

머신 러닝 기법을 이용한 PIC 범퍼 빔 설계 방법

함석우* · 지승민* · 전성식*[†]

The PIC Bumper Beam Design Method with Machine Learning Technique

Seokwoo Ham*, Seungmin Ji*, Seong S. Cheon*[†]

ABSTRACT: In this study, the PIC design method with machine learning that automatically assigning different stacking sequences according to loading types was applied bumper beam. The input value and labels of the training data for applying machine learning were defined as coordinates and loading types of reference elements that are part of the total elements, respectively. In order to compare the 2D and 3D implementation method, which are methods of representing coordinate value, training data were generated, and machine learning models were trained with each method. The 2D implementation method is divided FE model into each face and generating learning data and training machine learning models accordingly. The 3D implementation method is training one machine learning model by generating training data from the entire finite element model. The hyperparameter were tuned to optimal values through the Bayesian algorithm, and the k-NN classification method showed the highest prediction rate and AUC-ROC among the tuned models. The 3D implementation method revealed higher performance than the 2D implementation method. The loading type data predicted through the machine learning model were mapped to the finite element model and comparatively verified through FE analysis. It was found that 3D implementation PIC bumper beam was superior to 2D implementation and uni-stacking sequence composite bumper.

초 록: 본 연구에서는 머신 러닝을 통해 하중 유형에 따른 구간을 나누어 각 하중 유형에 강한 적층 각도 순서가 배치되는 PIC 설계 방법이 범퍼 빔에 적용되었다. 머신 러닝을 적용하기 위한 학습 데이터의 입력 값과 라벨은 각각 전체 요소 중 일부인 참조 요소의 좌표와 하중 유형으로 정의되었다. 좌표 값을 나타내는 방법인 2D 표현 방법과 3D 표현 방법을 비교하기 위하여 각각의 방법으로 학습 데이터 생성 및 머신 러닝 모델이 학습되었다. 2D 표현 방법은 유한요소 모델을 각 면으로 나누고 그에 따른 학습 데이터 생성 및 머신 러닝 모델을 학습시키는 방법이며, 3D 표현 방법은 유한요소 모델 전체에서 학습 데이터를 생성하여 하나의 머신 러닝 모델을 학습시키는 방법이다. 머신 러닝 모델의 성능에 영향을 미치는 하이퍼파라미터는 베이지안 알고리즘을 통해 최적 값으로 튜닝 되었으며, 튜닝 된 모델 중 k-NN 분류 방법이 가장 높은 예측률과 AUC-ROC로 나타났다. 그리고 2D 표현 방법과 3D 표현 방법 중 3D 표현 방법이 더 높은 성능을 보였다. 튜닝 된 머신 러닝 모델을 통해 예측된 하중 유형 데이터가 유한요소 모델에 매핑되었으며, 유한요소 해석을 통해 비교 검증되었다. 3D 표현 방법의 머신 러닝 모델로 설계된 PIC 방법이 강도 측면에서 더 우수함이 검증되었다.

Key Words: 머신 러닝(Machine Learning), 복합재료(Composite Materials), PIC (Piecewise Integrated Composite), 범퍼 빔(Bumper Beam)

1. 서 론

최근 전세계적으로 이상 기후를 방지하기 위한 탄소 배출 규제의 강화 및 에너지 사용 제고로 인한 자동차 경량화 연구에 대한 필요성이 대두되고 있다[1]. 그로 인하여 자동차 업계에서는 연비 향상, 전기 차량의 모터 시스템 그리고 부품 경량화 및 강도 향상 등에 대한 연구가 많이 진행되고 있다[2]. 경량화 소재로는 비철금속, 열가소성 플라스틱, 복합재료 등이 대표적으로 여겨지고 있으며, 특히 복합재료는 기존 재료보다 비강도, 비강성이 우수하여 광범위한 응용분야에 적용되고 있다. 특히, 자동차의 여러 부품에 복합재료를 적용하기 위한 연구가 활발하게 진행되고 있다. Cheon 등[3]은 승용차를 위한 새로운 유형의 하이브리드 복합재 범퍼 빔을 제안하고 유한요소해석을 수행하였으며, Belingardi 등[4]은 펄트루전(Pultrusion)으로 제조된 복합재료 범퍼 빔에 대해 수치해석으로 최적화된 단면 형상을 제안하였다. Kim 등[5]은 최적화된 자동차 하이브리드 복합재 범퍼 빔에 관한 연구를 진행하였다. 이처럼 복합재료 범퍼 빔에 대한 연구가 다양하게 시도되고 있으나, 범퍼 빔 전 영역에 단일 적층 각도 순서를 적용하는 것이 일반적이었다. Jeong 등 [6]은 범퍼 빔을 5개의 균등한 영역으로 나누어 인장, 압축, 전단의 하중 유형을 분석하고 하중 유형에 따라 복합재료의 적층 순서를 나누어 배열하여 구간조합 복합재료 범퍼 빔을 제안하였다. 또 유한요소 해석을 진행하여 하중 유형에 따라 적층 각도 순서 영역이 나누어진 범퍼 빔이 단일 적층 각도 순서를 적용한 범퍼 빔보다 최대 지지 하중 및 에너지 흡수율이 증가하는 것을 입증하였다. 하지만 임의로 5개의 균등한 구간을 나누어 하중 분석을 하였기 때문에 이에 대한 구간 최적화가 필요하다. Ham 등[7]은 머신 러닝(Machine Learning)을 적용하여 하중 유형에 따라 구간을 나누어 적층 각도 순서를 배치하는 PIC(Piecewise Integrated Composite) 기법을 제안하였으며, 단순 보에 적용시켜 PIC 설계 기법의 우수함을 입증하였다. Ji 등[8]은 PIC 로봇 암에 3차원 학습 데이터를 이용한 PIC 단순보의 강성에 대한 연구를 진행하였으며 학습 데이터의 3D 표현방법을 사용하는 것이 경쟁력이 있음을 확인하였다. 하지만 기존 연구들은 단순한 형상의 모델에 적용하였고, 복잡한 형상에서의 연구는 진행되지 않았다.

본 연구에서는 머신 러닝을 이용한 PIC 기법을 단순 보보다 복잡한 형상의 차량 전방 범퍼 빔에 대하여 적용되었다. 복잡한 형상에서 학습 데이터의 2D 표현 방법과 3D 표현 방법 중 경쟁력이 있는 방법을 확인하고자 두 방법에 대하여 차량의 전방 범퍼 빔에 적용되었으며, 유한요소해석을 통하여 비교 검증되었다.

2. 머신 러닝을 적용한 PIC 설계 방법

2.1 PIC 범퍼 빔으로의 머신 러닝 적용 방법

PIC 설계 기법은 하중 유형에 따라 적층 각도 순서를 다르게 하여 최대 지지 하중 및 에너지 흡수율을 높이는 방법이다. FE 모델에서 하중 유형 구간을 효율적으로 나누기 위하여 머신 러닝 알고리즘 중 분류(Classification) 기법이 사용되었다. 분류 기법은 학습데이터를 통해 주어진 데이터를 라벨(Label)별로 구별해내는 과정이며, 다양한 분류 알고리즘으로 학습을 시키고, 머신 러닝 모델을 생성시키는 방법이다[9]. 머신 러닝을 적용하여 PIC 범퍼 빔을 설계하기 위한 플로우 차트는 Fig. 1과 같으며, 우선 학습 데이터의 미가공 데이터(Raw Data)인 응력 삼축 특성값(Stress Triaxiality)을 얻기 위하여 알루미늄 물성이 적용된 IIHS 범퍼 빔 선행 유한요소해석이 진행되었다. 미가공 데이터는 전체 요소 중 일부 요소인 참조 요소(Reference Element)에서 취득된다. 미가공 데이터를 입력값과 라벨로 구성된 학습 데이터로 만들기 위하여, 참조 요소의 좌표 값은 입력값, 응력 삼축 특성값이 하중 유형 데이터로 변환되었다[10].

본 연구에서는 머신 러닝 알고리즘 중 Decision tree, SVM(Support Vector Machine) 그리고 k-NN 알고리즘 등이 있다. 각 알고리즘들은 고유의 하이퍼파라미터(Hyperparameter)를 가지고 있으며, 하이퍼파라미터에 의해 모델의 성능이 결정된다고 알려져 있다[11]. 머신 러닝 알고리즘은 학습 데이터를 통해 학습시키게 되면 머신 러닝 모델이 생성되며, 모델의 성능은 예측률과 ROC(Receiver Operation Characteristic)의 AUC(Area Under the Curve)를 통해 확인될 수 있으며, 예측률이 75% 이하일 경우, 하이퍼파라미터 튜닝을 통해 예측률을 75% 이상의 성능이 도출될 수 있도록 하였다.

2.2 학습 데이터의 구성 방법

머신 러닝 기법이 PIC 범퍼 빔 설계 방법에 적용되기 위하여 우선적으로 학습 데이터가 생성되어야 한다. 학습 데

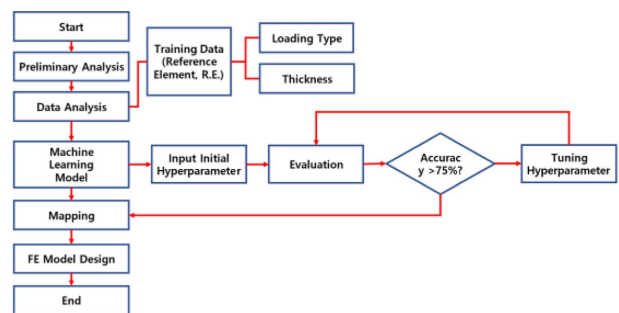


Fig. 1. Flowchart of PIC design with machine learning




Fig. 2. Preliminary FE analysis boundary condition




Fig. 3. Cross section of bumper beam

이터는 선형 유한요소해석을 통해 얻은 결과 값을 기반으로 만들어진다. 선형 유한요소해석 모델은 Fig. 2에 나타난 것처럼 IIHS 범퍼 충돌 해석이며 충돌 속도는 10 km/h이다. 범퍼 범 모델의 요소 수는 19,000개이며, 참조 요소 수는 전체 요소의 약 12.7%인 2,400개이며 배치는 규칙적으로 이루어졌다.

본 연구에서는 참조 요소의 좌표 값이 2D와 3D로 표현되었으며, 2D 표현 방법은 범퍼 범의 단면을 Fig. 3과 같이, Top Face, Bottom Face, Front Face, Rear Face, Chamfered Face, 그리고 Rib Face로 나누어 각 Face마다의 학습 데이터가 만들어지며, 그에 따라 머신 러닝 모델이 생성된다. 학습 데이터의 입력 값인 참조 요소의 좌표는 (x, y) 형태이며, 각 면의 하중 유형 특성을 잘 드러낼 수 있다는 장점이 있다. 3D 표현 방법은 2D 표현과 같이 면을 나누지 않고 전체 FE 모델에 참조 요소를 배치하여 학습 데이터가 생성되고, 그에 따라 하나의 머신 러닝 모델이 생성된다. 학습 데이터의 입력 값은 (x, y, z)로 나타나게 되며, 하나의 머신 러닝 모델을 이용하기 때문에 계산 시간을 줄일 수 있다는 장점이 있다.

2.3 머신 러닝 모델 및 하이퍼파라미터 최적화

본 연구에서는 Decision tree, SVM, k-NN 알고리즘이 사

용되었다. 결정 트리는 분류 규칙으로 노드(Node)가 분기되는 과정을 통해 데이터를 분류하는 모델이고, 하이퍼파라미터는 Maximum Number of Splits과 Splits Criterion이 있다[12]. SVM은 초평면(Hyperplane)을 통해 경계를 결정하여 데이터를 분류하는 모델이며, 하이퍼파라미터로는 kernel function, kernel scale, box constraint level, 그리고 multiclass method가 있다[13]. k-NN 알고리즘은 새로운 데이터를 입력 받았을 때, 해당 데이터와 가장 가까이 있는 k개의 학습 데이터를 통해 분류하는 모델이다. 하이퍼파라미터는 number of neighbors, distance metric, 그리고 distance weight가 있다[14].

각 모델들은 하이퍼파라미터 튜닝을 통하여 최적의 성능을 이끌어 낼 수 있다. 본 연구에서는 베이지안 최적화 알고리즘을 통해 하이퍼파라미터 튜닝이 이루어졌다. 획득 함수(Acquisition Function)는 예상 개선값-비용 가중-플러스가(Expected-Improvement-Per-Second-Plus)가 사용되었으며 반복 횟수는 500회이다[15]. 하이퍼파라미터 튜닝을 통해 최적의 성능을 갖게 된 머신 러닝 모델의 성능 지표는 예측률과 ROC-AUC를 통해 비교되었다. 2D 표현 방법과 3D 표현 방법의 예측률을 비교하기 위하여 2D 표현 방법의 머신 러닝 모델들의 예측률 평균과 3D 표현 방법의 예측률이 비교되었다. Table 1와 같이, 3D 표현 방법의 k-NN 모델이 예측률이 86.3%로 다른 모델보다 우수한 성능으로 나타났다. 우수한 성능을 나타낸 3D 표현 방법의 머신 러닝 모델의 ROC-AUC 값은 Table 2에 나타나져 있으며, ROC-AUC 값 또한 k-NN 분류 기법이 가장 우수하게 나타났다.

Table 1. Machine learning model predict rate

		Prediction Rate [%]		
Implementation		Decision Tree	SVM	k-NN
2D	Top	75.9	79.1	80.7
	Bot.	92.1	92.5	92.5
	Front	87.8	91.1	91.1
	Rear	96.5	96.5	96.5
	Chamfered	75.3	75.8	75.2
	Rib	77.7	80.4	81.1
	Avg.	84.2	85.9	86.0
3D		85.4	86.2	86.3

Table 2. ROC-AUC value of machine learning models

Machine Learning Model	Predict Rate [%]	AUC		
		Tension	Comp.	Shear
Decision Tree	85.4	0.95	0.94	0.80
SVM	86.2	0.96	0.94	0.62
k-NN	86.3	0.98	0.97	0.87

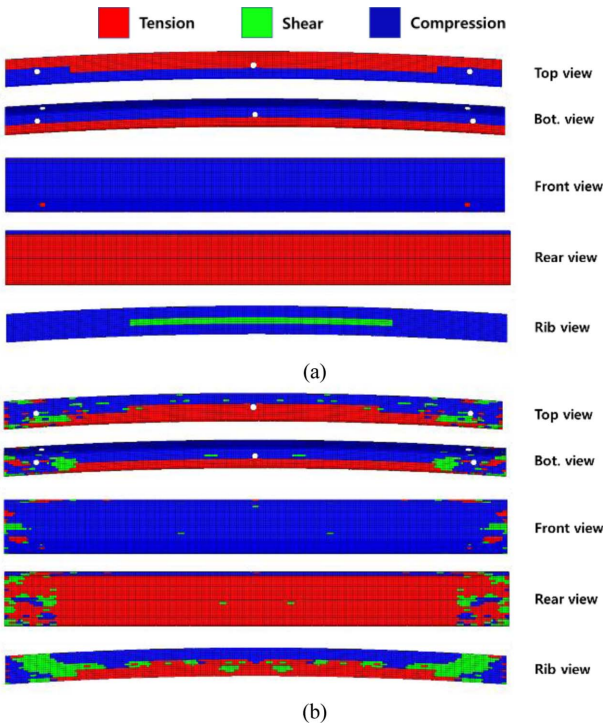


Fig. 4. PIC FE model: (a) 2D implementation, (b) 3D implementation

2.4 머신 러닝 적용 결과

우수한 성능으로 나타난 학습된 2D 및 3D 표현 k-NN 모델을 통해 선형 유한요소 모델의 요소 좌표에 대하여 하중 유형이 예측되었으며, 예측된 데이터는 유한요소 모델에 매핑되었다.

Fig. 4(a)와 (b)는 각각 2D 표현 방법과 3D 표현 방법으로 생성된 학습 데이터로 학습된 머신 러닝 모델로 예측된 데이터가 매핑된 유한요소 모델이다. 3D 표현 방법은 2D 표현과 달리 각 면이 연결된 부분에서 다른 면의 하중 유형의 영향을 받은 것을 예측하였다. 이는 3D 표현이 각 면 사이의 연결성이 있어서 다른 면에서의 하중 유형 영향도 고려되지만, 2D 표현은 고려되지 않는 것으로 사료된다.

3. PIC 설계 검증을 위한 유한요소해석

머신 러닝 기법이 적용된 범퍼 빔의 강도 향상을 검증하기 위하여 단일 적층 순서(Uni Stacking Sequence)로 모델링된 범퍼 빔이 PIC를 통해 모델링된 범퍼 빔과 비교되었다. 선형 유한요소해석과 동일한 조건의 해석이 진행되었다. 해당 범퍼 빔에 적용된 재료는 T700 Carbon fibre/2510이다[16]. 각 하중 유형에 대하여 강도가 높다고 알려진 적층 각도 순서는 Table 3에 나타나져 있으며, 해당 적층 각도 순서들은 하중 유형별로 매핑된 요소에 적용되었다[17].

해석 결과는 Fig. 5와 같이 Force-Displacement 선도로 나

Table 3. Stacking sequence of loading type

Loading Type	Stacking Sequence
T(Tension)	$[90/0/\bar{0}]_{6S}$
C(Compression)	$[\pm 5/\pm 45/90]_{3S}$
S(Shear)	$[0/0/90]_{15}$

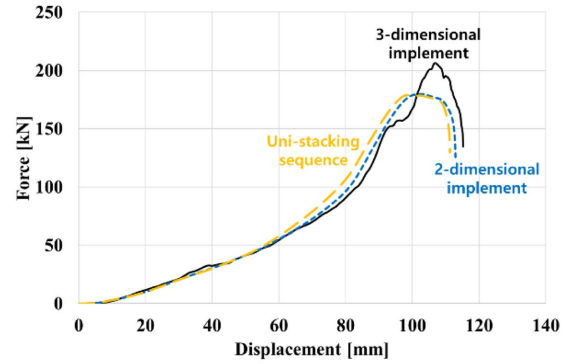


Fig. 5. Force-displacement curves

타냈으며, 3D 표현 방법으로 설계된 범퍼 빔의 최대 지지 하중은 약 206.2 kN으로 가장 높게 나타났고 2D 설계 기법과 단일 적층 순서로 모델링된 범퍼 빔 보다 각각 약 12.7%, 약 13.1% 높게 나타났다.

4. 결론

본 연구에서는 단순 보 보다 복잡한 형상의 차량 전방 범퍼 빔에 머신 러닝 기법을 이용한 PIC 설계 기법이 적용되었다. 학습 데이터의 2D 표현 방법과 3D 표현 방법을 중 경쟁력이 있는 방법을 확인하고자 범퍼 빔에 대하여 두 방법을 통한 PIC 설계 기법이 적용되어 설계되었다. 2D 표현 방법은 유한요소 모델을 각 면으로 나누어 학습 데이터를 생성하게 되며, 학습 데이터의 입력 값인 참조 요소의 좌표를 (x, y)로 나타낸다. 각 면의 하중 유형 특성을 잘 드러낼 수 있는 장점이 있다. 3D 표현 방법은 전체 요소에 대하여 학습 데이터가 생성되며 참조 요소의 좌표 값은 (x, y, z)의 형태이며, 하나의 머신 러닝 모델을 사용하기 때문에 모델링 시간을 줄일 수 있는 장점이 있다. 두 방법을 통하여 생성된 머신 러닝 모델들은 베이지안 알고리즘으로 하이퍼파라미터가 최적 값으로 튜닝되었다.

2D 표현 방법에서는 k-NN 분류 모델이 가장 우수한 성능으로 나타났으며, 3D 표현 방법 또한 k-NN 분류 모델이 가장 우수한 성능으로 나타났다. 2D 표현 방법과 3D 표현 방법의 성능을 비교하기 위하여, 2D 표현 방법을 이용한 머신 러닝 모델 평균 예측률과 3D 표현 방법을 이용한 머신 러닝의 예측률이 비교되었으며, 3D 표현 방법이 근소한 차이로 높은 성능으로 나타났다.

우수한 성능으로 나타난 머신 러닝 모델을 통해 매핑 된 결과에서 3D 표현 방법은 2D 표현 방법과 달리 각 면이 연결된 부분에서 다른 면의 하중 유형의 영향을 받는 것으로 예측되었으며, 이는 각 면 사이의 연결성이 있어 다른 면에서의 하중 유형 영향이 고려되는 것으로 사료된다.

2D 표현 방법과 3D 표현 방법이 적용된 범퍼 빔을 비교하기 위하여 선형 유한요소해석과 동일한 조건으로 유한요소해석이 진행되었으며, 3D 표현 방법이 적용된 범퍼 빔의 강도는 2D 표현 방법이 적용된 범퍼 빔 보다 약 12.7% 향상되었고, 단일 적층 각도 순서로 모델링 된 범퍼 빔보다 약 13.1% 향상되어 3D 표현 방법의 우수함이 검증되었다.

PIC 설계 기법으로 설계된 범퍼 빔이 단일 적층 각도 순서로 모델링 된 범퍼 빔과 유사한 강도로 설계된다면 경량화 역시 가능할 것이라고 사료된다. 유사한 강도로 설계를 하기 위해서는 범퍼 빔의 두께 역시 구간을 나누어 PIC를 적용하는 방법에 대한 연구가 필요할 것으로 보인다.

후 기

본 연구는 2018년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2018R1D1A1B07051169).

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, No. 1, 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. Ham, S.W., Cheon, S.S., and Jeong, K.Y., "Strength Optimization of Piecewise Integrated Composite Beam through Machine Learning," *Transactions of the KSME, A*, Vol. 43, No. 8, 2019, pp. 521-528.
8. Ji, S.M., Ham, S.W., Choi, J.K., and Cheon, S.S., "Stiffness E Enhancement of Piecewise Integrated Composite Beam using 3D Training Data Set," *Composites Research*, Vol. 34, No. 6, 2021, pp. 394-399.
9. Li, D., Gu, M., Liu, S., Sun, X., Gong, L., and Qian, K., "Continual Learning Classification Method with the Weighted K-nearest Neighbor Rule for Time-varying Data Space Based on the Artificial Immune System," *Knowledge-Based Systems*, Vol. 240, No. 15, 2022, 108145.
10. 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.
11. Shahhosseini, M., Hu, G., and Pham, H., "Optimizing Ensemble Weights and Hyperparameters of Machine Learning Models for Regression Problems," *Machine Learning with Applications*, Vol. 7, No. 15, 2022, 100251.
12. Liu, X., Liu, T.Q., and Feng, P., "Long-term Performance Prediction Framework Based on XGBoost Decision Tree for Pultruded FRP Composites Exposed to Water, Humidity and Alkaline Solution," *Composite Structures*, Vol. 284, No. 15, 2022, 115184.
13. Fayed, H.A., and Atiya, A.F., "Decision Boundary Clustering for Efficient Local SVM," *Applied Soft Computing*, Vol. 110, 2021, 107628.
14. Lee, S.H., Mazumder, J., Park, J.W., and Kim, S.G., "Ranked Feature-Based Laser Material Processing Monitoring and Defect Diagnosis Using k-NN and SVM," *Journal of Manufacturing Processes*, Vol. 55, 2020, pp. 307-316.
15. Fakhrmoosavi, F., Kamjoo, E., Kavianipour, M., Zockaie, A., Talebpour, and A., and Mittal, A., "A Stochastic Framework Using Bayesian Optimization Algorithm to Assess the Network-level Societal Impacts of Connected and Autonomous Vehicles," *Transportation Research Part C: Emerging Technologies*, Vol. 139, 2022, 103663.
16. Tsai, S.W., and Melo, J.D.D., "A Unit Circle Failure Criterion for Carbon Fiber Reinforced Polymer Composites," *Composites Science and Technology*, Vol. 123, No. 8, 2016, pp. 71-78.
17. 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.