

본 연구는 부산대학교 정밀정형 및 금형가공 연구센터를 통한 한국과학재단 우수센터 지원금에 의한 것입니다.

## 시계열 모델과 상관차원 해석을 통한 공구수명의 감시

김정석\*, 이득우\*, 강명창\*\*, 최성필\*\*\*

### Monitoring of Tool Life through AR Model and Correlation Dimension Analysis

Jeong-Suk Kim\*, Deuk-Woo Lee\*, Myeong-Chang Kang\*\*, Sung-Pil Choi\*\*\*

#### ABSTRACT

Recently, monitoring of tool life is a matter of common interesting because tool life affects precision, productivity and cost in machining process. Especially flank wear has a direct effect on cutting mechanism, so the various pattern of cutting force is obtained experimentally according to variation of wear condition.

By investigating cutting force signal, AR(Autoregressive) modeling and correlation dimension analysis is conducted in turning operation. In this modeling and analysis, we extract features through 6th AR model, correlation integral and normalized correlation integral. After the back-propagation model of the neural network is utilized to monitor tool life according to flank wear.

As a result, a very reliable classification of tool life was obtained.

**Key Words** : Tool Life Monitoring(공구수명 감시), Force Signal(절삭력 신호), AR Model(시계열 모델), Correlation Dimension Analysis(상관차원 해석), Normalized Correlation Integral(노말라이징 인자), Neural Network(신경회로망)

#### 1. 서론

최근 생산분야에서의 기술발달은 기계가공의 정밀도 향상, 자동화 공작기계의 개발로 이루어지고 있으며 이러한 목적을 이루기 위한 기본기술로서 가공중 발생하는 공작기계의 상태진단 및 공구의 이상상태 감시 등에 대한 연구가 활발히 진행중이다. 특히 공구파손·마멸과 같은 공구 이상상태는 가공품의 품질 및 정밀도를 떨어뜨리고 공

구와 공작기계의 손실을 초래하여 전체공정의 저생산성과 고생산비를 발생시킨다.

공구마멸의 감시방법은 크게 두가지로 나눌 수 있다. 하나는 절삭공구의 형상변화를 직접 측정하는 방법으로 CCD 카메라나 레이저 등을 이용한 광학적인 방법이 이용된다.<sup>(1)</sup> 이 방법은 측정장비가 비싸고 장치가 복잡하여 실제 공정에서의 이용에 많은 제약이 따른다. 다른 하나는 절삭과정중에 발생하는 물리적인 파라메타를 이용하는

\* 부산대 기계공학부/정밀정형 및 금형가공 연구센터  
\*\* 부산대 기계기술연구소  
\*\*\* 대한중석초경(주)공구연구개발실

간접적 방법인데 이 중 절삭력을 이용한 간접적 방법에 관한 연구가 상대적으로 많이 행해지고 있다. 이는 절삭력이 상대적으로 측정하기 쉬운 파라메타중의 하나이기 때문이다. 이러한 연구중에는 주로 절삭력의 정적성분의 크기를 이용하여 마멸의 증가에 따른 절삭분력의 증감에 관한 연구가 주로 행해졌는데<sup>(2,3,4)</sup> 절삭력이 시편이나 공구, 절삭조건에 따라 변화가 크기 때문에 실제공정에서의 이용은 극히 제한적이다. 이 외에는 절삭력의 스펙트럼 분석<sup>(5)</sup>이나 절삭력신호의 패턴을 인식하는 방법<sup>(6)</sup>을 이용한 공구마멸의 감시에 관한 연구가 행해지고 있다.

일반적으로 센서를 이용한 감시시스템은 가공상태에 대한 정보를 가지고 있는 신호를 검출하는 감시신호검출부, 특정한 가공상태에 민감한 특징을 추출하는 신호처리부, 추출된 특징을 이용하여 가공상태를 진단하는 진단부로 구성된다.

본 연구에서는 공구동력계를 이용하여 절삭력 신호를 검출하고, 이를 시계열 모델(Time series model)을 이용하여 6차의 AR 모델링 한 후 AR 계수를 특징으로 추출한다. 또한 새로이 제안하고자 하는 상관차원 해석(Correlation dimension analysis)을 통하여 해석과정에서 구할 수 있는 상관적분계수와 노말라이징 인자를 특징으로 추출한다. 그리고 최종적으로는 이들을 이용하여 각각의 신경회로망(Neural network)을 구성하여 공구 수명을 감시하고자 한다.

## 2. AR 모형과 상관차원 이론

### 2.1 AR 모형을 이용한 AR 계수 추정

동적 시스템을 수학적으로 모델링하여 어떤 특정순간에 변하는 물성치를 계산하는 것은 때때로 가능하지만 불가능한 경우가 대부분이다. 따라서 통계적 모델을 이용하여 동적 시스템을 묘사하게 되는데 이러한 방법중의 하나가 시계열 해석법이다.

시계열 모형은 해석방법에 따라 AR 모형, MA 모형, ARMA 모형 등으로 수립할 수 있으나 동적 시스템은 시간에 따라 빠르게 변화하므로 실시간적으로 응용하고자 한다면 이산적으로 획득한 센서 신호가 순간적 시스템 동력계에 적용되도록 모델링 되어야 한다.

센서신호를 AR 모델로 특성화 하면 신호의 모델 파라메타는 각 센서의 발생 메카니즘의 변화에 따른 신호의 변화에 따라 계속적으로 개선되고 결국 이러한 시변 파라메타들이 절삭공구 마멸조건에 대한 정보를 가지게 된다.

2.1.1 순차형 최소자승법을 이용한 AR 모델의 추정  
주어진 시계열 데이터를 자기회귀 모델(Autoregressive model, AR 모델)화 하면 이산시간 신호  $y(k)$  ( $k = 0, 1, \dots, N-1$ )에서 추정치의 현재값은 N개의 이전값들의 선형결합으로 표현된다.<sup>(7)</sup>

$$\overline{y(k)} = n(k) + \sum_{i=1}^N a_i(k) y(k-i) \quad (1)$$

여기서

$n(k)$ : 백색잡음(white noise),

$a^T(k) = [a_1(k), a_2(k) \dots a_N(k)]$ : AR 계수,

$y^T(k) = [y_1(k), y(k-i) \dots y(k-N)]$ : 시계열 벡터

여기서 백색잡음  $n(k)$ 는 모르는 값이므로 현재의 측정값  $y(k)$ 와 한단계 이전의 모델식에 의하여 예측된 값사이의 오차  $e(k)$  ( $e(k) = y(k) - \overline{y(k)}$ )의 제곱합을 최소화하여 계수  $a_1 \sim a_n$ 를 결정한다.

오차  $e(k)$ 를 최소화 하기위해 순차형 최소자승법(Recursive least square method)을 쓰면 최소화된 평가함수  $J$ 는 다음과 같다.

$$J = \sum_{k=n}^{N-1} \{y(k) + a_1 y(k-1) + \dots + a_n y(k-n)\}^2 \quad (2)$$

가 되고 알고리즘은 다음과 같이 모델링된다.

$$\overline{a(k)} = \overline{a(k-1)} - \frac{\{P(k)z(k)z(k)\overline{a(k-1)} - z(k)y(k)\}}{\lambda(k)} \quad (3)$$

$$P(k) = \frac{\{P(k-1) - P(k-1)z(k)(\lambda(k) + z(k)P(k-1)z(k))^{-1}z(k)P(k-1)\}}{\lambda(k)} \quad (4)$$

여기서 AR 파라메타 벡터  $\overline{a(k)}$ 와 과거의 관측 데이터 벡터  $z(k)$ 는 다음과 같이 나타낼 수 있다.

$$\overline{a(k)} = (-a_1(k), -a_2(k), \dots, -a_n(k))$$

$$z(k) = (y(k-1), y(k-2), \dots, y(k-n))$$

이때 망각계수(Forgetting factor)  $\lambda(k)$ 가 주어져 수렴속도를 증가시키는데  $\lambda(k)$ 는  $0 < \lambda(k) \leq 1$  을 만족시키는 스칼라 양으로 다음과 같다.

$$\lambda(i) = \lambda \cdot (i-1) + (1-\lambda) \quad (5)$$

여기서 망각률인  $\lambda$ 와 초기값  $\lambda_0$ 는 임의 선택되는데  $\lambda = 0.99$ ,  $\lambda_0 = 0.95$ 로 선택하였다. 그리고 공분산은  $P_0 = \alpha I$  초기화 하는데,  $\alpha$ 는 충분히 큰 값으로서 오차의 초기 신뢰값을 결정하는데 영향을 미치고 수렴속도를 결정하는 정수값으로 여기서는 1000으로 선정하였다.

이러한 초기값들은 수렴율이나 모델계수의 안정성에 영향을 미치는데 이들의 선택에 따라 모델이 달라지게 된다.

### 2.1.2 AR 모델의 적용가능성

후향 시간이동 연산자(Backward time shift operator)  $q^{-i}$ 를  $y(k-i) = q^{-i}y(k)$ 로 정의하면 AR 시계열 모델은 다음과 같이 주어질 수 있다.

$$y(k) = \frac{1}{1 - \sum_{i=1}^N a_i(k)q^{-i}} n(k) = G(q^{-i})n(k) \quad (6)$$

여기서  $G(q^{-i})$ 의 특성근을  $\lambda_i (i=1 \dots N)$ 이라 하면 다음 식과 같이 둘 수 있다.

$$y(k) = \frac{1}{1 - \prod_{i=1}^N (1 - \lambda_i(k)q^{-1})} n(k) \quad (7)$$

두 식 (6)과 (7)을 비교하면 AR계수가 다음과 같이 얻어진다.

$$a_1 = \sum_{i=1}^N \lambda_i, a_2 = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j = \lambda_i^2, \dots, a_N = \prod_{i=1}^N \lambda_i$$

즉 AR 계수가 입력  $n(k)$ , 출력  $y(k)$ 에 대한 특성근의 함수이므로 공구마멸에 따른 출력신호가 바뀌면 계수가 바뀌므로 공구마멸을 추적할 수 있다.

## 2.2 상관 차원 해석

### 2.2.1 프랙탈 차원의 정의 및 종류

프랙탈(Fractal) 혹은 프랙탈 차원(Fractal dimension)은 불규칙성의 정도를 나타내는 것으로 어떤 물체의 거칠거칠한 정도, 혹은 부서진 정도 혹은 불규칙한 정도를 정량화하는 방법이다. 예를 들면 꼬불꼬불한 해안선은 길이 관점에서는 측정이 불가능하지만 들쭉날쭉한 정도에서는 어떤 특성을 가지고 있다. 이러한 정도는 소수차원으로 나타난다.

이러한 해석은 카오스적(Chaos) 현상을 나타내는 비선형계의 비선형정도를 나타내기 위한 방법으로 연구되기 시작하였으며, 어떤 계의 정보를 담고있는 센서신호로부터 특징을 추출하기 위한 방법으로 응용할 수 있다.

프랙탈 차원의 계산방법은 제한한 사람이나 적용대상 그리고 계산상의 알고리즘에 따라 여러 가지가 있으나,<sup>(8-10)</sup> 이 중에서 상관 차원(Correlation dimension)은 다른 차원에 비해 비교적 간단한 알고리즘으로 계산이 가능하고 시계열 벡터에의 응용이 쉬워 센서신호에의 응용이 용이하다.

### 2.2.2 상관 차원의 수학적 알고리즘

프랙탈 차원 중 상관 차원을 구하는 수학적 알고리즘은 다음과 같다.

시계열 데이터로부터 n차원의 벡터  $X_j$ 를 구성한다.

$$X_j = \{X(t_i), X(t_{i+1}), \dots, X(t_{i+n-1})\} \quad (8)$$

여기서 임의의 2개의 벡터의 거리  $|X_i - X_j|$ 가 r 이하가 되면 상관 적분계수(Correlation integral)  $C(r)$ 을 계산하게 되는데, 이렇게 만든 N종류의 샘플에 대한 상관적분계수의 계산식은 다음과 같다.

$$C(r) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N H(r - |X_i - X_j|) \quad (9)$$

여기서  $H(x)$ 는 헤비사이드 계단 함수(Heaviside step function)로서 다음과 같이 계산된다.

$$r \geq |X_i - X_j| = 1$$

$$r < |X_i - X_j| = 0$$

그리고 상관차원은 상관적분계수  $C(r)$ 이  $r^d$ 에 비례할 때 그 지수 d가 상관 차원이 된다. 즉 상관 차원 d는 다음과 같이 정의된다.

$$d = \frac{\log(c(r_2)) - \log(c(r_1))}{\log(r_2) - \log(r_1)} \quad (10)$$

## 3. 실험장치의 구성 및 실험

### 3.1 실험장치

절차력 신호를 이용한 공구수명의 감시 가능성을 파악




Fig. 1 Schematic diagram of experimental set-up

Table 1 Specification of Experimental Apparatus

Instruments	Model	Maker
Lathe	HML - 580	HanKook Lathe
Dynamometer	Type 9257B	Kistler
Charge Amplifier	Type 5007	Kistler
A/D Converter	PCL - 718	Advantech
Tool Holder	PSDNN 2525	Korea Tungsten
Insert Tip	SNMA 120408	Korea Tungsten

하기 위한 실험장치를 Fig. 1과 같이 구성하고 실험에 사용한 장비들은 Table 1에 나타내었다.

절삭실험은 무단변속 선반에서 절삭속도를 일정하게 하기 위해서 시편의 반경에 따른 회전수를 조절하며 행하였고, 공작물은 탄소강(SM45C)을 사용했다. 공구는 P10 계열의 초경공구를 사용하였다.

### 3.2 실험방법

실험은 공구동력계를 이용하여 3분력 방향의 절삭력을 전하증폭기를 통해서 A/D 변환기로 입력한 후, 2초간의 데이터를 1 msec로 샘플링하여 2000개를 받아 PC에 저장하였다.

실험의 양과 시간을 줄이기 위해 인위적으로 어느정도 마멸을 준 팁과 가공을 하지 않은 팁을 사용하여 각각 테

이터를 입력받았다. 마멸은 경사면 마멸보다는 여유면 마멸이 많이 발생하는 낮은 절삭속도에서 마멸을 주었는데, 절삭속도 100 m/min, 이송량 0.1 mm/rev에서 연속적인 가공을 하여 마멸을 주었고, 공구수명의 기준을 ISO 규정에 의하여 여유면 마멸을 0.3mm로 정하였다.

절삭조건은 일반적으로 사용하는 조건을 정하였는데, 절삭속도와 이송량의 변화에 따라 특성을 파악하고자 하였다. 절삭깊이는 가공후의 공구마멸을 일정한 기준으로 파악하기 위해 한가지로 고정시켰다.

본 실험에서 사용한 절삭조건은 Table 2와 같고 건식 절삭을 행하였다.

Table 2 Cutting Conditions

Cutting Speed [m/min]	100, 120, 140, 160
Feed Rate [mm/rev]	0.06, 0.08, 0.1, 0.12, 0.15
Width of Cut [mm]	1.0

## 4. 특징추출 및 패턴인식의 결과

### 4.1 AR 모델을 이용한 특징추출

가공중에 발생하는 절삭력 신호는 가공에 관한 정보를 담고 있다. 이 신호를 시계열 모형 중의 하나인 AR 모형으로 모델링하면 가공의 진행 및 상태에 관한 정보를 얻을 수 있다.

AR 모델의 결정시 고려하여야 할 중요한 인자는 앞에서 설명한 망각률  $\lambda$ , 공분산  $P_0$  및 망각계수  $\lambda_0$ 의 초기치 결정이다. 그리고 모델의 결정시 고려하여야 할 중요한 것이 모델차수의 결정인데, 이는 정확한 모델과 수렴시간에 관계하는 어려운 문제이다. 즉 계산시간의 문제에 있

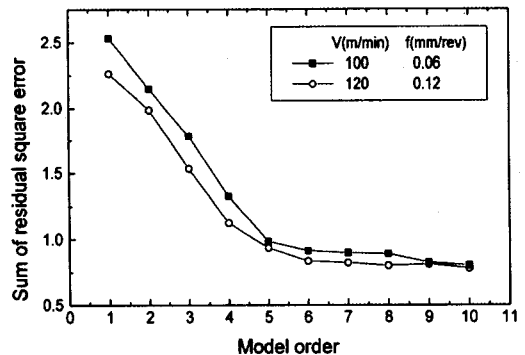


Fig. 2 Sum of residual square error according to model order

어서는 낮은 차수가 유리하고, 정확한 모델을 위해서는 높은 차수가 유리하게 된다. 그러나 Fig. 2에서 보는 바와 같이 순차형 최소자승법을 이용한 AR 모델에서 6차 이상의 모델에서는 뚜렷한 오차의 감소를 볼 수 없었다.

따라서 본 연구에서는 6차의 AR 모델로 결정하였다.


Fig. 3(a)는 6차 AR 모델로 모델링하였을 때 예측한 신호와 실험으로 측정된 신호를 비교하였다. 이때의 전체 샘플링데이터에 대한 오차를 Fig. 3(b)에 보였는데 데이터 개수가 증가할수록 오차가 줄어들어 순차형 최소자승법의 장점인 데이터의 증가에 따른 모델 계수의 안정화를 볼 수 있다.

여기서 AR 계수는 공구마멸에 관한 정보를 담고 있는 특징이 되고 이를 통하여 공구마멸의 진행에 따른 정보를 추출할 수 있다. 6차 AR 모델에서의 여유면 마멸에 대한 변화를 Fig. 4(a)~(b)에 나타내었다. Fig. 4(a)에서 AR 계수값은 전체 1024개의 데이터를 적용시킨 후의 최


종 값을 나타낸 것이다. 그림에서 보는 바와 같이 새로운 공구와 여유면 마멸량이 0.3mm일 때, AR 계수값은 1, 2, 3차에서 변화가 크게 나타남을 알 수 있다. 또한 Fig. 4(b)는 AR 계수값의 가공시간의 증가(공구마멸의 진전)에 따른 변화를 나타낸 것으로, 가공시간의 진행에 따라 1, 2, 3차 AR 계수값은 변화의 경향이 일정하나, 4, 5, 6차에서는 불규칙한 변화를 보인다. 따라서, 이러한 특징으로부터 신경회로망의 입력변수로서 1, 2, 3차의 AR 계수값이 유효함을 알 수 있다.

4.2 상관적분계수를 이용한 특징추출

Fig. 5(a), (b)에 마멸이 되지 않았을 때와 여유면 마멸이 0.3mm가 진행되었을 때의 주분력 신호를 나타내었다. 질삭 3분력 신호를 이용하여 상관차원을 구하기 위해 각 분력이 축이 되는 3차원 공간좌표를 형성하여 상관차원을 구하였다. 여기서 각 데이터 획득시간에서의 주분력

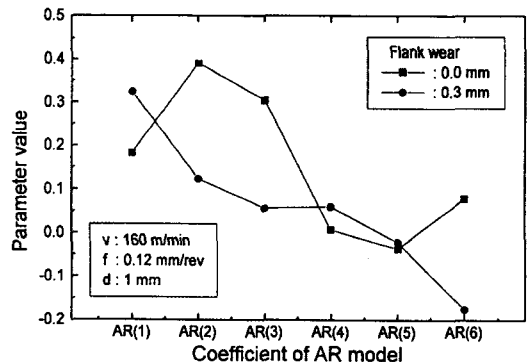


(a) Principal force signal using AR(6) model

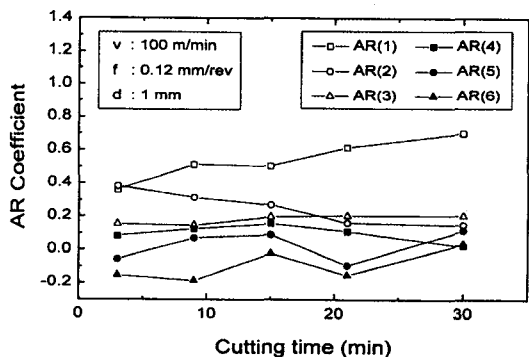


(b) residual error signal

Fig. 3 Residual error signal of principal force using AR(6) model

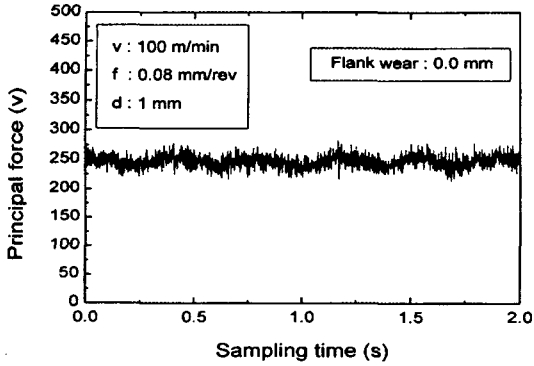


(a) AR parameter in the new and worn tool




(b) AR parameter according to cutting time


Fig. 4 Variation of AR parameter according to flank wear



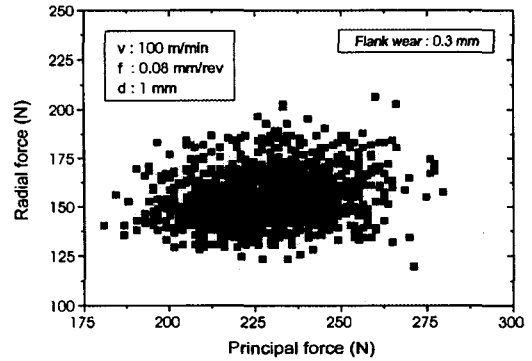
(a) principal force in flank wear 0 mm



(a) force distribution in flank wear 0 mm



(b) principal force in flank wear 0.3 mm



(b) force distribution in flank wear 0.3 mm

Fig. 5 Signal of principal force according to variation of flank wear

Fig. 6 Distribution of principal and radial force according to flank wear

$F_p$ , 배분력  $F_r$ , 이송분력  $F_f$  로 구성된 신호가 하나의 벡터를 형성한다. Fig. 6(a), (b)는 그 결과를 그래프로 보이기 위하여 주분력과 배분력을 축으로하는 2차원 좌표를 구성하여 절삭력의 분포를 나타낸 것이다. 공구마멸이 되었을 때의 분포가 넓게 퍼져 공구마멸이 진행되었을 때의 절삭력신호의 변동이 심한 것을 볼 수 있다.

이렇게 구한 절삭력 벡터에서 식 (9)에 따른 계산을 하면 거리  $r$ 의 변화에 따른 상관 적분계수를 구할 수 있게 되고 여기서 상관 차원은 대수좌표계 상에 나타나는  $r$ 의 변화에 따른 상관 적분계수의 기울기가 된다. Fig. 7은 거리  $r$ 의 변화에 따른 상관적분계수의 변화를 나타낸 것이고 이를 Table 3에 나타내었는데 이에 따라 계산된 상관 차원은 여유면 마멸이 0mm일 때 3.29이고 여유면 마멸이 0.3mm일 때 3.32로 구해진다.

그러나 상관차원 해석 중에 계산되는 상관적분계수는 각 조건에서의 여유면 마멸에 따른 값의 차이가 커서 특

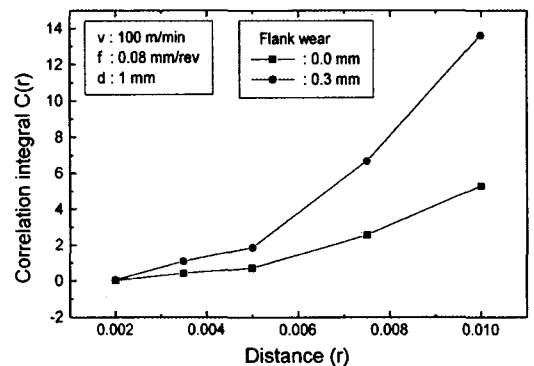


Fig. 7 Variation of correlation integral according to flank wear

징으로 추출할 수 있으나 절삭조건에 따른 값의 차이도 크게 나타나는 것을 알 수 있다. 이는 본 연구에서 실험한 절삭조건에서 절삭속도와 이송량이 증가함에 따라 가공이 안정화되어 절삭력의 진폭이 작아지기 때문이다.


**Table 3** The variation of C(r) and Log(C(r)) according to flank wear  
(Cutting condition : V=100 m/min, f=0.08 mm/rev, d=1 mm)

r	C(r)		Log(r)	Log(C(r))	
	(VB:0mm)	(VB:0.3mm)		(VB:0mm)	(VB:0.3mm)
0.0020	0.057	0.021	-2.699	-1.254	-1.688
0.0035	1.088	0.414	-2.456	0.037	-0.383
0.0050	1.875	0.720	-2.301	0.273	-0.143
0.0075	6.698	2.571	-2.125	0.826	0.410
0.0100	13.612	5.302	-2.000	1.134	0.724

따라서 식 (11)과 같이 절삭속도와 이송량의 변화에 따라 차이가 나는 부분을 줄이기 위해 아래와 같이 노말라이징하여 이 값을 신경회로망에 입력시켰고, 이를 노말라이징 인자(Normalized correlation integral)  $Inp(r)$ 로 정의하였다.

$$Inp(r) = \frac{C(r) \times V \times f}{100} \quad (11)$$


이러한 방법을 통해 Fig. 7에서 보인 상관적분계수에 대한 노말라이징 인자  $Inp(r)$ 값을 Fig. 8에 보였는데 상관적분계수의 값이 절삭속도 100(m/min), 이송량 0.06(mm/rev)에서 마멸에 따른 값의 차이가 r이 0.01 일 때 15.846과 6.253이고, 절삭속도가 160(m/min), 이송량 0.15(mm/rev)에서는 2.738과 1.508인데 식 (11)을 이용하여 노말라이징 한 후의 값의 차이가 0.951과 0.254, 그리고 0.636과 0.390으로 나타나 절삭조건에 따른 변화에 따른 값의 차이가 줄어들었음을 알 수 있다.



**Fig. 8** Variation of normalized correlation integral according to flank wear

따라서 노말라이징 인자를 이용하여 특징을 추출한 후 신경회로망에 학습시켰다.

Fig. 9는 노말라이징 인자의 가공시간의 증가에 따른 변화를 나타낸 것으로 여유면 마멸이 0.3 mm가 될 때까지 가공을 한 것이다. 공구마멸이 진전됨에 따라 노말라이징 인자가 선형적으로 감소하여 절삭 3분력의 진폭이 차츰 증가함을 보여주고 있다.



**Fig. 9** Variation of normalized correlation integral with respect to cutting time

### 4.3 신경회로망의 구성 및 인식 결과

공구마멸의 진전에 따른 수명감시에 신경회로망을 이용하는 이유는 뚜렷하지 않은 추출 파라메타들 사이의 관계로부터 효과적인 정보를 얻기 위해서이다.

앞에서 언급한 바와 같은 특징인자들로부터 공구마멸을 감시하기 위해 신경회로망을 이용하였다. 신경회로망 프로그램은 상용 프로그램인 Neural Networks Professional II를 이용하였다. 이 때 각 층간의 연결강도를 조절하는데 출력층 뉴런으로부터 하위층으로 오차를 역전파하여 조절하는 역전파법(Back propagation)을 사용하였고, 각 뉴런간의 전달함수로는 시그모이드 함수를 이용하여 감독학습시키는 신경회로망을 구성하여 추출한 데이터를 학습시켰다.

#### 4.3.1 AR 계수를 이용한 인식 결과

먼저 앞에서 추출한 AR 계수를 이용한 공구마멸의 감시를 위해, 입력층에는 절삭조건(절삭속도와 이송량)과 6개의 AR 계수를 입력시키는 8개의 노드를 두고 은닉층에는 9개, 그리고 출력층에는 1개의 노드를 두어 8-9-1의 신경회로망을 구성하였다. 출력층에서는 공구수명이 되었을 때 <1>을 출력하고, 수명이 되지 않았을 때 <0>을

출력하도록 학습시켰다. 학습 데이터는 20개의 가공조건에 대한 데이터의 2배를 주어 총 80개의 데이터를 학습시켰다. 그리고 신경회로망의 인식여부를 확인하기 위해 학습한 80개의 데이터와 학습하지 않은 데이터 160개를 함께 적용시켜 총 240개의 데이터를 적용시켰다. 그 결과를 Fig. 10에 나타내었는데 대체적으로 잘 인식함을 알 수 있다. 이때 출력력 0.5를 기준으로 마멸여부를 판단할 때 91.7%의 인식율을 보이고 있다. 여기서 데이터수 0~40은 학습시킨 데이터이고 41~120은 학습시키지 않은 데이터인데, 학습을 시키지 않은 데이터에서는 오인식이 많아지는 것을 볼 수 있다.




Fig. 10 Recognition result of neural network using AR parameter (1st~6th order)

여기서 Fig. 4(a)~(b)에 보인바와 같이 여유면 마멸에 따른 AR 계수의 변화가 특히 1, 2, 3차 계수에서 크게 나타났다. 따라서 AR 계수중 1, 2, 3차 계수와 절삭조건(절삭속도와 이송량)을 사용하여 5-6-1의 신경회로망을 구성하여 학습시켰을 때의 결과는 인식율이 87%로 6개의 AR 계수를 사용했을 때보다는 인식율이 떨어지나, 대체적으로 잘 인식하고 있으며 이로부터 1, 2, 3차 계수만으로도 공구마멸의 감사가 가능함을 알 수 있다.

#### 4.3.2 노말라이징 인자를 이용한 인식 결과

식 (11)에서 정의한 노말라이징 인자  $Inp(r)$  및 절삭속도와 이송량을 입력으로 하는 5-8-1의 신경회로망을 구성하여 앞선 방법과 유사한 과정으로 학습시킨 후 적용 여부를 확인해 보았다. 그 결과를 Fig. 11에 보이고 있는데, 역시 잘 인식함을 알 수 있으나 AR 계수를 이용한 신경회로망에는 성능이 미치지 못함을 알 수 있다. 이 때의 인식율은 85%이었다. 여기서 Fig. 8에서 보인 바와 같

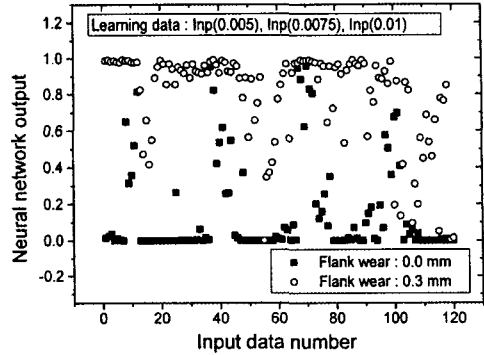


Fig. 11 Recognition result of neural network using normalized correlation integral  $Inp(0.05, 0.0075, 0.01)$

이  $r$ 이 커질수록 공구마멸에 따른 값의 차이가 커진다. 따라서 노말라이징 인자 중에서는  $r$ 이 0.005, 0.0075, 0.01일 때의 값으로만 학습시켰다.

#### 4.3.3 AR 계수와 노말라이징 인자를 동시에 사용한 인식 결과

앞선 실험에서 신경회로망이 인식하지 못한 데이터의 조건을 검토해 본 결과 AR 계수를 이용한 신경회로망에서는 이송량이 0.06 mm/rev일 때와 0.08 mm/rev일 때가 대부분을 차지한 반면 노말라이징 인자를 이용한 신경회로망에서는 이송량이 큰 0.12 mm/rev일 때와 0.15 mm/rev일 때가 대부분을 차지하고 있었다. 이러한 각 신경회로망에서의 단점을 보완하기 위해, 추출한 두가지 특징을 복합하여 Fig. 12와 같이 신경회로망을 구성하였




Fig. 12 Architecture of neural network when input data is AR parameter and normalized correlation integral



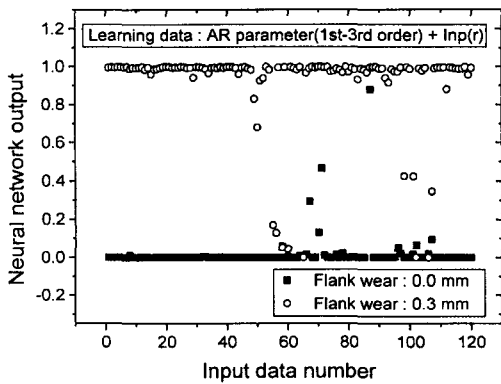


Fig. 13 Recognition result of neural network using AR parameter and normalized correlation integral

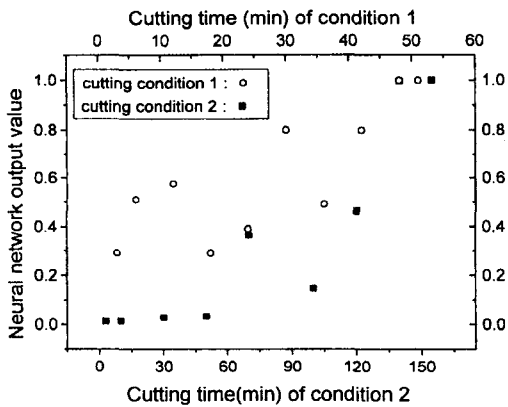


Fig. 14 Recognition result of neural network according to progress of flank wear and each cutting condition (condition 1 : V=160m/min, f=0.15mm/rev, d=1mm condition 2 : V=100m/min, f=0.10mm/rev, d=1mm)

다. 이 때의 입력 데이터로 AR 계수중에서는 1, 2, 3차 계수를 선택하였고 노말라이징 인자 중에서는 r이 0.005, 0.0075, 0.01일 때의 값을 선택하였다.

그 결과를 Fig. 13에 나타내었는데 앞선 두 경우에 비해 인식율이 크게 증가하여 인식율이 95%가 됨을 볼 수 있으며 이로부터 노말라이징 인자와 AR 계수를 복합한 신경회로망이 AR 계수만을 이용한 신경회로망보다 인식률이 좋아 공구마멸의 감지에 있어 신뢰성을 향상시킬 수 있음을 보여주고 있다.

그리고 공구마멸의 진전에 따른 인식여부를 알아보기 위해, 절삭속도 100 m/min, 이송량 0.1 mm/rev일 때와 절삭속도 160 m/min, 이송량 0.15 mm/rev일 때의

두 절삭조건에 대해 마멸이 진전 중일 때의 신호의 특징을 앞에서 학습시킨 신경회로망에 적용시킨 결과를 Fig. 14에 보였는데 최종 가공시간은 여유면 마멸량이 0.3mm를 넘었을 때를 나타내었다. 가공초기의 값이 대부분 0.5 이하의 값을 보이고, 가공이 진행되어 마멸이 진전됨에 따라 학습결과가 공구수명으로 학습시킨 <1>에 가까운 결과를 보이고 있으며 특히 절삭속도 100 m/min, 이송량 0.1 mm/rev일 때가 절삭속도 160 m/min, 이송량 0.15 mm/rev일 때 보다 마멸의 분류가 뛰어나 고속·고이송량일 때보다 저속·저이송량에서 공구수명을 잘 인식함을 알 수 있다.

## 5. 결론

절삭력 신호를 이용한 AR 모형과 상관차원 해석을 통해 추출한 특징을 이용하여 공구수명을 감지하기 위하여 신경회로망에 적용한 결과 다음과 같은 결론을 얻었다.

- (1) 순차형 최소자승법을 이용한 AR 모형은 절삭력신호를 매우 잘 예측하였다.
- (2) AR 계수와 노말라이징 인자를 이용하여 신경회로망에 적용시켜 본 결과 공구수명의 감지가 가능하며, 두 패턴을 복합한 모형의 인식율이 가장 뛰어남을 보였다.
- (3) 프랙탈 해석을 통해 구한 상관적분계수와 노말라이징 인자는 새로운 신호처리방법으로 응용할 수 있다.

## 참고 문헌

1. J. U. Jeon and W. Kim, "Optical flank wear monitoring of cutting tools by image processing," *Wear* 127, pp. 207-217, 1988.
2. S. E. Oraby, D. R. Hayhurst, "Development of models for tool wear force relationship in metal cutting," *Int. J. Mech. Sci* 33(2), pp. 125-138, 1991.
3. K. Uehara, F. Kiyosawa and H. Takeshita, "Automatic tool wear monitoring in NC turning," *Ann. CIRP* 28, pp. 39-42, 1979.
4. P. M. Lister and G. Barrow, "Tool condition monitoring system," *Proc. 26th Int. Machine Tool Design and Research Conf.*, pp. 271-288, 1986.

5. N. Akgerman, J. Frisch, "The Use of Cutting Force Spectrum for Tool Wear Compensation during turning," Int. MTDR, 1971.
6. W. Konig, K. Langhammer, H. U. Schemmel, "Correlation between Cutting Force Components and Tool Wear," Annals of the CIRP, Vol. 21, 1972.
7. S. Weigend, A. Gershenfeld, "Time Series Prediction : Forecasting the Future and Understanding the Past," Proceedings of the NATO Advanced Research Workshop, Vol. X V, 1992.
8. H. S. Greenside, A. Wolf and J. Swift, T. Pignataro, "Impracticality of a box-count algorithm for calculating the dimensionality of strange attractor," Physical review A, Vol. 25 No. 6, 1982.
9. J. Theiler, "Efficient algorithm for estimating the correlation dimension from a set of discrete point," Physical review A, Vol. 36 No. 9, 1987.
10. J. P. Eckmann, S. O. Kamporst, D. Ruelle and S. Ciliberto, "Lyapunov exponents from a time series," Physical review A, Vol. 34, 1986.
11. G. Boothroyd, "Fundamentals of Machining and Machine Tools," McGraw-Hill, Inc., pp. 133-134, 1989.