

◆특집◆ 지능형 Machine Vision 응용

신경회로망을 이용한 BGA 납땜 형상 분류

김종형*, 고국원**, 조형석***

Neural Network Based BGA Solder Joint Classification

Jong Hyeong Kim*, Kuk Won Ko** and Hyung Suck Cho***

Key Words : neural network(신경회로망), solder joint inspection(납땜검사), cross-sectional image(단층 영상), X-ray, BGA(Ball Grid Array), tomosynthesis(영상 합성법)

1. 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 접착시키는 방법이다. 표면 실장 기술은 제품의 소형화에 따라서 사용되는 부품의 크기가 점점 작아지고 있으며, 최근 실장효율을 높이기 위하여 납땜부가 부품의 아래면에 위치하는 BGA(ball grid array) 부품의 출현으로 인하여 현재 사용되고 있는 컬러 링 조명과 레이저를 이용한 방법 등의 외관 검사 방법은 최근 실장 효율을 높이기 위해 개발된 부품들의 적용이 불가능 하다.

이러한 표면 실장 부품의 검사를 위해서는 X-선을 광원으로 하여 부품 내부의 영상을 획득하는 방법을 사용하여야 한다.

X-선을 위한 검사 방법은 투과식 방법과 단층식 방법으로 늘 수 있으며, 투과식 방법은 단순히 X 선을 투과하여 영상을 획득 하는 방법이며, 단층식 방법은 원하는 위치의 단면을 얻을 수 있으므로 고밀도 인쇄회로기판의 BGA 검사에 적합하다.[1-4]

X 선을 이용한 단층 영상 합성 방법은 크게 라미노그래피(Laminography) 방법과 디지털 영상 합성법(digital tomosynthesis)방법이 있다.. 본 연구에서는 BGA 의 단층 영상을 얻기 위하여 디지털 합성법을 사용하여 납땜부의 단면영상을 획득하고 이 영상을 이용하여 납땜부의 형태를 검사하였다. X 선을 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 다층 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, 계층적으로 구성된 신경회로망 검사기는 기존의 자

* 서울 산업대학교 기계설계자동화공학부

Tel. 02-970-6357, Fax. 02-974-8270

Email : johnkim@snut.ac.kr

** 선문대학교 기계 및 제어공학부

Tel. 041-530-2348, Fax. 041-530-2981

Email kuks2309@sunmoon.ac.kr

*** 한국과학기술원 기계공학과

Tel. 042-869-3213, Fax. 042-869-3289


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

을 학습을 바탕으로 한 LVQ 신경회로망의 문제점을 극복하기 위하여 지도 학습의 다층 신경회로망과 결합하여 보다 정확한 분류 결과를 얻을 수 있다. 제안된 방법의 유용성을 검증하기 위하여 실제 산업 현장에서 생산되는 PCB 기판에서 추출한 BGA 의 영상 샘플을 이용하여 BGA 부품의 납땜부를 검사하며 분류 결과를 살펴 보았다.


2. X 선 단층영상 시스템

2.1 단층 영상 시스템 원리

단층 영상 획득에 사용되는 기본 원리인 라미노그래피 방법은 X 선 투사 영상에서, 구하고자 하는 단면이외의 부분에 있는 상을 흐려지게 만들어 특정 단면 형상의 상대적인 선명도(Contrast)를 증가 시켜 주는 방법이다[5].



(a) The principle of Laminography



(b) The image of Laminography

Fig. 1 The principle of Laminography

그림 1(a)는 라미노그래피의 원리를 설명하는 그림으로 검사 하고자 하는 한 단면에 대하여 일정 각도 기울인 채 중심에 대하여 X 선을 회전시키면, 그 면에서 기하학적인 초점 평면이 결정된다. 이때 X 선원의 위치와 초점 평면의 중심의 연


장선 상에 검출기의 중심이 위치하도록 동기화 시켜 각 방향에서 투과한 X 선 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 평면상의 형상만이 선명하게 부각되게 된다.[1]

그림 1(b)는 라미노그래피의 원리에 의하여 세 개의 단면에 각기 삼각형, 원형, 사각형의 물체가 있는 경우, 초점 평면에 있는 원형의 물체는 각 영상에서 위치 이동이 없이 상을 맺지만 나머지 평면상의 삼각형, 사각형은 각기 다른 곳에 상이 맺혀 이들 영상을 중첩 시키게 되면 그 영향이 줄어들어 중첩 영상에서는 나타나지 않게 된다. 라미노그래피 방식으로 단층을 얻기 위한 시스템으로는 영상 증배관 혹은 형광 스크린과 X 선원을 기계적으로 돌려 주며 영상을 받는 방식과 X 선원을 기구적으로 움직이지 않고 전기적으로 회전 하는 X 선원과 회전 하는 형광 스크린을 동기시켜 중첩된 영상을 얻는 방식 등이 있다.[5]


디지털 영상 합성의 원리를 사용하여 단층 영상을 얻기 위한 장치를 다음 그림 2 와 같이 구성하였다. 시스템은 반경 35mm 이내의 임의의 위치에서 X-ray 를 발생시킬 수 있는 스캐닝 X-ray 튜브, PCB 를 이송할 XYZ 3축 테이블, X-ray 영상을 가시화 해주는 영상 증배관, 영상 증배관에서 가장자리에 차례로 맺히는 부분 영상을 취득하기 위한 회전 프리즘 및 줌 카메라로 구성되어 있다.

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 8 방향의 투과 영상을 얻은 후 앞서 설명한 라미노그래피 방법 또는 디지털 영상 합성과정을 통하여 얻을 수 있다.



(a) structure of X-ray system



(b) X-ray system

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

2.2 BGA 단층 영상 특징

BGA는 구형의 리드 볼(lead ball) 아래에 납땜부가 위치하므로 외관 검사가 불가능할 뿐 아니라, 투과형 X선 영상에서 납땜부는 리드 볼에 가려 납땜 부위에 대한 정보를 얻기가 쉽지 않다. 따라서, 디지털 영상합성의 방법으로 납땜 부에 대한 X선 단층 영상을 얻음으로써 납땜의 상태를 검사하는 것이 검사의 신뢰성을 높일 수 있는 방법이다. 그러나, 일반적으로 라미노그래피(Laminography) 방식의 영상에서 초점 평면에 대

한 영상만이 얻어지지 않고, 초점 평면 밖의 물체에 의하여 단면 영상의 형상이 왜곡되는 가림 현상(Artifact)이 존재하게 된다. 또한 초점 평면에서 얻어지는 영상은 초점 평면에서 물체의 단층에서의 단면만 아니라 초점 평면 밖의 물체에 의한 그림자까지도 포함되어 있다. 따라서, 초점평면에 나타나는 영상에서 불량 특징을 추출하는 것이 쉬운 일은 아니며, 위에서 말한 초점 평면 밖의 물체에 의한 가림 현상의 차이까지 고려하여야 한다.[1]

획득된 단층 영상에 나타나는 기하학적 특징치가 정확히 단층 영상의 형상을 나타내지 못하므로 납땜 불량에서 나타나는 기하학적 특징치를 대변할 수 있는 단층 영상의 특징을 찾기 위한 연구가 반드시 필요하다.[1-4]

3. BGA 납땜 검사를 위한 신경회로망

3.1 신경회로망 구조

초점 평면에서 얻어지는 X-선 단층 영상은 초점 평면에서 물체의 단층에서의 단면과 초점 평면 밖의 물체에 의한 가림 현상에 의한 그림자가 포함되어 있다. 획득된 단층 영상에 나타나는 기하학적 특징치가 정확히 단층 영상의 형상을 대변하지 못하므로 불량에서 나타나는 기하학적 특징치와 단층 영상의 특징치와 정확한 관계를 구하기는 어렵다.

본 연구에서는 영상상의 특징치와 BGA 볼 납땜부의 정량적으로 구하기 힘든 연관성을 알아내기 위하여 신경회로망을 적용하였다. 신경회로망은 입력과 출력에 해당되는 데이터가 주어지면 이러한 입출력간의 상관 관계를 학습 할 수 있으며 학습된 신경회로망은 학습에 사용되지 않은 데이터나 노이즈(noise)가 포함된 데이터라 하더라도 그에 해당하는 적절한 출력을 나타내는 능력이 있으며 일단 학습이 되면 기존의 방법에 비해 비교적 빨리 입력에 해당되는 출력을 생성시킬 수 있다는 장점이 있다.

본 연구에서 BGA 볼의 납땜부를 검사하기 위해 제안된 신경회로망의 구조는 그림 3에 나타내었다. 제안된 신경회로망은 단층 자율 학습 분류 신경회로망과 다층 신경회로망으로 구성되어 있으며, 입력으로는 단층 영상 시스템을 사용하여 획득한 영상의 4방향의 밝기 분포 형태(graylevel profile)를 이용하고

있다. 아래 부분에 위치한 자율 학습 군집화 신경 회로망은 다양한 형태의 BGA 영상의 밝기 분포 형태를 몇 개의 대표 패턴의 형태로 분류하기 위하여 사용되었으며 위 부분에 위치한 다층 신경회로망은 군집화 신경회로망에 의해서 나누어진 결과를 바탕으로 하여 전문가의 분류 지식을 학습하여 분류기로 사용하도록 구성되어 있다.

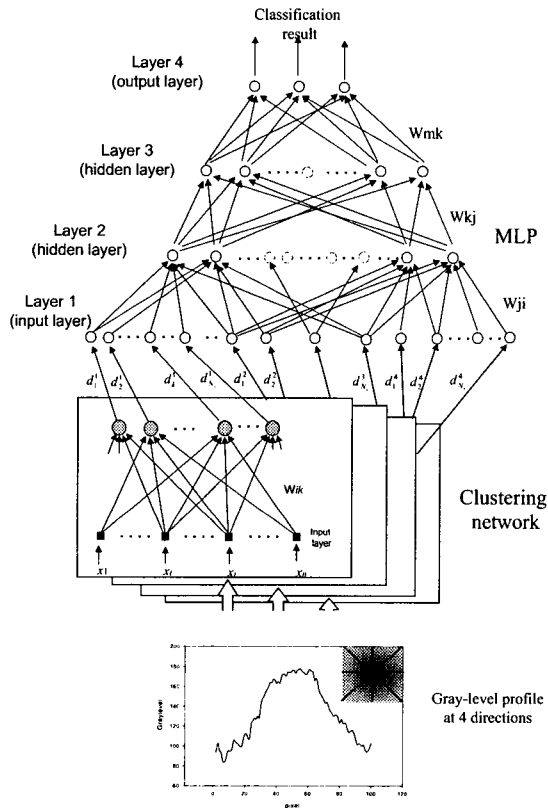


Fig. 3 Proposed neural network structure

이러한 두개의 신경회로망을 접목하여 사용한 이 유는 널리 사용되고 있는 자율 학습 군집화 신경회로망과 다층 신경회로망의 단점을 보완하기 위한 것이다.

자율 학습 신경회로망은 자율적인 학습방법에 의해서 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 되풀

이 해야 한다는 단점이 있다. 이러한 문제점을 해결하기 위해서 자율 학습 후 지도 학습을 추가하여 분류 성능을 높이기도 한다. 반면에 다층 신경회로망은 입력과 출력의 상관 관계를 학습가능하지만, 입력 데이터의 차원이 클 경우 학습 도중 국부 국소에 빠지거나, 학습 효율이 떨어진다.

이러한 문제점은 입력 영상을 자율 학습에 지도 학습을 추가하여 자율 학습의 문제점을 보완하고, 자율 학습 신경회로망의 학습을 통하여 비슷한 입력 영상을 모으는 클러스터링 과정을 통하여 입력 영상의 차원을 줄여 다층 신경회로망의 학습 효율을 높이는 역할을 한다. [6-8]

3.2 자율 학습 신경회로망

다양한 기관의 BGA 부품에서 획득된 X-ray 단층 영상으로부터 구한 단면 형상을 사용하여 검사에 기준이 되는 기준 단면을 구하는 것은 여러 가지 데이터 그룹에서 유사한 패턴끼리 모으는 클러스터링(clustering) 기법을 사용하였다.

4 방향의 영상의 밝기 값의 입력의 순서를 $\vec{X}^j = \{x_1, x_2, \dots, x_{120}\}$ 이라고 하고 신경회로망의 가중치를 \vec{w} 라 하고 각 클래스의 가중치의 학습은 식(1) 의해서 수행되며, 신경회로망의 가중치 벡터의 학습의 기회는 입력 패턴과 거리를 구하여 제일 거리가 가까운 가중치 벡터에 대해서 학습이 이루어진다.

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

학습이 진행되어 감에 따라서 가중치는 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.

3.3 다층 신경회로망 분류기

다층 신경회로망은 4개의 BGA 납땜 부의 단면 밝기 분포를 사용하여 미리 여러 영상의 밝기 단면을 이용하여 만들어 놓은 기준 패턴과 비교하여

관하게 될 판단 기준을 전문가의 판단 결과를 통하여 학습 하도록 구성되었다. 다층 신경회로망은 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.

다층 신경회로망의 입력으로는 입력으로는 식(2)과 같이 결정되어지는 LVQ 분류기의 가중치와 입력 패턴과의 유클리디안 거리를 사용한다. 이때 a 방향의 b 번째 가중치의 유클리디안 거리 d_a^b 는 다음과 같다.

$$d_a^b = \|\bar{X} - \bar{W}_a^b\| \quad (2)$$

다층 신경회로망의 최종입력은 식(3)과 같다.

$$[d_1^1, d_1^2, \dots, d_1^b, d_1^c, \dots, d_1^d, d_2^1, d_2^2, \dots, d_2^b, d_2^c, \dots, d_2^d, \dots, d_a^1, d_a^2, \dots, d_a^b, d_a^c, \dots, d_a^d] \quad (3)$$

위 입력에 해당되는 출력 뉴런의 지도 패턴은 BGA 볼 납땜부의 검사 형태에 따라 식(4)와 같이 나누어진다.

$$\begin{aligned} [1, 0, 0] : & \text{insufficient soldering quality} \\ [0, 1, 0] : & \text{acceptable soldering quality} \\ [0, 0, 1] : & \text{excess soldering quality} \end{aligned} \quad (4)$$

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

4. 실험 및 토의

4.1 실험 영상 데이터

분류 실험을 위해서 실제 산업체에서 생산한 5 장의 기판에서 추출한 220 개의 BGA 납땜부의 영상 데이터 중에 160 개의 영상 데이터를 사용하였다. 나머지 60 개의 영상 데이터는 구성된 본 연구에서 제한한 신경회로망의 성능을 평가하기

위하여 사용하였다. 수집한 납땜부의 영상 데이터는, 경험이 풍부한 검사자들에 의해 납량에 따라 미납(I), 정상(A), 과납(E)의 3 개의 클래스로 구분하였다. 신경회로망의 학습 영상은 그림 4 와 같이 100 x 100 화소(pixel)의 크기로 구성되었다.




Fig. 4 Training images

4.2 자율 학습 신경회로망의 학습

자율 학습 군집화 신경회로망의 학습을 위해서 그림 5와 같이 획득한 영상의 4 방향의 밝기 분포 형태(graylevel profile)를 먼저 추출한다. 이때 입력 패턴의 형태는 180개의화소로 구성되어 있는 1차원 배열이며 신경회로망의 입력으로는 각 화소 배열의 크기와 동일한 180개의 노우드를 가진다. 경쟁층에 속해 있는 출력 노우드의 수는 분류 하고자 하는 클러스터의 수와 동일하도록 설정한다.




Fig. 5 4-directional profiles for input

군집화 과정에서 신경회로망은 BGA 납 볼에서 획득한 단면 영상에서 추출한 다양한 밝기 분포들 중에서 비슷한 패턴끼리 모여, 학습 후 신경 회로망의 가중치 값은 클러스터를 대표하는 프로토 타입, 즉 대표 패턴이 된다.

분류하고자 하는 최적 클래스의 수를 구하기 위하여 분류하고자 하는 클래스의 수를 바꾸어 학습 후 분류 실험 결과를 표 1에 나타내었다. 그 결과 7개로 분류할 때 최소의 군집화 오차를 얻었으며 이때 최종적으로 LVQ알고리즘을 통하여 생성된 기준 패턴은 그림 6과 같다.

Table 1 clustering error at different number of neuron

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

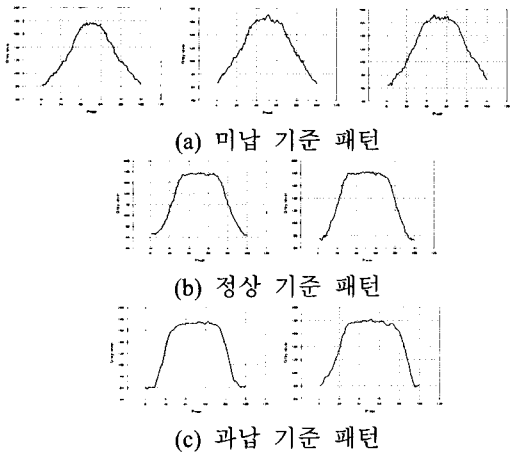


Fig. 6 Prototypes of clustering neural network

4.3 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 7 에 나타내었다. 20 개의 첫째 은닉층의 뉴런과 20 개의 두번째 은닉층의 뉴런의 구조를 가지는 신경회로망이 최소의 오차를 가졌다.




Fig.7 training errors of different structures

4.4 BGA 볼 납땜 분류 실험

자율 학습 군집화 신경회로망과 다층 신경회로망의 학습 후 분류 결과를 살펴 보기 위하여 학습에 사용한 영상들에 대한 분류 실험 결과를 표 2 에 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.

Table 2 Classification results of training 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.

Table 3 Classification results 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

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 불량률의 가능성이 높아진다.

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

4.5 비교 연구

제안된 신경회로망 분류기의 성능을 살펴보기 위하여 기존 LVQ-II 신경회로망과 다층 신경회로망을 사용한 결과와 비교 연구를 수행하였다.

LVQ-II 신경회로망으로 단층 BGA 볼 납땜 영상을 학습하여 분류 하기 위한 구조는 그림8과 같이 100x100의 2차원 구조로 되어 있으며 최적의 클래스 수를 구하기 위하여 앞서 실험한 방법과 같이 뉴런의 수를 바꾸어 가면서 최소의 분류 오차를 가지는 구조를 선택하였다.




Fig. 8 The structure of LVQ-II classifier

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

Table 4 Classification results of LVQ II

(a) results of training patterns

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) results of test patterns

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

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

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 9과 같은 구조의 다층 신경회로망을 사용하여 160개의 BGA 볼 영상을 사용한 학습 결과와 학습에 사용되지 않은 60개 영상을 이용한 분류하였다. 신경회로망의 입력으로는 100x100영상을 25x25으로 축소한 영상의 각 화소(pixel)의 밝기 값을 사용하였다.




Fig. 9 The structure of MLP neural classifier

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, 두번째 은닉 층의 개수는 40개 였다. 이때 학습 패턴의 분류 결과와 학습에 사용하지 않은 패턴의 분류 결과를 표 5에 나타내었다.

Table 5 Classification results of MLP1

(a) results of training patterns

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) results of test patterns

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 줄어들어도 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. 다층 신경회로망은 비선형 분류기로써 널리 사용되고 있지만, 영상과 같은 차원이 큰 패턴의 분류에 학습의 효

율성이 떨어져, 복잡한 영상 패턴의 적용이 쉽지 않다.

4. 결론

본 연구에서는 기존의 시각검사로 불가능한 BGA 볼의 납땜 검사를 위해서 X선 단층 시스템을 사용하여 단층 영상을 획득하고, 단층 영상으로 납땜 부의 납량을 검사하기 적합한 신경회로망 분류기를 설계하다 제안된 신경회로망 분류기는 실제 다양한 PCB 기판에서 수집된 여러 납땜 패턴에 대해서 분류 실험을 하였다.

획득된 다양한 BGA 부품의 납땜 검사 작업은 형상 인식 문제 이외에도 납땜부의 형상이나 그 불량 형태가 다양하여, 이를 잘 분리할 수 있는 분류기의 개발이 필요하다.

최근 신경회로망 분류기가 영상처리 분야의 패턴 인식 및 분류 문제에 널리 적용되고 있다. 본 연구에서는 일반적인 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 저하를 해결하기 위하여 군집화 신경회로망에 다층 신경회로망을 접합한 분류기를 설계하였다.

앞서 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.

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 제안된 두 가지 신경회로망의 결합된 형태로 구조를 최적화 하는 기법에 대한 연구가 진행되고 있다.

참고문헌

1. K.W. Ko, Y.J. Roh and H.S.Cho, "A Neural Network Approach to the Inspection of Ball Grid Array Solder Joints on Printed Circuit Boards," IJCNN'2000
2. 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, December 1995. pp 851-861.
3. 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. 1991, pp 484-497.
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. A. E. M. Bocage, "Laminographic imaging system for high energy radiation," French Patent 536464(1922).
6. R.P. Lippmann, "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, Vol. 4, pp.4-22, April, 1987.
7. R.P. Lippmann, "Pattern Classification Using Neural Networks," IEEE, 1989.
8. Y.H. Pao, "Adaptive Pattern Recognition and Neural Networks," Addison-Wesley, pp 269-330, 1989.