

개선된 스케일 스페이스 필터링과 함수연결연상 신경망을 이용한 화학공정 감시

Monitoring of Chemical Processes Using Modified Scale Space Filtering and Functional-Link-Associative Neural Network

최 중 환, 김 윤 식, 장 태 석, 윤 인 섭
(Jung-Hwan Choi, Yoon-Sik Kim, Tae-Suk Chang, and En-Sup Yoon)

Abstract : To operate a process plant safely and economically, process monitoring is very important. Process monitoring is the task to identify the state of the system from sensor data. Process monitoring includes data acquisition, regulatory control, data reconciliation, fault detection, etc. This research focuses on the data reconciliation using scale-space filtering and fault detection using functional-link associative neural networks. Scale-space filtering is a multi-resolution signal analysis method. Scale-space filtering can extract highest frequency factors(noise) effectively. But scale-space filtering has too large calculation costs and end effect problems. This research reduces the calculation cost of scale-space filtering by applying the minimum limit to the gaussian kernel. And the end-effect that occurs at the end of the signal of the scale-space filtering is overcome by using extrapolation related with the clustering change detection method. Nonlinear principal component analysis methods using neural network have been reviewed and the separately expanded functional-link associative neural network is proposed for chemical process monitoring. The separately expanded functional-link associative neural network has better learning capabilities, generalization abilities and short learning time than the exiting neural networks. Separately expanded functional-link associative neural network can express a statistical model similar to real process by expanding the input data separately. Combining the proposed methods - modified scale-space filtering and fault detection method using the separately expanded functional-link associative neural network - a process monitoring system is proposed in this research. The usefulness of the proposed method is proven by its application a boiler water supply unit.

Keywords : process monitoring, fault detection, scale-space filtering, functional link associative neural network

1. 서론

공정 감시란 센서 데이터로부터 공정의 상태를 파악하여 공정의 거동을 감시하고 특정 이벤트를 제거함으로써 공정을 향상시키는 작업으로 공정을 안전하고 경제적으로 조업하기 위해 꼭 필요하다.

공정 감시를 위해서는 공정 데이터의 다양한 스케일에서의 해석과 이를 통한 변화감지, 데이터의 정성적 해석, 공정 경향의 표현 등이 선행되어야 한다. 본 연구에 사용된 스케일 스페이스 필터링(scale-space filtering)은 Witkin(1993)에 의해서 개념이 소개된 방법으로 스케일 매개변수(scale parameter)의 크기를 증가시켜 가면서 가우시안 커널(gaussian kernel)과 공정데이터와의 컨벌루션(convolution)을 통해 필터링을 수행하는 방법이다. 이 방법은 다양한 스케일에서의 효율적인 분석이 가능하지만, 데이터의 증가에 따라 계산량이 급격히 증가하며 종점 문제(end-effect)를 지니고 있어 실시간 적용이 불가능하다는 단점을 지닌다.

근래에는 측정변수가 많고 변수간 상호연관성이 크다는 화학공정의 특성상, PCA(Principal Component

Analysis)나 PLS(Partial Least Squares)와 같은 다변량 통계기법을 이용하여 공정 감시 또는 제어를 수행하고 있다. 이러한 다변량 통계기법들은 변수들간의 상호연관성을 고려하고 측정 변수들의 차원을 효과적으로 줄일 수 있을 뿐만 아니라 공정에 대한 수학적 모델 없이도 과거의 데이터들을 이용하여 통계적 모델을 구축할 수 있다는 장점을 지닌다.(Dong, 1996) 특히 PCA는 그 구조가 신경망을 학습시키는 과정과 유사하여 신경망을 이용하여 PCA를 행하려는 연구가 활발히 진행되었다.(Kramer, 1991) 본 연구에서는 화학공정의 비선형성을 고려하여 비선형성을 효과적으로 표현할 수 있는 함수연결연상 신경망(Functional-Link-Associative Neural network; FLAN)을 이용하여 비선형 PCA를 구축하고 이를 이용하여 공정 감시를 행하였다. 함수연결연상 신경망은 비선형성을 효과적으로 표현하기 위해 자동연상 신경망(Auto-Associative Neural Network; ANN)에 함수연결(functional link)개념을 도입한 방법이다.

본 연구에서는 실시간 적용이 가능하도록 종점문제를 해결하고 계산량을 고정시킨 스케일 스페이스 필터링 방법과 서로 다른 스케일을 가지는 공정데이터를 효과적으로 학습할 수 있도록 개선된 함수연결연상 신경망을 제안하고 이를 이용하여 아래와 같은 실시간 이상진단 시스템을 제안하였다.

접수일자 : 1999. 11. 30., 수정일자 : 2000. 7. 4.

최중환 : SK Chemicals 중앙연구소

김윤식, 장태석, 윤인섭 : 서울대학교 응용화학부




그림 1. 제안된 공정감시 모델의 개략도.
Fig 1. Outline of suggested process monitoring model.

먼저 off-line으로 정상상태의 공정 데이터를 입력 받아 scale-space filtering을 통해 변화 감지 한계값을 설정하고 함수연결연상 신경망을 학습시킨다. 이를 이용하여 on-line으로 입력되는 공정 데이터의 잡음수준을 체크하여 센서 이상 감지와 공정감시를 수행한다. 제안된 방법은 효율적인 공정감시 뿐만 아니라 센서의 이상까지도 감지할 수 있다는 장점을 지닌다.

II. 스케일 스페이스 필터링

1. 스케일 스페이스 이론

1차원의 연속된 신호에 대해 살펴보면, 스케일 스페이스 필터링은 다음과 같이 표현될 수 있다.

$$L(\cdot; t) = g(\cdot; t) * f \tag{1}$$

식에서 $L(\cdot; t)$ 는 스케일 스페이스 필터링된 신호를 나타내고, f 는 원래 주어진 신호, $g(\cdot; t)$ 는 가우시안 커널, 그리고 $*$ 은 컨볼루션을 나타낸다.

컨볼루션을 적분 형태로 표시하면, 다음과 같다.

$$L(x; t) = \int_{-\infty}^{\infty} g(\xi; t) f(x - \xi) d\xi \tag{2}$$

가우시안 커널 g 는 다음과 같이 표현된다.

$$g(x; t) = \frac{1}{\sqrt{2\pi t}} e^{-x^2/2t} \tag{3}$$

$$\int_{-\infty}^{\infty} g(x; t) dx = 1 \tag{4}$$

위 식에서 x 는 공간(space)을, t 는 스케일(scale)을 나타낸다. 즉, 스케일 스페이스는 시간축과 주파수축 그리고 데이터축으로 표현되는 3차원 좌표계로 표현된다.

가우시안 커널의 스케일 변화에 따른 가우시안 커널의 변화는 다음과 같다.

다양한 스케일에서의 해석이란 가우시안 커널의 스케일을 변화시켜가면서 원래 신호와의 컨볼루션을 행한다는 의미다. 이때, 그림 2에서 알 수 있듯이 가우시안 커널의 스케일이 증가할수록 원래 신호에서 더 넓은 범위의 데이터가 포함되므로, 거시적인 공정의 거동을 살펴볼 수 있다.




그림 2. 스케일 변화에 따른 가우시안 커널의 변화.
Fig 2. Gaussian kernel according to scale change.

2. 스케일 스페이스 필터링 적용

앞에 소개한 스케일 스페이스 필터링은 연속적인 데이터에만 적용이 가능하기 때문에 이산화되어 있는 화학 공정 데이터에 적용하기 위해선 이산화된 가우시안 커널을 사용하거나, 연속적인 가우시안 커널에서 필요한 값을 추출해서 계산하는 방법을 사용한다. 실제 공정 데이터에 적용해보기 전에, 다양한 스케일에서의 해석의 유용성을 알아보기 위하여 다음과 같이 증가하는 데이터에 진동과 시간에 따라 증가하는 잡음을 합친 인위적인 데이터를 만들어 이를 스케일 스페이스 필터링해 보았다.

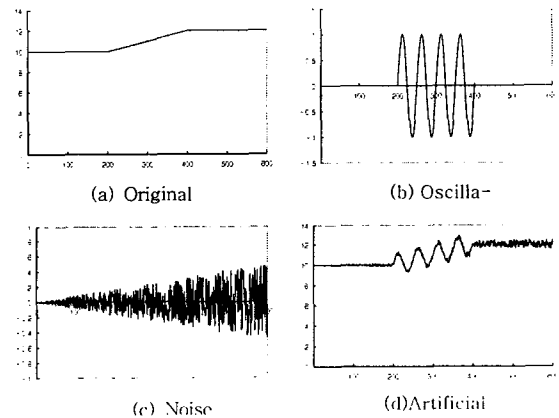




그림 3. 진동과 잡음을 포함한 인위 데이터.
Fig 3. Artificial data included noise and oscillation.


다음 그림은 스케일 매개변수를 변화시켜 가면서 스케일 스페이스 필터링을 행하여 인위적으로 만들어진 oscillation과 noise를 추출해낸 것이다.



(a) 스케일 스페이스 필터링된 데이터



(b) 필터링을 통하여 추출된 잡음



(c) 필터링을 통하여 추출된 진동

그림 4. 스케일 스페이스 필터링 결과.

Fig 4. Result of scale space filtering.

위에서 알 수 있듯이, 스케일 스페이스 필터링을 이용하면 잡음뿐만 아니라 진동까지도 효과적으로 추출해낼 수 있다. 그러나, 그림 4의 (a)에서 볼 수 있듯이, 데이터의 양 끝부분에서 필터링된 값이 실제값보다 작게 나오는 종점문제(end-effect)가 발생함을 알 수 있다. 종점 문제는 스케일 스페이스 필터링이 현재 데이터를 기준으로 과거의 데이터뿐만 아니라 미래의 데이터도 필요로 하기 때문에 발생하게 된다. 즉, 과거 데이터가 없는 시작부분과 미래 데이터가 없는 끝부분에서 종점문제가 발생하는 것이다.

3. 스케일 스페이스 필터링의 실시간 적용

스케일 스페이스 필터링 기법은 모든 데이터들이 가중치를 갖기 때문에 데이터 수의 증가에 따라 계산량이 기하급수적으로 증가하기 때문에 실시간 적용이 불가능하다. 이러한 방법을 개선하기 위하여 본 연구에서는 다음 그림 5와 같이 가우시안 커널에 최소한계를 설정하는 방법을 제안하였다. 이는 기존의 스케일 스페이스 필터링 기법이 실질적으로 현재의 데이터에 별 영향을 미치지 않는 과거와 미래의 모든 데이터에 가중치를 줌으로써 발생하던 계산량 문제를 효율적으로 해결한 방법이다.




그림 5. 수정된 가우시안 커널.

Fig 5. Modified gaussian kernel.

본 연구에서 제안한 방법과 기존의 방법의 계산량을 비교한 그림은 다음과 같다.





그림 6. 기존 방법들과의 계산량 비교.

Fig 6. Calculation cost comparison with existing Methods.


위 그림에서 재귀(Recursive) 스케일 스페이스 필터링 방법(Choi, 1995)은 기존 필터링 계산 결과값들을 기억하여 현재 데이터의 필터링 계산에 활용하는 방법으로써 계산량을 효과적으로 줄일 수 있지만 과거의 필터링 계산값들을 모두 기억해야 하므로 메모리면에서 매우 비효율적이다. 반면 본 연구에서 제안된 방법은 가우시안 커널 가중치(그림 4 참조)에서 최소 한계값을 0.001로 설정함으로써 실질적으로 필터링에 영향을 미치지 못하는 먼 과거와 미래의 데이터를 필터링 계산에서 제외시킴으로써 시간의 흐름에 따라 항상 일정한 계산량을 갖는 것을 알 수 있다.

또한 본 연구에서는 종점문제를 해결하기 위해, 변화감지기법과 연계된 외삽방법으로 미래 데이터를 예측하는 방법을 사용하였다. 변화감지기법으로는 클러스터링 기법을 사용하였는데, 클러스터링 기법의 중심값을 이용하여 외삽을 수행하였다.


본 연구에서 제안한 방법을 사용하여 필터링을 수행한 결과는 다음과 같다.



(a) 필터링된 데이터



(b) 필터링을 통해 추출된 진동



(c) 필터링을 통해 추출된 잡음


그림 7. 필터링 결과.

Fig 7. Result of filtering.


III. 비선형 PCA 를 이용한 공정감시

1. PCA

DCS(Distributed Control System)등을 통해 실시간으로 많은 양의 상호연관성이 큰 공정 데이터들이 얻어지는 화학공정의 특성상 측정변수들의 차원을 효과적으로 줄일 수 있고 변수들 간의 상호연관성을 잘 표현할 수 있는 PCA, PLS와 같은 다변량 통계기법들이 화학공정 감시를 위해 많이 사용되고 있다. 특히, PCA는 상호연관성이 큰 변수들을 새로운 축을 정의하여 기존 변수들보다 적은 수의 변수들(Principal Component; PC)로 mapping시키기 때문에, 공정 정보를 그대로 유지하면서 시스템의 차원을 줄일 수 있는 방법이다. PCA는 이와 같은 mapping과정과 demapping과정을 거쳐 입력된 측정변수의 값을 그대로 예측할 수 있기 때문에 정상상태의 공정 데이터를 학습시켜 놓으면 실제 공정 입력값에 대해서도 정상상태의 데이터와 유사한 값을 예측하게 된다. 이러한 성질을 이용하여 실제 공정감시의 적용에 있어서는 입력데이터와 예측데이터간의 SPE(Squared Prediction Error)를 가지고 공정의 이상유무를 판단하게 된다.



(a) 자동 연결 연상 신경망



(b) 함수 연결 연상 신경망

그림 8. 자동 연결 연상 신경망과 함수 연결 연상 신경망의 비교

Fig 8. Comparison between FLAN and ANN.

2. 신경망을 이용한 비선형 PCA

1991년에 Kramer는 다음 그림의 (a)와 같이 5개의 층으로 이루어진 ANN(Autoassociative Neural Network)을 이용하여 비선형 PCA를 구축하였다. (b)는 본 연구에 사용된 함수연결연상 신경망으로 Pao(1989)에 의해 제안된 함수연결 개념을 도입하여 비선형성을 좀더 잘 표현할 수 있도록 입력층을 확장시킨 것이다.

함수연결이란 입력값들의 내적이거나 입력값에 제곱 또는 sine이나 cosine을 취한 값을 추가로 입력하여 학습시키는 개념이다. 비선형성을 고려한 입력값으로 학습하기 때문에 비선형성을 좀더 잘 나타낼 수 있다. 최근에 많이 사용되고 있는 IT(Input Training)-net(Reddy, 1998)은 학습에 필요한 계산량이 너무 많고, principal curve를 사용하는 방법은 비선형 함수를 선형으로 연결한다는 단점을 지니고 있다.

FLAN(Functional-Link-Associative Neural Network)은 공정 변수들의 비선형적 관계를 고려하여 입력을 확장시키므로써 비선형성을 효율적으로 학습시킬 수 있지만, 모든 입력값을 하나의 함수(제곱 또는 sine이나 cosine)로 확장시킨다는 단점이 있다. 하나의 예로 다음과 같은 관계를 갖는 3개의 입력 x_1, x_2, x_3 을 생각해보자.

$$x_3 = k \cdot x_1^2 \cdot x_2^2 \tag{5}$$

k: 상수

위와 같은 입력에 대해서 기존의 FLAN을 사용하면 모든 입력에 대해서 제곱 또는 세제곱을 취한 추가적인 입력을 주게 된다. 이 경우, x_3 의 불필요한 입력 확장으로 인해 계산량이 많아질 뿐만 아니라 x_1 이나 x_2 도 부정확하게 입력이 확장되기 때문에 비효율적인 학습이 이루어지게 된다. 위와 같이 입력변수들간의 관계를 알고 있는 경우는, 입력을 그에 맞게 확장시키므로써 불필요한 계산을 줄이고 학습효율을 높일 수 있다. 본 연구에서는 입력변수들을 일괄적으로 확장시켜 학습시키는 기존의 방법 대신 변수간의 관계에 맞춰 확장시켜 학습시키는 방법을 사용하여 보다 효율적인 학습을 수행하였다.

IV. 사례연구

1. 보일러 급수부 이상 감지

다음 그림은 본 연구에서 제안한 방법을 Visual C++를 이용하여 코딩한 off-line 모듈과 이를 이용하여 보일러 급수부의 데이터들(FC2002, FC2002M, FC2002S, LC2002, LC2002M, LI2002A)을 학습시킨 결과이다.

앞의 보일러 급수부 데이터들을 ANN과 FLAN, modified FLAN을 가지고 학습횟수를 20000번으로 고정시켜놓고, 학습시킨 결과 ANN의 경우, SSE (Squared Sum Error)가 0.22, FLAN이 0.11, modified FLAN이 0.13이 나왔다. FLAN의 경우는 sine, cosine함수를 이용하여 입력을 확장시켰으며, modified FLAN의 경






그림 9. 개선된 함수 연결 연상 신경망을 이용한 보일러 급수부 데이터의 예측.
Fig 9. Prediction of Boiler water supply part using modified FLAN.

우선 FC2002와 FC2002M은 sine, cosine으로, FC2002S와 LC2002M, LC2002, LI2002A는 제곱을취해 입력을 확장시켜서 학습시켰다. 입력 변수간의 관계는 기본적으로 두 변수간의 상관 관계를 알고 있는 경우(예 : $x \propto y^2$) 그러한 관계로 확장을 시키고, 변수간의 상관 관계를 모르는 경우는 실제 공정 데이터를 가장 잘 표현하는 확장을 통하여 계산한다. 신경망 구조가 다르기 때문에 초기 학습 조건(weight)이 동일하지는 못했지만, FLAN과 modified FLAN의 수렴성이 ANN보다 더 우수함을 알 수 있다. FLAN의 경우는 6개의 입력을 sine, cosine으로 확장했기 때문에, 입력이 18개로 확장이 되지만, modified FLAN의 경우는 14개로 확장이 되므로 같은 횟수의 계산을 하더라도 modified FLAN의 경우가 계산시간이 더 적게 들었다. 실제로 변수들간의 상관관계를 알고 있는 경우, 본 연구에서 제안한 modified FLAN을 적용하면, 학습시간과 오차를 크게 줄일 수 있을 것이다. 또한 변수들간의 상관관계를 모르더라도, 각 변수들의 입력확장을 조절함으로써 입력 전체를 일괄적으로 확장하는 것보다 더 효율적인 학습을 수행할 수 있다.

다음 그림 10은 보일러 급수부에서 LCM(액위 제어기 출력)이 50시간 이후부터 제어기 고장으로 인해 정상값보다 높게 출력되는 경우를 가정하여 이상감지를 수행한 것이다. 액위제어기 출력값이 정상값보다 높게 설정되었지만



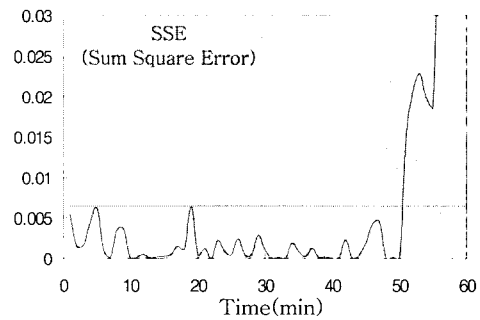
(a) LCM(액위 제어기 출력)의 입력 데이터와 예측 데이터 비교




(b) 보일러 급수부의 입력 데이터와 예측 데이터 비교
그림 10. 액위 제어기 이상 발생시 입력 데이터와 예측 데이터 비교.

Fig 10. Comparison between predicted data and input data at the time of LC fault.

신경망은 학습했던 정상상태의 값을 추정해내므로 위 그림과 같이 측정오차가 생기게 된다. 이와 같은 측정오차를 감지해냄으로써 실제 공정의 이상유무를 판단하게 된다. 다음은 실제 이상을 감지하기 위한 감시 차트(monitors chart)이다.



(a) LCM(액위 제어기 출력)의 공정 감시도



(b) FCS(유량 제어기 설정치)의 공정 감시도

그림 11. 공정 감시도.
Fig 11. Process monitoring chart.

위의 감시 차트를 보면 실제 이상을 가정한 액위제어기 설정값의 경우, 이상이 발생한 직후(50분) 오차감

지한계를 넘어서므로써 이상이 발생했음을 알 수 있다. 또 액위제어기 설정값의 직접적인 영향을 받는 유량제어기 설정값의 경우 57분 이후에 이상이 발생했음을 알 수 있다. 위 결과를 종합해볼 때, LCM의 이상으로 인해 FCS에 이상이 전파됐음을 알 수 있다.

2. Tennessee eastman 공정 이상 감시

다음은 Downs와 Vogel(1995)이 Eastman사의 Tennessee Eastman공정을 모사한 공정을 가지고 사례연구를 수행한 것이다. TE공정은 41개의 측정변수와 12개의 조작변수를 가지고 있는 비교적 복잡한 공정으로 A,C,D,E의 반응물이 들어가서 G와 H가 생산되는 공정으로 공정제어와 최적화, 이상진단에 널리 사용되는 공정이다. 본 연구에서는 G와 H의 비를 5:5에서 4:6으로 바꿀 때, 촉매의 비활성화가 일어난 경우에 대하여 이상감지를 수행하였다.

다음 그림 13은 촉매의 비활성화가 일어난 경우에 대해 실제데이터와 신경망을 통해 유추한 데이터를 plot한 것이다.




그림 12. Tennessee eastman 공정도.
Fig 12. Tennessee eastman process.






그림 13. 촉매 비활성화 발생시 입력 데이터와 예측 데이터의 비교.
Fig 13. Comparison between predicted data and input data at the time of catalyst deactivation.

위 그림에서 촉매 비활성화 발생 후 대략 50분만에



(a) 함수연결 연상 신경망을 이용한 공정 감시도



(b) 개선된 함수 연결 연상 신경망을 이용한 공정 감시도

그림 14. 촉매 비활성화 발생시 tennessee eastman 공정의 공정 감시도.

Fig 14. Tennessee eastman process monitoring chart using modified FLAN, at the time of catalyst deactivation.

공정에 이상이 발생했음을 감지할 수 있다.

다음 그림 14는 위와 같이 촉매 비활성화가 일어난 경우의 공정 감시 차트이다.

위 감시 차트는 정상상태를 학습시킨 120분까지의 데이터에 촉매 비활성화가 일어난 120~240분까지의 이상 데이터에 대한 SPE(Squared Prediction Error : 각 공정 변수들의 Sum Square Error의 합)를 plot한 것이다. 위 차트에서 알 수 있듯이 기존 FLAN을 사용한 경우에는 정상상태의 데이터 중에도 110분에 오차 감지한계를 넘어서는 것을 볼 수 있다. 또한 220분 정도 즉, 이상이 발생한 후 약 100분 뒤에 이상을 감지하는 것을 알 수 있다. 그러나 본 연구에서 제안한 개별확장 FLAN을 사용한 결과, 50분만에 공정에 이상이 발생했음을 알 수 있다.

V. 결론

본 연구에서는 실시간 적용이 가능하도록 개선된 스케일 스페이스 필터링과 입력변수의 개별확장을 통해 학습효율을 높인 FLAN을 이용한 공정감시 모델을 제시하였다. 스케일 스페이스 필터링의 경우, 실시간 적용의 가장 큰 걸림돌이었던 방대한 계산량을 일정하게 고정시켜 성능 저하 없이 실시간 적용이 가능하도록 하였으며, FLAN의 경우는 일괄적인 입력 확장이 아니라 입력변수별로 적절한 함수를 통해 입력을 확장하도록 하여 계산시간과 학습효율을 크게 높일 수 있었다.


참고문헌

- [1] J., Babaud A. P. Witkin, M. Baudin, and R. O. Duda, "Uniqueness of the gaussian kernel for scale-space filtering", *IEEE Trans. Pattern Analysis Machine Intel.* vol. 8, pp. 26-33, 1986.
- [2] D. Dong, and T. J. McAvoy, "Nonlinear principal component analysis-Based on principal curves and neural networks", *Computers chem. Engng.*, vol. 20, no. 1, pp. 65-78, 1996.
- [3] Kramer, M. A., "Nonlinear principal component analysis using autoassociative neural networks", *AICHE Journal*, vol. 37, no. 2, pp. 233-243, 1991.
- [4] T., Lindeberg, "Scale-space for discrete signals", *IEEE Trans. Pattern Analysis Machine Intel*, vol. 12, no. 3, pp. 234-254, 1990.
- [5] V. N. Reddy and M. L. Mavrovouniotis, "An input-training neural network approach for gross error detection and sensor replacement", *Trans IchemE.*, 76(A), pp. 478-489, 1998.
- [6] 모경주, "클러스터링 기법과 함수연결연상 신경망을 이용한 실시간 화학공정 감시에 관한 연구", 박사학위논문, 서울대학교 화학공학과, 1998.
- [7] 최용진, "실시간 공정데이터의 정성적 해석을 위한 Scale-space 필터링 기법의 응용과 구현에 관한 연구", 박사학위논문, 서울대학교 화학공학과, 1995.



최 중 환

1976년 2월 9일생. 1998년 서울대학교 화학공학과 (공학사). 2000년 서울대학교 화학공학과 (공학석사). 2000년~현재 SK Chemicals 연구원. 관심분야는 공정 모니터링, 공정모사 및 제어.



김 윤 식

1972년 2월 15일생. 1995년 서울대학교 화학공학과(공학사). 1997년 서울대학교 화학공학과(공학석사). 1997년~현재 서울대학교 대학원 화학공학과 박사과정 재학중. 관심분야는 공정제어, 공정 모니터링.



장 태 석

1969년 10월 9일생. 1994년 서울대학교 화학공학과(공학석사). 1996년 서울대학교 화학공학과(공학석사). 1996년~현재 서울대학교 대학원 화학공학과 박사과정 재학중. 관심분야는 공정 최적화, 공정 모니터링.



윤 인 섭

1949년 6월 4일생. 1971년 서울대학교 화학공학과(공학석사). 1982년 MIT 화학공학과(공학박사). 1983년~현재 서울대학교 응용화학부 교수. 관심분야는 공정 설계 및 제어, 공정 최적화, 이상진단.