

밀링공정의 적응모델링과 공구마모 검출을 위한 신경회로망의 적용

고 태 조*, 조 동 우**

Adaptive Milling Process Modeling and Neural Networks Applied to Tool Wear Monitoring

Tae-Jo Ko*, Dong-Woo Cho**

ABSTRACT

This paper introduces a new monitoring technique which utilizes an adaptive signal processing for feature generation, coupled with a multilayered neural network for pattern recognition. The cutting force signal in face milling operation was modeled by a low order discrete autoregressive model, where parameters were estimated recursively at each sampling instant using a parameter adaptation algorithm based on an RLS(recursive least square) method with discounted measurements. The influences of the adaptation algorithm parameters as well as some considerations for modeling on the estimation results are discussed. The sensitivity of the estimated model parameters to the tool state(new and worn tool) is presented, and the application of a multilayered neural network to tool state monitoring using the previously generated features is also demonstrated with a high success rate. The methodology turned out to be quite suitable for in-process tool wear monitoring in the sense that the model parameters are effective as tool state features in milling operation and that the classifier successfully maps the sensors data to correct output decision.

Key Words : milling process(밀링공정), adaptive signal processing(적응 신호처리), autoregressive time series(자동회귀 시계열), Recursive Least Square(순환최소자승), feature(특징), tool wear(공구마모) neural network(신경회로망)

1. 序 論

FMS(Flexible Manufacturing System), FMC(Flexible Manufacturing Cell)과 같은 유연 생산시스템 뿐만이 아니고 공장자동화(FA)의 최하위 단위인 절삭가공공작기계에 대한 무인화의 실현은 머지않은 장래

에 완성될 IMS(Intelligent Manufacturing System)시스템의 구축에 있어서 최대의 걸림돌이 되고 있다.

전통적인 생산시스템에서는 경험을 가진 작업자에 의해 절삭공정이 감시되어지며, 만약 이상이 발생했을 때에는 그 상태에 따른 적절한 조치를 즉시 취할 수 있었다. 그러나 급속도로 연구가 진행되는 무인생산 시스

* 포항공과대학 대학원 기계공학과

** 포항공과대학 기계공학과

템에서는 이러한 작업자의 역할이 컴퓨터에 의한 자동적인 감시 및 제어 시스템으로 대체되어야 한다. 이러한 감시활동 중에는 공구마모 및 파단의 검출은 효율적인 공구교환정책, 가공물의 품위유지 및 공구와 공작기계의 보호를 위해서 가장 중요한 부분으로 취급되고 있다.

공구 마모(wear)를 검출하기 위한 방법은 여러가지가 발표되어 있으나^{(1), (2)}, 최근의 동향은 1) 공구의 상태와 관련된 가공정보를 측정하기 위한 복수개의 센서사용 2) 공구의 마모와 밀접한 관계가 있는 특징(feature)의 추출 3) 공구의 마모를 분류할 수 있는 패턴분류기의 개발로 요약된다. 그러나 대부분의 연구는 단절인을 사용하는 선삭가공의 경우이며, 밀링가공의 경우에 대해서는 공구의 파단(breakage)에 대한 몇가지 연구는 거의 없다.

Jiaa와 Dornfeld는 면삭과정에서 AE(acoustic emission) 신호를 격자필터(lattice filter)를 이용한 신호처리로 밀링공구의 마모에 대해서 연구했으며⁽³⁾, Elbestawi등은 공구마모에 따른 특정주파수에 대한 절삭력 성분의 변동을 이용하는 공구마모검출법을 제시했다⁽⁴⁾. 최근에는 Teitenberg등이 면삭과정에서 절삭과정 모델링을 이용한 해석적인 방법을 제시했다⁽⁵⁾.

한편, 밀링절삭과정은 절삭력이 주기적으로 변동하는 성질, 즉 다절인(multi-point tool) 공구가 회전함에 따라서 단속절삭을 하게되고 절삭칩의 두께가 절삭되는 동안 변한다. 또한 다절인 절삭에서는 한개 이상의 절인이 동시에 절삭에 참여하게 되므로 절삭과정의 해석은 매우 복잡하다. 따라서 절삭력을 이용하는 통상의 방법으로 밀링과정을 효과적으로 해석하기 위해서 복잡한 신호처리방법을 필요로 했다⁽¹⁰⁾.

이러한 이유로, 절삭력이나 가속도 신호를 모델링하기 위해서 AR(Autoregressive)/ARMA(Autoregressive Moving Average)등의 시계열 방법을 이용하게 되었다^{(6), (7)}. Takata와 Sata는 칼만필터 그리고 모델에 기초한 적응신호처리를 이용하여 주축모터의 전류신호에 대한 27차 AR모델링으로 공구파단의 검출 가능성을 제시했다^{(8), (9)}. 유사한 연구는 Lan과 Naerheim에 의해 계속되어졌는데, 그들은 절삭력에 적응 AR모델을 적용하여 매순간 신호를 샘플링할 때마다 순환적으로 파라미터를 개선하여 공구파단을 검출하였다. 또한, 모델의 차수는 최소한 공구의 1회전을 포함할 수가 있어야 하고 더 나은 결과를 위해서는 2회전 혹은 3회전 정도를 포함하여야 하며 따라서 15차 모델을 사용했다⁽¹⁰⁾.

그러나 이러한 높은 차수의 모델은 실시간 감시를 위한 신호처리의 모델로 사용하는데 있어서 어려움이 있다.

본 논문에서는 밀링공구의 마모검출을 위해서 RLS(Recursive Least Square)방법을 이용하는 적응 AR 모델링으로, 절삭력을 낮은 차수의 모델로써 모델링하는 과정을 제시한다. 또한 샘플링 주파수, 모델의 차수 그리고 모델의 알고리즘에서 망각계수(forgetting factor)와 적응이득(adaptation gain)과 같은 계수값의 영향이 모델링에 미치는 영향을 평가하고 모델의 차수와 더불어 이들의 적절한 값을 제안한다. 그리고 AR모델의 계수가 공구의 마모와 밀접한 관계가 있으며 이들을 추적함에 따라서 공구의 마모를 검출할 수 있다는 가능성도 함께 제시한다. 또한 신경회로망과 적응신호처리방법을 결합한 신경망 분류기는 밀링공구의 마모 검출에서 탁월한 능력을 보이며 이들은 in-process 공구마모 검출에 적당함을 보인다.

2. 적응AR모델을 이용한 밀링공정 모델링

시스템이 선형 미분방정식으로 모델링이 된다면, 이산신호로부터 Autoregressive Moving Average (ARMA : 자동회귀 이동평균) 형태의 스토케스틱 차분방정식을 구할 수가 있다⁽¹¹⁾. t 가 이산신호를 나타내는 지수이고, 시계열 x_t 에 대한 n 차 AR모델을 사용하면, 현재의 값에 대한 예측은 n 단계 이전 값들의 선형 조합으로 표현이 가능하다. 일반적인 AR(n) 모델은

$$x_t - \phi_1 x_{t-1} - \phi_2 x_{t-2} - \dots - \phi_n x_{t-n} = a_t \quad (1)$$

로 표현된다. 여기서 x_t 는 계의 응답, $\phi_1, \phi_2, \dots, \phi_n$ 는 자동회귀 계수, 그리고 a_t 는 평균이 0(zero)이고 분산이 σ_a^2 인 백색잡음이다. 추정벡터 $\phi(t)$ 와 계수벡터 $\theta(t)$ 를 다음과 같이 정의하면

$$\phi(t) = \{ x(t-1), x(t-2), \dots, x(t-n) \} \quad (2)$$

$$\theta(t) = \{ \phi_1, \phi_2, \dots, \phi_n \}^T \quad (3)$$

추정값과 모델의 예측값 사이의 차이인 모델링 오차는

$$e(t) = x(t) - \phi^T(t) \hat{\theta}(t-1) \quad (4)$$

로 된다. 여기서 $\theta(t-1)$ 는 시점 $t-1$ 에서 평가한 계수벡터이다. 만일 백색잡음에 대한 계의 응답이 정적스토케스틱 과정이라면 식(1)로 주어지는 AR(n) 모델의 모든

계수들은 평균자승오차(mean-square error)를 최소화함에 의해 최적화할 수가 있다(11).

만일 계가 시변이라면 과거의 데이터에는 불신이 가해지고 새로운 데이터에 더욱 비중을 주는 것이 합리적이다. 따라서 본 연구에서는 망각계수(forgetting factor)인 불신측정(discounted measurement)을 이용하는 순환최소자승법(recursive least square : RLS)을 적용하고자 하며, 이 모델은 신호의 통계적 성질을 사전에 필요로 하지 않으므로 실제상황에서의 적용이 용이하다. 또한 batch 알고리즘이 모델링하려는 전체의 신호를 이용하여 계수를 구하는 반면, 적응 모델링에서는 매번 한 신호가 샘플링될 때마다 모델이 개선이 된다는 의미에서 적용적이므로 in-process에서의 실시간 신호처리에 적합하다. Ljung의 순환모델링(12)에 의하면, 불신측정으로 망각계수를 이용하는 RLS는 순환규명(recursive identification) 알고리즘으로서 다음과 같이 모델링이 된다.

$$\hat{\theta}(t) = \hat{\theta}(t-1) + k(t)e(t) \quad (5)$$

여기서 $k(t)$ 는 적응이득(adaptation gain)으로서 다음과 같다.

$$k(t) = \frac{R(t-1)\varphi(t)}{\{\lambda(t) + \varphi^T(t)R(t-1)\varphi(t)\}} \quad (6)$$

$$R(t) = \left\{ I - \frac{R(t-1)\varphi(t)\varphi^T(t)}{\lambda(t) + \varphi^T(t)R(t-1)\varphi(t)} \right\} \frac{R(t-1)}{\lambda(t)} \quad (7)$$

$$\lambda(t) = \lambda_0 \lambda(t-1) + (1 - \lambda_0) \quad (8)$$

망각계수를 정의하는 식(8)에서 망각률 λ_0 와 초기값 $\lambda(0)$ 는 임의선택된다. 계수벡터와 측정벡터의 통상적인 초기화 값은 $\theta(0) = 0$, $\varphi(0) = 0$, 그리고 공분산의 초기값은 $R(0) = \alpha I$ 로 한다. α 는 행렬의 대각요소(diagonal element)로서 오차의 초기 신뢰값을 결정하는데 영향을 미치는 값이 되며 I 는 $n \times n$ identity 행렬이다. 이러한 초기값은 수렴율이나 모델계수의 안정성에 영향을 미친다. 따라서 λ_0 , $\lambda(0)$ 그리고 $R(0)$ 의 선택에 따라서 여러 종류의 모델이 만들어짐을 알 수가 있다.

식(4)와 (5)는 시간 t 에서의 관측 $x(t)$, 한단계 이전에서부터 n 단계 이전값들의 측정벡터 $\varphi(t)$ 그리고 한단계 이전에 평가한 계수벡터 $\theta(t-1)$ 와 공분산 $R(t-1)$ 을 이용하여 $\theta(t)$ 를 순환적으로 평가함을 보이고 있다. 이 순환형태는 데이터를 매번 샘플링할 때마다 모델을 갱신하기 때문에 매우 편리하며, 절삭과정의 점진적 변화를

잘 추종하게 된다. 따라서 만일 모델계수가 조정(tuning)이 잘 된다면, 절삭과정의 동특성변화가 모델계수 및 예측오차에 반영됨으로서 공구의 마모와 같은 점진적인 변화는 이러한 데이터를 관측함에 의해 감지할 수가 있다.

3. 실험방법

공구의 마모감시를 위한 실험은 knee형 수직형 밀링 머신에서 그림 1과 같이 수행했다. 밀링공구는 8개의 등간격으로 인서트공구를 끼워넣게 되어 있으며, 이중 3개의 인서트가 절삭과정에 참여하게 된다. 실험에 사용된 밀링커터와 인서트의 규격은 표 1과 같다.

Table 1 Details of cutter and insert for cutting experiment

Cutter	1. Maker : Korea Tungsten 2. Model : M315SP-04R/L-12 3. Specification : Lead angle : 15 deg. Radial rake angle : 0 deg. Axial rake angle : 7 deg. Insert number : 8
Insert	1. Maker : Korea Tungsten 2. Model : SPKN 1203 EDR 3. Specification : Material : Tungstem Carbide (P20) Tool nose radius : Plane chamfered Flank relief angle : 11 deg.

또한 소재는 SS41로 된 사각형 시편(60×70mm)을 사용했으며, 절삭속도, 이송속도 그리고 절삭깊이는 각각 180-520rpm, 22-41mm/min 그리고 0.2-5.0mm로 변경되었다. 밀링공구의 마모는 인서트의 축방향 및 반경방향 runout 때문에 여러가지 경우로 나타난다. 즉, 모든 인서트가 동일하게 마모되기도 하고, 한개 또는 두개의 인서트만 특히 많이 마모되기도 한다. 이러한 현상을 방지하기 위하여 인서트의 삽입시에는 다이얼계 이지를 이용하여 정확한 삽입이 공구몸체에 이루어지도록 했다. 그러나 각 인서트 사이에는 공구마모길이에 약간씩의 차이가 발생할 수 있으며, 이러한 변동은 다

음과 같이 평균처리되었다.

$$VB_{av} = \frac{1}{n} \sum_{i=1}^n VB(i) \quad (9)$$

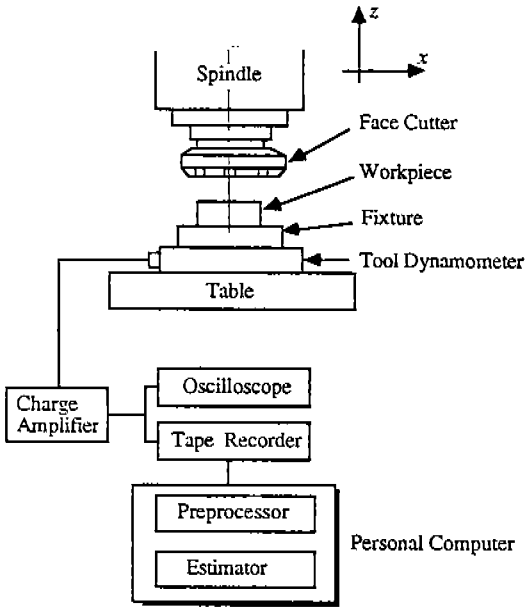


Fig.1 Schematic diagram of experimental set up.

여기에서 n 은 면삭공구에서 날의 수이고 $VB(i)$ 는 i 번째 인서트의 공구마모 길이이다. 모든 절삭에서 VB_{av} 가 0.5mm로 정의된 공구의 수명양료를 공구현미경으로 검사하고 기록하였다(4).

절삭과정동안 공구동력계(Kistler type 9257A)를 이용하여 이송방향의 절삭력을 측정하였으며, 모든 신호는 off-line신호처리를 위해서 신호증폭기(charge amplifier)를 통해 데이터 기록계(VHS cassette data recorder)에 저장하였다.


4. AR 모델링 결과

4.1 절삭과정 모델링


절삭조건과 절삭공구에 영향을 받는 절삭력의 DC성분 및 공구의 runout 성분을 제거하기 위해서, 먼저 절삭력 신호에 대해서 20-1000Hz의 대역통과 필터링을 했다. 이 신호는 off-line 신호처리를 위해 AD변환기를 통해서 1000개씩 PC로 읽어 들여졌다.

주어진 연속 시스템 신호를 이산화 시키기 위해 사용


하는 샘플링시간(sampling time)의 선택은 이산모델의 최종성능에 영향을 미친다. 모델링을 하는데 있어서 샘플링시간의 영향을 조사하기 위해서 마모된 공구로 절삭한 절삭력을 200, 1000 그리고 2000Hz로 각각 샘플링했을 때의 데이터를 모델링한 후의 자승오차의 합(sum of square error)을 그림 2에 나타내었다. 이 조사에서 알 수 있듯이 샘플링시간에 따라서 자승오차의 합은 큰 영향을 받는다.



(a) 2000Hz,



(b) 1000Hz,




(c) 200Hz.


Fig.2 Comparison of residual sum of square error with different sampling rates. (Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm, $R(0) = \alpha \cdot I$)

한편, 각각의 샘플링시간에 대해서 AR모델링 한후의 모델계수를 이용하여 구한 절삭력의 파워스펙트럼(부록 A)이 그림 3에 나타나있다. 낮은 샘플링 주파수에서는 공구통과주파수(tooth passing frequency)의 하모닉이 잘 나타나는 반면 높은 샘플링 주파수의 모델 결과에서는 그렇지 않다. 일반적으로 밀링가공에서는 절삭력이 주기적이고 또한 공구마모에 관한 정보는 공구통과주파수의 처음 세번째까지의 하모닉성분에 주로 존재한다 (4). 이 공구통과주파수는 절삭조건과 공구의 인서트 갯수에 따라 변하므로 이에따라 샘플링 주파수는 조정될 필요가 있다.

모델차수의 선택은 모델의 복잡성과 데이터의 정확한 모델사이에 타협이 필요한 난이한 문제이다. 근본적인 방법은 서로 다른 모델차수에 대해서 모델의 성능을 비교하고 더 높은 차수의 모델이 가치가 있는지 판단하는 것이다. 그러나 실시간 감시가 필요한 경우에는, 계산시간의 측면에서 낮은 차수의 모델이 유리하다. 그림 2(c)에서 알 수 있듯이 모델의 차수가 증가할수록 자승오차의 합이 감소하고 있다. 그러나 8차 이상의 모델차



(a) 200Hz,



(b) 2000Hz.

Fig.3 Power spectral density of feed directional cutting force with different sampling rates. (Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm, model order : 8)

수에서는 급격한 자승오차의 합의 감소를 기대할 수가 없으며 따라서 실시간 감시의 목적으로 밀링가공에서의 동적 절삭력을 모델링하기 위해서는 8차의 모델이 적당함을 알 수가 있다.

여러가지 α 값(공분산의 대각요소)에 따라 평가된 모델의 첫번째 계수(ρ_1)는 그림 4에 나타나있다. 그림에서 알 수 있듯이 $\alpha \geq 10$ 에서 모델계수는 빨리 수렴한다. 그리고 과도영역($0 \leq t \leq 1$)에서는 큰 α 값에 대해서는 하나의 값에서 다음 하나의 값으로 모델링 될때 큰 변화를 일으키나, 작은 α 값에서는 그러하지 못하다. 즉 초기값에 큰 신뢰가 주어져 있다고 설명할 수 있다. 이 문제에서는 $\alpha = 1000$ 이 적절한 선택이다. 그러나 그림 2(c)에서 볼 수 있듯이 α 값은 모델의 성능에는 영향을 미




Fig. 4 Convergence rates with different covariance values. (Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm)

Table 2 Validity measures for different values of λ_0 and $\lambda(0)$.

λ_0	$\lambda(0)$	No. of data n	Variance σ_a
0.9	0.9	200	0.001243
		1000	0.000867
		2000	0.000814
0.99	0.85	200	0.001155
		1000	0.000833
		2000	0.000795
0.99	0.9	200	0.001158
		1000	0.000829
		2000	0.000793
0.99	0.95	200	0.001202
		1000	0.000834
		2000	0.000795
0.99	0.99	200	0.001341
		1000	0.000888
		2000	0.000825
0.999	0.99	200	0.001331
		1000	0.000881
		2000	0.000825
1.0	1.0	200	0.001403
		1000	0.000936
		2000	0.000857


치지 않고 단지 수렴속도에 주로 관여함을 알 수 있다.

망각계수 $\lambda(t)$ 역시 모델계수의 수렴속도에 영향을 미친다. 과거의 데이터에 불신을 가하려면 식(8)과 같이 $\lambda(t)$ 는 t 에 따라 증가하는 함수이고 1보다 적어야 한다(12). λ_0 와 $\lambda(0)$ 에 따른 잔류오차의 분산을 모델링시키는 데이터의 수에 대해 각각 계산한 결과가 표 2이다.


표 2에서 알 수 있듯이 시변망각계수를 사용할 때가 고정된 값($\lambda(t)=1$)으로 모델링했을 때보다 성능이 우수하며, $\lambda_0=0.99$, $\lambda(0)=0.9$ 로 선택할 때가 최적임을 알 수가 있다.

4.2 모델링 결과


2초 동안 기록한 전형적인 이송방향의 밀링 절삭력과 한단계 미리 예측한 예측값, 모델링 후의 잔류오차 그리고 첫번째부터 네번째 모델계수($\phi_1-\phi_4$)의 수렴과정을 그림 5에 나타내었다. 그림에 의하면 시간에 따라서 오차가 감소하고 있음을 볼 수 있다. 또한 최초로 모델계수가 수렴하는데는 1초가 걸리고 있으며 이후 이 시간은 초기값을 영으로 하는 대신 최근의 최적값을 초기값으로 사용함으로써 현저히 줄어든다. 모델링과정에서 초기의 큰 변동은 초기계수의 임의추측(모든 모델계수를 영으로 함)과 측정 데이터가 들어오기 전까지는 아닐




(a)



(b)



(c)




(d)

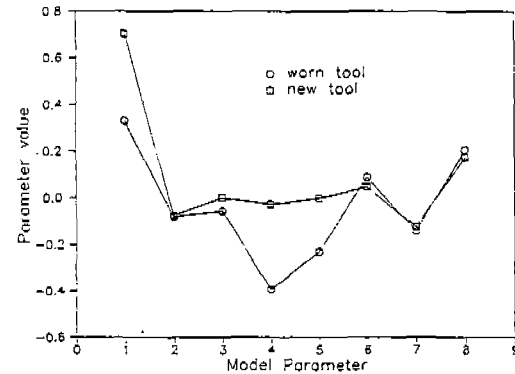
Fig. 5 (a) Feed directional cutting force signal, (b) one step ahead predicted values, (c) Residual error, (d) Convergence of first parameters. (model order : 8, $\theta_0=0.99$, $\theta(0)=0.9$, $\alpha=1000$, sampling rate=200Hz, Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm)

값을 영으로 하기 때문이다. 그림 5(a)와 5(b)에서, 측정신호와 예측신호 사이에 큰 차이를 발견할 수 없으므로 모델이 측정데이터를 잘 추종하고 있음을 알 수 있다.

이송절삭력의 AR 모델계수와 공구마모와의 상관관계를 조사하기 위해서 계수벡터(ϕ_1, \dots, ϕ_8)값을 그림 6에 나타내었다. 두 상태(새로운 공구와 마모공구)는 두 절삭조건(절삭속도 180, 520rpm) 하에서 잘 분리되고 있으며 따라서 AR 모델계수를 이용하여 공구의 상태를 감시할 수 있다. 물론 520rpm의 절삭조건에서는 공구 통과주파수성분의 세번째 성분까지 포함시키기 위하여



(a) Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm



(b) Cutting speed : 520rpm, feed : 32mm/min, depth of cut : 1mm

Fig. 6 Model parameters under different tool states.

샘플링 주파수를 600Hz로 조정하였다. 모델계수중에서 ϕ_1 과 ϕ_4 가 특히 공구의 상태를 분별할 수 있는 특징으로 잘 작용하고 있다. 그러나 넓은 절삭조건 범위에 있어서 구한 모든 ϕ_1 과 ϕ_4 를 그림 7과 같이 그려보면 2차원 특징공간에서는 완전히 두 공구의 상태를 분리시킬 수가 없다. 그러나 공구의 두 상태는 그림 8과 같은 전형적인 비선형 문제인 "Exclusive-OR" 문제를 풀 수 있는 신경회로망을 이용하여 8차원 공간상에서는 완전히 분리시킬 수가 있다.

그림 9는 플랭크 면의 마모길이 진행에 대해서 AR 모델계수를 이용하여 구한 파워 스펙트럼(부록 A)이다.

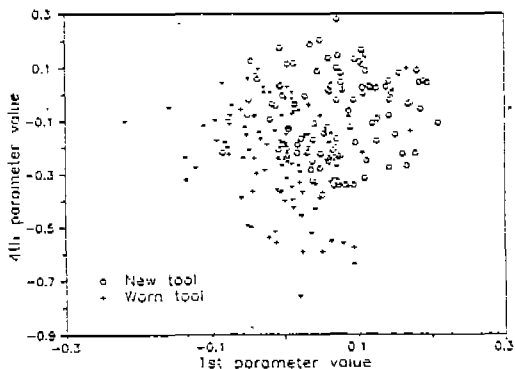




Fig.7 Distribution of tool state in two dimensional feature space under the wide range of cutting conditions




○ : pattern belonging to class C1
 × : pattern belonging to class -C1

Fig.8 Pattern-recognition problem that cannot be handled by a linear classifier. (x1, x2 : features of cutting process, c1, ~c1 : certain classes)

플랭크면 마모에 대해서 공구통과주파수의 첫번째 주파수(fundamental frequency)의 변화가 특별히 민감하다. 즉 AR 모델계수는 이러한 경향을 잘 반영하는 것이고 따라서 공구의 마모상태에 대한 특징으로서 사용



(a) Cutting speed : 180rpm, feed : 32mm/min, depth of cut : 1mm



(b) Cutting speed : 520rpm, feed : 32mm/min, depth of cut : 1mm

Fig.9 Variation of power spectral density with the progress of tool wear.

을 하도록 한다.

5. 신경회로망의 적용

오차 역전파 학습방법을 적용할 수 있는 다층신경회로망(부록 B)을 공구의 두 상태, 즉 새로운 공구와 마모된 공구를 구별해내기 위해서 사용했다. 신경회로망을 학습시키기 위해서 넓은 범위의 절삭조건(절삭속도 :

180-520rpm, 이송속도 : 22-41mm/min, 절삭깊이 : 0.2-5.0mm) 하에서 만들어진 246개의 샘플패턴 중에서 두 공구의 상태가 잘 분포된 31개의 패턴을 선택했다. 여기서 실제와 다른 공구의 상태를 나타내는 패턴은 학습의 능력을 저하시키기 때문에 훈련패턴은 주의해서 선택해야 한다.

앞장에서 기술했듯이, AR계수를 신경회로망의 입력데이터로 사용한다. AR계수가 절삭조건에 따라서 민감하게 반응하는 것을 보상하기 위해서 절삭조건 역시 입력데이터로서 사용이 가능하며, 따라서 NC콘트롤러에서 즉시 구할 수 있는 정보인 이송속도와 절삭속도를 부가적인 입력데이터로 사용한다. 따라서 10개의 특징이 공구의 감시를 위한 신경회로망의 입력데이터로 사용된다. 특히 절삭조건은 신경회로망의 시그모이드 함수의 조기포화현상에 의한 학습의 어려움을 방지하기 위해서 사용가능한 최대값으로 나누어서 정규화하여 사용한다.

입력층에서의 노드의 갯수는 입력특징의 수와 같게 10 (8 AR계수, 2절삭조건) 으로, 출력층의 노드갯수는 1로 했다. 학습자료는 표 3에 나타나있다.

Table 3 Learning data set for training neural network.

input nodes	output node	learning conditions
AR model parameters	tool state (new/wear)	input node number 10
		output node number 1
		sample pattern number 31
		learning rate η 0.5
		momentum rate γ 0.5
		shape factor γ_0 1.0
		error bound 0.01

학습을 위해서 출력노드의 목표값은 마모공구에 대해서는 0.9 그리고 새로운 공구에 대해서는 0.1로 설정했다. 그림 10은 신경회로망의 학습과정중에 출력노드의 값과 목표값의 차이를 나타내는 오차의 수렴을 나타내는 것이다. 여기서 사용한 신경망은 10-10-5-1 (입력노드 10, 첫번째 중간층노드 10, 두번째 중간층 노드5, 출력층 노드 1) 이다. 학습의 초기에는 신경망의 출력값은 목표값과 큰 차이를 보이나 순환을 계속함에 따라 출력값은 목표값으로 천천히 수렴해 나가고, 마침내 학습샘플의 모든 입력과 출력의 관계를 익히게 된다.

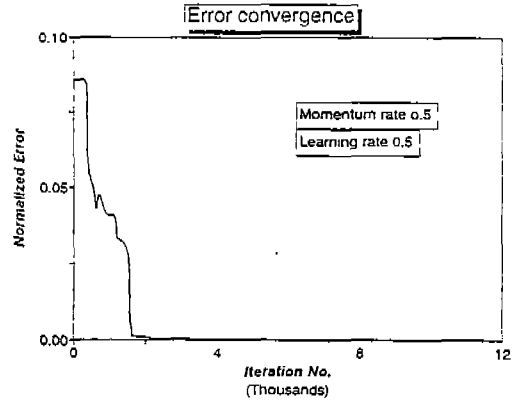




Fig.10 Convergence of the output error with the number of iterations.

학습을 완료한 후, 학습에 참여하지 아니했던 새로운 입력데이터를 제시함으로써 신경회로망 분류기의 성능을 검사했다. 출력의 값이 0.5보다 크면 현재의 상태는 마모, 그렇지 않으면 새로운 공구로 했다.

감시 시스템의 성능은 숨은 층의 구조에 따라서 많이 변화한다. 본 연구에서는 만족할만한 성능이 10-10-5-1 (입력노드 10, 첫번째 중간층노드 10, 두번째 중간층노드 5, 출력층 노드 1)의 구조일 때 얻어졌으며, 더 이상 숨은 층을 증가해도 성능향상을 기대할 수가 없었다. 그림 11(a)와 11(b)는 109개의 새로운 공구와 106개의 마모공구에 대한 신경회로망 출력노드의 값이다. 점선으로 된 경계선을 벗어나는 경우를 제외하고는 대부분의 공구상태는 잘 인식이 되었으며, 채택된 신경망의 구조로 이루어진 분류기의 정확도는, 신경망 분류기가 넓은 범위의 절삭조건하에서 작동을 하였음에도 불구하고 95%에 달하는 성능을 나타냈다.



(a) New tool



(b) Worn tool

Fig. 11 Output node values with respect to input test samples.

6. 결 론

밀링가공에서 공구의 마모를 검출하기 위해서 적응신호처리방법과 신경회로망을 동시에 사용하였다. 동적 절삭력을 모델링하기 위해서는 8차 AR 모델이면 충분하였으며, 이는 예전의 다른 연구자들에 의해 주장되어 온, 밀링공정의 고차 AR 모델링의 필요성을 불식시킬 수 있으리라 사료된다. 모델링 방법으로는 매 샘플링순간 적응적으로 모델계수를 개선하기 위해서, 망각계수를 이용한 불신측정을 갖는 RLS로 수행하였다. 이 적응알고리즘은 모델링을 위한 컴퓨터의 메모리 문제를 없앨 뿐만 아니라 모델계수를 평가하는데 필요한 시간을 감소시키기 때문에 실제의 적용을 가능하게 한다.

한편, 샘플링 주파수는 절삭속도와 인서트의 갯수에 따라 변화하는 공구의 통과주파수의 처음 세번째 정도의 하모닉 성분을 포함시키도록 조절되어야 한다. 초기 적응이득값을 결정짓는 신뢰계수 α 는 모델계수의 빠른 수렴을 보장하기 위해서 1000으로 결정하였다. 망각율은 $\lambda_0 = 0.99$, 초기 망각계수는 $\lambda(0) = 0.9$ 가 적당했으며 이들 값은 모델계수의 수렴속도에 큰 영향을 미친다.

공구의 상태와 AR계수 사이는 강한 연관성이 있으며 이는 AR계수가 공구의 상태를 감시하기 위해 사용하는 특징으로 효과적임을 보여주는 것이다. 학습과 공구의 상태 분류는 다층구조를 갖는 신경회로망으로 된 분류기를 통하여 성공적으로 수행이 되었으며, 이 방법은 넓은 범위의 절삭조건하에서도 높은 성공율을 보였으며

따라서 실시간의 공구마모 감시방법으로 적당하다고 판단된다.

부 록

A. Autoregressive Power Spectrum⁽¹¹⁾

적절한 모델이 설정되고 나면, 정규화된 파워 스펙트럼을 다음과 같이 구할 수가 있다.

$$f(\omega) = \frac{\sigma_a^2}{2\pi} \frac{1}{\phi_n(e^{-i\omega}) \phi_n^*(e^{i\omega})} \quad (A1)$$

여기서 $\phi_n(e^{-i\omega}) = 1 - \phi_1 e^{-i\omega} - \dots - \phi_n e^{-in\omega}$ 그리고 $i = -1$ 이다. 이 스펙트럼은 모델계수에 의거하여 구한 것이기 때문에 본질적으로 매끈한 형상을 갖는다.

B. 신경회로망

그림 12와 같은 구조를 갖는 다층신경회로망^(13, 14)이 패턴분류를 위한 목적으로 사용된다. 구조는 입력층, 숨은 층 그리고 출력층으로 되어 있다. 숨은 층과 출력층은 뉴런과 시냅스라고 불리는 처리 유닛




Fig. 12 (a) Multilayer perceptron architecture and (b) Processing unit 2 on layer 2 (N= Number of processing units on layer 1)

(processing unit)와 연결고리(interconnection)를 갖고 있으며 여기에는 고유의 연결강도를 지니고 있다. 숨은 층의 수와 각 층에서의 노드수는 신중하게 선정해야 하며, 숨은 층과 노드의 수가 너무 적을 때는 신경망이 주어진 정보를 잘 모델링 할 수가 없으며, 너무 복잡한 구조는 학습이 어렵고 일반화(generalization)에 제약이 있기 때문에 새로운 패턴에 대해서 잘 작동하지 못한다. 노드라고 불리는 처리 유니트는 강도를 곱한 각각의 입력값에 바이어스값을 더해서 시그모이드 함수를 통과하여 출력을 만들어 낸다. 입력 층을 제외하고는 각 노드에 대한 총 입력은 그 전 층의 모든 노드의 출력값에 강도를 곱한 값들이다. 즉 k층의 j노드에 대한 총 입력은

$$net_j^k = \sum_i w_{ji}^k o_i^{k-1} \quad (B1)$$

따라서 k층의 j노드에서의 출력은

$$o_j^k = \frac{1}{1 + e^{-(net_j^k + \theta_j^k) / \theta_0}} \quad (B2)$$

여기서 w_{ji}^k 는 (k-1)번째 층의 i번째 노드에서 k번째 층의 j번째 노드 사이의 강도이다. 식 (B2)에서 계수 θ_j 는 바이어스 값으로 양의 값일 때는 수평축을 따라서 활성화 함수를 왼쪽으로 움직이게 한다. θ_0 는 그림 13과 같이 시그모이드의 형상을 수정하는 형상수정계수이다.

입력의 숨은 층을 갖는 다층구조 신경회로망에서 입력과 출력사이를 학습시키기 위해서는 오차역전파법을 사용한다(13). 이것은 감독학습으로서 입력패턴에 대해서 출력값을 구하고 이것을 목표값과 비교하여, 동일한 입력이 다음에 들어올 때는 목표값에 가까워지도록 연결강도의 값을 수정하는 방법이다.

일반적으로 출력값은 목표값과 같지 않고, 따라서 평균 시스템 오차를 다음과 같이 구할 수가 있다.

$$E = \frac{1}{2p} \sum_p \sum_m (t_{pm} - o_{pm})^2 \quad (B3)$$

여기서 p는 p번째 학습패턴이고, m은 m번째 출력노드를 나타낸다. 목적함수 식(B3)를 연결강도 w_j 에 대해서 최소화 시키는 것은 steepest-descent방법으로 가능하며 따라서 연결강도는 다음과 같이 개선된다.

$$w_j^k(n+1) = w_j^k(n) + \Delta w_j^k(n) \quad (B4)$$

여기서

$$\Delta w_{ji}^k(n) = -\eta \frac{\partial E}{\partial w_{ji}^k} \quad (B5)$$

알고리즘 (B4)와 (B5)는 단순히 현재의 강도를 steepest descent 방향으로 가도록 새로운 강도를 형성하는 것으로 그 정도는 학습율 η 에 의해서 조절된다. 큰 값의 η 는 빠른 학습을 가져오나 진동을 유발할 수가 있고 이것을 피하기 위해서 Rumelhart 등(13)은 모멘텀을 갖는 수정된 학습식을 제안했다. 즉,

$$\Delta w_{ji}^k(n+1) = -\eta \frac{\partial E}{\partial w_{ji}^k} + \gamma \Delta w_{ji}^k(n) \quad (B6)$$




Fig.13 The Sigmoidal activation function, with bias and shape modification.

여기서 (n+1)은 (n+1)번째 단계를 나타내는 것이고 γ 는 모멘텀율로서 (n+1)단계에서 학습되는 강도가 n번째 단계의 값과 심한 차이를 갖지 못하도록 하는 것이다. 여기서 바이어스 값 θ_j 역시 다른 연결강도와 같이 학습이 된다.

참고문헌

1. L. Dan, J. Mathew, "Tool wear and failure monitoring techniques for turning-A review", Int. j. Mach. Tools Manufact. Vol. 30, No. 4, pp. 579~598, 1990.
2. J. Tlustý, "A critical review of sensors for unmaned machining", Annals of the CIRP Vol. 32, pp. 563!~572, 1983.
3. C. L. Jiaa, D. A. Dornfeld, "On-line tool condition monitoring in face milling with

- Ootsuka, K. Matushima, T. Sata, "Real-time monitoring system of tool breakage using kalman filtering", *Robotics & Computer Integrated Manufacturing*, Vol. 2, No. 1, pp.33~40, 1985.
4. M. A. Elbestawi, T. A. Papazafiriou and R. X. Du, "In-process monitoring of tool wear in milling using cutting force signal", *Int. J. Mach. Tools Manuct.* Vol. 31, No. 1, pp.55~73, 1991.
 5. T. M. Teitenberg, A. E. Bayoumi, G. Yucesan, "Tool wear modeling through an analytical mechanistic model of milling processes", *Wear*, Vol. 154, pp.287~304, 1992.
 6. D. J. Waldorf, S. G. Kapoor, R. E. Devor, "Automatic recognition of tool wear on a face mill using a mechanistic modeling approach", *Wear*, Vol. 157, pp.350~323, 1992.
 7. S. M. Wu, "Dynamic data system : A new modeling approach", *ASME Journal of Engineering for industry*, Vol. 99, No. 3, pp.708~714, 1977.
 8. S. Takata, M. Ogawa, P. Bertok, J. acoustic emission", *Proceedings of the ASME Winter Annual Symposium on Computer-Aided Design and Manufacturing of Cutting and Forming/Forging Tools*, pp.45~53, 1989.
 9. S. Takata, T. Sata, "Model referenced monitoring and diagnosis-Application to the manufacturing system", *Computers in industry*, Vol. 7, pp.31~43, 1986.
 10. M. S. Lan, Y. Naerheim, "In-process detection of tool breakage in milling", *ASME Journal of Engineering for industry*, Vol. 108, pp.191~197, 1986.
 11. S. M. Pandit, S. M. Wu, *Time Series and System Analysis with Applications*, John Wiley & Sons, Inc., 1983.
 12. Ljung, T. Söderström, *Theory and Practice of Recursive Identificatin*, Cambridge, MA. : MIT Press, p.279, 1987.
 13. D. Rumelhart, J. McClelland, *Parallel Distributed Processing*, Vol. 1, Cambridge, M. A. : MIT Press, pp.318, 1986.
 14. Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Company, Inc., pp.113, 1989.