

유연 로봇의 디지털 트윈을 위한 머신러닝 기반 Softness 최적화 기초 연구

A Preliminary Study on Softness Optimization Using Machine Learning for the Digital Twin of Soft Robots

권 태 준¹, 남 세 광^{1*}

(Taejun Kwon¹ and Saekwang Nam^{1,*})

¹Graduate School of Data Science, Kyungpook National University

Abstract: This study presents a machine learning-based approach for optimizing Young's modulus, a critical physical parameter of soft robots. Instead of directly utilizing conventional material property data, the method predicts Young's modulus based on positional coordinate data measured from key points on the deformed soft robot. The research consists of simulation and experimental phases. In the simulation phase, the convergence of the Young's modulus estimation framework is first validated through gradient descent optimization. Subsequently, random forest and neural network models are trained using coordinate data collected over a Young's modulus range of 10^2 – 10^{10} Pa. The random forest model exhibits the lowest RMSE for predicting specific Young's modulus values (10^6 and 10^8 Pa), demonstrating optimal performance. In the experimental phase, deformation data from a TPU-based 3D-printed soft robot are applied to the optimized random forest model to predict Young's modulus in real-world conditions. The proposed method provides realistic predictions compared to publicly available modulus values. These findings confirm that simulation-trained machine learning models can be effectively applied to optimize soft robot design and control, enhancing the reliability of digital twins and soft robot engineering.

Keywords: young's modulus, nvidia isaacsim, soft robot, machine learning

I. 서론

로봇 공학에서 시뮬레이션 환경은 다양한 기계학습 기법, 특히 강화학습을 적용하는 데 필수적인 요소로 자리 잡았다. 강화학습은 특정 상태에서 보상을 최대로 받기 위한 최적의 행동을 학습하는 방식으로, 최적의 행동 패턴을 찾기 위해 다양한 조건을 실험적으로 변화시키며 반복 학습이 필요하다. 그러나, 현실에서 물리적 실험을 반복 수행하는 것은 시간적, 비용적, 안전성 측면에서 큰 제약이 따르며, 로봇이 실제 환경에서 실패할 경우 하드웨어 손상 등의 위험이 존재한다[1]. 이를 해결하기 위해, 가상 시뮬레이터가 강화학습 및 로봇 공학에서 중요한 역할을 하고 있다. 시뮬레이터는 실제 환경과 유사한 물리적 조건을 반영하여 로봇의 움직임을 예측할 수 있도록 하며, 대규모 반복 실험을 수행하는 데 최적화된 플랫폼을 제공한다. 예를 들어, Rudin et al. (2021)은 가상 시뮬레이션을 활용하여 로봇 개가 다양한 지형에서 걷도록 학습하는 실험을 진행하였으며, 현실 실험에 비해 훨씬 적은 비용과 시간을 투자하면서도 성공적인 보행 정책을 학습할 수 있음을 입증하였다[2]. 강체 로봇의 경우, 비교적 단순한 물리적 특성을 가지기 때문에 시뮬레이션 환경에서의 모델링이 상대적으로 용이하다. 그러나, 소프트 로봇은 높은 유연

성과 환경 적응성 덕분에 강체 로봇보다 다양한 이점을 제공함에도 불구하고, 시뮬레이션 환경에서 다루기가 훨씬 까다롭다[3]. 소프트 로봇의 변형 거동은 비선형성, 이력 효과, 탄성 등의 복잡한 물리적 특성을 포함하기 때문에, 기존 강체 로봇을 위한 가상 시뮬레이터로는 정확한 재현이 어렵다[4]. 따라서, 소프트 로봇의 모델링과 시뮬레이션 최적화는 현재 로봇 공학 분야에서 해결해야 할 중요한 과제 중 하나로 꼽힌다[5].

소프트 로봇의 시뮬레이션에서 가장 중요한 요소 중 하나는 재료의 물리적 특성을 정확하게 반영하는 것이다. 특히, 영률(Young's modulus)은 소프트 로봇의 변형 거동을 표현하는 가장 기본적인 물리적 특성으로, 이를 가상환경에서 정확하게 설정하는 것이 시뮬레이션 결과의 신뢰도를 높이는 첫 걸음이다. 그러나, 많은 연구자들은 주로 재료의 사양 정보나 시편 테스트 결과로부터 영률 정보를 가져오는 방식이 일반적이었다[6,7]. 이와 같은 접근 방식은 재료의 밀도 차이, 재료 내부 구조 형상을 고려하지 않으므로, 실제 3D 프린터 등으로 제작된 구조체의 가상화에 있어, 위에서 언급한 형태의 영률을 그대로 적용하면 변형 거동 측면에서 큰 오차를 발생시킬 개연성이 높다. 이는 가상환경에서의 시뮬레이션 결과와 실제 환경에서의 동작 결과 간에 신뢰도와 일치도를 낮추

* Corresponding Author

Manuscript received February 10, 2025; revised March 3, 2025; accepted April 1, 2025

권태준: 경북대학교 데이터사이언스대학원 대학원생(ktjmmamoo0629@knu.ac.kr, ORCID[®] 0009-0008-9387-3017)

남세광: 경북대학교 데이터사이언스대학원 조교수(s.nam@knu.ac.kr, ORCID[®] 0000-0002-7713-8505)

※ This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (Ministry of Science and ICT) (No. RS-2023-00242528, No. RS-2024-00436182) and by the IITP (Institute for Information & Communications Technology Planning & Evaluation)-ITRC (Information Technology Research Center) grant funded by the Korea government (MSIT) (No. IITP-2025-RS-2024-00437756).

는 주요 원인 중 하나로 작용할 수 있다. 따라서, 보다 현실적인 물리적 특성 반영을 위해 영률을 추정하는 새로운 접근 방식이 요구된다.

본 연구에서는 현실과 가상 환경의 변형 거동 차이를 줄이기 위하여, 소프트 로봇의 밀도 차이와 재료 내부 구조 형상을 고려한 영률을 추정하는 새로운 접근 방식을 제안한다. 기존 연구와 달리, 본 연구는 재료의 사양 정보나 공개된 물성 데이터를 직접 활용하는 대신, 머신러닝 기반 영률 추정 프레임워크를 활용하여 입력 힘에 따른 실제 소프트 로봇의 변형 정도를 활용하여 영률을 예측하는 방식을 제안한다.

본 연구는 (1) 소프트 로보틱스 분야의 대표적 가상환경 소프트웨어인 NVIDIA Isaac Sim을 활용하여 다양한 힘 조건에 의하여 변형되는 소프트 로봇의 좌표 값과 해당 영률을 머신러닝 모델에 학습시킨 영률 추정 프레임워크를 검증하는 1단계 과정과, (2) 가상환경에서 제작된 로봇과 같은 크기를 가진 실제 모형의 영률을 상기 프레임워크를 이용하여 추정하는 2단계 추정 과정으로 구성된다. 이러한 접근 방식은 소프트 로봇의 내부 구조 형상, 밀도 차이와 같이 겉으로는 알기 힘든 재료적 특성을 보다 현실적으로 반영할 수 있으며, 디지털 트윈의 관점에서 기존의 물성 데이터 기반 영률 추정 방식보다 더욱 효과적으로 활용될 수 있다. 궁극적으로, 본 연구는 시뮬레이션과 현실 간의 차이를 줄이고, 소프트 로봇의 설계 및 제어를 더욱 정밀하게 수행할 수 있도록 기여하는 것을 목표로 한다.

II. 연구 방법론

본 연구에서는 소프트 로봇에서 중요한 물리적 매개 변수인 영률을 예측하기 위해 시뮬레이션을 활용한 영률 예측 모델을 실험에 적용하였다. 연구 과정은 크게 두 단계로 구성된다. 첫 번째 단계에서는 시뮬레이션을 활용하여 영률 추정 프레임워크를 구축하고, 두 번째 단계에서는 실제 3D 프린트된 소프트 로봇을 대상으로 영률을 추정하였다.

각 단계에서는 소프트 로봇의 특정 위치에 가해진 입력 힘에 의한 준정적 변형 데이터를 수집하고, 변형에 따른 영률 예측 머신러닝 모델을 구축 및 적용하였다. 이를 통해, 시뮬레이션 환경에서 학습된 영률 추정 모델이 실제 실험 환경에서도 적용될 수 있는지를 검증하고, 로봇에 사용된 소재의 공개된 영률 값과 비교 분석하였다.

1. 시뮬레이션 활용 영률 추정 프레임워크

1.1. 시뮬레이션 환경 설정

첫 번째 단계에서는 유연 로봇을 위한 대표적인 가상 환경 플랫폼인 NVIDIA Isaac Sim을 활용하여 가상의 소프트 로봇을 구성하고, 특정 영률값을 설정하였다. 이후, 로봇에 가해진 입력 힘에 의해 변형된 구조물의 좌표 데이터를 수집하고, 이를 기반으로 대표적인 최적화 알고리즘인 경사하강법을 적용하여, 변위에 따른 영률 추정 프레임워크의 적용 가능성을 가상환경에서 검증하였다.

이후, 시뮬레이션 기반으로 학습된 영률 추정 머신러닝 모델을 (랜덤 포레스트, 뉴럴 네트워크) 실제 실험 환경에 적용하여, 3D 프린트된 소프트 로봇의 변형된 좌표 데이터에 따라 달라지는 영률값을 도출하고, 이를 로봇에 사용된 소재의

공개된 영률 값과 비교 분석하였다[8].

먼저, 시뮬레이션 환경에서는 가로, 세로, 두께가 각각 $5\text{ cm} \times 15\text{ cm} \times 1\text{ cm}$ 의 직육면체 모델을 생성하였다. 그림 1은 가상환경에서 만들어진 소프트 로봇의 초기 상태를 측면에서 바라본 모습 나타내며, 구조물의 아랫면은 바닥에 완벽히 고정된 상태이다. 입력 힘에 따른 준정적 변형을 측정하기 위하여 로봇에서 주요 좌표를 그림 1과 같이 측면의 상단 좌측, 상단 우측, 그리고 중앙으로 설정하였다. 이러한 주요 좌표는 실험에서 변형 거동을 관찰하고 정량적으로 분석하기 위한 기준점으로 사용된다.

소프트 로봇에 가해지는 입력 힘의 종류와 위치는 하나이다. 입력 힘은 바닥으로부터 13 cm 떨어진 지점에서 x축 방향으로 천천히 밀어 로봇의 반작용 힘이 0.7 N 이 되는 시점에서 상기 정의된 좌표들의 변위를 측정하였다. 그림 2는 변형된 로봇의 상태를 나타내며, 외력에 의해 변화된 상단 좌측, 상단 우측, 중앙의 좌표들을 시각적으로 확인할 수 있다. 이 좌표 데이터는 영률 최적화 프레임워크에서 중요한 입력 값으로 사용된다. 구체적으로, 본 프레임워크는 특정 영률에 따라 변형되는 로봇의 3개 좌표(x, y, z)를 $10^2 - 10^{10}\text{ Pa}$ 범위 안에서 순차적으로 추출하여, 영률에 따른 변형 거동 좌표 빅 데이터를 수집하였다. 시뮬레이션 환경에서는 3D 좌표 데이터를 얻을 수 있었지만, 실제 실험에서 카메라를 이용한 데이터 수집 과정에서 2D 좌표만 사용하였기 때문에, 현실 데이터와의 일관성을 유지하기 위해 x, z 좌표만을 사용하였다.




그림 1. 주요 좌표점이 표시된 소프트 로봇의 초기 상태.

Fig. 1. Initial configuration of the soft robot with key points marked for optimization.




그림 2. x축 방향으로 힘을 가한 후 변형된 소프트 로봇의 상태.

Fig. 2. Deformed state of the soft robot after applying force in x-axis.

1.2. 영률 추정 프레임워크의 수렴성 검증

소프트 로봇의 영률을 가상환경에서 정확하게 추정할 수 있는지를 검증하기 위해, 우리는 영률 추정 프레임워크를 구현하였다. 구체적으로, 가상환경 내에서 소프트 로봇에 특정 영률을 부여하여 유연성을 정의한 후, 해당 프레임워크가 설정된 영률 값을 낮은 오차로 추정할 수 있는지를 평가하였다.

위치 정보를 기반으로 본 프레임워크의 수렴성 검증을 위하여, 경사 하강법(GD, Gradient Descent)을 이용하였다. 경사 하강법 기반 직접 최적화의 목적함수는 찾고 싶은 영률을 가진 소프트 로봇의 변형(타겟 좌표, C_i^{Target})과 시뮬레이션 상의 로봇 변형(시뮬레이션 좌표, C_i^{Sim})의 차이를 최소화하도록 설계했으며, 이는 아래 식 (1)과 같다.

$$MSE_{GD} = \frac{1}{3} \sum_{i=1}^3 (C_i^{Sim}|_E - C_i^{Target})^2 \quad (1)$$

본 연구의 목적함수(식 (1))는 시뮬레이션 좌표와 타겟 좌표 간의 평균 제곱 오차(MSE_{GD}, Mean Squared Error for Gradient Descent)를 계산하고, 이를 최소화하는 조건에서 타겟 좌표를 재현하는 영률 값을 찾는 것을 목표로 한다. 식 (1)에서 E는 추정하려는 영률 값을 의미하며, C_i^{Sim} 는 시뮬레이션 환경에서 측정된 i번째 좌표, C_i^{Target} 는 타겟 영률을 갖는 소프트 로봇의 i번째 좌표를 나타낸다. 좌표는 로봇 상단의 좌측, 우측, 중앙 등 총 세 지점에서 측정되었으며(그림 1 참조), 이는 직사각형 형태의 소프트 로봇의 변형 양상을 설명하기에 충분하다. 식 (1)의 목적함수를 최소화하는 과정은 시뮬레이션 좌표(C_i^{Sim})와 타겟 좌표(C_i^{Target}) 간의 비교를 통해 타겟 로봇의 영률 값을 추정하는 절차에 해당한다. 경사하강법(GD)의 성능은 MSE_{GD} 기반의 목적함수를 통해 평가되었으며, 해당 오차를 최소화하는 영률 값을 찾는 것이 최적화 과정의 핵심 목표이다. 제한한 프레임워크의 성능은 III.1.절에서 상세히 기술한다.

1.3. 머신러닝 모델을 통한 영률 예측

영률 추정 프레임워크를 통해 최적화 알고리즘의 유효성을 검증한 후, 우리는 소프트 로봇의 변형된 좌표 (C_i^{Sim})로부터 영률 값을 직접 예측할 수 있는 머신러닝 기반 모델($\hat{E} = f(C_i^{Sim})$)을 구성하였다. 이를 위해 랜덤 포레스트(Random Forest)와 뉴럴 네트워크(Neural Network)의 두 가지 모델을 설계하고, 그 성능을 비교 분석하였다. 즉, 예측 모델은 함수 f 로 정의되며, 다음과 같은 수식으로 표현된다.

$$\hat{E} = f(\{C_i^{Sim}|i = \text{Center, Top Right, Top Left}\}) \quad (2)$$

랜덤 포레스트와 뉴럴 네트워크를 활용한 예측 모델의 학습을 위해, 소프트 로봇 시뮬레이터를 사용하여 $10^2 - 10^{10}$ Pa 범위의 다양한 영률 (E) 값에 따른 변형된 좌표 C_i^{Sim} 를 수집하였다. 이때 생성된 (C_i^{Sim} , E) 쌍의 데이터셋은 각 머신러닝 모델의 학습에 사용되었으며, 데이터셋은 총 150개의 데이터 포인트로 구성되었다.

두 모델은 학습 방식에서 차이를 보인다. 랜덤 포레스트는 여러 개의 의사결정 트리를 기반으로 한 앙상블 학습 기법을 사용하여, 개별 트리의 예측값을 평균함으로써 최종 예측을 수행한다. 반면, 뉴럴 네트워크는 Adam최적화 알고리즘을 통해 학습되었다. Adam은 경사하강법(GD)의 변형으로, 모멘텀

과 적응적 학습률을 결합하여 보다 효율적인 학습이 가능하다.

두 모델의 성능 평가는 실제 영률 값 E_i 와 예측된 영률 값 \hat{E}_i 간의 평균 제곱근 오차(root mean squared error, RMSE_{NN,RF})를 목적함수로 설정하여 수행되었으며, 이는 다음과 같은 수식으로 정의된다.

$$RMSE_{NN,RF} = \sqrt{\sum_{i=1}^n \frac{(E_i - \hat{E}_i)^2}{n}} \quad (3)$$

1.4. 가상과 실제환경에서 머신러닝 모델의 검증

앞서 구현된 두 가지 머신러닝 모델은 가상환경뿐만 아니라 실제 환경에서도 그 유효성을 검증하였다. 먼저, 가상환경에서의 검증은 두 가지 영률 조건 하에서 수행되었다. 본 연구에서는 영률이 각각 10^6 Pa과 10^8 Pa에 해당하는 소프트 로봇의 좌표 데이터를 타겟 좌표로 설정하고, 다양한 영률 조건에서 변형된 로봇의 좌표와의 비교를 통해 목적 함수가 충분히 수렴했을 때의 추정 영률이 실제 타겟 값에 근접하는지를 확인하였다. 즉, 특정 영률값에서 생성된 시뮬레이션 좌표를 학습된 머신러닝 모델에 입력하였을 때, 해당 모델이 영률을 얼마나 정확하게 예측할 수 있는지를 평가하였다.

마지막으로, 가상환경에서 검증된 머신러닝 모델을 현실 환경에 적용하여, 3D 프린터로 제작된 소프트 로봇의 영률을 예측하였다. 예측된 영률은 해당 소재의 실제 영률값에 대한 기존 문헌의 연구 결과와 비교되었으며, 이를 통해 추정값과 실제값 간의 차이를 분석하고 논의하였다.

2. 실제 소프트 로봇의 영률 예측 및 검증

상기 두 가지 머신러닝 모델은 시뮬레이션 상의 로봇모형과 같은 크기로 제작된 실제 로봇의 영률 예측에 효과적으로 사용될 수 있다. 이를 위해, 우리는 열가소성 폴리우레탄(TPU, Thermoplastic Polyurethane) 필라멘트를 사용하는 3D 프린터를 활용하여 크기 $5 \text{ cm} \times 15 \text{ cm} \times 1 \text{ cm}$ 의 직사각형 소프트 로봇을 제작하였다. 그림 3은 제작된 소프트 로봇의 (a) 정면, (b) 측면, (c) 상단에서 본 모습을 보여준다. TPU는 유연 물체의 3D 프린팅에 널리 사용되는 소재로, 우수한 탄성과 내구성을 제공한다[9]. 3D 프린팅 과정에서는 레이어 높이 0.2mm, 벽 두께 2, 내부 채움 밀도 75%, 내부 채움 패턴은 그리드(Grid) 패턴을 적용하여 구조물을 제작하였다. 제작된 로봇의 하단은 광학 브레드보드 테이블(optical table)에 단단히 고정하였으며, 상단부에는 Dobot Robotics사의 MG 400 로봇암에 힘 측정 센서(force sensor)와 인텐더(intender)를 장착하여 x축 방향으로 0.7 N의 외력을 가하였다(그림 4(b)). 이러한 실제 실험 조건은 가상 환경과 동일하게 설정되었으며, 변형된 구조의 데이터를 수집하는 과정에서 일관성을 유지하는 데 중점을 두었다.

실험에서 측정된 세 개의 좌표 데이터는 촬영된 이미지에 나타난 좌표점(그림 4의 빨간색 점)을 OpenCV 라이브러리를 활용하여 추출하였다. 외력이 가해져 변형된 소프트 로봇에서 상단 좌측, 상단 우측, 중앙의 총 세 지점의 이동 위치를 기록하였다. 로봇의 실제 크기를 기준으로 픽셀 단위 크기와 물리적 크기 간의 비율을 계산하여, 이미지 상의 픽셀 좌표를 물리적 좌표계로 변환하였다. 이를 통해 원점을 기준으로 한 2차원 물리적 좌표를 도출할 수 있었다.




그림 3. 3D 프린팅된 TPU 소프트 로봇: (a) 정면 뷰, (b) 측면 뷰, (c) 상단 뷰. 제작 시 레이어 높이는 0.2mm, 내부 채움 밀도는 75%, 채움 패턴은 Grid로 설정하였음.

Fig. 3. A 3D-printed soft robot made of TPU: (a) Front view, (b) Side view, and (c) Top view. The printing parameters were set to a layer height of 0.2 mm, an infill density of 75 %, and a grid infill pattern.




그림 4. 실제 환경 및 외력 적용에 따른 소프트 로봇의 변형: (a) 초기 상태에서 주요 실험 장비(Force sensor, Indenter)와 실험 환경 (Optical table)의 구성. (b) MG 400 로봇을 이용하여 x축 방향으로 외력을 가한 후 변형된 소프트 로봇의 모습.

Fig. 4. Deformation under real-world conditions and external force application: (a) Initial setup showing the key experimental components, including the force sensor, indenter, and the optical table. (b) Deformed state of the soft robot after applying external force along the x-axis using the MG 400 robot.

실험에서는 카메라 기반 2D 이미지로부터 데이터를 수집하였으며, 2D 좌표(x, y)만을 활용하였다. 이에 따라, 현실 로봇에서 수집된 2D 좌표와 가상 로봇에서 얻은 3D 좌표 간의 비교를 위해 가상환경의 평면 좌표를 평면 상으로 투영하여 현실환경의 2D 좌표계에 맞추어 분석을 수행하였다.

수집된 실제 데이터는 시뮬레이션을 통해 학습된 좌표 및 영률 데이터와 함께 머신러닝 모델의 학습에 사용되었으며, 이를 통해 소프트 로봇의 영률을 예측할 수 있었다. 최종적으로, 머신러닝 모델이 예측한 영률값과 실제 실험 데이터를 기반으로 도출된 변형 좌표 간의 차이를 비교함으로써, 가상

환경에서 학습된 모델이 현실 환경에서도 높은 정확도로 적용 가능한지를 평가하였다.

III. 실험 결과 및 고찰

본 연구에서는 가상환경에서 학습된 머신러닝 모델을 활용하여 현실환경에서 3D 프린팅된 소프트 로봇의 영률 예측을 시도하였으며, 경사 하강법을 통한 영률 추정 프레임워크의 수렴성 검증과 랜덤 포레스트, 뉴럴 네트워크의 성능을 비교 분석하였다. 머신러닝 모델(랜덤 포레스트, 뉴럴 네트워크)의 검증은 가상환경에서 영률값이 각각 10^6 Pa 과 10^8 Pa 일 때 소프트 로봇의 좌표값을 모델에 입력시켰을 때, 출력되는 예측 영률 값이 각각 10^6 Pa 과 10^8 Pa 에 가까운지 검증하였으며, 객관적인 성능 비교를 통해 가장 우수한 예측 성능을 보인 모델을 사용하여 현실 환경의 소프트 로봇의 영률 예측을 수행 및 평가하였다.

1. 가상환경에서의 검증 결과

1.1. 경사하강법(GD)을 통한 영률 추정 프레임워크 수렴성 검증

먼저, 소프트 로봇의 영률을 가상환경에서 정확하게 추정할 수 있는지를 검증하기 위해, 경사 하강법(GD)을 사용하여 영률 추정 프레임워크의 수렴성을 확인하였다. 본 프레임워크는 특정 영률 값에서 생성된 타겟 좌표와 시뮬레이션 좌표 간의 평균 제곱 오차(MSE)를 최소화하는 방향으로 영률 값을 최적화한다. 이를 통해 시뮬레이션과 타겟 로봇 간의 거동 차이를 최소화할 수 있다. 구체적으로 경사하강법은 좌표 오차 기반의 MSE(mm)를 평가 지표로 사용한다. 그림 5는 서로 다른 학습률에 따른 GD의 수렴 속도를 시각화하였다.

그림 5에서 볼 수 있듯이, 학습률에 따른 경사하강법의 수렴 성능에 큰 차이가 나타났다. 학습률이 0.1일 경우 초기에 매우 빠른 손실 감소를 보이며, 약 15회 반복 이후에는 거의 0에 가까운 손실값으로 효과적으로 수렴하였다. 반면, 학습률이 0.01인 경우에는 상대적으로 느린 감소 속도를 보이며 30회 반복 후에도 약 30 정도의 비교적 높은 손실값에 머물러, 완전한 수렴에 실패하였다. 학습률이 0.001일 경우에는 전체 학습 과정에서 손실값이 50 근처에서 거의 감소하지 않아, 효과적인 학습이 이루어지지 않았음을 보여준다. 결론적




그림 5. GD 학습률에 따른 수렴 속도 비교.
Fig. 5. Convergence rate comparison of GD with different learning rate.

으로, 본 모델에서는 0.1의 비교적 높은 학습률이 가장 효과적임을 보여준다. 높은 학습률에도 불구하고 안정적인면서도 빠른 수렴을 달성했는데, 이는 본 연구에서 다루는 영률 변화 범위가 10^6 Pa 이상의 매우 큰 값을 가지기 때문으로 해석된다. 이러한 큰 스케일의 데이터에서는 작은 학습률(0.01, 0.001)을 사용할 경우 기울기 업데이트가 미미하여 제한된 시간내에 유의미한 학습 결과를 얻기 어렵다. 반면, 0.1의 학습률은 영률에 관한 큰 스케일의 기울기 값을 적절히 보정하여 효율적인 파라미터 업데이트를 가능하게 하였으며, 이는 그래프에서 보이는 빠른 수렴 결과로 입증된다. 경사 하강법을 통한 영률 최적화 프레임워크의 수렴성 검증 결과, MSE 값은 학습률 0.1, 30번 반복 기준 26.125 mm로 측정되었다.

1.2. 머신러닝 모델을 통한 영률 예측

경사 하강법을 통해 영률 최적화 프레임워크의 수렴성을 검증한 후, 좌표 데이터를 기반으로 특정 영률값(10^6 Pa, 10^8 Pa)을 직접 예측할 수 있는 랜덤 포레스트와 뉴럴 네트워크 머신러닝 모델을 구축하고 비교 분석하였다. 데이터셋은 총 150개의 데이터 포인트로 구성되었으며, 이는 가상환경 로봇의 3개 좌표(x, y, z)를 $10^2 - 10^{10}$ Pa 범위 안에서 순차적으로 추출하여 수집하였다. 현실 데이터와의 일관성을 위해 평면 좌표만을 사용하였으며, 각 데이터 포인트는 3점의 x, z 좌표(총 6개의 변수)와 영률 값으로 구성된다. 데이터 전처리 과정에서는 MinMaxScaler를 사용하여 좌표값을 -1에서 1 범위로 정규화한 후 전체 데이터셋을 8:2 비율로 훈련용과 테스트용으로 분할하였다(랜덤 포레스트와 뉴럴 네트워크 기준). 아래 표 1은 랜덤 포레스트와 뉴럴 네트워크 모델의 RMSE를 비교한 결과이다. 랜덤 포레스트는 가장 낮은 RMSE 값($2,032 \times 10^4$ Pa)을 보였으며, 데이터셋 크기가 제한적인 상황에서도 높은 예측 정확도를 보였다. 이는 랜덤 포레스트가 비교적 단순한 데이터 구조에서도 효과적으로 동작할 수 있음을 시사한다. 반면, 뉴럴 네트워크는 상대적으로 높은 RMSE 값($534,131 \times 10^4$ Pa)을 기록하며, 본 연구에서 사용된 소규모 데이터셋에서는 랜덤 포레스트보다 다소 낮은 성능을 보였다. 이는 뉴럴 네트워크가 일반적으로 대규모 데이터

표 1. 머신러닝 모델별 RMSE 비교.

Table 1. Comparison of RMSE among ML models.

	RMSE
Random Forest	$2,032 \times 10^4$ Pa
Neural Network	$534,131 \times 10^4$ Pa

표 2. 머신러닝 모델별 영률 예측 및 오차율 비교

Table 2. Comparison of young's modulus prediction and error rate by machine learning models.

	Target	Predicted	Error Rate
	Young's Modulus (Pa)	Young's Modulus (Pa)	(%)
GD	10^6	1,000,346	3.46
	10^8	93,200,456	6.80
Random Forest	10^6	985,000	1.50
	10^8	104,400,440	4.40
Neural Network	10^6	1,366,651	36.67
	10^8	113,418,288	13.42

셋에서 최적의 성능을 발휘하는 모델이기 때문이며, 향후 데이터셋을 확장하여 추가 실험이 필요함을 시사한다.

여기서 주목할 점은 경사하강법은 머신러닝 모델이 아닌 영률 최적화 프레임워크의 수렴성을 검증하기 위해 사용된 접근법이라는 것이다. GD는 특정 영률값(10^6 , 10^8 Pa)에서 생성된 시뮬레이션 좌표 데이터(C_i^{Sim})를 타겟으로 설정하고, 임의의 영률값에서 시작하여 해당 타겟 좌표에 가까워지도록 영률을 조절하는 과정을 통해, 결과적으로 원래의 영률값에 수렴하는지를 검증하였다. 표 2에 제시된 경사하강법의 결과는 학습률 0.1로 30번의 반복을 통해 얻어낸 최종 영률값이다. 모델 간 공정한 비교를 위해 오차율(%)을 사용하여 각 접근법의 영률 예측 성능을 객관적으로 평가하였다. 오차율은 목표 영률과 예측 영률 간의 차이를 목표 영률로 나누어 백분율로 표현한 값으로, 모든 접근법에 동일하게 적용할 수 있는 직관적인 지표이다.

랜덤 포레스트는 비교적 낮은 오차율을 기록하며, 작은 데이터셋에서도 안정적인 성능을 보였음을 확인할 수 있었다. 반면, 뉴럴 네트워크의 경우 상대적으로 높은 오차율을 보였으며, 특히 10^6 Pa의 데이터에서는 36.67%의 큰 편차가 발생하였다. 뉴럴 네트워크가 예상보다 낮은 성능을 보인 주요 원인은 데이터셋의 크기에 있다. 본 연구에서 사용된 150개의 데이터셋은 뉴럴 네트워크를 충분히 학습시키기에는 부족한 양이다. 반면, 랜덤 포레스트는 여러 개의 의사결정 트리를 앙상블하여 예측하는 방식으로, 비교적 적은 데이터에서도 효과적으로 학습이 가능하다는 장점이 있다. 또한 Grinsztajn et al. (2022)의 연구에 따르면, 테이블 형태의 데이터에서는 트리 기반 모델이 신경망보다 더 나은 성능을 보이는 경우가 많다[10]. 종합적인 비교 결과를 통해, 본 연구에서는 랜덤 포레스트가 소프트 로봇의 영률 예측에 가장 적합한 모델임을 확인하였으며, 이 모델을 선택하여 실제 환경에서의 영률 추정에 적용하였다.

2. 실제 환경에서 소프트 로봇의 영률 예측

앞서 시뮬레이션 기반으로 학습된 머신러닝 모델 중, 가장 낮은 RMSE를 기록한 랜덤 포레스트 모델을 실제 실험 데이터에 적용하여 영률값을 예측하였다. 열가소성 폴리우레탄 소재(판매사 제공 영률: $67,000,000$ Pa)로 만든 소프트 로봇의 힘 인가에 의한 변형 좌표를 랜덤 포레스트 모델의 입력값으로 사용하였으며, 본 모델의 결과인 영률 예측치는 표 3에 정리되어 있다.

랜덤 포레스트 모델을 사용하여 예측된 소프트 로봇의 영률은 115 MPa로써, 로봇에 사용된 소재(TPU)의 판매사 제공 값 (67 M Pa)과 비교했을 때, 상당한 차이를 보였다. 이러한 예측값의 차이는 3D 프린팅 공정에 필요한 매개변수의 영향으로 보여진다. 구체적으로, Bárbara et al. (2022)는 TPU 98A를 사용하여 레이어 높이 0.2mm, 내부 채움 밀도 75% 조건에서 영률이 약 100 MPa에 도달함을 확인하였으며, 이는 프린팅 매개변수가 재료의 영률에 지대한 영향을 미친다는 것을 시사한다[11,12]. 본 실험에 사용된 소프트 로봇의 3D 프린팅의 매개변수 또한 상기 조건과 같으므로, 학습된 랜덤 포레스트 모델을 활용한 소프트 로봇의 영률 예측은 높은 신뢰도를 보여준다.

표 3. 실제 환경의 소프트 로봇의 영률 예측.

Table 3. Young's modulus prediction of the soft robot in real-world environment.

	Predicted Young's Modulus (Pa)
Random Forest	115,823,134

IV. 결론 및 향후 연구

본 연구는 머신러닝 기법과 가상환경 시뮬레이터를 활용하여 소프트 로봇에서 중요한 물리적 매개변수인 영률을 예측할 수 있음을 보여주었다. 특히, 재료의 사양 정보나 공개된 물성 데이터를 직접 활용하는 대신, 머신러닝 기반 영률 최적화 프레임워크를 가상공간에서 활용하여 구축된 영률 예측 모델을 실제 환경에서 적용해 봄으로써, 실제 3D 프린트된 소프트 로봇의 변형 거동과 가상의 변형 거동을 영률을 통하여 맞추어줌으로써, 디지털 트윈 구축법에 대한 방법론을 제시하였다.

본 연구에서 제안한 접근법 중, 경사 하강법은 영률 최적화 프레임워크의 수렴성을 검증하는 데 효과적이었으며, 학습률 조절을 통해 안정적인 수렴성을 확인하였다. 머신러닝 모델 중에서, 랜덤 포레스트는 소규모 데이터셋에서도 높은 성능을 보이며 초기 회귀 분석 모델로서 유효성을 입증하였다. 반면, 뉴럴 네트워크는 상대적으로 높은 오차율을 보였으나, 데이터의 복잡성이 증가하거나 구조가 더 복잡해질 경우 성능이 개선될 가능성을 보여주었다. 다만, 본 연구에서는 단순한 직사각형 구조와 제한된 데이터셋을 기반으로 실험이 진행되었기 때문에, 뉴럴 네트워크의 확장 가능성을 직접적으로 검증하지는 못했다.

향후 연구에서는 데이터셋을 확장하여 더 다양한 물리적 매개변수와 복잡한 형상을 포함하는 실험을 진행할 필요가 있다. 또한, 현실 데이터가 2D 좌표로 제한된 상황을 극복하기 위해, 카메라 캘리브레이션 등을 활용하여 물리적 3D 좌표를 추출할 필요가 있다. 이를 통해 시뮬레이션 데이터와 현실 데이터 간의 차이를 최소화하고, 더 정밀한 분석 및 모델링이 가능할 것이다. 뿐만 아니라, 시뮬레이션과 현실 간의 차이를 줄이기 위한 실시간 최적화 모델의 개발과 같은 연구도 중요한 과제이다. 이러한 연구는 소프트 로봇 응용 분야에서 가상-물리 통합 최적화를 한 단계 더 발전시키고, 다양한 로봇 응용 분야에 활용 가능한 범용적인 솔루션을 제시하는 데 기여할 것으로 기대된다.

REFERENCES

- [1] H. Nguyen and H. La, "Review of deep reinforcement learning for robot manipulation," *IEEE*, pp.590–595, 2019.
- [2] N. Rudin, D. Hoeller, P. Reist, and M. Hutter, "Learning to walk in minutes using massively parallel deep reinforcement learning," *PMLR*, pp.91–100, 2022.
- [3] D. Kim, S. Kim, T. Kim, B. B. Kang, M. Lee, W. Park, S. Ku, D. Kim, J. Kwon, and H. Lee, "Review of machine learning methods in soft robotics," *Plos one, Public Library of Science San Francisco*, vol. 16, no. 2, 2021.
- [4] K. Kim, C. W. Sung, G. H. Kim, and A. Y. Hong, "Development of the gripping system for moving objects using a soft gripper,"

Institute of Control, Robotics and Systems (in Korean), pp. 522–523, 2023.

- [5] B. Frank, R. Schmedding, C. Stachniss, M. Teschner, and W. Burgard, "Learning the elasticity parameters of deformable objects with a manipulation robot," *IEEE*, pp.1877–1883, 2010.
- [6] S. Bishnoi, S. Singh, R. Ravinder, M. Bauchy, N. N. Gosvami, H. Kodamana, and N. A. Krishnan, "Predicting Young's modulus of oxide glasses with sparse datasets using machine learning," *J.Non Cryst.Solids*, 2019.
- [7] H. Khakurel, M. Taufique, A. Roy, G. Balasubramanian, G. Ouyang, J. Cui, D. D. Johnson, and R. Devanathan, "Machine learning assisted prediction of the Young's modulus of compositionally complex alloys," *Scientific reports, Nature Publishing Group* vol. 11, no. 1, pp.17149, 2021.
- [8] J. Joo, J. Ha, and J. Kang, "Prediction of ground reaction forces and joint torque through squatting motion with deep learning algorithm," *Journal of Institute of Control, Robotics and Systems (in korean)*, pp. 123–124, 2024
- [9] A. Georgopoulou, B. Vanderborcht, and F. Clemens, "Fabrication of a soft robotic gripper with integrated strain sensing elements using multi-material additive manufacturing," *Frontiers in Robotics and AI, Frontiers Media SA*, vol. 8, 2021.
- [10] L. Grinsztajn, E. Oyallon, and G. Varoquaux., "Why do tree-based models still outperform deep learning on typical tabular data?," *Advances in Neural Information Processing Systems*, vol. 35, pp. 507–520, 2022.
- [11] B. Adrover-Monserrat, J. Llumà, R. Jerez-Mesa, and J. A. Travieso-Rodriguez, "Study of the influence of the manufacturing parameters on tensile properties of thermoplastic elastomers," *Polymers, MDPI*, vol. 14, no. 3, pp.576, 2022.
- [12] D. M. Haid, O. Duncan, J. Hart, and L. Foster, "Characterisation of thermoplastic polyurethane (TPU) for additive manufacturing," *Tagungsband zum*, vol.14, pp.85–88, 2022.



권태준

2023년 경북대학교 전자공학부 졸업.
2024년~현재 경북대학교 데이터사이언스 대학원 석사과정 재학 중. 관심분야는 시뮬레이션, 머신러닝.



남세광

2011년 Kanazawa University 인간기계공학과 (학사). 2013년 University of California, San Diego 컴퓨터과학과 (석사). 2022년 University of Tuebingen 컴퓨터과학과 (박사). 2024년~현재 경북대학교 데이터사이언스대학원 조교수. 관심분야는 시뮬레이션, 최적화, 로봇.