

결함유형별 최적 특징과 Support Vector Machine 을 이용한 회전기계 결함 분류§

김양석*† · 이도환* · 김성국**

* KEPCO 전력연구원, ** ㈜엠앤디

Fault Classification for Rotating Machinery Using Support Vector Machines with Optimal Features Corresponding to Each Fault Type

Yang Seok Kim*†, Do Hwan Lee* and Seong Kook Kim**

* KEPCO Research Institute,

** M&D

(Received June 7, 2010 ; Revised August 26, 2010 ; Accepted August 27, 2010)

Key Words: Fault Classification(결함분류), Support Vector Machine(SVM), Feature Selection(특징선택), Rotating Machinery(회전기계)

초록: Support Vector Machine(SVM)을 이용한 회전기계 진단 연구가 많이 수행되어 왔으나 결함 분류 성능은 입력 특징과 더불어 다중 분류 방법, 이진분류기, 커널함수 등에 따라 다르다. SVM 을 이용한 대부분의 기존 연구들은 한번 입력 특징들을 선정하면 결함 분류시 동일한 특징데이터를 이용한다. 본 논문에서는 회전기계의 다양한 결함조건에서 측정된 진동신호로부터 추출한 통계적 특징들을 이용하여 각각의 결함을 분류하기 위한 최적 특징들을 선정 한 후, 해당 결함상태를 분류하기 위한 SVM 학습과 분류에 각각 이용하였다. 실험자료를 이용한 검증 결과, 제안한 단계 분류 방법이 상대적으로 적은 학습시간으로 단일 다중 분류 방법과 유사한 분류 성능을 얻을 수 있었다.

Abstract: Several studies on the use of Support Vector Machines (SVMs) for diagnosing rotating machinery have been successfully carried out, but the fault classification depends on the input features as well as a multi-classification scheme, binary optimizer, kernel function, and the parameter to be used in the kernel function. Most of the published papers on multi-class SVM applications report the use of the same features to classify the faults. In this study, simple statistical features are determined on the basis of time domain vibration signals for various fault conditions, and the optimal features for each fault condition are selected. Then, the optimal features are used in the SVM training and in the classification of each fault condition. Simulation results using experimental data show that the results of the proposed stepwise classification approach with a relatively short training time are comparable to those for a single multi-class SVM.

- 기호설명	\vec{w}	: 두 집합의 경계를 정의하는 가중치 벡터(weight vector)	
b	: 한계값(threshold value)	\vec{x}	: 입력 데이터 벡터(input vector)
$f(x)$: 결정함수	y_i	: 클래스 출력값 (+1 또는 -1)
$K(\vec{x}, \vec{x}_i)$: 커널 함수	α_i	: 라그랑지안 승수(Lagrange multipliers)
N	: 입력 특징데이터 집합의 수	σ	: RBF 커널 인자

§ 이 논문은 2010년도 대한기계학회 신뢰성부문 춘계학술대회 (2010. 5. 27.-28., 전남대 컨벤션홀) 발표논문임.

† Corresponding Author, kimys@kepri.re.kr

© 2010 The Korean Society of Mechanical Engineers

1. 서론

원자력발전소에 설치되어 있는 주요 기기들은

설계특성, 설치상태, 운전조건 및 사용기간에 따라 다양한 이상상태가 나타난다. 특히 모터, 펌프, 터빈등과 같은 회전기계의 경우 질량 불평형에 의한 편심, 정렬 불량, 베어링 성능 저하 등에 의해 이상진동이 유발되며 이는 곧 회전기계의 성능 저하 및 수명단축을 가져와 심한 경우 발전정지까지 유발할 수 있다. 따라서 원전에 설치된 주요 회전기계에 대해서는 최적의 성능을 유지시키기 위해 시험, 검사 및 정비를 일정한 주기로 수행하고 있으며 예방정비뿐만 아니라 예측정비 및 상태진단에도 큰 관심을 가져왔다.

회전기계 진단 연구는 진동, 음향방출 등의 신호 처리 및 분석을 통하여 기기의 상태를 진단하거나^(1,2) Artificial Neural Networks(ANNs), Support Vector Machines(SVMs) 등과 같은 지능형 분류 알고리즘을 기기 상태에 대한 자동 진단에 적용하는 방향으로 수행되어 왔다.⁽³⁻¹²⁾ 일반화 성능면에서 더 나은 것으로 알려져 있는 SVM은 1960 년대의 통계적 학습이론으로부터 Vapnik 에 의해 개발되어 1990 년대 중반부터 패턴인식분야에 주로 적용되었고 진단분야에는 2000 년대 초반부터 적용하기 시작하여 상당히 좋은 분류 성능을 보여주었다⁽³⁻⁶⁾. 그러나 SVM은 이진분류 모델이어서 실제로 많이 존재하는 다중 분류 문제에 적용할 경우 분류 성능이 저하되고 데이터량이 많거나 분류대상이 많을 경우 학습시간이 길어진다는 단점이 있다. 이와 같은 단점을 극복하기 위하여 SVM 앙상블(Ensemble)을 이용하여 고장을 분류하는 방법이 제안되었다^(7,13). SVM 앙상블은 SVM 분류기들의 집합을 구성하고 각각의 SVM 분류기의 결과를 조합하여 최종 결과로 이용하는 학습알고리즘이며 각각의 SVM 분류기들은 bagging, boosting 과 같은 방법을 이용한다. 분류대상이 많은 경우, ARTD (Autonomous Recursive Task Decomposition)을 이용하여 분류모델의 크기와 복잡도를 줄임으로써 학습시간을 크게 단축시키기도 하였다.⁽¹⁴⁾ 그러나 3 가지 이상의 다중분류 문제에 SVM을 적용하거나 SVM 앙상블을 이용하는 기존 연구들은 동일한 특징데이터를 각각의 SVM에 이용하였다. 한편 분류 성능은 ANN과 SVM과 같은 분류기의 성능뿐만 아니라 입력 특징데이터에 의해서도 영향을 받기 때문에 회전기계에서 측정된 시간영역 측정 신호에서 직접 추출한 특징 이외에 시간영역신호를 웨이블릿 변환, 필터링 등을 거친 신호로부터 추가로 특징을 추출하여 이용하기도 하였다.⁽⁷⁻⁹⁾

본 연구에서는 회전기계의 정상상태로부터 비정

상상태를 우선 분류한 뒤 다양한 비정상상태의 결합을 분류하는 단계 분류 방법을 제안하였다. 각 단계별로 최적 특징을 선정하고 이를 각각 적용하였으며 절차를 단순화하기 위하여 회전기계에서 측정된 시간영역 진동 신호로부터 추출한 특징데이터만을 이용하였다. 본 논문의 제 2 절에서는 본 모델의 입력데이터로 활용하기 위한 회전체 결합 실험을 간략히 소개하고 측정 데이터로부터 결합 유형별 최적 특징 선정 내용을 기술하였다. 제 3 절에서는 SVM에 대해 간략히 기술하였고 제 4 절에서 단계 결합분류 알고리즘을 제안하고 실험 자료를 이용하여 알고리즘을 적용한 결과를 기술하였다.

2. 결합유형별 최적 특징

2.1 회전체 결합 실험 개요

Fig. 1에 나타낸 회전기계 결합 실험 장치를 이용하여 원심펌프와 같은 회전기계에서 나타나는 다양한 결합조건에 대하여 가속도 신호를 취득하였다. 실험장치는 모터, 그리드 커플링, 베어링 하우징과 축으로 구성되어 있으며 모터의 회전수는 1800rpm 이고 베어링 하우징에 설치된 단축 가속도센서를 이용하여 진동을 측정하였다(샘플링율: 25kSa/s). 각 결합유형별로 취득된 데이터 수는 최하 190,000 개였으며 총 5 회를 측정하였다.

Table 1에 나타낸 바와 같이 정상상태 외에 실험 장치를 통해 모사한 결합유형은 질량 불평형(C2)에서 커플링 결합(C11)까지 총 10 가지였으며 이는 크게 베어링 결합(내륜, 외륜, 볼), 로터(접촉마모, 불평형), 축 결합(축크랙, 축굽힘) 및 풀림 결합(베어링하우징 풀림, 커플링 풀림)으로 나눌 수




Fig. 1 Test section to simulate rotating machinery faults

Table 1 Fault types examined

Fault type	Faulted part
C1 : Normal	-
C2 : Mass unbalance	Rotor
C3 : Inner race defect	Bearing
C4 : Outer race defect	Bearing
C5 : Ball defect	Bearing
C6 : Brass contact wear	Rotor
C7 : Aluminum contact wear	Rotor
C8 : Shaft bending	Shaft
C9 : Shaft crack	Shaft
C10 : Loosened bearing housing	Bearing housing
C11 : Loosened coupling fault	Coupling

있다. Table 1 에 나타낸 바와 같이 정상상태를 포함한 각 결함유형은 C1 ~ C11 로 표기하기로 한다.

2.2 측정 신호

가속도계로부터 측정된 데이터 중 일부를 Fig. 2 에 나타내었다. 대부분의 결함신호는 정상 신호 (C1)와 차이가 있음을 알 수 있으며 측정 신호로부터 이상상태의 발생 여부를 판단하고 신호분석을 통해 이상상태의 특정 결함에 대한 진단까지도 가능할 것으로 판단된다. 그러나 결함 진단을 위해서는 일정 수준의 전문성과 진단 경험이 요구되며 비전문가가 쉽게 진단할 수 있는 영역은 아니다. 예를 들어 C4 신호를 보고서 정상상태가 아님을 알 수 있으나 이는 비교대상인 정상상태의 신호에 대한 지식이 있어야 하며 결함 유형을 판단하기도 쉬운 일이 아니다. 더구나 C2 신호는 측정 신호만으로 정상상태와 구분하기도 어렵다. 따라서 일반적으로 주파수 변환 또는 웨이블릿 변환 등을 통한 신호분석이 추가로 필요하게 된다.

2.3 결함유형별 최적 특징

앞에서 살펴보았듯이 가속도계로부터 측정된 신호 자체 또는 측정신호를 다양한 방법으로 변환하거나 통계적으로 처리한 후 결함 여부를 진단할 수는 있으나 결함유형까지 판단하는 것은 어려운 일이다. 따라서 측정데이터로부터 특징을 추출하고 추출한 특징들을 그대로 이용하거나 최적의 특징을 추출하여 학습을 한 다음 결함을 분류하는 패턴분류기법을 이용하여 회전기계의 다양한 결함을 진단하거나 분류하는 연구들이 지속적으로

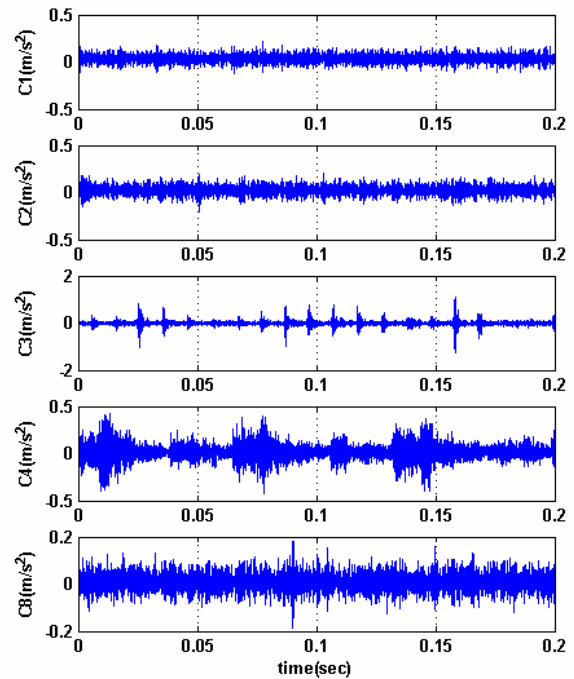


Fig. 2 Typical time domain signals

수행되어 왔다.^(3~12)

본 논문에서는 패턴인식 기법 중 SVM 을 이용하여 결함을 분류할 목적으로 측정신호의 평균값, rms, 왜도, 첨도, 최대 첨두치, 형상계수 등 18 가지 특징을 추출하였다. 5 번의 측정 자료(D1~ D5 로 표기)는 각각 9500 개의 샘플데이터로 구성된 20 개의 신호로 등분하고 등분된 신호로부터 각각 18 개의 특징을 추출하였다. 정상상태(C1)를 포함한 11 개 결함 유형별 측정신호로부터 추출한 특징의 예를 Fig. 3 에 나타내었는데, 가로축의 숫자는 결함유형(C1~C11)을 의미한다. Fig. 3 을 보면 1, 2, 11, 17, 18 번 특징들이 비교적 각 결함유형을 잘 구분하고 있으며 3 ~ 9 번 특징은 베어링 내륜결함 (C3)을 다른 결함으로부터 비교적 잘 구분하나 C3 을 제외한 다른 결함에 대해서는 특징의 차이가 없음을 알 수 있다. 따라서 11 개 결함유형을 분류하기 위한 학습에 3 ~ 9 번 특징만을 이용할 경우 좋은 분류 성능을 기대하기 어렵다.

3. Support Vector Machines

3.1 SVM 개요⁽¹⁵⁾

기본적으로 SVM 은 이진분류문제를 다루며 Fig. 4 에 나타낸 바와 같이, 서포트 벡터(support vector)

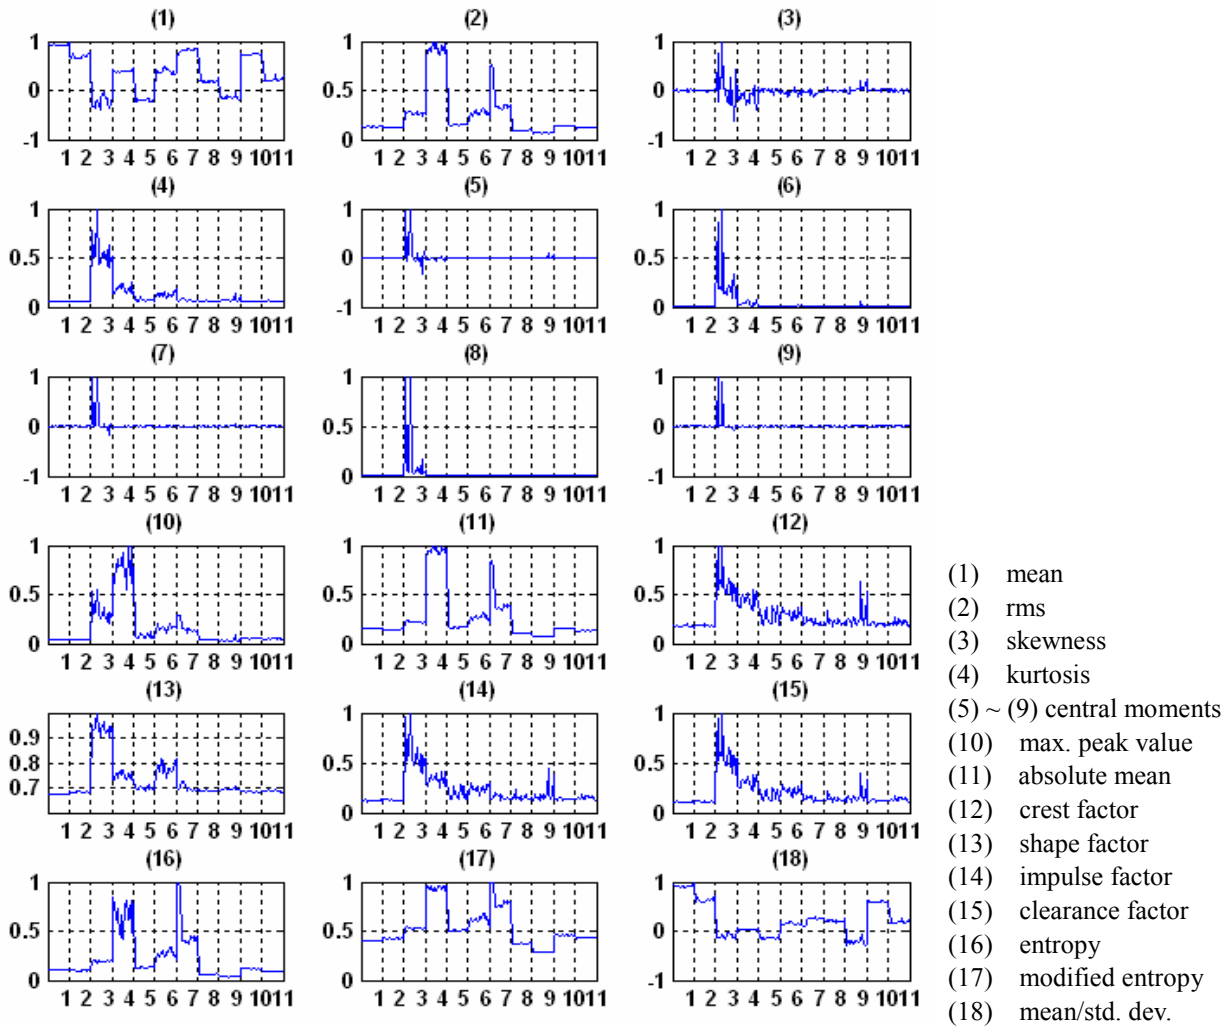


Fig. 3 Normalized features from data set 1(D1). The labels along the x-axis mean the identification numbers of the 11 classes




Fig. 4 Classification concept by support vectors

로 정의되는 초평면으로 두 개의 클래스를 구분하며 각 클래스에 속한 데이터 중 경계와 가장 인접한 데이터가 서포트 벡터가 된다. 서포트 벡터가

결정되면 서포트 벡터를 제외한 나머지 데이터들은 이용되지 않으며 새로운 데이터 분류시 서포트 벡터만을 이용하게 된다. 따라서 모든 데이터를 이용하는 알고리즘에 비해 데이터의 과적합(overfitting)을 피할 수 있고 분류 시간도 상대적으로 빠르다. SVM 에 대한 상세한 내용은 참고문헌에 잘 정리되어 있으며 여기서는 간략히 개념을 소개하고자 한다.

Fig. 4 에서 두 개의 클래스 A 와 B 의 경계에 위치한 데이터는 다음 식을 만족시킨다.

$$\vec{w} \cdot \vec{x} + b = 0 \tag{1}$$

여기서 \vec{w} 는 경계를 정의하는 벡터이고 \vec{x} 는 데이터벡터, b 는 한계값이다. 두 초 평면(H1, H2)에 서포트 벡터들이 위치하며 두 클래스에 속한 나머

지 데이터에 대해서는 다음 식이 만족된다.

$$\vec{w} \cdot \vec{x} + b \geq 1 \text{ 또는 } \vec{w} \cdot \vec{x} + b \leq -1 \quad (2)$$

따라서 입력 벡터 \vec{x} 가 속한 클래스를 결정하는 결정함수는 다음과 같이 정의할 수 있다.

$$f(x) = \text{sign}(\vec{w} \cdot \vec{x} + b) \quad (3)$$

경계를 정의하는 벡터인 \vec{w} 는 두 개의 데이터 클래스를 분리하는 최적의 초평면 H1 과 H2 사이의 거리를 최대화 하는 최적화 문제를 이용하여 다음과 같이 구할 수 있다.

$$\vec{w} = \sum_{i=1}^N \alpha_i y_i \vec{x}_i, \quad \sum_{i=1}^N \alpha_i y_i = 0 \quad (4)$$

여기서 y_i 는 서포트 벡터 \vec{x}_i 가 속한 클래스, α_i 는 라그랑지안 승수(Lagrange multiplier), N 은 입력 특징데이터 집합의 수이다. 식 (4)를 이용하여 결정함수를 다시 정의하면 다음과 같다.

$$f(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i (\vec{x}_i \cdot \vec{x}) + b\right) \quad (5)$$

따라서, 학습을 통해 α_i, \vec{x}_i, b 를 구하면 식 (5)를 이용하여 새로운 입력 데이터 \vec{x} 를 분류할 수 있다. 그러나 입력공간이 선형적으로 분리가 가능한 경우는 식 (5)를 이용하여 클래스를 분류할 수 있으나 대부분의 경우 선형적으로 쉽게 분리할 수 없다. 따라서 비선형 입력공간의 데이터를 커널(kernel) 함수를 이용하여 고차원의 특징공간으로 변환함으로써 선형화하는 방법을 이용한다. 커널 함수를 이용하여 결정함수를 다시 나타내면 다음과 같이 된다.

$$f(x) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i K(\vec{x}, \vec{x}_i) + b\right) \quad (6)$$

일반적으로 사용되는 커널 함수로는 RBF 커널, 다항(polynomial) 커널, 선형(linear) 커널, 시그모이드(sigmoid) 함수 등이 있으며 본 논문에서는 다음과 같이 정의된 RBF 커널을 이용하였다.

$$K(\vec{x}, \vec{x}_i) = \exp\left\{-\frac{\|\vec{x} - \vec{x}_i\|^2}{(2\sigma^2)}\right\} \quad (7)$$

여기서 σ 는 RBF 커널 인자이며 일반적으로 특

징데이터 집합에 대하여 최적의 결과를 얻을 수 있도록 선택하지만 최적 커널 선정이 본 논문의 주제가 아니기 때문에 여기서는 0.5 의 값을 이용하였다.

3.2 다중 분류 방법⁽¹⁶⁾

SVM 을 3 가지 이상의 다중 분류에 적용할 경우, 여러 개의 이진분류 SVM 을 구성하고 결과들을 조합하는 방법과 이진분류기를 이용하지 않고 모든 데이터를 이용하여 직접 분류하는 2 가지 방법이 있다. 현재까지는 이진분류 SVM 을 이용하는 방법이 주로 이용되고 있으며, OAA(One-Against-All), OAO(One-Against-One), DDAG(Decision Directed Acyclic Graph), ADAG(Adaptive Directed Acyclic Graph)와 같은 방법들이 제안되었다. 본 논문에서는 3 가지 이상의 결함을 분류하는 경우 OAO 알고리즘을 적용하였다.

4. 단계 결함분류 알고리즘

4.1 단계 결함분류 알고리즘

분류 문제는 입력데이터의 크기(수), 입력 특징의 수 및 분류하여야 할 클래스의 수에 크게 의존한다. 본 연구에서 고려하고 있는 입력데이터의 수 (220 개)와, 입력특징의 수(최대 18 개)는 많다고 볼 수 없으나 분류하여야 할 클래스의 수는 11 개로 적다고 볼 수 없다. 따라서 본 논문에서는 Fig. 5 에 나타낸 단일 다중분류 SVM 을 이용하여 11 개 결함을 분류하는 방법과 달리, Fig. 6 에 나타낸 단계 분류 알고리즘을 적용하여 결함유형을 분류하였다. 분류하여야 할 클래스가 많고 입력데이터의 양이 아주 많은 분류 문제에 단계 분류 알고리즘을 적용한 사례가 있으나 각 단계에서의 특징은 동일한 특징을 이용하였다.⁽¹⁴⁾

본 논문에서 제안한 단계 결함 분류 알고리즘을 적용하기 위해서는 결함 분류의 단계와 각 단계에서의 분류 대상 결함 유형을 먼저 정의하여야 한다. 분류 대상 결함유형에 대한 어느 정도의 사전 지식이 있다면 분류 성능이 개선될 수 있지만 사전 지식이 없다면 임의로 구성할 수 밖에 없는 단점이 있다. 본 논문에서는 우선 입력 특징데이터를 정상-비정상으로 분류하고(SVM1) 비정상으로 분류되면 다시 SVM2 를 이용하여 4 가지 비정상 유형, 즉 {C2, C10, C11}, {C3, C4, C5}, {C6, C7} 및 {C8, C9}로 분류하고 분류결과에 따라 SVM3 ~ SVM6 를 이용하여 최종 결함유형을 결정하도록




Fig. 5 Single multi-class SVM for 11 classes

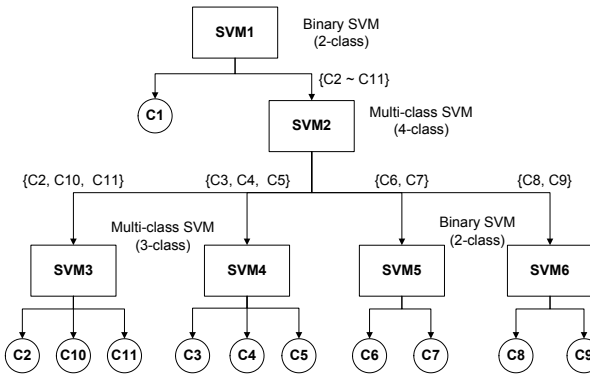


Fig. 6 Proposed stepwise classification concept

하였다. 그러나 각 단계별로 이용하는 특징들은 결합유형별 분류성능이 가장 좋은 특징들을 각각 적용하여 최적의 분류성능을 얻을 수 있도록 하였다. SVM2~SVM4 와 같이 3 가지 이상의 결합 분류 시 OAO 기법을 적용하였고, 서포트 벡터는 Pratt 이 제안한 SMO 알고리즘을 이용하여 구하였다.⁽¹⁷⁾

4.2 단계별 최적 특징

SVM 을 이용하여 학습에 이용되는 특징의 수가 많을 경우 학습시간이 길어지고 분류성능에도 영향을 미칠 수 있다. 또한 동일한 특징을 이용한 결합분류시 결합유형별 분류성능에는 차이가 있을 것으로 예상되므로 본 논문에서는 결합유형별로 특징의 차이가 최대이고 동일 결합유형내 특징의 차이는 최소가 되는 특징들을 최적 특징으로 정의하고 유효성을 평가하였다.^(7,8)

Fig. 6 의 각 단계별 SVM 분류기에 대하여 입력 특징의 유효성 우선 순위가 높은 순서대로 18 개 특징을 Table 2 에 나타내었다. 여기서 D1 ~ D5 는 5 개의 220x18 특징데이터 집합을 각각 나타내며 이를 학습을 위한 입력데이터로 이용하였다는 것을 의미한다. 예상한 바와 같이, Table 2 를 보면 단계 분류 알고리즘을 적용할 경우 각 단계에서의 SVM 분류기 (SVM1 ~ SVM6)에 대한 입력 특징들의 유효성 순위가 각각 다름을 확인할 수 있으며

OAO 알고리즘을 이용하여 11 개 클래스를 분류하는 단일 다중 분류 SVM(Fig. 5)의 입력 특징들의 유효성 순위와도 차이가 있음을 알 수 있다.

4.3 단계별 최적 특징 적용 결과

동일 가속도계를 이용하여 독립적으로 측정된 5 번의 시계열 데이터를 이용하여 제안 알고리즘을 검증하였다. 5 개의 220x18 특징데이터 집합을 각각 이용하여(D1 ~ D5) SVM 분류기들을 학습하였고 학습에 이용되지 않은 4 개의 220x18 특징데이터 집합을 이용하여 검증하였다. 예를 들어 D3 이 학습용 입력 데이터일 경우 검증용 데이터는 D1, D2, D4, D5 가 된다. 결합유형별 최적 특징 데이터를 고려하지 않고 모든 데이터에 대한 최적 특징데이터(Table 2 의 단일 다중 분류 SVM)와 OAO 알고리즘을 이용하여 11 개 클래스에 대한 분류 결과를 Table 3 에 나타내었고 단계별 분류 알고리즘을 이용한 결과는 Table. 4 에 나타내었다. Table 3 과 4 에서, 특징의 수가 1 이고 학습용 특징 데이터 집합이 D1 인 경우 SVM1 에서 SVM6 까지의 단계 분류 알고리즘에 이용한 특징은 각각 16, 17, 1, 11, 1, 17이며 단일 다중분류 SVM 을 이용한 경우 1 을 의미한다(Table 2).

Table 3 과 4 를 보면 입력 특징데이터의 수가 10 이상이 되면 분류성능에 큰 영향이 없는 것으로 나타나 우선순위가 11 번째 이상인 특징들은 분류성능에 큰 영향을 미치지 않음을 알 수 있다. 입력 특징데이터의 수가 5 이하로 작아질 경우 D1 을 학습데이터로 이용할 경우를 제외하고는 단일 다중분류 SVM 을 이용한 경우가 더 나은 분류성능을 보여주고 있으며 10 개 이상의 특징을 이용할 경우에는 단계 분류 알고리즘의 성능이 약간 나은 것으로 보이나 그 차이는 크지 않다. 결합유형별 최적 특징 데이터의 수를 1 개만 이용하는 경우, 단일 다중분류 SVM 은 D1 을 예외로 하여도 59%의 최저 분류 성능을 보여주고 있으나 단계 분류 알고리즘은 63% 이상의 분류성능을 보여주고 있다. 전체적으로 분류 정확도 측면에서는 두 가지 방법이 비슷한 결과를 나타내었고 특히 결합유형별 특징데이터의 수가 많은 경우는(최대 18 개) 두 가지 방법에 의한 결과가 거의 동일함을 알 수 있다. 그러나 Table 5 에 나타낸 상대 학습시간을 보면 두 경우 모두 특징데이터 수(최대 18)에 따른 학습시간의 차이는 거의 없으나, 단계 분류 알고리즘의 학습시간이 단일 다중분류 SVM 학습시간의 60~70% 정도로 짧은 것으로 나타나 적은 학습시간으로 유사한 분류 성능을 얻을 수 있음을 알 수 있다.

Table 2 Optimal Features for each SVM classifier (D1 ~ D5 : data set for training)

Classifiers	Features selected				
	D1	D2	D3	D4	D5
SVM1	18,1,13,12,14,1 5,17,10,4,6,2,16 ,8,11,9,7,5,3	18,1,13,12,14,1 5,4,17,10,6,8,2, 16,11,3,5,7,9	18,1,12,14,15,1 3,10,4,17,6,2,16 ,8,11,9,7,5,3	18,1,13,12,14,1 5,17,10,4,6,2,16 ,8,11,9,7,5,3	18,1,13,12,14,1 5,4,17,10,6,8,2, 16,11,3,5,7,9
SVM2	17,18,10,16,2,1 1,1,4,13,14,15,1 2,6,8,9,7,5,3	17,16,11,2,10,1 8,1,4,6,14,12,15 ,13,8,3,5,7,9	17,10,2,11,16,1 8,1,4,13,15,14,1 2,6,8,9,7,5,3	17,18,10,16,2,1 1,1,4,13,14,15,1 2,6,8,9,7,5,3	17,16,11,2,10,1 8,1,4,6,14,12,15 ,13,8,3,5,7,9
SVM3	1,18,16,2,11,17, 13,10,15,14,12, 8,6,4,3,5,7,9	1,18,16,11,2,17, 13,10,4,15,14,9, 12,6,3,7,8,5	1,18,11,16,2,17, 13,15,14,12,8,1 0,6,4,9,5,3,7	1,18,16,2,11,17, 13,10,15,14,12, 8,6,4,3,5,7,9	1,18,16,11,2,17, 13,10,4,15,14,9, 12,6,3,7,8,5
SVM4	11,17,2,13,1,16, 10,4,18,15,14,1 2,6,8,9,7,5,3	11,2,17,13,1,18, 10,4,16,15,14,6, 12,8,3,5,7,9	17,11,2,13,1,16, 10,18,4,15,14,1 2,6,8,3,9,5,7	11,17,2,13,1,16, 10,4,18,15,14,1 2,6,8,9,7,5,3	11,2,17,13,1,18, 10,4,16,15,14,6, 12,8,3,5,7,9
SVM5	1,13,17,4,15,14, 6,12,16,11,8,2,1 8,10,5,7,9,3	1,18,13,17,16,4, 2,15,10,11,14,1 2,6,8,9,7,5,3	1,18,17,16,13,2, 11,10,7,9,5,8,3, 6,15,4,14,12	1,13,17,4,15,14, 6,12,16,11,8,2,1 8,10,5,7,9,3	1,18,13,17,16,4, 2,15,10,11,14,1 2,6,8,9,7,5,3
SVM6	17,11,16,2,1,18, 13,4,6,8,9,7,5,1 5,14,12,3,10	11,17,2,16,1,18, 10,13,12,14,15, 7,5,9,4,3,8,6	17,11,2,16,1,18, 10,9,7,8,13,12,1 4,5,15,6,3,4	17,11,16,2,1,18, 13,4,6,8,9,7,5,1 5,14,12,3,10	11,17,2,16,1,18, 10,13,12,14,15, 7,5,9,4,3,8,6
Single multi-class SVM (Fig. 5)	1,17,18,11,2,13, 10,16,4,15,14,1 2,6,8,9,7,5,3	1,11,18,17,2,13, 16,10,4,15,14,6, 12,8,3,5,7,9	1,17,18,11,2,16, 13,10,4,15,14,1 2,6,8,9,7,3,5	1,18,11,2,17,13, 16,10,4,15,14,1 2,6,8,9,7,5,3	1,18,17,11,2,13, 16,10,4,15,14,1 2,6,8,5,7,9,3

Table 3 Training and classification results by single multi-class SVM

No. of features	Training results (%)					Classification results (%)				
	D1	D2	D3	D4	D5	D1	D2	D3	D4	D5
1	70.9	87.7	81.4	88.2	82.7	39.3	59.2	64.6	61.9	60.7
3	99.5	98.2	98.6	97.3	99.5	73.8	91.3	88.8	83.6	83.5
5	100	99.1	99.1	100	100	78	91	88.4	85.8	83.3
10	100	99.5	99.5	100	100	84.7	93.5	91.1	87	87.2
15	100	99.5	99.5	100	100	83.3	94.1	90.2	86.5	87.3
18	100	99.5	99.5	100	100	83.8	94.1	91.5	86.1	87.2

Table 4 Training and classification results by stepwise classification algorithm

No. of features	Training results (%)					Classification results (%)				
	D1	D2	D3	D4	D5	D1	D2	D3	D4	D5
1	94.1	78.2	80.5	84.5	78.2	66.6	63.8	69.2	72.3	77.6
3	100	90.5	89.1	95.5	94.5	78.6	83.6	77.7	77.4	78.6
5	100	94.1	91.8	95.5	95	86.6	84.6	78.9	77.9	79.1
10	100	99.5	99.5	100	100	84.3	94	91.7	87.6	88
15	100	99.5	99.5	100	100	83.2	94.1	91.4	88.1	87.8
18	100	99.5	99.5	100	100	83.5	94.1	91.6	88.1	87.9

Table 5 Relative training time of stepwise classification algorithm to single multi-class SVM

No. of features	Relative training time				
	D1	D2	D3	D4	D5
1	0.58	0.59	0.66	0.63	0.65
3	0.66	0.61	0.65	0.6	0.71
5	0.69	0.63	0.64	0.62	0.64
10	0.68	0.64	0.62	0.69	0.65
15	0.67	0.6	0.65	0.64	0.68
18	0.67	0.64	0.69	0.63	0.64

5. 결론

본 연구에서는 결합유형별 최적 특징과 SVM 을 이용하여 회전기계의 정상상태로부터 비정상상태를 우선 분류하고 다양한 비정상상태 결합을 분류하는 단계 결합분류 알고리즘을 제안하였다. 결합유형별 최적특징은 측정 신호에 대한 전처리 없이 시간영역 진동신호로부터 직접 추출한 특징들을 이용하여 도출하였다. 제안 알고리즘을 정상상태를 포함한 11 가지 인위적 결합 실험 데이터를 이용하여 검증한 결과, 단일 다중분류 SVM 에 비해 60~70%의 학습시간으로 유사한 분류성능을 얻을 수 있었다. 제안 알고리즘은 회전기계에 대한 이상상태 여부에 대한 판단과 함께 이상상태에 대한 결합 분류에 적용할 수 있으며 시간영역 측정데이터의 전처리 데이터를 이용하여 더 많은 입력 특징데이터를 고려할 경우 분류 성능이 개선될 것으로 기대된다.

향후 결합의 크기 영향에 대한 실험 수행 및 특징데이터 추가 개발을 통해 회전기계의 결합 분류뿐만 아니라 결합의 크기까지 진단할 수 있도록 하고, 본 알고리즘을 이용하여 현장에서 실시간 진단이 가능한 진단 프로그램을 개발할 계획이다.

참고문헌

(1) Tse, P.W., Peng, Y.H. and Yam, R., 2001, "Wavelet Analysis and Envelope Detection for Rolling Element Bearing Fault Diagnosis – Their Effectiveness and Flexibilities," *Journal of Vibration and Acoustics*, Vol.123, pp.303~310.
 (2) Zhang, Y.X. and Randall, R.B., 2009, "Rolling Element Bearing Fault Diagnosis Based on the Combination of Genetic Algorithm and Fast Kurtogram," *Mechanical Systems and Signal Processing*, Vol.23, pp.1509~1517.

(3) Jack, L.B. and Nandi, A.K., 2002, "Fault Detection Using Support Vector Machines and Artificial Neural Networks, Augmented by Genetic Algorithms," *Mechanical Systems and Signal Processing*, Vol.16, pp.373~390.
 (4) Hwang, W.W. and Yang, B.S., 2004, "Fault Diagnosis of Rotating Machinery Using Multi-Class Support Vector Machines," *Trans. of the KSNVE*, Vol. 14, No.12, pp.1233~1240.
 (5) Samanta, B., 2004, "Gear Fault Detection Using Artificial Neural Networks and Support Vector Machines with Genetic Algorithms," *Mechanical Systems and Signal Processing*, Vol.18, pp.625~644.
 (6) Yang, B.S., Hwang, W.W., Kim, D.J. and Tan, A., 2005, "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.
 (7) Hu, Q, He, Z.J, Zhang, Z.S. and Zi, Y.Y., 2007, "Fault Diagnosis of Rotating Machinery Based on Improved Wavelet Package Transform and SVMs ensemble," *Mechanical Systems and Signal Processing*, Vol.21, pp.688~705.
 (8) Yang, B.S., Han, T. and Hwang, W.W., 2005, "Fault Diagnosis of Rotating Machinery Based on Multi-Class Support Vector Machines," *KSME Int. J.*, Vol. 19, No.31, pp.846~859.
 (9) Tyagi, C.S., 2008, "A Comparative Study of SVM Classifiers and Artificial Neural Networks Application for Rolling Element Bearing Fault Diagnosis using Wavelet Transform Preprocessing," *Proceedings of World Academy of Science, Engineering and Technology*, Vol.33, pp.319~327.
 (10) Samanta, B., Al-Balushi, K.R. and Al-Araimi, S.A., 2003, "Artificial Neural Networks and Support Vector Machines with Genetic Algorithm for Bearing Fault Detection," *Engineering Applications of Artificial Intelligence*, Vol. 16, pp.657~665.
 (11) Hu, Z.H, Cai, Y.Z., Li, Y.G. and Xu, X.M., 2005, "Data Fusion for Fault Diagnosis Using Multi-class Support Vector Machines," *J. Zhejiang University Science*, Vol. 10, No.6A, pp.1030~1039.
 (12) Yan W.W., Shao, H.H. and Wang, X.F., 2003, "Parallel Decision Models Based on Support Vector Machines and Their Application to Distributed Fault Diagnosis," *Proceedings of the American Control Conference, Denver, Colorado, June 4-6, 2003*, pp.1770~1775.
 (13) Kim, H.C., Pang, S.N., Je, H.M., Kim, D.J. and Bang S.Y., 2003, "Constructing Support Vector Machine Ensemble," *Pattern Recognition*, Vol. 36, pp.2757~2767.
 (14) Rovero, D., 2002, "ARTD: Autonomous Recursive Task Decomposition for Many-Class Learning," *International J. Knowledge-Based Intelligent Engineering*

Systems, Vol. 6, No. 4.

(15) Cristianini, N. and Shawe-Taylor, J., 2000, *An Introduction to Support Vector Machines and other Kernel-Based Learning Methods*, Cambridge University Press, Cambridge.

(16) Hsu, C.W. and Lin, C.J., 2002, "A Comparison of

Methods for Multiclass Support Vector Machines," *IEEE Transactions on Neural Networks*, Vol. 13, No.2, pp.415~425.

(17) Platt, J.C., 1998, *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*, Technical Report MSR-TR-98-14.