

신경회로망을 이용한 디젤기관의 데이터 이상감지 시스템에 관한 연구

천 행 춘* · 유 영 호**

A Data Fault Detection System for Diesel Engines Using Neural Networks

H-C. CHUN · Y-H. YU

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

Abstract

The operational data of diesel generator engine is two kinds of data. One is interactive the other is non interactive. We can find the fault information from interactive data measured for every sampling time when the changing rate, direction and status of data are investigated in comparition with those of normal status to diagnose the fault of combustion system. The various data values of combustion system for diesel engine are not proportional to load condition. The criterion to decide the level of data value is not absolute but relative to relational data. This study proposes to compose malfunction diagnosis engine using neural networks to decide that level of data value is out of normal status with the data collected from generator engine of the ship using the commercial data mining tool. This paper investigates the real ship's operational data of diesel generator engine and confirms usefulness of fault detecting through simulations for fault detecting.

1. 서 론

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 경보 발생 등은 물론이고, 이들 운전 데이터

를 분석하여 고장 예측과 진단으로 시스템 정지상황을 미연에 방지하는 지능적 의사결정 시스템으로 발전하고 있다. 감시된 데이터로 디젤기관의 고장진단을 행하는 방법을 적용한 사례는 보기 드물고 지식기반고장진단은 화학 시스템에 적용한 사례가 있다.⁽¹⁾

운전 중의 각종 감시 데이터의 종류는 온도, 압력, 레벨, 회전수, 주파수, 전력, 암페어 등이 있다.

* 한국해양대학교 대학원

** 한국해양대학교 기계·정보공학부

이들 감시 데이터의 특성을 분류해보면 텡크레벨과 같이 공급펌프의 작동불량이나 텡크누설, 레벨센서 불량 등의 경우처럼 원인이 단순한 것이 있으며, 또 하나의 데이터만으로는 고장원인을 파악할 수 없으며 여러 가지 데이터를 조사하여 고도의 전문가적 지식에 의해 원인이 판단되는 상호 의존도가 높은 데이터가 있다. 데이터의 정성적인 것과 정량적인 것을 동시에 처리할 필요가 있는데 이렇게 하는 것은 신경회로망이 적합하다.⁽²⁾

보통 운전 모니터링 시스템에서 감시되는 연속신호의 처리는 정상 값 범위를 기준으로 하여서 높은 값을 경고하는 고경보(HIGH ALARM) 출력 신호, 높은 값에 의해서 정지되는 고정지(HIGH TRIP) 출력 신호, 낮은 값을 경고하는 저경보(LOW ALARM) 출력 신호와 낮은 값에 의해서 정지되는 저정지(LOW TRIP) 출력 신호로 구분하여 처리한다. 그러나 연속 신호의 현재 값이 경고값이나 정지경보 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.

즉 전문가 시스템을 구성하여 지식기반으로 자동고장진단을 행할 수 있다.⁽³⁾

본 연구에서는 선박의 자동고장진단시스템을 구축하기 위하여 데이터 감시장치로부터 수집되는 감시데이터를 상호의존도와 영향도가 낮은 단순데이터와 상호의존도와 영향도가 높은 복잡데이터로 나누고 복잡데이터를 체계적으로 분석하여 자동으로 고장진단을 행할 수 있는 시스템을 구성하는 방법에 관하여 연구 하고자 한다. 그 일환으로 본 논문에서는 발전기 구동용 디젤기관을 대상으로 연속적으로 감시되는 배기가스온도, T/C 배기가스출구온도, 부하, 소기압력과 온도 등 연소계통에 관계되는 데이터로부터 디젤기관의 연소계통 고장진단을 위하여 연소계통 감시 데이터의 이상을 감지하는 시스템을 제안한다.

2. 실선 운전 데이터 분석

발전기의 로그북에 기록된 28종류의 데이터를 살펴보면 선박의 이동성 때문에 지역적인 특성에 영향을 받아서 데이터 값들은 같은 부하 조건이라도 그 경향은 다르게 나타난다. 즉 덥고 습한 지역이나 춥고 건조한 지역 등에서의 운전은 똑같은 부하 조건이라도 각종 운전 데이터의 경향은 다르게 나타난다. 물론 이동성이 없는 기관이라도 운전데이터의 경향은 계절이나 날씨의 변화와 같이 외적환경 변화나 디젤기관내 연소상태 등 내적환경 변화에 따라 다르게 나타난다. 이것은 어느 특정한 조건을 기초로 하여 고장 진단을 행할 경우에는 내외적환경 변화에 따라 오진단을 일으킬 수 있는 요인인 된다.

또한 디젤기관의 운전데이터는 정속운전기관과

Table 1 The operation range of main data

No.	데이터 명	NORMAL 운전범위	비 고
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.TMP	70~80	냉각 청수 입구 온도(°C)
9	LW.CYL		최저냉각수 출구온도 실린더 번호
10	LW.TMP	75~81	최저냉각수 출구온도(°C) 최고냉각수 출구온도 실린더 번호
11	HW.CYL		
12	HW.TMP	78~84	최고냉각수 출구온도(°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.TMP	54~62	윤활유 입구 온도(°C)
24	F.O.IN.TMP	135~145	연료유 입구 온도(°C)
25	SCAV.TMP	42~52	소기 온도(°C)
26	GEN.BR.TMP	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%)

변속운전기관에 따라 그 변화 경향은 크게 차이가 있으며 Table 1에는 디젤발전기의 주요데이터를 나타내었다.

디젤기관의 각부 온도와 압력은 부하에 따라 종속되어 변할 것으로 추정되므로 부하에 따른 데이터의 분포를 분석해보면 Fig. 1에서 Fig. 6 과 같다. 그림에서 부하의 크기에 따라 소기압력, 소기온도, T/C 출구온도, 배기가스 온도 등을 보면 논리적인 연관관계를 찾아내기가 어렵다. 즉 부하가 낮은 경우에 소기 압력이 높은 경우도 있고 낮은 경우도 있으며, 배기가스온도 또한 높은 경우와 낮은 경우가 있을 뿐만 아니라 각 실린더 기통마다 다르다.

이것은 정상적인 상태에서 정해진 운전범위만

으로 데이터의 경향이 높다거나 낮다고 판단할 수 없다는 것을 의미한다.

Table 2는 부하와 밀접한 관계가 있는 중요데이터의 분포관계를 알아보기 위하여 부하가 높다, 중간, 낮다의 경우에 따라 소기압력, 소기온도, T/C 배기기아스 출구온도 및 1번 배기기아스온도의 분포도를 나타내었다.

여기서 각종 데이터의 높다, 중간, 낮다라는 것은 Table 1에서와 같이 기관 제조자의 운전 매뉴얼을 참조하여 범위를 정하고 연속형 신호를 일정한 샘플링 타임마다 디지털 값으로 읽어들여서 양자화된 신호들이 이 범위에 속할 때 그 값을 각각 세 가지 부류로 분류한 것이다. Table 2에 나타난 부하가 높은 경우에 소기압력이 높다(HIGH)는 25.0%,

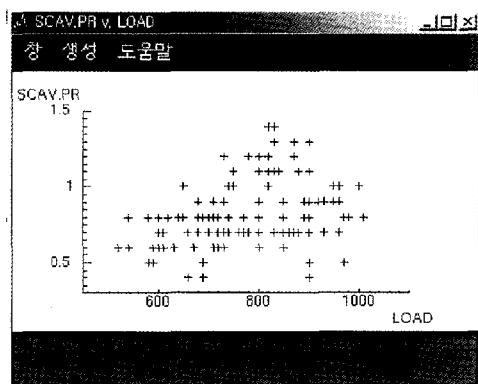


Fig. 1 Distribution of scavenging air pressure vs load

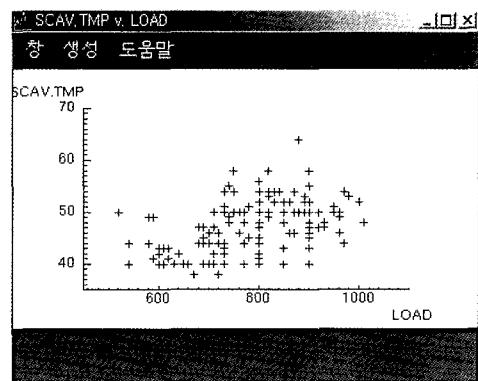


Fig. 2 Distribution of scavenging air temperature vs load

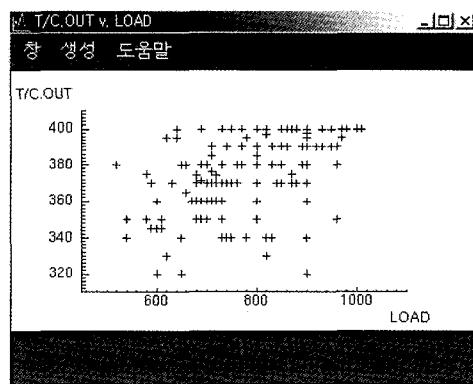


Fig. 3 Distribution of exhaust gas temperature of T/C vs load

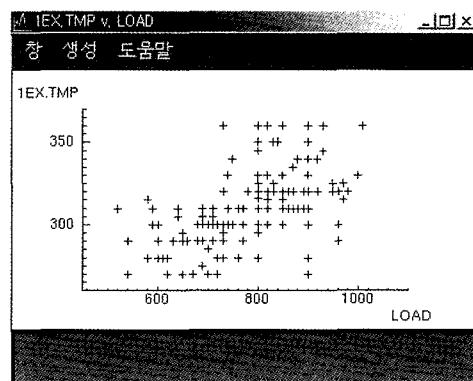


Fig. 4 Distribution of exhaust gas temperature of No.1 cylinder vs load

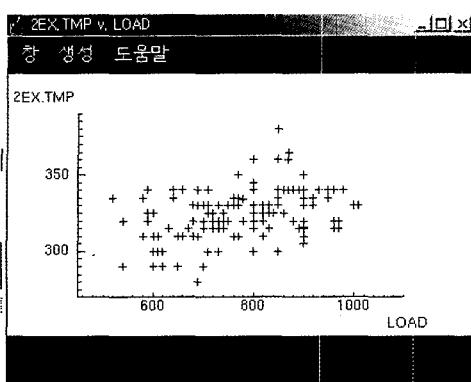


Fig. 5 Distribution of exhaust gas temperature of No.2 cylinder vs load

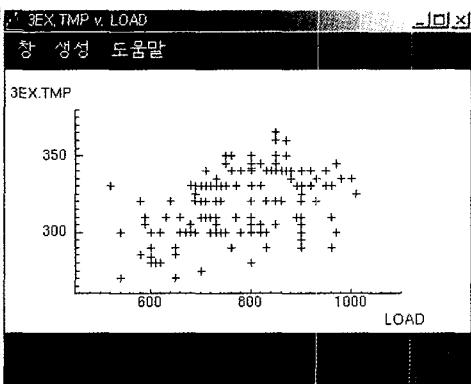


Fig. 6 Distribution of exhaust gas temperature of No.3 cylinder vs load

Table 2 Distribution of main data vs load(%)

빈도수(%)		load		
		high	mid	low
scav.	high	25.0	37.7	7.6
	mid	62.5	62.3	81.8
	low	12.5	0	10.6
tmp	high	25.0	34.8	6.1
	mid	71.9	55.1	62.1
	low	3.1	10.1	31.8
T/C	high	65.6	46.4	12.1
출구	mid	18.8	36.2	54.5
온도	low	15.6	17.4	33.3
배기ガス	high	25.0	17.4	3.0
	mid	65.6	75.4	51.5
	low	9.4	7.2	45.5

중간(MID)은 62.5%, 낮다(LOW)는 12.5%로 분포되어 있다. 부하가 높으면 배기ガス의 열에너지가 높아 과급기의 회전수도 높아져서 소기압력도 높아질 것으로 예상되나 실제 운전 데이터 분석에 의하면 오히려 중간(MID)의 경우가 더 많으며 낮다(LOW)의 경우도 12.5%나 됨을 알 수 있다.

따라서 부하가 높을 때 소기압력이 낮다(LOW)인 12.5%의 경우도 고장이라고는 판정할 수 없게 된다. 부하에 의해 영향을 받는 데이터들이지만 이들 데이터가 부하의 변화에 따라 일관성을 가지고 변화하지 않는 것을 알 수 있다. 소기온도, 과급기 출구온도 및 실린더의 배기ガス온도도 이와 유사하며 특히 실린더 배기ガ스온도의 경향특성은 실린더마다 다르다. 이것은 서로 영향을 끼치는 데이터라 하더라도 데이터 상호간에 일관성과 논리성을 끌어내기가 어려우며 동일 환경과 조건에서도 데이터의 재현성이 낮음을 알 수 있다.

단순히 작동온도범위에 따라 높다, 중간, 낮다라고 일률적으로 규정하여 진단하는 것은 무리가 있고, 연관된 데이터들을 군집화하여 처리할 필요가 있다.⁽⁴⁾ 따라서 디젤기관마다 그 운전데이터로 각각의 기관과 실린더가 가지는 특성에 따라 모델링하여 배기ガス온도, 소기압력과 온도 등 연소계통에 상호영향을 주는 복잡데이터로부터 연소계통의 이상 유무를 판단하는 것이 바람직하며 신경회로망은 이러한 문제를 해결하는데 좋은 방법이 될 수 있다.⁽⁵⁾

3. 신경회로망의 구조와 학습

신경회로망으로 연소계통의 이상 감지를 하기 위하여 데이터 수집장치에 의해 얻어진 각종 데이터들을 연소계통에 영향이 큰 것끼리 군집화하여 처리할 필요가 있다.⁽⁶⁾

Fig. 7은 신경회로망을 이용한 이상데이터 감지

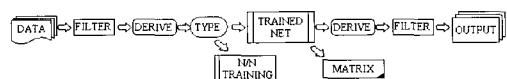


Fig. 7 The construction of fault detecting system using neural network.

시스템의 구조도이다. 그럼에서 수집된 감시 데이터 중에서 연소계통에 영향을 주는 데이터들만 골라내는 필터(FILTER)를 통과한 후에 출력 데이터에 쓰일 데이터의 목표필드를 만들어내는 파생(DERIVE) 필드작업으로 매뉴얼상의 운전 범위를 참고하여 높다, 중간, 낮다의 범주를 가진 필드를 만들어서 목표필드로 한다. 이들 데이터 중에서 입력과 출력관계를 유형(TYPE)필드 작업으로 정해 준다.⁽⁷⁾

이렇게 준비된 데이터로 신경회로망을 학습한다. 학습된 신경회로망을 통과한 데이터들에 경보 설정 파생 필드작업을 행하고 출력으로 내기위한 필드만 골라내는 필터작업을 하여 출력하면 처리된 데이터 중에서 이상감지가 된 데이터들만 경보로 표시되어 나오게 된다. 이런 일련의 처리과정을 디젤기관의 연소계통에 관계되는 데이터마다 적용하여 데이터의 특성이 고려된 신경회로망의 모델을 구성한다.

본 연구에서는 상용으로 사용되는 데이터마이닝 툴에서 제공하는 신경망모델 소프트웨어를 사

용하였다.

신경회로망 입력은 연소계통에 관계되는 데이터수와 같다. Table1의 데이터들 중에서 부하에 영향받는 데이터는 소기압력, 소기온도, 각 실린더 배기가스온도(9실린더) 및 T/C 배기가스 출구온도 등을 들 수 있다.

적합한 신경회로망을 구성하기 위하여 여러 가지 구조로 시뮬레이션 해 본 결과 입력층은 연소에 영향을 미치는 데이터로 13 뉴런과 은닉층은 한층으로 4 뉴런이고 출력 뉴런은 높다, 중간, 낮다와 예외 경우를 출력하는 4 뉴런으로 구성하였다. 학습을 위한 목표치는 연속형 데이터를 기관 운전 매뉴얼의 정상운전 참조값을 기준으로 하여 높다(HIGH), 중간(MID), 낮다(LOW)의 3가지 범주형 데이터로 각 변수명에 1을붙인 변수로 표기 하였다.

학습된 신경회로망의 출력은 예측 출력값과 예측 정확도를 0과 1 사이의 값으로 출력한다.⁽⁷⁾ 제안된 신경회로망을 실선에서 얻은 데이터로 학습한 결과 각각의 데이터에 대한 학습은 95%이상의 예측정확도를 나타내었다. 학습된 각 데이터의 출력은 각각

Table 3 The output of neural network(1)

신경망 "LOAD" 구조	신경망 "SCAV.PR" 구조
입력층 : 13 뉴런	입력층 : 13 뉴런
은닉층 #1 : 4 뉴런	은닉층 #1 : 4 뉴런
출력층 : 4 뉴런	출력층 : 4 뉴런
예측 정확도 : 97.44%	예측 정확도 : 100.00%
입력에 대한 상대적 중요도	입력에 대한 상대적 중요도
LOAD : 0.66737	SCAV.PR : 0.72007
T/C.OUT : 0.18922	2EX.TMP : 0.14873
5EX.TMP : 0.17195	T/C.OUT : 0.09420
SCAV.PR : 0.16810	5EX.TMP : 0.06098
8EX.TMP : 0.14848	7EX.TMP : 0.05540
3EX.TMP : 0.13443	4EX.TMP : 0.05496
7EX.TMP : 0.09276	3EX.TMP : 0.02947
1EX.TMP : 0.09253	1EX.TMP : 0.02498
9EX.TMP : 0.06347	8EX.TMP : 0.01942
SCAV.TMP : 0.06170	SCAV.TMP : 0.01733
4EX.TMP : 0.05984	9EX.TMP : 0.01557
2EX.TMP : 0.05884	LOAD : 0.01383
6EX.TMP : 0.01125	6EX.TMP : 0.01371

Table 4 The output of neural network(2)

신경망 "1EX.TMP" 구조	신경망 "2EX.TMP" 구조
입력층 : 13 뉴런	입력층 : 13 뉴런
은닉층 #1 : 4 뉴런	은닉층 #1 : 4 뉴런
출력층 : 4 뉴런	출력층 : 4 뉴런
예측 정확도 : 98.65%	예측 정확도 : 98.82%
입력에 대한 상대적 중요도	입력에 대한 상대적 중요도
1EX.TMP : 0.66771	2EX.TMP : 0.33748
3EX.TMP : 0.24185	7EX.TMP : 0.09434
8EX.TMP : 0.17025	5EX.TMP : 0.09044
2EX.TMP : 0.14666	9EX.TMP : 0.06968
SCAV.TMP : 0.14559	T/C.OUT : 0.04879
7EX.TMP : 0.12040	LOAD : 0.04547
SCAV.PR : 0.10607	SCAV.TMP : 0.04047
5EX.TMP : 0.09284	6EX.TMP : 0.03341
4EX.TMP : 0.07330	3EX.TMP : 0.03185
9EX.TMP : 0.06223	8EX.TMP : 0.03027
T/C.OUT : 0.06091	1EX.TMP : 0.02685
LOAD : 0.00764	SCAV.PR : 0.02450
6EX.TMP : 0.00744	4EX.TMP : 0.01434

Table 5 The output of neural network(3)

신경망 "T/C.OUT" 구조	신경망 "SCAV.TMP" 구조
입력총 : 13 뉴런	입력총 : 13 뉴런
온닉총 #1 : 4 뉴런	온닉총 #1 : 4 뉴런
출력총 : 4 뉴런	출력총 : 4 뉴런
예측 정확도 : 97.75%	예측 정확도 : 98.78%
입력에 대한 상대적 중요도	입력에 대한 상대적 중요도
T/C.OUTS : 0.70579	SCAV.TMP : 0.72486
CAV.TMP : 0.11391	T/C.OUT : 0.18422
3EX.TMP : 0.07240	8EX.TMP : 0.17678
4EX.TMP : 0.06419	2EX.TMP : 0.13425
SCAV.PR : 0.04899	LOAD : 0.10787
9EX.TMP : 0.04823	3EX.TMP : 0.08976
1EX.TMP : 0.04522	1EX.TMP : 0.08973
8EX.TMP : 0.04484	5EX.TMP : 0.08341
6EX.TMP : 0.04105	6EX.TMPs : 0.08238
LOAD : 0.02116	SCAV.PR : 0.07765
5EX.TMP : 0.01966	7EX.TMP : 0.07054
2EX.TMP : 0.01371	9EX.TMP : 0.06999
7EX.TMP : 0.01218	4EX.TMP : 0.06210

의 데이터가 학습되면서 자기 자신의 데이터에 대한 상대적 중요도를 가장 많이 가지고 출력되며 다른 데이터와의 상대적 중요도만큼 영향을 받아 결정되므로 각각의 데이터를 매뉴얼에 따라 높다, 중간, 낮다로 구분하는 것하고는 차이가 있다.

즉 각 데이터를 신경회로망을 통하지 않고 구분하게 되면 그 구분은 단순히 현재 그 데이터의 상태만을 나타낼 뿐 다른 데이터와의 연관성은 없게 된다.

이런 방법은 데이터 값의 범위를 정하여 어느 범위 이상으로 나오는 데이터를 이상 데이터로 처리하는 방법인데, 발전기 구동용 디젤 기관의 경우는 앞 절에서 분석된 것에 의하면 부하가 높을 때 배기ガ스온도가 높게 되는 경우도 있지만 중간이나 낮게 되는 경우도 있으므로, 어느 범위 이상인 데이터가 이상 데이터라고 분류할 경우 이상데이터로 분류된 데이터는 실제로 이상 데이터로써 주목할 필요가 있는지 아닌지를 분별하기가 어렵다.

그러나 신경회로망을 거친 데이터는 그 자신의 중요도(하중계수)뿐만 아니라 연소계통에 관계 있

는 다른 데이터들의 상대적 중요도를 고려하여 이상 데이터로 분류하기 때문에 기관의 연소계통의 상태를 파악하는 데는 훨씬 더 유용하게 쓰일 수 있다. Table 3에서 Table 5는 실선데이터로 제안한 신경회로망을 학습 하였을 때 연소계통에 영향을 주는 여러 데이터가 출력데이터에 대해 어느 정도 영향을 주어 결정하였는가 하는 상대적 중요도를 나타낸 것이다.

Table 3은 부하의 상태(높다, 중간, 낮다 등)를 판단하는 경우 부하자신에 대한 판단의 비중은 66.7%이며 판단의 33.3%는 부하 외의 연소상태에 영향을 미치는 데이터 즉 T/C출구온도, 소기압력, 소기온도, 각 실린더 배기가스온도 등으로 결정한다. Table 4는 1번 배기ガス, 2번 배기ガ스온도를 Table 5는 T/C출구온도와 소기온도에 대하여 나타내었다.

4. 제안한 시스템에 의한 처리 결과 및 고찰

Table 6은 같은 선박에서 채취한 다른 날자의 데이터를 가지고 학습된 신경회로망을 통하여 데이터의 이상감지를 한 결과의 일부이다.

학습된 신경회로망으로 이상여부를 판단한 데이터들의 특징을 살펴보면 높다, 중간, 낮다라는 경계 근방에 있는 데이터는 다른 데이터의 영향을 받아서 동일 값을 가진 데이터라 하더라도 출력은

Table 6 A part of output of fault detecting system for load

LOAD	LOAD1	\$N		ALARM
		-LOAD1	-LOAD1	
850	MID	MID	0.888379	default
930	HIGH	HIGH	0.961178	ALARM
1010	HIGH	HIGH	0.972798	ALARM
930	HIGH	HIGH	0.951261	ALARM
800	MID	MID	0.843881	default
970	HIGH	HIGH	0.972521	ALARM
900	HIGH	HIGH	0.666023	default
900	HIGH	HIGH	0.799001	default
900	HIGH	HIGH	0.915493	ALARM
900	HIGH	HIGH	0.840214	default
920	HIGH	HIGH	0.919913	ALARM

다르게 나타날 수 있는데 이것은 전문가인 엔지니어가 이상데이터를 판단할 때 데이터 자체만 가지고 높다 낮다라고 판단하지 않고 다른 데이터들을 참조하여 전문적인 지식에 의해 판단하는 것과 유사한 방법이라 할 수 있다.

따라서 신경회로망에 의해 판단된 출력과 이 출력에 대한 예측정확도는 범주의 경계에서 더 멀어질수록 단순범주의 판단결과와 같아지는 경향이 있고 범주의 경계 부근에 있는 데이터는 다른 데이터에 의해 영향을 받아 결정되므로 단순 범주에 의한 판단결과와 다를 수 있다.

Table7은 신경회로망의 학습데이터에 대한 중요 데이터의 예측 정확도를 나타내고 있다. 또 학습된 신경회로망으로 테스트 데이터를 처리하였을 때 중요 데이터의 예측정확도를 Table 8에 보인다. Table 7에서 비교적 상호의존도가 낮은 데이터의 예측정확도는 높게 나타남을 알 수 있다. 즉, 소기압력은 과급기의 출력에 영향을 많이 받으며 과급기출력은 배기가스의 열에너지의 양 즉 부하에 의존하므로 소기압력의 예측정확도는 Table7과 Table8에서 모두 높은 것을 알 수 있다.

Fig.7 The result of estimation(training data)

		예측정확도(%)		
		high	mid	low
load	high	96.9	3.1	0
	mid	0	98.6	1.4
	low	0	1.5	98.5
scav. pr.	high	100	0	0
	mid	0	100	0
	low	0	0	100
scav. tmp	high	97.2	2.8	0
	mid	1.0	99.0	0
	low	0	0	100
T/C 출구 온도	high	100	0	0
	mid	6.3	98.5	1.5
	low	0	2.6	97.4
1번 배기가스 온도	high	100	0	0
	mid	0.9	99.1	0
	low	0	0	100

Table 8 The result of estimation(test data)

		예측정확도(%)		
		high	mid	low
load	high	90.9	9.1	0
	mid	0	100	0
	low	0	5.9	94.1
scav. pr.	high	100	0	0
	mid	0	100	0
	low	0	0	100
scav. tmp	high	90.0	10.0	0
	mid	3.4	96.6	0
	low	0	0	100
T/C 출구 온도	high	100	0	0
	mid	0	100	0
	low	0	0	100
1번 배기가스 온도	high	100	0	0
	mid	0	100	0
	low	0	0	100

따라서 데이터 이상감지를 할 때 예측정확도를 적정 수준으로 설정하고 데이터가 높거나 낮은 경우를 이상데이터로 처리하는 것이 바람직하다. 전술한 바와 같이 디젤엔진은 어느 한 데이터가 표준운전범위를 벗어났다고 하여 계통고장이라고 단정할 수 없으므로 표준운전범위를 벗어난 데이터를 중심으로 상호 영향을 미치는 관련 데이터를 체계적으로 조사하여 계통고장가능성을 진단하는 것이 이상적이다. 이러한 방법으로 관련 데이터를 종합적으로 분석하여 이상이 있다고 판단되면 이상이 있는 계통의 세부 고장개소를 추적하는 방법을 쓴다.

운전중인 기관의 고장진단을 행하기 위해서는 감시되는 데이터를 가능하면 다각도로 검토하여 고장개소를 추정하는 것이 올바른 고장개소를 발견하는 방법이 되므로 이상데이터라고 판단되는 데이터를 가능하면 여러 연관된 데이터들을 비교분석하여 판단하는 것이 좋다.

5. 결 론

실제의 선박에서 수집한 발전기 데이터를 사용하여 부하를 중심으로 데이터 분포를 분석하여 본 결과 부하에 따라 데이터의 분포가 규칙 있는 모형을 가지지 않고 데이터의 재현성이 없으며 명확히 구분되지 않음을 알 수 있었다.

그러나 이들 데이터 중에는 정상적인 데이터들도 있고 이상데이터들도 포함되어 있다. 방대한 데이터들을 분류하는 방법은 여러 가지가 있을 수 있으나 디젤기관의 감시 데이터들 중에서 이상데이터를 골라내기 위해서는 서로 연관성이 있는 것끼리 분류하여 연관을 지어 처리할 필요가 있다.

속달된 엔지니어는 디젤기관의 어느 한 가지 데이터만으로 기관의 이상상태를 파악하지 않고 상호의존도가 높은 데이터를 비교 분석하여 전문지식에 의해 이상 여부를 판단한다. 본 연구에서는 이러한 전문가의 판단과정과 유사한 진단엔진을 구성하기 위하여 신경회로망을 이용하여 디젤기관 연소계통의 데이터 이상여부를 판단하는 데이터이상감지시스템을 구성하였다.

제안한 신경회로망에 의한 데이터이상감지시스템은 이상데이터 판단을 데이터의 범위만으로 결정하지 않고 상호의존도가 높고 영향을 주는 데이터를 고려하여 판단하는 것을 보였다. 또한 학습된 신경회로망으로 구성한 데이터이상감지시스템을 사용하여 실시간으로 감시되는 데이터로부터 디젤기관 연소계통의 데이터이상감지를 시뮬레이션을 통하여 확인하여 본 결과 이상데이터를 감지 할 수 있음을 보였다.

예측정확도를 적정한 수준으로 정하고 데이터이상감지를 하여 고장 계통을 확인한 후 세부적으로 고장 부위를 찾아가면 이상적인 고장진단이 가능할 것으로 판단되어 향후 제안한 방법에 의해 처리된 데이터를 지식기반 퍼지추론엔진으로 연결하여 고장 개소와 정비 방법을 제시하는 통합 고장진단 정비시스템에 대한 연구를 계속할 예정이다.

이 논문은 2002년도 두뇌한국21 사업에 의하여 지원되었음.

참 고 문 현

- [1] Panos J. Antsaklis, Kevin M. Passino, An Introduction to Intelligent and Autonomous Control, [P. R. Prasad, J. F. Davis, chapter 16. "A Framework for Knowledge-Based Diagnosis in Process Operations"], KLUWER ACADEMIC PUBLISHERS, pp. 401-422, 1992.
- [2] 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.
- [3] P. J. Antsaklis and K. M. Passino, "An Introduction to Intelligent and Autonomous Control," [K. J. Astrom, K. E. Arzen, chapter 7. "Expert Control"] KLUWER academic publishers, pp.163-189, 1992
- [4] Kohonen, T., Self-organization and associative memory, springer verlag, pp. 10-17, 1984.
- [5] Y. C. Pati, P. S. Krishnaprasad, "Analysis and Synthesis of Feedforward Neural Networks Using Discrete Affine Wavelet Transformations", electrical engineering department and systems research center, university of Maryland,
- [6] 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.
- [7] 허준, 최병주, 클레멘타인을 이용한 데이터마이닝, SPSS아카데미, 2001.

저 자 소 개



천행춘(千幸春)

1958년 12월생. 1980년 한국해양대학교 기관학과 졸업. 1997년 한국해양대학교 대학원(공학석사). 2000년 한국해양대학교 대학원박사과정수료.



유영호(劉永昊)

1951년 10월생. 1974년 한국해양대학교 기관학과 졸업. 1990년 한국해양대학교 대학원(공학박사). 당학회 재무이사, 평의원. 1991~현재 해양대학교 기계·정보공학부 부교수.