

공 학 석 사 학 위 논 문

Relevance Vector Machine을 이용한 전동기 결함진단



2013년 2월

부 경 대 학 교 대 학 원

메카트로닉스공학과

박 진 희

공 학 석 사 학 위 논 문

Relevance Vector Machine을 이용한 전동기 결함진단

지도교수 이 연 원

이 논문을 공학석사 학위논문으로 제출함.



2013 2월

부 경 대 학 교 대 학 원

메카트로닉스공학과

박 진 희

박진희의 공학석사 학위논문을 인준함



주	심	공학박사	이 일 영	인
위	원	공학박사	손 정 현	인
위	원	공학박사	이 연 원	인

목 차

I. 서 론	1
1.1 연구 배경	1
1.2 연구 내용	2
II. 특징 추출 및 분류이론	4
2.1 개요	4
2.2 특징 추출 파라미터	4
2.2.1 시간 영역	4
2.2.2 주파수 영역	9
2.2.3 Entropy 영역	11
2.3 특징 추출 알고리즘	14
2.3.1 PCA	14
2.3.2 ICA	18
2.4 분류 알고리즘	20
2.4.1 Relevance Vector Machine	20
2.4.2 Support Vector Machine	22
V. 전동기 결함 진단	26
3.1 실험장치	26
3.2 전동기 진동신호	27
3.2.1 데이터 취득	27
3.2.2 특징 추출	31
3.2.3 분류	34

3.3 전동기 전류신호	39
3.3.1 데이터 취득	39
3.3.2 특징 추출	43
3.3.3 분류	45
VI. 결론	50
참고 문헌	52
부록	54



Fault diagnosis of motor using RVM

Jin-Hee Park

Department of Mechanical Engineering,

The Graduate School,

Pukyong National University

Abstract

Recently Condition monitoring and fault diagnosis of a motor has been received considerable attention, which can increase machinery availability and performance, reduction in consequential damage, increase in machine life, and reduction in spare parts manufacturing and less maintenance. Since engineers with expert knowledge and experience are rare, intelligent systems are necessary in the world.

The aim of this study is to address the problem of detecting a motor fault and to find reliable methods for fault diagnosis

This paper introduces a general Bayesian framework for obtaining sparse solutions to classify predicting, and a practical model 'relevance vector machine' (RVM) by Michael E. Tipping. In this study, the data is acquired from motor using accelerometer sensors and current sensors.

RVM algorithm is applied for the intelligent condition classification and fault

diagnosis system of the motor. Also, the feature extraction is employed using principle component analysis (PCA), independent component analysis (ICA) and selecting feature value.

The results obtained shows that the RVM model has high accuracy and much less testing time. Also, results show that multi-class RVM produces promising results and has the potential for use in fault diagnosis of motor.



제 I 장 서론

1.1 연구 배경

전동기는 구조가 간단하고 견고하며 가격이 비교적 저렴하고 취급이 편리한 등의 이점으로 인해 산업계에서 가장 널리 사용되고 있다. 그러나 전동기는 최근 대용량화, 고속화에 따라 대규모화하고 있고, 고속의 운전 속도, 대규모의 하중 그리고 가혹한 운전 조건으로 인해 진동 소음과 관련된 트러블이 많이 발생하고 있다. 따라서 전동기의 품질을 보증하는 것은 전동기의 안정적인 기능 유지와 신뢰성 확보를 통한 품질 향상, 수명 연장을 위하여 무엇보다도 중요하다.⁽¹⁾

전동기의 구조는 터빈, 압축기 등의 다른 회전 기계에 비하여 비교적 단순한 구조를 가지고 있으나, 진동 및 소음의 특징은 매우 복잡하고 높은 주파수까지의 넓은 주파수 대역의 성분을 가지고 있다. 그러므로 전동기의 결함 분석에는 많은 현장 트러블 해결 경험과 사례 베이스의 구축, 고장 모드의 파악과 고장 원인과 증상과의 관계인 인과 행렬의 구축 등이 필요하고, 이를 이용한 체계적인 고장 원인 분석이 필요하다. 그러나 이상이나 고장이 발생했을 경우, 진동 데이터로부터 원인을 추정하는 데에는 매우 전문적인 지식이나 오랜 경험이 필요하다. 또한 원인 추정에 있어서 잘못된 판단은 큰 사고와 경제적 손실을 초래하는 경우가 많다. 이러한 배경으로 인해 진동 신호와 전류신호를 이용한 상태 감시 및 진단 기술의 자동화를 도모하고자 할 때에는 진동원인과 발생하는 현상과의 관계를 잘 표현 할 수 있는 기법이 요구되며 이에 대한 알고리즘이 개발 되고 있다.

이러한 알고리즘으로 Artificial Neural Networks(ANN), Self-Organizing

Feature Map(SOFM), Support Vector Machine(SVM) 등이 있다. SVM은 고차원의 비선형 패턴 분류에 있어서 좋은 분류 성능을 나타내며 적은 학습 데이터에 대해서도 인식 성능이 뛰어나다. 그러나 인위적으로 정하여야 하는 상수 값이 존재하는 점이 있으며 분류시간에 영향을 미치게 된다.⁽²⁻⁴⁾ 고 산업현장에서 중요한 설비일 경우 아주 짧은 시간 내에 결함을 인지함으로써 막대한 피해를 줄 일 필요가 있어 이러한 점을 보완하기 위하여 Relevance Vector Machine(RVM)이 제안하였다.

RVM은 비교적 최근의 이론으로 베이지의 확률이론에 근거하여 조건부 확률을 이용하여 유사한 데이터 집합간의 개연성을 확보할 수 있는 근거를 마련해 주었고, 본 연구에서는 전동기에서 발생할 수 있는 결함을 진단하기 위해 RVM 알고리즘을 이용한 결함진단 시스템을 제안하고, 인위적인 결함을 부여할 수 있는 실험 장치로부터 취득한 진동신호를 이용하여 제안된 알고리즘의 유용성을 확인 하였다.

1.2 연구 내용

본 연구에서는 전동기에서 발생하는 결함들을 취득된 신호로부터 다양한 특징(feature)을 계산하고 이로부터 유용한 특징추출(feature extraction)을 통해 RVM을 이용하여 전동기의 결함진단 알고리즘을 구성하고 전동기에 인위적으로 결함을 부여 할 수 있는 실험장치를 통하여 분류화 성능을 검토하였다.

우선 이에 대한 배경지식으로 제 2장에서는 RVM의 훈련(training) 및 테스트(test) 과정에 사용되는 입력 파라미터인 특징 파라미터에 대한 기본적인 이론과 특징 추출 방법과 분류 방법에 대하여 설명하였다.

제 3장에서는 실험장비에서 얻은 진동 데이터와 전류데이터로 시간영역에서

특징값을 계산하였고, 특징값으로 분류가 잘되도록 특징추출을 하였다. RVM과 SVM 알고리즘의 성능을 비교하기 위해 RBF커널함수와 커널파라미터 γ 를 동일하게 하였고, 다중분류화를 위해 one-against-all 방법으로 하였다. 이러한 과정을 통하여 RVM과 SVM을 이용하여 분류하였다.

제 4장에서는 본 연구의 주요 결론을 요약하였다.



제 II 장 특징 추출 및 분류

2.1 개요

진동 신호는 기계의 각 상태에 따른 일정한 진동 특징을 가지고 있다. 그러므로 진동을 측정하고 분석함으로써 기계의 상태 파악과 각종 결함 원인을 진단할 수 있다. 진동의 측정은 시간에 따른 진동 진폭의 변화를 측정하게 되며 측정된 시간 신호를 기반으로 적절한 신호처리기법을 통하여 기계의 상태에 따른 진동 특징을 추출할 수 있다. 이러한 과정을 특징추출(feature extraction)이라고 하며, 특징 추출의 기본원칙은 다음과 같다.

- 1) 특징량을 정확하게 선택하여야 한다.
- 2) 동일한 특징량은 시각에 따라 변하지 않고 일정한 값이어야 한다.
- 3) 서로 다른 상태의 특징량 사이에는 뚜렷한 구별이 있어야 한다.
- 4) 특징량의 수는 각 상태를 충분히 표현할 수 있는 조건 하에서 가능한 적어야 한다.

2.2 특징 추출 파라미터

2.2.1 시간 영역

1) 평균(Mean)

평균은 시계열 신호의 전체를 대표하는 값으로써 식(2.1)과 같이 표현된다.

$$\bar{x} = \frac{x_1 + x_2 + \cdots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.1)$$

평균은 모든 관측값들에 포함된 정보에 기초하지만 극단적인 관측값의 영향에 민감하다. 즉, 아래와 같은 성질을 가지고 있다.

① 계열 신호의 각각의 값들의 편차의 합은 0이다.

$$\sum_{i=1}^n (x_i - \bar{x}) = 0 \quad (2.2)$$

② 평균에 대한 시계열 신호의 각각의 값들의 편차의 제곱합은 다른 임의의 값에 대한 각각의 값들의 제곱합보다 작다.

$$\sum_{i=1}^n (x_i - \bar{x})^2 \leq \sum_{i=1}^n (x_i - a)^2 \quad (2.3)$$

2) 표준편차(Standard deviation)

시계열 신호의 산포를 측정하는 척도로 분산과 표준편차가 사용가능하지만 표준편차가 분산에 비해 의미가 있는 척도이다. 분산은 관측값들의 제곱한 단위를 사용하지만 표준편차는 관측값과 같은 단위를 사용한다. 따라서 표준편차를 이용해서 시계열 신호의 구조를 해석하기가 용이하다. 표준편차의 정의식은 식(2.4)와 같다.

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.4)$$

3) 왜도(Skewness)

시계열 신호에 대한 관측값들의 확률밀도함수 분포의 대칭 정도와 방향을 나

타내는 값을 왜도라고 한다. 평균과 분산이 차원을 가지고 있지만 왜도는 무차원수이다. 만일 단봉형 분포에서 긴 왼쪽 꼬리를 가지면 음의 왜도(negative skewness)를 가지며 좌비대칭이라 하고, 오른쪽으로 긴 꼬리를 가지면 양의 왜도를 가지며 우비대칭이라 한다. 왜도는 왜도 계수의 절대치가 커질수록 비대칭정도가 커짐을 의미하고 우비대칭이면 양수, 좌비대칭이면 음수, 대칭이면 0의 값을 가진다. 왜도를 계산하는 방법은 다음과 같다.

① Pearson 방법

평균과 중앙값(또는 최빈값)의 차이를 표준편차로 나눈 값으로 구하는 방법이다.

$$\beta_1 = \frac{\bar{x} - \text{mode}}{\sigma} \approx \frac{3(\bar{x} - \text{median})}{\sigma} \quad (2.5)$$

여기서, mode는 최빈값, median은 중앙값을 의미한다.

② 평균에 대한 표준편차의 비를 이용한 방법

왜도의 적률계수(moment coefficient of skewness 혹은 anomaly)를 구하는 방법으로 가장 많이 사용된다. 평균으로부터 편차를 세제곱하여 표준편차의 세제곱으로 나눈 값이다.

$$\beta_1 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^3}{\sigma^3} \quad (2.6)$$




Fig. 2.1 The relation of skewness and probability density function

4) 첨도(Kurtosis)

첨도는 파형의 4차 모멘트를 표준편차 σ^4 으로 나누어 규격화한 값으로 파형의 진폭 크기와 관계없이 파형의 형태에 의해 결정된다. 또한 피크치가 강조되는 베어링이나 기어등에서 얻어지는 신호의 정량화, 평가 및 진단에 이용된다.

첨도는 시계열 신호의 확률밀도함수 분포가 갖는 첨예의 정도를 나타내는 척도이다. 앞에서 설명한 평균, 표준편차, 왜도가 모두 같다고 하더라도 자료의 분포 형태가 다른 경우가 있을 수 있으며, 따라서 자료의 양적 구조를 나타내기 위해 관측값들이 중심에 집중되는 정도를 나타내는 값인 첨도가 필요하게 된다. 첨도의 적률계수의 정의는 식(2.7)와 같다.

$$\beta_2 = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{\sigma^4} \quad (2.7)$$

시계열 신호가 정규분포를 가질 경우 첨도 계수는 3이며, 첨도 계수가 3 이

상일 경우 정규분포보다 뾰족한 분포가 되고(급첨: leptokurtic), 3보다 작을 경우 완첨(platykurtic)이 된다.




Fig. 2.2 The relation of kurtosis and probability density function

5) 실효치(RMS)

진동의 심한 정도를 나타내는 특성인 진동 진폭을 정량화 하는 하나의 방법으로 RMS값을 사용하고 있다. 이는 평균치의 정보나 scatter의 정보(분산)가 포함되어 있으며 시간에 대한 변화량을 고려하고 진동의 파괴적 능력을 나타내는 에너지량과 직접 관련된 진폭을 표시하므로 진동 크기의 표현에 가장 적절하다. RMS의 정의는 식(2.8)와 같다.

$$x_{rms} = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}} \quad (2.8)$$

6) 형상계수(Shape factor)

진동의 overall값에 대한 진동 평균의 비를 나타낸다.

$$SF = \frac{x_{ms}}{\bar{x}} \quad (2.9)$$

7) 파고율(Crest factor)

진동의 Peak값과 overall값의 비를 나타내며, 베어링이나 기어의 결함을 식별하는데 사용되고 있다. 이 값은 신호 검출 센서나 사용되는 증폭기의 gain과 관계없이 파형이 갖는 특징을 나타낸다. 파고율의 정의는 식(2.10)과 같다.⁽⁵⁾

$$CF = \frac{x_p}{x_{ms}} \quad (2.10)$$

2.2.2 주파수 영역

1) Frequency center

Frequency center는 이산 시계열 신호를 전 주파수 대역에서 보았을 때 스펙트럼 밀도의 중심을 나타낸다. 이의 정의식은 식(2.12)과 같이 나타낸다.

연속 신호에 대한 Frequency center는 다음과 같다.

$$F/C = \frac{\int_0^{+\infty} f \cdot s(f) df}{\int_0^{+\infty} s(f) df} \quad (2.11)$$

이산 신호에 대한 Frequency center의 정의식은 다음과 같다.

$$F/C = \frac{\sum_{i=2}^n \dot{x}_i \cdot x_i}{2\pi \sum_{i=1}^n x_i^2} \quad \text{여기서 } s(f) \text{는 파워 스펙트럼을 말한다.} \quad (2.12)$$

2) Mean square frequency

연속 신호에 대한 Mean square frequency는 다음과 같다.

$$MSF = \frac{\int_0^{+\infty} f^2 \cdot s(f) df}{\int_0^{+\infty} s(f) df} \quad (2.13)$$

이산 신호에 대한 Mean square frequency는 다음과 같다.

$$MSF = \frac{\sum_{i=2}^n \dot{x}_i^2}{4\pi^2 \sum_{i=1}^n x_i^2} \quad (2.14)$$

3) Root mean square frequency

$$RMSF = \sqrt{MSF} \quad (2.15)$$

4) Variance frequency

전 스펙트럼에서 중심 주파수를 중심으로 다른 성분의 주파수들 사이의 분산을 나타내는 값이다.

$$VF = \frac{\int_0^{+\infty} (f - FC)^2 \cdot s(f) df}{\int_0^{+\infty} s(f) df} \quad (2.16)$$

또는

$$VF=MSF-(FC)^2 \quad (2.17)$$

5) Root variance frequency

$$RVF=\sqrt{VF} \quad (2.18)$$

2.2.3 Entropy 영역

1) Entropy estimation 및 entropy error

엔트로피(Entropy)라는 용어는 정보이론에만 등장하는 것이 아니고 물리학이나 화학 등에서 에너지의 상태를 표시하기 위하여 오래 전부터 사용되어 왔다. 그러나 정보이론의 체계에서 정의되는 엔트로피의 개념은 이러한 자연과학적 의미에서 벗어나 정보의 양(amount of information)을 평가하는 기준으로서 정보공학적 의미를 갖는다.[6] 즉, 엔트로피는 불확실성의 척도로서 사용되어진다. 이 개념은 1940년대에 Shannon에 의해 제시되었었다.

확률론적인 관점에서 추정치와 실제 파라미터 벡터 x 사이의 오차 v_i 는 확률변수(random variables)이며 Z^m 에 속한다. Entropy function은 식 (2.19)과 같이 정의된다.

$$H(x)=\int p(x) \cdot \ln p(x) dx \quad (2.19)$$

여기서, $\tilde{x}$ 는 estimation error, $p(\tilde{x})$ 는 밀도함수(density function), $p(\tilde{x}/z^m)$ 는 조건밀도함수(conditional density function), 그것의 moments Ex^n , Z^m 은 상태 공간내의 추정치의 집합을 나타낸다. 또한 아래의 Orthogonal- projection이론에 의하여 entropy error값을 계산할 수 있다.

[Orthogonal-Projection 이론]

- ① $\hat{x}(k/m) \in Z^m$
- ② $\tilde{x}(k/m) = \hat{x}(k/m) - x(k)$ 은 Z^m 내에서 모든 벡터들은 직교이다.
- ③ $\hat{x}(k/m)$ 은 Hilbert 상태공간 X 에서 유일하다.
- ④ estimation error $\tilde{x}(k/m)$ 는 $E\{\|\tilde{x}(k/m)\|^2\}$ 이다. 그리고 error

는

최소 공분산을 가진다. 즉 $E\{\tilde{x}(k/m)\tilde{x}^T(k/m)\} = \min$ 을 가진다.




Fig.2.3 Orthogonal projection

2) Lower bound와 upper bound

Lower bound와 upper bound는 시계열 신호에 대한 히스토그램과 관련하여 상한과 하한의 경계값을 나타내고 있다. 이들의 정의식은 식 (2.20)과 같다.

$$\begin{aligned} \text{Lower} &= \max(\mathbf{x}) - \frac{\text{delta}}{2} \\ \text{Upper} &= \max(\mathbf{x}) + \frac{\text{delta}}{2} \end{aligned} \quad (2.20)$$

여기서, $\text{delta} = \frac{\max(\mathbf{x}) - \min(\mathbf{x})}{n-1}$ 이다.



2.3 특징 추출 알고리즘

2.3.1 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. 2.4 Relation between performance and dimension

Fig. 2.4에서 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.

PCA를 통해 얻고자 하는 것은 Fig. 2.5와 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 주축을 통계적 방법으로 구하고 구해진 추축 방향으로 특징 벡터들을 Fig. 3.6과 같이 사영(projection)함으로써 차원을 축소할 수 있다. 사영은 행렬의 내적을 이용하게 된다.

PCA를 통하여 변환행렬을 구하는 것은 다음의 절차에 따라 계산한다.⁽⁶⁾

- 데이터의 평균벡터를 구하고 분산-공분산 행렬 Σ 를 계산한다.

$$m(\text{평균벡터}) = \frac{1}{N} \sum_{n=1}^N X_n \quad (2.21)$$




Fig. 2.5 The process of PCA

Fig. 2.6 The result of projection through product

여기서, X_n : 특징 벡터, N : 특징 벡터 개수

$$\sum(\text{공분산 행렬}) = \frac{1}{N-1} \sum_{n=1}^N (x_n - \mathbf{m})(x_n - \mathbf{m})^T \quad (2.22)$$

- 고유분석을 통해 고유값을 계산한다.

$$\lambda_i u_i = \sum \cdot u_i \quad \text{여기서, } \lambda_i : \text{고유값} \quad u_i : \text{고유벡터} \quad (2.23)$$

- 고유값이 높은 순서대로 정렬하고 가장 큰 m 개의 고유값을 선택한다.

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

$$W = [u_1 \cdots u_i] \quad (2.24)$$

- 특징 벡터를 다음의 변환식으로 나타낸다.

$$y = W^T x \quad (2.25)$$




Fig. 2.7 The summary of PCA process

2.3.2 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. ICA는 데이터의 통계적 독립성을 판정하기 위해 확률밀도함수와 역행렬을 이용한다. ICA 모델은 식 (2.26)과 같다.

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{S} \quad (2.26)$$

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.

$$\mathbf{S} = \mathbf{W} \cdot \mathbf{X} \quad (2.27)$$

입력 신호 $\mathbf{S}$ 는 식 (2.27)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 (3.20)과 식 (3.21)를 이용하면, 식 (2.28), (2.29), (2.30)을 얻게 된다.⁽⁷⁾

$$X = A \cdot W \cdot X \quad (2.28)$$

$$I = A \cdot W \quad (2.29)$$

$$A^{-1} = W \quad (2.30)$$


ICA의 계산 과정을 요약하면 다음과 같다.

Step 1. 진동 신호 디지털 변환

Step 2. (진동 신호 계측 채널 수) x (데이터 수) 행렬 구성

Step 3. 분리 행렬(W) 계산, 독립 성분 행렬 계산

Step 4. 진동 신호 재구성



2.4 분류 알고리즘

2.4.1 Relevance Vector Machine

RVM(relevance vector machine)은 베이지 정리를 이용한 사후확률을 구하여 그 확률이 높은 집단으로 주로 2개의 범주를 분류하는 이진 분류기이다. 그리고 통계적 방법이며 $\sigma(y) = 1/(1 + e^{-y})$ 함수를 $y(x)$ 에 대입하고 $P(t|x)$ 를 위해 베르누이 분포에 적용하면 우도는 식(2.31)와 같다.

$$P(t|w) = \prod_{n=1}^N \sigma y(X_n; w)^{t_n} [1 - \sigma y(X_n; w)]^{1-t_n} \quad (2.31)$$

w의 최대우도추정은 과다접합(over fitting)을 발생시킬 수 있다. 이를 피하기 위해, RVM은 베이지 관점에서 적용되어졌고, auto relevance determination(ARD) 사전분포는 각 가중치 w_n 에 개별 초평면 α_n 을 정했다. 그러므로, 사전가중치 분포는 식(2.32)와 같다.

$$p(w|\alpha) = \prod_{n=0}^N \left(\frac{\alpha_n}{2\pi} \right)^{\frac{1}{2}} \exp - \frac{\alpha_n}{2} w_n \quad (2.32)$$

α 는 N+1 초평면 벡터이다. 이러한 방법은 MacKay에 의해 제안되어졌고, 라플라스 방법으로 다음과 같이 적용되어졌다.

1) α 의 고정값을 위해 주어진 사후분포를 통해 최대사후가중치를 알아야 한다. w의 사후분포는 식(2.33)와 같다.

$$p(w|t, a) = \frac{p(t|w)p(w|a)}{p(t|a)} \quad (2.33)$$

$p(w|t, \alpha) \propto P(t|w)p(w|a)$ 이후 식(2.34)의 w 최대값을 계산하는 것과 같다.

$$\log P(t|w)p(w|a) = \sum_{n=1}^N [t_n \log y_n + (1 - t_n) \log(1 - y_n)] - \frac{1}{2} w^T A w \quad (2.34)$$

2) 라플라스 방법은 근사치가 적용된다. 식(2.34)와 식(2.35)은 두배정도 차이가 난다.

$$\nabla_w \nabla_w \log p(w|t, \alpha)|_{w_{MP}} = -(\Phi^T B \Phi + A) \quad (2.35)$$

3) 초평면은 식(2.36)을 통해 변환다.

$$\alpha_i^{new} = \frac{\gamma_i}{u^{2_i}} \quad (2.36)$$

$\gamma_i \equiv 1 - \alpha_i \sum_{ii}$ 에서 $\sum_{ii}$ 는 $\Sigma = (\Phi^T B \Phi + A)^{-1}$ 의 공분산의 I번째 대각 요소이고, u 는 $w_{MP} = \Sigma \Phi^T B t$ 와 비슷하다.

다중클래스에서 RVM은 one-against-all 방법으로 분류를 한다. 이러한 방법으로 독립적으로 n분류를 한다.

$$P(t|w) = \prod_{n=1}^N \prod_{k=1}^K \sigma y_k(x_n; w_k)^{t_n k} \quad (2.37)$$

$t_n k$ 는 클래스 k 에 있는 n 관찰하기 위한 변수이다. 다중클래스 우도로써 식(2.38)와 같다.⁽⁸⁻¹⁰⁾

$$P(t|w) = \prod_{n=1}^N \prod_{k=1}^K \sigma(y_k; y_1, y_2, \dots, y_k)^{t_{nk}} \quad (2.38)$$

2.4.2 Support Vector Machine

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 (2.39)과 같다.

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (2.39)$$

여기서 $\mathbf{w}$ 는 가중치 벡터이고, b 는 bias 항이다. 훈련벡터 x_i 와 분리경계면과의 거리를 마진(Margin)이라고 하고, 식 (2.40)와 같이 표현한다.

$$m = \frac{\mathbf{w}^T \mathbf{x} + b}{\|\mathbf{w}\|} \quad (2.40)$$

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.

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

$$\text{minimize } \|w\|^2 \quad (2.41)$$

$$\text{subject to } y_i(w^T x_i + b) \geq 1 \quad (2.42)$$

위의 최적화 문제는 LM으로서 구할 수 있으며, 식 (2.42)와 같다.

$$L(w, b, \alpha_i) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w x_i + b) + \sum_{i=1}^N \alpha_i \quad (2.43)$$




Fig. 2.8 The concept of SVM

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

$$(2.44) \quad \frac{\partial L}{\partial w} = w - \sum_i \alpha_i y_i x_i = 0, \quad \frac{\partial L}{\partial b} = - \sum_i \alpha_i y_i = 0$$

식 (2.44)을 식 (2.45)에 대입하여 다시 정리하면,

$$L(w, b, \alpha_i) = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1} \alpha_i \quad (2.45)$$

식 (2.45)의 두 번째 항이 최소이면, 조건 α 에서 L 은 최대로 되므로, 이 것은 결국 QP 문제가 된다.

$$\text{maximize} \quad -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j x_i^T x_j + \sum_{i=1} \alpha_i \quad (2.46)$$

$$\text{subject to} \quad \sum_i \alpha_i y_i = 0, \quad \alpha_i \geq 0 \quad (2.47)$$

SVM이 효과적인 이유는 저차원에서 비선형인 데이터 집합을 보다 높은 차원에서 볼 때 선형성을 띤다고 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. 2.9와 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 변

환 즉 사상을 Φ 라 하면, 커널 함수와 특징 공간의 관계는 식 (2.48)와 같다.⁽¹⁰⁻¹³⁾

$$K(x, \acute{x}) = \Phi(x)^T \Phi(\acute{x}) \quad (2.48)$$




Fig. 2.9 Transformation to higher dimensional space.

제 Ⅲ장 전동기결함 진단

3.1 실험 장치

실험 장치는 Fig. 3.1는 전동기, 벨트, 풀리, 축, 팬으로 구성되어 있다. 정상 상태 모터와 결함모터의 상태에 대하여 진동신호와 전류신호를 연속적으로 20 개씩 6가지 상태로 총 120개의 시간신호를 취득하였다. 샘플링 데이터 개수는 16384개 이다.

Fig 5.2에서는 전동기에 인위적으로 결함 낸 부분 나타내었고, Table 5.1은 결함에 대해 정보를 나타내었다.



Fig. 3.1 Test rig

Table. 3.1 Description of fault motor

Fault condition	Fault description	Others
Normal	No fault	
Bowed rotor	Maximum bowed shaft deflection	Air-gap:0.25mm
Faulty bearing	A spalling on outer raceway	
Eccentricity	Parallel and angular misalignments	Adjusting the bearing pedestal
Broken rotor bar	No. of broken bar:12 ea	Total number of 34 bars





Fig. 3.2 Fault condition


3.2 전동기 진동 신호

3.2.1 데이터 취득


모터의 베어링 하우징 부분에 가속도 센서를 이용하여 데이터를 취득하였고, Fig. 3.3에서 각 결함 상태에서 취득한 시간 파형을 나타내고 Y축은 중력 가속도(G)값을 나타내고 있다. Fig.3.3(a) 정상상태 시간신호와 Fig.3.3(d) 불평형 상태 시간신호의 진폭이 비슷하게 나타나는 것을 확인 할 수 있었고, Fig. 3.3(e) 평형 정렬불량 상태와 Fig. 3.3(f) 각 정렬불량 상태간의 진폭이 유사하게 나타나는 것을 확인 할 수 있었다. 그리고 Fig. 3.3(g) 회전자 바 깨짐 상태는 6가지 상태와는 다른 진폭이 낮게 나타남을 확인 할 수 있었다.




(a) Normal condition




(b) Bowed rotor condition




(c) Faulty bearing condition



(d) Parallel misalignment condition



(e) Angular misalignment condition



(f) Broken rotor bar condition

Fig. 3.3 The time signals from rotor

3.2.2 특징추출

각 결합상태들의 특징값을 계산 후 PCA, ICA 알고리즘을 이용하여 결합의 군집이 잘 되도록 하였다. 그리고 Fig.3.4는 21가지 특징값들의 유효성 평가 결과를 보여주고 있다. 유효성 평가는 각 상태내의 데이터의 차를 다 구하여 합하고 상태들의 거리의 차의 합에 나눔으로써 상태내의 데이터 군집이 잘되었는지와 상태간의 거리가 떨어진 정도를 나타냄으로써 Fig. 3.5에서 유효성 값이 크게 나타나는 7번째 특징값(Frequency center)과 2번째 특징값(RMS) 2가지를 선택하였다.

Fig. 3.5은 알고리즘을 통하여 특징 추출된 파라미터 값들과 선택된 파라미터 값을 나타내었고, 각 결합당 20개의 값을 2차원에 맵핑(mapping) 시켰다. 그리고 X축과 Y축은 특징값을 정규화 시킨 값들이다.

선택된 파라미터가 군집이 잘 이루어진 것을 Fig. 3.5(a)를 통해 확인 할 수 있었다. 6가지의 상태가 조밀하게 군집이 잘되어 있다. PCA 알고리즘을 이용한 방법도 Fig. 3.5(b)를 보게 되면 특징값을 선택한 Fig. 3.5(a) 보다는 조밀하지 않지만 좋은 군집 형태를 나타내고 있다. ICA 알고리즘을 이용한 방법인 Fig. 3.5(c) 경우는 3가지 상태씩 섞여 있어 좋은 군집이라 할 수 없다.






Fig. 3.4 Test for effectiveness



(a) Selected feature



(b) PCA



(c) ICA

Fig. 3.5 Feature extraction using vibration data

3.2.3 분류

전동기 결함진단을 위해 분류 알고리즘으로 RVM을 이용하였다. 총 데이터는 120개이며 훈련을 위한 데이터로 90개(결함 상태당 15개), 테스트 데이터로 30개(결함 상태당 5개)를 사용하였다. RVM과 비교를 위하여 SVM 알고리즘을 이용하였으며 동일하게 다중 분류화를 수행하기 위해 One-against-all 기법과 RBF 커널 함수를 사용하였고, 커널 파라미터 γ 을 0.5로 동일하게 하였다. SVM 에서는 매개변수 C 값을 정확도가 높게 나오는 값으로 설정하였다.

RVM과 SVM을 이용하여 분류결과를 나타낸 Table 3.2 와 Table 3.3에서 두 알고리즘의 분류 정확도가 특징값을 선택한경우와 PCA를 이용한 경우는 분류정확도가 같게 나왔으나 ICA를 이용한 경우에는 RVM이 좋지 않은 분류 정확도를 나타내었다.

Fig. 3.6를 보게되면 RVM Test 결과를 볼 수 있다. 특징값을 선택한 경우와 PCA는 분류가 잘된 것을 볼 수 있고, ICA를 이용한 방법은 분류가 잘 되지 않았다.

Fig. 3.7을 보게되면 SVM Test 결과를 볼 수 있다. RVM과 동일하게 특징값을 선택한 경우와 PCA는 분류가 잘된 것을 볼 수 있고, ICA를 이용한 방법은 분류가 잘 되지 않았다.

RVM과 SVM의 RV의 개수와 SV의 개수를 Table 3.2와 Table 3.3를 통해 보면 RVM에서는 특징값을 선택한 경우는 29개이며 분류시간은 4.19s이 반면 SVM에서는 특징값을 선택한 경우는 43개이며 분류시간 또한 7.98s로 조금 오래 걸리는 것을 확인할 수 있다.

PCA를 이용한 경우 RV의 개수는 26개 이지만 SV의 개수는 20개이었다. 그

러나 분류시간은 RVM 5.05s 이며 SVM은 5.56s로 RVM을 이용한 경우가 RV의 개수가 많았음에도 분류시간이 적게 걸리는 것을 확인할 수 있었다.


ICA를 이용한 경우는 분류 정확도는 특징값을 선택한 경우와 PCA를 이용한 경우보다 낮고 RVM을 이용한 분류가 안되는 것을 확인 할 수 있었다. 그리고 SVM을 이용한 경우는 Parameter C값이 커지면서 분류시간이 오래 걸리는 것을 확인할 수 있었다.

Table 3.2 RVM classification result


Component analysis	Training accuracy(%)	Test accuracy(%)	Total accuracy(%)	No.of RV	Time(s)
Selected features	100	100	100	29	4.19
PCA	100	100	100	26	5.05
ICA	10	11.11	10.8	16	4.37

Table 3.3 SVM classification result


Component analysis	Training accuracy(%)	Test accuracy(%)	Total accuracy(%)	No.of SV	Parameter C	Time(s)
Selected features	100	100	100	43	32	7.98
PCA	100	100	100	20	16	5.56
ICA	40	76.66	67.5	78	256	51.0



(a) Selected using RVM




(b) PCA using RVM



(c) ICA using RVM

Fig. 3.6 Classification using RVM



(b) PCA using SVM






Fig. 3.7 Classification using SVM


3.3 전동기 전류신호

3.3.1 데이터 취득


Fig.3.1 의 왼쪽 하단 부분에 전류 센서를 이용하여 데이터를 취득하였고, Fig. 3.8에서 각 결함 상태에서 취득한 시간 파형을 나타내고 Y축은 전류단위 (mA)를 나타내고 있다. Fig.3.8에서 나타나는 시간신호에서는 6가지 상태의 최대진폭이 거의 비슷하게 나타나는 것을 확인할 수 있었다.




(a) Normal condition




(b) Bowed rotor condition




(c) Faulty bearing condition



(e) Parallel misalignment condition



(f) Angular misalignment condition



(g) Broken rotor bar condition

Fig. 3.8 The time signals using current sensor

3.3.2 특징추출

각 결합상태들의 전류신호를 이용하여 특징값을 계산하여 앞서 진동신호를 이용한 방법과 동일하게 진행을 하였다. 그리고 Fig.3.9는 14번째 특징값 (Auto-regression coefficient(1))과 15번 특징값 (Auto-regression coefficient(2))을 선택하였다.

Fig. 3.10에서는 진동신호와 동일한 방법으로 알고리즘을 통하여 특징 추출된 파라미터 값들과 선택된 파라미터 값을 나타내었고, 각 결합당 20개의 값을 2차원에 맵핑 시켰다.

Fig. 3.10(a)를 통하여 선택된 파라미터 군집을 확인 할 수 있는데 6가지 상태중 4가지 상태는 군집이 잘되었으나 2가지 상태인 회전축 휨과 평행정렬불량의 데이터가 아주 근접하게 있어 좋지 않다. 그리고 PCA 알고리즘을 이용한 방법은 Fig. 3.10(b)를 통해 보면 6가지 상태 모두 군집이 잘되어 있는 것을 확인 할 수 있었다. 마지막으로 ICA 알고리즘을 이용한 방법을 Fig.






Fig. 5.9 Test for effectiveness


3.10(c)를 통해 보게되면 6가지 상태중 3가지 상태간에 데이터가 겹쳐있어 좋지 않은 특징추출을 보이고 있다.



(a) Selected feature



(b) PCA



(c) ICA

Fig. 3.10 Feature extraction using current data

3.3.3 분류

전동기 결함진단을 전류센서를 이용한 데이터를 제외한 진동신호를 이용한 방법과 동일하게 분류를 하였다.

Table. 3.4와 Table. 3.5에서 두 알고리즘의 분류 정확도를 보게되면 특징값을 선택한 경우와 PCA를 이용한 경우는 RVM을 이용하였을 때 정확도가 SVM 보다 높게 나타났으나, ICA는 진동데이터를 이용한 경우와 같게 RVM을 이용한 경우는 분류 정확도가 낮게 나타나는 것을 확인할 수 있었다.

그리고 RV와 SV의 개수를 비교함에 있어서 RV과 적으며 분류시간 또한 SVM을 이용한 경우보다 적을 것을 확인할 수 있었다. 특징값을 선택한 경우 RV의 개수는 20개이며 분류시간은 3.616초인 반면에 SV의 개수는 46개이며

분류시간 또한 11.18초로 높게 나타나는 것을 확인할 수 있었다. PCA의 경우에도 RV의 개수는 26개이며 분류시간은 3.84초인 반면에 SV의 개수는 33개이며 분류시간도 7.53초로 약 2배정도 오래 걸리는 것을 확인할 수 있다.


ICA의 경우는 RV의 개수는 20개이며 분류시간은 3.55초이며 SV의 개수는 89개이며 시간은 137.3초로 벡터의 개수에 의한 걸리는 시간이 크게 영향을 미치는 것을 확인할 수 있었다.

Table 3.4 RVM classification result


Component analysis	Training accuracy(%)	Test accuracy(%)	Total accuracy(%)	No.of RV	Time(s)
Selected features	96.6	93.3	94.1	20	3.616
PCA	100	98.8	99.1	26	3.84
ICA	3.3	10.0	8.3	20	3.55

Table 3.5 SVM classification result


Component analysis	Training accuracy(%)	Test accuracy(%)	Total accuracy(%)	No.of SV	Parameter C	Time(s)
Selected features	90	92.21	91.6	46	128	11.18
PCA	96.6	98.8	98.3	33	16	7.53
ICA	36.66	68.88	60.8	89	256	137.3



(a) Selected feature




(b) PCA




(c) ICA


Fig. 3.11 Classification using RVM



(a) Selected feature



(b) PCA



(c) ICA

Fig. 3.12 Classification using SVM

제 IV 장 결론

본 연구에서는 전동기의 결함을 진단함에 있어서 현실적인 문제인 전문지식을 소유한 진단 전문가의 부족과 기계 설비의 상태감시 및 진단의 자동화를 위하여 RVM 알고리즘을 제안하였다.

실험장비에서 얻은 진동 데이터와 전류데이터로 시간영역에서 특징값을 계산하였고, 특징값으로 분류가 잘 되도록 특징추출을 하였다. RVM과 SVM 알고리즘의 성능을 비교하기 위해 RBF커널함수와 커널파라미터 γ 를 동일하게 하였고, 다중분류화를 위해 one-against-all 방법으로 하였다. 이러한 과정을 통하여 RVM과 SVM을 이용하여 분류하였다.

RVM과 SVM을 이용한 분류 방법에서 PCA와 특징값을 선택한 특징추출에서는 두 분류기법중 RVM이 분류정확도가 높게 나타났으며 분류시간에서도 더 빠른 시간에 분류하는 것을 확인 할수 있었다. 그리고 파라미터 C값의 선택과 Vector의 개수도 시간의 경과에 영향을 미치는 것을 확인 할수 있었다.

ICA를 이용한 특징추출에 의한 분류에서는 확연히 RVM은 군집이 좋지 않았고 분류의 정확도에서도 SVM에 비해 현저히 낮게 나타나는 것을 확인 할수 있었다. 이렇듯 분류이전의 단계에서도 분류의 정확도에 영향을 미치는 것을 확인할 수 있었다.

그리고 진동데이터의 경우 특징추출에서 군집이 아주 명확하게 되어 RVM과 SVM 둘 다 분류정확도가 100%가 나왔고, 전류데이터의 경우엔 RVM과 SVM 둘 다 분류정확도가 90% 이상으로 아주 높은 분류 정확도를 확인 할수 있었으나 분류시간에서는 전류데이터를 이용한 경우가 약 0.5초에서 3.3초 정도 빠르게 나타나는 것을 확인할 수 있었다. 이렇듯 중요한 설비의 경우에

는 전류데이터로 확인 후 진동데이터를 확인함으로써 현장에서 소프트웨어로 사용되면 높은 정확도와 비용을 절감 효과가 있을 거라 생각된다.



참고문헌

- (1) 양보석, “전동기의 결합 분석”, GMK, 2008.
- (2) L. Liao, J. Lee, Design of a reconfigurable prognostics platform for machine tools, Expert Systems with Applications, (2010), Vol.37, No.1,
- (3) 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,
- (4) 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,
- (5) 김전경, 박진호, 박헌진, 이재준, 전홍석, 황진수, “통계학”, 자유아카데미
- (6) 오상훈, 독립성분분석과 NMF의 특징추출 특성 비교, 한국콘텐츠학회, (2007)
- (7) 한학용, 패턴인식 개론: MATLAB 실습을 통한 입체적 학습, 한빛미디어, (2005)
- (8) M. E. Tipping, "Sparse Bayesian Learning and the Relevance Vector Machine," Journal of Machine Learning Research, vol.1
- (9) Y. Li, Y. Huang, C. Liu, S. Fei, "Relevance Vector Machine Based Gear Fault Detection", Pattern Recognition. CCPR 2009
- (10) Widodo. A, Kim. E. Y., Son. J. D. Yang. B. S. Tan. Andy C. C., Gu. D. S., Choi. B. K., Mathew. J., "Fault diagnosis of low speed bearing based on relevance vector machine and support vector machine" Exper systems with applications, vol.36 no.3, pp.7252-7261, 2009.
- (11) W. W. Hwang, M. H Goh, B. S. Yang, "Cavitation Condition Monitoring of

Butterfly Valve Using Support Vector Machine”, Transactions of the Korean society for noise and vibration engineering, vol14, pp119-127, 2004.

(12) 황원우, “Support Vector Machine을 이용한 회전기계의 상태 분류 및 결함 진단”, 부경대 공학석사 학위논문, 2004.

(13) 양승욱, “Support Vector Machine을 이용한 냉간 압연기의 판 터짐 결함 검지”, 부경대 공학석사 학위논문, 2010.



[부록]

전동기의 결함 진동 특성

A.1 개요

전동기에서 발생하는 기계적인 결함들은 펌프, 압축기, 터빈 등의 각종 회전 기계에서 발생하는 결함과 동일한 문제를 일으킨다. 회전자의 기계적인 결함은 질량 불평형, 축 굽힘, 정적 편심, 동적 편심과 정렬불량 등이 있고, 고정자의 기계적결함은 고정자 편심과 철심 이완 등이 주를 이룬다. 더욱이, 회전자의 편심을 발생시키는 베어링 결함은 유도 전동기에서 가장 흔한 기계적 결함이다. 그리고 회전자와 고정자 사이의 접촉, 고정자와 회전자의 피로와 같은 결함은 위에서 언급한 결함에 의해 2차적으로 야기되는 결함들이다.[1]

A.2 정렬불량

정렬불량(misalignment)은 불평형과 같이 진동원인의 대부분을 차지한다. 대부분의 기계는 단품으로 작동되기 보다는 모터 또는 엔진과 같이 동력을 발생시키는 기계요소와 송풍기, 펌프 등과 같이 특별한 용도로 이용되는 기계 요소와의 결합으로 이루어져 있다. 때문에 두 기계요소의 결합이 요구되는데 이 때 커플링에 의한 결합이 일반적이다. 정렬불량이라는 것은 구동축과 피동축이 같은 중심선 상에 있지 않기 때문에 높은 진동이 발생하는 현상을 말한다. 정렬불량이 있으면 회전체 축이 강제적으로 굽혀지기 때문에, 외관 상의

초기굽힘이 생기고, 그것에 의해 진동을 발생한다.


정렬불량에는 Fig. 1와 같이 편심 정렬불량(parallel misalignment), 편각 정렬불량(angular misalignment) 그리고 편심 및 편각 정렬불량이 혼합된 복합 정렬 불량의 3가지로 나눌 수 있다. 주요 진동 특성을 살펴보면 아래와 같다.

- 1) 진동 신호의 시간 파형은 조화 파형(harmonic waveform)이다.
- 2) 반경방향의 진동 주파수 스펙트럼에서 1X 성분과 2X 성분을 주요 성분으로 나타나며 대부분의 경우 1X 성분보다 2X성분이 크게 나타난다.
- 3) 축 방향의 진동주파수 스펙트럼에서 1X 성분이 크게 나타난다.
- 4) 전형적인 축의 휘돌림은 전향(forward)이며 궤적(orbit)은 바나나형상이다.
- 5) 진동은 하중에 민감하고, 진폭은 하중의 증가에 따라 증가한다.



(a) Parallel misalignment

(b) Angular misalignment



(c) Combined misalignment

Fig. 1 Misalignment type

불평형과 정렬불량은 기계 고장 중 가장 일반적인 형태로 매우 빈번하게 나타나며, 모든 고장의 원인이 되기 때문에 항상 중요하게 생각해야 한다. 또한 심하지 않는 정렬불량에 의한 진동은 축 중심이 회전중심과 어긋나기 때문에 불평형에 의한 진동과 같이 회전 속도 성분의 피크가 높게 나타나게 된다. Table 1.1에는 불평형과 정렬불량에 의한 진동특성의 차이를 나타내었다.

Table 1 The difference between unbalance and misalignment

불평형 진동	정렬 불량
· 1X에서 높은 진동 발생 · 반경방향에 대한 높은 진동 진폭 · 온도변화와 무관 · 속도증가와 비례한 진동 특성 · 부하에 둔감	· 1X에 대한 높은 하모닉 성분 · 높은 축방향 진동 · 온도변화에 따른 진동특성 변화 · 속도변화에 둔감 · 커플링이 lock 되었을 때 부하에 민감

A.3 베어링 결함

베어링(bearing)은 회전기계의 운전 신뢰성 및 성능에 직접적인 영향을 미치는 가장 중요한 핵심 기계요소 중의 하나이다. 일반적인 회전기계에서 발생하는 많은 문제들은 주로 베어링 자체의 결함이나 또는 베어링과 연관되어 발생한다. 따라서 베어링에서 발생하는 사소한 문제는 회전기계 시스템 전체의 운전에 영향을 미칠 뿐만 아니라 시스템의 운전 정지에 따른 엄청난 경제적 손실을 초래한다. 여기서는 마찰 손실이 적고 수명이 긴 구름요소 베어링의 일반적인 결함특성에 관하여 설명한다.

Fig. 2는 대표적인 구름요소 베어링인 볼 베어링의 구조를 나타내고 있으며, 외륜, 내륜, 전동체 그리고 리테이너로 구성되어 있다. 볼 베어링은 구조상 극히 작은 틈새(clearance)를 갖고 있으며, 축에서부터 전달된 진동 신호는 베어링의 전동체를 통하여 베어링의 외륜까지 전달되어져서 결국에는 베어링의 하우징까지 전달 되어진다.

볼 베어링의 고장의 원인에 대한 특정한 주파수가 검출되며, 이 때 측정된 진동의 크기로 베어링의 상태를 알 수 있다. 볼 베어링에서 나타나는 기본적인 4가지 진동 주파수는 다음과 같다.




Fig. 2 Geometry of ball bearing

· 기본열 주파수(fundamental train frequency, FTF):

$$FTF = \frac{ns}{2} \left[1 - \frac{Bd}{Pd} \cos \phi \right]$$

· 볼 자전 주파수(ball spin frequency, BSF):

$$BSF = \frac{Pd}{2Bd} (rps) \left[1 - \left(\frac{Bd}{Pd} \right)^2 \cos^2 \phi \right]$$

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

$$BPFO = N(FTF)$$

· 내륜 통과 주파수(ball pass frequency of inner race, BPFI) :

$$BPFI = N(rps - FTF)$$

여기서, Bd는 볼의 직경, Pd는 피치 직경, N은 볼의 수, rps는 내륜의 1초당 회전수를 말한다.

A.4 축 휨

일반적으로 베어링으로 지지된 채로 정지하고 있거나 회전 운동 또는 회전 요동 운동을 하여 물체를 받치면서 동력을 전달시키는 기계 요소를 축이라 하고, 전동기 회전자 축은 동력 전달을 위한 폴리, 기어, 냉각 팬 등이 부착되어 있는 경우가 많다. 축은 주어진 운전 조건과 하중 조건하에서 파손되지 않도록 충분한 강도와 함께 처짐과 비틀림이 어느 한도 내에 있도록 필요한 강성을 가지도록 설계된다. 그러나 설계 단계에서 고려된 설계 하중보다 과대한 하중의 작용에 의한 응력이 축에 작용하게 되면 축의 파손 등의 고장이 발생하게 된다.




Fig. 3 A typical example of the load acting on the shaft

축 고장의 원인을 결정하기 전에 축에 작용하는 힘인 축 하중에 대한 명확한 이해가 필요하다. **Fig. 3** 는 피로 파손을 초래할 수 있는 전동기 축 부하의 가장 일반적인 3가지의 하중 형태를 나타낸다. 내다지 하중은 굽힘 피로와 축 마찰을 일으키며, 축방향 하중은 베어링 고장을 그리고 비틀림 하중은 비틀림 파손을 일으킬 수 있다. 설계 응력집중이 발생하기 쉬운 전동기 축의 단면 부분을 Fig. 4 에 나타내었다. 응력 집중은 베어링 shoulder, 스냅 링 홈, 키 홈, 축 나사 홈과 같은 축 표면의 불연속 부분에서 주로 발생한다. 축 손상이나 부식 역시 응력을 증가시킬 수 있다. 피로 균열과 고장은 통상 이 부분에서 발생한다. 전동기에서 가장 일반적으로 발생하는 위치는 Fig. 4 에서 베어링 저널의 shoulder(H) 나 커플링 키 홈(J) 부분이다. 축 손상의 가장 일반적인 부분은 H에서 J 부분이다. 대부분의 베어링 고장은 축방향 하중의 결과로 발생한다.




Fig. 4 Rotor shaft stress concetration location

1.5 회전자 봉 파손

회전자의 결함 문제는 주로 다이캐스팅 회전자의 주조 불량 또는 조립 회전자에서 빈약한 용접이나 경랍 땀에 의한 높은 저항의 조인트로부터 발생한다. 이러한 경우 봉에 발생하는 불균일한 응력은 피할 수 없다. 그러나 흔히 대부분의 고장은 피로에 의해 야기되는 봉의 파괴에 기인하여 발생한다. 이는 급속 제동과 가속 주기 동안에 필연적으로 회전자 내에 높은 응력을 받는 불균일하고 무거운 부하 운전을 하는 기계에서는 일반적으로 나타나는 현상이다.

회전자 봉의 파손의 주요 원인으로는 아래와 같다

- 1) 열적 과부하 및 불균형, 고온점 또는 과대한 손실, 불꽃
- 2) 전자기력, 불평형 자기 흡인력(UMP), 전자기 소음과 진동에 기인하는 자기 응력
- 3) 제작 문제에 기인하는 잔류 응력
- 4) 축 토크, 원심력 및 주기적인 응력들로부터 발생하는 동적 응력
- 5) 오염 또는 습기 등에 의한 회전자 재료의 연삭 마멸에 기인하는 환경적인 응력
- 6) 적층의 헐거움, 피로 부품이나 베어링 고장에 의한 기계적인 응력 등이 있다.

감사의 글

먼저 이 논문이 나오기까지 부족한 저에게 정성 어린 지도와 관심을 주신 지도교수 이연원 교수님께 깊은 감사 드립니다. 아울러 이 분야의 관심을 석사과정으로 이끌어 주신 (故) 양보석교수님께도 진심으로 감사드립니다. 또한 본 논문의 완성도를 높이기 위해 많은 조언을 해 주신 이일영 교수님, 손정현 교수님께 깊이 감사 드립니다.

2010년 봄에 연구실에 들어와서 졸업하는 지금 이 순간까지 저에게 관심과 도움을 주신 시크한 민찬이형, 정말 형같은 준석이형, 술황제 원정이형, 실험실의 리더같은 정민이형, 항상 밝은 선용이형, 동기인 도운이형과 회전기계에 대해 강의해주신 주호진선배님, 베어링에 대해 강의해주신 최성필 선배님, 회전체 동역학 강의해주신 최병근 선배님, 포스코파워에서의 업무에 관해 설명해주신 오용민선배님, 김선화선배님, 내진설계 부분에 도움주신 최원호 선배님, 그리고 실험실에 걱정해주신 이소환 선배님 외 졸업하신 선배님들께 감사드립니다. 그리고 실험실 생활에서 한 번씩 인연이 되었던 모든 사람들에게도 감사드립니다. 마지막으로 학업에만 매진 할 수 있도록 도와주시고 항상 믿어주신 부모님께도 감사드립니다.

아울러 이 논문에 관련된 모든 분들께 감사합니다.