(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0120992
(43) 공개일자 2024년08월08일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) *G06N 3/0455* (2023.01)
G06T 7/00 (2017.01)
(52) CPC특허분류
G06N 3/088 (2023.01)
G06N 3/0455 (2023.01)
(21) 출원번호 10-2023-0013663
(22) 출원일자 2023년02월01일
심사청구일자 2023년02월01일

(71) 출원인
서강대학교산학협력단
서울특별시 마포구 백범로 35 (신수동, 서강대학교)
(72) 발명자
양지훈
서울특별시 은평구 백련산로2길 19 백련산힐스테이트1차 101동 404호
김성민
서울특별시 강남구 언주로30길 56 타워팰리스 B동 3905호
(74) 대리인
이지연

전체 청구항 수 : 총 10 항

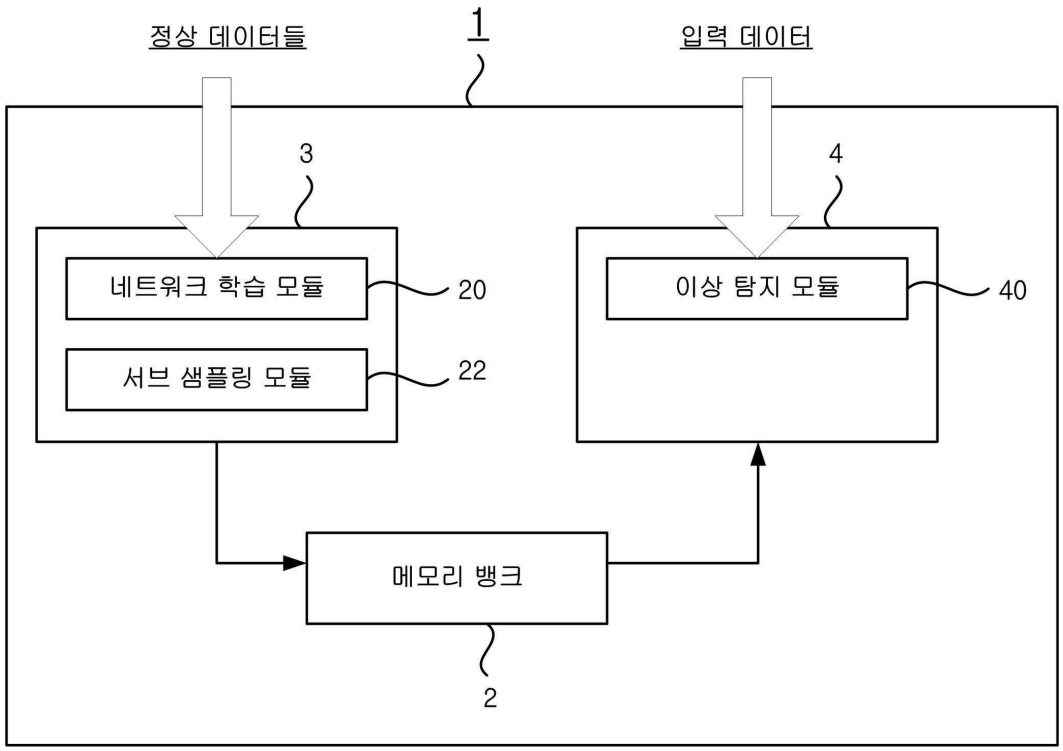
(54) 발명의 명칭 **학생-교사 네트워크를 기반으로 한 이상 탐지 시스템 및 이상 탐지 방법**

(57) 요 약

본 발명은 Student-Teacher 네트워크 기반의 이상 탐지 시스템에 관한 것이다. 상기 이상 탐지 시스템은, 정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키고, 학습 과정에서 정상 데이터들에 대해 생성된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 학습 시스템; 및 상기 학습된 Student-Teacher 네트워크 및 상

(뒷면에 계속)

대 표 도 - 도3



기 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여, 입력 데이터에 대하여 이상 탐지하는 추론 시스템;을 구비한다.

본 발명에 따른 이상 검출 시스템은 인코더 및 디코더 기반의 Teacher-Student 네트워크를 학습하여 정상 데이터들에 대한 저차원의 임베딩 특징 벡터들을 생성하여 메모리 뱅크에 저장하고, 추론시에는 입력 데이터에 대한 임베딩 특징 벡터와 메모리 뱅크의 임베딩 특징 벡터들간의 거리를 계산함으로써, 메모리 뱅크를 효율적으로 사용하고 추론 속도를 단축시킬 수 있게 된다.

(52) CPC특허분류
G06T 7/0002 (2013.01)
G06T 2207/20084 (2013.01)

이 발명을 지원한 국가연구개발사업
과제고유번호 1711160600
과제번호 2022-0-00956-001
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 디지털역기능대응기술개발
연구과제명 소셜네트워크에서의 온라인그루밍 위험성 자가탐지 기술 개발
기 여 율 1/2
과제수행기관명 한국전자통신연구원
연구기간 2022.04.01 ~ 2024.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1465037241
과제번호 HI22C1983000022
부처명 보건복지부
과제관리(전문)기관명 한국보건산업진흥원
연구사업명 정신건강연구개발사업
연구과제명 국민 정신건강 트렌드 모니터링 · 관리 플랫폼 개발
기 여 율 1/2
과제수행기관명 서강대학교 산학협력단
연구기간 2022.07.01 ~ 2027.12.31

명 세 서

청구범위

청구항 1

메모리 뱅크;

정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키고, 학습 과정에서 정상 데이터들에 대해 생성된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 학습 시스템; 및

상기 학습된 Student-Teacher 네트워크 및 상기 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여, 입력 데이터에 대하여 이상 탐지하는 추론 시스템;

을 구비하는 Student-Teacher 네트워크 기반의 이상 탐지 시스템.

청구항 2

제1항에 있어서, 상기 학습 시스템은,

정상 데이터를 이용하여 Student-Teacher 네트워크를 학습시키고, 학습 과정에서 정상 데이터의 특징을 함축한 저차원의 보틀넥 임베딩 특징 벡터를 생성하는 네트워크 학습 모듈; 및

학습 과정에서 정상 데이터들에 대하여 생성된 보틀넥 임베딩 특징 벡터들을 서브 샘플링하고, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 서브 샘플링 모듈;

을 구비하는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 시스템.

청구항 3

제2항에 있어서, 상기 네트워크 학습 모듈은,

입력된 데이터에 대한 특징 벡터를 추출하도록 사전 학습되어 가중치를 고정시킨 Teacher 네트워크;

상기 Teacher 네트워크로부터 생성된 특징 벡터들을 결합하는 특징 벡터 연결 레이어;

데이터의 멀티 스케일 특징 벡터가 포함된 저차원 공간으로 함축되도록 학습시켜, 상기 결합된 특징 벡터들로부터 저차원의 임베딩 특징 벡터들을 추출하는 임베딩 레이어; 및

상기 임베딩 레이어의 임베딩 특징 벡터들로부터 데이터를 재건하도록 학습되는 Student 네트워크;

를 구비하는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 시스템.

청구항 4

제3항에 있어서, 상기 Teacher 네트워크는 입력된 데이터에 대한 특징 벡터를 추출하도록 사전 학습된 인코더 구조로 이루어지고,

상기 Student 네트워크는 임베딩 특징 벡터를 학습시키도록 구성된 디코더 구조로 이루어진 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 시스템.

청구항 5

제1항에 있어서, 상기 추론 시스템은 이상 탐지 모듈을 구비하고,

상기 이상 탐지 모듈은,

새로운 데이터가 입력되면, 학습된 Student-Teacher 네트워크의 Teacher 네트워크를 통해 임베딩 특징 벡터를 추출하고,

추출된 임베딩 특징 벡터와 메모리 뱅크안에 저장된 임베딩 특징 벡터들 간의 거리를 계산하여 이상치 점수를 산출하고,

이상치 점수를 통해 이상치 위치 식별하는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 시스템.

청구항 6

메모리 뱅크 및 Student-Teacher 네트워크를 구비한 이상 탐지 시스템에서의 이상 탐지 방법에 있어서,

(a) 정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키는 단계;

(b) Student-Teacher 네트워크의 학습 과정에서 정상 데이터의 특징을 함축한 보틀넥 임베딩 특징 벡터를 생성하는 단계;

(c) 정상 데이터들에 대해 생성된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 단계; 및

(d) 상기 학습된 Student-Teacher 네트워크 및 상기 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여, 입력 데이터에 대하여 이상 탐지하는 단계;

을 구비하는 Student-Teacher 네트워크 기반의 이상 탐지 방법.

청구항 7

제6항에 있어서, 상기 (c) 단계는,

학습 과정에서 정상 데이터들에 대해 생성된 보틀넥 임베딩 특징 벡터들을 서브 샘플링하고, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 방법.

청구항 8

제6항에 있어서, 상기 Student-Teacher 네트워크는,

사전 학습된 Teacher 네트워크를 통해 데이터에 대한 특징 벡터를 추출하고,

상기 Teacher 네트워크로부터 생성된 특징 벡터들을 결합하고,

데이터의 멀티 스케일 특징 벡터가 포함된 저차원 공간으로 함축되도록 학습시켜, 상기 결합된 특징 벡터들로부터 임베딩 특징 벡터를 추출하고,

상기 임베딩 특징 벡터로부터 데이터를 재건하도록 Student 네트워크를 학습시키는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 방법.

청구항 9

제8항에 있어서, 상기 Teacher 네트워크는 입력된 데이터에 대한 특징 벡터를 추출하도록 사전 학습된 인코더 구조로 이루어지고,

상기 Student 네트워크는 임베딩 특징 벡터를 학습시키도록 구성된 디코더 구조로 이루어진 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 방법.

청구항 10

제6항에 있어서, 상기 (d) 단계는,

(d1) 새로운 데이터가 입력되면, 학습된 Student-Teacher 네트워크의 Teacher 네트워크를 통해 상기 입력 데이터에 대한 임베딩 특징 벡터를 추출하는 단계;

(d2) 추출된 임베딩 특징 벡터와 메모리 뱅크안에 저장된 임베딩 특징 벡터들의 거리를 계산하여 이상치 점수를 산출하는 단계; 및

(d3) 이상치 점수를 통해 이상치 위치 식별하는 단계;

를 구비하는 것을 특징으로 하는 Student-Teacher 네트워크 기반의 이상 탐지 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 이상 탐지 시스템 및 그 방법에 관한 것으로서, 더욱 구체적으로는 인코더-디코더 구조의 Teacher-Student 네트워크를 학습시키고, 학습 과정에서 정상 데이터들에 대한 보틀넥 임베딩 특징 벡터들을 생성하여 메모리 뱅크에 저장하며, 추론시에는 학습된 Teacher-Student 네트워크와 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여 데이터에 대한 이상 탐지를 신속하게 수행할 수 있도록 구성된 것을 특징으로 하는 학생-교사 네트워크를 기반으로 한 이상 탐지 시스템 및 이상 탐지 방법에 관한 것이다.

배 경 기 술

[0002] 결함 탐지는 데이터들의 일반적인 패턴을 따르는지 여부에 따라 정상 데이터와 비정상 데이터 중 하나로 식별하게 된다. 이상 탐지 분야는 실제 산업에서도 많이 쓰이고 있을 뿐만 아니라 제조 산업 분야에서도 많이 필요로 하는 요소로서, 그 예로는 제품 품질 관리, 의료 진단, 비디오 감시 등이 있다. 비정상 데이터는 산업에서 많이 발생하지 않기 때문에 데이터가 많지 않으며, 이로 인하여 지도 학습으로 문제를 해결하기 어려울 뿐만 아니라 데이터에 대한 라벨링도 어렵다. 따라서 이러한 문제들로 인하여, 이상 데이터 탐지는 지도 학습으로 접근하지 않고 비지도 학습을 통해 접근하게 된다.

[0003] 일반적으로, 데이터들은 단일 클래스 분류 모델(One-Class Classification) 형식으로 구축되는데, 학습 데이터 셋은 정상 데이터들로만 구성되고 테스트 데이터 셋은 정상 및 비정상 데이터를 모두 포함하여 구성된다. 이런 학습 방법을 "비지도 학습 방법"이라고 부른다. 이러한 방식으로 학습을 시키게 되면 네트워크가 정상 데이터의 특징만을 학습을 하게 될 것이고 학습이 끝난 뒤 테스트 데이터 셋으로 추론을 할 때 학습된 정상 특징과는 다른 특징들을 걸러낼 수 있게 된다.

[0004] 비지도 학습 방법 중의 하나인 오토 인코더(Autoencoder)와 생성 모델(Generative Adversarial Network;'GAN')은 이상 탐지를 위해 많이 연구되었다. 오토 인코더 및 GAN과 같은 생성 모델을 사용하여 재건을 통해 이상 탐지하는 방법은 정상 데이터로만 학습된 모델이 오직 정상적인 부분들만 재건할 수 있고 비정상적인 부분들은 재건하지 못할 것이라는 가정에 의존한 방법들이다. 도 1은 종래의 기술에 따른 오토 인코더 기반의 이상 탐지 구조를 도시한 구성도이다. 정상 데이터를 사용하여 학습을 하게 되면 추론 시에 정상 데이터가 들어왔을 때 원래 입력 이미지와 네트워크를 통해 새로 생성된 이미지와의 차이가 작을 것이고 비정상 데이터가 들어왔을 때는 원래 입력 이미지와 새로 생성된 이미지와의 차이가 상대적으로 클 것이다. 종래의 오토 인코더와 생성 모델을 이용한 이상 탐지 방법은 이러한 차이 값을 통해 데이터의 이상 유무를 판단할 수 있게 된다. 하지만, 이러한 재건(Reconstruction) 방법은 클래스 간의 분산이 클 때는 재생성해내기 어렵다. 하나의 네트워크가 다양한 카테고리의 제조품들을 학습시키기 어렵기 때문이다.

[0005] 이러한 문제점을 해결하기 위하여, 특징 매칭(Feature Matching) 기반의 방법들이 많이 제안되고 있다. 특징 매칭 방법들은 특징 분포 간의 거리를 계산하여 결함을 탐지하게 된다.

[0006] 한편, 최근 사전 학습 모델을 활용한 이상 탐지 방법들도 제안되고 있다. 최근 연구에서는 ImageNet과 같이 큰 데이터로 사전 학습된 네트워크가 이상 탐지를 위한 좋은 차별적인 특징 벡터를 추출할 수 있다는 것을 증명했다. 사전학습 네트워크를 사용하여 추출된 정상 데이터의 특징 벡터를 사용하여 비정상 데이터를 식별해낼 수 있다. 예를 들어, 사전학습 모델로부터 특징 벡터를 추출하여 메모리 뱅크에 저장시키고 KNN 기반의 이상 탐지 방법을 사용하거나, 사전학습 네트워크에서 추출된 정상 데이터의 분포를 활용하여 마할라노비스(Mahalanobis) 거리 측정을 통해 비정상 데이터를 탐지하는 방법 등이다. 하지만, 이러한 방식은 연산적으로 비효율적이라는 단점이 있다.

[0007] 한편, Student-Teacher Feature Matching for anomaly detection(STFPM) 방법은 Student-Teacher 네트워크 구조를 활용한 이상 탐지 방법으로서, 사전 학습된 네트워크를 Teacher 네트워크(Teacher Network)로 사용하고, Teacher 네트워크와 동일한 구조의 Student 네트워크(Student Network)에 Teacher 네트워크로부터 받은 지식을 이전한다. 도 2는 종래의 기술에 따른 STFPM 방식에 따른 Student-Teacher 네트워크 구조를 도시한 구성도이다. 이러한 종래의 방식에 따른 Student-Teacher 네트워크 구조의 결함 탐지 방법은 사전 학습된 네트워크를 통해 추출된 특징 벡터를 사용하여, 특징 매칭을 통해 결함을 탐지하며, 종래의 오토 인코더와 생성 모델을 이용한 재건 기반의 모델들보다 우수한 성능을 보였다. 하지만, 이러한 방법은 특징 매칭을 위한 특징 벡터들을 저장하기 위한 메모리 공간이 많이 필요할 뿐만 아니라 특징 매칭을 위한 추론 속도가 느린 한계점을 갖

고 있다.

선행기술문헌

특허문헌

[0008] (특허문헌 0001) 한국등록특허공보 제 10-2348536호

(특허문헌 0002) 한국공개특허공보 제 10-2022-0055970호

(특허문헌 0003) 한국등록특허공보 제 10-2232138호

(특허문헌 0004) 한국등록특허공보 제 10-2476300호

발명의 내용

해결하려는 과제

[0009] 전술한 문제점들을 해결하기 위하여, 본 발명은 인코더 및 디코더 기반의 Teacher-Student 네트워크를 학습하여 정상 데이터들에 대한 저차원의 임베딩 특징 벡터들을 추출하여 메모리 뱅크에 저장하고, 추론시에는 입력 데이터에 대한 임베딩 특징 벡터와 메모리 뱅크의 임베딩 특징 벡터들간의 거리를 계산함으로써, 메모리 뱅크를 효율적으로 사용하고 추론 속도를 단축시킬 수 있는 이상 검출 시스템 및 방법을 제공하는 것을 목적으로 한다.

과제의 해결 수단

[0010] 전술한 기술적 과제를 달성하기 위한 본 발명의 제1 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 시스템은, 메모리 뱅크; 정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키고 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 학습 시스템; 및 상기 Student-Teacher 네트워크의 사전 학습된 Teacher 네트워크 및 상기 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여, 입력 데이터에 대하여 이상 탐지하는 추론 시스템;을 구비한다.

[0011] 전술한 제1 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 시스템에 있어서, 상기 학습 시스템은, 정상 데이터를 이용하여 Student-Teacher 네트워크를 학습시키고, 정상 데이터의 특징을 저차원의 공간으로 함축하도록 학습된 보틀넥 임베딩 특징 벡터를 생성하는 네트워크 학습 모듈; 및 학습 과정에서 생성된 정상 데이터들에 대한 보틀넥 임베딩 특징 벡터들을 서브 샘플링하고, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 서브 샘플링 모듈;을 구비하는 것이 바람직하다.

[0012] 전술한 제1 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 시스템에 있어서, 상기 Student-Teacher 네트워크는, 데이터에 대한 특징 벡터를 추출하도록 사전 학습되고, 가중치를 고정시킨 Teacher 네트워크; 상기 Teacher 네트워크로부터 생성된 특징 벡터들을 결합하는 특징 벡터 연결 레이어; 데이터의 멀티 스케일 특징 벡터가 포함된 저차원 공간으로 함축되도록 학습시켜, 상기 결합된 특징 벡터들로부터 임베딩 특징 벡터를 추출하는 임베딩 레이어; 및 상기 임베딩 레이어의 임베딩 특징 벡터들로부터 데이터를 재건하도록 학습되는 Student 네트워크;를 구비하는 것이 바람직하다.

[0013] 전술한 제1 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 시스템에 있어서, 상기 Teacher 네트워크는 인코더 구조로 이루어지고, 상기 Student 네트워크는 디코더 구조로 이루어진 것이 바람직하다.

[0014] 전술한 제1 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 시스템에 있어서, 상기 추론 시스템은 이상 탐지 모듈을 구비하고, 상기 이상 탐지 모듈은, 새로운 데이터가 입력되면, 상기 Student-Teacher 네트워크의 사전 학습된 Teacher Network를 통해 임베딩 특징 벡터를 추출하고, 추출된 특징 벡터와 메모리 뱅크안에 저장된 임베딩 특징 벡터 간의 거리를 계산하여 이상치 점수를 산출하고, 이상치 점수를 통해 이상치 위치 식별하는 것이 바람직하다.

[0015] 본 발명의 제2 특징에 따른 이상 탐지 방법은, 메모리 뱅크 및 Student-Teacher 네트워크를 구비한 이상 탐지 시스템에서의 이상 탐지 방법에 관한 것으로서, (a) 정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키는 단계; (b) Student-Teacher 네트워크의 학습 과정에서 정상 데이터의 특징을 저차원의 공간으로 함축하도록 학습된 보틀넥 임베딩 특징 벡터를 생성하는 단계; (c) 상기 생성된 보틀넥 임베딩 특징 벡터들을 메모

리 뱅크에 저장하는 단계; 및 (d) 상기 Student-Teacher 네트워크의 사전 학습된 Teacher Network 및 상기 메모리 뱅크에 저장된 보틀넥 임베딩 특징 벡터들을 이용하여, 입력 데이터에 대하여 이상 탐지하는 단계; 를 구비한다.

[0016] 전술한 제2 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 방법에 있어서, 상기 (c) 단계는, 학습 과정에서 생성된 보틀넥 임베딩 특징 벡터들을 서브 샘플링하고, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장하는 것이 바람직하다.

[0017] 전술한 제2 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 방법에 있어서, 상기 Student-Teacher 네트워크는, 데이터에 대한 특징 벡터를 추출하도록 사전 학습된 Teacher 네트워크를 통해 데이터에 대한 특징 벡터를 추출하고, 상기 Teacher 네트워크로부터 생성된 특징 벡터들을 결합하고, 데이터의 멀티 스케일 특징 벡터가 포함된 저차원 공간으로 함축되도록 학습시켜 상기 결합된 특징 벡터로부터 저차원의 임베딩 특징 벡터를 추출하고, 상기 임베딩 특징 벡터들로부터 데이터를 재건하도록 Student 네트워크를 학습시키는 것이 바람직하다.

[0018] 전술한 제2 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 방법에 있어서, 상기 Teacher 네트워크는 인코더 구조로 이루어지고, 상기 Student 네트워크는 디코더 구조로 이루어진 것이 바람직하다.

[0019] 전술한 제2 특징에 따른 Student-Teacher 네트워크 기반의 이상 탐지 방법에 있어서, 상기 (d) 단계는, (d1) 새로운 데이터가 입력되면, 학습된 Student-Teacher 네트워크를 통해 임베딩 특징 벡터를 추출하는 단계; (d2) 추출된 특징 벡터와 메모리 뱅크안에 저장된 특징 벡터 간의 거리를 계산하여 이상치 점수를 산출하는 단계; (d3) 이상치 점수를 통해 이상치 위치 식별하는 단계;를 구비하는 것이 바람직하다.

발명의 효과

[0020] 본 발명에 따른 이상 검출 시스템은 인코더 및 디코더 기반의 Teacher-Student 네트워크를 학습하여 정상 데이터들에 대한 저차원의 임베딩 특징 벡터들을 생성하여 메모리 뱅크에 저장하고, 추론시에는 입력 데이터에 대한 임베딩 특징 벡터와 메모리 뱅크의 임베딩 특징 벡터들간의 거리를 계산한다. 따라서, 본 발명에 따른 이상 탐지 시스템은, 학습을 통해 정상 데이터의 특징을 함축한 보틀넥 임베딩 특징 벡터를 활용함에 따라, 더욱 효율적으로 메모리를 저장시킬 수 있게 되며, 추론 속도를 단축시킬 수 있게 된다.

도면의 간단한 설명

[0021] 도 1은 종래의 기술에 따른 오토인코더 기반의 이상 탐지 구조를 도시한 구성도이다.

도 2는 종래의 기술에 따른 STFPM 방식에 따른 Student-Teacher 네트워크 구조를 도시한 구성도이다.

도 3은 본 발명의 바람직한 실시예에 따른 Student-Teacher 네트워크를 기반으로 한 이상 탐지 시스템을 전체적으로 도시한 구성도이다.

도 4는 본 발명의 바람직한 실시예에 따른 이상 탐지 시스템에 있어서, Student-Teacher 네트워크 학습 모듈의 구조를 도시한 구성도이다.

도 5는 본 발명의 바람직한 실시예에 따른 이상 감지 시스템에 있어서, 코어셋 메모리 뱅크 알고리즘을 도시한 것이다.

발명을 실시하기 위한 구체적인 내용

[0022] 이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시예에 따른 Student-Teacher 네트워크를 기반으로 한 이상 탐지 시스템 및 이상 탐지 방법에 대하여 구체적으로 설명한다.

[0023] 도 3은 본 발명의 바람직한 실시예에 따른 Student-Teacher 네트워크를 기반으로 한 이상 탐지 시스템을 전체적으로 도시한 구성도이다. 도 3을 참조하면, 본 발명에 따른 이상 탐지 시스템(1)은 메모리 뱅크(2), 학습 시스템(3) 및 추론 시스템(4)으로 이루어진다. 상기 학습 시스템(3)은 정상 데이터들을 이용하여 Student-Teacher 네트워크를 학습시키고, 학습 과정에서 생성된 보틀넥 임베딩 특징 벡터들을 서브 샘플링하며, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크(2)에 저장한다. 추론 시스템(4)은 입력 데이터가 주어지면, 상기 Student-Teacher 네트워크의 사전 학습된 Teacher Network를 통해 임베딩 특징 벡터를 추출하고, 추출된 임베딩 특징 벡터와 메모리 뱅크(2)의 보틀넥 임베딩 특징 벡터간의 유클리디언 거리를 계산하여 이상치 점수를 산출하며, 이상치 점수를 이용하여 이상 위치를 식별한다.

[0024] 이하, 본 발명에 따른 이상 탐지 시스템의 학습 시스템(3)에 대하여 구체적으로 설명한다. 상기 학습 시스템은 Student-Teacher 네트워크를 학습시키는 네트워크 학습 모듈(20) 및 학습 과정에서 생성된 보틀넥 임베딩 특징 벡터들을 서브 샘플링하여 메모리 뱅크에 저장하는 서브 샘플링 모듈(22)을 구비한다. 상기 메모리 뱅크(2)에는 서브 샘플링된 정상 데이터들에 대한 보틀넥 임베딩 특징 벡터들이 저장된다.

[0025] 본 발명에 따른 이상 탐지 시스템은, Student-Teacher 네트워크를 활용하고 계층적인 특징 매칭 방식의 학습 과정을 통해 정상 데이터의 특징을 학습한다. 도 4는 본 발명의 바람직한 실시예에 따른 이상 탐지 시스템에 있어서, Student-Teacher 네트워크 학습 모듈의 구조를 도시한 구성도이다. 도 4를 참조하면, 상기 Student-Teacher 네트워크 학습 모듈(20)은 정상 데이터의 특징 분포를 학습하기 위해 인코더-디코더 형식의 Student-Teacher 네트워크를 사용하며, 사전 학습된 인코더 구조의 Teacher Network(200), 특징 벡터 연결 레이어(210), 학습 가능한 임베딩 레이어(220) 및 학습 가능한 디코더 구조의 Student Network(230)를 구비한다.

[0026] 상기 Teacher Network(200)는 인코더 구조로 이루어져 데이터에 대한 특징 벡터를 추출하도록 사전 학습되며, 가중치를 고정시킨 것을 특징으로 한다. 상기 특징 벡터 연결 레이어(210)는 사전 학습된 상기 Teacher 네트워크로부터 추출된 특징 벡터들을 합성곱 레이어(Convolution Layer)를 통해 공간 해상도 크기(Spatial Resolution)를 맞추어 주고 연결(Concatenation)하여 채널 기준으로 결합한다. 상기 임베딩 레이어(220)는 WideResNet-50 모델에서 사용된 Residual Block을 활용하여, 데이터의 멀티 스케일 특징 벡터가 포함된 저차원 공간으로 함축되도록, 상기 결합된 특징 벡터들을 학습시켜 저차원의 보틀넥 임베딩 특징 벡터들을 생성한다. 상기 Student Network(230)는 상기 임베딩 레이어의 임베딩 특징 벡터들로부터 데이터를 재건하도록 학습된다.

[0027] 일반적으로, Teacher Network와 Student Network가 같은 구조를 사용하는 기존의 Student-Teacher 네트워크와는 달리, 본 발명에 따른 Teacher 네트워크와 Student 네트워크는 각각 인코더와 디코더 형식의 구조를 따르는 것을 특징으로 한다. 본 발명에 따른 Teacher 네트워크는 인코더 형식으로 이루어져, 정상 데이터의 특징을 함축한 임베딩 특징 벡터를 학습하고, 본 발명에 따른 Student 네트워크는 디코더 형식으로 이루어져, 함축된 임베딩 특징 벡터로부터 정상 데이터를 다시 재건한다. 이때, Teacher 네트워크는 사전 학습된 네트워크로서, 고정시켜 그레디언트(gradient)가 업데이트 되지 않도록 한다. 그리고 이와 같이 함축된 임베딩 특징 벡터를 보틀넥이라고 부른다. 더 작은 차원의 임베딩 특징 벡터로 인코딩 함으로써 정상 데이터의 중복적인 정보를 없애고 중요한 정보들만 압축된 벡터를 활용할 수 있다.

[0028] 전술한 구조를 갖는 Student-Teacher 네트워크는, 입력 데이터가 주어졌을 때 인코더 형식의 Teacher 네트워크로부터 멀티 스케일의 특징 대표(Feature Representation)을 추출하고 중간의 보틀넥 임베딩 레이어에 정상 데이터의 특징 대표가 잘 저장될 수 있도록 디코더 형식의 Student 네트워크를 학습시킨다. 이는, Teacher 네트워크에서 추출된 멀티 스케일의 특징 벡터를 목표로 보고 Student 네트워크에 지식 증류를 하는 방법이다. 이런 학습 과정을 거치게 되면 결과적으로 보틀넥 임베딩 레이어는 정상 데이터의 멀티 스케일 특징 벡터가 포함된 저차원의 공간으로 함축된다. 이와 같이, Student-Teacher 네트워크 학습 모듈을 통해 학습된 저차원의 임베딩 특징 벡터는 후술되는 서브 샘플링 모듈을 통해 서브 샘플링되어 중복된 특징들을 줄인 후, 메모리 뱅크에 저장된다.

[0029] 본 발명에 따른 이상 탐지 시스템은 고수준 특징(high-level feature)를 사용하지 않고 중간 수준 특징(mid-level feature)를 활용하여 ImageNet 데이터에 대한 편향을 줄일 수 있다. 기존의 PatchCore 모델에서는 별도의 학습 과정 없이 사전학습 모델로부터 추출된 특징 벡터를 활용하기 때문에 많은 메모리와 빠르지 않은 추론 속도를 보였다. 하지만, 본 발명에 따른 이상 탐지 시스템은, 학습을 통해 정상 데이터의 특징을 함축한 보틀넥 임베딩 특징 벡터를 활용함에 따라 더욱 효율적으로 메모리를 저장시킬 수 있게 되며, 추론 속도를 단축시킬 수 있게 된다.

[0030] 이하, 상기 네트워크 학습 모듈이 Student-Teacher 네트워크를 학습시키는 과정을 구체적으로 설명한다.

[0031] 상기 네트워크 학습 모듈은 학습 과정에서 정상 데이터의 특징을 잘 함축해 놓은 보틀넥 임베딩 특징 벡터를 얻는 것을 목표로 한다. 비정상인 부분이 없는 정상 데이터 셋을 $D = \{I_1, I_2, \ldots, I_n\}$ 라고 하고, 목표는 정상 데이터의 위상 공간(Manifold)를 선생 네트워크와 학생 네트워크의 l 개의 층으로부터 추출된 특징 벡터들의 특징 매칭을 통해 학습하는 것이다. 입력 이미지는 $I_k \in \mathbb{R}^{w \times h \times d}$ 로 표현되며 w는 width, h는

height, d는 dimension이다. 그리고 l 은 선생, 학생 네트워크의 각각 레이어 블록의 순서라고 가정한다. 선생 네트워크의 l 번째 층의 특징 맵의 경우는 $F_t^l(I_k) \in \mathbb{R}^{w_l \times h_l \times d_l}$ 이고, 학생 네트워크의 l 번째 층의 특징 맵의 경우는 $F_s^l(I_k) \in \mathbb{R}^{w_l \times h_l \times d_l}$ 이며 w_l, h_l, d_l은 각각 해당 레이어 특징 맵의 width, height, dimension이다.

[0032] F_t^l와 F_s^l는 각각 선생 네트워크와 학생 네트워크의 특징 벡터들이고 두 네트워크에서 추출된 특징 벡터 사이의 코사인 유사도를 구한다. 따라서 손실 함수를 l2-normalized 특징 벡터 사이의 코사인 유사도로 정의하고 수학식 1은 코사인 유사도이며, 손실 함수의 식은 수학식 2와 같다.

수학식 1

$$S^l(I_k)_{h,w} = 1 - \frac{F_t^l(I_k)_{h,w}^T F_s^l(I_k)_{h,w}}{\| F_t^l(I_k)_{h,w} \| \| F_s^l(I_k)_{h,w} \|}$$

[0033]

수학식 2

$$Loss = \sum_{l=1}^{l} \left\{ \frac{1}{h_l w_l} \sum_{h=1}^{h_l} \sum_{w=1}^{w_l} S^l(D)_{h,w} \right\}$$

[0034]

[0035] 여기서 l 은 특징 레이어의 개수다. Loss 값은 0과 1사이의 값이며 낮을수록 특징 벡터 간의 코사인 유사도가 높다고 할 수 있다. 전체 이미지 셋의 손실 값은 각각의 공간 위치의 평균값을 취한 것과 같으며 특징 레이어의 개수만큼 모두 더해준 값이 전체 손실 값이 된다.

[0036] 사전 학습된 Teacher 네트워크로부터 특징 벡터를 추출하는 경우, 크고 풍부한 특징 대표를 저장하고 있기 때문에 해당 특징 맵 안에 중복되는 특징 벡터가 존재할 수 있다. 따라서, 임베딩 레이어는 이러한 특징 대표 중에서 중요한 특징으로만 인코딩하여 중복성을 줄이고 정상 데이터를 잘 표현하는 중요한 특징으로만 구성된 임베딩 특징 벡터를 학습한다. 특징 벡터 연결 레이어는 사전 학습된 Teacher 네트워크로부터 추출된 특징 벡터가 입력되고, 입력된 특징 벡터에 대하여 합성곱 레이어(Convolution layer)를 통해 공간 해상도 크기(Spatial Resolution)를 맞추고 연결(Concatenation)을 함으로써, 채널 기준으로 특징 벡터를 결합하여 임베딩 레이어로 출력한다. 임베딩 레이어는 특징 결합 연결 레이어로부터 결합된 특징 벡터가 입력되며, 입력된 특징 벡터에 대하여 WideResNet-50 모델에서 사용된 Residual block을 활용하여 정상 데이터의 특징을 잘 표현하는 더 작은 차원의 특징 벡터로 함축시켜 보틀넥 임베딩 특징 벡터를 추출한다.

[0037] 상기 서브 샘플링 모듈은, 학습된 Student-Teacher 네트워크를 통해 추출한 보틀넥 임베딩 특징 벡터들을 서브

샘플링하고, 서브 샘플링된 보틀넥 임베딩 특징 벡터들을 메모리 뱅크에 저장한다.

[0038] 이하, 서브 샘플링 모듈이 서브 샘플링하는 과정을 설명한다. 먼저, 서브 샘플링 모듈은, 임베딩 레이어에 의해 추출된 임베딩 특징 벡터를 무작위 선형 투영(Random linear projection)을 통해 더 작은 차원의 벡터로 투영시켜준다. d^* < d일 때 $\psi : \mathbb{R}^d \rightarrow \mathbb{R}^{d^*}$ 로 나타낼 수 있다. 그리고 전체 데이터 개수 중에 사전 설정된 비율(%)에 따라, 원래 데이터로부터 해당 비율만큼 서브 샘플링을 진행한다. 도 5는 본 발명의 바람직한 실시예에 따른 이상 감지 시스템에 있어서, 코어셋 메모리 뱅크 알고리즘을 도시한 것이다. 전술한 바와 같이, 서브 샘플링 모듈에 의해 메모리 뱅크에 서브 샘플링된 보틀넥 임베딩 특징 벡터들이 저장된다.

[0039] 이하, 본 발명에 따른 이상 탐지 시스템의 추론 시스템(4)에 대하여 구체적으로 설명한다. 상기 추론 시스템은, 상기 학습된 Student-Teacher 네트워크 및 메모리 뱅크에 저장된 정상 데이터들에 대한 보틀넥 임베딩 특징 벡터들을 이용하여 데이터에 대한 이상 탐지하는 이상 탐지 모듈을 구비한다.

[0040] 이하, 상기 추론 시스템(4)의 이상 탐지 모듈의 동작에 대하여 구체적으로 설명한다. 상기 이상 탐지 모듈은, 새로운 데이터가 입력되면, Teacher 네트워크를 통해 임베딩 특징 벡터를 추출한다. 추출된 특징 벡터인 $x^{test} = \phi(x_i)$ 와 메모리 뱅크안에 저장된 특징 벡터 간의 거리 계산을 통해 이상치 점수를 산출한다. 이미지 단위의 이상치 점수는 x^{test} 와 계산된 거리 중 가장 큰 값으로 산정된다. 이미지 객체 위치 식별 방법 기반인 픽셀 기준 이상치 점수도 비슷한 방식으로 산출된다. 추출된 특징 벡터는 $x^{test} \in \mathbb{R}^{h \times w \times d}$ 와 같으며 h×w 크기의 패치들이 각각의 이상치 점수를 갖게 되고 이 크기를 쌍 선형 보간법(Bilinear Interpolation)을 통해서 원래 이미지 크기로 맞춰준다. 이 과정을 거치면 각각의 픽셀에 해당되는 이상치 점수를 얻을 수 있고, 해당 이상치 점수를 통해 이상치 위치 식별을 한다.

[0041] 이상에서 본 발명에 대하여 그 바람직한 실시예를 중심으로 설명하였으나, 이는 단지 예시일 뿐 본 발명을 한정하는 것이 아니며, 본 발명이 속하는 분야의 통상의 지식을 가진 자라면 본 발명의 본질적인 특성을 벗어나지 않는 범위에서 이상에 예시되지 않은 여러 가지의 변형과 응용이 가능함을 알 수 있을 것이다. 그리고, 이러한 변형과 응용에 관계된 차이점들은 첨부된 청구 범위에서 규정하는 본 발명의 범위에 포함되는 것으로 해석되어야 할 것이다.

부호의 설명

[0042] 1 : 이상 탐지 시스템

2 : 메모리 뱅크

3 : 학습 시스템

4 : 추론 시스템

20 : 네트워크 학습 모듈

22 : 서브 샘플링 모듈

200 : Teacher Network

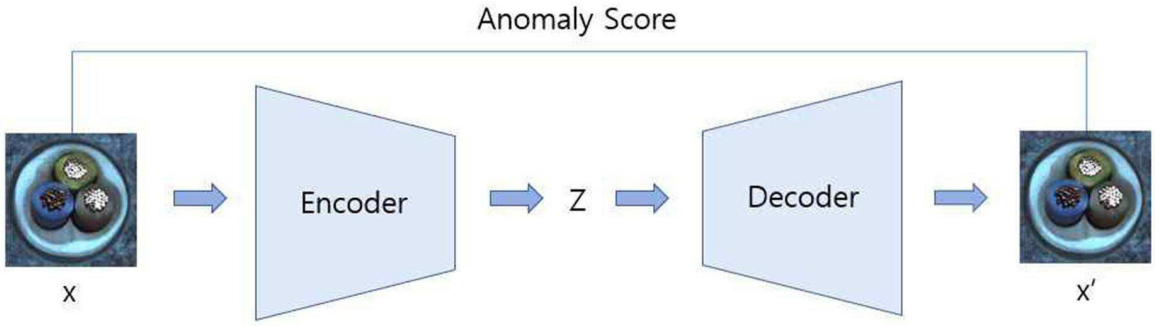
210 : 특징 벡터 연결 레이어

220 : 임베딩 레이어

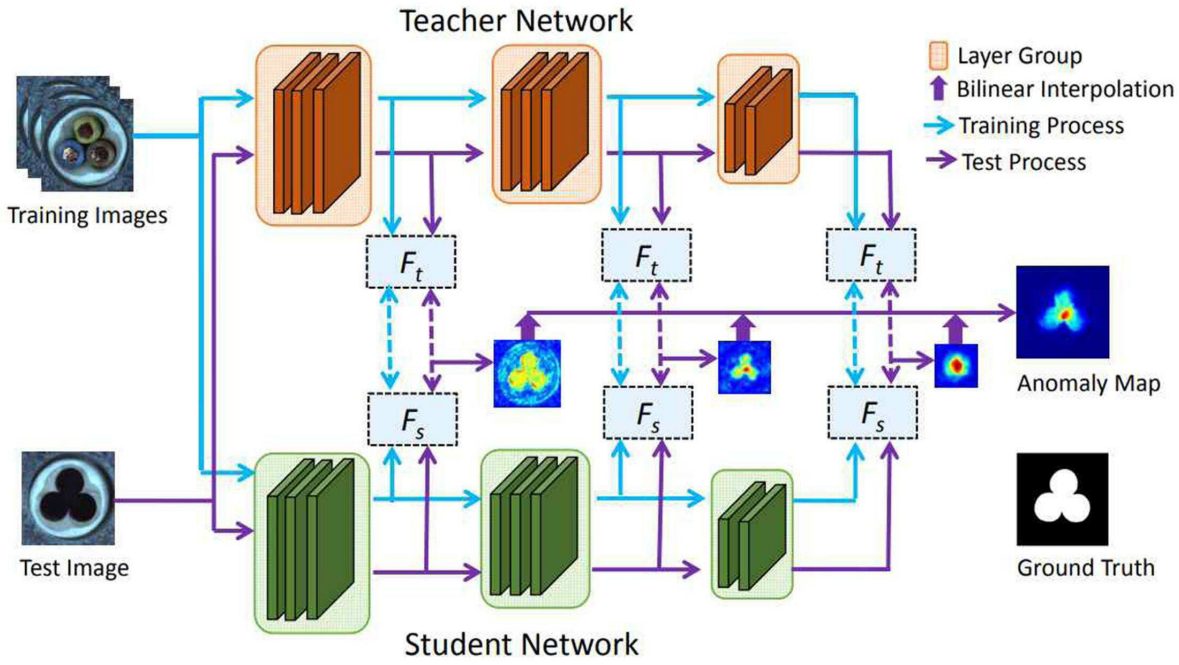
230 : Student Network

도면

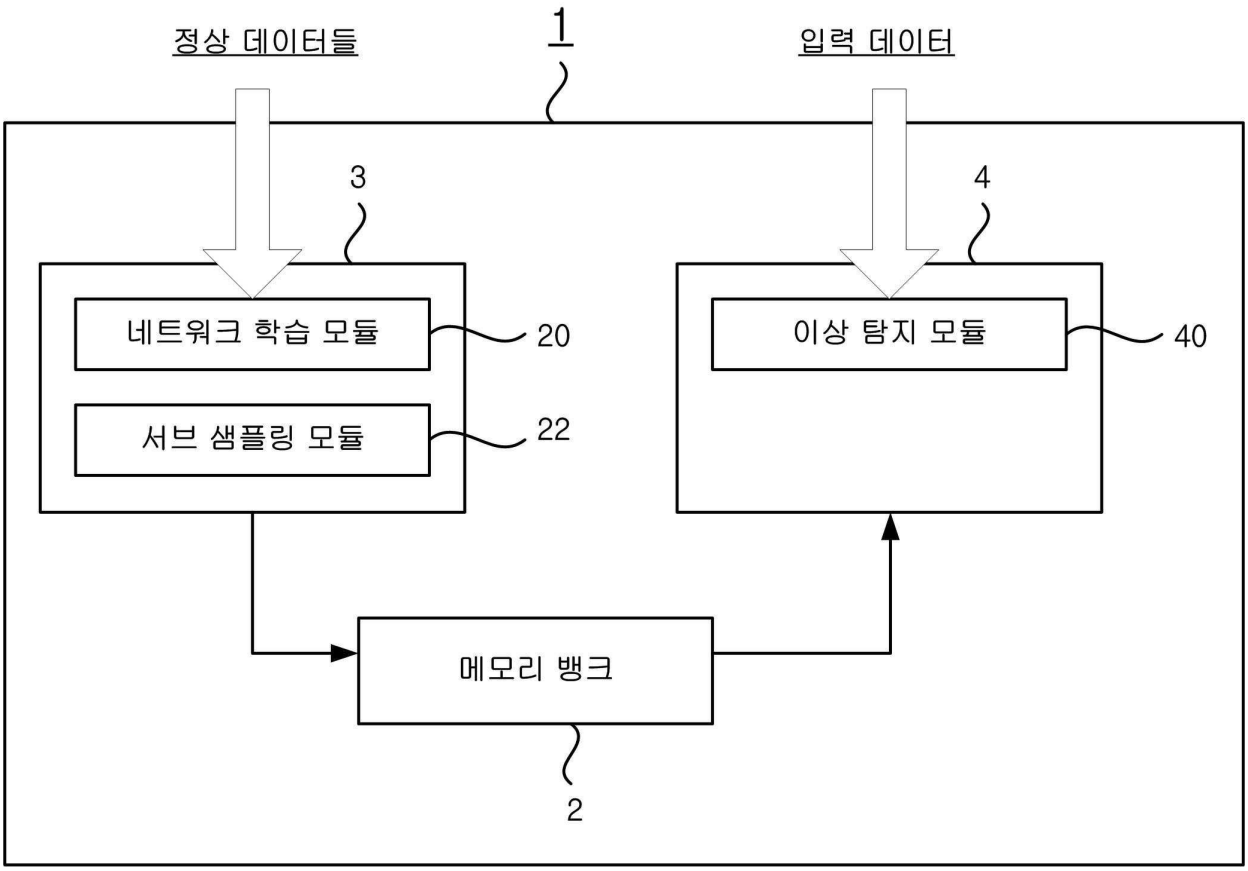
도면1


Anomaly Score
Encoder
Z
Decoder
X
X′

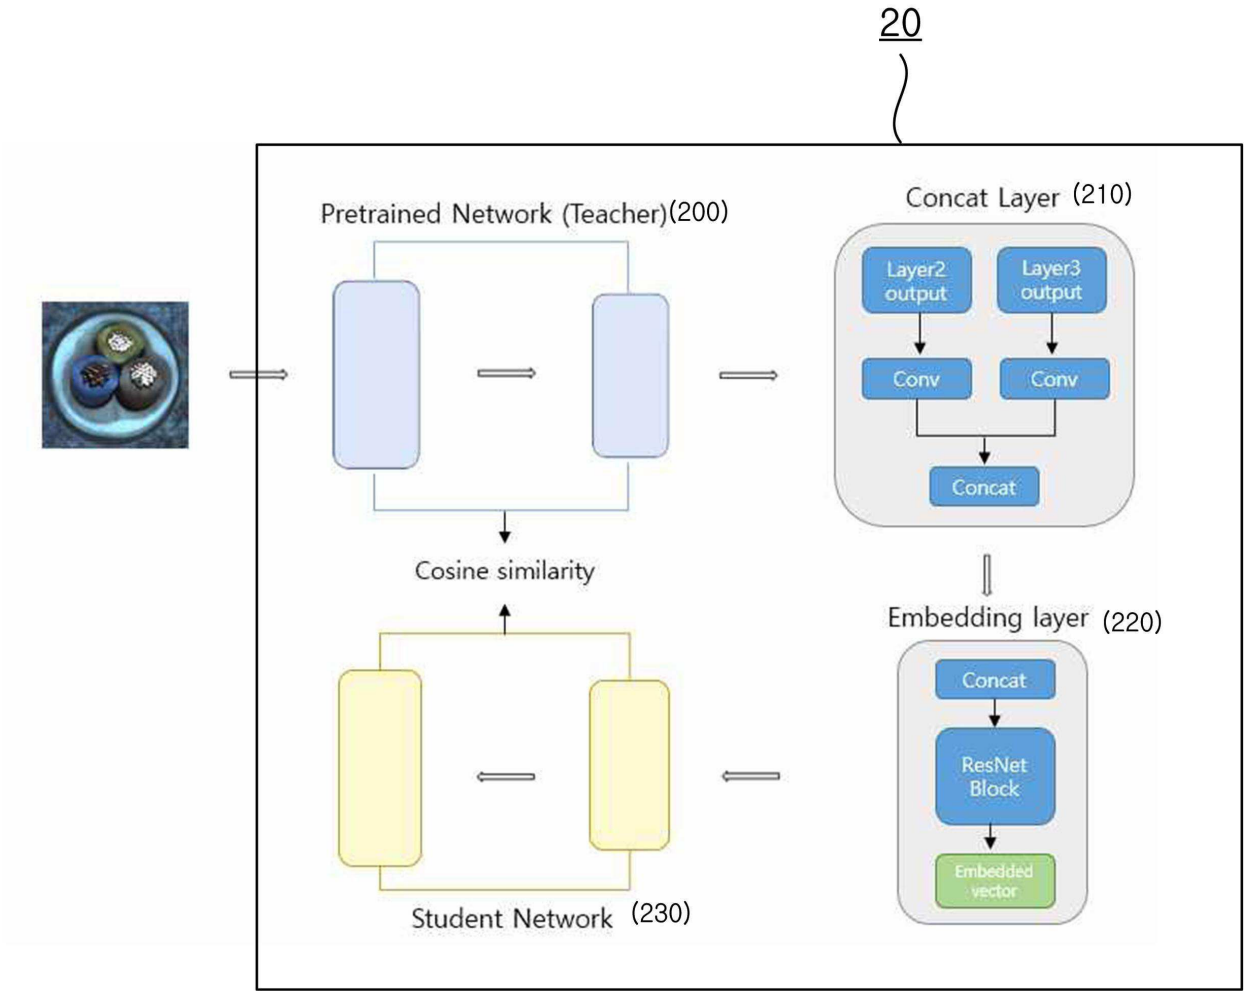
도면2


Teacher Network
Layer Group
Bilinear Interpolation
Training Process
Test Process
Training Images
F_t
F_s
Anomaly Map
Test Image
Ground Truth
Student Network

도면3



도면4


20
Pretrained Network (Teacher)(200)
Concat Layer (210)
Layer2 output
Layer3 output
Conv
Conv
Concat
Cosine similarity
Embedding layer (220)
Concat
ResNet Block
Embedded vector
Student Network (230)

도면5

Algorithm 1. Coreset Memory Bank

Input : Trained Student-Teacher network ϕ, nominal data X_n, coreset target t, random linear projection ψ

Output : Patch-level Memory bank M.

$M \rightarrow \{\ \}$

for $x_i \in X_N$ **do**

$M \leftarrow M \cup \phi(x_i)$

end

Apply greedy coreset selection

$M_C \leftarrow \{\ \}$

for $i \in [0, \ldots, l-1]$ **do**

$m_i \leftarrow \underset{m \in M - M_C}{\arg\max} \underset{n \in M_C}{\min} \| \psi(m) - \psi(n) \|_2$

$M_C \leftarrow M_C \cup \{m_i\}$

end for

$M \leftarrow M_C$