(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0080480
(43) 공개일자 2024년06월07일

(51) 국제특허분류(Int. Cl.)
G06V 10/774 (2022.01) *G06N 20/00* (2019.01)
G06V 10/764 (2022.01) *G06V 20/70* (2022.01)
(52) CPC특허분류
G06V 10/7753 (2023.08)
G06N 20/00 (2021.08)
(21) 출원번호 10-2022-0163873
(22) 출원일자 2022년11월30일
심사청구일자 2022년11월30일

(71) 출원인
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
백성욱
서울특별시 강남구 영동대로 22, 813동 1303호(일원동, 디에이치 자이 개포)
이미영
서울특별시 강남구 학동로82길 6(삼성동, 삼성리치빌)
(뒷면에 계속)
(74) 대리인
특허법인위더피플

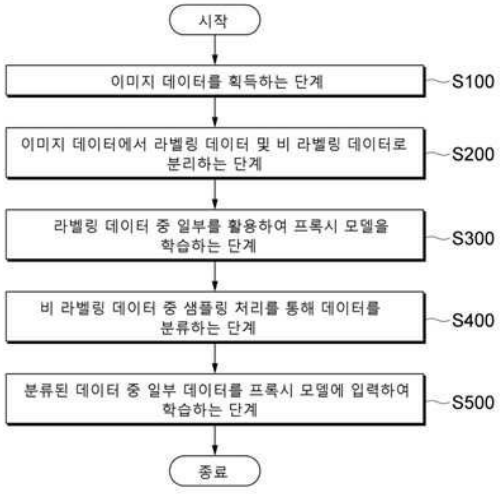
전체 청구항 수 : 총 14 항

(54) 발명의 명칭 **비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법 및 그 장치**

(57) 요 약

본 발명은 이미지 분류 장치에 의해 수행되는 방법에 있어서, 이미지 분류가 필요한 이미지 데이터를 획득하는 단계, 이미지 데이터에서 라벨링 데이터 및 비 라벨링 데이터로 분류하는 단계, 라벨링 데이터 중 일부를 활용하여 프록시 모델을 학습하는 단계, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계, 및 분류된 비 라벨링 데이터 중 일부 데이터를 프록시 모델에 입력하여 학습하는 단계를 포함하는 비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법 및 그 장치에 관한 것이다.

대 표 도 - 도2



(52) CPC특허분류
G06V 10/764 (2023.08)
G06V 20/70 (2023.08)
(72) 발명자
아바스 칸
서울특별시 광진구 능동로 209 세종대학교 대양AI 센터 411호
탄비어 후세인
서울특별시 광진구 능동로 209 세종대학교 대양AI 센터 411호
김민제
서울특별시 광진구 천호대로110길 83-5, 101호(능동, 에코빌)
이수민
경기도 안산시 단원구 선부로 166, 120동 509호(선부동, 공작한양아파트)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711159679
과제번호	2020-0-00062-003
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	sw컴퓨팅산업원천기술개발
연구과제명	이종 정보 활용 및 데이터 융합을 통한 데이터 증식 기술 개발
기 여 율	1/1
과제수행기관명	(주)와이즈넛
연구기간	2022.01.01 ~ 2022.12.31

명 세 서

청구범위

청구항 1

이미지 분류 장치에 의해 수행되는 방법에 있어서,

이미지 분류가 필요한 이미지 데이터를 획득하는 단계;

이미지 데이터에서 라벨링 데이터 및 비 라벨링 데이터로 분류하는 단계;

라벨링 데이터 중 일부를 활용하여 프록시 모델을 학습하는 단계;

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계; 및

분류된 비 라벨링 데이터 중 일부 데이터를 프록시 모델에 입력하여 학습하는 단계; 를 포함하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 2

제1항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 상기 샘플링 처리와 관련하여 신뢰도 임계값을 설정하는 단계를 더 포함하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 3

제2항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 비 라벨링 데이터 중 신뢰도가 미리 설정한 임계값 보다 낮은 제1 데이터를 분류하는 단계를 더 포함하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 4

제3항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 제1 데이터 제외한 제2 데이터를 프록시 모델에 입력하여, 프록시 모델을 학습하는 단계를 더 포함하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 5

제4항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 제1 데이터를 제외한 제2 데이터를 초기 이미지 데이터에 추가하는 단계를 더 포함하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 6

제5항에 있어서,

상기 프록시 모델은 적어도 하나 이상의 Max pooling layer와 적어도 4개 층으로 이루어진 CNN(Convolutional Neural Networks) layer로 이루어진

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 7

제6항에 있어서,

상기 프록시 모델은 Softmax function을 활성화 함수로 하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법.

청구항 8

프로세서;

네트워크 인터페이스;

메모리; 및

상기 메모리에 로드(Load)되고, 상기 프로세서에 의해 실행되는 컴퓨터 프로그램을 포함하되,

상기 프로세서는,

이미지 분류가 필요한 이미지 데이터를 획득하는 인스트럭션;

이미지 데이터에서 라벨링 데이터 및 비 라벨링 데이터로 분류하는 인스트럭션;

라벨링 데이터 중 일부를 활용하여 프록시 모델을 학습하는 인스트럭션;

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 인스트럭션; 및

분류된 비 라벨링 데이터 중 일부 데이터를 프록시 모델에 입력하여 학습하는 인스트럭션; 를 포함하여 수행하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 9

제8항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 인스트럭션은 상기 샘플링 처리와 관련하여 신뢰도 임계값을 설정하는 인스트럭션을 더 포함하여 수행하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 10

제9항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 인스트럭션은 비 라벨링 데이터 중 신뢰도가 미리 설정한 임계값 보다 낮은 제1 데이터를 분류하는 인스트럭션을 더 포함하여 수행하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 11

제10항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 인스트럭션은 제1 데이터를 프록시 모델에 입력하여, 프록시 모델을 학습하는 인스트럭션을 더 포함하여 수행하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 12

제11항에 있어서,

비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 인스트럭션은 제1 데이터를 제외한 제2

데이터를 초기 이미지 데이터에 추가하는 인스트럭션을 더 포함하여 수행하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 13

제12항에 있어서,

상기 프록시 모델은 적어도 하나 이상의 Max pooling layer와 적어도 4개 층으로 이루어진 CNN(Convolutional Neural Networks) layer로 이루어진

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

청구항 14

제13항에 있어서,

상기 프록시 모델은 Softmax function을 활성화 함수로 하는

비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 비전 기반 산업 응용 프로그램에서 프록시 모델을 활용한 라벨링 데이터를 획득하는 방법 및 그 장치에 관한 것으로서, 보다 구체적으로는 비 라벨링 데이터를 샘플링 처리하는 프록시 모델을 통해 라벨링 데이터를 생성하고, 획득하는 방법 및 그 장치에 관한 것이다.

배 경 기 술

[0002] 기계학습에서 충분한 데이터가 필요하다는 것은 이미 널리 알려진 사실이고, 데이터 획득을 위해 거의 모든 산업에서 디지털 전환으로 모든 데이터를 디지털화 하고 있다.

[0003] 기계학습의 방법론 중 흔히 접하는 지도학습의 경우, 무엇이 정답인지 또는 정답이 아닌지를 추출하는 기계학습 알고리즘 방법론에 해당한다. 이러한 지도학습 알고리즘의 정확성은 지도학습 알고리즘을 학습하는 학습 데이터의 정확성에서부터 시작한다. 다시 말해서, 학습 데이터의 정확성은 지도학습 알고리즘을 학습시키는 학습 데이터가 무엇이 정답이고 아닌지를 명확히 담고 있어야 함을 의미한다. 이렇게 학습 데이터에 무엇이 정답이고 아닌지를 작성하는 것을 '데이터 라벨링' 또는 '데이터 어노테이션'이라고 말한다.

[0004] 비전 기반의 지도학습 알고리즘, 즉 이미지를 인식하고 이미지를 분류하는 지도학습 알고리즘의 경우 이러한 데이터 라벨링 작업은 이미지 데이터에서 정답에 해당하는 구역에 바운딩 박스를 그리고, 이에 정답을 라벨링하는 과정으로 수행되나, 이러한 과정은 일일이 사람이 해야하는 수작업에 해당하기도 하고, 그 정확성이 모호한 문제가 있다. 또한, 간혹 이미지 중 정답을 라벨링 하기 어려운 이미지도 존재하기도 한다.

[0005] 따라서, 지도학습 알고리즘의 정확성을 향상시키기 위한 학습 데이터의 정확성을 향상시키기 위해 라벨링 데이터를 보다 정화하고 빠르게, 또는 다량으로 획득하는 방법에 대한 구체적인 논의가 필요한 실정이다.

[0006] 전술한 배경기술은 발명자가 본 발명의 도출을 위해 보유하고 있었거나, 본 발명의 도출 과정에서 습득한 기술정보로서, 반드시 본 발명의 출원 전에 일반 공중에게 공지된 기술이라 할 수는 없다.

발명의 내용

해결하려는 과제

[0007] 본 발명의 몇몇 실시예를 통해 해결하고자 하는 과제는 이미지 분류를 하기 위해 라벨링 데이터를 생성하는 과정에서 비 라벨링 데이터를 샘플링 처리할 수 있는 방법 및 그 장치를 제공하는 것에 있다.

[0008] 또한, 본 발명의 몇몇 실시예를 통해 해결하고자 하는 과제는 비 라벨링 데이터를 신뢰 임계값을 활용, 프록시

모델을 통해 라벨링 데이터를 생성할 수 있는 방법 및 그 장치를 제공하는 것에 있다.

[0009] 또한, 본 발명의 몇몇 실시예를 통해 해결하고자 하는 과제는 프록시 모델을 지속적으로 학습시켜, 비 라벨링 데이터를 라벨링 데이터를 생성할 수 있는 딥러닝 모델의 모델 효율성을 향상시키는 방법 및 그 장치를 제공하는 것에 있다.

과제의 해결 수단

[0010] 상기 기술적 과제를 해결하기 위한, 본 발명의 몇몇 실시예에 따른 이미지 분류 장치에 의해 수행되는 방법에 있어서, 이미지 분류가 필요한 이미지 데이터를 획득하는 단계, 이미지 데이터에서 라벨링 데이터 및 비 라벨링 데이터로 분류하는 단계, 라벨링 데이터 중 일부를 활용하여 프록시 모델을 학습하는 단계, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계 및 분류된 비 라벨링 데이터 중 일부 데이터를 프록시 모델에 입력하여 학습하는 단계를 포함할 수 있다.

[0011] 일 실시 예에 있어서, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 상기 샘플링 처리와 관련하여 신뢰도 임계값을 설정하는 단계를 더 포함할 수 있다.

[0012] 일 실시 예에 있어서, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 비 라벨링 데이터 중 신뢰도가 미리 설정한 임계값 보다 낮은 제1 데이터를 분류하는 단계를 더 포함할 수 있다.

[0013] 일 실시 예에 있어서, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 제1 데이터를 프록시 모델에 입력하여, 프록시 모델을 학습하는 단계를 더 포함할 수 있다.

[0014] 일 실시 예에 있어서, 비 라벨링 데이터 중 샘플링 처리를 통해 비 라벨링 데이터를 분류하는 단계는 제1 데이터를 제외한 제2 데이터를 초기 이미지 데이터에 추가하는 단계를 더 포함할 수 있다.

[0015] 일 실시 예에 있어서, 상기 프록시 모델은 적어도 하나 이상의 Max pooling layer와 적어도 4개 층으로 이루어진 CNN(Convolutional Neural Networks) layer로 이루어질 수 있다.

[0016] 일 실시 예에 있어서, 상기 프록시 모델은 Softmax function을 활성화 함수로 할 수 있다.

발명의 효과

[0017] 전술한 본 발명의 과제 해결 수단에 의하면, 이미지 분류를 위해 딥 러닝 모델을 활용할 때, 비 라벨링 데이터를 프록시 모델을 통해 생성하여 이미지 인식 및 분류의 딥 러닝 모델의 효율성을 향상시킬 수 있다.

[0018] 또한, 본 발명의 과제 해결 수단에 의하면, 비 라벨링 데이터를 프록시 모델을 통해 라벨링 데이터로 생성하여 이미지 분류 및 인식의 효율성을 향상시킬 수 있다.

[0019] 또한, 본 발명의 과제 해결 수단에 의하면, 프록시 모델을 지속적으로 학습시켜, 비 라벨링 데이터를 샘플링 처리하는 능률을 향상시킬 수 있다.

도면의 간단한 설명

[0020] 도 1은 본 개시의 몇몇 실시예에 따른 이미지 분류 장치가 적용될 수 있는 예시적인 환경을 도시한다.

도 2는 본 개시의 몇몇 실시예에 따라 이미지 분류 장치에서 수행될 수 있는 비 라벨링 데이터를 샘플링 처리하고, 프록시 모델에 입력하여 학습하는 방법을 설명하기 위한 순서도이다.

도 3은 본 개시의 몇몇 실시예에 따른 비 라벨링 데이터의 샘플링 처리 과정에 대해 구체적으로 설명하기 위한 순서도이다.

도 4는 본 발명의 이미지 분류 인식에 관한 딥 러닝 모델의 예시도면이다.

도 5는 본 발명의 비 라벨링 데이터의 프록시 모델을 활용하여 학습하는 과정을 설명하기 위한 예시도면이다.

도 6는 본 개시의 다양한 실시예에 따른 장치 및/또는 시스템을 구현할 수 있는 예시적인 컴퓨팅 장치 도면이다.

발명을 실시하기 위한 구체적인 내용

[0021] 이하, 첨부된 도면을 참조하여 본 개시의 바람직한 실시예들을 상세 히 설명한다. 본 개시의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시예들을 참조하면 명확해질 것이다. 그러 나 본 개시의 기술적 사상은 이하의 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 수 있으며, 단지 이하의 실시예들은 본 개시의 기술적 사상을 완전하도록 하고, 본 개시가 속하는 기술 분야에서 통상의 지식을 가진 자에게 본 개시의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 개시의 기술적 사 상은 청구항의 범주에 의해 정의될 뿐이다.

[0022] 각 도면의 구성 요소들에 참조부호를 부가함에 있어서, 동일한 구성 요소들에 대해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 부호를 가 지도록 하고 있음에 유의해야 한다. 또한, 본 개시를 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 개시의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다.

[0023] 다른 정의가 없다면, 본 명세서에서 사용되는 모든 용어(기술 및 과 학적 용어를 포함)는 본 개시가 속하는 기술분야에서 통상의 지식을 가진 자에게 공통적으로 이해될 수 있는 의미로 사용될 수 있다. 또 일반적으로 사용되는 사전에 정의되어 있는 용어들은 명백하게 특별히 정의되어 있지 않는 한 이상적으로 또는 과도하게 해석되지 않는다. 본 명세서에서 사용된 용어는 실시예들을 설명하기 위한 것이며 본 개시를 제한하고자 하는 것은 아니다. 본 명세서에서, 단수형은 문 구에서 특별히 언급하지 않는 한 복수형도 포함한다.

[0024] 또한, 본 개시의 구성 요소를 설명하는 데 있어서, 제1, 제2, A, B, (a), (b) 등의 용어를 사용할 수 있다. 이러한 용어는 그 구성 요소를 다른 구성 요소와 구별하기 위한 것일 뿐, 그 용어에 의해 해당 구성 요소의 본질이나 차례 또는 순서 등이 한정되지 않는다. 어떤 구성 요소가 다른 구성 요소에 "연결", "결합" 또는 "접속"된다고 기재된 경우, 그 구성 요소는 그 다른 구성 요소에 직접적으로 연결되거나 또는 접속될 수 있지만, 각 구성 요소 사이에 또 다른 구성 요소 가 "연결", "결합" 또는 "접속"될 수도 있다고 이해되어야 할 것이다.

[0025] 명세서에서 사용되는 "포함한다(comprises)" 및/또는 "포함하는 (comprising)"은 언급된 구성 요소, 단계, 동작 및/또는 소자는 하나 이상의 다른 구성 요소, 단계, 동작 및/또는 소자의 존재 또는 추가를 배제하지 않는다.

[0026] 이하, 본 개시의 다양한 실시예들에 대하여 첨부된 도면에 따라 상세하게 설명한다.

[0027] 또한, 본 발명의 구성 요소를 설명하는 데 있어서, 제 1, 제 2, A, B, (a), (b) 등의 용어를 사용할 수 있다. 이러한 용어는 그 구성 요소를 다른 구성 요소와 구별하기 위한 것일 뿐, 그 용어에 의해 해당 구성 요소의 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.

[0029] 도 1은 본 개시의 몇몇 실시예에 따른 이미지 분류 장치가 적용될 수 있는 예시적인 환경을 도시한다.

[0030] 도 1에 도시된 데이터 베이스(100) 및 이미지 분류 장치(200)가 포함된 시스템을 통해 이미지 분류 장치(200)는 이미지가 입력되면 이미지 내 객체를 인식하고, 이를 적어도 하나 이상의 분류 기준에 따라 분류할 수 있다. 이러한 과정은 이미지 분류 장치(200)가 지도학습 알고리즘인 딥러닝 알고리즘을 기반으로 라벨링 데이터를 포함하는 학습 데이터를 통해 기 학습되고, 학습의 결과로 이러한 동작을 수행할 수 있다.

[0031] 이하에서는 상술한 시스템을 통해 제공되는 이미지가 입력되면 이를 인식하고 분류하는 동작과 관련된 도 1에 도시된 구성 요소들의 동작들에 대해 보다 구체적으로 설명하기로 한다.

[0032] 도 1은 데이터 베이스(100)와 이미지 분류 장치(200)가 네트워크를 통해 연결된 예를 도시하고 있으나, 이는 이해의 편의를 제공하기 위한 것일 뿐이고, 네트워크에 연결될 수 있는 장치의 개수는 얼마든지 달라질 수 있다.

[0033] 한편, 도 1은 본 개시의 목적을 달성하기 위한 바람직한 실시예를 도시하고 있을 뿐이며, 필요에 따라 일부 구성 요소가 추가되거나 삭제될 수 있다. 이하, 도 1에 도시된 구성 요소들에 대해 보다 구체적으로 설명하기로 한다.

[0034] 이미지 분류 장치(200)는 데이터 베이스(100)에서 입력되는 적어도 하나 이상의 이미지 데이터에서 객체를 인식하고, 이를 객체 분류 기준에 따라 분류할 수 있다.

[0035] 데이터 베이스(100)는 이미지 데이터가 저장되어 있는 장치일 수 있다. 데이터 베이스(100)는 네트워크를 통해 통신할 수 있다. 상기 네트워크는 근거리 통신망 (Local Area Network; LAN), 광역 통신망(Wide Area Network; WAN), 이동 통신망 (mobile radio communication network), Wibro(Wireless Broadband Internet) 등과 같은 모든 종류의 유/무선 네트워크로 구현될 수 있다. 데이터 베이스(100)은 네트워크를 통해 이미지 데이터를 지속적으로 획득할 수 있으며, 이러한 이미지 데이터는 데이터 베이스(100)에 저장되고 이미지 분류 장치(200)로 송신될 수 있다.

[0036] 이미지 분류 장치(200)는 수집된 다양한 이미지 데이터를 기초로 딥 러닝 알고리즘을 활용하여 이미지 내 객체를 인식하고, 이를 분류할 수 있다.

[0037] 중복된 설명을 배제하기 위해, 이미지 분류 장치(200)가 수행하는 다양한 동작들에 대해서는 추후 도 2 이하의 도면을 참조하여 보다 상세히 설명하도록 한다.

[0038] 한편, 이미지 분류 장치(200)는 하나 이상의 컴퓨팅 장치로 구현될 수 있다. 예를 들어, 이미지 분류 장치(200)의 모든 기능은 단일 컴퓨팅 장치에서 구현될 수 있다. 다른 예로써, 이미지 분류 장치(200)의 제1 기능은 제1 컴퓨팅 장 치에서 구현되고, 제2 기능은 제2 컴퓨팅 장치에서 구현될 수도 있다. 여기서, 컴퓨팅 장치는, 노트북, 데스크톱(desktop), 랩탑(laptop) 등이 될 수 있으나, 이에 국한되는 것은 아니며 컴퓨팅 기능이 구비된 모든 종류의 장치를 포함할 수 있다. 다만, 이미지 분류 장치(200)는 고성능의 서버급 컴퓨팅 장치로 구현되는 것이 바람직할 수 있다. 컴퓨팅 장치의 일례에 대해서는 도 6를 참조하여 설명하기로 한다. 나아가, 데이터 베이스(100) 역시 하나 이상의 컴퓨팅 장치로 구현될 수 있음은 당연하다.

[0039] 몇몇 실시예에서, 이미지 분류 장치(200)가 적용된 환경에 포함된 구성 요소들은 네트워크를 통해 통신할 수 있다. 상기 네트워크는 근거리 통신망 (Local Area Network; LAN), 광역 통신망(Wide Area Network; WAN), 이동 통신망 (mobile radio communication network), Wibro(Wireless Broadband Internet) 등과 같은 모든 종류의 유/무선 네트워크로 구현될 수 있다.

[0040] 한편, 도 1에 도시된 환경은 데이터 베이스(100)와 이미지 분류 장치 (200)를 경유하여 네트워크를 통해 연결된 것을 도시하고 있으나, 본 개시의 범위가 이에 한정되는 것은 아니고, 데이터 베이스(100)들이 P2P(Peer to Peer)로 연결될 수도 있음을 유의해야 한다.

[0041] 지금까지 도 1을 참조하여, 본 개시의 몇몇 실시예에 따른 이미지 분류 장치(200)가 적용될 수 있는 예시적인 환경을 설명하였다. 이하, 도 2 이하의 도면들을 참조하여, 본 개시의 다양한 실시예에 따른 방법들에 대하여 상세하게 설명하기로 한다.

[0042] 후술될 방법들의 각 단계는 컴퓨팅 장치에 의해 수행될 수 있다. 다시 말하면, 방법들의 각 단계는 컴퓨팅 장치의 프로세서에 의해 실행되는 하나 이 상의 인스트럭션들로 구현될 수 있다. 이러한 방법들에 포함되는 모든 단계는 하나의 물리적인 컴퓨팅 장치에 의하여 실행될 수도 있을 것이나, 방법의 제1 단계들은 제1 컴퓨팅 장치에 의하여 수행되고, 방법의 제2 단계들은 제2 컴퓨팅 장치에 의하여 수행될 수도 있다.

[0043] 이하 도 2에서는, 방법들의 각 단계가 도 1에 예시된 이미지 분류 장치(200)에 의해 수행되는 것을 가정하여 설명을 이어가도록 한다. 다만, 설명의 편의상, 방법들에 포함되는 각 단계의 동작 주체는 그 기재가 생략될 수도 있다.

[0044] 또한, 본 발명에서 기계학습, 딥러닝, 인공지능, AI 알고리즘은 모두 동일하게 사용될 수 있는 용어이며, 범용적으로는 통상의 기술자가 이해할 수 있는 범위에서 기계학습 알고리즘을 모두 통칭할 수 있음에 유의해야 한다.

[0046] 도 2는 본 개시의 몇몇 실시예에 따라 이미지 분류 장치에서 수행될 수 있는 비 라벨링 데이터를 샘플링 처리하고, 프록시 모델에 입력하여 학습하는 방법을 설명하기 위한 순서도이다.

[0047] 단계 S100에서, 이미지 분류 장치(200)는 이미지 데이터를 획득할 수 있다. 이미지 분류 장치(200)는 데이터 베이스(100)를 통해 이미지 데이터를 수신 받을 수 있고, 이미지 분류 장치(200)는 상기 이미지 데이터를 딥 러닝 모델을 학습하는데 활용할 수 있다.

[0048] 상기 이미지 데이터는 이미지 내 객체가 포함되어 있는 2D 이미지, 3D 이미지 일 수 있으며, 그 저장 형태는 일예에 국한되지 않는다. 따라서 이미지 데이터는 .jpg, .png, .jpeg, .mov 등 다양한 형태의 저장 형식으로 저장

된 이미지 데이터일 수 있다.

[0049] 또한, 이미지 데이터는 이미지 데이터 내 적어도 하나 이상의 객체를 포함하거나 객체를 포함하지 않은 이미지 데이터일 수 있다.

[0050] 따라서, 본 발명에서의 이미지 데이터는 통상의 기술자가 획득할 수 있는 그림, 사진 등에 관한 이미지 데이터일 수 있으며, 특정 이미지에 국한되어 해석되지 않음에 유의해야 한다.

[0051] 단계 S200에서, 이미지 분류 장치(200)는 이미지 데이터에서 라벨링 데이터 및 비 라벨링 데이터로 분류할 수 있다. 이미지 분류 장치(200)는 수신한 이미지 데이터를 분류할 수 있다. 상기 라벨링 데이터는 데이터 베이스(100)에서 수신하는 시점에서 이미 라벨링 과정이 수행되어 생성된 데이터일 수 있다. 여기서 라벨링 데이터란, 딥 러닝 모델을 학습하기 위한 데이터로서, 이미지 데이터 내 객체가 위치하고 있는 영역의 바운딩 박스가 표시되어 있고, 상기 바운딩 박스의 상기 객체에 관한 정보가 라벨링 되어 있는 데이터일 수 있다. 예를 들어, 이미지 데이터 내 개 또는 고양이가 포함되어 있는 경우, 라벨링 데이터는 개 또는 고양이가 이미지 내 위치하고 있는 영역의 적어도 하나 이상의 바운딩 박스가 표시되어 있고, 상기 적어도 하나 이상의 바운딩 박스의 각각 개 또는 고양이가 기재되어 있는 데이터일 수 있다.

[0052] 비 라벨링 데이터는 이미지 데이터 내 객체가 포함되어 있으나 상기 라벨링 과정이 수행되지 않은 데이터일 수 있다. 따라서, 비 라벨링 데이터는 어떠한 바운딩 박스가 표시되어 있지 않거나, 바운딩박스가 표시되어 있더라도 이에 대응하는 정보가 표시되지 않은 데이터일 수 있다.

[0053] 또한, 나아가 비 라벨링 데이터는 이미지 데이터 내 바운딩 박스는 표시되어 있으나 객체가 포함되어 있는 영역이 아니라 다른 영역의 잘못 표시된 데이터일 수 있다.

[0054] 따라서, 비 라벨링 데이터는 큰 의미로서 딥 러닝 모델을 학습하기 위한 학습 데이터로서 그 학습 효율이 낮은 데이터를 의미할 수도 있다. 또한, 이러한 비 라벨링 데이터는 불확실한 이미지 데이터로서 명명될 수 있으며,

[0055] 단계 S300에서, 이미지 분류 장치(200)는 라벨링 데이터 중 일부를 활용하여 프록시 모델을 학습할 수 있다.

[0056] 상기 프록시 모델은 앞서 상술한 라벨링 과정을 자동으로 수행할 수 있게 하는 딥 러닝 모델일 수 있다.

[0057] 프록시 모델은 DL 모델인 ResNet-50 모델일 수 있으며, ResNet-50은 50개의 컨볼루션 레이어를 포함하는 블록 구조로 배열되어 있을 수 있다. 또한, 잔여 네트워크를 포함하며, 상기 네트워크의 아키텍처는 컨볼루션 레이어, 최대 풀링 레이어 및 4개의 잔여 컨볼루션 블록으로 구성되며 내부의 각 블록은 컨볼루션 레이어와 최대 풀링 레이어의 조합으로 구성될 수 있다. 상기 4개의 컨볼루션 블록, 평균 풀링 레이어, 완전 연결 레이어, SoftMax 활성화 함수 레이어로 연결된 CNN(합성곱 신경망 모델)의 일종으로 구성될 수 있다.

[0058] 프록시 모델의 학습 과정은 H개의 클래스와 각 클래스에 N개의 샘플이 있는 레이블이 지정되지 않은 데이터 풀이 있다고 가정하고, 사용자의 입력을 받아 첫번째 과정에서는 N개의 샘플 중 적어도 하나 이상의 샘플을 선택하고 작은 하위 집합(S)을 생성한다. 즉, H 클래스 각각의 N개의 샘플 중 적어도 하나 이상의 샘플이 선택된 작은 하위 집합(S)을 생성하고, 상기 선택된 작은 하위 집합(S)은 사용자의 입력을 받아 각각 이에 대응하는 라벨링 과정을 수행하게 한다. 즉, 상기 선택된 작은 하위 집합(S)은 사용자의 입력을 통해 각각 라벨링된 데이터일 수 있다.

[0059] 여기서, 이미지 분류 장치(200)는 이미지 분류 장치(200) 내 포함하고 있는 활성 모델인 ML(Machine Learning) 모델을 학습시킬 수 있다. 상기 활성 모델인 ML는 딥 러닝 모델로서 CNN 모델의 일종일 수 있으며, 상기 활성 모델은 이미 라벨링 된 데이터를 이용하여 학습하여, 이미지 데이터가 입력되면 이미지 데이터를 분류하고, 이미지 데이터 내 객체를 인식하고 이를 분류할 수 있는 딥 러닝 모델일 수 있다.

[0060] 이미지 분류 장치(200)는 다른 하위 집합(L)을 활용하여, 활성 모델(ML)을 학습시킬 수 있다. 다른 하위 집합(L)은 반복적으로 증가하고 각 반복에서 활성 모델을 훈련하는 데 사용되는 반면, 작은 하위 집합(S)는 일정하고 프록시 모델을 훈련하는 데만 사용할 수 있다.

[0061] 따라서, 이미지 분류 장치(200)는 장치 내 프록시 모델과 활성 모델 2가지 딥 러닝 모델이 각기 학습하여 일정 과정을 수행하여 이미지를 분류하고 이미지내 객체를 인식, 분류할 수 있다.

[0062] 단계 S400에서, 이미지 분류 장치(200)는 비 라벨링 데이터 중 샘플링 처리를 통해 데이터를 분류할 수 있다. 즉, 이미지 분류 장치(200)는 비 라벨링 데이터를 샘플링 처리를 통해 분류하고, 이를 프록시 모델로 입력하는 일련의 과정을 통해 활성 모델에서 이미지를 보다 잘 분류하고 인식할 수 있게 할 수 있다. 구체적인 과정은 도

3을 통해 상술한다.

[0064] 도 3은 본 개시의 몇몇 실시예에 따른 비 라벨링 데이터의 샘플링 처리 과정에 대해 구체적으로 설명하기 위한 순서도이다.

[0065] 단계 S410에서, 이미지 분류 장치(200)는 샘플링 처리와 관련하여 신뢰도 임계값을 설정할 수 있다. 상기 샘플링 처리는 비 라벨링 데이터 중 신뢰도가 사전 정의된 임계값보다 많은 데이터는 활성 모델에 대한 레이블이 지정된 초기 데이터인 다른 하위 집합(L)에 추가될 수 있다. 따라서, 다른 하위 집한인(L)의 데이터는 계속하여 증가할 수 있으며, 지속적으로 활성 모델이 학습할 수 있다.

[0066] 즉, 이미지 분류 장치(200)는 비 라벨링 데이터에 대해서 신뢰도를 추출하고, 상기 추출된 신뢰도를 기초로 임계값과 비교하여 임계값 보다 높은 데이터를 프록시 모델에 작은 하위 집합(S)를 생성하는 레이블이 지정되지 않은 데이터 풀로 이동시킬 수 있다. 또는 임계값 보다 높은 데이터를 활성 모델에 입력할 수 있는 다른 하위 집합(L)에 추가할 수도 있다.

[0067] 이 때, 비 라벨링 데이터에 대한 신뢰도는 레이블이 지정되지 않은 데이터 풀에서 특정 양의 불확실한 샘플을 선택하고, 이를 조사하는 과정에서 창출될 수 있다.

수학식 1

[0068] $$ms = p(y_1|x) - p(y_2|x)$$

[0069] 여기서, ms는 마진 샘플로 신뢰도를 의미하며 y1과 y2는 활성 모델에서 가장 강하게 예측한 클래스 x의 확률을 의미한다. 즉, 활성 모델에서 이미지 분류를 하는 과정에서 복수의 이미지 분류 클래스 중 가장 높은 확률로 예측한 클래스들 중 2가지 확률값을 의미한다. 즉, y1과 y2는 적어도 하나 이상의 이미지 데이터를 의미하고, 기학습된 활성 모델을 통해서 y1, y2 라벨링 과정을 거친 데이터를 입력하였을 때, 상기 y1, y2의 라벨링 된 결과를 맞출 확률값을 $p(y_1|x)$, $p(y_2|x)$ 로 정의하며, 이 값에 차이를 라벨링 되지 않은 y1 데이터의 신뢰도로 설정할 수 있다.

[0070] 즉, 이 과정에서 신뢰도는 다른 후보에 대한 후보 샘플의 예측 확률값의 차이로 산출하며, 상기 차이가 낮을수록 신뢰도 값을 낮게 설정할 수 있다.

[0071] 단계 S420에서, 이미지 분류 장치(200)는 비 라벨링 데이터 중 신뢰도가 미리 설정한 임계값보다 낮은 제1 데이터를 분류할 수 있다. 단계 S410에서 미리 설정한 임계값보다 낮은 비 라벨링 데이터 중 제1 데이터는 프록시 모델 또는 활성 모델을 학습하는 것에 있어 효율성이 떨어지는 바, 제외할 수 있다.

[0072] 단계 S430에서, 이미지 분류 장치(200)는 제1 데이터 제외한 제2 데이터를 프록시 모델에 입력하여 프록시 모델을 학습할 수 있다. 즉, 이미지 분류 장치(200)는 신뢰도가 높은 데이터를 프록시 모델에 학습할 수 있는 학습 데이터로서 활용하여 프록시 모델의 학습 효율을 향상시킬 수 있다. 즉, 이미지 분류 장치(200)는 상기 제2 데이터를 프록시 모델을 학습하기 위해 라벨링 되지 않은 데이터 풀로 이동시키고, 프록시 모델을 학습하기 위한 작은 하위 집합(S)를 생성하는데 활용할 수 있다.

[0073] 단계 S440에서, 이미지 분류 장치(200)는 제1 데이터를 제외한 제2 데이터를 초기 이미지 데이터에 추가할 수 있다. 즉, 이미지 분류 장치(200)는 제2 데이터를 활성 모델을 학습하기 위한 초기 이미지 데이터에 추가할 수 있고, 상기 추가하는 과정에서 이미지 분류 장치(200)는 사용자 입력을 받아 라벨링 과정을 거친 이후 초기 이미지 데이터에 추가할 수도 있다.

[0074] 이 과정에서 활성 모델은 신뢰도가 임계값보다 높은 데이터에 대해서 라벨링 과정을 거친 이후 학습할 수 있어, 학습 효율이 향상될 수 있다.

[0075] 다시 도 2로 돌아와, 단계 S500에서, 이미지 분류 장치(200)는 분류된 데이터 중 일부 데이터를 프록시 모델에 입력하여 학습할 수 있다. 즉, 단계 S500에서는 프록시 모델이 지속적으로 학습하는 과정을 수행할 수 있음을 의미하며, 상기 일부 데이터는 단계 S430에서 상술하는 제2 데이터일 수 있고, 또는 제2 데이터가 추가된 라벨

링 되지 않은 데이터 풀에서 생성된 작은 하위 집합 (S)를 통해 학습할 수 있는 데이터일 수도 있다.

[0076] 이하에서는 도 4를 활용하여 딥 러닝 모델의 예시를 설명하도록 한다.

[0078] 도 4는 본 발명의 이미지 분류 인식에 관한 딥 러닝 모델의 예시도면이다.

[0079] 본 발명의 개시에서 활성 모델은 CNN 모델일 수 있다. 상기 CNN 모델은 합성곱 신경망 모델로서, Convolutional layer, pooling layer, fully connected layer, activating function layer을 포함할 수 있다.

[0080] Convolutional layer는 적어도 하나 이상의 Filter를 포함하고 있으며, 적어도 하나 이상의 Filter는 각각 특정 모양에 대한 특징을 갖을 수 있다. 예를 들어, 물체의 윤곽을 알아내기 위한 edge Filter의 경우 이미지를 커버할 수 있는 선과 같은 특정 모양에 대한 특징을 갖을 수 있다. edge Filter를 이미지에 적용시키는 경우, edge Filter에 부합하는 특징 정보를 얻을 수 있다. Convolutional layer에 포함된 적어도 하나 이상의 Filter를 통해 특징 맵을 추출할 수 있다.

[0081] Pooling layer는 Convolutional layer의 사이 사이에 구조적으로 위치할 수 있다. 또는 복수의 Convolutional layer가 계층적으로 위치한 후, Pooling layer가 위치할 수도 있다. Pooling layer는 Convolutional layer를 통해 추출된 특징 맵에서 특정 영역에 대한 특정 값을 추출하는 기능을 수행한다. Pooling layer는 여러 가지 종류를 가지고 있으며, 일 예로는 Max Pooling layer, Median Pooling layer 등이 있을 수 있다.

[0082] Fully Connected Layer는 적어도 하나 이상의 Convolutional Layer와 Pooling Layer를 통해 추출된 특징 맵에 대해서 이미지 분류 기능을 수행할 수 있다. 일 예로 Fully Connected Layer는 특징 맵을 일렬의 형태로 위치한 후 hidden layer를 거쳐 이미지를 분류할 수 있다.

[0083] Activation Function layer는 활성화 함수 층으로서 특징 맵에 적용될 수 있다. Activation Function layer는 Fully Connected Layer 이후 정량적 값에 대해, 특징 정보를 포함하고 있는 여부에 관한 결과로 바꿔 주는 기능을 수행할 수 있다. 본 발명에서는 Activation Function layer를 Softmax function layer로 설정할 수 있다.

[0084] 또한, 본 발명에서는 Max Pooling layer, 적어도 하나 이상의 Convolutional layer, Fully Connected Layer, Softmax layer로 이루어질 수 있으며 이는 일 예에 해당할 뿐, 이에 국한되어 해석되는 것은 아님에 유의해야 한다.

[0086] 도 5는 본 발명의 비 라벨링 데이터의 프록시 모델을 활용하여 학습하는 과정을 설명하기 위한 예시도면이다.

[0087] 도 5를 참조하면, 활성 모델인 ML에 Labeled data가 입력되어 학습할 수 있다. 여기서 Labeled data는 앞서 상술한 라벨링 데이터를 의미할 수 있으며, Unlabeled data의 경우 비 라벨링 데이터일 수 있다.

[0088] 도 5에서 이미지 분류 장치(200)는 ML과 Proxy model를 포함할 수 있다. 또한, 도 5에서 이미지 분류 장치(200)는 data sampling(데이터 샘플링)을 통해 Uncertain data와 Certain data로 분류할 수 있다. 상기 Uncertain data는 신뢰도가 임계값이 낮은 불확실한 데이터인 제1 데이터에 해당할 수 있고, Certain data는 신뢰도가 임계값을 초과한 확실한 데이터인 제2 데이터일 수 있다.

[0089] 따라서, 상기 제1 데이터를 Proxy model에 입력하여 학습하게 할 수 있고, 제2 데이터를 Proxy model에 입력하여 학습하게 할 수도 있다.

[0090] 또는, 제2 데이터를 ML에 다시 입력하여 학습하게 할 수 있으며, 이 과정에서 사용자의 입력을 받아 라벨링 과정을 수행하고, ML을 학습하게 할 수도 있다.

[0091] 이하에서는 도 6을 통해 본 발명이 구현될 수 있는 컴퓨팅 장치를 상술하도록 한다.

[0093] 도 6은 본 개시의 다양한 실시예에 따른 장치 및/또는 시스템을 구현할 수 있는 예시적인 컴퓨팅 장치 도면이다.

[0094] 컴퓨팅 장치(1500)는 하나 이상의 프로세서(1510), 버스(1550), 통 신 인터페이스(1570), 프로세서(1510)에 의하여 수행되는 컴퓨터 프로그램(1591)을 로드(load)하는 메모리(1530)와, 컴퓨터 프로그램(1591)을 저장하는 스

토리지 (1590)를 포함할 수 있다. 다만, 도 6에는 본 개시의 실시예와 관련 있는 구성 요소들 만이 도시되어 있다. 따라서, 본 개시가 속한 기술분야의 통상의 기술자라면 도 6에 도시된 구성 요소들 외에 다른 범용적인 구성 요소들이 더 포함될 수 있음을 알 수 있다.

[0095] 프로세서(1510)는 컴퓨팅 장치(1500)의 각 구성의 전반적인 동작을 제어한다. 프로세서(1510)는 CPU(Central Processing Unit), MPU(Micro Processor Unit), MCU(Micro Controller Unit), GPU(Graphic Processing Unit) 또는 본 개시의 기술 분야에 잘 알려진 임의의 형태의 프로세서를 포함하여 구성될 수 있다. 또한, 프로세서(1510)는 본 개시의 실시예들에 따른 방법을 실행하기 위한 적어도 하나의 애플리케이션 또는 프로그램에 대한 연산을 수행할 수 있다. 컴퓨팅 장치 (1500)는 하나 이상의 프로세서를 구비할 수 있다.

[0096] 메모리(1530)는 각종 데이터, 명령 및/또는 정보를 저장한다. 메모 리(1530)는 본 개시의 실시예들에 따른 방법을 실행하기 위하여 스토리지(1590)로부터 하나 이상의 프로그램(1591)을 로드할 수 있다. 메모리(1530)는 RAM과 같은 휘발성 메모리로 구현될 수 있을 것이나, 본 개시의 기술적 범위가 이에 한정되는 것은 아니다.

[0097] 버스(1550)는 컴퓨팅 장치(1500)의 구성 요소 간 통신 기능을 제공한다. 버스(1550)는 주소 버스(Address Bus), 데이터 버스(Data Bus) 및 제어 버스 (Control Bus) 등 다양한 형태의 버스로 구현될 수 있다.

[0098] 통신 인터페이스(1570)는 컴퓨팅 장치(1500)의 유무선 인터넷 통신을 지원한다. 또한, 통신 인터페이스(1570)는 인터넷 통신 외의 다양한 통신 방식을 지원할 수도 있다. 이를 위해, 통신 인터페이스(1570)는 본 개시의 기술 분야에 잘 알려진 통신 모듈을 포함하여 구성될 수 있다.

[0099] 몇몇 실시예들에 따르면, 통신 인터페이스(1570)는 생략될 수도 있다.

[0100] 스토리지(1590)는 상기 하나 이상의 프로그램(1591)과 각종 데이터를 비임시적으로 저장할 수 있다.

[0101] 스토리지(1590)는 ROM(Read Only Memory), EPROM(Erasable Programmable ROM), EEPROM(Electrically Erasable Programmable ROM), 플래시 메 모리 등과 같은 비휘발성 메모리, 하드 디스크, 착탈형 디스크, 또는 본 개시가 속 하는 기술 분야에서 잘 알려진 임의의 형태의 컴퓨터로 읽을 수 있는 기록 매체를 포함하여 구성될 수 있다.

[0102] 컴퓨터 프로그램(1591)은 메모리(1530)에 로드 될 때 프로세서(1510)로 하여금 본 개시의 다양한 실시예에 따른 방법/동작을 수행하도록 하는 하나 이상의 인스트럭션들을 포함할 수 있다. 즉, 프로세서(1510)는 상기 하나 이상의 인스트럭션들을 실행함으로써, 본 개시의 다양한 실시예에 따른 방법/동작들을 수행할 수 있다.

[0103] 지금까지 도 1 내지 도 6을 참조하여 본 개시의 다양한 실시예들 및 그 실시예들에 따른 효과들을 언급하였다. 본 개시의 기술적 사상에 따른 효과 들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 명세서의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

[0104] 지금까지 도 1 내지 도 6을 참조하여 설명된 본 개시의 기술적 사상은 컴퓨터가 읽을 수 있는 매체 상에 컴퓨터가 읽을 수 있는 코드로 구현될 수 있다. 상기 컴퓨터로 읽을 수 있는 기록 매체는, 예를 들어 이동형 기록 매체(CD, DVD, 블루레이 디스크, USB 저장 장치, 이동식 하드 디스크)이거나, 고정식 기록 매체(ROM, RAM, 컴퓨터 구비 형 하드 디스크)일 수 있다. 상기 컴퓨터로 읽을 수 있는 기록 매체에 기록된 상기 컴퓨터 프로그램은 인터넷 등의 네트워크를 통하여 다른 컴퓨팅 장치에 전송되어 상기 다른 컴퓨팅 장치에 설치될 수 있고, 이로써 상 기 다른 컴퓨팅 장치에서 사용될 수 있다.

[0105] 이상에서, 본 개시의 실시예를 구성하는 모든 구성 요소들이 하나로 결합되거나 결합되어 동작하는 것으로 설명되었다고 해서, 본 개시의 기술적 사상이 반드시 이러한 실시예에 한정되는 것은 아니다. 즉, 본 개시의 목적 범위 안에 서라면, 그 모든 구성 요소들이 하나 이상으로 선택적으로 결합하여 동작할 수도 있다.

[0106] 도면에서 동작들이 특정한 순서로 도시되어 있지만, 반드시 동작들이 도시된 특정한 순서로 또는 순차적 순서로 실행되어야만 하거나 또는 모든 도시 된 동작들이 실행되어야만 원하는 결과를 얻을 수 있는 것으로 이해되어서는 안 된다. 특정 상황에서는, 멀티태스킹 및 병렬 처리가 유리할 수도 있다. 더욱이, 위에 설명한 실시예들에서 다양한 구성들의 분리는 그러한 분리가 반드시 필요한 것으로 이해되어서는 안 되고, 설명된 프로그램 컴포넌트들 및 시스템들은 일반적으로 단일 소프트웨어 제품으로 함께 통합되거나 다수의 소프트웨어 제품으로 패키지 될 수 있음을 이해하여야 한다.

[0107] 이상 첨부된 도면을 참조하여 본 개시의 실시예들을 설명하였지만, 본 개시가 속하는 기술분야에서 통상의 지식을 가진 자는 그 기술적 사상이나 필수 적인 특징을 변경하지 않고서 본 개시가 다른 구체적인 형태로도 실시될 수 있다는 것을 이해할 수 있다. 그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적인

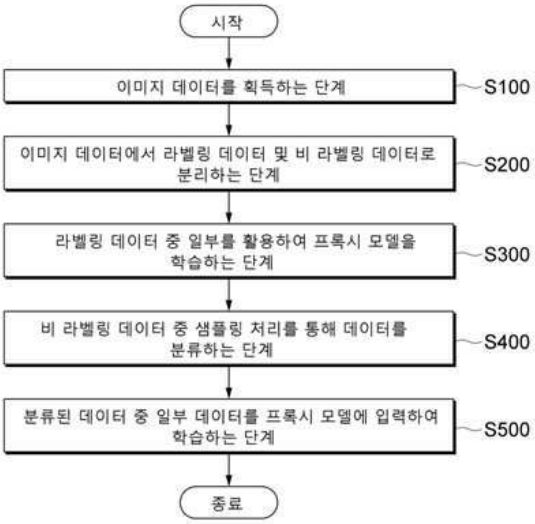
것이 아닌 것으로 이해해야만 한다. 본 개시의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 개시에 의해 정의되는 기술적 사상의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

도면

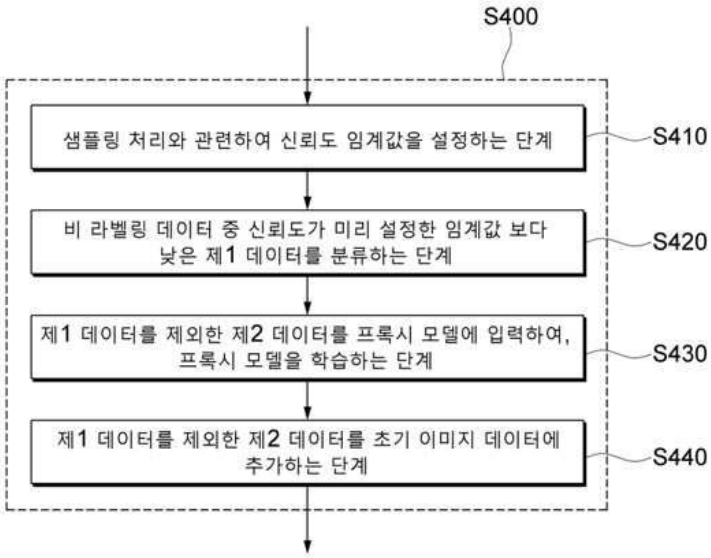
도면1



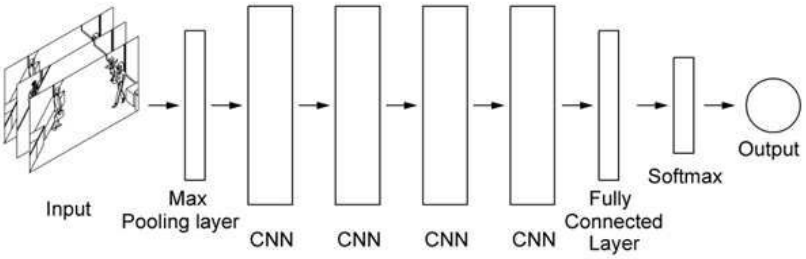
도면2



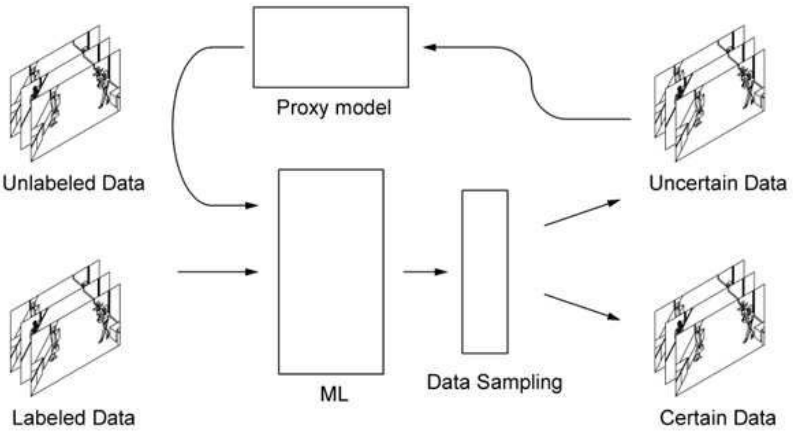
도면3


S400
샘플링 처리와 관련하여 신뢰도 임계값을 설정하는 단계
S410
비 라벨링 데이터 중 신뢰도가 미리 설정한 임계값 보다 낮은 제1 데이터를 분류하는 단계
S420
제1 데이터를 제외한 제2 데이터를 프록시 모델에 입력하여, 프록시 모델을 학습하는 단계
S430
제1 데이터를 제외한 제2 데이터를 초기 이미지 데이터에 추가하는 단계
S440

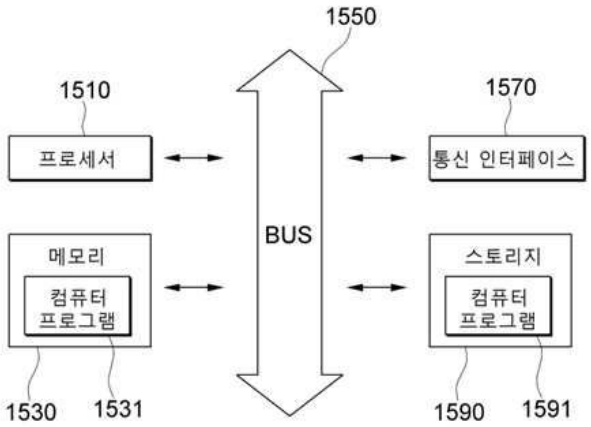
도면4


Input
Max Pooling layer
CNN
CNN
CNN
CNN
Fully Connected Layer
Softmax
Output

도면5


Proxy model
Unlabeled Data
Uncertain Data
Labeled Data
ML
Data Sampling
Certain Data

도면6


1550
1510
1570
프로세서
통신 인터페이스
BUS
메모리
컴퓨터
프로그램
스토리지
컴퓨터
프로그램
1530
1531
1590
1591