유도 전동기의 고장 검출 및 분류를 위한 특징 벡터 추출과 분류기의 다양한 설정에 따른 분류 성능 비교

Feature Vector Extraction and Classification Performance Comparison According to Various Settings of Classifiers for Fault Detection and Classification of Induction Motor

강 명 수, 뉘엔 투 낙, 김 용 민, 김 철 홍*, 김 종 먼
(Myeongsu Kang, Thu-Ngoc Nguyen, Yongmin Kim, Cheolhong Kim*, Jong-Myon Kim)

울산대학교 전기공학부, *전남대학교 전자컴퓨터공학부
(접수일자: 2011년 7월 8일; 수정일자: 2011년 9월 14일; 채택일자: 2011년 9월 22일)

최근 항공 산업, 자동차 산업 등의 산업 현장에서 유도 전동기의 사용이 증대되고 있으며, 유도 전동기는 산업 현장에서 중요한 역할을 하고 있다. 따라서 유도 전동기의 고장으로 인한 피해를 최소화하기 위해 유도 전동기의 고장 검출 및 분류 시스템의 개발이 중요한 문제로 대두되고 있다. 이와 같은 이유로 본 논문에서는 유도 전동기의 고장을 조기에 검출하고 진단하기 위해 에너지 (short-time energy)와 특이치 분해와 이산 코사인 변환과 특이치 분해를 이용한 특징 벡터 추출 방법을 제안하였고, 이를 역 전파 신경 회로망과 다층 서포트 벡터 머신의 입력으로 이용하여 유도 전동기의 고장을 유형별로 분류하였다. 하지만 본 논문에서는 역 전파 신경 회로망과 다층 서포트 벡터 머신을 분류기로 사용함에 있어 역 전파 신경 회로망은 신경망을 구성하는 입력 뉴런 수, 은닉 뉴런 수, 학습 알고리즘에 의해 분류 성능이 달라지며, 다층 서포트 벡터 머신은 커널 함수로 사용한 가우시안 방사 기저 함수의 표준 편차 값에 따라 분류 성능이 달라지는 점을 고려하여 여러 가지 조건하에서의 실험을 통해 높은 분류 성능을 보이는 설정 방법을 제시하였다.

핵심용어: 유도 전동기, 특징 벡터 추출, 역 전파 신경 회로망, 다층 서포트 벡터 머신

투고분야: 음향 신호처리 분야 (1.7)

The use of induction motors has been recently increasing with automation in aeronautical and automotive industries, and it plays a significant role. This has motivated that many researchers have studied on developing fault detection and classification systems of an induction motor in order to minimize economical damage caused by its fault. With this reason, this paper proposed feature vector extraction methods based on STE (short-time energy)+SVD (singular value decomposition) and DCT (discrete cosine transform)+SVD techniques to early detect and diagnose faults of induction motors, and classified faults of an induction motor into different types of them by using extracted features as inputs of BPNN (back propagation neural network) and multi-layer SVM (support vector machine). When BPNN and multi-layer SVM are used as classifiers for fault classification, there are many settings that affect classification performance: the number of input layers, the number of hidden layers and learning algorithms for BPNN, and standard deviation values of Gaussian radial basis function for multi-layer SVM. Therefore, this paper quantitatively simulated to find appropriate settings for those classifiers yielding higher classification performance than others.

Keywords: Induction motor, Feature vector extraction, Back propagation neural network, Multi-layer support vector machine

ASK subject classification: Acoustic Signal Processing (1.7)

I. 서 론

책임저자: 김 종 먼 (jmkim07@ulsan.ac.kr)
680-749 울산광역시 남구 무거동 대학로 93
울산대학교 전기공학부 7-308호
(전화: 052-259-2217)

산업 현장이 자동화됨에 따라 전동기의 활용 범위가 확대되어 왔다. 로봇 시스템 등의 특별한 용도의 전동기

와는 달리 일반적인 성능이 요구되는 산업 현장의 설비에서 간단한 구조와 기계적 견고함을 갖춘 유도 전동기는 전체 계통에 대한 동력을 공급한다 [1]. 이러한 유도 전동기의 고장으로 인한 설비의 중단은 계통 전체의 치명적인 고장과 함께 경제적 손실을 발생시킬 수 있다. 따라서 최근에는 운전에 영향을 미치지 않으면서 유도 전동기의 문제점을 조기에 검출하고 진단하는 연구가 활발히 진행되고 있다 [2].

유도 전동기와 같은 회전 기계의 운전 상태를 점검하는 지표로는 진동 신호가 가장 많이 이용되는데, 진동 신호에는 회전 기계의 고장 유형별 고유의 특징을 포함하고 있기 때문이다 [3]. 하지만 취득한 진동 신호에는 고장 유형별 특징과 관계없는 데이터들이 많이 포함되어 있어 취득한 진동 신호를 모두 고장 분류를 위한 분류기(classifier)의 입력으로 사용할 경우 분류에 많은 시간을 소요할 뿐만 아니라 고장 유형별 특징을 구분하는데 방해가 된다. 그러므로 취득한 진동 신호를 시간 영역 분석, 주파수 영역 분석, 시간-주파수 영역 분석을 통해 고장 유형을 뚜렷하게 구분시켜 줄 특징 벡터 추출 방법에 관한 연구가 활발히 진행되고 있다 [3]. 이러한 이유로 본 논문에서는 효과적인 고장 분류를 위해 취득한 유도 전동기 진동 신호를 시간 영역 분석과 주파수 영역 분석을 통한 특징 벡터 추출 방법을 제안한다. 시간 영역에서의 특징 벡터 추출을 위해서는 신호의 에너지(short-time energy, STE)와 특이치 분해(singular value decomposition, SVD) 기법을 이용하였으며, 주파수 영역에서의 특징 벡터 추출을 위해서는 이산 코사인 변환(discrete cosine transform, DCT)과 특이치 분해 기법을 이용하였다. 이와 더불어 본 논문에서는 유도 전동기의 고장 검출 및 분류를 위해 추출된 특징 벡터를 역 전파 신경 회로망(back propagation neural network, BPNN), 다층 서포트 벡터 머신(support vector machine, SVM)의 입력으로 사용하였다. 일반적으로 역 전파 신경 회로망을 분류기로 사용함에 있어서는 신경 회로망을 구성하는 입력 뉴런 수, 은닉 뉴런 수, 학습 알고리즘 등에 의해 분류 성능이 달라지며, 다층 서포트 벡터 머신을 분류기로 사용함에 있어서는 커널 함수가 분류 성능에 많은 영향을 미친다. 따라서 본 논문에서는 많은 실험을 통해 유도 전동기 고장 검출 및 분류에 있어 최적의 성능을 보이는 설정 방법을 제시한다.

본 논문의 구성은 다음과 같다. 2장에서는 기존 연구와의 차별성을, 3장에서는 고장 유형별 유도 전동기 진동 신호의 종류와 그 특징에 대해 설명하고, 4장에서는 유도

전동기 고장 검출 및 분류를 위한 특징 벡터 추출 방법에 대해 소개한다. 5장에서는 추출된 특징 벡터를 역 전파 신경 회로망과 다층 서포트 벡터 머신의 입력으로 사용하여 다양한 설정에 따른 분류 성능에 대한 결과를 보이며, 마지막으로 6장에서는 본 논문의 결론을 맺는다.

II. 기존 연구와의 차별성

일반적으로 유도 전동기의 고장 검출 및 분류를 위해 이용하는 신호로는 계측이 쉬운 전동기의 전류 신호 [4-6]와 전동기 진동 신호 [7-8] 등이 있다. 진동 신호의 경우는 취득한 신호가 비결정적(non-deterministic)이고 비정상 상태(non-stationary)의 특징을 가지지만 전동기의 동작 상태를 잘 반영하고 있다는 점을 고려하여 본 논문에서는 유도 전동기의 진동 신호를 고장 검출 및 분류를 위해 사용한다. 하지만 유형별 고장 유형을 분류함에 있어서 취득한 진동 신호 전체를 분류기의 입력으로 사용하는 것은 매우 비효율적이므로, 적은 수의 데이터로 각 고장의 특징을 잘 나타낼 수 있는 특징 추출이 요구된다. 이와 같은 특징 추출은 시간 영역 분석, 주파수 영역 분석, 시간-주파수 영역 분석을 통해 이루어진다. 먼저 시간 영역 분석을 이용한 대표적인 특징 추출 방법의 경우는 취득한 신호의 평균(mean), 분산(variance), 실효값(root-mean-square), 첨예도값(kurtosis)과 같은 통계적 방법을 이용하며, 주파수 영역 분석을 이용한 방법에는 푸리에 변환 기반의 특징 추출 방법이 주로 사용된다 [3, 7-9]. 또한 시간-주파수 영역 분석을 이용한 방법에는 STFT(short-time Fourier transform)와 웨이블릿 변환(wavelet transform)을 이용한 통계적 방법과 MFCC(mel-frequency cepstral coefficient)를 이용한 방법 등이 있다 [3, 9-12]. 하지만 이산 웨이블릿의 대역별 첨예도, 평균, 분산 등의 통계치 값을 특징으로 할 경우 [3], 베어링의 진동 신호의 특징을 잘 나타내었던 것과는 달리 유도 전동기에 대해서는 그림 1(a)-(b)와 같이 고장 유형 분류를 위한 일정한 패턴을 보이지 않았으며, 그림 1(c)와 같이 특정한 패턴을 보이더라도 그 차이가 너무 작아 유도 전동기의 고장 유형 분류에는 적합하지 않는 결과를 보였다. 따라서 본 논문에서는 유도 전동기의 유형 분류에 적합한 특징을 추출하기 위해 일정한 패턴 형성에 기여할 수 있는 특이치 분해(SVD) 기반 특징 추출 방법을 제안한다. 또한 유도 전동기 결함에 대한 자세한 지식의 요구 없이도 결함에 대한 형태를 분류하기 위해 신경 회로망(neural network)과 서포트 벡터 머신

그림 1. 3단계 웨이블릿 패킷 (wavelet packet, WPK)과 통계적 방법 (첨예도, 평균, 분산)을 이용한 유도 전동기 특징 추출 결과. (a) 3단계 웨이블릿 패킷과 4차 첨예도 (kurtosis)를 이용한 특징 추출 결과, (b) 3단계 웨이블릿 패킷과 평균 (mean)을 이용한 특징 추출 결과, (c) 3단계 웨이블릿 패킷과 분산을 이용한 특징 추출 결과

Fig. 1. Feature extraction results using 3-level wavelet packet + statistical methods. (a) feature extraction result using a 3-level wavelet packet + 4th order kurtosis method, (b) feature extraction result using a 3-level wavelet packet + mean method, (c) feature extraction result a 3-level wavelet packet + variance method.

(support vector machine)을 분류기로 주로 사용하는데 [13-15], 기존의 연구에서는 어떠한 특징 조건에서 고장 유형 분류의 성능만을 살펴보았다. 이와 달리 본 논문에서는 신경 회로망과 서포트 벡터 머신을 분류기로 사용함에 있어 분류기의 설정 방법에 따른 유도 전동기의 고장 유형별 분류 성능을 분석한다.

III. 유도 전동기 진동 신호

본 논문에서는 유도 전동기의 고장 검출 및 분류를 위해 진동 신호를 사용하였으며, 이는 부경대학교 지능기계연구실에서 제공한 것으로 정상 상태를 포함 네 가지의 비정상 상태의 고장에 대한 신호이다 [16]. 데이터 취득은 베어링 하우징에 축 방향, 수평 방향 및 수직 방향으로

가속도 센서를 부착하여 진동 가속도 신호를 취득하였으며, 본 논문에서 사용한 네 가지 비정상 상태의 진동 신호는 다음과 같다.

- 각 정렬 불량 (angular misalignment, AM) : 축 지지대를 조절하여 각 정렬 불량 상태를 가지게 함으로써 취득한 진동 신호
- 회전자 봉 균열 (broken rotor bar, BR) : 34개의 회전자 봉 가운데 12개의 봉을 파손하여 취득한 진동 신호
- 회전자 불균형 (rotor unbalance, RU) : 회전자에 8.4 g의 불균형 질량을 회전자에 부착하여 취득한 진동 신호
- 베어링 결함 (fault bearing, FB) : 외륜에 고장을 발생시켜 취득한 진동 신호

그림 2. 고장 유형별 1초 길이의 진동 신호

(a) 시간 영역에서의 고장 유형별 진동 신호, (b) 주파수 영역에서의 고장 유형별 진동 신호

Fig. 2. One-second long vibration signals for various faults of an induction motor.

(a) vibration signals of various faults in time domain, (b) vibration signals of various faults in frequency domain

취득한 진동 신호의 샘플링율은 8 kHz이며, 고장 유형별 분류를 위해 분류기의 학습과 테스트 데이터를 만들기 위해 취득한 신호를 1초 길이로 나누어 각 고장 유형별 105개의 신호를 추출하여 사용하였다. 그림 2는 정상 상태 및 비정상 상태의 고장 유형별 진동 신호의 파형(그림 2 (a))과 스펙트럼(그림 2 (b))을 보이며, 진동 신호의 스펙트럼은 고장 유형별 특징을 잘 나타낸다.

IV. 특징 벡터 추출

그림 2에서와 같이 취득한 진동 신호는 고장 유형별 고유의 특징을 보이고 있지만, 고장 검출 및 분류를 위해 신호를 모두 사용하는 것은 비효율적이다. 따라서 본 논문에서는 시간 영역 분석 및 주파수 영역 분석과 특이치 분해 방법을 이용하여 고장 유형별 특징을 잘 표현할 수 있는 특징 벡터를 추출하고, 이를 분류기의 입력으로 사용한다.

4.1. 특이치 분해 (Singular Value Decomposition, SVD)

특이치 분해는 크기가 크고, 다루기 힘든 행렬을 보다 작은 가역 정사각행렬로 근사하게 분해하는데 유용하게 사용되는 행렬 분해 방법으로 모든 $n \times n$ 행렬 A 는 특이치 분해를 이용하여 식 (1)과 같이 분해할 수 있다.

$$A = U \cdot S \cdot V^T \quad (1)$$

즉, 크기가 $n \times n$ 인 행렬 A 를 특이치 분해하면 직교행렬 (U, V^T)과 대각행렬 (S)로 분해할 수 있는데, 직교행렬 (orthogonal matrix) U 는 AA^T 의 고유벡터 (eigenvector) 이고, 직교행렬 V^T 는 $A^T A$ 의 고유벡터이다. 대각행렬 (diagonal matrix) S 는 정방행렬이면서 행렬 A 가 아닌 $A^T A$ 로부터 계산된 고유치 (eigenvalue)들로 구성되며, 이때 식 (2)에서와 같이 $\sigma_1, \sigma_2, \dots, \sigma_n$ 을 행렬 A 의 특이치 (singular value)라고 한다 [17].

$$\begin{aligned}
 A &= U \cdot S \cdot V^T \\
 &= [u_1, u_2, \dots, u_n] \times \begin{bmatrix} \sigma_1 & & \\ & \sigma_2 & \\ & & \ddots \\ & & & \sigma_n \end{bmatrix} \times [v_1, v_2, \dots, v_n] \\
 &= \sum_{i=1}^n u_i \sigma_i v_i^T
 \end{aligned} \quad (2)$$

분해된 특이치들은 $[\sigma_1 > \sigma_2 > \dots > \sigma_n]$ 의 순서로 나열되는데, 이러한 특이치는 유도 전동기의 진동 신호 취득 시 취득 센서의 종류에 따라 다른 양의 센서 잡음이 추가되더라도 특이치는 그 값의 변화가 크지 않으므로 유도 전동기의 고장 유형 분류를 위한 특징 벡터 추출에 유용하게 사용될 수 있다.

4.2. 시간 영역 분석과 특이치 분해를 이용한 특징 벡터 추출

본 논문에서는 유도 전동기의 고장 검출 및 분류를 위해 에너지 (short-time energy, STE)와 특이치 분해 (singular value decomposition, SVD) 방법을 이용한 특징 벡터 추출 방법을 제안한다. STE는 다양한 응용 분야에서 분류를 위해 사용되는 간단한 특징으로 Zhang과 Li 등은 이를 음악과 음성 분류 등의 오디오 장르를 분류하기 위해 사용하였으며 [18-19], 식 (3)과 같다.

$$STE = \sum_{m=0}^{M-1} x^2(m) \quad (3)$$

여기서 M 은 처리중인 윈도우 (window) 내에서 오디오 샘플의 총 수이며, $x(m)$ 은 m 번째 샘플 값이다. 그림 3은 본 논문에서 취득한 고장 유형별 105개의 고장 신호 가운데 고장 유형별 20개의 고장 신호를 임의 추출한 후

STE 값의 패턴을 나타낸다.

그림 3에서 확인할 수 있듯이 STE 값은 대체로 고장 유형 분류를 위한 좋은 특징이 될 수 있다. 하지만 정상 신호와 회전자 봉 균열 고장 신호, 회전자 봉 균열 고장 신호와 각 정렬 불량 고장 신호의 경우는 STE 값이 중첩되는 경우가 발생하게 되는데, 이는 유도 전동기의 고장 분류 성능을 저하시키는 요인이 될 수 있다. 따라서 본 절에서는 STE와 특이치 분해를 이용한 특징 추출 방법을 제안하며, 그림 4는 이를 이용한 특징 추출 과정과 그 결과를 나타낸다.

그림 4 (a)는 STE+SVD를 이용한 특징 추출 과정을 나타내는데, 먼저 단계 1에서는 1초 길이의 입력 신호를 $N_{feature} \times N_{feature}$ 개의 서브 밴드로 나누어 각 밴드에서 STE 값을 계산하고, 단계 2에서는 STE 값을 이용하여 크기가 $N_{feature} \times N_{feature}$ 인 행렬을 구성한다. 여기서 $N_{feature}$ 는 특징 수를 나타낸다. 마지막으로 본 논문에서는 STE 값으로 구성된 행렬을 특이치 분해 한 후 특이치를 유도 전동기의 고장 검출 및 분류를 위한 특징 벡터로 사용한다. 그림 4 (b)는 그림 3의 경우와 마찬가지로 고장 유형별 105개의 고장 신호 가운데 임의로 20개의 고장 신호를 추출한 후 특징 수를 10으로 하였을 때의 각 고장 신호에 대한 특징을 나타낸다. 이는 그림 3에서 STE 값만을 이용한 특징 보다는 더 규칙적인 패턴을 갖게 되어 고장 분류 성능을 향상시키는데 효과적이다. 하지만 그림 4 (b)에서 볼 수 있듯이 특이치 분해 결과 식 (2)에서와 같이 특이치 값들이 작아지는 특성으로 인해 추출된 특징들이 중첩되는 현상이 나타나며 이는 고장 분류 성능을 저하시키는 원인이 될 수 있다. 따라서 본 논문에서는 $N_{feature}$ 개의 특징을 추출한 뒤 마지막 3개의 특징을 제외한 나머지를 특징 벡터로 사용한다.

그림 3. 고장 유형별 20개의 고장 신호에 대한 STE 값의 패턴

Fig. 3. Patterns of STE values for 20 vibration signals of each fault.

그림 4. STE+SVD를 이용한 특징 추출 과정 및 그 결과

Fig. 4. Process to extract feature vector using the STE+SVD technique and extracted features.

그림 5. DCT+SVD를 이용한 특징 벡터 추출

Fig. 5. Feature vector extraction using the DCT+SVD technique.

4.3. 주파수 영역 분석과 특이치 분해를 이용한 특징 벡터 추출

그림 2 (b)에서와 같이 취득한 고장 신호의 스펙트럼은 고장 유형별 특징을 잘 나타낸다. 따라서 본 논문에서는 시간 영역 분석 방법인 에너지 (STE)와 특이치 분해 방법을 이용한 특징 추출 방법과 더불어 주파수 영역 분석 방법인 이산 코사인 변환 (discrete cosine transform, DCT)과 특이치 분해 방법을 이용한 특징 추출 방법도 함께 제안한다. DCT 계수는 식 (4)와 같으며, $X(m)$ 은 입력 신호, M 은 입력 신호의 길이, $Y_x(k)$ 는 k 번째 DCT 계수이다 [20].

$$Y_x(0) = \frac{\sqrt{2}}{M} \sum_{m=0}^{M-1} X(m),$$

$$Y_x(k) = \frac{\sqrt{2}}{M} \sum_{m=0}^{M-1} X(m) \cos \frac{(2m+1)k\pi}{2M}, k=1, 2, \dots, (M-1). \quad (4)$$

본 논문에서는 고장 유형별 특징 추출을 위해 DC 계수와 특이치 분해 방법을 이용하였다. 특징 추출 과정은 그림 4 (a)와 거의 유사한데, DCT+SVD를 이용한 특징 추출 방법에서는 그림 4 (a)의 단계 1과 2에서 STE 값을 이용하는 대신 각 밴드의 DC 계수를 이용하여 특이치 분해를 위한 행렬을 구성하였다. 그림 5는 DCT+SVD를 이용하여 특징을 추출한 결과를 보이며, 유도 전동기의 고장 검출 및 분류를 위한 좋은 특징 벡터가 될 수 있음을 확인할 수 있다.

4.4. 제안한 특징 추출 기법의 잡음 환경에의 강인성

본 논문에서는 유도 전동기의 고장 유형 분류를 위해 진동 신호를 사용하였는데, 일반적으로 진동 신호 취득 시 센서 잡음 (sensor noise)이 추가 될 수 있으며, 이와

그림 6. 잡음이 추가된 이후의 STE+SVD 기법을 이용한 특징 추출 결과

(a) 잡음이 추가 되지 않았을 때 STE+SVD를 이용한 특징 추출 결과, (b) SNR=15 dB일 때 STE+SVD를 이용한 특징 추출 결과, (c) SNR=10 dB일 때 STE+SVD를 이용한 특징 추출 결과, (d) SNR=5 dB일 때 STE+SVD를 이용한 특징 추출 결과

Fig. 6. Feature extraction results using the STE+SVD technique after white Gaussian noise addition.

(a) feature extraction result using the STE+SVD technique when no noise addition, (b) feature extraction result using the STE+SVD technique when SNR=15 dB, (c) feature extraction result using the STE+SVD technique when SNR=10 dB, (d) feature extraction result using the STE+SVD technique when SNR=5 dB

그림 7. 잡음이 추가된 이후의 DCT+SVD 기법을 이용한 특징 추출 결과

(a) 잡음이 추가 되지 않았을 때 DCT+SVD 이용한 특징 추출 결과, (b) SNR=15 dB일 때 STE+SVD를 이용한 특징 추출 결과, (c) SNR=10 dB일 때 DCT+SVD 이용한 특징 추출 결과, (d) SNR=5 dB일 때 DCT+SVD 이용한 특징 추출 결과

Fig. 7. Feature extraction results using the DCT+SVD technique after white Gaussian noise addition.

(a) feature extraction result using the DCT+SVD technique when no noise addition, (b) feature extraction result using the DCT+SVD technique when SNR=15 dB, (c) feature extraction result using the DCT+SVD technique when SNR=10 dB, (d) feature extraction result using the DCT+SVD technique when SNR=5 dB

같은 센서 잡음은 백색 가우시안 잡음 (white Gaussian noise)으로 간주된다. 그림 6과 7은 유도 전동기의 진동 신호 및 진동 신호와 백색 가우시안 잡음을 추가한 신호의 신호 대 잡음비 (signal-to-noise ratio, SNR)가 15 dB, 10 dB, 5 dB가 되도록 한 후 본 논문에서 제안한 특징 추출 방법인 STE+SVD, DCT+SVD 기법을 각각 이용하여 추출한 특징을 보여준다. 그림 6과 7에서 확인할 수 있듯이 제안한 특징 추출 방법을 이용할 경우 잡음에 크게 영향을 받지 않았다.

V. 분류기의 설정에 따른 고장 분류 성능 결과

본 논문에서는 STE+SVD와 DCT+SVD를 이용한 특징 벡터를 역 전파 신경 회로망과 다층 서포트 벡터 머신의 입력으로 사용하여 유도 전동기의 고장을 유형별로 분류한다. 하지만 역 전파 신경 회로망과 다층 서포트 벡터 머신을 고장 분류를 위한 분류기로 사용하기 위해서는 학습 함수 (training function) 설정, 뉴런 (neuron) 수 설정, 커널 함수 (kernel function) 설정 등 많은 설정이 요구되며, 이러한 설정에 따라 분류 성능에 많은 영향을 미친다. 이에 본 논문에서는 유도 전동기의 고장 유형 분류를 위해 역 전파 신경 회로망과 다층 서포트 벡터 머신 사용 시 다양한 설정에 따른 분류 성능을 비교함으로써

고장 분류에 효율적인 설정 방법을 제시한다.

5.1. 역 전파 신경 회로망

역 전파 신경 회로망 (back propagation neural network, BPNN)의 사용은 유도 전동기의 결함에 대한 자세한 지식의 요구 없이 결함에 대한 형태를 분류 할 수 있도록 한다. 그림 8은 역 전파 신경 회로망을 이용한 유도 전동기의 고장 분류를 위한 블록도로 본 논문에서 사용한 신경 회로망은 n ($n = 5, 6, \dots, 10$)개의 입력 뉴런 (input neuron), 1개의 은닉 층 (hidden layer), m ($m = 6, 7, \dots, 15$)개의 은닉 뉴런, 5개의 출력 뉴런 (output neuron)으로 구성되며 각각의 뉴런은 완전 연결되어 있다. 이때 은닉 층의 뉴런은 학습을 통해 점진적으로 발전되는 특징을 찾아내는데 중요한 역할을 하지만 이는 해결하고자 하는 문제에 따라 최적의 뉴런 개수가 달라지기 때문에 사용 분야에 알맞은 적절한 은닉 뉴런 개수를 정해야 한다 [21]. 따라서 본 논문에서는 은닉 뉴런의 개수를 6에서 15로 바꾸어 실험하면서 그에 따른 성능을 살펴보았다. 또한, 역 전파 신경 회로망의 입력으로 사용되는 입력 뉴런 수 (또는 추출한 특징 수)에 따라서도 분류 성능은 달라지므로 유도 전동기 고장 분류에 적합한 입력 뉴런 수를 찾고자 입력 뉴런 수를 5에서 10으로 바꾸어 가며 그에 따른 성능도 함께 살펴보았다.

역 전파 신경 회로망을 이용한 고장 분류 절차는 피드 포

그림 8. 역 전파 신경 회로망을 이용한 유도 전동기의 고장 분류 메커니즘

Fig. 8. Fault classification mechanism of an induction motor using the back propagation neural network.

그림 9. STE+SVD를 이용한 특징 수와 온닉 뉴런 수에 따른 분류 성능 결과
 (a) 레벤버그-마쿼트 (Levenberg-Marquardt) 학습 알고리즘 적용, (b) 켈레 경사 (scaled conjugate gradient) 학습 알고리즘 적용, (c) 베이시안 (Bayesian) 학습 알고리즘 적용
 Fig. 9. Comparison of classification performance according to both different numbers of features extracted from the STE+SVD technique and various numbers of hidden layers.
 (a) training algorithm: Levenberg-Marquardt, (b) training algorithm: scaled conjugate gradient, and (c) training algorithm: Bayesian

그림 10. DCT+SVD를 이용한 특징 수와 은닉 뉴런 수에 따른 분류 성능 결과
 (a) 레벤버그-마퀴트 (Levenberg-Marquardt) 학습 알고리즘 적용, (b) 쥬레 경사 (scaled conjugated gradient) 학습 알고리즘 적용, (c) 베이시안 (Bayesian) 학습 알고리즘 적용
 Fig. 10. Comparison of classification performance according to both different numbers of features extracted from the DCT+SVD technique and various numbers of hidden layers.
 (a) training algorithm: Levenberg-Marquardt, (b) training algorithm: scaled conjugated gradient, and (c) training algorithm: Bayesian

워드 (feed-forward) 과정과 역 전파 (back propagation) 과정을 통해 연결 강도 (connection weight)를 조절하고, 계산된 결과 값과 목표 값과의 오차를 최소화하는 과정을 통해 이루어진다 [22]. 역 전파 신경 회로망은 교사 학습 (supervised learning)의 한 종류로 학습을 위한 다양한 알고리즘이 있으며, 학습 알고리즘에 따라 분류 성능은 달라진다. 본 논문에서는 역 전파 신경 회로망의 학습을 위해 경사 기반 학습 알고리즘의 하나로 수렴 속도가 빠르고 좋은 성능을 보이는 학습 기법인 레벤버그-마퀴트 (Levenberg-Marquardt) 알고리즘 [23], 경사 기반 학습 알고리즘의 하나로 일반적으로 성능이 뛰어나다고 알려진 켈레 경사 (scaled conjugate gradient) 알고리즘 [24], 많은 학습 기법들 가운데 성능 및 계산량 측면에서 평균 이상의 성능을 보이는 베이시안 (Bayesian) 알고리즘 [13]을 각각 이용하여, 그에 따른 성능을 살펴보았다. 학습 정도는 표준 오차 평균 (mean squared error)의 학습 임계 값을 $1.00e-5$ 로 정하여 신경망 회로를 학습하였고, 또한 2000번 이상의 학습에도 불구하고 수렴하지 못하면 자동으로 학습을 종료하도록 하였다. 신경 회로망의 학습과 테스트를 위한 데이터는 추출한 특징 벡터의 80 % (각 고장 유형별 84개의 특징 벡터)를 학습을 위한 데이터로, 20 % (각 고장 유형별 21개의 특징 벡터)를 테스트를 위한 데이터로 사용하였다. 또한, Kearns의 권장 사항으로 학습 데이터의 20 % (고장 유형별 21개의 특징 벡터)를 검증에 위한 데이터로 사용하였다 [21]. 그림 9와 10은 STE+SVD와 DCT+SVD를 이용하여 추출한 고장 유형별 특징을 역 전파 신경 회로망의 입력으로 하여 세 가지 학습 알고리즘에 대해 입력 뉴런 수 (특징 수)와 은닉 뉴런의 수를 달리하면서 분류 성능을 나타낸 것이다.

먼저 그림 9에서와 같이 역 전파 신경 회로망의 학습을 위해 레벤버그-마퀴트 알고리즘을 이용한 경우는 입력 뉴런 수 (특징 수 혹은 $(N_{feature}-3)$)가 7일 때, 켈레 경사 알고리즘을 이용한 경우는 입력 뉴런 수가 8과 10일 때, 베이시안 알고리즘을 이용한 경우는 입력 뉴런 수가 7일 때 은닉 뉴런의 개수에 크게 영향을 받지 않으며 좋은 분류 성능을 보였다. 특히, 입력 뉴런 수가 8이고, 켈레 경사 알고리즘을 이용하였을 경우에 있어 전체적인 고장 분류 성능이 95 % 이상으로 가장 좋은 분류 성능을 보였다. 그림 10은 DCT+SVD를 통해 특징을 추출하여 역 전파 신경 회로망의 입력으로 사용한 경우 학습 알고리즘과 입력 뉴런 수 및 은닉 뉴런의 수에 따른 분류 성능으로 레벤버그-마퀴트 알고리즘과 베이시안 알고리즘을 이용하여 학습하고 입력 뉴런 수가 8과 10일 때 100 %의 고장

분류 성능을 보였다.

5.2. 다층 서포트 벡터 머신

서포트 벡터 머신 (Support Vector Machine, SVM)은 최근 패턴 인식을 포함한 다양한 분야에서 분류, 추정 등의 문제를 다루는데 널리 활용되고 있다. 서포트 벡터 머신은 클래스 간의 최소 거리를 최대화하는 초평면 (hyperplane)을 찾아냄으로써 클래스를 분류하는 방법이다. 즉, m 차원의 특징 벡터 x_i 와 클래스 $y_i \in \{-1, 1\}$ 를 갖는 학습 데이터 집합을 $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$ 라고 하면 그림 11과 같이 두 클래스 간 마진 (margin)을 최대화하는 초평면 $w^T x + b$ 을 찾을 수 있으며, 임의의 특징 벡터 x_i 는 초평면 $w^T x + b$ 에 대해 식 (5)를 만족한다. 이 때 마진의 경계 상에 위치한 특징 벡터를 서포트 벡터 (support vector)라고 한다.

$$y_i = \begin{cases} 1 & w^T x_i + b \geq 0, \quad i = 1, 2, \dots, n \\ -1 & w^T x_i + b < 0, \quad i = 1, 2, \dots, n. \end{cases} \quad (5)$$

하지만 그림 11에서와는 달리 대부분의 클래스를 분류하는 문제에서는 선형적으로 분리되지 않을 경우가 많은데, 이러한 경우 서포트 벡터 머신은 원 데이터를 보다 고차원의 공간으로 사상시키고 사상된 공간에서 최적의 초평면을 찾게 된다. 이를 위해 커널 함수 (kernel function)를 이용하며, 서포트 벡터 머신에서 사용되는 대표적인 커널 함수는 다항 함수 (polynomial function), 가우시안 방사 기저 함수 (Gaussian radial basis function), 지수 방사 기저 함수 (exponential radial basis function) 등이 있다.

본 논문에서는 유도 전동기의 고장 유형 분류를 위해

그림 11. 서포트 벡터 머신을 이용한 클래스 분류
Fig. 11. Classification of classes by SVM.

그림 12. 다층 서포트 벡터 머신을 유도 전동기의 고장 유형 분류

Fig. 12. Fault classification of an induction motor by the multi-layer support vector machine.

그림 13. STE+SVD로부터 추출한 특징과 표준 편차 값에 따른 다층 서포트 벡터 머신을 이용한 유도 전동기 고장 분류 성능
(a) 각 정렬 불량 고장, (b) 회전자 봉 균열 고장, (c) 정상, (d) 회전자 불균형 고장, (e) 베어링 결함

Fig. 13. Classification performance according to both various numbers of features extracted from the STE+SVD technique and different numbers of sigma value for the multi-layer support vector machine.

(a) angular misalignment, (b) broken rotor bar, (c) normal, (d) rotor unbalance, and (e) fault bearing

그림 12와 같이 다층 서포트 벡터 머신을 이용하였으며, 커널 함수로는 일반적으로 좋은 분류 성능을 보이는 가우시안 방사 기저 함수를 이용하였다 [25].

SVM1은 각 정렬 불량 고장 신호와 그 이외의 신호를, SVM2는 회전자 봉 균열 고장 신호와 그 이외의 신호를, SVM3는 정상 신호와 그 이외의 신호를, SVM4는 회전자

그림 14. DCT+SVD로부터 추출한 특징과 표준 편차 값에 따른 다층 서포트 벡터 머신을 이용한 유도 전동기 고장 분류 성능
(a) 각 정렬 불량 고장, (b) 회전자 봉 균열 고장, (c) 정상, (d) 회전자 불균형 고장, (e) 베어링 결함

Fig. 14. Classification performance according to both various numbers of features extracted from the DCT+SVD technique and different numbers of sigma value for the multi-layer support vector machine.

(a) angular misalignment, (b) broken rotor bar, (c) normal, (d) rotor unbalance, and (e) fault bearing

불균형 신호와 그 이외의 신호를 SVM5는 베어링 결함 고장 신호를 분류하는데 이용된다. 서포트 벡터 머신의 커널 함수로 가우시안 방사 기저 함수를 사용하기 위해서는 표준 편차 (σ) 값을 설정해야하며, 이는 분류 성능에 많은 영향을 미친다. 따라서 본 논문에서는 각 고장 유형별 특징 수와 표준 편차 값에 따른 성능을 비교함으로써 유도 전동기의 고장 유형 분류에 적합한 표준 편차 값을 살펴보았으며 그림 13과 14는 STE+SVD와 DCT+SVD로부터 추출한 특징을 다층 서포트 벡터 머신의 입력으로 사용하였을 때의 고장 분류 성능 결과를 보인다.

가우시안 방사 기저 함수를 커널 함수로 사용함에 있어 높은 분류 성능을 제공하기 위해 적합한 표준 편차 값을 찾기 위해 본 논문에서는 표준 편차 값을 0.1에서 0.46까지 0.02의 크기 단위로 바꾸어 가며 실험한 결과 먼저 그림 13에서 볼 수 있듯이 STE+SVD로부터 추출한 특징을 다층 서포트 벡터 머신의 입력으로 사용한 경우 각 정렬 불량 고장 신호를 분류하기 위해서는 표준 편차 값이 0.4에서 0.46사이 일 때, 회전자 봉 균열 고장 신호

분류를 위해서는 0.24에서 0.32사이 일 때, 정상 신호를 분류하기 위해서는 0.16에서 0.34사이 일 때 특징의 수에 크게 영향을 받지 않고 좋은 성능을 보였으며 회전자 불균형과 베어링 결함의 경우는 모든 경우에 있어 100 %의 분류 성능을 보였다. 다음으로 그림 14에서와 같이 DCT+SVD로부터 추출한 특징을 이용한 경우에는 각 정렬 불량 고장 신호를 분류하기 위한 표준 편차 값은 0.32에서 0.46사이 일 때, 회전자 봉 균열 고장은 0.3에서 0.42사이 일 때, 정상 신호는 0.26에서 0.38사이 일 때 좋은 분류 성능을 보였다. 회전자 불균형과 베어링 결함은 DCT+SVD로부터 추출한 특징을 이용한 경우에서도 100 %의 분류 성능을 보였다.

VI. 결론 및 향후 과제

본 논문에서는 유도 전동기의 고장을 조기에 검출하고 진단하기 위해 STE+SVD와 DCT+SVD를 이용한 특징 벡터 추출 방법을 제안하였고, 이를 역 전파 신경 회로망과

다층 서포트 벡터 머신의 입력으로 이용하여 유도 전동기의 고장을 유형별로 분류하였다. 하지만 본 논문에서는 역 전파 신경 회로망과 다층 서포트 벡터 머신을 분류기로 사용함에 있어 역 전파 신경 회로망은 신경망을 구성하는 입력 뉴런 수, 은닉 뉴런 수, 학습 알고리즘에 의해 분류 성능이 달라지며, 다층 서포트 벡터 머신은 커널 함수로 사용한 가우시안 방사 기저 함수의 표준 편차 값에 따라 분류 성능이 달라지는 점을 고려하여 여러 가지 조건하에서의 실험을 통해 높은 분류 성능을 보이는 설정 방법을 제시하였다. 먼저 역 전파 신경 회로망의 경우 레벤버그-마쿼트, 결계 경사, 베이지안 학습 알고리즘에 대해 신경망을 구성하는 입력 뉴런 수 (특징 수)와 은닉 뉴런 수를 달리하며 실험한 결과 STE+SVD로부터 추출한 특징 이용 시 입력 뉴런 수가 8이고, 결계 경사 알고리즘을 이용하여 학습하였을 때 전체적인 고장 분류 성능이 95 % 이상의 분류 성능을 보였고, DCT+SVD로부터 추출한 특징을 이용하였을 경우는 레벤버그-마쿼트와 베이지안 알고리즘을 통해 학습하고, 입력 뉴런 수가 8과 10 일 때 100 %의 분류 성능을 보였다. 다층 서포트 벡터 머신의 경우 STE+SVD와 DCT+SVD를 이용한 특징 이용 시 가우시안 방사 기저 함수의 표준 편차 값이 각 정렬 불량 고장 신호는 0.24-0.32와 0.32-0.46일 때, 회전자 봉 균열 고장 신호는 0.24-0.32와 0.3-0.42일 때, 정상 신호는 0.16-0.34와 0.26-0.38일 때 각각 좋은 분류 성능을 보였으며, 회전자 불균형과 베어링 결함의 경우는 모든 경우에 있어 100 %의 분류 성능을 보였다.

일반적으로 산업 현장에서 유도 전동기의 진동 신호를 취득하기 위해서는 다양한 센서를 이용하게 되는데, 센서의 종류에 따라 취득 신호에 포함되는 센서 잡음의 레벨이 달라지며 이는 고장 분류를 위한 특징 추출 및 고장 유형 분류 성능에 영향을 미칠 수 있다. 따라서 향후 취득한 진동 신호에 포함된 센서 잡음의 영향을 고려한 연구도 진행되어야 할 것이다.

감사의 글

이 논문은 2010년도 정부 (교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2011-0017941).

참고 문헌

1. 김승석, 이대중, 박장환, 유정웅, 전명근, “조건부 FCM과 방사 기저 함수 네트워크를 이용한 유도 전동기 고장 검출”, *한국지능시스템학회 논문지*, 14권, 7호, 878-882쪽, 2004.
2. V. Sugumaran, V. Muralidharan, and K. I. Ramachandran, “Feature Selection Using Decision Tree and Classification through Proximal Support Vector Machine for Fault Diagnosis of Roller Bearing,” *Mechanical Systems and Signal Processing*, vol. 21, pp. 930-942, 2007.
3. F. Li, G. Meng, L. Ye, and P. Chen, “Wavelet Transform-based Higher-order Statistics for Fault Diagnosis in Rolling Element Bearings,” *J. Vibration and Control*, vol. 14, no. 11, pp. 1691-1709, 2008.
4. 이대중, 조재훈, 윤종환, 전명근, “유도 주파수 선택과 선형판별분석기법을 이용한 유도 전동기 고장 진단 시스템”, *한국지능시스템학회 논문지*, 20권, 3호, 380-387쪽, 2010.
5. 정병훈, 신대철, “전류 분석을 이용한 유도 전동기의 결함 분석 알고리즘 개발”, *한국소음진동공학회 논문집*, 14권, 8호, 675-683쪽, 2004.
6. 정병훈, 신대철, “전류 신호를 이용한 유도 전동기의 회전자봉 결함 검출에 관한 연구”, *한국소음진동공학회 논문집*, 12권, 4호, 287-293쪽, 2002.
7. 한형섭, 조상진, 정의필, “신경회로망 기반 고장 진단 시스템을 위한 고장 신호별 특징 벡터 결정 방법”, *한국소음진동공학회 논문집*, 20권, 11호, 1009-1017쪽, 2010.
8. H. Ocaik, and K. A. Loparo, “Estimation of the Running Speed and Bearing Defect Frequencies of an Induction Motor from Vibration Data,” *Mechanical Systems and Signal Processing*, vol. 18, pp. 515-533, 2004.
9. F. V. Nelwamondo, and T. Marwala, “Faults Detection Using Gaussian Mixture Models, Mel-Frequency Cepstral Coefficients and Kurtosis,” *IEEE Int’l Conf. Systems, Man and Cybernetics (SMC’ 06)*, pp. 290-295, 2006.
10. K. M. Silva, B. A. Souza, and N. S. Brito, “Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN,” *IEEE Trans. Power Delivery*, vol. 21, pp. 2058-2063, 2006.
11. F. V. Nelwamondo, T. Marwala, and U. Mahola, “Early Classifications of Bearing Faults Using Hidden Markov Models, Gaussian Mixture Models, Mel-frequency Cepstral Coefficients and Fractals,” *J. Innovative Computing, Information and Control*, vol. 2, no. 6, pp. 1281-1299, 2006.
12. M. Ge, G. C. Zhang, and Y. Yu, “Feature Extraction from Energy Distribution of Stamping Processes Using Wavelet Transform,” *J. Vibration and Control*, vol. 8, pp. 1323-1032, 2002.
13. S. Poyhonen, “Support Vector Machine Based Classification in Condition Monitoring of Induction Motors,” *Thesis Presented at Helsinki University of Technology*, 2004.
14. M. Deriche, “Bearing Fault Diagnosis Using Wavelet Analysis,” *2005 Int’l Conf. Comput., Commu., and Signal Processing with Special Track on Biomedical Engineering (CCSP 2005)*, pp. 197-201, 2005.
15. N. Mehla, and R. Dahiya, “An Approach of Condition Monitoring of Induction Motor Using MCSA,” *J. Systems Applications, Engineering and Development*, vol. 1, pp. 13-17, 2007.
16. 양보석, 김광진, 한천, “진동 및 전류 신호의 데이터 융합을 이용한 유도 전동기의 결함 진단”, *한국소음진동공학회 논문집*, 14권, 11호, 1091-1100쪽, 2004.
17. G. Strang, “Linear Algebra and Its Application,” Thomson, 4/E, 2006.
18. L. Lu, H. -J. Zhang, and H. Jiang, “Content Analysis for Audio Classification and Segmentation,” *IEEE Trans. Speech and Audio Processing*, vol. 10, no. 7, pp. 504-516, 2002.

19. D. Li, I. K. Sethi, N. Dimitrova, and T. McGee, "Classification of General Audio Data for Content-based Retrieval," *Pattern Recognition Letters*, vol. 22, no. 5, pp. 533-544, 2001.
20. N. Ahmed, T. Natarajan, and K. R. Rao, "Discrete Cosine Transform," *IEEE Trans. Comput.*, pp. 90-93, 1974.
21. S. Haykin, "Neural Networks: A Comprehensive Foundation," Prentice-Hall, New Jersey, pp. 156-248, 1999.
22. I. A. Basheer, and M. Hajmeer, "Artificial Neural Network: Fundamentals, Computing Design, and Application," *J. Microbiological Methods*, vol. 43, no. 1, pp. 3-31, 2000.
23. C. Bishop, "Neural Networks for Pattern Recognition," Oxford University Press, New York, 1995.
24. S. Dreiseitl, and L. Ohno-Machado, "Logistic Regression and Artificial Neural Network Classification Models: A Methodology Review," *J. Biomedical Informatics*, vol. 35, pp. 352-359, 2002.
25. C. J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," *J. Knowledge Discovery and Data Mining*, vol. 2, pp. 121-167, 1998.

저자 약력

•강 명 수 (Myeongsu Kang)

한국음향학회지 제28권 2호 참조

•뉘옌 투 낙 (Thu-Ngoc Nguyen)

2010년 8월: 하노이 과학 기술 대학교 졸업
 2010년 9월 ~ 현재: 울산대학교 전기공학부 석사
 과정
 ※ 주관심 분야: 디지털 신호처리, 병렬 아키텍처 설
 계, IC 설계

•김 용 민 (Yongmin Kim)

한국음향학회지 제29권 3호 참조

•김 철 홍 (Cheolhong Kim)

1998년: 서울대학교 컴퓨터공학과 졸업 (학사)
 2000년: 서울대학교 컴퓨터공학부 졸업 (공학석사)
 2006년: 서울대학교 전기컴퓨터공학부 졸업 (공학박사)
 2005년 ~ 2007년: 삼성전자 반도체총괄 SYS.LSI사
 업무 책임연구원
 2007년 ~ 현재: 전남대학교 전자컴퓨터공학부 교수
 ※ 주관심 분야: 임베디드시스템, 컴퓨터구조, SoC
 설계, 저전력 설계 등

•김 중 먼 (Jong-Myon Kim)

한국음향학회지 제28권 6호 참조