

Neural network을 이용한 OPR예측과 short circulation 동특성 분석
Dynamic analysis of short circulation with OPR prediction used neural network

전준석¹⁾ · 여영구¹⁾ · 박시한²⁾ · 강홍³⁾

1) 한양대학교, 2) 신무림제지 3) j-j컨설팅

ABSTRACT

Identification of dynamics of short circulation during grade change operations in paper mills is very important for the effective plant operation. In the present study a prediction method of One Pass Retention(OPR) is proposed based on the neural network. The present method is used to analyze the dynamics of short circulation during grade change. Properties of the product paper largely depend upon the change in the OPR. In the present study the OPR is predicted from the training of the network by using grade change operation data. The results of the prediction are applied to the modeling equation to give flow rates and consistencies of short circulation.

Key words: Neural network, Short circulation, Dynamic analysis, Grade change, Retention, OPR

1. 서론

제지공정은 입력과 출력이 다수인 다변수 비선형 공정이다. 이러한 공정을 분석하고 정확한 제어를 하기 위해서는 정밀한 모델이 필요하다. 모델을 세우기 위해서는 여러 가지 데이터들이 필요하며 때에 따라서는 측정되지 않는 부분의 데이터가 모델 수립의 관건이 되기도 한다.

본 연구에서는 제지공정의 비선형성을 철저히 분석하여 각 입력 변수와 출력 변수간의 관계를 규명하기 위하여 공정 변수가 농도에 미치는 영향을 연구한 Bo¹⁾와 생산량과 유량등을 연구한 Mardon²⁾의 관점을 바탕으로 wet end의 short circulation의 공정을 silo와 stock으로 나누어 동특성을 분석하였다.

Short circulation 공정의 동특성을 분석하기 위해서는 One Pass Retention(OPR)이 필요하다. 왜냐하면 retention 수치인 OPR에 따라서 wire상의 유량과 농도가 결정되고 이것은 다음 공정인 건조 과정의 제어에 중요한 요소가 되기 때문이다. 그래서 이에 대한 연구로 Piipponen과 Ritala³⁾는 PI제어기에 smith predictor를 추가하여 retention등의 제어를 다루었고 Makonen, Rantanen⁴⁾는 retention을 이용한 제어기법 (PI+smith predictor, IMC, GPC)에 대한 성능을 비교하였다. 그렇지만 OPR의 측정은 전적으로 feedback에 의존하므로 short circulation 공정 이후의 wire상 유량과 농도를 분석하기 위해서는 사전에 OPR을 예측할 수 있어야 한다. 그러나 retention에 관여되는 요소들은 화학적 반응과 물리 흡착 반응에 따른 요소들로서 이 요소들을 아우르는 정확한 모델의 수립은 현실적으로는 어려운 상황이다. 이를 극복하기 위하여 본 연구에서는 neural network 학습을 통한 OPR 예측을 제안 하였다. Neural network은 비선형 공정에 대해서 학습을 통하여 일반화 할 수 있는 특성을 지니고 있으며 [Zurada, 1992]⁵⁾ 우수한 black box 모델을 형성시켜 준다. 이러한 neural network의 학습에서는 neuron이 sigmoid형태의 활성화 함수를 갖고 두 개 이상의 은닉층에 무한히 많은 뉴런을 갖는 경우 모든 비선형 함수를 근사할 수 있음이 확인된 바 있다.[Hornik, 1989]⁶⁾ Neural network 학습에 의해 예측된 OPR을 이용하여 유도된 모델식으로 short circulation 공정 이후의 wire상 동특성 분석이 가능하게 되었다.

2. Neural network 학습 방법

본 연구에서는 neural network 학습 방법으로 backpropagation을 이용하였다. 오류 역전파 알고리즘이라고 불리는 backpropagation은 feedforward multi-layer의 학습에 효과적으로 사용할 수 있어서 다양한 분야에 가장 널리 활용되는 학습 알고리즘이다. 이를 이용한 neural network 학습은 크게 3단계로 진행되는데, 1단계는 학습 패턴

을 입력하여 출력을 구하고 2단계는 출력과 목표치의 오차를 구하며 3단계에서는 오차 값을 역방향으로 전파시키면서 output layer의 weight 및 hidden layer의 weight를 변경시키는 것이다. 이러한 학습 과정에서 오차에 관련된 출력이 역방향으로 전파되며, 학습이 완료되면 입력이 feedforward로 진행되면서 출력이 나오는 feedforward neural network를 나타낸다. 알고리즘에 의한 학습에는 상당한 시간이 소요되기도 하지만 일단 학습이 완료되면 응용 단계에서는 매우 빠르게 결과를 산출할 수 있다.

Backpropagation는 입력 변수가 hidden layer의 입력 수치가 되고 여기서 tansigmoid 전달함수로 계산된 수치는 다음 layer인 output layer의 입력 변수로 된다. 최종적으로는 output layer에서 linear 전달함수를 통해 최종의 output 수치를 유추할 수 있게 되는데 이것이 바로 OPR 수치가 된다. 이러한 학습 효율을 높이기 위하여 tansigmoid 전달함수를 사용하는 hidden layer 2개와 linear 전달함수를 사용하는 output layer 1개를 설정하고 neuron의 개수를 각각 30, 20, 10으로 하여 학습을 진행하였다. 전달함수로 사용한 tansigmoid와 linear 수식은 식 [1]과 식 [2]에 명시된 바와 같다.

Tansigmoid transfer function

$$n = \frac{2}{(1 + e^{(-2n)})} - 1 \quad [1]$$

Linear transfer function

$$purelin(n) = n \quad [2]$$

위의 전달함수를 사용하기 위해서는 Table 1에서와 같은 8가지의 입력 변수와 목적치로 사용되는 OPR의 데이터가 필요하다. 여기서는 제지공장에서 실제로 사용되었던 지중교체간의 실제 데이터를 사용하여 학습을 진행하였으며 그때의 평량(g/m²) 변화는 63→66, 67→57, 47→57, 58→73, 72→51, 52→65, 63→71, 71→78, 77→52, 50→46, 47→51, 51→53, 62→72, 71→61, 61→63, 62→60, 52→48, 48→70, 71→75, 62→76 와 같이 총 20개 set으로 묶었다. 이렇게 해서 만들어진

net을 통해 OPR 모사를 신속 정확하게 할 수 있었고 short circulation 공정 이후의 wire상 유량과 농도도 파악할 수 있었다.

3. Short circulation 분석 방법

Short circulation 분석을 하기 위해서는 정확한 모델식이 필수적으로 필요하다. 하지만 현실적으로 그 모델식을 이용한 데이터 분석은 쉬운 일은 아니다. 왜냐하면 short circulation 공정 이후의 wire상 유량과 농도는 측정 되지 않는 데이터이므로 이의 입력 변수와 출력 변수와의 동특성 분석은 제약이 따를 수 밖에 없기 때문이다. 하지만 short circulation의 retention인 OPR을 유추할 수 있으면 short circulation 공정 이후의 wire상 유량과 농도 분석이 가능하게 된다. Fig. 1는 short circulation의 개략도를 나타내는데 본 연구에서는 short circulation 공정을 두 부분으로 나누어서 분석을 하였다. Fig. 1에서의 G_1 는 neural network 학습을 통하여 OPR을 예측하기 위한 부분이고 G_2 는 G_1 에서 구한 OPR 데이터를 이용하여 short circulation 공정 이후의 wire상 유량(Q_3)과 농도(C_3)를 유추하는 부분이다. 이와 같은 접근법을 사용한 이유는 wire상의 유량(Q_3)과 농도(C_3)를 파악하여 short circulation의 동특성을 파악하기 위함이다. 물론 근본적으로 wire상의 유량(Q_3)과 농도(C_3)를 측정할 수 있는 방법이 있다면 이러한 절차는 필요치 않을 것이다. 하지만 현재의 기술로서는 이것이 불가능하기 때문에 이와 같은 방법을 이용하였다. 현재 제지공정에서는 OPR 데이터를 식 [3]과 같이 백수의 농도와 head box의 농도로 확인하고 있다.

$$R = 1 - \frac{C_1}{C_s} \quad [3]$$

R : OPR(%)

C_1 : 백수의 농도, %

C_s : head box의 농도, %

즉, short circulation을 하나의 계라고 보았을 때 백수의 농도(C_1)와 head box 농도

(C_s)는 입력 변수와 출력 변수 사이에서 유추되어야 할 값이다. 그러므로 OPR 값은 이들에 대한 데이터가 없으면 확인 할 수 없다. OPR을 알 수 없으면 초기의 입력 변수로서 short circulation 공정의 동특성을 분석할 수가 없게 되어 기존의 feedback제어를 통한 공정 운영을 답습하게 된다. Table 1은 short circulation 공정 G_1 부분의 입력 변수와 출력 변수간의 관계를 나타내고 있다. 각 인자들을 제거 하면서 학습 시켜본 결과 OPR에 영향을 미치는 인자로 이들 입력 변수 8개를 선택하였을 경우에 학습 효과가 가장 우수 하였다. 이런 방법으로 유추된 OPR을 이용하여 백수의 농도(C_1)를 유도하면 다음의 식 [4]와 같이 표현 할 수 있는데 이는 식 [3]을 변형하여 나타낸 것이다.

$$C_1 = C_s(1 - OPR) \quad [4]$$

또한 head box의 유량(Q_s)은 DCS 데이터를 통해 식 [5]과 같이 유도할 수 있고 백수의 회수량(Q_2)도 식 [6]와 같이 유도할 수 있다. 그리고 silo의 부피(V)는 일정하게 유지됨을 고려하고 계 밖으로 방출되는 유량(Q_q)은 실시간 측정되지 못하므로 백수의 유량(Q_1)의 0.05%라고 가정하여 나타낼 수 있는데 이렇게 해서 식 [7]와 같이 백수의 유량(Q_1)을 유도할 수도 있다. 여기서 계 외로 방출되는 유량(Q_q)은 실시간으로 측정할 수 없으므로 운전 데이터를 이용하여 가정하였다.

$$Q_s = \text{Jet / wire ratio} \times \text{Pond width} \times \text{Slice lip opening} \times \text{Wire speed} \times 1000 \quad [5]$$

Q_s : head box에서 wire로 나가는 유량, ℓ /min

Jet/wire ratio : 1.04

Pond width : 3.96m

Slice lip opening : 0.0102m

Wire speed : DCS data (m/min)

$$Q_2 = Q_s - (Q_0 \times 1000 + Q_f + Q_r + Q_b)$$

[6]

- Q_2 : 백수의 회수량, ℓ/min
- Q_5 : head box에서 wire로 나가는 유량, ℓ/min
- Q_0 : thick stock 유량, m^3/min
- Q_f : filler 유량, ℓ/min
- Q_r : retention aid 유량, ℓ/min
- Q_b : bentonite 유량, ℓ/min

$$Q_1 = Q_q + Q_2 \quad (\text{where, } Q_q = 0.05Q_1)$$

[7]

Q_q : 계 외로 방출되는 유량 (가정), ℓ/min

4. 결과 및 고찰

Short circulation 분석을 위하여 OPR의 영향에 따른 농도비를 분석한 연구¹⁾와 물질 수지식을 이용한 이론적 분석²⁾에서는 인자들간의 관계를 수학적 모델식으로 표현하여 서로간의 상관관계를 묘사하였으며 농도, ash, OPR 등의 상관관계를 모식화한 연구^{7,8)} 결과도 보고된 바 있다. 이 연구들은 OPR제어의 중요성이 절실함을 확인시켜 주었으나 정작 중요한 OPR 예측에 관한 연구는 아직까지 미비한 실정이다. 이에는 OPR에 영향을 주는 변수가 많기 때문에 그 변화에 맞는 모델식을 유추하기가 어려운 이유가 있겠으나 근래들어 컴퓨터를 이용하여 여러 변수를 고려한 데이터 관계 분석이 가능하게 되었으며, 알고리즘을 이용한 closed loop ID와 neural network 기법 등이 공정의 모델을 분석하는데 효과적으로 이용될 수 있게 되었으므로 OPR 예측 방법의 연구가 가능하게 되었다.

OPR은 제지 성상 과정중의 원료의 유량과 농도, 첨가제의 유량과 농도, 그리고 wire speed 등의 여러 변수들과 관련이 있다. 이들을 고려하여 정밀한 OPR 값을 유추하기 위하여 입력 데이터를 Table 1과 같이 하였고, 이 데이터로 구해진 OPR을 목적값으로

설정하였다. 이는 공장에서 feedback으로 측정된 OPR 제어를 하기 때문에 기존에 측정된 OPR 데이터를 목적치로 한 것이고 이렇게 변수를 설정하여 backpropagation 학습을 진행하였다. 학습 과정은 장시간이 소요되는 단점은 있으나 학습이 완료되고 만들어진 net(일종의 black box model)을 통해 다른 데이터와 OPR의 관계를 바로 확인할 수 있게 되었다.

Fig. 2의 그래프는 평량(g/m_2)이 변화하는 경우의 OPR 수치를 학습한 결과로 net을 만들어 예측한 OPR(적색)을 실제 공정의 operation 데이터(흑색)와 비교한 것이다. 각 그래프에서 확인되는 것처럼 상당히 정밀한 OPR을 예측할 수 있었다. 이렇게 예측된 OPR로 short circulation 공정의 동특성 확인을 위하여 식 [1] ~ [5]를 사용하여 short circulation 공정 후의 wire상 유량과 농도를 모사하였다. Fig. 3는 평량(g/m^2)이 $63 \rightarrow 66$ 으로 변화할 때의 예측된 OPR모사 그래프와 이를 통해 계산된 백수의 농도(C_1)와 short circulation 공정 이후의 wire상 mass flow(Q_3C_3)를 나타내고 있다. 그리고 Fig. 4은 wire상의 유량(Q_3)과 농도(C_3)를 나타내고 있다. 여기서 유량 Q_3 와 농도 C_3 는 실측정이 안되는 부분이다. 하지만 이를 알아야 short circulation의 동특성을 파악할 수 있으므로 예측된 OPR을 이용하여 이들을 계산하게 된 것이다. 이로써 좀더 신뢰성 있는 short circulation의 동특성을 분석할 수 있었다.

5. 결론

Short circulation 동특성을 분석하기 위해서는 short circulation 공정 이후의 유량(Q_3)과 농도(C_3)가 필요 하지만 이것은 측정이 불가능 하기 때문에 정확한 연구 수행 및 분석에 장애가 있었다. 그럼에도 short circulation의 retention인 OPR은 그 수치에 따라 retention aid 양이 조절되고 지질 방지와 제지성상에 중요하므로 OPR을 예측하여 올바른 제어를 수행하고자 본 연구에서는 지종교체간의 측정된 OPR 데이터를 목적값으로 설정하고 입력값으로 8개의 인자들을(Table 1) 선정하여 neural network의 backpropagation 학습을 진행하였다. 학습의 결과로 모사된 OPR은 실측된 수치와 비슷하여 신뢰성을 입증할 수 있었으며 이것에 의한 short circulation 공정 이후의 wire상 유량(Q_3)과 농도(C_3) 유추를 통해 동특성의 변화를 분석할 수 있었다.

인용 문헌

1. Norman, Bo., EUCEPA 1990 Print Paper and Board Products for Printing in the Nineties Conference Proceedings, EUCEPA, Paris, p. 217
2. Mardon, J., Jackson, M. and Serenius, R., *Appita J.*, 25(1): 45 (1971).
3. Piipponen J. and Ritala R., *Control engineering practice*, 3(10):1463 (1995).
4. Makkonen A., Rantanen R., Kaukovirta A., Lieslehto J., Koivo H.N. and Huhtelin T., *Control engineering practice*, 3(10):1471 (1995).
5. Zurada, J. M., *Introduction to artificial neural systems*, PWS Publishing Company, Boston, (1992).
6. Hornik, K., Stinchcombe, M. and White, H., *Multilayer feedforward networks are universal approximators*, *Neural networks*, 2(5):359 (1989).
7. Artama, M., Nokelainen, J., *Paper Technology*, 38(8):33 (1997).
8. Rantala, T., Tarhonen, P., and Koivo, H. N., *Tappi J.*,77(12):125 (1994).

Table. 1. Required variables in the G_1 section

Input (8)	Output (1)
Thick stock flow (m^3/min)	Retention(OPR) (%)
Thick stock ash (%)	
Thick stock consistency (%)	
Filler consistency	
Filler flow rate (l/min)	
Polymer (Retention aid) (l/min)	
Bentonite (l/min)	
Wire speed (m/min)	




Figure. 1 . Schematic of short circuit




Figure. 2 . Results of OPR simulation during grade change operations




Figure. 3 . Changes of consistency and mass flow rates according to the predicted OPR

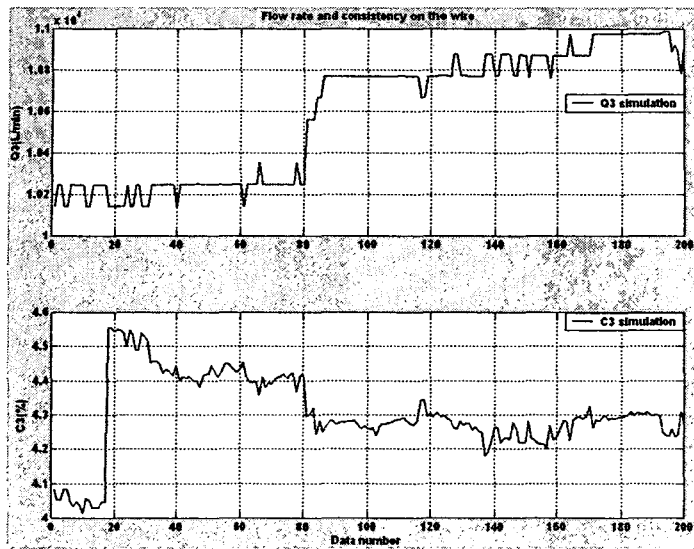


Figure. 4 . Changes of flow rates(Q_3) and consistency(C_3) according to the predicted OPR