



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0078757
(43) 공개일자 2021년06월29일

- | | |
|---|---|
| <p>(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2006.01) G06N 3/04 (2006.01)</p> <p>(52) CPC특허분류
G06N 3/08 (2013.01)
G06N 3/049 (2013.01)</p> <p>(21) 출원번호 10-2019-0170519</p> <p>(22) 출원일자 2019년12월19일
심사청구일자 없음</p> | <p>(71) 출원인
에스케이텔레콤 주식회사
서울특별시 중구 을지로 65 (을지로2가)
포항공과대학교 산학협력단
경상북도 포항시 남구 청암로 77 (지곡동)</p> <p>(72) 발명자
남궁정현
서울특별시 중구 을지로 65 SKT-타워
김태경
서울특별시 중구 을지로 65 SKT-타워
(뒷면에 계속)</p> <p>(74) 대리인
이철희</p> |
|---|---|

전체 청구항 수 : 총 18 항

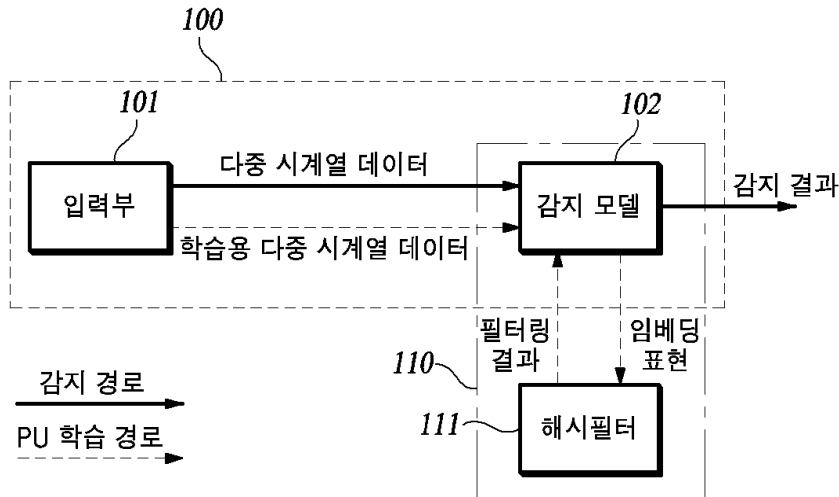
(54) 발명의 명칭 다중 시계열 데이터에 대한 이상 감지방법 및 장치

(57) 요약

다중 시계열 데이터에 대한 이상 감지방법 및 장치를 개시한다.

본 실시예는, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 사전에 트레이닝된 딥러닝(deep learning) 기반 감지 모델(detection model)이 다중 시계열(multiple time series) 데이터로부터 이상을 감지함으로써, 다중 시계열 데이터에 포함된 이상에 대한 감지 성능을 향상시키는 것이 가능한 이상 감지방법 및 장치를 제공한다.

대표도 - 도1



(72) 발명자

주현준

경상북도 포항시 남구 청암로 77 정보통신연구소

유환조

경상북도 포항시 남구 청암로 77 정보통신연구소

명세서

청구범위

청구항 1

PU(Positive and Unlabeled) 학습장치의 PU 학습방법에 있어서,

학습용 다중 시계열(multiple time series) 데이터를 획득하는 과정;

상기 다중 시계열 데이터를 기반으로 딥러닝(deep learning) 기반 감지 모델(detection model)이 임베딩 표현(embedding representations)을 생성하는 과정;

상기 임베딩 표현을 이용하여, 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering)을 실행하여 필터링 결과를 생성하는 과정; 및

상기 필터링 결과 및 상기 다중 시계열 데이터 중 레이블이 있는(labeled) 이상(anomaly) 샘플을 이용하여 상기 감지 모델에 대한 심화 메트릭 학습(DML: Deep Metric Learning)을 실행하는 과정

을 포함하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 2

제1항에 있어서,

상기 다중 시계열 데이터는,

상기 레이블이 있는 이상 샘플 및 레이블이 없는(unlabeled) 샘플을 포함하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 3

제1항에 있어서,

상기 임베딩 표현은,

상기 다중 시계열 데이터의 비정상성(abnormality)에 대한 표현으로서, 상기 다중 시계열 데이터의 시간적 및 공간적 연관성(correlations)을 이용하여 상기 감지 모델이 생성하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 4

제2항에 있어서,

상기 필터링 결과를 생성하는 과정은,

상기 레이블이 없는 샘플로부터 정상 샘플 및 비정상 샘플을 식별(identification)하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 5

제4항에 있어서,

상기 DML을 실행하는 과정은,

상기 필터링 결과 및 상기 레이블이 있는 이상 샘플을 이용하여, 트리플렛 손실(triplet loss)을 최소화하는 방향으로 감지 모델의 파라미터를 업데이트하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 6

제5항에 있어서,

상기 DML을 실행하는 과정은,

상기 트리플렛을 구성하는 앵커(anchor), 긍정(positive) 및 부정(negative)에 대하여, 상기 레이블이 있는 이상 샘플 또는 상기 비정상 샘플의 집합에서 상기 앵커 및 긍정을 선택하고, 상기 정상 샘플의 집합에서 상기 부정을 선택하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 7

제4항에 있어서,

상기 DHF를 실행하는 과정은,

적어도 하나의 k (k 는 자연수) 비트 해시 함수(hash functions)를 생성하는 과정;

상기 레이블이 없는 샘플을 기반으로 상기 k 비트 해시 함수를 이용하여, 상기 k 비트 해시 함수 별로 해시 테이블(hash tables)을 생성하는 과정;

해밍 거리(Hamming distance)를 기반으로 상기 해시 테이블로부터 상기 정상 샘플(normal samples)을 식별하는 과정; 및

상기 해시 테이블로부터 상기 비정상 샘플(abnormal samples)을 식별하는 과정

을 포함하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 8

제7항에 있어서,

상기 k 비트 해시 함수는,

k 개의 1 비트 해시 함수를 포함하되, 상기 1 비트 해시 함수는, 상기 레이블이 없는 샘플과 기 선정된 레이블이 있는 이상 샘플 간의 거리 메트릭(distance metric), 및 상기 레이블이 없는 샘플과 기 선정된 레이블이 없는 샘플 간의 거리 메트릭의 곱합을 이용하여, 상기 레이블이 없는 샘플이 상기 기 선정된 레이블이 있는 이상 샘플과 더 유사하면 1을 생성하고, 상기 레이블이 없는 샘플이 상기 기 선정된 레이블이 없는 샘플과 더 유사하면 0을 생성하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 9

제7항에 있어서,

상기 해시 테이블을 생성하는 과정은,

상기 레이블이 없는 샘플을 상기 k 비트 해시 함수에 적용하여 해시 코드(hash code)를 생성하고, 상기 해시 코드가 인덱싱(indexing)하는 버킷(bucket)에 상기 레이블이 없는 샘플을 포함시키는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 10

제7항에 있어서,

상기 정상 샘플을 식별하는 과정은,

상기 해시 테이블 별로, 0으로만 구성된 해시 코드와 상기 해밍 거리가 가장 짧은 해시 코드를 선택하고, 상기 선택된 해시 코드가 인덱싱하는 버킷에 포함된 샘플을 상기 정상 샘플로 식별하되, 상기 선택된 해시 코드가 복수인 경우, 상기 복수의 해시 코드가 인덱싱하는 버킷 중에서, 가장 많은 샘플을 포함하는 버킷에 포함된 샘플을 상기 정상 샘플로 식별하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 11

제7항에 있어서,

상기 비정상 샘플을 식별하는 과정은,

상기 해시 테이블 전체에 대하여, 1로만 구성된 해시 코드가 인덱싱하는 버킷에 포함된 샘플의 교집합을 구한

후, 상기 교집합에서 상기 식별된 정상 샘플을 제외함으로써 상기 비정상 샘플을 식별하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법.

청구항 12

다중 시계열(multiple time series) 데이터를 획득하는 입력부; 및

상기 다중 시계열 데이터의 시간적, 공간적 연관성(correlations)을 기반으로 상기 다중 시계열 데이터에 대한 임베딩 표현(embedding representations)을 생성하고, 상기 임베딩 표현을 이용하여 상기 다중 시계열 데이터를 이상(anomaly) 데이터 및 정상(normal) 데이터로 분류하는 감지 모델(detection model)

을 포함하는 것을 특징으로 하는 이상 감지장치.

청구항 13

제12항에 있어서,

상기 감지 모델은,

딥러닝 기반으로 구현되며, 학습용 다중 시계열 데이터 중 레이블이 없는(unlabeled) 샘플에 대한 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering) 결과 및 상기 학습용 다중 시계열 데이터 중 레이블이 있는(labeled) 이상 샘플을 이용하여, 트리플렛 손실함수(triplet loss function)를 기반으로 사전에 트레이닝되는 것을 특징으로 하는 이상 감지장치.

청구항 14

이상(anomaly) 감지장치가 이용하는 PU(Positive and Unlabeled) 학습장치에 있어서,

학습용 다중 시계열(multiple time series) 데이터를 획득하는 입력부;

상기 다중 시계열 데이터에 대한 임베딩 표현(embedding representations)을 생성하는 감지 모델(detection model); 및

상기 임베딩 표현을 이용하여 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering)을 실행하여 필터링 결과를 생성하는 해시필터(hash filter)를 포함하되,

트레이닝 과정에서 상기 감지 모델은 상기 필터링 결과 및 상기 다중 시계열 데이터 중 레이블이 있는(labeled) 이상 샘플을 이용하고, 상기 해시필터는 상기 임베딩 표현을 이용하는 것을 특징으로 하는 PU 학습장치.

청구항 15

제14항에 있어서,

상기 다중 시계열 데이터는,

상기 레이블이 있는 이상 샘플 및 레이블이 없는(unlabeled) 샘플을 포함하는 것을 특징으로 하는 PU 학습장치.

청구항 16

제14항에 있어서,

상기 임베딩 표현은,

상기 다중 시계열 데이터의 비정상성(abnormality)에 대한 표현으로서, 상기 다중 시계열 데이터의 시간적 및 공간적 연관성(correlations)을 이용하여 상기 감지 모델이 생성하는 것을 특징으로 하는 PU 학습장치.

청구항 17

제15항에 있어서,

상기 필터링 결과는,

상기 레이블이 없는 샘플로부터 식별된(identified) 정상 샘플 및 비정상 샘플인 것을 특징으로 하는 PU 학습장치.

청구항 18

제1항 내지 제11항 중 어느 한 항에 따른 PU 학습방법이 포함하는 각 단계를 실행시키기 위하여 컴퓨터로 읽을 수 있는 기록매체에 저장된 컴퓨터프로그램.

발명의 설명

기술 분야

[0001] 본 발명은 다중 시계열 데이터에 대한 이상 감지방법 및 장치에 관한 것이다.

배경 기술

[0002] 이하에 기술되는 내용은 단순히 본 발명과 관련되는 배경 정보만을 제공할 뿐 종래기술을 구성하는 것이 아니다.

[0003] 이상 감지(anomaly detection, 또는 outlier detection)는 데이터에 존재하는 비정상 패턴(abnormal patterns)을 식별(identification)하는 것을 목표로 한다. 대다수의 데이터와 확연하게 차이가 있는 특이 패턴이 이상으로 취급되며, 이상은 특정 시스템의 동작에 심각한 영향을 줄 수 있다. 이상 감지가 이용되는 분야는, 이상거래 감지(fraud detection), 제품 생산 시스템에서의 이상 감지(fault detection), 보안 시스템에서의 침입 탐지(intrusion detection), 의료 진단(medical diagnosis) 등 매우 다양하다.

[0004] 이상 감지를 위한 종래의 기술로, 비지도 학습(unsupervised learning)을 이용하여 데이터의 정상성을 모델링(normality modeling)하는 방법이 존재한다. AE(AutoEncoder) 또는 GAN(Generative Adversarial Network) 등과 같은 딥러닝(deep learning) 기반 모델이 정상성 모델링에 이용되었다(비특허문헌 1, 2 참조). 정상성 모델링 방법에서는, 정상 데이터(normal data)만을 이용하여 딥러닝 모델을 트레이닝함으로써, 딥러닝 모델이 정상 데이터를 정확하게 복원(reconstruction)하도록 하되, 복원 오차(reconstruction error)에 기반하여 이상을 감지하였다. 이상이 배제된 순수한(pure) 정상 데이터가 트레이닝에 사용되어야 하므로, 정상성 모델링은 점차적으로 사람에 의한 조정(intervention)을 필요로 한다. 또한 이상 및 정상 데이터가 혼합된 트레이닝 데이터를 이용하는 경우, 딥러닝 모델의 감지 성능이 심하게 저하될 수 있다는 단점이 존재한다.

[0005] 한편, 제품 생산 시스템에서는 생산 과정의 모니터링을 위해 다중 센서(multiple sensors)를 이용하여, 전압, 온도, 압력 등과 같은 각종 정보를 수집한다. 제품 생산 시스템을 안정적으로 유지하고, 생산된 제품에 대한 불량 발생을 예방하기 위하여, 다중 시계열(multiple time-series) 데이터로부터 생산 과정 또는 제품에 대한 이상을 자동으로 감지하는 방법에 대한 요구가 많이 있다.

[0006] 실제 상황에서 수집된 데이터는, 소수의 제한적인 이상 샘플과 대다수의 레이블이 없는(unlabeled) 샘플을 포함하는 경우가 대부분이다. 예컨대, 제품 생산 과정에서, 비정상 제품은 비정상이라는 레이블이 기록되나, 나머지 제품에는 레이블이 부착되지 않는 것이 보편적이다.

[0007] 제한적인 이상 이벤트에 대한 정보가 존재하는 경우에 대하여, 전술한 바와 같은 비지도 학습 기반의 정상성 모델링 방법을 적용하는 것은 어렵다. 대안으로 PU(Positive and Unlabeled) 학습이 고려될 수 있다. PU 학습에서는 레이블이 없는 데이터뿐만 아니라 레이블이 있는 긍정 데이터(이하 이상을 긍정으로 가정함)를 이용하여 딥러닝 모델이 트레이닝된다. 초기의 PU 학습은, 이상 클래스는 균질(homogeneous)하나 대다수의 데이터는 이질적(heterogeneous)인 경우에 주로 적용되었다. 그러나, 대다수의 이상 감지 시나리오에서 이상 클래스는 다양한 반면, 레이블이 없는 데이터는 상대적으로 균질할 수 있다.

[0008] 클래스는 다양하나 개수가 제한적인 이상 이벤트에 대한 정보를 이용하는 PU 학습 기반 이상 감지방법이 존재한다(비특허문헌 3 참조). 이 방법에서는, 이상 점수(anomaly score)를 이용하여 레이블이 없는 샘플에 대한 의사 라벨(pseudo label)을 생성한 후, 의사 라벨을 기반으로 딥러닝 모델을 트레이닝시킨다. 그러나, 이상 점수를 이용하여 의사 라벨을 만드는 과정이 매우 불안정하고, 이상 클래스의 다양성에 맞는 의사 라벨이 생성되지 못한다는 단점이 있다.

[0009] 따라서, 클래스는 다양하나 개수가 제한적인 이상 이벤트에 대한 정보를 포함하는 다중 시계열 데이터에 대하여, 이상 감지를 효율적으로 수행할 수 있는 딥러닝 기반 이상 감지방법이 요구된다.

선행기술문헌

비특허문헌

- [0010] (비특허문헌 0001) 비특허문헌 1: An, J., & Cho, S. (2015). Variational autoencoder based anomaly detection using reconstruction probability. Special Lecture on IE, 2, 1-18.
- (비특허문헌 0002) 비특허문헌 2: Zenati, H., Romain, M., Foo, C. S., Lecouat, B., & Chandrasekhar, V. R. (2018). Adversarially learned anomaly detection. 2018 IEEE International Conference on Data Mining (ICDM), (pp. 727-736).
- (비특허문헌 0003) 비특허문헌 3: Zhang, Y.-L., Li, L., Zhou, J., Li, X., & Zhou, Z.-H. (2018). Anomaly detection with partially observed anomalies. In Companion of the The Web Conference 2018 on The Web Conference 2018 (pp. 639-646). International World Wide Web Conferences Steering Committee.
- (비특허문헌 0004) 비특허문헌 4: Schroff, F., Kalenichenko, D., & Philbin, J. (2015). Facenet: A unified embedding for face recognition and clustering. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 815-823).
- (비특허문헌 0005) 비특허문헌 5: N Kalchbrenner, L Espeholt, K Simonyan, A Oord, and A Graves, Neural machine translation in linear time. arXiv preprint arXiv:1610.10099.

발명의 내용

해결하려는 과제

- [0011] 본 개시는, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 사전에 트레이닝된 딥러닝(deep learning) 기반 감지 모델(detection model)이 다중 시계열(multiple time series) 데이터로부터 이상을 감지함으로써, 다중 시계열 데이터에 포함된 이상에 대한 감지 성능을 향상시키는 것이 가능한 이상 감지방법 및 장치를 제공하는 데 주된 목적이 있다.

과제의 해결 수단

- [0012] 본 발명의 실시예에 따르면, PU(Positive and Unlabeled) 학습장치의 PU 학습방법에 있어서, 학습용 다중 시계열(multiple time series) 데이터를 획득하는 과정; 상기 다중 시계열 데이터를 기반으로 딥러닝(deep learning) 기반 감지 모델(detection model)이 임베딩 표현(embedding representations)을 생성하는 과정; 상기 임베딩 표현을 이용하여, 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering)을 실행하여 필터링 결과를 생성하는 과정; 및 상기 필터링 결과 및 상기 다중 시계열 데이터 중 레이블이 있는(labeled) 이상(anomaly) 샘플을 이용하여 상기 감지 모델에 대한 심화 메트릭 학습(DML: Deep Metric Learning)을 실행하는 과정을 포함하는 것을 특징으로 하는, 컴퓨터 상에 구현되는 PU 학습방법을 제공한다.
- [0013] 본 발명의 다른 실시예에 따르면, 다중 시계열(multiple time series) 데이터를 획득하는 입력부; 및 상기 다중 시계열 데이터의 시간적, 공간적 연관성(correlations)을 기반으로 상기 다중 시계열 데이터에 대한 임베딩 표현(embedding representations)을 생성하고, 상기 임베딩 표현을 이용하여 상기 다중 시계열 데이터를 이상(anomaly) 데이터 및 정상(normal) 데이터로 분류하는 감지 모델(detection model)을 포함하는 것을 특징으로 하는 이상 감지장치를 제공한다.
- [0014] 본 발명의 다른 실시예에 따르면, 이상(anomaly) 감지장치가 이용하는 PU(Positive and Unlabeled) 학습장치에 있어서, 학습용 다중 시계열(multiple time series) 데이터를 획득하는 입력부; 상기 다중 시계열 데이터에 대한 임베딩 표현(embedding representations)을 생성하는 감지 모델(detection model); 및 상기 임베딩 표현을 이용하여 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering)을 실행하여 필터링 결과를 생성하는 해시필터(hash filter)를 포함하되, 트레이닝 과정에서 상기 감지 모델은 상기 필터링 결과 및 상기 다중 시계열 데이터 중 레이블이 있는(labeled) 이상 샘플을 이용하고, 상기 해시필터는 상기 임베딩 표현을 이용하는 것을 특징으로 하는 PU 학습장치를 제공한다.
- [0015] 본 발명의 다른 실시예에 따르면, PU 학습방법이 포함하는 각 단계를 실행시키기 위하여 컴퓨터로 읽을 수 있는

기록매체에 저장된 컴퓨터프로그램을 제공한다.

발명의 효과

- [0016] 이상에서 설명한 바와 같이 본 실시예에 따르면, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 사전에 트레이닝된 감지 모델(detection model)이 다중 시계열(multiple time series) 데이터로부터 이상을 감지하는 이상 감지방법 및 장치를 제공함으로써, 다중 시계열 데이터에 포함된 이상에 대한 감지 성능을 향상시키는 것이 가능해지는 효과가 있다.
- [0017] 또한 본 실시예에 따르면, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 딥러닝(deep learning) 기반 감지 모델(detection model)을 사전에 트레이닝하는 이상 감지방법 및 장치를 제공함으로써, 다중 시계열(multiple time series) 데이터에 포함된 레이블이 없는(unlabeled) 샘플에 대하여 높은 정확도의 레이블을 생성하는 것이 가능해지는 효과가 있다.
- [0018] 또한 본 실시예에 따르면, 다중 데이터의 시간적, 공간적 특징을 기반으로 딥러닝 기반 감지 모델을 이용하여 임베딩 표현을 생성하는 이상 감지방법 및 장치를 제공함으로써, 이상 감지 성능을 향상시키는 것이 가능해지는 효과가 있다.

도면의 간단한 설명

- [0019] 도 1은 본 발명의 일 실시예에 따른 이상 감지장치 및 PU 모델에 대한 구성도이다.
- 도 2는 본 발명의 일 실시예에 따른 다중 시계열 데이터에 대한 예시도이다.
- 도 3은 본 발명의 일 실시예에 따른 감지 모델에 이용되는 DCNN의 인코더에 대한 개념도이다.
- 도 4는 본 발명의 일 실시예에 따른 DHF 및 DML의 동작을 설명하기 위한 개념도이다.
- 도 5는 본 발명의 일 실시예에 따른 감지 모델의 트레이닝 과정에 대한 순서도이다.
- 도 6은 본 발명의 일 실시예에 따른 해시 테이블에 포함된 해시 코드와 버킷 간의 인덱싱에 대한 개념도이다.

발명을 실시하기 위한 구체적인 내용

- [0020] 이하, 본 발명의 실시예들을 예시적인 도면을 참조하여 상세하게 설명한다. 각 도면의 구성요소들에 참조부호를 부가함에 있어서, 동일한 구성요소들에 대해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 부호를 가지도록 하고 있음에 유의해야 한다. 또한, 본 실시예들을 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 실시예들의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다.
- [0021] 또한, 본 실시예들의 구성요소를 설명하는 데 있어서, 제 1, 제 2, A, B, (a), (b) 등의 용어를 사용할 수 있다. 이러한 용어는 그 구성요소를 다른 구성요소와 구별하기 위한 것일 뿐, 그 용어에 의해 해당 구성요소의 본질이나 차례 또는 순서 등이 한정되지 않는다. 명세서 전체에서, 어떤 부분이 어떤 구성요소를 '포함', '구비'한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다. 또한, 명세서에 기재된 '...부', '모듈' 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다.
- [0022] 첨부된 도면과 함께 이하에 개시될 상세한 설명은 본 발명의 예시적인 실시형태를 설명하고자 하는 것이며, 본 발명이 실시될 수 있는 유일한 실시형태를 나타내고자 하는 것이 아니다.
- [0023] 본 실시예는 다중 시계열 데이터에 대한 이상 감지방법 및 장치에 대한 내용을 개시한다. 보다 자세하게는, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 사전에 트레이닝된 딥러닝(deep learning) 기반 감지 모델(detection model)이 다중 시계열(multiple time series) 데이터로부터 이상을 감지함으로써, 다중 시계열 데이터에 포함된 이상에 대한 감지 성능을 향상시키는 것이 가능한 이상 감지방법 및 장치를 제공한다.
- [0024] 이하, 다중 시계열 데이터는 제품 생산 현장에서 다중 센서(multiple sensors)로부터 동시에 수집되는 온도, 진압, 압력 등과 같은 다양한 정보를 포함하는 것으로 가정한다.
- [0025] 이하 다중 시계열 데이터는 수집된 정보에 대한 일반적인 표현이고, 감지 모델이 처리하기 적당하도록 데이터를

시간축 상에서 분할한 것을 샘플(samples)로 표현한다. 따라서, 데이터는 샘플의 집합(set)을 의미할 수 있다. 시계열 데이터를 표현하기 위한 샘플은 벡터 또는 행렬일 수 있다.

- [0026] 도 1은 본 발명의 일 실시예에 따른 이상 감지장치 및 PU 모델에 대한 구성도이다.
- [0027] 본 발명에 따른 실시예에 있어서, 이상 감지장치(100)는 다중 시계열 데이터를 감지 모델(detection model)에 적용하여 이상을 감지한다. 이상 감지장치(100)는 입력부(101) 및 감지 모델(102)의 전부 또는 일부를 포함한다.
- [0028] 본 실시예에 따른 이상 감지장치(100)에 포함되는 구성요소가 반드시 이에 한정되는 것은 아니다. 예컨대, 이상 감지장치(100) 상에 감지 모델의 트레이닝을 위한 트레이닝부(미도시)를 추가로 구비하거나, 외부의 트레이닝부와 연동되는 형태로 구현될 수 있다. 도 1에 도시된 PU(Positive and Unlabeled) 모델(110)은 트레이닝부에 의하여 PU 학습된다. PU 모델(120)은 감지 모델(102) 및 해시필터(111, hash filter)를 포함한다. 감지 모델(102)은 이상 감지장치(100) 상에 구비되나, 해시필터(111)는 이상 감지장치(100)의 외부에 존재한다. 따라서, 해시필터(111)는 학습 시에만 이용되고, 이상 감지장치(100)의 동작 중에는 이용되지 않는다.
- [0029] 입력부(101)는 다중 시계열 데이터를 획득한다.
- [0030] 도 2는 본 발명의 일 실시예에 따른 다중 시계열 데이터에 대한 예시도이다.
- [0031] 다중 시계열 데이터는 다중 센서(multiple sensors)로부터 실시간으로 획득된 데이터이거나, 다중 센서(multiple sensors)로부터 수집되어 사전에 저장장치(미도시)에 저장된 데이터일 수 있다.
- [0032] 다중 센서로부터 획득된 시계열 데이터를 사용하는 경우, 데이터 간의 시간적 연관성(temporal correlation) 외에 공간적 연관성(spatial correlation)을 이용하는 것이 가능하다.
- [0033] 도 2에 도시된 바와 같이, N (N 은 자연수) 개의 센서로부터 수집된 다중 시계열 데이터가 표현될 수 있다. 시간 t 근처에서 이상이 발생했다고 가정하는 경우, 센서 별로 이상이 관찰되는 시계열 구간이 다르거나, 제3 센서에 서와 같이 이상이 관찰되지 않을 수도 있다. 하나의 센서를 사용했을 때보다, 다중 센서를 사용하는 경우 시간적, 공간적으로 더 풍부한 데이터를 획득함으로써, 개별 센서의 데이터 간 상호 보완이 가능하다. 따라서, 각 센서로부터 감지된 개별 데이터 간의 시간적, 공간적 연관성을 이용함으로써, 이상 감지 성능을 향상시키는 것이 가능해지는 효과가 있다.
- [0034] 본 실시예에 따른 감지 모델(102)은 다중 시계열 데이터를 기반으로 이상을 감지한다. 감지 모델(102)은 임베딩 표현(embedding representations)을 생성하여 입력부(101)에서 획득된 다중 시계열 데이터를 이상 및 정상 데이터로 분류한다.
- [0035] 분류 기능을 수행하고, 시계열 데이터를 처리할 수 있는 어느 딥러닝 모델이든 감지 모델로서 이용이 가능하다. 이용 가능한 딥러닝 모델로는 LSTM(Long Short-Term Memory), C-RNN(Convolutional Recurrent Neural Network) 또는 DCNN(Dilated Convolutional Neural Network) 등이 있다. 본 실시예에서는, 다중 시계열 데이터를 시간적, 공간적으로 이용하는 데 있어서 장점을 보이는 DCNN을 이용한다.
- [0036] 본 실시예에 따른 감지 모델(102)은, 개별 시계열 데이터에 오버랩이 없이(without overlapping) 고정 크기의 슬라이딩 윈도우(fixed-size sliding window)를 적용하여 벡터를 생성한 후, 생성된 벡터를 벡터 처리가 가능한 감지 모델(102)의 인코더에 입력한다. 도 3의 (a)는 벡터 처리가 가능한 DCNN의 인코더에 대한 예시이며, 2×1 컨볼루션 커널(convolution kernel)을 이용하는 모델을 나타낸다. 따라서 N (N 은 자연수) 개의 시계열 데이터에 대하여 동수의 인코더가 임베딩 특징 벡터를 생성한 후, 결합 레이어(association layer)에서 공간적으로 결합됨으로써, 최종적인 인코더 출력이 생성될 수 있다.
- [0037] 본 발명의 다른 실시예에 있어서, 감지 모델(102)은 N 개의 시계열 데이터 전체에 오버랩이 없이 고정 크기의 슬라이딩 윈도우를 적용하여 행렬을 생성한 후, 생성된 행렬을 행렬 처리가 가능한 인코더에 입력할 수 있다. 도 3의 (b)는 행렬 처리가 가능한 DCNN의 인코더에 대한 예시를 나타내며, 3×3 컨볼루션 커널을 이용하되, 좌측에서 우측으로 갈수록 희석(dilation)의 간격이 증대되는 것을 나타낸다. 행렬을 이용하는 경우, 결합 레이어가 추가로 필요하지는 않으나, 인코더의 복잡도가 증대될 수 있다.
- [0038] 다중 시계열 데이터에 존재하는 이상 구간의 길이가 슬라이딩 윈도우보다 길어서 두 개의 이상의 샘플에 걸치는 경우, 해당되는 샘플은 모두 이상 샘플인 것으로 가정한다.
- [0039] PU 모델(110)을 기반으로 트레이닝부에 의하여 감지 모델(102)은 사전에 트이닝될 수 있다. 감지 모델(102)에

대한 트레이닝 과정은 추후에 설명하기로 한다.

- [0040] 도 1의 도식에서 이상 감지장치(100) 내부의 데이터 흐름은 실선 화살표로 표시된 감지 경로를 따른다.
- [0041] 이하, 도 1을 참조하여, 감지 모델(102)의 트레이닝에 이용되는 PU 모델(110) 및 PU 학습에 대하여 설명한다. 도 1의 도식에서 PU 모델(110)에 기반하는 PU 학습을 위한 데이터 흐름은 점선 화살표로 표시된 PU 학습 경로를 따른다. PU 학습에 있어서, 입력부(101)의 기능은 동일하다.
- [0042] 입력부(101)로부터 획득되는 학습용 다중 시계열 데이터는 레이블이 있는(labeled) 긍정 데이터(positive data), 즉 이상 데이터 및 레이블이 없는(unlabeled) 데이터를 포함하는 것으로 가정한다. 레이블이 없는 데이터는 비정상 데이터(abnormal data) 및 정상 데이터(normal data)를 포함한다. 또한 이상 데이터 및 비정상 데이터는 다양한 상황의 이상을 포함하여 이질적(heterogeneous)인 반면, 정상 데이터는 균질(homogeneous)한 것으로 가정한다.
- [0043] 본 실시예에 따른 PU 모델(110)에 대한 PU 학습은, 레이블이 있는 이상 데이터 및 레이블이 없는 데이터를 이용하여 감지 모델(102)을 트레이닝시키는 과정이다. PU 모델(110)은 감지 모델(102) 및 해시필터(111)를 포함한다.
- [0044] 감지 모델(102)은 다중 시계열 데이터에 대한 임베딩 표현을 생성한다.
- [0045] 다중 시계열 데이터에 대한 임베딩 표현을 이용하여, 해시필터(111)는 레이블이 없는 데이터에 대한 거리 해싱 기반 필터링(DHF: Distance Hashing-based Filtering)을 수행한다. 여기서, 거리를 표현할 수 있는 어느 메트릭(metric)이든 거리로서 사용될 수 있으며, 본 실시예에서는 거리에 대한 간단한 표현 방식 중의 하나인 해밍 거리(Hamming distance)를 이용하는 것으로 가정한다.
- [0046] 도 4에 도시된 바와 같이 해시필터(111)는 DHF를 수행하여, 레이블이 없는 데이터로부터 잠재적인(potential) 비정상 데이터 및 신뢰가능한(reliable) 정상 데이터를 식별(identification)하여 감지 모델(102)에게 제공한다.
- [0047] 레이블이 있는 이상 데이터와 해시필터(111)가 제공한 비정상 및 정상 데이터를 기반으로 감지 모델(102)에 대한 심화 메트릭 학습(DML: Deep Metric Learning)이 실행된다. 트레이닝부는 트리플렛(triplet, 비특허문헌 4 참조) 기반 메트릭(metric)을 이용하는 DML을 실행하여, 이상 및 정상 데이터에 대한 분류가 용이한 임베딩 표현을 생성하도록 감지 모델(102)을 트레이닝시킨다. 도 1 및 도 4에 도시된 바와 같이, 해시필터(111)가 실행하는 DHF 및 감지 모델(102)에 대한 DML의 실행은 필터링 결과 및 임베딩 표현을 상호 교환하면서, 기 설정된 에폭(epoch) 이내에서 교차적으로 반복 실행될 수 있다.
- [0048] PU 학습의 주요 과정인 해시필터(111)의 DHF 및 감지 모델(102)에 대한 DML에 대한 자세한 사항은 추후에 설명하기로 한다.
- [0049] 도 1의 도식은 본 실시예에 따른 예시적인 구성이며, 다중 시계열 데이터의 형태, 감지 모델 및/또는 PU 모델의 구조에 따라 다른 구성요소 또는 구성요소 간의 다른 연결을 포함하는 구현이 가능하다.
- [0050] 본 실시예에 따른 이상 감지장치(100)가 탑재되는 디바이스(미도시)는 프로그램가능 컴퓨터일 수 있으며, 서버(미도시)와 연결이 가능한 적어도 한 개의 통신 인터페이스를 포함한다.
- [0051] 전술한 바와 같은 감지 모델(102)에 대한 트레이닝은, 이상 감지장치(100)가 탑재되는 디바이스의 컴퓨팅 파워를 이용하여, 이상 감지장치(100)가 탑재되는 디바이스에서 진행될 수 있다.
- [0052] 전술한 바와 같은 감지 모델(102)에 대한 트레이닝은 서버에서 진행될 수 있다. 디바이스 상에 탑재된 이상 감지장치(100)의 구성요소인 감지 모델(102)과 동일한 구조의 딥러닝 모델에 대하여 서버의 트레이닝부는 트레이닝을 수행할 수 있다. 디바이스와 연결되는 통신 인터페이스를 이용하여 서버는 트레이닝된 딥러닝 모델의 파라미터를 디바이스로 전달하고, 전달받은 파라미터를 이용하여 이상 감지장치(100)는 감지 모델(102)의 파라미터를 업데이트할 수 있다. 또한 디바이스 출하 시점 또는 이상 감지장치(100)가 디바이스에 탑재되는 시점에, 감지 모델(102)의 파라미터가 설정될 수 있다.
- [0053] 이하, 도 5 및 도 6을 참조하여, PU 학습에 따른 감지 모델에 대한 트레이닝 과정을 자세히 설명한다.
- [0054] 도 5는 본 발명의 일 실시예에 따른 감지 모델의 트레이닝 과정에 대한 순서도이다. 여기서, 도 5의 (a)는 PU 학습에 따른 감지 모델(102)의 트레이닝 과정에 대한 순서도이고, 도 5의 (b)는 해시필터(111)의 DHF(S502

단계)에 대한 상세한 순서도이다.

[0055] 본 실시예에 따른 이상 감지장치(100)의 트레이닝부는 학습용 다중 시계열 데이터를 획득한다(S501). 표 1에 나타난 바와 같이, 다중 시계열 데이터의 집합(set) X는 레이블이 있는 소수의 이상 샘플의 집합 A 및 레이블이 없는 샘플의 집합 U를 포함한다.

표 1

		집합	
X	A	레이블이 있는 어노말리 샘플의 집합	
	U	U _a	레이블이 없는 비정상 샘플의 집합
		U _n	레이블이 없는 정상 샘플의 집합

[0056]

[0057] 또한 레이블이 없는 샘플의 집합 U는 비정상 샘플의 집합 U_a 및 정상 샘플 집합 U_n 을 포함한다. 집합 A 와 U는 서로 배타적(mutually exclusive)이고, U_a 및 U_n 도 서로 배타적이다. 집합 A에 속한 샘플의 개수는 U에 속한 샘플의 개수보다 매우 작고, U_a 에 속한 샘플의 개수는 U_n 에 속한 샘플의 개수보다 매우 작은 것으로 가정한다.

[0058] 다중 시계열 데이터를 기반으로 감지 모델이 생성하는 임베딩 표현을 이용하여, 해시필터는 DHF를 실행하여 필터링 결과를 생성한다(S502).

[0059] 유사한 임베딩 표현을 생성하는 레이블이 없는 샘플이 동일한 버킷(bucket)에 포함될 수 있도록, 해시필터(111)는 DHF를 실행하여 레이블이 없는 샘플의 집합 U를 복수의 버킷으로 분할한다. 또한 버킷에 대한 인덱스, 즉 해시 코드(hash codes)를 생성하고, 인덱스를 이용하여 버킷으로부터 필터링 결과를 생성한다. 해시필터(111)는 해시 코드 및 버킷을 포함하는 해시 테이블을 생성한 후, 생성된 해시 테이블을 이용하여 필터링 결과를 생성한다. 여기서, 도 4에 도시된 바와 같이, 필터링 결과는 레이블이 없는 데이터로부터 식별된(identified), 잠재적인 비정상 데이터에 대한 집합 U_a 및 신뢰가능한 정상 데이터에 대한 집합 U_n 이다.

[0060] 이하, DHF를 설명하기 위해 다음을 가정한다.

[0061] 감지 모델(102)을 Φ(·) 로 표현한다. Φ(·) 는 임베딩 함수(embedding function)이며, 입력을 임베딩 공간(embedding space) 측으로 임베딩시킨다. 즉, 학습용 다중 시계열 데이터에 대하여 Φ(·) 는 임베딩 공간 상에 생성된 임베딩 표현을 의미한다.

[0062] 1 비트 해시 함수(hash function) h(·) 의 집합을 H로 표현한다. k(k는 자연수) 비트 해시 함수 g(·) 는 k개의 1 비트 해시 함수를 구비하여 해시 테이블(hash table)을 생성한다. 해시 테이블의 개수는 J(J는 자연수)개로 가정하고, 전체 J 개의 해시 테이블 중 i번째 해시 테이블은 T_i 로 표기한다.

[0063] 해시 테이블을 생성하는 과정은 다음과 같은데, 하나의 해시 테이블 T_i (i는 J 이내의 자연수)를 생성하는 과정을 예로 들어 설명한다.

[0064] 먼저, 1 비트 해시 함수를 이용하여 k 비트 해시 함수를 생성한다(S511). 트레이닝부는 식별될 대상 샘플(target sample to be identified) u(u ∈ U)에 대하여, 수학적 1에 표현된 바와 같이 k 비트 해시 함수

$g_i(u)$ 를 구성한다.

수학식 1

$$g_i(u) = (h_1(u), h_1(u), \dots, h_k(u))$$

여기서, 1 비트 해시 함수 $h(u)$ 는 1 비트 해시 함수의 집합 H로부터 임의로 선택될 수 있다. 대상 샘플 u 에 대하여 1 비트 해시 함수는 수학식 2로 표현된다.

수학식 2

$$h(u; a_*, u_*) = \begin{cases} 1 & \text{if } d(u; a_*, u_*) \geq 0 \\ 0 & \text{otherwise} \end{cases}$$

여기서, 거리 함수 $d(u)$ 는 대상 샘플 u에 대하여 수학식 3으로 표현된다.

수학식 3

$$d(u; a_*, u_*) = \|\Phi(u) - \Phi(u_*)\|^2 - \|\Phi(u) - \Phi(a_*)\|^2$$

여기서 a_* 는 레이블이 있는 이상 샘플이고, u_* 는 레이블이 없는 샘플이다. 전술한 바와 같이 $\Phi(\cdot)$ 는

학습용 다중 시계열 데이터에 대한 임베딩 표현을 의미하고, 메트릭 $\|\Phi(\cdot)\|^2$ 은 L2 메트릭을 의미한다. 따라서, 대상 샘플이 이상 샘플에 가까우면, 거리 함수는 큰 값을 생성한다. 반면 대상 샘플이 레이블이 없는 샘플에 가까우면, 거리 함수는 작은 값을 생성할 수 있다. 결론적으로, 1 비트 해시 함수는 대상 샘플이 이상 샘플에 가까우면, 1을 생성하고, 반면 대상 샘플이 레이블이 없는 샘플에 가까우면, 0을 생성한다.

트레이닝부는 k 비트 해시 함수를 이용하여 해시 테이블을 생성한다(S512).

도 6은 본 발명의 일 실시예에 따른 해시 테이블에 포함된 해시 코드와 버킷 간의 인덱싱에 대한 개념도이다. 도 6의 도시는 k가 5인 해시 코드를 포함하는 해시 테이블을 나타낸 것이다.

레이블이 없는 대상 샘플에 대하여, 해시필터(111)는 k 비트 해시 함수 $g_i(u)$ 를 이용하여 k 비트 해시 코드를 생성하고, 생성된 해시 코드가 인덱싱(indexing)하는 버킷에 대상 샘플을 포함시킨다. 도 6에 도시된 바와

같이 해시 테이블 T_i 는 해시 함수 $g_i(u)$ 가 생성할 수 있는 해시 코드를 포함하고, 각 해시 코드는 하나의 버킷을 인덱싱한다. 각 버킷은 동일한 해시 코드를 생성하는 레이블이 없는 대상 샘플의 집합이다. 해시 테이블이 생성되었다는 것은, 임의의 레이블이 없는 샘플에 대하여 해시 코드가 생성되고, 해시 코드가 인덱싱하는 버킷에 임의의 레이블이 없는 샘플이 포함됨으로써, 레이블이 없는 샘플의 집합 U가 복수의 버킷으로 분할되었다라는 의미이다.

k 비트 해시 함수가 이용되므로, 해시 테이블이 포함할 수 있는 해시 코드의 최대 개수는 2^k 이다. 따라서

해시 코드가 인덱싱할 수 있는 버킷의 최대 개수도 2^k 가 된다.

[0075] 트레이닝부는 J 개의 해시 테이블의 생성 여부를 확인한다(S513). 아직 생성해야 할 해시 테이블이 존재하는 경우, 해시 테이블에 대한 생성 과정(S511 및 S512 단계)을 반복한다.

[0076] J 개의 해시 테이블이 존재하므로, 레이블이 없는 샘플은 각 테이블 별로 하나의 버킷에 속할 수 있다.

[0077] J 개의 해시 테이블이 모두 생성되면, 트레이닝부는 해밍 거리를 기반으로 해시 테이블로부터 정상 샘플을 식별한다(S514). 신뢰가능한 정상 샘플에 대한 식별은 각 해시 테이블 별로 수행되며, 수학적 4를 이용한다.

수학적 4

[0078]
$$\arg \min_{c \in C(T_i)} d_H(0 \dots 0, c)$$

[0079] 수학적 4에서, $0 \dots 0$ 은 0만으로 구성된 k 비트 해시 코드이고, $d_H(a, b)$ 는 두 해시 코드 a와 b 간의 해밍

거리(Hamming distance)이다. $C(T_i)$ 는 해시 테이블 T_i 에 포함된 해시 코드의 집합이다. 해시 코드 $0 \dots 0$ 에 가까운 해시 코드에 해당하는 버킷에 포함된 샘플일수록 이상 샘플과 유사하지 않을 가능성이 높다고 가정한다. 따라서 수학적 4에 근거하여, 0만으로 구성된 해시 코드와 해밍 거리가 가장 짧은 해시 코드가 선택된다.

[0080] 수학적 4에 따라 선택된 해시 코드가 1 개이면, 해당되는 해시 코드가 인덱싱하는 버킷에 속한 모든 샘플을 신

뢰가능한 정상 샘플의 집합 \hat{U}_n 에 포함시킨다. 선택된 해시 코드가 1 개 이상이면, 선택된 해시 코드가 인덱싱하는 버킷 중, 포함된 샘플의 수가 가장 많은 버킷을 선택하고, 선택된 버킷에 포함된 샘플을 \hat{U}_n 에 포함시킨다. 정상 샘플은 균질하다고 가정하였으므로, 가장 많은 샘플을 포함한 버킷을 정상으로 식별하는 것은 합리적이다.

[0081] 트레이닝부는 J 개의 해시 테이블로부터 정상 샘플을 식별했는지를 확인한다(S513). 아직 정상 샘플을 식별하는 과정이 수행되지 않은 해시 테이블이 존재하면, 정상 샘플을 식별하는 과정(단계 S514)을 반복한다.

[0082] J 개의 해시 테이블로부터 정상 샘플 식별하는 과정이 종료되면, 트레이닝부는 해시 테이블로부터 비정상 샘플을 식별하되(S516), 식별은 수학적 5를 이용한다.

수학적 5

[0083]
$$\hat{U}_a = \cap_{i=1}^J T_i(1, \dots, 1) - \hat{U}_n$$

[0084] 해시 코드 $1 \dots 1$ 에 가까운 해시 코드에 해당하는 버킷에 포함된 샘플일수록 이상 샘플과 유사할 가능성이 높다고 가정한다. 수학적 5에 따르면, 각 해시 테이블 별로 해시 코드 $1 \dots 1$ 이 인덱싱하는 버킷에 속한 샘플의 교집합을 구한 후, 앞 단계(S514)에서 식별된 정상 샘플을 제외함으로써, 비정상 샘플을 식별하여 잠재적인 비정상

샘플의 집합 \hat{U}_a 를 생성한다.

[0085] 트레이닝이 정상적으로 진행되어, 레이블이 없는 샘플이 비정상 및 정상 샘플로 정확히 구분될수록, 각 해시 테이블에 포함된 해시 코드의 수, 즉 버킷의 수는 감소할 수 있다. 또한, 트레이닝이 정상적으로 진행될수록, 각 테이블이 포함하는 코드 중, 모두 0으로 이루어진 해시 코드와 모두 1로 이루어진 해시 코드가 인덱싱하는 버킷에 포함되는 샘플의 수가 증가할 수 있다.

[0086] 트레이닝부는 레이블이 있는 이상 샘플 및 필터링 결과를 이용하여 감지 모델에 대한 DML을 실행한다(S503). 전술한 바와 같이 필터링 결과는 잠재적인 비정상 데이터에 대한 집합 \hat{U}_a 및 신뢰가능한 정상 데이터에 대한 집합 \hat{U}_n 이다.

[0087] 감지 모델(102)에 대한 DML을 실행하기 위한 메트릭(metric)으로는 수학식 6에 표현된 바와 같은 트리플렛 손실함수(triplet loss function)를 이용한다.

수학식 6

[0088]
$$\mathcal{L} = \sum_{(x^*, x^+, x^-) \in \mathcal{J}_a} [\|\Phi(x^*) - \Phi(x^+)\|^2 - \|\Phi(x^*) - \Phi(x^-)\|^2 + \alpha]_+$$

[0089] 여기서 $[x]_+$ 는 $\max(x, 0)$ 이고, α 는 마진(margin)을 위하여 삽입된 항목이다. \mathcal{J}_a 는 트리플렛의 집합이며, 트리플렛의 구성원인 앵커(anchor), 긍정(positive) 및 부정(negative) x^*, x^+, x^- 는 $x^*, x^+ \in \hat{U}_a \cup A$ 및 $x^- \in \hat{U}_n$ 이다. 즉, 앵커와 긍정은 레이블이 있는 이상 샘플 또는 잠재적인 비정상 샘플의 집합에서 선택되고, 부정은 신뢰가능한 정상 샘플의 집합에서 선택된다. 따라서, 수학식 6에 나타난 손실함수를 최소화하는 것은, 앵커와 긍정 간의 거리를 최소화하고, 앵커와 부정 간의 거리를 최대화하는 것과 동일한 의미이다.

[0090] 트레이닝부는, 수학식 7에 기반하여 손실함수를 최소화하는 방향으로 감지 모델(102)의 파라미터를 업데이트한다.

수학식 7

[0091]
$$\min_{\Phi(\cdot)} \mathcal{L} \text{ s.t. } \|\Phi(\cdot)\|^2 \leq 1$$

[0092] 수학식 7에 따라, 감지 모델(102)이 생성하는 임베딩 표현의 크기는 단위 원(unit sphere) 이내에 존재하게 된다. 해시필터(111)의 DHF 과정에서 $\Phi(\cdot)$ 를 이용하기 위해, 수학식 7에 나타난 바와 같은 제약이 필요하다.

[0093] 도 4에 도시된 바와 같이, DML의 실행에 따라 감지 모델(102)은 정상 샘플과 비정상 샘플에 대한 구별이 더 용이해진 임베딩 표현을 생성하게 된다.

[0094] 트레이닝부는 트레이닝이 기 설정된 최대 에폭에 도달했는지를 확인하여(S504), 최대 에폭(epoch)에 도달하지 않았다면, DHF 및 DML의 실행 과정(S502 및 S503 단계, S502는 S511부터 S516까지의 단계를 의미함)을 반복한다.

[0095] 트레이닝이 기 설정된 최대 에폭에 도달한 경우, 트레이닝부는 감지 모델(102)에 대한 트레이닝을 종료한다. 트레이닝 종료 시점의 파라미터를 이용하여, 감지 모델(102)은 이상 감지를 실행할 수 있다.

[0096] 본 발명의 다른 실시예에 있어서, 트레이닝부는 트레이닝의 중간 단계에서 감지 모델에 대한 최적의 파라미터를 선정할 수 있다. 최적의 파라미터를 선정하기 위하여 트레이닝부는 매 에폭 별로 평균 해시 코드의 개수와 트리플렛 손실을 이용할 수 있다.

- [0097] 먼저 평균 해시 코드의 개수가 기 저장된 최소 해시 코드의 개수보다 적은 경우, 이 경우에 대응되는 감지 모델의 파라미터를 최적의 파라미터로 선정한다. 다음, 평균 해시 코드의 개수가 기 저장된 최소 해시 코드의 개수와 같은 경우, 트리플렛 손실이 기 저장된 최소 트리플렛 손실보다 작으면, 이 경우에 대응되는 감지 모델의 파라미터를 최적의 파라미터로 선정한다. 그리고, 평균 해시 코드의 수가 기 저장된 최소 해시 코드의 개수보다 많은 경우에는, 기 저장된 최적의 파라미터를 유지한다. 선정된 최적의 파라미터를 이용하여, 감지 모델(102)은 이상 감지를 실행할 수 있다.
- [0098] 본 발명의 또다른 실시예에 있어서, 트레이닝부는 최대 에폭에 도달하지 않은 경우라도, 해시필터(111)가 생성한 필터링 결과에 더 이상의 레이블 변동이 없을 때, 트레이닝을 종료할 수 있다. 트레이닝 종료 시점의 파라미터를 이용하여, 감지 모델(102)은 이상 감지를 실행할 수 있다.
- [0099] 이상에서 설명한 바와 같이 본 실시예에 따르면, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 딥러닝(deep learning) 기반 감지 모델(detection model)을 사전에 트레이닝하는 이상 감지방법 및 장치를 제공함으로써, 다중 시계열(multiple time series) 데이터에 포함된 레이블이 없는(unlabeled) 샘플에 대하여 높은 정확도의 레이블을 생성하는 것이 가능해지는 효과가 있다.
- [0100] 이하, 본 실시예에 따른 이상 감지장치(100)의 성능에 대한 실험예를 설명한다.
- [0101] 실험에서는 제품 생산 과정에서 획득한, 77 개의 시리즈로 구성된 다중 시계열 데이터를 검증용으로 이용하였다. 임의로 선택된 시리즈의 일부 구간을 다운샘플링(down-sampling) 또는 업샘플링(up-sampling)하여 값을 변환시키거나, 반복 패턴이 지속되는 구간의 일부를 역순으로 배열함으로써, 비정상 샘플을 생성하였다.
- [0102] 비교 대상은 DCNN을 기반으로 AE(AutoEncoder)를 구현한 바이트넷(ByteNet, 비특허문헌 5 참조)을 이용하였다. 바이트넷은 AE를 구성하는 인코더 및 디코더 각각에 DCNN을 적용한 것이다.
- [0103] 전술한 바와 같이, 본 실시예에 따른 이상 감지장치(100)는 DCNN을 감지 모델(102)로 이용하되, 감지 모델은 PU 학습 방법인 DHF 및 DML을 기반으로 사전에 트레이닝되었다.
- [0104] 비교 척도로는 AUC(Area Under the receiver operating Curve)를 이용하였다. AUC는 0부터 1까지의 값을 가지며, 이상 감지 성능을 산정하기 위한 표준적인 척도로 널리 이용된다.
- [0105] 본 실시예에 대한 AUC의 계산에는 비정상 점수(abnormal score)를 사용하되, 검증용 샘플 x에 대하여 비정상 점수는 수학적 식 8과 같이 계산될 수 있다.

수학적 식 8

$$\text{abnormal score}(x) = \frac{1}{|\hat{U}_n|} \sum_{\hat{u} \in \hat{U}_n} |\Phi(\hat{u}) - \Phi(x)|^2$$

- [0106]
- [0107] 여기서, $|\hat{U}_n|$ 는 PU 학습 방법에서 최종적으로 식별된 신뢰가능한 정상 샘플의 집합에 포함된 정상 샘플의 개수이다. 수학적 식 8에 따르면, 검증용 샘플 x에 대한 비정상 점수는 x의 임베딩 표현과 신뢰가능한 정상 샘플 \hat{u} 의 임베딩 표현 간의 차이를 평균한 값이다.
- [0108] 비교 대상에 대한 AUC의 계산에도 비정상 점수를 이용하였으며, 검증용 샘플 x에 대한 재구성 오차(reconstruction error)를 이용하여 비정상 점수를 계산하였다.
- [0109] 본 실시예 및 비교 대상의 감지 성능은 표 2에 나타나 있다.

표 2

모델	AUC
AE(DCNN)	0.66
본 실시예	0.97

[0110]

[0111]

[0112]

[0113]

[0114]

[0115]

[0116]

[0117]

[0118]

표 2에 나타난 바와 같이, 본 실시예의 AUC가 비교 대상에 비하여 50% 정도 증가되어, 탁월한 성능 향상을 보였다.

이상에서 설명한 바와 같이 본 실시예에 따르면, 제한된 이상 정보(limited anomaly information) 및 PU 학습(Positive and Unlabeled learning)을 이용하여 사전에 트레이닝된 감지 모델(detection model)이 다중 시계열(multiple time series) 데이터로부터 이상을 감지하는 이상 감지방법 및 장치를 제공함으로써, 다중 시계열 데이터에 포함된 이상에 대한 감지 성능을 향상시키는 것이 가능해지는 효과가 있다.

본 실시예에 따른 각 순서도에서는 각각의 과정을 순차적으로 실행하는 것으로 기재하고 있으나, 반드시 이에 한정되는 것은 아니다. 다시 말해, 순서도에 기재된 과정을 변경하여 실행하거나 하나 이상의 과정을 병렬적으로 실행하는 것이 적용 가능할 것이므로, 순서도는 시계열적인 순서로 한정되는 것은 아니다.

본 명세서에 설명되는 시스템들 및 기법들의 다양한 구현예들은, 디지털 전자 회로, 집적 회로, FPGA(field programmable gate array), ASIC(application specific integrated circuit), 컴퓨터 하드웨어, 펌웨어, 소프트웨어, 및/또는 이들의 조합으로 실현될 수 있다. 이러한 다양한 구현예들은 프로그래밍가능 시스템 상에서 실행가능한 하나 이상의 컴퓨터 프로그램들로 구현되는 것을 포함할 수 있다. 프로그래밍가능 시스템은, 저장 시스템, 적어도 하나의 입력 디바이스, 그리고 적어도 하나의 출력 디바이스로부터 데이터 및 명령들을 수신하고 이들에게 데이터 및 명령들을 전송하도록 결합되는 적어도 하나의 프로그래밍가능 프로세서(이것은 특수 목적 프로세서일 수 있거나 혹은 범용 프로세서일 수 있음)를 포함한다. 컴퓨터 프로그램들(이것은 또한 프로그램들, 소프트웨어, 소프트웨어 애플리케이션들 혹은 코드로서 알려져 있음)은 프로그래밍가능 프로세서에 대한 명령어들을 포함하며 "컴퓨터가 읽을 수 있는 기록매체"에 저장된다.

컴퓨터가 읽을 수 있는 기록매체는, 컴퓨터 시스템에 의하여 읽혀질 수 있는 데이터가 저장되는 모든 종류의 기록장치를 포함한다. 이러한 컴퓨터가 읽을 수 있는 기록매체는 ROM, CD-ROM, 자기 테이프, 플로피디스크, 메모리 카드, 하드 디스크, 광자기 디스크, 스토리지 디바이스 등의 비휘발성(non-volatile) 또는 비일시적인(non-transitory) 매체일 수 있으며, 또한 캐리어 웨이브(예를 들어, 인터넷을 통한 전송) 및 데이터 전송 매체(data transmission medium)와 같은 일시적인(transitory) 매체를 더 포함할 수도 있다. 또한 컴퓨터가 읽을 수 있는 기록매체는 네트워크로 연결된 컴퓨터 시스템에 분산되어, 분산방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수도 있다.

본 명세서에 설명되는 시스템들 및 기법들의 다양한 구현예들은, 프로그램가능 컴퓨터에 의하여 구현될 수 있다. 여기서, 컴퓨터는 프로그램가능 프로세서, 데이터 저장 시스템(휘발성 메모리, 비휘발성 메모리, 또는 다른 종류의 저장 시스템이거나 이들의 조합을 포함함) 및 적어도 한 개의 커뮤니케이션 인터페이스를 포함한다. 예컨대, 프로그램가능 컴퓨터는 서버, 네트워크 기기, 셋탑 박스, 내장형 장치, 컴퓨터 확장 모듈, 개인용 컴퓨터, 랩탑, PDA(Personal Data Assistant), 클라우드 컴퓨팅 시스템 또는 모바일 장치 중 하나일 수 있다.

이상의 설명은 본 실시예의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 실시예가 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 실시예의 본질적인 특성에서 벗어나지 않는 범위에서 다양한 수정 및 변형이 가능할 것이다. 따라서, 본 실시예들은 본 실시예의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예에 의하여 본 실시예의 기술 사상의 범위가 한정되는 것은 아니다. 본 실시예의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 실시예의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

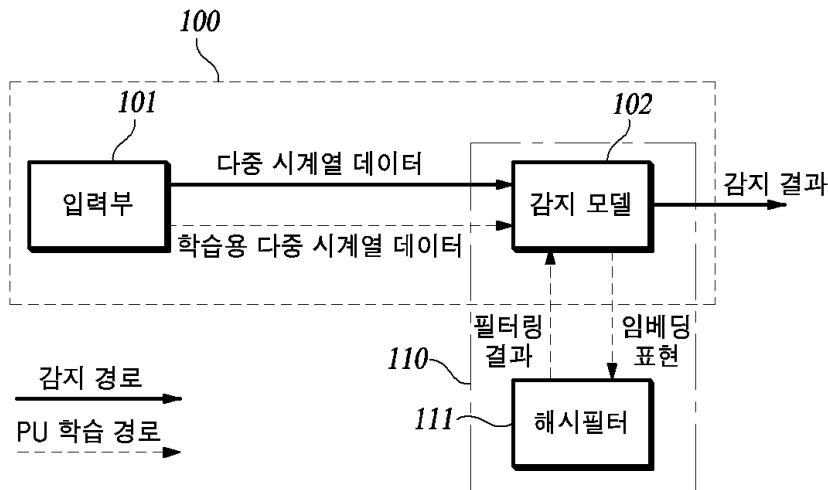
부호의 설명

100: 이상 감지장치(100) 101: 입력부
102: 감지 모델 110: PU 모델

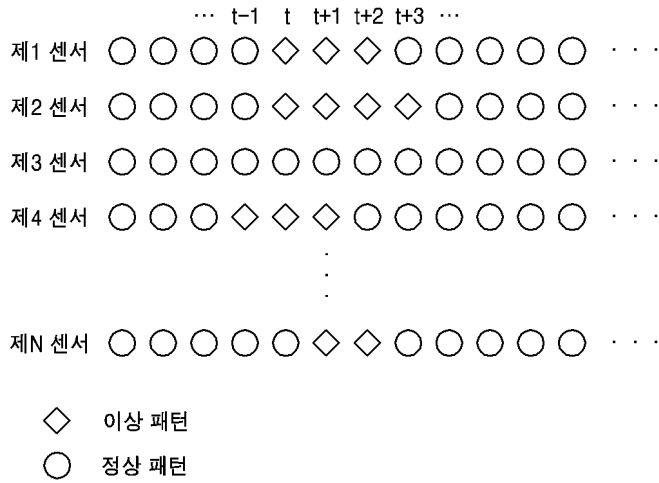
111: 해시필터

도면


도면1




도면2



도면3




(a)



(b)

도면4

- ◆ 레이블이 있는 이상 데이터
- 레이블이 없는 비정상 데이터
- 레이블이 없는 정상 데이터



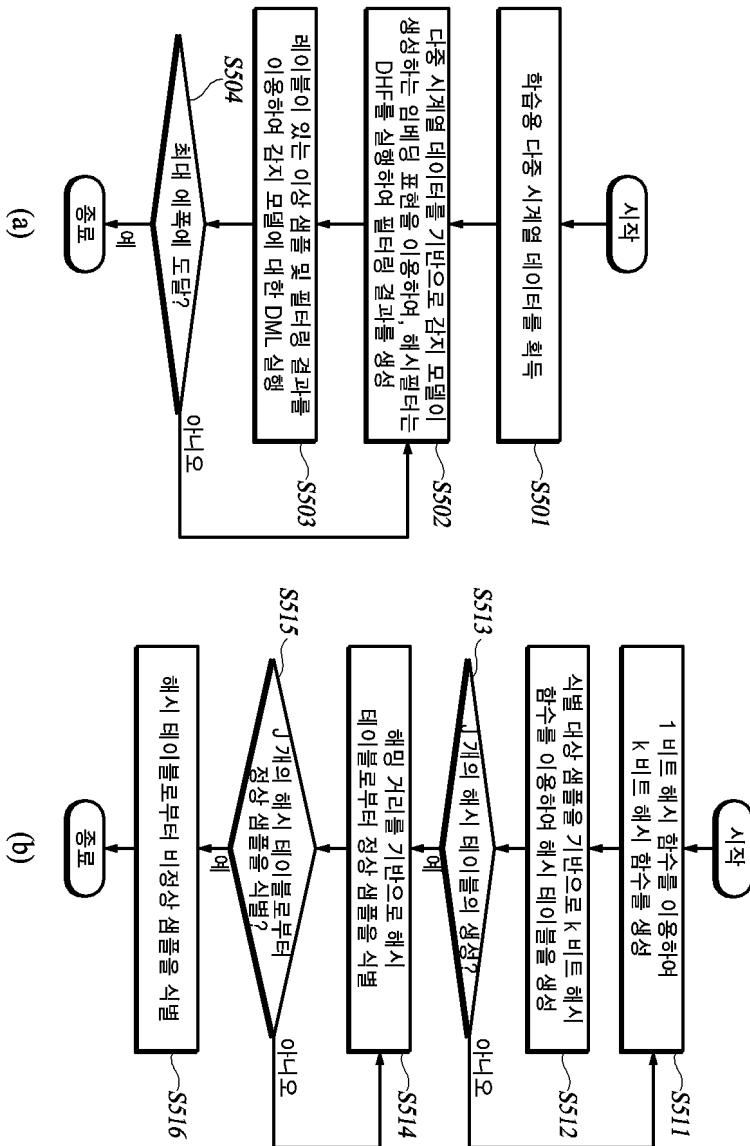
DHF : Distance Hashing-based Filtering

레이블이 없는 비정상 데이터 및 정상 데이터 식별

DML : Deep Metric Learning

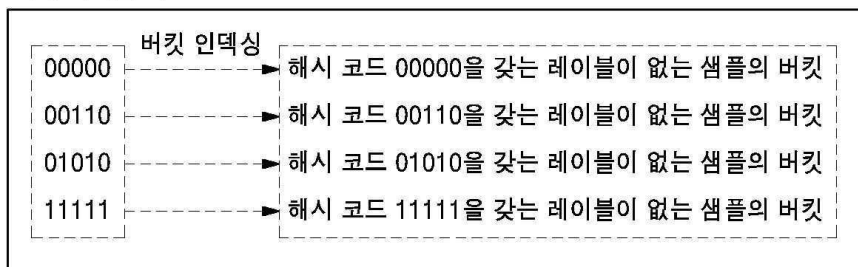
감지 모델에 대한 트레이닝

도면5



도면6

해시 테이블 T_i



(k=5인 경우)