

◆특집◆ 지능형 Machine Vision 응용

PCA 알고리즘을 기반으로 한 SMT 각칩의 자동 검사 방법

고경철*, 고국원*, 김종형**, 최현주***, 김재선****

An Automatic Inspection of SMT Rectangular Chips based on PCA Algorithm

Kyoung Chul Koh*, Kuk Won Ko*, Jong Hyeong Kim**, Hyun Joo Choi*** and Jae Seon Kim* ***

Key Words : SMT(표면실장기술), PCB Inspection(인쇄회로기판 검사), AOI(자동시각검사), PCA(principle component analysis, 고유축 분석), Recangular chip(각형 칩 부품)

1. 서론

현재 산업체에서 생산하고 있는 PCB 조립용 부품의 크기는 소형화되고 기판 위의 밀집도(board density)는 매우 증가하고 있다. 따라서 한 장의 PCB 내에서 검사하여야 할 검사 점의 수도 늘어나고, 처리 시간 면에서도 고속화된 검사 시스템이 요구된다. 반면에 조립된 PCB를 검사하는 검사기의 개발은 아직 미진하여, 사람의 수동적 육안 검사에 의존하는 경우가 많다. 작업자가 일일이 소형화 된 부품의 결함을 검사하는 것은 힘든 작업으로 쉽게 피로하고 시간이 많이 걸릴 뿐만 아니라, 검사 과정에 대한 객관성이 보장되지 않는다. 이러한 이유 때문에 육안 검사는 PCB 상의 부품 밀도가 높아질수록 검사의 객관성과 검사 결과의 신뢰성에 한계를

보인다.[1]

이와 같은 이유로 더욱 신뢰성 있고 빠른 시간 안에 부품을 자동 인식 할 수 있는 AOI 기법이 요구 되는데, 이를 위해 지금까지 제안된 고전적인 AOI 알고리즘 중에는 템플릿 매칭(template matching), 퓨리에 해석(Fourier analysis), 경계 해석, 기하학적 특징 인식, 광학 문자 인식(optical character recognition, OCR) 등이 있다.[2-5] 이와 같은 알고리즘들은 정형화된 검사 모델에 대해서는 좋은 검사 결과를 보여 준다. 그러나 실제 환경에서는 동일한 부품이라 하더라도 조명의 차이나 기계적 위치 오차 때문에 서로 다른 부품의 영상이 얻어 지므로, 고정된 템플릿 방법은 유연성이 떨어지는 한계를 보인다. 또한 이러한 알고리즘들은 검사하고자 하는 부품의 학습 시간이 오래 걸리고, 새로운 실장 부품의 적용에 유연성 있게 대처할 수 없으며, 사용자의 오랜 경험을 요구하는 등의 단점이 있다. 이러한 문제점을 해결하기 위해 종종 여러 가지 영상 분석 기술들이 혼합, 연결되어 사용되기도 한다. 그러나 하나의 보드에는 보통 수십에서 수백 개의 부품이 조립되므로, 이러한 혼합형 알고리즘은 프로그래밍 엔지니어에게 보드가 바뀌고 조정될 때마다 매번 프로그램 수정을 요구하고, 수정 작업은 복잡할 뿐만 아니라 오랜 시간이 소요된다. 또한 완전히 새로운 보드를

* 선문대학교 기계 및 제어공학부 교수
Tel. 041-530-2348, Fax. 041-530-2981

mail: kuks2309@sunmoon.ac.kr

** 서울 산업대학교 기계설계자동화공학부
Tel. 02-970-6357, Fax. 02-974-8270

Email : johnkim@snut.ac.kr

*** Embedded web 연구원

**** (주)Synapse imaging 대표

영상 처리를 이용한 시각 검사 자동화 및 지능화, 영상처리 시스템 개발, 인공지능에 관심을 두고 연구하고 있다

검사하기 위한 경우에는 프로그램의 최적화를 위하여 수주일이 소요되기도 한다.

본 연구에서는 이러한 문제점을 극복하고, 보다 효율적인 부품 검사를 위해, 통계학적 학습 알고리즘들의 도입이 검토되었다.[6-10] 특히, 본 연구에서는 사전에 입력 데이터분석을 통해 효과적 학습 방법인 고유축 분석(PCA, Principal Component Analysis)을 통하여, SMT 전자 부품의 자동 검사 방법을 개발하고자 한다. 또한 재귀적 형태의 학습 구조와 새로운 부품 특징치를 적용하여 보다 향상된 PCB 상의 부품 검사 방법을 연구한다.

2. 제안된 검사 알고리즘

2.1 개요

본 논문에서 제안된 알고리즘은 그림 1에서와 같이 크게 영상 입력 단계, 학습 단계, 검사 단계의 세 단계로 나누어지며, 영상 입력 단계에서는 입력된 PCB 영상을 전처리 하는 과정으로, 부품의 위치와 크기를 보정하는 알고리즘을 제안하였다. 학습 단계는 입력된 각 부품 영상을 통계학적 알고리즘을 기반으로 학습하는 단계로, 이 과정에서 생성되는 학습 데이터 베이스는 검사 단계에서 대상 부품의 양/불량 판정 기준이 된다. 학습 단계에서는 PCA 알고리즘의 사용과 새로운 부품 특징 치 선정 방법 및 재귀적 형태의 학습 구조를 제안하였다. 검사 단계에서는 부품 양/불량 판정 알고리즘을 제안하였으며, 앞서 제안한 재귀적 형태의 학습 구조의 사용으로 검사 단계에서 새로운 부품 특성 추가 시에 생기는 번거로움을 최소화하였다.

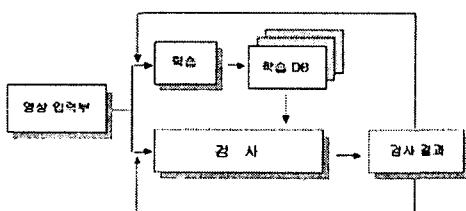


Fig. 1 Block diagram of proposed inspection algorithm

2.2 전처리 과정

부품 학습 및 검사시에 입력되는 PCB 영상에 대한 전처리 과정은 ROI (Region Of Interest)내의 부

품 위치를 보정(calibration)하는 단계와 학습 및 검사하고자 하는 부품의 영상을 지정된 크기로 보간(interpolation)하는 단계로 이루어진다.

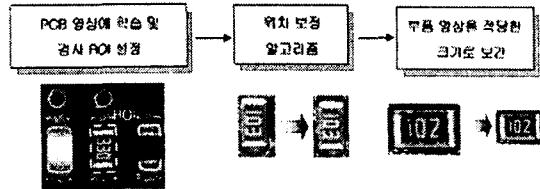


Fig. 2 Pre-processing algorithm

2.3 부품위치 보정 알고리즘

통상 SMD 마운터의 기계 정밀도는 $25 \sim 30 \mu\text{m}$ 정도로, 이는 영상 좌표계에서 약 1 픽셀 정도에 해당되지만, 본 연구에서는 ROI 내의 부품 자체를 특징치로 사용하므로 단 1 픽셀이라도 ROI의 중심이 부품의 중심에서 벗어나게 되면 검사 결과 신뢰성이 저하된다. 따라서 ROI 내 부품의 위치 보정이 필요하다.

본 논문에서는 부품의 위치 보정 방법으로서, 그림 3과 같이 ROI 내의 이미지를 각각 수직/수평으로 사영(projection)시킨 값에 적당한 마스크를 사용하여 컨벌루션(convolution)한 값이 최대치가 되는 점을 부품의 중심으로 보정하는 알고리즘을 사용한다.

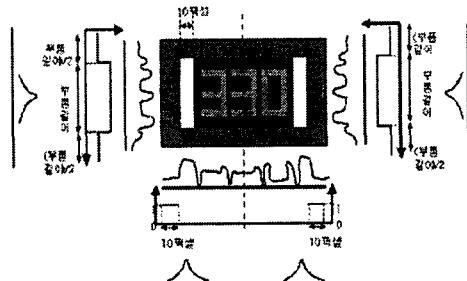


Fig. 3 Part Location detection algorithm

수직방향 컨벌루션후에는 그림 4 와 같이 2 개의 최고점(peak point)이 생긴다. 이는 부품 양끝 단에 존재하는 각 리드의 중심을 나타내는 것으로, 이 두 개의 최고점의 중심 값이 부품 ROI 내에서의 가로축 중심이다.

마찬가지로 수평방향 컨벌루션후에도 부품 ROI

의 좌/우에 2 개의 최고점이 생기는데, 이 두 점을 연결한 직선의 기울기는 ROI 내 부품이 회전된 각도 θ 이다. ROI 내 부품의 중심은 그림 4에서 와 같이 가로축 중심 (a)와 ROI 좌/우의 최고점을 연결한 직선 (b)가 만나는 점이다.

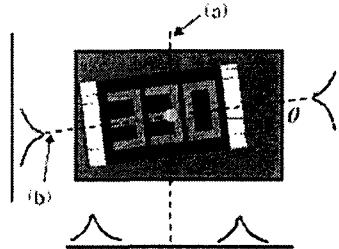


Fig. 4 Result of part location detection

2.4 영상 크기 보정

PCB 상에서 임의의 부품을 학습시키거나 검사하기 위해서는 부품을 포함하는 적당한 크기의 ROI를 설정해야 한다. 그러나 보통 한 장의 PCB 상에는 수십에서 수백 가지의 부품들이 놓여 있는데, 이 가운데 같은 부품끼리 같은 크기의 ROI를 써워서 학습시키는 것은 숙련된 기술자라 하더라도 매우 어렵고 번거로운 일이다. 그렇다고 모든 부품에 대하여 고정된 크기의 마스크를 써우는 것은 비효율적이며, 실제로 다른 크기의 새로운 부품일 경우 ROI를 매번 수정해야 한다. 본 논문에서는 이러한 문제점을 해결하기 위해 대상 부품 근처에 적당한 ROI를 설정하면, 부품 종류에 따라 지정된 크기의 ROI로 부품 영상을 보간하는 방법을 제안한다.

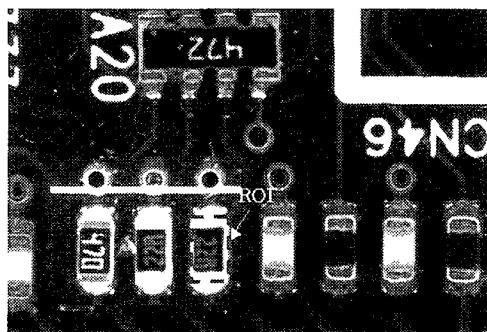


Fig. 5 Image of part on PCB

그림 5 와 같이 PCB 상에 캐패시터가 놓여 있을 경우, 마우스를 사용하여 부품 근처에

적당한 ROI를 지정할 수 있다. ROI 범위와 보간 범위의 비례 축소비가 2 배 이내라 가정하고, 그림 6에서와 같이 PCB 영상 상에서 지정된 ROI의 폭을 Col, 높이를 Row 라하고, 보간 할 영상의 폭과 높이를 각각 C, R이라 한다. 그러면 보간 범위의 크기를 기준으로 할당하여야 할 각 픽셀들의 크기는 높이가 Row/R 이 되고 폭은 Col/C 가 된다. 보간 범위의 각 픽셀값은 그림 7 과 같이 새로 계산되어야 할 픽셀 위치 좌표값을 기준으로 근처 4 개 근방의 픽셀값 ($P_{00}, P_{01}, P_{10}, P_{11}$) 과 각 픽셀까지의 거리 (dx, dy)를 선형 결합하여, 식 (1)과 같이 계산된다.

$$P = P_{00}(1-dx)(1-dy) + P_{01}(dx)(1-dy) + P_{10}(1-dx)(dy) + P_{11}(dx)(dy) \quad (1)$$

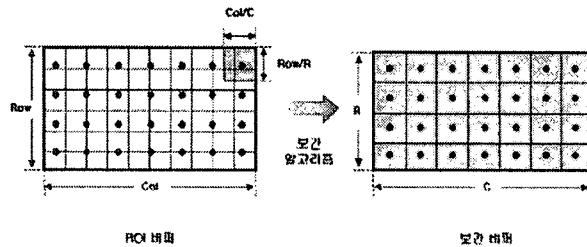


Fig. 6 Resize method of image

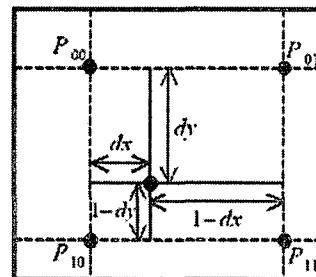


Fig. 7 Linear interpolation

2.5 특징치 선정

본 연구에서는 부품 영상의 밝기값(intensity)을 부품 특징치로 사용한다. 부품 특징치 선정에 제안된 방법은 3×3 격자 모델과 사영 단면 모델이 있다. 3×3 격자 모델 방법은 3×3 크기의 격자를 이용하여 부품 정보를 샘플링(sampling)하는 방법으로, 격자크기는 3은 제한된 계산 시간 내에서 부품 크기 및 검사 결과의 신뢰성을 고려하여 결

정된 값이다. 사영 단면 모델은 부품 영상 밝기값을 각각 수직과 수평 방향으로 사영 시킨 값을 부품 특징치로 사용하는 방법이다.

2.6 PCA(Principal component analysis)

코호넨 러브 변환(Karhunen-Loeve transform) 혹은 호텔링 변환(Hotelling transform)이라고도 불리는 PCA 알고리즘은 고유값과 고유 벡터의 통계적 특성에 기반을 둔 알고리즘으로, 임의의 n 차원으로 표현될 수 있는 데이터를 고유축을 사용하여 적당한 차원으로 줄여서 표현할 수 있는 장점이 있다[6, 7].

그림 8 과 같이 임의의 표본 집단에서 i 번째 데이터의 평균은 \bar{X}_i 라하고, j 번째의 고유축은 e_j 라고 하자. 그러면 표본 집단에 속하는 i 번째 원소 X_i 는 e_j 축 상에서 가장 가까이 있는 X' 로 근사화 될 수 있다. 여기서 b 는 평균 \bar{X}_i 와 X' 사이의 거리이다.

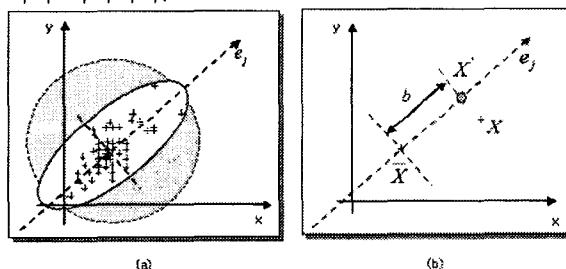


Fig. 8 Concept of PCA learning algorithm

다음과 같이 n 개의 요소를 갖는 임의의 학습 패턴을 생각해 보자.

$$X = [x_1 \ x_2 \ \cdots \ x_n]^T \quad (2)$$

여기서 T 는 벡터의 전치(transposition)임을 나타낸다. 그리고 임의의 모집단에서 추출한 S 개의 벡터 표본에 대해서, 공분산 행렬(covariance matrix)과 평균 벡터는 표본들을 가지고 아래와 같이 구할 수 있다.

$$C = \frac{1}{S} \sum_{i=1}^S (X_i - \bar{X})(X_i - \bar{X})^T \quad (3)$$

$$\bar{X} = \frac{1}{S} \sum_{i=1}^S X_i \quad (4)$$

공분산 행렬 C 는 실수값을 가지고 대칭이기 때문에, n 개의 정규 직교 고유 벡터 집합을 찾는 것은 항상 가능하다. $i = 1, 2, \dots, n$ 인 e_i 및 λ_i 를 C 의 고유 벡터와 그에 상응하는 고유값이라 하고, $j = 1, 2, \dots, n-1$ 에 대해, $\lambda_j \geq \lambda_{j+1}$ 이 되도록 내림차순으로 정렬한다. 즉 Φ 가 식(5)과 같이 t 개의 고유 벡터 e_i 들을 가지고 만들어낸 행렬이라면, Φ 의 첫 번째 열은 가장 큰 고유값에 대응되는 고유 벡터이고 마지막 열은 가장 작은 고유값에 대응되는 고유 벡터가 된다.

$$\Phi = (e_1 \ e_2 \ \cdots \ e_t) \quad (5)$$

표본들을 학습한 후에 얻어진 평균 벡터 \bar{X} 와 적당한 t 개의 고유벡터 집합으로 구성된 Φ 로 부터 임의의 학습 패턴 X 는 다음 식을 사용하여 X' 로 근사화 될 수 있다.

$$X \approx X' = \bar{X} + \Phi b \quad (6)$$

여기서 b 는 학습 평균 벡터부터 적당한 범위내에 있는 임의의 변형된 패턴을 구하는 변수이다. b 의 범위는 학습 패턴으로부터 얻어진 분산으로부터 유도되며, 일반적으로 $i = 1, 2, \dots, t$ 에 대해서 다음 식 (7)과 같이 그 범위를 제한한다.

$$-3\sqrt{\lambda_i} \leq b \leq 3\sqrt{\lambda_i} \quad (7)$$

2.7 재귀적 형태의 학습 구조

기존의 부품 검사 알고리즘은 비재귀적인 방식(non-iterative)으로 새로운 실장 부품의 삽입이나, 학습 데이터를 추가하고 싶을 경우에는 다시 처음부터 모든 과정을 되풀이해야만 하는 단점이 있다. 이 방법은 한 기관 당 부품의 수가 적을 경우에도 수정하는 데만 하루 내지는 이틀의 시간이 소요되고, 요즘과 같이 기관 위의 부품 밀도가 매우 높은 기관의 경우, 시간적으로나 비용 면에서 적용하기 어려운 방법이다.

본 연구는 실제 SMD 마운터 장비에 적용할 수 있는 검사 알고리즘 개발에 그 목적이 있으므로, 학습 패턴의 통계학적 학습 모델을 재귀적 형태(iterative form)로 구할 필요가 있다. 재귀적인 상관 행렬을 구하기 위해 먼저 평균 벡터도 재귀적으로 구해야 한다. 먼저 k 번째 학습패턴이 들어왔을 때의 이미지 특징 벡터의 평균은 다음과 같다.

$$\bar{X}_k = \frac{1}{k} \sum_{i=1}^k X_i \quad (8)$$

식(8)의 k 번째 평균 열벡터와 $k+1$ 번째 영상의 열벡터를 사용하여 $k+1$ 번째 평균 벡터의 재귀적 형태는 다음과 같이 쓸 수 있다.

$$k \bar{X}_k = \sum_{i=1}^k X_i \quad (9)$$

$$\bar{X}_{k+1} = \frac{1}{k+1} \left(\sum_{h=1}^k X_h + X_{k+1} \right) \quad (10)$$

$$\bar{X}_{k+1} = \frac{1}{k+1} \left(k \bar{X}_k + X_{k+1} \right) \quad (11)$$

그리고 k 번째 학습패턴이 들어왔을 때의 이미지 특징 벡터의 분산행렬은 식(3)으로부터 다음과 같이 쓸 수 있다.

$$C_k = \frac{1}{k} \sum_{i=1}^k (X_i - \bar{X}_k)(X_i - \bar{X}_k)^T \quad (12)$$

$$= \frac{1}{k} \left\{ \sum_{i=1}^k X_i X_i^T - \left(\sum_{i=1}^k X_i \right) \bar{X}^T - \bar{X} \left(\sum_{i=1}^k X_i \right)^T + \sum_{i=1}^k \bar{X} \bar{X}^T \right\} \quad (13)$$

$$\therefore k C_k = \frac{1}{k+1} \left\{ k S_k + (X_{k+1} - \bar{X}_k)(X_{k+1} - \bar{X}_k)^T \right\} \quad (14)$$

여기서 $\sum_{i=1}^k X_i X_i^T - (k-1) \bar{X}_{k-1} \bar{X}_{k-1}^T$ 이다.

$$(k-1) C_{k-1} = \sum_{i=1}^{k-1} X_i X_i^T - (k-1) \bar{X}_{k-1} \bar{X}_{k-1}^T \quad (15)$$

따라서 $k+1$ 번째 학습패턴이 추가되었을 때 분산행렬의 재귀적 형태는 다음과 같이 쓸 수

있다.

$$C_{k-1} = \frac{1}{k+1} \left\{ k S_k + (X_{k+1} - \bar{X}_k)(X_{k+1} - \bar{X}_k)^T \right\} \quad (16)$$

2.8 부품 양/불량 판정 알고리즘

식(6)에서, 평균(\bar{X})과 PCA 행렬(Φ) 값은 학습 모델로부터 학습되는 통계학적 모델의 특징이 된다. 벡터 b 는 검사 모델의 매개변수 집합으로 정의되며 b 의 요소값을 변화시킴으로써 식(6)을 이용하여 학습 패턴의 다른 예를 만들어 낼 수 있다. 주어진 샘플패턴(X')으로부터 식(6)을 이용하여 다음과 같이 변형벡터 b 를 계산한다.

$$b = \Phi^T (X' - \bar{X}) \quad (17)$$

여기서 학습 패턴에 포함되지 않았던 임의 샘플패턴(X')이 기존의 학습 패턴과의 유사성을 판단하는 기준으로는 크게 다음과 같이 Hard Limitation 과 Soft Limitation 의 2 가지 방법이 있다.

방법-I) Hard Limitation

벡터 b 의 i 번째 변수인 b_i 의 통계학적 분산은 λ_i 가 된다. 만약 학습 패턴의 변형 벡터 b 의 요소 b_i 가 독립적이고, 정규 분포(Gaussian Distribution)를 갖는다면, b 가 3σ 의 확신을 가지고 학습 패턴 확률 분포 내에 포함될 조건은 다음과 같다.

$$|b_i| = 3\sqrt{\lambda_i} \quad (18)$$

여기서 $3\sqrt{\lambda_i}$ 는 b_i 의 hard limit 이 된다. 따라서 주어진 샘플패턴(X')이 학습 패턴(X)과 유사한지 아닌지를 판단하는 기준은 다음과 같이 정한다.

$$L_k = (|b_1| \leq 3\sqrt{\lambda_1}) \oplus (|b_2| \leq 3\sqrt{\lambda_2}) \oplus \cdots \oplus (|b_t| \leq 3\sqrt{\lambda_t}) \quad (19)$$

여기서 \oplus 은 AND 연산을 나타내고, $i=1, 2, \dots, t$ 에 대해서 각각의 행에서 $|b_i|$ 가 $3\sqrt{\lambda_i}$ 이하이면 1 이 된다. 따라서 $L_k = 1$ 이면, 주어진 샘플패턴(X')이 학습 패턴(X)과 유사하다고 판단하고, $L_k = 0$ 이면 다르다고 판단할 수 있다.

방법-II) Soft Limitation

이 방법은 학습 패턴에 대하여 주어진 모델의 변형 벡터 b_i 를 계산하여 부품의 양/불량 판정을 하는 것으로, Soft Limitation 방법에서 제안된 판정 방법들은 다음 6 가지이다.

1. $\sum_{i=1}^t |b_i|$
2. $\sum_{i=1}^t |b_i| W_i$
3. $\sum_{i=1}^t b_i^2$
4. $\sum_{i=1}^t b_i^2 / 9\lambda_i$
5. $\sum_{i=1}^t C_i / L_i$
6. $\sum_{i=1}^t (C_i / L_i) W_i$

여기서 t 는 고유 벡터의 전체 개수를 n 개라고 할 때 ($n \geq t$), 전체 고유 벡터를 사용하지 않고서도 부품의 특성을 충분히 표현할 수 있는 최소의 t 이다. W_i 는 $\lambda_i / \sum_{i=0}^n \lambda_i$ 으로 부품의

전체 특성에 대해서 i 번째 특성이 갖는 비율을 나타내며, 가중치로 사용된다. L_i 는 i 번째 특성의 범위 즉, $-3\sqrt{\lambda_i} \sim 3\sqrt{\lambda_i}$ 의 거리를 나타낸다. 그리고 C_i 는 $b_i + 3\sqrt{\lambda_i}$ 와 $b_i - 3\sqrt{\lambda_i}$ 의 값을 계산하여, 두개의 값 중에서 작은 값으로 할당된다.

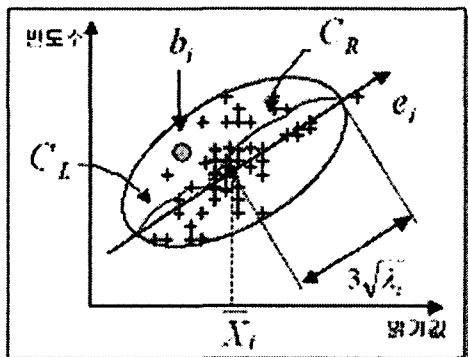


Fig. 9 Decision rule of soft limitation

이와 같이 제안된 6 가지의 방법으로 계산된 값을 L_k 라 했을 때, 주어진 검사 부품의 양/불량 판정은 다음 식 (20)와 같이 δ_t 에 따라 결정된다. 여기서 δ_t 는 임계값으로 실험을 통해 적절하게 정한다.

$$L_k \leq \delta_t \quad (20)$$

이 방법의 판단기준은 여러 기준(b_i)의 총 점수의 형태이므로 학습시킨 부품과 얼마나 유사한지를 연속적으로 표현할 수 있고, 임계값을 어떻게 결정하느냐에 따라 주어진 샘플패턴(X')의 유사성이 결정되므로 방법 1 보다 유연하다는 장점을 갖는다.

3. 제안된 알고리즘의 성능 평가

3.1 실험 환경

본 논문에서는 제안된 알고리즘을 실제 PCB 검사 장비에 탑재하여 구현하기 전에, 장비와 연결되어 있지 않은 컴퓨터에서 검증 단계를 거쳤다. 이하 위와 같이 장비와 연결되어 있지 않은 컴퓨터상에서 부품의 영상을 갖고 검사한 방법을 오프라인(off-line)에서의 검사라 하고, 실제 산업라인에서와 같이 장비와 연결되어 있는 환경을 온라인(on-line)상에서의 검사라 정의한다. 오프라인 상에서의 실험 장치는 그림 10 과 같다.

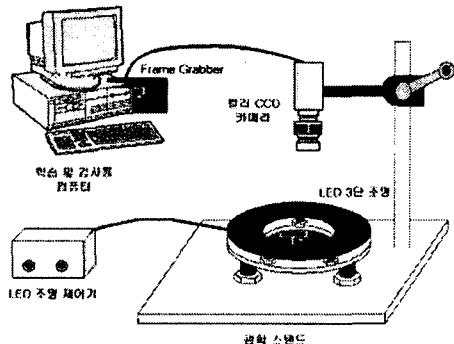


Fig. 10 Experimental setup

오프라인 상에서는 실제 SMD 검사 장비와 연결되어 있지 않아서 PCB 기판을 이동하면서 자동으로 학습 및 검사를 할 수는 없으나, 일반적인 SMD 검사 장비와 같은 원리의 광학 장치를 적용하여 검사 환경의 신뢰도를 높였다. 온라인상의 검사는 일반적인 SMD 검사 장비가 연결되어 있는 모의 환경을 통해 이루어 졌으며, 본 연구에서의 실험 결과는 모두 SMD 모의 실험 환경에서 이루어진 결과이다. 장비가 연결되어 있는 컴퓨터의 사양은 CPU 800MHz, 512MB RAM이다.

제안된 부품 검사 알고리즘은 크게 영상 입력부에서의 초기화 단계, 학습 단계, 검사 단계로

나누어 볼 수 있다. 초기화 단계는 첫 번째 학습 부품에 대해서만 이루어지며, 부품의 학습 및 검사시에 사용되는 여러 가지 파라메터 및 부품의 이름, 부품 특징치, 그리고 보간 베피의 크기를 설정한다. 초기화 단계에서 설정된 파라메터 값들은 같은 부품명을 가진 부품에 대해 모두 적용되며, 부품의 이름은 학습 DB 호출시에 부품을 구별하는데 사용된다.

그림 11은 부품의 학습 및 검사 단계의 흐름도이며, 점선은 재귀적 형태의 학습 구조를 나타낸 것이다. 첫 번째 학습 대상 부품에 대해서만 초기화를 하며, 계산 시간 단축을 위해 학습 마지막 단계에서만 고유값과 고유 벡터를 계산한다.

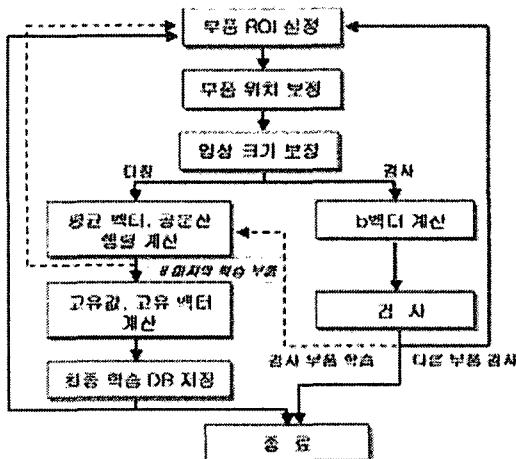


Fig. 11 Overall experimental flowchart

3.2 판단기준 변화 실험

양/불량 판정 기준 변화 실험은 2.9 절의 Soft Limitation에서 제안된 각각의 판정 방법들을 적용하여 부품을 검사하였을 때, FRR과 FAR을 살펴보는 실험이다. 부품 특징치는 제안된 방법 가운데 부품 정보 신뢰성이 가장 낮을 것으로 예상되는 $N \times N$ 격자 모델의 3×3 평활화 방법을 사용하였다. 다음의 결과들은 330 저항 21 개를 학습시킨 후에, 학습 접합 내에 속하는 부품(계열 1)과 비학습 접합에 속하는 부품(계열 2)을 검사한 것이다. 표 1에서 사용된 임계값 1과 임계값 2는 각각 학습군에 속하는 부품을 검사한 결과값들의 평균값과 최대값이다. 실험 결과를 비교한 표 1를 보면 $\sum_{i=1}^l b_i^2 / 9\lambda_i$ 의 경우가 가장 낮은 FRR와

FAR를 유발하였고, 그림 16 ~ 그림 21에서도 불

수 있듯이, 학습 부품군과 비학습 부품군의 구별도 가장 뚜렷하게 나타난다. 따라서 본 연구 실험에서 제안한 부품의 양/불량 판정 기준 방법들 가운데 $\sum_{i=1}^l b_i^2 / 9\lambda_i$ 를 적용한 부품 판정이 가장 신뢰성이 있음을 알 수 있다.

Table 1 Experimental results of various decision rule

| 검사 판정 기준 | 임계값_1 | FRR(%) | FAR(%) | 임계값_2 | FRR(%) | FAR(%) |
|-----------------------------------|----------|--------|--------|----------|--------|---------|
| $\sum_{i=1}^l b_i$ | 1063.811 | 54.838 | 0.000 | 1431.064 | 0.000 | 5.405 |
| $\sum_{i=1}^l b_i W_i$ | 172.2347 | 54.838 | 35.135 | 249.4758 | 0.000 | 91.891 |
| $\sum_{i=1}^l b_i^2$ | 167449.1 | 48.387 | 2.702 | 231462.5 | 0.000 | 5.405 |
| $\sum_{i=1}^l b_i^2 / 9\lambda_i$ | 2.949498 | 29.032 | 0.000 | 5.860672 | 0.000 | 0.000 |
| $\sum_{i=1}^l C_i / L_i$ | 7.10E+00 | 76.741 | 91.891 | 7.57E+00 | 0.000 | 100.000 |
| $\sum_{i=1}^l (C_i / L_i)W_i$ | 3.58E-01 | 45.161 | 81.081 | 4.26E-01 | 0.000 | 100.000 |

3.3 위치보정 변화 실험

위치 보정 유무 실험의 목적은 위치 보정 알고리즘을 전처리 과정에 추가했을 경우와 그렇지 않았을 경우의 검사 결과를 비교하여, 위치 보정 알고리즘의 필요성과 효과를 살펴보는데 있다. 실험 조건은 각각 표 2과 같고, 실험은 정상 위치에 있는 부품 ROI를 오른쪽, 아래쪽과 대각선 방향으로 각각 1~5 픽셀씩 이동했을 때의 경우로 나누어 하였다.

Table 2 Location Experimental condition1

| 학습 모델(학습 개수) | 검사 모델 | |
|-----------------|--------------------------|--|
| 부품 No.1~16 | 330 저항 계열 | |
| 부품 No.17~55 | 학습 부품 계열과 다른 종류의 부품 | |
| 330 저항 (21개) | 평활화(숫자부분만) Offset = 0 | |
| | 평활화(숫자부분만) Offset = 1 | |
| | 평활화(숫자부분만) Offset = 2 | |
| | 평활화(숫자부분만) Offset = 3 | |
| | 평활화(숫자부분만) Offset = 4 | |
| | 평활화(숫자부분만) Offset = 5 | |

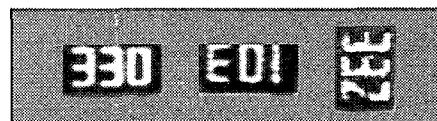


Fig. 12 ROI by experter

그림 12 는 숙련된 검사자가 PCB 상의 부품에 적당한 ROI 설정하였을 때 얻은 부품 영상이다. 그림 13 은 그림 12 에서 설정된 ROI 를 오른쪽(X-Offset)과 아래쪽(Y-Offset), 그리고 대각선(XY-Offset) 방향으로 1~5 픽셀씩 이동했을 때의 이미지이다.

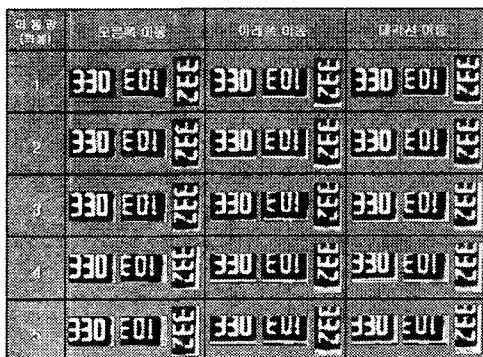


Fig. 13 ROI shift image

그림 14 는 정상 위치에 있는 ROI 를 이동시킨 후에, 위치 보정을 하지 않고 부품 검사를 한 결과이다. X, Y 위치의 값을 표현하였는데, 정위치 때의 값과 많은 차이를 보여 주고 있다.

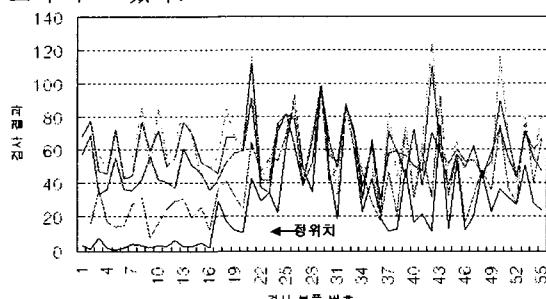


Fig. 14 Inspection results

330 저항 21 개를 학습 부품으로 사용하였으며, 검사 부품 번호 16 번까지는 학습군에 포함되는 부품이며 나머지 검사 부품 번호 17~55 번은 비학습군에 포함되는 부품이다. 그림 14 의 검사 결과는 ROI 가 정위치에 있는 경우 16 번째까지 검사 부품과 나머지 부품간의 결과값이 확인해 구분되지만, 나머지 검사 결과 값은 한 두 픽셀 정도만 ROI 가 정위치에서 벗어나도 결과값의

신뢰도가 많이 떨어짐을 알 수 있다. 이는 ROI 가 정위치에서 벗어나면서 부품 영상에 다른 영상이 삽입되기 때문이다. 따라서 별도의 부품 위치를 보정하는 알고리즘이 요구된다.

그림 15 는 앞에서 언급된 부품 위치 보정 알고리즘을 실험하기 위해 사용한 부품 샘플 영상이다. 이 실험은 위치 보정 알고리즘을 사용하지 않았을 경우의 실험과 동일하게 정상 모양의 330 저항 21 개를 학습시킨 후, 330 저항 16 개와 다른 종류의 부품 39 개를 검사하였다. 단지 차이점은, 위치 보정 알고리즘이 부품 리드 부분과 부품 전체 영상을 사영시킨 정보를 갖고 수행되므로, 검사 영역의 ROI 는 부품 전체 영상을 포함한다. 그리고 납땜부를 포함하지 않은 부품의 리드 영역만을 확실히 얻기 위하여 조명을 어둡게 하였다.

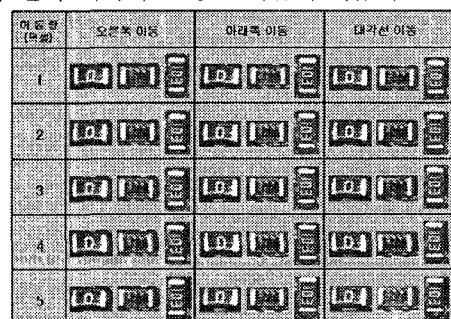


Fig. 15 ROI relocation image

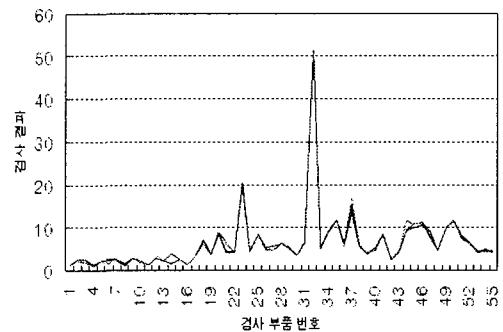


Fig. 16 Inspection result of position relocation

그림 16 은 330 저항 21 개를 학습시키고 난 후, ROI 내 부품의 위치를 보정하였을 때의 검사 결과를 나타낸 것이다. 그 결과 2.3 절에서 제안한 위치 보정 알고리즘을 적용한 결과 검사 성능이 개

선됨을 알 수 있다.

4. 결론

본 논문에서는 PCB 상의 SMT 전자 부품에 대해서 동일한 부품의 변화에 유연성 있게 적응하고, 학습 시간이 짧으며, 검사 결과의 신뢰성이 보장되는 알고리즘을 개발하였다.

영상 입력 단계에서 제안한 부품 위치 보정 알고리즘은 ROI 내 부품의 이동이나 회전, 변환 등이 있는 경우에도 효과적으로 부품의 위치를 찾을 수 있다. 또한 영상 크기 보간 알고리즘은 부품 ROI 설정시의 번거로움을 줄였다.

학습 단계에서 부품의 변화 정보는 통계학적 학습 알고리즘인 PCA를 통해 유연성 있게 학습되며, 새로운 부품의 삽입이 있을 경우에는 재귀적 학습 방법을 통해 추가 부품만을 다시 학습함으로서 학습 시간을 단축할 수 있다. 제안된 부품 특징치는 부품 학습시의 작업 숙련도를 요구하지 않는 장점을 가진다.

고유축 분석을 통해 부품 영상의 어느 부분이 부품 정보에 많은 영향을 주는지를 알 수 있었으며, 부품 ROI(region of interest) 설정시에 고유축 변화를 반영하는 것이 부품 검사에 효율적임을 알 수 있다.

본 논문에서의 실험은 모의 SMD 검사 장비 환경에서 수행되며, 생산 단계의 PCB를 대상으로 하여, 기판상의 각 칩 부품에 대해 실험을 하였다. 실험 결과는 제안된 방법이 실제적으로 SMD 검사 장비에 적용 가능하고 효과적인 방법임을 보여 준다.

향후의 연구 계획은 실험 대상을 각 칩에서 뿐만 아니라 PCB 상의 다른 종류의 부품까지 확장하여, 각 칩 이외의 부품에 대해서도 제안된 알고리즘의 유연성과 신뢰성을 검증하는 것이다. 덧붙여 고유축 분석을 통해 각 부품마다 적절한 ROI의 설정과 학습 부품에 대한 선별 기준이 생긴다면, PCB 조립 공정이나 검사 공정에 제안된 알고리즘이 실용적으로 적용될 수 있을 것으로 기대된다.

후기

본 연구는 선문대학교 신임교수 지원 연구 지원 사업 및 RRC의 지원으로 수행되었으므로 이에 감사드립니다.

참고문헌

1. SMT Magazines, "New Advances in AOI Technologies", <http://www.smt.com>
2. T. F. Cootes, C. J. Taylor, D. H. Cooper, J. Graham, "Active Shape Models-Their Training and Application", Computer Vision and Image Understanding, Vol. 61, No. 1, pp. 38 ~ 59, 1995
3. T. F. Cootes, C. J. Taylor, "Statistical Models of Appearance for Computer Vision", <http://www.wiau.man.ac.uk>
4. Visual Automation Ltd., "Active Shape Model Toolkit Manual"
5. Rafael G. Gonzalez, Richard E. Woods, "Digital Image Processing", pp. 148 ~ 156
6. T. F. Cootes, D. H. Cooper, C. J. Taylor, J. Graham, "Training Models of Shape from Sets of Examples", Proc. 3rd British Machine Vision Conference, pp. 9 ~ 18, Sep. 1992 Springer Verlag.
7. A. Hill, C. J. Taylor, "Automatic Landmark Generation for Point Distribution Models", BMVC, 1994
8. William H. Press, Saul A. Teukolsky, William T. Vetterling, Brian P. Flannery, "Numerical Recipes in C 2nd", pp. 456 ~ 469
9. Principal Component Analysis site, <http://fonsg3.let.uva.nl>
10. Principal Component Analysis site, <http://www.csu.edu.au/>