

실시간 시멘트 품질예측기의 개발

김봉준*·이종필 이성문

〈동양중앙연구소〉 〈동양메이저 동해공장〉

1. 서 론

최근 국내외의 시멘트 생산능력이 급격하게 신장되면서 시멘트의 수요보다 공급이 늘어나는 추세이다. 따라서, 고객의 요구에 능동적으로 대처하고 시장 경쟁에서도 우위를 선점하기 위해서는 시멘트의 생산량보다는 품질을 중요시 하는 생산 전략이 필요하다.

시멘트 분쇄공정은 전체 시멘트 생산공정에서 최종의 제품을 생산하는 공정으로 시멘트의 품질을 결정하는데 직접적 영향을 미치는 공정이다. 이러한 중요성에도 불구하고, 현재까지 개발된 시멘트 분쇄공정에 관한 제어시스템은 생산량의 증대만을 목적으로 하는 시스템이 대부분이었다. 또한, 생산되는 시멘트의 품질도 이미 생산된 시멘트를 일정시간 간격으로 샘플을 채취, 분석하는 수동적 품질관리 방법을 이용하였다.

시멘트의 품질을 중요시 하는 노력의 일환으로 시멘트 분쇄공정에 대한 자동제어 시스템에 품질 제어의 개념을 추가하려는 시도가 주요 시멘트 생산업체에서 이루어졌다. 그러나, 현재와 같이 1시간~수시간 간격으로 시멘트를 샘플링하는 방법으로는 샘플링 주기 동안에 생산되는 시멘트의 품질에 대한 모니터링과 제어가 이루어지지 않으므로, 공정의 외란에 미리 대처할 수가 없다. 또한, 제어동작도 그만큼의 지연시간을 가져오게 되므로, 품질에 큰 편차가 발생할 수 있으며, 이 편차의 복구시간도 길어지게 된다. 특히, 안정적인 시멘트의 품질은 경제성과 직결되는 매우 중요한 사항으로 많은 연구가 이루어졌으나, 실제 공정에 적용하기에는 너무 복잡하거나, 운영이 어려운 단점이 있다.

이러한 단점을 극복하고자 생산되는 시멘트의 품질(Blaine)을 실시간으로 예측할 수 있는 품질 예측기를 개발하였다. 품질예측기는 inferential sensor 또는 soft-sensor라고 불리는 기술을 응용한 것으로, 시멘트 분쇄공정의 공정 변수와 실험실 품질 분석치의 상관관계를 밝혀내는 것이다. Inferential sensor는 직접측정이 어렵거나, 시간지연이나 샘플링 주기가 큰 변수(예: 실험실 분석치 등)를 실시간으로 측정이 쉽고 샘플링 주기가 짧은 연관된 다른 변수(예: 온도, 압력 등)를 이용하여 추정하는 방법이다.

본 연구에서는 두가지의 방법을 제시한다. 하나는 과거부터 많이 이용되어온 시간에 따른 공정 변수를 다항식으로 연관짓는 방법으로, 공정 변수를 주변수와 부변수로 나누어 공정 모델을 구성하는 방법이다. 이 방법은 많은 방법이 알려져 있으나, 정확한 공정 모델을 구성하기가 어렵고, 변수사이의 영향을 충분히 고려하지 못하며, 잡음에 매우 민감한 단점을 보인다.

다른 하나는 최근에 많은 연구가 진행된 것으로, 통계적인 데이터 베이스를 이용하는 방법으로 대표적으로는 Principle Component Analysis(PCA)가 있다. 이 방법은 모델의 구성이 용이하며, 공정 변수의 연관성을 배제할 수 있고, 잡음의 영향을 최소화하는 안정적 출력을 얻을 수 있다는 장점이 있다.

2. Soft-Sensor (Inferential Sensor)

2.1 General Model Structure

일반적으로 시멘트의 품질은 시료의 추출, 전

처리, 분석을 거치므로 sampling interval이 긴, infrequently measured variable이다. 이에 반하여 온도, 압력 등의 공정 측정치는 data acquisition system에 의해 비교적 손쉽게 측정할 수 있는 frequently measured variable이다. 품질예측기를 구성하는 input variable(frequently measured variable)은 추정하려는 변수와의 시간지연이 있으므로, 각 변수마다 이를 고려하여 적절하게 재배열되어야 한다. 그러나, 시멘트 품질의 sampling interval은 frequently measured variable의 sampling interval에 비하여 매우 긴 것이 일반적이다. 따라서, 시멘트 품질의 한 sampling interval 사이의 모든 frequent한 공정 측정치는 모두 다음 단계의 생산품에 영향을 미친다고 가정할 수 있다. 또한, 이렇게 구성된 모델은 각 변수 사이의 시간지연을 특별히 고려하지 않고도 모델을 손쉽게 구성할 수 있다는 장점이 있다.

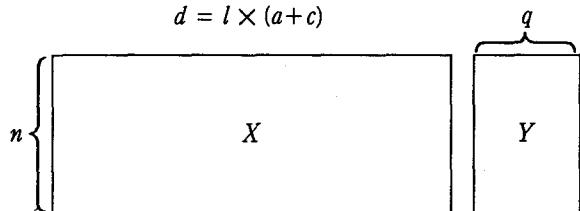
품질예측기의 일반적 모델은 다음과 같이 표현할 수 있다.

$$y_k = f(U_{k-1}, d_k) \quad (1)$$

$x \in R^d$ 는 추정하고자 하는 infrequently measured variable이고, $U_{k-1} = [u_{k-1}^T \cdots u_{k-l}^T]^T$ 는 직접적인 조작이 가능한 known variable이며, $u_i \in R^a$ ($k-l \leq i \leq k-1$)는 공정에 연속적으로 작용하는 unknown parameter이다. k 는 각 sampling step을 나타내며, l 은 y 의 한 sampling interval 사이에 들어가는 frequent process measurements의 sampling step의 개수이다. y 이외에 추가적인 변수를 고려할 수 있는데, 이를 V 로 표현하자. V 는 온도, 압력 등 직접 조작할 수는 없지만, 다른 조작변수에 의한 공정 출력으로 frequently measured variable이다.

$$\begin{aligned} V_k &= \phi(U_{k-1}, d_k), \quad V_k = [v_{k-l+1}^T \cdots v_k^T]^T \\ v_i &\in R^c \quad (k-l+1 \leq i \leq k-1) \end{aligned} \quad (2)$$

식(2)에서 V 에 대한 일련의 정보를 알고 있으므로, 이를 이용하여 unknown parameter d 를 추정할 수 있다. 만약, d 를 추정할 수 있는 최적의 모델을 알고 있다면, 다음과 같이 표현할 수 있다.



<Fig. 1> 입력변수 x 와 출력변수 y 의 sampling interval에 따른 관계

$$\hat{d}_{k|k} = \beta(U_{k-1}, V_k) \quad (3)$$

이를 이용하여, 품질예측기를 재구성 하면 다음과 같다.

$$\begin{aligned} \hat{y}_k &= f[U_{k-1}, \beta(U_{k-1}, V_k)] \\ &= g(U_{k-1}, V_k) \end{aligned} \quad (4)$$

결과적으로, 추정하려는 변수 y 는 분쇄공정의 manipulated variable u 와 secondary variable인 v 의 함수로 구성되며, 모두 입력 변수로 동일하게 취급할 수 있다.

2.2 Principle Component Analysis

$x \in R^d$, $(d = l \times m, m = a + c)$, $(d = l \times m, m = a + c)$ 가 품질예측기의 입력변수 u 와 v 를 나타내는 vector라고 하자. 앞서 설명한 바와 같이, 출력변수 y 의 한 sampling interval 사이에서의 모든 정보는 바로 다음step의 y 에만 영향을 미친다고 가정하면, <Fig. 1>과 같은 관계를 구성할 수 있다. 만약 입력변수와 출력변수를 n 번 만큼 sampling 했다면 각각의 matrix은 $X \in R^{n \times d}$, $Y \in R^{n \times q}$ 가 된다.

PCA는 matrix X 를 다음과 같이 p 개의 component로 구성된, score와 loading matrix의 product로 분해한다.

$$X = TP^T + E \quad (5)$$

E 는 residual이며, 입력 data에서 noise 부분을 나타낸다. $T \in R^{n \times p}$ 는 score matrix를 X 는 loading matrix를 나타낸다. T 와 P 는 NIPALS 등과 같은 알려진 알고리즘을 이용하여 구할 수 있다. 추출한 component는 공정 특성의 정보를 가지고 있으며, 이는 prediction model을 구성하는데 기반이 된다.

식 (5)는 입력변수 X 를 보다 뛰어난 특성의 새로운 변수로 바꾸는 과정이며, 새로운 multidimensional space로 span하는 것이다. 추출된 principle component는 orthogonal 하기 때문에 regression시에 matrix inverse를 계산하는데 singularity problem이 없으며, collinearity나 ill-conditioning과 같은 문제를 해결할 수 있다. 또한, 영향이 미소한 component를 제거함으로써 original data로부터 noise(random error)를 줄이는 효과를 얻을 수 있다. 일부 필요한 information이 residual term에 남아버려질 가능성은 prediction에 가장 적절한 개수의 component를 선정함으로써 최소화 할 수 있다. 따라서, data set 이 well conditioning 되었다는 것과, PC의 test 과정을 제외하고는 일반적인 regression 방법을 동일하게 적용할 수 있다는 장점이 있다.

하나의 training set X 로부터 component를 추출한 후, 새로운 data set를 sampling 했을 경우의 score는 data set x_{new} 를 score vector area로 projection하면 얻을 수 있다.

$$\hat{t} = P^T x_{new} \quad (6)$$

이를 이용하여 prediction 및 residual을 구하면 각각 :

$$\hat{x}_{new} = P\hat{t} = PP^T x_{new} = \varepsilon x_{new} \quad (7)$$

$$r = x_{new} - \hat{x}_{new} = (I - \varepsilon) x_{new} \quad (8)$$

이다.

2.3 Build a Prediction Model

입력변수로부터 출력변수 y 를 직접 관계시키는 것이 아니라, score t 에서 y 와의 error를 최소화 시키는 model을 수립한다.

$$\min \left[\sum_{k=1}^n \| y_k - \Gamma(t_k, \theta) \|^2 \right] \quad (9)$$

θ 는 model parameter이다. 품질예측기는 score vector와 y 가 보이는 특성에 따라 여러가지 형태를 보일 수 있다. 가장 간단하게는 linear model을 적용할 수도 있고, non-linear model을 적용할 수도 있다. Linear model을 이용할

경우 prediction model은 principle component regression (PCR) model이 된다.

3. Application

3.1 Prediction Model

시멘트의 품질은 분쇄공정의 내부 흐름, 외부 흐름, 밀내부의 충진율, 원료의 hardness 등과 관계가 있다. 따라서, 공정변수 중 이러한 요소와 관계가 깊으며, 품질과 상관성이 큰 6개의 변수를 선정하여 모델을 구성하였다. 생산되는 시멘트는 1시간마다 sampling이 이루어지며, input variable은 10분마다 sampling을 수행하였다. 따라서, 6개 변수는 시멘트 품질의 실험실 분석치가 1번 sampling 되는 동안 6번의 sampling이 이루어진다. 앞서 2.2절에서 설명한 바와 같이 '6개의 변수 \times 6번의 sampling = 36개의 공정 data'는 모두 1개의 시멘트 품질과 대응되도록 구성된다. 공정 특성상 회전체나 궤도 운전체가 많기 때문에, 적절한 noise filter를 사용하였으며, 모든 공정변수는 mean centering 및 variance scaling을 통하여 전처리하였다.

$$\hat{Y} = \hat{B}T, \hat{B} = (T^T T)^{-1} T^T Y \quad (10)$$

식 (9)의 criteria를 만족하는 model로는 (17)과 같은 간단한 linear model을 구성하였으며, 결과적으로 principle component regression (PCR)을 수행한 결과가 된다. Score vector T 는 orthogonality로 인하여 regression시에 $T^T T$ 의 inverse는 문제를 일으키지 않는다.

3.2 Time series model

Principle component를 이용한 품질예측기의 성능 비교를 위하여, 일반적인 time series model을 구성하고 동일한 공정변수의 data set을 이용하여 비교하였다. Time series model의 구조는 다음과 같다.

$$y(t) = \sum_{i=1}^p \frac{B_i(q^{-1})}{A(q^{-1})} x_i(t) + e(t) \quad (11)$$

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_l q^{-l} \quad (12)$$

$$B_i(q^{-1}) = b_{i,1} q^{-1} + \dots + b_{i,l} q^{-l}$$

$e(t)$ 는 residual이며, q 는 time shift operator이다. μ 의 크기는 y 가 sampling하는 주기 동안에 sampling하는 x_i 의 개수로 지정하였으며, 결과적으로 principle component를 이용한 품질 예측기와 동일한 구성을 보인다. 이것은 y 와 다른 변수의 시간지연 및 시정수를 비교하면 합리적인 구성으로 볼 수 있으며, 또한 principle component 추출에서 설정한 가정 — y sampling 주기가 충분히 길면, 해당주기 동안의 x data는 모두 다음번의 y 에 영향을 미친다. — 과도 일치한다. y 의 sampling 주기가 l 이므로, 식 (11)은 다음과 같이 표현된다. 결과적으로 모델은 37개의 parameter로 표현된다.

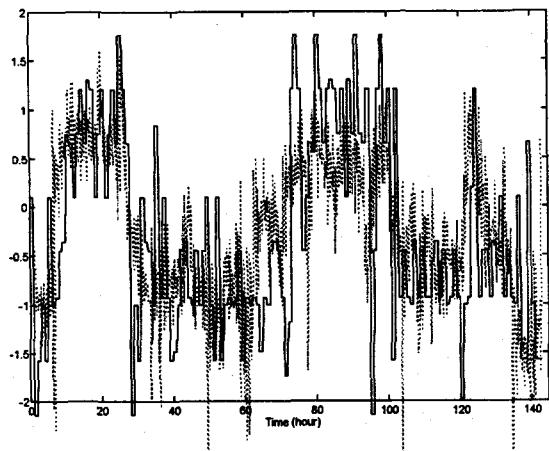
$$(1 + \alpha_1 q^{-1}) \hat{y} = (\beta_{1,1} q^{-1} + \dots + \beta_{1,l} q^{-l}) x_1(t) + \dots + (\beta_{\mu,1} q^{-1} + \dots + \beta_{\mu,l} q^{-l}) x_\mu(t) \quad (13)$$

3.3 Application result

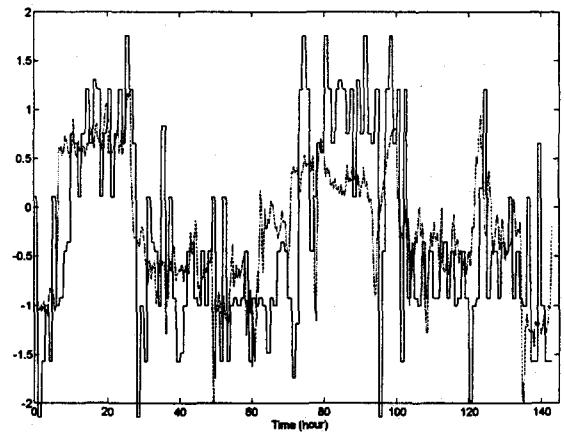
공정실험은 동양시멘트(주)의 북평공장에서 수행하였다. Training set는 두 종류의 품질을 번갈아 생산하는 7일간의 연속운전 데이터를 이용하였고, 수일 후 3일간의 연속운전 데이터를 다시 수집하여 예측 성능을 비교하였다. Training set은 의도적으로 짧은 시간에 공정 상황이 크게 변화하는 구간을 설정하였다. 실제로 이와 같이 운전하는 경우는 드물다.

Training set의 데이터를 이용하여 각각 time series model과 principle component를 이용하여 regression한 결과를 Fig. 2에 보였다. Sum of squared error(SSE)를 비교해 보면, 0.6854와 0.6531로 PCR의 경우가 약간 뛰어난 성능을 보였다. 전체적인 경향을 볼 때, PCR의 경우가 noise reduction이 더 뛰어난 것을 확인할 수 있다.

Fig. 3가 이러한 경향을 두드러지게 나타낸다. 해당 구간을 training set으로 가정하고 regression을 수행한 결과이다. SSE를 비교하면 각각 0.7105와 0.4951로 큰 차이를 보이고 있다. 전체적인 pattern은 두 경우 모두 유사한 경향을 보이지만, time series model의 경우에는 잡음 요소를 가지고 있는 변수가 regression에서 주도적인 영향을 미치게 되면 noisy한 경향을 보인다.



(a) Model-based : time series

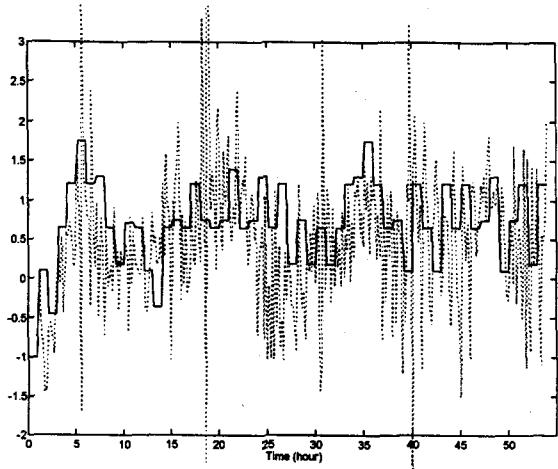


(b) Data-based : PCR

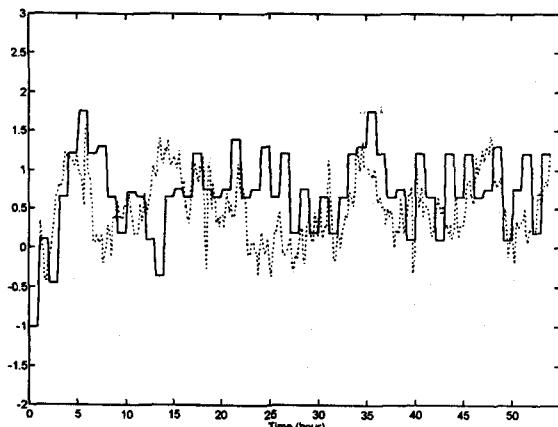
<Fig. 2> Fineness estimation : training set

따라서, 품질예측기의 안정성이 떨어지며, 이를 이용하여 control loop를 구성하는 경우에는 전체적인 system에 unstable한 요인으로 작용하거나, 과도한 control action을 요구하는 등, control input으로 부적절한 요소를 지니고 있다. 이에 반하여 PCR의 경우에는 noise reduction의 기능이 뛰어나, 안정적인 regression 결과를 나타내고 제어기의 동작에도 과도한 부하를 주지 않게 된다.

예측 성능을 알아보기 위하여, training set에서 구한 parameter를 이용하여 다른 구간의 Blaine 값을 예측한 결과를 Fig. 4에 보였다. Time series model의 경우는 동일한 regression parameter를 이용한 것이고, PCR의 경우는 동일한 principle component와 regression



(a) Model-based : time series

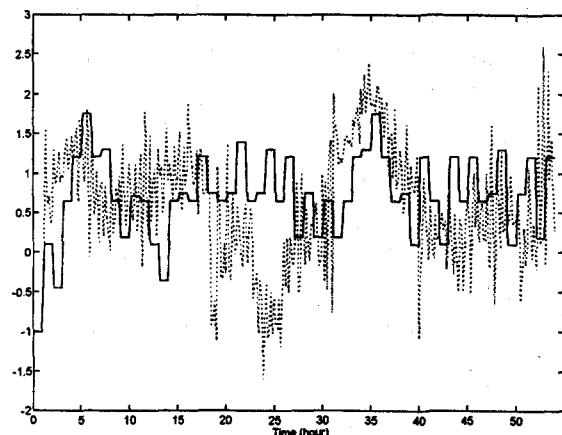


(b) Data-based : PCR

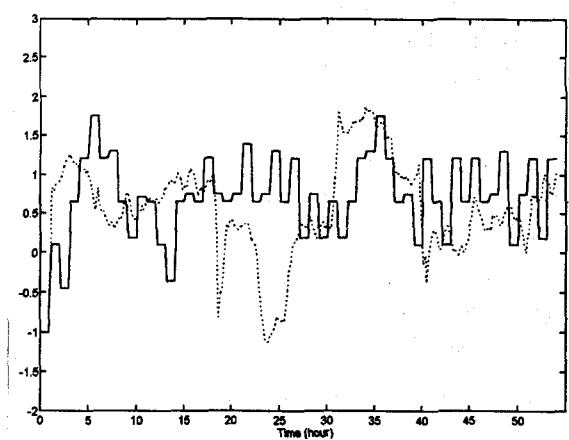
<Fig. 3> Fineness estimation : noise reduction

parameter를 이용하였다. 두 경우의 SSE는 0.7088과 0.6147로 prediction pattern은 유사 하지만, PCR이 더 뛰어난 예측 결과를 보이는 것으로 나타났다. 그러나, 공정실험을 수행한 구간이 공정상황이 자주 변동하는 구간이므로, 일부 구간에서는 실험실 분석치와 다른 경향을 나타내기도 하였다.

실제응용에서 공정상황의 급격한 변화에도 안정된 예측 성능을 보장하기 위해서는 training set으로부터 추출한 principle component를 이용하더라도, regression parameter를 adaptive하게 변화할 필요가 있을 것으로 판단된다. <Fig. 5>에 그 결과를 나타내었다. 즉, principle component를 재추출하지는 않지만, recursive least square regression을 이용하여 실험실 분

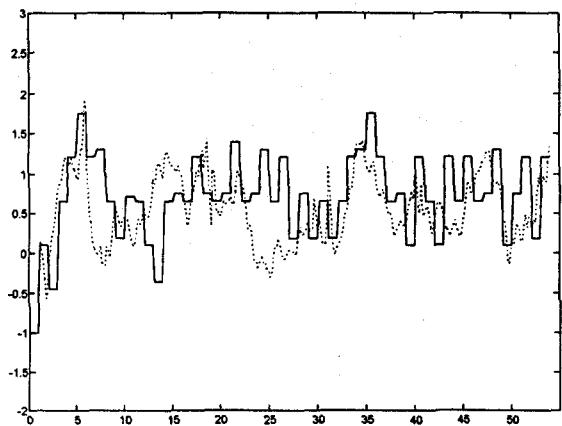


(a) Model-based : time series



(b) Data-based : PCR

<Fig. 4> Fineness estimation with fixed parameters of training set



<Fig. 5> Fineness estimation with RLS regression

석치가 입력되는 매단계마다 regression parameter를 update하였다. 데이터가 noisy한 때문

인지 regression parameter만을 update한 경우 가 component를 재추출한 경우보다 SSE가 더 작은 값을 보였다. ($SSE = 0.4679$)

4. Conclusion

시멘트 생산공정에서의 실시간 품질예측을 위한 예측기를 Model 구성의 관점과 database를 응용하는 관점에서 개발하였다. Model을 구성하는 접근법은 많은 알려진 이론을 적용할 수 있으며, 공정의 dynamics를 충분히 반영할 수 있다 는 장점이 있으나, 공정변수의 잡음을 효과적으로 제거하지 못하여 예측결과가 noisy하며, 실제적으로 정확한 model을 구성하기 어려운 단점이 있다. Database를 이용하는 접근법은 모델의 구성이 용이하고 특히, noise reduction이 뛰어나 예측결과가 안정적인 장점이 있으나, 공정의 dynamics를 충분히 표현하지 못하는 단점이 있다.

향후에는 database를 이용한 접근법에 principle component를 추출하기 위하여 연관된 변수를 선정하는 방법, dynamics를 표현하는 방법, 공정의 nonlinearity를 표현하기 위한 regression 방법의 변경 등에 대한 연구가 수행되어야 한다. 또한, sensor fault로 인한 품질예측기의 성능저하를 막기 위한 공정변수의 예측과, extrapolation test를 통한 공정상태 변화를 감지하여 principle component를 재추출하는 방법에 관한 연구도 필요하다.

개발된 품질예측기는 시멘트의 품질에 대한 관심도가 증가하는 현재의 시장상황에서 품질의 실시간 모니터링으로 뿐만 아니라, 다양한 품질의 시멘트를 생산하는 공정에도 도움을 줄 것으로 예상되며, 향후 품질제어기의 구성에도 많은 기

여를 할 것으로 사료된다.

References

- 1) Joseph, B., and Brosilow, C., 'Inferential control of processes', AIChE J., 1978, 24, 485~509.
- 2) Lee, J.H., and Morari, M., 'Robust inferential control of multi-rate sampled data systems', Chem. Eng. Sci., 1992, 47, 865~885.
- 3) Tham, M.T., Montague, G.A., Morris, A.J., and Lant, P.A., 'Soft-sensors for process estimation and inferential control', J. Proc. Cont., 1991, 3~14.
- 4) MacGregor, J.F., Jaeckle, C., Kiparisides, C., and Koutoudi, M., 'Process monitoring and diagnosis by multiblock PLS methods', AIChE J., 1994, 40, 826~838.
- 5) Geladi, P., and Kowalski, B.R., 'Partial least-squares Regression : a tutorial', Analytica Chemica Acta, 1986, 185, 1~17.
- 6) Wise, B.M., Ricker, N.L., Veltkamp, D.F., and Kowalski, B.R., 'A theoretical basis for the use of principal component models for monitoring multivariate processes', Process control and quality, 1990, 1, 41~51.
- 7) Bang, S.H., Kim, B.J., Hwang, I.Y., and Hong, C.S., 'Control system upgrade at Tong Yang Cement', World Cement, Sep. 1996.