

# 제지공정의 모델예측제어

Dynamic Matrix Control of Grade Change Operations in Paper Mills

박종호 · 여영구<sup>1)</sup> · 강홍<sup>2)</sup>

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

## Abstract

In this work the Dynamic Matrix Control method is applied to control the grade change operations in paper mills. Paper process trained by neural network regards a real-plant. The model obtained with operation data is used to achieve DMC. Results of simulations for DMC control of grade change operations are compared with plant operation data response. From the comparison, we can see that the proposed DMC method exhibits faster response for the grade change of paper and achieves stable steady-state.

*Key words:* Neural Networks, PEM, Dynamic Matrix Control

## 1. 서 론

제지공정은 공정의 비선형적 특성뿐만 아니라 thick stock, filler등 각 입력 요소들로부터 reel까지의 원료 전달 과정이 복잡하며 이에 따른 시간 지연도 크다. 이에 더하여 입력하는 조절변수가 다수이고 제어변수가 다수인 전형적인 MIMO(Multi-Input, Multi-Output)공정으로 현재는 feedback제어 작용이 원활하지 못하고 불안정하여 인력으로 수동제어를 하고 있다. 그럼에 따른 비효율적 운전으로 인한 생산성 저하 및 생산비용이 증가하는 문제점이 있다. 그래서 자동교체 시스템 도입의 필요성이 요구되고 있고, 최근 제지 공정에 모델 예측제어를 이용한 제어가 시도 되고 있다. 본 연구에

서는 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( $\text{g}/\text{m}^2$ ), ash content(%), moisture content(%)를 모델예측제어 기법을 이용하여 제어하여 보았다. 인공신경망을 이용하여 공정과 거의 일치하는 결과를 얻어 이를 실공정이라 간주하고 PEM으로 공정을 인식하였다. 인공신경망을 이용한 예측기술이 점점 널리 쓰이는 이유는 인공신경망 모델이 예측방법론에 있어서 복잡한 비선형 시스템을 효과적으로 나타내어 주기 때문이다.<sup>1,2)</sup> 본 연구에서는 모델예측제어 기법 중 DMC(Dynamic Matrix Control)의 이름으로 시작되어 발전되어 온 예측제어 알고리즘을 사용하여 구해진 최적의 입력값으로 출력값을 얻어 운전 데이터와 비교하였다.

## 2. 인공 신경망

인공신경망은 현재 많은 제어전략에서 가장 강력한 툴로 적용되고 있다.<sup>3)</sup> 3-layer Backpropagation 네트워크와 같은 인공신경망 모델은 Schlkoff에 의해서 증명되었다.<sup>4)</sup> 그는 공정의 입출력 데이터를 이용하여 어떤 비선형 시스템 또는 함수를 최적의 알고리즘으로 훈련시켰다. 본 연구에서도 Backpropagation 알고리즘을 적용한 다층 퍼셉트론으로 신경망을 구현하였다. 학습 알고리즘으로는 Levenberg–Marquardt를 이용하여 학습을 시켰다. 은닉층의 수는 2개를 사용했고 각각의 뉴런 수는 학습 결과 가장 좋은 결과를 나타내는 20, 30개로 두었다. 활성함수로 시그모이드 함수를 사용하여 비선형성을 고려하도록 하였다. Fig. 1에 인공신경망 flowchart를 나타내었다.

### 2.1 Levenberg–Marquardt backpropagation 알고리즘

Levenberg–Marquardt 방법은 2차 훈련식에 접근하기 위해 개발되었다. 즉 이 알고리즘의 목적함수는 2차 미분항으로 나타낼 수 있다. 그러므로 특히 1차식으로 나타나는 gradient descent 방법 보다 목적값에 더 잘 도달한다. 이 알고리즘을 간략하게 다음과 같이 나타낼 수 있다.

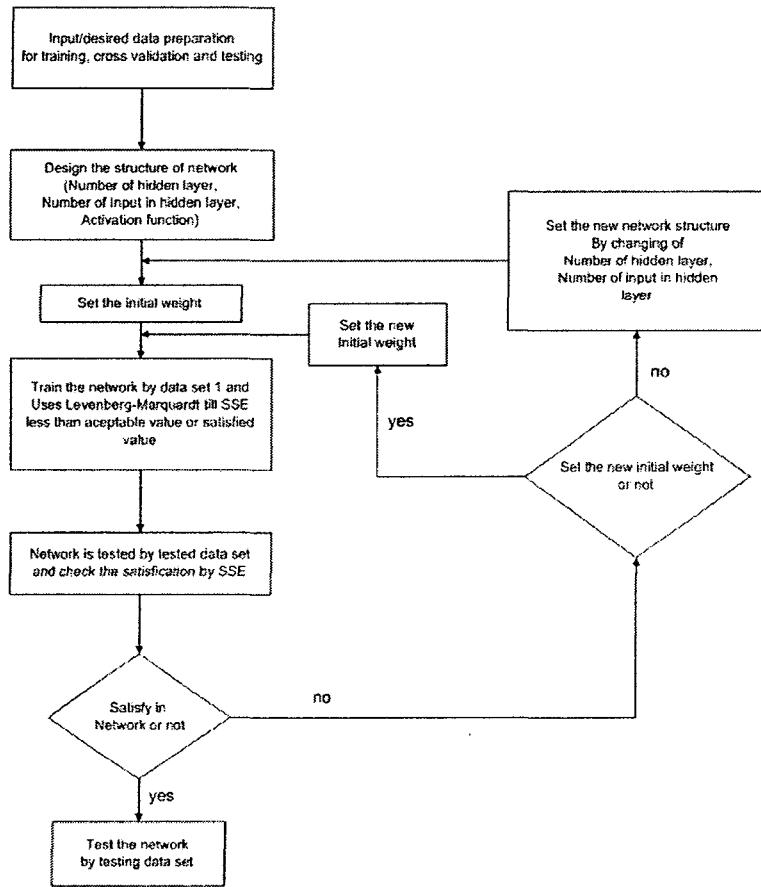


Figure 1. Flowchart of the formulation of neural networks models

$$e(\phi) = d - F(\phi, u) \quad (1)$$

$$J = \frac{e^2}{2} \quad (2)$$

$$\Delta \phi = - (\nabla^2 J(\phi))^{-1} \nabla J(\phi) \quad (3)$$

$\nabla J(\phi)$ : the error gradient of  $J$

식 1에서 함수  $e(\phi)$ 에 테일러 급수를 적용하면, 식 4의 1차 미분항의 jacobian식을 얻을 수 있다.

$$J_s = \begin{bmatrix} \frac{\partial e_1}{\partial \phi_1} & \dots & \frac{\partial e_1}{\partial \phi_B} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_1}{\partial \phi_1} & \dots & \frac{\partial e_1}{\partial \phi_1} \end{bmatrix} \quad (4)$$

$$\Delta \phi = N_\phi = -(J_s^T J_s + uI)^{-1} J_s^T e \quad (5)$$

### 3. Prediction Error Method

PEM은 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 실제 값과의 오차를 최소화하여 adjustable parameter를 계산하는 방법을 말한다.

#### 3.1 ARX\_LS

ARX모델을 간단히 나타내면 식 6과 같이 나타낼 수 있다.

$$A(q)y(t) = B(q)u(t) + e(t) \quad (6)$$

$A(q)y(t)$ : Auto-Regressive,  $B(q)u(t)$ : eXogeneous,  $e(t)$ : Moving Average  
ARX-LS방법의 목적은 parameter  $A$ ,  $B$ 를 조절하여 측정된 공정 출력과 예측된 공정 출력의 오차를 최소화하는 것으로 목적함수를 식 7과 같이 정의하였다.

$$\min_{A, B} V(\theta) = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2 \quad (7)$$

$$\text{이때 } \hat{y}(t) = \varphi^T(t) \theta \quad (8)$$

$\varphi(t)$ 은 regression vector,  $\theta$ 은 adjustable parameter,  $N$ 은 데이터 수를 나타낸다.  
식 7의 최적의 solution은 다음 식 9의 조건을 만족해야 한다.

$$\begin{aligned} \nabla V(\theta) &= -\frac{2}{N} \sum_{t=1}^N (y(t) - \varphi^T(t) \theta) \cdot \varphi(t) \\ &= -\frac{2}{N} \sum_{t=1}^N \varphi(t) \cdot (y(t) - \varphi^T(t) \theta) = 0 \end{aligned} \quad (9)$$

식 7의 solution vector는 식 10이다.

$$\theta_{LS} = \left( \frac{1}{N} \sum_{i=1}^N \varphi(t) \varphi^T(t) \right) \left( \frac{1}{N} \sum_{i=1}^N \varphi(t) y(t) \right) \quad (10)$$

## 4. 모델예측제어

### 4.1 모델예측제어

모델예측제어는 어떤 구간 내의 공정의 미래 출력값을 공정의 동특성 모델을 이용하여 예측하고 예측에 따른 원하는 값과의 오차와 제어입력의 크기에 대한 목적함수를 최소화하는 현재의 입력을 구하는 방법이다.

### 4.2 Dynamic Matrix Control(DMC) 알고리즘

모델에 step변화를 도입하여 공정의 응답을 구한다.

$$y(t) = \sum_{i=0}^{\infty} g_i \Delta u(t-i) \quad (11)$$

horizon에 따른 예측되는 출력은 다음 식으로 표현된다.

$$\begin{aligned} \hat{y}(t+k|t) &= \sum_{i=1}^{\infty} g_i \Delta u(t+k-i) + \hat{n}(t+k|t) \\ &= \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t+k-i) + \hat{n}(t+k|t) \end{aligned} \quad (12)$$

외란이 일정하다고 가정하면

$$\hat{n}(t+k|t) = \hat{n}(t|t) = y_m(t) - \hat{y}(t|t) \quad (13)$$

이를 식 12에 적용하면 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \hat{y}(t+k|t) &= \sum_{i=1}^k g_i \Delta u(t+k-i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t+k-i) + [y_m(t) - \sum_{i=1}^{\infty} g_i \Delta u(t-i)] \\ &= \sum_{i=1}^k g_i \Delta u(t+k-i) + f(t+k) \end{aligned} \quad (14)$$

위에서  $f(t+k)$ 는 시스템의 free response로서 미래의 제어작용과는 무관하다.

$$f(t+k) = y_m(t) + \sum_{i=1}^{\infty} (g_{k+i} - g_i) \Delta u(t-i) \quad (15)$$

공정이 set-point에 접근할수록 안정적으로 수렴하여 N sampling time 후에 일정한 응답 경향을 나타내면  $g_{i+1} - g_i \approx 0 (i > N)$ 이 되고 free response는 다음의 식으로 계산된다.

$$f(t+k) = y_m(t) + \sum_{i=1}^N (g_{k+i} - g_i) \Delta u(t-i) \quad (16)$$

예측 범위 ( $k=1, 2, \dots, p$  일 때)에 따른 출력을 계산하기 위해 m제어작용을 가정하면

$$\begin{aligned} \hat{y}(t+1|t) &= g \Delta u(t) + f(t+1) \\ \hat{y}(t+2|t) &= g \Delta u(t) + g_1 \Delta u(t+1) + f(t+2) \\ &\vdots \qquad \vdots \\ \hat{y}(t+p|t) &= \sum_{i=p-m+1}^p g_i \Delta u(t+p-i) + f(t+p) \end{aligned} \quad (17)$$

Dynamic matrix G는 다음과 같이 정의 된다.

$$G = \begin{bmatrix} g_1 & 0 & \cdots & 0 \\ g_2 & g_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_m & g_{m-1} & \cdots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_p & g_{p-1} & \cdots & g_{p-m+1} \end{bmatrix} \quad (18)$$

이를 이용하면 식 17는 다음과 같이 쓸 수 있다.

$$\hat{y} = Gu + f \quad (19)$$

위에서

$$\underline{u} = [\Delta u(t) \ \Delta u(t+1) \ \cdots \ \Delta u(t+m-1)]^T \quad (20)$$

$$\hat{y} = [\hat{y}(t+1|t) \ \hat{y}(t+2|t) \ \cdots \ \hat{y}(t+p|t)]^T \quad (21)$$

미래의 제어 신호는

$$\Delta u = [\Delta u_1(t), \ \cdots, \ \Delta u_1(t+m_1-1), \ \cdots, \ \Delta u_\nu(t+m_\nu-1)]^T \quad (22)$$

한편 free response는 다음의 식으로 정의된다.

$$f = [f_1(t+1|t), \ \cdots, f_1(t+p_1|t), \ \cdots, f_{ny}(t+1|t), \ \cdots, f_{ny}(t+p_{ny}|t)]^T \quad (23)$$

출력  $i$ 에서의 free response는  $y_i$ 의 과거값과 모든 제어신호의 과거값에 의존하여 계산된다. MIMO공정에 대한 dynamic matrix  $G$ 는 다음과 같이 나타낼 수 있다.

$$G = \begin{bmatrix} G_{11} & G_{12} & \cdots & G_{1\nu} \\ G_{21} & G_{22} & \cdots & G_{2\nu} \\ \vdots & \vdots & \ddots & \vdots \\ G_{ny1} & G_{ny2} & \cdots & G_{ny\nu} \end{bmatrix} \quad (24)$$

각각의  $G_{ij}$ 는  $j$ 에서의 입력에 상응하는  $i$ 의 step응답계수를 포함한다. 모사결과에서 보이겠지만 입력 범위가 제약조건이 없는 최적의 알고리즘을 이용하여도 조업범위 안에서 나오는 결과를 보였다. 따라서 계산상의 부담을 덜고 계산 속도를 위하여 본 연구에서는 제약조건이 없는 최적 입력을 구하였다.

#### 4.3 제어 방법

미래 제어구간은 50, 예측구간은 5로 하였고, 입력가중치는 [1 5 6 7]로 설정하였다. 출력에 대한 각각의 경로는 예측되는 출력과의 오차를 줄이기 위해 다음과 같은 1차 전달함수 형태의 식으로 설정하였다.

$$\text{Basis Weight} = \frac{K_{BW}}{s+1} \quad (25)$$

$$\text{Ash Content} = \frac{K_{ASH}}{1.5s+1} \quad (26)$$

$$\text{Moisture Content} = \frac{K_{Moisture}}{5s+1} \quad (27)$$

$K_{BW}$ : basis weight의 gain

$K_{ASH}$ : ash content의 gain

$K_{Moisture}$ : moisture content의 gain

매 sampling time마다 그 시간에 해당되는 경로가 입력되게 설정하였다.

#### 5. 결과 및 고찰

A사의 공정을 대상공정으로 하여 모사하였다. 지종교체시 평량  $94 \rightarrow 78 (\text{g}/\text{m}^2)$  변화

에 대하여 모사하였다. Fig. 2는 입력의 비교로서 DMC에 의한 모사 결과가 운전데이터 결과와 차이가 있는데 실제 공정에 DMC에 의한 입력값을 적용했을 때 더 나은 결과를 줄 수 있을 것으로 기대할 수 있다. 이 입력값을 이용한 출력의 모사결과를 Fig. 3에 나타내었다. 출력 결과로는 실제 공정보다 빠른 지종 교체 면모를 보였고, 특히 지절의 주요 원인인 종이의 수분량의 변화 있어 실제 공정 데이터보다 안정적으로 진동 없이 set-point에 유지됨을 확인 할 수 있었다. 지종교체도 운전 데이터와 비교했을 때 빠르게 시작되는 것을 알 수 있었다.

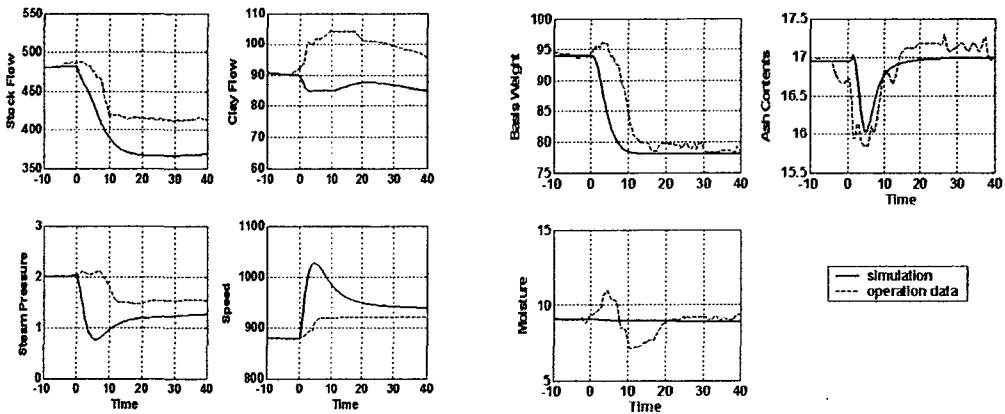


Figure 2. DMC input trend at  $94\text{g}/\text{m}^2 \rightarrow 78\text{g}/\text{m}^2$

Figure 3. DMC output trend at  $94\text{g}/\text{m}^2 \rightarrow 78\text{g}/\text{m}^2$

## 6. 결 론

본 연구에서는 MIMO공정이기 때문에 다변수 공정에 맞도록 DMC 알고리즘을 설정하였으며 제한 조건이 없는 최적화 방법을 이용하여 예측 입력값을 구하였다. DMC를 실제 온라인상으로 공정에 적용하지 않았기 때문에 외란의 요소는 감안 할 수 없었지만 DMC 출력의 경우 운전 데이터보다 빠른 지종교체 변화를 보였고 지종교체 후 정상상태에 도달하는 시간에 많은 차이를 보였다. 모사 결과는 변화의 범위가 작고 신속하게 안정적으로 정상상태에 이르는 것을 알 수 있었다.

## 인용문헌

1. Borari, M.; Wang, H.; Roberts, J. C. Dynamic modeling of a paper making process based on bilinear system modeling and genetic neural networks. UKAACC International conference of control September, 1998, publication No. 455, 1277–1282.
2. 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.
3. Hussain, M.; Kittisupakorn, P. and Daosud, W. "Implementation of Neural-Network-Based Inverse-Model Control Strategies on an Exothermic Reactor". Science Asia, 27: 41–50(2001)
4. Schloff,R.J. Artificial Neural Network. New York: McGraw-Hill.(1997)  
CDC 90, HI, 1990, 596–604