



# AI-머신비전 융합 기반 MLCC 외관 검사 알고리즘 및 장비 개발

고국원<sup>a,\*</sup>

## AI and Machine Vision Integrated System for MLCC Defect Inspection

Kuk Won Ko<sup>a,\*</sup><sup>a</sup> Department of Future Mobility, Halla University

### ARTICLE INFO

#### Article history:

|          |    |       |      |
|----------|----|-------|------|
| Received | 22 | April | 2025 |
| Revised  | 2  | June  | 2025 |
| Accepted | 13 | June  | 2025 |

#### Keywords:

AI and conventional vision integration  
Defect detection  
Machine vision  
MLCC inspection

### ABSTRACT

This paper presents an inspection system developed for the final stage of Multi-Layer Ceramic Capacitor (MLCC) production. It performs electrical capacitance measurement and visual inspection of bulk-supplied MLCC chips, separating defective units before packaging. To meet the required inspection rate of over 3,800 units per minute, a high-speed vision system (100 fps) and advanced image processing algorithms were implemented. Visual inspection uses strobe lighting and a hybrid method combining traditional feature extraction with AI to detect defects. The system identifies electrode length issues, chipping, and cracks with 98.98% accuracy. Tests on 3,245 non-defective and 543 defective samples showed a false positive rate of 0.65% and a false negative rate of 3.2%, with a processing speed of 3,875 units per minute. A multi-threaded architecture enables real-time inspection with high accuracy, making the system suitable for high-volume MLCC manufacturing.

## 1. 서론

현대 전자 산업의 발전과 함께 적층 세라믹 콘덴서(MLCC)의 중요성은 지속적으로 증가하고 있다. 스마트폰, IoT 기기부터 전기 자동차에 이르기까지 다양한 전자제품의 회로 안정화에 핵심적인 역할을 담당하는 MLCC는 최근 초소형화 및 고성능화 추세에 따라 품질 관리의 중요성이 더욱 부각되고 있다. 특히 4차 산업혁명과 자율주행차 시장의 확대에 의해 전장용 MLCC의 수요가 급증하면서, 생산 공정에서의 효율적인 품질 검사 시스템 구축이 산업 경쟁력 확보의 관건으로 떠오르고 있다<sup>[1]</sup>.

MLCC의 제조는 Fig. 1과 같이 복잡한 여러 단계의 공정을 거쳐 이루어진다. 원료 준비와 슬러리 제조부터 시작하여 전극 인쇄, 적층, 소성, 외부 전극 형성, 전기적 특성 측정, 그리고 최종

테이핑에 이르는 15개 이상의 정밀 공정이 요구된다. 이 과정에서 품질 관리는 각 단계마다 중요하지만, 특히 최종 공정인 테이핑 단계에서의 검사는 제품의 출하 품질을 결정짓는 중요한 요소이다<sup>[2]</sup>.

MLCC 제조 공정 중 최종 단계인 테이핑(taping) 공정은 대량의 제품을 고속으로 처리해야 하는 특성상 자동화된 검사 시스템이 필수적이다. 이 과정에서 벌크 상태로 공급되는 MLCC를 정렬하고, 정전용량 측정 및 외관 검사를 통해 불량품을 선별한 후, 양품만을 캐리어 테이프에 포장하는 일련의 작업이 이루어진다. 그러나 분당 3,800개 이상의 처리 속도를 요구하는 고속 공정 환경에서 정확한 외관 불량 검출은 여전히 기술적 도전 과제로 남아있다. 이러한 기술적 과제를 해결하기 위해 최근에는 머신 비전 기반의 경량 딥러닝 네트워크와 전기기계적 응답 분석 등 다양한 접근법

\* Corresponding author. Tel.: +82-33-760-1579

E-mail address: kukwon.ko@halla.ac.kr (Kuk Won Ko).

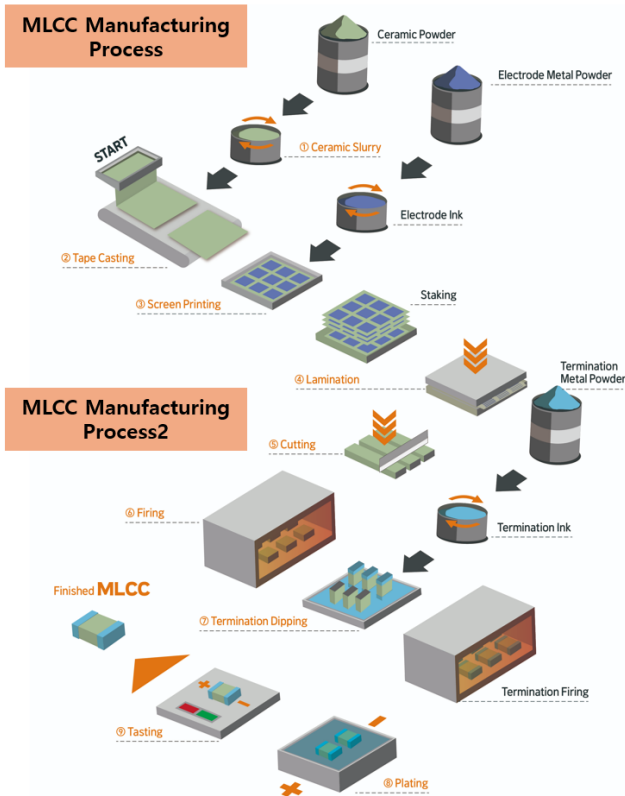


Fig. 1 MLCC manufacturing process

이 제안되고 있다.

고속 카메라와 인공지능 알고리즘을 결합한 외관 검사 시스템은 크랙, 깨짐, 전극 손상과 같은 미세 결함을 실시간으로 검출하는데 효과적이며, 경량 멀티스케일 네트워크를 적용함으로써 연산 효율을 극대화할 수 있다<sup>[3]</sup>. 시각 정보 기반 방법만으로는 탐지하기 어려운 내부 결함에 대해서는 전기 자극에 따른 기계적 응답을 분석하는 방식이 보완적으로 활용되고 있다<sup>[4]</sup>. 그리고, 하이브리드 검사 체계는 MLCC의 품질 신뢰성을 제고하고, 불량률을 낮추며, 나아가 스마트팩토리 기반의 전자동 생산 환경 구현에도 기여할 수 있다<sup>[5]</sup>.

이에 본 연구에서는 기술 동향을 반영하여 머신 비전 기술을 활용한 MLCC 외관 검사 장비 개발에 초점을 맞추었다. 특히 고속 처리 환경에서도 높은 정확도를 유지할 수 있는 검사 시스템을 구현하기 위해, 전통적+ 기반 검사 방법과 인공지능 기반 알고리즘을 병합한 하이브리드 접근법을 제안한다. 이를 통해 전극 길이 불량, 깨짐, 크랙 등 다양한 유형의 MLCC 외관 불량을 효과적으로 검출할 수 있는 시스템을 개발하고, 그 성능을 검증하고자 한다. 개발된 시스템은 산업 현장에서 요구되는 고속 처리 능력과 정확도를 모두 충족시킴으로써, MLCC 생산 공정의 품질 향상 및 생산성 증대에 기여할 것으로 기대된다.




Fig. 2 MLCC inspection process




Fig. 3 MLCC vision system

## 2. 머신 비전 기반 MLCC 자동 검사 장치 설계

### 2.1 MLCC Taping 공정의 개요

고속 MLCC 검사 및 테이핑 시스템의 자동화를 위해서는 여러 핵심 기능 모듈로 구성되어 있다. Fig. 2에서 볼 수 있듯이, 이 시스템은 제품의 안정적 공급을 위한 정렬 메커니즘(파츠피더 또는 리니어 피더 방식), 원활한 부품 이송을 위한 슈팅 시스템, 고속 제품 반송 장치를 포함한다. 또한 품질 보증을 위한 정전용량 측정 모듈, 머신 비전 기반 외관 검사 장치, 검사 결과에 따른 양품/불량품 분류 시스템이 통합되어 있다. 최종 포장 단계에서는 carrier tape 공급 장치, reel 시스템, 그리고 검사 완료된 MLCC 칩의 정밀 포장 모듈이 작동하여 전체 공정을 완성한다. 이러한 다양한 기능 모듈들이 유기적으로 연결되어 고효율 자동화 시스템을 구현한다.

### 2.2 고속 비전 검사 시스템 구성

MLCC 제품의 미세한 외관 불량을 고속으로 검출하기 위해서는 고속 머신 비전 시스템의 구축이 필수적이다. 본 연구에서 개발된 비전 검사 장치는 Fig. 3에서 나타난 바와 같이 초당 100프레임 이상의 고속 카메라 2대와 정밀하게 조명 타이밍 제어가 가능한 스트로브 조명 시스템을 중심으로 설계되었다. Fig. 4에 나타난 바와 같이, 이 시스템은 고속으로 회전하는 인덱스 테이블과 동기화되어 작동한다. 0.4 mm × 0.2 mm 크기의 작은 MLCC 부품의 표면 특성과 수십 마이크로미터 크기의 미세 크랙이나 표면 결함까지 감지하기 위해 2 μm/pixel의 높은 공간 분해능을 확보하였다. 이다. 또한 고속 이미지 처리를 위한 전용 프로세싱 유닛을 탑재하여 실시간 불량 판정이 가능하도록 시스템을 최적화하였다.

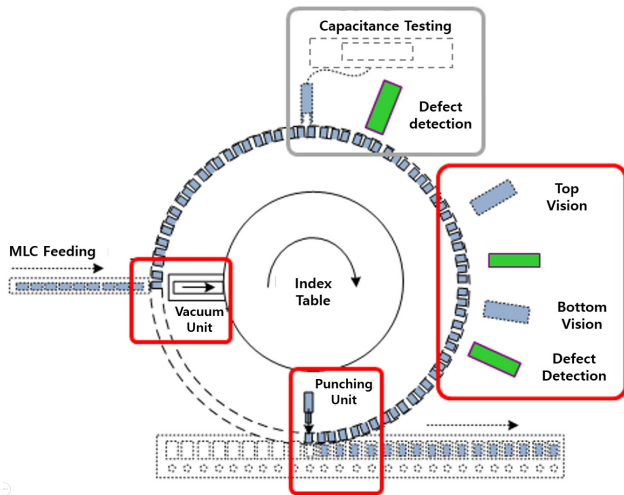


Fig. 4 MLCC inspection main process




Fig. 5 MLCC inspection system

조명 시스템은 MLCC 표면의 다양한 특성(유전체 세라믹 부분과 금속 전극 부분)에 최적화된 조명 구조를 채택하였으며, 특히 반사율이 높은 금속 전극 표면의 결함을 강조할 수 있도록 설계되었다. LED 광원의 파장은 검출이 어려운 크랙 불량이 잘 나타나는 460-470 nm를 파장을 선택하였으며, 다양한 실험을 통한 파장 최적화를 거쳐 여러 유형의 외관 불량에 대한 검출 신뢰성을 크게 향상시켰다.

### 2.3 고속 Reel Taping 검사 장치

본 연구를 통해 개발된 MLCC 고속 reel taping 검사 장치는 Fig. 5에 나타난 바와 같이 크게 다섯 개의 핵심 모듈로 구성되어 있다. 첫째, 정밀 진동 제어 기술이 적용된 MLCC 공급 장치는 미세 부품의 안정적 투입을 담당한다. 둘째, 다중 스펙트럼 조명과 고해상도 카메라를 활용한 외관 검사 모듈은 표면의 미세 결함까지 검출한다. 셋째, 고속과 임피던스 측정 기반의 정전용량 검사 시스템은 전기적 특성을 실시간으로 평가한다. 넷째, 검사 결과에 따라 양품과 불량품을 효율적으로 분류하는 정밀 배출 장치가 구




Fig. 6 MLCC defect types

현되었다. 마지막으로, 검증된 양품만을 캐리어 테이프에 정렬하여 포장하는 자동화 시스템이 통합되어 있다. 이러한 모듈식 구조는 향후 확장성과 유지보수 효율성을 높이는 동시에, 분당 3,800개 이상의 처리 능력을 안정적으로 구현할 수 있다.

## 3. MLCC 외관 불량 검출을 위한 알고리즘 구현

### 3.1 MLCC 표면 결함의 유형 분류 및 특성

MLCC 제품은 최종 전자 제품의 품질에 큰 영향을 미치므로 다양한 유형의 표면 결함을 정확히 식별하고 분류할 수 있어야 한다. 본 연구에서는 고객의 품질검사 요구사항(quality inspection specification)에 기반하여 Fig. 6과 같이 MLCC의 주요 외관 불량을 크게 세 가지 범주로 분류하였다.

전극 길이 불량은 설계 규격 대비 가로·세로 길이가 5% 이상 편차를 보이는 경우로, 주로 인쇄 오류나 소성 과정 변형에서 발생한다. 깨짐 불량은 MLCC 본체의 파손이나 모서리 손상으로, 면적의 10% 이상 변형 시 불량으로 판정하며 주로 물리적 충격이나 열응력에 기인한다. 마지막으로 크랙 불량은 제품 표면의 미세 균열로, 육안 식별이 어렵고 장기적 신뢰성에 영향을 미치는 결함이다. 크랙은 고해상도 이미지 처리와 정밀 알고리즘이 필요한 가장 검출이 까다로운 불량 유형이다.

### 3.2 검사 영역 자동 설정 및 전극 추출

MLCC 부품의 외관 검사를 위한 첫 단계는 Fig. 7(a) 처럼 이미지에서 검사 대상을 정확히 식별하고 관심 영역을 자동으로 설정하는 것이다. 고속 카메라를 통해 획득된 원본 영상에서 MLCC의 전극은 금속성 재질로 인한 높은 반사도 특성을 가지고 있다. 이러한 특성으로 인해 수직 조명에 대해 강한 반응을 보이므로, 단순한 이진화 기법만으로도 전극 영역을 효과적으로 분리할 수 있다. Fig. 7(b)와 같이 기본적인 임계값 기반 이진화 처리를 통해 MLCC의 외관 형상이 명확히 구분되어, 검사 영역의 자동 설정이 가능해진다<sup>3)</sup>.

다음 단계에서는 Fig. 7(b)와 같이 모폴로지 연산(morphological operations)과 윤곽선 추출(contour extraction) 기법을 복합적으로 적용하여 전극 영역을 정확히 분리한다. 이때 Fig. 7(c)와 같이 부품의 회전 각도를 계산하여 주축 방향(principal axis)이 수평이

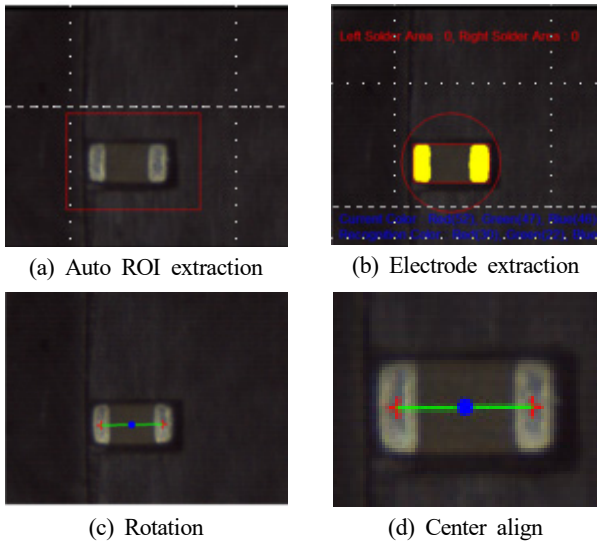


Fig. 7 Automatic detection of inspection area

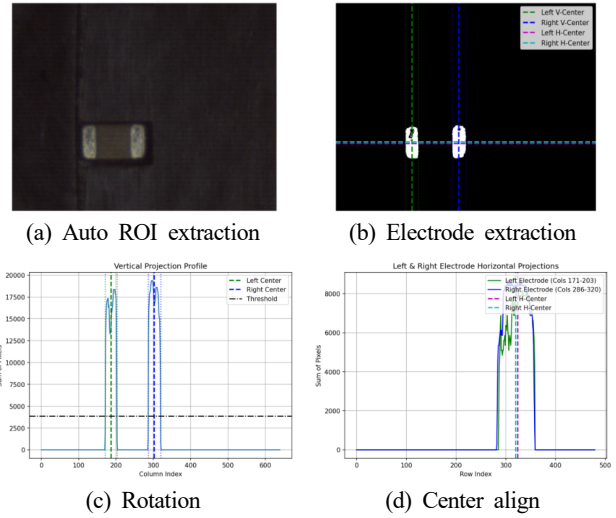


Fig. 8 Automatic detection of inspection area

되도록 Fig. 7(d)처럼 영상의 회전 변환을 수행함으로써, 불량 검출의 정확도를 높인다.

### 3.3 특징치 기반 불량 유형별 검출 알고리즘

#### 3.3.1 전극 길이 불량 검출

전극 길이 불량 검출을 위해, 먼저 Fig. 8(a)에서 ROI를 자동으로 정하고 Fig. 8(b)에서 전극을 추출한 뒤, 수평으로 정렬된 전극 이미지에 대해 Fig. 8(c), (d)와 같이 중심점을 기준으로 수평 및 수직 방향의 투영 프로파일(projection profile)을 생성한다<sup>[6]</sup>. 이 프로파일은 각 방향으로 픽셀 밝기값의 적분을 나타내며, 전극의 길이와 폭을 수치적으로 추출하는 데 활용된다.

투영 프로파일에서 밝기값의 급격한 변화가 발생하는 지점을 경계로 인식하여 전극의 가로와 세로 길이를 계산한다. 측정된 길이는 제품 규격의 허용 오차 범위(±5%)와 비교하여 불량 여부를 판정한다. 이때 정밀한 측정을 위해 서브픽셀(sub-pixel) 정확도의 엣지 검출 알고리즘을 적용하였다.

또한 전극 위치의 중심 오프셋(center offset)을 계산하여 전극 배치의 정확성도 함께 평가한다. 이 과정은 부품의 정확한 기하학적 정렬이 이루어진 후에 수행되므로, 회전에 의한 오차를 최소화할 수 있다.

#### 3.3.2 깨짐 불량 검출

깨짐 불량은 MLCC 모서리나 측면의 구조적 손상을 의미하며, 이를 검출하기 위해 형태학적 분석 기법을 적용한다. 첫 번째 단계로, 분리된 전극 이미지에 대해 컨벡스 헐(convex hull)<sup>[7,8]</sup>을 생성하고 실제 형상과의 차이를 계산한다. 정상적인 MLCC는 거의 직사각형에 가까운 형태를 갖기 때문에, 컨벡스 헐과 실제 형상 간의

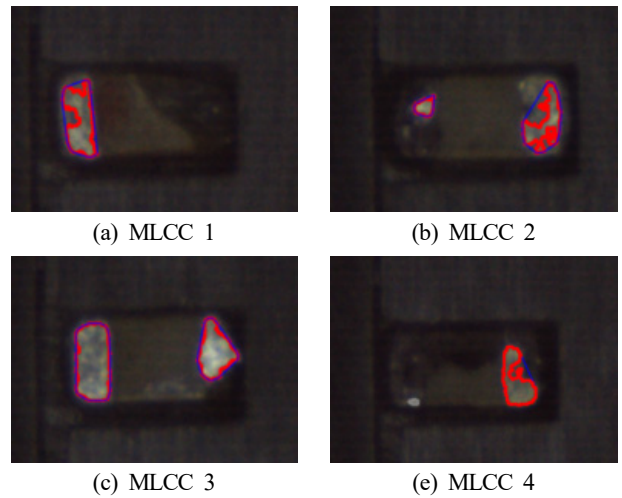


Fig. 9 Electrode deflection of MLCC

차이가 크게 나타나는 경우 깨짐 불량을 Fig. 9와 같이 판단할 수 있다. Fig. 9에서 4개의 MLCC의 깨짐 불량의 검출 예를 나타내었으며, 각 이미지에서 파란색은 컨벡스 헐 도형이고 붉은 색은 실제 도형이다. 식 (1)과 같이 면적을 비교 방법도 병행하여 적용한다.  $A_{Template}$ 는 컨벡스헐의 면적이고,  $A_{current}$ 는 영상에서 MLCC 전극의 면적이다. 기준대비 현재 검사 중인 MLCC의 면적 비율을 계산하여, 10% 이상의 면적 손실이 발생한 경우 깨짐 불량으로 판정한다.

$$Lossratio = \frac{A_{Template} - A_{current}}{A_{current}} \times 100(\%) \quad (1)$$

### 3.4 고속 처리를 위한 다중 쓰레드 구현

전체 영상처리 파이프라인은 처리 효율을 극대화하기 위해 다중

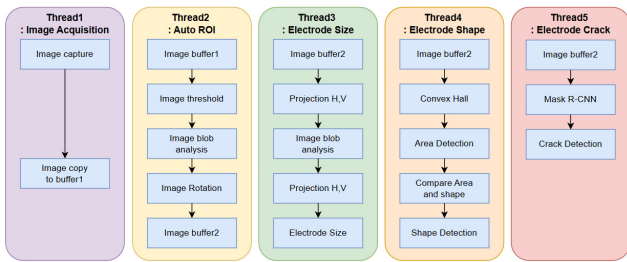


Fig. 10 Thread based image processing




Fig. 11 Crack annotation example

쓰레드 구조로 구현되었다. Fig. 10에서와 같이 이미지 획득, 전극 길이검출, 깨짐 검출, crack 검출 각각 별도의 쓰레드에서 실행되며, 멀티 버퍼링 기법을 통해 데이터 흐름을 최적화하였다. 이러한 병렬 처리 아키텍처는 초당 100프레임 이상의 고속 처리를 가능하게 하며, 시스템의 전체 처리량(throughput)을 크게 향상시킨다. 쓰레드 간 데이터 교환은 세마포어 기반 동기화로 구현되었다. 이러한 병렬 처리 구조는 특히 MLCC와 같은 소형 부품의 고속 검사에 적합하며, 실험 결과 검사 장비는 분당 3,800개 이상의 MLCC를 고속으로 처리할 수 있었다.

## 4. 인공지능기반 MLCC외관 크랙 검출

### 4.1 Mask R-CNN 기반 Crack 검출 알고리즘

MLCC의 크랙과 같은 미세 결함 검출에서 기존 영상처리 기법의 edge 추출 방법의 한계를 극복하기 위해 본 연구에서는 Mask R-CNN 기반의 딥러닝 모델을 활용하였다<sup>[9]</sup>. Mask R-CNN의 모델은 비교적 빠른 검출 속도로 인하여 crack 검출에 많이 사용되고 있다<sup>[10,11]</sup>. Fig. 11에서 보이는 바와 같이 Mask R-CNN의 학습을 위해 250 × 200 pixel의 300개의 크랙 샘플을 사용하여 데이터셋을 구축하였으며, 각 이미지에는 크랙의 위치와 세그멘테이션 마스크를 roboflow를 이용하여 학습하였다. 모델 학습은 리눅스(우분투 20.04) 환경에서 수행되었으며, 주요 하이퍼파라미터는 다음과 같다. 학습률(learning rate)은 0.005, optimizer는 Stochastic Gradient Descent(SGD, momentum=0.9), batch size는 4, 학습 epoch 수는 총 2000으로 설정하였다. Backbone은 ResNet-50과 FPN 구조를 사용하였으며, anchor scales는 [32, 64, 128, 256,




Fig. 12 Crack detection result



Fig. 13 TensorRT conversion

512]로 구성하였다. 손실 함수는 classification과 bounding box regression에 대해 cross-entropy와 smooth L1 loss를 사용하였고, segmentation에는 binary cross-entropy를 적용하였다. 또한, 데이터 증강을 위해 horizontal flip을 적용하였다. Fig. 12는 인공지능 학습 후의 crack 검출 결과를 나타내었다.

### 4.2 고속처리를 위한 AI 추론 엔진 구현

실제 산업 현장에서 요구되는 고속 처리 능력을 충족시키기 위해, Fig. 13과 같이 TensorRT를 활용하여 모델의 양자화(quantization)와 그래프 최적화를 수행함으로써 추론 속도를 크게 향상시켰다. 이러한 최적화 과정을 통해 이미지당 평균 처리 시간을 14 ms 이하로 단축하여, 최고 분당 4,200개 이상의 MLCC를 검사할 수 있는 능력을 확보하였다.

## 5. 실험 결과 및 성능 비교 분석

### 5.1 실험 환경 및 평가 방법

개발된 MLCC 검사 시스템의 성능을 객관적으로 평가하기 위해 실제 산업 현장에서 수집된 테스트 데이터셋을 구성하였다. 테스트 데이터셋은 정상 제품 3,245개와 다양한 유형의 불량 제품(전극 길이 불량, 깨짐 불량, 크랙 불량을 포함한 543개)을 포함하여 총 3,788개의 MLCC 이미지로 구성되었다.

성능 평가는 정확도(accuracy), 정밀도(precision), 재현율(recall)과 같이 표준화된 평가 지표를 사용하였으며, Table 1에서 나타난 바와 같이 불량 유형별 검출 성능과 처리 속도를 중점적으로 분석하였다. 동일한 샘플을 사용하여 총 5회 반복 실험을 수행한 결과 전체 정확도는 98.98%로 나타났고, 98.98%로 나타났고, 오검출률(false positive)은 0.65%, 미검출률(false negative)은 3.21%로 측정되었다. 처리 속도 측면에서는 분당 3,875개의 MLCC를 처리

**Table 1 Comparison of detection performance by MLCC defect types**

| Defect type      | Accuracy (%) | False positive (FP) (%) | False negative (FN) (%) | Detection time (ms) | Recall (%)   |
|------------------|--------------|-------------------------|-------------------------|---------------------|--------------|
| Electrode length | 99.34        | 0.51                    | 2.8                     | 10.52               | 97.29 ± 0.15 |
|                  | 99.37        | 0.5                     | 2.83                    | 10.43               |              |
|                  | 99.63        | 0.51                    | 2.82                    | 10.52               |              |
|                  | 99.53        | 0.53                    | 2.79                    | 10.53               |              |
|                  | 99.27        | 0.5                     | 2.81                    | 10.43               |              |
| Avg.             | 99.098       | 0.31                    | 0.51                    | 10.49               |              |
| Chipping         | 98.49        | 0.7                     | 3.51                    | 10.11               | 98.33 ± 0.16 |
|                  | 98.51        | 0.7                     | 3.5                     | 10.23               |              |
|                  | 99.09        | 0.71                    | 3.53                    | 10.22               |              |
|                  | 98.47        | 0.67                    | 3.5                     | 10.11               |              |
|                  | 98.82        | 0.68                    | 3.49                    | 10.24               |              |
| Avg.             | 98.596       | 0.41                    | 0.69                    | 10.18               |              |
| Crack            | 97.92        | 0.81                    | 4.2                     | 13.14               | 95.66 ± 0.12 |
|                  | 98.11        | 0.82                    | 4.18                    | 13.13               |              |
|                  | 97.8         | 0.79                    | 4.2                     | 13.22               |              |
|                  | 97.21        | 0.8                     | 4.19                    | 13.01               |              |
|                  | 97.99        | 0.81                    | 4.19                    | 13.13               |              |
| Avg.             | 98.196       | 0.59                    | 0.79                    | 13.126              |              |
| Total defects    | 99.23        | 0.65                    | 3.19                    | 13.12               | 96.77 ± 0.19 |
|                  | 98.91        | 0.66                    | 3.21                    | 13.11               |              |
|                  | 99.3         | 0.66                    | 3.17                    | 13.22               |              |
|                  | 99.5         | 0.64                    | 3.18                    | 13.11               |              |
|                  | 98.86        | 0.66                    | 3.21                    | 13.14               |              |
| Avg.             | 98.98        | 0.65                    | 3.21                    | 13.14               |              |

할 수 있는 성능을 보였다. 이 수치는 세계 최고 수준에는 미치지 못하지만, 실제 산업 현장의 요구사항은 충분히 충족하는 것으로 판단된다. 재현율의 경우, 크랙 불량 검출에서는 95.66%로 타 불량 유형에 비해 다소 낮은 수치를 보였으나, 적용된 인공지능 기반 방법은 고속 처리 환경에서도 비교적 안정적인 검출 성능을 유지하는 것으로 나타났다. 또한, 최적으로 동기화된 조명 시스템 역시 신뢰성 높은 영상 데이터를 제공하는 데 기여한 것으로 분석된다.

## 5.2 불량 유형별 검출 성능 비교

MLCC 크랙 불량 검출에 있어 기존 특징치 기반 영상처리 방법과 Mask R-CNN 기반 인공지능 방법의 성능을 비교 분석하였다. 크랙 불량에 대한 두 방법의 검출 성능과 처리 시간을 종합적으로 평가하였다.

인공지능 기반 MLCC 크랙 검출 시스템의 성능을 평가하기 위

해 다양한 평가 지표와 비교 분석 방법을 활용하였다. 정확도(accuracy), 정밀도(precision), 재현율(recall)와 같은 표준화된 평가 지표를 사용하여 모델의 종합적인 성능을 평가하였다. 각 지표는 총 5회 반복 실험 결과의 평균값과 표준편차(mean ± SD)를 기준으로 제시하였다. 이를 통해 모델 성능의 신뢰도와 일관성을 함께 확보하고자 하였다.

오검출(false positive) 및 미검출(false negative) 사례를 질적으로 분석했을 때, 반사나 이물질에 의한 오검출, 그리고 극도로 얇은 크랙의 미검출 사례가 확인되었으며, 이를 개선하기 위해서는 해상도 개선과 최적의 광원 파장을 선정해야 할 것으로 예상된다.

## 6. 결론

본 연구에서는 적층 세라믹 콘덴서(multi-layer ceramic capacitor, MLCC) 생산 과정의 마지막 단계인 테이핑(taping) 공정에서의 고속 검사 장비를 개발하였다. MLCC의 외관 검사를 위해 특징치 기반 영상처리 알고리즘과 인공지능 기반 검출 알고리즘을 결합한 하이브리드 접근법을 제안하였다. 전극 길이 불량과 깨짐 불량은 특징치 기반 영상처리 방법을 이용하여 고속으로 검출하였으며, 검출이 까다로운 미세 크랙 불량은 Mask R-CNN 기반의 인공지능 모델을 적용하여 검출 정확도를 크게 높였다. 이러한 하이브리드 구조는 각 불량 유형에 최적화된 검출 방법을 선택적으로 적용함으로써 시스템의 처리 속도와 정확도를 모두 향상시켰다.

실험 결과, 개발된 장비는 분당 3,875개의 MLCC를 안정적으로 분류할 수 있었으며, 98.98%의 높은 정확도를 달성하였다. 특히 오검출률(false positive)은 0.65%, 미검출률(false negative)은 3.21%로 산업 현장에서 요구하는 품질 기준을 충족하였다. 인공지능 기반 크랙 검출 알고리즘은 기존 영상처리 방법으로는 검출이 어려운 20 μm 수준의 크랙에서도 98.2%의 높은 검출률을 달성하여, 품질 검사의 신뢰성을 크게 향상시켰다.

다중 쓰레드 기반의 병렬 처리 아키텍처와 GPU 가속 추론 엔진의 구현을 통해 고속 처리 능력을 확보하여, 고속 생산 라인에서도 실시간 검사가 가능한 시스템을 구현하였다. 개발된 시스템은 고품질의 MLCC 생산을 위한 핵심 검사 장비로서, 스마트폰, IoT 기기, 전자동차 등 다양한 전자제품의 품질 향상에 기여할 것으로 기대된다.

향후 연구로는 더 많은 불량 데이터를 확보하여 인공지능 모델의 성능을 지속적으로 개선하고, 다양한 종류의 MLCC에 대한 검사 기능을 확장하는 것이 필요하다. 현재 4가지 불량 유형을 더 세밀하게 분류할 수 있도록 알고리즘을 개선할 계획이다. 크랙부

분의 불량 검사 효율을 개선하기 위하여 카메라의 해상도 증대와 불량별로 최적의 광원을 적용하여 다중 카메라의 사용도 진행할 예정이다.

세계 1위의 제품과 경쟁하기 위해서는 다중 카메라와 인공지능 가속기를 활용하여 초당 4,000개 이상의 고속 검출 성능을 확보하고 H/W 검사 시스템의 처리 능력을 높이는 것도 필요하다. 그리고 생산 환경의 변화에 자동으로 적응할 수 있는 자가 학습 시스템의 개발을 통해 검사 장비의 지능화를 더욱 발전시킬 계획이다.

## References

- [1] Jung, J. U., Kim, H. J., Son, S. B., Oh, H. S., 2022, MLCC Lamination Alignment Inspection System using Deep Neural Network, Journal of Institute of Control, Robotics and System, 28:7 699-705, <https://doi.org/10.5302/J.ICROS.2022.22.0071>.
- [2] Ko, K. W., Lee, J. Y., 2023, Development of Visual MLCC Inspection Machine, Korea Academia-Industrial cooperation Society Fall Conference 152-155, <[https://www.kais99.org/jkais/springNfall/autumn2022/oral/2022\\_autumn\\_049.pdf](https://www.kais99.org/jkais/springNfall/autumn2022/oral/2022_autumn_049.pdf)>.
- [3] He, J., Cao, X., Takamasu, K., Chen, M., 2024, Machine Vision-Based Lightweight Multiscale Automatic Defect Segmentation Network for MLCC, IEEE Transactions on Instrumentation and Measurement, 73 2523908, <https://doi.org/10.1109/TIM.2024.3415777>.
- [4] Lee, C. H., Yoon, J. R., 2022, Reliability Characteristics of High-capacity Multilayer Ceramic Capacitors According to Highly Accelerated Life Test, Journal of Ceramic Processing Research, 23:6 794-798, <https://doi.org/10.36410/jcpr.2022.23.6.794>.
- [5] Ko, K. W., Lee, J. Y., 2023, Development of a Visual Inspection System for Wafer Handling with Collets, J. Korean Soc. Manuf. Technol. Eng., 32:1 29-36, <https://doi.org/10.7735/ksmte.2023.32.1.29>.
- [6] Gonzalez, R. C., Woods, R. E., 2008, Digital Image Processing 3rd, Prentice-Hall, USA.
- [7] Knueven B., Ostrowski J., Castillo A., Watson J., 2022, A Computationally Efficient Algorithm for Computing Convex Hull Prices, Comput. Ind. Eng., 163 107806, <https://doi.org/10.1016/j.cie.2021.107806>.
- [8] Thot, C. D., O’rourke, J., Goodman, J. E., 2017, Handbook of Discrete and Computational Geometry(Third Edition) - Chapter 26 : Convex Hull Computations, CRC Press, USA, <https://doi.org/10.1201/9781315119601>.
- [9] He, K., Gkioxari, G., Dollár, P., Girshick, R., 2017, Mask R-CNN, Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2980-2988, <https://doi.org/10.1109/ICCV.2017.322>.
- [10] Lee, D. H., Kim J. H., Lee, D.W., 2019, Robust Concrete Crack Detection Using Deep Learning-Based Semantic Segmentation, Int. J. Aeronaut. Space Sci., 20 287-299, <https://doi.org/10.1007/s42405-018-0120-5>.
- [11] Golding, V. P., Gharineiat, Z., Munawar, H. S., Ullah, F., 2022, Crack Detection in Concrete Structures Using Deep Learning, Sustainability, 14:13 8117, <https://doi.org/10.3390/su14138117>.



**Kuk Won Ko**  
 Professor in the Department of Future Mobility,  
 Halla University. His research interest is  
 Machine Vision.  
 E-mail: [kukwon.ko@halla.ac.kr](mailto:kukwon.ko@halla.ac.kr)