법과, 모수적 선형 변환 기법을 활용하여 7개의 기본 선형으로부터 변형된 형상과 선속별 표면 속도 벡터장 데이터를 총 366개 마련하였다. 케이스 스터디에 사용한 인공신경망은 짧은 스킵 커넥션과 긴 스킵 커넥션의 포함

유무에 따라 총 4 가지 서로 다른 Unet으로 설계하였다. 또한 중앙의 합성곱층에 무 차원 속도인 프루드수를 요소별로 합할 수 있도록 하였다.

학습 결과 스킵 커넥션을 연결한 Unet의 경우 연결하지 않은 경우보다 항상 낮은 오차를 보여 줌을 확인할 수 있었으며, 짧은 스킵 커넥션만 연결한 경우 최대 오차 감소율인 36%의 오차 감소를 보임을 확인할 수 있었다. 그러나 효과를 보인 두 스킵 커넥션을 모두 사용한 경우 그 효과가 중첩되어 나타나지 않음을 확인할 수 있었다. 이는 Fig. 6과 같이 전단의 고차원 데이터가 이어 붙여진 후 곧바로 출력층으로 전달되는 구조가 충분히 깊은 구조가 아니기 때문으로 사료된다.

테스트 데이터로 확인한 속도 벡터 예측결과 는 전반적으로 정답 데이터와 높은 일치율을 보임을 확인하였다. 그러나 선형의 국소적인 변형이 학습데이터에 포함되지 않았을 때, 해당 부분의 예측 정확도 또한 비교적 떨어짐을 확인할 수 있었다.

후 기

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

REFERENCE

- 1) Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015.
- 2) Thuerey, N., Weissenow, K., Prantl, L., Hu, X., 2020, Deep Learning Methods for Reynolds-Averaged Navier-Stokes Simulations of Airfoil Flows, AIAA
- 3) 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.
- 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) LeCun, Yann, et al. "Gradient-based learning applied to document recognition." Proceedings of the IEEE 86.11 (1998): 2278-2324.
 - 9) Alzubaidi, Laith, et al. "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions." Journal of big Data 8.1 (2021): 1-74.
 - 10) He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.