

# 웨이브렛 변환과 신경망 알고리즘을 이용한 드릴링 버 생성 음향방출 모니터링

이성환<sup>#</sup>, 김태은\*, 라광렬\*

## Acoustic Emission Monitoring of Drilling Burr Formation Using Wavelet Transform and an Artificial Neural Network

Seoung Hwan Lee<sup>#</sup>, Tae Eun Kim\*, Kwang Youel Raa\*

### ABSTRACT

Real time monitoring of exit burr formation is critical in manufacturing automation. In this paper, acoustic emission (AE) was used to detect the burr formation during drilling. By using wavelet transform (WT), AE data were compressed without unnecessary details. Then the transformed data were used as selected features (inputs) of a back-propagation artificial neural net (ANN). In order to validate the in process AE monitoring system, both WT-based ANN and cutting condition (cutting speed, feed, drill diameter, etc.) based ANN outputs were compared with experimental data.

**Key Words :**Drilling Burr (드릴링 버), AE Monitoring (음향방출 모니터링), Wavelet Transform (웨이브렛 변환), Artificial Neural Network (인공지능신경망)

### 1. 서론

Gillespie<sup>1</sup>에 따르면 버 제거 (deburring) 비용이 정밀부품 생산공정 비용 가운데 30% 정도를 차지한다고 한다. 특히 버 발생은 생산공정 중 병목현상을 발생시켜 자동화에 중대한 저해요소가 되므로, 실시간으로 버 발생 및 형태를 감시하는 기술의 개발이 필수적이다. 최근 들어 Acoustic Emission (AE, 음향방출)을 이용한 절삭 상태를 감시하는 연구가 이론 및 실험적으로 활발히 진행되고 있다. 음향 방출 신호는 결합의 검출과 특성 파악에 있어서 매우 중요한 비파괴 검사 기법이며, 재료 내부에서 갑작스런 에너지의 방출이 있을 때

탄성파의 형태로 비산된 후 표면에서 센서에 의해 검출된다. 이때 검출된 음향방출 신호는 보통 비정상 (non-stationary)이며 여러가지 다이나믹한 신호들이 섞여 있다. 음향 방출 신호의 처리에서 일반적인 문제는 일정한 물리적인 파라메터에 관련된 신호가 시간과 주파수 영역 모두에서 나타날 때, 이 파라메터에 관련된 정보를 어떻게 추출하느냐 하는 것이다. 기존의 시간 영역이나 주파수 영역에서 만의 해석은 이런 문제를 해결하는데 어려움을 지니고 있다. 따라서 시간과 주파수 모두를 고려하는 방법의 필요성이 대두되었으며, Wavelet Transform (WT, 웨이브렛 변환)이 상기 요

접수일: 2004년 9월 24일; 게재승인일: 2005년 1월 21일  
<sup>#</sup>교신저자, 한양대학교 기계공학과  
E-mail: sunglee@hanyang.ac.kr, Tel.: (031) 400-5288  
\*한양대학교 대학원 정밀기계공학과

건을 충족시키는 방법으로 부각되고 있다.

많은 연구자가 AE 신호의 민감도 및 웨이브렛 변환의 신호분석에 있어서의 장점을 이용하여 복합재료의 파괴거동 등을 해석하였다. Qi<sup>3</sup> 등은 복합재의 인장 시험에서 발생하는 음향 방출 신호의 해석에 이산 웨이브렛 변환을 사용하여 웨이브렛 변환의 결과와 음향방출 신호의 이벤트와의 관계를 찾았다. 또한 Qi 와 Barhorst<sup>4</sup>는 이산 웨이브렛 변환을 이용한 AE 신호의 해석이 복합재의 파괴거동을 예측하는데 있어 기존의 방법보다 효율적이라는 것을 보인 바 있다. Suzuki 등<sup>5</sup>은 복합재의 인장시험에서 발생하는 음향방출 신호를 웨이브렛을 사용하여 분석하고 시간-주파수 평면에 도시한 결과, 파괴상태에 따라 상이한 신호 형태가 발생하는 것을 보였다. 그러나, 이 연구는 도시된 웨이브렛 변환의 결과를 일정한 기준 없이 가시적인 형태를 바탕으로 분류하는 것에 그치고 있다.

본 논문에서는 빠른 신호처리능력과 시간-주파수의 특성을 동시에 고려할 수 있는 웨이브렛의 장점을 이용하여 AE 원신호에서 의미있는 신호를 추출해낸 후(feature selection) 이 추출된 신호를 인공지능 신경망과 연계시켜 드릴링 시 실시간 버발생 형태의 감시 시스템을 구축하고자 하였다. 특히 절삭조건을 Artificial Neural Network (ANN)의 입력변수로 사용한 실행연구<sup>6</sup>와는 달리, 웨이브렛 변환 계수들의 평균과 표준편차값을 ANN의 입력데이터로 사용하는 WT-ANN 시스템을 채택함으로써, 절삭공정의 갑작스런 변화에 응답할 수 있는 효율적이고 신뢰성 있는 온라인 버 발생 모니터링 시스템의 구축 가능성을 보였다.

## 2. 웨이브렛 변환

임의의 신호가 있다고 가정할 때, 이 신호는 ‘하나의 작은 웨이브 조각(wavelet)’을 스케일링과 shifting 하여 생기는 여러 개의 작은 웨이브 조각들의 집합체로 생각할 수 있다. 이 때 ‘하나의 작은 웨이브 조각’을 모 웨이브렛 (mother wavelet) 혹은 기본 웨이브렛이라 하며, 이렇게 신호를 웨이브렛으로 쪼개어 그 상관 관계를 구하는 것을 웨이브렛 변환이라 한다. 또한 그 역의 과정도 성립할 수 있으며, 이를 웨이브렛 재구성(wavelet reconstruction)이라 한다.

웨이브렛은 스케일링에 따라 관련 주파수대가

변화하게 되며, 따라서 신호의 특정 주파수와 관련된 성질을 구할 수 있다. 그러므로 특정 주파수 대역에서 시간 축에 대한 성질 또한 얻을 수 있다.

웨이브렛 변환의 이러한 점을 이용하여 신호의 특성을 시간-주파수 두 축으로 이루어진 평면상에 도시하는 것이 가능하다. 이 평면을 시간-주파수 평면이라 한다. 신호에 웨이브렛 변환을 가하여 얻어진 웨이브렛 계수(wavelet coefficients)를 시간-주파수 평면상에 나타냄으로써 신호의 해석이 용이해 질 수 있으며, 이와 같은 시간-주파수 해석은 비정상 신호의 해석에 유용하다.

웨이브렛 변환은 그 방법에 따라 연속 웨이브렛 변환과 이산 웨이브렛 변환으로 나뉘어 진다.

### 2.1 연속 웨이브렛 변환

시간 t의 함수 f(t)의 웨이브렛 변환은 다음식으로 정의된다.

$$W(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (1)$$

식(1)에서 보는 바와 같이 웨이브렛 변환의 결과인 웨이브렛 계수는 a, b의 함수이며, a는 주파수 축에서의 스케일링으로 a>0 이고, b는 시간 축에서의 shifting을 나타내며,  $\bar{\psi}$ 는  $\psi$ 의 복소공액을 나타낸다.

함수  $\psi(t)$ 는 허용조건

$$\int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (2)$$

를 만족하며, 기본 웨이브렛이라고 불린다. 여기서  $\hat{\psi}$ 는 푸리에 변환을 나타내며, 허용조건 식(2)을 만족하는 함수는 기본 웨이브렛으로 사용될 수 있다.

### 2.2 이산 웨이브렛 변환

이산 웨이브렛 변환은 높은 주파수 대역의 신호를 분리해내는 하이패스 필터와 낮은 주파수 대역의 신호를 분리해내는 로우패스 필터의 집합인 필터뱅크(filter bank)로 구성된다. 필터뱅크는 트리 구조(tree structure)를 가지며 로우패스 필터를 통과한 신호가 다시 웨이브렛 변환되는 형식으로

구성된다. 일반적으로 신호의 특성을 결정짓고 신호를 다른 신호와 구별되게 하는 특징은 낮은 주파수 쪽에 있으므로 로우패스 필터를 통과한 신호는 신호의 대체적인 특징을 나타내주는 근사신호가 되며, 하이패스 필터를 통과한 신호는 신호의 세부사항을 나타내는 세부신호(detail)이 된다.

이산 웨이브렛 변환은 앞서 언급된 변환식에서  $a, b$  를 2의 누승이 되는 스케일을 사용하여 나타내게 된다. 즉,  $a = 2^j, b = k2^j$  일때, 웨이브렛은  $\psi_{j,k} = 2^{-\frac{j}{2}} \psi(2^{-j}t - k)$ 로 표현되며, 이산 웨이브렛 계수는 다음과 같이 정의된다.

$$c_{j,k} = \int x(t) \overline{\psi_{j,k}(t)} dt \quad (3)$$

### 3. 실험장치 및 조건

실험에 사용된 피삭재는 기계부품 등에 널리 사용되는 순동(copper)과 황동(brass)을 택하였으며, 화학적인 성분과 조성은 Table 1과 같다. Table 2는 피삭재들의 기계적 성질을 나타내고 있다.

Table 1 Chemical composition (wt.%) of workpieces

Material	Composition (wt. %)			
	Cu	Zn	Pb	Fe
Brass	64.2	35.5	0.07	0.05
Copper	99.96	-	-	-

Table 2 Mechanical properties of workpieces

Material	Tensile strength (MPa)	Modulus of Elasticity (GPa)	Hardness (Hv)
Brass	317	103	100
Copper	250	115	77

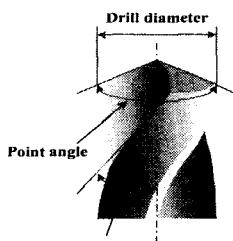


Fig. 1 Drill geometry

Table 3 Drill specifications

Items	Specifications
Model	HSS 표준드릴
Point angle	118°
Helix angle	24°
Material	텅스텐, 주철, 탄소강
Diameter	3mm, 5mm

실험은 수직형 머시닝 센터 (현대정공 AJV-18)를 사용하여 수행하였다. Fig. 1과 Table 3은 각각 실험에 사용된 드릴의 형상 및 사양을 나타낸다.

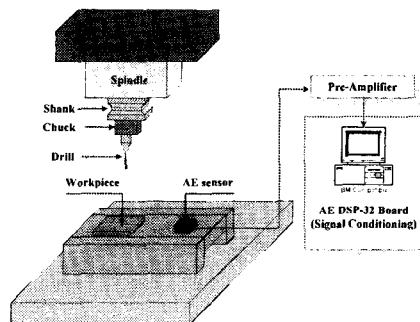


Fig. 2 Experimental setup

Table 4 Cutting conditions

Items	Conditions
Materials	Brass, Copper
Drill diameter (mm)	3, 5
Spindle speed (rpm)	600, 1000, 1500, 2000, 3000
Feed (mm/rev)	0.05, 0.1, 0.15, 0.2, 0.25
Exit length (mm)	0.1
Cutting fluid	dry

Fig. 2는 드릴 가공 중에 발생하는 신호를 AE 센서를 이용해서 신호처리하는 과정을 나타내고 있다. AE신호는 PAC사의 광대역형 R15 AE 센서와 AE신호 샘플링을 위한 고속신호처리용 DSP보드인 AEDSP32/16 및 컴퓨터를 이용하여 측정하였다. 샘플링율은 1MHz로 하였으며, AE센서에서 검출된 신호는 전치 증폭기에서 40dB증폭하고, AEDSP32/16에서 디지털 신호로 변환되어 컴퓨터

에 입력되게 하였다. 입력된 디지털 신호는 AE 전용 소프트웨어인 MISTRAS프로그램을 사용하여 처리하였다. 실험에 사용된 시편은  $30 \times 30 \times 0.5\text{mm}$ 의 크기를 가지는 직사각형 형태를 가진다. Table 4는 실험에 사용된 절삭 조건을 나타낸다.

#### 4. 실험 결과

##### 4.1 버 형태의 분류

Table 5에서 버의 형태를 관찰한 결과를 3가지로 분류하였다. 첫째, Type I은 버 높이가 작고 일정한 경우이며 이송이 가장 작을 때 많이 발생하였다. 둘째, Type II는 출구 모서리에 캡(cap)이 옆에 붙어있는 형태로 이 경우도 이송이 작을 때 많이 생성되었다. 셋째, Type III은 버의 형태가 출구 주위에 찢어진 형태로 남아있는 경우이다. 드릴링 버는 Type I에서 III으로 갈수록 가공정밀도 및 조립 등에 악영향을 미친다. 또, 일반적으로 발생 버의 형태는 이송이 일정하고 rpm이 높아지면 Type III에서 Type I로, rpm이 일정하고 이송이 높아지면 Type I에서 Type III으로 가는 경향을 보인다<sup>6,7</sup>. 본 연구에서는 Type I과 Type II를 Type A, Type III을 Type B로 각각 정의하였다.

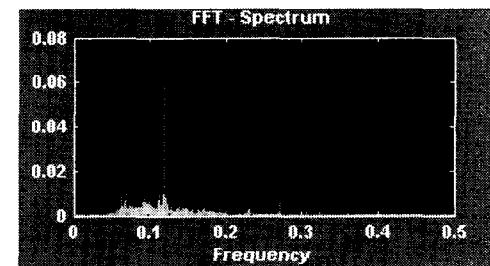
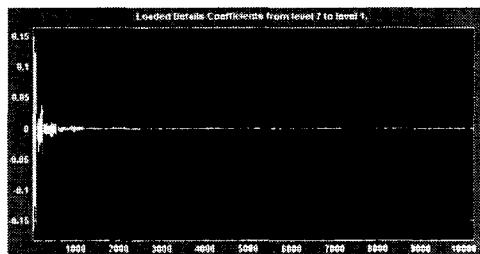
Table 5 Classification of drilling burrs

Materials	Type	Type A	Type B
	Type I (uniform burr)	Type II (uniform burr with cap)	Type III (petal burr)
Brass			
Copper			

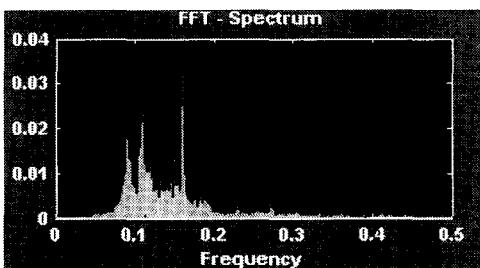
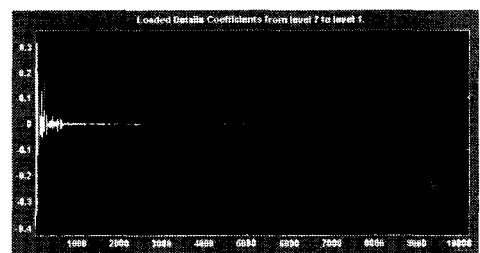
##### 4.2 신호분석 및 특징추출

본 연구에서는 모 웨이브렛으로 다우비치 웨이브렛(Daubechies Wavelet)을 사용하였다. 다우비치 웨이브렛은 다른 웨이브렛 변환보다 콤팩트하고, 불규칙한 모양의 신호에 대하여 더욱 뛰어난 성능을 보이므로 음향방출 신호의 해석에 있어서 효율적이다. Fig. 3, 4는 각 재료 조건별 AE 원신호

(raw signal)에서 10240개의 샘플을 취한 후FFT 및 7레벨까지의 웨이브렛 변환을 수행한 결과 중 일부를 예시한 것이다. AE원신호만 가지고 버의 형태를 구별하기 힘들고, FFT신호 또한 유용한 데이터를 무시할 수 있는 가능성이 있는 반면, Fig. 3과 Fig. 4의 경우 (웨이브렛 변환 데이터) 각 주파수 범위-즉, 각 레벨-에서 신호의 특징을 볼 수 있다.

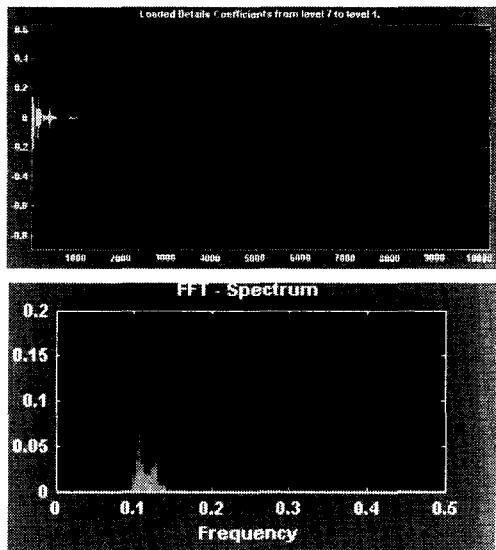


(a) Type A(rpm=600, feed=0.05mm/rev, dia=3mm)

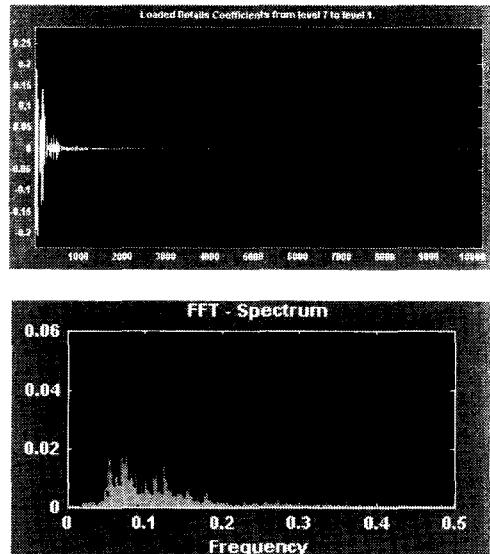


(b) Type B (rpm=1500, feed=0.1mm/rev, dia=3mm)

Fig. 3 Wavelet transform and FFT results (Brass)



(a) Type A(rpm=1000, feed=0.05mm/rev, dia=3mm)

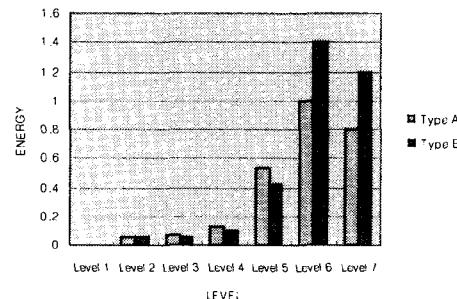


(b) Type B(rpm=1500, feed=0.1mm/rev, dia=3mm)

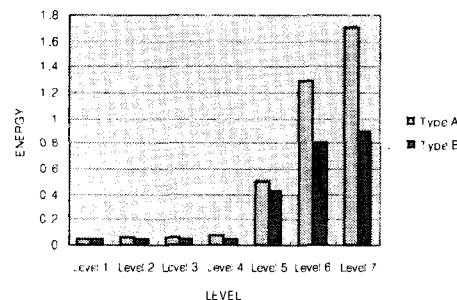
Fig. 4 Wavelet transform and FFT results (Copper)

Fig.5는 웨이브렛 변환 후 각 레벨에서의 에너지 값을 표시한 것으로 어떤 주파수 범위가 베의 형성에 있어서 가장 민감한 부분인지 보여주고 있다. 그림에서와 같이 레벨6(62.5 -125 kHz)과 레벨7(125-250 kHz)에 대부분의 에너지가 집중됨을 알 수 있으며 따라서 본 연구에서는 레벨6, 7의 웨이

브렛 계수의 평균과 표준편차를 신경회로망의 입력 변수로 사용하였다.



(a) Brass



(b) Copper

Fig. 5 Energy levels during drilling

## 5. 뉴럴네트워크를 이용한 베의 예측

Table 6 Learning data set (wavelet coefficients ) for training neural network

Input nodes	Output node	Learning condition
[1] Level 7 Mean [2] Level 7 Standard Deviation [3] Level 8 Mean [4] Level 8 Standard Deviation	BurrType (TypeA/ Type B)	[1] Input node number 4 [2] Output node number 1 [3] No. of Hidden layer nodes 5 [4] Sample pattern number 20 [5] Initial learning rate 0.1 [6] Error bound 0.1

뉴럴네트워크는 출력층의 오차 신호를 이용하여 은닉층과 출력층간의 연결강도를 변경하고, 출력층의 오차 신호를 은닉층에 역전파하여 입력층과 은닉층 간의 연결강도를 변경하는 학습방법인

BP (back propagation) 알고리즘을 사용하였다. 결과 데이터 값이 0인 경우는 Type A (uniform burr, uniform burr with cap)에 해당하며, 데이터 값이 1인 경우는 Type B (petal burr)에 해당한다. 학습 데이터셋은 Table 6에 나타내었다.

학습으로부터 얻은 노드 간의 연결강도를 Fig. 6과 같은 구조의 뉴럴네트워크에 적용하였다. 드릴 가공 시 얻은 AE데이터를 웨이브렛 변환한 후 특정 추출을 통해서 얻은 평균과 표준편차를 입력 변수로 사용하였고, 입력 값은 실험에서 얻은 데이터 중 연결 강도를 구하는데 사용한 데이터를 제외한 나머지 데이터를 사용하였다. Fig. 7은 선행 연구<sup>7</sup>에서 사용된 뉴럴네트워크 구조로써 실험 조건은 동일하며, Fig. 6과 달리 실험 조건 자체를 입력 변수로 사용한 경우이다. Table 7은 웨이브렛 계수를 사용한 인공지능신경망 적용 결과를 정리한 것이다.

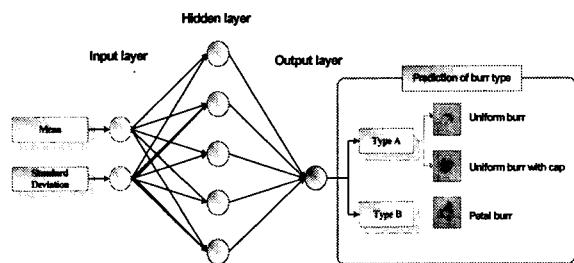


Fig. 6 Architecture of WT+ ANN

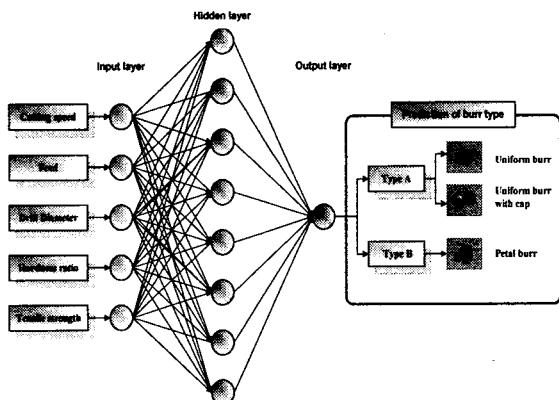


Fig. 7 Architecture of cutting condition based neural network

Table 7 ANN results using wavelet coefficients

Index	Input Parameter			Output	Real Type
	LEVEL 6	LEVEL 7	Burr Type (TypeA=0, Type B=1)		
1	0.000035012	0.001891	-0.0001512	0.00511	0.0141 0
2	0.0000214	0.002103	-0.0000436	0.007892	0.055 0
3	-0.00002556	0.01215	0.001145	0.01845	0.017 0
4	-0.0001202	0.01059	0.0006123	0.0024102	0.9821 1
5	0.0001105	0.006511	-0.0000073	0.02501	0.9128 1
6	0.00005125	0.01602	0.0000420	0.02996	0.9668 1
7	0.000008678	0.0019068	-0.0001750	0.009001	0.9042 1
8	-0.00003125	0.008712	0.0009741	0.02298	0.1325 0
9	-0.00004456	0.00423	0.0002226	0.02327	0.0859 0
10	-0.0001169	0.003101	-0.0002714	0.01835	0.1002 0
11	-0.00003508	0.002004	-0.0001296	0.006114	0.0898 0
12	0.00004641	0.004626	0.001188	0.01092	0.013 0
13	0.00005698	0.002415	-0.0001598	0.005146	0.9249 1
14	0.00003838	0.003658	-0.001604	0.01193	0.9024 1
15	0.00004921	0.003359	-0.003295	0.01074	0.1024 0
16	-0.00001257	0.001754	0.00002449	0.004661	0.9479 1
17	0.00002692	0.002497	0.00007707	0.01389	0.9231 1
18	-0.0000382	0.003788	-0.0003015	0.0158	0.0946 0

Fig. 8에서 선행연구 결과와 웨이브렛 변환의 계수를 입력변수로 사용한 본 연구의 결과를 비교해보았다. 베형상을 예측하는데 있어 웨이브렛 계수를 입력 값으로 이용한 결과값이 더욱 높은 신뢰성을 보여주고 있다. 특히, 웨이브렛 변환을 이용한 학습은 선행 연구되었던 절삭 조건을 입력 변수로 하였을 때와 비교하여 보다 효과적인 특정 치 추출 성능을 가질 뿐만 아니라, 적은 양의 학습 데이터를 사용하여, 계산/수렴속도 향상을 보임으로써 효율적이고 정확한 베 예측 시스템의 설계를 가능하게 하였다.

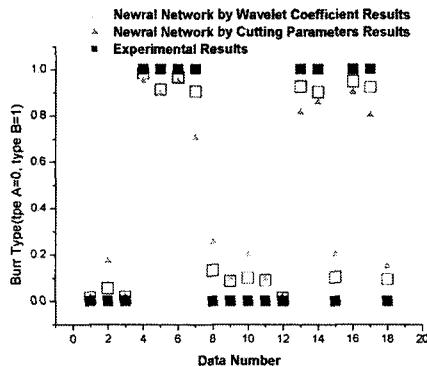


Fig 8 Prediction results of burr type using neural networks

## 6. 결 론

본 연구에서는 순동과 황동 드릴 가공 시 발생하는 AE신호를 이용하여 버의 형상을 예측하고 모니터링 하는데 있어 필요한 연구를 수행하였다. 특히 AE데이터로부터의 효율적인 특징 추출 (feature extraction) 및 특징 선택 (feature selection)을 위하여 웨이브렛 변환과 뉴럴네트워크를 연계하여 (WT + ANN) 사용하였고, 선행 연구되었던 절삭 조건을 이용한 뉴럴네트워크 결과와 비교해 보았다. 결론은 다음과 같다.

- [1] 드릴 가공 시 발생하는 AE신호를 7레벨의 웨이브렛 신호로 변환 후, 신호와 버 발생 형태를 비교한 결과, 특정 레벨 (레벨6, 7) 의 평균과 표준편차 값으로 버 형성 형태를 분류 할 수 있었으며, 따라서 이 값들을 특징값 (feature value)으로 정하였다.
- [2] 선행연구에서 사용되어진 절삭조건을 입력 값으로 하는 경우와 비교하여, 버 형상을 예측하는데 있어 WT+ ANN의 결과가 더 높은 신뢰성을 보여주어 향후 지능형 가공 시스템 구축에 있어 유용하게 사용될 수 있음을 입증하였다.

## 참고문헌

1. Gillespie, L. K., "Deburring Precision Miniature Parts," *Precision Engineering*, Vol. 1, No. 4, pp. 189-198, 1979.
2. Serrano, E. P. and Fabio, M. A., "Application of the Wavelet Transform to Acoustic Emission Signals Processing," *IEEE Transaction on Signal Processing*, Vol. 44, No. 5, pp. 1270-1275, 1996.
3. Qi, G., Barhorst, A., Hashemi, J. and Kamala, G., "Discrete Wavelet Decomposition of Acoustic Emission Signals from Carbon-Fiber-Reinforced Composites," *Composite Science and Technology*, Vol. 57, pp. 389-403, 1997.
4. Qi, G. and Barhorst, A., "On Predicting the Fracture Behavior of CFR and GFR Composite Using Wavelet-Based AE Techniques," *Engineering Fracture Mechanics*, Vol. 58, No. 4, pp. 363-385, 1997.
5. Suzuki, H., Kinjo, T., Hayashi, Y., Takemoto, M. and Ono, K., "Wavelet Transform of Acoustic Emission Signals," *Journal of Acoustic Emission*, Vol. 14, No. 2, pp. 69-84, 1996.
6. Kim, J. and Dornfeld, D. A., "Development of a Drilling Burr Control Chart for Stainless Steel," *Trans. of NAMRC/SME* Vol. XXVIII, pp. 317-322, 2000.
7. Lee, S.H. and Kwon, S. Y., "Prediction of Burr Size in Micro-Drilling," *Journal of the Korean Society of Precision Engineering*, Vol. 20, No11, 2003.
8. Monostori, L., "Learning Procedures in Machine Tool Monitoring," *Computers in Industry*, North-Holland, Vol. 7, pp. 53-64, 1986.
9. Rao, R.M. and Bopardikar, A., "Wavelet Transform," Addison-Wesley Longman, 1998.