

## 고경도강 선삭시 절삭특성 및 공구 이상상태 검출에 관한 연구

이상진\*, 신형곤, 김민호, 김종택, 이한교(전북대 대학원), 김태영(전북대 기계공학부,  
자동차신기술 연구소),

### A Study on the Cutting Characteristics and Detection of the Abnormal Tool State in Hard Turning

S.J. Lee\*, H.G. Shin, M.H. Kim, J.T. Kim, H.K. Lee(Graduate School, Chonbuk Nat'l Univ.),  
T.Y. Kim(Chonbuk Nat'l Univ.),

#### ABSTRACT

The cutting characteristics of hardened steel by a PCBN tool is investigated with respect to workpiece surface roughness, cutting force and tool flank wear of the vision system. Backpropagation neural networks (BPNs) were used for detection of tool wear. The neural network consisted of three layers: input, hidden and output. The input vectors comprised of spindle rotational speed, feed rates, vision flank wear, and thrust force signals. The output was the tool wear state which was either usable or failure. Hard turning experiments with various spindle rotational speed and feed rates were carried out. The learning process was performed effectively by utilizing backpropagation. The detection of the abnormal states using BPNs achieved 96.4% reliability even when the spindle rotational speed and feedrate were changed.

**Key Words :** tool wear(공구마모), hard turning(고경도강 선삭), Backpropagation neural networks(오류역전파 신경회로망), PCBN tool(CBN 입방격자 소결공구)

#### 1. 서론

절삭재료 뿐만 아니라 가공공구의 생산기술이 발달함에 따라 절삭가공 기술이 확립되고, 절삭이 어려운 난삭재를 불리우는 신소재들도 속속 생산되고 있다. 자동차 및 기계 산업에서 베어링은 응력을 많이 받는 부품들 중 하나이며, 강도와 내마모성을 향상시키기 위해 고경도강을 주로 이용하고 있다. 고경도강의 정의는 다소 차이가 있으나 HRC45 이상으로 정의되고 있다. 고경도강의 선삭은 hard turning이라 불리우며, hard turning의 대표적인 재료들은 열처리 또는 표면경화를 통해 얻어진다. 이러한 강은 다른 재료에 비해 향상된 강도와 공구마모의 영향 때문에 기계재료의 관점에서 중요한 역할을 하고 있다. 가공능률의 향상과 표면정밀도 때문에 이들 재료들은 마무리 공정에 연삭 같은 연마과정이 실행된다. 그러나 최근의 산업기술의 진보는 가공공구

기술의 개선과 CBN 절삭공구의 출현을 가져오게 되었고, 이는 고경도강을 선삭 또는 밀링으로 가공이 가능하게 하였다. 이는 연삭과정에서의 이득이 최신의 선반에서 hard turning으로 얻을 수 있음을 의미한다. hard turning의 이익은 유연성의 증가, 가공시간의 감소, 가공공구 비용에 감소, 친환경적 절삭 등 많은 이익이 존재한다. 이러한 이익들에도 불구하고 hard turning의 시도는 상대적으로 낮은 범위에 있다. 주로 가공후의 표면의 품질에 관한 내용과 CBN 공구의 마모 움직임에 관한 이해의 부족이 원인으로 지적되고 있다.

CBN 공구는 고가이기 때문에 과도한 공구마모는 hard turning의 경제적 이익을 감소시킨다. 이 목적을 달성하기 위해 논문에서는 AISI52100 강(HRC62)을 코팅된 초경과 코팅되지 않은 CBN 공구로 hard turning했을 때 마모의 변화에 대한 영향을 연구하

였다.

한편, 공구파손으로 인한 제품 손상 및 정지시간의 증가는 경제적으로 큰 손실을 초래한다. 특히 가공 중에 드릴 파손이 발생하게 되면 가공물을 버리거나 후처리하는데 시간적, 경제적으로 비용이 많이 들게 된다. 따라서 공구 마모상태에 대한 제반관리가 이루어져야 하며, 공구의 과도한 마모 및 파손을 감지 또는 예측할 수 있는 시스템 개발이 시급한 과제로 남아 있다. 그래서 많은 연구들이 행해졌는데, 최근에는 신경회로망을 이용한 연구가 진행되고 있다. 신경회로망은 예측 작업과 분류, 검색할 수 있는 컴퓨터 시스템들의 병렬적인 연결이다. 이것은 높은 정밀도가 있고, 비선형 함수를 위한 모델링 뿐만 아니라, 소음에 의해 누락되어지는 데이터의 특성을 인식할 수 있다. 이런 확고성 때문에 신경망은 최근에 연구가들에게 많은 연구 과제로 떠오르고 있으며 기계 처리 과정을 자동적으로 모니터링하고 센서로 얻어진 불완전한 데이터를 다루기 위해 사용된다. Govekar와 Grabec<sup>(1)</sup>는 자기 조직 신경회로망을 모우멘트와 절삭력 신호들로부터 플랭크 마모를 분석하는데 적용하였다.

본 연구에서는 많은 장점을 가진 신경망을 이용하기 위해, 공구동력계와 컴퓨터 영상처리를 통해서 추출된 패턴을 종합 분석하여 공구 이상상태를 최종 결정하기 위한 신경회로망의 입력패턴으로 제시하였다.

## 2. 실험장치 및 방법

### 2.1 시험편 및 사용공구

본 실험에 사용한 재료로 고경도강인 AISI52100은 베어링 산업에 널리 사용되는 강의 하나이다. 직경  $d=45\text{mm}$ 이고, 절삭을 용이하게 하기위해 길이는  $l=230\text{mm}$ 로 절단하였다. 재료의 화학적 성분은 Table 1에 나타내었다. 시험편은 860의 열처리를 통해 표면의 경도가 대략 HRC 62 정도를 유지하도록 하였다.

본 실험에서 사용된 공구인 PCBN 공구는 다이아몬드와 매우 비슷한 구조를 가지고 있으며, 1400 - 1500의 고온과 5-7GPa의 고압으로 소결하여 합성된다. PCBN은 소결된 CBN에 Co, TiC, TiN과 다른 재료를 혼합하여 만들어진다. 일반적으로 CBN 공구는 TiC 또는 TiN을 첨가하여 만든 high CBN 공구와 Co를 첨가하여 만든 low CBN 공구로 나누어진다. 이들 공구의 능력을 평가하기 위해 코팅된 초경합금과의 비교 실험도 수행하였다. Table 2는 공구재료에 따른 절삭조건 즉, 각 공구에 대한 3가지 절삭속도와 이송량, 절입깊이, 공구재질에 대해 보여준다.

Table 1 Chemical compositions of workpiece(Vol.%)

Material	C	Cr	Fe	Mn	Si	P	S
specimen	0.98~1.1	1.4	97.05	0.35	0.25	<0.25	<0.25

Table 2. Conditions for tool evaluation study

condition	Speed	Feed	Depth	Tool Material
1	130	0.157	0.4	TaeguTec
2		0.079	0.4	KB90 - high CBN
3		0.157	0.4	
21	130	0.157	0.4	TaeguTec
22		0.079	0.4	TB650 -
23		0.157	0.4	low CBN
31	130	0.157	0.4	TaeguTec
32		0.079	0.4	TT1500 - coated Carbide
33		0.157	0.4	

## 2.2 실험방법

본 실험에 사용한 공작기계는 NC 선반(화천기계 HL-460)이다. 절삭력은 선반에 설치된 공구동력계(Kistler 9257B)를 이용하고, 공구동력계로부터 미소전류를 증폭하기 위하여 charge amplifier(Kistler, 5017A)를 사용하였다. Amplifier에서 증폭된 아날로그 신호는 A/D converter를 통해 얻어진 정량화 된 데이터의 결과로 변환하여, computer에 저장 분석하였다. 공구마모는 공구현미경에 비전시스템을 설치하여 측정하였다. 마모관찰에 사용한 장비는 CCD 카메라, 화상입력보드(Data Translation, DT3155), 컴퓨터로 구성하였다. 획득된 절삭력 데이터는 데이터분석 프로그램에 의해 X, Y, Z축에 평균값을 신호 획득 시간으로 환산하여 컴퓨터에 저장하였다. 마모의 영상은 CCD 카메라를 통해 프레임 그레이버(frame grabber)에 의해 256 밝기 등급으로 컴퓨터에 저장되며 이 영상을 컴퓨터에서 분석하였다. 플랭크 마모의 영상을 획득하고, 마모 길이를 계산한 후, 절삭회전수, 이송량, 절삭력, 공구마모의 인자를 인공신경망 프로그램에 대입하여 공구의 마모를 판정하였다.

## 3. 실험결과 및 고찰

### 3.1 공구의 재료에 따른 절삭력과 마모

Fig. 1은 절삭속도  $v=130\text{m/min}$ , 이송속도  $f=0.157\text{mm/rev}$ , 절입깊이  $d=0.4\text{mm}$ 로 가공하였을 때 가공시간에 따른 절삭력에 대한 그래프이다. 그럼으

로부터 시간의 증가에 따라 절삭력이 증가하는 경향을 알 수가 있다. 절삭력 중 배분력이 가장 큰 변화를 보여주며, 가공시간 36분 정도에서 가공불능의 상태가 일어남을 알 수가 있다. 주분력과 이송분력은 서서히 증가함을 알 수 있다. 이는 절삭력 중에서 고경도강 가공시 배분력이 더 많은 영향을 줌을 알수 있는데 이는 많은 연구가들에 의해 발표된 결과와 유사한 결과를 보여준다.<sup>(2)</sup>

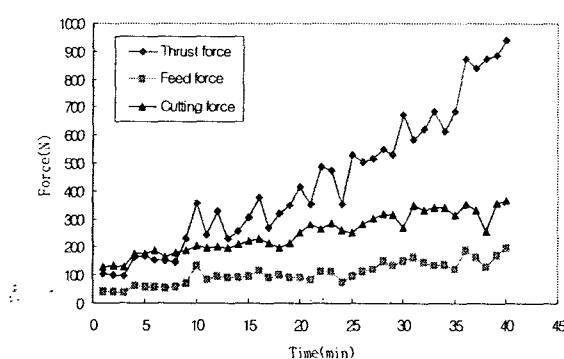


Fig. 1 Typical force progression over the life of a single cutting tool ( $v=130\text{m/min}$ ,  $f=0.157\text{mm/rev}$ )

Fig. 2는 재료에 대한 3가지 힘의 요소에 대한 초기값을 보여준다. 절삭력의 초기값은 공구의 수명에 대한 힘의 거동을 뚜렷하게 묘사하기가 쉽지 않다. 그러나 절삭력은 재료에 대한 정보를 보다 쉽게 표시할 수 있도록 도와준다. 초경의 경우는 큰 값이 나타나는 이유는 3분 안에 파괴가 되었기 때문이다.

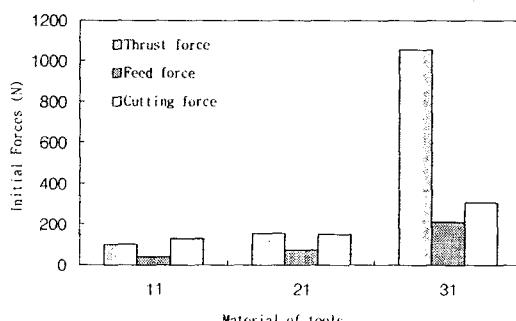


Fig. 2 Initial cutting forces for condition group x 1

Fig. 3(a)는 절삭속도  $V=130\text{m/min}$ , 이송속도  $f=0.157\text{mm/rev}$ 의 조건으로 가공하였을 때, 3분이 지난 공구마모 영상을 보여준다. 전반적으로 화소값들이 불균일하게 분포되어 있어있다. 이 영상을 고대

비에서 저대비로 변환하기 위하여 인터레이싱 작업을 하고, 고주파 잡음을 감소시키기 위해서 미디안 필터링을 하였다. 2진 영상을 구성하는데는 쓰레스홀딩 값이 필요하게 되는데 각 절삭 조건에 따라 가공한 가공면의 영상에는 각기 다른 정보를 갖고 있으므로 이와 같은 조건에 따른 쓰레스홀딩 값을 150으로 하여 적용하였다. Fig. 3(b)는 쓰레스홀딩한 2진 영상을 나타내고 있다.

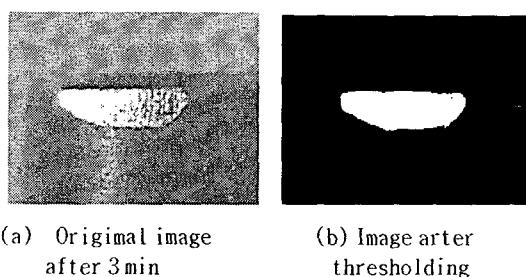


Fig. 3 Image processing procedure

본 논문에서는 필터링작업을 행한 2진 영상으로부터 공구 플랭크 마모 길이를 계산하였다. Fig. 5는 절삭속도  $v=130\text{m/min}$ , 이송속도  $f=0.157\text{mm/rev}$ , 절입깊이  $d=0.4\text{mm}$  조건으로 재료변화에 따른 플랭크 마모길이를 나타내었다. 그림에서 나타난 것처럼, 가공시간의 증가에 따라 플랭크 마모길이가 증가함을 알 수 있으며, low CBN 공구가 high CBN 공구보다 고경도강 절삭에 적합하다는 것을 알 수 있다.

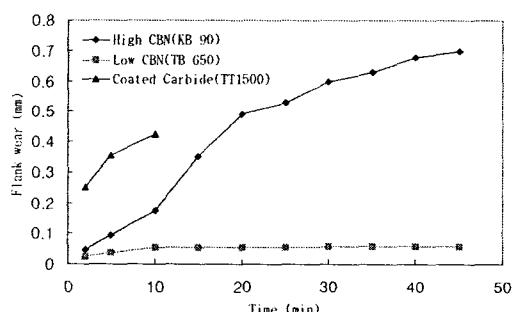


Fig. 4 Vision wear area after filtering by computer image system ( $v=130\text{m/min}$ ,  $f=0.157\text{mm/rev}$ )

### 3.2. 신경회로망에 의한 데이터 분석

선삭에서의 절삭력은 절삭조건에 따라 심하게 변화하므로, 직접 신경회로망에 입력하기가 매우 까다롭다. 따라서 모든 절삭력과 마모길이 등 모든 데이터는 전처리 방식을 거쳐서 신경회로망에 입력된다. 본 연구에서는 가공후의 평균 절삭력을 구한 후 각각 1회 가공시의 데이터를 나누는 방법을 선택하였다. 전처리 방식을 거친 데이터는 신경회로망의 입

력에 알맞은 값의 범위로 변환되며 절삭력 상수로 적절하게 일반화되었다.

절삭력 중 가장 큰 영향을 미치는 thrust force와 spindle rotational speed, feed, 컴퓨터 영상처리 시스템을 이용하여 구한 마모 길이, 표면조도를 입력으로 하는 오류 역전파(backpropagation) 신경회로망을 사용하였다. 다중인자의 구조는 입력 5, 은닉 층 2이고 노드는 7과 3, 출력은 1인 5-7-3-1 구조를 사용하였다. 노드수는 20번의 실험을 거쳐 가장 최적의 노드수를 택하였다. 출력층은 0에 가까운 값을 가지면 정상상태를, 1에 가까운 값을 가지면 공구의 플랭크 마모 VB=0.3에 이르는 마모나 파손 등이 일어났음을 나타낸다. 학습률은 0.8 모멘텀은 0.6으로 하였으며 반복 학습은 10,000회로 제한하였다. 전체 최대오차가 0.0005보다 작게 학습하였다.

학습과정이 진행됨에 따라 학습 오차가 수렴되어가는 과정을 Fig. 5에 나타내었다. 신경회로망의 반복 학습을 30번까지 수행하였을 때 학습 오차의 변화량이 급격히 줄어들다가 반복 횟수가 증가함에 따라 점진적으로 감소하여 수렴해 가는 것을 알 수 있다. 본 연구에서 구현한 신경회로망은 370번까지 반복 학습시킴에 따라 오차가 0.0005까지 줄어듬을 알 수 있었고, 학습 패턴을 입력으로 제시하여 출력 패턴을 조사한 결과 학습이 성공적임을 알 수 있었다.

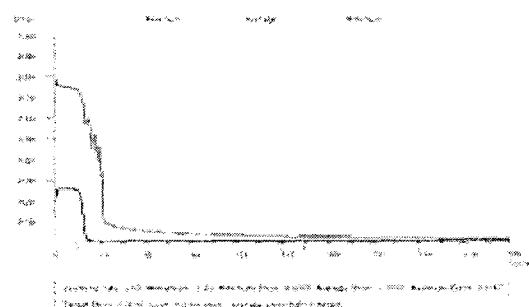


Fig. 5 Convergence of learning error versus number of iterations in the training process

Fig. 6은 오류 역전파 신경회로망을 이용한 결과를 나타내고 있다. 그래프에서 보는 것처럼 정상상태일 때는 약간 증가하면서, 공구가 갑자기 파괴되는 부근에서 1 근처로 뛰어 오르는 값을 가지며 명확한 공구마모암을 알려주었다. 이것은 학습 과정을 거친 신경회로망이 정확한 신호 패턴 분류를 할 수 있음을 알려준다.

이상의 결과에서 보는 바와 같이 신경회로망은 공구의 상태를 감시하는데 있어서 매우 유용하게 쓰일 수 있다.

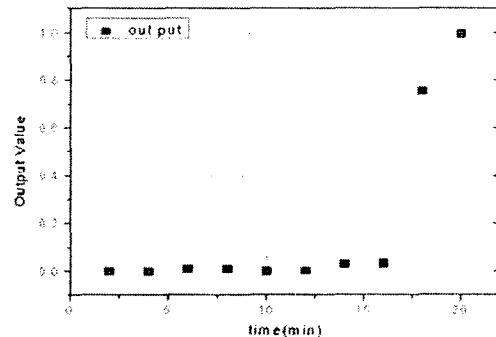


Fig. 6 Output data of neural network vs cutting time

#### 4. 결 론

본 연구에서는 AISI52100 고경도강의 선삭시 가공특성 및 신경회로망을 이용하여 공구마모를 검출하는 시스템을 구축하였다. 이번 연구를 통하여 다음과 같은 결론을 얻을 수 있었다.

1. 절삭력과 공구마모등을 통해 high CBN 공구보다 low CBN 공구가 고경도강 절삭에는 보다 효과적인 공구임을 확인하였다.
2. 오류 역전파 신경회로망을 이용한 결과가 1에 가까운 값들을 출력함으로써 간접적으로 공구 상태를 감시하기에 충분하였다.
3. 공구동력계에 의한 신호와 컴퓨터 영상처리 시스템을 통해 구한 공구 마모를 입력으로 하는 오류 역전파 신경 회로망은 생산 현장에서 자동화, 무인화에 실제적인 적용 가능성이 있음을 보여준다.

#### 참고문헌

1. Govekar E. and Grabec, I., "Self-Organizing Neural Network Application to Drill Wear Classification," ASME Journal of Engineering For Industry, Vol. 116, May 1994, pp. 233-238.
2. Ty G. Dawson, and Thomas R. Kurfess, "Quantification of tool wear using white light interferometry and three-dimensional computational metrology". International Journal of Machine Tools & Manufacture, pp. 1-6, (2004)
3. Sandeep S. Jaiswal "Prediction of Tool wear using Neural Networks", The University of Alabama in Huntsville, 1999.
4. J. Mou, "A Method of Using Neural networks and Inverse Kinematics for machine Tools Error Estimation and Correction", ASME Journal of manufacturing Science and Engineering . Vol.119, pp.247-254, 1997.