

시계열을 따르는 공정데이터의 모델 모수기반 이상탐지

박시제¹ · 박정술¹ · 김성식¹ · 백준걸^{1*}

Model Parameter Based Fault Detection for Time-series Data

Si-Jeo Park · Cheong-Sool Park · Sung-Shick Kim · Jun-Geol Baek

ABSTRACT

The statistical process control (SPC) assumes that observations follow the particular statistical distribution and they are independent to each other. However, the time-series data do not always follow the particular distribution, and most of cases are autocorrelated, therefore, it has limit to adopt the general SPC in tim series process. In this study, we propose a MPBC (Model Parameter Based Control-chart) method for fault detection in time-series processes. The MPBC builds up the process as a time-series model, and it can determine the faults by detecting changes parameters in the model. The process we analyze in the study assumes that the data follow the ARMA (p, q) model. The MPBC estimates model parameters using RLS (Recursive Least Square), and K^2 -control chart is used for detecting out-of-control process. The results of simulations support the idea that our proposed method performs better in time-series process.

Key words : Time-series, Fault detection, Parameter monitoring, K^2 -control chart, model-based, MPBC

요약

본 연구에서는 시계열 공정데이터 관리를 위한 모델모수 기반 이상 탐지방법을 제안한다. 일반적인 공정관리에 널리 쓰이는 전통적인 통계적 관리기법의 관리도(SPC chart)는 측정되는 데이터가 특정 분포를 따르며 상관관계가 없는 상황을 가정한다. 따라서 공정데이터 형태가 시계열데이터와 같이 특정분포를 따르지 않고, 자기상관관계를 갖는다면 전통적인 관리도로는 관리에 한계를 보인다. 본 연구는 시계열을 따르는 공정의 이상을 탐지를 위한 MPBC(Model Parameter Based Control-chart) 방법을 제안한다. 제안된 MPBC는 시계열공정을 모델링하고, 모델모수의 변화를 감지하여 공정의 이상을 탐지하는 방법이다. 시계열 공정은 ARMA(p, q) 모델을 가정하며, RLS(Recursive Least Square)를 이용하여 시계열 모델의 모수를 추정하고, 추정된 모수를 K^2 관리도로 관리한다. 제안된 방법은 기존 알고리즘과 비교하여 시계열 공정 변화 탐지에 우수한 성능을 보였으며 시계열 데이터에 있어서 보다 효율적인 공정관리 방향을 제시한다.

주요어 : 시계열, 공정이상탐지, 모델모수, K^2 관리도, 모델모수기반 관리도, MPBC

1. 서론

최근 고객만족과 시장에서의 생존을 위하여 기업은 품질의 중요성을 강조하고 있다. 기업이 높은 품질을 만족하는 제품 생산을 위해서는 제조환경에서 공정의 안정화

를 필수적으로 요구한다(Ann, 2007).

제조공정에서 생산되는 제품은 품질 산포가 발생하게 된다. 품질 산포를 발생시키는 원인은 크게 두 가지로 나누어 볼 수 있다. 공정의 엄격한 관리상태 하에서도 불가피하게 자연적으로 발생하는 우연원인(Common Cause)과, 공구 마모와 같이 지속적 또는 갑작스런 변동으로 인한 이상원인(Assignable cause)이다. 그림 1과 같이 공정이 우연원인에 의해서만 변동하고 있으며, 관측되는 데이터가 정규분포(Normal distribution)를 따르고 있는 안정상태의 공정을 관리상태(In control)라고 한다. 또한 이상원인이 존재하여 공정 평균과 분산이 변화된 공정을 이상

접수일(2011년 10월 24일), 심사일(1차 : 2011년 12월 6일), 게재 확정일(2011년 12월 6일)

¹⁾ 고려대학교 산업경영공학과

주 저 자 : 박시제

교신저자 : 백준걸

E-mail; jungeol@korea.ac.kr

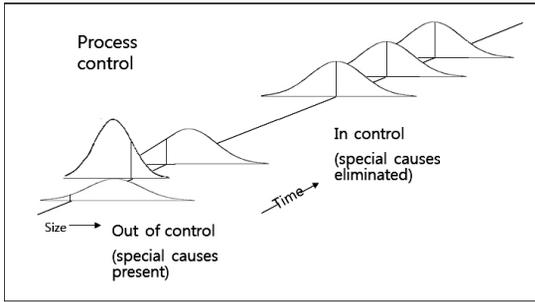


그림 1. 관리상태와 이상상태

상태(Out of control)라고 한다.

공정안정을 유지하기 위한 방법으로 통계적 품질관리 기법(SPC; Statistical Process Control)이 널리 쓰인다. 대표적인 통계적 품질관리 기법인 관리도(Control Chart)는 매회 수집되는 표본을 바탕으로 공정이상을 탐지하는 방법이다. 관리도는 수집되는 데이터가 정규분포를 따르며 독립적인 데이터라는 가정을 바탕으로 둔다. 또한, 이러한 가정을 바탕으로 공정이 관리상태인지, 이상상태인지 결정하는 연속적인 가설 검정이다. 정상공정에서 수집된 데이터를 분석해 평균과 분산을 가정하고, 평균을 중심으로 중심선에 의한 관리상한선과 관리하한선을 결정한다. 여기에 공정의 상태를 나타내는 데이터를 타점하여 관리한계선을 벗어나거나 특별한 패턴을 보이면 공정에 이상 원인이 발생하였다고 판단한다. 공정이상을 관리하는 관리도에서는 정상공정에서 관측되는 데이터가 실제 참입에도 불구하고 거짓이라고 판단하는 제1종 오류(Type I error ; α)와, 모델 변화 후 이상공정에서 관측되는 데이터가 이상입에도 불구하고 정상이라고 판단하는 제2종 오류(Type II error ; β)가 존재하게 된다. 제 1종 오류가 높아질 때 제 2종 오류가 낮아지며, 그 반대의 경우도 마찬가지다. ARL(Average Run Length)은 관리도에 이상이 발생한 후 관리한계선을 벗어난 타점이 보일 때 까지 추출한 표본 수이다. 성능이 우수한 관리도는 이상상태 발생 시점 이후 짧은 ARL을 갖는다.

본 연구는 시계열을 따르는 공정데이터에서 공정 이상탐지 방법인 MPBC(Model Parameter Based Control-chart)를 제안한다. 시계열을 따르는 공정의 예로는 김종락 등(2004)의 수처리 공정 형태, 최인후 등(1994)의 초음파 진동 절삭 공정 형태 등이 있다. 시계열데이터는 그림 4와 같이 p -값이 0.05미만으로 정규분포를 따르지 않으며, 그림 5와 같이 자기상관관계를 갖고 있다. 따라서 기존

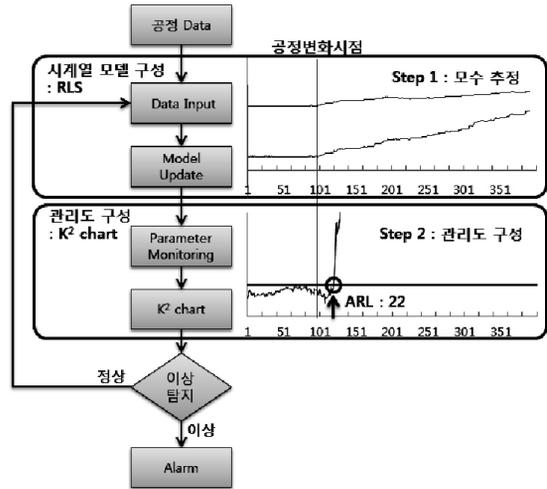


그림 2. 제안기법 절차

SPC관리도를 이용한 시계열공정 데이터 관리에는 한계가 있다. 따라서 본 연구에서는 모델모수를 기반으로 하는 시계열공정의 이상탐지방법을 제안한다. 제안기법 MPBC는 그림 2와 같이 크게 두 단계의 절차로 나누어 볼 수 있다. 첫 번째 단계에서 시계열 모델을 구성하며, 모델을 실시간으로 업데이트 한다. 모델의 모수를 관측함으로써 공정의 상태를 파악할 수 있다. 그림 12의 패턴 4와 같은 형태의 데이터는 평균과 분산의 변화가 없으며, 패턴의 변화 또한 육안으로 확인 할 수 없다. 따라서 직접적인 방법으로는 관측되는 데이터의 이상을 탐지할 수 없다. 이와 같은 형태의 변화를 탐지하기 위해서는 모델 자체의 변화를 감지해야 하며, 모델모수를 관측함으로써 이를 수행할 수 있다. MPBC의 두 번째 단계에서는 모델의 모수를 기반으로 K^2 관리도를 구성하고, 관리한계를 설정하여 이상 발생여부를 확인한다.

Shewhart(1924)는 품질 특성을 나타내는 평균뿐만 아니라 편차까지 관리하는 \bar{X} -S, \bar{X} -R 관리도를 제안하였다. \bar{X} 관리도는 공정에서 나타나는 n 개 샘플을 군(群)으로 묶어 표본평균으로 사용한다. 하지만 샘플 평균을 기반으로 관리도를 구성하는 \bar{X} 관리도는 미세한 평균 변화(Mean shift)가 발생할 때 이상탐지에 둔감하다. 따라서 미세한 평균변화를 찾아내기 위해 관리도 가정을 확장한 누적합(CUSUM ; Cumulative Sum) 관리도(Page, 1954), 지수 이동평균(EWMA ; Exponential Weighted Moving Average) 관리도(Roberts, 1959)와 이동평균(MA ; Moving Average) 관리도(Montgomery, 1985) 등이 제안되었다(Montgomery,

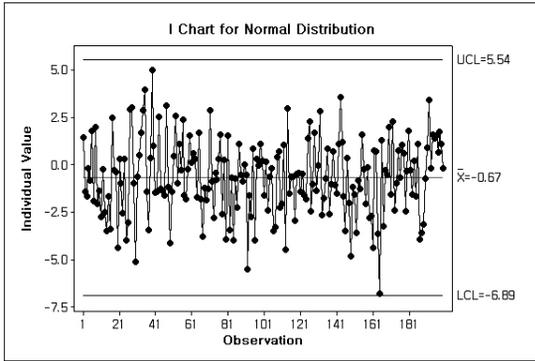


그림 3. \bar{X} 관리도

2001).

\bar{X} 관리도와 마찬가지로 CUSUM, EWMA, MA 관리도 또한 표본이 독립이라는 가정을 두고 있다. 이상의 관리도에 대해 Apley 등(2002)은 자기상관관계(Autocorrelation) 데이터에서 관리 성능문제와 실제 공정에서 가정을 만족시키지 못하는 경우를 지적하였다. 자기상관관계를 갖는 대표적인 데이터는 시간에 따라 연속적으로 발생하는 시계열 데이터(Time-series data)이다. 시계열 모델과 같이 자기상관관계를 가지는 데이터를 처리하기 위한 방법으로 많은 연구가 진행되었으며, 대표적으로 모델기반 관리도(Model-based Control Chart)가 있다(Montgomery, 2001). Mandel(1969)은 전통적인 관리도와 회귀모형(Regression)을 조합한 모델기반 관리기법을, Healy(1987)는 선형조합(Linear Combination)모델을 기반으로 한 CUSUM관리도를 제안하였으며, Apley 등(2002)은 불확실한 시계열 모델의 관리도를 구성하기 위하여 수정된 EWMA를 기반으로 한 관리도를 제안하였다. 또한, Harris 등(1991), Lu 등(1999)은 시계열 모델을 기반으로 자기상관관계가 있는 데이터를 위한 관리도를 제안하였으며, Apley 등(1999)은 자기상관관계가 있는 데이터의 평균이동(Mean Shift)을 감지하기 위하여 잔차기반 관리도를 제안하였다. 하지만 이상의 관리기법은 모델 모수가 정확하게 정의되어 있어야 하며, 모델과 실제 데이터간 유사성, 잔차간 독립성에서 한계를 보인다.

시계열 데이터는 정규분포와 같이 특정 분포를 나타내지 않는다. 또한 자기상관관계를 갖고 있어 과거의 데이터가 현재의 데이터에 영향을 미치는 특징이 있다. 시계열 데이터 분석방법으로는 과거 데이터가 현재데이터에 영향을 미치는 만큼 일정 값을 임의로 가중하여 현재 값

을 예측하는 EWMA, MA같은 방법이 있으며, 대표적인 시계열 분석방법으로 Box와 Jenkins(1970)가 제안한 Box-Jenkins모델이 있다. Box-Jenkins 모델은 AR, MA, ARMA, IMA, ARIMA, SARIMA 와 같이 다양한 모델을 포함하고 있는 것이 특징이며, 분석과 예측을 위해 데이터 모델링이 사용된다(Bowerman 등, 2005; Box 등, 1994).

본 연구의 2장에서는 시계열을 따르는 공정을 ARMA(p, q)모델로 가정하여 모델링하며, RLS(Recursive Least Square)를 이용하여 실시간으로 모델이 업데이트 되는 과정을 설명한다. 3장에서는 수립된 모델의 모수를 기반으로 K^2 관리도를 구성하고, 모델변화를 감지한다. 4장에서는 시뮬레이션을 통해 기존 알고리즘과 비교평가를 수행한다.

2. 시계열 모델 구성

2.1 시계열 모델의 수립

제조 환경에서는 시간에 따라 측정되는 데이터가 존재한다. 많은 연구에서 시간의 영향을 받는 공정의 예를 보여준다. 김종락 등(2004)은 안정적인 운영을 위한 수처리 공정 모델링이, 오창근 등(1998)은 화학공정의 연속식 PS(polystyrene) 중합반응계 모델이 ARMA(1,1)을 따른다고 하였다. Pandit 등(1983)은 기계 역학시스템(Mechanical dynamic system) 중 스프링이나 제동장치에서 관측되는 데이터가 최인후 등(1994)은 신소재 정밀 가공을 위한 초음파 진동 절삭공정모델이 ARMA(2,1) 시계열 모델을 따른다고 하였으며, Pandit 등(1983)은 단일 축 자동 스크류 기계(Single-spindle automatic screw machine)의 부품제조 공정 중 드릴의 지름을 측정하는 품질 검사 공정이 ARMA(3,2)모델 따른다고 하였다.

이상의 연구에서와 같이 시계열을 따르는 공정이 존재하며, 이러한 공정의 관리가 필요하다. 따라서 실시간으로 데이터를 분석하고 공정을 관리하는 방법이 필요하다. 본 연구는 이상의 공정과 같이 시계열을 따르는 공정을 가정한다. 시계열로 관측되는 공정은 일반적인 공정 데이터와는 다른 특성을 갖는다. 그림 4, 그림 5와 같이 시계열 데이터는 정규성이 만족되지 않으며, 자기상관관계를 갖고 있다. 본 연구에서 제안하는 MPBC는 이상의 특징을 갖는 시계열 데이터 관리를 위해 모델링 단계를 거친다. Box-Jenkins 시계열 모형은 과거 데이터가 현재 값에 미치는 형태를 다양하게 정의한다.

식 (1)은 Box-Jenkins 시계열 모형중 ARMA(p, q) 모델

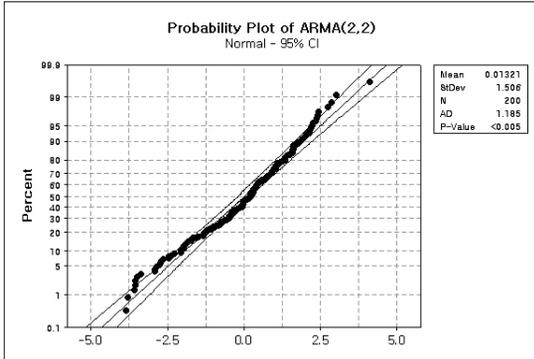


그림 4. ARMA(2,2) 데이터의 정규성 검정(p-value < 0.05)

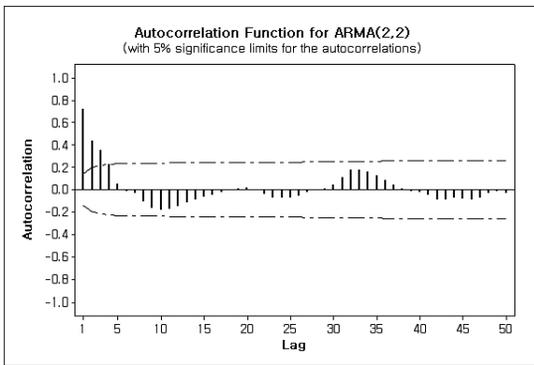


그림 5. ARMA(2,2) 데이터의 자기상관관계 도표

(Autoregressive Moving Average Model)이다. ARMA(p, q) 모델은 AR(p)모델과 MA(q)모델이 합쳐진 형태로써, 시계열 자료 $\{y_t\}$ 가 과거의 관측데이터와 오차항에 모두 영향을 받아 결정되는 경우 ARMA(p, q)로 표현한다.

$$y_t = a_0 + a_1 y_{t-1} + \dots + a_p y_{t-p} + \varepsilon_t + b_1 \varepsilon_{t-1} + \dots + b_q \varepsilon_{t-q} \quad (1)$$

y_t : t 시점의 관측데이터

a_i : AR i 번째 모수

b_i : MA i 번째 모수

ε : 오차항

자기 회귀(Autoregressive) AR(p)모델은 과거 p 시점까지의 관측 데이터가 현재시점 t 에 영향을 미치는 모델 형태이다. 확률변수인 시계열 데이터 y_t 는 과거 관측된 데이터 y_{t-n} ($n \leq p$)의 영향을 받으므로, 자기상관관계가 존재한다. 따라서 매 시점 관측되는 데이터간의 독립을

가정할 수 없다. 관리상태 공정에서 평균과 분산이 0과 σ^2 으로 일정하게 존재하며, 각 시점에서 공분산이 0인 오차항(White Noise)을 포함하고, 오차항 사이에는 상관관계가 존재하지 않는다.

AR(p)모델과는 다르게 y_t 가 과거 오차항의 영향을 받아 결정되는 경우 이동 평균(Moving Average) MA(q)모델이라 한다. MA(q)모델은 오차항 가중치의 합으로 나타내며 오차항 분포와 상관관계에 의해 설명된다.

2.2 모델 업데이트

수립된 모델의 모수를 추정하기 위해서는 실시간(Real Time)으로 관측되는 공정 데이터를 처리해야 한다. 실시간 모수 추정에 대표적으로 사용되는 RLS 알고리즘을 활용하여 모델모수를 추정할 수 있다. 1960년 Kalman에 의해 개발된 선형 최적 필터(Linear Optimal Filter), Kalman Filter(KF) 알고리즘을 기초로 하여 개발된 RLS는 실시간 데이터를 기반으로 가장 적합한 모델형태를 찾아가는 대표적인 적응형 알고리즘이다. 추정 모수 $\hat{\theta}(t)$ 는 $f(\theta(t-1))$ 과 같이 이전시점 데이터에 관한 함수로 표현되며, 재귀적인 방법으로 계산을 진행한다. 이전 시점 데이터에 과거 정보가 함축되어있는 재귀적 알고리즘의 특성상 계산량과 계산 시간을 줄일 수 있는 장점을 갖고 있다(Alessandri 등, 2007; Welch 등, 2006; Moonen, 2004).

본 연구에서는 RLS를 이용하여 실제공정에 가장 적합한 모델을 스스로 업데이트 하며, 업데이트 되는 모델을 기반으로 공정 상태를 파악한다. 식 (1)과 같은 시계열 모델 ARMA(p, q)의 실시간 모수 추정을 위해서는 몇 가지 절차가 필요하다. RLS 알고리즘에서 모수 a_i , b_j 와 관측 데이터 y_t , 오차항 ε_t 은 다음과 같이 $\theta(t)$, $\varphi(t)$ 로 정의한다.

$$\theta(t) = [a_0, a_1, \dots, a_p, b_1, \dots, b_q]^T \quad (2)$$

a_i : AR 모수

b_j : MA 모수

$$\varphi(t) = [1, y_{t-1}, y_{t-2}, \dots, y_{t-p}, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}]^T \quad (3)$$

y_t : t 시점의 y

ε_t : t 시점의 오차항 ε

t 시점의 모수 $\theta(t)$ 를 추정하기 위해서 식 (4), (5), (6),

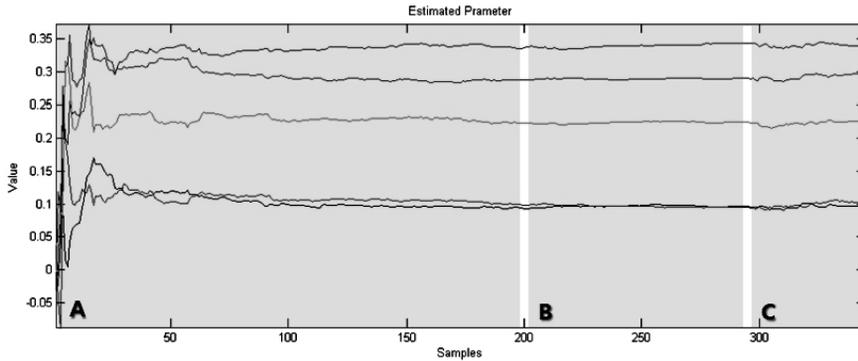


그림 6. 모델의 수립(A)과 안정화(B), 모델의 변화(C)

(7) 과 같은 단계를 거친다.

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)\varepsilon(t) \quad (4)$$

$$\varepsilon(t) = y(t) - \varphi(t)^T \hat{\theta}(t-1) \quad (5)$$

$$K(t) = P(t-1)\varphi(t)[I + \varphi(t)^T P(t-1)\varphi(t)]^{-1} \quad (6)$$

$$P(t) = [I - K(t)\varphi(t)^T]P(t-1) \quad (7)$$

$y(t)$: t 시점의 관측 데이터

$K(t)$: 칼만 게인

$P(t)$: $\varphi(t)$ 의 공분산 행렬

I : 단위행렬

식 (4)에서 t 시점 모수추정치는 이전시점 데이터를 포함하는 함수 형태로 나타내며, 식 (5)는 실제 관측된 데이터와 모델에 의한 예측 값의 오차를 계산하는 과정이다.

칼만 게인(Kalman Gain) 또는 조합 인자(Blending Factor)라 불리는 식 (6)의 $K(t)$ 는 오차가 최소화 되도록 매회 계산마다 적응하며 $\theta(t)$ 를 추정하는 조정인자 역할을 한다. 식 (7)은 오차항 공분산 $P(t)$ 의 보정 부분이다. 공정에서 실시간으로 관측되는 데이터를 바탕으로 위의 식은 모델모수 추정에 재귀적으로 반복된다.

Goodwin과 Sin에 의해 RLS 알고리즘에 관한 기본적인 사항들이 연구되었으며(Goodwin 등, 1984), Ljung 등 (1983)은 초기 $\hat{\theta}(0)$ 와 $P(0)$ 는 가능한 작은 값을 갖는 것이 빠른 모델의 학습에 유리한 것을 입증 하였다. 모델이 학습되는 것은 모델 모수의 관측으로 확인할 수 있다.

모델의 특질(Feature)중 하나인 모델모수는 공정 상태를 대표하며, 모델모수를 관리함으로써 공정을 반영하는

모델의 이상을 탐지 할 수 있다. 그림 6은 RLS 알고리즘에 의해 예측된 실시간 모델모수 변화이다. 그림 6은 ARMA(2,3) 모델을 실시간으로 업데이트 한 것으로 5개 ($p+q$) 모수 추정 결과를 나타낸 것이다. 그림 6의 A는 모델의 업데이트 초기 상태이다. 초기 상태 모델은 정보를 충분히 반영하고 있지 않기 때문에 관측되는 실제값과 추정값의 오차가 커지고, 따라서 업데이트시 모델 모수의 변화가 크게 나타난다. 식 (6)에서 오차 $\varepsilon(t)$ 의 값이 커지면 식 (5)에 영향을 주며, 추정 모수 $\hat{\theta}(t)$ 가 크게 진동하는 형태로 관측된다. 그림 6의 B부분은 업데이트되는 모델 모수의 진동크기가 점차 줄어들어 일정 값으로 수렴하는 단계이다. 모델이 충분히 학습되어 과거 데이터를 기반으로 계산된 예측값이 실제 관측되는 값과 유사한 단계이다. 모델이 안정단계에 접어든 상태로써, 이 단계에서는 수립된 모델이 실제 공정을 충분히 반영하고 있다고 여겨진다. 또한, 공정이 변하지 않는다면 모델모수는 허용범위 내의 오차를 갖게 되고 안정상태를 유지한다. 따라서 B시기의 시계열 모델은 공정이 정상상태에서 운영되고 있음을 보여준다.

3. 이상탐지

3.1 공정 변화

공정은 모델 업데이트를 통해 안정화되는 단계를 거치면서 추정된 모수에 의해 설명될 수 있다. 반면, 이상원인에 따라 공정상태가 변하고 관리상태에서 벗어나게 된다면, 모델은 공정을 제대로 반영하지 못하게 된다. 그림 6의 C는 모델이 공정과 일치하지 않아 모수가 불안정하게 변화하는 부분이다. 공정 변화는 실시간으로 업데이트 되는 모델에 직접 영향을 미치며, 변화는 모수의 변동을 통

해 파악할 수 있다. 즉, 정상상태 공정에서 허용 범위 내의 변화만을 유지하던 모수는 변화된 공정을 반영하여 그림 6의 C와 같이 불안정 상태에 접어들게 된다.

ARMA(p, q)모델의 변화는 크게 두 경우로 규정할 수 있다. ARMA(1,2)에서 ARMA(2,2)로 변화하는 것과 같이 계수 p 와 q 가 변하는 경우와, 식 (1)에 해당되는 a_i 와 b_i 에 해당되는 수가 변하는 두 가지 경우이다. 본 연구에서 정의하는 공정모델의 변화는 $p=2 : (a_1=0.1, a_2=0.4)$ 에서 $p=2 : (a_1=0.3, a_2=0.1)$ 과 같이 모델 변화가 a_i 나 b_i 의 변화로 나타나는 경우이다. 각각의 a_i, b_i 는 Massey(1951)가 제안한 Kolmogorov-Smirnov 정규성 검정과 Aderson(1952)등이 제안한 Anderson-Darling 검정 결과 0.05보다 작은 p -값을 나타냈다. 모델모수는 두개 이상이 존재하므로 다변량 데이터 처리의 문제로 정의되며, 또한 상관관계 분석을 통해 높은 자기상관관계를 갖는 것으로 보였다. 따라서 각각의 모수 역시 관측되는 시계열 데이터와 같이 정규분포를 만족하지 않으며, 자기상관관계를 띄고 있는 것을 알 수 있다. 다변량 공정은 Hotelling's T^2 관리도(Hotelling, 1947), MEWMA(Mltivariate Exponentially Weighted Moving Average)관리도(Lowry 등, 1992), MCUSUM(Multivariate Cumulative Sum) 관리도(Corsier, 1988)와 같은 방법으로 관리될 수 있으며 많은 연구가 진행되고 있다. 하지만 이상의 기법들은 자기상관관계가 없는 독립적인 데이터를 가정하고 있으므로 본 연구에서 가정하는 시계열공정 모델모수 관리에는 한계를 보인다(Montgomery, 2001).

3.2 관리도 구성

MPBC에서는 K^2 관리도를 이용하여 다변량, 자기상관관계를 갖는 시계열 모델모수 관리도를 구성하여 이상을 탐지한다. Sukchotrat 등(2010)은 다변량, 자기상관관계를 갖는 데이터의 관리를 위해 OCC(One Class Classification) 기법중 Tax(2001)가 제안한 kNNDD(k nearest-neighbors data description)를 기반으로 K^2 관리도를 제안하였다. OCC는 분류기법(Classification)의 한 범주로 목적(Target) 클래스와 그 외(Other)의 클래스를 구분하는 방법이다. 두 개 혹은 이상의 클래스(Two-Class or Multi-Class)를 구분하는 일반적인 분류 문제와는 다르게 OCC는 목적 클래스 정보만으로 클래스를 구분한다. 그림 7은 목적 클래스와 이상치 데이터를 나타낸 것이다. 공정이 변하여 관리상태 데이터가 목적범위를 벗어나는 것을 볼 수 있다.

kNNDD알고리즘은 훈련데이터를 이용하여 목적범위

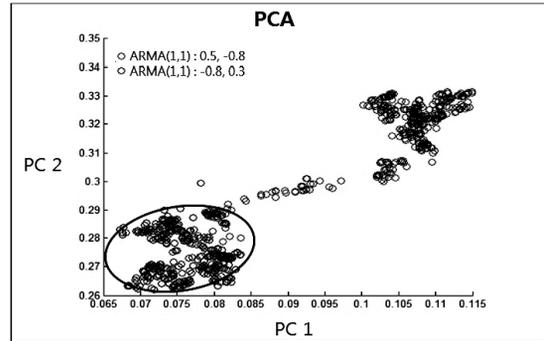


그림 7. PCA : 목적범위와 이상데이터

(Control Boundary)를 정의한다. 관측 데이터를 중심으로 k 개의 인접한 데이터를 찾고, 찾아진 데이터를 기반으로 목적 범위를 형성한다. 데이터가 늘어날수록 목적 범위는 확장 된다. 훈련데이터를 통해 형성된 목적 범위는 새롭게 관측되는 데이터가 목적클래스인지를 판단한다(Bartkowiak 등, 2010).

kNNDD를 기반으로 하는 K^2 관리도는 식 (8)과 같이 K^2 를 정의하여 통계량으로 이용한다. 식 (8)에서 z 는 관측되는 데이터이며, $NN_i(z)$ 는 z 와 i 번째로 인접하고 있는 데이터를 의미한다. k 개의 인접 값과의 거리를 평균으로 한 K^2 값을 관리도의 통계량으로 구성한다.

$$K^2 = \frac{\sum_{i=1}^k \|z - NN_i(z)\|}{k} \quad (8)$$

z : 관측데이터

관측되는 K^2 값이 관리한계에서 벗어나지 않으면 관리상태공정 이라고 판단한다. 관리한계(CL; Control Limit)를 벗어나면 목적범위에서 멀어지는 것으로 판단하며 이상 데이터로 판단하게 된다. 본 연구에서 관리한계 기준은 Sukchotrat(2010)가 제안한 부트스트랩 백분위(Bootstrap Percentile) 방법에 근거하였다(Kim 등, 2010; Sukchotrat 등, 2010).

제시된 방법으로 K^2 값을 계산하고 관리한계선을 설정하여 관리도를 구축 한다. 관리도의 데이터는 실시간 나타나며 관리한계선을 초과하여 이상이 발생 하였을 때, 공정의 이상이 나타난 것을 알린다. 그림 8은 관리상태 공정이 ARMA(1,1)의 모수(0.5, -0.8)을 갖는 것으로 가

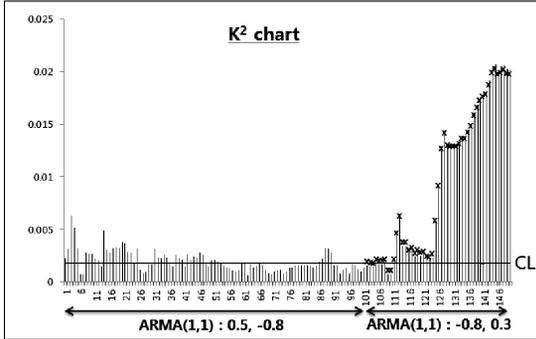


그림 8. K^2 관리도

표 1. K^2 관리도의 관리한계선(CL)

- Step 1. 샘플의 크기가 N인 Phase 1의 K^2 값을 J번의 부트스트랩으로 $K_{j(1)}^2, K_{j(2)}^2, \dots, K_{j(N)}^2$ 를 만든다. ($j = 1, \dots, B$)
- Step 2. $K_{j(1)}^2 < K_{j(2)}^2 < \dots < K_{j(N)}^2$ 와 같이 각각의 부트스트랩 샘플을 크기순으로 정렬한다. ($K_{j(i)}^2$, j부트스트랩 샘플 중, i번째로 큰 값)
- Step 3. 관리한계는 사용자가 지정한 α ($0 < \alpha \leq 1$)와 샘플의 사이즈 N으로 계산한다. i는 $(1-\alpha)^{th}$ 의 백분위 값으로 지정하여 다음의 값을 계산한다. (예, $100(1-\alpha)^{th}$ 백분위 수; $N = 100$)

$$CL = \sum_{j=1}^B K_{j(i)}^2 / B$$

정하고, 공정변화가 발생하여 모델이 변화된 상황이다. 실험데이터로 관리되고 있는(In control) 데이터와 이상이 발생하여 관리에서 벗어난 데이터(Out of control)의 K^2 관리도를 구축한 것이다. 정상공정 데이터는 0에 가깝게 존재하며, 이상공정 데이터는 비교적 큰 값을 갖는다. 그림 8에서 변화된 공정을 나타내는 데이터는 점차 큰 값을 갖게 되며, 관리한계선을 넘어 이상상황을 나타낸다.

4. 시뮬레이션 및 평가

4.1 실험 설계 및 시뮬레이션

일반적으로 ARMA(p,q)에서 $p = 1, q = 1$ 형태가 시계열 공정을 가장 잘 표현하는 것으로 알려져 있다(Tsung 등, 2003). 따라서 본 연구에서 가정하는 시계열 공정 모델 계수 p,q는 (1,1)로 표현하며, AR모수인 a_1 과 MA모수인 b_1 의 변화로 다양한 공정모형을 표현한다. Hu 등 (1996)은 평균에 지속적 변화가 발생하는 경우 $|a_1| < 1$ 과 $|b_1| < 1$ 인 ARMA(1,1) 모수 영역을 3가지로 구분하여 공

표 2. ARMA(1,1) 모델형태 구분

모수 영역	모수 형태
1	$a_1 \leq b_1$
2	$b_1 < a_1 \leq b_1 + 1$
3	$a_1 > b_1 + 1$

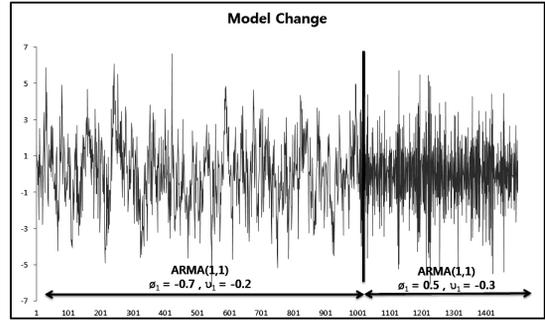


그림 9. 모델 상태의 변화

정모형을 표현하였다. 표 2는 본 연구에서 시뮬레이션 하는 세 가지 모수영역과 모수 형태를 나타낸다.

모델 상태(Status)는 공정이 특정모델을 따르고 있는 것을 말하며, 공정 변화를 감지하는 것은 모델상태가 다른 상태로의 변화를 찾아내는 것이다. 그림 9는 모델상태 변화를 보여준다. 모델상태의 변화를 직접적으로 확인할 수 있는 경우가 있지만, 실제 평균과 분산이 변하지 않는 경우 공정상에서 탐지하기란 쉽지 않다. 본 실험에서는 평균과 분산이 다를 때의 상태변화, 평균과 분산이 같을 때의 상태변화를 시뮬레이션 한다. 시뮬레이션한 공정을 제안기법인 MPBC와 전통적인 SPC의 \bar{X} 관리도, EWMA 관리도와 비교 평가를 수행한다.

그림 9는 ARMA(1,1)모델의 모수가 각각 (-0.7, -0.2), (0.5, -0.3)인 데이터이다. 각각의 평균과 분산은 0.012, 3.69과 0.01, 3.63을 갖는다. 특정 시점 이후, 공정변화를 시계열 모델이 반영하였으나, 평균과 분산이 같은 경우 기존 \bar{X} 관리도는 상태 변화를 감지해 낼 수 없다. 그림 10은 시계열 공정 상태가 변하며 평균과 분산이 모두 변하는 경우이다. 평균과 분산의 변화를 탐지하는 전통적인 \bar{X} 관리도는 짧은 시간 내에 공정변화 탐지가 가능함을 보여준다. 그림 11은 공정상태 변화와 같이 관측데이터의 평균과 분산이 변하지 않는 경우이다. 평균과 분산의 변화로 이상을 탐지하는 전통적인 SPC관리도는 그림 11과 같은 경우 이상을 탐지하지 못한다.

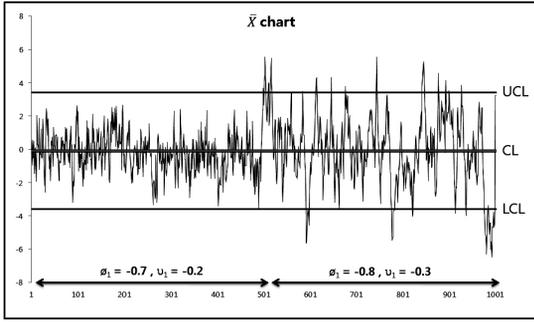


그림 10. 시계열 데이터의 SPC관리도(평균, 분산의 변화가 있는 경우)

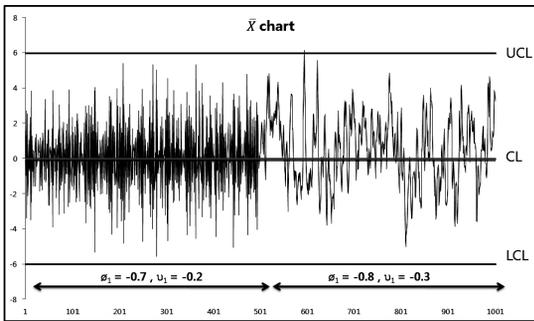


그림 11. 시계열 데이터의 SPC관리도(평균, 분산의 변화가 없는 경우)

표 3은 모수 영역에 따라 공정의 상태를 정의한 것이다. 정의된 상태를 조합하여 다양한 형태의 공정 변화를 구현 할 수 있다.

실제 공정은 다양한 패턴으로 공정변화가 발생할 수 있다. 예를 들어 상태 1과 같이 데이터가 추세를 갖고 자기상관관계를 띠고 있는 공정이 상태 3과 같이 자기상관관계가 적고 백색잡음(White Noise)과 같은 공정형태로 변화하는 경우가 발생한다. 또한, 관리상태 공정과 매우 유사하지만, 작은 변화가 생기는 경우도 발생할 수 있다. 본 연구에서는 다양한 경우의 공정 변화패턴을 표현하기 위하여 표 4와 같이 네 가지로 시뮬레이션패턴을 구성 하였다. 첫 번째 패턴은 공정이 미세하게 변하는 상황을 가정한다. 그림 12의 패턴 1과 같이 공정이 미세하게 변하는 것은 시계열 모델의 모수가 작은 변동을 일으키는 것으로 표현 하였다. 두 번째 패턴은 작은 진폭을 갖는 공정에서 큰 진폭을 갖는 공정으로 변동을 일으키는 경우이다. 자기상관관계를 갖고 있는 시계열 데이터는 이전 시점의 데이터에 영향을 받게 된다. 따라서 진폭 변화가 크지 않

표 3. 공정 상태의 정의

	모수 영역	a_1	b_1
상태 1	1	-0.8	0.3
상태 2	1	-0.9	0.2
상태 3	2	0.9	0.5
상태 4	3	0.5	-0.8

표 4. 시뮬레이션 패턴의 정의

	상태 변화	설 명
패턴 1	1 → 2	모델모수의 미세한 변화공정(그림 12;패턴 1)
패턴 2	1 → 3	작은 진폭에서 큰 진폭으로의 변화공정(그림 12;패턴 2)
패턴 3	3 → 1	큰 진폭에서 작은 진폭으로의 변화공정(그림 12;패턴 3)
패턴 4	4 → 3	모델모수의 변화는 크지만 육안으로 확인이 불가능한 변화공정(그림 12;패턴 4)

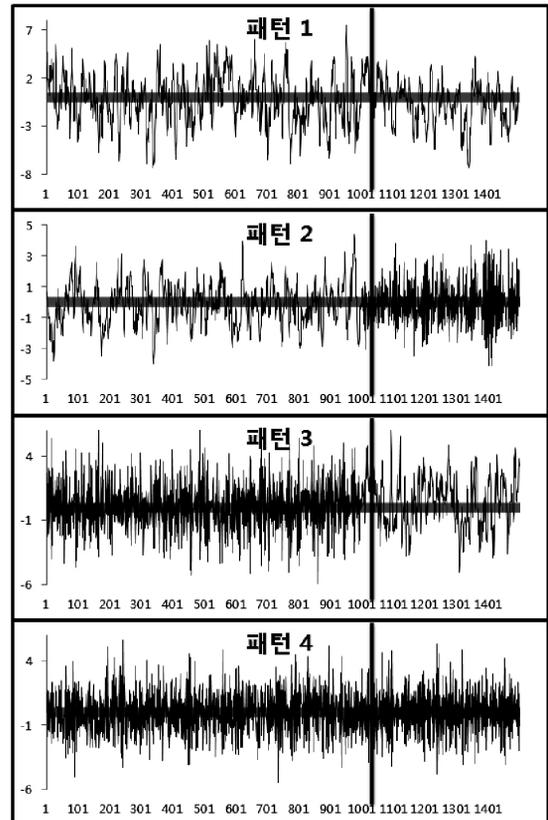


그림 12. 변화 패턴 시뮬레이션

으므로 그림 12 패턴 2의 전반부와 같은 형태를 보이게 된다. 시간 흐름에 따라 공정이 변동을 일으켜 패턴 2의 후반부와 같이 자기상관관계가 작아지며 진폭의 변화가 커진다. 패턴 3은 패턴 2의 반대 상황이다. 네 번째 패턴은 모니터링 그래프만으로는 공정에 큰 변동이 일어나 보이지 않은 경우이다. 공정상태가 크게 변하여 시계열 모델모수가 큰 변화를 일으켰지만, 그림 12의 패턴 4와 같이 관측데이터의 형태는 크게 변하지 않은 것을 볼 수 있다.

MPBC를 이용하여 앞서 정의한 네 종류의 시계열 공정변화 패턴을 탐지한다. 공정의 상태변화가 발생하는 시점으로부터 얼마나 빠르게 이상을 탐지하는지를 알기 위하여 런 길이(Run Length)를 사용하며, 런 길이가 짧을수록 이상 공정을 빠르게 탐지할 수 있다고 할 수 있다. 실험을 위하여 관리도가 이상을 찾아내지 못할 경우 300 런 길이를 갖는 것으로 가정하였다. 본 연구에서 제안하는 MPBC는 전통적인 SPC관리도의 \bar{X} 관리도, EWMA관리도와 비교를 통하여 그 성능을 평가 한다.

본 연구의 시뮬레이션은 평균과 분산의 변화 유무에 따라 크게 두 케이스로 나누었으며, 공정의 상태를 정의한 것을 기반으로 상태 변화를 4가지 패턴으로 분류하여 다양한 시뮬레이션 환경을 구성하였다. 또한, 각 시뮬레이션 환경마다 100개의 샘플을 통한 반복실험을 행하였으며, 랜덤시드(Random Seed)를 통제함으로써 시뮬레이션의 재현성을 확보하였다. 제안기법인 MPBC는 일정시간 후 모델이 안정화 단계로 수렴한다. 모델이 수렴하는 속도에 관한 연구는 현재까지 없는 실정이며, 본 연구에서는 임의로 1000회 런 이후의 시점을 수렴상태라 가정하여 K^2 관리도를 구성하였다.

4.2 실험결과 및 분석

그림 13은 세 알고리즘 이상탐지를 보여준다. 공정변화 시점이 일정하지만, 변화된 공정에서 이상을 탐지하는 시점은 알고리즘마다 조금씩 차이를 보이는 것을 볼 수 있다. \bar{X} 관리도와 EWMA관리도는 관리기준에 맞춰 관리한계선을 설정하고 이상을 찾아낸다. \bar{X} , EWMA관리도는 그림 13과 같이 평균과 분산의 변화가 작고, 육안으로 볼 때 큰 변화가 없는 공정에서 비교적 느린 공정이상 탐지를 볼 수 있다. MPBC는 모수 추정과 K^2 관리도 구성 두 과정을 거쳐 이상을 탐지하며, 그림 13에서 보듯 비교적 빠른 시계열 공정이상 탐지를 볼 수 있다.

일반적으로 제 1종 오류(α)와 제 2종 오류(β)의 확률로 관리도의 성능을 평가한다. 두 오류의 확률이 모두 낮

은 관리도가 우수한 성능의 관리도라 할 수 있으나, 두 오류의 제어는 서로 상충관계(Trade-off)를 갖고 있다. 따라서 한 가지 오류를 고정된 채 다른 오류가 낮아 질 수 있도록 관리도를 설계한다. 그림 14에서와 같이 두 오류의 판단은 정규분포의 평균과 분산으로 정해지게 된다. 정상상태(H_0)와 이상상태(H_a) 공정은 정규분포 가정을 전제로 하고 있다. 또한 α, β 란 정상상태 혹은 이상상태에서 발생하는 이상데이터의 비율이며, 공정은 이상데이터의 전제가 뒷받침 되어야 한다. 본 연구에서 가정하는 시계열 공정은 α 와 β 를 이용한 관리도 성능평가에 부합하지 않는다. 시계열 공정은 정규분포의 가정을 따르지 않으며 평균과 분산으로 공정상태가 대표되지 않는다. 또한, 시계

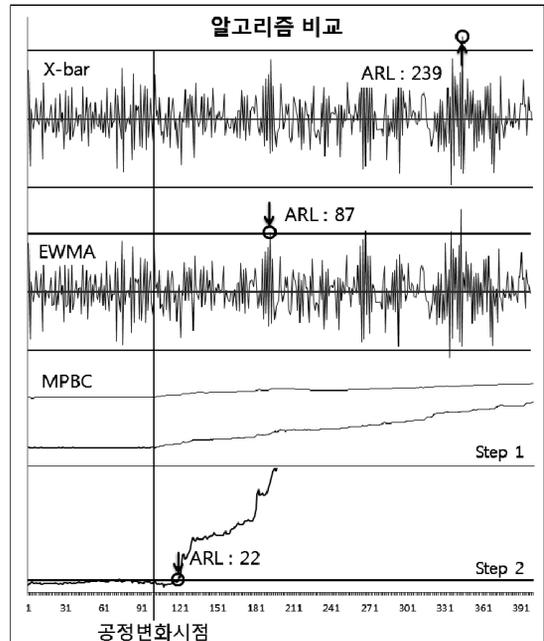


그림 13. 알고리즘 비교(패턴 4)

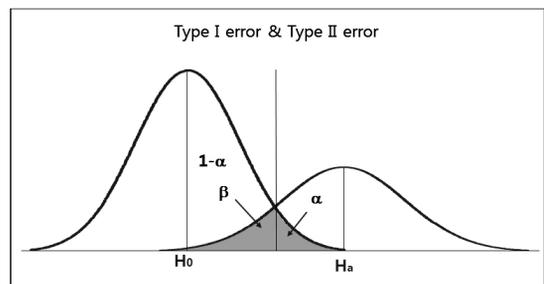


그림 14. α, β

열 모델을 시뮬레이션 하여 변화 패턴 시점을 정의하고, 변화된 패턴을 탐지하는 관리기법이다. 따라서 본 연구는 특정시점 이후의 공정변화를 얼마나 빠르게 탐지하는가에 목적을 두고, 그 성능을 평가하였다.

표 5는 시뮬레이션 패턴에 따른 이상탐지 결과이다. 제안 알고리즘 MPBC는 부분적으로 \bar{X} 관리도와, EWMA 관리도보다 우수한 성능을 나타냈다. 평균과 분산에 변화가 있는 경우(Case 1), 패턴 1과 패턴 2에서 EWMA관리

도가, 패턴 3과 패턴 4에서 MPBC관리도가 우수한 성능을 보였다. 모델모수변화가 작은 패턴 1의 경우, 모델 모수를 기반으로 관리하는 MPBC관리도의 취약점이 나타났다. 모델모수를 기반으로 이상을 탐지하는 MPBC는 모수의 변화가 작은 경우 비교적 긴 런 길이어후에 이상을 탐지할 수 있었다. 패턴 2,3의 경우 MPBC관리도가 우수한 성능을 나타냈다. 자기상관관계가 큰 쪽에서 작은 쪽으로 변동하는 패턴 2의 경우, EWMA관리도의 $\lambda=0.8$ 의

표 5. 시뮬레이션 비교 실험 결과 $\mu(\sigma)$

Case	패턴	ARL		
		*MPBC (CL 0.05)	\bar{X} 관리도 (CL 0.05)	EWMA 관리도 (CL 0.05, $\lambda=0.8$)
Case 1 (μ, σ 변화 있음)	1	109.51(124.67)	268.94(71.12)	11.24(14.02)*
	2	6.16(6.98)	187.32(105.98)	3.70(6.33)*
	3	9.92(12.04)*	220.40(101.68)	139.44(98.84)
	4	8.17(10.45)*	212.57(104.33)	108.81(91.96)
Case 2 (μ, σ 변화 없음)	1	80.86(109.39)	117.86(86.67)	6.03(7.90)*
	2	11.36(14.81)*	300(0)	20.51(26.06)
	3	5.95(6.11)*	44.98(56.36)	19.45(21.02)
	4	12.12(16.62)*	292.94(40.45)	263.91(84.31)

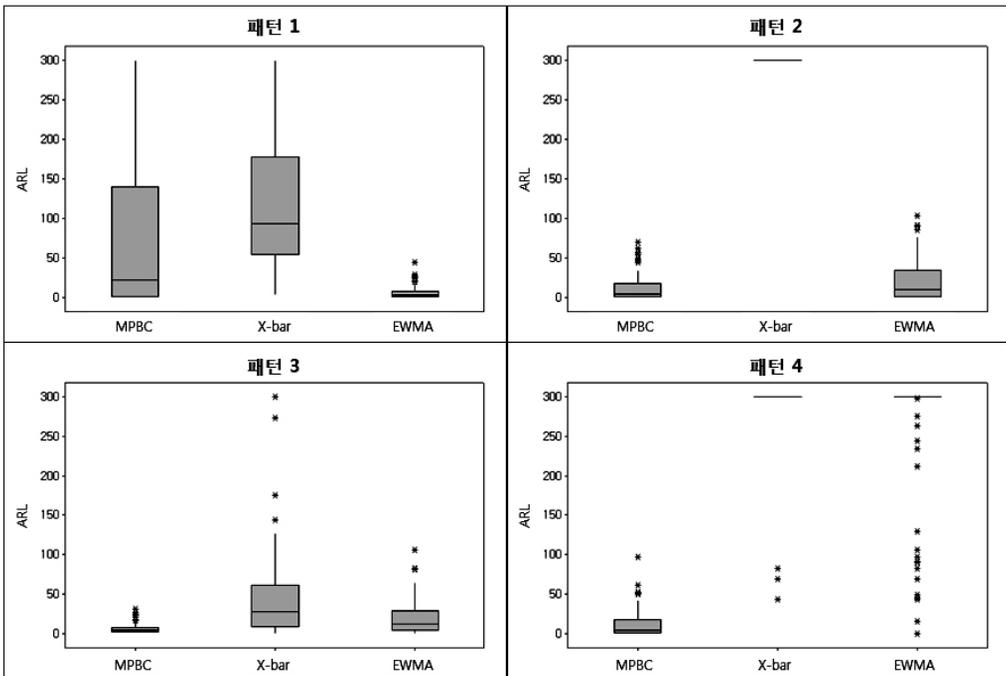


그림 15. Boxplot : 평균과 분산의 변화가 없는 경우(Case 2) 패턴별 ARL(패턴별 100Sample 시뮬레이션)

큰 값을 가질 때 좋은 성능을 보였지만, 반대 경우인 패턴 3에서 현저히 떨어지는 결과를 볼 수 있다. EWMA관리도가 갖는 λ 의 가정이 한계를 보일 수 있다는 것을 나타낸다. 평균과 분산에 변화가 없는 경우(Case 2)에서는 전반적으로 MPBC가 비교적 우수한 성능을 나타냈으며, 평균과 분산의 변화를 기반으로 공정이상을 판단하는 \bar{X} 관리도는 매우 낮은 성능을 보였다. Case 1에서와 마찬가지로 패턴 1과 같은 미세한 모델모수 변화 탐지에는 EWMA 관리도가 우수한 성능을 나타냈다. 패턴 2에서 공정에 변화가 시작된 후 평균 11.36 런 길이 후 공정 변화를 찾아낼 수 있었으며, Case 1에서 가장 좋은 성능을 나타냈던 EWMA관리도는 조금 느린 20.51의 런 길이 후에 공정이상을 찾아낼 수 있었다. 패턴 2에서 \bar{X} 관리도는 공정이상이 발생하였음에도 불구하고 전 범위 데이터가 관리상태에 있다고 판단하였다. 관측값의 크기와 패턴에는 큰 변화가 없지만, 모델모수가 변하는 공정인 패턴 4에서는 제안기법인 MPBC관리도가 우수한 성능을 나타냈다.

5. 결 론

본 연구에서는 시계열을 따르는 공정의 이상탐지기법을 제안하였다. 시간의 영향으로 관측되는 공정데이터를 시계열로 가정하였으며, 시계열 모델링을 위해 실시간으로 관측되는 데이터를 기반으로 한 RLS알고리즘을 이용해 시계열 모델을 추정하였다. 추정된 모델은 공정을 대표하므로, 모델변화를 모니터링 함으로써 공정 이상유무를 탐지해 낼 수 있었다. 기존의 관측치를 기반으로 하는 이상 탐지 기법에서 모델을 기반으로 한 실시간 이상탐지 가능성을 보였으며, 시계열을 따르는 공정관리에 있어서 특정 분포의 가정이나 자기 상관관계, 관리도 모수의 가정 등의 제약에서 벗어날 수 있음을 보였다. 반면, 특정 공정 환경에서는 제안 알고리즘이 갖고 있는 한계를 보였으며, MPBC관리도는 모델모수의 변동이 작을 경우 관리가 취약함을 나타냈다. 시계열을 따르는 실제 공정 환경은 다양한 변화가 발생 할 수 있다. 따라서 특정 환경에 우수한 관리도만으로 공정을 관리하기엔 한계를 갖는다. 본 연구에서 제안하는 MPBC는 기존의 전통적인 관리도와 함께 사용된다면 보다 효과적인 공정관리가 될 수 있을 것이다.

본 연구에서는 Box-jenkins모델 중 ARMA(1,1)모델을 대상으로 공정 상황을 가정 하였으나, ARMA(p,q)모델에서 p 와 q 의 값을 추정하여 모델의 형태를 결정하는

것 또한 시계열 데이터 분석에 중요한 연구이다. RLS를 이용한 실시간 모델 업데이트는 ARMA(p,q)모델의 p 와 q 를 추정하는 연구로 이어질 수 있다. 또한, 현재의 연구는 단변량 시계열 데이터 공정을 대상으로 하였다. 추후 연구로는 제안 방법을 활용하여 다변량 시계열 공정에서의 연구로 이어질 수 있을 것이다. 더불어 MPBC에서 사용된 OCC관리도는 다양한 알고리즘 중의 한 가지인 K^2 관리도를 기반으로 하였다. 하지만 관리환경과 알고리즘 성능에 따라 다양한 OCC알고리즘을 활용하여 보다 나은 성능을 가지는 관리도를 활용 할 수 있을 것이다.

감사의 글

이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임(2011-0002528). 본 과제는 정보통신산업진흥원의 SW공학 요소기술 개발과 전문인력 양성사업의 결과물임을 밝힙니다.

참 고 문 헌

1. 김종락, 이언경, 김지선, 정민기, 박지영, 김창원(2004), "시계열 분석을 이용한 생물학적 수처리 공정의 거동 예측", *대한환경공학회 추계학술연구발표회 논문집*, Vol. 10, pp. 925-928.
2. 오창근, 나상섭, 이현구(1998), "비선형 ARMA 모델을 이용한 연속식 PS 중합 반응계의 식별", *한국화학공학회*, Vol. 4, No. 2, pp. 2253.
3. 이재현, 김미정(2010), "자기회귀이동평균(1,1) 잡음모형에서 이상원인 탐지 및 재수정 절차", *한국데이터정보과학회지*, Vol. 21, No. 5, pp. 841-852.
4. 최인후, 김정두(1994), "자기회귀-이동평균(ARMA) 모델에 의한 초음파 진동 절삭 공정의 해석", *한국정밀공학회지*, Vol. 11, pp. 160-165.
5. Alessandri, A., Cuneo M., Pagnan S. and Sanguineti S. (2007), "A Recursive Algorithm for Nonlinear Least-squares Problems", *Computational Optimization Applications*, Vol. 38, pp. 195-216.
6. Anderson, T. W. and Darling, D. A. (1952), "Asymptotic theory of certain "goodness-of-fit" criteria based on stochastic processes". *Annals of Mathematical Statistics*, Vol. 23, pp. 193-212.
7. Ann, Y. J. (2007), "Six Sigma and Quality Management", Parkyoungsa, Seoul, Korea.
8. Apley, D.W. and Tsung F. (2002), "The autoregressive

- T-squared chart for monitoring univariate autocorrelated processes”, *Journal of Quality Technology*, Vol. 34, pp. 80-96.
9. Apley, D.W. (2002), “Time Series Control Charts in the Presence of Model Uncertainty”, *ASME Journal of Manufacturing Science and Engineering*, Vol. 124, No. 4, pp. 891-898.
 10. Apley, D.W., and Shi, J. (1999), “GLRT for Statistical Process Control of Autocorrelated Processes”, *IIE Transactions*, Vol. 31, No. 12, pp. 1123-1134.
 11. Bartkowiak, A.M. (2010), “Anomaly, novelty, one-class classification: A short introduction”, *Computer Information Systems and Industrial Management Applications (CISIM)*, 2010 International Conference on 8-10 Oct. 2010.
 12. Bowerman, B., O’Connell R. and Koehler A. (2005), *Forecasting Time Series and Regression*, 4th Edition, Thomson Brooks.
 13. Box, G.E.P., Jenkins G.M., and Reinsel G.C. (1994), *Time Series Analysis: Forecasting and Control*. Prentice-Hall, Inc.
 14. Welch, G and Bishop, G. (2006), *An Introduction to the Kalman Filter*, <http://www.cs.unc.edu/~welch>, UNC-Chapel Hill, 95-041.
 15. Goodwin, G.C. and Sin, K.S. (1984), *Adaptive Filtering Prediction and Control*. Prentice-Hall, Englewood Cliffs, N.J.
 16. Harris, T. J. and Ross, W. H. (1991), “Statistical process control procedures for autocorrelated observations”. *The Canadian Journal of Chemical*. Vol. 69, pp. 48-57.
 17. Healy J.D. (1987), “A note on multivariate CUSUM procedure”. *Technometrics* Vol. 29, pp. 409-412.
 18. Hu, S. J. and Roan, C. (1996), “Change patterns of time series-based control charts”. *Journal of Quality Technology*, Vol. 28, pp. 302-312.
 19. Kim, S. B., Weerawat, J. and Thuntee, S. (2010), “One-Class Classification-Based Control Chart for Monitoring Autocorrelated Multivariate Processes” *Communications in Statistics—Simulation and Computation*, Vol. 39, pp. 461-474.
 20. Ljung, L. and Soderstrom, T. (1983), “Theory and Practice of Recursive Identification”, *The MIT Press*, October 1983, pp. 551
 21. Lu, C. W. and Reynolds, M. R. (1999a), “Control chart for monitoring the mean and variance of autocorrelated processes”. *Journal of Quality Technology*. Vol. 31, pp. 259-274.
 22. Massey, F. J. (1951), “The Kolmogorov-Smirnov Test for Goodness of Fit”. *Journal of the American Statistical Association*. Vol. 46, pp. 68-78.
 23. Mandel, B.J. (1969), “The regression control chart”. *Journal of Quality Technology*. Vol. 1, pp. 1-9.
 24. Montgomery, D. C. (2001), *Introduction to Statistical Quality Control, 5th Edition*, Hohn Wiley & Sons, NewYork, NY, 2001.
 25. Moonen, M. (2004), *Introduction to adaptive signal processing*, Department of Electronic Engineering, Belgium; ALARI/DSP - Lecture 4.
 26. Pandit, S. M. and Wu, S. (1983), *Time Series and System Analysis with Application*, John Wiley, New York. pp. 291, 491-492.
 27. Sukhotrat, T., Kim, S.B. and Tsung, F. (2010), “One-class Classification-based control charts for Multivariate process monitoring”. *IIE Transactions*. Vol. 42, No. 2, pp. 107-120.
 28. Tax, D.M.J. (2001), *One-Class Classification: Concept-Learning in the Absence of Counter-Examples*, PhD thesis, Delf University of Technology, Netherlands.
 29. Tsung, F. and Tsui, K. L. (2003), “A mean-shift pattern study on integration of SPC and APC for process monitoring”. *IIE Transactions*, Vol. 35, pp. 231-242.



박 시 저 (parkcaesar@korea.ac.kr)

2009 고려대학교 산업시스템정보공학과 학사
2009~현재 고려대학교 정보경영공학전문대학원 석사

관심분야 : Advanced process control, Data mining applications



박 정 슴 (dumm97@korea.ac.kr)

2003 고려대학교 산업시스템정보공학과 학사
2006 고려대학교 산업시스템정보공학과 석사
2005~2006 삼성경제연구소 6시그마실 Research Analyst
2006~2007 고등기술연구원 로봇생산기술센터 연구원
2008~현재 고려대학교 정보경영공학전문대학원 박사과정

관심분야 : Advanced process control, Data mining



김 성 식 (sungskim@korea.ac.kr)

1972 고려대학교 기계공학과 학사
1974 고려대학교 산업공학과 석사
1976 미국 Southern Methodist University 산업공학과 석사
1979 미국 Southern Methodist University 산업공학과 박사
1979~현재 고려대학교 산업경영공학과 교수

관심분야 : Advanced process control, System modeling and optimization



백 준 걸 (jungeol@korea.ac.kr)

1993 고려대학교 산업공학과 학사
1995 고려대학교 산업공학과 석사
2001 고려대학교 산업공학과 박사
2001~2002 고려대학교 정보통신기술연구소 연구조교수
2002~2007 인덕대학교 산업시스템경영학과 조교수
2007~2008 광운대학교 경영학부 조교수
2008~현재 고려대학교 산업경영공학과 부교수

관심분야 : Advanced process control, Intelligent fault detection, Data mining applications