

PCB 검사를 위한 개선된 통계적 그레이레벨 모델

복진섭[†] · 조태훈

[†]한국기술교육대 컴퓨터공학부

Improved Statistical Grey-Level Models for PCB Inspection

Jin Seop Bok[†] and Tai-Hoon Cho

[†]Korea University of Technology and Education, School of Computer Engineering

ABSTRACT

Grey-level statistical models have been widely used in many applications for object location and identification. However, conventional models yield some problems in model refinement when training images are not properly aligned, and have difficulties for real-time recognition of arbitrarily rotated models. This paper presents improved grey-level statistical models that align training images using image or feature matching to overcome problems in model refinement of conventional models, and that enable real-time recognition of arbitrarily rotated objects using efficient hierarchical search methods. Edges or features extracted from a mean training image are used for accurate alignment of models in the search image. On the aligned position and orientation, fitness measure based on grey-level statistical models is computed for object recognition. It is demonstrated in various experiments in PCB inspection that proposed methods are superior to conventional methods in recognition accuracy and speed.

Key Words : Statistical model, Object recognition, Template matching, Image alignment, Model refinement.

1. 서 론

많은 산업 현장에서의 검사 시스템은 불량품 선별에 영상 처리를 사용한 물체 인식 기법을 사용하고 있으며 이는 장비의 신뢰성을 보장할 수 있도록 하는 중요한 기법 중 하나이다. 물체 인식은 많은 제약 조건을 갖더라도 높은 신뢰성을 보장하는 것이 중요하며 현장에 투입되는 시간과 비용을 절약하기 위해 수행시간이 빠른 시스템이 선호된다. 이런 시스템은 물체의 위치를 찾고 분류하는 문제를 다룬다. 일반적으로 검사되는 물체의 크기와 모양은 엄격한 허용오차를 요구하지만, 물체의 모양은 매우 다양할 수 있으며 가끔 극단적인 변화를 보이기도 한다. 이런 변화는 빛의 변화나 카메라의 잡음에 의해 발생하는데, 일반적인 상관계수를 이용한 방법으로는 제대로 된 물체의 위치를 찾을 수 없다.

따라서 물체의 위치를 정확하게 찾고 분류하기 위해서는 물체의 모양과 변화의 정도를 잘 나타낸 좋은 모델이 필요하다.

가장 간단한 고정 물체 탐색의 방법은 상관관계를 기반으로 한 매칭 기법이다. 이 방법은 물체가 다양한 모양을 갖거나 너무 많은 잡음(noise)이 있는 경우 매칭에 실패할 수 있다. Eigen-feature 모델과 다중 해상도 탐색 기법을 혼합한 방법을 사용하면 결과가 아주 신뢰성 있으나, 가끔 예상외의 위치에서 매칭이 실패할 때가 있다[1]. 그 외의 접근법으로는 Active Shape Models[2,3]이 있다.

T.F Cootes는 그레이레벨에서 물체의 변화를 기반으로 한 통계적 모델을 물체 인식에 어떻게 사용하는가에 대하여 기술한 그레이레벨 통계적 모델을 제안하였다[1]. 본 논문은 이 모델을 분석하고 이 모델이 가진 문제점을 해결할 방법을 제시하며, 더 나은 모델로 개선할 수 있는 방법에 대하여 제안한다.

[†]E-mail : qataro@kut.ac.kr

2. 그레이레벨 통계적 모델

2.1. 기본 모델(Basic Model)

인식 시스템은 새로운 영상에 있는 물체의 정확한 위치를 찾아야 한다. 먼저 주어진 영역에 물체가 존재하는지 알아내야 하고, 다음으로는 허용오차 범위 내로 위치와 각도들을 알아내야 한다. 이때 배경이나 다른 것들과 확실히 구별이 되어야 하고 가능한 한 비슷한 물체도 구별이 되어야 한다.

이런 조건을 만족하기 위해서 통계적 모델을 사용하며, 이는 학습 영상 집합으로부터 다음 방법을 이용하여 구한다. 모델 벡터는 다음과 같은 ROI(region of interest) 영상에서 사용자가 지정한 사각 영역의 $n_x \times n_y$ 그레이레벨 영상으로부터 $n = n_x n_y$ 요소를 가진 벡터를 모델 벡터 \mathbf{x} 로 사용한다. 일반적으로 일관되게 샘플링 한다면 어떤 모양의 영역이든 모델 벡터로 사용 가능하다.




Fig. 1. Model examples with region of interest images.

위 그림은 모델을 포함하는 ROI 영상을 예로 든 것이다. 이런 영상들이 모델을 학습하는 영상으로 주어지며 네모난 틀은 모델을 생성하는 물체의 영역을 나타낸다. 시작 위치는 사용자가 지정하거나 시스템이 자동으로 찾아 정렬한다.

통계적 모델의 기반이 되는 선형 고유모델(linear 'eigen' model)은 주어진 모델 벡터 집합 $\mathbf{x}_i (i=1 \dots s, s$ 는 영상 개수)에 주요 성분 분석(Principle Component Analysis: PCA)을 적용하여 생성한다. 여기서 n 크기의 평균 $\bar{\mathbf{x}}$ 와 모델의 주요 변화를 대표하는 t 개의 고유벡터(eigenvectors)인 $n \times t$ 크기의 \mathbf{P} 를 얻어낸다. t 값은 학습 영상 집합에서 모델 변화의 적절한 비율을 나타내도록 적당한 비율(예를 들어 95%)을 선택한다[2]. 값을 선택하는 식은 다음과 같다.

$$t = \arg \min_k \left(\sum_{i=1}^k \lambda_i / \sum_{i=1}^n \lambda_i \geq T_\lambda, k < n \right) \quad (1)$$

식 (1)에서 n 은 모델의 픽셀 수이고 λ_i 는 i 번째로 큰 고유값이며 T_λ 는 사용자가 지정한 모델의 변화를 대표하는 비율이다. 이렇게 계산된 벡터들을 이용하여 영상

의 특정 부분 \mathbf{x} 를 모델과 잘 들어맞는 \mathbf{x}' 으로 다음과 같이 근사할 수 있게 된다.

$$\mathbf{x} \approx \mathbf{x}' = \bar{\mathbf{x}} + \mathbf{P}\mathbf{b}, \quad \mathbf{b} = \mathbf{P}^T(\mathbf{x} - \bar{\mathbf{x}}) \quad (2)$$

에러 \mathbf{r} 은 $\mathbf{r} = \mathbf{x} - \mathbf{x}'$ 으로 표시된다.

2.2. 적합도 (Quality of fit measure)

통계적 모델은 영상의 특정 부분이 만들어진 모델과 얼마나 잘 맞아 떨어지는가에 중점을 둔다. 따라서 잘 맞아떨어지는 정도를 적합도로 정의하고 이를 나타낼 수 있는 몇 개의 식을 제공한다. 계산된 적합도는 값이 작을수록 더 많이 일치함을 뜻한다. Turk and Pentland[4]는 모델과 가장 잘 들어맞는 근사 \mathbf{x} , 즉 \mathbf{x}' 와 \mathbf{x} 의 차이 값을 제공한 함을 사용했다.

$$R^2 = \mathbf{r}^T \mathbf{r} = (\mathbf{x} - \bar{\mathbf{x}})^T (\mathbf{x} - \bar{\mathbf{x}}) - \mathbf{b}^T \mathbf{b} \quad (3)$$

이 방법은 학습 영상 집합의 변화를 잘 보여주나, 모델의 모드에 따라 변화하는 값의 크기는 제한할 수 없다. 이를 제한하기 위해 Cootes[2]는 다음 식을 사용했다.

$$f_0 = M_t + \frac{R^2}{0.5\lambda_t}, \quad M_t = \sum_{i=1}^t \frac{b_i^2}{\lambda_i} \quad (4)$$

M_t 는 모델로부터 생성된(spanned) 평균으로부터의 거리를 측정하는 것이고, λ_t 는 PCA에서 t 번째로 큰 고유값이다. R^2 은 에러 차이를 제공한 함으로, 분산이 $0.5\lambda_t$ 인 가우시안 분포를 근사적으로 따른다고 가정한다.

식(4)의 방법보다는 R^2 의 분산 V_r 을 추정하는 것이 좀 더 합리적인 접근법이다. Haslam[5]는 학습 데이터로 miss-N-out 실험(또는 bootstrap jackknife 추정[6])하는 방법을 보여주며, 이를 다음과 같이 나타냈다.

$$f_1 = M_t + \frac{R^2}{V_r} \quad (5)$$

Moghaddan and Pentland[7]에 의한 유사한 척도는 확률 분포의 최적화된 추정으로부터 결정된다. 이 처리법은 최상의 모델로부터 나온 에러 값인 r_j 가 동등하게 중요한 것처럼 나타냈으나, 사실 모든 경우에 그렇지는 않다. 별로 좋지 않게 모델링 된 픽셀에서의 에러는, 잘 모델링 된 픽셀에서의 에러보다 덜 중요할 것이다. 따라서 이를 다르게 적용하는 것이 더 합리적이다. 각 픽셀마다 가중치가 적용되는 방식으로 \mathbf{x} 의 j 번째 픽셀 값의 에러 차이인 r_j 로 miss-N-out 실험[6]을 이용하여

r_j 의 분산인 v_j 를 추정하는 방법을 사용한다. 여기서 추정된 v_j 가 더 작을수록 j 번째 요소가 더 잘 모델링 된 것이다. 이 정보를 통합하여 수식을 통해 나타내면 다음과 같다.

$$f_2 = M_r + \sum_{j=1}^n \frac{r_j^2}{v_j} \quad (6)$$

사용될 통계적 모델의 데이터는 다음과 같다.

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{P}\mathbf{b} + \mathbf{r} \quad (7)$$

여기서 \mathbf{b} 의 i 번째 성분 b_i 는 평균이 0이고 분산은 λ_i 인 가우시안이고, \mathbf{r} 의 j 번째 성분 r_j 는 평균이 0이고 분산은 v_j 인 가우시안이며, \mathbf{P} 의 열(column)은 상호 직교다.

2.3. 점증적인 학습(Incremental training)

모델을 생성한 후 영상을 추가해 나가며 학습하는 방법을 적용할 수 있으며, 이는 모델을 빠르고 효과적으로 생성할 수 있게 한다. 통계적 모델을 적용한 시스템은 적은 학습 모델로도 대부분의 새로운 영상에 대하여 정확하게 위치를 찾는다. 그러나 적은 학습 영상으로 생성된 모델은 정확도를 보장할 수 없으므로, 생성하는 학습 영상 수를 많게 하여 모델 생성의 정확도를 보장하는 것이 중요하다.

2.4. 모델 갱신(Model refinement)

학습 영상을 만들 때의 물체의 위치를 사람이 입력했거나, 학습 영상 집합에 포함될 영상을 정렬하는 데 사용된 모델의 학습 영상 수가 적은 경우에 정렬된 위치가 옳바르지 않을 수 있다. 이런 오류는 모델을 만드는 과정에 학습 영상 안의 물체 위치가 한 번 입력되고 나서 변경되지 않기 때문에 발생한다.

이런 오류를 줄이는 방법 중 하나는 완전하게 모델이 만들어진 이후 학습 영상들 각각이 가진 물체의 위치를 다시 찾아 갱신시키는 것이다. 이 탐색에는 물체 위치를 갱신하려는 영상을 제외한 학습 영상으로 만들어진 모델을 사용한다. 탐색 범위는 최초 주어진 물체 위치에서 일정 반경 내로 하면 된다. 갱신 위치는 해당 모델로 찾아진 가장 적합도가 높은 위치를 사용한다. 모든 영상에 대하여 물체 위치가 갱신되었으면 갱신된 영상 집합으로 모델을 재 생성한다.

2.5. 물체의 존재 유무 확인

새로운 영상에서 모델에 가장 적합한 위치를 찾으면, 우리는 그 위치에 원하는 물체가 존재하는지 확인해야

한다. 이 작업은 구해진 적합도 값이 특정 값보다 작거나 큰 정도를 기준으로 하여 구해진다. 이 기준은 적합도의 각 인자 값이 특정 확률 분포를 보여주는 것을 이용한다. 최선의 방법은 같은 분포를 갖는 클래스의 영상들을 이용하여 모델을 생성하고, 주어진 학습 영상 집합에서 특정 비율(예를 들어 0.1%) 이상의 에러율을 내지 않도록 임계값을 설정하는 것이다.

학습 영상과 근사한 모델과의 차이인 \mathbf{r} 이 정규분포를 따르고 각 요소가 독립적이면, 해당 학습 영상 집합으로 만든 통계적 모델의 적합도 f_1, f_2 값은 카이제곱 분포(Chi-squared distribution)를 따르게 된다. 이는 다음과 같은 관계에 기초한다.

$$\chi^2 = X_1^2 + X_2^2 + \dots + X_n^2 : \chi\text{-squared dist.} \quad (8)$$

식(8)에서 $X_i(i=1 \dots n)$ 는 평균이 0, 분산이 1인 표준정규분포이고, n 은 카이제곱분포의 자유도가 된다. 일반적인 카이제곱분포의 평균은 n 이고 분산은 $2n$ 이지만 f_1, f_2 를 이용하여 실험 시 평균은 n 인 반면 분산은 $2n$ 보다 더 크게 나온다. 이는 카이제곱분포가 자유도 k 에 의해 n/k 로 스케일링 되었다고 추측할 수 있으며, 그러므로 평균은 n , 분산은 $2n^2/k$ 로 구해야 한다. σ^2 이 실제 계산된 분산이면 $k = 2n^2/\sigma^2$ 으로 추측할 수 있다. 이를 카이제곱분포 표를 이용한 임계값 계산에 사용한다.

$$p(f) = \left(\frac{n}{k}\right) \chi^2 \left(\frac{fk}{n}, k\right) \quad (9)$$

$$P[\chi^2 \geq \chi_{\alpha, k}^2] = \alpha (k: \text{degree of freedom}) \quad (10)$$

위 식에서 $p(f)$ 는 f 의 확률밀도함수(probability density function)이다. 예를 들어 10의 자유도를 가지고 0.001의 에러 확률을 갖는 카이제곱분포의 임계값 $\chi_{0.001; 10}^2$ 는 29.59이다.

3. 제안하는 모델 개선 방안

3.1. 회전된 영상에서의 탐색

회전된 영상의 탐색에 대해서는 모델 생성 및 회전 각도에 대한 것 등 고려할 사항이 많음에도 불구하고 기존 통계적 모델[1]에서는 거의 언급이 없다. 본 논문에서는 회전된 영상의 탐색에 대하여 고찰하고 통계적 모델만을 사용하는 것이 아니라 다른 방법을 적용한 탐색 방법을 제안한다.

학습 데이터를 나타내는 벡터 \mathbf{x}_i 의 각 값에 대응하는

픽셀 좌표 벡터 p_i 를 이용하여, 회전된 좌표 p'_i 을 계산하고 이를 이용하여 통계적 모델을 생성한다. 벡터 p'_i 는 식(11)로 구한다.

$$p'_i = H_p p_i = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} p_i \quad (11)$$

식(11)에서 p'_i 는 회전된 좌표 벡터이고, H_p 는 좌표 벡터를 회전시킬 동차 행렬(homogeneous matrix)이다. θ 는 회전시킬 각도 값이다. 회전된 영상에서 탐색하기 위한 통계적 모델은 다중 해상도 모델을 이용하며, 레벨 별 해상도 변화 비율은 2배로 할 경우 각도 샘플링 간격은 상위 레벨로 올라갈 때마다 2배씩 증가한다.

3.2. 모델 갱신의 문제점 해결

모델 생성 시 특정 학습 영상의 물체 위치가 일정 이상 어긋나 있다면 모델 갱신은 제 기능을 수행하지 못한다. 이는 통계적 모델이 갖는 고유값이 어긋난 영상에서 더욱 높은 가중치를 갖기 때문이다. 이는 어긋난 영상이 포함된 모델로 탐색 시 어긋난 위치가 지정될 수 있음을 의미한다. 다음 그림은 이런 문제를 보여주는 예이다.




Fig. 2 Training image examples with a wrong aligned image.

이 문제는 통계적 모델 대신 다른 모델을 사용하여 해결한다. 본 논문은 템플릿 매칭을 이용한 방법을 제안하며 그 중 NCC (normalized cross correlation)[8]를 사용한다. 이는 모델과 탐색 영상간의 상관 관계를 따르므로, 같은 클래스인 학습 영상들의 위치를 갱신하는데 좋은 성능을 보인다. 이 방법은 속도가 비교적 빠르며 확실히 갱신된 모델을 보장한다.

$$r(u, v) = \frac{\left(N \sum_i I_i M_i - \left(\sum_i I_i \right) \left(\sum_i M_i \right) \right)}{\sqrt{\left(N \sum_i I_i^2 - \left(\sum_i I_i \right)^2 \right) \left(N \sum_i M_i^2 - \left(\sum_i M_i \right)^2 \right)}} \quad (12)$$

식(12)는 NCC의 상관계수 계산식이다. I_i 는 $(u + x_i, v + y_i)$ 의 영상 화소이며, M_i 는 상대적인 offset (x_i, y_i) 의

대응되는 모델 화소를 가리키며, N 은 모델 화소의 개수를 나타낸다

3.3. 탐색 시간 효율 개선

탐색은 모델과 유사한 물체가 존재하는 위치를 찾아내는 정렬 작업과 찾아낸 물체가 학습된 영상들과 같은 클래스인지 판단하는 클래스 판단, 두 가지 단계로 나눌 수 있다. 기존 시스템은 이 두 단계에 모두 통계적 모델을 사용하였고, PCA를 이용한 벡터 연산이 주를 이루기 때문에 연산량이 많다. 본 논문은 정렬 작업에서 연산이 비교적 적은 다른 매칭 방법을 사용하여 탐색 시간을 줄인다. 통계적 모델을 대체할 매칭 방법으로는 NCC[8]를 이용한 템플릿 매칭과 Sobel edge detector를 이용한 Similarity measure(이후 SIM)[9] 방법을 제안한다.

NCC는 앞서 모델 갱신에 사용했던 식(12)를 이용한다. SIM 기법은 Sobel mask를 사용하여 에지를 구하고 이 에지를 이용하여 방향 벡터를 구한 뒤 탐색 영상에서 해당 방향 벡터와 유사한 방향 벡터를 가진 위치를 찾는 방법이다. SIM의 매칭 정도를 나타내는 유사도(similarity measure)를 구하기 위한 식은 다음과 같다.

$$s = \frac{1}{n} \sum_{i=1}^n \frac{\langle d'_i, e_{q+p'} \rangle}{\|d'_i\| \|e_{q+p'}\|} \quad (13)$$

$$= \frac{1}{n} \sum_{i=1}^n \frac{t'_i v_{x+x'_i, y+y'_i} + u'_i w_{x+x'_i, y+y'_i}}{\sqrt{t_i'^2 + u_i'^2} \cdot \sqrt{v_{x+x'_i, y+y'_i}^2 + w_{x+x'_i, y+y'_i}^2}}$$

여기서 n 은 픽셀 수이고 모델 좌표 집합 $p_i = (x_i, y_i)^T$ 이고, 연관된 방향 벡터는 $d_i = (t, u)^T$, $i = 1, \dots, n$ 이다. d'_i 와 p'_i 은 각각 d_i, p_i 에 변환 행렬 H_p 를 곱한 값이다. 여기서 변환 행렬 H_p 는 회전을 나타내며 식(11)의 H_p 와 같다. $e_{xy} = (v_{xy}, w_{xy})^T$ 는 탐색 영상의 (x, y) 좌표에서 방향 벡터를 나타내며 e_{p+q} 은 기준 좌표 $q = (x, y)^T$ 에서 p' 만큼 이동한 좌표를 나타낸다.

통계적 모델만을 이용한 때와 마찬가지로 탐색 시간을 줄이기 위해 계층 탐색을 이용한다. 클래스 판단은 찾아낸 위치에 어느 정도 확장된 영역을 주어 통계적 모델을 이용하여 매칭한다. 이 방법을 사용하여 탐색 성능은 떨어뜨리지 않으면서 탐색 속도만 줄일 수 있다.

3.4. 자동 임계값 계산

기존 통계적 모델[1]에서 임계값을 계산하는 방법은 카이제곱분포(Chi-squared distribution) 표를 기준으로 하여 오류 확률에 해당하는 특정 기준치(예를 들어

0.01%)에 적합한 임계값을 구하는 것이다. 이 임계값 계산 방법은 계산에 사용된 데이터가 표준정규분포를 따르고 독립일 경우를 가정하고 있다. 만약 독립적이지 않은 데이터라면 이 방법은 신뢰성이 많이 떨어질 수 있다. 그리고 학습 영상 수가 적을 경우에는 카이제곱 분포를 따른다는 것을 확실히 알 수 없기 때문에 계산된 임계값이 정확하지 않을 수도 있다.

본 논문은 이런 임계값 계산 방법의 한계점을 보완하기 위한 다른 임계값 계산 방법을 제안한다. 이 방법은 다음 식으로 간단하게 나타낼 수 있다.

$$T = (BF + WT) / 2 \quad (14)$$

식(14)에서 BF 는 Best False의 약자로 다른 클래스로 학습된 영상 중 가장 좋은 적합도 값을 나타내고, WT 는 Worst True의 약자로 같은 클래스로 학습된 영상 중 가장 좋지 않은 적합도 값을 나타낸다. 이는 모델과 같은 클래스만을 모아놓은 영상 외에 다른 클래스의 영상을 추가적으로 학습하여, 두 클래스가 갖는 적합도 경계의 중앙값을 임계값으로 선택하는 방법이다. 이 방법은 모델과 다른 클래스 영상의 추가적인 학습이 필요하다는 단점이 있으나 학습 영상에 조건이 붙지 않고 같은 클래스로 학습된 모든 영상이 올바른 데이터로 인식된다는 장점이 있다. 그리고 다른 클래스 영상을 학습함으로써 다른 클래스의 영상과 같은 클래스로 영상 간의 경계를 확실하게 나눠놓을 수 있다는 장점이 있다.

4. 실험 결과

4.1. 학습 모델의 적합도 평가

통계적 모델은 학습 영상의 개수에 따라 그 성능이 달라질 수 있다. 또한 학습 영상의 개수가 적을 경우 제대로 된 학습 모델이 생성되지 않는다. 이런 조절이 불가능한 조건을 제외한 좋은 학습 모델은 우리가 사용하려는 적합도의 조건에 얼마나 부합하느냐에 달려 있다. 통계적 모델[1]은 영상에서 추출한 적합도 계산에 사용되는 데이터가 각각 표준정규분포를 따르기를 가정하므로 이런 조건에 만족하는 데이터를 가진 영상 집합이 좋은 학습 영상 집합이라 할 수 있다.

실험에는 다음과 같은 영상들이 사용되었다.




Fig. 3. Training set image examples.

위 영상은 모델을 포함하는 ROI 영상의 예이다. 영상의 크기는 50×80 이며 20×40 의 모델 영역을 가지고 있다. 이 물체는 0402로 불리는 PCB에 장착된 칩이며 실제 크기는 0.2 mm, 0.4 mm이다. 본 논문에서 분류를 원하는 클래스의 학습 영상으로 사용되었다.

다음은 모델 영상과 다른 클래스 즉, 0402 칩이 아닌 물체를 포함하는 학습 영상이다.




Fig. 4. Training images for other class data.

테스트 영상은 학습 영상과 크게 다르지 않은 영상들을 선택하였다. 이외에 크기가 640×400 인 영상을 크기가 다른 경우의 속도 차이를 구하기 위해 사용하였다.

적합도 f_0, f_1, f_2 중 f_1 과 f_2 는 그 안의 수식이 정규화되지 않은 부분이 있다. 식의 결과가 모델의 크기에 관계없이 일정한 수가 나오도록 식(5), 식(6)을 수정하면 다음과 같다.

$$f_1' = M_t + \frac{R^2}{nV_r} \quad (15)$$

$$f_2' = M_t + \frac{1}{n} \sum_{j=1}^n \frac{r_j^2}{v_j} \quad (16)$$

f_1' 과 f_2' 은 f_1, f_2 의 R^2 과 r_j^2 을 모델 크기 n 으로 정규화한 식이다. 정규화를 해야 수식의 값이 일정하게 나오면서 M_t 와 다른 수식의 크기 차이도 작게 하면서 M_t 가 식에 제대로 적용된다. 하지만 이렇게 M_t 를 적용하면 학습 영상 수에 따라 BF/WT 의 편차가 심하게 변하게 되어 학습 영상 수에 따른 고려가 더 필요하게 된다. 따라서 M_t 는 사용하지 않는 것이 더 나은 선택이라 볼 수 있다. 본 논문에서는 이런 결과로 다음 실험 결과부터는 M_t 를 제외한 f_1', f_2' 을 사용하였다.

물체 인식에 사용되는 세 적합도 중 가장 나은 인식 성능을 보이는 적합도는 f_2 다[1]. 이를 확인해보기 위해 같은 학습 영상으로 정규화된 적합도에 대하여 BF/WT 값을 비교해 본 결과는 Table 1과 같다. 이 실험을 위한 모델 영상은 30개를 사용하였고 테스트 영상은 같은 클래스 영상을 100개 다른 클래스 영상을 50개 사용하였다.

이 비율은 학습에 사용된 영상과 테스트에 사용된 영상의 모양에 따라 다르게 나올 수 있는 부분이므로

Table 1. BF/WT of f_0, f_1', f_2'









	f_0	f_1'	f_2'
BF/WT	1.55	1.65	2.31
BF	8.75	3.60	6.16
WT	5.63	2.18	2.67

절대적인 수치보다는 각 적합도 간의 차이가 더 중요한 지표가 된다. 표의 결과는 같은 데이터를 사용했을 시 나온 결과이고 f_2' 의 BF/WT 비율이 가장 높게 나왔으므로 가장 물체 분류가 잘 되는 적합도로 판단된다.

4.2. 회전된 영상에서의 탐색 결과

회전 영상에서의 탐색 결과는 기존 통계적 모델[1]에서 언급된 부분이 없고 실제 탐색한 영상이 제대로 나왔는가에 대한 실험 결과가 전혀 없다. 따라서 본 논문에서 제안한 정렬 방법이 제대로 적용되는가에 대해서 테스트한 결과를 보인다. 실험은 학습 영상과 같은 클래스 영상에 대해서 수행하였고 각각 30도, 45도, 90도, 330도 회전한 영상에 대해서 제대로 각도를 찾는지 보였다. 모델 생성에 사용한 영상 수는 50개이며 계층 탐색은 2레벨 수준에서 탐색되었으며 최하위 레벨에서 1도 단위로 탐색하였다. 다음은 각 영상에서 NCC와 SIM 기법을 적용하여 정렬하였을 때 나온 각도 값이다.

Table 2. Search results on rotated test image

	30	45	90	330
NCC	 29	 44	 90	 329
SIM	 31	 45	 90	 331

결과 영상은 1도 정도의 오차가 나지만, 이 오차범위에서 적합도는 차이가 없기 때문에 나온 결과이다.

4.3. 모델 갱신의 문제점 해결

통계적 모델[1]의 모델 갱신은 제대로 정렬되지 않은 학습 영상의 경우에는 제대로 된 모델 갱신이 이뤄지지 않는 경우가 있다. 이는 Fig. 2에 나타난 것과 같은 문제이며 이를 해결하기 위한 방법으로 본 논문에서

서는 NCC를 이용한 정렬 방법을 사용한다. NCC를 이용한 모델 갱신 작업을 수행한 결과는 다음 그림과 같다.




Fig. 5. Model refinement result using NCC.

기존 모델과 다르게 NCC를 적용한 결과는 제대로 물체가 정렬되지 않은 영상이 학습 영상에 포함되어 있어도 만족스런 정렬 결과를 내는 것을 볼 수 있다. 따라서 기존 시스템에 모델 갱신 문제를 해결하기 위해서는 기존 방법이 아닌 다른 방법을 사용해야 하고, NCC를 사용한 결과 제대로 된 정렬이 이루어진 것을 알 수 있다.

4.4. 물체 검사 시간 비교

다음은 각각 기존 모델(SAM)과 NCC, 그리고 SIM을 이용하여 물체를 정렬한 결과를 나타낸 것이다. 학습 영상은 영상의 증가에 따라 속도가 어떻게 변화하는지 알기 위해 개수를 10개, 50개로 바꿔가며 실험하였다. 테스트에 사용한 탐색 영상은 크기 변화에 따른 속도 차이를 알아보기 위해 크기를 작은 크기(50×80)와 큰 크기(640×400)로 바꿔가며 실험했다. 각도는 단일 각도에 대하여 수행되었으며 2레벨 계층 탐색하였고 적합도는 f_2 가 사용되었다.

Table 3. Search time comparison of the methods

[unit: ms]			
10 training samples	SAM (t=7)	NCC	SIM
50×80	3.6	2.5	2.5
640×400	420.0	75.7	50.8
50 training samples	SAM (t=25)	NCC	SIM
50×80	4.6	2.7	2.6
640×400	671.1	76.5	51.4

위 결과는 학습 영상을 각각 10개, 50개로 하여 모델을 생성했을 경우, 각 정렬 방법의 물체 인식에 걸린 시간을 나타낸 것이다. 결과를 보면 SIM이 가장 빠르며 SAM이 가장 느리다. 그리고 영상 크기가 커질수록 수행 속도 차이가 크게 나서 SIM이 가장 좋고 SAM이 가장 나쁜 것을 알 수 있다.

4.5. 물체 인식 성능 비교

해당 기법을 평가하는 척도로 속도가 감소하는 것도 중요하지만 그에 따라 인식 성능 또한 감소하지 않았는지 확인하는 것이 중요하다. 따라서 같은 조건일 때 각 기법의 BF, WT, BF/WT 값의 변화를 비교해보았다. 실험 데이터는 Table 3에 사용된 것 중 50×80 영상의 데이터를 사용했다.

Table 4. BF/WT comparison of the search methods

10개 학습	SAM	NCC	SIM
WT	2.46	2.46	2.46
BF	4.78	4.89	5.67
BF/WT	1.95	1.99	2.31

50개 학습	SAM	NCC	SIM
WT	2.94	2.94	2.94
BF	4.94	4.89	5.91
BF/WT	1.68	1.66	1.98

Table 4는 NCC나 SIM을 사용할 때 SAM과는 약간 다른 결과가 나올 수도 있다는 것을 보여준다. WT 값은 세 방법 모두 같은 값을 산출하지만, BF 값은 정렬 방법에 따라 정렬된 위치가 약간 차이가 나서, 조금 다른 값들을 내주는 것을 볼 수 있다.

Table 3, 4의 실험 결과를 종합해보면 물체 위치 정렬에 걸리는 시간은 NCC와 SIM이 SAM보다 적고 성능은 비슷하다. 따라서 물체 인식 과정 중 물체를 정렬하는 과정을 SAM 대신 NCC나 SIM으로 대신할 수 있음을 알 수 있다.

5. 결 론

본 논문에서는 그레이레벨 통계적 모델을 PCB 검사에 적용했을 때 생길 수 있는 문제를 해결하고 수행 시간을 향상시킬 수 있는 방법에 대해서 제안했다. 제안된 방법에서 기대할 수 있는 점은 다음과 같다. 먼저 각도가 알려지지 않은 회전된 영상에서의 물체 인식이 고려되었다. 이는 물체 인식 시 각도 단위까지 물체의 변화를 파악해야 할 때나 회전된 영상에서 물체 인식을 더욱 용이하게 해줄 것이다. 둘째, 제안된 방법으로 모델 갱신의 문제점을 해결하여 학습 데이터가 정교하지 않은 경우에도 강건할 수 있었다. 이는 통계적 모델을 더욱 신뢰성 있는 학습 모델로 만들어 줄 것이다. 셋째, 하나의 영상으로 시작하여 추가적으로 모델을 생성할 때에도 확실한 정렬 효과를 낼 수 있었다. 사용자

의 번거로움을 피할 수 있고 적은 학습 영상에서 취약할 수 있는 문제점도 해결해 주었다. 넷째, 물체 인식의 속도를 빠르게 하여 큰 영상에서도 실시간으로 검사를 해낼 수 있는 가능성을 보였다. 이는 더욱 고속화되기 힘든 하드웨어 성능을 뒷받침해 줄 것이다.

개선된 그레이 레벨 통계적 모델은 PCB 검사뿐만 아니라 사용자가 원하는 여러 산업 환경에 적용 가능할 것이다. 이 시스템을 사용하면 기존 시스템의 장점은 유지하면서 더욱 빠르고 강건하게 물체의 인식이 가능할 것이다.

참고문헌

1. T. Cootes, G. Page, C. Jackson, and C. Taylor, "Statistical grey-level models for object location and identification.", *Image and Vision Computing*, 14(8), pp. 533-540, 1996.
2. T.F. Cootes, A. Hill, C.J. Taylor and J. Haslam, "The use of active shape models for locating structures in medical images", *Image and Vision Computing*, 12(6), pp. 355-366, July 1994.
3. C. Liang-Chia, V. T. Nguyen and T. Abraham Mario "Automatic Optical Detection of Offset and Orientation of Electronic Component by Enhanced Active Shape Model (EASM)", *American Scientific Publishers*, vol. 20, pp. 1047-1055, 2012.
4. M. Turk and A. Pentland, "Eigenfaces for recognition. *J. Cognitive*", *Neuroscience*, 3(1), pp. 71-86, 1991.
5. J. Haslam, C.J. Taylor and T.F. Cootes, "A probabilistic fitness measure for deformable template models", In E. Hancock (ed.), *Proc. British Machine Vision Conference*, BMVA Press, pp. 33-42, 1994.
6. B. Efron and R. Tibshirani, "Bootstrap methods for standard errors, confidence intervals, and other measures of statistical accuracy", *Statistical Science*, 1(1), pp. 54-77, 1986.
7. B. Moghaddam and A. Pentland, "Probabilistic visual learning for object detection" *Proc. 5th Int. Conf. on Computer Vision*, pp. 786-793, 1995.
8. R. Jain, R. Kasturi and B.G. Schunck, "Machine Vision", McGraw-Hill, 1995.
9. C. Steger, "Similarity measures for occlusion, clutter, and illumination invariant object recognition", Ed. by B. Radig and S. Florczyk, *Pattern Recognition*, DAGM 2001, LNCS 2191, Springer Verlag, pp. 148-154, 2001.

접수일: 2013년 1월 3일, 심사일: 2013년 2월 4일,
게재확정일: 2013년 2월 28일