

적응형 이진화와 컨벡스 헐 기법을 적용한 심층학습 기반 기계부품 (오링) 불량 판별

김현태^{1*} · 성은산²

Machine Parts(O-Ring) Defect Detection Using Adaptive Binarization and Convex Hull Method Based on Deep Learning

Hyun-Tae Kim^{1*} · Eun-San Seong²

^{1*}Professor, Major of Applied Software Engineering, Dongeui University, Busan, 47340 Korea

²Graduate Student, Department of Digital Media Engineering, Dong-Eui University, Busan, 47340 Korea

요 약

오링은 기계 부품들 사이에서 틈을 메워주는 역할을 한다. 지금까지 불량품 선별은 육안 및 수작업으로 수행하여 분류 오류가 자주 발생한다. 따라서 사람의 개입이 없는 카메라 기반의 불량품 분류 시스템이 필요하다. 그러나 카메라 입력 영상에서 배경으로부터 필요 영역을 분리하기 위해 이진화 과정이 필요하다. 본 논문에서는 주변 조명의 변화나 반사 등의 요인으로 인해 단일 임계값 이진화를 적용하기 어려워, 주변 화소 값을 함께 고려한 적응형 이진화 기법을 적용한다. 또한 누락되는 화소 부분을 보완하기 위해 컨벡스 헐 기법도 함께 적용한다. 그리고 분리된 영역에 적용할 학습 모델은 불량 특성이 비선형인 경우에 유리한 잔류 오차 기반의 심층학습 신경망 모델을 적용한다. 실험을 통해 제안하는 시스템이 오링의 불량 판별 자동화에 적용 가능하다는 것을 제시한다.

ABSTRACT

O-rings fill the gaps between mechanical parts. Until now, the sorting of defective products has been performed visually and manually, so classification errors often occur. Therefore, a camera-based defect classification system without human intervention is required. However, a binarization process is required to separate the required region from the background in the camera input image. In this paper, an adaptive binarization technique that considers the surrounding pixel values is applied to solve the problem that single-threshold binarization is difficult to apply due to factors such as changes in ambient lighting or reflections. In addition, the convex hull technique is also applied to compensate for the missing pixel part. And the learning model to be applied to the separated region applies the residual error-based deep learning neural network model, which is advantageous when the defective characteristic is non-linear. It is suggested that the proposed system through experiments can be applied to the automation of O-ring defect detection.

키워드 : 오링, 적응형 이진화, 컨벡스 헐, 딥러닝

Keywords : O-ring, Adaptive binarization, Convex hull, Deep learning

Received 6 October 2021, Revised 9 October 2021, Accepted 28 October 2021

* **Corresponding Author** Hyun-Tae Kim(E-mail:htaekim@deu.ac.kr, Tel:+82-51-890-1992)
Professor, Major of Applied Software Engineering, Dongeui University, Busan, 47340 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.12.1853>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

오링은 기계 부품들 사이 틈을 메워 기체 등이 새어나 오지 않도록 한다. 원활한 기계 부품 사용을 위해 필요한 부품이다. 오링은 일반적인 사출 성형방식으로 생산된다. 업체 대부분은 불량품을 수작업으로 분류한다. 사출 성형 관련 불량 종류는 크랙, 플래시, 충전 부족, 흑 줄, 플로우 마크, 변형, 휨 등이 있다. 그림 1과 그림 2에 오링 부품의 실제 형상을 양품과 불량품으로 구분하여 각각 나타내었다. 이러한 영상기반 불량품 분류 시는 주위 특성을 반영하는 것이 필요하다. 본 논문에서는 조명의 반사, 불량을 판별할 부품 외의 이물질 유입 등을 해결하기 위해 컨벡스 헐과 적응형 이진화를 사용한 전처리 과정을 적용하여 부품만 찾아내어 해당 영역만 추출한 후 잔류 오차 CNN(컨볼루션 신경망) 모델을 사용하여 학습시킨다[1, 2]. GPU 기반 실험 환경에서 제안하는 방법의 검출 성능이 기존 성능을 달성하는 지를 확인한다.




Fig. 1 The examples of o-ring(normal condition)

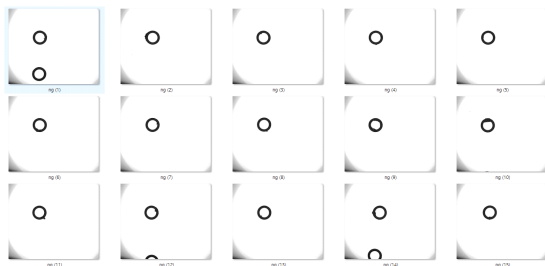


Fig. 2 The examples of o-ring(abnormal condition)

II. 제안한 시스템

전처리 과정이 포함된 전체 시스템의 블록도는 그림 3과 같으며 처리 블록도 중에서 핵심 기능을 수행하는 적응형 이진화 과정과 컨벡스 헐 적용 과정 그리고 적용

한 딥러닝 모델에 대해 보다 상세히 언급한다.

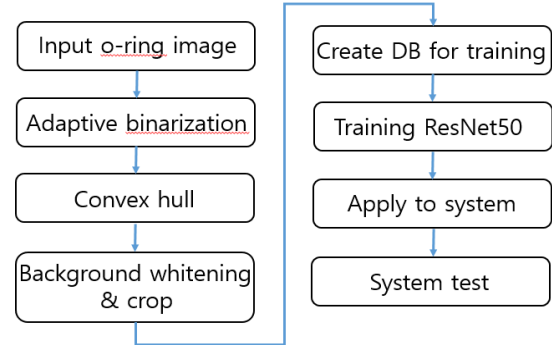


Fig. 3 Block diagram of the entire system including preprocessing

2.1. 전처리 1단계(적응형 이진화)

영상의 이진화 적용을 위해 그레이스케일 영상 기준으로 임계값을 정해 흑백 영상으로 나누는 기준으로 사용하며, 이를 기준으로 이진화한다.

그러나 영상 내에서 조명 등 주위 환경 등의 요인으로 인하여 한가지 임계값 혹은 어떠한 임계값으로도 이진화가 어려운 영상이 존재하기 마련이다. 이처럼 영상의 이진화 적용을 위해 국소적으로 임계값을 다르게 적용해야 한다. 이를 위해 적응형 이진화 알고리즘을 적용한다[3, 4].

블록사이즈를 먼저 정하고 그 다음으로 감산 값을 정하며, 평균 가중치 방식으로 결과 값을 계산한다. (x,y) 의 임계값은 식 (1)로 정한다.

$$T(x,y) = \mu(x,y) - C \quad (1)$$

위 수식에서 (x,y) 의 블록사이즈 영역 평균값은 $\mu(x,y)$ 이고, C는 감산 값이다. 적응형 이진화 계산 수식은 식 (2)와 같다.

$$T(x,y) = \frac{1}{blockSize^2} \sum_{x_i} \sum_{y_i} I(x+x_i, y+y_i) - C \quad (2)$$

2.2. 전처리 2단계(컨벡스 헐)

입력영상으로 적응형 이진화 처리후에도 원본영상과 비교해보면 부품 내 픽셀들이 제외되기도 한다. 이를 보완하기 위하여 컨벡스 헐이라는 알고리즘을 추가로 적용하였다[5, 6].

컨벡스 헐에서 사용되는 대표적인 방식은 Graham

scan 이다. 절차는 x와 y 좌표 값이 적은 점(anchor point) 을 하나 선택한다. 이 점을 기준으로 하여 기울기 순으로 정렬하는데 같은 기울기라면 거리순으로 정렬한다. 점들을 하나씩 컨벡스 헐 그룹에 포함한다. 앞서 그룹에 마지막으로 포함되었던 3개의 점의 CCW(Counter Clock Wise)가 일치하지 않는다면 3개의 점 중에서 중간점을 제외하고 다음 점으로 넘어간다.

이때 CCW란 벡터의 외적을 사용하여 평면 위에 놓인 세 점의 방향 관계를 알 수 있는 알고리즘이다. 세 점 A, B, C가 있을 때 벡터 AB를 기준으로 점 C가 왼쪽인지 같은 직선인지 오른쪽에 있는지 판별한다. 먼저 원점에 맞추어 벡터 AB를 만들고 식 (3)에 따라 외적을 계산하면 된다[7].

$$S = \begin{vmatrix} A.x & A.y & 1 \\ B.x & B.y & 1 \\ C.x & C.y & 1 \end{vmatrix} \quad (3)$$

$$= (A.x \times B.y + B.x \times C.y + C.x \times A.y) - (A.y \times B.x + B.y \times C.x + C.y \times A.x)$$

전처리 과정을 통해 획득한 출력 영상은 그림 4에 나타내었다. 그림 4의 (a)는 양품에 대한 것이며, (b)는 불량품에 대한 전처리 결과 이미지이다.

2.3. 잔류 오차 기반 합성곱 신경망(ResNet-50)

잔류 오차 기반 합성곱 신경망은 신경망의 레이어가 깊을수록 학습과정에서 오류가 증가하는 문제를 해결하기 위해 그림 5와 같이 바로가기 연결을 도입한 모델이다[1]. 잔류 오차 기반 합성곱 신경망은 신경망 구조 변경이 거의 없어 학습 파라미터 증가가 발생하지 않고 다층 신경망의 깊이가 깊어지더라도 기울기 소실 문제를 해결할 수 있는 장점이 있다[8].

ResNet 구조를 보다 자세히 살펴보면, 합성곱 계층과 완전 연결 계층이 결합하는 구조이며, 통합 계층, 활성화 계층, 배치 정규화 계층이 사이에 들어가 있다. 합성곱 계층에는 입력 특징맵으로 불리는 입력 활성화값들에 3차원 합성곱 연산을 수행해서 출력 특징맵, 즉 출력 활성화값들을 생성한다. 완전 연결 계층은 입력 활성화값을 하나의 벡터로 보고 행렬-벡터 곱 연산을 수행한다. 통합 계층은 다수 입력 활성화값에서 단수의 출력 활성화값을 만든다.



(a) normal condition



(b) abnormal condition

Fig. 4 Output images from proposed pre-processing

활성화 계층은 비선형 함수를 통해 비선형 특성을 증대시켜 판별 성능을 높이는 역할을 한다.

제안하는 잔류 오차 기반 합성곱 신경망에서는 비선형 함수로 ReLU(rectified linear unit)함수가 사용된다. ReLU는 입력이 양수이면 직접 출력하고 그렇지 않으면 0을 출력하는 부분적으로 선형 함수입니다. 이를 사용하는 모델이 훈련하기 쉽고 종종 더 나은 성능을 달성하기 때문에 많은 유형의 신경망에 대한 기본 활성화 함수로 사용된다.

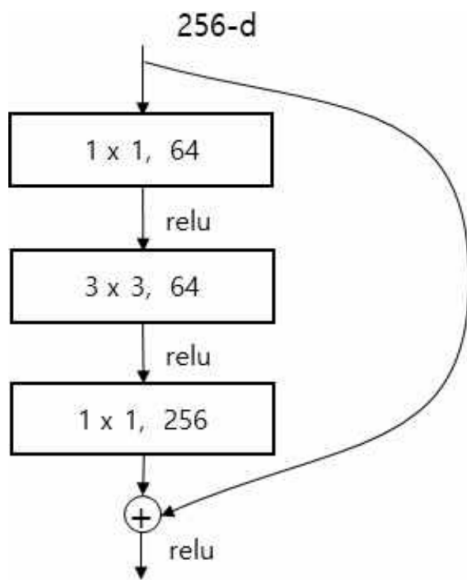


Fig. 5 Bottleneck building block for ResNet50

끝으로 배치정규화 층은 입력 활성화값을 정규화함으로써 학습을 안정화시키는 역할을 한다[2]. 표 1은 ResNet50의 전체적인 구조를 나타낸 것으로, 표 2에 표시되지는 않았지만, conv3_1, conv4_1, conv5_1에서도 스트라이드(stride) 2로 다운샘플링이 진행된다.

III. 실험 환경 및 결과

3.1. 실험 환경

실험에 사용한 영상은 양품 371장, 불량품 2000장이며, 이를 다시 3가지로 크기별로 분류하고 그 중에서 학습용과 검증 및 테스트용으로 다시 세분하여 사용하였다[9].

Table. 1 Architecture of ResNet50

Layer name	Output size	ResNet-50
conv1	112×112	7×7, 64, stride 2
conv2_x	56×56	3×3 max pool, stride 2
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4_x	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$
conv5_x	7×7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	avg.pool, 1000d FC

훈련 및 테스트에 사용한 하드웨어는 Intel Xeon Gold 5118, 128GB 메모리, NVIDIA TITAN V 12GB GPU를 사용하였다. 학습에 사용한 프레임워크는 PyTorch이고 잔류 오차 기반 합성곱 신경망은 ResNet-50을 사용하였다.

UI는 wxPython을 사용하여 제작하였다. 아래의 그림 6은 별도로 제작한 불량 판별 시스템 UI화면을 나타내며 그림 6 (a)는 테스트 실행 전이며, 그림 6 (b)는 테스트 실행 결과 화면이다.

3.2. 성능 평가 항목

(1) 시스템 처리 속도 테스트

파일 형태의 입력 이미지가 처리 시스템에 유입된 순간부터 처리 시스템의 양품/불량품 판별 출력으로 나오는 시간까지 걸리는 시간(초)으로 정의한다.

(2) 양품/불량품 판별의 정확성 관련 테스트

① 재현율(recall) : 동일 개수의 양품과 불량품을 대상으로 테스트한 결과를 바탕으로 아래 수식 (4)을 적용하여 계산함.

$$R = \frac{TP}{TP+FN} \times 100(\%) \quad R: \text{Recall} \quad (4)$$

- 여기서, FN(False Negative)는 미검출 값 또는 인식 못한 이미지 개수이며, TP(True Positive)는 정상검출 값 또는 인식한 이미지 개수임.

② 정확도(precision) : 동일 개수의 양품과 불량품을 대상으로 테스트한 결과를 바탕으로 아래 수식 (5)을 적용하여 계산함.

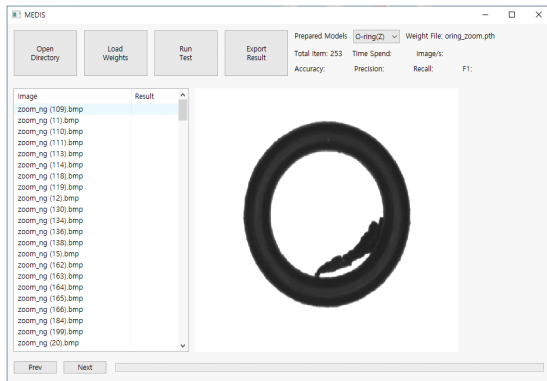
$$P = \frac{TP}{TP + FP} \times 100(\%) \quad P: \text{Precision} \quad (5)$$

- 여기서, FP(False Positive)는 오검출 값 또는 잘못 인식한 이미지 개수임.

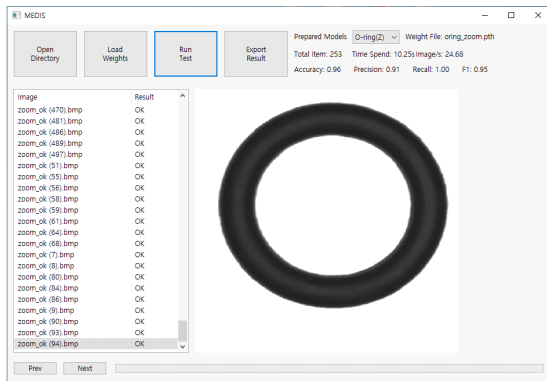
③ F1 스코어(score) : 상기 ①번 항목 값과 ②번 항목 값의 조화 평균 값에 해당하여 아래 수식 (3)을 적용하여 계산함.

$$F1 = \frac{2RP}{R + P} \quad (1st \text{ order}) \quad (6)$$

experimental item	reference values	ResNet-50	
Recall	90% above	Large	100%
		Middle	91%
		Small	92%
Precision	90% above	Large	96%
		Middle	93%
		Small	93%
F1 Score	90% above	Large	95%
		Middle	92%
		Small	92%



(a) before



(b) after

Fig. 6 System UI screen before/after test

Table. 2 Test results

experimental item	reference values	ResNet-50	
Processing Speed	0.5 cut/sec above	Large	20.37
		Middle	20.48
		Small	20.52

3.3. 실험 결과

제안한 오링 불량 판별 시스템에 대한 성능 실험은 표 2에 표시하였다. 표 2에서 첫 번째 항목인 ‘시스템 처리 속도’는 초당 20장 이상 처리 가능하였으며, 판별 성능은 크기 기준 ‘대’의 경우 성능이 가장 뛰어났으며, 크기 ‘중’과 크기 ‘소’는 유사한 성능을 보인다. 이는 육안으로도 크기가 큰 경우 구별이 용이하기 때문에 높은 성능을 보이는 것으로 판단되며, 크기 기준 3 종류 모두 90%를 초과하는 판별 율을 보이고 있다.

IV. 결 론

적응형 이진화와 컨벡스 헐을 함께 전처리로 사용하고 딥러닝 모델을 잔류 오차 기반 심층학습 모델을 적용한 경우 기준을 충족하는 성능을 보였다. 향후 전처리과정 없이 바로 딥러닝 모델에 적용하여도 전처리를 적용한 경우 못지않은 성능을 얻을 수 있도록 모델 최적화에 초점을 맞출 계획이다. 그리고 오링의 크기를 대, 중, 소로 구분하였으나 각 사이즈 경계에 해당하는 경우도 많아, 향후에는 크기 구별 없이 불량 판별 모델을 만들어 판별 성능을 비교할 계획이다.

ACKNOWLEDGEMENT

This work was supported by Dong-eui University Grant.(202101970001)

References

- [1] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [2] H. J. Kang, "Efficient Fixed-Point Representation for ResNet-50 Convolutional Neural Network," *Journal of the Korea Institute of Information and Communication Engineering*, Korea, vol. 22, no. 1, pp. 1-8, May. 2018.
- [3] M. L. Feng and Y. P. Tan, "Adaptive binarization method for document image analysis," *2004 IEEE International Conference on Multimedia and Expo (ICME) (IEEE Cat. No.04TH8763)*, Taipei, Taiwan, vol. 1, pp. 339-342, 2004.
- [4] J. S. Kim, "Recognition Performance Improvement of QR and Color Codes Posted on Curved Surfaces," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 23, no. 3, pp. 267-275, Mar. 2019.
- [5] D. Avis, D. Bremner, and R. Seidel, "How good are convex hull algorithms?," *Computational Geometry*, vol. 7, no. 5-6, pp. 265-301, 1997.
- [6] H. S. Park and J. W. Lee, "Correct Linear Skyline Algorithm in High-Dimensional Space," *Journal of the Korean Institute of Information Scientists and Engineers*, vol. 45, no. 10, pp. 1089-1095, Oct. 2018.
- [7] Muthukrishnan, Understanding Graham scan algorithm for finding the Convex hull of a set of Points [Internet]. Available: <https://muthu.co/understanding-graham-scan-algorithm-for-finding-the-convex-hull-of-a-set-of-points/>.
- [8] M. K. Kim, "Feature Extraction on a Periocular Region and Person Authentication Using a ResNet Model," *Journal of Korea Multimedia Society*, vol. 22, no. 12, pp. 1347-1355, Dec. 2019.
- [9] E. S. Seong and H. T. Kim, "Rubber O-ring defect detection using adaptive binarization, Convex Hull preprocessing, and convolutional neural network learning method," in *Proceeding of the Korean Institute of Information and Communication Sciences Conference*, pp. 623-625, 2021.



김현태(Hyun-Tae Kim)

2000 부산대학교 전자공학과 공학박사
2008 Georgia Institute of Tech. 방문연구원
2010~2012 부산T융합부품연구소 부소장
2002~현재 동의대학교 응용소프트웨어공학 교수
※관심분야: 영상 및 음향신호처리, 컴퓨터비전, 딥러닝



성은산(Eun-San Seong)

2020 동의대학교 응용소프트웨어공학 공학사
2021~현재 동의대학교 대학원 디지털미디어공학과 석사과정
※관심분야: 인공지능, 컴퓨터비전, 딥러닝, 지능형 네트워크