

QFN 반도체 패키지의 외형 결함 검사를 위한 효과적인 결함 분류 시스템 개발

Development of an Effective Defect Classification System for Inspection of QFN Semiconductor Packages

김효준, 이정섭, 주효남, 김준식

Hyo-Jun Kim, Jung-Seob Lee, Hyonam Joo, Joon-Seek Kim

요약

반도체 외관결함에는 발생 요인이 각각 다른 crack, foreign material, chip-out, chip, void 등이 있으며, 검사 시스템에서는 결함 유무 및 결함 분류를 수행하여 효과적인 공정관리가 가능하여야 한다. 본 논문에서는 QFN 패키지 결함의 분류를 위한 알고리즘 및 광학시스템을 제안한다. 제안한 방법에서 분류가 어려운 결함 중 하나인 foreign material 과 chip의 효과적인 분류를 위해 제안한 결함의 위치, 밝기의 특징정보(feature)를 사용한 ML(Maximum Likelihood ratio) 분류방법 및 특징정보 획득에 효과적인 광학계를 제안하였다. 실험 결과에서 분류가 어려운 foreign material과 chip에 대한 신뢰성 높은 분류성능을 보였다.

Abstract

There are many different types of surface defects on semiconductor Integrated Chips (IC's) caused by various factors during manufacturing process, such as cracks, foreign materials, chip-outs, chips, and voids. These defects must be detected and classified by an inspection system for productivity improvement and effective process control. Among defects, in particular, foreign materials and chips are the most difficult ones to classify accurately. A vision system composed of a carefully designed optical system and a processing algorithm is proposed to detect and classify the defects on QFN(Quad Flat No-leads) packages. The processing algorithm uses features derived from the defect's position and brightness value in the Maximum Likelihood classifier and the optical system is designed to effectively extract the features used in the classifier. In experiments we confirm that this method gives more effective result in classifying foreign materials and chips.

Keywords : Maximum likelihood, QFN, Semiconductor package, chip, foreign material, classification, surface defect

I. 서론

최근 각광을 받고 있는 리드가 없는 패키지로는 대표적으로 Leadless Chip Carriers (LCC), Bumped Chip Carriers (BCC) 그리고 Quad Flat No Leads (QFN)가 있다. 이러한 패키지들은 크기가 작고, 리드가 없어 PCB 상에서 차지하는 면적이 약 50% 가까이 축소되고 생산 비용 또한 기존의 소형 패키지와 유사하여 많은 주목을 받고 있다. 리드가 없는 패키지들은 이러한 여러 장점들이 있지만, 크기가 작아지고 기존의 반도체 소자들과는 형태가 달라

이에 맞는 검사 기술이 필요하다. 최근에는 자동 검사 항목의 증가, 검사시간 단축 등의 검사 대상의 고급화로 결함 분류에 의한 공정관리가 어려워지고 있다[1].

이러한 문제의 대표적인 해결 방안으로 영상 데이터를 이용한 대상 분류법이 있는데 지금까지 연구되어온 대표적인 영상 데이터의 분류법으로는 이진화 이미지를 이용한 방법과 명암 이미지를 이용한 방법이 있다. 이진화 이미지에서의 분류방법은 질감을 이용하는 방법, 블록 높이 및 백화소의 길이를 이용하는 방법, 그리고 체인코드를 이용하는 방법 등이 연구되었다[2][3]. 명암 이미지에서의 영상 분류 방법은 인공지능기법과 통계적 기법이 있는데 인공지능기법으로는 뉴럴 네트워크, 퍼지 이론, 디지전 트리와 같은 것이 있으며 이들은 각각 장단점이 있다. 뉴럴 네트워크는 특별한 규칙성이 없는 데이터에 대해 각각 다른 가중치를 할당하여 좋은 분류성능을 보이지만, 계산량이 많아지고, 변수

*호서대학교

접수 일자 : 2009. 3. 29 수정 완료 : 2009. 4. 28

게재확정일자 : 2009. 4. 29

※ 본 연구는 교육과학기술부와 한국산업기술재단의 지역혁신인력양성사업으로 수행된 연구 결과임.

들마다 다른 가중치를 부여해야 하는 난점이 있다. 퍼지 이론은 패턴분류에 있어 성공적으로 적용되어 왔지만 분류하고자 하는 클래스의 수가 많거나 대상의 특성이 여러 가지를 갖는 경우 계산이 매우 복잡해지는 단점이 있다. 디지전 트리는 서로 연관성이 없는 변수들의 분류에 사용되었다 [4][5]. 통계적 기법으로는 minimum distance, ML, nearest neighbor, parallel-piped 등이 있다. 그 중 ML은 클래스에 대한 데이터가 가우스 분포를 갖는다는 가정이 필요하며 분류성능은 학습된 클래스의 품질에 의존하게 된다[6][7].

본 논문은 반도체 패키지의 외관결함 가운데 검출과 분류가 다루어지지 않던 그림 1과 같은 foreign material과 chip 결함을 대상으로 ML 분류법을 사용하였을 때 가장 높은 분류성능을 갖게 하는 특징정보의 선정과 특징정보의 정확한 획득을 위한 광학계 설계를 목적으로 하였다.




그림 1. 분류할 결함의 형태
Fig. 1. Type of defects used for classification

제안한 방법에서는 결함의 위치, 밝기 특징정보와 ML을 이용한 분류방법, 그리고 특징정보 획득에 좋은 광학계 선정 방법을 보인다. 실험에서는 각각 다른 색 LED광원(red, blue, infra red, white)을 사용한 네 가지 광학계로 영상들을 촬영하였고 결함 영역의 위치, 밝기의 특징정보 및 여러 일반적인 특징정보를 이용한 분류모델들을 생성하였다. 최종적으로 ground-truth를 알고 있는 결함 패키지 영상을 제안한 분류방법에 적용하여 분류 성능을 1차 검증 하였고 Fisher's linear discriminant[8]를 이용한 클래스간 분산 (S_B)과 클래스 내 분산(S_W)의 비율로 2차 검증 하였다. 제안한 방법은 1차, 2차 성능 검증 결과 일반적인 feature보다 본 논문에서 제안한 feature를 사용할 때 가장 높은 분류성능을 보였고 red 조명을 사용하면 다른 조명을 사용할 때보다 더 나은 성능을 나타내는 것을 확인 할 수 있다.

II. 제안한 광학계

반도체 패키지의 외관결함들은 각기 다른 발생원인으로 형태, 크기 등이 다르므로 효과적인 검사 시스템의 광학계 설계를 위해 대상의 특징을 고려해야 한다. Foreign material은 sawing 공정 후 세척불량으로 molding 성분의 잔여물이 패키지에 남아 결함으로 나타나며 폭이 최소 100 μm 이상인 결함을 검사 대상으로 하고 있다. Chip은 sawing 공정 시 사용되는 water-knife 불량으로 발생하며 패키지 외곽의 molding 부분이 깨진 형태이고, 폭은 foreign material과 같은 최소 100 μm 이상의 결함을 검사 대상으로 하고 있다. 이러한 foreign material과 chip은 재질이 같고 표면의 구조가 다르므로 효과적인 검출을 위해

구조의 차이를 최대화시킬 수 있는 조명이 필요하다. 이를 위해 본 논문에서 제안하는 광학계의 구성을 그림 2에서 보인다.




그림 2. 기존 광학계와 제안한 광학계의 구성.
Fig. 2. Composition of conventional and proposed optical systems.

제안하는 광학계는 측사조명을 0도로 사용하는 것을 제안한다. 하지만 측사조명만 사용할 경우 반도체 패키지의 고르지 않은 표면의 특성도 동시에 나타나게 된다. 이러한 노이즈 성분을 감소시키기 위해 동축 조명을 같이 사용하였다

제안한 광학계에서 촬영한 영상과 기존 광학계에서 촬영한 영상을 그림 3에서 보이고 있다. 그림 3(b)는 기존 광학계에서 촬영한 영상 그림 3(a)를 histogram-stretch 방법으로 콘트라스트를 개선한 영상이고, 그림 3(c)는 제안한 광학계에서 촬영한 영상이다. 그림 3(b)와 그림 3(c)를 3.4장에서 언급하려고 하는 영역 분할 방법에 적용한 결과영상을 그림 3(d), 그림 3(e)에서 보이고 있다. 기존 광학계에서 촬영한 영상은 콘트라스트를 개선한 후에도 chip 결함을 검출하지 못하는 것을 확인할 수 있다. 정확한 결함의 분류를 위해서는 먼저 결함의 검출이 필수적으로 수행되어야 한다. 제안한 광학계에서 촬영한 영상에 대한 결과에서는 foreign material과 chip 모두 검출되는 것을 확인하였다.




그림 3. 광학계 영상비교.

Fig. 3. Acquired images and processed results using conventional & proposed optical system.

또한 그림 3(b)와 그림 3(c)를 비교하기 위한 또 다른 방법으로 각 영상 histogram에서의 클래스내 분산과 클래스간 분산을 이용하였다. 표 1은 클래스내 분산을 클래스간 분산으로 나눈 값을 나타내었으며, 이 값이 작을수록 배경과 결함의 구분이 쉬운 영상이라 할 수 있다.

표 1. 기존 광학계와 제안한 광학계 클래스 분할 측정.

Table 1. Class separation measures of convectional and proposed optical system.

	S_W/S_B
기존 광학계	13270.12
기존 광학계 (개선영상)	5425.24
제안한 광학계	153.91

* S_W : 클래스내 분산, S_B : 클래스간 분산

표 1에서 보는 바와 같이 기존 광학계의 개선한 영상보다 제안한 광학계의 영상이 결함과 배경의 구분이 분명하여 결함 검출에 용이한 영상 촬영이 가능한 것을 확인하였다.

광학시스템에서 조명의 선정은 매우 중요하다. 조명 선정을 위해 고려해야 할 부분은 조명의 형태, 광원, 조명의 색 등이 있다. 본 논문에서는 앞서 소개한 광학시스템에서 측사조명의 색을 변화시켜 그 영향이 결함 분류에 미치는 영향을 확인하고 분류에 가장 적합한 조명의 색을 제안한다. 사용한 색은 광원이 LED인 IR, red, blue, white이고 이들은 각각 다른 파장을 갖는다. 파장에 따라 대상의 형태가 다르게 나타나므로 조명 선정은 결함 분류를 위한 중요 요소라 할 수 있다. 그림 4는 LED 조명의 색에 따른 파장대역을 나타낸 것이다.

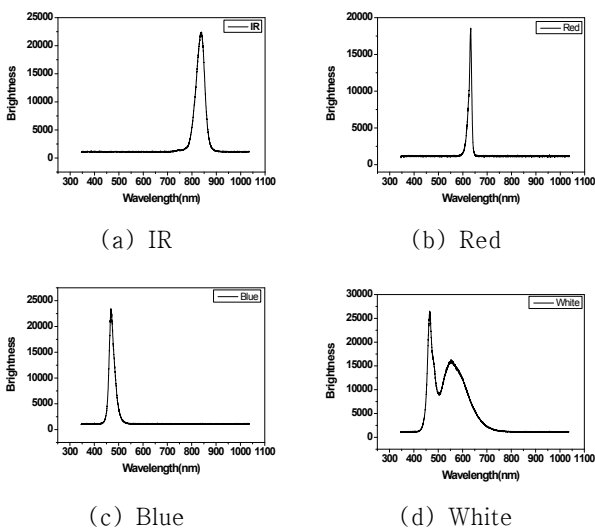


그림 4. 실험에 사용한 4가지 조명의 스펙트럼.

Fig. 4. Spectrum of 4 illumination used in experiments.

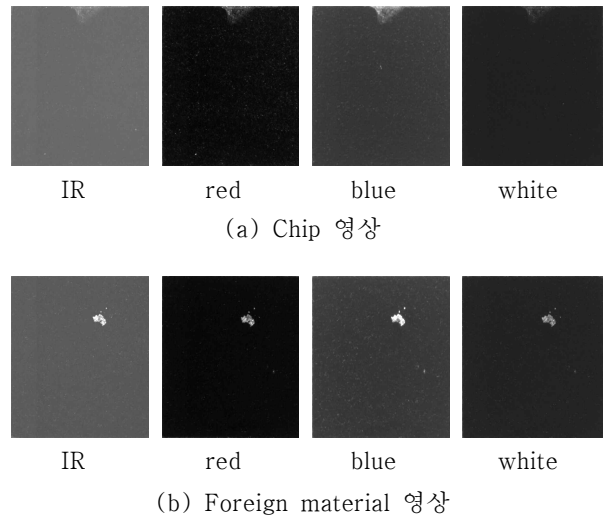


그림 5. 4가지 광원에 따른 결함 영상.

Fig. 5. Defect images acquired by 4 illumination methods.

그림 5에서는 사용한 조명의 색에 따른 반도체 패키지 영상을 보이고 있다. 하지만 조명색의 변화에 따라 영상의 밝기 차이가 있음을 알 수 있다. 본 논문에서는 조명색에 따른 특징정보 데이터의 신뢰성 평가가 목적이므로 밝기 변화에 따른 특징정보 데이터의 변화에 대한 확인이 필요하였다. 확인을 위해 그림 5의 8장 영상을 histogram-stretch 방법으로 영상의 밝기 차이를 개선시켜 각 영상의 밝기가 유사하도록 처리한 후 개선 전 영상의 특징정보 데이터와 비교하였으나 차이가 없었다.

III. 제안한 분류방법

3.1 Maximum likelihood ratio

ML은 입력패턴으로부터 분포의 특징패턴을 추출하는 방법으로 확률밀도함수를 사용하여 훈련패턴으로부터 데이터를 순차적으로 추정하는 parametric model이다. 식 (1)의 확률밀도함수는 입력패턴들의 발생이 서로 독립적인 D차원 가우시안이라는 가정하에 성립하게 된다.

$$P(\omega_i|X)P(X) = P(X|\omega_i)P(\omega_i) = \frac{P(\omega_i)}{(2\pi)^{D/2}|\Sigma_i|^{1/2}} \cdot \exp^{-(1/2)} \cdot (X - \mu_i)^T(\Sigma_i^{-1})(X - \mu_i) \quad (1)$$

ω_i $i = 1, \dots, M$ (member of classes)

$X = 'D'$ dimensional feature vector

μ_i 는 클래스 i 의 평균벡터(mean vector), Σ_i 는 클래스 i 의 공분산행렬(covariance matrix)을 나타낸다. 평균벡터 μ_i 와 공분산행렬 Σ_i 는 식 (2)와 (3)에 의해 훈련패턴으로 추정된다.

$$\mu_{ij} = \frac{1}{P_i} \sum_{l=1}^{P_i} x_{ijl} \quad (2)$$

$$\sigma_{ijk} = \frac{1}{P_i - 1} \sum_{l=1}^{P_i} (x_{ijl} - \mu_{ij})(x_{ikl} - \mu_{ik}) \quad (3)$$

식에서 P_i 는 클래스 i 의 훈련패턴 수, 식 (2)의 μ_{ij} 는 μ_i 의 j 번째 값을 나타내며, 식 (3)의 σ_{ijk} 는 σ_i 의 jk 성분, x_{ijl} 는 클래스 i 의 jl 성분을 의미한다. 또한 위 식을 근거로 식 (4)와 같이 likelihood ratio를 나타낼 수 있다. 이때 $\Lambda(X) < 1$ 또는 $\Lambda(X) > 1$ 의 경우에 따라 ML 기준을 적용하여 feature vector X 가 소속하는 클래스를 추정할 수 있게 된다[9].

$$\Lambda(X) = \frac{P(X|\omega_i)}{P(X|\omega_j)}, \quad i \neq j \quad (4)$$

3.2 Fisher's linear discriminant

Fisher의 선형 판별식은 두 개의 클래스로 이루어진 D차원 점들이 1차원의 직선에 사상(mapping)될 때, 두 클래스를 가장 잘 나누는 직선의 기울기를 찾기 위해 제안되었다.

두 클래스를 잘 나누는 직선을 찾기 위해서는 1차원 직선에 사상된 두 클래스의 분할 정도를 판별할 수 있어야 한다. D차원의 점이 기울기 벡터가 W 인 1차원 직선에 사상된 클래스의 분할 정도를 판단하는 함수 $J(W)$ 는 아래와 같이 Fisher의 목적함수를 S_W 와 S_B 항에 의한 식 (5)와 같이 정의 할 수 있다.

$$J(W) = \frac{W^T S_B W}{W^T S_W W} \quad (5)$$

여기서 변환행렬 W 를 찾아내야 하는데 본 논문에서는 W 는 찾지 않고 S_W , S_B 만을 이용해 2차 성능 검증을 하였다.

$$S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \quad (6)$$

$$S_W = \sum_{i \in \omega_1} (x_i - \mu_1)(x_i - \mu_1)^T + \sum_{i \in \omega_2} (x_i - \mu_2)(x_i - \mu_2)^T \quad (7)$$

결론적으로 S_B 는 값이 클수록 좋고, S_W 는 값이 작을수록 좋다. 2차 검증 방법에서는 S_B / S_W 을 사용하여 가장 큰 값을 가지는 feature를 선택 한다.

3.3 Feature selection

본 논문에서 분류하고자 하는 결함인 foreign material 과 chip은 크기, 위치, 방향이 일정하지 않아 분류를 위한 특징정보는 크기, 위치, 방향에 독립적이어야 한다. 실험에서는 제안한 특징정보와 일반적으로 사용하는 특징정보를 비교하기 위해 두 가지 특징정보를 모두 적용해보았다 먼저 일반적인 특징정보로는 compactness(조밀성), eccentricity(이심률), roundness(원형성)를 후보로 선정하였고, 제안한 특징정보로 CB (Connected Boundary ratio), DM(Difference of Mean)을 선정하였다. 이들에 대해 다음에서 설명한다.

Compactness는 영역의 넓이와 둘레에 대한 비율로, 넓이가 a , 둘레가 l 일 때 식 (8)과 같이 나타낼 수 있으며 '1'이면 원, '0'이면 직선을 나타낸다. Eccentricity는 영역을 포함하는 타원의 초점과 장축길이(major axis length)의 비율로서 타원의 중심에서 초점까지 거리를 f , 장축길이는 l_m 일

때 식 (9)과 같이 나타낼 수 있고 그 값이 '1'이면 직선, '0'이면 원을 나타낸다. Roundness는 해당 영역의 단축길이(minor axis length)와 장축길이의 비율로서 '1'이면 원, '0'이면 직선을 나타낸다[9][10].

$$\text{Compactness} = \frac{4\pi a}{l^2} \quad (8)$$

$$\text{Eccentricity} = \frac{f}{l_m} \quad (9)$$

본 논문에서 제안하는 CB는 해당 영역 둘레의 일부가 반도체 패키지 외곽에 연결되어 있는 비율로서 외곽에 연결된 화소의 개수가 c , 둘레는 l 일 때 식 (10)과 같이 표현할 수 있다. DM는 패키지 면의 평균밝기와 결함 영역의 평균 밝기에 대한 비율로서 배경의 평균밝기를 m_b , 결함의 평균 밝기를 m_d 라 하면 식 (11)과 같이 나타낼 수 있다.

$$\text{CB} = \frac{c}{l} \quad (10)$$

$$\text{DM} = \frac{m_b}{m_d} \quad (11)$$

제안한 특징정보는 반도체 패키지의 외곽에서 발생하는 chip 결함의 고유특성과 조명에 의해 결함의 화소 값이 패키지 면과 차이를 갖는 특성을 고려하여 제안하였다.

3.4 결함 분류 알고리즘

영상에서 특정영역의 분리를 위해 가장 널리 사용되는 방법으로는 threshold 기법이 있다. 본 논문에서 사용한 threshold 기법은 Kittler & Illingworth의 minimum error threshold 방법[11]이다. 또한 threshold 처리 후 나타나는 불필요한 영역제거와 결함의 본래 형태를 유지하기 위해 모폴로지 기법을 이용하였다. 영역 분할과정을 그림 6에서 나타내었다.

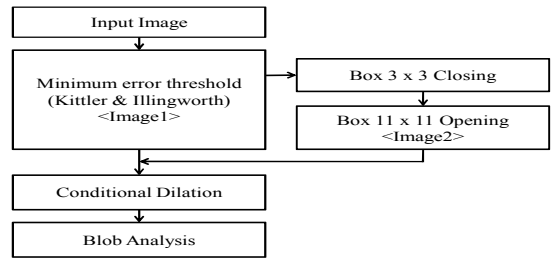


그림 6. 분할 알고리즘 흐름도.

Fig. 6. Flowchart of defect segmentation algorithm.

먼저 입력영상을 minimum error threshold를 이용하여 이진화하고 이것을 Image1이라고 하였다. Image1에서 발생할 수 있는 1~2개 화소 크기의 hole을 없애기 위해 3x3 box의 structuring element로 closing 연산을 하였다. 또한 배경에서 5~10개 화소 크기로 분포하는 노이즈 성분을 최소화하기 위해 11x11 box의 structuring element로 opening 연산을 하고 결과영상을 Image2라 하였다. Opening으로 인하여 본래 모양을 잃었을 결함 영역을 최소화하기 위해 Image1과 Image2를 이용하여 conditional dilation기법을 적용하였다. 마지막으로 특징정보 추출을 위

해 분할 된 영역에 blob analysis를 수행하였다.

IV. 실험 방법 및 결과

영상 취득에 사용한 카메라는 해상도 1024×768의 mono CCD 카메라를 사용하였고 검사할 반도체 패키지는 QFN 4mm×4mm패키지를 사용하였다.

표 2. 실험에 사용된 광학계 사양.

Table 2. Optical system specification used in experiments.

Working Distance (mm)	216
Focal Length (mm)	134
Object size (QFN) (mm)	4 × 4
CCD Size (mm)	4.76 × 3.57
Field of View (mm)	7.06 × 5.3
Pixel Resolution (μm/pixel)	6.9

실험에서는 결합 영역에 대한 일반적인 특징정보의 데이터와 제안한 특징정보 CB, DM의 데이터가 ML 방법에 적용되었을 때의 분류성능 및 조명의 색에 따른 특징정보 데이터의 정확성에 대해 평가하기 위하여 조명의 색을 IR, red, blue, white로 변화를 주면서 각각에 대해 foreign material 결합 영상과 chip 결합 영상을 약 800장 촬영하였고 각 영상에서 얻은 다섯 개의 특징정보 데이터 중 2개의 특징정보를 이용하여 ML 분류를 위한 분류모델들을 생성하였다. 또한 생성한 분류모델들의 ML 분류성능 평가 및 검증에 위해 두 가지 검증방법을 사용하였다. 1차 검증방법으로 조명의 색과 결합 별로 총280장의 새로운 결합 영상을 촬영 후 분류모델에 적용하여 정확히 분류한 개수와 분류를 하지 못한 개수를 분석하여 1차 검증을 하였다. 표 3은 검증방법의 수행결과를 나타내었다.

표 3을 통해 red 측사조명을 사용하였을 경우 선정한 특징정보의 조합에 의한 분류성능이 평균 98.88%로 가장 좋은 결과를 보였다. Blue 조명에서는 가장 부정확한 특징정보 데이터가 얻어진 것을 알 수 있다. 또한 DM vs CB 방법을 사용하였을 경우엔 조명색의 변화에 따라 성능이 변화하는 다른 특징정보들과는 다르게 4가지 색 모두에서 99.9%의 분류성능을 보였다.

표 3. 다른 종류의 조명하에 실험한 분류결과.

Table 3. Separating power of features used in experiments under different illumination.

조명색	White (%)	Blue (%)	Red (%)	IR (%)
특징정보				
Comp vs Ecc	96.5	96.5	98.6	96.5
Ecc vs DM	97.2	99.3	99.9	99.3
DM vs CB	99.9	99.9	99.9	99.9
Round vs Comp	96.5	96.5	97.9	96.5
Round vs Ecc	94.4	30.1	97.9	94.4
Average performance	96.9	84.46	98.84	97.32
Standard deviation	1.98	30.42	1.01	2.26

*Comp : compactness, Ecc : eccentricity, Round : roundness

2차 검증방법으로 특징정보 도메인에서 각 클래스간 분산과 클래스 내 분산을 구한 후 클래스간 분산을 클래스내 분산으로 나눈 값으로 분류성능을 비교하였다. 다음의 표 4에서는 2차 검증결과를 보이고 있다.

표 3에서 red조명을 사용하였을 때 분류성능이 가장 좋았기 때문에 2차 검증 방법을 red조명만 검증 하였다. 표 4에서의 S_B 는 값이 클수록 좋고, S_W 는 값이 작을수록 좋다. S_B/S_W 를 사용하여 가장 큰 값을 가지는 분류모델이 분류가 잘되는 적을 확인할 수 있다.

표 4. red조명 실험에서 특징정보 S_B 와 S_W 의 비.


Table 4. Ratio of S_B and S_W of features used in experiments under red illumination.

Data	S_B	S_W	S_B/S_W
특징정보			
Comp vs Ecc	4.81 e-04	4.03 e-04	1.195
Ecc vs DM	5.20 e-04	9.24 e-05	5.629
DM vs CB	3.94 e-04	2.74 e-05	14.347
Round vs Comp	9.30 e-04	7.34 e-04	1.266
Round vs Ecc	3.98 e-04	5.53 e-04	0.721


* S_W : 클래스내 분산, S_B : 클래스간 분산

위 결과에서도 DM vs CB 방법을 사용하였을 때 가장 좋은 결과를 보였다. 이 결과는 특징정보 도메인에서 두 클래스간 독립성이 크다는 것을 의미하며 이것은 분류성능과 직접적인 관계를 가지고 있다.


그림 7은 chip과 FM에 대하여 각 특징정보별 생성 모델을 보여주고 있다. 그림 7의 모델 생성 후 표 3의 결과를 얻기 위해 모델에 데이터를 넣고 ML분류법을 사용하여 결합 분류를 하였다.




(a) Compactness vs. eccentricity




(b) Eccentricity vs. DM



(c) DM vs. CB



(d) Roundness vs. compactness



(e) Roundness vs. eccentricity

그림 7. Red조명 영상의 특징정보 도메인에서의 chip, foreign material 결함 분류모델.

Fig. 7. Scattergrams of pair of features used in experiments to compare the classification power.

그림 7의 모델은 특징정보를 2개를 비교하여 2차원으로 모델을 생성하여 실험을 하였다.

일반적인 특징정보에 의해 생성된 분류모델들은 결함의 특성분포가 표 4에서 확인한 것과 같이 분류모델의 클래스 내 분산, 클래스간 분산이 좋지 않아 일부 겹치지만 본 논문에서 제안한 그림 7(c)의 특징정보에 의해 생성된 분류모델은 결함의 특성분포가 거의 독립적으로 분포하는 것을 볼 수 있다. DM vs CB 특징정보 도메인을 나타낸 그림 7(c)를 보면 제안한 특징정보 CB는 반도체 패키지의 외곽 영역에서만 발생하는 chip과 위치에 독립적으로 발생하는 foreign material의 특성을 이용하여 제안한 특징정보로써 분류성능을 향상시키기 충분한 특징정보라 판단되며, 밝기 차이 정보를 이용한 DM도 분류 성능 향상에 효과적인 분류모델을 생성하는 것을 확인하였다.

V. 결론

반도체 패키지의 외관검사 시스템은 검사 항목들에 대한

결함 유무 검사 이외에 결함의 종류를 분류하는 기능도 필요하다. 본 논문에서는 반도체 패키지의 외관에서 발생하는 foreign material과 chip 결함의 효과적인 분류를 위한 광학계와 분류방법을 제안하였다.

광학시스템에서는 재질은 같으나 결함 표면의 차이를 극대화 시키고 반도체 패키지 표면의 특성에 의한 노이즈는 최소화할 수 있도록 측사조명과 동축조명을 동시에 사용하였으며, 제안한 광학계를 통해 기존 광학계에서는 검출이 어려운 chip 결함의 검출이 용이한 것을 확인하였다. 또한 일반적인 특징정보 보다 결함의 위치 및 밝기 특성을 이용한 특징정보 CB, DM를 제안하였다. 검증을 위해 불량 영상을 이용한 실험적 검증방법과, 얻어진 특징정보를 통해 생성된 클래스의 분산을 분석하는 방법을 사용하였다. 실험 결과 제안한 특징정보를 사용하였을 경우 일반적인 특징정보(eccentricity, roundness, compactness)를 사용한 결과보다 분류성능이 대폭 향상되는 것을 확인하였으며, 측사 red 조명을 사용하였을 경우 다른 색의 광원을 사용하였을 때보다 향상된 분류성능을 보이는 것을 실험결과를 통해 확인하였다.

참고 문헌

- [1] R. Bertz and P. Leahy, "Inspection Challenges of Leadless Packages," Proc. SEMICON, pp. 418-422, 2002.
- [2] D. Wang and S. N. Srihari, "Classification of Newspaper Image Blocks using Texture Analysis," ComputerVision, Graphics, and ImageProcessing, Vol. 4, pp. 327-352, Jan. 1989.
- [3] F. M. Wahi, K. Y. Wong, and R. G. Casey, "Block Segmentation and Text Extraction in Mixed Text/Image Documents," Computer Graphics and Image-Processing, Vol. 22, pp. 375-390, Feb. 1982.
- [4] S. C. Horng and S. Y. Lin, "A Hybrid Classification Tree for Products of Complicated Machines in Flexible Manufacturing Systems," IEEE International Conference on Systems, Man and Cybernetics, Vol. 4, pp. 3775-3780, Oct. 2005.
- [5] R. A. Gpinath, "Maximum Likelihood Modeling with Gaussian Distributions for Classification," Proceeding of ICASSP, pp. 661-664, 1998.
- [6] F. Maselli, C. Conese, T. D. Filippis, and M. Romani, "Integration of Ancillary Data into a Maximum-Likelihood Classifier with Nonparametric Priors," ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 50, No. 2, 1995.
- [7] F. Maselli, C. Conese, Ljiljana, and R. Resti, "Inclusion of Prior Probabilities Derived from a Nonparametric Process into the Maximum-Likelihood Classifier," Photogrammetric Engineering & Remote

Sensing, Vol. 58, No. 2, pp. 201-207, Feb. 1992.
 [8] 한학용, 패턴인식 개론, pp. 306-314, 2005.
 [9] C. H. Wang, S. J. Wang, and W. D. LEE, "Automatic Identification of Spatial Defect Patterns for Semiconductor Manufacturing," International Journal of Production Research, Vol. 44, No. 23, pp. 5169-5185, Dec. 2006.
 [10] R. C. Gonzalez, R. E. Wood, and S. L. Eddins, Digital Image Processing Using MATLAB, pp. 476-506, 2004.
 [11] Kittler and J. Illingworth, "Minimum Error Thresholding," Pattern Recognition, Vol. 19, pp. 41-47, 1986.



김 준 식 (Joon-Seek Kim)

1987년 2월 서강대학교 전자공학과 (공학사)
 1989년 2월 서강대학교 전자공학과 (공학석사)
 1993년 8월 서강대학교 전자공학과 (공학박사)
 1993년 9월~1994년 2월 서강대학교
 부설산업기술연구소 박사후연구원
 2007년 3월~2008년 2월 Southern Oregon University
 교환교수
 1994년 3월 ~ 현재 호서대학교 전자공학과 교수
 ※관심분야 : 컴퓨터비전, 머신비전, 영상통신, 반도체
 /FPD 검사장비, 검사자동화 등.



김 효 준 (Hyo-Jun Kim)

2008년 2월 호서대학교 전자공학과(공학사)
 2008년 2월 ~ 현재 호서대학교 대학원
 전자공학과 석사과정
 ※관심분야 : 광학 시스템 설계,
 반도체/디스플레이장비개발



이 정 섭 (Jung-Seob Lee)

2007년 2월 호서대학교 정보제어학과(공학사)
 2007년 ~ 현재 호서대학교 대학원 디지털
 디스플레이공학과 석사과정
 ※관심분야 : 패턴인식,
 반도체/디스플레이장비개발



주 효 남 (Hyonam Joo)

1976년 서울대학교 전기공학(공학사)
 1976년 ~ 1982년 국방과학연구소(선임연구원)
 1985년 Virginia Polytechnic Institute & State
 Univ. VA, USA 전기전자공학(공학석사)

1990년 ~ 1996년 Machine Vision International (선임연구원)
 1990년 ~ 1996년 The Boeing Company(Principal Engineer)
 1991년 Univ. of Washington 전기전자공학(공학박사)
 1996년 ~ 2000년 삼성전자 생산기술센터 자동화연구소
 (연구소장)
 2000~2002년 (주) 넥스트아이 연구개발 부문(사장)
 2002년~ 현재 호서대학교 디스플레이공학과 교수
 2003~2007년 호서대학교 반도체 제조장비 국산화연구센터
 (소장)

※ 최근 연구과제 : 반도체 소자의 결함 검사를 위한 Vision
 Inspection Module 개발, FPD종합 구동
 검사용 Vision Inspection Module 개발,
 LCD 핵심 부품용 검사장비 개발