

〈논 문〉

# 절삭공정에서 Fault-tolerance 기능을 갖는 지능형 감시 및 제어시스템의 개발

최 기 흥\*

(1996년 7월 10일 접수)

## Development of a Fault-tolerant Intelligent Monitoring and Control System in Machining

Gi Heung Choi

**Key Words :** Supervisory Control(수퍼바이저 제어), Built-up Edge(구성인선), Tool Wear(공구마모)

### Abstract

The dynamic characteristics of industrial processes frequently cause an abnormal situation which is undesirable in terms of the productivity and the safety of workers. The goal of fault-tolerance is to continue performing certain activities even after the failure of some system components. A fault-tolerant intelligent monitoring and control system which is robust under disturbances is proposed in this paper. Specifically, the fault-tolerant monitoring scheme proposed consists of two process models and the inference module to preserve such a robustness. The results of turning experiments demonstrate the effectiveness of the fault-tolerant scheme in the presence of buildup edge.

### 1. 서 론

생산공정이 갖고 있는 다양한 동적(dynamic) 특성은 어떠한 비정상적인 상황도 발생시킬 수 있으며, 이는 곧 생산의 효율성을 저해하고 작업자의 안전을 방해할 수 있다. 이때, 현장 작업자의 대처 방법은 매우 느리고 불완전한 경우가 대부분이다. 따라서, 사전계획 뿐만 아니라 비정상 상황 발생 이후에 어떻게 대처하는가도 생산공정의 자동화 뿐만 아니라 작업 안전의 관점에서도 대단히 중요하다. 비정상 상황이 발생했을 때, 지능형 감시 및 제어시스템은 우선 즉각적인 조치(reaction)가

필요한가를 판단하고 필요시 이를 즉각 수행해서 현장에서의 운영상태를 정상화할 수 있는 Fault-tolerance 기능을 확보해야 한다. 즉, Fault-tolerance 확보의 궁극적인 목적은 시스템 일부의 성능이 저하되거나 정지되어도 정해진 생산 활동을 지속할 수 있도록 하는 데 있다.<sup>(1,2)</sup> 또한, 이와 같은 상황의 여파가 다른 공정에 파급되는 것을 막는 목적도 있다. 일반적으로, 절삭공정에서 지능형 제어를 기능에 따라 분류하면 Servo 제어, Process 제어, 그리고 Supervisory 제어의 3 계층으로 분류할 수 있다.<sup>(3)</sup> Fig. 1는 제어기의 기능별 데이터 형태를 도시하고 있다.

공정모델에 근거한 지능형 감시 및 진단시스템의 개발에 관한 연구 결과가 참고문헌 (4), (5)에 보고된 바 있다. 참고문헌에서는 다이아몬드공구를

\* 회원, 한성대학교 산업시스템공학부

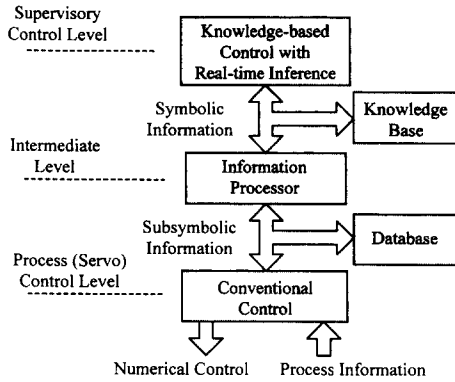


Fig. 1 Data structure of a control system in turning

사용한 선삭공정에서 절삭력 신호로부터 가공물의 표면특성을 예측하는 물리적인 모델 (mechanistic model)과 이를 토대로 가공 표면의 품질, 공구마모(다이아몬드공구와 같은 최성물질의 경우 일종의 미세한 파손으로 볼 수 있음), 그리고 가공기계의 동적특성을 실시간 감시하고 진단할 수 있는 방법이 제안되었다. 이때, 상대엔트로피(cross entropy)라고 불리는 정보량과 상대 엔트로피의 최소화 원리를 사용하였다.

본 연구에서는 이와 같은 결과를 보다 일반적인 선삭공정에까지 확장하고 supervisory 제어의 핵심인 Fault-tolerance 기능을 갖는 지능형 감시 및 제어시스템에 관하여 언급하고자 한다. 절삭공정중 발생하는 비정상상태로는 공구파손, 구성인선(built-up edge), 그리고 채터(Chatter) 등에 의한 감시 및 제어시스템의 불안정성을 들 수 있다. 이 중 구성인선의 생성은 완만하게 진행되고 공구파손이나 채터는 갑자기 발생하는 것이 보통이다. 공구파손, 채터의 감시에 관한 연구결과는 많은 연구자에 의해 발표된 바 있으며, 채터의 억제에 관해서도 많은 연구가 진행된 바 있다. 본 연구에서는 구성인선의 발생에 의한 시스템의 불안정성과 이와 연관된 Fault-tolerance 기능에 관하여 언급하고자 한다. 감시대상으로는 선삭공정중 발생하는 공구의 마모를 선정하였다.

## 2. Preprocessor

본 연구에서 제안된 시스템의 기능별 흐름도가 Fig. 2에 나타나 있다. 이 시스템은 크게 Preprocessor, Fault Detection Classifier, 그리고 Diag-

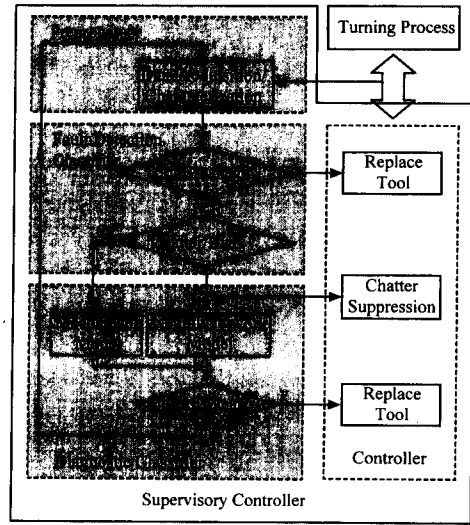


Fig. 2 Flow chart of a supervisory control in turning

nostic Classifier의 3부분으로 나누어져 있다.<sup>(6)</sup> Preprocessor에서는 센서로부터 입력된 신호의 상태를 고른다음 특성화한다. 선삭공정중 비정상상태의 발생여부를 판단하는 중요한 방법중의 하나는 정상상태와 불안정한 상태 사이의 천이과정에 민감한 신호의 특성을 찾아내는 것이다. 본 연구에서는 이와 같은 특성으로 엔트로피(entropy)와 상대엔트로피(cross entropy)의 개념을 적용하기로 한다.<sup>(4,5,7)</sup> 엔트로피는 어떤 시스템이 갖고 있는 정보량을 나타내며 고려되는 모든 사건  $k$ (확률  $q_k$ )에 대하여

$$E[q] = -\sum_k q_k \log \frac{1}{q_k} \quad (1)$$

로 나타낼 수 있다. 상대엔트로피는 엔트로피 개념을 사건  $k$ 에 대한 사전확률  $p_k$ (prior distribution)가 존재하는 경우에 대하여 확장한 것으로

$$H[q, p] = \sum_k q_k \log \left( \frac{q_k}{p_k} \right) \quad (2)$$

와 같이 주어진다. 식 (2)에 의하면 불규칙한 사건에 의해 얻어지는 정보량은 이미 알고 있는 확률  $p_k$ 에 의한 정보량과 현재의 확률  $q_k$ 에 의해 추가되는 정보량의 합이 된다. 이는 신호처리과정에서 기존의 정보를 활용할 수 있는 합리적인 방법을 제시하며 Fault-tolerance의 개념과 함께 환경의 변화에도 능동적으로 대처할 수 있게 함으로써 감시 및

제어시스템의 강건성을 확보할 수 있도록 한다.

이제,  $y_q, y_{q_i}, i=1,2$ 를 각각 현재의 측정데이터(절삭력 신호 또는 공정모델로부터 예측된 표면형상데이터), 그리고 미리 준비된 정상상태( $i=1$ ) 또는 공구마모시( $i=2$ )의 샘플패턴이라고 하자. 그러면,  $E[q], E[q_i]$ 는 각각  $y_q, y_{q_i}$ 의 진폭분포(amplitude distribution)로부터 얻을 수 있다. 즉, 엔트로피를 계산하기 위해 측정데이터의 최대(양), 최소(음) 진폭을 미리 정한 다음 이들 사이의 구간을 짝수개(10개)의 동일한 간격을 갖는 미소 구간으로 나누었다. 그런 다음, 절삭력신호의 중심선을 Fig. 3에서와 같이 최대, 최소 진폭의 중앙에 일치하도록 하였다. 그러면, 각각의 구간에 대한 확률분포를 구할 수 있고, 이로부터 엔트로피가 계산되었다.

상대엔트로피는 다음과 같이 계산된다.<sup>(8)</sup>

$$H[q, q_i] = \frac{1}{\sigma^2} \left\{ r_x(0) r_a(0) + 2 \sum_{s=1}^S r_x(s) r_a(s) \right\} + \log \sigma^2, \quad i=1,2$$

$$r_a(s) = \begin{cases} \sum_{k=0}^{s-s} a_k a_{k+s}, & s \leq S \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

$r_x(s), r_a(s)$ 는 각각  $y_q, y_{q_i}$ 의 자기연관함수 (autocorrelation function)이며,  $a_k$ 는 샘플패턴  $y_{q_i}$ 를 사용하여 얻어진  $S$ 차 AR (autoregressive) 모델의 계수이다.  $a_k$ 는 패턴벡터 (pattern vector)  $A_i = \{a_0, a_1, \dots, a_s\}$ 를 형성한다.

특정패턴  $i$ 에 대하여 다수의 측정데이터 또는 패턴벡터(예를 들면,  $N$ 개의 패턴벡터  $A_i^{(j)}; j=1, \dots, N$ )를 사용할 경우 중심벡터 (centroid,  $\bar{A}_i$ )를 구하여야 한다.  $\bar{A}_i$ 의 성분(components)은  $A_i^{(j)}$  성분의 산술적 평균을 구함으로써 얻을 수 있으며 이로부터  $H[q, \bar{q}_i]$ 을 구한다.<sup>(4,5,8)</sup> 마찬가지로,  $E[\bar{q}_i]$ 는 진폭분포의 평균( $\bar{q}_i$ )으로부터 계산할 수 있다.




Fig. 3 Probability distribution for amplitude density

### 3. Fault Detection Classifier

Fault Detection Classifier에서는 추론(inference) 기능을 활용하여 구성인선의 발생(fault)을 감시하고 Controller가 적절한 조치를 취하도록 한다. 즉, 구성인선의 발생이 과다할 경우에는 작업을 중단하고 공구를 교환하도록 하며, 이로 인한 chatter 발생시 이를 억제(chatter suppression)할 수 있는 기능을 가동시킨다.

#### 3.1 감시지수의 설정

본 연구에서는 Preprocessor에서 얻어진  $E[q], E[\bar{q}_i], H[q, \bar{q}_i]$ 를 이용하여 다음과 같은 감시지수 (monitoring index)를 정의한다.

$$MI[q, \bar{Q}_i] = H[q, \bar{q}_i] + \left| \log \frac{E[\bar{q}_i]}{E[q]} \right|, \quad i=1,2 \quad (4)$$

감시지수의 첫번째 항  $H[q, \bar{q}_i]$ 은 두 신호  $y_q, \bar{y}_{q_i}$ 간의 주파수 특성의 차이를 나타내며 특히 피크 (peak) 성분의 기여도가 크다. 참고문헌 (5)에 의하면 엔트로피 값은 측정데이터의 에너지 레벨과 선형적인 관계를 나타내며, 상대엔트로피는 특히 저주파 영역에서의 피크성분에 민감하다. 따라서, 구성인선의 발생에 의한 절삭력신호의 총에너지 증가는 저주파 성분에서의 에너지 증가에 기인하므로 식 (4)에 정의된 감시지수는 구성인선에 의한 동적 특성의 변화를 잘 반영한다고 할 수 있다. 일반적으로,  $H[q, \bar{q}_i]$ 는 측정데이터의 에너지 레벨에 의한 영향을 배제하기 위하여 두 신호  $y_q, \bar{y}_{q_i}$ 를 정규화하여 사용한다.

#### 3.2 패턴인식 (Pattern Classification)

구성인선의 발생여부를 판단하는 규칙은 다음과 같다.

(1) 선삭공정으로부터 얻어진 절삭력 신호를 사용하여  $MI[q, \bar{q}_i]$ 를 계산한다.  $i=1,2$ 는 각각 정상, 구성인선의 발생상태를 나타낸다.

(2)  $MI[q, \bar{q}_i] \leq MI[q, \bar{q}_j]$  for  $i \neq j$ 가 되는  $i$ 를 찾는다.

### 4. Diagnostic Classifier

Diagnostic Classifier는 공구마모를 감시하게 된

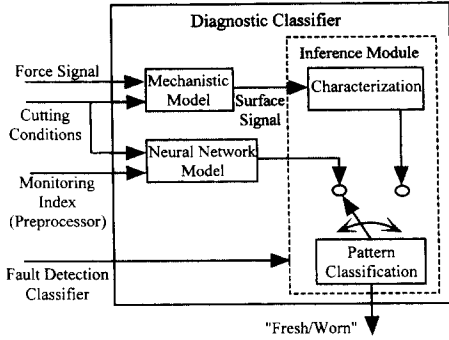


Fig. 4 Fault-tolerant diagnostic classifier in turning

다. 일반적으로, 공정모델에 근거한 감시 및 진단은 공정변수나 상태의 예측결과(parameter/state estimation)를 이용한다. 즉, 마모가 발생하면 이는 궁극적으로 공정변수나 상태의 변화로 나타나고 이를 측정, 판단함으로써 감시가 이루어진다. 본 Diagnostic Classifier는 Fig. 4에서와 같이 두 개의 공정모델과 추론모델로 구성된다. 이와 같은 구성의 목적은 동적특성이 변화하는 가운데서도 적절한 공정모델을 선택사용함으로써 Fault-tolerance를 확보할 수 있도록 하는데 있다.<sup>(9)</sup> 즉, 공정의 정상적인 운영중에는 주공정모델(main process model)을 사용하여 점진적인 공구마모를 감시하게 된다. 공정 운영의 이상 유무는 supervisory 제어기의 감시 기능(fault detection classifier)을 통해 매 시간간격마다 감시되며, 공정이상(Fault, 즉 구성인선)이 발생하면 보조모델(auxiliary model)을 선택하여 시스템의 강건성을 확보하도록 한다. 그러나, 이 경우 공정모델의 정밀도는 저하된다. 본 연구에서는 물리적 모델(mechanistic model)을 주공정모델로, 그리고 실험적 모델(empirical model)중 신경회로망 모델을 보조모델로 사용한다.<sup>(4)</sup>

참고문헌 (5)에 제안된 다이아몬드 선삭공정을 위한 주공정모델에 의하면 공작물 반경방향의 절삭력(radial cutting force)  $F_y(T)$ 는

$$F_y(T) = F_o + \Delta F_y(T) = \mu \left( H_a f t_1(T) + \frac{RK}{\alpha} \theta_{max} + \frac{RK}{\alpha^2 f} (e^{-\alpha f \theta_{max}} - 1) \right) \quad (5)$$

와 같이 주어지며  $\theta_{max}$ 는  $\cos \theta_{max} = 1 = t_1(T)/R$ 을 만족한다. 또한, 다이아몬드 선삭가공된 Al6061-

T6 표면의 경도는 다음과 같이 지수적으로 변화하는 것으로 알려져 있다.

$$H(t) = H_o + K e^{-\alpha t} \quad (6)$$

이때,  $H_o$ 와  $K$ 는 Al6061-T6에 대하여 각각 40 kg/mm<sup>2</sup>와 130.5 kg/mm<sup>2</sup>의 값을 갖는다. 상수  $\mu$ 는 공구-칩 사이의 마찰조건에 따라 변하는데 Al6061-T6에 대해서는 1.0에 가까운 값을 가지며  $\alpha$ 는 3.26이다.

이제, 보다 일반적인 절삭공정에 적용하기 위하여는 force model을 변경할 필요가 있다. 일반적으로,  $F_y(t)$ 와 절삭조건 사이에는 다음과 같은 관계가 성립한다:

$$F_y(T) = K V_w f a t_1^b(T) \quad (7)$$

$V_w, f, t_1(T)$ 는 각각 절삭속도, 이송속도, 순간적인 절삭깊이(instantaneous depth of cut)이며,  $K$ 는 비례상수이다. 선삭실험에 의하면 주어진 절삭속도에 대하여  $a \approx 1, b \approx 1$ 로 놓을 수 있다. 따라서, 순간적인 절삭깊이  $t_1(T)$ 를 공칭값( $t_o$ )과 이의 순간적인 변화량( $\Delta t_1(T)$ )의 합으로 표시하면(즉,  $t_1(T) = t_o + \Delta t_1(T)$ ) 위의 force model을 다음과 같이 표기할 수 있다.

$$F_y(T) = F_o + \Delta F_y(T) = K a f (t_o + \Delta t_1(T)) \quad (8)$$

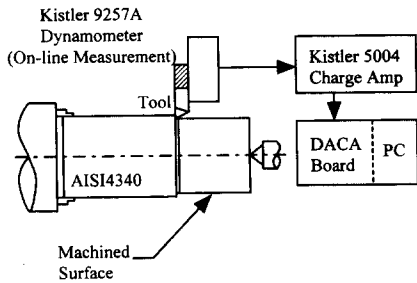
이 때,  $K_a = K V_w$ 이며,  $K$ 는  $F_y(T)$ 의 평균값과  $t_o$ 와의 실험적 관계로부터 구할 수 있다. 주공정모델을 사용하는 경우 입력된 절삭력 신호로부터 공작물의 표면형상이 실시간으로 예측되며, 이를 토대로 감시지수를 계산할 수 있다.

### 5. 실험 및 결과

본 연구에서 제안된 시스템은 실제 공정을 통하여 얻어진 실험데이터에 의해 그 성능이 평가되어야 한다. 이를 위한 절삭실험이 Kennametal사의 TPGF-322 K68 Tungsten Carbide 공구와 직경 102 mm의 AISI4340 원형봉 공작물을 사용하여 Tree-1000 Lathe에서 실시되었다. 실험의 편의상 공구의 여유면을 연삭가공하여 약 1 mm 정도의 마모면이 형성된 공구를 마모된 공구로 사용하였다. 또한, 직경 51 mm의 Al6061-T6 원형봉 공작물의 다이아몬드 선삭으로부터 얻어진 데이터를 비

**Table 1** Correct recognition rate for tool wear monitoring


	Conventional Turning	Diamond turning
Workpiece	AISI4340	Al6061-T6
Tool	Kennametal TPGF-322 K68	Kennametal TPG321
Cutting speed, m/min	76.2~106.7	191.5
Depth of cut, mm	0.127~2.032	0.051~0.203
Feed rate, mm/rev	0.254~1.778	0.051~0.203



**Fig. 5** Schematic diagram of experimental setup used in this study

교 목적으로 사용하였다. 실험에 사용된 절삭조건은 Table 1에 나타나 있다. 본 연구에 사용된 실험 장치는 Fig. 5에 도시되어 있으며, 자세한 실험 방법은 참고문헌(4,5,10,11)에 제시되어 있다.

본 연구에서는 우선 Fault Detection Classifier에서 비정상상황, 즉 구성인선의 감시에 관한 실험을 행하였다. 이를 위하여 식 (4)에 정의된 감시지수의 각 항들을 절삭력 신호에 적용하여 보았다. Fig. 6은 위의 절삭조건하에서 얻어진 절삭력신호로부터 계산된  $H[q, \hat{q}_1]$ 와  $\left| \log \frac{E[\hat{q}_1]}{E[q]} \right|$ 의 변화를 도시하고 있다. 구성인선의 발생에 따른 진폭분포의 변화와 주파수 성분의 변화가 명확하게 구분되어 나타나고 있다. 이는 Fault Detection Classifier에서 공정모델을 사용하지 않고 절삭력 신호의 특성화만으로도 추론할 수 있음을 말해 준다. 또한, Fig. 7에 나타나 있듯이 표면신호의 엔트로피 값은 에너지 레벨과 선형적인 관계를 나타내므로 식 (4)에서  $\frac{E[\hat{q}_1]}{E[q]}$ 은  $y_q, \hat{y}_q$ 의 에너지 레벨을 비교하는 것이 된다. 이 값이 1보다 크면  $y_q$ 의 에너지가  $\hat{y}_q$ 의 그것에 비하여 작은 것을 의미하며 1보다 작으면 반대이다. log 함수의 특성으로 보아




**Fig. 6** Variation of  $\left| \log \frac{E[\hat{q}_1]}{E[q]} \right|$  with  $H[q, \hat{q}_1]$  in turning

두 번째 항은  $\frac{E[\hat{q}_1]}{E[q]}$ 이 1보다 작을 때 급격히 증가한다. 즉, 샘플패턴의 에너지가 현재 측정데이터의 에너지보다 큰 경우가 반대인 경우 보다 감시지수에 크게 기여하게 된다.

다음은 Diagnostic Classifier에서 주공정모델 또는 보조모델을 이용하여 정상상태에서와 구성인선이 발생했을 경우에 대하여 공구마모의 판정률(correct recognition rate)을 검토하였다. 주공정모델의 입력은 절삭조건(절삭속도, 이송속도, 절삭깊이)과 절삭력신호이며, 출력은 가공표면의 형상(surface texture)데이터이다. 이로부터 감시지수를 정상, 마모상태에 대하여 각각 계산하고 앞에서 설명한 패턴인식의 과정을 거치게 된다. 감시성능의 평가에는 정상, 마모 패턴의 중심벡터에 의한

**Table 2** Correct recognition rate (%) for tool wear monitoring.

	Conventional turning (AISI4340)		Diamond turning (Al6061~T6)
	Normal	BUE	Normal
Mechanistic model	95	73	97
Neural network model	87	80	92




**Fig. 7** Variation of RMS values with the entropy calculated from the raw force signal in turning. The arrow represent the increasing depth of cut and feed direction.  $V_w=76.2$  m/min,  $t_1=0.127\sim 2.032$  mm,  $f=0.254\sim 1.778$  mm/rev

감시지수를 입력으로 사용하였다. AR 모델의 차수는  $S=5$ 이었다.

보조모델로 사용된 4-3-1 신경회로망의 입력으로는 Fig. 8에 나타난 바와 같이 절삭조건과 이들 절삭조건에 대응하는 감시지수가 사용되었다. 출력은 공구마모가 발생되었을 때 1, 정상일 때 0이 되도록 역전파법에 의해 학습되었다. 그러면 신경회로망의 출력이 0.5 이상일 때 공구마모로, 그 이하일 때에는 정상으로 판정된다.

Table 2은 일반적인 선삭과 다이아몬드 선삭에서의 공구마모 판정률을 나타내고 있다. 정상상태에서 공구마모의 판정률은 주공정모델을 이용한 경우가 신경회로망을 이용한 경우보다 높게 나타나고 있다. 특히, 다이아몬드 선삭과 같이 가공표면의 형상이 잘 정의되는 경우 주공정모델은 유효하다.<sup>(5)</sup>



**Fig. 8** Pattern classification of tool wear using neural network

그러나, 일반적인 선삭에서 구성인선 발생시 판정률은 보조모델을 사용한 경우가 다소 높게 나타남을 알 수 있다. 주공정모델은 공구의 선단의 형상이 정확히 유지된다는 조건하에서만 신뢰도가 보장된다. 그러나, 칩터가 발생하면 공구와 공작물이 순간적으로 격리되는 현상이 발생하고 공구삭이나 구성인선의 발생시에도 공구선단의 형상이 변하기 때문에 제안된 모델의 신뢰도는 감소하게 된다. 이 때, 판정률의 차이가 예상보다 크지 않은 것은 구성인선의 발생이 미미하기 때문인 것으로 판단된다. 구성인선의 발생이 명확해지면 판정률에도 영향을 미칠 것임을 예상할 수 있다. 따라서, 절삭상태에 따라 적절한 공정 모델을 선택함으로써 진단 및 감시시스템의 성능을 개선시킬 수 있다 하겠다.

## 6. 결 론

본 연구에서는 Supervisor Level에서 Fault-tolerance 기능을 갖는 감시 및 제어기의 기본 구조가 제안되었다. 특히, 감시 및 진단을 위한 신호의 특성화에 (상대)엔트로피로 표현되는 정보공학적 개념을 적용하였다. 이와 같이 정보공학적 개념

을 생산공정에 적용한 것은 정보량의 특성상 일관된 판단기준을 제시할 수 있고, 확률적 추론과 의사결정에 근거한 실시간 전문가시스템의 구현을 가능케 한다. 또한, Supervisory 제어의 개념중 공정 감시 및 진단시스템을 구현하기 위하여 두 개의 공정 모델과 추론 및 의사결정 모듈로 시스템을 구성하였다. 이와 같은 시스템 구성으로 동적특성이 변화하는 가운데서도 적절한 공정모델을 선택 사용함으로써 시스템의 성능을 개선시킬 수 있음을 보였다. 향후 연구과제로는 다수의 센서를 이용한 정량적/정성적 모델을 활용하여 시스템의 성능이나 운용을 환경에 맞게 변화시킬 수 있도록 하고, 절삭공정중 발생하는 설비의 Error 복구 기능을 구현하는 것을 들 수 있다. 또한, 본 시스템의 개발에 적용된 기술은 절삭공정 이외의 보다 일반적인 고분산형태를 갖는 생산공정에도 적용할 수 있을 것으로 사료된다.

## 후 기

본 연구는 학술진흥재단의 95년도 신진교수연구과제의 일부로 수행된 것으로 관계자께 감사드립니다.

## 참고문헌

- (1) Chintamaneni, P.R., Jalote, P., Shieh, Y. and Tripathi, S.K., 1988, "On Fault Tolerance in Manufacturing Systems," *IEEE Network*, Vol.2, No.3, pp.32~38
- (2) Albert, T. and Charles, R., 1986, "A Proposed Hierarchical Control Model for Automated Manufacturing Systems," *J. Manufacturing Systems*, Vol.5, No.1, pp.15~25
- (3) Stein, J., 1993, "Modeling and State Estimator Design Issues for Model Based Monitoring System," *ASME J. Dynamic Systems, Measurement, and Control*, Vol.115, pp.122~132
- (4) 최기흥, 1996, "절삭공정에서 Fault-tolerance 기능을 갖는 지능형 감시 및 진단시스템의 개발," 대한설비관리학회지, 제1권.
- (5) Choi, Gi H. and Choi, Gi S., 1996, "Application of Minimum Cross Entropy to Model-based Monitoring in Diamond Turning," *Mechanical Systems and Signal Processing*, Vol.10, No.5, pp. 615~631
- (6) Zhang, J., Martin, E. and Morris, J., 1995, "Fault Detection and Classification through Multivariate Statistical techniques," *Proc. American Control Conf., Seattle*, pp.751~755
- (7) Kullback, S., 1969, *Information Theory and Statistics*; Dover, NewYork
- (8) Shore, J. and Gray, R., 1982, "Minimum Cross Entropy Pattern Classification and Cluster Analysis", *IEEE Trans., Pattern Analysis and Machine Intelligence, PAMI-4*, pp.11~17
- (9) Ramamyrti, K. and Agogino, A., 1993, "Real-time Expert System for Fault-Tolerant Supervisory Control," *ASME J. Dynamic Systems, Measurement, and Control*, Vol. 115, pp.219~225
- (10) Choi, G.S., 1990, "Monitoring and Control of Machining Processes Using Neural Network," PhD Thesis, Department of Mechanical Engineering, University of California, Berkeley
- (11) 최기흥, 최기상, 1992, "선삭공정을 위한 지능형 실시간 공구 감시시스템에 관한 연구," 한국정밀공학회지, 제9권, 제4호, pp. 22~35