



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2022년08월05일
(11) 등록번호 10-2429233
(24) 등록일자 2022년08월01일

(51) 국제특허분류(Int. Cl.)
G05B 23/02 (2006.01) G06N 20/00 (2019.01)
(52) CPC특허분류
G05B 23/0283 (2013.01)
G05B 23/0254 (2013.01)
(21) 출원번호 10-2020-0159607
(22) 출원일자 2020년11월25일
심사청구일자 2020년11월25일
(65) 공개번호 10-2021-0066730
(43) 공개일자 2021년06월07일
(30) 우선권주장
1020190155539 2019년11월28일 대한민국(KR)
(56) 선행기술조사문헌
JP2019185422 A*
KR1020190070428 A*
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
이중수
서울특별시 강남구 압구정로33길 70 현대아파트
53동 405호
김진영
인천광역시 부평구 충선로 77 백조아파트 303
(뒷면에 계속)
(74) 대리인
특허법인 플러스

전체 청구항 수 : 총 4 항

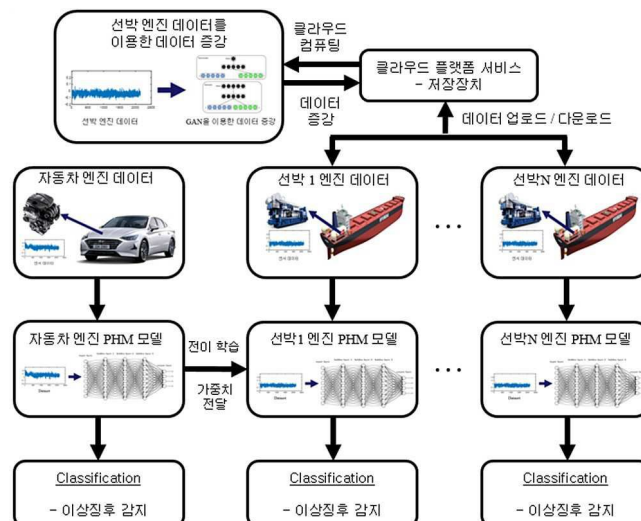
심사관 : 김윤한

(54) 발명의 명칭 클라우드 플랫폼 서비스 기반 데이터 증강을 통한 건전성 예측 관리 모델 설계 방법 및 시스템

(57) 요약

본 발명은 건전성 예측 관리(PHM, Prognostics and Health Management) 모델 생성 시 필요한 많은 데이터들을 클라우드 플랫폼 서비스(Cloud Platform Service)기반 조건부 생성적 적대 신경망(GAN, Generative Adversarial Networks)을 이용한 데이터 증강(Data Augmentation)과 전이 학습(Transfer Learning)을 적용하여 데이터 부족에 따른 PHM 모델의 성능저하 문제를 해결하는 방법 및 시스템에 관한 것이다.

대표도 - 도22



(52) CPC특허분류

G06N 20/00 (2021.08)

(72) 발명자

이형운

인천광역시 서구 청마로 170 당하푸르지오아파트
301-1104

김진혁

충청남도 서산시 음암면 석동로 36, 101-710

명세서

청구범위

청구항 1

진전성 예측 관리(PHM, Prognostics and Health Management) 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 데이터 획득부;

상기 데이터 획득부가 획득한 데이터를 전달받아, 상기 전달받은 데이터를 증강하여 증강 데이터를 생성하는 데이터 증강부;

상기 데이터 증강부가 생성한 증강 데이터를 전달받아, 상기 증강 데이터를 기반으로 상기 대상 시스템 또는 장치의 PHM 모델을 생성하는 PHM 모델 생성부; 및

다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 기 학습 PHM 모델 저장부;를 포함하고,

상기 데이터 증강부는 클라우드 플랫폼 상에서 구현되는 것으로,

상기 클라우드 플랫폼은,

클라우드 저장공간을 이용하여 상기 데이터 획득부가 획득한 상기 데이터를 수집하고, 클라우드 컴퓨팅을 이용하여 상기 데이터를 기반으로 증강 데이터를 생성하고,

상기 클라우드 컴퓨팅은 생성적 적대 신경망(GAN, Generative Adversarial Network)을 이용하여 데이터 증강을 수행하며,

상기 PHM 모델 생성부는,

상기 증강 데이터를 기반으로 머신러닝 또는 딥러닝하여 상기 시스템 또는 장치의 PHM 모델을 생성하되,

상기 기 학습 PHM 모델 저장부로부터 전달받은 기 학습된 PHM 모델을 전이 학습하고,

상기 기 학습된 PHM 모델의 합성곱이 학습한 가중치를 전달받고, 상기 가중치를 새로 생성할 상기 대상 시스템 또는 장치의 PHM 모델의 합성곱에 그대로 전달하여 상기 대상 시스템 또는 장치의 PHM 모델을 생성하며,

상기 전이 학습은, 특성 추출기, 분류기 및 도메인 판별기를 포함하는 도메인 적응 기법(DANN, Domain Adversarial Neural Network)이 적용되는, PHM 모델 설계 시스템.

청구항 2

삭제

청구항 3

삭제

청구항 4

삭제

청구항 5

삭제

청구항 6

삭제

청구항 7

삭제

청구항 8

제1항에 있어서,

상기 데이터는, 상기 각 객체의 이상 징후에 대한 정보를 포함하는 것을 특징으로 하는, PHM 모델 설계 시스템.

청구항 9

건전성 예측 관리 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 단계;

상기 데이터를 증강하여 증강 데이터를 생성하는 단계;

상기 증강 데이터를 기반으로 상기 대상 시스템 또는 장치의 PHM 모델을 생성하는 단계; 및

상기 PHM 모델을 생성하는 단계 이전에, 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 단계;를 포함하고,

상기 증강 데이터를 생성하는 단계는 클라우드 플랫폼 상에서 구현되는 것으로,

상기 클라우드 플랫폼은,

클라우드 저장공간을 이용하여 상기 데이터를 수집하고, 클라우드 컴퓨팅을 이용하여 상기 데이터를 기반으로 증강 데이터를 생성하고,

상기 클라우드 컴퓨팅은 생성적 적대 신경망을 이용하여 데이터 증강을 수행하며,

상기 PHM 모델을 생성하는 단계는,

상기 증강 데이터를 기반으로 머신러닝 또는 딥러닝하여 상기 시스템 또는 장치의 PHM 모델을 생성하되,

상기 기 학습된 PHM 모델 저장 단계의 기 학습된 PHM 모델을 전이 학습하고,

상기 기 학습된 PHM 모델의 합성곱이 학습한 가중치를 전달받고, 상기 가중치를 새로 생성할 상기 대상 시스템 또는 장치의 PHM 모델의 합성곱에 그대로 전달하여 상기 대상 시스템 또는 장치의 PHM 모델을 생성하며,

상기 전이 학습은, 특성 추출기, 분류기 및 도메인 판별기를 포함하는 도메인 적응 기법(DANN, Domain Adversarial Neural Network)이 적용되는, PHM 모델 설계 방법.

청구항 10

삭제

청구항 11

삭제

청구항 12

삭제

청구항 13

삭제

청구항 14

삭제

청구항 15

삭제

청구항 16

제9항에 있어서,

상기 데이터는, 상기 각 객체의 이상 징후에 대한 정보를 포함하는 것을 특징으로 하는, PHM 모델 설계 방법.

발명의 설명

기술 분야

- [0001] 본 발명은 건전성 예측 관리(PHM, Prognostics and Health Management) 모델 생성 시 필요한 많은 데이터들을 클라우드 플랫폼 서비스(Cloud Platform Service)기반 조건부 생성적 적대 신경망(GAN, Generative Adversarial Networks)을 이용한 데이터 증강(Data Augmentation)과 전이 학습(Transfer Learning)을 적용하여 데이터 부족에 따른 PHM 모델의 성능저하 문제를 해결하는 방법 및 시스템에 관한 것이다.

배경 기술

- [0002] PHM의 머신러닝 또는 딥러닝은 공학적 시스템의 상태 기반 정비(CBM, Condition Based Management)의 솔루션으로 공학적 문제를 해결한다. 이때 공학적 문제란 운용 중인 시스템이나 장치에 대해 시스템의 이상상황을 감지하고 분석 및 예지 진단을 통해 고장시점을 사전에 예측해 설비관리를 최적화 할 수 있는가 여부의 문제이다.
- [0003] 성능이 좋은 PHM 모델을 가지게 되면 현재 운용중인 시스템이나 장치를 오랫동안 사용할 수 있고, 사용 중 성능저하를 막아 많은 비용의 절감으로 이어진다. 여기서 PHM 모델이란 건전성 예측 관리에 사용되는 신경망의 모든 종류이다. 대표적으로 이미지 분류 신경망인 합성곱 신경망(CNN, Convolutional Neural Network)과 시계열 데이터 분류 신경망인 장단기 기억 순환 신경망(LSTM, Long Short Term Memory)가 있다.
- [0004] 성능이 좋은 PHM모델 설계에는 2가지 문제가 존재한다. 첫 번째로 건전성 예측 관리의 대상이 되는 시스템이 바뀔 때마다, PHM 모델의 학습을 반복해야 한다는 점이다. 도 1은 데이터 셋이 상이한 PHM 모델을 나타낸 것으로, 도시된 바와 같이 PHM 모델이 적용되는 시스템이 바뀔 때 마다 그에 맞는 모델을 학습해야 한다. 이때 모델을 학습하면서 드는 시간비용이 소모되며, 특정 모델에서의 데이터가 부족 할 시에는 학습률이 낮아 PHM 모델의 성능이 저하 된다.
- [0005] 예를 들어 상대적으로 개체 수도 많고, 종류도 많고, 운행 환경 및 운행 시간도 다양한 자동차 엔진의 PHM 모델은 데이터가 많고 다양하기 때문에 모델의 성능이 좋은 반면, 상대적으로 적은 데이터를 가지고 있는 선박 엔진의 PHM 모델은 성능이 떨어진다. 즉, 데이터 셋(set)의 크기가 확연하게 차이가 난다면, PHM 모델 성능은 확연히 차이가 나게 되며, 예를 들어 상대적으로 부족한 크기의 선박 엔진 데이터 셋으로 PHM 모델을 학습할 시, 부정확한 예측모델이 생성 될 수 있다.
- [0006] 이런 데이터 부족 문제 해결을 위해 원본 데이터에 노이즈를 인가하는 전통적인 데이터 증강 방법을 사용해서 보완할 수 있다. 전통적인 데이터 증강은 주로 원본 데이터에 노이즈를 인가해 이미지파일의 경우 이미지 회전, 중심 좌표 변경(shifting), 색상, 채도, 밝기 등을 임의의 조정하여 데이터를 생성한다. 이렇게 만들어 지는 데이터는 데이터의 종류가 매우 제한적이라는 단점이 존재 한다. 즉, 제한된 범위의 이상감지를 벗어나면 감지를 못하는 모델이 생성된다.
- [0007] 성능이 좋은 PHM 모델을 설계하는 것에 있어서 2번째 문제점으로는 데이터 수집이다. 선박 엔진과 자동차 엔진은 데이터 셋의 크기와 다양성에서 차이가 나지만, 둘 다 데이터 수집이 쉽지 않다. 특히 선박 모델의 경우 바다에 넓게 분포되어 있고, 항해시간이 길기 때문에 데이터 수집이 어렵다. 또한, 넓은 범위의 데이터를 얻기 위해 다양한 환경(극지방, 적도지역, 다양한 기상상태 등)에서 운행 중인 선박들의 데이터를 수집하여 데이터 증강을 실행 해야 하는데, 이와 같은 물리적, 환경적 요인은 데이터 수집에 제약으로 작용될 수 밖에 없다.

선행기술문헌

특허문헌

[0008] (특허문헌 0001) KR2019-0091868A(2019.08.07.)

발명의 내용

해결하려는 과제

- [0009] 본 발명은 상술한 바와 같은 문제점을 해결하기 위하여 안출된 것으로서, 멀리 떨어져 있는 객체들의 이상 징후 데이터(다양한 환경에서의 이상 데이터)를 시간과 거리의 제약을 받지 않고 수집할 수 있는 방법을 제시하는 것에 그 목적이 있다.
- [0010] 또한, 본 발명은 수집된 데이터 수가 부족한 경우 PHM 모델 생성을 위한 많은 데이터를 확보할 수 있는 방법을 제시하는 것에 그 목적이 있다.
- [0011] 또한, 본 발명은 PHM 모델에 사용되는 머신러닝 또는 딥러닝 신경망의 성능을 높여 예지보전을 더욱 정확하게 할 수 있는 방법을 제시하는 것에 그 목적이 있다.

과제의 해결 수단

- [0012] 본 발명의 일 예에 따른 PHM 모델 설계 시스템은, 건전성 예측 관리(PHM, Prognostics and Health Management) 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 데이터 획득부; 상기 데이터 획득부가 획득한 데이터를 전달받아, 상기 전달받은 데이터를 증강하여 증강 데이터를 생성하는 데이터 증강부; 및 상기 데이터 증강부가 생성한 증강 데이터를 전달받아, 상기 증강 데이터를 기반으로 상기 대상 시스템 또는 장치의 PHM 모델을 생성하는 PHM 모델 생성부;를 포함할 수 있다.
- [0013] 상기 데이터 증강부는 클라우드 플랫폼 상에서 구현되는 것으로, 상기 클라우드 플랫폼은, 클라우드 저장공간을 이용하여 상기 데이터 획득부가 획득한 상기 데이터를 수집하고, 클라우드 컴퓨팅을 이용하여 상기 데이터를 기반으로 증강 데이터를 생성할 수 있다.
- [0014] 상기 클라우드 컴퓨팅은, 생성적 적대 신경망(GAN, Generative Adversarial Network)을 이용하여 데이터 증강을 수행할 수 있다.
- [0015] 상기 PHM 모델 생성부는, 상기 증강 데이터를 기반으로 머신러닝 또는 딥러닝하여 상기 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0016] 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 기 학습 PHM 모델 저장부;를 더 포함하고, 상기 PHM 모델 생성부는, 상기 기 학습 PHM 모델 저장부로부터 전달받은 기 학습된 PHM 모델을 전이 학습하여 상기 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0017] 상기 PHM 모델 생성부는, 상기 기 학습 PHM 모델 저장부로부터 상기 기 학습된 PHM 모델의 합성곱이 학습한 가중치를 전달받고, 상기 가중치를 새로 생성할 상기 대상 시스템 또는 장치의 PHM 모델의 합성곱에 그대로 전달하여, 상기 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0018] 상기 전이 학습은, 특성 추출기, 분류기 및 도메인 판별기를 포함하는 도메인 적응 기법(DANN, Domain Adversarial Neural Network)이 적용될 수 있다.
- [0019] 상기 데이터는, 상기 각 객체의 이상 징후에 대한 정보를 포함할 수 있다.
- [0020] 본 발명의 일 예에 따른 PHM 모델 설계 방법은, 건전성 예측 관리 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 단계; 상기 데이터를 증강하여 증강 데이터를 생성하는 단계; 및 상기 증강 데이터를 기반으로 상기 대상 시스템 또는 장치의 PHM 모델을 생성하는 단계;를 포함할 수 있다.
- [0021] 상기 증강 데이터를 생성하는 단계는 클라우드 플랫폼 상에서 구현되는 것으로, 상기 클라우드 플랫폼은, 클라우드 저장공간을 이용하여 상기 데이터를 수집하고, 클라우드 컴퓨팅을 이용하여 상기 데이터를 기반으로 증강 데이터를 생성할 수 있다.
- [0022] 상기 클라우드 컴퓨팅은, 생성적 적대 신경망을 이용하여 데이터 증강을 수행할 수 있다.
- [0023] 상기 PHM 모델을 생성하는 단계는, 상기 증강 데이터를 기반으로 머신러닝 또는 딥러닝하여 상기 시스템 또는

장치의 PHM 모델을 생성할 수 있다.

- [0024] 상기 PHM 모델을 생성하는 단계 이전에, 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 단계;를 더 포함하고, 상기 PHM 모델을 생성하는 단계는, 기 학습된 PHM 모델을 전이 학습하여 상기 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0025] 상기 PHM 모델을 생성하는 단계는, 상기 기 학습된 PHM 모델의 합성곱이 학습한 가중치를 전달받고, 상기 가중치를 새로 생성할 상기 대상 시스템 또는 장치의 PHM 모델의 합성곱에 그대로 전달하여, 상기 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0026] 상기 PHM 모델을 생성하는 단계는, 상기 기 학습된 PHM 모델의 합성곱이 학습한 가중치를 새로 생성될 상기 대상 시스템 또는 장치의 PHM 모델의 합성곱에 그대로 전달하여, 상기 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0027] 상기 데이터는, 상기 각 객체의 이상 징후에 대한 정보를 포함할 수 있다.

발명의 효과

- [0028] 본 발명에 따르면, 멀리 떨어져 있는 객체들의 이상 징후 데이터(다양한 환경에서의 이상 데이터)를 클라우드 플랫폼 서비스를 이용해 수집할 수 있고, GAN을 이용한 데이터 증강을 통해, 수집된 데이터보다 더 많은 데이터를 확보할 수 있게 되어 부족한 데이터수에 따른 PHM모델 성능 저하 방지를 방지할 수 있다.
- [0029] 또한, 본 발명에 따르면 전이 학습을 통한 PHM 모델에 사용되는 머신러닝 또는 딥러닝 신경망의 성능을 높여 예지보전을 더욱 정확하게 할 수 있다.
- [0030] 또한, 본 발명에 따르면 시간과 거리의 제약을 받지 않고, PHM 모델을 지속적으로 운용할 수 있다.

도면의 간단한 설명

- [0031] 도 1은 데이터 셋이 상이한 PHM 모델을 나타낸다.
- 도 2는 건전선 예측 관리 프로세스를 나타낸다.
- 도 3은 본 발명의 일 예에 따른 PHM 모델 설계 방법의 흐름을 나타낸다.
- 도 4는 본 발명의 일 예에 따른 PHM 모델 설계 시스템의 구성을 나타낸다.
- 도 5는 클라우드 플랫폼 서비스를 이용하여 객체의 데이터(선박 엔진 데이터)를 수집하는 경우의 개념도이다.
- 도 6은 클라우드 플랫폼의 구성도이다.
- 도 7은 GAN의 흐름도이다.
- 도 8은 생성기와 판별기의 학습 과정을 나타낸다.
- 도 9는 CGAN의 아키텍처를 나타낸다.
- 도 10은 DGCAN의 아키텍처를 나타낸다.
- 도 11은 전이 학습의 학습 효과를 나타낸다.
- 도 12는 전이 학습의 원리를 나타낸다.
- 도 13은 많은 데이터를 사용하여 만든 신경망을 새로운 신경망에 전이 학습을 통해 적용한 예시이다.
- 도 14는 신경망의 구조를 나타낸다.
- 도 15는 node의 구조를 나타낸다.
- 도 16은 본 발명의 일 예에 따른 전이학습을 이용한 베어링 상태의 예지분류 학습을 나타낸다.
- 도 17은 DANN의 구조를 나타낸다.
- 도 18은 DANN의 학습과정을 나타낸다.
- 도 19는 전이학습을 적용한 근사 최적설계의 개념을 나타낸다.

도 20은 DANN을 적용한 베어링 고장 진단 방법을 나타낸다.

도 21는 DANN을 적용한 베어링 고장 진단의 학습 및 진단 과정을 나타낸다.

도 22는 본 발명을 이용하여 선박 엔진의 PHM 모델을 생성하는 과정을 나타낸다.

발명을 실시하기 위한 구체적인 내용

- [0032] 이하, 첨부된 도면을 참조하여 본 발명을 상세히 설명한다.
- [0033] 도 2는 건전성 예측 관리 프로세스를 나타낸 것으로서, 건전성 예측 관리(PHM)는 운용 중인 객체(시스템, 장치 등)에 대해 건전성(결함이나 성능저하)을 지속관찰(Monitoring)하고, 이상 징후를 진단(Diagnosis)하며 언제 고장수준 또는 사용불능에 도달할지 미리 예지(Prognosis)하여 필요한 경우에만 정비조치를 하는 건전성 관리(Health Management)를 수행하는 기술이다.
- [0034] PHM 모델을 생성할 때 머신러닝 또는 딥러닝을 사용할 수 있다. 사용되는 딥러닝 기법은 예를 들면 CNN(Convolutional Neural Network), LSTM(Long Short Term Memory)등이 있으며, CNN은 이미지를 이용한 이상 분류에 사용된다. 또한 CNN은 시계열 데이터 분류에도 사용되기도 한다. LSTM은 시계열 데이터를 다루는 신경망으로 센서로부터 받는 진동 데이터들이 이러한 시계열 데이터의 예가 된다.
- [0035] 이하에서는 이해를 돕기 위해 선박 엔진에 대한 PHM 모델 생성을 예로 들어 설명하기로 한다.
- [0036] 모든 종류의 PHM 모델은 시스템이나 장치마다 모델의 성능이 다르다. 모델의 성능이 다른 이유는 다음과 같다.
- [0037] 첫째, 데이터 셋(set) 생성에 유리한 모델과, 불리한 모델이 있다. 예를 들어 자동차 엔진은 많은 자동차 모델과 수가 있으며, 다양한 환경에서 작동하기 때문에, 정상 데이터뿐만 아니라 넓은 범위의 이상 징후 데이터를 다량으로 수집하는 것도 용이하여 데이터 셋 생성에 유리하다. 하지만 선박 엔진의 경우 모델도 적으며, 이상 징후 데이터 숫자도 적어 범위도 한정되어 있고, 자동차보다는 상대적으로 다양한 환경에서 작동하지 않아 양질의 데이터 셋 생성이 힘들다. 선박 엔진 데이터 같이 데이터가 적은 경우 건전성 예측 관리 모델이 제대로 학습하지 못해 PHM 모델 성능이 떨어진다.
- [0038] 둘째, 연구실 환경과 같이 인위적 데이터를 만들기 힘든 모델이 있다. 예를 들어 선박 엔진은 구동 환경에서 이상 징후 데이터를 얻는 것이 어렵기 때문에, 데이터를 보완하기 위해 인위적인 이상 징후 데이터를 만들어야 할 필요가 있다. 하지만 크기가 너무 크고, 다양한 이상 징후 환경을 만들기가 어려워, 연구실 환경에서 인위적인 데이터를 만드는 것이 어렵다.
- [0039] 건전성 예측관리 모델 생성에는 데이터 셋 구성이 모델 성능에 가장 중요한 요인이며, 특히 이상 징후 데이터를 다양한 환경에서 얻을 수 없다면 성능이 좋은 모델 생성이 힘들어 예측의 정확도가 부정확해 지는 결과를 초래할 수도 있다.
- [0040] 이러한 문제점들을 극복하기 위하여, 본 발명에서는 각 선박에서 이상 징후 데이터와 다양한 고장 유형을 클라우드 플랫폼 서비스(Cloud Platform Service)의 저장장치(Cloud Storage)에 수집 한 뒤, 클라우드 컴퓨팅 서비스(Cloud Computing Service)를 이용, GAN신경망으로 데이터 증강을 한다. 그리고 클라우드 저장장치 서비스를 이용해 각 객체(ex. 각각의 선박)에 데이터를 공유 한다. 그리고 풍부한 데이터 셋(ex. 자동차)을 이용해 만들었던 PHM모델의 가중치를 객체(ex. 선박)의 PHM모델에 전이 학습하여, PHM모델의 학습을 높여 성능을 향상 시킨다.
- [0041] 도 3은 본 발명의 일 예에 따른 PHM 모델 설계 방법의 흐름을 나타내는 것으로, 도 3을 참조하면 본 발명은, 건전성 예측 관리 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 단계(S100); 상기 데이터를 증강하여 증강 데이터를 생성하는 단계(S200); 및 상기 증강 데이터를 기반으로 상기 대상 시스템 또는 장치의 PHM 모델을 생성하는 단계(S300);를 포함하며, 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 단계(S400);를 더 포함할 수 있다.
- [0042] 도 4는 본 발명의 일 예에 따른 PHM 모델 설계 시스템의 구성을 나타내는 것으로, 도 4를 참조하면 본 발명은, 건전성 예측 관리 모델을 생성할 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 데이터 획득부(100); 데이터 획득부가 획득한 데이터를 전달받아, 전달받은 데이터를 증강하여 증강 데이터를 생성하는 데이터 증강부(200); 데이터 증강부가 생성한 증강 데이터를 전달받아, 증강 데이터를 기반으로 대상 시스템 또는 장치의 PHM 모델을 생성하는 PHM 모델 생성부(300);을 포함하며, 나아가 다른 시스템 또는 장치에 대해 기 학습

된 PHM 모델을 저장하는 기 학습 PHM 모델 저장부(400);를 더 포함할 수 있다.

- [0043] 이하에서는 구체적으로 도 3 내지 도 22를 참조하여, 각 단계별로 본 발명에 따른 PHM 모델의 성능 향상 방법 및 시스템에 대해 설명한다.
- [0044] (1) 대상 시스템 또는 장치의 각 객체에 대한 데이터를 획득하는 단계(S100)
- [0045] 데이터 획득부(100)는 PHM 모델을 생성하고자 할 시스템 또는 장치의 각 객체로부터, 각 객체에 대한 데이터를 획득할 수 있다.
- [0046] (2) 데이터를 증강하여 증강 데이터를 생성하는 단계(S200)
- [0047] 데이터 증강부(200)는 데이터 획득부(100)로부터 객체에 대한 데이터를 전달받아 데이터 증강을 수행할 수 있다. 이때, 데이터 증강부는 클라우드 플랫폼 상에서 구현될 수 있다.
- [0048] 도 5는 클라우드 플랫폼 서비스를 이용하여 객체의 데이터(선박 엔진 데이터)를 수집하는 경우의 개념도이고, 도 6은 클라우드 플랫폼의 구성도이다.
- [0049] 클라우드 플랫폼 서비스는 클라우드(인터넷)를 이용해 컴퓨터 시스템 리소스를 제공하는 클라우드 컴퓨팅(Cloud Computing)과 클라우드 저장 공간(Cloud Storage)등을 제공하는 서비스이다. 구글 클라우드 플랫폼 서비스가 대표적이다. 구글에서 제공하는 프로그래밍 언어는 자바, 파이썬 등이 있으며, 이러한 프로그래밍 언어를 이용하여, 수집되어오는 데이터를 이용해 신경망을 학습시킨다.
- [0050] 본 발명에서는, 다양한 환경과 물리적으로 멀리 떨어져 운행중인 객체(선박)들의 데이터를 수집한다. 이렇게 수집된 각 선박들의 데이터들을 클라우드 플랫폼 서비스의 저장공간(저장장치)에 업로드를 하고, 이를 클라우드 컴퓨팅 서비스를 이용해서 후술할 GAN의 데이터 셋으로 이용하여 데이터 증강을 실행한다.
- [0051] (3) 증강 데이터를 기반으로 대상 시스템 또는 장치의 PHM 모델을 생성하는 단계(S300)
- [0052] PHM 모델 생성부(300)는 데이터 증강부(200)로부터 증강 데이터를 전달받아, 증강 데이터를 기반으로 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.
- [0053] 여기서, 본 발명은 GAN을 이용하여 새로운 데이터를 만들어내어 더 풍부한 데이터를 얻을 수 있다. GAN을 이용한 데이터 증강 방법은 선박 데이터와 같이 정상 데이터 및 비정상 데이터의 불균형이 있을 때 특히 중요하다고 할 수 있는데, 새로운 데이터를 만들어 내기 위해서는 먼저 기존의 데이터가 갖고 있는 분포를 파악해야 한다. 고차원 데이터의 경우 분포가 매우 복잡하게 나타나는 것이 일반적인데, 최근 많은 주목을 받고 있는 인공 신경망을 사용할 경우 이러한 데이터를 효과적으로 처리할 수 있다.
- [0054] GAN은 데이터 생성에 사용되는 대표적인 알고리즘으로, 게임 이론(game theory)에 기반하여 개발되었으며, 판별기(discriminator)와 생성기(generator)라는 두 개의 신경망으로 이루어져 있다.
- [0055] 도 7은 GAN의 흐름도를 나타내고, 도 8은 생성기와 판별기의 학습 과정을 나타낸다. 생성기는 기존 데이터의 분포를 학습하여 새로운 데이터를 만들어 내고, 판별기는 입력 받은 데이터가 실제 존재하는 데이터일 확률을 계산한다. 즉, 두 개의 신경망은 제로섬 게임(zero-sum game)을 하게 되며, 도 8과 같이 이러한 상황의 균형점(Nash equilibrium)은 생성기가 실제 데이터와 구별이 안 되는 데이터를 만들어 내고, 판별기는 실제와 가상 데이터 모두에 대해 0.5의 확률을 배정하는 지점이 된다.
- [0056] 본 발명에서는 조건부 생성적 적대 신경망(Conditional Generative Adversarial Network; CGAN)이 사용될 수도 있다. 도 9는 CGAN의 아키텍처를 나타낸다.
- [0057] 일반적인 GAN의 경우, 생성되는 데이터의 모드(mode)를 제어하기 불가능하다는 단점이 있다. 이러한 특징은 특정한 종류의 데이터를 만들고자 할 때 큰 단점이 된다. 예를 들어, 정상이 아닌 비정상 상태의 데이터나 특정한 비정상 타입의 데이터만을 필요로 할 경우 일반적인 GAN을 사용하는 것은 많은 제약이 따르게 된다. 도 8은 조건부 생성적 적대 신경망의 구조를 나타낸 것으로, CGAN은 일반적인 GAN의 단점을 극복할 수 있는 신경망으로서, 데이터의 레이블(label) 또한 신경망의 입력 값으로 사용할 수 있다.
- [0058] 또는, 본 발명에서는 합성곱 생성적 적대 신경망(DCGAN, Deep convolutional Generative Adversarial Network)이 사용될 수도 있다. 도 10은 DCGAN의 아키텍처를 나타낸다.
- [0059] 일반적인 GAN의 경우, 각 층의 모든 노드(node)가 서로 연결되어 있는(fully connected) 특징을 갖는다. 이는 이미지와 같은 데이터가 갖고 있는 공간적인 특징을 고려하지 않은 것으로, 공간적인 특징을 고려하면 더 효율

적으로 데이터를 처리할 수 있게 된다. 도 9는 합성곱 생성적 적대 신경망의 구조를 나타낸 것으로, DCGAN은 GAN의 모든 층을 합성곱 층(convolutional layer)으로 교체함으로써 더 효과적인 신경망 학습을 가능하게 한다.

[0060] (4) PHM 모델을 생성하는 단계(S300) 이전에, 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장하는 단계(S400)

[0061] 기 학습 PHM 모델 저장부(400)는 다른 시스템 또는 장치에 대해 기 학습된 PHM 모델을 저장할 수 있으며, 이때 PHM 모델 생성부(300)는, 기 학습 PHM 모델 저장부(400)로부터 전달받은 기 학습된 PHM 모델을 전이 학습하여 대상 시스템 또는 장치의 PHM 모델을 생성할 수 있다.

[0062] PHM 모델을 생성하는 단계(S300)에서, 데이터 또는 이미지 생성 및 분류 문제에 사용되는 신경망의 구조 설계와 학습에는 제약 조건이 발생한다. 먼저 훈련 데이터의 수가 충분해야 하며, 학습하기 충분한 시간과 비용이 필요하다. 하지만 PHM 모델을 생성 할 때 마다 신경망을 학습시키기는 것은 시간과 비용 측면에서 비효율적이다.

[0063] 이러한 제약조건에 따른 데이터 수, 시간과 비용에 대한 문제를 전이 학습으로 해결한다. 예를 들어 설명하고 있는 선박 엔진 데이터와 같이, 모든 모델에 대한 데이터 수가 항상 충분히 확보되지 않는다. 만약 적은 데이터 수로 PHM 모델을 학습을 시킨다면 과적합을 발생시키는데, 이는 잘못된 건전성 예측 관리를 할 수 있으며, 이를 방지하기 위하여 전이 학습을 사용할 수 있다. 이때 전이 학습시 비슷한 유형의 신경망끼리 가중치를 공유하도록 하여 신경망의 계산비용을 감소시킬 수 있다.

[0064] 예를 들어, 자동차 엔진의 PHM 모델과 선박 엔진의 PHM 모델은 양자 모두 엔진의 성능과 관련된 건전성 예측관리 모델이라는 점에서 유사한 모델이라고 볼 수 있다. 이때, 많은 데이터 셋으로 학습된 성능이 좋은 자동차 엔진 PHM 모델의 가중치(신경망 학습내용)를 선박 엔진 PHM 모델에 전이 학습해 기존 모델보다 더 나은 성능을 나타 낼 수 있다.

[0065] 도 11은 전이 학습의 학습 효과를 나타내는 것으로, 도 11을 참조하면, 전이 학습을 할 경우 더 높은 학습률(higher start)에서 학습을 시작할 수 있으며, 학습 속도(higher slope)가 전이 학습을 적용하지 않았을 때보다 더 가파른 것을 볼 수 있다. 또한 더 높은 성능 최대치(higher asymptote)를 가진다.

[0066] 도 12는 전이 학습의 원리를 나타내는 것으로, 도 12(a)와 같이 전이 학습 미적용 시 학습 수렴을 위해 많은 시행착오를 겪지만, 도 12(b)와 같이 전이 학습을 적용 시키면 적은 시행착오로 학습을 수렴 할 수 있다.

[0067] 이처럼 전이 학습은 많은 데이터 수로 학습된 신경망 모델을 새로운 신경망에 적용시켜, 학습의 시간과 비용을 줄이고 상대적으로 적은 데이터 수로 학습을 효율적으로 할 수 있다.

[0068] 도 13은 많은 데이터를 사용하여 만든 신경망을 새로운 신경망에 전이 학습을 통해 적용한 예시이다. 도 13(a)는 기존에 학습된 신경망 모델을 의미하고, 도13(b)는 새로운 신경망 모델을 의미한다. (a)의 합성곱(Convolutional Layer)이 학습한 가중치를 (b)의 합성곱에 그대로 전달해, (b)의 합성곱을 빠르게 학습하는데 도움을 준다. 그리고 (b)신경망은 완전 연결 층(Fully Connected Layer-FC Layer)을 학습해 결과 도출을 한다. 도 13에서 가장 마지막에 위치 한 완전 연결 층은 합성곱의 특징을 받아 분류기를 생성하는 층이다. 여기서 분류기란 정상 또는 비정상 상태를 판별하는 층이다. 여기서 가중치란 신경망의 hidden layer의 node를 계산할 때 사용되는 가중치이다.

[0069] 도 14는 신경망의 구조를 나타내고, 도 15는 node의 구조를 나타낸다. 신경망의 구조는 도 13과 같은데, 이 구조에서 hidden layer를 구성하는 것을 node라고 하며, node의 구조는 도 14와 같다. 입력 데이터($x_1, x_2, x_3, \dots, x_n$)에 가중치(weight)($w_1, w_2, w_3, \dots, w_n$)를 곱해서 y값을 도출 한다.

[0070] 신경망은 데이터를 이용하여 가중치를 업데이트하면서 학습한다. 전이 학습은 가중치를 초기 보정한 상태로 학습을 실시할 수 있으며 이 상태가 상술한 도 10에 표시된 higher start이다.

[0071] 전이 학습은 상대적으로 다량의 데이터에도 적용 하거나, 완전 다른 종류의 신경망에도 적용 할 수 있는데, 하기 표 1은 데이터 수와 신경망 모델의 종류에 따른 전이 학습 적용 범위를 정리한 것이다.

표 1

	비슷한 종류의 신경망 학습	다른 종류의 신경망 학습
매우 적은 데이터	완전 연결층만 학습	데이터가 서로 다르기 때문에 다른 학습 방법 필요

많은 데이터	완전 연결층 뿐만 아니라 합성곱도 부분적으로 최적화	전체적으로 최적화 하면서 학습
--------	------------------------------	------------------

- [0073] 여기서 다른 종류의 신경망은 진동데이터 분류 신경망과 이미지 분류 신경망을 예로 들 수 있다. 데이터 부족으로 인한 신경망의 성능 저하와 과적합을 극복하기 위해, 비슷한 범주의 빅 데이터로 학습을 시키고, 전이 학습을 이용해 적은 데이터수의 단점을 보완한다.
- [0074] 도 16은 본 발명의 일 예에 따른 전이학습을 이용한 베어링 상태의 예지분류 학습을 나타낸 것으로, 비슷한 종류의 신경망 학습의 유형의 예시로는 기관차의 베어링의 상태를 진단 예지하는 신경망 모델을 들 수 있다. 실험실에서 만들어진 모터 베어링의 데이터를 가지고 신경망을 학습한 후, 부족한 결함 데이터에 대해 보완하기 위하여, 전이 학습을 통해 기관차 베어링의 상태 진단 예지하는 신경망을 학습할 수 있다.
- [0075] 한편, 이와 같은 전이 학습에 있어서, 본 발명은 특히 전이 학습의 여러 기법 중 도메인 적응(domain adaptation) 기법을 적용시킬 수 있다. 도메인 적응 기법은 레이블(Label)이 풍부한 소스 도메인(source domain)에서 학습된 신경망이 레이블이 없는 유사하지만 다른 도메인(target domain)에서도 잘 작동하도록 하는 방법이다. 이를 이용하여 데이터가 풍부한 도메인에서 학습이 된 신경망을 이용하여 데이터가 부족한 도메인에서의 신경망의 학습을 더욱 효율적으로 할 수 있게 된다.
- [0076] 보다 구체적으로, 본 발명은 도메인 적응 기법 중 DANN(Domain Adversarial Neural Network) 기법을 적용할 수 있다. DANN은 특성 추출기(feature extractor), 분류기(classifier), 도메인 판별기(domain discriminator)로 구성된다. 특성 추출기는 두 도메인 데이터의 특성을 추출한다. 그 후 레이블이 풍부한 데이터의 특성을 이용하여 분류기를 학습시킨다. 그와 동시에 도메인 판별기를 이용하여 두 도메인의 특성이 어느 도메인의 특징인지 구별한다. DANN은 신경망의 학습 과정인 오차 역전파 과정에서 그라디언트 반전층(gradient reversal layer)를 이용하여 도메인 판별기 오차의 부호를 바꾸어 전달하여 두 도메인의 구별 성능을 약화시키고, 결과적으로 두 도메인을 잘 구별할 수 없는 공통의 특성을 얻을 수 있게 한다. 이렇게 얻어낸 특성을 이용하여 데이터가 풍부한 도메인에서 잘 작동하는 분류기를 데이터가 부족한 도메인에서도 잘 작동하게 만들 수 있다. 도 17은 DANN의 구조를 나타내며, 도 18은 DANN의 학습과정을 나타낸다.
- [0077] 여기서, 근사 최적설계를 진행할 때 계산량 감소를 위해서 복잡한 모델을 근사하는 근사모델(surrogate model)을 사용할 수 있다. 정확한 데이터를 얻어내기 위해서는 충분한 양의 데이터가 필요하나, 이러한 데이터를 얻어내는 과정은 많은 비용과 시간이 소요된다. 이러한 상황에서 많은 양의 데이터가 존재하는 비슷한 모델의 데이터를 활용한다면 데이터 부족을 극복하고 정확한 근사모델을 얻을 수 있다. 입력 데이터를 그대로 복원하는 자기부호화기(autoencoder)에 DANN을 적용하여 데이터가 풍부한 모델(source domain)의 데이터를 데이터가 부족한 모델(target domain)의 데이터로 변형할 수 있다. 자기부호화기는 입력 데이터를 압축하여 특징을 추출하는 Encoder와, 압축된 특징을 원래대로 복원하는 Decoder로 구성되어 있다. 특징을 추출하는 Encoder에 DANN을 적용하여 두 개의 서로 다른 모델의 데이터를 구별할 수 없는 공통의 특징을 추출한다. 그 후 데이터가 부족한 모델의 데이터를 복원하는 Decoder에 이러한 특징을 입력하면 공통의 특징으로 바뀌고 데이터가 부족한 모델(target domain)의 형태로 변형될 수 있다. 도 19는 전이학습을 적용한 근사 최적설계의 개념을 나타낸다.
- [0078] 이때, 정확한 고장 진단을 위한 가장 중요한 조건은 충분한 양의 고장 데이터이다. 하지만 실제 산업현장에서 고장 데이터를 확보하는 것에는 상당한 어려움이 따른다. 이러한 고장 데이터의 부족은 고장 진단을 더욱 어렵게 만드는 요소 중에 하나이다. 충분한 고장데이터가 확보된 유사한 시스템(source domain)이 있다면 전이학습 기법을 적용하여 고장 데이터가 부족한 시스템(target domain)의 고장 진단에 활용할 수 있다.
- [0079] 본 발명에서는 일례로서 전이학습 기법을 적용하여 고장에 대한 정보가 없는 상황에서 베어링의 고장(inner race fault, outer race fault, ball fault)를 진단한다. 이때 상술한 도 18의 DANN 구조를 사용하여 학습을 진행할 수 있다. 특성 추출기와 분류기를 이용하여 고장에 대한 정보가 풍부한 시스템의 고장을 진단함과 동시에 두 시스템의 구별을 어렵게 하는 특성을 DANN을 이용하여 추출할 수 있다. 학습이 완료된 이후, 고장에 대한 정보가 부족한 데이터를 특성 추출기와 분류기를 이용하여 고장을 진단할 수 있다. 도 20은 DANN을 적용한 베어링 고장 진단 방법을 나타내고, 도 21은 DANN을 적용한 베어링 고장 진단의 학습 및 진단 과정을 나타낸다.
- [0080] 도 22는 본 발명을 이용하여 선박 엔진의 PHM 모델을 생성하는 과정을 나타낸다. 선박모델의 경우 비정상 데이터를 수집하기 어렵다. 비정상데이터를 수집하여, 더 나은 PHM 모델을 만들고자 하지만, 물리적 거리가 멀리 떨어져 있는 각 객체들의 데이터를 수집하기는 어렵다. 그리고 선박은 정해진 항로로만 운행을 하기 때문에 다양한 환경에서 운행된 이상 데이터를 모으기가 어렵다는 단점이 있다. 이러한 이유로 선박의 PHM 모델 생성시 높

은 성능을 기대하기가 어렵다.

[0081] 이러한 단점을 보완하기 위하여, 본 발명의 PHM 모델 생성 방법을 사용하면, 즉, 클라우드 플랫폼 서비스와 데이터증강 및 다양한 데이터를 가진 모델을 이용한 전이 학습을 사용하면 더 나은 PHM 모델 생성을 할 수 있다.


[0082] 이상과 같이, 본 발명에 따르면, 멀리 떨어져 있는 객체들의 이상 징후 데이터(다양한 환경에서의 이상 데이터를)를 클라우드 플랫폼 서비스를 이용해 수집하고, GAN을 이용한 데이터 증강을 통해 수집된 데이터보다 더 많은 데이터를 확보할 수 있게 되어 부족한 데이터수에 따른 PHM 모델 성능 저하 방지를 방지할 수 있다.

[0083] 또한, 본 발명에 따르면 전이 학습을 통한 PHM 모델에 사용되는 머신러닝 또는 딥러닝 신경망의 성능을 높여 예지보전을 더욱 정확하게 할 수 있고 시간과 거리의 제약을 받지 않고, PHM 모델을 지속적으로 운용할 수 있다.

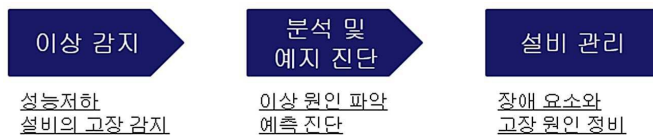
[0084] 이상 본 발명의 설명을 위하여 예시로 든 실시예는 본 발명이 구체화되는 하나의 실시예에 불과하며, 본 발명의 요지가 실현되기 위하여 다양한 형태로 조합이 가능하다. 따라서 본 발명은 상기한 실시예에 한정되지 않고, 이하의 청구범위에서 청구하는 바와 같이 본 발명의 요지를 벗어남이 없이 당해 발명이 속하는 분야에서 통상의 지식을 가진 자라면 누구든지 다양한 변경실시가 가능한 범위까지 본 발명의 기술적 특징이 있다고 할 것이다.

도면

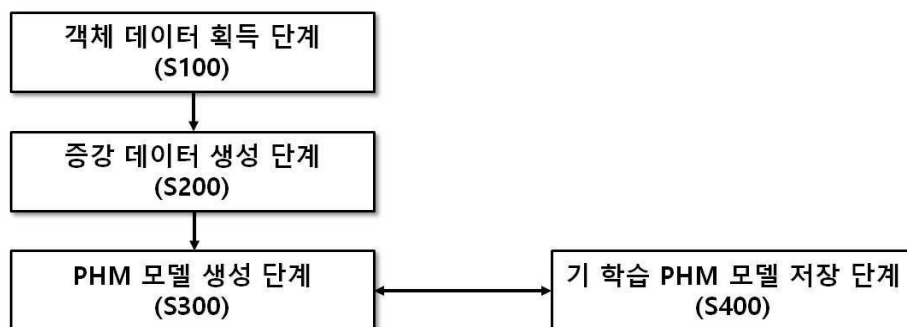
도면1



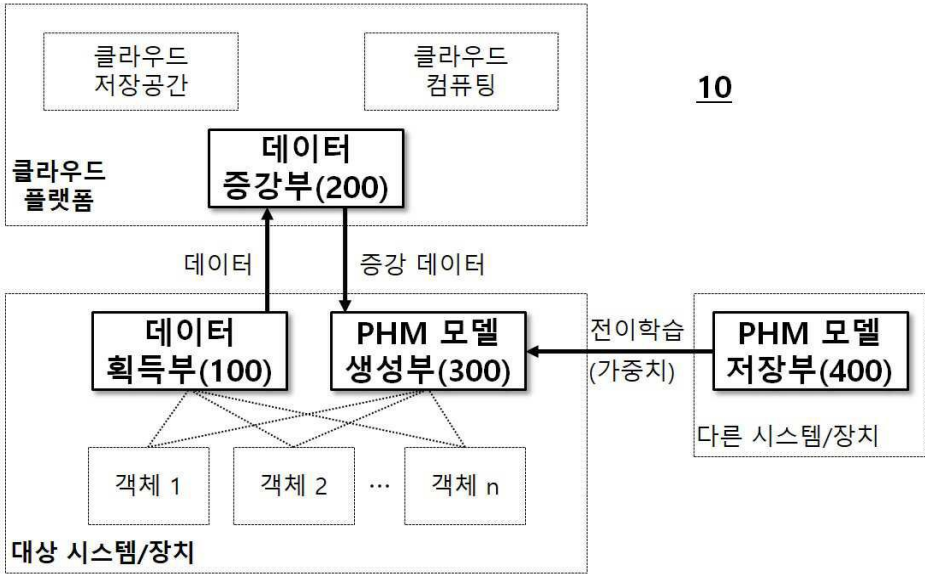
도면2



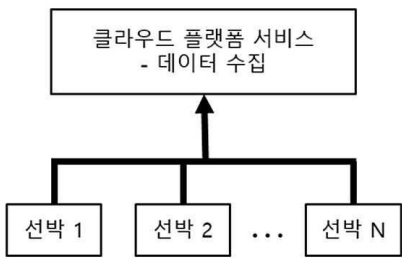
도면3



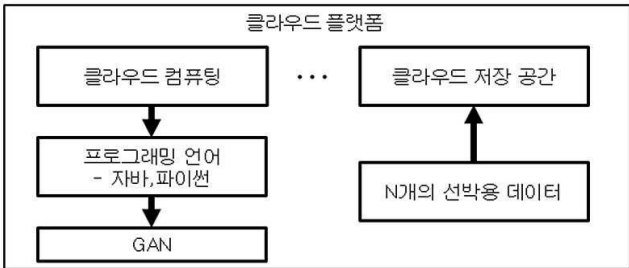
도면4



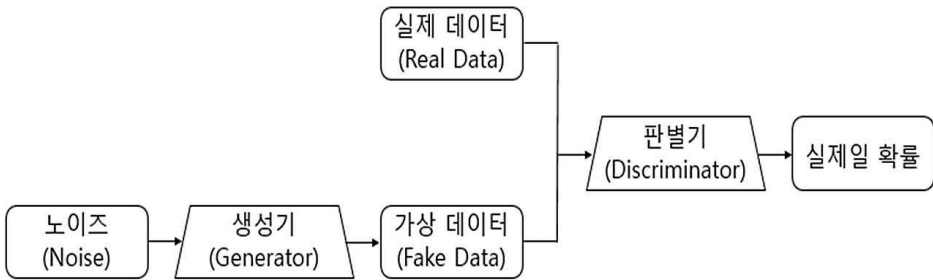
도면5




도면6



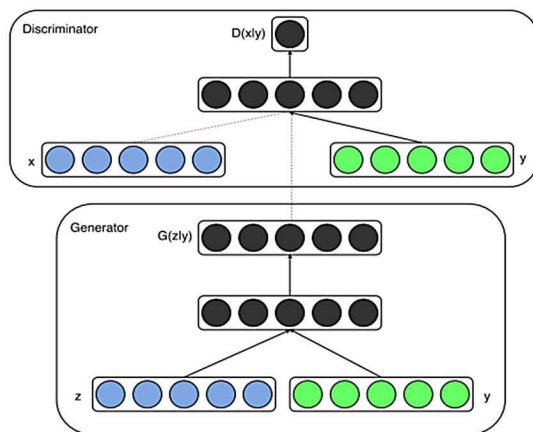
도면7




도면8




도면9



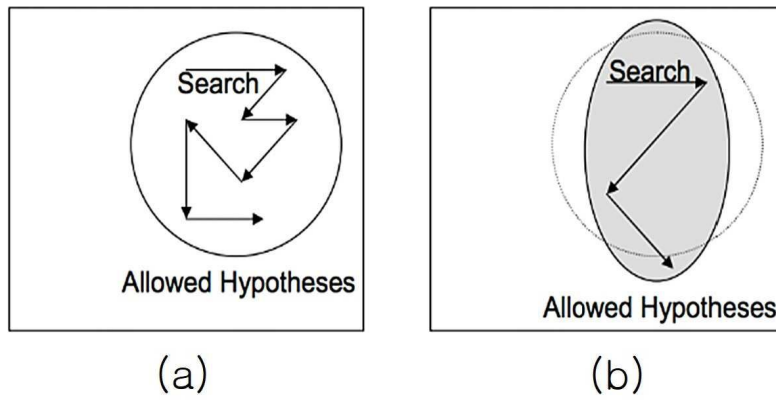
도면10



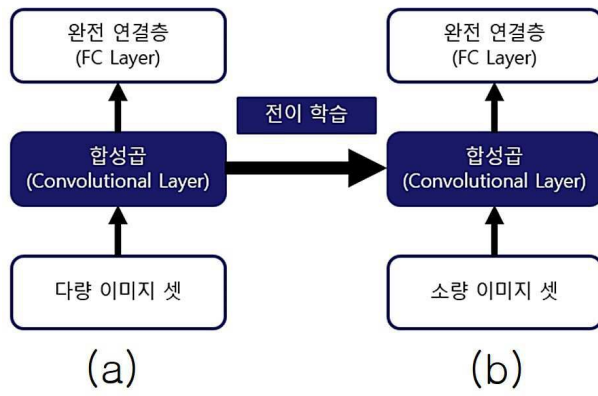
도면11




도면12




도면13



도면14




도면15




$$y(\text{node}) = x_1 w_1 + x_2 w_2 + x_3 w_3 + \dots + x_n w_n$$

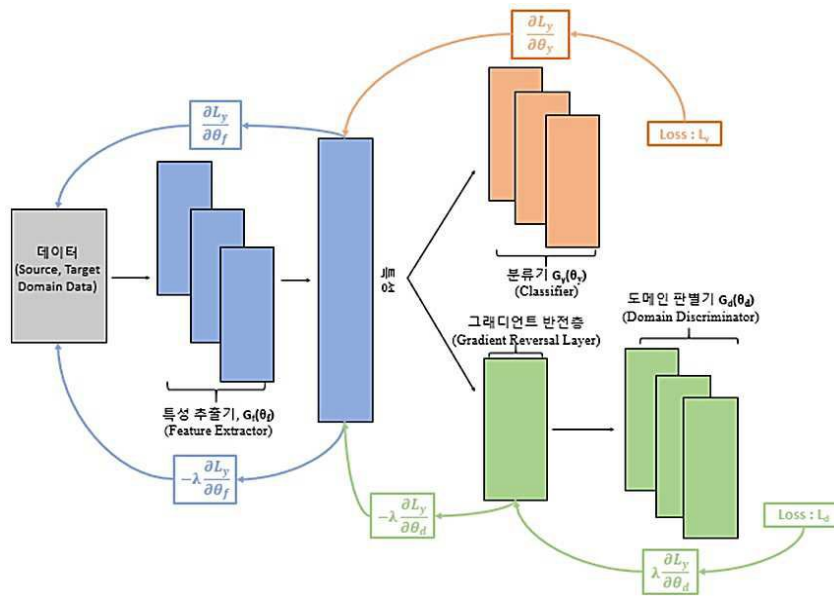
도면16




도면17



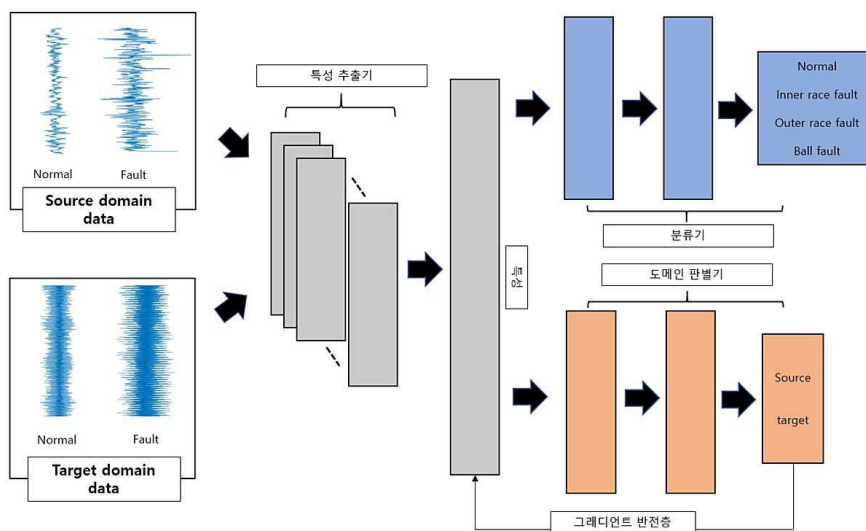
도면18



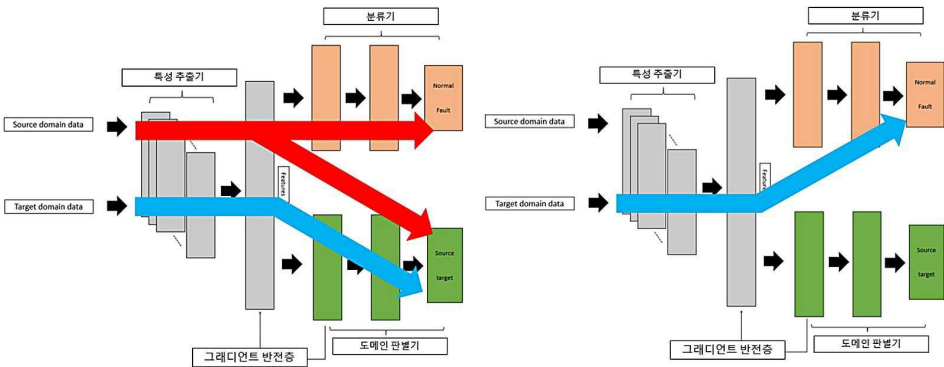
도면19



도면20



도면21



도면22

