



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0077916
(43) 공개일자 2024년06월03일

(51) 국제특허분류(Int. Cl.)
G01N 29/14 (2006.01) G01N 29/06 (2006.01)
G01N 29/44 (2006.01) G06N 3/08 (2023.01)
(52) CPC특허분류
G01N 29/14 (2013.01)
G01N 29/069 (2013.01)
(21) 출원번호 10-2022-0160319
(22) 출원일자 2022년11월25일
심사청구일자 2022년11월25일

(71) 출원인
포항공과대학교 산학협력단
경상북도 포항시 남구 청암로 77 (지곡동)
(72) 발명자
김호연
경상북도 포항시 남구 청암로 77
김경영
경상북도 포항시 남구 청암로 77
(뒷면에 계속)
(74) 대리인
특허법인(유한)아이시스


전체 청구항 수 : 총 13 항

(54) 발명의 명칭 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법 및 분석장치

(57) 요약

압력 용기의 결함 유형을 분류하는 분석 장치는 타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 인터페이스 장치, 압력 용기에서 측정되는 AE 신호 데이터 또는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 입력받아 압력 용기의 결함 유형을 분류하는 딥러닝 모델을 저장하는 저장장치 및 상기 입력되는 AE 신호 데이터 또는 상기 입력되는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 상기 딥러닝 모델에 입력하고, 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 연산장치를 포함한다.

대표도 - 도4



(52) CPC특허분류

G01N 29/4481 (2013.01)

G06N 3/08 (2023.01)

G01N 2291/0289 (2013.01)

G01N 2291/2695 (2013.01)

(72) 발명자

김다현

경상북도 포항시 남구 청암로 77

김동주

경상북도 포항시 남구 청암로 77

이 발명을 지원한 국가연구개발사업

과제고유번호	1415180518
과제번호	20202910100070
부처명	산업통상자원부
과제관리(전문)기관명	한국에너지기술평가원
연구사업명	에너지안전관리핵심기술개발
연구과제명	수소 충전소용 고압 저장용기 안전검사를 위한 AET 기반 가동 중 진단 시스템 및 안전검사 기준 개발
기여율	70/100
과제수행기관명	주식회사 아이디케이
연구기간	2020.05.31 ~ 2022.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1345354019
과제번호	2022R1A6A1A03052954
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	이공학학술연구기반구축
연구과제명	인공지능연구원
기여율	30/100
과제수행기관명	포항공과대학교
연구기간	2022.06.01 ~ 2023.02.28

명세서

청구범위

청구항 1

분석장치가 타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 단계;

상기 분석장치가 상기 AE 신호 데이터를 변환하여 2차원 이미지 데이터를 생성하는 단계;

상기 분석장치가 상기 이미지 데이터를 사전에 학습한 딥러닝 모델에 입력하는 단계; 및

상기 분석장치가 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 단계를 포함하는 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 2

제1항에 있어서,

상기 타깃 압력 용기는 수소 저장 용기이고,

상기 타깃 압력 용기는 금속, 알루미늄 및 플라스틱 중 하나의 소재로 구성되는 라이너(liner) 및 CFRP(Carbon Fiber Reinforced Plastic)로 구성되는 외곽층을 포함하는 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 3

제1항에 있어서,

상기 분석장치가

상기 AE 신호 데이터에 STFT(Short-Time Fourier Transform)를 하여 상기 이미지 데이터인 스펙트로그램 데이터를 생성하거나,

상기 AE 신호 데이터에 CWT(Continuous Wavelet Transform)를 하여 상기 이미지 데이터인 스케일로그램 데이터를 생성하는 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 4

제1항에 있어서,

상기 딥러닝 모델은 상기 타깃 압력 용기와 동일한 구조의 압력 용기의 외곽층 소재에 대하여 인장력을 높여가면서 측정되는 AE 신호 데이터 및 상기 외곽층 소재의 결함 상태를 이용하여 학습되고,

상기 딥러닝 모델은 정상, 층간 전단, 기지 균열 및 층간 분리 중 어느 하나로 상기 결함 유형을 예측하는 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 5

제1항에 있어서,

상기 AE 신호 데이터 상기 타깃 압력 용기에서 다수의 지점에 배치된 AE 센서들로부터 측정된 신호 데이터들을 결합한 데이터인 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 6

분석장치가 타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 단계;

상기 분석장치가 상기 AE 신호 데이터를 사전에 학습한 딥러닝 모델에 입력하는 단계; 및

상기 분석장치가 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 단계를 포함하되,

상기 딥러닝 모델은 상기 타깃 압력 용기와 동일한 구조의 압력 용기의 외곽층 소재에 대하여 인장력을 높여가면서 측정되는 AE 신호 데이터 및 상기 외곽층 소재의 결함 상태를 이용하여 학습되고,

상기 결함 유형은 정상, 층간 전단, 기지 균열 및 층간 분리 중 어느 하나인 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 7

제6항에 있어서,

상기 타깃 압력 용기는 수소 저장 용기이고,

상기 타깃 압력 용기는 금속, 알루미늄 및 플라스틱 중 하나의 소재로 구성되는 라이너(liner) 및 CFRP(Carbon Fiber Reinforced Plastic)로 구성되는 외곽층을 포함하는 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 8

제6항에 있어서,

상기 AE 신호 데이터 상기 타깃 압력 용기에서 다수의 지점에 배치된 AE 센서들로부터 측정된 신호 데이터들을 결합한 데이터인 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법.

청구항 9

타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 인터페이스 장치;

압력 용기에서 측정되는 AE 신호 데이터 또는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 입력받아 압력 용기의 결함 유형을 분류하는 딥러닝 모델을 저장하는 저장장치; 및

상기 입력되는 AE 신호 데이터 또는 상기 입력되는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 상기 딥러닝 모델에 입력하고, 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 연산장치를 포함하는 압력 용기의 결함 유형을 분류하는 분석 장치.

청구항 10

제9항에 있어서,

상기 타깃 압력 용기는 수소 저장 용기이고,

상기 타깃 압력 용기는 금속, 알루미늄 및 플라스틱 중 하나의 소재로 구성되는 라이너(liner) 및 CFRP(Carbon Fiber Reinforced Plastic)로 구성되는 외곽층을 포함하는 압력 용기의 결함 유형을 분류하는 분석 장치.

청구항 11

제9항에 있어서,

상기 연산장치는

상기 입력되는 AE 신호 데이터에 STFT(Short-Time Fourier Transform)를 하여 상기 이미지 데이터인 스펙트로그램 데이터를 생성하거나,

상기 입력되는 AE 신호 데이터에 CWT(Continuous Wavelet Transform)를 하여 상기 이미지 데이터인 스케일로그램 데이터를 생성하는 압력 용기의 결함 유형을 분류하는 분석 장치.

청구항 12

제9항에 있어서,

상기 딥러닝 모델은 상기 타깃 압력 용기와 동일한 구조의 압력 용기의 외곽층 소재에 대하여 인장력을 높여가면서 측정되는 AE 신호 데이터 및 상기 외곽층 소재의 결함 상태를 이용하여 학습되고,

상기 딥러닝 모델은 정상, 층간 전단, 기지 균열 및 층간 분리 중 어느 하나로 상기 결함 유형을 예측하는 압력

용기의 결함 유형을 분류하는 분석 장치.

청구항 13

제9항에 있어서,

상기 AE 신호 데이터 상기 타깃 압력 용기에서 다수의 지점에 배치된 AE 센서들로부터 측정된 신호 데이터들을 결합한 데이터인 압력 용기의 결함 유형을 분류하는 분석 장치.

발명의 설명

기술 분야

[0001] 이하 설명하는 기술은 압력 용기의 결함을 진단하는 기법에 관한 것이다.

배경 기술

[0002] 수소는 깨끗하고 효율적이며 재생이 가능한 특성으로 인하여 주목받는 에너지원이다. 수소는 작은 분자로 쉽게 누출될 수 있고 다른 물질과 결합 시 큰 폭발을 일으킬 수 있기 때문에 안전한 저장 및 관리가 필요하다.

[0003] 음향방출시험(Acoustic Emission Testing, AET)은 AE 센서를 표면에 부착하여 물체의 표면에서 발생하는 진동 데이터를 이용하여 용기의 결함을 진단하는데 활용될 수 있다.

선행기술문헌

특허문헌

[0004] (특허문헌 0001) 한국등록특허 제10-2457361호

발명의 내용

해결하려는 과제

[0005] 충전 AE 센서 기반의 결함 진단 방식은 신호 에너지, 피크 주파수, 진폭, 상승 시간(Rise Time), 신호 길이(Duration), 신호 횟수 등과 같은 신호 특성 파라미터를 이용한다. 한편, 고압 수소 저장 용기는 철강, 알루미늄, 나일론(Nylon), 에폭시(Epoxy) 및 탄소섬유강화플라스틱(Carbon Fiber Reinforced Plastic, CFRP) 등 다양한 소재로 구성된다. 고압 수소 저장 용기는 충전 AE 센서 기반의 결함 진단 방식을 적용하여 정확한 진단을 하기 어렵다. 고압 수소 저장 용기에서 수집하는 AET 신호는 여러 소재로부터 중첩되어 분석에 적절하지 않기 때문이다.

[0006] 이하 설명하는 기술은 고압 수소 저장 용기와 같은 압력 용기에 대한 결함 진단 기법을 제공하고자 한다.

과제의 해결 수단

[0007] 딥러닝 모델을 이용하여 압력 용기의 결함 유형을 분류하는 방법은 분석장치가 타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 단계, 상기 분석장치가 상기 AE 신호 데이터를 변환하여 2차원 이미지 데이터를 생성하는 단계, 상기 분석장치가 상기 이미지 데이터를 사전에 학습한 딥러닝 모델에 입력하는 단계 및 상기 분석장치가 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 단계를 포함한다.

[0008] 압력 용기의 결함 유형을 분류하는 분석 장치는 타깃 압력 용기에서 측정된 AE(Acoustic Emission) 신호 데이터를 입력받는 인터페이스 장치, 압력 용기에서 측정되는 AE 신호 데이터 또는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 입력받아 압력 용기의 결함 유형을 분류하는 딥러닝 모델을 저장하는 저장장치 및 상기 입력되는 AE 신호 데이터 또는 상기 입력되는 AE 신호 데이터를 변환하여 생성되는 이미지 데이터를 상기 딥러닝 모델에 입력하고, 상기 딥러닝 모델이 출력하는 정보에 따라 상기 타깃 압력 용기의 결함 유형을 분류하는 연산 장치를 포함한다.

발명의 효과

[0009] 이하 설명하는 기술은 복합적 소재로 구성된 압력 용기에서 수집한 AE 신호 데이터를 해석하는 기계 학습 모델을 이용하여 정확하게 용기의 결함을 진단한다.

도면의 간단한 설명

- [0010] 도 1은 압력 용기의 결함을 진단하는 시스템에 대한 예이다.
- 도 2는 AE 신호 데이터의 후처리 과정에 대한 예이다.
- 도 3은 AE 신호 데이터 유형에 따라 압력 용기의 결함 유형을 분류하는 딥러닝 모델에 대한 예이다.
- 도 4는 압력 용기의 결함 유형 추론 과정에 대한 예이다.
- 도 5는 압력 용기의 결함 유형을 분류하는 분석장치에 대한 예이다.

발명을 실시하기 위한 구체적인 내용

- [0011] 이하 설명하는 기술은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다. 그러나, 이는 이하 설명하는 기술을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 이하 설명하는 기술의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.
- [0012] 제1, 제2, A, B 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 해당 구성요소들은 상기 용어들에 의해 한정되지는 않으며, 단지 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 이하 설명하는 기술의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. 및/또는 이라는 용어는 복수의 관련된 기재된 항목들의 조합 또는 복수의 관련된 기재된 항목들 중의 어느 항목을 포함한다.
- [0013] 본 명세서에서 사용되는 용어에서 단수의 표현은 문맥상 명백하게 다르게 해석되지 않는 한 복수의 표현을 포함하는 것으로 이해되어야 하고, "포함한다" 등의 용어는 설명된 특징, 개수, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함을 의미하는 것이지, 하나 또는 그 이상의 다른 특징들이나 개수, 단계 동작 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 배제하지 않는 것으로 이해되어야 한다.
- [0014] 도면에 대한 상세한 설명을 하기에 앞서, 본 명세서에서의 구성부들에 대한 구분은 각 구성부가 담당하는 주기능 별로 구분한 것에 불과함을 명확히 하고자 한다. 즉, 이하에서 설명할 2개 이상의 구성부가 하나의 구성부로 합쳐지거나 또는 하나의 구성부가 보다 세분화된 기능별로 2개 이상으로 분화되어 구비될 수도 있다. 그리고 이하에서 설명할 구성부 각각은 자신이 담당하는 주기능 이외에도 다른 구성부가 담당하는 기능 중 일부 또는 전부의 기능을 추가적으로 수행할 수도 있으며, 구성부 각각이 담당하는 주기능 중 일부 기능이 다른 구성부에 의해 전담되어 수행될 수도 있음은 물론이다.
- [0015] 또, 방법 또는 동작 방법을 수행함에 있어서, 상기 방법을 이루는 각 과정들은 문맥상 명백하게 특정 순서를 기재하지 않은 이상 명기된 순서와 다르게 일어날 수 있다. 즉, 각 과정들은 명기된 순서와 동일하게 일어날 수도 있고 실질적으로 동시에 수행될 수도 있으며 반대의 순서대로 수행될 수도 있다.
- [0016] 이하 설명하는 기술은 압력 용기(pressure vessel)에 대한 결함을 진단하는 기법에 관한 것이다.
- [0017] 압력 용기는 화학 공장의 탭류, 반응기, 열교환기, 저장 용기 및 공기압축기 등에서 활용되는 용기로서 내부에 액화 가스 내지 압축 가스를 저장한다. 압력 용기는 관련 법규정에서 내부 물질에 따라 일정한 압력을 초과하는 압력을 받는 용기이다.
- [0018] 수소 압력 용기는 다양한 재질로 구성될 수 있다. 예컨대, 수소 압력 용기는 라이너(liner)와 외곽층으로 구성될 수 있다. 라이너는 대부분 금속, 알루미늄, 플라스틱(수지)과 같은 단일 소재로 구성된다. 외곽층은 압력 용기의 내부에서 발생하는 팽창력에 의한 변형 및 파손을 방지하기 위하여 탄소 및 유리 섬유가 적용된 복합 소재(CFRP)가 주로 사용된다.
- [0019] 연구자는 고압 수소 저장 용기를 기준으로 결함 진단을 연구하였다. 따라서, 이하 수소 압력 용기를 중심으로 설명하지만, 이하 설명하는 기술이 용기 내용물이나 용기 구조에 제한되지 않는다.

- [0020] 이하 설명하는 기술은 압력 용기에 부착된 센서에서 수집한 센싱 데이터를 기준으로 압력 용기의 결함을 진단한다.
- [0021] 이하 설명하는 기술은 기계 학습 모델을 이용하여 센싱 데이터를 분석하고, 분석 결과에 따라 압력 용기의 결함을 진단(분류)할 수 있다.
- [0022] 한편, 기계 학습 모델은 결정 트리, RF(random forest), KNN(K-nearest neighbor), 나이브 베이즈(Naive Bayes), SVM(support vector machine), ANN(artificial neural network) 등이 있다. DNN(deep learning network)은 대표적인 ANN 중 하나이다. DNN은 다양한 유형의 모델이 연구되었다. 예컨대, DNN은 CNN(Convolutional Neural Network), RNN(Recurrent Neural Network), RBM(Restricted Boltzmann Machine), DBN(Deep Belief Network), GAN(Generative Adversarial Network), RL(Relation Networks) 등이 있다.
- [0024] 도 1은 압력 용기의 결함을 진단하는 시스템(100)에 대한 예이다. 시스템(100)은 AE 센서(110), 프리앰프 및 필터(Pre-amplifier and Filter, 120), AE 신호 프로세서(130), 저장장치(140) 및 분석장치(150)를 포함할 수 있다.
- [0025] 압력 용기 V는 적어도 하나의 AE 센서가 부착된다. 연구자는 복수의 VE 센서를 부착하여 데이터를 수집하였다. 따라서 AE 센서(110)는 압력 용기 V에서 사전에 결정된 특정 지점들에 부착된 복수의 AE 센서들로 구성될 수 있다. 연구자는 고압 수소 저장용기의 실린더 부위에 120° 간격으로 라인에 따라 3개의 AE 센서들을 배치하였고, 보스부 부위의 전면 및 후면에 각각 1개의 AE 센서들을 배치하였다. 한편, 실린더 부위에 배치되는 AE 센서의 수는 변경될 수 있지만, 각 라인 사이의 간격은 같아야 한다.
- [0026] 프리앰프 및 필터(120)는 AE 신호를 증폭하고, 해당 신호에서 잡음(배경 신호)을 제거할 수 있다. 즉, 프리앰프 및 필터(120)는 AE 신호 데이터에 대하여 일정한 전처리를 수행할 수 있다.
- [0027] AE 신호 프로세서(130)는 수집된 AE 신호 데이터를 신호에 대한 파라미터 및 신호 파형 정보를 기준으로 데이터를 구분할 수 있다. 파라미터는 신호 에너지, 피크 주파수, 진폭, 상승 시간, 신호 길이, 신호 횟수 등을 포함할 수 있다. 한편, 저장장치(140)는 구분된 AE 신호 데이터를 저장할 수 있다.
- [0028] AE 신호 프로세서(130)는 AE 신호 데이터에 대하여 일정한 후속 처리를 할 수 있다. AE 신호 프로세서(130)는 AE 신호 데이터에 대하여 일정한 변환을 할 수 있다. 예컨대, AE 신호 프로세서(130)는 AE 신호 데이터를 스펙트로그램과 같은 데이터로 변화할 수 있다.
- [0029] 분석장치(150)는 수집된 AE 신호 데이터를 이용하여 압력 용기 V의 결함 여부 내지 결함 유형을 분류할 수 있다. 분석장치(150)는 딥러닝 모델을 이용하여 압력 용기에서 수집한 AE 신호 데이터를 분석한다.
- [0031] 연구자가 딥러닝 모델을 구축하는 과정을 설명한다.
- [0032] 연구자는 수소 압력 용기의 CFRP 샘플들에 대한 인장 시험(tensile test)을 수행하면서 학습 데이터를 수집하였다. CFRP에 인장력이 지속적으로 가해지면, CFRP 층이 평행하게 미끄러지기 시작하고 섬유 사이의 매트릭스가 끊어져 계층 간의 결합이 분리되고 결국 샘플이 파괴된다. 연구자는 인장력을 받는 CFRP의 상태를 변화의 시간 및 로드(load)를 기준으로 (i) 정상, (ii) 층간 전단(interlaminar shear), (iii) 기지 균열(matrix cracking) 또는 (iv) 층간 분리(delamination)로 구분(라벨링)하였다. 연구자는 CFRP에 대한 인장 시험에서 AE 신호 데이터를 측정하였다. 연구자는 아래 표 1과 같이 AET에서 측정된 시간 간격 및 이벤트 빈도를 기준으로 결함 유형을 구분하였다. 여기서 이벤트는 변형 또는 크랙 진행을 의미한다.
- [0033] 한편, 연구자는 AET 과정 중 발생된 파형 데이터 결함 유형에 대해 이벤트 발생 빈도 수와 용기에 가해진 압력 그래프가 동시에 변화하는 시점을 기준으로 라벨링 작업을 수행하였다. 연구자는 라벨링 수행 후 라벨별 데이터 수 비율이 차이가 날 경우 시간 축 이동(Time-Shifting), SMOTE(Synthetic Minority Over-sampling Technique) 등과 같은 데이터 증강 기법을 통해 학습 데이터를 증강하였다. 또한, 연구자는 AE 센서로부터 수집된 파형 신호의 경우 AE 센서의 설정 환경에 따라 수집한 파형 데이터의 길이와 샘플링 주파수가 다를 수 있어 이를 보정하기 위한 후처리 작업을 수행하였다. 후처리 작업은 샘플링 주파수 동기화를 위한 리샘플링, 데이터의 스케일을 맞추기 위한 데이터 정규화 및 이상치 데이터 제거 작업을 포함할 수 있다.

표 1

Defect type	Normal	Interlaminar sheer	Matrix crack	Delamination
Time interval(s)	0-124	125-359	160-1,369	1,370 -
Event Counts	1,820	44,412	90,248	5,620

[0035]

[0037]

[0038]

[0039]

[0040]

[0041]

[0042]

[0043]

[0045]

[0046]

[0047]

학습 데이터는 입력 데이터 및 라벨값 쌍으로 구성된다.

입력 데이터는 AE 신호 데이터 또는 AE 신호 데이터를 후처리한 데이터를 이용할 수 있다. AE 신호 데이터는 복수의 AE 센서로부터 수집된 데이터를 이용할 수 있다. 이 경우, AE 신호 데이터는 복수의 AE 센서로부터 수집한 데이터를 결합한 형태일 수 있다.

입력 데이터는 특정 압력 용기에서 수집한 AE 신호 데이터를 후처리하여 다양한 유형의 데이터로 마련될 수 있다. 학습 데이터 마련 및 딥러닝 모델의 학습은 학습 장치가 수행한다고 설명한다. 학습 장치는 데이터 처리 및 연산이 가능한 컴퓨터 장치이다.

연구자는 AE 신호 데이터를 기준으로 3개의 유형의 데이터를 학습에 사용하였다. 학습 데이터의 유형은 웨이브폼 데이터(waveform data), 스펙트로그램 데이터(spectrogram data) 및 스케일로그램 데이터(scalogram data)이다.

입력 데이터는 전술한 바와 같이 인장 시험을 통하여 산출하였다. 학습 장치는 특정 압력 용기를 대상으로 AE 신호 데이터를 수집하였다. 입력 데이터는 특정 압력 용기에서 수집한 AE 신호 데이터 및 AE 신호 데이터를 후처리한 데이터이다. 도 2는 AE 신호 데이터의 후처리 과정에 대한 예이다. 웨이브폼 데이터는 AE 센서로부터 측정되는 일차원 시계열 데이터이다. 따라서, 학습 장치는 AE 센서에서 수집된 AE 신호 데이터에서 잡음 제거와 같은 전처리만을 수행하여 웨이브폼 데이터를 산출할 수 있다. 학습 장치는 웨이브폼 데이터에 대한 STFT(Short-Time Fourier Transform)를 수행하여 스펙트로그램 데이터를 산출할 수 있다. 학습 장치는 웨이브폼 데이터에 대한 CWT(Continuous Wavelet Transform)를 수행하여 스케일로그램 데이터를 산출할 수 있다. STFT 및 CWT는 시간 도메인의 웨이브폼 데이터를 주파수 도메인의 데이터로 변환한다. STFT 및 CWT는 2차원 이미지 형태로 변환한다.

한편, AE 신호 데이터의 유형에 따라 연구자는 서로 다른 유형의 딥러닝 모델을 사용하였다. 1-D(dimension) CNN은 웨이브폼 데이터를 입력받아 결합 유형을 분류한다. 2-D CNN은 2차 데이터인 스펙트로그램 데이터 및 스케일로그램 데이터를 입력받아 결합 유형을 분류한다.

학습 과정에서 이용하는 라벨값은 인장 시험을 통하여 산출된다. 전술한 바와 같이 라벨값은 특정 용기에서 인장력을 높여가면서 수집되는 AE 신호 데이터에 대응되는 결합 유형이다. 라벨값은 정상, 층간 전단, 기지 균열 및 층간 분리 중 어느 하나이다.

연구자는 인장 시험을 통해 마련된 전체 데이터를 3:1:1로 나누어 각각 학습 데이터 세트, 검증 세트 및 테스트 세트로 사용하였다.

도 3은 AE 신호 데이터 유형에 따라 압력 용기의 결합 유형을 분류하는 딥러닝 모델에 대한 예이다. AE 신호 데이터는 기본적으로 1차원 파형 데이터이다. 1-D CNN은 웨이브폼 데이터를 입력받아 결합 유형을 분류하도록 학습된다. 제1 2-D CNN은 스펙트로그램 데이터를 입력받아 결합 유형을 분류하도록 학습된다. 제2 2-D CNN은 스케일로그램 데이터를 입력받아 결합 유형을 분류하도록 학습된다. 결합 유형은 학습 과정의 라벨값과 같이 정상, 층간 전단, 기지 균열 및 층간 분리 중 어느 하나이다.

1-D CNN와 2-D CNN은 입력 데이터의 유형과 컨볼루션 계층의 구조가 상이하다. 1-D CNN에서 커널은 일방향으로

이동하고, 2-D CNN에서 커널은 2차원 평면에서 2개 방향으로 이동한다. 2-D CNN은 이미지 처리에 주로 활용된다.

[0048] 1-D CNN은 컨볼루션 계층을 쌓을 때 두 가지 방법이 이용될 수 있다. 하나는 커널의 크기에 변화를 주는 것이고, 다른 하나는 컨볼루션 계층의 확장 간격(dilation rate)에 변화를 주는 것이다. 연구자는 1-D CNN에서 컨볼루션 계층의 깊이로 10개 계층들을 사용하였고, 2-D CNN에서 9개 계층들을 사용하였다.

[0050] 연구자는 구축한 분류 모델에 대한 성능을 검증하였다. 아래 표 2는 분류 모델의 성능을 검증한 결과이다. 검증 결과 1-D CNN이 2-D CNN보다 성능이 조금 더 높았다. 또한, 1-D CNN은 확장 간격이 변화하는 계층 구조를 가질 때 가장 높은 성능을 보였다. 이는 AET 사용하여 결합 분류를 수행할 때 시간 계열 특성이 중요하다는 의미이다.

표 2

Data type	Waveform	Spectrogram	Scalogram
Model	1-D CNN	2-D CNN	2-D CNN
Accuracy	90.43%	83.75%	82.89%

[0052]

[0054] 도 4는 압력 용기의 결합 유형 추론 과정(200)에 대한 예이다. 추론 과정은 분석장치가 수행한다고 설명한다. 분석장치는 물리적으로 다양한 형태로 구현될 수 있다. 예컨대, 분석장치는 PC와 같은 컴퓨터 장치, 네트워크의 서버, 데이터 처리 전용 칩셋 등의 형태를 가질 수 있다.

[0055] 먼저, AE 센서 시스템이 분석 대상인 압력 용기에 배치된 AE 센서를 이용하여 AE 신호 데이터를 수집한다(210). 분석장치는 수집한 AE 신호 데이터를 입력받는다.

[0056] 분석장치는 AE 신호 데이터의 증폭 및/또는 잡음 제거와 같은 전처리를 수행할 수 있다(220).

[0057] 분석장치는 AE 신호 데이터를 일정한 유형의 데이터로 변환(후처리)할 수 있다(230). 예컨대, 분석장치는 웨이브폼 데이터인 AE 신호 데이터에 STFT를 수행하여 스펙트로그램 데이터를 산출할 수 있다. 또한 분석장치는 웨이브폼 데이터에 대한 CWT를 수행하여 스케일로그램 데이터를 산출할 수 있다.

[0058] 분석장치는 AE 신호 데이터, 스펙트로그램 데이터 또는 스케일로그램 데이터를 사전에 구축한 분류 모델에 입력하여 신호를 분석할 수 있다(240).

[0059] 분석장치는 분류 모델이 출력하는 정보를 기준으로 압력 용기 V의 결합 여부 또는 결합 유형을 예측(분류)할 수 있다(250).

[0061] 도 5는 압력 용기의 결합 유형을 분류하는 분석장치(300)에 대한 예이다. 분석장치(300)는 저장장치(310), 메모리(320), 연산장치(330), 인터페이스 장치(340), 통신장치(350) 및 출력장치(360)를 포함할 수 있다.

[0062] 저장장치(310)는 분석 대상인 압력 용기(타깃 압력 용기)의 AE 신호 데이터를 저장할 수 있다.

[0063] 저장장치(310)는 결합 유형을 분류하는 딥러닝 모델(분류 모델)을 저장할 수 있다. 딥러닝 모델은 입력 데이터의 유형에 따라 사전에 구축된다. 전술한 바와 같이 딥러닝 모델은 웨이브폼 데이터를 입력받아 분석하는 1-D CNN 기반 모델, 스펙트로그램 데이터를 입력받아 분석하는 2-D CNN 기반 모델 및 스케일로그램 데이터를 입력받아 분석하는 2-D CNN 기반 모델 중 적어도 하나일 수 있다. 저장장치(310)는 세가지 유형의 모델을 모두 저장할 수 있다.

[0064] 저장장치(310)는 분석 결과(결합 유형)를 저장할 수 있다.

[0065] 메모리(320)는 분석장치(300)가 AE 신호 데이터를 이용하여 압력 용기의 결합 유형을 분류하는 과정에서 생성되

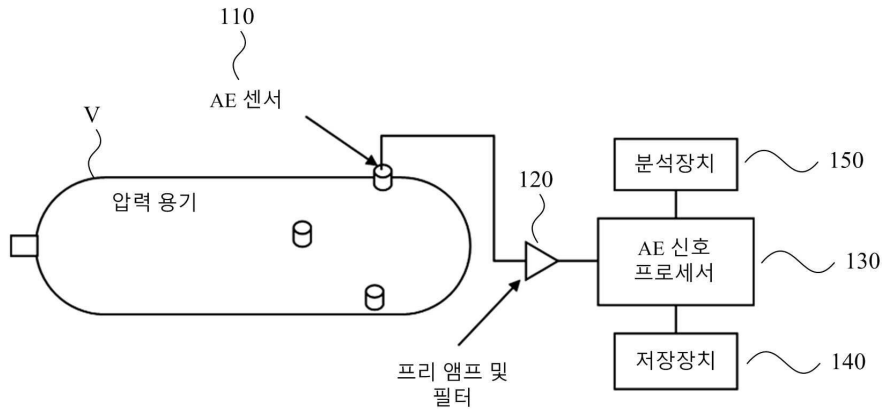
는 데이터 및 정보 등을 저장할 수 있다.

- [0066] 인터페이스 장치(340)는 외부로부터 일정한 명령 및 데이터를 입력받는 장치이다. 인터페이스 장치(340)는 물리적으로 연결된 입력 장치 또는 외부 저장장치로부터 분석 대상인 압력 용기의 AE 신호 데이터를 입력받을 수 있다. 한편, 인터페이스 장치(340)는 통신장치(350)를 통해 전달되는 데이터 및 정보를 입력받을 수도 있다. 인터페이스 장치(340)는 분석 결과를 외부 객체에 전달할 수도 있다.
- [0067] 통신장치(350)는 유선 또는 무선 네트워크를 통해 일정한 정보를 수신하고 전송하는 구성을 의미한다. 통신장치(350)는 외부 객체로부터 분석 대상인 압력 용기의 AE 신호 데이터를 수신할 수 있다. 또는 통신장치(350)는 분석 결과를 사용자 단말과 같은 외부 객체에 송신할 수도 있다.
- [0068] 출력장치(360)는 일정한 정보를 출력하는 장치이다. 출력장치(360)는 데이터 처리 과정에 필요한 인터페이스, 분석 결과 등을 출력할 수 있다.
- [0069] 연산 장치(330)는 저장장치(310)에 저장된 명령어 내지 프로그램 코드를 이용하여 AE 신호 데이터를 기준으로 압력 용기의 결함 유형을 예측 내지 분류할 수 있다.
- [0070] 연산 장치(330)는 AE 신호 데이터에서 잡음 제거와 같은 전처리를 수행할 수 있다.
- [0071] 연산 장치(330)는 필요에 따라 AE 신호 데이터를 다른 유형의 데이터로 변환할 수도 있다. 예컨대, 연산 장치(330)는 웨이브폼 데이터인 AE 신호 데이터를 STFT 변환하여 스펙트로그램 데이터를 산출할 수 있다. 또한 연산 장치(330)는 웨이브폼 데이터인 AE 신호 데이터를 CWT 변환하여 스케일로그램 데이터를 산출할 수 있다.
- [0072] 연산 장치(330)는 입력 데이터를 저장장치(310)에 저장된 딥러닝 모델에 입력하여 압력 용기의 결함 유형을 분류할 수 있다. 연산 장치(330)는 입력 데이터의 유형(웨이브폼 데이터, 스펙트로그램 데이터 및 스케일로그램 데이터)에 따라 대응하는 딥러닝 모델을 이용한다.
- [0073] 연산 장치(330)는 입력된 데이터를 분석하여 딥러닝 모델이 출력하는 정보를 기준으로 압력 용기의 결함 유형을 분류할 수 있다. 결함 유형은 학습 과정의 라벨값과 같이 정상, 중간 진단, 기지 균열 및 층간 분리 중 어느 하나이다.
- [0074] 경우에 따라서, 연산 장치(330)는 다수의 입력 데이터를 이용하여 압력 용기의 결함 유형을 분류할 수 있다. 예컨대, 연산 장치(330)는 1-D CNN이 웨이브폼 데이터인 AE 신호 데이터를 입력받아 출력하는 제1 정보, 2-D CNN이 스펙트로그램 데이터를 입력받아 출력하는 제2 정보 및 2-D CNN이 스케일로그램 데이터를 입력받아 출력하는 제3 정보 중 적어도 하나를 이용하여 최종적으로 압력 용기의 결함 유형을 분류할 수 있다. 연산 장치(330)는 다수의 모델이 산출하는 정보들을 기준으로 압력 용기의 결함 유형을 분류할 수 있다. 예컨대, 연산 장치(330)는 다수결에 따라 최종적인 압력 용기의 결함 유형을 분류할 수 있다.
- [0075] 연산 장치(330)는 데이터를 처리하고, 일정한 연산을 처리하는 프로세서, AP, 프로그램이 임베디드된 칩과 같은 장치일 수 있다.
- [0076] 또한, 상술한 바와 같은 압력 용기의 결함 유형 분류 내지 예측 방법은 컴퓨터에서 실행될 수 있는 실행가능한 알고리즘을 포함하는 프로그램(또는 어플리케이션)으로 구현될 수 있다. 상기 프로그램은 일시적 또는 비일시적 판독 가능 매체(non-transitory computer readable medium)에 저장되어 제공될 수 있다.
- [0077] 비일시적 판독 가능 매체란 레지스터, 캐쉬, 메모리 등과 같이 짧은 순간 동안 데이터를 저장하는 매체가 아니라 반영구적으로 데이터를 저장하며, 기기에 의해 판독(reading)이 가능한 매체를 의미한다. 구체적으로는, 상술한 다양한 어플리케이션 또는 프로그램들은 CD, DVD, 하드 디스크, 블루레이 디스크, USB, 메모리카드, ROM (read-only memory), PROM (programmable read only memory), EPROM(Erasable PROM, EPROM) 또는 EEPROM(Electrically EPROM) 또는 플래시 메모리 등과 같은 비일시적 판독 가능 매체에 저장되어 제공될 수 있다.
- [0078] 일시적 판독 가능 매체는 스태틱 램(Static RAM, SRAM), 다이내믹 램(Dynamic RAM, DRAM), 싱크로너스 디램(Synchronous DRAM, SDRAM), 2배속 SDRAM(Double Data Rate SDRAM, DDR SDRAM), 증강형 SDRAM(Enhanced SDRAM, ESDRAM), 동기화 DRAM(Synclink DRAM, SLDRAM) 및 직접 램버스 램(Direct Rambus RAM, DRRAM) 과 같은 다양한 RAM을 의미한다.
- [0079] 본 실시예 및 본 명세서에 첨부된 도면은 전술한 기술에 포함되는 기술적 사상의 일부를 명확하게 나타내고 있는 것에 불과하며, 전술한 기술의 명세서 및 도면에 포함된 기술적 사상의 범위 내에서 당업자가 용이하게 유추

할 수 있는 변형 예와 구체적인 실시례는 모두 전술한 기술의 권리범위에 포함되는 것이 자명하다고 할 것이다.

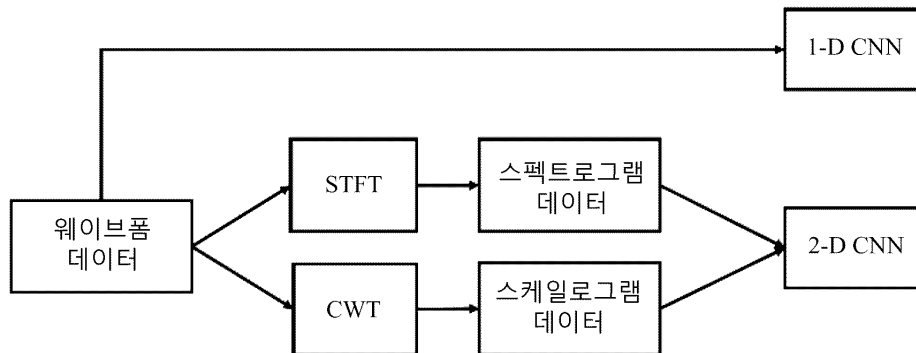
도면

도면1

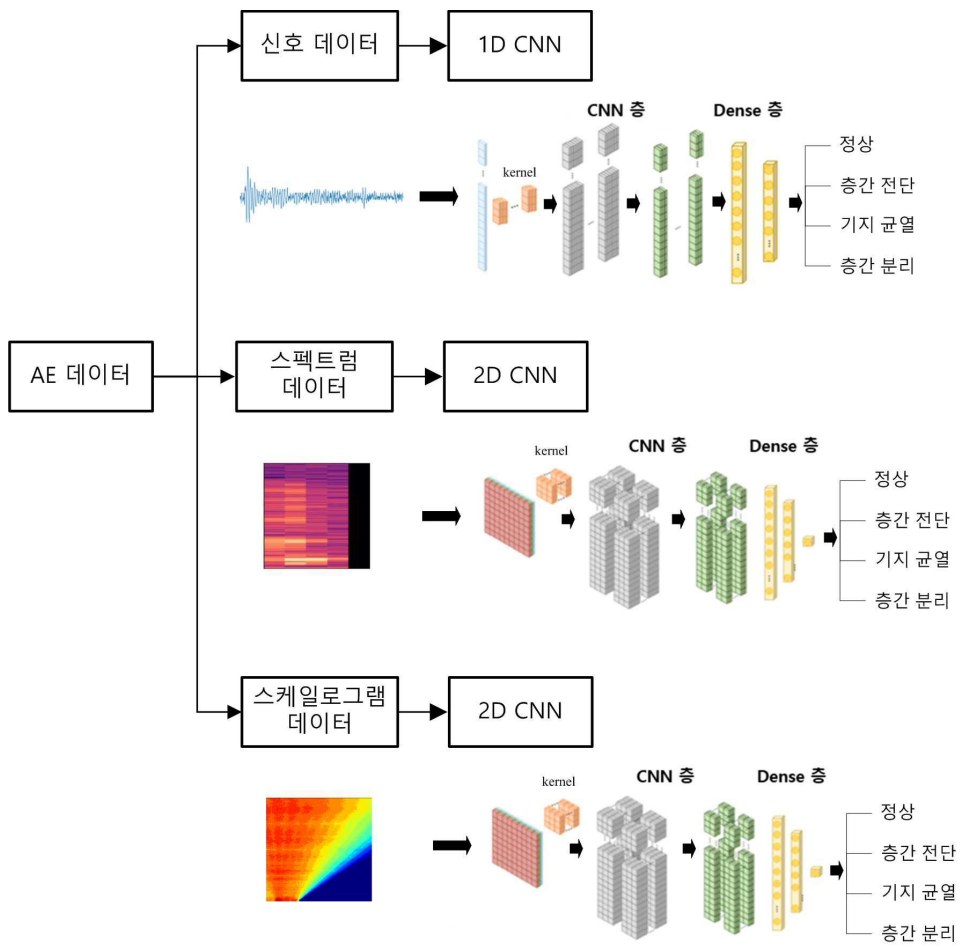


100


도면2



도면3



도면4



도면5

