

전이학습 기반 CNN을 통한 폴림 방지 코팅 볼트 이진 분류에 관한 연구

노은솔¹, 이사랑¹, 홍석무^{1,2*}

¹공주대학교 미래융합공학과, ²공주대학교 미래자동차공학과

Binary classification of bolts with anti-loosening coating using transfer learning-based CNN

Eunsol Noh¹, Sarang Yi¹, Seokmoo Hong^{1,2*}

¹Department of Future Convergence Engineering, Kongju National University

²Department of Future Automotive Engineering, Kongju National University

요약 폴림 방지 코팅 볼트는 주로 자동차 안전 관련 부품을 결합하는 데 사용되므로 안전성 유지를 위해 코팅 결함을 사전에 감지해야 한다. 이를 위해 이전 연구 [CNN 및 모델 시각화 기법을 사용한 코팅 볼트 불량 판별]에서는 합성곱 신경망을 사용했다. 이때 합성곱 신경망은 데이터 수가 많을수록 이미지 패턴 및 특성 분석 정확도가 증가하지만 그에 따라 학습시간이 증가한다. 또한 확보 가능한 코팅 볼트 샘플이 한정적이다. 본 연구에서는 이전 연구에 전이학습을 추가적으로 적용해 데이터 개수가 적은 경우에도 코팅 결함에 대해 정확한 분류를 하고자 한다. 전이학습을 적용할 때 학습 데이터 수와 사전 학습 데이터 ImageNet 간의 유사성을 고려해 분류층만 학습했다. 데이터 학습에는 전역 평균 풀링, 선형 서포트 벡터 머신 및 완전 연결 계층과 같은 분류층을 적용했으며, 고려한 모델 중 완전 연결 계층 방법의 분류층이 가장 높은 95% 정확도를 가진다. 추가적으로 마지막 합성곱층과 분류층을 미세 조정하면 정확도는 97%까지 향상된다. 전이학습 및 미세 조정을 이용하면 선별 정확도를 향상시키는 물론 이전보다 학습 소요시간을 절반으로 줄일 수 있음을 보였다.

Abstract Because bolts with anti-loosening coatings are used mainly for joining safety-related components in automobiles, accurate automatic screening of these coatings is essential to detect defects efficiently. The performance of the convolutional neural network (CNN) used in a previous study [Identification of bolt coating defects using CNN and Grad-CAM] increased with increasing number of data for the analysis of image patterns and characteristics. On the other hand, obtaining the necessary amount of data for coated bolts is difficult, making training time-consuming. In this paper, resorting to the same VGG16 model as in a previous study, transfer learning was applied to decrease the training time and achieve the same or better accuracy with fewer data. The classifier was trained, considering the number of training data for this study and its similarity with ImageNet data. In conjunction with the fully connected layer, the highest accuracy was achieved (95%). To enhance the performance further, the last convolution layer and the classifier were fine-tuned, which resulted in a 2% increase in accuracy (97%). This shows that the learning time can be reduced by transfer learning and fine-tuning while maintaining a high screening accuracy.

Keywords : Bolts With Anti-loosening Coating, Convolutional Neural Networks, Transfer Learning, Fine-tuning, Fully Connected Layer

*Corresponding Author : Seokmoo Hong(Kongju National Univ.)

email: smhong@kongju.ac.kr

Received October 17, 2020

Accepted February 5, 2021

Revised October 28, 2020

Published February 28, 2021

1. 서론

자동차나 전자 제품과 같은 기계 및 장비들은 많은 부품들의 조립으로 제작되며, 부품간 체결 및 고정을 위해 볼트가 사용된다. 볼트는 적정 토크가 가해지면 축력 및 체결력이 작용해 체결체와 고정된다. 그러나 체결체 사이에 접촉 마찰력보다 큰 충격 또는 진동 등의 외부 힘이 가해지면 공간차가 발생해 이로 인해 체결된 볼트가 풀리게 된다. 볼트 풀림 문제를 방지하기 위해 다양한 방법이 개발되고 있으며, 이 중 한 가지 예로 볼트 풀림 방지 코팅 볼트가 있다. 코팅 볼트는 나사산 사이에 풀림 방지 코팅액을 도포해 마찰력을 높이고 체결력을 안정화하는 방식이다. 코팅 볼트는 도입, 도포, 건조 및 선별 총 4가지 공정으로 생산되며, 코팅액은 Fig. 1과 같이 볼트를 회전시키면서 도포된다. 이때 도포 공정 특성상 코팅액 분포가 균일하지 않아 양품과 불량품을 선별하는 공정이 필수적으로 행해진다. 실제 현장에서 선별 공정은 육안이나 비전 선별기로 수행된다. 그러나 기존 비전 선별기는 다양한 형태의 볼트에 대해 선별이 불가능하며, 단순히 색상만으로 불량을 판단하기 때문에 대부분을 육안 선별에 의존하게 된다. 그러나 피로감으로 인해 선별 정확도 및 속도가 저하되고 인건비 등의 소요 비용문제가 있다. 이와 같은 문제점을 개선하기 위해 이전 연구에서는 제품의 결합 검출에 적용되고 있는 딥러닝을 사용하여 불량량을 선별했다[1]. 이때 딥러닝 기법 중 합성곱 신경망(CNN: Convolutional Neural Networks)을 사용해 VGG16 구조로 학습했으며, 이미지 데이터는 실제 선별 공정과 유사하게 제작된 지그로 촬영됐다. 딥러닝은 데이터를 사용하여 특징과 패턴을 찾아 분류




Fig. 1. application of anti-loosening coating

하기 때문에 데이터 양이 많을수록 보다 좋은 성능을 확보할 수 있다. 그러나 이전 연구에서는 양품/불량 코팅 볼트 샘플이 한정적이라 확보 가능한 데이터의 한계로

총 652장만을 사용했다. 또한 많은 양의 데이터를 확보 하더라도 하드웨어 성능의 한계가 있고 VGG16의 모든 층을 학습하기에 소모되는 시간이 길다.

코팅 볼트와 같이 다양한 결함을 갖는 제품에 대해 판별할 때 딥러닝 방법이 많이 활용되지만 데이터 확보에 한계가 있어 제한된 데이터를 사용해야 하는 경우가 있다. 이처럼 학습데이터가 적은 경우, 높은 성능을 확보하기 위해 전이학습이 많이 사용된다. 전이학습은 ImageNet이나 OpenImage와 같은 대용량 데이터 셋으로 사전 학습된 가중치를 사용하여 새로운 데이터 특징을 추출하고 분류하는 방법이다. 모든 층을 학습하지 않고 부분적인 학습을 진행하기 때문에 학습 시간 절감 뿐만 아니라 성능에서도 효율적이다. Ferguson 등[2]은 전이학습을 사용해 적은 데이터 세트(set)에 대해 CNN으로 높은 정확도를 갖는 주요 결합 구분 알고리즘을 구축했다. Gopalakrishnan 등[3]은 포장 도로 내 균열 이미지를 전이학습으로 분류해 좋은 성과를 얻었다. 이에 본 연구에서도 적은 양의 데이터로도 좋은 성능을 확보하고 학습 시간 또한 단축시키기 위해 전이학습을 활용한다. 이전 연구에서 사용한 VGG16을 채택하고, 사전 학습 가중치는 일반적으로 많이 사용되는 ImageNet을 적용한다[4]. 이와 같은 조건으로 코팅 볼트 데이터 특징을 추출하고 ImageNet과 유사도 및 데이터 개수를 고려해 분류층을 학습한다. 이때 분류층은 여러 방법을 비교해 코팅 볼트 선별에 가장 적합한 방법을 적용한다. 추가적으로 미세 조정(fine-tuning)하여 코팅 볼트 분류 모델의 성능을 향상시키고자 한다.

다음 절에서는 전이학습 및 분류층에 대한 이론을 설명하고 코팅 볼트 데이터와 증식 방법 및 분류층 비교 결과는 3절에서 기술한다. 또한 전이학습 기반 VGG16 모델로 학습 및 미세조정 후 결과를 비교 분석해 4절에서 결론을 제시한다.

2. 본론

2.1 VGG16 및 전이학습

딥러닝 기법 중 하나인 CNN은 합성곱 신경망으로 영상 및 이미지를 입력 데이터로 받아 필터링 기법을 인공 신경망에 적용하는 분류 기법이다. 이미지에서 특징 및 패턴을 찾아 분류하기 때문에 많은 분야에서 사용된다[5]. 특히 기계나 생산 제품 내 결함은 위치별로 크기가 일정하지 않고 형상이 매우 다양하기 때문에 제조 산업


에서 제품 내 결함을 검출하기 위한 방법으로 많이 사용되고 있다[6]. 이 때 딥러닝은 이미지에서 추출한 패턴과 특징을 비교 분석하여 선별하기 때문에 이미지를 학습할 때 많은 데이터 수가 요구되지만 여러 조건과 상황들로 인해 충분한 데이터 확보가 불가능한 경우가 있다. 예를 들어 항공 엔진과 같은 고가의 제품은 경제적 비용 문제로 샘플 개수가 한정적이므로 학습하기에 충분한 데이터를 얻는 것이 불가능하다[7]. 또한 생산된 제품 중 불량 개수가 매우 적어 양품과 불량품 데이터 세트의 균형을 맞출 경우 학습에 사용가능한 데이터 양이 적어진다[8].

이와 같이 여러 원인으로 데이터 개수가 제한될 때 높은 성능을 확보하기 위한 방법들이 있다. 일반적으로 빅 데이터로 사전 학습된 가중치만을 사용하여 특징을 추출하는 방법이 주로 사용되며, 이를 전이학습[9]이라 한다. 처음부터 모든 데이터를 각각 학습하는 기계 학습과 달리 전이학습은 사전 학습된 소스(source) 데이터의 가중치를 사용해 타겟(target) 데이터에 맞는 모델을 구축한다[10] (Fig. 2). 때문에 학습에 소요되는 시간이 감소되며, 성능 또한 향상되는 장점이 있다. 사전 학습에 쉽게 사용 가능한 이미지 데이터 세트는 일반적으로 ImageNet, CIFAR 등이 있다. 이때 소스 데이터와 타겟


데이터의 유사성 및 이미지 크기를 고려해 동결할 층과 초기화하여 학습할 층을 구분해야 한다. 학습할 데이터 수가 적고 사전 학습 데이터와의 유사성이 클 경우 미세 조정을 할 때 과적합이 발생할 수 있다. 두 번째로 데이터 수가 많고 유사성이 클 경우 전체적인 층에 미세 조정이 가능하다. 데이터 수가 적고 유사성이 작은 경우에는 분류층 뿐만 아니라 마지막 합성곱층(convolution layer) 또한 고려해야 하며, 데이터가 많고 유사성이 작은 경우는 전체 층에 대해 미세 조정되어야 한다.

2.2 분류층(classifier layer) 종류 및 특징

전이학습 기반 VGG16 구조는 크게 두 부분으로 나뉜다. 첫 번째는 이미지에서 특징을 추출하는 합성곱층과 특징을 하나의 클래스로 선별하는 분류층으로 나뉜다. 분류층은 일반적으로 모든 계층이 연결되어 있는 완전 연결 계층(FC: Fully Connected)이 많이 사용된다. 그 외 전역 평균 풀링(GAP: Global Average Pooling)과 선형 서포트 벡터 머신(LSVM: Linear Support Vector Machines) 분류 방법이 있다. GAP[11]은 합성곱 층을 통해 추출된 특징을 일정 영역 내 평균을 계산하여 하나의 값으로 출력하는 방법이다. LSVM[12]은 합성곱 층에서 추출된 특징에 대해 지도학습 방법 SVM으로 분류하는 방법이다. 특히 L2-norm SVM은 MINST 및 CIFAR-10 표준 데이터 세트를 학습할 때 활성화 함수 소프트맥스(softmax) 보다 좋은 결과를 보인다. 그러나 각 분류층은 데이터에 따라 정확도가 달라지므로 비교 및 분석을 통해 코팅 볼트 분류에 가장 적합한 분류층을 사용하고자 한다.



(a) Traditional Machine Learning



(b) Transfer Learning

Fig. 2. Different between the learning processes of traditional and transfer learning[9]

3. 연구방법

3.1 데이터 세트

이전 연구와 학습 소요 시간과 성능을 비교하기 위해 동일한 크기 및 종류의 볼트를 사용한다. 양품 [Fig. 3 (a)] 및 불량품 [Fig. 3 (b)]은 코팅된 길이, 이물질 부착 및 패임 여부, 코팅 미도포에 따라 분류되며, 분류 기준은 전과 동일하다. 이와 같은 기준을 적용해 분류된 불량 종류는 미코팅, 패임, 이물질 및 길이 불량이며, 이를 Fig. 3에 나타냈다. (b)에 나타낸 불량은 왼쪽 상단부터 시계 방향으로 길이, 미코팅, 패임 및 이물질 불량이고 해당 위치를 붉은색 실선으로 표기했다. 앞서 제시한 이미지를 학습 데이터로 사용하기 전 복잡한 배경 요소의 영향도

를 줄이고자 이미지 전처리 기법을 사용했다. 이전 연구에서 사용된 이진화(binary), 형태 변환(morph) 및 거리




Fig. 3. Examples of bolts with (a) good and (b) defective coatings

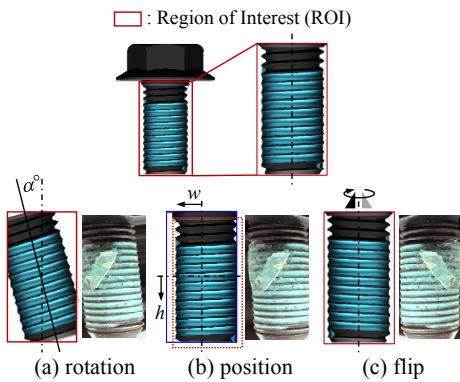


Fig. 4. Data augmentation method

변환(distance transform) 이미지 필터링 방법은 볼트 자체 색상과 배경 색상이 흡사하여 명확한 분리가 어렵다. 따라서 볼트 나사산 영역만을 관심 영역으로 지정하여 이미지를 분할해 사용했다. 확보된 전체 데이터 개수는 총 652장이며 양품과 불량 개수가 각각 326장으로 동일하다. 확보한 데이터 양이 적기 때문에 최대한 많은 특징을 추출하도록 임의로 기하학적인 변형을 가해 보다 많은 이미지를 학습하는 효과를 낸다 (Fig. 4). 이때 이미지 내 불량 위치 및 크기가 다양하기 때문에 많은 변형을 가하면 이미지 상에서 결함 확인이 불가할 수 있다. 따라서 이를 고려하여 이미지 변형할 때 회전 [Fig. 4 (a)], 수평 및 수직 방향 평행 이동 [Fig. 4 (b)] 및 수평 대칭 [Fig. 4 (c)]을 사용해 임계값을 지정했다. 회전 각도(a) 범위는 $\pm 10^\circ$, 수평 및 수직 방향 평행 이동(w)은 이미지 크기의 0.1비율로 이동을 제한했다.

3.2 코팅 볼트 분류를 위한 전이학습

3.2.1 사전 학습 가중치 및 분류층

전이학습은 적은 데이터 셋으로도 모델 정확도를 향상시킬 수 있다. 또한 일반적으로 모든 층을 학습하는 기계 학습보다 학습 시간이 적다. 전이학습의 이와 같은 성능을 비교하기 위해서 이전 연구와 동일한 조건 및 모델을 사용해야 한다. 따라서 CNN 기반 VGG16을 사용하며, 사전 학습 가중치는 일반적으로 많이 사용되는 ImageNet을 사용한다. ImageNet 데이터 세트는 총 1000개의 클래스를 분류할 수 있다. 이때 분류하고자 하는 코팅 볼트는


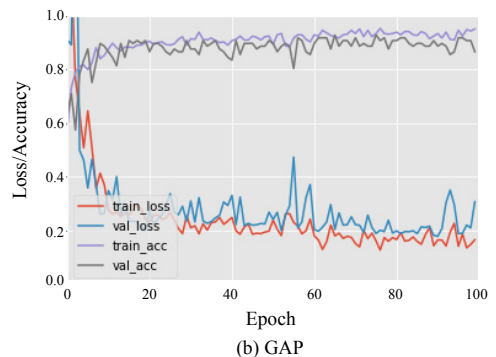



Fig. 5. Accuracies and losses of the 3 models identified according to classifier layer

ImageNet 데이터와 유사하지 않고 해당 클래스가 존재하지 않는다. 그러나 여러 분야에서 ImageNet을 적용한 연구를 볼 때 타겟 데이터가 소스 데이터와 유사도가 적고 연관성이 없음에도 적용 가능성을 보인다. Shin 등 [13]은 의료 분야에서 ImageNet 가중치를 사용해 간질성 폐질환과 흉부 복부 림프절 CT 이미지를 분류했으며, Kim 등 [14]은 외래 종류 16개종을 ImageNet과 VGG19를 사용해 분류했다. 특히 ImageNet과 가장 연관성이 적은 제조 산업에서 발생하는 결함 분류에도 적용 가능성을 보였다[15]. 이는 ImageNet으로 사전 학습된 가중치만을 사용하여 합성곱층에서 이미지의 특징만을 추출하기 때문에 유사성이 적음에도 분류가 가능하다.

전이학습은 section 2.1에 제시한 것처럼 사전 학습된 가중치를 사용할 때 타겟 데이터 개수 및 소스 데이터와의 유사성 모두 고려하여 각 상황에 맞게 사용해야 보다 정확한 모델을 구현할 수 있다. 따라서 코팅 볼트 데이터의 수가 작고 ImageNet과 유사성이 적음을 고려하여 합성곱층의 가중치를 동결시키고 분류층을 학습한다. 이때 분류층은 세 가지 방법을 비교하여 코팅 볼트 분류에 가장 적합하며, 가장 좋은 성능을 보이는 방법을 사용한다. section 2.3에서 제시한 FC, GAP 및 SVM 세 가지 방법을 적용했으며, 모두 동일한 조건 python3.7, Tensorflow 2.0을 사용하여 학습했다. FC와 GAP은 Dropout 0.5를 적용하였으며, 출력층에서 활성화 함수 소프트맥스를 사용했다. SVM은 penalty를 2로 설정하고 손실은 squared hinge로 기본값을 사용했다. 분류층 종류에 따른 학습 결과는 Fig. 5와 같으며, 이는 epoch별 모델 정확도와 손실값을 나타낸 그래프이다. 그래프에 따르면 FC와 GAP 분류층은 큰 차이를 보이지는 않지만 2~3% 정도의 차이로 FC의 정확도가 더 높다. SVM 분류층의 경우는 학습 정확도가 모두 100%를 유지한다. 이는 과적합의 경향을 보이므로 사용하기 적합하지 않다. 따라서 코팅 볼트 분류층으로 FC를 사용하고자 한다.

3.2.2 전이학습

마지막 합성곱층 이후 FC 층은 초기화하여 추출된 특징 벡터와 코팅 볼트 데이터에 맞게 학습했다 (Fig. 6). Batch size는 32, epoch은 100으로 설정했으며, 활성화 함수 소프트맥스로 클래스를 결정했다. 코팅 볼트 선별은 양품/불량 이진 분류이므로 활성화 함수로 시그모이드(sigmoid)가 더 적절하나, 결과적으로 소프트맥스와 차이가 없으며, 이전 연구와의 비교 분석을 위해 동일한

활성화 함수 소프트맥스를 사용한다. 이를 검증하고자 양품 및 불량 데이터 각 66장을 분류했으며, 이에 대한 결과를 Table 1에 정밀도(P : Precision), 재현율(R : Recall), 조화 평균(F_1 : F1-score)으로 나타냈다. 이는 Eq. (1), (2)와 Eq. (3)으로 구한 값이다. epoch별 학습 그래프 Fig. 5를 볼 때 모델 정확도는 약 95%이며, 검증 정확도 또한 동일하다. 그러나 이는 이전 연구에서 모든 층을 학습한 결과 97%에 비해 정확도가 낮다. 전이학습은 다른 데이터 가중치를 사용했기 때문에 모든 층을 학습했을 때보다 정확도가 낮아질 수 있다. 따라서 코팅

Table 1. Validation of CNN VGG16 based on transfer learning

	P	R	F_1	Support
NG	0.95	0.94	0.95	66
OK	0.94	0.95	0.95	66

$$P_{OK} = \frac{TP}{TP+FP}, P_{NG} = \frac{FN}{FN+TN} \quad (1)$$

$$R_{OK} = \frac{TP}{TP+FN}, R_{NG} = \frac{TN}{FP+TN} \quad (2)$$

$$F_{L_{OK}} = \frac{2P_{OK}R_{OK}}{P_{OK}+R_{OK}}, F_{L_{NG}} = \frac{2P_{NG}R_{NG}}{P_{NG}+R_{NG}} \quad (3)$$




Fig. 6. Structure of VGG16 based on transfer learning

볼트 분류 모델의 성능을 개선하고자 학습 레이어 개수를 늘려 미세 조정한다.

3.3 실험 결과 및 미세조정

미세 조정 방법은 사전 학습된 모델을 분류하고자 하는 데이터에 맞게 가중치를 조절하는 방법이다. 전이학습에서는 분류층만을 학습했으나 VGG16 모델의 마지막 합성곱층 또한 같이 학습시켜 성능을 향상시킨다. 이때 과적합을 방지하기 위해서 합성곱층과 최대풀링(MaxPooling)으로 특징을 추출하는 Block 1~4까지 모두 고정시키고 마지막 합성곱층 Block5와 FC층의 가중치만 미세조정 한다. 학습율은 아주 작은 값 0.0001을 사용했으며, epoch 50 및 SGD, 경사하강법으로 안정적인 학습속도를 유지하며 이전 학습의 가중치 훼손을 방지했다.

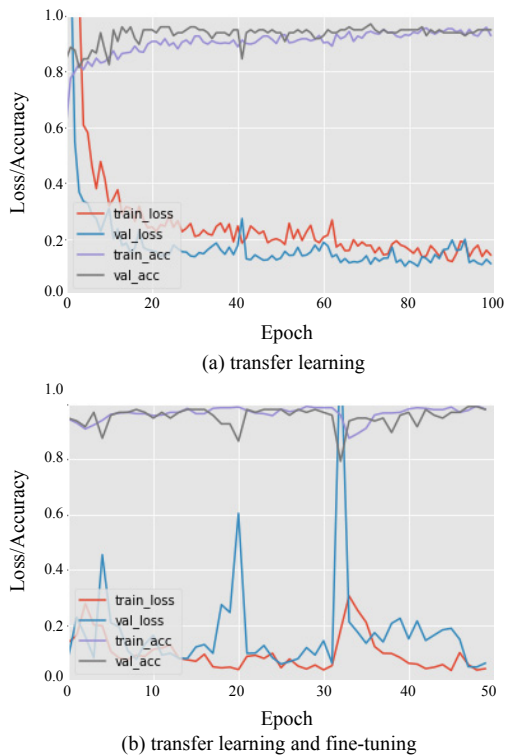


Fig. 7. Accuracies and losses of training and validation based on transfer learning and fine-tuning

Table 2. Validation of CNN VGG16 algorithm based on transfer learning and after fine-tuning

	<i>P</i>	<i>R</i>	<i>F₁</i>	Support
NG	0.96	0.98	0.97	66
OK	0.98	0.95	0.97	66

미세 조정된 모델을 검증하고자 이전 모델에서 사용한 테스트 데이터 132장으로 재확인했다. 결과적으로 모델 정확도는 약 98%, 검증 정확도는 97%이며, 이전 학습보다 2~3%정도 향상됨을 보였다 (Table 2). Fig. 7에 전이 학습(a)과 미세조정(b)한 후 정확도 및 손실을 나타내 비교했다. epoch 초기에는 학습과 검증 정확도가 거의 유사하여 과적합의 경향은 보이지 않고, epoch 80 이후부터 모델 정확도가 95%로 수렴하는 경향을 보인다. 이후 미세 조정된 결과 일부분 값이 일정치 못한 부분은 있으나, epoch 50일 때 정확도 99%에 가깝게 수렴함을 보인다. 이는 미세조정을 통해 코팅 볼트 분류 모델의 정확도가 향상되었으며, 적은 데이터 수로도 좋은 성능 도출이 가능함을 보여준다.

4. 결론

본 연구는 풀림 방지 코팅 볼트를 선별하기 위해 전이 학습과 미세조정을 적용하여 다음과 같은 결론을 얻었다.

(1) 딥러닝 기법 CNN은 이미지를 기반으로 패턴 및 특성을 분석하므로 충분한 데이터 확보가 필요하다 그러나 본 논문에서 선별하고자 하는 코팅 볼트 샘플 한정적이며, 데이터 개수가 부족하다. 또한 CNN은 모든 층을 학습하기 때문에 시간적 소모가 크다. 따라서 적은 데이터로도 좋은 성능을 도출하고 학습 시간을 단축하기 위해 전이학습 기반 CNN으로 코팅 볼트를 선별한다.

(2) 코팅 볼트 선별을 위해 사용된 딥러닝 모델은 VGG16이며, ImageNet 사전 학습한 가중치를 사용한다. 이때 분류층은 FC, GAP, LSVM 세 가지 방법을 사용했다. 이 중 95%로 가장 높은 정확도를 보인 FC층을 사용한다.

(3) 코팅 볼트의 데이터 수와 ImageNet과의 유사성을 고려하여 합성곱층을 제외한 분류층만을 학습했으며, 95% 정확도를 얻었다. 그러나 이는 모든 층을 학습한 결과보다 2%정도 낮다.

(4) 따라서 더 좋은 성능을 확보하기 위해 마지막 합성곱층과 분류층을 미세 조정하여 97%의 정확도를 얻었다. 본 논문은 전이학습과 미세 조정을 통해 코팅 볼트 학습 시간을 단축하며, 약 97%의 높은 선별 정확도를 확보할 수 있었다.

본 연구는 코팅의 단일 색상만을 사용하여 학습하였으나, 보다 다양한 종류의 코팅 볼트를 전이학습으로 추가 학습하면 코팅 볼트 종류와 불량 선별이 동시에 가능할 것으로 기대된다.

References

- [1] E. Noh, S. Yi, M. Kim and S. Hong, "Identification of bolt coating defects using CNN and Grad-CAM", *Journal of the Korea Society of Mechanical Engineers*, 2020, In press
- [2] M. K. Ferguson, A. K. Ronay, Y. T. T. Lee and K. H. Law, "Detection and Segmentation of Manufacturing Defects with Convolution Neural Networks and Transfer Learning", *Smart Sustainable Manufacturing System*, Vol.2, pp.137-164, Sep. 2018.
DOI: <https://doi.org/10.1520/SSMS20180033>
- [3] K. Gopalakrishnan, S. K. Khaitan, A. Choudhary and A. Agrawal, "Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection", *Construction and Building Materials*, Vol.157, pp.322-330, Dec. 2017.
DOI: <https://doi.org/10.1016/j.conbuildmat.2017.09.110>
- [4] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", *arXiv:1409.1556*, pp.1-14, 2014.
- [5] S. H. Lee, "Deep learning based face mask recognition for access control", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.21, No.8, pp.395-400, Aug. 2020.
DOI: <http://dx.doi.org/10.5762/KAIS.2020.21.8.395>
- [6] K. Imoto, T. Nakai, T. Ike, K. Haruki and Y. Sato, "A CNN-based Transfer Learning Method for Defect Classification in Semiconductor Manufacturing", *2018 International Symposium on Semiconductor Manufacturing*, Tokyo, Japan, Dec. 2018.
DOI: <http://dx.doi.org/10.1109/ISSM.2018.8651174>
- [7] J. Wu, Z. Zhao, C. Sun, R. Yan and X. Chen, "Few-shot transfer learning for intelligent fault diagnosis of machine", *Journal of Measurement*, Vol.166, No.15, pp.1-13, Dec. 2020.
DOI: <https://doi.org/10.1016/j.measurement.2020.108202>
- [8] S. Kim, Y. K. Noh and F. C. Park, "Efficient neural network compression via transfer learning for machine vision inspection", *Journal of Neurocomputing*, Vol.413, pp.294-304, Nov. 2020.
DOI: <https://doi.org/10.1016/j.neucom.2020.06.107>
- [9] S. J. Pan and Q. Yang, "A Survey on Transfer Learning", *IEEE Transactions of Knowledge and Data Engineering*, Vol.22, No.10, pp.1345-1359, Oct. 2010.
DOI: <http://dx.doi.org/10.1109/TKDE.2009.191>
- [10] H. Lee, J. Kim, J. Yu, Y. Jeong and S. Kim, "Multi-class Classification using Transfer Learning based Convolutional Neural Network", *Journal of Korean Institute of Intelligent Systems*, Vol.28, No.6, pp.531-537, Dec. 2018.
DOI: <http://dx.doi.org/10.5391/JKIS.2018.28.6.531>
- [11] M. Lin, Q. Chen and S. Yan, "Network in network", *arXiv:1312.4400*, 2014.
- [12] Y. Tang, "Deep Learning using Linear Support Vector Machines", *arXiv:1306.0239*, Jun. 2013.
- [13] H. C. Shin, H. R. Roth, M. Gao, L. Lu, Z. Xu, I. Nogues, J. Yao, D. Mollura and R. M. Summers, "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning", *IEEE Transactions on Medical Imaging*, Vol.35, No.5, pp.1285-1298, May 2016.
DOI: <http://dx.doi.org/10.1109/TMI.2016.2528162>
- [14] N. K. Kim, J. W. Lee, J. I. Kim and S. H. Hong, "Exotic Plants Classification Using the Transfer Learning", *The Institute of Electronics and Information Engineers*, Vol.41, No.2, pp.477-480, Nov. 2018.
- [15] S. Kim, W. Kim, Y. K. Noh and F. C. Park, "Transfer learning for automated optical inspection", *2017 International Joint Conference on Neural Networks*, AK, USA, May 2017.
DOI: <http://dx.doi.org/10.1109/IJCNN.2017.7966162>

노 은 솔(Eunsol Noh)

[준회원]




- 2020년 2월 : 국립공주대학교 금형설계공학과
- 2020년 3월 ~ 현재 : 국립공주대학교 미래융합공학과 석사과정

<관심분야>

인공지능, 머신러닝

이 사 랑(Sarang Yi)

[준회원]



- 2019년 2월 : 국립공주대학교 금형설계공학과
- 2019년 3월 ~ 2021년 2월 : 국립공주대학교 미래융합공학과 석사

<관심분야>

인공지능, 머신러닝

홍 석 무(Seokmoo Hong)

[종신회원]



- 1999년 2월 : 서강대학교 기계공학 학과 (기계공학 학사)
- 2001년 2월 : 서강대학교 기계공학 학과 (기계공학 석사)
- 2007년 3월 : Technical University of Munich, Germany, Department of Mechanical Engineering (기계공학박사)
- 2007년 4월 ~ 2015년 2월 : 삼성전자 GTC, 수석연구원
- 2015년 3월 ~ 2020년 12월 : 국립공주대학교 기계자동차공학부
- 2021년 ~ 현재 : 국립공주대학교 미래자동차공학과, 미래융합공학과

<관심분야>

금속 판재성형 및 단조, 유한요소해석, 최적 설계