

전이학습기반 PCB 부품조립 이상탐지

이지호, 김지원, 전창재*
세종대학교

alyssa1107@naver.com, kimjiwon15124@gmail.com, *cchun@sejong.ac.kr

Transfer Learning-Based Anomaly Detection for PCB Part Assembly

Ji Ho Lee, Ji-Won Kim, Chang-Jae Chun
Sejong Univ.

요 약

최근 대부분의 제조업체는 제조공정간 결함 발생으로 인한 불량률 증가에 따른 매출손실을 최소화하고자 한다. 이에 따라 스마트팩토리 전환과 인공지능 비전 모델을 활용한 결함 탐지 시스템이 도입되고 있다. 하지만, 이러한 시스템을 구축하기 위해서는 많은 학습 데이터가 필요하며, 대상별로 결함탐지 모델을 개발해야 하기 때문에 많은 시간과 비용이 들어간다. 이러한 문제점을 해결하기 위해 본 논문에서는 부품 조립 시 발생하는 이상을 탐지하는 모델을 제안했고, 특히 전이학습 (Transfer Learning)을 활용한 여러 부품에 대해 효과적인 모델을 구축하는 방법을 제안했다. 시뮬레이션을 통해 제안하는 방법이 부품 각각에 대해 이상탐지 모델을 구축하는 것에 비해 학습시간이 약 24 % 단축되어, 제안하는 방법이 부품조립 이상탐지에 더 효과적인 것을 확인했다.

I. 서 론

대부분의 제조업체 불량 감별 방법은 전문 감별원에 의한 수작업으로 진행되고 있으며, 공정상 불량 발생에 따른 납기 지연 문제를 발생시켜 매출 상에 큰 손실을 초래하고 있다. 이에 따라 최근 스마트 팩토리 전환과 인더스트리 4.0 을 위한 AI 비전, 품질 및 결함 탐지 방법에 관한 기술 개발이 전세계적으로 활발하게 진행 중에 있다. 하지만, 모든 부품에 대한 이상탐지 모델 개발은 많은 시간을 초래하고 고비용 문제로 인해 많은 중소 공장에 현실적으로 도입이 어려운 상황이다. 연구 [1]에서는 두 가지 커넥터 부품에 대한 결함 탐지를 위해 CNN 기반 VGGNet 모델을 사용하였으며 Canny-Edge, Morphology 연산 방법을 사용하여 각 데이터 전처리에 따라 정확도를 비교하였다. 연구 [2]에서는 6 개의 결함 유형에 대해 포토샵 프로그램을 통해 인공적으로 이상데이터를 생성하였고, 생성한 데이터를 바탕으로 Image Subtraction 을 통해 결함 모양과 위치 찾기를 통한 결함 탐지를 진행하였다. 하지만 [1], [2]와 같은 연구에서는 유사한 부품에 대한 결함 탐지를 진행하기 때문에 타 부품에 대한 일반화된 탐지에 대한 고려가 부족하다. 또한, 이상데이터를 인공적으로 생성하였기 때문에 실제 제조분야에서의 이상데이터와 차이가 있을 수 있다. 본 논문에서는 실제 제조업체에서 사용되고 있는 PCB 부품들을 기반으로 하여 조립이상탐지를 진행하였다. 특히, 여러 부품에 대한 각각의 새로운 모델 개발보다 짧은 시간안에 효과적으로 모델구축이 가능하도록 전이학습 (Transfer Learning)을 기반으로 한 이상탐지방법을 제안하였다.

대해 각각의 모델을 새롭게 학습하지 않아도 되어, 효과적인 모델 구축이 가능한 장점이 있다. 전이 학습 기법 중 미세조정(Fine Tuning)은 사전 학습 모델과 전이학습 모델의 데이터양과 유사성에 따라 4 가지 유형으로 나눌 수 있으며 보통 특징을 추출하는 앞부분 레이어의 가중치는 변경하지 않고 뒷부분 레이어의 가중치를 수정한다[4].

2.2 데이터 구성

본 논문에서는 PCB 기판에 존재하는 부품 별 이미지를 사용하였다. 사용된 부품은 그림 1 과 같은 다중 스크류와 그림 2 와 같은 단일 커넥터이다. 다중 스크류 RAW 데이터의 이미지 크기는 346 X 282 이며, 그림 1 과 같이 정상 및 이상 데이터 각 497 장으로 총 994 장이다. 정상 데이터는 스크류 7 개가 모두 결합되어 있는 이미지를 수집하였으며, 이상 데이터는 스크류가 1 개부터 7 개까지 결합되어 있지 않은 경우의 수를 고려하여 수집하였다. 단일 커넥터 RAW 데이터의 이미지 크기는 118 X 377 이며, 그림 2 와 같이 정상, 이상 데이터 각 115 장으로 총 230 장이다. 정상 데이터는 커넥터의 결합이 정상적으로 이루어진 이미지를 수집하였으며, 이상 데이터는 커넥터가 완전히 결합되어 있지 않은 이미지를 수집하였다.



그림 1. 다중 스크류 결합 여부에 따른 정상/이상 데이터



그림 2. 단일 커넥터 결합 여부에 따른 정상/이상 데이터

II. 본론

2.1 전이학습

전이학습은 사전 학습된 모델의 일부를 변형하여 다른 모델에 학습시키는 방법이다. 따라서 각 대상에

2.3 데이터 전처리

데이터의 품질이 모델 성능에 영향을 주기 때문에 다음과 같은 3 가지 데이터 전처리 과정을 추가하였다. 본 논문에서는 다중 스크류, 단일 커넥터의 결합 여부를 판단하는 것이므로 3 차원의 색 공간 채널을 가진 RGB 이미지의 필요성이 적다고 판단되었다. 따라서 Grayscale 을 사용하여 이미지 픽셀 값을 0~255 값으로 정규화를 진행하였다. 또한, Bilateral Filter 를 적용하여 부품 이미지의 Noise 는 제거하고 Edge 를 보존하여 부품의 윤곽에 대한 선명도를 증가시켰다. 보통 많은 부품을 짧은 시간에 edge device 에서 이상탐지를 해야 하는 현장 상황을 고려하여, RAW 이미지 데이터를 32 X 32 크기로 Resize 하여 학습에 활용했다.

2.4 결합 탐지 모델 구성

본 논문에서 사용된 결합 탐지 모델은 다음과 같다: i) 그림 3 과 같은 구조로 다중 스크류 데이터셋을 활용한 CNN 기반 모델 (M1), ii) 단일 커넥터 데이터셋을 활용한 CNN 기반 모델 (M2), 그리고 iii) 그림 4 와 같은 구조로 전이학습을 활용한 단일 커넥터 결합 탐지를 위해 M1 모델에서 미세조정을 통해 분류기 (Classifier)만 재 학습시킨 CNN 기반 모델 (M3). 모델 M1, M2 은 이미지 분류에 대한 용이한 네트워크 구조인 Resnet50 모델을 기본구조를 사용하였고, M3 모델은 M1 모델에서 사전 학습된 Convolutional base 를 기반으로 미세조정을 위한 분류기를 추가하였다. 미세조정을 위한 분류기 구조는 2 개의 layer 로 구성되어 있으며, 활성화 함수는 ReLu, 출력함수는 Sigmoid, 손실함수는 이진분류에 용이한 Binary Cross entropy 를 사용했고 최적화를 위해 RMSprop 알고리즘을 사용하였다. 모델의 학습 횟수는 100 epoch 이고 학습률은 0.001 이다.




그림 3. CNN 기반 모델 구조 (M1, M2)



그림 4. CNN 기반 모델 구조 (M3)

M1 모델을 학습 및 테스트할 때에는 다중 스크류 데이터셋을 활용했고, 총 데이터샘플 994 개 (정상 497 개, 이상 497 개)를 학습하였으며, 8:2 비율로 구분하여 각각 Training set 과 Test set 으로 활용하였다. M2 모델을 학습 및 테스트할 때에는 단일 커넥터 데이터셋을 활용했고, 총 데이터샘플 230 개 (정상 115 개, 이상 115 개)를 학습하였으며, 8:2 비율로 구분하여 각각 Training set 과 Test set 으로 활용하였다. M3 모델을 학습 및 테스트할 때에는 단일 커넥터 데이터셋을 활용했고, 총 데이터샘플 230 개 (정상 115 개, 이상 115 개)를 학습하였으며, 8:2 비율로 구분하여 각각 Training set 과 Test set 으로 활용하였다. 모델 M1-M3 에 대한 설명을 표 1 에 정리했다.

구조 \ 모델	M1	M2	M3
특징 추출	다중스크류 데이터셋 (전체모델 학습)	단일커넥터 데이터셋 (전체모델 학습)	M1 결과 사용
분류			단일커넥터 데이터셋 (미세조정)

표 1. 구조 및 모델 별 활용된 데이터셋

2.5 실험 결과

본 연구에서는 학습 및 테스트 데이터 세트를 사용하여 출력된 정확도 (Accuracy), 학습 소요시간 (Training Time)을 학습 방법의 평가 지표로 사용하였다. 결합 탐지 모델에 따른 정확도를 표 2 에 비교했다. 전이학습을 한 M3 모델이 M2 모델에 비해 약 24 % 단축된 시간에 같은 정확도를 보임을 확인할 수 있다.

평가지표 \ 모델	M1	M2	M3
정확도 (Accuracy, %)	99 %	100 %	100 %
학습시간 (Training Time, 초)	257 s	155 s	119 s

표 2. 결합 탐지 모델에 따른 정확도 비교

III. 결론

본 논문에서는 전이학습을 활용한 PCB 부품 별 조립결합 탐지 모델을 구축 방법을 제안했고, 시뮬레이션을 통해 부품별로 각각의 모델을 구축하는 것에 비해 제안하는 방법이 효과적임을 보였다. 실제 제조공정에서 이상데이터 수가 적고 부품별로 모델을 개발하기에는 많은 시간과 비용이 든다는 한계가 있기 때문에, 본 연구를 통해 각 부품 별로 모델을 구축하지 않아도 전이학습을 사용한 일반화된 결합 탐지 모델이 구축 가능함을 확인하였다.

ACKNOWLEDGMENT

이 논문은 2022 년도 정부(중소벤처기업부)의 재원으로 중소기업기술정보진흥원-제조데이터 공동활용 플랫폼 기술개발(인공지능비전 기반, 데이터 증강 및 결합 탐지 플랫폼 개발)사업의 지원을 받아 수행된 연구임(RS-2022-00156456). 이 논문은 산업통상자원부 "열공급망 수용가 빅데이터 기반 에너지관리 기술개발 및 실증" 사업의 연구비지원(20212020900150)에 의해 수행됨.

참 고 문 헌

- [1] 최원호, "딥러닝(CNN) 이용한 PCB 불량 검출 시스템 설계 및 구현," *한양대학교*, Feb. 2022.
- [2] J. Kim, J. Ko, H. Choi and H. Kim, "Printed Circuit Board Defect Detection Using Deep Learning via A Skip-Connected Convolutional Autoencoder," in *MDPI Sensors* 2021, no. 15:4968, July 2021.
- [3] J. Li, J. Gu, Z. Huang and J. Wen, "Application Research of Improved YOLO V3 Algorithm in PCB Electronic Component Detection," in *MDPI Applied Sciences*, no. 18:3750, Sep 2019.
- [4] E. Chalmers, E. B. Contreras and B. Robertson, "Learning to Predict Consequences as a Method of Knowledge Transfer in Reinforcement Learning," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 6, pp. 2259-2270, June 2018