

합성곱 신경망과 인코더-디코더 모델들을 이용한 익형의 유체력 계수와 유동장 예측

서장훈* · 윤현식[†] · 김민일*

Prediction of aerodynamic force coefficients and flow fields of airfoils using CNN and Encoder-Decoder models

Janghoon Seo*, Hyun Sik Yoon[†] and Min Il Kim*

Abstract The evaluation of the drag and lift as the aerodynamic performance of airfoils is essential. In addition, the analysis of the velocity and pressure fields is needed to support the physical mechanism of the force coefficients of the airfoil. Thus, the present study aims at establishing two different deep learning models to predict force coefficients and flow fields of the airfoil. One is the convolutional neural network (CNN) model to predict drag and lift coefficients of airfoil. Another is the Encoder-Decoder (ED) model to predict pressure distribution and velocity vector field. The images of airfoil section are applied as the input data of both models. Thus, the computational fluid dynamics (CFD) is adopted to form the dataset to training and test of both CNN models. The models are established by the convergence performance for the various hyperparameters. The prediction capability of the established CNN model and ED model is evaluated for the various NACA sections by comparing the true results obtained by the CFD, resulting in the high accurate prediction. It is noted that the predicted results near the leading edge, where the velocity has sharp gradient, reveal relatively lower accuracies. Therefore, the more and high resolved dataset are required to improve the highly nonlinear flow fields.

Key Words : Convolutional Neural Network(합성곱 신경망), Encoder-Decoder(인코더-디코더), Deep Learning(심층 학습), Airfoil(익형), Computational Fluid Dynamics(전산유체역학)

1. 서론

익형은 항공기 날개, 프로펠러와 팬 및 덕트

의 단면, 풍력발전기 블레이드 등의 다양한 분야에 활용되어진다. 또한 층류 영역에서의 익형은 MAV(Micro-air vehicle) 및 생체모방기술 분야에 적용되어진다. 따라서, 익형의 성능으로서 양력과 항력의 예측과 이의 물리적 근거가 되는 유동장의 해석은 매우 중요하다. 이러한 연구를 위해, 최근 인공지능 방법 중 하나인 딥러닝 기술은 CFD와 실험을 대체할 수 있는 대안으로 떠오르고 있다.⁽¹⁾ 따라서 최근에 딥러닝을 활용

[†] 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

하여 익형 주위의 유체역학적 유동특성을 연구한 아래와 같은 선행연구들이 있다.

Yilmaz and German⁽²⁾은 합성곱 신경망(CNN) 모델을 사용하여 1,562개의 익형의 표면 좌표점을 입력 데이터로 그 위치에서의 비점성 기반 압력 계수를 예측하였다. Zhang et al.⁽³⁾은 Yilmaz and German⁽²⁾과 같이 CNN 모델을 사용하였지만, 입력 데이터로는 Yilmaz and German⁽²⁾와는 달리 133개 익형 단면의 이미지를 활용하여 양력 계수를 예측하였다.

Chen et al.⁽⁴⁾은 CNN 모델을 도입하여 입력 데이터(data)로서 300개의 익형 단면 이미지를 활용하였고 대응하는 출력 라벨(label)로 피치 모멘트, 항력과 양력 계수로 구성하였다.

Duru et al.⁽⁵⁾은 Encoder-Decoder(ED) 모델을 이용하여 익형 주위의 압력 계수 분포를 예측하였다. 여기서 ED 모델의 입력 데이터와 출력 라벨은 200개 익형 단면에 대한 거리장 이미지와 익형 주위의 압력 계수 분포로서 각각 구성하였다.

앞서 언급한 선행연구들에서는 익형의 성능만을 예측하거나, 유체의 압력 계수 분포만을 예측하였다. 이에 본 논문에서는 딥러닝 모델을 통해 익형의 항력과 양력 및 성능의 물리적 근거가 되는 유동장에 관련된 압력장과 속도 벡터장을 동시에 예측하고, CFD 해석 결과와 비교를 통해 구축된 딥러닝 모델을 확립하고자 한다.

2. 연구 방법

딥러닝 모델의 훈련(training) 및 테스트(test)의 순서는 다음과 같다. 먼저 NACA 익형 형상을 이용하여 CFD 해석을 수행하고 이를 통해 데이터 세트(dataset)를 준비한다. 스칼라 값을 직접 예측할 수 있는 CNN 모델과 저차원의 값을 고차원의 데이터로 변환할 수 있는 ED 모델을 사용하여, 익형의 항력 및 양력 계수와 익형 주위 압력계수 분포 및 속도장을 각각 훈련 및 예측한다. 데이터 세트를 얻기 위하여 도입되어진 CFD 관련 내용을 아래에 간략히 기술한다.

2.1 CFD 해석을 통한 데이터 세트 구성

2.1.1 지배방정식

본 연구에서는 익형 주위의 유동을 2차원 정상, 비압축성과 층류 유동으로 가정하였다. 따라서, 이에 대응하는 지배방정식들인 연속방정식과 Navier-Stokes 방정식은 아래와 같다.

$$\frac{\partial u_i}{\partial x_i} = 0 \quad (1)$$

$$\frac{\partial}{\partial x_j}(\rho u_i u_j) = -\frac{\partial p}{\partial x_i} + \frac{\partial}{\partial x_j} \left[\mu \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \right] \quad (2)$$

여기서 x_i 는 좌표계이고, u_i 는 각 방향 속도 성분들이며, p , ρ 와 μ 는 압력, 유체의 밀도와 점성을 각각 의미한다.

수치해석 기법들로는 속도-압력의 상호 연계 및 전체 해석 절차를 위해 2차 semi-implicit method for pressure-linked equation (SIMPLE) 기법과 확산항에는 2차 중심 차분 기법이 사용되었다. 해의 수렴 조건은 10^{-6} 으로 설정하였다. 자세한 해석 방법은 STAR CCM+ 매뉴얼⁽⁶⁾에 나타나 있다.

2.1.2 해석 영역 및 경계 조건

익형 형상의 경우 대칭 및 비대칭 NACA 단면이 사용되었으며, 익형 단면의 범위로 두께는 코드 길이(c)의 10%~30%, 최대 캠버는 0%~6% 및 캠버 위치는 0%~9%로 설정하였다. 이에 따라 딥러닝 모델에 총 561개 익형 형상을 사용하였다. 코드 길이는 1로 정의하고 받음각은 0°으로 고정하였다.

해석 영역 및 경계 조건은 Fig. 1에 나타내었으며, 해석 영역의 길이와 높이는 $25c$ 와 $16c$ 로 각각 설정하였다. 경계조건들로 입구와 출구에는 균일류와 대류 경계 조건 ($a\partial u_i/\partial x = 0$)을 각각 부여하였다. 익형 벽면과 원방(far-field)경계에는 점착조건과 대칭조건을 각각 부여하였다.

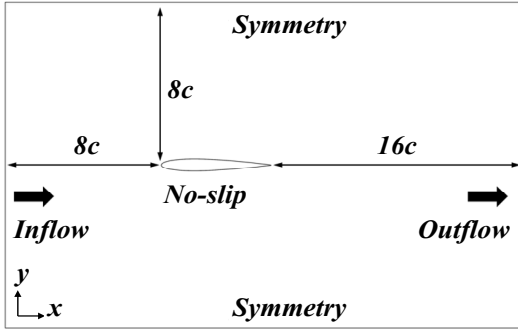


Fig. 1. Schematic of computational domain and boundary conditions

2.2 격자 시스템 및 검증

계산영역 전체의 격자 시스템을 Fig. 2에 나타내었다. 격자 시스템은 속도구배가 큰 익형 주위와 후류 지역에 격자를 집중적으로 분포시켰다. 더불어 경계층의 첫 번째 격자 크기는 $0.002c$ 로 설정하였으며, 무한원방으로 향할수록 격자의 크기는 점차 증가하도록 설정하였다.

그리고 딥러닝 모델 훈련을 위한 해석 조건으로 레이놀즈 수($Re = U_{\infty}c\rho/\mu$)는 1,000으로 정하였다.

격자 수에 따른 해석 결과의 영향을 확인하고자 격자 의존성 검토를 수행하였으며 그 결과를 Table 1에 나타내었다. 격자 시스템에 따른 항력 계수 차이는 1%이하이며, 본 연구에서는 중간 크기의 격자 시스템을 사용하였다.

본 연구에서 사용되어지는 수치해석기법들을 검증하기 위해 NACA 0012의 결과를 고려하였다. 받음각 0° 와 10° 조건에서 본 연구에서 얻은 항력




Fig. 2. The grid system of the airfoil section

Table 1. Grid dependency test for NACA 0012 at $\alpha = 0^{\circ}$.

Case	Number of grids	C_D	Difference (%)
Coarse	58,006	0.1253	-0.31
Medium	128,201	0.1256	
Fine	192,302	0.1257	0.24

Table 2. Comparison of force coefficients with previous data for the NACA 0012 at $\alpha = 0^{\circ}$ and 10°

Case	$\alpha(^{\circ})$	C_D	C_L
Kurtulus ⁽⁷⁾	0	0.1207	0.0
Present		0.1256	0.0
Difference (%)		3.9	0.0
Kurtulus ⁽⁷⁾	10	0.1649	0.4173
Present		0.1682	0.4123
Difference (%)		2.0	-1.2

과 양력 계수들을 선행연구의 결과⁽⁷⁾들과 Table 2에서 비교하였으며, 두 결과가 비교적 잘 일치함을 확인하였다.

3. 딥러닝 모델 구조 및 데이터 세트

CNN 모델은 딥러닝의 대표적인 모델 중 하나이며 주요 특징은 합성곱 층을 이용하여 입력 데이터의 주요 특징을 추출하고 출력 라벨의 관계를 훈련하는 것이다. 이와 더불어 ED 모델은 고차원 데이터를 저차원 데이터로 변경하는 인코더와 저차원 데이터를 고차원 데이터로 변경하는 디코더로 구성된다.

본 연구에 사용된 CNN 모델과 ED 모델들의 구조를 Fig. 3에 나타내었다. CNN 모델은 Fig. 3(a)와 같이 익형 이미지를 입력 데이터로 합성곱 층(Convolution layer) 과 밋 풀링 층 (Pooling layer) 연산을 거쳐 완전 연결 층(Fully connected layer)에 이어지도록 설계되었다.

ED 모델의 구조는 Fig. 3(b)에 나타난 바와 같이, 입력 데이터에서부터 합성곱 층 연산을 통해 완전 연결 층에 이어지며, 이어서 합성곱 전치 층(Convolution transpose layer) 연산을 통해 출력 층으로 연결되도록 설계되었다. 각 층들의 활성화 함수는 rectified linear unit을 사용하였다.

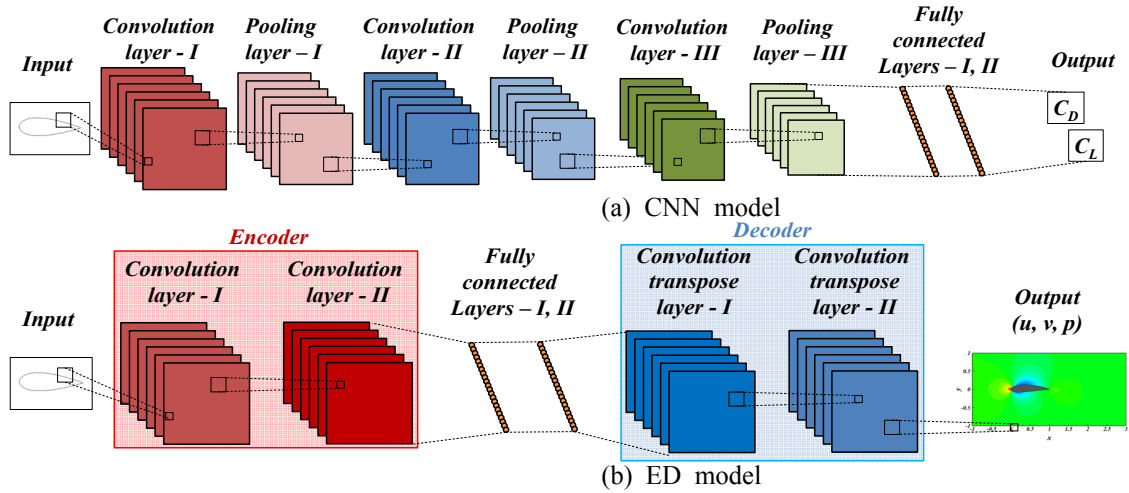


Fig. 3. Typical layer architectures of CNN and ED models

CNN 모델 및 ED 모델에 대한 보다 자세한 내용은 선행 연구를 통해 확인할 수 있다^(4,5).

본 연구에서는 딥 러닝의 데이터 세트를 총 561개의 NACA 단면들로 구성하였고, 훈련과 테스트에 471개와 90개를 각각 활용하였다.

4. 결과 및 고찰

4.1 CNN 모델과 ED 모델의 훈련

훈련 프로세스의 수렴 정도를 검토하고자 훈련 진행동안의 손실함수를 확인하였다. 본 연구에서 손실함수는 전체 평균 제곱 오차(Mean Square Error, MSE)로 정의하였다. 각 익형의 항력과 양력 계수 및 유동장 값에 대한 평균 제곱 오차를 모두 반영한 전체 평균 제곱 오차로 정확도를 확인하였다.

$$MSE = \frac{\sum_{i=1}^n (Prediction_i - True_i)^2}{n} \quad (3)$$

여기서 *Prediction*는 훈련 결과, *True*는 CFD 계산 결과를 나타내며 *n*은 훈련에 사용되어진 데이터 세트의 개수이다.

두 모델들의 학습 과정에서 신경망 구조 매개 변수들의 수렴도에 미치는 영향을 손실함수를

통해 검증하였다. 매개변수는 Table 3과 Table 4와 같이 변경하며 손실함수의 수렴도를 Fig. 4에서 확인하였다.

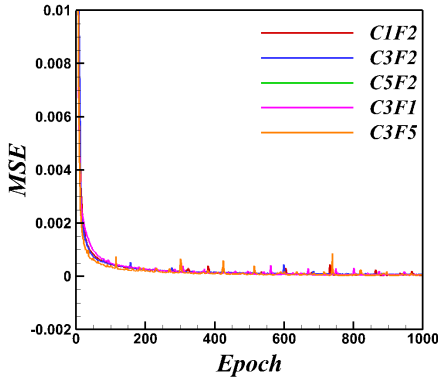
매개변수의 변화에 따른 손실함수 수렴도는 큰 차이가 없으며, 훈련 결과에 영향이 미비함을 확인할 수 있다. 이에 테스트를 위한 모델로 Table 3의 C3F2와 Table 4의 ED2F2을 선정하였다.

Table 3. Parameters for CNN model

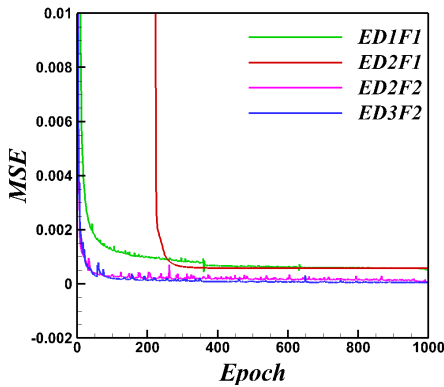
	Convolution layers	Fully connected layers
C1F2	1	2
C3F2	3	2
C5F2	5	2
C3F1	3	1
C3F5	3	3

Table 4. Parameters for ED model

	Convolution & Convolutional transpose layers	Fully connected layers
ED1F1	1	1
ED2F2	2	1
ED2F2	2	2
ED3F2	3	2



(a)



(b)

Fig. 4. Convergence histories of loss function with different hyperparameters, (a) CNN model and (b) ED model

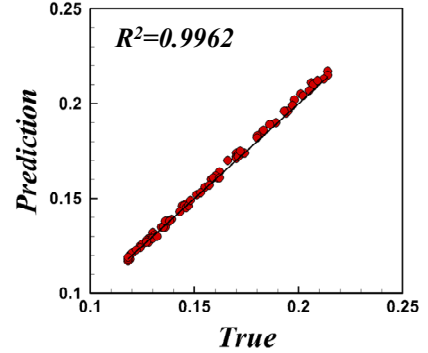
4.2 CNN 모델 테스트

훈련을 통해 구축된 CNN 모델의 예측 정확도를 평가하기 위하여 일반적으로 거치는 테스트를 수행하였다.

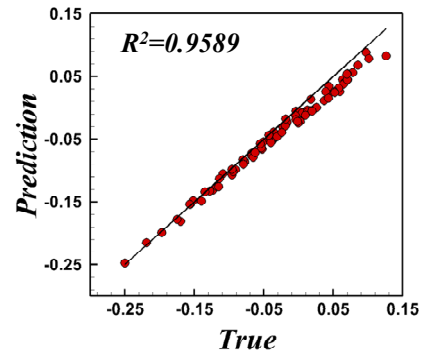
테스트에 사용되어진 90개의 NACA 단면들의 항력과 양력 계수들로 구축된 CNN 모델로 예측되어진 값(Prediction)과 CFD 결과 값(True)을 Fig. 5에 나타내었다.

또한, 테스트의 평균 정확도 평가를 위해 아래 식(4)과 같이 정의되어지는 결정계수 (Coefficient of determination, R^2)를 Fig. 5에 추가하였다.

$$R^2 = \frac{\sum_{i=1}^n (\text{Prediction}_i - \text{True}_i)^2}{\sum_{i=1}^n (\text{True}_i - \overline{\text{True}})^2} \quad (4)$$



(a)



(b)

Fig. 5. Comparison of true and predicted values, (a) C_D and (b) C_L

여기서 $True$ 는 CFD 결과값들의 평균이다.

항력과 양력 값들의 결정계수들은 모두 1에 근접한 0.95이상으로 나타났으며, CFD 결과 값과 CNN 모델 예측 결과들의 높은 상관 관계를 보이는 것을 Fig. 5에서 확인할 수가 있다. 이는 본 연구에서 구축되어진 CNN모델의 높은 신뢰도를 반영한다.

4.3 ED 모델 테스트

훈련을 통해 확립된 ED 모델의 예측 정확도를 평가하기 위하여 앞서 CNN 모델의 테스트에 사용되어진 동일한 90개의 데이터 세트를 활용하였다. 테스트 데이터 중 익형의 성능에 영향을 주는 주요 인자인 익형 두께와 최대 캠버가 서로 다른 단면들인 NACA 2530, 2914, 5512와 6930에 대해 확립된 ED 모델을 통해 얻은 압

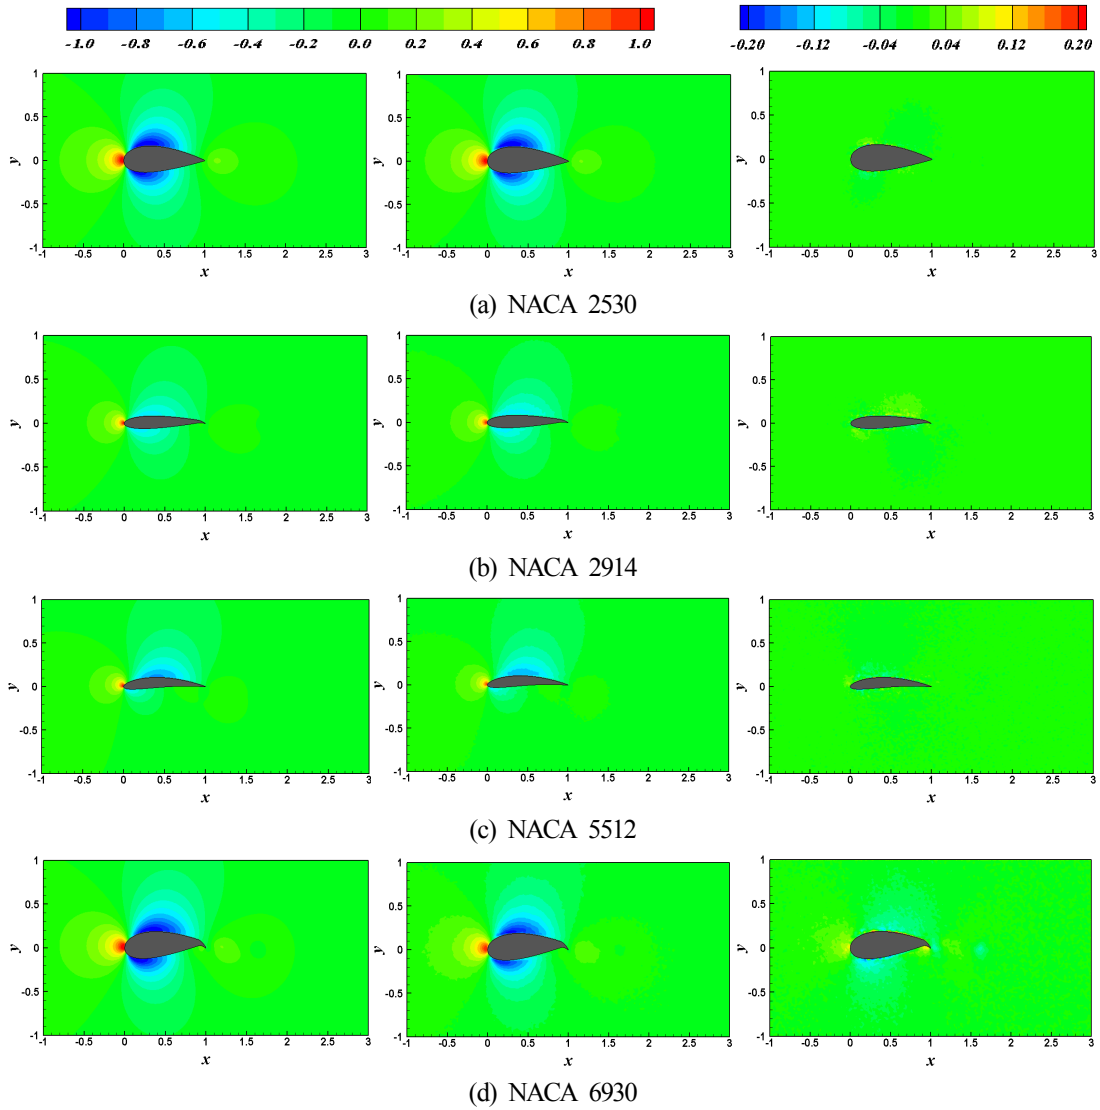


Fig. 6. Contours of pressure coefficient in the x - y plane for true values (left column), predicted values (center column) and error values (right column) for different NACA sections




Fig. 7. Typical instantaneous velocity vector fields in the x - y plane with black filled arrows for true values and red hollowed arrows for predicted values for different NACA sections

력장과 속도 벡터장의 예측 결과와 CFD 결과 (True)를 Fig. 6과 Fig. 7에서 각각 비교하였다.

전반적으로 ED 모델로 예측되어진 두 단면 주위의 압력 계수의 분포들은 CFD 결과와 유사함을 Fig. 7에서 확인할 수가 있다. 각 단면에서 선단에서의 높은 압력과 비대칭으로 인한 압력 면과 흡입면에서 압력차이 뿐만 아니라, 두께 차이에 의한 압력 분포의 차이도 ED 모델 이 CFD 결과를 잘 재현하고 있다. 이러한 두 결과 들의 유사성은 ED 모델 예측 값과 CFD 결과 값을 차이를 보여주는 Fig. 6의 오차 분포에서도 확인할 수가 있다.

Fig. 6(d)를 통해, ED 모델 예측값과 CFD 결과 값을 차이가 상대적으로 큰 영역이 앞전 주위의 흡입면과 압력면임을 확인할 수가 있다. 잘 알려진 바와 같이, 이들 영역에서는 큰 속도 구배로 인해 상대적으로 급격한 압력 구배가 형성되어진다. 이러한 결과로부터, ED 모델의 경우 비선형 유동이 강한 영역에서는 예측값이 정확도가 상대적으로 낮을 수가 있는 것으로 추정되어진다. 따라서, 이러한 영역에서 ED 모델의 예측 정확도의 향상을 위해 보다 많은 양질의 데이터 세트를 활용한 훈련이 필요할 것으로 판단되어진다.

앞선 Fig. 6의 압력 계수 분포에서 언급한 바와 같이, 두 단면 모두 급격한 속도 구배가 발생하는 앞전 주위의 흡입면과 압력면에서 ED 모델 결과와 CFD 결과들이 미세한 차이를 보이고, 나머지 영역들에서는 매우 유사하기에 벡터가 거의 겹쳐져서 차이를 식별하기 어려운 것을 Fig. 7에서 확인할 수가 있다.

5. 결론

본 연구는 인공지능망을 활용하여 익형의 성능 평가 지표로 활용되는 항력과 양력을 예측할 수 있는 CNN 모델을 구축하였다. 특히, 익형의 성능의 물리적 근거가 되는 유동장과 관련된 압력장과 속도 벡터장을 예측할 수 있는 ED 모델을 확립하였다.

CNN과 ED 모델들의 학습 데이터를 구성하

기 위하여 익형 주위의 유동을 2차원, 정상상태, 점성 및 비압축성 가정 하에 총 561개의 NACA 단면들 주위 유동 정보를 얻기 위해 CFD 해석을 수행하였다.

두 모델들의 입력은 이미지를 동일하게 사용하지만, 출력 라벨로는, CNN 모델은 항력과 양력 값들을 사용하고, 반면 ED 모델은 익형 주변의 속도 벡터장과 압력 분포를 사용한다. 두 모델들의 학습 과정에서 신경망 구조 매개변수들의 수렴도에 미치는 영향을 손실함수를 통해 검증하였다. 또한, 결정계수들이 1에 근접하는 구축된 모델의 높은 예측 정확도를 테스트를 통해 검증하였다. 전반적으로, 구축된 ED 모델로 예측한 익형 주위의 속도장과 압력 분포는 CFD 결과들을 매우 잘 재현하였다.

하지만, 큰 속도 구배가 발생하는 영역에서는 ED 모델 예측값과 CFD 결과 값의 다소 차이가 있었다. 즉, 비선형 유동이 강한 영역에서는 ED 모델의 예측값의 정확도가 다소 낮을 수 있을 것으로 추정되어진다. 따라서, 이러한 영역에서 ED 모델의 예측 정확도의 향상을 위해 보다 많은 양질의 데이터 세트를 활용한 훈련이 필요할 것으로 판단되어진다.

본 연구에서 CNN 및 ED 모델의 훈련 및 테스트에 사용된 시간은 CFD 해석 시간에 비해 약 5배 가량 적게 소요되었다. 이는 적절히 훈련된 딥러닝 모델을 이용 시, 설계 초기 단계에서 여러 익형 단면들의 유체역학적 특성 비교 및 설계 조건 선정을 위한 시간을 절약할 수 있을 것으로 판단된다.

후 기

이 과제는 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.

REFERENCE

- 1) Swingler, K., 1996, "Applying neural networks: a practical guide," Morgan Kaufmann.
- 2) Yilmaz, E. and German, B., 2017, "A convolutional

neural network approach to training predictors for airfoil performance,” In 18th AIAA/ISSMO multidisciplinary analysis and optimization conference, 3660.

- 3) Zhang, Y., Sung, W. J. and Mavris, D. N., 2018, “Application of convolutional neural network to predict airfoil lift coefficient,” In 2018 AIAA/ASCE/AHS/ASC structures, structural dynamics, and materials conference, 1903.
- 4) Chen, H., Weiqi, Q. and Song, W., 2020, “Multiple Aerodynamic Coefficient Prediction of Airfoils Using a Convolutional Neural Network,” *Symmetry*, Vol.12(4), pp.544.
- 5) Duru, C., Alemdar, H. and Baran, Ö. U. 2021, “CNNFOIL: Convolutional encoder decoder modeling for pressure fields around airfoils,” *Neural Computing and Applications*, Vol.33(12), pp.6835-6849.
- 6) Siemens, 2018. STAR CCM+ User Guide.
- 7) Kurtulus, D.F., 2015, “On the unsteady behaviour of the flow around NACA 0012 airfoil with steady external conditions at $Re=1000$,” *Int. J. Micro Air Veh.*, Vol.7(3), pp.301-326.