



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0089999
(43) 공개일자 2023년06월21일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) G01R 31/64 (2020.01)
G06N 3/04 (2023.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
G01R 31/64 (2020.01)
(21) 출원번호 10-2021-0178855
(22) 출원일자 2021년12월14일
심사청구일자 2021년12월14일

(71) 출원인
한국기술교육대학교 산학협력단
충청남도 천안시 동남구 병천면 충절로 1600 (한국기술교육대학교내)
(72) 발명자
오홍선
충청남도 천안시 동남구 병천면 충절로 1600, 434호(공학2관)
손성빈
경상북도 구미시 봉곡로24길 33-11, 107동 2001호(봉곡동, 봉곡e편한세상)
(뒤편에 계속)
(74) 대리인
특허법인오암

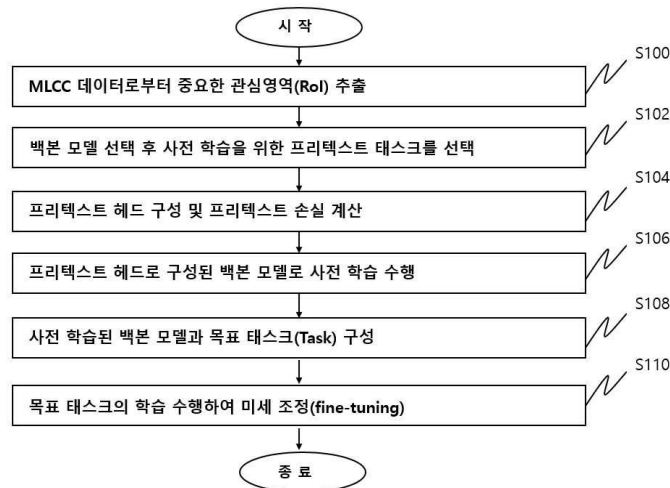
전체 청구항 수 : 총 19 항

(54) 발명의 명칭 딥러닝 기반의 MLCC 데이터에 특화된 전이 학습 방법 및 장치

(57) 요약

본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 방법은, MLCC 적층 얼라인먼트 검사를 위한 딥러닝 기반의 MLCC 데이터에 특화된 전이 학습 방법에 있어서, (a) 검사 공정에 사용되는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하는 단계; (b) 추출된 관심영역에 대한 사전 학습(Pre-training)을 위한 프리텍스트 헤드(Pretext Head)로 구성된 자기지도(Self Supervised) 학습 기반의 백본 모델로 사전 학습을 수행하는 단계; (c) 지도(Supervised) 학습 기반의 딥러닝 모델에서 사전 학습된 백본(Backbone) 모델과 목표 태스크에 대한 태스크 헤드(Task Head)를 포함하도록 구성하는 단계; (d) 상기 목표 태스크의 학습을 수행하여 미세 조정(fine-tuning)하는 단계를 포함한다.

대표도 - 도1



(52) CPC특허분류

G06N 3/04 (2023.01)

(72) 발명자

박주찬

경기도 광주시 고불로 453, 103동 1304호(삼동, 우남퍼스트빌)

이선훈

충청남도 천안시 동남구 병천면 가전8길 102-4, 302호(장원맨션)

정준욱

대구광역시 달서구 달서대로 67, 103동 1603호(유천동, 유천동 포스코 더샵아파트)

박용준

충청남도 천안시 동남구 병천면 가전7길 1-13, b동 201호(골든빌)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711134128
과제번호	2021-0-00921-001
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	2021년도 ICT R&D 혁신 바우처 지원 사업
연구과제명	MLCC 데이터에 특화된 전이학습 방법
기여율	1/1
과제수행기관명	삼성기전(주)
연구기간	2021.04.01 ~ 2021.12.31

명세서

청구범위

청구항 1

MLCC 적층 얼라인먼트 검사를 위한 딥러닝 기반의 MLCC 데이터에 특화된 전이 학습 방법에 있어서,

- (a) 검사 공정에 사용되는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하는 단계;
- (b) 추출된 관심영역에 대한 사전 학습(Pre-training)을 위한 프리텍스트 헤드(Pretext Head)로 구성된 자기지도(Self Supervised) 학습 기반의 백본 모델로 사전 학습을 수행하는 단계;
- (c) 지도(Supervised) 학습 기반의 딥러닝 모델에서 사전 학습된 백본(Backbone) 모델과 목표 태스크에 대한 태스크 헤드(Task Head)를 포함하도록 구성하는 단계;
- (d) 상기 목표 태스크의 학습을 수행하여 미세 조정(fine-tuning)하는 단계를 포함하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 2

제1항에 있어서,

상기 MLCC 데이터는

MLCC 적층의 검은 영역에 해당하는 전극부와, 하얀 영역에 해당하는 유전체 부분에 대한 이미지 데이터로 이루어지는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 3

제1항에 있어서,

상기 (b) 단계는

딥러닝 기반의 백본 모델 선택 후 사전 학습을 위한 프리텍스트 태스크를 정의하는 단계;

상기 프리텍스트 태스크를 백본 모델이 사전 학습할 수 있도록 프리텍스트 헤드를 구성하는 단계;

를 더 포함하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 4

제3항에 있어서,

상기 프리텍스트 헤드는

자기 지도 방식의 학습을 수행하도록 구성하되, Context Prediction, Jigsaw Puzzle, Colorization, Rotation, Feature Distance 중 적어도 어느 하나의 방식을 포함하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 5

제2항에 있어서,

상기 백본 모델은

CNN(Convolution Neural Network) 모델 또는 Transformer 모델 중 택일적으로 선택되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 6

제1항에 있어서,

상기 목표 태스크에 대한 딥러닝 모델은 이미지의 특징을 추출하는 백본 모델과, 목표 태스크의 태스크 헤드를

합쳐서 전체 모델이 구성되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 7

제6항에 있어서,

상기 목표 태스크의 태스크 헤드는 상기 백본 모델의 사전 학습 결과로 나온 출력 특징값(output feature)에 FC(Fully-Connected) Layer를 이용하여 태스크 헤드가 구성되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 8

제6항에 있어서,

상기 목표 태스크는 MLCC 데이터 이미지로부터 양볼 판정을 위한 데이터를 결과로 추출하기 위한 태스크로서, 특정 객체(불량 객체 영역)를 추출하는 객체 탐지(Object Detection)와, MLCC 데이터의 양볼 판정 경계를 구분하기 위한 세그멘테이션(Segmentation)을 포함하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 9

제6항에 있어서,

상기 프리텍스트 헤드는 목표 태스크에 대한 지도학습 모델을 위한 태스크 헤드 구성시 추가하여 구성할 수 있으며,

상기 프리텍스트 헤드는 프리텍스트 태스크의 사전 학습 결과에 대한 특징값들이 포함될 수 있어 목표 태스크의 전이 학습시 원하는 결과를 도출하는 데에 도움을 줄 수 있는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 방법.

청구항 10

하드웨어인 컴퓨터와 결합되어, 제1항 내지 제9항의 MLCC 데이터에 특화된 전이 학습 방법을 수행할 수 있도록 컴퓨터에서 판독 가능한 기록매체에 저장된 컴퓨터 프로그램.

청구항 11

하나 이상의 프로세서; 및

상기 하나 이상의 프로세서에 의한 실행 시, 상기 하나 이상의 프로세서가 연산을 수행하도록 하는 명령들이 저장된 하나 이상의 메모리를 포함하고,

상기 프로세서에서 수행되는 연산은,

검사 공정에 사용되는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하는 연산, 추출된 관심영역에 대한 사전 학습을 위한 프리텍스트 헤드로 구성된 자기지도 학습 기반의 백본 모델로 사전 학습을 수행하는 연산, 지도 학습 기반의 딥러닝 모델에서 사전 학습된 백본 모델과 목표 태스크에 대한 태스크 헤드를 포함하도록 구성하는 연산, 상기 목표 태스크의 학습을 수행하여 미세 조정(fine-tuning)하는 연산을 포함하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 12

제11항에 있어서,

상기 MLCC 데이터는

MLCC 적층의 검은 영역에 해당하는 전극부와, 하얀 영역에 해당하는 유전체 부분에 대한 이미지 데이터로 이루어지는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 13

제11항에 있어서,

상기 백본 모델로 사전 학습을 수행하는 연산은,

딥러닝 기반의 백본 모델 선택 후 사전 학습을 위한 프리텍스트 태스크를 정의하는 연산과,

상기 프리텍스트 태스크를 백본 모델이 사전 학습할 수 있도록 프리텍스트 헤드를 구성하는 연산을 포함하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 14

제13항에 있어서,

상기 프리텍스트 헤드는

자기 지도 방식의 학습을 수행하도록 구성하되, Context Prediction, Jigsaw Puzzle, Colorization, Rotation, Feature Distance 중 적어도 어느 하나의 방식을 포함하는

를 포함하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 15

제12항에 있어서,

상기 백본 모델은

CNN(Convolution Neural Network) 모델 또는 Transformer 모델 중 택일적으로 선택되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 16

제11항에 있어서,

상기 목표 태스크에 대한 딥러닝 모델은 이미지의 특징을 추출하는 백본 모델과, 목표 태스크의 태스크 헤드를 합쳐서 전체 모델이 구성되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 17

제16항에 있어서,

상기 목표 태스크의 태스크 헤드는 상기 백본 모델의 사전 학습 결과로 나온 출력 특징값(output feature)에 FC(Fully-Connected) Layer를 이용하여 태스크 헤드가 구성되는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 18

제16항에 있어서,

상기 목표 태스크는 MLCC 데이터 이미지로부터 양불 판정을 위한 데이터를 결과로 추출하기 위한 태스크로서, 특정 객체(불량 객체 영역)를 추출하는 객체 탐지(Object Detection)와, MLCC 데이터의 양불 판정 경계를 구분하기 위한 세그멘테이션(Segmentation)을 포함하는 MLCC 데이터에 특화된 전이 학습 장치.

청구항 19

제16항에 있어서,

상기 프리텍스트 헤드는 목표 태스크에 대한 지도학습 모델을 위한 태스크 헤드 구성시 추가하여 구성할 수 있으며,

상기 프리텍스트 헤드는 프리텍스트 태스크의 사전 학습 결과에 대한 특징값들이 포함될 수 있어 목표 태스크의 전이 학습시 원하는 결과를 도출하는 데에 도움을 줄 수 있는 것을 특징으로 하는 MLCC 데이터에 특화된 전이 학습 장치.

발명의 설명

기술분야

[0001] 본 발명은 MLCC 데이터에 특화된 전이 학습 방법 및 장치에 관한 것으로, 더욱 상세하게는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하여 자기지도(Self Supervised) 학습 기반의 백본 모델로 사전 학습을 수행하고, 사전 학습된 백본(Backbone) 모델을 활용하여 목표 태스크에 대한 전이 학습을 수행하는 딥러닝 기반의 MLCC 데이터에 특화된 전이 학습 방법 및 장치에 관한 것이다.

배경기술

[0002] 기존의 전이 학습(Transfer Learning) 방법으로는 레이블링(Labeling)된 데이터와 지도(Supervised) 학습 방식을 이용해 사전 학습(Pre-training)을 진행 후 원하는 태스크(Task)에 미세 조정(Fine tuning)하는 방식이 주를 이루고 있다.

[0003] 사전 학습이란 모델을 바로 주어진 데이터(Downstream Task)에 학습시키기 이전에 다른 데이터에 먼저 사전에 학습을 시키는 것을 의미하며, 사전 학습된 모델의 파라미터를 이용해 모델을 초기화 후 풀고자 하는 목표 태스크에 미세 조정하게 되면 임의로 초기화된 파라미터를 가진 모델을 처음부터 학습시키는 것보다 더 높은 성능을 보이게 된다.

[0004] 또한 미세 조정(fine-tuning)이란 사전 학습된 모델을 풀고자 하는 목표 태스크에 맞게 재구성하기 위해 사전 학습된 백본(Backbone) 모델과 풀고자 하는 목표 태스크의 분류기인 헤드(Head)를 추가하여 학습을 진행하는 방법으로 구체적인 방법은 3 가지가 존재한다.

[0005] 먼저, 모든 네트워크 구조를 학습 시키는 방법이고, 두 번째는 일부 Layer 는 고정시킨 채, 나머지 Layer와 분류기(head)를 학습시키는 방법이며, 세 번째는 백본(Backbone) 모델의 Layer는 모두 고정시키고 오직 분류기(head)만 학습시키는 방법이다.

[0006] 또한 지도 학습은 대규모의 데이터에서 Label을 해당 이미지의 카테고리 예를 들어 개, 사람, 고양이 이미지 등을 이용하여 모델이 카테고리를 분류할 수 있는 구성을 만들어 백본 모델을 학습시키는 방식이다.

[0007] 한편, MLCC(Multi Layer Ceramic Capacitor)칩은 전자제품의 회로에 전류가 일정하게 흐르도록 제어하는 핵심 부품으로 자동차를 비롯하여 다양한 스마트 전자기기 분야에 활용되고 있다. 이러한 MLCC 칩의 적층 얼라인먼트 검사는 적층 공정 이후의 검사 공정을 포함할 수 있다.

[0008] 검사 공정에 사용되는 MLCC 데이터는 Vision 검사가 가능하도록 크게 MLCC 적층의 검은 영역에 해당하는 전극부와 하얀 영역에 해당하는 유전체 부분에 대한 이미지 데이터로 이루어져 있으며, MLCC 데이터의 특성상 불량 판정은 도 9를 참조하면 크게 얼라인먼트(Alignment) 밀림, 시트(Sheet) 접힘, 전극 빠짐, 얼라인먼트 틀어짐으로 총 4 가지의 불량이 발생할 수 있다.

[0009] 현재 해당 불량은 수작업으로 일일이 작업자들이 분류하고 있어, 많은 시간과 비용이 들어가는 문제가 있다.

[0010] 따라서, 머신러닝 학습을 이용한 불량 판정 알고리즘을 활용할 필요성이 있으나, MLCC 공정상 불량률이 현저히 낮아 학습에 필요한 데이터 수집이 매우 어려우며, 전문가가 아니면 레이블링의 어려움이 높은 애로 사항이 있다.

[0011] 따라서 시간과 비용을 줄여 생산속도를 높이기 위해서는, Deep Learning 학습 기반의 양불 판정이 필요하다.

[0012] 하지만 그렇다 하더라도 현재 학습에 필요한 MLCC 데이터의 수집이 보안상 매우 어렵고, 데이터를 수집하고 레이블링을 진행해 지도학습으로 학습을 진행하기에는 데이터의 양이 매우 적은 문제점이 존재한다.

[0013] 따라서 적은 Labeled MLCC 데이터를 사용하더라도 높은 성능을 달성할 수 있는 MLCC 데이터에 특화된 전이 학습(Transfer Learning) 방법에 대한 연구가 필요하게 되었다.

[0014] 종래의 일반적인 전이 학습 방법은 한국공개특허 제10-2019-0138238호에 개시되어 있다.

선행기술문헌

특허문헌

[0015] (특허문헌 0001) 한국공개특허 제10-2019-0138238호(2019년12월12일 공개)

발명의 내용

해결하려는 과제

[0016] 본 발명의 목적은 데이터 수집과 레이블링이 매우 어려운 특수한 데이터인 MLCC 데이터에서 양불 판정에 중요한 부분인 유전체 부분에 중점을 맞춰 사전 학습을 진행하는 과정에서 자기 지도(Self supervised) 방식을 사용하는 전이 학습 방법인, MLCC 데이터에 특화된 전이 학습 방법 및 장치를 제공하는 것이다.

과제의 해결 수단

[0017] 본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 방법은, MLCC 적층 얼라인먼트 검사를 위한 딥러닝 기반의 MLCC 데이터에 특화된 전이 학습 방법에 있어서, (a) 검사 공정에 사용되는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하는 단계; (b) 추출된 관심영역에 대한 사전 학습(Pre-training)을 위한 프리텍스트 헤드(Pretext Head)로 구성된 자기지도(Self Supervised) 학습 기반의 백본 모델로 사전 학습을 수행하는 단계; (c) 지도(Supervised) 학습 기반의 딥러닝 모델에서 사전 학습된 백본(Backbone) 모델과 목표 태스크에 대한 태스크 헤드(Task Head)를 포함하도록 구성하는 단계; (d) 상기 목표 태스크의 학습을 수행하여 미세 조정(fine-tuning)하는 단계를 포함한다.

[0018] 상기 MLCC 데이터는 MLCC 적층의 검은 영역에 해당하는 전극부와, 하얀 영역에 해당하는 유전체 부분에 대한 이미지 데이터로 이루어지는 것을 특징으로 한다.

[0019] 상기 (b) 단계는 딥러닝 기반의 백본 모델 선택 후 사전 학습을 위한 프리텍스트 태스크를 정의하는 단계; 상기 프리텍스트 태스크를 백본 모델이 사전 학습할 수 있도록 프리텍스트 헤드를 구성하는 단계; 를 더 포함한다.

[0020] 상기 프리텍스트 헤드는 자기 지도 방식의 학습을 수행하도록 구성되되, Context Prediction, Jigsaw Puzzle, Colorization, Rotation, Feature Distance 중 적어도 어느 하나의 방식을 포함한다.

[0021] 상기 백본 모델은 CNN(Convolution Neural Network) 모델 또는 Transformer 모델 중 택일적으로 선택되는 것을 특징으로 한다.

[0022] 상기 목표 태스크에 대한 딥러닝 모델은 이미지의 특징을 추출하는 백본 모델과, 목표 태스크의 태스크 헤드를 합쳐서 전체 모델이 구성되는 것을 특징으로 한다.

[0023] 상기 목표 태스크의 태스크 헤드는 상기 백본 모델의 사전 학습 결과로 나온 출력 특징값(output feature)에 FC(Fully-Connected) Layer를 이용하여 태스크 헤드가 구성되는 것을 특징으로 한다.

[0024] 상기 목표 태스크는 MLCC 데이터 이미지로부터 양불 판정을 위한 데이터를 결과로 추출하기 위한 태스크로서, 특정 객체(불량 객체 영역)를 추출하는 객체 탐지(Object Detection)와, MLCC 데이터의 양불 판정 경계를 구분하기 위한 세그멘테이션(Segmentation)을 포함한다.

[0025] 상기 프리텍스트 헤드는 목표 태스크에 대한 지도학습 모델을 위한 태스크 헤드 구성시 추가하여 구성할 수 있으며, 상기 프리텍스트 헤드는 프리텍스트 태스크의 사전 학습 결과에 대한 특징값들이 포함될 수 있어 목표 태스크의 전이 학습시 원하는 결과를 도출하는 데에 도움을 줄 수 있는 것을 특징으로 한다.

[0026] 상기 MLCC 데이터에 특화된 전이 학습 방법은, 하드웨어인 컴퓨터와 결합되어, 컴퓨터에서 판독 가능한 기록매체에 저장된 컴퓨터 프로그램에 의해 수행될 수 있다.

[0027] 본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 장치는 하나 이상의 프로세서; 및 상기 하나 이상의 프로세서에 의한 실행 시, 상기 하나 이상의 프로세서가 연산을 수행하도록 하는 명령들이 저장된 하나 이상의 메모리를 포함하고, 상기 프로세서에서 수행되는 연산은, 검사 공정에 사용되는 MLCC 데이터로부터 중요한 관심영역(RoI) 추출하는 연산, 추출된 관심영역에 대한 사전 학습을 위한 프리텍스트 헤드로 구성된 자기지도 학습 기반의 백본 모델로 사전 학습을 수행하는 연산, 지도 학습 기반의 딥러닝 모델에서 사전 학습된 백본 모델과 목표 태스크에 대한 태스크 헤드를 포함하도록 구성하는 연산, 상기 목표 태스크의 학습을 수행하여 미세 조정(fine-tuning)하는 연산을 포함한다.

발명의 효과

- [0028] 본 발명은 자기 지도 방식의 사전 학습 및 사전 학습 결과를 활용한 지도 방식의 전이 학습 방법을 수행함으로써, 적은 Labeled MLCC 데이터를 사용하더라도 높은 성능을 달성할 수 있는 MLCC 데이터에 특화된 전이 학습(Transfer Learning) 방법을 수행할 수 있는 장점이 있다.
- [0029] 또한, 자기 지도(Self Supervised) 학습에 의해 Labeled 데이터를 사용하지 않고, 이미지 자체의 특성을 모델이 사전 학습할 수 있게 하여 모델의 표현력(Representation Power)을 향상시키도록 프리텍스트(Pretext) 기반의 모델 구성을 만들어 백본 모델을 사전 학습시킬 수 있는 장점이 있다.
- [0030] 또한, 전이 학습에 의한 결과로서, 객체 탐지(Object Detection)로 MLCC 이미지 데이터의 검출된 핵심 영역에서 세그멘테이션(segmentation)하고, 세그멘테이션 결과를 이용하여 기준 마진을 범위에 따라 불량 여부를 판단하는 데에 활용할 수 있다.
- [0031] 또한 세그멘테이션(Segmentation)을 사용하는 과정에서 프리텍스트 헤드(Rotation, Jigsaw) 등을 이용해, 데이터의 표현력(특징)을 조금 더 향상시켜줄 수 있도록 프리텍스트 헤드를 추가로 구성한다면 성능 향상에 도움이 될 수 있다.
- [0032] 또한, 프리텍스트 헤드는 목표 태스크에 대한 지도학습 모델을 위한 태스크 헤드 구성시 추가하여 구성할 수 있으며, 프리텍스트 헤드는 프리텍스트 태스크의 사전 학습 결과에 대한 특징값들이 포함될 수 있어 목표 태스크의 전이 학습시 원하는 결과를 도출하는 데에 도움을 줄 수 있다.

도면의 간단한 설명

- [0033] 도 1은 본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 방법의 순서도이다.
- 도 2는 본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 장치의 내부 구성을 보인 블록도이다.
- 도 3은 본 발명의 MLCC 데이터에 특화된 전이 학습 방법의 사전 학습 및 미세 조정 과정을 수행하기 위한 구성 개념을 설명하기 위한 도면이다.
- 도 4는 본 발명의 MLCC 데이터에 특화된 전이 학습 방법의 미세 조정 과정을 구체적으로 수행하기 위한 구성 개념을 설명하기 위한 도면이다.
- 도 5는 MLCC 데이터(이미지)로부터 프리텍스트 태스크를 수행하기 위해 태스크를 선택(정의)하는 과정을 설명하기 위한 도면이다.
- 도 6은 본 발명에 적용되는 백본 모델의 예시를 보인 도면이다.
- 도 7은 본 발명에 적용되는 MLCC 데이터의 예시를 보인 도면이다.
- 도 8은 본 발명에서 마진을 판단 예시를 설명하기 위한 도면이다.
- 도 9는 본 발명에 적용되는 MLCC 검사 종류를 나타낸 도면이다.

발명을 실시하기 위한 구체적인 내용

- [0034] 이하에서는 도면을 참조하여 본 발명의 구체적인 실시예를 상세하게 설명한다. 다만, 본 발명의 사상은 제시되는 실시예에 제한되지 아니하고, 본 발명의 사상을 이해하는 당업자는 동일한 사상의 범위 내에서 다른 구성요소를 추가, 변경, 삭제 등을 통하여, 퇴보적인 다른 발명이나 본 발명 사상의 범위 내에 포함되는 다른 실시예를 용이하게 제안할 수 있을 것이나, 이 또한 본원 발명 사상 범위 내에 포함된다고 할 것이다. 또한, 각 실시예의 도면에 나타나는 동일한 사상의 범위 내의 기능이 동일한 구성요소는 동일한 참조부호를 사용하여 설명한다.
- [0035] 도 1은 본 발명의 일 실시예에 따른 MLCC 데이터에 특화된 전이 학습 방법의 순서도이다.
- [0036] MLCC 데이터(10)에 특화된 전이 학습 방법은 우선 도 7을 참조하면, 이미지 형태인 MLCC 데이터(10)로부터 중요한 영역에 해당하는 관심영역(Region of Interest, RoI)을 추출할 수 있다(S100).
- [0037] 이때, 관심영역을 추출하는 방법은 구체적으로 이미지 이진화(Binarization)를 이용하거나 객체 탐지(Object Detection) 모델을 이용해 관심 영역을 추출할 수 있으며, 추출 영역은 예컨대 Annotation 도구의 박스(BOX) 좌

표가 될 수 있다. 또한 사용자가 임의로 정의한 영역들을 관심 영역으로 사용할 수도 있다.

- [0038] 또한 관심 영역은 사용자가 중요하다고 생각하는 부분을 구성하여 사용할 수 있으며, 관심 영역이 없다면 이미지 전체를 관심 영역으로 지정할 수도 있다.
- [0039] 본 발명에서의 MLCC 데이터(10)의 관심 영역 또는 데이터 이미지 자체는 구체적으로 MLCC 적층의 검은 영역에 해당하는 전극부와 하얀 영역에 해당하는 유전체 부분에 대한 이미지 데이터가 될 수 있다.
- [0040] 이제 추출된 관심 영역 또는 MLCC 데이터(10) 이미지를 토대로 백본 모델을 활용하여 자기 지도 방식의 사전 학습을 수행할 수 있다.
- [0041] 또한 본 발명에 적용되는 자기 지도(Self Supervised) 학습은 도 3을 참조하면, Labeled 데이터를 사용하지 않고, 이미지 자체의 특성을 모델이 학습할 수 있게 하여 모델의 표현력(Representation Power)을 향상시키도록 프리텍스트(Pretext) 기반의 모델 구성을 만들어 백본 모델을 학습시키는 학습 방식이다.
- [0042] 여기서 백본 모델은 입력이 들어와서 출력에 관련된 모듈에 처리된 입력을 전달해주는 역할로 볼 수 있으며, 이미지로부터 좋은 특징들을 추출하는 딥 러닝(deep learning) 모델이다.
- [0043] 또한 백본 모델 구조로는 예컨대 도 6에 도시된 바와 같이, CNN(Convolution Neural Network) 모델과 Transformer 모델이 사용될 수 있으며, 구체적으로 기존 벤치마크 데이터셋에서 좋은 성능을 보여주는 CNN 계열(Resnet), Transformer 계열(ViT)이 백본 모델로 사용하기에 적합할 수 있다.
- [0044] 또한 CNN과 Transformer는 별개의 독립적인 모델로, CNN 모델을 선택 시 백본 모델은 CNN 구조로만 이루어진 모델이 사용되게 되고, Transformer 모델을 선택 시 백본 모델은 Transformer 구조로만 이루어진 모델이 사용될 수 있다.
- [0045] 이제 백본 모델 선택 후 도 5를 참조하면, 사전 학습을 위한 프리텍스트 태스크(Pretext Task)를 정의(선택)하는 과정을 거친다(S102).
- [0046] 즉, 백본 모델의 입력으로는 MLCC 데이터(10)의 원본 이미지가 될 수 있으며, 백본 모델은 모델의 출력 특징값을 바탕으로 사용자가 정한 프리텍스트 태스크를 백본 모델이 학습할 수 있도록 프리텍스트 헤드(Pretext Head)를 구성하며, 프리텍스트 손실(Loss)을 계산하여 백본 모델로 역전파를 진행하여 사전 학습을 진행하게 된다(S104, S106).
- [0047] 백본 모델의 사전 학습을 위해 각 프리텍스트 헤드를 구성하는 자기 지도 방식의 종류는 예컨대 이미지로부터 patch를 추출하여 patch 간의 상대적인 위치를 예측하도록 학습하는 Context Prediction, Jigsaw Puzzle, Colorization, Rotation, Feature Distance 등이 될 수 있으며, 백본 모델은 이들 중 하나 이상의 방식을 중복하여 프리텍스트 헤드를 구성할 수 있다.
- [0048] 즉, 중복 예시로는 Jigsaw Puzzle과 Rotation의 조합, Rotation과 Feature Distance의 조합 등이 될 수 있다.
- [0049] 이와 같이, 프리텍스트 구성 방식은 사용자 정의에 따라 임의로 정해질 수 있다.
- [0050] 여기서 Jigsaw Puzzle 방식은 Puzzle처럼 이미지를 Patch로 분할하고, Patch 를 섞은 후 원본 이미지로 돌아가기 위한 이미지의 순열(Permutation)을 예측하는 방법이다.
- [0051] 또한 Rotation 방식은 이미지를 90 도 단위로 회전시켜 나온 이미지와 원본 이미지를 비교하였을 때 원본 대비 회전시킨 이미지의 각도가 몇 도(0, 90, 180, 인지를 예측하는 방법이다.
- [0052] 구체적 예를 들면, 프리텍스트 헤드를 구성한 Rotate 방식에서는 MLCC 데이터(10)에서 추출된 관심영역을 랜덤(Random)하게 회전시키고, 모델이 관심 영역의 회전된 각도를 예측(0,90,180,270)하게 된다.
- [0053] Jigsaw 방식에서는 MLCC 데이터(10)에서 추출된 관심 영역을 Puzzle처럼 섞은 후 순서대로 원래 위치를 예측(1,3,4,2)할 수 있다.
- [0054] 또한, 프리텍스트 태스크는 중복 적용이 가능하며, 이 때 프리텍스트 헤드는 태스크 개수만큼 구성되도록 설정될 수 있다.
- [0055] 프리텍스트 태스크의 사전 학습 방식은 자기 지도(Self Supervised) 방식이 사용될 수 있으며, 각 방식들을 중첩하여 프리텍스트 헤드를 구성하여 사용 가능하다.
- [0056] 여기서 프리텍스트 태스크를 사용한 사전학습을 수행하는 이유는 적은 레이블링 데이터셋으로도 원하는 성능을

연구 위해서 구축하고자 하는 데이터의 특징들을 잘 내포하고 있는 백본 모델을 구축하여 사전 학습을 수행할 수 있도록 하는 것이다.

- [0057] 즉, 지도 학습 기반의 성능을 높이기 위해서는 대규모의 레이블링된 데이터셋이 필요하지만, MLCC 데이터(10)와 같은 특수한 데이터의 경우 대규모의 레이블링된 데이터셋을 구축하기 위해서는 많은 비용과 시간이 걸리게 되므로, 데이터의 특징들을 잘 내포하고 있는 백본 모델을 구축하여 사전 학습을 함으로써, 목표 태스크에서 원하는 학습 결과를 도출할 수 있도록 전이 학습할 수 있게 하는 것이다.
- [0058] 즉, 목표 태스크에 대한 딥러닝 모델은 이미지의 특징을 추출하는 백본 모델과, 풀고자 하는 목표 태스크 (Detection, Segmentation, Classification)의 태스크 헤드를 합쳐서 전체 모델이 구성된다(S108).
- [0059] 백본 모델의 사전 학습 결과로 나온 출력 특징값(output feature)에 FC(Fully-Connected) Layer를 이용하여 풀고자 하는 목표 태스크의 태스크 헤드가 구성된다.
- [0060] 이때 태스크 헤드는 프리텍스트 태스크를 어떤 것을 선택 했느냐에 따라 달라지게 된다(Class 개수의 차이).
- [0061] 마지막 FC Layer의 끝은 Class의 개수로 지정되고, Rotation의 경우 각도가 4개이므로, Class 개수는 4개가 선택되며, Jigsaw의 고정된 순열 조합들의 수가 Class 개수가 된다.
- [0062] FC Layer의 Output은 각 Class에 대한 확률을 의미하며, 확률이 가장 높은 class가 모델이 예측한 정답이라고 생각할 수 있다.
- [0063] 프리텍스트 태스크를 중첩해서 사용하는 경우(Rotation + Jigsaw), 프리텍스트 헤드는 2개가 사용되며, 각 헤드는 Rotation에 대한 class와, Jigsaw에 대한 class를 각각 예측하게 된다.
- [0064] 프리텍스트 헤드를 중복하여 사용하는 이유는 한 가지 프리텍스트만 적용할 시 모델의 일반화의 어려움이 생길 수 있기 때문에, 여러 가지를 사용하여 모델의 표현력을 높이기 위함이다.
- [0065] 이제 프리텍스트로 학습된 백본 모델과 풀고자 하는 목표 태스크에 맞는 헤드를 구성하여 도 4에 도시된 바와 같이, 실제 미세조정 학습을 진행할 수 있다(S110).
- [0066] 또한 실제 미세조정 학습을 진행하는 과정에서 프리텍스트로 학습된 백본 모델이 풀고자 하는 목표 태스크에 필요한 정보를 충분히 포함하고 있지 않은 경우, 프리텍스트 헤드를 추가로 구성함으로써, 이후 원하는 목표 태스크(풀고자 하는 태스크)에서의 모델의 표현력(Representation Power)을 향상시킴으로써 원하는 성능 도달이 가능하도록 전이 학습을 수행할 수 있게 된다.
- [0067] 즉, 주어진 목표 태스크(Downstream Task)에 해당하는 실제적으로 풀고자 하는 목표 태스크(문제)에 대한 학습 (미세 조정)이 진행될 수 있다.
- [0068] 여기서 풀고자 하는 목표 태스크는 MLCC 데이터(10) 이미지로부터 양불 판정을 위한 데이터를 결과로 추출하기 위한 태스크로서, 특정 객체(불량 객체 영역)를 추출하는 객체 탐지(Object Detection)가 될 수 있고, MLCC 데이터(10)의 양불 판정 경계를 구분하기 위한 세그멘테이션(Segmentation)이 될 수 있다.
- [0069] 이와 같이 전이 학습에 의한 결과로서, 예컨대 객체 탐지(Object Detection)로 MLCC 이미지 데이터의 검출된 핵심 영역에서 세그멘테이션(segmentation)하고, 세그멘테이션 결과를 이용하여 도 8을 참조하면, 기준 마진을 범위에 따라 불량 여부를 판단하는 데에 활용할 수 있다.
- [0070] 좀 더 구체적으로 마진을 판단은 촬영된 이미지 데이터를 가지고 인쇄 패턴에서의 전극과 전극 사이의 거리(마진 구간)를 4등분하여 전극이 마진 부분에 해당하는 기준 마진율인 1/4(25%)을 초과하여 벗어나면 불량, 1/4 이내면 양품으로 판단하는 것이다.
- [0071] MLCC 데이터(10)에서는 궁극적으로 불량 검출을 MLCC 사이의 영역을 기준으로 마진율을 판정해야 하기 때문에, 경계면을 분할하는 태스크인 세그멘테이션(Segmentation)을 사용할 수 있는 것이다.
- [0072] 또한 세그멘테이션(Segmentation)을 사용하는 과정에서 프리텍스트 헤드(Rotation, Jigsaw) 등을 이용해, 데이터의 표현력(특징)을 조금 더 향상시켜줄 수 있도록 프리텍스트 헤드를 추가로 지도학습 기반 딥러닝 모델에 구성한다면 성능 향상에 도움이 될 수 있다.
- [0073] 즉, 프리텍스트 헤드는 목표 태스크에 대한 지도학습 모델(딥러닝 모델)을 위한 태스크 헤드 구성시 프리텍스트 헤드(백본 모델로 사전 학습된 특징값들)를 추가하여 구성할 수 있으며, 프리텍스트 헤드는 프리텍스트 태스크의 사전 학습 결과에 대한 특징값들이 포함될 수 있어 목표 태스크의 전이 학습시 원하는 결과를 도출하는 데에

도움을 줄 수 있는 것이다.

- [0074] 도 2는 본 발명의 일 실시예에 따른 MLCC 데이터(10)에 특화된 전이 학습 장치의 내부 구성을 보인 블록도이다.
- [0075] MLCC 데이터(10)에 특화된 전이 학습 장치(100)는 후술하는 기능을 수행할 수 있는 기기로서, 예를 들어 서버 컴퓨터, 개인 컴퓨터 등으로 구성될 수 있다. 일 실시예에서, MLCC 데이터(10)에 특화된 전이 학습 장치(100)는 하나 이상의 프로세서(110) 및/또는 하나 이상의 메모리(120)를 포함할 수 있다.
- [0076] 일 실시예에 따라 하나 이상의 프로세서(110)에 의해 수행되는 연산은, 검사 공정에 사용되는 MLCC 데이터(10)로부터 중요한 관심영역(RoI) 추출하는 연산, 추출된 관심영역에 대한 사전 학습을 위한 프리텍스트 헤드로 구성된 자기지도 학습 기반의 백본 모델로 사전 학습을 수행하는 연산, 지도 학습 기반의 딥러닝 모델에서 사전 학습된 백본 모델과 목표 태스크에 대한 태스크 헤드를 포함하도록 구성하는 연산, 상기 목표 태스크의 학습을 수행하여 미세 조정하는 연산을 포함할 수 있다.
- [0077] 또한 백본 모델로 사전 학습을 수행하는 연산은, 딥러닝 기반의 백본 모델 선택 후 사전 학습을 위한 프리텍스트 태스크를 정의하는 연산과, 상기 프리텍스트 태스크를 백본 모델이 사전 학습할 수 있도록 프리텍스트 헤드를 구성하는 연산을 더 포함할 수 있다.
- [0078] 상술한 MLCC 데이터(10)에 특화된 전이 학습 장치(100)는, 통신망 상의 서버 또는 퍼스널 컴퓨터(PC)에 설치되어 실행되는 컴퓨터 프로그램(모바일의 경우 모바일 어플리케이션) 자체가 될 수도 있다.
- [0079] 또한 MLCC 데이터(10)에 특화된 전이 학습 장치(100)는 프로세서(110) 및 메모리(120)를 포함할 수 있다. 실시예에서, MLCC 데이터(10)에 특화된 전이 학습 장치(100)는 네트워크 인터페이스(또는 통신 인터페이스)(미도시), 스토리지(미도시), 버스(bus)(미도시)를 더 포함할 수 있다.
- [0080] 일 실시예에서, 프로세서(110)는 MLCC 데이터에 특화된 전이 학습 장치(100)의 각 구성의 전반적인 동작을 제어할 수 있다. 프로세서(110)는 CPU(Central Processing Unit), MPU(Micro Processor Unit), MCU(Micro Controller Unit), 또는 본 발명의 기술 분야에 잘 알려진 임의의 형태의 프로세서(110)를 포함하여 구성될 수 있다.
- [0081] 실시예에서, 프로세서(110)는 본 발명의 실시예들에 따른 방법을 실행하기 위한 적어도 하나의 애플리케이션 또는 프로그램에 대한 연산을 수행할 수 있다. 실시예에서, 프로세서(110)는 하나 이상의 코어(core, 미도시) 및 그래픽 처리부(미도시) 및/또는 다른 구성 요소와 신호를 송수신하는 연결 통로(예: 버스(bus) 등)를 포함할 수 있다.
- [0082] 실시예에서, 프로세서(110)는 프로세서(110) 내부에서 처리되는 신호(또는, 데이터)를 일시적 및/또는 영구적으로 저장하는 램(RAM: Random Access Memory, 미도시) 및 롬(ROM: Read-Only Memory, 미도시)을 더 포함할 수 있다. 또한, 프로세서(110)는 그래픽 처리부, 램 및 롬 중 적어도 하나를 포함하는 장치온칩(SoC: system on chip) 형태로 구현될 수 있다.
- [0083] 실시예에서, 프로세서(110)는 메모리(120)에 저장된 하나 이상의 인스트럭션(instruction)을 실행함으로써, 상술한 MLCC 데이터(10)에 특화된 전이 학습 방법을 수행할 수 있다.
- [0084] 일 실시예에서는, MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 이 구성요소들 중 적어도 하나가 생략되거나, 다른 구성요소가 MLCC 데이터(10)에 특화된 전이 학습 장치(100)에 추가될 수 있다. 또한 추가적으로 (additionally) 또는 대체적으로(alternatively), 일부의 구성요소들이 통합되어 구현되거나, 단수 또는 복수의 개체로 구현될 수 있다. MLCC 데이터(10)에 특화된 전이 학습 장치(100) 내, 외부의 구성요소들 중 적어도 일부의 구성요소들은 버스, GPIO(general purpose input/output), SPI(serial peripheral interface) 또는 MIPI(mobile industry processor interface) 등을 통해 서로 연결되어, 데이터 및/또는 시그널을 주고 받을 수 있다.
- [0085] 하나 이상의 메모리(120)는 다양한 데이터를 저장할 수 있다. 메모리(120)에 저장되는 데이터는, MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 적어도 하나의 구성요소에 의해 획득되거나, 처리되거나, 사용되는 데이터로서, 소프트웨어(예: 프로그램)를 포함할 수 있다. 메모리(120)는, 휘발성 및/또는 비휘발성 메모리(120)를 포함할 수 있다. 하나 이상의 메모리(120)는, 하나 이상의 프로세서(110)에 의한 실행 시, 하나 이상의 프로세서(110)가 연산을 수행하도록 하는 명령들을 저장할 수 있다. 일 실시예에서, 하나 이상의 메모리(120)는 하나 이상의 사용자에 대한 개인화 정보 및/또는 하나 이상의 상품에 대한 추천 정보를 저장할 수 있다. 본 개시에서, 프로그램 내지 명령은 메모리(120)에 저장되는 소프트웨어로서, MLCC 데이터(10)에 특화된 전이 학습

장치(100)의 리소스를 제어하기 위한 운영체제, 어플리케이션 및/또는 어플리케이션이 장치의 리소스들을 활용할 수 있도록 다양한 기능을 어플리케이션에 제공하는 미들웨어 등을 포함할 수 있다.

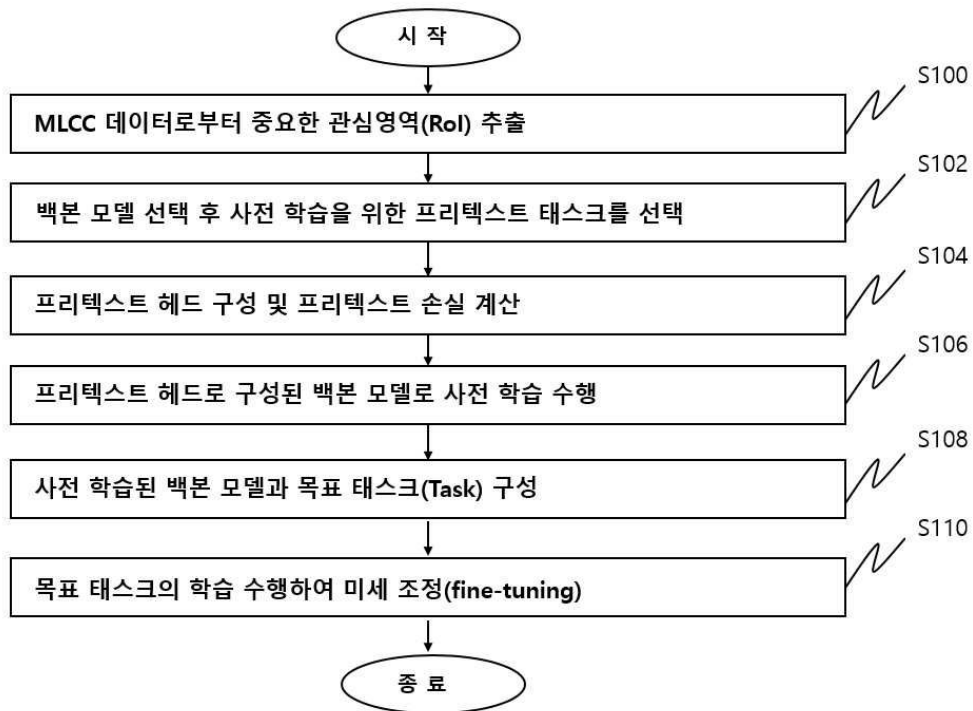
- [0086] 하나 이상의 프로세서(110)는, 소프트웨어(예: 프로그램, 명령)를 구동하여 프로세서(110)에 연결된 MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 적어도 하나의 구성요소를 제어할 수 있다. 또한 프로세서(110)는 본 개시와 관련된 다양한 연산, 처리, 데이터 생성, 가공 등의 동작을 수행할 수 있다. 또한 프로세서(110)는 데이터 등을 메모리(120)로부터 로드하거나, 메모리(120)에 저장할 수 있다
- [0087] 일 실시예에서, MLCC 데이터(10)에 특화된 전이 학습 장치(100)는 통신 인터페이스(도시되지 않음)를 더 포함할 수 있다
- [0088] 통신 인터페이스에 의해 통신하는 통신망은 단말기들 및 서버들과 같은 각각의 노드 상호 간에 정보 교환이 가능한 연결 구조를 의미하는 것으로, 근거리 통신망(LAN: Local Area Network), 광역 통신망(WAN: Wide Area Network), 인터넷 (WWW: World Wide Web), 유무선 데이터 통신망, 전화망, 유무선 텔레비전 통신망 등을 포함한다.
- [0089] 무선 데이터 통신망의 일례에는 3G, 4G, 5G, 3GPP(3rd Generation Partnership Project), LTE(Long Term Evolution), WIMAX(World Interoperability for Microwave Access), 와이파이(Wi-Fi), 블루투스 통신, 적외선 통신, 초음파 통신, 가시광 통신(VLC: Visible Light Communication), 라이파이(LiFi) 등이 포함되나 이에 한정되지는 않는다.
- [0090] 본 개시에 따른 MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 다양한 실시예들은 서로 조합될 수 있다.
- [0091] 각 실시예들은 경우의 수에 따라 조합될 수 있으며, 조합되어 만들어진 MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 실시예 역시 본 개시의 범위에 속한다.
- [0092] 또한 전술한 본 개시에 따른 MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 내/외부 구성 요소들은 실시예에 따라 추가, 변경, 대체 또는 삭제될 수 있다. 또한 전술한 MLCC 데이터(10)에 특화된 전이 학습 장치(100)의 내/외부 구성 요소들은 하드웨어 컴포넌트로 구현될 수 있다.
- [0093] 나아가 본 발명의 MLCC 데이터(10)에 특화된 전이 학습 방법은 컴퓨터와의 결합을 통해 실행시키기 위한 저장매체에 저장된 컴퓨터 프로그램으로 구현되거나, 이 컴퓨터 프로그램이 동작하는 컴퓨터 하드웨어에 탑재되는 모듈 형태로 구현될 수 있다.
- [0094] 또한, 본 발명의 일 실시예에 따른 MLCC 데이터(10)에 특화된 전이 학습 방법은, 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리, SSD(Solid State Drive) 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

부호의 설명


- [0095] 10 : MLCC 데이터
- 100 : MLCC 데이터에 특화된 전이 학습 장치
- 110 : 프로세서
- 120 : 메모리

도면

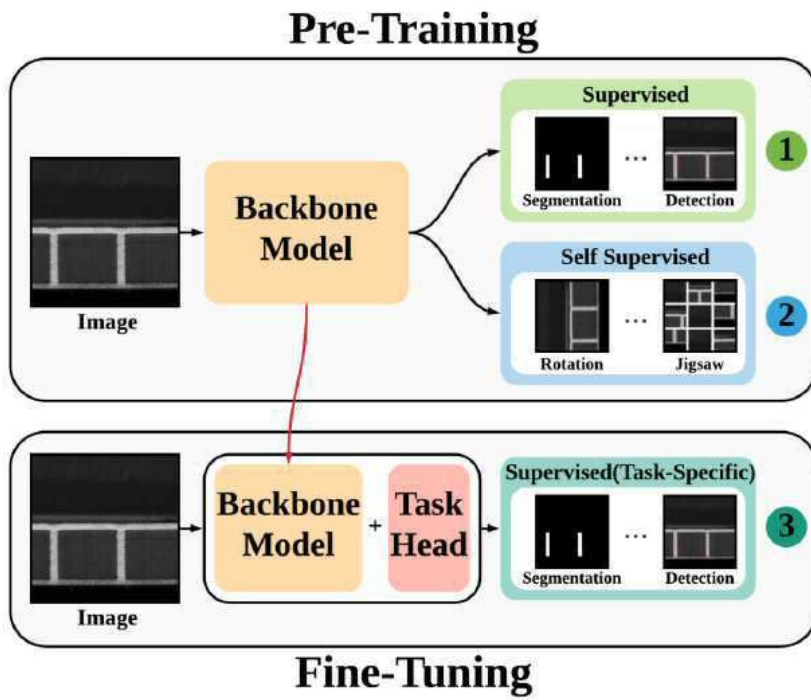
도면1



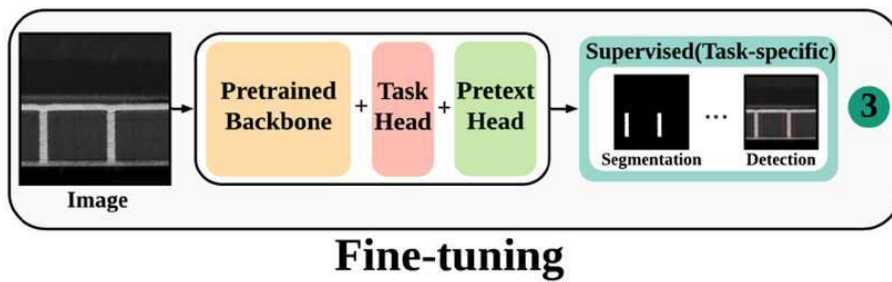
도면2




도면3



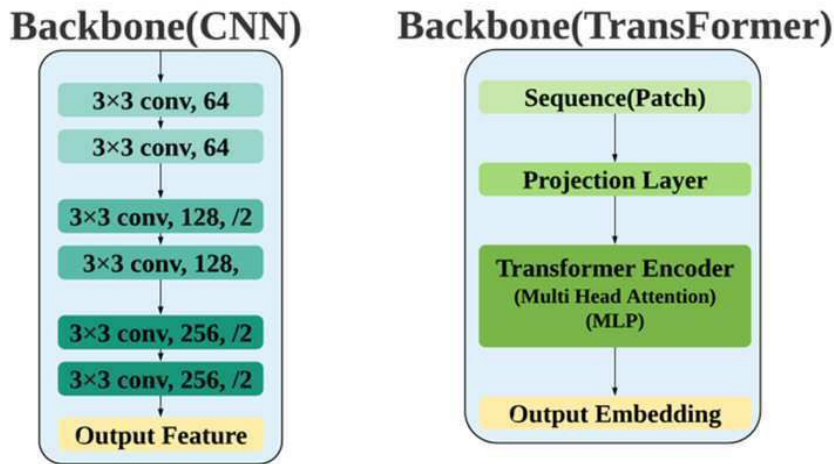
도면4




도면5




도면6



도면7



도면8



도면9

