

인공신경망을 이용한 화학공정 제어

김석준, 박선원

한국과학기술원

1. 서 론

화학공정은 혼합, 반응, 분리, 전달현상 등을 포함하는 단위공정들의 대단위 복합체이다. 그러므로 화학공정은 정도의 차이는 있지만 강한 비선형성, 복잡성과 불확실성을 지니고 있다. 이러한 성질들은 화학공정을 이해하고 또한 제어하는데 많은 어려움을 준다. 그러나 최근 화학공정 제어분야의 연구가 급속도로 활성화되고 발전하고 있는데, 여기에는 마이크로 프로세서의 급속한 발전, 비선형 제어기법의 진보 등의 몇 가지 요인이 중요한 영향을 주고 있다.

대부분의 비선형 제어이론들은 정밀한 비선형 공정모델을 이용하지만, 실제적으로 정밀한 비선형 공정모델을 얻기란 매우 힘들고, 개발된 모델도 시간이 지남에 따라서 정밀도를 잃게 된다. 이러한 원인은 화학공정의 기초현상들을 완전히 파악하지 못하고 있고, 실험을 하는데 많은 시간과 비용을 들여야 하기 때문이다. 또한 모델 개발에 사용된 변수들에 대하여 실시간 측정장치를 얻기 힘든 경우도 많이 있다[Anderson et al. 1991].

인간의 신경체계를 모방한 인공신경망은 위에서 언급한 난점을 풀기에 적합한 많은 특성을 지니고 있다. 이들은 뉴런이라고 불리우는 많고 간단한 계산요소들로 이루어져 있다. 인공신경망은 주로 패턴분류기(pattern classifier)와 함수 추정기(function approximator)로 사용되는데 이들의 기능은 학습을 하는 동안 결합가중치(connection weight)들을 변화시키면서 결정된다. 또한 이들은 주어진 대상계를 표현하는데 기본적으로 대상계의 입출력 정보만을 필요로 한다. 그래서 최근에 인공신경망이 제어분야에 도입된 이후에 [IEEE Control Systems, 1988, 1989, 1990] 많은 활발한 연구가 수행되고 있으며, 화학공학에서도 여러 분야

에 걸쳐 인공신경망의 응용이 연구되고 있다.

본 논문에서는 화학공정 제어분야에서 수행된 인공신경망을 이용한 연구에 대하여 정리하였다. 본 논문의 구성은 먼저 인공신경망의 일반적인 특성에 대하여 개괄적으로 알아보았고, 인공신경망을 모델링과 제어에 사용한 연구들을 체계적으로 정리하였다. 또한 마지막으로 화학공정에 적용된 사례를 소개하고, 화학공정에 인공신경망을 사용하는 경우에 대하여 문제점과 특성을 논의하였다.

2. 인공신경망

2.1 역 사

최근들어 인간의 뇌의 구조에 대한 연구가 활발히 진행되어 왔다. 이러한 연구들은 생물학적인 연구결과에 근거하여 패턴인식과 신속한 정보처리 등을 위하여 새로운 컴퓨터 모델들을 개발하게 되었다. 1940년대에 인공신경망 분야의 선구자인 McCulloch와 Pitts(1943)는 뉴런모델에 근거한 간단한 계산요소들을 연결하는 경우에 대하여 수치적인 가능성과 기능에 대하여 연구하였다. Hebb(1949)와 같은 다른 연구자들은 신경체계의 적응성에 대하여 관심을 갖고 연구하였고, 최초로 인공신경망의 학습 알고리즘을 제안하였다. Rosenblatt (1958)은 많은 관심을 끌게 된 퍼셉트론(Perceptron)을 고안하였다. Minsky와 Papert (1969)는 퍼셉트론에 대하여 심도 깊은 연구를 수행하였고, 기존에 개발된 여러 가지 인공신경망 모델의 한계성을 지적하였다. 그들은 단층(single-layer) 신경망이 exclusive-or gate와 같은 간단한 문제도 풀 수 없음을 수학적으로 증명하였다. Grossberg(1976)는 생물학적이고 심리학적인 연구결과에 근거하여 몇가지 뛰어난 특성을 갖는 비선형 동적구조를 갖

는 모델을 제안하였다. Hopfield (1982)는 특별한 최적화와 같은 기술적인 문제를 풀기 위하여 비선형 동적구조를 적용하였다. 1986년은 인공지능망 연구의 큰 전환점이 되는 때로 Rumelhart 등의 연구자들이 parallel distributed processing(PDP) 그룹에서 일련의 연구결과와 알고리즘을 발표하였다. 이들은 다층(multi-layer) 신경망을 학습하기 위한 역전파(backpropagation) 학습 알고리즘을 발표하였다. 이 연구는 인공지능망 연구분야에 강한 영향을 주었고 뒤따르는 많은 연구의 촉매작용을 하였다.

2.2 구조 및 출력

인공신경망에는 multi-layer feedforward neural network, Hopfield network, bidirectional associative memory, adaptive resonance theory network, self-organizing network, radial basis function network 등의 다양한 모델이 있다.

그림 1은 모델링과 제어분야에 가장 많이 사용되는 다층신경망(multi-layer feedforward neural network)을 보여준다. 다층신경망은 여러 개의 층으로 이루어져 있으며, 각각의 층은 많은 수의 뉴런을 포함하고 있다. 뉴런들은 가중치로 연결되어 있고, 다층신경망의 경우에는 같은 층의 뉴런 사이에는 연결이 없으며 다른 층에 속해 있는 뉴런 사이

에만 연결이 되어 있다. 각각의 뉴런은 입력을 받아서 이들을 더하는 합산기(summation)와 합산기의 출력을 변환하는 활성화함수(activation function)로 이루어져 있다. sigmoid 활성화함수를 갖는 뉴런의 기능을 수식으로 표현할 때 l 번째 층의 i 번째 뉴런의 출력은 다음과 같다:

$$Z_i^l = \sum_{j=1}^{N_j} W_{ji}^{l-1} O_j^{l-1} \quad (1)$$

$$O_i^l = \sigma(Z_i^l) = \frac{1}{1 + \exp(-Z_i^l)} \quad (2)$$

여기서 $\sigma(\cdot)$ 은 sigmoid 활성화함수를, W_{ji}^{l-1} 은 $l-1$ 번째 층의 j 번째 뉴런과 l 번째 층의 i 번째 뉴런을 연결하는 가중치이다.

최근 radial basis function(RBF) network이 많은 연구에서 사용되고 있다. RBF network은 은닉층에서 radial basis function을 활성화함수로 사용하며, 은닉층에서 출력층으로의 연결이 선형이다. RBF network의 중요한 특성은 정보의 지역화(locality)로써 각각의 뉴런의 출력이 작은 영역에 한정된다. 또한 RBF network은 best approximation property를 갖는 것이 증명되었다[Poggio와 Girosi, 1989].

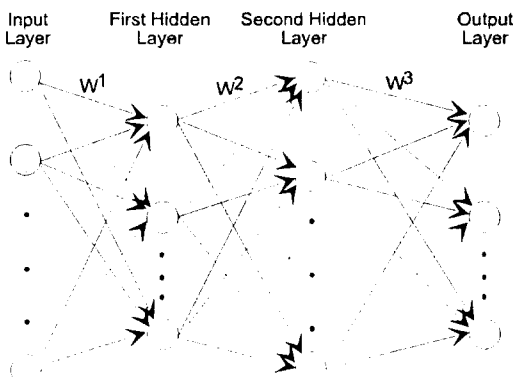
2.3 특 성

인공신경망이 인간의 신경체계를 단순화시킨 모델이지만, 인간의 신경체계와 비슷한 많은 특성을 갖고 있다. 이 특성들은 다른 컴퓨팅 기술과는 다른 많은 장점을 갖고 있다. 여러 가지 인공신경망의 특성 중에서 비선형 근사, 학습능력과 병렬 분산 구조[Lippman, 1989; Hunt 등, 1992] 등이 모델링과 제어에 매우 중요하고 유용한 것들이다.


비선형 근사(nonlinear approximation)

이 특성은 인공신경망을 이용하여 비선형 문제를 푸는데 있어서 가장 중요한 것이다. 먼저 이론적인 관점에서 Kolmogorov의 연구(1957)는 정밀한 비선형 근사문제에 대한 가능성을 시사하고 있다. 그의 이론은 N 개의 변수로 이루어진 연속함수를 표현하기 위해서는 첫 번째 층에 $N(2N+1)$ 개의 구성단위와 두 번째 층에 $(2N+1)$ 개의 구성단위가 필요하다는 것이다. 그러나 이 이론은 학습방법이나 내부함수의 선택방법에 대해서는 언급하지 않았다. 최근 연구결과에 따르면[Cybenko, 1988, 1989; Hornik 등, 1989], 뉴런이 sigmoid 활성화함수(activation function)를 갖고 은닉층(hidden layer)이 무한히 많은 뉴런을 가질 수 있는 경우에 한 개의 은닉층을 갖는 다층신경망은 모든 비선형 함수를 근사할 수 있다는 것이 증명되었다.


학습능력(learning capability)



Artificial Neural Network



Artificial Neuron



Activation Function

그림 1. 다층신경망의 구조.

인공신경망은 대상문제에 따라서 자신의 출력을 변화시킬 수 있는 학습능력을 갖고 있다. 초기 인공신경망의 가중치(weight)는 무작위로 결정된 작은 값을 가지므로, 출력이 거의 없다. 그러나 가중치 값은 미리 정해진 학습 알고리즘에 의해서 적절한 값으로 조절되어진다. 결과적으로 인공신경망은 요구되어지는 출력을 발생하게 된다.

병렬 분산 구조(parallel distributed structure)

인공신경망은 뉴런과 가중치가 병렬적으로 연결된 구조를 갖고 있기 때문에 구조적으로 많은 장점을 지니고 있다: 강건성, data fusion, 다변수계의 처리, 하드웨어 구현 등. 인공신경망은 노이즈 등으로 인한 입력변수의 작은 변화에 대하여 출력에 큰 변화가 없으며, 이진변수와 연속변수를 동시에 처리할 수 있다. 또한, 여러 개의 입력변수를 처리할 수 있고, 하드웨어에 구현할 경우에 고속계산 처리에 강하다.

2.4 학습법

학습법은 먼저 지도(supervised) 학습과 자율(unsupervised) 학습으로 나눌 수 있다. 지도학습에서는 현재 인공신경망의 출력과 요구되는 출력과의 차이를 이용하여 인공신경망을 학습시키지만 자율학습은 요구되는 출력을 사용하지 않는다. 학습방법에 대한 또다른 분류법은 배치학습(batch learning)과 패턴학습(pattern learning)이다. 배치학습은 전체 패턴집합에 대한 gradient를 구하여 이를 학습에 이용하는 것이고, 패턴학습은 개개의 패턴에 대한 gradient를 이용하는 방법이다.

모델링과 제어에 있어서 많이 사용되는 인공신경망과 학습법은 다층 신경망과 역전과 학습법이다. 여기서는 다층 신경망을 이용하는 경우에 패턴학습으로 이루어지는 역전과 학습법만을 다루겠다. 또한 설명의 편의를 위하여 단일 입력 출력 시스템의 경우만을 다루겠다.

먼저 학습 목적함수(E)는 다음과 같이 현재 인공신경망의 출력층에서 뉴런의 출력(y)과 요구되는 출력(T)의 차이의 제곱으로 설정된다:

$$E = (T - y)^2 \quad (3)$$

앞에서 언급한 바와 같이 학습은 이 학습 목적함수를 최소화하기 위하여 가중치를 변화시키는 것이다. 학습은 먼저 인공신경망이 입력을 받는 것으로부터 시작된다. 입력을 받은 후 인공신경망은 이 입력에 대하여 현재 가중치를 이용하여 현재 출력을 계산한다. 그리고 (3)에 의해서 학습 목적함수값을 계산한다. 가중치의 변화는 다음의 식에 의해서 이루어진다.

$$W_{ij}^{1,(k+1)} = W_{ij}^{1,(k)} + \Delta W_{ij}^{1,(k)} \quad (4)$$

$$\Delta W_{ij}^{1,(k)} = -\eta \frac{\partial E}{\partial W_{ij}^1} \quad (5)$$

여기서 η 는 학습속도이다.

3. 인공신경망을 이용한 모델링

인공신경망은 앞에서 언급한 바와 같이 비선형 근사 능력이 탁월하여 근본적으로 비선형성이 강한 화학공정을 모델링하는데 매우 적합하다. 인공신경망을 이용한 화학공정의 모델링은 크게 학습 데이터의 선처리와 인공신경망의 학습으로 나뉘어진다[Piovosso와 Owens, 1991].

3.1 데이터의 선처리

인공신경망의 대표적인 응용분야인 패턴인식과 비교하여, 화학공정의 모델링의 큰 특징은 첫 번째로 화학공정 변수들이 일반적으로 연속변수이므로 연속적인 값을 갖는 데이터를 처리해야하는 것이고, 두 번째로 화학공정에서 얻어지는 데이터들은 측정기의 부정확성이나 노이즈 등으로 인하여 불완전하므로 이들을 적절히 처리해야 하는 것이다. 그러므로, 인공신경망의 학습 전에 공정 데이터를 적절히 처리하는 것이 매우 중요하다.

공정 데이터의 선처리는 먼저 여러 가지 변수값들의 크기 조절(scaling)이다. 화학공정에는 수많은 종류의 센서들이 있고, 이들로부터의 데이터도 여러 가지이다. 예를 들어 어떤 화학공정의 정상조업에서 온도는 100~200℃의 범위로 변화하는 반면, 반응물의 유량은 6000~8000kg/hour의 범위로 변화하는 경우가 생길 수 있다. 일반적인 최적화 문제와 마찬가지로 인공신경망 학습에서도 이들 각 변수들을 적절한 크기로 조절해 주어야 학습이 올바르게 수행된다. 일반적으로 사용되는 방법은 전체 변수값을 0.1~0.9의 범위가 되도록 크기를 조절해 주는 것이다. 만일 올바르게 변수값의 크기를 조절해 주지 못하면 현재의 현상 또는 패턴에 주요한 원인을 제공하는 입력정보의 역할이 제대로 반영되지 못하고, 이는 마치 인체에서 감각기관의 감도가 제 역할을 하지 못하는 것과 같아진다.

공정 데이터 선처리의 다음 단계는 데이터 중에서 특이한 데이터(outlier)를 제거하는 것이다. 이러한 특이한 데이터는 많은 경우에 노이즈나 장치고장 등으로 인한 잘못된 정보인 경우가 많지만, 경우에 따라서는 공정의 특별한 특성을 나타내기도 한다. 이 두 경우를 구별할 수 있는 방법은 대상공정을 가장 잘 이해하는 전문가가 판별하는 수 밖에는 없다. 잘못된 데이터를 제거하는 첫 번째 방법은 Clustering 방법이다. Clustering 방법은 비슷한 입력 데이터를 cluster로 모으는 방법이다. 매우 적은 입력 데이터만을 포함하는 cluster는 잘못된 데이터로 처리한다. 두 번째 방법은 chemo-metrics를 이용한 방법이다[Piovosso와 Owens,

1991]. 세 번째 방법은 인공신경망을 이용하는 방법이다. 원래의 공정 데이터로 인공신경망을 학습한 후 인공신경망의 출력과 상이한 공정 데이터를 제거하는 방법이다. 이렇게 비정상적인 데이터를 제거한 후에 다시 한 번 변수값의 크기를 조절해야 한다.

적절하게 변수값의 크기를 조절하고, 비정상적인 데이터를 제거한 후에 얻어진 전체 데이터는 학습 데이터와 검사 데이터로 나뉜다. 학습 데이터는 인공신경망의 가중치를 변화시키기 위하여 학습하는데 사용되고, 검사 데이터는 학습 도중에 과학습(over-training)이 되는 것을 알아보기 위하여 사용된다.

3.2 모델링에서 인공신경망의 학습

준비된 학습 데이터를 이용하여 인공신경망을 학습하는데 중요한 과정은 인공신경망의 구조를 결정하는 것이다. 기본적으로 인공신경망의 종류를 선택하는 것 이외에 입력정보의 선택과 은닉층의 뉴런의 개수가 중요하다. 입력정보의 선택은 공정에 대한 이해가 필요한 과정으로써 먼저 입력으로 사용할 공정변수를 선택하고, 한 개의 변수에 대해서도 공정의 시간지연을 고려하기 위하여 몇 개의 과거정보를 사용할지를 결정해야 한다.

모델링에서 일반적인 학습과정은 다음과 같다.

1. 은닉층의 뉴런의 개수를 결정하고 인공신경망의 가중치를 초기화한다.
2. 학습 데이터를 이용하여 인공신경망을 학습한다. 학습을 하는 도중에 검사 데이터에 대한 목적함수값도 동시에 계산한다.
3. 검사데이터에 대한 목적함수가 최소가 되도록 하는 최적의 가중치를 구한다. 이는 학습 데이터를 학습한 인공신경망이 과학습되어(over-training) 일반화(generalization)에 대한 성능을 잃는 것을 방지하기 위한 것이다.
4. 은닉층의 뉴런의 개수를 늘리고, 학습을 반복한다.
5. 여러 가지에 은닉층의 뉴런의 개수를 대하여 가장 작은 목적함수값을 산출하는 경우를 결정한다.

인공신경망을 이용한 모델링 기술의 또다른 분야는 인공신경망만을 이용하는 것이 아니라 기존에 개발된 모델링 기술과 복합체(hybrid)로 사용하는 것이다. Narendra와 Parthasarathy (1990)는 기본적으로 선형식과 결합한 여러 가지 형태의 복합체 모델을 제안하고 이에 대한 모사연구를 수행하였다. 화학공정 분야에서는 그림 2와 같이 공정의 수학적으로 유도된 원론 모델식(the first principal model)과 인공신경망을 병합한 기법을 많이 사용한다[Psychogios와 Ungar, 1992; Su 등, 1992]. 인공신경망은 에너지 수지식, 물질 수지식과 반응식과 같은 원론 모델식과 실제 공정 데이터와의 차이를 보상에 준다. Su와 McAvoy(1993)는

Hammerstein 모델에 인공신경망을 사용하였는데, 여기서 그들은 비선형 정상상태를 인공신경망으로 표현하고, 선형 동특성 모델식과 병합하여 전체적으로 복합체 모델을 구성하였다.




그림 2. First principal model과 인공신경망의 복합모델.

4. 인공신경망을 이용한 제어

표 1에는 화학공정 제어분야에서 인공신경망을 이용한 제어구조가 정리되어 있다. 직접제어(direct control)에서는 인공신경망을 제어기만으로 이용하지만, 간접제어(indirect control)에서는 인공신경망으로 구성된 공정모델을 먼저 만들고 이 공정모델을 제어에 이용하는 것이다. Gain scheduling control은 여러 가지 경우의 예제로 학습한 인공신경망을 이용하여 제어기의 조절변수(tuning parameter)를 조절기로 사용하는 것이다. 본 장에서는 이중에서 대표적인 일곱 가지의 경우에 대하여 정리해보았다.


4.1 Generalized learning architecture (GLA)와 Specialized learning architecture (SLA)

GLA와 SLA는 인공신경망을 이용한 가장 간단한 제어구조로서 그림 3과 같은 구조를 이루고 있다[Psaltis 등, 1988]. GLA에서는 인공신경망을 이용하여 역공정 모델(inverse process model)을 만든다. 즉 공정출력을 입력으로 사용하여 그때 주어진 제어입력을 출력하도록 학습된다. GLA의 특성에 대해서는 많은 연구가 수행되었는데[Jordan과 Rumelhart, 1991] 여러 가지 단점이 지적되었다. 먼저 GLA는 반대모델에 대한 학습이 이루어지더라도, 이 반대모델이 제어기로 적합하지 않을 수 있고, 학습이 효과적이지 않으며, 공정 입출력이 일대일 관계에 있는 경우에만 적용된다.


SLA도 마찬가지로 Psaltis 등에 의해서 제안되었는데 이는 GLA의 단점을 극복하기 위해서 제안되었다. SLA는 주어진 설정치에 대해서 현재 설정치와 공정출력의 차이를 최소화하도록 학습이 이루어진다. 이때 공정출력의 차이를 공정입력의 차이로 변환하기 위하여 공정의 Jacobian이 필요하게 된다. Psaltis 등은 Jacobian을 구하기 위하여 이의 근사식을 이용하였다. SLA의 단점은 학습이 충분히 이루어지

표 1. 인공신경망을 이용한 제어체계.

	인공신경망의 사용	종 류
직접 제어	제어기	<ul style="list-style-type: none"> • Generalized learning architecture • Specialized learning architecture • Feedback error learning • Disturbance error learning • Neural linearizing control scheme
간접제어	제어기 + 공정모델	<ul style="list-style-type: none"> • Neural internal model control • Neural model reference adaptive control
	공정모델	<ul style="list-style-type: none"> • Neural internal model control • Neural Model predictive control
	측정기	<ul style="list-style-type: none"> • Neural inference control
	변수 조절기	<ul style="list-style-type: none"> • Neural self-tuning control
Gain scheduling	Scheduler	<ul style="list-style-type: none"> • Neural gain scheduling control



(a) GLA의 구조



(b) SLA의 구조

그림 3. GLA와 SLA의 구조.

지 않은 상태에서는 제어가 제대로 이루어지지 않으며, 노이즈나 시간지연 등의 원인에 의해서 Jacobian을 제대로 구하지 못할 경우에 사용할 수 없다는 것이다.

4.2 Feedback error learning (FEB)과 Disturbance error learning (DEL)

Kawato(1988)에 의해서 제안된 FEB의 제어구조도는

그림 4와 같다. feedback loop안에 비례제어기가 위치하고, 인공신경망의 역할은 설정치를 추적하는 feedforward action을 출력하므로, 전체 제어신호는 이들 출력의 합이 된다. 학습신호는 비례제어기의 출력이다. 이 구조의 장점은 다음과 같다: 인공신경망을 학습하기 위한 요구되는 출력이 필요하지 않다; 제어와 학습이 동시에 수행된다; 학습을 위하여 SLA와 같이 제어대상을 역으로 거치는 과정이 필요하지 않다. 그러나 이 구조는 화학공정에 적용하기에는 외란 제거 제어문제를 다루지 못하고 학습이 불안정화할 수 있는 단점을 지니고 있다.




그림 4. FEB의 구조.




그림 5. DEL을 이용한 feedforward controller.

Lee와 Park(1992)은 측정외란을 제어하기 위하여 개념적으로 FEB와 유사한 feedforward controller를 고안하였고, 이의 학습을 위한 DEL을 제안하였다. 그림 5는 그들의 제어구조를 보여주는데 feedback loop 안에는 DMC(dynamic matrix control)가 위치하고 있다. DMC 출력(Δu_c)은 다음과 같이 모델에 의한 부분(Δu_m)과 모델오차에 의한 부분(Δu_d)으로 나뉘어진다.

$$\Delta u_c = \Delta u_m + \Delta u_d \quad (6)$$

이 중에서 Δu_d 를 이용하여 인공신경망을 학습한다.

4.3 Neural linearizing control scheme (NLCS)

그림 6은 NLCS의 제어구조를 보여준다[Kim 등, 1996]. 이는 안정한 선형제어기에 의해서 제어되는 공정에 적용이 가능하며, 인공신경망은 선형제어기의 출력과 공정출력의 비선형적인 관계를 선형화하도록 학습되어진다. 학습신호는 공정출력과 미리 정의된 선형 참조 모델의 차이이다. 선형 참조 모델은 특별한 실험없이 과거 선형제어기의 조업정보를 분석하여 구성된다. 인공신경망의 학습이 충분히 이루어지면 인공신경망과 공정을 합한 전체 동특성은 선형이 되어 선형 참조 모델과 같아지고, 제어성능이 향상된다.




그림 6. NLCS의 구조.

인공신경망이 선형제어기와 병렬로 연결되므로 제어성능이 학습 도중에도 선형제어기의 제어성능 이상으로 유지되고, 또한 인공신경망이 선형제어기와 공정 사이에 위치하므로 외란제거 제어문제도 함께 다룰 수 있다.

4.4 Neural Internal Model control (NIMC)

IMC의 제어구조도는 그림 7과 같으며 선형공정[Garcia와 Morari, 1982]과 비선형공정[Economou 등, 1986]에 적용할 수 있다. 이는 다음과 같은 대표적인 세 가지 성질을 갖고 있다: stable control, perfect control, offset-free control. Bhat와 McAvoy(1990)는 인공신경망을 화학공정의 모델링과 제어분야에 도입하면서 인공신경망을 이용한 IMC 구조에 대한 전망을 논하였고, 이후에 많은 시도가 이루어진 제어구조이다.




그림 7. NIMC의 구조.

NIMC를 구현하기 위해서는 먼저 인공신경망을 이용한 공정모델을 구성해야 한다. 그러나 인공신경망으로 구성된 공정모델이 비선형 모델이므로, 이를 사용하는 제어기는 선형의 경우와는 달리 비선형 알고리즘을 필요로 한다. NIMC의 제어기는 크게 두 가지로 나뉘어진다. 초기에 시도된 연구들은 GLA와 같이 인공신경망으로 역공정 모델을 구성하여 이를 IMC 제어구조에 사용하는 것이었다. 그러나 모든 경우에 역공정 모델을 구성하는 것이 가능하지 않으며, 정확한 정상상태 모델링이 이루어지지 않으면 정상상태에서 offset을 남길 수 있다[Nahas와 Seborg, 1992]. 다음으로 제어출력을 계산하는데 최적화 알고리즘을 사용하는 것이 있다[Nahas와 Seborg, 1992; Pshichogios와 Ungar, 1992; Ydstie, 1990]. 제어출력은 다음의 식을 만족시키도록 계산된다.

$$v(k) - y_m(k + \theta + 1) = G [u(k)] = 0 \quad (7)$$

Nahas와 Seborg는 Newton의 방법을 써서 다음과 같이 제어출력을 계산하였다.

$$u^i(k) = u^{i-1}(k) - \frac{G [u^{i-1}(k)]}{\frac{\partial}{\partial u(k)} G [u^{i-1}(k)]} \quad (8)$$

4.5 Neural Model predictive control (NMPC)

MPC는 최근 특히 화학공정에서 가장 각광을 받는 제어 기법이며 실제 적용도 많이 이루어져 있으며, 상용화된 제어 소프트웨어도 많이 사용되고 있다[Ricker, 1991]. MPC는 시간지연을 효과적으로 처리할 수 있고, 중앙집중식(centralized) 제어기이고, 제어출력과 공정출력에 대한 제약조건을 다룰 수 있는 특성이 화학공정에 적용하는데 큰 장점이 된다.

위와 같은 이유에서 NMPC는 NIMC와 마찬가지로 화학공정에서 많은 연구가 이루어져 왔다[Blum et al., 1994; Cooper et al., 1992; Eikens and Karim, 1994; Lee and Park, 1992; Montague et al., 1992; Pottmann and Seborg, 1992; Psychogios and Ungar, 1991; Saint-Donat et al., 1991; Song and Park, 1993; Ungar et al., 1989; Willis, 1991]. NMPC를 적용하는데 필요한 단계는 공정모델링, 목적함수 구성, 최적화, 미래 공정출력 예측 등

이 있다. 대부분의 경우에 NMPC는 Sistu와 Bequette (1991)의 방법을 사용하는데, 그 이유는 비선형인 인공신경망 공정모델을 다루기에 알고리즘이 간단하기 때문이다.

Song과 Park(1993)은 NMPC의 특성에 대하여 다음과 같이 기술하고 있다.

1. NMPC는 공정모델에 불확실성이 존재하고 제약조건이 있는 공정을 제어하기 위하여 비선형 최적화 기법과 인공신경망의 모델링 능력을 결합하여 사용한다.
2. 공정모델을 구성하기 위하여 open-loop에서 수행된 실험결과나 과거 조업정보를 이용하여 복잡한 공정특성을 학습한다.
3. 인공신경망의 구조를 적절히 결정함으로써 부족한 정보를 보상하고 모델링 능력을 향상할 수 있다.
4. NMPC는 거대한 행렬계산을 실행하지 않으므로, 실시간에서 MPC보다 적은 계산시간을 이용하여 미래 공정모델 예측을 수행할 수 있다.

NMPC의 제어법칙은 일종의 최적화 문제로서 다음과 같이 나타낼 수 있다:

$$\min J = \sum_{i=1}^{H_r} \gamma [r(k+i) - y_m(k+i)]^2 + \sum_{i=1}^{H_u} \lambda \Delta u(k+i-1)^2 \quad (9)$$

여기에 공정출력과 제어출력에 대한 제약조건들을 포함시킨다. 미래 공정출력 예측은 다음과 같은 인공신경망 공정모델에 현재 모델오차를 합한 것을 사용한다.

$$y_m(k+i) = y_N(k+i) + d(k) \quad (10)$$

공정의 시간지연과 느린 동특성을 보상하기 위하여 일반적으로 NMPC는 다단계 미래 공정출력 예측을 사용하는데, 미래 공정출력값을 현재에는 사용할 수 없으므로 인공신경망 공정모델의 출력값을 다시 입력값으로 사용하여 다단계 예측을 수행한다[Saint-Donat 등, 1991].

NMPC에 사용되는 최적화 방법은 Newton 방법이나 SQP 등이 많이 사용된다. 그리고 목적함수의 gradient를 구하는데 finite difference method를 주로 사용한다.

NIMC와 마찬가지로 NMPC도 인공신경망을 사용하여 공정모델을 구하는데 많은 이점을 갖게되지만, 제어기의 특성 측면에서 NMPC는 기본적으로 MPC가 갖는 장·단점을 모두 지니고 있다.

4.6 Neural inferencial control (NIC)

화학공정에는 측정할 수 없거나 제어기가 실시간으로 사용할 수 없는 농도, 점도, photodegradation, 촉매의 활성, 발효조에서 세포함량 등의 많은 변수가 있다. 이러한 경우에 실시간으로 측정가능한 변수로부터 필요한 변수를 추정

하여 사용하는 inferencial control이 많이 사용된다.

특히 인공신경망은 비선형 모델링에 장점이 있으므로 이 분야에 대한 연구가 매우 많이 이루어지고 있다. 변수값을 측정하기에 오랜 시간이 걸리지만 정밀한 값을 실험실에서 얻을 수 있는 경우에 실시간으로 측정가능한 변수값을 입력으로 사용하고 필요로 하는 변수값을 출력하도록 인공신경망을 학습한다.

inferencial control에 인공신경망을 사용하는 또다른 이유는 센서의 노이즈를 줄이기 위하여 사용하는 것이다. 센서에 노이즈가 심하거나 성능이 저하되는 경우에 센서값을 개선하도록 인공신경망을 사용할 수 있다[Kramer, 1992].

4.7. Neural gain scheduling control (NGSC)

이 방법은 간단한 선형 제어를 이용하여 비선형 공정을 제어하기 위한 제어구조 중에서 가장 오래된 제어기법이다. 그 이유는 복잡한 이론 없이 간단하고 성능이 입증된 선형 제어기의 튜닝 변수만을 변화시켜줌으로써 공정의 비선형성을 다룰 수 있으므로, 응용이 간편하고 성능이 강건하기 때문이다. GSC는 조업영역이 달라짐에 따라서 생기는 현상들을 보상하기 위하여 공정의 동특성과 연관이 있는 공정변수를 사용한다. 그림 8은 NGSC의 제어구조도를 보여준다. 여기에는 또한 적절한 튜닝 법칙이 필요하다.

이 분야의 선구적인 연구는 Guez 등(1988)에 의해서 이루어졌는데 이들을 Hopfield 신경망을 사용하여 공정변수를 추정하였다. 먼저 선형화한 공정모델을 결정하고, 인공신경망 추정기는 이 선형모델의 계수를 변화시켜주며, 이 모델에 적합한 제어기의 튜닝 변수를 조절한다. Scott과 Ray (1993)는 인공신경망으로 구성된 공정모델을 선형화한 후, 이를 PI 제어기의 수식과 비교하여 PI 제어기의 튜닝 변수를 결정하는 방법을 사용하였다. Willis와 Montague (1993)는 integral squared error와 decay ratio를 이용한 튜닝 법칙을 이용하여 PI 제어기의 튜닝 변수를 변화시키는 방법을 사용하였다. 이들은 인공신경망 공정모델과 PI 제어기를 가지고 실시간으로 모사를 수행하면서 최적의 튜닝 변수를 구하는 최적화 기법을 사용하였다.




그림 8. NMPC의 구조.




그림 9. NGSC의 구조.

5. 실공정 적용례

Kim 등(1992)은 두 개의 정유공정에 생산품의 휘발도를 예측하기 위하여 인공신경망을 적용하였다. 그들은 또한 인공신경망 공정모델과 선형 회귀 모델의 결과들을 비교하였다. 그들의 연구결과에 의하면 인공신경망 공정모델이 선형 회귀 모델보다 우수한 예측성능을 보였으며, 공정에 노이즈가 있는 경우에도 좋은 성능을 보여주었다.

Malik(1992)은 잔사유 수소처리 반응기(resid hydro-treating reactor)와 접촉 분해 공정(catalytic cracking process)의 증류탑에 인공신경망을 비롯한 여러 가지 모델링 기법을 적용하여 공정모델을 개발하였고, 이들의 효율성 및 성능을 비교하였다. 또한 이렇게 개발된 공정모델을 IMC와 DMC에 사용하였다. 반응기의 경우 인공신경망을 이용한 공정모델이 선형 ARMAX 모델보다 더 좋은 모델링 성능을 보여주었다. 증류탑의 경우에 학습 데이터를 많이 확보하지 못한 이유로 인공신경망을 이용하지 못하고 PLS (partial least squares) 기법만을 이용하였다.

Savkovic-Stevanovic (1992)는 butylacetate-butylalcohol-water 계에 대한 산업체 분리공정의 증류탑에 인공신경망을 이용한 공정모델을 구성하고, 이를 이용하여 공정의 최적조업 조건을 구하였다. 이들은 입력정보로 각 물질의 성분, 증류탑의 압력차, 내부 환류비와 외부 환류비를 사용하였고 은닉층에 2개의 뉴런을 사용하여, 생산품의 성분을 예측하였다.

Chessari 등(1994)은 heavy straight run naphtha를 이용한 접촉 개질 공정(catalytic reforming process)에 대하여 인공신경망 공정모델을 개발하였다. 이 공정은 여러 시간이 걸리는 상당히 느린 시상수를 갖고 있으며, 촉매가 지속적으로 비활성화되는 동특성을 지니고 있다. 이들은 변수 간의 연관성을 알아내기 위하여 인공신경망을 이용한 nonlinear principal component analysis를 수행하였으며, 세 개의 은닉층을 갖는 인공신경망을 이용하여 identity mapping[Kramer, 1991]을 수행하였다. 연구결과 구성된 공정모델을 DCS(distributed control system)에 실시간으로

로 작동하도록 설치하였다.

Cooper와 Woll(1994)은 injection molding process에서 압력센서값에 의한 생산품의 품질을 예측하기 위하여 인공신경망 모델을 사용하였다. 이들은 세 가지 실험을 수행하여 학습 데이터와 검사 데이터를 구하였다. 이들의 연구결과에 따르면 인공신경망 공정모델은 좋은 내삽성능 보여주었으며, 그들이 사용한 statistical process control보다 좋은 성능을 보였다.

Agamennoni 등(1994)은 프로판 반응기에서 melt flow index(MFI)를 예측하기 위하여 인공신경망 공정모델을 개발하였다. 이들은 서로 다른 두 개의 인공신경망 구조를 이용하였으며 개발된 공정모델이 MFI를 잘 예측한 결과를 보고하였다.

Willis 등(1991)은 인공신경망을 이용한 모델링과 제어에 관한 많은 연구를 수행하였다: mycelia 연속 발효조, 페니실린 회분식 발효조, 고순도 증류탑. 페니실린 공정에서 이산화탄소 발생량, 발효시간과 반응기에 공급되는 기질의 양을 사용하여 생물체의 농도를 추정하는데 인공신경망을 사용하였다. 또한 고순도 증류탑에서 생산물의 성분을 추정하는 인공신경망 공정모델을 구성하여 PI 제어기의 튜닝변수를 변화시키는 inferencial control을 연구하였다.

Kim 등(1996)은 Pilot-scale 증류탑에 DEL을 사용하여 인공신경망을 이용한 feedforward 제어기의 성능을 연구하였다. 증류탑의 측정되는 외란인 feed 유량의 변화에 대하여 탑상과 탑저 온도를 유지하는데 feedforward PI 제어기, feed forward DMC 제어기와 feed forward 인공신경망 제어기의 제어성능을 비교하였는데 feed forward 인공신경망 제어기가 가장 좋은 제어성능을 보여주었다.

Kim과 Park (1995)은 실험실 규모의 pH 공정에 대하여 NLCS를 적용하였다. 이 연구결과에 의하면 비선형성이 강한 pH 공정에서 실시간 학습을 통하여 pH에 대한 설정치 추적과 산성용액의 농도에 대한 외란제거 제어문제에서 NLCS가 좋은 제어성능을 보여주었다.

그밖에도 Rudd(1994)는 인공신경망 공정모델에 근거하는 제어구조를 사용하여 제지기계의 paper crush property와 porosity를 제어하였으며, Koivisto 등(1993)은 NIMC를 이용하여 실험실 규모의 가열공정을 제어하였다.

6. 토의 및 결론

비선형 모델링에 강점을 갖는 인공신경망을 모델링과 제어에 이용하더라도 기존의 PLS나 PCA와 같은 실험적 방법 또는 확률적 방법에서 생기는 한계를 여전히 지니고 있다[Ungar 등, 1995]. 예를 들어, 충분한 상관관계가 있는 변수들을 선택하여 모델을 구성하여야하고, 사용하는 학습 데이터를 충분히 전처리하여 잘못된 데이터를 제거하고 변

수간의 크기를 조절해 주어야 한다.

인공신경망은 다양한 데이터를 학습할 수 있는 자유로운 표현능력이 대표적인 장점이 되지만, 이러한 특정 대상공정을 학습하려면 충분한 양의 공정정보가 필요하다. 공정정보가 부족한 상황에서는 좋은 내삽기능을 기대하기 어렵다. 그러나 화학공정의 경우 모든 경우에 충분한 학습정보를 얻기란 불가능하다. 최근의 몇몇 연구는 모사기를 이용하여 인공신경망을 학습하고 이를 실시간으로 개선하는 방법들이 연구중이다.

화학공정에서 인공신경망의 응용은 주로 공정 모델링에 대하여 이루어지고 있으며, 이들은 좋은 모델링 성능을 보여주고 있다. 대부분의 연구자들이 이러한 인공신경망 공정 모델을 기존의 모델에 근거한 제어기법(model-based control)에 사용하면 제어성능이 증가할 것으로 기대하고 있다. 그러나 이를 증명하기 위해서는 보다 많은 제어에 관한 연구가 수행되어야 할 것이다. 왜냐하면 비선형 이론을 적용하는 경우에 적은 모델링 오차일지라도 제어출력에 많은 변화를 가져올 수 있기 때문이다. 또한 노이즈나 비측정 외란에 대한 영향도 모델링이 아닌 제어기 설계의 측면에서 더 많은 연구가 수행되어야 한다.

앞으로 원론 모델식과 병합하는 기법처럼 기존의 모델링 기법을 인공신경망과 병합한 연구가 더욱 많이 수행되어야 할 것이다.

감사의 글

※ 본 연구는 한국과학재단 지정 우수연구센터인 공정산업의 지능 자동화 연구센터의 연구비지원에 의하여 이루어진 것으로서, 연구비를 지원해 주신 연구센터에 감사드립니다.

참 고 문 헌

[1] Agamennoni, O., C. Chessari, J. A. Romagnoli, G. W. Barton, and K. Bourke, "A neural network based prediction scheme for an industrial propane reactor," World Congress on Neural Networks, San Diego, 1., p179, 1994.

[2] Anderson, H. W., K. H. Rasmussen and S. B. Jorgensen, "Advances in Process Identification," Chemical Process Control CPC IV Conf., AIChE, p237-269, NY, 1991.

[3] Bhat, N. and T. J. McAvoy, "Use of Neural Nets for Dynamic Modeling and Control of Chemical Process Systems," Comp. and Chem. Engng., 14, 4/5, p573-583, 1990.

[4] Blum, J., P. Villard, A. Leuba, T. Karjala and D. Himmelblau, "Practical Issues in Applying Artificial Neural Networks for Identification in Model Based Predictive Control," WCNN, San Diego, 2, p135-141, 1994.

[5] Chessari, C., B. McKay, O. Agamennoni, G. Barton, and J. Romagnoli, "The application of neural networks in the development of an on-line model for a semi-regenerative catalytic reformer," World Congress on Neural Networks, San Diego, 1., p173, 1994.

[6] Cooper, D. J., and L. B. Woll, "Using pressure sensor pattern analysis for precision injection molded parts," World Congress on Neural Networks, San Diego, 1., p179, 1994.

[7] Cybenko, G., "Continuous valued networks with two hidden layers are sufficient," Technical Report, Department of Computer Science, Tufts University, 1988.

[8] Economou, C. G., M. Morari and B. O. Palsson, "Internal model control. 5. Extension to nonlinear systems," Ind. Eng. Chem. Process Des. Dev., 25, p403-411, 1986.

[9] Eikens, B. and M. N. Karim, "Identification of a Waste Water Neutralization Process Using Neural Networks," WCNN, San Diego, 1, p185-190, 1994.

[10] Garcia, C. E. and M. Morari, "Internal model control-1. A unifying review and some new results," Ind. Eng. Chem. Process Des. Dev., 21, p308-323, 1982.

[11] Guez, A., J. L. Eilbert and M. Kam, "Neural Network Architecture for Control," IEEE Control Systems Magazine, 8, p22-25, 1988.

[12] Hornik, K., M. Stinchcombe and H. White, "Multilayer feedforward networks are universal approximators," Neural Networks, 2, p359-366, 1989.

[13] Hunt, K. J., D. Sbarbaro, R. Zbikowski and P. J. Gawthrop, "Neural Networks for Control Systems-A Survey," Automatica, 28, 6, p1083-1112, 1992.

[14] IEEE, Special issue on neural networks, IEEE Control Systems Magazine, 8, 1988.

[15] IEEE, Special issue on neural networks, IEEE Control Systems Magazine, 9, 1989.

[16] IEEE, Special issue on neural networks, IEEE Control Systems Magazine, 10, 1990.

[17] Jordan, M. I. and D. E. Rumelhart, Forward mod-

- els : supervised learning with a distal teacher, Occasional Paper 40, Center for Cognitive Science, Massachusetts Institute of Technology; p49, 1991.
- [18] Joseph, B., F. H. Wang and D. S.-S. Sheih, "Exploratory Data Analysis : A Comparison of Statistical Methods with Artificial Neural Networks," *Comp. and Chem. Engng.*, 16, 4, p413-423, 1992.
- [19] Kawato, M., Y. Uno, M. Isobe and R. Suzuki, "Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics," *IEEE Control System Magazine*, 8, p8-17, 1988.
- [20] Koivisto, H., V. T. Ruoppila and H. N. Koivo, "Real-time Neural Network Control-An IMC Approach," *IFAC, Sydney*, 4, p47-52, 1993.
- [21] Kim, H. C., X. Shen and M. Rao, "Artificial neural network approach to inferential control of volatility in refinery plants," *IFAC Algorithms and Architectures for Real-time Control*, Seoul, Korea, p135-139, 1992.
- [22] Kim, S. J., M. Lee, S. Park, S. Y. Lee and C. H. Park, "Neural Linearizing Control with Radial Basis Function Network for Chemical Processes," *WCNN, San Diego*, 2, p94-99, 1994.
- [23] Kim, S.-J., M. Lee, and S. Park, "Experimental study of neural linearizing control scheme using a radial basis function network," *Intelligent Systems in Process Engineering '95*, Colorado, 1995.
- [24] Kim, S.-J., M. Lee, and S. Park, "An experimental study of neural feedforward controller with generalized disturbance error learning," submitted to *Journal of Chem. Eng. of Japan*, 1996.
- [25] Kim, S.-J., M. Lee, S. Park, S.-Y. Lee, and C. H. Park, "A neural linearizing control scheme for nonlinear chemical processes," *Com. and Chem. Eng.*, in press, 1996.
- [26] Koivisto, H., V. T. Ruoppila and H. N. Koivo, "Real-time Neural Network Control-An IMC Approach," *IFAC, Sydney*, 4, p47-52, 1993.
- [27] Kramer, M. A., "Autoassociative neural networks," *Comp. and Chem. Eng.*, 16, p313, 1992.
- [28] Lee, M. and S. Park, "A New Scheme Combining Neural Feedforward Control with Model-Predictive Control," *AIChE Journal*, 38, 2, p193-200, 1992.
- [29] Lippmann, R. P., "An Introduction to Computing with Neural Nets," *IEEE ASSP Magazine*, 4, p4-22, 1987.
- [30] Malik, S. A., "Nonlinear identification and control of resid hydrotreating reactors," *AIChE Annual Conference*, Nov., 1992.
- [31] Montague, G. A., M. T. Tham, M. J. Willis and A. J. Morris, "Predictive Control of Distillation Column Using Dynamic Neural Networks," *IFAC, Maryland*, p231-236, 1992.
- [32] Nahas, E. P., M. A. Henson and D. E. Seborg, "Nonlinear Internal Model Control Strategy for Neural Network Models," *Comp. and Chem. Engng.*, 16, 12, p1039-1057, 1992.
- [33] Narendra, K. S. and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Transactions on Neural Networks*, 1, 1, p4-27, 1990.
- [34] Piovoso, M. J., and A. J. Owens, "Sensor data analysis using neural networks," *Chemical Process Control CPC IV Conf.*, AIChE, p101, NY, 1991.
- [35] Poggio, T. and F. Girosi, "Networks for approximation and learning," *Proc. of IEEE*, 78, p1481-1497, 1990.
- [36] Pottmann, M. and D. E. Seborg, "A Nonlinear Predictive Control Strategy based on Radial Basis Function Networks," *IFAC, Maryland*, p309-314, 1992.
- [37] Psaltis, D., A. Sideris and A. A. Yamamura, "A Multilayered Neural Network Controller," *IEEE*, 8, p17-21, 1988.
- [38] Pshichogios D. C. and L. H. Ungar, "Direct and indirect model based control using artificial neural networks," *Ind. Engng. Chem. Res.*, 30, p2564-2573, 1991.
- [39] Pshichogios D. C. and L. H. Ungar, "A hybrid neural network-first principles approach to process modeling," *AIChE JI*, 38, p1499-1511, 1992.
- [40] Qin, S. J. and T. J. McAvoy, "Building Nonlinear FIR Models via a Neural Net PLS Approach for Long-term Prediction," *AIChE Annual Meeting in Miami*, Nov., 1992.
- [41] Ricker, N. L., "Model-Predictive Control; State of the Art," *Chemical Process Control CPC IV Conf.*, AIChE, p271-296, NY, 1991.
- [42] Rudd, J. B., "Prediction and control of paper machine parameters using neural networks," *World Congress on Neural Networks*, San Diego, 1., p152, 1994.

- [43] Saint-Donat, J., N. Bhat and T. J. McAvoy, "Neural Net Based Model Predictive Control," Int. J. Control, 54, 6, p1453-1468, 1991.
- [44] Savkovic-Stevanovic, J., "A neural network model for analysis and optimization of processes," European Symposium on Computer Aided Process Engineering-2, S412, 1992.
- [45] Scott, G. M. and W. H. Ray, "Creating Efficient Nonlinear Neural Network Process Models That Allow Model Interpretation," J. Proc. Cont., 3, 3, p163-178, 1993.
- [46] Sistu, P. B. and B. W. Bequette, "Nonlinear Control of uncertain Chemical Processes-Application to a CSTR," AIChE JI, 37, p1711-1723, 1991.
- [47] Song, J. J. and S. Park, "Neural Model Predictive Control for Nonlinear Chemical Processes," J. of Chem. Eng. of Japan, 26, 4, p347-354, 1993.
- [48] Su, H. T., N. Bhat, P. A. Minderman and T. J. McAvoy, "Integration Neural Networks with Principles Models for Dynamic Modeling," IFAC, Maryland, p77-82, 1992.
- [49] Su, H. T. and T. J. McAvoy, "Integration of Multilayer Perceptron Networks and Linear Dynamic Models : A Hammerstein Modeling Approach," Ind. Eng. Chem. Res., 32, p1927-1936, 1993.
- [50] Ungar L. H., B. A. Powell and S. N. Kamens, "Adaptive networks for fault diagnosis and process control," Comp. and Chem. Engng., 14, p561-572, 1990.
- [51] Ungar, L., E. J. Hartman, J. D. Keeler, and G. D. Martin, "Process modeling and control using neural networks," Intelligent Systems in Process Engineering "95, Colorado, 1995.
- [52] Wasserman, P., Neural Computing - Theory and practice, Van Nostrand Reinhold, NY., 1989.
- [53] Willis, M. J., C. D. Massimo, G. A. Montague, M. T. Tham and A. J. Morris, "Artificial Neural Networks in Process Engineering," IEE Proceedings-D, 138, 3, p256-266, 1991.
- [54] Willis M. J., G. A. Montague, C. Di Massimo, M. T. Tham and A. J. Morris, "Non-linear predictive control using optimization technique," Proc. Am. Control Conf., Boston, p2488-2793, 1991.
- [55] Willis M. J. and G. A. Montague, Auto-tuning PI (D) Controllers with Artificial Neural Networks, IFAC, Sydney, 5, p131-136, 1993.
- [56] Ydstie, B. E., "Forecasting and Control Using Adaptive Connectionist Networks," Comp. and Chem, Engng., 14, 4/5, p583-599, 1990.
- [57] Ye, N. and J. McAvoy, "An Inferential Approach Using Neural Network Models for Controlling Chemical Processes," WCNN, San Diego, 1, p201-206, 1994.

저 자 소 개



김 석 준

1968년 7월 3일생. 1990년 과학기술대학교 화학공학과 졸업(학사). 1992년 한국과학기술원 화학공학과 졸업(석사). 1996년 한국과학기술원 화학공학과 졸업(박사).



박 선 원

1948년 1월 9일생. 1970년 서울대학교 화학공학과 졸업(학사). 1974년 Oklahoma State University 화학공학과 졸업(석사). 1979년 Univ. of Texas at Austin 화학공학과 졸업(박사). 1987년 Univ. of Houston-Clear Lake(MBA). 1979~88년

Hoechst Celanese, System Engineer, Sr. Process Control Engineer, Staff Engineer. 1988년~현재 한국과학기술원 화학공학과 교수.