

상수처리시스템 응집제 주입공정 퍼지 모델링과 제어 Fuzzy Modeling and Control for Coagulant Dosing Process in Water Purification System

이수범, 남의석*, 우광방*, 이봉국**

*연세대학교 공과대학 전기공학과(Tel:361-2767; Fax:312-7735; E-mail:lsb@auto.yonsei.ac.kr)
** LG 산전(주) 연구소 공정제어 사업 Unit(Tel:0343-50-7658)

Abstracts In the water purification plant, the raw water is promptly purified by injecting chemicals. The amount of chemicals is directly related to water quality such as turbidity, temperature, pH and alkalinity. At present, however, the process of chemical reaction to the turbidity has not been clarified as yet. Since the process of coagulant dosage has no feedback signal, the amount of chemical can not be calculated from water quality data which were sensed from the plant. Accordingly, it has to be judged and determined by Jar-Test data which were made by skilled operators.

In this paper, it is concerned to model and control the coagulant dosing process using jar-test results in order to predict optimum dosage of coagulant, PAC(Polymerized Aluminium Chloride). The considering relations to the reaction of coagulation and flocculation, the five independent variables(turbidity, temperature, pH, Alkalinity of the raw water, PAC feed rate) are selected out and they are put into calculation to develop a neural network model and a fuzzy model for coagulant dosing process in water purification system. These model are utilized to predict optimum coagulant dosage which can minimize the water turbidity in flocculator.

The efficacy of the proposed control schemes was examined by the field test.

Keywords Fuzzy model, Fuzzy C-Means, Clustering, Neural network, Coagulant

1. 서론

을 검증하였다.

상수처리 플랜트의 역할은 양질의 안전한 식수 및 공업용수를 공급하는 것이다. 이러한 원수의 근원은 지하수, 강 또는 호수의 표면수 등이다. 최근에는 표면수가 수원을 보호하기 위하여 주로 사용되고 있다. 표면수는 최근 많은 용도로 사용되고 있으나 다량의 불순물을 포함하고 있어 수질 변화폭이 크다. 응집제는 이러한 불순물을 완전히 또는 효과적으로 처리하기 위해 투입된다. 응집제 투입율은 정수장에 흘러들어오는 원수의 수질변화에 따라 적절히 조절되어야 한다. 그러나 응집제에 의해 불순물을 응집하는 과정은 복잡하고 단지 제한된 항목만이 수질센서로 측정가능하다. 이러한 이유로 현재 동작자의 판단에 의한 응집제 투입방법이 주로 사용되고 있다.

일반적으로, 응집제 투입율은 Jar test의 결과에 기초하거나 또는 조건표에 의하여 숙련된 운전자가 결정한다. 그러나 Jar test의 결과에 기초하는 경우, 그 효과는 우수하나 급격한 수질변화에 능동적으로 대응하기에는 테스트 시간이 오래 걸리고, 또한 경우에 따라서 Jar-Test를 할 수 있는 인력이 없는 경우도 있다. 조건표를 이용하는 경우, 조건표 자체가 단지 원수의 탁도와 수온만을 고려한다. 따라서 응집제 투입공정은 다른 인자들에 의해서도 영향을 받는 것으로 알려져 있기 때문에 이와같은 방법은 효과적일 수 없다. 이러한 상황에서, 긴 테스트 시간을 요구하지도 않고 효과적으로 응집제 투입공정을 모사할 수 있는 기법이 필요하다.

본 논문은 숙련된 조작자의 경험을 과거의 Jar-Test 결과를 이용하여 신경회로망으로 모사하는 기법과 퍼지모델을 구축하는 방법을 제시하고, 기존의 통계패키지를 이용한 기법과 비교한다.

공정의 신경회로망 모델과 퍼지 모델을 동정하기 위하여 1년 6개월동안의 Jar-Test 데이터를 사용하여 기법의 유용성

2. 상수처리시스템의 응집제 주입공정

본 절에서는 상수처리시스템의 응집제 주입제어의 목적과 실질적인 제어 방법 및 기존의 제어 기법을 설명한다.

상수처리시스템의 정수처리공정이 그림 1.에 나타나 있다. 그림 1.에서와 같이 정수처리공정은 응집, 침전, 여과, 살균소독 처리공정을 거치며, 이 중 약품주입에 의한 응집, 침전 및 살균소독처리는 상수처리시스템에서 가장 핵심부분이다. 상수처리시스템에서 약품주입제어는 응집, 침전을 위한 응집제 주입공정과 살균, 소독을 위한 염소 주입공정으로 구성된다.




그림 1. 상수처리 시스템 개요도

응집제는 그림 1.에서와 같이 착수정에서 투입되며 이는 불순물을 응집시켜 가라앉게 하는 역할을 한다. 이러한 응집제 투입율은 응집, 침전지에서 측정된 탁도가 기준치를 만족시킬 수 있도록 Jar-Test를 이용하여 결정된다.

본 연구에서는 그림 1.의 응집제 주입공정 부분을 Jar-Test결과를 이용하여 모델링 한다.

3. 기존제어 방식과 문제점

기존의 응집제 주입율의 설정 방법은 크게 2가지 이다. 첫째는 Jar-Test에 의한 방법이다. 이것은 샘플 테스트로 5~6개의 비이커에 원수를 넣어 응집제 주입율을 바꾸어 주입하여 탁질의 침전상태를 보는 것이다. 이 중에서 탁질의 제거 상태가 제일 좋은 주입율을 선택하는 방법이다. 이 방법은 매우 정확하나 테스트 시간이 오래 걸리기 때문에 장마철과 같이 원수의 수질이 급격하게 변하는 경우 효과적이지 않다. 또한 테스트시에 바꾸어 넣는 주입율의 선택이 숙련된 Jar-Test 전문가에 의존하기 때문에 전문가가 필요하다. 이와같은 Jar-Test는 그 결과에 전문가의 전문 지식이 포함되어 있다. 따라서 본 연구에는 응집제 주입공정의 신경회로망 모델과 퍼지 모델 구축에 있어서 전문가의 지식이 포함된 Jar-Test 데이터를 이용한다. 둘째는 통계적인 기법을 이용하는 것으로 과거의 실적 데이터로부터 통계적으로 응집제 주입율을 구하는 선형 모델을 만들고 계산기로 계산하여 출력하는 방식이다. 그러나 통계 모델은 수처리 같은 비선형 시스템에는 효과적이지 않다.

본 논문에서는 숙련된 운전자의 지식을 효과적으로 이용하기 위하여 숙련된 운전자의 지식이 내포된 Jar-Test 데이터를 이용하여 응집제 주입공정을 신경회로망 모델 및 퍼지모델을 구축하고, 이 모델로부터 최적의 응집제 주입율을 결정한다.

4. 응집제 주입 공정 모델링과 제어

그림 3은 응집제 주입율의 설정 방법의 흐름을 보여준다.

숙련된 전문가로부터 만들어진 Jar-Test 데이터가 응집제 주입공정의 지능형 모델 구축을 위해 사용된다. 이 Jar-Test 데이터는 숙련된 전문가의 지식을 내포하고 있다. 이 지능형 모델은 주기적으로 Jar-Test 데이터에 의해 학습된다.




그림 2. 응집제 주입율 설정 방법 흐름도

학습된 모델의 파라미터들이 MODEL로 다운로드 되어지고, 이 모델의 출력 트랜드로부터 최적의 응집제 주입율을 찾는다. 원수의 수질 상태를 나타내는 필드 데이터는 10분마다 상위 컴퓨터로 전해진다. 이 필드데이터를 이용하여 현재의 수질 상태에 최적인 응집제 주입율을 모델로부터 결정된다. 이렇게 결정된 응집제 주입율이 필드의 actuator로 전송된다.

4.1 Jar-Test 결과로부터의 데이터 수집

Jar-Test 데이터는 정상상태와 비정상 상태로 크게 2가지로 구분된다. 이러한 데이터 구분의 기준은 원수의 탁도이다. 일반적으로 원수의 탁도가 30 NTU 이상이면 비정상 상태로 간주하고 그 이하이면 정상 상태로 간주한다.

일반적으로 상수처리에서 응집과 침전 반응을 고려할 때, 4개의 독립변수 원수 탁도, 수온, pH, 알칼리도가 응집 반응에 상대적으로 관련도가 큰 것으로 알려져 있다. 따라서 Jar-Test 데이터는 이들 4개의 독립변수들에 대한 정보 및 이에 따른 응집제 효과에 대한 정보를 포함한다. 그러므로 이들 4개의 독립변수를 응집 프로세스에 입력변수로 하여 공정을 모델링하는 것이 필요하다.

4.2 응집제 주입공정의 신경회로망 모델

원수의 수질상태가 정상인 경우와 장마철과 같은 비정상인 경우에 운전자의 제어 행동이 다르기 때문에 응집제 주입 공정 신경회로망 모델도 정상인 경우와 비정상인 경우 2가지로 나누어 구축된다. 각각의 신경회로망은 4개의 입력 뉴런과 12개의 중간 뉴런 및 1개의 출력 뉴런으로 구성된다. 4개의 독립변수인 원수의 탁도, 수온, pH, 알칼리도를 입력 뉴런으로 할당한다. 응집제 주입율은 신경회로망 모델의 출력 뉴런에 할당된다. 그림 4는 응집제 주입공정의 신경회로망 모델을 나타낸다.




그림 3. 응집제 주입 공정의 신경회로망 모델.

신경회로망의 학습을 위해서 Rumelhart[5]등이 제안한 역전파(Back propagation) 알고리즘을 이용한다. 학습 알고리즘은 아래와 같다.

[Hidden to Output Weight]

$$\Delta W_{3k,2j}(t+1) = \alpha \frac{\partial E_{e,3k}}{\partial W_{3k,2j}} + \mu \Delta W_{3k,2j}(t) \quad (1)$$

$$E_{e,3k} = \frac{1}{2} (Y_{3k} - Y_{t,3k})^2 \quad (2)$$

where, $\Delta W_{3k,2j}$: the change of $W_{3k,2j}$

$W_{3k,2j}$: the weight between the k-th hidden and j-th output neuron

Y_{3k} : the value of the k-th output neuron

$Y_{t,3k}$: the training signal of the Y_{3k}

α : learning rate

μ : momentum parameter

[Input to Hidden Weight]

입력층과 중간층 사이의 결합하중도 위와 같은 방법에 의해 갱신된다. 주어진 Jar-Test 데이터를 이용하여, 위의 식에 적당한 학습율과 모멘텀 계수를 설정해 줄으로서 네트워크를 학습시킨다.

4.3 응집제 주입공정의 퍼지 모델

다입력 퍼지 모델의 경우 입력변수의 수가 많아지면 이에 따른 규칙수가 필요이상으로 너무 많아지므로 불필요한 규칙을 제거하고 꼭 필요한 규칙수들을 얻어내기 위하여 Clustering 기법을 이용하여 입력공간을 분할하였다. 본 연구에 사용된 퍼지 C-Means Clustering 기법은 다음과 같다.

데이터 x 에 대한 퍼지 분할 $P = \{A_1, A_2, \dots, A_p\}$ 라 하면 A_i 는 다음을 만족시킨다.

$$\sum_{i=1}^p A_i(x_k) = 1 \text{ and } 0 < \sum_{i=1}^p A_i(x_k) < n \quad (3)$$

그리고 각 클러스터의 중심 v_i 와 목적함수 $J_m(P)$ 는 다음과

같이 계산 된다.

$$v_i = \frac{\sum_{k=1}^n [A_i(x_k)]^m x_k}{\sum_{k=1}^n [A_i(x_k)]^m} \quad (4)$$

$$J_m(P) = \sum_{k=1}^n \sum_{i=1}^m [A_i(x_k)]^m \|x_k - v_i\|^2 \quad (5)$$

위의 식에 의해 조건을 만족시킬때까지 다음을 반복한다.

[Step 1] 초기 분할 P(0)를 설정한다.

[Step 2] 클러스터의 분할 P(t)에 대한 중심을 식(5)에 의해 결정한다.

[Step 3] 다음 과정에 의해 분할 P(t+1)을 결정한다.

if $\|x_k - v_i^{(t)}\|^2 > 0$

$$\text{then } A_i^{(t+1)}(x_k) = \left[\sum_{j=1}^m \left(\frac{\|x_k - v_i^{(t)}\|^2}{\|x_k - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right] \quad (6)$$

if $\|x_k - v_i^{(t)}\|^2 = 0$

then $A_i^{(t+1)}(x_k)$ is nonnegative real number for $i \in I$

$A_i^{(t+1)}(x_k)$ is 0 for $i \in N_c - I$

[Step 4] 만약 $|P(t+1) - P(t)|$ 가 ϵ 보다 작으면 즉 종료조건을 만족하면 종료하고 그렇지 않으면 Step2로 돌아간다.

위의 식을 이용하여 퍼지 분할을 하기 위해서는 클러스터의 수를 정하여 주어야 하는데 본 연구에서는 클러스터의 수를 2개부터 증가시켜 가면서 평가지수가 가장 낮은 클러스터의 개수를 규칙수로 선택하였다. 평가지수는 다음식과 같다.

$$S = \frac{J_m(P)}{n \times \min_{i,j} \|v_i - v_j\|^2} \quad (7)$$

클러스터링에 의해 규칙의 수가 설정되면 이 규칙을 이용하여 모델 동정을 한다. 전진부의 멤버십 함수의 형태는 중심을 클러스터의 중심값으로 하고 폭은 각 클러스터내의 데이터의 표준편차로 결정되는 가우시안 함수로 설정하였다. 그리고 모델의 후진부는 기존의 멤버십함수를 쓰지 않고 신경회로망 모델로 표현하였다. 이를 도식화하면 그림 4와 같다.

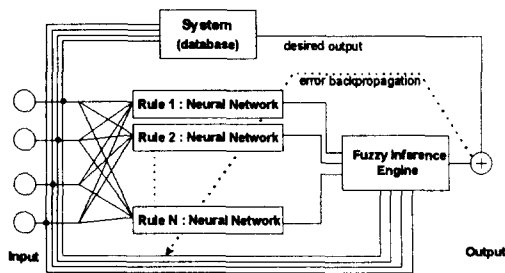


그림 4. 응집제 주입공정의 퍼지 모델

즉 위의 그림에서와 같이 모델은 기존의 퍼지 모델을 이용하고 이를 동정하는데 신경회로망 기법을 이용하였다.

모델의 동정에 규칙수만큼의 신경회로망을 구현함으로써 각각의 규칙에 대한 출력이 정확한 값을 가질수 있도록 하였고 각각의 규칙을 만족시키는 데이터는 비슷한 데이터의 유형을 가지므로 학습속도를 향상시킬수 있다. 신경회로망의 학습방법은 4.2절과 같이 모멘트법을 사용하였다. 하지만 각각의 규칙이 현재의 입력에 대하여 출력에 미치는 영향이 다르므로 각각의 규칙에 대한 적합도를 weight 수정에 고려하여 보정을 행한다. 이를 식으로 나타내면 다음과 같다.

$$\Delta W_{R,3k,2j}(t+1) = w_r \times \alpha \frac{\partial E_{e,3k}}{\partial W_{R,3k,2j}} + w_r \times \mu \Delta W_{R,3k,2j}(t) \quad (8)$$

여기서, w_r 은 각각의 규칙에 대한 적합도를 나타내며 R은 R번째의 규칙을 의미한다.

퍼지 추론부에서는 다음 식에서와 같이 각각의 규칙에 대한 출력값의 무게중심을 이용하여 모델의 출력을 계산한다,

$$y = \frac{\sum_{i=1}^N w_i \times y_i}{\sum_{i=1}^N w_i} \quad (9)$$

where N : number of rules.

w_i : fitness value of i th rule.

y_i : neural network output of i th rule.

여기서, w_i 는 입력의 전진부의 멤버십 함수에 대한 적합도를 의미한다.

5. 시뮬레이션

제안된 기법의 검증을 위해 수도권의 상수처리 플랜트 중의 하나를 모델로하여 테스트를 하였다. 이 플랜트는 하루에 평균 1,320,000톤의 처리능력과 최신의 분산제어시스템을 갖추고 있다. 응집제로는 PAC를 사용하고 있다.


시뮬레이션은 1년 6개월 동안의 데이터에 의해 이루어 졌다. 즉 이 기간동안의 Jar-Test 데이터를 이용하여 응집제 주입공정을 모델링 하고 실제 주입율과 비교 하였다. 제안된 두 가지 모델과 통계적 모델 오차를 표 1.에 나타내었다.

표 1. 모델의 최소 좌승 오차



METHOD		Errors
통계적 모델	Normal	1.079
	Abnormal	3.259
신경회로망 모델	Normal	0.481
	Abnormal	0.709
퍼지 모델	Normal	0.499
	Abnormal	1.513

그림 6.은 실제 주입율과 각 모델로부터 얻어진 주입율을 비교하여 보여준다.



결과에서 볼 수 있듯이 제안된 두 기법이 모두 기존의 통계적 모델보다는 우수한 성능을 보임을 알 수 있다. 이 중 신경



(a) 통계적 기법



(b) 신경회로망 기법



(c) 퍼지 기법

그림 6 실제 주입율과 모델로부터 계산된 주입율

회로망 모델이 가장 정확한 모델링 결과를 나타내었으며 실제로 이 기법은 적용단계에 있다. 퍼지 모델의 경우 정확도는 신경회로망 모델과 비교하여 떨어지지만 동작자에게 구체적으로 모델링 결과에 대한 언어적 정보를 제공할수 있다는 점에서 의미를 찾을 수 있다.

6. 결론

본 연구에서는 숙련된 조작자의 지식이 내포된 Jar-Test 데이터를 이용하여 상수처리시스템의 핵심 공정인 응집제 주입 공정을 모델링 하였고, 이 모델로부터 응집제 주입율을 탐색하는 기법을 제안하였다. 또한 신경회로망 기법은 실제 공정에 적용하여 검증한 결과, 기존의 기법 보다 우수함을 보였다.

제안된 기법은 기존의 여타 연구들과는 달리 모델링 데이터로 필드 데이터를 이용하지 않고 Jar-Test 데이터로 함으로써 숙련된 조작자가 하는 것과 같은 효과를 낼 수 있도록 하였다.

7. 참고문헌

- [1] George J. Klir and Bo Yuan, "Fuzzy Sets and Fuzzy Logic", Prentice-Hall International, Inc., pp. 358-362, 1995
- [2] Baba, K., Enbutsu, I. and Yoda, M. "Intelligent support for water and sewage treatment plants which includes a past history learning function - coagulation

injection guidance system using neuralnet algorithm", Instrumentation, Control and Automation of Water and Wastewater Treatment System, pp. 227-234, 1990.

[3] Yagishita, O., Itoh, O. and Sugeno, M., "Application of fuzzy theory to the control of coaglant injection in a waterpurification plant", System and Control(Japanese), 28(10).

[4] Kim, H.S., Kim, S.H., "The experimental study of prediction optimum dosage of PAC using jar-test results", Journal of Water and Wastewater, vol 2, pp. 39-45, 1993(6).

[5] Rumelhart D.E. et al., "Learning internal representations by error propagation", MIT Press, Parallel Distributed Processing, Vol. 1, pp. 318-362, 1986.