

레터논문 (Letter Paper)

방송공학회논문지 제26권 제6호, 2021년 11월 (JBE Vol.26, No.6, November 2021)

<https://doi.org/10.5909/JBE.2021.26.6.809>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

전이학습 기반의 CNN을 이용한 컨포멀 코팅 PCB에 발생한 기포 검출 방법

이동희^{a)}, 조성령^{b)}, 정경훈^{a)}, 강동욱^{a)‡}

A Bubble Detection Method for Conformal Coated PCB Using Transfer Learning based CNN

Dong Hee Lee^{a)}, SungRyung Cho^{b)}, Kyeong-Hoon Jung^{a)}, and Dong Wook Kang^{a)‡}

요 약

PCB를 코팅하는 과정에서 기포가 발생하면 회로 오작동의 원인이 되기 때문에 기포 검출은 컨포멀 코팅 검사에서 매우 중요한 작업이다. 이전 연구에서는 기포의 밝기 특성을 이용하여 기포의 후보를 추출하고, 합성곱 신경망(CNN: Convolutional Neural Networks)을 이용하여 추출된 후보를 검증하였다. 본 논문에서는 전이학습 기반의 합성곱 신경망 모델을 이용하여 기포를 검출하는 방법을 제안한다. 이를 위해 합성곱 신경망 모델로 VGGNet을 사용하고, 분류층(Classification Layer)으로 시그모이드(Sigmoid)를 적용하였으며, 마지막 합성곱층(Convolutional Layer)과 분류층을 함께 학습하는 전이학습 방법을 적용하였다. 제안하는 방법의 기포 검출 성능은 F1-score 0.9044로서 이전 연구 대비 약 0.17의 개선 효과를 나타내었다.

Abstract

Air bubbles which may be generated during the PCB coating process can be a major cause of malfunction. so it is necessary to detect the bubbles in advance. In previous studies, candidates for bubbles were extracted using the brightness characteristics of bubbles, and the candidates were verified using CNN(Convolutional Neural Networks). In this paper, we propose a bubble detection method using a transfer learning-based CNN model. The VGGNet is adopted and sigmoid is used as a classification layer, and the last convolutional layer and classification layer are trained together when transfer learning is applied. The performance of the proposed method is F1-score 0.9044, which shows an improvement of about 0.17 compared to the previous study.

Keyword : Transfer Learning, CNN, Bubble Detection, Conformal Coating, VGGNet

a) 국민대학교 전자공학부(Kookmin University, School of Electronics)

b) (주)임팩 엔터프라이즈(IMPEC Enterprise Co., Ltd.)

‡ Corresponding Author : 강동욱(Dong Wook Kang)

E-mail: dwkang@kookmin.ac.kr

Tel: +82-2-910-5394

ORCID: <https://orcid.org/0000-0001-7388-1927>

※ This work was supported by IMPEC Enterprise Co., Ltd.

※ This work was supported by the Technology development Program(S3142665) funded by the Ministry of SMEs and Startups(MSS, Korea)

· Manuscript received October 13, 2021; Revised November 16, 2021; Accepted November 16, 2021.

Copyright © 2021 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

1. 서론

컨포멀 코팅은 먼지, 습기 등의 외부요인으로부터 PCB를 보호하는 기술이다. 코팅 과정에서 발생하는 기포는 코팅이 벗겨질 수 있기 때문에 회로 오작동의 원인이 된다. 코팅의 품질 유지를 위해 기포를 검출하는 작업은 매우 중요한 작업이다. 이전 연구에서는 기포의 밝기 특성을 이용하여 기포의 후보 영역을 추출하고, 합성곱 신경망(CNN: Convolutional Neural Networks)을 적용하여 추출된 후보를 검증하였다^[1].

본 논문에서는 전이학습(Transfer Learning) 기반의 합성곱 신경망 모델을 이용하여 기포를 검출하는 방법을 제안한다. 전이학습을 위한 합성곱 신경망 모델로 VGGNet^[2]을 사용하였고, 기포 검출을 위한 최적의 분류층(Classification Layer)으로 시그모이드(Sigmoid)를 적용하였다. 전이학습은 일반적으로 분류층만 학습하지만 논문에서는 전이학습의 기포 검출 성능을 개선하기 위해서 분류층과 마지막 합성곱층(Convolutional Layer)을 함께 학습한 모델을 제안한다. 다음 절에서 VGGNet과 전이학습 그리고 학습 데이터를 설명하고, 마지막 절에서 전이학습 기반의 기포 검출 결과를 기술한다.

II. 본론

1. VGGNet과 전이학습

VGGNet은 합성곱층의 수에 따라 A, A-LRN, B, C, D, E의 버전이 있고, 논문에서는 VGG19(E)를 사용하였다. VGG19는 그림 1과 같이 16개의 합성곱층과 3개의 FC (Fully Connected layer)층으로 구성되고, 분류층으로 소프트맥스(Softmax)를 사용한다. VGGNet은 1,000가지 사물을 분류하는 모델이지만 코팅 과정에서 발생하는 기포는 범주에 없으므로 모델을 새로 학습해야 한다. 이는 다양한 학습 파라미터를 적용하여 모델을 학습하는 것을 말하며, 다수의 학습 과정을 반복하기 때문에 시간이 오래 걸린다. 또한 높은 성능을 만족하기 위해서는 충분한 데이터가 필요하다. 이러한 문제를 해결하기 위해 전이학습을 적용한다. 전이학습은 그림 2와 같이 적은 수의 데이터로 모델을

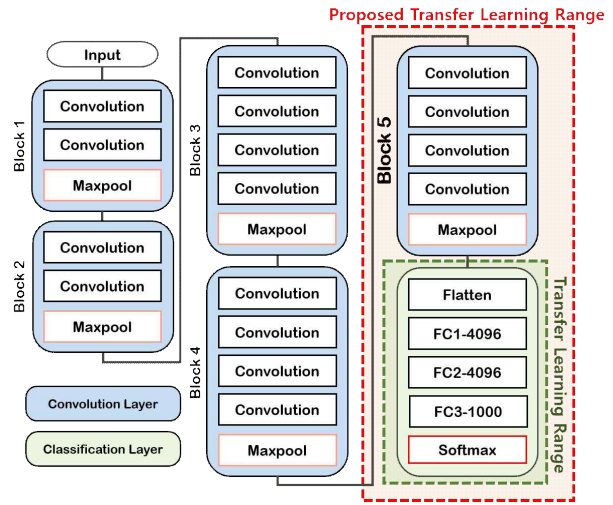


그림 1. VGG19의 구조
Fig. 1. Structure of VGG19

학습할 때 충분한 양의 데이터로 학습한 모델, 즉 사전 학습된 모델(Pre-trained model)을 사용할 수 있다. 사전 학습된 모델의 가중치를 합성곱층에 적용하고, 새로운 데이터에 대해 특징을 추출한다. 그리고 추출된 특징을 기반으로 분류층만 새로 학습하는 것을 전이학습이라 한다. 전이학습은 데이터가 소량인 새로운 클래스에 대해서 단시간 내에 높은 성능을 얻을 수 있기 때문에 많이 활용되고 있다.

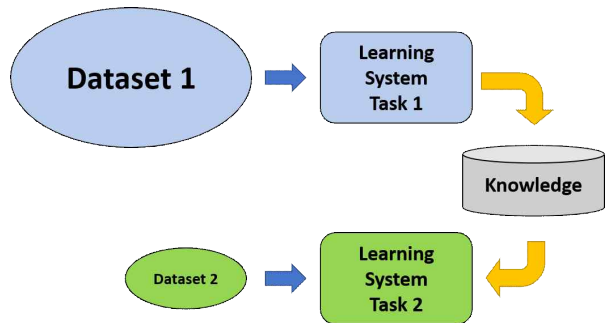


그림 2. 전이학습과 사전 학습된 모델
Fig. 2. Transfer Learning and Pre-trained model

논문에서는 분류층에 따라 전이학습의 성능 차이가 발생할 수 있으므로 기포 검출에 적합한 분류층을 구하였다. 그림 3과 같이 구성하여 분류층으로 소프트맥스와 시그모이드, 그리고 기계학습 방법의 하나인 서포트 벡터 머신(SVM, Support Vector Machine)을 적용하였다. 최적의 분

류층은 전이학습의 기포 검출 성능을 통해 정하였고, 전이 학습을 적용한 결과 시그모이드 분류층의 기포 검출의 성능이 가장 우수하였다. 그러나 논문에서는 전이학습의 성능 개선을 위해 학습 영역을 그림 1처럼 시그모이드 분류층과 마지막 합성곱층인 Block 5를 포함하여 학습한 모델을 제안한다. Block 5는 가장 많은 가중치를 포함하고 있기 때문에 특징 추출에 가장 중요한 합성곱층이다. 그러므로 새로운 데이터에 대해서 Block 5를 미세 조정(Fine-Tune)하여 모델의 성능을 개선하였다. 전이학습에 따른 자세한 실험 결과는 3절에 기술하였다.




그림 3. 분류층 (a) 소프트맥스 (b) 시그모이드 (c) 서포트 벡터 머신
 Fig. 3. Classification Layer (a) Softmax (b) Sigmoid (c) SVM

2. 학습 데이터

일반적인 기포는 원 모양으로 발생하지만 컨포멀 코팅 과정에서 발생하는 기포는 크기가 다양하고 비정형으로 발생한다. 특히 비정형 기포는 MCU 주위에서 발생하는데 PCB의 수가 한정적이기 때문에 데이터의 수가 부족하다. 논문에서는 비정형 기포의 데이터 부족 문제를 전이학습을 통해 해결하였다. 데이터 획득을 위해 그림 3의 (a)와 같은 환경에서 UV(Ultra Violet) 조명 일체형 카메라를 이용하여

영상을 획득한다. 그림 4의 (b)는 획득한 컨포멀 코팅 영상이고, 그림 4의 (c)는 영상에서 추출한 기포 데이터이다. 기포가 아닌 데이터는 기포가 없는 위치에서 무작위로 생성하였고, 기포 영상 17,500개, 기포가 아닌 영상 17,500개 총 35,000개의 학습 데이터를 만들었다.

III. 실험 및 결과

1. 학습

35,000개의 데이터에 대해서 훈련 세트(Training Set) 19,600개, 검증 세트(Validation Set) 8,400개, 시험 세트(Test Set) 7,000개를 구성하였다. 또한 수평 및 수직 방향 대칭에 대해서 데이터 증식(Data Augmentation)을 적용하여 데이터의 수를 증가시켰다. 전이학습에 사용된 사전 학습된 모델은 ImageNet^[3]을 적용하였고, 학습 파라미터로 옵티마이저(Optimizer)는 아담(Adam)을 사용하였다. 그리고 학습률(Learning rate)은 실험을 통해 모델마다 다르게 적용하였다. 실험마다 시험 세트에 대해서 정확도(Accuracy) 0.99 이상, 손실(Loss) 0.06 이하가 나왔기 때문에 성능 비교를 위해 MCU 주변에서 기포 영상 325개, 기포가 아닌 영상 325개 총 650개의 성능 평가용 데이터를 획득하여 성능을 비교하였다.

2. 분류층에 따른 전이학습의 기포 검출 성능

시그모이드, 소프트맥스, 서포트 벡터 머신 등 분류층에 따른 기포 검출의 성능 비교를 위해 650개의 영상에 대해서




그림 4. (a) 영상 취득 장비 (b) 컨포멀 코팅 영상 (c) 기포 데이터
 Fig. 4. (a) Image acquisition equipment (b) Conformal coating image (c) Bubble data

표 1. 분류층에 따른 전이학습의 기포 검출 결과

Table 1. The bubble detection result of transfer learning methods according to classification layer

Classification layer	F1-Score (Without Transfer Learning)	TP	FP	TN	FN	Accuracy	Precision	Recall	F1-Score
Sigmoid	0.7314[1]	244	81	322	3	0.8708	0.9879	0.7508	0.8532
Softmax	0.7117	245	80	314	11	0.8600	0.9570	0.7538	0.8433
SVM	-	205	120	323	2	0.8123	0.9903	0.6308	0.7707

표 2. 합성곱층과 분류층을 학습한 전이학습의 기포 검출 결과

Table 2. The bubble detection result of transfer learning methods that learned classification and convolution layers

Base model VGG19 (Classification layer : Sigmoid)	TP	FP	TN	FN	Accuracy	Precision	Recall	F1-Score
Block5 & Classification Layer Transfer Learning	279	46	312	13	0.9092	0.9555	0.8585	0.9044
Classification Layer Transfer Learning	244	81	322	3	0.8708	0.9879	0.7508	0.8532
Without Transfer Learning[1]	207	118	291	34	0.7662	0.8589	0.6369	0.7314

TP(True Positive), FP(False Positive), TN(True Negative), FN(False Negative)을 구하고, Precision, Recall, F1-score 등의 결과를 표 1에 정리하였다. 서포트 벡터 머신 실험에서는 RBF(Radial Basis Function) 커널을 사용하여 FC1의 출력을 특징으로 학습하였다. 실험 결과 시그모이드 분류층을 사용한 모델의 성능이 가장 우수하였다. 또한 분류층의 종류와 관계없이 전이학습을 적용함으로써 성능이 향상됨을 확인하였다.

3. 합성곱층을 포함한 전이학습의 기포 검출 성능

합성곱층과 분류층을 학습한 전이학습 모델, 분류층만 학습한 전이학습 모델 그리고 전이학습을 적용하지 않은 모델^[1]의 성능을 표 2에 정리하였다. 그림 1의 마지막 합성곱층 Block 5와 분류층을 학습한 전이학습 모델의 성능이 가장 우수하였고, 전이학습을 적용하지 않은 모델보다 F1-score가 약 0.17 개선되었다. 또한 표에는 없지만 합성곱층의 범위를 Block 4부터 Block 1 등의 넓은 범위까지 전이학습을 적용한 결과 학습 시간이 오래 걸리고, 제안하는 방법보다 성능이 개선되지 않았다. 마지막으로 그림 5는 제안하

는 방법을 적용했을 때 개선되는 분류 결과를 보여준다. 전이학습을 적용하지 않은 모델에서 잘못 분류된 비정형 기포, MCU 다리, PCB 패턴 등이 올바르게 분류되었다.

IV. 결론

본 논문에서는 전이학습 기반의 합성곱 신경망 모델을 이용하여 컨포멀 코팅 과정에서 발생하는 기포를 검출하였다. 합성곱 신경망 모델로 VGGNet을 사용하였으며, 실험을 통해 기포 검출을 위한 최적의 분류층으로 시그모이드를 적용하였다. 650개의 영상에 대해서 분류한 결과 분류층만 학습한 전이학습 모델은 F1-score 0.8532의 성능을 보였으며, 논문에서 제안하는 분류층과 마지막 합성곱층을 학습한 전이학습 모델은 F1-score 0.9044의 성능으로서 이전 연구 대비 약 0.17의 개선 효과를 보였다.

참고 문헌 (References)

- [1] D. Lee, S. Cho, K. Jung and D. Kang, "A problematic bubble detection algorithm for conformal coated PCB using convolutional neural networks", Journal of Broadcast Engineering, Vol 26, No.4, pp.409-418, July 2021.
- [2] Karen Simonyan, Andrew Zisserman, "Very deep convolutional networks for large-scale image recognition", arXiv:1409.1556, pp.1-14, 2015.
- [3] J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," IEEE Conference, Computer Vision and Pattern Recognition, Miami, USA, pp. 248 - 255, June 2009.




그림 5. 개선된 분류 결과

Fig. 5. Improved bubble detection results