

지종교체 공정의 예측제어

Model Algorithmic Control of Grade Change Operations in Paper Mills

박종호¹⁾ · 여영구¹⁾ · 김영곤²⁾ · 강홍³⁾

1) 한양대학교 2) 한국제지 3) J-J 컨설팅

Abstract

In this work the Model algorithmic control method is applied to control the grade change operations in paper mills. The neural network model for the grade change operations is identified first model is then extracted from the neural model. Results of simulations for MAC control of grade change operations are compared with plant operation data response. From the comparison, we can see that the proposed MAC method exhibits faster response for the grade change of paper and achieves stable steady-state.

Key words: Neural Networks, Finite Impulse Model, Model Algorithmic Control

1. 서론

제지 공정의 지종교체에 있어서 모델예측제어방법이 효율적으로 이용되기 위해서는 지종교체 모델이 정확하여야 한다. 그러나 제지공정은 공정 입력 변수간의 간섭이 심한 다변수 공정으로서 비선형, 복잡성, 그리고 불확실성으로 인하여 시스템에 대한 정확한 모델을 찾기가 힘들다. 본 연구에서는 지종교체 공정이 4개의 input(thick stock, filler flow, speed, steam pressure)과 3개의 output(basis weight, ash content, moisture content)로 구성되는 시스템이라 간주하고 제지 조절변수의 주요 3가지인 basis

weight(g/m²), ash content(%), moisture content(%)를 제어하여 보았다. 여기서는 인공신경망 기법을 이용하여 공정과 거의 일치하는 결과를 얻어 FIR(Finite Impulse Response)모델을 이용하여 공정을 인식하였고 이를 바탕으로 예측제어 기법을 구사하였다. 인공신경망을 이용한 예측기술이 점점 널리 쓰이는 이유는 인공신경망 모델이 예측방법론에 있어서 복잡한 비선형 시스템을 효과적으로 나타내어 주기 때문이다.¹⁾ 이렇게 인공신경망을 이용한 예측제어에 대한 연구로 인공신경망과 General Predictive Control(GPC), Dynamic Matrix Control(DMC), 그리고 Receding Horizon Control(RHC) 결합하여 제어하는 연구가 있었다.²⁾ 본 연구에서는 MAC(Model Algorithmic Control)의 이름으로 시작되어 발전되어 온 예측제어 기법을 사용하였다. 이 방법은 플랜트 모델로서 FIR모델을 사용하여 알고리즘 형태로 제시되었는데, 이때 시스템에 가해지는 제한 조건들을 알고리즘에 포함시킴으로서 제한조건들을 만족시키는 범위에서 최적의 제어입력이 구해진다. 이렇게 구해진 최적의 입력값으로 출력값을 얻어 운전 데이터와 비교하였다.

2. 인공 신경망

2.1 인공신경망 모델

본 연구에서는 Backpropagation 알고리즘을 적용한 다층 퍼셉트론으로 신경망을 구현하였다. 다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망으로 계층구조로 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 Levenberg-Marquardt를 이용하여 학습을 시켰다. 은닉층의 수는 2개를 사용했고 각각의 뉴런 수는 학습 결과 가장 좋은 결과를 나타내는 20, 30개로 두었다. Hornik는 어떤 연속 함수도 두개의 hidden layer와 하나의 고정 layer로 이루어진 feedforward neural network에 의해 근사되어질 수 있다는 것을 증명했다.³⁾ 활성

함수로 시그모이드 함수를 사용하여 비선형성을 고려하도록 하였다. 식(1)은 bipolar sigmoid함수이고 매핑범위는 -1에서 +1까지이다.

$$f(\neq t) = \frac{2}{1 + e^{-\lambda \cdot \neq t}} - 1 \quad (1)$$

시간지연을 고려한 시간(t)에서의 입력을 넣어 학습하였다. Fig. 1은 이렇게 구성한 인공신경망 모델로부터 학습된 output simulation이다. 인공신경망을 통하여 나온 모델을 검증했을 때 operation data를 정확히 인식하였다.

3. Impulse Model

Impulse 모델을 이용하는 방법의 가장 큰 장점은 공정에 대한 지식을 필요로 하지 않고 인식과정이 간단하며 시간 지연 등의 복잡한 비선형적 요소들도 간단히 표현할 수 있다는 점이다. 식(2)는 MIMO공정의 impulse model이다.

$$\text{MIMO} : y_k(t) = \sum_j^{nu} \sum_i^n h_{k,j,i} u_j(t-i) \quad (k=1, \dots, ny) \quad (2)$$

인공신경망으로 학습한 모델을 실제 공정이라 가정하고 그 공정에 impulse를 가했을 때 얻어지는 공정 output을 새로운 input값으로 사용한다. 모델의 차수는 impulse input을 가한 후 system이 정상상태에 이르기 시작한 시간으로 이용한다. 다변수 ARX 모델은 다음의 식(3)과 같고 impulse 모델에서 ARX 모델은 식(4)과 같은 A가 단위행렬인 경우로 볼 수 있다.

$$A_0 Y(t) = B_1 U(t-1) + B_2 U(t-2) + \dots + B_n U(t-n) \quad (3)$$

$$A_0 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad B_i = \begin{bmatrix} b_{1,1,i} & b_{1,2,i} & b_{1,3,i} & b_{1,4,i} \\ b_{2,1,i} & b_{2,2,i} & b_{2,3,i} & b_{2,4,i} \\ b_{3,1,i} & b_{3,2,i} & b_{3,3,i} & b_{3,4,i} \end{bmatrix} \quad (4)$$

$$U(t-i) = [u_{stock}(t-i) \ u_{filler}(t-i) \ u_{speed}(t-i) \ u_{steam}(t-i)]^T \quad (5)$$

식(3)의 행렬 B는 우리가 찾아야 할 impulse parameter를 나타낸다. 이를 이용하여 모델 gain을 설정하고 최소자승 곡선 맞춤 방법을 이용하여 모델 gain 구하였다.

4. MAC 방법

4.1 다 변수 MAC 알고리즘

다변수 Impulse mode은 식(2)와 같이 나타낸다. 식(2)의 1 time 예측은 식(6)과 같다.

$$\begin{aligned} \widehat{y}_k(t+l) &= \sum_{j=1}^{nu} \sum_{i=1}^n b_{k,j,i} U_j(t+l-i) + \widehat{n}_k(t+l) \quad (k=1, \dots, ny) \quad (j=1, \dots, nu) \quad (6) \\ \widehat{y}_k(t+l) &= \sum_{j=1}^{nu} \sum_{i=1}^l b_{k,j,i} U_j(t+l-i) + \sum_{j=1}^{nu} \sum_{i=l+1}^n b_{k,j,i} U_j(t+l-i) + \widehat{n}_k(t+l) \quad (k=1, \dots, ny) \end{aligned}$$

미래의 noise는 현재의 noise와 같다고 가정하면

$$\widehat{n}_k(t+l) = \widehat{n}_k(t) = \sum_{j=1}^{nu} \sum_{i=1}^n b_{k,j,i} U_j(t-i) \quad (k=1, \dots, ny) \quad (7)$$

식(7)은 실시간 MAC를 적용하지 않은 상태이다. 따라서 $y_k(t)$ (측정된 output)과

$\sum_{j=1}^{nu} \sum_{i=1}^n b_{k,j,i} U_j(t-i)$ (model output)은 같다고 가정하였다. 즉 model은 noise가 없는 완전한 model 이라고 가정 하여 모사하였다.

$$U_+ = \begin{bmatrix} U(t) \\ U(t+1) \\ \vdots \\ U(t+M-1) \end{bmatrix}, \quad U_- = \begin{bmatrix} U(t-N+1) \\ U(t-N+2) \\ \vdots \\ U(t-1) \end{bmatrix}, \quad y = \begin{bmatrix} \widehat{y}(t+1) \\ \widehat{y}(t+2) \\ \vdots \\ \widehat{y}(t+M) \end{bmatrix} \quad (8)$$

여기서 U_+ =future input, U_- =past input, y =predictive output을 나타낸다.

$$n = \begin{bmatrix} \widehat{n}(t+1) \\ \widehat{n}(t+2) \\ \vdots \\ \widehat{n}(t+M) \end{bmatrix} = \begin{bmatrix} \widehat{n}(t) \\ \widehat{n}(t) \\ \vdots \\ \widehat{n}(t) \end{bmatrix}, \quad w = \begin{bmatrix} u(t+1) \\ u(t+2) \\ \vdots \\ u(t+M) \end{bmatrix} \quad (9)$$

$$H_1 = \begin{bmatrix} h_1 & 0 & \cdots & 0 \\ h_2 & h_1 & & \vdots \\ \vdots & \vdots & \ddots & 0 \\ h_M & h_{M-1} & & h_1 \end{bmatrix}, \quad H_2 = \begin{bmatrix} h_n & \cdots & h_i & \cdots & h_2 \\ 0 & \cdots & h_j & \cdots & h_3 \\ \vdots & & \vdots & & \vdots \\ 0 & \cdots & 0 & \cdots & h_{M+1} \end{bmatrix} \quad \text{으로 두면}$$

$$y = H_1 U_+ + H_2 U_- + n = H_1 U_+ + f \quad (10)$$

4.2 예측제어 방법

원하는 output경로는 다음과 같이 설정하였다.

$$w_k(t+l) = \alpha \cdot w_k(t+l-1) + (1-\alpha) \cdot \gamma(t+l) \quad (11)$$

위에서 $\gamma(t)$ 는 시간 t에서의 setpoint이며 α 는 trajectory가 setpoint에 근접하는 속도를 나타내주는 상수로서 작을수록 trajectory는 setpoint에 빨리 다다르게 된다. 제약 조건이 없을 경우 최적의 예측제어 알고리즘이 계산하는 최적의 input 예측값은 식(14)과 같은 방식으로 구해진다.

$$U_+ = (H_1^T H_1 + \lambda I)^{-1} H_1^T (w - f) \quad (12)$$

$$e = w - y = w - H_- U_- - n - H_+ U_+ = w - f - H_+ U_+ \quad (13)$$

$$U_+ = (H_+^T H_+ Q + \lambda I)^{-1} H_+^T (w - f) \quad (14)$$

식(14)에서 얻은 U_+ 의 첫 번째 원소만이 공정에 적용된다. 제어모사에서 미래 제어 구간은 20, 예측구간은 15로 하였고, 입력가중치(Q)는 [0.2 0.35 0.24 0.4] 출력가중치(R)는 [4 3 2]로 하였다. α 는 0.97로 설정하였다.

5. 결과 및 고찰

A사의 공정을 대상공정으로 하여 모사하였다. 지중교체시 평량 67→105, 67→53, 77→107, 99→82, 66→82, 68→82, 67→53 60→82, 66→84, 67→57(g/m^2) 변화에 대하여 데이터를 연결하여 모사하였다. 이는 실제 공장에서 실시되는 지중교체가 아니라 모사 결

과와 운전데이터를 쉽게 비교하기 위해서 sampling time을 0.1분으로 하여 10개 data를 임의로 연결한 것이다. Fig. 2는 input의 비교로서 MAC에 의한 모사 결과가 운전데이터 결과와 차이가 있는데 실제 공정에 MAC에 의한 input을 적용했을 때 더 나은 결과를 줄 수 있을 것으로 기대할 수 있다. 이 input을 이용한 output 모사결과를 Fig. 3에 나타내었다. output 결과로는 실제 공정보다 빠른 지중 교체 면모를 보였고, 특히 지질의 주요 원인인 종이의 수분량의 변화 있어 실제 공정 data 보다 안정적으로 진동 없이 setpoint에 유지됨을 확인 할 수 있었다. 지중교체도 운전 데이터와 비교했을 때 빠르게 시작되는 것을 알 수 있었다.

6. 결 론

본 연구에서는 제지공정의 지중교체 데이터를 인공신경망을 이용하여 impulse model parameter를 구하여 MAC제어를 하였다. 인공신경망을 통한 모사결과는 운전 데이터와 거의 일치하였다. 이렇게 학습된 인공신경망 모델로 부터 impulse parameter를 구하였는데 impulse model은 고차의 모델이나 LS방법을 통하여 차수를 낮춰 실제 운전 데이터와 비교하였을 때에도 거의 일치하였다. MAC제어에서는 차수를 낮춘 모델을 이용하였다. 이 모델은 MIMO공정이기 때문에 다변수 공정에 맞도록 MAC algorithm을 설정하였으며 제한 조건이 없는 최적화 방법을 이용하여 예측 입력값을 구하였다. MAC를 실제 online상으로 공정에 적용하지 않았기 때문에 외란의 요소는 감안 할 수 없었지만 MAC output의 경우 운전 데이터보다 빠른 지중교체 변화를 보였고 지중교체 후 정상상태에 도달하는 시간에 많은 차이를 보였다. 모사 결과는 변화의 범위가 작고 신속하게 안정적으로 정상상태에 이르는 것을 알 수 있었다.

인용문헌

- [1] Morris, A. J., Montague, G., and Willis, M. J., Chemical engineering research & design : transactions of the Institution of Chemical Engineers, 72(1) 3~(1994).
Artificial Neural Networks: Studies in Process Modelling and Control.

[2] Azlan Hussain, H., Artificial intelligence in engineering, 13(1), 55~68(1999). Review of the applications of neural networks in chemical process control-simulation and online implementation.

[3] Hornik, K., Stinchcombe, M., and White, H., Neural network : the official journal of the International Neural network Society, 2(5), 359~366(1989). Multilayer feedforward networks are universal approximators.

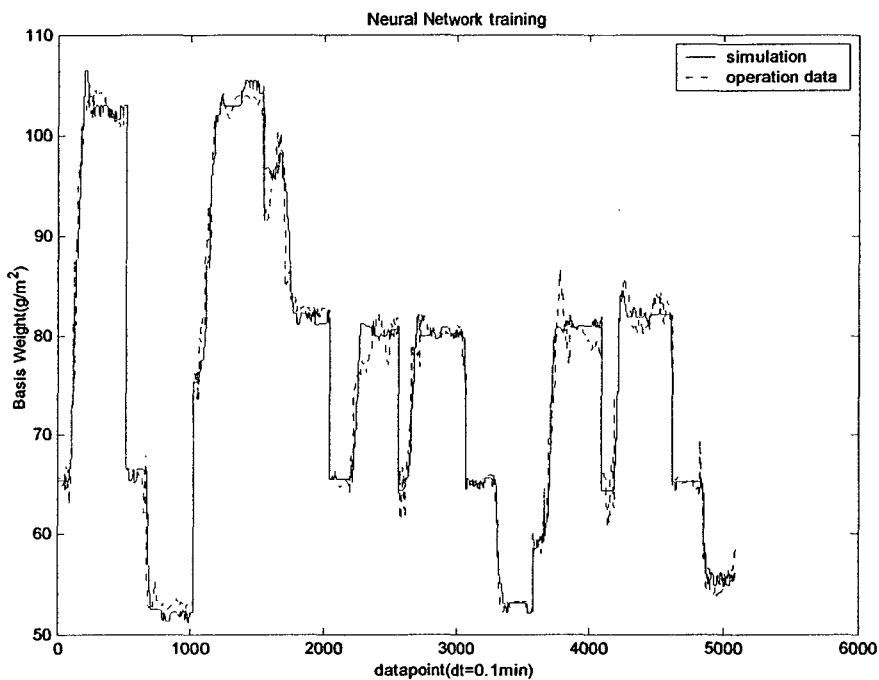


Figure 1. Neural Network training output(Basis Weight(g/m^2))




Figure 2. MAC input trend at $67\text{g/m}^2 \rightarrow 105\text{g/m}^2$




Figure 3. MAC output trend at $67\text{g/m}^2 \rightarrow 105\text{g/m}^2$