

정면밀링작업에서 절삭력을 이용한 On-Line 표면조도 감시에 관한 연구

백대균*, 고태조**, 김희술**

A Study of the On-Line Surface Roughness Monitoring Using the Cutting Force in Face Milling Operation

Dae Kyun Baek,* Tae Jo Ko**, Hee Sool Kim**

ABSTRACT

This paper presents the on-line monitoring of the surface roughness in a face milling operation. The cutting force was used to monitor the surface roughness, since the insert run-outs not only deteriorate surface roughness but also change cutting force. AR model and band energy method were taken to extract the features from the cutting force. The features extracted from AR modelling are more accurate about the monitoring than those from band energy method, whereas, the computing speed of the former is slow. An artificial neural network discriminated the level of the surface roughness by using the features extracted via signal processing.

Key Words : The surface roughness monitoring(표면조도 감시), AR model(자기회귀 모델),

Band energy method(밴드에너지법), Feature extraction(특징추출), Neural network(신경회로망)

1. 서론

정면밀링가공은 회전하는 공구에 대하여 가공물이 공구 축에 수직인 방향으로 상대적 운동을 하면서 절삭을 행한다. 밀링가공은 공구의 회전과 함께 절삭칩의 두께가 연속적으로 변화하는 단속절삭이고, 하나 이상의 절삭날이 동시에 절삭작용에 참여하게 되므로 절삭공정의 해석이 어렵다. 밀링공정에서 이상현상(Malfunction)이 발생하

게 되면 공작물의 가공정밀도가 저하되고, 공구 및 공작기계의 수명을 감소시킨다. 따라서 공작기계의 보호와 가공정밀도의 향상을 위해서는 밀링공정을 감시할 필요가 있다.

밀링가공의 이상진단에 관한 연구는 활발하게 진행되어 오고 있는데 그 중에서 공구마모와 파단 그리고 칩터에 관한 연구가 주류를 이루고 있다. 그러나 최근 공작기계의 이상상태의 온-라인(On-line)감시에 대한 연구가 활

* 영남대학교 금형기술 연구센터

** 영남대학교 기계공학부

발히 진행되어감에 따라 표면거칠기의 온-라인 감시도 요구되고 있다. 지금까지 표면조도의 측정은 촉침식, 광학식 등의 적절한 표면조도 측정장치를 이용하여 직접 가공 후에 측정하였다.

따라서 본 연구에서는 공구동력계를 이용하여 간접적인 방법으로 표면조도를 감시하고자 한다. 일반적으로 밀링 작업에서 인서트 런아웃은 표면조도와 절삭 단면적을 변화시키고, 절삭 단면적의 변화는 절삭력 신호로 나타나므로 절삭력으로 표면조도를 감시할 수 있다. 표면조도 감시에 관한 대표적인 연구들을 살펴보면 Shiraiishi는 선삭에서 레이저 빔을 이용하여 표면조도의 In-Process측정에 관하여 연구하였고⁽¹⁾, 김정두 등은 선삭에서 절삭력신호와 표면생성에 관한 연구에서 절삭력으로부터 표면의 특징을 알 수 있음을 보였다⁽²⁾.

본 연구에서 제안하는 표면조도 감시법은 먼저 표면조도 모델^(3,4,5,6)과 절삭력 모델^(7,8,9)로부터 표면조도와 절삭력을 시뮬레이션한 후 신호처리하여 표면조도의 변화에 따라 절삭력 신호에 어떤 특징이 나타나는지를 알아본다. 이러한 시뮬레이션으로부터 신호처리방법을 선정 한 후 절삭실험을 수행하여 절삭력으로부터 표면조도의 변화에 따른 특징을 추출(Feature Extraction)하여 감독형 신경회로망(Neural Network)에 학습하여 표면조도를 감시한다.

2. 신호처리 기법

공작기계가 고속화 되어감에 따라 빠른 시간내에 이상 상태를 진단해야 하는 데 본 연구에서는 대표적 신호처리 기법인 AR모델, 디지털필터를 이용하는 대역에너지들 각각 사용하여 절삭력 신호로부터 특징을 추출하고 서로의 장단점을 비교하고자 한다.

신호처리기법에서 추출된 특징은 일반적으로 단순하게 임계치를 이용하거나 패턴분류기(Pattern classifier)에 의하여 이상상태를 판정하기도 한다. 많이 사용되고 있는 패턴분류기로는 선형식별함수, 퍼지 알고리즘, 신경회로망 등을 들 수 있다. 본 연구에서는 샘플된 학습데이터로 먼저 학습시켜야 한다는 단점을 가지고는 있으나 표면조도의 정확한 감시를 위하여 감독형 학습알고리즘인 오차역전파 신경회로망을 패턴분류기로 이용한다.

2.1 시계열 분석

시계열 데이터로부터 구해진 수학적 모델은 자기회귀

이동평균(Autoregressive Moving Average) 모델이라 부르는 통계적 차분방정식으로 나타내고 ARMA(n,m)으로 표시한다⁽¹⁰⁾.

이때의 차분방정식은 다음과 같다.

$$\Phi(B)X_t = \Theta(B)a_t \tag{1}$$

여기에서

$$\Phi(B) = 1 - \varphi_1 B - \varphi_2 B^2 \cdot \cdot \cdot - \varphi_n B^n$$

$$\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 \cdot \cdot \cdot - \theta_m B^m$$

φ_i : Autoregressive parameter

θ_i : Moving average parameter

B : Back shift operator

$$E(a_t) = 0$$

$$E(a_t^2) = \sigma_a^2$$

신호의 Variance인 σ_a^2 을 푸리에 변환을 하면 측정 신호의 파워 스펙트럼을 식(2)와 같이 구할 수 있다.

$$S(f) = \frac{\sigma_a^2 \cdot \Delta t}{2\pi} \left| \frac{\Theta(B)}{\Phi(B)} \right|_2^2 \Big|_{B=\exp(-j2\pi f \Delta t)} \tag{2}$$

여기서 Δt 는 이산시간, f 는 주파수를 나타낸다.

ARMA 모델은 AR 모델보다 신호를 잘 모델링할 수 있으나 모델링을 할 때에 AR모델은 선형최소자승법을 이용하고 ARMA모델은 비선형최소자승법을 이용하므로 ARMA모델이 모델링에 시간이 더 많이 걸리게 된다⁽¹⁰⁾. 따라서 공작기계의 진단에서는 AR 모델을 많이 사용하고 있으며^(11,12), 본 연구에서도 On-line감시를 위하여 AR 모델을 이용한다.

2.2 디지털 필터에 의한 대역에너지

디지털 필터를 이용하여 관심의 대상이 되는 주파수만 통과시키거나 특정주파수를 저지한 후 파워를 구하면 FFT보다 연산속도를 빨리 할 수 있다. 절삭상태의 이상에 따른 특징은 특정대역의 주파수성분에서 두드러지게 나타나므로, 대역주파수 에너지법은 이 경우 효과적으로 이용할 수 있다. 특정 대역주파수의 에너지(E_{xBPF})는 다음과 같이 구할 수 있다.

$$E_{xBPF} = \int_{f_L}^{f_H} G_x(f) df \tag{3}$$

여기서 $G_x(f)$ 는 신호 $x(t)$ 의 파워스펙트럼 밀도함수이고, f_L, f_H 는 각각 관심의 주파수의 저역과 고역의 주파수를 나타낸다. 식 (3)은 FFT를 수행한 후 대역주파수에서 에너지를 추출하는 방법을 채택하고 있으므로 신호처리에 많은 시간이 걸리게 된다. 이 경우 디지털필터를 이용하게 되면 관심의 대상이 되는 대역주파수를 추출하여 시간영역에서 에너지값을 구할 수 있기 때문에, 계산시간이 짧아지게 되어 실시간 처리에 이용할 수 있는 장점이 있다. 그러나 필터는 리플을 가지게 되므로 정확도는 FFT에 미치지 못한다. 식(4)는 디지털 필터를 통과한 대역에너지를 나타낸다.

$$E_{xBPF} = \lim_{T \rightarrow 0} \frac{1}{T} \int_0^T x^2(t)_{BPF} dt \quad (4)$$

$$= \frac{1}{N} \sum_{n=1}^N x_n^2(t)_{BPF}$$

여기서 $x_n(t)$ 는 이산화된 데이터를 나타내고, T 는 시간, N 은 신호의 갯수이다.

3. 특징추출 (Feature Extraction)

인서트 런아웃을 변화시키면서 표면조도 모델^(3,4,5,6)과 절삭력 모델^(7,8,9)로부터 표면조도와 절삭력을 시뮬레이션하고 신호처리하여 표면조도의 변화에 따라 어떤 특징이 나타나는 지를 알아본다. 신호처리기법으로서 FFT, 8차 AR모델, 밴드에너지를 사용하여 절삭력을 신호처리하여 표면조도 감시를 위한 샘플링 타임과 대역주파수를 선택한다.

추축회전수 370 rpm, 이송속도 342 mm/min에서 인서트 런아웃값을 Table 1과 같이 점점 크게 변화시키면서 표면조도모델⁽⁶⁾로부터 표면조도를 시뮬레이션하여 Fig.1과 Fig.2에 도시하였다. Table 1의 런아웃값을 절삭력모델^(8,9)에 적용하여 절삭력을 시뮬레이션하여 Fig.3과 Fig.4에 나타내었다. Fig.1, 2에서 보는 것과 같이 인서트 런아웃이 심해짐에 따라 표면거칠기는 나빠지고, 최고 표면거칠기로 나타나는 표면조도값도 커지게 된다. Fig.3, 4의 절삭력들을 살펴보면 표면거칠기가 심해짐에 따라 절삭력의 변동이 점점 두드러지게 나타남을 알 수 있다. 이 절삭력들을 FFT를 행하여 Fig.5에 나타내었고, AR 8차의 모델링된 계수로부터 파워스펙트럼을 구하여 Fig.6에 도시하였다. Fig.5의 FFT를 살펴보면 모든

Table 1 The values of the axial and radial run-outs for simulation.

		(mm)				
		ϵ_1	ϵ_2	ϵ_3	ϵ_4	ϵ_5
a)	Axial run-out	0.000	0.000	0.000	0.000	0.000
	Radial run-out	0.000	0.000	0.000	0.000	0.000
b)	Axial run-out	0.005	0.000	0.000	0.010	0.000
	Radial run-out	0.005	0.000	0.000	0.010	0.000
c)	Axial run-out	0.010	0.000	0.000	0.020	0.000
	Radial run-out	0.010	0.000	0.000	0.020	0.000
d)	Axial run-out	0.020	0.000	0.000	0.030	0.000
	Radial run-out	0.020	0.000	0.000	0.030	0.000




Fig.1 Simulated surface profile with varying run-out

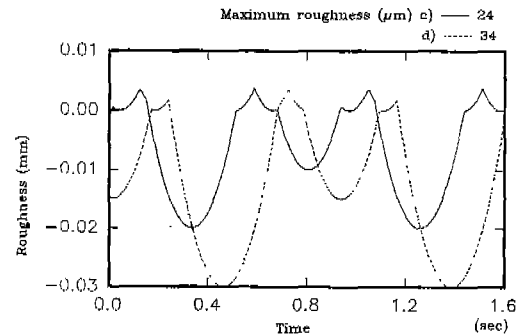


Fig.2 Simulated surface profile with varying run-out

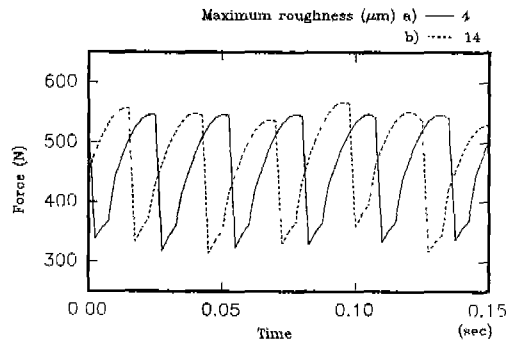


Fig.3 Simulated X-dir. forces with varying run-out




Fig. 4 Simulated X-dir. forces with varying run-out




Fig.6 AR spectrum of simulated forces

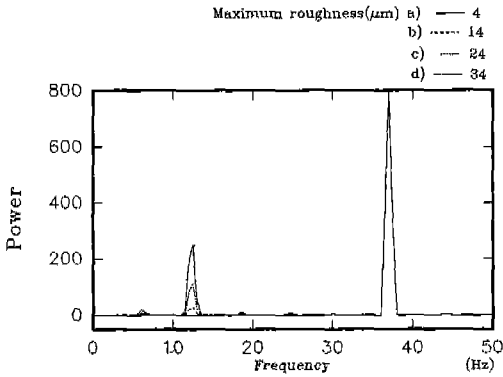


Fig. 5 FFT of X-dir. forces




Fig.7 Filtered X-dir. forces

경우에 인서트 통과 주파수(Hz)의 파워는 같고 그보다 저주파수는 표면의 악화와 함께 증가한다. Fig.6의 AR 스펙트럼을 살펴보면 표면조도가 나빠짐에 따라 인서트 통과 주파수의 파워는 작아지고 그보다 저주파수 영역의 파워는 증가한다.

Fig.5에서 보는 바와 같이 표면거칠기의 특성은 절삭력의 인서트 통과 주파수 앞쪽에서 나타나므로 실시간 신호 처리를 위하여 대역통과 필터(5-25Hz)를 사용하여 Fig.3, 4의 절삭력을 필터링하여 Fig.7에 모두 나타내었다. Fig.7의 절삭력을 FFT하여 Fig.8에 나타내었다. 그림에서 보는 바와 같이 표면조도가 악화될수록 절삭력의 변동이 심해지고 20Hz이상의 인서트 통과 주파수는 거의 나타나지 않으므로 이 필터된 절삭력을 식 (4)로 대역 에너지를 구하여 Table 2에 나타내었다. 표에서 보는 것과 같이 표면조도가 악화될수록 대역에너지는 증가함을 알 수 있다. Fig.8에서 살펴보면 5-25Hz 대역 주파수를

Table 2 Band energy of X-dir. cutting force.

Maximum surface roughness	Band energy (5 - 25Hz)
a) 4 μm	59 (N^2)
b) 14 μm	240 (N^2)
c) 24 μm	788 (N^2)
d) 34 μm	1712 (N^2)

사용하였는데 25Hz이상 주파수 성분이 약간 나타나는 이유는 필터특성상 완전한 필터링은 불가능하여 저주파수 성분이 약간 통과하게 된다. 그러나 본 연구에서는 이러한 영향은 통과 성분에 비해 미소하므로 무시할 수 있다.

따라서 샘플링 타임의 선정은 인서트 주파수를 인식할 수 있을 정도로 선정하고, 대역주파수는 인서트 통과 주파수보다 저주파를 선정한다.




Fig.8 FFT of filtered X-dir. forces

4. 실험장치 및 방법

수직밀링머신의 이송 테이블 위에 공구동력계를 고정하고 그 위에 시편을 고정하여 절삭실험을 수행하였다. Table 3은 실험장치에 대한 사양이다.

절삭실험에 사용된 밀링머신은 수직형이며, 커터는 직경 100mm의 삽입식(KTM415 SP04 R-12)으로 6개의 초경인서트(KT, SPGN1203)를 삽입하여 건식 절삭실험을 행하였다. 시험편의 재질은 기계구조용 압연강재(SS41)이다. 인서트 런아웃을 조정하기 위하여 수평정반 위에 지그를 놓고 그 위에 커터를 회전시키면서 다이얼 인디케이터로 런아웃을 측정하였다.

절삭력 측정을 위한 공구동력계는 압전식으로 고유진동수는 4KHz이다. 공구 동력계에서 측정된 절삭력 신호를

Table 3 Specification of experimental setup

Milling machine	Hwacheon WMV-1100 (1100 X 280 mm)
Tool dynamometer	Kistler(type 9257A)
Cutter	Korea Tungsten M415SP04 R-12
Insert	SPGN 120304, 120308 P20
Workpiece	130 x 77 x 45 mm
A/D converter	Data Translation DT2833 conversion rate:250KHz resolution:12bit
Oscilloscope	Tektronix(2202 storage)
Surface roughness tester	Mitutoyo Type EDM-R75C

전하 증폭기로 증폭한 후 A/D변 환기(Converter)를 통하여 컴퓨터에 저장하였다. 전하 증폭기의 필터는 1KHz 저역통과로 선택하였다.

공구동력계로 절삭력을 측정된 시편을 표면조도계로 표면거칠기를 측정하였다. 본 연구에 사용된 조도계는 축심식 조도계(Mitutoyo type EMD-R75C)로써 변위량에 비례하는 전압을 증폭기에서 증폭한 후 A/D 변환기를 통하여 컴퓨터에 저장하였다. 표면조도계의 Tracing속도는 3.0 mm/sec로 선정하였고, Cut off 값은 0.8 mm로 선택하였다.

표면조도 감시를 위하여 각 조건에서 측정된 절삭력신호를 2장에서 제시한 신호처리방법으로 각각 신호처리하여 입력파라메타로 하고 최고 거칠기의 한계값을 출력파라메타로 하여 신경회로망에 학습하였다. 학습된 가중치(Weight)를 이용하여 표면조도를 On-line감시하였다.

5. 표면조도의 On-Line감시

본 연구에 사용된 신경회로망은 감동형 학습으로 입력이 주어졌을 때 올바른 패턴값으로 출력하도록 연결강도(Weight)를 조정한다. 현재 가장 많이 이용되고 있는 감동형 학습 알고리즘인 오차 역전파(Back propagation of error)학습 알고리즘⁽¹³⁾으로 학습하여 연결강도를 구하였다.

Table 4에 나타낸 절삭조건에서 인서트를 매번 교환하여 한 절삭조건에서 20회씩 실험을 하여 X방향의 절삭력과 표면조도를 측정하였다. 절삭력의 샘플링 시간은 0.0025초이고 370rpm에서는 63개의 데이터를 신호처리하였고 520 rpm에서는 46개의 데이터를 신호처리하였다. 이 데이터 갯수는 샘플링 시간 0.0025초로 각 조건에서 1회전하는 동안에 획득한 신호에 해당된다.

본 연구에서는 On-line감시가 목적이므로 신호처리기

Table 4 Experimental conditions

Spindle rotation speed	370 rpm, 520 rpm
Table feed rate	127, 187, 267, 342 mm/min
Depth of cut	1, 2 mm
Milling type	Symmetric cutting
Number of insert	6
Sampling time	0.0025 sec
Number of data	46, 63

범 중에서 AR모델의 파라메타와 식 (4)의 대역 에너지(Band energy)를 이용하여 각각 2개의 신경회로망에 학습하여 그 성능을 비교, 검토하였다.

밀링절삭에서 일반적으로 날당 이송이 작아지면 표면조도는 좋아지고 반대로 날당 이송이 커지면 표면조도는 나빠지는데 본 연구에서는 아래와 같은 경우의 표면조도를 감시하였다. 즉, 절삭조건 370 rpm에서는 최고 거칠기가 20 μm 이하를 합격으로 판정하였고 520 rpm에서는 10 μm 이하를 합격으로 판정하였다. 370 rpm에서 20 μm 이하의 입력 패턴에 대하여 출력 패턴을 0.01으로 하였고 20 μm 이상의 입력 패턴에 대하여 출력 패턴을 0.99로 하여 학습하였다. 520 rpm에서도 마찬가지로 10 μm 이하의 입력 패턴에 대하여 출력 패턴을 0.01로 하였고 10 μm 이상의 입력 패턴에 대하여 출력 패턴을 0.99로 학습하였다.

입력노드(Node)수는 AR모델인 경우는 절삭속도, 이송속도, 절삭깊이, AR(8)모델의 파라메타, AR(8)모델의 Variance, 이상 총 12개를 입력변수로 하였다. AR계수를 제외한 나머지 입력변수들은 각 변수의 최고값으로 나누어 Normalized시켜서 학습하였다. 절삭속도는 520 rpm, 이송속도는 342 mm/min, 절삭깊이는 2 mm, Variance는 최고값으로 각각 나누어서 입력하였다. AR모델에서 차수를 8차로 선택한 이유는 차수가 너무 높으면 계산시간이 많이 걸리고 적으면 유용한 특징을 잡지 못하는데 8차가 적당하기 때문이다. AR(8)모델의 Variance를 입력변수로 선택한 이유는 식 (2)에서 보는 것처럼 Variance는 AR스펙트럼의 파워를 결정하기 때문이다. 대역 에너지 경우에 입력노드수는 절삭속도, 이송속도, 절삭깊이, 대역에너지 총 4개를 입력변수로 하였다. 370 rpm에서는 5 - 25 Hz의 대역에너지를 입력하였고, 520 rpm에서는 5 - 35 HZ의 대역에너지를 입력하였다.

절삭력의 신호처리에 AR모델을 사용할 경우에 입력층의 노드수는 12개이고 출력층의 노드수는 1개이다. 은닉층의 숫자와 노드수의 결정은 아직까지 정확한 방법은 제시되고 있지 않으므로 시행착오를 통하여 결정하고 있다. 본 연구에서는 은닉층을 1층으로 정하고 은닉층의 노드수를 변화시키면서 학습시킨 결과 은닉층의 노드수가 7개일 때 가장 에러(Error)가 작았다. 은닉층의 수를 1층으로 설정한 이유는 은닉층의 수가 2층이상으로 할 때 학습시간이 많이 걸리고 성능은 많이 개선되지 않았기 때문이고 신호처리 시간을 단축시키기 위한 목적이다. 따라

서 AR모델을 이용할 경우 신경망 구조는 12-7-1의 구조이고, 오차역전파 알고리즘으로 320쌍을 학습하여 가중치를 저장하였다. 저장된 가중치는 DSP보드에서 실시간 감시에 이용되었다. Table 5에 AR모델의 신경회로망 구

Table 5 Learning parameters and structure of neural network for AR(8).

Learning condition	Learning rate : 0.9 Momentum rate : 0.7 Learning iteration : 50000 Input samples : 320
Input layer node	12 : RPM, Feed rate, Depth, AR(8) Parameters, Variance
Hidden layer node	7
Output layer node	1 : Normal = 0.01 Abnormal = 0.99

Table 6 Learning parameters and structure of neural network for band energy.

Learning condition	Learning rate : 0.9 Momentum rate : 0.7 Learning iteration : 50000 Input samples : 320
Input layer node	4 : RPM, Feed rate, Depth, Band energy
Hidden layer node	12
Output layer node	1 : Normal = 0.01 Abnormal = 0.99

조 및 학습파라메타를 나타내었다.

절삭력의 신호처리에 밴드에너지를 이용할 경우에 입력노드수는 4개이고 출력노드수는 1개이다. 은닉층을 1층으로 정하고 은닉층의 노드수를 변화시키면서 학습시켜 은닉층의 노드수를 12개로 선정하였다. 대역에너지의 신경망 구조는 4-12-1의 구조이고, 오차역전파 알고리즘으로 240세트 학습하여 가중치를 저장하였다. Table 6에 대역에너지의 신경망 구조 및 학습파라메타를 나타내었다.

절삭실험을 수행하여 신경망모델에 학습한 가중치를 이용하여 On-line감시시스템을 구축하였다. 실험을 통하여 구한 가중치를 입력하고 절삭조건과 X방향의 절삭력을 신호처리하여 구한 파라메타들로 구성된 입력패턴을 신경망에 통과시킨다. 신경망의 출력값이 0.5 이상이 면

D/A의 첫번째 채널에 5V를 출력하여 LED를 켜고 동시에 PC화면에 "Roughness condition = Abnormal"을 출력한다. 출력값이 0.5 미만을 나타낼 때는 0V를 출력하여 LED를 Off상태로 하고 PC화면에 "Roughness condition = Normal"을 출력한다. 이와 같이 감시하여 본 결과 370rpm에서 20 μ m의 근처에서 생성되는 절삭력의 신호와 520rpm에서 10 μ m의 근처에서 생성되는 절삭력의 신호에서는 정상을 나타내는 신호와 비정상을 나타내는 신호를 불규칙적으로 출력하므로 상태를 판단하기가 어렵다. 따라서 5회전마다 한번씩 표면조도 상태를 출력하게 하였다. 신경회로망으로부터 나오는 출력값을 5회 동안 합산하여 3.0이상이면 D/A의 채널에 5V를 출력하여 LED를 켜고 동시에 PC 화면에 "Roughness condition = Abnormal"을 출력한다. 5회마다 합산한 값이 3.0 미만을 나타낼 때는 0V를 출력하여 LED를 Off상태로 하고 PC 화면에 "Roughness condition = Normal"을 출력한다. 공구의 파단을 감시하는 경우 실시간 감시가 필요하므로 매 회전마다 공구상태의 이상여부를 판단해야하고 정확한 감시가 필요하지만 표면조도는 완전한 실시간 감시보다는 현재 작업중에 인식한다는 개념이 더 중요하므로 5회전마다 표면조도의 상태를 출력해도 상관 없을 것으로 생각된다.

인서트 런아웃을 변화시키면서 표면조도의 감시 상태를 PC화면 과 LED를 살펴보고 시편을 표면조도계로 측정하였다. 절삭속도 370 rpm의 경우 인서트 런아웃이 심하여 20 μ m보다 표면조도가 많이 나쁜 경우와 20 μ m보다 아주 좋은 경우는 신호가 명확하게 구분되므로 잘 감시할 수 있었다. 그러나 20 μ m부근에서는 5회전마다 출력함에도 불구하고 신경회로망에서의 출력값이 절삭작업이 진행되는 동안에 정상신호와 비정상신호를 불규칙적으로 출력한다. 따라서 절삭작업중에 5회전마다 한번씩 표면조도의 상태를 표시하여 한번이라도 비정상 신호가 발생하면 이송속도를 낮추어 실험을 하였다. 즉, 이송속도를 계속 낮추어 가면 결국 정상신호만 출력하게 된다.

Fig.9는 370 rpm, 이송속도 342mm/min에서 표면조도가 14 μ m일 때의 절삭력 신호와 26 μ m일 때의 절삭력 신호를 나타내었다. 그림에서 보는 바와 같이 b)의 26 μ m에서는 인서트 런아웃이 심하게 발생하여 절삭력이 a)의 14 μ m보다 크게 변동함을 알 수 있다. a)의 신호에서는 절삭작업 중에 감시상태는 모든 경우




Fig.9 Y-dir. forces of normal and abnormal roughness.

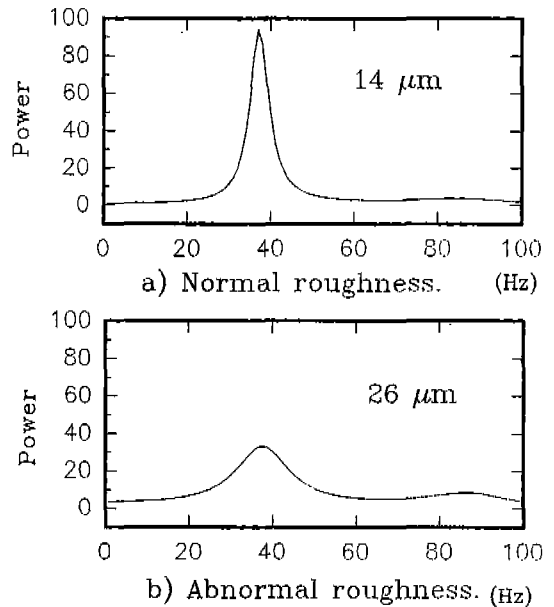


Fig.10 AR(8) spectrum of normal and abnormal roughness.

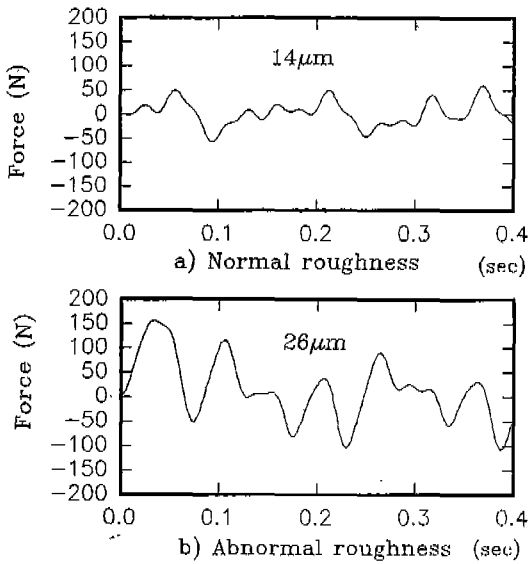


Fig.11 Filtered forces of normal and abnormal roughness.

에 정상임을 PC화면과 LED는 표시하였고, b)의 신호에서는 비정상임을 표시하였다. Fig.10은 절삭력 신호의 AR(8)스펙트럼으로써 26µm에서는 인서트 주파수가 감소하고 저주파수가 커지고 있다. Fig.11은 절삭력을 대역 필터링(5-25 Hz)하여 나타내었는데 26µm의 필터된 절삭력이 크게 나타남을 알 수 있다.

AR(8)모델로 신호처리를 수행하였을 경우에는 표면조도가 문턱값보다 클 때와 작을 때에는 비교적 정확하게 감시하였고 문턱값 부근에서는 에러를 발생하였다. 그러나 밴드에너지의 경우에는 AR(8)모델보다 더 많은 에러를 발생하였다. 계산시간은 디지털필터에 의한 대역에너지가 AR모델보다 더 짧았다. 따라서 표면조도의 감시는 계산시간에 민감하지 않으므로 AR모델링된 데이터로부터 신경회로망을 학습하여 감시하는 것이 효과적일 것으로 사료된다.

6. 결 론

정면밀링작업에서 절삭력을 신호처리하여 특징을 추출하여 신경회로망 모델에 입력하여 표면조도를 감시한 연구에서 다음과 같은 결론을 얻었다.

1. 밀링커터에서 발생하는 인서트 런아웃은 표면조도를 변화시키고 또한 절삭력을 변화시키므로 절삭력을 이용하여 표면조도를 감시할 수 있음을 알 수 있었다.

2. 인서트 런아웃의 변화에 따라 표면조도 모델과 절삭력모델을 이용하여 표면조도와 절삭력을 시물레이션해본 결과 표면조도의 특징은 주파수 영역의 절삭력에서 인서트 통과 주파수보다 저주파수에 나타났다.

3. 절삭력을 이용한 표면조도의 On-line 감시에서 계산시간은 디지털필터에 의한 대역에너지가 AR모델보다 더 짧았고, 특징추출의 정확성은 AR모델이 우수하였다.

참 고 문 헌

1. Shiraiishi, M., "In-Process Measurement of Surface Roughness by Laser Beam", ASME J. of Eng. for Ind., Vol. 103, pp. 203-209, 1981.
2. 김정두, 이은복, "절삭력 신호를 이용한 공구운동의 모델링과 고정도 표면생성에 관한 연구", 대한기계학회논문집, 제17권, 제8호, pp. 1951-1962, 1993.
3. Elbestawi, M. A., Ismail, F. and Yuen, K. M., "Surface Topography Characterization in Finish Milling", Int. J. Mach. Tools Manufac., Vol. 34, No. 2, pp. 245-255, 1994.
4. 김병희, 주종남, "자유곡면의 정밀가공을 위한 표면거칠기의 정량적 해석에 관한 연구", 대한기계학회 논문집, 제18권, pp. 1483-1495, 1994.
5. 김병희, 주종남, "3축 머시닝센터와 치구를 이용한 금형의 정밀 가공시의 특성해석", 한국정밀공학회지, 제12권, 제3호, pp.119-129, 1995.
6. 백대균, 고태조, 김희술, "정면밀링가공에서 표면조도 모델 개발", 한국정밀공학회지, 제12권, 제12호, pp. 149~156, 1995.
7. Fu, H. J., Devor, R. E. and Kapoor, S. G., "A Mechanistic Model for Prediction of the Force System in Face Milling Operation", ASME J. of Eng. for Ind., Vol. 106, pp. 81-88, 1984.
8. 김희술, 이상석, 이병철, "정면밀링작업에서 동절삭력 해석", 대한기계학회논문집, 제16권, 제12호, pp. 1807-1815, 1992.

9. 이병철, 백대균, 김희술, "평균 비절삭저항을 이용한 정면 밀링의 동절삭력 모델 개발", 한국정밀공학회지, 제8권, 제8호, pp. 39-52, 1995.
10. Wu, S. M. and Pandit, S. M., Time Series and System Analysis with Applications, Jhon Wiley and Sons, 1983.
11. Takata, S., Ogawa, M., Bertok, P., Ootsuka, J., Matushima, K., and Sata, T., "Real-Time monitoring System of Tool Breakage Using Kalman Filtering", Robotics & Computer Integrated Manufacturing, Vol.2, No.1, pp. 33-40. 1985.
12. Lan, M. S., and Naerheim, Y., "In-Process Detection of Tool Breakage in Milling", ASME J. of Eng. for Ind., Vol. 108, pp. 191-197. 1986.
13. Neural Computing Theory and Practice, Van Nostrand Reinhold, 1989.