

TypeIII 수소저장용기 가동 중 안전 검사를 위한 음향방출시험 기반 딥러닝 CFRP 소재 결함 분류

김다현[○], 황병일^{*}, 김정영^{*}, 김동주^{*}

[○]포항공과대학교 인공지능연구원

^{*}포항공과대학교 인공지능연구원

e-mail: kdhyun8011@postech.ac.kr[○], {bihwang, gy_kim, kkb0320}@postech.ac.kr^{*}

Deep Learning CFRP Failure Classification based on Acoustic Emission Testing for Safety Inspection during TypeIII Hydrogen Vessel Operation

Da-Hyun Kim[○], Byeong-Il Hwang^{*}, Gyeong-Yeong Kim^{*}, Dong-Ju Kim^{*}

[○]POSTECH Institute of Artificial Intelligence, Pohang University of Science and Technology,

^{*}POSTECH Institute of Artificial Intelligence, Pohang University of Science and Technology

● 요약 ●

최근 기후 변화가 심각해짐에 따라 수소 에너지에 대한 관심이 집중되고 있으며 이를 안전하게 운송/보관할 수 있는 용기에 대한 연구도 활발히 진행되고 있다. 특히 고압 가스를 저장하는 TypeIII 용기의 노후화 및 안전과 관련되어 결함을 인지하는 연구가 활발하다. 그러나 이 용기의 외각층을 이루는 CFRP 소재는 탄소 섬유와 에폭시 복합체 구조로 구성되어 결함별 탐지가 매우 어렵다. 본 논문에서는 음향방출시험과 딥러닝을 활용하여 CFRP 결함 데이터셋을 구축하고 이를 분류할 수 있는 모델을 제안한다. 특히 CFRP 시편을 직접 제작하여 AE 센서를 부착하고 파괴하여 파형 데이터를 수집하였다. 이후 표현 학습을 통해 데이터의 특징을 압축/추출하고 유사도를 비교해 결함별 데이터를 판별하는 알고리즘을 개발하였다. 구축된 데이터셋의 실루엣 계수는 0.86으로 높은 군집도를 보였다. 마지막으로 구축된 데이터셋을 실시간으로 분류할 수 있는 1D-CNN 딥러닝 모델을 개발하였으며 99.33%의 높은 분류 정확도를 보였다.

키워드: 음향방출(Acoustic Emission), 딥러닝(Deep Learning), 표현 학습(Representation Learning)

I. Introduction

최근 지구온난화 등으로 인해 기후 변화가 심각해짐에 따라 화석 연료 대체 에너지원으로 수소가 주목받고 있다. 그러나 수소는 주로 고압가스 형태로 저장 되어 폭발 위험이 있어 다양한 특수한 형태의 용기를 사용한다[1]. 이중 TypeIII 용기는 가벼우면서도 높은 압력을 견딜 수 있으며 안정성이 높아 향후 수소 연료 충전에 범용적으로 사용될 가능성이 높다. 한편 위험물을 고압으로 보관하는 만큼 결함 발생 시 위험성이 높아지므로 결함을 인지하는 것이 중요하다. 그러나 결함 확인을 위해 일반적으로 용기를 파괴하여 단면을 확인해야 하는 심각한 결함이 용기 가동 중 발생할 경우 폭발 위험이 높아지므로 비파괴 형식의 결함 검사 방법이 필요하다. 또 용기의 외부의 외각층 소재인 CFRP(Carbon Fiber Reinforced Polymer)는 탄소 복합체 적층 구조라 어떤 결함인지 파악하는 것이 어렵다. 따라서 비파괴 방식의 실시간 TypeIII 용기의 CFRP 결함 인지를 위한 새로운 방법이

필요하다. 본 논문에서는 음향방출시험과 딥러닝 기반의 CFRP 결함을 실시간으로 구분하는 방법을 제안한다.

II. Preliminaries

1. Backgrounds

1.1 TypeIII 용기와 CFRP 결함

TypeIII 수소 저장 용기는 금속으로 이루어진 내부 용기인 라이너와 겹을 둘러싸는 외각층으로 구분된다. 라이너는 알루미늄 또는 스테인리스강으로 이루어지며 외각층은 CFRP를 사용한다. CFRP란 탄소 섬유와 에폭시 수지를 섞어 견고하게 만든 탄소 복합체이다. 이를

여러 개 적층해 더욱 견고하게 만들어 외각층으로 사용한다. Fig. 1.은 TypeIII 수소 용기 구조와 적층 CFRP를 나타낸 것이다.




Fig. 1. (a) TypeIII Hydrogen Gas Storage (b) CFRP

TypeIII에서 발생하는 결함은 크게 라이너에서 발생하는 금속 결함과 외각층에서 발생하는 CFRP 결함으로 나눌 수 있다. 금속의 소재 특성이 분명해 결함 구별이 쉬우나 CFRP 결함은 다른 소재와 구조에서 발생해 구분이 어렵다. CFRP의 결함은 크게 단층 탄소 복합재의 에폭시에 균열이 생기는 기지 균열, 적층 접합제 에폭시에 균열이 생기며 층이 분리되는 층간 분리, 탄소 섬유가 끊어지는 섬유 파단 세 가지이다. Fig. 2.는 CFRP 각 결함 예시를 보인 것이다.




Fig. 2. CFRP Failure Modes : (a) 섬유 파단 (b) 기지 균열 (c) 층간 분리

1.2 음향방출 시험

음향방출시험(AET)이란 AE(Acoustic Emission) 센서를 물체 표면에 부착하여 방출되는 음향을 분석하는 기법이다. 이는 비파괴 분석이 가능해 가동 중 실시간 결함 분석에 적합하다. Fig. 3.은 수소 저장 용기에 AE 센서를 부착하고 방출 음향을 분석하는 예시를 나타낸 것이다.




Fig. 3. Hydrogen Gas Storage Failure Analyze with AET

2. Related Works

AET 기반 CFRP 결함 분류 관련 연구로는 파형의 주파수 특성을 분석하는 방법과 딥러닝으로 분류하는 방법으로 나뉜다. 이들 모두 CFRP 시편을 제작하고 AE 센서를 부착 후 인장 시험(Tensile Testing)으로 시편을 파괴하여 음향 데이터를 수집하여 분석한다. 전자는 주로 최대 주파수 성분(Peak Frequency)을 기준으로 결함을 구분한다[2]. 하지만 파형 특성상 데이터의 특성이 매우 다양해 단일 특성인 최대 주파수 성분만으로 정밀하게 구분하기는 적합하지 않다. 후자는 탄소 섬유 시편(C1)과 에폭시 시편(C2) 적층 CFRP(C3)를

만들어 파괴 음향 데이터를 수집해 딥러닝으로 이를 분류한다[3]. C1에서는 섬유 파단, C2에서는 기지 균열 데이터만 존재하나, C3에서는 모든 결함이 포함될 수 있다. 하지만 해당 연구는 단순 C1, C2, C3만을 구별해 세 가지 결함을 완벽하게 분리하였다고 볼 수 없다. 또 탄소 섬유, 에폭시 시편만으로 수집한 데이터는 복합재료인 CFRP의 섬유 파단 및 기지 균열과 특성과 차이가 있을 가능성이 높다. 따라서 정확한 결함 인지를 위해서는 CFRP의 각 결함을 완전히 분리할 수 있는 새로운 방법론이 필요하다.

III. The Proposed Scheme

1. Data Acquisition

CFRP 결함 데이터 수집을 위해 C1, C2, C3 시편을 제작하고 인장 시험으로 파괴하여 음향 방출 신호를 수집하였다. 또 에폭시만의 기지균열이 아닌 CFRP 내에서 발생한 기지 균열 데이터를 수집하고자 단층의 CFRP 시편(C4)도 제작했다. 센서는 IDK-AES-H150를 사용했으며 배경 노이즈를 배제하기 위해 30dB의 임계값을 초과하는 파형만 수집했다. Fig. 3.은 인장 시험 환경 그리고 센서 이미지를 나타낸 것이다. 또 Table 1.은 각 시편 예시와 수집된 데이터를 보인다.




Fig. 4. (a) Tensile Testing Environment (b) AE Sensor

Table 1. Specimens Image and Number of Wave Forms

시편 종류	이미지	이벤트 파형 수
탄소 섬유(C1)		16,709
에폭시(C2)		12,562
적층 CFRP(C3)		11,806
단층 CFRP(C4)		6,202

2. Data Labeling with Representation Learning

수집 데이터는 표현 학습(Representation Learning) 기반으로 특징을 압축/추출하고 유사도 비교를 통해 결함을 분리했다. 표현 학습 기법으로는 오토인코더(Autoencoder)를 활용했다. Fig. 5.은 표현 학습을 통한 특징 추출과 유사도 비교 기반 결함 판별 알고리즘을 나타낸 것이다.

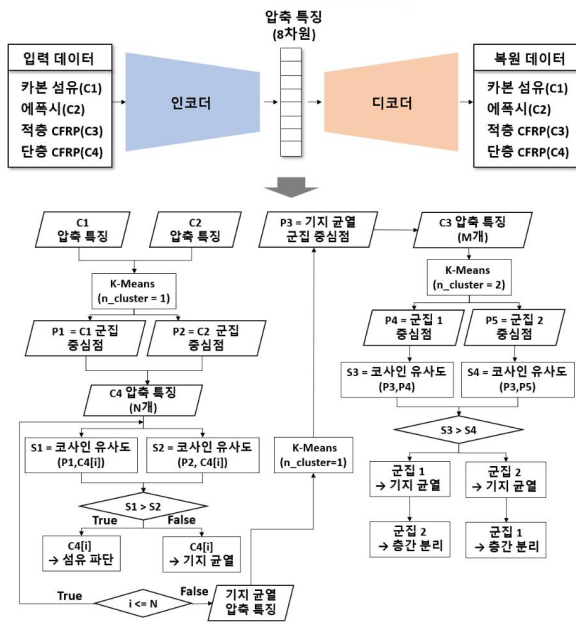


Fig. 5. Feature Extraction by Autoencoder and Failure Discrimination Algorithm

오토인코더는 데이터를 원본과 같은 형태로 복원하는 과정에서 특징을 압축한다. 압축 특징을 분석할 경우 원본 데이터에 비해 중요 특징만으로 결함을 분석할 수 있다. 그러나 파형 데이터는 음수 값을 포함되어 오토인코더 복원 성능이 저하되어 원활한 압축이 어렵다. 또 파형은 값들의 편차가 커 복원이 어렵다. 따라서 FFT(Fast Fourier Transform)로 주파수 스펙트럼을 구축하고 복원하도록 학습시켰다. Fig. 6. 는 파형 데이터와 주파수 스펙트럼 데이터의 예시를 보인다.




Fig. 6. (a) Wave Form (b) Frequency Spectrum

데이터셋에서 결합별로 분리하기 위해 먼저 C1, C2 시편의 특징 데이터를 추출해 이들의 군집 중심점(P1, P2)을 K-Means 클러스터링 알고리즘을 통해 계산한다. 그리고 C4 데이터셋의 압축된 특징 데이터를 추출하여 각 특징 벡터(C4[i])와 P1, P2와의 코사인 유사도를 계산한다. 해당 특징 벡터가 P1과 유사도가 더 높을 경우 섬유 파단으로 분류하고 반대의 경우 지지 균열로 분류하였다. 이후 C3 데이터에서도 유사도를 기반으로 에폭시 소재 결합을 구분하였다. 다만 적층 CFRP에서는 지지 균열, 층간 분리 두 가지 에폭시 소재 결합이 모두 발생해 이를 분리할 필요가 있다. 따라서 C3 데이터에서 에폭시로 구분된 데이터에 K-Means 클러스터링을 적용하여 두 가지 군집으로 나누고 중심점을 구하였다(P4, P5). 그리고 앞선 C4 데이터에서 지지 균열로 판정된 특징 벡터 군집 중심점(P3)을 계산하여 P4, P5와 코사인 유사도를 비교하여 높은 값을 가지는 군집을 지지 균열로, 다른 군집을 층간 분리로 판별하였다. 이 알고리즘을 통해 분리한 세 결합의 실루엣 계수는 0.86으로 높은 군집 수준을 보였다. Fig.

7.은 탄소 섬유와 에폭시 특징 벡터와 각 중심점 그리고 단층/적층 CFRP 결합별 특징 벡터를 T-SNE를 통해 2차원으로 시각화 한 것이다[4]. 또 Table. 2.는 위 알고리즘으로 구분된 결합 데이터의 수를 나타낸다.




Fig. 7. (a) Caborn Fiber and Epoxy (b) Prepreg CFRP (c) Laminated CFRP

Table 2. CFRP Failure Data

결함 종류	데이터 수
섬유 파단	16,268
지지 균열	1,408
층간 분리	318

3. 1D-CNN CFRP Failure Classification Model

구축된 데이터셋을 기반으로 실시간 결합 인지를 할 수 있도록 딥러닝 기반 CFRP 결합 분류 모델을 개발하였다. 이 모델은 시계열 데이터 분석에 적합한 Dilated Causal 1D-CNN(Convolution Neural Network) 구조를 기반으로 개발하였다. 3:1:1의 비율로 학습/검증/테스트 데이터셋을 분할하였으며 결합 간의 데이터 수 불균형이 심해 SMOTE 알고리즘을 통해 훈련 데이터셋을 증강했다[5]. Fig. 8.은 개발된 Dilated Causal 1D-CNN CFRP 결합 분류 모델 구조를 보인 것이다. Table. 3은 증강된 학습 데이터셋과 검증 및 테스트 데이터셋 수를 나타낸다.

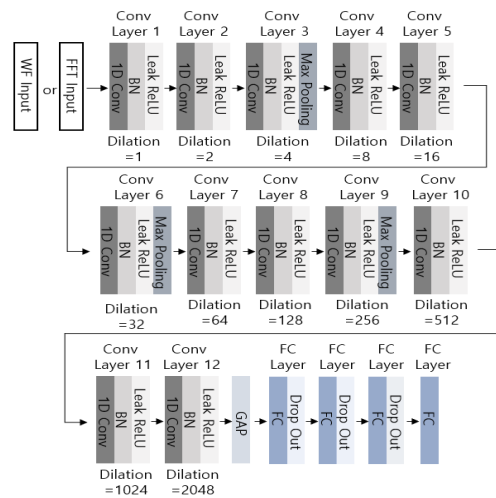


Fig. 8. CFRP Failure Classification Model Structure

Table 3. Train and Validation/Test Dataset

결함 종류	훈련 데이터 수		검증 데이터	테스트 데이터
	증강 전	증강 후		
섬유 파단	9,768	9,768	3,257	3,257
기지 균열	844	9,768	282	282
층간 분리	190	9,768	64	64

학습된 모델을 테스트 한 결과 99.33%의 높은 분류 정확도를 분석하였다. 각 결함별로 재현율(Recall)은 섬유 파단 99.79%, 기지 균열 99.82%, 층간 분리 81.25%를 달성하였다. 층간 분리의 경우 학습할 데이터셋이 너무 적어 다른 두 결함에 비해 분류 성능이 다소 부족한 것으로 분석된다. Fig. 9. 테스트셋에 대한 혼동 행렬 (Confusion Matrix)를 나타낸다.



Fig. 9. Confusion Matrix for Test Dataset

IV. Conclusions

본 연구에서는 TypeIII 수소 저장 용기 담라닝을 기반으로 외각층 CFRP 소재에서 발생하는 결함을 구분해 데이터셋을 구축하였다. 또 구축된 데이터셋을 기반으로 1-D CNN 기반의 실시간 CFRP 소재 결함 분류 모델을 구축하였다. 향후 개발된 알고리즘을 통해 TypeIII 수소 저장 용기의 안전 검사에 활용될 수 있기를 기대한다.

ACKNOWLEDGEMENT

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업이며 (No.2022R1A6A1A03052954), 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신산업진흥원(S0443-23-1005, AI 기반 균열 진단 SW 개발을 통한 노후 건축물 안전진단 서비스 사업화)의 지원을 받아 수행된 연구임.

REFERENCES

- [1] Barthélémy, H. (2012). Hydrogen storage-Industrial perspectives. *International journal of hydrogen energy*, 37(22), 17364-17372.
- [2] Gutkin, R., Green, C. J., Vangrattanachai, S., Pinho, S. T., Robinson, P., & Curtis, P. T. (2011). On acoustic emission for failure investigation in CFRP: Pattern recognition and peak frequency analyses. *Mechanical systems and signal processing*, 25(4), 1393-1407.
- [3] Guo, F., Li, W., Jiang, P., Chen, F., & Liu, Y. (2022). Deep Learning Approach for Damage Classification Based on Acoustic Emission Data in Composite Materials. *Materials*, 15(12), 4270.
- [4] Van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9(11).
- [5] Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.