

# 머신러닝을 이용한 알루미늄 전해 커패시터 고장예지

박정현\*, 석종훈\*, 천강민\*, 허장욱\*<sup>#,</sup>

\*금오공과대학교 기계시스템공학과

## Machine Learning Based Failure Prognostics of Aluminum Electrolytic Capacitors

Jeong-Hyun Park\*, Jong-Hoon Seok\*, Kang-Min Cheon\*, Jang-Wook Hur\*<sup>#,</sup>

\*Department of Mechanical System Engineering, Kumoh National Institute of Technology

(Received 06 June 2020; received in revised form 23 August 2020; accepted 26 August 2020)

### ABSTRACT

In the age of industry 4.0, artificial intelligence is being widely used to realize machinery condition monitoring. Due to their excellent performance and the ability to handle large volumes of data, machine learning techniques have been applied to realize the fault diagnosis of different equipment. In this study, we performed the failure mode effect analysis (FMEA) of an aluminum electrolytic capacitor by using deep learning and big data. Several tests were performed to identify the main failure mode of the aluminum electrolytic capacitor, and it was noted that the capacitance reduced significantly over time due to overheating. To reflect the capacitance degradation behavior over time, we employed the Vanilla long short-term memory (LSTM) neural network architecture. The LSTM neural network has been demonstrated to achieve excellent long-term predictions. The prediction results and metrics of the LSTM and Vanilla LSTM models were examined and compared. The Vanilla LSTM outperformed the conventional LSTM in terms of the computational resources and time required to predict the capacitance degradation.

**Key Words :** Aluminum Electrolytic Capacitor(알루미늄 전해 커패시터), Machine Learning(머신러닝), Failure Prognostics(고장예지), Failure Mode and Effect Analysis(고장모드 및 영향 분석), Failure Mode(고장모드)

## 1. 서 론

4차 산업혁명으로 Big data를 활용한 인공지능이 금융, 주식, 의료, 농수산업, 기계, 전자 및 에너지 등 다양한 분야에 적용되어 연구개발이 활발하게 진행되고 있다. 인공지능은 인간이 가지고

있는 지각, 학습, 추론, 사고 및 자연언어의 이해 등을 컴퓨터 프로그램으로 실현한 기술로 머신러닝, 자연어 처리, 음성인식, 시각인식 등 첨단 기술개발에 활용되고 있으며, 특히, 장비의 고장을 사전에 예측하는 고장예지 기술 등을 통해 장비의 가동률을 향상시키고, 소요되는 비용을 절감하는 분야에 있어서도 활발한 연구가 진행되고 있다<sup>[1]</sup>.

대부분의 산업용 장비의 전원공급장치, 주파수 조절장치 및 충전장치 등에 사용되고 있는 알루미늄

# Corresponding Author : hhjw@kumoh.ac.kr  
Tel: +82-54-478-7399

높 전해 커패시터는 얇은 산화막 유전체를 이용하여 크기에 비해 큰 전하용량을 가지고 있으며, 가격이 저렴한 특징이 있으나, 열에 취약하여 고장이 자주 발생하고 있다. 또한, 전자회로에는 커패시터 뿐만 아니라 다양한 전자부품들이 장착되어 있기 때문에 커패시터에 고장이 발생할지라도 인식하기 어려워 전자회로보드를 교체하는 작업이 요구되고 있다. 커패시터에 대한 과거 연구는 열화 정도에 따라 부풀어 오르는 스웰링 현상을 카메라로 촬영하여 수명을 판단하고, 시험을 통해 수명을 예측한 내용 등이 발표되고 있으나<sup>[2-3]</sup>, 머신러닝 기법의 알고리즘 적용에 대한 구체적인 결과는 확인되지 않고 있다.

따라서 본 연구에서는 알루미늄 전해 커패시터를 대상으로 머신러닝 기법 중 LSTM(Long Short-Term Memory)과 Vanilla LSTM을 적용하여 고장예지를 하였으며, 각각의 기법에 대해 epoch에 따른 loss와 모델의 정확성을 평가하기 위해 척도인 RMSE(Root Mean Square Error)와 MAE(Mean Absolute Error)를 이용하여 성능을 비교하였다.

## 2. 고장모드 및 시험

### 2.1 고장모드

알루미늄 전해 커패시터의 FMEA(Failure mode




Fig. 1 Internal structure of Al electrolytic capacitor

and effects analysis) 결과는 Table 1과 같이 과도하게 인가된 전압으로 인한 단락 회로, 접착제/코팅 재료와 응력에 의한 개방 회로, 실린트 재료의 열화와 과열에 의한 전류 및 전해질 증발 그리고 과도하게 인가된 전압과 전해질 감소로 인한 정전용량 감소 등 크게 4가지로 구분할 수 있다<sup>[4]</sup>. 표에서 알 수 있는 바와 같이 RPN(Risk Priority Number)이 가장 높은 전류 및 전해질 감소는 정전용량 감소에 영향을 미치는 요인으로 정전용량 감소를 주요 고장모드로 판단하여, 온도 조건을 변화시켜 가면서 알루미늄 전해 커패시터의 고장예지를 위한 가속 수명 시험을 실시하였다.

알루미늄 전해 커패시터의 내부 구조는 Fig. 1과 같으며<sup>[2]</sup>, 전극판, 리드선 및 절연체로 구성되어 리드선으로 흘러들어오는 DC 전류가 절연체에 의해 차단되어 경계 부분에 전하가 비축되는 원리

Table 1 FMEA of Al electrolytic capacitor

failure mode	failure causes	failure effects	severity	occurrence	detection	RPN
short circuit between electrodes	excessive applied voltage	unable to store	9	4	6	216
open circuit	mechanical stress	breakdown of terminal leads and corrosion	8	4	8	256
	use of adhesive/coating material					
current and electrolytic evaporation	deterioration of sealant material	insufficient sealing electrolyte reduction	7	7	8	392
	high temperature					
capacitance reduction	high temperature	anode and cathode foil capacitance reduction	7	7	6	294
	excessive applied voltage					
	reverse voltage applied electrolytic reduction					
	deterioration of oxide film					

로 에너지를 저장한다. 정전용량은 커패시터가 전하를 저장하는 능력으로, 정전용량의 감소는 커패시터의 용량이 감소함을 의미하며, 이는 커패시터 고장의 원인이 되고, 표준 접근 방식에 의하면 정전용량이 초기 정전용량에 비해 15~20% 감소할 경우 고장으로 간주한다<sup>[5]</sup>.

정전용량이 감소하는 가장 큰 이유는 열 발생에 의한 것으로, 알루미늄 전해 커패시터 내에 소비되는 전력이 높아지게 되면 커패시터 내부의 온도가 상승하고, 전해액의 온도가 높아져 전해액의 증발을 야기하며, 전해액이 증발하게 되면 커패시터의 정전용량이 감소하여 커패시터 고장으로 나타난다.

### 2.2 시험 장치 및 방법

알루미늄 전해 커패시터로부터 데이터를 수집하기 위해 Fig. 2와 같이 회로를 설계하고<sup>[6]</sup>, 커패시터를 이용한 회로, 챔버 및 DAQ(Data Acquisition) 등으로 시험장치를 Fig. 3과 같이 구성하였다<sup>[7]</sup>. 이를 통해 커패시터의 반복적인 충전 및 방전에 의한 전압 데이터를 수집하였고, 랩뷰(Labview)를 이용하여 저장하였다. 이때, sampling rate는 1000sps, sampling 수는 1로 설정하여 1초에 1,000




Fig. 2 Circuit for accelerated life test




Fig. 3 Fault prediction big data collection system conceptual diagram

Table 2 Specification of Al electrolytic capacitor

rated voltage	limiting temperature	capacitance
16V	85°C	10 $\mu$ F




Fig. 4 The waveform of load voltage and current during discharge period

개의 데이터를 받았다.

시험에 사용한 알루미늄 전해 커패시터의 사양은 Table 2와 같으며, 140°C에서 고온시험을 진행한 결과 약 72 ~ 480시간 후 고장이 발생한 것을 확인할 수 있었다.

### 2.3 데이터 수집 및 추출

FMEA의 고장모드 분석 결과로부터 온도를 주요 파라미터로 선정하여 데이터를 수집 및 분석하였으며, 수집된 전압 데이터의 그래프는 Fig. 4와 같이 약 3.8V에서 방전이 시작하여 약 3V에서 방전이 끝나는 일정한 형태를 가지고 있다.

커패시터의 정전용량(C)은 에너지(E)와 전압(V)의 관계로부터 식(1)과 같이 나타낼 수 있다<sup>[8]</sup>.

$$C = \frac{2E}{V(t_1)^2 - V(t_2)^2} \quad (1)$$

또한, 에너지(E)는 전압(V), 전류(I), 측정주기(T) 및 샘플링 개수(n)의 관계로부터 식 (2)와 같이 표현할 수 있다.

$$E = \frac{\sum_{n=1}^{\infty} V_{(n)} I_{(n)}}{n} \times T [J] \quad (2)$$

위의 식을 적용하여 알루미늄 전해 커패시터의 전압 데이터를 정리하였으며, Python을 이용하여 필요한 데이터만을 추출하여 정전용량 추정기법을 통해 정전용량으로 변환하였다. 정전용량의 정확도는 Table 3을 통해 확인할 수 있으며, 샘플링 개수(n)가 높고 측정주기(T)가 작을수록 오차율이 감소하는 경향을 보였기 때문에 n = 30이고, 인 T = 30ms을 대상으로 하여 시험을 진행하였다.

커패시터의 온도가 140℃에서 1일차, 5일차, 9일차 등 4일 간격으로 같은 시간에 충전 및 방전 전압 cycle을 하나씩 표시하였을 때 Fig. 5(a)와 같다. 1일차와 21일차에 측정된 결과를 비교하면, 알루미늄 전해 커패시터가 완충되었을 때 전압은 약

3.8V에서 약 4.2V까지 증가하였고, 30ms 동안 방전된 후 전압은 약 3V에서 약 0.1V만큼 감소하였다. 21일 동안 측정된 전압 데이터에 대해 식 (1)과 식 (2)를 이용하여 정전용량으로 변환하였을 때 Fig. 5(b)와 같이 표시할 수 있으며, 정전용량은 초기 11.07μF을 시작으로 약간 증가하였다가 감소하는 모습을 나타내고 있다. 초기 방전 전압이 증가함에 따라 정전용량은 증대하고 있으나, 약 7일이 지나면 초기 방전 전압의 증가와 30ms동안 방전 후 전압의 감소에 따라 정전용량이 감소하는 것을 알 수 있다.

### 3. LSTM과 Vanila LSTM

연속된 sequence 형태의 데이터 처리에 있어 가장 기본적인 모델인 RNN(Recurrent Neural Networks)은 시계열 데이터가 길어지면 vanishing gradient 문제가 발생하는데, 이 문제를 해결한 기법이 LSTM이다. LSTM은 Fig. 6과 같은 구조로 적용하는 데이터가 손실 및 변형이 일어나지 않게 전달할 수 있는 셀 상태(the cell state)와 정보를 추가하거나 제거하여 선택적으로 정보를 다음 단계로 전달하는 시그모이드 신경망 레이어 (sigmoide neural net layer) 및 탄젠트 레이어(tanh layer)가 상호작용을 하며 3가지 게이트(gates)로 구성되어 있다<sup>[9][10]</sup>.

LSTM의 첫 번째 단계인 forget gate layer( $f_t$ )는  $\sigma$  (sigmoid layer)를 통해 셀 상태에서부터 어떤 정보를 기억하고 제거할 것인지 결정하며, 식 (3)과 같이 표시할 수 있다.


$$f_t = \sigma(W_f \cdot [h_{t-1} + x_t] + b_f) \tag{3}$$

- 여기서,  $W$  : weight vectors of each gate
- $h_{t-1}$  : hidden previous cell output
- $x_t$  : input vector
- $b$  : bias of each gate


두 번째 단계는 앞으로 들어올 데이터 중 어떤 데이터를 저장할 것인지 결정하는 input gate layer

Table 3 Error rate for sampling number and time

type	n	T(ms)	error(%)
1	20	30ms	40% or more
2	30	30ms	1% or less
3	60	60ms	10% or more



(a) voltage



(b) capacitance

Fig. 5 Capacitor voltage measurement for accelerated life test at 140℃




Fig. 6 Simple structure of LSTM

(i)로 어떤 값을 업데이트할지 결정하는 sigmoid layer와 셀 상태에 더할  $\tilde{C}_t$ (candidate vector)을 만드는 tanh layer로 구성되어 식 (4) 및 식 (5)와 같이 나타낼 수 있다.

$$i_t = \sigma(W_i \cdot [h_{t-1} + x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1} + x_t] + b_C) \quad (5)$$

앞 단계에서 획득한 데이터( $f_t$ ,  $i_t$  및  $\tilde{C}_t$ )를 이전의 셀상태  $C_{t-1}$ (previous cell memory)에 적용하여 새로운 셀 상태  $C_t$ (current cell memory)로 갱신하기 위해 식 (6)을 사용하여 최신했다.

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (6)$$

여기서,  $\odot$ 는 element wise multiplication이다.

마지막 단계는 output gate layer( $O_t$ )로 sigmoid layer와 tanh layer를 사용하여 출력 데이터를 결정하는 과정이며, 식 (7) 및 (8)과 같이 표시할 수 있다.

$$O_t = \sigma(W_o \cdot [h_{t-1} + x_t] + b_o) \quad (7)$$

$$h_t = O_t \odot \tanh(C_t) \quad (8)$$

LSTM은 이러한 반복 과정을 걸쳐 오랜 시간동안 정보를 기억하고 학습하여 이상 신호 검출 및 예측 등을 수행할 수 있다. 그러나 분석에 시간이 많이 걸리는 단점이 있으며, 이러한 단점을 보완하기 위해 단일 hidden layer와 output layer를 가지는 단순한 구조의 Vanilla LSTM이 주목받고 있는데, 이는 simple sequence data 및 특정 data에 대하여 기존 LSTM보다 빠르고 정확하게 분석 및 예측을 할 수 있는 특징을 가지고 있다.

#### 4. AI 전해 커패시터 고장 예지

알루미늄 전해 커패시터의 고장예지를 위한 머신러닝을 수행하기 위해 주피터(Jupyter) 프로그램을 사용하여 keras를 프레임워크로 LSTM을 수행하였다. 먼저, 획득한 데이터를 대상으로 오차를 줄이기 위해 centered moving average를 이용하여 5개의 데이터를 평균화하는 전처리 작업을 통해 Fig. 7와 같이 data set을 구축하였다.

data set 중 70%(115,416)의 데이터는 training data로 하고, 나머지 30%(49,464)의 데이터는 test data로 사용하였다. 학습 중 overfitting 또는 underfitting이 발생하는지 확인하기 위해 validation data는 training data 중 15%(17,312)를 사용하여 검증하였다. 또한 ground truth를 x축, actual data를 y축으로 하여 그래프로 나타내면 Fig. 8과 같으며, 이때 상관계수( $r$ )는 0.8945로 산출되어 연구결과가 신뢰성이 있음( $r \geq 0.7$ )을 확인할 수 있었다<sup>[1]</sup>.

hidden layer의 개수를 100개로 하여 learning rate = 0.001, epoch = 100, batch size = 1000 등을 설정한 LSTM과 hidden layer를 1개로 한 Vanilla




Fig. 7 Capacitance graph of moving average data






Fig. 8 Correlation graph between ground truth and actual data



(a) LSTM




(b) Vanilla LSTM


Fig. 9 Capacitance graph of actual data and prediction data

LSTM을 수행한 결과를 Fig. 9와 같이 나타내었다. LSTM 및 Vanilla LSTM의 적용 결과를 보았을 때 실제 값과 예측값이 같거나 차이가 심한 현상인 overfitting 또는 underfitting은 보이지 않았고, 두 그래프를 비교하기에 큰 차이는 확인이 곤란하였다.

epoch는 데이터 셋에 대해 학습한 횟수를 의미하며, loss는 예측 값과 실제 값의 차이를 표시한



(a) LSTM



(b) Vanilla LSTM

Fig. 10 Loss of LSTM and Vanilla LSTM

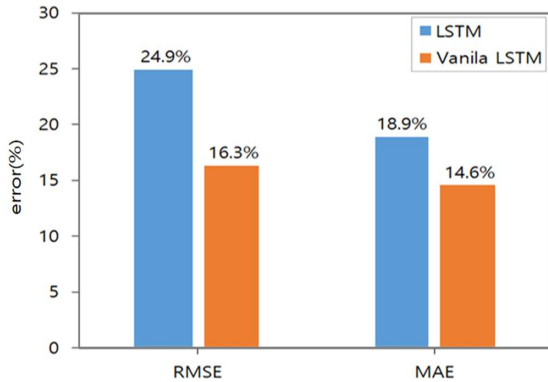
다. 즉, train loss와 validation loss가 0에 가까워질수록 학습이 잘 되었다고 할 수 있으며, epoch 값을 통해 몇 번 학습을 했는지 Fig. 10을 통해 확인할 수 있다. 그림에서 LSTM 및 Vanilla LSTM의 train loss는 적은 epoch 증가에 따라 loss가 0에 가까워졌으며, validation loss도 epoch 증가에 따라 감소하여 LSTM의 경우 epoch=100일 때 0.087, Vanilla LSTM의 경우 epoch=14일 때 0.044를 나타내고 있다. 이 결과 Vanila LSTM은 epoch가 14에서 early stopping하여 overfitting 현상을 방지하였음에도 validation loss가 기존 LSTM보다 0.044 작게 나타났으며, 빠르고 정확하게 진행되었습니다. 이를 통해 Vanila LSTM

은 최적의 epoch 도출에 의한 머신러닝을 수행한다면 LSTM보다 시간과 정확도 측면에서 유리함을 알 수 있다.

LSTM과 Vanila LSTM 모델의 정확성을 평가하기 위해 모델이 예측한 값과 실제 측정값의 오차를 구할 때 사용하는 식 (9) 및 식 (10)과 같이 RMSE(Root Mean Square Error)와 MAE(Mean

**Table 4 Results of RMSE and MAE**

Type	LSTM(%)	Vanila LSTM(%)	Deviation
RMSE	24.9	16.3	8.6
MAE	16.3	14.6	1.7



**Fig. 11 RMSE and MAE of LSTM and Vanila LSTM**

Absolute Error)의 척도를 적용하여 비교할 수 있었다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\nu_i - \hat{\nu}_i)^2}{N}} \quad (9)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\nu_i - \hat{\nu}_i| \quad (10)$$

여기서,  $\nu_i$  : actual capacitance data  
 $\hat{\nu}_i$  : predicted capacitance data by the models  
 $N$  : number of data points

최적의 조건의 LSTM(epoch 100)과 Vanila LSTM (epoch 14)을 대상으로 머신러닝을 수행하여 RMSE와 MAE를 계산한 결과를 Fig.11과 Table 4에 나타내었다. RMSE는 Vanila LSTM이 LSTM보다 8.6%, MAE는 1.7% 높은 것을 보아 알루미늄 전해 커패시터 고장 예측 시 Vanilla LSTM이 기존 LSTM보다 빠르고 정확하게 진행할 수 있다.

## 4. 결 론

대부분의 전자회로에서 사용하고 있는 알루미늄 전해 커패시터를 대상으로 빅 데이터와 머신러닝을 수행하여 고장을 예지하였다. 얻어진 결과를 요약하면 다음과 같다.

- 1) 고온에서 알루미늄 전해 커패시터의 capacitance를 측정하여 머신러닝을 통해 고장을 예지할 수 있다.
- 2) LSTM과 Vanila LSTM은 epoch 증가에 따라 loss가 감소하나, Vanila LSTM이 LSTM보다 빠르게 loss가 최소화된다.
- 3) Vanila LSTM은 LSTM보다 RMSE가 8.6%, MAE가 1.7% 감소하였다.

## 후 기

본 논문은 방위사업청과 국과연의 지원(RAM 특화연구실, UD150042AD)을 받아 수행된 연구결과이다.

## REFERENCES

1. Choi, J. H., "Introduction of Failure Prognosis and PHM," Journal of The Korean Society of Mechanical Engineers, Vol. 53, No. 7, pp. 24-34, 2013.
2. Jo, H. S., Park, S. C. and Jang, J. S., "Swelling-based Failure Prediction of Electrolytic Capacitors", Journal of Applied Reliability, Vol. 19, No. 2, pp. 149-159, 2019.
3. Chen, Y. R., Liao, H. and Chen, J. F., "Life Prediction of Aluminum Electrolytic Capacitors under Normal Operation", 2019 IEEE 4th International Future Energy Electronics Conference (IFEEEC), pp. 25-28, 2019.
4. Rastayesh, S., Bahrebar, S., Blaabjerg, F., Zhou, D., Wang, H. and Sorensen, D., "A System Engineering Approach using FMEA and Bayesian Network for Risk Analysis - A Case Study,"

- Sustainability, Vol. 12, No. 1, pp. 77-95, 2020.
5. “Capacitors Age and Capacitors Have an End of Life”, Emerson Network Power, pp. 1-14, 2008.
  6. Shon, J. G. and Kim, D. J., “A Simple Capacitance Estimation Method for Failure Diagnosis of DC Link Electrolytic Capacitor in Power Converters”, The Korean Institute of Electrical Engineers, Vol. 59, No. 4, pp. 378-383, 2010.
  7. Choi, H., Kim, T. K., Heo, G. R., Choi, S. D. and Hur, J. W., “Study of Fuel Pump Failure Prognostic Based on Machine Learning Using Artificial Neural Network”, Journal of the Korean Society of Manufacturing Process Engineers, Vol. 18, No. 9, pp. 52-57, 2019.
  8. Shon, J. G., “On-line Failure Detection Method of DC Output Filter Capacitor in Power Converters”, The Transaction of the Korean Institute of Electrical Engineers, Vol. 58, No. 4, pp. 483-489, 2009.
  9. “Understanding LSTM Networks”, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
  10. Yang, Y. S. and Bae, K. Y., “Prediction of Upset Length and Upset Time in Inertia Friction Welding Process Using Deep Neural Network”, Journal of the Korean Society of Manufacturing Process Engineers, Vol. 18, No. 11 pp. 47-56, 2019.
  11. Park, S. B., Kim, G. H., Baek, H. J., Han, J. H. and Kim, J. H., “Remote Pulse Rate Measurement From Near-Infrared Videos” IEEE Signal Processing Letters, Vol. 25, No. 8, pp. 1271-1275, 2018.