

## 이방성 헤르츠 접촉 이론을 도입한 Hybrid PINN 기반 적층 복합재의 층간 전단 응력 예측

조성욱\* · 전성식\*<sup>†</sup>

### Prediction of Interlaminar Shear Stress in Laminated Composites using Hybrid PINN incorporated with Anisotropic Hertzian Contact Theory

Sungwook Cho\*, Seong S. Cheon\*<sup>†</sup>

**ABSTRACT:** Interlaminar shear stress in laminated composites is a critical factor governing the initiation of delamination and overall structural integrity, and the short-beam shear test is widely used to evaluate this behavior. However, due to the complex contact-shear interactions that arise near the indenter and support regions, classical beam theory and finite element analysis-based approaches suffer from limitations in terms of computational cost and modeling efficiency. To address these issues, this study proposes a Hybrid Physics-Informed Neural Network (Hybrid PINN) framework for predicting interlaminar shear stress by incorporating anisotropic Hertzian contact theory. The proposed model embeds the governing equations of an orthotropic elastic solid under plane stress conditions into the loss function and imposes the load-dependent contact pressure distribution as a physical constraint. In addition, reference data obtained from finite element analysis are used to guide the early stage of training, thereby improving convergence stability and prediction accuracy. Validation under short-beam shear test conditions demonstrates that the Hybrid PINN successfully reproduces interlaminar shear stress distributions that are qualitatively consistent with FEA results, while the maximum interlaminar shear stress is predicted within 1% error. These findings indicate that the proposed approach provides an efficient alternative for predicting interlaminar shear stress in laminated composites.

**초 록:** 적층 복합재에서 층간 전단 응력은 층간 분리의 발생과 구조 건전성을 좌우하는 핵심 인자로, 단보 전단 시험은 이를 평가하기 위해 널리 활용되고 있다. 그러나 압입자와 지지점 부근에서 발생하는 복잡한 접촉-전단 상호작용으로 인해, 고전적인 보 이론이나 유한요소해석 기반 접근법에는 계산 비용 및 모델링 측면에서 한계가 존재한다. 본 연구에서는 이러한 문제를 해결하기 위해 이방성 헤르츠 접촉 이론을 도입한 Hybrid Physics-Informed Neural Network(Hybrid PINN) 기반 층간 전단 응력 예측 모델을 제안하였다. 제안된 모델은 평면 응력 상태의 직교 이방성 탄성체에 대한 지배 방정식을 손실 함수에 포함하고, 하중에 따른 접촉 압력 분포를 물리 제약 조건으로 반영하였다. 또한 유한요소해석 참조 데이터를 학습 초기 가이드로 활용하여 수렴성과 예측 정확도를 향상시켰다. 단보 전단 시험 조건에서의 검증 결과, Hybrid PINN은 FEA와 정성적으로 유사한 전단 응력 분포를 재현하였으며, 최대 층간 전단 응력은 1% 이내의 오차로 예측되었다. 이는 제안된 방법이 적층 복합재의 층간 전단 응력 예측을 위한 효율적인 대안이 될 수 있음을 시사한다.

**Key Words:** 물리정보신경망(Physics-informed neural network, PINN), 층간 전단 응력(Interlaminar shear stress), 단보 전단 시험(Short-beam shear test), 유한요소해석(Finite Element Analysis), 탄소섬유 복합재료(CFRP)

## 1. 서 론

탄소섬유강화플라스틱(Carbon Fiber Reinforced Plastics, CFRP)은 높은 비강도(Specific strength)와 비강성(Specific stiffness)을 지니고 있어 항공우주, 자동차 및 방위 산업 등 경량화가 필수적인 분야에서 핵심 소재로 활용되고 있다. 그러나 서로 다른 물성을 가진 층(Ply)이 적층된 구조적 특성상, 층간(Interlaminar)에서의 기계적 거동이 전체 구조물의 건전성을 좌우하게 된다. 특히 외부 하중이나 충격에 의해 발생하는 층간 전단 응력(Interlaminar Shear Stress)은 층간 분리(Delamination)를 유발하는 주된 원인으로 지목되며, 이는 복합재 구조물의 급격한 강도 저하와 파손으로 이어진다[1,2].

이에 따라 복합재의 층간 전단 강도(Interlaminar Shear Strength, ILSS)를 정확히 평가하는 것은 매우 중요하다. 현재 가장 널리 통용되는 시험법은 ASTM D2344[3] 규격에 따른 단보 전단 시험(Short-beam shear test)이다. 이 시험법은 시편의 길이(Span)를 두께 대비 짧게 설정하여 굽힘 모멘트보다 전단력을 극대화함으로써 층간 파손을 유도한다. 그러나 이 방식은 하중이 가해지는 압입자(Indenter)와 지지점(Support) 부근에서 복잡한 3차원 응력 상태와 급격한 응력 집중(Stress concentration) 현상이 발생한다는 한계가 있다[4]. 이러한 국부적인 응력 집중은 고전적인 보 이론(Beam Theory)으로는 정확한 해석이 불가능하며, 실험값의 신뢰도를 저하시키는 요인이 된다.

전통적인 수치 해석 방법인 유한요소해석(Finite Element Analysis, FEA)은 이러한 복잡한 응력장을 예측하는 데 효과적이지만, 접촉 부위의 요소를 지나치게 미세하게 분할해야 하는 메쉬 의존성(Mesh-dependency) 문제와 높은 계산 비용이 소요된다는 단점이 존재한다. 최근에는 이러한 수치 해석의 한계를 극복하기 위해 물리 정보 신경망(Physics-Informed Neural Network, PINN)이 새로운 대안으로 주목받고 있다. PINN은 데이터에만 의존하는 기존 딥러닝과 달리, 지배 방정식을 손실 함수(Loss function)에 포함하여 물리 법칙을 만족하는 해를 도출할 수 있다[5].

Haghighat 등[6]은 선형 탄성체의 평면 변형률 문제를 대상으로 PINN 기반 예측 모델을 구축하여, FEA 수준의 변위장을 낮은 계산비용으로 재현할 수 있음을 보고하였다. Geneva 등[7]은 2D 고체역학 편미분 방정식을 PINN으로 해석하며 경계조건 변화에도 안정적으로 작동하는 모델을 제안하였고, Wen 등[8]의 연구에서는 대변형 탄성체의 무마찰 접촉 문제에 대해, 변분 에너지를 손실로 사용하는 에너지-기반 PINN을 제안하고 FEA와 비교를 통해 PINN이 이방성 재료, 경계조건 변화, 접촉 비선형성과 같은 고체역학적 특성을 직접 처리할 수 있는 가능성을 보여준다. 그러나 대부분의 기존 연구는 복합재와 같은 이방성 재료가 아닌

등방성 재료를 취급하고 있으며, 층간 전단 응력과 같이 복합재 특유의 접촉-전단 상호작용이 지배하는 문제에 PINN을 적용한 사례는 여전히 드물다.

본 연구에서는 이방성 재료 특성을 고려한 이방성 헤르츠 접촉 이론(Anisotropic Hertzian Contact Theory)[9]의 도입과 FEA 참조 데이터가 해의 탐색 방향을 가이드 함으로써 학습 수렴성과 정확도를 향상시킬 수 있는 Hybrid PINN 모델을 제안한다. 본 모델은 이방성 재료의 접촉 면적에 따른 압력 분포를 물리적 제약 조건으로 반영하여 접촉 부위의 특이성 문제를 해결하고, FEA 데이터를 참조하여 학습의 초기 수렴성을 확보하도록 설계되었다. 특히, 본 연구에서는 Hybrid PINN 모델의 학습 효율성과 모델의 명확한 검증에 위해 해석 도메인을 평면 응력(Plane Stress) 상태로 가정하여 2차원 문제에서의 층간 전단 응력 예측 성능을 평가하고자 한다.

## 2. Hybrid PINN 해석 모델 및 방법론

### 2.1 구성 및 지배 방정식

본 Hybrid PINN은 두께 방향의 응력을 무시할 수 있는 평면 응력 상태의 2차원 탄성 문제로 가정될 수 있으며, 재료는 직교 이방성 선형 탄성 이론을 따른다. 이에 따른 구성 방정식은 후의 법칙을 따르며, 식 (1)와 같이 정의된다. 지배 방정식으로는 체적력을 무시한 정적 평형 방정식이 적용되었으며, Hybrid PINN의 손실 함수에서 잔차(Residual)를 최소화해야 하는 물리적 제약 조건은 다음 식 (2)-(3)과 같다.

$$\begin{Bmatrix} \sigma_x \\ \sigma_z \\ \tau_{xz} \end{Bmatrix} = [Q] \begin{Bmatrix} \varepsilon_x \\ \varepsilon_z \\ \gamma_{xz} \end{Bmatrix} \quad (1)$$

$$\frac{\partial \sigma_x}{\partial x} + \frac{\partial \tau_{xz}}{\partial z} = 0 \quad (2)$$

$$\frac{\partial \tau_{xz}}{\partial x} + \frac{\partial \sigma_z}{\partial z} = 0 \quad (3)$$

여기서  $\sigma$ 와  $\varepsilon$ 은 각각 응력과 변형률 벡터를 나타내고  $[Q]$ 는 평면 응력 조건( $\sigma_y = 0$ )이 고려된 축소 강성 행렬을 의미한다.

경계 조건 설정에 있어 indenter와 support가 접촉되는 지점이 단순 점 하중일 경우 PINN에서 학습 시 접촉 부위의 응력 특이성으로 인해 실제 층간 전단 응력을 예측하는데 한계가 존재한다. 또한 indenter에 의한 압축 시 하중 크기에 따라 변동되는 접촉 면적을 반영하기 위해 본 연구에서는 이방성 헤르츠 접촉 이론[9]을 Hybrid PINN의 물리 방정식에 추가로 도입하였다. 따라서 하중에 따른 접촉 반폭(Contact Half-width)  $a(P)$ 는 다음 식 (4)-(5)을 통해 계산된다.

$$a(P) = \sqrt{\frac{4PR}{\pi E'}} \quad (4)$$

$$E' \approx \left( S_{zz} - \frac{S_{xz}^2}{S_{xx}} \right)^{-1} \quad (5)$$

여기서  $P$ 는 각 접촉 지점에서의 하중을 의미하며, 무차원 하중인  $\hat{p}$ 에 기준 하중을 곱하여 복원된 실제 하중이 적용된다.  $R$ 은 각 접촉 지점에서의 indenter와 Support의 반경을 의미하며,  $E'$ 은 등가 탄성 계수로, 직교 이방성 재료의 컴플라이언스 성분 통해 계산된다. 이는 하중 방향의 컴플라이언스( $S_{zz}$ )가 지배적이되, 섬유 방향( $S_{xx}$ )과의 상호작용( $S_{xz}$ )을 고려한 유효 강성을 의미한다[10].

최종적으로 계산된 접촉 반쪽내에서의 수직 응력 분포는 포물선 형태로 근사하여 식 (6)-(7)과 같이 indenter와 support에서의 경계조건에 적용되게 된다.

$$\sigma_z(x) = -P_{max} \left( 1 - \left( \frac{x-x_c}{a} \right)^2 \right), \quad |x - x_c| \leq a \quad (6)$$

$$P_{max} = \frac{3P}{4at} \quad (7)$$

여기서  $x_c$ 는 지지점과 하중점의 중심 좌표를 의미하며,  $x - x_c$ 는 접촉 중심으로부터 임의의 위치  $x$ 까지의 상대적 거리를 나타낸다. 즉, 접촉 중심( $x = x_c$ )에서 응력이 최대가 되고, 접촉 경계( $|x - x_c| = a$ )로 갈수록 0으로 감소하는 분포가 형성된다. 또한  $P_{max}$ 는 접촉 중심에서 발생하는 최대 접촉 압력으로 전체 하중  $P$ 가 포물선 분포를 따라 적분값과 일치되도록 계산된다.

## 2.2 FEA 참조 데이터 및 재료 물성

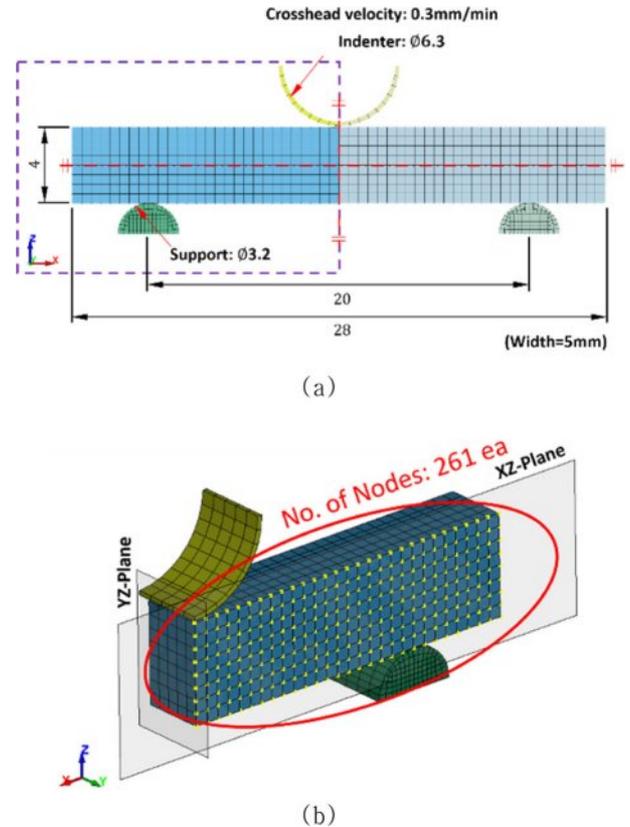
본 Hybrid PINN 학습을 위한 FEA 참조 데이터를 구축하기 위해 단보 전단 시험이 ANSYS/LS-DYNA의 implicit method로 수행되었다. 해석을 위한 모델 형상은 1/4만 고려되었으며, 시편에는 UD CFRP 물성인 Table 1이 MAT54/55 Enhanced Composite Damage을 통해 적용되었다. Fig. 1(a)와 같이 시편의 요소는 0.5 mm 크기의 Hexahedral element이며, 총 1,120개 요소로 이루어졌다. ASTM D2344/

**Table 1.** Material properties of IM7/8552 [11]

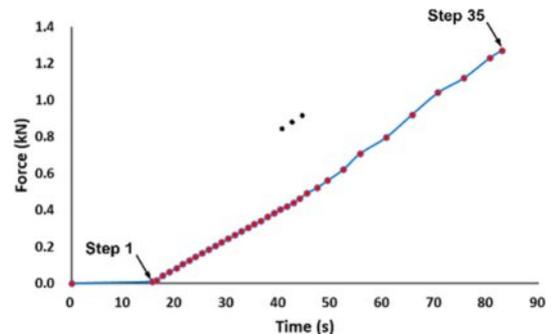
Specific gravity		1.52
Elastic modulus (GPa)	$E_x$	161
	$E_y = E_z$	11.4
	$G_{yz}$	3.98
	$G_{xy} = G_{zx}$	5.17
Poisson's ratio	$\nu_{yz} = \nu_{xz}$	0.023
	$\nu_{zy}$	0.436

D2344M[3] 규격에 따라 indenter와 support의 반지름은 각각  $\varnothing 6.3$  mm,  $\varnothing 3.2$  mm이고, Span은 20 mm이며, 압입 속력은 0.3 mm/min FEA가 수행되었다.

FEA로 구현된 단보 전단 시험은 시편의 탄성 구간내에서 압입되는 총 35개의 타임스텝으로 구성되며, Fig. 1(b)에서와 같이 대칭면인 XZ면에 존재하는 총 261개의 node에서 각 타임스텝에 따른 각 node의 좌표가 추출되었다. 추출된 node 좌표는 Fig. 2에서와 같이 indenter에서 도출된 하중과 매칭되어 Hybrid PINN 학습에 적용되었다.



**Fig. 1.** 1/4 Short-beam shear FE model: (a) Full model, (b) Node where data is extracted from the XZ plane



**Fig. 2.** Contact force derived from the indenter

### 2.3 Hybrid PINN 학습 전략

본 연구에서 제안하는 Hybrid PINN은 단보 전단 시험에 가해지는 다양한 하중 조건에 대한 응력장을 하나의 네트워크로 예측하고자 한다. 이에 식 (8)과 같이 예측하고자 하는 응력장의 공간 좌표와 하중으로 구성된 총 3개의 변수가 입력층에 투입되며, 식 (9)와 같이 출력층은 2개의 변위 ( $u, w$ )를 도출하게 된다.

$$\mathbf{x} = \{x, z, \hat{p}\} \quad (8)$$

$$\mathbf{u} = \{u(x, z, \hat{p}), w(x, z, \hat{p})\} \quad (9)$$

여기서  $x, z$ 는 시편의 공간 좌표를 의미하며,  $\hat{p}$ 은 입력 하중  $p$ 를 전체 하중 범위 중 절댓값이 큰 값을 기준으로 표준화된 무차원 하중 변수를 의미한다.

심층 신경망(Deep Neural Network)의 은닉층은 총 10개의 층으로 구성되었으며, 각 층에는 32개의 뉴런을 배치하여 하중과 공간 좌표에 따른 변위를 학습할 수 있도록 설정되었다. 활성화 함수(Activation function)로는 매끄러운 곡선 형태를 띠어 미분 가능성을 보장하는 Swish function[12]이 적용되었으며, 최적화기(Optimizer)로는 학습 초기에 오차를 빠르게 줄여 수렴성과 학습 안전성 향상에 도움이 되는 Adam(Adaptive Moment Estimation)이 적용되었다.

모델 학습을 위한 collocation point는 Short-beam shear의 물리적 거동을 학습하는 도메인과 경계 조건을 학습하는 영역으로 구분되며, 8,000개의 collocation point가 도메인 내부에 균일하게 분포된다. 자유단 및 대칭 조건을 위한 경계 영역에는 1,000개, 그리고 indenter와 support에서의 접촉 거동을 학습하기 위한 접촉 영역에는 각각 1,500개씩 배치되어 접촉부에서의 응력 집중 현상이 정밀하게 예측될 수 있도록 설정되었다.

학습은 총 50,000 epoch 동안 진행되었으며, 초기 학습률은  $10^{-4}$ 로 설정하되 2,000 epoch 마다 0.9배씩 감소되는 전략을 통해 학습 효율성을 높였다. 전체 손실 함수( $\mathcal{L}_{Total}$ )는 다음 식 (10)과 같이 세 가지 항의 합으로 정의된다.

$$\mathcal{L}_{Total} = \lambda_{PDE} \mathcal{L}_{PDE} + \lambda_{BC} \mathcal{L}_{BC} + \lambda_{Data} \mathcal{L}_{Data} \quad (10)$$

여기서  $\mathcal{L}_{PDE}$ 는 편미분 방정식(Partial Differential Equation) 형태의 정적 평형 방정식의 잔차를 나타내고  $\mathcal{L}_{BC}$ 는 경계조건(Boundary Condition)에서의 잔차 그리고  $\mathcal{L}_{Data}$ 는 FEA 참조 데이터와의 평균 제곱 오차(Mean Squared Error, MSE)를 의미한다.

먼저,  $\mathcal{L}_{PDE}$ 는 다음 식 (11)과 같다.

$$\mathcal{L}_{PDE} = \frac{1}{N_e} \sum_{i=1}^{N_e} \left( \left\| \frac{\partial \sigma_x}{\partial x} + \frac{\partial \tau_{xz}}{\partial z} \right\|^2 + \left\| \frac{\partial \tau_{zx}}{\partial x} + \frac{\partial \sigma_z}{\partial z} \right\|^2 \right) \quad (11)$$

여기서  $N_e$ 는 도메인 내부의 collocation point 개수를 의미한다.

다음으로  $\mathcal{L}_{BC}$ 는 Hybrid PINN 모델이 물리적으로 타당한 경계 거동을 학습하도록 유도하는 항으로, 다음 식 (12a)와 같이 세 가지 항의 합으로 구성된다.

$$\mathcal{L}_{BC} = \mathcal{L}_{Sym} + \mathcal{L}_{Cont} + \mathcal{L}_{Free} \quad (12a)$$

$$\mathcal{L}_{Sym} = \frac{1}{N_s} \sum_{j=1}^{N_s} \left( \|u(0, z_j)\|^2 + \|\tau_{xz}(0, z_j)\|^2 \right) \quad (12b)$$

$$\mathcal{L}_{Cont} = \frac{1}{N_c} \sum_{k=1}^{N_c} \|\sigma'_z(x_k, P_k) - \sigma_z(x_k, P_k)\|^2 \quad (12c)$$

$$\mathcal{L}_{Free} = \frac{1}{N_f} \sum_{m=1}^{N_f} (\|\sigma_n\|^2 + \|\tau_{nt}\|^2) \quad (12d)$$

여기서  $\mathcal{L}_{Sym}$ 은 시편 중앙에서의 대칭 거동을 의미하며,  $N_s$ 는 대칭 경계 영역에 배치된 collocation point 개수를 나타낸다.  $\mathcal{L}_{Cont}$ 은 indenter와 support에 의한 접촉 경계조건을 의미하며,  $N_c$ 는 접촉 경계 영역에 배치된 collocation point 개수를 의미한다.  $\sigma'_z$ 은 Hybrid PINN이 예측한 접촉 응력을 의미하고,  $\mathcal{L}_{Cont}$ 은 식 (6)에서 정의된 이방성 헤르츠 접촉 이론에 따른 목표 응력( $\sigma_z$ ) 분포와의 차이가 최소가 되도록 한다.  $\mathcal{L}_{Free}$ 는 하중이 작용하지 않는 표면에서의 응력 자유 조건을 나타내며,  $N_f$ 는 자유 경계 영역에 배치된 collocation point 개수를 나타낸다.  $\sigma_n$ 은 수직 응력,  $\tau_{nt}$ 는 접선 방향으로 작용하는 응력을 의미한다.

마지막으로, FEA 참조 데이터와 Hybrid PINN의 예측값 사이의 변위 오차를 나타내는  $\mathcal{L}_{Data}$ 는 다음 식 (13)과 같다.

$$\mathcal{L}_{Data} = \frac{1}{N_d} \sum_{n=1}^{N_d} (\|u(x_n)\|^2 - \|u_{FEA}(x_n)\|^2 + \|w(x_n)\|^2 - \|w_{FEA}(x_n)\|^2) \quad (13)$$

여기서  $N_d$ 는 학습에 사용된 FEA 참조 데이터의 총 개수를 의미하며,  $u_{FEA}$ 와  $w_{FEA}$ 는 FEA 참조 데이터의  $x, z$ 방향 변위를 나타낸다.

각 항의  $\lambda_{PDE}$ ,  $\lambda_{BC}$  그리고  $\lambda_{Data}$ 는 각 손실항의 가중치에 해당하며, 물리적 정합성과 FEA 참조 데이터와의 적합성간 균형이 고려되어 각각 3.0, 1.0, 그리고 2.0으로 설정되었다.

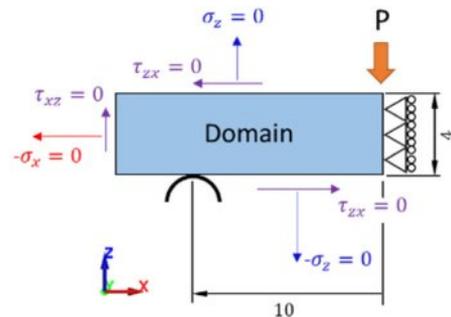


Fig. 3. Short-beam shear test problem definition

### 3. 결 과

#### 3.1 학습 수렴성 분석

제안된 Hybrid PINN의 학습 과정에 따른 손실 함수의 수렴 거동은 Fig. 4와 같다. 전체 학습 구간은 손실 함수의 감소 경향에 따라 크게 초기 급감 구간과 안정화 구간으로 구분될 수 있다.

학습 초기(0~3,000 epoch)에는 FEA 참조 데이터와의 오차를 나타내는  $\mathcal{L}_{Data}$ 가 급격히 감소하며 모델이 전체적인 변위장 거동을 빠르게 학습하는 경향을 보였다. 이는 Hybrid PINN의 학습이 평형 방정식에만 의존할 경우 불확실성이 높은 초기 학습 과정에서, FEA 참조 데이터가 해의 존재 가능성이 높은 영역으로 탐색 범위를 한정해 주는 역할로 작용되었음을 시사한다. 3,000 epoch 이후의 안정화 구간에서는  $\mathcal{L}_{BC}$ 와  $\mathcal{L}_{Data}$ 가 일정 수준으로 수렴한 상태에서, 평형 방정식의 잔차인  $\mathcal{L}_{PDE}$ 가 점진적으로 감소하는 양상을 나타냈다. 이는 모델이 FEA 참조 데이터가 존재하지 않는 collocation point 영역에서도 평형 방정식을 만족시키기 위해, 신경망 내부 가중치 파라미터를 미세하게 조정하며 해의 정밀도를 높여가는 과정으로 해석되며, 최종적으로 20,000 epoch 시점에서 모든 손실 항이 안정적으로 수렴됨을  $\mathcal{L}_{Total}$ 을 통해 확인할 수 있다.

#### 3.2 정성적 비교

학습이 완료된 Hybrid PINN 모델을 이용하여 최대 하중 조건에서의 층간 전단 응력 분포( $\tau_{xz}$ )를 예측하고, 이를 FEA 결과와 정성적으로 비교하였으며, 다음 Fig. 5와 같다. 비교 결과, Hybrid PINN은 FEA 해석 결과와 매우 유사한 응력 분포 패턴을 보였다. 특히 단보 전단 시험의 전형적인 특징인 indenter에서 support로 이어지는 ‘Wing[2]’ 형태의 전단 응력 집중 패턴이 명확하게 구현되었다. 또한 보 이론에 따라 시편의 두께 방향 중심축에서 최대 전단 응력이 발생하는 현상 역시 정확히 모사하였다. 주목할 점은 접촉 부위에서의 응력 분포이다. 이방성 헤르츠 접촉 이론이 도입된 Hybrid PINN은 하중 영역에서 응력이 한 점에 집중되지 않고 접촉 면적을 따라 연속적으로 분포하는 거동을 보였다. 이러한 하중에 따른 부드러운 응력 분포는 FEA 결과와 일치하

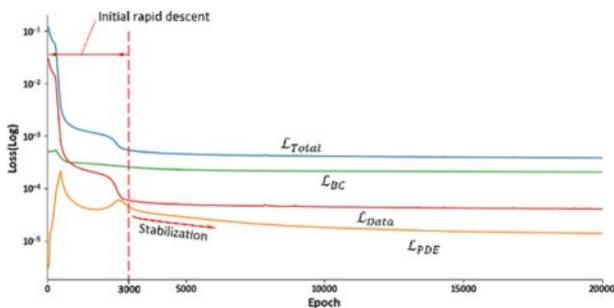


Fig. 4. Each loss convergence curves

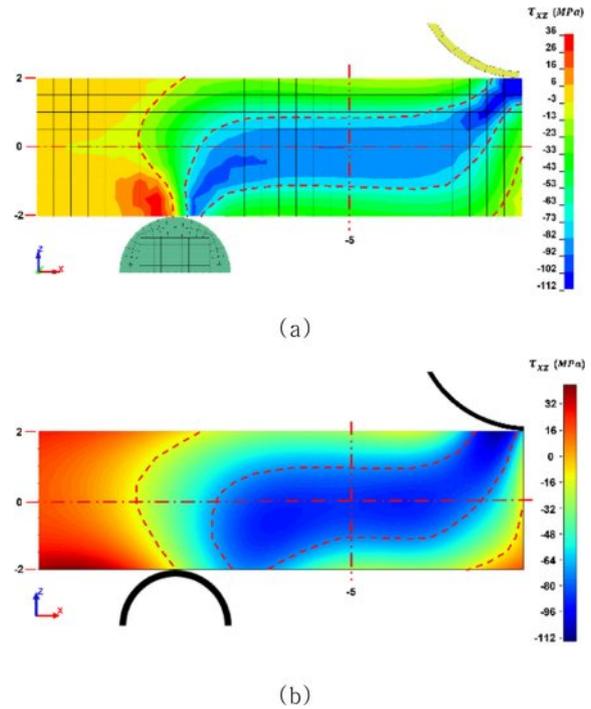
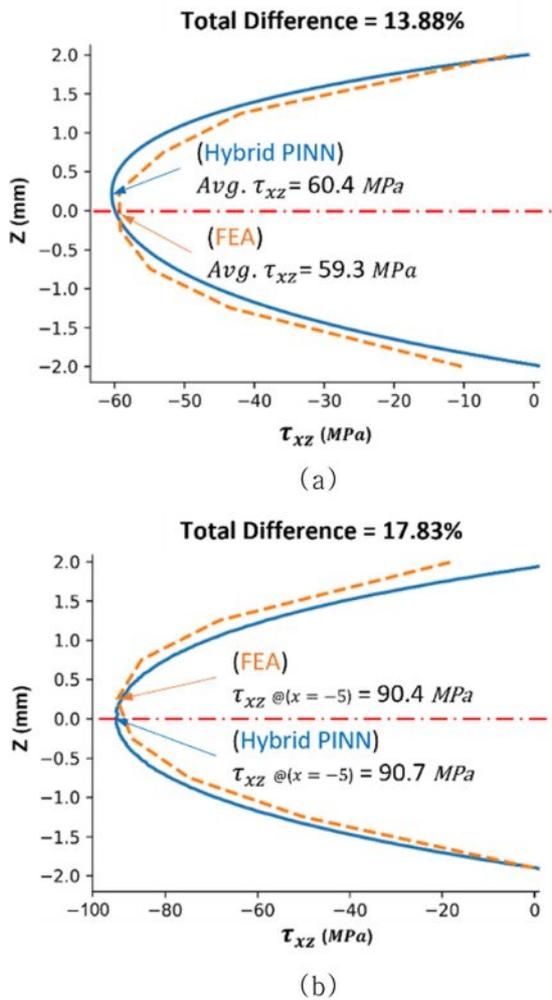


Fig. 5. Qualitative comparison of interlaminar shear stress at the max load: (a)  $\tau_{xz}$  in FEA, (b)  $\tau_{xz}$  in Hybrid PINN

며, 제안된 접촉 모델링 기법이 국부적인 응력 집중 현상을 효과적으로 모사하고 있음을 알 수 있다. 다만 support 부근에서 Hybrid PINN과 FEA 사이의 전단 응력장 차이는, 접촉 반력의 분포를 부여하는 방식의 차이에서 기인한 것으로 해석된다. Hybrid PINN에서는 이방성 헤르츠 접촉 이론을 기반으로 접촉 반력과 포물선형 수직 응력 분포를 물리 제약 조건으로 부과하여 접촉 하중을 연속적으로 모델링하였다. 반면 FEA에서는 접촉 알고리즘 및 접촉 강성에 의해 반력이 비선형적으로 재분배되며, 접촉/비접촉 전환 경계에서 국부 응력 구배가 급격히 변화할 수 있다[13–15]. 또한 PINN은 강형(Strong-form) 잔차 최소화에 기반하므로 지지점과 같이 구배가 큰 영역에서 점 단위 미분값 오차가 상대적으로 증폭될 수 있는 반면, FEA는 요소 평균 및 적분 기반 계산으로 인해 국부장에 스무딩 효과가 포함되며, 이는 곧 support 근방에서의 응력장 차이로 나타난 것으로 판단된다.

#### 3.3 정량적 비교

Hybrid PINN 모델의 예측 정확도를 정량적으로 검증하기 위해, 파손에 가장 치명적인 영향을 미치는 최대 하중 조건에서 두 가지 주요 단면에 대한 층간 전단 응력 값을 분석하였다. 우선 시편의 두께 방향 중심선( $x = 0$ )을 따라 층간 전단 응력의 평균 분포를 Fig. 6(a)과 같이 비교하였다. FEA와 PINN 모두 시편의 중심부( $z = 0$ )에서 최대 응력을 나타냈으며, 이때의 최대 전단 응력 평균값은 FEA가 59.3 MPa, Hybrid PINN이 60.4 MPa로 예측되어 약 1.8%의 근소한 차



**Fig. 6.** Quantitative comparison of interlaminar shear stress at the max load: (a) Average  $\tau_{xz}$  along the Z direction, (b)  $\tau_{xz}$  at  $x = -5$

이를 보였다. 나아가 실제 전단 파손이 주로 발생하는 하중점과 지지점의 중간 지점( $x = 5$ )에서의 두께 방향 응력 분포를 Fig. 6(b)와 같이 비교하였다. 해당 단면에서의 최대 층간 전단 응력은 FEA가 90.4 MPa, Hybrid PINN이 90.7 MPa를 기록하여, 오차율이 1% 미만(약 0.33%)에 불과한 매우 높은 정확도를 달성하였다. 다만, 전체적인 응력 분포 프로파일에서는 약 13.9%~17.8% 수준의 평균 오차가 관찰되었다. 이는 미분 방정식 기반으로 점 단위 즉, collocation point에서의 미분값을 최적화하는 Hybrid PINN과, 적분을 통해 요소 평균값을 도출하는 FEA의 수치 해석적 접근 방식의 차이에서 기인한 것으로 사료된다.

#### 4. 결 론

본 연구에서는 단보 전단 시험에서 발생하는 적층 복합

재의 층간 전단 응력을 효율적이고 안정적으로 예측하기 위해, 이방성 헤르츠 접촉 이론을 도입한 Hybrid Physics-Informed Neural Network(Hybrid PINN) 모델을 제안하였다. 기존 PINN이 접촉 경계에서의 응력 특이성과 수렴성 문제로 인해 적용에 한계를 보였던 반면, 본 연구에서는 이방성 접촉 거동을 물리 제약 조건으로 명시적으로 반영하고, 유한요소해석(FEA) 참조 데이터를 학습 초기 가이드로 활용함으로써 이러한 문제를 효과적으로 완화하였다.

제안된 Hybrid PINN 모델은 평면 응력 상태의 직교 이방성 탄성체를 대상으로 구성되었으며, 단보 전단 시험 조건에서의 하중-공간 좌표-변위 관계를 하나의 신경망으로 학습하도록 설계되었다. 학습 수렴성 분석 결과, FEA 참조 데이터 항은 초기 학습 단계에서 해의 탐색 범위를 안정적으로 제한하는 역할을 수행하였고, 이후 평형 방정식과 경계 조건 손실이 점진적으로 감소하며 물리적으로 타당한 해로 수렴함을 확인하였다.

정성적 비교 결과, Hybrid PINN은 FEA에서 관찰되는 전형적인 ‘Wing’ 형태의 층간 전단 응력 분포와 두께 방향 중심축에서의 최대 전단 응력 발생 위치를 정확히 재현하였다. 특히, 이방성 헤르츠 접촉 이론을 통해 하중점과 지지점에서의 응력이 점 집중 형태가 아닌 유한한 접촉 면적에 걸쳐 연속적으로 분포하는 거동을 효과적으로 모사하였다. 이는 접촉부 응력 특이성이 완화된 보다 현실적인 응력장을 예측할 수 있음을 의미한다.

정량적 비교 결과, 파손에 가장 민감한 최대 전단 응력 지점에서 Hybrid PINN의 예측값은 FEA 대비 1% 이내의 오차를 나타내어 매우 높은 정확도를 확보하였다. 구조 건전성 평가에 핵심적인 최대 층간 전단 응력의 위치와 크기를 정확히 예측하였다는 점에서, 제안된 모델의 실용적 유효성이 입증되었다. 그러나 전체 응력 분포에서 평균 오차가 10% 이상으로 도출된 것은 점 기반 강형 해석을 수행하는 PINN과 요소 평균값을 기반으로 계산하는 FEA의 수치적 접근 방식 차이에 의한 것으로 판단된다. 또한 학습에 사용된 최적화기인 Adam이 초기 수렴에는 좋지만, 정밀한 수렴에는 한계가 있으므로[16] Hybrid PINN 학습에 특화된 최적화기 설계가 이뤄진다면 평균 오차가 크게 줄어들 것으로 사료된다.

본 연구에서 제안한 Hybrid PINN은 이방성 접촉 문제와 복합재 특유의 층간 전단 거동을 동시에 고려할 수 있는 효율적인 예측 프레임워크를 제공한다. 이는 반복적인 Mesh 수정과 높은 계산 비용이 요구되는 기존 FEA를 보완할 수 있는 대안적 접근법으로서, 향후 실험 데이터 기반 보정, 비선형 재료 거동 및 손상 모델의 확장, 3차원 해석으로의 적용을 통해 구조 건전성 모니터링 및 실시간 평가 분야로의 활용 가능성이 기대된다.

## 후 기

본 논문은 한국 정부(MSIT)의 재원으로 국가과학기술연구회(NST)의 지원을 받아 수행되었습니다(CRC23011-210) 또한 본 연구성과는 2025년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. RS-2025-25430087).

## REFERENCES

1. Laminates, T., "Standard Test Method for Short-Beam Strength of Polymer Matrix Composite Materials," Vol. 03, 2000.
2. Allott, N.R. and Czabaj, M.W., "Characterization of the interlaminar shear strength of IM7 / 8552 using small-scale short beam shear tests," *Composites Part A*, Vol. 142, 2021, p. 106200.
3. "ASTM D2344 / D2344M Standard Test Method for Short-Beam Strength of Polymer Matrix Composite Materials and Their Laminates," 2022.
4. Nishimura, A., "Effect of radius of loading nose and supports in short beam test fixture on fracture mode and interlaminar shear strength of gfrp at 77 k," *AIP Conference Proceedings*, Vol. 986, 2008, pp. 50–59.
5. Khalid, S., Yazdani, M.H., Azad, M.M., Elahi, M.U., Raouf, I., and Kim, H.S., "Advancements in Physics-Informed Neural Networks for Laminated Composites: A Comprehensive Review," *Mathematics*, Vol. 13, No. 1, 2025, pp. 17.
6. Haghighat, E., Raissi, M., Moure, A., Gomez, H., and Juanes, R., "A deep learning framework for solution and discovery in solid mechanics," Vol. 379, 2020.
7. Geneva, N. and Zabaraz, N., "Modeling the dynamics of PDE systems with physics-constrained deep auto-regressive networks," *Journal of Computational Physics*, Vol. 403, 2020, p. 109056.
8. Bai, J., Lin, Z., Wang, Y., Wen, J., Liu, Y., Rabczuk, T., Gu, Y.T., and Feng, X.Q., "Energy-based physics-informed neural network for frictionless contact problems under large deformation," *Computer Methods in Applied Mechanics and Engineering*, Vol. 437, 2025, p. 117787.
9. Willis, J.R., "Hertzian contact of anisotropic bodies," *Journal of the Mechanics and Physics of Solids*, Vol. 14, No. 3, 1966, pp. 163–176.
10. Lekhnitskii, S.G., "Anisotropic plates," 1968.
11. May, M., Arnold-Keifer, S., and Haase, T., "Damage resistance of composite structures with unsymmetrical stacking sequence subjected to high velocity bird impact," *Composites Part C: Open Access*, Vol. 1, 2020, p. 100002.
12. Zoph, B. and Le, Q. V., "Searching for activation functions," *6th International Conference on Learning Representations, ICLR 2018 - Workshop Track Proceedings*, No. 1, 2018, pp. 1–12.
13. Kloosterman, G., "Contact methods in finite element simulations," 2002.
14. Herrmann, L.R., "Finite Element Analysis of Contact Problems," *ASCE Journal of the Engineering Mechanics Division*, Vol. 104, No. 5, 1978.
15. Zhang, J. and Aragón, A.M., "An improved stress recovery technique for the unfitted finite element analysis of discontinuous gradient fields," *International Journal for Numerical Methods in Engineering*, Vol. 123, No. 3, 2022, pp. 639–663.
16. Weng, M., Mao, Z., and Shen, J., "Deep collocation method: A framework for solving PDEs using neural networks with error control," Vol. 48, No. 1, 2026, pp. C77-C102.