

## 심층신경망을 이용한 CFRP 복합재 구조의 공정 유도 스프링백 예측

이유선<sup>1</sup>, 김동협<sup>2,4</sup>, 김상우<sup>2,3,4,†</sup>, 이수용<sup>4</sup><sup>1</sup>한경국립대학교 ICT로봇기계공학부<sup>2</sup>한국항공대학교 항공우주 및 기계공학과<sup>3</sup>한국항공대학교 항공우주공학과<sup>4</sup>한국항공대학교 항공우주산업기술연구소Prediction of Process-Induced Spring-Back of CFRP Composite Structure  
Using Deep Neural NetworkYuseon Lee<sup>1</sup>, Dong-Hyeop Kim<sup>2,4</sup>, Sang-Woo Kim<sup>2,3,4,†</sup> and Soo-Yong Lee<sup>4</sup><sup>1</sup>School of ICT, Robotics & Mechanical Engineering, Hankyong National University<sup>2</sup>Department of Aerospace and Mechanical Engineering, Korea Aerospace University<sup>3</sup>Department of Aeronautical and Astronautical Engineering, Korea Aerospace University<sup>4</sup>Research Institute of Aerospace Engineering and Technology, Korea Aerospace University

## Abstract

A deep neural network (DNN) was employed to predict the spring-back of a CFRP composite spar induced by the curing process. A total of 816 spring-back data points, derived from varying stacking angles, layer counts, and flange radii, were generated through finite element method (FEM)-based curing analysis to train the DNN model. The trained model demonstrated an R-squared value of 0.99 and a mean squared error of 0.00093, indicating excellent performance. For untrained flange radii, the spring-back predicted by the DNN exhibited a mean relative error of 2.18% when compared to FEM results. Additionally, while FEM analysis required approximately 20 minutes, the DNN-based prediction required only about 14 milliseconds. These results highlight the potential of using DNNs for the rapid prediction of process-induced deformation in CFRP composites.

## 초 록

본 연구에서는 심층신경망을 활용하여 CFRP 복합재 스파의 경화 공정에 의한 스프링백을 예측하였다. 유한요소법 기반 경화 해석을 통해 적층 각, 적층 수, 플랜지 반경에 따른 총 816 개의 스프링백 데이터를 생성하여 심층신경망 모델을 학습시켰다. 학습된 모델의 R-squared 값은 0.99, 평균제곱오차는 0.00093으로 산출되어 모델 성능이 우수함을 확인하였다. 학습되지 않은 플랜지 반경에 대한 스프링백 예측 결과, 유한요소해석 결과와 비교하여 평균 상대오차는 2.18%로 나타났다. 또한, 유한요소해석은 약 20 min이 소요된 반면, 심층신경망을 통한 예측 시간은 약 14 ms에 불과하였다. 이를 통해 CFRP 복합재의 공정 유도 변형을 빠르게 예측하기 위한 심층신경망의 활용 가능성을 확인하였다.

**Key Words** : Carbon Fiber Reinforced Plastics(탄소 섬유 강화 플라스틱), Curing Process(경화 공정), Process-Induced Deformation(공정유도 변형), Deep Learning(딥러닝), Deep Neural Network(심층신경망)

## 1. 서 론

탄소 섬유 강화 플라스틱(CFRP; carbon fiber

reinforced plastics)은 비강도와 비강성이 높아 구조재의 경량화가 중요한 항공우주와 자동차 산업에서 주목받고 있다[1-3].

CFRP 복합재는 경화 공정 중 예상치 못한 변형(PID; process-induced deformation)이 발생하며, 이는 제품의 물성과 치수 변화를 초래한다. Fig. 1은 굽어진 구조물에서 나타나는 스프링백(spring-back)과 스프링인(spring-in) 변형을 보여준다.

Received: Aug. 02, 2024 Revised: Aug. 19, 2024 Accepted: Aug. 22, 2024

† Corresponding Author

Tel: +82-02-200-0286, E-mail: swkim@kau.ac.kr

© The Society for Aerospace System Engineering




Fig. 1 (a) Process-Induced Spring-Back and (b) Spring-In of CFRP Composite Structure

이러한 변형이 허용 오차 범위를 벗어나면 제품과 금형의 재가공으로 인해 추가적인 비용과 시간이 요구된다. 따라서 복합재 구조의 품질을 보장하고 제품 개발 비용과 시간을 절감하기 위해 PID를 미리 예측하여 복합재 구조 설계에 반영해야 한다[4]. 그러나 PID는 적층 재료와 패턴, 두께와 형상, 경화 주기 등 수많은 공정 변수에 영향을 받는다. 이처럼 많은 변수를 고려하여 복합재 구조의 PID를 예측하고 설계에 반영하기 위해서는 정확할 뿐만 아니라 빠른 계산이 가능한 예측 방법이 개발되어야 한다.

복합재 구조의 PID 예측에는 주로 유한요소법(FEM; finite element method)이 사용된다[5-6]. 그러나 FEM은 비선형 재료 물성과 복잡한 형상을 갖는 구조물의 경화 해석 시 많은 계산 비용과 시간을 요구한다. 따라서 기계 학습(machine learning)을 도입하여 많은 변수를 고려하면서 빠르게 복합재의 PID를 예측하는 연구의 필요성이 제기되고 있다[7-9]. Hou 등[10]은 역전파(back propagation), 유전 알고리즘-역전파(genetic algorithm-back propagation), 방사 기저 함수(radial basis function) 신경망 모델을 활용하여, 열경화성 복합재의 압축 성형 공정에서 발생하는 온도차와 경화도를 예측하기 위한 다양한 머신러닝 모델을 개발하고 비교하였다. 각 모델의 성능을 비교한 결과, 방사 기저 함수 신경망이 가장 좋은 예측 성능을 보였다. Fan 등[11]은 합성곱 신경망(CNN; convolutional neural network) 모델을 활용하여 CFRP 복합재의 PID를 예측하였다. 적층 순서, 섬유 방향, 온도 변화를 고려한 복합재 구조의 PID를 시각적으로 표현한 클라우드 맵을 사용하여 CNN 모델을 학습시켰다. 항공기

복합재 테일 러더(rudder)의 CNN 모델을 통한 PID 예측은 9.671 s가 소요된 반면, FEM은 6 min 이상 소요되었다. 또한, CNN 모델을 사용하여 예측한 PID의 정확도는 96%에 달하여 우수한 성능을 나타냈다.

본 연구에서는 딥러닝(deep learning) 기법의 일종인 심층 신경망(DNN; deep neural network)을 활용하여 CFRP 복합재 스파(spar)의 공정 유도 스프링백을 예측한다. FEM 기반 경화 해석을 통해 스프링백 데이터를 생성하여 DNN 모델을 학습시킨다. 학습 범위 내외의 플랜지 반경에 대한 스프링백을 예측하고, FEM 기반 경화 해석 결과와 비교하여 모델 성능을 평가한다. 이를 통해 복합재의 공정 유도 변형을 빠르게 예측하기 위한 DNN의 활용 가능성을 확인한다.

## 2. 학습 데이터 생성

### 2.1 유한요소법 기반 경화 해석

본 연구에서는 Fig. 2에 나타낸 것과 같이 항공기 날개의 CFRP 복합재 토션 박스(torsion box)에 적용된 스파에 대한 PID를 예측하였으며, 스파 구조는 경화 공정 중 스프링백(또는 스프링인) 변형이 발생한다.




Fig. 2 CFRP Spar in Aircraft Wing Torsion Box

평직(plain woven) AS4/3501-6 프리프레그(prepreg)의 물성을 적용하였고, Kim 등[5]이 제안한 PID 예측 절차에 따라 경화 모델링을 구축하였다. 이때 Eqs. 1-3에 나타낸 수정 Arrhenius 방정식 기반의 경화 동역학 모델을 통해 3501-6 수지의 경화 조건에 따른 경화도를 계산하였다[12].

$$\alpha(t) = \int_0^t \frac{d\alpha}{dt} dt \quad (1)$$

$$\frac{d\alpha}{dt} = \begin{cases} (K_1 + K_2\alpha)(1-\alpha)(0.47-\alpha) & \alpha \leq 0.3 \\ K_3(1-\alpha) & \alpha > 0.3 \end{cases} \quad (2)$$

$$K_r = A_r \exp\left(\frac{-\Delta E_r}{RT}\right); \quad (r=1, 2, 3) \quad (3)$$

여기서  $A_r$  과  $\Delta E_r$  은 지수 인자와 활성화 에너지이며,  $R$  과  $T$  는 기체 상수와 온도를 의미한다. 또한 복합재의 경화도에 따른 물성 변화를 산출하기 위해 Liu 등 [13]이 제안한 구성 모델을 적용하였으며, 이는 Eqs. 4-5로 표현된다.

$$C^y = \begin{cases} C^{y0} & T > T_g(\alpha) \\ \left[\frac{T_c - T}{T_c - T_g(\alpha)}\right]^2 C^{y0} + \left[\frac{T - T_g(\alpha)}{T_c - T_g(\alpha)}\right]^2 C^{y1} & T \leq T_g(\alpha), T > T_c \\ C^{y1} & T \leq T_g(\alpha), T < T_c \end{cases} \quad (4)$$

$$T_g(\alpha) = 283.34 + 11.86\alpha + 178.04\alpha^2 \quad (5)$$

여기서  $C^y$  는 강성행렬이며,  $T_g$  와  $T_c$  (395.87 K)는 각각 유리전이 온도와 임계 온도를 나타낸다. 또한 위 첨자 “0”과 “1”은 각각 고무(rubbery) 상태와 고체 상태를 의미한다.




Fig. 3 (a) FE Model of Spar and (b) Curing Cycle used in Curing Simulation

상용 FEM 소프트웨어인 ABAQUS/Standard를 활용하여 경화 공정에 대한 과도(transient) 해석을 수행하였고, 사용자 재료 정의 부 프로그램(UMAT)을 통해 Eqs. 1-5에 나타난 CFRP 복합재의 경화 모델링을 FEM과 연동시켰다. 해석 속도를 단축시키기 위해 3D Shell 요소(element)로 CFRP 복합재 스파를 모델링하였고, 대칭(symmetry) 경계 조건을 부여하였다. 열진달 해석과 경화 변형 해석에는 각각 DS8과 S8R 요소를 사용하였고, 910 개의 요소와 2,853 개의 절점을 동일하게 적용하였다. Fig. 3은 경화 해석에 사용된 스파의 FE 모델과 경화 사이클을 보여준다. 본 연구에서는 스파의 두께가 3 mm 미만임을 감안하여, Chen 등 [14]의 연구 결과에 따라 스파 전체에 걸쳐 온도 분포가 균일함을 가정하였다. 따라서 Fig. 3(b)에 나타난 경화 사이클을 스파 전체에 균일하게 적용하였다.

본 연구에서는 Table 1에 나타난 적층 각, 적층 수, 플랜지 반경에 따라 스파의 경화 해석을 수행하였다.

Table 1 Manufacturing Parameters Used in Curing Simulation for CFRP Spar

Parameters	Values	Units
Stacking Angle	0, 45	deg.
No. of Plies	4, 8	Plies
Flange Radius	5, 10, 15	mm

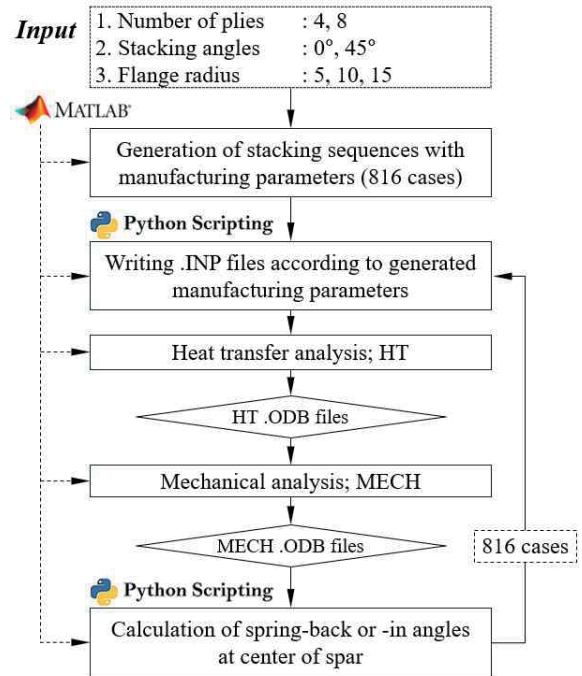


Fig. 4 Flowchart for Curing Simulation with Manufacturing Parameters

각 변수에 대한 모든 경우의 수는 총 816 가지로, Fig. 4에 나타난 것과 같이 MATLAB과 ABAQUS Python scripting을 활용하여 FEM 기반 경화 해석에 대한 전처리와 스프링백 각도 계산을 위한 후처리 자동화 코드를 구축하였다.

MATLAB을 통해 적층 각, 적층 수, 플랜지 반경에 따른 적층 패턴(stacking sequence) 조합을 생성하였다. 생성된 적층 패턴에 따라 Python scripting을 활용하여 스파의 열전달 해석과 경화 변형 해석에 대한 INP 파일을 작성하였다. 이후 열전달 해석을 통한 온도 분포를 경화 변형 해석에 반영하여 스파의 스프링백 각도를 계산하였다.

Figure 5는 FEM 기반 경화 해석을 통해 도출된 최종 경화 시점에 대한 스파의 PID 경향을 보여준다.

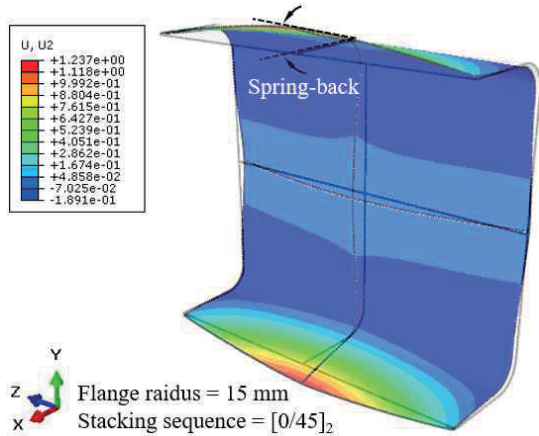


Fig. 5 Process-Induced Spring-Back of Fully Cured Spar

본 연구에서는 스파 중심부에 대한 스프링백 각도를 계산하여 DNN의 학습 데이터로 활용하였다.

## 2.2 DNN 학습 데이터 전처리

DNN 모델 학습에 사용된 입력 데이터는 Table 1에 나타난 적층 각, 적층 수, 플랜지 반경이고, 출력 데이터는 Fig. 5에 나타난 최종 경화된 스파 중심부의 스프링백 각도이다. 총 816 개의 스프링백 각도 데이터를 추출하였으며, 이 중 87%(706 개)를 DNN 모델 학습에 사용하였고, 나머지 13%(110 개)를 모델의 성능 검증에 활용하였다.

Figure 6은 FEM 기반 경화 해석을 통해 추출된 CFRP스파 구조의 스프링백 각도 데이터의 분포를 보여준다. Fig. 6(a)에 나타난 것과 같이 추출된 데이터에는 일반적인 데이터 분포에서 크게 벗어난 이상치(outlier)가 검출되었다. 이상치는 모델의 학습 과정에서 편향된 학습과 손실 함수(loss function)의 왜곡을 야기하고, 과적합(overfitting) 문제와 신뢰성 저하를

유발한다. 이는 모델의 성능과 신뢰성을 크게 저하시키므로 이상치를 최소화하기 위한 방안이 요구된다.

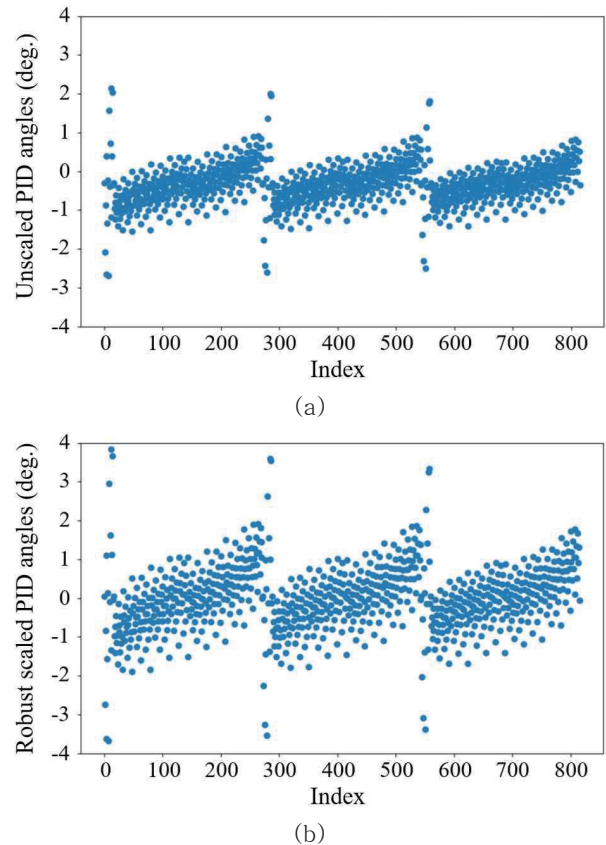


Fig. 6 Spring-Back Angles Acquired from FE-Based Curing Simulation: (a) Unscaled, (b) Robust Scaled

본 연구에서는 이상치의 영향을 최소화하기 위해 로버스트 스케일러(robust scaler)를 사용하여 데이터 전처리를 수행하였다. 로버스트 스케일러는 데이터의 평균(mean)이나 표준편차(standard deviation)를 사용하는 대신 중앙값과 사분위수 범위(IQR; interquartile range)을 통해 데이터 범위를 조정한다. 평균과 표준편차는 이상치에 민감하지만, 중앙값과 IQR은 이상치의 영향을 거의 받지 않는다. 따라서, 로버스트 스케일러는 이상치가 있는 데이터에 대해서도 안정적으로 데이터 범위 조정이 가능하다. 또한 데이터의 중앙값을 기준으로 범위를 조정하므로 전처리 이후에도 데이터 분포의 중심을 잘 유지하여 이상치가 포함된 데이터셋에 매우 적합하다. 로버스트 스케일러는 Eq. 6과 같이 계산된다.

$$X_{\text{scaled}} = \frac{X - \text{median}(X)}{IQR(X)} = \frac{X - \text{median}(X)}{Q_3 - Q_1} \quad (6)$$

여기서  $median(X)$  는 데이터의 중앙값,  $Q_3$  은 3사분위수,  $Q_1$  은 1사분위수를 의미한다. 로버스트 스케일러를 이용하여 데이터 전처리가 수행된 데이터 분포를 Fig. 6(b)에 나타내었다.

### 3. 심층 신경망

DNN 모델은 인간의 뇌 신경망 구조를 모방한 인공신경망(artificial neural network) 중 하나로 Fig. 7과 같이 입력층(input layer)과 출력층(output layer) 사이에 두 개 이상의 은닉층(hidden layer)을 포함한다 [13].




Fig. 7 DNN Model Structure

각 층은 다수의 노드(node)로 구성되며, 각 노드는 이전 층의 노드로부터 입력 값을 받는다. 이후 입력 값에 가중치(weight)와 편향(bias)을 적용한 뒤, 활성화 함수(activation function)를 이용하여 다음 층으로 출력 값을 전달한다[15].

본 연구에서는 입력층, 출력층, 100 개의 뉴런으로 구성된 10 개의 은닉층으로 DNN 모델을 구축하였다. 입력층은 적층 각, 적층 수, 플랜지 반경을 나타내기 위해 9 개의 뉴런으로 구성되었고, 출력층의 뉴런은 최종 경화된 스파 중심부의 스프링백 각도를 나타낸다. 또한, 복잡한 비선형 관계를 갖는 경화 해석 결과를 고려하여 모델의 복잡성을 증가시키기 위해 모든 층이 이전 층의 모든 뉴런과 연결되는 완전 연결 계층(fully-connected layer)으로 DNN 모델을 구성하였다.

본 연구에서는 ReLU(rectified linear unit) 함수를 활성화 함수로 사용하였다. ReLU 함수는 연산이 빠르고 비선형 함수로 신경망의 비선형성을 도입하여 복잡한 함수 근사를 가능하게 한다. ReLU 함수는 Eq. 7과 같이 표현된다.

$$\text{ReLU}(x) = \max(0, x) \quad (7)$$

여기서  $x$  는 입력 값으로  $x$  가 양수일 때는 그 값을 그대로 반환하고, 0 이하일 때는 0을 반환한다.

신경망 모델의 최적화에 필요한 파라미터를 조정하고, 학습 속도를 높여 모델을 안정적으로 학습하기 위해 ADAM(adaptive moment estimation) optimizer를 사용하였다[17-18]. 이때 평균 제곱 오차(MSE; mean squared error)를 손실 함수로 사용하였으며, 손실 함수를 최소화하여 모델의 성능을 극대화하였다. MSE는 Eq. 8과 같이 계산된다.

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

여기서  $n$  은 데이터의 개수,  $y_i$  는 해석 값,  $\hat{y}_i$  는 예측 값을 의미한다.

### 4. 결 과

#### 4.1 DNN 모델 성능 평가

본 연구에서는 FEM 기반 경화 해석을 통해 추출된 816 개의 데이터 중 13%를 모델의 성능 평가에 사용하였다. 이때 결정계수 R-squared와 MSE를 통해 학습된 DNN 모델의 성능을 평가하였다.

R-squared는 해석 값과 예측 값 사이의 관계를 나타내며, Eqs. 9-12를 통해 계산된다.

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST} \quad (9)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (10)$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad (11)$$

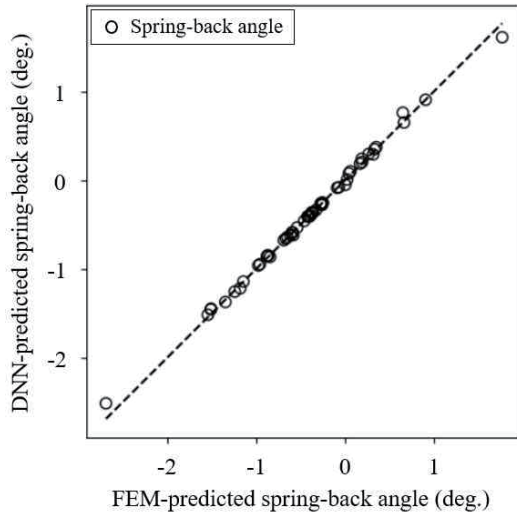
$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

여기서  $y_i$  는 해석 값,  $\bar{y}$  는 해석 값의 평균,  $\hat{y}_i$  는 예측 값을 의미한다. R-squared는 0과 1 사이의 값으로 표현되며, 1에 가까울수록 모델 성능이 우수함을 의미한다. 본 연구에서 학습된 DNN 모델의 R-squared 값은 0.99로 산출되었다.

MSE는 Eq. 8에 나타난 것과 같이 해석 값과 예측 값의 차이를 제곱하여 모델의 예측 정확도를 평가하며, 주로 회귀 모델을 평가하기 위한 지표로 사용된다. 본

연구에서 학습된 DNN 모델의 MSE는 0.00093으로 매우 낮은 값을 보여주었다. 따라서 R-squared와 MSE를 기반으로 본 연구에서 학습된 DNN 모델의 성능을 평가한 결과, 모델 성능이 우수함을 확인하였다.

Figure 8은 FEM 기반 해석 값과 DNN 모델을 통한 예측 값의 관계를 나타낸다. 데이터가 점선에 가까이 분포할수록 예측 값과 해석 값이 유사하다는 것을 의미한다.



**Fig. 8** Scatter Plot of Spring-Back Angles Predicted by the DNN and FEM

**Table 2** Prediction Results of Spring-Back Angles by FEM and DNN for Flange Radius Ranges of 6–9 mm and 11–14 mm

Radius (mm)	No. of Layers	Stacking Sequences	Spring-Back Angles (deg.)		Errors (%)
			FEM	DNN	
6	4	[0°/45°/0°/0°]	-0.816	-0.815	0.21
6	8	[0°/45°/45°/0°/45°/0°/45°/0°]	-0.432	-0.445	2.92
7	4	[0°/0°/45°/45°]	2.036	2.108	3.42
7	8	[0°/0°/45°/0°/45°/45°/45°/0°]	0.098	0.094	4.23
8	4	[45°/0°/45°/0°]	-1.299	-1.278	1.64
8	8	[0°/45°/45°/0°/45°/0°/0°/45°]	-0.319	-0.323	1.12
9	4	[45°/45°/45°/0°]	-2.629	-2.617	0.45
9	8	[45°/0°/0°/45°/0°/0°/45°/0°]	-0.482	-0.480	0.51
11	4	[0°/45°/0°/0°]	-0.684	-0.676	1.22
11	8	[0°/0°/45°/0°/45°/0°/45°/0°]	-0.106	-0.101	5.10
12	4	[0°/45°/0°/0°]	-0.683	-0.670	1.87
12	8	[45°/45°/45°/45°/0°/0°/0°/45°]	-1.026	-1.013	1.26
13	4	[0°/0°/45°/0°]	0.221	0.226	2.16
13	8	[45°/0°/45°/0°/45°/0°/45°/0°]	-0.539	-0.540	0.28
14	4	[0°/45°/0°/0°]	-0.680	-0.668	1.83
14	8	[45°/0°/45°/0°/0°/45°/0°/45°]	-0.340	-0.341	0.37

## 4.2 DNN 모델 예측 결과

한편 DNN 모델 성능을 평가한 후, 모델에 학습되지 않은 플랜지 반경을 적용하여 복합재 스파의 스프링백 각도를 예측하였고, FEM을 통해 계산된 결과와 비교하였다. 학습된 플랜지 반경(5, 10, 15 mm) 범위에 포함된 6–9 mm, 11–14 mm와 학습된 플랜지 반경에 포함되지 않은 16–25 mm에 대한 스프링백 예측 결과를 Tables 2–3에 나타내었다.

Table 2에 나타낸 것과 같이 학습된 플랜지 반경 범위에 포함된 경우, 0.21–5.1%의 상대오차를 나타내었고, 이에 따른 평균 상대오차는 1.78%인 것으로 나타났다. 또한 Table 3에 나타낸 것과 같이 학습된 플랜지 반경을 벗어난 경우, 0.7–8.46%의 상대오차를 나타내었고, 평균 상대오차는 2.8%로 산출되었다. 따라서 학습되지 않은 플랜지 반경에 대한 종합적인 평균 상대 오차는 2.18%로, 높은 정확도를 보였다. 한편, 일부 케이스에서 오차가 크게 발생한 경우를 해결하기 위해 데이터 양을 증가시키거나, K-겹 교차 검증(K-fold cross validation)을 활용하여 학습을 진행할 수 있다.

또한, FEM 기반 경화 해석은 약 20 min이 소요된 반면, DNN을 통한 예측 시간은 약 14 ms에 불과하였다. 이를 통해 CFRP 복합재의 공정 유도 변형을 빠르고 정확하게 예측하기 위한 DNN의 활용 가능성을 확인하였다.

**Table 3** Prediction Results of Spring-Back Angles by FEM and DNN for Flange Radius Ranges of 16–25 mm

Radius (mm)	No. of Layers	Stacking Sequences	Spring-Back Angles (deg.)		Errors (%)
			FEM	DNN	
16	8	[0°/45°/45°/0°/45°/0°/45°/0°]	-0.409	-0.400	2.25
17	4	[0°/0°/45°/45°]	1.694	1.675	1.12
18	4	[45°/0°/45°/0°]	-1.205	-1.214	0.70
19	8	[45°/0°/0°/45°/0°/0°/45°/0°]	-0.479	-0.457	4.80
20	4	[0°/45°/0°/0°]	-0.679	-0.698	2.67
21	8	[45°/45°/45°/45°/0°/0°/0°/45°]	-0.943	-0.971	2.80
22	8	[45°/0°/45°/0°/45°/0°/45°/0°]	-0.522	-0.532	1.72
23	8	[45°/0°/45°/0°/0°/45°/0°/45°]	-0.352	-0.358	1.85
24	4	[0°/45°/0°/0°]	-0.672	-0.734	8.46
25	8	[0°/45°/45°/0°/45°/0°/0°/45°]	-0.339	-0.345	1.63

5. 결 론

후 기

본 연구에서는 DNN을 이용하여 CFRP 복합재 스파의 경화 공정에 의한 스프링백 각도를 예측하였다. FEM 기반 경화 해석을 통해 복합재 스파의 공정 유도 스프링백 각도 데이터를 추출하였고, 이를 DNN 모델 학습에 활용하였다. 적층 각, 적층 수, 플랜지 반경에 따른 총 816 개의 스프링백 데이터를 수집하였으며, 그 과정에서 MATLAB과 ABAQUS Python scripting을 활용하여 FEM 경화 해석 데이터 수집을 위한 자동화 코드를 구축하였다. 수집된 데이터 중 87%는 DNN 모델 학습에 사용되었고, 13%는 모델 성능 검증에 사용되었다. R-squared와 MSE를 기반으로 DNN 모델의 성능을 평가한 결과, R-squared 값은 0.99, MSE는 0.00093으로 산출되어 모델 성능이 우수함을 확인하였다.

DNN 모델에 학습되지 않은 플랜지 반경을 적용하여 CFRP 복합재 스파의 스프링백 각도를 예측하고, FEM을 통해 계산된 결과와 비교하였다. 그 결과, 학습되지 않은 플랜지 반경에 대한 평균 상대 오차는 2.18%에 불과하여 높은 정확도를 보였다. 또한, FEM 기반 경화 해석은 약 20 min이 소요된 반면, DNN을 통한 예측 시간은 약 14 ms에 불과하였다.

본 연구 결과는 CFRP 복합재 구조의 PID 예측에 DNN을 활용함으로써, 다양한 공정 변수를 신속하게 고려하여 복합재 설계에 효과적으로 반영할 수 있음을 보여준다. 향후, 본 연구 결과를 바탕으로 DNN을 활용하여 복합재 구조물의 다양한 지점에서 발생하는 공정 유도 변형을 예측하는 연구를 진행할 계획이다. 또한, 일반화 성능을 개선하고 오차를 감소시키기 위해 K-겹 교차 검증을 활용한 추가적인 연구도 수행할 예정이다.

본 연구는 2024년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No.2022R1A6A1A03056784). 또한 본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제번호 RS-2024-00444205).

References

- [1] B. Dhiman, V. Guleria, and P. Sharma, "Applications and future trends of carbon fiber reinforced polymer composites: a review," *International Research Journal of Engineering and Technology*, vol. 7, no. 10, pp. 1883-1889, Oct. 2020.
- [2] M. Al-Dhaheri, K. A. Khan, R. Umer, F. Van Liempt, and W. J. Cantwell, "Process-induced deformation in U-shaped honeycomb aerospace composite structures," *Composite Structures*, vol. 248, pp. 112-503, Apr. 2020.
- [3] D. H. Kim, S. W. Kim, H. K. Kim, S. C. Kim, and B. G. Shin, "A study on the verification method of bird strike certification requirements for civilian helicopters through numerical analysis," *Journal of the Korean Society for Aeronautical & Space Sciences*, vol. 13, no. 6, pp. 70-79, Dec. 2019.
- [4] M. Fiorina, A. Seman, B. Castanie, K. M. Ali, C. Schwob, and L. Mezeix, "Spring-in prediction for carbon/epoxy aerospace composite structure," *Composite Structures*, vol. 168, pp. 739-745, May 2017.
- [5] D. H. Kim, S. W. Kim, and I. Lee, "Evaluation of curing

- process-induced deformation in plain woven composite structures based on cure kinetics considering various fabric parameters," *Composite Structures*, vol. 287, pp. 115-379, May 2022.
- [6] D. H. Kim and S. W. Kim, "Process-induced distortion of triaxially braided composites considering different geometric parameters using simplified constitutive model with effective property," *Finite Elements in Analysis and Design*, vol. 222, pp. 103-974, Jul. 2023.
- [7] A. Bhaduri, A. Gupta, and L. Graham-Brady, "Stress field prediction in fiber-reinforced composite materials using a deep learning approach," *Composites Part B: Engineering*, vol. 238, Jun. 2022.
- [8] Y. Shokrollahi, M. M. Nikahd, K. Gholami, and G. Azamara, "Deep learning techniques for predicting stress fields in composite materials: A superior alternative to finite element analysis," *Journal of Composites Science*, vol. 7, no. 8, pp. 311-323, Jul. 2023.
- [9] Y. Wang, C. Soutis, D. Ando, Y. Sutou, and F. Narita, "Application of deep neural network learning in composites design," *European Journal of Materials*, vol. 2, no. 1, pp. 117-170, Apr. 2022.
- [10] J. Hou, B. You, J. Xu, and T. Wang, "Prediction of curing process for thermosetting prepreg compression molding process based on machine learning," *Polymer Composites*, vol. 43, no. 3, pp. 749-1762, Jan. 2022.
- [11] S. Fan, J. Zhang, B. Wang, J. Chen, W. Yang, W. Liu, and Y. Li, "A deep learning method for fast predicting curing process-induced deformation of aeronautical composite structures," *Composites Science and Technology*, vol. 232, pp. 109-844, May 2023.
- [12] W. I. Lee, A. C. Loos, and G. S. Springer, "Heat of reaction, degree of cure, and viscosity of Hercules 3501-6 resin," *Journal of Composite Materials*, vol. 16, no. 6, pp. 510-520, Jun. 1982.
- [13] X. Liu, Z. Guan, X. Wang, et al., "Study on cure-induced residual stresses and spring-in deformation of L-shaped composite laminates using a simplified constitutive model considering stress relaxation," *Composite Structures*, vol. 272, p. 114-203, Oct. 2021.
- [14] W. Chen and D. Zhang, "A micromechanics-based processing model for predicting residual stress in fiber-reinforced polymer matrix composites," *Composite Structures*, vol. 204, pp. 153-166, Aug. 2018.
- [15] B. J. Kang, S. W. Cheon, H. S. Cho, Y. J. Ki, and T. S. Kim, "A deep neural network-based model for predicting sectional structural stiffness of rotorcraft blades," *Journal of the Korean Society for Aeronautical & Space Sciences*, vol. 18, no. 1, pp. 21-28, Jan. 2024.
- [16] V. Sze, Y. H. Chen, T. J. Yang, and J. S. Emer, "Efficient processing of deep neural networks: A tutorial and survey," *Proc. of the IEEE*, vol. 105, no. 12, pp. 2295-2329, Dec. 2017.
- [17] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, Dec. 2014.
- [18] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv preprint arXiv:1609.04747*, Sep. 2016.