

신경회로망과 퍼지 규칙을 이용한 인쇄회로 기판상의 납땜 형상 검사

Solder Joint Inspection Using a Neural Network and Fuzzy Rule-Based Classification Method

고 국 원, 조 형 석, 김 종 형, 김 성 권

(Kuk Won Ko, Hyung Suck Cho, Jong Hyeong Kim, and Sung-Kwon Kim)

Abstract : In this paper, we described an approach to automation of visual inspection of solder joint defects of SMC(Surface Mounted Components) on PCBs (Printed Circuit Board) by using neural network and fuzzy rule-based classification method. Inherently, the surface of the solder joints is curved, tiny and specular reflective; it induces a difficulty of taking good image of the solder joints. And the shape of the solder joints tends to greatly vary with the soldering condition and the shapes are not identical to each other, even though the solder joints belong to a set of the same soldering quality. This problem makes it difficult to classify the solder joints according to their qualities. Neural network and fuzzy rule-based classification method is proposed to efficiently make human-like classification criteria of the solder joint shapes. The performance of the proposed approach is tested on numerous samples of commercial computer PCB boards and compared with the results of the human inspector performance and the conventional Kohonen network.

Keywords : solder joint inspection, 3-color circular illumination, Learning vector quantization, Fuzzy rule-based classification

1. 서론

최근 들어 전자 기기의 소형 경량화, 고기능화에 의해 전자 부품을 고밀도 인쇄 회로 기판(Printed Circuit Board, PCB)에 담기 위한 표면 실장 기술의 개발이 다방면으로 진행 중이다. 표면 실장 기술은 인쇄회로기판 위에 만들어진 전기적 도체 표면에 칩(chip) 형상의 부품 및 평면 IC등의 표면 실장형 부품을 납 접착제(solder paste)를 바른 후 탑재 하여 접착 시키는 방법이다. 현재 표면 실장 기술은 제품의 소형화에 의해 사용되는 부품의 크기가 점점 작아지고 있다. 현재 주로 사용되는 SMD부품 중 IC칩은 보통 0.2mm 크기로 약 100~140개의 리드(lead)를 가지고 있다.

기판 위의 실장 부품의 상태를 검사 작업의 하나인 납땜부의 검사는 최종 제품의 품질에 영향을 주는 중요한 공정이므로 신뢰성과 정확성이 있는 검사 작업이 필요하다. 최근 검사 작업의 신뢰성과 정확성을 높이기 위하여 시각 자동 검사에 관한 많은 연구가 이루어지고 있다.

현재 연구된 납땜 검사 방법은 조명 방식과 검사 알고리즘에 의해서 나누어진다. 조명 방식으로는 경면의 특성을 가지고 있는 납땜부의 형상을 관찰하기 위하여 여러 개의 점 광원을 구형으로 배치한 방법과[1], 원형 형태의 조명[2][5][9][12]~[15][17], 그리고 레이저[16]를 사용한 방법이 있다. 이러한 조명 방식들은 조명과 카메라 및 납땜 표면의 상대적인 위치를 이용하여 납땜부의 3차원 정보를 측정하고 있다. 다양한 조명 방식을 이용

하여 추출된 납땜부의 3차원 정보로부터 양/불량을 검출하는 검사 방법들은 기하학적 특징치(feature)들을 통계학적으로 분석하여 검사 규칙을 정하는 방법[1][2], 전문가 시스템을 이용하여 검사 규칙을 추론하는 방법[3][4][12], 신경회로망을 이용하여 입력 영상과 납땜부의 관계를 학습하여 검사 규칙으로 사용하는 방법[9][13][15][16]으로 나뉘어진다.

현재 상용화되어 널리 사용되고 있는 검사 알고리즘은 납땜부에 생긴 2차원 패턴에서 추출한 색 패턴의 면적, 순서, 도심(centroid) 등의 특징치들의 확률적 통계 자료를 바탕으로 유도해 낸 고정 규칙(rule)을 이용한 것이다[1]~[4][12]. 이러한 방법은 각 품질에 대한 많은 시료와 실험을 통해서 얻어질 수 있는 충분한 통계적 자료를 바탕으로 하지만, 예상하지 못한 시료들에 대한 유연성이 결여될 수 있다. 이러한 시료들에 대해서 미리 설계자가 준비한 대응책이 없는 경우 신뢰성 있는 검사가 어렵다는 단점이 있다.

최근 이러한 문제점을 해결하기 위하여 패턴 인식 분야에서의 널리 사용되고 있는 신경회로망을 적용한 사례가 증가하고 있다. 신경회로망은 학습에 의하여 입력 영상으로부터 검사 규칙을 유도하므로, 기존 방법에 비해 검사 규칙 유도를 위해 필요한 실험을 줄일 수 있고, 신경회로망 자체가 가지고 있는 영상 복원 기능과 잡음 제거 기능을 활용하여, 미처 예상치 못한 다양한 형태의 시료나 조명 이상으로 인하여 손상된 영상에 대해서도 어느 정도 검사가 가능하다는 장점이 있다.

납땜 검사에 주로 사용되고 있는 신경회로망은 학습 방법에 의해 지도학습(supervised learning)방법과 자율 학습(unsupervised learning)방법으로 나뉘며, 다층 신경

회로망(multilayer perceptron) [9],과 코호넨 신경회로망 분류기(Kohonen neural network classifier) [18]와 LVQ 분류기(Learning Vector Quantization) [19] 등이 사용되고 있다.

다층 신경회로망은 미리 얻어진 영상과 이에 해당하는 품질과의 관계를 지도 학습 과정을 통하여 인간의 판단 규칙을 배울 수 있다는 장점이 있지만 복잡하고 큰 크기의 패턴을 분류할 경우 학습 과정에 발생하는 국부 극소(local minimum)로 인하여 학습 규칙을 완전히 배울 수 없는 경우가 일어나기도 한다[9]. 반면에 자율학습 신경회로망인 코호넨 신경회로망 분류기는 크기가 큰 입력 패턴을 빠르게 분류 할 수 있는 장점은 있지만, 자율 학습에 의하여 스스로 입력 패턴들을 분류 하므로 설계자가 원하는 분류 결과를 얻기가 어려우며, 설계자의 의도를 직접적으로 포함할 수 없다는 단점이 있다.

이러한 자율 학습 신경회로망의 문제점 중 학습 과정에 설계자의 의도를 포함시켜 분류 성능을 높이기 위해서 자율 학습후 지도 학습을 통하여 분류 경계를 재 조정하여 정확성을 높이는 방법을 사용하였다[9] [17]. 그러나, 지도 학습을 통한 분류 경계 재 조정 방법은 이웃하는 두 경계를 조절하기 위해서 대표 값의 위치를 바꾸므로 이웃하지 않는 다른 경계까지 영향을 미친다는 단점이 있다.

본 연구에서는 기존의 자율 신경회로망의 납땜 형상 분류와 같이 복잡한 패턴 검사에 적용할 때 발생하는 문제점을 극복하고자 기존의 자율 학습 신경회로망과 퍼지 기법을 혼용하여 자율 학습 신경회로망의 단점을 보완하고자 하였다. 퍼지 규칙은 작업자의 검사 규칙을 퍼지 룰로 표현하여 자율 학습에 의해서 생성된 클래스의 경계를 지도 학습에 의해서 재 조절하여 분류 성능을 높이고 작업자의 경험을 포함 할 수 있도록 하였다.

제안된 퍼지 신경회로망을 사용한 검사 방법의 성능을 평가하기 위하여 산업 현장에서 생산된 인쇄 회로기판에서 얻은 다양한 납땜 형상에 대해 적용 하였으며, 기존의 코호넨 신경회로망 분류기 및 LVQ 분류기를 사용한 방법과 동일한 납땜 형상에 대해서 적용을 하였다. 그 결과 기존 자율 학습 신경회로망을 사용한 방법과 비교하여 학습 납땜 영상에 대하여 우수한 분류 결과를 얻을 수 있었으며, 또한 학습에 사용되지 않는 납땜 영상에 대해서도 우수한 분류 결과를 얻을 수 있었다.

II. 삼색 원형 조명 장치와 납땜부의 영상

납땜부의 표면은 거울면과 같이 경면 반사(specular reflection) 특성을 가진다. 경면 반사 특성을 갖는 물체는 수광부 또는 광원부의 미소한 움직임으로 인하여 경면 반사가 나타나기도 하고 사라지기도 하여 명암에 의해 물체의 형상을 인식하는 일반적인 머신 비전(machine vision)기법을 적용하기 어렵다. 그 이유는 경면 반사가 일어나는 부분에서는 경계선 추출 방법(edge detection)이나 영역 분리(region segmentation) 방법을 사용위해 기본이 되는 명암 정보를 이용할 수가 없기

때문이다.

경면 물체의 측정 방법은 물체의 명암 취득을 위하여 빛의 반사 모델을 세우고 수광부와 광원부를 잘 정리하여 경면 반사 성분의 명암을 적극적으로 활용하여 형상을 측정하는 것이다. 흔히 조명 및 시각의 위치에 기하학적 제한 조건을 두어 경면 반사에 의한 영상의 밝은 명암의 값을 가지고 물체의 특성을 추출하여 인식하는 방법이 사용되고 있다. 본 연구에서는 그림 1에서와 같이, 경면 반사 특성을 가진 납땜부의 표면을 검사하기 위한 조명 장치로서 칼라 카메라(color camera)와 동일한 측상에 놓여 있는 3개의 빨강, 파랑, 그리고 녹색으로 구성된 원형의 광원을 사용하였다. 삼색 원형 조명 장치는 납땜 검사에서 널리 사용되고 있는 조명 방법으로써 3개의 Ring 조명을 높이와 크기 및 배치를 다르게 하여 검사하고자 하는 납땜부에 각기 다른 입사각으로 조명 되도록 구성되어 있다.




그림 1. 삼색 원형 조명 시스템.

Fig. 1. Schematic of overall illumination and vision system.

파랑 색 원형 조명은 40mm의 지름을 가지고 맨 위쪽에 위치하여 20도의 각도로 인쇄 회로 기판에 조명 되고, 빨강 조명은 70mm로 40도, 그리고 녹색은 130mm로 70도로 조명 된다.

주어진 원형 조명 아래에서는 10도 정도의 경사도의 평평한 면은 파란색으로, 20도 정도의 경사의 약간 기울어진 면은 빨간색으로, 그리고 35도 부근의 급한 경사면은 녹색으로 보여진다. 삼색 원형 조명 장치는 세 개의 광원을 동시에 조명하는 효과를 나타내며, 동시에 납땜부의 표면의 3가지 경사도의 패턴을 한 장의 색 영상에 얻을 수 있다.

그림 2는 삼색 원형 조명을 사용하여 얻은 인쇄 회로기판의 영상이다. 리드(lead)와 납땜 표면등과 같이 경면 반사의 특성을 갖는 면들은 경사도에 따라 각기 다른

색깔을 선명히 보여 주지만, 플라스틱 package나 인쇄 회로 기판의 바닥면 등과 같이 난반사(lambertian reflection) 특성을 가지고 있는 부분은 원래 제질 고유의 색깔을 보여 준다. 카메라 렌즈(lens)의 초점이 납땜부에 맞추어져 있기 때문에 높이가 다른 부분은 보다 흐리게 보인다.

카메라를 통하여 얻은 납땜부의 색 띠는 납땜부의 같은 기울기에서 나타나는 등 경사도 곡선(iso-inclination contour)이다. 등 경사도 곡선은 경면 물체의 형상을 효과적으로 추출할 수 있는 신뢰성 있는 특징치로 많이 사용되어 왔으며, 납땜의 형상 인식에도 등경사도 곡선의 형태를 분석하여 3차원 형상을 재 구성할 수 있으므로 중요한 특징치로 널리 사용되고 있다[2] [9] [12] ~ [14] [17].




그림 2. 삼색 원형 조명 시스템에서 인쇄회로기판의 영상.

Fig. 2. Image of PCB inspected under the proposed illumination system.

그림 3은 다양한 납땜부의 등경사도 곡선의 색 띠의 분포를 보여 준다. 납땜의 형상은 크게 납땜의 양의해서 미납(I), 미납 정상(IA), 정상(A), 정상 과납(EA), 그리고 과납(E)과 같이 5개의 종류로 나누었다. 미납 정상은 정상적인 납땜부의 형상이지만 납의 양이 적은 경우를 말하며, 과납 정상은 정상적인 납땜부의 형상이지만 납의 양이 약간 많은 경우를 의미한다. 미납은 납이 부족하여 생기는 현상으로서 리드와 페드에 납이 없으므로 평면과 가까운 형상을 하고 있고, 납땜부의 색 영상은 파란색이 주로 나타난다. 미납 정상의 경우에는 리드에 약간의 납땜부가 생기므로 리드 끝에서 페드(pad)쪽으로 약간의 경사면이 존재하고, 이 경사면에 기울기에 따라 약간의 녹색과 빨간색이 영상에 나타나기 시작한다. 정상 납땜에서는 납땜부가 적당히 경사져 있어 말 안장 형상의 일부분처럼 보인다. 영상에서는 녹색, 빨간색, 파란색이 순차적으로 나타난다. 과납 정상에서는 납이 과다해지기 시작하여 완만한 형태의 볼록한 곡면의 형태로 되어 있으므로 주로 완만한 경사에서 생기는 빨간색 패턴이 많이 나타난다. 과납에서는 리드의 납땜이 과다하여 볼록한 형태를 이루므로 파란색의 띠와 빨간색과 녹색 띠로 둘러 싸여 있는 형태를 취하고 있다.

영상에서 2차원 색 패턴의 변화는 그림 3에서 나타난

바와 같이 납땜부의 3차원 형상을 대변해 줄 수 있는 중요한 특징이며, 색 띠의 순서 및 면적 변화로부터 납땜부의 불량 형태의 특징과 양품의 특징 형태를 비교하여 불량을 판단 할 수 있다.

납땜 종류	3차원 형상	3색 칼라 패턴
(1) 미납 Insufficient soldering		
(2) 미납 정상 Insufficient but Acceptable soldering		
(3) 정상 Acceptable soldering		
(4) 과납 Excess soldering		
(5) 과납 정상 Excess but Acceptable soldering		

Green pattern : Blue pattern : Red pattern

그림 3. 납땜부와 칼라 패턴.

Fig. 3. Solder joint shapes and schematic color images.

III. 신경회로망과 퍼지규칙을 이용한 납땜검사

1. 개요

본 장에서는 앞서 말한 바와 같이 자율 학습 신경회로망을 이용한 납땜 패턴 분류 작업에서 발생할 수 있는 문제점을 해결하기 위한 방법으로 자율 신경회로망과 퍼지 규칙을 결합한 새로운 검사 방법을 제안하고자 한다. 제안된 방법은 기존의 LVQ 자율학습 신경회로망 분류기에 퍼지 규칙으로 표현된 작업자의 경험을 결합하였다.

본 연구에서 제안한 방법은 그림 4에서와 같이 2개의 계층 구조로 이루어져 있다. 아래 층에서는 삼색 원형 조명 장치를 사용하여 얻은 납땜부의 색 패턴을 분류하기 위하여 자율 학습 신경회로망 분류기인 LVQ (Learning Vector Quantization)으로 이루어 졌으며, 위 층에는 신경회로망에서 분류된 결과를 퍼지 입력으로 사용하는 퍼지 규칙을 이용한 판단(fuzzy rule-based decision)부분으로 구성되어 있다.




그림 4. 제안된 검사 알고리즘의 구조.
Fig 4. The structure of the proposed inspection algorithm.

본 연구에서는 입력 영상을 3개의 영역으로 나누어 각 영역에 대하여 서로 다른 LVQ 신경회로망 분류기를 적용하여 학습 영상을 분류하였다.

납땜부의 형상의 특징을 살펴 보면, 납땜부의 중앙부의 형상 변화는 납땜 가장자리의 형상 변화 보다 적다. 효율적으로 전체 영상을 나누기 위해서는 변화 정도에 따라 3개의 부분으로 나누고 각 부분에 각각 다른 LVQ 신경회로망을 적용하여 각 부분의 납땜 형상을 분류한다면, 전체의 영상을 하나의 LVQ 신경회로망을 적용하는 것 보다 납땜부 형상 변화가 큰 부분은 더욱 세밀하게, 반면에 변화가 작은 부분은 적은 수의 출력 노우드

를 사용하여 분류를 할 수 있다. 그리고, 하나의 LVQ 모듈을 사용하여 세밀하게 학습할 때에 비해서 전체적인 가중치의 크기를 줄이면서, 향상된 분류 결과를 기대할 수 있다는 장점이 있다. 이러한 방법은 LVQ 신경회로망이 복잡한 패턴을 분류하는데 있어 난이도를 줄여 학습 효율과 분류 성능을 높일 수 있다[14] [17]. 또한 후반부의 퍼지 규칙에서 나누어진 입력 공간의 조합으로 판단을 하므로 국부 형상 변화가 생기는 납땜부의 판단에 보다 효과적이며, 퍼지 규칙에 전문가의 지식을 포함할 수 있다는 장점이 있다.

2 LVQ(Learning Vector Quantization) 신경회로망분류기

LVQ 신경회로망은 널리 알려진 자율 학습 분류기이다. 납땜 영상 패턴을 분류하기 위한 LVQ 신경회로망 분류기는 그림 4에서와 같이 입력층(input layer)과 경쟁층(competitive layer)으로 이루어져 있다.

입력층은 납땜 영상 그 자체를 입력으로 사용하기 위하여 2차원의 형태로 영상과 같은 크기로 구성되어 있으며 경쟁층의 출력 노우드와 가중치(weight)로 연결되어 있다. 학습을 통하여 가중치는 입력 패턴을 닮아 가도록 수정된다. LVQ 신경회로망을 이용한 패턴의 분류 방법은 출력 노우드와 연결된 가중치와 입력 패턴과의 유사도(similarity)를 판별하여 경쟁 학습(competitive learning) 과정을 통하여 가중치를 입력 패턴을 닮도록 학습시킨 후, 입력 패턴과 출력 노우드의 가중치들과 상호 유사성을 판별하여 제일 유사도가 큰 출력 노우드가 반응을 하게 되어 입력 패턴을 분류하게 된다. LVQ 신경회로망의 학습 방법을 자세히 살펴 보면 다음과 같다.

Procedure 1 먼저 LVQ 신경회로망에 입력될 하나의 입력 값을 선택한다. 이때 입력 값으로는 납땜부의 칼라 영상의 각 pixel의 명암 값을 사용하였다. 칼라 영상은 빨강, 녹색으로 분리되어 각각의 입력으로 사용되며 다음과 같이 표현될 수 있다.

$$I_c = \{I_c(l, i, j) | l = 1, 2, 3, i = 1, 2, 3, \dots, n, j = 1, 2, 3, \dots, m\} \quad (1)$$

여기서 c는 입력 영상 클래스를 나타내고, $I_c(l, i, j)$ 는 (i, j) 화소(pixel)의 l 번째 디지털 메모리의 프레임(frame)을 나타내며 1은 빨간색, 2는 녹색, 3은 파랑색을 나타낸다. 여기서 n, m은 입력 영상의 화소의 크기를 나타낸다. 첫번째 선택된 영상의 명암 값을 첫 번째 출력 노우드의 가중치로 지정한다.

$$W_c^k = I_c, \quad k = l \quad (2)$$

Procedure 2 다음 입력 영상 중에서 무작위로 추출하여 신경회로망에 입력하고 가중치와 비교하여 승자(winner) 출력 노우드를 구한다.

$$\begin{aligned} & \|W_c^{l,m} - I_c\| < \|W_k^{l,m} - I_c\|, \text{ for all } k \text{ or} \\ & \sum_i \sum_j \sum_l |w_c^{l,m}(l, i, j) - I_c(l, i, j)| < \\ & \sum_i \sum_j \sum_l |w_k^{l,m}(l, i, j) - I_c(l, i, j)| \end{aligned} \quad (3)$$

Procedure 3 : 이때 (3)의 조건을 만족시키는 경쟁 층의 출력 노우드가 (4)를 만족할 경우 가중치를 (5)에 의해서 학습시킨다.

$$\|W_c^{(t)} - I_c\| < \zeta \times (n \times m \times 3) \quad (4)$$

$$W_c^{(t+1)} = W_c^{(t)} + \eta(t) \cdot \{I_c - W_c^{(t)}\} \quad (5)$$

(4)의 ζ 는 유사성을 판별하는 문턱 값으로써 선택된 영상이 얼마나 승자 출력 노우드에 가까운가를 판별하게 되며 문턱 값 이하를 만족하게 되면 유사성을 인정받아 학습을 하게 된다. 그리고 t 는 학습을 위한 반복 횟수를 나타내며, $\eta(t)$ 는 동 학습 계수로 t 가 증가할수록 그 값은 감소한다. (5)에 의해 학습된 가중치를 입력된 영상을 닮아 간다.

Procedure 4 : 만약 입력 영상 $I_c(l, t, j)$ 가 승자 출력 노우드의 가중치 $W_c^{(t)}$ 와 유사도가 (6)과 같이 문턱 값보다 크거나 같을 경우엔 새로운 노우드를 하나 생성하고 생성된 노우드의 가중치는 (7)에 의해서 학습된다.

$$\|W_c^{(t)} - I_c\| \geq \zeta \times (n \times m \times 3) \quad (6)$$

$$W_c^{(t+1)} = W_c^{(t)} + \eta(t) \cdot \{I_p - W_c^{(t)}\}, t=1 \quad (7)$$

$$W_c^{(1)} = I_p$$

Procedure 5 : 모든 입력 영상에 대하여 procedure 2, 3, 4의 과정을 되풀이한다.

Procedure 6 : 신경회로망의 학습 성능을 높이기 위하여 모든 입력 영상을 대해서 학습 과정을 마친 후 지도 학습 과정을 통하여 자율 학습 과정에 의해서 생성된 경계를 다시 새롭게 강화하는 방법이 필요하다. 이때는 작업자가 미리 분류하여 놓은 결과를 이용하여 학습 과정을 거쳐 클래스의 경계를 다시 조정한다. 만약 입력 I_p 가 q -클래스에 속해야 하나 다른 c -클래스로 분류 되었을 경우 다음 (8)을 사용하여 가중치 값을 수정한다.

$$W_c^{(t+1)} = W_c^{(t)} - \eta(t) \cdot \{I_p - W_c^{(t)}\} \quad (8)$$

(8)은 잘못 분류된 입력으로부터 선택된 가중치를 반대 방향으로 밀어내어 분류 경계(class boundary)를 재 조정하는 역할을 한다. 학습이 완료되면 각 출력 노우드에 연결된 가중치들은 출력 노우드가 나타내는 클래스의 대표 영상을 의미하게 되고 이를 프로토타입 영상(prototype image)이라 한다.

3 퍼지 규칙을 이용한 낱뿔 부분류

LVQ 신경회로망을 이용한 패턴의 분류 방법은 입력 영상과 학습에 의해서 자동으로 생성된 가중치 벡터와 입력과 유클리디안 거리(Euclidean distance)로 구해지는 유사성의 척도를 사용하여 제일 유사성이 큰 가중치의 클래스를 분류 결과로 나타낸다. LVQ 신경회로망을 이용한 분류 방법은 설계자가 직접적으로 클래스들 경계 부분을 조정하는 것이 어렵다는 단점이 있다.

본 연구에서는 기존 신경회로망을 사용한 한계를 극

복하기 위한 방법으로 LVQ 신경회로망에 퍼지 방법을 사용하여 정확한 분류 결과를 얻고, 또한 설계자의 의도를 분류기에 첨가하기 위하여 퍼지 규칙을 사용하였다. 퍼지 규칙부의 입력은 경계 부분에서의 분류 결과의 성능을 높이기 위해서 유사도가 제일 큰 두개의 클래스의 소속도를 사용하였으며, 퍼지 규칙은 3개의 낱뿔 형상의 상태를 검사자의 경험과 판단을 토대로 하여 식(9)와 같이 IF, THEN 규칙으로 구성하였다.

IF the shape in the right column window is(I,IA,A,EA,E)
AND the shape in the center column window is(I,IA,A,EA,E)
AND the shape in the left column window is(I,IA,A,EA,E)
THEN the classification result is (I,IA,A,EA,E) (9)

여기서 I는 Insufficient soldering의 약자로 미납을 의미하며, IA는 Insufficient but Acceptable soldering의 약자로 미납 정상율, A는 Acceptable soldering으로 정상율, EA는 Excessive but Acceptable soldering으로 과납 정상율, 마지막으로 E는 Excessive soldering으로 과납을 의미한다.


본 연구에서 제안된 퍼지 룰 패턴을 이용한 검사 방법은 작업자가 낱뿔의 영상을 보고 품질을 판단 방법을 묘사한 것이다. 3개의 LVQ 신경회로망의 분류 결과들 각 퍼지 규칙의 소속도로 변환하기 위해서는 식(10)과 같이 각 LVQ 모듈의 제일 큰 2개의 유사도들 가지는 클래스들의 유클리디안 거리가 사용되며, 그림 5와 같이 퍼지 멤버쉽(fuzzy membership) 함수에 의해서 퍼지화(fuzzification) 되어진다.

$$O(x) = f(c_1, c_2, d^{c1}(x), d^{c2}(x)) = \begin{cases} c_1 \times \frac{d^{c1}(x)}{d^{c1}(x) + d^{c2}(x)}, & \text{if } c_1 \leq c_2 \\ c_2 \times \frac{d^{c2}(x)}{d^{c1}(x) + d^{c2}(x)}, & \text{otherwise} \end{cases} \quad (10)$$


여기서 c_1 과 c_2 는 분류자에 의해서 라벨화된 값이며 미납의 패턴이 1의 값을 가지고 과납으로 갈 수록 큰 값을 가지게 된다. $d^{c1}(x)$ 는 입력 패턴 x 와 클래스 c_1 의 가중치와 유클리디안 거리를 의미하며 전체적인 (10)의 의미는 입력 패턴 x 가 클래스 c_1 과 c_2 에 속하는 정도를 나타내며 $O(x)$ 는 c_1 과 c_2 의 사이에 있다.

(10)에 의해 계산된 값은 그림 5과 같은 fuzzy membership 함수에 의하여 퍼지화 시킨 다음 이를 이용하여 미리 구성된 퍼지 규칙과 비교하여 제일 적합도가 큰 규칙에 의해 낱뿔부의 상태를 판정하게 된다. 이때 그림 5에서 세로 축은 퍼지 소속도를 나타내며, 가로 축은 (10)에 의해서 정량화된 입력 변수 값이다.

낱뿔의 형상 판단에 사용되는 퍼지 규칙은 미납의 분류에는 표 1, 미납 정상에는 표 2, 정상에는 표 3, 과납 정상에는 표 4 그리고 과납에는 표 5가 사용된다. 입력



(a) Membership function for side shape of solder joint



(b) Membership function for center shape of solder joint

그림 5. 퍼지 소속 함수.

Fig. 5. Fuzzy membership function.

영상은 3개의 LVQ 신경회로망에 의해서 분류되어지고 그 결과를 이용해서 퍼지 멤버 칩에 의해서 퍼지화 된 다음 표 1~5와 같이 작업자에 의해서 미리 구성된 퍼지 규칙과 비교하여 미리 설정된 퍼지 규칙에 적합도가 제일 큰 규칙의 판단 결과로 분류하게 된다. 즉 디퍼지 퍼케이션(defuzzification)은 각 퍼지 규칙의 적합도를 구하고 퍼지 규칙의 적합도가 최대화된 값의 결과를 분류 결과로 선택하는 방법이다.

표 1. 미납 검사 규칙.

Table 1. Inspection rule for insufficient soldering.

	Premise			Consequence
	R	C	L	
R1	I	I	I	I
R2	I	IA	I	I
R3	I	I	IA	I
R4	IA	I	I	I
R5	IA	I	IA	I

R : right module, C : center module, L : left module

표 2. 미납 정상 검사 규칙.

Table 2. Inspection Rule for insufficient but acceptable soldering.

	Premise			Consequence
	R	C	L	
R6	IA	IA	IA	IA
R7	IA	I	IA	IA
R8	I	IA	IA	IA
R9	IA	IA	I	IA

R : right module, C : center module, L : left module

표 3. 정상 검사 규칙.

Table 3. Inspection rule for acceptable soldering.

	Premise			Consequence
	R	C	L	
R10	A	A	A	A
R11	A	EA	A	A
R12	A	A	EA	A
R13	EA	A	A	A
R14	EA	A	EA	A
R15	A	IA	A	A

R : right module, C : center module, L : left module.

표 4. 과납 정상 검사 규칙.

Table 4. Inspection rule for excess but acceptable soldering.

	Premise			Consequence
	R	C	L	
R16	EA	EA	EA	EA
R17	EA	E	EA	EA
R18	EA	EA	E	EA
R19	E	EA	EA	EA
R20	EA	A	EA	EA

R : right module, C : center module, L : left module

표 5. 과납 검사 규칙.

Table 5. Inspection rule for excess soldering.

	Premise			Consequence
	R	C	L	
R6	E	E	E	E
R7	E	E	EA	E
R8	EA	E	E	E
R9	E	EA	E	E

R : right module, C : center module, L : left module

표 6은 입력 패턴이 분류 결과를 나타내고 있다. 입력 패턴의 LVQ 신경회로망의 분류 결과를 퍼지 멤버 칩에 의해서 퍼지화된 값은 미납 규칙의 경우 각각 0.7, 0.8, 0.6 이고 미납 정상인 경우에 각각 0.3, 0.2, 0.4 이다. 이때 규칙의 적합도는 미납 규칙은 0.7 미납 정상은 0.3 이므로 최대 적합도가 되는 0.7의 규칙의 판단 결과인 미납으로 납땜의 상태를 판단하게 된다.

표 6. 미납 판단 결과.

Table 6. Classification result of insufficient soldering.

Premise			Fuzzy fitness	Consequence
R	C	L		
I : 0.7	I : 0.8	I : 0.6	$I : (0.7+0.8+0.6)/3 = 0.7$	I
IA : 0.3	IA : 0.2	IA : 0.4	$IA : (0.3+0.2+0.4)/3 = 0.3$	

IV. 실험 및 토의

제안된 검사 알고리즘의 성능을 평가하기 위하여 삼색 원형 조명 장치를 사용하여 얻은 영상을 이용하여 먼저 LVQ 신경회로망을 이용하여 입력 영상을 분리하였다. 분리된 영상의 결과를 이용하기 위한 fuzzy decision 모듈은 전문가의 경험을 토대로 하여 퍼지 룰 규칙을 구성하고 이를 이용하여 최종 납땜부의 양/불량 판정을 하였다. 마지막으로 본 알고리즘에 의한 결과와 이미 잘 알려진 코호넨 신경회로망을 이용한 분류 결과와 비교 분석하였다.

1. 실험 영상 데이터

LVQ 모듈과 퍼지 룰 패턴을 학습하기 위하여 실제 산업체에서 생산한 5장의 기판에서 추출한 400개의 납땜부의 영상 데이터 중에 300개의 영상 데이터를 사용하였다. 나머지 100개의 영상 데이터는 구성된 본 연구에서 제안한 검사 알고리즘의 성능을 평가하기 위하여 사용하였다. 수집한 납땜부의 영상 데이터는, 우선 경험이 풍부한 검사자들에 의해 미납(I), 미납 정상(IA), 정상(A), 과납 정상(EA), 과납(E)의 5개의 클래스로 구분하였다.

각 영상 데이터는 55 x 45화소(pixel)의 크기의 window 영상으로 납땜부에 정확히 위치시켜 명암 값(graylevel)을 추출하였다. 본 실험에서는 리드(lead)의 끝이 항상 평평한 사각형의 모양이므로 이를 기준으로 납땜부를 찾았다. 그림 9는 학습에 사용된 영상을 보여주고 있다.



그림 6. 학습 영상.
Fig. 6. Training image.


2. LVQ 신경회로망의 학습

LVQ 신경회로망 모듈의 입력 node의 수는 납땜의 중앙부의 영상을 분류하기 위한 모듈은 19x45 화소의 삼색 칼라 영상을 받기 위하여 3x19x45의 노우드로 구성되어 있으며, 가장자리 영상을 분류하기 위한 모듈은 18x45 화소의 삼색 칼라 영상을 위하여 3x18x45로 구성되어 있다. LVQ 알고리즘의 가중치는 입력 영상과 같은 크기이며, 각 가중치는 입력 영상의 밝기 값과 같이 0-255의 값을 갖는다. 학습에 앞서서 유사도 범위(similarity bound) ξ 의 설정은 (11)과 같이 정하였다.


$$\xi = \frac{\sum_{l=1}^3 \sum_{i=1}^n \sum_{j=1}^m |I^a(l,i,j) - I^b(l,i,j)|}{n \times m \times 3} \quad (11)$$

여기서, m 과 n 은 영상 윈도우(window)의 크기를 나타내는 수이다. 중앙 부분의 LVQ 신경회로망에서는 m 과 n 은 19와 45, 가장자리 부분에서는 18과 45이다. 유사도 범위, ξ 은 비슷한 두 영상 I^a 와 I^b 간의 명암 차이

를 의미한다. 중앙 부분의 납땜 형상의 분류를 위해서 ξ 은 36, 가장 자리의 분류를 위해서도 마찬가지로 36으로 설정했다. 학습 과정 후 가장자리 부분의 납땜부 형상의 분류를 위해서는 8개의 class를 가장 자리의 납땜부 형상 분류를 위해서는 10개의 class가 생성되었다. 그림 7은 학습 후 생성된 각 classifier의 prototype image를 나타내었다.



(a) Prototypical image for both side column window



(b) Prototypical image for the center column window
그림 7. 학습 후 가중치 영상.

Fig. 7. Trained prototypical image.

3. Fuzzy membership function의 튜닝

퍼지 규칙 패턴은 작업자의 판단 경험을 묘사하여 표현한 것이다. 퍼지 규칙의 튜닝은 퍼지 규칙의 멤버쉽 함수의 형태(shape)를 대변하는 사다리꼴, 혹은 삼각형의 위치를 바꾸어 원하는 분류 결과를 얻고자 한다. 퍼지 멤버쉽 함수의 결정은 설계자가 원하는 분류 결과를 얻도록 위치를 입력 패턴의 분류 결과를 보고 수정한다. 그림 5는 설계자가 최종적으로 구한 퍼지 소속 함수의 형태이다.

4. 실험 결과

표 7은 학습 후 학습에 사용한 300개의 영상을 사용하여 분류 실험을 한 결과이다. 모든 학습된 샘플에 대하여 정확히 분류하였음을 알 수 있다.

표 7. 학습 영상의 분류 결과.

Table 7. Classification result for training samples.

Q	NS	I	IA	A	EA	E	NC
I	54	54					0
IA	26		26				0
A	134			134			0
EA	32				32		0
E	54					54	0
Total success rate : 1-0/300 = 1.00(100%)							

Q : quality, NS : no. of samples, NC : no. of confusion

표 8은 학습에 사용하지 않은 100개의 영상에 대한 분류 결과이다. 미납 정상과 과납 정상 클래스에서 분류 오차가 발생하였다. 이 경우 영상은 납땜의 경계 부분으로 숙련된 작업자도 실제 영상으로 판별이 어려운 부분이였다. 그러나, 이러한 패턴에 있어서는 퍼지 규

칙의 멤버십 함수의 값을 조정함으로써, 양쪽에 가까운 클래스의 경계 부분에 포함되어 있는 패턴을 불량에 포함하도록 하여, 차후 작업자의 불량 수정 작업 시 수동 검사에 의해서 다시 재 검사 및 수정의 기회를 줄 수 있다. 그러나, 불량을 정상으로 판단했을 경우에는 작업자의 검사/수정을 거칠 수 없으므로 불량 기판이 만들어질 가능성이 커진다.

표 8. 학습에 사용되지 않은 영상의 분류 결과.

Table 8. Classification result for test samples.

Q	NS	I	IA	A	EA	E	NC
I	20	20					0
IA	20	2	18				2
A	20			20			0
EA	20				18	2	2
E	20					20	0
Total success rate : 1-4/100 = 0.96(96%)							

Q : quality, NS : no. of samples, NC : no. of confusion

5. 비교 연구

표 9는 코호넨 자율 학습 분류기와 이용하여 동일한 학습 영상에 대하여 자율적으로 분류한 결과이다.

이때 분류하고자 하는 클래스의 개수는 두 경우 모두 10개로 정하였으며, 학습에 사용되는 초기 학습 계수는 0.3으로 정했으며, 초기 가중치 값은 0-255의 값을 사용하였다. 코호넨의 경우 초기 neighborhood의 경우에는 5로 선정하였으며 시간이 증가함에 따라 감소되도록 하였다.

표 7의 결과와 비교해 볼 때 큰 차이를 알 수 있다. 이와 같이 자율 학습 분류기 (unsupervised self-clustering algorithm)의 단점은 분류기가 스스로 비슷한 데이터들 끼리 모으므로 분류 작업에 검사 목적이나 검사자의 의도와 일치하지 않을 수 있으므로 원하는 결과를 얻기가 어렵다는 것이다.

표 9. 학습 영상의 분류 결과.

Table 9. Classification result by Kohonen classifier.

Q	NS	I	IA	A	EA	E	NC
I	54	51	3				3
IA	26	6	20				6
A	134			131	3		3
EA	32			4	20	8	12
E	54				28	26	26
Total success rate : 1-50/300 = 0.8333(83.33%)							

Q : quality, NS : no. of samples, NC : no. of confusion

V. 결론

본 연구에서는 인쇄회로 기판의 납땜부의 검사를 위하여 기존의 신경회로망의 퍼지 기법을 적용하여 표면 실장형 인쇄 회로 기판의 납땜부를 검사 방법을 제시하


였다. 납땜부의 검사 작업은 자동화에 있어서 형상 인식 문제 이외에도 납땜부의 형상이나 그 불량 형태가 다양하여, 이를 잘 분리할 수 있는 분류기의 개발이 필요하다. 그러나, 일반적인 자율 학습 분류기의 단점은 스스로 분류된 클래스의 결과가 검사 목적이나 검사자의 의도와 항상 일치하지 않는 점이다. 물론 이러한 방법이 전혀 입력 영상들의 확률 분포를 모르는 경우에 이들의 특성을 살펴보기 위하여 사용되어 질 수 있으나 작업자의 의도와 일치하기 위해서는 많은 실험을 뒤풀이 해야 한다는 단점이 있다.

본 연구에서는 LVQ 신경회로망에 퍼지 기법을 적용하여 작업자의 판단 결과를 최종 검사 규칙에 반영하였다. 이러한 방법은 LVQ 신경회로망의 분류 결과에 설계자의 의도를 포함할 수 있어 보다 인간과 비슷한 분류 결과를 얻을 수 있다. 실제 납땜 검사에서는 납땜부의 형상을 작업자와 같이 분류할 수 있는 분류기가 자동화에 반드시 필요하다. 또한, 퍼지 규칙의 멤버십 함수 값을 수정하여 기판의 특성이 바뀌거나 검사 조건이 조금씩 바뀔 경우 기존의 검사 기법과는 달리 유연하게 새로운 검사 규칙을 쉽게 적용할 수 있다는 장점이 있다. 그러나, 퍼지 멤버 쉽의 값을 조정하는데 있어서는 현재 자동 기법이 개발되어 있지 않아 작업자가 수동으로 룰을 튜닝해야 한다는 단점이 있다. 이를

참고문헌

- [1] P. J. Bartlett, C. L. Besl, R. Cole, D. Jain, Mukherjee, and K. D. Skifstad. "Automated solder joint inspection". *IEEE trans. PAMI*, vol 10, no 1, pp. 31-43, 1988.
- [2] Capson and S. L. Eng, "A tiered color illumination approach for machine inspection of solder joint", *IEEE Trans. PAMI*, vol 10, no 3, pp. 387-393, 1988.
- [3] S. Takagi, and W. B. Hata, "Visual inspection machine for solder joints using tiered illumination", *Pro. SPIE*, vol. 1386, pp. 21-29, 1990.
- [4] J-S Park, and J. T. Tou, "A solder joint inspection system for automated printed circuit board manufacturing", *Pro. IEEC Conf. Robotics and Automation*, vol. 2 pp. 1290-1295, 1999.
- [5] J. H. Kim and H. S. Cho, "Neural network-based inspection of solder joints using a circular illumination", *Image and Vision Computing*, 1995.
- [6] H. J. Zimmermann. "Fuzzy set theory and its applications". *Kluwer-Nijhoff Publishing*, pp. 205-212.
- [7] 이광형, 오길록, "퍼지 이론 및 응용", 홍릉과학출판사, vol. 2, chap 7.
- [8] A. C. Nayer, L. E. Sanderson, Weiss, and Simon D.D., "Specular surface inspection using structured highlight and Gaussian images", *IEEE Trans. Robotics Automation*, vol. 6, no. 2, pp.

- 108-218, 1999.
- [9] J. H. Kim and H. S. Cho, "Neural network-based inspection of solder joints using a circular illumination", *Image and Vision computing*, vol. 13, pp. 479-490, 1995.
- [10] J. C. Bezdeck, "Pattern recognition with fuzzy objective function algorithm", *Plenum Press*, 1991.
- [11] J. S. Park and J. T. Tou, "A solder joint inspection system for automated printed circuit board manufacturing". *Proc. of Int. Conf. on Robotics and automation*, pp. 1290-1295, 1990.
- [12] H. S. Cho, J. S. Kim, J. H. Kim, "Development of visual inspection machine for solder joint", *KAIST LCA Tech. Report*, 1993.
- [13] H. S. Cho, K. W. Ko, I. S. Joung, "Development of advanced solder joint inspection system for SMC", *KAIST LCA Tech. Report*, 1996.
- [14] K. W. Ko, J. H. Kim, and H. S. Cho, "Solder joints inspection using a circular illumination & fuzzy pattern matching", *ICARCI'96*, pp. 1044-1048, 1996.
- [15] J. H. Kim and H. S. Cho, "Pattern Classification of solder joint images using vector correlation neural network", *J. Engineering Application of Artificial Intelligent*, vol. 9, no. 6, pp. 655-669, 1996.
- [16] Y. K. Ryu and H. S. Cho, "New optical measuring system for solder joint inspection", *Optics and Lasers in Engineering*, vol. 26, no. 6, pp. 487-514, 1997.
- [17] K. W. Ko, H. S. Cho, J. H. Kim, J. S. Kim, S. K. Kim, "Solder joints inspection using neural Network and fuzzy rule-based classification", *IROS 98*, 1998.
- [18] Jacek M. Zurada, "Introduction to artificial neural systems", *West Publishing company*, 1992.
- [19] Yoh-Han Pao, "Adaptive pattern recognition and neural networks", *Addison-Wesley Publishing Company*, 1989.
- [20] Kuk Won Ko and Hyung Suck Cho, "Solder joints inspection using a neural network and Fuzzy Rule-Based Classification Method", *IEEE CPMT (to appear)*



고 국 원

1992년 서울대학교 농기계공학과(농학사). 1994년 한국과학기술원 정밀공학과(공학석사) 1994~현재 한국과학기술원 기계공학과 박사과정재학중. 관심분야는 머신 비전, 시각

검사, 지능 제어.



김 종 형

1984서울대학교 기계공학과(공학사), 1989년 한국과학기술원 생산공학과(공학석사), 1995년 한국과학기술원 기계공학과 박사 ~현재 삼성전자


생산기술센터 수석연구원 관심분야는 머신 비전, 로봇 제어, 시각 지능 검사



조 형 석

1944년생. 1971년 서울대학교 공업교육학과(학사). 1973년 Northwestern Uni. 기계공학과(석사). 1977년 Uni. of California at Berkely (박사). 1978년~현재 한국과학기술원 기계

공학과 교수. 1990년~1983년 IFAC Manufacturing Committee의 부회장. 현재 국제 Journal인 Robotica, Control Engineering Practice와 Advanced Robotics의 편집위원. 주관심분야는 인공지능응용, 비전시스템, 공정 제어, 보로틱스 그리고 조립자동화임.



김 성 권

1949년생. 1972년 동아대 공대 기계공학과(학사). 1986년 Uni. of Minnesota 기계공학과(석사). 1988년 Uni. of Minnesota 기계공학과(박사). 1976년 금성사(주) 근무, 1988

년~현재 삼성전자 생산기술센터 센터장, 부사장. 주관심분야는 보로틱스 및 자동화.