

Wavelet을 이용한 압연기 진단

Diagnosis of Rolling Mill Using Wavelet

*김 이 곤 **김창원 ***송길호

* 여수대학교 전기공학과

**광주대학교

*** 포항제철 기술연구소

<Abstract>

A diagnosis system that provides early warnings regarding machine malfunction is very important for rolling mill so as to avoid great losses resulting from unexpected shutdown of the production line. But it is very difficult to provide early warnings in rolling mill. Because dynamics of rolling mill is non-linear. This paper proposes a new method for diagnosis of rolling mill using wavelet to solve this problem. Proposed method that measures the vibration signals of rolling mill on-line and analyze it using wavelet to acquire pattern datas. And we design a nero-fuzzy model that diagnose a rolling mill using this data. Validity of the new method is asserted by numerical simulation.

I. 서 론

산업 활동에서 자동화 생산 설비의 신뢰성 확보는 제품의 질과 생산성 증대를 위해 대단히 중요하며, 설비의 신뢰성 확보를 위해서는 설비의 상태 진단이 우선적으로 필요하다. 압연기의 상태 진단이라 함은 진동, 베어링 온도, 윤활압력, 윤활유의 오염 정도등 압연기의 상태에 관련된 여러 변수들을 측정하여, 압연기의 운전상태 불량 정도를 결정하는 것을 말한다. 그리고 더 나아가 측정된 변수들의 자료로부터 압연기의 고장 원인을 파악하는 것까지도 포함된다. 일반적으로 상태 진단은 상태에 따른 정비 시스템과 연결되는 것이 보통이다. 즉 상태 진단에 의해 고장발생이 예측되면 즉시 정비를 하는 것을 의미한다. 대부분의 공장에 채택하는 정비 시스템으로는 기계 고장발생 이후에 정비하는 고장 후 정비(Run-to Breakdown)시스템을 채택하거나, 기계의 상태와 관계없이 주기적으로 필요 없는 부품을 교환하는 정비 시스템을 채택하고 있는 실정이다. 그러나 예측 진단과 연계된 정비 시스템의 장점은 비용이 많이 들거나 위험한 결과를 초래하는 예측되지 않은 대규모의 고장을 피할 수 있으며, 기계의 정밀 분해 검사(Overhaul)의 양을 최소로 줄일 수 있고, 불필요한 기계의 운전 정지를 없애고 결함이 생기는 것을 사전에 방지할 수 있어서 유지비용의 절감을 기대할 수 있고, 예비 부품을 제때에 주문할 수 있게 하여 재고 비용을 줄일 수 있다.

따라서 예측 진단에 의한 정비시스템의 대한 요구가 높아지고 있으며 국내, 외적으로 많은 연구가 수행되고 있는 실정이다[1-6]. 압연기의 상태 진단에 대한 연구는 현재까지 국제적으로 많은 연구가 이뤄져 왔다. 압연기는 제철소의 철강 생산 공정에서 코일의 질을 결정하는 중요한 설비

이다. 다양한 생산 조건으로 과중한 속도와 하중의 변화가 압연기에 중대한 고장을 자주 유발하여 생산활동에 치명적인 영향을 미친다. 생산 공정의 형태가 연속(One-Line)적이므로 고장이 발생할 경우 치명적인 사고를 초래하므로 사전에 상태 진단이 필요하다. 압연기의 경우 규모가 크고 동작 조건이 열악하여 고장의 형태가 매우 비선형적 특성이 강하여 일반적인 회전기의 상태진단 방법으로는 신뢰성확보가 어렵다. 압연기 베어링 상태진단에 이용하는 변수는 온도와 소음, 진동 그리고 윤활제가 있다. 분석 방법으로는 온도 추이 분석, 소음 분석, 진동 분석, 윤활제 분석방법이 주로 이용되고 있으며, 온도 추이 분석은 급격하고 미세한 변동의 징후에 대한 사전 정보를 얻기에는 충분하지 않으나 고장 발생을 발견하는데 신뢰성 있는 정보를 제공할 수 있다. 윤활제 분석 방법은 신뢰성이 높지만 윤활제의 온-라인 측정이 어렵다는 단점을 갖고 있다. 소음 및 진동 분석 방법은 초기 미세한 징후의 변동에 민감하고 초기 고장의 원인을 분석하는데 중요한 정보를 제공할 수 있지만, 중대한 고장의 진행에 대한 정보를 얻기에는 그 비선형성 때문에 어렵다. 그러나 외부에서의 신호 측정을 통해 내부의 상태를 예측할 수 있는 장점이 있고, 측정 장치의 탈착이 용이하다는 점에서 다른 변수들에 비해 유리하다. 특히 기어나 베어링 같은 회전기계의 진동신호는 몇가지 전형적인 형태로 나타나기 때문에 고장의 원인 및 위치를 쉽게 발견할 수 있는 장점이 있다.

본 연구에서는 압연기의 상태진단의 변수로 베어링의 진동 신호를 이용하였다. 고장 베어링의 상태 진단 방법으로는 일반적으로 진동 분석 방법이 가장 많이 이용되고 있지만 그 중에서도 진동 측정에 의한 진동 분석 방법 중에서 FFT를 이용한 주파수 스펙트럼 분석방식을 많이 적용하고 있다. 진동 분석 방법에는 Kutorsis[41], Envelope Technique[5], FFT[8], Cepstrum[7], Cres-Factor [8]등이 있으며, 이 방법에 의한 회전체의 상태 진단 및 모니터링이 많이 연구되고 있다. 이 방법은 진동 신호로부터 축차적으로 일정 기간내의 주파수 스펙트럼 분포 형태를 분석하여 Bearing의 상태에 대한 정보를 얻어 회전체의 상태를 진단하는 가장 일반적인 기법이다.

그러나 이들 방법들은 압연기와 같이 대형이며 고장이 순간적으로 발생, 진행되는 복잡한 작업 환경에서 나타나는 고장 상태에 대한 정보를 얻기는 대단히 어렵다[7]. 따라서 본 연구에서는 진동신호를 시간축상에서 실시간 분석이 가능한 wavelet 변환을 이용하였다. 웨이브렛 변환은 원시 신호를 오리지날(Mother) Wavelet의 천이값과 스케일값의 가변으로 여러 신호성분으로 분해하는 것으로, 시간에 따라 각각의 주파수성분 신호의 변화 추이를 실-시간으로 관측할 수 있어 신호의 순간적 변화를 검출하는데 대단히 유용한 방법이다[1,2]. 웨이브렛 변환의 특징은 필터링 기능을 이용한 노이즈제거 기능을 갖고 있다. 그래서 신호의 노이즈의 영향을 최소화할 수 있으며 비선형시스템에 보다 적합한 특성을 갖게 된다[2,3].

본 연구에서는 신호 측정 센서로 고주파수 성분까지 측정할 수 있는 가속도센서를 사용하였다. 측정된 진동신호에서 Wavelet변환을 이용하여 신호의 노이즈를 제거하고, 실시간으로 각 스케일 값에의해 분석된 신호를 고장 패턴 입력으로 하여 비선형 시스템에 적합한 뉴로-퍼지 모델을 설계하였다. 이렇게 얻어진 모델을 이용한 압연기의 고장 진단 시스템을 구성하여 진단을 수행할 수 있음을 실측 데이터를 이용한 시뮬레이션을 통해 입증하였다.

II. wavelet 변환

웨이브렛 변환의 이론적 배경은 STFT의 최적 구간(Window)의 설정 방법과 같다. 일반적인 방법으로 시간-주파수 웨이브렛 변환은 신호 $s(t)$ 을 시간-주파수 단위의 선형 조합으로 분해하는 것이다. 웨이브렛은 평균값이 영인 효과적으로 제한된 기간의 파형을 말하며, 웨이브렛 분석은 원시신호를 식(2)와같이 오리지날(Mother) 웨이브렛의 천이값과 스케일값의 가변에 따른 여러 신호성분으로 분해하는 것으로, 시간에 따라 각각의 주파수성분 신호의 변화 추이를 실시간으로

관측할 수 있어 신호의 순간적 변화를 검출하는데 대단히 유용한 방법이다. 기존의 푸리에 분석은 임의 신호를 여러 주파수의 사인파로 분류하는 것으로 $-\infty$ 에서 $+\infty$ 까지 시간영역의 신호(time-Volt)를 주파수 스펙트럼(Frequency -Magnitude)으로 분석하는 것으로 연속적인 주파수 성분의 변화를 실시간 분석하기는 불가능하다. 이 문제를 해결하기 위해 짧은 시간 구간(Window)을 결정하여 분석하는 STFT(Short Time Fourier Transform)방법을 적용하고 있지만, 보다 실시간의 신호 분석을 위해 WT(Wavelet Transform)를 이용하는 것이 보다 적합하다[1,2]. 그리고 웨이브렛 변환의 특징은 필터링 기능을 이용한 노이즈제거 기능을 갖고 있어 신호의 노이즈 영향을 최소화할 수 있으며, 비선형시스템에 보다 적합한 특성을 갖는 장점을 갖고 있다[3,4]. WT는 스케일(Scale)과 쉬프트(shift or position)인덱스값이 연속값인 경우가 CWT (Continuous Wavelet Transform), 이산치인 경우가 DWT(Discrete Wavelet Transform)이다. CWT는 적분이 가능한 힐버트공간(Hilbert Space)으로 정의하면 다음식과 같다.

$$CWT_x(\tau, a) = \frac{1}{\sqrt{|a|}} \int f(t) \psi\left(\frac{t-\tau}{a}\right) dt \quad (1)$$

a 는 실수인 스케일 지수이고, τ 는 위치 지수이다. Fig. 2-2는 원시 신호를 CWT에 의해 Fig. 2-1의 웨이브렛함수로 분석한 결과이다. Fig. 2-2와 같이 시간,스케일, 웨이브렛 계수 3변수로 표현된다.




Fig. 2-1 Symlet wavelet function

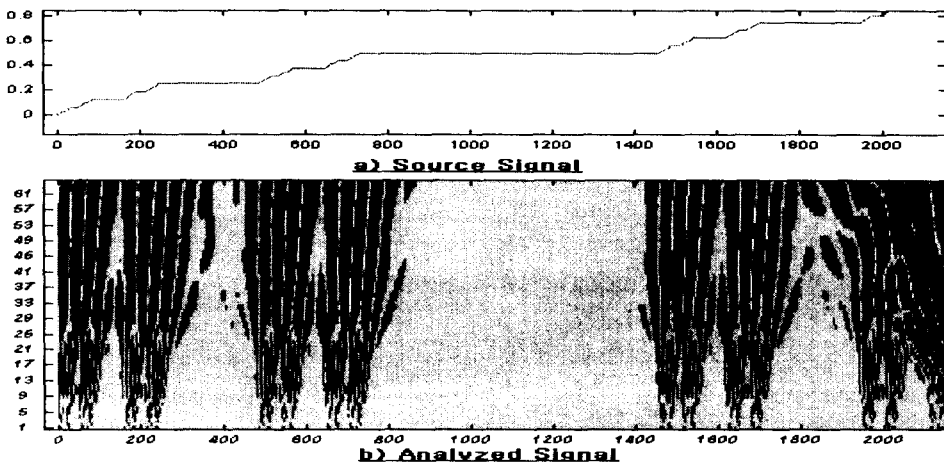


Fig. 2-2 Result of Continuous wavelet transform

스케일값이 적으면 빠른 신호를 분석하는데 민감하고 반대로 큰 경우는 낮은 신호 변화에 보다 적합함을 보여주고 있다. 이 방법은 신호를 실시간으로 분석하여 신호의 패턴을 분석하는데 적합한 방법이다. 스케일의 값의 변화에 따라 계수값이 변화 됨을 볼 수 있고, 그 값은 원신호의 변화율, 즉 주파수 성분에 비례함을 알 수 있다. DWT웨이브렛 변환식은 식(2)과 같다.

$$DWT(a, \tau) = \sum_{n \in \mathbb{Z}} f(n) \Phi_{a, \tau}(n) \quad (2)$$

$$\Phi_{(a, \tau)}(n) = 2^{-\frac{a}{2}} \Phi(2^{-a}n - \tau) \quad (3)$$

$\Phi(t)$ 는 이산 웨이브렛 변환을 이용하여 신호 분석에 이용되는 Mother 함수이다. a 는 크기 지수(scale index)이고, τ 은 위치 지수(location index)이다. a 는 웨이브렛의 폭 크기를 가르키고, τ 는 웨이브렛의 위치를 가르킨다. 식(2)로부터 스케일 a 에 따른 $f(n)$ 의 저역값(Approximation)을 제공하고, 스케일값 a 를 고정한 상태에서 τ 에 대한 부분함인 고역값(Detail)를 제공한다.

$$W(t) = \sum_{k=1}^{N-2} (-1)^k c_{k+1} \Phi(2t - k) \quad (4)$$

윗식은 웨이브렛의 스케일 방정식으로 $W(x)$ 는 웨이브렛이고, c_k 는 웨이브렛 계수들이다. 웨이브렛 계수들은 다음식을 만족해야한다.

$$\sum_{k=0}^{N-1} c_k = 2, \quad \sum_{k=0}^{N-1} c_k c_l = 2 \delta_{l,0} \quad (5)$$

여기서 δ 는 Kronecker 델타 함수이다.

DWT의 일정 크기의 스케일 값을 이산적으로 한정된 범위안에서 가변하며, 큰 스케일값인 경우는 작은 주파수 성분의 신호 성분을 분해하고, 낮은 스케일 값인 경우는 높은 주파수의 신호성분을 분류할 수 있다. 이때 큰 스케일 값에의한 계수 값을 저역값(Approximation)라하고, 작은 스케일 값의 경우를 고역값(Details)이라 한다. Fig. 2-4와 같이 스케일 값에의해 여러 단계의 성분으로 분해가 이뤄진다. 최적의 신호 분석을 하기 위해 최적 계수의 선택을 여러 가지 측정 함수를 이용하여 실시하고, 신경회로망의 학습 기능을 이용하여 최적 값을 얻기도 하여 트리 모양의 최적 level을 얻는다[2,3].




Fig. 2-3 db5 wavelet mother functionn

본 연구에서는 노이즈를 포함하는 전류파 측정 신호를 웨이브렛을 이용하여 노이즈를 제거하고, 제거된 신호로부터 일정 크기 이상의 임펄스성 전류파의 빈도를 추출하여 2차원의 고장 상태 진단 패턴 데이터를 구하였다.




Fig. 2-4 Result of 1-D Discrete Wavelet transform.

III. 압연기 상태 진단

3.1 웨이브렛 신호분석과 진단모델설계

압연기의 상태진단의 변수로 베어링의 진동 신호를 이용하였다. 고장 베어링의 상태 진단 방법으로는 일반적으로 진동 분석 방법이 가장 많이 이용되고 있지만 그 중에서도 진동 측정에 의한 진동 분석 방법 중에서 FFT를 이용한 주파수 스펙트럼 방식을 적용하였다. 이 방법은 진동 신호로부터 축차적으로 일정기간내의 주파수 스펙트럼의 분포 형태를 분석하여 베어링의 상태에 대한 정보를 얻어 회전체의 상태를 진단하는 가장 일반적인 기법이다. 그러나 이 방법은 축차적 방법의 FFT의 단점 때문에 순간적으로 변화하는 신호의 정보를 실시간으로 취득하지 못한다. 본 연구에서는 진동신호를 wavelet을 이용하여 시간축상에서 실시간으로 분석한 데이터에서 얻어진 상태 진단에 필요한 진단 패턴을 취득하였다.

모든 회전기계의 결함탐지 단계에서는 회전기계가 작동하는 동안 일어날 가능성이 있는 모든 종류의 결함을 탐지하는 것이 바람직하다. 기존의 제안된 방법은 충격 주파수를 검출하는 스펙트럼 분석을 적용하여 결함의 특징을 추출하였다. 스펙트럼 분석에서도 포락선 검출방법은 지금까지 연구된 내용에서 기계의 결함탐지에 특히 유용한 방법으로 제시되었다[1-3]. 그러나 이 방법의 적용결과 여러 필터를 거치면서 필요한 정보의 갖는 신호의 감쇄로 인하여 적절히 적용할 수 없었으며, 고장상태의 진전이 대단히 빠르게 진행되므로 실시간으로 변화하는 상태의 진행을 모니터링하기 위해서는 웨이브렛 해석방법이 필요하다. 그리고 압연기의 동작 환경이 대단히 열악하고 복잡하여 진동신호에 포함된 노이즈신호의 영향이 대단히 크다.

진단 모델로 신경망 모델은 시스템의 강인성은 좋은 편이나, 모델이 복잡하고, 입력신호는 진동에서 발생하는 신호가 원천적으로 미세하므로 노이즈를 수반하게 되어 노이즈에 보다 강인한 다른 알고리즘이 요구된다. 본 연구에서는 뉴로-퍼지 모델을 이용한 추론과 웨이브렛을 이용한 패턴 인식 방법을 제안한다.

압연기에 사용된 베어링의 구조는 Fig 4-1과 같으며, 베어링의 진동신호를 Fig 4-2와같이 구성된 데이터 수집장치에 의해 온-라인 상태로 수집하여 분석하는 시스템을 구성하였다. 데이터 수집장치로는 Analog Instrument사의 데이터 수집장치를 I80586으로 구성하였으며, 샘플링시간은 4KHz로 하였다.

측정된 신호는 고장 발생전에서 1초간 동안 4000개의 데이터를 간헐적으로 취득된 데이터를 대상으로 분석하였다. Fig. 3-1과 같이 노이즈와 함께 측정된 신호를 웨이브렛을 이용한 저역과 고역의 5개의 채널로 분석된 결과를 보여주고 있다. 압연기 진동신호의 정량화는 미지의 압연기 진동 패턴으로부터 압연기의 고장단계를 예측할 수 있는 고장진단 추론모델을 구성할 수 있도록 압연기 진동 데이터와 고장 상태와의 관계를 정량화 하는 것으로 한다.

본 연구에서는 a1에서부터 a5까지의 그룹별 압연기 진동의 시작으로부터 압연기 고장의 진척에 따라 압연기파괴에 이르는 과정의 일정 간격의 이산 데이터를 취득하여 변화량을 평균값으로 정량화하였다. 입력변수는 5개변수의 변화와 압연기 고장의 진척정도 간의 상관성을 이용하여 압연기 고장진단 모델을 설계한다. 압연기고장의 메카니즘은 대단히 복잡하고 여러 가지 환경요인의 복잡한 비선형적 특성을 갖고 있어 일반적인 수식에 의한 표현은 거의 불가능하다. 따라서 수치데이터를 이용한 퍼지-뉴로모델링 이용하여 추론모델을 설계한다. Fig. 3-2 고장진단 설계과정은 정량화된 데이터를 이용하여 고장진단 뉴로-퍼지모델의 구성도이다. 데이터 취득장치로부터 읽어 들인 진동신호를 웨이브렛을 이용하여 실시간으로 분해해서 특정 대역의 신호의 변화량의 정보를 얻는다. 얻어진 정보를 입력스치데이터로 이용하여 퍼지진단 모델을 설계하고 신경망을 이용하여 학습시키는 퍼지 신경망 진단 모델을 구성한다.

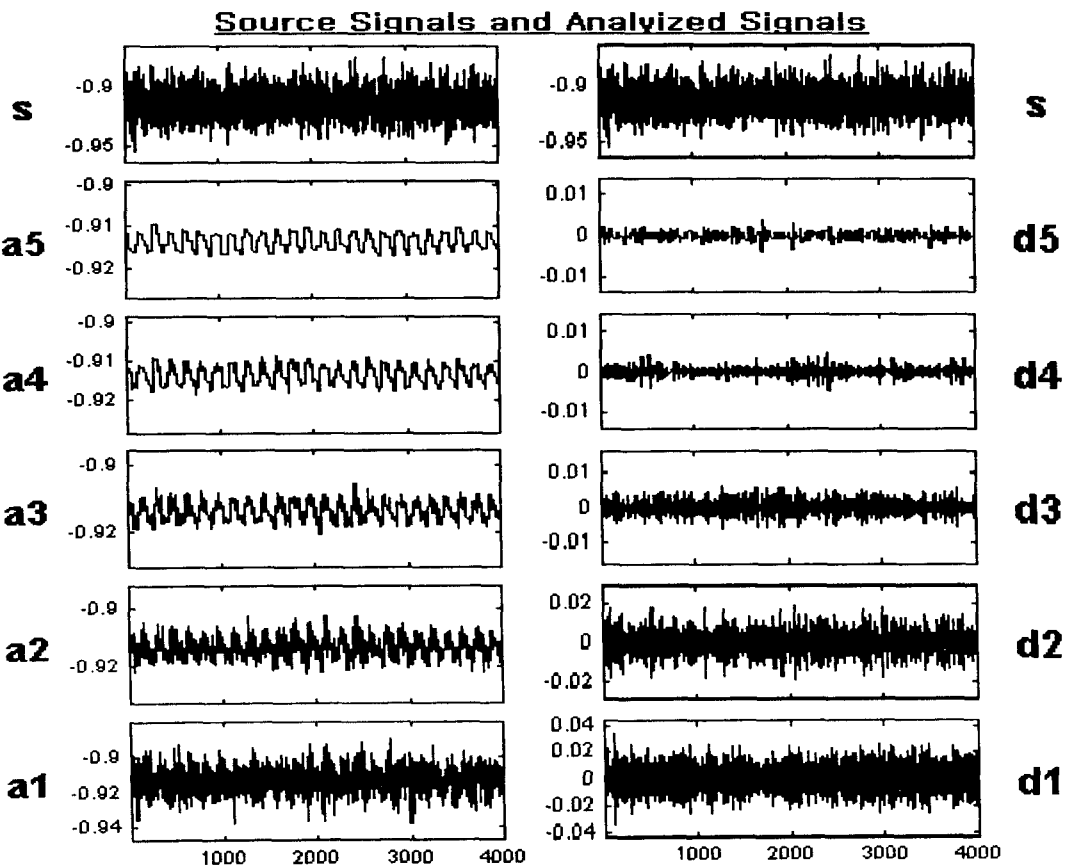


Fig. 3-1 Source Signals and Analyzed Signals




Fig. 3-2 Neuro-Fuzzy Diagnosis Model

3.2 압연기의 구조와 고장주파수의 관계

압연기 상태의 변화에 대한 정보를 얻기 위해서는 진동스펙트럼은 동일 운전조건에서 비교되어야 한다. 기준 스펙트럼은 한 번도 사용하지 않은 새로운 기계에서 구할 필요는 없고, 기계가 가장 안정된 상태에서 운전중 일 때의 스펙트럼으로 정하였다. 요구되는 측정간격은 기계마다 다르고, 고장과 예상된 고장의 왜곡증가율 사이의 예상 평균시간에 직접적으로 영향을 받으므로 초기의 신호왜곡이 발생하면 측정주기를 작게 해야 한다. 결함의 조기 발견은 우수한 상태진단 시스템을 구축하는 첫 번째 단계이다. 초기에 기계의 상태 악화를 발견하는 것은 고장 진단 및 경향 해석시 중요한 정보를 제공하기 때문이다. 볼 베어링의 결함을 탐지할 수 있는 두 가지 방법으로 저주파수영역에서 충격율의 기본주파수를 찾고, 고주파수 영역에서 충격주파수의 하모닉성분을 분석하는 방법을 적용한다. 본 연구에서는 전자의 방법을 적용한 결함 탐지를 시도하였다. 압연기의 회전체의 베어링의 구조를 Fig 3-3에 나타내었다. Fig 3-3의 구조에서 베어링 이상 때 발생할 수 있는 진동신호의 주파수 스펙트럼 분석을 통해 분석할 수 있고 기계적 구조 분석에 의한 고장 주파수 분석을 통해 Table 3-1과 같이 계산할 수 있다.




Fig 3-3 Structure of bearing

Table 3-1) Defected Frequency

Impact Rates(Hz)	Formulae	d: Ball Dia D: Pitch Dia α : Contact angle f_0 : Relative rps between inner & outer races
f_r (System Resonance rates)	$f_r = 0.4 \cdot Z \cdot f_0$	
f_i (Inner Race Defect)	$f_i = \frac{Z}{2} f_0 \left(1 + \frac{d}{D} \cos \alpha\right)$	
f_c (Outer Race Defect)	$f_c = \frac{Z}{2} f_0 \left(1 - \frac{d}{D} \cos \alpha\right)$	
f_b (Ball Defect)	$f_b = \frac{f_0 \cdot Z}{2} f_0 \left(1 - \frac{d^2}{D^2} \cos^2 \alpha\right)$	

IV. 압연기 및 Bearing 구조와 압연기 상태진단 모델 설계




Fig 4-1. Elements of rolling mill's bearing

압연기에 사용된 베어링의 구조는 Fig 4-1과 같으며, 베어링의 진동신호를 Fig 4-2와같이 구성된 데이터 수집장치에 의해 온-라인 상태로 수집하여 분석하는 시스템을 구성하였다. 데이터 수집장치로는 Analog Instrument사의 데이터 수집장치를 I80586으로 구성하였으며, 샘플링시간은 4KHz로 하였다. 고속 데이터 수집을 위해 수집 방법은 일정시간 간격으로 1초 동안씩 하였으며, 고장발생 전의 데이터로부터 고장으로 인해 동작 불가능 상태 동안까지 데이터를 수집하였다. 수집된 데이터는 5개의 그룹으로 분류하였으며, 각 그룹의 데이터 수집시간은 Table 4-1과 같다.




Fig 4-2 Structure of diagnosis systems

Table 4-1 Sampling Times and Groups

Groups	Measuring time	Sampling frequency	Acquisition During	Samples
1	-01 : 56	4kHz	1sec	4000
2	-01 : 49	4kHz	1sec	4000
3	-01 : 14	4kHz	1sec	4000
4	-00 : 08	4kHz	1sec	4000
5	00 : 00	4kHz	1sec	4000

Table 4-2 Defected Frequency

Impact Rates(Hz)	Formulae	Frequency
f_r (System Resonance rates)	$f_r = 0.4 \cdot Z \cdot f_o$	326,652,978,1304,1630
f_i (Inner Race Defect)	$f_i = \frac{Z}{2} f_o (1 + \frac{d}{D} \cos \alpha)$	439, 878, 1319, 1754,
f_c (Outer Race Defect)	$f_c = \frac{Z}{2} f_o (1 - \frac{d}{D} \cos \alpha)$	375,750,1125,1500,1875
f_b (Ball Defect)	$f_b = \frac{f_o \cdot Z}{2} (1 - \frac{d^2}{D^2} \cos^2 \alpha)$	151,302,453,604,755,906

본 연구에서 Fig 4-1 진단 대상인 압연기 베어링의 구조에 대한 베어링의 고장 주파수는 Table 4-2와 같이 계산된다. 실측된 데이터를 푸리에변환하여 스펙트럼 분석하면 다음 Fig 4-3,4-4와 같이 나타난다. 정상상태의 주파수 스펙트럼은 Table 4-2를 참조하면 f_c 의 요소가 강하게 나타나지만 Fig 4-4는 f_r, f_i, f_c 가 복합적으로 나타남을 알 수 있다.

Fig 4-3. Frequency spectrum in normal state




Fig 4-3에서와 같이 각 베어링 구조요소의 동적 거동에 의한 진동 주파수의 스펙트럼이 2000Hz의 주파수대역에 분포되어 나타나고 있다. 그러나 고장 징후가 순식간에 발생하고 고장의 진행 동안의 주파수 스펙트럼의 분포는 Fig 4-4와 같다. 이와 같이 순간적인 고장의 이상 징후가 발생하고 고장 진행이 빠른 시간에 진행되는 경우는 지금까지 발생된 사고 유형이 거의 일치하고 있다. 빠르게 진행되는 이유는 지금까지의 고장 발생과정에서 압연기의 베어링에 인가되는 하중

과 속도가 대단히 크기 때문에 사료되며, 이 경우 중대한 사고로 전전되는 농작기계의 예후가 필요하다.

Fig 4-4. Frequency spectrum in abnormal state




Fig 4-2와 Fig 4-3에서 정상 상태와 고장 상태의 주파수 스펙트럼의 경향을 살펴보면 정상 상태와 고장 상태의 경우의 신호 레벨의 크기는 오히려 고장 상태에서 줄어드는 경향을 보여 주고 있다. 시간에 따라 변하는 스펙트럼을 Fig 4-4에서 보여 주고 있다. 정상 상태와 고장 상태의 신호 크기는 예상과 다르게 오히려 줄어들고 있지만 고장에 관계되는 주파수의 분포가 더욱 종합적으로 고장의 형태가 확장되고 있음을 관측할 수 있다. 이상으로 살펴볼 때 고장의 주파수 스펙트럼의 분포의 형태가 일반적인 경우와 다르지만 특정 대역으로 분류하여 크기가 비선형적이지만 고장의 진척에 따라 시간과 함께 증가하고 있는 경향을 알수 있다.

따라서 고장 발생 시간의 경과에 따른 시간 축상의 신호 크기의 변화를 그림 4-5에서 분할한 5개의 특정 대역의 시간에따른 변화를 나타내었다. 이 값을 이용하여 설계한 이상 상태 진단 시스템의 경과시간 변화의 추론치와 실측된 시간 데이터의 값을 Fig 4-9에 보여주고 있다.




Fig 4-5 Source




Fig 4-6 Reasoning result of proposed Diagnosis model

V. 결 과

본 연구의 내용은 광양제철의 생산 프렌트의 일부인 압연기의 베어링의 파손 고장데이터를 취득하여 고장의 진행상태에 대한 진단 모델의 설계에 대한 연구이다. 진동데이터의 분석결과 연구 보고된 일반적 고장형태와는 다른 고장의 특징을 보여주고 있어 기존의 보고된 연구 결과의 적용이 어려움을 알 수 있었다. 따라서 본 연구에서는 웨이블릿을 이용한 신호의 분석으로부터 특정 대역의 분할과 각 대역의 신호의 크기 누적치의 변화를 특징 입력으로 하여 퍼지 신경망 모델을 설계하고 실측 데이터를 적용하여 타당성을 입증하였다. 그 결과 그림4-6에서 신뢰성 있는 추적 결과를 보여주고 있어 타당성이 입증되었다. 한정된 고장 형태에 대한 연구로 인해 다른 여러 형태의 고장에 적용에 대한 지속적인 연구가 필요하다.

참고 문헌

- [1] Jun-Wei Hsieh, Min-Tat Ko, Hong-Yuan Kuo, Chin Fan, "A new wavelet-based edge detector via constrained optimization", Image and Vision Computing, Pp511-527, 15(1997)
- [2] Christopher J. Deschenes, "Fuzzy Kohonen Network for Classification of Transients Using the Wavelet Transform for Feature Extraction", Information Science 87, Pp247-266, 1995
- [3] R. A. Gopinath and C.S. Burrus, Wavelet Transform and Filter Banks, wavelets-A Tutorial in Theory and Application, Pp.603-644, 1992
- [4] Alfredson R.J. 'Time Domain Methods for Monitoring the Condition of Rolling Elements Bearings' mechanical Engineering Transactions Institute of Mechanical Engineers, Australia 1985 pp102-107.
- [5] Ratcliffe G.A. 'Condition Monitoring of Rolling Element Bearings Using the Envelope Technique' Proc. I Mech. E Seminar on Machine Condition

- Monitoring, Jan. 1990.
- [6] K. F. Martin and P. Thrope, 'Normalized Spectra in Monitoring of rolling Bearing Elements' *Wale*, 159(1992) pp153-160.
 - [7] P. J. Thrope BSc and K. F. Martin, 'Milling Machine bearing Monitoring.' *I. Mech. E.* pp151-157.
 - [8] P.D. McFadden and J.D. Smith, 'Vibration Monitoring of Rolling Element Bearings by the High-Frequency Resonance Technique—a Review', *TRIBOLOGY International*, Vol.17, No. 14, pp3-10, February 1984.
 - [9] Dr. Alexej V. Barkov, Dr. Natalia A. Barkova, 'Diagnostics of Gearing and Geared Couplings Using Envelope Spectrum Methods',
<http://www.inteltek.com/articles/index.htm>
 - [10] 임영철, 장영학, 조경영, 김이곤, 박봉기, "퍼지신경회로망을 이용한 자율주행차량의 조향제어 관한 연구", *Proceedings of JCEANF 93'* 1993.
 - [11] M.Sugeno and T.Ysugawa, "A Fuzzy-Logic-Based Approach to Qualitative Modeling," *IEEE Trans. on Fuzzy Systems*, Vol.1, pp.7-31, Feb.1993.
 - [12] 이계호, 임영철, 김이곤, 조경영, "신경회로망을 이용한 퍼지룰의 추론과 학습에 관한 연구", *한국통신학회 논문지*, Vol. 18, No.2, pp.231-238, 1993.