



물리 정보 신경망 기반 3차원 내압 구조물 거동의 하이브리드 예측 모델

최다정^{a,†}, 박진욱^{a,†}, 신보성^{a,*}

Hybrid Prediction Model of Structural Behavior Under Three-Dimensional Internal Pressure Based on Physics-Informed Neural Networks

Dajeong Choi^{a,†}, Jinwook Park^{a,†}, Bosung Shin^{a,*}^a Department of Optics and Mechatronics Engineering, Pusan National University

ARTICLE INFO

Article history:

Received 26 December 2025
Revised 3 February 2026
Accepted 3 February 2026

Keywords:

Physics-informed neural networks (PINN)
Surrogate modeling
Von Mises stress prediction
Pressure vessel
Machine learning (ML)
Transfer learning

ABSTRACT

The accurate prediction of structural responses under complex loading is crucial for ensuring structural integrity in engineering systems. Conventional finite element method (FEM) analyses provide high-fidelity solutions but become computationally expensive for iterative evaluations, whereas purely data-driven deep-learning models exhibit limited extrapolation capability and reduced physical consistency. This study proposes a hybrid physics-informed neural network surrogate model for a three-dimensional oil-water separator pressure vessel subjected to internal pressure. The model integrates FEM-generated displacement and stress data with soft physics constraints from linear elasticity and boundary conditions. To improve the training stability in high-dimensional settings, a two-stage transfer learning strategy comprising data-driven pretraining followed by physics-informed fine-tuning is adopted. Validation results indicate the accurate prediction of displacement and von Mises stress fields as well as reliable performance under unseen pressure conditions, including extrapolation at 4.0 MPa, highlighting the potential of the proposed model for rapid and efficient structural assessment.

1. 서론

항공우주, 기계, 에너지 시스템 등 다양한 공학 분야에서 구조물의 구조적 건전성(structural integrity)을 확보하기 위해서는 외력, 유동, 열과 같은 복합적인 하중 조건 하에서의 시스템 응답을 정확히 예측하는 것이 필수적이다. 그러나 실제 물리 시스템은 강한 비선형성과 다중 물리 상호작용을 포함하며, 그 거동은 상호 결합된 고차 편미분 방정식(partial differential equations, PDEs)으로 기술된다. 이러한 특성으로 인해 일반적으로 수학적 해석해

(analytical solution)의 도출은 제한적이며, 현실적인 공학 문제에 직접 적용하기에는 근본적인 한계가 존재한다^{1, 2)}.

이 때문에 유한요소법(finite element method, FEM)은 복잡한 형상과 다양한 경계 조건을 정밀하게 반영할 수 있는 대표적인 수치해석 도구로 자리 잡아왔다. FEM은 구조 응답을 높은 해상도로 계산할 수 있다는 장점이 있으나, 해석 도메인을 요소로 분할하는 격자 생성(mesh generation)이 필수적이며, 설계 변경 및 최적화 과정처럼 반복 연산이 수반되는 상황에서는 계산 비용과 시간이 급격히 증가한다는 문제를 가진다^{3, 4)}. 또한, 입력 조건이 달라질

† These authors equally contributed to this work.

* Corresponding author. Tel.: +82-51-510-3310

E-mail address: bosung@pusan.ac.kr (Bosung Shin).

경우 전체 시뮬레이션을 다시 수행해야 하므로, 실시간 예측이나 다변수 파라미터 탐색 측면에서는 활용 효율이 제한된다⁵⁾.

최근에는 이러한 계산 부담을 줄이기 위한 대안으로 기계학습(machine learning, ML)이 주목받고 있다. 특히 딥러닝(deep learning)은 복잡한 비선형 매핑을 근사할 수 있는 표현력을 바탕으로 고비용 수치해석 결과를 빠르게 대체할 가능성을 보여주었으며, 반복 설계 및 최적화 문제에서 계산 효율을 크게 향상시킬 수 있다^{6,7)}. 다만 순수 데이터 기반(data-driven) 모델은 학습 데이터에 대한 의존도가 높고, 물리 법칙을 내재적으로 반영하지 못한다는 한계를 가진다. 결과적으로 학습 범위를 벗어난 외삽(extrapolation) 조건에서는 예측 성능이 급격히 저하되거나, 물리적 일관성(physical consistency)이 결여된 해를 산출할 위험이 존재한다^{8,9)}.

이와 같은 문제를 완화하기 위한 접근으로, 물리 정보 신경망(physics-informed neural networks, PINN)은 지배 방정식(governing equations)과 경계 조건(boundary conditions)을 손실 함수(loss function)의 제약으로 포함하여 학습 과정에 물리 법칙을 직접적으로 반영하는 방법론으로 제안되었다¹⁰⁾. PINN은 상대적으로 적은 양의 데이터로도 물리적으로 타당한 해를 유도할 수 있으며, 격자 생성이 불필요한(mesh-free) 형태로 연속적인 해 공간을 구성할 수 있다는 장점이 가진다. 따라서 PINN은 FEM 기반 고정밀 데이터와 결합될 경우, 계산 효율성과 물리 일관성을 동시에 확보하는 하이브리드 모델로 확장될 수 있다.

그럼에도 불구하고 기존 PINN 연구는 주로 2차원 또는 단순 기하 형상 문제에 집중되어 왔으며, 복잡한 3차원 산업용 구조물로의 적용 사례는 여전히 제한적이다¹¹⁻¹³⁾. 특히, 내부 형상이 복잡하고 경계 조건이 다양하게 분포하는 3차원 문제에서 FEM 데이터와 물리 제약을 결합하고, 학습 범위를 넘어서는 외삽 조건에서 일반화 성능을 체계적으로 검증한 연구는 드문 실정이다.

이에 본 연구에서는 복잡한 3차원 산업용 유수분리기 압력용기를 대상으로 고정밀 FEM 데이터와 PINN의 물리 제약을 결합한 하이브리드 프레임워크를 제안한다. 또한, 3차원 고차원 문제에서 빈번히 나타나는 학습 불안정성을 완화하기 위해, 데이터 기반 사전 학습(pre-training)과 물리 정보 기반 미세 조정(fine-tuning)으로 구성된 2단계 전이 학습(transfer learning) 전략을 도입하였다. 이를 통해 전역 응답을 안정적으로 학습하는 동시에, PDE 및 경계 조건 제약을 통해 물리적 일관성과 외삽 구간에서의 일반화 성능을 강화하고자 한다.

2. 본 론

2.1 유한요소해석 및 데이터 생성

본 연구에서는 유수분리기(oil-water separator)의 내압 성능을




Fig. 1 Schematic diagrams of the oil-water separator

평가하고, 물리 정보 신경망(physics-informed neural networks, PINN) 학습에 필요한 고정밀 데이터를 확보하기 위해 상용 유한요소해석 소프트웨어인 Abaqus를 사용하여 구조 해석을 수행하였다.

해석 대상인 유수분리기 압력용기는 복잡한 곡면을 포함한 3차원 형상으로 구성된다. Fig. 1은 해석에 사용된 모델의 형상 및 주요 치수를 나타낸다. 전체 높이는 약 180 mm이며, 외경은 약 60 mm, 벽 두께는 약 5 mm로 설계되었다. 본 연구에서는 해당 기하학적 특징을 반영하여 3차원 모델을 구축하고, 이를 기반으로 내압 조건에서의 구조 응답을 평가하였다.

압력용기의 소재는 Nylon 6로 설정하였다. 또한 고압 조건에서의 소성 변형 및 파손 가능성을 고려하기 위해 탄소성(elastic-plastic) 구성 방정식과 연성 손상 기준(ductile damage criterion)을 적용하였다. Nylon 6의 소성 거동은 등방 경화(isotropic hardening) 법칙을 따르는 것으로 가정하였으며, 손상 개시(damage initiation)는 파단 변형률($\bar{\epsilon}_D^{pl}$)을 응력 삼축비(η) 및 소성 변형률 속도($\dot{\epsilon}^{pl}$)의 함수로 정의하여 평가하였다.

$$\bar{\epsilon}_D^{pl}(\eta, \dot{\epsilon}^{pl}) \quad (1)$$

손상 발생 이후의 재료 거동은 파괴 에너지(fracture energy)에 기반한 손상 진전(damage evolution) 모델을 통해 강성 저하(stiffness degradation)로 모사하였으며, 최종적으로 요소 삭제(element deletion) 소멸되도록 설정하였다. 이를 통해 내압 증가

Table 1 Material properties of Nylon 6

Property	Value	Unit
Young's modulus (E)	2,500	MPa
Poisson's ratio (ν)	0.39	-
Density (ρ)	1.13×10^{-9}	ton/mm ³
Yield stress (σ_y)	85	MPa

Table 2 Ductile damage parameters for Nylon 6

Fracture strain	Strain triaxiality	Strain rate [s^{-1}]	Fracture energy [N/mm]
0.6	0	0.001	5
0.25	0.33		
0.18	0.5		
0.15	0.67		
0.1	1		

에 따른 국부 파열 가능성과 구조적 한계 거동을 해석에 반영하였다. Nylon 6의 기계적 물성과 연성 손상 파라미터는 각각 Table 1과 Table 2에 정리하였다.

해석의 정확도와 수렴성을 확보하기 위해 요소를 2 mm 크기의 4면체 요소(C3D4)로 구성하여 격자를 생성하였다. 경계 조건 (boundary condition)으로는 실제 지지 상태를 모사하기 위해 상단 지지부를 고정(fixed support)하여 변위 및 회전 자유도를 구속하였으며, 하중 조건으로는 압력용기 내부 표면에 등분포 내압을 적용하였다. 내압은 전체 해석 시간(step time) 0.1 s 동안 점진적으로 증가하도록 설정하여 준정적(quasi-static) 거동을 모사하였다. 이러한 조건에서 총 8가지 내압(0.5-4.0 MPa, 0.5 MPa 간격)에 대해 해석을 수행하고 각 조건에서의 응력 및 변위 분포를 평가하였다.

해석 결과, 내압이 증가함에 따라 용기 벽 두께 방향의 응력과 변위가 전반적으로 단조 증가하는 경향을 확인하였다. 최대 주응력(σ_{max})과 최대 폰 미세스 응력($\sigma_{VM,max}$)은 내압 증가에 따라 증가하였으며, 최대 변위($|u|_{max}$) 또한 내압 0.5 MPa에서 수십 μ m 수준에서 4.0 MPa일 때 수 mm 수준으로 증가하였다. Table 3에는 내압 조건별 최대 주응력(σ_{max})과 최대 변위($|u|_{max}$) 값을 정리하였다. 응력은 용기 중심부보다 고정부 등 경계 인근에서 상대적으로 크게 나타났으며, 변위는 용기 전체가 팽창하는 형태로 증가하는 경향을 보였다.

최종적으로 유한요소해석을 통해 획득한 노드별 좌표(x, y, z), 시간 t , 압력 p 에 따른 변위(u_x, u_y, u_z) 및 응력 텐서 성분($\sigma_{11}, \sigma_{22}, \sigma_{33}, \sigma_{12}, \sigma_{13}, \sigma_{23}$)은 2.3절에서 제안하는 PINN 모델의 학습 및 검증 데이터로 활용되었다.

2.2 물리 정보 신경망의 이론적 배경

물리 정보 신경망(PINN)은 딥러닝의 기반 함수 근사(function

Table 3 Summary of FEA results under various internal pressure conditions

	Max. Von Mises stress ($\sigma_{VM,max}$)	Max. displacement ($ u _{max}$)
0.5 MPa	18.5 MPa	0.63 mm
1.0 MPa	33.2 MPa	1.29 mm
1.5 MPa	52.2 MPa	1.96 mm
2.0 MPa	75.2 MPa	2.61 mm
2.5 MPa	75.7 MPa	3.23 mm
3.0 MPa	78.7 MPa	3.88 mm
3.5 MPa	82.2 MPa	4.71 mm
4.0 MPa	86.1 MPa	5.49 mm

approximation) 능력과 물리 법칙 기반 제약 조건을 결합한 방법론으로, Raissi et al.에 의해 제안되었다^[1]. 기존의 데이터 기반 딥러닝 모델은 입력과 출력 사이의 매핑 관계를 중심으로 학습이 이루어지므로, 학습 데이터 범위를 벗어난 조건에서 물리적 일관성이 저하될 수 있다. 반면, PINN은 지배 방정식인 편미분 방정식의 잔차(residual)를 손실 함수에 포함함으로써, 물리 법칙을 만족하는 해를 탐색하도록 학습을 유도한다.

3차원 선형 탄성 문제에서 PINN은 주어진 도메인 Ω 와 경계 Γ 에 대해 다음의 운동량 보존 법칙을 만족하도록 구성된다.

$$\nabla \cdot \sigma + f = 0 \quad \text{in } \Omega \tag{2}$$

여기서 Ω 는 코시 응력 텐서(Cauchy stress tensor), f 는 체적력(body force)을 의미한다. 또한, 변형률-변위 관계식과 선형 탄성 구성 방정식은 다음과 같이 정의된다.

$$E = \frac{1}{2} (\nabla u + (\nabla v)^T) \tag{3}$$

$$\sigma = \lambda \text{tr}(\epsilon)I + 2\mu\epsilon \tag{4}$$

여기서 ϵ 은 변형률 텐서, u 는 변위 벡터, λ 와 μ 는 선형 탄성 재료의 응력-변형률 관계를 정의하는 라메 상수(Lamé parameters)이다. PINN은 이러한 물리적 제약 조건을 학습 과정에서 규제항(regularization term)으로 포함함으로써, 데이터가 희소하거나 노이즈가 포함된 상황에서도 물리적으로 타당한 해석 결과를 제공할 수 있다.

본 연구의 목적은 상기 지배 방정식의 엄밀해(exact solution)를 직접 계산하는 것이 아니라, 고비용 수치해석을 대체할 수 있는 빠르고 효율적인 물리 기반 대리 모델(surrogate model)을 구축하는 데 있다. 이를 위해 본 연구에서는 데이터의 현실성과 물리 제약의 일반화 성능을 결합하는 하이브리드 학습 전략을 채택하였다.

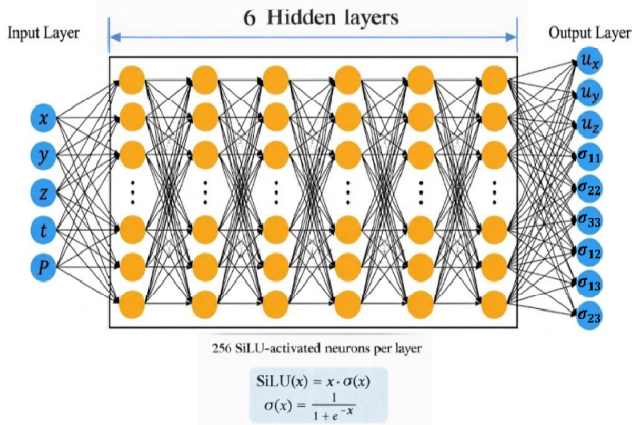


Fig. 2 Schematic diagram of the proposed PINN architecture

구체적으로, 실제 구조물의 비선형 거동은 고정밀 FEM 데이터 기반 손실항 L_{data} 를 통해 신경망이 우선적으로 학습하도록 구성하였다. 반면 선형 탄성 지배방정식은 학습 과정에서 물리적으로 불가능한 해를 억제하고, 데이터 노이즈에 대한 과적합(overfitting)을 완화하기 위한 최소한의 물리 제약으로 활용하였다. 특히 3차원 복잡 형상 문제에서 비선형 구성 방정식을 손실 함수에 직접 포함할 경우 최적화 난이도가 증가하여 수렴 안정성이 저하될 수 있으므로, 본 연구에서는 선형 탄성 방정식을 연성 제약으로 적용하여 학습 안정성을 확보하였다. 이와 동시에 FEM 데이터와 결합함으로써 고압 조건에서 나타나는 비선형적 거동 경향까지 효과적으로 예측할 수 있도록 설계하였다.

2.3 PINN 모델 구조 및 학습 방법

2.3.1 물리 정보 신경망 구조

본 연구에서는 다양한 내압 조건에서 유수분리기 압력용기의 구조 응답을 예측하기 위해 완전 연결 신경망(fully connected neural network, FCNN) 기반의 물리 정보 신경망을 구성하였다. 모델의 개략도는 Fig. 2에 제시하였다.

입력층(input layer)은 시공간 좌표 및 하중 조건을 포함하는 5차원 벡터(x, y, z, t, p)로 정의하였다. 출력층(output layer)은 변위 벡터와 응력 텐서 성분을 포함한 9차원 벡터($u_x, u_y, u_z, \sigma_{11}, \sigma_{22}, \sigma_{33}, \sigma_{12}, \sigma_{13}, \sigma_{23}$)로 구성하였다. 은닉층(hidden layer)은 총 6개 층으로 설정하였으며, 각 층은 256개 뉴런으로 구성하였다. 활성화 함수(activation function)로는 미분 가능하며 깊은 네트워크에서도 비교적 안정적인 학습이 가능한 Sigmoid Linear Unit (SiLU)를 사용하였다.

2.3.2 전이 학습 기반의 2단계 최적화 전략

복잡한 3차원 형상과 다항 손실 최적화에서 학습 수렴성을 확보

하기 위해, 본 연구에서는 2단계 전이 학습 전략을 채택하였다. 일반화 성능 평가를 위해 학습 데이터는 1.0, 2.0, 3.0 MPa 조건에서만 구성하였으며, 각 조건에서 125,000개 노드 데이터를 추출하였다. 반면 0.5 MPa(내압 구간) 및 4.0 MPa(외압 구간)를 포함한 미 학습 압력 조건은 학습에 전혀 사용하지 않고 최종 성능 평가에만 활용하였다.

(1) 1단계: 데이터 기반 사전 학습

첫 번째 단계에서는 FEM 해석 데이터(1-3 MPa)를 이용하여 신경망이 변위 및 응력장의 전반적인 경향성을 우선적으로 학습하도록 하였다. 이 단계에서는 지배방정식 손실 L_{PDE} 와 경계조건 손실 L_{BC} 를 제외하고, 데이터 손실 L_{data} 및 구성방정식의 일관성 손실 L_{cons} 만을 사용하여 학습 효율을 높였다. 학습은 5,000 Epochs 동안 수행하였으며, 배치 크기(batch size) 32,768, 학습률(learning rate) 5×10^{-4} 를 적용하였다.

(2) 2단계: 물리 정보 기반 미세 조정

두 번째 단계에서는 1단계에서 학습된 가중치를 초기값으로 사용하고, 물리 방정식과 경계 조건 잔차를 손실 함수에 포함하여 미세 조정(fine-tuning)을 수행하였다. 이를 통해 데이터가 존재하지 않는 영역에서도 물리 제약을 만족하도록 예측 해를 보정하였다. 2단계 학습은 3,000 Epochs 동안 진행하였으며, 학습률은 초기 1×10^{-5} 에서 시작하여 마지막 1,000 Epochs 구간(tail epoch)에서는 2×10^{-6} 으로 감소시키는 스케줄러를 적용하였다.

2.3.3 손실 함수의 정의 및 구성

학습에 사용된 전체 손실 함수는 데이터 오차와 물리적 제약 항들의 가중합으로 정의된다.

$$L = L_{data} + W_{pde}L_{PDE} + W_{bc}L_{BC} + W_{cons}L_{cons} \quad (5)$$

각 항의 구체적인 물리적 의미와 수식적 정의는 다음과 같다.

데이터 손실 L_{data} 은 PINN 예측값과 FEM 해석값 간의 차이를 최소화한다. 구조 해석에서 변위는 $10^{-2} \sim 10^{-1}$ mm 수준의 상대적으로 작은 값인 반면, 응력은 $10^1 \sim 10^2$ MPa 수준의 큰 값을 가지므로 단순 MSE를 사용할 경우 학습이 특정 물리량에 편향될 수 있다. 이를 완화하기 위해 본 연구에서는 각 출력 성분의 데이터 표준편차 $\sigma_{k,sta}$ 로 정규화한 Normalized MSE를 사용하고, 물리량별 가중치 α_k 를 적용하였다. 여기서 N_d 는 데이터 샘플 수이며, 본 연구에서는 변위에 $\alpha_u = 4.0$, 응력에 $\alpha_\sigma = 10.0$ 을 적용하였다.

$$L_{data} = \sum_{k \in \{u, \sigma\}} \alpha_k \left(\frac{1}{\sigma_{k, std}} \right)^2 \frac{1}{N_d} \sum_{i=1}^{N_d} \| y_{pred, k, i} - y_{GT, k, i} \|^2 \quad (6)$$

구성 방정식 손실 L_{cons} 은 예측된 변위장 u_{pred} 과 응력장 σ_{pred} 사이의 물리적 모순을 줄이기 위한 항이다. Pytorch 자동 미분을 통해 u_{pred} 로부터 변형률 ε 을 계산하고, 후의 법칙으로부터 응력 $\sigma(\varepsilon)$ 을 산출한 뒤, 이를 σ_{pred} 와 일치시키도록 구성하였다.

$$L_{cons} = \frac{1}{N_c} \sum_{i=1}^{N_c} \| \sigma_{pred, i} - \sigma(\nabla u_{pred, i}) \|^2 \quad (7)$$

지배 방정식 손실 L_{PDE} 은 도메인 내부의 임의의 점 (collocation points)에서 선형 탄성 평형 방정식($\nabla \cdot \sigma = 0$)의 잔차를 최소화한다. 3차원 공간에서의 힘 평형이 만족되도록, 발산 벡터의 각 성분에 대해 제곱합 형태로 정의하였다.

$$L_{PDE} = \frac{1}{N_f} \sum_{i=1}^{N_f} [(\nabla \cdot \sigma_{pred})_{x, i}^2 + (\nabla \cdot \sigma_{pred})_{y, i}^2 + (\nabla \cdot \sigma_{pred})_{z, i}^2] \quad (8)$$

경계 조건 손실 L_{BC} 은 고정부의 변위 구속(dirichlet)과 내압 작용면의 표면력 조건(neumann)을 반영하기 위해 두 항으로 구성하였다.

$$L_{BC} = L_{Hole} + L_{Press} \quad (9)$$

고정부에서는 $u = 0$ 을 만족하도록 하며, 내압 작용면에서는 $\sigma n = -Pn$ 의 조건을 만족하도록 정의하였다.

$$L_{BC} = \frac{1}{N_{hole}} \sum_{i=1}^{N_{hole}} \| u_{pred, i} \|^2 + \frac{1}{N_{press}} \sum_{i=1}^{N_{press}} \| (\sigma_{pred, i} \cdot n_i) - (-P_i \cdot n_i) \|^2 \quad (10)$$

최종적으로 2단계 학습에서 가중치는 $W_{pde} = 0.3$, $W_{cons} = 5.0$, $W_{bc} = 20.0$ 으로 설정하였다. 이 값들은 손실 항들 간 스케일 불균형 완화, 경계조건 위반이 정체 해석장에 미치는 영향, 학습 수렴 안정성을 종합적으로 고려한 예비 실험을 통해 결정하였다. 특히 3차원 복잡 형상에서는 경계 오차가 내부로 전파되기 쉬우므로, 경계조건 손실에 상대적으로 큰 가중치를 부여하여 전체 물리 일관성을 우선적으로 확보하도록 하였다.

2.4 연구 결과 및 고찰

2.4.1 학습 안정성 및 수렴 거동

제안한 PINN 모델의 학습 안정성을 확인하기 위해 물리 기반 미세 조정 단계에서 손실 함수의 수렴 거동을 분석하였다(Fig. 3). Fig. 3은 개별 손실 항과 전체 손실의 변화를 나타낸다. 학습 초기




Fig. 3 Evolution of individual loss components and total loss during PINN training




Fig. 4 RMSE of displacement magnitude $|U|$ versus pressure

에는 경계조건 손실이 빠르게 감소하며 전체 손실 감소를 주도하였고, 이는 신경망이 우선적으로 경계 제약을 만족하는 방향으로 최적화되었음을 의미한다. 중반부(300-1,000 epochs)에서는 변위 관련 손실과 지배방정식 잔차가 비교적 안정화되는 가운데, 구성 방정식 제약 항 및 응력 관련 손실이 점진적으로 감소하였다. 후반부(1,500 epochs 이후)에서는 모든 손실 항이 큰 진동 없이 완만하게 수렴하여, 다항 손실이 동시에 감소하는 방향으로 학습이 진행되었음을 확인하였다.

2.4.2 정량적 오차 분석

예측 정확도는 평균 제곱근 오차(root mean square error, RMSE)를 이용해 평가하였다. RMSE는 물리량의 단위(mm, MPa)를 유지하므로 직관적인 해석이 가능하며, 큰 오차에 더 큰 가중을 부여하는 특성이 있다. Fig. 4와 Fig. 5는 내압 변화에 따른 변위 크기와 및 폰 미세스 응력의 RMSE 변화를 나타낸다.

두 물리량 모두 내압이 증가할수록 RMSE가 증가하는 경향을 보였다. 이는 RMSE가 절대오차 기반 지표이므로, 물리량의 절대 크기가 커질수록 오차 역시 증가할 수 있음을 반영한다. 특히 폰




Fig. 5 RMSE of Von Mises stress versus pressure




Fig. 8 Comparison of Von Mises stress under different pressure conditions




Fig. 6 FEM-PINN comparison of mean displacement magnitude under training pressure conditions




Fig. 7 FEM-PINN comparison under unseen pressure conditions

미세스 응력은 여러 응력 성분의 비선형 결합으로 계산되며, 또한 응력 자체가 변위장의 공간 미분과 연계되는 물리량이므로 변위 예측의 미세 오차가 응력 및 폰 미세스 계산 과정에서 증폭될 수 있다. 따라서 고압 조건에서의 RMSE 변화는 물리량 스케일과 후처리 계산 특성을 함께 고려하여 해석할 필요가 있다.

2.4.3 일반화 성능 및 응력 거동

PINN의 일반화 성능을 평가하기 위해 학습 압력 조건(1.0, 2.0, 3.0 MPa)과 미학습 압력 조건(0.5, 1.5, 2.5, 3.5, 4.0 MPa)에서의 예측 결과를 FEA 결과와 비교하였다(Fig. 6, Fig. 7). 비교 결과,

학습 구간 내 내압 조건(1.5, 2.5 MPa) 뿐 아니라 학습 범위를 벗어난 외압 조건에서도(0.5, 4.0 MPa) 변위 거동의 전반적인 추세가 FEM 결과와 일관되게 나타났다. 이는 데이터 손실에 더해 지배방정식 및 경계조건 제약이 학습 과정에서 예측 해의 물리적 범위를 제한함으로써, 제한된 학습 압력 조건에서도 연속적인 압력-응답 관계를 근사하는 데 기여했음을 시사한다.

Fig. 8은 압력 조건별 폰 미세스 응력 예측 결과를 비교한 것이다. 응력의 전반적인 증가 추세 및 분포 경향은 FEM과 유사하게 재현되었으나, 고압 조건에서 응력이 급격히 변하는 국부 영역에서는 최대 응력값이 다소 완화되어 예측되는 경향이 관찰되었다. FEM은 요소 기반 이산화 계산으로 국부 피크 값을 선명하게 포착하는 데 유리한 반면, PINN은 연속 함수로 해를 근사하므로 급격한 값이 변화 구간에서 평활화(smoothing) 경향이 나타날 수 있다. 또한, 손실 최소화 과정에서 전체 오차를 감소시키는 방향이 국부 극값을 정확히 일치시키는 것보다 우선시될 수 있어, 결과적으로 최대 응력이 다소 완화되어 나타난 것으로 해석된다.

2.4.4 공간적 오차 분포 및 기하학적 상관성

예측 신뢰도를 확인하기 위해 오차의 공간적 분포를 분석하였다(Fig. 9, Fig. 10). 변위 오차(Fig. 9)는 무작위로 분포하기보다는 두께 변화, 곡률 변화, 형상 급변부 등 기하학적 불연속 영역에서 상대적으로 크게 나타났다. 특히 변위가 구속된 지지부와 자유 변형이 발생하는 몸체 사이 경계에서는 변위 구배가 급격히 변하므로, 예측 난이도가 증가하는 경향을 보였다.

응력 오차(Fig. 10)는 변위 오차보다 국부적으로 더 집중되는 양상을 보였다. 응력은 변위장의 공간 미분과 직접적으로 연계되므로, 변위 예측에서 발생한 미세 오차가 응력 계산 과정에서 증폭되기 때문이다. 오차 집중 영역은 응력 집중이 발생하는 모서리 및 체결부 형상과 높은 상관성을 보였으며, 이는 오차가 단순 노이즈가 아니라 복잡 형상에서의 구조적 해석 난이도와 연관됨을 시




Fig. 9 Spatial distribution of displacement magnitude prediction error at different pressure levels




Fig. 10 Spatial distribution of Von Mises stress prediction error at different pressure levels

사한다.

또한, 내압이 증가할수록 높은 오차가 나타나는 영역이 확장되는 경향을 확인하였다. 이는 변형 및 응력의 절대 규모가 커질수록 예측해야 할 함수 범위가 넓어져 학습 난이도가 증가하는 효과로 해석할 수 있다. 종합하면, 국부 피크 값의 차이는 존재하더라도 PINN은 취약 부위의 위치 및 전반적인 구조 거동을 안정적으로 재현하며, 구조 응답 예측의 대리 모델로서 활용 가능성을 확인하였다.

3. 결론

본 연구에서는 내압을 받는 3차원 구조물의 변위 및 폰 미세스 응력을 예측하기 위해 물리 정보 신경망 기반의 물리 대리 모델을

구축하였으며, 유한요소해석 결과와의 비교를 통해 제안 모델의 유효성을 검증하였다. 본 연구의 주요 결론은 다음과 같다.

첫째, 2단계 학습 전략을 적용한 결과, 학습 과정에서 개별 손실 항들이 큰 진동 없이 점진적으로 수렴하였고, 경계조건 및 지배방정식 제약이 학습 안정화에 기여함을 확인하였다.

둘째, 내압이 증가할수록 RMSE가 증가하는 경향은 RMSE가 절대 오차 기반 지표라는 특성과 물리량의 절대 규모 증가에 따른 스케일 효과에 의해 설명될 수 있으며, 단순히 모델 성능 저하로 해석하기 어렵다는 점을 논의하였다.

셋째, 변위 예측 결과는 학습에 사용된 압력 조건뿐 아니라 미학습 압력 조건에서도 FEM 결과와 전반적으로 일치하는 추세를 보였으며, 이는 데이터 적합과 더불어 물리 제약이 예측 해의 물리적 범위를 제한, 보정하는 역할을 수행했음을 시사한다.

넷째, 응력 예측에서는 분포의 전반적인 경향이 FEM과 유사하게 재현되었으나, 급격한 변화가 발생하는 국부 영역에서는 연속 함수 기반 근사 특성에 따른 평활화 경향으로 최대 응력값이 다소 완화되어 예측되었다. 또한 공간적 오차 분석을 통해 오차가 무작위로 분포하기보다는 기하학적 불연속부 및 응력 집중부와 같은 민감 영역에 국부적으로 집중됨을 확인하였다.

종합하면, 본 연구에서 제안한 하이브리드 PINN 모델은 제한된 데이터와 선형 탄성 기반의 물리 제약만으로도 복잡한 3차원 구조물의 전역 거동을 물리적 정합성을 유지한 형태로 예측할 수 있음을 보였다. 특히 미학습 하중 조건에서의 예측 가능성을 확인함으로써, 반복 해석이 요구되는 설계 탐색 및 신속 평가 문제에서 물리 기반 대리 모델로의 적용 잠재성을 제시하였다.

향후 연구에서는 본 연구의 선형 기반 프레임워크를 확장하여, 소성 및 손상 역학을 포함하는 비선형 구성 방정식을 PINN 손실 함수에 직접 도입할 계획이다. 이를 통해 항복 이후 거동, 균열 진전, 과단 임계점 등 극한 하중 조건에서의 구조 응답 예측 정확도를 추가적으로 향상시킬 수 있을 것으로 기대된다.

후 기

이 연구는 교육부와 부산광역시의 재원으로 지원을 받아 수행된 부산형 지역혁신중심 대학지원과제(RISE)의 연구결과입니다 (2025-RISE02-004-11930001-02). 또한, 본 연구의 컴퓨터 시뮬레이션은 한국과학기술정보연구원(KISTI)의 슈퍼컴퓨팅 자원을 사용하여 수행되었습니다.

References

[1] Raissi, M., Perdikaris, P., Karniadakis, G. E., 2019,

- Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations, *J. Comput. Phys.*, 378 686-707, <https://doi.org/10.1016/j.jcp.2018.10.045>.
- [2] Lu, L., Meng, X., Mao, Z., Karniadakis, G. E., 2021, DeepXDE: A Deep Learning Library for Solving Differential Equations, *SIAM Rev.*, 63:1 208-228, <https://doi.org/10.1137/19M1274067>.
- [3] Han, Z., Ou, J., Koyamada, K., 2024, A Physics-informed neural network-based Surrogate Model for Analyzing Elasticity Problems in Plates with Holes, *J. Adv. Simul. Sci. Eng.*, 11:1 21-31, <https://doi.org/10.15748/jasse.11.21>.
- [4] Wang, L., Liu, G., Wang, G., Zhang, K., 2024, M-PINN: A Mesh-Based Physics-Informed Neural Network for Linear Elastic Problems in Solid Mechanics, *Int. J. Numer. Meth. Eng.*, 125:9 e7444, <https://doi.org/10.1002/nme.7444>.
- [5] Lee, H. J., Jung, W. T., Jung, J. H., 2024, Comparison of 2D Flow Analysis between PINN and Commercial Software, *J. Comput. Fluids Eng.*, 29:4 217-232, <https://doi.org/10.6112/ksce.2024.29.4.217>.
- [6] Panagiotopoulou, V., Vlachas, K., Chatzi, E., Giglio, M., Sbarufatti, C., 2024, Physics-Informed Surrogate Modeling for a Damaged Rotating Shaft, *Proc. 11th Eur. Workshop Struct. Health Monit. (EWSHM 2024)*, <https://doi.org/10.58286/29689>.
- [7] Bai, J., Jeong, H., Batuwatta-Gamage, C. P., Xiao, S., Wang, Q., Rathnayaka, C. M., Alzubaidi, L., Gu, Y., 2023, An Introduction to Programming Physics-Informed Neural Network-Based Computational Solid Mechanics, *Int. J. Comput. Methods*, 20:10 2350013, <https://doi.org/10.1142/S0219876223500135>.
- [8] Bhatnagar, S., Comerford, A., Banaeizadeh, A., 2024, Physics-Informed Neural Networks for Modeling of 3D Flow Thermal Problems With Sparse Domain Data, *J. Mach. Learn. Model. Comput.*, 5:1 39-67, <https://doi.org/10.1615/JMachLearnModelComput.2024051540>.
- [9] Park, S. S., Park, J. R., Park, J. S., 2025, Estimation of Displacements of Retaining Wall Based on Physics-informed Neural Networks, *J. KIECS*, 20:1 113-122, <https://doi.org/10.13067/JKIECS.2025.20.1.113>.
- [10] Gopinath, V., Kag, V., 2024, Physics-Informed Neural Networks for Modeling Dynamic Linear Elasticity, *SSRN*, <https://doi.org/10.2139/ssrn.4841930>.
- [11] Bazmara, M., Silani, M., Mianroodi, M., Sheibani, M., 2023, Physics-Informed Neural Networks for Nonlinear Bending of 3D Functionally Graded Beam, *Structures*, 49 152-162, <https://doi.org/10.1016/j.istruc.2023.01.115>.
- [12] Moon, H., Lee, S., Demeke, W., Ryu, B., Ryu, S., 2025, Physics-Informed Neural Operators for Generalizable and Label-Free Inference of Temperature-Dependent Thermoelectric Properties, *npj Comput. Mater.*, 11 272, <https://doi.org/10.1038/s41524-025-01769-1>.
- [13] Zhang, E., Yin, M., Karniadakis, G. E., 2020, Physics-Informed Neural Networks for Nonhomogeneous Material Identification in Elasticity Imaging, *arXiv preprint*, <https://doi.org/10.48550/arXiv.2009.04525>.
- [14] Haghghat, E., Raissi, M., Moure, A., Gomez, H., Juanes, R., 2021, A physics-informed deep learning framework for inversion and surrogate modeling in solid mechanics, *Comput. Methods Appl. Mech. Eng.*, 379 113741, <https://doi.org/10.1016/j.cma.2021.113741>.



Dajeong Choi

Undergraduate student in the Department of Optics and Mechatronics Engineering, Pusan National University. Her research interests include physics-informed neural networks, computational mechanics, and advanced microfabrication and 3D fabrication technologies.

E-mail: dajeongchoe8@gmail.com



Jinwook Park

Undergraduate student in the Department of Optics and Mechatronics Engineering, Pusan National University. His research interests include computational mechanics, the application of machine learning in mechanical engineering, and laser material processing.

E-mail: pjo4007@naver.com



Bosung Shin

Professor in the Department of Optics and Mechatronics Engineering, Pusan National University. His research interests include biodegradable materials, microbial decomposition technologies, computational modeling, molecular dynamics, machine learning, and sustainable innovations in nanotechnology.

E-mail: bosung@pusan.ac.kr