

특징 추출과 검출 오차 최소화 알고리즘을 이용한 회전기계의 결함 진단

Fault Diagnosis for Rotating Machine Using Feature Extraction and Minimum Detection Error Algorithm

정 의 필* · 조 상 진* · 이 재 열*

Ui-pil Chong, Sang-jin Cho and Jae-yeal Lee

(2005년 1월 27일 접수 : 2005년 12월 12일 심사완료)

Key Words : Fault Diagnosis(결함 진단), Feature Extraction(특징 추출), Gradient Descent(기울기 강하), Wavelet Transform(웨이블릿 변환), Rotating Machine(회전 기계)

ABSTRACT

Fault diagnosis and condition monitoring for rotating machines are important for efficiency and accident prevention. The process of fault diagnosis is to extract the feature of signals and to classify each state. Conventionally, fault diagnosis has been developed by combining signal processing techniques for spectral analysis and pattern recognition, however these methods are not able to diagnose correctly for certain rotating machines and some faulty phenomena. In this paper, we add a minimum detection error algorithm to the previous method to reduce detection error rate. Vibration signals of the induction motor are measured and divided into subband signals. Each subband signal is processed to obtain the RMS, standard deviation and the statistic data for constructing the feature extraction vectors. We make a study of the fault diagnosis system that the feature extraction vectors are applied to K-means clustering algorithm and minimum detection error algorithm.

1. 서 론

회전기계에 이상이 발생했을 때, 막대한 경제적 손실이나 인명 피해를 가져올 수 있으므로 회전기계에 대한 이상 진단은 매우 중요하다.

다양한 기술들 중 중요한 방법의 하나가 회전기계의 진동신호를 측정하는 것이다. 이상 진단을 위해 진동신호에 대해 신호의 평균값 등의 특징 데이터를 결정하고 그 데이터를 이용하여 패턴 인식 등의 방법으로 이상을 진단하는 기술이 많이 이용되어 왔다. 그러나 회전기계의 진동은 종류, 용도, 사양 등

에 따라 각각 다르며 동일한 기계도 완전히 같은 진동을 갖지는 않으므로 단일 특징 데이터를 이용하는 것은 많은 제약이 따르고 또한 원하는 결과도 얻기 힘들다^(1,2).

이 논문에서는 회전기계의 이상 진단 연구를 위해 보일러 급수 펌프 구동을 위한 유도 전동기에 대해 정상 상태의 진동 신호 및 이상 현상의 원인에 맞추어 다양한 방법으로 이상 현상을 발생시킨 각 이상 상태별 진동 신호를 진동 센서를 통해 취득된 데이터를 이용하였다. 2장에서는 이러한 이상 상태에 대해 주파수 특성 등을 비교 분석한다. 3장에서는 각 상태의 진동신호를 웨이브릿 변환(wavelet transform)을 적용하여 나누어진 주파수 대역별 신호의 특징을 추출하기 위한 통계 데이터들에 대해 설명하였다. 4장에서는 3장에서 언급된 방법으로 구성된 특징 추출 벡터를 패턴 인식의 간단한 알고리즘인 K-means

† 책임저자 : 정희원, 울산대학교 컴퓨터정보통신공학부
E-mail : upchong@mail.ulsan.ac.kr
Tel : (052) 259-220, Fax : (052) 258-1687

* 울산대학교 컴퓨터정보통신공학부

clustering 알고리즘을 통해 초기 이상 진단을 하고 이상 진단의 정확성을 높이기 위해 검출 오차 최소화(minimum detection error) 알고리즘을 적용하여 이상 진단 시스템을 개선하였다.

2. 회전 기계의 이상

2.1 회전 기계의 이상 현상 및 원인

다양한 종류의 회전기계에서 발생할 수 있는 여러 가지 이상 현상은 회전기계의 용도, 사양, 크기 등에 따라 각기 다른 특성을 가지지만, 회전기계라는 구조적 특성 때문에 공통적인 이상 원인과 특성을 가지기도 한다. 이런 일부 공통적인 이상 원인들에 대해 이상 진단을 할 때 많이 이용될 수 있는 것이 진동 신호이다. 진동 신호는 이상 진단을 위해 고려되는 전기적 특성이나, 회전 방향, 온도 등의 다른 자료들에 비해 주변 환경에 영향을 적게 받고 비슷한 구조의 회전기계들에 대해 공통적으로 적용될 수 있다는 장점이 있다.

회전기계의 규모나 용도 등에 따라 다양한 종류의 이상이 발생하고 나타나는 특성 또한 달라서 모든 종류의 회전기계에 대해 단일한 이상 진단 시스템을 적용하는 것은 아주 어려운 일이므로, 공통적으로 많이 나타나는 이상 현상에 대한 연구가 우선되어야 한다.

이 논문에서는 회전기계 중에서 산업용, 가정용 등으로 일반적으로 널리 쓰이는 유도 전동기(Fig. 1)를 대상으로 연구하였다. 연구에 이용된 진동 신호의 데이터는 부경대학교 지능역학연구소에서 제공되었다.

유도 전동기에서 주로 이상이 발생하는 부분으로는 회전자축(shaft), 베어링(bearing), 회전자(rotor) 등이 있고, 이들 부분에서 질량 불평형(mass unbalance),

정렬 불량(misalignment), 베어링 결함(faulty bearing), 회전자봉 균열(broken rotor bar), 굽은 회전축(bowed rotor shaft) 등의 이상 현상들이 발생한다. 각각의 이상 현상을 간단히 정리하면 다음과 같다^(1,3).

(1) 질량 불평형

질량 불평형은 회전체의 기하학적 중심축과 질량 중심이 일치하지 않는 경우에 발생하며 회전체의 제작시의 오류 또는 운전시의 마모나 부식이 원인이 되어 발생한다.

(2) 회전축 정렬 불량

정렬 불량은 회전기계의 조립 시 또는 열 변형 등의 원인에 의해 발생하는 이상으로 회전축의 정렬이 평행하지 않은 상태이다. 크게 정렬 이상의 두 가지 현상으로 분류할 수 있는데, 각 정렬 불량(angular misalignment)은 회전축이 평행한 방향으로 놓여있지 않고 서로 다른 각도를 가진 상태이고 수평 정렬 불량(parallel misalignment)은 회전축의 높이가 어긋난 상태를 말한다.

(3) 베어링 결함

베어링은 회전축의 회전 운동을 좀 더 원활하게 하고 회전축의 하중을 지탱하는 역할을 한다. 베어링 결함은 회전축을 지지하는 베어링이 오랜 운전으로 열과 마찰 등으로 마모되는 상태로써 회전기계에서 가장 일반적으로 발생하고 이는 회전자의 편심을 유도하므로 다른 고장을 일으킬 수 있다.

(4) 굽은 회전축

기기를 장시간 가동 하지 않을 경우, 회전자 자체의 무게에 의해 회전축이 휘어지거나, 정렬불량의 상태로 운전했을 때 회전축이 강제로 굽혀지는 현상을 가져오게 되고 이것에 의해서 비정상적인 진동이 발생된다.

(5) 회전자봉 균열

유도 전동기의 회전자는 여러 개의 회전자봉(rotor bar)으로 구성되어 있는데, 이들 중 일부의 회전자봉에 손상 또는 균열이 생기게 되면 이상 진동이 발생하게 된다.

2.2 이상 상태의 진동 주파수 특성

Fig. 2의 정상 상태에서 진동 주파수 스펙트럼을 보면, 60 Hz 부근에서 회전주파수 성분이 크게 나타나고, 대부분의 성분들이 저주파 대역에 있음을 알 수 있다.




Fig. 1 Structure of induction motor

그러나 Fig. 3에서와 같이 질량 불평형 상태의 주파수 스펙트럼을 정상 상태 스펙트럼과 비교해보면, 다른 주파수 성분들의 진폭 변화는 적지만 회전주파수 성분이 많이 증가했고, 조화성분(harmonics)들도 조금씩 증가하는 것을 알 수 있다.

각 정렬 불량 및 수평 정렬 불량 상태에서는 질량 불평형에 비해 회전주파수 성분은 조금 증가하고 그 이상의 조화 성분들 중에서 특히 3차 및 4차 조화성




Fig. 2 Frequency spectrum of normal operation




Fig. 3 Frequency spectrum of unbalance condition




Fig. 4 Frequency spectrum of faulty bearing condition




Fig. 5 Frequency spectrum of bowed rotor shaft condition




Fig. 6 Frequency spectrum of broken rotor bar condition

분들 크게 증가했으며, 그 이상의 조화 성분도 크게 증가한다.

Fig. 4의 베어링 결함 상태의 주파수 스펙트럼을 보면, 회전주파수가 약간 감소하고 정상상태에서는 발생하지 않았던 고주파수 성분이 전체적으로 크게 증가한 것을 알 수 있다.

Fig. 5에서는 굽은 회전축의 경우로서 회전주파수를 포함한 저주파수 성분이 전체적으로 많이 감소하고, 1 kHz 이상의 고주파수 성분이 크게 증가한다.

Fig. 6의 회전자봉 균열 상태의 주파수 스펙트럼을 보면, 정상 상태에 비해 회전주파수 및 저주파수 성분이 전체적으로 조금씩 감소하는 것을 알 수 있다.

위와 같이 시간 영역의 신호에서는 확인하기 어려운 각종 이상 상태의 특징을 주파수 영역의 스펙트럼에서는 회전주파수 및 조화 성분을 비교하거나 고주파수 성분을 관찰해서 쉽게 확인할 수 있다.

3. 특징 데이터의 추출

3.1 특징 데이터의 비교

유도전동기의 이상 진단을 위해 취득된 진동 신호는 시간 영역의 데이터로써 서로 다른 진폭과 주파수를 가지는 많은 신호들의 조합으로 이루어져 있고 많은 특징 정보를 가지지만, 또한 잡음 성분과 같은 불필요한 부분이 많으므로 직관적인 특징을 얻기 어렵다. 따라서 효과적인 이상 진단을 위해서 신호 처리 기법을 이용하여 각 기계별 혹은 이상 종류별 고유한 특징을 찾아내는 것이 필요한데 이런 과정을 특징 추출(feature extraction)이라고 한다. 특징을 추출하여 각 이상 상태의 특성을 일정한 패턴으로 나타내고 이 특성 패턴에 따라 각 이상 상태를 진단한다⁽²⁾.

이상 진단을 위해 필요한 특징 추출을 위한 특징 데이터의 조건으로 각 이상 상태별 특징 데이터는 일정한 패턴을 유지해야 한다. 우선 각 특징 데이터는 같은 상태에 대해서 큰 차이가 나지 않도록 일정한 값을 유지해야 하고, 서로 다른 상태에 대해서는 어느 정도의 차이가 있어야 한다. 따라서 각 정상 및 이상 상태에서 비슷한 값을 가지는 특징 데이터는 제거하고 상태별 차이가 많고 같은 상태에 대한 편차가 적은 특징 데이터를 이용한다. 또한 다른 특징 데이터가 나타내지 못 하는 특정한 상태를 나타내는 특징 데이터가 있는가를 확인해 볼 필요가 있다⁽¹⁾.

특징 추출을 위해서 위의 조건들에 의해 각 특징 데이터는 평균(mean), 표준편차(standard deviation), 왜도(skewness), 첨도(kurtosis) 등의 통계적 데이터들과 일반적으로 실효값으로 많이 이용되는 RMS (root mean square)를 적용해 보고 어떤 특징 데이터가 유용한 지를 비교한다.

3.2 웨이브릿 변환의 적용 및 특징추출벡터

웨이브릿 변환을 적용하여 대역별로 나누어진 신호에 대해 특징 데이터들을 적용하여 서로 비교하였다. 실험에 사용된 진동신호는 산업용 회전기계의 구동기로 사용되는 유도 전동기(induction motor)에서 정상 및 각종 이상 상태의 조건을 발생시켜 측정된 데이터로 샘플링 주파수 8kHz의 시간 2.1333초 길이로 취득하였으며, 같은 기계에 대해 여섯 번씩 측정하여 각 상태별 총 12.78초 길이를 갖는다. 실험에서는 전체 데이터를 0.35초 길이의 프레임으로 나누어 각 상태별 30개씩의 데이터 집합(data set)을 구성했다. 원래 시간 영역의 신호와 4단계 웨이브릿을 거쳐 d1(4~8 kHz), d2(2~4 kHz), d3(1~2 kHz), d4(0.5~1 kHz)로 나누어진 주파수 대역별 신호에 대해 특징 데이터들을 비교해보고 어떤 특징 데이터가 각 상태를 구분하는 데 유용한지 분석하였다.

Fig. 7에서 수평축은 입력 신호의 각 상태별 데이터 샘플을 나타내고, 수직축은 각각 데이터의 RMS, 평균, 표준편차, 왜도, 첨도를 나타낸다. 다른 특징 데이터들은 각 상태별 큰 차이가 나지 않고, RMS와 표준편차의 경우 베어링 결함, 굽은 회전축 상태가 다른 상태들과 차이가 나타난다.




Fig. 7 Feature data of original signal

Fig. 8과 9을 비교해보면, 웨이브릿 변환을 거친 데이터의 대역별 신호 중에서 고주파수 영역 신호인 4~8kHz 대역의 신호에서는 RMS와 표준편차를 이용하여 베어링 결함, 굽은 회전축의 이상 상태를 알아낼 수 있다. 이상 상태의 주파수 특성에서 보았듯이, 베어링 결함과 굽은 회전축 상태는 정상 상태와 비교했을 때 고주파수 성분이 크게 나타나므로 다른 상태들과 구분이 잘 될 수 있다. 그러나 저주파수 대역인 0.5~1 kHz 영역의 신호에서는 질량 불평형, 각 정렬 불량, 수평 정렬 불량, 회전자봉 균열 등의 이상 주파수 특성이 저주파수 대역에서 나타나는 이상 현상들을 더 잘 구분할 수 있다.

위와 같이 기본 시간 신호에서 찾을 수 없는 특징들을 각 대역별 신호에서 각각 찾아낼 수 있고 이런 대역별 신호의 특징들을 조합하여 여러 가지 상태들의 특징 추출 벡터를 구성할 수 있다.




Fig. 8 Feature data of 4~8 kHz(d1) band signal




Fig. 9 Feature data of 0.5~1 kHz(d1) band signal

4. 이상 진단 시스템

4.1 K-Means Clustering 알고리즘

위의 특징 데이터들에 정상 및 이상 상태의 분류를 위해, 패턴 인식의 간단한 알고리즘 중 하나인 K-means clustering 알고리즘에 적용하였고, 이 알고리즘을 요약하면 다음과 같다⁽⁵⁾.

1. Initialize : Set $\{\lambda_i^{(0)}\}_{i=1}^M, k=0, D^{(0)}$. Select threshold ϵ
2. Classification :

$$V_i^k = \{X: d(X, \lambda_i) < d(X, \lambda_j) \forall j \neq i\}$$

$$j = 1, 2, \dots, M-1, \text{ where } X \text{ is input}$$
3. Compute overall distortion:

$$D^{(k)} = \sum_{i=1}^M \int_{J_i^{(k)}} \|X - \lambda_i^{(k)}\|^2 p(X) dX \text{ where } p(X) \text{ is pdf function}$$
4. Termination : If $\frac{D^{(k)} - D^{(k-1)}}{D^{(k)}} < \epsilon$
 Stop ; otherwise, continue
5. Updating : $\{\lambda_i^{(k+1)}\}_{i=1}^M = \text{centroids of } \{V_i^{(k-1)}\}$
 Go to Step 2.

여기서 λ 는 각 상태의 모델을, d 는 하나의 입력 데이터와 상태 모델과의 차이를, D 는 상태모델과 입력값의 전체 오차를, X 는 입력 데이터를, V 는 X 의 값이 어떤 상태로 분류되었음을 의미한다.

Fig. 10은 K-means clustering 알고리즘을 적용하여 각 상태 모델을 결정하고 상태 모델과 입력 데이터와 가장 적은 차이를 갖는 상태를 입력의 상태로 결정하여 정상 및 이상 상태를 진단하는 진단 시스템을 나타낸다.

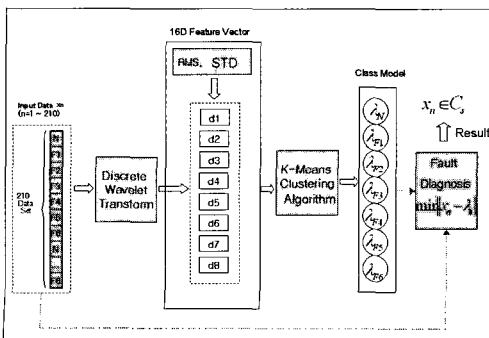


Fig. 10 Fault diagnosis system using K-means clustering

4단계 4개 대역 웨이브릿 변환 신호와 6단계 8개 대역 웨이브릿 변환 신호에 대해 특징 벡터를 구성하기 위해 실험했던 5가지의 특징 데이터들을 조합하여 K-means 알고리즘에 적용하였을 때, 정상 및 각종 이상 상태를 구분하는 정도를 식 (1)과 같이 계산하였다.

$$\text{진단율} = \frac{\text{Detection 데이터 Set 수}}{\text{전체데이터 Set 수}(210)} \times 100(\%) \quad (1)$$

Table 1은 프레임 길이를 0.4초로 하고 웨이브릿 변환을 4단계 4개 대역 신호로 두고 특징 데이터를 서로 바꿔 조합해 비교했을 때, K-means clustering 알고리즘에서 결정된 상태별 모델과 비교해서 이상 진단 결과의 진단율을 나타낸 것이다. 표의 결과에서 RMS 값과 표준편차를 이상 진단의 특징 추출을 위한 특징 벡터로 사용하는 것이 유리하다는 것을 알 수 있다.

4.2 검출 오차 최소화 학습

특징 데이터를 이용해 구성된 특징 추출 벡터를 K-means clustering 알고리즘을 적용하여 초기 이상 진단 시스템을 구성하고, 이상 진단 시스템의 진단율을 향상하기 위해 검출 오차 최소화 학습(minimum detection error training)을 적용하여 초기 이상 진단 시스템과 비교해 보았다.

Table 1 Detection rate for each feature data

2-feature data	Detection rate(%)
Mean, STD	74.67
RMS, STD	94.76
RMS, Skewness	84.67
RMS, Kurtosis	73.34
Skewness, Kurtosis	46.0
STD, Kurtosis	82.67




Fig. 11 Process of state decision for MDE training

Fig. 11에서는 상태 모델의 개선을 위하여 각 상태에 대해 임계 값(h_s)를 설정하고 상태 모델(λ_s)과 입력 벡터(x_n) 간의 거리(g_s)가 임계 값보다 작다면 입력을 그 상태로 결정한다. 임계 값의 설정에 따라 하나의 상태가 아니라 여러 개의 상태로 결정될 수도 있고, 어떤 상태에도 분류되지 않을 수도 있다.

검출 오차 최소화 학습은 각 상태의 클래스 모델을 기울기 강하(gradient descent)의 방법을 기반으로 만약 입력 데이터가 올바른 상태 클래스가 아닌 다른 상태 클래스에 분류되었다면 이것을 잘못된 검출(false alarm)로 두고, 올바른 상태 클래스로 분류되지 못했을 경우 검출 실패(detection failure)의 두 가지 상태 클래스 분류의 오차로 나누어 상태 클래스 모델과 임계 값의 오차가 적도록 수정하게 된다⁽⁶⁾.

상태 모델과 임계 값은 $\Lambda_s = \{\lambda_s, h_s\}$ 로 두어 MDE 훈련에 적용한다. 오차 함수를 식 (2)와 같이 임계 값과 거리 함수의 차이로 두고,

$$d_s(x_n, \Lambda_s) = h_s - g_s(x_n, \lambda_s) \quad (2)$$

이 오차 함수를 smoothed zero-one 함수, 식 (3)에 적용하여 기울기가 커지도록 학습하게 된다. 여기서 검출 실패(DF error)와 잘못된 검출(FA error)의 두 가지로 나누어 학습을 다르게 한다.

$$l_s(x_n, \Lambda_s, \alpha_s) = \frac{1}{1 + \exp(\alpha_s \cdot d_s(x_n, \Lambda_s))}$$

$\alpha_s > 0$ for $x_i \in C_s$ (DF error)
 $\alpha_s < 0$ for $x_i \notin C_s$ (FA error)

(3)

식 (3)의 값을 미분을 통해 기울기를 구하여 기울기가 커지는 방향으로 학습하여 상태 모델과 임계 값이 이상 진단에서 오류가 적도록 수정하게 된다^(6,8).

$$\Lambda_s^{(t+1)} = \Lambda_s^{(t)} - \epsilon U_s \nabla_{\Lambda_s} l_s(x_n, \Lambda_s^{(t)}, \alpha_s) \quad (4)$$

식 (4)의 ϵ 은 학습률을 나타내고, U_s 는 임계 값과 상태 모델로 구성된 학습 데이터에 대해 정의된 행렬이다.

Fig. 12는 K-Means Clustering 알고리즘과 검출 오차 최소화 학습을 결합하여 고장 진단의 전반적인 시스템을 나타내고 있다. 먼저 입력데이터 X 로부터 K-Means Clustering 알고리즘을 적용한 결과를 검출 오차 최소화 학습 알고리즘에 입력시켜 최종 결과를 얻을 수 있다. 최종 결과는 입력 X 가 어떤 진단 상태에 속하는 지를 결정하게 된다.

검출 오차 최소화 학습을 이상 진단에 다시 적용한 결과는 Table 2와 3에서 알 수 있다. Table 2의 N 은 정상상태, F1은 질량 불평형, F2는 각 정렬 불량, F3는 수평 정렬 불량, F4는 베어링 결함, F5는 회전자

Table 2 Detection rate for each state(%)

	N	F1	F2	F3	F4	F5	F6
K-Means	83.33	93.33	93.33	96.67	100	100	96.67
MDE	90	96.67	93.33	96.67	100	100	96.67

Table 3 Average detection rate(%)

	K-Means	MDE
Detection rate(%)	94.76	96.19

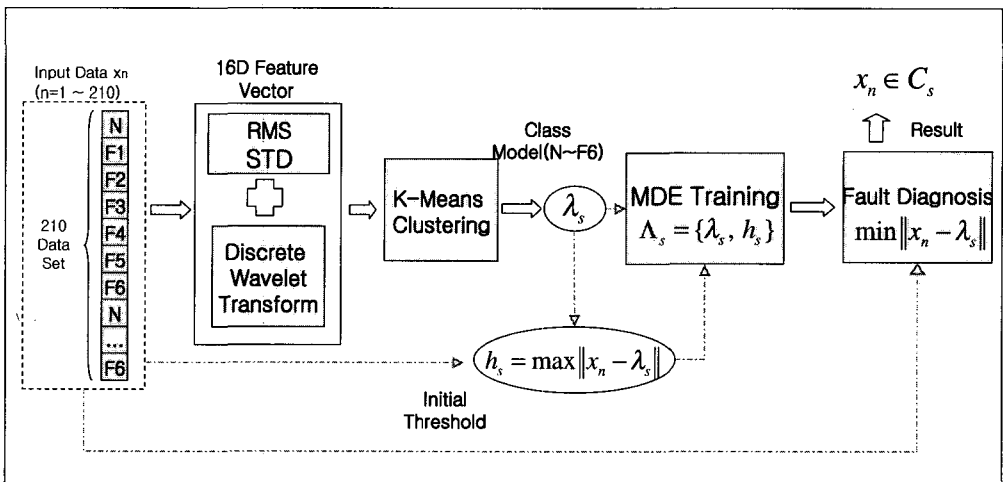


Fig. 12 Overall fault diagnosis system using MDE

봉 균열, F6는 굽은 회전축의 상태를 의미한다.

K-Means Clustering 알고리즘을 적용한 초기 상태와 검출 오차 최소화 학습을 적용한 후의 상태를 비교했을 때, 각 상태별 진단율에서는 정상 상태(N)와 질량 불평형(F1) 상태가 개선되었다. 따라서 전체 상태의 평균 진단율은 94.76 %에서 96.19 %로 약 1.43 % 증가하였다.

5. 결론 및 향후 과제

이 논문에서는 진동 신호를 이용하여 회전기계의 이상을 진단하는 시스템을 연구하였다. 많은 계산을 필요로 하고 시간 영역의 정보를 손실하는 주파수 영역에서 진단하는 것을 피하기 위해, 시간 영역 신호에 대해 주파수 대역별 신호로 나누어지는 웨이브릿 변환을 거쳐 주파수 대역별로 나누어진 신호를 이상 진단에 적용해 보고 원래 신호를 이상 진단에 적용하는 것과 비교하였다. 그리고 이상 상태의 분류를 위한 알고리즘에 적용할 특징 벡터를 추출하기 위해 RMS, 평균값, 표준편차, 왜도, 첨도 등의 여러 가지 특징 데이터를 계산하여 비교해 본 결과, RMS와 표준 편차가 같은 상태에서 편차가 적어 일정한 값을 유지하고 다른 상태들을 구분하는데 유용하여 이상 진단 시스템에 적용하였다. 웨이브릿 변환과 특징 데이터의 비교를 통해 결정된 특징 추출 벡터를 각 상태의 구분을 위해 패턴 분류의 한 방법인 K-means clustering 알고리즘에 적용하여 각 상태 모델을 결정할 수 있었다. 그리고 이상 진단의 정확성 향상을 위해, 이전에 시도되지 않았던 방법인 검출 오차 최소화 학습을 적용하였을 때 효과가 있음을 확인하였다.

회전기계의 이상 진단은 기계의 사양이나 용도 등에 따라 정해진 시스템으로 일반적으로 적용하기에는 많은 문제점이 있다. 이런 문제점의 보완을 위해서는 특징 데이터에 대한 연구가 더욱 필요하고, 패턴 인식의 다양한 알고리즘을 적용할 필요가 있다. 그리고 실제 모든 회전 기계에서 이상 현상이 한 가지만 발생하지는 않으므로 두 가지 이상의 이상 원인이 있을 경우에 대한 연구도 이루어져야 할 것이다. 또한 이 연구의 실험 데이터로 이용된 유도 전동기 외의 다른 회전기계에 대해 이상 진단 시스템을 적용하여 비슷한 결과를 얻을 수 있는지도 확인하여야 한다.

후 기

이 연구는 산업자원부·울산광역시 지원 울산대학교 네트워크 기반 자동화연구센터의 지원 및 지역 혁신 인력 양성 사업의 지원에 의한 것입니다.

참 고 문 헌

- (1) Yang, B. S., Kim, K. J. and Han, T., 2004, "Fault Diagnosis of Induction Motors Using Data Fusion of Vibration and Current Signals", Transactions of the KSNVE, Vol. 14, No. 11, pp. 1091~1100.
- (2) An, J. L., Hna, T., Yang, B. S., Jeon, J. J. and Kim, W. C., 2002, "Fault Diagnostics Algorithm of Rotating Machinery Using ART-Kohonen Neural Network", Transactions of the KSNVE, Vol. 12, No. 10, pp. 799~807.
- (3) Seo, D. W., 2000, "A Study on the Condition Monitoring and Diagnosis of Rotating Machinery and Tools Using Wavelet Analysis", Seo-kang Univ, in Korean, MS Thesis.
- (4) Yang, B. S., Hwang, W. W., Kim, D. J. and Tan, A.C.C., 2003, "Condition Classification of Small Reciprocating Compressor for Refrigerators using Artificial Neural Networks and Support Vector Machines," Mechanical Systems and Signal Processing, Vol. 19, pp. 371~390.
- (5) Kondo, A. M., 1998, "Digital Speech", Neural Networks for Signal Processing VIII, pp. 383~392.
- (6) Hideyuki W., Yuji M., Satoru T. and Shigeru K., 1998, "Sound Monitoring based on the Generalized Probabilistic Descent Method," Neural Networks for Signal Processing VIII, pp. 383~392.
- (7) Lee, C. H., 2000, "Development of the Fault Diagnostic System on the Rotating Machinery", Han-yang Univ, in Korea, MS Thesis.
- (8) Juang, B. H. and Katagiri, S., 1992, "Discriminant Learning for Minimum Error Classification," IEEE Trans. Signal Processing, Vol. 40, No. 12, pp. 3043~3054.
- (9) Hwang, W. W. and Yang, B. S., 2004, "Fault Diagnosis of Rotating Machinery Using Multi-class Support Vector Machines", Transactions of the KSNVE, Vol. 14, No. 12, pp. 1233~1240.