

# 머신러닝을 이용한 스타트 모터의 고장예지

고도현\*, 최욱현\*, 최성대\*, 허장욱\*.#

\*금오공과대학교 기계시스템공학과

## Failure Prognostics of Start Motor Based on Machine Learning

Do-Hyun Ko\*, Wook-Hyun Choi\*, Seong-Dae Choi\*, Jang-Wook Hur\*.#

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

(Received 27 May 2021; received in revised form 05 July 2021; accepted 13 July 2021)

### ABSTRACT

In our daily life, artificial intelligence performs simple and complicated tasks like us, including operating mobile phones and working at homes and workplaces. Artificial intelligence is used in industrial technology for diagnosing various types of equipment using the machine learning technology. This study presents a fault mode effect analysis (FMEA) of start motors using machine learning and big data. Through multiple data collection, we observed that the primary failure of the start motor was caused by the melting of the magnetic switch inside the start motor causing it to fail. Long-short-term memory (LSTM) was used to diagnose the condition of the magnetic locations, and synthetic data were generated using the synthetic minority oversampling technique (SMOTE). This technique has the advantage of increasing the data accuracy. LSTM can also predict a start motor failure.

**Keywords:** Start Motor(스타트 모터), Machine Learning(머신러닝), Failure Prognostics(고장예지), Failure Mode(고장모드), Long Short-Term Memory(장단기 메모리)

### 1. 서 론

시스템에 결함이나 손상이 발생할 경우 시스템의 가동 중단을 야기할 수 있으며, 이로 인해 막대한 경제적 피해가 발생할 수 있다. 따라서 고장이 발생하기 전에 예방정비를 실행하는 것이 중요하며, 현재 대부분의 시스템은 일정한 시간 간격을 두고 실시하는 정기적 예방정비에 의존하고 있

다. 그러나 정기적 예방정비는 부품의 실제 결함 유무와 관계없이 일정한 주기에 의해 실시되므로 정상 부품의 불필요한 교체로 인한 비용손실을 발생시킬 수 있으며, 갑작스런 시스템의 고장을 예방하는 데에 한계가 있다.

이러한 문제들을 해결하기 위해 최근 고장예지 및 건전성관리(PHM, Prognostics and Health Management) 기술이 활발히 연구되고 있다<sup>[1]</sup>. PHM 기술은 시스템의 상태를 실시간으로 감시하여 시스템의 이상을 조기에 감지하고, 미래에 발생할 고장을 사전에 예측한다.

# Corresponding Author : hhjw88@kumoh.ac.kr

Tel: +82-54-478-7399

자동차의 스타트 모터는 전조 증상이 없이 고장이 나는 부품 중 하나로서, 만약 스타트 모터가 고장이 나게 되면 자동차의 시동 자체가 걸리지 않아 여러가지 위험한 상황에 노출될 수 있다. 따라서 본 논문에서는 스타트 모터의 고장모드를 FMEA(Failure Mode and Effects Analysis)를 적용하여 분석하고, 주요 원인을 도출하였다. 또한, 실험을 통해 획득한 데이터를 바탕으로 머신러닝 기법 중 LSTM(Long Short-Term Memory) 알고리즘을 적용하여 스타트 모터의 고장을 예지하였으며, epoch에 따른 loss와 모델의 정확성에 대해 여러 가지 척도를 대상으로 성능을 평가하였다.

## 2. 고장모드 및 실험

### 2.1 고장모드

스타트 모터의 FMEA 분석 결과는 Table 1과 같으며, 과도한 전류로 열이 발생하여 스타트 모터 내부에 있는 마그네틱 코일이 녹으면서 일어나는 마그네틱 스위치 기능 손상, 스타터 모터와 플라이휠 사이에 연결 역할을 하는 피니언기어와 링기어의 마모, 케이블의 노화로 인해 발생하는 단락으로 케이블이 파손되는 현상, 시동이 걸리는 과정에서 반복된 마찰과 접촉으로 인해 발생하는 스파크로 B단자가 파손되는 현상 등 4가지 고장유형으로 분류되고 있다.<sup>[2]</sup> 표의 결과로부터 알 수 있듯이 RPN(Risk Priority Number)이 가장

높은 마그네틱 스위치 고장을 가장 큰 위험요인이라고 판단할 수 있다.

차량의 시동을 걸기 위해서 시동버튼을 누르게 되면 스타트 모터 내부에 설치되어 있는 마그네틱 스위치 코일에 전류가 흘러 시동이 걸린다. 하지만 시동이 정상적으로 걸리지 않아 시동버튼을 오랫동안 누르거나 계속 반복하여 누르면 과도한 전류로 인해 마그네틱 스위치 내부 코일의 온도가 점점 상승하다가 녹아버리면서 Fig. 1과 같이 마그네틱 스위치가 고장나 시동이 더 이상 걸리지 않게 된다.

이와 같이 마그네틱 스위치 코일의 온도가 상승하는 과정에서 발생하는 자기장 데이터를 획득하기 위해 차량용 배터리를 마그네틱 스위치에 연결한 후 자기장 리니어 홀센서를 사용하여 실험을 진행하였다.

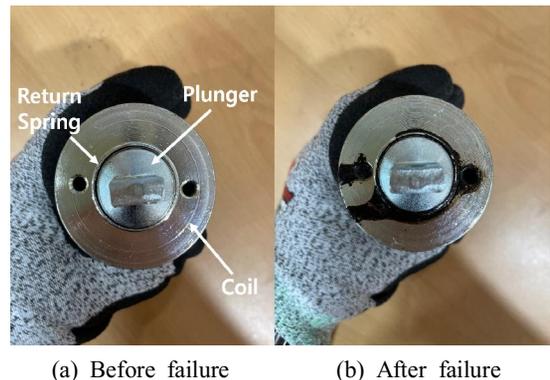


Fig. 1 Photos of before and after failure of start motor

Table 1 FMEA results of Start Motor

Part name	Function	Failure mode	Cause of failure	Occurrence	Severity	Detection	RPN
Magnetic Switch	Connects the start motor to the flywheel	Coil melts	Deterioration, electrical overload	8	5	8	320
Pinion Gear & Ring Gear	Drive connection between starter motor and flywheel	Grinding sound at start a car	Damaged due to abrasion on pinion gear and ring gear	3	4	4	48
Cable	External power supply	Broken cable due to short circuit	Short circuit due to aging	3	5	4	60
B Terminal	Main power and battery charging	Motor Failure	Electric sparks due to repeated contact	3	7	6	126

## 2.2 실험 장치 및 방법

실험 장치는 Fig. 2와 같이 스타트 모터의 마그네틱 스위치에 차량용 배터리를 연결하여 전류를 공급하고, 자기장 리니어 홀센서와 아두이노를 사용하였으며, 획득한 데이터를 활용하여 머신러닝에 의한 고장예지를 하기 위해 Python 프로그램을 활용하였다.

실제 차량에 쓰이는 스타트 모터는 차의 사양에 따라 상이하기 때문에 소형, 중형 및 대형 차량인 모닝, 아반떼 HD 및 스타렉스의 3개 차종 스타트 모터를 대상으로 하였으며, 각각 12V 40AH, 12V 60AH 및 12V 90AH 차량용 배터리를 사용하였다.

마그네틱 스위치 내부에 있는 마그네틱 코일의 상태를 확인하기 위해 자기장 데이터를 활용하였으며, 이는 주변 요인들에 대한 간섭을 최대한 받지 않기 위해 전류가 흐르는 동안에 자석과 같은 성질을 갖게 되는 마그네틱 코일의 특성을 이용한 것이다.<sup>[3]</sup>

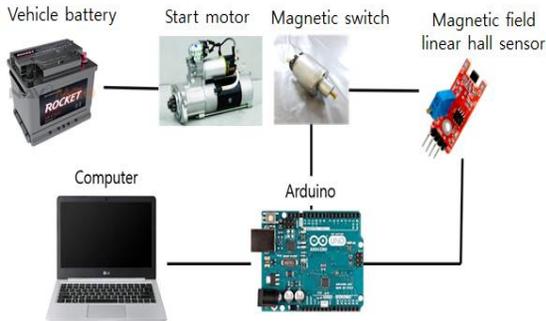


Fig. 2 Failure prognostics data collection system conceptual diagram

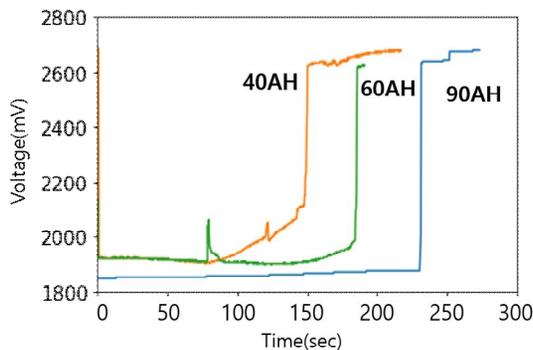


Fig. 3 Choosing the right data for data analysis

## 2.3 데이터 수집 및 추출

자기장 리니어 홀센서와 아두이노로 측정되는 자기장은 식 (1)을 사용하여 전압(V)으로 변환하였다.

$$V = \frac{5}{1023} \times B \quad (1)$$

40AH, 60AH 및 90AH의 배터리를 이용하여 측정된 데이터와 식(1)을 적용하면 Fig. 3과 같이 나타낼 수 있으며, 머신러닝을 적용하기 위해서는 점진적으로 변화하는 특성의 데이터가 유리하므로 40AH의 배터리 데이터가 가장 적합함을 알 수 있다. 40AH의 그림으로부터 마그네틱 스위치 속의 코일이 정상적으로 작동할 때는 1,900mV 정도의 전압을 유지하며, 코일이 녹으면서 전압이 점점 올라가다가, 2,100mV 수준에서는 순식간에 2,700mV까지 상승하는 것을 알 수 있다.

## 3. LSTM 기법

순차적으로 등장하는 데이터 처리에 적합한 기법인 RNN(Recurrent Neural Networks)은 관련 정보와 그 정보를 사용하는 지점 사이의 거리가 멀 경우 학습 능력이 크게 저하되는 vanishing gradient problem이 발생한다. 이러한 문제점을 보완하기 위해 발명된 기법이 LSTM으로 Fig. 4와 같이 새로운 값을 덧셈으로 받는 구조인 셀 상태(cell state)와 이전 단계의 정보에 값을 추가하거나 잊게 하여 다음 단계로 전달하는 sigmoid layer 및 tanh layer가 서로 상호작용을 하며, forget gate, input gate 및 output gate로 구성되어 있다[4][5].

먼저 forget gate layer( $f_t$ )는 이전 단계의 셀 상태 값을 얼마나 이용하고 버릴지 결정한다. 0에서 1사이의 출력 범위를 가지는  $\sigma$  layer의 값이 0이라면 이전 단계의 정보를 전부 잊고, 1이라면 이전 단계의 정보를 완전히 기억하게 되며, 식 (2)와 같이 나타낼 수 있다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

여기서,  $W_f$  : weight for the forget gate

$h_{t-1}$  : output of the previous LSTM block

$x_t$  : input at current timestamp

$b_f$  : bias of forget gate

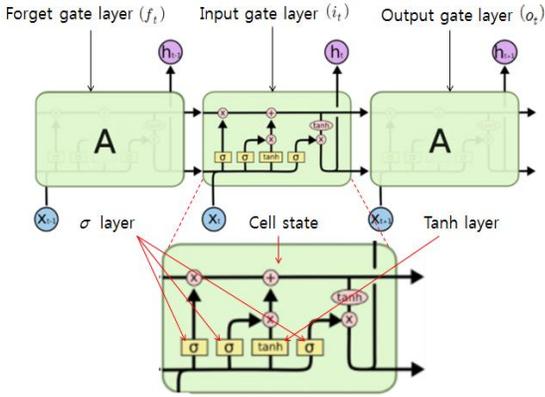


Fig. 4 Structure of LSTM

그 다음 순서로 input gate layer( $i_t$ )는 들어오는 값들 중에서 어떤 정보를 기억할지 결정하고,  $\sigma$  layer의 출력 범위에 따라 이전 셀 상태  $C_{t-1}$ (previous cell memory)에 얼마나 새로운 정보를 추가할지 결정하며, 식 (3)과 같이 표현할 수 있다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

여기서,  $W_i$  : weight for the input gate

$b_i$  : bias of input gate

그리고 tanh layer를 적용해서 셀 상태에 더해줄  $\tilde{C}_t$  (candidate vector)를 만든다.  $\tilde{C}_t$ 는 셀이 저장하려는 새로운 정보를 담고 있으며, 식 (4)와 같이 표시할 수 있다.

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

여기서,  $W_C$  : weight for the cell

$b_c$  : bias of cell

이때, 신규로 업데이트 된 셀 상태 ( $C_t$ )는 식 (2)-(4)를 이용하여 식 (5)와 같이 표현할 수 있다.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

여기서,  $*$  : element wise multiplication

마지막으로 output gate( $o_t$ )는 신규로 업데이트 된 셀 상태를 셀의 출력으로 얼마나 보낼지 결정하며,  $\sigma$  layer와 tanh layer를 적용해서 식 (6) 및 식 (7)과 같이 나타낼 수 있다.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

여기서,  $W_o$  : weight vectors of output gate

$b_o$  : bias of output gate

이와 같이, LSTM을 사용하면 일련의 과정을 통해 정보를 저장하고 학습하는 것을 반복하여 고장 진단 및 예측 등을 수행할 수 있으나 정보를 분석하는데 다소 시간이 많이 소요된다는 단점이 있다.

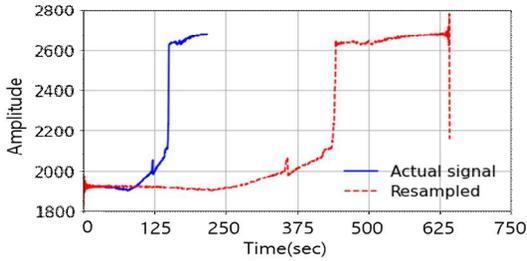
#### 4. 스타트 모터 고장예지

스타트 모터의 고장예지를 위한 머신러닝을 적용하기 위해 Python Jupyter Notebook을 사용하여 keras를 프레임 워크로 LSTM을 적용하였다.

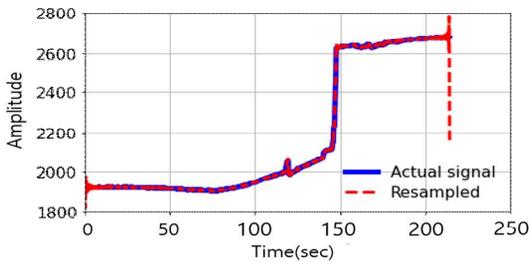
먼저, 이전에 획득 및 추출한 데이터 중 40AH의 데이터를 대상으로 Fig. 5와 같이 SMOTE(Synthetic Minority Oversampling Technique) 기법을 적용하였다. 이는 기존 샘플 간의 기능 공간 유사성에 기반한 합성 데이터를 생성하는 기법이며, 이를 통해 데이터를 오버샘플링 함으로서 데이터의 정확도를 증가시켰다<sup>[6]</sup>.

그리고 노이즈 및 고주파 구성요소로 인한 BIAS 및 불확실성을 제거하기 위해 Fig. 6과 같이 smoothing 작업을 수행하였으며<sup>[7]</sup>, 서로 다른 데이터 세트를 비교하기 위해 Fig. 7과 같이 normalization 기법을 통해 표본을 0과 1사이의 범위에 속하도록 하였다<sup>[8]</sup>.

또한, Jupyter 프로그램에 시계열 예측에 효과적인 n-step ahead regression technique를 적용하였으며, 프로그램의 학습 횟수를 나타내는 epoch를 50, batch size를 40으로 설정하였다. 그리고 epoch에 대해 실제 값과 예측 값의 차이를 나타내는 loss를 Fig. 8에 나타내었다. 그림으로부터 epoch가 10이상이 되면, 예측 값과 실제 값의 차이인 loss가 0에 근접함을 알 수 있다.



(a) Before application data



(b) After application data

Fig. 5 Synthetic minority over sampling technique (SMOTE) applied data

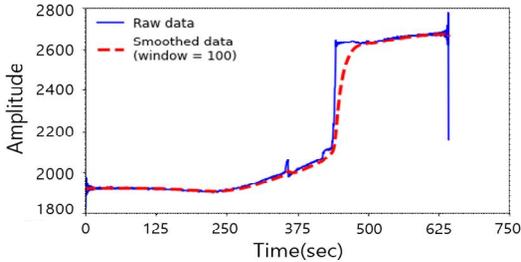


Fig. 6 Process of smoothing data

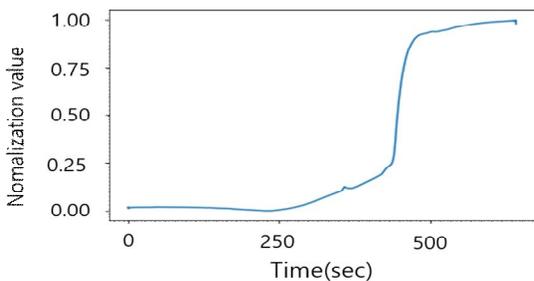


Fig. 7 Normalization data

LSTM을 사용하여 training set을 기준으로 예측한 결과 값과 실제 값의 차이를 Fig. 9에 나타내었으며, LSTM을 적용한 결과 예측 값과 실제 값의 차이가 심한 현상인 underfitting은 발생하지 않았다. 또한, LSTM의 정확도를 평가하기 위해 식 (8)~(10)과 같이 MAE(Mean Absolute Error), MAPE(Mean Absolute Percentage Error)와 RMSE(Root Mean Square Error)를 적용하여 비교하였다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - x_i^*}{x_i} \right| \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - x_i^*)^2}{n}} \quad (10)$$

여기서,  $x_i$  : actual capacitance data

$x_i^*$  : predicted capacitance data by the models

$n$  : number of data points

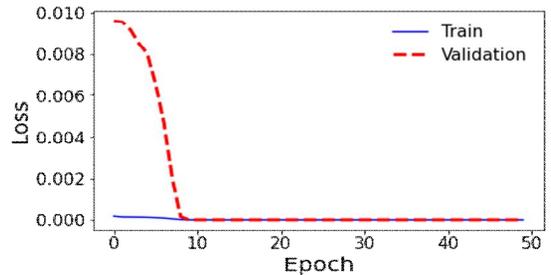


Fig. 8 Loss of LSTM

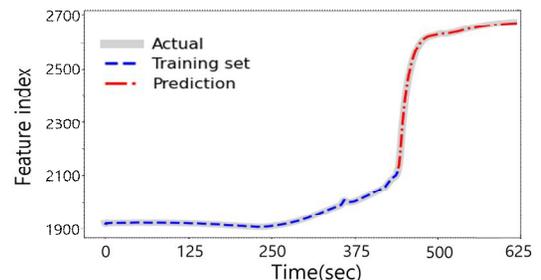


Fig. 9 Visualize predictions

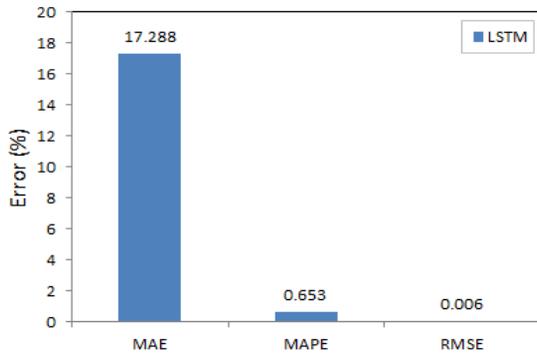


Fig. 10 MAE, MAPE and RMSE of LSTM

Table 2 Results of MAE, MAPE and RMSE

Type	MAE	MAPE	RMSE
Error(%)	17.288	0.653	0.006

LSTM을 대상으로 머신러닝을 진행하여 MAE<sup>[9]</sup>, MAPE와 RMSE<sup>[10][11]</sup>를 적용한 결과를 Fig. 10과 Table 2에 나타내었다. MAE는 약 17%의 오차가 있지만, MAPE와 RMSE는 약 1% 이하 오차로 우수한 결과를 나타내고 있으며, 특히 RMSE는 0.01% 이하의 오차를 표시하고 있다.

## 5. 결 론

자동차의 주요 품목인 스타트 모터를 대상으로 머신러닝을 수행하여 고장을 예지하였다. 얻어진 결과를 요약하면 다음과 같다.

- 1) 스타트 모터 마그네틱 스위치의 자기장에 대해 LSTM 알고리즘을 적용하여 고장을 예지할 수 있다.
- 2) 프로그램의 학습 횟수인 epoch를 10 이상으로 수행하면 실행값과 예측값의 오차인 loss가 0에 근접한다.
- 3) LSTM 알고리즘을 적용한 머신러닝의 정확도를 평가한 결과, MAE, MAPE, RMSE는 각각 17.3%, 0.6% 및 0.006%가 계산되었다.

## 후 기

이 논문은 2019년도 정부(교육부)의 재원으로 한국

연구재단의 지원을 받아 수행된 기초연구사업임(No. 2019R111A3A01063935).

## REFERENCES

1. Choi, J. H., An, D. W. and Gang, J. H., "A Survey on Prognostics and Comparison Study on the Model-Based Prognostics," Journal of Institute of Control, Robotics and Systems, Vol. 17, Issue 11, pp. 1095-1100, 2011.
2. Woo, S. W., Park, J. M., Hyun, B. S., Nam, J. W., Park, W. S., Kim, J. P., Cho, Y. J., Ko, J. M. and Park, N. G., "A Experimental Study on Insulation Breaking Fire Case of Starter Motor B Terminal," Journal of the Korean Society of Safety, Vol. 34 Issue 5, pp. 55-62, 2019.
3. Kook, J. H., Ahn, J. W. and Lee, H. H., "Output Characteristics of Helical Magnetic Flux Compression Generators with Varing Current Density Flowing through Coil," The Journal of KIEE Vol. 2002, No. 11, pp. 21-23, 2002.
4. "LSTM and It's Equations," <https://medium.com/@divyanshu132/lstm-and-its-equations-5ee9246d04af> (accessed 06, JUL, 2018)
5. "Understanding LSTM Networks," <http://colah.github.io/posts/2015-08-Understanding-LSTMs> (accessed 27, Aug, 2015)
6. Shin, D. I., "Synthetic Minority Over-Sampling Technique with Adversarial Auto-Encoder for Imbalanced Data" Graduate School of Sogang University, Republic of Korea, 2018.
7. "Language Model (2) Smoothing," <https://heiwais25.github.io/nlp/2019/10/06/Language-model-2/> (accessed 06, Oct, 2019)
8. Lee, S. H. and Park, K. S., "A Local Alignment Algorithm using Normalization by Functions," Journal of KIISE, Vol. 34, No. 5/6, pp. 187-194, 2007.
9. Cheong, W. S., Lee, B. K., Han, C. H., Kwon, S. G., Jang, J. K. and Lee, K. I., "A Fast Block Matching Algorithm Using Mean Absolute Error

- of Neighbor Search Point and Search Region Reduction,” The Journal of Korean Institute of Communications and Information Sciences, Vol. 25, Issue. 1B, pp. 128-140, 2000.
10. Kim, E. M. and Lee, B. H., “Performance and Root Mean Squared Error of Kernel Relaxation by the Dynamic Change of the Moment,” Journal of Korea Multimedia Society, Vol. 6, No. 5, pp. 788-796, 2003.
  11. Jung, H. and Kim, J. W., “A Machine Learning Approach for Mechanical Motor Fault Diagnosis,” Journal of the Society of Korea Industrial and Systems Engineering, Vol. 40, Issue. 1, pp. 57-64, 2017.