

머신러닝을 이용한 열화상 카메라 회로보드의 고장 진단 알고리즘 분석

김선모, 이하예림, 황인수, 허장욱*
금오공과대학교 기계시스템공학과

Analysis of Fault Diagnosis Algorithm for Thermal Imaging Camera Circuit Board Using Machine Learning

Seon-Mo Kim, Ha-Ye-Rim Lee, In-Soo Hwang, Jang-Wook Hur*
Department of Mechanical System Engineering, Kumoh National Institute of Technology

요약 열화상 카메라는 군사용 목적의 활용뿐만 아니라, 온도제어가 필요한 산업현장, 그리고 일상생활의 많은 곳에서 사용되고 있다. 특히 자율주행차량에 탑재된 열화상 카메라는 기존 라이다, 레이더 등의 센서를 사용하는 자율주행차량의 약점을 보완해 줄 가능성이 높다. 그러나 자율 주행 중에 열화상 카메라의 회로보드가 고장날 수 있어 이는 운전자에게 불편을 줄 수 있고, 사고의 위험성 또한 크다. 본 연구에서는 회로보드의 고장 유형을 파악하고, 고장을 진단하고 분류하였다. FMEA에 따르면 열화상 회로보드의 주요 고장 모드는 과전압이다. 따라서 실험을 통해 열화상 회로보드의 저전압, 정격전압, 과전압을 인가하여 출력전압 데이터를 수집하였다. 머신러닝에 앞서 수집한 데이터의 축소 과정을 거쳤다. PCA, TSNE, ISOMAP, LLE의 총 4가지 기법을 수행하고 비교한 결과, TSNE 기법이 수집된 데이터에 가장 적합하였다. SVC, LR, DT, GNB의 4가지 고장진단 알고리즘을 수행한 결과 가장 우수히 고장진단을 수행한 DT 알고리즘은 Train Data를 학습시켜 Test Data에 적용한 결과, Precision, Recall, F1-score 및 Accuracy에서 97%의 정확도를 얻어 4개의 머신러닝 알고리즘 중 가장 높게 산출되었다.

Abstract Thermal imaging cameras are used in many places. Therefore, it is highly likely to be mounted on an autonomous vehicle. It can also improve the weakness of autonomous vehicles using LiDAR and RADAR. On the other hand, the thermal imaging circuit board may fail during autonomous driving, which will cause an accident and inconvenience the driver. In this study, the failure type and impact of the circuit board were identified, and the failure was diagnosed. According to the FMEA, the primary failure mode of a thermal imaging circuit board is overvoltage. Accordingly, through the experiment, this study applied low voltage, rated voltage, and overvoltage to the thermal imaging circuit board and collected output voltage data. The data went through a data reduction process prior to machine learning. A comparison of the four techniques revealed the TSNE technique to be the most appropriate for the data obtained. The decision tree algorithm obtained 97% accuracy and was the most appropriate for the machine learning algorithm comparing the four machine learning algorithms.

Keywords : Machine Learning, Thermal Imaging Camera, Circuit Board, Failure Classification, Failure Mode and Effect Analysis

본 논문은 과학기술정보통신부 및 정보통신기획평가원의 지능정보화혁신인재양성(Grand ICT연구센터) 사업의 연구결과(IITP-2022-2020-0-01612)로 수행되었음.

*Corresponding Author : Jang-Wook Hur(Kumoh National Institute of Technology)
email: hhjw88@kumoh.ac.kr

Received June 10, 2021
Accepted October 7, 2021

Revised July 14, 2021
Published October 31, 2021

1. 서론

열화상 카메라는 물체에서 방사하는 적외선을 감지하여 영상으로 변환하는 장비로서 국방, 보건의료, 산업현장, 보안 등 다양한 분야에서 폭넓게 활용되고 있다. 특히 자율주행 차량에서 인지 프로세스에 CRI(Camera-Ragar-LiDAR)과 같은 센서 융합 시스템이 사용되고 있으나 개별 센서마다 감지할 수 있는 데이터의 물리량과 유효 감지 범위(Field of View)가 다르고 데이터를 취득할 수 있는 속도(Frame Rate)와 데이터 해상도(Resolution)에 한계가 있기 때문에 자동차에 구현될 수 있는 기능도 제한이 생기게 된다[1]. 최근에는 적외선 센서가 성능 향상과 가격 인하 등 기술적 요인과 함께 야간 및 가시거리가 짧은 상황에서 물체 식별이 가능하다는 특징으로 인해 가까운 미래에는 자율주행 자동차의 시스템에 장착될 가능성이 높다.

이와 같이 향후에는 열화상 카메라가 장착된 자동차가 상용화될 것임을 예상할 수 있고, 이때 자율주행 중 열화상 카메라의 회로보드에 고장이 발생하여 시스템이 오작동을 일으킬 경우 인명사고를 초래할 수 있다. 이에 따라 열화상 카메라는 높은 신뢰성이 요구되며, 고장을 분류하고 진단하는 시스템의 적용이 필수적이다. 따라서 본 연구에서는 열화상 카메라 회로보드의 고장 유형 및 영향을 파악하고, 실험을 통해 수집한 데이터를 축소 기법을 통해 분류하였으며, 다양한 머신러닝 기법들을 이용하여 고장을 진단함으로써 최적의 머신러닝 알고리즘을 선정하였다.

2. 고장모드 분석 및 실험

열화상 카메라 회로보드에 대한 FMEA(Failure Mode and Effect Analysis)는 Table 1과 같으며, 주요 고장

원인은 과전압, 과전류 및 고온 등이 있다. 실험에서는 여러 가지 고장 원인 중 RPN(Risk Priority Number)이 가장 높은 MOSFET의 과전압을 대상으로 입력전압을 변경하면서 데이터를 획득하였다[2].

회로보드에 임의의 전압을 인가하여 출력전압 데이터를 수집하기 위해 Fig. 1과 같이 전원공급장치, 회로보드, DAQ, 컴퓨터로 실험 장치를 구성하였으며, 수집한 데이터는 Excel을 통해 저장하였다. 회로보드의 출력 단자로서 카메라 모듈을 장착하는 부분인 MCU(Micro Controller Unit)의 사양은 Table 2와 같으며, 입력전압 5V에서 출력전압은 3.3V임을 Fig. 2를 통해 확인할 수 있다.




Fig. 1. Diagnostic process of circuit board

Table 2. Specifications of MCU in Circuit Board

Rated voltage	Output voltage	Rated power
5V	3.3V	1W




Fig. 2. Circuit diagram of MCU

Table 1. FMEA Results of Circuit Board

Type	Failure Cause	Severity	Occurrence	Detection	RPN
Fuse	Over voltage, high temperature	2	3	2	12
Electrolytic capacitor	High current, high temperature	4	2	4	32
MOSFET	Over voltage, high current, high temperature	4	3	4	48
Transformer	High temperature	3	3	3	27




Fig. 3. Output voltage of MCU in circuit board

열화상 카메라 회로보드의 정격전압 5V, 저전압 3V, 그리고 과전압 6V와 7V를 대상으로 데이터를 획득하였다. 이때 정격전압이 아닌 경우 전압 강하가 일어나기 때문에 저전압과 과전압의 데이터를 모두 획득하였고, Fig. 3은 입력전압에 따른 출력전압의 데이터 형태를 나타내고 있다.

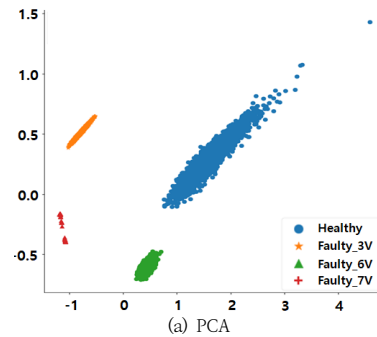
3. 머신러닝을 이용한 고장분류

3.1 데이터 차원 축소

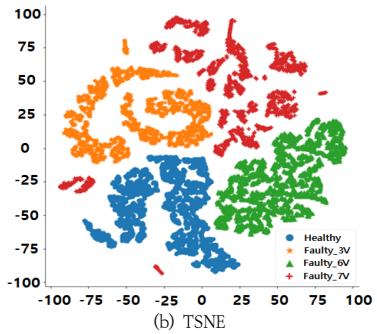
회로보드에 3V, 5V, 6V, 7V의 전압을 인가하여 1초당 1,000개의 데이터를 수집하였고, 각 전압별 약 4,200,000 개의 데이터를 획득하였다. 획득한 데이터에 `numpy.reshape()` 함수를 사용하여 각 전압별 데이터를 (1000,4200)의 형태로 변형시켰으며, 특성 데이터를 추출하기 위해 상관분석(Correlation analysis)을 수행하여 Mean, RMS(Root Mean Square), VAR(Variation), STD(Standard Deviation), GSTD(Geometric Standard Deviation), IQR(Inter- Quartile Range), SEM(Standard Error of the Mean), MAX(Maximum), MIN(Minimum), KUR(KURtosis), SKEW(SKEWness), CF(Crest Factor)의 특성 데이터를 추출하였다.

머신러닝을 수행하기 전에 차원 축소를 통해 고차원의 특성 데이터를 저차원으로 변환이 필요하며, PCA (Principal Component Analysis),

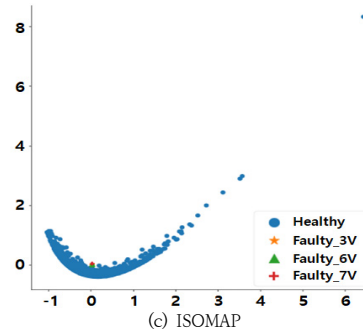
TSNE(t-Stochastic Neighbor Embedding), ISOMAP, LLE (Locally Linear Embedding)의 총 4가지의 차원 축소 기법을 Fig. 4와 같이 적용하였다.



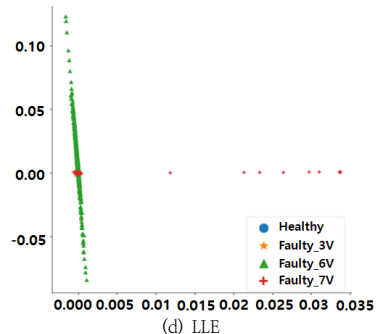
(a) PCA



(b) TSNE



(c) ISOMAP



(d) LLE

Fig. 4. Technique Performed for Dimension Reduction

PCA는 상관된 변수의 집합을 상관되지 않는 변수의 집합으로 변환하는 직교 선형 변환이며[3], ISOMAP은 고차원 데이터들의 쌍별 거리(pairwise distance)가 유

지되도록 저차원 데이터로 변형시키는 기법이고[4], TSNE는 고차원에서의 거리와 저차원에서의 거리가 최대한 일치하는 방향으로 차원 축소를 수행한다[5]. 그리고 LLE는 서로 인접한 데이터를 보존하며, 고차원의 데이터를 저차원으로 축소한다[6].

Fig. 4의 (c)와 (d)를 보면 데이터의 분류와 표현이 명확하게 식별되지 않기 때문에 ISOMAP과 LLE 기법은 적합하지 않다고 판단하였다. 반면, PCA와 TSNE의 차원 축소 결과는 데이터 경계 식별이 명확하지만, TSNE의 경우, PCA와 비교하였을 때 과전압인 7V의 데이터 분류를 우수하게 수행하였다. 따라서 수집된 데이터에 최적인 데이터 차원 축소기법은 TSNE로 판단되었으며, TSNE로 데이터 차원을 축소하여 머신러닝 알고리즘에 적용하였다.

3.2 고장진단 알고리즘 적용

3.2.1 SVC 알고리즘

SVC(Support Vector Classification) 알고리즘은 SVM(Support Vector Machine)에 속해있는 알고리즘으로 범주형 변수일 경우에 사용된다. 2개 이상의 데이터를 분류하는 분류 알고리즘이며, 높은 일반화 성능을 기대할 수 있다[7]. SVC 알고리즘의 Test Data를 Confusion Matrix로 Fig. 5와 같이 나타내었으며, 5V에서는 1,260개의 데이터에서 1,250개(99%)를 분류하였고, 3V는 962개(76%), 6V는 1,190개(94%), 7V는 961개(76%)를 구분하였다.




Fig. 5. Confusion Matrix of SVC




Fig. 6. Confusion Matrix of Logistic Regression




Fig. 7. Confusion Matrix of Decision Tree

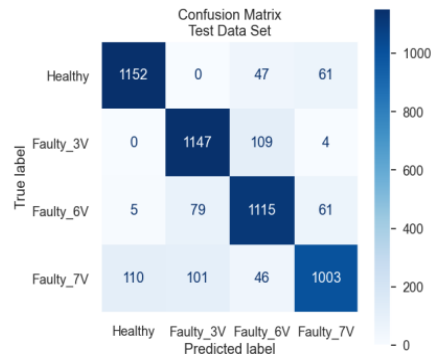


Fig. 8. Confusion Matrix of Gaussian NB

3.2.2 LR 알고리즘

LR(Logistic Regression) 알고리즘은 특정 사고가 발생할 확률을 추정하는 분석 방법의 일종으로, 반응변수가 범주형인 경우에 사용되는 대표적인 회귀분석 모델이고, 설명변수와 종속변수가 설명변수와 종속변수가 서로 연속형 변수일 때 회귀계수를 이용하여 관계를 분석한다[8]. LR 알고리즘의 Test Data를 Confusion Matrix로 Fig. 6과 같이 나타내었으며, 5V에서는 1,260개의 데

이더에서 959개(76%)를 분류하였고, 3V는 1,158개(92%), 6V는 983개(78%), 7V는 548개(43%)를 구분하였다.

3.2.3 DT 알고리즘

DT(Decision Tree) 알고리즘은 Data Mining에 일반적으로 사용되는 방법론적 분류 기법으로 입력 변수를 바탕으로 목표변수의 값을 예측하는 모델을 생성하는 방식이다[9]. DT 알고리즘의 Test Data를 Confusion Matrix로 Fig. 7과 같이 나타내었다. 5V에서는 1,260개의 데이터에서 1,257개(100%)를 분류하였고, 3V는 1,209개(96%), 6V는 1,177개(93%), 7V는 1,256개(100%)를 구분하였다.

3.2.4 Gaussian NB 알고리즘

Gaussian NB는 설명변수가 연속형일 때 사용하는 기법으로, 조건부 확률에 베이지 정리를 적용하고, 데이터를 구성하는 각각의 요소들이 등장할 확률에 대한 독립성을 가정하여 입력 벡터를 확률적으로 분류하는 방식이다[10]. Gaussian NB의 Test Data를 Confusion Matrix로 Fig. 8과 같이 나타내었으며, 5V에서는 1,260개의 데이터에서 1,152개(91%)를 분류하였고, 3V 1,147개(91%), 6V는 1,115개(88%), 7V는 1,003개(80%)를 구분하였다.

4. 결과 및 고찰

고장진단 모델의 성능은 Fig. 9의 분류성능 평가지표를 통해 식 (1) ~ (4)와 같은 파라미터를 이용하여 평가할 수 있다. 여기서 TP는 True Positive로 모델이 True라고 예측한 것이 실제 정답은 True임을 의미하고, TN은 True Negative로 모델이 False라고 예측한 것이 실제

정답은 False임을 표시한다. 또한, FP는 False Positive로 모델이 True라고 예측한 것이 실제 False임을 의미하고, FN은 False Negative로 모델이 False라고 예측한 것이 실제 정답은 True임을 표시한다.

		True Label	
		True	False
Predicted Label	True	True Positive	False Positive
	False	False Negative	True Negative

Fig. 9. Example of performance evaluation indicator

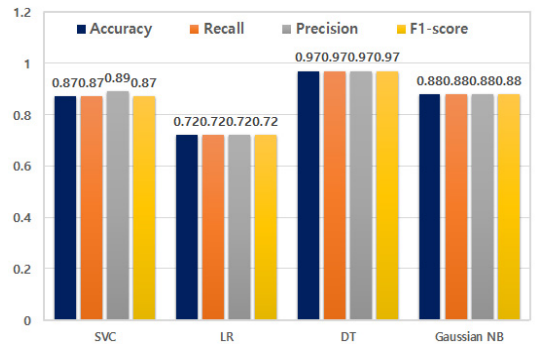


Fig. 10. Performance Metrics for Different Classifier

Accuracy는 올바르게 예측된 데이터의 수를 전체 데이터의 수로 나눈 값이고, Recall은 실제의 수를 의미하며, Precision는 모델이 True로 예측한 데이터 중 실제 True인 데이터의 수이다. 그리고 F1-score는 Precision과 Recall의 조화평균이다. 4가지 고장진단 알고리즘을 적용한 결과를 Fig. 10과 Table 3에 나타내었다. 표에서 Accuracy, Recall, precision, F1-score가 SVC 알고리즘은 87%, LR 알고리즘은 72%, DT 알고리즘은 97%, Gaussian NB 알고리즘은 88%이며, 이러한 결과로부터 가장 적합한 고장진단 알고리즘은 DT임을 알 수 있다.

Table 3. Machine Learning Algorithm Classification Report

Algorithm	Precision					Recall					F1-score					Accuracy
	Mean	H	F_3	F_6	F_7	Mean	H	F_3	F_6	F_7	Mean	H	F_3	F_6	F_7	
SVC	0.89	0.72	0.95	0.99	0.88	0.87	0.99	0.76	0.94	0.76	0.87	0.83	0.85	0.97	0.82	0.87
Logistic Regression	0.72	0.71	0.87	0.80	0.49	0.72	0.76	0.92	0.78	0.43	0.72	0.74	0.89	0.79	0.46	0.72
Decision Tree	0.97	0.94	0.99	0.95	1.00	0.97	1.00	0.96	0.93	1.00	0.97	0.97	0.98	0.94	1.00	0.97
Gaussian NB	0.88	0.91	0.86	0.85	0.89	0.88	0.91	0.91	0.88	0.80	0.88	0.91	0.89	0.87	0.84	0.88

5. 결론

열화상 카메라에 내장된 회로보드를 대상으로 빅데이터와 머신러닝을 수행하여 고장을 진단하였다. 얻어진 결과를 요약하면 다음과 같다. 첫째로 회로보드의 FMEA 결과는 과전압에 의한 고장발생이 주요 고장 원인이며, 입력전압에 따른 출력전압 데이터를 이용하여 머신러닝에 의한 고장진단이 가능하다. 둘째로 회로보드의 입력 전압(3V, 5V, 6V, 7V)에 따른 출력 전압의 데이터를 차원 축소한 결과, TSNE가 PCA, ISOMAP 및 LLE 등의 기법보다 우수하게 데이터를 분류하였다. 끝으로 4가지 알고리즘을 대상으로 Train Data를 학습시켜 Test Data에 적용한 결과, Precision, Recall, F1-score 및 Accuracy에서 DT 알고리즘이 97%로 가장 높게 산출되었다. 본 논문은 다른 센서 시스템에 비해 연구가 활발하게 진행되지 않은 열화상 카메라의 회로보드의 고장진단을 머신러닝 기법을 통해 수행하였다는 점에서 의의는 있으나, 고장 예지는 나아가지 못했다는 한계점이 있다. 따라서 이러한 데이터를 기반으로 회로보드의 고장 예지에 대한 연구도 수행되어야 할 것이다.

References

- [1] D. S. Cho, I. B. Yang, "Thermal Imaging Camera Development for Automobiles Using Detail Enhancement Technique", Journal of the Korea Academia-Industrial Cooperation Society, Vol. 19, No. 3, pp. 687-692, 2018.
DOI: <https://doi.org/10.5762/KAIS.2018.19.3.687>
- [2] Rastayesh, S., Bahrebar, S., Blaabjerg, F., Dalsgaard, J., "Lifetime Estimation and Failure Risk Analysis in a Power Stage Used in Wind-Fuel Cell Hybrid Energy Systems", Journal of the Electronics, pp. 7-8, 2019.
DOI: <https://doi.org/10.3390/electronics8121412>
- [3] I. S. Lee, S. S. Ahn, "PCA Based Fault Diagnosis of the Gas Sensor in the Gas Monitoring System", Journal of Korean Institute of Information Technology, Vol. 2013, No. 5, pp. 419-421, 2013.
- [4] B. H. Koh, J. H. Choi, M. J. Jeong, "A Study on Isomap-based Damage Signal Classification" Korean Society of Manufacturing Process Engineers, Vol. 2011, pp. 1251-1252, 2011.
- [5] S. M. Lee, M. S. Choi, Lee, J. H. Lee, G. H. Jeong, W. K. Yoon, S. R., "t-SNE Based Clustering Analysis for Drug Response Measurement of Glioblastoma", Journal of Korea Computer Congress, Vol. 2017, No. 6, pp. 716-717, 2017.
- [6] S. H. Oh, "Training of Locally Linear Embedding using Multilayer Perceptrons", Journal of the Korea Contents Association, Vol. 5, No. 2, pp. 218-220, 2007.
- [7] M. K. Kim, S. I. Son, S. I. Yoo, "A study on Improvement of Support Vector Machine with Incremental Local Outlier Factor", Korea Computer Congress, Vol. 38, No. 1(C), pp. 354-356, 2011.
- [8] S. B. Jin, J. W. Lee, "Study on Accident Prediction Models in Urban Railway Casualty Accidents Using Logistic Regression Analysis Model", Journal of the Korean Society for Railway, Vol. 20, No. 4, pp. 482-490, 2017.
DOI: <https://doi.org/10.7782/JKSR.2017.20.4.482>
- [9] J. J. Seo, G. S. Cho, J. K. Song, "The Study on the Decision Tree Method to Improve Land Cover Classification Accuracy of Hyperspectral Image", Journal of the Korean Association of Geographic Information Studies, Vol. 21, No. 3, pp. 205-213, 2018.
DOI: <https://doi.org/10.11108/kagis.2018.21.3.205>
- [10] S. G. Kang, B. K. Kwon, C. W. Kwon, S. M. Park, L. S. Yun, "Development of Incident Detection Algorithm Using Naive Bayes Classification", J. Korea Instrumental Intelligent Transportation, Vol. 17, No. 6, pp. 25-39, 2018.
DOI: <https://doi.org/10.12815/kits.2018.17.6.25>

김 선 모(Seon-Mo Kim)

[준회원]



• 2017년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학 중)

<관심분야>
기계/재료

이 하 예 림(Ha-Ye-Rim Lee)

[준회원]



- 2019년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학 중)

<관심분야>
기계/재료

황 인 수(In-Soo Hwang)

[준회원]



- 2017년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학 중)

<관심분야>
기계/재료

허 장 욱(Jang-Wook Hur)

[정회원]



- 1992년 10월 ~ 1995년 9월 : 일본 동경공대 기계물리공학과 (박사)
- 2009년 1월 ~ 2011년 12월 : 방사청 KHP사업단 체계종합/사업총괄담당 (중령)
- 2012년 3월 ~ 2012년 8월 : 탄약사 기술관리처장 (대령)
- 2012년 9월 ~ 현재 : 금오공과대학교 기계시스템공학과 교수

<관심분야>
시스템엔지니어링, 신뢰성공학, RAM, CBM+