

뉴럴네트워크를 이용한 디젤기관의 데이터 이상감지 시스템에 관한 연구

천행춘*, 김영일*, 김경엽*, 안순영*, 오현경*, 유영호**

A study on the data fault detection system for diesel engine using neural network.

H. C. CHUN, Y. I. KIM, K. Y. KIM, S. Y. AHN, H. G. OH, Y. H. YU

*한국해양대학교 대학원

**한국해양대학교

Abstract

The operational data of diesel generator engine is two kind of discrete signal and analog signal. We can find the fault information from analog data measured for every sampling time if it is invested the changing rate or direction of data. This paper propose the Malfunction Diagnosis Engine(MDE) using the commercial data mining tool and show the data process and fault finding method with the data collected from generator engine of the ship.

Key words : Fault diagnosis(고장 진단), Malfunction Diagnosis Engine(MDE 고장진단엔진),
Fault Detecting(고장 감지)

1. 서론

오늘날 자동화 시스템의 발달로 시스템의 제어, 운전 및 감시는 통합되어 점점 거대화 되어가고 있다. 특히 기계시스템 자동화는 대부분 기동 및 정지의 자동화, 각종 안전장치의 동작에 의한 비상정지, 기동 후 운전상태 유지, 운전 데이터의 모니터링 및 알람 발생 등은 물론이고 이들 운전 데이터를 분석하여 고장 예측과 진단으로 시스템 정지의 상황을 미연에 방지하는 지능적 의사결정 시스템으로 발전하고 있다. 운전 중의 각종 감시 데이터는 온도, 압력, 레벨, 회전수, 주파수, 전력, 암페어 등의 데이터들이 주종을 이루며, 이들의 데이터를 분류해보면 이산신호(온 또는 오프 신호)와 연속신호(아날로그 신호)로 나눌 수 있다. 그중에서도 연속신호는 그 데이터를 감시 분석하면 발전기의 운전 상태 및 향후 어떤 고장을 유발할 것인지를 알아낼 수 있다.

즉 계속해서 온도가 올라가는 추세에 있다면 앞으로 이러한 추세가 계속되어 급기야 얼마되지 않아서 알람이나 트립상태에 이르게 된다는 것을 알 수 있다.

이와 같이 연속 신호를 지속적으로 측정하여 측정된 데이터들 속에 포함된 정보를 활용하면 기관의 운전상태를 보다 정확히 파악할 수가 있다.

운전 모니터링 시스템에서 연속신호의 처리는 정상 값을 기준으로 하여서 높은 값을 경고하는 고경보(HA) 출력 신호, 낮은 값을 경고하는 저경보(LA) 출력 신호 와 낮은 값을 정지되는 저정지(LS) 출력 신호로 처리한다. 처리기준 값의 크기는 정동작일 때에 높은 값 정지 출력 신호 > 높은 값 경고 출력 신호 > 낮은 값 경고 출력 신호 > 낮은 값 정지 출력 신호의 순이며 일어날 수 있는 경우는 모두 15 경우이지만 이러한 경우에 도달할 때 까지는 항상 정상으로만 출력한다.

뉴럴네트워크를 이용한 디젤기관의 데이터 이상감지 시스템에 관한 연구

그러나 연속 신호의 정상 값이 경고 값이나 정지알람 값을 향해서 서서히 진행하고 있을 때 이러한 조짐을 미리 알아차릴 수 있다면 경고나 정지에 도달하기 전에 미리 조치를 취할 수 있어 시스템 정지로 인한 손실을 예방할 수 있고 정비계획을 수립할 수 있어 시스템의 운전 성능을 한층 높여 줄 수 있으리라 판단된다. 본 논문에서는 선박용 디젤발전기를 대상으로 운전 데이터 속에 내재한 정보들을 활용하여 좀더 빠르고 정확한 고장 진단 시스템을 구축하기 위하여 상용 소프트웨어를 이용하여 뉴럴네트워크를 구성하고, 실선에서 얻은 운전 데이터로 네트워크를 학습하여 학습된 뉴럴 네트워크로 고장진단 시스템구성 요소중 첫 단계인 데이터 이상 감지 시스템에 관하여 논하고자 한다.

뉴럴 네트워크는 입력노드와 출력노드의 개수가 같게 구성하고 연속형 데이터를 입력하여 낮다, 중간, 높다 등의 범주형 데이터가 출력 되도록 하였다.

구성된 뉴럴 네트워크는 26개의 입력 데이터를 범주형 데이터로 변환하고 뉴럴 네트워크를 학습하여 학습된 데이터와 학습데이터의 신뢰도를 출력한다.

2. 실선 운전 데이터 분석

발전기의 로그북에서 기록된 28종류의 데이터를 살펴 보도록 한다.

특히 선박의 이동성 때문에 지역적인 특성에 영향을 받아서 데이터들은 같은 부하 조건이라도 다르게 나타나는 경향이 있다.

즉 덥고 습한 지역이나 춥고 건조한 지역 등에서의 운전은 똑같은 부하 조건이라도 각종 운전 데이터의 기록은 다르게 나타난다.

물론 이동성이 없는 기관이라도 계절의 변화와 날씨의 변화에 따라서 역시 같은 부하 조건의 운전 데이터 기록이 다르게 나타난다.

이것은 어느 특정한 조건을 기초로 하여 고장 진단을 할 경우에 지역적인 특성이나 계절적인 특성 때문에 오동작을 일으킬 수 있는 요인이 된다.

따라서 주어진 데이터들을 어느 일정 주기로 얻은 후에 학습을 행하고 이 학습된 네트워크로 기관 상태에 대한 고장진단을 행하면 더욱 더 정확한 진단이 이루어지리라 본다.

이렇게 그때그때 얻어지는 데이터로 학습을 행

하고 학습된 네트워크로 현재 운전 데이터를 처리하는 방법으로는 뉴럴 네트워크를 이용하는 것이 바람직하다.

운전 데이터 중에는 서로 다른 데이터에 영향을 주거나 받는 데이터와 일부 액위 경보와 같이 하나의 데이터에만 작용하는 것이 있다. 감시되는 모든 운전 데이터 중 디젤기관의 운전에 관계되는 주요 데이터는 표 1과 같다.

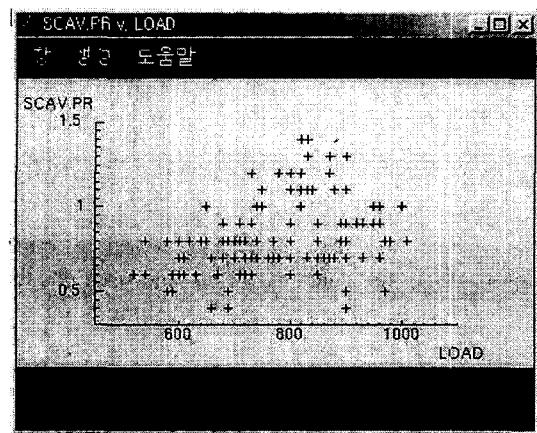


그림 1 LOAD(부하)에 따른 SCAV.PR(소기 압력)의 분포

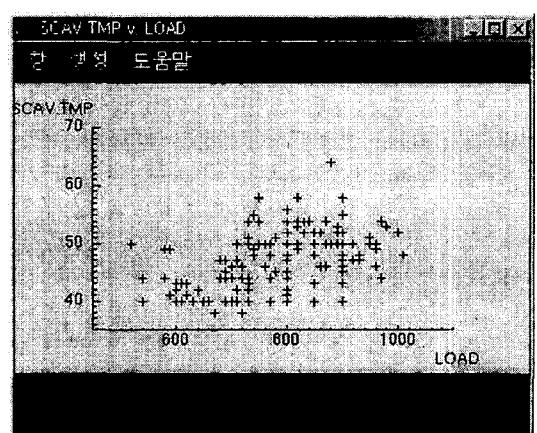


그림 2 LOAD(부하)에 따른 SCAV.TMP(소기 온도)의 분포

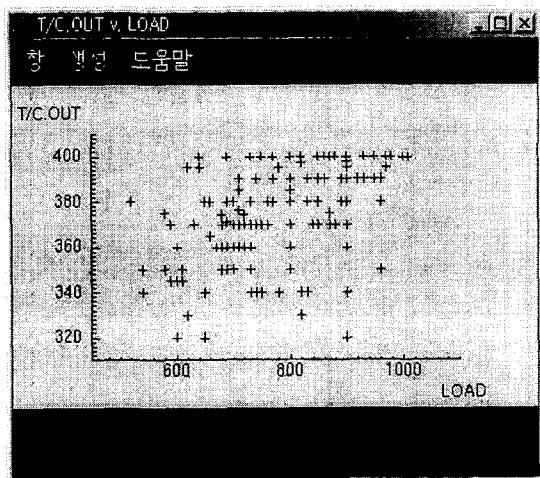


그림 3 LOAD(부하)에 따른
T/C.OUT(터보차저 배기ガス 출구 온도)의
분포

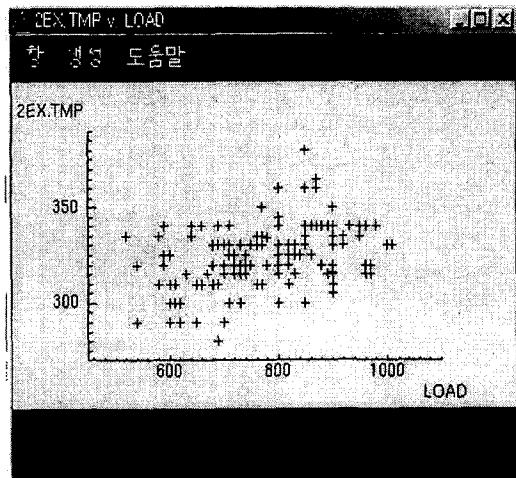


그림 5 LOAD(부하)에 따른 2EX.TMP(2번
배기ガス 출구 온도)의 분포

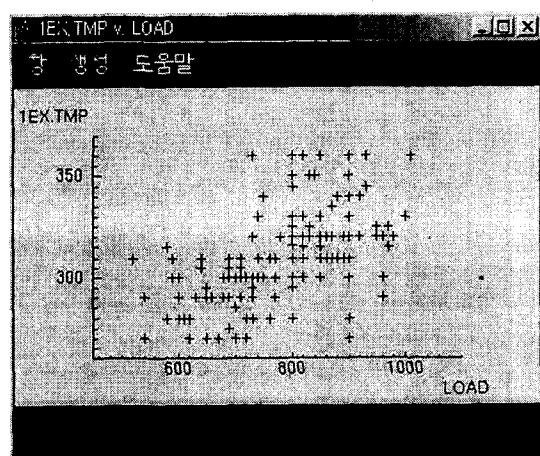


그림 4 LOAD(부하)에 따른 1EX.TMP(1번
배기ガス 출구 온도)의 분포

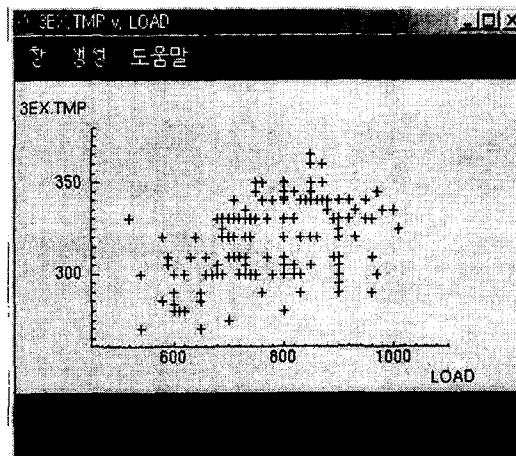


그림 6 LOAD(부하)에 따른 3EX.TMP(3번
배기ガ스 출구 온도)의 분포

뉴럴네트워크를 이용한 디젤기관의 데이터 이상감지 시스템에 관한 연구

표 1 주요 데이터의 운전 범위

1	LOAD	750 ~ 900	발전기 부하 (kW)
2	AMP	1150 ~ 1350	발전기 전류 (A)
3	L.O.IN.PR	3.7 ~ 4.0	윤활유 입구 압력(kg/cm ²)
4	F.O.IN.PR	7.0 ~ 8.5	연료유 입구 압력(kg/cm ²)
5	SCAV.PR	0.6 ~ 1.0	소기 압력(kg/cm ²)
6	F.W.IN.PR	1.6 ~ 2.6	냉각 청수 입구 압력(kg/cm ²)
7	S.W.PR	2.3 ~ 3.0	해수 압력(kg/cm ²)
8	F.W.IN.T MP	70 ~ 80	냉각 청수 입구 온도(°C)
9	LW.CYL		최저냉각수 출구온도 실린더 번호
10	LW.TMP	75 ~ 81	최저냉각수 출구 온도(°C)
11	HW.CYL		최고냉각수 출구온도 실린더 번호
12	HW.TMP	78 ~ 84	최고냉각수 출구 온도(°C)
13	1EX.TMP	300 ~ 340	1번 배기가스 출구 온도(°C)
14	2EX.TMP	300 ~ 340	2번 배기가스 출구 온도(°C)
15	3EX.TMP	300 ~ 340	3번 배기가스 출구 온도(°C)
16	4EX.TMP	300 ~ 340	4번 배기가스 출구 온도(°C)
17	5EX.TMP	300 ~ 340	5번 배기가스 출구 온도(°C)
18	6EX.TMP	300 ~ 340	6번 배기가스 출구 온도(°C)
19	7EX.TMP	300 ~ 340	7번 배기가스 출구 온도(°C)
20	8EX.TMP	300 ~ 340	8번 배기가스 출구 온도(°C)
21	9EX.TMP	300 ~ 340	9번 배기가스 출구 온도(°C)
22	T/C.OUT	360 ~ 390	터보차저 배기가스 출구 온도(°C)
23	L.O.IN.T MP	54 ~ 62	윤활유 입구 온도(°C)
24	F.O.IN.T MP	135 ~ 145	연료유 입구 온도(°C)
25	SCAV.TM P	42 ~ 52	소기 온도(°C)
26	GEN.BR.T MP	58 ~ 65	발전기 베어링 온도(°C)
27	S.W.TMP	15 ~ 32	해수 온도(°C)
28	L.O.SMP. LVL	6.0 ~ 8.0	윤활유 섬프탱크 레벨(x10%)

본 연구에서는 이들 데이터를 분석 검토하고 뉴럴 네트워크의 입력 데이터로 사용한다. 각각의 데이터의 운전 범위를 결정하여 상한값 이상은 HIGH로 하한값 이하는 LOW로 정하고 상한값과 하한값 사이에 데이터가 있을 때는 정상값으로 정하는데 이값은 MID로 표기한다. 각 데이터의 정상값 범위는 표 1과 같다.

디젤기관의 각부 온도와 압력은 부하에 따라 종속되어 변하므로 부하에 따른 데이터의 분포를 분석해보면 그림 1 ~ 그림 6 과 같다.

표 2 부하에 대한 중요 데이터의 분포도(%)

		load		
빈도수(%)		high	mid	low
scav. pr.	high	20.5	17.1	36.4
	mid	66.7	36.8	0
	low	12.8	46.2	63.6
scav. tmp	high	25.6	21.4	0
	mid	59	37.9	28
	low	15.4	40.8	72
T/C 출구 온도	high	35	9.5	11.4
	mid	53.3	54	31.8
	low	11.7	36.5	56.8
1번 배기ガ 스 온도	high	66.7	19.2	7.9
	mid	33.3	51.7	10.5
	low	0	29.2	81.6

그림 1에서 그림 6은 부하에 따라 소기압력, 소기온도, T/C 출구온도, 배기가스 온도의 관계를 나타낸 그림으로 일반적으로 부하가 증가하면 소기 압력이나 온도, T/C 출구온도, 배기가스온도 등이 증가하는 추세를 보이고 있으나 발전기구동 디젤기관이므로 부하가 변화해도 회전수는 일정하며 기관의 중요 데이터는 여러 요인에 따라서 변화 하므로 그림처럼 뚜렷한 경향을 정하기가 어렵다. 표 2는 이들 데이터의 관계를 표로 정리한 것이다. 부하의 높다, 정상, 낮다의 경우에 따라 소기압력, 소기온도, T/C출구온도 및 1번 배기가스온도의 분포도를 나타내었다. 부하가 높은 경우에 소기압력이 높다는 20.5%, 정상은 66.7%, 낮다는 12.8%정도로 분포되어있다. 부하에 따라 터보차저의 회전수는 비례하고 소기압력도 비례할 것으로 예상되나 표에 의하면 오히려 mid(정상)의 경우가 더 많으며 low(낮음)의 경우도 12.8%나됨을 알 수 있다. 따라서 소기압력이 low인 12.8%의경우도 고장이라고는 판정할 수 없게 된다. 그러나 1번 실린더 배기가스 온도를 보면 부하의 정도에 따라 배기가스온도의 경향은 비례하고 있음을 알 수 있다.

3. 뉴럴 네트워크의 구조와 데이터 처리

데이터 처리를 위한 뉴럴 네트워크 구조는 입력레이어 26 뉴런과 숨김 레이어는 한층으로 30 뉴런이고 출력 뉴런은 입력 뉴런과 같은 수인 26 뉴런으로 구성되어 있다.

연속형 데이터를 낮다, 중간, 높다의 3가지 범주형 데이터로 변환하여 각 변수명에 1을 붙인 변수로 표기하였다.

구성된 뉴럴 네트워크를 표로 출력하면 표 내용은 입력데이터와 입력을 범주형으로 바꾼 데이터 및 뉴럴 네트워크 출력과 이 출력의 신뢰도가 출력으로 나오게 된다. 출력의 신뢰도는 입력데이터가 문자형일 때만 나타나고 0과 1사이의 값을 가지게 되며 1에 가까울수록 예측 결과 값들이 맞을 확률이 높음을 나타낸다. 이렇게 구성된 뉴럴 네트워크에 26 종류의 연속형 입력 데이터를 처리하는 프로그램의 구성도는 그림 7과 같다.

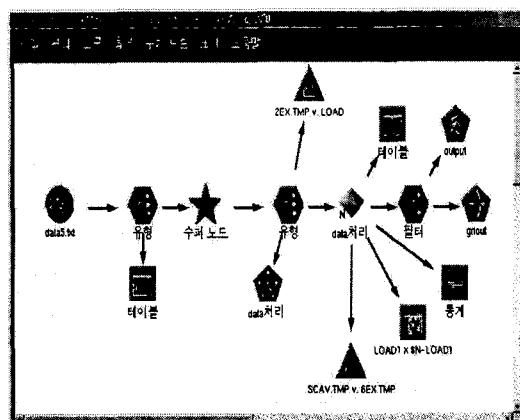


그림 7 뉴럴 네트워크의 처리를 위한
프로그램 구성도

4. 뉴럴 네트워크의 처리 결과 및 고찰

표 3은 뉴럴네트워크의 출력과 입력 데이터의 범주형 변환 데이터간의 예측정확도를 나타낸다. 표 3에서 실제 부하가 높은 것을 높다고 출력한 것은 85.7%, 정상인 것을 높다고 한 것이 16.7%이며 낮은 것을 높다고 한 것은 0%이다. 또한 부하가 높은 것을 정상이라고 한 것이 14.3%이며 높은 것을 낮다고 한 것은 0%이다.

즉 낮은 것을 높다고 하거나 높은 것을 낮다고 하는 경우는 없으며 부하의 경우 정상을 낮다로 하거나 낮은 것을 정상으로 할 경우는 각각 7.1%와 3.2%이며 정상을 높다고 하거나 높은 것을 정상으로 하는 경우가 16.7%와 14.3%로써 정상과 낮은 것은 비교적 잘 구분하나 높은 것과 정상의 경우는 전자보다 구별을 못하는 것으로 볼 수 있다.

표 3 중요 데이터 각각의 예측정확도.

		예측정확도(%)		
		high	mid	low
load	high	85.7	14.3	0
	mid	16.7	76.2	7.1
	low	0	3.2	96.8
scav. pr.	high	94.7	5.3	0
	mid	2.3	89.1	8.5
	low	0	3.5	96.5
scav. tmp	high	79.5	20.5	0
	mid	4.9	89.3	5.8
	low	0	8	92
T/C 출구 온도	high	95	5	0
	mid	6.3	93.6	0
	low	0	11.4	88.6

5. 결론

실제의 선박에서 얻어진 발전기의 데이터를 부하를 중심으로 하여 데이터를 처리하고 예측하여 본 결과 부하에 따른 데이터의 분포가 규칙 있는 모형을 가지지 않으며 명확한 구분을 가지고 나타나지는 않았다.

그러나 일반적으로 예상했던 것처럼 부하가 높으면 높은 쪽으로 학습을 하였으며 이 학습 결과를 이용하여 고장 진단 엔진의 데이터 입력 자료로 쓰일 데이터의 이상여부를 예측할 수 있다는 것을 보인다.

여러 가지 데이터가 일정한 샘플링 주기로 들어오면 데이터를 수집하여 학습하고 학습된 네

뉴럴네트워크를 이용한 디젤기관의 데이터 이상감지 시스템에 관한 연구

트워크에 의해 데이터를 분석 예측하고 예측 정 확도가 일정수준에 도달하였을 때의 네트워크를 이용하여 고장진단 엔진으로 입력하여 진단에 활용할 수 있다.

향후 보고의 방법에 의해 처리된 데이터를 고 장진단 엔진으로 고장 개소와 정비 방법을 제 시하는 통합 고장진단 정비시스템에 대한 연구 를 계속할 예정이다.

참고문헌

- [1] 허준,최병주, "클레멘타인을 이용한 데이터 마이닝,SPSS아카데미,서울,2001
- [2] P. R. Prasad, "A Framework for Knowledge-Based Diagnosis in Process Operations"
- [3] P. J. Antsaklis and K. M. Passino, "An introduction to intelligent and autonomous control," KLUWER academic publishers, pp.401-422, 1993
- [4] Harald Hruschka, Martin Natter, "Comparing performance of feedforward neural nets and K-means for cluster-based market segmentation" European Journal of Operational Research 114, pp 346-353, 1999.
- [5] Kohonen, T. "Self-organization and associative memory", springer verlag, 1984.
- [6] Y. C. Pati, P. S. Krishnaprasad, "Analysis and Synthesis of Feedforward Neural Networks Using Affine Wavelet Transformations", electrical engineering department and systems research center, university of Maryland,
- [7] K. J. HUNT, D.SBARBARO, R. ZBIKOWSKI and P. J. GAWTHROP, "neural networks for control systems-A Survey", automatica, Vol.28, No.6, pp. 1083-1112, 1992.