

# DNN과 Decoder 모델 구축을 통한 생체모방 3차원 파형 익형의 유체역학적 특성 예측

김민기\* · 윤현식<sup>†</sup> · 서장훈\*\* · 김민일\*\*

## Establishment of DNN and Decoder models to predict fluid dynamic characteristics of biomimetic three-dimensional wavy wings

Minki Kim\*, Hyun Sik Yoon<sup>†</sup>, Janghoon Seo\*\* and Min Il Kim\*\*

**Abstract** The purpose of this study establishes the deep neural network (DNN) and Decoder models to predict the flow and thermal fields of three-dimensional wavy wings as a passive flow control. The wide ranges of the wavy geometric parameters of wave amplitude and wave number are considered for the various the angles of attack and the aspect ratios of a wing. The huge dataset for training and test of the deep learning models are generated using computational fluid dynamics (CFD). The DNN and Decoder models exhibit quantitatively accurate predictions for aerodynamic coefficients and Nusselt numbers, also qualitative pressure, limiting streamlines, and Nusselt number distributions on the surface. Particularly, Decoder model regenerates the important flow features of tiny vortices in the valleys, which makes a delay of the stall. Also, the spiral vortical formation is realized by the Decoder model, which enhances the lift.

**Key Words** : Deep Neural Network(심층 신경망), Decoder(디코더), Three-dimensional Wavy Wing(3차원 파형 익형), Computational Fluid Dynamics(전산유체역학)

### 1. 서론

파형은 혹등고래 등지느러미의 독특한 구조에서 영감을 받은 생체 모방 기술이다. 특히 익형 설계 시 유체 역학 및 유동 제어 측면에서 중

요한 이점이 있음이 확인되었으며, 이러한 유체역학적 파형을 익형 설계 시 적용함으로써 연구자들은 양력, 항력 등 유체력 성능 개선을 달성할 수 있었다<sup>(1-14)</sup>. 이는 항공기 익형, 풍력 터빈, 심지어 냉각 팬과 같은 다양한 분야에서의 응용으로 이어졌다.

이러한 파형의 특성을 조사하기 위해 연구자들은 일반적으로 전산유체역학(CFD) 또는 실험 유체역학(EFD) 방법을 사용하나 정확한 데이터를 생성하는 데는 많은 비용과 시간이 소요된다. 따라서, 유체력 계수, 열 계수, 유동 및 열 유동장과 같은 다양한 유체역학 특성을 효과적으

<sup>†</sup> Department of Naval Architecture and Ocean Engineering, Pusan National University, Professor  
E-mail: lesmodel@pusan.ac.kr

\* Department of Naval Architecture and Ocean Engineering, Pusan National University, Ph.D candidate

\*\* Department of Naval Architecture and Ocean Engineering, Pusan National University, Ph.D

로 예측하기 위하여 최근 기계 학습 기술에 대한 수요가 높아지고 있으며, 관련 연구 또한 활발하게 진행되고 있다<sup>(15-16)</sup>.

Chen et al.<sup>(17)</sup>은 CNN 모델을 사용하여 유체력 계수 및 익형 형상을 예측하는 딥러닝 방법을 수립하였는데, 300개의 익형 단면 이미지를 입력 데이터로 활용하여 피치 모멘트, 항력과 양력 계수를 출력하는 모델을 구성하였다.

Kim and Yoon<sup>(18)</sup>은 CNN 모델을 사용하여 기하학적 수정을 기반으로 2차원 익형 성능을 개선하는 방법을 개발하였는데, 이 방법은 익형 형상 변형을 통한 유동 제어 방법이다.

Duru et al.<sup>(19)</sup>은 익형 주변의 압력장을 예측하기 위해 합성곱 계층 인코더 디코더를 제안하였는데, 제안된 모델은 CFD 시뮬레이션에 비해 전반적인 유동 패턴을 정확하게 예측할 수 있으며 효율적인 속도 성능을 나타내었다.

Seo et al.<sup>(20)</sup>은 익형 형상으로부터 2차원 NACA 단면 주변의 유동 및 열 특성을 예측하기 위한 CNN 및 ED 모델을 수립하였는데, CNN 및 ED 모델을 사용하여 익형의 공기역학 계수,  $Nu$  수, 그리고 압력, 속도 및 온도에 대한 유동장과 온도장을 예측하였다. 결과는 CNN 및 ED 모델이 2차원 익형 주변의 유동 및 열전달 특성을 예측하는 데 매우 유용하다는 것을 보여주었다.

Kim et al.<sup>(21)</sup>은 3차원 익형 주변의 유동 및 열 특성을 예측하기 위한 CNN 및 ED 모델을 개발하였는데, CNN 및 ED 모델을 통하여 유체력 계수,  $Nu$  수에 대한 양적인 예측 성능 뿐만 아니라 압력, 유속선 및 온도 등의 유동장과 온도장에 대한 질적 예측 또한 잘 수행하였다.

앞서 언급한 선행 연구들에서는 파형의 성능, 유체의 유동 및 열전달 특성을 2차원으로 예측하였다. 최근에 Kim et al.<sup>(19)</sup>이 고려한 3차원 파형은 복잡한 형상 좌표 정보가 입력되었으나, 정형화된 단순한 파라미터로 정의할 수 있는 형상이므로 이러한 정형화된 형상에 대해서는 입력을 형상 파라미터로 사용하는 DNN 모델과 Decoder 모델을 활용하면 보다 입력 데이터 생성을 효율적으로 할 수 있을 것으로 판단된다.

따라서, 본 연구에서는 CNN과 ED 모델로 Kim et al.<sup>(21)</sup>이 수행한 파형 익형에 대한 연구를 DNN 및 Decoder 모델로 동일하게 수행한다. 추가적으로 본 논문에서는 Kim et al.<sup>(21)</sup>이 고려하지 않은 파형에 의해서 생성되는 유체역학적 특성인 박리를 지연시키는 작은 와도의 존재를 예측하기 위한 모델의 정확도를 높이기 위해서 Kim et al.<sup>(21)</sup>보다 더 많은 데이터 세트를 사용한다.

## 2. 연구 방법

본 연구에서는 파형 익형의 유동 및 열전달 특성을 예측하기 위해 Deep Neural Network (DNN) 과 Decoder 모델들을 개발하였다. 기존 CNN 및 ED(Encoder-Decoder) 모델들 중 CNN 모델은 파형 익형 표면의  $x, y, z$  좌표를 입력 데이터로 사용하고 출력 레이블은 양력, 항력 및  $Nu$  수로 구성되며, 동시에 ED 모델은 CNN 모델과 동일한 입력 데이터를 사용하여 압력, 표면 마찰속도 및  $Nu$  수로 구성된 출력 레이블로 훈련된다. 그러나, DNN 과 Decoder 모델들은 CNN 및 ED 모델들 대비 출력 레이블은 동일하나 파형 익형 표면 좌표 대신  $AR$ (aspect ratio),  $W_n$ (wavy number),  $A_m$ (wavy amplitude)와  $\alpha$ (angle of attack) 와 같은 기하학적 매개변수를 입력 레이블로 구성한다. 딥러닝 모델의 훈련(training) 및 테스트(test) 절차는 하기와 같다. 먼저, 3차원 파형 익형 형상에 대한 CFD 해석을 수행하고 이를 통해 데이터 세트를 준비한다. 이러한 DNN 과 Decoder 모델을 사용하여 파형 익형의 항력 및 양력 계수와 파형 익형 주위 압력계수 분포, 제한 유속분포 및  $Nu$  분포를 각각 훈련 및 예측한다. 마지막으로 훈련된 딥러닝 모델은 예측 결과와 실제 결과를 비교하여 테스트 된다.

## 2.1 CFD 해석을 통한 데이터 세트 구성

### 2.1.1 지배방정식

본 연구에서는 파형 익형 주위의 유동을 3차원 정상, 비압축성과 층류 유동으로 가정하였

다. 따라서, 그에 따른 지배 방정식들인 연속방정식, Navier-Stokes 방정식 및 에너지 방정식은 아래와 같다.

$$\frac{\partial p}{\partial t} + \frac{\partial}{\partial x_j}(\rho u_i) = 0 \quad (1)$$

$$\frac{\partial}{\partial t}(\rho u_i) + \frac{\partial}{\partial x_j}(\rho u_i u_j) = -\frac{\partial p}{\partial x_i} + \frac{\partial}{\partial x_j} \left[ \mu \frac{\partial u_j}{\partial x_i} - \overline{\rho u_i' u_j'} \right] \quad (2)$$

$$\frac{\partial}{\partial t}(\rho T) + \frac{\partial}{\partial x_i}(\rho u_i T) = \frac{\partial}{\partial x_i} \left( \frac{k}{c_p} \frac{\partial T}{\partial x_i} - \overline{\rho u_i' T'} \right) \quad (3)$$

여기서  $x_i$ 는 좌표계이고,  $u_i$ 는 각 방향 속도 성분들이며,  $p$ ,  $\rho$ 와  $\mu$ 는 압력, 유체의 밀도와 점성을 각각 의미한다.

수치해석 기법들로는 속도-압력의 상호 연계 및 전체 해석 절차를 위해 semi-implicit method for pressure-linked equation (SIMPLE) 기법과 유한 체적법을 기반으로 한 2차 공간 이산화 기법이 사용되었다. 해의 수렴 조건은  $10^{-6}$ 으로 설정하였다. 본 연구에서는 3차원 문제를 시뮬레이션하기 위해 소프트웨어 STAR CCM+<sup>(26)</sup>을 사용하였다.

### 2.1.2 해석 영역 및 경계 조건

해석 영역 및 경계 조건이 Fig. 1에 나타내었다. 고정된 직교 좌표계 ( $x$ ,  $y$ ,  $z$ )가 사용되며, 익형




Fig. 1. Schematic of computational domain and boundary conditions

끝이 원점으로 사용된다.  $x$  축은 유입 흐름 방향과 정렬되며,  $y$  축은  $x$  축에 수직이다. 계산 영역의 크기는 15C의 길이와 10C의 높이로 정의된다. 익형 표면은 미끄러짐 없는 경계 조건을 받고, 원방(far-field) 경계는 대칭 조건으로 설정된다. 유입은 자유 스트림 속도로 균일한 흐름을 가하며, 유출은 이류 조건을 받는다. 계산은 1.5C 폭의 NACA 0020 익형 단면 주위의 흐름을 포함하며, Reynolds 수 1,000,000에서 각각 0에서 40까지의 각도에서 수행된다.

### 2.2 격자 시스템 및 검증

계산영역 전체의 격자 시스템을 Fig. 2에 나타내었다. 익형 표면의 최소 격자 간격은 평균값으로  $2 \times 10^{-5}$ 이며, 이는  $y^+ = 1$ 의 벽법칙에 의거한다. 격자 간격은 익형 표면에서의 거리가 증가함에 따라 점점 더 거칠어진다. 본 연구에서 사용된 총 격자 수는 260만이다.

Fig. 3. 에서는 매끄러운 익형의 경우 현재 연구에서 얻은 힘 계수는 Molland 및 Turnock<sup>(22)</sup>의 실험 데이터와 비교되었으며 post stall까지 포함된다. 본 연구에서 얻은 유체력 계수가 Molland 및 Turnock<sup>(22)</sup>의 실험 결과와 잘 일치함을 보여준다. 또한, 본 연구의 파형 익형 유체력 계수는 Kim et al. <sup>(18)</sup>의 계산 결과와도 잘 일치함을 보여준다.




Fig. 2. Grid system of wavy wing

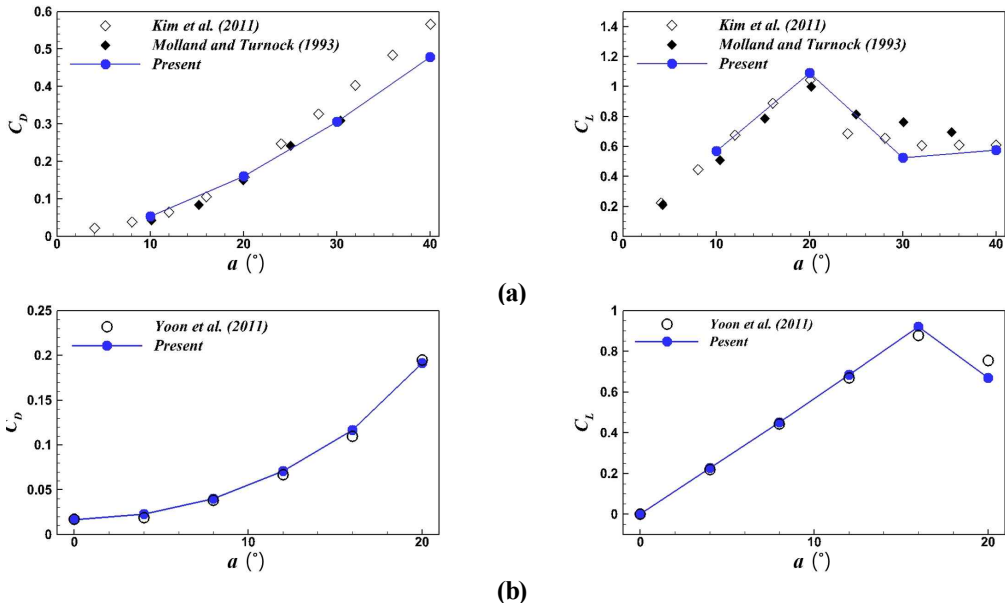


Fig. 3. Drag and lift coefficients of the (a) smooth wing and (b) wavy wing at Re=106

3. 딥러닝 모델 구조 및 데이터 세트

본 연구에 사용된 딥러닝 모델은 DNN과 Decoder 모델로서 두 모델의 일반적인 구조는 Fig. 4과 같다. DNN 모델은 입력층(input layer), 완전연결부(fully connected part)과 출력층(output layer)으로 구성되어 있으며, 입력층으로부터 입력데이터를 받아, 여러 은닉층(hidden layer)으로 구성된 완전연결부를 통해 데이터세트의 특성을 추출한다. 완전연결층을 통해 추출된 특성은 출력층을 통해 예측값을 도출한다.

Decoder 모델의 구조는 익형 표면 및 주위의

유동 및 열전달 특성을 도출하기 위해 완전연결부 이후 디코더부(Decoder part)로 연결된다. 디코더부는 합성곱 전치층(convolution transpose layer)과 역방향 계산 풀링층(upsampling layer)로 구성된다. 각 층들의 활성화 함수(activation function)는 ReLU(rectified linear unit)를 사용하였다.

DNN 모델과 Decoder 모델의 입력데이터는 각 과형 익형의  $AR$ ,  $W_m$ ,  $A_m$  및  $\alpha$  이며, DNN 모델의 출력라벨은 양력, 항력 계수 및  $Nu$  이며, Decoder 모델의 출력라벨은 익형 표면의 압력분포 및 주위 유동장으로 설정하였다. 본 연구에서는 총 940개의 다양한 형상 변수들이 적용된




Fig. 4. Typical layer architectures of (a) DNN and (b) Decoder models

3차원 익형들을 기계학습 데이터 세트로 구성하였고, 해당 데이터는 무작위로 훈련 80%와 테스트 20%로 반영하여 각각 752개와 188개를 각각 활용하였다.

## 4. 결과 및 고찰

### 4.1 DNN 모델과 Decoder 모델의 훈련

DNN 및 Decoder 훈련의 과정은 최적화의 과정과 유사하다. 훈련은 Adaptive Moment estimation (ADAM)<sup>(23)</sup> 및 역전파 알고리즘<sup>(24)</sup>을 사용하여 수행되며, 목적함수는 평균 제곱 오차 (Mean Squared Error, MSE)를 손실함수로 선정하였다. MSE는 다음과 같이 CFD 해석을 통해 얻은 결과와 DNN 및 Decoder 모델을 통해 얻은 예측값의 차이로 정의된다:

$$MSE = \frac{1}{N} \sum_{i=1}^N (\text{Prediction} - \text{True})^2$$

여기서  $\text{Prediction}_i$ 는 훈련 결과,  $\text{True}_i$ 는 CFD 계산 결과를 나타내며  $n$ 은 훈련에 사용되어진 데이터 세트의 개수이다.

두 모델들의 학습 과정에서 신경망 구조 매개변수들의 수렴도에 미치는 영향을 손실함수를 통해 검증하였다.

본 연구에서는 매개변수 중에서 완전연결층의 개수에 따른 영향을 확인하였으며, 완전연결층의 개수를 1에서 9까지 2씩 변화시켰다. 이에 따른 DNN모델은 DNN-1F에서 DNN-9F로 정의하였으며 Decoder 모델의 경우 Decoder-1F에서 Decoder-9F로 정의하였다. 각 모델에 대한 정의와 완전연결층의 개수를 Table 1과 Table 2에 나타내었으며, 손실함수의 수렴도를 Fig. 5에서 확인하였다.

DNN 모델의 경우 DNN-1F 모델을 제외한 다른 모델들의 손실함수 수렴도는 유사한 값으로 수렴하는 것을 Fig. 5(a)에서 확인할 수 있다.

매개변수의 변화에 따른 손실함수 수렴도는 큰 차이가 없으며, 훈련 결과에 영향이 미미함

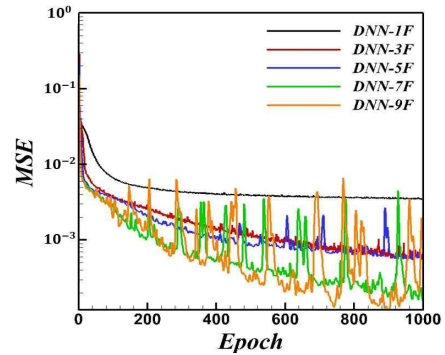
을 확인할 수 있다. 이에 테스트를 위한 모델로 Table 1의 DNN-7F와 Table 2의 Decoder-9F를 선정하였다.

Table 1. Parameters for DNN model

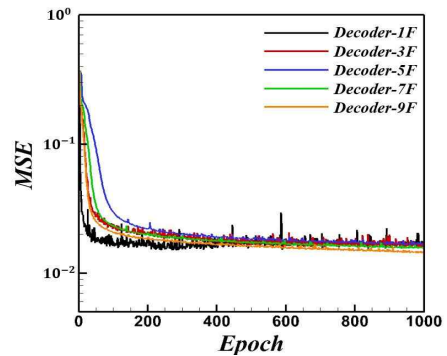
	Fully connected layers
DNN-1F	1
DNN-3F	3
DNN-5F	5
DNN-7F	7
DNN-9F	9

Table 2. Parameters for Decoder model

	Fully connected layers
Decoder-1F	1
Decoder-3F	3
Decoder-5F	5
Decoder-7F	7
Decoder-9F	9



(a)



(b)

Fig. 5. Convergence histories of MSE with different (a) DNN and (b) Decoder model.

### 4.2 유체력 계수와 $Nu$ 수 예측(DNN 모델)

과형 익형 익형 형상의 파라미터 입력에 대한  $C_D/C_L$  및  $Nu$  를 예측하기 위해 188개의 과형 익형 샘플을 이용하여 DNN 모델의 정확도가 평가되었는데, 이는 전체 데이터셋의 약 20%에 해당된다.  $C_D/C_L$  및  $Nu$ 는 각각 익형의 항공 역학적 성능과 열 효율을 평가하는 데 일반적으로 사용된다. CNN 모델에 의해 얻은 예측 결과는 CFD에 의해 계산된 실제 값과 비교하여 Fig. 6 와 같이  $C_D/C_L$  및  $Nu$  의 산점도로 나타내었다. 대부분의 예측된  $C_D/C_L$  및  $Nu$ 는 각각 Fig. 6(a) 및 6(b)에 나타난 것처럼 45도 선의 근처에 군집되어 있는데, 이러한 군집화는 본 연구에서 개발된 DNN 모델로부터 얻은 예측된  $C_D/C_L$  및  $Nu$ 가 CFD에 의해 얻은 실제 값과 유사함을 나타낸다.




Fig. 6. Comparison of true and predicted values, (a)  $C_D/C_L$  and (b)  $Nu$

### 4.3 유동장과 온도장 예측(Decoder 모델)

개발된 Decoder 모델의 유동 및 온도장 예측 성능을 평가하고 선행연구에서 사용한 CNN 및 ED 모델과의 비교를 위해 Kim et al.<sup>(21)</sup>와 동일한 4개의 과형 익형이 고려되었는데, Table 3 과 같이 총 4가지 경우를 고려하여 Decoder 모델의 예측능력을 평가하였다. 이러한 4가지 경우의 Decoder 모델은 2에서 15 까지의 넓은 범위의  $C_D/C_L$ 임을 Fig. 6(a)에서 확인할 수 있다.

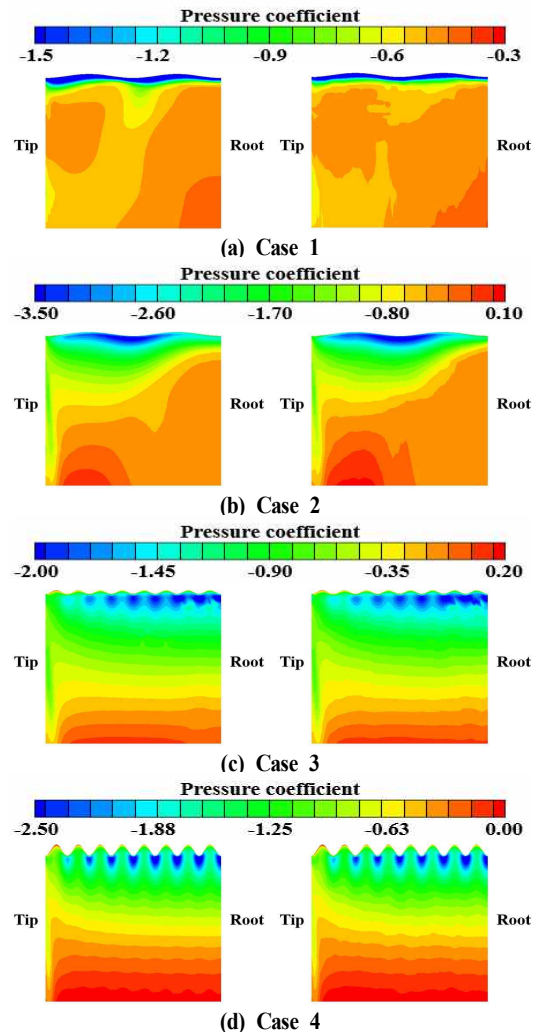


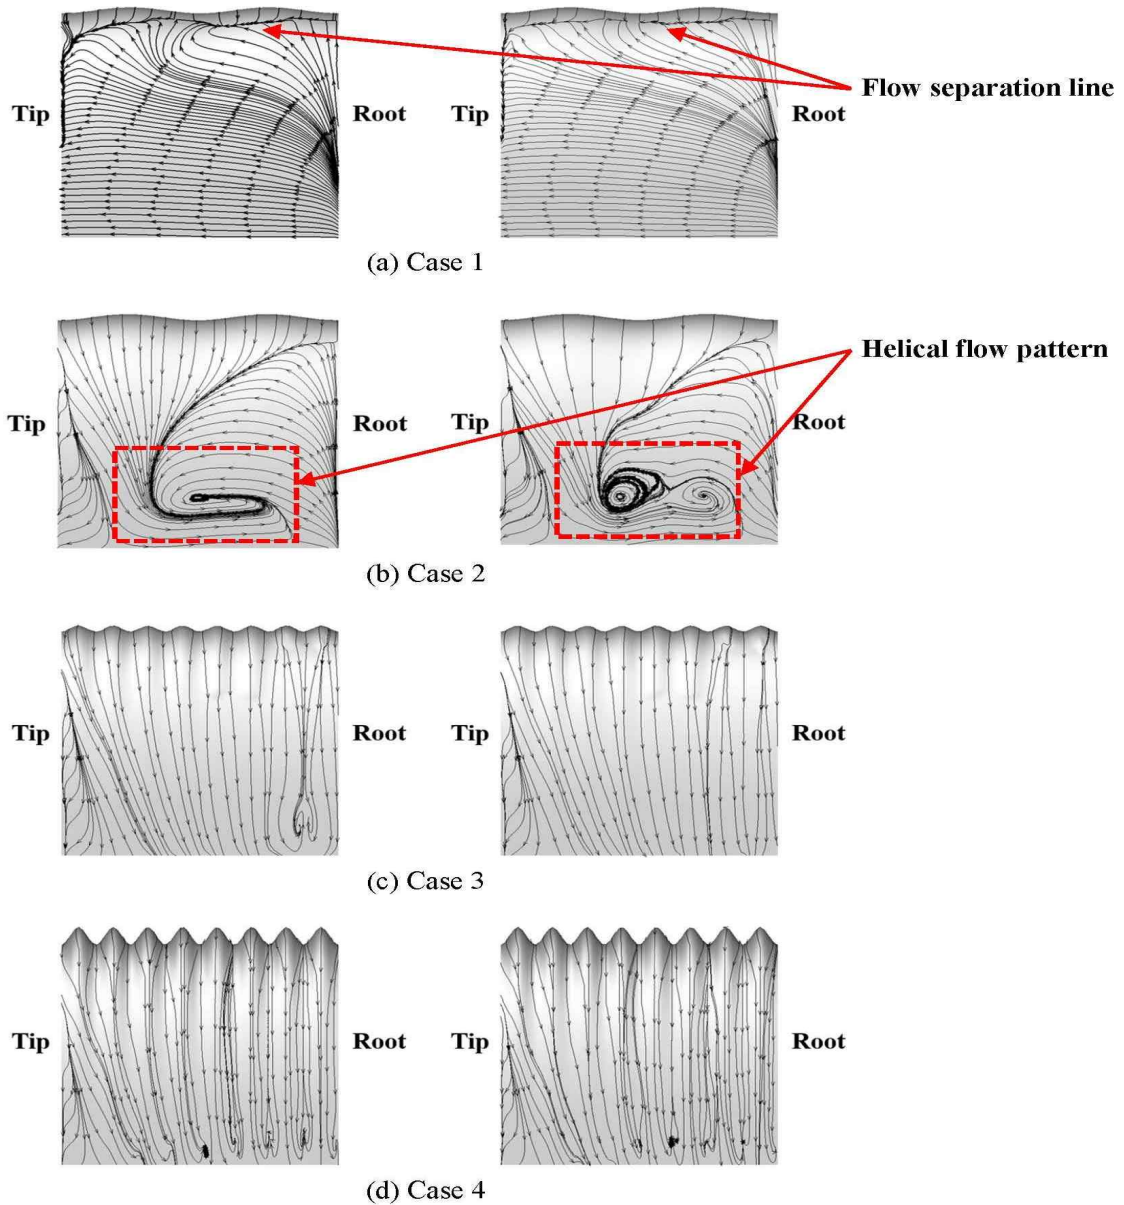
Fig. 7. Contours of pressure coefficient on the upper surface of different wavy wings for true (left column) and Decoder prediction (right column): (a) Case 1, (b) Case 2, (c) Case 3 and (d) Case 4.



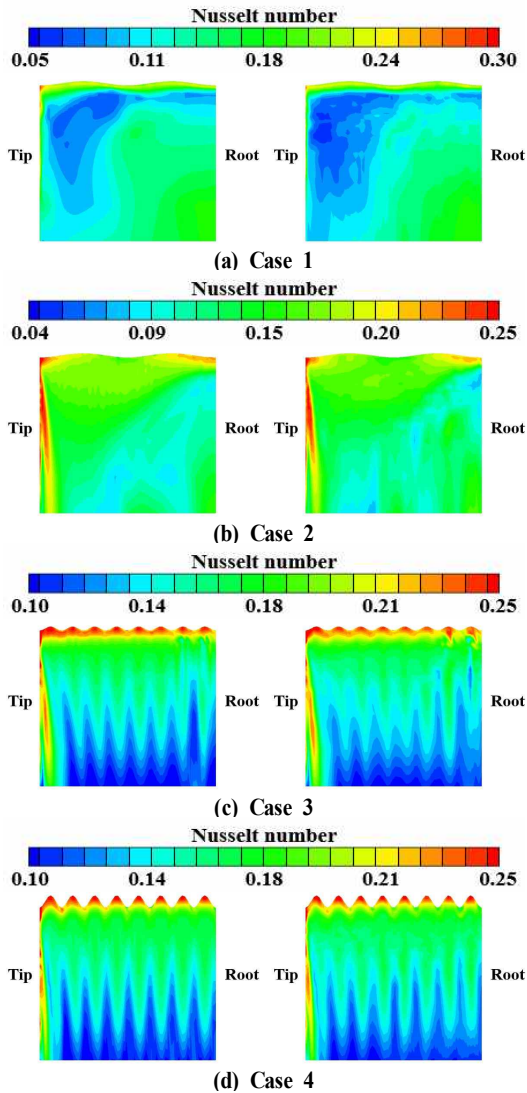
**Table 3.** Geometry parameters of wavy wings (1)

	$\alpha$	$A_m$	$A_m$	$AR$
Case 1	30°	0.0125	2	1.0
Case 2	20°	0.0125	2	2.0
Case 3	10°	0.0125	8	1.5
Case 4	10°	0.0375	8	2.5

Fig. 7 에 나타난 바와 같이, 각 4가지 경우의 서로 다른 파형 익형에 대한 압력 계수 분포의 실제 CFD 결과와 Decoder 예측결과를 비교 하였다. 실제 결과 대비 Contour 경계부근에 Oscillation 이 있기는 하나 파형에 상관없이 각



**Fig. 8.** Limiting streamlines on the upper surface of different wavy wings for true (left column) and Decoder prediction (right column) : (a) Case 1, (b) Case 2, (c) Case 3 and (d) Case 4.



**Fig. 9.** Contours of Nusselt number on the upper surface of different wavy wings for true (left column) and Decoder prediction (right column) : (a) Case 1, (b) Case 2, (c) Case 3, and (d) Case 4.

Case별 실제 CFD 결과와 Decoder 예측결과는 거의 유사한 경향을 나타낸다.

Fig. 8은 각 4가지 경우의 서로 다른 파형 익형에 대한 제한 유속선을 실제 CFD 결과와 Decoder 예측 결과로 비교 검토 하였다. Fig. 7 과 같이 실제 CFD 결과 대비 Decoder 예측 결과가 상당히 유사함을 알 수 있다. 특히, Fig. 8(a) Case 1 및 (b) Case 2 에서 볼 수 있듯이, Zanin et al.<sup>(25)</sup>에서

언급된 spiral 유동으로 인한 박리 지연 현상이 실제 CFD 결과에서도 나타남을 확인하였으며, 그러한 spiral 유동으로 인한 박리 지연 현상이 Decoder 예측 모델에서도 매우 유사하게 잘 예측됨을 알 수 있다. 특히, Fig. 8(a)에서 flow separation, Fig. 8(b)에서 helical nature, Fig. 8(c)와 (d)에서의 small vortex 가 실제 CFD 결과와 거의 유사하게 예측 결과에서도 잘 나타난다.

또한, Fig. 9에서는 각 4가지 경우의 서로 다른 파형 익형에 대한  $Nu$  분포를 실제 CFD 결과 및 Decoder 예측 결과로 비교 검토하였다.

Fig. 9의  $Nu$  분포 예측 결과는 contour 경계 부근에서 oscillation 을 나타내는데, 이는 Fig. 7의 압력장에서 확인한 바와 유사하다.

Fig. 9 (a)-(c)의 leading edge와 root 부근에서 실제 결과와 예측 결과 사이에 약간의 차이가 나타내었으나, Fig. 8(c)와 (d)의 유속선 분포와 같이 trailing edge 부근에서는 Fig. 9(c)와 (d)의  $Nu$  수 분포에서도 실제 결과가 보다 잘 예측되었음을 알 수 있다.

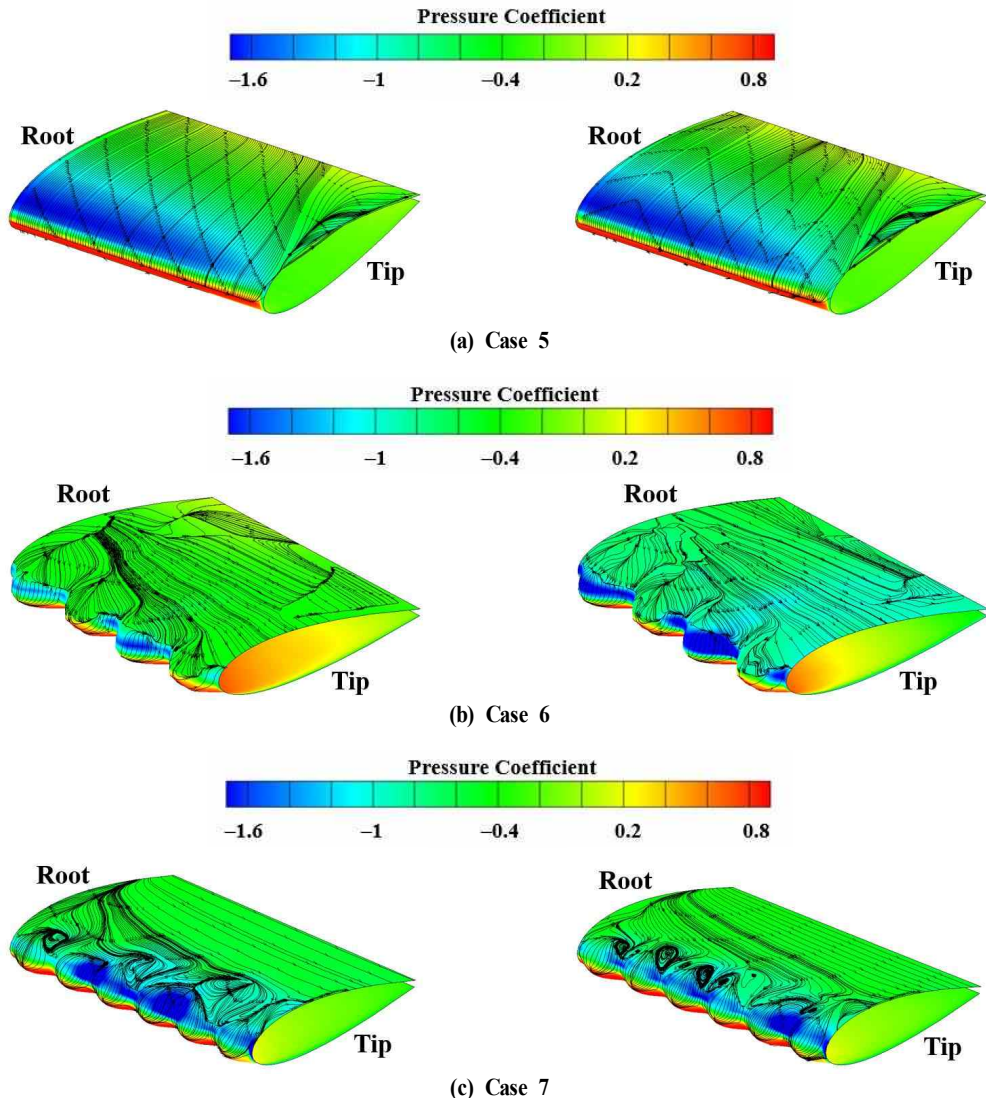
따라서, 각 4가지 경우에 대한 실제 CFD 결과와 Decoder 모델을 통한 결과가 높은 정확도로 거의 유사하게 잘 예측됨을 확인할 수 있다.

Figures. 7-9 에 언급된 4가지 파형 익형 형상의 경우 별 압력 분포, 제한 유속선 분포 및  $Nu$  분포에 대한 CFD 및 Decoder 예측결과 비교에 더하여, 모델의 신뢰도를 추가 확인하기 위해서 Table 4와 같이 Case 5( $AR=1.0$ ,  $\alpha=10^\circ$ ), Case 6( $AR=2.5$ ,  $Am=0.0500$ ,  $Wn=4$  and  $\alpha=40^\circ$ )과 Case 7( $AR=3.0$ ,  $Am=0.0375$ ,  $Wn=6$  and  $\alpha=15^\circ$ ) 등 총 세 가지 경우를 추가 고려하여 Decoder 모델의 예측 능력을 평가하였다.

Fig. 10 은 파형 익형의 압력 계수 및 제한된 유속선의 등고선을 나타내며, 예측된 결과와 실제 유동장을 비교하고 예측된 ED 모델의 유동장 예측 정확성을 검증하기 위한 Decoder 예측 결과를 보여준다.

예측된 결과에서 등고선 경계는 실제에 비해 진동이 나타나지만, 파형 익형을 정의하는 기하학적 매개변수와 관계없이 전반적으로 매우 유사한 압력 분포를 나타낸다.





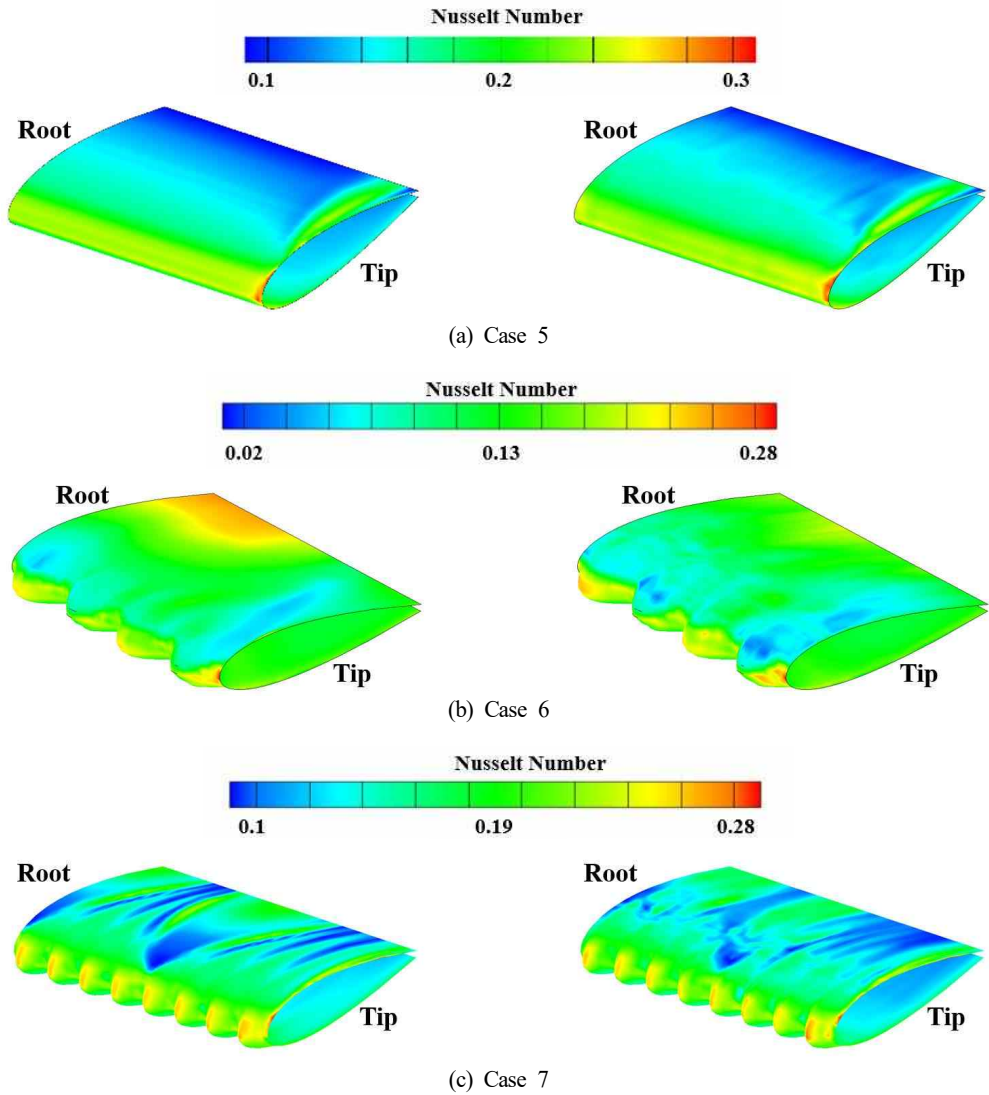
**Fig. 10.** Pressure coefficient and limiting streamlines of true(left column) and Decoder prediction(right column) (a) Case 5, (b) Case 6 and (c) Case 7.

**Table 4.** Geometry parameters of wavy wings (2)

	$\alpha$	$A_m$	$A_m$	$AR$
Case 5	10°	-	-	1.0
Case 6	40°	0.0500	4	2.5
Case 7	15°	0.0375	6	3.0

특히, 압력장에서 Fig. 10(a)의 매끄러운 익형 대비 Fig. 10(b)와 (c)의 파형 익형의 유동 인입부에 약간의 압력 차이가 존재하나 대부분의 영

역에서 CFD 결과와 유사한 예측결과를 나타낸다. 제한된 유속선 분포는 선행 연구 결과와도 일치한다. 결과적으로 파형 매개변수에 관계없이 유동박리, 나선형 특성 및 소용돌이와 같은 제한된 유속선의 특성은 대부분 비슷하게 잘 예측되었음을 확인하였다. 특히, leading edge에서 나선형 유동이 파형 익형에서의 주요한 특징인데 CFD 결과에서도 잘 확인되고 예측결과 또한 잘 나타냄을 확인하였다.



**Fig. 11.** Nusselt number of true(left column) and Decoder prediction(right column) : : (a) Case 5, (b) Case 6 and (c) Case 7.

Fig. 11는 곡형 익형의  $Nu$  에 대한 CFD 결과, 예측 결과를 나타낸다. Fig. 11(a) 매끄러운 익형 대비 Fig. 11(b)와 (c)의 곡형 익형에 대한  $Nu$  에서 CFD 결과와 예측 결과 간에 약간의 차이가 있음을 보여주나 대체적으로 유사한 결과를 나타냄을 알 수 있다.

## 5. 결론

본 연구는 곡형 익형의 항력과 양력을 예측하고, 압력장 및 유속분포의 유동장과  $Nu$  온도장을 예측할 수 있는 DNN 및 Decoder 모델을 확립하였다.

DNN과 Decoder 모델들의 학습 데이터를 구성하기 위하여 곡형 익형 주위의 유동을 3차원, 정상상태, 점성 및 비압축성 가정 하에 총 940개

의 3차원 파형 익형 주위 유동 정보를 얻기 위해 CFD 해석을 수행하였다.

두 모델들의 입력은 각 파형 익형의  $AR$ ,  $W_n$ ,  $A_m$  및  $\alpha$  등의 형상 매개변수 데이터를 동일하게 이용한다. 하지만, 출력 라벨에서 DNN 모델은 항력과 양력을 나타내는 반면, Decoder 모델은 파형 익형 주변의 제한 유속선 분포, 압력 분포 및  $Nu$  분포를 나타낸다. 두 모델들의 학습 과정에서 신경망 구조 매개변수들의 수렴도에 미치는 영향을 손실함수를 통해 검증하였다.

전반적으로, 구축된 Decoder 모델로 예측한 3차원 파형 익형 주위의 압력장과 제한 유속 분포는 CFD 결과들을 매우 잘 재현하였다. 특히, leading edge에서 나선형 유동이 파형 익형에서의 주요한 특징인데 CFD 결과에서도 잘 확인되고 예측결과 또한 잘 나타냄을 확인하였다.

$Nu$  분포를 나타내는 온도장의 경우 또한 CFD 결과와 Decoder 모델 예측결과 간에 약간의 차이가 있음을 보여주나 대체적으로 유사한 결과를 나타냄을 알 수 있다. 그러므로, 이러한 영역에서 Decoder 모델의 예측 정확도 향상을 위해 보다 많은 양질의 데이터 세트를 활용한 훈련이 필요할 것으로 판단되어진다.

본 연구에서는 복잡한 이미지 데이터를 요구하는 기존 CNN 및 ED 모델 대비 sinusoidal 형상과 같이 매개변수가 정형화되는 단순한 형상은 DNN 및 Decoder 모델들을 활용하여 CNN 및 ED 모델과 거의 유사한 수준으로 높은 정확도의 결과를 예측하는 모델을 구축하였다. 특히, Kim et al.<sup>(21)</sup> 고려하지 않은 파형에 의해서 생성되는 유체역학적 특성인 박리를 지연시키는 작은 와도의 존재를 예측하기 위한 모델의 정확도를 높이기 위해서 Kim et al.<sup>(21)</sup>보다 더 많은 데이터 세트를 사용하였다. 그러나, 파라미터를 정의하기 어렵거나 형상 자체가 복잡한 경우에는 CNN 및 ED 모델들이 활용성이 높을 것으로 판단된다.

## 후 기

이 과제는 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.

## REFERENCE

- 1) Watts, Phil, and Frank E. Fish., 2001, "The influence of passive, leading edge tubercles on wing performance." Proc. Twelfth Intl. Symp. Unmanned Untethered Submers. Technol. Durham
- 2) Miklosovic, D. S., et al., 2004, "Leading-edge tubercles delay stall on humpback whale (Megaptera novaeangliae) flippers." Physics of fluids 16.5: L39-L42.
- 3) Fish, FEandlauder, and George V. Lauder., 2006, "Passive and active flow control by swimming fishes and mammals." AnNu. Rev. Fluid Mech. 38: 193-224.
- 4) Van Nierop, Ernst A., Silas Alben, and Michael P. Brenner., 2008, "How bumps on whale flippers delay stall: an aerodynamic model." Physical review letters 100.5: 054502.
- 5) Kim, Mi Jeong, and Hyun Sik Yoon., 2012, "Hydrodynamic characteristics for flow around wavy wings." APS Division of Fluid Dynamics Meeting Abstracts.
- 6) Pérez-Torró, Rafael, and Jae Wook Kim., 2017, "A large-eddy simulation on a deep-stalled aerofoil with a wavy leading edge." Journal of Fluid Mechanics 813: 23-52.
- 7) Chen, Weijie, Weiyang Qiao, and Zuojun Wei., 2020, "Aerodynamic performance and wake development of airfoils with wavy leading edges." Aerospace Science and Technology 106: 106216.
- 8) Wu, Liming, and Xiaomin Liu., 2021, "Dynamic stall characteristics of the bionic airfoil with different waviness ratios." Applied Sciences 11.21: 9943.
- 9) Fan, Menghao, et al., 2022, "Numerical and experimental study on flow separation control of airfoils with various leading-edge tubercles." Ocean Engineering 252: 111046.
- 10) Liu, Jiaqi, et al., 2023, "Deep-learning-based

- aerodynamic shape optimization of rotor airfoils to suppress dynamic stall." *Aerospace Science and Technology* 133: 108089.
- 11) Lou, Jinhua, et al., 2023, "Aerodynamic optimization of airfoil based on deep reinforcement learning." *Physics of Fluids* 35.3.
  - 12) Wu, Ming-Yu, et al., 2023, "Airfoil shape optimization using genetic algorithm coupled deep neural networks." *Physics of Fluids* 35.8.
  - 13) Dussauge, Thomas P., et al., 2023, "A reinforcement learning approach to airfoil shape optimization." *Scientific Reports* 13.1: 9753.
  - 14) Yoon, H. S., Hung, P. A., Jung, J. H., Kim, M. C., 2011, "Effect of the wavy leading edge on hydrodynamic characteristics for flow around low aspect ratio wing" *Comput. Fluids*, 49, 276-289.
  - 15) Seo, J., Yoon, H. S., Kim, M. I., 2022, "Prediction of aerodynamic force coefficients and flow fields of airfoils using CNN and Encoder-Decoder models" *The Korean Society of Visualization*: 94-101.
  - 16) Xu, H. J., et al., 2022, "Bent Pipe Flow Prediction Based on Ultrasound Doppler Velocimetry and Machine Learning." *The Korean Society of Visualization*: 31-32.
  - 17) Chen, H., Weiqi, Q. and Song, W., 2020, "Multiple Aerodynamic Coefficient Prediction of Airfoils Using a Convolutional Neural Network," *Symmetry* 12 (4), 544.
  - 18) Kim, M. J.; Yoon, H. S.; Jung, J. H.; Chun, H. H.; Park, D. W., 2012, "Hydrodynamic characteristics for flow around wavy wings with different wave lengths", *Int. J. Nav. Archit. Ocean Eng.*, 4, 447-459.
  - 19) Duru, C., Alemdar, H. and Baran, Ö. U. 2021, "CNNFOIL: Convolutional encoder decoder modeling for pressure fields around airfoils," *Neural Computing and Applications*, 33(12), 6835-6849.
  - 20) Seo, J., Yoon, H. S., Kim, M. I., 2022, "Establishment of CNN and encoder-decoder models for the prediction of characteristics of flow and heat transfer around NACA sections." *Energies* 15.23: 9204.
  - 21) Kim, M. I., Hyun-Sik Yoon, and Jang-Hoon Seo., 2023, "Deep Learning Models for the Evaluation of the Aerodynamic and Thermal Performance of Three-Dimensional Symmetric Wavy Wings." *Symmetry* 16.1: 21.
  - 22) Molland, A. F., and S. R. Turnock. 1993, "Wind tunnel tests on the influence of propeller loading on ship rudder performance: Four quadrant operation, low and zero speed operation."
  - 23) Kingma, D.P.; Ba, J. Adam, 2015, "A Method for Stochastic Optimization. In Proceedings of the International Conference on Learning Representations (ICLR)", San Diego, CA, USA, 24-28
  - 24) LeCun, Y.; Boser, B.; Denker, J. S.; Henderson, D.; Howard, R. E.; Hubbard, W. 1989, "Jackel, L. D. Backpropagation applied to handwritten zip code recognition.", *Neural Comput.*, 1, 541-551.
  - 25) Zanin, B. Y.; Zverkov, I. D.; Kozlov, V. V.; Pavlenko, A. M., 2008, "Vortex structure of separated flows on model wings at low freestream velocities.", *Fluid Dynamics*, 43, 938-944.
  - 26) Siemens. STAR-CCM+ User Guide Version 16.04; Siemens: New York, NY, USA, 2016.