

백프로파게이션 알고리즘을 이용한 칩 형태의 인식 Identification of the Chip Form Using Back Propagation Algorithm

심재형*(부산대 대학원), 권혁준(경주전문대), 백인환(부산대 공대)
Jae-hyung Sim*(Pusan Graduate School, Pusan Univ.), Hyeog-jun Kweon(Kyungju jr. College)
and In-hwan Paik(Pusan Univ.)

ABSTRACT

A major problem in automation of turning operation is the difficulty in obtaining a sufficient and reliable chip control. Therefore it becomes desirable to find a method which can detect the chip form. In this paper, a method of the identification of chip form using output of pyrometer and neural network technique is developed. An efficiency of developed method is examined by experiments in turning and the validity of it is confirmed.

Key Words : chip control(칩제어), chip form(칩형태), emmissivity(방사율), pyrometer(방사온도계), Neural Network(신경망), Backpropagation(오류역전파)

1. 서론

현대의 기계적 생산의 궁극적 목표로 들 수 있는 것은 고속화에 의한 가공성의 향상이다. 이를 위하여 여러 가지 시도들이 행하여지고 있는데 대표적인 것으로 무인자동화에 의한 생산을 들 수 있다. 사람의 간섭없이 제품을 생산해 낼 수 있다는 것은 여러 가지 많은 장점을 가지고 있다. 이를 위하여 현대의 절삭에서 칩의 처리는 중요한 요소로 대두되고 있다. 연속적으로 생성되는 칩은 가공물과 공작기계의 정밀도를 저해하고 공구의 마모를 촉진시키며 작업자에게 대단히 위험한 요소가 된다.

이러한 칩처리 문제를 해결하기 위하여 많은 학자들이 경험적 데이터와 간단한 수학적 이론을 사용하거나 여러 가지 센서를 사용하여 절삭상태를 감시하려는 시도를 하였다.

그러나 칩의 생성, 배출의 문제는 이론적으로 매우 복잡하고 다양한 조건들이 수반되므로 수학적인 모델링이나 신호처리의 기법으로 해결하려는 데에는 한계가 있다. 이러한 문제를 해결하기 위하여 많은 논문에서 지능적 알고리즘을 이용한 "block-box"형 접근방법을 제안하였다. Ralston 등은 AE 신호를 Fuzzy 인식기에 도입하여 칩형태를 예측하였으며, 백인환 등은 방사온도계의 출력신호를 Fuzzy 인식

기에 도입하여 칩형태를 실시간으로 인식하였다⁽¹⁻³⁾. 본 연구에서는 방사온도계를 이용하여 각 가공에 있어서 칩상태에 따른 방사온도계의 출력값을 검토한 후 백프로파게이션 알고리즘을 통하여 칩형태를 실시간적으로 인식하고 실험을 통하여 인식기의 성능을 평가한다.

2. 이론적 배경

2-1 적외선 방사온도계

방사온도계의 원리는 「모든 물체는 그 절대온도의 4제곱에 비례한 에너지를 표면에서 방사한다」라는 스테판 볼츠만의 법칙을 이용하며 식(2-1)과 같이 주어진다. 그러나 동일 온도일지라도 물체종류 혹은 표면상태에 따라 방사에너지가 변화하므로 스테판 볼츠만 법칙은 각 물체 고유의 방사율을 이용하여 식(2-2)처럼 수정되어야 한다. 즉 식(2-1)은 물체자신에서 최대의 에너지를 방사하는 흑체의 경우에 해당하며, 모든 물체의 방사율은 흑체의 방사율(1)에 대한 비율을 의미하는 것이다.

$$P = \sigma \cdot T^4 [W \cdot cm^{-2}] \quad (2-1)$$

$$P = \epsilon \cdot \sigma \cdot T^4 [W \cdot cm^{-2}] \quad (2-2)$$

- P Incident Energy
- σ Stefan - Boltzmann constant
($5.67 \times 10^{-8} W \cdot m^{-2} \cdot K^{-4}$)
- ϵ Emissivity
- T Absolute Temperature

적외선 방사 온도계는 Fig. 1에 나타낸 것처럼 열방사를 고효율로 집광하여 필요에 따라 특정파장대를 선택하는 소자, 집광된 열방사를 전기신호로 변화하는 검출소자 및 전기신호를 증폭처리하는 전기계로 구성된다.

광학계는 검출소자에 에너지를 집중시키는 집광작용 외에 특정파장대를 선택하기 위해 광학필터로도 사용되며 검출소자에는 열방사를 열로서 받아들여 소자의 미소 온도변화를 전기적 신호로 변환하는 형태와 열방사를 빛으로 포착하여 광전효과를 이용하는 광양자형 등이 개발되어 있다. 본 연구에 사용된 서모 파일(Thermo Pile)은 열전대를 직렬로 집적한 것으로 양단의 온도차에 의하여 발생하는 열기전력에 의하여 온도를 계산할 수 있다.




Fig. 1 Constitution of pyrometer

이처럼 열형 적외선 센서는 물체로부터 방사에너지를 받아서 수광부의 온도를 변화시키고 이로부터 출력신호를 얻는 것이며 수광부는 흑체로 되어 있으므로 검출감도에 파장 의존성이 없다. 따라서 파장특성은 사용하는 필터에 의해 정해지며 일반적인 서

모파일에서 사용하는 Si 필터의 투과파장영역은 1.2 - 15 μ m의 적외영역이다. 측정되는 온도는 시야에 잡히는 물체의 평균온도를 나타내므로 어떤 영역의 정확한 온도를 계측하려면 집광렌즈의 사용 또는 내면이 흑화된 실린더의 사용 등과 같은 시야를 한정하는 방법이 요구된다.

2-2 칩 처리 및 분류

선삭가공에 있어서 연성재료의 고속절삭시는 대부분 긴 연속형 칩이나 리본타입의 칩이 형성되며 이는 제품에 대한 손상 뿐 아니라 곧 칩이 뒤엉킨 등 우리(nest) 형상으로 발전하기 때문에 공작기계의 능력을 가로막는 요인이 되고 있다. 즉 칩 nest를 제거하기 위하여 기계를 주기적으로 정지시켜야 하므로 생산성이 저하될 뿐 아니라 무인자동화의 장애요인이 되는 것이다.

Lang은 칩패키비(R)를 다음과 같이 제안하여 만족스러운 칩 처리를 위해서는 R의 값이 4정도가 되어야 하며 이를 위하여 주기적으로 칩을 끊어주어야 한다고 주장하였다.

$$R = \frac{\text{volume of chip}}{\text{equivalent volume of uncut metal}} \quad (2-4)$$

한편, 칩의 형태는 CIRP(국제생산가공연구회의), 일본기계진흥협회 및 INFOS(독일절삭정보센터) 등에 의해 분류되고 있지만 그 주류는 동일하므로 본 연구에서는 INFOS의 분류(Fig. 2참조)에 기초하여 칩 상태를 판별하였다.

1		ribbon chips	unstable
2		tangled chips	
3		corkscrew chips	
4		helical chips	
5		long tubular chips	stable
6		short tubular chips	
7		spiral tubular chips	
8		spiral chips	
9		long comma chips	
10		short comma chips	

Fig. 2 Classification of chip pattern(INFOS)

3. 칩 체류에 따른 방사온도계의 출력

3-1 실험장치 구성

본 실험에서는 시판의 적외선 방사온도계(Watlow 사)를 이용하였다. 이 온도계의 시야를 절삭시 칩이 머무르는 곳에 집적시키면 시야에 머무는 칩에서 발생하는 방사에너지를 대소를 측정할 수 있다. 이를 이용하면 칩의 양을 간접적으로 측정할 수 있게되고 칩의 양을 통하여 칩의 형태를 인식할 수 있다.

실험장치는 Fig. 3처럼 온도출력용 인디케이트를 생략하고 적외선 온도센서의 전류출력 양단에 정밀 저항을 걸어 전압신호로 변환한 후 A/D 변환기내장된 컴퓨터에서 칩상태를 판별하도록 하였다.




Fig. 3 Measurement system of emissivity energy

3-2 선삭가공

이 절에서는 선삭가공의 경우 이송량과 절삭깊이에 따른 방사온도계의 출력을 검토하였다. 실험장치 구성시 입사거리와 입사각도를 일정하게 하고 방사온도계를 절삭점 부근에 90°로 조사할 수 있도록 지지대를 공구홀더에 직접 용접하여 설치하였다. 단 공구온도의 상승에 의해 방사온도계의 출력이 상승하는 것을 방지하기 위해 방사온도계의 시야부분은 주로 피삭재 위로 유동하는 칩 부분으로 하였다.

Fig. 4는 다른 절삭조건을 일정하게 하고 이송량을 변화시키면서 가공할 때 방사온도계의 출력을 나타낸 것이다. 그림에서 확인할 수 있듯이 이송량이 적어질수록 방사온도계의 출력이 증가하는 경향을 보이는데 이송량이 비교적 작은 영역인 0.073~0.157 mm/rel에서는 연속형 칩(Fig. 2의 1, 2, 3)이 발생하였고 그 결과 칩이 절삭점 부근에서 엉키면서 방사온도계의 시야에 다량의 고온칩이 머물기 때문인 것으로 사료된다. 이송량이 0.314에서는 분절형 칩(Fig. 2의 4, 5)이 발생하여 이 결과 방사온도계의

시야에 머무는 칩의 면적이 작아져 결과적으로 방사온도계의 출력이 줄어든 것으로 사료된다. 특히 이송량이 0.409인 경우는 잘게 부서지는 칩(Fig.2의 7, 8)이 발생되어 출력값이 적을 뿐 아니라 칩이 랜덤하게 비산하므로 다른 실험치에 비하여 결과의 편차가 컸다.

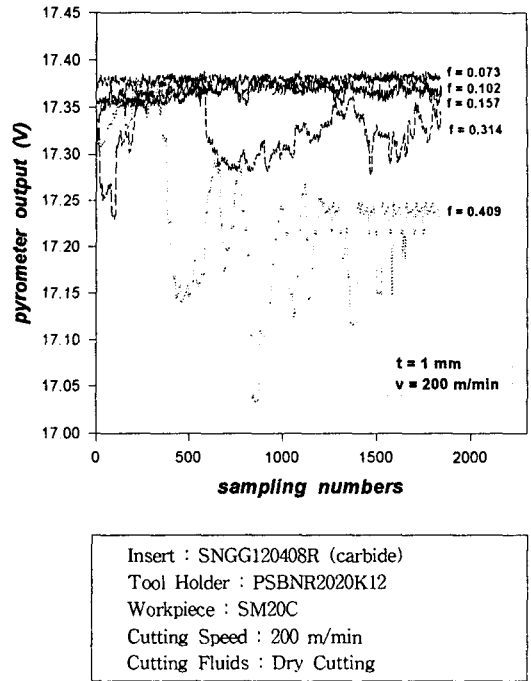


Fig. 4 Relationship between Pyrometer Output and Chip Pattern

4. 신경망의 구성과 시뮬레이션

4-1. 신경망의 개요

인공지능을 구현하는 하나의 방법인 신경망은 뇌의 신경세포를 단순화시켜 수학적으로 모델링한 인공 신경세포(artificial neuron)와 그것들의 연결로 구성되어있다. 신경회로망에 있어서 각각의 요소에 해당하는 뉴런과 입력, 그리고 그들을 상호 연결하는 결합하중사이의 관계를 도식화 한 것이 Fig. 5이다. 그림에서 보인바와 같이 인공세포는 정보처리의 핵심인 인공신경세포와 기억의 핵심인 연결가중치로 구성되어 있다.

대뇌의 뉴런은 자신과 연결된 많은 다른 신경세포들로부터 전기, 화학적 신호들을 시냅스를 통하여 받아들여 종합하고, 설정되어 있는 역치를 통하여 출력을 조정하지만, 신경회로망에 있어서 뉴런은

Fig. 5과 같이 다른 인공 신경세포에서 전달된 출력 값(X_i)에 결합하중(W_{ij})을 곱하여 단순히 산술적 합




Fig. 5 Diagram of artificial neuron

산에 의해 구하여진 총합(U_i)을 전달함수 $S(u_i)$ 에 입력한다. 입력에 대한 그 뉴런의 흥분이 클수록 뉴런의 출력 U_j 는 큰 값이 되고, 그 값을 다음의 뉴런으로 전달한다.

신경망의 흥분 정도는 결합하중 W 의 값에 따라 좌우되고, 신경망의 학습은 그 결합하중을 조정함으로써 행하여 진다. 신경망의 각 계층들은 전후 층의 노드(Node)들과 연결되고 이 결합들의 가중치를 여러 학습알고리즘을 이용하여 결정한다.

본 연구에서는 각 계층의 결합하중을 결정하는 학습알고리즘으로 오류 역전파법(Back Propagation)을 이용하였다.

입력된 데이터는 각 결합하중과 곱하여져 중간층, 출력층으로 입력되고 출력층에서 출력된 결과를 감독 데이터(Supervised Data)와 비교하여 그들 사이의 오차를 구하고 구하여진 오차를 최소화 시킨다. 위의 Fig. 6은 백프로파게이션 학습과정을 순서대로 나타낸 것이다.

4-2 신경망의 구성

서론에서 잠시 언급한 것과 같이 칩의 생성, 배출 문제는 이론적으로 매우 복잡하고 다양한 인자들로 구성되어 정확한 수학적 모델링이나 신호처리의 기법으로 해결하려는 데는 한계가 있다. 이런 이유로 본 연구에서는 칩처리에 정확한 모델링 없이 문제를 해결할 수 있는 신경망을 적용한다.

신경망은 칩의 생성과정에 관련된 수학적 지식이나 질산인자들이 칩 생성에 미치는 영향에 대한 지식이 거의 없는 상태에서도 적용이 가능하고, 경향이 뚜렷한 패턴들로부터 학습을 통하여 가중치만 결정되고 학습의 과정이 없이도 유사한 입력패턴에 대하여 그 결과를 추정할 수 있도록 자기조직화(Self-Organization)하는 이점이 있다.

본 연구에서 사용된 신경망은 Fig. 7과 같이 $6 \times 10 \times 10 \times 3$ -6개의 입력 유닛을 가지는 입력층(Input Layer), 각각 10개의 유닛을 가지는 2개의 중간층(Hidden Layer), 3개의 유닛을 가지는 출력층-으로 구성되어 있다.

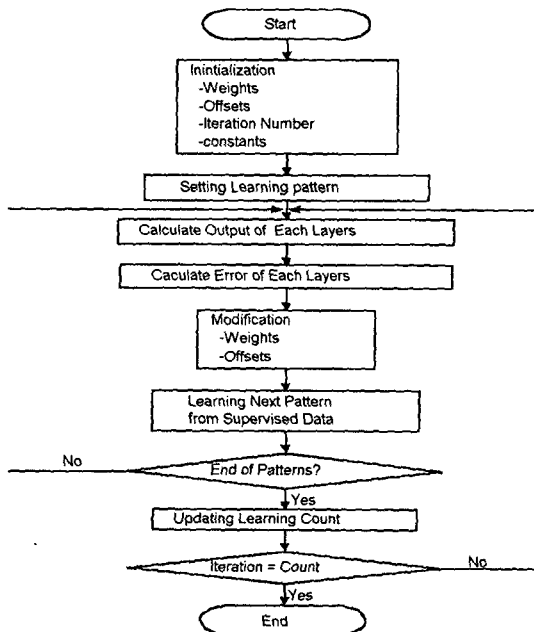


Fig. 6 Flow chart of backpropagation




Fig.7 Architecture of neural network

입력데이터로 사용되는 데이터는 보통 각종 센서(Sensor)들의 출력나 이들의 분산 또는 RMS 값들이 사용된다⁽⁴⁻⁶⁾. 그러나 이러한 방법들은 센서들의 신호처리 과정이 복잡할뿐더러 많은 비용이 들게 되

고, 실시간으로 데이터를 처리하는 데 어려움이 있다. 때문에 본 연구에서는 여섯 번의 샘플링 시간 동안 측정된 방사온도계의 출력값만을 입력 데이터로 사용한다.

출력데이터는 Fig. 4의 칩 패턴분류에 사용되는 언어변수인 Stable, Usable, Unstable가 사용된다. 이 값들에 대한 출력값을 구한 다음, 가장 크기가 크게 나오는 변수의 상태로 칩의 형태를 인식하게 된다.

앞에서 언급하였듯이 학습은 감독학습법에 의한 백 프로파게이션 알고리즘을 이용하여 행하였고 오차를 줄이는 방법으로 오차의 제곱값을 줄이는 Delta Rule을 사용하였다. 또 전달함수는 시그모이드 함수를 사용하였다.

4-3. 감독 데이터와 학습조건

칩의 전형적인 형태에 대한 인식을 위하여 감독데이터는 Fig. 7에서 이송량이 0.073, 0.314, 0.409 일때의 결과치를 이용하였다. 패턴을 얻기 위하여 각각의 실험 결과치에서 50회 단위로 샘플을 채취하여 부분평균을 낸 다음 평균에 가까운 패턴들을 선정하였다.

위의 결과를 바탕으로 3개의 출력조건에 대하여 각각 10개씩 30개의 감독데이터를 선정하였다. 선정된 데이터를 Table 2에 수록하였다. 각각의 데이터들은 3개의 실험조건의 시간에 따른 평균치의 변화량을 나타낼 수 있게 선정되었다. 실제 실험에 의하여 구하여진 데이터들은 절대값이 커서 학습속도가 느리므로 각 측정치에서 소수점 위의 정수부분인 17을 뺀 값을 감독데이터로 사용하였다.

학습은 전체 시스템의 오차가 1.5%가 이하가 되거나, 반복회수가 30,000회가 될 때 까지 수행하였다.

4-4 시뮬레이션

선정된 감독데이터를 이용하여 백 프로파게이션 알 신경망 프로그램을 작성하여 시뮬레이션을 행하였다.

실제 절삭과정에서 추출한 패턴을 이용하여 학습시킨 결과가 Table 1에 수록되었다. Table 2는 신경망의 자기조직특성을 확인하기 위하여 감독 데이터에서 사용하지 않은 패턴에 대한 인식결과이다. 측정 데이터들은 여러 실험조건에서 얻어진 실험치들을 임의로 추출하여 얻은 것이다.

위의 결과에서도 볼 수 있듯이 신경망은 실제결과에 상당히 근접하는 값을 출력한다. 그러므로 신경망 시뮬레이터는 주어지지 않은 패턴에 대하여서도

우수한 적응성을 가짐을 확인할 수 있다.

Table 1 Supervised data for learning

Input Pattern						Desired Output			Result
x_{t_n-5}	x_{t_n-4}	x_{t_n-3}	x_{t_n-2}	x_{t_n-1}	x_{t_n}	Stable	Usable	Unstable	
0.355	0.355	0.356	0.356	0.355	0.354	0	0	1	Unstable
0.359	0.358	0.358	0.357	0.356	0.355	0	0	1	Unstable
0.361	0.360	0.358	0.355	0.353	0.353	0	0	1	Unstable
0.366	0.366	0.367	0.369	0.370	0.370	0	0	1	Unstable
0.372	0.373	0.372	0.369	0.368	0.365	0	0	1	Unstable
0.382	0.382	0.381	0.380	0.381	0.381	0	0	1	Unstable
0.384	0.384	0.384	0.383	0.383	0.381	0	0	1	Unstable
0.375	0.374	0.372	0.370	0.371	0.372	0	0	1	Unstable
0.381	0.382	0.382	0.384	0.384	0.383	0	0	1	Unstable
0.381	0.378	0.376	0.374	0.374	0.373	0	0	1	Unstable
0.313	0.315	0.316	0.316	0.317	0.316	0	1	0	Usable
0.303	0.306	0.307	0.307	0.308	0.308	0	1	0	Usable
0.306	0.304	0.301	0.300	0.300	0.300	0	1	0	Usable
0.304	0.302	0.298	0.293	0.290	0.288	0	1	0	Usable
0.286	0.287	0.289	0.290	0.291	0.292	0	1	0	Usable
0.297	0.296	0.294	0.292	0.290	0.290	0	1	0	Usable
0.298	0.298	0.289	0.290	0.291	0.293	0	1	0	Usable
0.294	0.294	0.294	0.294	0.292	0.290	0	1	0	Usable
0.288	0.286	0.284	0.283	0.283	0.283	0	1	0	Usable
0.284	0.286	0.287	0.287	0.287	0.287	0	1	0	Usable
0.166	0.167	0.169	0.169	0.169	0.169	1	0	0	Stable
0.167	0.164	0.157	0.150	0.146	0.143	1	0	0	Stable
0.143	0.143	0.143	0.145	0.146	0.148	1	0	0	Stable
0.148	0.146	0.145	0.153	0.146	0.142	1	0	0	Stable
0.139	0.138	0.138	0.139	0.139	0.142	1	0	0	Stable
0.142	0.142	0.142	0.141	0.139	0.139	1	0	0	Stable
0.141	0.143	0.143	0.143	0.145	0.146	1	0	0	Stable
0.257	0.240	0.228	0.222	0.219	0.221	1	0	0	Stable
0.035	0.035	0.037	0.035	0.034	0.032	1	0	0	Stable
0.032	0.031	0.031	0.031	0.032	0.032	1	0	0	Stable

Table 2 Implementation results

Input Pattern						Output			Desired result	Result
x_{t_n-5}	x_{t_n-4}	x_{t_n-3}	x_{t_n-2}	x_{t_n-1}	x_{t_n}	ST	US	UST		
0.376	0.375	0.374	0.373	0.372	0.373	0	0	0.99	UST	UST
0.369	0.371	0.372	0.374	0.374	0.372	0	0	0.99	UST	UST
0.367	0.364	0.361	0.357	0.356	0.359	0	0	0.99	UST	UST
0.374	0.372	0.371	0.371	0.370	0.370	0	0	0.99	UST	UST
0.356	0.352	0.355	0.354	0.350	0.349	0	0	0.99	UST	UST
0.300	0.301	0.300	0.301	0.301	0.300	0	0.90	0.01	US	US
0.290	0.290	0.291	0.290	0.289	0.294	0	0.89	0.01	US	US
0.283	0.283	0.282	0.284	0.293	0.306	0	0.91	0.01	US	US
0.321	0.322	0.322	0.321	0.319	0.318	0	0.90	0.01	US	US
0.321	0.312	0.312	0.313	0.315	0.316	0	0.90	0	US	US
0.216	0.221	0.231	0.240	0.247	0.252	1	0	0	ST	ST
0.249	0.249	0.249	0.249	0.250	0.253	1	0	0	ST	ST
0.184	0.195	0.202	0.209	0.212	0.214	1	0	0	ST	ST
0.240	0.246	0.243	0.240	0.237	0.238	1	0	0	ST	ST
0.218	0.219	0.222	0.222	0.224	0.225	1	0	0	ST	ST

(주) ST : stable, US : usable, UST : unstable

4-5 성능평가

위에서 구축된 신경망 인식기가 실제 가공중에서 발생하는 다양한 온도계의 출력에 대하여 올바른 인을 수행하는지의 여부에 대하여 평가하기 위하여 실험을 행하였다.




Fig. 8 Pyrometer output and chip pattern in feed change

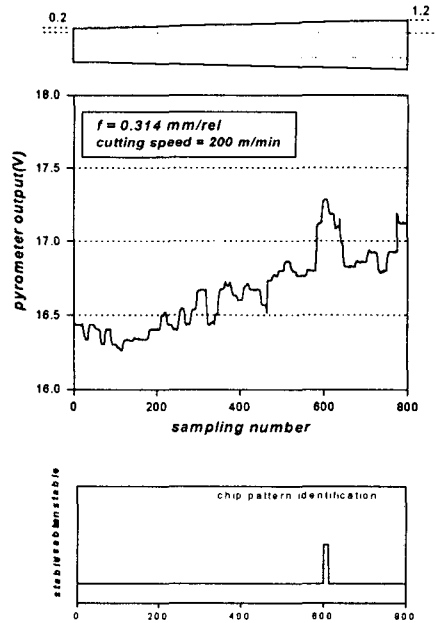


Fig. 9 Pyrometer output and chip pattern in change of depth of cut

위의 Fig. 8은 연속적인 이송량의 변화에 따른 인식기의 출력결과를 그래프로 나타낸 것이다. 방사온도계의 출력이 감속데이터에 적절히 수렴하여 비교적 올바른 결과가 출력되는 것을 보이고 있다.

아래의 Fig. 9는 테이퍼 가공된 소재를 가공시 절삭깊이의 변화에 따른 방사온도계의 출력값과 인식기의 인식결과를 그래프로 나타낸 것이다. 절삭과정의 대부분에서 Fig. 2의 6, 7, 8번에 해당하는 칩이 발생하였고 인식결과도 위의 사실에 정확히 일치함을 볼 수 있다.

5. 결론

본 연구에서는 방사온도계에서 얻어진 출력값으로부터 절삭과정중에서 발생하는 칩의 형태를 인식하기 위하여 신경회로망을 적용하여 다음의 결론을 얻었다.

[1] 방사온도계의 출력을 신경회로망에 응용하여 칩 형태를 인식하는 시뮬레이터를 개발하였다.

[2] 각 절삭과정에서의 실제 출력데이터를 이용하여 학습을 행함으로써 실시간 제어 시스템의 가능성을 확인할 수 있었다.

참고문헌

1. P.A.S. Ralston, K.E. Stoll, T.L. Ward, "Fuzzy Logic Control of Chip Form During Turning", Computer ind. Engeer., Vol.22, No.3, pp.223-230, 1992.
2. 백인환 외 3인, "방사온도계에 의한 칩 형태 인식", 한국정밀공학회, 제13권, 제7호, pp.59-65, 1996.
3. Sawai Sukvittayawong, Ichiro Inasaki, "Idenfication of Chip Form in Turning Process", JSME Vol.34, No.4, 1991, pp.553-560
4. D. Dornfeld, "Neural Network Sensor Fusion for Tool Condition Monitoring", Annals of the CIRP, Vol.39, No.1, pp101-105, 1990.
5. Y.L Yao, et al., "Assessment of Chip Forming Patterns with Tool Wear Progression in Machining via Neural Networks", Int. J. Mach. Tools Manufact., Vol.33, No.1, pp.89-102, 1993.
6. 森脇俊道 外 1人, "ニューラルネットワークを用いた切削状態の認識に関する研究", 日本精密工學會誌, Vol.59, No.5, pp.779-784, 1993.