

하이브리드 신경회로망을 이용한 디지털 단층 영상의 BGA 검사

Hybrid Neural Network Based BGA Solder Joint Inspection Using Digital Tomosynthesis

고 국 원, 조 형 석, 김 종 형, 김 형 철

(Kuk Won Ko, Hyung Suck Cho, Jong Hyeong Kim, and Hyung Cheol Kim)

Abstract : In this paper, we described an approach to the automation of visual inspection of BGA solder joint defects of surface mounted components on printed circuit board by using neural network. Inherently, the BGA solder joints are located underneath its own package body, and this induces a difficulty of taking good image of the solder joints by using conventional imaging systems. To acquire the cross-sectional image of BGA solder joint, X-ray cross-sectional imaging method such as laminography and digital tomosynthesis has been currently utilized. However, the cross-sectional image obtained by using laminography or DT methods, has inherent blurring effect and artifact. This problem has been a major obstacle to extract suitable features for classification. To solve this problem, a neural network based classification method is proposed in this paper. The performance of the proposed approach is tested on numerous samples of printed circuit boards and compared with that of human inspector. Experimental results reveal that the proposed method provides satisfactory performance and practical usefulness in BGA solder joint inspection.

Keywords : neural network, solder joint inspection, cross-sectional image, X-ray, BGA, tomosynthesis

I. 서론

최근 들어 전자 기기의 소형 경량화, 고기능화에 따라 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 IC 등의 표면 실장형 부품을 납 접착제(solder paste)를 바른 후 탑재 하여 접착 시키는 방법이다. 현재 많은 전자 제품들 내에 이러한 표면 실장 기술에 의해 조립된 인쇄 회로 기판이 더욱 많은 비중을 갖고 사용되고 있다. 현재 표면 실장 기술은 제품의 소형화에 따라서 사용되는 부품의 크기가 점점 작아지고 있다. 현재 주로 사용되는 SMD부품 중 IC칩은 보통 0.2mm 크기의 약 100~140개의 리드(lead)를 가지고 있다. 그럼에도 불구하고 실장효율을 높이기 위하여 리드가 부품의 아래면에 위치하는 BGA(Ball Grid Array)와 같은 부품의 출연으로 인하여, 현재 사용되고 있는 광 커팅 법, 열전도도를 이용한 방법, 컬러 링 조명 법, 일반 조명을 이용한 방법, 레이저를 이용한 방법 등의 외관 검사 방법의 적용이 불가능하다. 이러한 부품들의 검사의 검사를 위해서는 X-선을 광원으로 하여 부품내부의 영상을 획득하는 방법을 사용하여야 한다.

X-선을 위한 검사 방법은 투과식 방법과 단층식 방법으로 놀 수 있다. 투과식 방법은 단순히 X-선을 투과하여 영

상을 획득 하는 방법으로 최근 널리 사용되고 있는 양면 기판에 적용이 어렵다는 단점이 있다. 반면 단층식 방법은 원하는 위치의 단면을 얻을 수 있으므로 고밀도 인쇄회로 기판의 BGA검사에 적합하다.

X선을 이용한 단층 영상 합성 방법은 크게 라미노그래피(Laminography) 방법과 디지털 영상합성법(digital tomosynthesis) 방법을 사용한다. 본 연구에서는 BGA의 단층 영상을 얻기 위하여 디지털 합성법을 사용하여 납땜부의 단면영상을 획득하고 이 영상을 이용하여 납땜부의 형태를 검사한다. X선을 이용하여 얻은 단층 영상은 선명하지 못하고 흐리므로 일반적인 머신 비전(machine vision)에서 널리 사용하는 이진화 영상을 사용하여 납량을 정량적으로 추출하는 것은 어렵다. 이러한 문제점을 극복하기 위하여 영상의 밝기 프로파일(profile)을 추출하고 이를 learning vector quantization (LVQ) 신경회로망과 단층 신경회로망을 이용하여 납땜의 형태에 따라 분류하는 방법을 제안한다. 제안된 신경회로망을 이용한 검사 방법은 기하학적 특징치를 추출하지 않으므로 선명하지 못한 X-ray 단층 영상을 사용한 검사 방법에 적합하다. 또한, 계측적으로 구성된 신경회로망 검사기는 기존의 자율 학습을 바탕으로 한 LVQ 신경회로망의 문제점을 극복하기 위하여 지도 학습의 단층 신경회로망과 결합하여 보다 정확한 분류 결과를 얻을 수 있다. 제안된 방법의 유용성을 검정하기 위하여 실제 산업 현상에서 생산되는 PCB 기판에서 추출한 BGA의 영상 샘플을 이용하여 BGA 부품의 납땜부를 검사하며 분류 결과를 살펴 보았다.

II. X-선 단층 영상 시스템 구성

1. X-선 단층 영상의 원리

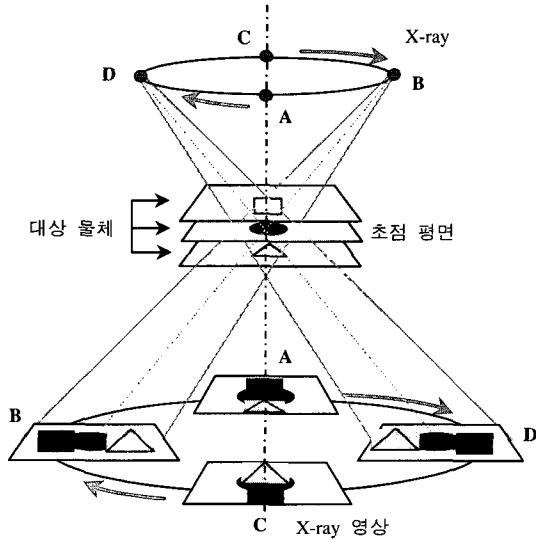
접수일자 : 2000. 3. 7., 수정완료 : 2000. 12. 15.

고국원, 조형석 : 한국과학기술원 기계공학과 (kkw@lca.kaist.ac.kr/
hscho@lca.kaist.ac.kr)

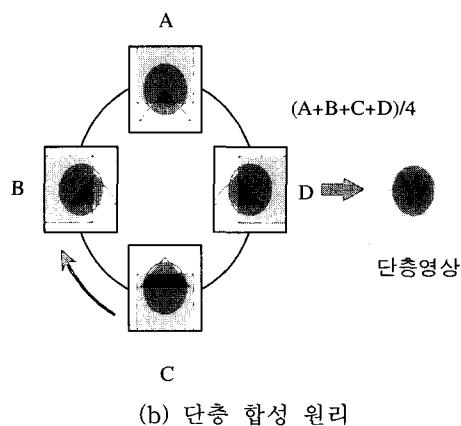
김종형, 김형철 : 삼성전자 생산기술센터(jhkimss@samsung.co.kr/
/whitefay@samsung.co.kr)

※ 본 논문은 삼성전자 지원하에 연구하였습니다.

단층 영상 획득에 사용되는 기본 원리인 라미노그래피 방법은 X선 투사 영상에서, 구하고자 하는 단면이외의 부분에 있는 상을 흐려지게 만들어 특정 단면 형상의 상대적인 선명도(Contrast)를 증가 시켜 주는 방법이다[1].



(a) 라미노그래피에 의한 단층 방법



(b) 단층 합성 원리

그림 1. 라미노그래피의 원리.
Fig. 1. The principle of laminography.

그림 1 (a)는 라미노그래피의 원리에 대하여 나타내었다. 검사 하고자 하는 한 단면에 대하여 일정 각도 기울인 채 중심에 대하여 X선을 회전시키면, 그 면에서 기하학적인 초점 평면이 결정된다. 이때 X선원의 위치와 초점 평면의 중심의 연장선 상에 검출기의 중심이 위치하도록 동기화 시켜 각 방향에서 투과한 X선 영상을 얻게 되면, 초점 평면 상의 형상은 투과 방향에 상관 없이 항상 검출기의 일정한 위치에 상을 맺게 되는 반면 초점 평면 밖의 형상은 투과 방향에 따라 검출기에 상을 맺는 위치가 달라지게 된다. 따라서 이렇게 각 방향에서 얻어진 영상들을 중첩 시키게 되면 초점 평면

상의 형상만이 선명하게 부각되게 된다[1]. 그림 1 (b)는 세 개의 단면에 각기 삼각형, 원형, 사각형의 물체가 있는 경우, 초점 평면상의 물체인 원형에 대한 단층 영상을 구하는 것을 보여주는 것으로써, 각 방향에 대하여 X선 투과 영상을 구하였을 때의 영상들과 이를 영상을 중첩하여 얻은 초점 평면에 대한 단층 영상을 보여 준다. 초점 평면에 있는 원형의 물체는 각 영상에서 위치 이동이 없이 상을 맺지만 나머지 평면상의 삼각형, 사각형은 각기 다른 곳에 상이 맺혀 이를 영상을 중첩시키게 되면 그 영향이 줄어들어 중첩 영상에서는 흐리게 나타난다. 라미노그래피 방식으로 단층을 얻기 위한 시스템으로는 영상 증배판 혹은 형광 스크린과 X선원을 기계적으로 돌려 주며 영상을 받는 방식과 X선원을 기구적으로 움직이지 않고 전기적으로 회전하는 X선원과 회전하는 형광 스크린을 동기시켜 중첩된 영상을 얻는 방식 등이 있다[2].

최근 개발된 SBL(Scanned Beam Laminography)는 X선을 전기적으로 조향하여 빠르게 회전시키고 동시에 형광스크린을 회전시켜 얻어지는 영상들을 회전하는 거울을 통하여 카메라로 상을 맺게 한다. 이러한 방법은 여러 방향의 투사 영상이 광학적 노출을 통하여 중첩되게 되어 라미노그래피의 원리를 구현한다.

2. 단층 영상 시스템 구성

디지털 영상 합성의 원리를 사용하여 단층 영상을 얻기 위한 장치를 다음 그림 2와 같이 구성하였다. 시스템은 반경 35mm이내의 임의의 위치에서 X-ray를 발생시킬 수 있는 스캐닝 X-ray튜브, PCB를 이송할 XYZ 3축 테이블, X-ray영상을 가시화 해주는 영상 증배판, 영상 증배판에서 가장자리에 차례로 맺히는 부분 영상을 취득하기 위한 회전 프리즘 및 줌 카메라로 구성되어 있다.

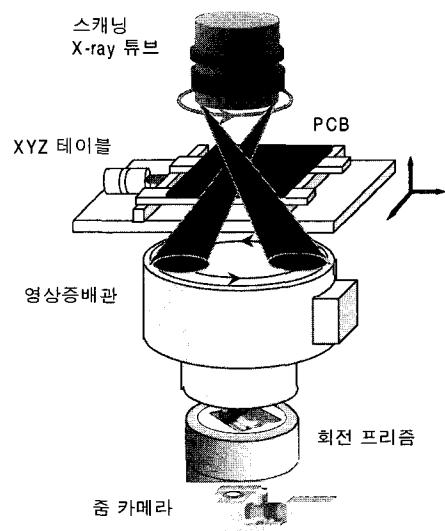


그림 2. 단층 영상 시스템의 구조.

Fig. 2. The cross-sectional X-ray imaging

영상 증배관의 아래 부분에 위치한 회전 프리즘과 줌 카메라(zoom camera)는 서로 다른 방향에서 X-ray를 투사 시켜 얻은 영상들을 취득하기 위한 장치이다. 즉, 그림 2의 시스템에서 X-ray는 일정한 반경으로 8방향으로 순차적으로 발생이 되며, 이때 X-ray의 위치에 대하여 검사 영역(Field of View)은 영상 증배관의 가장자리에 차례로 상을 맺게 된다. 이렇게 영상 증배관 출력면의 가장자리에 위치를 달리하며 맺히는 영상은 전동 줌 카메라와 회전프리즘을 사용하여 출력면의 부분 영상만을 취한다.

단층 영상은 각 8방향의 투과 영상을 얻은 후 앞서 설명한 라미노그라피 방법 또는 디지털 영상 합성과정을 통하여 얻을 수 있다.

3. BGA 단층 영상의 특징

BGA는 구형의 리드 볼(lead ball)의 단층 영상을 그림 3에 나타내었다. 일반적으로 라미노그라피(Lamino-graphy) 방식의 영상에서 초점 평면에 위치한 물체들의 단층 영상이 얻어지지 않고, 초점 평면 밖의 물체에 의하여 단면 영상의 형상이 왜곡되는 가림 현상(Artifact)이 존재하게 된다.

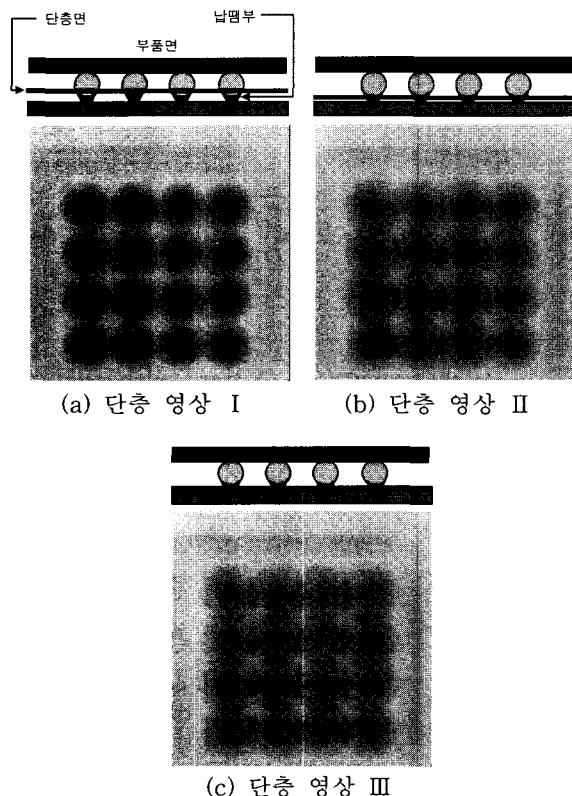


그림 3. BGA 단층 영상.

Fig. 3. The cross-sectional image of BGA.

가림 현상으로 인하여 획득되는 영상에는 초점 평면 밖의 물체에 의한 그림자까지도 포함되어 있으므로, 초점 평면에서의 불량 특성을 추출하는 것이 쉽지 않다. 따라서 일반적인 이진화 처리와 같은 영상으로 BGA

볼의 면적이나 밝기 정보로 납량을 유추하는 것은 어렵다[3]. 단층 영상상에서 추출할 수 있는 신뢰성이 높은 정보는 영상상의 밝기 변화이므로 영상의 밝기 변화와 납량의 관계를 알아낼 수 있도록 분류기를 설계하는 것이 필요하다.

III. BGA 검사를 위한 신경회로망 구조

1. 제안된 신경회로망

본 연구에서 BGA 볼의 납땜부를 검사하기 위해 제안된 신경회로망의 구조는 그림 4에 나타내었다. 제안된 신경회로망은 LVQ 자율 학습 신경회로망과 다층 신경회로망으로 구성되어 있다.

제안된 신경회로망 분류기의 입력으로는 제안된 단층 영상 시스템을 사용하여 획득한 영상의 4 방향(0도, 45도, 90도, 180도)의 밝기 분포 형태(graylevel profile)를 이용하고 있다. 아래 부분에 위치한 LVQ 자율 학습 신경회로망은 다양한 형태의 BGA 영상의 밝기 분포 형태를 몇 개의 대표 패턴의 형태로 분류하기 위하여 사용되었으며 위 부분에 위치한 다층 신경회로망은 LVQ 신경회로망에 의해서 나누어진 결과를 바탕으로 하여 전문가의 분류 지식을 학습하여 분류기로 사용하도록 구성되어 있다.

이러한 두개의 신경회로망을 접목하여 사용한 이유는 널리 사용되고 있는 자율 학습 LVQ 신경회로망과 다층 신경회로망의 단점을 보완하기 위한 것이다.

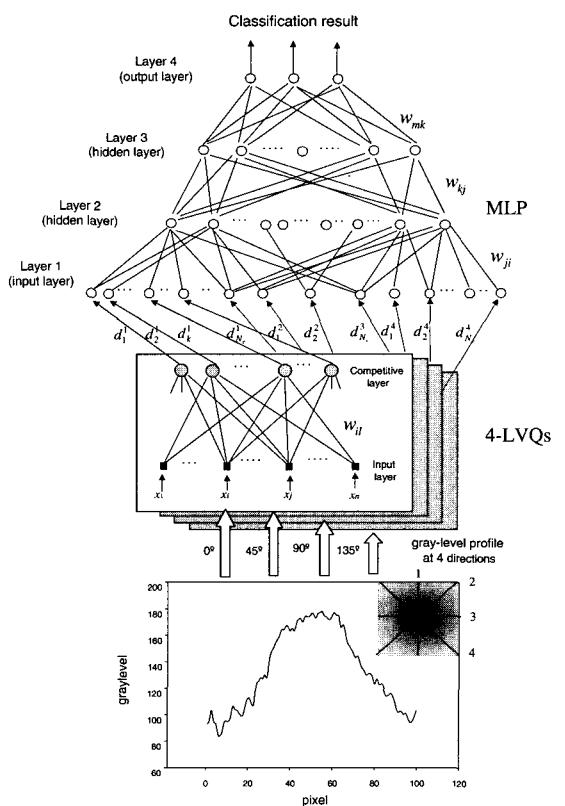


그림 4. 제안된 신경회로망 구조.

Fig. 4. The proposed structure of hybrid neural Network.

자율 학습 신경회로망은 자율적인 학습 방법에 의해 분류 작업을 하므로 원하지 않은 분류 결과를 얻는 경우가 있다. 이러한 방법이 전혀 입력 영상들의 확률 분포를 모르는 경우에 이들의 특성을 살펴보기 위하여 사용되어 질 수 있으나 작업자의 의도와 일치하기 위해서는 많은 실험을 되풀이 해야 한다는 단점이 있다.

이러한 단점을 해결하기 위해서 자율 학습 후 지도 학습을 추가하여 분류 성능을 높이기도 한다. 반면에 다층 신경회로망은 입력과 출력의 상관 관계를 학습 가능하지만, 입력 데이터의 차원이 클 경우 학습 도중 국부 국소에 빠지거나, 학습 효율이 떨어진다는 단점이 있다.

본 연구에서는 제안한 신경회로망의 구조는 자율 학습 신경회로망의 단점을 보완하고 지도 학습 신경회로망이 다차원 패턴에 대해서 학습 효율이 떨어지는 것을 상호 보완하기 위하여 자율 학습 신경회로망을 통하여 비슷한 입력 영상을 모으는 클러스터링 과정으로 입력 영상의 차원을 줄여 다층 신경회로망의 학습 효율을 높이도록 구성하였다.

2. LVQ 자율 학습 신경회로망

다양한 기판의 BGA 부품에서 획득된 X-ray 단층 영상으로부터 구한 단면 형상을 사용하여 검사에 기준이 되는 기준 단면을 구하는 것은 여러 가지 데이터 그룹에서 유사한 패턴 끼리 모으는 군집화((clustering) 기법을 사용하였다. 클러스터링 방법은 LVQ(Learning Vector Quantization) 방법을 사용하였다.

LVQ 신경회로망의 학습 방법은 경쟁 학습(competitive learning) 원리를 기초로 한 승자 독점 원칙(winner takes all)의 학습 철칙으로, 입력이 패턴이 들어 오면 입력 층과 경쟁 층 사이에 연결된 가중치와 입력과 얼마나 가까운 가를 계산하여 거리가 제일 가까운 뉴런이 승자가 되어 학습의 기회를 부여 받는다. 그럼 4과 같이 입력 패턴을 \bar{X} 라 하면 \bar{X} 는 입력 영상의 픽셀 수와 같은 수를 가진다. 경쟁 층에서 i 번째 출력 뉴런을 o_i 라 하면 주어진 입력 패턴 \bar{X} 와 가장 유사한 가중치 벡터 \bar{W}_i 를 가진 뉴런만이 1의 출력을 가지고, 나머지 뉴런은 0의 값을 가진다.

$$O_i = \begin{cases} 1, & \text{if } i = c \text{ such that } \|\bar{X} - \bar{W}_i\| = \min_i \|\bar{X} - \bar{W}_i\| \\ 0, & \text{otherwise} \end{cases}, \quad i = 1, 2, \dots, N_c \quad (1)$$

여기서 N_c 는 신경회로망의 경쟁 층의 출력 뉴런의 개수를 나타내며, 분류하고자 하는 클러스터의 수와 직접적인 관련이 있다.

(1)에서 1의 출력 값을 가지는 경쟁 층의 승자 뉴런에 연결된 가중치 벡터의 학습 규칙은 (2)에 의해서 정신된다.

$$\bar{W}_i(t+1) = \begin{cases} \bar{W}_i(t) + \alpha(t) \cdot (\bar{X}(t) - \bar{W}_i(t)), & \text{if } O_i = 1, i = c \\ \bar{W}_i(t), & \text{otherwise} \end{cases} \quad (2)$$

여기서 $\alpha(t)$ 는 학습 계수로 0에서부터 1의 값을 가지며 반복 횟수가 함께 따라 단조 감소한다. 출력 뉴런에 연결된 가중치 벡터의 학습의 기회는 입력 패턴과 거리를 구하여 제일 거리가 가까운 가중치 벡터를 가진 승자 뉴런에게만 주어진다. 학습이 진행되어 감에 따라서 승자 뉴런에 연결된 가중치 벡터는 점차 유사한 입력 들의 평균으로 학습되어 간다. 학습이 끝난 후의 가중치 벡터는 각 출력 뉴런에 속하는 비슷한 패턴의 평균값과 유사하게 된다. 이때 각 출력 뉴런에 연결된 가중치들은 출력 뉴런이 나타내는 클래스의 대표 영상을 의미하게 되고 이를 프로토 타입 영상(prototype image)이라 한다.

3. 다층 신경회로망 분류기

다층 신경회로망은 4개의 BGA 납땜 부위의 단면 밝기 분포를 사용하여 미리 여러 영상의 밝기 단면을 이용하여 만들어 놓은 기준 패턴을 바탕으로 전문가의 판단 결과를 학습 하도록 구성되었다. 다층 신경회로망은 그림 4에서 보는 바와 같은 구조를 가지고 있으며 여러 개의 노우드로 구성된 몇 개의 층(layer)과 이웃하는 층의 노우드들은 가중치(weight)로 연결되어 있다. 각 노우드는 계산이 이루어 지는 요소에 해당하며 각 가중치는 학습되는 값이다.

첫번째 입력 층을 제외한 노우드의 입력은 그전 층에 있는 노우드의 출력 값에 가중치 값이 곱해진 후 이 값들이 모두 더해진 값이 입력된다. 각 노우드에서는 입력 값과 바이어스의 시그모이드 함수(sigmoid function) 계산이 이루어지고 이 함수의 출력이 곧 노우드의 출력 값이 된다. 그림 4에서 입력 층의 노드의 입력값은 d_i 로 표시하였다. 첫번째 은닉 층의 노우드는 O_p , 두 번째 은닉 층의 노우드는 O_k , 출력 층의 노우드는 O_l 로 나타내었고, 출력 층의 목표 값은 t_j 로 표시하였다.

입력 데이터가 가해지면 입력 층에서는 그 전의 은닉 층이 없으므로 입력 층의 i 번째 노드의 출력은 입력 데이터와 같은 값을 갖는 O_{ip} 이다. 그 후 다음 층의 j 번째 노우드의 실제 입력은 다음과 같이 계산된다.

$$net_j = \sum_i w_{ji} O_i \quad (3)$$

여기서 w_{ji} 는 첫번째 은닉 층(hidden layer)의 j 번째 신경회로망의 분류기의 학습은 다음과 같이 이루어진다. 그림 4에서와 같이 신경회로망의 j 번째 출력 노우드와 입력 층(input layer)의 i 번째 노우드 사이의 가중치 (weight) 값을 나타낸다. 그러면 노우드 j 의 출력은 다음과 같은 시그모이드 함수로 표시되며, 여기서 θ_j 는 노우드 j 의 바이어스(bias) 값이다.

$$O_j = f_j(net_j) = \frac{1}{1 + \exp[-(net_j + \theta_j)]} \quad (4)$$

다층 신경회로망의 학습에는 오차 역 전파법(error back-propagation)을 사용하여 학습한다. (5)와 같이 오차를 정의한다. 이때

$$E_p = \frac{1}{2} \sum_p (t_p - o_p) \quad (5)$$

여기서 t_p 는 지도 패턴을 의미하고 o_p 는 신경회로망의 출력을 의미한다. 아랫첨자 p 는 학습 패턴을 의미한다. 전체 입력 패턴에 대한 평균 오차는 (6)과 같다.

$$E_p = \frac{1}{2P} \sum_p (t_p - o_p)^2 \quad (6)$$

여기서 P 는 전체 학습 패턴의 개수를 의미한다.

이제 학습을 위해서 각 노우드에 연결된 가중치 값의 학습은 (8)에 의해서 이루어진다. (8)은 (7)의 오차를 줄이는 방향으로 가중치의 학습이 이루어 지도록 되어 있다.

$$\Delta w_{ji}(n+1) = \eta \cdot \delta_j \cdot o_i + \alpha_w \Delta w_{ji}(n) \quad (7)$$

여기서 η 는 학습 계수이며, α_w 는 모우먼터(momentum rate)이며, n 은 학습 횟수를 나타낸다.

출력 층의 노우드에 대한 오차 신호 δ_m 는 다음과 같이 구해진다.

$$\delta_m = (t_m - o_m) f'_m(\text{net}_m) \quad (8)$$

여기서 t_m 은 노우드 m 의 target output, and $f'_m(\text{net}_m)$ 은 net_m 에 대하여 $f_m(\text{net}_m)$ 을 편미분한 값을 의미한다. 두번째 은닉층의 k 번째 노우드의 오차 신호 δ_k 는 다음과 같이 주어진다.

$$\delta_k = f'_k(\text{net}_k) \delta_m w_{mk} \quad (9)$$

여기서 δ_m 은 (9)에 의한 값이다. 전체적인 학습 과정은 (7)과 같은 과정을 통하여 반복적인 방법으로 수행된다.

다층 신경회로망의 입력으로는 (11)과 같이 결정되어지는 LVQ 분류기의 가중치와 입력 패턴과의 유 кл리디안 거리를 사용한다. 이때 a 방향의 b번째 가중치의 유 кл리디안 거리 d_a^b 는 다음과 같이 표현된다.

$$d_a^b = \|\bar{X} - \bar{W}_a^b\| \quad (10)$$

다층 신경회로망의 최종입력은 다음 (12)와 같다.

$$[d_1^1, d_2^1, \dots, d_r^1; d_1^2, d_2^2, \dots, d_r^2; d_1^3, d_2^3, \dots, d_r^3; d_1^4, d_2^4, \dots, d_r^4] \quad (11)$$

위 입력에 해당되는 출력 뉴런의 지도 패턴은 BGA 볼 납땜부의 검사 형태에 따라 (12)와 같이 나누어진다.

[1, 0, 0] : insufficient soldering quality

[0, 1, 0] : acceptable soldering quality (12)

[0, 0, 1] : excess soldering quality

다층 신경회로망의 학습으로는 널리 사용되고 있는 오차 역 전파법(error back propagation)을 사용하였다. 오차 역 전파법[6]은 주어진 입력 패턴에 대한 신경회로망의 출력과 미리 주어진 출력과의 오차를 줄이도록 신경회로망의 가중치를 수정하는 방법으로 미리 정의된 에너지 함수를 최소화 하도록 구성이 되어있다.

IV. 실험 및 토의

1. 실험 영상 데이터

분류 실험을 위해서 실제 산업체에서 생산한 5장의 기판에서 추출한 220개의 BGA 납땜부의 영상 데이터 중에 160개의 영상 데이터를 사용하였다. 나머지 60개의 영상 데이터는 구성된 본 연구에서 제안한 신경회로망의 성능을 평가하기 위하여 사용하였다. 수집한 납땜부의 영상 데이터는, 경험이 풍부한 검사자들에 의해

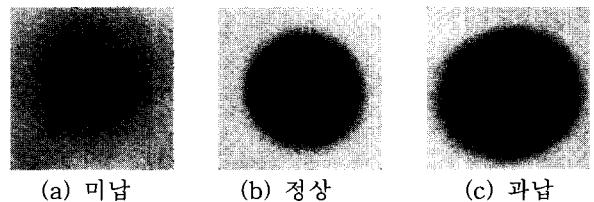


그림 5. 학습 영상. Fig. 5. Training images.

납량에 따라 미납(I), 정상(A), 과납(E)의 3개의 클래스로 구분하였다. 신경회로망의 학습 영상은 100 x 100화소(pixel)의 크기로 구성되었다. 학습 영상을 중에서 대표적인 영상을 그림 5에 나타내었다.

2. LVQ 신경회로망의 학습

LVQ 자율 학습 신경회로망의 학습을 위해서 그림 4와 같이 획득한 영상의 4 방향의 밝기 분포 형태(graylevel profile)를 먼저 추출한다. 이때 입력 패턴의 형태는 180개의 화소로 구성되어 있는 1차원 배열이며 신경회로망의 입력으로는 각 화소 배열의 크기와 동일한 180개의 노우드를 가진다. 경쟁층에 속해 있는 출력 노우드의 수는 분류하고자 하는 클러스터의 수와 동일하도록 설정한다.

표 1. 분류 클래스의 수에 따른 분류 오차.

Table. 1. The classification errors of different number of neuron.

Number of neuron	Clustering error
5	34.3%
6	10.1%
7	4.5%
8	9.8%
9	8.1%

LVQ 신경회로망은 BGA 볼에서 획득한 단면 영상에서 추출한 다양한 밝기 분포들 중에서 비슷한 패턴끼리 모으는 클러스팅 역할을 하며 이때 신경회로망의 가중치 값은 클러스터를 대표하는 프로토 타입 패턴이 된다.

분류하고자 하는 최적 클러스터의 수는 실험으로 구하였다. 최적의 클러스터의 수를 구하기 위한 여러 가지 방법들이 제안되었지만, 본 연구에서는 최적의 클러스터 수는 신경회로망의 학습 후 최소 클러스팅 오차를 가지

는 클래스의 수를 최적 클러스터의 수로 정의하였다. 분류하고자 하는 클래스의 수를 바꾸어 학습 후 분류

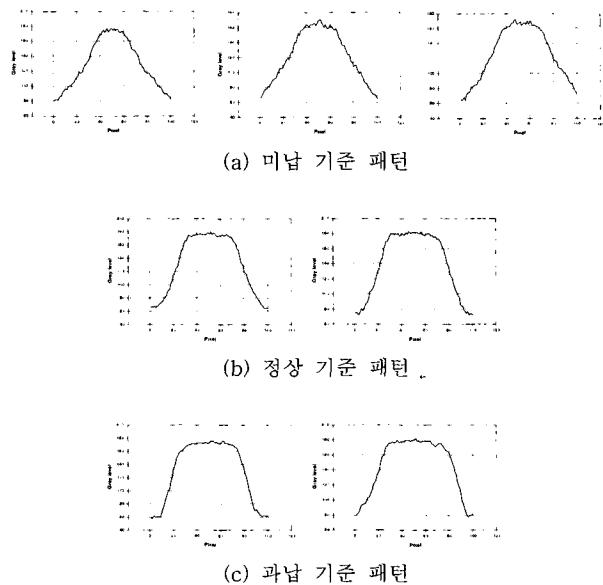


그림 6. LVQ 신경회로망의 학습 결과.

Fig. 6. The prototypes obtained by an LVQ.

실험 결과를 표 1에 나타내었다. 표 1에서 볼 수 있듯이 7개로 분류할 때 최소 분류 오차를 얻었으며 이때 최종적으로 LVQ 알고리즘을 통하여 생성된 기준 패턴은 그림 6과 같다.

3. 다층 신경회로망의 학습

다층 신경회로망은 은닉 층과 뉴런의 수에 따라 다른 분류 성능을 가진다. 그러므로 서로 수의 은닉 층과 뉴런의 수를 가지는 신경회로망을 사용하여 실험한 학습 결과를 그림 7에 나타내었다. 그림 7에서 나타나듯이 20개의 첫째 은닉층의 뉴런과 20개의 두번째 은닉층의 뉴런의 구조를 가지는 신경회로망이 최소의 오차를 가졌다.

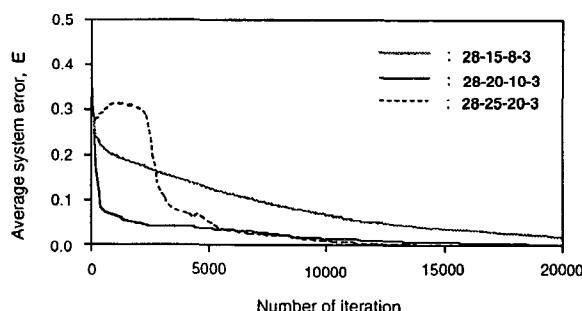


그림 7. 다양한 신경회로망 구조에 따른 학습 결과.

Fig. 7. The learning errors obtained by different Structures.

4. BGA 볼 납땜 분류 실험

LVQ 자율 학습 신경회로망과 다층 신경회로망의 학습 후 분류 결과를 살펴 보기 위하여 학습에 사용한 영상들에 대한 분류 실험 결과를 표 2에 나타내었다. 160개의 납땜 단층 영상에 대하여 분류 결과는 약 99.88%이다. 미납 영상 중 하나 만이 정상으로 분류되었다. 이 영상의 경우에는 정상과 비슷한 모습을 가져 정상에 가까운 미납의 형태를 가지고 있었다.

표 2. 학습 패턴에 대한 분류 결과.

Table 2. The classification result of learning patterns.

Q	NS	I	A	E	NC
I	64	64	1		1
A	50		50		0
E	46			46	0
Total		success	rate	: 1-1/160 =	
0.99375(99.375%)					

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

반면에 학습에 사용되지 않는 60개의 BGA 볼의 납땜 단층 영상에 대한 실험 결과를 표 3에 나타내었다. 전체 60개의 패턴 중에서 1개의 미납 볼이 정상으로 판정이 되었으며, 2개의 정상 납 볼이 미납으로 판정이 되었다. 결과적으로 전체 분류 결과는 95%이었다.

그러나, 실제 납땜 검사에서는 정상을 불량으로 판정되는 비율보다, 불량을 정상으로 판정하는 일은 가능한 적어야 한다. 이러한 이유는 불량으로 판정된 납 볼의 경우, 작업자에 재 검사의 기회를 가지므로 2차 검사에서 수정될 확률이 높지만, 불량을 정상으로 판정될 경우에는 이러한 기회가 없어 불량의 가능성성이 높아진다.

이러한 분류 오차는 분류 결과를 미납, 미납 정상, 정상, 과납 정상, 과납의 5개의 패턴으로 분류한다면 미납과 정상의 경계 부분에 위치한 볼들은 미납 정상으로 분류되어 보다 높은 분류 결과를 얻을 수 있을 것으로 기대된다.

표 3. 학습에 사용되지 않은 패턴에 대한 분류 결과.

Table 3. The classification result of test patterns.

Q	NS	I	A	E	NC
I	17	16	1		1
A	21	2	19		2
E	22			22	0
Total success rate : 1-3/60 = 0.95(95%)					

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

5. 비교 연구

제안된 신경회로망 분류기의 성능을 살펴보기 위하여 기

존 LVQ-II 신경회로망과 다층 신경회로망을 사용한 결과와 비교 연구를 수행하였다.

LVQ-II 신경회로망으로 단층 BGA 볼 납땜 영상을 학습하여 분류하기 위한 구조는 그림8과 같이 100×100 의 2차원 구조로 되어 있으며 최적의 클래스 수를 구하기 위하여 앞서 실험한 방법과 같이 뉴런의 수를 바꾸어 가면서 최소의 분류 오차를 가지는 구조를 선택하였다.

최종적으로 구한 수는 입력 뉴런의 수는 100×100 이며 경쟁 층의 출력 뉴런의 수는 8개이다. 학습 후 LVQ-II 신경회로망은 재 학습 과정을 거쳐서 경계를

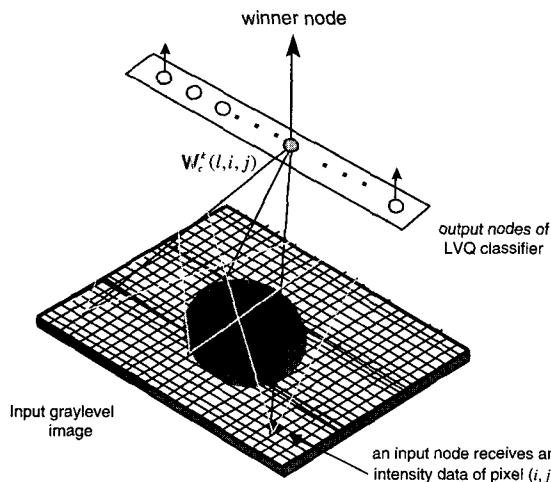


그림 8. LVQ-II 신경회로망 분류기 구조.

Fig. 8. The structure of LVQ-II neural network Classifier.

재 조정과정을 거쳐 분류 성능을 높인다. 표 4는 LVQ-II 신경회로망을 사용하여 160개의 BGA 볼 영상을 사용한 학습 결과와 학습에 사용되지 않은 60개 영상을 이용한 분류한 결과를 나타내고 있다.

표 4에 나타난 바와 같이 학습에 사용한 영상의 분류 결과는 약 93.6%의 분류 결과를 가지며, 학습에 사용되지 않은 영상의 분류 결과는 85%이였다. LVQ-II 신경회로망의 경우 자율 학습 후 지도 학습 과정을 거치지만, 제안한 신경회로망에 비하여 낮은 분류 결과를 나타낸다.

표 4. LVQ-II를 이용한 BGA 볼 영상 분류 결과.
Table 4. The classification results by the LVQ-II.

(a) 학습 패턴에 대한 분류 결과					
Q	NS	I	A	E	NC
I	64	59	5	5	
A	50	2	46	2	4
E	46		1	45	1
Total			success rate	:	$1 - 10/160 = 0.9357(93.57\%)$

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

(b) 학습에 사용되지 않은 패턴에 대한 분류 결과

Q	NS	I	A	E	NC
I	17	14	3		3
A	21	4	17		4
E	22		2	20	2
Total success rate : $1 - 9/60 = 0.85(85\%)$					

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

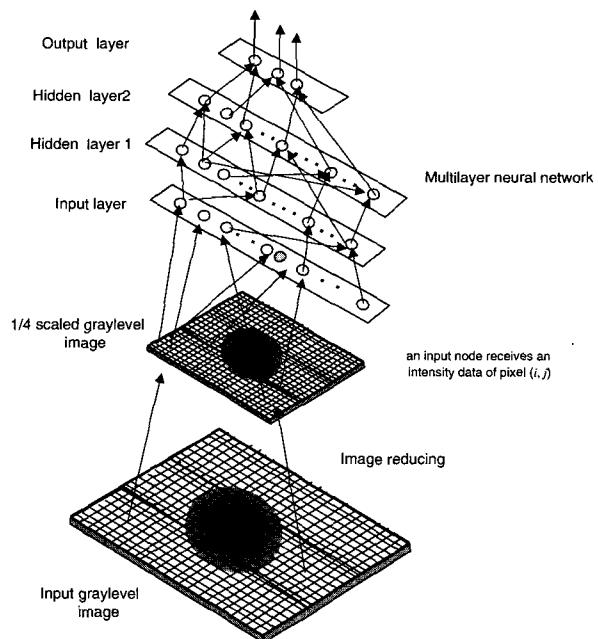


그림 9. 다층 신경회로망 분류기 구조.

Fig. 9. The structure of a MLP neural classifier.

이러한 이유는 LVQ 신경회로망의 분류 경계는 선형 경계를 가지므로, 다양하고 복잡한 패턴의 분류에 어려움이 있다. 그러므로, 학습에 사용하지 않은 패턴의 경우에도 납땜의 분류 클래스의 경계 부분에 위치한 패턴들의 분류 성능이 떨어지기 때문에 비교적 낮은 분류 결과를 보인다.

다층 신경회로망을 사용하여 패턴을 분류하기 위해서는 그림 9와 같은 구조의 다층 신경회로망을 사용하여 160개의 BGA 볼 영상을 사용한 학습 결과와 학습에 사용되지 않은 60개 영상을 이용한 분류하였다.

신경회로망의 입력으로는 100×100 영상을 25×25 으로 축소한 영상의 각 화소(pixel)의 밝기 값을 사용하였다.

신경회로망의 최적의 구조를 구하기 위하여 은닉 층의 수와 은닉 층의 뉴런의 수를 바꾸어 가면서 실험을 하였다. 은닉 층이 1개이고 뉴런의 수가 40개 이하일 경우에는 수렴이 되지 않았다. 따라서 은닉 층의 수를 2개로 제한하고 뉴런의 수를 각각 10씩 증가 시킨 후 구한 최적의 구조는 첫번째 은닉 층의 뉴런의 개수는 80개, 두 번째 은닉 층의 개수는 40개였다. 이때 학습 패턴의 분류 결과와 학습에 사용하지 않은 패턴의 분류 결과를 표 5에 나타내었다.

표 5. 다층 신경회로망을 이용한 분류 결과.
Table 5. The classification results by the MLP.

(a) 학습 패턴에 대한 분류 결과

Q	NS	I	A	E	NC
I	64	61	3		3
A	50	2	48	1	3
E	46		2	44	2
Total success rate : 1-8/160 = 0.95(95%)					

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

(b) 학습에 사용되지 않은 패턴에 대한 분류 결과

Q	NS	I	A	E	NC
I	17	15	2		2
A	21	3	17	1	4
E	22		1	20	1
Total success rate : 1-7/60 = 0.8833(88.33%)					

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

표 5의 결과에서 다층 신경회로망은 학습 패턴에 대해서 95%의 분류 결과를 얻었으며, 학습에 사용되지 않은 테스트 패턴에 대해서는 88.33%의 분류 결과를 얻었다. 학습 영상에 대해서는 만족할 만한 분류 결과를 얻었지만, 테스트 영상에 대해서는 비교적 낮은 분류 결과를 얻었다. 다층 신경회로망은 비선형 경계의 특성을 갖지만, 입력 패턴의 차원이 클 경우 비록 학습 도중에 오차는 줄어듦에도 불구하고, 패턴들의 경계 부분의 오차는 줄어들지 않는 경우가 있다. 이러한 현상은 신경회로망이 학습에 의해서 클래스의 비선형 경계 부분을 생성할 때 경계 부분이 overfit 또는 underfit 되는 현상으로 인한 것이다[10]. 다층 신경회로망은 비선형 분류기로써 널리 사용되고 있지만, 영상과 같은 차원이 큰 패턴의 분류에 학습의 효율성이 떨어져, 복잡한 영상 패턴의 적용이 쉽지 않다.

V. 결론

본 연구에서는 기존의 시각검사로 불가능한 BGA 볼의 납땜 검사를 위해서 X선 단층 시스템을 사용하여 단층 영상을 획득하고, 단층 영상으로 납땜 부의 질을 검사하기 적합한 신경회로망 분류기를 설계하고 이를 이용하여, 실제 수집된 여러 납땜 패턴에 대해서 분류 실험을 하였다.

BGA 부품의 납땜 검사 작업은 X-ray 단층 영상을 사용하므로 납땜부의 영상이 흐리므로, 이러한 영상 특징을 잘 이용할 수 있는 분류기의 개발이 필요하다.

본 연구에서는 X-ray 단층 영상에 적합한 신경회로망 분류기의 구조를 개발하여, 여러 가지 BGA 납땜부의 영상의 분류에 적용을 하였다. 제안된 신경회로망은

자율학습 신경회로망과 지도학습 신경회로망의 구조적 으로 결합하여, 자율 학습 분류기의 단점인 스스로 분류된 클래스의 결과가 검사 목적이나 검사자의 의도와 항상 일치하지 않는 점과 지도 학습 다층 신경회로망의 입력 패턴의 차원이 클 때 생기는 학습 효율 저하의 문제점을 상호 보완하였다.

비교 연구에서 살펴 본 바와 같이 자율 학습 신경회로망만을 사용했을 경우에 비하여 높은 분류 결과를 보였으며, 다층 신경회로망만 사용했을 경우에 비하여 간단한 구조와 빠른 학습 결과와 우수한 분류 결과를 얻을 수 있었다.

본 연구에서 제안한 자율 학습 신경회로망과 지도학습 신경회로망의 결합은 각 신경회로망의 단점을 보완하고 장점을 살려서 빠른 학습 시간과 적은 구조로 인하여 높은 분류 결과를 얻을 수 있었다.

향후 자율 학습 신경회로망 구조와 다층 신경회로망의 구조를 함께 최적화 하는 방법이 개발되어 있지 않아 수동으로 적합한 구조를 찾아야 한다는 단점이 있다. 이를 해결하기 위해서 현재 LVQ와 다층 신경회로망의 결합된 형태로 구조를 최적화 하는 기법에 대한 연구가 진행되고 있다.

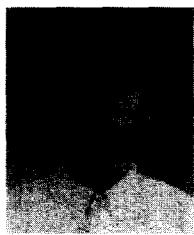
참고문헌

- [1] A. E. M. Bocage, "Laminographic imaging system for high energy radiation", French Patent 536464(1922).
- [2] Adams, "X-ray laminography analysis of ultra fine pitch solder connections on ultra-thin boards", *Integrated Circuit Metrology, Inspection, and Process Control V (SPIE)* vol. 1464. pp. 484-497. 1991.
- [3] M. Rooks, B. Benhabib, and K. C. Smith, "Development of an inspection process for ball-grid-array technology using scanned beam x-ray laminography", *IEEE trans. on Components, Packing, and Manufacturing Technology - Part A* vol. 18, no. 4, pp. 851-861. December, 1995.
- [4] Black, D. L. Millard, and K. Nilson, "An animated interface for x-ray laminographic inspection of fine-pitch interconnect", *IEMT Symposium 1991*, pp. 207-211.
- [5] Jacek M. Zurada, "Introduction to artificial neural systems", West Publishing company, 1992.
- [6] Y. Linde, et al., "An algorithm for vector quantizer design", *IEEE Trans. On Communication*, vol. com-28, no. 1, pp. 84-95, 1990.
- [7] Y. H. Pao, "Adaptive pattern recognition and neural networks", Addison-Wesley, pp. 269-330, 1989.
- [8] D. H. Ballard, "Computer vision", Prentice Hall,

- 1985.
- [9] Jurgen Schurmann, "Pattern classification : A unified view of statistical and neural approaches", A Wiley-Interscience Publication, 1996.
- [10] R. P. Lippmann, "Pattern classification using neural networks", IEEE, 1989.
- [11] 노영준, 조형석, 김형철, "디지털 영상 합성에 의한

X-선 단층 영상의 형상 정확도와 선명도 분석", 제어·자동화·시스템공학논문지, vol. 5, no. 5, pp. 558-567, 1999.

- [12] Kuk Won Ko, Young Jun Roh., and Hyung Suck Cho, "A neural network approach to the inspection of ball grid array solder joints on printed circuit boards", IJCNN, 2000.



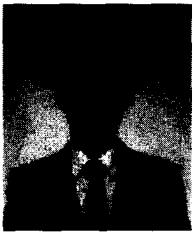
고 국 원

1992년 서울대학교 농기계공학과 (농학사), 1994년 한국과학기술원 정밀공학과(공학석사) 1994~현재 한국과학기술원 기계공학과 박사 과정 재학중. 관심분야는 머신비전, 시각검사, 지능제어.



조 형 석

1944년생. 1971년 서울대학교 공업 교육학과(학사). 1973년 Northwestern Uni. 기계공학과(석사). 1977년 Uni. Of California at Berkely(박사). 1978년~현재 한국과학기술원 기계공학과 교수. 1990년~1983년 IFAC Manufacturing Committee의 부회장. 현재 국제 Jourinal인 Robotica, Control Engineering Practice와 Advanced Robotics의 편집위원. 주 관심분야는 인공지능응용, 비전시스템, 공정제어, 로보틱스, 조립자동화임.



김 종 형인

1984년 서울대학교 기계공학과(공학사), 1989년 한국과학기술원 생산공학과(공학석사), 1995년 한국과학기술원 기계공학과 박사, ~현재 삼성전자 생산기술센터 수석연구원 관심분야는 머신비전, 로봇제어, 시각 지능검사.



김 형 철

1988년 한양대학교 전자공학과 졸업 (공학사), 1999년 아주대학교 졸업, 대학원 정보전자공학자 졸업, 현재 삼성전자 책임 연구원. 관심 분야는 지능형 검사 자동화, X-ray 디지털 토모신세스.