

# 가공 재질에 따른 공구 마열의 특성 추출과 신경회로망을 이용한 마열 검출

## Features Extraction of Tool Wear and its Detection using Neural Network

이호영\*(대우자동차), 조동우(포항공대)

HoYoung Lee\*(Daewoo Motors), DongWoo Cho(Pohang Univ)

### ABSTRACT

Al6061, SB41 and SM45C was used for developing tool wear monitoring system in face milling. First of all, Neural networks of which inputs are 8<sup>th</sup> order AR model parameters, frequency band energies, cutting conditions was used to monitor tool wear for each material. Finally, A unified neural network, which has tensile strengths of each material as an additional input, was constructed to consider the effect three materials on the features of tool wear. It was verified that tensile strength is the one of properties of workpiece materials.

**Key Words :** neural network(신경 회로망), AR model parameter(AR 모델 파라미터), frequency band energy(주파수 밴드 에너지), tensile strength(인장강도)

### 1. 서 론

가공공정 중에서 중요한 역할을 하는 밀링절삭과정은 절삭력이 주기적으로 변동하는 성질, 즉 다점인(multi-point tool)공구가 회전함에 따라 단속절삭을 하게 되고 절삭침의 두께가 절삭되는 동안 변하며, 한 개 이상의 절인이 동시에 절삭에 참여하게 되므로 절삭과정의 해석은 매우 복잡하다. 이와 같은 절삭에서는 공구의 마열, 파단과 같은 특징 추출에 어려움이 많다. 따라서, 절삭력이나 가속도 신호를 모델링하기 위해서 AR/ARMA 등의 시계열 방법이 많이 이용되고 있다..

Ko 와 Cho[1]는 마열의 특징으로서 새 공구와 마열된 공구의 시계열모델의 파라미터를 사용하고 이를 신경회로망으로 학습시켜 온라인으로 공구마열을 예측하는 방법을 제시하였다. Waldorf 등[2]은 run-out 을 고려하여 실험적으로 결정한 정절삭력모델(static force model)을 공구마열과 연관시켜서 특징을 추출하였다. Elbestawi 등[3]은 공구마열에 따른 특정주파수의 절삭력성분의 변동을 이용하는 공구마열검출방법을 제시하였다.

본 논문에서는 Ko 와 Cho[1]가 사용한 시계열모델의 파라미터를 밀링공구 마열의 특징추출의 기본방

법으로 사용하고, 특정한 주파수 대역의 파워합의 크기를 정규화하여 이를 공구마열의 특징으로 포함시켰다. 주파수 대역의 파워합의 크기는 선삭에서의 공구마열의 특징 검출을 위해서 사용되었다[7]. 선삭에서 공구가 마열됨에 따라 band power의 합이 증가함을 보임으로써 이 방법이 마열검출에 사용될 수 있는 가능성을 보였다. Waldorf 등[2]은 밀링에서의 공구마열의 특징추출을 위한 패턴분류기의 입력으로 스픈들 회전주파수의 파워값과 공구통과 주파수의 파워값을 사용하였다. Constantinides[10]등은 스픈들모터 파워의 주파수해석에서 얻은 power spectral energy 의 누적합이 공구마열과 깊은 상관관계가 있음을 보였다. Ko 와 Cho[1]는 공구가 마열됨에 따라 파워가 커짐을 그림과 함께 명시적으로 지적하였다.

위에서 언급한 모든 연구는 특정한 재질을 가공할 때의 마열검출 연구로서 가공물의 재질이 바뀔 때의 특징추출의 차이점은 고려되지 않았다. 가공물의 재질이 달라지면 그에 따라 절삭력의 크기 및 형태가 달라지며 공구마열시에 추출된 특징도 달라지게 되므로 각 재질마다 특징의 차이가 존재하게 된다.

따라서, 본 논문에서는 초경공구로 세가지 재질을 가공할 때의 절삭력에서 얻은 특성으로 공구마열을 예측하고자 한다. 먼저, 절삭력을 적절한 차수의 AR

모델링을 하여 특징으로서 모델의 파라미터를 얻고 각 절삭조건에 대한 파워의 합을 구한다. 그 다음, AR 모델 파라미터와 특정한 주파수 대역의 파워의 합, 절삭조건을 입력으로 하는 신경회로망을 구성하여 각 재질의 공구마멸 상태를 분류해 본다. 그리고 최종적으로 재질의 특성값을 입력으로 추가한 하나의 신경회로망을 구성하여 세가지 재질을 가공할 때의 공구마멸을 on-line으로 검출하고자 한다. 본 연구에서 사용한 공작물의 재질은 일반적으로 많이 사용되는 Al6061, SB41과 SM45C로 하였다.

## 2. 밀링공정의 모델링

본 연구에서는 Ljung[1,5]의 순환최소자승법(Recursive Least Square : RLS)을 적용한 8 차의 AR 모델링을 사용하였다[1,4,5]. 이 순환형태는 데이터를 매번 샘플링할 때마다 모델을 갱신하기 때문에 절삭과정의 점진적 변화를 잘 추종할 수 있다.

실제 밀링작업에서는 커터 및 인서트의 제작시 치수오차, 스픈들의 회전시의 편심에 의한 오차 그리고 인서트 삽입오차 등에 기인하여 커터의 run-out 성분은 엄연히 존재하고 있으므로 이 영향이 절삭력에 그대로 반영되어 나타난다.

인서트의 이러한 run-out 성분에는 축방향성분과 반경방향성분이 있는데 축방향성분은 절삭깊이에 비해 상대적으로 작기 때문에 절삭력에 큰 영향은 주지 못하고 단지 가공물의 표면거칠기에 직접적으로 관계되며 공구수명에는 관계가 없는 것으로 알려져 있다. 반면 반경방향성분은 공구수명에 밀접히 관련된다[6]. 또한 이 반경방향 run-out 성분은 각 인서트의 chip load를 변화시켜 밀링공정의 절삭력모델링에 많이 사용되는 이송방향 절삭력에 영향을 미치게 되므로 중요한 요소이다.

Fu 등[9]은 feed/tooth의 변화에 대한 전체 주파수성분 중의 공구통과 성분 및 스픈들회전 성분의 비율을 그림으로 나타내었다. 날당 이송량(feed/tooth)이 작으면 주파수 성분 중의 스픈들회전 성분의 비율이 커지는데 이는 특정추출에 좋지 않은 영향을 미친다. 날당 이송량이 크면 run-out의 영향은 감소하지만 그러한 조건에서만 가공이 이루어지지는 않으므로 이에 대한 고려가 필요하다. 많은 연구에서는 tool presetter를 사용하여 run-out의 영향을 배제하고 있지만 현실적으로는 존재하고 있으므로 이를 어느정도 보상해 줄 수 있는 현실적인 특정추출방법이 요구된다. 그러므로 절삭력을 취득할 때 식(1)과 같은 컷오프 주파수를 사용하였다.

$$f_L = \text{첫번째 공구통과 주파수} - d$$

$$f_H = \text{샘플링 주파수} / 2 \quad (1)$$

여기서  $f_L$ 과  $f_H$ 는 각각 대역통과필터의 저주파 및 고주파 컷오프주파수이며,  $d$ 는 첫번째 공구통과 주파수 근방의 절삭력 성분을 잘 취득하기 위하여 설정한 값으로서 여기서는 10을 택하였다. 이와 같이 하여 밀링공정의 절삭력모델링의 난제인 커터의 run-out 성분을 많이 제거하여 특정추출을 용이하게 하였다.

일반적으로 밀링가공에서는 절삭력이 주기적이고 공구마멸에 관한 정보는 공구통과주파수의 처음 세 번째까지의 하모닉성분에 주로 존재한다[3]. 따라서, 샘플링주파수의 선정은 세번째 공구통과주파수를 포함하도록 조정하였다. 이 공구통과주파수는 주축회전속도와 인서트갯수에 따라 변하므로 이에 따라 샘플링주파수의 조정이 필요하다. 본 논문에서는 일괄적으로 첫번째 공구통과주파수의 7.3 배를 샘플링주파수로 택하였다.

## 3. 실험

### 3.1 실험장치 및 가공재료

실험은 수직형 머시닝센터(vertical machining center: ACE - V30, 대우중공업)에서 Fig. 1과 같이 수행하였다. 커터(KORLOY Inc., EP 4080 R/L)는 등간격으로 5개의 인서트(KORLOY Inc., SPCN 1203 EDR)를 끼워넣게 되어있다. 소재는 SB41 사각형 시판( $50mm \times 70mm$ )을 사용하였다. 공작물이 장착되어 있는 동력계(Kistler type 9257B)로 이송방향의 절삭력을 AD 변환기를 통해 1024 개씩 읽어들이고 이 절삭력 신호를 오실로스코프로 관찰함과 동시에 데이터기록계(VHS cassette data recorder)에 저장하였다.

공구수명판정의 기준으로 ISO가 추천하는 기준은 평균 여유면 마멸폭( $VB_{av}$ )이 0.3mm이고 최대 여유면 마멸폭( $VB_{max}$ )은 0.6mm이다. 본 연구에서는 평균 여유면 마멸폭이 0.3mm에 이를 때를 공구수명으로 하였다. 밀링공구의 마멸은 축방향 및 반경방향 run-out 때문에 모든 인서트가 동일하게 마멸되지는 않는다. 따라서, 각 인서트의 마멸길이에는 약간씩의 차이가 발생할 수 있으며 이러한 변동은 식 (2)와 같이 평균처리하였다.

$$VB_{av} = \frac{1}{n} \sum_{i=1}^n VB_{av}(i) \quad (2)$$

여기서  $n$ 은 절삭커터의 인서트 수이다. 모든 절삭실험에서 0.3mm로 정의된 공구수명의 완료를 공구현미경으로 검사하고 기록하였다.

실험에 사용한 Al6061-T4는 AI 합금 가운데 중간 정도의 강도를 가진 구조용 합금이다. SB41은 일반

구조용 암연강재(rolled steel for general structure)이며, SM45C는 기계구조용단소강(carbon steels for machine structural use)으로서 현재 널리 사용되고 있다. Table 1에 사용 재료의 기계적 성질을 나타내었다.

### 3.2 Frequency band energy 와 마멸특성 추출

주파수 영역에서의 평균 밴드 에너지는 다음과 같이 표현할 수 있다[7].

$$E_{x_{BPF}} = \int_{f_L}^{f_H} G_x(f) df \quad (3)$$

여기서  $G_x(f)$ 는 신호  $x(t)$ 의 파워스펙트럼 밀도 함수이며,  $f_L$ 과  $f_H$ 는 각각 대역통과필터의 저주파 및 고주파의 컷오프주파수이다. 이 값을 구하기 위하여 신호를 주파수 영역에서 계산할 필요는 없다. 대역통과필터의 출력신호를  $x(t)_{BPF}$ 라고 하면

$$E_{x_{BPF}} = \lim_{T \rightarrow 0} \frac{1}{T} \int_t^{t+T} x^2(\tau)_{BPF} d\tau \quad (4)$$

컴퓨터로 샘플링을 할 때는 이산 시계열 신호  $\{x_n\}_{BPF}\}$ 를 얻어서 처리하게 되므로 평균 밴드 에너지는 다음과 같이 나타낼 수 있다.

$$E_{x_{BPF}} = \frac{1}{N} \sum_{n=1}^N x_n^2_{BPF} \quad (5)$$

본 연구에서는 공구의 run-out 성분에 크게 영향을 받는 스펀들 회전성분을 특징추출에서 제거하였으므로 절삭력을 AR 모델링하기 위하여 취득한 데이터를 직접 사용할 수 있다.

Table 2는 실험 절삭조건을 나타낸다. AR 모델의 차수는 계산시간과 자승오차합을 고려하여 8 차로 택하였다[1]. Fig. 2는 새 공구와 마멸된 공구에서의 AR 모델 파라미터값을 나타낸다. 마멸된 공구의 AR 모델 파라미터값은 새 공구와는 다른 값을 가지며, 또한 같은 절삭조건에서도 재질에 따라서 파라미터 값에는 차이가 나타남을 알 수 있다. 공구마멸과 AR 모델 파라미터의 관계는 이미 Ko 와 Cho[1]의 연구에서 잘 나타나있다. Fig. 3은 여러 절삭조건에서 세 재질의 새 공구와 마멸된 공구의 주파수밴드에너지를 나타낸다. 같은 재질에서는 마멸된 공구의 주파수밴드에너지가 크고, 같은 공구상태에서는 Al6061, SB41, SM45C 쪽으로 갈수록 에너지값이 커짐을 알 수 있다.

## 4. 신경회로망에 의한 공구마멸감시

### 4.1 신경회로망의 적용

오차역전파 학습법을 이용한 신경회로망[8]이 공구 상태를 구분하기 위해 사용된다. 신경회로망의 입력데이터로서 AR 모델파라미터와 주파수밴드에너지를

사용한다. 절삭조건은 시그모이드함수의 조기포화현상으로 인한 학습의 어려움을 방지하기 위하여 사용 가능한 최대값으로 나누어서 정규화하여 사용한다.

학습데이터로 사용되는 패턴은 주의깊게 선택되어야 한다. 새 공구와 마멸된 공구의 패턴이 비슷하거나 실제와 다른 공구상태를 나타내는 패턴은 학습능력을 저하시키기 때문에 학습데이터로 채택하지 않아야 한다. Table 2의 실험조건에서 Al6061에 대해서는 36 개, SB41에 대해서는 40 개, SM45C에 대해서는 38 개를 학습데이터로 선정하였다.

주파수밴드에너지도 신경회로망의 입력으로 사용하기 위해서는 -1과 1 사이의 값으로 정규화하여야 한다. 이를 위하여 우선 주파수밴드에너지를 절삭조건의 함수로 놓는다.

$$\text{band energy} = A(rpm)^B (\text{feedrate})^C (\text{depth of cut})^D \quad (6)$$

주파수밴드에너지는 밴드패스필터링한 절삭력신호를 이용하는 것이므로 절삭력과 밀접한 관계를 가지고 있다. 절삭력에 영향을 미치는 요소로는 공구와 공작물의 기하학적 형상(axial rake angle, radial rake angle, insert number, entry angle, exit angle etc), 공작물과 공구의 재질에 의한 영향(공작물의 hardness or tensile strength, 공구와 공작물 사이의 마찰계수), 그리고, 절삭조건(주축 회전수, 이송속도, 절삭깊이)등이 있다. 같은 공구로 특정한 재질을 가공할 경우, 바뀌는 것이 절삭조건과 공구의 마멸상태 밖에 없으므로 절삭력으로부터 계산된 주파수밴드에너지는 주어진 마멸상태에서 절삭조건의 함수로 나타낼 수 있다. 식(6)에서 A, B, C, D는 AR 모델파라미터를 구한 절삭데이터를 재사용하여 새 공구와 마멸된 공구에 대하여 각각 구한다. 이 때에는 구하려는 미지수의 개수보다 절삭조건이 많으므로 least square solution을 구하게 된다. 이렇게 하여 구한 Al6061, SB41, SM45C에 대한 A, B, C, D 값은 식 (7)과 같다.

$$\begin{aligned} \text{Al6061bandenergy}_{new} &= 21430(\text{rpm})^{-1.421} (\text{feedrate})^{1.072} (\text{depth of cut})^{1.779} \\ \text{Al6061bandenergy}_{worn} &= 10610(\text{rpm})^{-1.372} (\text{feedrate})^{1.459} (\text{depth of cut})^{1.343} \\ \text{SB41bandenergy}_{new} &= 5985(\text{rpm})^{-1.639} (\text{feedrate})^{0.896} (\text{depth of cut})^{1.784} \\ \text{SB41bandenergy}_{worn} &= 9263(\text{rpm})^{-1.352} (\text{feedrate})^{0.908} (\text{depth of cut})^{1.348} \\ \text{SM45Cbandenergy}_{new} &= 35225(\text{rpm})^{-1.186} (\text{feedrate})^{0.945} (\text{depth of cut})^{1.723} \\ \text{SM45Cbandenergy}_{worn} &= 14650(\text{rpm})^{-2.022} (\text{feedrate})^{0.573} (\text{depth of cut})^{0.979} \end{aligned} \quad (7)$$

신경망의 학습데이터로 사용하기 위해서는 식(7)로 계산된 밴드에너지를 정규화하는 절차가 남았다. 학습패턴의 각 절삭조건에서 새 공구의 주파수밴드에너지의 정규화값은 모두 -0.5로 한다. 마멸된 공구의 밴드에너지는 식(8)에 의해 정규화된다.

$$E_{\text{worn tool, Normalized}} = -0.5 + \frac{E_{\text{worn tool}} - E_{\text{new tool}}}{E_{\text{worn tool}}} \quad (8)$$

여기서  $E_{\text{new tool}}$ ,  $E_{\text{worn tool}}$ 은 각각 새 공구 및 마멸된 공구의 주파수 밴드에너지값이며,  $E_{\text{worn tool, Normalized}}$ 은 마멸된 공구의 정규화된 주파수 밴드에너지값이다.

주파수 밴드에너지를 특정한 값으로 정규화하면 새 공구와 마멸된 공구 사이의 밴드에너지의 차이가 크지 않은 학습테이터의 경우에는 밴드에너지값의 민감도가 커지게 된다. 따라서, 식(8)과 같이 정규화하여 새 공구와 마멸된 공구의 밴드에너지의 차이에 따라 마멸된 공구의 학습패턴의 값은 적절히 바뀌게 된다. 이와같이 주파수 밴드에너지를 fitting하고 난 후에 이 값을 정규화하여 신경회로망의 학습테이터로 사용하는 이유는 학습시키지 않은 다른 절삭조건에 대한 밴드에너지값이 신경망의 테스트테이터로 입력되는 경우를 고려하기 위함이다.

학습이 끝난 신경회로망에 어떤 절삭조건에서의 절삭력 데이터의 밴드에너지값이 입력되면 그 절삭조건에서 식(7)에 의해 새 공구와 마멸된 공구의 밴드에너지값을 각각 계산한다. 새 공구에 대한 정규화값을 -0.5로 하고 마멸된 공구의 정규화값을 식(8)에 의해 계산된 값으로 한다면 입력으로 들어온 밴드에너지값을 얼마로 할 것인가가 결정된다.

#### 4.2 각 재질에 대한 공구마멸의 감시결과

AR 모델파라미터, 주파수 밴드에너지, 그리고 절삭조건을 입력으로 하여 세 재질에 대해 각각 신경회로망을 구성하여 공구마멸 검출을 시도하였다. 신경회로망의 입력층의 노드갯수는 입력특징의 수와 같고 그 특징으로서는 AR 모델파라미터 8개, 절삭조건 3개, 그리고 주파수 밴드에너지 1개를 사용하였다. 출력층의 노드갯수는 1개로 하였는데, 새 공구에 대해서는 0.1, 마멸된 공구에 대해서는 0.9로 설정하였다. Table 3에 그 인식률을 나타내었다. 세 재질에 대하여 모두 90%가 훨씬 넘는 공구상태 인식률을 얻었음을 알 수 있다.

#### 4.3 재질을 고려한 하나의 신경회로망의 구성

공구수명에 관한 기존의 연구들을 보면 경도(hardness)가 수명에 영향을 미치는 한 요소로서 포함되어 있다. 경도와 인장강도(tensile strength)는 서로 연관관계가 있으므로 재질의 특성으로서 인장강도를 사용하여도 무방하다[11]. 따라서, 본 연구에서는 재질의 특성으로서 인장강도를 택하였다. 그리고, 여러 재질을 가공할 때의 공구상태를 하나의 신경회로망

으로 인식하려는 시도로서 인장강도를 신경회로망의 입력으로 추가한다.

Al6061, SB41과 SM45C를 가공할 때의 공구상태를 학습시키는데 사용한 그 절삭데이터를 사용하여 식(9)를 얻고 이를 정규화하여 신경회로망의 학습패턴으로 사용한다.

$$\begin{aligned} \text{hardeng}_{\text{initial}} &= 0.067(\mu m)^{-1406} (\text{feedrate})^{0.9774} (\text{depthofcut})^{1.756} (\text{tensilestrength})^{1.98} \\ \text{hardeng}_{\text{final}} &= 4.568(\mu m)^{-1.88} (\text{feedrate})^{0.7768} (\text{depthofcut})^{1.278} (\text{tensilestrength})^{1.224} \end{aligned} \quad (9)$$

인장강도는 SM45C의 값이 가장 크므로 이 값으로 나누어 정규화하였다. 따라서 신경회로망의 입력은 AR 모델파라미터 8개, 정규화된 주파수 밴드에너지 1개, 정규화된 인장강도 1개, 그리고 절삭조건 3개로서 총 13개가 된다. Fig. 5는 13-20-1 구조에서 세 재질을 가공할 때의 공구상태의 인식결과를 나타낸 것이며 Fig. 4는 이 인식률을 그림으로 나타낸 것이다. 세 재질 각각에 대하여 신경회로망을 구성했을 때에 비하여 공구상태 인식결과의 데이터가 훨씬 많지만 최소 83.3%, 최대 100%의 인식결과를 얻었다.

## 5. 결 론

본 연구에서는 초경공구로 Al6061, SB41과 SM45C를 가공할 때의 절삭력 신호로부터 얻은 AR 모델파라미터와 주파수 밴드에너지를 공구마멸의 특징으로 삼아 신경회로망을 학습시켜 공구의 상태를 분류하였다. 또한 재질의 인장강도를 고려하여 하나의 통합된 신경회로망으로 공구의 마멸의 검출을 시도하였다. 다음은 실험을 통해 얻은 결론이다.

1. 가공물의 재질이 다르면 공구마멸을 판단하는 신경망의 구조 및 weight 값이 달라지는 것을 확인하였다. 즉, 하나의 신경망으로서 다양한 재질의 가공물에 대한 판별을 수행하기가 어려우므로 재질의 특성도 신경망의 입력특징으로 하여 학습시켜, 재질의 변화까지도 수용할 수 있는 하나의 공구마멸검출 신경망을 구성하였다. 이 신경망은 AR 모델파라미터, 주파수 밴드에너지, 인장강도와 절삭조건을 입력으로 하며 13-20-1의 구조를 가지며 최소 83.3%, 최대 100%의 인식률을 얻었다.

2. 여러재질을 가공할 때에는 인장강도가 각 재질에 따른 절삭력의 특징의 차이를 구별짓는 요소가 된다. 이 때의 공구상태는 하나의 신경회로망으로도 인식할 수 있으므로 본 논문에서 사용된 특징추출방법과 신경회로망은 실제 가공시에도 유용하게 사용될 수 있다.

## 참 고 문 헌

1. T. J. Ko, D. W. Cho, "Cutting state monitoring in milling by a neural network," *Int. J. Mach. Tools Manufact.*, Vol. 34, No. 5, 1994, pp. 659-676.
2. D. J. Waldorf, S. G. Kapoor, R. E. DeVor, "Automatic recognition of tool wear on a face mill using a mechanistic modeling approach, *Wear*," Vol. 157, 1992, pp. 305-323.
3. M. A. Elbestawi, T. A. Papazafiriou, R. X. Du, "In-process monitoring of tool wear in milling using cutting force signature," *Int. J. Mach. Tools Manufact.*, Vol. 31, No. 1, 1991, pp. 55-73.
4. S. M. Pandit, S. M. Wu, *Time Series and System Analysis with Applications*, 1983, pp. 13-45. John Wiley & Sons, Inc.
5. L. Ljung, T. Soderstrom, *Theory and Practice of Recursive Identification*, 1987, pp. 57-59, Cambridge, MIT Press.
6. A. Bar, D. Feldman, "The influence of radial location on the wear behavior of multi-tooth face milling cutter," *Annals of the CIRP*, Vol. 25, No. 1, 1977, pp.1-4.
7. C. Y. Jiang, Y. Z. Zhang, H. J. Xu, "In-process monitoring of tool wear stage by the frequency band-energy method," *Annals of the CIRP*, Vol. 36, No. 1, 1987, pp. 45-48.
8. Y. H. Pao, *Adaptive pattern recognition and neural networks*, Addison-Wesley Publishing Company, Inc., pp.113, 1989.
9. H. J. Fu, R. E. DeVor, S. G. Kapoor, "A mechanistic model for the prediction of the force system in face milling operations," *ASME J. Engng. Ind.*, Vol. 106, 1984, pp. 81-88.
10. N. Constantinides and S. Bennett, "An investigation of methods for the on-line estimation of tool wear," *Int. J. Mach. Tools Manufact.*, Vol. 27, No. 2, 1987, pp. 225 - 237.
11. C. Rubenstein, "An analysis of tool life based on flank-face wear," *ASME J. Engng. Ind.*, Vol. 98, 1976, pp. 227-232.

Table 1 Mechanical properties of workpieces

Material	Tensile yield strength (MPa)	Tensile strength (MPa)	Elongation (%)
Al6061-T4	110 이상	175 이상	16 이상
SB41	216 이상	402-510	23 이상
SM45C	343 이상	569 이상	20 이상

Table 2 Cutting conditions for tool wear experiments

Cutting speed (rpm)	Feed rate (mm/min)	Depth of Cut (mm)
240	80, 120	0.5, 1.0
360	40, 80, 120, 160	0.5, 1.0
450	80, 120, 160	0.5, 1.0
540	40, 80, 120, 160	0.5, 1.0
630	80, 120, 160	0.5, 1.0
720	40, 80, 120, 160	0.5, 1.0

Table 3 Performances of the tool wear detection  
(In case that features of tool wear are AR model parameters, frequency band power and cutting condition)

	Structure of hidden layer	New tool	Worn tool
Al6061	14-12	98.3%	100%
SB41	14-8	98.4%	97.2%
SM45C	14-8	94.9%	95.3%

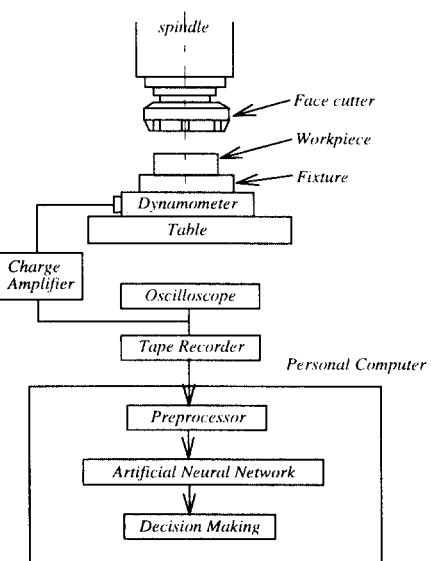
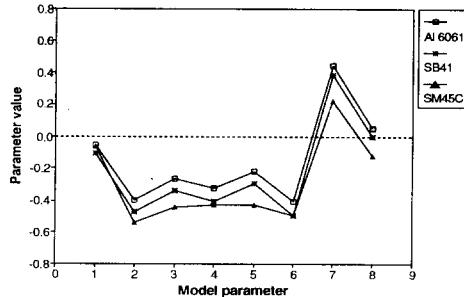
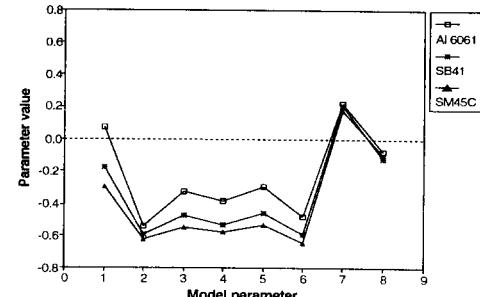


Fig. 1 Schematic diagram of the experimental setup



(a) AR parameters for new tools



(b) AR parameters for worn tools

Fig. 2 Variation of AR parameters for three materials

(Cutting speed : 720rpm, Feed rate : 120mm/min, Depth of cut : 1.0mm)

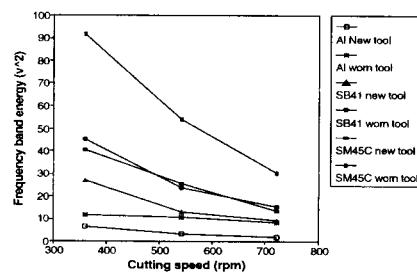


Fig. 3 Frequency band energy under different materials and cutting conditions  
(feedrate : 120mm/min, depth of cut : 1.0mm)

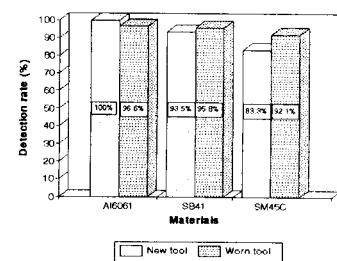
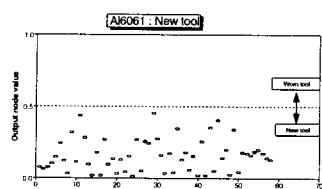
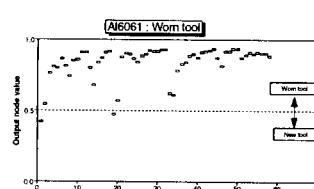


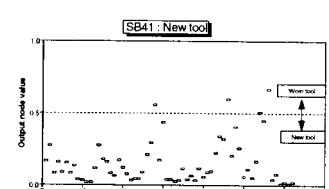
Fig. 4 Tool state detection rate of a unified neural network



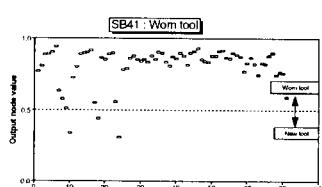
(a)



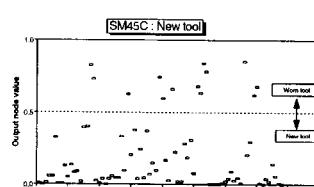
(b)



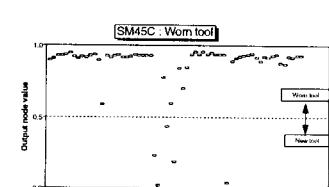
(c)



(d)



(e)



(f)

Fig. 5 Results of tool state classification using a unified neural network