

EIV를 이용한 신경회로망 기반 고장진단 방법

Neural-network-based Fault Detection and Diagnosis Method Using EIV(errors-in variables)

한형섭*·조상진*·정의필†

Hyungseob Han, Sangjin Cho and Uipil Chong

(2011년 8월 16일 접수 ; 2011년 10월 26일 심사완료)

Key Words : Fault Diagnosis(고장진단), Feature Extractions(특징추출), LPC Coefficients(LPC 계수), EIV, Neural Network(신경회로망), Rotating Machines(회전기계)

ABSTRACT

As rotating machines play an important role in industrial applications such as aeronautical, naval and automotive industries, many researchers have developed various condition monitoring system and fault diagnosis system by applying artificial neural network. Since using obtained signals without pre-processing as inputs of neural network can decrease performance of fault classification, it is very important to extract significant features of captured signals and to apply suitable features into diagnosis system according to the kinds of obtained signals. Therefore, this paper proposes a neural-network-based fault diagnosis system using AR coefficients as feature vectors by LPC(linear predictive coding) and EIV(errors-in variables) analysis. We extracted feature vectors from sound, vibration and current faulty signals and evaluated the suitability of feature vectors depending on the classification results and training error rates by changing AR order and adding noise. From experimental results, we conclude that classification results using feature vectors by EIV analysis indicate more than 90 % stably for less than 10 orders and noise effect comparing to LPC.

1. 서론

회전기계는 항공산업, 조선업, 자동차 산업 등의 산업현장에서 중요한 역할을 하고 있다. 이러한 회전기계가 오동작을 일으키면 기계 자체에 영향을 줄 뿐 아니라 전체 공정의 중단 등 막대한 경제적 손실과 인명피해를 유발 할 수 있다. 이러한 이유로 최근에는 고장진단 및 감시 시스템의 개발이 매우 중요한 문제로 대두되었다. 진단 시스템의 주요 목적은 고장이 발생했을 때 기술자들이 기계의 어느

부분을 분해해야 할지 알려주는 것과 내부 부품의 상태를 적절하게 분석하여 실시간 감시를 가능하게 하는 것이다⁽¹⁾.

기계의 운전 상태를 점검하는 지표로는 온도, 음향, 사운드, 전류 등이 있다. 기어 시스템 등에서 고장진단에 음향신호 분석을 사용하기도 하지만 일반적으로 기계의 상태를 나타내는 포괄적인 지표로는 진동 신호가 가장 널리 이용된다⁽²⁾. 진동 신호의 에너지 크기는 기계의 상태와 직접적인 상관관계가 있어 에너지를 통해 기계의 상태를 평가할 수 있지만 고장의 기준이 되는 명확한 임계값(threshold)을 부품마다 정의해야 하여 기계의 상태 진단은 제한적인 상황에서 추출된 파라미터들의 비교에 의해서 가능하다. 이러한 진동 신호에는 각각의 고장 성분

† 교신저자; 정희원, 울산대학교 전기공학부
E-mail : upchong@ulsan.ac.kr
Tel : (052)259-2220, Fax : (052)258-1687
* 울산대학교 전기공학부

들이 포함되어 있지만 고장의 특징을 반영한 파라미터들은 대부분 숨겨져 있기 때문에 취득 데이터를 고장진단에 직접적으로 이용하기에 어려움이 있다. 신호의 변조(signal modulation), 잡음(noise), 높은 공진주파수(high frequency resonance)와 같이 취득된 신호를 비결정적(non-deterministic)이고 비정상적(non-stationary)로 만드는 환경 또한 고장진단을 어렵게 만드는 요소이다. 그러므로 취득된 신호로부터 고장의 특징을 정확하게 추출하는 방법과 이를 효과적으로 분류하는 기술이 고장진단 시스템에 있어 매우 중요하다⁽¹⁻³⁾.

초기에는 규칙 기반 전문가 시스템(rule-based expert systems)기반⁽⁴⁾과 데이터베이스 기반 고장진단 시스템⁽⁵⁾이 제안되었지만 고정적 규칙으로 인한 시스템 확장의 어려움⁽⁶⁾과 데이터베이스 선정과 기준이 되는 임계값 설정과 같은 제한점을 야기하였다. 이러한 제한 사항을 해결하기 위해 인공 신경망 모델을 고장진단 시스템에 적용하는 연구가 진행되기 시작하였다. 신경회로망의 장점은 학습을 통해 최적화된 분류 모델을 만들어 전문가 시스템의 단점을 극복 할 수 있다는 것과 학습이 완료된 후에는 계산속도가 매우 빠르기 때문에 실시간 시스템에 적용 시킬 수 있다는 것이다^(5,7). 이 논문에서는 주어진 각기 다른 고장 데이터를 효과적으로 분류하는 것이 목적이기 때문에 교사 학습(supervised learning)이 적절하다고 판단하였고 MLP 신경회로망을 사용하였다.

실질적으로 산업현장에서 회전기기의 초기 고장은 대부분 급작스럽게 발생하므로 기기의 부품별 상태 신호는 상당히 비정상적(non-stationary)이고 신호의 대부분의 에너지가 주파수 영역에서의 피크 지점에 몰려있다는 특징이 있다. 단순히 시간분석과 주파수 분석만으로는 짧은 순간에 일어날 수 있는 고장신호의 특징을 충분히 잡아내기 어렵다. 그러므로 신호의 pole을 추정하면서 매우 짧은 시간에 높은 해상도를 가지는 파라미터 기반의 AR(auto-regressive) 모델이 고장 신호의 특징벡터 추출이 용이하여 고장진단 시스템에 적합하다⁽⁸⁻¹¹⁾.

이 논문은 AR 모델을 기반으로 하여 입력 노이즈를 고려하지 않은 LPC(linear predictive coding) 분석과 입력과 관측 노이즈를 모두 고려한 EIV(errors-in variables) 방법으로부터 추출한 계수를

신경회로망의 입력 특징벡터로 제안한다. 또한 제안한 특징 벡터의 적절성을 판단하기 위하여 각기 다른 유도전동기에서 취득한 사운드, 진동, 전류 신호로부터 특징 벡터를 추출하였고 차수에 따른 각각의 분류 결과와 학습 오차의 정도에 따라 적합한 특징 벡터를 판단하였다.

이 논문의 구성은 다음과 같다. 2장에서는 신호 처리 기술을 이용하여 특징벡터를 추출하는 기존의 연구에 대해 소개한다. 3장에서는 전체적인 고장진단 시스템을 소개한다. 고장진단에 사용될 사운드, 진동, 전류 신호와 앞서 언급한 제안한 특징 추출 알고리즘에 대해서 설명한다. 또한 MLP 신경회로망에 대한 설명과 구성방법에 대해서 설명한다. 4장은 진동, 사운드, 전류 신호에 대한 고장진단 결과에 대해 고찰한 후, 마지막으로 결론과 향후 과제에 대해서 요약한다.

2. 기존연구

기계 고장진단 및 예측 시스템에서 특징을 추출하기 위해서는 취득 신호를 분석하는 신호처리 기술이 선행되어야 한다⁽⁶⁾. 실질적으로 산업현장에서 회전기기의 초기 고장은 대부분 급작스럽게 발생함과 동시에 기기의 부품별 상태 신호는 상당히 비정상적(non-stationary)인 환경에 놓여있다. 그러므로 근래에는 년-파라미터(non-parametric)기반인 STFT(short-time Fourier transform), Wigner-Ville distribution(WVD), Choi-Williams distribution(CWD), 웨이블릿 변환과 같은 시간-주파수 분석을 이용한 응용기술들이 고장진단 시스템의 신호분석에 적합하다는 연구결과를 보였다⁽¹²⁾.

년-파라미터(non-parametric)기반 시간-주파수 분석 기법은 비정상적(non-stationary)인 상태의 신호 분석에는 적합하나 다음과 같은 문제점을 가지고 있다. STFT는 고정적인 샘플링 포인트 개수로 인한 해상도 저하와 해상도가 윈도우의 종류 따라 의존하는 문제점을 가진다. 또한 WVD와 CWD는 신호가 여러 성분으로 이루어진 경우 cross-term에 의하여 성능에 상당한 영향을 미친다. 웨이블릿 기반 고장진단 시스템이 최근에 많이 제안되었지만 그럼에도 불구하고 웨이블릿 변환은 상대적으로 강한 주파수 성분만을 보상하기 때문에 고주파 성

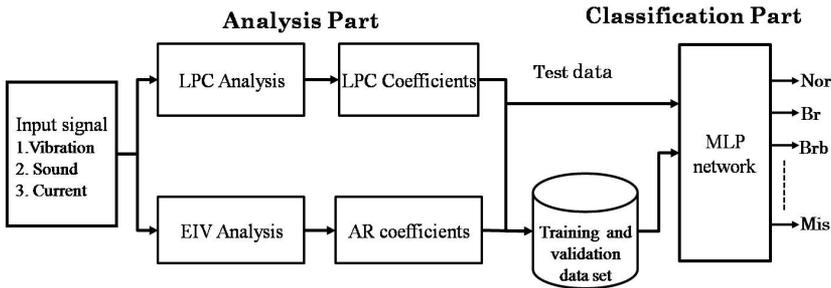


Fig. 1 Proposed fault diagnosis system

분으로 갈수록 심각한 오류가 발생한다는 연구를 보였다⁽⁸⁾.

이에 반해 파라미터 기반의 시불변 계수(time invariant coefficients)를 이용하는 시계열 모델링(AR, MA, ARMA)은 매우 짧은 시간동안 변화하는 주파수를 감지하는 고시간 분해능(high temporal resolution)을 특징으로 하여 초기단계에 고장을 진단할 수 있는 장점을 가진다. 특히 AR 모델은 알고리즘의 단순함으로 인한 연산속도 측면에서의 장점과 파워스펙트럼에서의 피크치 추정에 적합하여 고장진단 시스템에 적용한 연구가 진행되었다^(9,10).

기존 AR 기반 고장진단 시스템은 AR 모델의 잔여신호를 응용한 고장별 특징벡터 추출 알고리즘을 제안하였다⁽¹¹⁾. 잔여신호는 노이즈 환경에서의 안정성을 가지고 있지만 여전히 각 고장간의 잔여신호의 임계값 설정의 문제를 남기고 있다. 이 논문은 기존의 특징벡터 설정의 모호성을 극복함과 동시에 진단율도 높이기 위하여 EIV(error-in variables) 방법을 이용한 AR계수를 특징벡터로 제안하였고 신경회로망 기반 고장진단 시스템의 정량적 데이터베이스를 구축할 수 있게 하였다. 또한 기존의 입력 노이즈를 고려하지 않은 LPC(linear predictive coding) 방법과 비교 분석하여 노이즈에 대한 강인한 정도를 평가하였다.

3. 제안한 고장진단 시스템

이 논문에서의 전체적인 고장진단 절차는 Fig. 1과 같다. 신경회로망 기반의 진단 시스템에 적절한 특징벡터를 선정하기 위하여 각기 다른 유도전동기로부터 사운드, 진동, 전류 신호를 취득하였고 LPC 분석과 EIV 방법으로부터 추출한 계수를

MLP 신경회로망의 입력 특징벡터로 제안하고 결과를 비교 분석하였다.

3.1 실험 데이터

(1) 사운드

모터 회전수를 달리하여(500, 1000, 2000, 3000 RPM) 서로 다른 고장에 대한 데이터를 취득하였다. 취득 데이터의 샘플링 주파수는 25.6 kHz, 데이터의 종류는 정상(normal, Nor), 베어링 결함(faulty bearing, Fbr), 볼트 불균형(bolt unbalance, Bo), 정렬불량(misalignment, Mis), 베어링 불평형(bearing unbalance, Un)으로 모두 5가지이다^(13,14). 각각의 회전수에 대하여 고속 푸리에 변환(FFT)과 Wigner 방법으로 분석한 결과 2000 RPM에서 취득한 데이터가 고장 유형별로 가장 두드러진 특성을 나타내었다⁽¹³⁾. 이 논문에서는 2000 RPM의 데이터를 이용하였고 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 1초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다.

(2) 진동

진동 데이터는 6개의 유도전동기(0.5 kW, 60 Hz, 4극)에 각각 정상 데이터와, 정렬불량, 베어링 결함, 회전봉 파손(broken rotor bar, Brb), 굽은 회전축(bowed rotor shaft, Br), 회전자 불평형(rotor unbalance, Run) 고장 데이터를 인위적으로 발생시켜 취득한 데이터이다⁽¹⁵⁾. 샘플링 주파수는 8 kHz이며, 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 2.1333초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용하였다.

(3) 전류

실험에 사용된 전류 데이터는 MCSA(motor current signature analysis) 시뮬레이터를 이용하여 인위적으로 고장을 발생시킨 후 데이터를 취득 하였다. 취득한 데이터는 정상, 정렬 불량, 베어링 결함, 회전봉 불균형, 굽은 회전축, 회전자 불평형 6 가지이다. 샘플링 주파수는 24 kHz이며, 학습과 테스트를 위한 충분한 데이터 집합(data set)을 만들기 위하여 취득 데이터를 0.5초 길이의 프레임으로 나누어 각 상태별로 100개의 데이터를 추출하여 사용 하였다.

3.2 LPC(linear predictive coding) 분석

LPC는 현재 과형은 과거 값과 가중치의 곱을 합하여 추정될 수 있다는 것을 가정으로 한다. 전달 특성 필터는 all-pole 모델을 사용하여 식(1)과 같이 차분 방정식의 형태로 나타낼 수 있다. 여기서 $x(n)$ 과 $s(n)$ 은 입력 신호와 출력 신호이고, a_j 와 p 는 전달 특성 필터 차수와 pole이며, G 는 입력 신호의 가중치이다. 현재 신호와 과거 신호의 누적된 추정치의 오차는 식(2)와 같다. 여기서 식(1)의 a_j 에 대한 추정치인 α_j 를 LPC 계수라고 정의한다⁽¹⁶⁾.

$$s(n) = Gx(n) + \sum_{j=1}^p a_j s(n-j) \quad (1)$$

$$e(n) = s(n) - \sum_{j=1}^p \alpha_j s(n-j) \quad (2)$$

식(3)은 예측 오차 $e(n)$ 에 대한 MSE(mean square error), J 이며 J 를 최소로 하는 LPC 계수 α_j 를 찾아내기 위하여 식(4)의 과정과 같이 α_j 에 대해서 편미분하여 0이 되는 p 개의 선형 연립방정식(5)를 얻을 수 있다.

$$J = E[e^2(n)] = E\left[\left\{s(n) - \sum_{j=1}^p \alpha_j s(n-j)\right\}^2\right] \quad (3)$$

$$\frac{\partial J}{\partial \alpha_j} = E\left[\left\{s(n) - \sum_{j=1}^p \alpha_j s(n-j)\right\} s(n-j)\right] = 0, \quad \text{for } i = 1 \dots p \quad (4)$$

$$\sum_{j=1}^p \alpha_j \phi_n(i, j) = \phi_n(i, 0), \quad \text{for } i = 1 \dots p \quad (5)$$

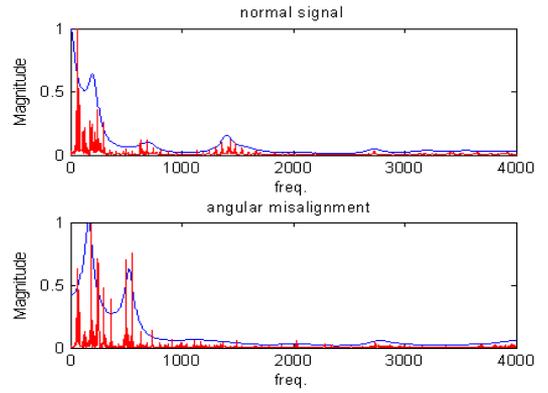


Fig. 2 LPC Envelop and Spectrum for Vibration signals

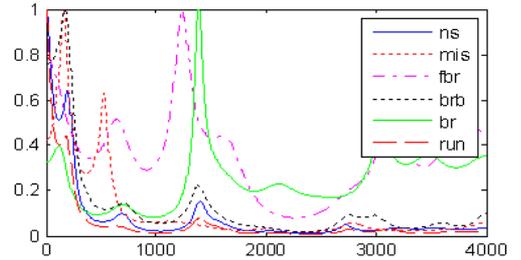


Fig. 3 LPC Envelop for each faulty case

여기서,

$$\phi_n(i, j) = E\{s(n-i)s(n-j)\}. \quad (6)$$

여기서 $\phi_n(i, j)$ 는 LPC 방정식이라 부르며 이 논문은 이 방정식의 해인 p 개의 α_j 구하기 위하여 Durbin 알고리즘을 이용하였다.

3.3 LPC 분석을 이용한 특징벡터 추출

LPC 분석을 이용한 고장진단시스템의 적합성을 위하여 진동신호에 대한 LPC 필터의 주파수 특성과 스펙트럼을 유사성을 Fig. 2에서 비교하였다. Fig. 2에서 알 수 있듯이 LPC Envelop이 스펙트럼과 유사하여 pole을 잘 추정하였다는 결과를 얻을 수 있다. Fig. 3은 고장 신호별 LPC envelop을 나타내었고 각각 고장 종류별 추정된 pole의 위치가 각각 다르게 나타나서 LPC 계수가 고장 신호별 대표성을 가짐을 알 수 있다. Table 1은 사운드, 진동, 전류의 입력신호들 중에서 대표적으로 진동 신호에 대한 특징 벡터로 12개의 LPC 계수를 나타낸 것이다.

Table 1 LPC coefficients of vibration signals

Coeff (ak)	Br	Brb	Fbr	Nor	Mis	Run
1	0.3324	-0.7790	-0.1999	-0.8031	-1.1967	-0.7700
2	0.0263	-0.3104	-0.5509	-0.3327	-0.0647	-0.3303
3	0.1121	0.2480	0.5640	0.2569	0.4335	0.1056
4	-0.0842	0.0831	0.2362	0.0197	0.2162	0.0499
5	-0.4638	-0.4163	0.6905	-0.4438	-0.4356	-0.4440
6	-0.3489	-0.2006	-0.0393	-0.0147	0.0007	-0.0051
7	-0.1860	0.5903	0.4410	0.4160	0.3673	0.4870
8	-0.0811	-0.0696	-0.2843	0.1406	-0.1662	0.0368
9	0.1716	-0.1140	-0.1345	-0.1925	-0.1172	0.0315
10	0.1345	0.0697	0.2487	0.0068	0.1380	-0.0610
11	-0.0491	-0.0281	-0.0569	0.0207	-0.6198	-0.0373
12	-0.0394	0.0324	-0.1318	-0.0140	-0.0080	-0.0272

3.4 EIV(errors-in variables) 분석

시스템 식별(system identification)에서 오차와 노이즈를 입력과 출력에 모두 나타내는 것을 “errors-in variables”(EIV) 모델이라고 하며 Fig. 4는 EIV scheme을 나타낸 것이다⁽¹⁷⁾.

EIV를 이용한 예측 여러 알고리즘이 제안 되었지만 이 논문에 적용된 EIV 분석 특징은 다음 세 가지로 요약 할 수 있다⁽¹⁸⁾.

- ① Frisch scheme의 해집합의 성질을 이용
- ② 시불변 동적 시스템의 shift 성질을 이용
- ③ 자기 상관행렬의 양의 정 부호 행렬(positive definite matrix)을 만족시키는 AR 계수, 입력 과 측정 노이즈 분산을 동시에 추정

Frisch scheme와 shift 성질을 이용하여 노이즈 평면에서의 노이즈 분산이 최소가 되는 지점을 찾을 수 있다. 즉, 노이즈 환경에서 예측한 AR 계수들의 오차를 최소화 시킬 수 있어 노이즈에 보다 강인한 특징벡터를 추출할 수 있다. 이하에 N개의 유한 데이터에서 EIV 모델기반 AR 계수 예측 알고리즘에 대해 간략히 기술하였다⁽¹⁹⁾.

단계 1: $k=p+1, p+2$ 에 대한 공분산 행렬 R_y^k 를 계산한다. 여기서 $R_y^k \in R^{(k+1) \times (k+1)}$ 인 공분산 행렬은 다음과 같이 정의 한다.

$$R_y^k = \lim_{N \rightarrow \infty} \left[\frac{1}{N-k} (H_y^k)^T H_y^k \right] \quad (7)$$

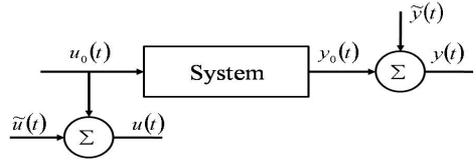


Fig. 4 EIV scheme for AR estimation

H_y^k 는 신호 $y = \{y[0], y[1], \dots, y[N-1]\}$ 로부터 생성된 Hankel 행렬이고 다음과 같이 정의한다.

$$H_y^k = \begin{bmatrix} y[0] & y[1] & \dots & y[k] \\ y[1] & y[2] & \dots & y[k+1] \\ \vdots & \vdots & \ddots & \vdots \\ y[N-k+1] & y[N-k] & \dots & y[N-1] \end{bmatrix} \quad (8)$$

단계 2: 노이즈 평면 R2에서 생성점(generic point) $A_i = (\alpha_i, \beta_i)$ 은 $i=1, 2$ 부터 시작한다. 여기서 α_i 와 β_i 값은 σ_x^2 와 σ_w^2 이다. σ_x^2 은 신호 x 에 대한 분산이고 $\sigma_x^2 = \sigma_u^2 + \sigma_w^2$ 의 식으로 나타낼 수 있다.

생성점 $A_i = (\alpha_i, \beta_i)$ 는 A_1 과 A_2 에 대해서 $k=p+1, p+2$ 일 때 $\alpha_i \geq \beta_i, \sum_y^k (\sigma_u^2, \sigma_w^2) \geq 0$ 과 $\frac{\beta_1}{\alpha_1} = \frac{\beta_2}{\alpha_2}$ 을 만족 시키는 파라미터이다.

단계 3: $k=p+1, p+2$ 에 대하여, 식 (9)를 계산한다.

$$\sum_y^k (A_1) = R_y^k - \text{diag} \left[\underbrace{\beta_1, \dots, \beta_1}_{k}, \alpha_1 \right] \quad (9)$$

단계 4: $k=p+1$ 에 대해서 $\sum_y^k (A_1) a(A_1) = 0$ 이 됨에 의하여 AR 계수 벡터, $a = [a_p, a_{p-1}, \dots, a_1, 1]^T$ 를 구한다. 여기서 $a(A_1)$ 은 $\sum_y^k (A_1) a(A_1) = 0$ 로부터 얻어진 AR 계수 벡터를 의미한다.

단계 5: $\Theta = [0, a^T]^T$ 일 때 식 (10)에 주어진 SR 비용함수를 계산한다.

$$J_{SR}(A_1, A_2) = \left\| \sum_y^{p+2} \Theta \right\|^2 = \Theta^T \left(\sum_y^{p+2} \right) \sum_y^{p+2} \Theta \quad (10)$$

단계 6: SR 비용함수, $J_{SR}(A_1, A_2)$ 를 최소화하는 분산 $A^* = (\alpha^*, \beta^*)$ 를 탐색한다.

단계 7: $A^* = (\alpha^*, \beta^*)$ 와 일치하는 AR 계수 벡터, $a = [a_p, a_{p-1}, \dots, a_1, 1]^T$ 를 구한다.

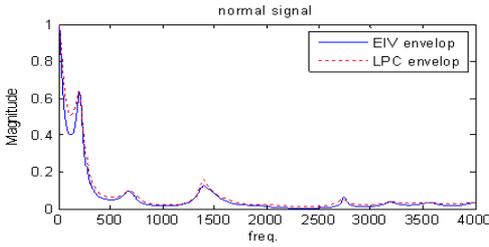


Fig. 5 Comparison EIV envelop to LPC envelop

Table 2 AR coefficients of vibration by EIV analysis

Coeff (ak)	Br	Brb	Fbr	Nor	Mis	Run
1	-0.2756	-0.9353	-1.3912	-1.3949	0.6555	-0.2196
2	-0.8383	-0.5248	-0.0728	0.0256	0.2697	-1.0213
3	0.90192	0.70511	0.8993	0.5923	0.1249	0.0447
4	0.44512	0.17041	0.1559	-0.1418	-0.2864	0.5805
5	-1.2711	-0.9465	-1.026	0.0884	-0.8572	-0.6404
6	0.04160	0.01903	0.2159	-0.4607	-0.8457	-0.3399
7	1.06286	0.91795	0.8904	0.7790	-0.5688	0.6932
8	-0.5761	-0.0602	-0.5148	-0.5430	-0.2376	0.4363
9	-0.5116	-0.6308	-0.4678	0.0553	0.2463	-0.4841
10	0.64575	0.28879	0.4965	0.3185	0.4416	-0.2699
11	0.02272	0.28945	0.0425	-0.5397	0.3386	0.2187
12	-0.3982	-0.2534	-0.1595	0.2829	0.2118	0.0589

Table 3 Parameters of MLP neural network

Parameters	Configuration
Learning algorithm	Scaled conjugate gradients
Learning rate	0.05
Transfer function	Tangent sigmoid
Training method	Batch training
Performance function	MSE(mean square errors)

3.5 EIV 분석을 이용한 특징벡터 추출

EIV 분석을 이용한 고장진단시스템의 적합성을 위하여 진동신호에 대하여 EIV와 LPC 방법으로 추정된 AR 필터의 주파수 특성을 Fig. 5에서 비교하였다. Fig. 5에서 알 수 있듯이 EIV 스펙트럼과 LPC 스펙트럼이 유사하여 EIV 분석을 통한 AR계수 역시 고장 신호별 대표성을 가진다. EIV 차수를 12로 하여 고장별 진동 신호에 대한 AR 특징 벡터를 Table 2에 나타내었다.

3.6 MLP 신경회로망 구성

고장진단 시스템에 사용될 MLP 신경회로망은 교사학습(supervised learning)의 한 종류로 음성인식, 단백질 구조분석, 수중음파의 분석 등 광범위한 분야에 응용 되어왔으며 다른 신경회로망 분류기와 비교 했을 때에 상대적으로 메모리 요구량이 적은 장점을 가지고 있다⁷⁾.

이 논문에서는 신경회로망의 크기를 최적화하기 위해 은닉 층의 개수를 범용 근사화 이론(universal approximation)에 따라 1개로 설정하였다. MLP 신경망을 구성하는데 있어서 은닉 층의 뉴런 개수를 10개부터 3개까지 줄여가면서 실험하였고 그 결과 은닉 층의 뉴런 개수가 5개 이하부터는 분류 성능이 점점 줄어드는 것을 확인하였다. 그러므로 이 논문에서는 신경회로망의 크기의 최적화와 고장 분류 성능의 극대화를 동시에 만족시키는 은닉 층의 뉴런 개수를 6개로 결정하였다. 학습 알고리즘은 비교적 성능이 뛰어나다고 알려진 scaled conjugated gradient 알고리즘을 이용하였고 정확한 결과를 얻었다. 학습 정도는 학습 횟수(epochs)보다 표준오차 평균(MSE: mean squared error)를 우선으로 하여 학습 임계값을 1.00E-05로 정하였다. 또한 300번 이상의 학습에도 불구하고 수렴하지 못하면 자동으로 학습 종료를 시켰다. 분석에 사용된 MLP 신경회로망의 설정 값은 Table 3과 같다.

4. 실험 결과

제안한 알고리즘에 의해 추출된 각각의 특징 벡터의 고장 분류 성능을 판단하기 위해 각기 다른 전동기로부터 취득한 사운드, 진동, 전류 신호를 사용하였다. 실험 조건으로 학습과 테스트를 위한 데이터 설정은 특징 추출 알고리즘으로부터 추출한 특징 벡터의 70%를 학습 데이터로 30%를 테스트 데이터로 나누었고 최상의 학습 모델 선정과 학습 과정에서 조기 중단(early stopping)을 결정하기 위해 학습 데이터 집합의 하위 집합인 모델을 검증하는 데이터 집합을 나누었다. 제안한 시스템에서는 Kearns의 권장사항으로 학습 데이터의 20%를 검증을 위한 데이터로 나누었다. 논문에서 적용한 MLP 신경회로망 설계 및 학습은 MathWorks사 Matlab 7.6.0의 Neural Network Toolbox를 이용하였다. 이

Table 4 Fault classification rate of changing AR order(unit : %)

AR order	AR modeling					
	LPC			EIV		
	Sound	Vibration	Current	Sound	Vibration	Current
20	100	100	100	100	100	100
...	100	100	100	100	100	100
12	100	100	100	98	100	100
10	87	85	95	95	98	100
8	x	x	83	93	94	98

실험은 아래의 세 가지 방향으로 진행하였다.

- ① AR 차수의 변화에 따른 LPC와 EIV의 분류율을 비교
- ② AR 차수를 고정시켜 사운드, 진동, 전류 신호에 대한 성능 비교
- ③ 테스트 데이터에 노이즈를 추가하여 LPC와 EIV의 고장 분류율을 비교

AR 차수 변화에 따른 사운드, 진동, 전류 데이터별 고장 분류 결과를 Table 4에 나타내었다. 12차까지는 LPC와 EIV 모두 우수한 결과 보였지만 차수가 줄어들수록 LPC방법에서 분류 성능이 급격하게 줄어드는 것을 확인할 수 있다. 특히 차수가 8 이하일 때 사운드와 진동 데이터에 대해서 학습 데이터에 따라서 학습시 수렴을 하지 못하는 경우가 발생하여 불안정한 결과를 나타내었다. 인공지능망기반 고장진단 시스템의 이슈는 특징벡터 알고리즘으로 인한 보다 적은 특징값으로 안정적으로 높은 분류율을 나타내는 것이다. 그러므로 EIV 분석 방법은 높은 차수와 적은 차수에도 높은 고장분류 성능을 유지하여 안정적인 진단시스템 구축할 수 있고 시스템을 간소화 시킬 수 있어 실시간 시스템에 적합한 것으로 판단된다.

각기 다른 환경에서 취득한 사운드, 진동, 전류 데이터에 대한 제안 시스템의 성능을 알아보기 위하여 EIV 계수를 12차로 하여 각각의 데이터에 대한 학습과 테스트 과정에서의 수렴도를 계산하였다. Figs. 6~8은 사운드, 진동, 전류 데이터에 대한 각각의 학습 및 테스트 성능 결과를 보여준다. Figs. 6~8은 제안 시스템이 사운드, 진동, 전류 데이터에 모두 우수한 성능으로 수렴하여 안정적으로 고장을 분류할 수 있게 한다. 특히 Fig. 8의 결과와 같이

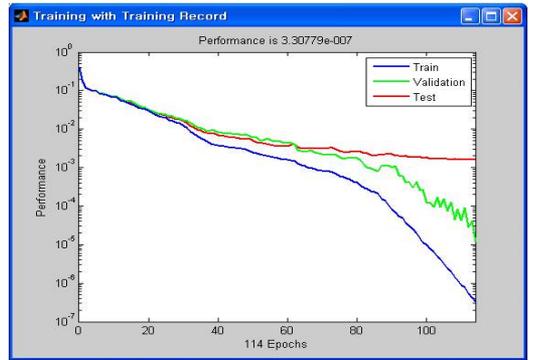


Fig. 6 Training performance for vibration data

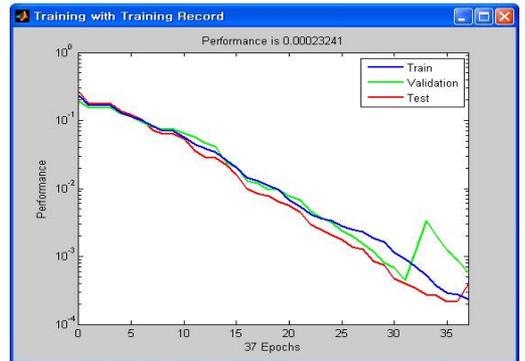


Fig. 7 Training performance for sound data

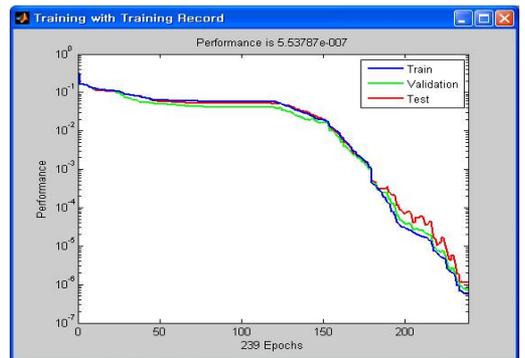


Fig. 8 Training performance for current data

전류 데이터의 경우 학습오차가 0.53×10^{-7} 으로 가장 낮았으며 테스트 오차도 학습 오차에 근접하여 안정적인 성능을 보여 제안 시스템이 노이즈에 따라 성능에 영향을 받는 것으로 판단된다. 이는 취득된 사운드, 진동, 전류 데이터 중에서 전류 데이터에 노이즈가 포함될 가능성이 낮기 때문이다.

Table 5 Errors rates of classification after adding noise(unit : %)

SNR (%)	AR modeling			
	LPC		EIV	
	Sound	Vibration	Sound	Vibration
40	0	0	0	0
30	0	0	0	0
20	1	6	0	0
10	9	12	2	6
5	18	23	6	8

전류 데이터와 달리 사운드와 진동 데이터를 실제 산업현장에서 취득 시 주변 노이즈가 포함될 가능성이 크다. 따라서 이 논문에서는 취득한 각 고장 데이터의 테스트 집합에 화이트 가우시안 노이즈를 추가하여 고장 분류 성능을 평가하는 실험을 하였다. 그리하여 원 신호와 노이즈를 추가한 신호와의 SNR을 40, 30, 20, 10, 5 dB로 변경시키면서 제안한 특징벡터들이 추가된 노이즈에 얼마나 강인한지 평가하였다. Table 5는 노이즈가 추가된 사운드와 진동 데이터에 대한 특징 벡터들의 식 (11)에 의한 고장 분류 오차율을 나타내었다.

$$Error\ rate = 100 - \frac{Decton\ data\ set}{The\ number\ of\ whole\ data\ set} \times 100 \quad (11)$$

5. 결 론

이 논문은 신경회로망 기반 고장진단 시스템에서 AR 모델을 기반으로 기존에 적용하지 않았던 LPC 분석과 EIV 분석으로부터 추출한 계수를 신경회로망의 입력 특징벡터로 제안한다. 또한 제안한 특징 벡터의 적절성을 판단하기 위하여 각기 다른 유도 전동기에서 취득한 사운드, 진동, 전류 신호로부터 세 종류의 특징 벡터를 추출하였고 차수에 따른 각각의 분류 결과와 학습 오차의 정도에 따라 적합한 특징 벡터를 판단하였다.

진단시스템에 적용된 특징 벡터는 적은 파라미터를 가지고도 사운드, 진동, 전류신호에 대해 모두 높은 진단율을 보였다. 특히 전류 신호에서 특징 벡터를 안정적으로 추출 하여 AR 모델이 전류신호에

적합하였다. 입·출력 노이즈를 고려한 EIV의 경우 LPC 보다 적은 차수와 노이즈가 섞여있는 환경에서도 안정적인 성능을 유지하여 LPC 분석 보다 강한 특징벡터로 활용 될 수 있다.

이 연구의 향후 과제는 제안한 고장진단 시스템을 실시간 시스템으로 발전시켜 실제 산업현장에 적용시켜야 할 것이다. 또한 이 논문에서 다룬 고장진단 시스템은 한 가지 고장이 발생했을 경우에 대해서만 진단하는 것을 기본전제로 한다. 그러므로 실제 현장에서 여러 고장이 복합적으로 일어나는 환경에 적용하기에는 많은 어려움이 있다. 향후에는 복합적으로 발생하는 고장에 대해서도 원인을 알아 낼 수 있는 연구가 이루어져야 할 것이다.

후 기

이 논문은 2011년도 울산대학교 교내연구비 지원을 받아 수행된 연구임.

참 고 문 헌

- (1) Crupi, V., Guglielmino, E. and Milazzo, G., 2004, Neural-network-based System for Novel Fault Detection in Rotating Machinery, Journal of Vibration and Control, Vol. 10, pp. 1137~1150.
- (2) Li, F., Meng, G., Ye, L. and Chen, P., 2008, 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.
- (3) Li, F., Meng, G., Ye, L. and Chen, P., 2005, Feature Extraction with Discrete Wavelet Transform for Drill Wear Monitoring, Journal of Vibration and Control, Vol. 11, No. 11, pp. 1375~1390.
- (4) Goode, P. V. and Chow, M.-Y., 1995, Using a Neural/Fuzzy System to Extract Heuristic Knowledge of Incipient Faults in Induction Motors: Part I—Methodology, IEEE Transactions On Industrial Electronics, Vol. 42, No. 2, pp. 131~138.
- (5) Chong, U.-P., Cho, S.-J. and Lee, J.-Y., 2006, Fault Diagnosis for Rotating Machine Using Feature Extraction and Minimum Detection Error Algorithm,

Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 16, No. 1, pp. 23~33.

(6) Sanz, J., Perera, R. and Huerta, C., 2007, Fault Diagnosis of Rotating Machinery Based on Auto-associative Neural Networks and Wavelet Transforms, Journal of Sound and Vibration, pp. 981~999.

(7) Lippmann, R. P., 1989, Pattern Classification Using Neural Network, IEEE Communication Magazine.

(8) Baillie, D. C. and Mathew, J., 1995, A Comparison of Autoregressive Modeling Techniques for Fault Diagnosis of Rolling Element Bearings, Mechanical Systems and Signal Processing, Vol. 10, No. 1, pp. 1~17.

(9) Thanagasundram, S. and Schlindwein, F. S., 2006, Autoregressive based Diagnostics Scheme for Detection of Bearing Faults, Proceedings of ISMA2006 Noise and Vibration Engineering Conference, pp. 3531~3546.

(10) Zhan, Y. M. and Jardine, A. K. S., 2005, Adaptive Autoregressive Modeling of Non-stationary Vibration Signals under Distinct Gear States. Part 1: Modeling, Journal of Sound and Vibration, Vol. 286, No. 3, pp. 429~450.

(11) Lee, S.-S., Cho, S.-J. and Chong, U.-P., 2005, Fault Diagnosis System of Rotating Machines Using LPC Residual Signal Energy, Journal of the Institute of Signal Processing and Systems, Vol. 6, No. 3, pp. 143~147.

(12) Nelwamondo, F. V., Marwala, T. and Mahola, U., 2006, Early Classifications of Bearing Faults using Hidden Markov Models, Gaussian Mixture Models, Mel-frequency Cepstral Coefficients

and Fractals, International Journal of Innovative Computing, Information and Control, Vol. 2, No. 6, pp. 1281~1299.

(13) Tuan, D. V., 2009, Fault Detection and Diagnosis for Induction Motors using Local Feature, Variance, Cross-correlation and Wavelet, Ph.D Dissertation in University of Ulsan.

(14) Tuan, D. V., Cho, S.-J. and Chong, U.-P., 2009, Fault Detection and Diagnosis for Induction Motors Using Variance, Cross-correlation and Wavelet, Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 19, No. 7, pp. 726~735.

(15) Yang, B.-S., Kim, K. J. and Han, T., 2004, Fault Diagnosis of Induction Motors Using Data Fusion of Vibration and Current Signal, Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 14, No. 11, pp. 1091~1100.

(16) Markel, J. D. and Gray Jr., A. H., 1976, Linear Prediction of Speech, Springer-Verlag, Berlin Heidelberg, New York.

(17) Soderstrom, T., 2007, Errors-in-variables Methods in System Identification, Automata, Vol. 43, No. 6, pp. 290~294.

(18) Diversi, R., Soverini, U. and Guidorzi, R., 2005, A New Estimation Approach for AR Models in Presence of Noise, in Proc. Preprints 16th IFAC World Congr., pp. 290~294.

(19) Bobillet, W., Diversi, R., Grivel, E., Guidorzi, R., Najim, M. and Soverini, U., 2007, Speech Enhancement Combining Optimal Smoothing and Errors-in-variables Identification of Noisy AR Processes, IEEE Transactions on Signal Processing, Vol. 55, No. 12, pp. 5564~5578.