



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0067694
(43) 공개일자 2025년05월15일

- (51) 국제특허분류(Int. Cl.)
G06N 3/0455 (2023.01) G01H 1/14 (2006.01)
G06N 3/0464 (2023.01) G06N 3/049 (2023.01)
- (52) CPC특허분류
G06N 3/0455 (2023.01)
G01H 1/14 (2013.01)
- (21) 출원번호 10-2024-0117989
(22) 출원일자 2024년08월30일
심사청구일자 없음
- (30) 우선권주장
1020230153659 2023년11월08일 대한민국(KR)
- (71) 출원인
현대자동차주식회사
서울특별시 서초구 현릉로 12 (양재동)
기아 주식회사
서울특별시 서초구 현릉로 12 (양재동)
울산과학기술원
울산광역시 울주군 언양읍 유니스트길 50
- (72) 발명자
이경우
경기도 화성시 남양읍 현대연구소로 150
성대운
경기도 화성시 남양읍 현대연구소로 150
(뒷면에 계속)
- (74) 대리인
박병석

전체 청구항 수 : 총 18 항


(54) 발명의 명칭 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법

(57) 요약

본 발명은 인코더와 디코더 중 적어도 어느 하나에 삽입되어 모든 데이터의 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network: FCN)를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법에 관한 것으로, 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 차량 부품에서 발생하

(뒷면에 계속)

대표도 - 도5



는 진동 신호를 시계열 방식으로 센싱하는 복수의 센서가 배치된 센서부 및 상기 복수의 센서로부터 제공된 센싱 데이터에 기초하여 진동 주파수 데이터를 분석하는 컴퓨팅 장치를 포함하여 이루어지며, 인공지능 구조 기반의 진동 주파수 데이터 분석 방법은 차량 부품에서 발생하는 진동 신호의 센싱 데이터를 시계열 방식으로 수신하는 단계; 수신된 센싱 데이터를 이미지 데이터로 변환하는 단계; 상기 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코딩 단계; 상기 인코딩 단계를 통해 저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코딩 단계; 및 서로 대칭되는 구조를 갖는 상기 인코딩 단계와 디코딩 단계 중 적어도 어느 하나의 단계에 모든 데이터의 상관 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(FCN)를 이용한 중간 처리단계를 포함하여 이루어진다.

(52) CPC특허분류

G06N 3/0464 (2023.01)

G06N 3/049 (2023.01)

(72) 발명자

정영록

경기도 화성시 남양읍 현대연구소로 150

류용현

경기도 화성시 남양읍 현대연구소로 150

이슬기

울산광역시 울주군 언양읍 유니스트길 50

박광렬

울산광역시 울주군 언양읍 유니스트길 50

명세서

청구범위

청구항 1

차량 부품에서 발생하는 진동 신호를 시계열 방식으로 센싱하는 복수의 센서가 배치된 센서부; 및
상기 복수의 센서로부터 제공된 센싱 데이터에 기초하여 진동 주파수 데이터를 분석하는 컴퓨팅 장치를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 2

제1항에 있어서, 상기 컴퓨팅 장치는,

부품에 대한 센싱 데이터를 입력 받아 일정한 간격마다 소정의 윈도우 크기로 슬라이싱(slicing)한 후 샘플링 주기마다 신호 크기를 추출하여 1차원의 신호 입력 벡터를 생성하는 입력 벡터 생성부;

부품에 대한 센싱 데이터를 입력 받아 푸리에 변환을 이용하여 시간에 따라 변하는 센싱 신호를 주파수 성분으로 변환하여 주파수 변환 벡터를 생성하는 신호 변환부; 및

상기 입력벡터 생성부 및 상기 신호 변환부로부터 제공된 신호 입력벡터 및 주파수 변환 벡터를 입력받아 U-Net 구조 기반의 딥러닝 기반 모델을 통해 진동 주파수를 분석하여 복수의 상태 정보를 출력하는 분석부를 포함하여 이루어지는 U-Net 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 3

제2항에 있어서, 상기 분석부는,

상기 센싱 데이터를 이미지 데이터로 변환하는 데이터 변환부;

상기 변환된 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코더(Encoder);

저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코더(Decoder); 및

서로 대칭되는 구조를 갖는 상기 인코더와 디코더 중 적어도 어느 하나에 삽입되어 모든 데이터의 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network: FCN) 블록을 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 4

제3항에 있어서, 상기 완전 연결 네트워크(FCN) 블록이 인코더의 마지막 부분에만 적용된 것을 특징으로 하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 5

제3항에 있어서, 상기 완전 연결 네트워크(FCN) 블록이 디코더의 시작 부분에만 적용된 것을 특징으로 하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 6

제3항에 있어서, 상기 완전 연결 네트워크(FCN) 블록이 인코더의 마지막 부분과 디코더의 시작 부분 모두에 적용된 것을 특징으로 하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 7

제3항에 있어서, 상기 인코더는,

상기 이미지 데이터를 필터를 통해 컨볼루션 연산을 처리하며 연산 결과로 특성맵(feature map)의 크기를 줄이는 컨볼루션 레이어(Convolution Layer); 및

상기 출력된 특성맵을 서브 샘플링(sub sampling)을 통해 특성맵의 크기를 줄이는 풀링 레이어(Pooling Layer)를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 8

제7 항에 있어서, 상기 풀링 레이어(Pooling layer)는 필터와 겹치는 영역안에서 최대값을 추출하여 다운 샘플링(down sampling)하는 맥스 풀링(Max Pooling) 방식으로 특성맵의 크기를 줄이는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 9

제3항에 있어서, 상기 디코더는

특성맵의 차원을 늘리고 채널수를 줄이는 업스케일 컨볼루션 레이어 (Upscale Convolution Layer); 및

스킵 연결을 통해 상기 인코더에서 복사한 특성맵에 크기를 증가시켜 이미지 데이터와 같은 사이즈로 출력하는 트랜스포스 컨볼루션 레이어(Transposed convolution layer)를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 10

제1항에 있어서, 상기 센싱 데이터는 차량의 자동차 감속기와 차량의 실내에서 센싱한 진동 신호들인 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 11

제10항에 있어서, 상기 센싱 데이터는 3채널 1차원 데이터이고, 각 채널에는 2048길이의 1차원 데이터를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치.

청구항 12

차량 부품에서 발생하는 진동 신호의 센싱 데이터를 시계열 방식으로 수신하는 단계;

수신된 센싱 데이터를 이미지 데이터로 변환하는 단계;

상기 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코딩 단계;

상기 인코딩 단계를 통해 저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코딩 단계; 및

서로 대칭되는 구조를 갖는 상기 인코딩 단계와 디코딩 단계 중 적어도 어느 하나의 단계에 모든 데이터의 상관관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network: FCN)를 이용한 중간 처리 단계를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 13

제12항에 있어서, 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 인코딩 단계의 마지막 부분에서 수행되는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 14

제12항에 있어서, 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 디코딩 단계의 시작 부분에서 수행되는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 15

제12항에 있어서, 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 인코딩 단계의 마지막 부분에서와 상기 디코딩 단계의 시작 부분에서 모두 수행되는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 16

제12항에 있어서, 상기 센싱 데이터는 차량의 자동차 감속기와 차량의 실내에서 센싱한 진동 신호들인 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 17

제16항에 있어서, 상기 센싱 데이터는 3채널 1차원 데이터이고, 각 채널에는 2048길이의 1차원 데이터를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

청구항 18

제12항에 있어서, 상기 중간 처리단계는 서로 대칭되는 구조를 갖는 U-net 구조에 상기 완전 연결 네트워크(FCN)를 차용하여, 저주파 및 고주파와 같은 양 끝에 위치한 데이터의 정보도 함께 분석하는 인공지능 구조 기반의 진동 주파수 데이터 분석 방법.

발명의 설명

기술 분야

[0001] 본 발명은 진동 주파수 데이터 분석 장치 및 방법에 관한 것으로서, 더욱 상세하게는 인코더와 디코더 중 적어도 어느 하나에 삽입되어 모든 데이터의 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network: FCN)를 포함하는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법에 관한 것이다.

배경 기술

[0002] 딥러닝은 기존에 알려진 인공 신경망(Artificial Neural Network)의 여러 문제점(즉, vanishing problem, overfitting 등)을 정규화(Normalization)의 개발과 드롭아웃(Drop-out)과 같은 알고리즘 개선으로 그 성능을 향상시켰고, 또한 GPU(Graphic Processing Units)와 같은 하드웨어의 발전과 복잡한 구조를 학습시킬 수 있는 빅데이터의 힘 덕분에 최근 여러 분야에 뛰어난 성능을 발휘하고 있다.

[0003] 이러한 딥러닝 기술은 해외 많은 기업(구글, 페이스북, 애플, 마이크로소프트, 알리바바, 바이두)에 의해 빠르게 발전되고 있으며 얼굴인식, 음성인식, 자연어 처리, 검색 서비스, 의료 등의 분야에 적용되고 있다. 이렇게 빠르게 발전하는 딥러닝의 최신 기술을 확보하고 더 나아가 응용 분야를 선점하고 빠르게 상용화 하는 것이 시급하다.

[0004] 종래의 결함 검사 장비에서 사용되는 결함 분류 방법은 도 1과 같다.

[0005] 알고리즘 개발자가 영상에서 분류가 잘 될 것 같은 특징을 영상처리 알고리즘으로 추출한 후 이러한 특징들을 분류기(SVM, Decision tree)로 학습한다.

[0006] 조명과 카메라를 이용하여 광학 장치를 구성하고, 결함 부분에서 빛의 경로가 변함에 따라 카메라에 들어오는 빛의 양의 변화를 영상으로 변환하여 결함 부위의 잡음 비율(Signal/Noise ratio)을 높인다. 이러한 영상에서 결함 검출 알고리즘이 결함 후보를 검출하고, 결함 후보 영상에 대해 특징 추출 알고리즘과 분류 알고리즘을 이용하여 결함을 검출 및 분류하게 된다.

[0007] 이러한 방법은 사람이 얼마나 특징 추출 알고리즘을 잘 디자인하여 특징을 추출하는지가 성능의 한계이다. 또한 선택된 특징에 따라 분류 성능이 제한적이고, 영상의 회전, 밝기 변화, 크기 변화 등에 따라 분류 성능이 달라지는 문제점이 있다. 제품별로 영상의 특징이 달라서 이를 분석하여 개발하는데, 시간이 많이 소요되는 단점도 존재한다.

[0008] 최신 기술인 딥러닝 중 CNN 방법을 응용한 분류 알고리즘은 영상에서 인공지능이 스스로 특징을 추출하고 학습하는 방법이다. 딥러닝 기술을 응용하여 결함 분류 알고리즘을 구성하면 위의 문제를 해결할 수 있다. 다양한 딥러닝 구조 중 영상 분야에서의 딥러닝은 CNN(Convolutional Neural Network)이라는 구조가 사용된다.

[0009] CNN을 이용한 영상 분류는 CNN 스스로가 분류 성능을 높일 수 있는 특징을 추출하고 학습한다는 특징이 있다.

[0010] 이러한 특징을 이용하여 영상을 기반으로 하는 결함 검출 분야에 적용한다면 획기적인 성능 향상을 기대할 수

있다.

- [0011] 일반적인 딥러닝을 이용한 분류기의 구성은 도 2와 같다.
- [0012] 입력 영상에 대해 컨벌루션 층(Convolution layer)과 활성화함수(Activation function)를 적용시킨 후 나온 특징 맵(feature map)을 풀링 층(Pooling layer)을 통해 크기를 줄인 후 다음 컨벌루션 층(convolution layer)으로 전달한다. 이러한 기본 구조를 반복적으로 깊게 쌓아서 영상에서 결함 분류 또는 고장 진단을 위한 특징을 효과적으로 추출하게 한다.
- [0013] 종래의 고장 진단 방법은 부품의 물리적 모델을 기반으로 하여 정상인지 이상인지 여부를 판단하였다. 하지만 운전 상태가 여러 환경 조건에 따라 변하여 그에 따른 물리 모델이 찾기가 어려워지는 단점이 있었다. 최근에는 물리 모델이 아니라 수집된 데이터를 기반으로 머신러닝 등의 데이터 분석 방법에 따른 접근법이 많이 연구되고 있다.
- [0014] 구체적으로, 대상물에서 발생하는 진동, 변위, 온도, 초음파 등의 신호를 센싱하고 이러한 센싱값을 기반으로 선형 예측 계수를 통한 시계열 분석, 고속 푸리에 변환을 통한 주파수 분석, 이산 분석을 통해 주파수 대역별 실효값과 분산을 분석한 후 이들의 데이터에 대한 테스트 및 타당성을 검증한 결과를 멀티레이어 퍼셉트론 네트워크를 통해 분류함으로써 고장 특징이 추출되는 방식이 채택되었다.
- [0015] 그러나 종래 방법은 시간 변화에 따른 센싱 신호만을 가지고 고장 특징을 추출하기 때문에 시간에 따라 특성이 다양하게 변하는 부품의 상태 및 고장 진단을 하는데 한계가 있다는 문제점이 있다.

발명의 내용

해결하려는 과제

- [0016] 본 발명은 UNet의 전체 구조를 차용하면서도, 지역성이 없는 데이터를 처리할 수 있는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법을 제공하는 것을 목적으로 한다.
- [0017] 본 발명의 다른 목적은 주파수 도메인인 진동 데이터에 효과적으로 동작할 수 있는 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법을 제공하는 것이다.
- [0018] 본 발명의 또 다른 목적은 저주파 대역과 고주파 대역의 데이터의 관계를 인공지능이 학습할 수 있도록 하는 것이다.

과제의 해결 수단

- [0019] 이러한 목적을 달성하기 위한 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 차량 부품에서 발생하는 진동 신호를 시계열 방식으로 센싱하는 복수의 센서 센서가 배치된 센서부 및 상기 복수의 센서로부터 제공된 센싱 데이터에 기초하여 진동 주파수 데이터를 분석하는 컴퓨팅 장치를 포함하여 이루어진다.
- [0020] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서, 상기 컴퓨팅 장치는 부품에 대한 센싱 데이터를 입력 받아 일정한 간격마다 소정의 윈도우 크기로 슬라이싱(slicing)한 후 샘플링 주기마다 신호 크기를 추출하여 1차원의 신호 입력벡터를 생성하는 입력벡터 생성부; 부품에 대한 센싱 데이터를 입력 받아 푸리에 변환을 이용하여 시간에 따라 변하는 센싱 신호를 주파수 성분으로 변환하여 주파수 변환 벡터를 생성하는 신호 변환부; 및 상기 입력벡터 생성부 및 상기 신호 변환부로부터 제공된 신호 입력벡터 및 주파수 변환 벡터를 입력받아 U-Net 구조 기반의 딥러닝 기반 모델을 통해 진동 주파수를 분석하는 분석부를 포함하여 이루어진다.
- [0021] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서, 상기 분석부는 상기 센싱 데이터를 이미지 데이터로 변환하는 데이터 변환부; 상기 변환된 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코더 (Encoder); 저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코더 (Decoder); 및 서로 대칭되는 구조를 갖는 상기 인코더와 디코더 중 적어도 어느 하나에 삽입되어 모든 데이터의 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크 (Fully Connected Network: FCN) 블록을 포함하여 이루어진다.
- [0022] 본 발명의 일 실시예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 상기 완전 연결 네트워크 (FCN) 블록이 인코더의 마지막 부분에만 적용될 수 있다.

- [0023] 본 발명의 다른 실시예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 상기 완전 연결 네트워크(FCN) 블록은 디코더의 시작 부분에만 적용될 수 있다.
- [0024] 본 발명의 또 다른 실시예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 상기 완전 연결 네트워크(FCN) 블록은 인코더의 마지막 부분과 디코더의 시작 부분 모두에 적용될 수 있다.
- [0025] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서 상기 인코더는 상기 이미지 데이터를 필터를 통해 컨볼루션 연산을 처리하며 연산 결과로 특성맵(feature map)의 크기를 줄이는 컨볼루션 레이어(Convolution Layer); 및 상기 출력된 특성맵을 서브 샘플링(sub sampling)을 통해 특성맵의 크기를 줄이는 풀링 레이어(Pooling Layer)를 포함하여 이루어질 수 있다.
- [0026] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서 상기 풀링 레이어(Pooling layer)는 필터와 겹치는 영역안에서 최대값을 추출하여 다운 샘플링(down sampling)하는 맥스 풀링(Max Pooling) 방식으로 특성맵의 크기를 줄일 수 있다.
- [0027] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서 상기 디코더는 특성맵의 차원을 늘리고 채널수를 줄이는 업스케일 컨볼루션 레이어(Upscale Convolution Layer) 및 스킵 연결을 통해 상기 인코더에서 복사한 특성맵에 크기를 증가시켜 이미지 데이터와 같은 사이즈로 출력하는 트랜스포스 컨볼루션 레이어(Transposed Convolution layer)를 포함하여 이루어진다.
- [0028] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서 상기 센싱 데이터는 차량의 자동차 감속기와 차량의 실내에서 센싱한 진동 신호일 수 있다.
- [0029] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치에서 상기 센싱 데이터는 3채널 1차원 데이터이고, 각 채널에는 2048길이의 1차원 데이터를 포함할 수 있다.
- [0030] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법은 차량 부품에서 발생하는 진동 신호의 센싱 데이터를 시계열 방식으로 수신하는 단계; 수신된 센싱 데이터를 이미지 데이터로 변환하는 단계; 상기 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코딩 단계; 상기 인코딩 단계를 통해 저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코딩 단계; 및 서로 대칭되는 구조를 갖는 상기 인코딩 단계와 디코딩 단계 중 적어도 어느 하나의 단계에 모든 데이터의 상관 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network: FCN)를 이용한 중간 처리단계를 포함하여 이루어질 수 있다.
- [0031] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법에서 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 인코딩 단계의 마지막 부분에서 수행될 수 있다.
- [0032] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법에서 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 디코딩 단계의 시작 부분에서 수행될 수 있다.
- [0033] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법에서 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계는 상기 인코딩 단계의 마지막 부분에서와 상기 디코딩 단계의 시작 부분에서 모두 수행될 수 있다.

발명의 효과

- [0034] 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 방법은 저주파 대역과 고주파 대역의 데이터의 관계를 인공지능이 학습할 수 있어서 UNet의 전체 구조를 차용하면서도 지역성이 없는 데이터를 처리할 수 있고, 주파수 도메인인 진동 데이터에 효과적으로 동작할 수 있다.

도면의 간단한 설명

- [0035] 도 1은 종래 결함 분류 방법을 설명하기 위한 예시도이다.
- 도 2는 일반적인 딥러닝을 이용한 분류기의 구성을 나타낸 예시도이다.
- 도 3은 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치의 개략적인 구성을 나타낸 블록도이다.

도 4a 및 도 4b는 센싱 신호의 처리 상태를 나타낸 예시도이다.

도 5는 도 3의 분석부를 구체적으로 나타낸 예시도이다.

도 6은 본 발명의 일 실시예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이다.

도 7은 본 발명의 다른 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이다.

도 8은 본 발명의 또 다른 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이다.

도 9는 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치의 실시 예에 따른 val-epoch-loss 관계를 나타낸 그래프이다.

발명을 실시하기 위한 구체적인 내용

- [0036] 본문에 개시되어 있는 본 발명의 실시 예들에 대해서, 특정한 구조적 내지 기능적 설명들은 단지 본 발명의 실시 예를 설명하기 위한 목적으로 예시된 것으로, 본 발명의 실시 예들은 다양한 형태로 실시될 수 있으며 본문에 설명된 실시 예들에 한정되는 것으로 해석되어서는 안 된다.
- [0037] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 형태를 가질 수 있는 바, 특정 실시 예들을 도면에 예시하고 본문에 상세하게 설명하고자 한다. 그러나 이는 본 발명을 특정한 개시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.
- [0038] 제1, 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되지 않는다. 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 본 발명의 권리 범위로부터 이탈되지 않은 채 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다.
- [0039] 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급된 때에는, 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성요소가 다른 구성요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는, 중간에 다른 구성요소가 없는 것으로 이해되어야 할 것이다. 구성요소들 간의 관계를 설명하는 다른 표현들, 즉 "~사이에"와 "바로 ~사이에" 또는 "~에 이웃하는"과 "~에 직접 이웃하는" 등도 마찬가지로 해석되어야 한다.
- [0040] 본 출원에서 사용한 용어는 단지 특정한 실시 예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함한다" 또는 "가진다" 등의 용어는 개시된 특징, 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.
- [0041] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 나타낸다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 나타내는 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.
- [0042] 한편, 어떤 실시 예가 달리 구현 가능한 경우에 특정 블록 내에 명기된 기능 또는 동작이 흐름도에 명기된 순서와 다르게 일어날 수도 있다. 예를 들어, 연속하는 두 블록이 실제로는 실질적으로 동시에 수행될 수도 있고, 관련된 기능 또는 동작에 따라서는 상기 블록들이 거꾸로 수행될 수도 있다.
- [0043] 이하에서, 첨부된 도면을 참조하여 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치 및 이를 이용한 분석 방법에 관하여 설명한다.
- [0044] 도 1은 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치의 구성을 개략적으로 나타낸 블록도이다. 도시한 바와 같이, 복수의 차량 부품(100)에서 발생하는 진동 신호를 시계열 방식으로 센싱하는 복수

의 센서(200A, 200B, 200C, ..., 200N)가 배치된 센서부(200) 및 상기 센서부(200)의 복수의 센서들(200A, 200B, 200C, ..., 200N)로부터 제공된 센싱 데이터에 기초하여 진동 주파수 데이터를 분석하는 컴퓨팅 장치(300)를 포함하여 이루어진다.

[0045] 상기 컴퓨팅 장치(300)는 입력벡터 생성부(310), 신호 변환부(320) 및 분석부(330)를 포함하여 이루어진다. 입력벡터 생성부(310), 신호 변환부(320) 및 분석부(330)는 소프트웨어 또는 하드웨어로 구현될 수 있다.

[0046] 입력벡터 생성부(310)는 부품에 대한 센싱 데이터를 입력 받아 신호 입력벡터를 생성한다. 다양한 종류의 센서가 센싱 대상물에 설치될 수 있다. 본 발명에서는 센싱 대상물로서 자동차 부품을 예시로 하고, 센싱 데이터는 진동 데이터인 것으로 설명하지만, 본 발명이 이에 국한되는 것을 의미하는 것은 아니다. 즉, 센싱 데이터로는 진동, 변위, 온도, 초음파 등이 가능할 수 있다. 입력벡터 생성부(310)는 부품에 대한 센싱 데이터를 입력 받아 도 4a에 도시한 바와 같이 수신된 센싱 신호를 일정한 간격(T1, T2, T3, T4, ...)마다 소정의 윈도우 크기(W1, W2, W3, W4, ...)로 슬라이싱(slicing)한 후 분석부(330)에 입력될 수 있도록 샘플링 주기마다 신호 크기를 추출하여 1차원 신호 입력벡터를 생성한다. 예를 들어, 도 4b에 도시한 바와 같이 시간 간격 50ms, 윈도우 크기 100ms, 샘플링 주기 1ms일 때, 50ms마다 100개의 신호 값으로 구성된 신호 입력 벡터가 생성될 수 있다.

[0047] 신호 변환부(320)는 부품에 대한 센싱 데이터를 입력 받아 주파수 변환하여 주파수 변환벡터를 생성한다. 신호 변환부(320)는 푸리에 변환을 이용하여 시간에 따라 변하는 센싱 신호를 각 타임 스텝에 대해 주파수 성분으로 변환하여 각 타임 스텝의 주파수를 출력시킨다. 각 타임 스텝의 주파수 신호는 1차원 주파수 신호 벡터로 변환되어 분석부(330)로 입력된다.

[0048] 분석부(330)는 상기 입력벡터 생성부(310) 및 상기 신호 변환부(320)로부터 제공된 신호 입력벡터와 주파수 변환 벡터를 입력받아 인공지능 구조 기반의 딥러닝 기반 모델을 통해 진동 주파수를 분석한다. 분석부(330)는 컨볼루션 신경망(CNN)을 통해 1차원 신호 입력 벡터로부터 신호 특징 벡터를 추출하고, 추출한 신호 특징 벡터와 주파수 변환 벡터를 결합하고, 결합 벡터를 심층 신경망을 통해 분석하여 부품에 대한 상태 진단 결과를 출력하게 된다. 구체적으로는 Pooling 신경망과 컨볼루션 신경망(CNN)들을 통해 고해상도 정보가 존재하는 상기 결합된 벡터에서 저해상도 정보를 점진적으로 분석하고, 이를 다시 Transposed 컨볼루션 신경망(Transposed CNN)들을 통하여 얻은 고해상도 정보와 정보와 Pooling 신경망과 컨볼루션 신경망(CNN)을 통과하기 전의 고해상도 정보와 결합하는 방식으로 U-Net 구조 기반의 딥러닝 기반 모델을 통해 진동 주파수를 분석하여 부품에 대한 상태 진단 결과를 출력한다.

[0049] 도 5는 도 3의 분석부를 구체적으로 나타낸 예시도이다.

[0050] 상기 분석부(330)는 상기 센싱 데이터를 이미지 데이터로 변환하는 데이터 변환부(331), 상기 변환된 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코더(Encoder)(332), 저차원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코더(Decoder)(334) 및 서로 대칭되는 구조를 갖는 상기 인코더(332)와 디코더(334) 중 적어도 어느 하나에 삽입되어 모든 데이터의 관계를 분석하여 출력 데이터를 만드는 완전 연결 네트워크(Fully Connected Network, 이하 "FCN"이라 함) 블록(333)을 포함하여 이루어진다. 도5에 도시한 바와 같이 인코더(332)와 디코더(334) 모두에 FCN을 도입하거나, 혹은 둘 중 일부에 FCN을 도입할 수 있다.

[0051] 대규모 데이터에서 스스로 중요한 패턴 및 규칙을 찾아내어 학습하는 딥러닝(Deep Learning)의 대부분은 합성곱 신경망(Convolutional Neural Network, 이하 CNN)을 기반으로 하는 연구들로 진행되고 있다.

[0052] CNN 초기 모델은 개발 당시의 하드웨어 성능으로는 높은 연산량을 처리하는데 긴 시간이 소요되며, 괄목할만한 성능을 보이지 못해 주목받지 못하였으나, 최근 하드웨어의 성능 발전으로 기존 방식의 문제점이었던 높은 연산량을 빠른 속도의 처리와 더불어 높은 수준의 성능까지 보여 많은 연구자의 주목을 받아 다양한 목적으로 활발한 연구가 진행되고 있다.

[0053] 특히, 컨볼루션 구조 변경은 특징맵 추출에 가장 직접적인 영향을 반영하기에 CNN에 관한 주된 연구는 대부분 컨볼루션 구조 변경으로 진행되고 있다.

[0054] 본 발명은 U-net의 전체 구조를 차용하면서도, 지역성이 없는 데이터를 처리할 수 있는 인공지능 구조를 위해 인코더와 디코더 사이에 FCN를 추가하였다.

[0055] 인코더(332)는 상기 이미지 데이터를 필터를 통해 컨볼루션 연산을 처리하며 연산 결과로 특성맵(feature map)의 크기를 줄이는 컨볼루션 레이어(Convolution Layer); 및 상기 출력된 특성맵을 서브 샘플링(sub sampling)을

통해 특성맵의 크기를 줄이는 풀링 레이어(Pooling Layer)를 포함하여 이루어진다.

[0056] 상기 풀링 레이어(Pooling layer)는 필터와 겹치는 영역안에서 최대값을 추출하여 다운 샘플링(down sampling)하는 맥스 풀링(Max Pooling) 방식으로 특성맵의 크기를 줄인다.

[0057] 상기 디코더(334)는 특성맵의 차원을 늘리고 채널수를 줄이는 업스케일 컨볼루션 (Upscale Convolution Layer); 및 스킵 연결을 통해 상기 인코더에서 복사한 특성맵에 크기를 증가시켜 이미지 데이터와 같은 사이즈로 출력하는 트랜스포스 컨볼루션레이어(Transposed convolution layer)를 포함한다.

[0058] FCN은 CNN과는 다르게 지역성을 고려할 필요가 없는 인공지능 기법이며, $x_1 \sim x_N$ 의 데이터가 주어질 때, 모든 데이터의 관계가 분석되어 출력 데이터를 만든다. 즉, 입력이 $x_1 \sim x_N$, 출력이 $y_1 \sim y_M$ 이라고 한다면, FCN은 다음과 같은 선형대수학적으로 [수학식 1]과 같이 표현할 수 있다.

[0059] $Y = WX + b$ (수학식 1)

[0060] 여기서 X 는 $x_1 \sim x_N$ 으로 이뤄진 N 크기의 벡터이며, b 는 바이어스 항인 $b_1 \sim b_N$ 으로 이뤄진 N 크기의 벡터, Y 는 $y_1 \sim y_M$ 으로 이뤄진 M 크기의 벡터이며, W 는 weight 항인 $w_{11} \sim w_{MN}$ 으로 이루어진 $M \times N$ 크기의 매트릭스이다. 여기서 W 와 b 는 인공지능이 데이터를 학습함에 따라 자동으로 조정되는 값이다. 해당 수식을 y_1 에 대해 분석해 보면 다음의 수학식 2와 같이 표현할 수 있다.

$$y_1 = \sum_{i=1}^N (w_{\{1,i\}} * x_i) + b_1$$

[0061](수학식 2)

[0062] 위의 수식에서 알 수 있는 것처럼 출력인 y_1 은 $x_1 \sim x_N$ 까지의 모든 데이터를 반영하는 것을 알 수 있으며, 이것이 FCN이 지역성을 고려할 필요 없는 이유이다. 본 발명은 이러한 FCN 기법을 UNet의 인코더와 디코더 부분에 삽입함으로써 UNet과 같은 구조에서도 지역성이 적은 데이터를 효과적으로 처리할 수 있다. FCN이 적용된 U-Net은 위치적으로 떨어져 있는 데이터의 관계도 인공지능이 분석할 수 있기 때문에, 주파수 데이터의 경우, 저주파 대역과 고주파 대역의 데이터의 관계를 인공지능이 학습할 수 있게 된다는 장점이 존재한다. 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치는 FCN을 N 차원까지 확장하여 2D 데이터인 이미지 데이터 혹은 그 이상의 고차원 데이터에서도 동작가능하다.

[0063] 도 6은 본 발명의 일 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이고, 도 7은 본 발명의 다른 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이고, 도 8은 본 발명의 또 다른 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법의 진행 과정을 나타낸 흐름도이다.

[0064] FCN은 다른 인공지능 기법인 CNN이나 RNN 계열과 달리 입력력 데이터 개수 대비 상당히 많은 가중치 변수가 필요하다. 즉, 매트릭스 W 의 크기가 CNN과 RNN 계열과 달리 상당히 크다는 단점이 있다. 하지만 본 발명에서 FCN은 인코더의 마지막 부분이나 디코더의 시작 부분 또는 인코더의 마지막 부분이나 디코더의 시작 부분에 넣음으로써 FCN에 들어가는 데이터의 크기를 줄였다. 결과적으로 FCN의 가중치 변수 개수를 줄이면서도, 모델 전체적으로 보았을 때 지역성이 적은 데이터도 효과적으로 처리할 수 있는 구조가 되었다.

[0065] 도 6에서 나타낸 바와 같이, 각 부품에 배치된 복수의 센서(200A ~ 200N)들은 차량 부품에서 발생하는 진동 신호를 센싱하여 컴퓨팅 장치(300)로 전송한다. 컴퓨팅 장치(300)의 입력벡터 생성부(310) 및 신호 변환부(320)는 센싱 데이터를 시계열 방식으로 수신한다 (S501).

[0066] 센싱 데이터는 차량의 자동차 감속기와 차량의 실내에서 센싱한 진동 신호들이 다. 상기 센싱 데이터는 3채널 1차원 데이터이고, 각 채널에는 2048길이의 1차원 데이터를 포함한다.

[0067] 분석부(330)는 상기 입력벡터 생성부(310) 및 신호 변환부(320)로부터 제공된 입력벡터를 입력받아 인공지능 구조 기반의 딥러닝 기반 모델을 통해 진동 주파수를 분석한다. 분석부(330)의 데이터 변환부(331)는 수신된 센싱 데이터를 이미지 데이터로 변환한다 (S502).

[0068] 인코더(332)는 상기 이미지 데이터의 특징을 포착할 수 있도록 채널의 수를 늘리면서 차원을 축소해나가는 인코딩 동작을 개시한다 (S503).

[0069] 인코더의 마지막 부분에서 완전 연결 네트워크(FCN) 블록(333)이 모든 데이터의 관계가 분석되어 출력 데이터를 만든다 (S504).


- [0070] FCN 블록(333)이 동작을 마치면 인코더(330)는 마지막 컨볼루션을 수행하면서 인코딩 동작을 종료한다 (S505).
- [0071] 디코더(334)는 상기 인코더에 의해 저장원으로 인코딩된 정보만 이용하여 채널의 수를 줄이고 차원을 늘려서 데이터를 복원하는 디코딩을 개시한다 (S506).
- [0072] 디코더(334)는 디코딩을 종료하여 센싱된 이미지 데이터를 학습한다 (S507).
- [0073] 도 7은 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계가 디코딩 동작이 개시된 시점 즉, 디코딩 단계의 시작 부분에서 수행(S606)되는 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법을 나타내고 있다.
- [0074] 도 8은 상기 완전 연결 네트워크(FCN)를 이용한 중간 처리단계가 인코딩 동작이 종료되기 전 인코딩의 마지막 부분(S704)과, 디코딩 동작이 개시된 후의 시작 부분 (S707) 모두에서 수행되는 실시 예에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 방법을 나타내고 있다.
- [0075] 도 9는 본 발명에 따른 인공지능 구조 기반의 진동 주파수 데이터 분석 장치의 실시 예에 따른 val-epoch-loss 관계를 나타낸 그래프이다. 완전 연결 네트워크(FCN)의 유무와 위치에 따른 진동 주파수 데이터의 검증 데이터에 대한 손실(validation loss)를 나타낸 것이다. 굵은 실선(—)은 디코더의 개시부분에 FCN을 도입한 경우의 전체 데이터셋을 학습한 횟수(epoch)가 증가할 때의 손실 변화를 나타낸 그래프이다. 굵은 점선(--)은 인코더의 마지막 부분에 FCN을 도입한 경우의 전체 데이터셋을 학습한 횟수(epoch)가 증가할 때의 손실 변화를 나타낸 그래프이다. 한편, 완전 연결 네트워크(FCN)를 인코더 또는 디코더 어느 곳에도 적용하지 않는 경우는 학습 횟수 늘어나더라도 얇은 실선 (___)과 같이 가장 큰 손실 값을 갖는다. 반면, 상기 인코딩 단계의 마지막 부분에서와 상기 디코딩 단계의 시작 부분에서 모두 수행되는 경우는 얇은 점선 (---)과 같이 학습 횟수가 증가할수록 손실 값이 가장 낮은 값을 가질 수 있다. 즉, 진동 주파수 데이터를 더욱 잘 분석하는 것을 알 수 있다.
- [0076] 본 발명은 인공지능 구조 의 인코더와 디코더 모두 혹은 둘 중 일부에 FCN을 도입함으로써 지역적 특성이 강한 데이터뿐만 아니라 그렇지 않은 데이터에서도 효과적으로 나은 성능을 낼 수 있는 인공지능 구조를 기대할 수 있다. 기존의 CNN으로만 이뤄진 U-Net은 진동 주파수 데이터의 경우 저주파와 고주파 사이의 관계를 분석하는데 효과적이지 않은 구조이지만, U-Net 구조에 FCN을 차용한 본 발명은 저주파와 고주파 같은 양 끝단에 위치한 데이터의 정보도 함께 분석할 수 있어 극단적인 위치에 있는 데이터 간의 관계도 U-Net 기반의 인공지능이 분석할 수 있다는 효과가 있다.
- [0077] 상기에서는 본 발명의 바람직한 실시 예를 참조하여 설명하였지만, 해당 기술 분야의 숙련된 당업자는 하기의 특허 청구의 범위에 기재된 본 발명의 사상 및 영역으로부터 벗어나지 않는 범위 내에서 본 발명을 다양하게 수정 및 변경시킬 수 있음을 이해할 수 있을 것이다.

부호의 설명


- [0078] 100: 부품 200: 센서
- 300: 컴퓨팅 장치 310: 입력벡터 생성부
- 320: 신호 변환부 330: 분석부
- 331: 데이터 변환부 332: 인코더
- 333: FCN 334: 디코더

도면


도면1




도면2




도면3




도면4a




도면4b




도면5




도면6



도면7



도면8



도면9

