

PCA-SVM 기반의 SMPS 고장예지에 관한 연구

유연수*, 김동현*, 김 설*, 허장욱*,#

*금오공과대학교 기계시스템공학과

Fault Prognostics of a SMPS based on PCA-SVM

Yeon-Su Yoo*, Dong-Hyeon Kim*, Seol Kim*, Jang-Wook Hur*#

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

(Received 03 June 2020; received in revised form 30 June 2020; accepted 06 July 2020)

ABSTRACT

With the 4th industrial revolution, condition monitoring using machine learning techniques has become popular among researchers. An overload due to complex operations causes several irregularities in MOSFETs. This study investigated the acquired voltage to analyze the overcurrent effects on MOSFETs using a failure mode effect analysis (FMEA). The results indicated that the voltage pattern changes greatly when the current is beyond the threshold value. Several features were extracted from the collected voltage signals that indicate the health state of a switched-mode power supply (SMPS). Then, the data were reduced to a smaller sample space by using a principal component analysis (PCA). A robust machine learning algorithm, the support vector machine (SVM), was used to classify different health states of an SMPS, and the classification results are presented for different parameters. An SVM approach assisted by a PCA algorithm provides a strong fault diagnosis framework for an SMPS.

Key Words : Failure Prognostic(고장예지), Machine Learning(기계학습), Switching Mode Power Supply(스위칭 모드 전원공급장치), Prognostics and Health Management(고장예지 및 건전성 관리)

1. 서 론

고장예지는 기존 공학적 지식에 인공지능, 사물 인터넷, 빅 데이터 등을 융합한 4차 산업혁명의 핵심으로서 활발한 기술 개발이 이루어지고 있다^[1]. 현재 대부분의 장비는 고장 발생을 억제하기 위해 정기적인 계획정비를 하고 있기 때문에 사용 상황에서 과도한 시간 및 유지보수 비용을 초래하는 문제점이 발생하고 있다. 이를 보완한 것

이 고장예지 및 건전성 관리(PHM : Prognostics and Health Management)라고 할 수 있으며, 이는 장비나 시스템의 건전성을 실시간으로 모니터링하여 상태를 진단하고, 잔존 유효수명을 예측하는 연구 분야이다. 그 동안 PHM 분야는 고도의 안전이 요구되는 분야에 적용하여 왔지만, 최근에는 여러 산업 분야에 사용되어 사회적 및 경제적 손실을 줄이고 있다.

고장예지 성공사례로는, ‘딥러닝을 활용한 저널 베어링 고장진단’, ‘상호학습을 활용한 베어링 수명 예측’, ‘전력용 변압기의 기계적 고장 진단 및 예지’ 등 각 산업에서 활발하게 시스템의 성능을 검증 및

Corresponding Author : hhjw@kumoh.ac.kr

Tel: +82-54-478-7399


발전하는 단계에 있다²⁾.

특히, 대부분의 장비는 스위칭 동작에 의한 전원 공급장치인 SMPS(Switching Mode Power Supply)를 사용하고 있는데, 이는 장시간 작동 시 전기적 과부하나 기계적 균열 등으로 인하여 고장이 발생하기 때문에, SMPS의 고장예지에 의한 건전성 관리의 중요성도 함께 증가하고 있다^{3, 4)}.

따라서, 본 연구에서는 일상에서 SMPS가 사용되는 대표적인 경우로 LED 조명이 있으므로 LED 조명용 SMPS의 고장유형 및 영향 분석(FMEA, Failure Mode Effect and Analysis)을 조사하여 고장현상을 파악하고, 시험을 통해 정상상태와 고장상태의 전압 데이터를 확보한 후, 머신러닝을 적용하여 SMPS의 고장예지를 수행하였다.

2. 고장모드 분석 및 시험

SMPS에 대한 FMEA결과는 Table 1과 같이 과전압 및 내부 발열로 인한 커패시터의 누설 전류 증가, 전해부식으로 인한 전기적 특성 변화, 열화에 따른 내구성 감소로 인한 바리스터 고장, 급속한 화학물 석출에 의한 PCB 고장, 그리고 전기적 과부하로 인한 스위칭 소자(MOSFET)의 열화 및 손상 등 총 5가지의 형태로 구분할 수 있다⁵⁾. 가장 취약한 고장형태는 RPN이 제일 높은 varistor이지만, SMPS에서 가장 핵심적인 기능을 수행하고 있는 MOSFET을 대상으로 하였으며,



(a) Before failure (b) After failure

Fig. 1 Photos of before and after MOSFET failure

고장 형태는 전기적 과부하로 인한 열화 및 손상이고, 고장 전후의 사진을 Fig. 1에 나타내고 있다.

SMPS로부터 데이터를 수집하기 위해 Fig. 2와 같이 SMPS, LED 및 data logger(USB-4702) 등으로 시험장치를 구성하였으며, SMPS의 사양은 Table 2와 같다. SMPS속 MOSFET에 과전류가 가해지거나 이상이 있을 때에는 LED가 깜빡거리고 빛의 세기가 약해지는 현상이 발생하였으며, 이러한 현상이 일정시간 지속되면 LED가 점멸하는 고장으로 연결되었다.

전기적 과부하로 인한 MOSFET의 열화 및 손상이 고장의 주요 원인으로 파악됨에 따라 SMPS속 MOSFET과 data logger(USB-4702)를 연결하여 실시간으로 전압데이터를 측정하였다. 저항 값을 낮추어 전류를 높이는 방법을 사용하였고⁶⁾, Table 3은 MOSFET과 연결된 저항 값들을 표시하고 있으며, 초기 저항값(R_0)에서 각각 5%(R_1), 25%(R_2), 50%(R_3)로 변경하였다.

Table 1 FMEA results of SMPS

Type	Function	Failure mode	Cause of failure	Occurrence	Severity	Detection	RPN
Capacitor	Noise rejection	Leakage current increase	Overvoltage & internal heating	4	4	3	55
Resistor	Voltage¤t control	Bad connection & corrosion	Increased resistance due to corrosion	3	3	3	30
Varistor	Circuit protection	Electrical breakdown	Reduced durability due to deterioration	8	8	8	512
PCB	Electronic migration	Short & crack	Intermetallic compound precipitation	4	8	4	128
MOSFET	Switching control force generation	Short & crack	Electrical overload & crack	4	8	5	160




Fig. 2 Fault prediction big data collection system conceptual diagram

Table 2 Specification of SMPS

Model	Voltage	Rated current	Rated power
LRS-50-12	12 V	4.2 A	50.4 W

Table 3 Failure rate and resistance category

Resistance	Value(Ω)
R ₀	6850
R ₁	6390
R ₂	5130
R ₃	3371

3. 머신러닝을 이용한 고장예지

3.1 데이터 수집 및 전처리

MOSFET에 연결된 저항이 R₀와 R₁의 시험에서는 LED가 정상적으로 작동되었으나, R₂와 R₃의 시험에서는 LED 빛의 세기가 약해지거나 점멸하였으며, 이러한 시험결과를 바탕으로 R₀와 R₁을 정상 데이터(normal data), R₂와 R₃를 고장 데이터(faulty data)로 고려하였다. data logger를 이용하여 전압 데이터를 분석한 결과, 100만 개의 데이터가 수집되었으며, 머신러닝을 수행하기 위해서는 빅 데이터를 training data로 변환하는 전처리 과정이 필요하다. 이를 위해 데이터 축소(data reduction) 방법을 적용하여 Table 4와 같이 정리하였으며, 총 2,000개의 데이터 중 머신러닝에 사용할 학습 데이터는 1,500개이고, 시험 데이터는 500개로 하였다.

Table 4 Results of data reduction

No	Min	Max	Mean	Std	Var	RMS	State
0	-2.63	8.76	0.38	1.96	3.84	2.00	0
1	-2.42	8.74	0.39	1.95	3.80	1.99	0
2	-5.34	8.76	0.39	1.96	3.85	2.00	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1997	-2.51	8.74	0.76	2.09	4.36	2.22	1
1998	-2.67	8.79	0.74	2.07	4.30	2.20	1
1999	-2.54	8.77	0.74	2.06	4.26	2.19	1

3.2 PCA 기반의 SVM 머신러닝 기법

PCA(Principal Component Analysis)는 다양한 분야의 패턴 인식에서 대표적으로 차원 축소를 위해 이용되는 다변량 통계 분석 방법이다. 주어진 데이터를 분산이 최대가 되는 축으로 변환하는 것으로, 새로운 차원에서의 데이터의 벡터들을 주성분(Principal Components)이라고 한다. 이 때 분산이 작은 성분을 제거함으로써 데이터의 차원을 줄이는 동시에 데이터에 포함되어 있던 잡음(noise)를 제거할 수 있다.

PCA에 의해 축소된 데이터는 구조를 최적으로 분류하는 강력한 알고리즘인 SVM(Support Vector Machine)의 학습 데이터로 사용하였다. SVM은 비선형 매핑함수를 이용하여 학습 데이터의 공간을 최적의 선형 초평면(optimal hyperplane)이 만들어지는 고차원 특징 공간으로 매핑하고, 초평면과 가장 가까운 입력 샘플벡터를 지지벡터(support vector)라고 하며, 서로간의 거리가 최대가 되도록 최적화하는 특징을 가지고 있다^[7].

선형분리 가능한 데이터에 대한 초평면의 예를 Fig. 3에 표시하고 있으며, 이 때 커널함수는 비선형 매핑함수의 내적계산을 함수 형식으로 치환하여 간단하게 해주고, SVM을 구현하기 위하여 학습 데이터를 식 (1)과 같이 나타낼 수 있다^[8].

$$D = \{(x_i, y_i) | i = 1, 2, \dots, n\} \quad (1)$$

여기서, x_i 는 n 차원의 특징벡터를 의미하고, 클래스 $y_i \in \{-1, 1\}$ 를 갖는다.




Fig. 3 Description of support vector machine

Table 5 Changing parameters by kernel

Type	Parameter	Change value
Linear	none	change C values only
Polynomial	γ	2, 3, 4, 5, 6, 7, 8, 9, 10
RBF	γ	0.01, 0.1, 1, 5, 10, 15, 25
Sigmoid	γ	0.001, 0.01, 0.1, 1, 50, 100

SVM의 분류 정확성과 복잡성은 커널 파라미터 C(cost)와 결정 경계의 곡률인 γ 을 어떻게 정의하느냐에 달려 있기 때문에 최적의 파라미터를 찾아야 한다. 여기서 C는 오류 허용 임계치로 얼마나 많은 데이터 샘플이 다른 클래스에 놓이는 것을 허용하는지 결정하며, γ 는 하나의 데이터 샘플이 영향력을 행사하는 거리를 조정한다.

SVM의 커널은 일반적으로 linear, polynomial, RBF, sigmoid 커널을 사용하는데, 각 커널의 C값은 1, 10, 50, 100, 1000, 10,000으로 동일하게 변경하고, linear 커널을 제외한 polynomial, RBF 및 sigmoid의 γ 는 Table 5와 같이 선정하였다⁹⁾.

PCA를 통해 전압 데이터의 특징 벡터를 추출한 학습 데이터로 SVM 모델을 만들고, 4개 커널 (linear, polynomial, RBF, sigmoid)의 파라미터 C와 γ 을 조절해 가며 정확도를 기록하며, 가장 높은 정확도의 커널과 파라미터를 최적의 PCA-SVM 전압 분류기로 선정 후, confusion matrix를 통해 시험 데이터를 이용하여 분류의 정확도를 판단하였다.

4. 고장예지 결과 및 고찰

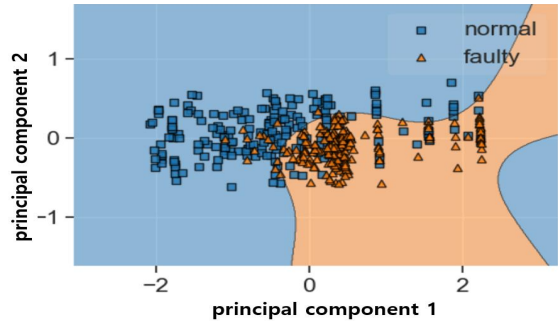


Fig. 4 Testing results of support vector machine



Fig. 5 Confusion matrix of SVM




Fig. 6 Result of support vector machine

PCA-SVM 전압 분류기로 전압을 분류한 결과를 Fig. 4에 나타내었으며, PCA를 통해 principal component 1, 2를 축으로 하는 학습 데이터의 SVM 모델을 시각적으로 표현하고 있다. SVM의 confusion matrix를 Fig. 5에 표현하였으며, x축은 실제 데이터를 나타낸 축이고, y축은 머신러닝을 통해 데이터를 어떤 클래스로 몇 개를 분류하였는지 표시하고 있다. 실제 normal data 174개 중 157

Table 6 Accuracy comparison of kernel type and parameters

Type	Parameters		Precision	Recall	F1-score	Accuracy (%)
	C	γ				
Linear	10	-	77.5	77.5	77.3	77
Polynomial	10	10	49.5	49.5	49.3	49
RBF	1,000	0.1	79.0	79.0	78.8	79
Sigmoid	10,000	0.001	75.0	75.0	75.0	75

개(90%)를 normal로 구분하였고, faulty data 226개 중 188개(83%)를 faulty로 식별하였다. PCA-SVM 전압 분류기의 알고리즘을 적용한 support vector machine의 결과를 Fig. 6에 나타내었다. 약 50개의 support vector를 찾을 수 있었으며, RBF 커널을 이용한 optimal hyperplane을 식별할 수 있었다.

PCA에 의해 차원이 축소된 데이터를 대상으로 SVM을 이용한 분류를 위해 학습 데이터와 시험 데이터를 10-fold 교차 검증을 하였으며, 이때 3:1의 비율로 나누어 사용하였다. 그리고 기본 클래스 및 조합 클래스에 대한 고장진단을 위한 함수 학습모델의 예측 정확성을 평가하기 위해 다음 식과 같이 precision, recall 및 F1-score를 계산하였다^[10].

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

$$F_1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

전체적인 예지 모델의 성능 평가는 식 (5)와 같이 Accuracy를 적용하였다.

$$\text{Accuracy} = \frac{TP+TN}{TP+FN+TN+FP} \quad (5)$$

여기서 TP는 True Positive, TN은 True Negative, FP은 False Positive, FN은 False Negative를 의미한다.

각 커널별로 파라미터 C와 γ 를 최적으로 설정

하였을 때의 분류 결과를 Table 6으로 나타내었다. 파라미터를 C=1000, $\gamma=0.1$ 으로 설정한 RBF 커널을 사용하였을 때, 가장 높은 정확도인 79%를 보였다.

5. 결론

대부분의 장비에서 핵심품목으로 사용하고 있는 SMPS를 대상으로 빅 데이터 및 머신러닝을 수행하여 고장을 예지하였다. 얻어진 결과를 요약하면 다음과 같다.

1. SMPS의 MOSFET에 연결된 저항변화를 이용한 전압 데이터를 획득 및 추출하여 머신러닝을 통해 고장을 예지할 수 있다.
2. normal data 174개 중 157개(90%)를 normal로 구분하였고, faulty data 226개 중 188개(83%)를 faulty로 식별하였다.
3. PCA-SVM을 통해 머신러닝을 수행한 결과 RBF 커널의 accuracy가 79%로 가장 높게 나타났다.

후 기

본 논문은 국방과학연구소의 지원(RAM 특화연구실, UD180018AD)을 받아 수행된 연구 결과임.

REFERENCES

1. Choi, H., Kim, T. K., Heo, G. R., Hur, J. W., Choi, S. D., "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.
2. Yun, B. D., "Cases of Fault Diagnosis and Prediction Technology Application to the Energy Industry", The Korean Society of Mechanical Engineers International Journal, Vol. 53 No. 7, pp. 44-52, 2013.
3. Zheng, X., Wu, L., Guan, Y., and Li, X., "Analysis of the Degradation of MOSFETs in Switching Mode Power Supply by Characterizing

- Source Oscillator Signals”, *Mathematical Problems in Engineering*, Vol. 2013, Special Issue, pp. 1-7, 2013.
4. Ye, X., Chen, C., Wang, Y., Zhou, Y. and Vachtsevanos, G., "Health-assessment methodology research for SMPS based on simulation", 2015 Annual Reliability and Maintainability Symposium (RAMS), Palm Harbor, FL, pp. 1-7, 2015.
 5. Jang, I. H., “A Study on the Design and Analysis of Degradation Test for LED Lamp SMPS”, Ph. D. dissertation, Chosun University, Republic of Korea. 2016.
 6. Hayes, J. H., “Modeling and Tracking Degradation in Electronic Components”, Ph. D. dissertation, Clemson University, United States of America, 2017.
 7. Yun, S. H., Park, B. H., Lee, C. W., “A Study on Fault Diagnosis Algorithm for Rotary Machine using Data Mining Method and Empirical Mode Decomposition”. *Journal of the Korean Society of Manufacturing Process Engineers*, Vol. 15, No. 4 pp. 23-29 2016.
 8. Kim, S. J., “A Wavelet-based Profile Classification using Support Vector Machine”, *Journal of Korean Institute of Intelligent Systems*, Vol. 18 No. 5, pp. 718-723, 2008.
 9. Kim, S. Y., Park, S. H., "Multi-class Classification of Database Workloads using PCA-SVM Classifier", *Journal of Korean Institute of Information Scientists and Engineers : Databases*, Vol. 38, No. 1, pp. 1-8, 2011.
 10. Jung, H., Kim, J. W., "A Machine Learning Approach for Mechanical Motor Fault Diagnosis," *Journal of the Society of Korea Industrial and Systems Engineering*, Vol. 40, No. 1, pp. 57-64, 2017.