

절삭조건과 절삭력 파라메타를 이용한 공구상태 진단에 관한 연구(II) - 의사결정 -

정진용*, 서남섭**

A Study on the Diagnosis of Cutting Tool States Using Cutting Conditions and Cutting Force Parameters(II) - Decision Making -

Chin-Yong Cheong*, Nam-Sup Suh**

ABSTRACT

In this study, statistical and neural network methods were used to recognize the cutting tool states. This system employed the tool dynamometer and cutting force signals which are processed from the tool dynamometer sensor using linear discriminant function. To learn the necessary input/output mapping for turning operation diagnosis, the weights and thresholds of the neural network were adjusted according to the error back propagation method during off-line training. The cutting conditions, cutting force ratios and statistical values(standard deviation, coefficient of variation) obtained from the cutting force signals were used as the inputs to the neural network.

Through the suggested neural network a cutting tool states may be successfully diagnosed.

Key Words : error back propagation(오차역전파), neural network(신경회로망), cutting condition(절삭조건), cutting force parameter(절삭력 파라메타)

1. 서론

최근의 절삭가공 형태는 자동화와 무인화, 가공품의 고정밀도를 요구하는 형태로 되고 있으며 이러한 요구조건

을 만족시키기 위한 부단한 노력이 행해지고 있다. 그리고 가공 중 공구상태의 진단은 정상적인 가공상태의 유지와 가공품의 정밀도 유지 측면에서 매우 중요하게 되었다. 기계가공 프로세스의 상태를 감시하기 위한 지적센싱

* 군장공업전문대학 기계설계과
** 전북대학교 기계공학과

시스템의 개발은 생산가공시스템의 자동화, 무인화를 실현하는데 중요한 핵심기술의 하나로 되고 있으며 지적센싱시스템을 구축하는데 필요한 센서용융기술, 신호처리 및 특징추출, 의사결정방법 등에 대한 연구가 활발히 진행되고 있다. 그럼에도 불구하고 가공 중 공구상태를 진단할 수 있는 정보는 한정되어 있고 범용성, 신뢰성면에서 아주 만족할 수 있는 상태는 아니다. 따라서 본 연구에서는 절삭가공 중 특성이 다른 여러가지의 정보, 절삭조건과 절삭력파라메타를 이용하여 보다 정확하고 신뢰성 있게 공구상태를 진단하고자 하였다. 공구상태를 신속하고 신뢰성 있게 진단하기 위한 방법으로 절삭조건과 절삭력파라메타를 신호처리 및 특징추출^{(1),(2),(3)}을 통한 통계적인 기법(Fisher의 선형식별함수)을 이용하여 판별변수들의 타당성을 확인⁽⁴⁾하였다. 또한 학습에 의해서 비교적 용이하게 판별의 정도를 향상시킬 수 있는 최종 의사결정(decision making)방법으로 신경회로망(neural network)을 이용하는 방법^{(5),(6),(7)}을 적용하였다. 최근 신경회로망을 이용하여 절삭상태와 공구마모의 인식에 관한 연구^{(8),(9),(10),(11),(12)}가 진행되고 있기는 하지만 주로 한정된 상황에 대응할 수 있는 경우이므로 본 연구에서는 신호처리 및 특징추출 방법으로 처리변수를 결정하고 결정된 변수들의 유의성을 검증하여 신뢰성을 높이고 범용성이 좋은 시스템을 구축하는데 목표를 두고 있다.

2. 의사결정

센서로부터 검출된 센서정보를 통합하고, 가공상태를 최종결정하기 위한 방법으로 신경회로망을 이용하는 방법이 프로세스의 감시에 비교적 유용한 것으로 보고 되고 있다. 본 연구에서도 절삭공구의 이상상태 진단의 최종 의사결정 방법으로 이러한 신경회로망 모델을 응용하였다. 입력신호는 절삭 프로세스로부터 특성이 다른 복수의 정보를 취하여 공구상태를 진단하며 진단의 신뢰성, 범용성을 높이고자 하였다. 절삭력 센서를 통하여 절삭력의 상태를 측정하고 이들을 분석하여 그 특징을 추출한 후 추출된 특징변수(배분력 표준편차(standard deviation: S.D.), 절삭력 변동계수(coefficient of variation: C.V.), 절삭력 평균비(initial avg./final avg.: AVG(i)/AVG(f)), 절삭력 분리비(feed force/principal force: F_f/F_p)를 판별분석으로 그 유용성을 확인하여 이것을 절삭조건과 함께 진단시스템의 입력신호로 적용하였다. 각각의 입출력 정보를 신경회로망의 오차역전파(error ba-

ck propagation)^{(5),(6)} 학습알고리즘을 이용하여 학습 완료 후 학습상태를 판정하고 미학습 절삭신호를 입력하여 본 실험에서 구축한 신경회로망 모델을 이용하여 공구마모와 파손을 진단하고자 하였다. 신경회로망의 입력변수는 연구성과와 시행착오를 기초로 하여 선택되는 것이 기본인데 본 실험에서는 일단 통계적인 처리를 거쳐 타당성 있는 변수를 선정함으로써 이와같은 시행착오를 줄이며 학습정도를 높여 양호한 학습과정을 갖도록 하였다.

3. 신경회로망에 의한 고찰

3.1 학습 및 테스트

사용된 신경회로망의 구조는 Table 1과 같다.

Table 1 Structure of neural networks for training

classification	learning conditions
number of input units	7
number of output units	3
number of hidden units	1'st layer : 14 2'nd layer : 7
number of hidden layers	2
learning rate η	0.5
momentum rate γ	0.5
shape factor	80

입력 유닛은 총 7개로 절삭력 신호로부터 추출된 특징변수(절삭력 평균비, 절삭력 표준편차, 절삭력 변동계수, 절삭력 분리비) 4가지와 절삭조건(절삭속도, 이송, 절삭깊이) 3가지로 하고 은닉층의 수는 2개이며 첫번째 은닉층의 유닛 수는 14개, 두번째 은닉층의 수는 7개로 하였다. 출력 유닛의 수는 이상가공상태(플랭크마모, 크레이터마모, 공구파손)를 판별하기 위하여 3개로 하고, 학습률 $\eta=0.5$, 모멘텀 $\gamma=0.5$, 형상계수 $\theta_0=1.0$ 이다. 이상에서 결정된 신경회로망 구조, 7-14-7-3 형태의 구조와 학습률, 모멘텀 값은 여러번의 시행착오를 거치며 공구상태를 가장 잘 진단할 수 있고 학습시간을 고려하여 알맞은 구조를 찾기 위하여 은닉층의 갯수와 각 은닉층에서의 유닛 수를 변화시켜 가면서 최종적으로 선택된 구조이다. 은닉층이 2개일 경우 유닛 수가 너무 적거나 크면 학습시간이 오래 걸리거나 총 학습오차가 크게 나타났다. 또한 은닉층이 1개일 때는 학습오차가 크게 나타나고 유닛 수를 크게 하여도 학습률이 그다지 좋아지지 않았다. 마찬가지로 은닉층의 수를 늘리거나 유닛 수를 증가시켜도 학습률이 크게 좋아지지 않으며 큰 학습시간이 요구되었다. 따라서 본 실험조건에서 공구상태의

진단에 효율적인 신경회로망 구조는 2개의 은닉층에 유닛 수는 각각 14개, 7개면 충분하리라 판단된다. 전체 출력변수의 이상상태를 각각 1과 0으로 판별하여 출력하

Table 2 Input conditions for learning

classification	1	2	3
cutting speed	100	150	200
feed	0.1	0.25	0.38
depth of cut	0.4	0.8	1.2
S. D.	~ 3	3 ~ 10	10 ~
C. V.	~ 40	40 ~ 60	60 ~
AVG(i)/AVG(f)	~ 1.2	1.2 ~	
F_r / F_b	~ 0.3	0.3 ~	

Table 3 Output category

classification	1	0
flank wear	wear	normal
crater wear	wear	normal
tool fracture	fracture	normal

Table 4 Learning conditions

number	classification						
	cutting speed	feed	depth of cut	S. D.	C. V.	AVG(i)/AVG(f)	F_r / F_b
1	1	1	1	1	1	1	1
2	1	1	2	1	1	1	1
3	1	1	3	1	1	1	1
4	1	2	1	1	1	1	1
5	1	2	2	2	1	1	1
6	1	2	3	3	1	1	1
7	1	3	1	1	1	1	1
8	1	3	2	2	1	1	1
9	1	3	3	3	2	2	2
10	2	1	1	1	1	1	1
11	2	1	2	1	1	1	2
12	2	1	3	2	2	2	2
13	2	2	1	1	3	2	2
14	2	2	2	2	2	1	2
15	2	2	3	3	3	2	2
16	2	3	1	2	1	2	2
17	2	3	2	3	1	2	2
18	2	3	3	3	3	2	2
19	3	1	1	1	3	2	2
20	3	1	2	1	3	2	2
21	3	1	3	2	2	2	2
22	3	2	1	2	1	1	1
23	3	2	2	2	3	2	2
24	3	2	3	2	2	2	2
25	3	3	1	2	2	2	1
26	3	3	2	3	3	2	2
27	3	3	3	3	3	2	2

도록 하였다. 또한 진단의 신뢰정도를 높이기 위하여 출력유닛 값이 0.90 이상인 경우와 0.10 이하를 출력값으로 인정하고 그 사이값은 오류로 판정하였다. 또한 출력값이 0이나 1이면 시그모이드 함수의 특성에 따라 무한대 값을 가지므로 0.01에서 0.99 사이의 값을 갖도록 하였다.

Table 2는 학습을 위한 입력시 코딩 값이고 Table 3은 출력 카테고리(category)이다. 플랭크마모는 공구수명 한계인 평균마모폭(VB) 값이 0.3mm 이상인 것을 출력값 1로하고 그 이하를 0으로 나타내었으며 크레이터마모는 STS304 절삭시 절삭날 가까이에 생성되는 특징으로 크레이터마모 최대 깊이(KT) 값이 0.1mm 이상이 되면 절삭날이 파손되고 표면거칠기가 나빠지므로 크레이터마모 최대 깊이가 0.1mm 이상이 되면 출력값을 1로하고 그 이하를 0으로 출력하였다.

Table 4는 전체 27개의 패턴을 무작위로 실험한 후 Table 2를 이용하여 코딩한 학습표본을 나타낸다.

Table 5는 실제 가공시의 결과와 학습결과로 전체 에

Table 5 Actual results and learning results

number	classification	actual results			learning results		
		flank wear	crater wear	tool fracture	flank wear	crater wear	tool fracture
1		0	0	0	0.01	0.01	0.02
2		0	0	0	0.03	0.01	0.01
3		0	0	0	0.01	0.04	0.01
4		0	0	0	0.04	0.01	0.01
5		0	0	0	0.01	0.01	0.06
6		0	0	0	0.01	0.02	0.01
7		0	0	0	0.01	0.01	0.01
8		0	0	0	0.04	0.01	0.03
9		0	0	0	0.02	0.01	0.05
10		0	0	0	0.04	0.01	0.01
11		0	0	0	0.01	0.02	0.01
12		1	0	0	0.99	0.01	0.01
13	slot	1	0	1	0.77	0.35	0.96
14	slot	1	1	1	0.92	0.95	0.83
15	slot	1	1	1	0.86	0.87	0.45
16		1	0	0	0.93	0.06	0.02
17		1	1	0	0.99	0.97	0.07
18		1	1	1	0.99	0.94	0.98
19		0	0	1	0.03	0.03	0.98
20		1	1	1	0.93	0.98	0.96
21		1	1	0	0.99	0.98	0.03
22		1	1	0	0.97	0.94	0.03
23		1	1	1	0.99	0.98	0.99
24		1	1	0	0.97	0.99	0.03
25		1	1	1	0.99	0.98	0.93
26		1	1	1	0.96	0.98	0.99
27		1	1	0	0.96	0.95	0.04




Fig. 1 Dimensions of slotted insert

러울(total error)을 0.01로 하고 이때 총 반복 학습횟수는 29525회이었다. 학습결과와 실제가공시의 결과를 비교하여 보면 일치 정도가 아주 좋음을 알 수 있다. 다만 공구에 슬롯을 낸 경우 일반 절삭 때와 절삭특성이 다르므로 약간 학습률이 떨어지지만 전체적으로 학습상태가 양호한 것으로 판정 되었다. 실험에 쓰인 슬롯공구의 형상은 Fig. 1과 같으며 실제가공은 랜덤하게 선택된 절삭 조건을 임의 시간동안 절삭가공 후 판정하였다. 실제 마모된 공구와 파손된 공구의 모습은 Fig. 2와 같다.

구축된 신경회로망으로 미지의 공구상태를 진단하기 위하여 Table 6과 같이 실험조건 상태를 달리(절삭시간의 변화, 슬롯공구의 임의선정, 마모, 파손공구로 절삭)하여 25개의 테스트 조건을 선정하였다.


Table 7은 선정된 조건의 테스트 결과와 실제 가공상태로 20번째 실험에서의 결과가 플랭크마모와 크레이터 마모의 진단에서 오류 진단으로 나타났다.



(a) flank wear



(b) crater wear



(c) fracture tool

Table 6 Test input conditions

classification							
number	cutting speed	feed	depth of cut	S.D.	C.V.	AVG(i)/AVG(f)	F_r / F_p
1	1	2	2	2	2	1	2
2	1	2	3	3	2	1	2
3	1	3	3	3	2	2	1
4	2	1	1	1	1	2	2
5	2	1	3	2	2	2	2
6	2	1	3	3	3	1	2
7	2	2	1	3	3	2	2
8	2	3	3	3	3	2	1
9	3	1	1	3	3	2	2
10	3	2	1	2	2	2	2
11	3	2	2	3	3	2	2
12	1	3	1	2	1	1	1
13	1	3	2	2	2	2	2
14	2	1	2	2	2	1	2
15	2	2	1	1	1	2	1
16	2	2	2	2	1	1	2
17	2	3	1	2	1	1	1
18	2	3	2	2	1	2	2
19	3	1	1	1	1	1	2
20	3	1	1	2	3	2	2
21	3	1	2	1	1	1	1
22	3	1	2	2	3	2	2
23	3	2	1	2	1	1	1
24	3	2	2	2	1	1	2
25	3	3	1	2	2	2	2

Fig. 2 Shape of tool (a) flank wear, (b) crater wear, (c) fracture tool

Table 7 Test results and actual results

number	test results			actual results		
	flank wear	crater wear	tool fracture	flank wear	crater wear	tool fracture
1	0.01	0.02	0.01	normal	normal	normal
2	0.02	0.01	0.01	normal	normal	normal
3	0.01	0.03	0.02	normal	normal	normal
4	0.01	0.01	0.01	normal	normal	normal
5	0.01	0.01	0.03	normal	normal	normal
6	0.98	0.99	0.96	wear	wear	fracture
7	0.99	0.99	0.99	wear	wear	fracture
8	0.98	0.94	0.99	wear	wear	fracture
9	0.98	0.93	0.98	wear	wear	fracture
10	0.99	0.96	0.99	wear	wear	fracture
11	0.98	0.99	0.97	wear	wear	fracture
12	0.04	0.02	0.01	normal	normal	normal
13	0.01	0.03	0.03	normal	normal	normal
14	0.02	0.01	0.01	normal	normal	normal
15	0.01	0.06	0.04	normal	normal	normal
16	0.02	0.01	0.02	normal	normal	normal
17	0.93	0.92	0.05	wear	wear	normal
18	0.99	0.98	0.06	wear	wear	normal
19	0.01	0.02	0.02	normal	normal	normal
20	0.45	0.34	0.99	wear	wear	fracture
21	0.02	0.04	0.01	normal	normal	normal
22	0.98	0.93	0.99	wear	wear	fracture
23	0.99	0.92	0.06	wear	wear	normal
24	0.99	0.94	0.05	wear	wear	normal
25	0.98	0.99	0.98	wear	wear	fracture

이상의 분석으로 Table 8과 같은 결과를 얻을 수 있었다. 진단 결과로, 플랭크마모는 전체 입력 패턴수 25개 중 1개의 오류가 발생하여 96%의 진단이 가능하였으며 크레이터마모 역시 25개 중 1개의 오류가 발생하여 96%의 정답률을 보였다. 공구파손은 전체 패턴을 모두 인식하여 100%의 정답률을 보였다. 진단결과를 살펴보면 전체적으로는 97.3%의 정답률을 보여주고 있어 진단율이 양호하다고 판단된다.

이와같이 양호한 진단율은 결국 신호처리와 특징추출을 통한 판별변수의 선정으로 변수 선정단계에서 검증은 거친 결과로 이와같은 처리 기법을 통하여 시행착오를 줄일 수 있고 우수한 진단 결과를 얻을 수 있다는 것이 판명되었다.

Table 8 Performance of neural networks

classification	flank wear	crater wear	tool fracture
number of test patterns	25	25	25
number of errors	1	1	0
accuracy percent(%)	96	96	100

4. 결론

선삭가공에서 공구상태를 진단하고자 절삭조건과 절삭력 파라메타를 이용하여, 신호처리 및 특징추출의 방법으로 선형식별함수 방법인 Fisher의 선형판별함수를 사용하고 최종 의사결정 방법으로 신경회로망을 적용하여 다음과 같은 결론을 얻었다.

선택된 변수들을 선형판별함수를 이용하여 공구상태를 분류, 판별하고 유의성을 검증하여 신경회로망 학습변수로서의 타당성 판별하고, 신경회로망을 도입하여 선택된 27개 패턴의 가공상태를 학습한 후 25개의 실제 가공 중 발생하는 공구상태를 진단한 결과 플랭크마모, 크레이터마모는 96%, 공구파손은 100%의 정답률을 보여 전체적으로 97%가 넘는 양호한 진단 결과를 보였다. 이상의 결과로 신호처리와 특징추출을 통한 학습변수의 선정이 신경회로망을 이용한 진단에 유용하게 적용됨을 알 수 있고 다른 실험조건에도 충분히 적용될 수 있으리라 생각된다.

참 고 문 헌

1. J. Colgan, H. Chin, K. Danai and S. R. Hayashi, "On-Line Tool Breakage Detection in Turning : A Multi-Sensor Method", ASME J. of Engineering for Industry, Vol. 116, FEBRUARY, pp. 117~123, 1994.
2. D. A. Dornfeld, K. A. Elijah, "Acoustic Emission During Orthogonal Metal Cutting", Int. J. Mach. Sci., Vol. 22, pp. 285~296, 1986.

3. J. L. Andreasen, L. De Chiffre, "Automatic Chip-Breaking Detection in Turning by Frequency Analysis of Cutting Force", *Annals of the CIRP*, Vol. 42/1. pp. 45~48, 1993.
4. 정진용,유기현,권용기,서남섭, "절삭조건과 절삭력 파라메타를 이용한 공구상태 진단에 관한 연구 (I)", *한국정밀공학회지*, 14권, 10호 pp. 135~140, 1997.
5. 이성환, "패턴인식의 원리 II", *홍릉과학출판사*, pp. 3~134, 1994.
6. Timothy Masters, "Practical Neural Network Recipes in C++", *Academic Press, Inc.* pp. 77~116, 1993.
7. Frank h. Eeckman, "NEURAL SYSTEMS: ANALYSIS AND MODELING", *KLUWER ACADEMIC*, pp. 5~38, 1993.
8. S. Rangwala, D. A Dornfeld, "Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring", *ASME J. of Engineering for Industry*, Vol. 112, pp. 219~228, 1990.
9. T. Moriwaki, Y. Mori, "Recognition of Cutting State Based on Neural Network Sensor Fusion", *JSPE-59-05*, pp. 77~82, 1993.
10. D. A. Dornfeld, M. F. Devries, "Neural Network Sensor Fusion for Tool Condition Monitoring", *Annals of the CIRP*, Vol. 39/1, pp. 102~105, 1990.
11. K. Iwata, "Estimation of Cutting Tool Life by Processing Tool Image Data with neural network", *Annals of the CIRP*, Vol. 42/1, pp. 59~62, 1993.
12. 고태조, 조동우, "밀링공정의 적응모델링과 공구마모 검출을 위한 신경회로망 적용", *한국정밀공학회지*, 11권, 1호 pp. 138~149, 1994.