

인공신경망을 이용한 머신러닝 기반의 연료펌프 고장예지 연구

최홍*, 김태경*, 허경린*, 최성대*, 허장욱*^{#,}

*금오공과대학교 기계시스템공학과

Study of Fuel Pump Failure Prognostic Based on Machine Learning Using Artificial Neural Network

Hong Choi*, Tae-Kyung Kim*, Gyeong-Rin Heo*, Sung-Dae, Choi*, Jang-Wook Hur*^{#,}

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

(Received 8 June 2019; received in revised form 11 July 2019; accepted 18 July 2019)

ABSTRACT

The key technology of the fourth industrial revolution is artificial intelligence and machine learning. In this study, FMEA was performed on fuel pumps used as key items in most systems to identify major failure components, and artificial neural networks were built using big data. The main failure mode of the fuel pump identified by the test was coil damage due to overheating. Based on the artificial neural network built, machine learning was conducted to predict the failure and the mean error rate was 4.9% when the number of hidden nodes in the artificial neural network was three and the temperature increased to 140 °C rapidly.

Key Words : Failure Prognostic(고장예지), Machine Learning(머신러닝), Fuel Pump(연료펌프), Artificial Neural Network(인공신경망), Sensor(센서)

1. 서 론

4차산업 혁명으로 대변되는 인공지능은 상태 진단(Diagnostic)을 위해 다량의 정보를 감지(Sensing)하는 기술과 이를 실시간으로 처리하는 빅 데이터 기술 및 예지(Prognostic)하는 기술을 기반으로 하고 있다^[1-2]. 현재 대부분의 산업용 장비는 설비의 상태를 고려하지 않고, 예방정비를 통해 사용기간이 만료된 것은 무조건 교환하는 방식이기 때문에

과도한 유지보수 비용을 초래하기도 한다. 이를 보완한 것이 예지 보전 시스템이라 할 수 있으며, 이는 고장예지 및 건전성관리의 핵심기술로 유비쿼터스 센서 네트워크(USN : Ubiquitous sensor network)를 이용하여 산업용 장비의 상태를 모니터링하고, 고장의 징후를 포착하는 진단기술과 잔여 유효수명(RUL : Remaining useful life)의 예지 및 효과적인 건전성관리 기술(Health management)을 의미한다^[3,4].

최근 고장예지 진단 성공사례로는, ‘증기터빈 로터 고장 진단 기술’, ‘발전소 변압기 고장 진단 기술’, ‘LNG 플랜트 고장 진단 기술’, ‘리튬 이온

Corresponding Author : hhjw@kumoh.ac.kr

Tel: +82-54-478-7399

배터리 건전성 진단 기술’, ‘상수도관 누수 진단 기술’, ‘풍력발전기 구동계 고장 진단 기술’, ‘발전기 수냉식 고정자 권선의 흡습현상 진단 및 예지 기술’ 등 각 산업에서 활발하게 시스템의 성능을 검증 및 평가하는 단계에 있다^[5].

특히, 대부분의 시스템에서 핵심품목으로 구분되는 연료펌프는 장시간 작동 시 펌프 내부의 온도 상승에 의한 코일의 피복 손상 등에 의해 고장이 발생하기 때문에, 펌프의 고장 예지에 의한 건전성 관리의 중요성도 함께 증가하고 있다. 따라서, 본 연구에서는 연료펌프의 고장유형 및 영향 분석(FMEA)을 수행하여 고장현상을 파악하고, 온도 및 진동 센서 등으로부터 데이터를 확보하여 인공지능망(ANN, Artificial Neural Network) 기반의 머신러닝을 실시함으로써 고장을 예지하였다.

2. 고장모드 분석 및 시험

2.1 고장모드 분석

연료펌프에 대한 FMEA(Failure mode and effects analysis) 결과는 Table 1과 같으며, 총 5가지 형태로 구분할 수 있다. 연료펌프의 고장모드는 마모 및 부식으로 인한 피스톤 실린더의 구조적 결함, 피로로 인한 스프링 계수의 변화, 내부 충격에 따른 손상 및 마모로 인한 체크밸브 고장, 내부 충격에 의한 축압기(Accumulator)고장, 그리고 과열로 인한 코일의 피복 손상 등 총 5가지의 형태를 예상할 수 있다.

연료펌프 입력 전원의 전압, 전류 및 주파수의 조건을 변경하면서 시험을 수행하였을 때, Fig 1에 나타난



(a) Before failure (b) After failure
Fig. 1 Photos of before and after fuel pump failure




Fig. 2 Fault prediction big data collection system conceptual diagram

바와 같이 과열로 인한 코일의 피복 손상이 가장 취약한 고장모드임을 확인할 수 있었으며, 이러한 결과를 이용하여 연료펌프의 고장예지를 위한 시험을 수행하였다.

2.2 시험장치 및 방법

연료펌프로부터 데이터를 수집하기 위해 Fig. 2에 나타난 바와 같이 연료펌프, 온도 센서, 가속도 센서 및 DAQ 등으로 시험 장치를 구성하였다. 부착된 센서에서 DAQ Chassis를 통해 수집된 데이터를 랩뷰(Labview)를 이용하여 저장하고, 실시간 그래프로 데

Table 1 FMEA results of fuel pump

Part name	Function	Failure mode	Cause of failure	Detection method
Piston cylinder	Volume change	Structural defect	Wear & corrosion due to impurities	Flow rate change
Spring	Piston power transmission	Spring coefficient change	Fatigue	Flow rate change
Check valve	Maintain flow direction & prevent back flow	No transfer of bi-directional fuel	Damage & wear due to internal impact	Flow rate change
Accumulator	Vibration damping	Ripped	Fatigue due to internal shock	Increased vibration
Coil	Induction electromotive force generation	Short	Covering damage due to overheating	Non-operating

Table 2 Specification of fuel pump

Model	Rated voltage	Power consumption	Maximum flow	Maximum pressure
VSC63	200V	25VA	17.7L/h	17.3kgf/cm ²

이터를 도식화하여 분석하였다.

연료펌프의 사양은 Table 2와 같으며, 연료펌프에 입력되는 전류, 전압 및 주파수 특성을 변경하였을 때 약 23시간 이후 고장이 발생하였다.

3. 인공신경망을 이용한 고장 예지

3.1 데이터 수집 및 분석

FMEA의 고장모드를 확인하기 위해 다양한 시험을 수행한 결과, Fig. 1에 나타낸 바와 같이 코일이 과열되어 합선으로 인한 파손이 고장의 주요 원인임을 알 수 있었다. 이에 따라 온도를 주요 파라미터로 선정하고 데이터를 수집 및 분석하였으며, Fig. 3은 연료펌프의 작동 시작부터 고장이 발생할 때까지의 온도변화를 나타낸 것이고, 3개의 점선으로 된 사각형은 각각 안정, 불안정 및 위험으로 표시한 구간 분류를 의미한다.

시험을 통해 진동데이터를 수집하여 Fig. 4와 같이 나타내었으며, 진폭이 커지면 펌프의 유량이 감소하는 경향을 보였지만, 고장으로 이어지는 않았다. 머신러닝을 수행하기 위해서는 방대한 양의 빅 데이터(Big data)를 학습데이터로 변환하는 전처리 과정과 함께 인공신경망 시스템 구성에 적합한 형태로 만들어 주어야 한다.

이를 위해 데이터 전처리 과정 중 데이터 축소(Data reduction)와 데이터 클리닝(Data cleaning)을




Fig. 3 Graph of fuel pump failure temperature data




Fig. 4 Graph of fuel pump failure vibration data

Table 3 Failure rate and temperature category

Failure rate(%)	Temperature(°C)
0	less than 130
10	130
21	135
32	140
43	145
54	150
65	155
76	160
87	165
99	170

적용하였다^[6]. 즉, 시험을 통해 수집한 데이터의 샘플링 타임(Sampling time)을 조정하여 60만 개의 데이터를 1만 개로 축소하였으며, 코일의 온도가 130 °C 이하일 때 0%의 고장률 및 170 °C 이상일 때 99%의 고장률을 기준으로 선형보간법을 적용하여 Table 3과 같이 온도 범주를 설정하였다. 또한, 1만개씩 2set의 고장 데이터(Failure data)를 대상으로 노이즈와 이상치를 제거하고, 500개씩 38set의 학습 데이터(Training data)를 Table 4와 같이 분류(Labeling)하였다.

3.2 인공신경망 파라미터 설정

인공신경망은 머신러닝의 가장 핵심적인 기술로써, 신경세포(Neuron)를 추상화한 망(Network)이며, 일반적으로 어떠한 형태의 함수라도 근사할 수 있는 통계학적 학습 알고리즘이다.

인공신경망은 Fig. 5에 나타낸 바와 같이 인공 신경세포, 연결구조 및 학습규칙의 3가지 요소로 정의되며, 인공신경망을 구축하기 위한 이론은 다

Table 4 Training data labeling

Type	No.	1	2	3	4	5	6	7	...	38
Labeling (%)		0	10	21	43	54	65	76		99
Temp.(°C)	1	105.502	125.554	135.361	144.479	149.749	149.977	157.919	...	169.138
	2	105.504	125.587	135.366	144.504	149.753	149.972	157.932		169.259
	3	105.511	125.615	135.373	144.531	149.759	149.965	157.936		169.383
	4	105.516	125.645	135.381	144.552	149.756	149.959	157.939		169.503
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮		⋮
	500	105.139	135.35	136.430	149.121	149.688	157.744	169.029		174.459

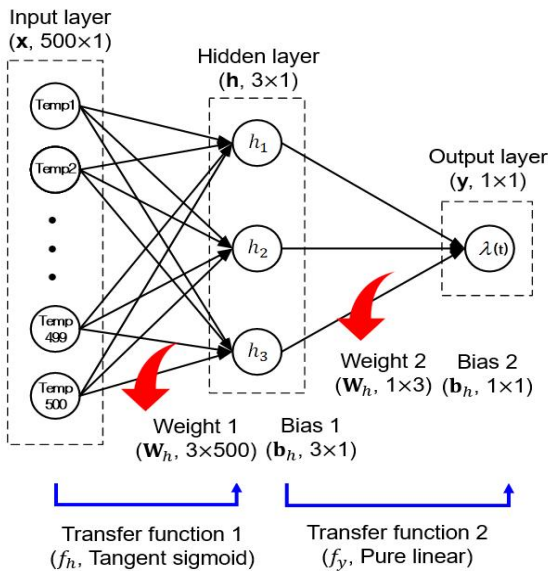


Fig. 5 Structure of artificial neural network

음 식과 같다^[7].

$$u = \sum_{i=1}^n w_i x_i \quad (1)$$

$$f(\sum w_i x_i) = \begin{cases} 1 & \text{if } u \geq \theta \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

$$f(\sum w_i x_i) = \text{Transfer function} \quad (3)$$

하나의 인공 신경세포는 n개의 입력(x_1, x_2, \dots, x_n)에 대해서 연결 강도(w_1, w_2, \dots, w_n)에 따른 가중치를 곱하고, 받아들인 값을 모두 합하여 가중합

($u = \sum w_i x_i$)을 계산하며, 가중합은 다시 활성화 함수를 통과하여 다음 신경세포로 전달될 출력이 결정된다.

신경세포의 특성을 결정하는 것은 활성화 함수이며, 이는 인공 신경세포의 특성이자 임계치(θ) 이상에서 활성화됨을 보이는 특성을 수학적으로 표현하게 한다. 여기서는 네트워크 개발의 Hidden layer의 신경세포 수와 네트워크 보정 반복수를 설계변수로 선택하였다.

4. 연료펌프 고장예지

머신러닝을 수행하기 위해 매트랩(Matlab) 프로그램으로 Neural Network Toolbox를 사용하였다. 인공 신경망의 Hidden layer에는 Tansig함수(Tangent sigmoid 함수)를 사용하였으며, Output layer에는 Purelin함수(Pure linear 함수)를 사용하였다.

Tansig함수는 -1~1의 값을 가지며, 미분이 가능한 성질로부터 연결 강도(w)를 결정하는 역할을 한다. 또한 Purelin함수는 Hidden layer에서 전달받은 값에 가중치를 곱하여 가중합(u)을 계산하여 Output을 출력한다. 인공신경망은 Fig.5와 Fig.6에 나타낸 바와 같이 Hidden layer 1개와 Output layer 1개로 구성하였다.

데이터의 정확도를 확인하기 위해 학습 데이터로 사용하지 않은 고장 데이터를 Labeling하여 Table 5와 같이 시험 데이터(Test data)로 적용하였다.

또한, 시험 데이터로 얻은 결과의 오차율을 계산하여 적정시간 내에 높은 정확도의 결과를 얻는

Table 5 Test data labeling

Type	No.	Test 1	Test 2	Test 3	Test 4	Test 5
Labeling (%)		0	10	21	65	99
Temp. (°C)	1	95.34428	131.9293	135.4094	154.2599	168.1846
	2	95.36858	131.9241	135.4228	154.2759	168.2367
	3	95.36659	131.9382	135.433	154.2588	168.3037
	4	95.36747	131.985	135.5029	154.2475	168.3543
	⋮	⋮	⋮	⋮	⋮	⋮
	500	96.37469	133.283	138.3227	156.1546	177.4101




Fig. 6 Established artificial neural network

Table 6 Machine learning error rate with 2 nodes

Labeling(%)	Machine learning result(%)	Error(%)
0	0	0
10	3	70
21	14	33.3
65	53	18.4
99	92	7.1
Average error rate(%)		25.8

Table 7 Machine learning error rate with 3 nodes

Labeling(%)	Machine learning result(%)	Error(%)
0	0	0
10	10	0
21	23	9.5
65	58	10.8
99	95	4
Average error rate(%)		4.9

Table 8 Machine learning error rate with 4 nodes

Labeling(%)	Machine learning result(%)	Error(%)
0	0	0
10	16	60
21	26	23.8
65	57	12.3
99	94	5
Average error rate(%)		20.2

Hidden node 수를 찾아 학습정도를 평가하였다^[8].

인공신경망의 Hidden layer 수를 1개로 하고, Hidden node 수를 2~4개로 했을 때 머신러닝 결과를 Table 6~8에 나타내었다. 표에서 나타낸 결과는 Table 4에서 정의한 Labeling(%)의 시험 데이터를 이용한 것이며, Hidden node 수에 따른 평균 오차율은 2개일 때 25.8%, 3개일 때 4.9%, 4개일 때 20.2%로 Hidden node 수가 3개일 때 가장 우수하였다.

또한, Labeling에 따른 최대 오차율은 2개일 때 Labeling 21%에서 33.3%, 3개일 때 Labeling 65%에서 10.8%, 4개일 때 Labeling 21%에서 23.8%를 보이고 있으며, Hidden node 수가 3개일 때 Labeling 시험 데이터별 최대 오차가 가장 적었다.

5. 고찰

학습 데이터의 정확도를 높이기 위해 Hidden node 수에 따른 학습 데이터의 오차율을 비교한 결과, 시험 데이터 5개의 평균 오차율이 4.9%로 가장 낮은 Hidden node 3개의 경우를 인공신경망의 Hidden node 수로 설정하여 머신러닝한 결과를 Table 9와 Fig. 7에 나타내었다. 그림으로부터 코일

Table 9 Machine learning results

Test data	Temp.(°C)	Failure rate(%)
1	95~96	0
2	132~133	10
3	135~138	23
4	154~156	58
5	168~177	95

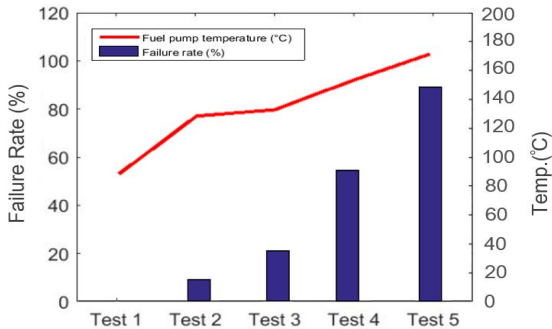


Fig. 7 Graph of machine learning result

의 온도가 약 140 °C 이상이 되면 연료펌프의 고장률이 급격하게 상승하는 것을 알 수 있다.

향후에는 고장 데이터의 Labeling을 수정하여 현상 반영률을 높임으로써 정확성을 향상시키는 연구를 수행할 계획이다.

6. 결론

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

1. 연료펌프의 가장 취약한 고장모드는 과열로 인한 코일의 피복 손상이다.
2. 인공신경망의 Hidden node 수가 3개일 때 평균 오차율이 4.9%로 가장 정확한 학습 데이터를 확인할 수 있다.
3. 연료펌프 코일의 온도가 140 °C 이상이 되면 고장률이 급격하게 증가한다.

후기

이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2019R111A3A01063935).

REFERENCES

1. Choi, H., Kim, T. K., Heo, G. R., Hur, J. W.

and Choi, S. D., “A Study on the Prediction of Failure of Fuel Pump Based on Big Data and Machine Learning”, Proceedings of the KSMPE Spring Conference, pp. 231, 2019.

2. Kim, B. R., Lee, Y. H., Roh, H. U., Kim, D. J. and Kim, K. J., “Deep Learning System Based on Time Series Data for Robot Prognostics”, 2018 Summer Conference of IEICE, pp. 1340-1342, 2018.

3. Kim, S. H., Chang, M. S., Lee, K. S., Lee, S. K., Baek, M. H. and Park, J. W., “A Study on the Life Prediction of Vibro-hammer Structure Part Using Field Data”, Proceedings of the KSME Spring Conference, pp. 1640-1645, 2018.

4. Ashwini, K., Lukumon, O., Marina, M. and Gehan, S., “Big data: A New Revolution in the UK Facilities Management Sector”, Royal Institution of Chartered Surveyors (RICS), 2018.

5. Seo, B. S., Jang, B. C. and Hwang, S. D., “Success Cases and Vision in Engineering System of Failure Prediction Diagnosis Technology”, The Korea Society for Noise and Vibration Engineering(KSNVE), Vol. 25, No. 1, pp. 7-15, 2015.

6. Lee, J. H., “A Study on Automation of Big Data Quality Diagnosis Using Machine Learning”, The Korean Journal of Big Data, Vol. 2, No. 2, pp. 75-86, 2017.

7. Park, H. Y. and Lee, K. Y., “Pattern Recognition and Machine Learning Foundation to Use”, Ehan Publication, pp. 236-237, 2011.

8. Cho, H., Cha, D. W., Lee, H. S. and Jung, S. S., “Survey of Prognostics and Health Management Processes in Automotive Lead-acid Batteries for Estimating Remaining Useful Life in Real Time”, 2014 Fall Conference of the Korean Society of Industrial and Engineering Engineers, pp. 2883 - 2888, 2014.