

다변량 가스공정의 동적 신경회로망 설계에 관한 연구

박현기, 송상옥, 신동일*, 윤인섭
서울대학교 응용화학부, 서울대학교 화학공정신기술 연구소

Dynamic Neural Net Design for a Multi-Variables Gas Process

Hyun Ki Park, Sang Ok Song, Dong Il Shin*, En Sup Yoon
School of Chemical Engineering, Seoul National University, Seoul 151-742, Korea
*Institute of Chemical Processes, Seoul National University, Seoul 151-742, Korea

1. 서론

생산물의 품질이나 효과적인 공정조업을 위해서 어떤 특정 변수(물질의 조성 등)들은 실시간으로 측정되어야 하나 GC(Gas Chromatography)와 같은 실시간 분석기는 가격이 비싸고, 채취(Sampling)가 제한되어 있으며 채취 및 분석시간이 길어서 측정 신뢰도가 떨어지고 비싼 유지비, 보수비용을 필요로 한다. 추론 모델(Inferential Model)은 이와 같이 높은 압력, 온도 하에서 조업, 비싼 설치, 유지, 보수비용 등의 이유로 센서의 설치가 불가능하거나, 측정지연 등으로 실시간 측정이 어려운 경우 신속하고 쉽게 실시간 측정이 가능한 변수로부터 측정이 힘든 변수를 예측하는 모델이다.

신경회로망의 비선형 시스템에 대한 모델링, 제어, 이상진단으로의 응용은 최근 집중적으로 연구되어 왔다. 보통 행해지고 있는 다항식 모델에 기반한 비선형 시스템 식별(Identification)과 비교할 때, 신경회로망 모델링에서는 단지 모델 차수(model order)와 시간 지연(time delay)만을 필요로 한다. 왜냐하면 만일 은닉층(hidden layer)에 충분한 뉴런(neuron)이 존재한다면, 신경망은 비선형 변환에 의해 어떤 비선형성도 미리 정해진 정확도까지 표현할 수 있기 때문이다. 그러므로 신경회로망 모델링 시 모델 구조 선택이 연구되어야 한다.

신경회로망의 비선형 시스템에 대한 모델링은 주로 NARX 모델에 기반하며, 널리 사용되는 접근 방법으로는 신경회로망의 입력(inputs)을 변화시켜가면서 예측 값(prediction error)이 가장 적은 모델을 선택하는 것이다. 그러나 이 방법은 특히, 다변량 시스템을 다룰 때 많은 컴퓨터 용량과 실행 시간을 요구하므로 이 방법을 이용한 신경회로망 모델링은 경제적이라고 할 수 없다. 또한 다변량 특성과 복잡성으로 인하여 산업현장의 시스템에 적용하는 것이 점점 어려워지고 있다. 본 연구에서는 신경회로망을 이용하여 비선형 시스템 모델링 시, 이러한 다변량의 특성과 복잡성을 줄이는 방법을 제안하고자 한다.

2. 이론

2.1 자동연상기(Autoassociator)

자동연상기(autoassociator)는 통계학적인 것과 신경회로망에 기반한 것으로 분류되며, 기본 구조는 다음과 같다.




Fig. 1 자동연상기(Autoassociator)의 기본 구조

$G(X)$ 와 $F(Z)$ 는 자동연상기의 맵핑(mapping)과 디맵핑(demapping) 함수이며, Z 는 입력 값(X)으로부터 추출된 특성변수이므로 자동연상기는 추정함수인 $G(X)$ 와 $F(Z)$ 에 의해서 수립되어진다.

2.1.1 Self-Supervised MLP

자동연상기는 또한 병목층(bottleneck)에서 맵핑(mapping)함수 F 와 G 를 수행하기 위해서 MLP(Multi-Layer Perceptron)구조를 이용해서 행하여질 수도 있다. 이 접근 방법은 학습되는 동안 출력 데이터가 입력 데이터와 동일하다는 점에서 Self-Supervised Operation이라 불려진다. Self-Supervised MLP는 또한 병목(bottleneck) MLP, 비선형 PCA 네트워크(Kramer, 1991), 또는 모사(Replicator) 네트워크라고도 불리운다. Self-Supervised MLP의 가장 간단한 형태로 k 개의 뉴런(neuron)을 가지는 한 개의 은닉층(hidden layer)과 m 개의 선형 입력/출력 뉴런(neuron)을 가진다. ($k < m$) 효과적으로 비선형 차원 감축(Dimensional reduction)을 수행하기 위해선 그림 1의 맵핑 함수인 $F(Z)$, $G(X)$ 의 함수는 반드시 비선형이어야 한다. 이는 다음의 그림과 같이 3개의 은닉층(hidden layer)이 쓰여야 함을 제시한다.

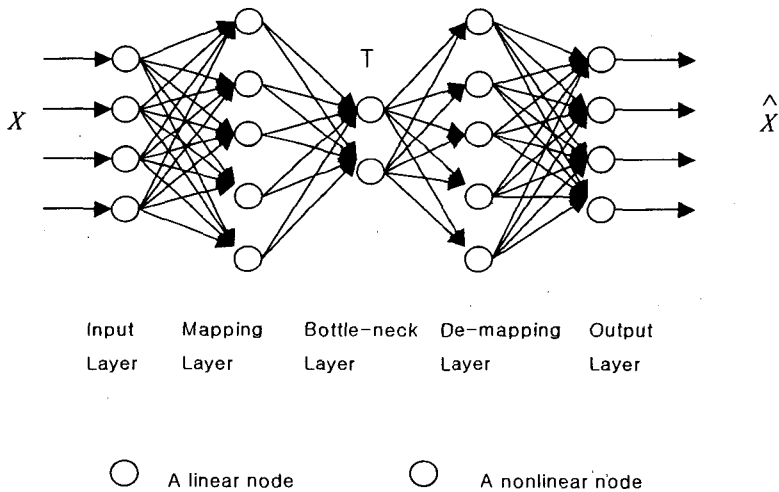


Fig. 2 Self-Supervised MLP의 구조

2.2 NARX 모델

문제를 간단히 하기 위해서, 시스템이 한 개의 입력과 출력을 가진다고 가정하자. $y(n)$ 을 변화하는 이산 시간(n)에 대한 입력 $u(n)$ 에 따른 시스템의 출력이라고 하면, NARX 모델의 식은 다음과 같이 표현된다.

$$\bar{y}_y(n+1) = \Phi(y(n), \dots, y(n-q+1), u(n), \dots, u(n-q+1))$$

여기서 q 는 시스템의 차수이며, Φ 는 비선형 함수이다. 시간 $n+1$ 에서 q 개의 지난 입력과 q 개의 지난 출력 값이 모두 사용 가능하다. 모델 출력 값 $\bar{y}_y(n+1)$ 는 실제 출력 값 $y(n+1)$ 의 추정값이다. 오차 신호를 생성하기 위해서 $y(n+1)$ 에서 $\bar{y}_y(n+1)$ 를 빼주며, 이는 신경회로망의 연결 강도(synaptic weight)를 조정하는데 사용된다. 본 연구에서 사용할 NARX 모델의 도식적인 그림은 다음과 같다.

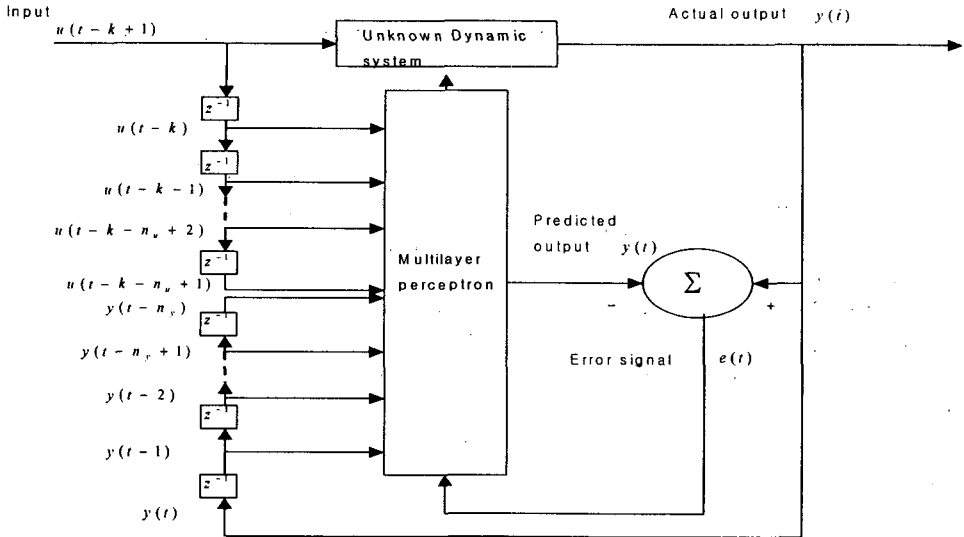


Fig. 3 NARX solution for system identification problem(training)

2.3 NARX 모델 학습(training) 절차

1. 시스템의 입력(inputs)과 출력(outputs) 각각에 NPCA를 수행하여 차원이 감축된 특성변수 $t(n)$ 과 $z(n)$ 을 얻는다.
 2. 시간 지연(time delay)을 결정한다: 모델 구조에서 정확한 시간 지연(time delay)을 선택하는 것은 매우 중요하며, correlation analysis로부터 impulse response estimate에 의해 추론 할 수 있다.
 3. 모델 차수(model order)를 결정한다: 앞에서 찾은 시간 지연(time delay)를 고정해놓고 모든 가능한 모델 차수의 조합 중에서 가장 적은 예측 오차(prediction error)를 내는 모델의 차수를 결정한다.
 4. NARX 모델을 학습시킨 후, 모사(simulation)하여 얻어진 모델의 예측 값을 NPCA를 이용하여 원래의 차원으로 디맵핑(demapping)시킨다.
- 본 연구에서 제안하는 NARX 모델 학습 절차의 구조는 개념적으로 다음과 같다.

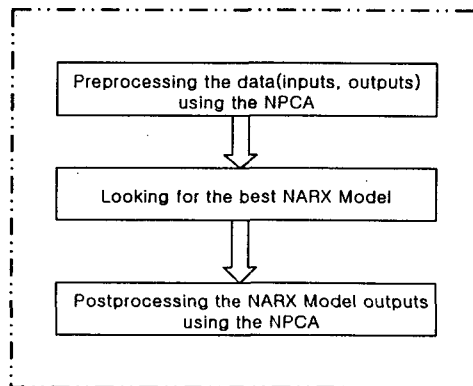


Fig. 4 Structure of a NARX Model training

3. 실험

적용된 공정은 BTX공정을 구성하는 요소 중 증기를 생성하는 메인 unit이다. 메인 unit은 증기를 생성하는 부분으로서 급수부에서 공급되는 물을 가열하여 필요한 증기를 생성하며 발생한 증기는 1차, 2차 과열기를 지나면서 고온, 고압의 증기가 된다. 두 과열기 사이에는 2차 과열기에서 나오는 증기의 온도와 압력의 조절을 용이하게 하기 위한 장치(Desuperheater)가 존재한다. 그림 5는 메인 드럼 부분의 공정도를 나타내었다. 여기서 측정되는 변수는 11개로 신경망에 학습되는 변수는 11차원이다.

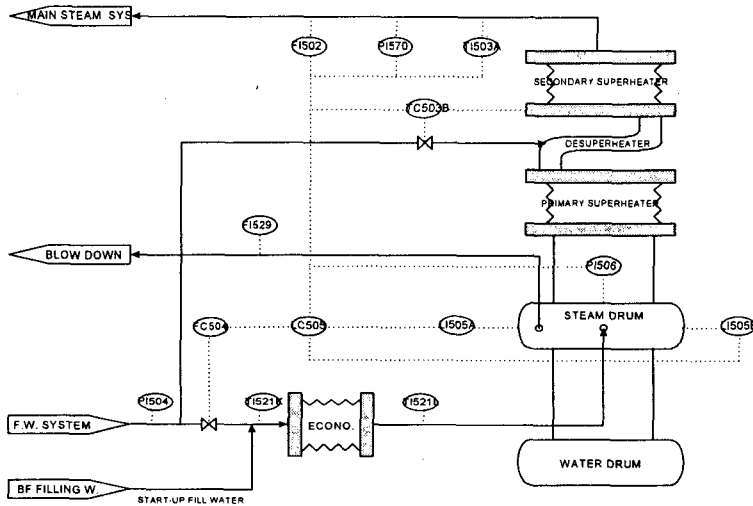


Fig. 5 Process flow diagram of the main drum in boiler system

4. 결과 및 토의

본 연구에서 제안한 방법은 NARX 모델링에서 모델 차수(model order)와 시간 지연(time delay)를 결정하는데 유용한 접근 방법임을 알 수 있고, 시스템의 차원을 감축함으로써 특히 복잡한 비선형 다변량 시스템의 신경회로망 모델링에 있어서 잘못된 모델 차수(model order)와 시간 지연(time delay) 선택을 피할 수 있다.

5. 감사

본 연구는 교육부를 통한 두뇌한국 21 사업과 국가지정연구실 사업 지원금에 의한 것입니다.

6. 참고 문헌

1. Mark A. Kramer, "Nonlinear Principal Component Analysis Using Autoassociative Neural Networks", AIChE Journal, 37(2), pp. 233-243(1991)
2. Edward C. Malthouse, "Limitation of Nonlinear PCA as Performed with Generic Neural Networks", IEEE Transaction on Neural Networks, 9(1), pp. 165-173(1998)
3. Yangdong Pan, Su W. Sung, "Data-based construction of feedback-corrected nonlinear prediction model using feedback neural networks", control engineer practice 9(2001) 859-867
4. Lennart Ljung, "System Identification", Prentice Hall PTR(1999)