(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0083570
(43) 공개일자 2023년06월12일

(51) 국제특허분류(Int. Cl.)
G01M 13/028 (2019.01) *G01H 1/00* (2006.01)
G01H 1/14 (2006.01) *G01M 13/021* (2019.01)
G01M 13/025 (2019.01) *G06N 3/08* (2023.01)
(52) CPC특허분류
G01M 13/028 (2019.01)
G01H 1/003 (2013.01)
(21) 출원번호 10-2021-0171703
(22) 출원일자 2021년12월03일
심사청구일자 2021년12월03일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
이상권
서울특별시 강남구 선릉로 120, 9동 901호(대치동, 개포1,2차 우성아파트)
김선원
경기도 시흥시 비둘기공원7길 27, 102동 106호(대야동)
백지선
광주광역시 북구 대천로 21, 2동 402호(오치동, 대동아파트)
(74) 대리인
양성보

전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **딥러닝 기반의 소음 신호를 이용한 파워 드라이빙 시스템의 건전성 감시 방법**

(57) 요 약

딥러닝 기반의 소음 신호를 이용한 파워 드라이빙 시스템의 건전성 감시 방법이 개시된다. 일 실시예에 따른 건전성 감시 시스템에 의해 수행되는 파워 드라이빙 시스템의 건전성 감지 방법은, 파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성하는 단계; 상기 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받는 단계; 및 상기 학습 모델을 이용하여 상기 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류하는 단계를 포함할 수 있다.

대 표 도 - 도5

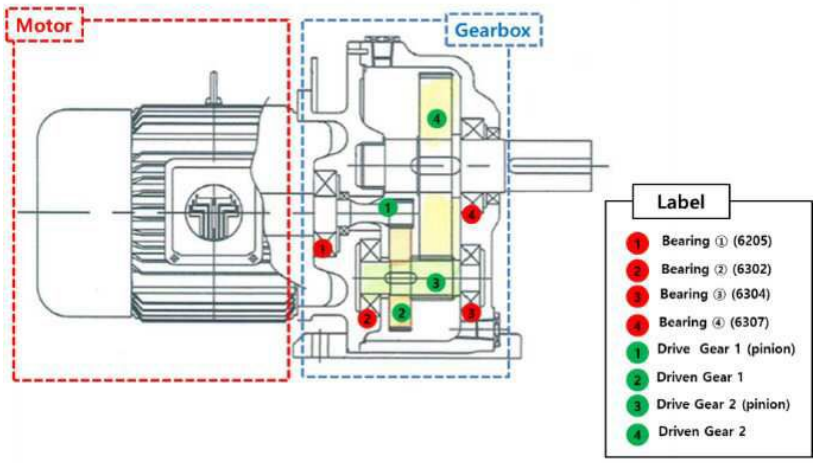

(52) CPC특허분류
G01H 1/14 (2013.01)
G01M 13/021 (2019.01)
G01M 13/025 (2019.01)
G06N 3/08 (2023.01)

명 세 서

청구범위

청구항 1

건전성 감시 시스템에 의해 수행되는 파워 드라이빙 시스템의 건전성 감지 방법에 있어서,

파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성하는 단계;

상기 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받는 단계; 및

상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류하는 단계

를 포함하고,

상기 결함 진단을 위한 학습 모델은,

이미지로부터 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴이 분류되도록 학습된 것을 특징으로 하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 2

제1항에 있어서,

상기 생성하는 단계는,

상기 측정된 소음 신호에 연속 웨이블렛(CWT)에 적용하여 시간-주파수 영역의 이미지 데이터를 생성하는 단계

를 포함하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 3

제1항에 있어서,

상기 학습 모델은,

상기 생성된 이미지가 입력되는 입력층, 필터 크기가 3×3인 16개의 특징 지도가 있는 합성곱 층, 크기가 2×2인 최대 풀링층, 필터 크기가 3×3인 32개의 특징 지도가 있는 합성곱층, 크기가 2×2인 최대 풀링층이 있는 합성곱 층, 소프트맥스 함수가 적용된 최종 합성곱 층으로 구성된 것을 특징으로 하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 4

제3항에 있어서,

상기 학습 모델은,

이미지로부터 결함 정보를 추출하는 단계; 및

상기 추출된 결함 정보를 포함하는 특징 지도를 추출하는 단계를 통해 학습되는 것

을 특징으로 하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 5

제1항에 있어서,

상기 파워 드라이빙 시스템은 모터, 체인, 피니언, 스프라켓, 기어, 베어링 또는 회전축을 포함하는 부품들, 상기 부품들의 결합으로 구성되는 것을 포함하고,

상기 결함 패턴을 분류하는 단계는,

상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 결함 조건과 관련 있는 결함 특징 정보를 추출하고, 상기 추출된 결함 특징 정보에 기초하여 상기 파워 드라이빙 시스템의 결함 패턴을 분류하는 단계

를 포함하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 6

제1항에 있어서,

상기 결함 패턴을 분류하는 단계는,

상기 생성된 이미지로부터 상기 파워 드라이빙 시스템의 결함 부품을 진단하고, 상기 진단된 결함 부품에 대한 단일 결함 패턴 또는 다중 결함 패턴을 분류하는 단계

를 포함하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 7

제1항에 있어서,

상기 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴은,

구동 기어의 치차 크랙, 구동 기어의 치차 절손, 모터에서 구동축의 편심, 베어링의 구멍으로 인한 외륜 결함, 베어링의 이물질로 인한 내륜 결함, 모터의 구동축 편심 + 구동 기어의 치차 절손, 모터의 구동축 편심 + 구동 기어의 치차절손 + 베어링의 외륜 결함, 모터의 구동축 편심 + 구동 기어의 치차 절손 + 베어링의 내륜 결함 또는 정상 조건 중 어느 하나를 포함하는 것을 특징으로 하는 파워 드라이빙 시스템의 건전성 감지 방법.

청구항 8

건전성 감시 시스템에 있어서,

파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성하는 이미지 생성부;

상기 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받는 이미지 입력부; 및

상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류하는 결함 패턴 분류부

를 포함하고,

상기 결함 진단을 위한 학습 모델은,

이미지로부터 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴이 분류되도록 학습된 것을 특징으로 하는 건전성 감지 시스템.

발명의 설명

기 술 분 야

[0001] 아래의 설명은 파워 드라이빙 시스템의 건전성을 감시하는 기술에 관한 것이다.

배 경 기 술

[0003] 파워 드라이빙 시스템(Power Driving System; PDS)은 큰 동력을 필요로 하는 공작기계, 자동차 엔진 타이밍 시스템 등 다양한 산업 분야에서 중요한 기계 시스템으로 적용되었다. 파워 드라이빙 시스템에서 발생하는 결함을 조기에 발견하여 경제적 손실과 인명 피해를 미연에 방지하기 위해 여러 기법들이 연구되어오고 있다.

[0004] 파워 드라이빙 시스템의 결함은 동력을 전달하는 샤프트와 기어를 지지하는 베어링의 결함 또는 체인의 파손에 의해 발생한다. 결함을 조기에 발견하기 위해서 일반적으로 음향 진동 신호를 측정하여 측정된 신호부터 결함의 특징을 추출하여 결함의 유무를 판단한다. 측정된 음향 진동 신호로부터 결함 특징을 추출하기 위해서 다양한 방법이 사용되어 왔다. 일례로, 시간 평균법, 켑스트럼 분석, 스도-위그너-빌 분포, 웨이블렛 변환, 고차항

방법, 적응형 선향상법, 경험적 모드 분해, 주기정상적 분석과 같은 특징 추출 방법이 사용되어 왔다. 이러한, 결함의 특징을 활용하여 결함의 종류를 분류하기 위해 최근접 이웃 알고리즘, 베이지안 분류기, 지지 벡터 기계, 그리고 인공신경망 등이 사용되고 있다.

[0005] 보다 정확하게 파워 드라이빙 시스템의 결함 진단 및 패턴 분류하기 위한 기술이 요구된다.

발명의 내용

해결하려는 과제

[0007] 연속 웨이블렛 변환(CWT) 및 딥러닝 기술을 이용하여 파워 드라이빙 시스템의 결함 진단 및 패턴 분류 방법 및 시스템을 제공할 수 있다.

과제의 해결 수단

[0009] 건전성 감시 시스템에 의해 수행되는 파워 드라이빙 시스템의 건전성 감지 방법은, 파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성하는 단계; 상기 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받는 단계; 및 상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류하는 단계를 포함하고, 상기 결함 진단을 위한 학습 모델은, 이미지로부터 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴이 분류되도록 학습된 것일 수 있다.

[0010] 상기 생성하는 단계는, 상기 측정된 소음 신호에 연속 웨이블렛(CWT)에 적용하여 시간-주파수 영역의 이미지 데이터를 생성하는 단계를 포함할 수 있다.

[0011] 상기 학습 모델은, 상기 생성된 이미지가 입력되는 입력층, 필터 크기가 3×3인 16개의 특징 지도가 있는 합성곱 층, 크기가 2×2인 최대 풀링층, 필터 크기가 3×3인 32개의 특징 지도가 있는 합성곱층, 크기가 2×2인 최대 풀링층이 있는 합성곱 층, 소프트맥스 함수가 적용된 최종 합성곱 층으로 구성될 수 있다.

[0012] 상기 학습 모델은, 이미지로부터 결함 정보를 추출하는 단계; 및 상기 추출된 결함 정보를 포함하는 특징 지도를 추출하는 단계를 통해 학습되는 것일 수 있다.

[0013] 상기 파워 드라이빙 시스템은 모터, 체인, 피니언, 스프라켓, 기어, 베어링 또는 회전축을 포함하는 부품들, 상기 부품들의 결합으로 구성되는 것을 포함하고, 상기 결함 패턴을 분류하는 단계는, 상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 결함 조건과 관련 있는 결함 특징 정보를 추출하고, 상기 추출된 결함 특징 정보에 기초하여 상기 파워 드라이빙 시스템의 결함 패턴을 분류하는 단계를 포함할 수 있다.

[0014] 상기 결함 패턴을 분류하는 단계는, 상기 생성된 이미지로부터 상기 파워 드라이빙 시스템의 결함 부품을 진단하고, 상기 진단된 결함 부품에 대한 단일 결함 패턴 또는 다중 결함 패턴을 분류하는 단계를 포함할 수 있다.

[0015] 상기 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴은, 구동 기어의 치차 크랙, 구동 기어의 치차 절손, 모터에서 구동축의 편심, 베어링의 구멍으로 인한 외륜 결함, 베어링의 이물질로 인한 내륜 결함, 모터의 구동축 편심 + 구동 기어의 치차 절손, 모터의 구동축 편심 + 구동 기어의 치차절손 + 베어링의 외륜 결함, 모터의 구동축 편심 + 구동 기어의 치차 절손 + 베어링의 내륜 결함 또는 정상 조건 중 어느 하나를 포함할 수 있다.

[0016] 건전성 감시 시스템은, 파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성하는 이미지 생성부; 상기 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받는 이미지 입력부; 및 상기 결함 진단을 위한 학습 모델을 이용하여 상기 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류하는 결함 패턴 분류부를 포함하고, 상기 결함 진단을 위한 학습 모델은, 이미지로부터 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴이 분류되도록 학습된 것일 수 있다.

발명의 효과

[0018] 연속 웨이블렛 변환(CWT) 및 딥러닝 기술을 이용하여 파워 드라이빙 시스템의 결함 진단 및 패턴 분류의 정확도

를 향상시킬 수 있다.

[0019] 부품의 결함으로 파워 드라이빙 시스템에 완전 파손이 발생하는 것을 방지할 수 있다.

도면의 간단한 설명

[0021] 도 1은 일 실시예에 있어서, 건전성 감시 시스템에서 파워 드라이빙 시스템의 결함 패턴을 분류하는 동작을 설명하기 위한 도면이다.

도 2는 일 실시예에 따른 건전성 감시 시스템의 구성을 설명하기 위한 블록도이다.

도 3은 일 실시예에 따른 건전성 감시 시스템에서 파워 드라이빙 시스템의 건전성 감시 방법을 설명하기 위한 흐름도이다.

도 4는 일 실시예에 있어서, 파워 드라이빙 시스템의 소음 데이터를 측정하는 동작을 설명하기 위한 도면이다.

도 5는 일 실시예에 있어서, 파워 드라이빙 시스템의 구성을 설명하기 위한 도면이다.

도 6은 일 실시예에 있어서, 파워 드라이빙 시스템의 결함 패턴을 설명하기 위한 예이다.

도 7은 일 실시예에 있어서, 시간 영역 소음 데이터를 나타낸 그래프이다.

도 8은 일 실시예에 있어서, 소음의 파워 스펙트럼 밀도를 나타낸 그래프이다.

도 9는 일 실시예에 있어서, 소음 데이터에 대한 연속 웨이블렛 변환 동작을 나타낸 그래프이다.

도 10은 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 구조를 설명하기 위한 예이다.

도 11 및 도 12는 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 정확도를 나타낸 그래프이다.

도 13은 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 특징 지도를 나타낸 예이다.

도 14는 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 t-확률적 임베딩 방법을 이용하여 데이터를 시각화한 것을 나타낸 예이다.

발명을 실시하기 위한 구체적인 내용

[0022] 이하, 실시예를 첨부한 도면을 참조하여 상세히 설명한다.

[0024] 도 1은 일 실시예에 있어서, 건전성 감시 시스템에서 파워 드라이빙 시스템의 결함 패턴을 분류하는 동작을 설명하기 위한 도면이다.

[0025] 건전성 감시 시스템(100)은 파워 드라이빙 시스템의 부품 결함으로 완전파손이 발생하는 것을 방지하기 위하여 결함 진단을 위한 학습 모델(101)을 활용하여 부품의 결함을 조기에 진단할 수 있다. 이때, 예를 들면, 파워 드라이빙 시스템은 체인, 스프라켓, 기어, 베어링, 회전축 등의 부품들 또는/및 부품들의 결합으로 구성될 수 있다.

[0026] 일례로, 결함 진단을 위한 학습 모델(101)은 파워 드라이빙 시스템의 결함 진단을 위하여 합성곱 신경망(CNN) 기반으로 구성될 수 있으며, 결함 진단을 위한 데이터 셋을 이용하여 결함 진단 및 결함 패턴이 학습되도록 구축된 것일 수 있다.

[0027] 이러한, 결함 진단을 위한 학습 모델(101)에 파워 드라이빙 시스템에서 측정되는 신호를 이용하여 생성된 이미지가 입력 데이터(110)로 입력될 수 있다. 실시예에서는 시간-주파수 영역의 이미지 데이터가 결함 진단을 위한 학습 모델(101)에 입력 데이터(110)로 입력될 수 있다.

[0028] 입력 데이터(110)에 입력된 결함 진단을 위한 학습 모델(101)을 통해 출력 데이터(120)가 출력될 수 있다. 결함 진단을 위한 학습 모델(101)을 이용하여 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴이 분류될 수 있다. 다시 말해서, 출력 데이터(120)로서 결함 패턴이 분류될 수 있다.

[0029] 상세하게는, 파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지가 생성될 수 있다. 측정된 소음 신호에 연속 웨이블렛 변환(CWT)을 적용하여 시간-주파수 영역의 이미지 데이터가 생성될 수 있다. 연속 웨이

블렛 변환 분석 방법은 다음과 같이 정의될 수 있다.

[0030] 수학식 1:

[0031] $$\psi_{a,b} = \frac{1}{\sqrt{a}}\phi\left(\frac{t-b}{a}\right), \qquad a > b \quad \in \Re,$$

[0032] 여기서, ψ는 모 웨이블렛으로 시간과 주파수 영역에서 국부화된 고정함수이다. 함수 $\psi_{a,b}$는 시간 도메인에서 이동(b-tanslation)과 주파수 도메인에서 모웨이블렛으로 스케일링(a-dilation)을 적용한다. 실시예에서 사용된 모 웨이블렛은 모아렛(Morlet) 웨이블렛이며 다음과 같이 정의될 수 있다.

[0033] 수학식 2:

[0034] $$\phi(t) = \frac{1}{\sqrt{\pi B}} e^{jw_0 t - (\frac{t^2}{B})},$$

[0035] w_0는 모 웨이블렛이 주파수 도메인으로 변환될 때 모 웨이블렛의 중심 주파수이다. 실시예에서는 측정된 소음 신호에 연속 웨이블렛 변환을 적용하여 시간-주파수 영역의 이미지 데이터가 생성되고, 상기 생성된 시간-주파수 영역의 이미지 데이터가 결함 진단을 위한 학습 모델(101)의 입력 데이터로 사용될 수 있다.

[0036] 이러한 결함 진단을 위한 학습 모델(101)은 합성곱 신경망(CNN) 기반으로 구성될 수 있다. 합성곱 신경망은 측정된 소음 신호에 연속 웨이블렛 변환을 통하여 생성된 이미지가 복수 개의 합성곱층(layer) 및 풀링층(pooling layer)을 통해 상기 생성된 이미지에 대한 결함 정보가 추출될 수 있다. 합성곱 신경망에서 신경망은 복수 개의 합성곱층 및 풀링층의 단계로 이루어져 있으며, 각 합성곱층에서 결함 정보를 가진 특징 지도(feature map)를 추출할 수 있다. 제1 번째 합성곱 층에서 특징 지도 y_j^l 은 다음과 같이 수학식3을 통하여 획득할 수 있다.

[0037] 수학식 3:

[0038] $$y_j^l = \emptyset\left(b_j^l + \sum_{i \in Z_j^l} y_i^{l-1} \otimes f_{ij}^l\right),$$

[0039] 여기서, $\emptyset$는 비선형 활성화 함수이고 b_j^l은 *l*번째 층의 스칼라(scalar) 바이어스(bias) 이다. Z_j^l는 (*l*-1)번째 층에서 선택된 특징 지도이다. $\otimes$는 이전 층의 y_i^{l-1} 활성화 함수를 합성곱하는 합성곱 연산자를 나타낸다. f_{ij}^l는 2차원 필터 (filter)이며 필터의 가중치는 특정한 특징을 감지하도록 학습될 수 있다. 따라서 새로운 입력 이미지의 정확한 분류를 위해 서로 다른 카테고리를 구별할 수 있는 연속적인 단계에서 효과적인 특징 선택이 필요하다. 이러한 이유로 풀링층이 사용되며 *l*번째 풀링층 p_d^l은 다음과 같이 나타낼 수 있다.

[0040] 수학식 4:

[0041] $$p_d^l = \chi(d_j^l, N^l),$$

[0042] χ는 N_j^l에 의해 축소된 평균 또는 최대값 함수와 같은 축소 함수이다. 그리고 d_j^l는 축소되기 위한 합성곱된 특징 지도이다. 합성곱 신경망의 입력값이 연속적으로 합성곱 및 풀링 과정을 지나면서 네트워크는 모든 이미지를 효율적으로 특징을 추출하는 학습을 진행할 수 있다. 마지막 신경망 층의 출력값 y_p는 수학식5 와 같이 주어진다.

[0043] 수학식 5:

[0044] $$y_p = \psi(b_p + \boldsymbol{W}\boldsymbol{f}),$$

[0045] b_p는 출력 층의 바이어스이고, W는 완전히 연결된 층의 입력층과 출력층 사이의 가중치 행렬이며, f는 완전히 연결된 층의 특징을 나타내는 특징 벡터 (feature vector)를 나타내고, ψ는 결함을 분류하는 소프트맥스 (softmax) 함수이다. 학습 매개변수, b_j^l, f_{ij}^l, b_p 및 W는 학습 과정에서 최적화된 값이 결정될 수 있다. 실제 출력값과 원하는 목표값 간의 오차를 최소화하기 위해 확률적 경사하강법(SGD; stochastic gradient descent)을 통해 학습 매개변수의 최적화가 이루어질 수 있다. 여기서 경사값은 역전파(back propagation) 방법을 통하여 계산될 수 있다.

[0046] 도 2는 일 실시예에 따른 건전성 감시 시스템의 구성을 설명하기 위한 블록도이고, 도 3은 일 실시예에 따른 건전성 감시 시스템에서 파워 드라이빙 시스템의 건전성 감시 방법을 설명하기 위한 흐름도이다.

[0047] 건전성 감시 시스템(100)의 프로세서는 이미지 생성부(210), 이미지 입력부(220) 및 결함 패턴 분류부(230)를 포함할 수 있다. 이러한 프로세서의 구성요소들은 건전성 감시 시스템에 저장된 프로그램 코드가 제공하는 제어 명령에 따라 프로세서에 의해 수행되는 서로 다른 기능들(different functions)의 표현들일 수 있다. 프로세서 및 프로세서의 구성요소들은 도 3의 건전성 감시 방법이 포함하는 단계들(310 내지 330)을 수행하도록 건전성 감시 시스템을 제어할 수 있다. 이때, 프로세서 및 프로세서의 구성요소들은 메모리가 포함하는 운영체제의 코드와 적어도 하나의 프로그램의 코드에 따른 명령(instruction)을 실행하도록 구현될 수 있다.

[0048] 프로세서는 건전성 감시 방법을 위한 프로그램의 파일에 저장된 프로그램 코드를 메모리에 로딩할 수 있다. 예를 들면, 건전성 감시 시스템에서 프로그램이 실행되면, 프로세서는 운영체제의 제어에 따라 프로그램의 파일로부터 프로그램 코드를 메모리에 로딩하도록 건전성 감시 시스템을 제어할 수 있다. 이때, 이미지 생성부(210), 이미지 입력부(220) 및 결함 패턴 분류부(230) 각각은 메모리에 로딩된 프로그램 코드 중 대응하는 부분의 명령을 실행하여 이후 단계들(310 내지 330)을 실행하기 위한 프로세서의 서로 다른 기능적 표현들일 수 있다.

[0049] 단계(310)에서 이미지 생성부(210)는 파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성할 수 있다. 이미지 생성부(210)는 측정된 소음 신호에 연속 웨이블렛(CWT)에 적용하여 시간-주파수 영역의 이미지 데이터를 생성할 수 있다.

[0050] 단계(320)에서 이미지 입력부(220)는 생성된 이미지를 결함 진단을 위한 학습 모델에 입력받을 수 있다. 이때, 학습 모델은, 이미지로부터 복수 개의 결함 조건 및 정상 조건을 포함하는 결함 패턴이 분류되도록 학습된 것일 수 있다. 상세하게는, 학습 모델은 생성된 이미지가 입력되는 입력층, 필터 크기가 3×3인 16개의 특징 지도가 있는 합성곱 층, 크기가 2×2인 최대 풀링층, 필터 크기가 3×3인 32개의 특징 지도가 있는 합성곱층, 크기가 2×2인 최대 풀링층이 있는 합성곱 층, 소프트맥스 함수가 적용된 최종 합성곱 층으로 구성될 수 있다. 이와 같이 구성된 학습 모델은 이미지 데이터로부터 결함 정보를 추출하고, 추출된 결함 정보를 포함하는 특징 지도를 추출하는 과정을 통해 학습될 수 있다.

[0051] 단계(330)에서 결함 패턴 분류부(230)는 결함 진단을 위한 학습 모델을 이용하여 생성된 이미지로부터 파워 드라이빙 시스템의 결함 패턴을 분류할 수 있다. 결함 패턴 분류부(230)는 결함 진단을 위한 학습 모델을 이용하여 생성된 이미지로부터 결함 조건과 관련 있는 결함 특징 정보를 추출하고, 추출된 결함 특징 정보에 기초하여 파워 드라이빙 시스템의 결함 패턴을 분류할 수 있다. 결함 패턴 분류부(230)는 생성된 이미지로부터 파워 드라이빙 시스템의 결함 부품을 진단하고, 진단된 결함 부품에 대한 단일 결함 패턴 또는 다중 결함 패턴을 분류할 수 있다. 예를 들면, 결함 패턴 분류부(230)는 파워 드라이빙 시스템에 한 가지의 결함만 탐지될 경우, 단일 결함으로 진단하고, 파워 드라이빙 시스템에 여러 가지의 결함이 탐지될 경우, 다중 결함으로 진단할 수 있다.

[0052] 도 4는 일 실시예에 있어서, 파워 드라이빙 시스템의 소음 데이터를 측정하는 동작을 설명하기 위한 도면이다.

[0053] 도 4는 실험에 사용된 파워 드라이빙 시스템 실험장치의 구성도 및 제어장치를 나타낸 예이다. 파워 드라이빙 시스템은 동력전달의 구동을 위해서, 모터, 기어박스, 베어링, 체인시스템, 회전축, 스프라켓, 피니언 등의 기계 부품 또는/및 기계 부품들의 결합으로 구성될 수 있다. 실시예에서는 인위적으로 기계 부품들에 결함을 만들어 제작 결합한 것을 예를 들어 설명하기로 한다. 파워 드라이빙 시스템의 구동 중 기계 부품들의 결함으로부터 발생되는 이상 소음을 측정하고, 결함의 패턴을 분류하기 위해서, 소음 측정용 마이크로폰이 설치될 수 있다. 예를 들면, 파워 드라이빙 시스템에서 1M 떨어진 위치에 마이크로폰이 배치되어 소음 데이터가 측정될 수 있다. 1/2인치 free-field microphone (B & K 4192, 덴마크)를 사용하여 소음 데이터가 측정될 수 있고, Data

Acquisition System(NI 9233, USA)을 통해 건전성 감시 시스템으로 전송될 수 있다. 이때, 건전성 감시 시스템은 컴퓨터로 구현되어 신호분석이 가능한 것일 수 있다. 측정된 소음 데이터는 계측 장비를 통하여 디지털 데이터로 변환되어 건전성 감시 시스템으로 전송될 수 있다. 건전성 감시 시스템에서는 결함 부품을 진단하고 결함의 패턴을 분류하는 작업을 시행한다.

[0054] 도 5는 일 실시예에 있어서, 파워 드라이빙 시스템의 구성을 설명하기 위한 도면이다.

[0055] 도 5는 파워 드라이빙 시스템의 구동 시스템을 위한 주요 부품을 나타낸 것으로, 파워 드라이빙 시스템에 적용된 베어링 및 기어 등에 대한 상세 위치를 나타낸 것이다. 예를 들면, 실험용 파워 드라이빙 시스템은 4개의 베어링, 4개의 기어, 1개의 체인, 2개의 스프라켓 및 1개의 모터로 구성될 수 있다. 입력용 구동축의 회전 속도는 1800rpm(30Hz)이고 출력용 구동축의 회전 속도는 59.4rpm(0.99Hz)이고, 감속비는 30이다. 실시예에서는 모터 샤프트, 베어링, 기어에 인위적 결함을 적용하고, 스프라켓 및 체인에는 결함이 발생하면 완전 파손이 발생할 수 있음으로 인위적 결함을 적용하지 않은 것을 예를 들어 설명하기로 한다.

[0056] 도 6은 일 실시예에 있어서, 파워 드라이빙 시스템의 결함 패턴을 설명하기 위한 예이다.

[0057] 도 6은 파워 드라이빙 시스템에 구동 기어 2에 3개의 치차 크랙, 구동 기어 2에 치차 절손, 베어링 1의 구멍으로 인한 외륜 결함을 나타낸 예이다.

[0058] 결함 조건(종류)은 구동 기어 2의 치차 크랙(결함 1), 구동 기어 2의 치차 절손(결함 2), 모터에서 구동축의 편심(결함 3), 베어링 ①의 구멍으로 인한 외륜 결함(결함 4), 베어링 ①의 이물질로 인한 내륜 결함(결함 5), 모터의 구동축 편심 + 구동 기어 2의 치차 절손(결함 6), 모터의 구동축 편심 + 구동 기어 2의 치차절손 + 베어링 ①의 외륜 결함(결함 7), 모터의 구동축 편심 + 구동 기어 2의 치차 절손 + 베어링 ①의 내륜 결함(결함 8), 정상 상태 (정상)를 포함하는 결함 패턴으로 분류될 수 있다.

[0059] 다시 말해서, 결함 패턴은 다음과 같이 표로 정리될 수 있다.

[0060] 표 1:

[0061]

번호	베어링	기어	모터 축
1	-	구동 기어2의 이 3개 치차 크랙	-
2	-	구동 기어2의 이 0.5개 치차 절손	-
3	-	-	편심
4	베어링 1의 구멍으로 인한 외륜결함	-	편심
5	베어링 1의 이물질로 인한 내륜결함	-	편심
6	-	구동 기어2의 이 1개 치차 절손	편심
7	베어링 1의 구멍으로 인한 외륜결함	구동 기어2의 이 1개 치차 절손	편심
8	베어링 1의 이물질로 인한 내륜결함	구동 기어2의 이 1개 치차 절손	편심

[0062] 파워 드라이빙 시스템의 소음 데이터를 측정하기 위해 파워 드라이빙 시스템에서 특정 거리만큼 떨어진 위치에서 마이크로폰이 배치될 수 있다. 배치된 마이크로폰을 통해 파워 드라이빙 시스템의 소음 데이터가 측정될 수 있고, 측정된 소음 데이터에 기초하여 정상 및 결함 상태의 데이터가 획득될 수 있다. 각각의 결함 조건에 대해 실험이 수행될 수 있다. 예를 들면, 총 700번의 실험이 수행될 수 있으며, 각각의 테스트 구동 시간은 5분이며, 마이크로폰을 사용하여 획득된 마지막 30초의 소음 데이터가 결함 진단에 사용될 수 있다.

[0063] 도 7은 일 실시예에 있어서, 시간 영역 소음 데이터를 나타낸 그래프이고, 도 8은 일 실시예에 있어서, 소음의 파워 스펙트럼 밀도를 나타낸 그래프이다.

[0064] 시간 영역에서 측정된 소음 데이터는 MATLAB (MathWorks, USA) 신호 처리 툴박스를 사용하여 주파수 및 연속 웨

이블렛 변환 분석이 시행될 수 있다. 도 7은 마이크로폰으로 측정한 8 개의 결함 및 1 개의 정상 신호의 시간 영역 데이터를 나타낸다.

[0065] 도 8은 정상 소음 신호와 8 개의 고장 소음 신호의 파워 스펙트럼을 각각 비교한 것을 나타낸 것이다. 각각의 결함에 따라 시간 영역 소음 데이터와 스펙트럼의 형태가 차이가 발생하게 된다. 스펙트럼에서 파란색 곡선은 결함 상태를 나타내고, 주황색 곡선은 정상 상태를 나타낸다.

[0066] 상세하게는, 8 개의 고장 신호의 파워 스펙트럼은 정상 신호의 파워 스펙트럼의 형태와 차이가 난다. 회전 기계의 진동이론에 따르면, 파워 드라이빙 시스템과 같은 회전기계의 경우, 기계의 진동 소음을 유발하는 여러 가진력이 존재하는데, 기어 맞물림으로 인한 가진력, 베어링의 구름 접촉으로 인한 접촉가진력, 그리고 모터의 샤프트의 가진력 및 스프라켓과 체인의 충격으로 인한 충격 가진력 등이 있다. 상기 가진력은 파워 드라이빙 시스템의 정상적인 조건에서도 존재함으로 기본적으로 존재하는 소음 진동이다. 파워 드라이빙 시스템의 8개 결함으로 가진력은 변화될 수 있으며, 변화된 가진력은 소음신호에 주파수 스펙트럼의 변화를 일으킨다. 이에, 8 개 고장 신호의 파워 스펙트럼은 정상 신호의 파워 스펙트럼의 형태와 차이가 나타난다.

[0067] 도 9는 일 실시예에 있어서, 소음 데이터에 대한 연속 웨이블렛 변환 동작을 나타낸 그래프이다.

[0068] 실시예에서는 마이크로폰으로 측정된 소음 신호에 연속 웨이블렛 변환을 적용하여 이미지가 생성될 수 있다. 연속 웨이블렛 변환을 통하여 분석된 이미지는 도 9에 도시된 바와 같이, 파워 드라이빙 시스템의 운전 상태에 대한 정보를 제공한다. 도 9는 파워 드라이빙 시스템의 정상 운전 조건에서 측정된 소음 신호에 대한 연속 웨이블렛 변환 결과를 나타낸 것이다. 이 결과에 따르면 정상 조건에서 각종 부품의 가진력과 관련된 소음 신호가 발생됨을 알 수 있다. 결함이 발생하는 경우 소음 신호의 연속 웨이블렛 변환은 변화하게 된다. 이와 같이, 연속 웨이블렛 변환 결과, 스프라켓의 주파수, 기어 2의 맞물림 주파수, 베어링 1의 결함 주파수 등이 나타남을 확인할 수 있다.

[0069] 실시예에서는 8개의 결함 조건에서 30초마다 측정된 소음 데이터에 대해서 연속 웨이블렛 변환을 적용하여 이미지를 획득한 후, CNN 기반의 학습 모델의 입력 데이터로 사용할 수 있다. 예를 들면, 각 결함 당 100개의 연속 웨이블렛 변환 이미지를 구하고, 정상 조건을 포함하여 총 900개의 이미지 데이터를 CNN 기반의 학습 모델의 입력 이미지 데이터로 사용할 수 있다. 이때, 각 이미지의 데이터 크기는 244 X 244 X 3일 수 있다.

[0070] 도 10은 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 구조를 설명하기 위한 예이다.

[0071] 연속 웨이블렛 변환 알고리즘은 MATLAB에서 제공한 CNN 툴박스가 사용될 수 있다. 결함 진단을 위한 학습 모델을 결함 패턴 분류 및 결함 특징 추출에 성공적으로 적용하기 위해서는 네트워크의 아키텍처 구성이 중요하다. 네트워크의 아키텍처 구성에 필요한 특별한 기술은 없으며 다양한 구성을 통하여 최적의 아키텍처 구성 찾는 것이다.

[0072] 도 10을 참고하면, 연속 웨이블렛 변환이 수행된 이미지가 입력되는 입력층과, 입력층 다음에 위치하는 첫 번째 층은 필터 크기가 3X3인 16개의 특징 지도가 있는 합성곱 층이다. 그 다음은 크기가 2X2인 평균 풀링 층이 있다. 그 다음 층은 필터 크기가 3X3의 32개의 특징 지도와 2X2 평균 풀링층이 있는 합성곱 층이다. 출력층은 8 개의 결함과 1 개의 정상 조건에 대응하는 9 개의 뉴런이 있다. 마지막의 최종 합성곱층(fully connected layer)에는 분류 함수로 소프트맥스(softmax) 함수가 적용될 수 있다. 경사하강법 학습 방법으로 최적화하고, 학습과정의 학습율은 0.001의 초기 학습 속도로 네트워크를 학습시키는 데 사용될 수 있다. 배치(Batch) 크기는 128로 취하고, 학습은 1300 회를 반복(30 epoch)하여 수행될 수 있다. 학습이 진행되는 동안 정확도의 변화는 도 11에 나타나 있다.

[0073] 도 11 및 도 12는 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 정확도를 나타낸 그래프이다.

[0074] 예를 들면, 최적의 가중치 값은 최소의 오차로 400 회를 학습 후 획득될 수 있다. 학습을 위해 900 개의 데이터 중 700 개의 샘플이 학습에 사용되고, 100 개의 샘플이 검증에 사용되었으며 100 개의 샘플이 테스트에 사용될 수 있다.

[0075] 결함 분류의 정확도는 총 테스트 샘플 수에서 정확하게 분류된 테스트 샘플 수의 비율이며 수학식 6과 같다.

[0076] 수학식 6:

[0077] $$정확도 = \frac{정확히\ 분류된\ 표본의\ 개수}{표본의\ 총\ 개수}.$$

[0078] 실험을 통해 100개의 테스트 샘플 중 90개의 샘플이 도 12와 같이 높은 정확도로 분류되었음을 확인할 수 있다.

[0079] 도 13은 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 특징 지도를 나타낸 예이다. 결함 진단을 위한 학습 모델의 학습 결과, 8 개의 결함 및 1 개의 정상 상태의 특징 지도가 최종 합성곱 층에서 추출될 수 있다. 이러한 결과에 의하면, 각 결함에 대하여 서로 다른 이미지를 나타냄을 확인할 수 있다.

[0080] 도 14는 일 실시예에 있어서, 결함 진단을 위한 학습 모델의 t-확률적 임베딩 방법을 이용하여 데이터를 시각화한 것을 나타낸 예이다.

[0081] 특징 지도를 t- 확률적 임베딩(t-SNE; t-stochastic neighbor embedding) 방법을 이용하여 고차원 데이터를 저차원 데이터로 변환하여 도 14와 같이 시각화 할 수 있다. "고차원"은 특징의 개수가 많다는 것을 의미하고, "2차원"은 특징의 개수가 2개라는 의미를 나타낸다. 도 14(a)는 학습 모델에 의해 100개의 입력 이미지의 차원이 감소된 2차원 특징을 나타낸다. 도 14(b)는 학습 모델에 의해 학습된 10개의 서로 다른 최종 네트워크 합성곱 층에서 추출된 특징 지도에 대한 차원이 축소된 2차원의 특징을 보여준다. 원본 이미지의 특징은 무작위로 흩어지기 때문에 결함과 정상 상태의 분류를 어렵게 만든다. 그러나, 학습된 네트워크에 의해 획득된 특징은 결함 또는 정상 상태에 따라 그룹화될 수 있다. 따라서 결함 상태와 정상 상태를 분류할 수 있다.

[0082] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0083] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

[0084] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0085] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가

진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

[0086] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

도면1

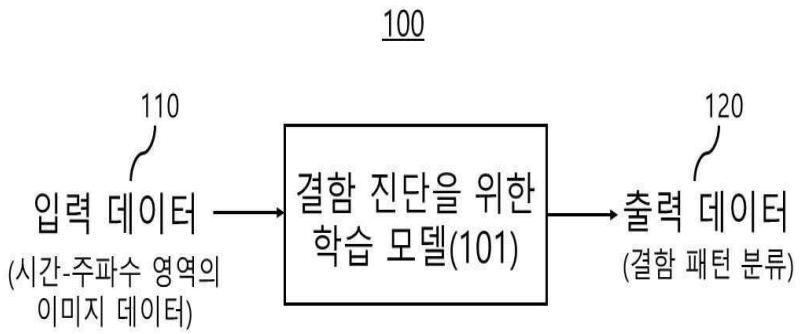

도면2

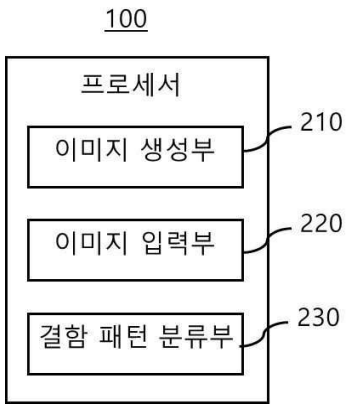

도면3

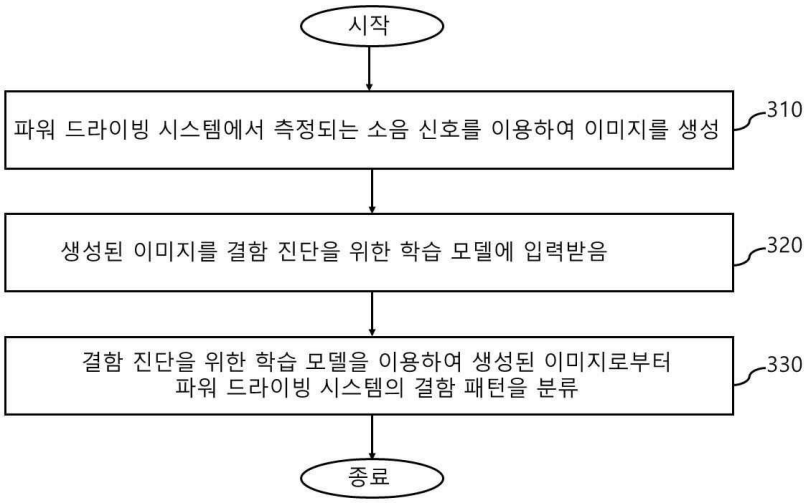
시작
파워 드라이빙 시스템에서 측정되는 소음 신호를 이용하여 이미지를 생성
310
생성된 이미지를 결함 진단을 위한 학습 모델에 입력받음
320
결함 진단을 위한 학습 모델을 이용하여 생성된 이미지로부터
파워 드라이빙 시스템의 결함 패턴을 분류
330
종료

도면4

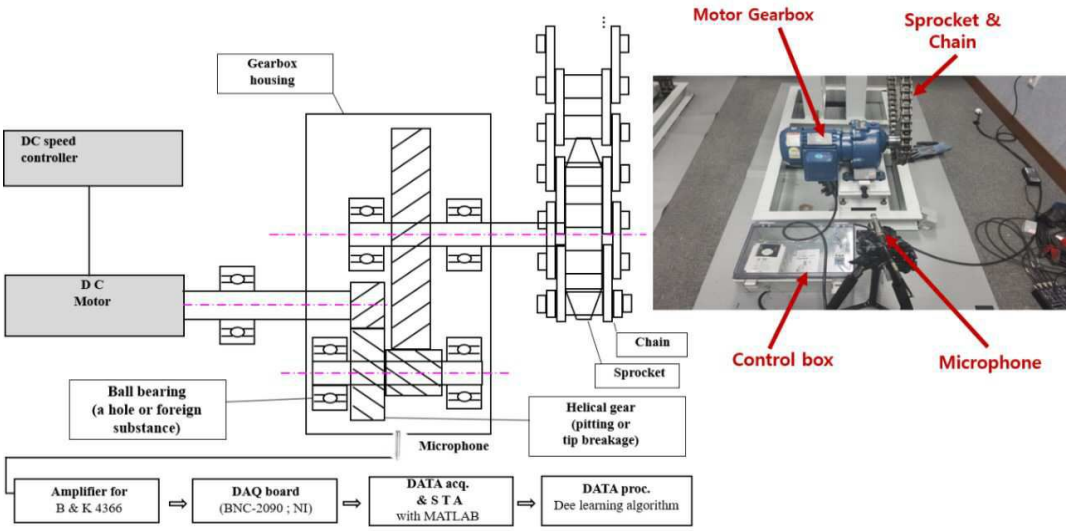
Motor Gearbox
Sprocket & Chain
Gearbox housing
DC speed controller
D C Motor
Chain
Sprocket
Ball bearing (a hole or foreign substance)
Helical gear (pitting or tip breakage)
Microphone
Control box
Microphone
Amplifier for B & K 4366
DAQ board (BNC-2090 ; NI)
DATA acq. & S T A with MATLAB
DATA proc. Dee learning algorithm

도면5

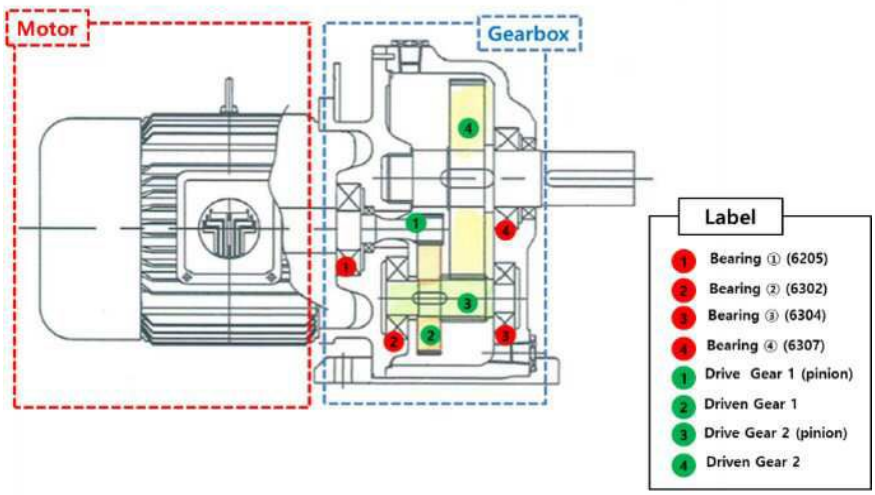
Motor
Gearbox
Label
Bearing ① (6205)
Bearing ② (6302)
Bearing ③ (6304)
Bearing ④ (6307)
Drive Gear 1 (pinion)
Driven Gear 1
Drive Gear 2 (pinion)
Driven Gear 2

도면6

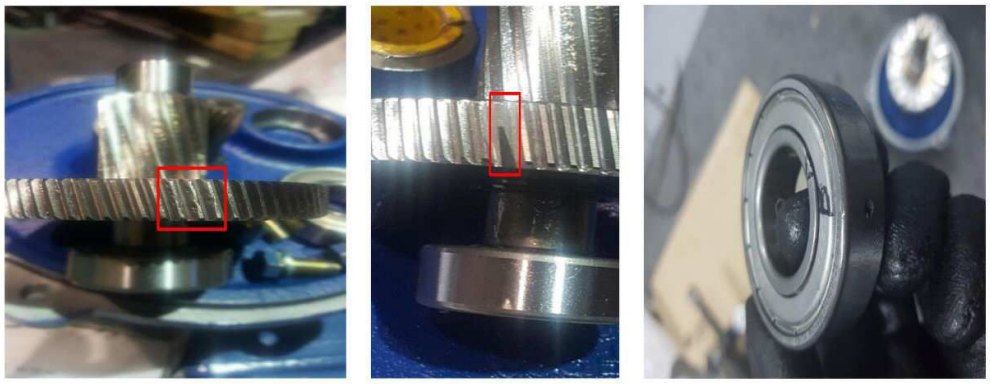

〈구동 기어2의 이 3개 치차 크랙〉 〈구동 기어2의 이 0.5개 치차 절손〉 〈베어링 1의 구멍으로 인한 외륜결함〉

도면7

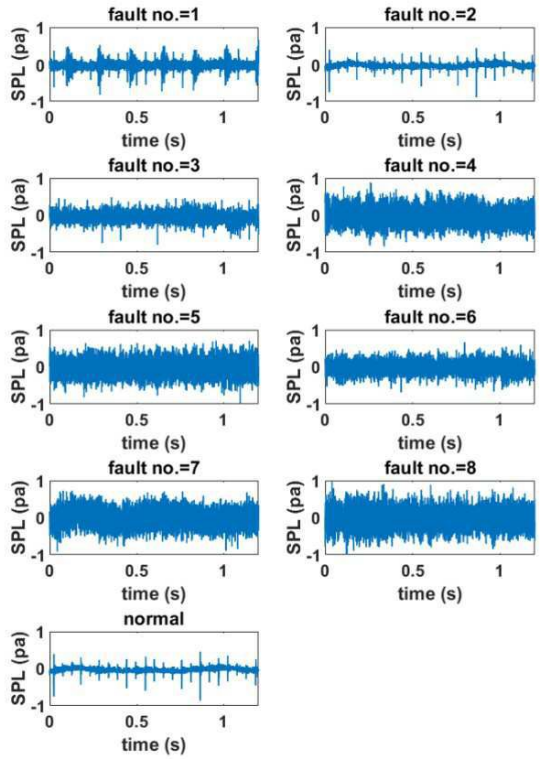

도면8

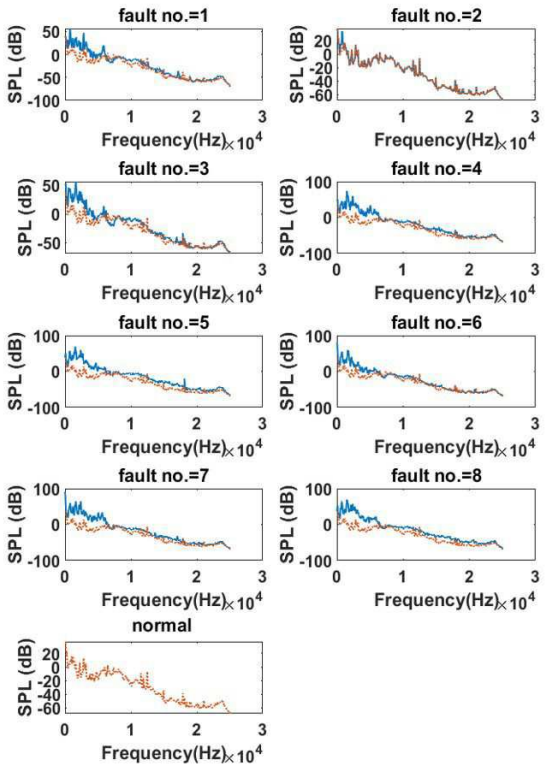
fault no.=1
fault no.=2
fault no.=3
fault no.=4
fault no.=5
fault no.=6
fault no.=7
fault no.=8
normal
SPL (dB)
Frequency(Hz)
×10^4

도면9

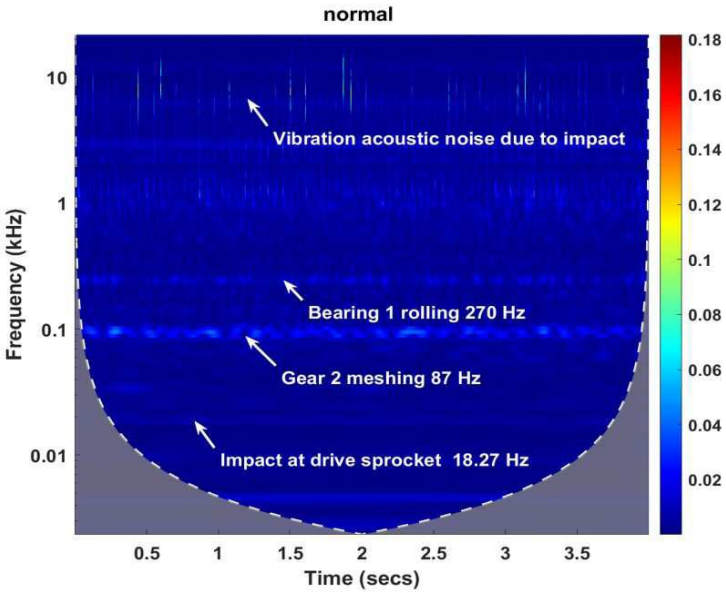
normal
Vibration acoustic noise due to impact
Bearing 1 rolling 270 Hz
Gear 2 meshing 87 Hz
Impact at drive sprocket 18.27 Hz
Frequency (kHz)
Time (secs)

도면10

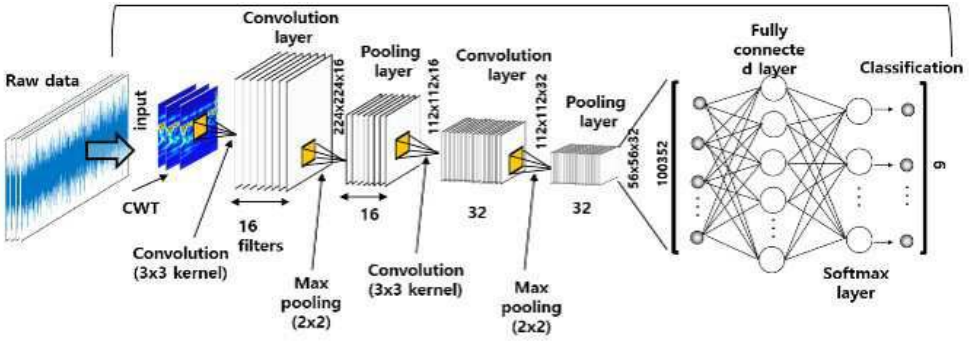

도면11

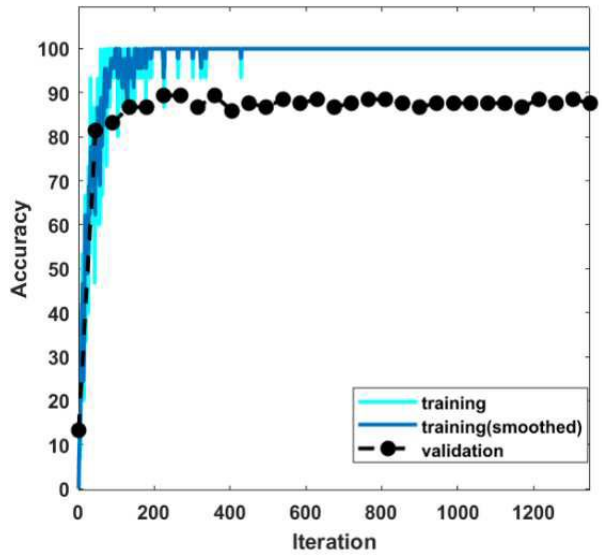

도면12

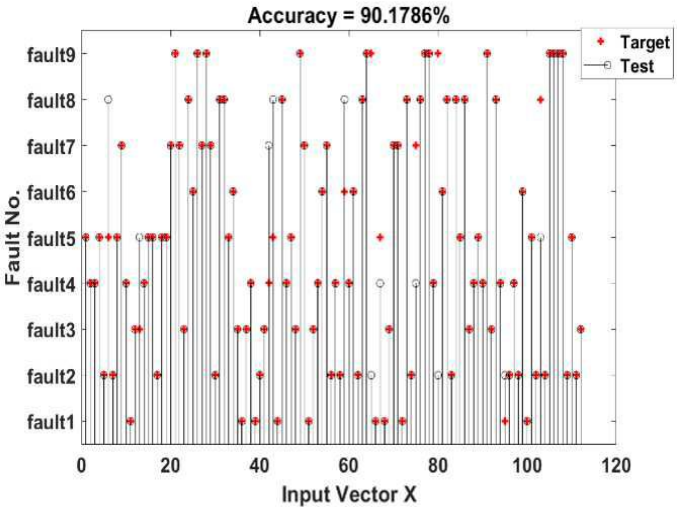

도면13

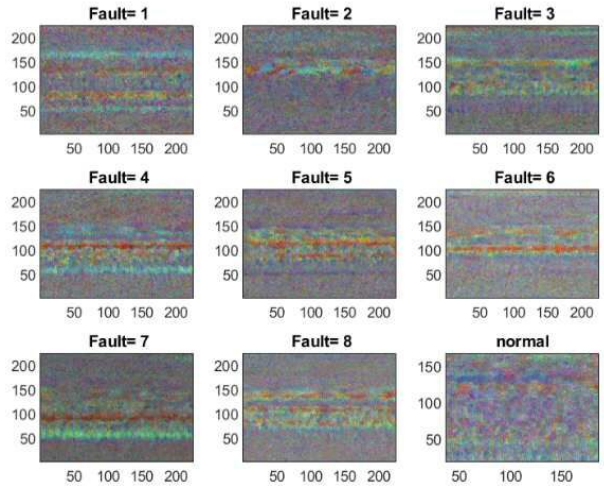
Fault= 1
Fault= 2
Fault= 3
Fault= 4
Fault= 5
Fault= 6
Fault= 7
Fault= 8
normal

도면14

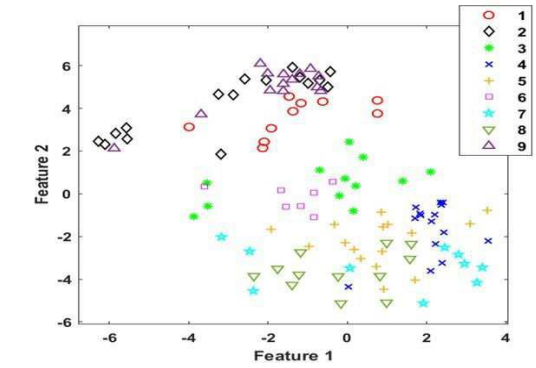
Feature 1
Feature 2
1
2
3
4
5
6
7
8
9

(a)

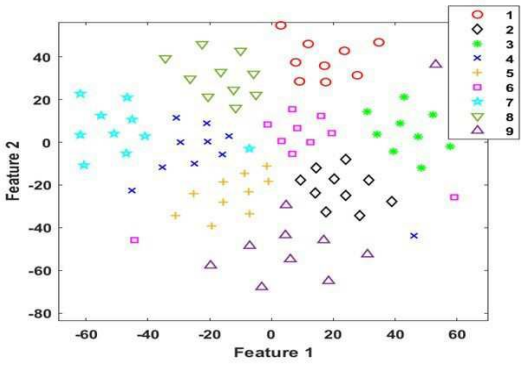
Feature 1
Feature 2
1
2
3
4
5
6
7
8
9

(b)