

서포트 벡터 머신을 이용한 볼 베어링의 결함 정도 진단[§]

김양석^{*†} · 이도환^{*} · 김대웅^{*}

* 한국수력원자력(주) 중앙연구원

Fault Severity Diagnosis of Ball Bearing by Support Vector Machine

Kim Yang-seok^{*†}, Lee Do-hwan^{*} and Kim Dae-woong^{*}

* Central Research Institute, Korea Hydro & Nuclear Co., Ltd.

(Received June 14, 2012 ; Revised March 18, 2013 ; Accepted March 19, 2013)

Key Words: Support Vector Machine(서포트 벡터 머신), Fault Classification (결함분류), Optimized Feature(최적 특징), Bearing Fault(베어링 결함)

초록: 서포트 벡터 머신(Support Vector Machine, SVM)은 학습용 데이터 집합이 확보되어 있을 경우, 매우 강력한 분류 알고리즘이다. 따라서 패턴인식은 물론 기계학습 분야에서 결함진단 도구의 하나로 이용되고 있다. 본 논문에서는 최적 특징과 SVM 을 이용하여 볼 베어링의 결함유형과 결함의 정도를 진단한 결과를 기술하였다. SVM 학습용 특징데이터에는 12 개의 시간영역 특징과 9 개의 주파수영역 특징들이 포함되어 있으며 이들 특징들은 다양한 베어링 결함조건에서 측정된 진동신호와 진동신호의 이산 웨이블릿 변환신호로부터 추출되었다.

Abstract: A support vector machine (SVM) is a very powerful classification algorithm when a set of training data, each marked as belonging to one of several categories, is given. Therefore, SVM techniques have been used as one of the diagnostic tools in machine learning as well as in pattern recognition. In this paper, we present the results of classifying ball bearing fault types and severities using SVM with an optimized feature set based on the minimum distance rule. A feature set as an input for SVM includes twelve time-domain and nine frequency-domain features that are extracted from the measured vibration signals and their decomposed details and approximations with discrete wavelet transform. The vibration signals were obtained from a test rig to simulate various bearing fault conditions.

- 기호설명 -

b : 한계값(threshold value)
 C : 오차에 대한 페널티 상수
 f_i : 주파수
 $f(\mathbf{x})$: 결정함수
 $K(\mathbf{x}_i, \mathbf{x}_j)$: 커널함수
 $L_D(a)$: 라그랑지안 함수
 N : 입력 특징데이터 집합의 수 또는 스펙트럼 라인의 수
 $P_1 \sim P_9$: 주파수 영역 특징(Table 1)
 $P(x)$: 이산신호의 에너지 확률분포 함수
 $S(f)$: 스펙트럼 파워

\mathbf{w} : 가중치 벡터
 \mathbf{x} : 입력 벡터
 y_i : 클래스 속성(+1 또는 -1)
 a_i : 라그랑지안 승수
 ζ_i : 잔여 변수(slack variable)

1. 서론

원자력발전소에 설치되어 있는 주요 회전기계의 경우 베어링 성능 저하에 의해 이상진동이 유발되고 이는 곧 회전기계의 성능 저하 및 수명단축을 가져와 심한 경우 발전정지까지 초래할 수 있다. 따라서 원전에 설치된 주요 회전기계에 대해서는 최적의 성능을 유지시키기 위한 시험, 검사 및 정비를 일정 주기로 수행하고 있으며 예측정비 및 상태진단을 추가로 수행하기도 한다.

§ 이 논문은 2012년도 대한기계학회 에너지 및 동력공학부문 춘계학술대회(2012. 5. 17.-18., 재료연구소) 발표논문임

† Corresponding Author, kimysrj@khnpc.co.kr

© 2013 The Korean Society of Mechanical Engineers

회전기계의 볼 베어링 이상상태는 일반적으로 진동 주파수 성분과 진동의 크기를 분석하는 방법을 이용한다. 여기서 분석이란 단순히 측정된 진동데이터 파형이나 크기, 주파수 분석뿐만 아니라 웨이블릿 변환 등 다양한 신호 처리 기법을 이용하기도 한다^(1,2). 최근에는 인공신경망(Artificial Neural Networks, ANNs), 서포트 벡터 머신(Support Vector Machines, SVMs) 등과 같은 지능형 분류기법을 기기상태 또는 베어링 진단에 적용하기도 하였다⁽³⁻⁶⁾. 지능형 분류기법의 분류성능은 ANN 과 SVM 과 같은 분류기의 성능뿐만 아니라 입력 특징데이터에 의해서도 영향을 받기 때문에 회전기계에서 측정된 진동신호에서 직접 추출한 특징 이외에 진동신호의 웨이블릿 변환이나 필터링 등을 거친 신호로부터 추가로 특징을 추출하여 이용하기도 하였다. 그러나 현재까지는 볼 베어링의 결합 정도에 대한 진단보다는 내륜, 외륜, 볼 등의 주요 결함유형에 대한 진단 위주로 수행되어 왔다.

본 논문에서는 볼 베어링의 다양한 결합조건에서 측정된 진동신호와 SVM 을 이용하여 볼 베어링의 결합 정도를 진단하는 방법을 제안하였다. 먼저 SVM 학습용 데이터를 얻기 위하여 볼 베어링 결합 실험을 수행하고 그 내용을 제 2 절에 기술하였다. 제 3 절에서는 SVM 이론에 대해 간략히 기술하였고 제 4 절에서 진동신호로부터 추출한 SVM 입력 특징데이터 및 SVM 을 이용한 볼 베어링의 결합 정도 진단 결과를 기술하였다.

2. 베어링 결함 실험

2.1 실험 개요

볼 베어링의 결함 실험은 Fig. 1 에 나타난 회전기계 결함 실험장치를 이용하여 수행하였다. 실험장치는 모터, 커플링, 로터, 베어링 하우징과 축으로 구성되어 있으며, 모터 회전수는 1800rpm 이고 베어링 하우징에 설치된 단축 가속도 센서를 이용하여 진동을 측정하였다(샘플링율: 25kSa/s).

Fig. 1 에 나타난 바와 같이, 정상상태 외에 베어링 내륜 결함, 외륜 결함, 볼 결함, 그리고 내륜, 외륜 및 볼 결함이 복합된 결함을 모사하여 실험을 수행하였다. 베어링 내륜, 외륜 및 볼 결함의 정도는 다섯 가지로 하였고 내륜, 외륜 및 볼 결함을 모두 가한 복합 결함의 정도는 세 가지로 하였다. 내륜 및 외륜 결함은 결함의 폭을 일정하게 ($W = 8\text{mm}$) 하고 길이(L)를 각각 0.5, 1.0, 2.0, 3.0, 4.0mm 로 하였고, 볼 결함의 경우 결함의 직경(D)




Fig. 1 Test section to simulate rotating machinery with bearing faults (defect width, $W = 8\text{mm}$)

를 각각 0.5, 1.0, 2.0, 3.0, 4.0mm 로 하였다. 복합결함의 경우 내륜, 외륜의 결함길이 및 볼 결함 직경의 조합을 각각 $0.5\text{mm} \times 0.5\text{mm} \times 1.0\text{mm}$, $2.8\text{mm} \times 2.8\text{mm} \times 1.0\text{mm}$, $1.0\text{mm} \times 1.0\text{mm} \times 2.8\text{mm}$ 로 하였다.

2.2 측정 신호

가속도 센서로부터 측정된 진동신호의 일부를 Fig. 2 에 나타내었다. 볼 베어링의 결함신호는 정상신호와 차이가 있고 결함유형에 따라서도 차이가 있음을 알 수 있다. 그러나 결함진단에 관한 일정 수준의 전문성과 진단 경험이 있다 하더라도 Fig. 2 의 진동신호만으로 각각의 결함을 진단하기는 쉽지 않다. 더구나 Fig. 3 ~ Fig. 6 에 나타난 것처럼, 베어링 결함유형이 동일하더라도 결함의 정도가 다를 경우에도 신호가 모두 다르다. 따라서 볼 베어링의 결함진단에는 일반적으로 주파수 변환 또는 웨이블릿 변환 등을 통한 신호분석을 추가로 수행하게 된다.

Fig. 7 은 정상 및 베어링 내륜 결함신호에 대한 이산 웨이블릿 변환 (Discrete Wavelet Transform, DWT) 신호를 나타낸 것으로, Doubeches-10 기저함수를 이용하여 레벨 3 까지 분해된 신호이다. Fig. 7 을 보면, 측정된 진동신호 외에 DWT 변환 신호에서도 정상상태와는 다른 특징들을 추출할 수 있을 것으로 판단된다.

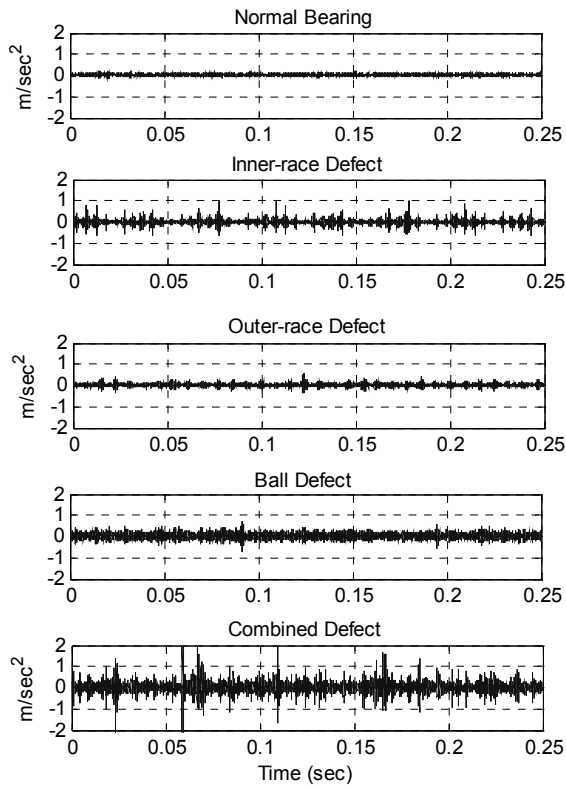


Fig. 2 Vibration signals with normal and various bearing defects

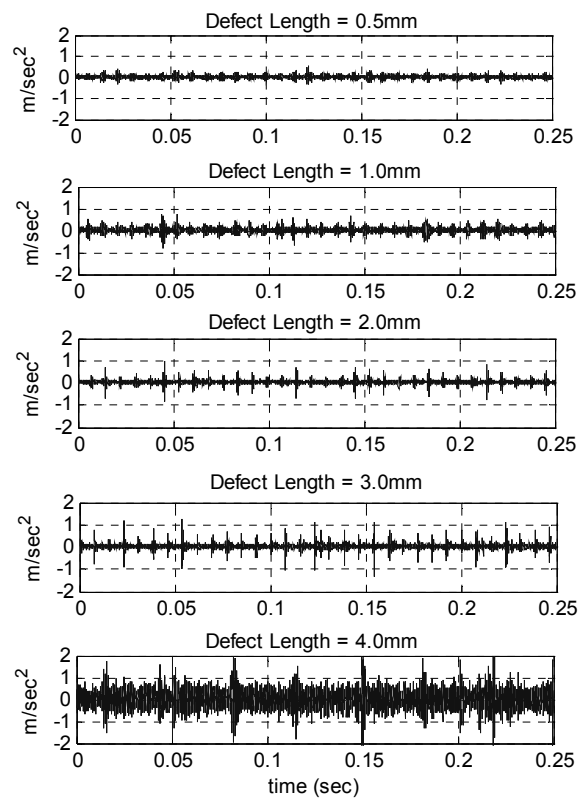


Fig. 4 Vibration signals with bearing outer race defects (defect width = 8mm)

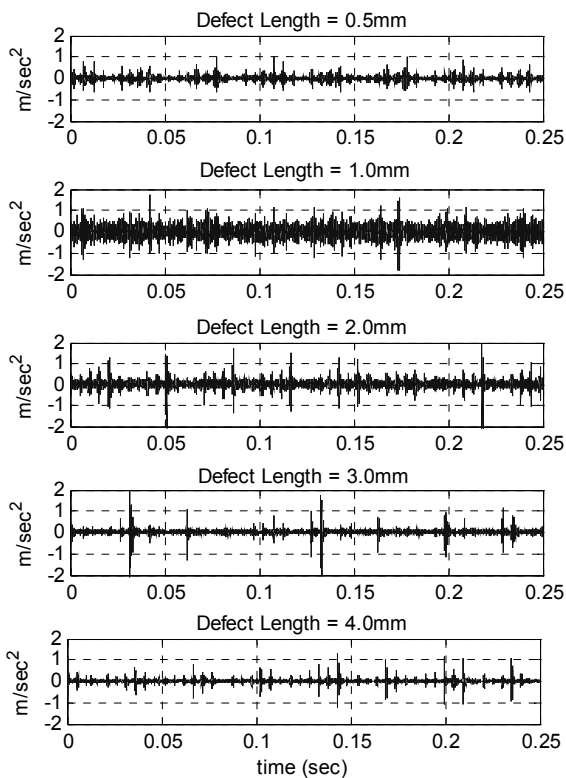


Fig. 3 Vibration signals with bearing inner race defects (defect width = 8mm)

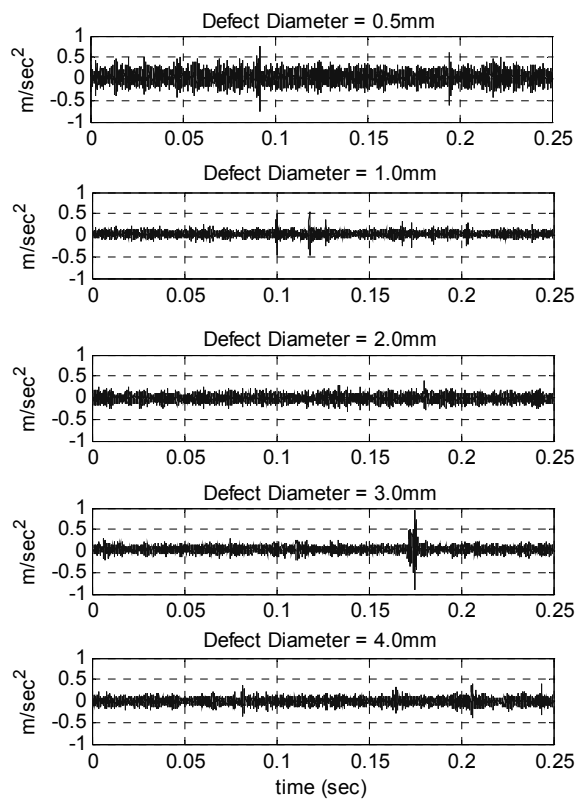


Fig. 5 Vibration signals with bearing ball defects

3. Support Vector Machine

SVM 은 통계적 학습 이론에 기반을 둔 분류기로, SVM 에 대한 상세한 내용은 참고문헌에 잘 정리되어 있어⁽⁷⁻⁹⁾ 여기서는 간략히 개념만을 소개하고자 한다. 기본적으로 SVM 은 이진분류문제를

다루며 Fig. 8 에 나타난 바와 같이, 서포트 벡터로 정의되는 최대거리 초평면으로 두 개의 클래스를 구분한다. 각 클래스에 속한 데이터 중 경계와 가장 인접한 데이터인 서포트 벡터를 결정하고 서포트 벡터만을 이용하여 새로운 데이터를 분류하므로, 모든 데이터를 이용하는 알고리즘에 비해 데이터의 과적합을 피할 수 있고 분류시간도 상대적으로 빠르다.

Fig. 8 과 같이 학습용 데이터 집합 (\mathbf{x})이 주어진 경우, 두 개의 클래스 1 과 2 의 경계에 위치한 데이터는 다음 식을 만족시킨다.

$$\mathbf{w} \cdot \mathbf{x} - b = 0 \tag{1}$$

여기서 \mathbf{w} 는 경계를 정의하는 가중치 벡터이고 \mathbf{x} 는 데이터벡터, b 는 한계값이다. 두 개의 초평면 (H_1, H_2) 위에 서포트 벡터들이 위치하며 두 클래스에 속한 나머지 데이터에 대해서는 다음과 같은 결정함수를 이용하여 입력 벡터 \mathbf{x} 가 속한 클래스를 결정할 수 있다.

$$f(\mathbf{x}) = \text{sign}(\mathbf{w} \cdot \mathbf{x} - b) \tag{2}$$




Fig. 6 Vibration signals with combined defects: defect size means defect lengths of inner – and outer-race and defect diameter of ball, respectively

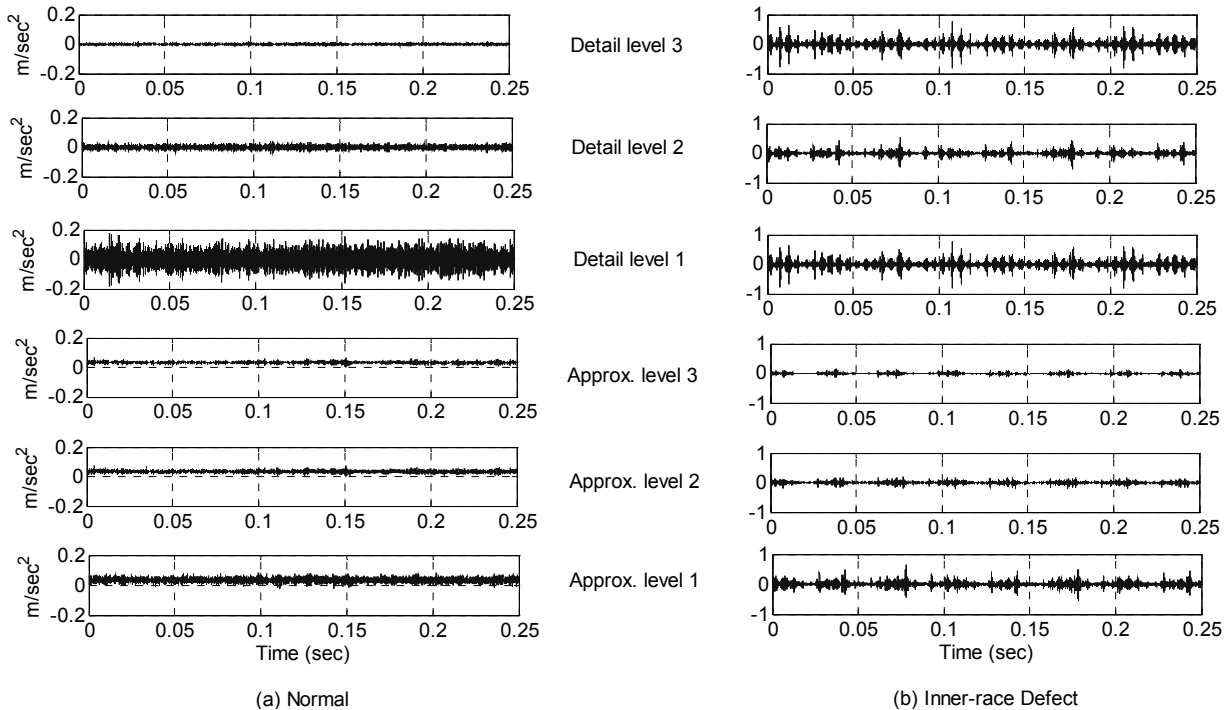


Fig. 7 Comparisons of DWT signals between normal and inner-race defect bearings




Fig. 8 Binary Classification using support vectors

식 (1)과 두 개의 클래스를 분리하는 초평면 H1과 H2 사이의 거리를 최대로 하는 제한조건을 고려하면 다음과 같은 최적화 문제를 이용하여 가중치 벡터와 한계값을 구할 수 있다.

$$\begin{aligned} \text{Minimize } \tau(\mathbf{w}) &= \|\mathbf{w}\|^2 / 2 \\ \text{Subject to } y_i \cdot (\mathbf{w} \cdot \mathbf{x} - b) &\geq 1, \quad i = 1, 2, 3, \dots, N \end{aligned} \quad (3)$$

그러나 입력공간이 선형적으로 분리가 가능한 경우는 식 (3)을 이용하여 클래스를 분류할 수 있으나 선형적으로 완전 분리가 불가능한 경우, 제한조건에서 벗어나는 정도를 나타내는 부가 변수를 도입하여 다음과 같은 최적화 문제를 이용한다.

$$\begin{aligned} \text{Minimize } \tau(\mathbf{w}) &= \|\mathbf{w}\|^2 / 2 + C \sum_{i=1}^N \xi_i \\ \text{Subject to } y_i \cdot (\mathbf{w} \cdot \mathbf{x} - b) &\geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, 2, 3, \dots, N \end{aligned} \quad (4)$$

식 (4)는 제약조건이 부등식인 최적화 문제가 되며 여러 가지 최적화 해법 중에서 라그랑지안 승수를 이용하여 다음과 같이 라그랑지안 함수로 나타낼 수 있다.

$$\begin{aligned} \text{Maximize } L_D(\alpha) &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \\ \text{Subject to } \sum_{i=1}^N \alpha_i y_i &= 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, N \end{aligned} \quad (5)$$

식 (5)를 이용하여 라그랑지안 승수 α_i 와 서포트 벡터 \mathbf{x}_i , 가중치 벡터 \mathbf{w} , 한계값 b 를 구하면 다음과 같이 결정함수를 다시 정의할 수 있다.

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i (\mathbf{x} \cdot \mathbf{x}_i) - b\right) \quad (6)$$

한편 비선형 입력 벡터에 대해서는 커널 함수를 이용하여 고차원의 특징공간으로 변환함으로써 선형화하는 방법을 이용한다. 본 논문에서는 다항 (polynomial) 커널을 이용하였으며 결정함수 식 (6)을 커널 함수로 다시 나타내면 다음과 같다.

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) - b\right) \quad (7)$$

앞에서 기술한 바와 같이 SVM은 기본적으로 두 개의 클래스를 분류하는 이진분류기이므로 세 개 이상의 클래스를 분류하는 다중분류문제에 그대로 적용할 수 없다. SVM을 세 가지 이상의 다중분류에 적용할 경우, 여러 개의 이진분류 SVM을 구성하고 결과들을 조합하는 방법과 이진분류기를 이용하지 않고 모든 데이터를 이용하여 직접 분류하는 방법이 제안되어 있다⁽¹⁰⁾. 현재까지 모든 데이터를 직접 분류하는 방법보다는 이진분류 SVM을 이용하는 방법이 주로 이용되고 있으며, OAA(One-Against-All), OAO(One-Against-One), DDAG(Decision Directed Acyclic Graph)와 같은 방법들이 있다.

4. 베어링 결함 정도 진단

분류 문제에서 분류성능은 입력데이터 집합의 크기, 입력 특징 및 입력 특징의 수, 분류하여야 할 클래스의 수 등에 따라 달라진다. 본 논문에서는 정상상태를 포함하여 베어링 결함유형(내륜, 외륜, 볼, 복합) 및 결함의 정도에 따라 각각 10개의 입력 특징데이터 집합을 SVM 학습에 이용하였다. SVM 학습 후 검증에 이용된 특징데이터 집합의 수는 결함유형에 따라 25 ~ 42 개였다. 입력 특징데이터 집합의 특징 수는 최대 84 개이며 분류하여야 할 클래스는 정상상태 포함 19 개이다 (Fig. 3 ~ Fig. 7 참조). 다중분류방법으로 OAO 기법을 적용하였고, 서포트 벡터는 Pratt이 제안한 SMO 알고리즘을 이용하여 구하였다⁽¹¹⁾.

4.1 특징 추출

2절에서 기술한 베어링 결함 실험으로부터 측정된 진동신호와 진동신호에 대한 이산 웨이블릿 변환 결과인 세 개의 detail 및 approximation 신호를 이용하여 SVM 입력을 위한 특징을 추출하였다.

진동신호와 세 개의 DWT detail 신호에 대해서는 각각 평균값, RMS, 왜도, 첨도, 형상계수, 과고율, 엔트로피 추정값 및 엔트로피 추정 오차, 히스토그램의 상·하한값, 바이블(Weibull) 및 정규 음

의 로그-우도값(negative log-likelihood) 등 12 개의 시간영역 특징을 추출하였다. 또한, 진동신호와 세 개의 DWT approximation 신호에 대한 FFT 스펙트럼으로부터 Table 1 에 나타난 9 개의 특징을 추가로 추출하였다⁽¹²⁾. 따라서 시간영역 신호로부터 총 48 개, FFT 스펙트럼으로부터 총 36 개의 특징을 구하였고, 해당 특징들을 구분하기 위하여 Table 2 에 나타난 바와 같이 번호를 부여하였다.

4.2 결함유형별 결함 정도 진단

이전 연구에서 제안한 단계분류 알고리즘은 결

함유형을 먼저 분류한 뒤 결함유형별 결함의 정도를 분류하는 것이었다⁽¹³⁾. 결함유형별로 결함의 정도를 진단할 경우, 내륜, 외륜, 볼 및 복합 결함의 경우 각각, 5 개, 5 개, 5 개, 3 개의 클래스를 분류하는 것에 해당된다. Table 3 에 나타난 바와 같이 84 개 특징 전부를 이용하여 진단한 결과 분류성능은 아주 좋게 나타났다. 본 논문에서는 결함유형과 결함정도를 한번에 분류하는 방법을 제안하여 정상상태 포함 총 19 개 클래스를 분류할 수 있도록 하였다.

Table 1 Definitions of frequency domain features where N, f_i and $S(f_i)$ are total number of spectrum line, frequency, and spectrum power, respectively

$$P_1 = \frac{\sum_i^N f_i S(f_i)}{\sum_i^N S(f_i)}, \quad P_2 = \sqrt{\frac{\sum_i^N (f_i - P_1)^2 S(f_i)}{N-1}}, \quad P_3 = \sqrt{\frac{\sum_i^N f_i^2 S(f_i)}{\sum_i^N S(f_i)}}, \quad P_4 = \sqrt{\frac{\sum_i^N f_i^4 S(f_i)}{\sum_i^N f_i^2 S(f_i)}}$$

$$P_5 = \frac{\sum_i^N f_i^2 S(f_i)}{\sqrt{\sum_i^N S(f_i) \sum_i^N f_i^4 S(f_i)}}, \quad P_6 = \frac{P_2}{P_1}, \quad P_7 = \frac{\sum_i^N (f_i - P_1)^3 S(f_i)}{P_2^3 N}, \quad P_8 = \frac{\sum_i^N (f_i - P_1)^4 S(f_i)}{P_2^4 N}$$

$$P_9 = \frac{\sum_i^N \sqrt{|f_i - P_1|} S(f_i)}{\sqrt{P_2 N}}$$

Table 2 Feature identification numbers by signal sources.

	Original	DWT Level 1		DWT Level 2		DWT Level 3	
	time signal	Details	Approx.	Details	Approx.	Details	Approx.
Mean	1	22	-	43	-	64	-
RMS	2	23	-	44	-	65	-
Skewness	3	24	-	45	-	66	-
Kurtosis	4	25	-	46	-	67	-
Shape factor	5	26	-	47	-	68	-
Crest factor	6	27	-	48	-	69	-
Entropy estimation	7	28	-	49	-	70	-
Entropy estimation error	8	29	-	50	-	71	-
Upper bounds of histogram	9	30	-	51	-	72	-
Lower bounds of histogram	10	31	-	52	-	73	-
Weibull negative log-likelihood	11	32	-	53	-	74	-
Normal negative log-likelihood	12	33	-	54	-	75	-
P ₁	13	-	34	-	55	-	76
P ₂	14	-	35	-	56	-	77
P ₃	15	-	36	-	57	-	78
P ₄	16	-	37	-	58	-	79
P ₅	17	-	38	-	59	-	80
P ₆	18	-	39	-	60	-	81
P ₇	19	-	40	-	61	-	82
P ₈	20	-	41	-	62	-	83
P ₉	21	-	42	-	63	-	84

Table 3 Classification results for fault severity of each bearing fault type

Fault types	No. of severity classes	Training (%)	Test (%)
Inner-race defect	5	100	100
Outer-race defect	5	100	100
Ball defect	5	100	100
Combined defect	3	100	97.6

4.3 특징의 수 및 신호처리에 따른 영향

SVM 을 이용하여 학습에 이용되는 특징의 수가 많을 경우 학습시간이 길어지고 분류성능에도 영향을 미칠 수 있다. 또한 클래스 별 특징의 차이가 최대이고 동일 클래스 내 특징의 차이는 최소가 되는 특징들이 클래스 분류 유효성이 더 크므로, 본 논문에서는 84 개 특징에 대하여 정상상태 포함 19 개 클래스 별 특징의 차이와 각 클래스 내 특징의 차이를 이용하여 적용 우선순위를 결정하였다.

Fig. 9 는 우선순위가 높은 특징의 수에 따른 분류성능을 보여주고 있다. 그림을 보면 SVM 에 사용된 특징의 수가 어느 정도 이상이 되면 더 이상 결과에 영향을 미치지 않음을 알 수 있다. 이는 Table 4~ Table 6 를 통해서도 쉽게 확인할 수 있는데 우선순위별 사용된 특징번호도 같이 나타내었다. 시간영역 특징의 경우 20 개 이상의 특징을 이용하여 최대 분류성능을 얻을 수 있는 반면 주파수영역 특징은 12 개의 특징만으로 유사한 분류성능을 얻을 수 있었다. 그러나 Table 6 에 나타낸 바와 같이 시간과 주파수영역 특징을 모두 이용할 경우에는 우선순위가 높은 8 개의 특징만으로도 최대 분류성능(93.3%)을 얻을 수 있었으며, 8 개의 특징은 시간영역 특징 5 개, 주파수영역 특징 3 개였다. 우선순위가 높은 5 개 시간영역 특징은 DWT detail 레벨 3 신호 및 진동신호의 엔트로피 추정값(70, 7), DWT detail 레벨 3 신호의 RMS(65), DWT detail 레벨 1 신호의 엔트로피 추정값(28), DWT detail 레벨 3 신호의 정규 음의 로그-우도 값(75)이었고 주파수영역 특징은 진동신호의 P9, P4, P2(21,16,14)였다. Table 4 와 5 에 나타낸 바와 같이, 8 개의 특징 중 시간영역 특징 5 개만을 이용할 경우 89.8%, 주파수영역 특징 3 개만을 이용할 경우 87.6%의 분류성능을 보여 주었다.

5 개 미만의 특징을 이용할 경우에는 시간영역 특징이 주파수 영역 특징에 대해 우수한 분류성능을 보여 주는 것으로 보이거나 차이는 크지 않았다.

Table 4 Classification results of ball bearing faults and their severities with time domain features

No. of features	Feature ID	Training (%)	Test (%)
1	70	81.1	71.3
2	70,7	97.9	84.2
3	70,7,65	99.5	91.3
4	70,7,65,28	100	89.5
5	70,7,65,28,75,	100	89.8
10	70,7,65,28,75,23,33,2,49,12	100	90.0
15	70,7,65,28,75,23, 33,2,49,12, 1,74,44,54,29	100	92.7
20	70,7,65,28,75,23, 33,2,49,12, 1,74,44,54,29,32,27,11,8,6	100	94.0
30	70,7,65,28,75,23, 33,2,49,12, 1,74,44,54,29,32,27,11,8,6, 53,71,50,25,69,4,31,9,30,10	100	93.1
48	1~12, 22~33, 43~54, 64~75	100	93.6

Table 5 Classification results of ball bearing faults and their severities with frequency domain features

No. of features	Feature ID	Training (%)	Test (%)
1	21	72.6	65.8
2	21,16	97.4	79.5
3	21,16,14	100	87.6
4	21,16,14,42	100	90.7
5	21,16,14,42,20	100	90.7
10	21,16,14,42,20,18,35,19,15,34	100	93.1
12	21,16,14,42,20,18,35,19,15,34, 41,36	100	93.3
15	21,16,14,42,20,18,35,19,15,34, 41,36,63,13,39	100	93.3
20	21,16,14,42,20,18,35,19,15,34, 41,36,63,13,39,17,38,55,62,40	100	93.3
30	21,16,14,42,20,18,35,19,15,34, 41,36,63,13,39,17,38,55,62,40, 84,56,60,61,57,82,59,83,76,37	100	93.3
36	13~21, 34~42, 55~63, 76~84	100	93.3


**Fig. 9** Comparisons of classification accuracies between feature sources as input for SVM

Table 6 Classification results of ball bearing faults and their severities with all features

No. of features	Feature ID	Training (%)	Test (%)
1	21	72.6	65.8
2	21,70	95.8	84.4
3	21,70,7	98.4	86.7
4	21,70,7,65	99.5	87.6
5	21,70,7,65,28	100	86.9
8	21,70,7,65,28,75,16,14	100	93.3
10	21,70,7,65,28,75,16,14,42,23	100	91.8
15	21,70,7,65,28,75,16,14,42,23,33,2,20,49,12,1	100	92.7
20	21,70,7,65,28,75,16,14,42,23,33,2,20,49,12,1,18,35,19,74	100	92.7
30	21,70,7,65,28,75,16,14,42,23,33,2,20,49,12,1,18,35,19,74,44,54,29,15,34,32,41,27,11,36	100	93.6
84	(1~84)	100	93.1

5. 결론

본 연구에서는 SVM 을 이용하여 볼 베어링의 결함유형 및 결함의 정도를 진단하는 방법을 제안하였다. 회전기계 결함 실험장치를 이용하여 정상상태 외 결함의 정도가 다른 18 개의 내·외륜, 볼 및 복합 결함을 모사하여 진동신호를 측정하고, 측정신호와 측정신호의 이산 웨이블릿 변환신호로부터 시간영역 특징 12 개, 주파수영역 특징 9 개를 추출하였다. SVM 을 이용한 진단결과, 시간영역 및 주파수 영역 특징만을 이용하는 경우 각각 20 개, 12 개 특징을 이용하여 94%, 93.3%의 베어링 결함유형 및 결함의 정도를 진단할 수 있었으나 두 가지 영역 모두의 특징을 이용하면 8 개의 특징만으로 93.3%의 진단결과를 얻을 수 있었다.

향후, 시간영역 특징은 진동신호와 이산 웨이블릿 변환신호를 이용하고 주파수영역 특징은 진동신호를 이용하면 최적의 분류성능을 얻을 수 있을 것으로 판단된다. 그러나 결함유형 및 결함의 정도에 대하여 구분이 좀더 용이한 특징을 추가로 개발하는 것도 필요한 것으로 보인다.

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) 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.
- (4) 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.
- (5) 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.
- (6) Kankar, P.K., Sharma, Satish C. and Harsha, S.P., 2011, "Fault Diagnosis of Ball Bearings Using Continuous Wavelet Transform," *Applied Soft Computing*, Vol. 11, pp.2300~2312.
- (7) Vapnik, V.N., 1999, An Overview of Statistical Learning Theory, *IEEE Transactions on Neural Networks*, Vol.10, No.5, pp.988~999.
- (8) Burges, C.J.C., 1998, A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, Vol.2, p.121~167.
- (9) Cristianini, N. and Shawe-Taylor, J., 2000, An Introduction to Support Vector Machines and other Kernel-Based Learning Methods, Cambridge University Press, Cambridge.
- (10) 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.
- (11) Platt, J.C., 1998, *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*, Technical Report MSR-TR-98-14.
- (12) Fukunaga, K., 1990, Introduction to Statistical Pattern Recognition, Academic Press.
- (13) Kim, Y.S., Lee, D.H. and Park, S.K., 2012, "Fault Size Classification of Rotating Machinery Using Support Vector Machine," *The 18th Pacific Basian Nuclear Conference (PBNC 2012)*, Busan, Korea, March 18~22, 2012.