(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0120896
(43) 공개일자 2023년08월17일

(51) 국제특허분류(Int. Cl.)
G01M 15/11 (2006.01) *G01M 15/06* (2006.01)
G06N 3/04 (2023.01) *G06N 3/08* (2023.01)
(52) CPC특허분류
G01M 15/11 (2013.01)
G01M 15/06 (2013.01)
(21) 출원번호 10-2022-0017712
(22) 출원일자 2022년02월10일
심사청구일자 2022년02월10일

(71) 출원인
울산대학교 산학협력단
울산광역시 남구 대학로 93(무거동)
(72) 발명자
권성오
울산광역시 남구 문수로409번길 23, 203동 803호 (신정동, 문수로아이파크)
샤히드 사이예드 마즈
울산광역시 남구 대학로 93 (무거동)
(74) 대리인
김종선, 이형석

전체 청구항 수 : 총 10 항

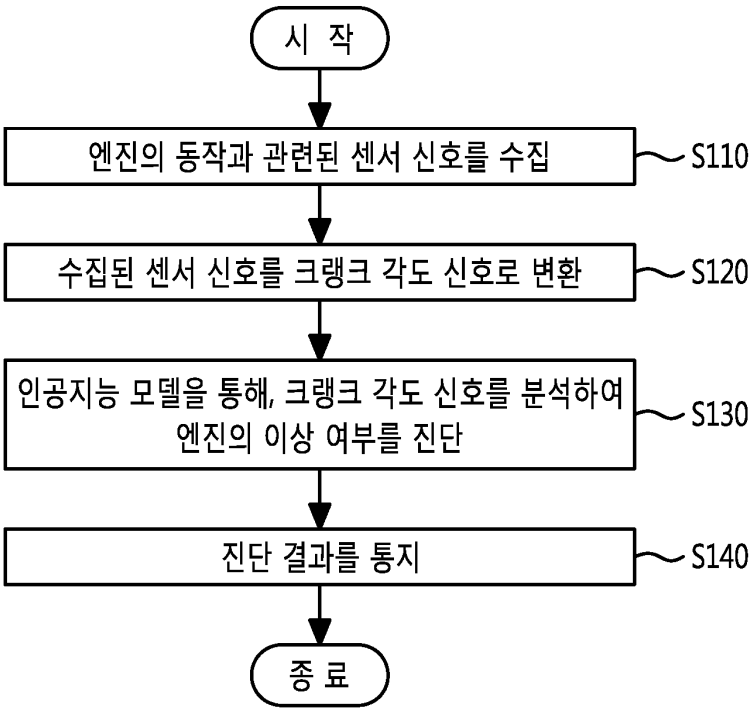
(54) 발명의 명칭 **인공지능 기반의 엔진 이상을 실시간으로 진단하는 방법 및 장치**

(57) 요 약

본 발명은 인공지능 기반의 엔진 이상을 실시간 진단하는 방법 및 장치에 관한 것이다. 상기 방법은 엔진의 동작과 관련된 센서 신호를 수집하는 단계; 상기 수집된 센서 신호를 실린더 내의 크랭크샤프트의 회전각을 나타내는 크랭크 각도(crank angle degree: CAD) 신호로 변환하는 단계; 기 학습된 인공지능 모델을 통해, 상기 변환된 크

(뒷면에 계속)

대 표 도 - 도1a



랭크 각도 신호를 분석하여 상기 엔진의 이상 여부를 감지하는 단계; 및 상기 인공지능 모델을 통해 상기 감지된 엔진 이상의 타입을 분류하는 단계를 포함할 수 있다. 본 발명의 일 실시 예는 다양한 엔진 이상을 효율적으로(예: 정확하고 빠르게(실시간으로)) 진단(예: 검출 및 분류)할 수 있고, 엔진 이상을 빠르고 정확하게 진단할 수 있어 사용자의 신뢰성을 향상시킬 수 있으며, 쉘로우 구조(shallow architecture)의 인공 신경망(예: 1차원 CNN(convolution neural network))을 이용함에 따라 학습 및 진단 시간을 감소할 수 있는 효과를 제공할 수 있다.

(52) CPC특허분류
G06N 3/04 (2023.01)
G06N 3/08 (2023.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345334517
과제번호	2021R1I1A3A04037415
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	지역대학우수과학자지원사업(후속)
연구과제명	5GB/6G환경에서 초밀집 소형셀 네트워크 최적화 방안 연구
기 여 율	1/1
과제수행기관명	울산대학교 산학협력단
연구기간	2021.06.01 ~ 2022.02.28

명 세 서

청구범위

청구항 1

인공지능 기반의 엔진 이상을 실시간으로 진단하는 방법에 있어서,

엔진의 동작과 관련된 센서 신호를 수집하는 단계;

상기 수집된 센서 신호를 실린더 내의 크랭크샤프트의 회전각을 나타내는 크랭크 각도(crank angle degree: CAD) 신호로 변환하는 단계;

기 학습된 인공지능 모델을 통해, 상기 변환된 크랭크 각도 신호를 분석하여 상기 엔진의 이상 여부를 감지하는 단계; 및

상기 인공지능 모델을 통해 상기 감지된 엔진 이상의 타입을 분류하는 단계를 포함하는 것을 특징으로 하는 방법.

청구항 2

제 1 항에 있어서,

상기 변환된 크랭크 각도 신호를 정규화 및/또는 필터링하는 단계를 더 포함하는 것을 특징으로 하는 방법.

청구항 3

제 1 항에 있어서,

상기 센서 신호는

상기 크랭크 샤프트의 움직임을 시간 도메인 상에서 센싱한 신호인 것을 특징으로 하는 방법.

청구항 4

제 1 항에 있어서,

상기 엔진 이상의 타입을 분류하는 단계는

상기 크랭크 각도 신호로부터 특징을 추출하는 단계; 및

상기 추출된 특징에 기초하여 엔진 상태를 정상, 실화(misfire), 또는 부하 변화 중 하나로 분류하는 단계를 포함하는 것을 특징으로 하는 방법.

청구항 5

제 1 항에 있어서,

상기 변환하는 단계는

상기 센서 신호를 전처리하고, 상기 전처리된 센서 신호로부터 기본 신호(primary signal)를 추출하는 단계; 및

상기 기본 신호를 1차원 크랭크 각도 신호로 변환하는 단계를 포함하는 것을 특징으로 하는 방법.

청구항 6

제 1 항에 있어서,

상기 인공지능 모델은 1차원의 컨볼루션 뉴럴 네트워크(convolution neural network: CNN)기반의 인공 신경망으로, 쉘로우 구조(shallow architecture)를 가지는 것을 특징으로 하는 방법.

청구항 7

인공지능 기반의 엔진 이상을 실시간으로 진단하는 장치에 있어서,

상기 엔진의 동작을 센싱하여 센서 신호를 수집하는 센서 모듈;

인공지능 모델을 저장하는 메모리; 및

상기 수집된 센서 신호를 실린더 내의 크랭크샤프트의 회전각을 나타내는 크랭크 각도(crank angle degree: CAD) 신호로 변환하고, 상기 인공지능 모델을 통해 상기 변환된 크랭크 각도 신호를 분석하여 상기 엔진의 이상 여부를 진단하는 프로세서를 포함하는 것을 특징으로 하는 장치.

청구항 8

제 7 항에 있어서,

상기 프로세서는

상기 센서 신호를 전처리하고, 상기 전처리된 센서 신호로부터 기본 신호(primary signal)를 추출하고, 상기 추출된 기본 신호를 1차원 크랭크 각도 신호로 변환하는 것을 특징으로 하는 장치.

청구항 9

제 7 항에 있어서,

상기 프로세서는

상기 인공지능 모델을 이용하여 상기 크랭크 각도 신호로부터 특징을 추출하고, 상기 추출된 특징에 기초하여 엔진 상태를 정상, 실화(misfire), 또는 부하 변화 중 하나로 분류하는 것을 특징으로 하는 장치.

청구항 10

제 7 항에 있어서,

상기 프로세서는

상기 인공지능 모델을 통해 상기 크랭크 각도 신호를 분석하기 전에 상기 크랭크 각도 신호의 정규화 및/또는 필터링을 수행하는 것을 특징으로 하는 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 인공지능(artificial intelligence, AI) 기반의 엔진 이상을 실시간으로 진단하는 방법 및 장치에 관한 것이다.

배 경 기 술

[0002] 자동차의 엔진은 점화 또는 연료 시스템의 결함(또는 이상) 시 실린더 내에서 실화(misfire)가 발생할 수 있다.

실린더 내의 실화는 엔진의 효율성을 저하시키고, 연료 손실 및 배기 가스 배출의 증가시켜 엔진의 수명을 저하시킬 수 있다. 또한, 엔진은 광범위한 범위의 부하에서 작동한다. 따라서, 엔진의 효율성을 높이기 위해서는 엔진 부하 조건의 변화에 대응하여 엔진 동작을 제어해야 한다.

[0003] 상술한 엔진의 이상(예: 실화(misfire) 및/또는 부하 조건의 변화)를 감지하여 적절히 대처하지 못하는 경우 엔진이 파손될 수 있다. 따라서, 최근에는 엔진의 이상 여부를 빠르고(예: 실시간) 정확하게 진단할 수 있는 방법 및 장치가 요구되고 있다.

발명의 내용

해결하려는 과제

[0004] 본 발명은, 전술한 종래 기술의 문제점을 해결하기 위한 것으로, 엔진 동작과 관련된 다양한 엔진 이상 여부를 효율적으로(빠르고 정확하게) 진단할 수 있는 인공지능 기반의 엔진 이상을 실시간으로 진단하는 방법 및 장치를 제공할 수 있다.

과제의 해결 수단

[0005] 이와 같은 목적을 달성하기 위한 본 발명의 일 실시예에 따른 인공지능 기반의 엔진 이상을 실시간으로 진단하는 방법은 엔진의 동작과 관련된 센서 신호를 수집하는 단계; 상기 수집된 센서 신호를 실린더 내의 크랭크샤프트의 회전각을 나타내는 크랭크 각도(crank angle degree: CAD) 신호로 변환하는 단계; 기 학습된 인공지능 모델을 통해, 상기 변환된 크랭크 각도 신호를 분석하여 상기 엔진의 이상 여부를 감지하는 단계; 및 상기 인공지능 모델을 통해 상기 감지된 엔진 이상의 타입을 분류하는 단계를 포함할 수 있다.

[0006] 본 발명의 일 실시예에 따른 인공지능 기반의 엔진 이상을 실시간으로 진단하는 장치는 상기 엔진의 동작을 센싱하여 센서 신호를 수집하는 센서 모듈; 인공지능 모델을 저장하는 메모리; 및 상기 수집된 센서 신호를 실린더 내의 크랭크샤프트의 회전각을 나타내는 크랭크 각도(crank angle degree: CAD) 신호로 변환하고, 상기 인공지능 모델을 통해 상기 변환된 크랭크 각도 신호를 분석하여 상기 엔진의 이상 여부를 진단하는 프로세서를 포함할 수 있다.

발명의 효과

[0007] 본 발명의 일 실시 예는 다양한 엔진 이상을 효율적으로(예: 정확하고 빠르게(실시간으로)) 진단(예: 검출 및 분류)할 수 있다. 또한, 본 발명은 엔진 이상을 감지하는 장치(또는 시스템)의 효율성을 향상(예: 성능 및 속도 향상)시킬 수 있다. 또한, 본 발명은 엔진 이상을 빠르고 정확하게 진단할 수 있어, 사용자의 신뢰성을 향상시킬 수 있다. 또한, 본 발명은 쉘로우(shallow) 구조의 인공 신경망(예: 1차원 CNN(convolution neural network))을 이용함에 따라 학습 및 진단 시간을 감소할 수 있다.

도면의 간단한 설명

[0008] 도 1a는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 방법을 도시한 흐름도이다.

도 1b는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 절차를 개략적으로 도시한 도면이다.

도 2는 본 발명의 일 실시 예에 따른 센서를 통해 획득된 센서 신호를 도시한 도면이다.

도 3a는 본 발명의 일 실시 예에 따른 다양한 부하 조건에서 측정된 크랭크 각도 신호를 도시한 그래프이다.

도 3b 및 도 3c는 본 발명의 일 실시 예에 따른 실화 시 측정된 크랭크 각도 신호를 도시한 그래프이다.

도 4는 본 발명의 일 실시 예에 따른 전처리된 크랭크 각도 신호를 도시한 도면이다.

도 5a는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치의 구성을 도시한 블록도이다.

도 5b는 본 발명의 일 실시 예에 따른 엔진 이상을 진단하는 인공지능 모델의 구조를 개략적으로 도시한 도면이다.

도 6a 및 도 6b는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치 및 종래의 인공 신

경망 기반의 진단 장치들의 성능을 비교한 결과를 도시한 그래프이다.

발명을 실시하기 위한 구체적인 내용

[0009] 이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시예를 상세히 설명한다. 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시예들을 참조하면 명확해질 것이다. 그러나 본 발명은 이하에서 개시되는 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 것이며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하며, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 발명은 청구항의 범주에 의해 정의될 뿐이다. 이하에서 동일한 참조 부호는 동일 구성 요소를 지칭한다.

[0010] 비록 제1, 제2 등이 다양한 소자, 구성요소 및/또는 섹션들을 서술하기 위해서 사용되나, 이들 소자, 구성요소 및/또는 섹션들은 이들 용어에 의해 제한되지 않음은 물론이다. 이들 용어들은 단지 하나의 소자, 구성요소 또는 섹션들을 다른 소자, 구성요소 또는 섹션들과 구별하기 위하여 사용하는 것이다. 따라서, 이하에서 언급되는 제1 소자, 제1 구성요소 또는 제1 섹션은 본 발명의 기술적 사상 내에서 제2 소자, 제2 구성요소 또는 제2 섹션일 수도 있음은 물론이다.

[0011] 본 명세서에서 사용된 용어는 실시예들을 설명하기 위한 것이며 본 발명을 제한하고자 하는 것은 아니다. 본 명세서에서, 단수형은 문구에서 특별히 언급하지 않는 한 복수형도 포함한다. 명세서에서 사용되는 "포함한다(comprises)" 및/또는 "이루어지다(made of)"는 언급된 구성요소, 단계, 동작 및/또는 소자는 하나 이상의 다른 구성요소, 단계, 동작 및/또는 소자의 존재 또는 추가를 배제하지 않는다.

[0012] 다른 정의가 없다면, 본 명세서에서 사용되는 모든 용어(기술 및 과학적 용어를 포함)는 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 공통적으로 이해될 수 있는 의미로 사용될 수 있을 것이다. 또한, 일반적으로 사용되는 사전에 정의되어 있는 용어들은 명백하게 특별히 정의되어 있지 않는 한 이상적으로 또는 과도하게 해석되지 않는다.

[0013] 이하, 첨부된 도면을 참조하여 본 발명의 구성에 대하여 상세히 설명한다.

[0014] 도 1a는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 방법을 도시한 흐름도이고, 도 1b는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 절차를 개략적으로 도시한 도면이고, 도 2는 본 발명의 일 실시 예에 따른 센서를 통해 획득된 센서 신호를 도시한 도면이고, 도 3a는 본 발명의 일 실시 예에 따른 다양한 부하 조건에서 측정된 크랭크 각도 신호를 도시한 그래프이고, 도 3b 및 도 3c는 본 발명의 일 실시 예에 따른 실화 시 측정된 크랭크 각도 신호를 도시한 그래프이며, 도 4는 본 발명의 일 실시 예에 따른 전처리된 크랭크 각도 신호를 도시한 도면이다.

[0015] 도 1a 내지 도 4를 참조하면, 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 방법(이하, 진단 방법)은 엔진의 동작과 관련된 센서 신호(또는 데이터)를 수집하는 단계(S110)를 포함할 수 있다. 상기 S110 단계는, 도 1b에 도시된 바와 같이, 데이터 획득 시스템(12)이 엔진(11)(예: 디젤 엔진)에 연결된 센서(예: MPU(magnetic pickup) 센서)를 통해 측정되는 센서 신호(13)를 수집하는 단계일 수 있다. 상기 센서는 지정된 샘플링 레이트(예: 10 MHz)로 실린더 내의 크랭크샤프트(crankshaft)(또는 캠샤프트(camshaft))의 움직임(예: 회전 속도 또는 각속도)을 센싱할 수 있다. 상기 센서 신호(13)는, 이에 한정되지는 않지만, 도 2에 도시된 바와 같은 형태를 가질 수 있다. 상기 센서 신호(13)로부터 추출되는 한 주기 신호(single-period signal)(13-1)(또는 기본 신호(primary signal)로 명칭)는 m 개의 teeth(m-1 개의 teeth + 1개의 missing tooth)를 포함할 수 있다. 어떤 실시 예에 따르면, 상기 한 주기 신호는 다수 개(예: 2개)의 missing teeth를 포함할 수 있다.

[0016] 일 실시 예에 따르면, 상기 진단 방법은 수집된 센서 신호를 크랭크 각도(crank angle degree: CAD) 신호로 변환하는 단계(S120)를 포함할 수 있다. 상기 S120 단계는 각 실린더의 점화장치(ignition)의 크랭크 각도에 기초하여, 시간 도메인 상의 한 주기 신호(13-1)를 크랭크 각도 신호로 변환할 수 있다. 예를 들어, 상기 S120 단계는 상기 센서 신호를 전처리하여 기본 신호(primary signal)를 추출(S121)하고, 추출된 기본 신호를 1차원 크랭크 각도 신호로 변환(S122)할 수 있다. 여기서, 상기 크랭크 각도 신호는 점화중인 실린더의 연소 행정 동작(behavior of the combustion strokes)을 나타낸다. 한 주기의 신호(13-1)에서 한 tooth의 크랭크 각도는 "a"이고, M개의 teeth는 크랭크샤프트의 2회전(two revolutions)에 해당하는 "M x a"의 크랭크 각도를 가진다. 이때, 한 tooth의 크랭크 각도를 알고 있는 바, 각 tooth의 너비를 측정하여 한 주기 신호(13-1)를 크랭크 각도

신호로 변환할 수 있다. 즉, 크랭크 각도 신호(X[n])는 아래의 <식 1>과 같이 표현될 수 있다.

[0017] $X[n] = W_l;\ n = 1a, 2a, 3a, \cdots\cdots, Ma$ ····· <식 1>

[0018] 상기 <식 1>에서, W_l는 tooth 1의 폭(width)이고, "a"는 tooth의 크랭크 각도이고, "M"은 센서 신호에 포함된 teeth의 전체 수이고, "1"은 "n/a"이다. 상기 변환된 크랭크 각도 신호는 1차원 벡터 값일 수 있다.

[0019] 일 실시 예에 따르면, 상기 진단 방법은 기 학습된 인공지능 모델을 통해 상기 변환된 크랭크 각도 신호를 분석하여 엔진의 이상 여부를 진단(예: 감지 및 분류)하는 단계(S130)를 포함할 수 있다. 상기 S130 단계는 크랭크 각도 신호에 기초하여 엔진의 내부 연소(internal combustion: IC) 프로세스(process)를 분석하여 엔진 이상(예: 실화(misfire), 부하 변화)을 진단할 수 있다.

[0020] 인공지능 모델(30)은, 도 1b에 도시된 바와 같이, CNN(convolution neural network) 기반의 분류기(classifier)일 수 있다. 인공지능 모델(30)은 학습부(31) 및 진단부(32)를 포함할 수 있다. 학습부(31)는 다양한 훈련 데이터(training data)에 기초하여 인공지능 모델(30)의 학습(예: 지도 학습(supervised learning))을 지원할 수 있다. 상기 훈련 데이터는, 도 3a 내지 도 3c에 도시된 바와 같이, 정상 상태 또는 이상 상태를 가지며 다양한 부하 조건을 가지는 엔진들로부터 실제로 측정된 크랭크 각도 신호들에 대응할 수 있다. 여기서, 도 3a는 정상 상태의 엔진에서 로드 "100%"인 경우와 "50 %"일때 측정된 크랭크 각도 신호들이고, 도 3a는 정상 상태의 엔진에서 부하가 "100%" 및 "50 %"일때 측정된 크랭크 각도 신호들이고, 도 3b는 부하 50 % 상태에서 실화가 발생하지 않았을 때, 및 다수의 실린더 중 하나("A1")에서 실화가 발생했을 때 측정된 크랭크 각도 신호들이며, 도 3c는 부하 75 % 상태에서 실화가 발생하지 않았을 때 및 다수의 실린더 중 다른 하나("A6")에서 실화가 발생했을 때 측정된 크랭크 각도 신호들이다. 이와 같이, 엔진의 상태에 따라 크랭크 각도 신호가 달라진다. 학습부(31)는 학습을 통해 각 엔진 상태와 해당 상태에서의 크랭크 각도 데이터를 매핑할 수 있다.

[0021] 진단부(32)는 크랭크 각도 신호에 기초하여 엔진 이상 여부를 진단(예: 이상 감지 및 이상 타입을 분류)할 수 있다. 예를 들어, 진단부(32)는, 학습부(31)의 학습 결과(매핑 결과)에 기초하여, 입력된 크랭크 각도 신호에 대응하는 엔진 상태로 진단할 수 있다. 진단부(32)는, 이에 한정되지는 않지만, 도 1b에 도시된 바와 같이, 엔진의 상태를 정상(normal), 실화(misfire), 또는 로드 변화(load change) 중 어느 하나로 분류할 수 있다.

[0022] 어떤 실시 예에 따르면, 상기 변환된 크랭크 각도 신호는, 인공지능 모델에 의해 분석되기 전에 전처리(예: 정규화 및/또는 필터링)될 수 있다. 예를 들어, 상기 변환된 크랭크 각도 신호는, 도 4의 식별 부호 410에 도시된 바와 같이, 정규화될 수 있다. 상기 변환된 크랭크 각도 신호(X[n])는 아래의 <식 2>에 의해 정규화될 수 있다.

[0023] $$\bar{X}[n] = \frac{X[n] - \min_n X[n]}{\max_n X[n] - \min_n X[n]}$$ ····· <식 2>

[0024] 상기 변환된 크랭크 각도 신호를 정규화함에 따라, 본 발명은 인공지능 모델(30)의 훈련(training) 속도를 향상시킬 수 있고, 국소 최적점(local optima) 문제에 빠질 가능성을 감소시킬 수 있다. 이로 인하여, 본 발명은 인공지능 모델의 안정성 및 성능을 향상시킬 수 있다.

[0025] 다른 예로, 상기 변환된 크랭크 각도 신호는, 도 4의 식별 부호 420에 도시된 바와 같이, 원치않는 노이즈 성분을 제거하기 위하여 필터링(예: moving average filter의 적용)될 수 있다.

[0026] 일 실시 예에 따르면, 상기 진단 방법은 진단 결과를 통지하는 단계(S140)를 포함할 수 있다. 예를 들어, 상기 S140 단계는 진단 결과를 출력 장치(예: 스피커, 디스플레이)를 통해 사용자에게 통지할 수 있다. 다른 예로, 상기 S140 단계는 통신 장치를 통해 진단 결과를 외부 장치로 송신할 수 있다.

[0027] 도 5a는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치의 구성을 도시한 블록도이고, 도 5b는 본 발명의 일 실시 예에 따른 엔진 이상을 진단하는 인공지능 모델의 구조를 개략적으로 도시한 도면이다.

[0028] 도 5a 및 도 5b를 참조하면, 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치(500)(이하, 진단 장치)는 엔진(미도시)을 포함하는 이동 장치(예: 자동차)에 포함될 수 있다. 상기 진단 장치(500)는 메모리(510), 디스플레이(520), 프로세서(530), 및 센서 모듈(540)을 포함할 수 있다.

[0029] 메모리(510)는 프로세서(530)와 전기적으로 연결될 수 있고, 진단 장치(500)를 동작시키기 위한 다양한 프로그램들, 및 프로세서(530)를 동작시키기 위한 다양한 명령 및/또는 인스트럭션들을 저장할 수 있다. 메모리(510)

는 내장 메모리 또는 외장 메모리 중 적어도 어느 하나를 포함할 수 있다. 내장 메모리는 휘발성 메모리(예: DRAM, SRAM, 또는 SDRAM 등), 비휘발성 메모리(예: OTPROM(one time programmable ROM), PROM, EPROM, EEPROM, mask ROM, flash ROM, 플래시 메모리, 하드 드라이브, 또는 솔리드 스테이트 드라이브(SSD) 중 적어도 하나를 포함할 수 있다. 외장 메모리는 다양한 인터페이스를 통하여 진단 장치(500)와 연결될 수 있는 SD(secure digital), Micro-SD, Mini-SD, 또는 USB(universal serial bus) 메모리 등을 포함할 수 있다.

[0030] 메모리(510)는 인공지능 모델(511)을 포함할 수 있다. 인공지능 모델(511)은, 도 1 내지 도 4를 참조하여 상술한 바와 같이, 학습 데이터에 기초하여 학습(예: 지도 학습)될 수 있고, 학습 결과에 기초하여 엔진의 이상 여부를 진단할 수 있다.

[0031] 인공지능 모델(511)은 1차원 CNN 기반의 인공 신경망으로, 크랭크 각도 벡터에 기초하여 학습되고, 크랭크 각도 신호를 기초로 엔진의 이상 여부를 진단할 수 있다. 인공지능 모델(511)은, 도 5b에 도시된 바와 같이, 입력부(51), 특징 추출부(52), 분류부(53) 및 출력부(54)를 포함할 수 있다. 입력부(51)는 크랭크 각도 신호가 입력될 수 있다. 크랭크 각도 신호는 센서 모듈(540)에 의해 측정된 센서 신호를 변환하여 획득될 수 있다. 특징 추출부(52)는 입력된 크랭크 각도 신호의 특징을 추출할 수 있다. 특징 추출부(52)는 컨볼루션 레이어(52-1), 활성화 레이어(activation layer)(52-2), 및 맥스 풀링 레이어(52-3)를 포함할 수 있다.

[0032] 컨볼루션 레이어(52-1)는 크랭크 각도 신호로부터 특징을 추출할 수 있다. 예를 들어, 컨볼루션 레이어(52-1)는 입력 데이터의 세그먼트(x_1, x_2, …. x_n)를 동일한 크기의 커널로 컨볼루션하고, 입력 세그먼트로부터 특징을 추출할 수 있다. 컨볼루션 레이어(52-1)는, 이에 한정되지는 않지만, 6개의 커널을 포함하며, 각 커널의 크기는 2일 수 있다. 활성화 레이어(52-2)(예: ReLU)는 출력 특징을 생성할 수 있다. 활성화 레이어(52-2)는 뉴런의 관련성을 기반으로 활성화할 뉴런을 결정할 수 있다.

[0033] 상기 컨볼루션 레이어(52-1) 및 활성화 레이어(52-2)는 아래의 <식 3>에 의해 동작할 수 있다.

[0034]
$$a_{pi}^{l} = f\left(\sum_{j=1}^{h}\left(w_{pj} * \bar{x}_{i+j-1}^{l}\right)\right) \quad \cdots\cdots \quad \text{<식 3>}$$

[0035] 상기 <식 3>에서, a_{pi}^{l} 는 컨볼루션 레이어 "l"에서 p번째 필터의 i번째 뉴런의 출력을 의미하고, "f[]"는 활성화 함수이고, "h"는 필터 길이를 의미하고, "*"는 컨볼루션 연산을 의미하고, "Wpj"는 p번째 필터의 j번째 뉴런의 가중치를 의미하고, $\bar{x}_{i+j-1}^{l}$ 는 컨볼루션 레이어 "l"에서 p번째 필터의 i번째 뉴런의 입력을 의미한다.

[0036] 맥스 풀링 레이어(52-3)는 구조적 복잡성을 줄이고 과적합(overfitting)을 피하기 위하여 추가될 수 있다. 예를 들어, 맥스 풀링 레이어(52-3)는 활성화 레이어(52-2)의 출력 특징을 다운 샘플링할 수 있다. 이때, 서브 샘플링 계수(subsampling factor)는, 이에 한정되지는 않지만, 2로 설정될 수 있다.

[0037] 분류부(53)는 플랫 레이어(flatten layer)(53-1), 풀리 커넥티드 레이어(fully connected layer)(53-2), 및 출력 레이어(53-3)를 포함할 수 있다. 플랫 레이어(flatten layer)(53-1)는 2차원 특징 매트릭스를 풀리 커넥티드 레이어(53-2)로 입력되는 벡터로 변환할 수 있다. 풀리 커넥티드 레이어(53-2)는 다수(예: 200 개)의 뉴런으로 구성되며, 활성화 함수(예: ReLU)를 포함할 수 있다.

[0038] 출력 레이어(53-3)는 출력 클래스(예: 이상 타입)에 대한 확률 분포를 생성할 수 있다. 상기 출력 레이어(53-3)는, 이에 한정되지는 않지만, softmax 활성화 함수일 수 있다. softmax 활성화 함수는 아래의 <식 4>를 이용하여, 로짓을 확률로 변환할 수 있다.

[0039]
$$\mathrm{softmax}(y_o) = \frac{e^{y_o}}{\sum_{o=1}^{3} e^{y_o}} \quad \cdots\cdots\cdots \quad \text{<식 4>}$$

[0040] 상기 <식 4>에서, "y_o"는 출력 레이어 "y"의 "o"번째 로짓을 의미한다.

[0041] 출력부(54)는 분류부(53)에 의해 출력된 확률 분포에 기초하여 엔진 이상의 타입을 결정하여 출력할 수 있다. 여기서, 결정된 엔진 이상의 타입은, 이에 한정되지는 않지만, 정상(y_1), 실화(y_2), 및 로드 변화(y_3) 중 하나일 수 있다.

[0042] 본 발명의 일 실시 예에 따르면, 인공지능 모델(511)은, 이에 한정되지는 않지만, 아래의 <표 1>과 같은 구조적 파라미터를 포함할 수 있다.

표 1

Network Layer	Kernel Size	Feature Map
Input layer	-	200×1
Convolution layer	3	198×6
Pooling layer	2	99×6
Flatten layer	-	594
Dense layer	-	200
Softmax	-	3

[0043]

[0044] 일반적으로, 인공지능 모델은 입력 데이터의 길이, 차원(특징맵 크기), 필터의 수, 필터의 길이, 및 컨볼루션 레이어의 수에 의해 시간 복잡도(time complexity)가 결정된다. 본 발명의 일 실시 예에 따른 인공지능 모델(511)은 하나의 컨볼루션 레이어, 하나의 풀링 레이어, 및 하나의 풀리 커넥티드 레이어를 포함하고, 각 레이어가 드랍아웃(dropout)을 가지지 않도록 구현됨에 따라, 시간 복잡도가 현저히 감소된다.

[0045] 디스플레이(520)는 입력 기능 및/또는 출력 기능을 제공할 수 있다. 예를 들어, 디스플레이(520)는 터치 패널 및/또는 표시 패널을 포함할 수 있다. 디스플레이(520)는 진단 결과를 표시할 수 있다.

[0046] 프로세서(530)는 메모리(510)로부터 명령(command) 또는 인스트럭션들(instructions)을 수신하고, 수신된 명령 또는 인스트럭션들에 따라 각 구성 요소들을 제어하여, 다양한 기능들을 수행할 수 있다. 프로세서(530)는 중앙처리 장치(central processing unit: CPU), 마이크로 컨트롤 유닛(micro control unit: MCU), 마이크로 프로세서 유닛(micro processor unit: MPU) 등으로 형성될 수 있다. 본 발명의 일 실시 예에 따른 프로세서(530)는 인공지능 모델(511)의 학습 절차 및 인공지능 모델(511)을 이용한 엔진의 이상 여부를 진단하는 절차를 제어할 수 있다. 예를 들어, 프로세서(530)는, 도 1 내지 도 4를 참조하여 설명한 바와 같이, 센서 모듈(540)을 통해 수집되는 엔진 동작과 관련된 센서 신호를 크랭크 각도 신호로 변환하고, 인공지능 모델(511)을 이용하여 엔진의 이상 여부를 진단(감지 및 분류)할 수 있다.

[0047] 센서 모듈(540)은 엔진 동작과 관련된 센서 신호를 수집할 수 있다. 예를 들어, 센서 모듈(540)은 실린더의 크랭크샤프트의 움직임을 시간 도메인 상에서 센싱할 수 있다. 센서 모듈(540)은, 이에 한정되지는 않지만, MPU(magnetic pickup) 센서일 수 있다.

[0048] 한편, 진단 장치(500)는 외부 장치로 진단 결과를 전송하기 위한 통신 모듈(미도시)을 더 포함할 수 있다. 또한, 어떤 실시 예에 따르면, 인공지능 모델(511)은 외부 서버에 저장될 수 있다. 이러한 경우 진단 장치(500)는, 통신 모듈을 제어하여, 수집된 센서 신호(또는 변환된 크랭크 각도 신호)를 외부 서버로 전송하고, 외부 서버로부터 진단 결과를 수신할 수 있다.

[0049] 도 6a 및 도 6b는 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치 및 종래의 인공 신경망 기반의 진단 장치들의 성능을 비교한 결과를 도시한 그래프이다.

[0050] 도 6a 및 도 6b를 참조하면, 본 발명의 진단 방법은 종래의 진단 방법에 비하여, 정확도(accuracy), MCC(matthews correlation coefficient), 정밀도(precision), 재현율(recall), 및 F1-score 측면에서 뛰어남을 알 수 있다. 여기서, 도 6a는 인공지능 모델의 학습에 사용된 데이터들에 대한 진단 성능을 비교한 그래프이고, 도 6b는 인공지능 모델의 학습에 사용되지 않은 데이터들에 대한 진단 성능을 비교한 그래프이다.

[0051] 한편, 본 발명의 진단 방법 및 종래의 진단 방법의 시간 복잡도는 아래의 [표 2]와 같다.

표 2

ANN-based Classifiers	Time per prediction (μsec)	Training Time (min)
proposed 1D CNN	22	3.9
1D LeNet-5	40	7.2
shallow 1D LeNet-5	16	2.9
adaptive 1D CNN	66	11.9
1D AlexNet	809	146.4

[0052]

[0053] 상기 <표 2>를 참조하면, 본 발명의 진단 방법은 종래의 진단 방법에 비하여 시간 복잡도가 낮음을 알 수 있다. 다만, "shallow 1D LeNet-5"는, 본 발명과 유사하게 쉘로우 1차원 구조를 가지며, 본 발명보다 컨볼루션 레이어가 적은 수의 커널을 이용하기 때문에, 시간 복잡도가 본 발명보다 낮지만, 도 6a 및 도 6b에 도시된 바와 같이, 성능(정확도(accuracy), MCC(matthews correlation coefficient), 정밀도(precision), 재현율(recall), 및 F1-score)이 떨어짐을 알 수 있다.

[0054] 또한, 본 발명의 진단 방법 및 CNN 모델 기반이 아닌 다른 지도 학습 모델을 이용하는 종래의 진단 방법을 비교한 결과는 아래의 [표 3]과 같다.

표 3

Classifiers	Accuracy		MCC		F1-score	
	Train	Test	Train	Test	Train	Test
Proposed 1D CNN	0.999	0.997	0.998	0.996	0.998	0.995
SVM	0.973	0.970	0.951	0.948	0.968	0.963
*k*NN	0.976	0.968	0.968	0.942	0.975	0.966

[0055]

[0056] 상기 <표 3>을 참조하면, 본 발명의 진단 방법은 종래의 진단 방법에 비하여 정확도(accuracy), MCC(matthews correlation coefficient), 및 F1-score 측면에서 좋은 성능을 가짐을 알 수 있다. 이를 통해, 크랭크 각도 신호로부터 특징을 추출하여 이용함에 따라 본 발명은 크랭크 각도 벡터를 직접 이용하는 방법들과 비교하여 가독성(readability)을 증가시킬 수 있다.

[0057] 이상에서 상술한 본 발명의 일 실시 예에 따른 인공지능 기반의 엔진 이상을 진단하는 장치 및 방법은 엔진 작동과 관련된 다수의 불규칙성(irregularities)을 진단하는데 뛰어난 성능을 제공한다. 또한, 쉘로우 1차원 인공신경망(예: CNN)을 이용함에 따라 본 발명은 훈련 및 예측에 대한 시간 소요이 현저하게 감소된다. 이로 인하여, 본 발명은 엔진 이상의 실시간 진단을 지원(제공)할 수 있다.

[0058] 한편, 이상에서는, 정상, 실화, 및 로드 변화를 감지 및 분류하는 것으로 설명하였지만, 본 발명은, 인공지능 모델 더 많은 레이어를 추가하여, 더 많은 엔진 결함(예: 엔진 노크, 크랭크 결함 등)을 탐지하도록 확장될 수 있다.

[0059] 이상과 같이 본 발명의 도시된 실시 예를 참고하여 설명하고 있으나, 이는 예시적인 것들에 불과하며, 본 발명이 속하는 기술 분야의 통상의 지식을 가진 자라면 본 발명의 요지 및 범위에 벗어나지 않으면서도 다양한 변형, 변경 및 균등한 다양한 타 실시 예들이 가능하다는 것을 명백하게 알 수 있을 것이다. 따라서 본 발명의 진정한 기술적 보호 범위는 첨부된 청구범위의 기술적인 사상에 의해 정해져야 할 것이다.

부호의 설명

[0060] 500: 진단 장치

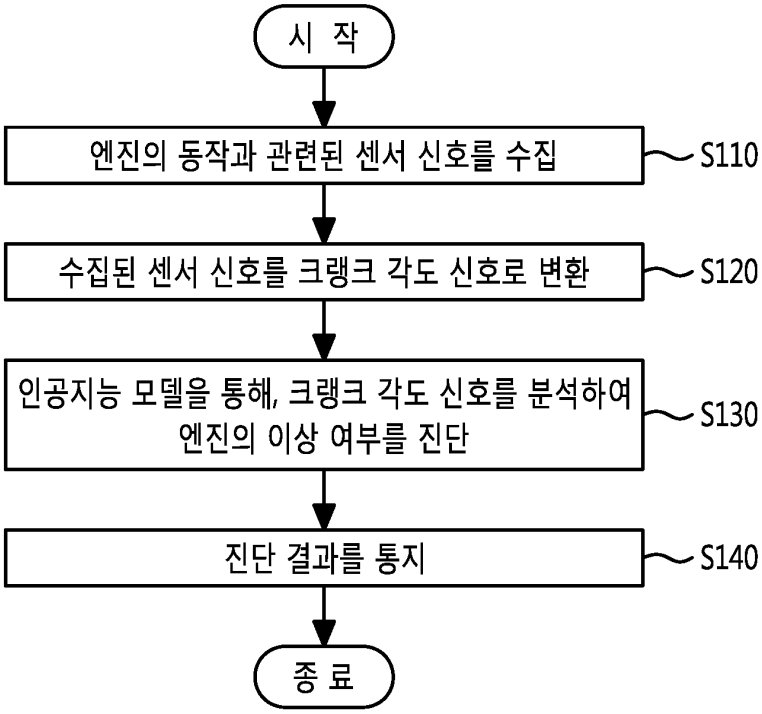
510: 메모리 511: 인공지능 모델

520: 디스플레이 530: 프로세서

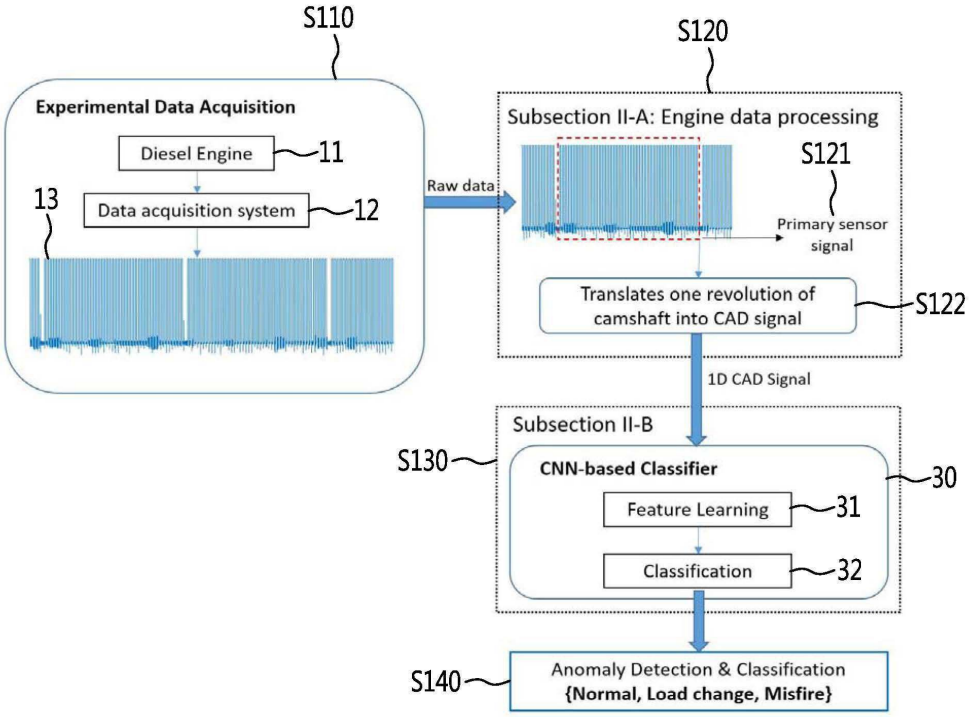
540: 센서 모듈

도면

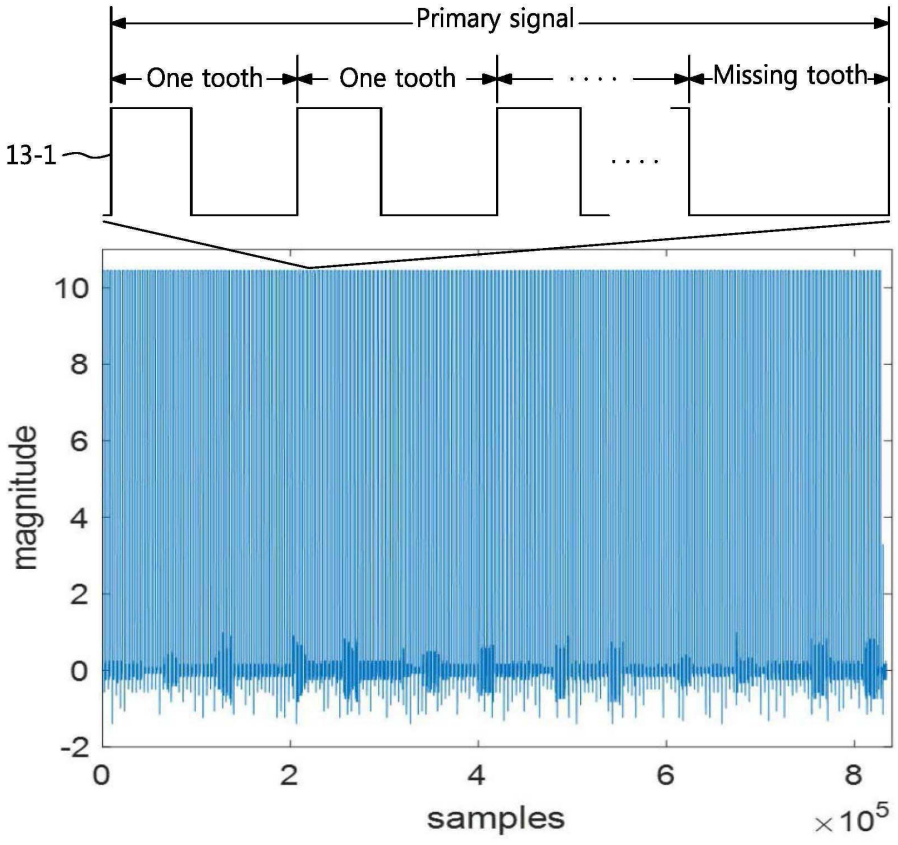
도면1a



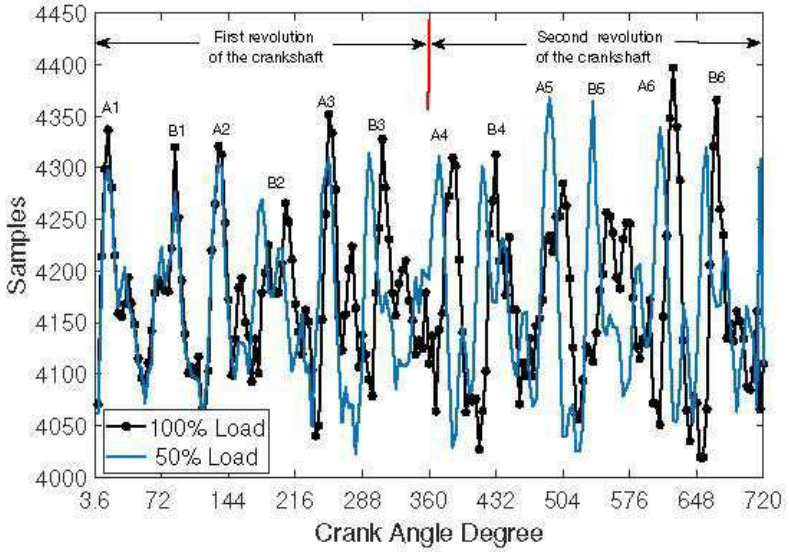
도면1b


S110
S120
Experimental Data Acquisition
Diesel Engine
11
13
Data acquisition system
12
Raw data
Subsection II-A: Engine data processing
S121
Primary sensor signal
Translates one revolution of camshaft into CAD signal
S122
1D CAD Signal
Subsection II-B
S130
CNN-based Classifier
30
Feature Learning
31
Classification
32
S140
Anomaly Detection & Classification
{Normal, Load change, Misfire}

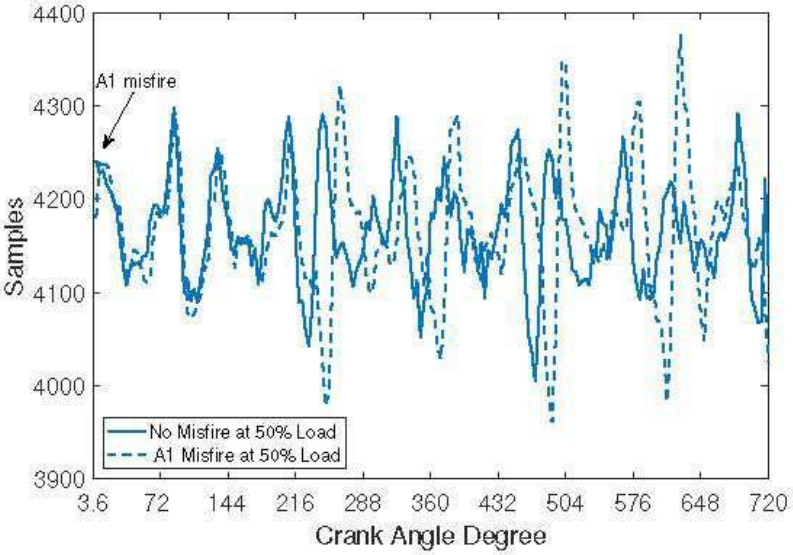
도면2


Primary signal
One tooth
One tooth
Missing tooth
13-1
magnitude
samples
×10^5

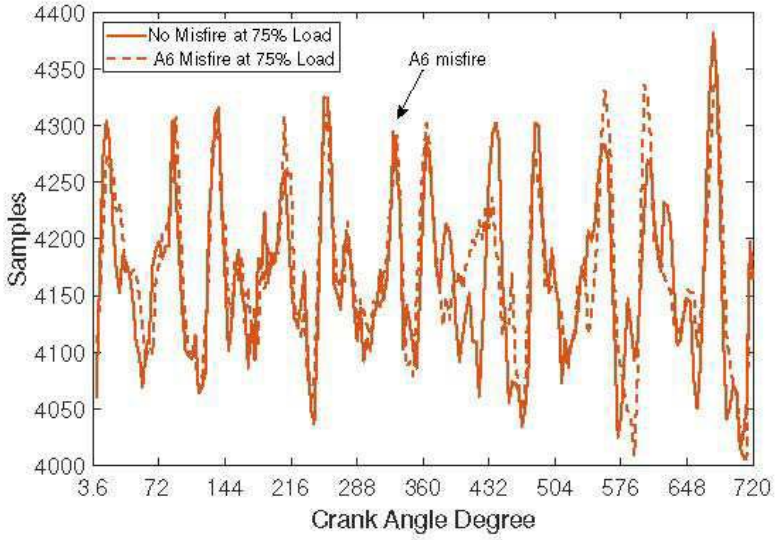
도면3a


First revolution
of the crankshaft
Second revolution
of the crankshaft
A1
B1
A2
B2
A3
B3
A4
B4
A5
B5
A6
B6
Samples
100% Load
50% Load
Crank Angle Degree

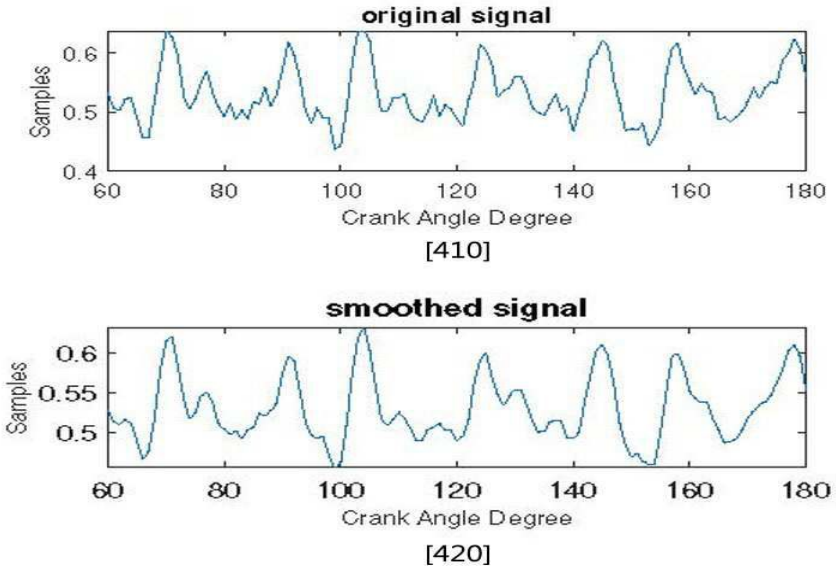
도면3b


A1 misfire
Samples
No Misfire at 50% Load
A1 Misfire at 50% Load
Crank Angle Degree

도면3c



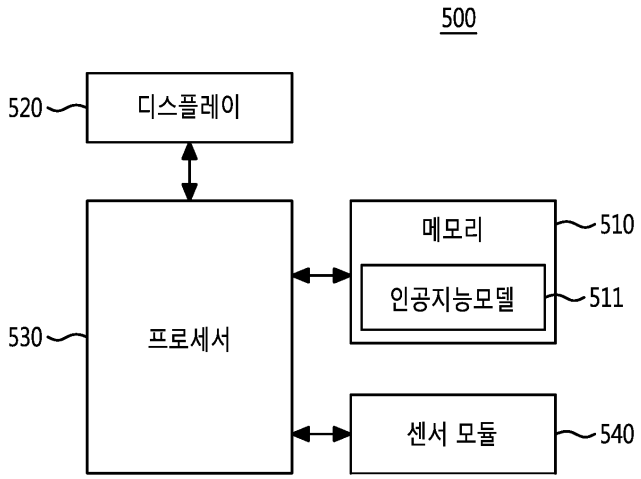
도면4



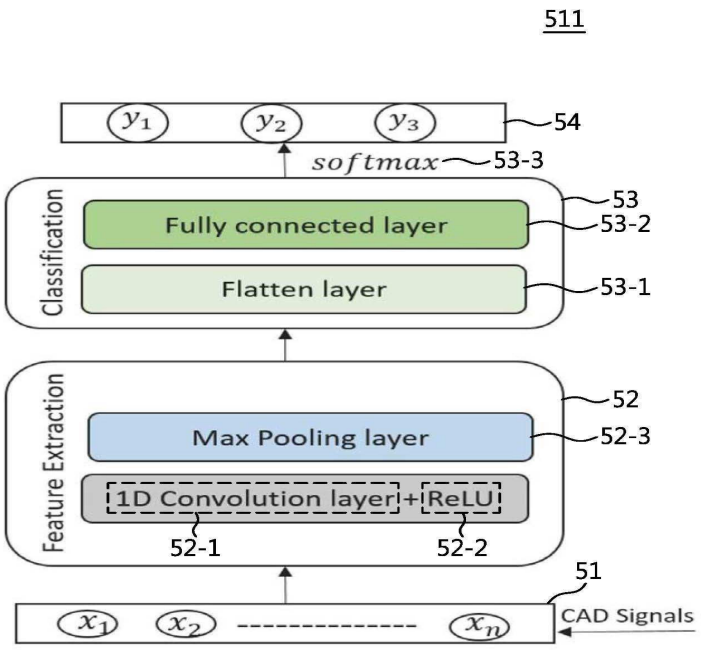
[410]

[420]

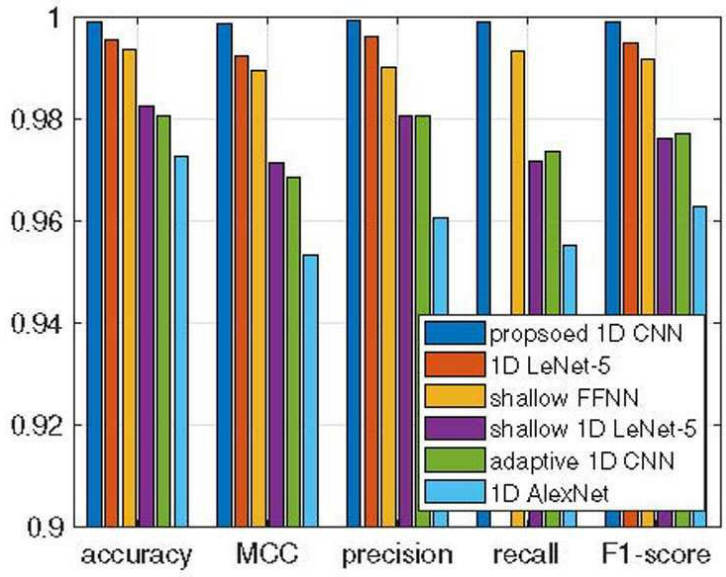
도면5a


500
520
디스플레이
메모리
510
인공지능모델
511
530
프로세서
센서 모듈
540

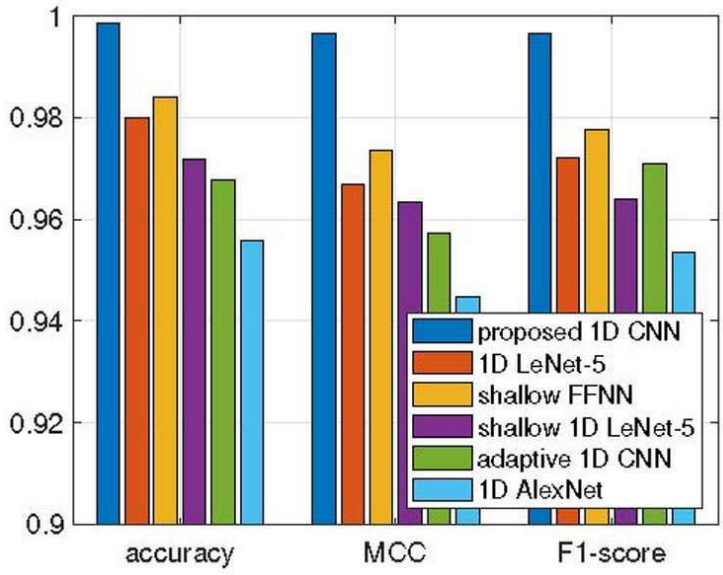
도면5b


511
y_1
y_2
y_3
54
softmax
53-3
Classification
53
Fully connected layer
53-2
Flatten layer
53-1
Feature Extraction
52
Max Pooling layer
52-3
1D Convolution layer+ReLU
52-1
52-2
51
x_1
x_2
x_n
CAD Signals

도면6a


1
0.98
0.96
0.94
0.92
0.9
accuracy
MCC
precision
recall
F1-score
propsoed 1D CNN
1D LeNet-5
shallow FFNN
shallow 1D LeNet-5
adaptive 1D CNN
1D AlexNet

도면6b


1
0.98
0.96
0.94
0.92
0.9
accuracy
MCC
F1-score
proposed 1D CNN
1D LeNet-5
shallow FFNN
shallow 1D LeNet-5
adaptive 1D CNN
1D AlexNet