

회전기계 고장 진단에 적용한 인공 신경회로망과 통계적 패턴 인식 기법의 비교 연구

김창구*, 박광호*, 기창두**

A Comparison of Artificial Neural Networks and Statistical Pattern Recognition Methods for Rotating Machine Condition Classification

Chang Gu Kim*, Kwang Ho Park*, and Chang Doo Kee**

ABSTRACT

This paper gives an overview of the various approaches to designing statistical pattern recognition scheme based on Bayes discrimination rule and the artificial neural networks for rotating machine condition classification. Concerning to Bayes discrimination rule, this paper contains the linear discrimination rule applied to classification into several multivariate normal distributions with common covariance matrices, the quadratic discrimination rule under different covariance matrices. Also we describes k-nearest neighbor method to directly estimate a posterior probability of each class. Five features are extracted in time domain vibration signals. Employing these five features, statistical pattern classifier and neural networks have been established to detect defects on rotating machine. Four different cases of rotating machine were observed. The effects of k number and neural networks structures on monitoring performance have also been investigated. For the comparison of diagnosis performance of these two methods, their recognition success rates are calculated from the test data. The result of experiment which classifies the rotating machine conditions using each method presents that the neural networks shows the highest recognition rate.

Key Words : Artificial Neural Networks(인공 신경망), Statistical Pattern Recognition(통계적 패턴 인식), k-NN Classification(K-NN 분류법), Rotating Machine(회전기계)

1. 서론

최근의 발전 플랜트 및 화학 플랜트는 대형화 되는 추세이고 플랜트의 기계적 고장에 의한 가동 정지가 빈번히 발생하고 있는 실정이다. 이러한

고장은 주로 회전 기계에서 발생하고 있으며 많은 연구자들이 관심을 갖고 플랜트 시스템의 신뢰성 및 가동률 향상을 위해 연구하고 있다¹⁾. 진동 신호 모니터링은 회전 기계의 상태를 해석하는 가장 유용한 수단이며 기계에 심각한 결함이 발생되어

* 전남대학교 기계공학과 대학원

** 전남대학교 기계공학과

교체를 해야 되기 전에 결함을 발견할 수 있도록 해준다²⁾.

패턴 인식 기법에 의한 회전기계 결함 분류는 진동 신호로부터 정량적인 특징 값을 얻어 내는 “특징 추출 과정”과 이미 회전체의 상태를 알고 있는 상태에서 취득한 패턴들을 이용하여 학습 지식 자료를 구성하는 “학습 과정”, 그리고 얻어진 학습 정보를 바탕으로 결함을 분류하는 “판단 과정”으로 나눌 수 있다.

패턴 인식 방법은 크게 통계적인 방법과 신경망을 이용한 방법으로 나눌 수 있다. 최근 신경회로망은 패턴인식 분야에서 활발히 응용되고 있고 진동 신호의 모니터링에도 적용되고 있다^(4,5,6,7,8,9,10).

회전기계 고장 진단에 적용된 패턴 인식 기법은 주로 통계적인 기법들이 사용되다가, 1980년대 중반에 다층퍼셉트론과 오류 역전과 알고리즘이 개발되면서 신경망 기법이 보편적인 방법으로 사용되고 있다. 이들 통계적 기법 및 신경망을 이용한 기법들이 꾸준히 발전을 거듭하고 있음에도 불구하고, 회전기계고장 진단 분야에서 이들 방법들을 서로 비교한 연구가 거의 이루어지지 않고 있다. 따라서 본 연구에서는 회전 기계 고장 진단에 통계적 기법과 신경망 기법을 적용하여 인식 결과를 비교 분석하였다. 통계적 방법중 모수적인 방법으로는 회전체 각 상태에 대한 정규성과 등분산성을 가정하는 선형판별함수(LDF)와 상태에 대한 정규성만을 가정하는 이차형 판별함수(QDF)를 다루었다. 각 상태에 대한 임의의 분포를 가정하지 않는 비모수적인 방법에서는 k-최근접 이웃방법(k-Nearest Neighbor Method)을 다루었다. 또한 신경망 기법에서는 가장 많이 응용되고 있는 기법중의 하나인 다층퍼셉트론(MLP)을 선택하여 이들 통계적인 기법들과 비교 하였다.

2. 통계적 패턴 인식

회전체 고장 진단에 적용한 패턴 분류의 목적은 p-차원의 벡터로 표현되는 미지의 진동 패턴 $x = \{x_1, \dots, x_p\}$ 를 g 개의 회전체 상태중의 하나로 할당하는 것이다. 이때 주어진 진동 패턴은 g 개의 상태중 단 하나의 상태에만 속한다고 가정한다. 통계적 패턴 인식은 베イズ 판별 규칙에 이론적 기반을 두고 있으며 베イズ 판별 규칙은 아래식과 같다.

$$x \rightarrow \hat{\pi}, \text{ if } p(\hat{\pi}|x) = \max_{1 \leq j \leq g} p(\pi_j|x) \quad (1)$$

즉 회전체 각 상태에 대한 사후 확률($p(\hat{\pi}|x)$)을 구해 가장 큰 확률을 갖는 부류로 회전체의 상태를 할당하는 방법이다. 여기서 상태 $\hat{\pi}$ 의 사후 확률은 다음과 같은 베イズ 정리에 의해 구할 수 있다.

$$p(\hat{\pi}|x) = \frac{p(x|\hat{\pi})P(\hat{\pi})}{\sum_{j=1}^g p(x|\pi_j)P(\pi_j)} \quad (2)$$

여기서 $P(\hat{\pi})$ 는 회전체 상태 $\hat{\pi}$ 의 사전 확률이다. 식(2)의 분모항은 생략될 수 있으므로 베イズ 판별규칙은 상태의 조건부 확률밀도함수 $p(x|\hat{\pi})$ 와 사전확률 $P(\hat{\pi})$ 의 추정방법에 의존하게 된다. 각 회전체 상태에 대한 확률밀도함수와 사전 확률을 알고 있다면 베이지 정리와 같은 모수적인 방법에 의하여 최적의 분류결과를 얻을 수 있다. 그러나 확률밀도 함수와 사전확률을 구하기 위한 데이터가 부족하여 모수적인 방법에 의한 고장 진단은 현실적으로 불가능한 경우가 많다. 이런 경우에 적용할 수 있는 방법이 비모수적인 방법이다. 비모수적 방법에는 히스토그램 방법과 커널 윈도우 방법과 같이 확률밀도함수를 추정한 후 베이지 정리를 적용하는 방법이 있고, 확률밀도함수가 필요 없이 거리가 가장 가까운 패턴으로 미지의 패턴을 분류하는 k-최근접 이웃 분류방법⁽¹¹⁾이 있다.

2.1. 모수적인 방법

사전확률 $P(\pi_k)$ 는 일반적으로 훈련집합에서 각 상태의 크기 비율로 쉽게 추정될 수 있는 반면에 각 회전체 상태에 대한 분포에 대한 정보를 얻기는 매우 힘들다. 그래서 회전체 상태 π_k 에 대하여 평균 벡터 μ_k 와 공분산 행렬 Σ_k 를 갖는 다변량 정규 분포를 가정하여 유도된 판별함수를 가장 많이 사용하고 있다. 다변량 정규 분포식을 식(2)에 대입하면 다음과 같은 이차형 판별함수(Quadratic Discriminant Function : QDF)를 얻을 수 있다.

$$d_i(x) = \min_{1 \leq k \leq g} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + \ln |\Sigma_k| - 2 \ln P(\pi_k) \quad (3)$$

만약 각 상태에 대하여 공분산 행렬을 동일하

다고 가정할 수 있다면 식(3)의 이차항은 생략 가능하여 다음과 같은 선형판별함수(Linear Discriminant Function : LDF)를 얻을 수 있다.

$$d_i(x) = \min_{1 \leq k \leq g} -2\mu_k^T \sum^{-1} x + \mu_k^T \sum^{-1} \mu_k - 2\ln P(\pi_i) \quad (4)$$

이때 모수 평균 벡터 μ_i 와 공분산 행렬 Σ 에 대한 추정량으로 다음과 같은 최우추정량(MLE)을 많이 사용한다.

$$\hat{\mu}_k = \bar{x}_k = \frac{1}{n_k} \sum_{j=1}^{n_k} x_{k,j} \quad (5)$$

$$\hat{\Sigma} = \sum_{k=1}^g \frac{n_k}{n} \hat{\Sigma}_k = \frac{1}{n} \sum_{k=1}^g \sum_{j=1}^{n_k} (x_{k,j} - \mu_k)(x_{k,j} - \mu_k)^T \quad (6)$$

여기서 $x_{k,j}$ 는 상태 π_k 의 j 번째 패턴을 가르키며, n_k 는 상태 π_k 의 크기, 그리고 n 은 총 훈련집합의 크기를 나타낸다.

2.2 비모수적인 방법(k-NN 분류 규칙)

지금까지는 각 상태의 분포를 가정하는 베이즈 판별 규칙에 대해 설명하였다. 그러나 실제 문제에서는 각 상태의 분포를 가정할 수 없는 경우가 많다.

Fix 와 Hodges 가 제안한 k-최근접 이웃 분류 방법은 베이즈 결정 규칙에서 사후 확률 $p(\pi_i|x)$ 를 바로 추정하는 방법이다.

$$x \rightarrow \pi_j, \text{ if } k_j = \max_{1 \leq i \leq g} k_i \quad (7)$$

여기서 k_i 는 패턴 x 와 근접한 k 개의 이웃중 상태 π_i 에 소속된 훈련 패턴의 개수이다. 이때 우리가 무한 훈련집합을 가정하면 k_i/k 는 상태 π_i 의 사후확률 $p(\pi_i|x)$ 의 불편추정량이 된다.

3. 신경망을 이용한 분류 방법

인공 신경망은 패턴인식분야에서 매우 효과적인 도구로 인정 받고 있다. 생물학적 신경망을 모델링 하고자 하여 만들어진 인공 신경망은 비교적 간단하면서도 전형적인 수많은 비선형 유니트들이 상호 연결된 네트워크로 구성되어 있다. 신경망은 각각의 학습 표본들에 대해서 올바른 출력을 하도록 학습이 된다. 여기서 학습이란 특정문제에 대한 입력이 주어졌을 때 원하는 출력이 나오도록 연결강도를 조정하는 과정을 말하며 출력값을 미

리 알려주는지 여부에 따라 시도형 학습과 비지도형 학습으로 크게 구분할 수 있다. 학습후에 인공적으로 구현된 신경망의 내부구조는 학습 집합으로부터 얻은 경험에 바탕을 두고 새로운 유사 패턴들이 주어질 경우에 그 패턴을 추정할 수 있도록 자기 조직화된다. 여러 종류의 신경회로망이 존재하지만 본 연구에서는 역전파 학습알고리즘을 채택한 전방향 다층 신경회로망모델을 이용하였다. 공식적인 통계에 의하면 신경망 모델중 85% 이상이 이 모델을 사용하고 있다⁽¹¹⁾

3.1 전방향 다층퍼셉트론 신경망

전형적인 전방향 다층 퍼셉트론 신경망은 입력층(Input Layer), 은닉층(Hidden Layer)과 출력층(Output Layer)으로 구성된다. 입력층과 출력층의 노드수는 패턴 분류 하고자 하는 문제의 성질에 따라 결정된다. 즉 입력층은 입력 특징의 차원수 만큼에 해당하는 뉴런수를 갖고 출력층은 분류하고자 하는 클래스 수만큼의 뉴런수를 갖는다. 은닉층의 수와 뉴런수는 실험을 통하여 결정한다. 각 뉴런은 그림 1과 같은 과정을 거쳐 출력값이 결정된다.




Fig. 1 Operation of an artificial neuron in a layer

먼저 각각의 입력값(X_i)을 그에 해당하는 연결강도(W_i)와 곱한 후 모두 합한 다음 다시 바이어스와 합한다. 바이어스는 계산된 값을 원점으로 부터 이동시켜주는 역할을 한다. 계산된 NET 값에 활성화 함수를 적용하여 최종 출력값을 계산한다. 활성화 함수는 노드 출력이 0에서 1 사이의 값을 같도록 제한한다. 결국 각 뉴런의 최종 출력값은 다음과 같이 쓸 수 있다.

$$OUT = f(NET) = f\left(\sum_{i=1}^n W_i X_i + \theta_i\right) \quad (8)$$

본 연구에서는 입력 특징 벡터를 정규화 하기 위하여 학습 데이터 중 절대값이 가장 큰 값으로

특징 벡터를 나누어 주었다. 결국 신경망의 입력은 (+1,-1)사이의 값이 된다.

학습 과정을 통해 출력값과 목표값의 차이에 대한 SSE(Sum-squared Error)가 최소가 되도록 가중치를 조정한다. 역전파 학습 알고리즘⁽¹²⁾은 학습 정보가 역방향으로 진행을 하면서 신경망 학습이 이루어지기 때문에 역전파 학습이라하며 SSEG(Sum-squared Error Goal) 값이 원하는 허용한도에 들어 올때까지 학습이 계속된다.

역전파 학습알고리즘이 수렴하는데 크게 영향을 미치는 파라미터는 초기 가중치(Initial Weights), 학습율(Learning Rate), 신경망 구조(히든층의 개수, 각층의 뉴런수)등 이다. 이러한 값들은 실험을 통해 모수의 최적화를 실현하여야 한다.

4. 특징 추출

진동 신호를 곧바로 패턴 분류기의 입력으로 사용할 수 없으므로 특징 벡터를 추출하여 분류기의 입력으로 사용한다. 본 연구에서는 회전 기계 고장 진단에 일반적으로 사용되는 시간 영역 특징을 이용하여 고장 진단을 시도하였다.

- RMS(Root Mean Square)

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - u)^2} \quad (9)$$

- 첨도(Kurtosis Value)

$$k = \left[\int_{-x}^x (X - u)^4 p(x) dx \right] / \sigma^4 \quad (10)$$

- 파고율(Crest Factor)

$$Cf = \frac{Peak}{RMS} \quad (11)$$

- 3 차 중심적률

$$E([X - u]^3) = \int_{-x}^x (X - u)^3 p(x) dx \quad (12)$$

- 5 차 중심적률

$$E([X - u]^5) = \int_{-x}^x (X - u)^5 p(x) dx \quad (13)$$

5. 실험 장치의 구성

본 연구의 실험 장치 구성은 아래 그림 2와같이 되어 있다. 회전 기계가 비정상적으로 작동할 때 발생하는 현상을 벤틀리 네바다 로터 키트

(Bently Nevada Rotor Kit)를 이용하여 인위적으로 만들어 주었다. 발생된 신호를 DSP 보드를 이용하여 A/D 변환하고 컴퓨터에 저장하였다. 본 연구에서는 아래와 같은 4 가지 조건에 대하여 상태 분류를 시도하였다.

- ① 정상 상태
- ② 러빙만 발생하도록 한 상태
- ③ 불평형만 발생하도록 한 상태
- ④ 러빙과 불평형을 동시에 발생하도록 한 상태

각 상태별 실험 방법을 살펴 보면 아래와 같다.

불평형 상태는 축에 달려 있는 디스크의 구멍에 질량(0.2g, 0.8g, 1.2g)을 추가하고 진동신호를 취득하였다. 러빙 상태는 러빙 나사(Rub Screw)를 이용하여 하우징 부위에 있는 구멍에 러빙 나사를 돌려(러빙의 정도를 변화시켜가며) 신호를 취득하였다.러빙과 불평형이 동시에 존재하는 상태는 1 과 2 의 두 가지 상태를 동시에 회전체에 만들어 주었다.




Fig. 2 Schematic diagram of experimental set up

수평 수직 진동을 측정하기 위하여 에디커런트 타입(Eddy Current Type)의 변위센서를 X, Y 축에 90°의 각도로 설치하였고 5KHz로 신호를 샘플링 하였다.

신호는 3600RPM 에서 각 상태당 60000 개씩 진동 신호를 취득하였다. 각 상태별로 취득한 데이터 60000 개중 40000 개는 학습용으로 나머지 20000 개는 테스트 용으로 사용하였다.

6. 실험 결과 분석

6.1 취득된 진동 신호의 고찰

회전체 상태별로 취득된 진동 신호를 그림 3~6에 나타내었다. 그림 3의 6개의 영역중 ③은 오빗이다. 이 오빗의 패턴을 주의 깊게 관찰함으로써 회전체의 상태를 관성할 수 있다⁽¹³⁾. 회전체 상태별로 오빗 그림을 비교해 보면 정상 상태보다 불평형 상태일 때 원의 반경이 커짐을 확인할 수 있다. 러빙이 존재하면 8자 모양의 패턴을 갖는다. 그림 3의 ①(X축), ④(Y축)영역은 진동 신호의 시간 영역 값을 나타낸다. ②(X축), ⑤(Y축) 영역은 주파수 분석 결과를 나타낸다. 스펙트럼 결과를 고찰해 보면 정상일때는 1X 성분만 나타난다. 불평형이 존재하면 다른 주파수 성분은 생기지 않고 1X 성분이 정상상태 보다 더 커졌다. 러빙이 존재하면 2X, 3X 등의 배수 주파수 성분이 발생함을 확인할 수 있다. 이런 사실은 이미 익히 알려진 사실이다⁽¹³⁾. 그림 3의 ⑥영역은 취득된 신호의 RMS와 PEAK 값을 보여준다. 신호 취득 프로그램은 DSP Board와 Visual C++을 이용하여 작성하였다.




Fig. 3 Vibration signal of normal condition




Fig. 4 Vibration signal of rubbing condition




Fig. 5 Vibration signal of unbalance condition




Fig. 6 Vibration signal of rubbing and unbalance condition

6.2 회전 기계 상태 인식 결과

6.2.1 통계적 인식 기법에 의한 진단

모수적인 방법으로는 LDF와 QDF를 사용하였다. LDF와 QDF에서 각 상태의 사전확률을 0.25로 주었다. 정규성과 등분산성을 가정하여 얻는 LDF에서는 25%의 낮은 인식율을 보였다. 이는 자료가 등분산성이라는 가정을 만족하지 않기 때문이다. 정규성만을 가정한 QDF에서는 87.5%의 인식율을 보였다. QDF가 LDF보다 높은 인식율을 보이는데 이는 가정이 좀더 현실적이기 때문으로 생각된다.

비모수적 방법으로는 k-NN을 사용하였다. k-NN에서 k값이 인식율에 미치는 영향을 조사하는 실험을 하였다. 거리는 유클리드 거리를 이용하였다. 실험결과를 그림 7에 나타냈다.




Fig. 7 Convergence of recognition rate with different k number

전반적으로 k 값이 증가함에 따라 인식율이 향상되었고 20-NN 이상이 되면 오히려 인식율이 떨어졌다. 13-NN 에서 5 가지 파라미터에 대한 인식율의 평균이 가장 높았다. 자료에 대한 어떠한 가정도 없이 사후확률을 직접 추정하는 13-NN 을 적용한 결과 93.4%의 인식율을 얻었다. 통계적인 패턴인식 방법중 k-근접 이웃 결정 규칙이 가장 좋은 인식율을 보여 주었다. 이는 자료에 대한 어떠한 가정도하지 않기 때문으로 사료된다. 그러나 패턴 분류 시간면에서 보수적인 방법은 학습 패턴 수의 영향이 없으나 k-NN 은 학습 데이터수에 비례하여 계산시간이 증가하는 단점을 보였다.

Table 1 Recognition success rate

실험 방법	인식율
LDF	25%
QDF	87.5%
k-NN	93.4%

6.2.2. 신경회로망을 이용한 인식 결과

본 연구에서는 $5 \times 30 \times 30 \times 4$ 구조의 다층퍼셉트론(MLP)을 이용하여 회전기계의 4 가지 상태 분류를 시도하였다. 첫번째 숫자는 입력 특징의 숫자(입력층 뉴런수)를 나타내고, 마지막 숫자는 출력층의 뉴런수를 나타낸다. 입력층과 출력층 사이의 숫자는 은닉층의 뉴런수를 나타낸다. 신경망

의 출력층은 4 개의 뉴런으로 구성되어 있다. 각 뉴런은 회전체의 각 상태(정상 상태, 러빙, 불평형, 러빙과 불평형 동시 존재)를 대표한다.

학습 파라미터 SSEG(Sum-squared Error Goal)는 0.5 로 학습율(Learning Rate)은 0.01 로 설정한후 신경망을 학습시켰다. 학습을 위한 출력층의 목표값은 아래 표 2 과 같이 설정하였다.

Table 2 Target vectors for output layer

회전체 상태	출력층
정상 상태	(1, 0, 0, 0)
러빙	(0, 1, 0, 0)
불평형	(0, 0, 1, 0)
불평형, 러빙	(0, 0, 0, 1)

학습 과정중 SSEG(Sum-squared Error Goal)은 0.5 로 설정하고 학습율은 0.01 로 설정한 후 신경망을 훈련시켰다. 학습에 사용하지 않은 진동 패턴을 신경망에 입력하여 4 개의 출력 뉴런중 가장 큰 값을 갖는 뉴런이 대표하는 상태로 회전체의 상태를 판정한 결과 인식율은 94.7%였다.

이 결과는 비교적 우수하지만 신경망이 최적으로 학습되었다고는 볼 수는 없다. 그러나 통계적 방법중 가장 우수했던 13-NN 보다 인식율이 높았다. 그러나 신경망이 최적으로 학습되었다고는 볼 수는 없다. 성공적인 신경망을 구성하기 위해서는 히든층의 수와 뉴런수가 중요한 인자중의 하나이다. 신경망 구조가 학습에 미치는 영향을 조사해 보고 최적의 망구조를 결정하기 위해 표 3 과 같은 구조로 된 신경망을 이용한 실험을 실시하였다. 객관적으로 비교하기 위해 초기 가중치와 바이어스는 같은 값을 갖게 하고 신경망을 학습시켰다.

Table 3 Neural network architectures and recognition rate

신경망 구조	인식율(%)
$5 \times 10 \times 4$	89.8
$5 \times 20 \times 4$	94.5
$5 \times 30 \times 4$	96.1
$5 \times 10 \times 10 \times 4$	93.8
$5 \times 20 \times 20 \times 4$	96.6
$5 \times 30 \times 30 \times 4$	94.7

전반적으로 신경망의 인식율이 k-NN 보다 높았다. 뉴런수를 늘린다고 해서 인식율이 계속 향상 되지 않음을 실험을 통해서 확인할 수 있었고 학습이 잘못된 경우에는 오히려 k-NN 보다 인식율이 좋지 못했다. 신경망은 실험을 통해 모수의 최적화를 실현하여야 한다. k-NN 은 학습 데이터가 많아 질수록 속도가 느려지는 단점을 보였으나 신경망은 학습 과정과 판별과정이 분리 되어 이루어지기 때문에 패턴 분류는 학습 데이터수에 상관없이 빨리 수행할 수 있었다.

7. 결론

본 논문에서는 회전 기계 고장 진단에 통계적 방법과 신경망 기법을 적용하여 인식 결과를 비교 연구하였다.

- (1) 실험에 사용된 방법중 MLP 가 가장 높은 인식율을 보였다. 일반적으로 통계적 방법보다 신경망이 높은 인식율을 보였다.
- (2) 통계적 방법중에서는 k-NN 이 가장 높은 인식율을 보였다. k-NN 은 분포에 대한 어떠한 가정도 하지 않기 때문으로 사료된다. LDF 와 QDF 는 낮은 인식율을 보였지만 이들은 회전체 각 상태에 대한 사후 확률을 추정해주는 장점을 가졌다.
- (3) 신경망은 학습에 전적으로 의존하므로 실험을 통해서 모수의 최적화를 실현하여야만 했다. 잘못 학습된 신경망은 k-NN 보다 인식율이 좋지 못하였다.
- (4) k-NN 은 학습 데이터가 많아질수록 속도가 느려지는 단점을 보였다. 실시간 패턴 분류에는 k-NN 보다 신경망이 적합하리라고 사료된다.

참고문헌

1. 이정철, "고정도 스펙트럼 해석법에 의한 회전 기계의 이상진단에 관한 연구" 한양대학교 대학원 박사학위논문, 1995.
2. J. T. Renwick "Vibration analysis - a proven technique as a predictive maintenance tool," IEEE Transactions on Industry Applications, Vol. 21, pp. 324-332, March 1985.

3. 정승호, 박영필, "진동신호를 이용한 볼 베어링의 결함진단에 관한 연구," 대한기계학회논문집 제 19 권 제 12 호, pp. 3260-3269, 1995.
4. A. C. McCormick and Nandi A.K., "Rotating machine condition classification using artificial neural networks" Preceeding of COMADEM '96, pp. 85-94, University of Sheffield, July 1996.
5. A. C. McCormick and Nandi A.K, "Classification of Rotating Machine Condition using Artificial Neural Networks," Proceedings of the Institution of Mechanical Engineers: Part C, Vol. 11 No. 6, pp. 439-450, 1997.
6. B.A. Paya, I.I.Esat and M.N.M.Badi, "Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as preprocessor," Mechanical Systems and Signal Processing, Vol. 11(5), 751-765, 1997.
7. T. I. Liu and J. M. Mengel, "Intelligent monitoring of ball bearing conditions," Mechanical Systems and Signal Processing, Vol. 6(5), 419-431, 1992.
8. 유송민, 김영진, 박상신, "볼베어링으로 지지된 회전축의 이상상태 진단을 위한 진단전문가 시스템의 개발," 한국정밀공학회지, 제 15 권, 제 11 호, pp. 218-226, 1998.
9. 김창구, 박광호, 기석호, 기창두 "복소 시계열 모멘트의 신경회로망 적용에 의한 회전기계 상태 진단" 한국소음진동공학회 1998년도 추계학술대회 논문집, pp. 527-531, 1998.
10. 이성로 "신경망회로망을 이용한 회전기계의 이상 진단" 포항공과대학교 대학원 석사학위논문, 1994.
11. P.D. Wasserman, "Advanced Methods in Neural Computing" Van Nostrand Reinhold 1993.
12. Chin-Teng Lin and C.S. George Lee, "Neural Fuzzy Systems" Prentice-Hall International Inc 1996.
13. 배용채, "터빈이상 진동의 자동 진단 시스템에 관한 연구" 전남 대학교 대학원 박사학위논문, 1995.