

특 허 출 원 서

출원인 관리번호 : PT20210167

대리인 참조번호 : DPP20212269KR

출원번호	10-2021-0097234	심사청구
출원일자	2021년 7월 23일	유
발명의 명칭	다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법	

독립항	2
종속항	14
명세서	24
도 수	9

출원인	국방과학연구소, 광주과학기술원
발명자	박진태, 이흥노, 강주성, 이창윤

유미특허법인

관인생략

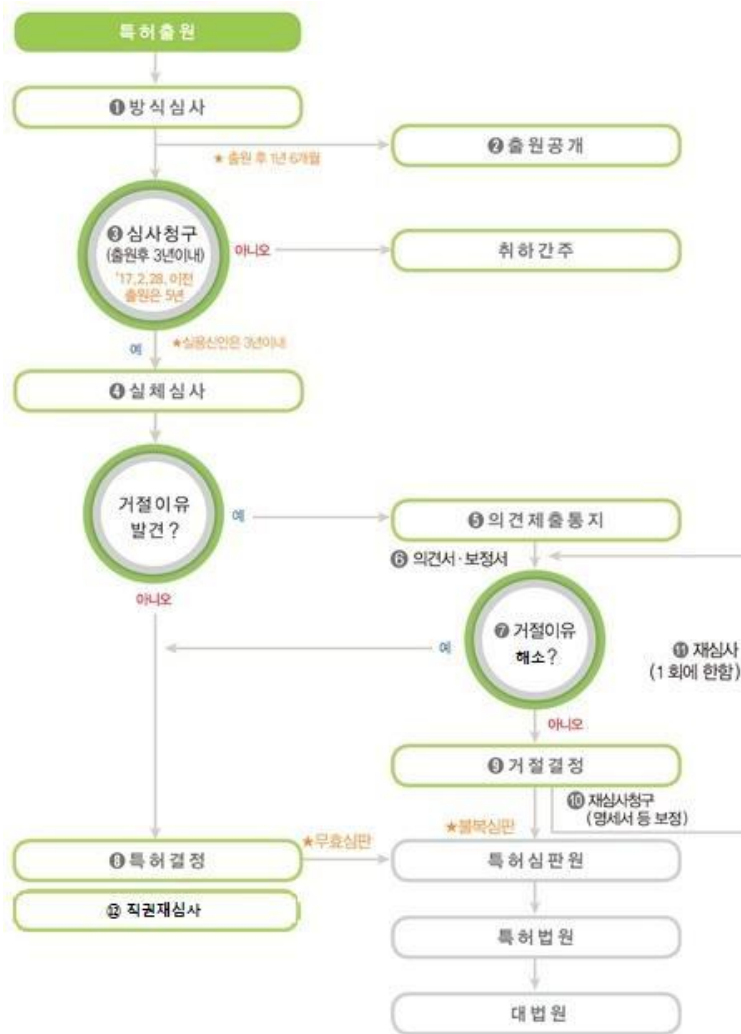
출원번호통지서

출원일자 2021.07.23
특기사항 심사청구(유) 공개신청(무) 참조번호(2269)
출원번호 10-2021-0097234 (접수번호 1-1-2021-0855232-13)
(DAS접근코드73F0)
출원인명칭 국방과학연구소(3-1998-005826-2) 외 1명
대리인성명 유미특허법인(9-2001-100003-6)
발명자성명 박진태 이흥노 강주성 이창윤
발명의명칭 다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법

특 허 청 청 장

<< 안내 >>

1. 귀하의 출원은 위와 같이 정상적으로 접수되었으며, 이후의 심사 진행상황은 출원번호를 이용하여 특허로 홈페이지(www.patent.go.kr)에서 확인하실 수 있습니다.
2. 출원에 따른 수수료는 접수일로부터 다음날까지 동봉된 납입영수증에 성명, 납부자번호 등을 기재하여 가까운 은행 또는 우체국에 납부하여야 합니다.
※ 납부자번호 : 0131(기관코드) + 접수번호
3. 귀하의 주소, 연락처 등의 변경사항이 있을 경우, 즉시 [특허고객번호 정보변경(경정), 정정신고서]를 제출하여야 출원 이후의 각종 통지서를 정상적으로 받을 수 있습니다.
4. 기타 심사 절차(제도)에 관한 사항은 특허청 홈페이지를 참고하시거나 특허고객상담센터(☎ 1544-8080)에 문의하여 주시기 바랍니다.
※ 심사제도 안내 : <http://www.kipo.go.kr>-지식재산제도



【우편번호】 34060

【주소】 대전광역시 유성구 북유성대로488번길 160(수남동)

【발명자】

【성명】 이흥노

【성명의 영문표기】 LEE, HEUNGNO

【우편번호】 61005

【주소】 광주광역시 북구 첨단과기로 123(오룡동)

【발명자】

【성명】 강주성

【성명의 영문표기】 KANG, JUSUNG

【주민등록번호】 880614-*XXXXXX

【우편번호】 61005

【주소】 광주광역시 북구 첨단과기로 123(오룡동)

【발명자】

【성명】 이창윤

【성명의 영문표기】 LEE, CHANGYUN

【주민등록번호】 930706-*XXXXXX

【우편번호】 01423

【주소】 서울특별시 도봉구 덕릉로 371, 101동 404호 (창동, 대우그
린아파트)

【출원언어】 국어

【심사청구】 청구

【공지예외적용대상증명서류의 내용】**【공개형태】** 논문발표**【공개일자】** 2021. 02. 17**【취지】** 위와 같이 특허청장에게 제출합니다.

대리인 유미특허법인 (서명 또는 인)

【수수료】**【출원료】** 0 면 46,000 원**【가산출원료】** 32 면 0 원**【우선권주장료】** 0 건 0 원**【심사청구료】** 16 항 847,000 원**【합계】** 893,000 원**【감면사유】** 공공연구기관(50%감면)[2]**【감면후 수수료】** 446,500 원**【수수료 자동납부번호】** 064-059182-01-018**【첨부서류】** 1. 공지예외적용대상(신규성상실의예외, 출원시의특례)규정을 적용받기 위한 증명서류_1통 2. 위임장[광주과학기술원]_1통

【발명의 설명】

【발명의 명칭】

다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법
 {MULTI-LABEL OUTLIER DETECTION METHOD AND SIGNAL EMITTER IDENTIFICATION MODEL
 EXTENSION METHOD}

【기술분야】

【0001】 본 발명은 다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법에 관한 것으로 더욱 상세하게는 무선 핑거프린팅 기술의 실사용을 위한 다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법에 관한 것이다.

【발명의 배경이 되는 기술】

【0002】 무선 핑거프린팅(Radio Frequency(RF) fingerprinting)이란 수신된 전파 신호 속에서 시그널 핑거프린트(Signal Fingerprint, SF)를 찾아 분석하여 수신 신호가 어떤 신호 송출원으로부터 발생되었는지를 식별하는 기술이다.

【0003】 무선 핑거프린팅 기술은 주어진 송출원으로부터 수집된 학습 데이터를 이용한 분류 문제(classification problem)로 모델링될 수 있다. 분류 문제는 별 다른 예외 조치를 인가하지 않는 이상 주어진 입력에 대해 학습한 송출원 중 1개로 무조건 판별하게 되며, 이는 비학습 데이터가 입력될 경우 잘못된 사용자 정보로 판별할 수 있는 위험성이 존재한다.

【0004】 일반적인 무선 핑거프린팅 기술은 통신 규격에 있어서 물리 계층에서의 보안 시스템에 주로 사용된다. 물리 계층에서의 전파 신호만을 가지고 신호 송출원을 추가 식별함으로써 등록된 신호 송출원으로부터의 메시지만이 고려되는 것이다. 이때, 신뢰성 있는 무선 핑거프린팅 기술을 위해서는 학습용 데이터 세트(Dataset)를 올바르게 마련하는 일이 중요하다. 이 경우, 등록된 사용자 및 알고 있는 신호 송출원과 같은 협조적 사용자로부터의 학습용 데이터를 마련하는 일은 그리 어려운 일이 아니다. 하지만 미등록 사용자나 새로 생긴 신호 송출원과 같은 비협조적 사용자로부터의 데이터를 수집하는 과정은 결코 쉬운 일이 아니다. 특히, 비협조적 사용자가 악의적인 의도로 무선 핑거프린팅 기술을 이용하고자 할 경우, 본인을 등록된 사용자 중 1인으로 잘못 판단하게 할 수 있어 매우 큰 문제이며, 이에 대한 대응 방안이 반드시 필요하다.

【발명의 내용】

【해결하고자 하는 과제】

【0005】 신뢰성 있는 무선 핑거프린팅 기술을 마련하기 위한 구체적인 요소 기술으로써, 아웃라이어 검출(Outlier detection)(예를 들어, Out of Distribution, OoD) 기법 및 증분식 학습(Incremental learning) 기술이 필요하다. 아웃라이어 검출은 딥러닝(deep learning) 모델 내에 학습되지 않은 신호가 입력될 때 이를 검출하는 방법에 관한 것이며, 증분식 학습은 학습되지 않은 새로운 데이터 세트에 대한 재학습(Re-training) 방법에 관한 것이다.

【0006】아웃라이어 검출 및 증분식 학습 관련 연구가 활발히 수행되고 있으나, 두 주제를 하나의 시스템에서 다루는 통합 프레임워크에 대한 연구는 아직 제대로 이루어지지 않고 있다. 또한, 대부분 이미지에 대한 연구일 뿐 무선 신호를 타겟으로 다루는 무선 핑거프린팅 목적으로의 연구는 확인되지 않고 있다.

【0007】일반적인 아웃라이어 검출 기술이 지니는 기술적 문제점은 기존에 학습된 송출원에 포함되지 않는 데이터 샘플을 무조건 아웃라이어로 판별하는 것이다. 여기에 추가 분석을 수행하지 않기 때문에 검출된 아웃라이어 샘플은 무조건 동일한 아웃라이어 클래스로 판별되며, 이러한 아웃라이어 샘플을 이용한 증분식 학습을 수행할 경우 서로 다른 아웃라이어들 간의 구분이 불가능하게 된다. 아웃라이어들 간의 차이를 구별하고 싶을 경우, 첫 번째 시간대에는 첫 번째 아웃라이어 샘플만을 입력받아 검출된 아웃라이어 샘플로 모델 업데이트를 수행하고, 이후에 두 번째 아웃라이어 샘플이 입력되어야 한다. 3개의 아웃라이어 샘플을 구별하기 위해 최소 3번의 모델 업데이트 과정이 필요하다. 이는 무선 핑거프린팅 기술의 실사용에는 맞지 않는 환경 가정이 필요하다.

【0008】본 발명이 해결하고자 하는 기술적 과제는 비학습 데이터에 대한 예외 처리 방법으로 더욱 신뢰성 있는 무선 핑거프린팅 기술을 마련하기 위한 다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법을 제공함에 있다.

【0009】즉, 본 발명에서는 기존의 무선 핑거프린팅 기술은 진행하여 신호 송출원 식별 과정을 수행하고, 여기에 추가로 분류기 출력(classifier output)에

대한 아웃라이어 검출 과정을 수행해 기존의 학습된 송출원과 차이를 보이는 아웃라이어 샘플들을 식별하고, 식별된 아웃라이어 샘플을 이용한 재학습 과정을 통해 새로운 신호 송출원 정보를 학습할 수 있는 다중 레이블 아웃라이어 검출 방법 및 신호 송출원 식별 모델 확장 방법을 제공하고자 한다.

【과제의 해결 수단】

【0010】 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법은 무선 핑거프린트를 검출하는 분류기의 특징 벡터를 포함하는 입력 신호와 미리 학습된 클래스의 분포 간의 거리 값을 획득하는 단계, 상기 입력 신호가 상기 클래스의 분포에 포함되면 상기 클래스로 검출하는 단계, 및 상기 입력 신호가 상기 클래스의 분포에 기준값 이내로 인접하여 위치하면 클래스 유사 아웃라이어로 검출하는 단계를 포함한다.

【0011】 상기 입력 신호가 상기 클래스의 분포에 상기 기준값 이내로 인접하여 위치하지 않으면 완전 아웃라이어로 검출할 수 있다.

【0012】 상기 다중 레이블 아웃라이어 검출 방법은 상기 완전 아웃라이어를 새로운 다른 하나의 클래스로 분류하는 단계를 더 포함할 수 있다.

【0013】 상기 입력 신호와 상기 클래스의 분포 간의 마할하노비스 거리 값을 획득할 수 있다.

【0014】 상기 다중 레이블 아웃라이어 검출 방법은 상기 클래스 유사 아웃라이어를 새로운 하나의 클래스로 분류하는 단계를 더 포함할 수 있다.

【0015】 상기 클래스의 송출기와 상기 클래스 유사 아웃라이어는 동일한 타입으로 분류될 수 있다.

【0016】 본 발명의 다른 실시예에 따른 신호 송출원 식별 모델 확장 방법은 무선 핑거프린트를 검출하는 분류기의 특징 벡터를 포함하는 입력 신호가 미리 학습된 클래스의 분포에 기준값 이내에 인접하여 위치하는 클래스 유사 아웃라이어에 대한 제1 분기 노드를 생성하는 단계, 및 미세 조정을 이용한 증분식 학습으로 미리 학습된 모델에서의 마지막 계층에 속하는 가중치 연결을 재학습하는 단계를 포함한다.

【0017】 상기 신호 송출원 식별 모델 확장 방법은 상기 마지막 계층에서의 가중치 값을 제외한 나머지 계층에서의 가중치 값을 고정하고, 상기 마지막 계층에서의 가중치 연결을 무작위로 초기화하는 단계를 포함할 수 있다.

【0018】 상기 신호 송출원 식별 모델 확장 방법은 상기 마지막 계층의 바로 직전 계층에서의 가중치 연결을 추가로 학습하는 단계를 더 포함할 수 있다.

【0019】 상기 마지막 계층의 바로 직전 계층에서의 가중치 연결은 초기화되지 않고 증분식 학습률이 기존의 값에서 줄어서 사용될 수 있다.

【0020】 상기 신호 송출원 식별 모델 확장 방법은 상기 클래스 유사 아웃라이어를 새로운 하나의 클래스로 분류하는 단계를 더 포함할 수 있다.

【0021】 상기 클래스의 송출기와 상기 클래스 유사 아웃라이어는 동일한 타입으로 분류될 수 있다.

【0022】 상기 신호 송출원 식별 모델 확장 방법은 상기 입력 신호와 상기 클래스의 분포 간의 거리 값을 획득하는 단계, 및 상기 입력 신호가 상기 클래스의 분포에 상기 기준값 이내로 인접하여 위치하지 않으면 완전 아웃라이어로 검출하는 단계를 더 포함할 수 있다.

【0023】 상기 입력 신호와 상기 클래스의 분포 간의 마할하노비스 거리 값을 획득할 수 있다.

【0024】 상기 신호 송출원 식별 모델 확장 방법은 상기 완전 아웃라이어를 새로운 다른 하나의 클래스로 분류하는 단계를 더 포함할 수 있다.

【0025】 상기 신호 송출원 식별 모델 확장 방법은 상기 완전 아웃라이어에 대한 제2 분기 노드를 생성하는 단계를 더 포함할 수 있다.

【발명의 효과】

【0026】 기존의 학습된 송출원과 차이를 보이는 아웃라이어 샘플들에 대한 재학습 과정을 통해 새로운 신호 송출원 정보를 학습함으로써 더욱 신뢰성 있는 무선 핑거프린팅 기술을 제공할 수 있다.

【도면의 간단한 설명】

【0027】 도 1은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법을 설명하기 위한 특징 맵을 나타내는 예시도이다.

도 2는 본 발명의 일 실시예에 따른 아웃라이어에 대한 계층적 데이터 구조를 나타내는 예시도이다.

도 3은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출을 이용한 신호 송출원 식별 모델 확장 방법을 나타내는 예시도이다.

도 4는 아웃라이어 검출 과정을 간략히 나타낸 예시도이다.

도 5는 마할하노비스 거리(Mahalanobis Distance) 값 기반의 아웃라이어 검출 방법을 나타내는 예시도이다.

도 6은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법을 나타내는 흐름도이다.

도 7은 본 발명의 일 실시예에 따른 증분식 학습을 위한 미세 조정 프로세스를 나타내는 예시도이다.

도 8은 본 발명의 일 실시예에 따른 증분식 학습에서 마지막 계층의 미세 조정 과정을 나타내는 예시도이다.

도 9는 본 발명의 일 실시예에 따른 증분식 학습에서 마지막 계층의 바로 직전 계층의 미세 조정 과정을 나타내는 예시도이다.

【발명을 실시하기 위한 구체적인 내용】

【0028】 이하, 첨부한 도면을 참고로 하여 본 발명의 실시예들에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다. 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예들에 한정되지 않는다.

【0029】 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략하였으며, 명세서 전체를 통하여 동일 또는 유사한 구성요소에 대해서는 동일한 참조 부호를 붙이도록 한다.

【0030】 또한, 명세서 전체에서, 어떤 부분이 어떤 구성요소를 "포함" 한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.

【0031】 이하, 도 1 및 2를 참조하여 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법에 대하여 설명한다.

【0032】 도 1은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법을 설명하기 위한 특징 맵을 나타내는 예시도이다. 도 2는 본 발명의 일 실시예에 따른 아웃라이어에 대한 계층적 데이터 구조를 나타내는 예시도이다.

【0033】 도 1 및 2를 참조하면, 단일 레이블 아웃라이어 검출 과정에서는 무선 핑거프린트를 검출하는 분류기의 분류기 출력 벡터(classifier output vector) 간의 수치적 거리 값을 기준으로 학습 분포에 포함되는지 여부만을 판단하고 있다. 이에 따라, 단일 레이블 아웃라이어 검출 과정에서는 단순히 아웃라이어 판별만이 수행된다.

【0034】 본 발명의 실시예에 따른 다중 레이블 아웃라이어 검출 방법은 아웃라이어 판별을 수행할 뿐만 아니라 아웃라이어 간의 거리, 학습 샘플 간의 거리, 아웃라이어 샘플 간의 거리 등을 추가로 측정하여 아웃라이어 타입 분석을 수행할

수 있다. 이를 다중 레이블 아웃라이어 검출이라 한다.

【0035】 다중 레이블 아웃라이어 검출에서는 샘플 간의 거리를 측정하기 위해, 모집단 분포와의 통계적 거리를 측정하는 마할라노비스 거리(Mahalanobis Distance, MD)를 사용할 수 있다. 다만, 샘플 간의 거리를 올바르게 측정할 수 있으면 유클리드 거리(Euclidean distance), 코사인 거리(cosine distance) 등이 이 용되어도 상관없다. 여기서 중요한 점은 비슷한 송출원 타입에서 송출된 전파 신호는 특징 맵(feature map)에서도 가까이 분포한다는 점이다.

【0036】 예를 들어, 도 1에 예시한 바와 같이, 특징 맵에서 제1 타입의 송출기와 제1 타입 유사 아웃라이어가 가까이 분포하고, 제2 타입의 송출기와 제2 타입 유사 아웃라이어가 가까이 분포하며, 어디에도 유사하지 않은 완전 아웃라이어(totally outlier)는 제1 타입의 송출기 및 제2 타입의 송출기와 멀리 분포하게 된다. 이를 바탕으로 아웃라이어 샘플 및 학습 샘플 간의 추가적인 거리를 계산할 경우, 도 1과 같이 제1 타입 유사 아웃라이어와 제2 타입 유사 아웃라이어와 같은 추가적인 정보 분석이 가능해진다. 이론적으로는 N개의 신호 송출원이 미리 학습된 분류기에 대해, N+1 종류의 아웃라이어 타입 분석이 추가로 가능하게 된다.

【0037】 이를 바탕으로 도 2에 예시한 바와 같이, 아웃라이어이지만 비슷한 타입으로의 계층적 데이터 구조(hierarchical data structure)가 구성될 수 있다. 예시한 바와 같이, 제1 타입의 송출기와 제1 타입 유사 아웃라이어(제1 아웃라이어)가 동일한 제1 타입으로 분류되고, 제2 타입의 송출기와 제2 타입 유사 아웃라이어(제2 아웃라이어)가 동일한 제2 타입으로 분류되고, 완전 아웃라이어(제

3 아웃라이어)가 최종적으로 아웃라이어로 분류될 수 있다. 즉, 다중 레이블 아웃라이어 검출에 의해 단 1번의 모델 업데이트로 다수의 아웃라이어들을 구별할 수 있다.

【0038】 이하, 도 3 내지 9를 참조하여 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출을 이용한 신호 송출원 식별 모델 확장 방법에 대하여 설명한다.

【0039】 도 3은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출을 이용한 신호 송출원 식별 모델 확장 방법을 나타내는 예시도이다.

【0040】 도 3을 참조하면, 다중 레이블 아웃라이어 검출을 이용한 신호 송출원 식별 모델 확장 방법은 분류기 학습(초기 학습)(Classifier Training) 과정, 아웃라이어 검출(추출)(outlier Detection) 과정 및 모델 확장(Model extension)(신경망 재학습) 과정을 포함한다.

【0041】 분류기 학습 과정은 일반적인 분류기 학습 모델 구축 과정을 의미한다. 즉, 본 발명의 실시예에서 분류기 학습 과정은 기존에 구비된 신호 송출원에 대한 학습 데이터 세트를 이용하여 무선 핑거프린팅 기술을 구현하는 과정이라 할 수 있다. 여기서는 설명을 위해 2개의 학습 신호 송출원(Class1, Class2)을 가정하고 있다.

【0042】 아웃라이어 검출 과정은 학습된 분류기(Trained CNN(Convolutional Neural Network))로부터 아웃라이어를 검출하는 과정이다. 아웃라이어 검출(추출)

과정에 대해서는 도 4를 예로 들어 설명한다. 도 4는 아웃라이어 검출 과정을 간략히 나타낸 예시도이다.

【0043】 도 4는 미리 학습된 2개의 신호 송출원(Class1, Class2)을 기준으로 아웃라이어를 검출할 수 있는 간단한 검출 방법을 나타내고 있다. 도 4에서 x 는 검출을 위한 특징 벡터(feature vector)이다. 여기서는 편의상 특징 벡터를 1차원으로 나타내었으며, 특징 벡터는 분류기 출력 벡터에서의 타겟 클래스(target class) k 에 대한 인덱스 값(index value)이라고 할 수 있다. 이때, 잘 학습된 분류기라면, x 값은 타겟 클래스 k 를 의미하는 특정 기준 값 μ_k 를 기준으로 가우시안(Gaussian) 분포를 따르게 된다. 즉, 정당한 사용자로부터의 신호라면 x 값은 가우시안 분포에 따라 $\mu_k \pm 3\sigma_k$ 사이의 값이 될 것이고, 비학습 데이터일 경우 그 범위 밖에 존재하게 될 것이다. 따라서 도 4를 기준삼는 아웃라이어 검출 방법은 다음의 수학적 식 1과 같이 나타낼 수 있다.

【0044】 【수학적 식 1】

$$\begin{aligned} \text{Class1} &:= \text{If}(\mu_1 - 3\sigma_1 < x < \mu_1 + 3\sigma_1) \\ \text{Class2} &:= \text{If}(\mu_2 - 3\sigma_2 < x < \mu_2 + 3\sigma_2) \\ \text{Outliers} &:= \text{If}(\text{else}) \end{aligned}$$

【0045】 즉, 분류기의 출력 벡터에서의 인덱스 값을 특징 벡터로 삼아 특징 벡터 x 가 미리 학습된 신호 송출원(Class1, Class2)의 가우시안 분포의 범위 내에

존재하는지 여부로 아웃라이어 검출(추출)이 수행될 수 있다.

【0046】 다른 실시예에 따른 아웃라이어 검출(추출) 과정에 대해서 도 5를 예로 들어 설명한다. 도 5는 마할하노비스 거리(Mahalanobis Distance) 값 기반의 아웃라이어 검출 방법을 나타내는 예시도이다.

【0047】 도 5를 참조하면, 마할하노비스 거리(Mahalanobis Distance, MD) 값 기반의 아웃라이어 검출 방법은 학습된 클래스에 대한 모집단과의 통계적 거리(statistical distance)를 측정하는 마할하노비스 거리(MD)를 특징 벡터로 결정한다.

【0048】 마할하노비스 거리(MD)는 수학식 2와 같이 구할 수 있다.

【0049】 【수학식 2】

$$MD_{x|D} = \sqrt{(\bar{x} - \bar{\mu})^T S^{-1} (\bar{x} - \bar{\mu})}$$

【0050】 모집단 D가 주어졌을 때 평균 $\bar{\mu}$, 및 공분산 S를 통해 입력 신호 \bar{x} 와의 표준편차 값을 측정하는 방식으로서, 마할하노비스 거리(MD)는 입력 신호 \bar{x} 가 모집단 분포로부터 얼마나 떨어져 있는지를 측정하는 통계적 거리를 의미한다.

【0051】 도 5에 예시된 바와 같이, 테스트 샘플이 제1 클래스(Class1)에 속하는 경우 제1 클래스(Class1)의 분포 영역 안에 위치하게 될 것이고, 이로 인해 마할하노비스 거리(MD) 값은 작은 값을 나타내게 된다. 그리고 테스트 샘플이 제2

클래스(Class2)에 속하는 경우 제2 클래스(Class2)의 분포 영역 안에 위치하게 될 것이고, 이로 인해 마할하노비스 거리(MD) 값은 작은 값을 나타내게 된다. 반면, 테스트 샘플이 아웃라이어일 경우, 제1 클래스(Class1) 또는 제2 클래스(Class2)의 분포 영역 어느 곳에도 포함되지 않을 것이고, 마할하노비스 거리(MD) 값은 큰 값을 나타내게 된다. 이러한 접근 방식은 마할하노비스 거리(MD) 값을 측정하기 위해 타겟 클래스의 학습 분포도가 주어져야 한다. 따라서, 이론적으로는 학습된 신호 송출원 개수 k만큼의 특징 치수(feature dimension)가 형성되며, 입력 신호가 타겟 클래스 k에 포함되는지 확인하기 위해서는, 도 4의 방식과 유사하게, 입력 신호 \bar{x} 및 모집단 분포 D_k 가 주어졌을 때의 마할하노비스 거리(MD) 값이 가우시안 분포된 모집단 분포 D_k 의 영역 안에 포함되는지를 확인하여 아웃라이어를 검출할 수 있다. 마할하노비스 거리(MD) 값 기반의 아웃라이어 검출 방법은 수학적 식 3과 같이 나타낼 수 있다.

【0052】 【수학적 식 3】

$$\begin{aligned}
 \text{Class1} &:= \text{If}(\mu_{MD_{\text{Class1|Class1}}} - 3\sigma_{MD_{\text{Class1|Class1}}} < MD_{\text{test|Class1}} < \mu_{MD_{\text{Class1|Class1}}} + 3\sigma_{MD_{\text{Class1|Class1}}}) \\
 \text{Class2} &:= \text{If}(\mu_{MD_{\text{Class2|Class2}}} - 3\sigma_{MD_{\text{Class2|Class2}}} < MD_{\text{test|Class2}} < \mu_{MD_{\text{Class2|Class2}}} + 3\sigma_{MD_{\text{Class2|Class2}}}) \\
 \text{Outliers} &:= \text{If}(\text{else})
 \end{aligned}$$

【0053】 도 4 및 5의 아웃라이어 검출 과정은 학습된 클래스에 포함되지 않으면 모두 아웃라이어 샘플로 간주하는 단일 레이블 아웃라이어 검출(Single-label

outlier detection) 방법이라 할 수 있다.

【0054】 이하, 도 6을 참조하여 다중 레이블 아웃라이어 검출(Multi-label outlier detection) 방법에 대하여 설명한다. 도 6은 본 발명의 일 실시예에 따른 다중 레이블 아웃라이어 검출 방법을 나타내는 흐름도이다.

【0055】 도 6을 참조하면, 신호가 입력되면(S110), 신경망(예를 들어, 합성곱 신경망(CNN))은 학습된 클래스의 분포를 획득하고(S120), 학습된 클래스에 대한 마할하노비스 거리(MD)의 기준값을 획득할 수 있다(S130). 신경망은 입력 신호와 학습된 클래스의 분포 간의 마할하노비스 거리(MD) 값을 획득(산출)할 수 있다(S140).

【0056】 신경망은 입력 신호와 학습된 클래스의 분포 간의 마할하노비스 거리(MD) 값을 기반으로 입력 신호가 제1 클래스(C1)의 분포에 포함되는지 확인하고(S150), 입력 신호가 제1 클래스(C1)의 분포에 포함되면 제1 클래스로 검출한다(S151). 신경망은 입력 신호가 제1 클래스(C1)의 분포에 포함되지 않으면 입력 신호가 제2 클래스(C2)의 분포에 포함되는지 확인하고(S160), 입력 신호가 제2 클래스(C2)의 분포에 포함되면 제2 클래스로 검출한다(S161). 신경망은 입력 신호가 제2 클래스(C2)의 분포에 포함되지 않으면 입력 신호가 제1 클래스(C1)의 분포와 유사한지 확인하고(S170), 입력 신호가 제1 클래스(C1)의 분포와 유사하면 제1 클래스 유사 아웃라이어로 검출한다(S171). 신경망은 입력 신호가 제1 클래스(C1)의 분포와 유사하지 않으면 입력 신호가 제2 클래스(C2)의 분포와 유사한지 확인하고(S180), 입력 신호가 제2 클래스(C2)의 분포와 유사하면 제2 클래스 유사 아웃라이

어로 검출하고(S181), 신경망은 입력 신호가 제2 클래스(C2)의 분포와 유사하지 않으면 완전 아웃라이어로 검출한다(S182). 여기서 분포와 유사하다는 것은 특징 맵에서 분포에 포함되지 않지만 기준값 이내로 인접하여 위치함을 의미할 수 있다.

【0057】 상기의 입력 신호와 학습된 클래스의 분포 간의 마할하노비스 거리(MD) 값을 기반으로 입력 신호를 제1 클래스, 제2 클래스, 제1 클래스 유사 아웃라이어, 제2 클래스 유사 아웃라이어, 완전 아웃라이어 등으로 검출하는 방법은 수학적 식 4와 같이 나타낼 수 있다.

【0058】 【수학적 식 4】

$$\begin{aligned}
 \text{Class1} &:= \text{If}(\mu_{MD_{Class1|Class1}} - 3\sigma_{MD_{Class1|Class1}} < MD_{test|Class1} < \mu_{MD_{Class1|Class1}} + 3\sigma_{MD_{Class1|Class1}}) \\
 \text{Class2} &:= \text{If}(\mu_{MD_{Class2|Class2}} - 3\sigma_{MD_{Class2|Class2}} < MD_{test|Class2} < \mu_{MD_{Class2|Class2}} + 3\sigma_{MD_{Class2|Class2}}) \\
 \text{Outliers(Type1)} &:= \text{If}(|MD_{test|Class1} - \mu_{MD_{Class1|Class1}}| < 3\sigma_{MD_{Class1|Class1}} + Thr_{Class1}) \\
 \text{Outliers(Type2)} &:= \text{If}(|MD_{test|Class2} - \mu_{MD_{Class2|Class2}}| < 3\sigma_{MD_{Class2|Class2}} + Thr_{Class2}) \\
 \text{Outliers(Totally)} &:= \text{If}(\text{else})
 \end{aligned}$$

【0059】 이와 같이, 아웃라이어를 판별할 때 미리 학습된 분포도 $D_{Class-k}$ 의 중심점으로부터 일정 거리 이상 떨어져 있는지를 각 클래스의 기준값 $Thr_{Class-k}$ 를 통해 한번 더 판별함으로써, 단순히 아웃라이어만을 판별하는 것이 아니라 아웃라이어이지만 타입 k와 유사한 샘플임을 확인할 수 있다. 즉, 입력 신호가 클래스의 분포에 포함되지 않지만 기준값 $Thr_{Class-k}$ 이내로 인접하여 위치하면 클래스 유사 아웃라이어로 검출될 수 있다. 이에 따라, 아웃라이어 타입 분석을 수행하는 다중 레이

블 아웃라이어 검출이 가능하게 된다.

【0060】 이하, 도 7 내지 9를 참조하여 모델 확장(신경망 재학습) 과정에 대하여 설명한다. 모델 확장 과정은 다중 레이블 아웃라이어 검출에 의해 검출된 아웃라이어 데이터 세트를 이용하여 새로운 송출원을 재학습하는 증분식 학습(Incremental learning) 과정이다.

【0061】 도 7은 본 발명의 일 실시예에 따른 증분식 학습을 위한 미세 조정 프로세스를 나타내는 예시도이다. 도 8은 본 발명의 일 실시예에 따른 증분식 학습에서 마지막 계층의 미세 조정 과정을 나타내는 예시도이다. 도 9는 본 발명의 일 실시예에 따른 증분식 학습에서 마지막 계층의 바로 직전 계층의 미세 조정 과정을 나타내는 예시도이다.

【0062】 새로운 송출원을 재학습하는 증분식 학습은 미세 조정(Fine tuning) 방법으로 수행될 수 있다. 분류기 출력 계층에서 새로이 검출된 아웃라이어 각각에 대한 분기 노드(branch node)를 생성한 후, 재학습 과정을 통해 가중치(weight)를 학습할 수 있다. 아웃라이어 샘플에서의 레이블이 잘 정리되어 있는 경우, 재학습 과정은 미세 조정을 이용한 간단한 형태의 증분식 학습만으로도 충분히 효과를 볼 수 있다.

【0063】 도 7에 예시한 바와 같이, 미세 조정 과정을 통해 제1 클래스 유사 아웃라이어(Outlier 1)를 새로운 제3 클래스(Class 3)로 구별하고, 제2 클래스 유사 아웃라이어(Outlier 2)를 새로운 제4 클래스(Class 4)로 구별하고, 완전 아웃라이어(Outlier 3)를 새로운 제5 클래스(Class 5)로 구별할 수 있다.

【0064】 새로 검출된 클래스(예를 들어, 아웃라이어 샘플)에 대한 증분식 학습은 기존에 학습된 모델의 가중치를 재조정하여 새로운 클래스에 대한 특징을 학습하는 다양한 방법을 포함할 수 있다. 이러한 방법으로, 모든 가중치를 처음부터 재학습하는 'learning from sketch', 일부 목표 계층에서의 가중치만을 재조정하는 'fine tuning', 그리고 긍정적 샘플(positive sample)에서의 가중치 값을 비중 있게 업데이트하는 'reinforcement learning based fine tuning' 방법 등이 있다.

【0065】 도 8에 예시한 바와 같이, 미리 학습된 모델에서의 마지막 계층(출력 계층)에 속하는 가중치 연결(weight connection)만을 재학습하는 미세 조정 기반의 증분식 학습 방법을 사용할 수 있다. 여기서는 2개의 클래스에 대한 초기 학습을 가정하고 있다. 미리 학습된 모델의 출력 계층에서의 노드 수는 2개이고, 바로 직전의 FC2 계층에는 임의의 128개 노드가 배치되어 있다. 따라서 마지막 계층에는 128×2 개의 가중치 연결이 존재하며, 초기 학습 과정을 통해 학습된 가중치 값을 내포하게 된다.

【0066】 재학습을 위한 가중치 고정(weights freeze) 과정이 필요하다. 마지막 계층에서의 가중치 값을 제외한 나머지 계층에서의 가중치 값을 고정하고, 마지막 계층에서의 가중치 연결은 무작위로 초기화(randomly initialization)한다. 이때, 추가된 아웃라이어에 대한 제3 클래스, 제4 클래스 및 제5 클래스에 대한 반영을 위해 마지막 계층에서의 노드는 5개로 배치된다. 즉, 128×5 개의 가중치 연결이 새로 초기화하여 생성된다.

【0067】 앞서 설명한 수학적 식 4와 같은 아웃라이어 검출 방법을 통해 입력된 샘플 데이터에 대한 제1 아웃라이어, 제2 아웃라이어 및 제3 아웃라이어로 구분할 수 있고, 이는 샘플 데이터에 대한 레이블링(Labeling)이 수행된 것으로 간주할 수 있다. 즉, 제3 내지 제5 클래스의 새로운 클래스로 레이블된 증분식 학습용 학습 데이터 세트가 구성된 것이라 할 수 있다.

【0068】 이제, 증분식 학습률(η) 및 준비된 아웃라이어 데이터 세트를 이용하여 재학습 과정이 수행된다. 재학습 방법은 초기 학습 과정과 동일하게 수행될 수 있다. 재학습 과정은 아웃라이어 데이터 세트를 이용해 수행될 수 있으며, 교차 엔트로피 손실 함수(cross-entropy loss function) 및 아담 옵티마이저(adam optimizer)가 사용될 수 있다. 이때, 재학습 과정에서의 가중치 업데이트는 마지막 계층에서만 이루어진다. 이에 따라, 초기 학습 과정에서 2개의 클래스에 대한 특징 추출 능력은 그대로 유지하되, 추출된 특징에 대한 상관관계를 재학습함으로써 추가된 클래스에 대한 인증(identification) 과정을 학습할 수 있는 것으로 해석된다.

【0069】 도 9에 예시한 바와 같이, 미리 학습된 모델에서의 마지막 계층뿐만 아니라 바로 직전의 FC2 계층에서의 가중치 연결을 추가로 학습하는 증분식 학습 방법을 사용할 수 있다. 이때, FC2 계층에서의 가중치 연결을 추가로 학습할 때 가중치 초기화는 수행되지 않으며, 증분식 학습률은 기존의 값에서 1/10로 줄여 사용될 수 있다. 즉, FC2 계층은 초기 학습 결과의 가중치에 추가로 업데이트를 수행하

며, 마지막 계층에서의 가중치는 처음부터 재학습을 수행할 수 있다. 이러한 학습 방법은 새로 추가된 제3 내지 제5 클래스에서 새로 고려해야 할 수 있는 특징에 대한 내용을 학습하고, 그 상관관계를 새로 정립한다는 점에서, 도 8의 재학습 방법 보다 강건한(robust) 미세 조정 방법이라 할 수 있다.

【0070】 본 발명의 실시예에 따른 다중 레이블 아웃라이어 검출 방법 및 이를 이용한 신호 송출원 식별 모델 확장 방법은 하드웨어나 소프트웨어, 또는 하드웨어와 소프트웨어의 결합으로 구현될 수 있다. 예를 들어, 다중 레이블 아웃라이어 검출 방법 및 이를 이용한 신호 송출원 식별 모델 확장 방법의 적어도 일부는 집적회로(IC)와 같이 하드웨어적으로 구현되거나, 컴퓨터 프로그램과 같이 소프트웨어적으로 구현되거나, 또는 컴퓨터 프로그램이 기록된 기록매체와 같이 하드웨어와 소프트웨어의 결합으로 구현될 수 있다.

【0071】 본 발명의 실시예는 기본적으로 앞서 개발된 무선 핑거프린팅 기술을 실제 전자전 환경에서 사용하기 위해 고려해야 하는 어려운 환경들에 대처하기 위한 것이다. 본 발명의 실시예에 따른 다중 레이블 아웃라이어 검출 방법 및 이를 이용한 신호 송출원 식별 모델 확장 방법은 아웃라이어에 대한 추가적인 분석을 수행할 수 있으며, 이는 전자전 환경에서 최대한 다양한 정보 분석을 수행해야 하는 시긴트(SIGINT, signal intelligence) 목적에서 큰 이득이라 할 수 있다.

【0072】 또한, 본 발명의 실시예에 따른 다중 레이블 아웃라이어 검출 방법 및 이를 이용한 신호 송출원 식별 모델 확장 방법은 사물인터넷(Internet of Things, IoT) 환경에서의 물리 계층 인증 시스템에서의 신뢰성을 향상시킬 수

있다. 최근 수많은 무선 장치가 존재하는 IoT 환경에서의 보안 문제가 대두되고 있다. 키 기반 접근(Key based approach)을 이용하는 MAC 계층에서의 보안 방식으로는 무선 장치의 수를 감당할 수 없는 지경에 이르고 있다. 이를 보완하기 위해 물리 계층에서의 보안 문제를 다루는 개별 인증 방법(Specific Identification method)이 주목받고 있으며, 무선 핑거프린팅이 적용될 수 있다. 본 발명의 실시예를 통해 무선 핑거프린팅 기술의 비학습 데이터 처리의 신뢰성을 향상시킬 수 있으며, 이는 IoT 환경에서의 보다 완벽한 보안 시스템 구축에 큰 도움을 줄 수 있다.

【0073】 그리고, 본 발명의 실시예에 따른 다른 다중 레이블 아웃라이어 검출 방법 및 이를 이용한 신호 송출원 식별 모델 확장 방법은 무선 신호 외에도 이미지, 음성신호 등 다양한 신호에 대한 딥러닝 모델 업데이트에 적용될 수 있으며, 비학습 데이터 처리 방법에 대한 새로운 방향을 제시함으로써 사람의 도움 없이도 새로운 클래스들을 효율적으로 학습할 수 있는 강인한 인공지능에 큰 영향을 줄 수 있다.

【0074】 지금까지 참조한 도면과 기재된 발명의 상세한 설명은 단지 본 발명의 예시적인 것으로서, 이는 단지 본 발명을 설명하기 위한 목적에서 사용된 것이지 의미 한정이나 특허청구범위에 기재된 본 발명의 범위를 제한하기 위하여 사용된 것은 아니다. 그러므로 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시 예가 가능하다는 점을 이해할 것이다. 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 특허청구범위의 기술적 사상에 의해 정해져야 할 것이다.

【청구범위】

【청구항 1】

무선 핑거프린트를 검출하는 분류기의 특징 벡터를 포함하는 입력 신호와 미리 학습된 클래스의 분포 간의 거리 값을 획득하는 단계;

상기 입력 신호가 상기 클래스의 분포에 포함되면 상기 클래스로 검출하는 단계; 및

상기 입력 신호가 상기 클래스의 분포에 기준값 이내로 인접하여 위치하면 클래스 유사 아웃라이어로 검출하는 단계를 포함하는 다중 레이블 아웃라이어 검출 방법.

【청구항 2】

제1 항에 있어서,

상기 입력 신호가 상기 클래스의 분포에 상기 기준값 이내로 인접하여 위치하지 않으면 완전 아웃라이어로 검출하는 다중 레이블 아웃라이어 검출 방법.

【청구항 3】

제2 항에 있어서,

상기 완전 아웃라이어를 새로운 다른 하나의 클래스로 분류하는 단계를 더 포함하는 다중 레이블 아웃라이어 검출 방법.

【청구항 4】

제1 항에 있어서,

상기 입력 신호와 상기 클래스의 분포 간의 마할하노비스 거리 값을 획득하는 다중 레이블 아웃라이어 검출 방법.

【청구항 5】

제1 항에 있어서,

상기 클래스 유사 아웃라이어를 새로운 하나의 클래스로 분류하는 단계를 더 포함하는 다중 레이블 아웃라이어 검출 방법.

【청구항 6】

제1 항에 있어서,

상기 클래스의 송출기와 상기 클래스 유사 아웃라이어는 동일한 타입으로 분류되는 다중 레이블 아웃라이어 검출 방법.

【청구항 7】

무선 핑거프린트를 검출하는 분류기의 특징 벡터를 포함하는 입력 신호가 미리 학습된 클래스의 분포에 기준값 이내에 인접하여 위치하는 클래스 유사 아웃라이어에 대한 제1 분기 노드를 생성하는 단계; 및

미세 조정을 이용한 증분식 학습으로 미리 학습된 모델에서의 마지막 계층에 속하는 가중치 연결을 재학습하는 단계를 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 8】

제7 항에 있어서,

상기 마지막 계층에서의 가중치 값을 제외한 나머지 계층에서의 가중치 값을 고정하고, 상기 마지막 계층에서의 가중치 연결을 무작위로 초기화하는 단계를 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 9】

제7 항에 있어서,

상기 마지막 계층의 바로 직전 계층에서의 가중치 연결을 추가로 학습하는 단계를 더 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 10】

제9 항에 있어서,

상기 마지막 계층의 바로 직전 계층에서의 가중치 연결은 초기화되지 않고 증분식 학습률이 기존의 값에서 줄어서 사용되는 신호 송출원 식별 모델 확장 방법.

【청구항 11】

제7 항에 있어서,

상기 클래스 유사 아웃라이어를 새로운 하나의 클래스로 분류하는 단계를 더 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 12】

제7 항에 있어서,

상기 클래스의 송출기와 상기 클래스 유사 아웃라이어는 동일한 타입으로 분

류되는 신호 송출원 식별 모델 확장 방법.

【청구항 13】

제7 항에 있어서,

상기 입력 신호와 상기 클래스의 분포 간의 거리 값을 획득하는 단계; 및

상기 입력 신호가 상기 클래스의 분포에 상기 기준값 이내로 인접하여 위치하지 않으면 완전 아웃라이어로 검출하는 단계를 더 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 14】

제13 항에 있어서,

상기 입력 신호와 상기 클래스의 분포 간의 마할하노비스 거리 값을 획득하는 신호 송출원 식별 모델 확장 방법.

【청구항 15】

제13 항에 있어서,

상기 완전 아웃라이어를 새로운 다른 하나의 클래스로 분류하는 단계를 더 포함하는 신호 송출원 식별 모델 확장 방법.

【청구항 16】

제13 항에 있어서,

상기 완전 아웃라이어에 대한 제2 분기 노드를 생성하는 단계를 더 포함하는 신호 송출원 식별 모델 확장 방법.

【요약서】**【요약】**

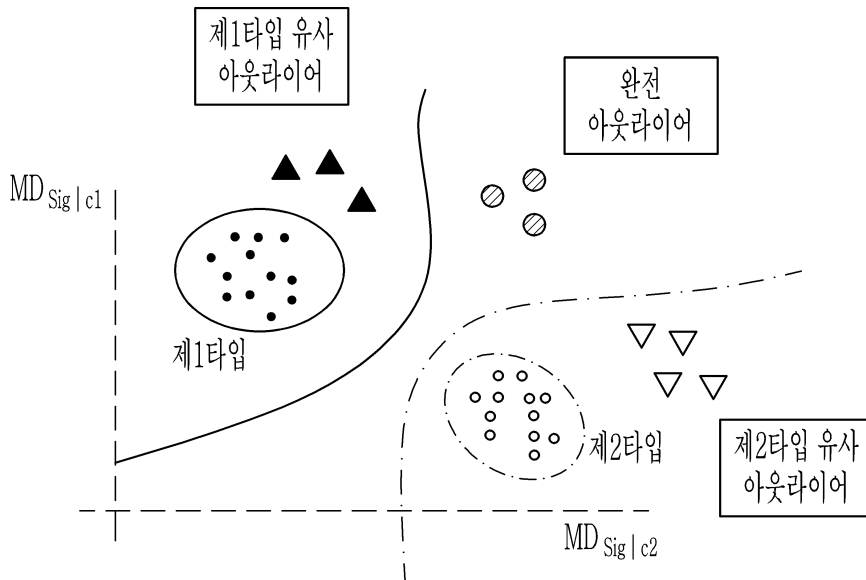
다중 레이블 아웃라이어 검출 방법은 무선 핑거프린트를 검출하는 분류기의 특징 벡터를 포함하는 입력 신호와 미리 학습된 클래스의 분포 간의 거리 값을 획득하는 단계, 상기 입력 신호가 상기 클래스의 분포에 포함되면 상기 클래스로 검출하는 단계, 및 상기 입력 신호가 상기 클래스의 분포에 기준값 이내로 인접하여 위치하면 클래스 유사 아웃라이어로 검출하는 단계를 포함한다.

【대표도】

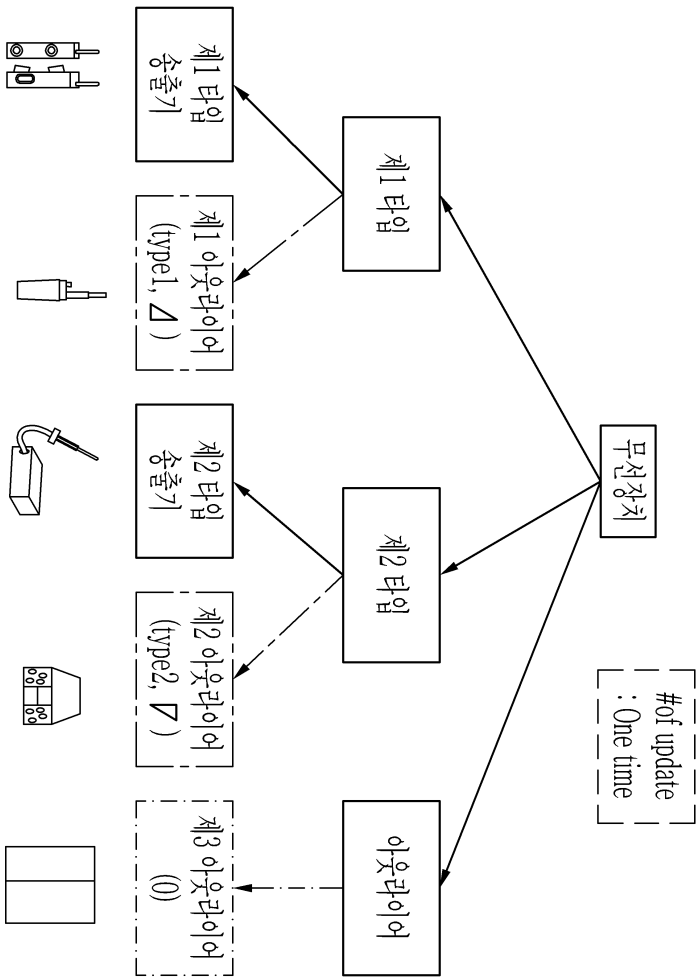
도 1

【도면】


【도 1】



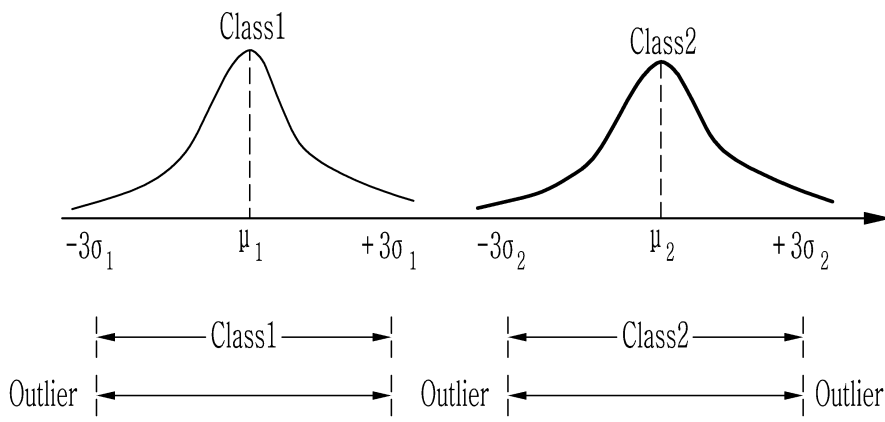
【도 2】



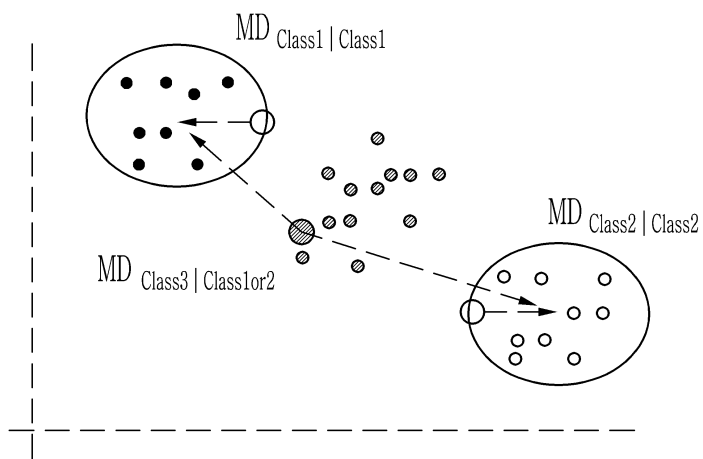
【표 3】




【도 4】




【도 5】



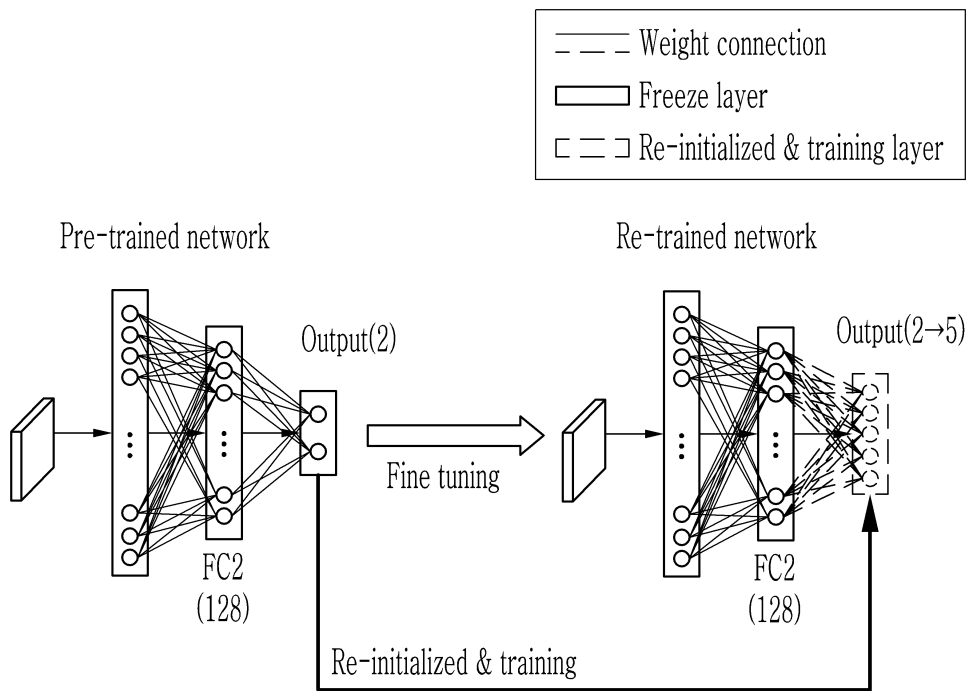
【도 6】



【도 7】



【도 8】



【도 9】

