

# 웨이브렛 변환을 이용한 밀링 버 생성 음향방출 모니터링

이성환<sup>+</sup>, 마채훈\*, 조용원\*

(논문접수일 2006. 1. 5, 심사완료일 2006. 5. 19)

## Acoustic Emission Monitoring of Milling Burr Formation Using Wavelet Transform

Seoung Hwan Lee<sup>+</sup>, Che Hoon Ma\*, Yong Won Cho\*

### Abstract

Detection of exit burr is very important in manufacturing automation. In this paper, acoustic emission(AE) was used to detect the burr formation during milling. By using wavelet transformation, AE data was compressed without unnecessary details. Then the transformed data were used as selected features(inputs) of a back-propagation artificial neural net. In order to validate the proposed scheme, the wavelet based ANN results were compared with cutting condition(cutting speed, feed, depth of cut, etc.) based ANN results.

**Key Words** : Neural Network(신경망), Milling(밀링), Burr(버), Acoustic Emission(음향 방출), Wavelet Transform(웨이브렛 변환)

## 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(음향방출, AE)을 이용한 절삭 상태를 감시하는 연구가 이론 및 실험적으로 활발히 진행되고 있다. 음향방출 신호는 절삭의 검출과 특성 파악에 있어서 매우 중요한 비

파괴 검사 기법이며, 재료 내부에서 갑작스런 에너지의 방출이 있을 경우, 탄성파의 형태로 비산된 후, 표면에서 센서에 의해 검출된다. 이 때 검출된 음향 방출 신호는 보통 비정상(non-stationary)이며 여러 가지 다양한 신호들이 섞여 있다. 음향방출 신호의 처리에서 주요한 문제는 물리적인 파라미터가 시간과 주파수 모두에 관련될 때, 이 파라미터를 어떻게 추출하느냐 하는 것이다. 기존의 시간 영역이나 주파수 영역에서만 해석은 이런 문제를 해결하는데 난점을 지니고 있다. 따라서 시간과 주파수 모두를 고려하는 방법의 필요성이 대두되었으며, 웨이브렛 변환이 상기의 요건을 충

<sup>+</sup> 한양대학교 기계공학과 (sunglee@hanyang.ac.kr)

주소: 426-791 경기도 안산시 상록구 사1동 1271

\* 한양대학교 대학원 메카트로닉스·시스템 공학과

족 시키는 방법으로 부각되고 있다.

Serrano와 Fabio<sup>(2)</sup>는 음향 방출 신호의 분석에 웨이브렛 변환이 사용될 수 있음을 보였고, Qi<sup>(3)</sup> 등은 복합재의 인장 시험에서 발생하는 음향 방출 신호의 해석에 불연속 웨이브렛 변환을 사용하여 웨이브렛 변환의 결과와 음향 방출 신호의 이벤트와의 관계를 찾았다. 또한 Qi와 Barhorst<sup>(4)</sup>는 불연속 웨이브렛 변환에 기초한 음향 방출신호의 해석이 복합재의 파괴 거동을 예측하는데 있어 기존의 방법보다 우수함을 보인 바 있다. Suzuki<sup>(5)</sup> 등은 연속 웨이브렛 변환을 이용하여 GFRP 복합재의 인장시험에서 발생하는 음향방출 신호를 분석하여 시간-주파수 평면에 도시한 결과, 여러 가지 파괴의 상태에 따른 신호들을 쉽게 분류 할 수 있음을 보였다. 그러나, Suzuki 등의 연구는 결합의 종류에 따라 신호를 분류하는데 웨이브렛 변환이 유효함을 보이고 있지만, 웨이브렛 변환의 결과를 시간-주파수 평면상에 도시하고 육안에 의해 분류하는 것에 그치고 있다.

본 논문에서는 빠른 신호처리능력과 시간-주파수의 특성을 동시에 고려할 수 있는 웨이브렛의 장점을 이용하여 AE 원신호에서 의미있는 신호를 추출해 낸 후(feature selection) 이 추출된 신호를 인공지능 신경망과 연계시켜 밀링 시 실시간 버 발생 형태의 감시 시스템을 구축하고자 하였다.

본 연구에서는 웨이브렛 변환 계수들의 평균과 표준편차 값을 ANN(Artificial Neural Network)의 입력 데이터로 사용하는 Wavelet Transform - Neural Networks(WT-NN) 시스템을 채택함으로써, 절삭공정의 갑작스런 변화에 응답할 수 있는 효율적이고 신뢰성 있는 온라인 버 발생 모니터링 시스템의 구축 가능성을 보였다.

## 2. 웨이브렛 변환<sup>(6)</sup>

참고 문헌 (6)에서 설명한 된 것과 같이 웨이브렛 변환은 다음과 같이 연속 웨이브렛 변환과 불연속 웨이브렛 변환으로 나눌수 있다.

### 2.1 연속 웨이브렛 변환

시간 t의 함수f(t)의 웨이브렛 변환은 다음식으로 정의된다.

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

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

는  $\psi$ 의 복소공액을 나타낸다.

함수  $\psi(t)$ 는 허용조건,

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

을 만족하며, 기본 웨이브렛 이라고 불린다. 여기서  $\hat{\psi}$ 는 푸리에 변환을 나타내며,

$$\hat{f}(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \quad (3)$$

이다. 허용조건 식 (3)을 만족하는 함수는 기본 웨이브렛으로 사용될 수 있다.

### 2.2 이산 웨이브렛 변환

불연속 웨이브렛 변환은 신호를 높은 주파수 대역의 신호를 분리해내는 하이패스 필터와 낮은 주파수 대역의 신호를 분리해내는 로우패스 필터의 집합인 필터 뱅크(filter bank)로 구성된다.

필터 뱅크는 트리구조(tree structure)를 가지며 로우-패스 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 나타내는 근사신호(approximation)가 되며, 하이패스 필터를 통과한 신호는 신호의 세부사항을 나타내는 세부신호(detail)이 된다.

불연속 웨이브렛 변환은 앞서 언급된 변환식에서 a, b를 2의 누승이 되는 스케일을 사용하여 나타내게 된다.

즉, a = 2<sup>j</sup>, b = k2<sup>j</sup>, k∈Z 일때, 웨이브렛은  $\psi_{j,k} = 2^{-\frac{j}{2}} \psi(2^{-j}t - k)$ 로 표현되며, 이산 웨이브렛은 다음과 같이 정의된다.

$$c_{j,k} = \int s(t) \bar{\psi}_{j,k}(t) dt \quad (4)$$

여기서 c<sub>j,k</sub>는 웨이브렛 계수이며 원래의 신호x(t)의 시간-주파수 그래프상에 나타나게 된다.

## 3. 실험장치 및 조건

### 3.1 실험장치

실험에 사용된 피삭재는 버의 연구에 주로 사용되어 왔으

며 가공성이 높은 Al6061을 택하였으며, 기계적 성질은 Table 1과 같다. 실험은 수직형 머시닝 센타(현대정공 AJV-18)를 사용하여 수행하였다. Fig. 1은 밀링 가공중에 발생하는 신호를 AE센서를 이용해서 신호처리 하는 과정을 나타내고 있다.

### 3.2 실험조건

실험에 사용된 시편은 25×25×50mm의 크기를 가지는 직사각형 형태를 가진다. 여기서 파라미터는 가장 보편적이면서도 중요하게 고려되는 IXA(In-plane eXit Angle), 절삭 깊이, 피드레이트, 절삭속도(spindle revolution)로 정하였고, 수준 은 가공영역을 벗어나지 않고 기술적으로 의미를 가지는 범위를 선정하였다. Table 2는 실험에 사용된 절삭 조건을 나타낸다.




Fig. 1 Experimental setup

Table 1 Mechanical properties of workpieces

Material	A6061	
Tensile strength	310MPa	
Yield stress	275MPa	
Fracture strain	0.50	

Table 2 Cutting conditions

Parameters	Range	Standard machining
In-plane exit angle(°)	30 ~ 150	90
Depth of cut(mm)	0.5 ~ 3.5	2
Feed rate(mm/tooth)	0.05 ~ 0.25	0.15
Cutting speed(rpm)	300 ~ 1100	700

## 4. 실험결과

### 4.1 버 형태의 분류

버는 type 1과 type 2의 두가지로 분류하였으며, type 1은 상대적으로 버의 치수가 작은 Secondary 버와 Edge-breakout 이 발생하는 경우를 말한다. type 2는 Curl-type 버, Wave-type 버, Knife type 버가 발생하는 경우이다.

### 4.2 신호분석 및 특징 추출

본 연구에서 사용된 마더 웨이브렛(mother wavelet)은 다우비치 웨이브렛(Daubechies Wavelet)을 사용하였다. 다우비치 웨이브렛은 다른 웨이브렛 변환보다 더욱 콤팩트 하고 불규칙한 모양의 신호에 대하여 더욱 뛰어난 성능을 보이므로 음향방출 신호의 해석에 있어서 더 효율적이다.

Fig. 3은 밀링과정 동안 AE sensor를 통해 수신된 원신호(raw signal)에서 10240개의 샘플을 취하여 8레벨까지의 웨




Fig. 2 Burr type classification

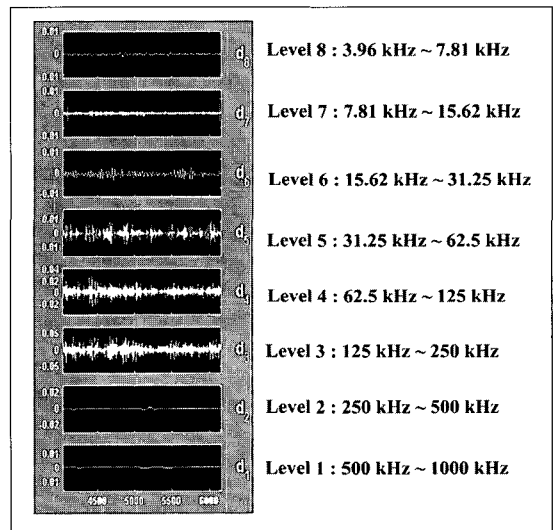


Fig. 3 Signal of each level




Fig. 4 Energy of each level in drilling process

이브렛 변환을 수행한 그림이다.

Fig. 4는 원신호를 가지고 웨이브렛 변환을 한 후 각 수준에서의 에너지값을 그린 것으로 어떤 수준 또는 어떤 주파수 범위가 버의 형성에 있어서 가장 민감한지를 보여주고 있다.

그림에서 보는 것처럼 Al6061은 밀링 초기에 버가 생성되어 진행되므로 버 생성과 관련된 수준 3, 4에서 가장 많은 에너지가 있음을 알 수 있으며 이것은 Fig. 3에서도 확인된 결과이다.

따라서 본 연구에서는 수준 3,4의 wavelet coefficient의 평균값과 표준편차값을 인공지능 신경망의 입력값으로 사용하였다.

### 5. 뉴럴네트워크를 이용한 버의 예측

뉴럴 네트워크는 출력층의 오차신호를 이용하여 은닉층과 출력층간의 연결강도를 변경하고, 출력층의 오차 신호를 은닉층에 역전파하여 입력층과 은닉층과의 연결 강도를 변경하는 학습 방법인 BP(back propagation) 알고리즘을 사용하였다.

#### 5.1 절삭조건을 입력값으로 한 경우

input node는 4개, hidden layer는 1층, hidden node는 6개, output node는 1개로 하며 input node의 각 변수들은 IXA, 절삭깊이, 피드레이트, 절삭속도로 4가지이다. 1개의 output node를 사용해서 버 형태를 분류하였다. 결과 데이터 값이 0인 경우는 type 1(secondary burr)에 해당하며, 1인 경우는 type 2(curl-type burr, wave-type burr, knife-type burr)에 해당한다.




Fig. 5 Architecture of Neural Network

Table 3 Learning data for neural network process

Input parameters				Desired output
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Cutting speed (rpm)	Burr type (type1=0, type2=1)
30	0.5	0.15	300	0
30	1.0	0.1	500	0
70	0.5	0.1	700	0
70	1.0	0.05	900	0
110	0.5	0.15	900	1
110	1.0	0.2	700	0
150	0.5	0.2	500	1
150	1.0	0.15	300	1

Table 4 Neural network process results

Input parameters				Output	Real type
In-plane exit angle (°)	Depth of cut (mm)	Feed rate (mm/tooth)	Cutting speed (rpm)	Burr type (type1=0, type2=1)	
30	1.5	0.15	700	0.0183	0
30	2.0	0.2	900	0.0178	0
70	1.5	0.2	300	0.6562	1
70	2.0	0.15	500	0.1366	0
110	1.5	0.05	500	0.2521	0
110	2.0	0.1	300	0.8991	1
150	1.5	0.1	900	0.9467	1
150	2.0	0.05	700	0.8872	1

Table 3은 Al6061의 학습에 사용된 데이터를 나타낸다. 이 데이터를 가지고 500,000회 학습을 바탕으로 노드간 연결강도를 구하였다. 그리고 학습으로부터 얻은 노드간의 연

결강도를 바탕으로 뉴럴네트워크를 실행 하였으며, 이 때 입력값은 연결강도를 구하는데 사용한 데이터를 제외한 나머지 데이터를 사용하였다. Table 4는 뉴럴네트워크를 사용하여 얻은 결과값이다.

**5.2 wavelet coefficient를 입력값으로 한 경우**

입력 노드의 각 변수들은 level 3, 4의 평균 및 표준편차 값 들이다. 1개의 출력 노드를 사용해서 버 형태을 분류하였다. 결과 데이터 값이 0인 경우는 type 1(secondary burr)에 해당하며, 데이터 값이 1인 경우는 type 2(curl-type burr, wave-type burr, knife-type burr)에 해당한다. Table 5는 Al6061의 학습에 사용된 데이터를 나타낸다. 이 데이터를 가지고 500,000회 학습을 바탕으로 노드간 연결강도를 구하였다. 그리고 학습으로부터 얻은 노드간의 연결강도를 바탕으로 뉴럴네트워크를 실행 하였으며, 이 때 입력값은 연결강도를 구하는데 사용한 데이터를 제외한 나머지 데이터를 사

용하였다. Table 6은 뉴럴네트워크를 사용하여 얻은 결과값이다.

**5.3 AE parameter를 입력값으로 한 경우**

밀링 과정 동안 AE sensor를 통해 수신된 원신호(raw signal)의 주파수 정보를 알아보기 위해서 FFT를 수행하였으며 재료에서 변형이 발생할 때는 주로 200~400kHz 사이의 신호가 발생한다는 것을 감안하여 FFT 신호 중 이 구간에서의 voltage 합계의 평균값을 입력값으로 하였다.

BP 알고리즘을 사용하였고 input node는 2개, hidden layer는 1층, hidden node는 5개, output node는 1개로 하며 input node의 각 변수들은 voltage(200~400kHz), count rate로 2가지이다. 1개의 output node를 사용해서 burr type을 분류 하였다. 결과 data 값이 0인 경우는 type 1(secondary burr)에 해당하며, data 값이 1인 경우는 type 2(curl-type burr, wave-type burr, knife-type burr)에 해당한다.

Table 7은 학습에 사용된 데이터를 나타내며, burr 형성에 가장 큰 영향을 미치는 IXA을 기준으로 분류하였다.

그리고 학습으로부터 얻은 노드간의 연결강도를 가지고 총 500,000회 학습을 수행하여 노드간의 연결강도를 바탕으로 뉴럴네트워크를 실행하였다. 이 때 입력값은 실험에서 얻은 데이터 중에서 연결강도를 구하는데 사용한 데이터를 제외한 나머지 데이터를 사용하였다. Table 8은 뉴럴네트워크를 사용하여 얻은 결과를 보여주고 있다.




Fig. 6 Architecture of Neural Network

Table 5 Learning data for neural network process

Input parameters				Desired output
Level 3		Level 4		
Mean	Standard deviation	Mean	Standard deviation	Burr type (type1=0 type2=1)
0.0001107	0.001429	-0.00006268	0.001518	0
-0.004028	0.353	-0.004646	0.1286	0
0.1144	1.432	-0.03336	0.1871	0
-0.09529	2.559	-0.09176	0.3124	1
0.02223	0.4687	0.04355	0.3333	0
-0.00005853	0.00338	-0.0005945	0.004376	1
0.0002055	0.003089	-0.00002429	0.002207	1
-0.0005735	0.008387	0.00127	0.00466	1

Table 6 Neural network process results

Input parameters				Desired output
Level 3		Level 4		
Mean	Standard deviation	Mean	Standard deviation	Burr type (type1=0 type2=1)
0.0007342	0.002195	0.0003442	0.00181	0
0.03949	1.805	-0.08116	0.2884	0
0.4334	2.956	0.4037	1.687	0
-0.1602	3.645	-0.02675	0.4038	1
-0.001391	0.08606	-0.0003709	0.0111	0
-0.00009177	0.002087	-0.00005316	0.0007436	1
0.00008581	0.004542	-0.0002179	0.00199	1
-0.0002847	0.006576	-0.0003428	0.003783	1




Fig. 7 Architecture of Neural Network

Table 7 Learning data for neural network process

In-plane exit angle(°)	Input parameter		Desired output
	Amplitude (voltage)	Count rate (count / S)	Burr type (type1=0, type2=1)
30	0.98	134	0
30	2.32	138	0
70	1.16	136	0
70	1.75	117	0
110	1.65	148	1
110	1.21	121	0
150	1.18	129	1
150	1.41	125	1

Table 8 Neural network process results

In-plane exit angle(°)	Input parameter		Out put	Real type
	Amplitude (voltage)	Count rate (count / S)	Burr type (type1=0, type2=1)	
30	0.84	139	0.11381	0
30	0.67	144	0.07796	0
70	1.93	155	0.22937	0
70	1.53	157	0.32181	0
110	3.38	115	0.90326	1
110	1.16	163	0.13172	0
150	2.18	112	0.98284	1
150	1.67	122	0.78023	1

5.4 인공지능 신경망을 사용한 버 예측 결과 비교

Fig. 8은 절삭조건으로 뉴럴네트워크를 실행한 데이터인 Table 4와, wavelet coefficient로 뉴럴네트워크를 실행한 데이터인 Table 6에서 구해진 결과를 서로 비교해 보기 위해 그래프로 나타낸 것이다.




Fig. 8 Prediction results of burr type using neural network

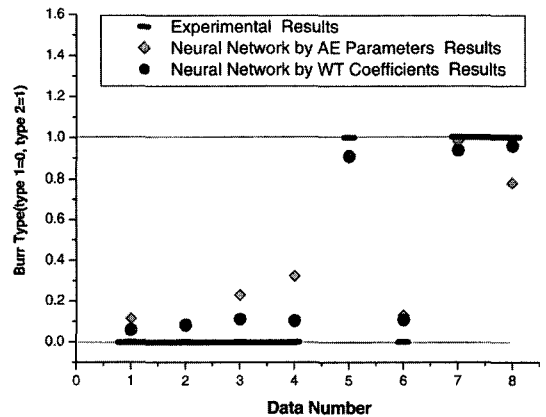


Fig. 9 Prediction results of burr type using neural network

그래프를 보면 알 수 있듯이, 버 형태를 예측하는데 있어 WT를 사용한 경우가, 절삭조건을 입력값으로 하였을 때 보다 실제 측정에서 얻은 버 형태와 비교해 보았을 때 더 높은 안정성과 신뢰성을 보여준다는 것을 알 수 있었다.

Fig. 9는 AE 파라미터로 뉴럴네트워크를 실행한 데이터인 Table 8과, wavelet coefficient로 뉴럴네트워크를 실행한 데이터인 Table 6에서 구해진 결과를 서로 비교해 보기 위해 그래프로 나타낸 것이다.

본문 내용의 그래프를 보면 알 수 있듯이, 버 형태를 예측하는데 있어 뉴럴네트워크의 결과값은, AE parameter를 입력값으로 하였을 때 보다 실제 측정에서 얻은 버 형태와 비교해 보았을 때 더 높은 안정성과 신뢰성을 보여준다는 것을 알 수 있었다.

## 후 기

이 논문은 2004년도 한국학술진흥재단의 지원에 의해 연구되었음(KRF-2004-041-D00061).

## 6. 결 론

본 연구에서는 Al6061의 밀링 가공 시 발생하는 AE신호를 이용하여 버의 형상을 예측하고 모니터링 하는데 있어 필요한 연구를 수행하였다. 특히 AE데이터로 부터의 효율적인 특징추출(feature extraction) 및 특징 선택(feature selection)을 위하여 웨이브렛 변환과 뉴럴 네트워크를 연계하여 사용하였고 이 결과를 AE 파라미터를 이용한 뉴럴네트워크 결과와 절삭 조건을 이용한 뉴럴 네트워크 결과와 비교해 보았다. 결론은 다음과 같다.

- (1) 8 수준까지 웨이브렛 변환 후, 버 형성에 가장 큰 영향을 미치는 3, 4 level의 mean 값과 standard deviation 값을 특징값 (feature value)으로 정하였다.
- (2) 인공지능신경망을 이용한 버 형태 예측에 있어 절삭조건을 입력값으로 하였을 때 나 AE 파라미터를 이용한 결과값 보다 wavelet coefficient를 입력값으로 이용한 결과값이 실제 측정에서 얻은 burr type과 비교해 보았을 때 더 높은 안정성과 신뢰성을 보여주었다.
- (3) 선행연구<sup>6)</sup>와는 다르게 본 논문은 많은 neural network의 입력 값을 변수로 사용하였고, 그 결과 acoustic emission monitoring을 드릴링과 비교하여 상대적으로 복잡한 밀링 공정에 적용하는 결과를 얻을 수 있었습니다.

## 참 고 문 헌

- (1) Gillespie, K. L., 1979, "Deburring Precision Miniature Parts," *Precision Engineering*, Vol. 1, No. 4, pp. 189~198.
- (2) Serrano, E. P. and Fabio, M. A., 1996, "Application of the Wavelet Transform to Acoustic Emission Signals Processing," *IEEE Transaction on Signal Processing*, Vol. 44, No. 5, pp. 1270~1275.
- (3) Qi, G., Barhorst, A., Hashemi, J. and Kamala G., 1997, "Discrete Wavelet Decomposition of Acoustic Emission Signals from Carbon-Fiver-Rein forced Composites," *Composite Science and Technology*, Vol. 57, pp. 389~403.
- (4) Qi, G. and Barhorst, A., 1997, "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.
- (5) Suzuki, H., Kinjo, T., Hayashi, Y., Takemoto, M. and Ono, K., 1996, "Wavelet Transform of Acoustic Emission Signals," *Journal of Acoustic Emission*, Vol. 14, No. 2, pp. 69~84.
- (6) Lee, S. H., Kim, T. E. and Kwang, Y. R., 2005, "Acoustic Emission Monitoring of Drilling Burr Formation Using Wavelet Transform and an Artificial Neural Network," *Journal of KSPE*, Vol. 22, No. 4, pp. 37~43.