



저작자표시 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.
- 이차적 저작물을 작성할 수 있습니다.
- 이 저작물을 영리 목적으로 이용할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#) 

공학 석사 학위 논문

무선 센서를 이용한 기계 건강 진단
및 예지를 위한 통합 소프트웨어



2011년 2월

부경대학교 대학원

메카트로닉스공학과

오준석

공학석사 학위논문

무선 센서를 이용한 기계 건강 진단
및 예지를 위한 통합 소프트웨어



지도교수 양보석

이 논문을 공학석사 학위논문으로 제출함.

2011년 2월

부경대학교 대학원

메카트로닉스공학과

오준석

오준석의 공학석사 학위논문을 인준함

2010년 12월



주	심	공학박사	김 선 진
위	원	공학박사	양 보 석
위	원	공학박사	손 종 덕



목 차

I. 서 론	1
1.1 연구 배경	1
1.2 연구 목적	2
1.3 연구 내용	2
II. 무선 센서 시스템	4
2.1 무선 센서 시스템 구성 하드웨어	4
2.2 무선 CBM의 구조	6
III. 이 론	7
3.1 사용된 알고리즘	7
3.2 배경 이론	7
3.2.1 데이터 처리	7
3.2.2 모니터링	18
3.2.3 진단	25
3.2.4 예지	32
IV. 개발 소프트웨어	35
4.1 인터페이스 구성	35
4.2 소프트웨어 흐름도	36
V. 실험 및 결과	38
5.1 실험	38
5.2 결과	41
5.2.1 데이터 처리	41
5.2.2 특징 모니터링	48
5.2.3 진단 및 예지 모듈	52
VI. 결론	56
참고 문헌	57

An Integrated Software for Machine Diagnostics and Prognostics using Wireless Sensors

Jun-Seok Oh

Department of Mechanical Engineering, The Graduate School,
Pukyong National University

Abstract

This study presents integrated software for machine health diagnostics and prognostics based on measured signals using wireless unit sensors which have been developed in previous work. This software consists of four modules sequentially: data processing, data analysis and condition monitoring, diagnostics, and prognostics. Each module has its detailed function to identify faults from hidden signals. The algorithms which are used these diagnostics and prognostics modules have been developed and estimated from our studies in the recent time. In diagnostic algorithm, 5 classifier machines are combined for accurate decision of machine diagnosis. Additionally, some methods utilized to feature representation, feature selection, feature extraction, etc are also introduced in this study. The aim of developed software is to offer useful information and propose one of solutions for practical problems. In order to verify, two different data are used in this software, which are K-Water system pump data and 7 kinds of faulty simulated data. The results indicate that the software could be used as a reliability tool to real application.

제 I 장 서론

1.1 연구 배경

기존의 유선 센서시스템은 안정적이고 신뢰성 있는 데이터를 취득할 수 있는 장점이 있으나, 시스템 구성을 위해 많은 장비들이 필요하고 이들을 연결하는 방대한 케이블링 작업으로 상당한 추가 비용이 요구되며 이를 유지·관리하기 위해 사용되는 비용 또한 적지 않은 부분을 차지하고 있다. 또한 환경적 공간적 제약으로 인해 신호를 계측하는데 소요되는 시간이 많아지며 이는 곧 진동 분석 및 문제 해결에 어려움으로 이어지게 된다.

무선 센서 시스템은 한정된 영역에 존재하는 많은 수의 센서로부터 진동신호를 계측해서 중앙의 수신부(receiver)로 무선 전송하는 시스템을 말한다. 이 시스템의 장점은 첫째, 계측 위치의 제약이 있는 기존의 유선 센서 시스템과는 달리 실제 사람이 직접 계측하기 어려운 곳이나 위험한 지역에 위치하여 원격지에서 필요로 한 정보를 수집할 수 있다. 둘째, 불필요한 케이블링 작업을 간소화함으로써 시간적, 비용적 측면을 개선하는 이점을 가진다. 특히 최근 들어 무선 센서시스템 [1]은 기계 상태감시나 진동 등의 신호를 계측하고자 하는 다양한 분야에 폭 넓게 응용되고 있다. 이러한 다양한 이점을 토대로 상태 감시 시스템이나 기계 건강 진단·예지 시스템을 무선 센서 시스템과 통합하여 기계를 체계적으로 유지보수 하고자하는 노력이 많이 이루어지고 있다.

유지보수는 제품의 신뢰성과 관련한 중요한 요소로, 제품의 가동기간 동안 만족스러운 신뢰성 레벨을 확보하는 효율적 방법으로 알려져 있다. 아무리 잘 설계된 제품이라 하더라도 실제 산업 환경의 가혹한 부하조건에서 지속적으로 운전되다보면 시간이 지날수록 성능이 저하되기 마련이다. 이러한 이유로 정비 전략에 대한 중요성이 점차 높아지고 있으며, 특히 기계의 상태를 기반으로 정비 전략을 수립하는 CBM(condition based maintenance)에 대한 연구가 활발하게 진행되어 오고 있다 [2-3]. 특히 CBM에 있어 가장 핵심이 되는 부분은 바로 기계의 상태 진단 및 예지에 대한 정확하고 충실한 정보를 획득하는 것이며, 이러한 정보를 토대로 주요 부품 또는 전체 시스템의 정비 주기를 결정

하고 예측 결과에 따라 정비 일정을 계획하게 된다. 이러한 이유로 최근 연구실에서 개발된 강력한 진단 및 예지 알고리즘을 통합하여 좀 더 신뢰할 수 있고 좀 더 합리적인 결과를 도출 할 수 있는 통합 소프트웨어를 개발하고자 본 연구를 수행하게 되었다.

1.2 연구 목적

최근 기계 건강상태의 진단과 예지에 대한 연구뿐만 아니라 이를 실제 현장에 효율적으로 적용하기 위한 여러 소프트웨어 및 하드웨어들이 개발되고 있다 [4-6]. 특히 기계 설비를 효율적으로 통합 관리하기 위해 LAN(local area network)이나 인터넷 [7] 을 통해 관리 시스템을 구축하고자 하는 노력이 많아지고 있으며 신호를 분석하고 기계 건강상태를 진단하며 향후 상태를 예지하기 위한 설비 관리용 통합 소프트웨어의 개발에 대한 요구도 높아지고 있다.

본 연구에서는 이러한 흐름에 맞추어 무선망(wireless network) 통신을 이용한 무선 센서 계측 시스템을 도입하였으며, 이를 바탕으로 계측된 신호를 분석 관리하기 위한 통합 소프트웨어를 개발함으로써 효율적 설비 관리를 위한 무선 CBM 시스템을 구축하는데 그 첫 번째 목적이 있다.

또한 CBM의 가장 핵심이 되는 기계 상태 진단 및 예지에 대해 다양한 신호처리 및 개발 알고리즘을 시도하여, 추출하고자하는 정보의 정확성과 신뢰성을 높이고 이를 실제 현장 시스템에 적용함으로써 설비 관리자에게 보다 실질적이고 유용한 정보를 최종적으로 제공하는 것이 두 번째 목적이라 할 수 있다.

1.3 연구 내용

본 연구에서는 주로 알고리즘을 통합하여 기계 건강 진단 및 예지를 위한 효율적인 소프트웨어를 구성하는데 많은 노력을 기울였다. 개발된 알고리즘의 대부분의 경우 입력되는 데이터가 명확할수록 알고리즘의 성능도 향상된다. 그러므로 입력 데이터에 대해 RMS(root mean square) 경향관리, 차수비 분석(order ratio analysis), 협대역 모니터링(narrow band monitoring), GMF(gear mesh

frequency) 탐지, 베어링 결함 주파수 탐지, FFT(fast furrier transform), Water-fall 과 같은 다양한 신호 처리 기법을 적용하여 알고리즘에 입력되기 전에 적절한 데이터를 추출하고 이를 알고리즘에 사용함으로써 개발 소프트웨어의 성능을 높이고자 하였다.

또한 소프트웨어를 모듈(module)로 구성함으로써 소프트웨어의 운영 효율을 높이고, 대상 기계에 따라 데이터 처리 순서를 달리함으로써 결함진단의 유연성을 높여 다양한 기계에 대한 적응이 쉽도록 구성하였다.

진단 모듈에서는 4가지 특징 추출 기법을 사용하여 가장 좋은 성능의 추출 기법으로부터 추출된 데이터를 진단 분류기의 학습데이터로 사용하였으며, 동일한 데이터에 대해 5 가지 분류기(classifier)의 결과를 동시에 확인함으로써 분류 결과에 대한 신뢰성을 확보하고자 하였다.

개발 소프트웨어의 성능을 검증하기 위해 2가지의 데이터가 이용되었으며, 첫째는 한국수자원공사의 원동취수장에 설치된 MEMS(micro electro mechanical systems) 기반의 센서를 통해 계측된 데이터를 이용하였고, 두 번째는 7 종류의 모의 모터 결함 데이터를 이용하여 수행하였다.

본 논문의 구성은 제 II장에서는 무선 센서 유닛의 개략적 구성과 이를 통합한 무선 CBM 시스템에 대해 설명하였으며, 제 III장에서는 소프트웨어 각 모듈에 대한 간략한 설명과 더불어 사용된 알고리즘에 대한 이론적 배경을 설명하였다. 제 IV장에서는 개발 소프트웨어의 전체 인터페이스(interface)를 소개하고 소프트웨어의 흐름도(flowchart)에 대해 설명하였다. 제 V장에서는 한국수자원공사 원동취수장의 펌프 시스템으로부터 무선 센서 유닛을 통해 계측된 실제 데이터를 적용한 사례와, 개발 소프트웨어의 진단 및 예지 모듈을 검증하기 위해 7가지 모터 모의 결함으로부터 취득한 데이터를 적용한 사례에 대한 결과를 제시하였으며, 마지막으로 제 VI장에서 본 연구의 주요 내용을 요약하고 결론으로 정리하였다.

제II장 무선 센서 시스템

2.1 무선 센서 시스템 구성 하드웨어

무선 센서 시스템의 하드웨어는 크게 무선 베이스 스테이션(base station), 무선 유닛(wireless unit), 센서(sensor) 3가지로 나눌 수 있다. 무선 베이스 스테이션은 우리가 쉽게 접하게 되는 개인 데스크탑 PC나 노트북 등 무선 유닛과 통신을 하여 데이터를 수신하게 된다.

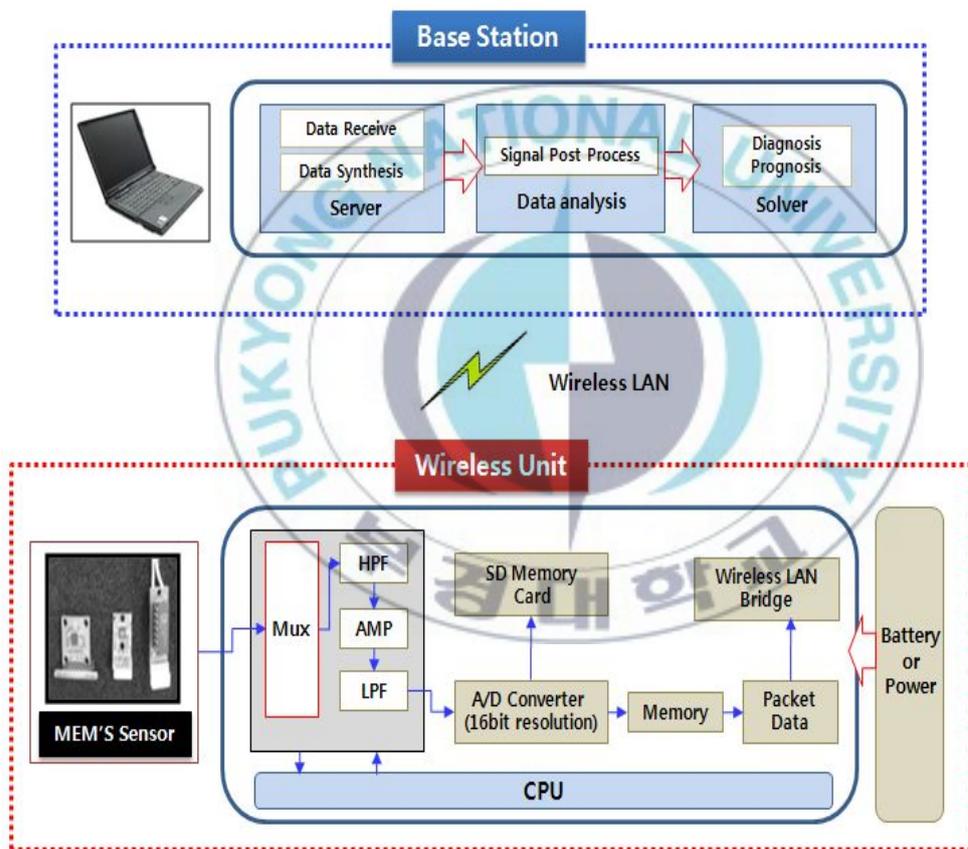


Fig. 2.1 The configuration of wireless unit hardware

무선 유닛은 무선 센서 시스템의 가장 중요한 하드웨어로써 Fig. 2.1에 보이는 가장 하위단인 MEMS 센서로부터 취득된 데이터를 취합하여, 무선 통신망을 통해 무선 베이스 스테이션으로 데이터를 송신하게 된다. 무선 유닛은 8채널 즉, 8개의 센서로부터 데이터를 받을 수 있으며 진동 4채널, 전류 3채널, 온도 1채널로 구성되어 있다. 무선 유닛으로 취득된 아날로그 신호는 고역 통과 필터(high pass filter) 및 저역 통과 필터(low pass filter)를 통과하면서 분석시에 노이즈(noise) 신호를 일차적으로 걸러 준다. 그 후 A/D 컨버터를 통과함으로써 아날로그 신호를 디지털 신호로 변환하게 되며 이때 데이터는 주파수 변환 이론에 따라 초당 2^{13} 개인 8192개의 데이터를 샘플링 하게되며 이때 분석 가능한 주파수 범위는 최대 0~4000Hz가 된다.

8개의 채널로부터 순차적으로 얻어진 데이터는 일시적으로 외부 메모리에 저장 되었다가 최종 무선 베이스 스테이션으로 보내진다. 센서는 Fig. 2.1와 같이 MEMS 센서 기반으로 기존의 센서에 비해 가격 경쟁력이 상당히 높고 22kHz의 주파수 응답 특성을 제공하고 있어 상태감시에 적합한 환경을 가지고 있다. 무선 센서 유닛의 상세 사양 Table 2.1과 같다 [8-9].

Table 2.1 The specification of wireless unit

Item	Function
Input range	±2.5V
Supply voltage	5V
Operation temp.	-25~60°C
Sensor type	MEMS(acceleration, current, temp.)
A/D resolution	16 bit/channel
Bandwidth	0~4000Hz
Data transfer	WLAN(TCP/IP)

2.2 무선 CBM의 구조

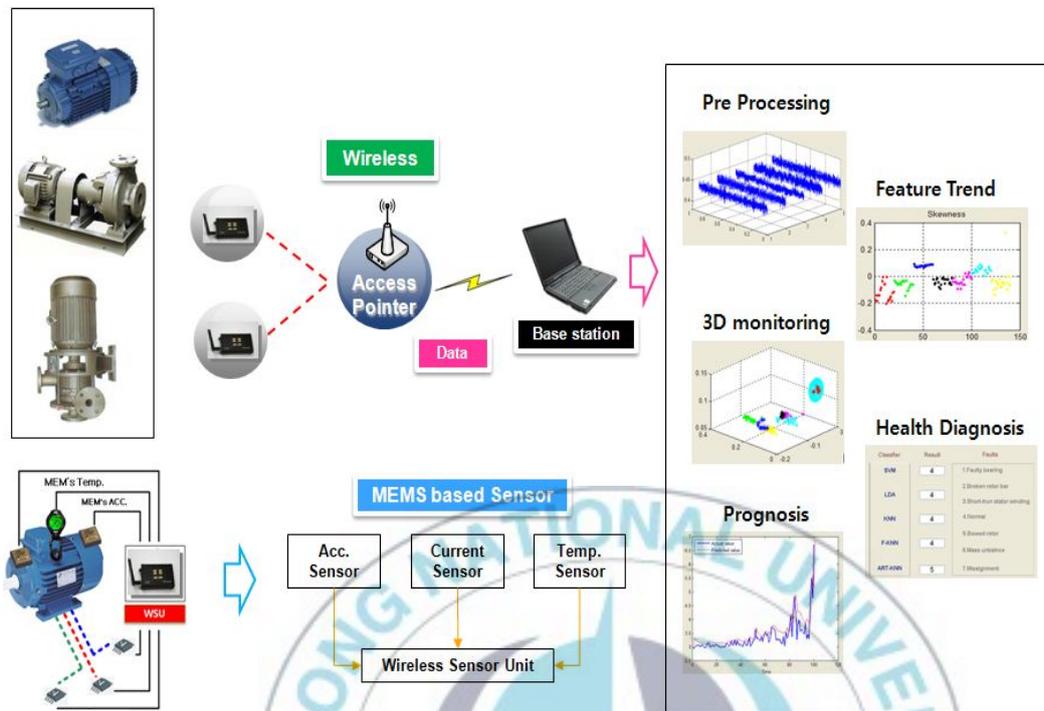


Fig. 2.2 The configuration of wireless CBM

대상 기계에 MEMS 기반의 센서를 부착하게 되며, 센서를 통해 취득된 진동, 전류, 온도 신호는 무선 센서 유닛으로 일시 저장된다. 저장된 데이터는 베이스 스테이션으로 전송되는데 이때 구축된 무선망이 특정한 환경 조건으로 인해 방해가 받게 되는 경우에는 AP(access point)를 사용함으로써 원활한 통신 환경을 구축할 수 있다. 베이스 스테이션으로 전송된 데이터는 개발 소프트웨어를 통해 데이터 신호 처리가 수행되며, 결함 징후가 발견되면 탑재되어 있는 진단 및 예지 알고리즘을 통해 기계 건강 상태를 최종 점검받게 된다.

제 Ⅲ 장 이 론

3.1 사용된 알고리즘

개발 소프트웨어는 크게 4개의 처리과정으로 이루어져 있으며, 이를 각각 모듈로 표시하고 독립적으로 운영이 가능하도록 구성하였다. Table 3.1에는 소프트웨어의 각 모듈에서 사용된 신호 처리기법 및 알고리즘을 표로 나타내었으며 본 장을 통해 사용된 기법들에 대한 배경 이론들을 간략하게 소개하고 개발 소프트웨어를 통해 구현하고자 했던 목적에 대해 설명하고자 한다.

Table 3.1 The used algorithms of each module

Module	Algorithm
Preprocessing	Time seires, FFT-Waterfall Band monitoring, Order monitoring Bearing fault, Gear fault
Monitoring	PCA, ICA, KPCA, KICA
Diagnosis	LDA, SVM, KNN, F-KNN, ART-KNN, Case based
Prognosis	ARMA-GARCH

3.2 배경 이론

3.2.1 데이터 처리

1) Time Series, FFT-Waterfall

Time Series 는 시간의 경과에 따라 일정한 간격으로 샘플링된 시간 신호의 데이터를 3차원으로 적층하듯이 시간 순으로 나열해서 관찰하는 기법이다. 분석적인 방법이라기보다는 한 눈에 쉽게 시간 데이터 간 비교가 가능하므로 데이터 처리의 첫 단계라 할 수 있으며 실제 개발 소프트웨어에서도 가장 먼저 수행된다. 이는 다음과 같은 충격 신호 비트(beat) 현상, 큰 폭으로 변하는 변동 성분, 진폭 크기 변화 등과 같이 직관적인 신호를 정상 상태의 신호와 비

교 할 때 유용한 방법을 제공한다. Fig. 3.1과 3.2를 통해 확인할 수 있다.

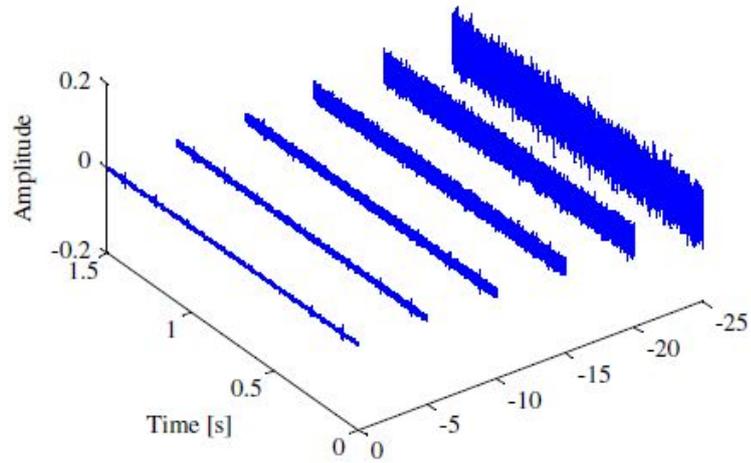


Fig. 3.1 The observable variation of amplitude in time series function

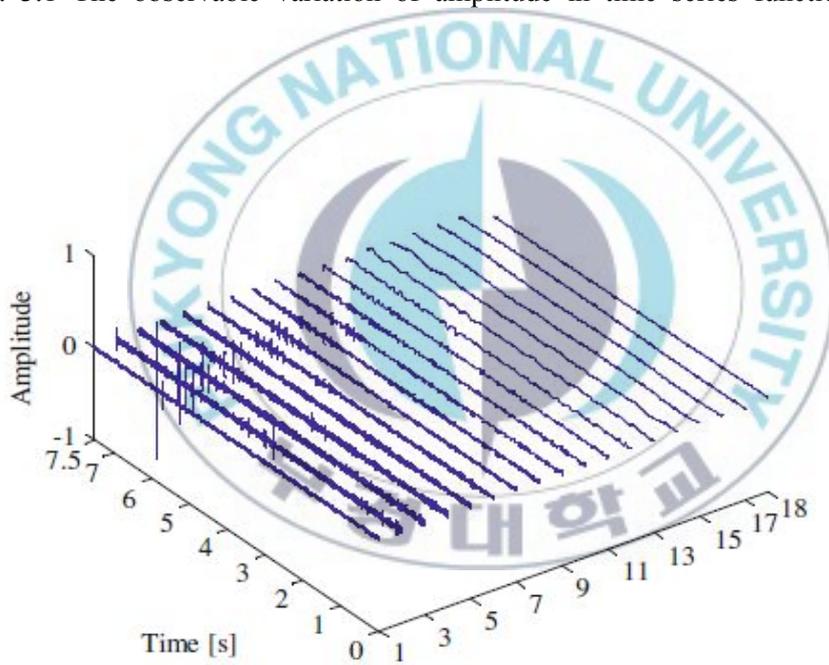


Fig. 3.2 The beat signal observed by time series function

FFT-Waterfall 기법은 FFT의 스펙트럼을 이용한 방법으로 폭포 스펙트럼 선도라고 한다. 이 방법은 시간에 따라 스펙트럼을 시간 순으로 전개하는 방법이다. 방법의 이점은 전체 주파수를 동시에 관찰 할 수 있으며, 주파수 위치별 변화를 쉽게 확인 할 수 있다는 점이다. 기본적으로 시간 데이터 기반이 아닌 주파수로 변환된 데이터를 사용하므로 주파수의 정보를 포함하고 있어 Time Series 보다 좀 더 폭 넓은 정보를 표현하는 장점이 있다 [10].

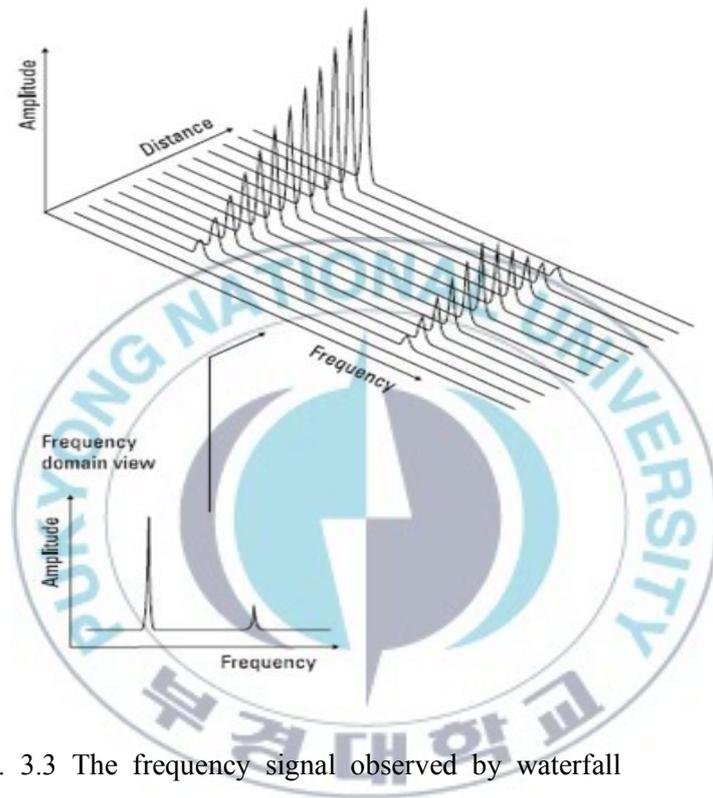


Fig. 3.3 The frequency signal observed by waterfall

회전기계에 있어서 진동은 필연적 현상으로 일정부분의 주파수가 관측되는 것은 당연한 결과이다. 하지만 시간이 경과함에 따라 기계의 성능이 저하되며 이와 함께 결함은 서서히 진전하게 된다. 이때 특정 주파수의 진폭 크기는 폭포 스펙트럼 선도에서 상승하게 되며 이는 주파수의 위치 정보와 함께 시간 정보, 크기 정보를 동시에 제공한다.

2) 협대역 모니터링

이 기법은 협대역 진동 경향 감시라고하며 일정 크기의 주파수 대역을 설정하고 이에 대한 경향을 대역 단위로 관리하는 기법을 말한다. 협대역을 설정할 때에는 대상 기계에 대한 정확한 이해가 선행되어야 한다. 무엇보다 대상 기계에서 발생 할 수 있는 결함 주파수에 대한 정의가 선행되어야 한다. 정의된 정보를 기반으로 결함 주파수를 포함하는 일정 범위의 주파수 대역을 협대역으로 설정할 수 있다. 예를 들어, 기어 결함 주파수인 기어 맞물림 주파수 (gear mesh frequency: 기어 이수 \times 운전속도 주파수)가 대략 3000Hz에서 발견되었다면 협대역은 10Hz를 대역폭으로 설정하여 2990~3010Hz를 GMF 대역으로 설정하고 이 대역에 대한 경향을 감시하게 되는 것이다.

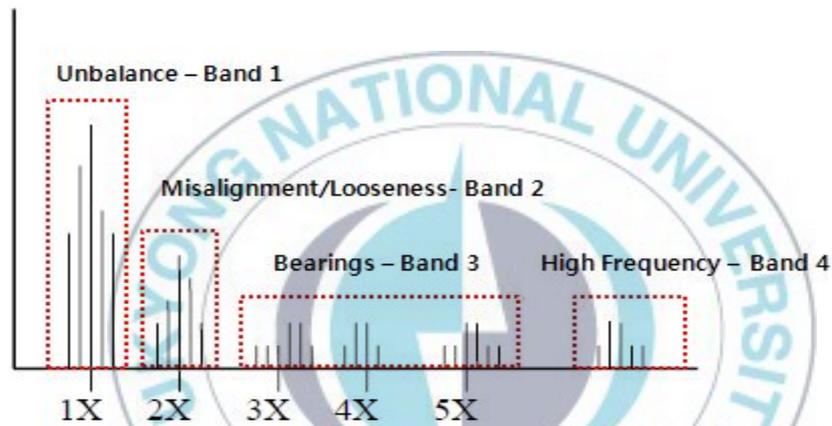


Fig. 3.4 The concept of band monitoring

일반적으로 협대역 경향 감시에서는 각 대역에서의 총 RMS 또는 최대 진폭의 경향을 경고 한계치와 비교하여 감시한다. 여기서 경고 한계치는 진동 스펙트럼의 성분 크기를 파악하고, 이들 값에 일률적으로 2배 또는 3배등으로 설정하거나, 각 밴드의 평균 이상의 2.5~2.8의 표준 편차를 설정하는 방법이 통상이다 [11].

실제 현장에서 계측되는 데이터에 대해 주파수 분석을 해보면 결함 주파수를 손쉽게 판별하는 것이 거의 불가능해 보일 정도로 조밀하게 또는 특정 주파수가 아닌 특정 구간의 주파수들이 군을 이루어 발생하는 경우가 많다. 협대역 경향 분석은 이러한 복잡한 신호 형태로부터 대역을 Fig. 3.4와 같이 결함이 발생하는 주요 주파수 대역을 각 부품에 맞는 범위의 구획으로 나누어 각 부품에 대한 열화 경향을 개별적으로 세분화하여 관리 할 수 있다는 이점이 있다. 즉, 대상 기계에서 발생하는 결함 이력이 어느 정도 정형화 되어있어 특정 부품에서 결함이 빈번히 발생하는 것을 사전에 이미 알고 있다면, 그 부품에 대한 협대역 경향을 감시함으로써 결함을 조기 탐지하고 그에 맞는 적절한 조치를 취할 수 있는 것이다. 하지만 대상 기계에 대한 정보를 면밀히 살피고 어느 정도 결함 주파수에 대한 정의와 이를 이해할 수 있는 사전 지식이 일정 부분 요구된다는 점에서 다소 어려움을 가지고 있다.

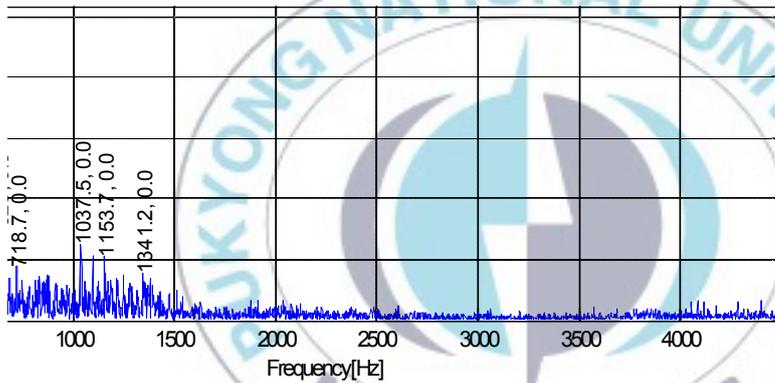


Fig. 3.5 The actual signal of vibration acquired from real field

3) 차수비 분석

본 기법은 기존의 차수비 분석(order ratio analysis)에서 착안된 방법으로 차수비 분석은 가로축에 회전주파수를 기준으로 진동 발생 주파수와의 비를 표시하고, 세로축에 진폭을 나타내는 분석 기법이다. 회전기에 있어 회전 주파수는 주파수 분석 시에 가장 중요한 요소로 회전속도의 특정 배수 성분이 결함 주파수로 검출되는 사례가 빈번하다. 이는 물리적으로도 회전 기계 부품에

서 발생하는 결함은 회전주파수의 주기로 반복적인 외력 즉, 가진력을 받게 되므로 회전주파수의 조화성분으로 주파수 선도 상에 표현되어진다. 그러므로 회전 주파수의 차수 즉, 배수 성분들은 보다 많은 결함 정보를 내포하고 있으며, 이에 대한 정확한 분석만으로도 일부 특정 결함들에 대한 진단이 가능해진다. 본 논문에서 제안하고자 하는 차수비 기법은 차수비 분석과 RMS 성분을 함께 분석하는 것을 말한다. 우선 RMS는 실효치라고 하며 이를 이용하여 전체 진동신호 크기의 경향을 파악하는 기준데이터로 사용된다. RMS는 식 (3.1)로 정의된다.

$$\text{RMS} = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt} \quad x: \text{피크 진폭}, T: \text{주요 성분 개수} \quad (3.1)$$

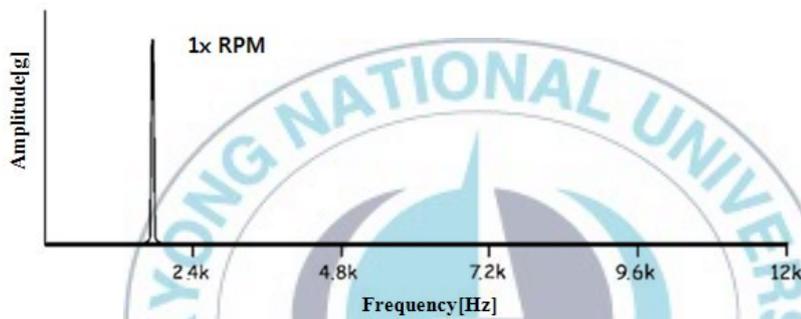
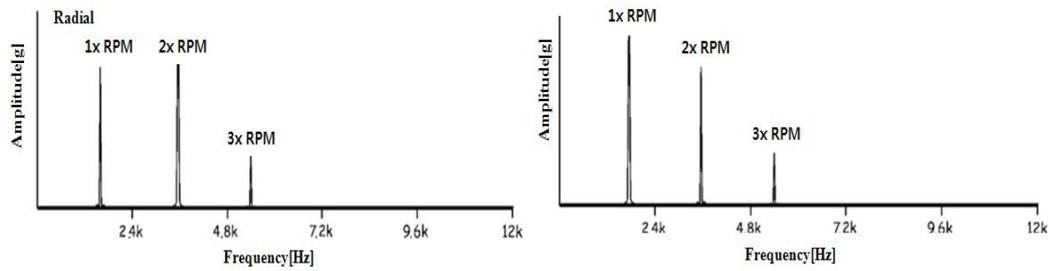
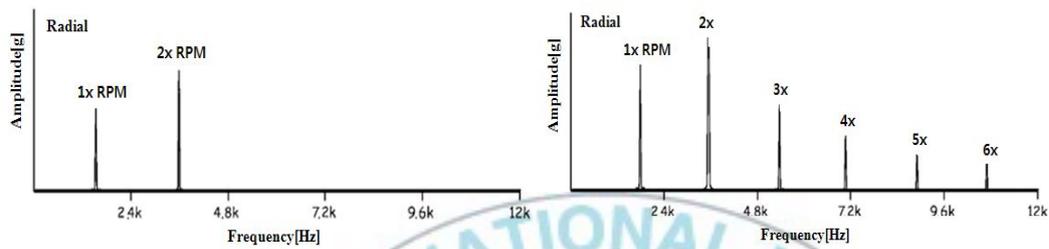


Fig. 3.6 Vibration component caused by unbalance

RMS를 통해 신호의 상태 변화에 따른 전체적인 경향을 확인하여 높은 변동량이 발견되면, 회전주파수의 차수 성분에 따른 주파수 변화를 관찰한다. 기본적으로 회전주파수인 1X성분이 다른 차수에 비해 탁월하게 크게 평가된다면 이는 질량불평형에서 기인한 결함으로 간주 되며, Fig. 3.6과 같이 주파수 영역에서 회전주파수 1X 성분이 과대하게 관측되는 것을 알 수 있다. 또한 일반적으로 기계결함은 회전주파수의 배수 성분을 많이 발생시키는데 이는 앞서 언급했듯이 회전주파수가 가진력으로 작용하는 이유에 기인한다고 할 수 있다. 그러므로 회전주파수의 배수 성분을 분석하는 것은 결함을 규명하는데 중요한 정보가 되며, Fig. 3.7과 같이 다양한 결함에서 실제 회전주파수의 배수 성분으로 나타나는 것을 알 수 있다 [12].



(a) Offset misalignment, (b) Angular misalignment



(a) Structure looseness, (b) Bearing looseness

Fig. 3.7 The variety of fault cases

3) Bearing fault detection

구름 요소 베어링에 대한 결함은 그 종류와 원인 및 결함 진행 단계에서 부터 대책까지 많은 부분이 이미 충분한 문헌을 통해 연구되어져 왔다 [13]. 구름 요소 베어링에서는 베어링 형상과 운전 속도에 따라 결정되는 특이한 베어링 특징 주파수 5가지가 검출되며, 이는 다음 수식으로 명확히 표현되어 진다 [14-15].

- 내륜의 회전 주파수:

$$f_r = \frac{rpm}{60} \quad (3.2)$$

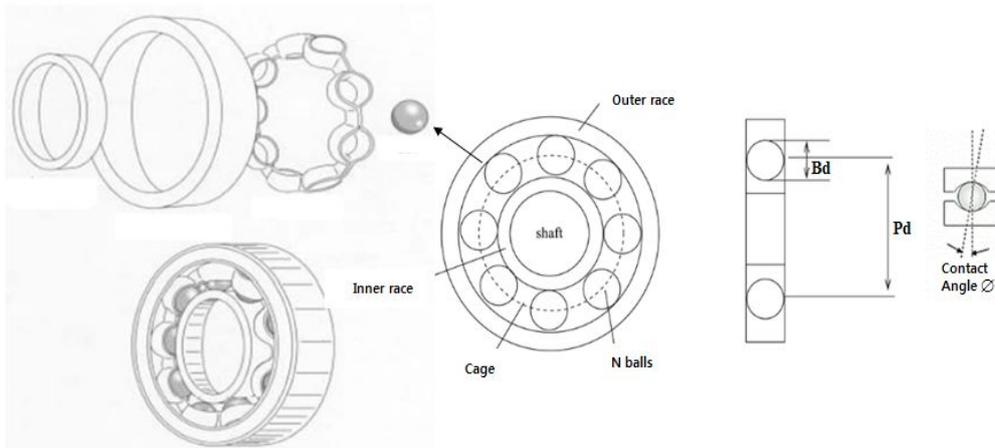


Fig. 3.8 The configuration of bearing

- 기본 열 주파수(fundamental train frequency, FTF), 케이지 주파수:

$$FTF = f_c = \frac{f_r}{2} \left[1 - \frac{Bd}{Pd} \cos \varnothing \right] \quad (3.3)$$

- 볼 자전 주파수(ball spin frequency, BSF):

$$BSF = f_s = \frac{Pd}{2Bd} f_r \left[1 - \left(\frac{Bd}{Pd} \right)^2 \cos \varnothing \right] \quad (3.4)$$

- 외륜 통과 주파수(ball pass frequency of outer race, BPFO) :

$$BPFO = f_o = N(FTF) = \frac{f_r}{2} N \left[1 - \frac{Bd}{Pd} \cos \varnothing \right] \quad (3.5)$$

- 내륜 통과 주파수(ball pass frequency of inner race, BPFi) :

$$BPFi = f_i = N(f_r - FTF) = \frac{f_r}{2} N \left[1 + \frac{Bd}{Pd} \cos \phi \right] \quad (3.6)$$

예로, 900rpm으로 회전하는 Fahnir사의 Model 7209베어링은 결합 주파수가 Table 3.2과 같이 계산된다.

Table 3.2 The result of bearing fault frequency

Fault type	1X frequency	2X frequency	3X frequency	4X frequency
BPFi	122.370	224.740	367.110	489.480
BPFO	87.240	174.480	261.720	348.960
BSF	37.290	74.580	111.870	149.160
FTF	6.225	12.450	18.675	24.900

명확한 이론을 바탕으로 베어링 제조사들은 자사 제품에 대한 베어링 형상 정보와 더불어 베어링 결합 주파수에 대한 정보를 함께 제공하는데 이러한 주파수 정보를 수집하여 데이터베이스화한 자료가 개발 소프트웨어의 기능 구현에 바탕이 되었다.

4) 기어 결합 탐지

기어 박스(gear box)는 원동기의 속력이나 회전력을 증감하기 위해 기어를 이용해 회전수를 가변시키는 동력전달 장치이다. 기어 박스는 운전 중에는 구동 기어와 피동기어가 연속적으로 맞물려 회전하게 되는데 이때 기어 시스템에서는 가장 기본적으로 측대역파(side band)를 가진 GMF가 발생한다 [16-17]. 기어 맞물림 주파수는 기어 이(teeth)의 수 Z와 회전 속도 N의 곱으로서 다음 식과 같이 표현할 수 있다.

$$f_m = \frac{N}{60} \times Z \quad (3.7)$$

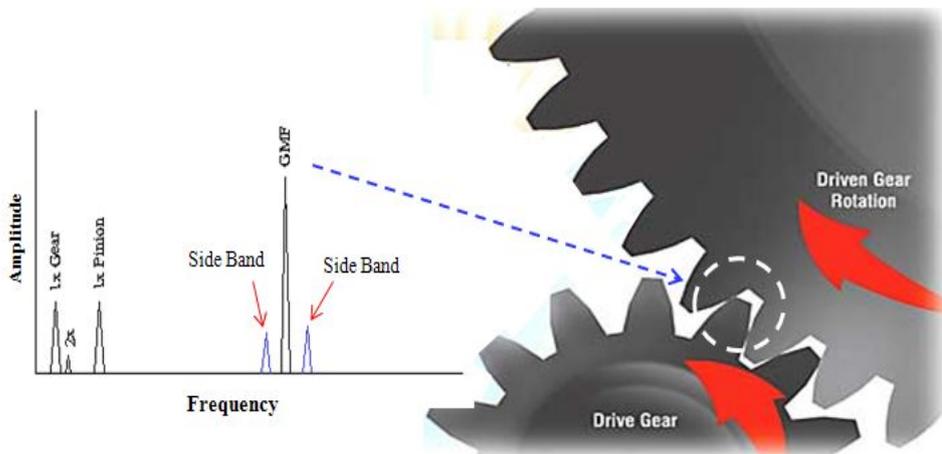


Fig. 3.9 The generation of gear mesh frequency

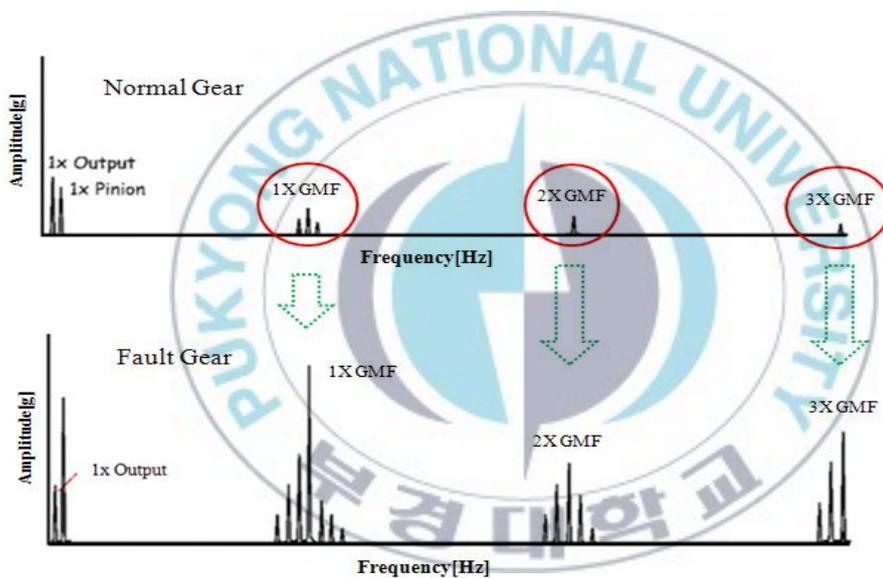


Fig. 3.10 Difference between normal and fault condition

측대역파는 기어 맞물림 주파수를 중심으로 회전주파수 합차만큼의 폭으로 발생하는 특징을 가지고 있다. 구동기어와 피동기어는 연속적으로 맞물려 회전하므로, 정상상태인 두 기어의 기어 맞물림 주파수는 같아야한다. 하지만, 기어 표면에 결함이 발생하게 되면 기어 맞물림 주파수와 더불어 기어 맞물림

주파수의 2차, 3차인 조화 성분들이 함께 발생하게 되는데 이때 특히 2차 조화 성분이 1차, 3차 조화 성분보다 상대적으로 큰 진폭을 가진다면, 이는 기어에 과도한 백래쉬(backlash)가 존재하거나 기어 이중에 하나가 진동을 하는 것을 의미한다.

백래쉬란 서로 물린 한 쌍의 기어에서 각 잇 면 사이의 간격, 혹은 기어를 반대방향으로 돌릴 때 기어이 사이의 공간에 의해 기어가 약간 헛도는 현상을 말한다. 이상적인 기어에서는 백래쉬가 없지만 실제 기어에서는 가공상의 오차, 조립상의 오차에 의해 백래쉬가 발생한다. 과도한 백래쉬가 발생하면 GMF사이의 배수 성분에서 높은 진폭이 발견되며, Fig. 3.11와 같이 기어의 공진 주파수로 의심되는 주파수 성분이 나타나기도 한다.

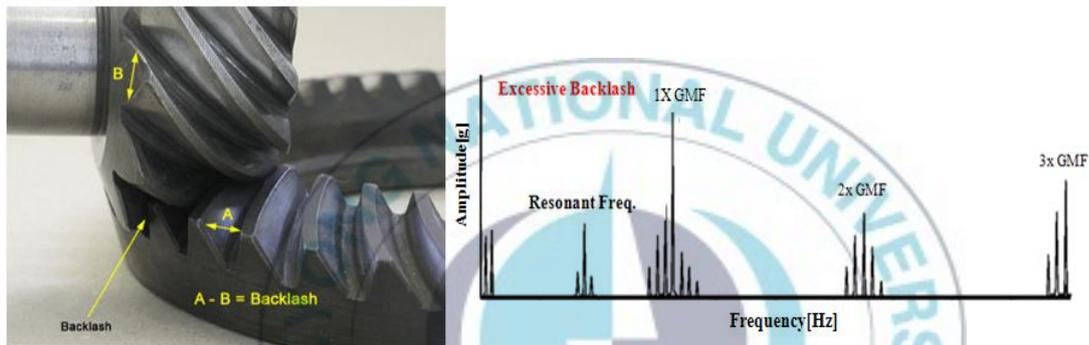


Fig. 3.11 Excessive backlash

특히 기어에 정렬불량이 생기면, 정렬 불량이 존재하는 기어 이 부위에서 서로 부딪히게 되어 기어의 자연스러운 회전을 힘들게 만든다. 이러한 현상은 주파수 분석에서 GMF의 2차 조화성분의 피크로 나타나는데 이로 인해 2X GMF는 통상 기어 정렬 문제로 인해 야기되는 결합 주파수로 간주된다.

3.2.2 모니터링

1) 특징 및 특징 계산

특징(feature)은 어떤 객체가 가지고 있는 객체의 고유의 분별 가능한 특성이 라고 정의할 수 있으며 여기서는 그 특성을 통계적인 상태량으로 표현한 신호의 대표값을 의미한다. 설비에서 취득되는 진동 신호와 전동기의 전류 신호는 설비의 각 상태에 따른 일정한 특징을 지니고 있다. 적절한 신호처리 기법을 통해 설비의 상태에 따른 특징을 계산 할 수 있는데 이러한 과정을 특징 계산이라 한다. 특징 계산을 통해 좋은 특징을 선택할 때에는 다음과 같은 조건을 만족하는지 확인해야 한다.

- 동일한 특징량은 시간에 따라 변하지 않고 일정한 값이어야 한다.
- 특징량의 수는 각 상태를 충분히 표현해야 하며 가능한 적어야 한다.
- 서로 다른 상태의 특징량 사이에는 뚜렷한 구별이 있어야하며 일정한 영역에서 적절한 군집(clustering)을 이루어야 한다.

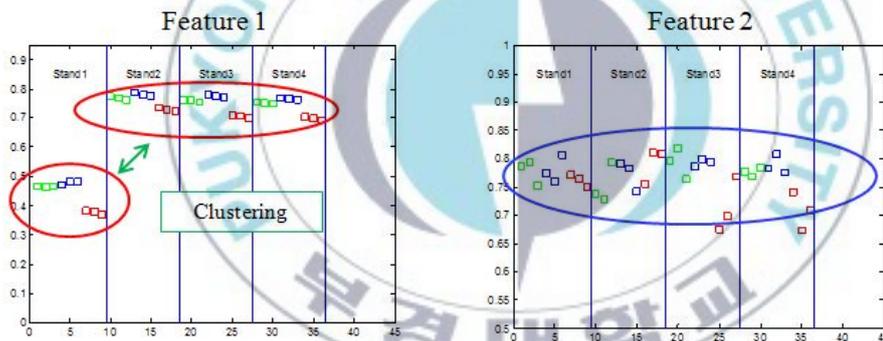


Fig. 3.12 Feature selection criteria, good feature(left) and bad feature(right)

특징은 시간 영역, 주파수 영역, 엔트로피 영역으로 나뉠 수 있으며 각 영역에서 얻어지는 특징값은 Table 3.3과 같이 정의된다 [18-19].

Table 3.3 Definition of features

Parameter	Definition	Parameter	Definition
Mean	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$	Kurtosis	$\beta_2 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{\sigma^4}$
RMS	$x = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$	Shape factor	$S/F = x_s/\bar{x}$
Standard deviation	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$	Crest factor	$C/F = x_p/x_s$
Skewness	$\beta_1 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^3}{\sigma^3}$		
Frequency center	$F/C = \frac{\sum_{i=2}^n x_i \cdot x_i}{2\pi \sum_{i=1}^n x_i^2}$	Variance frequency	$VF = \frac{\int_0^{\infty} (f-FC)^2 \cdot s(f)df}{\int_0^{\infty} s(f)df}$
Mean square frequency	$MSF = \frac{\sum_{i=2}^n x_i^2}{4\pi^2 \sum_{i=1}^n x_i^2}$	Root variance frequency	$RVF = \sqrt{VF}$
Root mean square frequency	$SF = \sqrt{MSF}$		
Entropy Estimation	$-\sum P(x) \ln P(x)$	Histogram upper bound	$\max(x) - \frac{\delta}{2}$
Entropy Estimation Error	$\sum P(x) \ln P(x)^2$	Auto-regression coefficient(8)	$x_t = \alpha_1 X_{t-1} + \dots + \alpha_{t-p} X_{t-p} + Z_t$
Histogram lower bound	$\max(x) + \frac{\delta}{2}$		

2) PCA, ICA

(1) PCA

PCA(principal components analysis)는 다 차원 특징 벡터로 이루어진 데이터에 대하여 높은 차원에서의 정보를 유지하면서 낮은 차원으로 축소시키는 다변량 데이터 처리 방법 중의 하나이다. 차원은 특징 벡터로 이루어진 행렬의 행 또는 열의 요소 개수를 의미하며, 특징 벡터의 차원이 높아짐에 따라 다음과 같은 문제점을 가진다.

- 특징이 많으면 잡음 특징들까지 포함되므로 오히려 분류에 나쁜 영향을 미친다.
- 특징이 많으면 패턴 분류기에 의한 학습과 인식 속도가 느려진다.
- 특징이 많으면 모델링에 필요한 학습 집합의 크기가 커진다.

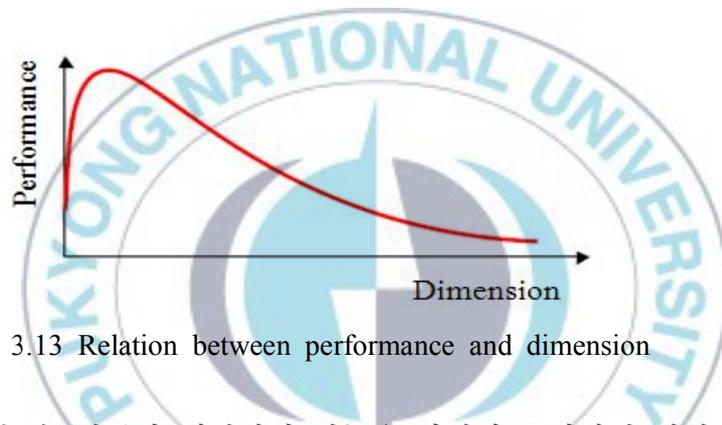


Fig. 3.13 Relation between performance and dimension

Fig. 3.13에서 볼 수 있듯이 패턴인식 성능은 차원이 증가하면 일정 범위 내에서는 성능 즉, 인식률이 증가하다가 일정 범위가 벗어나면 급격하게 성능이 나빠지는 것을 볼 수 있다. 그러므로 특징 벡터의 차원을 적절히 줄여 성능을 향상시키는 것이 패턴 인식에 있어 상당히 중요한 부분이라 할 수 있다.

PCA는 다차원 즉, 4차원 이상의 다변량 데이터를 저 차원 1~3차원 그래프로 나타내어 데이터의 특성을 알아보는 방법이다. 3차원 이상의 다변량 데이터의 특성을 산점도와 평균과 같은 특징값만으로 특성을 얻기가 힘들므로 군집 분석 결과에 대한 해석으로 PCA를 사용한다. PCA는 다음과 같은 원칙을 바탕으로 한다.

- 주성분 변수 간에는 서로 상관관계가 전혀 존재하지 않는다.(독립이다)
- 제 1 주성분은 데이터의 변동(분산, 정보)을 가장 많이 설명하고 제 2 주성분은 제 1 주성분이 표현하지 못한 변량을 표현하며 크기는 감소한다. 이는 제 3 주성분에 서도 같다.
- 제 2 주성분은 제 1 주성분은 서로 독립(수직)하며 기저 벡터가 된다.

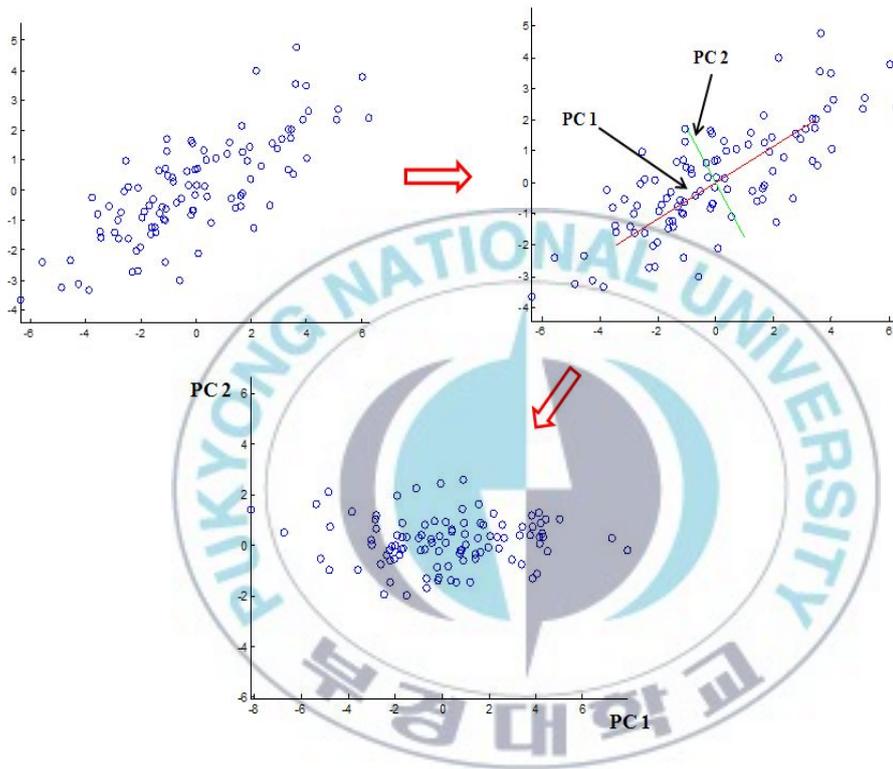


Fig. 3.14 The process of PCA

PCA를 통해 얻고자 하는 것은 Fig. 3.14과 같이 상관이 있는 변량들의 변동(분산)을 줄이는 목적에서 상관이 없는 변량의 집합으로 기준 축을 변환하는 것이다. 즉, 8차원 데이터를 3차원으로 축소하려면 기준 축을 8개에서 3개로 축소하면 된다는 의미이다. 따라서 다변량 데이터의 주성분에 해당하는 주

축을 통계적 방법으로 구하고 구해진 추축 방향으로 특징 벡터들을 Fig. 3.15 과 같이 사영(projection)함으로써 차원을 축소할 수 있다. 사영은 행렬의 내적을 이용하게 된다 [20].

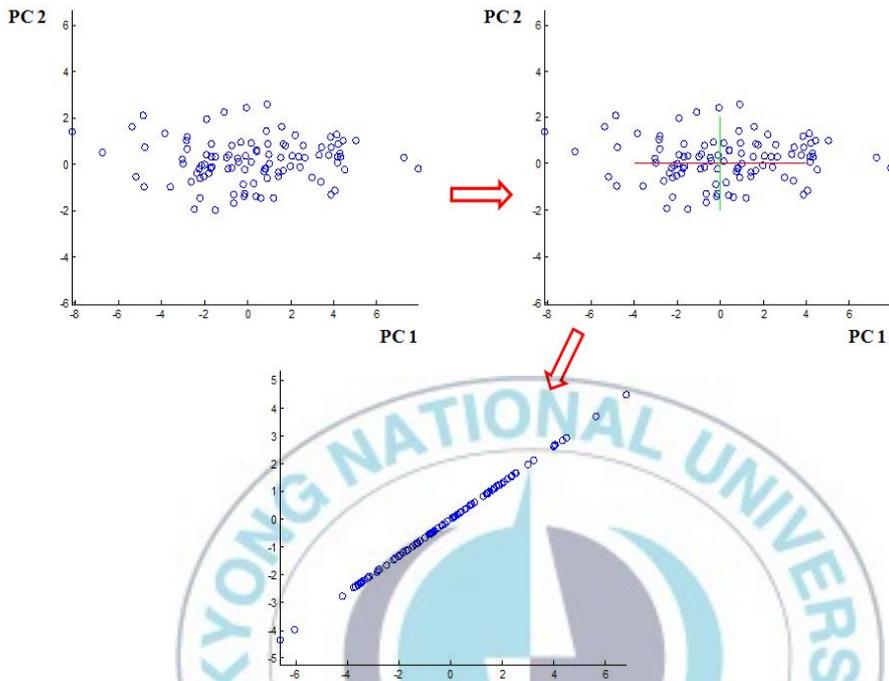


Fig. 3.15 The result of projection through product

PCA를 통하여 변환행렬을 구하는 것은 다음의 절차에 따라 계산한다.

- 데이터의 평균벡터를 구하고 분산-공분산 행렬 Σ 를 계산한다.

$$m(\text{평균벡터}) = \frac{1}{N} \sum_{n=1}^N X_n \quad (3.8)$$

여기서, X_n : 특징 벡터, N : 특징 벡터 개수

$$\sum(\text{공분산 행렬}) = \frac{1}{N-1} \sum_{n=1}^N (x_n - \mathbf{m})(x_n - \mathbf{m})^T \quad (3.9)$$

- 고유분석을 통해 고유값을 계산한다.

$$\lambda_i u_i = \sum \cdot u_i \quad \text{여기서, } \lambda_i: \text{고유값 } u_i: \text{고유벡터} \quad (3.10)$$

- 고유값이 높은 순서대로 정렬하고 가장 큰 m개의 고유값을 선택한다.

- 고유값과 관련된 고유벡터를 구하고 고유 벡터로 이루어진 변환 행렬 W를 생성한다.

$$W = [u_1 \cdots u_i] \quad (3.11)$$

- 특징 벡터를 다음의 변환식으로 나타낸다.

$$y = W^T x \quad (3.12)$$

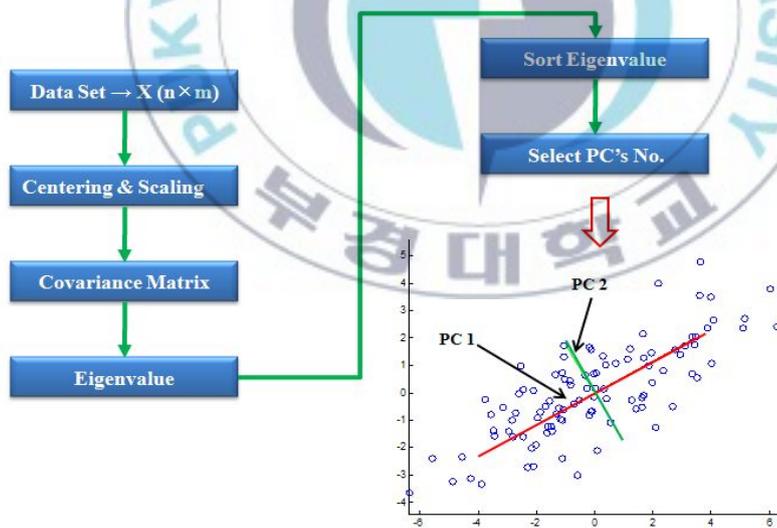


Fig. 3.16 The summary of PCA process

(2) ICA

PCA는 입력 데이터의 공분산에 의해 결정되는 정규 직교기저(orthonormal basis)로 표현되며, 가우스(gaussian) 변수의 모든 정보는 공분산행렬(covariance) 내에 포함되기 때문에 가우스 분포의 입력데이터에 대해서는 적당하다. 하지만 일반 진동 신호에는 비가우스 분포도 있으며, 이러한 경우에도 효과적으로 적용될 수 있는 선형변환 방법이 요구된다. ICA(independent component analysis)는 통계적 성질을 고려한 선형변환 기법으로 데이터의 분포정보를 이용하는 다차원 방법이다 [21-23]. ICA는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 이용한다. ICA 모델은 식 (3.13)와 같다.

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{S} \quad (3.13)$$

여기서 \mathbf{A} 는 입력 신호들을 혼합하는데 이용되는 혼합 행렬(mixing matrix), \mathbf{S} 는 입력신호로 독립요소 행렬(independent component matrix)이라 한다. 복합신호 \mathbf{X} 는 혼합 행렬 \mathbf{A} 에 입력 \mathbf{S} 를 통해 측정되는 m 개의 신호를 말한다. \mathbf{X} 를 구성하는 행렬의 행은 신호의 채널수가 되며, 열은 n 개의 측정 데이터가 된다. 입력신호를 혼합하는데 이용된 혼합행렬 \mathbf{A} 와 원신호 \mathbf{S} 는 알려져 있지 않으며, 혼합과정에서 잡음이 추가 될 수 있다. ICA는 알려진 혼합신호 \mathbf{X} 로부터 혼합행렬의 역행렬을 찾는 기법이다.

$$\mathbf{S} = \mathbf{W} \cdot \mathbf{X} \quad (3.14)$$

입력 신호 \mathbf{S} 는 식 (3.14)로 다시 정의되며, 여기서 \mathbf{W} 는 결합 엔트로피(joint entropy, $H(y)$)가 최대로 되고 상호 정보량(mutual information)이 최소가 되는 분리행렬(unmixing matrix)를 의미한다. 식 (3.13)과 식 (3.14)를 이용하면, 식 (3.15), (3.16), (3.17)을 얻게 된다.

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{W} \cdot \mathbf{X} \quad (3.15)$$

$$\mathbf{I} = \mathbf{A} \cdot \mathbf{W} \quad (3.16)$$

$$\mathbf{A}^{-1} = \mathbf{W} \quad (3.17)$$

ICA의 계산 과정을 요약하면 다음과 같다.

- Step 1. 진동 신호 디지털 변환
- Step 2. (진동 신호 계측 채널 수) \times (데이터 수) 행렬 구성
- Step 3. 분리 행렬(\mathbf{W}) 계산, 독립 성분 행렬 계산
- Step 4. 진동 신호 재구성

3.2.3 진단

1) LDA

DA(discriminant analysis)는 군집 분석(clustering analysis)과 함께 개체들에 대해 측정된 특성(변수)값을 이용하여 측정 변수들의 선형 결합 형태의 판별식을 구하고 이를 이용하여 새로운 개체를 분류하는 방법으로 개체 유도 기법(individual directed techniques)라 일컫는다. 판별 분석은 개체의 클래스(class)가 사전에 정의되어야 하며, 정의된 클래스로부터 적절한 판별식을 찾아내는 방법이다. 특히 LDA(linear discriminant analysis)은 PCA와 함께 특징 벡터 차원 축소 기법 중의 하나로 클래스 간 분산과 클래스 내 분산의 비율을 최대화하는 방식으로 데이터에 대한 특징 벡터의 차원을 축소함과 동시에 클래스 간 분류에 있어 판별이 용이한 분포를 이루도록 주축으로 사상시키는 방법을 말한다.

Fig. 3.17과 같이 클래스 A, B 로 이루어진 데이터 집합이 있다고 했을 때 주축을 X_1 로 해서 데이터 집합을 사상 시키게 되면 두 클래스 간에 중첩 밀도는 $D1$ 와 같이 표현되며, 주축을 X_2 로 정의하게 되면 두 클래스 간 중첩 밀도는 $D2$ 와 같이 표현된다. 하지만 주축을 Z 로 정의하면 중첩 밀도는 $D3$ 와 같이 표현된다. 주축을 Z 로 할 때 $D1$, $D2$ 보다 중첩 밀도가 작으며 두 클래스 간 밀도 중심 거리가 가장 멀어지는 것을 확인 할 수 있다.

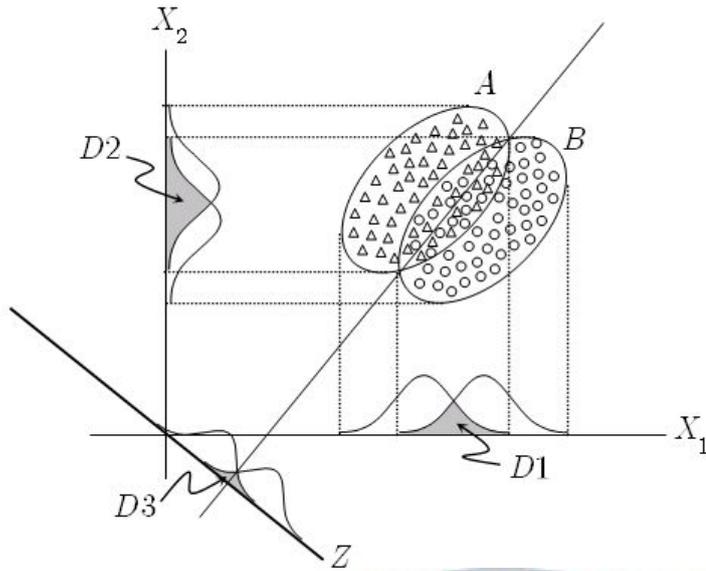


Fig. 3.17 The concept of discriminant

이때 주축 Z 가 선형 판별식의 기준이 되며 판별식은 식 (3.18)과 같이 사영된 데이터들의 중심 간의 거리를 목적 함수로 선택할 수 있다.

$$D(\mathbf{w}) = |\tilde{u}_1 - \tilde{u}_2| = |W^T(U_1 - U_2)| \quad (3.18)$$

여기서, U : 평균 벡터, W^T : 변환행렬

식 (3.18)의 목적 함수는 사용 벡터의 중심 간의 거리만 고려하였으며 클래스 간의 표준 편차 혹은 분산을 전혀 고려하지 않으므로 좋은 판별식이라고 할 수 없으며, 이를 보완하고자 식 (3.19)과 같이 정의되는 각 클래스의 분산 (within-class scatter)이라는 척도를 도입하여 식 (3.18)을 식 (3.20)과 같이 정의할 수 있다 [24].

$$\tilde{S}_i^2 = \sum_{y \in w_i} (y - \tilde{u}_i)^2 \quad (3.19)$$

여기서, y : 사영된 표본, \tilde{S}_i^2 : 클래스내 분산

$$D(\mathbf{w}) = \frac{|\tilde{u}_1 - \tilde{u}_2|^2}{(\tilde{s}_1^2 + \tilde{s}_2^2)} \quad (3.20)$$

2) SVM

SVM(support vector machine)은 주로 2개의 범주를 분류하는 이진 분류기이다. SVM는 분류에러를 최소화 하는 수식을 LM(lagrange Multiplier)를 이용해 계산하고 QP(quadratic programming) 문제를 풀어서 가장 최적의 결정 경계 즉, 분리경계면(hyperplane)을 찾는 방법이다. 최적의 경계는 두 집합사이를 통과하며 양 집합으로부터 가장 멀리 떨어진 분리경계면을 말한다. 경계면에 가장 가까이 있는 벡터를 SV(support vector)라 한다. 이진 분리경계면의 모델은 식 (3.21)과 같다 [25-27].

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (3.21)$$

여기서 \mathbf{w} 는 가중치 벡터이고, b 는 bias 항이다. 훈련벡터 x_i 와 분리경계면과의 거리를 마진(Margin)이라고 하고, 식 (3.22)와 같이 표현한다.

$$m = \frac{\mathbf{w}^T \mathbf{x} + b}{\|\mathbf{w}\|} \quad (3.22)$$

만약, $\mathbf{w}^T \mathbf{x} + b = 1$ 로 경계조건을 주게 되면 분리경계면까지의 거리는 $\frac{1}{w}$ 이 된다. $\mathbf{w}^T \mathbf{x} + b = -1$ 로 경계조건을 주게 되면 분리경계면까지의 거리는 역시 $1/w$ 이 되며 이는 $\mathbf{w}^T \mathbf{x} + b = 0$ 를 경계로 최대 마진이 $\frac{2}{w}$ 가 되는 것을 알 수 있다.

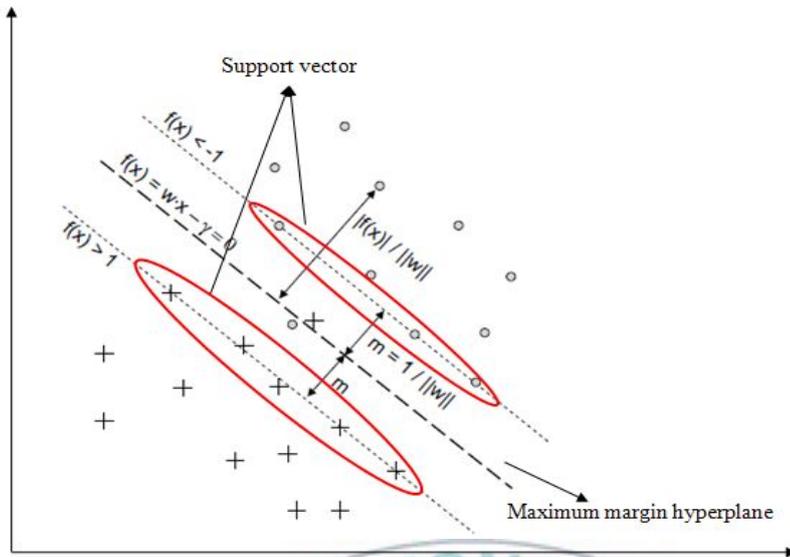


Fig. 3.18 The concept of SVM

SVM은 w^2 을 최소화함으로써 마진(margin)을 최대가 되는 경계면을 찾는 최적화 문제가 된다.

$$\text{minimize } \|w\|^2 \quad (3.23)$$

$$\text{subject to } y_i(w^T x_i + b) \geq 1 \quad (3.24)$$

위의 최적화 문제는 LM으로서 구할 수 있으며, 식 (3.25)와 같다.

$$L(w, b, \alpha_i) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w x_i + b) + \sum_{i=1}^N \alpha_i \quad (3.25)$$

여기서, $\alpha_i \geq 0$ 이며, w 와 b 가 최적의 값이라고 가정하면, w 와 b 에 대한 각각의 편미분결과는 0 이 되어야한다.

$$\frac{\partial L}{\partial w} = w - \sum_i \alpha_i y_i x_i = 0, \quad \frac{\partial L}{\partial b} = - \sum_i \alpha_i y_i = 0 \quad (3.26)$$

식 (3.26)을 식 (3.25)에 대입하여 다시 정리하면,

$$L(w, b, \alpha_i) = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1} \alpha_i \quad (3.27)$$

식 (3.25)의 두 번째 항이 최소이면, 조건 α 에서 L 은 최대가 되므로, 이 것은 결국 QP 문제가 된다.

$$\text{maximize} \quad -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1} \alpha_i \quad (3.28)$$

$$\text{subject to} \quad \sum_i \alpha_i y_i = 0, \quad \alpha_i \geq 0 \quad (3.29)$$

SVM이 효과적인 이유는 저차원에서 비선형인 데이터 집합을 보다 높은 차원에서 볼 때 선형성을 띠고 하면 차원을 확대해서 보다 더 빠르고 쉬운 선형적 분류를 수행하기 때문이다. 대부분의 패턴은 선형적으로 분리가 가능하지 않으며 비선형 패턴을 분리하기 위해 비선형 패턴의 입력공간을 선형 패턴의 특징 공간으로 변환한다. 이때 사용되는 방법이 커널(kernel) 함수이며 이를 이용해 비선형 분류를 한다. Fig. 3.19과 같이 2차원에서 비선형 분포인 데이터이지만 3차원으로 차원을 높이면 선형의 형태를 나타내는 데이터 분포가 되며 이에 대한 분리경계면이 선형이 됨을 알 수 있다. x 를 고차공간으로 변환 즉 사상을 Φ 라 하면, 커널 함수와 특징 공간의 관계는 식 (3.30)과 같다.

$$K(x, \hat{x}) = \Phi(x)^T \Phi(\hat{x}) \quad (3.30)$$

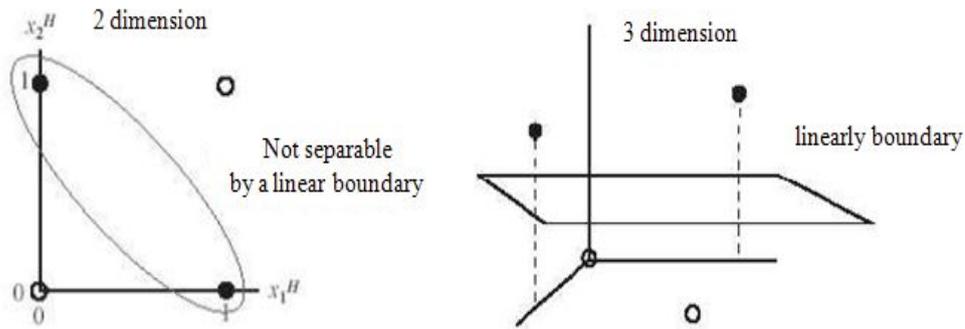


Fig. 3.19 Transformation to higher dimensional space.

3) k-NN

k-NN(k-nearest neighbor) 방법을 이용하여 데이터를 분류하기 위해서는, 데이터 간의 유사도 혹은 거리를 계산 한다. k개의 최근접 데이터들 중 가장 많은 비율을 차지하는 클래스로 평가샘플을 분류하는 방법으로 다양한 요인들을 고려하여 가장 근접해 있는 데이터를 찾아내는 기법이다. k-NN에서 최근접 이웃까지 계산된 거리 또는 유사도는 신뢰수준을 나타내며 멀리 떨어진 경우보다 가까울수록 신뢰 수준이 높은 것을 의미한다. k-NN 알고리즘 단계는 다음과 같다. 우선 일정한 차원의 벡터들로 구성된 학습 데이터 집합을 가정한다. 만일 동일한 차원을 가진 미지의 데이터를 분류할 경우, 그 데이터와 가장 가까운 거리에 위치하는 k개의 데이터를 선택한다. 이때 최근접 k값에 의해 분류 결과가 달라지므로 k값을 선택하는 것은 k값을 다양하게해서 오차율을 계산한 후 최소의 오분류 값을 갖는 k값을 선택한다. 또한 데이터간 거리는 Euclidean norm을 사용하여 식 (3.31)과 같다 [28-29].

$$D(x_i, y_i) = \|x_i - y_i\| \quad x_i, y_i: \text{데이터} \quad (3.31)$$

데이터 간 인접(유사)한 정도를 측정할 때, 각각의 데이터는 변수별로 단위크기에 영향을 받게 된다. 이러한 단위의 영향을 없애기 위해 거리를 계산하기

전에 값들을 정규화한다. 정규화는 모든 데이터들을 같은 단위로 변환한다는 의미를 가지는 것으로, 측정치에서 평균을 뺀 후, 표준편차로 나누어 계산한다. 분류 결과는 k 의 데이터 중에서 가장 다수가 속한 클래스가 입력된 미지의 데이터의 클래스로 분류한다. 평균, 표준편차, 정규화에 대한 식은 각각 식 (3.32), 식 (3.33), 식 (3.34)와 같다.

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_i}{i}, \quad x: \text{데이터}, i: \text{데이터 개수} \quad (3.32)$$

$$s = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_i - \bar{x})^2}{i-1}} \quad (3.33)$$

$$\hat{x}_i = \frac{x_i - \bar{x}}{s} \quad (3.34)$$



Fig. 3.20 The concept of k-NN

3.2.4 예지

최근 산업계에서 기계 정비는 점점 더 중요한 역할이 되고 있다. 적절한 정비 전략은 기계 설비의 결함으로 발생하는 막대한 생산 손실과 정비 비용을 저감할 수 있다. 이러한 측면에서 기계 건강 예지(prognosis)는 정비 전략을 수립하는데 있어 중요한 정보가 될 뿐 아니라 기계 상태를 평가하고 예측함으로써 기계 관리자에게 유용한 정보를 제공할 수 있다.

1) ARMA

ARMA(autoregressive moving average) 모델은 정상상태 시계열데이터를 분석하기 위한 수학적 모델로 데이터의 과거치(AR)와 과거 오차항(MA)이 설명변수인 선형회귀모형이다. 자기회귀모델(AR)이란 시계열자료(y_t)가 과거 값들로서 설명이 된다는 모형으로 식 (3.35)와 같다.

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t \quad (3.35)$$

현재(t)인 시점의 시계열 값(y_t)은 바로 전기($t-1$) 값으로부터 a_1 만큼, ($t-2$) 값으로부터 a_2 만큼 영향을 받는다고 할 수 있다. 그러므로 과거 r 기까지의 값들이 y_p 에 영향을 준다고 할 경우 식 (3.35)는 t 차 자기회귀모델이라고 부르며, AR(r)라고 표현한다. 바로 전기의 값이 현재의 값에 중요하게 영향을 주는 경우, AR(1) 모델이 된다.

이동 평균(MA) 모델은 시계열자료가 연속적인 오차항들의 영향을 받는다는 것으로 식 (3.36)와 같다.

$$y_\delta = \varepsilon_\delta - \beta_1 \varepsilon_{\delta-1} - \dots - \beta_q \varepsilon_{\delta-q} \quad (3.36)$$

식 (3.36)을 m 차 이동평균모델이라고 부르며, MA(m)로 나타낸다. 바로 이전 시점의 오차항만이 포함되는 경우라면 1차 이동평균모델이 되며 MA(1) 모형이 된다.

ARMA는 앞서 두 가지 모형을 합한 형태로 시계열자료(y_t)가 과거의 시계열자료 값들과 오차값들로 표현될 수 있으며 때로는 모두의 영향을 동시에 받는다고 가정한 모델이다. AR과 MA가 혼합된 모델은 식 (3.37)과 같다.

$$y_t = c + \sum_{i=1}^r \Phi_i y_{t-i} + \sum_{j=1}^m \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (3.37)$$

ARMA(r,m)으로 표현하며 AR(1)인 경우 ARMA(1,0)로 표현한다 [30].

2) GARCH

GARCH(generalized autoregressive conditional heteroscedasticity) 모델은 ARCH(auto regressive conditional heteroscedasticity) 모델을 일반화시킨 모델이다. 조건부 이분산(conditional variance) 모델은 시계열의 변동성이 보여주는 밀집현상(clustering) 등과 같은 경험적 특징들을 잘 반영하고 있다. ARCH은 조건부 분산을 모델화하고 예측하기 위해 Engle (1982) [31]에 의해 제안된 모델이다. 이는 오차의 이분산성을 고려한 최초의 모델로 t 시점의 오차항 e_t 의 분산이 이전 시점들의 오차값의 선형 결합 식으로 표현된다는 것으로 ARCH(q) 모델은 식 (3.38)과 같다.

$$\begin{aligned} \varepsilon_t &= \sqrt{h_t} e_t, e_t \sim iidN(0,1), \\ h_t &= w + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2, \\ 0 < w, 0 \leq \alpha_j, 0 \leq \sum_{j=1}^q \alpha_j < 1 \end{aligned} \quad (3.38)$$

이 모형을 차수 q 인 ARCH 모델 또는 ARCH(q) 모델이라 한다. ARCH(q) 모델에서는 현재의 오차항들에 대한 분산을 과거시점의 오차항들에 대한 제곱의 선형함수로 나타냈는데, 실증분석에서 ARCH(q) 모델은 비교적 긴 시차를 필요로 한다는 것이 알려졌다. 이러한 경우 모수(parameter)들을 동시에 추정하는

데 많은 어려움이 있다. 이러한 이유로 ARCH 모델을 발전시켜 Bollerslev (1986) [32]가 GARCH 모델을 제안하였으며 식 (3.39)와 같다.

$$\begin{aligned} \epsilon_t &= \sqrt{h_t} e_t, e_t \sim iidN(0,1), \\ h_t &= w + \sum_{j=1}^p \beta_j h_{t-j} + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2, \\ 0 < w, 0 \leq \alpha_i, \beta_j < 1, 0 \leq \sum_{j=1}^p \beta_j + \sum_{i=1}^q \alpha_i < 1 \end{aligned} \quad (3.39)$$

GARCH 모형을 도입하는 이유는 작은 수의 모수를 사용함에도 불구하고 긴 시차의 ARCH모형을 추정하는 것과 유사한 효과를 가져오며, GARCH와 같은 조건부 이분산 모델들은 시계열의 변동성이 보여주는 밀집현상 등과 같은 경험적 특징들을 잘 반영하는 특성을 지니고 있기 때문이다 [33-36].

3) 첨도

첨도(kurtosis)는 시계열 신호의 확률밀도함수 분포가 갖는 첨예의 정도를 나타내는 척도로서 데이터의 양적 구조를 나타내기 위해 관측 값들이 중심에 집중되는 정도를 나타낸다. 첨도는 파형의 4차 모멘트를 표준편차 σ 의 4승으로 나누어 규격화한 값으로 둔감한 저차 모멘트와 민감한 고차 모멘트 사이의 절충된 척도로서, 충격적 신호 파형에서 주로 관측되며 첨도 계수가 3 이상일 경우 정규 분포보다 뾰족한 분포를 가진다. 첨도는 본 장의 Tanble 3.3에서 정의한 바와 같이 식(3.40)으로 표현된다 [37].

$$\beta_2 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{\sigma^4} \quad (3.40)$$

여기서, x : 데이터, n : 데이터 개수, σ : 표준편차

제 IV장 개발 소프트웨어

4.1 인터페이스 구성

본 소프트웨어는 데이터 처리, 특징값 감시, 진단 및 예지 모듈로 크게 4가지로 나뉜다. 첫 번째 모듈인 데이터 처리 모듈에서는 기본적으로 연속된 시간 데이터를 바탕으로 신호를 감시하고 나아가 주파수 분석을 수행함으로써 데이터의 보다 상세한 결합 정보를 채집하게 된다. 또한 세부적인 기능들을 탑재하여 다양한 결합 정보를 효율적으로 비교하도록 구성 하였다.

특징값 감시 모듈에서는 데이터의 통계적 상태량을 특징값으로 정의하고, 각 특징값의 경향을 감시함으로써 기계의 현재 상태를 보다 명확히 과거의 이력 상태와 비교하는 방법을 제시한다. 특징이라고 하는 것은 어떤 객체가 가지고 있는 객체 고유의 분별 가능한 측면, 양, 혹은 특성이라고 정의할 수 있다. 특징이 하나 이상의 수치 값을 가질 경우에 특징벡터라고 표현하고, 벡터가 정의되는 임의의 차원의 공간을 특징 공간이라고 정의 한다. 특징값으로 축을 정의하여 특징 공간에 특징값을 뿌리게 되면 유사한 상태량들은 일정한 영역으로 수렴하여 군집을 이루게 되는데 이러한 특성을 이용하여 데이터의 상태를 가장 잘 표현하고 판별할 수 있는 특징값들을 선별할 수 있다. 이렇게 선정되어진 최종 특징값은 이후 3차원 경향 분석의 파라미터로 사용된다.

세 번째 모듈인 상태 진단 모듈에서는 특징값 감시 모듈에서 추출된 특징값을 기반으로 진단 모듈의 핵심인 분류기를 학습시킨다. 특징값을 정의하고 이를 추출, 선택하게 되는 또 다른 목적은 진단 및 예지 모듈의 학습에 요구되는 입력 데이터를 구성하기 위해서이다. 진단 및 예지 전략에 있어 학습은 알고리즘의 성능을 좌우하는 가장 중요한 과정으로 학습을 통해 데이터의 패턴을 이해하고 이데 대한 결과로 데이터를 유사한 집단으로 분류 또는 예지를 수행하게 된다. 특징값에 의해 학습된 분류기는 새롭게 입력된 데이터에 대해 가장 유사한 클래스 즉, 유사 계층으로 분류함으로써 입력된 데이터에 대한 클래스 정보를 제공하게 된다. 클래스에 대한 정의는 결합 데이터베이스를 기반으로 결정되며 이를 위해서는 오랜 기간 지속적이고 신뢰성 있는 데이터 취

득이 선행되어야 하며, 충분한 데이터베이스가 확보되면 이를 바탕으로 명확한 결함 클래스를 정의하게 된다.

진단 모듈과 함께 기계 상태를 평가해주는 또 하나의 모듈로써 예지 모듈이 있다. 예지 모듈 또한 충분한 훈련데이터의 확보가 예지 성능을 높이는 중요한 열쇠가 되며 장기간에 걸친 데이터 추이와 함께 기계 상태를 적합하게 표현하는 파라미터를 찾는 것이 핵심이 된다. 예지 모듈의 목적은 현재 상태를 평가하고 미래 상태를 예측함으로써 기계 관리자에게 기계에 대한 보다 유용한 정보를 제공함으로써 관리자의 의사 결정에 도움을 주는 것이 최종 목적이 된다.

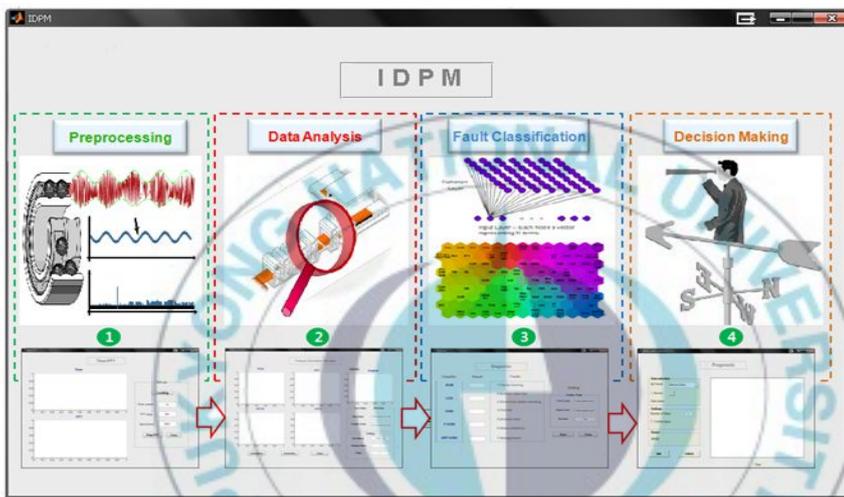


Fig. 4.1 Software interface

4.2 소프트웨어 흐름도

소프트웨어의 흐름도는 Fig. 4.2 에 간략히 나타내었다. 우선 데이터 처리 모듈의 프로세스가 시작되면, 데이터를 연속된 주파수 신호로 나열한다. 이때 각 신호의 RMS 값을 모니터링하게 되며, 시간 순서로 RMS 변화값이 그래프에 나타낸다. 이때 RMS 값이 이력 데이터의 평균값 보다 일정 이상의 큰 변동 성분을 가지면 정밀한 FFT 분석 을 통해 신호를 상세하게 검사하게 된다. 정

밀한 FFT 분석을 통해 얻어진 결과가 특정 결함 증상과 유사하거나 특정 결함 주파수와 동일한 주파수가 발견되게 되면 이 결과는 사례 기반 진단 모듈의 비교 과정을 통해 기계의 상태를 진단 받게 된다. 하지만 얻어진 결과가 모호하거나 명확하지 못하다면, 계측된 데이터로부터 특징값을 계산하게 된다. 계산된 특징값 중에서 기계 상태를 잘 반영하는 우월한 특징을 선택하고 이를 바탕으로 3차원 특징 공간상에서 각 축을 구성하는 특징에 대한 경향 감시를 수행한다. 이때 정의된 특징공간상에 정상상태로 간주되는 데이터의 특징 집합 즉, 군집영역의 최대거리를 계산하여 알람 경계가 결정된다. 특징값이 이 알람 경계를 넘어서게 되면 소프트웨어는 경고 알람 메시지를 발생시키며, 이를 받은 분류기 기반의 진단 모듈은 각 분류기를 학습시키게 된다. 이때 학습되는 방법은 특징 집합으로부터 우월한 특징만을 추출한 특징 집합을 통해 학습이 이루어지며 학습된 결과에 따라 데이터의 분류를 수행하며 최종 기계의 결함을 진단하게 된다.

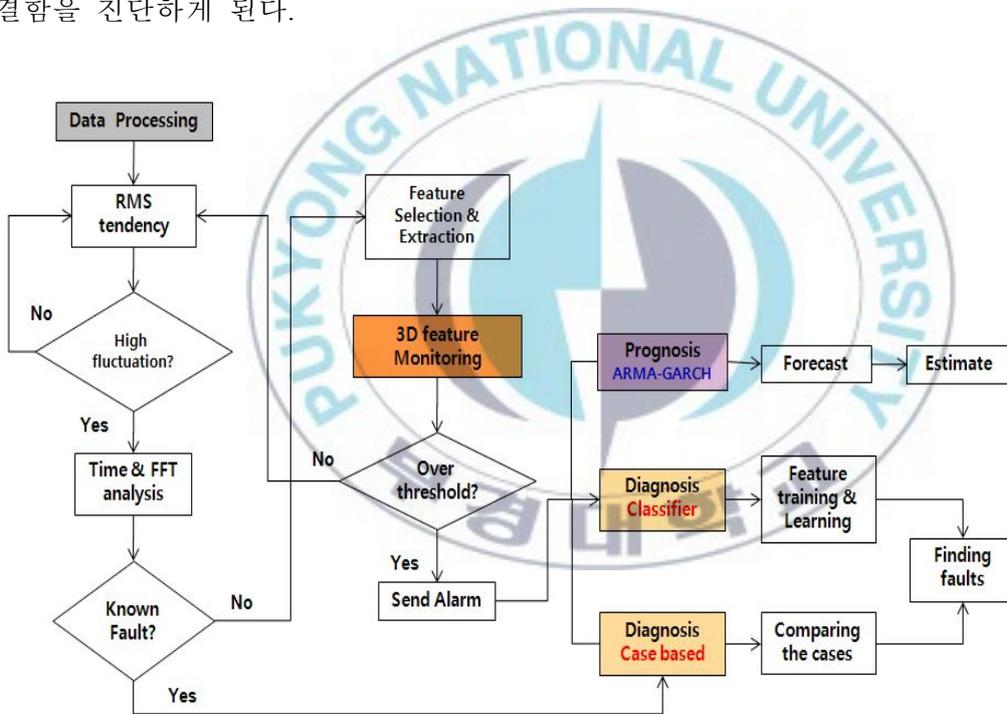


Fig. 4.2 Software flowchart

제 V 장 실험 및 결과

5.1 실험

본 장에서는 개발 소프트웨어의 성능을 검증하고자 2가지의 데이터가 사용되었다. Fig. 5.1은 한국수자원공사 원동취수장의 펌프시스템에 대한 개략도이다. 센서는 모터의 부하/반부하, 펌프의 부하/반부하 측의 베어링에 수직/수평 방향으로 설치되었으며, 총 8포인트로 구성되어있다. 포인트 1, 3, 5, 7에는 각각 베어링이 설치되어 있고, 센서에 대한 상세 정보는 제 II장의 Table 2.1에 설명한바 있다.

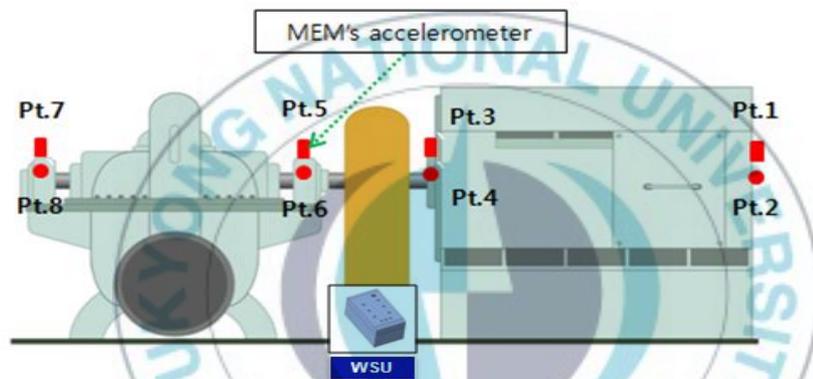
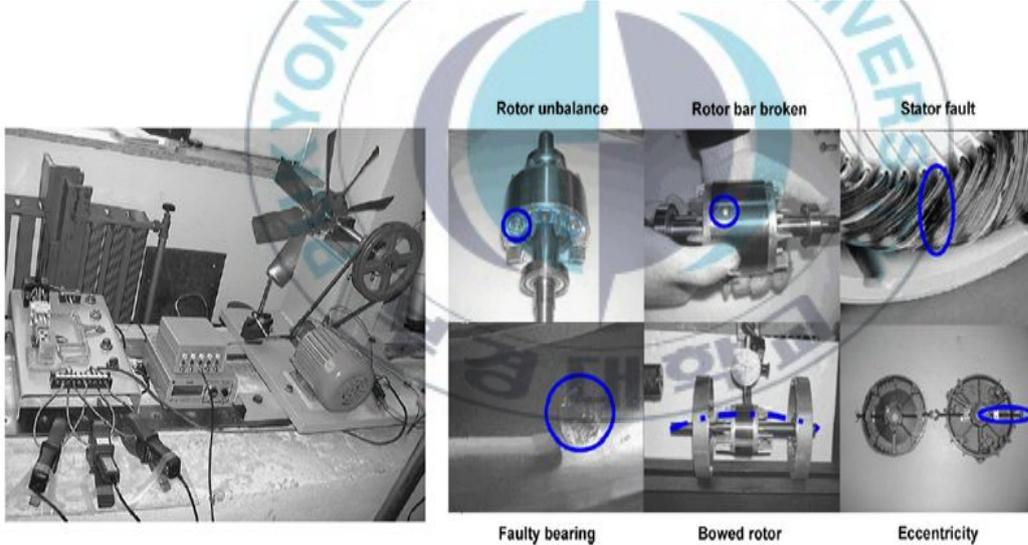


Fig. 5.1 K-Water Pump configuration

원동 펌프의 상세 사양은 Table 5.1에 나타내었다. 원동취수장에서 계측된 데이터를 이용하는 것은 실제 사례에서 얻어진 신호를 개발 소프트웨어에 적용하기 위한 목적이다. 계측 당시 펌프의 상태는 정상으로 양호한 상태였으며, 상태 감시를 비롯하여 진단 및 예지 모듈을 검증하기 위해 Fig. 5.2에 나타낸 모의 모터 결함 데이터를 사용하게 되었다. 모의 결함 데이터는 정상을 포함하여 총 7개의 형태로 나뉘며, 상세한 내용은 Table 5.2에 요약하였다.

Table 5.1 K-Water Pump system specification

Operating Speed		880 [rpm]	
Number of Pole		8	
Number of Vane		5	
Pump total ahead		75 [m]	
Position	Model	1X of fault type	Fault frequency[Hz]
Motor Bearing	SKF 62301	BPFO	118.969
		BPFI	233.052
		BSF	81.010
		FTF	19.828
Pump DE Bearing	SKF NU326	BPFO	310.665
		BPFI	452.045
		BSF	152.817
		FTF	23.898
Pump NDE Bearing	SKF 6330	BPFO	210.504
		BPFI	317.526
		BSF	138.789
		FTF	23.390



(a) Test rig.

(b) Fault conditions

Fig. 5.2 Faulty motor simulation configuration

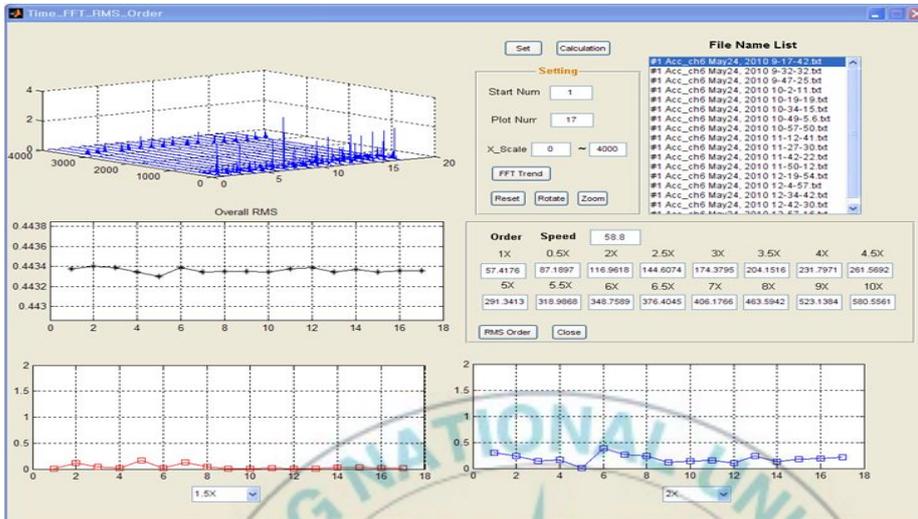
Table 5.2 Definition of faults

Label	Fault Type
1	Bearing fault
2	Rotor bar broken
3	Stator fault
4	Normal
5	Bowed
6	Rotor unbalance
7	Eccentricity

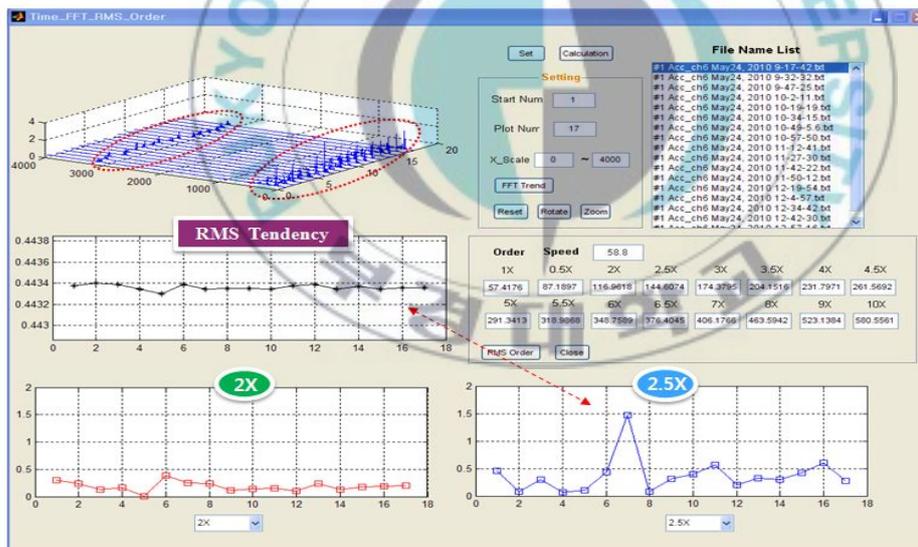


5.2 결과

5.2.1 데이터 처리



(a) 1X and 2X order results for RMS monitoring



(b) 2X and 2.5X order results for RMS monitoring

Fig. 5.3 The result of data processing

4.2장에서 설명했듯이 신호는 주파수영역에서 시간 순으로 그래프에 표현되며 각 신호의 RMS 값이 감시된다. Fig. 5.3(a) 에서 가장 두드러지게 나타나는 2가지 주파수 성분이 관찰되며, 차례로 RMS의 경향을 나타내는 그래프가 있으며, 아래로 각 조화성분을 개별적으로 관찰하도록 구성되어 있다. 880rpm으로 운전되는 8극 모터의 경우 운전 주파수는 아래 식으로부터 얻어진다.

$$\text{운전 속도}[Hz] = \frac{[RPM] \times [\text{극수}]}{120} \quad (5.1)$$

식 (5.1)로부터 운전 속도의 1X는 58.6Hz임을 알 수 있다. Fig. 5.3(a)에서 나타나듯이 운전 속도의 1.5X와 3X를 비롯한 조화성분에서는 변동크기 성분이 거의 나타나지 않으며 값 또한 아주 낮음을 알 수 있다. Fig. 5.3(b)의 결과는 운전속도의 2X와 2.5X의 배수 성분이 RMS 경향과 유사한 형태를 지니고 있음을 알 수 있고, 또한 2.5X의 결과 그래프가 다른 배수성분보다 높은 진폭을 가지고 있음을 알 수 있다. 사용된 데이터는 한국수자원공사의 원동취수장 펌프로부터 계측된 데이터로 센서 위치는 Fig. 5.1의 Pt.6 이며, 수평방향이다. Fig 5.3그래프의 X축은 데이터의 개수를 의미하며 사용된 데이터의 정보는 우측의 'File Name List' 에 명시된다. 인터페이스에 표시된 것과 같이 본 소프트웨어에서는 운전 속도의 최대 10X 성분까지를 모니터할 수 있도록 구성되어 있다.

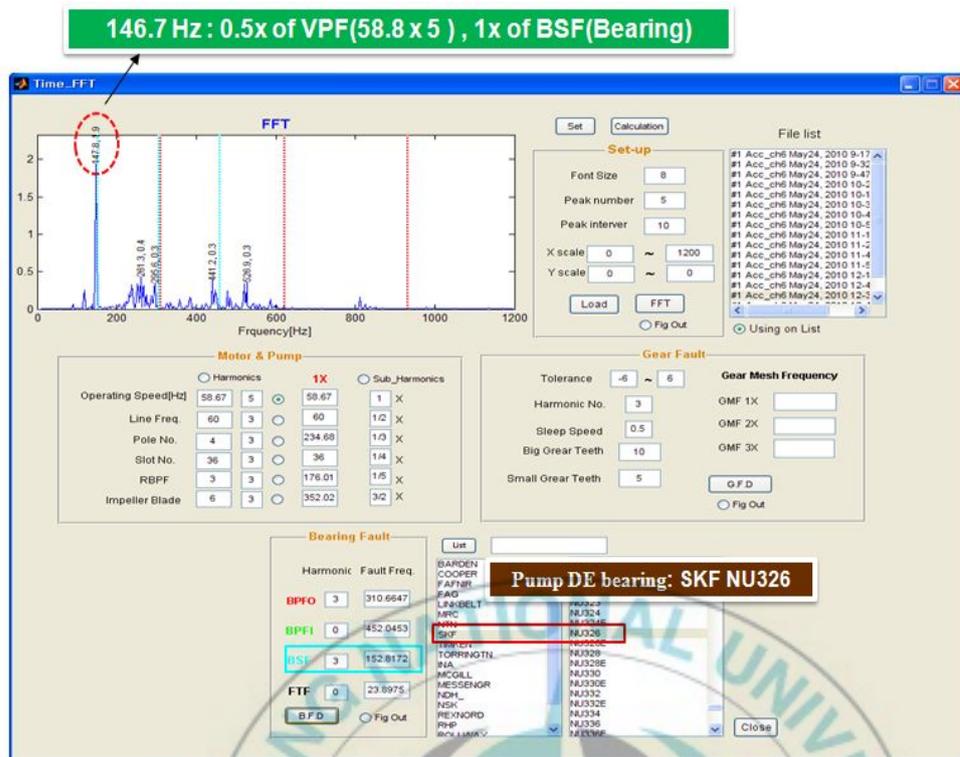


Fig. 5.4 The result of FFT analyzer

Fig. 5.4는 FFT 분석의 결과를 나타내고 있다. 주로 관측되었던 2가지 주파수 성분 중에 전체 RMS에 가장 영향을 많이 주는 주 관심 주파수는 146.7Hz로 관측되었다. Fig 5.1의 Pt.6 에서는 펌프 부하 측이며 베어링 모델 SKF NU326 이 설치 되어 있다. 베어링에 대한 정보를 본 소프트웨어에 적용하고 펌프 및 모터에 대한 사양을 입력한 결과 관측된 관심 주파수는 깃 통과 주파수(vane pass frequency)의 0.5X 성분과 베어링 볼 자전 주파수(ball spin frequency)의 1X 성분에 크게 영향을 받는 것으로 나타났다. 여기서 깃 통과주파수는 운전 속도[Hz] × 날개 수가 되며 계산 결과 293Hz가 된다. 또한 볼 자전 주파수는 3.2 장의 식 (3.4)에 의해 계산되어지며, Table 5.1에 결함 주파수가 명시되어 있다.

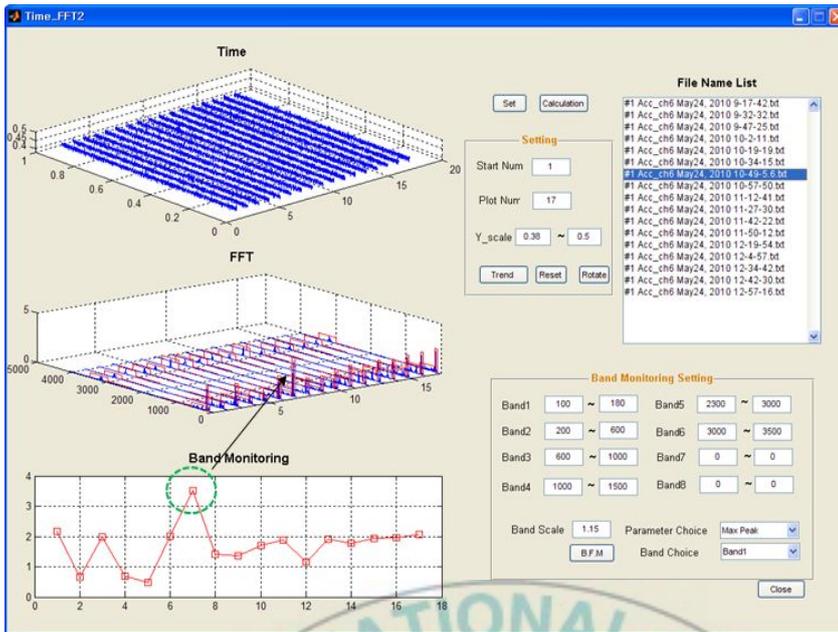


Fig. 5.5 The result of band_1 monitoring

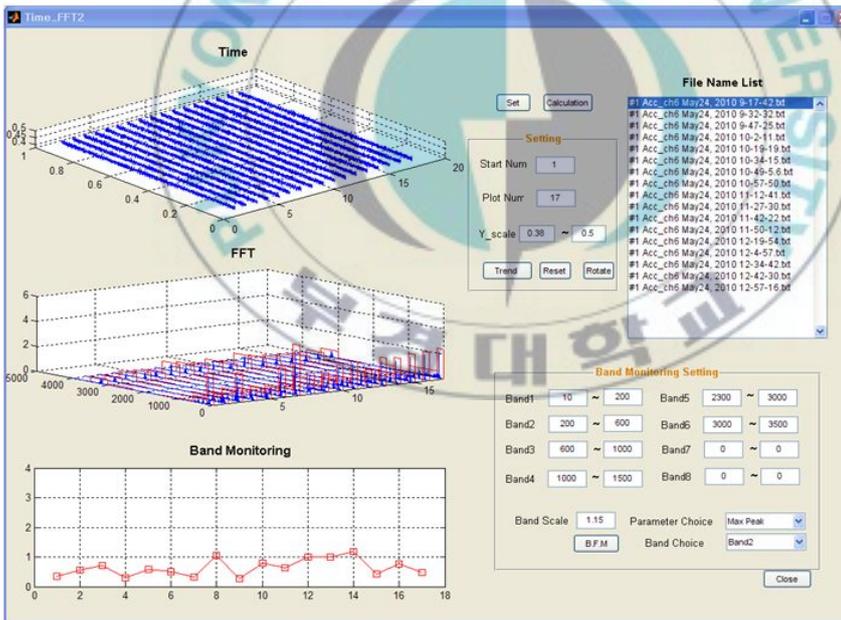


Fig. 5.6 The result of band_2 monitoring

Fig. 5.5는 데이터 처리 중 밴드 모니터링의 결과를 나타내었다. 밴드 모니터링의 밴드 폭은 앞의 데이터 처리 결과로부터 정의된다. 앞의 결과에서 운전속도의 2X성분과 2.5X성분을 포함한 146.7Hz 성분이 중요한 요소임을 알 수 있다. 이를 토대로 Band 1에 대한 정의를 100~180Hz로 정의 하였으며, 정의된 Band 1에 대한 전체 경향을 나타낸 결과가 Fig. 5.5의 가장 하단 그래프에 표현되었다. 일시적으로 Band 1의 크기가 증폭하는 현상이 있지만 전체적으로 안정되고 있음을 알 수 있다. Band 2에 대한 결과는 Fig. 5.6을 통해 알 수 있으며 Table 5.3에 요약된 바와 같이 Band 1에 비해 진폭이 낮고 변동이 작다.

Table 5.3 The comparing of Band 1 and Band 2

No.	Band 1: 100~180 [Hz]	Band 2	decreasing rate(%)
1	2.175	0.361	83.40
2	0.655	0.548	16.34
3	1.980	0.721	63.59
4	0.691	0.293	57.60
5	0.475	0.596	-25.47
6	2.011	0.509	74.69
7	3.510	0.324	90.77
8	1.403	1.048	25.30
9	1.359	0.282	79.25
10	1.711	0.801	53.19
11	1.884	0.637	66.19
12	1.152	1.002	13.02
13	1.910	0.988	48.27
14	1.776	1.172	34.01
15	1.942	0.432	77.75
16	1.974	0.773	60.84
17	2.070	0.476	77.00

본 경우는 원동취수장의 펌프시스템을 계측한 데이터를 기반으로 개발 소프트웨어를 통해 분석한 결과이다. 실제로 원동취수장의 펌프시스템은 정기적인 정비를 통해 항상 시스템을 정상상태로 관리하고 있으며, 결함이 발생되더라도 보조 펌프로 즉각 교체 운영되고 있어 결함 데이터를 취득하기는 어려웠다. 또한 MEMS 기반 센서들의 감도가 아직은 낮으며 측정 주파수 범위에서

선형성을 만족하는 영역이 안정되어 있지 않은 점도 개선해야 할 과제였다. 좀 더 안정적이고 신뢰성 있는 데이터를 취득한다면 개발 소프트웨어의 분석 결과도 좀 더 향상될 것으로 예상된다.

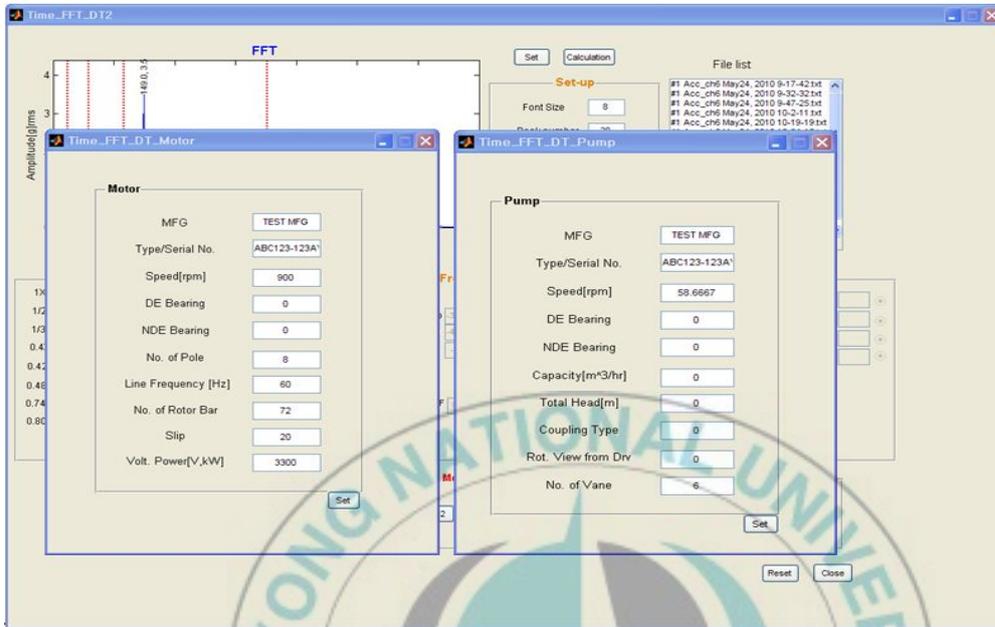


Fig. 5.7 The result of case based diagnosis module(1)

Fig. 5.7~5.9는 사례 기반 진단 모듈이다. 본 모듈의 아이디어는 사례 기반 진단 기법에서 참고했으며, 현재의 결함 정보를 다양한 결함 사례의 정보와 비교하여 가장 유사한 사례를 찾아 진단하는 기법이다. 사례 기반 진단의 장점은 현장에서 발생되었던 실 사례를 적용하기 때문에 유사한 사례를 찾을 수 있다면 직접적 해결책이 찾을 수 있다는 점이다. 하지만 다양한 사례 정보를 얻기가 쉽지 않고 기계 결함이 복합적으로 일어나는 경우에는 진단하는데 상당한 어려움이 있다. 이러한 이유로 소개된 사례 진단 모듈은 아직도 개발 중에 있으며, 많은 수정과 많은 자료 수집이 요구되고 있다. 모듈에 대해서만 언급하면 원동취수장의 경우와 같이 펌프 모터 시스템인 경우 Fig. 5.7에서 보다 상세한 사양을 입력하게 된다. 사양이 입력되면 이를 바탕으로 시스템에서 발생될 수 있는 결함 주파수정보들이 Fig. 5.8과 같이 비활성화 된 상태로 입력된다.

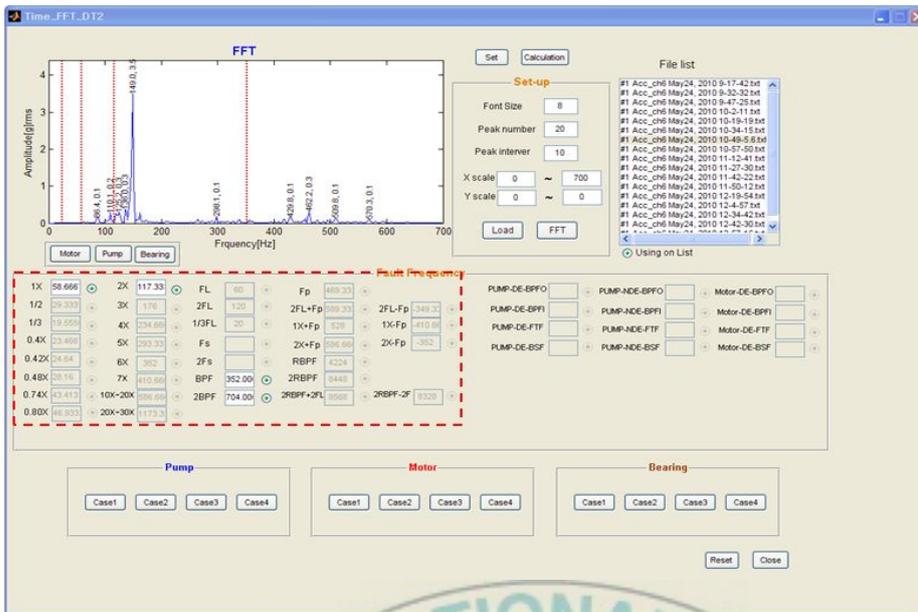


Fig. 5.8 The result of case based diagnosis module(2)

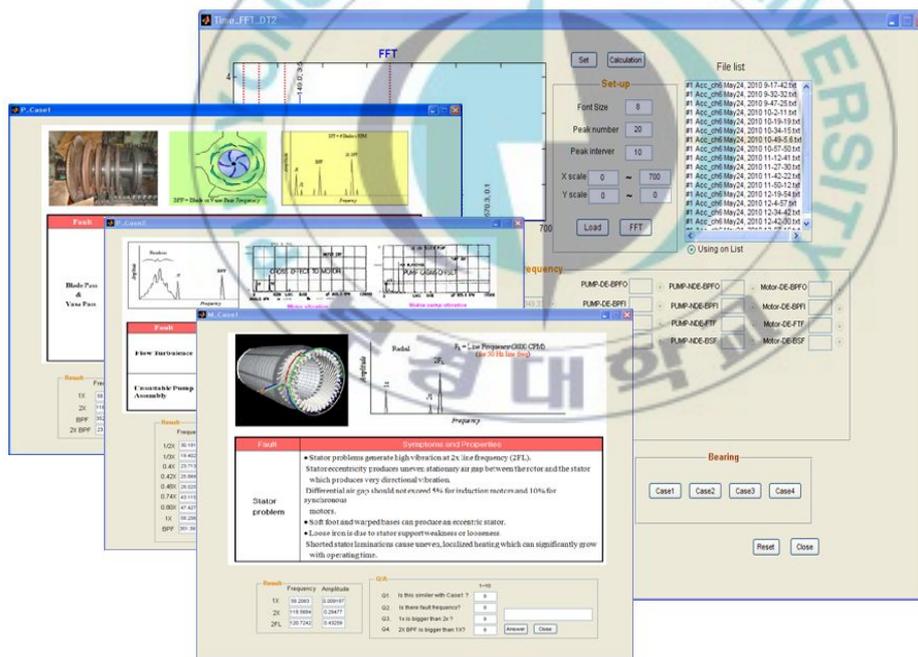
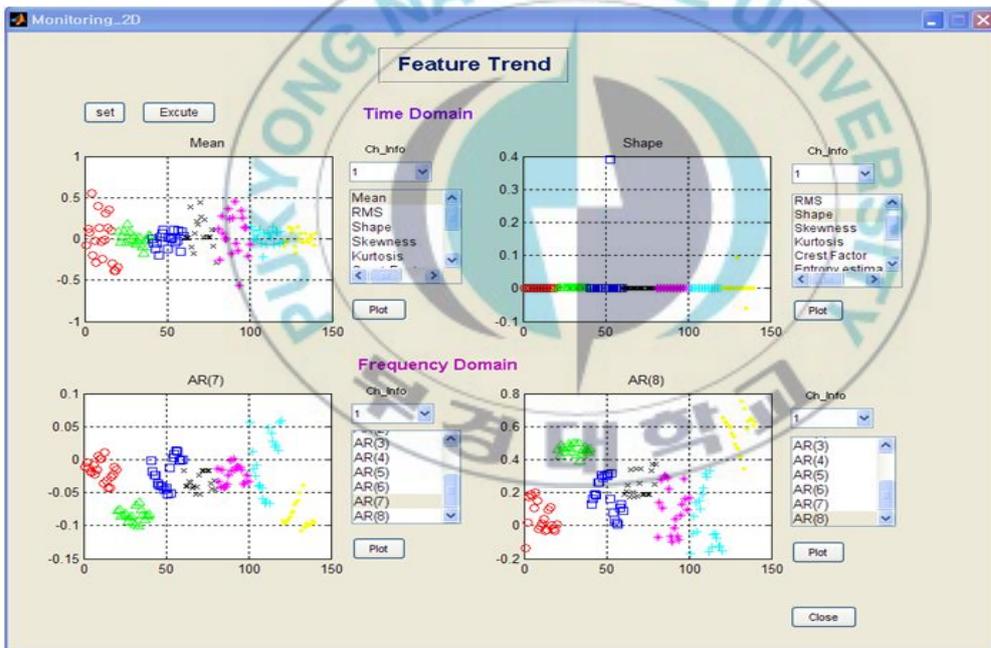


Fig. 5.9 The result of case based diagnosis module(3)

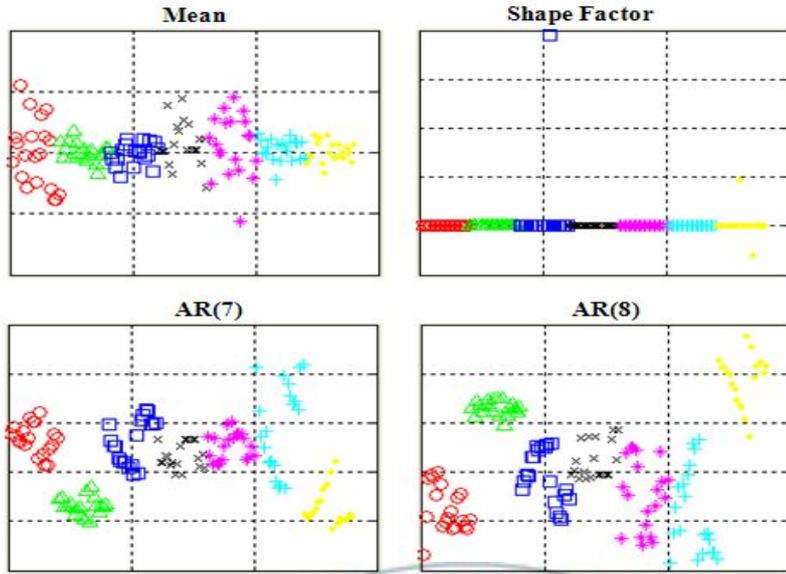
Fig. 5.7에 입력된 결함 주파수 정보를 바탕으로 Fig. 5.9에 나타나 있는 다양한 사례들 간의 유사성을 계산하여 어느 정도 유사하고 상관성이 있는지를 계산하게 된다. 계산된 유사도를 이용하여 유사성이 가장 높은 사례를 찾아 사용자에게 알려주는 것이 사례 진단 모듈의 최종 목적이라 할 수 있다.

5.2.2 특징값 상태감시

원동취수장의 사례는 결함 데이터를 얻을 수 없으므로 분류기의 학습을 위한 특징 추출과정을 수행할 수 없다. 진단 모듈의 성능을 검증하고자 Fig. 5.2에서 실험한 모의 모터 결함 데이터를 이용하기로 한다. 모의 모터 결함 방법은 총 7가지로 구성되며 Table 5.2에 요약되어 있다. 특징값 상태감시를 하기에 앞서 우선 상태를 잘 표현하는 우월한 특징값을 선정할 필요가 있다. 4.1장에서 설명했듯이 좋은 특징값은 특징공간상에서 일정한 영역에 수렴하여 군집을 이루는 특성을 보여주는데 이를 이용하여 특징값을 선별하게 된다.



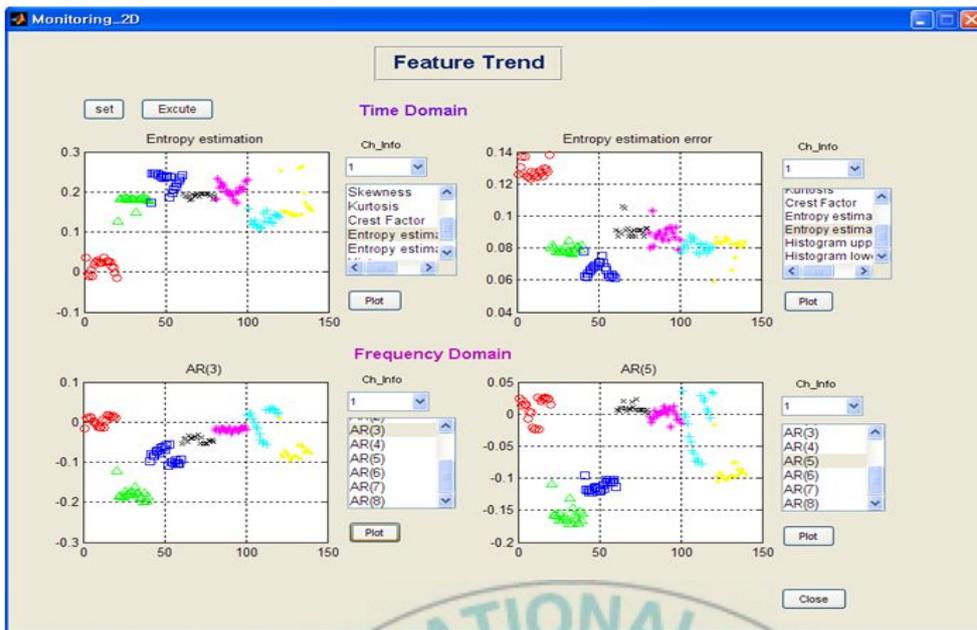
(a) Software plot



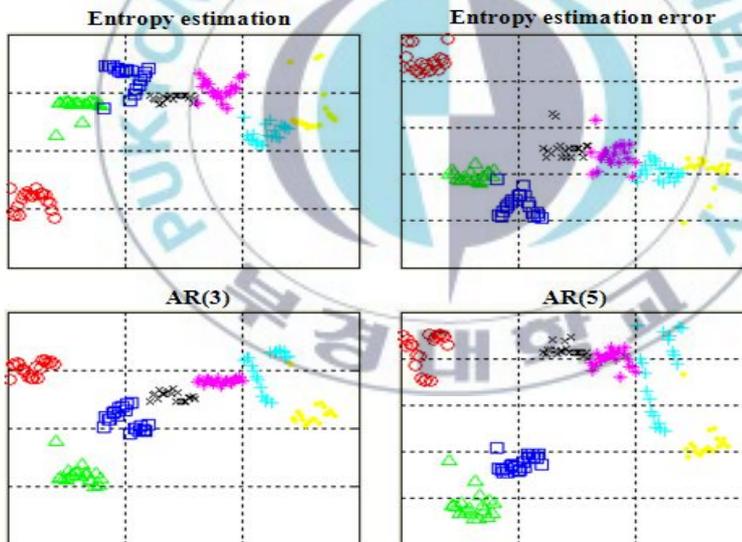
(b) Zoom plot

Fig. 5.10 The result of bad feature

Fig. 5.10의 결과는 나쁜 특징들을 나타내고 있다. 7개의 결함데이터는 색상으로 구분되며, 각 결함별로 20개의 데이터 샘플에 해당하는 특징값을 계산하여 특징공간에 표현하였다. 같은 색상은 같은 결함이므로 일정한 영역 내에서 군집을 형성해야한다. Fig. 5.10에서 볼 수 있듯이 좌측 상단은 평균을 특징값으로 선택한 예로 군집을 이루지 못하고 산포(scattering)되어 있음을 알 수 있다. 우측 상단은 형상 계수(shape factor) 값을 특징값으로 선택한 결과이며 7개의 결함에 대한 결과가 거의 동일하여 전혀 특성을 반영하지 못하고 있다. 하단의 두 그래프에서는 일정 부분 군집을 이루는 형태를 가지고 있으나 분포 범위가 상당히 넓으므로 좋은 특징이라고 할 수 없다.



(a) Software plot



(b) Zoom plot

Fig. 5.11 The result of good feature

Fig. 5.11은 좋은 특징값 선택 시의 결과를 보여 준다. 좌측 상단부터 엔트로피 평가(entropy estimation), 엔트로피 평가 오차(entropy estimation error), AR(3), AR(5)이 특징값으로 선택되었을 때의 결과이다. 각 결함별로 특정 영역에 잘 수렴하고 있는 것을 확인할 수 있으며, 정의된 특징값의 특성에 따라 결과가 조금씩 다른 것을 알 수 있다.

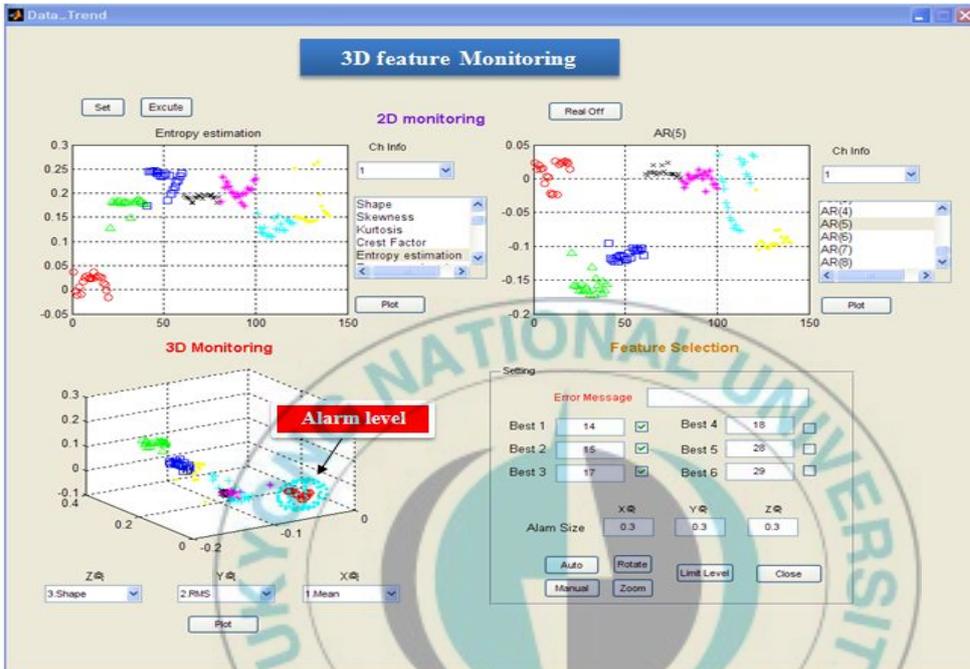


Fig. 5.12 The result of 3D feature monitoring

Fig. 5.12는 선택되어진 특징을 3차원의 각 축으로 정의하여 특징공간을 형성하고 3차원 공간에서 각 축 방향으로 동시에 특징의 변화를 감시하는 기법을 소개한다. 본 기법은 3차원 공간으로 특징을 정의함으로써 다차원으로 이루어진 특징값들의 차원 수를 줄일 수 있어 효율이 높아지고, 3가지의 특징을 동시에 감시할 수 있다는 이점을 가지고 있다. 하단의 그래프에서 보이듯이 정상상태의 데이터를 중심으로 알람 레벨 경계면이 구의 형태로 형성되는 것을 볼 수 있는데, 이 경계면은 정상데이터의 특징값 집합 중심과 중심으로부터 가장 먼 거리를 가진 데이터까지의 반경을 계산하여 구를 형성하게 되며 이때

에도 거리를 계산하기위해 유클리디언 벡터거리를 이용하였다. 형성된 경계면을 기준으로 정상 특징값의 크기가 경계면을 넘게 되면 개발 소프트웨어는 알람 경고 메시지를 발생한다.

5.2.3 진단 및 예지모듈

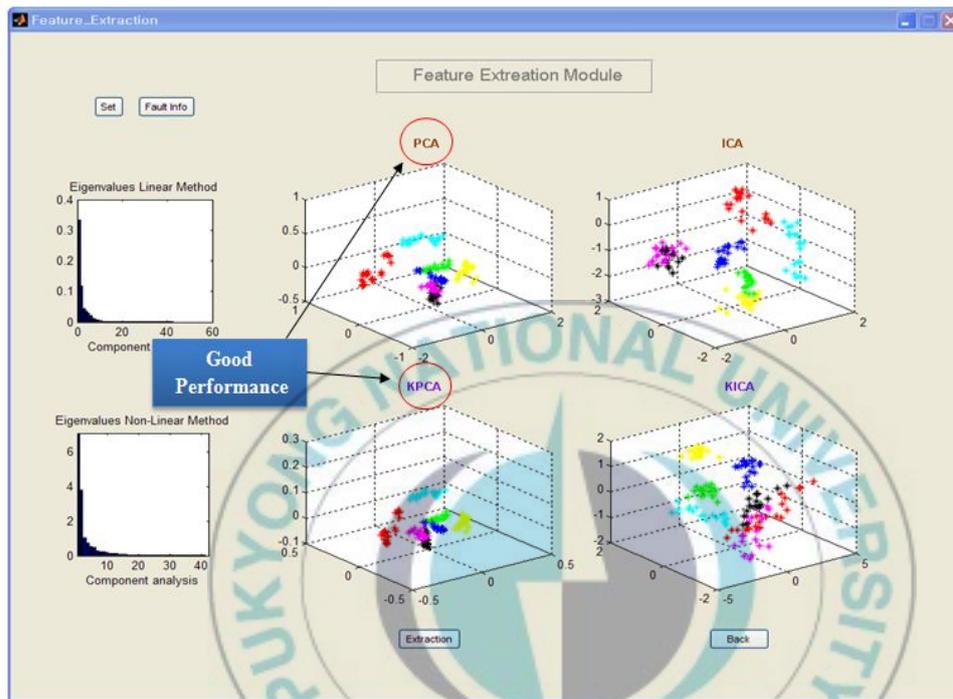


Fig. 5.13 The result of feature extraction

개발 소프트웨어에서 알람 메시지가 발생되면 진단이 수행되며, 이에 앞서 특징 추출이라고 하는 과정을 통해 진단 모듈의 분류기를 학습하기위한 학습 데이터를 얻어야 한다. 특징 추출과정에서 학습에 도움이 되고 학습량이 적으면서도 결함에 대한 특징을 명확히 포함하도록 하기위해서 PCA, ICA, KPCA, KICA와 같은 알고리즘을 도입하게 된다. 이 네 가지의 특징 추출 결과의 성능을 확인하기위해 Fig. 5.13과 같이 그래프 상에 표현을 하게 되며, 특징을 선택하는 과정에서 좋은 특징을 선별하는 것과 같은 기준을 이용하여 좋은 성능

을 지닌 특징 추출 알고리즘을 찾을 수 있다. 결과적으로 본 경우에는 PCA, KPCA의 성능이 양호한 것으로 나타났으며, 이를 이용하여 진단 모듈에 속해 있는 5개의 분류기의 학습데이터로 사용하도록 한다.

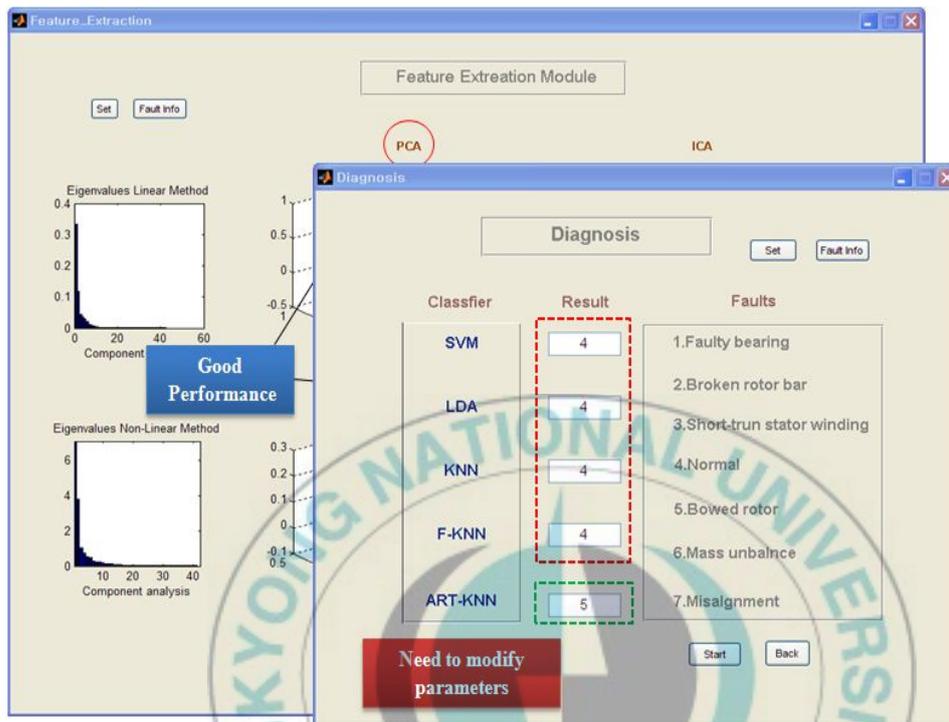


Fig. 5.14 The result of diagnosis module

Fig. 5.14는 앞의 결과를 토대로 성능이 좋았던 PCA를 이용하여 훈련시킨 분류기의 결과를 보여준다. 진단 모듈은 SVM, LDA, k-NN, F-kNN, ART-kNN으로 5개의 분류기로 구성되어 있으며, 우측에는 모의 모터 결함의 7가지 결함에 대한 인덱스를 표시하였다. 본 사례는 정상 상태의 데이터를 입력한 사례이며, 그에 따른 결과는 Fig. 5.14의 해당 결과란에 표현되었다. 상위의 4개의 분류기는 정상 데이터에 대한 ‘정상’이라고 하는 같은 결과를 표현하였으며, 반면 ART-kNN은 ‘굽은 로터’라고 하는 다른 결과를 표현하였다. ART-kNN의 결과가 다른 이유는 각 분류기에는 사용자가 임의로 입력해야 하는 설정 파라미터가 존재하며 이는 분류기마다 조금씩 다를 뿐 아니라 분류기

의 성능에도 지대한 영향을 미치게 된다. 그러므로 ART-kNN에 대한 설정 파라미터에 대한 수정이 필요하다.

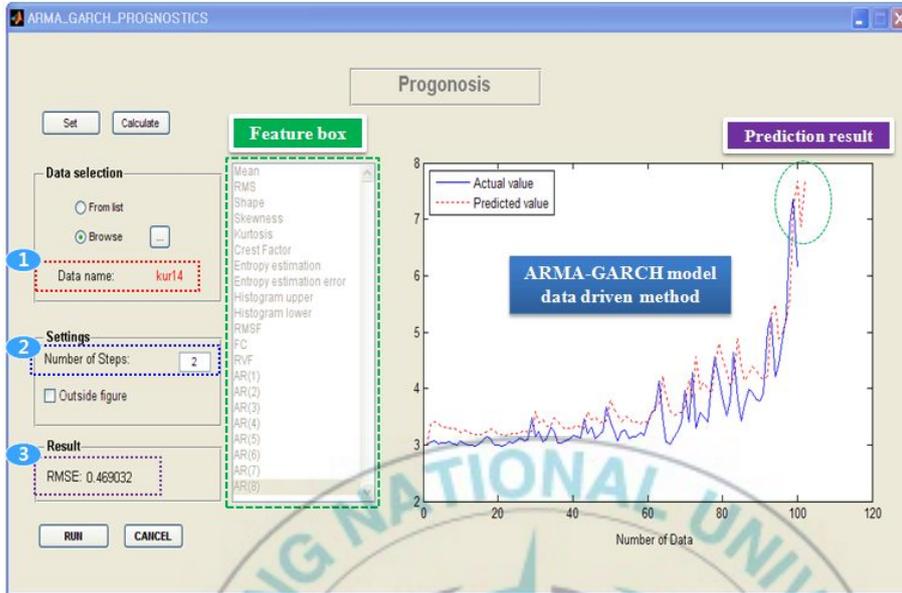


Fig. 5.15 The result of prognosis module(1)

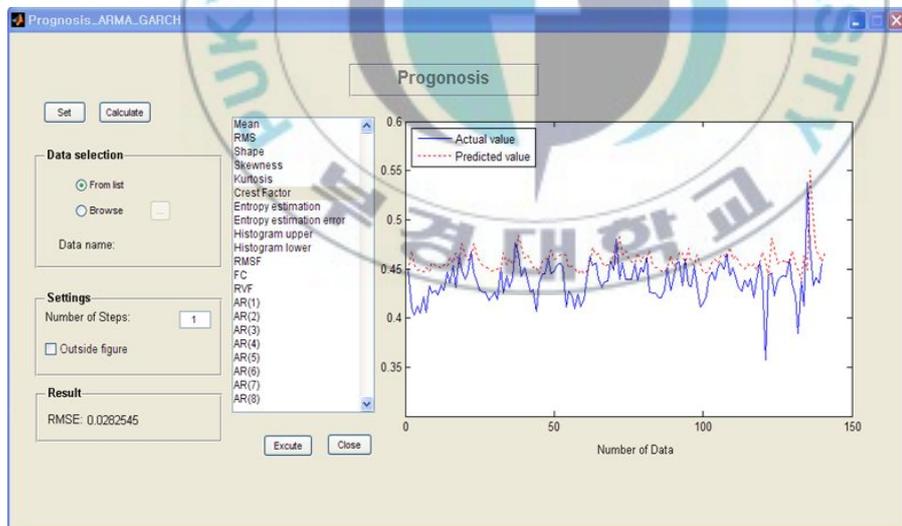


Fig. 5.16 The result of prognosis module(2)

Fig. 5.15, 5.16은 예지 모듈의 결과이다. 개발 소프트웨어의 예지 모듈에서는 RUL(remaining useful life)을 계산하지 않으며 데이터의 미래를 예측하는데 중점을 두고 있다. Data driven 방식을 이용한 ARMA-GARCH 모델을 도입하였으며, 특징 값으로 침도가 선택되었다. 2 step-ahead 을 적용하여 나타낸 결과가 Fig. 5.15의 우측 그래프에 나타내었다. 파란 실선은 실제 데이터이고 붉은 점선은 예측된 데이터이며, 본 사례의 경우 예측결과는 지속적으로 증가하는 것을 알 수 있다. 예지 모듈의 성능을 평가하기위해 RMSE(root mean square error)를 사용하였다. 본 사례의 경우 1 step-ahead에서 10 step-ahead 까지를 적용해 보았으나 실제 데이터와 예측 데이터 간의 오차를 평가하는 RMSE의 값이 스텝(step) 수를 증가시킬수록 높은 오차값이 보여 1에서 2 step-ahead 방법이 예측을 하는데 있어 적절한 것으로 나타났다.



제 VI장 결론

원동취수장에서 계측된 데이터는 센서 자체의 감도 문제와 각 결합에 대한 이력데이터의 부족으로 충분한 검증 결과를 도출하지 못하였다. 이를 보완하기 위해 모의 결합 데이터를 이용하여 특징값 감시 및 진단 모듈을 검증해본 결과 각 결합에 대한 특성을 잘 반영하는 좋은 특징값을 찾는 것이 명확히 구분되었으며, 이를 바탕으로 3차원 특징 공간에서도 정상상태와 결합 상태간의 구분이 확연하게 나타났음을 확인하였다.

또한 진단에 필요한 특징 추출 과정에서 PCA와 KPCA의 성능이 뛰어났으며, 이를 바탕으로 모의 모터 결합 데이터의 경우 PCA에서 도출된 추출 특징값을 분류기의 학습데이터로 사용하였다. 그 결과 정상 데이터에 대한 응답으로 4개의 분류기는 같은 결과를 표현한 반면 ART-kNN 분류기는 설정 파라미터의 결과로 다른 결과 표현하였다. 하지만 파라미터의 수정이 적절하게 만족된다면 더 좋은 결과를 기대할 수 있을 것으로 보인다.

예지 모듈의 결과는 다수개의 데이터 추이를 예측하는데 중점을 두고 있으며 본 사례에서는 특징값을 침도로 선택하여 수행한 결과 기계의 성능저하를 잘 예측하는 것으로 나타났다. 하지만 다수개의 데이터를 예측할수록 예측 값과 실제 값 간의 오차가 기하급수적으로 커지므로 1개 또는 2개의 데이터를 예측하는 것이 타당할 것으로 판단된다.

본 연구를 통해 구축하고자 하였던 무선 기반의 CBM 시스템은 소프트웨어의 일부 모듈 수정과 무선 계측 시스템의 안정성 및 신뢰성이 일정 부분 확보된다면 그 목적을 충분히 달성할 것으로 기대한다. 특히 수행된 사례 적용 결과 개발 소프트웨어가 실질적인 문제에 대해서도 어느 정도 타당하고 합리적인 분석 결과를 도출하였음을 알 수 있으며, 이는 기계 상태 진단에 대한 추출 정보로서 유용하게 사용될 수 있음을 시사한다. 앞으로 개발 소프트웨어의 지속적인 개발과 함께 좀 더 다양한 사례 정보를 수집할 수 있다면 더욱 광범위한 문제에 대해서도 유용하고 실질적인 정보를 제공할 수 있을 것으로 기대한다.

참고 문헌

- [1] J. Yick, B. Mukherjee and D. Ghosal, Wireless sensor network survey, *Computer Networks*, (2008), Vol.52, No.12, pp.2292-2330.
- [2] K.S. Jardine, D. Lin and D. Banjevic, A review on machinery diagnostics and prognostics implementing condition-based maintenance, *Mechanical Systems and Signal Processing*, (2006), Vol.20, No.7, pp.1483-1510.
- [3] D. Lin, M. Wiseman, D. Banjevic and K.S, Jardine, An approach to signal processing and condition-based maintenance for gearboxes subject to tooth failure, *Mechanical Systems and Signal Processing*, (2004), Vol.18, No.5, pp.993-1007.
- [4] L. Liao, J. Lee, Design of a reconfigurable prognostics platform for machine tools, *Expert Systems with Applications*, (2010), Vol.37, No.1, pp.240-252.
- [5] Z. Hameed, S.H. Ahn and Y.M. Cho, Practical aspects of a condition monitoring system for a wind turbine with emphasis on its design, system architecture, testing and installation, *Renewable Energy*, (2010), Vol.35, No.5, pp.879-894.
- [6] C. Emmanouilidis, E. Jantunen and J. MacIntyre, Flexible software for condition monitoring, incorporating novelty detection and diagnostics, *Computer in Industry*, (2006), Vol.57, No.5, pp.516-527.
- [7] M.C. Pan, P.C, Li, and Y.R. Cheng, Remote online machine condition monitoring system, *Measurement*, (2008), Vol.41, No.8, pp.912-921.
- [8] J.D. Son, G. Niu and B.S. Yang, Development of smart sensors system for machine fault diagnosis, *Expert Systems with Applications*, (2009), Vol.36, No.9, pp.11981-11991.
- [9] S.D. Tae, J.D. Son, B.S. Yang and D.H. Kim, Smart sensor for machine condition monitoring using wireless LAN, *The Korean Society for Noise and Vibration Engineering*, (2009), Vol.19, No.5, pp.523-529.
- [10] M. Zvokelj, S. Zupan and I. Prebil, Multi variate and multiscale monitoring of large-size low-speed bearings using ensemble empirical mode

- decomposition method combined with principal component analysis, *MechanicalSystemsandSignalProcessing*, (2010), Vol.24, No.4, pp-1049-1067.
- [11] H. Dennis, *Signal processing for effective vibration analysis*, (1995), pp1-11.
- [12] Vibration school homepage, <http://vibrationschool.com/mans/Plots/SPlots10.htm>
- [13] T. Momono and B. Noda, *Sound and vibration in rolling bearings*, *Motion & Control NSK*, (1999), N0.6,
- [14] 양보석 편저, *기계설비의 진동 상태 감시 및 진단, 인터뷰전*, pp.328~335.
- [15] S. Orhan, N. Akturk and V. Celik, *Vibration monitoring for defect diagnosis of rolling element bearings as a predictive maintenance tool: Comprehensive case studies*, *NDT&E International*, (2006), pp.293-298.
- [16] Vibanalysis homepage, <http://www.vibanalysis.co.uk/vibanalysis/gears/gears.html>
- [17] 양보석 편저, *기계설비의 진동 상태 감시 및 진단, 인터뷰전*, pp.356~359.
- [18] J.S. Oh, S.W. Yang, M.C. Shim, W. Caesarend, B.S. Yang, and W.H. Lee, *Condition monitoring for coil break using features of stationary rolling region*, *The Korean Society for Noise and Vibration Engineering*, (2009), Vol.19, No.12, pp.1252-1259.
- [19] S.W. Yang, J.S. Oh, M.C. Shim, W. Caesarend, B.S. Yang and W.H. Lee, *Strip rupture detection system of cold rolling mill using transient current signal*, *Journal of the Korea Society for Power System Engineering*, (2010), Vol.14, No.2, pp.40-47.
- [20] 한학용, *패턴인식 개론: MATLAB 실습을 통한 입체적 학습*, 한빛미디어, (2005), pp.274-292.
- [21] 조용현, 박용수, 권경희, 김향현, 신경망 기반 독립성분분석을 이용한 효율적인 복합영상 분리, *정보통신부 정보통신연구진흥원*, (2002), pp.17-22.
- [22] 오상훈, *독립성분분석과 NMF의 특징추출 특성 비교*, 한국콘텐츠학회, (2007), pp.1-4.
- [23] A. Widodo, B.S. Yang and T. Han, *Combination of independent component analysis and support vector machine for intelligent faults diagnosis of induction motors*, *Expert Systems with Applications*, (2007), Vol.32, No.2, pp.299-312.

- [24] 한학용, 패턴인식 개론: MATLAB 실습을 통한 입체적 학습, 한빛미디어, (2005), pp.306-309.
- [25] Support vector machine, 영남 대학교 지능 제어 특론, pp.1-4.
- [26] A. Widodo, B.S. Yang, Application of nonlinear feature extraction and support vector machines for fault diagnosis of induction motors, Expert Systems with Applications, (2007), Vol.33, No.1, pp.241-250.
- [27] A. Widodo, E.Y. Kim, J.D. Son, B.S. Yang, A.C.C. Tan, D.S. Gu, B.K. Choi and J. Mathew, Fault diagnosis of low speed bearing based on relevance vector machine and support vector machine, Expert Systems with Applications, (2009), Vol.36, No.3, pp.7252-7261.
- [28] 이수은, 정용규, K-NN 알고리즘을 이용한 유방암의 예후분류, 학술발표논문집, (2009), Vol.36, No.2, pp.179-183.
- [29] 민준기, 조성배, K-최근접 템플릿기반 다중 부류기 결합방법, 한국정보과학회 34회 추계학술대회, (2008), Vol.14, No.4, pp.451-455.
- [30] 권세혁, http://wolfpack.hannam.ac.kr/lecture/Spring05/ETS/ch3_arma.pdf, 한남대학교 비즈니스통계학과, (2005), pp.25-29.
- [31] R. Engle, Autoregressive conditional heteroskedasticity with estimates of the variance of unite kingdom inflation, Econometrica, (1982), Vol.50, No.4, pp.997-1008.
- [32] T. Bolerslev, Generalized Autoregressive Conditional Heteroskedasticity, Journal of Econometrics, (1986), Vol.31, pp307-327.
- [33] H.T. Pham and B.S. Yang, Estimation and forecasting of machine health condition using ARMA/ GARCH model, (2010), Vol.24, No.2, pp.546-558.
- [34] 김상용, 김진아, 일반 자기회귀 이분산 모형을 이용한 시계열 자료 분석, Journal of the Korean Data Information Science Society, (2009), Vol.20, no.3, pp.475-483.
- [35] 김상봉, <http://www.brainkim.com.ne.kr/index2.htm>.
- [36] 고봉현, GARCH 모형을 이용한 수산물의 가격변동성에 관한 연구, 해양정책연구, Vol.22, No.2, pp.6-25.
- [37] 양보석 편저, 기계설비의 진동 상태 감시 및 진단, 인터비전, pp.128~129.

감사의 글

본 논문을 완성하기까지 정성 어린 지도와 끊임없는 관심으로 지도해 주신 양보석 교수님께 진심으로 감사드립니다. 항상 부족한 저를 위해 조언과 질타를 아끼지 않고 석사과정을 무사히 잘 마칠 수 있도록 끝까지 도와주신 저의 영원한 선배 종덕이 형과 카리스마와 부드러움을 가진 진정한 리더의 모습을 보여준 민찬이 형에게도 깊은 감사를 드립니다.

아픈 부모님을 모시면서도 내색 않고 곳곳이 내 옆을 지켜준 동기 원정이, 비록 나이는 어리지만 항상 마음의 벗이 되어주었던 고독한 철학자 정민이, 바쁜 회사 업무에도 불구하고 선배들을 세심하게 배려하는 해외파 선용이, 가장 먼저 들어왔지만 아직도 막내 생활을 면치 못한 훈민이, 얼떨결에 친구 보러 왔다가 같이 막내 생활 중인 수줍은 청년 홍기, 감춰진 운동신경만큼 공부도 열심히 하는 학구파 도운이, 아이 폰과 같은 최적의 삶을 꿈꾸는 외로운 여행자 진희, 4년째 역학 공부중인 역학 고시생 선민이, 항상 남자답고 쿨한 꽃미남 원석이, 언제나 맑은 미소로 선배들을 웃게 해준 스무 살 비타민 소연이, 나의 첫 해외 여행기를 함께해준 Tung 박사, 힘든 한국 생활에도 곳곳이 적응중인 Stenly 이 모두에게 감사의 말과 함께 저에겐 함께한 지난 시간이 너무 소중한 선물이며 평생을 간직하고 살겠다고 전하고 싶습니다. 그리고 많이 바쁘신 와중에도 늘 신경 써 주시고 챙겨주신 사모님께도 감사합니다. 마지막으로 언제나 등 뒤에서 묵묵히 지켜주신 영원한 후원자 부모님과 사랑스러운 우리 여동생에게도 감사의 마음을 전합니다.

아무것도 모르고 시작했던 때가 엇그제 같습니다. 교수님께 항상 처음과 같은 마음으로 미친 듯이 열심히 하겠다는 맹세와 함께 맥주잔을 비우며 시작했던 석사 생활이었습니다. 언제나 그렇듯 지금 와서 돌이켜보니 그 맹세를 다 하지 못하고 떠나게 되는 것 같아 죄스러운 마음이 듭니다. 비록 부족하고 실수투성이의 모습으로 석사생활을 마치게 되었지만, 매번 그날의 철없고 무모했던 모습과 같이 교수님에 대한 맹세를 가슴으로 기억하며 이에 부끄럽지 않은 삶이 되도록 언제 어디서나 어떠한 모습으로도 노력하며 살겠습니다. 끝으로 교수님의 쾌유를 기원하며 저의 글을 마치고자 합니다.