

PRS를 이용한 제지공정의 인식 및 모델링에 관한 연구

Modeling and Identification of Paper Plants based on PRS

오창훈 · 여영구¹⁾ · 강홍²⁾

1) Department of Chemical Engineering, Hanyang University, 2) J.J. Engineering

Abstract

Paper process is complex and multivariable system. Identification of a paper process model is imperative for the development of predictive control method. 13-level Pseudo-Random Sequence Signals were used to identify the plant model in which the neural network model was considered model as a real paper process. Results of simulations for identification using 13-level PRS signals and Prediction Error Method are compared with plant operation data. From the comparison, we can see that the dynamics of the model show good agreement with those of real plant.

Keywords: Neural networks, Multi-level PRS signals, Prediction Error Method

1. 서 론

제지공정은 입력과 출력이 다수인 복잡한 비선형 다변수 공정이다. 지종 교체시 예측제어를 위해서는 공정의 동특성을 나타내어 주는 모델이 필수적이다. 현재 제지공정에서는 안정성과 경제적인 이유로 feedback 제어에 의한 closed-loop 상태로 조업하고 있다. 본 연구에서는 이러한 제지공정을 바탕으로 하여 4개의 input(thick stock, filler flow, steam pressure, speed)과 3개의 output(basis weight, ash content, moisture

content)으로 구성되는 시스템으로 설정하였다. 대상 공정인 제지공정의 모델을 찾기 위해 closed-loop data를 직접적으로 사용하여 인공신경망으로 학습시킨 모델을 실제 공정이라 가정하였다. 그 공정에 input data로서 13-level PRS signal을 가했을 때 얻어지는 공정응답을 구하였고, 이 data를 smoothing 작업을 거쳐 open-loop identification의 한 기법인 PEM(Prediction Error Method)으로 모델을 규명하였다. Fig. 1은 closed-loop data를 이용한 인공신경망 모델과 이 모델을 바탕으로 입력과 출력, Noise의 관계를 표현한 open-loop 상태의 공정을 나타내며, Fig. 2는 공정인식과정을 나타낸다. 여기서 얻은 모델은 고차의 상태 공간 모델이다. 이 모델을 검증한 결과 실제 공정과 비슷한 동특성을 나타냄을 알 수 있었다.

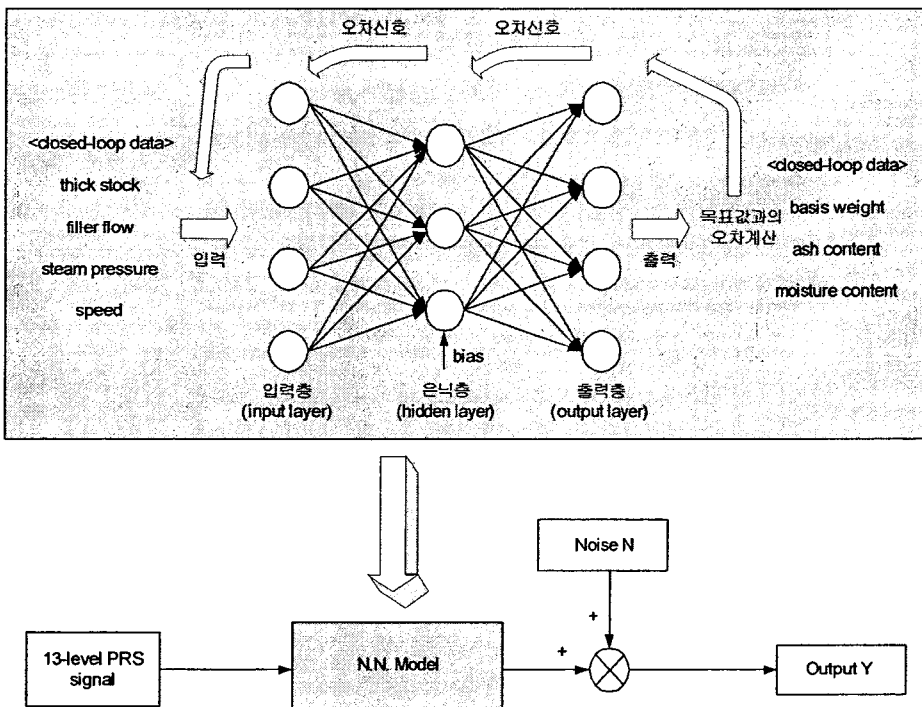


Figure 1. Multi-layer neural network model and open-loop configuration

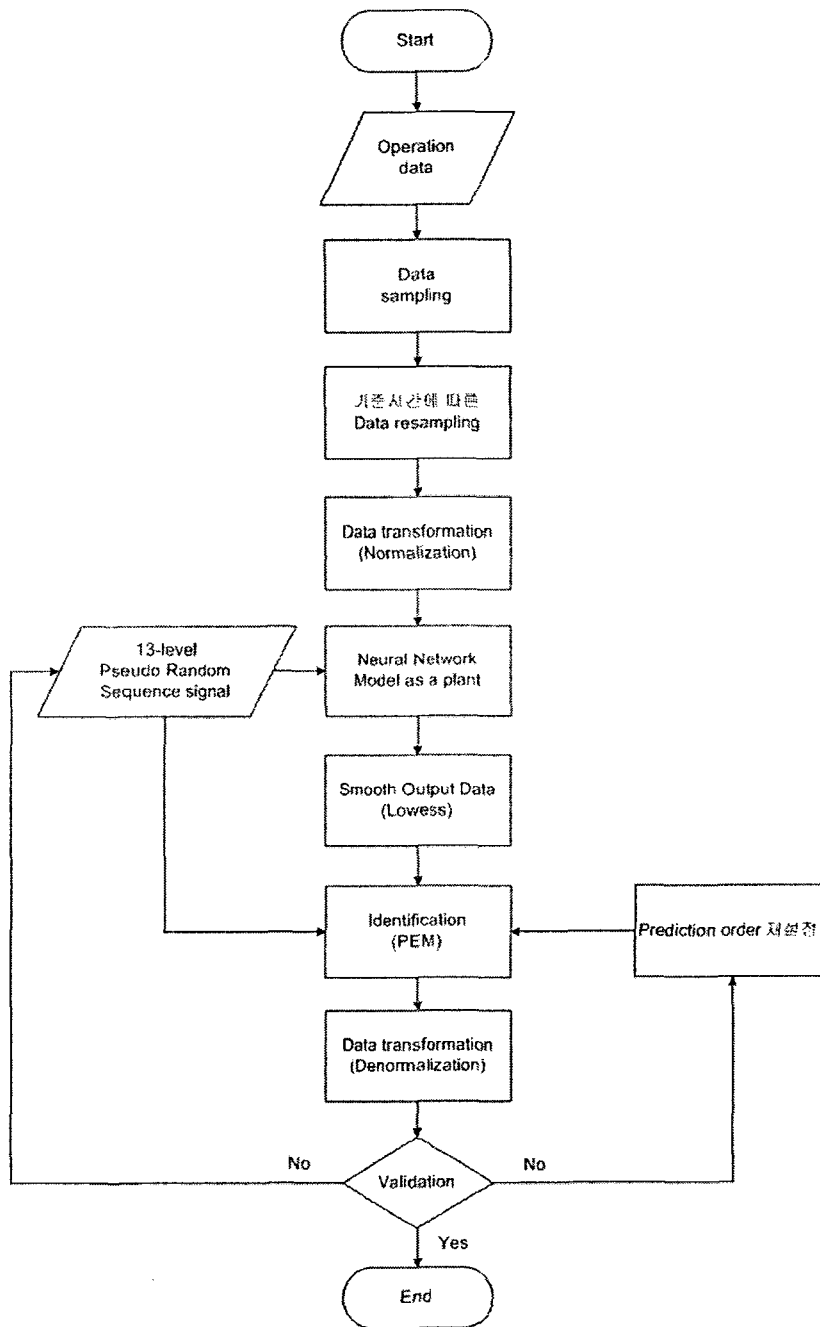


Figure 2. Identification flow chart

2. Neural Network

2.1 인공신경망 모델

본 연구에서는 Backpropagation 알고리즘을 적용한 다층 퍼셉트론으로 신경망을 구현하였다. 다층 퍼셉트론은 입력 층과 출력 층 사이에 하나 이상의 중간층이 존재하는 신경망이다. 계층구조는 단층 퍼셉트론과 유사한 구조를 가지고 있지만 중간층과 각 unit의 입출력 특성을 비선형화 함으로써 네트워크의 능력을 향상시켜 단층 퍼셉트론의 단점들을 극복했다.

2.2 학습방법

학습 알고리즘으로는 Bayesian regularization 방법을 이용하여 학습을 시켰다. 은닉 층의 수는 2개를 사용했고 각각의 뉴런 수는 A사 45, 20, B사 45, 30개로써 학습 결과 가장 좋은 결과를 나타내는 수로 두었다. Hornik는 어떤 연속 함수도 두 개의 hidden layer와 하나의 고정 layer로 이루어진 feedforward neural network에 의해 근사되어질 수 있다는 것을 증명했다.¹⁾ 활성화함수로 sigmoid 함수를 사용하여 비선형성을 고려하도록 하였다. 식[1]은 bipolar sigmoid 함수이고 매핑범위는 -1에서 +1까지이다.

$$f_j(\neq t_{ji}) = \frac{2}{1 + e^{-\lambda \cdot \neq t_{ji}}} - 1 \quad [1]$$

Fig. 3과 Fig. 4는 이렇게 구성한 인공신경망 모델로부터 학습된 A사와 B사의 output simulation이다. 인공신경망을 통하여 나온 모델을 검증했을 때 operation data를 정확히 인식하였다.




Figure 3. Neural Network training output of A company




Figure 4. Neural Network training output of B company

3. 13-level PRS signal design

System Identification을 하기 위해서는 대상공정에 step, impulse, pulse, PRBS(Pseudo-Random Binary Sequence)등과 같은 신호를 공정에 입력하여 이들 신호에 의해 변화된 공정 출력의 데이터가 필요하다. 이렇게 얻은 공정의 입력 및 출력 데이터를 사용하여 미리 사용자가 정의한 모델의 parameter를 계산하여 추정된 모델을 알아 낼 수 있다. 본 연구에서는 13-level PRS 신호를 이용하여 모델을 규명하였다. PRBS 신호는 단지 2-level로 이루어져있기 때문에 편향된 응답을 보일 수 있다. 따라서 공정의 비선형성에 대한 충분한 정보를 제공하지 못할 수 있다 (e.g. $y(k)=u^2(k)$). 하지만 Multi-level PRS 신호는 사용자가 정한 level로 이루어진 다양한 신호를 입력하여 비선형 함수의 편향되지 않은 응답을 알아 낼 수 있고 이를 바탕으로 비선형 함수의 선형적 동특성 추정을 가능케 한다.²⁾ Fig. 5에 전형적인 Multi-level PRS 신호를 나타내었고, Fig. 6은 A사 stock flow의 13-level PRS 신호 입력을 나타낸다. 나머지 3개의 조절변수에 대해서도 이와 같은 방법으로 입력을 주었다.




Figure 5. Typical multi-level PRS signal




Figure 6. Stock flow with 13-level PRS signal (Plant A)

4. Local Regression Smoothing

4.1 국소 회귀 평활

Open-loop system의 경우 출력 쪽에 측정 noise의 영향이 포함되는데, 이는 system의 Identification 성능을 떨어뜨리는 요인이 된다. Open-loop data인 13-level PRS 신호 입력시 얻어지는 응답곡선으로부터 이러한 noise를 제거하기 위해, 국소 회귀 평활의 한 기법인 Lowess (Locally weighted scatter plot smooth)을 사용하여 평활한 공정응답 곡선을 구하였다. Fig. 7은 A사 stock flow에 13-level PRS 신호 입력시 얻어지는, noise가 포함된 응답과 평활 응답을 나타낸다.

4.2 LOWESS

국소 가중 산점도 평활 기법은 아래와 같이 전개된다.

- 일정범위 안에서의 각 data point에 대한 회귀가중치 (regression weight)를 계산한다. 가중치는 식[2]와 같이 tricube function으로 표현된다.

$$w_i = \left(1 - \left| \frac{x - x_i}{d(x)} \right|^3\right)^3 \quad [2]$$

여기서 x 는 평활화 되는 응답과 관련된 predictor value를 나타내며, x_i 는 일정범위로 한정되어지는 x 와 가장 가까운 값을 나타낸다. $d(x)$ 는 x 와 가장 멀리 떨어져 있는 predictor value간의 횡좌표 간격을 의미한다.

- 가중최소자승회귀 (weighted least squares regression)를 수행한다. 여기서 회귀식은 1차 다항식이 쓰인다.




Figure 7. smooth data (Plant A)

5. Prediction Error Method

공정인식방법으로는 Parametric Estimation의 한 기법인 PEM³⁾(Prediction Error Method)을 이용하였는데, 이는 ARX(Auto-Regressive eXogeneous input), ARMAX(Auto-Regressive Moving Average with eXogeneous input), OE(Output Error) 등의 모델에 대해서 각 모델의 one-step ahead prediction으로 구한 값과 실측치와의 오차를 최소화하여 adjustable parameter를 계산하는 방법을 말한다. 본 연구에서 사용된 PEM은 Black-Box 상태 공간 모델로서 각 input 변수마다 13-level PRS signal을 입력하고 나머지 input 변수들은 정상상태 수치를 입력하였을 경우 식 [3]과 같은 4개의 상태 공간 모델을 구할 수 있다.

$$\begin{aligned} x(t+1) &= Ax(t) + Bu(t) + Ke(t) \\ y(t) &= Cx(t) + Du(t) + e(t) \end{aligned} \tag{3}$$

이러한 상태공간 모델들은 전달함수 형태로 표현할 수 있는데 다음과 같이 3×4 형태를 가진 전달함수들로 표현된다.

$$G_p : \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix} = \begin{matrix} \begin{bmatrix} G_{11}^{U_1} & G_{12}^{U_1} & G_{13}^{U_1} & G_{14}^{U_1} \\ G_{21}^{U_1} & G_{22}^{U_1} & G_{23}^{U_1} & G_{24}^{U_1} \\ G_{31}^{U_1} & G_{32}^{U_1} & G_{33}^{U_1} & G_{34}^{U_1} \end{bmatrix} & \cdot & \\ & \cdot & \\ & \cdot & \\ \begin{bmatrix} G_{11}^{U_4} & G_{12}^{U_4} & G_{13}^{U_4} & G_{14}^{U_4} \\ G_{21}^{U_4} & G_{22}^{U_4} & G_{23}^{U_4} & G_{24}^{U_4} \\ G_{31}^{U_4} & G_{32}^{U_4} & G_{33}^{U_4} & G_{34}^{U_4} \end{bmatrix} & \begin{bmatrix} U_1 \\ U_2 \\ U_3 \\ U_4 \end{bmatrix} \end{matrix} \tag{4}$$

이러한 전달함수들은 각 변수에 13-level PRS signal을 주었을 때 가장 영향을 많이 주는 전달함수들로 다음과 같이 재구성 되어 진다.

$$G_p : \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix} = \begin{bmatrix} G_{11}^{U_1} & G_{12}^{U_2} & G_{13}^{U_3} & G_{14}^{U_4} \\ G_{21}^{U_1} & G_{22}^{U_2} & G_{23}^{U_3} & G_{24}^{U_4} \\ G_{31}^{U_1} & G_{32}^{U_2} & G_{33}^{U_3} & G_{34}^{U_4} \end{bmatrix} \begin{bmatrix} U_1 \\ U_2 \\ U_3 \\ U_4 \end{bmatrix} \quad [5]$$

여기서 U_i 은 조절변수이고 (U_1 : stock flow, U_2 : clay flow, U_3 : steam pressure, U_4 : machine speed) Y_i 는 (Y_1 : basis weight at size press, Y_2 : ash content, Y_3 : moisture content at size press) 제어변수를 나타내며, G_p 는 open-loop 상태의 전달함수를 의미한다.

6. 결과 및 고찰

A사와 B사의 공정을 대상공정으로 하여 모델 모사결과를 나타내었다. sampling time은 두 회사 모두 0.5분으로 하였다. Fig. 8은 A사를 바탕으로 56→72→60→66→69→51→64→95→110→117→110→101→95→100→113→86g/m² 으로 지중이 변화할 때의 output 데이터와 simulation 데이터의 validation 수행결과이며, Fig. 9은 B사를 바탕으로 52→66→82→65→81→97→52→55→102→65→105→75→80→65→80→64g/m² 으로 지중이 변화할 때의 output 데이터와 simulation 데이터의 validation 수행결과를 나타낸다. Fig. 8과 Fig. 9로 볼 때 13-level PRS signal과 PEM을 이용한 모델로부터 계산된 결과는 실제 공장의 output과 비슷한 경향을 보이고 있음을 알 수 있다.




Figure 8. Validation (Plant A)




Figure 9. Validation (Plant B)

7. 결 론

지중 교체 시 효율적인 제어를 위해서는 공정을 표현하는 모델이 필수적이다. 본 연구에서는 모델을 찾기 위해 closed-loop data을 이용한 Neural Network Model을 실제 공정이라 가정하고 지중 교체시 제지공정을 모델링 하였다. 여기에서는 3×4 공정으로써 상태 공간 모델과 전달함수 형태로 모델을 구하였으며, 모델을 구할 때 13-level PRS signal과 PEM기법을 이용하였다. Validation을 수행하여 본 결과 실제 공정과 비슷한 경향을 나타냄을 알 수 있었으며, 향후 예측제어기 설계에도 도움이 될 것이다.

인용문헌

1. Hornik, K., Stinchcombe, M., and White, H., "Multilayer feedforward networks are universal approximators", Neural network the official journal of the International Neural network Society, 359-366(1989).
2. M. W. Braun, D. E. Rivera, A. Stenman, W. Foslien, and C. Hrenya, "Multi-level Pseudo-Random Signal Design and 'Model-on-Demand' Estimation Applied to Nonlinear Identification of a RTP Wafer Reactor", Proceedings of the American Control Conference, June, San Diego, California, 1573-1577 (1999).
3. Ljung, L., Mckelvey, T., "Subspace identification from closed loop data", Signal Processing, Vol.52, 209-215(1996).