

딥러닝 기법을 적용한 평직 CFRP 복합재의 유효물성 예측

이유선^{*,**} · 김동협^{***} · 김상우^{*,**,****†}

Deep Learning–Based Prediction of Effective Properties of CFRP Plain-Woven Composites

Yuseon Lee^{*,**}, Dong-Hyeop Kim^{***}, Sang-Woo Kim^{*,**,****†}

ABSTRACT: A deep neural network(DNN) based methodology is proposed to predict the effective thermo-mechanical properties of plain-weave CFRP composites. Ten distinct effective properties are evaluated by selecting three primary geometric parameters as design variables to account for variations in textile architecture. Representative volume element(RVE) modeling was performed using TexGen software, with periodic boundary conditions(PBCs) applied via the EasyPBC plugin. Effective thermo-mechanical analyses were subsequently conducted using the commercial finite element analysis(FEA) software, ABAQUS. The entire data generation process was automated to construct a comprehensive database of 728 datasets. Model performance was evaluated using 164 validation samples, which account for 20% of the total dataset. The evaluation yielded a Mean Relative Error(MRE) of 0.79% and a coefficient of determination(R^2) of 0.9991, confirming the model's reliability as a surrogate. While FEA-based homogenization required approximately 63.1 s, the DNN model completed predictions in only 14 ms, confirming a significant leap in computational efficiency. These results verify that the proposed DNN model effectively predicts effective thermo-mechanical properties in response to variations in weaving parameters.

초 록: 본 논문에서는 심층 신경망(deep neural network, DNN)을 활용하여 평직 CFRP 복합재의 열·기계적 유효 물성을 예측하는 방법론을 제시하였다. 직물 구조의 변화에 따른 10가지의 유효물성을 예측하기 위해 주요 기하학적 변수 3가지를 설계 변수로 선정하였다. TexGen 소프트웨어를 활용하여 RVE(representative volume element) 기반 모델링을 수행하고 Easy PBC 플러그인을 통해 주기 경계 조건을 부여하였다. 이후 상용 유한요소해석(finite element analysis, FEA) 프로그램인 ABAQUS를 활용하여 유효 열·기계적 해석을 수행하였다. 모든 데이터 생성 과정은 자동화하였으며, 총 728개의 데이터 세트를 구축하고 이를 DNN 모델 학습에 사용하였다. 전체 데이터의 20%인 164개의 검증 데이터를 활용한 모델 성능 평가 결과 평균 상대 오차는 0.79%, 결정계수(R^2)는 0.9991로 나타나 유효물성 예측을 위한 신뢰성 있는 대리모델로 활용 가능성을 보여주었다. 유한요소해석이 약 63.1 s 소요되는 것에 비해 DNN 모델을 약 14 ms 내에 예측을 완료하여 수치 해석 대비 비약적인 계산 효율성을 확인하였다. 이를 통해 제안된 DNN 모델이 직조 변수의 변화에 따른 유효 열·기계적 물성을 효과적으로 예측할 수 있음을 확인하였다.

Key Words: 탄소섬유강화플라스틱(Carbon fiber reinforced plastics), 유효물성(Effective property), 유한요소해석(Finite element analysis), 딥러닝(Deep learning), 심층신경망(Deep neural network)

Received 17 February 2026, received in revised form 29 March 2026, accepted 6 April 2026

*Department of Aerospace and Mechanical Engineering, Korea Aerospace University

**Department of Smart Air Mobility, Korea Aerospace University

***LIG Defense&Aerospace

****Department of Aeronautical and Astronautical Engineering, Korea Aerospace University

†Corresponding author (E-mail: swkim@kau.ac.kr)

1. 서 론

복합재료는 항공우주, 자동차 등 다양한 공학 분야에서 널리 활용되고 있으며, 유효물성은 실제 구조물의 성능을 좌우한다[1-3]. 특히 탄소섬유강화플라스틱(carbon fiber reinforced plastic, CFRP)의 유효물성은 재료의 물성뿐만 아니라 섬유 분포, 체적 분율, 미세 구조 형상에 의해 복합적으로 결정된다. 이러한 특성으로 인해 복합재의 유효물성을 정확하게 예측하는 것은 여전히 중요한 연구 과제로 남아있다.

전통적으로 복합재의 열-기계적 물성은 실험적 평가나 수치해석법을 통해 도출되었으나, 이러한 접근법은 상당한 시간과 비용을 수반한다. 물론 전통적 방법은 물리 법칙에 기반한 해석이라는 장점을 가지지만, 미세 구조가 복잡해질수록 모델링과 계산 비용이 급격히 증가하고, 다양한 형상과 조합에 대해 반복적인 해석을 수행하는데 한계를 보인다.

최근에는 유한요소해석(finite element analysis, FEA)에서 수반되는 막대한 계산 비용을 완화할 수 있는 방법으로 기계학습(machine learning, ML) 기법의 필요성이 증가하고 있다[4,5]. ML은 고분자 복합재의 강도 예측, 피로 거동 등 다양한 문제에 활용되고 있다[6-9]. 이는 ML 기반 접근이 복합재 거동을 효과적으로 근사하면서도 계산 효율성을 확보할 수 있음을 시사한다. 단일 물성 예측에 초점을 둔 기존 연구의 한계를 보완하기 위해 본 연구에서는 열-기계적 유효물성을 동시에 예측함으로써 복합재 설계에 필요한 물성 정보를 효율적으로 제공할 수 있는 대리모델을 제시한다.

본 논문은 심층 신경망(deep neural network, DNN)을 활용하여 평직 CFRP 복합재의 다양한 직물 구조에 따라 변화하는 열-기계적 유효물성을 신속하고 효율적으로 예측하는 방법을 제안한다. 이를 위해 먼저 FEA를 이용하여 CFRP 복합재 RVE 모델에 대한 열-기계적 거동을 분석하였고, 해당 결과로부터 10가지 유효물성 데이터를 체계적으로 구축하였다. 생성된 데이터는 DNN 모델의 학습에 활용되었으며, 이를 통해 직물 구조의 변화에 따른 유효물성의 비선형적 상관관계를 효과적으로 학습하도록 하였다. 제안된 딥러닝 기반 접근법의 예측 성능을 기존 FEA 결과와 비교를 통해 검증하였으며 복합재 구조 설계 단계에서의 적용 가능성을 평가하였다.

2. 학습 데이터 생성

2.1 유한요소법 기반 해석

상용 FEA 소프트웨어인 ABAQUS를 활용하여 직물 구조에 따라 변화하는 평직 CFRP 복합재의 대표체적요소(representative volume element, RVE) 모델에 대한 열-기계적 해석을 수행하였다. 정의된 직조 변수를 기반으로 TexGen 소프트웨어를 활용하여 RVE 기반 유한요소 모델을 생성

Table 1. Geometric parameters used for RVE-based FE model generation of 2D PW composites

Geometric parameters	Ranges	Increments	Units
Yarn to yarn distance (d)	0.6-3.0	0.2	mm
Yarn width (w)	0.4-2.8	0.2	mm
Yarn thickness (t)	0.06-0.2	0.02	mm




Fig. 1. RVE model of 2D PW composites

하였다[10]. 이후 Easy PBC 플러그인을 통해 주기 경계 조건(periodic boundary condition, PBC)을 부여하여 유효 열-기계적 해석을 수행하였다[11]. 2차원 평직 복합재의 단일 층 RVE 기반 유한요소 모델을 생성하였으며, 직물 구조는 2개의 경사(warp), 2개의 위사(fill)로 구성된 평직 패턴으로 정의하였다. 경사와 위사는 직교 방향으로 배열되며, 상호 교대로 교차하도록 모델링하였다. 이때 기하학적 타당성을 확보하기 위해 섬유 다발 간격이 섬유 다발의 폭보다 크도록 설정하였다. 직조 변수의 범위는 Table 1에 나타내었다.

각 섬유 다발(yarn)은 횡등방성 특성을 갖는 단방향(unidirectional) 복합재로 모델링하였으며, 섬유 다발 외의 영역은 순수 수지로 가정하였다. 본 연구에서 활용된 RVE 형상은 Fig. 1과 같다.

직물 구조 변화에 따라 RVE의 기하학적 변수는 달라지나 평직 복합재의 기본적인 직조 패턴은 모든 RVE에서 동일하게 유지된다. 따라서 본 연구에서는 직조 형상의 구조적 동일성을 전제로, 직조 변수 변화가 유효 물성에 미치는 영향만을 독립적으로 분석하였다.

TexGen에서 생성된 RVE 형상을 기반으로 수지와 섬유다발 영역을 구분하여 3차원 주기 요소(periodic mesh)를 생성하였다. 각 면의 절점이 1:1 대응을 이루도록 요소를 구성하여 주기 경계 조건을 적용하였다. 열전달 해석에는 DC3D4 요소, 기계적 거동 해석에는 C3D4 요소를 적용하였고 요소 크기를 RVE 대각선 길이의 1/80로 설정하였다. 본 연구에서는 8552 에폭시 수지와 AS4/8552 단방향 복합재의 물성을 적용하였다.

2차원 평직 CFRP 복합재의 유효 열전도도는 Fig. 2와 같이 유한요소 기반 정상상태 열전달 해석을 통해 산출하였다. 양 끝 단에 각각 100°C, 0°C를 부여하여 단일 방향의 열

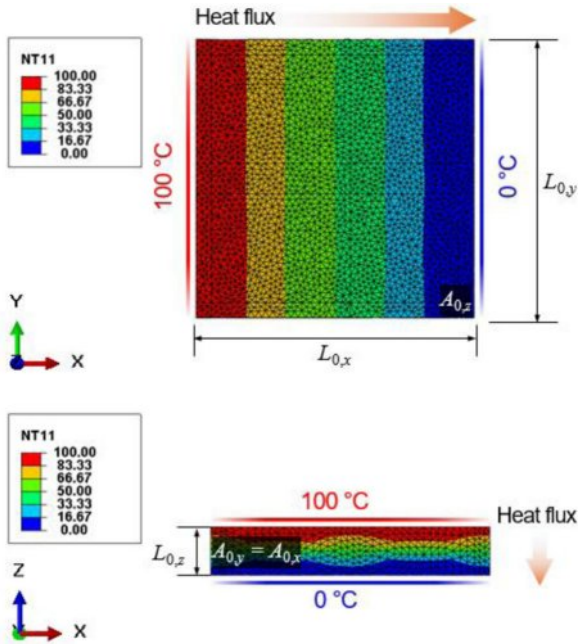


Fig. 2. FE-based steady-state heat transfer analysis for anisotropic thermal conductivity of 2D PW composites

유속(heat flux)을 유도하였으며 나머지 표면은 단열 조건으로 가정하였다.

해석을 통해 산출된 열유속을 바탕으로 식 (1)을 통해 이방성 열전도도를 계산하였다.

$$k_{pwi} = \left(\frac{\dot{Q}_{RFL} L_0}{A_0 \Delta T} \right)_i; (i = x, y, z) \quad (1)$$

2차원 평직 CFRP 복합재의 유효 열팽창계수와 공학적 상수인 탄성계수, 전단계수, 푸아송비는 Easy PBC를 통해 주기 경계 조건을 부여한 RVE 기반 유한요소 모델에 대한 기계적 거동 해석을 통해 도출하였다. 직물 구조의 경우, 3가지 주요 기하학적 매개 변수인 섬유 다발 간격(d), 섬유의 폭(w)과 두께(t)를 고려하여 총 728개의 데이터 세트를 구축하였다. 각 설계 변수가 정의된 범위 내에서 일정한 간격으로 값을 설정하고 해당 변수 조합을 기반으로 데이터 세트를 구성하였다. 이를 통해 설계 변수 공간 전반을 고르게 포함하도록 하였으며 총 728개의 데이터 세트를 통해 설계 변수 조합을 충분히 반영하도록 구성하였다.

Fig. 3에 나타낸 바와 같이 MATLAB과 Python 스크립팅을 활용하여 데이터 세트 구축 과정을 자동화하였다. 모든 직조 변수 조합을 생성한 후 이를 바탕으로 TexGen에서 RVE 기반 유한요소 모델을 생성하였다. 생성된 모델에 대해 열-기계적 해석을 수행하여 직조 변수에 따른 유효물성을 산출하였으며, 최종적으로 직조 변수와 이에 대응하는 10가지 유효물성을 DNN 학습에 활용하기 위해 심표로 구분된 CSV 파일 형식으로 정리하였다.




Fig. 3. FEM-based effective material properties dataset generation workflow

2.2 데이터 전처리

데이터의 기반 예측 모델에서는 학습 데이터의 분포와 스케일 특성이 모델 성능에 직접적인 영향을 미친다. 데이터 전처리가 수행되지 않은 데이터는 변수 간 크기 차이로 인해 학습 과정에서 수치적 불안정성을 유발할 수 있으며, 이는 모델의 수렴이나 예측 정확도 저하로 이어질 수 있다. Fig. 4는 정규화 되지 않은 데이터의 분포를 보여준다.

따라서 본 연구에서는 DNN의 학습의 안정성과 예측 성능을 향상시키기 위해 데이터 전처리 과정을 수행하였다. 본 연구에서는 데이터 분포의 왜곡과 이상치(outlier)의 영


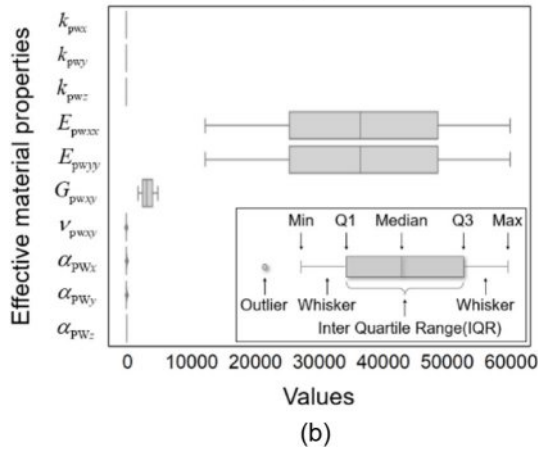




Fig. 4. Box plot distributions on the original scale: (a) Geometric parameters, (b) Effective materials properties

Fig. 5. Box plot distributions after robust scaling: (a) Geometric parameters, (b) Effective materials properties

향을 최소화하기 위해 로버스트 정규화 기법을 적용하였으며, 식 (2)-(3)으로 계산된다.

$$X_{\text{scaled}} = \frac{X - \text{median}(X)}{IQR(X)} \quad (2)$$

$$IQR = Q_3 - Q_1 \quad (3)$$

위 식에서 $\text{median}(X)$ 는 중앙값을 나타내며, Q_3 과 Q_1 은 각각 3사분위수와 1사분위수를 의미한다. 유효물성은 변수 간 스케일 차이가 커 이러한 데이터 특성에서 평균과 표준편차에 기반한 정규화 방법은 이상치에 민감하게 반응하여 학습 과정의 안정성을 저하시킬 수 있다. 이에 본 연구에서는 중앙값(median)과 사분위 범위($\text{interquartile range}$, IQR)를 기준으로 데이터를 스케일링하는 로버스트 정규화를 적용함으로써 이상치의 영향을 완화하고 각 변수의 상대적인 분포 특성을 보다 안정적으로 반영하고자 하였다. 이를 통해 DNN이 특정 데이터 구간에 편향되지 않고, 직조 변수와 열-기계적 유효물성 간의 비선형 관계를 보다 효과적으로 학습할 수 있도록 하였다. Fig. 5는 로버스트 정규

화를 적용한 데이터의 분포를 보여준다.

정규화 이후 일부 데이터가 상대적으로 큰 값으로 분포하는 경향을 보인다. 이는 정규화 과정에서 이상치가 새롭게 생성된 것이 아니라 데이터가 스케일링됨에 따라 특정 직조 조건에서의 물성 값이 중앙 분포에서 떨어져 위치하는 것이 명확히 표현된 것이다. 해당 데이터는 물리적으로 유효한 직조 변수 조합에서 도출된 해석 결과에 해당하며 수치적 이상치로 간주되지 않는다. 따라서 본 연구에서는 이러한 데이터를 제거하지 않고 유지하여 직물 구조의 변화에 따른 유효물성 분포 특성을 DNN 학습에 반영하였다.

구축된 전체 데이터 세트는 기하학적 매개변수와 이에 대응하는 유효물성을 샘플로 구분된 CSV 파일 형식으로 저장하여 학습에 활용하였다. 모델 학습과 성능 평가를 위해 학습 데이터와 검증 데이터로 분할하였다. 전체 데이터 728개의 80%인 582개를 학습 데이터로 사용하였고, 20%인 144개를 검증 데이터로 사용하였다. 학습 데이터는 DNN의 가중치 학습에 사용되었으며, 검증 데이터는 학습 과정에서 모델의 예측 성능을 평가하고 일반화 성능을 확인하는데 활용하였다.




Fig. 6. DNN model structures

3. 딥러닝

DNN은 다수의 은닉층(hidden layer)을 통해 입력 변수와 출력 변수 간의 복잡한 비선형 관계를 효과적으로 모델링할 수 있는 딥러닝(deep learning) 기법이다[12]. 기존의 선형 회귀 모델과 달리 DNN은 계층적 구조를 통해 입력 데이터로부터 단계적으로 특징을 추출함으로써 직물 구조와 유효물성 간의 복잡한 시스템 거동을 정밀하게 근사할 수 있다. 이러한 특성으로 인해 DNN은 반복적인 수치해석이나 실험이 요구되는 공학 문제에서 대리 모델로 활용될 수 있는 잠재력을 가진다.

본 연구에서는 이러한 장점을 바탕으로 평직 CFRP 복합재의 직조 변수와 열·기계적 유효물성 간의 비선형 관계를 학습하기 위해 DNN 모델을 적용하였다. 입력 변수로는 섬유 다발 간격, 섬유의 폭과 두께로 정의된 3가지 직조 변수를 사용하였으며, 출력 변수로는 열전도도, 열팽창계수, 탄성계수, 전단계수를 포함한 총 10가지 열·기계적 유효물성을 동시에 예측하도록 구성하였다. 모델은 10개의 은닉층으로 구성되며 각 층은 128개의 노드를 갖는 완전 연결 계층으로 설계하였다. 각 은닉층에는 ReLU 활성화 함수를 적용하였고, 출력층은 선형 활성화 함수를 사용하였다. 적용된 DNN 모델의 구조는 Fig. 6에 나타내었다.

구축된 학습 데이터를 이용하여 예측 오차를 최소화하는 방향으로 DNN 모델의 학습을 수행하였다. 손실 함수(loss function)로는 회귀 문제에 적합한 MSE를 사용하였으며, 이는 예측값과 해석값 간의 차이를 제공하여 평균한 값으로 정의된다. MSE는 식 (4)와 같이 표현된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

여기서 n 은 데이터의 개수를 나타내며, y_i 와 \hat{y}_i 는 각각 해석값과 예측값을 의미한다. MSE는 오차의 크기를 정량적

으로 평가할 수 있으며, 큰 오차에 대해 더 큰 패널티를 부여함으로써 예측 정확도 향상에 효과적인 지표이다. 가중치 최적화를 위해 Adam 최적화 알고리즘을 적용하였다. Adam은 학습률을 적응적으로 조정하는 방법으로 학습 안정성과 수렴 속도 측면에서 우수한 성능을 보인다.

모델 학습을 총 3,000 epochs 동안 반복 수행하였으며, 학습 과정에서 검증 데이터를 함께 사용하여 모델의 예측 성능을 주기적으로 평가하여 과적합 발생 여부와 일반화 성능을 확인하였다. 정규화된 출력값을 기준으로 MSE 값이 최소화되도록 모델을 학습하였다. MSE는 식 (4)에서 정의된 바와 같이 계산되며, 예측값과 해석값 간 오차의 크기를 정량적으로 평가하는 지표로 사용된다.

4. 결 과

DNN 모델이 학습용 데이터를 학습하는 데 약 1,126 초가 소요되었다. Fig. 7은 MSE로 계산된 학습 손실과 검증 손실의 epoch 이력을 나타낸다. 손실은 초기 구간에서 급격히 감소한 뒤 낮은 값으로 수렴하였고, 이후 구간에서도 검증 손실이 학습 손실과 유사한 수준으로 유지되었다. 즉, 학습이 안정적으로 수렴되었고 검증 손실의 증가가 관찰되지 않으므로 과적합 징후를 나타내지 않았다.

전체 데이터 중 20%에 해당하는 146개의 검증 데이터를 활용하여 모델의 예측 성능을 평가하였다. 동일한 정규화 출력 기준에서 검증 데이터에 대한 MSE는 0.0003으로 산출되었다. 또한 예측 성능을 물리적 단위에서 해석하기 위해 예측값과 해석값을 원래 스케일로 복원한 뒤 결정계수(coefficient of determination, R^2), MAE(mean absolute error), MRE(mean relative error)를 계산하였다. 이를 통해 직물 구조 변화에 따른 유효물성 예측 정확도를 정량적으로 분석하였다. R^2 는 해석 결과와 모델 예측 결과 간의 일치도를 정량적으로 나타내는 지표로 식 (5)-(8)을 통해 산출된다.

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (5)$$




Fig. 7. Mean squared error values for train and validation loss

Table 2. Predictive performance of the DNN model for the ten effective material properties

Effective properties		R^2	MRE [%]	MAE	
				Values	Unit
Thermal conductivities	k_{PWx}	0.9996	0.80	0.004	W/m·K
	k_{PWy}	0.9996	0.80	0.004	W/m·K
	k_{PWz}	0.9989	0.64	0.002	W/m·K
CTEs	α_{PWx}	0.9994	0.84	0.102	$\mu\epsilon/^\circ\text{C}$
	α_{PWy}	0.9994	0.84	0.102	$\mu\epsilon/^\circ\text{C}$
	α_{PWz}	0.9991	0.33	0.262	$\mu\epsilon/^\circ\text{C}$
Engineering constants	E_{PWxx}	0.9994	1.02	253.507	MPa
	E_{PWyy}	0.9994	1.02	253.586	MPa
	G_{PWxy}	0.9996	0.50	15.020	MPa
	ν_{PWxy}	0.9976	1.09	0.001	W/m·K

$$SST = \sum_{i=1}^N (y_i - \bar{y})^2 \quad (6)$$

$$SSE = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

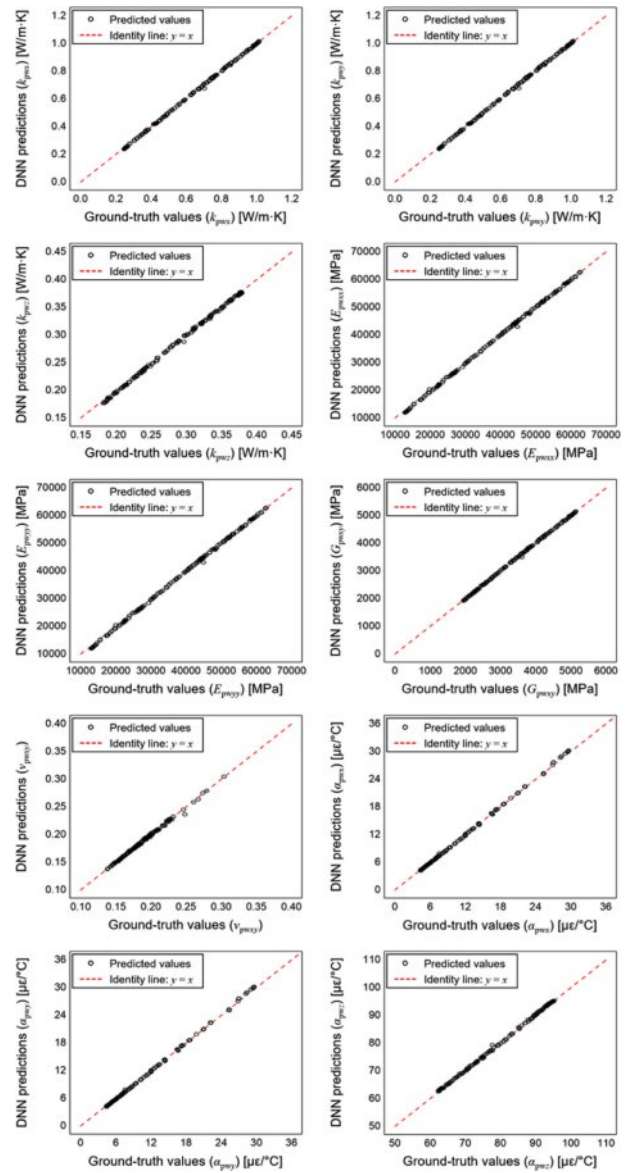
$$SSR = \sum_{i=1}^N (\hat{y}_i - \bar{y})^2 \quad (8)$$

여기서 y_i 는 해석 값, \bar{y}_i 는 해석 값의 평균, \hat{y}_i 는 예측 값을 의미한다. 결정계수는 1에 가까울수록 모델의 예측 성능이 우수함을 의미하며, 0에 가까울수록 모델의 설명력이 낮음을 나타낸다. MAE는 예측값과 해석값 간의 절대 오차의 평균을 의미하며, MRE는 실제 값 대비 상대 오차를 나타내는 지표로서 물성 값의 크기 차이를 고려한 정규화된 오차를 제공한다. 이러한 지표를 바탕으로 DNN 모델의 예측 성능과 적합도를 종합적으로 평가하였다.

Table 2에 나타난 바와 같이, DNN은 10가지의 열-기계적 유효물성 전반에서 높은 예측 성능을 보였다. R^2 는 0.9974에서 0.9996의 범위를 형성하였으며, MRE는 1.1% 이하로 매우 낮게 유지되었다. 최대 오차는 E_{PWyy} 에서 관찰되었고 나머지 물성들은 해석 결과와 매우 높은 일치도를 보였다. 이러한 결과는 DNN이 복합재의 기하학적 매개변수와 유효물성 간의 관계를 효과적으로 근사하고 있음을 보여준다.

Fig. 8의 산점도는 예측값과 해석값 간의 비교를 통해 앞선 결과를 추가로 뒷받침한다.

모든 물성에 대해 예측 결과가 기준선 주변에 밀집하여 분포하였으며, 직조 변수로부터 유효 물성을 신뢰성 있게 추정할 수 있음을 확인하였다. 또한 오차가 특정 구간에 집중되지 않고 전반적으로 고르게 분포하는 경향을 보여 다양한 직조 조건에 대해 안정적인 예측 성능을 나타낸다.

**Fig. 8.** Comparison between DNN model-predicted and ground-truth effective material properties

5. 결론

본 연구에서는 딥러닝 기법 중 하나인 DNN을 활용하여 평직 CFRP 복합재의 직물 구조 변화에 따른 열-기계적 유효물성을 예측하였다. 이를 위해 주요 기하학적 변수 3가지를 정의하고, 데이터 생성 과정을 자동화하여 RVE 기반 FEA를 수행하여 총 728개의 데이터 세트를 구축하였다. 구축된 데이터 세트를 이용하여 모델을 학습하였으며 검증 결과 높은 예측 정확도를 보였다. MRE와 R^2 를 산출하였으며 각각 0.79%, 0.9991로 높은 예측 성능을 보여주었다. FEA를 통한 유효물성 산출에는 약 63.1 s가 소요된 반면, DNN 모델을 통한 예측에는 49 ms가 소요되었다. 이는 DNN 모

델이 유효물성 예측에 소요되는 시간을 현저히 단축시켰음을 보여준다. 이는 단일 해석 조건을 넘어 반복 해석이 요구되는 복합재의 유효물성 기반 설계와 최적화 과정에서 계산 비용을 획기적으로 절감할 수 있음을 시사한다. 또한 제안된 DNN 모델은 FEA 대비 계산 비용을 크게 줄여 설계 변수 탐색을 보다 신속하게 수행할 수 있게 한다.

다만, 본 모델의 유효성은 학습에 사용된 변수 범위 내로 한정되므로 설계 공간 외 영역에 대한 일반화 성능은 향후 연구를 통해 보완이 필요하다.

이러한 한계에도 불구하고 본 연구는 DNN을 활용한 CFRP 평직 복합재의 유효물성 예측 기법을 제시하며, 유효물성 예측을 위한 신뢰성 있는 대리모델로 활용 가능성을 보여준다. 또한, 본 연구에서 제안한 데이터 생성 자동화와 DNN 기반 예측 프레임워크는 평직 구조뿐만 아니라 다양한 직조 구조의 복합재 물성 예측에도 적용 가능할 것으로 기대된다.

후 기

이 연구는 2026년도 산업통상자원부 및 한국산업기술기획평가원(KEIT) 연구비 지원에 의한 연구임(No.RS202400433049).

REFERENCES

- Kim, D.H., Kim, S.W., Kim, H.K., Kim, S.C., and Shin, B.G., "Study on Verification Methodology of Airworthiness Requirements for Bird Strike on Civilian Helicopter based on Numerical Analysis," *Journal of the Korean Society for Aeronautical & Space Sciences*, Vol. 13, No. 6, 2019, pp. 70-79.
- Baek, S.M., Lim, S.J., Kim, M.S., Ko, M.G., and Park, C.I., "Study on Mechanical Properties of CFRP Composite Orthogonal Grid Structure," *Composites Research*, Vol. 31, No. 2, 2018, pp. 69-75.
- Lee, Y., Kim, D.H. and Kim, S.W., "Prediction of Curing Deformation in CFRP Composite Structure Using Convolutional Neural Network Model", *Composites Research*, Vol. 38, No. 2, 2025, pp. 106-113.
- Sharma, A., Mukhopadhyay, T., Rangappa, S. M., Siengchin, S., and Kushvaha, V., "Advances in Computational Intelligence of Polymer Composite Materials: Machine Learning Assisted Modeling, Analysis and Design," *Archives of Computational Methods in Engineering*, Vol. 29, No. 5, 2022, pp. 3341-3385.
- Liu, X., Tian, S., Tao, F., and Yu, W., "A Review of Artificial Neural Networks in the Constitutive Modeling of Composite Materials," *Composites Part B: Engineering*, Vol. 224, 2021, 109152.
- Seyhan, A.T., Tayfur, G., Karakurt, M., and Tanog'lu, M., "Artificial Neural Network (ANN) Prediction of Compressive Strength of VARTM Processed Polymer Composites," *Computational Materials Science*, Vol. 34 No. 1, 2005, pp. 99-105.
- Ramasamy, P., and Sampathkumar, S., "Prediction of Impact Damage Tolerance of Drop Impacted WGFRP Composite by Artificial Neural Network Using Acoustic Emission Parameters," *Composites Part B: Engineering*, Vol. 60, 2014, pp. 457-462.
- Mini, M.K., and Sowmya, M., "Neural Network Paradigms for Fatigue Strength Prediction of Fiber-reinforced Composite Materials," *International Journal of Advanced Structural Engineering*, Vol. 4, No.1, 2012, pp. 7.
- Vassilopoulos, A.P., Georgopoulos, E.F., and Dionysopoulos, V., "Artificial Neural Networks in Spectrum Fatigue Life Prediction of Composite Materials," *International Journal of Fatigue*, Vol. 29, No. 1, 2007, pp. 20-29.
- Brown, L.P., and Long, A.C., "Modeling the geometry of textile reinforcements for composites: TexGen," *Composite Reinforcements for Optimum Performance*, 2021, pp. 237-265.
- Omairey, S.L., Dunning, P.D., and Sriramula, S., "Development of an ABAQUS Plugin Tool for Periodic RVE Homogenisation," *Engineering with Computers*, Vol. 35, No. 2, 2019, pp. 567-577.
- Liu, X., Guan, Z., Wang, X., Jiang, T., Geng, K., and Li, Z., "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, 2021, pp. 114203.