

잡음 환경에서의 유도 전동기 고장 검출 및 분류를 위한 강인한 특징 벡터 추출에 관한 연구

황철희*, 강명수**, 김종면***

A Study on Robust Feature Vector Extraction for Fault Detection and Classification of Induction Motor in Noise Circumstance

Chul-Hee Hwang*, Myeongsu Kang**, Jong-Myon Kim***

요약

유도 전동기는 항공 산업, 자동차 산업 등의 산업 현장에서 중요한 역할을 하고 있으며, 이러한 유도 전동기의 고장으로 인한 피해를 최소화하기 위해 유도 전동기의 고장 검출 및 분류 시스템의 개발이 중요한 문제로 대두되고 있다. 이에 본 논문에서는 정상 및 각종 비정상 상태의 유도 전동기 진동 신호에 대해 부분 자기 상관(partial autocorrelation, PARCOR) 계수, 로그 스펙트럼 파워(log spectrum powers, LSP), 캡스트럼 계수의 평균값(cepstrum coefficients mean, CCM), 멜 주파수 캡스트럼 계수(mel-frequency cepstrum coefficient, MFCC)의 네 가지 특징 벡터를 신경 회로망의 입력으로 사용하여 유도 전동기의 고장을 검출하고 분류하였다. 고장 분류를 위한 최적의 특징 벡터를 찾기 위해 추출하는 특징의 수를 2에서 20으로 바꾸어 가며 분류 성능을 평가한 결과 CCM을 제외한 나머지의 경우 5~6의 특징만으로 분류 정확도가 거의 100%에 가까운 결과를 보였다. 또한 본 논문에서는 실제 산업 현장에서 진동 신호 취득 시 포함될 수 있는 잡음을 고려하여 취득한 신호에 백색 잡음(white Gaussian noise)을 인위적으로 추가하여 실험한 결과 LSP, PARCOR, MFCC 순으로 잡음 환경에 강인한 특징 벡터임을 확인할 수 있었다.

▶ Keyword : 고장 검출 및 분류시스템, 부분 자기 상관 계수, 로그 스펙트럼 파워, 캡스트럼 계수 평균, 멜 주파수 캡스트럼 계수, 신경 회로망

• 제1저자 : 황철희 • 교신저자 : 김종면

• 투고일 : 2011. 04. 03, 심사일 : 2011. 04. 25, 게재확정일 : 2011. 05. 01.

* 울산대학교 전기공학부(School of Electrical Engineering, University of Ulsan) 석사과정

** 울산대학교 전기공학부(School of Electrical Engineering, University of Ulsan) 박사과정

*** 울산대학교 전기공학부(School of Electrical Engineering, University of Ulsan) 조교수

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

Abstract

Induction motors play a vital role in aeronautical and automotive industries so that many researchers have studied on developing a fault detection and classification system of an induction motor to minimize economical damage caused by its fault. With this reason, this paper extracts robust feature vectors from the normal/abnormal vibration signals of the induction motor in noise circumstance: partial autocorrelation (PARCOR) coefficient, log spectrum powers (LSP), cepstrum coefficients mean (CCM), and mel-frequency cepstrum coefficient (MFCC). Then, we classified different types of faults of the induction motor by using the extracted feature vectors as inputs of a neural network. To find optimal feature vectors, this paper evaluated classification performance with 2 to 20 different feature vectors. Experimental results showed that five to six features were good enough to give almost 100% classification accuracy except features by CCM. Furthermore, we considered that vibration signals could include noise components caused by surroundings. Thus, we added white Gaussian noise to original vibration signals, and then evaluated classification performance. The evaluation results yielded that LSP was the most robust in noise circumstance, then PARCOR and MFCC followed by LSP, respectively.

▶ Keyword : fault detection and classification system, partial autocorrelation coefficient, log spectrum powers, cepstrum coefficients mean, mel-frequency cepstrum coefficient, neural network

1. 서론

산업현장이 자동화됨에 따라 전동기의 활용범위가 확대되어 왔다. 로봇 시스템 등의 특별한 용도의 전동기와는 달리 일반적인 성능이 요구되는 산업 현장의 설비에서 간단한 구조와 기계적 견고함을 갖춘 유도 전동기는 전체 계통에 대한 동력을 공급한다[1]. 이러한 유도 전동기의 고장은 유도 전동기 자체의 문제뿐만 아니라 계통 전체의 치명적인 고장 및 경제적으로 막대한 손실을 발생시킬 수 있다. 따라서 최근에는 고장 검출 및 분류 시스템 개발에 관한 연구가 활발히 진행 중인데, 이는 기계의 고장을 실시간으로 감지하여 고장이 발생하였을 때 어떠한 고장인지 기술자에게 미리 알려주므로 치명적인 기계 고장으로 인한 경제적 손실을 사전에 예방할 수 있다 [2].

회전 기계의 운전 상태를 점검하는 지표로는 진동 신호가 가장 널리 이용되는데, 진동 신호에는 회전 기계의 고장 유형별 고유의 특징들이 포함되어 있기 때문이다[3]. 하지만 진동 신호에 포함된 고장 유형별 특징을 반영하는 파라미터는 대부분 숨겨져 있으므로 취약한 진동 신호를 고장 검출 및 분류

시스템에 직접적으로 이용하기에는 어려움이 있다. 따라서 취득한 진동 신호로부터 고장 유형별 특징을 잘 나타낼 수 있는 특징 벡터를 추출하는 방법은 고장 검출 및 분류 시스템에 있어 매우 중요하다.

과거에는 기계의 고장을 분류함에 있어 전문가의 지식과 경험에 의존하였다. 이에 연구자들은 전문가 없이 고장 데이터를 쉽게 분석하고 분류할 수 있는 시스템 개발에 많은 노력을 기울인 결과 규칙기반 전문가 시스템, 정상 및 비정상 데이터에 대한 데이터베이스를 만들어 상관관계를 비교하는 시스템 등을 개발하였다. 하지만 전문가의 지식과 퍼지 이론을 이용한 전자의 경우 지식의 수정 및 추가의 어려움으로 소규모 작업 환경에만 활용되는 제약이 있었고, 후자의 경우 데이터베이스의 선정과 고장 유형이 많아질수록 데이터베이스와 비교 연산이 증가하는 등의 문제점을 가지게 되었다. 이를 해결하기 위해 신경 회로망을 고장 검출 및 분류 시스템에 적용하였는데, 신경 회로망은 학습을 통해 최적화된 분류 모델을 제공하므로 기계에 대한 전문적인 지식 없이도 고장을 검출하고 분류한다. 또한 학습이 완료된 후에는 계산 속도가 빠르기 때문에 실시간 고장 검출 및 분류 시스템에 적용이 가능한 장점을 갖는다. 따라서 본 논문에서는 고장 유형별 효과적인 분류를 위해 신경 회로망을 사용한다.

취득한 유도 전동기의 고장 유형별 진동 신호는 고장별 고유의 특징과 관계없는 불필요한 데이터를 많이 포함하고 있어 이를 모두 신경 회로망의 입력으로 사용할 경우 학습 시 많은 시간을 소요할 뿐만 아니라 고장 유형별 특징을 구분하는데 방해가 된다[4]. 그러므로 고장 유형별 진동 신호의 분석을 통해 각 신호를 뚜렷하게 구분시켜 줄 특징 벡터의 추출 방법에 관한 연구가 활발히 진행되고 있다[3, 5]. 따라서 본 논문에서는 취득한 유도 전동기의 진동 신호를 시간 영역 분석(부분 자기 상관 계수), 주파수 영역 분석(로그 스펙트럼 파워), 시간-주파수 영역 분석(캡스트럼 계수의 평균값, 멜 주파수 캡스트럼 계수)을 통해 고장 유형별 특징 벡터를 추출하였다. 본 논문에서는 최적의 특징 벡터 추출을 위해 특징의 수를 달리 하며 신경 회로망의 입력으로 사용하고, 그에 따른 고장 분류 성능을 평가하였다. 또한 진동 신호 취득 시 주변 환경으로 인해 잡음이 추가될 수 있는 상황을 고려하여 취득한 신호에 인위적으로 백색 잡음(white Gaussian noise)을 원 신호와 잡음이 추가된 신호의 신호 대 잡음 비(signal-to-noise ratio, SNR)가 20dB, 15dB, 10dB, 5dB가 되도록 한 후 시스템의 성능을 평가하였다.

본 논문의 구성은 다음과 같다. 2장에서는 고장 유형별 유도 전동기 진동 신호의 특징과 취득 환경을 설명하고, 3장에서는 이러한 진동 신호의 고장 유형별 특징 벡터 추출 방법을 소개한다. 4장에서는 고장 분류를 위한 신경 회로망의 구성에 대해 언급하고, 5장에서는 다양한 특징 벡터를 이용한 고장 분류 결과를 보인다. 마지막으로 6장에서는 본 논문의 결론을 맺는다.

II. 유도 전동기 고장 유형별 진동 신호의 특징

본 논문에서는 유도 전동기의 고장 검출 및 분류를 위해 진동 데이터를 사용하였으며, 이는 부경대학교 지능기계연구실에서 제공한 것으로 정상 상태(normal, no)를 비롯한 5가지의 비정상 상태의 고장에 대한 신호이다[6]. 본 논문에서 사용한 5가지 비정상 상태의 진동 신호는 다음과 같다.

각 정렬 불량(angular misalignment, am) : 축 지지대를 조절하여 편각 정렬 불량 상태를 가지게 함으로써 얻어진 진동 신호

회전자봉 균열(broken rotor bar, br) : 34개의 회전자봉 중에서 12개의 봉을 파손하여 얻어진 진동 신호

굽은 회전자축(broken rotor shaft, bs) : 최대 0.0075mm

로 회전자를 굽혀서 측정된 진동 신호

평행 정렬 불량(parallel misalignment, pm) : 축 지지대를 조절하여 편심 정렬 불량 상태를 가지게 함으로써 얻어진 진동 신호

위상 불 평형(phase unbalance, pu) : 회전자에 8.4g의 불 평형 질량을 회전자에 부착하여 얻어진 진동 신호

취득한 진동 신호의 샘플링 주파수는 8kHz이며, 신경 회로망의 학습과 고장 검출 및 분류 성능 평가를 위한 충분한 데이터를 만들기 위해 취득한 신호를 1초 길이의 프레임으로 나누어 각 고장 유형별로 105개의 신호를 추출하여 사용하였다. 그림 1은 정상 상태 및 비정상 상태의 취득한 고장 유형별 진동 신호의 파형(그림 1(a))과 스펙트럼(그림 1(b))을 보이며, 진동 신호의 스펙트럼은 고장 유형별 특징을 잘 나타낸다.

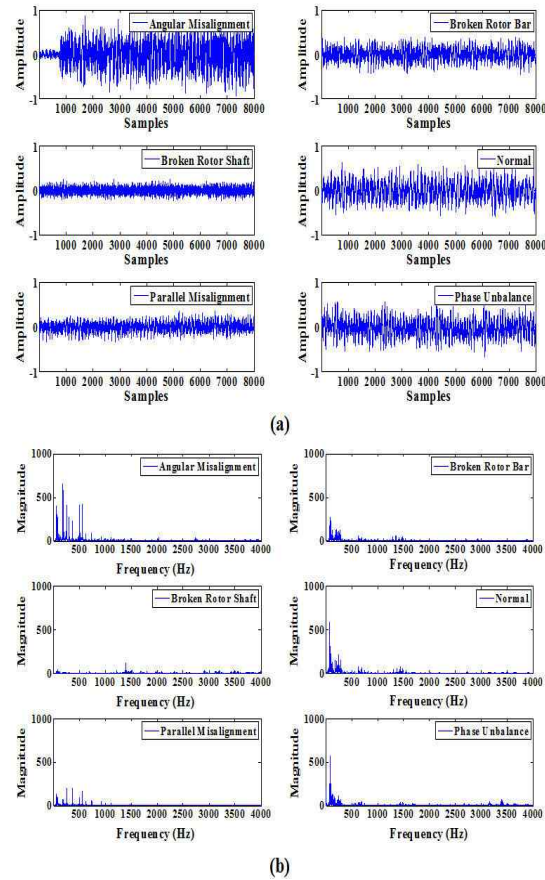


그림 1. 고장 신호의 파형과 스펙트럼. (a) 고장 신호의 파형, (b) 고장 신호의 스펙트럼

Fig. 1. Waveform and spectra of fault signals. (a) waveform of induction motor, and (b) spectra of induction motor

III. 특징벡터 추출기법

취득한 진동 신호는 고장 유형별 고유의 특징을 보이고 있지만, 고장 검출 및 분류를 위해 이러한 신호를 모두 사용하는 것은 비효율적이다. 따라서 본 논문에서는 시간 영역 분석, 주파수 영역 분석, 시간-주파수 영역 분석을 통해 고장 유형별 특징을 잘 표현할 수 있는 특징 벡터를 추출하여 신경 회로망의 입력으로 사용한다.

3.1 시간 영역 분석

3.1.1 부분 상관 계수

현재의 입력 샘플과 과거의 출력 샘플을 적절히 선형 조합하여 주어지지 않은 과거 시점의 새로운 출력 신호를 얻는 것을 선형 예측이라 하며, 음성에서는 선형 예측 코딩(linear predictive coding, LPC)을 이용하여 음성 신호를 분석하는데 이를 이용하면 음성 샘플 사이의 상관관계를 모델링할 수 있다[7]. 식 (1)은 사람의 발성 기관인 성도 전달 필터의 차분 방정식으로 $s(n)$ 은 출력 신호, $x(n)$ 은 입력 신호, G 는 입력 신호의 가중치, p 는 LPC의 차수이다.

$$s(n) = Gx(n) + \sum_{i=1}^p \alpha_i s(n-i), \dots\dots\dots (1)$$

LPC 계수 α_i 는 측정 신호(출력 신호)와 누적된 추정치의 오차를 최소화함으로써 얻을 수 있는데, 최소 추정 오차 $e(n)$ 을 얻기 위해 식 (2)를 α 에 대해 편미분하면 p 개의 LPC 계수를 구할 수 있다.

$$e(n) = s(n) - \sum_{i=1}^p \alpha_i s(n-i). \dots\dots\dots (2)$$

이를 이용하면 적은 수의 LPC 계수로 출력 신호의 스펙트럼 포락선(spectrum envelope)을 잘 표현할 수 있다. 그림 1에서 유도 전동기의 고장 신호는 고장 유형별 서로 다른 스펙트럼을 보이므로, 고장 신호 별 LPC 계수는 이러한 고장 신호를 검출하고 분류할 수 있는 특징 벡터로 사용할 수 있다. 그림 2는 유도 전동기 고장 신호 스펙트럼과 LPC 포락선과의 상관관계를 나타낸다.




그림 2. 유도 전동기 고장 신호의 스펙트럼과 LPC 포락선. (a) 굵은 회선축, (b) 위상 불평형
Fig. 2. Spectral and LPC envelope of induction motor. (a) broken rotor shaft, and (b) phase unbalance

하지만 LPC 계수는 출력 신호에 포함되는 잡음에 의해 그 값의 변화가 큰 단점을 가지고 있다. 본 논문에서는 고장 신호 취득 시 주변 환경의 영향으로 잡음이 추가될 수 있는 상황을 고려하여 이러한 현상을 최소화할 수 있는 부분 자기 상관 계수(partial autocorrelation, PARCOR)를 특징 벡터로 사용한다. 부분 자기 상관 계수는 반사 계수(reflection coefficients)라고도하며, 식 (3)과 같이 LPC 계수를 구하는 과정에서 얻을 수 있다[7].

$$k_i = \frac{\alpha_{i-1} - \alpha_i}{\alpha_{i-1} + \alpha_i}, \quad i = 1, 2, \dots, p \text{ and } \alpha = 0. \dots\dots\dots (3)$$

그림 3은 고장 신호에 백색 잡음을 원 신호와 잡음이 추가된 신호의 SNR이 15dB, 10dB, 5dB가 되도록 추가한 후 LPC 계수와 PARCOR 계수 값의 변화를 보여준다. 그림 3에서 볼 수 있듯이 잡음 환경에 대해 LPC 계수보다 PARCOR 계수의 변화가 적으며, 이는 유도 전동기의 고장 검출 및 분류를 위한 좋은 특징 벡터가 될 수 있다.

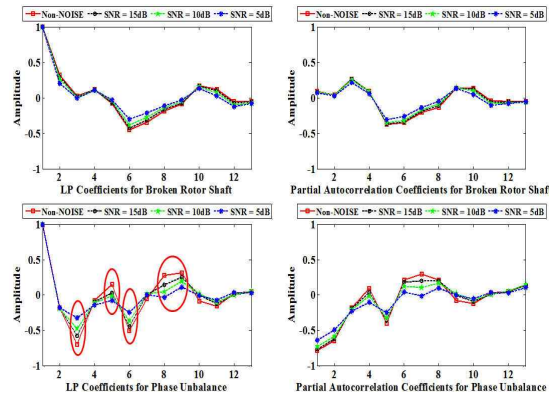


그림 3. 잡음 추가에 따른 LPC 계수와 PARCOR 계수 비교
Fig. 3. LPC coefficients and PARCOR coefficients after adding white Gaussian noise with SNR=20dB, 15dB, 10dB, and 5dB

3.2 주파수 영역 분석

3.2.1 LSP(Log Spectrum Powers)

앞서 언급하였듯이 그림 1은 유도 전동기의 진동 신호로 고장 유형별 서로 다른 스펙트럼을 보여준다. 주파수 영역 분석에서 이러한 특징을 반영하기 위한 특징 벡터 추출 방법으로 서브 밴드별 통계적 방법(서브 밴드별 평균값 또는 분산값), 서브 밴드별 최대값을 이용하는 방법, 서브 밴드별 스펙트럼 파워를 이용하는 방법 등이 있다. 본 논문에서는 식 (4)의 서브 밴드별 로그 스펙트럼 파워를 이용하여 특징 벡터를 추출하고 유도 전동기의 고장 검출 및 분류에 대한 성능을 평가한다[8].

$$P_i = \log\left(\int_{L_i}^{H_i} |F_i(\omega)|^2 d\omega\right), \dots\dots\dots (4)$$

여기서, L_i 와 H_i 는 i 번째 서브 밴드의 최소 주파수와 최대 주파수를 각각 나타내며, $F_i(\omega)$ 는 i 번째 서브 밴드의 스펙트럼이다.

그림 4는 잡음의 유무에 따른 굵은 회전축 고장의 스펙트럼으로 3번째 서브 밴드는 해당 신호를 다른 고장 신호와 분류할 수 있는 좋은 정보들을 포함하고 있다.

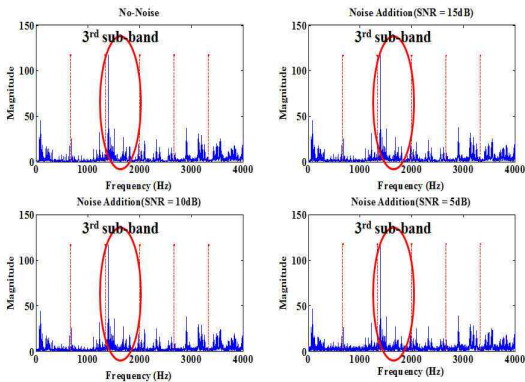


그림 4. 잡음 유무에 따른 굵은 회전축 고장의 스펙트럼
Fig. 4. Spectrum of broken rotor shaft according to the condition of noise addition

하지만 표 1에서와 같이 원 신호와의 SNR이 15dB, 10dB, 5dB가 되도록 백색 잡음을 추가한 후 스펙트럼 파워 값은 그 차이가 크게 나타났으며, 상대적으로 로그 스펙트럼 파워 값은 그 차이가 적게 나타났다. 이는 잡음이 추가된 환경에서 로그 스펙트럼 파워가 고장 신호의 특징을 더 잘 표현할 수 있음을 의미한다.

표 4. 잡음이 추가 후의 스펙트럼 파워 값과 로그 스펙트럼 파워 값 비교(굵은 회전축 고장의 3번째 서브 밴드)
Table 1. Comparison of spectrum powers and log spectrum powers after adding white Gaussian noise (for the 3rd sub-band of broken rotor shaft)

	No-Noise	SNR (15dB)	SNR (10dB)	SNR (5dB)
스펙트럼 파워($\times 10^4$)	4.4997	4.5016	4.6435	4.7983
로그 스펙트럼 파워	4.6532	4.6534	4.6668	4.6811

3.3 시간-주파수 영역 분석

3.3.1 CCM(Cepstral Coefficient Mean)

대부분의 시간 영역 신호는 시간의 변화에 따라 그 특징이 달리 나타난다. 따라서 본 논문에서는 고장 유형별 유도 전동기의 시간에 따른 변화 특징을 고장 검출 및 분류를 위한 특징 벡터로 추출하기 위해 취득한 1초 길이의 신호를 $1/N_{frame}$, $N_{frame} = 2, 3, \dots, 20$ 길이의 프레임으로 나누고, 각 프레임별 캡스트럼 분석을 하였다. 입력 신호를 $1/N_{frame}$ 길이의 프레임으로 나누기 위해 사각 윈도우(rectangular window)를 사용하였다. 식 (5)는 입력 신호 $x(n)$ 에 대한 캡스트럼 계수 c_x 이다[9].

$$c_x = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log|X(e^{j\omega})| e^{j\omega n} d\omega. \dots\dots\dots (5)$$

즉, 캡스트럼 계수는 입력 신호 $x(n)$ 의 스펙트럼 $X(e^{j\omega})$ 의 로그 값의 역푸리에 변환으로 정의된다. 그림 5는 캡스트럼 계수를 이용한 캡스트럼 포락선(cepstrum envelope)으로 입력 신호 $x(n)$ 의 캡스트럼 포락선은 길이 n_c 의 사각 윈도우와 c_x 의 곱을 푸리에 변환하여 구할 수 있다. 이 때 윈도우 크기 n_c 는 첫 번째 피크 값으로 정하였다. 이와 같이 캡스트럼 포락선은 각 고장 유형별 스펙트럼 모양을 표현하므로, 고장 유형별 고장 검출 및 분류를 위한 특징 벡터로 캡스트럼 계수를 이용할 수 있다. 하지만 n_c 개의 캡스트럼 계수를 모두 특징으로 사용하기에는 그 수가 너무 많으므로 본 논문에서는 각 프레임별 캡스트럼 계수의 평균을 신경 회로망의 입력으로 사용한다.

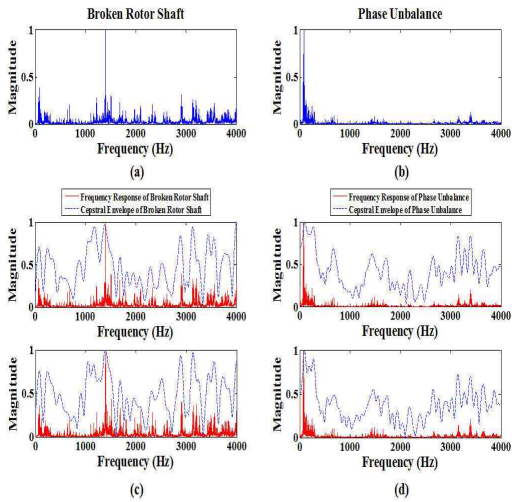


그림 5. 캡스트럼 계수를 이용한 캡스트럼 포락선. (a) 굵은 회전축 고장의 스펙트럼, (b) 위상 불 평형 고장의 스펙트럼, (c) 굵은 회전축 고장의 캡스트럼 포락선(첫 번째 프레임(위), 두 번째 프레임(아래)), (d) 위상 불 평형 고장의 캡스트럼 포락선(첫 번째 프레임(위), 두 번째 프레임(아래))

Fig. 5. Cepstral envelope using cepstrum coefficients. (a) spectrum of broken rotor shaft, (b) spectrum of phase unbalance, (c) cepstral envelope of broken rotor shaft (1st frame (up), 2nd frame (bottom)), and (d) cepstral envelope of phase unbalance (1st frame (up), 2nd frame (bottom))

3.3.2 MFCC(Mel-frequency cepstral coefficients)

멜 주파수 캡스트럼(Mel-frequency cepstrum)은 짧은 구간 신호의 파워스펙트럼을 표현하는 방법 중 하나로, 시간과 주파수 정보를 포함하고 있어 음성 인식이나 선형/비선형 신호에서 특징을 추출하는 방법으로 많이 사용된다. 그림 6은 멜 주파수 캡스트럼 계수(Mel-frequency cepstral coefficients, MFCC)를 구하기 위한 블록도이며, 자세한 과정은 아래와 같다[10].

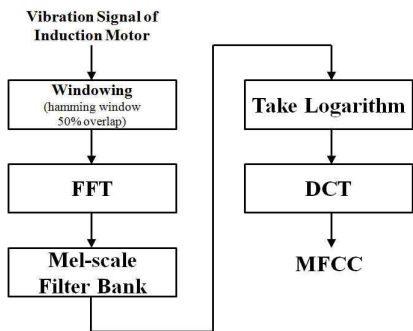


그림 6. 멜 캡스트럼 계수 추출을 위한 블록도
Fig. 6. Block diagram to extract MFCC

Step 1. 식 (6)과 같이 입력 신호 $x(n)$ 에 푸리에 변환을 취한다.

$$Y(m) = \frac{1}{N_{frame}} \sum_{n=0}^{N_{frame}-1} x(n)w(n)e^{-j\frac{2\pi}{N_{frame}}nm}, \dots\dots (6)$$

여기서 N_{frame} 는 프레임의 수, $0 \leq m \leq (N_{frame} - 1)$, $w(n)$ 은 윈도우 함수로 해밍 윈도우(hamming window)를 사용한다.

Step 2. 식 (7)을 이용하여 주파수를 Hz 스케일에서 멜 스케일로 변환하고, 멜 주파수 워핑(Mel-frequency wrapping)을 위해 필터 뱅크(filter bank)를 이용한다.

$$Mel = 2595 \times \log_{10} \left(1 + \frac{f(Hz)}{700} \right). \dots\dots\dots (7)$$

Step 3. Mel 주파수 캡스트럼 계수는 식 (8)과 같이 멜 스케일의 주파수 스펙트럼에 로그와 이산 코사인 변환을 취함으로써 얻을 수 있다.

$$C_m^i = \sum_{n=0}^{N_{frame}-1} \cos \left(m \frac{\pi}{N_{frame}} (n+0.5) \right) \log_{10}(H_n), \dots (8)$$

여기서 $0 \leq m \leq L-1$ 이며, L 은 i 번째 프레임에서 추출할 MFCC의 개수이다. H_n 은 필터 뱅크에서 n 번째 필터의 전달 함수이다. MFCC는 선형/비선형적인 특성을 포함하고 있는 유도 전동기의 진동 신호에서 특징을 추출함에 있어 유용하다. 따라서 본 논문에서는 이러한 MFCC를 유도 전동기의 고장 검출 및 고장 분류를 위한 특징 벡터로 사용하여 그 성능을 검증한다.

IV. 신경 회로망

유도 전동기의 고장 유형별 분류를 위해 본 논문에서는 신경 회로망을 사용하였으며, 신경 회로망의 사용은 유도 전동기 결함에 대한 자세한 지식의 요구 없이 결함에 대한 형태를 분류할 수 있도록 한다. 그림 7은 본 논문에서 사용한 신경 회로망으로, n ($n=3,4,\dots,20$) 개의 입력 뉴런(input neuron), 1개의 은닉 층(hidden layer), 12개의 은닉 뉴런, 6개의 출력 뉴런(output neuron)으로 구성되며 각각의 뉴런은 완전 연결되어있다. 신경 회로망을 이용한 고장 신호의 분류 절차는 피드 포워드(feed-forward) 과정과 역전파(back propagation) 과정을 통해 연결강도(connection weight)를 조절하고, 계산된 결과 값과 목표 값과의 오차를 최소화하는 과정을 통해 이루어

어진다[11]. 신경 회로망의 학습을 위해 Levenberg-Marquardt 알고리즘을 이용하였고, 학습 정도는 표준 오차 평균(mean squared error)의 학습 임계 값을 $1.00e-10$ 로 정하여 신경망 회로를 학습하였다.

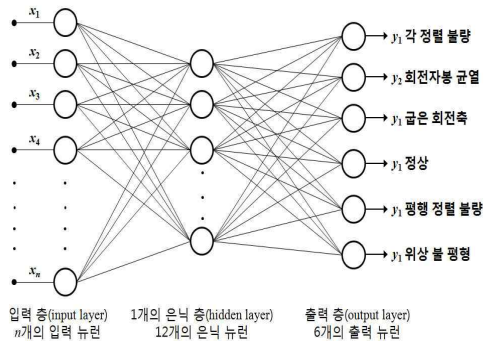


그림 7. 고장 분류를 위한 신경망 회로
Fig. 7. Neural network for fault classification for induction motor

신경 회로망의 학습과 테스트를 위한 데이터는 특징 추출 알고리즘으로부터 추출한 특징 벡터의 80%(고장 유형별 84개)를 학습을 위한 데이터로, 20%(고장 유형별 21개)를 테스트를 위한 데이터로 사용하였다. 또한 Keams의 권장사항으로 학습 데이터의 20%(고장 유형별 21개)를 검증에 위한 데이터로 사용하였다[4]. 본 논문에서는 유도 전동기의 고장 검출 및 분류를 위한 효율적인 특징 벡터를 찾기 위해 시간 영역, 주파수 영역, 시간-주파수 영역 분석을 통해 추출된 특징을 2에서 20으로 바꾸어가며 신경 회로망의 입력으로 사용하고, 각각에 대한 고장 유형별 분류 성능을 살펴본다.

표 5. 특징 추출 알고리즘과 신경망 회로를 이용한 고장 분류 성능
Table 2. Fault classification performance using the feature extraction algorithms and neural network

추출 알고리즘	특징 수 데이터 종류	특징 수					추출 알고리즘	특징 수 데이터 종류	특징 수				
		2	3	4	5	6			2	3	4	5	6
PARCOR	AM	96.7	100	100	100	100	LSP	AM	100	100	100	100	100
	BS	100	100	100	100	100		BS	100	100	100	100	100
	BR	100	100	100	100	100		BR	100	100	100	100	100
	NO	100	100	100	100	100		NO	100	100	100	100	100
	PM	100	100	100	100	100		PM	100	100	100	100	100
	PU	100	100	100	100	100		PU	100	100	100	100	100
CCM	AM	100	100	100	100	100	MFCC	AM	38.1	100	100	100	100
	BS	100	100	100	85.7	100		BS	100	100	100	100	100
	BR	71.4	66.7	76.2	85.7	76.2		BR	38.1	100	100	100	100
	NO	66.7	61.7	85.7	66.7	81.0		NO	71.4	100	100	100	100
	PM	100	100	100	100	100		PM	100	100	100	100	100
	PU	100	85.7	100	85.7	100		PU	100	100	100	100	100

V. 실험 결과

그림 8은 유도 전동기의 고장 분류를 위한 블록도로, 크게 두 단계로 이루어진다. 먼저, 취득한 고장 신호를 시간 영역, 주파수 영역, 시간-주파수 영역 분석 방법을 통해 각 고장 유형별 특징 벡터를 추출하고, 다음으로는 추출된 특징 벡터를 신경 회로망의 입력으로 사용하여 정상 상태 및 5가지 비정상 상태로 분류한다. 이와 더불어 분류 성능 평가를 위한 모의 실험에서는 특징의 수를 2에서 20으로 바꿔가며 각각에 대한 성능을 모두 평가하였으나 제한된 지면의 양으로 인해 본 논문에서는 특징 수가 2에서 6인 경우의 결과만을 표로 나타낸다. 자세한 실험 결과는 아래 웹페이지를 통해 확인할 수 있다.

http://eucs.ulsan.ac.kr/fd_induction_motor

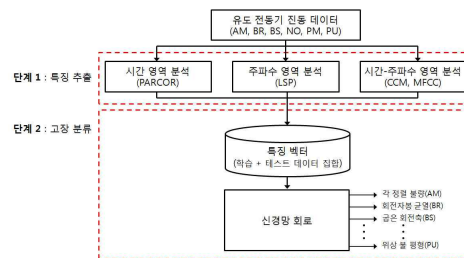


그림 8. 특징 벡터 추출 및 분류를 위한 블록도
Fig. 8. Block diagram for feature extraction and fault classification

표 2는 특징 추출 알고리즘과 신경 회로망을 이용한 고장 분류 성능을 나타낸다. 표 2에서 볼 수 있듯이 CCM을 이용한 특징 벡터를 제외하고는 고장 분류 성능이 매우 우수함을 알 수 있다.

그림 5에서 캡스트럼 계수 자체는 유도 전동기의 고장 유형별 스펙트럼 포락선을 잘 표현하므로 고장 분류를 위한 특징 벡터로 사용할 수 있지만 그림 9에서와 같이 서브 밴드별 캡스트럼 계수의 평균값은 다른 고장 신호와 중첩되는 경우가 발생하게 되어 분류 성능이 떨어지는 결과를 보였다. 따라서 높은 정확도가 요구되는 산업 현장에서 CCM으로 추출된 특징 벡터는 유도 전동기의 고장 검출 및 분류에 적합하지 않은 것으로 판단된다.

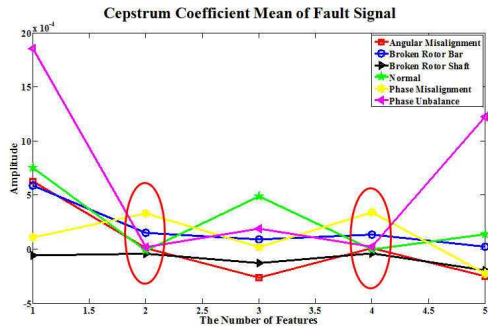


그림 9. 캡스트럼 계수 평균 값 분포
Fig. 9. Distribution of cepstrum coefficients mean

실제 산업 현장에서는 유도 전동기의 진동 신호 취득 시 주변 환경으로 인해 잡음이 추가될 가능성이 있다. 따라서 본 논문에서는 원 신호와 잡음이 추가된 신호의 SNR이 20dB, 15dB, 10dB, 5dB가 되도록 인위적으로 백색 잡음을 추가하여 CCM을 제외한 나머지 방법으로 추출한 특징 벡터들이 잡음 환경에 얼마나 강인한지 그 성능을 평가하였고, 그 결과는 표 3-5와 같다. 실험 결과에서 확인할 수 있듯이 PARCOR 계수는 각 정렬 불량, 회전자봉 균열 고장에 대해

SNR이 10dB, 5dB, 특징 수가 5이하인 조건에서 대체로 90%~95%의 분류 정확도를 보였으며, 특히 회전자봉 균열 대해 SNR이 5dB, 특징 수가 2인 경우에는 66.7% 정확도의 낮은 분류 성능을 보이기도 하였다. 하지만 특징 수가 6이상에서는 분류 정확도가 거의 100%로, 이는 PARCOR 계수를 유도 전동기의 고장 검출 및 분류를 위한 진단 시스템에 적용하기 위해서는 최소 6개 이상의 특징이 요구된다는 것을 의미한다. 표 4에서 LSP는 잡음이 추가된 환경에서도 최소의 특징으로 100% 정확도의 분류 성능을 보여 잡음 환경에서 가장 강인하였다. 따라서 유도 전동기의 진동 신호로부터 LSP를 이용하여 특징 벡터를 추출할 경우 이를 진단 시스템에 직접적으로 적용할 수 있는 장점이 있다. MFCC는 사람의 청각 기관을 모델링한 방법으로 적은 수의 특징 벡터를 사용할 경우 잡음 환경에 특별히 강인하지는 않았다. 표 5에서 볼 수 있듯이 MFCC는 정상 상태를 포함 각 정렬 불량, 회전자봉 균열, 평행 정렬 불량 고장에 대해 특징 수가 5이하인 경우 잡음 환경에 민감하였고, 특히 회전자봉 균열 고장에 대해서는 특징 수가 6이상인 경우에도 100% 분류 성능을 보이지 않는 경우가 있었다. 따라서 MFCC를 유도 전동기의 고장 진단을 위한 산업 현장에 적용할 경우 신호 취득의 정밀함과 특징 벡터 추출 전에 잡음을 제거하는 등의 전 처리(pre-processing) 과정이 요구된다.

VI. 결 론

본 논문에서는 유도 전동기의 고장 검출 및 분류를 위한 잡음 환경에 강인한 특징 벡터 추출 방법에 대해 연구하였다.

표 6. 잡음이 추가된 환경에서 PARCOR 계수를 이용한 고장 분류 성능
Table 3. Fault classification performance using PARCOR coefficients after adding white Gaussian noise

추출 알고리즘	데이터 종류	특징 수 SNR	특징 수					추출 알고리즘	데이터 종류	특징 수 SNR	특징 수				
			2	3	4	5	6				2	3	4	5	6
PARCOR	AM	5dB	90.5	100	95.2	100	100	PARCOR	NO	5dB	100	100	100	100	100
		10dB	100	95.2	100	100	100			10dB	100	100	100	100	100
		15dB	100	100	100	100	100			15dB	100	100	100	100	100
		20dB	100	100	100	100	100			20dB	100	100	100	100	100
	BR	5dB	100	100	100	100	100		PM	5dB	90.5	100	95.2	90.5	100
		10dB	100	100	100	100	100			10dB	100	100	100	100	100
		15dB	100	100	100	100	100			15dB	100	100	100	100	100
		20dB	100	100	100	100	100			20dB	100	100	100	100	100
	BS	5dB	66.7	100	100	100	100		PU	5dB	100	100	100	100	100
		10dB	95.2	100	100	100	100			10dB	100	100	100	100	100
		15dB	100	100	100	100	100			15dB	100	100	100	100	100
		20dB	100	100	100	95.2	100			20dB	100	100	100	100	100

시간 영역 분석(PARCOR 계수), 주파수 영역 분석(LSP), 시간-주파수 영역 분석(CCM, MFCC)을 통해 유도 전동기의 고장 유형별 특징 벡터를 추출하고, 이를 신경 회로망의 입력으로 사용하여 유형별 고장을 분류하였다. 최적의 특징 벡터 추출을 위해 특징의 수를 2에서 20으로 바꾸어 가며 실험한 결과 잡음이 포함되지 않은 환경에서는 CCM을 제외한 나머지 방법에서 특징 수가 3이상인 경우 분류 성능이 거의 100%에 가까웠으며, 잡음이 포함된 환경에서 PARCOR 계수는 특징 수가 5이하인 경우, MFCC는 특징 수가 6이하인 경우에는 분류 성능이 다소 떨어지는 결과를 보였다. 하지만 LSP의 경우는 잡음이 포함된 환경에서도 모든 경우에서 100%의 고장 분류 정확도를 보여 잡음 환경에 가장 강인한 특징 벡터임을 확인할 수 있었다.

참고문헌

- [1] S.-S. Kim, H.-B. Kim, J.-W. Ryu, M.-G. Chun, "Detection and Diagnosis of Induction Motor using Conditional FCM and Radial Basis Function Network," in Proc. 2004 Korean Fuzzy and Intelligent Systems Conference, Vol. 14, No. 1, pp. 321-324, April 2004.
- [2] V. Crupi, E. Guglielmino, G. Milazzo, "Neural-network-based System for Novel Fault Detection in Rotating Machinery," Journal of Vibration and Control, Vol. 10, No. 8, pp. 1137-1150, Aug. 2004.

표 7. 잡음이 추가된 환경에서 LSP를 이용한 고장 분류 성능
Table 4. Fault classification performance using LSP after adding white Gaussian noise

추출 알고리즘	데이터 종류	특징 수 SNR	특징 수					추출 알고리즘	데이터 종류	특징 수 SNR	특징 수				
			2	3	4	5	6				2	3	4	5	6
LSP	AM	5dB	100	100	100	100	100	LSP	NO	5dB	100	100	100	100	100
		10dB	100	100	100	100	100			100	100				
		15dB	100	100	100	100	100			100	100				
		20dB	100	100	100	100	100			100	100				
	BR	5dB	100	100	100	100	100		PM	5dB	100	100	100	100	100
		10dB	100	100	100	100	100			100	100				
		15dB	100	100	100	100	100			100	100				
		20dB	100	100	100	100	100			100	100				
	BS	5dB	100	100	100	100	100		PU	5dB	100	100	100	100	100
		10dB	100	100	100	100	100			100	100				
		15dB	100	100	100	100	100			100	100				
		20dB	100	100	100	100	100			100	100				

표 8. 잡음이 추가된 환경에서 MFCC를 이용한 고장 분류 성능
Table 5. Fault classification performance using MFCC after adding white Gaussian noise

추출 알고리즘	데이터 종류	특징 수 SNR	특징 수					추출 알고리즘	데이터 종류	특징 수 SNR	특징 수				
			2	3	4	5	6				2	3	4	5	6
MFCC	AM	5dB	52.3	100	100	100	100	MFCC	NO	5dB	90.5	100	100	90.5	100
		10dB	61.9	95.2	100	100	100			10dB	71.4	100	100	100	100
		15dB	52.3	100	100	100	100			15dB	57.1	100	100	100	100
		20dB	38.1	100	100	100	100			20dB	66.7	100	100	100	100
	BR	5dB	100	100	100	100	100		PM	5dB	95.3	100	100	100	100
		10dB	100	100	100	100	100			10dB	100	100	100	100	100
		15dB	100	100	100	100	100			15dB	100	100	100	100	100
		20dB	100	100	100	100	100			20dB	100	100	100	100	100
	BS	5dB	57	76.2	81	81	81		PU	5dB	100	100	100	100	100
		10dB	85.7	85.7	95	95.2	95.2			10dB	100	100	100	100	100
		15dB	71.4	95.2	95.2	95.2	95			15dB	100	100	100	100	100
		20dB	100	100	100	100	100			20dB	100	100	100	100	100

[3] F. Li, G. Meng, L. Ye, P. Chen, "Wavelet Transform-based Higher-order Statistics for Fault Diagnosis in Rolling Element Bearings," Journal of Vibration and Control, Vol. 14, No. 11, pp. 1691-1709, Nov. 2008.

[4] S. Haykin, "Neural Networks: A Comprehensive Foundation," Prentice-Hall, New Jersey, pp. 156-248, 1999.

[5] R. P. Lippman, "Pattern Classification using Neural Network," IEEE Communication Magazine, Vol. 27, No. 11, pp. 47-50, 59-64, Nov. 1989.

[6] B.-S. Yang, K. J. Kim, T. Han, "Fault Diagnosis of Induction Motors using Data Fusion of Vibration and Current Signal," Transaction of the Korean Society for Noise and Vibration Engineering, Vol. 14, No. 11, pp. 1091-1100, Nov. 2004.

[7] A. M. Kondoz, "Digital Speech Coding for Low Bit Rate Communication Systems," JOHN WILEY & SONS, pp. 42-52, 1995.

[8] S. Z. Li, "Content-based Audio Classification and Retrieval using the Nearest Feature Line Method," IEEE Transactions on Speech and Audio Processing, Vol. 8, No. 5, pp. 619-625, Sep. 2000.

[9] Y. Hong, S. Cho, J.-M. Kim, U. Chong, "Formant Synthesis of Haegeum Sounds Using Cepstral Envelope," Journal of Acoustical Society of Korea, Vol. 28, No. 6, pp. 526-533, Aug. 2009.

[10] H. Ocak, 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, No. 3, pp. 515-533, May 2004.

[11] I. A. Basheer, M. Hajmeer, "Artificial Neural Network: Fundamentals, Computing Design, and Application," Journal of Microbiological Methods, Vol. 43, Vol. 1, pp. 3-31, Dec. 2000.

저자 소개



황철희

2008 : 울산대학교 컴퓨터공학과 학사
 2008 : 울산대학교 컴퓨터공학과 석사
 과정 입학.
 관심분야 : 임베디드 SoC, 컴퓨터 구조,
 고장예측, 병렬처리
 Email: imus@hanmail.net



강명수

2008 : 울산대학교 컴퓨터공학과 학사
 2010 : 울산대학교 컴퓨터공학과 공학
 석사
 2010~현재 : 울산대학교 컴퓨터공학과
 박사과정
 관심분야 : 임베디드 시스템, 음향신호
 처리, 고장진단
 Email: ilmareboy@ulsan.ac.kr



김종면

1995 : 명지대학교 전기공학사
 2000 : University of Florida ECE
 석사
 2005 : Georgia Institute of Techn
 ology ECE 박사
 2005~2007 : 삼성종합기술원 전문연
 구원
 2007~현재 : 울산대학교 컴퓨터정보통
 신공학부 교수
 관심분야 : 프로세서 설계, 임베디드
 SoC, 컴퓨터구조, 병렬처리
 Email: jongmyon.kim@gmail.com