



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0162408
(43) 공개일자 2024년11월15일

(51) 국제특허분류(Int. Cl.)
G05B 23/02 (2006.01) G06N 3/0455 (2023.01)
G06N 3/0475 (2023.01) G06N 3/09 (2023.01)
(52) CPC특허분류
G05B 23/0262 (2013.01)
G05B 23/0243 (2013.01)
(21) 출원번호 10-2023-0079893
(22) 출원일자 2023년06월21일
심사청구일자 2023년06월21일
(30) 우선권주장
1020230059375 2023년05월08일 대한민국(KR)

(71) 출원인
한국수력원자력 주식회사
경상북도 경주시 문무대왕면 불국로 1655
포항공과대학교 산학협력단
경상북도 포항시 남구 청암로 77 (지곡동)
(72) 발명자
이승철
경상북도 포항시 남구 청암로 77
박형식
경상북도 포항시 남구 청암로 77
이지훈
경상북도 포항시 남구 청암로 77
(74) 대리인
특허법인아이엠

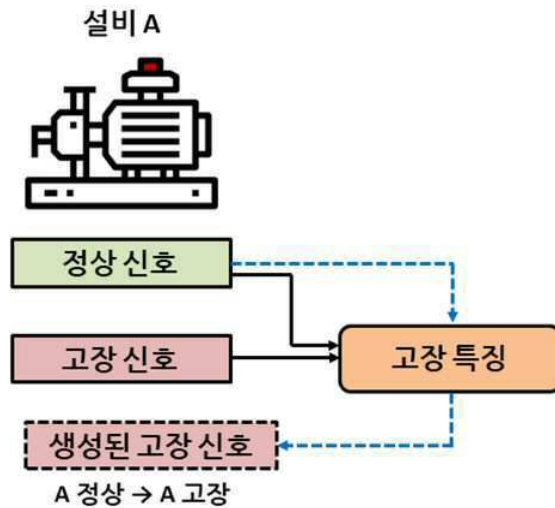
전체 청구항 수 : 총 10 항

(54) 발명의 명칭 인공지능 기반 고장 특성 조작을 이용한 설비의 정상 신호로부터 고장 신호 생성 방법

(57) 요약

본 발명은 인공지능 기반 고장 특성 조작을 이용한 설비의 정상 신호로부터 고장 신호 생성 방법에 관한 것이다. 본 발명에 따른 방법, (a) 설비에서 취득되는 정상 신호와 고장 신호의 차이를 통해 고장 신호에서 나타나는 특징을 도출하는 단계와, (b) 도출된 고장 신호의 특징을 정상 신호에 부여하여 새로운 고장 신호를 생성하는 단계를 포함하는 것을 특징으로 한다.

대표도 - 도1



(52) CPC특허분류

G05B 23/0275 (2013.01)

G06N 3/0455 (2023.01)

G06N 3/0475 (2023.01)

G06N 3/09 (2023.01)

명세서

청구범위

청구항 1

- (a) 설비에서 취득되는 정상 신호와 고장 신호의 차이를 통해 고장 신호에서 나타나는 특징을 도출하는 단계와,
- (b) 도출된 고장 신호의 특징을 정상 신호에 부여하여 새로운 고장 신호를 생성하는 단계를 포함하는, 고장 신호 생성 방법.

청구항 2

제1항에 있어서,

상기 설비는 제1설비와 제2설비를 포함하고,

상기 (a) 단계에서는, 제2설비에서 생성되는 정상 신호와 고장 신호의 차이를 통해 고장 신호에서 나타나는 특징을 도출하고,

상기 (b) 단계에서는, 제2설비에서 도출된 고장 신호의 특징을 제1설비에서 생성되는 정상 신호에 부여하여 제1설비의 고장 신호를 생성하는 단계를 포함하는, 고장 신호 생성 방법.

청구항 3

제1항 또는 제2항에 있어서,

상기 (a) 단계는,

(a-1) 상기 설비에서 취득된 신호를 전처리하여 정규화하는 단계와,

(a-2) 인코더 모델을 통해 정규화처리된 신호로부터 잠재 벡터를 예측하는 단계와,

(a-3) 상기 잠재 벡터를 분류 모델에 입력하여 정상 신호와 고장 신호를 분류하는 단계와,

(a-4) 정상 신호와 고장 신호 간의 손실(loss) 값을 구하는 단계를 포함하는, 고장 신호 생성 방법.

청구항 4

제3항에 있어서,

상기 (b) 단계는,

(b-1) 정상 신호로 분류된 잠재 벡터에 상기 손실(loss) 값을 적용하여 잠재 벡터를 업데이트하여 변환하는 단계와,

(b-2) 변환된 잠재 벡터를 생성 모델에 입력하여 새로운 고장 신호를 생성하는 단계를 포함하는, 고장 신호 생성 방법.

청구항 5

제3항에 있어서,

상기 정규화는 STFT(Short Time Fourier Transform)를 통해 처리된 것인, 고장 신호 생성 방법.

청구항 6

제3항에 있어서,
 상기 인코더 모델은 2차원 합성곱 신경망(Convolution layer)로 이루어진 것인, 고장 신호 생성 방법.

청구항 7

제4항에 있어서,
 상기 손실(loss) 값은 하기 [식 1]과 같이 적용되어 변환된 잠재 벡터를 생성하는 것인, 고장 신호 생성 방법.
 [식 1]

$$W_{new} = W_{origin} - \eta * W.grad$$

(여기서, W_{new} 는 변환된 잠재 벡터, W_{origin} 은 변환되기 전의 잠재 벡터, $W.grad$ 는 손실값이 역전파된 그래디언트 (gradient)값, η 는 사용자가 지정하는 변수)

청구항 8

제4항에 있어서,
 상기 생성 모델은 적대적 생성 신경망 기반의 인공지능 생성 모델인, 고장 신호 생성 방법.

청구항 9

제1항 또는 제2항에 있어서,
 상기 설비에서 취득되는 정상 신호와 고장 신호는, 진동 신호, 음향 신호, 가속도 신호 또는 이미지인, 고장 신호 생성 방법.

청구항 10

제2항에 있어서,
 상기 제2설비는 제1설비의 유사설비인, 고장 신호 생성 방법.

발명의 설명

기술 분야

[0001] 본 발명은 인공지능 기반 고장 특성 조작을 이용한 설비의 정상 신호로부터 고장 신호 생성 방법에 관한 것이다.

배경 기술

[0003] 보다 효율적이고 안정적인 설비 운영을 위해 설비의 고장 진단 방법들이 꾸준히 연구 및 개발되어 오고 있다. 일반적으로 고장 진단은 설비에 부착된 가속도 센서와 같은 측정 장비로부터 취득된 데이터를 분석하는 방식을 통해 이루어진다.

[0004] 이와 관련하여, 취득된 다량의 데이터를 활용하여 머신러닝, 딥러닝과 같은 인공지능 모델을 학습시켜 정확하고

자동화된 설비 진단을 하고자 하는 알고리즘들이 제안되고 있다.

- [0005] 그런데 실제 설비로부터 취득되는 정상 데이터와 비정상 데이터의 수에는 심각한 불균형이 존재하고, 이러한 데이터 불균형은 데이터 기반으로 동작하는 인공지능 모델이 편향된 정보를 학습하게 만들고 결과적으로 모델의 성능을 왜곡시킬 뿐만 아니라 모델의 신뢰성과 강건성에 심각한 문제를 초래한다.
- [0006] 이러한 데이터 불균형 문제를 해소하기 위해, 종래 데이터 샘플링을 하거나 고장 데이터와 유사한 데이터를 생성(증강)함으로써 데이터 불균형을 해소하는 방법이 제안되었다. 이러한 방법으로, 소수 클래스의 고장 데이터를 단순히 반복적으로 학습 데이터 세트에 포함시키는 오버 샘플링(over-sampling)이나 다수 클래스의 정상 데이터 중 일부만 학습 데이터 세트에 포함시키는 다운 샘플링(down-sampling)이 있다.
- [0007] 이 중 오버 샘플링의 경우, 소수 클래스의 고장 데이터를 단순히 복제하는 방식이므로 데이터의 수는 정상 데이터와 같아질 수 있으나 모델 과적합(overfitting)이 발생할 수 있으며 실질적으로 인공지능 모델이 학습하는 데이터의 수는 여전히 불균형하다. 그리고 다운 샘플링의 경우, 다수 클래스의 데이터 수를 줄이므로 데이터 불균형은 해소되나, 학습 데이터 자체가 급격히 감소하여 데이터의 중요한 특징들이 사라지는 문제가 있다. 즉, 샘플링 기반의 접근법들은 모두 데이터 불균형에 대한 근본적인 해결책이 될 수 없다.
- [0008] 또한, 적대적 인공 신경망(GAN, Generative Adversarial Network)과 같은 인공지능 기반 생성 모델을 통해 고장 데이터와 유사한 데이터를 생성한 후 생성된 고장 데이터를 학습 데이터 세트에 추가하는 방법이 있다.
- [0009] 이 방법은 인공지능 기반 생성 모델이 고장 데이터의 분포를 학습하고, 유사한 고장 특징을 가지는 새로운 데이터를 생성한다는 점에서 데이터 불균형 해소가 가능하지만, 해당 설비에 고장 데이터가 존재하는 경우에만 적용 가능하다는 한계점이 존재한다. 즉, 설비에 고장 데이터가 존재하지 않는 경우 생성 모델 학습과 데이터 증강이 불가능하다. 뿐만 아니라 취득된 고장 데이터가 적을 경우, 생성 모델 또한 고장 데이터의 국소적인 분포만을 학습하게 되고 이는 제한적인 특징만을 가진 고장 데이터를 생성한다는 한계점이 존재한다.
- [0010] 즉, 상술한 2가지의 종래기술은, 취득된 소수의 고장 데이터로 인공지능 기반 생성 모델을 학습시키기 때문에, 생성되는 고장 데이터들이 대부분 학습 데이터와 유사성이 높으며 다양성이 낮은 문제점이 있다. 또한, 설비에 고장 데이터가 없는 경우 생성 모델을 학습시킬 수도 데이터 증강도 불가능한 문제점이 있다.

선행기술문헌

특허문헌

- [0012] (특허문헌 0001) 대한민국 공개특허공보 제2021-0061517호

발명의 내용

해결하려는 과제

- [0013] 본 발명의 목적은 인공지능 기반 고장 특성 조작을 이용하여 설비의 정상 신호로부터 고장 신호를 생성할 수 있는 방법을 제공하는데 있다.

과제의 해결 수단

- [0015] 상기 과제를 해결하기 위하여 본 발명은 설비의 정상 신호로부터 고장 신호 생성 방법을 제공한다.
- [0016] (1) (a) 설비에서 생성되는 정상 신호와 고장 신호의 차이를 통해 고장 신호에서 나타나는 특징을 도출하는 단계와, (b) 도출된 고장 신호의 특징을 정상 신호에 부여하여 새로운 고장 신호를 생성하는 단계를 포함하는 고장 신호 생성 방법.
- [0017] (2) (1)에 있어서, 상기 설비는 제1설비와 제2설비를 포함하고, 상기 (a) 단계에서는, 제2설비에서 생성되는 정상 신호와 고장 신호의 차이를 통해 고장 신호에서 나타나는 특징을 도출하고, 상기 (b) 단계에서는, 제2설비에서 도출된 고장 신호의 특징을 제1설비에서 생성되는 정상 신호에 부여하여 제1설비의 고장 신호를 생성하는 단

계를 포함하는 고장 신호 생성 방법.

- [0018] (3) (1) 또는 (2)에 있어서, 상기 (a) 단계는, (a-1) 상기 설비에서 취득된 신호를 전처리하여 정규화하는 단계와, (a-2) 인코더 모델을 통해 정규화처리된 신호로부터 잠재 벡터를 예측하는 단계와, (a-3) 상기 잠재 벡터를 분류 모델에 입력하여 정상 신호와 고장 신호를 분류하는 단계와, (a-4) 정상 신호와 고장 신호 간의 손실 (loss) 값을 구하는 단계를 포함하는 고장 신호 생성 방법.
- [0019] (4) (3)에 있어서, 상기 (b) 단계는, (b-1) 정상 신호로 분류된 잠재 벡터에 상기 손실(loss) 값을 적용하여 잠재 벡터를 업데이트하여 변환하는 단계와, (b-2) 변환된 잠재 벡터를 생성 모델에 입력하여 새로운 고장 신호를 생성하는 단계를 포함하는 고장 신호 생성 방법.
- [0020] (5) (3)에 있어서, 상기 정규화는 STFT(Short Time Fourier Transform)를 통해 처리된 것인, 고장 신호 생성 방법.
- [0021] (6) (3)에 있어서, 상기 인코더 모델은 2차원 합성곱 신경망(Convolution layer)로 이루어진 것인, 고장 신호 생성 방법.
- [0022] (7) (4)에 있어서, 상기 손실(loss) 값은 하기 [식 1]과 같이 적용되어 변환된 잠재 벡터를 생성하는 것인, 고장 신호 생성 방법.
- [0023] [식 1]
- [0024]
$$W_{new} = W_{origin} - \eta * W.grad$$
- [0025] (여기서, W_{new} 는 변환된 잠재 벡터, W_{origin} 은 변환되기 전의 잠재 벡터, $W.grad$ 는 손실값이 역전파된 그래디언트 (gradient) 값, η 는 사용자가 지정하는 변수)
- [0026] (8) (4)에 있어서, 상기 생성 모델은 적대적 생성 신경망 기반의 인공지능 생성 모델인, 고장 신호 생성 방법.
- [0027] (9) (1) 또는 (2)에 있어서, 상기 설비에서 취득되는 정상 신호와 고장 신호는, 진동 신호, 음향 신호, 가속도 신호 또는 이미지인, 고장 신호 생성 방법.
- [0028] (10) (2)에 있어서, 상기 제2설비는 제1설비의 유사설비인, 고장 신호 생성 방법.

발명의 효과

- [0030] 본 발명에 따른 방법에 의하면, 종래 기술처럼 고장 신호만을 학습하는 것이 아니라, 정상 신호와 고장 신호 사이의 관계를 학습하고 이를 정상 신호에 적용하는 방식을 제공한다. 이를 통해 종래 기술에서 생성되는 고장 데이터들이 대부분 학습 데이터와 유사성이 높으며 다양성이 낮은 문제점을 해소하면서 정상 신호와 고장 신호 사이의 데이터 불균형을 해소할 수 있다.
- [0031] 또한, 본 발명의 일 실시형태에 의하면, 유사 설비의 고장 특징을 사용하여 설비에 고장 데이터가 없는 경우에도 고장 신호를 생성할 수 있게 되어, 종래 고장 데이터가 없는 경우 생성 모델을 학습시킬 수도 데이터 증강도 불가능한 문제를 해소할 수 있다.

도면의 간단한 설명

- [0033] 도 1은 정상 신호와 고장 신호가 모두 존재하는 경우, 고장 특징을 학습한 후 정상 신호에 부여하여 새로운 고장 신호를 생성하는 과정이다.
- 도 2는 설비에 정상 신호만 존재하는 경우, 유사 설비의 데이터를 활용하여 고장 신호를 생성하는 과정이다.
- 도 3은 설비 A와 설비 B의 진동 신호로서 정상 신호와 고장 신호의 상태를 나타낸 것이다.
- 도 4는 도 3의 정상 신호와 고장 신호를 STFT 형태로 변환되어 정규화된 데이터이다.
- 도 5는 잠재 벡터 예측에 사용되는 인코더 모델과 이 모델의 학습 과정을 나타낸 것이다.
- 도 6은 잠재 벡터 분류 모델 학습 과정과 고장 특성을 조작하는 방법을 나타낸 것이다.

- 도 7은 고장 특성이 조작된 잠재 벡터를 사용하여 STFT 이미지를 생성하는 생성 신경망 구조이다.
- 도 8은 정상 신호에 고장 특성을 부여하여 변환된 고장 신호의 검증용 분류 모델을 나타낸 것이다.
- 도 9는 실시예에 따른 생성 신경망으로 생성된 데이터와 실제 데이터의 STFT 이미지를 비교한 것이다.
- 도 10은 실시예에 따른 생성 신경망으로 생성된 데이터와 실제 데이터의 time-domain을 비교한 것이다.
- 도 11은 설비 A의 정상 신호를 설비 A의 고장 신호로 변환하여 도출된 결과이다($n=3$).
- 도 12는 설비 A의 정상 신호를 설비 A의 고장 신호로 변환하여 도출된 결과이다($n=20$).
- 도 13은 설비 B의 정상 신호를 설비 B의 고장 신호로 변환한 결과, (우) n 값이 증가함에 따라 생성되는 신호와 실제 데이터들을 t-SNE를 통해 나타낸 것이다.

발명을 실시하기 위한 구체적인 내용

- [0034] 아래에서는 첨부한 도면을 참조하여 본원이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 본원의 실시예를 상세히 설명한다. 그러나 본원은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예에 한정되지 않는다.
- [0035] 본원 명세서 전체에서, 어떤 부분이 어떤 구성 요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성 요소를 제외하는 것이 아니라 다른 구성 요소를 더 포함할 수 있는 것을 의미한다.
- [0036] 본 명세서에서 사용되는 정도의 용어 "약", "실질적으로" 등은 언급된 의미에 고유한 제조 및 물질 허용오차가 제시될 때 그 수치에서 또는 그 수치에 근접한 의미로 사용되고, 본원의 이해를 돕기 위해 정확하거나 절대적인 수치가 언급된 개시 내용을 비양심적인 침해자가 부당하게 이용하는 것을 방지하기 위해 사용된다. 또한, 본원 명세서 전체에서, "~ 하는 단계" 또는 "~의 단계"는 "~를 위한 단계"를 의미하지 않는다.
- [0037] 도 1은 정상 신호와 고장 신호가 모두 존재하는 경우, 고장 특징을 학습한 후 정상 신호에 부여하여 새로운 고장 신호를 생성하는 과정이다.
- [0038] 도 1에 도시된 것과 같이, 본 발명에서는 설비 A에서 발생하는 정상 신호와 고장 신호에서 양 신호의 차이를 고장 특징으로 도출하고, 정상 신호에 고장 특징을 소정 크기로 적용하는 방법을 통해 새로운 고장 신호를 도출하는 것을 특징으로 한다.
- [0039] 이를 통해 도출된 새로운 고장 신호는 다양하게 조절될 수 있으므로, 정상 신호와의 데이터 불균형을 해소할 수 있을 뿐 아니라, 종래 기술에서 생성되는 고장 데이터들이 대부분 학습 데이터와 유사성이 높으며 다양성이 낮은 문제점을 해소할 수 있다.
- [0040] 도 2는 설비에 정상 신호만 존재하는 경우, 유사 설비의 데이터를 활용하여 고장 신호를 생성하는 과정이다.
- [0041] 도 2에 도시된 것과 같이, 설비 B에는 정상 신호만이 있는 경우, 종래 방법에서는 생성 모델을 학습시킬 수도 없고 데이터 증강도 불가능하여, 머신러닝, 딥러닝과 같은 인공지능 모델에 의한 자동화된 설비 진단이 어렵다.
- [0042] 이 경우, 본 발명은 설비 B와 유사 설비 관계에 있고 정상 신호와 고장 신호가 취득되는 설비 A의 정상 신호와 고장 신호의 분석을 통해 고장 특징을 도출하고, 이 고장 특징을 유사 설비인 설비 B에 적용하여 설비 B의 고장 신호를 생성할 수 있다. 이를 통해 생성된 설비 B의 고장 신호를 사용하여 학습된 인공지능 모델을 통해 설비 B의 자동화된 설비 진단이 가능하게 된다.
- [0043] 설비에서 발생하는 정상 신호와 고장 신호에서 양 신호의 차이를 고장 특징으로 도출하고, 정상 신호에 고장 특징을 소정 크기로 적용하는 방법을 통해 새로운 고장 신호를 도출하는 과정은 다음과 같이, 데이터 전처리 단계, 잠재 벡터 예측 단계, 잠재 벡터 분류 단계, 고장 특성 도출 단계, 잠재 벡터 업데이트 단계, 생성 모델 적용 단계를 통해 인공지능 기반으로 이루어질 수 있다.
- [0045] (1) 데이터 전처리 단계
- [0046] 이 단계는 설비들에서 수집된 신호(즉, 데이터)를 인공지능 기반 학습모델을 사용할 수 있도록 처리하는 단계이다.

- [0047] 여기서, "신호"란 설비에 구비된 다양한 형태의 센서를 통해 취득할 수 있는 다양한 형태의 신호를 포함하며, 예를 들어 진동 신호, 음향 신호, 이미지 등일 수 있다.
- [0048] 도 3은 각각 설비 A와 설비 B에서 취득된 진동 신호의 예시로, 정상 신호(도면에서 "Normal"로 표시)와 고장 신호(도면에서 "Abnormal"로 표시)의 상태를 나타낸다.
- [0049] 이러한 신호들은, 도 4에 나타낸 것과 같이, STFT(Short Time Fourier Transform)을 통해 전처리되어 정규화된다.
- [0050] 한편, 도 4에 나타낸 B 설비의 고장 신호는 생성된 고장 신호와의 비교를 통해 본 발명의 효과를 확인하기 위한 것이다. 즉, 설비 B의 고장 신호는 오로지 검증용이며 설비의 개수와 고장 유형에도 제한이 없다.
- [0052] (2) 잠재 벡터 예측 단계
- [0053] 이 단계는 정규화 처리된 신호로부터 데이터 변환을 위한 데이터를 생성하도록 잠재 벡터값을 찾는 단계로, 전처리 단계를 통해 도출된 STFT 이미지를 입력받아 잠재 벡터를 예측하는 인코더 모델을 통해 이루어진다.
- [0054] 도 5에 도시된 것과 같이, 인코더 모델은 2차원 합성곱 신경망(Convolution layer)으로 이루어질 수 있으며, 이 모델은 예측된 잠재 벡터가 다시 생성자를 통해 재건(reconstruction)되고 실제 이미지와 재건된 이미지의 차이를 줄이는 방향으로 학습될 수 있다. 이때, 재건을 위한 생성자는 학습되지 않고 고정된다.
- [0056] (3) 잠재 벡터 분류 단계
- [0057] 이 단계에서는 고장 특성을 추출하기 위한 것으로, 전술한 인코더 모델을 통해 도출된 잠재 벡터를 분류 모델에 입력하여 정상 유형과 고장 유형을 분류한다.
- [0058] 분류 모델로는 예를 들어, 완전연결계층 신경망 (fully connected layers) 로 이루어진 DNN (Deep Neural Network) 이 사용될 수 있다.
- [0060] (4) 고장 특성 값 도출 단계
- [0061] 이 단계는 전술한 정상 신호와 고장 신호의 분류 단계를 통해 분류된 정상 신호와 고장 신호 간의 손실(loss) 값을 구하는 단계이다.
- [0063] (5) 잠재 벡터 업데이트 단계
- [0064] 이 단계는 정상 유형으로 분류된 잠재 벡터에 상기 손실(loss) 값이 역전파되어 그래디언트(gradient) 값을 계산하고, 계산된 그래디언트 값을 정상 유형으로 분류된 잠재 벡터에 소정 비율로 업데이트하여 새로운 잠재 벡터를 생성하는 단계이다.
- [0065] 도 6에 나타낸 것과 같이, 새로운 잠재 벡터는 아래 [식 1]에 따라 업데이트 될 수 있다.
- [0066] [식 1]
- [0067]
$$W_{new} = W_{origin} - \eta * W.grad$$
- [0068] (W_{new} 는 변환된 잠재 벡터, W_{origin} 은 변환되기 전의 잠재 벡터, $W.grad$ 는 손실값이 역전파된 그래디언트(gradient) 값, η 는 사용자가 지정하는 변수)
- [0069] 상기 [식 1]에서 사용자가 지정하는 η 값의 조절을 통해 고장 특징의 크기를 조절하여 다양한 고장 신호를 생성할 수 있게 된다.
- [0070] 잠재 벡터를 업데이트 하는 방법으로, 유사 설비의 고장 잠재 벡터에서 유사 설비의 정상 잠재 벡터를 뺀 (정상에서 고장으로의 방향) 벡터를 고장 특징 벡터로 정의하고 이를 목표 설비의 정상 벡터에 더하는 방식도 사용 가능하다.

- [0072] (6) 고장 신호 생성 단계
- [0073] 이 단계는 생성 모델을 사용하여 앞선 단계를 통해 생성된 새로운 잠재 벡터를 입력하여 고장 신호(이미지)를 생성하는 단계이다.
- [0074] 상기 생성 모델은 적대적 생성 신경망(Generative Adversarial Network, GAN) 기반의 인공지능 생성 모델로 구성될 수 있다.
- [0075] 예를 들어, 데이터 간의 복잡한 관계를 최대한 선형적으로 풀어내기 위해 도 7에 도시된 것과 같이, 정규분포에서 샘플링된 잠재 벡터(z)를 완전 연결 계층(Fully Connected Layer)을 통과시켜 계산된 잠재 벡터(w)로부터 STFT 이미지를 생성하는 생성 신경망(Generator)으로 구성될 수 있다.

- [0077] (7) 검증 단계
- [0078] 이 단계는 정상 신호에 고장 특성을 부여하여 변환된 고장 신호가 의도한 대로 변환되었는지를 판단하기 위한 단계이다.
- [0079] 이를 위한 검증 모델은 설비 A와 설비 B의 정상 및 고장 데이터를 전부 분류하도록 학습될 수 있고, 도 8과 같이 생성 신경망을 통해 생성된 STFT 이미지를 입력으로 받아 4가지 유형을 분류하는 모델이다.

- [0081] 생성된 고장 신호와 실제 신호의 비교
- [0082] 도 9는 이상과 같은 과정을 통해 최종적으로 생성 신경망으로 생성된 데이터와 실제 데이터의 STFT 이미지를 비교한 것이다. 도 9에서 확인되는 바와 같이, 생성 신경망을 통해 생성된 정상 데이터와 고장 데이터는 실제 데이터의 STFT 이미지의 특성과 매우 유사한 것을 알 수 있다.
- [0083] 도 10은 실시예에 따른 생성 신경망으로 생성된 STFT 이미지를 시간 도메인으로 변환한 후, 실제 데이터(도면에서 "Real"로 표시)와 생성 데이터(도면에서 "Generated"로 표시)를 비교한 결과를 나타낸 것이다. 도 10에서 확인되는 바와 같이, 생성 신경망으로 생성된 정상 신호와 고장 신호는 실제 측정된 정상 신호 및 고장 신호와 유사한 특징을 가짐을 알 수 있다.

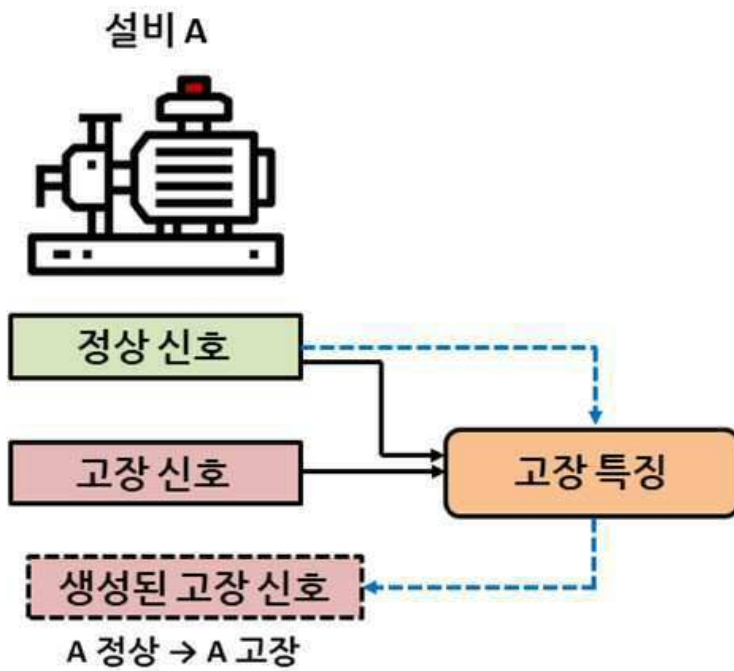
- [0085] 고장 특징의 조절
- [0086] 설비 A의 정상 신호를 인코딩하여 잠재 벡터를 계산한 후 잠재 벡터 분류 모델을 통해 예측한다.
- [0087] 다음으로, 변환하고자 하는 목표 특징을 "고장"으로 설정하여 잠재 벡터 업데이트($n=3$) 진행 후, 생성 신경망을 통해 STFT 이미지를 생성하고, 생성된 STFT 이미지를 시간 도메인으로 변환하였다.
- [0088] 그 결과, 도 11과 같이 고장 특징이 나타나는 신호로 변환되었으며, 전술한 검증 모델을 통해서도 설비 A의 고장 데이터로 분류됨을 확인하였다.
- [0089] 한편, 잠재 벡터 업데이트 시에 사용자가 지정하는 n 값을 조절함으로써 고장 특징의 정도를 조절할 수 있다.
- [0090] 예를 들어, n 값을 20으로 하여 고장 앰플리튜드(amplitude)를 더 크게 하여 잠재 벡터 업데이트를 진행한 후 생성 신경망을 통해 STFT 이미지를 생성하고, 생성된 STFT 이미지를 변환하면 도 12와 같은 고장 신호 데이터를 얻을 수 있다.

- [0092] 유사 설비로부터 고장 신호의 생성
- [0093] 설비 B의 신호를 인코딩 모델을 통해 잠재 벡터를 예측(계산)한 후 잠재 벡터 분류 모델을 통해 예측한다.
- [0094] 분류 모델을 통해 설비 B의 정상 신호로 분류된 잠재 벡터에 설비 A에서 도출된 목표 특징을 고장으로 설정하여, 잠재 벡터 업데이트를 진행한 후, 생성 신경망을 통해 STFT 이미지를 도출하고 생성된 STFT 이미지를 시간 도메인으로 변환하였다.

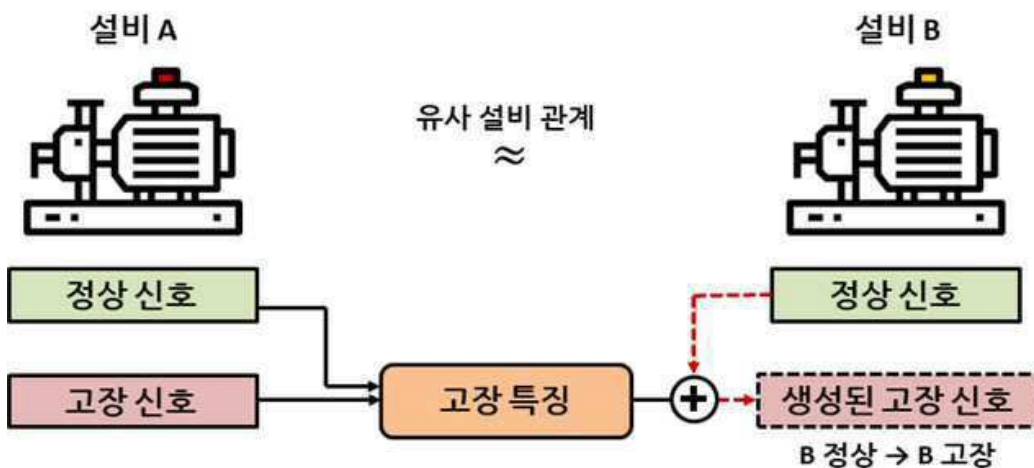
- [0095] 그 결과 도 13과 같이, 고장 특징이 나타나는 신호로 변환되었으며, 이를 검증 모델을 통해 검증한 결과, 설비 B의 고장 데이터로 분류되었다.
- [0096] 또한, 도 13의 우측 그림과 같이, 실제 데이터와 생성된 신호를 t-SNE 차원 축소 방법을 이용하여 나타냈을 때, n 값이 증가함에 따라 설비 B의 정상 신호로부터 설비 B의 고장 신호로 이동하였다.
- [0097] 이를 통해, 고장 데이터가 없는 경우에도 유사 설비의 데이터를 활용하여 목표 설비의 고장 데이터를 생성할 수 있음을 알 수 있다.

도면


도면1



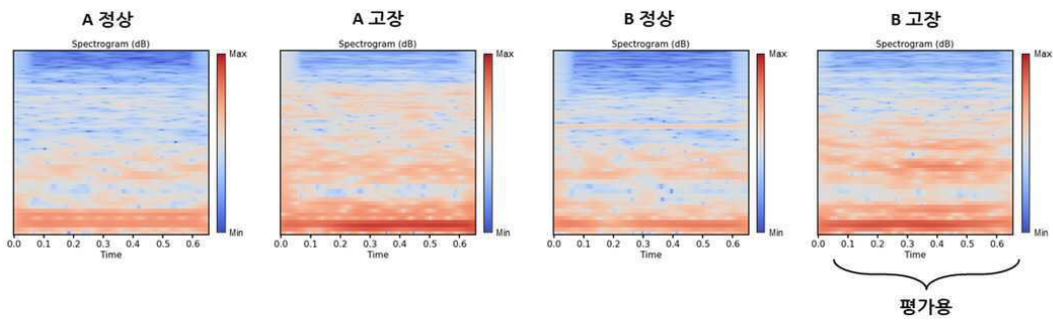
도면2



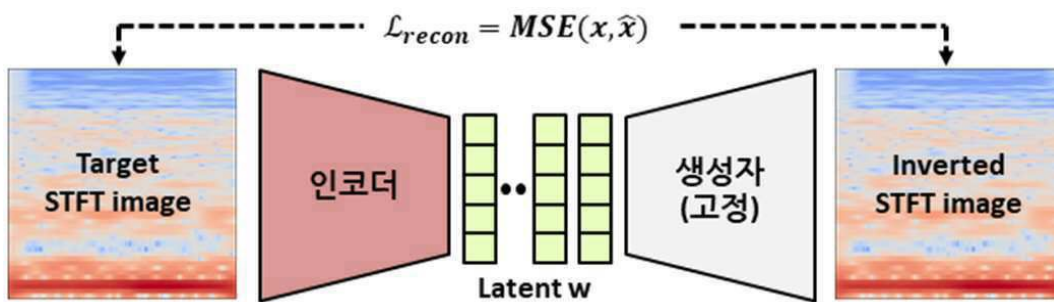
도면3



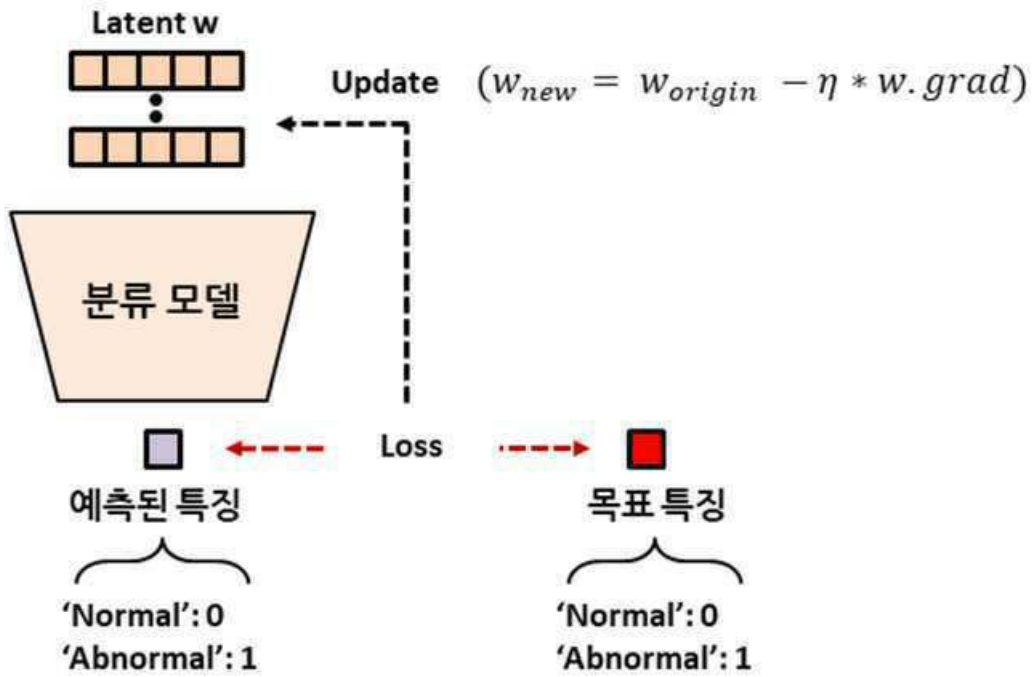
도면4



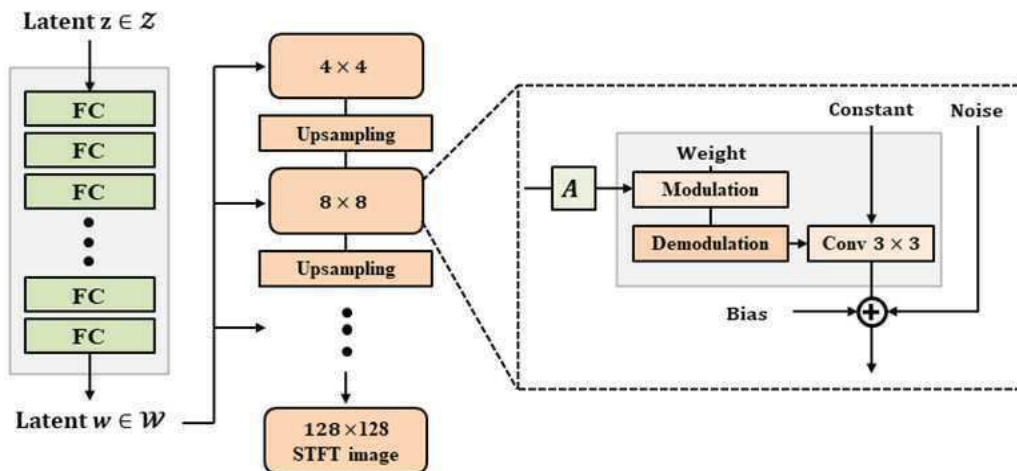
도면5




도면6



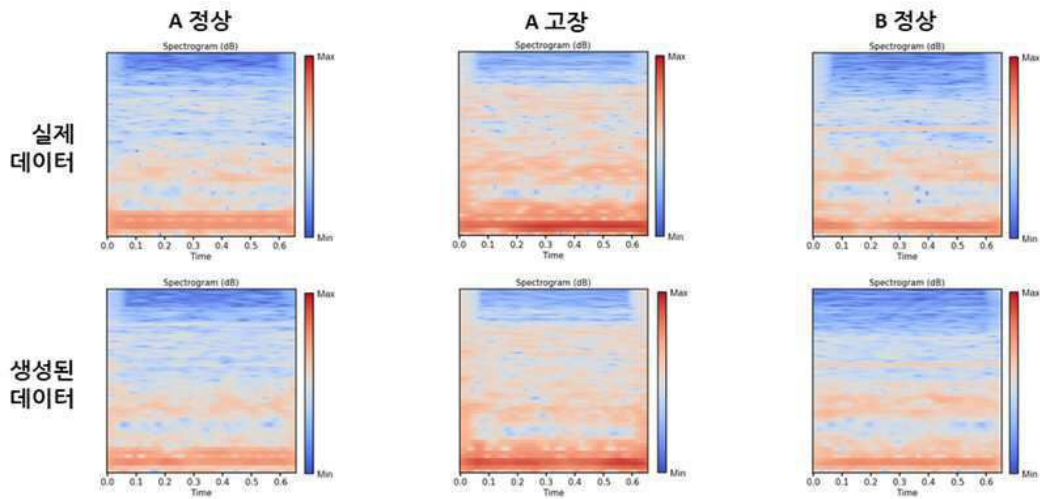
도면7




도면8



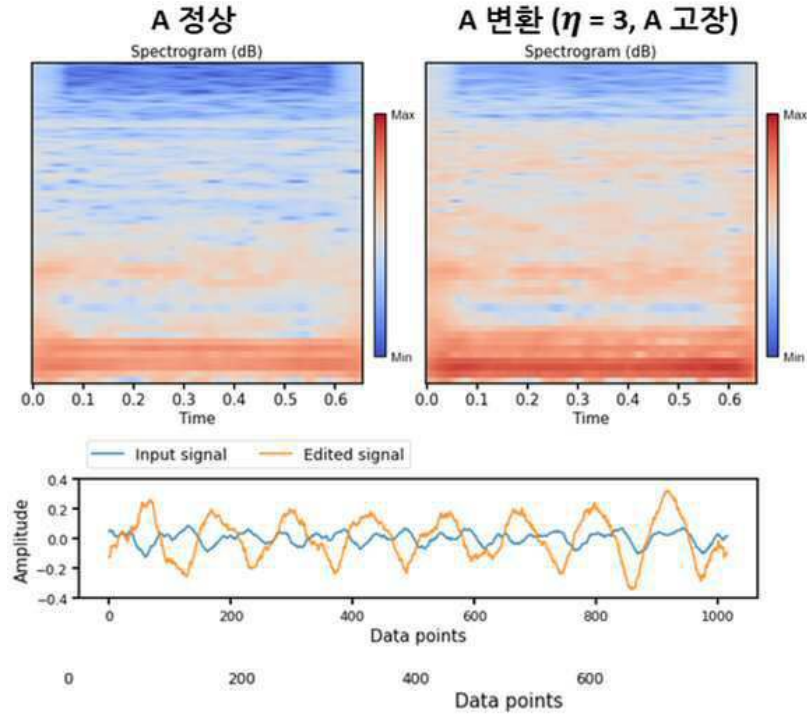
도면9



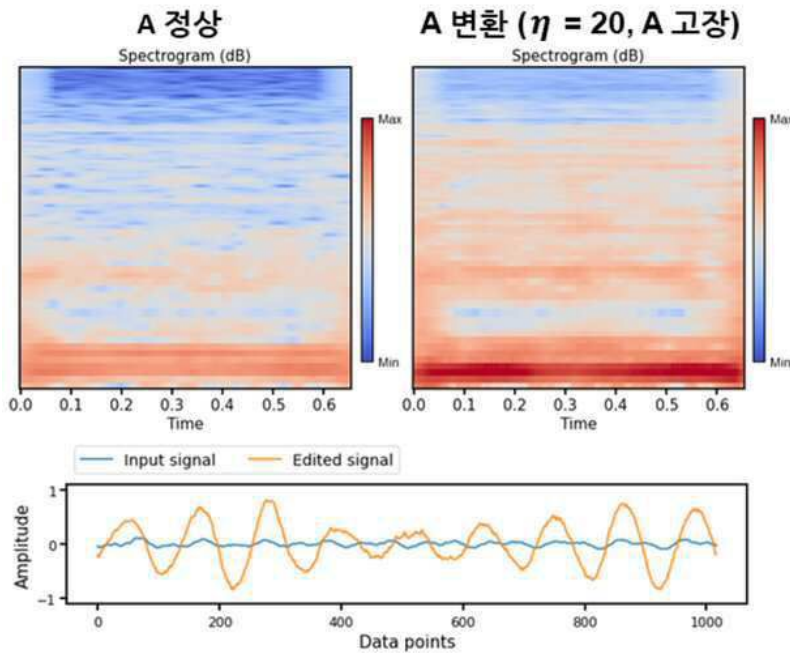
도면10



도면11



도면12



도면13

