

## k-NN 분류 모델의 학습 데이터 구성에 따른 PIC 보의 하중 충실도 향상에 관한 연구

함석우\* · 전성식\*<sup>†</sup>

### Load Fidelity Improvement of Piecewise Integrated Composite Beam by Construction Training Data of k-NN Classification Model

Seok Woo Ham\*, Seong S. Cheon\*<sup>†</sup>

**ABSTRACT:** Piecewise Integrated Composite (PIC) beam is composed of different stacking against loading type depending upon location. The aim of current study is to assign robust stacking sequences against external loading to every corresponding part of the PIC beam based on the value of stress triaxiality at generated reference points using the k-NN (k-Nearest Neighbor) classification, which is one of representative machine learning techniques, in order to excellent superior bending characteristics. The stress triaxiality at reference points is obtained by three-point bending analysis of the Al beam with training data categorizing the type of external loading, i.e., tension, compression or shear. Loading types of each plane of the beam were classified by independent plane scheme as well as total beam scheme. Also, loading fidelities were calibrated for each case with the variation of hyper-parameters. Most effective stacking sequences were mapped into the PIC beam based on the k-NN classification model with the highest loading fidelity. FE analysis result shows the PIC beam has superior external loading resistance and energy absorption compared to conventional beam.

**초 록:** Piecewise Integrated Composite (PIC) 보의 하중 유형에 따라 구간을 나누어, 각 구간마다 하중 유형에 강한 복합재료의 적층 순서를 배열한 보이다. 본 연구는 PIC 보의 구간을 머신 러닝의 일종인 k-NN(k-Nearest Neighbor) 분류를 통해 나누어 기존에 제시되었던 PIC 보에 비해 우수한 굽힘 특성을 갖게 하는 것이 목적이다. 먼저, 알루미늄 보의 3점 굽힘 해석을 통하여 참조점에서의 3축 특성(Triaxiality) 값 데이터를 얻었고, 이를 통해 인장, 전단, 압축의 레이블을 가진 학습 데이터가 만들어진다. 학습 데이터를 통해 각 면마다 독립적인 k-NN 분류 모델을 구성하는 방법(Each plane)과 전체 면에 대한 k-NN 분류 모델을 구성하는 방법(one part)을 이용하여 k-NN 분류 모델을 생성하였고, 하이퍼파라미터의 튜닝을 통하여 다양한 하중 충실도를 도출하였다. 가장 높은 하중 충실도를 가진 k-NN 분류 모델을 기반으로 보를 매핑(mapping)하였고, PIC 보에 대하여 유한요소 해석을 진행한 결과, 기존에 제시되었던 PIC 보에 비해 최대하중과 흡수 에너지가 커지는 특성을 보였다. 하중 충실도를 수동으로 조절하여 100%로 만든 PIC 보와 비교하였을 때, 최대하중과 흡수 에너지가 미소한 차이가 나타났으며 이는 타당한 하중 충실도로 보여진다.

**Key Words:** PIC 보(Piecewise Integrated Composite Beam), 3점 굽힘 해석(3 point bending analysis), k-NN 분류(k-NN classification), 3축 특성(Stress triaxiality)

## 1. 서 론

최근 환경문제로 인해 전세계적으로 법적 배출 가스 규제를 확대하여 자동차 생산회사들은 배출 가스를 줄이기 위하여 경량화에 관한 연구를 많이 진행하고 있다. 자동차의 경량화 연구는 머신 러닝(machine learning)을 적용한 위상최적화, 형상최적화 그리고 경량화 소재 치환하는 등 여러 가지 분야에서 진행되고 있다. 경량화 소재로는 비철금속, 고장력강, 복합재료가 대표적으로 여겨지고 있으며, 특히 복합재료는 금속 및 기타 소재에 비해 비강성 및 비강도가 우수하여 광범위한 응용분야에 적용되고 있다[1,2]. 특히, 자동차의 여러 부품에 적용하기 위한 연구가 활발하게 이루어지고 있다. Cheon 등[3]은 승용차를 위한 새로운 유형의 하이브리드 복합 범퍼 빔을 제안하고 유한요소 해석을 수행하였으며, Belingardi 등[4]은 펄트루전(Pultrusion)으로 제조된 복합재료 범퍼 빔에 대해 수치 해석으로 최적화된 단면 형상을 제안하였다. Kim 등[5]은 최적화된 자동차 하이브리드 복합 범퍼 빔에 관한 연구를 진행하였다. 이처럼 복합재료 범퍼 빔에 대한 연구는 다양하게 시도되고 있으나, 범퍼 빔 전 영역에 단일 적층 순서를 적용하는 것이 일반적이었다. Jeong 등[6]은 범퍼 빔을 5개의 균등한 영역으로 나누어 인장, 전단, 압축의 하중 유형을 분석하고 하중 유형에 따라 복합재료의 적층 순서를 나누어 배열하여 구간조합 복합재료 범퍼 빔을 제안하였다. 또, 유한요소 해석을 진행하여 여러 영역으로 나누면 최대 하중 및 에너지 흡수율이 증가하는 것을 입증하였다. 하지만 임의로 5개의 균등한 구간을 나누어 하중 분석을 하였기 때문에 이에 대한 구간 최적화가 필요하다. 각 면에 대하여 인장, 전단, 압축에 강한 복합재료의 적층 순서를 자동적으로, 보다 빠르게 설계가 될 필요가 있는데, 이는 머신 러닝을 통하여 해결할 수 있다. 본 연구에서는 머신 러닝 중 하나인 k-Nearest Neighbors (k-NN) 분류를 선택하였는데 그 이유는 k-NN 분류는 비모수적(Non-parametric statistics)으로 추정하는 방법이기 때문이다. 이 방법은 모집단이 정규 분포가 아닐 때 사용되는데, 유한요소 해석 결과도, 모집단이 정규 분포가 아니기 때문에 적합하기 때문이다[7].

본 논문에서는 복합재료 보의 3점 굽힘 시의 강도 및 에너지 흡수율을 최적화하기 위하여 k-NN 분류를 이용한 PIC 기법이 제안되었다. 우선, 3점 굽힘 시, k-NN 분류 모델 학습 데이터 생성을 위하여 알루미늄 보의 3점 굽힘 해석이 수행되었다. 학습 데이터는 3축 특성 값(Triaxiality) 분석을 통해 인장, 전단, 압축의 3개의 레이블(Label)로 생성되었고, 보의 전체 요소가 아닌 일정한 간격으로 배치된 참조점(Reference point)에서 추출되었다. 추출된 학습 데이터와 하이퍼파라미터(Hyperparameter)의 튜닝(tuning) 통해 k-NN 분류 모델이 생성된다. 본 연구에서는 2D와 3D의 두 가지 유형의 학습 데이터 형태로 k-NN 분류 모델이 생성되었

다. 2D 형태의 학습 데이터는 윗면, 옆면과 아랫면을 대상으로 (x, y) 형태로 생성되었고, 3D 형태의 학습 데이터는 전체 면을 대상으로 (x, y, z) 형태로 생성되었다. k-NN 분류 모델의 성능 지표인 하중 충실도(Load fidelity)를 도출하기 위하여 학습 데이터의 일부를 테스트 데이터로 사용하게 된다. 하중 충실도는 하이퍼파라미터의 튜닝에 의해 결정된다. 적절한 하중 충실도를 가진 k-NN 분류 모델을 통해 보의 전체 요소의 하중 유형을 예측한다. 예측 결과를 토대로 보의 유한요소 모델에 매핑하여 carbon/epoxy 복합재료 보의 적층 순서 구간을 최적화하였다. 그리고 기존에 사용되던 uni-type의 적층 순서로 이루어진 보, Jeong 등이 제안한 기법으로 설계한 보와 k-NN 분류를 통하여 최적화된 보의 강도를 비교 검증하였다. 또, 보를 2D 형태의 학습 데이터를 통해 생성한 각 면에 독립적인 k-NN 분류 모델을 생성하여 최적화한 방법과 보의 3D 형태의 학습 데이터를 통해 전체 면에 대한 k-NN 분류 모델을 생성하여 최적화한 방법의 강도를 비교하였다.

## 2. k-NN 분류 모델

k-NN분류는 새로운 데이터에서 가장 가까운 k개의 학습 데이터로 예측하는 방법이다. 예를 들어 Fig. 1과 같이 학습 데이터가 분포하여 있고, 그 레이블이 각각reference point A (R.P.A)와 reference point B (R.P.B)로 나타나 있을 때,  $k = 3$ 인 경우, 새로운 데이터에서 가장 가까운 3개의 기존 데이터는 R.P.A가 2개, R.P.B가 1개이다. R.P.A가 과반 이상이므로 새로운 데이터는 R.P.A로 예측된다[8]. 여기서 학습 데이터는 k-NN 분류 모델을 학습시키기 위한 데이터이고, 레이블은 데이터의 종류를 뜻한다.

k-NN 분류 모델은 하이퍼파라미터에 의해 튜닝되어 생성된다. 하이퍼파라미터에는 이웃의 수(k), 거리 측정 방법과 가중치(Weight)가 있다. 이웃의 수 k는 새로운 데이터에서 가장 가까운 k개의 학습 데이터를 나타낸다. 일반적인

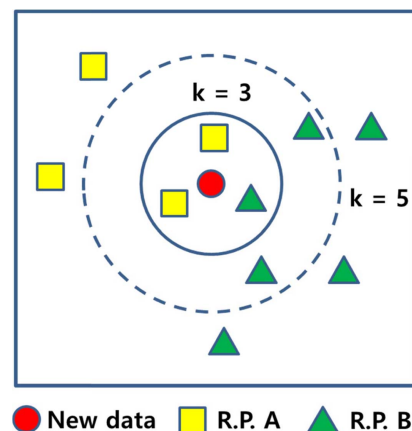


Fig. 1. k-NN classification example

로  $k$ 의 값이 작을수록 지역적 특성을 지나치게 반영하게 되어 잡음의 영향이 커지게 되고, 클수록 모델이 과하게 정규화 되어 경계가 모호하게 되는 것으로 알려져 있다. 이에 따라 적절한  $k$  값을 선택하는 것이 필요하며, 이 값은 데이터에 따라 달라질 수 있다. 두 번째로, 거리 측정 방법에는 유클리드 거리, 맨해튼 거리, 민코우스키 거리 측정법이 있다 [9]. 민코우스키 거리 측정법 공식인 식 (1)에서  $r$  값에 의해 유클리드 거리 측정법( $r = 2$ ), 맨해튼 거리 측정법( $r = 1$ ) 등으로 분류된다.

$$X = (x_1, x_2, \dots, x_n), Y = (y_1, y_2, \dots, y_n)$$

$$d = (X, Y) = \left( \sum_{i=1}^m |x_i - y_i|^r \right)^{1/r} \quad (1)$$

본 연구에서는  $k$ -NN 분류에서 가장 흔히 사용되고 있는 거리 측정방법인 유클리드 거리를 사용하였다. 유클리드 거리는 두 데이터 사이의 직선 최단거리를 측정하는 방법이다. 측정된 거리  $d(X, Y)$ 에 가중치를 부여할 수 있다. 그 방법에는 가중치를 모두 같게 하는 equal, 새로운 데이터와의 거리의 역수( $\frac{1}{d(X, Y)}$ )를 두는 inverse, 거리의 역수 제곱( $\frac{1}{d(X, Y)^2}$ )를 두는 squared inverse가 있다.

### 3. k-NN 분류를 통한 PIC보 강도 향상

#### 3.1 k-NN 분류 적용 방법

본 연구에서 진행된 알고리즘 구성도를 Fig. 2에 나타내었다. 먼저, 학습 데이터를 도출하기 위하여 하중 유형 분석이 진행되었다. 하중 유형 분석은 전체 요소에 대하여 진행했을 경우, 많은 시간이 소요되므로, 일부 요소에서 데이터를 얻게 된다. 그 일부 요소들은 참조점이라고 한다. 각 참조점에서의 하중 유형 분석은 3축 특성 값을 통해 인장, 전단, 압축으로 학습 데이터의 레이블을 나누게 된다. 여기서 3축 특성 값은 무차원의 값이고, 식 (2)와 같이 정의된다. 3축 특성 값은 인장 하중이 가해졌을 경우  $0.1 < \eta \leq 1$ , 전단 하중이 가해졌을 경우  $-0.1 \leq \eta \leq 0.1$ , 압축 하중이 가해졌을 경우  $-1 \leq \eta < -0.1$ 로 나타난다.  $\sigma_m$ 은 식 (3)과 같이 평균응력을 나타내고  $\bar{\sigma}$ 는 식 (4)과 같이 von Mises 응력을 나타낸다[10].

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

$$\sigma_m = \frac{1}{3}(\sigma_1 + \sigma_2 + \sigma_3) \quad (3)$$

$$\bar{\sigma} = \sqrt{\frac{1}{2}[(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2]} \quad (4)$$

학습 데이터의 형태는 레이블은 하중 유형과 참조점의 좌표로 나타난다. 본 연구에서는 각 면에 대하여 독립적인

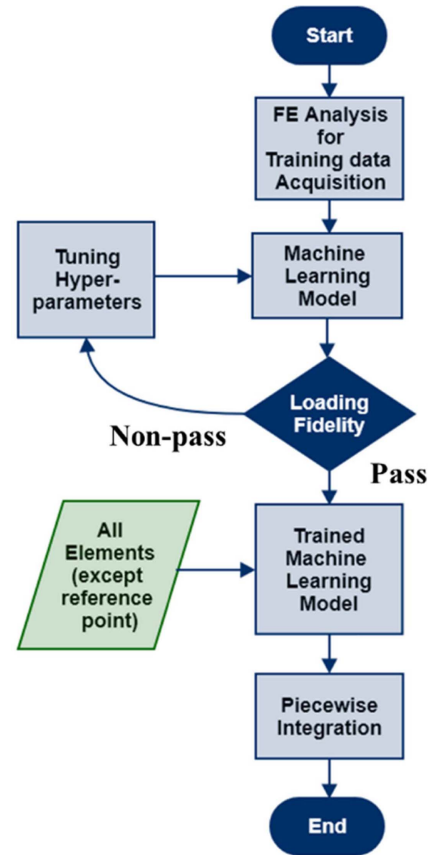


Fig. 2. An algorithm for FE analysis with k-NN classification

$k$ -NN 분류 모델(Each plane)을 구성하는 방법과 전체 면에 대하여  $k$ -NN 분류 모델(One part)을 구성하는 방법으로 진행되었다. Each plane 방법은 단일 면에 대한  $k$ -NN 분류 모델을 생성하기 때문에 참조점은  $(x, y)$  형태의 2차원 데이터로 나타내었고, one part 방법은 전체 면에 대한  $k$ -NN 분류 모델을 참조점은  $(x, y, z)$  형태의 3차원 데이터로 나타내었다.

학습 데이터와 하이퍼파라미터의 튜닝으로  $k$ -NN 분류 모델이 생성된다. 모델의 성능인 하중 충실도는 테스트 데이터를 모델에 입력하여 레이블을 예측하여 확인한다[4]. 식(5)에 나타난 것처럼 테스트 데이터 중  $k$ -NN 분류 모델이 예측한 점이 참일 때의 비율이다.

$$\text{Load fidelity (\%)} = \frac{\text{Predict}_{\text{True}}}{\text{Test data}} \times 100 \quad (5)$$

사용자가 하중 충실도를 통하여 학습 결과의 타당성을 판단한다. 만약 타당하지 않다고 판단할 시, 하이퍼파라미터들을 다시 튜닝하여 하중 충실도를 확인한다. 학습 결과가 타당하다고 판단되면 학습된  $k$ -NN 분류 모델을 통하여 전체요소들을 예측 및 매핑한다. 마지막으로 매핑된 결과로 각 하중에 강한 적층 순서를 배치한다[11].

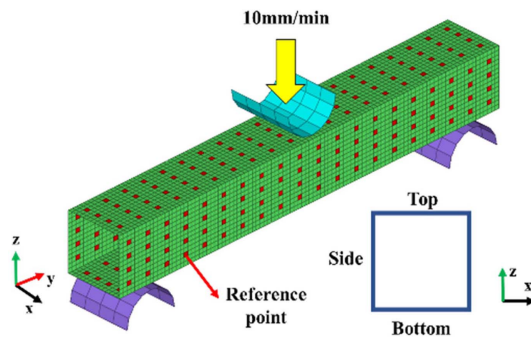


Fig. 3. Configuration of FE model

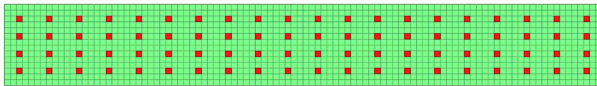


Fig. 4. Distribution of reference points in one face

### 3.2 알루미늄 보의 유한요소 해석

알루미늄 보의 하중 유형을 분석하기 위하여 선행적으로 3점 굽힘 해석을 진행하였다. 유한요소 모델은 Fig. 3와 같이 제작하였으며, 보는 윗면, 옆면, 아랫면으로 구성되어 있다. 참조점은 Fig. 4과 같이 한 면당 80 ( $20 \times 4$ )개로 동일한 간격으로 배치시켰다. Each plane 방법의 참조점은 각 모델마다 80개로 구성되어 있고, one part 방법의 참조점은 320개로 구성되어 있다. 해석 조건은 상단 지그를 10 mm/min으로 변위제어를 하였다.

유한요소 해석을 통해 참조점의 3축 특성 값을 분석하여 인장 특성, 전단 특성, 압축 특성이 지배적인 레이블로 나누어 학습 데이터를 생성하였다. Each plane 방법의 학습 데이터는 총 240개(k-NN 분류 모델 당 학습 데이터 80개, k-NN 분류 모델 3개), 테스트 데이터 총 48개로 구성되고, one part 방법의 학습데이터는 320개, 테스트 데이터 64개로 구성된다.

### 3.3 k-NN 분류 모델

3.2절에서 생성된 학습데이터를 기반으로 하이퍼파라미터를 튜닝하여 k-NN 분류 모델을 생성하였다.

Each plane 방법을 이용하였을 경우의 각 하이퍼파라미터 별 결과는 Table 1에 나타나있다. 윗면의 경우 k 값이 10, 거리 측정 방법이 유클리드, 가중치가 squared inverse인 모델, 옆면의 경우 각각 10, 유클리드, equal인 모델, 아랫면의 경우 각각 10, 유클리드, squared inverse인 모델이 가장 높은 하중 충실도를 보였다. 윗면, 아랫면의 가중치가 squared inverse인 경우 높은 하중 충실도가 도출되었는데, 이는 윗면과 아랫면의 실제 하중 유형이 횡축 방향에 대해서 같기 때문이라 생각된다. 또, 옆면에서는 가장 높은 하중 충실도를 보인 모델은 윗면과 아랫면에서 가장 높은 하중 충실도를 보인 모델에 비해 낮은 하중 충실도가 나왔는데, 이는 하

Table 1. Hyperparameter &amp; k-NN model with each plane load fidelity

k value	Distance	Weight	Load fidelity (%)		
			Top	Side	Btm
1	Euclidean	Equal	80.0	50.0	96.3
10	Euclidean	Equal	75.0	70.0	87.5
100	Euclidean	Equal	40.0	48.8	77.5
10	Minkowski r = 5	Equal	75.0	70.0	87.5
10	Euclidean	Squared inverse	81.3	57.5	96.3

Table 2. Hyperparameter &amp; k-NN model with one part load fidelity

k value	Distance	Weight	Load fidelity (%)
3	Euclidean	Equal	70.0
5		Equal	67.5
10		Equal	68.5
100		Equal	52.5
3		Inverse	67.5
3		Squared Inverse	75.0
5		Inverse	71.3
5		Squared Inverse	70.4
10		Inverse	69.6
10		Squared Inverse	71.3

중 분포를 고려하지 않고 참조점을 배치하였고, 다른 면에 의한 하중 영향을 고려하지 않았기 때문이라 사료된다.

One part 방법을 이용하였을 경우의 각 하이퍼파라미터 별 결과는 Table 2에 나타나있다. k 값이 3 거리 측정 방법이 유클리드, 가중치가 squared inverse일 때 가장 높은 하중 충실도가 도출되었다. 가중치가 Equal이고 k 값이 커질수록 하중 충실도가 낮아지는 경향을 보였다. 이는 가중치가 모두 같은 equal이고 k값이 커질수록 테스트 데이터와 관련도가 떨어지는 데이터가 포함되기 때문이라 생각된다.

Each plane 방법은 한 면에 대한 학습 데이터를 사용하였기 때문에 단순한 변형에 대하여 하중 충실도가 높게 나타났다. 하지만 다른 면의 영향으로 변형이 일어났을 경우엔 하중 충실도가 떨어지는 경향을 보였다.

One part 방법은 전체 면에 대한 학습 데이터를 사용하였기 때문에 단순한 변형의 경우 each plane 방법에 비해 하중 충실도가 낮게 도출되었지만 전체 면의 학습데이터도 고려하였기 때문에 다른 면의 영향을 받았을 경우, each plane 방법보다 높은 하중 충실도를 보였다.

Each plane 방법과 one part 방법을 이용하여 가장 높은 하중 충실도를 보인 모델들의 결과를 토대로 보의 각 면에 매핑하여 각각 Fig. 5와 Fig. 6에 나타내었다.

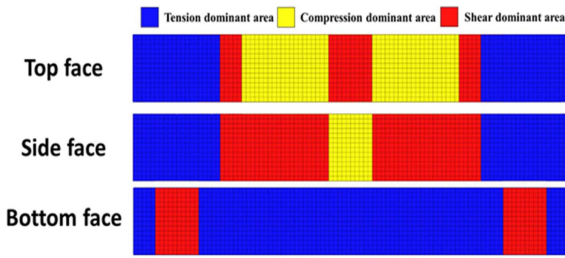


Fig. 5. Mapping using each plane method results

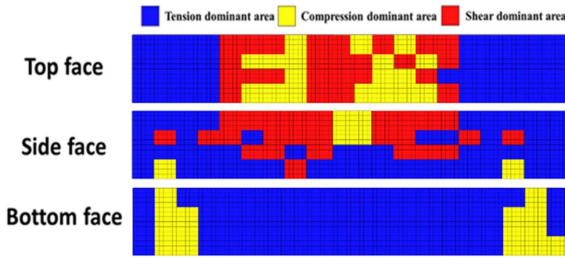


Fig. 6. Mapping using one part method results

## 4. 복합재료 보의 유한요소 해석

### 4.1 유한요소 해석 모델

유한요소 해석 모델은 앞서 진행한 알루미늄 보와 동일한 형상의 모델이고, 해석 조건 또한 동일하다. 해석 모델의 재료는 carbon/epoxy 복합재료인 ASI/3501-6을 사용하였다[12]. 하중 유형에 강한 적층 순서는 Table 3과 같다. k-NN 분류 모델을 사용하여 강도 최적화를 한 PIC 보들을 검증하기 위하여 단일 적층 순서로 이루어져 있는 보, Jeong이 제안한 기존의 PIC 방법으로 설계된 보와 비교 분석하였다. 또, 학습 데이터를 기반으로 수동으로 하중 충실도를 조절하여 각각 70%, 80%, 90%, 100%일 때와 비교하여 k-NN 분류 모델을 통해 도출된 하중 충실도의 타당성을 검증하였다. 수동으로 조절된 하중 충실도로 설계된 보의 선행 유한요소해석의 결과를 바탕으로 320개의 참조점 중 하중이 상대적으로 많이 작용하는 참조점을 대상으로 학습데이터와 각각 70%, 80%, 90% 그리고 정확히 일치한 데이터로 머신 러닝 모델을 생성 후 PIC보에 매핑하였다.

Table 4와 같이 Case 1~3은 각각 인장 특성, 압축 특성, 전단 특성에 강한 적층 순서로 이루어져 있는 보이고, PIC는 기존에 제안된 방법으로 설계된 보이다. PIC with each plane

Table 3. Stacking sequence of load dominant

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

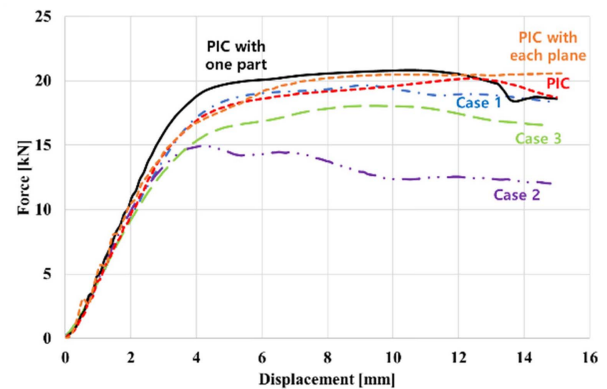
Table 4. Properties of cases

Dominant	Stacking sequence set
Case 1	Tension dominant
Case 2	Compression dominant
Case 3	Shear dominant
PIC	PIC
PIC with each plane	Optimization with k-NN
PIC with one part	Optimization with k-NN

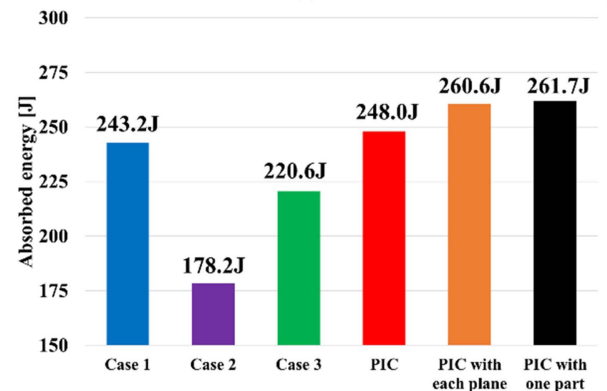
과 PIC with one part는 각각 each plane 방법과 one part 방법으로 도출된 데이터를 기반으로 매핑된 보이다.

### 4.2 유한요소 해석 결과

각 case들의 3점 굽힘 해석 결과, Fig. 7과 같이 최대 하중은 PIC with one part, PIC with each plane, PIC, case 1, case 3, case 2 순으로 높게 나타났으며, 에너지 흡수율 또한 같은 순으로 높게 나타났다. PIC with each plane과 PIC with one part는 기존의 방식으로 설계된 PIC 보 대비 최대 하중은 각각 1.9%와 3.1% 증가하는 것으로 나타났고 에너지 흡수율은 약 4.8%와 13.3% 증가하는 것으로 나타났다. 학습

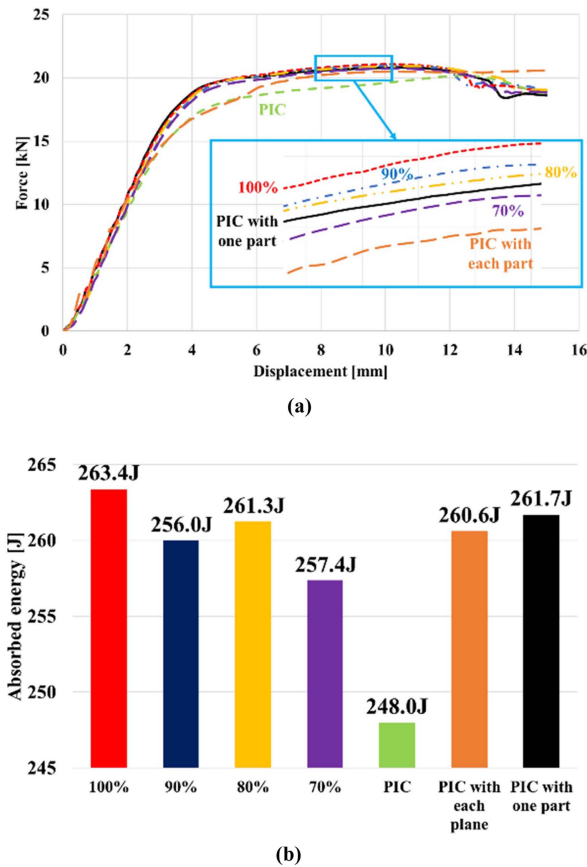


(a)



(b)

Fig. 7. Results of 3 point bending analysis: (a) Force vs displacement curve, (b) absorbed energy



**Fig. 8.** Results according to load fidelity: (a) Force vs displacement curve, (b) absorbed energy

데이터를 기반으로 수동으로 하중 충실도를 조절하여 매 평하여 설계한 보를 PIC, k-NN 분류 모델을 사용한 PIC보를 비교한 결과는 Fig. 8과 같다.

최대 하중은 100%, 90%, 80%, PIC with one part, 70%, PIC with each part, PIC 순으로 나타났으며, 에너지 흡수율은 100%, PIC with one part, 80%, PIC with each plane, 90%, 70%, PIC 순으로 나타났다. PIC with each plane과 PIC with one part는 하중 충실도 100% 대비 최대 하중은 각각 2.5%, 1.3% 감소하는 것으로 나타났고, 에너지 흡수율은 각각 1.1%, 0.6% 감소하는 것으로 나타났다. 위의 결과를 미루어 볼 때, PIC with each plane과 PIC with one part의 하중 충실도는 타당하다고 사료된다.

## 5. 결 론

본 연구에서는 PIC 복합재료 보의 강도를 최적화하기 위하여 머신 러닝의 일종인 k-NN 분류 모델을 통하여 인장 특성, 전단 특성, 압축 특성이 지배적인 영역을 분류하였다. 각 면에 대하여 독립적인 k-NN 분류 모델을 구성하는 방법(Each plane)과 전체 면에 대하여 k-NN 분류 모델을 구성하는 방법(One part)을 통하여 PIC 보의 강도를 최적화

하였다.

Each plane 방법을 이용했을 때, k-NN 분류 모델의 하이퍼파라미터는 윗면과 아랫면에서는 k 값이 10, 거리 측정 방법이 유클리드, 가중치가 squared inverse일 때, 하중 충실도가 각각 81.3%, 96.3%로 가장 높게 도출되었고, 옆면에서는 각각 10, 유클리드, equal일 때, 하중 충실도가 70%로 가장 높게 도출되었다. 옆면이 다른 면에 비하여 낮은 하중 충실도가 도출되었는데 이는 보의 거동을 고려하지 않았을 뿐만 아니라 다른 면의 영향도 고려하지 않았기 때문이라 사료된다.

One part 방법을 이용했을 때, k-NN 분류 모델의 하이퍼파라미터는 k 값이 3, 거리 측정 방법이 유클리드, 가중치가 squared inverse일 때, 하중 충실도가 75%로 가장 높게 도출되었다.

단순 변형의 경우, each plane 방법에 비해 하중 충실도가 낮게 도출되었지만, 전체 면의 학습 데이터를 고려하였기 때문에 다른 면의 영향을 받았을 때, each plane 방법보다 높은 하중 충실도를 보였다. 또, One part 방법은 each plane 방법보다 k-NN 분류 모델 생성 횟수가 적기 때문에 One part 방법이 더 효율적이라고 생각된다.

k-NN 분류 모델을 통하여 최적화된 PIC 보와 기존의 방법으로 설계된 PIC 보를 비교하였다. 그 결과, each plane 방법과 one part 방법의 최대 하중은 각각 20.6 kN, 20.8 kN으로 기존의 방법으로 설계된 PIC 보 보다 각각 1.8%, 3.1%가 높으며 단일 적층 순서 및 기존의 PIC 보들 보다 더 우수한 굽힘 특성이 나타나는 것을 확인하였다. 또, 학습 데이터를 기반으로 하여 하중 충실도를 수동으로 조절하여 비교 검증하였다. 하중 충실도가 100%일 때는 each plane 방법과 one part 방법 대비 최대하중은 각각 2.5%, 1.3% 높은 것을 확인할 수 있었고, 에너지 흡수율은 각각 1.1%, 0.6% 높은 것을 확인할 수 있었다. 이를 통하여 본 연구에서 사용된 k-NN 분류 모델의 하중 충실도는 타당하다고 사료된다.

본 연구 결과를 자동차 부품과 같은 복잡한 형상에 적용하기 위해서는 참조점을 하중 유형을 고려하여 배치하고, one part 방법을 활용해야 한다고 생각된다. 또한 PIC 기법을 구현하기 위해서는 적층 설계 및 제작 조건 등이 고려된 알고리즘에 대한 개발이 필요하다고 생각된다.

## 후 기

본 연구는 2019년 중소벤처기업부의 기업연계형 연구개발 인력양성사업(S2755803)의 지원을 받아 수행된 것이며, 지원에 대해 진심으로 감사드립니다.

## REFERENCES

1. Na, H.J., Chun, J.S., and Cho, K.S., "Development of CFRP

- Tubes for the Light-Weight Propeller Shaft of 4WD SUV Vehicles,” *Journal of the Korean Society of Manufacturing Process Engineers*, Vol. 17, No. 4, 2018, pp. 32-38.
2. Chun, D.M., and Ahn, S.H., “Change of Mechanical Properties of Injection-Molded Glass-Fiber-Reinforced Plastic (GFRP) According to Temperature and Water Absorption for Vehicle Weight Reduction,” *Transactions of the Korean Society of Mechanical Engineers - A*, Vol. 37, No. 2, 2013, pp. 199-204.
  3. Cheon, S.S., Choi, J.H., and Lee, D.G., “Development of the Composite Bumper Beam for Passenger Cars,” *Composite Structures*, Vol. 32, No. 1-4, 1995, pp. 491-499.
  4. Belingardi, G., Beyene, A.T., and Koricho, E.G., “Geometrical Optimization of Bumper Beam Profile Made of Pultruded Composite by Numerical Simulation,” *Composite Structures*, Vol. 102, 2013, pp. 217-225.
  5. Kim, D.H., Kim, H.G., and Kim, H.S., “Design Optimization and Manufacture of Hybrid Glass/carbon Fiber Reinforced Composite Bumper Beam for Automobile Vehicle,” *Composite Structures*, Vol. 131, 2015, pp. 742-752.
  6. Jeong, C.H., Ham, S.W., Kim, G.S., 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. Maeng, J.W., Bang, S.W., and Jhun, M.S., “On the Use of Modified Adaptive Nearest Neighbors for Classification,” *The Journal of Applied Statistics*, Vol. 23, No. 6, 2010, pp. 1093-1102.
  8. Han, J.C., Kim, S.K., and Yoon, C.H., “A New Incremental Instance-Based Learning Using Recursive Partitioning,” *The KIPS Transactions : Part B*, Vol. 13B, No. 2, 2006, pp. 127-132.
  9. Nguyen, B., Morell, C., and De Baets, B., “Distance Metric Learning for Ordinal Classification Based on Triplet Constraints,” *Knowledge-Based Systems*, Vol. 142, 2018, pp. 17-28.
  10. Kwon, O.H., and Kang, J.W., “An Estimation of Deformation for Composites by DIC,” *Journal of the Korean Society for Power System Engineering*, Vol. 18, No. 4, 2014, pp. 78-84.
  11. Ham, S.W., Cho, J.U., and Cheon, S.S., “Load Fidelity Improvement of Piecewise Integrated Composite Beam by Irregular Arrangement of Reference Points,” *Composites Research*, Vol. 32, No. 5, 2019, pp. 216-221.
  12. Bai, Y., and Wierzbicki, T., “A New Model of Metal Plasticity and Fracture with Pressure and Lode Dependence,” *International Journal of Plasticity*, Vol. 24, No. 6, 2008, pp. 1071-1096.