

QFN 납땜 불량 검출을 위한 효율적인 검사 기법

김호중* · 조태훈*

*한국기술교육대학교

Efficient Mechanism for QFN Solder Defect Detection

Ho-Joong Kim* and Tai-Hoon Cho*

*Korea University of Technology and Education

E-mail : hjhjhjof@naver.com

요 약

QFN(Quad Flat No-leads package)은 SMD(Surface Mount Device) 자재 중의 하나로써, 납땜을 하는 lead 부분이 따로 있지 않아 납땜에 대한 불량이 많이 발생하고 있다. 따라서 본 논문에서는 QFN의 납땜에 대한 불량을 검출하는 기법을 제안하고자 한다. 우리는 QFN의 납땜에 대한 불량 검출을 위해 기계학습 방법 중 하나인 Convolutional Neural Network(CNN)을 사용하였고, CNN에 학습을 시키기 위한 데이터로는 납땜을 한 QFN 컬러 다단 영상을 사용하였다. 이 영상은 3채널 컬러 영상으로, 이를 바로 CNN에 적용시켜 학습시키기에는 문제가 있다. 그렇기 때문에 3채널 컬러 영상을 세 개의 1채널 Grayscale 영상(Red, Green, Blue)로 분리시켜 CNN에 적용시켰다. 이렇게 학습시킨 결과를 이용하여 QFN의 납땜에 대한 불량을 검출할 수 있었다. 현재는 Dicing과 Punch에 대해서만 테스트를 해보았기 때문에, 추후에 이를 제외한 다른 것들에 대한 추가적인 연구가 필요하다.

ABSTRACT

QFN(Quad Flat No-leads package) is one of the SMD(Surface Mount Device). Since there is no lead in QFN, there are many defects on solder. Therefore, we propose an efficient mechanism for QFN solder defect detection at this paper. For this, we employ Convolutional Neural Network(CNN) of the Machine Learning algorithm. QFN solder's color multi-layer images are used to train CNN. Since these images are 3-channel color images, they have a problem with applying to CNN. To solve this problem, we used each 1-channel grayscale image(Red, Blue, Green) that was separated from 3-channel color images. We were able to detect QFN solder defects by using this CNN. Later, further research is needed to detect other QFN.

키워드

Machine Learning, Convolutional Neural Network, QFN, Dicing, Punch

1. 서 론

QFN(Quad Flat No-leads package)은 SMD(surface-mount devices)의 한 종류로써 리드(lead)가 없는 칩을 의미한다. QFN은 <그림 1>과 같다. 리드란 IC칩을 쉽게 납땜할 수 있게 해주는 부분이라고 볼 수 있다. QFN은 이러한 리드가 없기 때문에 납땜을 하는데 있어서 많은 어려움이 있고, 실제로 많은 불량이 나타나고 있다. 그렇고 해서 이 작업을 수작업으로 할 수도 없는 일이다. 점차적으로 산업이 자동화되고 있는 시기에, 이런 납땜을 수작업으로 하기는 많은 비용과

시간이 들기 때문이다. 또 이전까지는 QFN의 납땜에 대한 불량을 자동으로 검출하기 위한 연구가 활발히 이루어지지 않았다. 따라서 본 논문에서는 QFN의 납땜에 대한 불량 검출 방법을 제안하고자 한다.



그림 1. QFN(Quad Flat No-leads package)

II . Convolutional Neural Network

1989년에 Yann LeCun과 그의 동료들은 오류역전과 알고리즘(Backpropagation algorithm)에 기반하여 우편물에 손으로 쓰인 우편번호를 인식하는 deep neural networks를 소개했다. 알고리즘이 성공적으로 동작했음에도 불구하고, 신경망 학습에 소요되는 시간(10개의 숫자를 인식하기 위해 학습하는 시간)이 거의 3일이 걸렸고 이것은 다른 분야에 일반적으로 적용되기에는 비현실적인 것으로 여겨졌다. 하지만 하드웨어가 발전하고 기존 인공신경망 모델의 단점이 극복되면서 기계학습의 방법 중 하나인 neural network가 다시 떠오르고 있는 추세이다.[1] Convolutional Neural Network[2][3]은 이런 기계학습 방법 중 하나인 Multi-layer neural network[4]의 한 종류이다. 본 논문은 여러 Neural network중에서 Convolutional neural network를 선택하였는데, 그 이유로는 다음과 같다. 첫째, Convolutional neural network는 간단한 전처리를 통해 픽셀 이미지로부터 곧바로 시각적 패턴을 인식하도록 제작되었고, spatial topology를 잘 잡아내기 때문에 시각적인 분석 작업에 알맞기 때문이다. 둘째, Convolutional neural network는 가변성이 큰 패턴을 인식할 수 있고 영상의 찌그러뜨림이나 기하학적인 변화에 강건하기 때문이다. 이러한 이유로 본 논문에서는 QFN의 납땜에 대한 불량 검출을 위해 Convolutional neural network를 선정하였다. 일반적인 Convolutional neural network는 두 개의 convolution layer와 두 개의 fully connected layer로 구성 되어있다. convolution layer는 feature extractor의 역할을 하고, fully connected layer는 classifier의 역할을 한다. <그림 2>는 Convolutional neural network 구조의 한 예이다.

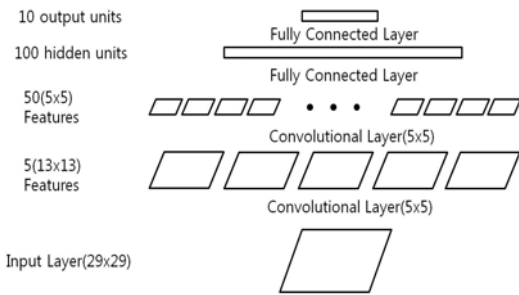


그림 2. Convolutional Neural Network의 구조 예

본 논문의 Convolutional neural network의 구조는 일반적인 구조와 달리 Input layer에 세 개의 영상이 들어간다. 이 구조를 도식화하면 <그림 3>과 같다.




그림 3. 제안된 Convolutional neural network 구조

Input layer에는 29×29 크기의 세 영상이 들어가고, 두 번째 layer와 세 번째 layer는 Convolutional layer로써 각각 13×13 크기의 feature map 6개, 5×5 크기의 feature map 50개로 되어있다. 또, Convolution layer에서 convolution 연산을 위해 5×5 크기의 마스크를 사용하였다. 다음으로, Fully connected layer에서는 각각 1×1 크기의 100개, 2개의 units로 되어 있다. 최종단인 2개의 output units는 입력 영상에 대해 정상, 불량에 대한 확률이 나오게 된다. 결국 이 확률을 이용하여 정상인지 불량인지를 판 가름하게 된다. <그림 3>에서 선으로 표현이 된 것은 각 layer에서 neuron들의 connection을 의미하고, 각 connection에는 이전 layer의 neurons에서 오는 값으로부터 현재 layer의 neurons의 값을 결정하는 가중치가 존재하게 된다. 가중치를 구하기 위한 Activation Function으로는 Lecun의 논문 [2]에 따라 hyperbolic tangent를 사용하고 있다.




그림 4. hyperbolic tangent graph

그 이유로는 hyperbolic tangent는 <그림 4>와 같이 완벽한 대칭성을 띄고 있고, derivative를 얻기에 쉽기 때문이다.[5]

III. 입력 데이터

앞서 설명했듯이, 제안한 시스템의 입력 영상으로 29×29 크기 세 개의 이미지가 들어가게 된다. 각각의 이미지는 하나의 컬러 이미지로부터 분리가 된 것이며, 이 컬러 이미지는 컬러 다단 영상을 의미한다. 컬러 다단 영상을 얻는 방법은 Red, Green, Blue 세 가지 색의 조명의 높이를 달리하여 설치 후, 각각을 돌아가며 비추게 한다. 각 조명을 비추어 얻은 세 개의 영상을 하나의 컬러 영상으로 합친 것이 바로 컬러 다단 영상이 된다. 따라서 컬러 다단 영상에는 높이에 대한 정보가 들어있게 된다. 이제 이 컬러 다단 영상을 제안한 Convolutional neural network에 적용시키기 위하여 Red, Green, Blue 세 개의 채널로 분리시킨다. 이렇게 분리시킨 영상이 <그림 3>의 Input layer에 들어가게 된다. 컬러 다단 영상과 Input layer에 들어가는 영상의 예는 <그림 5>에 나온 것과 같다.



그림 5. 좌측부터 컬러 다단 영상, Red, Green, Blue 영상




그림 6. 데이터 예

<그림 6>은 입력 데이터들의 예를 보여주고 있다. 상단부터 Dicing 정상, 불량, Punch 정상, 불량을 보여주고 있다. 영상들을 보면 QFN 종류와 정상, 불량에 따라 색상정보가 확연히 차이 나는 것을 확인할 수 있다. 이는 본 논문에서 제안하는 Convolutional neural network에 데이터를 학습시키는데 적절한 feature라고 볼 수 있다.

IV. 실험 결과

본 논문에서는 QFN의 종류인 Dicing과 Punch에 대하여 실험을 하였다. 실험을 위한 전체 데이터의 개수는 Dicing 229개(정상 201개, 불량 28개), Punch 144개(정상 137개, 불량 7개)이며 학습 세트와 테스트 세트의 비율을 조정하면서 실험을

진행하였다. 테스트를 위한 프로그램은 Windows 7(64bit), Microsoft Visual Studio 2010의 환경에서 개발하였다. Dicing에 대한 결과는 <표 1>, Punch에 대한 결과는 <표 2>와 같다.

표 1. Dicing에 대한 실험 결과

	Training set		Testing set		Epoch
	개수	에러율	개수	에러율	
1	171	0%	58	0%	4
2	150	0%	79	0%	3
3	115	0%	114	0%	3

표 2. Punch에 대한 실험 결과

	Training set		Testing set		Epoch
	개수	에러율	개수	에러율	
1	107	0%	37	0%	3
2	94	0%	50	0%	3
3	73	0%	71	0%	3

결과를 보면 3~4번의 epoch만큼만 학습을 시켰는데도 불구하고 에러율이 0%가 나오는 것을 확인할 수 있고, 이는 제안한 방법이 QFN 납땜의 불량 검출에 매우 적절하다고 볼 수 있게 해준다.

V. 결 론

본 논문에서는 납땜 하는 부분이 없는 QFN의 납땜 상태에 대한 불량 검출을 하기 위해 Convolutional neural network를 적용하는 방법을 제안하였다. 제안한 방법으로 QFN 중에서도 Dicing과 Punch에 대하여 아주 성공적으로 검출하는 것을 확인할 수 있었다. 하지만 QFN의 다른 종류들에 대한 추가적인 실험이 필요하고, 실험에 쓰인 Dicing과 Punch 데이터의 개수를 대폭적으로 증가하여 실험을 해보아야 할 것이다. 이러한 점이 보완 된다면 QFN 납땜 불량 검출을 매우 성공적으로 할 수 있을 것이다.

참고문헌

- [1] https://ko.wikipedia.org/wiki/%EB%94%A5_%E-B%9F%AC%EB%8B%9D
- [2] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-Based Learning Applied to Document Recognition", Proceedings of the IEEE, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
- [3] Patrice Y. Simard, Dave Steinkraus, John Platt, "Best Practices for Convolutional Neural

Networks Applied to Visual Document Analysis“, External Link International Conference on Document Analysis and Recognition (ICDAR), IEEE Computer Society, Los Alamitos, pp. 958-962, 2003.

[4] Richard O. Duda, Peter E. Hart, David G. Stork, “Pattern Classification” , 1973.

[5] <http://www.codeproject.com/Articles/16650/Neural-Network-for-Recognition-of-Handwritten-Digit>