

심층신경망 기반 회전익 블레이드의 단면 구조 강성 예측 모델

강병주¹, 천성우¹, 조해성^{1,†}, 기영중², 김태성³¹전북대학교 항공우주공학과²한국항공우주연구원³덴마크공과대학 풍력에너지학과

Cross-Sectional Structural Stiffness Prediction Model for Rotor Blade Based on Deep Neural Network

Byeongju Kang¹, Seongwoo Cheon¹, Haeseong Cho^{1,†}, Youngjung Kee² and Taeseong Kim³¹Department of Aerospace Engineering, Jeonbuk National University²Korea Aerospace Research Institute³Department of Wind Energy, Technical University of Denmark

Abstract

In this paper, two prediction models based on deep neural network that could predict cross-sectional stiffness of a rotor blade were proposed. Herein, we employed structural and material information of cross-section. In the case of a prediction model that used material properties as the input of the network, it was designed to predict the cross-sectional stiffness by considering elastic modulus of each cross-sectional member. In the case of the prediction model that used structural information as a network input, it was designed to predict the cross-sectional stiffness by considering the location and thickness of cross-sectional members as network input. Both prediction models based on a deep neural network were realized using data obtained by cross-sectional analysis with KSAC2D (Konkuk section analysis code – two-dimensional).

초 록

본 논문에서는 회전익 블레이드의 단면 구조 정보를 통해 블레이드의 단면 강성을 예측하고, 재료 정보를 이용하여 단면 강성을 예측할 수 있는 심층 신경망 기반 네트워크 예측 모델의 설계 및 적절성 검토를 수행하였다. 재료 정보를 네트워크 입력으로 갖는 예측 모델의 경우, 블레이드 단면 부재 재료의 탄성 계수를 네트워크의 입력으로 고려하여 단면 강성을 예측하도록 설계하였다. 또한, 단면 구조 정보를 네트워크 입력으로 갖는 예측 모델의 경우, 블레이드의 단면을 구성하는 단면 부재의 위치와 두께 정보를 네트워크 입력으로 고려하여 단면 강성을 예측하도록 설계하였다. 각 예측 모델은 심층신경망 구조를 기반으로 설계하였으며, 단면 해석 프로그램인 KSAC2D를 통한 단면 해석 결과를 네트워크의 훈련 및 검증 데이터로 사용하였다.

Key Words : Rotor Blade(회전익 블레이드), Cross-Section Analysis(단면 해석), Deep Neural Network(심층신경망), Cross-Sectional Stiffness(단면 강성)

1. 서 론

회전익 항공기나 풍력 터빈 블레이드 등의 로터 블

Received: Sep. 26, 2023 Revised: Dec. 26, 2023 Accepted: Dec. 28, 2023

† Corresponding Author

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

© The Society for Aerospace System Engineering

레이드는 특정 회전 수 범위에서 운용되며 회전에 의한 원심력, 코리올리 효과, 공력 하중 등이 작용하게 된다. 따라서 로터 블레이드의 구조 해석 및 하중 해석, 동특성 해석 등을 수행함으로써 블레이드의 구조적 강건성 및 공력탄성학적 안정성을 고려한 설계가 필요하다[1,2]. 블레이드의 구조 설계는 공력 설계를 통해 도출된 블레이드의 외형 및 공력 특성 등을 바탕으로 수행된다. 블레이드의 회전 고유진동수와 블레이

드 회전 속도의 정수배가 일치하게 되면 공진현상이 발생하여 동적 불안정을 유발하게 되며, 이를 회피하기 위해 블레이드의 동특성 해석 결과를 바탕으로 공진 회피 설계가 요구된다[2]. 복합재 로터 블레이드의 경우 복합재료의 종류, 분포, 적층 방향, 두께 등 다양한 단면 설계 변수를 고려할 수 있다[3,4].

이러한 최적 설계 과정에서 블레이드의 내부 부재에 대한 설계안이 지속적으로 변경될 수 있으며, 변경된 블레이드의 단면 구조를 반영한 단면 해석 및 동특성 해석 등을 수행해야 한다. 이에 따라 설계 초기 단계에서의 블레이드 구조 해석은 많은 반복 계산에 의한 큰 계산 비용을 요구한다. 이러한 계산 비용을 절감을 위해 딥러닝 기법을 이용하여 블레이드의 구조적 성능이나 동특성을 예측하는 연구는 활발히 진행되어 왔다.

Yoo, Seungho, et al.은 c형 스파 단면을 갖는 복합재 로터 블레이드의 진동 특성을 예측하는 심층신경망 모델을 설계하였다. 해당 연구에서는 단면 부재 중 스파 구조의 두께 분포를 입력 데이터로 사용하여, 각 모드 고유진동수를 출력 데이터로써 예측하도록 훈련을 수행하였다. 이에 따라, 단면 부재 중 스파 구조의 두께 분포가 블레이드의 길이 방향으로 감소하는 블레이드의 데이터를 예측 모델의 훈련 데이터로 사용하였으며, 스파 구조가 블레이드의 길이 방향으로 무작위 두께 분포를 갖는 데이터를 통해 예측 모델의 예측 성능을 평가하였다[5].

Nguyen, et al.은 딥러닝 기법을 기반으로 트러스 구조물의 구조 최적화를 수행하는 프레임워크에 대한 연구를 수행하였다. 해당 연구에서는 트러스 구조물의 각 절점과 구조물의 각도 등을 입력데이터로 사용하여 가해진 하중에 대하여 구조물의 변위 및 응력을 출력 데이터로써 예측하도록 예측 모델을 설계하였다. 이후, 예측 모델을 확장하여 변위 및 응력 데이터를 기반으로 최적 구조 형태를 예측 및 제시할 수 있는 예측 모델을 설계하였다. 또한, 예측 모델의 훈련 과정에서 네트워크의 하이퍼파라미터(hyperparameter) 최적화 과정을 수행함으로써 각 하이퍼파라미터들이 예측 성능 및 시간 비용에 미치는 영향을 비교 수행하였다[6].

Noh, Hong-Kyun, et al.은 합성곱 신경망 구조 기반의 2차원 이미지 합성 기법을 통하여 3차원 복합재 로터 블레이드의 동특성 예측 연구를 수행하였다. 해당 연구에서는 블레이드 길이 방향으로의 스킨과 스파의 너비 및 두께 정보, 2차원 단면 이미지를 통한 받음각 정보를 네트워크의 입력으로 사용하였다. 또한, 2차원 단면 이미지를 합성하여 합성곱 신경망 구조에 적용하여 3차원 복합재 블레이드의 팬 플롯을 예측하는 예측 모델을 설계하였다[7].

본 연구에서는 블레이드의 단면 구조와 재료 정보를

각각 이용하여 블레이드의 단면 강성을 예측하는 예측 모델을 설계하였다. 각 네트워크의 입력은 단면 부재의 재료 정보와 부재의 위치 및 두께를 고려하였다. 기존 선행 연구들의 경우 단면 부재의 구조적 특성을 고려하기 위해 일반적으로 부재의 두께와 너비 등을 고려하였으며, 부재의 위치를 고려할 경우 2차원 이미지로써 예측 모델의 학습을 수행하는 연구가 수행되었다. 스킨과 같이 매우 얇은 단면 부재의 경우 이미지를 통한 네트워크 학습이 비효율적일 수 있으며, 부재의 위치가 지속적으로 변경될 수 있는 블레이드 초기 구조 설계 과정에서 부재의 위치 변화를 효과적으로 고려하기 위해 수치화한 부재 위치 정보를 네트워크의 입력 데이터로 사용하였다. 네트워크의 훈련 및 검증 데이터는 건국대학교에서 개발한 단면 해석 프로그램인 KSAC2D[8]를 이용하였으며, 회전의 항공기의 로터 블레이드와 풍력 터빈 블레이드를 예제로 활용하여 제안하는 각 예측 모델의 정확성을 평가하였다.

2. 블레이드 단면 강성 예측 모델

2.1 로터 블레이드 단면 해석

로터 블레이드의 설계는 블레이드의 목표 설계 요구도에 따라 Fig. 1과 같은 흐름으로 수행된다. 이 중 구조설계의 경우, 공력 설계를 통해 도출된 블레이드의 외형 및 공력 특성 등을 고려하여 수행된다. 이후 도출한 구조 설계안에 대한 동특성 및 하중 해석을 수행함으로써 블레이드의 구조적 강건성 및 공력탄성학적 안정성을 확인한다.

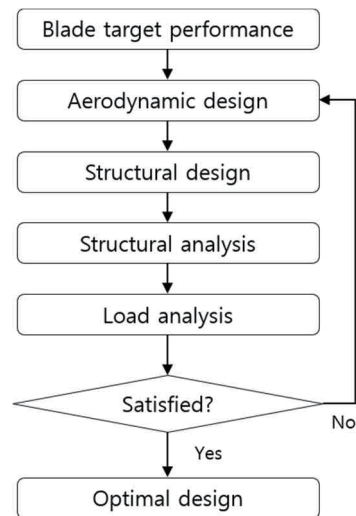


Fig. 1 Flow chart of blade design process

블레이드의 동특성 해석은 Eq. 1을 기반으로 블레이드의 고유진동수 ω 를 도출하게 되며, 이후 공진 회피

설계를 위해 블레이드의 고유진동수 ω_k 와 블레이드의 회전 수인 Ω 의 정수배가 각각 적절히 이격되어 있는지 확인함으로써 블레이드의 구조적 안정성을 판단하게 된다.

$$\begin{aligned} m\ddot{x} + c\dot{x} + kx &= 0 \\ kx &= \omega^2 m x \end{aligned} \quad (1)$$

따라서 블레이드의 구조적 안정성 확보를 위해 적절한 구조 강성이 요구됨을 확인할 수 있으며, 이에 따라 블레이드의 적절한 단면 구조 설계가 요구되는 것을 확인할 수 있다.

블레이드의 단면 해석은 통상적으로 유한요소법을 기반으로 수행되며, 각 단면 부재의 재료 물성과 단면 형상에 대한 이산화를 통해 도출되는 격자의 요소 연결성과 절점의 좌표 등을 이용한다. 단면 해석을 통해 단면 강성, 질량 행렬, 질량 중심과 전단 중심 등을 도출할 수 있으며, 이러한 단면 해석 결과를 활용하여 블레이드의 동특성 해석을 수행할 수 있다. KSAC2D는 대표적인 단면해석 프로그램으로 유한요소법을 기반으로 Fig. 2와 같은 비균질 이방성 보에 대한 2차원 단면 해석을 수행할 수 있다. 따라서 재료의 적층에 대한 적층 각도와 각 부재의 탄성 계수, 푸아송 비, 전단 계수 등의 재료 물성 정보, 단면 형상에 대한 이산화 정보를 이용하여 단면 해석을 수행하게 된다. 이를 통해 굽힘 거동 및 비틀림 거동을 모사할 수 있는 5×5 크기의 강성행렬을 계산한다[9]. 이러한 강성 행렬은 Eq. 2와 같이 보에 작용하는 하중 및 변위의 관계를 나타낸다. 이를 바탕으로 인장 중심 및 전단 중심 등의 단면 주요 중심치와 하중에 의해 단면에 부여되는 응력 및 변형률 등을 계산하게 된다.




Fig. 2 Beam configuration [9]

$$\begin{Bmatrix} F_x \\ M_x \\ M_y \\ M_z \\ M_\omega \end{Bmatrix} = \begin{bmatrix} EA & K_{12} & K_{13} & K_{14} & K_{15} \\ & GJ & K_{23} & K_{24} & K_{25} \\ & & EI_y & K_{34} & K_{35} \\ & & & EI_z & K_{45} \\ & & & & EC_\omega \end{bmatrix} \begin{Bmatrix} (u_x^0)' \\ \phi_x' \\ \phi_y' \\ \phi_z' \\ \phi_x'' \end{Bmatrix} \quad (2)$$

2.2 심층신경망

본 연구에서 정립한 단면 강성 예측 모델의 훈련 및 검증에 위해 단면 강성 정보는 전술한 단면해석 프로그램인 KSAC2D를 이용하였다. 또한 블레이드의 단면 강성 예측을 위해 심층신경망 구조를 기반으로 예측 모델을 설계하였다.

심층신경망의 구조는 Fig. 3과 같이 표현할 수 있으며, 기본적으로 입력 층과 출력 층 사이에 여러 개의 은닉층이 존재하는 인공신경망 구조를 갖는다. 이러한 심층신경망 기반의 예측 모델은 네트워크 학습을 통해 입력 값과 출력 값 사이의 가중치를 연산하게 되며, 경사 강하법이나 ADAM(adaptive moment estimation) 등의 최적화 알고리즘을 통해 실제 값과 예측 값이 최소 오차를 갖도록 하는 가중치를 연산하게 된다.

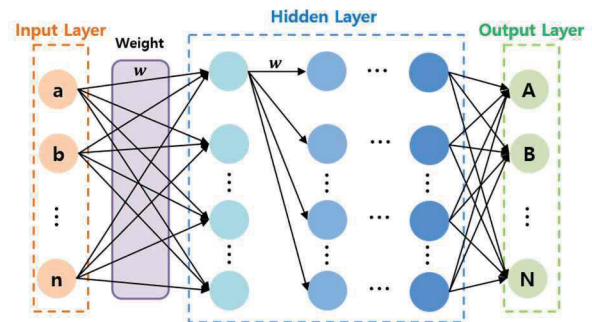


Fig. 3 Architecture of deep neural network

2.3 네트워크 구조

본 연구에서는 이러한 심층신경망 구조를 기반으로 블레이드 단면 부재의 재료 물성을 입력 값으로 사용하여 단면 강성을 예측하는 예측 모델 1과, 단면 부재의 위치와 두께를 입력 값으로 사용하여 단면 강성을 예측하는 예측 모델 2를 설계하였다.

두 예측 모델 모두 최적화 알고리즘은 ADAM을 이용하였으며, 각 뉴런의 출력 여부와 출력 값을 결정하는 활성화 함수는 Eq. 3과 같은 ELU(exponential linear unit)함수를 사용하였다. ELU 함수는 정규화 된 데이터 x 중 음수의 값을 갖는 데이터 또한 하이퍼파라미터 α 에 의해 학습 과정에 포함하게 한다. 또한, 예측 값과 실제 값 사이의 오차를 계산하는 오차 함수는 Eq. 4와 같은 평균제곱오차 함수를 사용하였으며, Eq. 4의 y_i 는 실제 값, \hat{y}_i 는 예측 값을 의미한다.

$$f(\alpha, x) = \begin{cases} x & (x > 0) \\ \alpha(e^x - 1) & (x \leq 0) \end{cases} \quad (3)$$

$$E = \frac{1}{2} \sum_i (y_i - \hat{y}_i)^2 \quad (4)$$

또한, 두 예측 모델의 입출력 변수를 재료 물성, 단면 구조 정보, 단면 강성 등을 고려함에 따라 각 입출력 값은 모두 서로 다른 분포를 갖게 되며, 일부 입력 값에 의해 이상치로 분류될 수 있는 데이터를 가질 수 있다. 이에 따라, 데이터 스케일링 기법을 이용하여 네트워크의 학습에 적합한 데이터 분포를 갖도록 데이터의 전처리 과정을 수행하였으며, 스케일링 기법은 Robust scaler를 이용하였다. Robust scaler는 Eq. 5와 같이 계산되며, 데이터의 중앙값과 사분위 편차를 이용하여 데이터 정규화를 수행하기 때문에 이상치에 의한 영향이 비교적 적다. Equation. 5의 x_{medin} 은 데이터의 중앙값을 의미하며, Q_1 은 데이터 분포 중 25% 지점의 데이터, Q_3 는 75% 지점의 데이터를 의미한다.

$$x_{skat} = \frac{x - x_{medin}}{Q_3 - Q_1} \quad (5)$$

2.3.1 예측 모델 1

예측 모델 1의 경우, 예측 모델을 통한 블레이드 단면 강성 예측의 유효성을 확인하기 위해 비교적 적은 입출력 변수만을 고려하여 예측 모델을 설계하였다. 이에 따라, 예측 모델 1의 네트워크 입력은 블레이드의 단면을 구성하는 각 단면 부재의 탄성 계수를 고려하였으며, 단면 주요 강성치 중 탄성 계수에 의해 계산되는 인장 강성(EA), 단면 두께 방향 굽힘 강성(EI_{fp}), 시위 길이 굽힘 강성(EI_{hg})을 네트워크의 출력으로 고려하여 예측 모델을 설계하였다. 예측 모델 1의 네트워크 구조는 8개의 은닉층을 가지며 각 은닉층을 구성하는 뉴런은 300개를 사용하였다.

2.3.2 예측 모델 2


예측 모델 2는 블레이드의 단면을 구성하는 단면 부재의 위치와 두께를 네트워크의 입력으로 고려하였으며, 네트워크의 출력은 단면 주요 강성인 EA, GJ, EI_{fp} , EI_{hg} 와 주요 강성치 간의 연성 항인 $K_{13}(EA - EI_{fp})$, $K_{14}(EA - EI_{hg})$, $K_{34}(EI_{fp} - EI_{hg})$ 를 고려하여 예측 모델을 설계하였다. 예측 모델 2의 경우, 네트워크 학습에 사용되는 네트워크 입출력 변수의 수가 모델 1에 비하여 증가함에 따라 네트워크의 예측 성능을 고려하여, 10개의 은닉층과 500개의 뉴런을 사용하여 네트워크 구조를 구성하였다.

3. 네트워크 훈련 및 결과


3.1 예측 모델 1의 훈련 및 검증

예측 모델 1의 훈련 및 검증을 위한 예제는 Sharpe's rotor[10,11] 블레이드의 단면을 이용하였으

며, Sharpe's rotor 블레이드의 단면 형상과 단면에 대한 이산화를 수행한 형상은 Fig. 4에 나타내었다.



(a) Sharpe's rotor blade [11]



(b) Discretized model of blade cross-section

Fig. 4 Example blade for prediction Model 1

예측 모델 1의 훈련 데이터 생성을 위해 정의한 각 입력 값의 설계 파라미터 공간과 출력항을 Table 1에 정리하였으며, 해당 공간 내에서 LHS(Latin hypercube sampling) 기법을 이용하여 총 980개의 데이터를 생성하였다.

Table 1 Design parameter space of Model 1

| Design parameter space [GPa] | |
|------------------------------|-----------------------------|
| Input | Weight $E \in [5, 300]$ |
| | Foam $E \in [0.001, 3.45]$ |
| | Spar $E_{11} \in [5, 200]$ |
| | Spar $E_{22} \in [5, 200]$ |
| | Skin $E_{11} \in [10, 200]$ |
| | Skin $E_{22} \in [10, 200]$ |
| Components | |
| Output | EA |
| | EI_{fp} |
| | EI_{hg} |

네트워크의 훈련 과정에서 데이터 샘플링을 통해 생성한 980개의 데이터 중 780개의 데이터를 훈련 데이터로 사용하였으며, 100개의 데이터를 검증 데이터로 사용하였다. 훈련 과정에 사용되지 않은 나머지 100개의 데이터는 네트워크 예측 성능 확인을 위한 테스트 데이터로 사용하였다. 훈련 과정에서의 훈련 및 검증 데이터의 손실률은 Fig. 5와 같다.




Fig. 5 Training history of Model 1

이후, 훈련 과정에 사용되지 않은 100개의 테스트 데이터를 통해 네트워크의 예측 성능을 확인하였다. 예측 모델이 테스트 데이터를 통해 예측한 예측 값과 KSAC2D를 통한 실제 단면 해석 결과를 비교하여 Fig. 6(a)-(c)에 나타내었다.

네트워크 예측 성능의 정량적 평가를 위해 네트워크의 예측 값과 실제 값에 대한 상대 오차와 결정 계수를 계산하였으며, 100개의 테스트 데이터에 대한 평균 상대 오차(Mean Relative Error, MRE)와 결정 계수(R^2)를 Table 2에 나타내었다.

실제 값과 예측 값 사이의 상대 오차는 Eq. 6을 통해 도출하였으며, 결정 계수는 Eq. 7-9를 통해 도출하였다. Eq. 6-9의 y 는 실제 값, \hat{y} 는 예측 값을 나타내며,

\bar{y} 는 실제 값의 평균을 의미한다. 예측 모델 1의 네트워크 예측 성능 평가 결과, 실제 값과 예측 값 사이의 평균 상대 오차는 모두 3% 미만으로 도출되는 것을 확인하였다.

$$e_{relative}(y, \hat{y}) = \frac{|y - \hat{y}|}{y} \quad (6)$$

$$R^2 = 1 - \frac{SSR}{SST} \quad (7)$$

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (9)$$

Table 2 Prediction results of Model 1

| | MRE (%) | R^2 |
|-------------|---------|--------|
| EA | 2.213 | 0.9758 |
| EI_{flap} | 0.693 | 0.9981 |
| EI_{lag} | 1.578 | 0.9969 |

3.2 예측 모델 2의 훈련 및 검증

예측 모델 2는 블레이드 단면 부재의 위치와 두께 정보를 이용하여 단면 강성을 예측하는 예측 모델이며, 예측 모델의 훈련 및 검증을 위한 예제 블레이드는 미국 NREL(National Renewable Energy Laboratory)의 IEA 15MW 기준 풍력 터빈 블레이드[12]를 사용하였다. IEA 15MW 기준 풍력 터빈 블레이드의 형상은 Fig. 7(a)와 같으며, 예측 모델의 훈련에 사용한 블레이드의 길이 방향 30% 지점의 단면에 대한 이산화 형상은 Fig. 7(b)에 나타내었다.




Fig. 6 Comparison of predicted values for Model 1

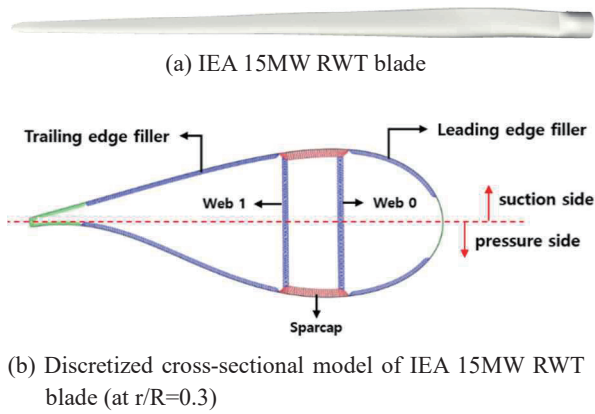


Fig. 7 Example blade for prediction Model 2

풍력 터빈 블레이드의 강성에 주요한 영향을 미치는 스파와 웹에 대한 각 부재의 위치와 두께 정보를 예측 모델의 입력 변수로 고려하였으며, 단면 주요 강성과 주요 강성 간의 연성 항인 K_{13} , K_{14} , K_{34} 를 출력 변수로 고려함으로써 총 7 개의 출력 변수를 고려하였다.




Fig. 8 Geometric parameterization for Model 2

단면 부재의 위치를 예측 모델의 학습에 효과적으로 반영하기 위해 부재의 위치를 수치화하여 입력 변수로 사용하였다. 부재 위치의 수치화 방법은 Fig. 8과 같이 단면 에어포일의 끝단을 기준으로 에어포일의 둘레 길이를 무차원 화하여 각 부재가 에어포일에 놓인 위치를 수치화 (S) 하였다. 이에 따라, 통상적으로 에어포

일의 앞전 부분에 $S = 0.5$ 인 지점이 존재하며, 각 부재가 에어포일에 놓인 지점 중 더 작은 S를 갖는 지점을 부재의 시작점으로 정의하였다.

해당 수치화 방법에 따라, 예측 모델 2의 입력 변수 중 부재의 위치는 Web 0, 1의 시작점과 윗면 및 아래면에 대한 각 스파 캡의 시작점과 끝점을 고려하였다. 이때, Web은 시위선에 직교하도록 가정하였기 때문에, 각 Web의 시작점과 끝점의 합은 항상 같으며 이를 바탕으로 예측 모델의 입력 변수로 시작점만을 고려하였다. 예측 모델 2의 훈련 데이터 생성을 위해 정의한 입력 값의 설계 파라미터 공간과 출력 값으로 고려된 강성치를 Table 3에 정리하였다.

설계 파라미터 공간 내에서 LHS 기법을 이용하여 총 980개의 데이터를 생성하였으며, 980개의 데이터 중 780개의 데이터를 훈련 데이터, 100개의 데이터를 검증 데이터로 사용하여 네트워크의 훈련을 수행하였다. 훈련 과정에 사용되지 않은 나머지 100개의 데이터는 네트워크 예측 성능 확인을 위한 테스트 데이터로 사용하였다. 예측 모델 2의 훈련 과정에 따른 손실률은 Fig. 9에 나타내었다.

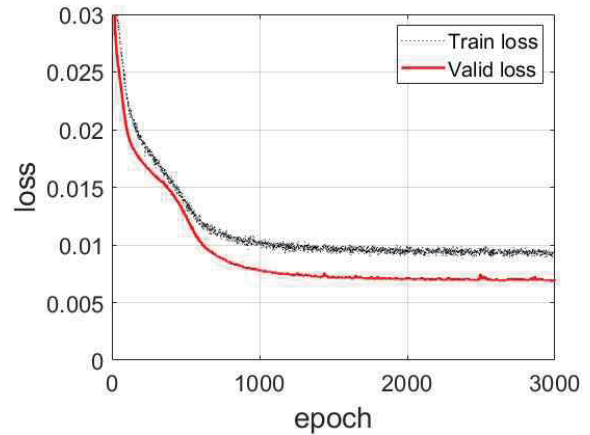


Fig. 9 Training history of Model 2

Table 3 Design parameter space of Model 2

| Design parameter space | | Components |
|------------------------|--|--|
| Input | Web 0 Start Point $S \in [0.32, 0.39]$ | Output EA GJ EI_{fp} EI_{hg} K_{13} K_{14} K_{34} |
| | Web 1 Start Point $S \in [0.24, 0.31]$ | |
| | Suction side Spar cap Start Point $S \in [0.32, 0.39]$ | |
| | Suction side Spar cap End Point $S \in [0.34, 0.41]$ | |
| | Pressure side Spar cap Start Point $S \in [0.58, 0.65]$ | |
| | Pressure side Spar cap End Point $S \in [0.69, 0.76]$ | |
| | Thickness of Web $\in [0.08 \text{ m}, 0.11 \text{ m}]$ | |
| | Thickness of Spar cap $\in [0.03 \text{ m}, 0.04 \text{ m}]$ | |

이후, 네트워크의 훈련 과정에 사용되지 않은 나머지 100개의 테스트 데이터를 통해 네트워크가 예측한 예측 값과 실제 값을 비교하여 Fig. 10과 11에 나타내었다.

네트워크 예측 성능의 정량적 평가를 위해 실제 값과 예측 값 사이의 평균 상대 오차와 결정 계수를 계산하였으며, 예측 모델 2의 예측 성능 평가 결과, 실제 값과 예측 값 사이의 평균 상대 오차는 모두 4% 미만으로 나타나는 것을 확인하였다. 예측 성능 평가 결과에 대한 평균 상대 오차와 결정 계수를 Table 4에 정리하였다.

Table 4 Prediction results of Model 2

| | MRE (%) | R ² |
|--------------------|---------|----------------|
| EA | 2.597 | 0.973 |
| GJ | 0.572 | 0.989 |
| El _{flap} | 3.029 | 0.968 |
| El _{lag} | 1.079 | 0.995 |
| K ₁₃ | 1.505 | 0.987 |
| K ₁₄ | 2.108 | 0.977 |
| K ₃₄ | 3.166 | 0.955 |

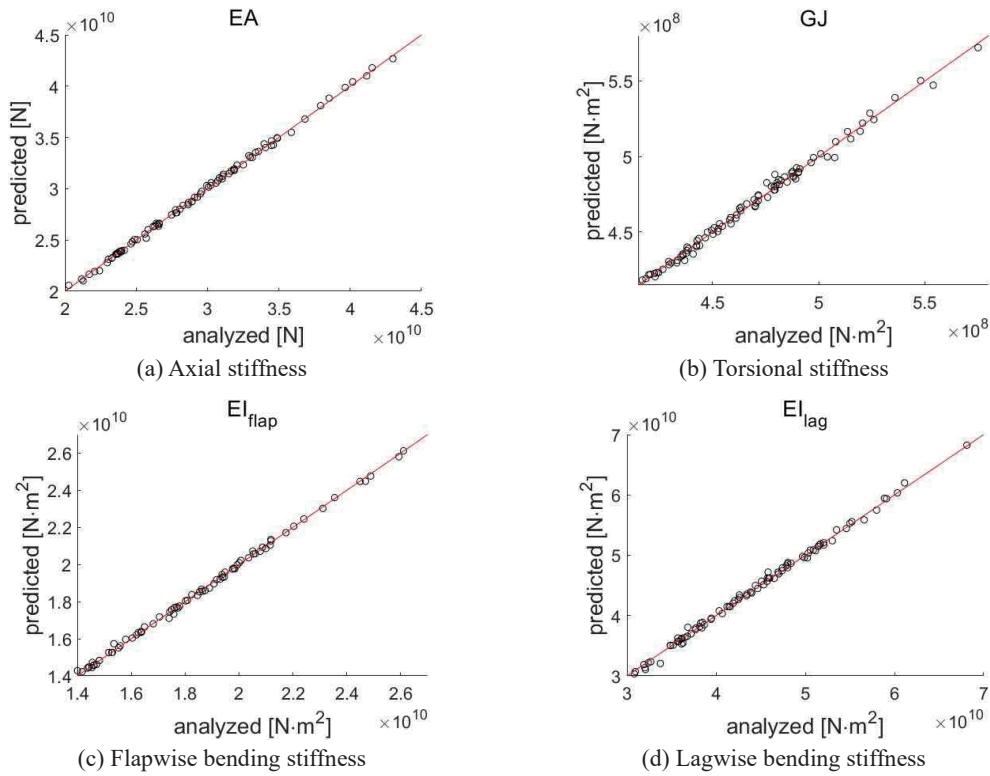


Fig. 10 Comparison of predicted values for Model 2




Fig. 11 Comparison of predicted values (coupling stiffness) for Model 2

5. 결 론

본 논문에서는 심층신경망을 이용하여 로터 블레이드의 단면 강성을 예측하는 예측 모델을 설계하였다. 예측 모델은 네트워크의 입출력에 따라 예측 모델 1과 2로 나누어 두 가지 예측 모델을 설계하였다.

예측 모델 1은 Sharpe's rotor 블레이드의 단면을 예제로 사용하였으며, 블레이드의 단면을 구성하는 각 부재의 탄성 계수를 네트워크의 입력으로 고려하여 단면 주요 강성인 EA , EI_{bp} , EI_{bg} 를 네트워크의 출력으로 고려하였다. 또한, 예측 모델 2는 IEA 15MW 기준 풍력 터빈 블레이드의 길이방향 30% 위치의 단면 형상을 예제로 사용하였으며, 단면 부재의 위치와 두께를 네트워크의 입력으로 사용하여 EA , GJ , EI_{bp} , EI_{bg} , K_{13} , K_{14} , K_{34} 항을 네트워크의 출력으로 예측하도록 설계하였다.

각 예측 모델의 훈련 및 검증을 위한 출력 데이터는 단면 해석 프로그램인 KSAC2D를 이용한 단면 해석 결과를 이용하여 네트워크의 학습을 수행하였다. 이후, 네트워크의 예측 성능 평가를 위해 훈련 과정에 포함되지 않은 데이터를 이용하여 예측 모델의 평가를 수행하였으며, 각 예측 모델의 예측 값과 실제 값에 대한 평균 상대 오차와 결정 계수를 계산하여 예측 성능 평가를 수행하였다.

예측 성능 평가 결과, 예측 모델 1의 경우 각 출력항에 대한 예측 값과 실제 값 사이의 평균 상대 오차는 모두 3% 미만으로 도출되는 것을 확인하였으며, 결정 계수는 0.97 이상으로 잘 예측됨을 확인하였다. 또한, 예측 모델 2의 경우 각 출력항에 대한 예측 값과 실제 값 사이의 평균 상대 오차는 모두 4% 미만이며, 결정 계수는 0.95 이상으로 잘 예측됨을 확인하였다. 향후, 재료 물성과 단면 부재의 위치 및 두께를 동시에 고려하여 단면 강성을 예측하는 예측 모델을 설계할 예정이며, 이후 재료의 적층 각도와 다양한 형상의 단면 등을 추가적인 네트워크 입력으로 고려함으로써 예측 모델을 확장할 예정이다.

후 기

본 논문은 2023년도 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임 (No. KRIT-CT-22-082, 고속장거리 기동헬기 개발 기술(Build-I)-강체 동축 주로터 시스템 설계/제작 기술).

References

- [1] Hodges, Dewey H. "Review of composite rotor blade modeling.", *AIAA journal*, vol. 28(3), pp. 561-565, 1990.
- [2] Chellil, A., et al. "Aeroelastic stability analysis of composite rotor blade.", *2013 5th International Conference on Modeling, Simulation and Applied Optimization (ICMSAO)*, Hammamet, Tunisia, 2013.
- [3] Kong, Changduk, Minwoong Kim, and Hyunbum Park. "A study on structural design and analysis of large scale and high efficiency blades for wind turbine system." *Journal of Aerospace System Engineering*, vol. 6(4), pp. 7-11, 2012.
- [4] Won, You-Jin, and Soo-Yong Lee. "Optimal Design of Composite Rotor Blade Cross-Section using Discrete Design variable." *Journal of Aerospace System Engineering*, vol. 8(1), pp. 12-17, 2014.
- [5] Yoo, Seungho, et al. "Prediction of Vibration Characteristics of a Composite Rotor Blade via Deep Neural Networks.", *Journal of Korean Astronomical Society*, vol. 50(5), pp. 317-323, 2022.
- [6] Nguyen, Long C., and H. Nguyen-Xuan. "Deep learning for computational structural optimization.", *ISA transactions*, vol. 103, pp. 177-191, 2020.
- [7] Noh, Hong-Kyun, et al. "Surrogate modeling of the fan plot of a rotor system considering composite blades using convolutional neural networks with image composition." *Journal of Computational Design and Engineering*, vol. 10(3), pp.1250-1266, 2023.
- [8] Jung, Sung Nam, et al. "Cross-sectional constants of composite blades using computed tomography technique and finite element analysis." *Composite Structures*, vol. 129, pp. 132-142, 2015.
- [9] Bae, Jae-Seong, et al. "Validation Study of Composite Rotor Blade Sectional Analysis Program (Ksec2d-AE)." *Journal of the Korean Society for Aeronautical & Space Sciences*, vol. 46(4), pp. 277-282, 2018.
- [10] Shang, Xiaoyang, Dewey H. Hodges, and David A. Peters. "Aeroelastic stability of composite hingeless rotors in hover with finite-state unsteady aerodynamics." *Journal of the American Helicopter Society*, vol. 44(3), pp. 206-221, 1999.
- [11] Sharpe, David L. "An experimental investigation of the flap-lag-torsion aeroelastic stability of a small-scale hingeless helicopter rotor in hover.", NASA TP-2546, 1986.
- [12] Gaertner, Evan, et al. "IEA wind TCP task 37: definition of the IEA 15-megawatt offshore reference wind turbine.", National Renewable Energy Lab.(NREL), Golden, CO (United States), NREL TP-5000-75698, 2020.