

머신러닝을 이용한 드론의 고장진단에 관한 연구

박수현*, 도재석*, 최성대*, 허장욱*[#]

*금오공과대학교 기계시스템공학과

Fault Diagnosis of Drone Using Machine Learning

Soo-Hyun Park*, Jae-Seok Do*, Seong-Dae Choi*, Jang-Wook Hur*[#]

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

(Received 27 May 2021; received in revised form 19 June 2021; accepted 19 July 2021)

ABSTRACT

The Fourth Industrial Revolution has led to the development of drones for commercial and private applications. Therefore, the malfunction of drones has become a prominent problem. Failure mode and effect analysis was used in this study to analyze the primary cause of drone failure, and blade breakage was observed to have the highest frequency of failure. This was tested using a vibration sensor placed on drones along the breakage length of the blades. The data exhibited a significant increase in vibration within the drone body for blade fracture length. Principal component analysis was used to reduce the data dimension and classify the state with machine learning algorithms such as support vector machine, k-nearest neighbor, Gaussian naive Bayes, and random forest. The performance of machine learning was higher than 0.95 for the four algorithms in terms of accuracy, precision, recall, and f1-score. A follow-up study on failure prediction will be conducted based on the results of fault diagnosis.

Key Words : Failure Prognostic(고장예지), Machine Learning(기계학습), Drone(드론), Blade(블레이드), Prognostics and Health Management(고장예지 및 건전성 관리)

1. 서 론

고도의 정보화를 기반으로 하는 4차산업 혁명에 있어서 머신러닝은 필수적 요소 중 하나이며, 공학적 지식과 경험적 데이터를 컴퓨터 학습과 융합해 기술 향상이 이루어지고 있다. 이러한 학습에 있어서 빅데이터가 필연적으로 요구되는데, 빅데이터는 방대한 데이터 양이라고 말할 수 있지만, 방대한 데이터로부터 경제적 가치를 추출 및 분석

할 수 있어야 한다. 이러한 빅데이터를 이용한 머신러닝을 활용하여 장비의 고장진단 및 고장예지 기술 연구가 최근 활발하게 진행되고 있다^[1].

4차산업 혁명에 있어서 드론은 기술 고도화의 집약체라고 할 수 있으며, 4차산업 혁명 이전의 드론은 일반적으로 군사적 역할에 치중되어 있었지만, 통신 및 제어 기술의 발전을 통해 산업현장 및 민간용 드론 보급이 크게 증가하고 있다. 이에 따른 드론 사용이 증가함에 따라 오작동에 의한 추락, 장애물과의 충돌, 배터리 과열에 의한 폭발 등의 사고들이 빈번하게 발생하고 있다^[2].

드론의 동력부 중 하나인 블레이드에 작은 손상

[#] Corresponding Author : hhjw88@kumoh.ac.kr

Tel: +82-54-478-7399

Table 1 FMEA results of Drones

Type	Function	Fault_ Mode	Cause of Fault_	Occurrence	Severity	Detection	RPN
Battery	Power Storage	Overheating & Lack of power	Hot weather/Manufacturing problem & Overloading	7	16	11	312
Motor	Switching to mechanical energy	Bearing Fault & Mechanical Malfunction	Fatigue & Mechanical Fault_	5	16	12	248
Blades	Thrusting device	Fracture & Crack	Manufacturing/collision with obstacle	7	15	9	232
GPS Antenna	Receive radio signals transmitted at a specific frequencies	Unable to receive accurate time and location data	Loss of connection due to range or weather/lack of power	5	8	4	160

이라도 발생한다면 추력을 잃는 것 뿐만 아니라, 드론 전체에 진동이 발생하게 되어 큰 손상을 야기하게 된다^[3]. 따라서, 본 연구에서는 드론에 대한 FMEA(Failure Mode Effect and Analysis)를 통해 고장 유형 및 영향을 분석하고, 실험을 통해 정상상태와 블레이드 고장상태의 진동 데이터를 수집하여, 최적의 머신러닝 알고리즘 선정 및 드론의 고장진단을 제시하였다.

2. 고장모드 분석 및 실험

드론에 대한 FMEA 결과는 Table 1과 같이 배터리 과열, 모터의 기계적 고장, 블레이드의 기계적 파손, GPS Antenna의 정확한 시간 및 위치 데이터 수신불가 등이 있다^[4]. 표에서 알 수 있는 바와 같이 가장 취약한 고장형태는 RPN(Risk Priority Number)이 제일 높은 Battery이지만, 발생 빈도가 높은 동적 구성품인 블레이드를 대상으로 실험을 진행하였으며, 고장 형태는 블레이드 파단에 의한 드론 내 진동변화를 고려하였다^[5-6].

드론으로부터 데이터를 수집하기 위해 Fig. 1과 같이 전원공급장치, 드론, 블레이드, 가속도 센서 등으로 시험장치를 구성하였으며, 드론의 사양은 Table 2와 같다. 드론에 전원을 계속해서 공급하기 위해 전원공급장치를 이용하여 드론 배터리에 직접 전압을 공급하는 유선드론 형식으로 적용하였고, 가속도 센서를 드론에 부착하였다.




Fig. 1 Fault prediction big data collection system conceptual diagram

Table 2 Specification of Drone

Model	Rated Voltage	Rated Current	Rated Power
MJX Bugs 3	7.4 V	5.94 A	43.96W

장애물과의 충돌 등으로 인한 블레이드의 기계적 파손을 고장의 주요 원인으로 파악함에 따라 DAQ와 가속도 센서를 드론에 연결하여 실시간으로 진동 데이터를 측정하였다. 블레이드의 파손 정도가 심해질수록, 드론 내 진동이 증가하기 때문에 이때 블레이드의 길이별 드론 내의 진동변화를 측정하였고, 정상 데이터값(Healthy)에서 각각 블레이드 길이를 0.5cm (Failure_1), 1cm(Failure_2), 1.5cm(Failure_3) 짧게하여 데이터를 추출하였다.

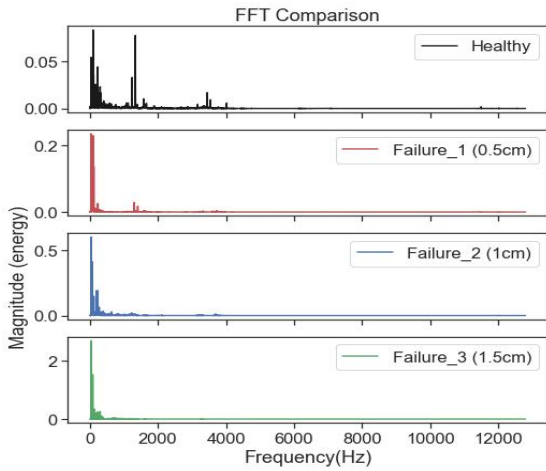


Fig. 2 FFT Comparison

3. 머신러닝을 이용한 고장진단

3.1 데이터 수집 및 전처리

드론의 블레이드 파단 길이별 드론의 기체 내 진동 변화를 활용해서 고장을 진단하기 위해 DAQ를 이용하여 768,000개의 진동 데이터를 수집하였다. 이 때, DAQ의 최대 샘플링 속도는 51.2ks/s이나 noise와 glitching 발생이 컸기 때문에 샘플링 속도를 25.6ks/s로 설정하여 데이터를 수집하였으며, 획득한 데이터 중 학습에 사용할 train data는 537,600개(전체 데이터의 70%), test data는 230,400개(전체 데이터의 30%)로 하였다.

수집한 데이터를 FFT로 변환한 그래프를 Fig. 2에 나타내었다. Failure_3(1.5cm)의 Magnitude가 2 이상으로 가장 크게 나왔고, Failure_2(1cm), Failure_1(0.5cm), Healthy 순으로 Magnitude가 작아짐을 확인할 수 있다.

Raw data를 이용하여 머신러닝 수행을 위해 식 (1)~(4)와 같이 RMS(Root Mean Square, 제곱평균), CF(Crest Factor, 파고율), KUR(KURtosis, 첨도), SKEW(SKEWness, 비대칭도) 등으로 특징을 추출하였으며, 그 결과를 Table 3에 나타내었다.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n)]^2} \quad (1)$$

$$CF = \frac{\max[x(n)]}{RMS} \quad (2)$$

$$KUR = \frac{N \sum_{n=1}^N [x(n) - \bar{x}]^4}{[N \sum_{n=1}^N [x(n) - \bar{x}]^2]^2} \quad (3)$$

$$SKEW = \frac{N \sum_{n=1}^N [x(n) - \bar{x}]^3}{[N \sum_{n=1}^N [x(n) - \bar{x}]^2]^{\frac{3}{2}}} \quad (4)$$

Table 3 Results of data reduction

No	RMS	CF	KUR	SKEW
0	0.270504	2.066042	-0.393896	-0.266308
1	0.285654	2.170659	-0.729146	-0.135784
2	0.242233	2.613306	-0.165856	0.231573
⋮	⋮	⋮	⋮	⋮
5997	2.152278	1.909145	-1.405251	0.111276
5998	2.112768	1.985272	-1.367877	0.339361
5559	2.197427	2.490363	-1.316691	0.238379

이때, 추출된 데이터는 다차원 데이터이므로 차원을 축소할 필요가 있는데, 차원 축소 기법으로는 분포의 주성분을 분석해주는 통계적 방법인 PCA(Principal Component Analysis)를 적용하였다. PCA는 데이터들의 분산이 가장 큰 방향을 의미하며, 데이터들의 평균점을 지나는 직선들 중에서 데이터의 분산이 최대가 되는 방향으로 데이터를 투영시켜 차원을 축소하는 방법이다^[7].

3.2 고장진단 알고리즘 적용

(1) SVM 기법

SVM(Support Vector Machine) 기법은 대표적인 기계 학습 알고리즘으로써 다양한 패턴 인식 분야에 적용되고, PCA로 처리한 데이터를 SVM으로 최적의 학습데이터를 사용한다^[8]. 머신러닝을 수행한 결과를 Fig. 3에 나타내었다. 그림에서 Healthy

와 Fault_1 그룹 및 Fault_2와 Fault_3 그룹은 각자 서로 인접한 분류를 표시하고 있으나, Healthy, Fault_1 그룹과 Fault_2, Fault_3 그룹은 명확하게 분류되고 있음을 알 수 있다. 또한, Confusion matrix를 Fig. 4와 같이 나타내었으며, 각 상태별 2,000개의 data에 대해 Healthy data는 1,779개, Fault_1 data는 1,781개, Fault_2 data는 1,771개, Fault_3 data는 1,773개를 올바르게 분류하고 있다.

(2) KNN 기법

KNN(k-Nearest Neighbor) 기법은 주어진 데이터를 활용하여 유사치를 측정하는 k개의 주변값을 예측하는 알고리즘이다. 이 알고리즘은 데이터 편

차의 고저에 따라 정확도가 크게 달라지고, 그에 따라 k 값 설정이 정확도에 큰 영향을 미친다^[9].

머신러닝 수행결과를 Fig. 5에 나타내었으며, SVM 기법과 유사한 분류형상을 보이고 있다. 또한, Confusion matrix를 Fig. 6과 같이 나타내었으며, 각 상태별 2,000개의 data에 대해 Healthy data는 1,779개, Fault_1 data는 1,781개, Fault_2 data는 1,774개, Fault_3 data는 1,737개를 올바르게 분류하고 있다.

(3) GNB 기법

GNB(Gaussian Naive Bayes) 기법은 연속성을 가진 데이터를 처리할 때, 그 데이터가 독립변수로




Fig. 3 Testing results of SVM

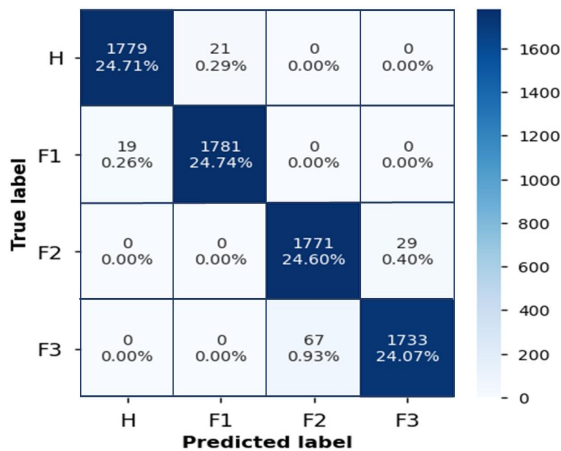


Fig. 4 Confusion matrix of SVM




Fig. 5 Testing results of KNN

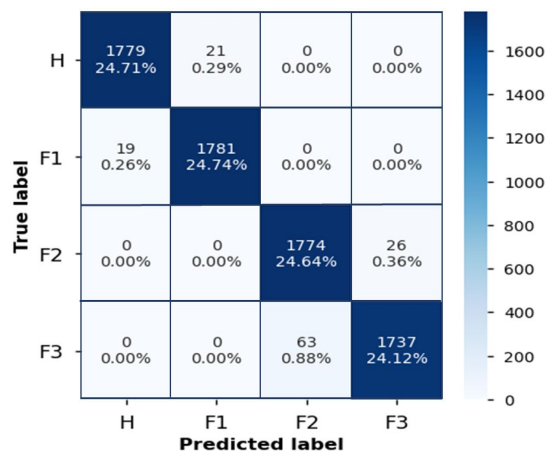


Fig. 6 Confusion matrix of KNN

가우스 분포를 따른다고 설정하여 결과에 영향을 주는 요소에 따라 베이지 정리를 적용하는 기법이다.

머신러닝 수행 결과를 Fig. 7에 나타내었으며, SVM 및 KNN 기법과 유사한 분류형상을 보이고 있다. 또한, Confusion matrix를 Fig. 8과 같이 나타내었으며, 각 상태별 2,000개의 data에 대해 Healthy data는 1,774개, Fault_1 data는 1,758개, Fault_2 data는 1,766개, Fault_3 data는 1,738개를 올바르게 분류하고 있다.

(4) RF 기법

RF(Random Forest) 기법은 회귀 분석에서 사용하는 앙상블 학습 중 하나로 학습과정에서

Decision Tree의 과적합되는 단점을 보완한 기법이다. 구성된 결정 트리를 복원 추출을 통해 무작위로 데이터를 가져온 후 트리의 숲을 만들고 분류 또는 평균 예측치를 출력하는 알고리즘이다. 이러한 기법은 변수 소거 없이 매우 많은 데이터 변수들을 재구성할 수 있어 정확성이 높다^[10].

머신러닝 수행 결과를 Fig. 9에 나타내었으며, SVM, KNN, 및 GNB 기법과 유사한 분류형상을 보이고 있다. 또한, Confusion matrix를 Fig. 10과 같이 나타내었으며, 각 상태별 2,000개의 data에 대해 Healthy data는 1,780개, Fault_1 data는 1,781개, Fault_2 data는 1,762개, Fault_3 data는 1,741개를 올바르게 분류하고 있다.




Fig. 7 Testing results of GNB

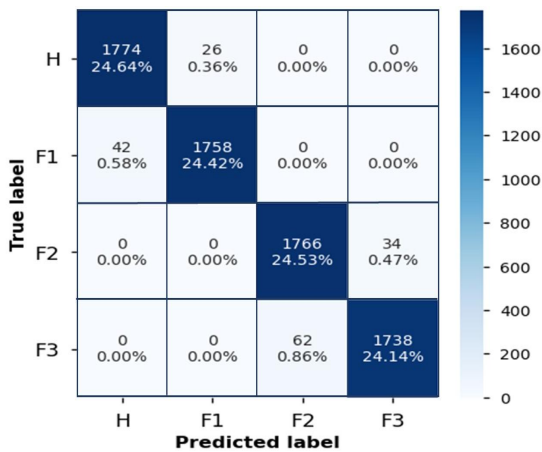


Fig. 8 Confusion matrix of GNB




Fig. 9 Testing results of RF

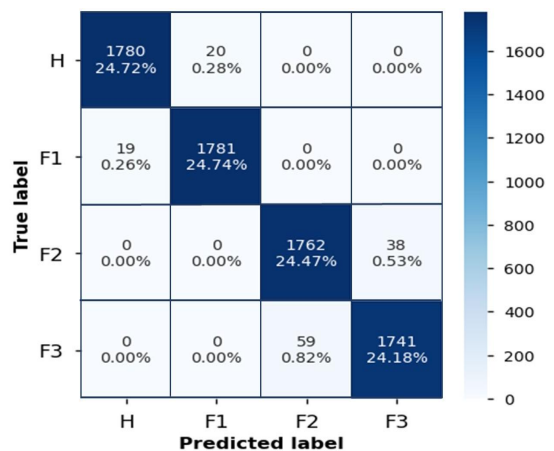


Fig. 10 Confusion matrix of RF

Table 4 Algorithm Classification Report

Algorithm	Accuracy	Precision					Recall					F1-score				
		Mean	H	F1	F2	F3	Mean	H	F1	F2	F3	Mean	H	F1	F2	F3
Support Vector Machine	0.98	0.98	0.99	0.99	0.96	0.99	0.98	0.99	0.99	0.99	0.96	0.98	0.99	0.99	0.97	0.97
k-Nearest Neighbor	0.98	0.99	0.99	0.99	0.97	0.99	0.98	0.99	0.99	0.99	0.96	0.99	0.99	0.99	0.98	0.98
Gaussian Naive Bayes	0.98	0.98	0.98	0.99	0.97	0.98	0.98	0.99	0.98	0.98	0.97	0.98	0.98	0.98	0.97	0.97
Random Forest	0.98	0.98	0.99	0.99	0.97	0.98	0.98	0.99	0.99	0.98	0.97	0.98	0.99	0.99	0.97	0.97

4. 고찰

고장진단 학습 모델의 성능은 식(5)~(8)과 같은 파라미터를 이용하여 평가할 수 있으며, 여기서 TP는 True Positive, FP는 False Positive, FN은 False Negative, 그리고 TN은 True Negative를 의미한다. 또한, Accuracy는 전체 데이터 중에서 True는 True로 False는 False로 분류한 것을 의미하고, Precision은 모델이 True로 분류한 값들 중에 실제 True인 것의 비율이며, Recall은 실제 True인 것 중 모델이 True로 예측한 비율이다. 마지막으로 F1-Score는 Precision과 Recall의 조화평균을 의미한다.

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

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (8)$$

4가지 머신러닝 알고리즘별 모델의 성능평가 파라미터를 활용하여 계산한 결과를 Table 4와 Fig. 11에 나타내었다. 표와 그림의 결과로부터 4가지 알고리즘 모두에서 Accuracy, Precision, Recall 및




Fig. 11 Performance metrics for different classifiers




Fig. 12 Time-performance for different classifiers

F1-score가 0.95이상으로 높게 나왔다. 또한, 각각의 알고리즘에 대한 시간(비용) 대비 성능은 Fig. 12와 같으며, Value 값이 낮을수록 학습에 있어 시간이 적게 소요됨을 나타내었다. 따라서, 비용대비 성능이 우수한 알고리즘은 KNN(0.15), SVM(0.21), RF(0.28) 및 GNB(0.32) 순이며, 이러한 결과로부터 KNN 알고리즘이 가장 우수함을 알 수 있다.

5. 결 론

드론에서 주요 고장원인 중 하나인 블레이드를 대상으로 빅데이터 및 머신러닝을 수행하여 고장을 진단하였다. 얻어진 결과를 요약하면 다음과 같다.

- 1) 드론의 FMEA 결과 블레이드 파손이 고장발생 빈도가 가장 높으며, 드론의 블레이드 고장을 대상으로 머신러닝에 의한 고장진단이 가능하다.
- 2) 머신러닝의 성능은 4가지 알고리즘 모두에서 Accuracy, Precision, Recall 및 F1-score가 0.95 이상으로 높게 나왔으며, 특히 KNN 알고리즘이 다른 기법보다 다소 높음을 알 수 있다.
- 3) 비용(시간)대비 성능이 우수한 알고리즘은 KNN (0.15), SVM(0.21), RF(0.28) 및 GNB(0.32) 순으로 나타났다.

후 기

이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2019R111A3A01063935).

REFERENCES

1. Om, S. Y., Park, J. H., and Kim, Y. H., "Implementation of Abnormality Diagnosis System for Drone Power Unit by Using Vibration Sensor", Journal of the KIIT, Vol. 18, No. 4, pp. 69-76, 2020.
2. Lee, Y. B., and Ko, S. H., "A Survey on Open-Source based UAVCAN Protocol Technology for Fault_Detection of Main Components of Drones", KSAS 2017 Fall Conference, pp. 782-783, 2017.
3. Lee, Y. B., and Ko, S. H., "A Survey on Open-Source based UAVCAN Protocol Technology for Fault_Detection of Main Components of Drones", KSAS 2017 Fall Conference, pp.782-783, 2017.
4. Shafiee, M., Zhou, Z., Mei, L., Dinmohammadi, F., Karama, J., and Flynn, D., "Unmanned Aerial Drones for Inspection of Offshore Wind Turbines: A Mission-Critical Failure Analysis", Robotics, Vol. 10, No. 26, pp. 1-27, 2021.
5. Jung, S. J., and Hur, J. W., "Deep Learning Approaches to RUL Prediction of Lithium-ion Batteries," Journal of the Korean Society of Manufacturing Process Engineers, Vol. 19 No. 12, pp. 21-27, 2020.
6. Shifat, T. A., Hur, J. W., "EEMD assisted supervised learning for the fault diagnosis of BLDC motor using vibration signal," Journal of Mechanical Science and Technology, Vol. 34, No. 10, pp. 3381-3390, 2020.
7. Xia, C. L., Shin, H. G., Park, M. C., and Ha, S. W., "A Fast Method for Face Detection Based on PCA and SVM", Journal of the KIIT, pp. 1129-1135, 2007.
8. Kim, S. J., Akpudo, U. E., and Hur, J. W., "A Study on Fault Classification of Solenoid Pumps based on Multi-Layer Perceptron," Journal of The Korean Reliability Society, Vol. 21 No. 1 pp. 12-19, 2021.
9. Lee, H. S., Kim, E. T., and Kim D. Y., "Pattern Recognition System Combining KNN rules and New Feature Weighting algorithm", The Institute of Electronics Engineers of Korea - Computer and Information, Vol. 42 No.4 pp. 43-50, 2005.
10. Kim, C. W., and Seo, Y. J., "Design and Performance Prediction of Ultra-low Flow Hydrocyclone Using the Random Forest Method", Journal of the Korean Society of Manufacturing Technology Engineers, Vol. 29 No. 2, pp. 83-88, 2020.