

K-겹 교차 검증과 서포트 벡터 머신을 이용한 고무 오링 결함 검출 시스템

이용은* · 최낙준** · 변영후*** · 김대원**** · 김경천*†

Rubber O-ring defect detection system using K-fold cross validation and support vector machine

Yong Eun Lee^{*}, Nak Joon Choi^{**}, Young Hoo Byun^{***},
Dae Won Kim^{****} and Kyung Chun Kim^{*†}

Abstract In this study, the detection of rubber o-ring defects was carried out using k-fold cross validation and Support Vector Machine (SVM) algorithm. The data process was carried out in 3 steps. First, we proceeded with a frame alignment to eliminate unnecessary regions in the learning and secondly, we applied gray-scale changes for computational reduction. Finally, data processing was carried out using image augmentation to prevent data overfitting. After processing data, SVM algorithm was used to obtain normal and defect detection accuracy. In addition, we applied the SVM algorithm through the k-fold cross validation method to compare the classification accuracy. As a result, we obtain results that show better performance by applying the k-fold cross validation method.

Key Words : Defect Detection(결함 검출), Data Augmentation(데이터 증강), Support Vector Machine(서포트 벡터 머신), Cross Validation(교차 검증)

1. 서론

인공지능은 IoT와 함께 4차 산업혁명의 기본 프레임 핵심 기술로 평가되고 있으며, 인공지능을 이용한 다양한 산업간의 융합과 응용 기술이 중요하

게 여겨지고 발전되고 있다. 이에 따라 최근 제조 현장에서도 인공지능 기술의 도입에 대한 많은 필요성이 강조 되고 있다. 제조 기술의 발전으로 복잡한 형상을 가지는 제품 생산이 가능하게 되었으며 이러한 제조 기술의 발전에 따라 다양한 형상의 제품에 대한 품질 검사 시스템의 요구가 점점 증대되고 있다. 제품 품질 향상과 관련하여 결함 검사 방식들도 다양화되고 확장되고 있지만, 난이도가 높은 결함 검사에서는 여전히 결함 검출 성능의 한계를 보이고 있다⁽¹⁻³⁾.

특히, 크기가 작은 제품의 경우 결함 주변의 구분이 명확하지 않기 때문에 결함을 검출하는 것이 더욱 어렵다. 그래서 본 논문에서는 인공지능을 이

^{†*} School of Mechanical Engineering, Pusan National University, Busan, South Korea, Professor
E-mail: kckim@pusan.ac.kr

^{*} School of Mechanical Engineering,
Pusan National University, Ph. D Student

^{**} ICT Co., LTD

^{***} Dae Young High-Chem Co., LTD

^{****} Intown Co., LTD

용하여 다양한 산업용 부품에 사용되고 있는 고무 재질의 오링의 결함 검출을 진행한다.

인공지능을 이용한 기법이 과거에는 물체 인식에 주로 적용되고 있었지만, 최근 들어서 제품 결함 검출에 대해서도 널리 적용되고 있다.

일반적으로 고무 재질의 오링에서 발생하는 결함은 찌힘, 찢어짐 등 매우 다양하며 형태나 크기 또한 일정하지 않은 특성을 가지고 있다. 또한 고무 오링의 특성상 표면이 균일하지 않거나, 또는 가공과정에서 어쩔 수 없이 포함되는 불균일한 표면 무늬 등이 존재하는 경우, 정상 제품과 결함의 외관에서의 구별이 매우 어렵다. 특히, 이러한 특성들이 조명과 결합되면 조명에 반사된 부분이 결함처럼 인식되기 쉽기 때문에 결함의 검출을 더욱 어렵게 한다. 이러한 문제점들을 인공지능 학습을 통해 결함을 빠르고 정확하게 구분할 수 있다는 장점을 이용하였다.

2. 실험 방법

2.1 데이터 수집 및 분류

본 연구에서는 고무 오링 불량 검출 인공지능 알고리즘 개발을 위해 python language를 이용하여 개발하였고, 행렬 연산 및 Plot 표시를 위해 numpy, matplotlib 라이브러리 등을 사용하였다.

고무 오링 이미지 데이터는 양품과 불량으로 나눠서 데이터를 분류 하였다.

불량 검출에 사용되는 이미지는 그림 1과 같이 육안으로 쉽게 구분이 가능한 경우도 있지만 그림 2처럼 마감 불량 및 스크래치 등과 같이 육안으로 판단하기 어려운 데이터들도 함께 들어있다.



Fig. 1. Defect o-ring (easy)




Fig. 2. Defect o-ring (hard)

2.2 이미지 프레임 정렬

데이터 처리에는 크게 3가지의 단계를 사용하였다. 첫 번째로 학습하고자 하는 이미지에서 관심 영역을 자르는 것이다.




Fig. 3. Detection image cutting

그림 3의 상위 이미지에서는 전체 프레임 중에서 고무 오링 부분 이외의 학습에 불필요한 영역이 많기 때문에 불필요한 부분을 최소화하고 탐색하고자 하는 범위를 확대하여 학습 정확도를 향상시키기 위해 그림 3의 하위 이미지처럼 프레임에서 고무 오링 이미지를 확대시켰다.

2.3 그레이 스케일 변화

두 번째 방법으로는 그레이 스케일을 변화시켰다. 그레이 스케일로 이미지를 변화시키는 이유는 학습 가능한 파라미터 수를 줄여 과적합을 방지하고 연산량의 감소로 컴퓨팅 자원을 절약 할 수 있다. RGB는 3차원의 색공간을 가지고 있다. 즉, R : 0~255, G : 0~255, B : 255를 가지고 있으며 이를 계산하면 $255 \times 255 \times 255 = 16,581,375$ 번의 연산을 해야 하지만 그레이 스케일은 1차원인 0~255만 따지게 되므로 연산량이 대폭 감소하고 연산량이 감소하면 과적합이 발생할 확률도 줄어 든다. 그래서, 이미지가 가지고 있는 형태나 픽셀의 분포에는 크게 영향을 주지는 않지만, 데이터의 양이 크게 줄어들고, RGB 색정보 보다 이미지의 형상이 더 중요한 데이터의 경우 그레이 스케일 이미지로 주요 알고리즘을 연산한다면, 정확도와 연산량에 큰 이점을 얻을 수 있다^(4,5).

2.4 이미지 어그멘테이션(Image augmentation)

다음 과정으로는 학습과 테스트에 사용될 데이터의 증폭 과정을 진행하였다. 적은 수의 이미지 데이터를 가지고 데이터를 학습할 때 과적합(overfitting) 문제가 발생할 수 있다. 과적합이란 훈련에 사용되는 이미지에 과도하게 학습되어서 새로운 이미지를 제대로 인식하지 못하는 현상이다. 또한 훈련에 사용되는 이미지가 적기 때문에 훈련 과정에서 보지 못한 유형의 이미지를 인식하지 못할 수 있다. 이미지 어그멘테이션 (Image augmentation)은 이미지 인식에 있어서 과적합 문제를 해결하기 위해 매우 간단하면서도 강력한 이미지 전처리 기법이다⁽⁶⁻⁸⁾. 이미지 어그멘테이션 기법을 적용할 때 주로 사용하는 이미지 변형 기법으로는 이미지 대



Fig. 4. Image augmentation result

칭, 이미지 크기, 이미지 회전, 이미지 밝기 조절 등이 있으며, 본 연구에서는 이미지 대칭과 이미지 회전 기법을 이용하여서 이미지 어그멘테이션 과정을 진행하였다.

그림 4와 같이 원본의 이미지를 이용하여 90°, 180°, 270° 회전을 하였으며 이미지 좌우, 상하 대칭 과정을 추가로 진행하여 학습 및 테스트에 사용할 이미지를 증폭 시켰다.

2.5 서포트 벡터 머신(Support vector machine)

본 연구에 사용된 인공지능 학습에는 서포트 벡터 머신(Support vector machine, SVM)이 사용되었다. 서포트 벡터 머신은 데이터가 가지는 특성을 모델링하고 특성에 따른 정보를 이용해 데이터를

분류하기 위한 방법으로 널리 사용되는 기계 학습 방법이다⁽⁹⁻¹¹⁾. 서포트 벡터 머신은 두 개의 카테고리 로 구성된 데이터가 있을 때, 각 데이터를 어떠한 한쪽을 선택하여 분류하는 이진 분류 방법에서 널리 적용되고 있다. 이것은 분류 모델을 구축하기 위한 학습 데이터로부터 특성 데이터들을 습득하고, 습득한 정보를 통해 두 개의 카테고리를 분류하는 모델을 생성한다. 학습 데이터로부터 생성한 분류 모델은 학습에 사용되지 않은 새로운 데이터에 대해서도 그 데이터가 속하는 카테고리를 효과적으로 예측할 수 있고, 새로운 문제에 대해 적용할 수 있는 분류 모델이 된다.

SVM의 분류 결과가 높은 변별력과 정확성을 가지기 위해서 학습 데이터의 특성들이 분류에 필요한 정보를 효율적으로 표현하고 있도록 학습하고자 하는 데이터의 전 처리과정이 중요하며, 두 개의 카테고리에 속하는 학습 데이터를 카테고리 별로 가장 큰 변별력을 가질 수 있는 분류 기준을 모델로 만듦으로써 분류 결과의 변별력을 높인다.

본 연구에서는 두 개의 카테고리인 양품과 불량을 구분하기 위해 적합한 알고리즘인 서포트 벡터 머신 알고리즘을 선택하였다.

2.6 K-fold cross validation(K-겹 교차 검증)

그리고 해당 데이터들을 이용하여서 k-fold cross validation 방법을 이용하여 모델에 대한 결과를 얻었다. K-fold cross validation은 가지고 있는 데이터를 k개의 그룹으로 나누어 그 그룹 중에서 하나를 추출하여 test set으로 사용하는 것이다. 그리고 이 과정을 k번 반복하여 나온 결과 값을 평균 내어 검증 결과 값으로 사용한다. K-fold의 장점은 모든 데이터를 training과 test에 쓸 수 있고 오버피팅의 염려도 크지 않다^(12, 13). K-fold cross validation 방법을 사용하지 않을 경우 데이터셋의 크기가 작은 경우 테스트 셋에 대한 성능 평가의 신뢰성이 떨어진다는 문제점이 존재하게 된다. 만약 테스트셋을 어떻게 잡느냐에 따라 성능이 다르면, 우연의 효과로 인해 모델 평가 지표에 편향이 생기게 된다. 이를 해결하기 위해 k-fold cross validation 은 모든 데이터가 최소 한 번은 테스트셋으로 쓰이도록 한다.

	A	B	C	D	E
Cross validation iteration 1	Train	Train	Train	Train	Test
Cross validation iteration 2	Train	Train	Train	Test	Train
Cross validation iteration 3	Train	Train	Test	Train	Train
Cross validation iteration 4	Train	Test	Train	Train	Train
Cross validation iteration 5	Test	Train	Train	Train	Train

Fig. 5. K-fold validation

그림 5처럼 본 연구에서는 데이터를 5개로 나누서 매번 test data를 바꿔 나가는 것을 볼 수 있다. 첫 번째 iteration에서는 ABCD를 트레이닝 셋으로 E를 테스트 셋으로 설정한 후 성능을 평가 하였다. 두 번째 iteration에서는 ABCE를 트레이닝 셋으로, D를 테스트 셋으로 하여 성능을 평가하였다. 그러면 총 5개의 성능 평가 지표가 생기게 되는데 이 값들을 평균을 내어 모델을 성능을 평가 하였다.

이때 몇 개로 나뉘느냐가 k-fold cross validation의 k가 되며, 보통 k-fold는 일반화 성능을 만족시키는 최적의 하이퍼 파라미터를 구하기 위한 모델 튜닝에 사용된다.

3. 결과 및 고찰

SVM 알고리즘을 이용하여 학습과 테스트를 진행한 결과와 SVM-k-fold cross validation 과정을 진행하여 결과를 비교해보았다. 학습과 테스트에 사용된 양품과 불량량의 이미지는 이미지 어그멘테이션 과정을 거친 후, 총 976개의 이미지 데이터를 이용하여서 진행하였다. 전체 데이터 중에서 학습과 테스트에 8:2 비율로 나눠서 780개는 학습에 사용하였고, 196개는 테스트에 사용하였다. SVM 알고리즘을 통해 나온 결과는 196개 이미지를 불량 검출 테스트하여 173개를 맞추고 23개는 틀린 결과가 나왔으며 88.27%의 불량 구분 정확도의 결과를 얻었다.

그리고 k-fold cross validation 방법을 이용하여 그림 5와 같이 5개로 테스트 셋을 나눠서 SVM 알고리즘을 이용하여 테스트를 진행하였으며 k-fold

cross validation을 이용하여 테스트를 진행한 것과 k-fold cross validation을 사용하지 않고 테스트를 진행한 결과들을 비교해보았다.

Cross validation iteration 1=96.79%, cross validation iteration 2=94.87%, cross validation iteration 3=94.87%, cross validation iteration 4=94.87%, cross validation iteration 5=96.15%의 결과를 얻었으며 평균 95.51%의 정확도로 양품과 불량품의 구분할 수 있는 결과를 얻을 수 있었다. 본 연구에 사용된 데이터들은 데이터 편향 현상이 발생 하였기 때문에 cross validation 적용 유무에 따라 정확도 차이가 크게 나타났다. 이러한 문제를 막기 위해 모든 데이터 셋을 훈련에 활용하여 정확도 향상 및 데이터 부족으로 인한 underfitting을 방지 할 수 있다. 그리고 모든 데이터 셋을 테스트에 활용할 수 있기 때문에 테스트에 사용되는 데이터 편중을 막을 수 있으며 테스트 결과에 따라 좀 더 일반화된 모델을 만들 수 있는 장점이 있기 때문에 k-fold cross validation을 이용하였다.

예측한 양품과 불량에 대한 결과 라벨링 작업까지 진행 되어서 그림 6과 그림 7처럼 각각 분류하여 쉽게 확인할 수 있도록 데이터가 최종적으로 정리할 수 있도록 구축하였다.




Fig. 6. Prediction of defect and resulting image




Fig. 7. Prediction of non-defect and resulting image

4. 결론

본 연구를 통해 일반적으로 사용하는 SVM 알고리즘을 사용 하였을 때의 불량 판별 정확도보다 k-fold cross validation 방법을 이용하여 데이터 셋을 나눠서 테스트를 진행 했을 때의 불량 판별 정확도를 비교해보았다.

학습과 테스트 비율을 8:2로 나눠서 SVM 알고리즘에 적용했을때는 88.27%의 결함 검출 정확도가 나왔으며 k-fold cross validation을 사용하여 SVM알고리즘에 적용했을때는 평균 95.51%의 결함 검출 정확도가 나와서 k-fold cross validation을 사용하였을 때 정확도가 더 높게 나오는 것을 확인할 수 있었다. 이는 모든 데이터 셋을 훈련에 활용할 수 있으며 평가에 사용되는 데이터 편중을 막을 수 있기 때문에 동일한 SVM 알고리즘을 사용하더라도 조금 더 정확도를 향상 시킬 수 있다.

추후, k-fold cross validation을 딥 러닝 알고리즘에 적용하게 되면 조금 더 높은 정확도 향상이 될 것으로 기대된다.

사 사

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2020R1A5A8018822).

REFERENCE

- 1) Y. Wang, W. Yang, P. Winter, and L. Walker, 2008, "Walk-through weighing of pigs using machine vision and an artificial neural network," *Biosyst. Eng.*, vol. 100, no. 1, pp. 117–125.
- 2) V. Singh and R. Mishra, 2006, "Developing a machine vision system for spangle classification using image processing and artificial neural network," *Surf. Coatings Technol.*, vol. 201, no. 6, pp. 2813–2817.
- 3) N. Behroozi Khazaei, T. Tavakoli, H. Ghasseman, M. H. Khoshtaghaza, and A. Banakar, 2013, "Applied machine vision and artificial neural network for modeling and controlling of the grape drying process," *Comput. Electron. Agric.*, vol. 98, pp. 205–213.
- 4) P. J. Toivanen, 1996, "New geodesic distance transforms for gray-scale images," *Pattern Recognit. Lett.*, vol. 17, no. 5, pp. 437–450.
- 5) J. Fridrich, M. Goljan, and R. Du, 2001, "Detecting LSB steganography in color and gray-scale images," *IEEE Multimed.*, vol. 8, no. 4, pp. 22–28.
- 6) M. D. Bloice, C. Stocker, and A. Holzinger, 2017, "Augmentor: An Image Augmentation Library for Machine Learning," *arXiv*, pp. 1–5.
- 7) J. Wang and L. Perez, 2017, "The effectiveness of data augmentation in image classification using deep learning," *arXiv*.
- 8) C. Shorten and T. M. Khoshgoftaar, 2019, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1.
- 9) W. S. Noble, 2006, "What is a support vector machine?," *Nat. Biotechnol.*, vol. 24, no. 12, pp. 1565–1567.
- 10) A. Widodo and B. S. Yang, 2007, "Support vector machine in machine condition monitoring and fault diagnosis," *Mech. Syst. Signal Process.*, vol. 21, no. 6, pp. 2560–2574.
- 11) K. Q. Shen, C. J. Ong, X. P. Li, and E. P. V. Wilder-Smith, 2008, "Feature selection via sensitivity analysis of SVM probabilistic outputs," *Mach. Learn.*, vol. 70, no. 1, pp. 1–20.
- 12) J. G. Moreno-Torres, J. A. Saez, and F. Herrera, 2012, "Study on the impact of partition-induced dataset shift on k-fold cross-validation," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 23, no. 8, pp. 1304–1312.
- 13) J. D. Rodríguez, A. Pérez, and J. A. Lozano, 2010, "Sensitivity Analysis of k-Fold Cross Validation in Prediction Error Estimation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 32, no. 3, pp. 569–575.