

# 시계열 모델과 프랙탈 해석을 이용한 공구마멸 감시

(Tool Wear Monitoring using Time Series Model and Fractal Analysis)

최성필(부산대 대학원), 강명창(부산대 기계기술연구소),  
이득우, 김정석(부산대 정밀기계공학과/NSDM 연구센터)

## ABSTRACT

Tool wear monitoring is very important aspect in metal cutting because tool wear effects quality and precision of workpiece, tool life etc.

In this study we detected force signal through tool dynamometer in turning and using it we conducted 6th AR modeling and fractal analysis. Finally the back-propagation model of the neural network is utilized to monitor tool wear and features are extracted through AR model and fractal analysis.

Keyword : tool wear monitoring(공구마멸 감시), force signal(절삭력 신호), AR model(AR 모델), fractal analysis(프랙탈 해석), neural network(신경회로망)

## 1. 서 론

최근 생산 분야에서의 기술발달은 기계가공의 정밀도 향상, 자동화 공작기계의 개발로 이루어지고 있으며 이러한 목적의 일환으로 가공중 발생하는 공작기계의 상태진단 및 공구의 이상상태 감시 등에 대한 연구가 활발히 진행중이다. 특히 공구마멸은 가공품의 품질 및 정밀도를 떨어뜨리고 공구와 공작기계의 손실을 초래하여 전체공정의 저생산성과 고생산비를 발생시킨다.

선삭시 절삭공구의 마멸종 플랭크마멸은 공작물 표면과 공구여유면 사이의 마찰에 의해 발생하는 현상으로 공작물의 표면조도에 직접적인 영향을 주고 있으며 특히 치수정도나 형상정도가 정밀함을 원하는 경우에 중요하게 고려하여 아할 마멸인자이다.

공구마멸의 감시방법은 크게 두가지로 나눌 수 있다. 하나는 절삭공구의 형상변화를 직접 측정하는 방법이고 다른 하나는 절삭과정중에 발생하는 물리적인 파라메타를 이용하는 간접적 방법이다. 이 중 절삭력을 이용한 간접적 방법에 관한 연구가 상대적으로 많이 행해지고 있는데, 절삭력이 상대적으로 S/N 비가 큰 파라메타중의 하이기 때문이다.<sup>(1)</sup>

그 외 Dornfeld등은 AE RMS 신호를 AR 모델링하여 공구마멸에의 감시 가능성<sup>(2)</sup>을 주장하기도 하였는데, 이러한 신호처리 기법을 이용하여 밀링가공에서의 절삭력 신호로 해석하여 공구마멸의 감시<sup>(3)</sup>에 응용한 연구도 행해지고 있다.

본 논문에서는 공구동력계를 이용하여 절삭력 신호를 검출하고, 이를 시계열 모델(time series model)을 이용하여 6차의 AR 모델링 한 후 AR 계수를 특징으로 추출한다. 또한 프랙탈 해석(fractal analysis)을 통하여 해석과정에서 구할 수 있는 인자를 특징으로 추출한다. 그리고 최종적으로는 이를 이용하여 각각의 신경회로망(neural network)을 구성하여 공구마멸을 감시하고자 한다.

## 2. 시계열 모형과 프랙탈 이론

### 2.1 시계열 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.

가공시의 센서신호를 AR 모델(Autoregressive model)로 특성화하면 신호의 모델 파라메타는 신호의 변화에 따라 계속적으로 개선되고 결국 이러한 시변 파라메타들이 절삭공구 마멸시의 마멸 조건에 대한 정보를 가지게 된다. 즉 시계열 데이터  $y(k)$  ( $k=0, 1, \dots, N-1$ )에서 측정치의 현재값은  $N$ 개 이전값들의 선형결합으로 표현된다.

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

여기서

$n(k)$  : 백색잡음(white noise),

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

$y^T(k) = [y(k), y(k-1) \dots y(k-N)]$  : 시계열 벡터

여기서 백색잡음  $n(k)$ 은 모르는 값이므로 현재의 측정값  $y(k)$ 와 한단계 이전의 모델식에 의해 예측된 값사이의 오차  $e(k)$  ( $e(k) = y(k) - \bar{y}(k)$ )의 제곱합을 최소로하여 계수  $a_1 \sim a_n$ 을 결정한다.

본 연구에서는 오차  $e(k)$ 를 최소화하기 위해 순차형 최소자승법(recursive least square method)을 이용하여 AR 계수를 구하였다.

## 2.2 프랙탈 차원 해석

프랙탈 혹은 프랙탈 차원은 불규칙성의 정도를 나타내는 것으로 어떤 물체의 거칠거칠한 정도나 부서진 정도 혹은 불규칙한 정도를 측정하는 방법이다. 예를 들면 꼬불꼬불한 해안선은 길이 관점에서는 측정이 불규칙하지만 들쑥날쑥한 정도에서는 어떤 특성을 가지고 있다. 이러한 정도는 소수차원(decimal dimension)으로 나타난다.

이러한 해석은 카오스(chaos)적 현상을 나타내는 비선형계의 비선형정도를 나타내기 위한 방법으로 연구되기 시작했는데, 자연계의 복잡한 풍경이나 형상을 나타내거나, 어떤 계의 정보를 담고 있는 센서신호로부터 특징을 추출하기 위한 방법으로 응용할 수 있다.

프랙탈 차원중의 하나인 상관 차원(correlation dimension)을 구하는 수학적 알고리즘은 다음과 같다.<sup>(4)</sup>

시계열 데이터로부터  $n$ 차원의 벡터

$$X_j = \{X(t_i), X(t_{i+1}), \dots, X(t_{i+n-1})\} \quad \dots \dots \quad (2)$$

를 구성하고 임의의 2개 벡터의 거리  $|X_i - X_j|$  가  $r$  이하가 되면 상관적분계수  $C(r)$  을 계산한다. 이렇게 만든  $N$ 종류의 샘플로부터

$$C(r) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N H(r - |X_i - X_j|) \quad \dots \quad (3)$$

를 계산한다. 만약 상관적분계수  $C(r)$ 이  $r^d$ 에 비례한다면, 그 지수  $d$ 가 상관 차원을 부여한다. 즉 상관 차원은

$$d = \frac{\log(c(r_2)) - \log(c(r_1))}{\log(r_2) - \log(r_1)} \quad \dots \dots \dots \quad (4)$$

이 된다.

여기서  $H(x)$ 는 해비사이드 계단함수(Heaviside step function)이다.

## 3. 실험장치의 구성 및 실험

### 3.1 실험장치

절삭력신호를 이용한 공구마멸의 감시 가능성을 파악하기 위한 실험장치를 Fig. 1과 같이 구성하였다.

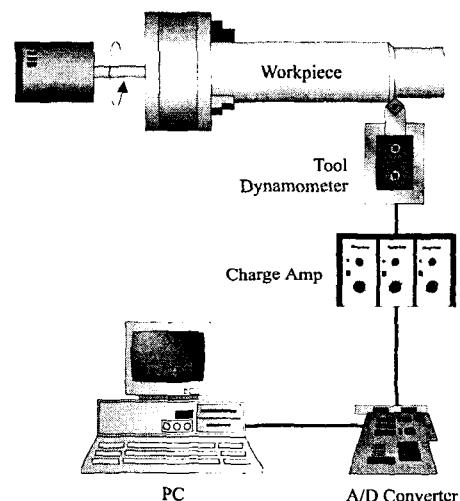


Fig. 1 Schematic diagram of experimental set-up

절삭실험은 무단변속선반에서 절삭속도를 일정하게 하기 위해 시편의 반경에 따른 rpm을 조절하며 행하였고, 공작물은 탄소강(SM45C)을 사용했다. 공구는 P10계열의 초경공구(SNMA 120408)를 사용하였다.

### 3.2 실험방법

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

실험의 양과 시간을 줄이기 위해 인위적인 마멸을 준 텁(worn tool)과 가공을 하지 않은 텁(fresh tool)을 사용하여 각각 데이터를 입력받았다. 공구마멸의 기준을 여유면 마멸 0.3mm 이상으로 정하여 텁에 절삭조건에 따른 연속적인 가공을 통해 마멸을 가하였다.

본 실험에서 사용한 절삭조건은 Table 1과 같고 전식 절삭을 실시하였다.

Table 1 Cutting Conditions

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

#### 4. 특징추출 및 신경회로망의 구성

##### 4.1 AR 모델을 이용한 특징추출

가공중에 발생하는 절삭력 신호는 가공에 관한 정보를 담고 있다. 이 신호를 AR 모형으로 모델링하면 가공의 진행 및 상태에 관한 정보를 얻을 수 있다. Fig. 2에는 순차형 최소자승법으로 6차 AR 모델로 모델링하였을 때 예측된 신호를 원래의 신호(raw signal)와 비교하여 나타내었다.

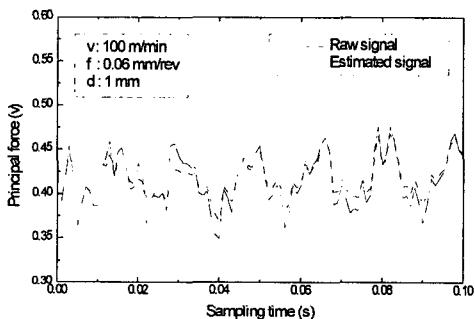


Fig. 2 Prediction of principal force signal using AR(6) model

여기서 AR 계수는 공구마멸에 관한 정보를 담고 있는 특징이 되고 이를 통하여 공구마멸의 진행에 따른 정보를 추출할 수 있다. 6차 AR 모델에서의 마멸에 따른 변화의 예를 Fig. 3에 나타내었다. 그림에서 보는 바와 같이 여유면 마멸량의 변화에 따른 AR 계수가 뚜렷한 구분을 보이고 특히 1, 2, 3차 계수의 변화가 크게 나타남을 알 수 있다.

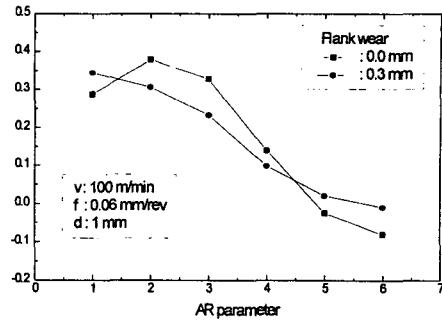


Fig. 3 The variation of AR parameter according to flank wear

##### 4.2 프랙탈 해석 기법을 이용한 특징추출

Fig. 4에 마멸이 되지 않았을 때와 여유면 마멸이 0.3mm가 진행되었을 때 주분력과 배분력을 축으로 하는 2차원 좌표를 구성하여 절삭력의 분포를 나타낸 것이다. 공구마멸이 되었을 때의 분포가 넓게 퍼져 공구마멸이 진행되었을 때 변동이 심한 것을 확연히 알 수 있다.

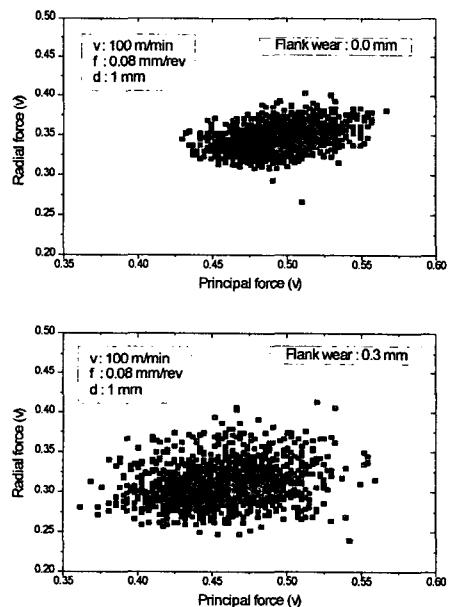


Fig. 4 Distribution of force signal in principal and radial force coordinate

Fig. 4를 이송분력축을 포함하는 3차원 좌표로 확장하면 각 데이터 획득시간에서의 {주분력  $F_p$ , 배분력  $F_t$ , 이송분력  $F_s$ }로 구성된 신호가 하나의 벡터를 형성한다. 이렇게 구한 절삭력 벡터에서

식(3)에 따른 계산을 수행하면 거리  $r$ 의 변화에 따른  $C(r)$ 을 구할 수 있게 되고 여기서 프랙탈 차원은 대수좌표계 상에 나타나는  $r$ 의 변화에 따른  $C(r)$ 의 기울기가 된다. Table 2에  $r$ 의 변화에 따른  $C(r)$ 의 변화를 한 절삭조건에 대해 나타내었고, 이에 따라 계산된 프랙탈 차원은 여유면 마멸이 0mm 일 때 3.28795이고 여유면 마멸이 0.3mm 일 때 3.3187이다.

Table 2 The variation of  $C(r)$  and  $\log(C(r))$  according to flank wear  
( $V=100$  m/min,  $f=0.08$  mm/rev,  $d=1$  mm)

$r$	$C(r)$ ( $V_B=0$ mm)	$C(r)$ ( $V_B=0.3$ mm)	$\log(r)$	$\log C(r)$ ( $V_B=0$ mm)	$\log C(r)$ ( $V_B=0.3$ mm)
0.0020	0.021	0.057	-2.699	-1.688	-1.254
0.0035	0.414	1.088	-2.456	-0.383	0.037
0.0050	0.720	1.875	-2.301	-0.143	0.273
0.0075	2.571	6.698	-2.125	0.410	0.826
0.0100	5.302	13.612	-2	0.724	1.134

본 연구에서는 먼저 공구마멸에 따른 값의 차이가 큰  $C(r)$ 값을 특징으로 하여 5개의 경우로 변하는  $r$ 의 값에 따른  $C(r)$ 값을 구한후 신경회로망에 입력시켜본 결과 절삭조건의 변화에 따른 값의 차이가 크게 나타나 신경회로망에서의 분류 오차가 커져 인식율이 크게 떨어짐을 알 수 있었다. 따라서 아래의 식 (5)과 같이 절삭속도와 이송량의 변화에 따라 차이가 나는 부분을 줄이기 위해 노말라이징(Normalizing)시켜 이 값을 신경회로망에 입력시켰고 이를 노말라이징 인자  $Inp(r)$ 로 정의하였다.

$$Inp(r) = \frac{C(r) \times V \times f}{100} \quad \dots \dots \dots \quad (5)$$

Fig. 5는 Table 2의 데이터를 식 (5)에 따라 계산한 값으로 이를 특징으로 선택하였다.

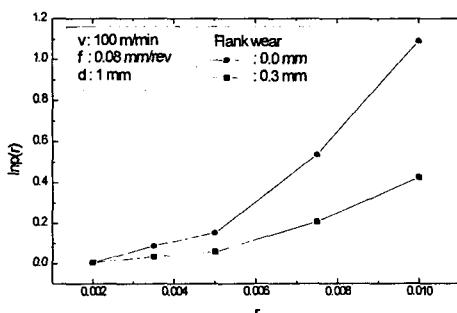


Fig. 5 The variation of  $Inp(r)$  according to flank wear

#### 4.3 신경회로망의 구성 및 컴퓨터 시뮬레이션

공구마멸의 감시에 신경회로망을 이용하는 이유는 뚜렷하지 않은 추출 파라메타들 사이의 관계로부터 효과적인 정보를 얻기 위해서이다.

앞에서 언급한 바와 같은 특징들로부터 공구마멸을 감시하기 위해 인공 신경회로망을 이용하였다. 이 때 각 층간의 연결강도를 조절하는데 출력층 뉴런으로부터 하위층으로 오차를 역전파하여 조절하는 역전파법(Back propagation)을 사용하였고, 각 뉴런간의 전달함수로는 시그모이드(Sigmoid)함수를 이용하여 감독학습(Supervised learning)시키는 신경회로망을 구성하여 추출한 데이터를 학습시켰다.

먼저 앞에서 추출한 AR 계수를 이용한 공구마멸의 감시를 위해 Fig. 6과 같은 신경회로망을 구성하여 입력층에는 절삭조건(절삭속도, 이송량)과 6개의 AR 계수를 입력시키는 8개의 노드(node)를 두고 은닉층에는 9개, 그리고 출력층에는 1개의 노드를 두어 8-9-1의 신경회로망을 구성하였다. 출력층에서는 공구마멸이 되었을 때 <1>을 출력하고 마멸이 되지 않았을 때 <0>을 출력하도록 학습시켰다. 학습 데이터는 16개의 가공조건에 대한 데이터의 2배를 주어 총 64개의 데이터를 학습시켰다.

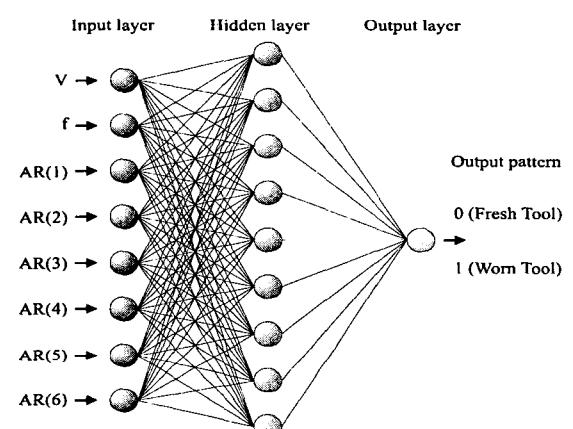


Fig. 6 Architecture of neural network when input data is AR parameter

그리고 신경회로망의 인식여부를 확인하기 위해 학습한 64개의 데이터와 학습하지 않은 데이터 64개를 함께 적용시켜 보았다. 그 결과를 Fig. 7에 나타내었는데 대체적으로 잘 인식함을 알 수 있다.

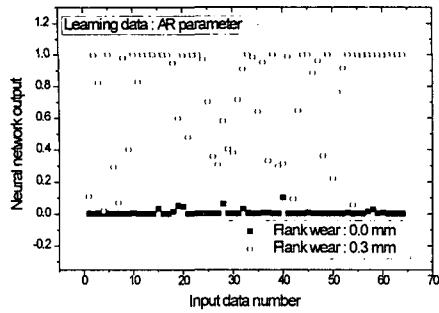


Fig. 7 Implementation results using AR parameter

그리고 앞에서 정의한 노말라이징 인자를 입력으로 하여 절삭조건(절삭속도, 이송량)과 5개의  $r$ 에 대한 노말라이징 인자를 입력하는 7-8-1의 신경회로망을 구성하여 앞선 방법과 유사한 과정으로 학습시킨 후 적용 여부를 확인해 보았다. 그 결과를 Fig. 8에 보이고 있는데, 역시 잘 인식함을 알 수 있으나 AR 계수를 이용한 신경회로망에는 성능이 미치지 못함을 알 수 있다. 이 중 AR 계수를 이용한 신경회로망에서는 이송량이 0.06 mm/rev일 때와 0.08 mm/rev일 때의 인식율이 떨어졌고 노말라이징 인자를 이용한 신경회로망에서는 이송량이 큰 0.1 mm/rev일 때와 0.12 mm/rev일 때의 인식율이 떨어졌다.

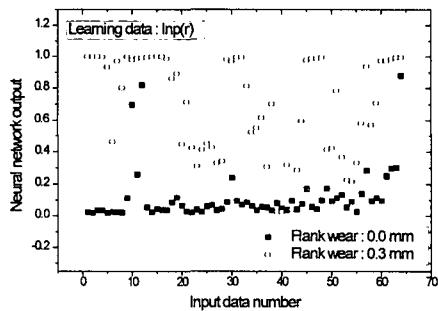


Fig. 8 Implementation results using  $Inp(r)$

따라서 이러한 각 신경회로망에서의 단점을 보안하기 위해 두가지 특징을 복합하여 입력 데이터로 AR 계수중에서는 1, 2, 3차 계수를 선택하였고 노말라이징 인자 중에서는  $r$ 이 0.005, 0.0075, 0.01일 때의 값을 선택하였다. 이는 각 데이터 중에서 이들의 값들이 공구마멸에 따른 패턴으로

잘 구분이 되기 때문이다. 그 결과를 Fig. 9에 나타내었는데 앞선 두 경우에 비해 인식율이 크게 증가 했음을 볼 수 있다.

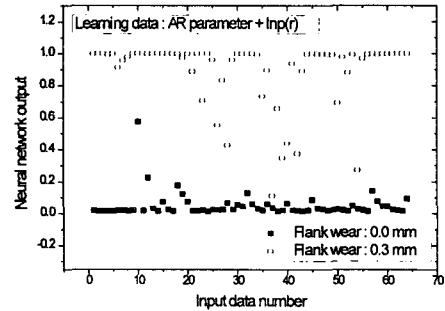


Fig. 9 Implementation results using AR parameter and  $Inp(r)$

## 5. 결론

- (1) 시계열 모델을 이용하여 절삭력신호의 예측이 가능함을 알 수 있었다.
- (2) 시계열 계수와 노말라이징 인자를 이용하여 신경회로망에 적용시켜본 결과 공구마멸의 감시가 가능함을 제시하였으며 두 패턴을 복합한 모델의 인식율이 더욱 뛰어남을 보였다.
- (3) 프랙탈 해석을 통해 구한 상관적분계수  $C(r)$ 과 노말라이징 인자  $Inp(r)$ 는 새로운 신호처리기법으로 응용가능함을 제안하였다.

## 참고 문헌

- (1) S. E. Oraby, D. R. Hayhurst, "Development of models for tool wear force relations hip in metal cutting", Int. J. Mech. Sci 33(2), 125-138, 1991
- (2) S. Y. Liang, D. A. Dornfeld, "Tool wear detection using time series analysis of acoustic emission", Trans. ASME, J. Eng. End, Vol. 111 199-205, 1989
- (3) Yosuf Altintas, "In-process detection of tool breakage using time series monitoring of cutting forces", Int. J. Mach. Tools Manufact. Vol. 28. No. 2, pp 157-172, 1988
- (4) J. Theiler, "Efficient algorithm for estimating the correlation dimension from a set of discrete point", Physical review A, Vol. 36 No. 9, 1987