

SVM 기법을 적용한 구름베어링의 부식 고장진단

고정일*, 이의영*, 이민재*, 최성대*, 허장욱*,#

*금오공과대학교 기계시스템공학과

Corrosion Failure Diagnosis of Rolling Bearing with SVM

Jeong-Il Go*, Eui-Young Lee*, Min-Jae Lee*, 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

A rotor is a crucial component in various mechanical assemblies. Additionally, high-speed and high-efficiency components are required in the automotive industry, manufacturing industry, and turbine systems. In particular, the failure of high-speed rotating bearings has catastrophic effects on auxiliary systems. Therefore, bearing reliability and fault diagnosis are essential for bearing maintenance. In this work, we performed failure mode and effect analysis on bearing rotors and determined that corrosion is the most critical failure type. Furthermore, we conducted experiments to extract vibration characteristic data and preprocess the vibration data through principle component analysis. Finally, we applied a machine learning algorithm called support vector machine to diagnose the failure and observed a classification performance of 98%.

Key Words : Failure Prognostics(고장진단), Rolling Bearing(구름베어링), Machine Learning(머신러닝), Failure Mode and Effect Analysis(고장모드 및 영향 분석)

1. 서 론

건전성 예측 및 관리 기술(PHM : Prognostics and Health Management)은 4차 산업 혁명에 있어 중요한 부분을 차지하고 있으며, 다양한 분야에서 적용되고 있다. PHM 기술의 궁극적인 목표는 다양한 사업 분야에서의 유지보수 비용 감소뿐만 아니라 정지시간 감소로 인한 장비 가동율 향상에 있으며, 최근에는 머신러닝

을 이용하여 데이터를 학습시켜 고장을 예지하는 방법론이 활발하게 연구되고 있다^[1].


자동차 산업, 제조산업, 터빈시스템 등 대부분의 기계설비 분야에서 회전체가 핵심 요소로 사용되고 있으며, 고속, 고효율 및 대형화로 인해 진동에 대한 문제가 중요하다^[2]. 특히, 고속으로 회전하는 구름베어링의 경우 높은 신뢰성이 요구되어 고장을 진단하는 시스템의 적용이 필수적인데, 대표적인 머신러닝 방법은 Naive Bayes Classification, RF(Random Forest) 및 SVM (Support Vector Machine) 등이 있으나, 대부분 미세 이물질로 인한 마멸과 질량 불균형 등을 대상으로 하고 있다^[3].

Corresponding Author : hhjw88@kumoh.ac.kr

Tel: +82-54-478-7399

Table 1 FMEA worksheet for bearing

Failure mode	Potential effect(s) of failure	Severity	Occurrence	Detection	RPN
Frictional corrosion	Surface damage in form of increased surface roughness	8	7	5	280
Moisture corrosion	Lubricant contamination, increase in friction	7	7	6	294
Plastic deformation	Change in bearing surface profile, increases friction and wear	8	6	6	288
Surface indentation	Formation of uneven valleys deteriorating surface smoothness and increasing friction	9	6	6	324

**Fig. 1 Testbed configuration for experiment**

따라서 본 연구에서는 구름베어링 회전체에 대해 FMEA(Failure Mode and Effects Analysis)를 수행하여 가장 치명적인 고장 유형 및 형태를 조사하고, RPN(Risk Priority Number)이 상대적으로 높은 구름베어링의 수분 부식을 대상으로 실험을 통해 진동 특성 데이터 추출 및 전처리를 수행하였으며, 머신러닝 알고리즘인 SVM을 적용하여 고장을 진단하였다.

2. 고장모드 및 실험

2.1 고장모드

구름베어링을 포함한 회전체를 대상으로 FMEA를 수행한 결과를 Table 1에 나타내었다^[4]. FMEA는 신뢰성 및 안전성 분석에 가장 널리 사용되는 도구로써, 부품의 고장모드가 시스템이나 기기에 어떤 영향을 주는지 평가하는데 주로 사용되고 있다. 표는 베어링에서 RPN 값이 가장 높은 상위 4개 항목을 표시하고 있으며, 마찰 부식, 수분 부식, 소성변형 및 표면 찍힘 등을 고장모드로 고려하고 있다^[3]. 이 중에서 RPN 값은 2번째

Table 2 Specification of SMPS

Model	Voltage	Rated current	Rated power
LRS-350-36	36 V	9.7 A	349.2

로 높지만, 발생빈도가 가장 큰 수분 부식은 구름베어링의 윤활을 오염시키므로 마찰이 증가하여 이상 진동을 발생시키기 때문에 실험 대상으로 선정하였다^{[5][6][7]}.

2.2 실험 장치 및 방법

구름베어링의 부식을 재현하기 위한 실험장치를 Fig. 1과 같이 나타내었으며, SMPS(Switching Mode Power Supply), 모터, 커플러, 구름베어링, 기어 박스 및 가속도 센서 등으로 구성하였다. SMPS의 사양은 Table 2와 같으며, SMPS로 모터를 구동하고, 구름베어링이 부착된 축을 통하여 동력이 기어 박스로 전달되도록 하였다.


구름베어링 부에 단축 가속도센서를 x, y축 두 곳에 부착하여 변화하는 진동 데이터를 추출하였다. 구름베어링이 정상상태일 때의 진동 데이터와 부식현상을 가속하여 유도하기 위해 산성비(pH 5.6)보다 pH 값이 낮은 묽은 염산(5%)에 각각 2시간 및 4시간 침적시켰을 때의 진동 데이터를 추출하여 비교하였으며, 이 때 정상상태와 수분부식 상태(묽은 염산에 침적시켜 각각 2시간 및 4시간 경과)의 형상을 Fig 2에 나타내었다.

3. 구름베어링 고장진단


FMEA를 기반으로 부식에 따른 정상상태 구름베어링과 고장상태 구름베어링의 진동 특성을 비교하기 위해



(a) Healthy



(b) Fault_1(2h)




(c) Fault_2(4h)


Fig. 2 Photos of healthy and corrosion (fault) rolling bearing

가속도 센서로부터 획득한 데이터 총 768,000개의 FFT 결과를 Fig. 3에 나타내었다. 그림으로부터 4시간 동안 묶은 염산(5%)에 투입하였던 구름베어링의 peak값이 2시간 동안 묶은 염산(5%)에 투입하였던 구름베어링의 peak값 및 정상상태의 peak값 보다 크게 증가하는 것을 알 수 있다.


획득한 데이터를 이용하여 특성 데이터를 추출하기 위해 여러 가지 함수를 대상으로 Fig. 4와 같이



(a) Healthy



(b) Fault_1(2h)



(c) Fault_2(4h)

Fig. 3 The FFT waveform of bearing vibration data

correlation analysis를 수행하였으며, 이를 통해 총 21,000 개의 데이터를 추출하였고, 특성 데이터는 Table 3에 표시한 바와 같이 RMS(Root Mean Square), VAR(Variance), STD (STandard Deviation), GSTD (Geometric STandard Deviation), IQR(Inter-Quartile Range), SEM(Standard Error of the Mean), MAD(Median Absolute Deviation), KUR (KURtosis), SKEW(SKEWness),

CF(Crest Factor) 등으로 표시할 수 있다.

correlation analysis를 통하여 추출한 데이터는 고차원을 유지하고 있으므로 머신러닝을 수행하기 위해서는 차원 축소가 필요하며, 일반적인 차원축소 알고리즘은 PCA(Principal Component Analysis)가 있다. PCA는 주요 요소들을 각각 PC-1 및 PC-2에 분류하고 적절한 초평면을 이용해 차원을 줄이는 방법이며, PCA를 통하여 총 6,000개의 데이터를 획득하였고 그 결과를 Fig. 5에 나타내었다.

SVM 기법은 다른 머신러닝 기법들과 달리 머신러닝에 사용하는 함수모형을 결정하는 다양한 kernel들을 가지며, 비선형 함수를 이용하여 데이터간의 거리가 최대가 되도록 분류하고, 최적화된 결정 경계를 찾는 특징을 가지고 있다. 또한 고차원 매핑이 가능하여 노이즈 데이터 등에 강점을 가지므로 회전체 고장진단에 가장 적합한 것으로 알려져 있다.

SVM에 각 라벨이 설정된 데이터들을 투입하면 SVM은 각 데이터들 사이에 큰 마진을 가지는 초평면을 만들고, 생성된 초평면은 같은 각 라벨이 설정된 데이터 포인트들을 hyperplane에 최대 거리를 가지도록 분류하며, 기본적으로 soft margin SVM hyperplane의 분류 성공률은 softening constraint에 따라 달라진다. 이 때, softening constraint는 샘플의 가중성을 최소화시키며, 규칙화 파라미터에 의해 정해진다. 결과적으로 SVM의 목표는 식 (1)에서 처럼 샘플의 가중치를 최소화하는 것이며, 식 (2)에서 정의된 classifier model을 생성한다.

$$\min \frac{\|w\|^2}{2} + C \sum_{i=1}^N \xi_i \quad (1)$$

$$f(x) = \text{sign}(b + \sum_{i=1}^N \alpha_i \cdot v_i \cdot K(X_i, \bar{X})) \quad (2)$$

여기서, w는 가중치, C는 결정경계 학습 파라미터인 규칙화 파라미터, ξ_i 는 softening constraint, K는 kernel, b는 bias, α 는 Lagrange coefficient, X_i 는 input samples 그리고 \bar{X} 는 mean of samples를 의미한다^[8].

또한 적절한 kernel을 사용하면 더 높은 진단 성공률을 얻을 수 있는데, linear, polynomial 및 RBF(Radial Basis Function) 등과 같은 다양한 kernel들이 있다. 이 중 linear kernel은 선형 데이터를 분류하는데 있어

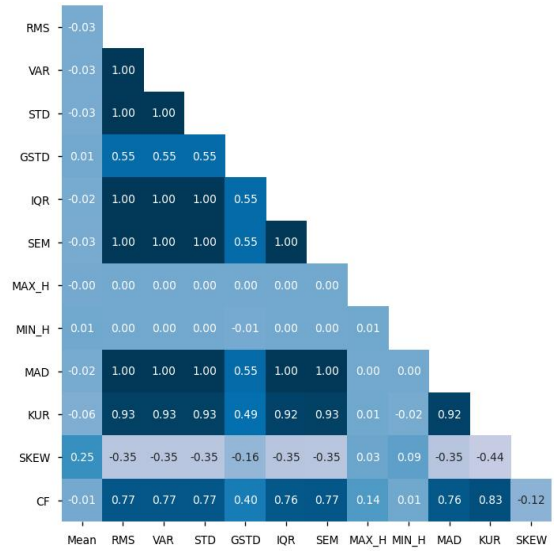


Fig. 4 Calculation the correlation between features

Table 3 Results of data reduction

No	Mean	RMS	GSTD	MAX_H	MIN_H	SKEW	State
0	0.005	0.73	3.14	3.03	-3.36	-0.017	0
1	-0.0004	0.73	3.05	2.98	-3.57	-0.004	0
2	0.0054	0.73	3.12	3.16	-3.29	-0.027	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
997	-0.019	2.22	3.08	2.98	-4.25	-0.067	2
998	-0.039	2.30	3.13	3.49	-3.49	-0.165	2
999	-0.032	2.26	3.12	3.67	-3.46	-0.075	2




Fig. 5 PCA about rolling bearing data set

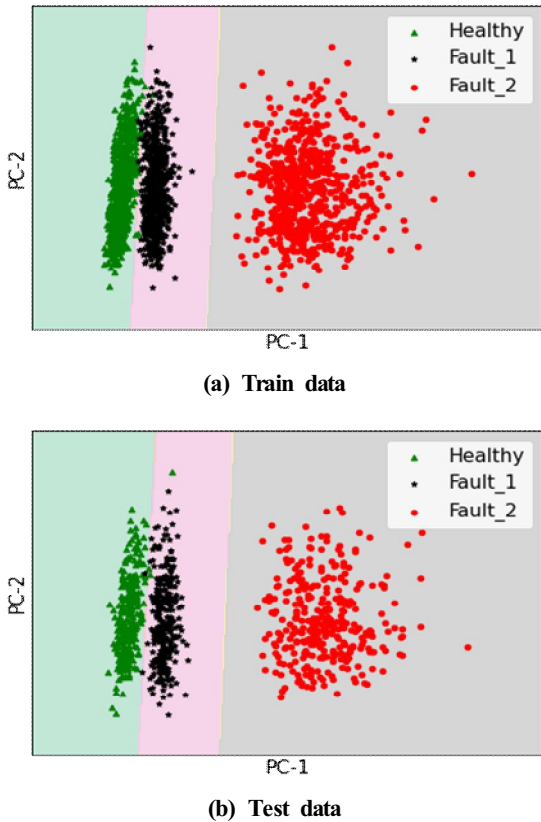


Fig. 6 Training results using the support vector machine

가장 효율적인 kernel이며, 데이터들의 형태를 고려하였을 때 가장 적합하다고 판단되어 linear kernel을 선정하였다.

SVM에 축소한 데이터 총 6,000개 중 train data 4,200개(70%)를 학습시킨 결과를 Fig. 6(a)에 나타내었으며, test data 1,800개(30%)를 적용한 결과는 Fig. 6(b)에 표시하였다. 그림으로부터 맑은 염산(5%)에 침적시킨 상태의 데이터(Fault_2)는 정상상태의 데이터 및 맑은 염산(5%)에 침적시킨 상태의 데이터(Fault_1)와 크게 구분이 되는 것을 알 수 있다^{[9][10]}.

머신러닝에 의한 분류 성능을 평가하기 위해서는 Table 4와 같이 4가지 지표를 사용하는데, 여기서 TP는 분류기가 Positive를 Positive로 정확하게 예측하는 수, TN은 Negative를 Negative로 정확하게 예측하는 수, FP는 Negative를 Positive로 잘못 예측하는 수, FN은 Positive를 Negative로 잘못 예측하는 수를 의미한다.

Table 4 Classified data

Types	Actual Positives	Actual Negatives
Positive Predictions	True Positives (TP)	False Positives (FP)
Negative Predictions	False Negatives (FN)	True Negatives (TN)

Table 5 Classification performance by SVM

Classes	Precision	Recall	F1-score	Accuracy
Healthy	0.99	0.99	0.99	0.996
Fault 1	0.99	0.99	0.99	
Fault 2	1.00	1.00	1.00	

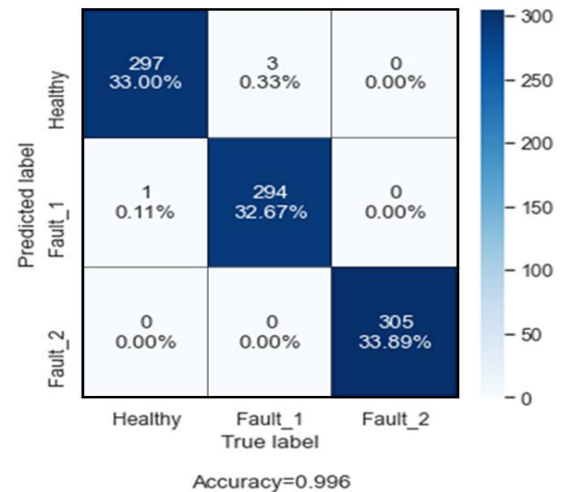


Fig. 7 Confusion matrix of SVM

그리고 분류성능은 식 (3)-(6)에 나타난 바와 같이 참이라고 분류된 것 중 실제로 참인 비율, Recall은 실제 참인 것 중 참이라고 분류된 비율, F1은 Precision과 Recall의 조화평균, Accuracy는 참을 참이라고 거짓을 거짓이라고 분류한 것의 비율을 의미한다.

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

SVM 알고리즘을 적용한 분류성능 결과를 Table 5에 나타내었으며, 이때의 confusion matrix를 Fig. 7에 표시하였다. Precision은 99% 이상, Recall은 99% 이상, F1-score은 99% 이상 그리고 Accuracy는 99.6%의 분류성능을 제시하고 있다^{[11][12]}.

4. 결 론

구름베어링의 고장유형 및 영향을 FMEA를 통해 분석하였고, 묶은 염산(5%) 용액에 구름베어링을 각각 2시간 및 4시간 동안 침적시킨 후 가속도 센서를 이용하여 진동을 측정하였다. 추출한 진동 데이터를 대상으로 SVM 알고리즘을 적용하여 고장을 분류하였으며, 얻어진 결과를 요약하면 다음과 같다.

- 1) 고장 발생률이 가장 높은 고장유형은 부식이며, 구름베어링을 묶은 염산(5%) 용액에 침적시킨 시간에 따라 검출되는 진동 데이터의 특성이 달라진다.
- 2) 추출된 데이터를 대상으로 PCA 기법을 이용하여 차원을 축소하고, SVM 기법으로 머신러닝을 수행하여 구름베어링의 고장진단이 가능하다.
- 3) SVM 알고리즘을 사용하여 고장진단을 수행한 결과, Precision은 99% 이상, Recall은 99% 이상, F1-score는 99% 이상 그리고 Accuracy는 99%의 분류성능을 얻을 수 있었다.

후 기

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

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. Jeon, H. K., Kim, J. S., Kim, B. J. and Kim, W. J., "A Study on the fault diagnosis of rotating machine by machine learning", Journal of The Acoustical Society of Korea, Vol. 39, pp. 263-269, 2020.
3. Hong, D. P. and Kim, W. T., "Quantitative NDE Thermography for Fault Diganosis of Ball Bearings with Micro-Foreign Substances", Journal of The Korean Society for Nondestructive Testing, Vol. 34, pp. 305-310, 2014.
4. Muzakkir, S. M., Lijesh, K. P. and Hirani, H., "Failure Mode and Effect Analysis of Journal Bearing", International Journal of Applied Engineering Research, Vol. 10, No. 16, pp. 36843-36850, 2015.
5. Ahn, D. G., Yoo, J. M. and Jang, J. S., "How to Perform FMEA Effectively for Weapon System Development Stage", Journal of Applied Reliability, Vol. 21, No. 1, pp. 45-60, 2021.
6. Fitch, J., "How Water Causes Bearing Failure", Machinery Lubrication, Vol. 7, pp. 2-4, 2008.
7. Alam, S. T. and Hu, 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. 3981-3990, 2020.
8. Kwak, T. H., Song, A. R. and Kim, Y. G., "The Impact of the PCA Dimensionality Reduction for CNN based Hyperspectral Image Classification", Korean Journal of Remote Sensing, Vol. 35, No. 6-1, pp. 959-971, 2019.
9. Jung, S. H., Lee, G. I., Kim, J. M., Hong, S. W., Chung, Y. S. and Jung, H. K., "A Comparison of Target Identification using Support Vector Machine with Various Kernel Functions" The Korean Institute of Electrical Engineers, Vol. 12, No. 1, pp. 77-95, 2020.
10. Yoo, Y. S., Kim, D. H., Kim, S. and Hur, J. W., "Fault Prognostics of a SMPS based on

PCA-SVM” Journal of The Korean Society of Manufacturing Process Engineers, Vol. 19, No. 9, pp. 47-52, 2020.

11. Lee, G. H., Shin, B. C. and Hur, J. W., “Fault Classification of Gear Pumps Using SVM”, Journal of Applied Reliability, Vol. 20, No. 2, pp. 189-196, 2020.
12. Hong, C. H., “Confusion Plot for the Confusion Matrix”, Journal of the Korean Data And Information Science Society, Vol. 32, No. 2, pp. 1065-1066, 2018.