

전문가시스템을 기반으로 한 통합기계상태진단 알고리즘의 구현(I)

장래혁[†] · 윤의성 · 공호성 · 최동훈*

한국과학기술연구원 트라이볼로지연구센터, 한양대학교 기계공학부*

Implementation of an Integrated Machine Condition Monitoring Algorithm Based on an Expert System

Rae-Hyuk Chang[†], Eui-Sung Yoon, Hosung Kong and Dong-Hoon Choi*

Tribology Research Center, KIST

School of Mechanical Engineering, Hanyang University*

Abstract – An integrated condition monitoring algorithm based on an expert system was implemented in this work in order to monitor effectively the machine conditions. The knowledge base was consisted of numeric data which meant the posterior probability of each measurement parameter for the representative machine failures. Also the inference engine was constructed as a series of statistical process, where the probable machine fault was inferred by a mapping technology of pattern recognition. The preposed algorithm was, through the user interface, applied for an air compressor system where the temperature, vibration and wear properties were measured simultaneously. The result of the case study was found fairly satisfactory in the diagnosis of the machine condition since the predicted result was well correlated to the machine fault occurred.

Key words – fault diagnosis, expert system, condition monitoring.

1. 서 론

산업이 발전하고 기술이 발달함에 따라 제품생산의 중요성 만큼이나 각종 시스템에 대한 유지, 보수 및 진단에 관한 인식이 높아져 가고 있으며 이미 커다란 경제적인 영역을 형성하고 있다[1]. 상태진단기술(condition monitoring technology)이란, 기계시스템의 예기치 않은 고장 또는 부품파손으로 인한 작동불능으로 발생하는 막대한 경제적, 인적 손실을 줄이기 위해 기계시스템의 운전상태를 지속적으로 또는 정기적으로 감시하며 이상 발생현상을 사전에 검지하여 예방, 조치하게 하는 첨단기술로서 선진국들을 중심으로 1980년대 초부터 연구개발되어 정착되고 있으며, 국내의 경우도 빈번한 사고발생 및 유지보수에 대한 인식의 확산으로 상기기술의 도입 및 연구개발의 필요성이

점차 대두되고 있다[1].

현재 국내외를 통하여 실용화된 상태진단기술들을 특성에 따라 분류하면, 시스템 작동변수(온도, 압력, 유량 등)들을 측정하는 방법, 기계부품 혹은 윤활유의 물리화학적 변화를 측정하는 방법, 마찰손실에너지(진동/소음)를 측정하거나 마멸에 의한 재료손실을 검지하는 방법 등이 있다.

이들 중 현재 국내외에 걸쳐 가장 많이 활용되고 있는 상태진단기술은 기계류 시스템의 진동 및 온도측정을 통한 동특성 해석과 온도경향 분석을 들 수 있다. 상기기술은 관련 분야에서의 이론정립 및 측정센서의 활발한 개발에 힘입어 많은 발전을 거듭해 왔으나, 측정신호들간의 상호간섭 및 전기적 외란 등의 복합적 요인들에 의한 부정확적 측정과 이에 따른 정밀신호처리 기법의 개발 및 전문인력의 필요성 등의 어려움이 여전히 남아 있다[1-2].

기계시스템 내에서 발생하는 마멸량을 측정, 분석함

[†]주저자 · 책임저자 : rhchang@kist.re.kr

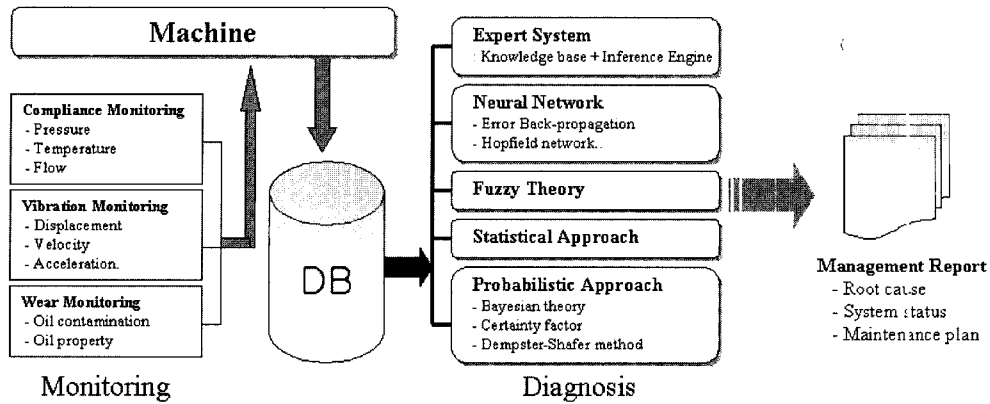


Fig. 1. Integrated condition monitoring & diagnosis.

으로써 기계부품의 파손여부 및 건전성을 판단하는 마멸분석을 통한 상태진단기술은 진동특성해석에 의한 제반단점을 보완함과 동시에 기계의 분해작업 없이 기계요소 부품들의 파손정도 및 여부를 정기적으로 혹은 연속적으로 검지할 수 있다는 장점을 지닌 신기술로써, 인체 내의 혈액을 분석하여 인체의 건강을 판단하는 것과 유사하여 기계건강진단기술(machine condition monitoring)이라 불리운다[2].

그러나, 상기의 다양한 진단기술 중 어느 하나의 측정결과만으로는 시스템의 이상발생여부 및 파손상태정도를 정확하게 진단 및 예측하기에는 어려움이 따른다. 따라서, 기계시스템 이상발생에 따른 효과적인 진단 및 예측을 위해서는 Fig. 1에서 보듯이 서로의 장단점을 보완할 수 있는 진동 및 마멸측정을 중심으로 한 통합상태진단기술이 적용되어야 하며[12], 여기에 적용된 다양한 측정결과들을 종합적으로 관리하고 이들 측정데이터를 바탕으로 기계시스템의 이상발생에 따른 진단 및 예측이 가능한 통합상태진단 알고리즘의 구현이 필수적일 것으로 사료된다.

본 연구에서는 진동, 마멸, 온도 등의 통합상태진단 측정결과들을 바탕으로, Fig. 1의 다양한 진단알고리즘을 검토하고 통합상태진단을 행하는 기계시스템에서의 이상발생에 대해 효과적인 진단이 가능한 전문가시스템 기반의 통합상태진단 알고리즘을 개발하였고, 실제 가동중인 대형 공기압축시스템을 통해 구현해 보았다.

2. 상태진단 알고리즘

상기 상태진단기술에 의해 측정된 데이터를 바탕으

로 실제 기계시스템의 상태진단에 있어서는 측정값의 다양성 및 비선형성, 이상발생에 대한 판단의 불확실성 등으로 인하여 기존의 컴퓨터 기술로는 구현하기에 어려움이 있으며 이의 해결을 위해 인공지능(AI)을 비롯한 많은 기법들이 적용되고 있다. 이 중 전문가시스템(expert system)과 신경회로망(neural network)이 가장 대표적이며 이 이외에 퍼지이론, 통계적처리, 확률적 접근, 패턴인식 등의 기법들이 적용되고 있으나, 대부분 특정 진단기술에 따른 동일한 속성과 범위를 갖는 측정값을 기반으로 적용되어왔다[3-9].

대표적인 신경회로망 기술은 1943년 McCulloch와 Pitts에 의해 시작되어 1980년 대 들어 활성화된 것으로, 인간 뇌의 신경세포의 정보처리전달체계를 수학적 모델링으로 구현한 것으로 학습을 통해 이루어진 결과를 토대로 최종적으로는 간단한 수학적 프로세스를 통하여 알고리즘 수행이 가능하여 예측 및 진단분야 뿐만 아니라 로봇제어, 신호 및 영상처리 등의 광범위한 분야에서 활용되고 있다[4].

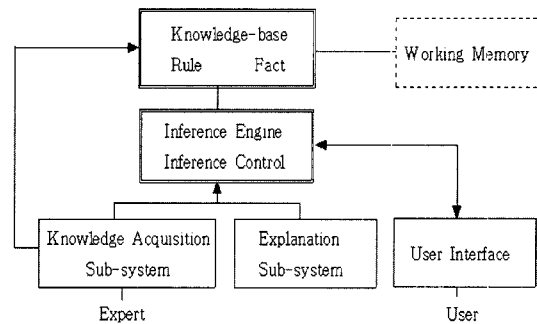


Fig. 2. Expert system.

그러나, 본 연구에서의 통합상태진단의 경우 신경망의 가장 큰 장점인 학습에 필요한 측정 및 사건발생 데이터의 부족에 따른 학습의 효율성 저하와 다양한 측정변수들로 인한 신경망 입력노드의 일관성을 확보하지 못한다는 단점을 가지며, 더불어 신경망 알고리즘 중 가장 널리 활용되는 오차 역전파알고리즘(error back-propagation)의 경우 학습의 수렴성을 보장할 수 없어 새로운 사건에 대한 진단알고리즘의 수정에 어려움이 있어 신경망의 경우 통합상태진단의 알고리즘에 부적합적인 요소가 많은 것으로 평가되었다.

신경망과 더불어 불확실성을 고려하는 방법으로 널리 이용되는 퍼지이론(fuzzy theory)은 1965년 Zadeh에 의해 제안된 것으로, 기존 이진수 논리체계를 0과 1 사이의 소속함수(membership function)로써 표현함으로써 인간언어의 표현체계를 어느 정도 수치화 한 것이다[4]. 식 (1)은 퍼지제어에 널리 사용되는 Mamdani가 제안한 추론방법이며 일반적으로 “IF-THEN” 형식의 퍼지규칙으로 정의한 후 사용된다.

$$\begin{aligned}
 & \text{[IF } x \text{ is } A \text{ and } y \text{ is } B \text{ THEN } z \text{ is } C] \\
 & R=A \cap B \rightarrow C=A \times B \times C \quad (1) \\
 & \int_{u \times v \times w} ((\mu_A(u) \wedge \mu_B(v) \wedge \mu_C(w)) / (u, v, w))
 \end{aligned}$$

퍼지이론의 적용으로 어떠한 입력에 대한 추론값을 연속적인 실수값으로 평가할 수 있다는 장점은 있으나, 기존 지식을 바탕으로 한 “IF-THEN” 형태의 규칙표현의 제한성과 유연성 부족이 본 연구에서의 상태진단알고리즘의 장애물로 평가되었다.

또 하나의 대표적인 방법인 전문가시스템은 인공지능(AI)의 가장 두드러진 응용분야로 어떤 특정분야의 전문가가 지닌 지식을 프로그래밍화 한 것으로, Fig. 2에서 보듯이 전문가의 지식과 경험을 다양한 표현기법으로 구성된 지식베이스(knowledge base)와 추론엔진(inference engine)을 중심으로 구성된다. 특히, 상태진단 분야에서의 전문가시스템의 활용은 80년대 인공지능 분야의 발전에 힘입어 신경망, 퍼지이론 등의 다른 기술보다 앞서 이루어졌다[5]. Fig. 3에 제시된 1993년 Durkin의 조사에서도 보듯이 약 2,500개의 전문가시스템들의 유형별 분류에서도 진단분야가 가장 많은 비율을 차지하고 있음을 알 수 있다. 그러나, 진단분야에서의 많은 적용에도 불구하고 동 분야의 특성상 지식베이스의 구성에 필요한 지식획득 및 표현의 어려움과 지식베이스의 유연성 부족이 가장 큰 장애물로 인식되




Fig. 3. Expert system - % application.

고 있으며 대부분의 적용이 특정 상태진단기술에 국한되어 적용되어 왔다[6].

상기의 여러 진단기법들을 토대로, 본 연구에서 수행할 통합상태진단기술의 진단알고리즘 구현에 필요한 특성을 살펴보면 다음과 같다. 첫째, 다양한 진단기술로부터의 측정값들로 인하여 입력 변수의 속성과 범위가 일정치 않다. 둘째, 이상진단분야의 특성과 더불어 여러 진단기술의 측정값들간에 상관관계 규명이 어려우며 마지막으로 성능향상을 위해 알고리즘의 유연성이 확보되어야 한다는 것이다. 이러한 특성을 만족시키기 위한 진단알고리즘은 기본적으로 “IF-THEN” 기반의 표현체계를 탈피한 연속적인 수치데이터 표현방식이 적절하며, 그러한 수치표현으로부터의 효과적인 추론을 위해서 여러 수학적, 통계적 기법들이 적용되는 것이 바람직하고 아울러 유연성 확보를 위한 적절한 방안이 제안되어야 한다.

따라서, 상기의 비교결과를 바탕으로 본 연구에서는 기존 생성규칙(production rule)을 기반으로 이루어진 전문가시스템을 수치데이터 지식표현방식에 근거한 지식베이스 구성과 수학, 통계적기법의 하향식 추론엔진을 중심으로 한 진단알고리즘을 구현하였다.

3. 대상 시스템

본 연구에서의 대상 시스템은 Fig. 4에 보여주는 바와 같이 모터, 증속기, 압축기를 주요 구성으로 하는 대형 공기 압축기의 기계유탄시스템이며, 상기 시스템의 주요 제원은 Table 1과 같다. 대상 시스템의 운전상태를 파악할 수 있는 정비이력을 살펴보면, 초기 설치 이후 현재까지 2년 주기로 정기 보수가 시행되고 있으며 비정기적인 이상발생으로 인하여 수 차례의 설




Fig. 4. Air-turbo-compressor System.

Table 1. Air-turbo-compressor system

- Air-turbo-compressor system
 - Main Component
 - Motor(8,500 kW), Oil Reservoir
 - Compressor, Gear Unit
- Main Machine Elements
 - Main Journal Bearing (Motor)
 - Tilting Pad Bearing (Compressor)
 - Gears, and Thrust Bearing
- Lubrication System
 - Oil Viscosity: 46 cSt @ 40°C (ISO VG46)
 - Operating Temperature: about 60°C
 - Oil Tank Capacity: about 5,500 L

비 수리가 시행된 바 있다.

현재 대상 시스템에 설치 운영되고 있는 상태진단기술을 살펴보면, 회전기에 적용되고 있는 대표적인 기술인 진동량 및 온도 측정을 실시간으로 하고 있다. Fig. 4에서 보듯이 온도는 7부위(T141~T147)에서 각 베어링부의 표면온도를, 진동량은 증속기 부위의 가속도(Y161, G), 종동축에서의 축방향변위(X163, mm), 압축기 입출력 부위에서의 변위(Y160A, Y160B, Y164A, Y164B) 등을 측정하고 있다. 또한, 사용 윤활유의 주요 물성값들(동점도, 점도지수, 수분기, 전산기, 혐잡물)의 변화를 1분기에 1회씩 수집, 분석하고 있다.

이외에도 대상시스템의 통합상태진단이 가능하도록 진동, 온도측정 이외에 실시간 마멸량 측정시스템이 추가적으로 설치되어 운영되고 있다. 상기 시스템은 시스템 내의 오일을 자동적으로 샘플링하여 오일 내에 함유되어 있는 기포를 자동적으로 제거한 후, 총 마멸 입자량(D₁) 및 자성 마멸입자량(D₂)을 각각 구별하여 측정하며 상기의 모든 결과들이 컴퓨터에 데이터베이스

스화되어 저장되고 있다[12].

4. 전문가 시스템 구현

4-1. 지식베이스

지식베이스(knowledge base)는 전문가의 지식을 표현, 저장하는 곳으로 해당 문제를 해결하는 사실(fact)과 의사결정의 자료로 사용되는 규칙(rule)으로 구성된다. 대상시스템에서의 사실들은 크게 측정센서의 입력과 이상진단을 위한 출력으로 구분되며, 각각 대상시스템의 이상진단을 위해 측정되는 26개의 다양한 센서값과 해당 시스템의 전형적인 이상발생이나 원인별 평가를 반영하는 것으로 선정하였으며, Table 2와 Table 3에서 보여주고 있다.

이 사실들간의 관계설정 및 의사결정의 바탕이 되는 규칙은 지식베이스에서 가장 중요한 지식표현(knowledge representation)으로 지난 20여년간에 걸쳐 많은 지식표현 방법이 제안되었으며 이 중 Mylopoulos 및 Levesque의 구분방법이 가장 대표적인데[5], 본 연구에서는 보편적으로 사용되는 IF-THEN 형식의

Table 2. Input facts of knowledge base

No	Measuring Data	Unit	Description	On/Off line	Device
1	D1	None	total contamination of oil	on-line	OMD
2	D2	None	ferrous contamination of oil	on-line	OMD
3	NAS	None	NAS grade	off-line	dCA
4	Fe	ppm	quantity of Fe particles in oil	off-line	ICP
5	Sn	ppm	quantity of Sn particles in oil	off-line	ICP
6	Si	ppm	quantity of Si particles in oil	off-line	ICP
7	PQ Index	None	index of ferrous particles in oil by PQ	off-line	PQ
8	RPD	None	qualitative analysis of wear particles	off-line	RPD
9	T140	°C	temperature of compressor(IN)	on-line	sensor
10	T141	°C	temperature of compressor(OUT)	on-line	sensor
11	T142	°C	temperature of pinion axis	on-line	sensor
12	T143	°C	temperature of pinion axis	on-line	sensor
13	T144	°C	temperature of wheel axis	on-line	sensor
14	T145	°C	temperature of wheel axis	on-line	sensor
15	T147	°C	temperature of thrust bearing	on-line	sensor
16	Y160A	µm	displacement of compressor(OU ⁺)	on-line	sensor
17	Y160B	µm	displacement of compressor(OU ⁻)	on-line	sensor
18	Y164A	µm	displacement of compressor(IN)	on-line	sensor
19	Y164B	µm	displacement of compressor(OUT)	on-line	sensor
20	Y161	G	acceleration of gear unit	on-line	sensor
21	X163	mm	displacement of pinion gear	on-line	sensor
22	Viscosity	cSt	viscosity of oil	off-line	device
23	Viscosity Index	None	viscosity index of oil	off-line	device
24	TAN	mgKOH/g	acidity degree of oil	off-line	device
25	Insoluble	ppm	quantity of foreign matters in oil	off-line	device
26	Water Content	ppm	quantity of water in oil	off-line	device

Table 3. Output facts of knowledge base

Case	Event	Code
Case I	Misalignment and Imbalance	C ₁
Case II	Gear Wear/Failure	C ₂
Case III	BRs Wea/Failure	C ₃
Case IV	Improper Lubrication	C ₄
Case V	Ingress of Foreign Matters	C ₅
Case VI	Oil Starvation	C ₆

Table 4. Standard code

	C1	C2	C3	C4	C5	C6
D1	0.0	0.4	0.2	0.1	0.2	0.1
D2	0.0	0.6	0.0	0.3	0.0	0.1
NAS	0.0	0.4	0.2	0.1	0.2	0.1
Fe	0.0	0.6	0.0	0.3	0.0	0.1
Sn	0.0	0.0	0.7	0.2	0.0	0.1
Si	0.0	0.0	0.0	0.0	1.0	0.0
PQ index	0.0	0.6	0.0	0.3	0.0	0.1
RPD	0.0	0.5	0.1	0.2	0.1	0.1
TE140	0.0	0.0	0.7	0.2	0.0	0.1
TE141	0.0	0.0	0.7	0.2	0.0	0.1
TE142	0.1	0.1	0.5	0.2	0.0	0.1
TE143	0.1	0.1	0.5	0.2	0.0	0.1
TE144	0.1	0.1	0.5	0.2	0.0	0.1
TE145	0.1	0.1	0.5	0.2	0.0	0.1
TE146	0.1	0.1	0.5	0.2	0.0	0.1
TE147	0.2	0.2	0.3	0.2	0.0	0.1
Y180A	0.4	0.3	0.1	0.1	0.0	0.1
Y180B	0.4	0.3	0.1	0.1	0.0	0.1
Y181	0.4	0.3	0.1	0.1	0.0	0.1
Y184A	0.4	0.3	0.1	0.1	0.0	0.1
Y184B	0.4	0.3	0.1	0.1	0.0	0.1
X183	0.8	0.2	0.0	0.0	0.0	0.0
Viscosity	0.0	0.1	0.1	0.7	0.0	0.1
Index	0.0	0.1	0.1	0.7	0.0	0.1
TAN	0.0	0.1	0.1	0.7	0.0	0.1
Insoluble	0.0	0.3	0.1	0.1	0.4	0.1
Water	0.0	0.0	0.0	1.0	0.0	0.0

논리적 절차표현 대신 구조적 지식표현 중 수치데이터 기반의 지식표현을 사용하였다. Table 4에서 제시된 표준코드의 설정은 해당 분야 전문가들의 경험적 지식과 대상시스템의 과거 수리이력을 토대로 구성하였다. 이러한 수치데이터 기반의 지식표현은 다른 방법들에 비해 수학적, 통계적인 기법들의 활용도가 크다는 장점이 있다[13].

표준코드 내의 값은 확률적 표현에서 주로 쓰이는 전통적인 'Bayes theorem'을 기반으로 사후확률 (posterior probability) 형태로 표현하였으며, 하나의 입력값 X_n 이 해당 이상발생원인 C_m 에 미치는 조건부확률 형태로 나타내었다.

Assumption: Prior probability

$$P(C_1)=P(C_2)=\dots=P(C_6)=constant$$

Sample Data: X

$$X=\{X_1, X_2, \dots, X_n\}, n=26 \quad (2)$$

Hypothesis: C

$$C=\{C_1, C_2, \dots, C_m\}, m=6$$

$$\sum_{m=1}^6 P(C_m/X_n)=1.0, \text{ where } n=1-26$$

4.2. 추론엔진

추론엔진(inference engine)은 지식베이스로부터 어떠한 입력에 대한 결과를 추리해 나가는 과정을 말한다. 본 연구에서는 수치기반의 지식베이스로 제안한 Table 4의 대상시스템에 대한 일종의 표준코드를 진단 시점의 측정데이터들과 비교하기 위해, Fig. 5과 같이 패턴인식(pattern recognition)에서 사용되는 맵핑기법을 바탕으로 한 일련의 과정을 통하여 지식베이스를 최종적으로 선형방정식으로 변환하여 대상 입력에 대한 추론을 수행하고자 하였다.

상기 목적을 위해 우선 Table 4의 6개의 output facts 사이의 유사성(similarity)을 수치적으로 표현하기 위해, 다차원 공간상에서의 거리측정으로 그 유사성을 나타내는 'Euclidean Distance'를 사용하였고 그 식은 다음과 같다.

$$E_{kl} = \sqrt{\sum_{i=1}^d (x_{ik} - x_{il})^2} \quad (3)$$

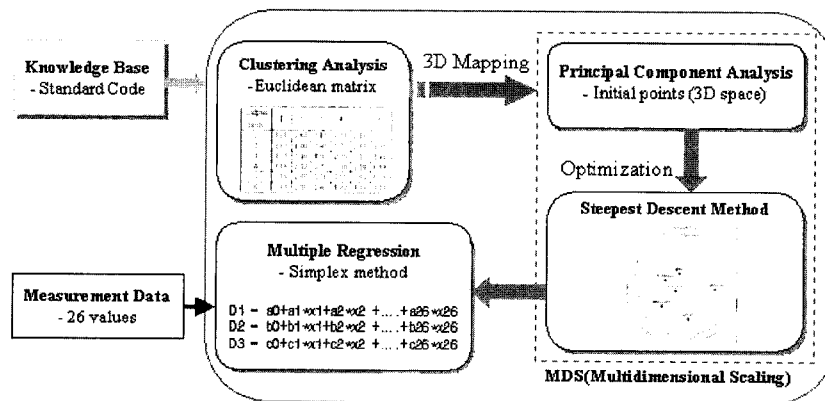


Fig. 5. Inference engine in expert system.

Table 5. Euclidean matrix

Output facts	1	2	3	4	5	6
1	0.00	2.63	3.13	2.89	.86	1.83
2	2.63	0.00	3.46	2.72	2.95	2.35
3	3.13	3.46	0.00	2.75	3.31	2.46
4	2.89	2.72	2.75	0.00	2.88	1.99
5	2.86	2.95	3.31	2.88	0.00	1.59
6	1.83	2.35	2.46	1.99	1.59	0.00

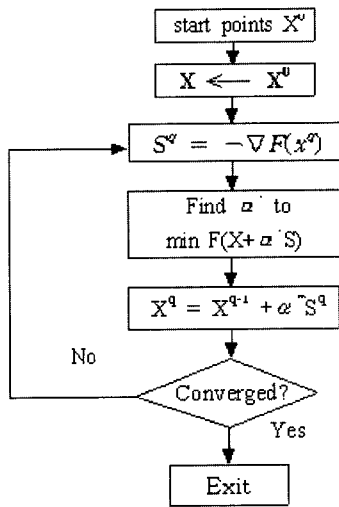


Fig. 6. Steepest descent.

where d : input facts of knowledge(1~26)
 l : output facts of knowledge(1~6)
 k : normalized measurement data

식 (3)을 통하여 계산된 output facts 의 상관관계는 Table 5의 대칭행렬형태로 나타난다. 상기 대칭행렬을 2, 3차원 상에서의 분석이 가능하도록 패턴인식에서 사용하는 맵핑 기법 중 하나인 principal component analysis를 이용하여 3차원 공간상으로 다음과 같이 1 차 맵핑을 하였다.

먼저 6x6 대칭행렬을 X 라 하고 각 행의 평균값 X_m 을 구한 후, 각 평균에 대한 분포값을 갖는 행렬 X_c 와 total scatter matrix를 구한다.

$$X_c = | X_{1j} - X_j^m \dots X_{6j} - X_j^m |, j=1-6$$

$$S[i,j] = X_c X_c', \text{ where } i, j=1-6 \quad (4)$$

여기서 투영된 모든 점들의 합이 최소가 되는 세 축

을 가정하면, 이 축들은 각 행의 평균벡터 X^m 을 통과하며 직각행렬 Q_1, Q_2, Q_3 에 의하여 정의된 각 축에 투영된 점들의 합은 다음 식과 같게 된다.

$$F(x) = \sum_{i=1}^6 s_{ii} - \sum_{j=1}^3 Q_j^T S Q_j \quad (5)$$

식 (5)의 최소값은 Q 가 고유벡터가 될 경우이므로, 최종 맵핑값은 식 (6)과 같다.

$$P_1'(X_{11} - X_1^m), \dots, P_1'(X_{16} - X_1^m)$$

$$P_2'(X_{21} - X_2^m), \dots, P_2'(X_{26} - X_2^m)$$

$$P_3'(X_{31} - X_3^m), \dots, P_3'(X_{36} - X_3^m) \quad (6)$$

식 (6)의 각 좌표는 Table 5의 지식베이스의 데이터를 3D 맵핑한 초기 값이므로, 그 오차를 최소화하기 위하여 불구속조건에서의 first-order method로 널리 알려진 Fig. 6의 steepest descent method의 최적화기법을 통하여 함수 최적화를 수행하였으며 그 결과를 Fig. 7에 보여주고 있다.

지식베이스의 3차원 공간상에서의 맵핑결과를 바탕으로 최종적으로 식 (7)과 같은 하나의 선형방정식으로 변환하기 위하여, Fig. 5에 제시한 바와 같이 N 개 변수를 가진 선형방정식의 해를 구하는 보편적인 방법인 simplex method를 통하여 지식베이스의 표준데이터를 최종적인 식 (7)의 선형방정식으로 변환하였다.

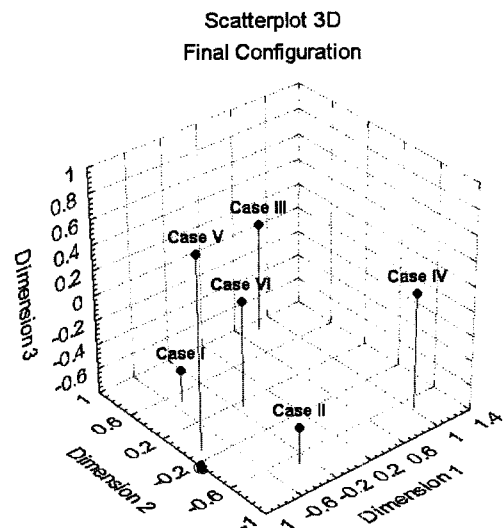


Fig. 7. Optimization result.

$$\begin{aligned}
 D_1 &= x_0 + x_1 * f_1 + x_2 * f_2 \dots\dots + x_{26} * f_{26} \\
 D_2 &= y_0 + y_1 * f_1 + y_2 * f_2 \dots\dots + y_{26} * f_{26} \\
 D_3 &= z_0 + z_1 * f_1 + z_2 * f_2 \dots\dots + z_{26} * f_{26}
 \end{aligned}
 \tag{7}$$

상기 방정식을 통하여 진단시점의 입력값인 f_1, f_{26} 에 따른 좌표 D_1, D_2, D_3 를 구한 후 6개의 좌표와의 거리를 계산함으로써 추론엔진이 수행된다.

4-3. Flexible Knowledge Base

전문가시스템의 지식베이스는 초기 구성시 전문가의 지식을 토대로 설정되기 때문에 대부분 고정적이어서 유연성을 가지기 어려운 단점을 가진다[5]. 본 연구에서는 대상 시스템의 이상 발생시 그 사고 데이터가 초기 지식베이스에 추가되어 향후 유사한 사건 발생시 보다 높은 진단결과를 갖게 하기 위해, 앞서 전문가에 의하여 설정된 표준코드를 간단한 피드-백 프로세스를 통하여 추가할 수 있는 ‘Knowledge-base Update Rule’을 사용하였다.

표준코드의 변경은 최종적으로 규명된 사건발생원인에 대한 가중치를 가함으로써 해당 시스템에서 발생할 수 있는 향후 유사한 사고에 대한 보다 높은 진단결과를 제시함을 원칙으로 하였다. Fig. 8에 제안된 알고리즘에서 보듯이, 하나의 입력에 대한 원인별 가중치의 합을 1로 유지하기 위해 Table 5의 output facts 사이의 상관관계를 이용하여 사고원인과 관련 없는 것에는 추가한 가중치를 반대로 가함으로써 업데이트가 수행된다.

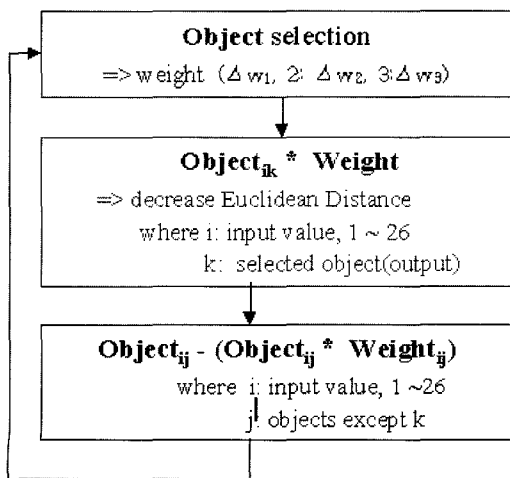


Fig. 8. Knowledge-based update rule.

5. 적용 예

대상시스템의 실제 사고발생 데이터를 기반으로 제안된 이상진단알고리즘을 적용하였다. 사고발생원인은 Fig. 3에서 압축기와 증속기 중동축의 축추력 사이의 균형이 깨어져 축방향 밀림방지를 위해 설치된 collar가 지속적으로 큰 축추력을 받은 것으로 추정되었으며 축어긋남에 의해 힘의 균형이 깨진 것으로 판명되었다 [11]. Fig. 9는 당시 파손된 collar를 보이고 있다.




Fig. 9. The broken collar element.




Fig. 10-(a). Vibration variation, Y160A, (b) Y161.




Fig. 11-(a). Temperature, T147., (b). temperature variation, T141.

당시 측정된 진단결과를 살펴보면, 우선 진동값 중 상대적으로 가장 높은 변화를 보였던 압축기 출력축 변위와 증속기 부위의 진동가속도(Fig. 10-(a),(b))를 운전이 중단된 시점 전까지 과거 약 1개월 동안의 측정 결과(하루동안 최고값 기준)를 보여주고 있다. 파손발생 시점 약 10일전에 측정값이 약간 감소하였다가 서서히 증가 또는 감소하였으나, 그래프에서 점선으로 표시된 관리기준치 이하로 현저하게 낮은 값을 보였다. 온도는 압축기 출력단과 스러스트 베어링에서의 측정 결과로 Fig. 11-(a),(b)에서 보듯이 관리치 이하로 낮게 운전되어 결과적으로 파손발생의 사전예측이 어려웠음을 알 수 있다. Fig. 12-(a),(b)는 같은 기간동안의 실시간 마멸량 측정시스템에서 측정된 대상시스템의 마멸량 변화추이를 보여주고 있다. 오일 내의 총마멸입자량(D_1) 및 상자성체 마멸입자량(D_2)의 결과들이 상호 유사한 경향을 보이고 있으며, 파손발생 25일 전에 초기징후가 나타나기 시작하여 특히 10일 전부터는 현저하게 증가된 측정결과를 나타내고 있다. 이 이외에도 오일 내 오염성분 및 물성치 변화를 살펴보기 위해 off-line 마모측정기기인 PQ, ICP, dCA 등을 통해 통




Fig. 12-(a). Total contamination (D_1), (b) (D_2).

Table 7. Diagnosis result

System: Air-turbo-compressor #9	Probability
Root cause 1: Gear wear/failure	88.4%
Root cause 2: Oil Starvation	56.1%
Root cause 3: BRs wear/failure	44.8%

합상태진단에 필요한 입력값들을 측정하였다.

상기 측정결과들을 바탕으로 26개 입력값 중 24개의 측정값이 진단알고리즘에 입력되었으며, 그 진단결과를 Table 7에 나타내고 있다. 수행결과 실제 사고발생원인에 매우 근접한 진단결과를 보여줌으로써 본 연구에서 제안한 통합진단알고리즘의 적용이 전반적으로 타당함을 확인할 수 있었다.

완성된 통합상태진단 프로그램의 구현은 Visual C++ 6.0을 사용하였으며, 일차적으로 각 측정값들의 관리기준치에 대한 비교에 의하여 시스템의 경보를 행하고, 이차적으로 다수의 측정값으로부터 시스템 상태에 관한 진단을 행한다. 진단 알고리즘의 추론엔진에 사용되는 측정값들인 마멸, 온도, 진동 및 오일물성치 등의 데이터는 측정값별로 DB 기반으로 저장 및 관리되며

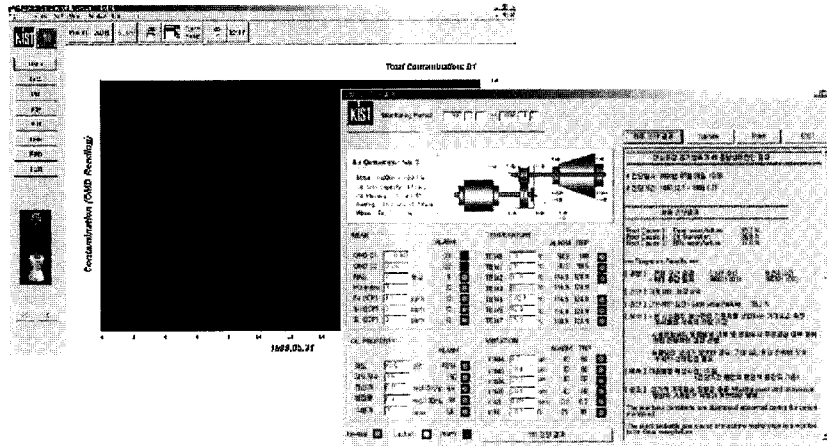


Fig. 13. User interface: diagnosis module in software.

지식베이스의 표준코드 및 추론엔진을 내부에 내장하고 있다. Fig. 13는 상기의 통합상태진단 소프트웨어와 진단모듈 화면의 예이다.

6. 결 론

본 연구에서는 기존의 개별적인 기계상태진단기술에 따른 진단알고리즘이 아닌 다양한 통합상태진단기술의 적용시 활용될 수 있는 진단알고리즘을 구현하였으며 그 결과를 살펴보면 다음과 같다.

첫째, 통합상태진단기술의 여러 특성에 따라 다양한 진단알고리즘을 살펴본 결과, 기존의 생성규칙에 따른 지식베이스가 아닌 수학, 통계적 추론기법의 활용이 가능한 수치기반의 지식베이스 기반의 전문가시스템이 가장 적합한 것으로 평가되었다.

둘째, 패턴인식의 맵핑기법을 기반으로 한 일련의 추론엔진을 구성하였으며, 실제 가동중인 대형 공기 압축기시스템을 대상으로 본 전문가시스템을 구현하였다.

셋째, 이상진단분야의 전문가시스템 적용시 단점으로 꼽히는 지식베이스 유연성 부족을 극복하며 이상 발생데이터의 축적을 통한 유사사고에 대한 높은 진단결과를 제시하기 위해 지식베이스 추가모듈을 사용하였다.

넷째, 구현한 진단알고리즘을 손쉽게 수행할 수 있는 소프트웨어를 개발하였으며, 대상 시스템의 실제 사고발생 데이터를 기반으로 프로그램을 수행한 결과에서 제안된 알고리즘의 타당성을 확인할 수 있었다.

참고문헌

1. Williams, Davies and Drakes, "Condition-based Maintenance and Machine Diagnostics," Chapman & Hall, 1994.
2. B.K.N. RAO, "Handbook of Condition Monitoring," Elsevier Advanced Technology, 1996.
3. Zhang A. H, "Monitoring and Diagnostic Technique for Mechatronic Equipment," Publishing House of Northwest University of Technology, 1995.
4. Chin-Teng Lin & C.S George Lee, "Neural Fuzzy Systems," Prentice-hall, 1996.
5. David W. Rolston, "Principles of Artificial and Expert System Development," McGraw-Hill, 1988.
6. Alexandru. A, "A Knowledge-based Approach for Fault Diagnosis and its Application," Proceedings of the 11th International Conference on COMADEM, Vol. 1, pp. 11-20, 1998.
7. 양보석, 전순기, 김호중, "퍼지이론을 이용한 회전기계의 진동진단법," 대한기계학회, Vol. 20, No. 5, pp.1411-1418, 1996.
8. 박홍식, 조연상, "기계구동계의 손상상태 모니터링을 위한 신경회로망의 적용," 한국윤활학회지, Vol. 14, pp.74-80, 1998.
9. 유송민, 김영진, "가공공정의 이상상태 진단을 위한 진단전문가시스템의 개발," 한국정밀공학학회지, Vol. 14, pp.147-153, 1997.
10. Hu W, Wang W. and Mathew J, "Machine Fault Diagnosis by Integrating Neural Network and Expert System," Proceedings of the 11th International Conference on COMADEM, Vol. 1, pp. 415-422, 1998.
11. Hosung Kong, Eui-Sung Yoon, Oh-Kwan Kwon, Jae-Soo Song, Hyoung-Sub Um, L.V.Markova, N.K.Myshkin, "Case Study of Wear Monitoring of a

- High-Duty Air-Compressor System by Using an On-line Opto-Magnetic Detector,” Proceedings of the 11th International Conference on COMADEM, Vol. 2, pp. 511-518, 1998.
12. 윤의성, 장래혁, 공호성, 한홍구, 권오관, 송재수, 김재덕, 엄형섭, “마모발생의 통합분석을 통한 대형기계윤활시스템의 상태진단기술 적용,” 한국윤활학회지, Vol. 14, pp.75-81, 1998.
 13. 장래혁, 윤의성, 공호성, A.Ya.Grigoriev, “임자유형별 형상추출에 의한 마모입자 자동인식에 관한 연구,” 한국윤활학회지, Vol.15, No.2, pp.205-211, 1999.