

LSTM을 이용한 열화상 카메라의 고장진단

정선우¹, 신지원¹, 민순재¹, 허장욱^{2*}

¹금오공과대학교 기계시스템공학과, ²항공기계전자융합공학전공

Failure Diagnostics of Thermal Imaging Camera by the LSTM

Sun-Woo Jeong¹, Ji-Won Shin¹, Sun-Jae Min¹, Jang-Wook Hur^{2*}

¹Department of Mechanical System Engineering, Kumoh National Institute of Technology

²Department of Aeronautics, Mechanical and Electronic Convergence Engineering

요약 열화상카메라는 주로 야간, 악천후 및 고온의 환경에서 사용되며, 고장이 발생하면 치명적인 손상을 입을 수 있어 장기간 사용에 따른 내구성이 매우 중요하다. 최근, 방역, 화재 및 고장진단 등 다양한 용도로 사용되는 열화상카메라의 수요가 증가하고 있다. 열화상카메라를 이용하여 다른 시스템의 고장을 진단하는 연구는 많지만, 열화상카메라 자체의 고장진단을 연구하는 사례는 거의 없다. 따라서 본 연구에서는 열화상카메라의 FMEA(Failure Mode and Effect Analysis)에 대해 RPN(Risk Priority Number)이 높은 PCB(Printed Circuit Board) 및 적외선 렌즈(IR Lens)를 대상으로 70~90°C 온도에 따른 데이터 값을 추출하였으며, PCB 모듈의 고장 시 저항이 증가하는 것을 확인하였다. 획득한 시계열 데이터를 딥러닝 기법 중 하나인 LSTM(Long Short-Term Memory)을 사용하여 분석을 진행하였다. 그 결과, 3가지의 데이터 정확도 오차를 온도별로 구하여 보았을 때, 다른 시스템의 모델에 비해 0.028~4.208%의 높은 정확도를 얻었다.

Abstract Thermal imaging cameras are mainly used at night, in bad weather, and in high-temperature environments. Their durability due to the intended long-term use is very important as failure can cause fatal damage. Recently, the demand for thermal imaging cameras used for various purposes, such as communicable disease control, fire, and failure diagnostics, has been increasing. There are many studies on failure diagnostics in systems using thermal imaging cameras. However, few studies diagnose faults specifically in thermal imaging cameras. Therefore, this study extracted data values at a temperature range of 70~90°C for the printed circuit board (PCB) and infrared (IR) lenses with high risk priority number (RPN) for the failure mode and effect analysis (FMEA) of thermal imaging cameras and confirmed that the resistance increased during the failure of the PCB module. The acquired time series data were analyzed using long short-term memory (LSTM), which is one of the deep learning techniques. The results showed that when three data accuracy errors were obtained by temperature, 0.028~4.208% higher accuracy was obtained compared to models of other systems.

Keywords : Thermal Imaging Camera, Deep Learning, Failure Diagnostics, Failure Mode, LSTM

본 논문은 과학기술정보통신부 및 정보통신기획평가원의 지역지능화혁신인재양성(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 September 21, 2022

Accepted December 7, 2022

Revised October 18, 2022

Published December 31, 2022

1. 서론

열화상 카메라는 주야간 및 악천후에서도 사용이 가능하기 때문에 적을 감시 및 탐지하고자 하는 군사용 무기체계에 널리 사용되고 있으며, 최근에는 코로나 19의 확산으로 인해 인체 온도체크를 위한 방역용으로 수요가 기하급수적으로 증가하고 있다. 이와 같이 열화상 카메라라는 특수 목적을 가지고 사용되는 특징으로 인해 고장이 발생하면 치명적인 피해가 발생할 수 있으므로 장시간 사용에 따른 내구성이 매우 중요하게 대두되고 있어 초기에 고장을 분석하는 것이 필요하다.

이와 같은 필요성에도 불구하고, 열화상카메라를 이용하여 다른 시스템의 고장을 진단하는 연구는 많지만, 열화상카메라 자체의 고장진단을 연구하는 사례는 거의 없다. 열화상카메라는 일반적으로 카메라와 같이 고장이 발생할 경우 카메라의 전원 공급 장치에서 전선과 부품이 연결되었는지를 확인하고, 이미지나 영상을 보여주지 않을 때 고장이 났다고 판단하는 등 문제가 발생한 후 이를 확인하는 방식으로 고장을 진단하고 있다[1].

본 연구는 선행연구 중 2016년도에 신뢰성연구센터에서 발표된 가정용 열측정 적외선 센서의 수명에 관한 연구를 참고하였다. 해당 연구는 적외선을 이용한 열측정 센서에 관한 신뢰성 시험으로, 85 ℃와 100 ℃에서 가속수명시험을 진행하였고, 30분마다 저항을 측정하여 저항이 10% 이상 증가하였을 경우를 고장으로 판정하여 고장시간을 추정한 후 ReliaSoft 사의 ALTA로 통계분석을 진행하였다. 정리하면, 해당 연구는 열측정 적외선 센서를 가속수명시험을 통해 고장시간을 유추하는 실험이

다[2].

그러나, 해당 선행연구는 열화상 카메라 전체에 관한 실험이 아닌 열측정 IR 센서에 대하여 진행이 되었고, 25℃ 사용조건에서의 수명만을 구하였다.

본 연구는 선행연구에서 저항이 증가하였을 경우를 고장으로 판정한 점을 착안하였고, 선행연구와는달리 고온의 사용환경에서 고장을 진단하기 위하여 열화상카메라를 대상으로 FMEA를 통해 주요 고장유형을 조사하였으며, 이때의 발생도, 심각도 및 검출도를 파악하여 치명품목으로 적외선 렌즈를 선정하였다. 실험은 적외선 렌즈가 장착된 PCB 모듈을 대상으로 하였으며, 고온에 의해 저항소자에서 균열이 발생하는 것을 예측할 수 있도록 LSTM 알고리즘의 딥러닝을 적용하여 고장을 진단하였다. 또한, LSTM 모델의 정확도를 평가하기 위해 식 (1)~(3)과 같이 RMSE(Root Mean Square Error), MAE (Mean Absolute Error) 및 MAPE(Mean Absolute Percentage Error)를 적용하여 데이터의 정확도 오차를 비교하여 LSTM 모델을 검증하였다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_i^*)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (2)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - x_i^*}{x_i} \right| \quad (3)$$

여기서, x_i 는 실제 데이터를 표시하고, x_i^* 는 모델에 의해 예측된 데이터를 나타내며, n 은 데이터의 개수이다.

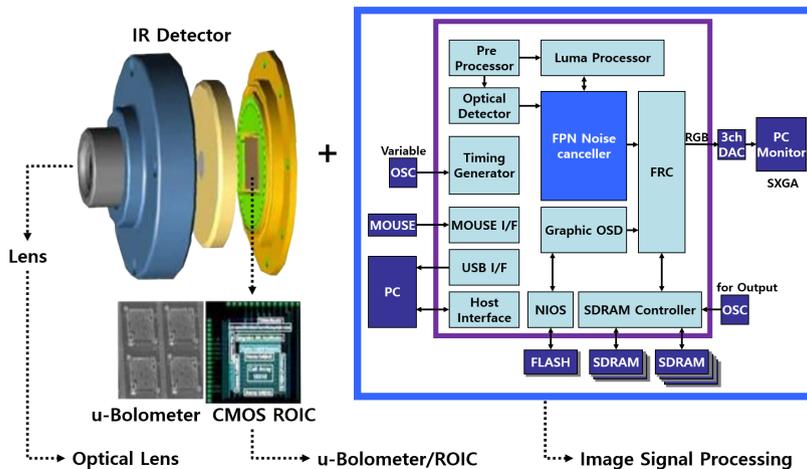


Fig. 1. Composition of thermal imaging camera

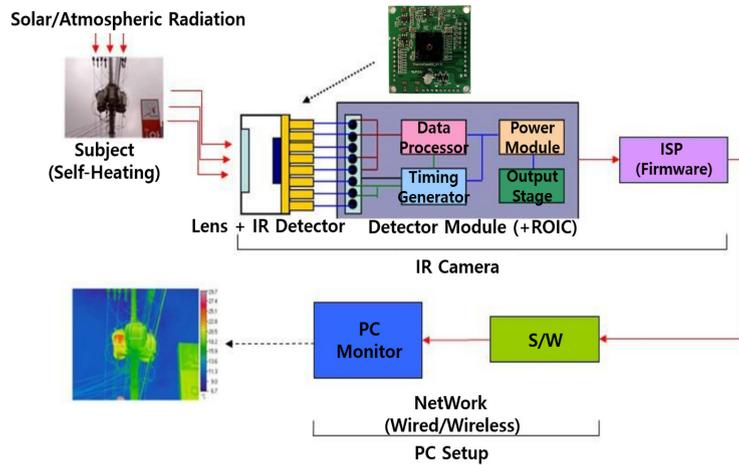


Fig. 2. Principle of thermal imaging camera

2. 열화상 카메라의 구성 및 실험방법

2.1 열화상 카메라 구성

열화상 카메라는 Fig. 1에 나타난 바와 같이 광학 렌즈 부분, 적외선 감지 센서 부분, 이미지 구현 부분으로 구성되어 있으며, 열화상 카메라의 종류는 사용하는 파장, 검출기, 적외선 검출방법 등에 따라 달라진다[3].

열화상 카메라는 렌즈를 통해 태양 및 대기의 복사열과 피사체에서 발생하는 복사에너지를 집광하고, 이를 센서에서 감지하여 신호를 발생한다. 발생한 신호는 소프트웨어를 통해 이미지화되며, 모니터 등 디스플레이 장치를 통해 영상을 보게 되는 원리이며, 이를 Fig. 2에 나타내었다.

특히, 열화상 카메라의 핵심 품목인 신호처리부는 적외선 검출기에서 나오는 전기적 영상정보를 재현장치에 가시광선으로 재구성하는 역할을 하며, 적외선 검출기에서 나오는 신호 정보를 영상재현에 필요한 전압 수준으로 바꾸어 주는 증폭기, 병렬신호를 비디오 영상재현에 적절하게 직렬신호로 변환하는 다중화기, 그리고 동기신호발생기로 구성되어 있다[3,4].

2.2 고장모드 및 실험방법

열화상 카메라의 FMEA 결과는 Table 1과 같으며, 주요 고장유형은 첫째, 잘못된 온도 데이터로 인한 적외선 렌즈 고장, 둘째, 굽힘, 파손으로 인한 PCB 고장, 셋째, 단락, 비정상적인 출력 전압, 균열로 인한 Li-ion 배터리 고장, 넷째, 단락으로 인한 케이블 손상이 있다. 표에서 알 수 있듯이 적외선 렌즈와 PCB는 발생도와 심각도가 커서 RPN이 높은 것으로 확인되었다. 적외선 렌즈가 PCB에 장착되어 있을 경우에만 전류가 흐른다는 것을 예비 실험으로 확인한 뒤, 적외선 렌즈를 부착한 PCB 모듈을 대상으로 실험을 진행하였다.

실험장치는 Fig. 3과 같이 구성하였으며, 데이터 수집 및 추출을 위해 Fig. 4와 같이 실험환경을 구축하였다. 고온에 의해 저항소자에서 균열이 발생하고[5], 균열이 발생할 때 저항값이 높게 측정되므로[6] 저항값을 고장 판단의 파라미터로 선택하였다.

적외선 렌즈를 장착한 PCB 모듈의 (-) 전원선과 전원 공급장치의 (-) 선을 케이블로 연결한 뒤, 아두이노 전류 센서(INA219)와 접속하였고, PCB 모듈과 전원공급장치

Table 1. FMEA results of Thermal Imaging Camera

Type	Failure Cause	Occurrence	Severity	Detection	RPN
IR Lens	Incorrect temperature data collection of failure	4	8	5	160
PCB	Scratches, board broken	4	8	3	96
Li-ion battery	Short circuit, abnormal output voltage, cracking	2	5	3	30
Cable	Cable damage due to short circuit	3	5	4	60

의 (+) 전원선을 아두이노 전류센서에 연결하여 전원공급장치로부터 5 V의 전압을 공급하였다. 저항을 직접 측정하기 어려워, 전류센서를 통해 전류를 측정한 뒤, 이를 저항으로 변환하여 덤퍼닝에 활용하였다.

PCB 모듈을 온도 챔버에 넣고 70 °C부터 5 °C씩 상승시켜 90 °C까지 실험을 진행하였다. PCB 모듈의 케이블 연결 부분이 열에 의해 합선되는 것을 방지하기 위해 테프론 선으로 제작된 케이블을 사용하였고, PCB 모듈의 상부와 하부에 온도 챔버의 열이 균일하게 전파되도록 나무로 된 받침대를 이용하여 바닥으로부터 9cm 띄운 뒤, 받침대 사이에 PCB 모듈을 위치시킨 후 실험을 진행하였다.

3. 데이터 수집 및 전처리

3.1 데이터 수집

화상 카메라의 고장 데이터를 획득하기 위해 고온에서 일정 시간 이후 저항이 급격히 상승하는 시간을 측정하고, 이때 온도를 70, 75, 80, 85, 90 °C로 하여 초당 50 개의 저항을 획득하였다. 실험을 통해 온도에 따라 수집

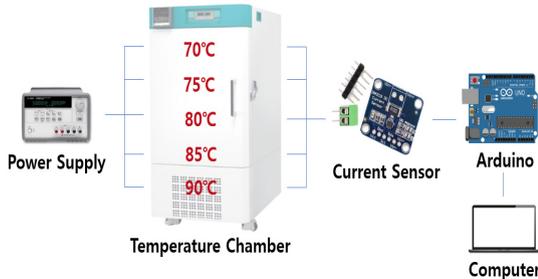


Fig. 3. Diagnostic process of thermal imaging camera

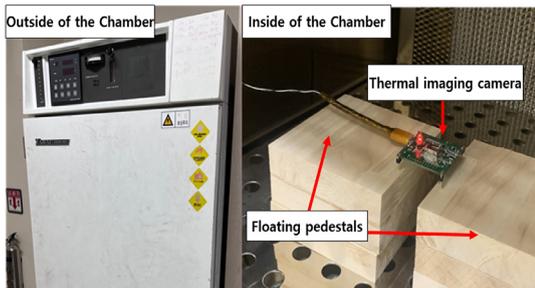


Fig. 4. Testbed configuration for temperature chamber experiment

한 데이터를 시간에 따른 저항 그래프로 Fig. 5와 같이 나타내었다. 열화상 카메라에서 측정되는 저항의 증가로 고장이 발생하여 정상 상태의 열화상 이미지(Fig. 6)가 잔상이 생긴 열화상 이미지(Fig. 7) 혹은 이미지 출력이 되지 않는 이미지(Fig. 8)로 변경되었음을 확인하였다.

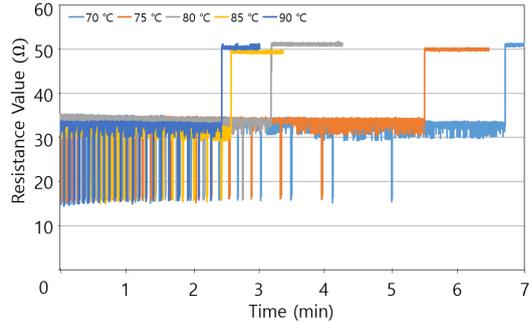


Fig. 5. Temperature experiment data

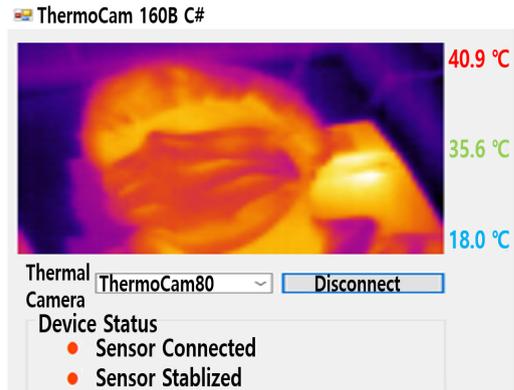


Fig. 6. Healthy photo of thermal image board

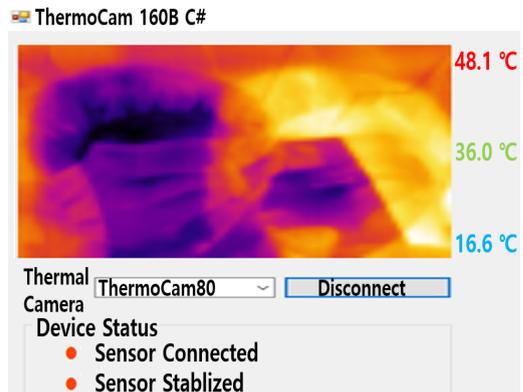


Fig. 7. After image photo of thermal image board

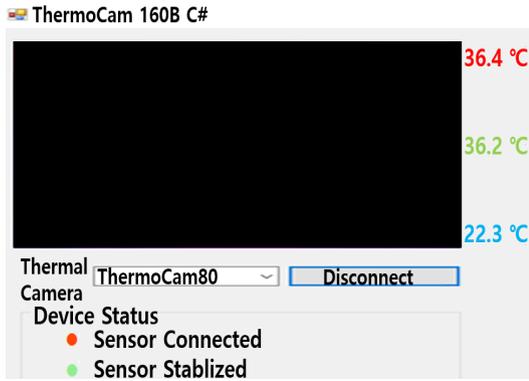


Fig. 8. Disconnected photo of thermal image board

3.2 데이터 전처리

시계열 데이터는 시간의 흐름에 따라 일정한 간격 동안 수집되며, 관측 순서대로 구성되는 데이터 셋의 집합이다. 연속한 관측 데이터는 서로 상관관계를 가지며, 시계열 데이터의 분석 목적은 시계열이 가지는 법칙성을 발견하여 이를 모형화하고, 추정 모형을 통해 미래의 값을 예측하거나, 모형화된 자료를 통해 시스템 또는 확률 과정을 이해하고 제어하는 것이다.

각 온도에서 수집한 Raw Data는 열화상 카메라의 적외선 렌즈가 초점을 잡기 위해 렌즈 커버가 닫혔다가 열려 저항값이 큰 폭으로 감소하는 특징으로 인하여 데이터가 비주기적이어서 시계열 분석을 사용하여 Smoothed Data 값으로 변환한 것을 Fig. 9와 같이 나타내었다.

4. 딥러닝을 이용한 고장진단

RNN(Recurrent Neural Network) 기반 언어모델은 입력 문장의 길이가 길어질수록 단어들간의 연관성 학습이 어려워지는 장기 의존성 문제(Long Term Dependency)를 동반하고[7], 장기 의존성 문제는 RNN 학습단계에서 문장의 길이가 길어지면 그 값이 0으로 수렴하는 Gradient Vanishing이 나타난다. 이러한 문제를 해결하기 위해 인공 순환 신경망 구조 중 하나인 LSTM이 고안되었으며[8], 정보를 선택적으로 통과시키는 방법인 게이트 구조에 의해 신중하게 조절되는 셀 상태에 정보를 제거하거나 추가하는 과정을 Fig. 10에 나타내었다.

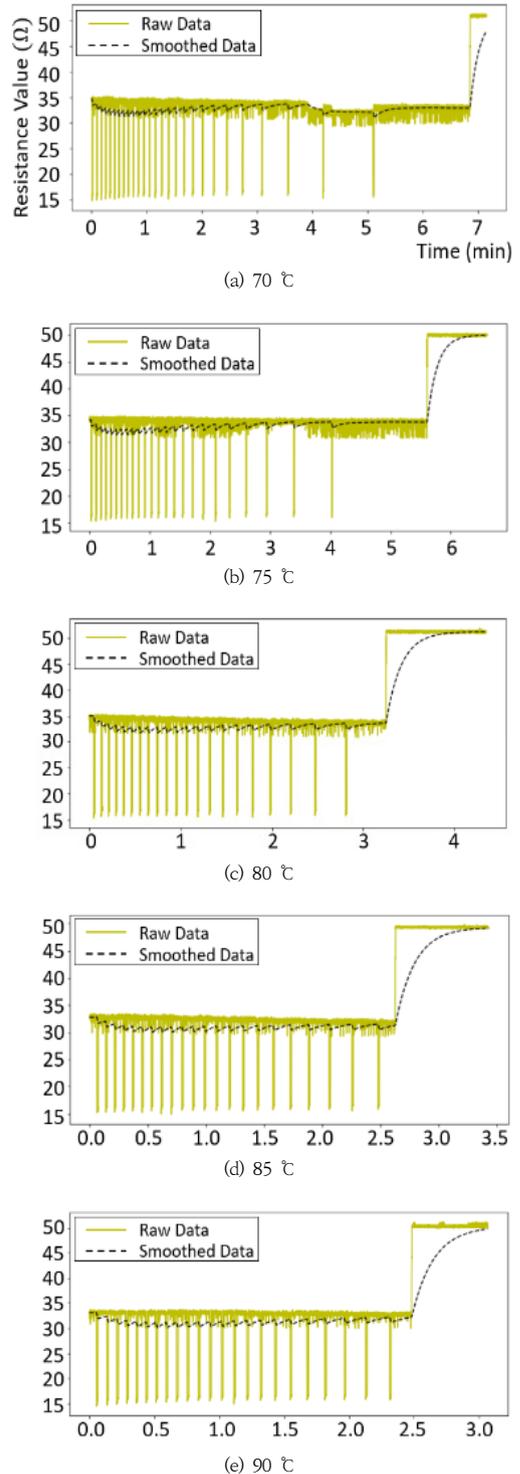


Fig. 9. Process of smoothing datas

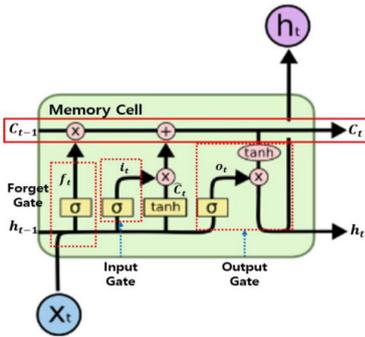


Fig. 10. Structure map of LSTM

LSTM은 셀 상태를 보호하고 제어하기 위해 3가지 게이트(gates)로 구성되어 있으며, LSTM의 첫번째 단계인 forget gate layer(f_t)는 σ (sigmoid layer)를 통해 셀 상태에서 어떤 정보를 기억하고 버릴 것인지 결정하고, 식 (4)과 같이 표시할 수 있다[9,10].

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

Where, W_f denotes weight for the forget gate, h_{t-1} denotes output of the previous LSTM block, x_t denotes input at current time stamp, b_f denotes bias of forget gate

다음 단계인 input gate layer(i_t)는 셀 상태에 저장할 새로운 정보를 결정하는 것이며, 식 (5)와 같이 표현할 수 있다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

Where, W_i denotes weight for the input gate, b_i denotes bias of input gate

먼저, σ layer가 업데이트할 값을 결정하고, tanh layer는 셀 상태에 추가할 \tilde{C}_t (candidate vector)를 만들며, \tilde{C}_t 는 셀이 저장하려는 새로운 정보에 대해 식 (6)과 같이 표시할 수 있다.

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

Where, W_C denotes weight for the cell, b_c denotes bias of cell

이 2가지를 결합하여 생성한 업데이트 된 셀 상태(C_t)는 식 (4)~(6)를 이용하여 식 (7)과 같이 표현할 수 있다.

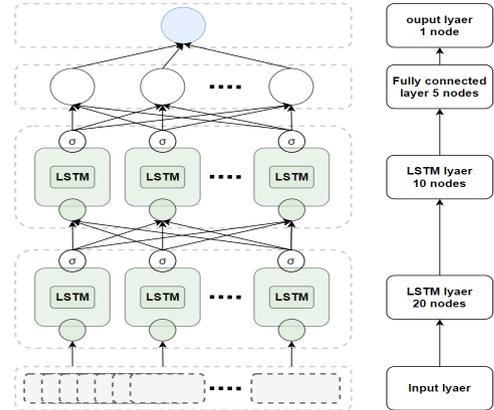


Fig. 11. The layer structure of the LSTM model

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (7)$$

Where, * denotes element wise multiplication

마지막으로 output gate(o_t)는 업데이트 된 셀 상태의 어떤 부분을 출력할지 결정하며, σ layer와 tanh layer를 적용해서 식 (8) 및 식 (9)와 같이 나타낼 수 있다.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t * \tanh(C_t) \quad (9)$$

Where, W_o denotes weight vectors of output gate, b_o denotes bias of output gate

학습에 사용한 모델의 구조는 Fig. 11과 같다.

LSTM layer 2개를 통해 데이터를 압축하고, LSTM의 마지막 출력 10개를 FC(Fully Connected network)의 입력층으로 전달하여 5개를 출력된 뒤, 다시 한번 FC의 입력층으로 5개를 전달하고 최종 한 개를 출력하는 총 5개의 계층으로 이루어져 있다. 모델의 학습은 구글 코랩(Google Colab)의 keras 환경에서 진행하였다. 학습을 위해 optimizer를 adam으로 선택하였으며, batch size를 40으로 설정하고, epochs를 50으로 하여 전체 데이터셋을 50번 학습하였다. 시계열 데이터에 대해 LSTM 기법을 이용하여 각 온도의 고장 데이터를 학습하고, 시계열 데이터가 정상 평균 저장값인 35Ω에 도달을 하였을 때 고장이 발생한다고 고장진단을 하였으며, 고장에 대한 예측 값을 나타낸 결과는 Fig. 12와 같다. LSTM은 정보를 분석하는 데 시간이 많이 소요된다는 단점이 있지만, 이와 같은 일련의 과정을 통해 효과

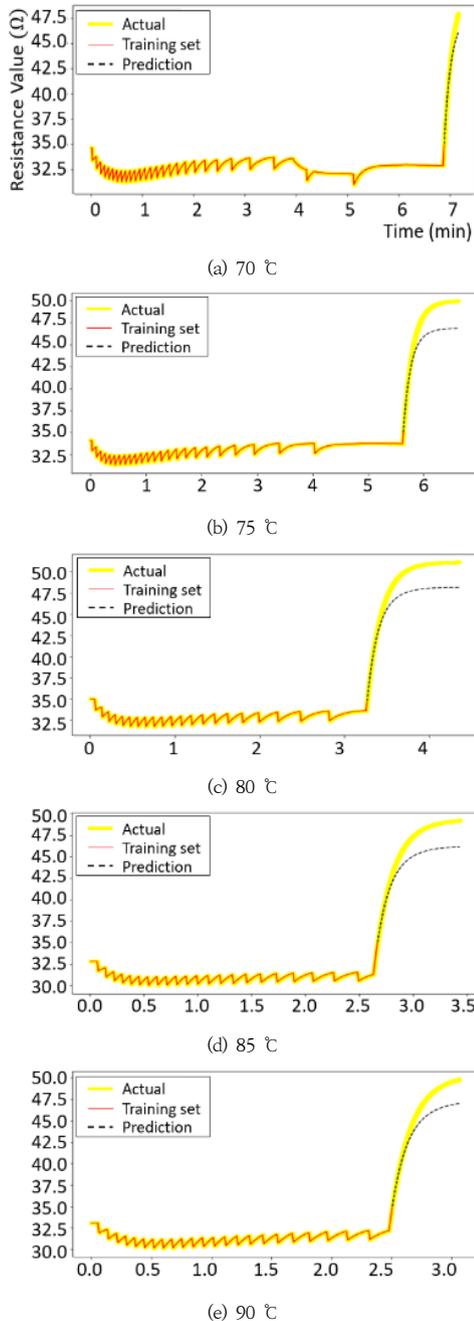


Fig. 12. Visualize predictions with LSTM

적으로 정보를 기억하고 학습을 반복하여 고장진단을 수행할 수 있다는 장점이 있다. 데이터의 정확도 오차를 비교하기 위해 식 (1)~(3)과, 같이 RMSE, MAE 및 MAPE를 적용한 결과는 Table 2와 같으며, 0.028~4.208% 수준의 오차를 나타내었다[11].

Table 2. Results of RMSE, MAE and MAPE

Type	RMSE[%]	MAE[%]	MAPE[%]
70 °C	0.028	1.276	2.815
75 °C	0.042	2.052	4.208
80 °C	0.043	2.161	4.316
85 °C	0.031	1.493	3.128
90 °C	0.029	1.381	2.891
Average	0.035	1.673	3.472

5. 결론

본 연구는 열화상 카메라를 대상으로 FMEA를 통해 주요 고장유형을 조사하고, 열화상 카메라의 고온에 의한 데이터를 획득하는 실험을 진행하여 저항 데이터를 수집하였다. 저항이 크게 변화하는 시점에서 고장이 발생하였다고 진단하였으며, 열화상카메라를 작동시켰을 때 열화상 이미지가 잔상이 생기거나 출력이 되지 않음을 확인하였다. 저항 데이터를 LSTM 알고리즘을 이용한 딥러닝으로 고장을 예측하였으며, 얻어진 결과를 요약하면 다음과 같다.

첫째, 열화상 카메라의 FMEA 결과 가장 취약한 품목은 적외선 렌즈이며, 적외선 렌즈를 장착한 PCB 모듈을 이용한 딥러닝으로 열화상 카메라의 고장진단이 가능하다.

둘째, PCB 모듈의 저항을 측정하여 정상상태와 이상상태의 열화상 이미지를 예측할 수 있다. 이때, 고장이 발생할 경우 열화상 이미지에 잔상이 생기거나 출력이 되지 않음을 확인할 수 있다.

셋째, LSTM 알고리즘을 적용하였을 때 정확도에 대한 오차는 RMSE가 0.035%, MAE가 1.673%, MAPE가 3.472%로 우수한 결과를 나타내었다.

마지막으로, 본 논문은 열화상카메라 자체의 고장진단에 관한 연구를 수행하였다는 것에 의의가 있다. 그러나, 실제와 더욱 유사한 가변하는 고온 환경에서의 고장진단을 하지 못했다는 한계점이 있다. 따라서 차후에는 가변하는 고온 환경에서의 연구도 수행되어야 할 것이다.

References

- [1] Security Cam Center [Internet]. How to fix CCTV security camera night vision problems, c2021 [cited 2021 February 13]. Available From: <https://securitycamcenter.com/security-camera-night>

[-vision-problems/](#) (accessed Sep. 20, 2022)

- [2] J. M. Kim, Y. S. Jo, K. H. Lee, "Investigation on the lifetime of thermal IR sensor for home application", Summer Annual Conference of IEIE, 2016, IEIE, Korea, pp.89-90, June 2016.
<https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE06725035>
- [3] S. P. Kwon, A Study on the Productivity Improvement of Thermal Infrared Camera an Optical Lens, Master's thesis, Management Korea Polytechnic University, Korea, pp.8, 14, 2009.
<https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE01225725>
- [4] B. J. Jeong, S. W. Jang, "Image Processing using Thermal Infrared Image", the Korea Academia-Industrial Cooperation Society, Vol.10, No.7, pp.1503-1508, 2009.
DOI: <https://doi.org/10.5762/KAIS.2009.10.7.1503>
- [5] J. M. Ryu, Y. J. Lee, K. I. Son, "A Study on the Fault Analysis of the Voltage Controller for the Combat Vehicle Generator", Journal of the Korea Academia-Industrial Cooperation Society, Vol.20, No.11, pp.386-393, 2019.
DOI: <https://doi.org/10.5762/KAIS.2019.20.11.386>
- [6] C. W. Han, N. C. Park, W. S. Hong, "Study on the Failure Mechanism of a Chip Resistor Solder Joint During Thermal Cycling for Prognostics and Health Monitoring", Journal of the Korean Society of Mechanical Engineers, Vol.35, No.7, pp.779-804, 2011.
DOI: <https://doi.org/10.3795/KSME-A.2011.35.7.799>
- [7] J. F. Kolen, S. C. Kremer, "Gradient Flow in Recurrent Nets: The Difficulty of Learning LongTerm Dependencies", A Field Guide to Dynamical Recurrent Networks, IEEE, pp.237-243, 2001.
<https://ieeexplore.ieee.org/document/5264952/citations#citations>
- [8] S. Hochreier, J. Schmidhuber, "Long Short-Term Memory", Neural Computation, Vol.9, No.8, pp.1735-1780, Nov. 1997.
DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>
- [9] J. H. Park, J. H. Seok, M. C. Kang, J. W. Hur, "Machine Learning Based Failure Prognostics of Aluminum Electrolytic Capacitors" Journal of the Korean Society of Manufacturing Process Engineers, Vol.19, No.11, pp.94-101, 2020.
DOI: <https://dx.doi.org/10.14775/ksmpe.2020.19.11.094>
- [10] O. Christopher, Understanding LSTM Networks, c2015 [cited 2015 Agust 27], Available From: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (accessed May. 5, 2022)
- [11] S. H. Son, and J. S. Kim, "Vulnerability Assessment for Fine Particulate Matter (PM2.5) in the Schools of the Seoul Metropolitan Area, Korea: Part I - Predicting Daily PM2.5 Concentrations" Korean Journal of Remote Sensing, Vol. 37, No. 6-2, pp. 1881-1890, 2021.
DOI: <https://dx.doi.org/10.7780/kjrs.2021.37.6.2.10>

정 선 우(Sun-Woo Jeong)

[준회원]



- 2017년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학중)
- 2021년 8월 ~ 현재 : 금오공과대학교 국방신뢰성연구실 학생연구원

<관심분야>

시스템엔지니어링, 신뢰성공학, 국방과학, RAM, CBM+

신 지 원(Ji-Won Shin)

[준회원]



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

<관심분야>

기계/재료

민 순 재(Sun-Jae Min)

[준회원]



- 2018년 3월 ~ 현재 : 금오공과대학교 기계시스템공학과 (재학중)

<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 :
탐약사 기술관리처장(대령)
- 2012년 9월 ~ 현재 : 금오공과대학교 기계시스템공학과
교수

<관심분야>

시스템엔지니어링, 신뢰성공학, RAM, CBM+