

## 3차원 학습 데이터를 이용한 PIC 보의 강성 향상에 대한 연구

지승민\* · 함석우\* · 최진경\*\* · 전성식\*†

# Stiffness Enhancement of Piecewise Integrated Composite Beam using 3D Training Data Set

Seungmin Ji\*, Seok Woo Ham\*, Jin Kyung Choi\*\*, Seong S. Cheon\*†

**ABSTRACT:** Piecewise Integrated Composite (PIC) is a new concept to design composite structures of multiple stacking angles both for in-plane direction and through the thickness direction in order to improve stiffness and strength. In the present study, PIC beam was suggested based on 3D training data instead of 2D data, which did offer a limited behavior of beam characteristics, with enhancing the stiffness accompanied by reduced tip deformation. Generally training data were observed from the designated reference finite elements, and preliminary FE analysis was conducted with respect to regularly distributed reference elements. Also triaxiality values for each element were obtained in order to categorize the loading state, i.e. tensile, compressive or shear. The main FE analysis was conducted to predict the mechanical characteristics of the PIC beam.

**초 록:** Piecewise Integrated Composite(PIC) 보의 구간 조합 복합재 보로 구간 마다 적층 각도 및 순서를 다르게 적용하여 보의 강성과 강도를 향상시킬 수 있는 복합재료 보의 새로운 개념이다. 본 연구에서는 보의 거동을 고려하기 어려운 2차원 학습 데이터를 대신하여 3차원 학습 데이터가 적용된 머신 러닝 모델을 이용한 PIC 보가 제안되었다. 학습 데이터 및 훈련 데이터 셋(Training Data Set)은 지정된 참조 요소에서 3축 특성 값(Stress Triaxiality Factor)을 추출하여 세 가지 하중 유형(인장, 압축 그리고 전단)으로 분류되어 구성되었고, 이에 따른 하이퍼파라미터(Hyperparameter)가 제안되었다. 이를 통하여 예측된 PIC 보로 유한 요소 해석이 진행되었고 3차원 학습 데이터로 예측된 모델이 처짐 변형량이 감소된 것이 확인되었다. 이를 통해 3차원 학습 데이터를 이용하는 것이 경쟁력 있는 것으로 판단되었고 처짐 변형량의 감소로 타당성이 검증되었다.

**Key Words:** PIC 보(Piecewise Integrated Composite Beam), 2점 집중 하중(2 point concentrated load), 머신 러닝(Machine Learning), 3축 특성(Stress triaxiality), k-NN분류(k-NN classification)

## 1. 서 론

로봇에 사용되는 재료는 로봇 조작기에 위치 정확도와 빠른 기동성을 제공하기 위해 높은 강성을 가져야 한다[1]. 이는 액정표시장치(Liquid Crystal Display, LCD)의 제조과

정 내 공정 사이 기관 이송하는 방법 중 로봇 암을 이용한 이송 로봇에서도 중요하게 작용된다. 그러나 로봇 암을 이용한 이송 방식은 이송 과정에서 로봇 암의 처짐으로 인해 LCD가 처짐 변형 등의 문제가 발생하였는데 이는 LCD의 대평판화가 진행됨에 따라서 심각하게 대두되었다[2].

Received 15 November 2021, received in revised form 3 December 2021, accepted 14 December 2021

\*Department of Mechanical Engineering, Graduated School, Kongju National University

\*†Department of Mechanical Engineering, Graduated School, Kongju National University, Corresponding author (E-mail: sscheon@kongju.ac.kr)

\*\*Lacomtech. Co. Ltd.

선행된 연구에서 머신 러닝을 이용한 복합재의 구간 조합(Piecewise integrated composite, PIC) 강성을 향상하여 보의 처짐 변형률을 줄이는 연구가 진행되었지만 2차원 학습 데이터를 이용한 머신 러닝 모델은 단일 면의 거동만 고려되어 각 면이 접하여 하중에 영향을 주는 부분에서의 머신 러닝 모델의 정확도가 하락하는 것이 확인되었다[3]. 또한 선행된 연구에서 학습 데이터로 활용되는 참조 요소의 수가 약 5.7%로 적어서 모델의 정확도가 낮게 도출되었다[4]. 그래서 참조 요소의 수를 증가시키고 단일 면의 거동만을 고려하는 것이 아닌 객체 형상을 유지하는 3차원 학습 데이터를 이용한 머신 러닝 모델에 대한 연구 필요성이 있다. 그래서 본 연구에서는 참조 요소의 수를 늘리고 3차원 모델 형상을 유지하여 학습 데이터화하는 방법으로 강성 향상 머신 러닝 모델이 제안되었다.

본 연구에서는 LCD 제조업에서 생산성을 높이기 위해 싱글 암형 로봇 보다 더블 암형 로봇을 사용하는 추세에 맞춰 [5] 더블 암형 로봇에 구간 조합 복합재료 보를 적용하여 2점 집중 하중 시 강성을 향상시켜 처짐 변형을 줄이기 위하여 PIC에 머신 러닝 지도 학습 모델 중 K-NN 분류 알고리즘이 사용되었고, 2차원 학습 데이터보다 보의 거동에 따라 각 면에서 주는 영향을 고려할 수 있는 3차원 학습 데이터가 제안되었다. 우선, 머신 러닝 모델 학습 데이터 생성을 위하여 Carbon/Epoxy 소재의 복합재료 보의 2점 집중 하중 해석이 수행되었다. 학습 데이터 가공을 위해서 보에 일정한 간격으로 배치된 참조 요소에서 나타난 3축 특성(Stress triaxiality) 값을 이용하여 인장, 압축, 전단 세 가지로 구분되었다. 그리고 각 참조 요소의 번호와 좌표, 구분된 하중 유형으로 학습 데이터가 구성되었다. 구성된 학습 데이터와 하이퍼파라미터(Hyperparameter) 학습 데이터를 제어하는 데 사용되는 매개변수의 조절을 통해 머신 러닝 모델이 생성되고 머신 러닝 모델의 성능 지표인 예측 정확도를 추출하기 위해 학습 데이터를 이용한 훈련을 진행한다. 훈련을 통해 생성된 적절한 예측 정확도를 가진 머신 러닝 모델을 이용하여 구간 조합 복합재 보의 전체 요소의 하중 유형이 예측된다. 예측한 하중 유형을 근거로 각 요소에서 나타난 하중 유형에 강한 적층 각도 순서를 적용하여 2점 집중 하중 유한 요소 해석이 진행되었다[6]. 기존 모델과 2차원 학습 데이터를 이용한 PIC 모델, 3차원 학습 데이터를 이용한 PIC 모델을 비교하고 검증되었다.

## 2. 머신 러닝 모델

### 2.1 K-NN 분류

머신 러닝의 종류에는 지도 학습, 비지도 학습, 강화 학습 이 세 가지가 있다. 이 중 지도 학습의 목적은 레이블된 훈련 데이터에서 모델을 학습하여 본 적 없는 미래 데이터에 대해 예측을 만드는 것이다. 또한, 이 지도 학습의 하

위 카테고리에는 과거의 관측을 기반으로 새로운 샘플을 예측하는 것을 목적으로 하는 분류가 있다. 이 지도 학습 분류 모델이 보의 하중 유형을 구분하여 만들어진 훈련 데이터를 관측한 것을 기반으로 이용해 본 적 없는 새로운 요소들을 예측하는 것에 적합하여 본 연구에서 사용되었다[7].

본 연구에서는 지도 학습 분류 알고리즘 중 정해진 거리 측정 기준을 통해 요소간의 거리를 측정하고 k개의 최근 접 이웃을 찾고 다수결 투표를 통해 분류하고 예측하는 K-NN 분류 알고리즘을 사용하였다. K-NN 분류는 기존 데이터 중 가장 가까운 k개의 데이터를 이용해서 새로운 데이터를 예측하는 방법이다. K-NN 분류의 하이퍼파라미터(Hyperparameter)는 이웃의 수(k), 거리 측정 방법이 있다. 일반적으로 k의 값이 작을수록 지역적 특성을 지나치게 반영하게 되어 잡음의 영향이 커지게 되고, 클수록 모델이 과하게 정규화 되어 경계가 모호하게 되는 것으로 알려져 있고, 이에 따라 적절한 k 값을 선택하는 것이 필요하며, 이 값은 데이터에 따라 달라질 수 있다[8].

### 2.2 하이퍼파라미터(Hyperparameter)

하이퍼파라미터란 학습 과정을 제어하는데 사용되는 매개 변수를 뜻한다. K-NN 분류에서는 하이퍼파라미터로 이웃의 개수(k)와 요소간의 거리가 사용된다. 따라서 요소간의 거리를 측정하는 방법이 중요한 변수 중에 하나인데, 본 연구에서는 이웃의 개수를 3, 6, 8, 10으로 지정하고 거리 측정 방법 식 (1)을 이용하여 2차원 학습 데이터를 훈련할 때에는 선행된 연구에서 정확도가 높게 나타난 유클리디안(Euclidean distance,  $p = 2$ ) 거리를 사용하고 3차원 학습 데이터를 훈련할 때에는 맨해튼 거리(Manhattan distance,  $p = 1$ )와 유클리디안 거리, 민코프스키 거리(Minkowski distance,  $p = 3$ )를 비교하여 높은 정확도를 도출해 낼 수 있는 적절한 하이퍼파라미터가 선정되었다.

$$D = \left( \sum_{i=1}^n |p_i - q_i|^p \right)^{1/p} \quad (1)$$

## 3. 머신 러닝을 통한 PIC보 강성 향상

### 3.1 PIC 보의 머신 러닝 적용 방법

학습 데이터를 생성하기 위해 모델에 참조 요소를 배치하고 하중 유형을 구분하기 위해서 3축 특성을 이용하여 인장, 압축, 전단 세 가지로 각 참조 요소에 우세하게 나타나는 하중 유형으로 구분된다. 3축 특성 값은 무차원의 값으로 식 (2)과 같이 정의된다. 구간별로 계산된 3축 특성 값이 양일 때는 인장 하중이 주로 작용하고, 음의 값일 때는 압축하중이 주로 작용하고,  $-0.3 < \eta < 0.3$  일 때 전단하중이 주로 나타나는 구간을 의미한다[9,10].

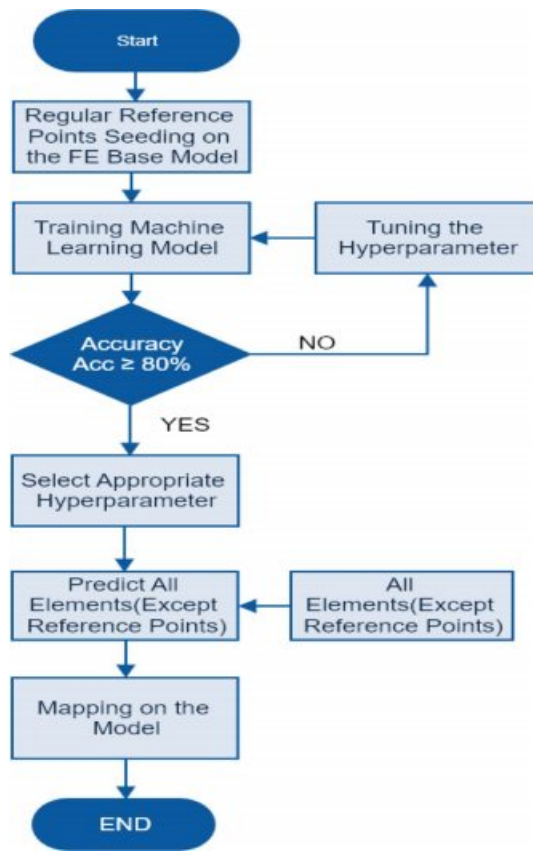


Fig. 1. Machine learning flow chart

$$\eta = \frac{\sigma_m}{\sigma} \quad (2)$$

본 연구에서 머신 러닝 모델 생성과정은 Fig. 1의 Flow chat와 같이 진행되었다. 먼저, 학습 데이터 생성을 위해 참조 요소를 일정한 간격으로 유한 요소 모델에 배치시키고 유한 요소 해석이 진행되었다. 해석에서 도출한 참조 요소의 좌표와 하중 유형으로 구성된 학습 데이터가 생성되었다. 생성된 학습 데이터와 하이퍼파라미터를 조절하여 머신 러닝 모델이 생성된다. 이때, 지도 학습 머신 러닝 모델의 성능 지표인 예측 정확도를 확인하여 가장 높은 정확도를 가진 하이퍼파라미터가 선별된다. 선별된 하이퍼파라미터를 적용한 머신 러닝 모델을 통해 모든 요소를 예측하고 예측된 결과를 이용하여 각 하중 유형에 강성이 우세한 적층 각도 순서가 배치된다.

### 3.2 보의 2점 집중 하중 모델로의 적용

본 연구에서는 3.5 kg의 기관을 4점 지지하는 더블 암형 로봇의 한 암을 단순화된 모델에 2점 집중 하중시, PIC 보의 강성을 향상시키는 연구가 진행되었다. Fig. 2와 같이 2점 집중 하중을 가했고 적층 각도 순서는  $[\pm 5/\pm 45/90]_{3S}$ 으로 유한 요소 모델링이 되었다. 보의 재질은 Carbon/Epoxy




Fig. 2. Configuration of FE model

Table 1. Material properties of T700/2510

Density $\rho$	1520	kg/m <sup>3</sup>
Modulus in 1-direction $E_1$	125	GPa
Modulus in 2-direction $E_2$	8.41	GPa
Shear modulus $G_{12}$	4.23	GPa
Major Poisson's ratio $\nu_{12}$	0.309	
Strength in x-direction, tension $X_t$	2.172	GPa
Strength in y-direction, tension $Y_t$	44.3	MPa
Strength in x-direction, compression $X_c$	1.448	GPa
Strength in y-direction, compression $Y_c$	199	MPa
Shear strength $S$	154	MPa

소재로 Toray사의 T700/2510이고 물성치는 Table 1에 나와 있다[11]. 참조 요소는 일정한 간격으로 각 면에 630개씩 총 2510개(약 12%) 배치되었다.

유한 요소 해석을 통해 도출된 3축 특성 값을 이용해 하중 유형을  $\eta < -0.1$ 일 때 압축,  $-0.1 \leq \eta \leq 0.1$ 일 때 전단,  $0.1 < \eta$ 일 때 인장으로 하중 유형을 분류하고 참조 요소의 좌표와 요소 별 구분된 하중 유형으로 구성된 2차원 학습 데이터와 3차원 학습 데이터가 생성되었다. 생성된 학습 데이터를 이용해 K-NN 분류 예측 훈련이 진행되었다. Table 2은 이웃의 개수에 따른 예측 정확도를 나타낸 것이다.

2차원 학습 데이터를 이용한 예측 훈련은 선행된 연구와 같이 상단과 하단면에서는 높은 정확도를 보였다. 상단과 하단 면의 경우 K-NN 분류 모델의 하이퍼파라미터는  $k$  값이 10일 때 97.8%와 96.3%로 예측 정확도가 제일 높게 도출되었고 보의 거동이 적은 상, 하단 면에서는  $k$  값이 증가할수록 높은 예측 정확도를 도출되는 것을 확인되었다. 하지만 양 옆면에서는 상, 하단면에 비해 정확도가 떨어지는 모습이 나타났고  $k$  값이 6일 때 82.1%, 좌측면에서는  $k$  값이 3일 때 80.6%로 예측 정확도가 가장 높게 도출되었다. 또한 선행된 연구에서 보인 적은 참조 요소 수로 인한 예측 정확도가 하락되는 문제는 참조 요소의 개수를 약 12% 증가시킴으로 해결되는 것으로 확인됐다.


3차원 학습 데이터를 이용한 예측 훈련은 2차원 학습 데

**Table 2.** Training accuracy by k

k	Dis	Accuracy (%)			
		Top	Bottom	Right	Left
3	2D	96.3	95.4	81.9	80.6
	3D(p=1)	96.7	95.7	82.1	79.5
	3D(p=2)	96.7	95.7	81.9	80.5
	3D(p=3)	96.7	94.9	81.9	80.5
6	2D	97.1	95.9	82.1	78.6
	3D(p=1)	97.6	96.2	82.1	76.8
	3D(p=2)	96.5	95.9	82.1	79.5
	3D(p=3)	96.5	95.9	81.9	79.8
8	2D	97.8	95.9	80.8	78.1
	3D(p=1)	97.3	96.2	79.2	77.6
	3D(p=2)	96.0	95.6	81.1	77.8
	3D(p=3)	95.9	95.7	81.6	77.3
10	2D	97.8	96.3	74.3	74.3
	3D(p=1)	97.8	96.0	66.2	64.0
	3D(p=2)	96.0	95.7	75.2	74.0
	3D(p=3)	96.0	95.1	78.7	76.5

**Table 3.** Training accuracy by set

	2D Data set (%)	3D Data set (%)		
		Manhattan	Euclidean	Minkowski
Set 1	95.2	95.2	95.2	95.2
Set 2	98.2	98.2	98.2	98.0
Set 3	98.4	99.0	95.6	95.6
Set 4	97.6	97.6	97.6	97.6
Set 5	96.8	96.6	94.8	94.8
Set 6	20.0	19.4	19.6	19.6
Set 7	89.3	74.0	88.9	92.1
Set 8	96.2	96.8	96.0	96.2
Set 9	95.4	93.8	94.6	94.2
Set 10	88.5	88.3	90.5	90.5
Set 11	95.6	94.8	95.6	95.6
Set 12	96.8	97.0	96.8	96.8
Set 13	95.6	96.0	96.0	96.8
Set 14	96.0	96.8	96.0	96.2
Set 15	95.2	95.4	94.0	91.5
Set 16	20.4	20.8	20.4	20.4
Set 17	88.9	75.0	88.9	93.5
Set 18	97.8	98.6	98.4	98.6
Set 19	96.6	96.4	96.8	97.2
Set 20	95.0	96.0	95.8	95.4

**Fig. 3.** Contour and reference points of FE base model: (a) Contour of FE base model, (b) reference points on FE base model

이터를 이용한 훈련보다 향상된 정확도를 보였다. 3차원 학습 데이터를 사용하였을 때, 상단과 하단 면의 경우 K-NN 분류 모델의 하이퍼파라미터는 k 값이 10이고 맨해튼 거리일 때 97.8%와 96.0%로 예측 정확도가 제일 높게 도출되었고, 양 옆면의 경우 우측면에서는 k 값이 3, 6이고 맨해튼 거리일 때 82.1%, 좌측면에서는 k 값이 3이고 유클리디안 거리일 때 80.5%로 예측 정확도가 가장 높게 도출되었다. 이때, 양 측면에서의 정확도가 상, 하단 면에서의 정확도 보다 다소 떨어지는 것을 확인되는데 이는 참조 요소 데이터 셋에 따른 훈련 정확도를 나타낸 Table 3를 보면 알 수 있다. 2차원 학습 데이터와 3차원 학습 데이터를 이용한 훈련 정확도가 양 옆면 중앙부의 데이터 셋(Set 6, Set16)을 이용한 훈련에서 예측 정확도가 많이 하락하는 모습이 나타났다. 이는 Fig. 3(a)를 보면 중앙부와 외곽의 하중이 다르게 나타나는 것을 확인할 수 있는데 이는 Fig. 3(b) 처럼 base model의 하중 분포를 고려하지 않고 참조 요소를 규칙적으로 배열할 때의 문제점으로 확인할 수 있었고 향후 연구에서는 base model의 하중 분포를 고려한 참조 요소의 불규칙 배치에 관한 연구가 필요한 것으로 보인다.

## 4. 복합재료 보의 유한 요소 해석




### 4.1 유한 요소 해석 모델

유한 요소 해석 모델은 앞서 진행한 Carbon/Epoxy 보와 동일한 형상의 모델이고, 해석 조건 또한 동일하다. 본 연구에서 가장 높은 정확도를 보인 하이퍼파라미터를 적용한 머신 러닝 모델을 통해 전체 요소를 예측하고 요소별 나타난 하중 유형에 따라 Table 4에 적힌 각 하중 유형에 강한 적층 각도 순서를 배치하였다. Fig. 4는 2차원 학습 데이터를 이용한 머신 러닝 모델을 통해 예측하고 배치된 모델의 모습이고, Fig. 5는 3차원 학습 데이터를 이용한 머신 러닝 모델을 통해 예측하고 배치된 모델의 모습이다. 머신 러닝을 이용해 강성 향상을 한 PIC 보들을 검증하기 위해 기존의 모델과 2차원 학습 데이터를 이용한 머신 러닝 모델을 통해 예측한 모델(2D PIC), 3차원 학습 데이터를 이용한 머신 러닝 모델을 통해 예측한 모델(3D PIC)을 비교 분석되었다.



**Table 4.** Stacking sequence of load dominant

Dominant	Stacking sequence
Tension	$[90/0/\bar{0}]_{6S}$
Shear	$[0/90]_{15}$
Compression	$[\pm 5/\pm 45/90]_{3S}$

**Fig. 4.** Mapping using 2D learning data set**Fig. 5.** Mapping using 3D learning data set**Fig. 6.** Base model bending deformation

#### 4.2 유한요소 해석 결과

각 PIC 방법으로 설계된 보들의 해석 결과, Fig. 6과 같이 3D PIC, 2D PIC, base 모델 순으로 처짐 변형량이 낮게 나오는 것이 확인되었다. Base 모델, 2D PIC 방법으로 설계된 보와 3D PIC 방법으로 설계된 보의 굽힘 변형량은 각각 약 0.077 mm, 0.072 mm, 0.07 mm으로 3D PIC 방법과 2D PIC 방법으로 설계된 보의 변형량이 base 모델 보다 각각 약 8.5%, 6.0% 감소하였으며 더 높은 강성을 갖는 것으로 확인되었다. 위의 결과를 통해서 2D PIC와 3D PIC의 예측 정확도는 타당한 것으로 사료된다.

## 5. 결 론

PIC 복합재료 보의 강성을 향상 시키기 위하여 머신 러닝 모델 중 K-NN 분류 모델을 사용하여 인장 특성, 압축 특성, 전단 특성이 지배적인 영역을 각각의 하중에 강성이 강한 적층 각도 순서가 배치되었다. 본 연구에서는 보의 거동을 고려하기 위해 참조 요소의 차원을 변화시켜서 PIC 보의 강성을 향상시키는 연구가 진행되었다.

2차원 학습 데이터를 사용하였을 때, 보의 거동이 적은 상 하단 면에서는 k 값이 증가할수록 높은 예측 정확도를 도출되는 것을 확인하였다. 반면 보의 거동이 많은 양 옆면에서는 k 값이 증가할 수 록 경계가 모호해져 예측 정확도가 하락하는 것이 확인되었다. 또한 선행된 연구에서 언급된 참조 요소의 개수가 적어서 생기는 예측 정확도 하락 문제는 참조 요소의 개수를 늘린 이번 연구에서 해결되는 모습이 확인되었다.

3차원 학습 데이터를 사용하였을 때, 2차원 학습 데이터를 이용한 훈련보다 향상된 정확도를 보였다. 또한 3차원 학습 데이터를 이용한 예측은 보의 거동 영향이 크게 작용하는 각 면의 외곽 부에서 2차원 학습 데이터를 이용한 예측보다 높은 정확도를 도출되었다. 이를 통해 3차원 학습 데이터를 이용한 머신 러닝 예측 모델은 2차원 학습 데이터를 이용한 머신 러닝 예측 모델에 비해 보의 거동을 고려하는 데에 우수한 성능을 가진 것으로 판단된다.

2차원 학습 데이터를 사용하였을 때와 3차원 학습 데이터를 사용하였을 때 공통적으로 양 옆면의 중앙부의 데이터 셋 예측 정확도가 급격히 하락하는 모습이 나타났다. 이는 중앙부 데이터 셋의 이웃 데이터들의 하중이 다르게 작용하는 것을 원인으로 찾을 수 있었고 이를 해결 하기 위해서는 참조 요소의 배치를 불규칙적으로 바꾸어서 해결할 수 있을 것으로 사료된다[12].

2차원과 3차원 학습데이터를 이용한 2가지 방법으로 복합재료 보에 매핑을 하여 비교하였다. 그 결과, 3D PIC 방법으로 설계된 보와 2D PIC 방법으로 설계된 보의 굽힘 변형량이 base 모델보다 감소하였으며 더 높은 강성을 갖는 것으로 확인되었다.

향후에는 앞서 언급된 참조 요소가 불규칙적으로 배치된 3차원 학습 데이터를 이용한 머신 러닝 모델에 관한 연구가 필요할 것으로 사료된다.

## 후 기

이 논문은 2019년 중소벤처기업부의 기업연계형 연구개발 인력양성사업(S2755803)의 지원을 받아 수행된 연구입니다.

## REFERENCES

1. Kim, Y.G., Jeong, K.S., Lee, D.G., and Lee, J.W., "Development of the Composite Third Robot Arm of the Six-axis Articulated Robot Manipulator," *Composite Structures*, Vol. 35, No. 4, 1996, pp. 331-342.
2. Ko, H.J., Kim, J.H., and Cho, W., "A Study of LCD Transfer System Using Thereof," *Korean Society for Precision Engineering*, 2008, pp. 411-412.
3. Ham, S.W., Cheon, S.S., and Jeong, K.Y., "Strength Optimization of Piecewise Integrated Composite Beam Through Machine Learning," *Transactions of the Korean Society of Mechanical Engineers, A*, Vol. 43, No. 8, 2019, pp. 521-528.
4. Ham, S.W., Ha, Y.S., and Cheon, S.S., "Predict Rate Machine Learning Model by Irregular Arrangement of Reference Points of Piecewise Integrated Composite Beam," *Proceeding of the Korean Society for Composite Materials*, Aug. 2020, pp. 121-122.
5. Lee, C.S., Lee, D.G., Oh, J.H., and Kim, H.S., "Composite Wrist Blocks for Double Arm Type Robots for Handling Large LCD Glass Panels," *Composite Structures*, Vol. 57, No. 1-4, 2002, pp. 345-355.
6. Jeong, C., Ham, S., Kim, G., and Cheon, S.S., "Development of the Piecewisely-integrated Composite Bumper Beam Based on the IIHS Crash Analysis," *Composites Research*, Vol. 31, No. 1, 2018, pp. 37-41.
7. Lantz, B., *Machine Learning with R*, 2nd ed., Packt Pub., UK, 2015.
8. Konjevoda, P., and Stambuk, N., "Open-source Tools for Data Mining in Social Science," *IntechOpen*, 2012.
9. Bai, Y., Teng, X., and Wierzbicki, T., "On the Application of Stress Triaxiality Formula for Plane Strain Fracture Testing," *Journal of Engineering Materials and Technology*, Vol. 131, No. 2, 2009, 021002.
10. Bao, Y., and Wierzbicki, T., "On Fracture Locus in the Equivalent Strain and Stress Triaxiality Space" *International Journal of Mechanical Sciences*, 46, No. 1, 2004, pp. 81-98.
11. Toray Composite Materials America, Inc., "2510 Prepreg System," <https://www.toraycma.com/wp-content/uploads/2510-Prepreg-System.pdf>, 2017.
12. Ham, S.W., and Cheon, S.S., "Load Fidelity Improvement of Piecewise Integrated Composite Beam by Construction Training Data of k-NN Classification Model," *Composites Research*, Vol. 33, No. 3, 2020, pp. 108-114.