

신경회로망 독립성분해석을 이용한 음향센서 기반 대전력기기의 고장진단 알고리즘

論 文

57-5-23

Acoustic Sensors based Fault Diagnosis Algorithm for Large-scaled Power Machines using Neural Independent Component Analysis

曹賢哲* · 李晉宇* · 李榮珍** · 李權純†

(Hyun-Cheol Cho · Jin-Woo Lee · Young-Jin Lee · Kwon-Soon Lee)

Abstract - We present a novel fault diagnosis methodology using acoustic sensor systems and neural independent component analysis for large-scaled power machines. Acoustic sensors are carried out to measure sounds generated from power machines whose signal is used to determine whether fault is occurred or not. Acoustic measurements are independently mixed and deteriorated from original source signals. We propose a demixing algorithm against such mixed signals by means of independent component analysis which is achieved based on information theory and higher-order statistics to derive learning mechanism.

Key Words : Fault diagnosis, Acoustic sensors, Large-scaled power machines, ICA, Neural networks

1. 서 론

최근 전력기기의 대형화, 고효율화의 추세가 이어져 오고 있으며 고장으로 인해 발생하는 경제적 손실을 사전에 줄이기 위한 고장진단 및 모니터링 시스템에 대한 연구가 활발한 진행 중에 있다. 고장진단 시스템은 고급 제어응용의 한 분야로서 수년전 제어공학자들로부터 많은 연구가 이어져 오고 있으며 최근 성공적인 적용사례가 발표되고 있다.

[1]에서 Salat와 Osowski는 패턴분류 알고리즘의 일종인 support vector machine[2] 기법을 이용하여 고전압 전력변환 시스템의 고장위치를 검출하는 새로운 알고리즘을 개발하여 200-km의 전력선에 적용하였다. Atkinson et. al.은 고장허용 알고리즘을 제안하여 엔진의 연료펌프에 부착된 전자모터의 모니터링 시스템을 구축하였으며, 고정자와 회전자의 기계적 손실을 감소하기 위한 효율적인 설계방식을 제안하였다[3]. Murphy et. al.은 [4]에서 기계학습(machine learning) 알고리즘을 이용하여 전력전자 인버터의 고장 발견 및 위치검출 모니터링 시스템을 제안하였다. 인버터에 발생하는 여러 가지 가능한 고장들을 신경회로망에 학습하여 동작점이 넓은 강인한 고장진단 시스템을 구축하였다. [5]에서 Mohamed et. al. 또한 신경회로망 기술을 적용한 고장진단 알고리즘을 개발하였으며 산업용 변압기의 고장형태 및 상(phase)의 이상유무를 모니터링하였다. 보다 최근에는 저전력 동기기를 위한 고장진단 알고리즘이 연구되었으며 주로 선간전류의 스펙트럼 분석을 통해 고장의 검출뿐만

아니라 고장위치를 정확히 분석하는 고급 알고리즘도 발표되고 있다[6].

현재까지 다양한 고장진단 기법이 소개되고 있으며, 그 중 모델기반 고장진단 알고리즘이 가장 많이 적용되고 있다 [7]. 이러한 고장진단 알고리즘은 실제 시스템의 동특성에 대하여 해석적 방법을 통해 시스템 모델링을 실시하여, 실시간에서 실 시스템과 모델의 시스템 상태를 비교하여 산출한 편차(residual)를 이용하여 고장유무를 판단한다. 실질적으로 회전기나 시스템 프로세서와 같은 동특성 모델이나 시스템 인과관계 등의 시스템 모델링이 확고하게 구현이 되는 경우 이러한 고장진단 기법은 바람직한 성능을 발휘한다.

반면, 대전력 교류기기와 같은 대규모 시스템의 구성이나 복잡한 기계적 구조를 갖는 시스템의 경우 일반적으로 시스템의 해석적 모델을 산출하기가 어려우며, 특히 오프라인 설계과정에서 예상치 못한 시스템의 불확실성(uncertainty), 섭동(perturbation) 등과 같은 요인들이 실시간에서 발생할 수 있으며 [8], 이러한 현상들은 고장진단 시스템의 성능을 저하시키는 원인이 될 수 있다. 따라서, 시스템의 고장발생을 사전에 방지하지 못하여 막대한 경제적 손실을 초래할 수 있다.

본 논문은 시스템의 상태 또는 출력에 대한 관측값을 이용하는 모델기반 고장진단 기법과 달리, 음향센서를 이용한 새로운 고장진단 방법론을 제안한다. 또한 여러 대의 기기에 대한 음향센서는 예상치 못한 잡음을 포함하므로 이에 대한 독립성분해석(ICA; Independent Component Analysis) [9]을 이용한 신호처리 기법을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서 음향센서 시스템을 이용한 고장진단 기법을 제안한다. 3장에서 신경회로망 ICA를 이용한 음향신호처리에 대하여 그리고 4장에서 컴퓨터 시뮬레이션 및 결과를 서술한다. 마지막으로 결론 및 향후 연구를 5장에 서술한다.

* 正 會 員 : 東亞大學校 電氣工學科 Post-Doc 研究員

** 正 會 員 : 한국폴리텍 航空大學 副教授

† 교신저자, 正會員 : 東亞大學校 電氣工學科 教授

E-mail : kslee@dau.ac.kr

接受日字 : 2007年 11月 7日

最終完了 : 2008年 3月 27日

2. 대전력 기기의 고장진단 시스템

2.1 음향센서기반 고장진단

본 논문에서 제안하는 음향센서 기반 대전력기기의 고장진단 시스템은 대전력 기기의 음향을 감지하여 고장유무를 판단하는 새로운 알고리즘이다. 그림 1은 제안하는 고장진단 알고리즘의 블록선도를 보여준다. 그림 1은 N 개의 대전력 시스템에 대하여 각각의 음향센서가 부착되어 있으며 이 센서로부터 감지된 음향신호를 알고리즘을 통하여 시스템의 고장유무를 판단하게 된다.

일반적으로 실시간 구현에 앞서, 충분한 반복실험을 통하여 정상적으로 동작하는 전력기기의 음향을 측정하여, 기존의 모델기반 기법과 유사한 방법으로, 이 측정신호를 기준신호로 정의한다. 하지만 음향신호는 일반적으로 결정론적 데이터가 아닌 확률성분신호가 대부분이므로, 기존의 결정론적 모델링 기법은 바람직하지 못하다. 다시 말해, 확률신호를 그대로 고장진단 알고리즘에 적용하기 어려우며, 확률론적 기반 고장진단 알고리즘을 적용하기 위하여, 우선 확률신호에 대한 확률분포를 추정하여야 한다.

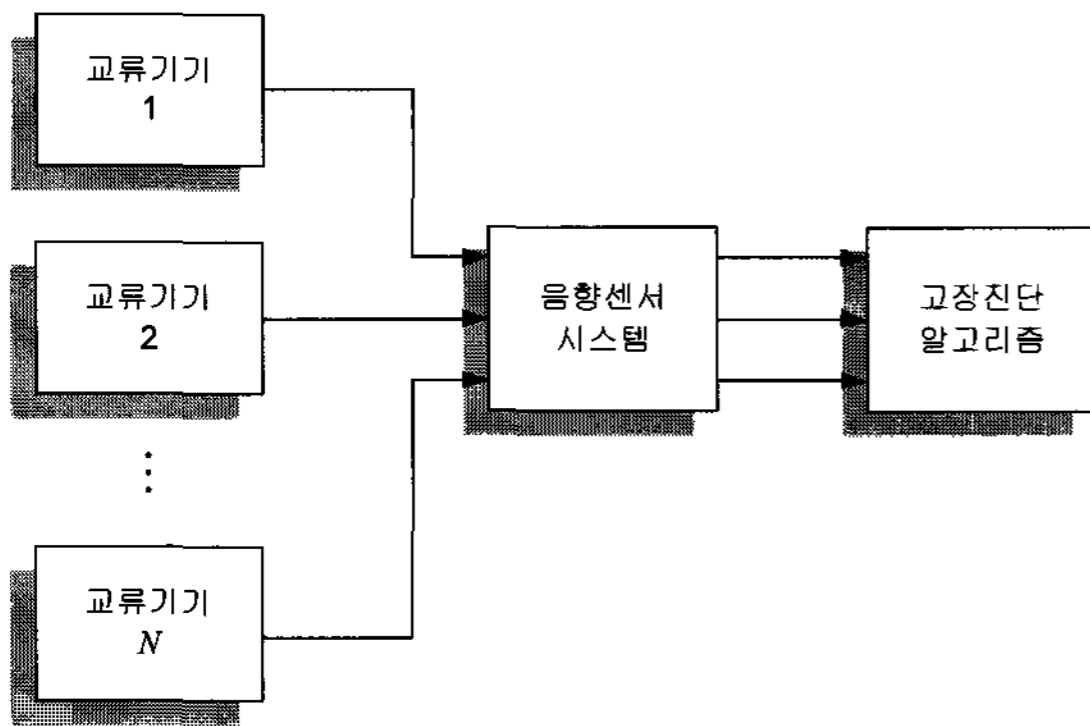


그림 1 음향센서 기반 대전력 기기의 고장진단 시스템
Fig. 1 Fault detection of large-scaled power machines with acoustic sensors

2.2 고장진단의 가설검정

모델기반 고장유무의 판단은 주로 이진 가설검정(binary hypothesis testing)을 이용한 의사결정법(decision making)을 주로 이용하며, 수학적 표현은 다음과 같다.

$$\begin{cases} H_0 : |\gamma| < c \\ H_1 : |\gamma| \geq c \end{cases} \quad (1)$$

여기서 $c > 0$ 이며 γ 는 실제 시스템과 모델사이의 편차를 나타낸다. 식 (1)에서 가설 H_0 는 시스템이 고장이 없는 정상상태를 의미하며, H_1 은 시스템에 고장이 발생한 상태를 나타낸다. 앞서 언급한 음향신호의 경우처럼, 신호의 확률분포를 추정하여 가설검정에 적용하기 위하여 우선 다음과 같은 의사결정을 정의한다.

$$\begin{cases} H_0 : p(x) < c \\ H_1 : p(x) \geq c \end{cases} \quad (2)$$

여기서 x 는 음향신호를 나타내며, 확률 $p(x) \in [0, 1]$ 이므로 $c \in [0, 1]$ 이다. 식 (2)는 식 (1)과 유사한 형태의 가설검정법으로 표현되지만, 식 (2)의 경우 음향신호 x 에 대한 확률값을 적용하여 고장유무를 판단한다. 확률분포함수에 대한 가설검정은 기존의 잘 알려진 Neyman-Pearson 이론을 적용하여 고장진단 알고리즘을 표현할 수 있다.

정리 1(Neyman-Pearson 이론) 주어진 $P_{FA} = \alpha$ 에 대하여

$$P_D = \int_{R_1} p(x; H_1) dx \quad (3)$$

를 최대화하기 위하여, 다음과 같은 관계가 성립되면 식 (2)의 가설검정은 H_1 이 성립된다.

$$L(x) = \frac{p(x; H_1)}{p(x; H_0)} > \gamma \quad (4)$$

여기서

$$P_{FA} = \int_{x: L(x) > \gamma} p(x; H_0) dx = \alpha \quad (5)$$

증명 식 (5)에 대하여 식 (3)의 P_D 를 최대화하기 위하여 라그랑지(Lagrange) 최적화 기법을 이용하면 다음과 같이 전개된다.

$$\begin{aligned} F &= P_D + \lambda(P_{FA} - \alpha) \\ &= \int_{R_1} p(x; H_1) dx + \lambda \left(\int_{R_1} p(x; H_0) dx - \alpha \right) \\ &= \int_{R_1} (p(x; H_1) + \lambda p(x; H_0)) dx - \lambda \alpha \end{aligned} \quad (6)$$

여기서 함수 F 를 최대화하기 위하여 R_1 의 영역에 x 을 포함시키면 다음과 같은 부등식을 얻을 수 있다.

$$p(x; H_1) + \lambda p(x; H_0) > 0 \quad (7)$$

여기서 λ 는 라그랑지 계수를 나타낸다. 식 (7)에서 $p(x; H_1) + \lambda p(x; H_0) = 0$ 일 경우 x 는 R_0 또는 R_1 의 어느 영역에도 포함될 수 있음을 알 수 있다. 하지만 이런 경우의 확률은 0이 되므로 이러한 경우는 고려하지 않는다. 만약 다음과 같은 부등식을 만족하면 H_1 이 선택됨을 알 수 있다.

$$\frac{p(x; H_1)}{p(x; H_0)} > -\lambda \quad (8)$$

여기서 라그랑지 계수 λ 는 이러한 제약조건에서 0보다 작

아야 됨을 알 수가 있다. 간단히, $\gamma = -\lambda$ 로 두면 식 (4)의 관계식을 유도할 수 있다. ■

식 (4)에서 $L(x)$ 를 가능성비율(likelihood ratio)이라 하며 가설 H_1 과 H_0 의 비율로 나타낸다. 이 비율에 대하여 γ 를 비교함으로써 가설검정을 선택하여 고장유무를 판단한다.

2.3 실시간 확률분포 추정

식 (8)의 부등식을 이용하기 위하여 각 신호에 대한 확률분포에 대한 정보를 알아야 한다. 일반적으로 시스템 상태에 대한 확률값을 사전에 아는 것이 어려우며, 이러한 경우 시스템 상태 신호를 수집하여 확률분포 추정 알고리즘을 통해 그 값을 얻을 수가 있다.

우선 연속 신호 x 에 대한 이산화를 위하여 다음과 같이 확률변수를 정의한다.

$$X(k) = \{x_1, x_2, \dots, x_N\} \quad (9)$$

여기서 k 는 이산시간을 나타내며, 확률변수는 다음과 같다.

$$p(X) = \{p(x_1), p(x_2), \dots, p(x_N)\} \quad (10)$$

확률공리(probability axiom)에 의하여 식 (10)의 확률변수는 다음의 제약조건을 갖는다.

$$\sum_{i=1}^N p(x_i) = 1 \quad (11)$$

가장 간단한 실시간 확률추정 기법은 전체 사건(event)의 수에 대한 특정한 사건의 발생 수에 대한 비로 나타낼 수 있다. 예를 들어, 전체 발생사건의 수를 n 으로 정의하고 이산사건 i 에 대한 발생수를 n_i 로 두면 i 에 대한 확률은 $p(X=i) = n_i/n$ 로 구해진다. 또한, 식 (9)의 이산시간 k 에 대하여 x_i 의 확률은

$$p(x_i) = \frac{n(x_i)}{k} \quad (12)$$

가 된다. 여기서 $n(x_i)$ 는 k 시간 동안 x_i 의 발생한 수를 나타낸다. 일반적으로 시스템은 오랜 시간동안 운전하게 되며 이러한 경우 이산시간 k 는 매우 큰 값이 되며 즉, $k \rightarrow \infty$ 로 된다. 따라서 매우 많은 계산량이 실시간 연산에 요구된다. 본 논문에서는 윈도우 기법을 적용하여 연산 데이터의 수를 유한한 값으로 한정하게 된다. 식 (12)에 윈도우 변수 N_W 를 적용하여 유한한 이산시간과 이에 대한 발생수를 확률로 나타내면 다음과 같다.

$$p(x_i) = \frac{n_W(x_i)}{N_W - k} \quad (13)$$

여기서 $0 < N_W$ 이며 초기시간에 $k < N_W$ 의 경우 윈도우 기법을 적용할 수 없으며 식 (12)를 적용하며 $N_W < k$ 경우 식 (13)을 적용한다.

3. 신경회로망 기반 독립성분분석

본 절에서는 센서를 통해 취득한 각각의 시스템 음향에 대한 전처리과정으로, ICA 기법을 통해 왜곡된 독립신호를 복원한다(그림 2 참조).

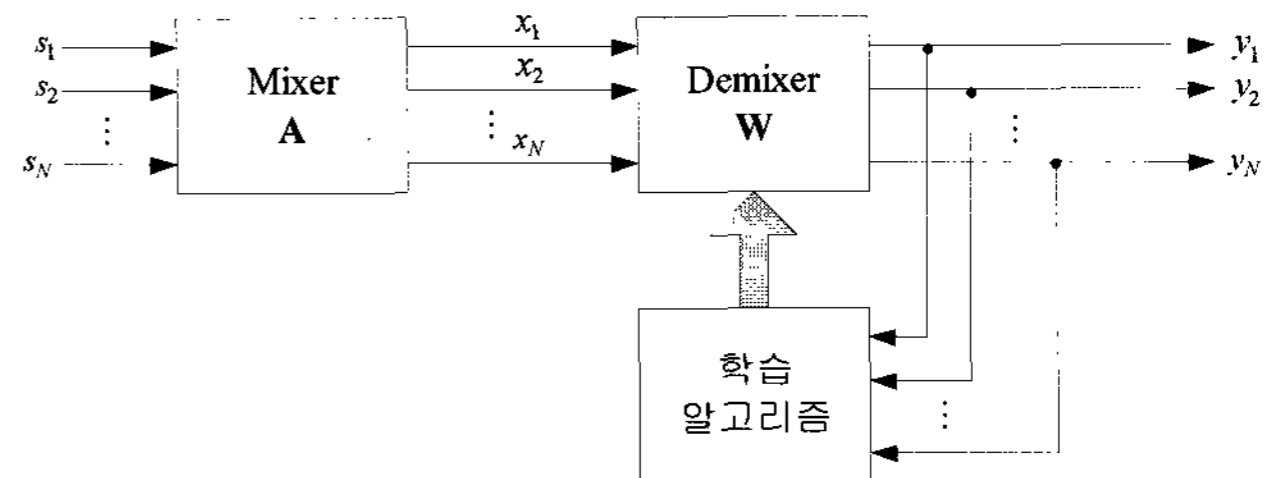


그림 2 혼합된 음향신호의 복원
Fig. 2 Restoration of mixed acoustic signals

3.1 독립성분분석

ICA는 독립성분의 혼합 랜덤신호를 원래의 신호로 복원하는 신호처리 기법중의 하나이다. 그림 2에서 미지의 원신호벡터를 $s \in R^N$, 관측벡터를 $x \in R^N$ 으로 정의하면 다음과 같은 선형관계로 된다.

$$x = As \quad (14)$$

여기서 $A \in R^{N \times N}$ 의 행렬이다. 이 때 x 에 대하여 다음과 같이 선형관계를 정의한다.

$$y = Wx \quad (15)$$

따라서 ICA 기법을 통해 식 (15)의 행렬 W 을 추정하면 식 (14)의 원신호 s 를 복원할 수 있다. 여러 가지 ICA 기법이 발표되었으며, 본 논문은 정보이론과 신경회로망 기법을 이용하여 ICA 알고리즘을 도출하며, 본 논문의 고장진단 알고리즘에 적용한다. 정보이론 기반 ICA의 원리는 두 개 이상의 신호에 대하여 상호정보(mutual information) 함수를 정의하여 최대화 기법을 통해 식 (15)의 행렬 W 를 결정하는 것으로, 따라서 W 에 대한 학습 알고리즘을 도출하여야 한다.

정의 1(Kullback-Leibler 함수) KL 함수는 두 가지 이상의 확률신호에 대한 상호정보의 정도(degree)를 엔트로피(entropy) 함수로 표현하는 것으로 다음과 주어진다.

$$D_{f_X \parallel f_Y} = -h(X) + \sum_{i=1}^N h_{x_i}(x_i) \quad (16)$$

여기서 h 는 확률변수 X 에 대한 엔트로피로서 다음과 같은 확률분포함수로 표현된다.

$$h(X) = - \int_{-\infty}^{\infty} f_X(x) \log f_X(x) dx \quad (17)$$

$$\begin{aligned} h_{x_i}(x_i) &= - \int_{-\infty}^{\infty} f_X(x) \log f_{x_i}(x_i) dx \\ &= - \int_{-\infty}^{\infty} f_{X_i}(x_i) \log f_{X_i}(x_i) dx_i \end{aligned} \quad (18)$$

식 (12)와 (13)을 식 (11)에 대입하면

$$\begin{aligned} D_{f_X \| f_{X_i}} &= \int_{-\infty}^{\infty} f_X(x) \log f_X(x) dx \\ &\quad - \sum_{i=1}^N \left\{ \int_{-\infty}^{\infty} f_{X_i}(x_i) \log f_{X_i}(x_i) dx_i \right\} \end{aligned} \quad (19)$$

와 같다. 정보이론 기반 ICA는 최적화 기법을 통하여 식 (19)의 KL 함수를 최소화함으로서 확률신호벡터 x 의 원 신호를 복원한다. ■

3.2 학습알고리즘

신경회로망 기반 ICA의 학습알고리즘을 도출하기 위하여 식 (15)를 식 (19)의 KL 함수로 나타내면

$$D(W) = -h(y) + \sum_{i=1}^N h_{y_i}(y_i) \quad (20)$$

이며 여기서 엔트로피의 특성[10]을 이용하면 식 (20)의 확률변수 y 에 대한 엔트로피는 다음과 같이 전개된다.

$$h(y) = h(x) + \log |\det(W)| \quad (21)$$

여기서 $\det(W)$ 는 행렬 W 의 행렬식을 나타낸다. 일반적으로 확률분포함수로 표현되는 엔트로피는 직접적으로 계산하는 것이 어려우므로 Gram-Charlier 전개법[11]을 이용하여 다음과 같이 근사화를 할 수 있다.

$$f_{y_i}(y_i) \approx \alpha(y_i) \left\{ 1 + \frac{k_{i,3}}{3!} H_3(y_i) + \frac{k_{i,4}}{4!} H_4(y_i) \right\} \quad (22)$$

여기서 α 는 가우시안 확률분포함수를 나타내며 다음과 같다.

$$\alpha(y_i) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{y_i^2}{2}\right) \quad (23)$$

또한 식 (22)에서 κ 는 확률변수의 cumulant로서 다음과 같이 주어진다[12].

$$\kappa_{i,1} = E(y_i) \quad (24-1)$$

$$\kappa_{i,2} = E(y_i^2) - (E(y_i))^2 \quad (24-2)$$

$$\kappa_{i,3} = E(y_i^3) - 3E(y_i)E(y_i^2) + 2(E(y_i))^3 \quad (24-3)$$

$$\begin{aligned} \kappa_{i,4} &= E(y_i^4) - 3(E(y_i^2))^2 - 4E(y_i^3)E(y_i) \\ &\quad + 12E(y_i^2)(E(y_i))^2 - 6(E(y_i))^4 \end{aligned} \quad (24-4)$$

여기서 E 는 평균값 연산자이다. 다음의 로그함수 근사식

$$\log(1+a) \approx a - \frac{a^2}{2} + O(a^2) \quad (25)$$

여기서 O 는 고차항을 나타내며, Chebyshev-Hermite 다항식의 특성[13]을 이용하여 식 (20)의 엔트로피 함수를 다음과 같이 전개한다.

$$\begin{aligned} h_{y_i}(y_i) &\approx \frac{1}{2} \log(2\pi e) - \frac{(k_{i,3})^2}{12} - \frac{(k_{i,4})^2}{48} \\ &\quad + \frac{5}{8} (k_{i,3})^2 k_{i,4} + \frac{1}{16} (k_{i,4})^3 \end{aligned} \quad (26)$$

식 (22)와 식 (26)을 식 (20)에 대입하여 전개하면 KL 함수는 최종적으로 다음과 같다.

$$\begin{aligned} D(W) &\approx -h(x) - \log |\det(W)| + \frac{m}{2} \log(2\pi e) \\ &\quad - \sum_{i=1}^m \left(\frac{(\kappa_{i,3})^2}{12} + \frac{(\kappa_{i,4})^2}{48} - \frac{5(\kappa_{i,3})^2 \kappa_{i,4}}{8} - \frac{(\kappa_{i,4})^3}{16} \right) \end{aligned} \quad (27)$$

식 (27)의 함수를 최소화하기 위한 식 (15)의 행렬 W 에 대한 수정규칙은 다음과 같다.

$$w_{ij}(k+1) = w_{ij}(k) - \eta \frac{\partial D(W)}{\partial w_{ij}}, \quad i, j = 1, \dots, N \quad (28)$$

여기서 $\eta \in (0, 1)$ 는 학습률을 나타낸다. 식 (27)을 식 (28)에 대입하여 엔트로피 특성을 통해 각각의 편미분항을 전개하면 다음과 같다.

$$\frac{\partial}{\partial w_{ij}} \log |\det(W)| = (W^{-T})_{ij} \quad (29)$$

$$\frac{\partial}{\partial w_{ij}} (\kappa_{i,3})^2 = 6E(y_i^3)E(y_i^2)x_j \quad (30)$$

$$\frac{\partial}{\partial w_{ij}} (\kappa_{i,4})^2 = 8E(y_i^4)E(y_i^3)x_j - 24E(y_i^3)x_j \quad (31)$$

$$\begin{aligned} \frac{\partial}{\partial w_{ij}} (\kappa_{i,3})^2 &= 6E(y_i^4)E(y_i^3)E(y_i^2)x_j \\ &\quad - 18E(y_i^3)E(y_i^2)x_j + 4(E(y_i^3))^3 x_j \end{aligned} \quad (32)$$

$$\frac{\partial}{\partial w_{ij}}(k_{i,4})^3 = 12(E(y_i^4) - 3)^2 E(y_i^3)x_j \quad (33)$$

여기서 확률변수 y 에 대한 정보를 오프라인 설계과정에서 추정하기가 어려우므로 식 (30)-식 (33)을 다음과 같이 근사화한다.

$$\frac{\partial}{\partial w_{ij}}(\kappa_{i,3})^2 = 6y_i^5 x_j \quad (34)$$

$$\frac{\partial}{\partial w_{ij}}(\kappa_{i,4})^2 = (8y_i^7 - 24y_i^3)x_j \quad (35)$$

$$\frac{\partial}{\partial w_{ik}}(\kappa_{i,3})^2 = (10y_i^9 - 18y_i^5)x_j \quad (36)$$

$$\frac{\partial}{\partial w_{ij}}(\kappa_{i,4})^3 = (12y_i^{11} - 72y_i^7 + 108y_i^3)x_j \quad (37)$$

위 결과식을 이용하면 식 (28)의 편미분항은 최종적으로 다음과 같다.

$$\frac{\partial}{\partial w_{ij}}D(W) \approx -(W^{-T})_{ij} + \phi(y_i)x_j \quad (38)$$

여기서

$$\phi(y_i) = \frac{29}{4}y_i^3 - \frac{47}{4}y_i^5 - \frac{14}{3}y_i^7 + \frac{25}{4}y_i^9 + \frac{3}{4}y_i^{11} \quad (39)$$

행렬 W 의 수정규칙을 벡터형태로 나타내면 다음과 같다.

$$W(k+1) = W(k) + \eta[I - \phi(y(k))y^T(k)]W(k) \quad (40)$$

여기서 $I \in R^{N \times N}$ 의 단위행렬이다.

4. 컴퓨터 시뮬레이션 및 결과 검토

본 논문에서 제안한 고장진단 알고리즘의 타당성을 검증하기 위하여 컴퓨터 시뮬레이션을 실시하였다. 앞서 도출한 신경회로망 및 정보이론 기반 ICA 알고리즘과 확률기법 기반 고장진단 알고리즘에 대한 시뮬레이션으로 각각 실시하였다. 우선 ICA에 대한 시뮬레이션으로서, 그림 3의 4개의 원 신호에 대하여 ICA 기법을 적용하였다. 원 신호는 다음의 행렬 A 에 의해 왜곡된다고 가정한다.

$$A = \begin{bmatrix} 0.70 & 0.15 & -0.22 & -0.48 \\ -0.92 & -0.90 & 0.27 & -0.93 \\ 0.40 & -0.91 & 1.00 & 0.78 \\ -0.88 & 0.99 & 0.10 & -0.78 \end{bmatrix} \quad (41)$$

식 (15)의 행렬 W 의 초기값은 $[-1, 1]$ 의 항등분포를 갖는 랜덤값으로 선택하였으며 학습 파라미터값 $\eta = 0.25$ 으로 선정하였다. 신경회로망의 반복학습을 통하여 그림 4와 같은 복원파형을 생성하였다. 이 때 식 (15)의 복원행렬 W 는 다음과 같이 구해졌다.


$$W = \begin{bmatrix} -0.3785 & 0.8146 & 0.4962 & -0.6256 \\ 0.1433 & -0.4299 & -0.1345 & 0.2154 \\ -0.4987 & -0.4223 & -0.0613 & -0.0833 \\ 0.2466 & -0.4563 & -0.4876 & 0.1303 \end{bmatrix} \quad (42)$$

원 신호파형에 대하여 복원파형의 형태는 비슷하나 진폭이나 신호의 위치가 바뀌었음을 알 수가 있다. 이러한 오차는 간단한 연산을 통해 거의 원 신호에 가까운 파형으로 복원할 수가 있다[8].

다음으로 고장진단 알고리즘에 대한 시뮬레이션을 실시한다. 우선 고장이 없는 시스템 상태 x 를 표준정규분포를 갖는 확률신호로 정의하며 그림 5는 이 신호에 대한 파형을 나타낸다. 우선 식 (12)의 알고리즘을 적용하기 위하여 그림 5의 신호를 다음과 같이 이산화를 실시한다.

$$x_1^+ \in [0,1), x_2^+ \in [1,2), x_3^+ \in [2,3), x_4^+ \in [3,\infty), x_1^- \in [-1,0), x_2^- \in [-2,-1), x_3^- \in [-3,-2), x_4^- \in [-\infty,-3)$$

2.3절에서 서술한 확률분포 알고리즘을 적용하여 그림 5의 신호에 대한 확률값을 추정하였으며 그림 6에 그 결과값을 보여준다. 다음으로 고장신호를 구현하기 위하여 500 sec에서 고장이 발생한다고 가정하며 그림 7은 고장신호에 대한 파형을 보여준다. 마찬가지로 고장신호에 대한 확률분포를 추정하였으며 그림 8은 확률파형을 보여준다. 마지막으로 그림 9는 식 (8)의 가능성비율을 보여주며, 500 sec에서 비율이 급격히 증가함을 알 수가 있다. 이러한 결과는 500 sec 이후에 고장으로 인하여, 정상상태 시스템의 상태확률과 급격한 차이가 있음을 알 수 있다.




(a) 원신호 s_1 (b) 원신호 s_2 (c) 원신호 s_3 (d) 원신호 s_4

그림 3 원 신호파형

(a) Original signal s_1 (b) Original signal s_2

(c) Original signal s_3 (d) Original signal s_4

Fig. 3 Original signal waveform



(a) 복원신호 y_1 (b) 복원신호 y_2
(c) 복원신호 y_3 (d) 복원신호 y_4

그림 4 복원 신호파형

(a) Restored signal y_1 (b) Restored signal y_2
(c) Restored signal y_3 (d) Restored signal y_4

Fig. 4 Restored signal waveform




그림 5 정상상태의 시스템 상태파형

Fig. 5 Time history of the steady-state response

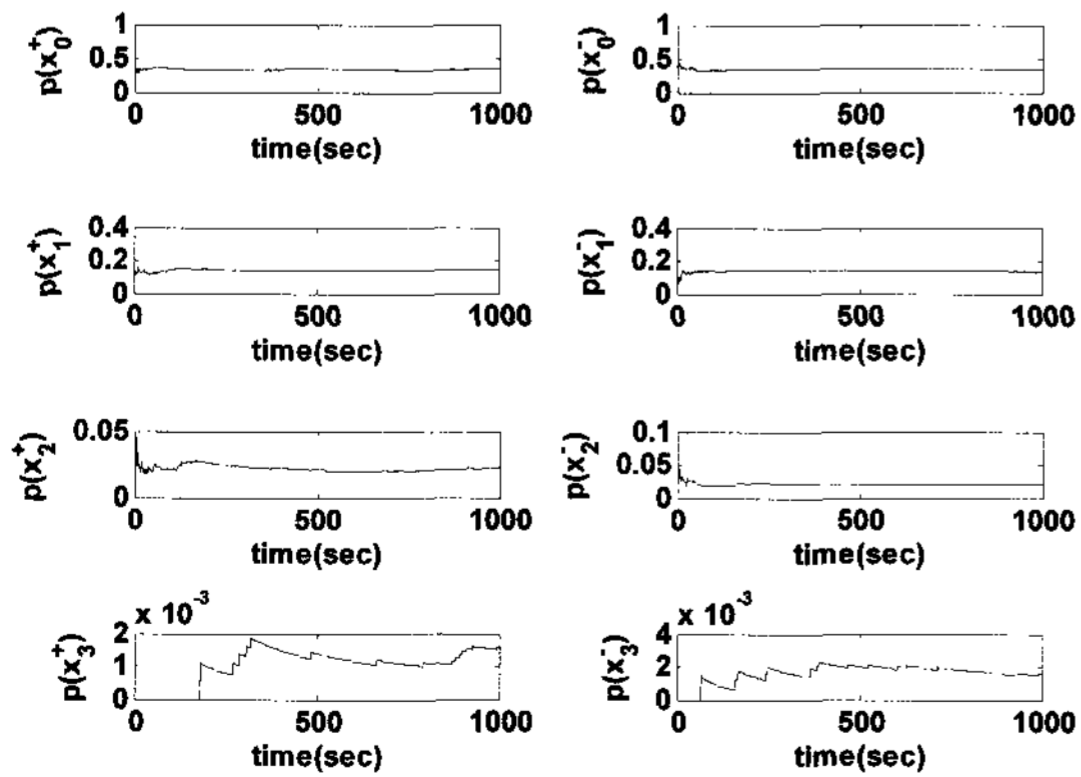


그림 6 정상상태의 확률분포 추정

Fig. 6 Probability density estimation for the system response




그림 7 고장상태의 시스템 상태파형

Fig. 7 System response for the faulty system

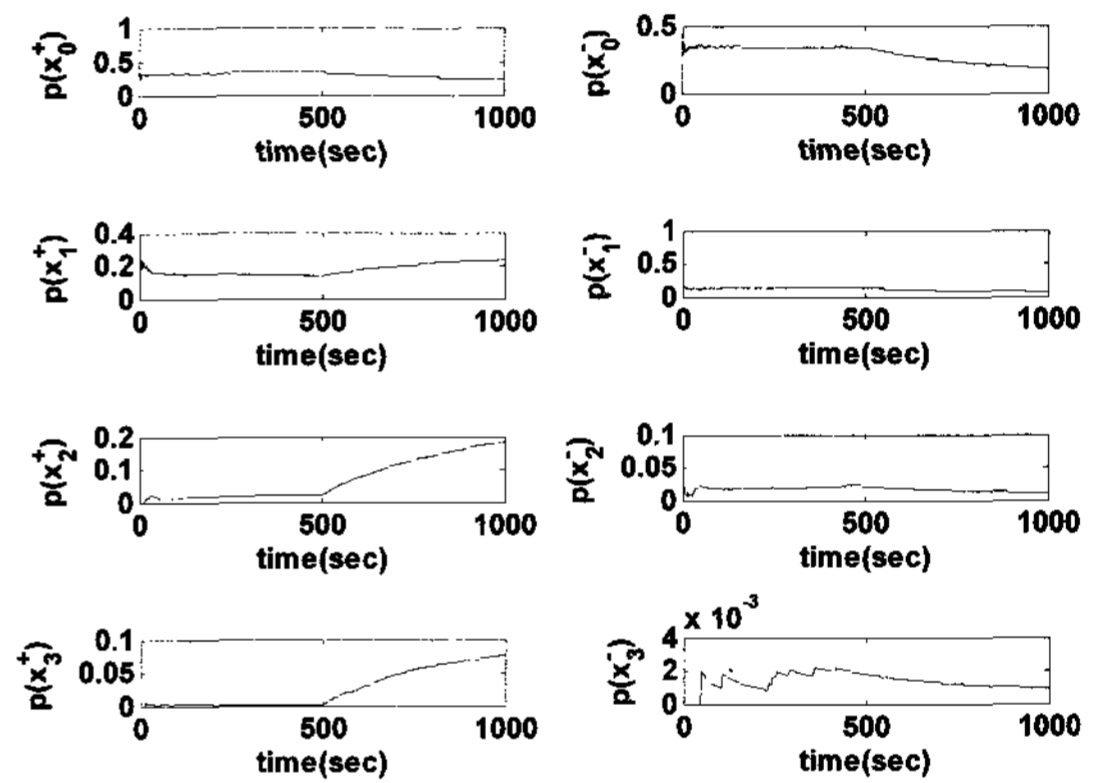


그림 8 고장상태의 확률분포 추정

Fig. 8 Probability density estimation for the faulty system response




그림 9 가능성비율 파형

Fig. 9 Time history of the likelihood ratio

5. 결 론

본 논문은 음향센서를 이용한 대전력 기기의 새로운 고장 진단 기법을 제안하였다. 대전력 회전기 및 변압기 같은 전력변환 기기는 정상동작시 기기 자체에서 소리가 발생하며 이것은 음향센서를 이용하여 고장유무를 판단한다. 이러한 음향은 여러 대의 기기에 대한 간섭작용으로 인하여 원래의 음향신호가 왜곡된다. 본 논문은 이러한 왜곡신호를 ICA 기법을 이용하여 통계적으로 독립성분을 갖는 원래 신호로 복원하였다. ICA 학습은 정보이론을 적용하여 학습알고리즘을 도출하였으며 컴퓨터 시뮬레이션을 통해 알고리즘의 타당성을 검증하였다. 향후 연구는 실시간 시스템에서 음향신호를 취득하여 본 논문에서 제안한 알고리즘을 적용할 것이며, 온라인 학습법을 개발하여 실시간에서 고장진단이 이루어질 수 있는 시스템을 개발하고자 한다.

감사의 글

본 논문은 한국전력공사의 한국에너지자원기술기획평가원 (KETEP)에서 지원한 전력변환시스템신기술 연구센터(과제번호 2007-0192)의 사업으로 수행되었습니다.

참 고 문 헌

- [1] R. Salat and S. Osowski, "Accurate fault location in the power transmission line using support vector machine approach," *IEEE Trans. on Power Systems*, vol. 19, no. 2, pp. 979-986, 2004.
- [2] V. Vapnik, *The nature of statistical learning theory*, Springer-Verlag, 2000.
- [3] G. J. Atkinson, B. C. Mecrow, A. G. Jack, D. J. Atkinson, P. Sangha, and M. Benarous, "The analysis of losses in high-power fault-tolerant machines for aerospace applications," *IEEE Trans. on Industry Applications*, vol. 42, no. 5, pp. 1162-1170, 2006.
- [4] Y. Murphey, M. Masrur, Z. Chen, and B. Zhang, "Model-based fault diagnosis in electric drives using machine learning," *IEEE/ASME Trans. on Mechatronics*, vol. 11, no. 3, pp. 290-303, 2006.
- [5] E. Mohamed, A. Abdelaziz, and A. Mostafa, "A neural network-based scheme for fault diagnosis of power transformers," *Electric Power Systems Research*, vol. 75, no. 1, pp. 29-39, 2005.
- [6] W. Roux, G. Ronald, and T. Habetler, "Detecting rotor faults in low power permanent magnet synchronous machines," *IEEE Trans. on Power Electronics*, vol. 22, no. 1, pp. 322-328, 2007.
- [7] R. Isermann, "Process fault detection based on modelling and estimation methods - A survey," *Automatica*, vol. 20, no. 4, pp. 387-404, 1984.

- [8] X. Tu, L.-A. Dessaint, M. El Kahel, and A. Barry, "A new model of synchronous machine internal faults based on winding distribution," *IEEE Trans. on Industrial Electronics*, vol. 53, no. 6, pp. 1818-1827, 2006.
- [9] P. Comon, "Independent component analysis - a new concept?," *Signal Processing*, vol. 36, pp. 287-314, 1994.
- [10] T. M. Cover and J. A. Thomas, *Elements of information theory*. Wiley, 2006.
- [11] S. S. Wilks, *Mathematical statistics*, New York, Wiley, 1962.
- [12] C. L. Nikias and A. P. Petropouou, *Higher-order spectra analysis*, Prentice-Hall, 1993.
- [13] C. W. Helstrom, *Statistical theory of signal detection*, Pergamon Press, 1968.

저 자 소 개



조 현 철 (曹賢哲)

1971년 9월 1일생. 1997년 부경대학교 제어계측공학과 졸업(학사). 1999년 동아대학교 대학원 전기공학과 졸업(석사). 2006년 미국 네바다대학교 전기공학과 졸업(박사). 현재 동아대 전기공학과 제어 및 시스템 연구실 포닥연구원.

Tel : 051)200-6950

Fax : 051)200-7743

E-mail : hyunccho@gmail.com



이 진 우 (李晉宇)

1972년 7월 15일생. 1998년 경남대학교 전기공학과 졸업. 2000년 동아대학교 대학원 전기공학과 졸업(석사). 2006년 동대학원 졸업(박사). 현재 동아대학교 전기공학과 제어 및 시스템 연구실 포닥연구원.

Tel : 051)200-6954

Fax : 051)200-7743

E-mail : jinwoo@donga.ac.kr



이 영 진 (李 榮 珍)

1966년 6월 17일생. 1992년 동아대학교 전기공학과 졸업(학사). 1994년 동 대학교 대학원 전기공학과 졸업(석사). 2000년 동 대학원 전기공학과 졸업(박사). 현재 한국폴리텍 항공대학 항공전기과 부 교수

Tel : 055)830-3482

E-mail : airlee011@hanmail.net



이 권 순 (李 權 純)

1955년 1월 18일생. 1977년 충남대학교 공업교육과 졸업(학사). 1981년 서울대학교 대학원 전기공학과 졸업(석사). 1990년 미국 오레곤 주립 대학교 전기 및 컴퓨터공학과 졸업(박사). 현재 동아대학교 전기공학과 교수

Tel : 051)200-7739

Fax : 051)200-7743

E-mail : kslee@dau.ac.kr