

ART-Kohonen 신경망을 이용한 회전기계의 결함진단 알고리즘

Fault Diagnostics Algorithm of Rotating Machinery Using ART-Kohonen Neural Network

안 경 룡* · 한 천* · 양 보 석[†] · 전 재 진** · 김 원 철***

Jing-Long An, Tian Han, Bo-Suk Yang, Jae Jin Jeon and Won-Cheol Kim

(2002년 7월 29일 접수 ; 2002년 9월 16일 심사완료)

Key Words : Artificial Neural Network(인공신경망), Fault Classification(결함분류), Rotating Machinery(회전기계), Vibration Signal(진동신호)

ABSTRACT

The vibration signal can give an indication of the condition of rotating machinery, highlighting potential faults such as unbalance, misalignment and bearing defects. The features in the vibration signal provide an important source of information for the faults diagnosis of rotating machinery. When additional training data become available after the initial training is completed, the conventional neural networks (NNs) must be retrained by applying total data including additional training data. This paper proposes the fault diagnostics algorithm using the ART-Kohonen network which does not destroy the initial training and can adapt additional training data that is suitable for the classification of machine condition. The results of the experiments confirm that the proposed algorithm performs better than other NNs as the self-organizing feature maps (SOFM), learning vector quantization (LVQ) and radial basis function (RBF) NNs with respect to classification quality. The classification success rate for the ART-Kohonen network was 94 % and for the SOFM, LVQ and RBF network were 93 %, 93 % and 89 % respectively.

1. 서 론

현재 결함진단을 위해 제안된 대부분의 인공신경망 (artificial neural network) 알고리즘은 먼저 결함신호를 취득하고, 이로부터 특징들을 추출하여 결함의 특징을 표현할 수 있는 훈련데이터의 집합을 구성한 후, 이 훈련집합을 이용하여 신경망을 훈련(학습)시킨 후에야 결함의 분류에 사용이 가능하며, 추가적인

새로운 훈련데이터를 학습하고자 하면 이전에 학습된 지식은 완전히 상실되는 단점을 가지고 있다. 그러나 현실적으로 각종 기계의 결함진단에 있어서 어떤 결함의 특징들은 단기간에 용이하게 취득될 수 있지만, 훈련에 필요한 모든 결함의 특징들을 단기간에 모두 취득하는 것은 용이하지 않고 장기간에 걸쳐 운전 중에 취득하지 않으면 안 되는 어려움이 있다. 그러므로 모든 결함의 특징을 표현할 수 있는 훈련집합을 한꺼번에 구축하는 것은 매우 어렵고, 실용상 많은 제약을 받고 있다.

따라서 결함진단을 위한 신경망 알고리즘은 인간의 두뇌와 같이 초기 지식이 부족한 상태에서부터 사용하여 가는 과정에서 지식을 점차 학습하고, 또 새로운 지식을 학습하는 과정에서 이전의 지식을 상실하지 않고 지식을 지속적으로 확장하여 가는 적응적인 기

[†] 책임저자, 정회원, 부경대학교 기계공학부
E-mail: bsyang@pknu.ac.kr
Tel: (051) 620-1604, Fax : (051) 620-1405
* 부경대학교 대학원
** 정회원, 국방과학연구소 제2체계개발본부
*** 정회원, 경상대학교 기계항공공학부

능이 필요하게 된다. 이러한 기능을 갖는 신경망으로 Grossberg와 Carpenter에 의해 제안된 적응공진이론 (adaptive resonance theory, ART) 신경망이 있다.^(1~4) 교사 없는 ART 신경망의 자기조직화는 모든 특징을 이용하여 미리 훈련할 필요가 없이 사용되는 과정에서 분류와 학습이 동시에 이루어지는 장점을 가지고 있고, 이러한 점은 기계의 결합진단에 매우 유용하다. 현재, ART 신경망에는 ART1, ART2, ART3 등이 제안되어 있다. ART1은 2진수만의 처리가 가능하고, ART2와 ART3은 10진수의 처리도 가능하지만, 입력단계에서 입력신호에 대하여 크기를 단위 길이로 정규화 하는 것은 결합진단에 있어서 불리한 점이다. 즉, 화상식별이나 음성식별 등에서는 신호의 절대 크기는 단지 전체가 밝고 어두움, 음성이 크고 작음을 나타내므로, 식별에 있어서 신호의 절대 크기는 의미가 없고 서로의 상대 크기만이 중요하기 때문에 신호를 입력할 때 정규화 하는 것이 유리하다. 그러나 기계의 결합진단의 경우, 진동신호의 절대 크기는 매우 중요한 특징정보이므로, 결합을 식별할 때 입력신호를 정규화 하는 것은 중요한 정보를 상실할 수 있다. 그리고 ART 신경망은 입력벡터에 대한 노이즈 제거가 매우 중요하며, 분류를 수행할 때마다 새로 입력된 벡터만으로 원래의 학습된 가중치를 단순히 대치하기 때문에 기억된 패턴이 점차 다른 패턴으로 변경될 수 있는 단점이 있다.⁽³⁾

자기조직화특징지도(self-organizing feature map, SOFM) 신경망과 같은 Kohonen 신경망⁽⁵⁾은 입력벡터를 다차원 공간상의 점으로 취급하여 공간상의 유클리드 거리로 각 벡터의 유사도(similarity)를 나타내고 거리가 멀면 유사도가 낮고 가까우면 유사도가 높다고 간주한다. 그러므로 거리가 가까운 벡터들을 같은 클러스터에 포함시켜 입력벡터에 대하여 클러스터링을 할 수 있다. Kohonen 신경망의 학습과정은 먼저 입력벡터에 대하여 몇 개의 패턴으로 분리할 것인가를 지정한다. 그리고 분리할 패턴의 수가 주어지면 공간상의 거리가 제일 가까운 벡터를 같은 패턴에 포함하여 지정된 수만큼의 패턴을 구성하고, 각 패턴은 이 패턴에 속하는 모든 벡터의 평균으로 표시한다. 즉, 입력된 벡터와 저장된 각 패턴사이의 거리를 구하여 제일 가까운 패턴으로 입력벡터를 분류한다.

본 연구에서는 기존의 신경망이 가지는 문제점을 해결하기 위해 ART 신경망을 도입하고, 앞에서 설명

한 ART 신경망이 가지는 단점을 해결하기 위하여 Kohonen 신경망의 알고리즘을 도입한 결합진단 알고리즘을 제안하였다. 즉, ART와 Kohonen 신경망이 가지는 각각의 장점을 결합한 ART-Kohonen 신경망을 이용한 결합진단 알고리즘을 제안하고, 회전기계에서 발생하는 결합의 분류에 적용하여 그 유용성을 검토하였다. 그리고 저자들에 의해 연구^(6~10)된 기존의 SOFM, 학습벡터양자화(LVQ), 레이디얼기저함수(RBF) 신경망과의 분류성능을 비교·검토하여 분류성능의 측면에서도 우수함을 확인하였다.

2. ART-Kohonen 신경망 알고리즘

ART-Kohonen 신경망의 구성은 Fig. 1과 같이 입력·비교층(input/comparison layer), 식별층(discernment layer), 가중치(weight) 및 제어(control) 등의 부분으로 구성되어 있다. 입력·비교층에 입력신호가 입력되면, 먼저 입력벡터를 식별층으로 전송하여 식별층의 각 뉴런과 유사도를 비교하고 제일 유사한 뉴런을 구하여 승자뉴런으로 한다. 다음 승자뉴런을 다시 입력·비교층으로 귀환하여 승자뉴런과 입력벡터의 절대적인 유사도를 평가한다. 유사도가 일정한 한계치 이내에 속하면 제어를 통하여 입력벡터를 현재의 승자뉴런으로 분류하고 가중치를 개선한 후 실행을 완료하고, 유사도가 한계치 이내에 속하지 않으면 제어를 통하여 식별층에 새로운 뉴런을 추가하고 가중치의 값은 현재의 입력벡터로 한다.

승자뉴런의 연산과정은 Kohonen 신경망에서의 승자뉴런의 계산방법을 도입하여 입력신호와 식별층의 각 뉴런, 즉 가중치의 유클리드 거리의 크기로 유사

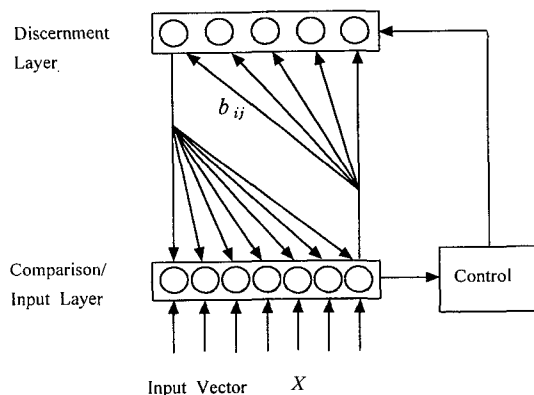


Fig. 1 Structure of ART network

도를 평가하고 거리가 제일 작은 뉴런을 승자뉴런으로 한다. 승자뉴런의 계산은 다음 식과 같다.

$$\|B_j - X\| < \|B_j - X\|; \quad j, J = 1, 2, \dots, n; j \neq J \quad (1)$$

여기서 B_j 는 식별층 뉴런의 가중치, B_J 는 승자뉴런의 가중치, j 는 식별층 뉴런의 번호, J 는 식별층의 승자뉴런의 번호, n 은 식별층의 뉴런 수, X 는 입력벡터이다.

구해진 승자뉴런을 입력·비교층으로 귀환한 후, 입력벡터 X 와의 절대적인 유사도 S 는 다음 식을 이용하여 평가한다.

$$S = \frac{\|B_j\| - \|B_j - X\|}{\|B_j\|} \quad (2)$$

식 (2)에서 B_j 와 X 가 같으면 $\|B_j - X\|$ 는 0이 되고, 유사도 S 는 1의 값을 갖게되며, B_j 와 X 사이의 유클리드 거리가 멀수록 S 는 작아진다. 따라서 유사도의 한계치 ρ 를 도입하여 $S > \rho$ 이면 충분한 유사성을 갖고 있다고 판단하고 입력벡터를 식별층 J 번째 뉴런이 갖고 있는 패턴으로 분류하고 가중치를 개선한 후 실행을 완료한다. 이 때의 가중치 개선 과정은 다음과 같다. ART-Kohonen 신경망의 가중치는 본질적으로 보면, Kohonen 신경망의 가중치와 같이 각 클러스터의 중심위치를 표현하는 벡터의 집합이다. 그러므로 가중치는 클러스터 당 1개의 자기 중심을 표현하는 벡터로 간주할 수 있다. 각 클러스터에 해당하는 가중치벡터는 이 클러스터에 포함되는 모든 벡터의 평균과 같다. 그러나 Kohonen 신경망은 훈련집합이 있기 때문에 훈련을 통하여 전체 입력벡터에 대하여 지정된 개수로 분류하고 분류된 각 클러스터에 포함되는 모든 벡터의 평균을 구하여 가중치로 할 수 있다. 그러나 본 연구에서 제안된 ART-Kohonen 신경망은 Kohonen 신경망과는 달리 훈련집합이 없고 입력벡터는 하나씩 주어지기 때문에 각 클러스터에 포함되는 모든 벡터의 평균을 구할 수 없으므로, 사용하는 과정에서 전에 입력되었던 모든 입력벡터를 이용하여 각 클러스터별로 평균을 구하면 가중치를 최대한 정확한 위치로 표현할 수 있다. 평균을 구하기 위해서는 각 클러스터에 포함되는 이전에 입력된 모든 입력벡터를 저장하여 새로운 입력벡터가

입력되면 추가하여 평균을 구할 수 있지만, 이러한 방법은 시간이 오래 경과하면 데이터 양이 방대하여지고 계산속도가 느리게된다. 따라서, 더욱 간단한 방법으로 평균을 구한 회수와 평균값만 저장하면 새로운 입력이 추가될 때마다 이전의 평균과 평균을 구한 회수를 곱한 후 입력을 더하고 평균을 구한 회수를 하나 더 추가하여 나누면 전체의 평균과 같게 된다. 그러므로 각 클러스터의 과거에 입력되었던 모든 입력벡터의 평균 위치, 즉 가중치는 다음 식과 같이 계산할 수 있다.

$$B_j = \frac{B_{j0} n + X}{n+1} \quad (3)$$

여기서 B_j 는 새로운 입력벡터를 포함하는 식별층의 승자뉴런이 대표하는 클러스터의 중심위치, B_{j0} 은 식별층 승자뉴런의 새로운 입력을 포함하지 않은 이전의 중심위치, n 은 학습한 회수이다.

이러한 학습방법은 이전에 학습되었던 전체 벡터와 새로 입력된 벡터의 평균으로 새로운 가중치의 값으로 취하므로 ART 신경망의 현재 입력된 벡터로 대체하는 학습방법과 비교하면 학습된 패턴이 점차 변화하여 다른 패턴으로 변화되는 것을 방지할 수 있다.

$S < \rho$ 의 조건이 되면, 승자뉴런의 가중치와 입력벡터 사이에 충분한 유사성이 없다고 판단하고 식별층에 뉴런을 추가하여 새로운 패턴을 구성하여 실행을 수행한다. 이 때 새로 형성되는 식별층 뉴런의 가중치 B_j 의 학습은 다음 식과 같다.

$$B_j = X \quad (4)$$

즉, 새로 추가한 식별층 뉴런의 가중치 B_j 는 이때의 입력벡터 X 로 나타내고, 앞으로 분류를 수행하는 과정에서 위와 같이 이 뉴런에 포함하는 입력벡터의 평균을 구하여 개선하여 간다.

3. ART-Kohonen 신경망을 이용한 결함진단 알고리즘

3.1 진단시스템의 구성

결함진단시스템은 Fig. 2와 같이 대상기계로부터의 진동가속도센서를 통한 원 신호(raw signal) 데이터의 취득, wavelet 변환과 통계적 처리를 통한 특징

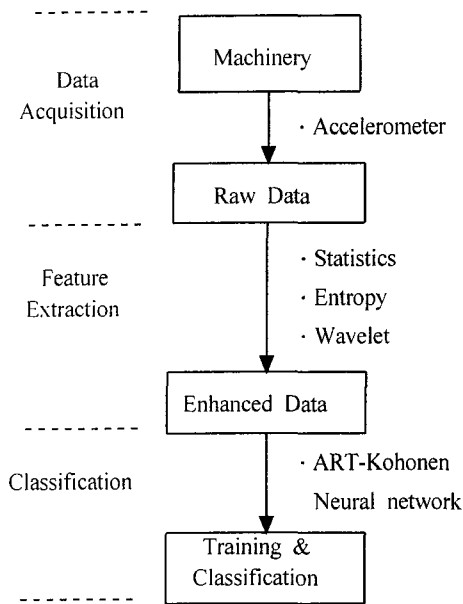


Fig. 2 Schematics for classification algorithm




Fig. 3 Experimental apparatus

추출(feature extraction), ART-Kohonen 신경망을 이용한 훈련 및 분류(classification)의 과정으로 구성된다.

3.2 신호 취득

결합진단시스템을 구성한 후, 실험장치에서 각종 결함에 대한 진동신호를 측정하여 시계열 신호를 취득하고, 특징추출 및 훈련과 분류를 수행하여 진단알고리즘을 검증하였다.

Fig. 3에 실험에 사용된 장치의 사진을 나타내었다. 실험장치는 그림에서와 같이 전동기, 커플링, 원판,

볼베어링, 베어링하우징 및 지지부 등으로 구성되고, 전동기의 회전속도는 0~6,000 rpm의 범위에서 임의로 조절할 수 있다.

진동신호의 측정은 실험장치의 우측 베어링하우징에 수직방향과 수평방향으로 가속도계를 설치하여 두 방향의 진동신호를 측정하고, 측정된 신호는 DSP 신호분석기를 이용하여 원 신호를 컴퓨터에 저장하였다. 그리고 레이저 변위계를 이용하여 회전속도를 측정하였다. 측정된 진동신호의 주파수범위는 5 kHz로 하고, 저장데이터의 개수는 16,384로 설정하였다. 가속도계의 측정주파수범위는 0.5~5,000 Hz이며, 수직 및 수평방향 가속도계의 감도는 각각 103.86 mmV/g, 104.63 mmV/g이다.

실험장치를 조절하여 정상상태, 불평형, 편심 및 편각 정렬불량, 베어링의 외륜결함, 내륜결함, 볼 결함 그리고 베어링에 여러 결함이 포함된 종합결함 등 8개의 정상 및 결함상태를 인공적으로 만들었다. 이 8 종류의 상태에 대하여 각 상태마다 20회를 측정하여 총 160개의 시계열 신호를 취득하였다.

3.3 특징 추출

특징 추출은 측정된 시계열의 진동신호에 대하여 먼저 평균(mean), 실효치(RMS치), 형상계수(shape factor), 왜도(skewness), 첨도(kurtosis), 파고율(crest factor), 엔트로피(entropy estimation) 및 표준편차(standard error)의 8개의 특징량을 구하였다. 그리고 일반적으로 베어링 결함에 의한 충격 가진으로 발생한 진동은 고주파수 영역의 고유진동수로 많이 발생하는 것을 고려하여 진동신호에 대하여 이산 wavelet 변환을 수행하고, wavelet 변환의 레벨 1(6.4~3.2 kHz), 레벨 2(3.2~1.6 kHz) 및 레벨 3(1.6~0.8 kHz)의 고주파수 영역에 대하여 위의 8개 특징량을 구하여 각 신호에 대하여 총 32개의 특징량⁽¹¹⁾을 구하였다. 실제 신경망에 입력되는 특징량의 수가 너무 많으면 계산속도가 크게 떨어지고 식별능력도 오히려 낮아질 수 있으므로, 일반적으로 5개에서 10개 정도로 취하고 있다.⁽⁶⁻¹⁰⁾ 본 연구에서는 특징량 유효성평가계수를 도입하여 32개 특징량 중에서 유효성평가계수가 제일 높은 8개를 선택하였다. 즉, 특징량 선택의 원칙은 선택된 특징량은 같은 상태에서는 식 (5)로 정의되는 상호거리가 작아야하고 서로 다른 상태에서는 커야 한다. 이에 근거하여 32개의 각 상

태량이 서로 다른 8종류의 상태에서 상호평균거리를 구하고, 또한 20개의 같은 상태에서는 상호평균거리를 구하여 두 거리의 비로 특징량의 유효성을 나타내었다. 이 비가 크면 서로 다른 상태는 거리가 멀고, 같은 상태는 거리가 짧은 것을 의미한다.

$$d_{i,j} = \frac{1}{N \times (N-1)} \sum_{m,n=1}^N |p_{i,j}(m) - p_{i,j}(n)| \quad (5)$$

$(m, n = 1, 2, \dots, N, m \neq n)$

여기서 N 은 같은 상태의 특징량의 수(= 20), $p_{i,j}$ 는 특징량, i 는 32개의 상태량, j 는 8종류의 상태, $d_{i,j}$ 는 각각의 같은 상태(20개)의 평균거리를 나타낸다. 8종류($j = 1 \sim M$)의 같은 상태의 평균거리를 평균하면, 전체의 같은 상태의 평균거리 \bar{d}_i 는 다음 식과 같이 정의된다.

$$\bar{d}_i = \frac{1}{M} \sum_{j=1}^M d_{i,j} \quad (6)$$

여기서 M 은 종류(상태)의 수(= 8)를 나타낸다. 같은 상태의 20개의 특징량에 대한 평균(mean) $\bar{p}_{i,j}$ 를 구하면, 다음 식과 같이 표현된다.

$$\bar{p}_{i,j} = \frac{1}{N} \sum_{n=1}^N p_{i,j}(n); (n=1, 2, \dots, N) \quad (7)$$

서로 다른 상태 사이의 평균거리 \bar{d}_i' 는 다음 식과 같이 정의할 수 있다.

$$\bar{d}_i' = \frac{1}{M \times (M-1)} \sum_{m,n=1}^M |\bar{p}_{i,m} - \bar{p}_{i,n}| \quad (8)$$

$(m, n = 1, 2, \dots, M; m \neq n)$

각 상태량의 다른 상태의 평균거리 \bar{d}_i' 와 같은 상태의 평균거리 \bar{d}_i 의 비를 α_i 라 하면, 다음 식과 같이 정의된다.

$$\alpha_i = \bar{d}_i' / \bar{d}_i \quad (9)$$

따라서 α_i 의 크기를 이용하여 특징량의 유효성을 비교할 수 있고, 본 연구에서는 α_i 를 유효성평가계수(effectiveness factor)라 정의한다. 32개의 특징량에 대하여 유효성평가계수를 구하면 Fig. 4와 같다. Fig. 4에서 유효성 평가계수가 제일 높은 8개의 특징량을 선택하면, 시계열 신호의 형상계수, 파고율 및 표준




Fig. 4 Effectiveness factor of features

편차, wavelet 변환 레벨 1의 평균 및 엔트로피, wavelet 변환 레벨 2의 형상계수 및 표준 오차, wavelet 변환 레벨 3의 엔트로피이다. 본 연구에서는 이 8개의 특징량을 각 상태분류를 위한 신경망의 입력정보로 사용하였다.

3.4 훈련과 결함분류

실험에서 취득한 160개의 신호를 진단시스템에 사용하고 각 상태의 특징량으로 앞에서 선택한 최적의 특징량 8개를 이용하였다.

실행과정과 결과는 Table 1과 같고, 표에서 각 기호의 의미로는 A: 입력데이터 번호, B: Table 2에 정의된 입력데이터 각 상태의 속성라벨, C: 신경망에 입력한 속성과 신경망이 출력한 속성, D: 신경망의 뉴런 번호이다. 표에서 “?”는 신경망이 새로운 뉴런을 형성할 때, 입력신호의 속성을 질문하는 것으로, 물음표 뒤의 숫자는 질문에 응하여 입력한 입력벡터의 속성이다.

ART-Kohonen 신경망의 실행과정은 1번 데이터를 입력하였을 때, 신경망은 내부에 저장된 패턴이 없으므로 새로운 패턴 1번 뉴런을 추가하고 속성을 물어 보며, 이에 속성을 1로 입력하면 1번 뉴런의 속성을 1로 표시한다. 다음 신호가 들어왔을 때, 내부에 있는 1번 뉴런과 비교하여 충분히 유사하면 1번 뉴런으로 분류하고 1번 뉴런이 갖고 있는 속성으로 출력을 표시하며 유사하지 않으면 새로운 뉴런을 추가한다. 2부터 10까지의 입력신호를 모두 1번 뉴런과 유사하므로 1번 뉴런으로 분류하고 1번 상태로 출력을 표시한다.

Table 1 Classification procedure and results of ART-Kohonen network

A	B	C	D	A	B	C	D	A	B	C	D	A	B	C	D
1	1	?:1	1	41	3	?:3	8	81	5	?:5	22	121	7	?:7	35
2	1	1	1	42	3	3	8	82	5	?:5	23	122	7	7	35
3	1	1	1	43	3	3	8	83	5	5	23	123	7	7	35
4	1	1	1	44	3	3	8	84	5	5	22	124	7	7	35
5	1	1	1	45	3	3	8	85	5	?:5	24	125	7	7	35
6	1	1	1	46	3	3	8	86	5	3	8	126	7	7	35
7	1	1	1	47	3	3	8	87	5	5	22	127	7	7	35
8	1	1	1	48	3	3	8	88	5	?:5	25	128	7	7	35
9	1	1	1	49	3	3	8	89	5	5	23	129	7	7	35
10	1	1	1	50	3	3	8	90	5	5	24	130	7	7	35
11	1	?:1	2	51	3	?:3	9	91	5	?:5	26	131	7	6	34
12	1	1	2	52	3	3	9	92	5	3	8	132	7	6	34
13	1	1	2	53	3	3	8	93	5	?:5	27	133	7	6	32
14	1	1	2	54	3	3	9	94	5	?:5	28	134	7	7	35
15	1	1	2	55	3	3	9	95	5	5	26	135	7	7	35
16	1	1	2	56	3	3	9	96	5	?:5	29	136	7	7	35
17	1	1	2	57	3	3	8	97	5	5	22	137	7	7	35
18	1	?:1	3	58	3	3	8	98	5	5	23	138	7	7	35
19	1	1	2	59	3	3	8	99	5	?:5	30	139	7	7	35
20	1	1	1	60	4	3	8	100	5	5	30	140	7	7	35
21	2	?:2	4	61	4	?:4	10	101	6	?:6	31	141	8	?:8	36
22	2	2	4	62	4	?:4	11	102	6	?:6	32	142	8	8	36
23	2	?:2	5	63	4	?:4	12	103	6	6	32	143	8	8	36
24	2	?:2	6	64	4	4	11	104	6	6	32	144	8	8	36
25	2	2	5	65	4	?:4	13	105	6	6	32	145	8	6	32
26	2	2	4	66	4	?:4	14	106	6	6	32	146	8	8	36
27	2	2	5	67	4	?:4	15	107	6	6	32	147	8	8	36
28	2	2	4	68	4	4	15	108	6	6	32	148	8	8	36
29	2	2	5	69	4	4	10	109	6	6	32	149	8	8	36
30	2	2	5	70	4	4	15	110	6	6	32	150	8	8	36
31	2	?:2	7	71	4	?:4	16	111	6	?:6	33	151	8	?:8	37
32	2	2	5	72	4	?:4	17	112	6	?:6	34	152	8	8	37
33	2	2	5	73	4	?:4	18	113	6	6	34	153	8	6	34
34	2	2	5	74	4	4	14	114	6	6	34	154	8	8	37
35	2	2	5	75	4	?:4	19	115	6	6	34	155	8	8	36
36	2	2	5	76	4	4	11	116	6	6	32	156	8	8	36
37	2	2	5	77	4	4	10	117	6	6	32	157	8	8	36
38	2	2	4	78	4	?:4	20	118	6	6	32	158	8	8	36
39	2	2	4	79	4	4	15	119	6	6	32	159	8	8	36
40	2	2	4	80	4	?:4	21	120	6	6	32	160	8	8	36

Table 2 Attribute label of each condition

Condition	Normal	Bearing defect				Misalignment		Unbalance
		Outer race	Inner race	Ball	Complex	Angular	parallel	
Label	1	2	3	4	5	6	7	8

다음에 11번 신호를 입력하면, 내부의 저장된 1번 뉴런이 충분히 유사하지 않기 때문에 새로운 패턴으로 판단하여 2번 뉴런을 추가하고 속성을 물어보며, 이때 11번 신호의 속성 1을 입력하면 2번 뉴런도 1번 속성을 가지며, 2번 뉴런에 소속하는 12~17번 입력 벡터도 1번 상태로 출력된다.

160개의 전체 데이터를 입력하면, Table 1의 D와 같이 총 37개의 뉴런이 생성되고, 이들이 8개의 상태에 포함되는 뉴런의 수는 Table 3과 같다.

Table 3에서 각 상태는 한 개의 뉴런으로 표현되는 것이 아니고 여러 개의 뉴런으로 표현되며, 또 상태에 따라 뉴런수도 다르다. 이것은 각 상태의 진동은 일정하지 않고 일정한 범위에서 변화하고, 또 상태에 따라 변화의 크기도 다르기 때문이다.

각 상태의 입력벡터분포 영역의 크기는 서로 다르기 때문에 영역이 큰 상태는 전체 영역을 표현하기 위하여 많은 뉴런이 필요하게 된다. 그러므로 Table 3에서 진동특징의 변화가 큰 베어링 불 결함과 종합 결함은 비교적 많은 뉴런이 생성되었다. ART-Kohonen 신경망에서 식별층의 뉴런 수는 입력벡터의 클러스터 수의 증가에 따라 증가하지만, Fig. 5와 6에 나타내듯이 일정한 입력에서는 유사도의 한계치 ρ 의 증가에 따라 급격히 변화하고, 분류성공률도 ρ 의 값에 따라 크게 변화하는 것을 알 수 있다. 분류성공률은 다음 식과 같이 정의한다.

$$\text{분류성공률(\%)} = \frac{\text{판정 수}}{(\text{총 데이터 수} - \text{뉴런 수})} \times 100$$

여기서 판정 수는 정확하게 판정한 수이며, 분모는 분류에 사용한 데이터 수로 총 입력데이터에서 학습에 사용한 데이터를 제거한 것이다. 입력된 총 데이터 수에서 학습에 사용된 데이터 수는 생성된 뉴런 수와 같으므로 분류에 사용한 데이터 수는 총 데이터 수에서 뉴런 수를 뺀 것과 같다.

Fig. 5에서 식별층 뉴런의 수는 ρ 의 증가에 따라 거의 지수적으로 증가하고, $\rho = 1$ 일 때는 식별층의 뉴런 수는 입력벡터의 수와 같게 된다. 이것은 학습된 각 패턴의 범위가 완전히 없는 상태이고, 입력벡터가 학습된 패턴과 완전히 같아야만 분류한다는 것을 의미한다. 실제로는 완전히 같은 경우는 존재하지 않기 때문에, 모든 입력은 모두 새로운 패턴으로 취급하므로 분류성공률이 0으로 된다. 그러므로 ρ 는

반드시 1보다 작은 값을 취하여야 한다. 예로 Fig. 5에서 전체신호 160개에서 최소한 60%는 분류에 그리고 40%를 훈련에 사용한다고 하면 뉴런의 수는 64개 이하여야 하며, ρ 의 값은 0.98 이하여야 한다. ρ 가 너무 작으면, 학습된 패턴의 범위가 너무 크기 때문에 입력벡터의 많은 클러스터를 포함하고 올바른 분류를 할 수 없게 된다. 최소한 각 클러스터 당 하나는 뉴런이 할당되어야 하므로, 뉴런 수는 8개 이상이어야 하며 그림에서는 ρ 의 값은 0.90 이상이 되어

Table 3 Number of neuron presenting each condition

Condition	1	2	3	4	5	6	7	8	Total
Neuron number	3	4	2	12	9	4	1	2	37

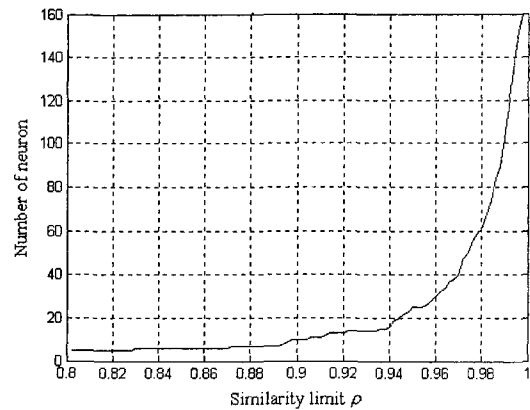


Fig. 5 Relationship of discernment layer neuron number and similarity limit




Fig. 6 Relationship of classification success rate and similarity limit

Table 4 Comparison of classification success rate

Neural network	SOFM	LVQ	RBF	ART-Kohonen
Classification success rate(%)	93	93	89	94

야 한다. Fig. 5에서 보면, 신경망의 분류성공률은 ρ 의 증가에 따라 전체적인 추세는 증가하고, ρ 가 1에 가까울 때는 100%에 도달한다. 그러나 앞에서 설명한 바와 같이, ρ 가 1에 가까울 때는 비록 정확도는 높지만 대부분은 학습에 사용하고 실제 분류한 수는 몇 개 밖에 되지 않기 때문에 의미가 없고, 유사도 한계치를 앞에서 추정된 0.90에서 0.98 사이의 값을 고려하여 0.95~0.98 사이의 값을 취하면 80% 이상의 분류성공률을 얻을 수 있다.

Fig. 6에서 분류성공률의 전체적인 추세는 ρ 의 증가에 따라 증가하지만 불연속적으로 변동하고 있다. 각 클러스터는 여러 개의 뉴런으로 표현되고 클러스터의 영역은 이 영역을 표현하는 전체 뉴런영역의 합으로 된다.

ρ 가 증가하면 각 클러스터를 표현하는 뉴런 수는 증가하고 ρ 의 증가로 각 뉴런의 영역은 작아지지만 뉴런 수는 증가하기 때문에 클러스터의 영역은 커질 수도 있고 작아질 수도 있으며, 크기는 입력벡터의 분포에 따라 작은 범위에서 변화한다. 이러한 원인으로 서로 인접한 클러스터의 거리가 가까우면 ρ 의 증가에 따라 분류성공률은 국부적으로 커질 수도 있고 작아질 수도 있다.

ART-Kohonen 신경망의 최대 분류성공률을 기존의 SOFM, LVQ 및 RBF 신경망에 의한 결과와 비교하면 Table 4와 같다.

표에서 보면 ART-Kohonen 신경망의 최대 분류성공률은 94%로서, SOFM, LVQ 및 RBF 신경망보다 약간 높은 것을 알 수 있다. 그리고 분류성공률이 80% 이상이 되는 뉴런 수의 범위는 SOFM은 20~75개, LVQ는 20~100개, RBF는 11~42개, ART-Kohonen은 22개 이상이다.

4. 결 론

본 연구에서는 회전기계의 결합진단에 더욱 적합한 ART 신경망과 Kohonen 신경망이 가지는 장점을 결

합한 새로운 ART-Kohonen 신경망을 이용한 결합진단 알고리즘을 제안하고, 제안된 알고리즘의 유용성을 확인하기 위해 결합실험장치로부터 취득한 진동신호를 이용하여 결합의 분류성능을 검증하였다. 또한 기존의 SOFM, LVQ 및 RBF 신경망을 이용하여 얻어진 분류성공률과 비교하였다. ART-Kohonen 신경망은 결합을 식별하기 전 훈련을 수행하지 않은 상태에서 직접 사용할 수 있고, 학습은 분류를 수행하는 과정에서 진행되며 새로운 지식을 학습하였을 때 과거의 지식을 유지하며 지속적으로 확장하여 가는 큰 장점을 가지는 것을 확인하였다. 아울러 결합에 대한 분류성공률도 약 94%에 달하고, 기존의 SOFM 및 LVQ 신경망과 같은 정도의 분류성공률을 가지는 것을 확인하였다.

후 기

본 연구는 수중음향특화연구센터 연구과제의 일부 분으로서 국방과학연구소의 지원으로 수행되었습니다.

참 고 문 헌

- (1) Carpenter, G. A. and Grossberg, S., 1987, "ART2 Self-organization of Stable Category Recognition Codes for Analog Input Patterns," *Applied Optics*, Vol. 26, No. 23, pp. 217~231.
- (2) Carpenter, G. A. and Grossberg, S., 1990, "ART3: Hierarchical Search Using Chemical Transmitters in Self-organizing Pattern Recognition Architectures," *Neural Networks*, Vol. 4, No. 3, pp. 129~152.
- (3) Carpenter, G. A. and Grossberg, S., 1992, "A Self-organizing Neural Network for Supervised Learning, Recognition, and Prediction," *IEEE Communications Magazine*, Vol. 30, No. 9, pp. 38~49.
- (4) Carpenter, G. A. and Grossberg, S., 1988, "The ART of Adaptive Pattern Recognition by a Self-organizing Neural Network," *IEEE Computer*, Vol. 21, No. 3, pp. 77~88.
- (5) Kohonen, T., Oja, E., Simula, O., Visa, A. and Kangas, J., 1996, "Engineering Application of

the Self-organizing Map," Proceedings of the IEEE, Vol. 84, No. 10, pp. 1358~1384.

(6) 양보석, 서상윤, 임동수, 이수중, 2000, "자기 조직화특징지도와 학습벡터양자화를 이용한 회전기계의 이상진동진단 알고리즘," 한국소음진동공학회지, 제 10 권 제 2 호, pp. 331~337.

(7) Yang, B. S., Lim, D. S., Seo, S. Y. and Kim, M. H. 2000, "Defect Diagnostics of Rotating Machinery Using SOFM and LVQ," Proceeding of 7th Int. Congress on Sound and Vibration, July 4-7, Garmisch-partenkirchen, Germany, pp. 567~574.

(8) Yang, B. S., Lim, D. S. and An, J. L. 2000, "Vibration Diagnostic System of Rotating Machinery Using Artificial Neural Network and Wavelet Transform," Proceeding of 13th Int.

Congress and Exhibition on Condition Monitoring and Diagnostic Engineering Management, Dec. 3-8, Houston, USA, pp. 923~932.

(9) 김광근, 최성필, 김영찬, 양보석, 2000, "RBF 신경망을 이용한 모델 개선법," 유체기계저널, 제 3 권 제 3 호, pp. 19~24.

(10) Yang, B. S., Lim, D. S. and Kim, K. K. 2002, "Vibration Diagnosis System of Rotating Machinery Using Radial Basis Function Neural Network," Proceedings of 4th Int. Conference on Quality Reliability Maintenance, Univ. of Oxford, England, March 21-22.

(11) Han, T. 2002, "Feature Extraction of Vibration Signal for Machinery Condition Monitoring," Master Thesis, Pukyong National University, pp. 1~61.