



• 특집 • 정밀 설계와 재료 기술을 활용한 제조 혁신

# 인공지능 기반 유연전자소자 결함 진단 모델 개선을 위한 데이터 규모 및 학습 파라미터 영향 분석

## Analysis of the Effects of Data Scale and Training Parameters on Improving AI-based Defect Diagnosis Models for Flexible Electronic Devices

유진호<sup>2</sup>, 김진걸<sup>1</sup>, 시바란지니 모하난<sup>1</sup>, 이종수<sup>1,2#</sup>  
Jinho Yoo<sup>2</sup>, Jingeol Kim<sup>1</sup>, Sivaranjini Mohanan<sup>1</sup>, and Jongsu Lee<sup>1,2#</sup>

<sup>1</sup> 국립순천대학교 첨단부품소재공학과 (Department of Advanced Components and Materials Engineering, Suncheon National University)

<sup>2</sup> 국립순천대학교 첨단신소재공학과 (Department of Advanced Materials Engineering, Suncheon National University)

# Corresponding Author / E-mail: ljs8755@gmail.com, TEL: +82-61-750-5264

ORCID: 0000-0001-9868-7266

KEYWORDS: Artificial intelligence (인공지능), Flexible electronics (인쇄전자), Printing (인쇄), Coating (코팅), Training data (학습데이터), Hyperparameter (하이퍼파라미터)

*Flexible electronics are becoming the next generation of devices due to their advantages, such as mechanical flexibility, eco-friendliness, large-area applicability, and scalability for mass production. However, solution-based manufacturing processes are prone to defects like discontinuities and local smudging, which can significantly degrade both device quality and yield. To tackle these challenges, rapid and accurate defect classification is crucial for real-time diagnosis during manufacturing. This study investigates the impact of data scale and key training hyperparameters on the performance of deep learning-based defect diagnosis models, using a dataset of conductive pattern defects in flexible electronics. We specifically examine how the number of training images affects model accuracy and generalization, and we analyze how adjustments to hyperparameters—such as L2 regularization and dropout—influence model performance in data-limited scenarios. Our findings offer insights into optimal training strategies tailored to different data scales and learning constraints, providing practical guidelines for designing and developing AI-based defect diagnosis models for flexible electronic devices.*

Manuscript received: December 11, 2025 / Revised: January 15, 2026 / Accepted: January 25, 2026

### NOMENCLATURE

Cost = Cost Function  
 $y$  = Actual Label  
 $x$  = Input Data  
 $w$  = Weight  
 $N$  = Number of Data

$M$  = Number of Features  
 $\lambda$  = Regularization Coefficient  
TP = True Positive  
TN = True Negative  
FP = False Positive  
FN = False Negative

## 1. 서론

유연 전자소자는 우수한 기계적 유연성, 친환경 공정성, 대면적 구현 가능성, 그리고 대량 생산 적합성과 같은 장점으로 인해 차세대 전자소자로 주목받고 있다. 그러나 용액 공정을 기반으로 하는 유연 전자소자 제조 과정에서는 단선(Discontinuity), 번짐(Smearing) 등 소자 구성 부품의 성능을 저하시킬 수 있는 다양한 인쇄 및 코팅 결함이 발생하며, 이는 소자의 품질 저하와 수율 감소로 직결되는 중요한 문제이다[1-3]. 이러한 이유로 제조 공정의 안정성과 소자 신뢰성을 확보하기 위해서는 부품 결함을 정밀하게 검출하고 부품 품질을 평가할 수 있는 효과적인 검사 기술의 중요성이 더욱 부각되고 있다. 인력에 의존한 육안 검사는 검사 효율이 낮고 작업자의 피로 누적으로 정확도가 저하되기 때문에, 현대 제조 산업이 요구하는 고품질·고신뢰성 기준을 충족하기 어렵다[4]. 반면, 딥러닝을 포함한 머신비전 기반 검사 기술은 고정밀·고효율·비파괴 검사를 가능하게 하여 생산성과 품질 신뢰성을 획기적으로 향상시킬 수 있는 유력한 대안으로 부상하고 있다. 특히 롤투롤(Roll-to-Roll) 공정과 같이 전자 소자의 연속 생산 공정에서는 생산 중 결함이 지속적으로 발생할 경우 이를 신속히 감지하고, 공정 조건을 개선하거나 필요 시 장비를 정지시켜야 하므로, 제조 과정에서 발생하는 결함을 실시간으로 탐지하고 분류할 수 있는 고속·고정밀 결함 분류기의 개발이 필수적이다.

최근 이러한 문제를 해결하기 위해 딥러닝 기반 결함 진단 모델에 대한 연구가 활발히 진행되고 있다. M. Bhatt 등은 딥러닝 기반 표면 결함 탐지 기술들을 학습 방법 및 모델 아키텍처의 관점에서 체계적으로 분류하고 분석하였다[5]. Gafurov 등은 롤투롤 스크린 인쇄 공정에서 발생하는 스미어링(Smearing) 결함을 정량적으로 분석하기 위해 U-Net 기반 의미론적 분할 모델을 개발하고 그 유효성을 입증하였다[6]. Masci 등은 강판(Steel) 표면의 미세 결함을 분류하기 위해 Max-pooling 기반의 CNN 모델을 제안하여 기존 분류기 대비 우수한 성능을 확인하였다[7]. Chen 등은 태양광 패널의 표면 결함을 정밀하게 검출하기 위해 다중 분광(Multispectral) 이미지를 활용한 CNN 모델을 구축한 바 있다[8]. Adibhatla 등은 인쇄회로기판(PCB) 제조 공정에 YOLO (You Only Look Once) 네트워크를 적용하여 결함 탐지의 정확도와 속도를 동시에 확보하였다[9]. Jing 등은 웹(Web) 기반의 직물(Fabric) 제조 공정에서 개선된 YOLOv3 모델을 활용하여 다양한 형태의 직물 결함을 효과적으로 분류할 수 있음을 보였다[10].

딥러닝 모델의 성능은 학습에 사용되는 데이터의 절대적 규모와, 과적합을 방지하기 위한 L2 정규화(Regularization) 및 드롭아웃(Dropout)과 같은 하이퍼파라미터 설정에 크게 영향을 받는다[11]. 특히 실제 산업 현장에서는 결함 데이터를 대규모로 확보하기 어려우며 [12-14], 이러한 환경에서는 모델이 학습 데이터에 과도하게 적합되는 과적합(Overfitting)이 쉽게 발생한다. 그 결과 학습 정확도는 높으나 검증 정확도는 낮은 일반화 격차

(Generalization Gap)가 확대되어, 실제 공정 적용 시 예측 신뢰도와 운용 안정성이 크게 저하된다. 따라서 실시간 결함 진단 모델의 신뢰성과 안정성을 확보하기 위해서는, 진단 대상의 특성에 부합하는 적정 데이터 규모를 규명하고 이를 기반으로 하이퍼파라미터를 최적화하여 일반화 성능을 극대화하는 전략이 요구된다.

본 연구에서는 샘플링 및 광학 장비 기반 측정을 통해 확보할 수 있는 마이크로 스케일의 미세 전도성 패턴 결함 이미지 데이터를 625장부터 5,000장까지의 범위로 구성하여, 학습 데이터 규모 변화에 따른 딥러닝 모델의 성능 특성을 분석하였다. 또한 이러한 ‘제한된 데이터 환경’에서 하이퍼파라미터 최적화가 일반화 격차 및 모델 성능 개선에 미치는 영향을 분석하였다.

## 2. 연구 방법

### 2.1 정규화 기법

본 연구에서는 제한된 데이터 환경에서 일반화 성능을 향상시키기 위해, 대표적인 정규화 기법인 L2 정규화와 드롭아웃을 주요 변수로 설정하였다.

#### 1) L2 정규화

L2 정규화는 가중치 감쇠(Weight Decay)라고도 불리며, 모델의 손실 함수(Loss Function)에 가중치의 크기에 비례하는 페널티 항을 추가하는 방식으로 작동한다. L2 정규화가 적용된 최종 비용 함수(Cost Function)는 식(1)과 같다.

$$Cost = \sum_{i=0}^N (y_i - \sum_{j=0}^M x_{ij} w_j)^2 + \lambda \sum_{j=0}^M |w_j| \quad (1)$$

L2 정규화를 통해 학습 과정에서 가중치 ‘w’의 값이 과도하게 커지는 것을 억제하여, 가능한 한 작은 값을 유지하도록 유도한다. 가중치가 작게 유지된 모델은 입력 데이터의 미세한 노이즈에 덜 민감하게 반응하며, 보다 단순하고 매끄러운 결정 경계(Decision Boundary)를 형성하게 된다. 이러한 특성은 학습된 모델의 일반화 성능 향상에 기여할 수 있다.

#### 2) 드롭아웃

드롭아웃은 학습 과정에서 각 뉴런을 일정 확률로 무작위로 비활성화하는 정규화 기법이다. 이는 매 학습 반복마다 서로 다른 형태의 얇아진 네트워크(Subnetwork)를 학습시키는 효과를 가져온다. 이 과정에서 개별 뉴런은 특정 뉴런에 과도하게 의존할 수 없게 되며, 그 결과 모델은 보다 견고하고 일반화된 특징을 학습하도록 유도된다.

### 2.2 결함 진단 모델 구축

본 연구에서는 이미지 데이터 규모가 결함 진단 모델 성능에 미치는 영향을 분석하였으며, 나아가 모델 설계 과정에서 과적합을 방지하기 위한 핵심 하이퍼파라미터인 L2 정규화 계수와 일반화

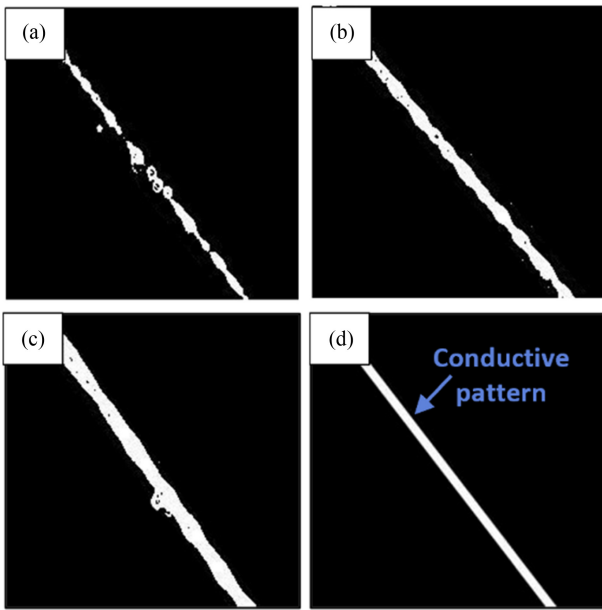


Fig. 1 Defects in micro-scale conductive patterns: (a) Discontinuity, (b) Edge waviness, (c) Local smudging, and (d) Normal

Table 1 Model training conditions

Initial learning rate	0.01
Max epoch	60
Number of images for training and validation	625, 1250, 2500, 5000
Dropout rate	0.1, 0.2, 0.3, 0.4
L2 regularization parameter	0.0001, 0.0002, 0.0003, 0.0004

성능 향상을 위한 드롭아웃 비율의 변화가 모델 성능에 어떠한 영향을 미치는지 분석하였다. L2 정규화 계수와 드롭아웃은 각각 가중치 감쇠와 노드 비활성화를 통해 모델의 복잡도를 독립적으로 제어할 수 있는 대표적인 하이퍼파라미터로, L2 정규화는 가중치(Weight)의 크기를 제한하여 모델의 복잡도를 물리적으로 억제하고, 드롭아웃은 네트워크 유닛의 일부를 무작위로 비활성화하여 특정 특징에 대한 과도한 의존성을 줄일 수 있다는 특징이 있다[16,17].

결함 진단을 위한 타겟 패턴은 마이크로 스케일의 미세 전도성 패턴(Conductive Pattern)으로 해당 패턴에서 발생하는 주요 결함인 단선(Discontinuity), 가장자리 불균일(Edge Waviness), 국부적 퍼짐(Local Smudging) 을 포함한다[1,3]. 본 결함들은 설계 패턴에 대한 제작 패턴의 색상, 명암 및 질감 차이보다 설계 패턴 형상에 대한 인쇄 패턴 형상의 충실도 관점에서 의 진단이 필요하고, 결함 발생 시, 이미지 데이터에서 해당 결함이 명확히 표현되어야 한다. 이를 위해 본 연구에서는 본 연구에서는 수집된 RGB 이미지를 흑백(Grayscale) 이미지로 변환함으로써 미세 전도성 패턴의 재질 및 외부 조명에 의해 발생하는 가변적인 색상 정보를 제거하고, 모델이 패턴의 경계면과 형태적 특징에

집중할 수 있도록 데이터를 구성 하였다[18]. Fig. 1은 결함 진단에 활용된 미세 전도성 패턴에서의 대표적인 결함 이미지를 보여준다.

결함 진단 모델 구축을 위해 GoogLeNet 아키텍처를 활용하였다. GoogLeNet은 Inception 모듈을 통해 다양한 크기의 컨볼루션 필터를 병렬적으로 사용하여 미세 전도성 패턴 내 특정 결함에 대한 다양한 크기의 특징을 효과적으로 추출할 수 있다. 특히, 보조 분류기(Auxiliary Classifier)를 통해 경사 소실 문제를 완화하고, ResNet-50, VGGNet 등 타 모델 대비 연산 효율 높아 데이터의 양이 제한된 조건에서 모델이 과적합되는 것을 방지하고 높은 일반화 성능을 확보하는 데 유리하다는 장점이 있다 [19,20]. 먼저, 데이터 규모에 따른 모델 성능을 분석하기 위해 학습 및 검증 이미지 수를 최대 5,000장으로 설정하고 625장부터 5,000장까지 네 조건으로 구분하여 모델 학습을 수행하였다. 학습과 검증 데이터의 비율은 7 : 3으로 설정하였다. L2 정규화 계수와 드롭아웃 비율을 각각 0.0001-0.0004, 0.1-0.4 [4] 범위에서 네가지 레벨로 설정하여 하이퍼파라미터 변화가 모델 성능에 미치는 영향을 비교·분석할 수 있도록 학습 조건을 구성하였다. 모든 조건에서 초기 학습률(Initial Learning Rate)은 0.01, 최대 에포크(Max Epoch)는 60으로 설정하였다. Table 1은 본 연구에서 사용한 모델 학습 조건을 보여준다.

### 3. 결과 및 토의

#### 3.1 데이터 규모가 모델 성능에 미치는 영향

Fig. 2는 5,000장 이하의 제한된 데이터 환경에서 이미지 데이터 규모가 딥러닝 모델의 분류 성능에 미치는 영향을 보여준다 진단 성능은 분류정확도(Classification Accuracy) 로 산출할 수 있으며, 식(2)는 진단 성능을 평가하기 위한 함수를 보여준다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 (\%) \quad (2)$$

막대 그래프는 데이터 규모 별 평균 진단 정확도를, 오차 막대는 진단 정확도의 표준 편차를 보여준다. 분석 결과, 이미지 데이터 수가 625장일 때 평균 진단 정확도는 91.8%로 가장 낮았으며, 진단 정확도의 표준 편차는 4%로 안정성 또한 매우 낮음을 알 수 있다. 이미지 데이터 수를 1,250장으로 증가시킨 경우 평균 성능은 94.2%로 향상되었으나, 표준편차는 4.4%로 모델 진단 성능이 여전히 불안정함을 알 수 있다. 반면, 데이터 수가 2,500장일 때 평균 성능은 96.2%로 크게 향상되었으며, 표준 편차 또한 1.8%로 눈에 띄게 감소하여 성능이 안정화되었음을 확인하였다.

5,000장의 데이터를 사용한 경우 평균 성능은 96.4%, 표준편차는 1.4%로 나타났으며, 2,500장 조건과 비교해 성능은 향상되었지만 그 향상 폭은 매우 미미함을 확인할 수 있다.

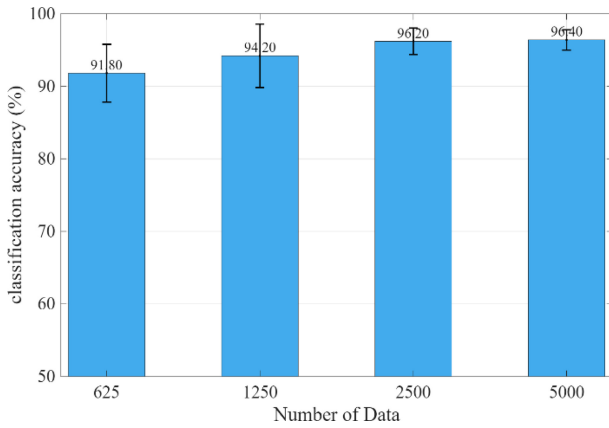


Fig. 2 Effect of date size on model performance according to the number of data

본 결과는 결합 진단 모델 구축 시, 학습·검증 데이터 수가 과도하게 적을 경우, 결합 진단 모델이 낮은 성능과 높은 불안정성을 보일 수 있음을 보여준다. 또한, 평균 95% 이상의 진단 성능과 2% 이하의 표준편차를 갖는 안정적인 모델을 확보하기 위해서는 최소 2,500장 이상의 데이터가 필요하며, 이러한 최소 데이터 요건을 충족하기 어려운 경우에는 모델의 진단 성능과 안정성을 보완할 수 있는 대안적 접근이 요구됨을 시사한다.

3.2 하이퍼파라미터 영향 분석

L2 정규화 파라미터와 드롭아웃 비율이 결합 진단 모델의 성능에 미치는 영향을 분석하고, 제한된 데이터 규모에서 발생하는 성능 및 안정성 저하를 보완할 수 있는지 여부를 확인하였다.

Figs. 3 과 4는 각각 데이터 규모 별 L2 정규화 파라미터와 드롭아웃 비율에 따른 진단 모델 성능을 보여준다. 막대 그래프는 데이터 규모 별 L2 정규화 파라미터 및 드롭아웃 비율에 따른 진단 정확도를, 선그래프는 데이터 규모 별 L2 정규화 파라미터 및 드롭아웃 비율에 따른 평균 진단 정확도를 보여준다.

Fig. 3은 L2 정규화 파라미터에 따른 모델 진단 성능 분석 결과로, 드롭아웃 비율은 0.2로 고정되었다.

본 그래프를 통해 이미지 데이터 수가 625장으로 매우 적은 경우, 결합 진단 모델 성능은 92% 이하로 L2 정규화 파라미터에 따른 진단 성능 차이가 미미한 반면, 1,250-5,000장의 경우, L2 정규화 파라미터 조절을 통해 진단 성능을 향상시킬 수 있음을 알 수 있다. 특히, 이미지 데이터 수가 1,250장인 조건에서 L2 정규화 계수를 0.0003 또는 0.0004로 설정한 경우 모델의 결합 진단 성능은 L2 정규화 계수 0.0002 대비 각각 4.5% (91.5% → 96%), 4% (91.5% → 95.5%) 향상되었으며, 이는 데이터 수가 2,500장인 조건에서 L2 정규화 계수를 0.0001 또는 0.0002로 적용했을 때보다 높은 성능을 나타내는 것으로 확인되었다.

Fig. 4는 드롭아웃 비율에 따른 진단 성능을 보여주며, L2 정규화 파라미터는 0.0002로 고정되었다. 이미지 데이터 수가 625장으로 매우 적은 경우, 결합 진단 모델 성능은 92% 이하로 드롭아웃 비율에 따른 진단 성능 차이가 미미한 반면, 1,250장

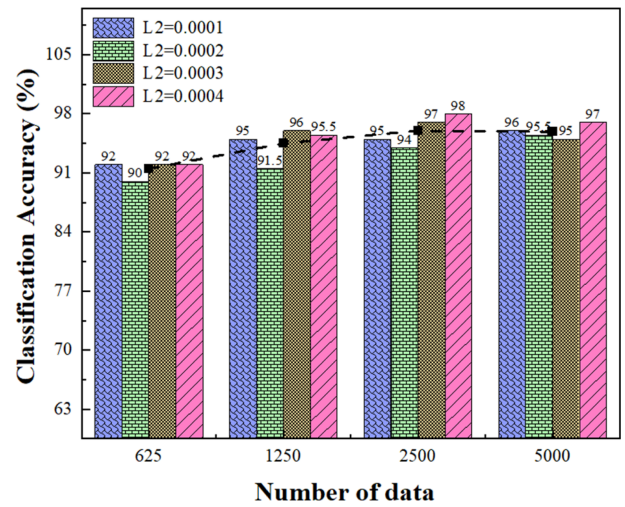


Fig. 3 Effect of L2 regularization parameter on model performance

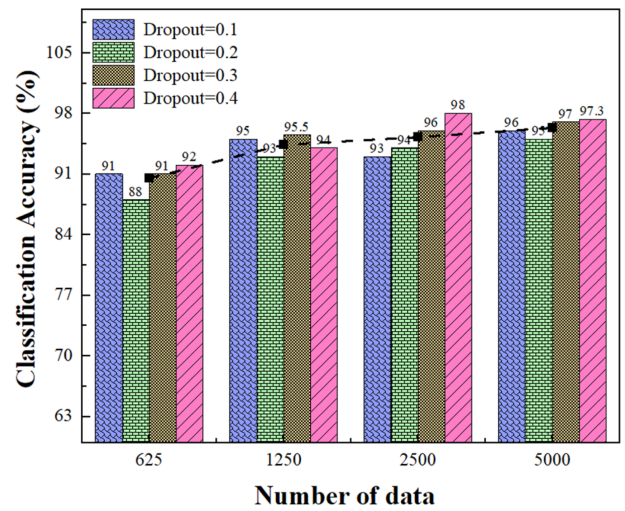


Fig. 4 Effect of dropout rate on model performance

이상에서는 L2 정규화 파라미터와 마찬가지로 드롭아웃 비율 조절을 통해 모델 성능을 향상시킬 수 있음을 알 수 있다.

특히, 이미지 데이터 수가 1,250장인 조건에서 드롭아웃 비율이 0.1, 0.3인 경우, 모델 성능은 드롭아웃 비율 0.2 대비 2% (93% → 95%), 2.5% (93% → 95.5%) 향상되었으며, 이는 데이터 수가 2,500장인 조건에서 드롭아웃 비율을 0.1 또는 0.2로 적용했을 때보다 높은 성능을 나타내는 것으로 확인되었다. 5,000장 이상 이미지 데이터에서는 모든 조건에서 95% 이상의 높은 진단 성능을 보이나, L2 정규화 파라미터 조절에 따른 성능 개선량은 최대 2%로 다른 조건들에 비해 낮음을 알 수 있다.

본 결과를 통해 L2 정규화 파라미터와 드롭아웃 비율 조절을 통해 제한된 데이터 규모로 인한 성능 저하를 보완할 수 있음을 확인하였다. 특히 데이터 수가 적은 경우에도 하이퍼파라미터 조절을 통해 더 많은 데이터를 사용한 조건보다 높은 성능을 확보할 수 있음을 확인하였으며, 이는 데이터 확보가 어려운 환경에서 적절한 하이퍼파라미터 설정이 모델 성능 향상에 기여할




Fig. 5 Generalization gap according to L2 regularization




Fig. 6 Generalization gap according to dropout

수 있음을 시사한다.

Figs. 5와 6은 각각 L2 정규화 파라미터 및 드롭아웃 비율에 따른 일반화 격차의 변화를 보여준다.

Figs. 5에서 드롭아웃 비율은 0.2로, 6에서 L2 정규화 파라미터는 0.0002로 고정되었다. Fig. 5에서 이미지 데이터 수가 625장인 경우, L2 정규화 파라미터에 따른 일반화 격차는 모두 5% 이상으로 높으며, L2 정규화 파라미터 조절에 따른 일반화 격차 개선량은 최대 0.8%로 미미함을 확인하였다. 반면, 이미지 데이터 수가 1,250장 이상인 경우, L2 정규화 파라미터 조절을 통해 모델 안정성을 향상시킴을 확인할 수 있다. 특히, 1,250장 조건에서 L2 정규화 파라미터가 0.0001일 때 일반화 격차는 6%로 나타나 높은 과적합 경향을 보이는 반면, 0.0004로 설정 시 일반화 격차가 2.8%로 감소함을 확인하였으며[15], 특히, 데이터 수가 2,500장인 조건에서 L2 정규화 파라미터를 0.0002 또는 0.0004로 적용했을 때보다 높은 모델 안정성을 보이는 것으로

확인되었다. 이는 조정된 L2 정규화 파라미터에 따른 가중치 감소(Weight Decay)가 모델의 복잡도를 효과적으로 제어하여 과적합을 억제하였음을 의미한다[15].

이미지 데이터 수가 5,000장인 경우, 모델 안정성은 3.5% 이하로, 다른 조건들에 비해 모델 안정성이 높으나, L2 정규화 파라미터 조절에 따른 모델 안정성 개선율은 최대 0.8%로 다른 조건들에 비해 낮음을 확인할 수 있다.

Fig. 6은 드롭아웃 비율에 따른 일반화 격차의 변화를 나타낸다. 그래프를 통해 이미지 데이터 수가 625장인 경우에도 드롭아웃 비율 조절을 통해 모델 안정성이 개선됨을 알 수 있으며, 이미지 데이터 수가 1,250장인 경우 드롭아웃 비율에 따라 최대 2.9% (7%→4.1%), 2,500장인 경우 최대 1.4% (4.4%→3%) 개선됨을 확인할 수 있다. 특히, 이미지 데이터 수가 1,250장인 조건에서 드롭아웃 비율을 0.3으로 설정한 경우, 데이터 수가 2,500장이고 드롭아웃 비율이 0.1인 조건과 비교하여 모델 안정성은 동등한 수준을 유지하면서도 더 우수한 진단 성능을 확보할 수 있음을 확인하였다. 한편, 5,000장 이상 이미지 데이터에서 드롭아웃 비율에 따른 일반화 격차는 2.2%로 이하로 다른 조건들에 비해 높은 안정성을 보이나, 드롭아웃 비율에 따른 안정성 개선 정도는 상대적으로 낮음을 알 수 있다.

본 결과는 이미지 데이터 확보가 제한된 환경에서도 L2 정규화 파라미터와 드롭아웃 비율 조절은 일반화 격차를 효과적으로 완화하며, 특히 데이터 수가 적은 경우에도 본 하이퍼파라미터 조절을 통해 더 많은 데이터를 사용한 조건보다 높은 성능을 확보할 수 있음을 보여준다.

#### 4. 결론

본 연구는 유연 전자소자 결합 진단을 위한 딥러닝 모델을 개발함에 있어, 실제 산업 현장에서 빈번하게 마주치는 제한된 데이터 확보 환경[4,5]에서 우수한 진단 성능을 확보하기 위해 필요한 최소 데이터 규모를 도출하고, 하이퍼파라미터 조절을 통한 모델 성능 개선 가능성을 제안하였다. 이를 위해 (1) 학습 데이터의 절대적인 규모가 모델의 성능에 미치는 영향을 분석하고, (2) 데이터가 부족한 환경에서 L2 정규화 파라미터 및 드롭아웃 비율과 같은 하이퍼파라미터의 변화가 성능 개선에 미치는 영향을 분석하였다.

분석 결과, 2,500장 미만의 이미지 데이터 환경에서는 평균 분류 성능이 상대적으로 낮을 뿐 아니라, 표준편차가 4% 이상으로 크게 나타나 학습 결과의 변동성이 매우 높은 반면, 이미지 데이터 수가 2,500장 이상일 경우, 모델 성능은 96% 이상으로 급격히 상승하고 표준 편차 또한 2% 이하로 현저히 감소하여, 모델이 안정적인 진단 성능을 확보하기 시작함을 확인하였다. 이는 높은 진단 성능과 안정성을 갖춘 모델을 확보하기 위한 최소 데이터 요건을 충족하기 어려운 경우에는 이를 보완할 수 있는 대안적 접근이 필요함을 보여준다.

또한, L2 정규화 파라미터와 드롭아웃 비율과 같은 하이퍼파라미터 조정을 통해 제한된 데이터 확보 환경에서 개발된 모델 성능 개선에 기여 할 수 있음을 확인하였다. 특히, 데이터가 충분하지 않은 상황에서도 하이퍼파라미터 최적화를 통해 더 큰 데이터셋을 사용한 조건보다 높은 진단 성능을 얻을 수 있음을 검증하였으며, 이는 데이터 수집이 어려운 환경에서 하이퍼파라미터 설정이 모델 성능 개선에 중요한 역할을 할 수 있음을 보여준다.

본 연구 결과는 데이터 수집에 상당한 비용과 시간이 요구되는 산업 환경에서, 높은 진단 성능을 확보하기 위해 최소 허용 데이터 수 이상의 확보가 중요함을 시사한다. 또한, 데이터 확보가 제한된 경우에는 하이퍼파라미터 최적화를 통해 데이터 규모의 한계로 인한 결함 진단 모델의 성능 저하를 효과적으로 보완하고, 모델의 안정성 역시 크게 향상시킬 수 있음을 보여준다.

향후 연구에서는 제한된 데이터 확보 환경에서 얻을 수 있는 원시 데이터(Raw Data)를 기반으로 데이터의 실질적 규모 확장을 위한 데이터 활용 기법을 모색하고, 유연 전자소자에서 발생하는 다양한 결함에 대해 모델의 진단 정확도와 안정성을 더욱 향상시키기 위한 연구를 수행할 계획이다.

## ACKNOWLEDGEMENT

This research was supported by the Regional Innovation System & Education (RISE) program through the Jeollanamdo RISE center, funded by the Ministry of Education (MOE) and the Jeollanamdo, Republic of Korea (No. 2025-RISE-14-003).

## REFERENCES

1. Lee, J., Park, S., Shin, K.-H., Jung, H., (2018), Smearing defects: A root cause of register measurement error in roll-to-roll additive manufacturing system, *The International Journal of Advanced Manufacturing Technology*, 98(9), 3155-3165.
2. Bulnes, F. G., Usamentiaga, R., Garcia, D. F., Molleda, J., (2016), An efficient method for defect detection during the manufacturing of web materials, *Journal of Intelligent Manufacturing*, 27(2), 431-445.
3. Lee, J., Park, J., Jeong, H., Shin, K.-H., Lee, D., (2016), Optimization of printing conditions for microscale multiline printing in continuous roll-to-roll gravure printing, *Journal of Industrial and Engineering Chemistry*, 42, 131-141.
4. Ren, Z., Fang, F., Yan, N., Wu, Y., (2022), State of the art in defect detection based on machine vision, *International Journal of Precision Engineering and Manufacturing-Green Technology*, 9(2), 661-691.
5. Bhatt, P. M., Malhan, R. K., Rajendran, P., Shah, B. C., Thakar, S., Yoon, Y. J., Gupta, S. K., (2021), Image-based surface defect detection using deep learning: A review, *Journal of Computing and Information Science in Engineering*, 21(4), 040801.
6. Gafurov, A. N., Phung, T. H., Ryu, B.-H., Kim, I., Lee, T.-M., (2023), Ai-aided printed line smearing analysis of the roll-to-roll screen printing process for printed electronics, *International Journal of Precision Engineering and Manufacturing-Green Technology*, 10(2), 339-352.
7. Masci, J., Meier, U., Ciresan, D., Schmidhuber, J., Fricout, G., (2012), Steel defect classification with max-pooling convolutional neural networks, *Proceedings of the International Joint Conference on Neural Networks*, 1-6.
8. Imoto, K., Nakai, T., Ike, T., Haruki, K., Sato, Y., (2019), A CNN-based transfer learning method for defect classification in semiconductor manufacturing, *IEEE Transactions on Semiconductor Manufacturing*, 32(4), 455-459.
9. Adibhatla, V. A., Chih, H.-C., Hsu, C.-C., Cheng, J., Abbod, M. F., Shieh, J.-S., (2020), Defect detection in printed circuit boards using you-only-look-once convolutional neural networks, *Electronics*, 9(9), 1547.
10. Jing, J., Zhuo, D., Zhang, H., Liang, Y., Zheng, M., (2020), Fabric defect detection using the improved YOLOv3 model, *Journal of Engineered Fibers and Fabrics*, 15, 1558925020908268.
11. Yu, T., Zhu, H., (2020), Hyper-parameter optimization: A review of algorithms and applications, *arXiv preprint arXiv:2003.05689*.
12. Song, K., Yan, Y., (2013), A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects, *Applied Surface Science*, 285, 858-864.
13. Yang, L., Jiang, H., (2021), Weld defect classification in radiographic images using unified deep neural network with multi-level features, *Journal of Intelligent Manufacturing*, 32(2), 459-469.
14. Chen, H., Pang, Y., Hu, Q., Liu, K., (2020), Solar cell surface defect inspection based on multispectral convolutional neural network, *Journal of Intelligent Manufacturing*, 31(2), 453-468.
15. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., (2014), Dropout: A simple way to prevent neural networks from overfitting, *The Journal of Machine Learning Research*, 15(1), 1929-1958.
16. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. R., (2012), Improving neural networks by preventing co-adaptation of feature detectors, *arXiv preprint arXiv:1207.0580*.
17. Xu, Q., Zhang, M., Gu, Z., Pan, G., (2019), Overfitting remedy by sparsifying regularization on fully-connected layers of cnns, *Neurocomputing*, 328, 69-74.
18. Shankar, R. S., Mahesh, G., Murthy, K., Ravibabu, D., (2020), A novel approach for gray scale image colorization using convolutional neural networks, *Proceedings of the International*

Conference on System, Computation, Automation and Networking , 1-8.

19. Kukkadapu, S., (2025), Image recognition and extraction of deep features using GoogLeNet, Proceedings of the 8th International Symposium on Big Data and Applied Statistics, 346-353.
20. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., (2015), Going deeper with convolutions, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1-9.

**Jinho Yoo**

B.S. candidate in the Department of Advanced Components and Materials Engineering at Sunchon National University, and his research interests include AI-based defect diagnosis for flexible electronics, and roll-to-roll manufacturing.

E-mail: 20210014@s.scnu.ac.kr

**Jingeol Kim**

B.S. candidate in the Department of Advanced Components and Materials Engineering at Sunchon National University, and his research interests include AI-based defect diagnosis for flexible electronics, and roll-to-roll manufacturing.

E-mail: 20210003@s.scnu.ac.kr

**Sivaranjini Mohanan**

Ph.D. candidate in the Department of Advanced Components and Materials Engineering at Sunchon National University, and his research interests include AI-based defect diagnosis for flexible electronics, wearable sensor, and roll-to-roll manufacturing.

E-mail: Sivaranjinimohan13@gmail.com

**Jongsu Lee**

Associate professor in the Department of Advanced Components and Materials Engineering, Sunchon National University. His research interests include AI-based defect diagnosis for flexible electronics, AI-based control systems, wearable sensor, and design of large-scale web handling systems.

E-mail: jslee0505@scnu.ac.kr