

에어포일 공력 성능 예측을 위한 딥러닝 기반 방법론 연구

천성우¹, 정호진¹, 박민규², 정인호¹, 조해성^{1,3,†}, 기영중⁴¹전북대학교 항공우주공학과²ISAE-SUPAERO³전북대학교 미래항공모빌리티 연구소⁴한국항공우주연구원

Deep learning-based Approach for Prediction of Airfoil Aerodynamic Performance

Seongwoo Cheon^{1,†}, Hojin Jeong¹, Mingyu Park², Inho Jeong¹, Haeseong Cho^{1,3,†} and Youngjung Ki⁴¹Department of AeroSpace Engineering, Jeonbuk National University²ISAE-SUPAERO³Future Air Mobility Research Center, Jeonbuk National University⁴Korea Aerospace Research Institute

Abstract

In this study, a deep learning-based network that can predict the aerodynamic characteristics of airfoils was designed, and the feasibility of the proposed network was confirmed by applying aerodynamic data generated by Xfoil. The prediction of aerodynamic characteristics according to the variation of airfoil thickness was performed. Considering the angle of attack, the coordinate data of an airfoil is converted into image data using signed distance function. Additionally, the distribution of the pressure coefficient on airfoil is expressed as reduced data via proper orthogonal decomposition, and it was used as the output of the proposed network. The test data were constructed to evaluate the interpolation and extrapolation performance of the proposed network. As a result, the coefficients of determination of the lift coefficient and moment coefficient were confirmed, and it was found that the proposed network shows benign performance for the interpolation test data, when compared to that of the extrapolation test data.

초 록

본 논문에서는 에어포일의 좌표 데이터에 대해 공력 특성을 예측할 수 있는 합성곱 신경망 기반 네트워크 프레임 워크를 설계하였으며 Xfoil을 이용한 공력 데이터를 적용하여 네트워크의 가능성을 확인하였다. 이 때 에어포일의 두께 변화에 따른 공력 특성 예측을 수행하였다. 부호화 거리 함수를 이용하여 에어포일의 좌표 데이터를 이미지 데이터로 변환하였으며 받음각 정보를 반영하였다. 또한 에어포일의 압력 계수 분포를 축소 모델 기법 중 하나인 적합 직교 분해를 이용하여 축소된 데이터로 표현하였으며 이를 네트워크의 출력 데이터로 사용하였다. 제시하는 네트워크의 내삽과 외삽 성능을 평가하기 위하여 시험 데이터를 구성하였고, 결과적으로 내삽 데이터에 대한 예측 성능이 외삽에 비해 우수함을 확인하였다.

Key Words : Convolutional Neural Network(합성곱 신경망), Proper Orthogonal Decomposition(적합 직교 분해), Airfoil(에어포일), Aerodynamic Coefficient(공력 계수), Pressure Coefficient(압력 계수), Signed Distance Function(부호화 거리 함수)

Received: Jan. 21, 2022 Revised: Apr. 04, 2022 Accepted: Jun. 15, 2022

† Corresponding Author

Tel: +82-62-270-3988, E-mail: hcho@jbnu.ac.kr

© The Society for Aerospace System Engineering

1. 서 론

Quadcopter 및 생체모방 날갯짓 비행체를 포함한
초소형 무인 비행체는 일반적으로 저 레이놀즈 수 영

역에서 비행하는 비행체로 최근 수 년 동안 관련 연구가 활발히 진행되고 있다[1,2]. 이에 따라 블레이드 또는 날개의 저 레이놀즈 영역의 공력 해석이 필수적이다.

일반적으로 $Re = 1 \times 10^2 \sim 1 \times 10^5$ 의 값을 가지는 저 레이놀즈 수 영역에서는 점성에 의한 효과가 커지며 결과적으로 경계층에서 흐름 박리, 유동 재부착 등의 물리적 현상이 발생한다. 이에 따라 항력이 증가하고 양력이 감소하게 된다[3,4]. 따라서 저 레이놀즈 수 영역에서의 공력 데이터를 획득하기 위해서는 풍동 실험이나 전산유체해석을 수행해야 한다. 하지만 풍동 실험의 경우 단일 레이놀즈 수 실험만 수행 가능하며 실험 장치의 민감도가 결과에 많은 영향을 준다. 전산유체해석은 풍동실험을 대신한 방법을 고려될 수 있으나, 상당한 계산 자원을 요구한다[4]. 따라서 최근 공력 해석에 필요한 시간을 단축시키면서 높은 정확도를 가지는 대리 모델 연구가 활발히 수행되고 있다.

Yilmaz et al(2017)은 합성곱 신경망을 이용하여 에어포일의 성능을 예측하는 연구를 수행하였다. 입력과 출력은 각각 에어포일의 x, y축 좌표와 좌표에 해당되는 압력 계수이다. 결과적으로 80% 정확도를 가지는 네트워크를 설계하였다[5]. Duru et al(2022)은 부호화 거리함수를 통해 생성한 에어포일 이미지 데이터를 이용하여 천이영역에서의 흐름장을 예측하는 네트워크를 제안하였다. 제안한 네트워크는 합성곱 계층으로 구성되며 다양한 에어포일 검증 데이터에 대해서 매우 잘 예측되는 것을 확인하였다[6]. Bhatnagar et al(2019)은 합성곱 오토인코더를 이용한 속도장과 압력장 예측 네트워크를 제시하였다. 에어포일 좌표 데이터를 부호화 거리 함수를 이용하여 변환한 이미지와 받음각, 레이놀즈 수를 네트워크 입력으로 사용하였으며 RANS를 이용하여 데이터를 생성하였다. 결과적으로 평균 제곱 오차가 10% 내외의 결과를 얻었다[7]. Zhang et al(2018)은 다층 퍼셉트론, 합성곱 신경망 등 3가지의 네트워크를 이용하여 에어포일의 양력 계수를 예측하였으며 네트워크의 성능을 비교하는 연구를 수행하였다. 에어포일의 이미지 데이터와 받음각, 마하수를 입력으로 사용하였으며 Xfoil을 이용하여 공력 성능 예측을 수행하였다 [8].

또한 유동장의 특성을 파악하고 시스템의 차수를 줄이기 위해 적합 직교 분해 (POD, proper orthogonal decomposition)와 같은 데이터 분석 기법이 사용될 수 있다. 적합 직교 분해는 다차원 시스템의 두드러진 특성을 포착하기에 효율적이며, 관련 특정 모드를 통해 그 시스템의 차수를 줄일 수 있다. 이러한 적합 직교 분해는 유동해석을 포함한 다양한 분야에서 사용되고 있으며, 난류 유동, 비정상 유동과 같은 전산유체해

석에 적용되었다[9].

Balla et al(2021)은 인공 신경망을 이용하여 에어포일과 3차원 날개의 압력 계수 분포를 예측하였으며 이를 적합직교분해를 통해 내삽한 데이터와 비교하였다. 인공신경망의 입력은 에어포일의 이미지 데이터, 받음각과 마하 수이며, 결과적으로 인공신경망을 통한 예측이 적합직교분해의 내삽보다 우수함을 확인하였으며 특히 충격과가 발생하게 되면 네트워크의 성능이 더욱 우수함을 확인하였다[9]. Murata et al은 동적 모드 분해를 통해 생성한 모드 데이터를 합성곱 오토인코더의 출력으로 구성하여 학습을 수행했으며 이를 적합직교분해와 비교하였다[10].

본 논문에서는 에어포일의 압력 계수 분포를 예측하는 네트워크를 제시한다. 압력 계수 분포는 차원 축소 기법인 직교적합분해를 이용하여 축소된 데이터로 표현하였으며, Xfoil[11]을 이용하여 에어포일의 압력 계수 분포 데이터를 생성하였다. 이를 통해 본 논문의 목표인 딥러닝 네트워크 기반 에어포일 공력 특성 예측의 가능성을 확인하였으며, 합성곱 신경망과 적합직교분해를 적용하였다. 네트워크를 통해 예측한 압력 계수 분포는 받음각에 대한 양력 계수 계산을 통해 비교하였다.

2. 본 론

2.1 데이터 생성

본 논문에서는 에어포일의 두께 변화에 따른 공력 성능을 예측하기 위해 에어포일 두께를 파라미터로 고려하였다. 이를 위해 캠버가 없는 8개의 NACA 4계열 에어포일을 고려하였고, NACA0006, 0008, 0010, 0012, 0015, 0018, 0021, 0024을 선택하여 네트워크 훈련 데이터를 구성하였다. 또한 NACA0017, 0022과 0026을 시험 데이터로 선정하였다.

Table 1 Xfoil parameter

Parameter	Value
Inviscid/viscous	Viscous
Number of panels	160
Reynolds number	3.31×10^6
Mach number	0.1471
Angle of attack	$-25^\circ \sim 25^\circ$
Max iteration	500
Ncrit	9

훈련 데이터 생성을 위해 에어포일 공력 해석 프로그램인 Xfoil을 사용하였다. 에어포일 해석 유동 조건은 레이놀즈 수 3.31×10^6 , 받음각 $[-25^\circ, 25^\circ]$, 마하

수 0.1471이며 Xfoil 파라미터는 Table 1에 나타내었다. 공력 해석 과정에서 발산하거나 수렴하지 않은 경우를 제외하여 총 647개의 데이터를 생성하였다.

본 논문에서는 에어포일을 이미지 데이터로 변환하여 네트워크의 입력으로 사용하였으며, 이미지 데이터 변환을 위해 부호화 거리 함수를 이용하였다. 부호화 거리 함수는 공간상의 특정 지점의 좌표와 임의의 형상 위의 점에 대한 유클리드 거리 중 최단 거리를 반환해주는 함수로 Eq. 1과 같이 나타낸다.

$$f(x) = \begin{cases} d(x, \partial\Omega), & x \in \Omega \\ 0, & x \in \Omega^c \end{cases} \quad (1)$$

$\partial\Omega$ 은 임의의 표면의 미소 경계 면이며 $d(x, \partial\Omega)$ 은 임의의 점과 표면 위의 점과의 최단 거리이다. 임의의 점과 이산화 된 에어포일 표면 좌표와의 최단 거리는 에어포일 표면 좌표에 의존적으로 결정되므로 에어포일 표면 좌표는 입력 데이터를 생성할 때 중요하게 고려되어야 할 요소이다. 에어포일 좌표를 조밀하게 구성하지 않으면 이미지 데이터를 생성하는데 에어포일의 경계 면에서 거리 값이 부정확한 값이 도출될 수 있으며, 에어포일의 형상이 정확하게 표현되지 않을 수 있다. 따라서 에어포일의 좌표 간의 보간이 필요하다. 또한, 이미지 데이터에 에어포일의 받음각 정보를 반영하기 위해 에어포일의 좌표를 해당되는 받음각만큼 회전 변환하여 부호화 거리 함수를 적용하였다.




Fig. 1 Results of Signed Distance Function (SDF) for NACA0026 with respect to the various angle of attack

Figure 1은 부호화 거리 함수를 통해 생성한 이미지 데이터의 예시이다. Eq. 1에 의해 에어포일 내부는 0 값을 가지며, 에어포일의 경계 면과 멀어질수록 큰 값이 정의된다. 부호화 거리 함수의 이산화 된 좌표를

사용하기 때문에 곡선을 완벽하게 표현하는데 한계점이 있으므로 이를 보완하기 위해 에어포일 이미지를 나타내기 위한 좌표를 조밀하게 구성해야 하며 Fig. 2는 SDF를 이용하여 곡선을 나타낸 예시이다.




Fig. 2 Comparison of SDF image and real geometry of NACA0026 leading edge at $\alpha = -17.5^\circ$

2.2 합성곱 신경망

합성곱 신경망은 합성곱 계층과 완전 연결 계층으로 구성된 딥러닝 네트워크 기법으로 입력 이미지에 대해 분류 모델 또는 회귀 모델을 학습하는 네트워크이다. 합성곱 필터를 이용하여 입력 값과 데이터 위치 정보에 따른 특징을 학습하게 되며 합성곱 계층을 형성한다. 또한 완전 연결 계층은 출력에 대해 분류 모델 또는 회귀 모델을 학습하게 된다. 합성곱 신경망은 필터의 수, 필터의 크기, Max pooling, Padding 등과 같은 파라미터를 통해 네트워크의 성능을 향상시킬 수 있다 [12]. 본 논문에서는 에어포일 좌표를 이미지 데이터로 변환하고 이를 합성곱 신경망의 입력 데이터로 활용하여 압력 계수 분포를 예측하는 네트워크를 설계하였다.

2.3 적합 직교 분해

적합 직교 분해는 대표적인 차원 축소 방법으로 난류 유동장, 천이 유동장 등 전산유체해석 분야에서 효율적인 문제 해결을 위해 많이 사용되고 있다 [13,14]. 적합 직교 분해는 완전 차수 데이터를 나타낼 수 있는 직교 기저를 제시하며 Eq. 2를 만족하는 축소 기저를 구축하여 데이터를 축소된 차원으로 투영하는 기법이다.

$$\min \sum_{i=1}^m \left\| \mathbf{u}_s^{(i)} - \mathbf{v} \mathbf{q}^{(i)} \right\|_2 \quad (2)$$

최적화 문제에서, $\mathbf{u}_s^{(i)} = [\mathbf{u}_1^{(i)}, \mathbf{u}_2^{(i)}, \dots, \mathbf{u}_N^{(i)}]$ 은 스냅샷 데이터이며, \mathbf{v} 는 최적화 미리 정의한 차원 n 의 부분 공간이다. $\mathbf{q}^{(i)}$ 는 위의 식을 만족시키기 위해 조정되는 값이다.

이를 위해 완전 차수 데이터를 이용하여 $N \times S$ 의 스냅샷 행렬 \mathbf{S} 를 Eq. 3와 같이 구성한다, 스냅샷 행렬에서 행 방향은 시스템 자유도와 관련되며, 열 방향은 변수 또는 시간에 따른 데이터로 구성한다. 다음으로 Eq. 4을 이용한 특이값 분해를 통해 기저 벡터를 생성한다.

$$\mathbf{S} = \begin{bmatrix} u_1^{(1)} & u_1^{(2)} & \dots & u_1^{(m)} \\ u_2^{(1)} & u_2^{(2)} & \dots & u_2^{(m)} \\ \vdots & \vdots & \vdots & \vdots \\ u_N^{(1)} & u_N^{(2)} & \dots & u_N^{(m)} \end{bmatrix} \quad (3)$$

$$\mathbf{S} = \Phi \Sigma^T \quad (4)$$

Φ 와 \mathbf{V} 는 직교 행렬이며 $\Phi = [\phi_1, \phi_2, \dots, \phi_N]$ 은 적합 직교 모드로 기저 벡터로 구성된다. $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_N)$ 는 특이 값이 포함하는 대각 행렬이며 데이터 값의 크기 순서로 정렬되어 있어 가장 큰 값을 가지는 순서로 스냅샷 행렬 데이터의 특징을 가장 많이 담게 된다. Eq. 5를 이용하여 시스템을 대표할 수 있는 n 개 만큼의 모드를 선택하여 데이터를 축소 표현할 수 있다.

$$E = \frac{\sum_{i=1}^n \sigma_i}{\sum_{i=1}^N \sigma_i} > 1 - \epsilon_{\text{POD}} \quad (n \ll N) \quad (5)$$

E 는 직교 행렬 Φ 에서 첫번째에서 n 번째 기저 벡터에 의해 나타내어진 스냅샷의 상대 에너지이다. 이를 통해 완전 차수 데이터 $\mathbf{u}_h = [u_1^{(1)}, u_2^{(2)}, \dots, u_N^{(m)}]$ 를 Eq. 6을 이용하여 적합 직교 모드와 적합 직교 계수의 선형 조합으로 근사할 수 있다.

$$\mathbf{u}_h = \sum_{i=1}^N \alpha_i \phi_i \approx \sum_{i=1}^n \alpha_i \phi_i = \Phi_n \alpha \quad (6)$$

$$\alpha = \Phi_n^T \mathbf{u}_h \quad (7)$$

이때, α 은 적합 직교 계수 또는 축소 차수 데이터이며 Eq. 7를 이용하여 계산한다.

2.4 네트워크 프레임워크 구성 및 학습

본 논문에서 제시하는 합성곱 신경망의 구조는 Table 2와 같다. 부호화 거리 함수를 통해 80×120 이미지 데이터를 637개 생성하였으며 이 때 에어포일 좌표 간 100개의 점으로 보간 하여 16,000개의 에어포일 좌표를 사용하였다. 에어포일의 압력 계수 분포

의 축소 데이터를 구하기 위해 Xfoil를 통해 생성한 압력 계수 분포를 이용하여 스냅샷 행렬을 구성하였다. 적합 직교 모드를 도출하기 위해 구성된 스냅샷 행렬을 이용하여 특이값 분해를 수행한다. 에너지 비를 고려하여 적합 직교 모드, $\Phi_n = [\phi_1, \phi_2, \dots, \phi_n]$ 를 선정하고 압력 계수 분포의 축소된 데이터를 생성한다. 결과적으로 네트워크의 입력과 출력으로 각각 부호화 거리 함수를 통해 생성한 에어포일 이미지와 적합 직교 분해를 통해 축소된 압력 계수 분포를 사용하였다.

Table 2 Architecture of Network framework

Layer	Kernal Size	Stride	Nums of filters	Output
Input	-	-	-	$80 \times 120 \times 1$
Conv1D + ReLU	6×6	1×1	4	$75 \times 115 \times 4$
Max pooling	-	2×2	1	$37 \times 57 \times 4$
Conv1D + ReLU	6×6	1×1	8	$32 \times 52 \times 8$
Max pooling	-	2×2	1	$16 \times 26 \times 8$
Conv1D + ReLU	6×6	1×1	16	$11 \times 21 \times 16$
Max pooling	-	2×2	1	$5 \times 10 \times 16$
Flatten	-	-	-	800
FC1 + ReLU	-	-	-	400
FC2 + ReLU	-	-	-	60

학습 데이터의 특이 값 분해를 통해 얻은 적합 직교 모드를 이용하여 네트워크의 출력을 다시 원래의 차원으로 정의된 압력 계수 분포로 복원하였다. 복원한 데이터는 결정 계수를 이용하여 원래 데이터와 비교하였으며 결정 계수 R^2 은 Eqs. 8-10을 통해 계산할 수 있다. Sum of Squared Total(SST)과 Sum of Squared Residual(SSR)은 각각 전체제곱합, 회귀제곱합을 의미하며 y_i 은 실제 값이며 \bar{y} 와 \hat{y}_i 는 각각 실제 값의 평균, 예측 값이다.

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

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$R^2 = 1 - \frac{SSR}{SST} \quad (10)$$

데이터 값이 큰 데이터를 과도하게 학습되는 것을

방지하며 데이터의 균일한 분포를 만들기 위해 Eq. 11을 이용하여 데이터 정규화를 수행하였다. x_{norm} 은 정규화 된 데이터이며, x_{min} 와 x_{max} 은 각각 데이터의 최대값, 최소값을 나타낸다. 네트워크의 훈련 데이터와 검증 데이터를 9:1 비율로 나눠 네트워크 학습을 진행하였다.

$$x_{norm} = (x - x_{min}) / (x_{max} - x_{min}) \quad (11)$$

합성곱 신경망은 3개의 합성곱 계층을 사용하였으며 각각 4, 8, 16개의 필터를 사용하였다. 이 때 사용한 필터의 크기는 6×6 이다. 또한 2×2 max pooling을 사용하여 큰 값이 주요하게 학습이 된다. 완전 연결 계층은 1개의 계층으로 구성하였으며, 계층은 400개의 뉴런으로 구성하였다. 활성화 함수는 모든 계층에서 ReLU를 사용하였다. ReLU는 Sigmoid나 tanh와 같은 전통적으로 많이 사용된 활성화 함수가 가지는 기울기 소멸 문제를 해결하고 미분 값이 간단하여 계산 비용 또한 감소시킬 수 있으며[15], 이는 Eq. 11과 같다.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (11)$$

회귀 모델에서 사용하는 손실 함수는 평균 제곱 오차, 평균 절대 오차 그리고 평균 절대 백분율 오차 등이 있다. 본 논문에서는 평균 제곱 오차를 네트워크의 훈련 지표로 사용하였으며, Eq. 12를 이용하여 계산하였다.

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (12)$$

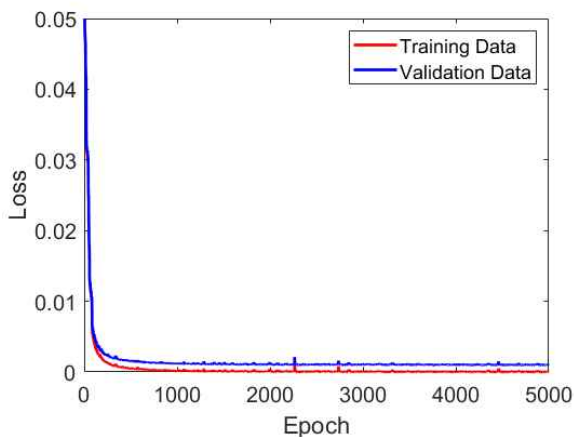


Fig. 3 Loss of training data and validation data

네트워크 최적화는 Adam[16] 최적화 알고리즘을 사

용하였다. Fig. 3은 네트워크 학습이 진행됨에 따라 훈련 데이터와 검증 데이터의 손실 함수 값을 나타낸다. 이를 통해 네트워크 훈련과정에서 과적합이 발생하지 않고 손실 함수가 최소화되는 방향으로 적절하게 훈련이 이루어졌음을 확인하였다.

3. 수치해석 결과

3.1 적합 직교 분해 데이터 축소 결과

Xfoil을 통해 생성한 압력 계수 분포 데이터를 이용하여 스냅샷 행렬을 구성하였으며, 최종적으로 도출한 스냅샷 행렬의 크기는 160×647 이다. 행 방향 데이터는 에어포일의 압력 계수 분포와 관련되며, 열 방향 데이터는 받음각 변화와 관련된다. 축소된 데이터의 에너지 비는 Fig. 4와 같이 0.95 ~ 1.00 범위를 고려하였다.




Fig. 4 Energy ratio

에어포일의 양력과 항력은 에어포일 주변의 압력 변화에 의해 발생한다. 하지만 Xfoil에서는 경계층 이론을 기반으로 항력 계수를 계산하기 때문에 압력 계수 분포를 이용하여 도출한 항력 계수를 직접 비교하는 것이 제한된다. 따라서 축소된 압력 계수 분포를 이용하여 양력, 모멘트 계수를 계산하였으며 Eq. 13, 14를 이용하였다.

$$C_l = \int C_p dx \quad (13)$$

$$C_m = \int -C_p [(x - x_{ref}) dx + (y - y_{ref}) dy] \quad (14)$$

여기서, C_l 은 양력 계수이며, C_p 과 C_m 은 각각 압력 계수, 모멘트 계수이다. x_{ref} 와 y_{ref} 은 에어포일의 공력

중심으로 각각 0.25, 0을 고려하였다. 이를 이용하여 선택한 적합 직교 모드 수의 적절성을 판단하였다. 이때 모멘트 계수의 기준 좌표는 공력중심으로 고려하였다. 양력 계수는 압력 계수 최대 값과 최소값 근처의 값에 주요하게 영향을 받으며 모멘트 계수는 모멘트 암의 역할로 인하여 에어포일의 뒷전 압력 계수 값이 작은 값을 가지지만 주요하게 영향을 미치게 된다.

Figure 5는 압력 계수 분포를 원래 데이터와 축소한 데이터를 비교한 예시로 NACA0018 압력 계수 분포 그래프이다. Fig. 6과 Fig. 7은 각각 이를 이용하여 양력, 모멘트 계수를 계산한 결과이다. 적합 직교 모드는 각각 20, 60개를 고려하였다. 적합 직교 모드를 20개 선택하였을 때 에너지 비는 0.9578이다. 적합 직교 분해를 통해 나타낸 압력 계수 분포와 비교하였을 때 평균 제곱 오차가 0.0038 이하로 적절하게 근사 하였지만 양력 계수와 모멘트 계수를 계산하였을 때 모멘트 계수의 오차가 큰 구간이 존재함을 확인할 수 있다.




Fig. 5 Pressure coefficient of NACA0018 at an angle of attack of 25 degrees




Fig. 6 Lift coefficient of NACA0018

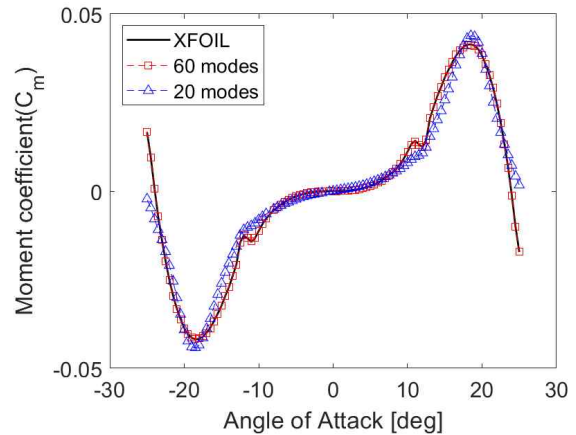


Fig. 7 Moment coefficient of NACA0018

Figure 7는 Fig. 5를 확대하여 나타낸 그림이다. 에어포일의 두께와 받음각이 증가하면 에어포일 뒷전의 압력 계수의 오차가 크게 나타나며, 유동 박리가 발생하는 지점에서 근사 오차가 커짐을 확인하였다. 에어포일 뒷전의 압력 계수의 오차는 모멘트 계수에 주요한 영향을 미치며, 그 결과 받음각이 큰 구간에서 모멘트 계수의 오차가 크게 발생하는 것을 확인하였다.

적합 직교 모드를 60개 선택하였을 때, 에너지 비는 0.9917이다. 압력 계수 값이 전술한 부분에서 잘 근사 되었으며 양력 계수와 모멘트 계수를 비교하였을 때, 상대적으로 정확하게 근사 되는 것을 확인하였다. 따라서 본 논문에서는 적합 직교 모드를 60개 이상 고려되어야 하지만 적합 직교 모드를 많이 사용함에 따라 네트워크 구성 및 훈련 시간이 증가하게 된다. 적합 직교 모드를 60개 사용하였을 때 훈련해야 하는 파라미터는 350,392개이며 1 epoch 당 93.96 ms가 소요된다. 반면, 적합 직교 모드를 모두 사용하였을 때 훈련해야 하는 파라미터는 390,492개이며 1 epoch 당 95.53 ms가 소요된다. 이러한 훈련 소요시간의 증가는 향후 속도장, 압력장과 같이 보다 큰 차원을 갖는 데이터를 네트워크에 적용하였을 때 보다 큰 폭으로 증가할 것으로 예상 가능하며, 이에 따라 적절한 적합 직교 모드 수를 선택하는 것이 중요하게 된다. 따라서 본 논문에서는 압력 계수 근사를 효과적으로 수행할 수 있는 60개의 적합직교모드를 사용하였다.

3.2 네트워크 내삽 결과

2.5절에서 제시한 네트워크 훈련과정을 수행한 후, 두께 파라미터 범위 내의 NACA0017와 NACA0022를 이용하여 네트워크의 내삽 성능을 평가하였다. NACA0017은 설계 파라미터 공간 안에서 중간 값에 위치한 데이터이며 NACA0022는 경계에 가까운 데이터이다. 데이터 생성을 위한 유동 및 Xfoil 해석 조건

은 Table 1과 동일하다.

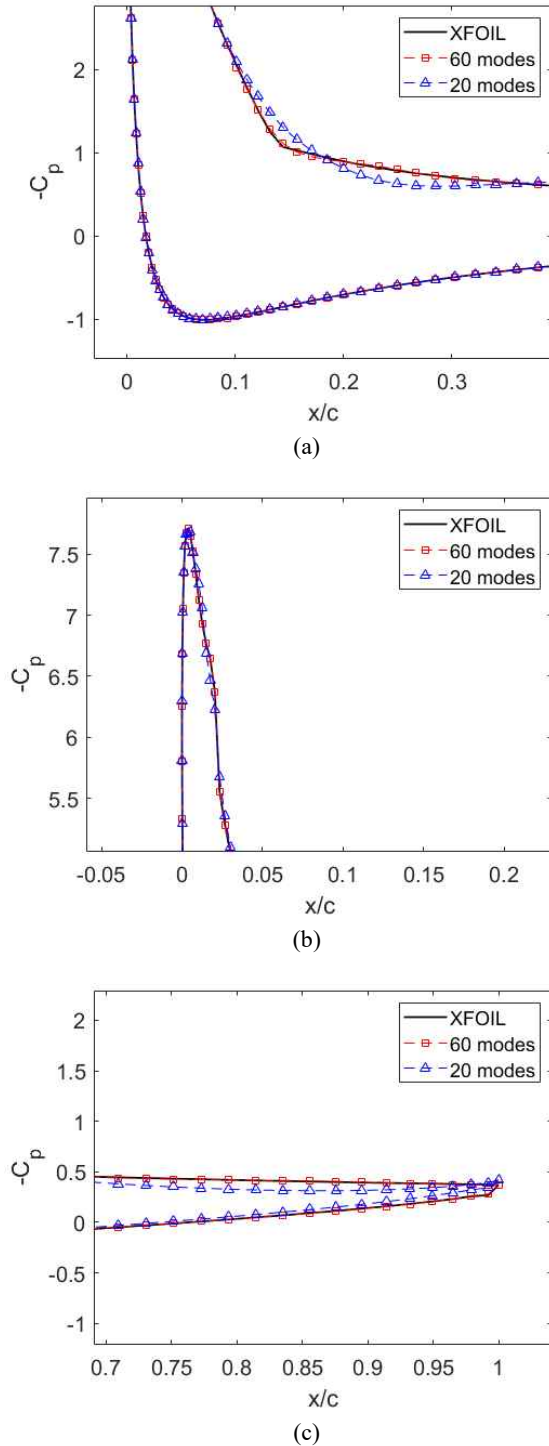


Fig. 8 Comparison of C_p distribution at (a), (b), and (c) positions in Fig. 5

네트워크를 통해 NACA0017와 NACA0022 에어포일의 압력 계수 분포에 대한 적합 직교 계수를 예측하

였으며 훈련 데이터의 스냅샷 행렬을 통해 생성한 적합 직교 모드를 곱하여 압력 계수 데이터 차원을 복원하였다.




Fig. 9 Prediction of pressure coefficient of NACA0017 at $\alpha = -23^\circ, 5^\circ, 15^\circ$




Fig. 10 Prediction of pressure coefficient of NACA0022 at $\alpha = -23^\circ, 5^\circ, 15^\circ$

Figure 9-10은 각각 NACA0017와 NACA0022의 압력 계수 분포의 기존 데이터와 예측 데이터를 비교

한 그림이다. 네트워크 예측 결과 결정 계수가 0.9672 이상임을 확인하였다. Fig. 11-14은 각각 NACA0017와 NACA0022의 양력 계수와 모멘트 계수를 계산하여 비교한 그래프이다. 예측 결과, NACA0017의 양력 계수와 모멘트 계수 그래프의 결정 계수가 각각 0.9974, 0.9935이며, NACA0022는 각각 0.9950, 0.9947임을 확인하였다. 하지만 양력 계수와 모멘트 계수의 오차가 다소 발생하는 것을 확인할 수 있으며, 받음각이 커짐에 따라 보다 큰 오차가 발생하는 것을 확인하였다. Fig. 15는 축소된 압력 계수 분포를 나타낸 것으로 20개와 60개를 선택하였을 때를 그래프로 나타낸다. 적합 직교 모드를 60개를 고려하게 되면 20개를 사용한 것보다 고차 모드까지 고려하여 기존의 데이터를 보다 정확하게 근사할 수 있지만 고차 모드가 저차 모드에 비해 매우 작은 값을 갖는 것을 확인할 수 있다. 이는 학습 과정에서 고차 모드에 대한 예측 정확성에 영향을 주며, 이는 양력 계수 및 모멘트 계수의 오차에 대한 원인으로 고려할 수 있다.




Fig. 11 Prediction of lift coefficient of NACA0017

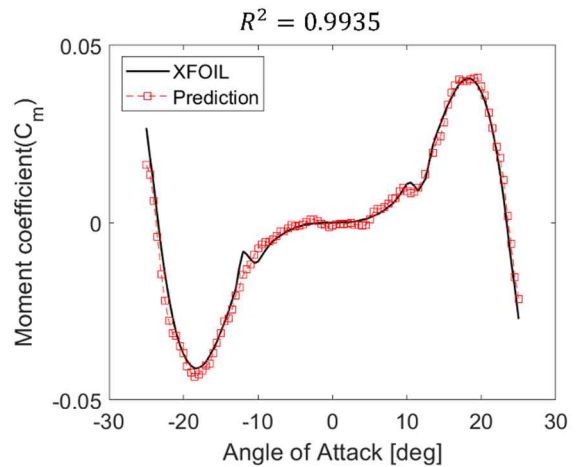


Fig. 12 Prediction of moment coefficient of NACA0017




Fig. 13 Prediction of lift coefficient of NACA0022

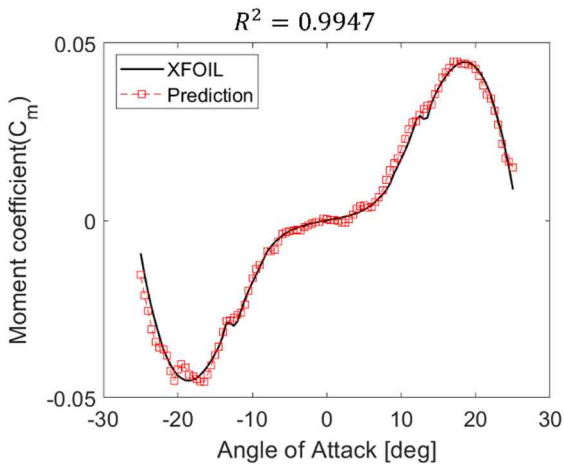


Fig. 14 Prediction of moment coefficient of NACA0022

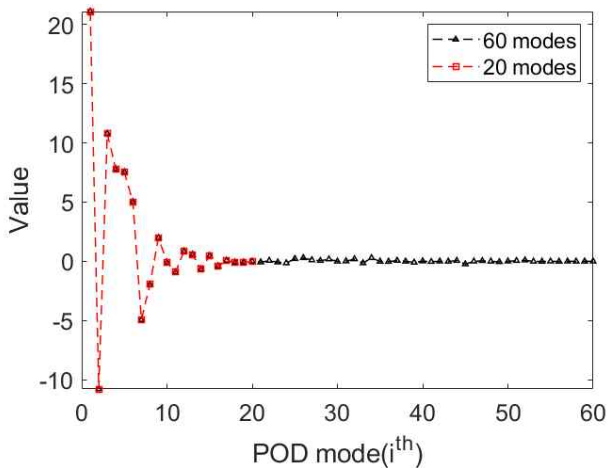
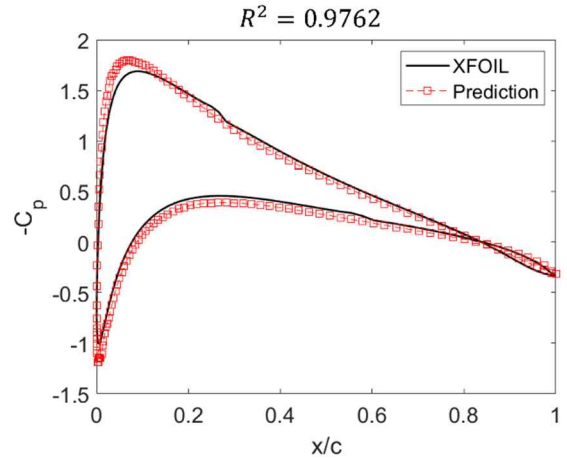




Fig. 15 POD coefficients



(a) $\alpha = -23^\circ$



(b) $\alpha = 5^\circ$



(c) $\alpha = 15^\circ$

Fig. 16 Prediction of pressure coefficient of NACA0026 at $\alpha = -23^\circ, 5^\circ, 15^\circ$

3.3 네트워크 외삽 결과

두께 파라미터 범위 외의 NACA0026을 이용하여 네트워크의 외삽 성능을 평가하였다. Xfoil 해석 조건

은 Table 1과 동일하며 네트워크를 통해 NACA0026의 축소된 압력 계수를 예측하였으며, 적합 직교 모드를 곱하여 압력 계수 데이터 차원을 복원하였다.

Figure 16은 NACA0026 압력 계수 분포의 기존 데이터와 예측 데이터 비교를 나타낸다. 네트워크 예측 결과, 결정 계수가 0.7607 이상임을 확인하였다. 양력 계수와 모멘트 계수의 예측은 Figs. 17, 18과 같으며, 예측 결과 결정 계수가 각각 0.9631, 0.8903이다. 따라서 받음각이 작은 구간에서는 외삽 검증 데이터가 훈련데이터와 비슷한 경향을 보이지만, 받음각이 큰 구간에서는 데이터의 경향이 상이해짐에 따라 네트워크의 외삽에 대한 예측 정확도는 내삽에 비해 매우 감소하는 것을 확인하였다. 설계 공간 밖의 매개 변수에 대해서 예측하는 네트워크의 외삽 예측은 일반적으로 도전적인 문제이며, 본 논문에서도 이러한 경향을 확인하였다. 네트워크의 외삽 문제 적용 시, 부정확한 결과를 도출하는 현상을 해결하기 위해 전이 학습[17]을 고려할 수 있다.

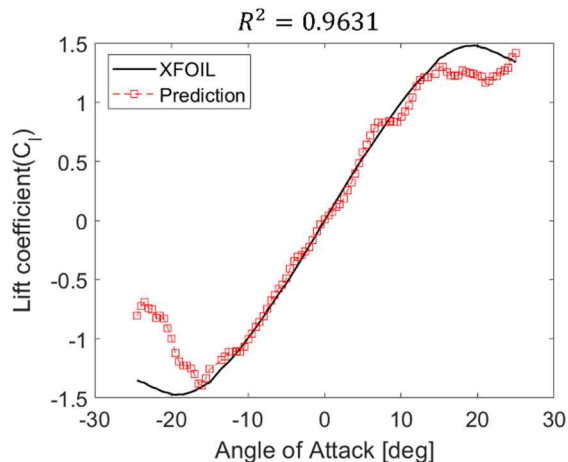


Fig. 17 Prediction of lift coefficient of NACA0026




Fig. 18 Prediction of moment coefficient of NACA0026

4. 결 론

본 논문에서는 합성곱 신경망을 이용하여 에어포일 좌표 데이터와 압력 계수 분포의 관계를 학습하였으며 이를 통해 임의의 유동 조건에서의 에어포일 압력 계수 분포를 예측하는 네트워크를 설계하였다. 이 때 에어포일 좌표는 부호화 거리 함수를 통해 이미지 데이터로 변환하였으며 압력 계수 분포는 적합 직교 분해를 통해 축소된 데이터를 사용하였다. 에어포일의 두께 변화에 따른 공력 특성을 예측하기 위하여 캠버가 없는 에어포일을 사용하였으며 Xfoil을 이용하여 에어포일의 좌표, 공력 데이터를 생성하여 적용하였다. 본 논문에서는 경험적인 방법을 통해 적합직교모드의 수를 선택하였으며, 이를 이용하여 네트워크를 구성하였다. 결과적으로 내삽 훈련 데이터의 압력 계수를 통한 양력, 모멘트 계수의 결정 계수가 NACA0017은 각각 0.9974, 0.9901, NACA0022는 각각 0.9950, 0.9947으로 잘 예측됨을 확인하였으며 외삽 훈련 데이터의 경우 결정 계수가 각각 0.9631, 0.8903으로 어려움을 확인하였다. 직교 적합 분해 이외에 딥러닝 네트워크 기법 중 하나인 오토인코더와 변이형 오토인코더 등을 사용하여 다양한 네트워크 구조를 제시할 수 있으며 선형 근사의 한계점을 극복할 수 있을 것으로 기대된다. 또한, 네트워크 외삽 문제에서 다소 부정확한 예측을 도출하는 현상을 해결하기 위해 전이 학습을 통해 설계 공간 밖의 매개 변수를 예측하는 방법을 고려할 계획이다. 마지막으로, 저 레이놀즈 수 영역의 에어포일 공력 데이터를 네트워크에 적용할 예정이다.

후 기

본 연구는 2021년 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2020R1C1C1006006)과 한국전력공사의 2021년 착수 기초연구 개발 과제 연구비의 지원(No. R21X001-6)을 받아 수행된 연구입니다.

References

- [1] R. Shrestha, M. Benedict, V. Hrishikeshavan and I. Chopra, "Hover performance of a small-scale helicopter rotor for flying on mars," *Journal of Aircraft*, vol. 53, no. 4, pp. 1160-1167, May 2016
- [2] J.-S. Wang and J.-J. Wang, "Wake-Induced Transition in the Low-Reynolds-Number Flow over a Multi-Element Airfoil," *Journal of Fluid Mechanics*, vol. 915, March

- 2021.
- [3] S. Wang, Y. Zhou, M. M. Alam and H. Yang, "Turbulent Intensity and Reynolds Number Effects on an Airfoil at Low Reynolds Numbers," *Physics of Fluids*, vol. 26, no. 11, p. 115107, Nov. 2014
- [4] J. Winslow, H. Otsuka, B. Govindarajan and I. Chopra, "Basic Understanding of Airfoil Characteristics at Low Reynolds Numbers ($10^4 - 10^5$)," *Journal of Aircraft*, vol. 55, no. 3 pp.1050-1061, Dec. 2018
- [5] E. Yilmaz, and B. German, "A Convolutional Neural Network Approach to Training Predictors for Airfoil Performance," *18th AIAA/ISSMO multidisciplinary analysis and optimization conference*, Denver, Colorado, p. 3660, Jun. 2017
- [6] C. Duru, H. Alemdar, and O. U. Baran, "A deep learning approach for the transonic flow field predictions around airfoils," *Computers & Fluids*, vol. 236, p.105312, Mar. 2022
- [7] S. Bhatnagar, Y. Afshar, S. Pan, K. Duraisamy and S. Kaushik, "Prediction of Aerodynamic Flow Fields Using Convolutional Neural Networks," *Computational Mechanics*, vol. 64, no. 2, pp. 525-545, June 2019
- [8] Y. Zhang, W. J. Sung and D. N. Mavris, "Application of convolutional neural network to predict airfoil lift coefficient," *AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference 2018*, Kissimmee, Florida, p. 1903, Jan. 2018
- [9] K. Balla, R. Sevilla, O. Hassan and K. Morgan, "An Application of Neural Networks to the Prediction of Aerodynamic Coefficients of Aerofoils and Wings," *Applied Mathematical Modelling*, vol. 96, pp. 456-479, Aug. 2021
- [10] T. Murata, K. Fukami, and K. Fukagata, "Nonlinear mode decomposition with convolutional neural networks for fluid dynamics," *Journal of Fluid Mechanics*, vol. 882, Jan. 2020
- [11] M. Drela, "Xfoil: An Analysis and Design System for Low Reynolds Number Airfoils," *Low Reynolds number aerodynamics*, pp. 1-12, Springer, Berlin, 1989.
- [12] D. Scherer, A. Mülle, and S. Behnke, "Evaluation of pooling operations in convolutional architectures for object recognition," *International conference on artificial neural networks*, Thessaloniki, Greece, pp. 92-101, Sep. 2010
- [13] G. Berkooz, P. Holmes, and J. L. Lumley, "The proper orthogonal decomposition in the analysis of turbulent flows," *Annual review of fluid mechanics*, vol. 25, no. 1, pp. 539-575, 1993
- [14] S. Walton, O. Hassan, K. Morgan, "Reduced order modelling for unsteady fluid flow using proper orthogonal decomposition and radial basis functions," *Applied Mathematical Modelling*, vol. 37, no. 20-21, pp. 8930-8945, Nov. 2013
- [15] A. F. Agarap, "Deep learning using rectified linear units(relu)," *arXiv preprint arXiv: 1803.08375*, Mar. 2018
- [16] D. P. Kingma, and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, Dec. 2014
- [17] S. P. Pan, and Q. Yang, "A survey on transfer learning," *IEEE Transactions on knowledge and data engineering*, vol. 22, no. 10, pp. 1345-1359