

논문 2025-2-8 <http://dx.doi.org/10.29056/jsav.2025.06.08>

# 인공지능 기반의 컨트롤보드 전기적 장애 예측

이봉규\*†

## AI-based Prediction of Electrical Faults in Control Boards

Bongkyu Lee\*†

### 요약

스마트공장은 효율적인 물류를 위하여 다양한 자율 이동 스마트 장비를 운용하고 있다. 이러한 스마트 장비를 제어하는 컨트롤보드에 발생하는 전기적인 장애는 오작동이나 화재의 원인이 된다. 탄화도는 컨트롤보드에서 발생하는 전기적인 장애를 확인할 수 있는 유용한 지표다. 본 연구에서는 스마트 장비를 제어하는 내부 컨트롤보드에서 전기적 장애가 발생하는지를 예측하는 인공지능에 기반한 탄화도 검사 시스템을 제안한다. 제안 시스템은 LSTM, CNN, MLP로 구성된 MMLSTM 유형의 앙상블 모델이다. LSTM과 CNN을 이용하여 서로 다른 유형의 데이터를 단일 형태의 특징 벡터로 조합한다. 조합된 특징 벡터는 MLP에 입력되어 컨트롤보드의 탄화도를 예측한다. 테스트베드에서 얻어진 데이터를 이용한 실험을 통하여 제안 시스템의 유용성을 증명한다.

### Abstract

Smart factories operate various self-moving smart equipment for efficient logistics. Electrical failures occurring in the control boards that control these smart equipment can cause malfunctions or fires. Carbonization is a useful indicator for identifying electrical failures occurring in the control boards. In this study, we propose an artificial intelligence-based carbonization inspection system that predicts whether electrical failures occur in internal control boards that control smart equipment. The proposed system is an ensemble model of MMLSTM type consisting of LSTM, CNN, and MLP. Using LSTM and CNN, different types of data are combined into a single feature vector. The combined feature vector is fed into the MLP to predict the carbonization degree of the control board. The usefulness of the proposed system is proven through experiments.

**한글키워드** : 스마트공장, 컨트롤보드, 탄화, 특징맵, 멀티모달

**keywords** : Smart Factory, Control Board, Carbonization, Feature Map, Multimodal

## 1. 서론

스마트공장에는 효율적인 제품생산을 위해 공정 설비의 연동을 기반으로 한 자동화된 작업흐

름 결정시스템이 필수적이다. 이를 위해 현장 작업 지시와 공정 관리 등 생산 활동을 지원하는 MES (Manufacturing Execution System), 제품의 주문에서 출하까지 물류 흐름을 관리하는

\* 제주대학교 데이터사이언스학과

† 교신저자: 이봉규(bklee@jejunu.ac.kr)

접수일자: 2025.05.22. 심사완료: 2025.06.07.

게재확정: 2025.06.20.

SCM (Supply Chain Management), 그리고 고객 주문 정보를 포함한 전사적 자원관리를 위한 ERP(Enterprise Resource Planning) 등이 포괄적으로 연결되어 제품생산과 공급을 효과적으로 연계시킨다[1]. 이러한 스마트공장의 물류시스템을 잘 보여주는 곳 중 하나가 반도체 제조 공정이다. 반도체 제조를 위한 물류 공정은 무인 이송 수단을 제어하기 위한 MCS(Material Control System)와 MCS로부터 전달받은 반송 지시를 수행하는 반송 차량 관리시스템인 VMS(Vehicle Management System)로 구성된다[2]. VMS는 공정에서 사용하는 운송수단에 따라 OCS (OHT Control System), ACS (AGV Control System), RCS (RGV Control System)로 구분한다[3]. 최근 반도체 물류를 비롯한 많은 스마트공장에서는 효율적인 공정 흐름을 위하여 공장 천장에 설치된 레일을 따라 제품을 이동하는 OHT (Overhead Hoist Transport)를 많이 활용하기 때문에 실제 현장에서는 OCS가 주류를 이룬다[4].

천정에 설치되는 OHT는 길게는 수십 킬로미터에 달하는 레일 위에서 다른 OHT들과 상호작용하며 작업을 진행하기 때문에 스스로 주변 환경을 인식하고 주행하여 수행할 수 있는 기능이 있어야 한다. 이러한 OHT의 기능을 실제 구현하고 수행하는 것이 내장된 컨트롤보드(Control Board)이다. OHT에 내장된 컨트롤보드는 레일에서의 합류, 분기, 회전 상황에서 타 장치와의 충돌과 같은 주변 환경에서부터 발생할 수 있는 다양한 상황을 고려하여 내부의 모터와 같은 기계적인 장치를 안정적으로 제어하고 구동시킨다. 만약 컨트롤보드에 기능적인 장애가 발생하여 모터나 주변기기에 대한 제어 및 운행이 잘못되면 전체 물류 흐름에 심각한 피해를 줄 수 있다.

OHT와 같은 지능형 장비를 제어하고 운영하는 내부 컨트롤보드는 물리적 결함, 이물질 끼임, 주변 온도 상승, 과전류로 인한 부하 및 스파크 전류

등이 원인이 되어 전기적인 장애가 발생한다. 특히 실제 작업환경에서는 컨트롤보드에서의 전기적인 장애로 인하여 발생한 열에 의한 대형 화재의 가능성도 있다. 따라서 공정에 관련된 자동화 장비에 대한 전기적인 장애를 예측하고 관리하는 것은 스마트공장의 효율적인 운용 및 화재와 같은 재해의 발생을 예방하는 데 필수적이다. 본 연구에서는 스마트 장비의 지능적 제어를 담당하는 컨트롤보드에서 발생할 수 있는 전기적 장애를 효과적으로 예측하는 새로운 방법을 제안한다.

## 2. 컨트롤보드 전기적 장애 예측 기법

전자장비에서 발생하는 장애를 예측하기 위하여 내장된 컨트롤보드를 검사하는 방법에 관한 다양한 연구가 진행되었다. 먼저 열화상 카메라에 내장된 컨트롤보드를 대상으로 빅데이터와 기계학습을 수행하여 고장을 진단하는 방법이 제시되었다. 이 연구에서는 컨트롤보드에 대해서 과전압에 의한 고장 발생을 주요 고장 원인으로 파악하고 입력전압에 따른 출력전압 데이터를 학습하는 기계학습 방법으로 고장진단을 하는 것으로, 화재와 관련이 있는 컨트롤보드의 오류에 대한 진단을 목적으로 했다[5]. PCA (Principal Component Analysis) 기법으로 반도체식 가스센서의 고장을 진단하는 연구가 있었다. 이 연구에서는 고장분류를 위해 센서의 측정 데이터를 PCA에 의해 전처리하여 사용하였으며, 분류를 위한 출력 변수의 수를 PCA에 의한 성분분석을 통해 두 개로 줄인 뒤 이를 이용하여 고장들을 분류할 수 있음을 보였다[6, 7]. 이 연구의 경우에는 직접적인 화재 발생 여부를 판단하는 것은 아니지만, 가스센서의 오류로 인한 간접적인 화재가 가능하므로 화재를 예방하는 것과 같은 효과이다.

다양한 외부 작동환경에 노출로 인하여 발생할 수 있는 PCB 표면의 물리적인 부식의 존재 여부를 예측하는 모델로써 전기화학적 이동 (Electrochemical Migration, ECM) 및 누설 전기 (Leakage Current, LC)를 학습데이터로 이용하는 인공지능 방법이 제시되었다[8]. 이 연구에서는 PCB (Printed Circuit Board) 표면에 생긴 부식을 찾는 것에 더하여 해당 컨트롤보드의 기능 장애나 화재 가능성도 간접적으로 예측할 수 있다는 결과를 보였다. 또 다른 연구로는 기계적인 결합에 의한 화재 가능성을 방지하려는 것이 있다. 비접촉 적외선 센서가 장착된 모듈을 이용하여 모터제어센터 내부에 있는 BUS BAR 및 BUS BAR 볼트 연결부의 온도 이상 유무를 감지한 연구가 있다[9]. 모터제어센터 내부에 산재한 BUS BAR는 기계의 진동으로 인한 오류로 발열 및 이상 전류의 흐름이 생길 수 있다. 이런 현상은 화재의 직간접적인 원인이 될 수 있어서 미리 감지하여 처리하는 것은 모터제어센터의 안정화에 중요하다.

현재까지 다양한 연구가 진행되었으나, 전자장비나 장치를 구동하는 컨트롤보드의 기능장애나 화재 발생에 직접적인 원인이 되는 전기적인 장애를 예측할 수 있는 효과적인 지표인 보드의 탄화(유기물질이 열분해 되어 탄소로 변하는 과정) 여부를 검사하는 방법에 관한 연구는 없었다. 논리가 하드웨어적으로 실제 구현되는 PCB 기판은 유리 섬유 강화 수지로 구성되어 있어 전기적인 장애가 일어나면 전기적 탄화가 발생한다. 전기적 탄화가 검출되는 컨트롤보드에는 전기적인 장애를 포함한 심각한 손상이 발생했다고 판단할 수 있다. 본 연구에서는 컨트롤보드에서 얻어지는 열화상 이미지와 센서값을 이용하여 스마트 장비의 컨트롤보드의 탄화도 (Carbonization Degree)를 검사하는 인공지능 기반의 새로운 방법을 제안한다.

### 3. 인공지능 기반 탄화도 검출 시스템

본 연구에서 제안하는 탄화도 예측을 위한 학습 모델은 MMLSTM (Multimodal Long Short-Term Memory)[10] 모델을 기반으로 하는 앙상블 모델이다. 제안된 시스템은 LSTM (Long Short-Term Memory), CNN (Convolution Neural Network)과 MLP (Multi-Layer Perceptron)으로 구성된다. 그림 1에서 제안된 시스템의 구조를 보여준다.

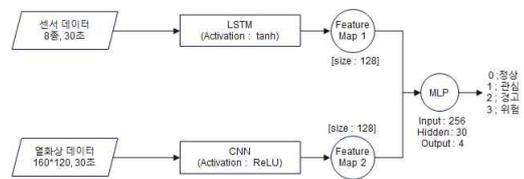


그림 1. 제안된 멀티모달 모델 구조  
Fig. 1. The proposed Multimodal model architecture

제안 시스템을 LSTM, CNN 및 MLP의 3가지 모델을 포함하는 앙상블 모델의 형태로 구성하는 것은 학습을 위하여 다양한 형태의 입력 데이터를 결합하여 예측 결과를 생성하기 때문이다. 일반적으로 자동화기기의 컨트롤보드에서 탄화 여부를 예측하기 위해 사용하는 것은 숫자 형태와 영상의 형태를 가지는 것으로 구분할 수 있다. 따라서 LSTM은 숫자 형태로 얻어지는 감지 데이터를 처리하여 예측에 필요한 특징을 추출하는 역할을 담당하고, CNN 모델은 이차원 이미지를 처리하여 예측에 필요한 특징을 추출하는 역할을 한다. 이렇게 처리된 LSTM과 CNN 모델의 출력은 하나의 단일벡터로 통합되어 MLP 모델에 입력되어 실제 탄화 정도를 예측하는 최종 특징으로 사용된다.

LSTM과 CNN의 입력부분은 사용하는 학습데이터에 따라서 가변적이다. 그러나 본 논문에서는 실제적 구현과 실험에 관한 내용을 기술하기 위하여 본 연구에서 사용했던 데이터에 맞추어 LSTM과 CNN 모델의 입력을 기술한다. 이런 이유로 그림 1에서 보듯이 LSTM은 8개의 센서로부터 30초간 받은 240개의 입력을 내부적으로 인코딩하여 128개의 실숫값으로 구성된 특징 맵을 구성한다. CNN 모델은 초당 1개씩 얻어지는 열화상 이미지(160\*120)를 30초간 입력받아 출력으로 128개의 실숫값으로 구성된 특징 맵을 생성한다. 생성된 특징 맵들은 256개의 원소를 가지는 단일벡터로 합해져서 MLP의 입력으로 주어진다. MLP는 입력으로 256개의 원소를 가지는 벡터를 입력으로 받아 대상 컨트롤보드 탄화도를 (정상, 관심, 경고, 위험) 4가지로 분류한다.

표 1에서는 본 연구에서 대상이 되는 스마트기기 컨트롤보드의 탄화도를 검사하기 위해서 실제 사용하는 측정 데이터에 대한 측정값들의 타입, 단위 및 의미를 보여주고 있다. 표에서 보듯이 8종의 숫자값 측정 센서 (NTC, PM10, PM2.5, PM1.0, CT1, CT2, CT3, CT4)는 크게 온도, 먼지, 입출력 전류값에 해당하는데, CT1에서 CT4까지는 본 연구에서 대상이 되는 컨트롤보드에 종속되어 정의한다. 공간 온도나 먼지센서는 대부분 컨트롤보드에 일반적으로 가능하다. 2차원 영상을 출력하는 열화상 카메라도 컨트롤보드에 일반적으로 적용할 수 있다. 그림 2에서는 숫자값이 아닌 이미지 형태의 측정 데이터인 열화상 영상 (변수명 :Thermal)의 예를 보여준다. 그림에서 보듯이 열화상 이미지는 컨트롤보드에서 나타나는 온도의 변화를 확인할 수 있는 정보를 가지고 있다. 따라서 열화상 영상이 전기적 장애 예측을 위한 유용한 정보를 포함하고 있음을 알 수 있다.

표 1. 정의된 입력 데이터

Table 1. Defined input data

데이터명	설명 (데이터 타입, 단위)
NTC	측정공간온도 (float, °C)
PM10	직경 10 $\mu$ m 이하 입자농도 (int, $\mu$ g/m <sup>3</sup> )
PM2.5	직경 2.5 $\mu$ m 이하 입자농도 (int, $\mu$ g/m <sup>3</sup> )
PM1.0	직경 1.0 $\mu$ m 이하 입자농도 (int, $\mu$ g/m <sup>3</sup> )
CT1	보드 입력전류 (float, A)
CT2	보드 출력전류 (float, A)
CT3	보드 부하1측 출력전류 (float, A)
CT4	보드 부하2측 출력전류 (float, A)
Thermal	열화상 카메라 이미지 (float, 배열)

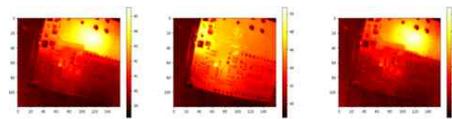


그림 2. 열화상 영상 예

Fig. 2. Examples of acquired IR images

#### 4. 실험 및 실험 결과

실제 모델에 대한 구현과 실험을 위하여 구성된 실험 환경은 표 2와 같다.

표 2. 실험을 위한 실험 환경

Table 2. The environment of experiments

CPU	Intel Xeon (2.5GHz)
Memory	DDR5 512G
GPU	GeForce RTX 4090 24GB GDDR6X * 9
OS (언어)	Ubuntu 24.04.1 (6.8.0-45-generic) (Python 3.10)
학습 조건	-epochs: 50 - batch_size: 16 - learning_rate: 0.001 - optimizer_type: Adam -loss_function: CrossEntropyLoss - image_size: (120, 160) - sensor_input_size: 8 - timestamp: 30 - num_classes: 4

제안한 인공지능 기반 탄화도 예측 모델의 성능을 검증하기 위한 데이터 수집 방법은 다음과 같다. 연구에 적합한 데이터를 위하여 OHT를 생산하는 기업 내에 구축된 반도체 공정 라인과 같은 조건의 테스트베드 환경에서 작동하는 OHT에서 3종(8유형)의 센서 값과 IR 이미지 데이터 정보를 획득한다. 진류센서는 컨트롤보드 PCB로 들어오는 입력단 (CT1), PCB에서 나가는 출력단 (CT2), 구동모터로 나가는 출력단(CT1)과 구동모터2로 나가는 출력단 (CT2) 등 4곳에서 수집하였다. 온도센서와 먼지센서는 PCB가 위치한 하우스 내부를 측정하였고, 열화상 카메라는 해당 PCB를 열화상 카메라로 촬영하여 적외선 이미지를 수집한다. 이런 방법을 통하여 총 73,733개의 데이터 셋을 획득하였다. 획득한 데이터는 학습용으로 58,976개, 검증( Validation)용으로 7,373개를 사용하고 학습된 시스템의 성능 평가를 위한 테스트에는 7,384개를 사용한다. 실제적인 공정 현장과 같은 조건의 테스트베드 환경에서 수집한 데이터를 통하여 제안된 모델의 유용성을 보다 정확히 판단할 수 있는 것이다. 그림 3에서 실제 데이터 수집에 사용된 OHT에서 수집 대상 위치와 수집하는 센서의 사양을 보여준다.

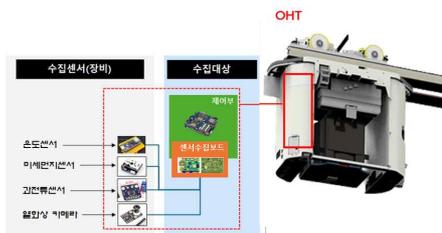


그림 3. 데이터 획득 시스템  
Fig. 3. Data Acquisition System

학습된 제안 시스템에 대해서 테스트 데이터를 적용한 인식 결과가 표 3에 나타나 있다. 표 3에서 보는 결과를 이용한 제안 시스템의 성능 평

가를 위하여 정확도 (Accuracy)와 F1-Score (Precision과 Recall의 조화평균)를 지표로 사용한다. 이렇게 두 가지 평가지표가 모두 의미 있는 결과를 나타내는 시스템이 되어야 실제 현장에서 유효하게 사용할 수 있는 것으로 판단할 수 있다. 먼저 실험결과표를 이용한 제안 시스템의 정확도(Accuracy)는 0.9193으로 나타났다. 즉 92%의 예측 정확도를 보이는 것이다. 또 다른 성능지표인 F1-Score 은 0.9110으로 확인되었다. 이런 결과를 통하여 제안된 시스템은 실제 현장에서 작동하는 컨트롤보드에 대한 상태를 비교적 정확히 예측할 수 있으며, 이를 통하여 실제 현장에서 사용하는 컨트롤보드의 장애 및 화재 발생 예측에 효과적으로 사용할 수 있음을 보였다.

표 3. 실험 결과  
Table 3. Experimental results

Actual \ Predicted	Predicted			
	정상	관심	경고	위험
정상	5710	232	22	8
관심	191	2464	71	8
경고	114	221	2337	18
위험	58	25	27	822

## 5. 결론

본 연구에서는 컨트롤보드의 탄화도를 검사하여 장애 가능성을 예측하는 새로운 인공지능 기법을 제안하였다. 탄화도는 화재 발생에 대한 가능성을 확인할 수 있는 직접적인 지표가 될 수 있어서 단순 기기의 장애와 더불어 설비에 대한 화재를 예방할 수 있는 지표로 사용할 수 있다. 제안한 방법을 구축된 학습데이터를 통해 학습시킨 후, 테스트 데이터를 통하여 유효성을 보였다. 실험 결과를 통하여 제안된 탄화도 예측 방법이 실제 현장에서 사용할 수 있음을 증명하였다.

본 연구에서 제안한 방법을 직접적으로 현장에 적용하기 위해 추후 핵심적으로 연구할 분야는 경량화로 판단된다. 현장에서 사용되는 많은 장비에 본 기술이 적용되기 위해서는 온디바이스(On-Device) 기기에서 알고리즘의 구현이 가능하게 하는 것이 필요하다. 이를 위한 낮은 연산량을 가지면서 성능에 변화가 적은 경량화된 알고리즘에 관한 연구가 이루어져야 할 것이다, 또한 인공지능 알고리즘의 구현용 경량형 온디바이스를 위한 하드웨어 설계 방법과 데이터에 관련된 소프트웨어 개발에 관해서도 연구할 필요가 있다.

“이 논문은 2025학년도 제주대학교 교원성과 지원사업에 의하여 연구되었음”

### 참고 문헌

- [1] H. S. Song, J. Y. Lee, and T. G. Kim. “DEVS-based Modeling Simulation for Semiconductor Manufacturing Using an Simulation-based Adaptive Real-time Job Control Framework”, Journal of the Korea Society for Simulation, 19(3), pp.45-54, 2013, <http://hdl.handle.net/10203/97188>
- [2] J.T. Lin, F.K. Wang, and C.K. Wu, “Connecting transport AMHS in a wafer fab”, International Journal of Production Research, 41(3), pp.529-544, 2003, DOI: 10.1080/0020754021000042418
- [3] F. K. Wang and J. T. Lin, “Performance evaluation of an automated material handling system for a wafer fab”, Robotics and Computer-Integrated Manufacturing, 20(2), pp.91-100, 2004, DOI:10.1016/j.rcim.2003.08.002
- [4] K. W. Lee, W. G. Lee, and S. C. Park, “Virtual Environment Hardware-In-the-Loop Simulation for Verification of OHT Controller”, Journal of the Korea Society for Simulation, 28(4), pp.11-20, 2019, DOI : 10.9709/JKSS.2019.28.4.011
- [5] S. M. kim, H. Y. Rim, I. S. Hwang and J. W. Hur, “Analysis of Fault Diagnosis Algorithm for Thermal Imaging Camera Circuit Board using Machine Learning”, Journal of the Korea Academia-Industrial Cooperation Society, 23(10), pp.118-124, 2022, DOI:10.5762/KAIS.2018.19.3.687
- [6] I. S. Lee, S. S. Ahn, “PCA Based Fault Diagnosis of the Gas Sensor in the Gas Monitoring System”, Proceedings of KIIT Conference, pp.418-422, 2013, <https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE02172722>
- [7] Y. Wang, F. Zhang and F. Chen, “The gas regulator fault diagnosis based on PCA-RBF neural network”, Proceedings of 20th International Conference on Electrical Machines and Systems, pp. 1-6, 2017, DOI: 10.1109/ICEMS.2017.8056001
- [8] S. Bahrebar, S. Homayoun and R. Ambat, “Using machine learning algorithms to predict failure on the PCB surface under corrosive conditions”, Corrosion science, 206, pp.1-21, 2022, DOI 10.1016/j.corsci.2022.110500
- [9] S. D. Kim, “A study on sensing for abnormality of BUS BAR in motor control center”, Journal of the Korea Academia- Industrial Cooperation Society, 12(13), pp.5838-5842, 2011, DOI: 10.5762/KAIS.2011.12.12.5838
- [10] S. Chen, B. Song and J. Guo, “Attention Alignment Multimodal LSTM for Fine-Grained Common Space learning”, IEEE Access, 6, pp.20195-20208, 2018, DOI: 10.1109/ACCESS.2018.2822663

저 자 소 개



이봉규 (Bong-Kyu Lee)

1995.2 서울대학교 컴퓨터공학과 박사

1996.3-현재 : 제주대학교 교수

<주관심분야> 인공지능, 패턴인식