

공정프로파일 모니터링에서 웨이블릿기반 T^2 -검정과 신경회로망의 성능비교

Performance Comparisons of Wavelet Based T^2 -Test and Neural Network in Monitoring Process Profiles

김성준* · 최덕기

Seong-Jun Kim* and Deokki Choi

* 강릉대학교 산업시스템공학과

강릉대학교 정밀기계공학과

요약

최근 공정 및 계측기술이 발전함에 따라 밀링, 그라인딩, 브로칭 등 공정작업의 온라인 모니터링에 대한 관심이 높아지고 있다. 온라인 모니터링 시스템은 공구의 마모나 파손 등과 같은 공정변화를 가급적 조기에 발견함으로써 설비를 보호하고 불필요한 비용의 발생을 억제하는 데 그 목적을 두고 있다. 본 논문에서는 온라인 공정관측 데이터가 프로파일로 주어질 때 웨이블릿변환을 이용한 T^2 -검정과 신경회로망의 모니터링 성능에 대해 고찰한다. 2006년 Axinte가 제시한 절삭력 데이터를 이용하여 수치실험을 수행한 결과, 웨이블릿기반 T^2 는 양호한 검출력을 나타냈지만 그 검사특성은 자기상관에 매우 민감하게 반응하였다. 반면, 자기상관의 존재 하에서도 신경회로망은 T^2 -검정에 비해 매우 안정적인 검사특성을 갖는 것으로 나타났다. 이는 웨이블릿기반 T^2 -검정에 노이즈분석을 위한 적응적인 요소가 필요하다는 점을 시사한다.

키워드 : 프로파일 모니터링, T^2 -검정, 웨이블릿, 신경회로망, 검사특성곡선

Abstract

Recent developments of process and measurement technology bring much interest to the online monitoring of process operations such as milling, grinding, broaching, etc. The objective of online monitoring systems is to detect process changes as early as possible. This is helpful in protecting facilities against unexpected failures and then preventing unnecessary loss. This paper investigates, when the process monitoring data are obtained as a profile, the monitoring performances of a statistical T^2 -statistic and a feedforward neural network by using a wavelet transform. Numerical experiments using cutting force data presented by Axinte show that the proposed wavelet based T^2 -test has an acceptable power in detecting profile changes. However, its operating characteristic is very sensitive to autocorrelation. On the contrary, compared with T^2 -test, the neural network has more stable performance in the presence of autocorrelation. This indicates that an adaptive feature to analyze noises should be incorporated into the wavelet based T^2 -test.

Key Words : Profile Monitoring, T^2 -test, Wavelet, Neural Network, Operating Characteristic Curve

1. 서 론

공정 및 계측기술이 발전으로 제조공정의 자동화가 가속화되면서 생산성향상과 원가절감이 가능하게 되었다. 하지만 미세한 제조환경에서는 공정 상의 사소한 장애도 커다란 손실로 이어질 수 있으므로 공정관리기술의 역할이 한층 더 부각된다. 공정이상을 뒤늦게 발견하였을 때는 이미 많은 불량

품이 생산되었고 고가인 설비에도 악영향을 미쳤을 가능성 이 크기 때문이다. 따라서 제조공정을 효과적으로 모니터링 하고 문제점을 조기에 발견하는 것은 품질 및 생산성 뿐만 아니라 비용 관점에서도 대단히 중요하다. 통계적 공정관리 (SPC, Statistical Process Control)는 제조공정의 모니터링 문제를 통계적인 관점에서 다루어온 분야로서 공정에 이상이 발생했는지의 여부를 통계적 가설검정을 통해 판단하게 된다. 최근 Ding *et al.* [2]에 의해 논의된 바와 같이, 계측セン서기술의 발전으로 인해 공정 데이터의 실시간적인 수집이 용이해지면서 이러한 환경에 보다 적절하게 활용할 수 있는 SPC 기법에 대해 많은 관심이 모아지고 있다. 특히 어떤 관측점에서 관측데이터가 스칼라 혹은 벡터가 아니라 프로파일 그 자체로 얻어지는 경우에 SPC를 어떻게 수행할 것인가가 주요 이슈로 떠오르고 있다. 프로파일 데이터는 공정의 상태에 대해 보다 많은 정보를 내재하고 있다는 점에서 이를

접수일자 : 2007년 12월 12일

완료일자 : 2008년 11월 30일

* 교신저자

본 논문은 2007년도 정부재원 (교육인적자원부 학술연구조성사업비)으로 한국학술진흥재단의 지원을 받아 연구되었음 (KRF-2007-521-D00545)

효과적으로 모델링하고 분석하는 것은 차세대 제조환경을 위한 공정관리 현장에서도 큰 의의가 있다. 본 논문에서는 제조공정의 프로파일을 모니터링하기 위해 웨이블릿을 이용한 통계적인 T^2 -검정과 신경회로망에 대해 연구하고자 한다.

그림 1은 Axinte [1]에서 소개된 브로칭(Broaching)공정에서 관측된 절삭력 중의 하나인 Push-off Force(단위: kN)의 프로파일을 보여주고 있다. 브로칭이란 브로치(Broach)라 불리우는 공구를 이용하여 금속에 복잡한 모양의 홈을 내는 공정으로서 정밀도 있게 원하는 형상을 만들 수 있는지는 브로치 날의 마모상태에 크게 의존하게 된다. 절삭력은 브로치의 마모가 진행됨에 따라 증가할 뿐 아니라 칩이나 파손이 발생했을 때에도 불규칙적인 모습을 갖기 때문에 절삭력 프로파일의 모니터링은 공정작업의 문제점을 적시에 검출하는 데 매우 유용하다. 따라서 이와 같은 프로파일 데이터를 적절하게 다룰 수 있는 방법이 필요하게 된다. 그림 내의 4개 프레임은 각각 브로치 날의 4가지 상태 즉 정상, 마모, 깎임, 파손에 해당되는 절삭력 프로파일이다.

Hotelling에 의해 제안된 T^2 -검정은 관측해야 할 변수가 다수인 다변량 시스템의 SPC를 위해 널리 활용되어 왔다.

확률벡터 $y = (y_1, y_2, \dots, y_n)$ 가 평균이 $E(y) = \mu = (\mu_1, \mu_2, \dots, \mu_n)$ 이고 공분산이 $Cov(y) = \Sigma$ 인 다변량 정규분포(Multi-variate Normal Distribution)를 따른다고 할 때 T^2 는

$$T^2 = (y - \mu)^t \Sigma^{-1} (y - \mu) \quad (1)$$

과 같이 정의되고 이는 자유도 n 인 카이제곱(χ^2) 분포를 따른다. 따라서 다변량 SPC에서는, 공정에서 얻은 y 의 표본으로부터 계산된 T^2 가 $\chi^2_\alpha(n)$ 보다 크면 공정에 변화가 있다고 판단하게 되고 후속조치를 강구하게 된다. 단 $\chi^2_\alpha(n)$ 는 자유도가 n 인 카이제곱분포의 $100(1-\alpha)\%$ 분위수(Percentile)를 의미한다. T^2 -검정에 관한 자세한 내용은 참고문헌[3]을 보기 바란다.

프로파일이 선형으로 얻어질 때 Kang and Albin [4]은 회귀계수(Regression Coefficients)에 의한 T^2 -검정으로 수행되는 SPC 절차에 대해 연구하였다. 하지만 공정 프로파일이 선형으로 나타나는 경우는 매우 제한적이며 대부분은 그림 1과 같이 복잡한 모습을 갖게 된다. 그림 1의 절삭력 프로파일은 횡축 변수를 증가시켜 가면서 종축 반응변수를 연속적으로 관측한 형태이므로 동일 Unit을 갖는 다변량 데이터의 한 종류로 이해할 수 있다. 하지만 관측된 순서에 의미가 있고 (Ordered), 인접 데이터 간에 강한 상관관계가 존재하고 (Highly Correlated), 관측 데이터가 매우 많고 (with High Dimension), 불규칙적으로 변화하는 (Non-stationary) 등의 특징을 갖고 있어 앞서 소개한 T^2 를 그대로 적용하기에는 어려움이 있다 [5]. 이와 같은 문제점을 극복하고자 Jin and Shi [6]는 웨이블릿변환을 이용한 SPC 절차를 제안하였다. 웨이블릿변환은 그림 1과 같이 여러 피크를 가지면서 불규칙적으로 변화하는 신호를 모델링하는 데 널리 이용되어 온 방법으로서, Jin and Shi [6]는 프로파일 데이터를 직접 다루지 않고 웨이블릿변환을 통해 구한 웨이블릿계수로부터 T^2 를 계산하고 공정변화를 검출하고자 하였다. 또한 Fan [7]이 지적한 바와 같이 웨이블릿계수를 모두 고려하는 것은 검출력을 저하시키게 되므로 의미있는 웨이블릿계수를 선별할 필요가 있다. 최근 Jeong et al. [5]은 절대값이 일정크기 이상인 웨이블릿계수 만을 선

택적으로 받아들이는 Adaptive Thresholding 기법을 제안하고 이로부터 얻어진 T^2 통계량이 공정변화 검출력을 높이는 데 도움이 될 수 있음을 수치실험을 통해 보였다. 이처럼 다변량 SPC를 위한 대안으로서 웨이블릿기반 T^2 에 대한 관심이 점차 높아지고 있지만, 자동화 공정 중에 흔히 재되는 자기상관(Autocorrelation)을 고려한 연구는 부족한 실정이다.

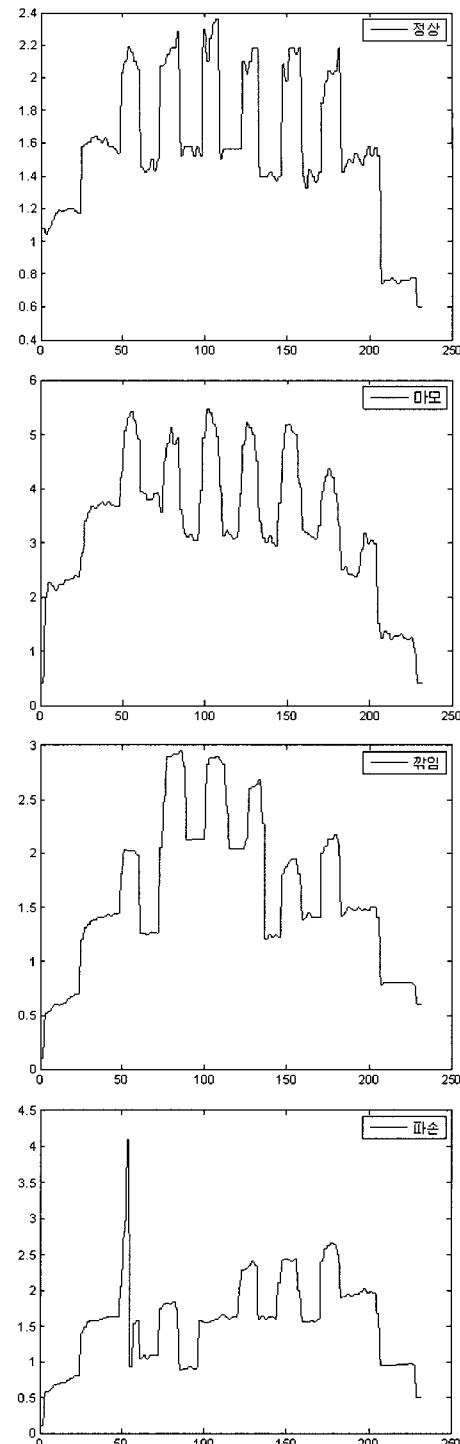


그림 1. 브로칭공정에서 절삭력 프로파일[1]
Fig. 1. Cutting Force Profiles in Broaching Process[1]

본 논문의 목적은 수치실험과 검사특성 (Operating Characteristic) 분석을 통해 자기상관이 웨이블릿 기반 T^2 에 미치는 영향을 고찰하고, 아울러 신경회로망을 이용할 경우 T^2 의 모니터링 성능을 높일 수 있는 방안을 연구하고자 한다. 다른 연구와는 달리 통계적 특징추출을 웨이블릿 영역에서 수행하는 것이 특징이며, 또한 SVM 학습에 요구되는 지배적 특징을 선별하기 위해 통계적인 방안으로서 분산분석 (Analysis of Variance)을 이용하는 절차를 제시하고자 한다. 아울러 Sugumaran et al. (2007, 2007)의 진동 실험 데이터를 이용하여 제안된 방법의 분류성능을 살펴보고자 한다.

2. 웨이블릿 기반 T^2 모니터링

2.1 웨이블릿변환과 T^2 -검정

1970년대 Morlet에 의해 제안된 웨이블릿은 다양한 스케일을 갖는 신호의 분석에 유용하다 [8]. 특히 불규칙적으로 변화하면서 급격한 피크를 갖는 신호를 다루는데 효과적이며 음성 및 영상 처리 뿐 아니라 최근에는 자동센서 신호에 대한 제조공정의 진단과 같은 문제에도 널리 활용되고 있다. 예를 들어, 배현 등 [9]은 진동센서에 의한 하수처리장비의 고장진단문제를 위해 웨이블릿변환을 이용하였고 Liao et al. [10]은 AE 센서신호에 대한 웨이블릿을 이용하여 연삭작업의 온라인 모니터링에 대해 연구하였다. 분석하고자 하는 함수 $f(t)$ 는 직교 웨이블릿을 통하여 다음과 같이 나타낼 수 있다.

$$f(t) \approx \sum_{k=0}^{2^L-1} a_{L,k} \phi_{L,k}(t) + \sum_{j=L}^{J-1} \sum_{k=0}^{2^j-1} d_{j,k} \psi_{j,k}(t) \quad (2)$$

단 $2^J = n$ 이고 L 은 스케일 분해수준 (Decomposition Level)을 의미한다. 식 (2)에서 $\phi_{L,k}(t)$ 와 $\psi_{j,k}(t)$ 는 각각 Father 웨이블릿과 Mother 웨이블릿을 나타내며 웨이블릿 계수인 $a_{L,k}$ 와 $d_{j,k}$ 는 $f(t)$ 와 웨이블릿의 내적으로 정의되는데 각각 다음과 같이 나타낼 수 있다.

$$\begin{aligned} a_{L,k} &= \int_R f(t) \phi_{L,k}(t) dt \\ d_{j,k} &= \int_R f(t) \psi_{j,k}(t) dt \end{aligned}$$

여기서 $\{a_{L,k}\}$ 와 $\{d_{j,k}\}$ 는 근사계수 (Approximation Coefficient)와 상세계수 (Detail Coefficient)에 각각 해당되고 이를 통해 신호의 Multi-resolution 분석이 가능해진다.

어떤 관측점 t_i 에서 프로파일 $y(t_i)$ 를 식 (3)과 같이 나타낼 수 있다고 가정한다.

$$y(t_i) = \mu_0(t_i) + \epsilon(t_i), \quad \epsilon(t_i) \sim N(0, \sigma^2) \quad (3)$$

단 $i = 1, 2, \dots, n$. 여기서 $\mu_0(t_i)$ 와 $\epsilon(t_i)$ 는 t_i 에서의 신호 참값과 노이즈를 각각 의미한다. 또한 노이즈 $\epsilon(t_i)$ 는 서로 독립이며 평균 0, 표준편차 σ 인 정규분포를 따른다고 가정한다. 새로운 프로파일 $y_f = (y_f(t_1), y_f(t_2), \dots, y_f(t_n))$ 를 얻었을 때 SPC에서는 통계적 가설검정을 통해 공정변동의 유무를 판정하는 문제를 다룬다. 귀무가설 H_0 는 공정에 변화

가 없다는 주장인 반면 대립가설 H_1 는 공정에 변화가 있다는 주장으로서 보통 다음과 같은 표현을 이용한다.

$$H_0: \mu_f = \mu_0 \quad \text{vs} \quad H_1: \mu_f \neq \mu_0$$

단 $\mu_f = (\mu_f(t_1), \mu_f(t_2), \dots, \mu_f(t_n))$ 이고 $\mu_0 = (\mu_0(t_1), \mu_0(t_2), \dots, \mu_0(t_n))$ 이다. 이 때 가설검정을 가장 널리 이용되는 검정통계량이 바로 Hotelling의 T^2 로서 다음 식 (4)와 같이 정의된다.

$$T^2 = \sum_{i=1}^n \frac{[\mu_f(t_i) - \mu_0(t_i)]^2}{\sigma^2} \quad (4)$$

이때, T^2 가 $\chi^2_\alpha(n)$ 보다 크면 귀무가설 H_0 를 기각하고 공정에 변화가 있다고 판정하는 것이다.

이제 식 (3)의 프로파일에 이산 웨이블릿변환을 적용하면 다음과 같이 변환결과 c 를 얻을 수 있다.

$$c = Wy = W\mu_0 + W\epsilon = \theta_0 + \xi \quad (5)$$

단 W 는 이산 웨이블릿변환행렬로서 $W^T W = I$ 를 만족하게 된다. 따라서 식 (5)의 오차항 $\xi = W\epsilon$ 은 $N(0, \sigma^2 I)$ 를 따른다. 결국 c 는 근사계수와 상세계수 벡터들을 차례대로 이어놓은 형태로서 다음과 같이 정리할 수 있다.

$$c = (a_{L,0}, \dots, a_{L,2^L-1}, d_{L,0}, \dots, d_{L,2^L-1}, d_{L+1,0}, \dots, d_{L+1,2^L-1}, \dots, d_{J,0}, \dots, d_{J,2^J-1}) \quad (6)$$

이제 새로운 프로파일이 주어졌을 때 변화가 발생하였는지를 판단하는 절차에 대해 살펴보자. 앞에서 언급한 대로 T^2 계산을 원래 프로파일 영역이 아니라 웨이블릿 영역에서 수행하게 된다. 이는 그림 1과 같이 공정프로파일 신호가 불규칙이고 급격한 피크를 다수 갖는다는 점을 전제로 한 것이다. T^2 -검정을 위해 식 (6)의 벡터로부터 선택된 웨이블릿을 $h = (h_1, h_2, \dots, h_n)$ 이라 하고 여기에 대응되는 웨이블릿을 식 (5)로부터 $\theta_0 = (\theta_{0,1}, \theta_{0,2}, \dots, \theta_{0,n})$ 이라 하면, T^2 는 다음과 같이 구할 수 있으며 역시 $T^2 > \chi^2_\alpha(n)$ 이면 공정에 변화가 있다고 판정한다.

$$T^2 = \sum_{j=1}^n \frac{(h_j - \theta_{0,j})^2}{\sigma^2} \quad (7)$$

2.2 예제

Liao et al. [10]이 지적한 대로, 프로파일을 다루는 데 있어 웨이블릿변환은 다른 대안에 비해 효율성이 높다는 장점이 있고 또한 웨이블릿의 계층적 구조는 다양한 문제를 다루는 데에도 적합하다. 특히 웨이블릿 영역에서 프로파일의 국부적인 변화가 분산되지 않고 드러나는 성질 ‘Localization Property’는 미세한 공정변화의 탐지를 가능하게 한다 [5]. 그림 1의 정상 프로파일에 $\sigma = 1$ 인 노이즈를 가미하여 웨이블릿변환을 적용한 결과는 다음과 같다. 이 결과는 Matlab에서 제공되는 wavemenu를 이용한 것으로 Haar 웨이블릿을 분해수준 3으로 적용하였다 [11].

그림에서 보는 바와 같이, 프로파일은 3개 수준으로 스케일 분해되었고 웨이블릿은 분해수준 별로 큰 차이가 있음을 알 수 있다. 이 경우 웨이블릿을 식 (6)과 같은 형식으로 나타내면 다음과 같다

$$c = (a_3, d_3, d_2, d_1) \quad (8)$$

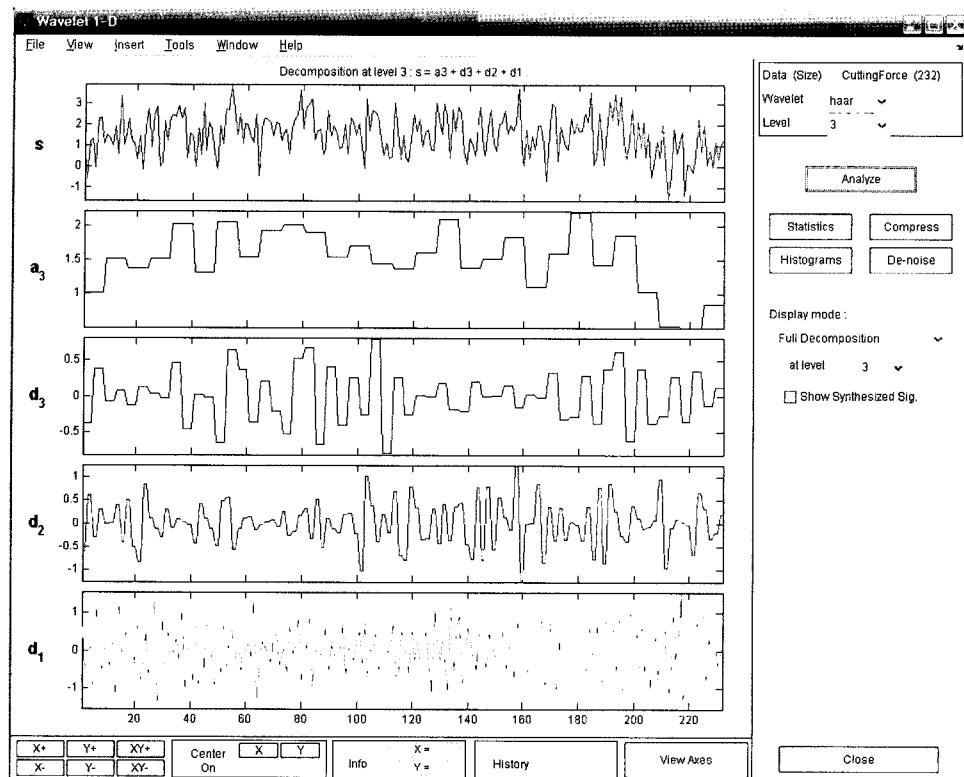


그림 2. 절삭력 프로파일의 웨이블릿분해
Fig. 2. Wavelet Decomposition of the Cutting Force Profile

식 (8)에서 4개의 벡터 a_3, d_3, d_2, d_1 은 각각

$$a_3 = (a_{3,1}, a_{3,2}, \dots, a_{3,29})$$

$$d_3 = (d_{3,1}, d_{3,2}, \dots, d_{3,29})$$

$$d_2 = (d_{2,1}, d_{2,2}, \dots, d_{2,58})$$

$$d_1 = (d_{1,1}, d_{1,2}, \dots, d_{1,116})$$

으로 정의되는 분해수준에 따른 웨이블릿이다. 그림 3은 이를 계층구조로 보여주고 있다.

의 프로파일은 변화가 없는 정상 프로파일이라고 결론지을 수 있다. 마찬가지로 (a_3, d_3) 와 (a_3, d_3, d_2) 에 대해서도 T^2 를 계산하면 다음과 같다.

$$T^2(a_2, d_2) = 40.764 < \chi^2_{0.05}(58) = 76.778$$

$$T^2(a_3, d_3, d_2) = 94.217 < \chi^2_{0.05}(116) = 142.138$$

역시 임계치를 초과하지 못하므로 프로파일에는 변화가 없다고 판단한다. 예제에 따라 다르겠지만 여기서는 분해수준에 따라 검정결과가 다르지 않았다. 그렇다면 T^2 -검정을 어떤 분해수준에서 적용하는 것이 더 바람직할까? 이에 관련된 실험적 고찰은 3장에서 이루어진다. 한편 d_1 에는 노이즈 성분만 남게 되므로 T^2 계산에는 포함시키지 않는 것으로 하였다. 설령 포함된다고 해도 자유도만 늘어나는 꼴이 되므로 T^2 -검정의 민감도를 저하시키게 된다.

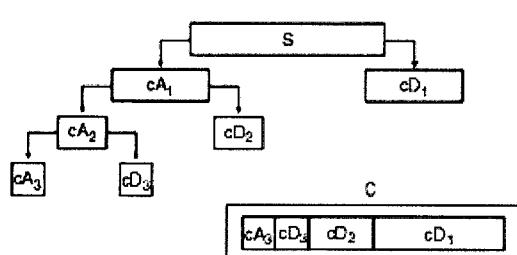


그림 3. 웨이블릿의 계층구조
Fig. 3 Hierarchical Structure of Wavelets

그림 2에서 얻어진 웨이블릿을 이용하여 T^2 -검정을 수행해 보자. 먼저 a_0 만 이용할 경우

$$T^2(\rho_0) = 16.327$$

가 된다. 이 값은 $\chi^2_{0.05}(29) = 42.557$ 보다 작으므로 그림 2

3 수치실험을 통한 성능비교

3.1 웨이블릿기반 T^2 의 검사통계 분석

앞의 예제에서, 노이즈가 가미된 정상 프로파일에 대해 웨이블릿에 의한 T^2 가 어떻게 반응하는지 알아보았다. 그렇다면, 프로파일의 일부에 변화가 발생했을 때에는 어떻게 될까? 이는 공정관리 실무에서 매우 중요한 관심사가 아닐 수 없다. 따라서, 프로파일의 변화량에 따라 T^2 -검정의 결과가 어떻게 변하는지 수치실험과 검사특성분석을 통해 살펴본다. 우선, 브로치의 마모가 진행됨에 따라 새롭게 관측된 절삭력 프로파일 $\cdot \cdot \cdot$ 를 다음과 같이 나타낸다.

$$y_f(t_i) = \mu_f(t_i) + \epsilon(t_i), \epsilon(t_i) \sim N(0, \sigma^2) \quad (9)$$

즉 프로파일 y_f 의 시점 t_i 에서의 평균 μ_f 는 마모에 의해 증가된 절삭력 프로파일을 의미하므로

$$\mu_f(t_i) = \mu_0(t_i) + k\sigma, t_i \in R \quad (10)$$

와 같이 나타내기로 한다. 단, k 는 프로파일의 증가량을 표현하기 위한 양의 상수로서 $k=0$ 은 곧 프로파일 y_f 에 변화가 없음을 의미한다. 또한 R 은 마모로 인해 프로파일 상에서 절삭력이 증가한 영역을 나타내는 Index Set이다.

T^2 -검정의 검사특성을 알아보기 위해 다음 표와 같이 4개의 인자를 고려하여 수치실험을 수행한다.

표 1. 수치실험을 위한 인자와 수준값

Table 1. Factors and Levels for Numerical Experiments

Factor	1	2	3
A. Code Size (h)	a_3	(a_3, d_3)	(a_3, d_3, d_2)
B. Noise (σ)	0.1	0.5	1.0
C. Autocorrelation (θ_1)	-0.3	0	+0.3
D. Region (R)	Large	Medium	Small

인자 A인 Code Size는 T^2 를 계산할 때 고려되는 웨이블릿 계수의 수준을 의미한다. 2장의 예제와 같이 a_3 , (a_3, d_3) , (a_3, d_3, d_2) 에 따라 T^2 의 성능이 어떻게 변화하는지 살펴본다. 역시 최하위 상세수준 d_1 은 고려대상에서 제외한다. 인자 B는 노이즈의 크기인 σ 를 말하며 그 값은 0.1, 0.5, 1.0으로 변화시켰을 때 T^2 -검정에 미치는 영향을 검토하게 된다. 인자 C는 자기상관이 존재할 때 T^2 의 성능을 보기 위한 것이다. 본 연구에서는 자기상관을 묘사하는 대표적인 모형 중 하나인 이동평균 (Moving Average)을 이용하기로 한다. 보통 MA(q)라 하면 차수가 q 인 이동평균모형을 말하는데 다음 식 (11)과 같이 표현된다.

$$z(t_i) = \epsilon(t_i) + \sum_{j=1}^q \theta_j \epsilon(t_{i-j}) \quad (11)$$

본 실험에서는 노이즈로서 우선 MA(1) 즉 $z(t_i) = \epsilon(t_i) + \theta_1 \epsilon(t_{i-1})$ 를 가정하고 θ_1 의 값으로는 -0.3, 0, +0.3 세 가지를 고려하기로 한다. 참고로, 다음 그림 4는 이에 따라 생성된 노이즈를 보여주고 있다. 인자 D는 프로파일 상에서 절삭력이 증가한 영역을 말한다. 작은 영역의 변화도 잘 감지할 수 있는지를 알아보기 위한 것으로, 실험에서는 대, 중, 소의 세 가지 크기로 고려한다. 이는 각각 $R = \{t_{46}, t_{47}, \dots, t_{63}\}$, $R = \{t_{49}, t_{50}, \dots, t_{60}\}$, $R = \{t_{52}, t_{53}, \dots, t_{57}\}$ 에 해당되는 것으로 한다.

실험에서 다룰 인자가 4개이고 각각 3가지 조건을 고려하게 되므로 총 가능한 실험점은 $3^4 = 81$ 가지가 된다. 하지만 실험규모가 너무 방대하다고 생각되어, 통계적인 실험계획법 (Design of Experiments)을 이용하여 실험점을 줄이고자 한다. 본 실험에서는 직교배열 (Orthogonal Array)을 이용하여 표 2와 같은 실험계획을 얻었다. 직교배열은 실험점을 줄이고자 할 때 널리 활용되는 실험계획 중 하나로, 본 실험에서 사용된 것은 $L_9(3^4)$ 이다. 직교배열에 관한 자세한 설명은 참고문헌 [12]를 참고하기 바란다.

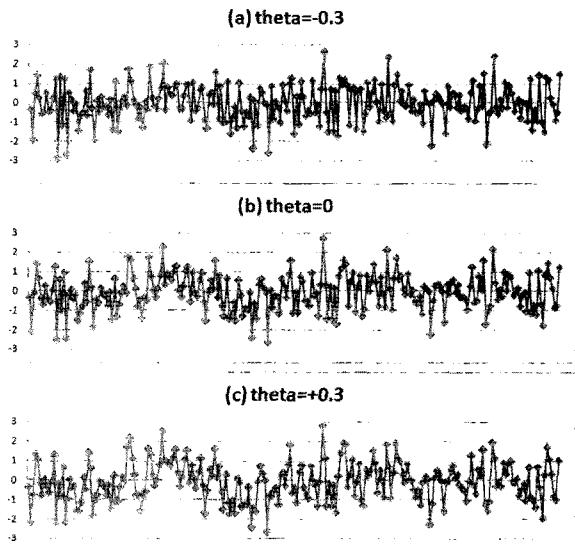


그림 4. MA(1)에 의한 노이즈
Fig. 4. Noise Examples Generated by MA(1)

표 2. $L_9(3^4)$ 에 의한 실험계획

Table 2. Design of Experiments by $L_9(3^4)$

No.	A	B	C	D	k						
					0.0	0.5	1.0	1.5	2.0	2.5	3.0
1	1	1	1	1							
2	1	2	2	2							
3	1	3	3	3							
4	2	1	2	3							
5	2	2	3	1							
6	2	3	1	2							
7	3	1	3	2							
8	3	2	1	3							
9	3	3	2	1							

표 2의 9개 조건에 대해서 해당 영역의 프로파일 평균을 $k\sigma$ 만큼 증가시키면서 T^2 의 검출력을 살펴본다. 일반적으로 검출력은 T^2 -검정에서 귀무가설 H_0 을 기각할 확률 혹은 프로파일 변화를 탐지할 확률로서 다음과 같이 정의된다.

$$P(k) = \Pr[T^2 > \chi^2_\alpha(\phi) | \mu_f(t_i) = \mu_0(t_i) + k\sigma, t_i \in R] \quad (12)$$

단 검정의 유의수준 α 는 5%로 고정시키기로 한다. 다음 표 3에는 600회의 시뮬레이션을 통해 얻어진 검출력 계산 결과가 제시되어 있다.

표 3의 결과로부터 인자 별로 평균 검출력을 구하고 이를 k 에 따라 도시한 것이 그림 5의 검사특성곡선이다. 검사특성곡선은 일반적으로 k 가 작을 때는 $P(k)$ 가 0에 가깝고 k 가 클 때에는 $P(k)$ 가 1에 가까운 것이 이상적이다. 인자 A인 Code Size의 경우는 첫 번째 조건 다시 말해 웨이블릿을 a_3 만 고려할 때가 검사특성이 가장 우수한 것으로 나타났다. 이 결과는 지나치게 많은 항의 웨이블릿을 고려하면 T^2 의 민감도를 저하시킬 수 있다는 기존 연구의 지적과도

일치하는 것이다. 인자 B는 노이즈의 크기를 말하는 것으로 $\sigma = 0.5$ 보다는 $\sigma = 0.1$ 혹은 $\sigma = 1.0$ 인 경우 검사특성이 좋은 것으로 나타났다. 인자 C 즉 자기상관의 영향은 매우 큰 것으로 나타났다. 자기상관이 없을 때 즉 $\theta_1 = 0$ 일 때에 매우 이상적인 검사특성을 보이지만 자기상관이 있을 때 특히 $\theta_1 > 0$ 일 때에는 작은 변화에도 민감하게 반응하고 있어 검사특성이 안정적이지 못하다. 마지막으로, 인자 D인 프로파일 변동영역은 그 크기가 어느 정도 이상이기만 하면 검사특성은 충분한 것으로 파악된다.

표 3. 수치실험에 의한 검출력 결과

Table 3. Results of P(k) by Numerical Experiments

No.	k						
	0.0	0.5	1.0	1.5	2.0	2.5	3.0
1	0.0000	0.0000	0.0683	0.8183	1.0000	1.0000	1.0000
2	0.0550	0.0867	0.3300	0.7733	0.9667	1.0000	1.0000
3	0.6117	0.6200	0.6950	0.8000	0.8850	0.9567	0.9783
4	0.0550	0.0550	0.1233	0.2350	0.4367	0.7217	0.9067
5	0.7683	0.8350	0.9433	0.9883	1.0000	1.0000	1.0000
6	0.0000	0.0000	0.0033	0.1300	0.7567	0.9983	1.0000
7	0.8117	0.8467	0.9433	0.9833	0.9950	1.0000	1.0000
8	0.0000	0.0000	0.0000	0.0050	0.0233	0.0967	0.3550
9	0.0517	0.0900	0.2617	0.7417	0.9700	1.0000	1.0000

3.2 웨이블릿 기반 T^2 와 신경회로망의 검사특성 비교

수치실험을 통해 3.1절에서 살펴본 결과, 웨이블릿 기반 T^2 는 ROC 관점에서 양호한 검출력을 보여주었다. 그러나 자기상관이 존재하는 경우에는 ROC 성능이 매우 불안정한 것으로 나타났다. 이는 노이즈를 통해 개입된 자기상관이 웨이블릿변환을 통해 d_1 뿐만 아니라 다른 분해수준으로도 확산되어 식 (7)의 T^2 추정에 편의(bias)를 가져온 때문으로 해석된다. 따라서 웨이블릿 영역에서 편의를 최소화하는 방안이 강구되어야 하지만 이 부분은 후속연구로 남겨두고 본 논문에서는 신경회로망을 이용하여 ROC성능을 개선할 수 있는지 수치실험을 통해 검토하기로 한다.

신경회로망은 다양한 분야에서 패턴분류 문제에 활용되어 온 대표적인 방법 중 하나이다. 따라서 프로파일 모니터링 위해서도 T^2 와 경쟁적 내지는 상호보완적 관계에 있다고 할 수 있다. 신경회로망의 여러 모델 중 본 논문에서는 다음 그림 6과 같은 구조의 다층퍼셉트론(Multi-layer Perceptron)을 이용하기로 한다 [13]. 그림에 나타냈듯이 입력층, 은닉층, 출력층의 뉴런은 각각 29개, 5개, 1개로 되어 있다. 입력층 뉴런이 29개인 것은 웨이블릿 벡터 a_3 만을 수치실험에서 다루기 때문이다.

또한 노이즈는 $\sigma = 1$ 로 두고 프로파일 변화영역은 표 1의 두 번째 조건으로 고정하였다. 우선 자기상관이 없는 경우 즉 $\theta_1 = 0$ 일 때, T^2 와 신경회로망의 검사특성곡선은 다음 그림 7과 같다. 이 결과 역시 600회의 수치실험으로 얻어졌다.

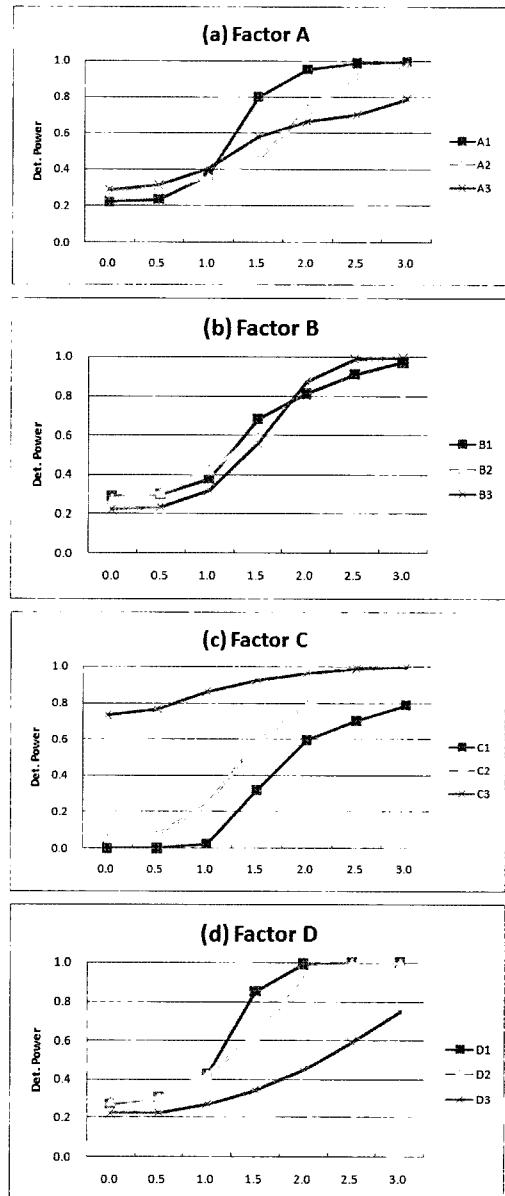


그림 5. 인자별 검사특성곡선

Fig. 5. OC Curves of Factors

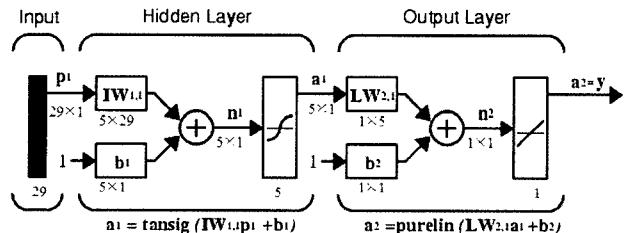


그림 6. 신경회로망 구조도

Fig. 6. Structure Diagram of the Neural Network

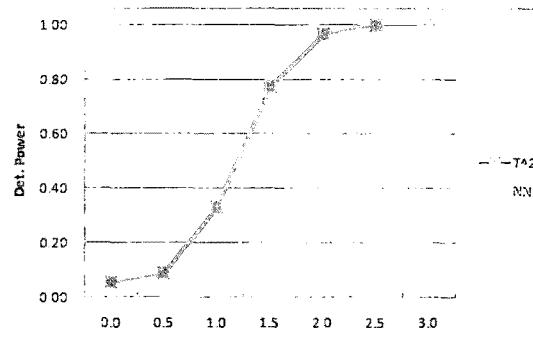


그림 7. $\theta_1 = 0$ 일 때 T^2 와 신경회로망의 검사특성곡선
Fig. 7. OC Curves of T^2 and the Neural Network when $\theta_1 = 0$

이 경우, T^2 와 신경회로망은 검사특성 측면에서 대체로 비슷한 결과를 보여주고 있다. 언뜻 보면 T^2 쪽이 프로파일 변화에 다소 민감하게 반응하는 것으로 보이지만 신경회로망 역시 학습과정 중에 변화판정의 기준치를 변경함으로써 전체적인 민감도를 조정할 수 있기 때문이다. 그렇다 하더라도, T^2 는 통계적인 유의성을 판단할 수 있는 근거를 제공하고 계산적으로도 간편하다는 면에서 장점을 찾을 수 있다.

그림 8(a)와 8(b)는 MA(1)의 경우 T^2 와 신경회로망의 검사특성곡선을 보여주고 있다. 여기서는 θ_1 을 좀 더 다양하게 -0.7, -0.3, +0.3, +0.7로 변화시켜 가면서 검출력을 계산하였다. 3.1절의 실험결과에서 밝혀진 바와 같이, T^2 의 성능은 불안정적이다. 특히 $\theta_1 = \pm 0.7$ 일 때 검사특성이 더

욱 극단적으로 나타나고 있으므로 자기상관이 심할수록 T^2 의 검출력을 신뢰하기 어렵다는 것을 알 수 있다. 한편, MA(2) 하에서 T^2 와 신경회로망의 검사특성곡선을 비교하기 위해 식 (11)로부터 노이즈를

$$z(t_i) = \epsilon(t_i) + \theta_1\epsilon(t_{i-1}) + \theta_2\epsilon(t_{i-2}) \quad (13)$$

과 같이 나타낸다. 단 θ_1 과 θ_2 는 $\theta_1 + \theta_2 < 1$, $\theta_2 - \theta_1 < 1$, $-1 < \theta_2 < 1$ 를 만족해야 하고 식 (13)의 분산은 $\sigma_z^2 = (1 + \theta_1^2 + \theta_2^2)\sigma^2$ 가 된다. 이에 대해 상세한 내용은 Box et al. [14]를 참조하기 바란다. 수차실험을 위한 θ_1 과 θ_2 는 그림 9와 같이 $\theta_1^2 + \theta_2^2 = 0.5$ 를 만족하도록 4개의 지점을 선택하였다. 이는 분산이 검사특성에 미치는 영향을 최소화하기 위함이다.

그림 8(c)와 8(d)에서 볼 수 있듯이 T^2 의 검사특성은 (θ_1, θ_2) 의 선택에 따라 크게 변하고 있다. 그중에서도 θ_2 보다는 θ_1 의 영향을 더 많이 받는 것으로 보이며 특히 $\theta_1 > 0$ 일 때에는 프로파일의 작은 변화에도 매우 민감하게 반응하는 것으로 나타났다. 또한 MA(1)과 비교했을 때에도 MA(2) 쪽이 보다 극단적인 검사특성을 보이고 있다. 한편 신경회로망의 검사특성은 MA(1)과 마찬가지로 (θ_1, θ_2) 에 따라 그리 큰 차이를 보이지 않는다. 역시 MA(2) 하에서도 역시 신경회로망은 T^2 에 비해 더 바람직한 검사특성을 갖는 것으로 나타났다.

4. 결 론

본 논문은 SPC 분야에서 프로파일의 모니터링을 위해

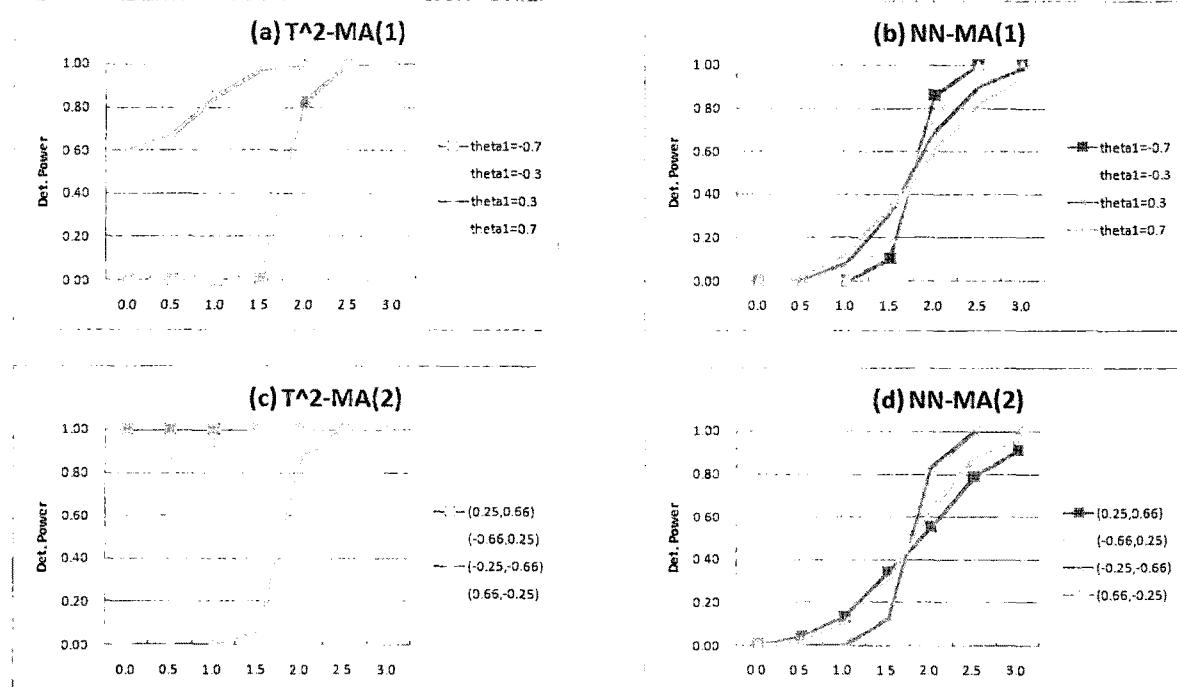


그림 8. MA(1)과 MA(2)에서 T^2 와 신경회로망의 검사특성곡선
Fig. 8. OC Curves of T^2 and the Neural Network under MA(1) and MA(2)

연구되고 있는 웨이블릿 기반 T^2 의 검출력에 대해 살펴보았다. 이를 위해, Axinte [1]의 절삭력 테이터를 이용한 수치실험을 수행하였으며 여러 인자를 동시에 다루기 위해 통계적인 실험계획법을 이용하였다.

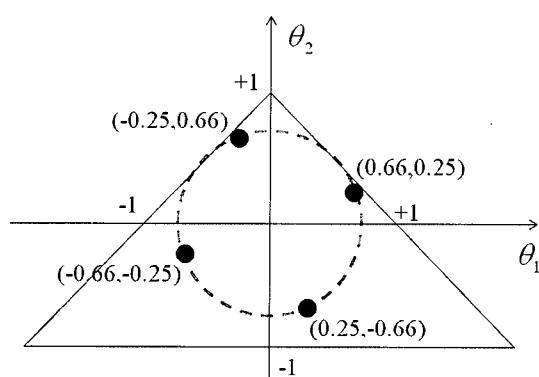


그림 9. 수치실험을 위한 (θ_1, θ_2) 의 실행가능영역
Fig. 9. Feasible Region of (θ_1, θ_2) for Numerical Experiments

실험결과, 근사수준의 웨이블릿 a_3 만 고려하더라도 T^2 -검정의 검사특성은 대체로 양호한 것으로 나타났다. 하지만 프로파일에 자기상관이 개입될 경우에는 웨이블릿 변환에 영향을 미치게 되고 따라서 T^2 -검정의 검사특성도 저하되는 것으로 파악되었다. 자기상관은 자동화된 공정에서 흔히 나타나는 현상 중의 하나이므로 웨이블릿 기반 T^2 모니터링은 이를 해결하기 위해 더 많은 연구가 있어야 할 것으로 판단된다.

아울러 신경회로망을 이용할 경우 검사특성에 차이가 나타나는지를 수치실험을 통해 알아보았다. 이동평균모형 MA(1)과 MA(2)를 이용하여 자기상관에 따른 영향을 검토한 결과, 신경회로망이 보다 안정적인 검사특성곡선을 갖는 것으로 나타났다. 자기상관이 없을 때와 비교해도 크게 차이가 나지 않는 것으로 볼 때, 신경회로망은 노이즈의 특성 변화를 적응적으로 잘 수용하고 있는 것으로 믿어진다. 이는 또한 웨이블릿 기반 T^2 모니터링에 적응적 요소가 필요하다는 점을 시사하는 것으로 그 의의가 있다고 판단된다. 한편, 프로파일의 모니터링을 통해 공정에 변화가 있다고 판정된 경우 그것이 어떤 변화였는지를 인식하는 문제 즉 프로파일의 온라인 분류도 공정관리 실무에서 중요한 문제이므로 프로파일의 모니터링 및 분류를 위한 웨이블릿 특징 추출에 대해서도 후속연구가 필요하다고 사료된다.

참 고 문 헌

- [1] D. A. Axinte, "Approach into the use of probabilistic neural networks for automated classification of tool malfunctions in broaching," *International Journal of Machine Tools and Manufacture*, Vol. 46, pp. 1445-1448, 2006.
- [2] Y. Ding, E. A. Elsayed, S. Kumara, J. C. Lu, F. Niu and J. Shi, "Distributed sensing for quality and productivity improvement," *IEEE*

Transactions on Automation Science and Engineering, Vol. 3, No. 4, pp. 344-359, 2006.

- [3] D. C. Montgomery, *Introduction to Statistical Quality Control*, Fourth Edition, Wiley, New York, 2001.
- [4] L. Kang and S. Albin, "On-line monitoring when the process yields a linear profile," *Journal of Quality Technology*, Vol. 32, pp. 418-426, 2000.
- [5] M. K. Jeong, J. C. Lu and N. Wang, "Wavelet-based SPC procedure for complicated functional data," *International Journal of Production Research*, Vol. 44, No. 4, pp. 729-744., 2006
- [6] J. Jin and J. Shi, "Feature preserving data compression of stamping tonnage information using wavelets," *Technometrics*, Vol. 41, pp. 327-339, 1999.
- [7] J. Fan, "Test of significance based on wavelet thresholding and Neyman's truncation," *Journal of American Statistical Association*, Vol. 90, pp. 1200-1224, 1996.
- [8] 이승훈, 윤동한, 알기 쉬운 웨이브렛 변환, 진한도서, 2002.
- [9] 배현, 최대원, 천성표, 김성신, 김예진, "시계열데이터마이닝을 이용한 하수처리연속회분식반응기 장비 진단," 퍼지 및 지능시스템학회 논문지, Vol. 15, No. 4, pp. 431-436, 2005.
- [10] T. Liao, C. Ting, J. Qu and P. J. Blau, "A wavelet-based methodology for grinding wheel condition monitoring," *International Journal of Machine Tools and Manufacture*, Vol. 47, pp. 580-592, 2007.
- [11] *Wavelet Toolbox*, The Math Works, 2006.
- [12] M. S. Phadke, *Quality Engineering Using Robust Design*, Prentice-Hall, 1989.
- [13] *Neural Network Toolbox*, The Math Works, 2006.
- [14] G. E. P. Box, G. M. Jenkins and G. C. Reinsel, *Time Series Analysis: Forecasting and Control*, 3rd Ed., Prentice Hall, 1994.

저 자 소 개



김성준(Kim, Seong Jun)

1989년 : 연세대학교 응용통계학과 학사

1991년 : 카이스트 산업공학과 석사

1995년 : 카이스트 산업공학과 박사

현재 : 강릉대학교 산업공학과 교수

관심분야 : 지능정보, 통계학습, 품질경영

Phone : 033-640-2375

Fax : 033-640-2244

E-mail : sjkim@kangnung.ac.kr



최덕기(Choi, Deokki)

1988년 : 서울대학교 기계설계학과 학사
1990년 : 서울대학교 기계설계학과 석사
1994년 : 서울대학교 기계설계학과 박사
현재 : 강릉대학교 정밀기계공학과 교수

관심분야 : 기계상태 검출 및 진단, 특수정밀가공

Phone : 033-640-2394

Fax : 033-640-2244

E-mail : choidk@kangnung.ac.kr