

양산라인 실시간 품질 검사를 위한 딥러닝 기반 엣지컴퓨팅 비전 검사 장치

김량수, 유학, 김근용, 김성창
한국전자통신연구원

rskim@etri.re.kr

Deep Learning-based Edge Computing Vision Inspection Device for Real-time Quality Inspection on Mass Production Line

Ryangsoo Kim, Hark Yoo, Geun-Yong Kim, Sung chang Kim
Electronics and Telecommunications Research Institute (ETRI)

요 약

본 논문에서는 공장의 양산라인에서 생산되는 인덕터 제품의 코어 크랙 여부를 실시간으로 검출하기 위한 딥러닝 기반 엣지컴퓨팅 응용솔루션을 소개한다. 인덕터 제품의 비전 데이터 취득을 위해 4 채널 조명이 장착된 비전 검사 장치를 자체 제작하여 인덕터 코어 크랙 데이터셋을 구축하였고, Pytorch 프레임워크를 활용하여 컨볼루션 신경망으로 구성된 딥러닝 모델 학습을 수행하였다. 학습이 완료된 딥러닝 모델의 실험결과 코어 크랙 판별 정확도는 약 99%임을 확인하였으며, 학습이 완료된 모델을 Nvidia Jetson Nano 엣지컴퓨팅 플랫폼에서 수행한 결과 약 9 FPS 로 추론이 가능함을 확인하였다.

I. 서 론

전자제품에 주요부품으로 사용되는 인덕터는 부품 단가가 몇백원 수준의 비교적 저가의 부품으로 인식된다. 그러나, 인덕터의 불량으로 인해 발생하는 In-Rush Current 가 TV 와 같은 고가의 전자제품 회로에 유입되는 경우 SMPS 와 같은 주요 부품에 지속적인 타격을 입혀 제품 수명을 단축시키는 원인이 된다. 이와 같은 문제를 해결하기 위해서는 인덕터를 생산하는 양산라인에서 정밀한 제품 검사를 수행하여 인덕터 패키징 크랙 유무를 판별하는 검사가 필수적이다. 하지만 자동화된 양산라인에서 생산 일정에 차질없이 수많은 인덕터의 크랙 유무를 판별하기 위해서는 실시간으로 제품의 이미지 데이터를 취득하고 판별해내는 검사 장치가 필요하다.

최근 딥러닝 기술의 급격한 발전으로 인해 다양한 실생활 이미지와 영상 데이터 분석이 가능한 딥러닝 기반 비전 시스템이 다양한 응용서비스 분야에 적용되고 있다[1]. 특히, 딥러닝 기술이 기존의 기계학습 알고리즘 수준을 뛰어넘는 성능을 선보이면서 영상 기반 결함 검사 기술이 다양한 분야에 적용되고 있다[2]. 본 논문에서는 비전 기반 양산라인 실시간 품질 검사를 위해 딥러닝 기술을 적용한 엣지컴퓨팅 비전 검사 장치를 소개한다. 엣지컴퓨팅 기반 비전 검사 장치는 인덕터 코어의 크랙 유무를 판별하기 위해 4 채널 조명을 제어하여 인덕터 코어 이미지 데이터를 취득하고 딥러닝 모델 기반 코어 크랙 유무 판별을 통해 인덕터의 불량 여부를 판별한다. 인덕터 코어 크랙 유무 검출을 위한 딥러닝 모델의 학습을 위한 데이터셋은 자체 제작한 비전 검사 장치를 통해 양품과 불량품 인덕터 샘플에 대한 이미지 데이터를 획득하였다. 딥러닝 기반 불량 유무 판별을 위하여 컨볼루션 신경망으로 이진 분류(Binary Classification) 모델을 구성한 뒤 자체적으로 확보한 데이터셋을 활용하여 학습을




그림 1. 비전 검사 장치 개요도 및 실물 사진

수행하였다. 학습이 완료된 딥러닝 모델은 엣지컴퓨팅 플랫폼인 Nvidia Jetson Nano 보드에서 실시간 추론을 수행하여 실시간으로 불량 유무 판별이 가능한지 여부를 실험을 통해 확인하였다.

II. 비전 검사 장치

기존의 인덕터 제품 불량 여부를 판별하는 작업은 작업자가 단일 조명 아래에서 인덕터를 상하좌우로 움직여가며 코어 상단 패키지 부분의 크랙 또는 찍힘 여부를 확인하는 방식으로 수행된다. 이는 코어 상단의 크랙 또는 미세한 찍힘 여부가 조명의 각도에 따라서 보여지는 형태가 다르기 때문이다. 따라서, 인덕터 코어의 미세한 찍힘까지 판별할 수 있는 딥러닝 모델을 학습하기 위해서는 다양한 각도의 조명을 제어하여 다수개의 이미지 데이터 확보가 가능한 비전 검사 장치가 필요하다. 이를 위해, 우리는 4 채널의 조명 제어가 가능한 비전 검사 장치를 그림 1 과 같이 자체 제작하였다.

그림 1 과 같이 자체 제작한 비전 검사 장치를 이용하여 인덕터 코어 크랙 불량 검출을 위한 데이터셋을 확보하였다. 인덕터 코어 크랙 불량 검출 데이터셋은 총 1,563 개의 인덕터 샘플을 통해 수집하였으며, 각 샘플은 조명 각도에 따라 4 개의 이미지 데이터를 생성하여 총 6,252 개의 이미지 데이터를 생성하였다. 6,252 개의 이미지 중 정상 샘플




그림 2. 인덕터 코어 크랙 불량 검출 데이터셋 샘플

이미지는 5,444 개이고 비정상 샘플 이미지는 808 개이며, 딥러닝 학습용 데이터와 학습이 완료된 모델의 성능 검증을 위한 테스트 데이터의 비율은 1:1로 설정하였다. 딥러닝 모델의 학습을 수행함에 있어서 딥러닝 모델의 과적합(overfitting) 여부를 확인하기 위한 검증용 데이터는 학습용 데이터의 20%를 따로 분리하여 사용하였다.

그림 2는 비전 검사 장치를 통해 획득한 인덕터 코어 크랙 이미지 데이터셋 샘플이다. 그림 2에서 정상 샘플은 코어 표면이 매끄러운 반면에 비정상 1과 같이 코어의 상단부가 깨지거나 비정상 2와 같이 크랙이 발생하거나 비정상 3~7에서와 같이 찍힘이 발생한 샘플이 비정상 샘플 데이터로 확보되어 있다. 위의 그림에서 비정상 6과 비정상 7은 동일한 샘플에 대하여 조명 각도 변경에 따라 촬영된 이미지 데이터이다. 동일한 미세 불량에 대하여 비정상 6 이미지에서는 육안으로 확인이 어려운 반면에 다른 각도의 조명 환경에서 촬영된 비정상 7 이미지는 미세 불량이 좀 더 명확하게 드러나는 것이 확인 가능하다.

위와 같이 자체적으로 확보한 데이터셋을 활용하여 인덕터 코어 크랙 불량 검출 여부를 판별하는 딥러닝 모델 학습을 수행하였다. 딥러닝 학습은 Pytorch 프레임워크를 이용해 수행되었으며, 이미지 기반 데이터셋으로 불량 검출을 수행하기 때문에 컨벌루션 신경망으로 구성된 딥러닝 모델을 생성하였다. 그림 3은 해당 딥러닝 모델에 대한 구조도를 나타낸다.

III. 실험 결과

비전 검사 장치를 통해 수집한 인덕터 코어 크랙 불량 검출 데이터셋을 활용하여 그림 3의 구조로 구성되어 있는 딥러닝 모델 학습을 수행하였다. 모델의 학습은 TITAN X 12GB GPU가 장착되어 있는 딥러닝 서버(Intel i7 8core)에서 20 epochs 동안 수행되었으며, 단일 epoch마다 테스트 데이터셋을 활용하여 모델의 성능평가를 수행하였다. 표 1은 20 epochs 중에서 가장 성능이 좋았던 19 epoch 학습 완료된 딥러닝 모델의 성능 지표 결과값을 나타낸다. 인덕터 코어 크랙 검출 데이터셋의 경우 정상 샘플과 비정상 샘플의 데이터 밸런스가 맞지 않기 때문에 F1-score를 모델 성능의 지표로 사용하였다.

표 1의 결과에서 알 수 있듯이 학습이 완료된 딥러닝 모델은 정상 및 비정상 샘플 판별에 대한 정밀도(Precision)는 100%를 달성하였으나 비정상 샘플에 대한 민감도(Recall)의 경우 98%를 달성함을 확인하였다. 비정상 샘플에 대한 민감도 98%가 의미하는 것은 비정상 샘플 중에서 2% 정도가 딥러닝 모델 추론




그림 3. 컨벌루션 신경망 기반 딥러닝 모델 구조

표 1. 인덕터 코어 크랙 판별 딥러닝 모델 추론 결과

	Precision	Recall	F1-score	Support
비정상	1.0	0.98	0.99	448
정상	1.0	1.0	1.00	2688

결과 정상으로 판별되고 있음을 의미한다. 인덕터 코어의 결함으로 인한 피해를 최소화하기 위해서는 정상 샘플에 대한 민감도를 손해보더라도 비정상 샘플에 대한 민감도를 100% 수준으로 향상시키는 것이 바람직하다. SVM과 같은 기존의 기계학습 방법의 경우 매개 변수를 조정하는 것이 가능하지만 딥러닝 모델의 경우 loss 함수에서 비정상 샘플을 정상으로 인식하는 케이스에 대한 loss 값에 가중치를 줘서 조절이 가능할 것이라 예상된다.

학습이 완료된 딥러닝 모델을 엡지컴퓨팅 환경에서 실험하기 위하여 Nvidia Jetson Nano 보드에서 추론 성능을 측정하였다. Jetson Nano 보드에서의 딥러닝 모델의 추론 실험을 위해 오픈소스 프로젝트인 TVM 컴파일러를 이용하여 Pytorch 모델을 TVM 런타임에서 실행가능하도록 컴파일을 수행했으며, 실험에 사용된 Jetson Nano는 cuda 10.2 버전을 기반으로 한 Jetpack 4.4 이미지를 사용하였다. 딥러닝 서버에서 추론 성능은 약 83FPS 정도가 나오지만 Nvidia Jetson nano 보드에서는 약 9FPS로 처리가 가능함을 확인하였다.

IV. 결론

본 논문에서는 공장 양산라인에서 생산되는 인덕터의 크랙 여부를 실시간으로 판별하기 위한 딥러닝 기반 엡지컴퓨팅 비전 검사 장치를 소개하였다. 비전 검사 장치를 개발함에 있어서 자체 제작한 4 채널 조명 제어 가능 비전 검사 장치를 이용해 인덕터 코어 크랙 검출을 위한 데이터셋을 확보하였고, 컨벌루션 신경망으로 이뤄진 이진 분류 딥러닝 모델을 학습시킨 뒤 엡지컴퓨팅 플랫폼에 적용하여 실시간으로 인덕터 코어 크랙 유무 판별이 가능함을 확인하였다.

ACKNOWLEDGMENT

본 연구 논문은 한국전자통신연구원 연구운영지원 사업의 일환으로 수행되었음. [호남권 지역산업 기반 ICT 융합기술 고도화 지원사업 (21ZK1100)]

참 고 문 헌

- [1] K. Yun *et al.*, "Vision-based garbage dumping action detection for real-world surveillance platform," in *ETRI Journal*, vol. 41, no. 4, pp. 494-505, Aug. 2019.
- [2] 이건영, 정선재, 서기성, "결함 검출을 위한 임베디드 딥러닝 시스템," 전기학회논문지, 69(2), pp. 325-330, 2020.02.