

이미지 데이터를 이용한 익형 매개변수화 및 공력계수 예측을 위한 인공지능 모델 연구

이승훈^{*.1} · 김보라^{**1,2} · 이정훈^{***1} · 김준영^{****3} · 윤민^{†.1,2}

Study of an AI Model for Airfoil Parameterization and Aerodynamic Coefficient Prediction from Image Data

Seung Hun Lee^{*.1}, Bo Ra Kim^{**1,2}, Jeong Hun Lee^{***1}, Joon Young Kim^{****3}, and Min Yoon^{†.1,2}

Abstract The shape of an airfoil is a critical factor in determining aerodynamic characteristics such as lift and drag. Aerodynamic properties of an airfoil have a decisive impact on the performance of various engineering applications, including airplane wings and wind turbine blades. Therefore, it is essential to analyze the aerodynamic characteristics of airfoils. Various analytical tools such as experiments, computational fluid dynamics, and Xfoil are used to perform these analyses, but each tool has its limitation. In this study, airfoil parameterization, image recognition, and artificial intelligence are combined to overcome these limitations. Image and coordinate data are collected from the UIUC airfoil database. Airfoil parameterization is performed by recognizing images from image data to build a database for deep learning. Trained model can predict the aerodynamic characteristics not only of airfoil images but also of sketches. The mean absolute error of untrained data is 0.0091.

Key Words : Airfoil (익형), Aerodynamic characteristics (공력특성), Image processing (이미지처리), Deep learning (심층학습), Airfoil parameterization (익형 매개변수화)

† Corresponding Author, Assistant Professor
E-mail: minyoon@kmou.ac.kr

¹ Department of Mechanical Engineering, Korea Maritime and Ocean University, Busan 49112

² Interdisciplinary Major of Ocean Renewable Energy Engineering, Korea Maritime and Ocean University, Busan 49112

³ Department of Ocean Advanced Materials Convergence Engineering, Korea Maritime and Ocean University, Busan 49112

* Master's student

** Ph.D. student

*** Master's Degree Researcher

**** Professor

1. 서론

익형(airfoil)은 주변 공기 흐름을 이용하여 낮은 항력 대비 높은 양력을 생성하는 물체이다. 익형은 비행기의 상승과 제어, 풍력 터빈의 회전에 필수적인 역할을 하며, 비행기 날개, 헬리콥터 로터 블레이드, 풍력 터빈 블레이드 등 여러 공학 어플리케이션에 적용된다. 익형의 형상과 크기는 양력과 항력을 결정하는 중요한 요소이다. 이러한 요소들은 많은 유체 기계의 성능에 결정적인 영향을 미친다. 양력 계수(C_L)와 항력 계수(C_D)를 결정하

는데 있어서, 대표적으로 풍동을 이용한 실험적 방법이 있다. 그러나 실험적 접근법인 풍동은 몇 가지 제한적인 측면을 가지고 있다. 첫째, 상당한 비용과 시간을 필요로 한다. 둘째, 풍동에서 사용되는 모델은 실제 형상보다 작아 상사성 문제를 야기할 수 있다. 셋째, 실제 운전 조건을 완벽하게 재현할 수 없다. 이러한 제한 때문에 실험적 방법에 대안적인 연구 방법이 필요하다.

이러한 문제들을 해결하기 위한 여러 가지 방법 중 하나는 전산유체역학(computational fluid dynamics; CFD)을 사용하는 것이다. CFD는 익형에 대한 공기 흐름과 그 효과를 수치적으로 해석하는데 사용된다. 하지만 CFD는 복잡한 계산을 필요로 하며 모델링 오류와 수치 불안정성을 초래할 수 있다. CFD는 고성능 컴퓨팅 자원을 필요로 하며 사용자의 전문 지식을 요구한다.

위와 같은 단점들을 해결하기 위해 Drela⁽¹⁾는 이론 및 수치해석 방법을 사용하여 Xfoil을 개발하였다. Xfoil은 패널기법(panel method) 및 경계층 이론을 사용하여 익형의 공력 특성을 분석할 수 있다. Xfoil을 활용한 공력 해석 프로그램으로는 XFLR5⁽²⁾이 있다. XFLR5는 Xfoil의 설계 및 해석의 장점을 기반으로 3D 패널기법을 적용한 공력 해석 프로그램이다. 하지만, Xfoil은 입력 데이터로 정규화된 익형의 좌표 데이터를 필요로 하고, 낮은 레이놀즈 수 유동에서는 잘 작동하지만, 높은 레이놀즈 수 유동에서는 정확도가 떨어진다. 또한, 특정 익형에서는 수렴을 하지 않으며 이러한 오류를 사용자에게 알려주지 않는다^(3,4).

딥러닝(deep learning)은 인공 신경망을 기반으로 한 머신 러닝의 한 분야로, 복잡한 패턴이나 관계를 학습하는 데 효과적이다. 딥러닝 모델은 대량의 데이터와 높은 계산력을 필요로 하지만, 이를 통해 높은 예측 성능을 달성할 수 있다. 따라서, 매개변수화(parameterization)된 익형 데이터를 입력으로 사용하고, 양력 계수와 항력 계수를 출력으로 예측하는 딥러닝 모델을 학습하는 것이 가능하다. 최근 실험과 CFD, Xfoil 등의 단점을 보완하고자, 익형과 인공지능을 융합한 여러 연구들이 진행되고 있다.

Kim 등⁽⁵⁾은 CNN(convolutional neural network)

모델을 활용하여 세 가지 익형의 여러 받음각(angle of attack), 레이놀즈 수(Reynolds number)에 대해 익형의 주변 유동장 및 공력 특성을 예측 연구를 수행하였다. Seo 등⁽⁶⁾ 역시 CNN 모델을 활용하여 560가지의 익형에 대해 공력 특성을 예측하는 연구를 수행하였다. 이와 같이 익형의 공력 특성을 딥러닝을 활용하여 예측하는 연구의 경우 대부분이 CNN 모델을 활용하는데 이는 정규화된 익형의 이미지 혹은 데이터를 요구하는 한계가 있다.

본 연구에서는 이러한 한계를 극복하고자 이미지 인식과 인공지능을 결합하여 익형을 매개변수화하고, 이를 바탕으로 C_L , C_D 값을 예측하는 새로운 방법론을 제시한다. 이 방법론은 익형 설계와 분석에 새로운 시각을 제공하며, 기존의 방법론을 보완하여 효율적인 익형의 공력 특성 분석을 가능하게 한다.

2. 이론적 배경

2.1 익형의 공력특성

익형에서는 공기 흐름 내부에서 받음각에 따른 압력의 변화로 인해 익형의 상부와 하부에서 속도 차이가 발생한다. 익형의 압력 차이는 유동 방향인 항력과 유동과 수직인 방향인 양력 두 개의 주요 성분으로 나누어진다. 양력과 항력은 공기 흐름에 대하여 익형의 시위선(chord line)이 갖는 각도인 받음각에 따라 변하게 된다.

$$C_L = \frac{F_L}{0.5\rho V^2 A} \quad (1)$$

식 (1)은 양력 계수(C_L)의 식으로 익형의 상부 및 하부에서 발생하는 압력 차로 공기 흐름의 방향에 수직인 힘(F_L)을 무차원한 것이다. 여기서 ρ 는 유체 밀도, V 는 유체 속도, A 는 평면적이다.

$$C_D = \frac{F_D}{0.5\rho V^2 A} \quad (2)$$

식 (2)는 항력 계수(C_D)로 물체가 유체의 흐름을 가질 때 저항하는 힘(F_D)을 무차원한 것이다. 항력은 표면에서의 점성 마찰력과 압력에 의한 영향으로 나눌 수 있다.

2.2 이미지 인식과 OpenCV

이미지 인식은 컴퓨터 비전의 핵심 분야로, 디지털 이미지에서 객체나 특징을 자동으로 식별하는 기술을 의미한다. 이는 디지털 이미지를 분석하여 특정 패턴이나 특징을 찾아내는 과정을 포함한다. 이미지 인식은 머신 러닝 알고리즘을 사용하여 학습 데이터를 기반으로 패턴을 학습하고, 이를 통해 새로운 이미지에서 객체나 특징을 인식한다.

OpenCV는 이러한 이미지 인식 작업을 수행하는 데 사용되는 주요 도구 중 하나이다. OpenCV는 다양한 이미지 처리 기능을 제공하며, 이를 통해 이미지에서 객체를 인식하고 분석하는 데 필요한 작업을 수행할 수 있다. OpenCV의 기능은 이미지 필터링, 기하학적 변환, 객체 추적, 스테레오 비전, 기계 학습 등 다양한 분야에 걸쳐 있다⁽⁷⁾.

OpenCV는 이미지를 gray scale로 변형하고, thresh hold를 진행한 후 남은 개체 중 끊어지지 않은 닫힌 개체를 하나의 개체로 인식하는 방식으로 해당 개체의 크기, 위치 등의 값을 활용할 수 있다. 따라서, OpenCV는 익형 이미지를 인식하고 매개변수화 하는 데 중요한 도구로 사용될 수 있다. 익형 이미지를 인식하면, 인식된 이미지의 특징을 parameter로 변환하여 이를 인공지능 모델의 입력 값으로 사용할 수 있다

2.3 익형 매개변수화

익형 매개변수화는 익형의 형상을 수학적으로 표현하는 과정이다. 이는 익형의 특성을 분석하고, 최적화하고, 디자인하는 데 중요한 방식이다. 매개변수화는 익형의 특정 특성을 캡처하고 이를 수치로 표현하는 것을 포함한다. 이러한 특성은 익형의 두께, 곡률, 각도 등이 포함될 수 있다.

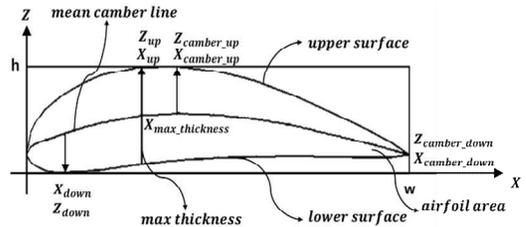


Fig. 1. Airfoil parameterization

본 연구에서는 OpenCV를 활용한 이미지 인식을 통해 Fig. 1에 나타난 익형의 이미지에서 익형의 upper surface와 lower surface의 길이 비율, Z값이 가장 큰 X좌표(X_{up}), 가장 작은 X좌표(X_{down}), max thickness의 위치($X_{max_thickness}$)와 길이 camber line 중 Z값이 가장 큰 X좌표(X_{camber_up})와 upper surface와 camber까지의 거리(Z_{camber_up}), camber line 중 Z값이 가장 작은 X좌표(X_{camber_down})와 lower surface와 camber까지의 거리(Z_{camber_down}), 익형의 가로세로 비율, 면적, 둘레를 parameter로 선정하여 총 11개의매개변수화를 진행한다.

이미지에서 인식된 익형의 camber 길이를 1이라고 고정하고 연구를 수행하였기 때문에, parameter의 값들은 모두 비율로 선정했다.

2.4 딥러닝

딥러닝은 인공 신경망에 기반한 머신러닝의 한 분야로, 컴퓨터가 데이터로부터 학습하고 패턴을 인식하는 능력을 향상시키는 데 사용된다. 이는 다양한 층을 가진 신경망을 통해 복잡한 패턴을 모델링하고, 이를 바탕으로 예측, 분류, 추천 등의 작업을 수행할 수 있다.

딥러닝의 기본 구성 요소는 퍼셉트론(perceptron)이다. 퍼셉트론은 가장 간단한 형태의 인공 신경망으로, 입력과 가중치를 곱하고, 이를 모두 더한 후 활성화 함수를 통과시켜 출력을 생성한다. 퍼셉트론의 출력은 다음과 같이 계산된다⁽⁸⁾.

$$y = f(\sum_i \omega_i x_i + b) \tag{3}$$

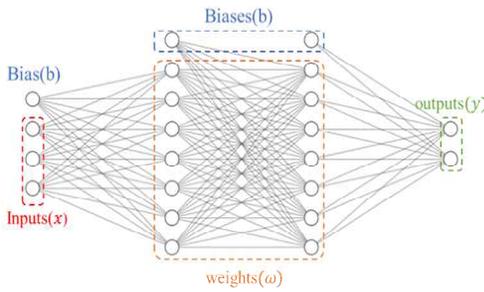


Fig. 2. Multilayer perceptron

식 (3)은 퍼셉트론의 출력에 관한 식으로의 f 는 활성화함수, ω_i 는 가중치, x_i 는 입력, b 는 편향이다. Fig. 2은 식 (3)의 다층 퍼셉트론을 그림으로 나타낸 것이다.

딥러닝 모델의 학습 과정에서는 오류 역전파(backpropagation) 알고리즘이 중요한 역할을 한다. 오류 역전파는 출력층에서 발생한 오차를 입력층 방향으로 전파시키면서 각 층의 가중치를 업데이트하는 방법이다. 이를 통해 모델은 학습 데이터셋에서 복잡한 관계와 패턴을 학습하고, 이를 바탕으로 새로운 데이터에 대한 예측을 생성한다.

본 연구에서는 익형 매개변수화를 수행한 값

을 입력으로하여, Xfoil을 통해 계산한 양항력 값을 출력으로 예측하는 딥러닝 모델을 구성했다.

2.5 Hyperopt

Hyperopt는 머신러닝 모델의 하이퍼파라미터 최적화를 위한 Python 라이브러리이다. 하이퍼파라미터는 머신러닝 모델의 성능에 큰 영향을 미치는 변수들로, 이들의 최적값을 찾는 것은 모델의 성능을 크게 향상시킬 수 있다⁽⁹⁾.

Hyperopt는 베이지안 최적화파라미터의 최적값을 찾는다. 베이지안 최적화(Bayesian optimization) 방법을 사용하여 하이퍼파라미터에 대한 목표 함수의 값이 어떤 분포를 따르는지를 모델링하고, 이를 바탕으로 목표 함수의 값을 최소화하는 하이퍼파라미터의 값을 찾는다⁽¹⁰⁾.

3. 결과 및 고찰

3.1 학습조건

UIUC airfoil database⁽¹¹⁾에 있는 모든 익형 데이

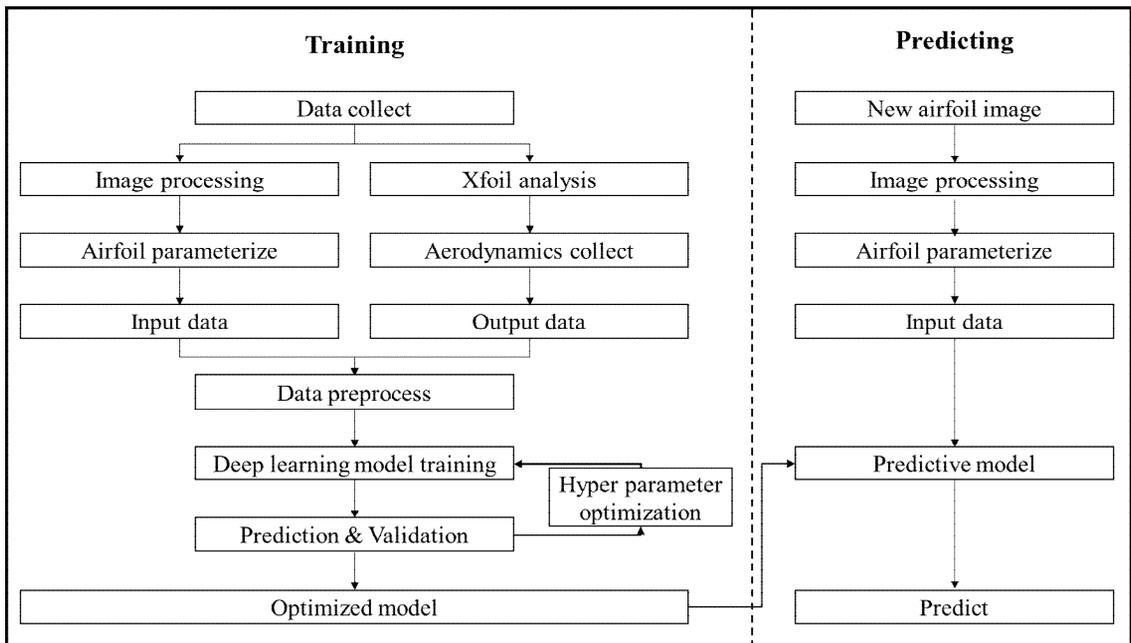


Fig. 3. Training & Predicting flow

터 중 Xfoil로 시위선이 1 m, 레이놀즈 수가 10,000, 받음각이 0°일 때 수렴하는 모든 익형을 대상으로 학습을 진행했다. 데이터의 수는 총 1,047개로 이를 train, validation, test data로 나누어 학습했다. 각각 매개변수화 한 값 13개를 입력 값, Xfoil로 계산한 C_L , C_D 값을 출력 값으로 딥러닝 학습을 진행했다.

3.2 학습 과정

학습 과정은 UIUC airfoil database에서 이미지 데이터와 coordinate 데이터를 parser를 활용하여 모두 수집한 후 익형 coordinate는 Xfoil 분석을 통해 C_L , C_D 값을 계산하고, 출력 데이터로 활용하기 위한 database를 생성한다.

UIUC airfoil database에서 추출한 익형 이미지 데이터는 image processing을 통해 매개변수화를 수행하고, 이를 input데이터로 활용하기 위한 database로 생성한다.

이후 input, output 데이터를 전처리하고 딥러닝 모델을 설계하고 학습을 진행한다. Hyperparameter를 찾기 위해서 예측 결과를 평가조건에 따라 판단하고, Hyperopt 기법을 활용하여 모델을 최적화한다. 최적화한 모델로 새로운 데이터 예측을 진행한다. Fig. 3은 이러한 모든 과정을 나타낸다.

3.3 평가 지표

딥러닝 모델 학습에 사용되는 평가 지표로 평균 절대 오차(mean absolute error: MAE)와 평균 제곱 오차(mean squared error: MSE)를 사용했다. 평균 제곱 오차와 평균 절대 오차 방식은 회귀 평가 지표로 자주 쓰이고 주로 손실함수와 metrics로 사용된다. 두 방식 모두 0에 가까울수록 좋은 모델이라고 평가한다⁽¹²⁾.

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (4)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (5)$$

식 (4)과 (5)에서 X_i 는 예측 값, Y_i 는 실제 값을 의미한다.

식 (4)의 평균 절대 오차는 실제 값과 예측 값의 차이의 절대값을 평균한 값이다. 오차의 절대값을 사용하기 때문에 모든 오차에 동일한 가중치를 부여하는 손실함수이다. 식 (5)의 평균 제곱 오차는 실제 값과 예측값의 차이를 제곱하여 평균을 낸 값이다. 평균 절대 오차와 달리 큰 오차에 더 큰 페널티를 부여하는 손실함수이다.

딥러닝 회귀 모델 평가에는 예측 성능을 측정하는 통계적 지표인 결정 계수(coefficient of determination) 또는 R2 score를 사용했다.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (6)$$

$$SS_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

$$SS_{tot} = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (8)$$

식 (6)은 R2 score의 식을 나타내고, 식(7)은 SS_{res} 잔차 제곱합이며, 식(8)은 SS_{tot} 총 제곱합을 의미한다. 식(7)과 (8)에서 y_i 는 실제 값, \hat{y}_i 는 예측 값, \bar{y}_i 는 실제 값의 평균을 의미한다. R2 score는 0과 1사이의 값을 가지며, 1에 가까울수록 회귀 모델이 데이터의 변동성을 얼마나 잘 설명하는지를 나타낸다⁽¹³⁾.

3.4 학습 결과

본 연구에서는 익형의 이미지 1,047 개를 8:1:1의 비율로 80%는 학습 데이터로, 10%는 검증 데이터, 10%는 테스트 데이터로 학습했다. 모델의 하이퍼파라미터는 모델의 node 수, 학습률(learning rate), 반복 횟수(epochs), 데이터크기(batch size) 등이 있고 이러한 하이퍼파라미터는 머신러닝 모델의 성능에 큰 영향을 미치는 변수들로 이를 최적화하기 위해서 Table 1에 나타난

조건 내에서 hyperopt 라이브러리를 활용하여 반복 학습을 하고, 이중 가장 뛰어난 예측율을 가지는 모델을 최적화 모델로 선정했다. 학습에 걸린 소요 시간은 한 번 학습에 소요되는 시간 평균 1 분으로 100 회 동안 반복 학습을 진행하여 1 시간 40 분 가량 소요되었다.

최적화 모델로 선정된 hyperparameter 는 Table 1 에 나타난 value 와 같다.

Table 1. Hyperopt's hyper parameter values

Hyper Parameter	Values
Dense1	16,32,64,128,256,512
Dense2	
Dense3	
Dense4	
Dense5	
Learning rate	0.00001 ~ 1
epochs	500,750,1000,1250,1500,2000,2500
Batch size	32,64,96,118,160,192,224,256

Table 2. Optimized model's hyperparameter

Hyper Parameter	Values
Dense1	512
Dense2	512
Dense3	64
Dense4	64
Dense5	16
Learning rate	0.006966482205030824
epochs	2500
Batch size	256

Table 3 은 평가지표로 훈련, 검증, 테스트 데이터의 평가지표인 평균 절대 오차, 평균 제곱 오차, R2 score 를 나타낸다. 평균 절대 오차와 평균 제곱 오차는 0 에 가까울수록 예측 정확도가 높은 값이고, R2 score 값은 1 에 가까울수록 모델이 데이터의 변동성을 얼마나 잘 설명하는지 나타내는 지표이다. 본 연구에서의 모델의 평가 지표는 모델이 익형 매개변수화의 입력 값으로 익형의 공력특성을 예측할 수 있음을 보여준다.

Table 3. Model's evaluation metrics

Parameter	Train	Test	validation
MAE	0.0075	0.0091	0.0088
MSE	0.00014	0.00027	0.00017
R2 score	0.992	0.989	0.991

3.5 공력 특성 예측 결과

Fig. 4 는 학습하지 않은 테스트 데이터의 C_L 예측 값과 원래 값을 나타낸 그래프이다. X label 은 각 값이 서로다른 익형을 나타내는 값이다. Fig. 4 에 나타난 C_L 데이터의 예측 제곱 오차의 범위는 $0.0055 > MSE > 0.0015$, 절대 오차의 범위는 $0.0741 > MAE > 0.0123$ 이다.

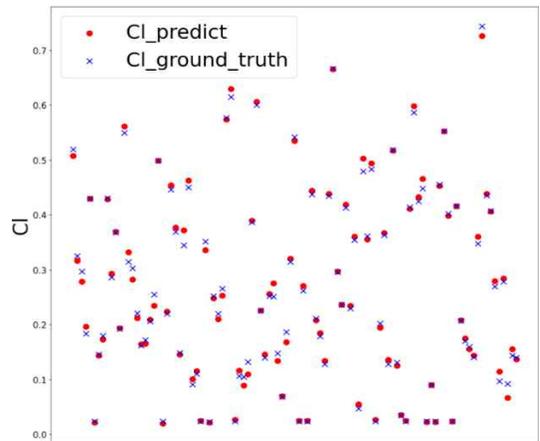


Fig. 4. Test C_L data predict & ground truth

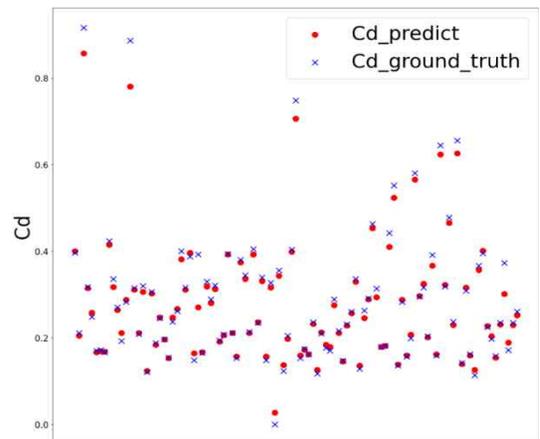


Fig. 5. Test C_D data predict & ground truth

Fig. 5는 학습하지 않은 테스트 데이터의 C_D 예측 값과 원래 값을 나타낸 그래프이다 Fig. 5에 나타난 C_D 데이터의 예측 제곱 오차의 범위는 $0.0355 > MSE > 0.0001$, 절대 오차의 범위는 $0.1884 > MAE > 0.0123$ 이다.

두 데이터에서 나타난 오차들을 평균을 취하면 Table 3에 나타나는 테스트 데이터의 MAE와 MSE 값을 계산할 수 있다. 학습하지 않은 익형에 대한 예측 값이기 때문에 오차가 발생하게 되고, 대부분의 익형의 C_L, C_D 값과 달리 비교적 높은 값의 C_L, C_D 값인 이상치 값을 가진 익형의 경우, 익형의 형태가 일반적인 익형과 달리 더 큰 두께를 가지거나, 아주 얇은 두께를 가진 익형, 익형의 굴곡에서 직선 부분을 가진 익형들이고 이러한 익형 데이터가 더 큰 오차를 가짐을 관찰할 수 있다.

Fig. 6은 익형 데이터 학습부터 예측까지의 과정을 이미지로서 나타내는 그림이다. 그림에서 나타나는 것과 같이 컴퓨터 상의 익형 이미지뿐만 아니라 현실의 스케치 익형의 공력특성 예측 역시 수행할 수 있다. 이미지에 나타난 녹색 선은 OpenCV를 활용하여 이미지에서 익형을 인식한 bounding box를 나타낸다

본 연구의 인공지능 모델은 받음각이 0° 일 때의 데이터를 기반으로 학습을 진행했기 때문에

다른 받음각에서의 예측을 정확히 하려면 각도와 같은 추가적인 파라미터값을 가진 데이터의 학습을 요구한다. 또한, 익형 데이터를 학습한 모델이기 때문에 다른 형상은 예측이 불가능하고, 적용하기 위해서는 추가적인 데이터 및 파라미터를 요구한다.

4. 결론

본 연구에서는 익형의 이미지에서 매개변수화를 수행한 결과를 입력으로 C_L, C_D 두 공력 특성을 예측하는 딥러닝 회귀 모델을 제안한다. 이는 다른 공력 특성을 예측하는 도구인 CFD나 Xfoil과 다르게 coordinate 정보를 필요로 하지 않고, 형상의 이미지 데이터나 스케치만으로도 공력 특성을 예측할 수 있다. 특정 익형에서 수렴하지 않는 문제를 보이는 Xfoil과 달리 본 모델에서는 수렴하지 않는 익형이 존재하지 않는다. 제안한 모델의 경우 결과 예측에 다른 여러 공력 특성 예측 도구보다 빠른 0.2초내의 시간이 소요된다.

후기

이 연구는 2021학년도 한국해양대학교 신진교수 정착연구지원사업 연구비 및 정부(과학기술

	Training			Prediction		
Step	1	2	3	4	5	6
Progress						<i>Airfoil aerodynamics (C_L, C_D)</i>
Method	Layout	Image Processing	Train	Handwritten	Image Processing	Deep learning
Process	Data Collection	Airfoil parameterization	Model train	Sketch	Airfoil parameterization	Prediction

Fig. 6. Progress of sketch airfoil prediction

정보통신부의 재원으로 한국연구재단의 무인이 동체원천기술개발 사업(2020M3C1C1A02086326)의 지원을 받아 수행되었습니다.

REFERENCE

- 1) Drela, M., 1989, "XFOIL: An analysis and design system for low Reynolds number airfoils," In *Low Reynolds Number Aerodynamics*, Springer, Berlin, Heidelberg., pp.1~12.
- 2) Xflr5., 2019, <http://www.xflr5.tech/xflr5.html>.
- 3) Oliver, J. M., Kipouros, T., and Savill, A.M., 2013, "A Self-adaptive Genetic Algorithm Applied to Multi-Objective Optimization of an Airfoil," In *EVOLVE-A Bridge between Probability, Set Oriented Numerics, and Evolutionary Computation IV. Advances in Intelligent Systems and Computing*, Springer Heidelberg., pp.261~ 276.
- 4) Echavarria, C., Hoyos, J. D., Jimenez, J. H., Suarez, G., and Saldarriaga, A., 2022, "Optimal airfoil design through particle swarm optimization fed by CFD and XFOIL," *J. Braz. Soc. Mech. Sci. Eng.*, Vol. 44(11), p.561.
- 5) Kim, B. R., Lee, S. H., Jang, S. H., Hwang, G. I., and Yoon, M., 2022, "Prediction of aerodynamics using VGG16 and U-Net," *J. Korean Soc. Vis.*, Vol. 20(3), pp.109~116.
- 6) Seo, J. H., Yoon, H. S., Kim, and M. I., 2022, "Prediction of aerodynamic force coefficients and flow fields of airfoils using CNN and Encoder-Decoder models.," *J. Korean Soc. Vis.*, Vol. 20(3), pp.94~101.
- 7) Bradski, G., 2000, "The openCV library," *Dr. Dobb's Journal: Software Tools for the Professional Programmer*, Vol. 25(11), pp.120~ 123.
- 8) Ramchoun, H., Ghanou, Y., Ettaouil, M., and Janati Idrissi, M. A., 2016, "Multilayer perceptron: Architecture optimization and training," *Proc. IJIMAI*, Vol. 4(1), pp.26~30.
- 9) Pokhrel, P., 2023, "A Comparison of AutoML Hyperparameter Optimization Tools for Tabular Data," Master's thesis, Youngstown State University.
- 10) Frazier, P. I., 2018, "A tutorial on Bayesian optimization," arXiv preprint arXiv:1807.02811.
- 11) Selig, M. S., 1996, "UIUC airfoil data site," Department of Aeronautical and Astronautical Engineering University of Illinois at Urbana-Champaign.
- 12) Chicco, D., Warrens, M. J., and Jurman, G., 2021, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, Vol. 7, pp.623.
- 13) Nagelkerke, N. J., 1991, "A note on a general definition of the coefficient of determination," *Biometrika.*, Vol. 78(3), pp.691~ 692.