

제조분야 자동 품질 검사를 위한 딥러닝 기반 대형 이미지 분류시스템 개발 및 구축

김진호
경희대학교
이과대학

icbf98@khu.ac.kr
제조
분야 자동 품질
검사를 위한 딥러닝
기반 대형 이미지
분류 시스템 개발
및 구축

권준우
경희대학교
이과대학

jwkwon@khu.ac.kr

황보유정
경희대학교
이과대학

hwangbo@khu.ac.kr

이경전
경희대학교
경영대학

klee@khu.ac.kr

Abstract - 딥러닝 알고리즘의 발전에 따라, 다양한 산업분야에서의 딥러닝의 도입이 가속되고 있다. 제조분야의 경우 딥러닝을 적용하는데 있어 기존 적용 기술의 정확도를 상회해야 하며, 제한된 시간 내에 프로세스가 완료되어야 한다. 본 연구에서는 나사 제조 분야에서의 제약 조건 및 성능 조건을 만족하는 딥러닝 기반 대형 이미지 분류 시스템을 구축하였다. 결품 분류 공정 중 획득할 수 있는 대형 이미지 사진을 기반으로, 요구 조건인 분류 정확도 95%와 연산시간 0.2초를 만족할 수 있는 딥러닝 모형을 구현하였다. 이미지의 전처리를 위해 Hough Circle 과 PCA 를 사용하고, VGG 모형을 기반으로 CNN 의 구조를 설계하였으며, 연산 속도 0.2초 내에 분류 정확도 99% 및 가 가능성을 확인하였다.

Key Terms - Convolution Neural Network, Deep Learning, Manufacturing, Deep Learning Application, Image Classification

사사표기 (논문 지원기간이 있는 경우, 여기에 표기)

I. 서론


딥러닝 알고리즘의 발전에 따라, 의료, 제조 등 다양한 분야에서의 활용이 증가하고 있다. 특히, Convolution Neural Network(CNN)의 발전에 따라 컴퓨터 비전 분야는 매년 발전을 거듭하고 있으며, 분류 정확도는 인간의 시야와

비슷하거나, 더 높은 수준을 보이고 있다. 하지만, 최근에 개발되고 있는 모형들은 많은 양의 연산을 필요로 하기 때문에, 공정별 시간이 제한되어 있어 제한된 시간내 모든 연산을 수행해야 하는 제조와 같은 분야에는 쉽게 적용되기 어렵다. 또한 산업 분야에서는 기존에 존재하는 알고리즘의 정확도를 상회하지 않는 경우, 각 기업에서는 도입이 매우 어렵다. 따라서, 실제 산업에 딥러닝이 적용되기 위해서는 기업이 요구하는 제약 조건하에서 요구치 이상의 정확도를 산출 할 수 있는 모형의 개발이 필수적이다. 본 연구에서는 너트류 제조회사인 (주)프론텍의 나사 자동 품질 검사 시스템을 구축하였으며, 회사의 제약조건을 만족할 수 있는 모형을 개발하였다. (주)프론텍의 공정에 따른 자동 검사 시스템의 시간적 제약 조건은 이미지 입력부터 연산 완료까지 0.2초 내 수행을 목표로 하며, 최소 95% 이상의 정확도를 필요로 한다. 본 연구에서는 VGG 모형 및 다수의 모수의 조정을 통해 정상/불량 구분 평균 정확도 98% 이상이 가능성을 확인하였다. 또한 VGG 의 가중치를 절반으로 줄임으로써 0.2초 내에 연산이 가능하도록 설계 및 구현하였다.

II. 데이터 및 전처리


결품 검사 공정에서 수집되는 원본 이미지는 <그림 1>과 같다. 결품 검사 공정은 나사의 윗면과 아랫면으로 나누어지며, 각 면에 대한 검사를 통해 하나 이상의 결품요소가 발생하는

경우 결품으로 분류하는 문제이다. 본 문제를 해결하기 위해 축적된 이미지는 1900x1200 픽셀의 크기이며, 윗면 (총 1198 장)의 경우 양품 500 장, 불량-터짐 431 장, 불량-찍힘 267 장, 아랫면 (총 2,031 장)의 경우 양품 500 장, 불량-내부칩 658 장, 불량-찍힘 410 장, 불량-돌기부찍힘 463 장을 활용하였다.




<그림 1> 나사 검사 공정에서 획득한 원본 이미지

본 이미지에 Hough Circles 알고리즘을 적용하여 배경을 제외하고 다음과 같이 나사 부분만을 750x750(픽셀)로 추출하였다 (<그림 2> 참조). <그림 2>에 각 결함 위치를 빨간색 원으로 표시하였다.



<그림 2> Hough circles 알고리즘을 적용한 이미지

또한 분류 정확도를 높이기 위하여 모든 양품 이미지의 픽셀 값을 기반으로 하여 PCA를 적용하여 압축 후, 다시 750x750으로 reverse trasformation을 적용하였다. 정상 PCA 이미지를 기반으로 타 이미지와의 차이 값을 활용하여 최종 입력 이미지로 사용하였다.



<그림 3> PCA 알고리즘을 적용한 양품 사진과 최종 입력 이미지

또한, 학습 이미지의 확보 및 다양한 조건에서의 견고성을 확보하기 위하여, 학습 이미지에 대해 무작위로 90, 180, 270 회전 및 좌우 반전을

적용하였다. 이는 학습 및 테스트 과정 모두에 적용하였다.

III. 모델 설계 및 파라미터 설정

본 연구에서는 4 종류의 모델을 설계하였다. 윗면 / 아랫면 각각에 대해 양품과 결품 여부를 분류하는 이진 분류 모형과, 결품의 유형을 분류하는 모형을 구현하였다. 모든 모델은 VGG를 기반으로 구성하였다 (Simonyan, K., and Zisserman, A., 2014). 본 연구에서는 연산 시간 제약 조건을 해결하기 위해 VGG에서 사용되는 kernel map의 수를 모두 절반으로 축소하였으며, fully connected layer는 기존 VGG의 값을 그대로 활용하였다.

또한, 다양한 모수에 대한 실험을 통해 최적의 조건을 산출하였다. 첫번째로, 학습에 대한 학습률 (learning rate)은 10^{-2} 부터 10^{-7} 까지 순차적으로 실험하였으며, Adam optimizer, RMSProp, Adaptive Gradient를 변경하며 실험하여, 학습률 10^{-6} 과 Adam optimizer에서 가장 높은 정확도를 보임을 확인하였다. 또한, Batch Size에 대한 연구(Keskar, N. S., et. al, 2016)를 토대로 256부터 16까지의 batch-size를 실험하였으며, 이 중 16의 batch-size가 가장 높은 성능을 보임을 확인하였다. 마지막으로 규격화를 위해 Batch-Normalization 기법을 도입하였으나, 기존 Dropout에 비해 성능이 좋지 않음을 확인하였으며, Dropout rate 0.5에서 가장 좋은 성능이 보임을 확인하였다. 최종적으로 분류에서 사용된 모형은 kernel map size를 절반으로 줄인 VGG이며, learning rate는 10^{-6} , Batch Size는 16, Optimizer는 Adam, 모든 layer에 rate를 0.5로 하는 Dropout을 적용하여 분석하였다.

IV. 결과

본 연구를 통해 윗면-이진분류의 경우 평균 98.54% ($\pm 1.34\%$)의 정확도를 보임을 확인하였으며, 분류 검사에 평균 0.07초가 소요됨을 확인하였다. 아랫면-이진분류의 경우 99.43% ($\pm 0.83\%$)의 정확도를 보임을 확인하였으며, 분류 검사에 평균 0.07초가 소요됨을 확인하였다. 따라서, 정상-불량의 이진 분류에 모두 0.14초가 소요됨을 확인할 수 있었다 (<표 1> 참조). 이 외에 윗면-불량유형의 경우 평균 91.50% ($\pm 2.86\%$), 아랫면-불량유형의 경우 평균 89.26% ($\pm 4.74\%$)을 보임을 확인하였다.

<표 1> 모델의 정확도 및 연산시간

모델	분류 정확도	연산시간
윗면, 이진분류	98.54 %	0.07 sec

모델	분류 정확도	연산시간
윗면, 이진분류	98.54 %	0.07 sec
아랫면, 이진분류	99.43 %	0.07 sec
윗면, 불량분류	91.50 %	0.07 sec
아랫면, 불량분류	89.26 %	0.07 sec

이 외에 PCA 에 대한 효과를 확인하기 위하여, PCA 를 적용하지 않은 데이터에 대하여 동일 연산을 수행하였다. 윗면-이진분류의 경우 98.03%, 윗면-불량유형 90.38%, 아랫면-이진분류 90.4%, 아랫면-불량유형 87.3%로 PCA 전처리를 적용한 모형이 더 좋은 결과를 보임을 함께 확인하였다.

V. 참고문헌

Simonyan, K., and Zisserman, A., Very deep convolutional networks for large-scale image recognition. arXiv preprint, arXiv:1409.1556, (2014).

Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., and Tang, P. T. P. (2016). On large-batch training for deep learning: Generalization gap and sharp minima. arXiv preprint arXiv:1609.04836.