

함수연결연상 신경망을 이용한 가스 공정의 모니터링

최중환, 김윤식, 김구희, 윤인섭

서울대학교 응용화학부

Monitoring of Gas Process Using Functional-Link-Associative Neural Network

Junghwan Choi, Yoonsik Kim, Ku Hwoi Kim, En Sup Yoon

Division of Chemical Engineering, Seoul National University, Seoul 151-742, Korea

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.

근래에는 측정변수가 많고 변수간 상호연관성이 큰 공정의 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.

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 서로 다른 스케일을 가지는 공정데이터를 효과적으로 학습할 수 있도록 개선된 함수연결연상 신경망을 제안하고 이 제안된 방법을 아래와 같은 실시간 이상진단 시스템의 한 모듈로 이용하였다.

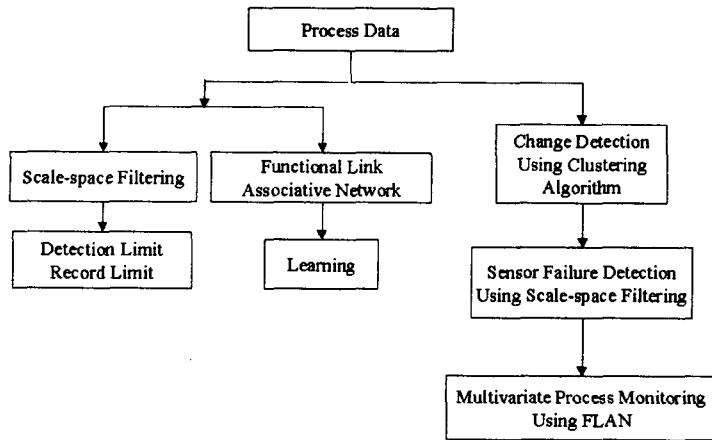


Fig. 1. Outline of Suggested process monitoring

2. 비선형 PCA를 이용한 공정감시

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 하나의 변수(Principal Component; PC)로 매핑시키기 때문에, 공정 정보를 그대로 유지하면서 시스템의 차원을 줄일 수 있는 방법이다. PCA는 이와 같은 매핑 과정과 역매핑 과정을 거쳐 입력된 측정변수들을 예측할 수 있기 때문에 실시간 공정감시에 사용된다. 실제 공정감시의 적용에 있어서는 입력데이터와 예측데이터간의 SPE(Squared Prediction Error)를 가지고 공정의 이상유무를 판단하게 된다.

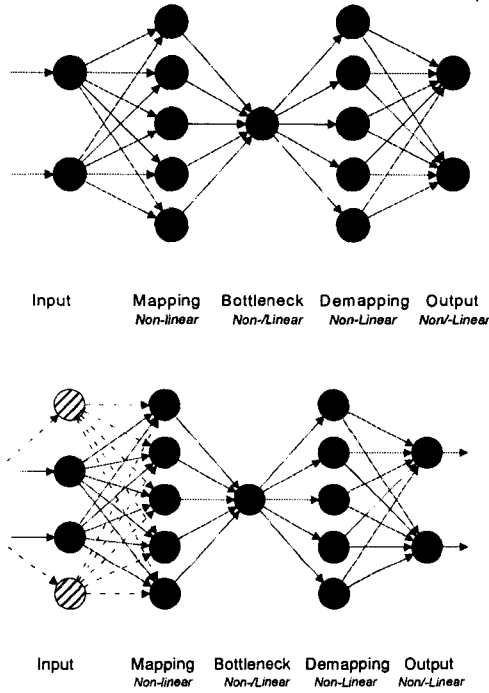
하지만 PCA는 선형 매핑에 기반한 방법으로 비선형 공정에 직접 적용의 어려움이 따른다. 현실적인 대안은 정상상태 부근의 조업점을 선형화하여 PCA를 적용하는 방법을 사용하거나 비선형 PCA를 적용하는 것이다. 비선형 PCA방법으로 이제까지 principal curve가 주로 사용되어 왔다.

한편 PCA의 구조가 신경망의 활성화함수를 학습시키는 방법과 유사하다는 것에 착안하여 신경망을 이용하여 비선형으로 확장하려는 노력이 있었다.

3. 신경망을 이용한 비선형 PCA

1991년에 Kramer는 그림2의 (a)와 같이 5개의 층으로 이루어진 ANN(Autoassociative Neural Network)을 이용하여 비선형 PCA를 구축하였다. 하지만 Kramer의 방법은 신경망의 학습이 어렵고 재현 능력이 떨어지는 단점을 지닌다. 또 최근에 많이 사용되고 있는 IT(Input Training)-net은 학습에 필요한 계산량이 너무 많고, principal curve를 사용하는 방법은 비선형 함수를 선형으로 연결한다는 단점을 지니고 있다.

그림2의 (b)는 본 연구에 사용된 함수연결연상 신경망으로 Pao(1989)에 의해 제안된 함수연결 개념을 도입하여 비선형성을 좀더 잘 표현할 수 있도록 입력층을 확장시킨 것이다.



(a) ANN

(b)FLAN

Fig. 2. ANN and FLAN

함수연결이란 입력값들의 내적이나 입력값에 제곱 또는 sine이나 cosine을 취한 값을 추가로 입력하여 학습시키는 개념이다. 비선형성을 고려한 입력값으로 학습하기 때문에 비선형성을 좀더 잘 나타낼 수 있다.

함수연결신경망은 입력단과 출력단 중에서 입력단만을 확장시키는 방법을 사용한다. 그리고 자동연상 신경망과 동일하게 매핑층과 역매핑층에서는 비선형 활성화함수를 사용하고 병목층과 출력층에서는 비선형 혹은 선형 활성화함수를 사용한다. 이때 중간 병목층이 바로 PC에 해당한다.

하지만 FLAN은 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.


$$x_3 = kx_1^2x_2^2$$

k : 상수

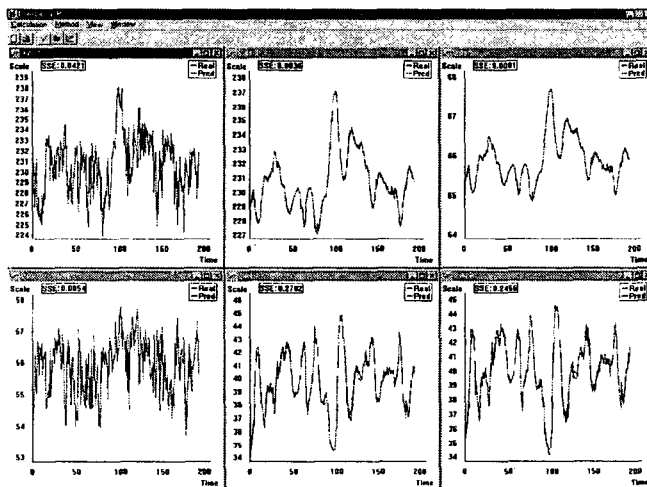
위와 같은 입력에 대해서 기존의 FLAN을 사용하면 모든 입력에 대해서 제곱 또는 세제곱을 취한 추가적인 입력을 주게 된다. 이 경우, x_3 의 불필요한 입력 확장으로 인해 계산량이 많아질 뿐만 아니라 x_1 이나 x_2 도 부정확하게 입력이 확장되기 때문에 비효율적인 학습이 이루어지게 된다.

하지만 위와 같이 입력변수들간의 관계를 알고 있는 경우는, 입력을 그에 맞게 확장시킴으로써 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. 그림3은 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.



(a) Interface of off-line module



(b) Real and predicted data of boiler water supply unit

Fig. 3. Modified FLAN

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 경우는 FC2002와 FC2002M은 sine, cosine으로, FC2002S와 LC2002M, LC2002, LI2002A는 제곱을 취해 입력을 확장시켜서

학습시켰다.

신경망 구조가 다르기 때문에 초기 학습조건(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.

4. 결론

본 연구에서는 입력변수의 개별확장을 통해 학습효율을 높인 FLAN을 이용한 공정감시 모델을 제시하였다. 이를 통하여 FLAN의 일괄적인 입력 확장이 아니라 입력변수별로 적절한 함수를 통해 입력을 확장하도록 하여 계산시간과 학습효율을 크게 높일 수 있었다.

감 사

본 연구는 포항공과대학교 지능자동화연구센터를 통한 한국과학재단 우수연구센터 지원금에 의한 것입니다.

참고문헌

1. Babaud J., A. P. Witkin, M. Baudin, R. O. Duda, Uniqueness of the Gaussian Kernel for Scale-Space Filtering, IEEE Trans. Pattern Analysis Machine Intel. vol. 8, 26-33, 1986.
2. Dong, D. and T. J. McAvoy, Nonlinear Principal Component Analysis Based on Principal Curves and neural Networks, Computers chem. Engng., vol. 20, no. 1, 65-78, 1996.
3. Kramer, M. A., Nonlinear Principal Component Analysis Using Autoassociative Neural Networks, AIChE Journal, vol. 37, no. 2, 233-243, 1991.
4. 모경주, 클러스터링 기법과 함수연결연상 신경망을 이용한 실시간 화학공정 감시에 관한 연구, 박사학위논문, 서울대학교 화학공학과, 1998.
5. 최용진, 실시간 공정데이터의 정성적 해석을 위한 Scale-space 필터링 기법의 응용과 구현에 관한 연구, 박사학위논문, 서울대학교 화학공학과, 1995.