(19)대한민국특허청(KR)
(12) 등록특허공보(B1)

(51) 。Int. Cl.
G01H 1/12 (2006.01)

(45) 공고일자 2007년01월09일
(11) 등록번호 10-0666452
(24) 등록일자 2007년01월03일

(21) 출원번호 10-2005-0083230
(22) 출원일자 2005년09월07일
심사청구일자 2005년09월07일

(65) 공개번호
(43) 공개일자

(73) 특허권자 울산대학교 산학협력단
울산 남구 무거동 산29

(72) 발명자 정의필
울산광역시 남구 무거2동 무거현대아파트 101동 207호

이재열
울산광역시 중구 학산동 5-12 강동빌라 B동 202호

(74) 대리인 특허법인신세기

(56) 선행기술조사문헌
KR1019960028091 A
KR1020020074615 A
KR1020050080005 A
* 심사관에 의하여 인용된 문헌

심사관 : 이현동

전체 청구항 수 : 총 8 항

(54) 회전기계의 상태 진단방법 및 그 방법을 사용하는 진단시스템

(57) 요약

본 발명은 회전기계의 상태 진단방법 및 그 방법을 사용하는 진단 시스템에 관한 것으로 피진단 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 진동데이터를 입력하는 단계; 상기 진동데이터의 통계적 수치 값에 웨이브릿 변환을 적용하여 특징추출 벡터를 구성하는 단계; 상기 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 얻어진 값과 미리 정해진 정상 상태와 다수의 비정상 상태의 값과 가장 적은 차이를 갖는 상태의 값으로 회전기계의 상태를 분류하는 단계로 이루어지는 회전기계의 상태 진단방법과 그 방법을 사용하는 회전기계의 상태 진단 시스템을 제공한다.

본 발명에 의하여 많은 하드웨어 적인 투자 없이도 실시간으로 신뢰성이 있는 회전기계의 운전상태를 진단할 수 있는 진단방법 및 진단 시스템이 제공된다.

대표도

도 11

특허청구의 범위

청구항 1.

피진단 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 진동데이터를 입력하는 단계; 상기 진동데이터의 통계적 수치 값에 웨이브릿 변환을 적용하여 특징추출 벡터를 구성하는 단계; 상기 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 얻어진 값과 미리 정해진 정상 상태와 다수의 비정상 상태의 값과 가장 적은 차이를 갖는 상태의 값으로 회전기계의 상태를 분류하는 단계로 이루어지는 회전기계의 상태 진단방법.

청구항 2.

제1항에 있어서, 상기 미리 정해진 상태 모델의 값은 정상 상태와 다수의 비정상 상태에 있는 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 각 상태의 진동데이터를 입력하는 단계; 상기 각 상태의 진동데이터의 통계적 수치에 웨이브릿 변환을 적용하여 각 특징추출 벡터를 구성하는 단계; 상기 각 상태의 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하는 단계; 및 검출오차 최소화 학습 단계로 이루어진 방법으로 결정되는 회전기계의 상태 진단방법.

청구항 3.

제2항에 있어서, 상기 회전기계는 유도전동기이고 상기 회전기계의 상태는 정상상태 또는 질량 불평형(mass unbalance), 정렬 불량(misalignment), 베어링 결함(faulty bearing)과 회전자봉 균열(broken rotor bar)로 이루어지는 군에서 선택되는 이상 상태인 회전기계의 상태 진단방법.

청구항 4.

제3항에 있어서, 상기 정렬 불량은 각 정렬 불량과 수평 정렬 불량으로 세분되는 회전기계의 상태 진단방법.

청구항 5.

제3항 또는 제4항에 있어서, 상기 상태 별로 상기 진동데이터의 통계적 수치 RMS와 표준편차에 대해서 4개 내지8 개 대역 주파수로 웨이브릿 변환을 적용하여 8차 내지 16차 특징추출 벡터를 구성하는 회전기계의 상태 진단방법.

청구항 6.

제5항에 있어서, 상기 진동데이터는 0.1Hz 내지 40KHz의 범위인 회전기계의 상태 진단방법.

청구항 7.

제6항에 있어서, 상기 진동신호센서는 가속도 센서인 회전기계의 상태 진단방법.

청구항 8.

제7항에 있어서, 상기 진동데이터는 0.5 Hz 내지 8KHz의 범위인 회전기계의 상태 진단방법.

청구항 9.
삭제

청구항 10.
삭제

청구항 11.
삭제

청구항 12.
삭제

명세서

발명의 상세한 설명

발명의 목적

발명이 속하는 기술 및 그 분야의 종래기술

본 발명은 회전기계의 상태 진단방법 및 그 방법을 사용하는 진단 시스템에 관한 것이다.

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

이론적으로는 동일 주기로 회전하는 회전기계는 주파수 영역에서 평균적인 진동 스펙트럼을 얻을 수 있고 이러한 진동 스펙트럼의 패턴에 의하여 회전기계의 운전 상태를 진단하는 것이 가능하다. 그러나 실시간으로 진동신호센서에 검출되는 신호에 의하여 일정 범위의 주파수 영역에서 진동 스펙트럼을 얻는 것은 어려울 뿐만 아니라 이러한 진동 스펙트럼의 해석에도 별도의 처리가 수행되어야 하기 때문에 굉장히 복잡하여 실질적으로 불가능하다.

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 등에 따라 각각 다르며 동일한 기계도 완전히 같은 진동을 갖지는 않으므로 단일 특징 데이터를 이용하는 것은 많은 제약이 따르고 또한 원하는 결과도 얻기 힘들다.

발명이 이루고자 하는 기술적 과제

본 발명은 실시간으로 신뢰성이 있는 회전기계의 상태 진단방법 및 그 방법을 사용하는 진단 시스템을 제공하기 위한 것이다.

또한 본 발명은 시간 영역데이터를 사용하여 경제적으로 구축할 수 있는 회전기계의 상태 진단방법 및 그 방법을 사용하는 진단 시스템을 제공하기 위한 것이다.

발명의 구성

본 발명에 의하여 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 진동데이터를 입력하는 단계; 상기 진동데이터의 통계적 수치 값에 웨이브릿 변환을 적용하여 특징추출 벡터를 구성하는 단계; 상기 특징추출 벡터에 케이민즈클

러스터링(K-means clustering) 알고리즘을 적용하여 얻어진 값과 미리 정해진 정상 상태와 다수의 비정상 상태의 모델 값과 가장 적은 차이를 갖는 상태의 값으로 회전기계의 상태를 분류하는 단계로 이루어지는 회전기계의 상태 진단방법이 제공된다. 상기 미리 정해진 상태 모델의 값은 바람직하게는 정상 상태와 다수의 비정상 상태에 있는 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 각 상태의 진동데이터를 입력하는 단계; 상기 각 상태의 진동데이터의 통계적 수치 값에 웨이브릿 변환을 적용하여 각 특징추출 벡터를 구성하는 단계; 상기 각 상태의 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하는 단계; 및 검출오차 최소화 학습 단계로 이루어진 방법으로 얻어진다.

회전기계 예를 들면, 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. 따라서 회전기계의 운전상태는 바람직하게는 정상상태와 상기 5개의 이상 상태로, 가장 바람직하게는, 정렬불량을 각 정렬 불량(angular misalignment)과 수평 정렬 불량(parallel misalignment)으로 세분하여 6개의 이상 상태로 분류할 수 있다. 각각의 이상 상태를 간단히 정리하면 다음과 같다.

(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. 경우에 따라서 두 가지 정렬 이상으로 분류할 수 있는데, 각 정렬 불량(angular misalignment)은 회전축이 평행한 방향으로 놓여있지 않고 서로 다른 각도를 가진 상태이고 수평 정렬 불량(parallel misalignment)는 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 상태로서 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 강제적으로 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.

상기 진동신호센서는 바람직하게는 변위센서 또는 가속도 센서이고 가장 바람직하게는 가속도 센서이다. 이러한 진동신호센서는 바람직하게는 회전축 베어링의 하우징에 부착된다.

상기 진동데이터는 0.1Hz 내지 40KHz의 범위, 바람직하게는 0.5 Hz 내지 8KHz의 범위이고 이의 통계적 수치 값은 바람직하게는 RMS 및/또는 표준편차이다. 일반적으로 사용되는 통계적 수치는 RMS(root mean square), 평균(mean), 표준편차(standard deviation), 왜도(skewness), 첨도(kurtosis) 등인데 특히 RMS(root mean square)와 표준편차가 유용하다.

회전기계의 운전상태 별로 바람직하게는 상기 진동데이터의 통계적 수치 RMS와 표준편차에 대해서 4개 내지8 개 대역 주파수로 웨이브릿 변환을 적용하여 8차 내지 16차 특징추출 벡터를 구성한다.

상기 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 얻어진 값과 미리 정해진 정상 상태와 다수의 비정상 상태의 모델 값과 가장 적은 차이를 갖는 상태의 값으로 회전기계의 상태를 분류한다. 상기 미리 정해진 상태 모델의 값은 정

상 상태와 다수의 비정상 상태에 있는 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 각 상태의 진동데이터를 진단 방법과 동일한 절차에 의하여 특징 추출벡터를 구성하고 상기 각 상태의 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 각 상태에 대하여 초기 모델의 값을 얻은 다음 검출오차 최소화 학습에 의하여 개선된 모델 값을 얻는다.

또한 본 발명에 의하여 피진단 회전기계의 구성요소에 설치된 진동신호센서; 상기 진동신호센서에 의하여 검출된 진동데이터를 통계적 수치 값으로 변환하고, 상기 통계적 수치 값에 웨이브릿 변환을 적용하여 특징추출 벡터를 얻고, 상기 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 얻어진 값과 미리 정해진 정상 상태와 다수의 비정상 상태의 모델값과 가장 적은 차이를 갖는 상태의 값으로 회전기계의 상태를 분류하는 컴퓨팅 수단;및 상기 분류된 회전기계의 상태를 표시하는 디스플레이수단을 포함하는 회전기계의 상태 진단 시스템이 제공된다. 상기 컴퓨팅 수단은 바람직하게는 정상 상태와 다수의 비정상 상태에 있는 회전기계의 구성요소에 설치된 진동신호센서에 의하여 검출된 각 상태의 진동데이터의 통계적 수치 값에 웨이브릿 변환을 적용하여 각 특징추출 벡터를 구성하고, 상기 각 상태의 특징추출 벡터에 K-means 클러스터링 알고리즘을 적용하여 상태 모델의 값을 1차로 얻은 다음 검출오차 최소화 학습화 단계를 거쳐 미리 정해진 상태 모델의 값을 얻는다. 상기 컴퓨팅 수단은 특별히 제한되지 않는다. 범용 워크스테이숀이면 본 발명에 사용될 수 있다. 디스플레이 수단은 예를 들면 CRT, LCD 또는 LED 등이다.

이하 도면에 의하여 본 발명을 상세히 설명한다.

도1은 본 발명의 진단방법이 적용되는 유도전동기를 보여주는 분해사시도 사진이다. 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.

도2 내지 도5는 종래에 개시된 유도전동기의 정상 상태와 여러가지 이상 상태의 진동 주파수 스펙트럼(부경대학교 지능역학연구실 제공)을 보여준다. 도2에 보이는 바와 같이 60Hz 부근에서 회전주파수 성분이 크게 나타나고, 대부분의 성분들이 저주파 대역에 있음을 알 수 있다. 도3은 질량 불평형 상태의 주파수 스펙트럼을 보여준다. 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 상태(도시 안됨)에서는 질량 불평형에 비해 회전주파수 성분은 조금 증가하고 그 이상의 조화 성분들 중에서 특히 3차 및 4차 조화성분들 크게 증가했으며, 그 이상의 조화 성분도 크게 증가한다. 도4의 베어링 결함 상태의 주파수 스펙트럼을 보면, 회전주파수가 약간 감소하고 정상상태에서는 발생하지 않았던 고주파수 성분이 전체적으로 크게 증가한 것을 알 수 있다. 굽은 회전축의 경우(도시 안됨) 회전주파수를 포함한 저주파수 성분이 전체적으로 많이 감소하고, 1kHz 이상의 고주파수 성분이 크게 증가한다. 도5의 회전자봉 균열 상태의 주파수 스펙트럼을 보면, 정상 상태에 비해 회전주파수 및 저주파수 성분이 전체적으로 조금씩 감소하는 것을 알 수 있다. 이상과 같이 이상 상태에 따라 다른 주파수 영역에서 특징이 쉽게 확인될 수 있고 시간 영역에서의 진동데이터를 주파수 대역별로 변환할 필요가 있음을 알 수 있다. 그러나 진동신호에 의하여 일정 범위의 주파수 스펙트럼을 구하는 것은 높은 진동센서 감도와 많은 계산량을 수반하는 것이므로 실질적으로 불가능하고 이를 해석하는 솔루션을 만드는 것도 쉽지 않다.

진동신호 시간 영역 데이터의 통계적 수치

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. 문헌(1)(양보석, 김광진, 한천, 2004, "진동 및 전류신호의 데이터 융합을 이용한 유도전동기의 결함 진단", 한국소음진동공학회논문집, 제14권, 제11호, pp.1091~1100)과 문헌(2)(안경룡, 한천, 양보석, 전재진, 김원철, 2002, "ART- Kohonen 신경망을 이용한 회전기계의 결함진단 알고리듬의 제안", 한국소음진동공학회 논문집, 12권 10호, pp.799~807.)를 참조한다.

특징 추출을 위한 진동신호 데이터는 평균(mean), 표준편차(STD;standard deviation), 왜도(skewness), 첨도(kurtosis) 등의 통계적 데이터들로 가공된다. 진동신호 데이터로서 바람직한 통계치는 표준편차와 RMS(root mean square)이다.

특징 데이터의 비교

유도 전동기(induction motor)에서 정상 및 각종 이상 상태의 조건을 발생시켜 측정한 데이터로 샘플링 주파수 8kHz의 시간 2.1333초 길이로 취득하였으며, 같은 기계에 대해 여섯 번씩 측정하여 각 상태별 총 12.78초 길이를 갖는다. 실험에서

는 전체 데이터를 0.35초 길이의 프레임으로 나누어 각 상태별 30개씩의 데이터 집합(data set)을 구성했다. 원래 시간 영역의 신호와 4단계 웨이브릿을 거쳐 d1(4~8kHz), d2(2~4kHz), d3(1~2kHz), d4(0.5~1kHz)로 나누었다. 도6에서 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.

도7과 도8을 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 0.5~1kHz 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.

K-Means Clustering 알고리즘의 적용

위의 특징 데이터들에 정상 및 이상 상태의 분류를 위해, 패턴 인식의 간단한 알고리즘 중 하나인 K-means 클러스터링(clustering) 알고리즘에 적용하였고, 이 알고리즘을 요약하면 다음과 같다. 이 알고리즘에 대해서는 문헌(5)(A. M. Kondoz, 1998, "Digital Speech", Neural Networks for Signal Processing VIII, pp. 383~392.)에 기재되어 있다.

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

2. *Classification :*

$$V_i^k=\{X: d(X,\lambda_i)<d(X,\lambda_j)\ \forall j\neq i\}\quad j=1,2,..,M-1\ ,\ \text{where } X \text{ is input}$$

3. *Compute overall distortion:*

$$D^{(k)}=\sum_{i=1}^{M}\int_{V_i^{(k)}}\left\|X-\lambda_i^{(k)}\right\|^2 p(X)dX \quad \text{where } p(X) \text{ is pdf function}$$

4. *Termination : If* $\dfrac{(D^{(k)}-D^{(k-1)})}{D^{(k)}}<\varepsilon$ *Stop; otherwise, continue*

5. *Updating :* $\{\lambda_i^{(k)}\}_{i=1}^{M}=centroid\{V_i^{(k-1)}\}$

Go to Step 2.

도9는 K-means 클러스터링(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.

검출 오차 최소화 학습

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

$$\text{진단율} = \frac{\text{Detection 데이터 Set수}}{\text{전체 데이터 Set수}(210)}\times 100(\%) \qquad (1)$$

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

Table 1 Detection rate for each feature data

2-feature data	Detection rate(%)
Mean, STD	74.67
RMS, STD	94.76

RMS, 왜도(Skewness)	84.67
RMS, 첨도(Kurtosis)	73.34
왜도(Skewness), 첨도(Kurtosis)	46.0
STD, 첨도(Kurtosis)	82.67

검출 오차 최소화 학습은 각 상태의 클래스 모델을 기울기 강화(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

상태 모델과 임계 값은 $\Lambda s = \lambda s, hs$ 로 두어 MDE 훈련에 적용한다. 오차 함수를 식(2)와 같이 임계 값과 거리 함수의 차이로 두고,

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

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.

$$l_s(x_n, \Lambda_s, \alpha_s) = \frac{1}{1+\exp(\alpha_s \cdot d_s(x_n, \Lambda_s))}$$
$$\alpha_s > 0 \quad for \quad x_t \in C_s(DF \ \ error)$$
$$\alpha_s < 0 \quad for \quad x_t \notin C_s(FA \ \ error) \qquad (3)$$

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

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

식(4)의 ε은 학습률을 나타내고, U_S는 임계값과 상태 모델로 구성된 학습 데이터에 대해 정의된 행렬이다.

검출 오차 최소화 학습을 이상 진단에 다시 적용한 결과는 표 2와 3에서 알 수 있다. K-Means 클러스터링(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.

표 2 각 상태의 진단율

	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

표 3 평균진단율

	K-means	MDE
진단율(%)	94.76	96.19

발명의 효과

본 발명에 의하여 많은 하드웨어적인 투자 없이도 실시간으로 신뢰성이 있는 회전기계의 운전상태를 진단할 수 있는 진단 방법 및 진단 시스템이 제공된다.

도면의 간단한 설명

도1은 본 발명의 진단방법이 적용되는 유도전동기를 보여주는 분해사시도 사진이고

도2 내지 도5는 종래에 개시된 유도전동기의 정상 상태와 여러 가지 이상 상태의 진동 주파수 스펙트럼이고

도6에서 원래의 시간 영역에서 샘플링된 진동신호의 통계치를 나타내고,

도7과 도8은 각각 주파수 대역(4~8Khz)과 주파수 대역(0.5~1Khz)에서 웨이브릿 변환된 진동신호의 통계치를 나타내고

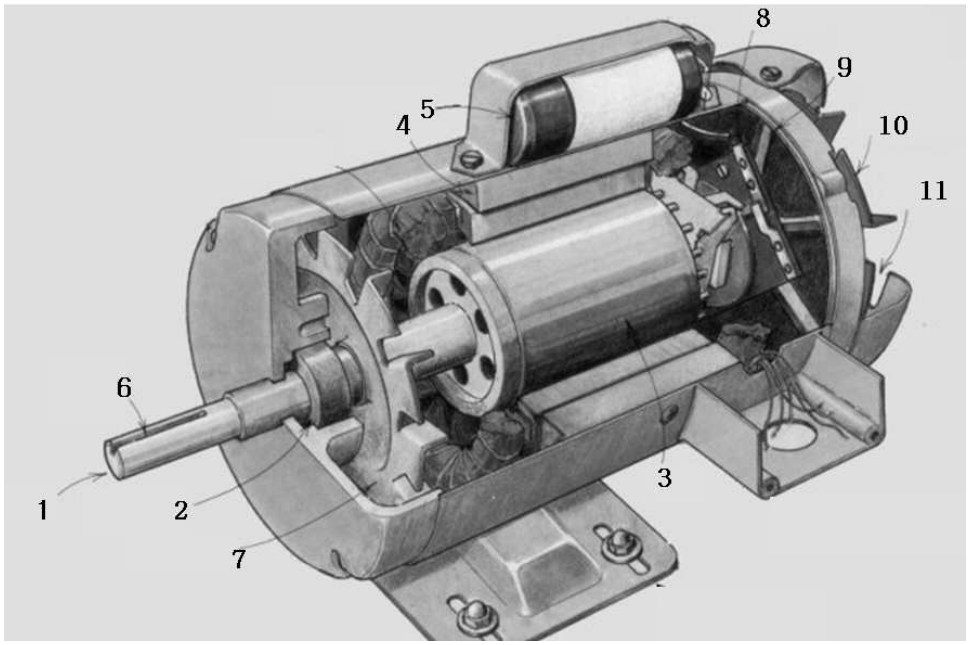
도9는 본 발명에서 K-means clustering 알고리즘을 적용한 블록도이고

도10은 데이터 세트에 검출 오차 최소화 학습(minimum detection error training)을 적용하는 과정을 보여주는 개념도이고

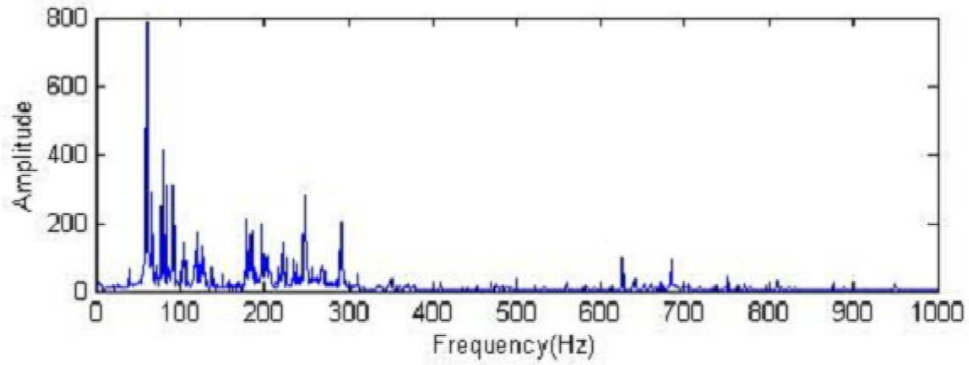
도11은 본 발명에서 검출 오차 최소화 학습(minimum detection error training)을 적용하는 블록도이다.
* 주요 도면 부호의 설명 *
1 : 모터 축 2 : 볼 베어링 3 : 로터
4 : 정류자 5 : 시동축전기 9 : 밀폐 내부하우징
10: 외부 팬 11: 환풍슬롯

도면

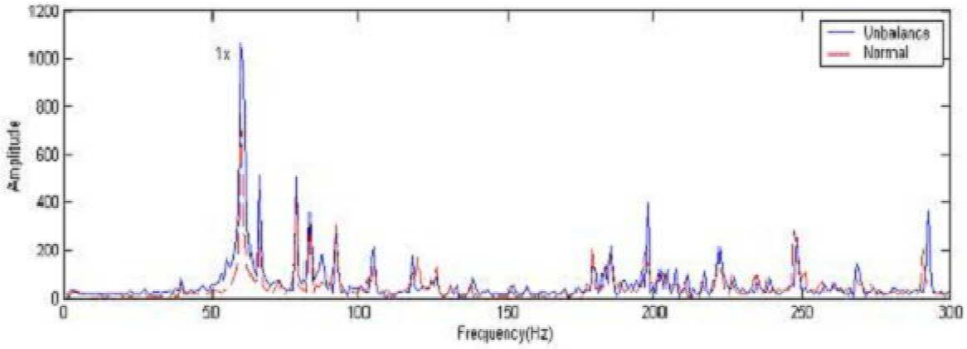
도면1



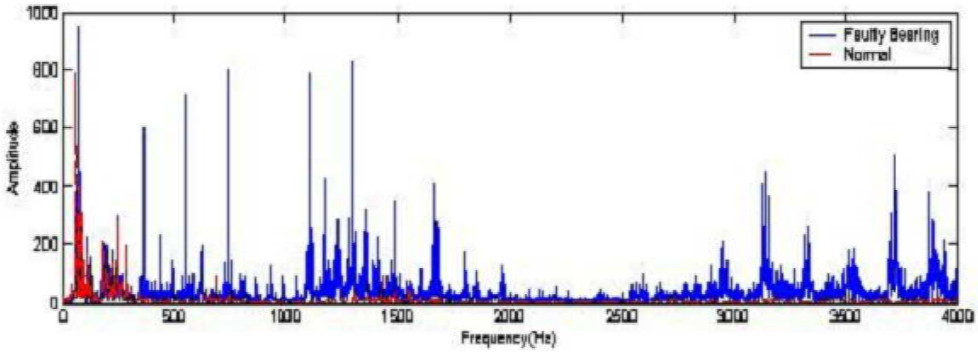
도면2



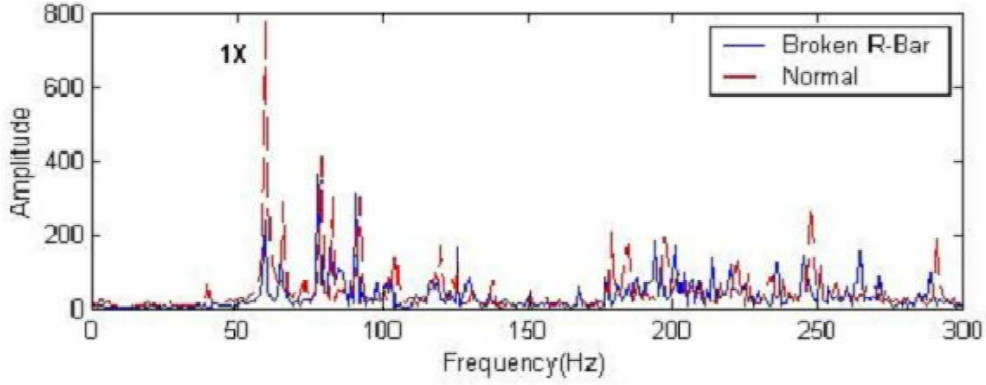
도면3



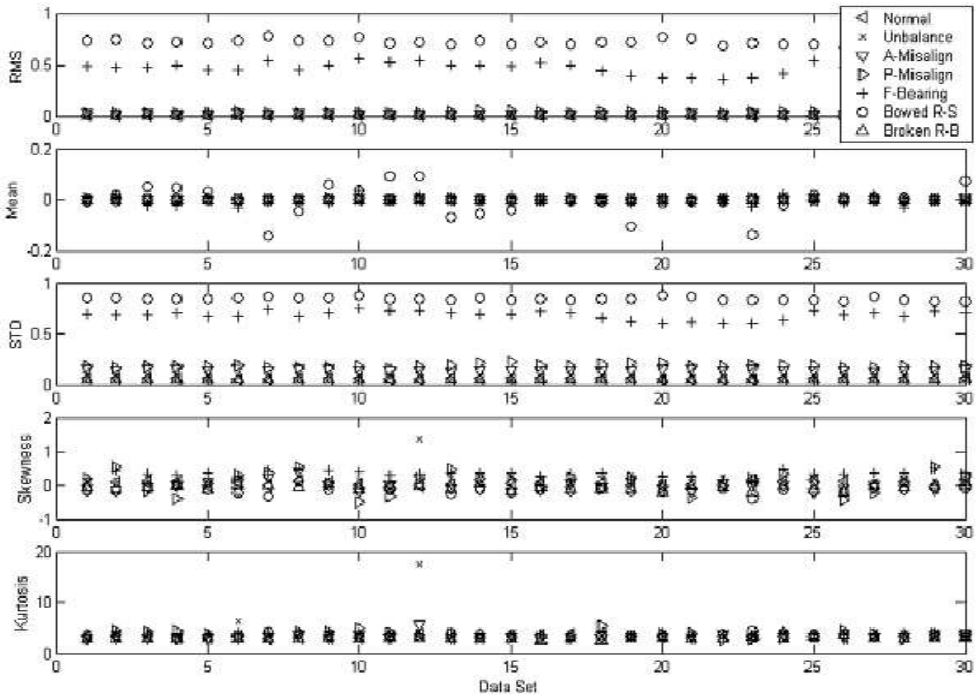
도면4



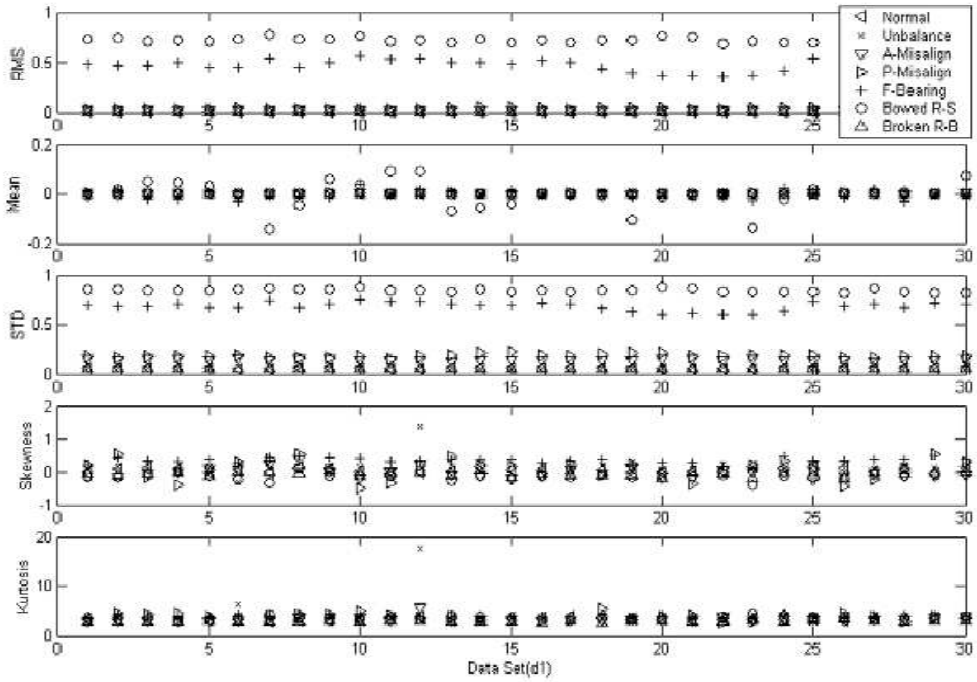
도면5



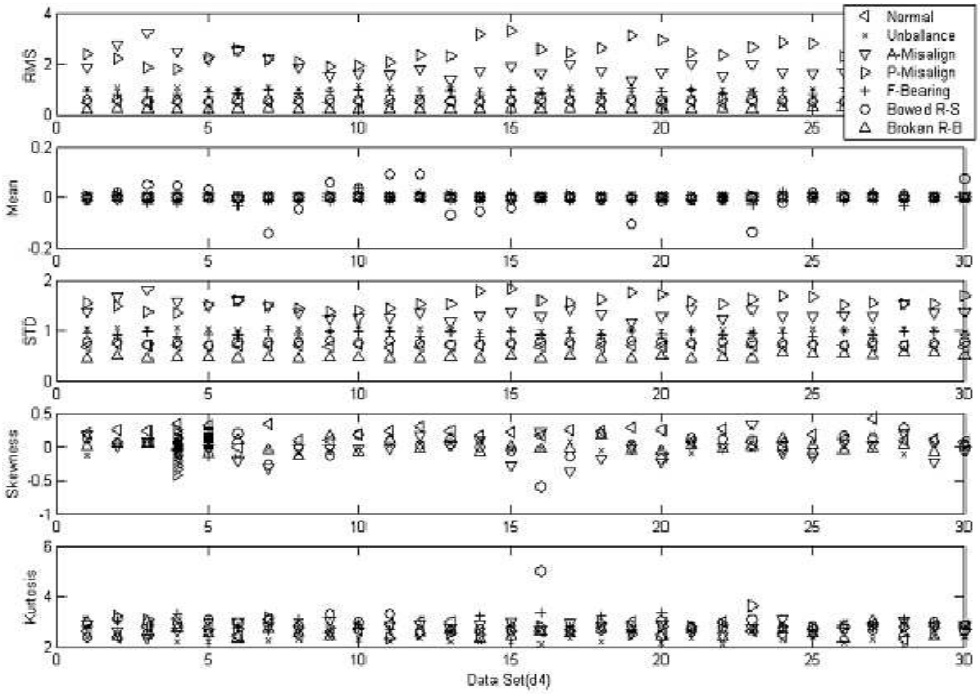
도면6


Normal
Unbalance
A-Misalign
P-Misalign
F-Bearing
Bowed R-S
Broken R-B
RMS
Mean
STD
Skewness
Kurtosis
Data Set

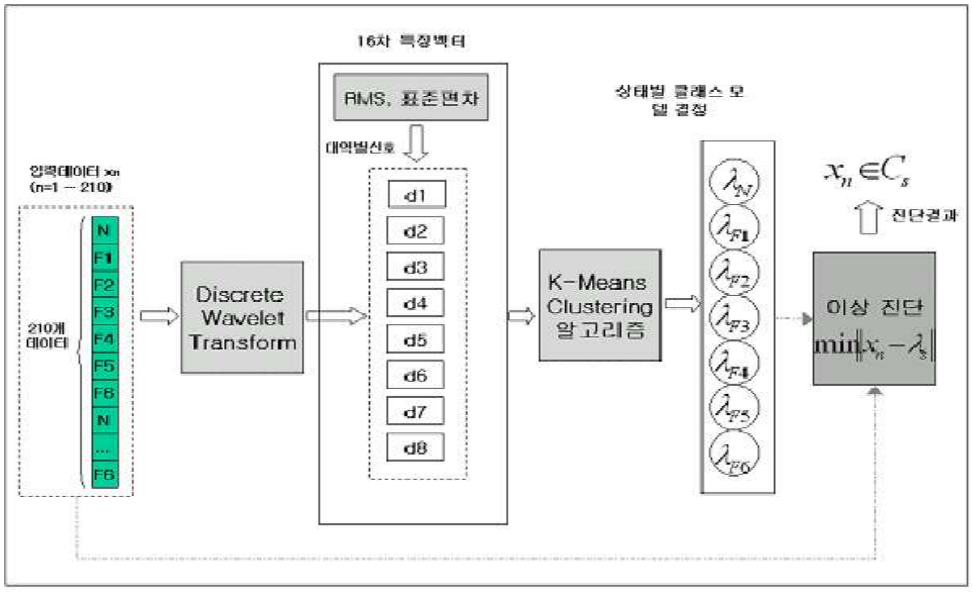
도면7


Normal
Unbalance
A-Misalign
P-Misalign
F-Bearing
Bowed R-S
Broken R-B
RMS
Mean
STD
Skewness
Kurtosis
Data Set(d1)

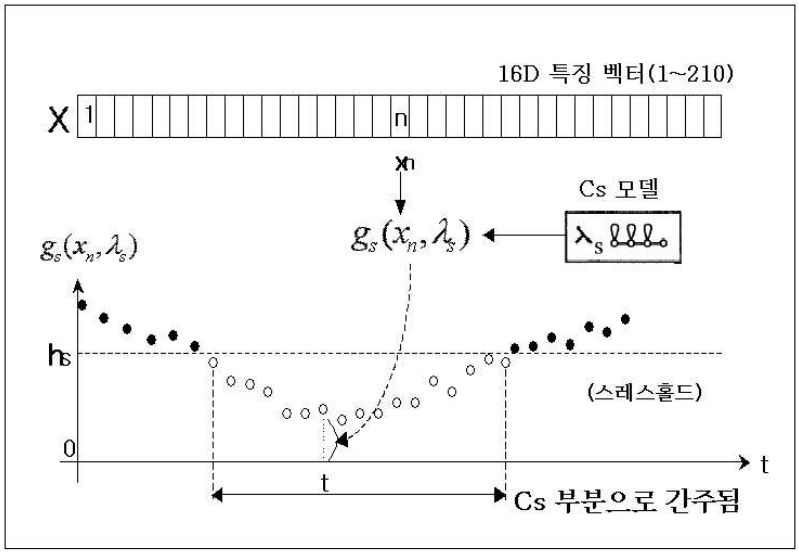
도면8


Normal
Unbalance
A-Misalign
P-Misalign
F-Bearing
Bowed R-S
Broken R-B
RMS
Mean
STD
Skewness
Kurtosis
Data Set(d4)

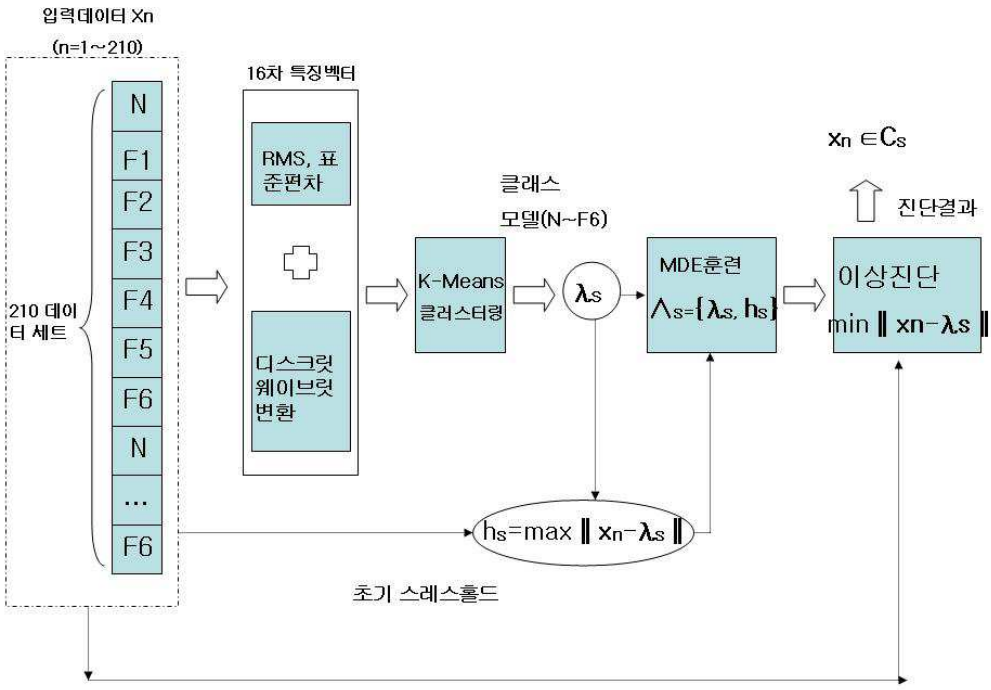
도면9


16차 특징벡터
RMS, 표준편차
대역별신호
d1
d2
d3
d4
d5
d6
d7
d8
입력데이터 xn
(n=1 ~ 210)
210개 데이터
N
F1
F2
F3
F4
F5
F6
N
...
F6
Discrete Wavelet Transform
K-Means Clustering 알고리즘
상태별 클래스 모델 결정
$x_n \in C_s$
진단결과
이상 진단
$\min\|x_n - \lambda_s\|$

도면10


16D 특징 벡터(1~210)
X
1
n
xn
Cs 모델
$g_s(x_n, \lambda_s)$
$g_s(x_n, \lambda_s)$
λ_s
hs
(스레스홀드)
0
t
t
Cs 부분으로 간주됨

도면11


입력데이터 Xn
(n=1~210)
210 데이터 세트
N
F1
F2
F3
F4
F5
F6
N
...
F6
16차 특징벡터
RMS, 표준편차
디스크릿 웨이브릿 변환
K-Means 클러스터링
클래스 모델(N~F6)
λs
MDE훈련
Λs={λs, hs}
이상진단
min ‖ xn−λs ‖
xn ∈Cs
진단결과
hs=max ‖ xn−λs ‖
초기 스레스홀드