

## 웨이브렛 변환을 이용한 교반기의 고장감지 및 진단

### Fault Detection and Diagnosis of an Agitator Using the Wavelet Transform

서동욱, 전도영

(Dong-Uk Seo, Do-Young Jeon)

**Abstract :** This paper proposes a method of fault detection and diagnosis of agitators based on the wavelet analysis of the current and vibration signals. The wavelet transform has received considerable interest in the fields of acoustics, communication, image compression, vision, and seismic since it provides the fast and effective means of analyzing signals recorded during operation. Neural network is used to diagnose the fault. Specifically, the proposed approach consists of (i) fault detection, (ii) feature extraction, and (iii) classification of fault types. The results show an effective application of the wavelet analysis on the monitoring of an agitator.

**Keywords :** agitator, wavelet transform, neural networks, fault detection and diagnosis

#### I. 서론

웨이브렛 이론은 순수 수학에서 시작되어 1990년대 들어 신호 및 시스템의 해석분야 관련 연구가 활발한데, 고장감지 및 진단에 적용하기도 하였고[2][3], 패턴인식을 위한 선처리 과정으로서 웨이브렛 계수를 그룹화함으로써 특징을 추출하는 방법을 제시하기도 하였다[4]. 또한 웨이브렛 변환과 신경망 회로를 사용하여 신호의 특징을 추출하고 분류하여 고장신호 감지 및 분류에 사용하기도 하였다[5]-[8].

3상 유도기로 구동되는 교반기는 교반 날개를 회전 시킴으로써 배설속의 내용물을 섞게 하는데 내용물의 수위가 낮아질 경우 임펠러를 정지하여야 하나 그렇지 못할 경우 교반기의 과도 진동과 임펠러축의 휨현상등으로 교반 기가 정지하여 생산공정에 큰 손실을 가져올 수 있다. 본 연구에서는 교반기로부터 수집한 전류와 진동 데이터의 웨이브렛 변환을 통하여 고장감지와 패턴추출을 하고, 이 패턴의 적용 가능성과 효용성을 실험하기 위해 신경망을 사용하여 패턴 인식을 수행하였다. 논문에서는 웨이브렛 변환의 이론적 배경을 간략히 설명하고, 교반기의 장치 구성과 신호처리에 사용된 변수선택에 관련된 사항을 설명 하며, 끝으로 실험 결과를 보인다.

#### II. 웨이브렛 변환

웨이브렛 변환은 여러 센서로부터 연속적으로 발생하는 신호 중 아주 불규칙 적이며 시간대역이 짧은 신호들의 해석에 있어서 기존의 신호처리방식에서 잡음으로 처리할 수도 있는 정보량들로부터 의미 있는 정보들을 추출할 수 있는 특징이 있다. 웨이브렛 변환은 분석하고자 하는 신호를 주어진 기저함수의 특성을 이용하여 분할하는 과정을 말하

논문접수 : 2002. 5. 20., 채택확정 : 2002. 8. 30.

서동욱 : 삼성전자 통신연구소(duseo@samsung.com)

전도영 : 서강대학교 기계공학과(dyjeon@sogang.ac.kr)

\* 본 연구는 유변공정연구센터(ARC)를 통한 한국 과학재단의 지원(R11-2000-020303-0)을 받아 이루어졌으며 지원에 감사 드립니다.

며, 이 때 사용하는 기저함수는 스케일링  $\phi(t)$ 함수와 웨이브렛 함수  $\psi(t)$ 로 나눌 수 있다. 이러한 웨이브렛 기저들은 모웨이브렛  $\psi(t)$ 의 확장과 천이로부터 얻어지며, 다음 두 가지 조건을 만족하여야 한다.

$$\lim_{t \rightarrow \infty} |\psi(t)| = 0$$

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (1)$$

스케일  $a$ 와 시간  $b$ 에 대응하는 웨이브렛은 다음과 같이 주어진다.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R, a \neq 0 \quad (2)$$

여기서  $a$ 와  $b$ 는 각각 확장과 천이 변수로서  $a$ 값이 커지게 되면 기저 웨이브렛  $\psi(t)$  가 확장되어서 주어진 신호  $x(t)$ 의 저주파 성분을 분석하는데 이용될 수 있게 되며,  $a$ 값이 작아지면  $\psi(t)$  가 수축되므로  $x(t)$ 의 고주파성분을 찾아내는데 유용하게 쓰일 수 있다. 이 때 연속 웨이브렛 변환은 다음과 같이 정의된다.

$$W(a, b) = \int_{-\infty}^{\infty} x(t) \psi^{*}_{a,b}(t) dt \quad (3)$$

여기서 \*는 공액 복소수를 의미한다. 웨이브렛 변환은 분석하는 신호와 스케일 되고 천이된 웨이브렛과의 유사성의 정도를 나타낸다.

이산 웨이브렛 변환은 앞서 언급된 변환식에서  $a$  와  $b$ 를 2의 누승이 되는 스케일(dyadic scale)을 사용하여 나타내게 된다.

$$a = 2^j, b = k2^j \quad (j, k \text{는 정수}) \text{ 일 때, } \psi_{j,k} = 2^{-j/2} \psi(2^{-j}t - k)$$

웨이브렛은 로 표현되며, 이산 웨이브렛 변환은 다음으로 정의 된다.

$$c_{j,k} = \int x(t) \psi^*_{j,k}(t) dt \quad (4)$$

여기서  $c_{j,k}$ 는 웨이브렛 계수이며 원래의 신호  $x(t)$ 의 시간과 주파수 그래프상에 나타나게 된다.

웨이브렛 이론의 배경은 주어진 신호를 직교성을 가지고 있는 웨이브렛들을 적용하여 분해할 수 있다는 것인데 이러한 원리로부터 다중해상도 분석이 수립되었으며, 이는 신호의 성분을 단계별로 더욱 세밀하게 표현하는 웨이브렛을 만들어서 작용하는 과정을 거치는 방법이다.

스케일링 함수  $\phi_{j,k} = 2^{-j/2} \psi(2^{-j} t - k)$ 는 스케일링 계수  $d_{j,k} = \int x(t) \phi^*_{j,k}(t) dt$ 를 낳게 되고, 이산 웨이브렛 변환은 웨이브렛 계수  $c_{j,k}$ 를 다음과 같이 계산한다.

$$\begin{aligned} c_{j,k} &= \sum_n x[n] g_j[n - 2^j k] \\ d_{j,k} &= \sum_n x[n] h_j[n - 2^j k] \end{aligned} \quad (5)$$

$j > 0$ 에서, 스케일링 계수와 웨이브렛 계수는

$$\begin{aligned} c_{j+1,k} &= \sum_n g[n - 2k] d_{j,k} \\ d_{j+1,k} &= \sum_n h[n - 2k] d_{j,k} \end{aligned} \quad (6)$$

으로 주어진다. 여기서  $g, h$ 는 각각 웨이브렛  $\psi(t)$ 와 스케일링 함수  $\phi(t)$ 로부터 유도된 고주파, 저주파 통과 필터 계수에 해당한다. 그래서  $C_{j+1,k}$  고주파성분(상세계수 성분)에 해당하며,  $d_{j+1,k}$ 는 저주파 통과 필터를 통과한 신호(유사계수성분)이다. 그림 1에 신호가 분해되는 과정이 도식적으로 나타나 있다.

유사계수성분은 크기와 해상도를 변화시킬 때 각 조건에서의 파형의 변화된 상태만을 나타내는 것이지만 상세계수성분은 그 결과로서 나타나는 잔여성분으로, 신호 분석에 중요한 정보를 제공하게 되고 고장진단에 활용될 수 있다. 본 연구에서도 이 상세계수성분을 정상신호와 이상신호의 분석에 이용하였다.

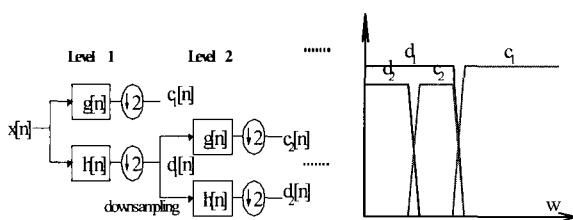


그림 1. 이산 웨이브렛 변환의 다중 필터화.

Fig. 1. Multi-stage filter bank for DWT(2-level).

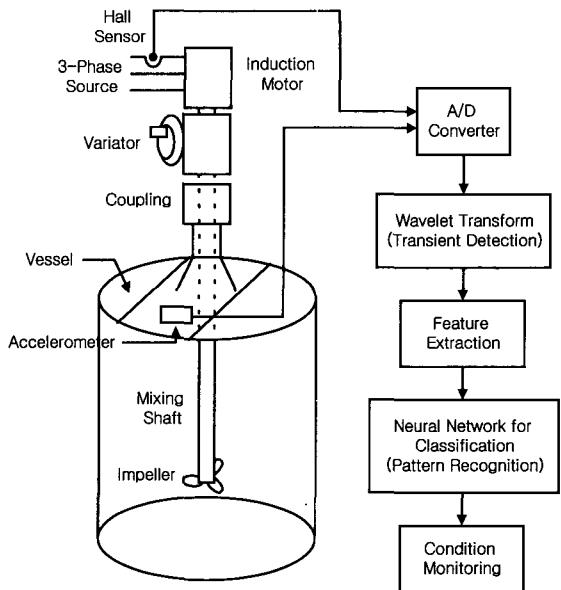


그림 2. 실험 장치 구성도.

Fig. 2. Schematic diagram of experimental set up.

### III. 실험장치 구성 및 변수

실험에는 (주)하도의 MT14-VPR-0.2 교반기를 사용했다. 이 교반기는 변속기가 설치되어 있어 분당 1회전 이하에서 1000회전까지 회전수의 변환이 가능하다.

교반기의 경우 교반볼질의 점도, 수위, 회전속도 등에 따라 진동과 전류의 측정신호가 달라진다. 본 연구에서는 교반볼질을 물로 하였고, 수위는 임펠러가 액면통과 할 때, 공회전 할 때, 30cm깊이에 있을 경우를 만들어 실험 하였으며, 교반기의 3상 유도 전동기의 인입전류를 측정하기 위해 Nana Electronics사의 SY-05 홀센서를 사용하였고, 진동을 측정하기 위해 PCB사의 1Hz~1kHz의 진동을 측정할 수 있는 가속도계를 사용하였다. 여러 회전속도에 대한 데이터는 1 kHz의 샘플링 주파수로 2048개의 데이터가 수집되었고 이를 웨이브렛 변환하였다.

### IV. 실험결과

#### 1. 축의 흔 감지 및 신호 분석

웨이브렛 분석을 하기 전에 그 분석을 위해 사용할 웨이브렛을 선택하고 분석할 레벨의 단계를 결정해야 한다. 본 논문에서 사용된 웨이브렛은 다우비치 웨이브렛 (Daubechies wavelet, db4)이며 최대 분할 레벨인 11레벨까지 웨이브렛 변환을 수행하였다. 표 1은 11레벨까지 웨이브렛 변환을 수행할 경우 각 레벨에서 표현되는 주파수를 나타낸다.

그림 3, 4는 공회전으로 600rpm의 회전속도로 운전시 교반축이 휘어지는 동안의 전류신호와 진동신호이다. 그림과 같이 1레벨의 신호로도 충분히 원신호로부터 순간적으로 변화하는 과도적 특성을 잡아낼 수 있음을 알 수 있다. 이는 웨이브렛 분석의 주요한 이점 중 하나인 국소화 (localization)이다. 이를 가지고 퓨리에 변환을 하여보면 주파수 성분만을 찾아낼 뿐, 그 시점을 알려주지 못하나 웨이브렛 변환은 그 시점이 국소화 됨을 알 수 있다.

표 1. 각 레벨의 주파수 범위.

Table 1. Frequency range in each levels.

Level	주파수 범위(Hz)
1	250.0~500.0
2	125.0~250.0
3	62.5~125.0
4	31.3~62.5
5	15.6~31.3
6	7.8~15.6
7	3.9~7.8
8	2.0~3.9
9	1.0~2.0
10	0.5~1.0
11	0.2~0.5

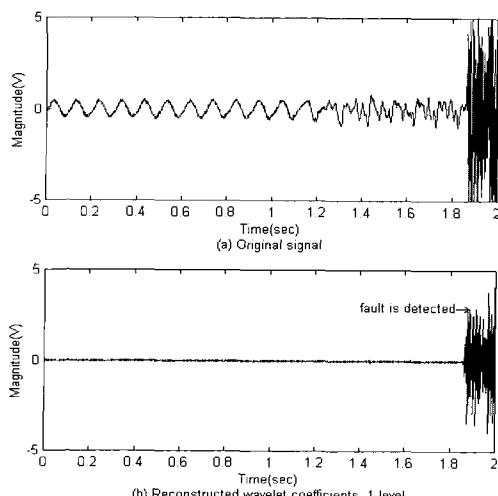


그림 3. 전류 신호를 이용한 이상 감지.

Fig. 3. Fault detection using current signal.

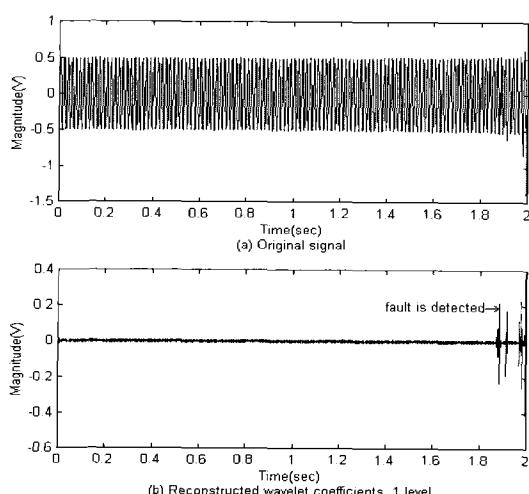


그림 4. 진동 신호를 이용한 이상 감지.

Fig. 4. Fault detection using vibration signal.

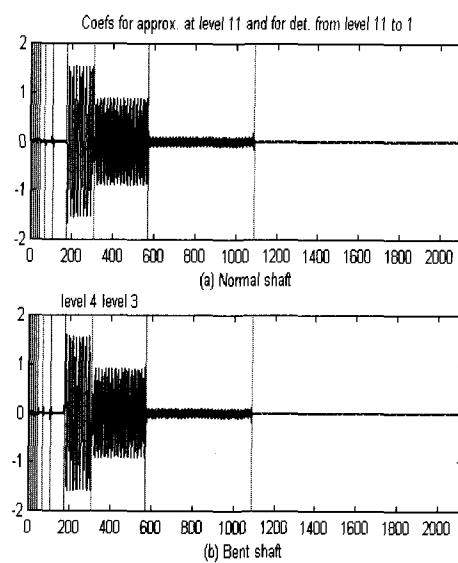


그림 5. 전류 신호의 웨이브렛 계수.

Fig. 5. Wavelet coefficients from current signal.

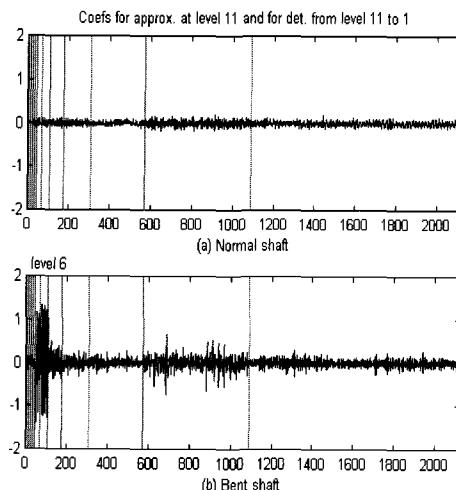


그림 6. 진동 신호의 웨이브렛 계수.

Fig. 6. Wavelet coefficients from vibration signal.

이러한 고장의 감지는 정상에서 축이 휘는 극단적인 경우를 고려한 것이고, 앞서 설명한 공회전, 액면통과 등 교반기의 다양한 고장에 대한 감지와 분석을 위해서는 여러 고장의 패턴을 분류하는 작업이 요구된다. 그림 5, 6은 회전속도 540rpm의 정상인 축과 휘 축 경우를 전류 및 진동신호를 최대 분할 레벨인 11레벨까지 웨이브렛 변환을 수행한 결과이다. 표 1에서 볼 수 있듯이 전류신호의 경우, 51, 69Hz와 42, 78Hz의 측파대(sideband)[1]를 포함하는 3, 4레벨(31.3~125.0Hz)에서 에너지가 나타나기는 하나 차이가 미약함을 알 수 있다. 반면에 진동신호의 경우는 회전속도에 해당하는 회전주파수(9Hz)를 포함하는 6레벨(7.8~15.6Hz)에서 에너지가 나오는 것을 알 수 있으며 차이가 가장 큼을 알 수 있다.

## 2. 변수 추출(feature extraction)

고장감지 및 진단을 위해서는 고장에 가장 민감한 부분이

감시되어야 할 것이다[6]. 그림 5는 앞서 분석한 신호를 웨이브렛 변환하여 각 레벨에서의 에너지 값을 그린 것으로 고장의 경우 이러한 민감한 부분이 어디인가를 알려준다. 예상한 바와 같이 전류신호의 경우, 51, 69Hz와 42, 78Hz의 축파대(sideband)[1]를 포함하는 레벨 3, 4에 에너지의 대부분이 있음을 알 수 있고 정상과 비정상의 차이가 나타나게 된다. 진동신호의 경우에는 회전주파수(9Hz)를 포함하는 레벨 6, 7에서 큰 차이를 보이게 되며, 이는 지금까지의 결과들과 모두 일치함을 알 수 있다.

패턴인식을 위해 신경망 회로로 적용할 때에도 이러한 민감한 부분, 즉 정상과 고장의 특색이 나타나는 적정레벨에 대해서만 입력변수로 취할 수 있을 것이고 웨이브렛 계수들을 직접 입력변수로 사용해도 되나, 본 연구에서는 적용하는 시스템에 대한 제반사항을 전혀 모른다고 가정하고, 웨이브렛 변환이 가능한 최대 레벨까지의 에너지 값을 신경망의 입력변수로 이용하였다[9]. 이는 입력변수의 차수를 줄일 수 있게 되어 패턴인식을 위한 신경망 회로의 구조를 단순화할 수 있을 뿐만 아니라, 신호에 포함된 노이즈의 영향도 줄일 수 있을 것이다 기대된다. 이 밖에도 각 레벨의 평균값과 편차 등을 입력변수로 취해[6][7] 실험한 결과 전류의 경우는 평균값과 편차가, 진동의 경우는 에너지 값이 가장 나은 결과를 보였다.

### 3. 고장유형 분류(neural network for classification)

제안된 방법의 성능을 테스트하기 위해 정상운전, 공회전 운전, 액면통과운전의 3가지 운전상태와 각 운전 상태에 대해 정상축과 축이 흔 경우의 총 5700개, 6개 유형의 데이터(학습을 위한 1140개의 데이터, 테스트를 위한 4560개의 데이터)가 사용되었다. 본 연구에서 사용된 신경망의 구성을 그림 8과 같다.

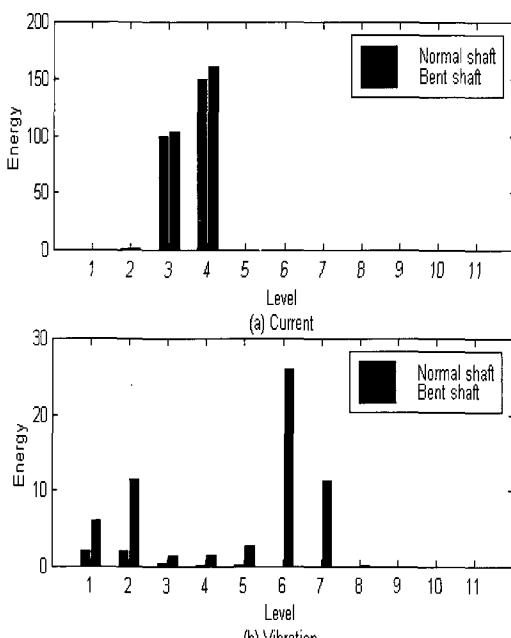


그림 7. 각 레벨의 에너지.

Fig. 7. Energy of each level.

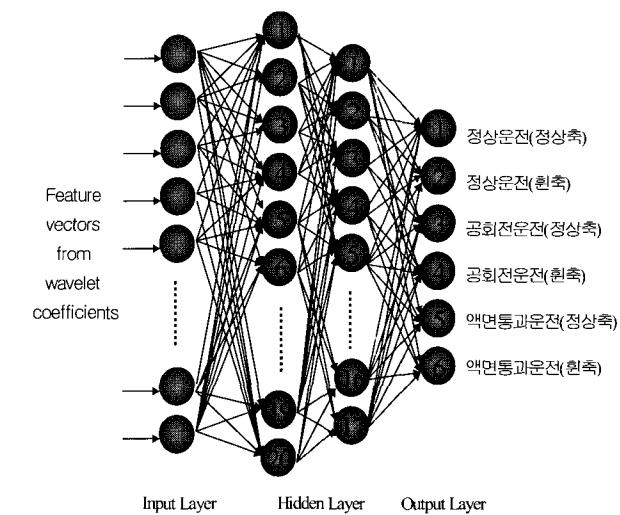


그림 8. 역전파 신경망의 구조.

Fig. 8. Architecture of back-propagation neural network.

신경망의 학습은 일괄 처리(batch mode)로 수행되었으며, 여러 가지의 고장 패턴을 분류하기 위해 20-17개의 뉴런을 가진 2개의 은닉층과 6개의 뉴런을 가진 출력층으로 이루어진 신경망을 구성하여 인지된 각 유형에 대해 1의 값을 출력하도록 하였다.

역전파 알고리즘이 사용되었으며 기중함수로 sigmoid 함수를 사용하였고 모멘텀 상수는 0.8로 하였다.

표 2는 테스트 결과로서, 예상한 것처럼 진동신호를 사용할 경우가 보다 나은 인식률을 보였다. 이는 물과 같은 저 점도의 물질을 실험에 사용하였기 때문에 이상 시에 교반기 모터의 전류 변화가 적었기 때문이라 생각 되며 90rpm의 저속회전에서 76.5%, 230rpm 이상의 속도에서는 88.9%의 진단 성공을 보였다.

표 2. 웨이브렛 변환을 이용한 실험 결과.

Table 2. Test results using the wavelet transform.

Class1 : 정상운전 a : normal shaft

Class2 : 공회전운전 b : bent shaft

Class3 : 액면통과운전

Class		Testing sample no.	Current data detection rate(%)	Vibration data detection rate(%)
1	a	1120	84.2	90.8
	b	560	40.2	87.9
2	a	640	65.2	90.3
	b	560	58.4	87.3
3	a	1120	73.5	84.9
	b	560	73.4	86.1
Total		4560	69	87.9

### V. 결론

본 연구에서는 교반기에 대해 웨이브렛 변환을 이용하여 순간적으로 변화하는 과도적 특성의 검출과 변수추출을 통한 고장감지 및 진단을 수행하였다. 신경망을 통하여 제안

된 방법의 가능성을 검토하였으며, 진동의 경우 약 88%의 패턴인식의 결과를 낳았다.

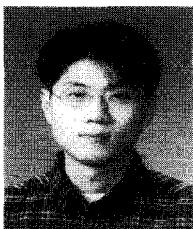
더 나은 인식률을 위해 웨이브렛 패킷의 이용, 적절한 클러스터링 등 최적의 입력변수의 선택 및 변수추출에 대한 연구가 진행 중이며, 패턴인식을 위한 적절한 신경망의 구성 및 최종적인 알고리즘의 개발이 현재 진행중이다. 대개 패턴 분류를 위한 신경망 회로는 고장감지만을 위한 신경망보다 더 그리고 더 복잡한 구조로 되어 있을 것이다. 또한 실제 시스템에서 대부분의 신호들은 정상일 것이기 때문에 고장감지와 패턴 분류를 위한 두 개의 별개의 신경망 회로를 구성하여 고장인 경우에만 두 번째 신경망을 구동하는 것이 실제 알고리즘 구현에 적절할 것이다. 궁극적으로, 본 연구는 일정한 주파수에서 작동하는 다양한 시스템에 있어서 고장 감지 및 진단에 적용 가능할 것이라 예상된다.

#### 참고문헌

- [1] R. Yacamini, K. S. Smith, and L. Ran, "Monitoring torsional vibrations of electro-mechanical systems using stator currents," *Journal of Vibration and Acoustics*, Vol. 120, pp. 72-79, 1998.
- [2] X. Li, S. Dong, and Z. Yuan, "Discrete wavelet transform for tool breakage monitoring," *International Journal of Machine Tools & Manufacture*, Vol. 39, pp. 1935-1944, 1999.
- [3] Y. Yao, X. Li, and Z. Yuan, "Tool wear detection with fuzzy classification and wavelet fuzzy neural network," *International Journal of Machine Tools & Manufacture*, Vol. 39, pp. 1525-1538, 1999.
- [4] X. Hongjian, Y. Kechong, and Y. Rong, "The shape characteristic detection of tool breakage in milling operations," *International Journal of Machine Tools & Manufacture*, Vol. 37, pp. 1651-1660, 1997.
- [5] G. S. Hong, M. Rahman, and Q. Zhou, "Using neural network for tool condition monitoring based on wavelet decomposition," *International Journal of Machine Tools & Manufacture*, Vol. 36, pp. 551-566, 1996.
- [6] Y. M. Niu, Y. S. Wong, and G. S. Hong, "Multi-category classification of tool conditions using wavelet packets and ART2 network," *Journal of Manufacturing Science and Engineering*, Vol. 120, pp. 807-816, 1998.
- [7] K. Mori, N. Kasashima, J. C. Fu, and K. Muto, "Prediction of small drill bit breakage by wavelet transforms and linear discriminant functions," *International Journal of Machine Tools & Manufacture*, Vol. 39, pp. 1471-1484, 1999.
- [8] P. W. Prickett and C. Johns, "An overview of approaches to end milling tool monitoring," *International Journal of Machine Tools & Manufacture*, Vol. 39, pp. 105-122, 1999.
- [9] S. Pittner and S. V. Kamarthi, "Feature extraction from wavelet coefficients for pattern recognition tasks," *IEEE Transactions on Pattern analysis and Machine Intelligence*, Vol. 21, pp. 83-88, 1999.
- [10] H. Wang and K. L. Butler, "Detection of transformer winding faults using wavelet analysis and neural network," *Intelligent Systems Application to Power Systems Conference*, pp. 231-235, 1999.

#### 서 동 육

1973년 1월 17일생. 1998년 단국 대학교, 전기공학과(공학사). 2001년 서강대학교 기계공학과 (공학석사). 2001년~현재 삼성전자 TN총괄 통신 연구소 연구원.



#### 전 도 영

1984년 서울대학교 기계공학과 (공학사). 1986년, 1991년 University of California, Berkeley 기계공학과 (공학석사, 공학박사) 1992년~1994년 University of Miami 조교수. 1994년~현재 서강대학교 기계공학과 교수. 관심분야는 고속고정밀서보제어, 기계가공관련제어, MR유체 응용, 공정모니터링시스템.

