

신경망을 이용한 칩 형태의 인식

심재형*, 권혁준**, 백인환***

Identification of the Chip Form Using Neural Network

Jae-hyung Sim*, Hyeog-jun Kweon**, In-hwan Paik***

ABSTRACT

A major problem in automation of turning operations is the difficulty in obtaining a sufficient and reliable chip control. The chip should be detected in order to provide a optimum chip control for unmanned turning operation.

Using the difference of energy radiated from the chip, chip patterns are estimated using pyrometer. From the initial output from the pyrometer, chips are identified according to the backpropagation algorithm developed in the research. The learning system developed in this work can be applied in real-time control of turning process with minor modification in drive system.

Key Words : Chip Control(칩제어), Chip Form(칩형태), Emmisivity(방사율), Pyrometer(복사온도계), Neural Network(신경망), Backpropagation(오류역전파)

1. 서론

자동화 기계에 의한 생산의 궁극적 목표는 생산성을 향상시켜 비용을 최소화 하는 것이다. 이를 위하여 현대의 절삭은 고속화, 무인화 경향을 띠고 있다.

고속가공에서는 짧은 시간 동안에 다량의 칩이 발생된다. 특히, 단인공구를 사용하는 선삭의 경우에는 고속가공 시 주로 길게 유동하는 연속형 칩들이 발생되고, 이 생성된 칩들은 짧은 시간 동안에 엉키어 등우리(nest)를 생성한다. 이 등우리는 제품의 표면을 긁어 정밀도를 저해하고 기계에 충격을 주어 고장을 일으키는 요소가 되며, 공구의 수명을 단축시키는 문제점을 발생시킨다. 또 고온의 칩은

작업자에게 위협을 초래하는 요소가 되기도 한다⁽¹⁾.

생산성 향상의 수단으로 들 수 있는 다른 하나는 무인 자동화에 의한 생산이다. 무인자동화에 의한 생산은 다품종 소량생산이라는 생산구조에 적합하고 생산비용의 절감을 가져오는 등 여러 이점이 있다.

무인 가공시 칩의 엉킴으로 발생하는 돌발적인 사태를 막기 위해서는 칩의 생성패턴을 자동으로 검출하는 것이 필수적이다.

이러한 칩처리 문제를 해결하기 위하여 많은 학자들이 경험적 데이터와 간단한 수학적 이론을 사용하거나 여러 가지 센서를 사용하여 절삭상태를 감시하려는 시도를 하였다⁽²⁻⁴⁾. 그러나 칩의 생성, 배출의 문제는 이론적으로 매

* 부산대학교 대학원 지능기계공학과
 ** 서라벌대학 자동차과
 *** 부산대학교 기계기술연구소

우 복잡하고 다양한 조건들이 수반되므로 수학적인 모델링이나 신호처리의 기법으로 해결하려는 데에는 한계가 있다.

이 때문에 지능적 알고리즘을 이용한 접근방법이 많은 학자들에 의하여 제안되었다. 그러한 접근방법 중 대표적인 것으로 들 수 있는 것이 fuzzy이론과 신경망이다⁽⁶⁻⁷⁾.

본 연구에서는 가공 중에 발생하는 칩 형태를 실시간적으로 인식하기 위하여 복사온도계를 이용하여 각 가공에 있어서 칩형태에 따른 복사온도계의 출력값을 검토하고 복사온도계의 출력을 신경망의 학습알고리즘인 백프로파게이션 알고리즘에 적용하여 칩형태를 실시간으로 인식하고 실험을 통하여 인식기의 성능을 평가한다.

2. 이론적 배경

2-1 적외선 복사온도계

복사온도계의 원리는 「모든 물체는 그 절대온도의 4제곱에 비례한 에너지를 표면에서 방사한다」라는 스테판 볼츠만의 법칙을 이용하여 복사에너지를 측정하는 것이다. 그러나 실제의 경우에는 물체종류 혹은 표면상태에 따라 복사에너지가 변화하므로 물체의 방사율을 고려하여 다음의 식으로 복사에너지를 측정할 수 있다.

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

P : Incident energy

σ : Stefan - Boltzman constant

$$(5.67 \times 10^{-8} W \cdot m^{-2} \cdot K^{-4})$$

T : Absolute temperature

적외선 복사온도계는 열복사를 고효율로 집광하여 필요에 따라 특정파장대를 선택하는 소자, 집광된 열복사를 전기신호로 변환하는 검출소자 및 전기신호를 증폭 처리하는 전기계로 구성된다.

광학계는 검출소자에 에너지를 집중시키는 집광작용 외에 특정파장대를 선택하기 위해 광학필터로도 사용되며 검출소자에는 열복사를 열로서 받아들여 소자의 미소 온도변화를 전기적 신호로 변환하는 형태와 열복사를 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.

2-2 칩 처리 및 분류

칩의 형태는 CIRP(국제생산가공연구회의), 일본기계진흥협회 및 INFOS(독일철삭정보센터) 등에 의해 분류되고 있지만 그 주류는 동일하므로 본 연구에서는 INFOS의 분류(Fig. 1참조)에 기초하여 칩 상태를 판별하였다.

그림에서와 같이 칩은 10가지의 형태로 나누어진다. 또 나누어진 칩의 형태를 3개의 언어변수, stable, usable, unstable로 분류할 수 있다. 이 3개의 언어변수들은 신경망을 구성하는 출력변수로 사용될 것이다.

2-3 신경망의 개요

인공지능을 구현하는 하나의 방법인 신경망은 뇌의 신경세포를 단순화시켜 수학적으로 모델링한 인공 신경세포(artificial neuron)와 그것들의 연결로 구성되어 있다. 신경회로망에 있어서 각각의 요소에 해당하는 뉴런과 입력, 그리고 그들을 상호 연결하는 연결강도 사이의 관계를 도식화한 것이 Fig. 2이다.

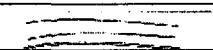
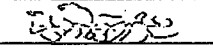
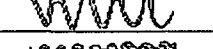
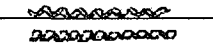


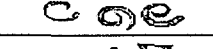

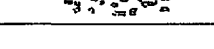
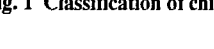
1		ribbon chips	unstable
2		tangled chips	
3		corkscrew chips	
4		helical chips	usable
5		long tubular chips	
6		short tubular chips	stable
7		spiral tubular chips	
8		spiral chips	
9		long comma chips	
10		short comma chips	

Fig. 1 Classification of chip pattern(INFOS)

그림에서 보인바와 같이 인공세포는 정보처리의 핵심인 인공신경세포와 기억의 핵심인 연결강도로 구성되어 있다.

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

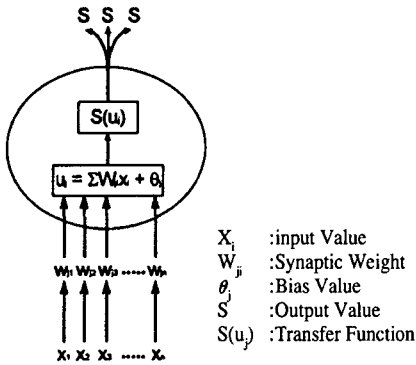


Fig. 2 Diagram of artificial neuron

만, 신경회로망에 있어서 뉴런은 Fig. 2와 같이 다른 인공 신경세포에서 전달된 출력값(X_i)에 연결강도(W_{ij})를 곱하여 단순히 산술적 합산에 의해 구하여진 총합(u_j)을 전달함수 $S(u_j)$ 에 입력한다. 입력에 대한 그 뉴런의 흥분이 클수록 뉴런의 출력 u_j 는 큰 값이 되고, 그 값을 다음의 뉴런으로 전달한다.

신경망의 흥분정도는 연결강도 W_{ij} 의 값에 따라 좌우되고, 신경망의 학습은 그 연결강도를 조정함으로써 행하여진다. 신경망의 각 계층들은 전후 층의 노드(Node)들과 연결되고 이 결합들의 가중치를 여러 학습알고리즘을 이용하여 결정한다.

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

입력된 데이터는 각 연결강도와 곱하여져 중간층, 출력층으로 입력되고 출력층에서 출력된 결과를 감독 데이터(Supervised Data)와 비교하여 그들 사이의 오차를 구하고 구하여진 오차를 최소화시킨다.

3. 칩 체류에 따른 복사온도계의 출력

3-1 실험장치 구성

본 실험에서는 시판되고 있는 적외선 복사온도계(Watlow 사)를 이용하였다. 이 온도계의 시야를 절삭시 칩이 머무르는 곳에 집적시키면 시야에 머무는 칩에서 발생하는 복사에너지를 대소를 측정할 수 있다. 이를 이용하면 칩의 양을 간접적으로 측정할 수 있게 되고 칩의 양을 통하여 칩의 형태를 인식할 수 있다.

실험장치는 Fig. 3처럼 온도출력용 인디케이터를 생략하고 적외선 온도센서의 전류출력 양단에 정밀저항을 걸




Fig. 3 Measurement system of emissivity energy

어 전압신호로 변환한 후 A/D 변환기가 내장된 컴퓨터에서 칩상태를 판별하도록 하였다.

3-2 선삭가공에서 칩 형태와 복사온도계의 출력

이 절에서는 선삭가공의 경우 이송량의 변화에 따른 복사온도계의 출력을 검토하였다. 실험장치 구성시 입사거리와 입사각도를 일정하게 하고 복사온도계를 절삭점 부근에 90°로 조사할 수 있도록 지지대를 공구홀더에 직접 용접하여 설치하였다

단 공구온도의 상승에 의해 복사온도계의 출력이 상승하는 것을 방지하기 위해 복사온도계의 시야 부분은 주로 피삭재 위로 유동하는 칩 부분으로 설정하였다. 복사온도계와 절삭점 사이의 거리가 약 230mm이므로 측정시야의 직경은 본 센서의 사양에 의하여 약 36mm가 된다.

Fig. 4는 다른 절삭조건을 일정하게 유지하고 이송량을 0.073에서 0.409mm/rev까지 세 가지로 변화시키면서 가공할 때 복사온도계의 출력을 나타낸 것이다. 보통의 3차원 선삭가공에서 칩의 형태에 가장 큰 영향을 미치는 조건이 이송량이다. 정상상태의 절삭에서 칩은 필연적으로 나선형이 되고 이 칩의 분절은 칩의 곡률반경에 의해 좌우된다. 곡률반경은 칩의 두께가 두꺼워 질수록 작아지는 경향을 띠는데 선삭에서는 이송량이 칩의 두께를 결정한다.

Fig. 4에 나타난 결과도 위의 조건을 만족시킨다. 이송량이 적어질수록 복사온도계의 출력이 증가하는 경향을 보이는데 이송량이 작은 0.073mm/rev에서는 연속형 칩(Fig. 1의 1, 2, 3)이 발생하였고 그 결과 칩이 절삭점 부근에서 엉키면서 복사온도계의 시야에 다량의 고온의 칩이 머물기 때문인 것으로 판단된다.

이송량이 0.314mm/rev에서는 분절형 칩(Fig. 1의 4,

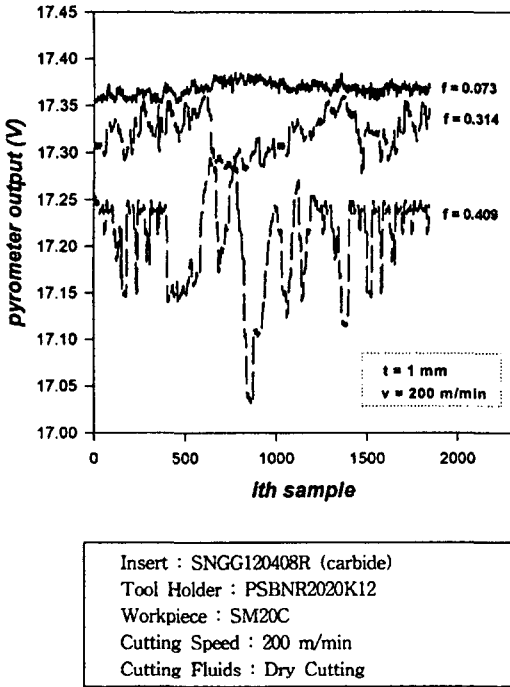


Fig. 4 Relationship between pyrometer output and chip pattern




Fig. 5 Photo of chip form

5)이 발생하여 이 결과 복사온도계의 시야에 머무는 칩의 양이 적어져 결과적으로 복사온도계의 출력이 줄어든 것으로 판단된다. 특히 이송량이 0.409mm/rev인 경우는 잘게 부서지는 칩(Fig. 1의 7, 8)이 발생되어 출력값이 적을 뿐 아니라 칩이 랜덤하게 비산하므로 다른 실험치에 비하여 결과의 편차가 커졌다.

즉, 실험결과 Fig. 5와 같이 0.073mm/rev의 이송에서는 unstable형 칩, 이송량 0.314mm/rev에서는 usable형 칩 그리고 이송량 0.409mm/rev에서는 stable형 칩이 발생하였다.

4. 신경망의 구성과 시뮬레이션

4-1 신경망의 구성

서론에서 기술한 것과 같이 절삭가공에 관련된 기존의 연구는 제한적인 가정 하에서 수학적 모델을 만드는 방법과 각종 센서신호를 고전적인 신호처리방법을 통하여 가공상태를 직접 예측하는 방법이 있다. 그러나 절삭현상은 매우 다양한 인자들의 영향을 받고, 각 인자들 사이의 정확한 인과관계를 규명하는 것이 불가능하므로 수학적 모델링기법이나 신호처리기법으로 절삭상태를 직접 예측하는 것은 매우 어려운 일이다.

이러한 이유로 최근에는 인공지능기법을 절삭가공에 빈번히 적용하고 있다. 제안되고 있는 인공지능기법의 대표적인 것으로 퍼지추론과 신경망기법이 있다. 퍼지추론은 전문가의 경험이나 실험을 통하여 퍼지규칙을 생성해야 하는 어려움이 존재하는데 비하여 신경망기법은 절삭에 전문가적 지식이 거의 없는 상태에서도 적용이 가능하고, 경향이 뚜렷한 패턴들로부터 학습을 통하여 가중치만 결정되면 학습의 과정에 사용되지 않은 유사한 입력패턴에 대하여 그 결과를 추정할 수 있도록 자기조직화(Self-Organization)하는 이점이 있다⁽⁸⁾.

신경망의 크기는 학습속도, 근사능력 등에 큰 영향을 미친다. 즉 신경망의 크기가 커지면 학습시간이 오래 걸리는 반면 근사능력이 향상되고, 계층의 수가 적어지면 학습속도가 빨라지나 분리성이 떨어진다.

적절한 신경망의 크기를 결정하기 위하여 노드 수와 계층 수를 변화시키면서 시뮬레이션을 행하였다. 이 결과 입력층-중간층-출력층의 노드 수가 6-10-10-3인 경우가 가장 우수한 근사능력을 나타내었다. 중간층의 개수나 각층의 노드 수를 줄이면 학습속도는 빨라지는 반면, 출력 오차가 커지고 이에 따라 칩 형태 인식결과도 칩의 형태가 급격히 변화되는 부분에서 부정확한 값이 생성되었다. 따라서 본 논문에서는 Fig. 6과 같이 6개의 입력 유닛을 가지는 입력층(Input Layer), 각각 10개의 유닛을 가지는 2개의 중간층(Hidden Layer), 3개의 유닛을 가지는 출력층으로 신경망을 구성한다.

입력데이터로 사용되는 데이터는 보통 각종 센서(Sensor)들의 출력나 이들의 분산 또는 RMS 값들이 사용된다⁽⁹⁻¹⁰⁾. 그러나 이러한 방법들은 센서들의 신호처리 과정이 복잡할뿐더러 많은 비용이 들게 되고, 실시간으로 데이터를 처리하는 데 어려움이 있다. 때문에 본 연구에서는 여섯 번의 샘플링 시간 동안 측정된 복사온도계의 출력값만을 입력 데이터로 사용한다.

샘플링시간은 칩의 절단주기보다도 짧아야 한다. 칩의

Input Layer Hidden Layer 1 Hidden Layer 2 Output Layer




Fig. 6 Architecture of neural network

절단주기가 가장 짧은 이송량 0.409mm/rev에서 초당 55회 정도 절단되므로 초당 약 60회 샘플링하여 칩의 절단주기보다도 짧게 하였다.

출력데이터는 Fig. 1의 칩 패턴분류에 사용되는 언어변수인 Stable, Usable, Unstable이 사용된다. 이 값들에 대한 출력값을 구한 다음, 가장 크기가 크게 나오는 변수의 상태로 칩의 형태를 인식하게 된다.

학습은 감독학습법에 의한 백프로파게이션 알고리즘을 이용하여 행하였고 오차를 줄이는 방법으로 오차의 제곱값을 줄이는 Delta Rule을 사용하였다. 또 전달함수는 시그모이드 함수를 사용하였다.

4-2. 감독 데이터와 학습조건

칩의 전형적인 형태에 대한 인식을 위하여 감독데이터는 Fig. 4에서 이송량이 0.073, 0.314, 0.409mm/rev 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 1에 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 때까지 수행하였다.

4-3 시뮬레이션과 실험에 의한 성능평가

선정된 감독데이터를 이용하여 백프로파게이션 알고리즘을 이용하여 신경망 프로그램을 작성한 후 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. 이 데이터들은 신경망이 학습에 주어진 감독 데이터 이외의 유사한 패턴에 대하여 얼마나 정확히 회상을 하느냐에 대한 결과를 나타낸 것이다.

두 가지의 칩형태에 대한 입력이 섞이는 경우에는 상당히 큰 오차를 발생하지만 최대값으로 인식을 하므로 인식 결과는 실제결과에 상당히 근접하는 값을 출력한다. 그러므로 신경망 시뮬레이터는 주어지지 않은 패턴에 대하여

Table 1 Supervised data for learning

Input Pattern						Desired Output			Result
x_{n-5}^t	x_{n-4}^t	x_{n-3}^t	x_{n-2}^t	x_{n-1}^t	x_n^t	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
$x_{i,n-5}$	$x_{i,n-4}$	$x_{i,n-3}$	$x_{i,n-2}$	$x_{i,n-1}$	$x_{i,n}$	ST	US	UST		
1.157	1.084	1.088	1.087	1.085	1.085	0	0	1	Unstable	Unstable
0.860	0.863	0.863	0.864	0.866	0.872	0	0	1	Unstable	Unstable
0.704	0.703	0.702	0.699	0.700	0.703	0	0	1	Unstable	Unstable
0.687	0.681	0.676	0.671	0.668	0.661	0	0	1	Unstable	Unstable
0.510	0.510	0.509	0.507	0.506	0.508	0	0	1	Unstable	Unstable
0.310	0.317	0.332	0.349	0.361	0.369	0.24	0.80	0	Usable	Usable
0.305	0.311	0.313	0.310	0.290	0.313	0.01	0.99	0	Usable	Usable
0.297	0.304	0.308	0.305	0.302	0.302	0.01	1	0	Usable	Usable
0.330	0.335	0.338	0.341	0.345	0.344	0.09	0.91	0	Usable	Usable
0.282	0.283	0.283	0.284	0.286	0.287	0.03	0.99	0	Usable	Usable
0.284	0.280	0.278	0.217	0.220	0.217	0.91	0.16	0	Stable	Stable
0.154	0.235	0.281	0.188	0.182	0.165	0.95	0.15	0	Stable	Stable
0.089	0.093	0.096	0.099	0.103	0.103	1	0	0	Stable	Stable
-0.007	-0.011	-0.013	-0.011	-0.009	-0.008	1	0	0	Stable	Stable
-0.171	-0.171	-0.171	-0.172	-0.172	-0.172	1	0	0	Stable	Stable

ST:stable, US:usable, UST:unstable

서도 우수한 적응성을 가짐을 확인할 수 있다.

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

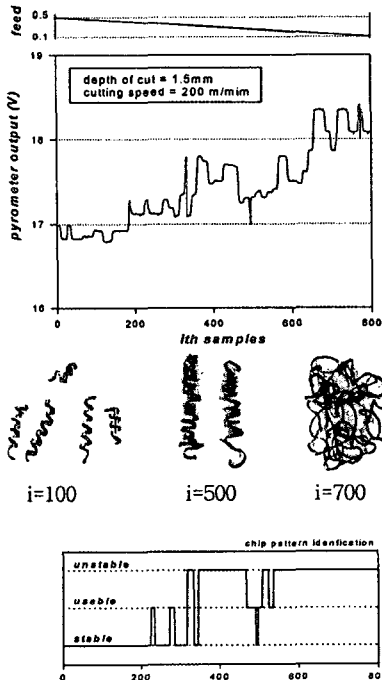


Fig. 7 Pyrometer output and chip pattern in feed change

위의 Fig. 7은 이송량을 0.5에서 0.1mm/rev까지 연속적으로 변화시키면서 인식기의 출력결과를 그래프로 나타낸 것이다. 실험에서 생성된 칩의 형태가 생성된 칩에 따른 복사온도계의 출력으로 인식된 결과가 생성되는 칩의 형태에 적절히 수렴하여 비교적 올바른 결과가 출력되는 것을 보이고 있다. 그림에서 복사온도계의 출력이 급격히 떨어지는 부분에서 잉킨 칩이 떨어져 나가므로 새로운 칩이 잉킬 때까지 인식기가 stable한 칩으로 인식함을 보인다.

다음의 Fig. 8은 테이퍼 가공된 소재를 가공하여 절삭깊이가 0.2에서 1.2mm까지 변화할 때, 절삭깊이의 변화에 따른 복사온도계의 출력값과 인식기의 인식결과를 그래프로 나타낸 것이다. 절삭과정의 대부분에서 Fig. 1의 6, 7, 8번에 해당하는 칩이 발생하였고 인식결과도 위의 사실과 정확히 일치함을 볼 수 있다. 그러나 Fig. 8에서 보인 바와 같이 절삭깊이가 1mm 부근에서는 usable로 인식한다.

이것은 실제 실험에서 가공조건이 결정되면 항상 같은 형태의 칩이 발생하지는 않는다. 감독데이터로 사용된 이송량 0.314mm/rev, 절삭깊이 1mm에서는 usable 형태의 칩이 발생하였고, 성능평가에 사용된 절삭깊이가 변

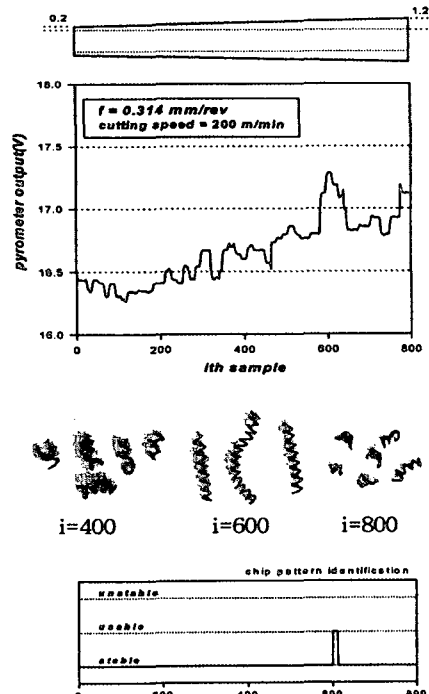


Fig. 8 Pyrometer output and chip pattern in change of depth of cut

화하는 경우에는 대부분의 구간에서 stable 형태의 칩이 생성되었지만 1mm 부근에서는 usable 형태의 칩이 생성되었다. 인식기에서도 생성되는 칩의 형태를 정확하게 인식하였다.

5. 결 론

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

- [1] 복사온도계의 출력을 신경회로망에 응용하여 칩 형태를 인식하는 시뮬레이터를 개발하였다.
- [2] 각 절삭과정에서의 실제 출력데이터를 이용하여 학습을 행함으로써 실시간 제어 시스템의 가능성을 확인할 수 있었다.

참 고 문 헌

1. 新井, 切りくず處理の基礎と應用, 日刊工業新聞社, 1990.
2. W.Kluft, W.K nig, C.A. van Luttervelt, K. Nakayama, A.J. Pekelharing, "Present Knowledge of Chip Control," Annals of the CIRP Vol. 28, No. 2, pp. 441-455, 1979.
3. 新井 實, 中山一雄, 塚田康夫, 加賀美信明 "放射溫度計による切りくず排出狀態の監視," 精密機械,

- 51卷, 4號, pp. 123-127, 1985.
4. K.Y. Yee, D.S. Blomquist, D.A. Dornfeld, C.S. Pan, "An Acoustic Emission Chip-Form Monitor for Single-Point Turning," Mach. Tool Des. Res. Conference, Proc. of the 26th. intl., pp. 305-311, 1986.
5. 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.
6. 백인환 외 3인, "방사온도계에 의한 칩 형태 인식," 한국정밀공학회, 제 13권, 제7호, pp. 59-65, 1996.
7. Sawai Sukvittayawong, Ichiro Inasaki, "Idenfication of Chip Form in Turning Process," JSME Vol. 34, No. 4, pp. 553-560, 1991.
8. 金大洙, 신경망의 이론과 응용(I), 하이테크정보, 1989.
9. D. Dornfeld, "Neural Network Sensor Fusion for Tool Condition Monitoring," Annals of the CIRP, Vol. 39, No. 1, pp. 101-105, 1990.
10. 森脇俊道 外 1人, "ニューラルネットワークを用いた切削狀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.