

뉴로-퍼지 알고리즘을 이용한 이상진단 시스템에 대한 연구 (A Study on Neuro-fuzzy Diagnostic System)

박제현, 김영진 (경희대학교)

Je-Hyun Park, Young-Jin Kim, (KyungHee University)

경기도 용인시 기흥읍 서천리 1번지 경희대학교 기계·산업시스템공학부 산업공학전공

Abstract

현재 공작기계의 상당부분에서 자동화 및 무인화가 이루어지고 있는 추세이며, 이러한 대부분의 산업시설들과 기계류에는 회전체 부품들을 가지고 있다. 이들 부품들에서 베어링(Bearing)은 절대적으로 매우 중요한 부분을 차지하고 있으며, 만일 회전축시스템(Rotor System)에서 베어링의 심각한 이상은 시스템이 정지되는 사태를 불러일으킬 수도 있다. 따라서 이상에 대한 조기감지의 역할은 전체 시스템의 향상뿐만 아니라, 비용이나 시간적인 측면에서도 크나큰 이익을 가져다 줄 수 있다.

지금까지 이러한 회전축시스템에 대해 다양한 이상진단을 시도하여 왔으며 앞으로도 많은 종류의 이상진단이 이루어지리라 생각한다. 이런 다양한 형태의 이상진단은 시스템에서 추출되는 데이터를 여러 가지 기법과 추출하는 센서의 특징을 파악하여 이상진단 알고리즘을 수립하는 과정을 망라하게 된다. 특히 이상진단 알고리즘에는 측정된 데이터의 불확실성을 감안한 이론이 적용되어야 한다.

본 논문에서는 회전축시스템의 베어링에 대한 이상진단을 통계적 기법, Fuzzy Clustering, Neural Network과 Neuro-fuzzy를 이용한 기법과의 상호비교를 통해서 여러 종류의 이상을 구분하는 작업수행을 연구하고자 한다.

1. 서론

CIM/FMS(Computer Integrated Manufacturing / Flexible Manufacturing System)의 실현을 위해서는 공작기계의 자동화 및 무인화가 요구되며, 이에 따른 요소기술 중의 하나가 시스템에 대한 이상유무를 판단하는 이상진단 기술이다. 대부분 산업 기계류들은 베어링(Bearing)을 기본으로 한 회전축시스템(Rotor System)으로 구성되어 있으며, 이러한 회전체 시스템의 고장 및 파손은 엄청난 손실을 초래하게 된다. 그러므로 베어링으로 지지된 회전축의 회전체시스템의 고장을 조기에 진단하고 대책을 수립하여 고장에 의한 경제적 손실을 최대한도로 줄이고자 하는 노력이 계속 시도되어 왔으며, 이상을 진단할 수 있는 데이터베이스의 구축과 진단시스템의 개발은 필수적이라 하겠다. [1]

본 논문에서는 베어링의 센서를 통해 얻어진

정상상태의 신호와 비정상상태의 신호를 추출하여 진단데이터 베이스를 구축하고 이를 여러 가지 판단 알고리즘에 적용시켜 결합의 부위 및 결합정도를 상호 비교를 통해서 좀더 효과적인 자동진단 방법을 개발하고자 한다. [2]

또한 Neuro-fuzzy를 이용함으로써 지금까지 시행되어진 다양한 추론방법과 상호비교를 통해서 정확성에 대한 성능을 비교 분석하고자 한다.

2. 다양한 베어링 진단 기법

베어링 이상유무에 대한 진단방법으로는 일반적으로 회전체축의 진동이나 변위측정, 윤활 상태의 감시 및 윤활유 온도 측정, 베어링의 온도 측정, 그리고 소음측정 등을 사용하여 항시 감시하거나 유지보수 기간을 이용하여 주기적인 점검을 하고 있는 설정이다. 또한 운전 중 또는 정지 중에 여러 종류의 파괴 또는 비파괴 시험들이 실시되고 있기도 하다. 이러한 진단방법들은 설비의 형태에 따라 다소 차이가 있으나 적용이 불가능하거나 설치가 용이하지 않은 점들로 인해 일부 기술만을 사용하거나 감시하고 있지 않는 베어링들도 매우 많다고 볼 수 있다. 더욱 중요한 것은 베어링의 손상이 어느 정도 나타났을 경우에 고장을 감지할 수가 있다는 것이다. 특히 고속, 고온, 고압 등의 조건 하에 사용되는 베어링의 경우, 단시간에 손상이 진행될 수 있으며, 급격한 속도로 파손에 이를 수 있으므로, 베어링 손상의 조기 감지는 매우 중요하다 할 수 있다.

베어링의 이상진단은 일반적으로 회전으로 발생한 진동신호가 기계의 상태에 대한 정보를 많이 내포하고 있고, 측정하기가 비교적 용이하여 베어링의 결합진단에 많이 이용되고 있다. 현재 최근까지의 연구 동향은 음향방출(Acoustic Emission : AE) 센서를 이용하여 비정상상태와 정상상태에서의 진동 신호를 분석하여 이를 샘플 데이터와 비교하는 방식이 주를 이루었으나 회전축시스템이 갖는 비선형적 특성을 해석하기에는 부족하기 때문에 이 논문에서는 다양한 휴리스틱 기법의 소개와 함께 Neuro-fuzzy 기법과의 비교를 통한 적절한 진단방법을 제시하고자 한다.

2.1 통계적 방법을 이용한 진단

통계적 방법을 이용하는 목적은 센서 데이터

가 불확실한 값을 가지고 있기 때문이다. 즉, 데이터에는 센서 자체의 나올 수 있는 오류값과 시스템 자체에서 발생할 수 있는 오류값이 동시에 전체적인 오류값을 형성하므로 이와 같이 오류값이 내재된 데이터에 대한 특정 추출은 통계적 처리를 통하여 가장 효과적으로 수행되어질 수 있다. [3] 회전축시스템의 결합여부를 판정하기 위해서는 먼저 센서를 통해 수집된 진동신호로부터 결합여부를 잘 나타내는 파라미터를 추출한 다음, 판단(또는 분류) 알고리즘에 따라 이 파라미터 값이 정상 상태의 집단에 속하는지 아니면 비정상상태의 이상집단에 속하는지를 판단하여야 한다.

따라서 이러한 결합진단의 효율성은 파라미터 추출방법 및 판단방법에 따라 그 결과값이 좌우된다. 파라미터 추출방법에는 음향방출(AE) 센서와 가속도(Acceleration : ACC) 센서가 활용되어진다. [4], [5]

음향방출(AE) 센서와 X방향, Y방향, Z방향의 각 세 방향에서 얻어진 가속도(ACC) 센서의 원시 데이터를 각각의 정상상태와 비정상상태에 대해서 평균값(μ)과 표준편차(σ), 그리고 RMS(Root Mean Square)를 구함으로써 그 특성을 얻을 수 있다.

$$RMS = \sqrt{\frac{1}{n} \sum_i (x_i - \mu)^2} \quad (1)$$

이 때 x_i , μ 와 n 은 각각 측정 데이터값, 평균과 계산 데이터 수를 나타낸다.[5]

기준 데이터들의 특징을 결정하는 인자는 AE, Acc-X, Acc-Y, Acc-Z에 대한 센서의 종류와 센서의 위치에 대한 데이터와 RPM의 변화에 대한 데이터 등이 있다. 따라서 실험 데이터를 취하는 경우의 수는 센서의 종류, 센서의 위치, RPM의 종류의 조합으로 얻어진다.

2.2 Fuzzy Clustering을 이용한 진단

Fuzzy 이론은 인간의 언어 및 사고에 관련된 애매함(Fuzziness)을 수리적으로 취급이 가능하도록 한다. 이것은 전통적인 논리 시스템보다 실제 세계의 근사적(Approximate)이고 부정확한(Inexact) 성질을 표현하는데 더 효과적이다. 임의의 복잡성(Complexity)을 가지는 비선형 함수를 모델링할 수 있고, 이러한 이론은 전문가의 경험이나 지식을 사용하여 구현될 수 있다.

이러한 Fuzzy Clustering을 활용한 이상진단에서는 Fuzzy c-Means(FCM) 기법을 이용한 알고리즘을 사용하였으며 그 개요는 다음과 같다.

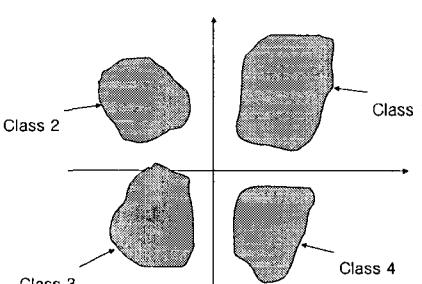


Fig. 1. General Fuzzy Clustering

클러스터링(Clustering) 기법의 주목적은 Fig 1.에서 보는 바와 같이 주어진 자료집합을 유사한 클러스터(Homogeneous Cluster)로 나누는 것이다. 여기서 유사하다는 것은 자료들 간의 특징에 대해 나타내고 있는 벡터공간상에서 같은 그룹 내 모든 점들이 서로 근접하고 다른 그룹의 점들과 멀리 떨어져 있다는 것을 의미한다. 클러스터링 알고리즘은 패턴 부류들을 만들거나 관련된 정보를 유지하도록 하면서 자료 집합의 크기를 줄이기 위해 사용될 수 있다.

어느 상황 하에서 데이터의 집합을 균등한 요소로 단순히 분할하는 것 뿐 아니라, 그 분할된 각 클러스터들을 잘 대표하는 원소를 찾기를 원하는 경우가 있다. 이를 위해 구현된 알고리즘이 Fuzzy c-Means 알고리즘이다. 클러스터링 기법은 데이터 집합 X 와 분할 행렬 U 를 연결한 것에 지나지 않으며, Fuzzy c-Means 알고리즘에서는 최적의 U 를 구하기 위해 다음과 같은 제곱 오차 합을 목적함수로 한다. [6]

$$J_m(U, v) = \sum_{j=1}^n \sum_{k=1}^c (u_{kj})^m \|x_j - v_k\|^2, \quad 1 \leq m \leq \infty \quad (2)$$

위의 제곱 오차 합을 극소(최소)로 하는 u_{kj} 와 v_k 는 $m > 1$ 에 대해 다음 조건을 만족한다.

$$u_{kj} = \left[\sum_{g=1}^c \left(\frac{\|x_j - v_g\|}{\|x_j - v_k\|} \right)^{\frac{2}{m-1}} \right]^{-1}, \quad \forall j, k \quad (3)$$

$$v_k = \frac{\sum_{j=1}^n (u_{kj})^m x_j}{\sum_{j=1}^n (u_{kj})^m}, \quad \forall k \quad (4)$$

2.3 Neural Network을 이용한 진단

Neural Network은 여러 가지 현상에 대한 적절한 판단을 유도하기 위한 것으로 함수로 표현하기 어려운 문제인 비선형적인 사상문제나 입출력간의 관계들을 해결하는 좋은 도구로 인식되고 있어 많은 연구와 함께 실용분야에서 그의 활용영역을 넓히고 있는 분야이다. Neural Network은 현상에 대한 분류 및 학습능력이 우수하고 외란에 대한 억제능력을 보유하고 있으며, 유연성을 보이고 있다. 또한 많은 양의 학습데이터가 제공될 수 있는 본 연구와 같은 진단 학습에 탁월하다는 것이다. Neural Network은 상호 연결된 병렬처리소자의 집합체로 생각할 수 있으며, 처리 소자 사이의 연결 강도는 Neural Network이 부여하는 정보의 중요성을 나타낸다.

Neural Network을 이용한 학습 방법에는 여러 가지가 있으며 가장 일반적으로 사용되는 것으로서 출력층의 오차(Error)를 처음 부분으로 전달하여 연결층의 가중치(Weight Factor)를 결정하는 역전파 알고리즘(Backpropagation Algorithm)이 있다. 이 Backpropagation 기법은 델타법칙(Delta Rule)을 일반화한 것으로 가장 일반적으로 사용되는 방법이다. 여기서 델타법칙이라 함은 Neuron의 요구된 출력값과 현재의 출력값 사이의 차이를 줄이기 위하여 끊임없이 두 Neuron 사이의 연결 강도를 수정하도록 하는 방법을 말한다. [7]

Backpropagation 기법은 두 가지의 단계로 나뉘는데, 첫 번째 단계는 전향 단계(Forward Phase)이다. 전향 단계에서는 각 뉴런에 입력이 들어와서 망으로 전파되고, 출력값이 계산된다. 각 뉴런에 대해서 모든 현재의 출력들은 원하는 출력과 비교되고, 그 차이인 오차값이 계산된다. 두 번째 단계는 후향 단계(Backward Phase)라고 부르는데, 두 번째 단계에서는 첫 번째 단계에서 얻어진 오차가 초기의 입력값으로 되돌려진다. 이 두 단계가 완료되어야만 새로운 입력이 뉴런들에 나타나게 된다. 일반적으로 이 기술은 세 개나 혹은 그 이상의 계층을 갖는 계층 구조적 망에 응용된다. 학습과정에서 주어진 목적치 (T_j)와 계산된 출력결과 (O_j)가 비교되어 오차 (E)가 계산된다. 즉

$$E = \frac{1}{2} \sum_j (T_j - O_j)^2 \quad (5)$$

이후에는 오차가 후방으로 전파되고 결과에 따라서 가중치가 다음의 변화된 식에 따라서 갱신된다.

$$\Delta w_i = [2K|X|^2] \frac{Ex_i}{|X|^2} \quad (6)$$

$$\eta = 2K|X|^2 \quad (7)$$

여기서 Δw_i 는 가중치변화량이고 η 는 학습률(Learning Rate)이다. 이러한 학습과정을 거치면서 초기에 무작위로 할당된 가중치는 사용자가 의도한 목표값에 적합하도록 수렴하게 된다. 학습이 종료되면 시험자료를 적용하여 Neural Network 시스템을 활용하게 된다.

2.4 Neuro-fuzzy를 이용한 진단 방법

Neuro-fuzzy Algorithm을 이용한 방법은 일반적으로 Fuzzy 인식기를 가지고 있는 3층 전방향 신경회로망 구조로 되어 있다. [8]

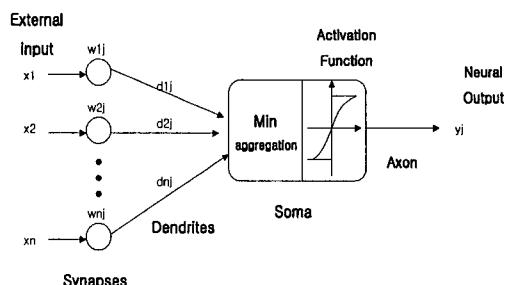


Fig 2. Neuro-fuzzy Simplified Model of Neuron as an Information Processor

패턴 분류(Pattern Classification)를 위한 Neuro-fuzzy 시스템은 입력 패턴으로부터 Fuzzy 규칙을 생성하는데 다음과 같은 단계를 거친다. 첫 번째 단계로 Fuzzy Clustering을 이용한 이상진단

방법에서도 살펴보았듯이 각각의 퍼지 클러스터링을 수행한 부분에 대한 데이터에는 센서 자체의 오류값과 시스템의 오류값이 동시에 전체적인 오류값을 형성한다. 이와 같이 오류값이 내재된 데이터에 대해서 식(8)에 의해서 각각의 클러스터의 95%의 신뢰구간을 적용시켜 $\pm 5\%$ 의 비신뢰 데이터를 처리함으로서 데이터에 대한 신뢰도를 높이고 여기서 얻어지는 데이터에 대해서 정상상태의 데이터와 비정상상태의 데이터를 정규분포의 최대치를 1로 하고 그에 대한 범위를 갖는 연속 구간으로 나눠서 해당되는 구간의 데이터값들을 선택하여 퍼지화(Fuzzification) 수행한다.

$$\frac{1}{\sqrt{(2\pi)\sigma}} e^{-\frac{1}{2} \left[\frac{(x-\mu)}{\sigma} \right]^2}, -2\sigma < x < 2\sigma \quad (8)$$

두 번째 단계로 Fig 2.에서 볼 수 있듯이 Dendritic 입력값은 Aggregation Operator에 의해서 이루어지는데 입력값과 가중치의 곱에 의해서 가장 작은 값 즉, 최소값을 선택하게 되어진다.

$$I_j = \bigwedge_{i=1}^n x_i w_{ij} \quad (9)$$

세 번째 단계로는 이러한 값을 출력층으로 보내서 Backpropagation Algorithm에 의해 수행되어지고 오차율(ϵ) 내로 수렴되어지면 멈추고 아니면 다시 처음 단계로 보내어져 변화된 가중치에 의해서 다시 계산되어지는 반복작업을 수행한다.

3. 시스템의 실험장치 및 실험과정

3.1 저널 베어링 실험장치

저널 베어링의 실험장치의 구성은 제작된 베어링을 기초로 하여 Fig 3.과 같이 베어링 진단 시험기를 설계하였다. 진단시험기를 제작하는데 다음의 사항을 고려하였다.

조립과 분해를 자주 해야 하므로 다루기 쉽고 무게가 적게 나가도록 만들었으며 모터의 진동에 관한 영향을 줄이기 위해 커플링을 사용하였다. 센서의 부착을 고려해 외부에서 기름을 공급하는 방식으로 기름 급유구가 필요하였다. Fig 3.에서 ①은 베어링용 하우징으로 위쪽에 오일 급유구를 설치하였다. ③은 베어링으로서 내경 30mm에 축과의 틈새는 35μm를 가지고 있도록 연마하였다.

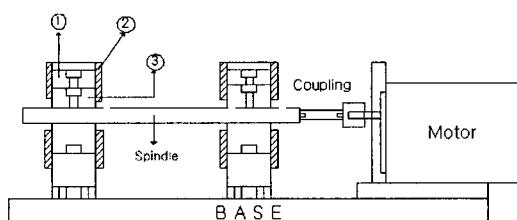


Fig 3. Schematic Diagram of the Rotor System

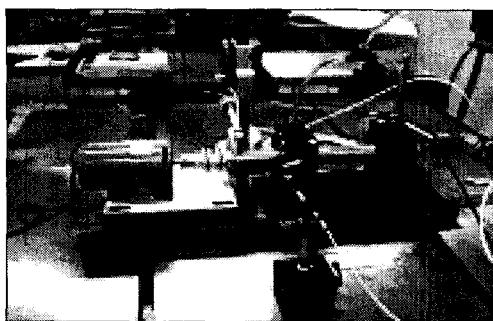


Fig 4. Journal Bearing Supported Rotor System.

그리고 ②번에 의해서 하우징과 고정이 될 수 있도록 하였다. 베어링 부품인 ③과 ①은 헐거운 끼워 맞춤을하도록 제작하였다.

Fig 4.는 축, 저널 베어링, 구동 모터, 커플링, 오일 공급장치 등이 장착된 저널 베어링 실험장치이다. [Yoo. S. M. , 1998]

3.2 실험과정

저널 베어링 실험장치로부터 진동 신호를 획득하기 위하여 가속도(ACC) 센서와 음향방출(AE) 센서, 그리고 비접촉식 Gap(근접) 센서가 사용되었다. 본 논문에 사용된 데이터 처리 시스템은 입력부, 중폭부, 신호처리부로 구성되어 있으며 입력부는 AE 센서, 가속도 센서, Gap 센서 등으로 이루어져 있다. 저널 베어링에 의한 회전축 시스템의 이상상태를 보기 위하여 저널 베어링에 다음과 같은 이상상태를 만들어 각각을 기록하였다.

N : 정상상태

F₀ : 비정상상태, 축방향 얇게 판 베어링

F₁ : 비정상상태, 축방향 깊게 판 베어링

F₂ : 비정상상태, 원주방향으로 판 베어링

실험은 1200 RPM에서 3600 RPM까지 600 RPM씩 증가하여 수행되었으며, 실험에 필요한 부분을 절단하거나 손상시킨 후 재조립하여 회전축을 지지하도록 함으로서 요구되는 비정상상태에 해당하는 운전조건을 인위적으로 조성하였다.

4. 실험 데이터의 분석 및 고찰

저널 베어링으로 지지된 회전축 시스템의 실험 데이터를 다양한 진단기법으로 분석하고 그 결과를 고찰한다. 본 논문에서 제안한 Neuro-Fuzzy 시스템은 2400 RPM에 대해서 음향방출(AE) 센서와 가속도(Acc) 센서에 대한 분류(Clustering)를 수행한다.

4.1 통계적 방법

여기에서 AE 센서의 Data와 Acc 센서의 X축, Y축, Z축 각 세 방향에 대한 Data로써 각각에 대한 이상진단에 필요한 분류로 사용되어진다. Fig 5.에서 보듯이 AE 센서의 경우에는 RPM의 증가의 따른 변화가 RMS와 무관함을 볼 수 있으며 상태

별 즉 N, F₀, F₁, F₂ 와 위치별(a, b, c, d 센서의 위치)로 차이가 난다는 것을 볼 수 있다. Acc 센서는 Fig 6.과 같이 RPM과 비례해서 커지는 것을 보이며 상태별(센서의 위치)로도 차이가 난다는 것을 알 수 있다. 위치에 따라 Acc 센서의 경우 b위치의 데이터 값이 상대적으로 작음을 볼 수 있다.

이렇게 얻어진 데이터를 통해 처리함으로서 N, F₀, F₁, F₂에 관한 Reference Data가 구해지고, Decision Matrix를 적용하여 결과를 찾는다.

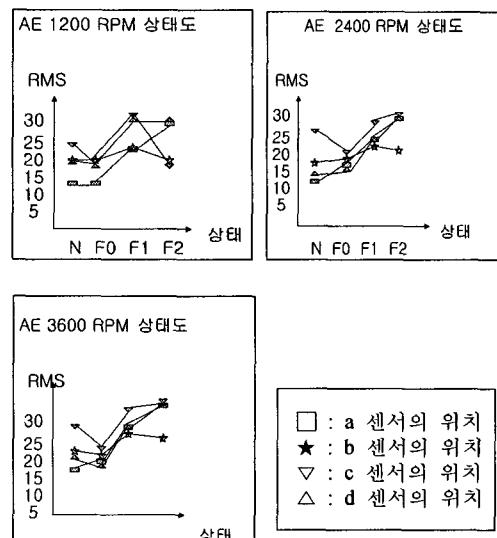


Fig 5. RMS Values of AE Sensors for Each RPM

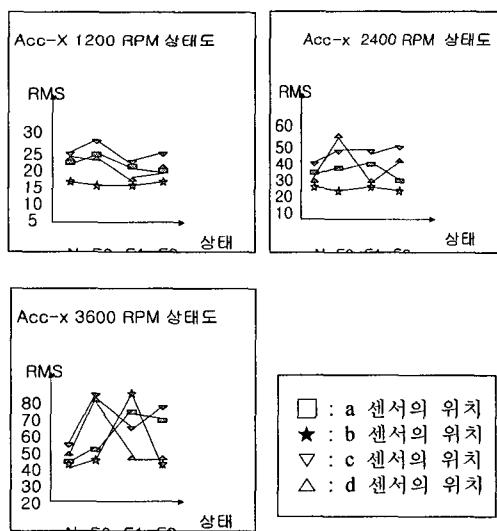
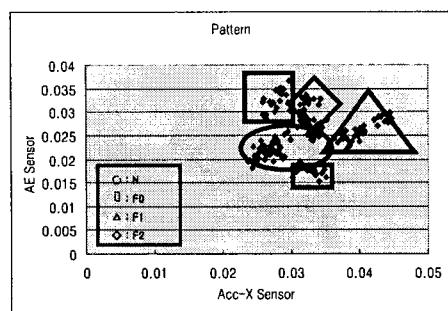


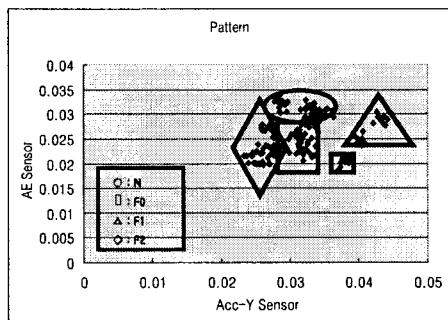
Fig 6. RMS Values of Acc-X Sensors for Each RPM

4.2 Fuzzy Clustering을 이용한 방법

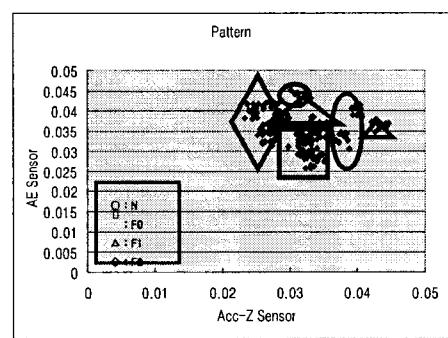
2400 RPM 데이터에 대해서 Fuzzy c-Means 기법을 적용하여 Fig 7.과 같이 AE 센서와 Acc 센서에 대한 클러스터링을 수행하였다. 여기서는 X축, Y축, Z축 방향 성분의 Acc 센서와 AE 센서의 RMS Data가 도시되어 있고, N, F₀, F₁, F₂에 대해서 서로 공통되어 접하는 부분이 존재하면서도 4개의 클러스터(Cluster)가 형성되고 있음을 보여준다.



(a) Fuzzy Clustering for X



(b) Fuzzy Clustering for Y



(c) Fuzzy Clustering for Z

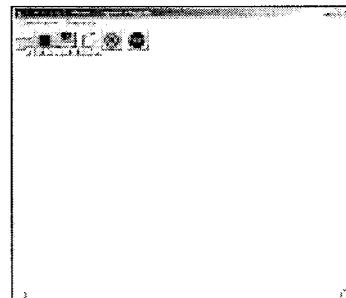
Fig 7. Fuzzy Clustering

Fig 8.에서 입력 변수 값에 군집은 4, 전체 데이터 집합인 n 은 768, 오차율 ε 은 0.001로 하였으며 가중치 변수 m' 는 2로 주어졌다. 이 입력은 Fuzzy Clustering Algorithm을 이용하여 Pattern Classification을 수행하고, 최적의 운전조건과 센서의 위치를 판별하여 전 처리기에서 처리된 데이터를 이용하여 Fig 8. (c)에 결과를 도시한다.

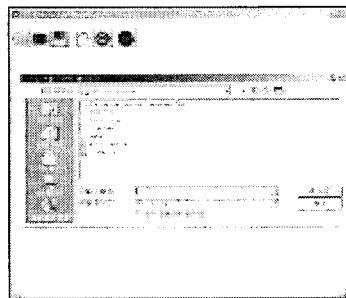
Sample Data에 대해서 검증한 결과 Class4에 속하는 부분의 Sample Data 값을 임의로 선택하여 Fig 8. (b)와 같이 텍스트 파일로 입력 받은 후 Iteration 한 결과 Class4에 속함을 Fig 8. (c)와 같이 프로그램 결과를 보여주고 있으며, 각 클러스터들의 중심값들이 매트릭스 형태로 계산되어져 나오는 것을 볼 수 있다.

그러나, Raw Data 값의 편차가 너무나 클 경우 각각의 클러스터간의 서로 교차하고 포함하는

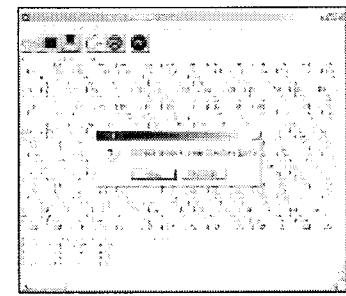
관계를 형성할 경우가 많다. 이러한 경우에는 이러한 알고리즘을 완벽히 수행하지는 못하는 부분이 나타나게 된다.



(a) Program Setup



(b) Call for Diagnosis Data



(c) Diagnosis

Fig 8. Program of Fuzzy c-Means Algorithm

4.3 Neural Network을 이용한 방법

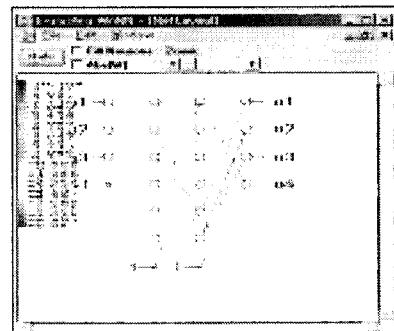


Fig 9. Architecture of WinNN

Neural Network을 이용한 방법도 마찬가지로

2400 RPM에 대해서 적용되며 WinNN이라는 Neural Network 프로그램을 이용하여 구현하였으며, 이 경우에 입력부는 3개의 Node로 구성되는데, 그것은 AE 센서, Acc-X, Acc-Y 센서에서 추출한 실험 테이터군이다.

Fig 9.에서는 $3 \times 6 \times 6 \times 4$ 로 구성되어 있는 Neural Network의 Architecture를 보여주고 있다. Sample Data에 대해서 빠른 수렴을 보여줬으며 그 결과는 Fig 10.와 같이 학습률이 0.5인 경우에 학습 결과로 RMS Error가 0.004, Iteration이 24035를 보여주고 있다.

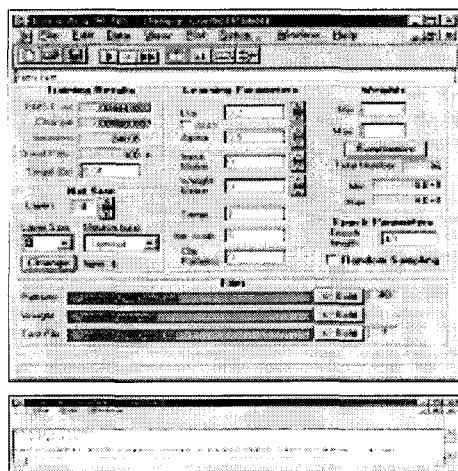


Fig 10. Results of Neural Network Program

4.4 Neuro-fuzzy를 이용한 방법

여기서도 앞서 보였던 방법들과 동일하게 2400RPM에 대한 전체 Raw Data값 6000개에 대하여 퍼지화(Fuzzification)한 값들에 의해서 500개씩 평균값을 선택하여 각각의 입력노드에 입력한다. Fig 11.에서 볼 수 있듯이 Neuro-fuzzy 시스템의 Architecture의 구성이 $4 \times 6 \times 4$ 로써 구성되어지며 Backpropagation Algorithm에 의해서 Neuron의 요구된 출력값과 현재의 출력값 사이의 차이를 줄이기 위하여 끊임없이 두 Neuron 사이의 연결강도를 수정하도록 프로그램에서 수행되어진다.

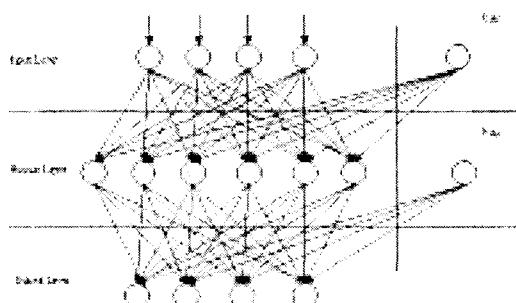


Fig 11. Neuro-fuzzy Architecture

Neuro-fuzzy 시스템에 대한 실행화면인 Fig 12.은 Data가 텍스트 파일을 통해 N, F_0 , F_1 , F_2 에 대해서 입력값을 받아들인다. 또 학습률(Learning Rate) 0.3과 Threshold 0.3의 오차율을 수행시키고 반복회

수(Iteration)를 10000번으로 입력시키고 4가지 상태의 데이터를 입력 받는 부분과 이를 학습시켜 수렴하게 하는 부분으로 나뉘어 Simulation을 수행시킨다.

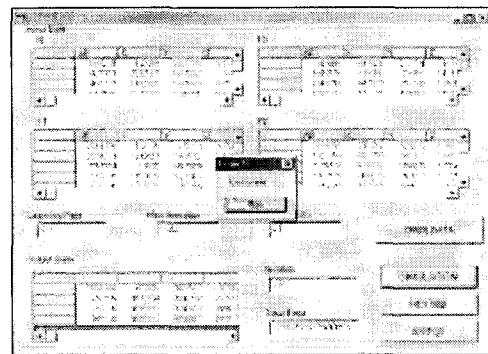


Fig 12. Input of Neuro-fuzzy Program

Fig 13.에서 볼 수 있듯이 Neuro-fuzzy 시스템이 회전축 시스템에 대한 특징분류에 새로운 제안으로써 Windows 프로그램으로 구현하였다. 결과에 대한 화면은 전체 데이터에 대해서 수행시킨 결과를 기반으로 하여 임의로 Sample Data를 추출하여 실험한 결과를 보여준다. 정상상태의 데이터를 추출하여 실험하였으며 그것이 정상데이터에 해당하는 값을 보였다.

실험결과 오차율 2.99 반복회수 550번을 수행한 끝에 정확한 값으로 수렴함을 Fig 13.에서 볼 수 있다.

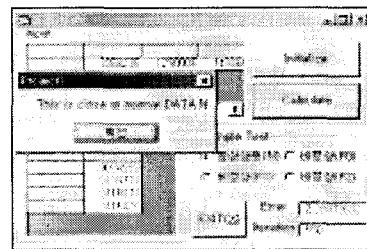


Fig 13. Result of Neuro-fuzzy Sample Data Test

5. 결과 및 향후 과제

저널 베어링의 이상상태 진단에 대한 방법으로 통계적 기법과 Fuzzy Clustering, Neural Network 등을 이용하였다. 2400 RPM 하에서의 AE 센서 및 Acc 센서에 의한 데이터에 대해 3가지 이상상태 진단방법을 수행한 결과 Neural Network을 이용하여 Sample Data에 대해 검증한 결과가 가장 우수함을 알 수 있다. 통계적인 방법을 이용한 진단 방법에서는 정해진 범주 내에서 샘플데이터와 비교해서 센서의 위치와 정상상태 비정상상태를 구분한다. 그러므로 범주에 대한 범위가 상호 포함하는 관계를 형성하여 진단에 대한 정확성과 신뢰도를 낮게 하는 단점을 내포한다.

Fuzzy Clustering을 이용한 방법은 Fuzzy Clustering 하는 과정에서 볼 수 있듯이 정상상태의

데이터와 비정상상태의 데이터로써 이루어진 Cluster가 접하는 것을 볼 수 있다. 그러므로 접하는 부분에 대해서는 진단의 어려움을 느끼게 하는 Fuzzy Clustering을 이용한 진단기법은 한계점을 나타낸다. Neural Network을 이용한 방법은 위에 설명한 통계적 방법과 Fuzzy Clustering을 이용한 방법보다는 현저한 정확성을 보여준다.

그러나 이러한 Neural Network을 이용한 방법도 초기 입력값인 학습율과 오차율을 어떻게 입력하느냐에 따라 학습시간이 달라지며, 엄청난 수의 Iteration을 통해서 시간적 손실을 경험하게 된다는 단점을 가지게 된다.

본 논문에서는 진단기법들 중에서 통계적 기법을 이용한 방법과 Fuzzy Clustering과 Neural Network을 이용한 방법의 문제점과 단점을 보완해보려 했다. 그러나 앞에서 제안된 Neuro-fuzzy 시스템도 어느 정도 제한된 범위의 Sample Data로서 시행되어진 실험 결과라는 것이며, 최적의 Fuzzy Rule과 Data의 신뢰성에서 많은 부분에 있어 이에 대한 한계점을 드러낸다. 따라서 앞으로 이러한 점들에 대한 보완하고 좀 더 유연한 프로그램의 개발이 필요할 것이라고 본다.

6. 참고문헌

- [1] Kim, Y. J. and Kim, Y. W.(1998), Development of Diagnostic Expert System for a Rotor System, Proc. of the 1st Korea-Japan Joint Conf. on Industrial Engineering and Management, Korea.
- [2] Kim, Y. J., A Framework for an On-Line Diagnostic Expert System for Intelligent Manufacturing, Expert Systems With Applications, Vol. 9, No. 1, 1995
- [3] Robert Schalkoff "Pattern Recognition" 1989 John Wiley & Sons, Inc
- [4] Yoo, S. M. , Kim, Y. J., and Park, S. S., Development of Diagnostic Expert System for Rotating Machinery Failure Diagnosis, 1998
- [5] Yoon, D. J., Kwon, O. Y., Chung, M. H., and Kim, K. W., Early Detection of Damages in Journal Bearings by Acoustic Emission Monitoring, Journal of Acoustic Emission, Vol. 13, No.1, pp. 1-10, 1995
- [6] Timothy J. Ross, Fuzzy Logic with Engineering Applications, McGraw-Hill, Inc., pp. 371-401, 1997
- [7] Fausett, L. (1994), Fundamentals of neural networks, Prentice Hall.
- [8] Lefteri H. Tsoukalas, Robert E. Uhrig, A Wiley-Interscience Publication JOHN WILEY & SONS, INC. Fuzzy and Neural Approaches in Engineering pp. 409-444, 1997