

# 시각 검사 시스템에서 신경 회로망을 이용한 납땜 상태 분류 기법

오 제 휘\*, 차 영 엽\*\*

## A Classification Techniques of Solder Joint Using Neural Network in Visual Inspection System

Je-Hui Oh\* and Young-Youp Cha\*\*

### ABSTRACT

This paper presents a visual inspection algorithm looking for solder joint defects of IC chips on PCBs(Printed Circuit Boards). In this algorithm, seven features are proposed in order to categorize the solder joints into four classes such as normal, insufficient, excess, and no solder, and optimal back-propagation network is determined by error evaluation which depend on the number of neurons in hidden and output layers and selection of the features. In the end, a good accuracy of classification performance, an optimal determination of network structure and the effectiveness of chosen seven features are examined by experiment using proposed inspection algorithm.

**Key Words** : Visual Inspection System(시각 검사 시스템), Neural Network(신경 회로망), Solder Joint Inspection(납땜 검사), Back-Propagation(역전파).

### 1. 서 론

오늘날 전자 제품의 소형화와 다기능화, 그리고 고성능화가 요구됨에 따라, 전자 제품 제작에 이용하는 SMD(Surface Mount Device) 실장기술은 수요자의 요구를 충족시키기 위해 소형화 그리고 고밀도화 되어 가고 있다. 그런데 이러한 부품제작과 실장기술의 급속한 발전에 반하여 검사기술은 기존의 인간에 의한 목시검사에 의존하는 실정이다. 기존의 목시검사는 소형화, 고밀도화

된 SMD 검사시 작업자 눈의 피로 가중, 집중력 저하, 작업자에 따른 판정기준 상이, 작업자의 숙련도와 컨디션에 따른 품질의 산포 다양, 검사 결과의 빠른 Feedback 불가, 품질의 신뢰도 하락, 인건비 상승 등의 문제점을 가지게 되었다. 따라서 이러한 단점을 극복하기 위하여 부품의 유무와 납땜 상태를 자동으로 검사하는 시스템들이 등장하기 시작했다.

이러한 검사 시스템의 대표적인 경우가 레이저(Laser), X선 그리고 카메라(Camera)등의 장치를 사용

\* 원광 대학교 대학원

\*\* 원광 대학교 기계공학부

하여 부품의 유무와 납땜 상태를 검사를 하는 것이다. 이 중에서 1980년 중반부터 연구되어진 카메라를 이용한 시각 검사 시스템(Visual Inspection System)은 타 장비에 비하여 가격의 상대적 저렴성과 검사의 정확성에 의해 많은 발전을 보이고 있다. 시각 검사 시스템은 검사 시스템 구성, 검사 영상 획득 방법 그리고 검사 알고리즘 등에 의해 검사 방법이 달라진다. 그러므로 부품의 유무와 납땜 상태 검사 시스템의 검사 정확성을 높이기 위한 연구가 계속 진행되어 왔으며, 대표적인 연구자와 연구 특징은 다음과 같다.

Bartlett<sup>(1)</sup>은 그레이 레벨(Gray Level) 영상을 받아 통계학적 패턴 인식(Statistical Pattern Recognition)과 전문가 시스템(Expert System)을 이용하여 특징값(Feature)을 얻은 다음 납땜 상태를 검사하였으며, Teoh<sup>(2)</sup>는 히스토그램(Histogram)을 이용하여 부품의 상태(즉, 부품 무(Missing), 이동(Alignment)과 회전(Orientation))와 납땜 상태를 검사하였다. 또한, Chi는 전문가 시스템을, Nishihara & Crossley는 Laplacian 신호를, 그리고 Chemaly는 Morphology를 이용하여 IC 칩(Chip)의 납땜 상태를 검사하였다<sup>(3)</sup>. Capson & Eng<sup>(4)</sup>는 빨강과 파랑의 단을 이룬 조명(Tiered Lighting)을 사용하여 컬러 영상을 받아 PCB의 납땜 상태를 검사하였고, Nayer<sup>(5)</sup>는 가우시안 영상(Gaussian Image)과 하이라이트(Highlight)의 배열 특성을 이용하여 3차원의 데이터를 얻어 납땜 상태를 검사하였다. Park & Tou<sup>(6)</sup>는 작성된 CAD(Computer Aided Design) 데이터를 이용하고, Takagi<sup>(7)</sup>는 단을 이룬 조명과 CAD 데이터를 이용하여 납땜 상태를 검사하였다. 그리고 최근에는 레이저를 사용한 검사 시스템에 신경회로망을 이용한 납땜 상태 분류 알고리즘을 적용하여 좋은 결과를 얻었다<sup>(8)</sup>.

본 연구는 이미 수행했던 납땜검사 최적경로 생성연구<sup>(9)</sup>와 CCD 카메라 보정(Calibration)에 관한 연구<sup>(10)</sup>에 연계하여, PCB 위의 IC 칩(Chip) 납땜불량을 자동으로 판별하는 시각 검사 알고리즘 개발에 대한 것이다. 여기서는, 납땜상태를 정상(Normal), 미납(Insufficient), 과납(Excess) 그리고 무납(No Solder)의 4가지로 분류하기 위하여 7가지의 새로운 특징값을 제안하고, 납땜 분류시 발생하는 오차평가에 의하여 최적의 역전파(Back-Propagation) 알고리즘 구조를 결정하는 것이 목적이다. 빛의 방향과 양을 조절할 수 없는 할로겐 조명은 달리, 이것이 가능한 2단의 LED 조명을 통해 얻어

진 영상을 이용하여 새로운 특징값을 추출할 수 있었다. 납땜 상태 분류 알고리즘으로 사용된 역전파 네트워크의 최적 구조 결정을 위하여, 은닉층과 출력층의 뉴런수를 변화시키고, 특징값의 선택적 사용에 따른 오차평가가 이루어졌다. 학습(Learning)과정과 적용(Recall) 과정으로 분리된 역전파 알고리즘은 학습을 위해 많은 시편 영상(Sample Image)과 학습시간이 필요하다는 단점을 제외하고는, 학습을 통해 얻어진 역전파 네트워크의 가중치를 이용하는 적용 과정에서는 기존의 통계학적 분석에서 해결하기 어려운 패턴 분류(Pattern Classification)를 빠르고 우수하게 수행한다는 장점이 있다.

IC 칩의 납땜 상태를 자동으로 검사하는 시각 검사 알고리즘 개발을 위하여, 2장에서는 검사 영상을 받아 납땜 분류를 할 수 있게 해주는 시각 검사 시스템의 구성을 설명하고, 3장에서는 시각 검사 시스템의 납땜 상태 분류를 위하여 새로운 특징값들을 정의한다. 그리고, 4장에서는 분류 알고리즘인 역전파 알고리즘의 이론적 배경을 설명한다. 5장에서는 제안된 특징값들의 선택적 도입과 역전파 네트워크의 구조결정에 실제 영상을 적용하여 오차평가를 함으로써, 이전의 통계학적인 분류보다 정확한 분류가 가능함을 보인다.

## 2. 검사 시스템 구성

본 연구를 위하여 만들어진 시각 검사 시스템의 구성은 Fig. 1과 같이 Host PC부, 영상(Imaging)부 그리고 구동(Driving)부로 나눌 수 있으며, 각각은 다음과 같다.

**Host PC부** : 검사 S/W가 실행되며, 주변 장치를 통제하고, 486-DX2 PC를 이용하여 부품과 납땜 상태 검사 알고리즘을 구현하는 부분이다.

**영상부** : 화상처리 보드를 사용하여 CCD 카메라를 통해 들어오는 영상을 검사 알고리즘에 이용할 수 있도록 처리해주는 부분으로 조명기, CCD 카메라, 화상처리보드, 화상 모니터로 구성되어 있다. 화상처리 보드는 Bar-Gold사의 IVP-550을, CCD 카메라는 Teli사의 CS8320을 사용하였다. 여기서, 화상처리 보드는 TI사의 DSP 칩(TMS320C50 40MIPS)을 이용하므로 고속 영상처리가 가능하고, 여러 카메라로 부터의 입력영상을 동시에 처리(입력: 9, 출력: 3)할 수 있으며, 영상 메모리는 최고 64Frame까지 저장할 수 있다. 그리고 CCD 카메라는 768×464의 픽셀(Pixel)을 가지며, CCD 화소 크

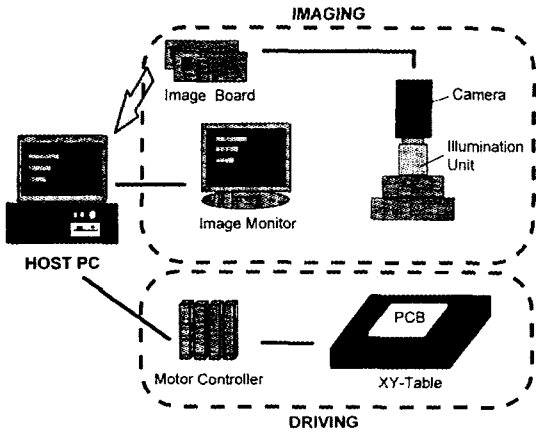


Fig. 1 Organization of Visual Inspection System

기는  $6.4 \times 4.8(mm^2)$ 이다.

**구동부** : 검사 시스템이 자동으로 동작하기 위한 작업 영역 이동, 카메라 조정 등의 작업을 하는 부분으로 모터 제어기(Motor Controller), 모터 그리고 X-Y Table로 구성되며, X-Y Table은 Parker사의 M315082S를 사용하였다. 최대 행정은  $203 \times 203(mm^2)$ 이고, 허용하중은 95kg이다. 그리고 모터와 제어기는 Parker사의 25000 pulse/rev의 마이크로 스테핑 모터와 OEM650X를 각각 사용하였다.

특히, 영상부는 검사를 위한 납땜영역을 받아들이는 부분으로서, 영상부의 특성에 따라 검사 알고리즘이 변하므로, 전체 시스템에서 가장 중요한 부분이다. Fig. 2는 영상부 중 CCD 카메라와 조명부로 구성되는 영상 획득부에 대한 것이다. 영상 획득부는 카메라, Zooming Pipe 그리고 LED 조명부로 이루어지며, LED 조명부는 2단의 원형 링 조명으로 구성되어져 있다. 여기서, 하단에 위치하는 1단 LED 원형 조명은 지면과  $30^\circ$ 의 각도로 입사하게 하였고, 상단에 위치하는 2단 LED 원형 조명은 지면과  $85^\circ$ 의 각도로 입사하게 구성하였다. Fig. 3은 본 연구를 위하여 제작된 검사 시스템을 보여주고 있다.

### 3. 납땜 상태 분류

본 연구에서 다룰 납땜 상태 검사 부품은 IC 칩으로 하였다. 우선 분류해야 할 납땜 상태를 설명하고, 본 논문에서 제안하려고 하는 특징값에 필요한 변수들을 기술한다.




Fig. 2 Part of Image Acquisition




Fig. 3 Visual Inspection System

그리고 나서, 납땜 상태의 분류를 가능하게 하는 7가지 특징값을 정의한다.

#### 3.1 일반적인 납땜 상태

PCB에 장착된 부품의 납땜상태 분류는 정상(Normal), 미납(Insufficient), 과납(Excess) 그리고 무납(No Solder) 등이며, Fig. 4는 납땜 상태의 패턴들을 도해적으로 보여주고 있다. 여기서 검정부분은 납땜부분을 나타내며, 흰 부분은 PCB기판과 IC 칩의 리드(Lead)를

Pattern	3-D Shape	Cross-Sectional View
Normal		
Excess		
Insufficient		
No Solder		

Fig. 4 Pattern of Solder Joint

나타내고 있다. 위의 분류에서 과납은 PCB 패드(Pad)와 리드 사이의 납땜이 기준보다 많은 경우로써 리드와 리드 사이의 납이 연결된 경우인 브릿지(Bridge)의 원인이 되므로 위험하며, 미납은 PCB 패드와 리드 사이의 납땜이 기준보다 적은 경우로써 PCB에 충격이 가해질 때 PCB 패드와 리드가 떨어질 수 있다. 그리고 무납은 PCB 패드와 리드 사이의 납땜이 없는 경우로써 PCB 패드와 리드가 분리되어 부품이 성능을 발휘할 수 없다. 그러므로, 위의 세 가지 납땜 상태는 정상인 경우와 구별할 수 있도록 분류해야 한다.

### 3.2 납땜 상태 해석

만일 1단의 LED 조명 강도를 2단의 LED 조명 강도보다 적게 하여 영상을 받아 이치화 시킨다면, Fig. 5와 같은 패턴의 영상을 얻을 수 있을 것이다. 여기서 (a)는 정상, (b)는 과납, (c)는 미납 그리고 (d)는 무납 상태의 경우를 나타내고 있다. 이 그림에서 무납을 제외하고 모두 2개의 하이라이트(Highlight) 부분이 있는데 이곳의 중심을 Peak라 부른다면, 하나는 리드 부분에, 다른 하나는 납땜부분에 나타날 것이다. 이 부분은 임의의 기준치보다 큰 값을 갖는 부분이다. 여기서, 리드에서의 하이라이트 부분을 Frist Peak라 하고 납땜에서의 하이라이트 부분을 Second Peak라 칭한다. 그리고, Frist Peak와 Second Peak사이의 거리를  $Dist_{peak}$  라고 정의한다.

그러면, 과납은 정상보다  $Dist_{peak}$ 의 거리가 짧을 것이며, 하이라이트 영역은 넓을 것이다. 그리고 전체의 그레이




Fig. 5 Analysis of Solder Joint

레벨값이 정상보다 높을 것이다. 미납은 정상보다  $Dist_{peak}$ 가 더 크거나 없을 것이며, 하이라이트의 영역은 적을 것이다. 그리고 전체의 그레이 레벨값이 정상보다 낮을 것이다. 마지막으로 무납은  $Dist_{peak}$ 가 없을 것이며, 대부분이 하이라이트 영역일 것이다. 그러므로 전체의 그레이 레벨값이 정상이나 과납보다 높을 것이다. 이러한 관계들과 추가적인 특징들을 이용하여 다음과 같은 7가지의 특징값을 정의한다.

### 3.3 특징값 정의

납땜 상태 분류 알고리즘에 적용하기 위한 검사영역  $r$ 에서  $Dist_{peak}$ 를 포함한 특징값들은 다음과 같이 정의된다.

i) 평균 그레이 레벨값 (Average Gray Level :  $F_1$ ) : 검사영역  $r$ 의 평균 그레이 레벨값으로 다음 식과 같다.

$$F_1(r) = \sum_{k=0}^{l(r)} Pixel_k(x, y) / I(r) \quad (1)$$

여기서  $I(r)$ 는 영역  $r$ 의 총 픽셀(Pixel) 수를 나타내며,  $Pixel_k(x, y)$ 는  $k$ 번째 픽셀 좌표  $(x, y)$ 에서의 그레이 레벨값을 나타낸다.

ii) 기준치 이상 영역 (Area Over Threshold :  $F_2$ ) : 평균 그레이 레벨값 보다 어느 정도 큰 값을 기준치라 하면, 기준치 이상의 값을 가진 픽셀의 수를 특징값으로 정한다.

$$F_2(r) = \sum_{k=0}^{l(r)} TA_k(x, y) / I(r) \quad (2)$$

여기서,  $Thr$ 을 임의의 기준치라 하면,  $TA_k(x,y)$ 는 다음과 같이 정의된다.

$$TA_k(x,y) = \begin{cases} 1, & Pixel_k(x,y) > Thr \\ 0, & otherwise \end{cases}$$

iii) 기준치 이하의 평균 그레이 레벨값 (Average Gray Level Less Than Threshold :  $F_3$ ) : 기준치 이하의 그레이 레벨값을 갖는 픽셀들의 평균 그레이 레벨값을 특징값으로 정한다.

$$F_3(r) = \sum_{k=0}^{l(r)} TP_k(x,y) / I(r) \quad (3)$$

여기서,  $TP_k(x,y)$ 는 다음과 같이 정의한다.

$$TP_k(x,y) = \begin{cases} Pixel_k(x,y), & Pixel_k(x,y) \leq Thr \\ 0, & otherwise \end{cases}$$

iv) 하이라이트 이상 영역 (Area Over Highlight :  $F_4$ ) : 가장 큰 그레이 레벨값에서 어느 정도 작은 값을 하이라이트라 정하면, 하이라이트 이상 값을 가진 픽셀의 수를 특징값으로 정한다.

$$F_4(r) = \sum_{k=0}^{l(r)} HA_k(x,y) / I(r) \quad (4)$$

여기서,  $HL$ 을 임의의 하이라이트 값이라 하면,  $HA_k(x,y)$ 는 다음과 같이 정의된다.

$$HA_k(x,y) = \begin{cases} 1, & Pixel_k(x,y) > HL \\ 0 & otherwise \end{cases}$$

v) 하이라이트 이하의 평균 그레이 레벨값 (Average Gray Level Less Than Highlight :  $F_5$ ) : 하이라이트 이하의 그레이 레벨값을 갖는 픽셀들의 평균 그레이 레벨값을 특징값으로 정한다.

$$F_5(r) = \sum_{k=0}^{l(r)} HP_k(x,y) / I(r) \quad (5)$$

여기서,  $HP_k(x,y)$ 는 다음과 같이 정의한다.

$$HP_k(x,y) = \begin{cases} Pixel_k(x,y), & Pixel_k(x,y) \leq HR \\ 0, & otherwise \end{cases}$$

vi)  $Dist_{peak}$ 의 크기 (Size Of  $Dist_{peak}$  :  $F_6$ ) : 1st Peak와 2nd Peak 사이의 거리를 특징값으로 한다.

$$F_6(r) = Dist_{peak} \quad (6)$$

vii) 1st Peak와 2nd Peak사이의 평균 그레이 레벨값 (Average Gray Level Between 1st Peak And 2nd Peak :  $F_7$ ) : 1st Peak와 2nd Peak 사이의 평균 그레이 레벨값을 특징값으로 한다.

$$F_7(r) = \sum_{k=0}^{l(r)} PP_k(x,y) / I(r) \quad (7)$$

여기서,  $Peak_1$ ,  $Peak_2$ 를 각각 첫 번째, 두 번째 Peak의 위치라 하면,  $PP_k(x,y)$ 는 다음과 같이 정의한다.

$$HP_k(x,y) = \begin{cases} Pixel_k(x,y), & Pixel_1 \leq Pixel_k(x,y) \leq Peak_2 \\ 0, & otherwise \end{cases}$$

#### 4. 분류 알고리즘

앞에서 정의한 특징값을 이용하는 분류 알고리즘으로는 신경 회로망 중 역전파 알고리즘을 이용한다<sup>(11,12)</sup>. 역전파 네트워크 구조는 Fig. 6과 같다. 전통적인 역전파 알고리즘에서, 실제 출력값과 요구되는 출력값의 오차 측정은 평균 제곱 오차 (Mean square error)를 사용하며, 이것은 연속적이고 미분 가능한 오차 함수라야만 적용할 수




Fig. 6 Back-Propagation Network

있다. 특히 오차 함수로 어떠한 함수를 사용하던 간에 네트워크에 요구되는 출력과 실제 출력사이의 측정 "거리 (즉, 오차)"를 보여 주어야한다는 것이다. 여기서 평균 제곱 오차는 다음과 같다.

$$E_p = \frac{1}{2} \sum_{j=1}^N (t_{pj} - O_{pj})^2 \quad (8)$$

여기서,  $E_p$  :  $p$  번째 패턴 벡터의 오차.

$t_{pj}$  :  $j$  번째 출력 뉴런의 요구되는 값.

$O_{pj}$  :  $j$  번째 출력 뉴런의 실제 출력.

합( $\sum$ )에서의 각각의 항은 각 출력 뉴런의 오차 분포를 나타낸다. 요구되는 출력과 실제 출력사이의 차에 절대값을 취하고 제곱하므로써, 요구되는 값보다 큰 출력값은 전체 오차에 강하게 작용할 수 있게 만들었다. 출력값을 얻는 전방향(Forward) 학습법칙은 다음과 같이 정의한다.

$$O_i^l = f(\text{net}_i^l) = f\left(\sum_j \omega_{ij}^l O_j^{l-1}\right) \quad (9)$$

여기서, 상 첨자  $l$ 은 층(Layer)으로  $l=1, 2, \dots, L$  이며,  $l=0$ 은 입력층을 나타낸다. 그리고  $T$ 를 일정 상수, 즉 가상의 온도(Temperature)라 하면,  $f(\text{net}_i^l)$ 는 비선형의 활성화 함수(Nonlinear Activation Function)로써 일반적으로 다음과 같은 시그모이드 함수(Sigmoid Function)를 사용한다.

$$f(\text{net}_i^l) = \frac{1}{1 + e^{-\frac{\text{net}_i^l}{T}}} \quad (10)$$

전방향 학습에서 얻어진 실제 출력값과 요구되는 출력값 사이의 오차를 이용하여 전체 네트워크의 가중치(Weights)를 변화시키기 위해 역전파는 일반적으로 기울기 감소법(Gradient descent method) 또는 최속강하법(Steepest descent method)이라 불리는 학습 알고리즘을 사용한다. 이 방법은 네트워크의 총 오차를 최소화 하는 방향으로 가중치를 조정한다. 가중치의 관점에서 오차 함수의 음의 기울기는 오차함수를 가장 빠르게 감소시키는 방향을 가리킨다. 가중치가 이 벡터를 따라 움직인다면 기울기가 영(Zero)인 국극적인 최소점에 도달하게 된다. 이러한 기법을 수학적으로 표현한다면 다음과 같다.

$$\Delta_p w_{ji} \propto -\frac{\partial E_p}{\partial w_{ji}} \quad (11)$$

여기서  $\Delta_p w_{ji}$  항은  $L-1$ 층의 근원지 뉴런(Source Neuron)  $i$ 와  $L$ 층의 목적지 뉴런(Destination Neuron)  $j$ 와의 연결 가중치의 변화를 나타낸다. 가중치에서 이 변화는 가중치 공간에서 보다 작은 오차로 향하는 스텝이다. 이것의 목적은 각각의 가중치를 조정하므로써 네트워크의 수렴성을 어떻게 성취하도록 결정하느냐이다. 식(11)은 각 가중치  $w_{ji}$ 의 변화가 국부 오차 표면에서 음의 최대 기울기에 따라 변하는 상태를 나타낸다. 식(11)과 시그모이드 함수를 이용하면 역전파에 사용되는 학습방정식은 다음과 같이 얻어진다.

$$\Delta w_{ji} = \eta \delta_{pj} O_{pi} \quad (12)$$

여기서,  $\eta$  : 학습율(Learning rate)

$O_{pi}$  :  $L-1$ 층의 뉴런  $i$ 의 출력값(Error signal)

$\delta_{pj}$  :  $L$ 층의 뉴런  $j$ 의 오차 신호(Error signal)

로써 다음 두 가지 경우가 있다.

- 출력 뉴런인 경우

$$\delta_{pj} = (t_{pj} - O_{pj}) O_{pj} (1 - O_{pj}) \quad (13)$$

- 은닉 뉴런(Hidden Neuron)인 경우

$$\delta_{pj} = O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \quad (14)$$

여기서,  $O_{pj}$ 는  $L$ 층의 출력값을,  $O_{pi}$ 는  $L-1$ 층의 출력값을,  $O_{pk}$ 는  $L-1$ 층의 출력값을 나타낸다.

원래의 기울기 감소법은 기울기에 설정된 방향에 따라 극소의 스텝으로 진행되어 그 진행 속도면에서 비효율적이다. 이러한 비효율성을 제거하기 위하여 학습율  $\eta$ 를 사용하였으며,  $\eta$ 는 상수로써 기울기 방향으로의 이동 스텝 크기를 결정한다고 볼 수 있다.  $\eta$ 를 충분히 크게 하는 이유는 네트워크가 과도응답(Overshooting)이나 진동(Oscillation)없이 수렴하기 위해서이다. 식(12), (13) 그리고 (14)에 대한 도해적인 표현은 Fig. 7과 같다. 그림의 상부는 출력층의 학습이고 하단부는 은닉층의 학습을 나타낸다. 실제로, 어떤 문제 영역에서는 보다 빠른 수렴을 얻기 위하여 식(12)에 추가항을 더하는 경우가 있다. 이러한 대표적인 예는 모멘텀(Momentum)이

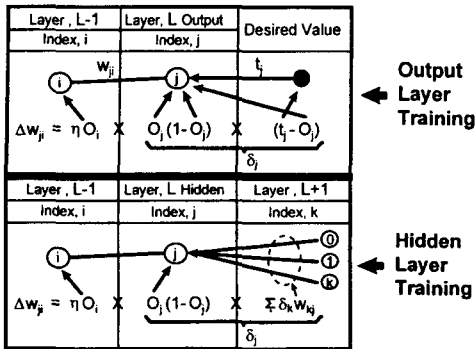


Fig. 7 Diagram of Back-propagation

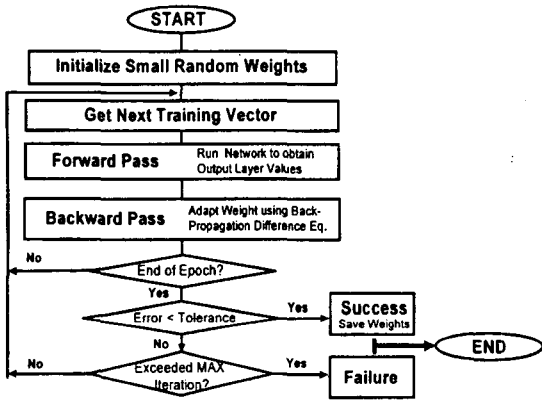


Fig. 8 Flowchart of Back-Propagation

다. 모멘텀은 과거 가중치 변화의 효과를 더하는 것이며, 모멘텀 상수  $\alpha$  에 의하여 조절된다.

$$\Delta w_{ji}(n+1) = w_{ji}(n) + \eta(\delta_{pj} O_{pi}) + \alpha \Delta w_{ji}(n) \quad (15)$$

전방향 과정(Forward pass)과 역방향 과정(Backward pass)을 포함한 전반적인 역전파 진행과정은 Fig. 8과 같다. 역전파를 이용하기 위하여 네트워크는 초기의 가중치를 작은 수로써 무작위(Random)로 초기화 하여야 한다. 만약에 초기의 가중치를 큰 수로 한다면 조기 포화로 학습을 할 수 없다. 초기화가 완료되면, 실제 출력값을 얻을 때까지 전방향으로 네트워크를 진행시킨다. 역전파는 새로운 가중치를 만들 때 이용하며, 이러한 반복을 통하여 실제 출력과 요구되는 출력사이의 전체 오차를 줄여 나간다. 학습 집합의 전체 벡터가 모두 한번씩 입력한 시기를 기점(Epoch)이라 한다면, 하나의 기점을 마친


후, 모든 오차가 허용오차보다 적은 경우 네트워크가 수렴했다고 할 수 있다. 여기서 모든 오차가 일정할 필요는 없다.

## 5. 실험 결과

분류 알고리즘의 실험을 위하여, 제안된 시각 검사 시스템에서 얻어진 영상 중 시편 영상에 대하여 관찰하였다. 그리고 분류 알고리즘인 역전파의 적용 네트워크와 그에 따른 변수들을 정하고, 정해진 네트워크를 시편 영상을 통해 학습시킨 후, 실제 영상에 적용하여 신뢰도를 확인하였다.


### 5.1 시편 영상 데이터

1단의 LED 조명 강도를 10%로 하고 2단의 LED 조명 강도를 50%로 하여 영상 획득부에서 얻어진 과납, 미납, 무납 그리고 정상 상태를 보여주는 영상들은 Fig. 9와 같다. 그리고 전체 영상에서 실제 검사 영역(20 pixel × 45 pixel)만을 추출하여 각각의 납땜 상태에 관한 영상 데이터를 3차원의 그래프로 나타내면 Fig. 10과 같다. 여기서 x축은 폭(Width), y축은 길이(Length), z축은 그레이 레벨값을 나타낸다. 그레이 레벨값은 0~255까지이며, 밝을수록 높은 숫자를 나타낸다. 그림에서는



(a) Excess and Insufficient

(b) Insufficient



(c) No Solder

Fig. 9 Real Image

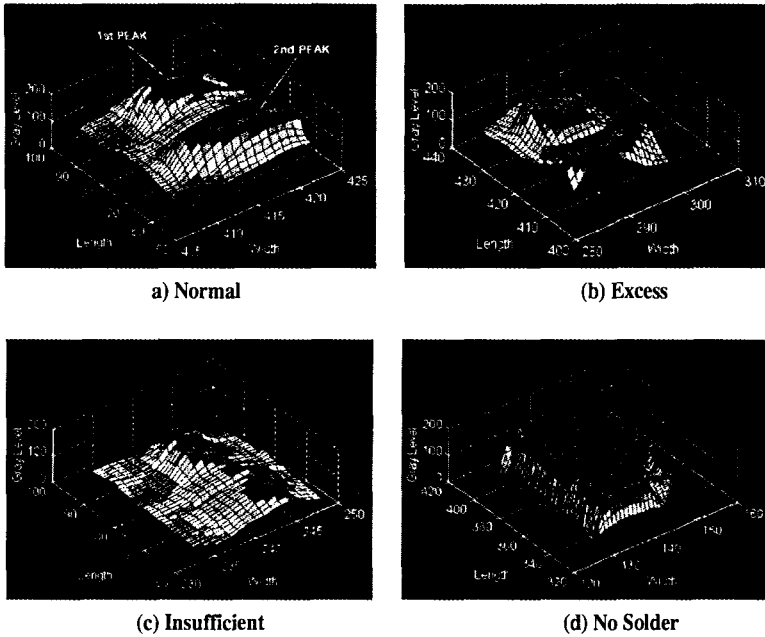
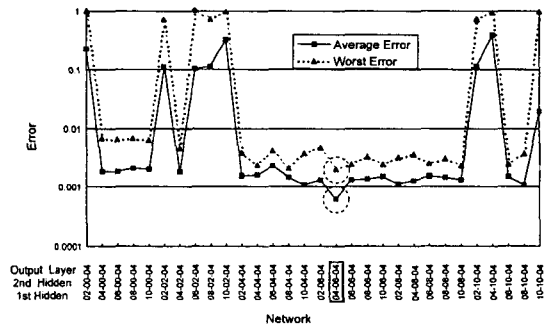


Fig. 10 3-Dimension Image Data


그레이 레벨값이 높을수록 짙은색으로 나타나며, 왼쪽의 Peak가 First Peak이고, 오른쪽의 Peak가 Second Peak이다.

5.2 분류 네트워크의 설정

분류 알고리즘을 적용하기 위한 네트워크의 결정과 특징값들이 올바르게 선택된지를 알기 위해, 네트워크의 입력값을 7개의 특징값 모두 사용한 경우와, 특징값을 줄여서 사용한 경우로 나누어 실험해 보았다. Fig. 11은 입력값이 7개인 경우와 특징값을 줄인 것 중 가장 낮은 오차를 가진 경우( $F_3$ 를 제거한 6가지 특징값)의 네트워크의 오차를 보여주고 있다. 실선은 평균 오차를 나타내고, 점선은 최대 오차를 나타낸다. 검사 할 때, 역전파의 변수인 가상의 온도  $T$ , 학습율  $\eta$ , 모멘텀 상수  $\alpha$ 를 각각  $T=0.6$ ,  $\eta=0.7$ ,  $\alpha=0.7$ 로 하여 2,000,000회 반복(약 15분 소요됨)하고 나서, 마지막 기점에서 평균 오차(Average Error)와 최대 오차(Worst Error)를 검사하였다. 네트워크의 결정은 평균 오차보다 최대 오차가 낮아야 오차범위(Tolerance)를 최소로 할 수 있으므로, 최대 오차가 가장 적은 네트워크를 분류 네트워크로 하였다. 그리고 적은 수의 네트워크일수록 계산량과 시간이 줄어들므로 비슷한 오차율이라면 네트워크 수가 적은 것을 선택해야



(a) Seven Input Neuron



(b) Six Input Neuron

Fig. 11 Network Error of Back-Propagation



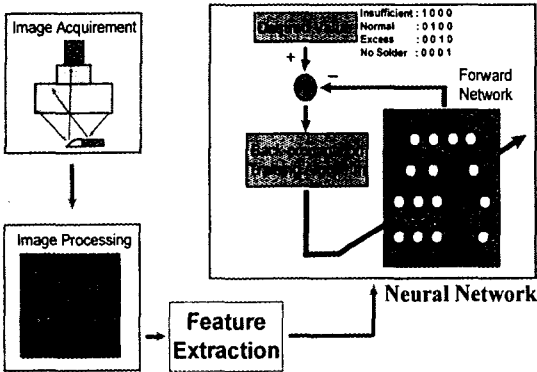


Fig. 12 Flowchart of Visual Inspection System

한다. Fig. 11에 의해 최대오차를 중심으로 선택한 네트워크는 7-4-6-4 구조와 6-8-4-4의 구조를 갖는 2개의 네트워크를 설정하였다.

5.3 실험

5.2절에서 설정된 2개의 네트워크를 이용하여 시편 영상에서 얻은 특징값으로 50개의 패턴을 만들어 학습을 하였다. 온도  $T$ , 학습률  $\eta$  그리고 모멘텀 상수  $\alpha$  값에 따라 실험 결과값의 변화가 있으므로 여러 테스트를 통하여 본 실험은 학습과정 중 오차범위를 0.0005, 변수들을  $T=0.6$ ,  $\eta=0.4$ ,  $\alpha=0.7$ 로 하여 네트워크 가중치들을 구하였다. 학습을 통하여 얻어진 네트워크의 가중치들을 가지고 200개의 IC 칩 리드에 적용하였다. 시각 검사 시스템의 분류 알고리즘 적용에 대한 간단한 흐름도는 Fig. 12와 같다. 먼저 비전 시스템의 카메라에서 영상을 받은 후, 화상 보드를 이용하여 영상 처리를 한다. 그리고, 특징값을 계산하고, 이 값들을 역전파 알고리즘에 적

용하여 납땜 상태를 분류한다. 이러한 분류 알고리즘을 적용한 결과 값은 Table 1과 같다. Table 1에서와 같이 7-4-6-4 네트워크는 97.7%의 신뢰도를 가지며, 6-8-4-4 네트워크는 96.5%의 신뢰도를 갖는다. 신뢰도 면에서 보듯이 특징값을 7가지 모두 쓴 경우의 네트워크가 특징값을 6가지 쓴 경우보다 월등히 좋음을 알 수 있다. 그러므로, 특징값의 선택이 적절하다는 것을 알 수 있다. 그리고, 기존의 납땜 상태 검사에 96~97%의 신뢰도 (Bartlett(1)의 연구는 96%이며, Capson & Eng(4)는 97%이고, Park & Tou(6)는 96.2%이다.)를 갖는 것에 비교하면 97.7%라는 좋은 신뢰도를 보이고 있다.

6. 결론

본 연구에서는 PCB 위의 IC 칩(Chip) 리드의 납땜량을 자동으로 판별하는 시각 검사 알고리즘을 개발하였다. 여기서는, 납땜상태를 정상(Normal), 미납(Insufficient), 과납(Excess) 그리고 무납(No Solder)의 4가지로 분류하기 위하여 7가지의 새로운 특징값을 제안하였고, 납땜분류시 발생하는 오차평가에 의하여 최적의 역전파(Back-Propagation) 알고리즘 구조를 결정하였다. 빛의 방향과 양을 조절할 수 있는 2단의 LED 조명을 통해 얻어진 영상을 이용하여 새로운 특징값을 추출할 수 있었다. 납땜 상태 분류 알고리즘으로 사용된 역전파 네트워크의 최적 구조 결정을 위하여, 은닉층과 출력층의 뉴런수를 변화시키고, 특징값의 선택적 사용에 따른 오차평가가 이루어졌다. 실험을 통하여 7-4-6-4 네트워크는 97.7%의 신뢰도를 가지며, 6-8-4-4 네트워크는 96.5%의 신뢰도를 갖는다는 것을 알 수 있었다. 신뢰도 면에서 보듯이 특징값을 7가지 모두 쓴 경우의 네트워크가 6가

Table 1. Classification Result of Solder Joint

Classification Network	Solder Joint Class	Number of Joints	Classification Result	
			Correct (Correct%)	Error (Error%)
7-4-6-4	Normal	173	169 (97.7)	4 (2.3)
	Excess	10	10 (100)	0 (0)
	Insufficient	12	12 (100)	0 (0)
	No Solder	5	5 (100)	0 (0)
6-8-4-4	Normal	173	167 (96.5)	11 (3.5)
	Excess	10	10 (100)	0 (0)
	Insufficient	12	11 (91.7)	1 (8.3)
	No Solder	5	5 (100)	0 (0)

지 쓴 경우보다 우수함을 알 수 있었다.

### 후 기

본 연구는 한국과학재단의 지원(과제번호:971-1007-048-2)에 의하여 이루어졌으며 관계자 여러분들에게 감사드립니다.

### 참고 문헌

1. S. L. Bartlett, P. J. Besl, C. L. Cole, R. Jain, D. Mukherjee, and K. D. Skifstad, "Automatic Solder Joint Inspection," IEEE Trans. Pattern Anal. Mach. Intell. vol. 10, no. 1, pp. 31-43, 1988.
2. E. K. Teoh, D. P. Mital, B. W. Lee and L. K. Lee, "An Intelligent Robotic Vision System for Inspection of Surface mount PCBs," in Proc. ICSMC91, vol. 1, pp. 13-17, 1991.
3. T. S. Newman and A. K. Jain, "A Survey of Automated Visual Inspection," computer vision and image understanding, vol. 61, no. 2, pp. 231-261, 1995.
4. D. W. Capson and S. K. Eng, "A Tiered-Color Illumination Approach for Machine Inspection of Solder Joints," IEEE Trans. Pattern Anal. Mach. Intell. vol. 10, no. 3, pp. 387-393, 1988.
5. S. K. Nayer, A. C. Sanderson, L. E. Weiss and D. A. Simon, "Specular Surface Inspection using Structured Highlight and Gaussian Images," IEEE Trans. Robotics and Automation, vol. 6, no. 2 pp. 208-218, 1990.
6. J. S. Park and J. T. Tou, "A Solder Joint Inspection System for Automated Printed Circuit Board Manufacturing," In Proc. ICRA, vol. 1, pp. 1290-1295, 1990.
7. Y. Takagi, S. Hata, W. Beutel and S. Hibi, "Visual Inspection Machine for Solder Joints using Tiered Illumination," In Proc. SPIE Machine Vision Systems Integration in Industry, SPIE vol. 1386, pp. 21-29, 1990.
8. Y. K. Ryu and H. S. Cho, "A Neural Network Approach to Extended Gaussian Image based Solder Joint Inspection," mechatronics, vol. 7, no. 2, pp. 159-184, 1997.
9. 오제휘, 차영엽, "부품 조립 공정에서 경로의 최적화 알고리즘," 한국정밀공학회지, 14권, 8호, pp.122-129, 1997.
10. Y.Y.Cha and D.G.Gweon, "A calibration and range-data extraction algorithm of an omnidirectional laser range finder for free ranging mobile robot," Mechatronics, vol. 6, no. 6, pp. 665-689, 1996.
11. D. R. Hush and B. G. Horne, "Progress in Supervised Neural Networks," IEEE Signal Processing Magazine, pp. 8-39, 1993.
12. A. S. Pandya and R. B. Macy, "Pattern Recognition with Neural Networks in C++," CRS Press, 1995.