

자기조직형 Fuzzy Neural Network에 의한 응집제 투입률 자동제어

Automatic Control of Coagulant Dosing Rate Using Self-Organizing Fuzzy Neural Network

변 두 균*, 오 석 영

(Doo-Gyoon Byun and Sueg-Young Oh)

Abstract : In this report, a self-organizing fuzzy neural network is proposed to control chemical feeding, which is one of the most important problems in water treatment process. In the case of the learning according to raw water quality, the self-organizing fuzzy neural network, which can be driven by plant operator, is very effective. Simulation results of the proposed method using the data of water treatment plant show good performance. This algorithm is included to chemical feeder, which is composed of PLC, magnetic flow-meter and control valve, so the intelligent control of chemical feeding is realized.

Keywords : coagulant dosing rate, self-organizing fuzzy neural network, water treatment plant

I. 서론

정수처리공정에서는 물속에 존재하고 있는 수없이 많은 콜로이드 입자에 양이온의 응집제를 주입하여 음이온의 콜로이드입자로 고흡물화 하여 제거하는 공정이 선 공정으로 이루어진다. 후속 공정으로는 미세입자를 여과시킨 후에 소독공정을 통하여 음용수로 공급하고 있다.

최근 환경에 대한 국민들의 관심이 고조되고 수질 오염이 심화됨에 따라 맑고 깨끗한 물을 공급하기 위한 정수시스템의 운영기술 및 제어방안의 중요성이 점차 높아지고 있다. 정수장에서 응집제 투입률은 대부분 자 테스트(Jar test)에 의해 수동으로 결정하여 온라인으로 운영되는 수처리 공정과는 별도로 주기적으로 투입률을 설정하여 운영하고 있는 실정이다. 이 방법에 의하면 수질변화에 적극적인 대처가 어렵게 된다. 따라서 본 논문에서는 지능형에 의하여 응집제 투입률을 자동으로 결정하는 방법을 제시하고자 한다.

정수장 유입관내, 착수정 월류부 혹은 혼화지 등에 주입시키고 있는 응집제는 투입 후 후속되는 공정에서 플록형성 상태를 관측할 수 있으므로 피드백 제어가 어려운 문제점을 지니고 있다. 이와 같은 수처리 공정의 특성상 자 테스트에 의해 산출되었던 응집제 투입률과 당시의 수질관련 데이터를 자기조직 형태의 퍼지 신경망으로 학습시킨 후에 이를 이용하여 응집제 투입률을 결정하여 약품을 투입시킨 후, 후속되는 공정에서 처리된 물의 플록상태를 유동전류검출기로 간접적으로 확인하는 방법에 의해서 미량 제어하는 방안이 모색될 수 있다.

퍼지 추론은 대상의 형식모델이 필요하지 않고 언어적

표현으로 제어가 가능하다는 점에서 응용영역이 확대되어 가고 있지만, 운영 근무자들의 오랜 경험을 바탕으로 if-then 형태의 언어 표현만으로 나타내기가 어렵다. 따라서 퍼지 제어기를 설계한 후에도 멤버십 함수의 인자조정은 제어 대상에 대한 정확한 판단을 요구한다.

본 논문은 자 테스트에 의해 채택되었던 응집제 투입률과 측정된 수질인자로부터 자동적으로 퍼지 제어규칙을 생성하고 동시에 전건부 멤버십 함수와 후건부 실수값을 자동적으로 튜닝할 수 있는 신경망구조의 학습형 퍼지 제어기를 구현하여 정수처리공정의 응집제 투입률 자동연산에 적용 가능성을 확인하고자 하였다.

II. Fuzzy Neural Network의 구조

1. 구조

본 연구에서 사용한 퍼지 신경회로망의 구조는 기존의 신경망에서 (1)과 같이 후건부가 실수값으로 표현되는 각각화된 퍼지 추론법을 융합한 것이다.

Rule h

if x_1 is A_{h1} and x_m is A_{hm} , then y is W_h (1)

단, x_i 는 입력변수, y 는 출력변수, A_{hi} 는 x_i 의 전건부 멤버십 함수, W_h 는 h 의 후건부 실수값을 의미한다. 전건부 멤버십 함수는 그림 1과 같이 양쪽을 두 개로 분할하여 정점을 a_{ki} 로 하여 음의 방향폭 β_{ki} , 양의 방향폭 γ_{ki} 를 파라미터로 하는 3각형 형태이며, 입력값에 대한 언어변수가 K개의 경우 각 파라미터 함수 $A_{hi}(x_{ki})$ 는 (2)와 같이 나타낼 수 있다.

$k = 1 ;$

* 책임저자(Corresponding Author)

논문접수 : 2004. 9. 25., 채택확정 : 2004. 10. 13.

변두균, 오석영 : 한국수자원공사 IT사업처

(dgbyun@kowaco.or.kr/ohs@kowaco.or.kr)




그림 1. 퍼지 멤버십 함수.
Fig. 1. Fuzzy membership function.

$$A_{ki}(x_i) \begin{cases} 1; & x_i \leq a_{ki} \\ d_{ki}x_i + c_{ki}; & a_{ki} \leq x_i \leq a_{ki} + \gamma_{ki} \\ 0; & a_{ki} + \gamma_{ki} \leq x_i \end{cases}$$

$$k = 2, \dots, K_i - 1;$$

$$A_{ki}(x_i) \begin{cases} b_{ki}x_i + a_{ki}; & a_{ki} - \beta_{ki} \leq x_i \leq a_{ki} \\ d_{ki}x_i + c_{ki}; & a_{ki} \leq x_i \leq a_{ki} + \gamma_{ki} \\ 0; & x_i \leq a_{ki} - \beta_{ki}, \quad a_{ki} + \gamma_{ki} \leq x_i \end{cases} \quad (2)$$

$$k = K_i;$$

$$A_{ki}(x_i) \begin{cases} 1; & a_{ki} \leq x_i \\ b_{ki}x_i + a_{ki}; & a_{ki} - \beta_{ki} \leq x_i \leq a_{ki} \\ 0; & x_i \leq a_{ki} - \beta_{ki} \end{cases}$$

다만, $k(=1, \dots, K_i)$ 는 멤버십 함수의 기호, K_i 는 입력 x_i 에 대해 사용된 멤버십 함수의 전체수이다. 여기서 $a_{ki}, b_{ki}, c_{ki}, d_{ki}$ 는 (3)과 같다.

$$\begin{aligned} a_{ki} &= -\frac{a_{ki} - \beta_{ki}}{\beta_{ki}}, & b_{ki} &= \frac{1}{\beta_{ki}} \\ c_{ki} &= \frac{a_{ki} + \gamma_{ki}}{\gamma_{ki}}, & d_{ki} &= -\frac{1}{\gamma_{ki}} \end{aligned} \quad (3)$$

이때 전건부 적합도와 간략화된 퍼지 추론에 의한 추론결과는 (4)와 (5)로 나타낼 수 있다.

$$\mu_h = \prod_{i=1}^m A_{hi}(x_i) \quad (4)$$

$$y^* = \frac{\sum_{h=1}^H \mu_h w_h}{\sum_{h=1}^H \mu_h} \quad (5)$$

1항에서 나타낸 바와 같이 간략화된 퍼지 추론의 과정을 신경망으로 표현하면 그림 2와 같이 나타낼 수 있다. 그림에서는 2입력 1출력의 경우에 한하여 나타낸 것이다. 제 1중간층에서는 (2)에 기초하여 $A_{hi}(x_i)$ 가 계산된다. 각각의 멤버십 함수의 형태는 입력층과 제 1중간층간의 링크하중인 (3)의 $a_{ki}, b_{ki}, c_{ki}, d_{ki}$ 에 의해서 결정된다.

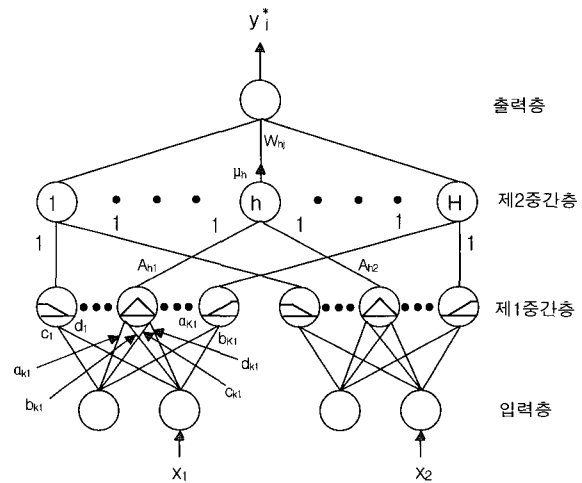


그림 2. 퍼지 신경망.
Fig. 2. Fuzzy neural network.

한편, 제 2중간층의 각 유니트에서는 제 1중간층의 유니트와의 링크관계에 의해 표현된 각 추론 규칙의 전건부 적합도 μ_h 가 (4)에 의해서 계산되고, 출력층에서는 (5)에 의한 추론치 y_j 가 계산된다.

본 논문에서의 네트워크에서는 제 2중간층과 출력층간의 링크하중인 후건부 실수값 w_{hj} 및 입력층과 제 1중간층간의 링크하중인 $a_{ki}, b_{ki}, c_{ki}, d_{ki}$ 의 학습을 수행한다.

2. 학습법

지능형 응집제 투입 시스템의 응집제 투입을 결정은 과거의 수질데이터를 퍼지 신경망으로 학습하여 응집제 투입 결정용 퍼지 규칙을 생성시킨 후, 이 규칙과 원수의 수질 데이터를 이용하여 응집제 투입률을 실시간으로 결정할 수 있도록 하였다.

본 논문에 사용된 퍼지 신경망의 추론모델은 간략화된 퍼지 추론법(simplified fuzzy inference method)을 이용하였고 삼각형 형태의 전건부 멤버십 함수를 사용하였다.

FNN의 학습법으로서는 일반적인 최급강하법을 이용하며 1조의 입출력 데이터($x_1, x_2, \dots, x_m; y$)에 대해 (6)과 같이 p번째의 입출력 데이터에 대한 네트워크의 출력 자승오차 E_p 를 평가함수로 하고 (6), (7), (8)을 사용하여 전건부 멤버십 함수의 파라메타인 ($a_{ki}, b_{ki}, c_{ki}, d_{ki}$)와 후건부 실수값(w_k)을 변경시킨다.

$$\begin{aligned} E_p &= \frac{1}{2} \sum_{j=1}^n (y_j^p - y_j^*)^2 \\ E &= \sum_{p=1}^m E_p \end{aligned} \quad (6)$$

여기에서 n 은 출력변수의 개수, m 은 입출력조의 개수, y^p 는 출력데이터, y^* 는 추론데이터를 의미한다.

$$\frac{\partial E_p}{\partial a_{ki}} = \frac{\partial E_p}{\partial c_{ki}} =$$




그림 3. 퍼지신경망 모델.
Fig. 3. Fuzzy neural network model.

$$\begin{aligned}
 & -(y^p - y^*)(w_h - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h} \frac{1}{A_{hi}(x_i)} \\
 \frac{\partial E_p}{\partial b_{ki}} &= \frac{\partial E_p}{\partial d_{ki}} = \\
 & -(y^p - y^*)(w_h - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h} \frac{1}{A_{hi}(x_i)} x_i \quad (7) \\
 \frac{\partial E_p}{\partial w_{hi}} &= -(y^p - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h}
 \end{aligned}$$

학습계수 $a_{ki}, b_{ki}, c_{ki}, d_{ki}$ 에서 각 파라메타의 학습계수 a_{ki} 와 c_{ki} 를 공통으로 하고, b_{ki} 와 d_{ki} 를 공통으로 하며 입력층과 중간층간의 학습률 (K_{ac}, K_{bd})과 중간층과 출력층간의 학습률(K_w)로 하면 학습식은 다음식과 같다.

$$\begin{aligned}
 a_{ki}(s+1) &= a_{ki}(s) - K_{ac} \cdot \frac{\partial E_p}{\partial a_{ki}} \\
 b_{ki}(s+1) &= b_{ki}(s) - K_{bd} \cdot \frac{\partial E_p}{\partial b_{ki}} \quad (8) \\
 w_h(s+1) &= w_h(s) - K_w \cdot \frac{\partial E_p}{\partial w_h}
 \end{aligned}$$

그림 3은 탁도, 수온, 알칼리도, pH, 전기전도도를 입력으로 하고 약품 투입률을 출력으로 한 FNN 모델이다.

입력층의 변수는 학습용 데이터의 최소치 및 최대치를 인식하여 정규화된 상태로 입력된다. 제1중간층에서는 결합하중($a_{ki}, b_{ki}, c_{ki}, d_{ki}$)에 의해 멤버십 함수의 형태가 결정되며, 제2중간층에서는 최소 연산에 의해 전건부 적합도를 계산한다. 출력층에서는 제2중간층의 출력과 결합하중(w_h)에 의해 추론치 (y^*)가 계산된다.

이상의 내용을 기본으로 하여 학습시의 신뢰성과 효율성을 증진시키기 위하여 자기조직형 퍼지 신경망을 구축하여 몇 가지 인자들을 스스로 탐색, 조절할 수 있도록 구성하였다.

III. 자기조직형 Fuzzy Neural Network에 의한 학습

퍼지신경망[2][3][4]에 사용한 응집제 제어설비를 현장에




그림 4. 퍼지 신경망의 퍼지제어.
Fig. 4. Fuzzy control of fuzzy neural network.

적용하기 위해서는 학습률 설정, 전건부 멤버십 함수와 후건부 실수 값의 초기설정, 학습상태의 중단시기결정 등의 어려움을 지니고 있다.

이러한 문제점을 보완함으로써 정수장 내 유입원수수질 관련 입출력 데이터로부터 정수장 운영근무자들의 용이한 사용을 위해서는 학습률 K_w, K_{bd} 과 중간층과 출력층간의 학습률 K_w 가 자동 설정되도록 하는 학습률의 동적인 제어 기능을 부여함과 동시에 퍼지 C 평균(Fuzzy C mean) 알고리즘의 적용으로 전건부 멤버십 함수의 초기설정이 가능한 자기조직형의 퍼지신경망의 개발이 요구된다.

1. 학습률의 동적제어

학습률은 입력층과 중간층 및 중간층과 출력층 사이의 결합하중의 변화속도를 결정하는 것으로 그 크기에 따라 학습의 상태가 크게 차이가 난다[5]. 일반적으로 학습률이 크면 수렴속도는 빠르지만 진동발생이 쉽고, 학습률이 작으면 그 반대의 현상이 일어난다. 그러나 국부적인 진동이외에 전체적인 학습안정도를 보증하기 위해서는 K_w 는 크게 설정하고 관성항을 생략하는 편이 유리하다.

삼각형 멤버십 함수와 간략화된 퍼지 추론을 사용하는 퍼지 신경망의 경우 K_w 는 $10^{-2} \sim 1$ 정도, K_{ac}, K_{bd} 는 10^{-3} 이하의 범위에서 적절한 학습이 이루어지는 것이 일반적이다. 앞에서 언급한 것처럼 본 논문에서는 원활한 학습을 위해 후건부 실수값의 변화에 관련된 학습률 K_w 만을 조정하도록 하였고, K_{ac}, K_{bd} 는 $10E-6$ 의 정도의 작은 값으로 고정하며 관성항(momentum term)은 생략하여 학습의 안정성을 기하였다. 가중치의 변화는 (9)에 의해 이루어진다.

$$\Delta w_h(s+1) = -K_w \nabla E(w_h(s)) \quad (9)$$

(9)의 K_w 를 동적으로 변화시키기 위해 그림 4와 같이 퍼지 신경망 전단에 별도의 퍼지 제어기를 설치하였다.

퍼지 제어의 입력변수는 (10)으로 표현되는 E의 변화율인 CE와 CE의 변화율인 CCE로 하였고 출력변수는 K_w 의 변화율로 하였다.

$$\begin{aligned}
 E_p &= \frac{1}{2} \sum_{j=1}^n (y_j^p - y_j^*)^2 \\
 E &= \sum_{p=1}^m E_p \quad (10)
 \end{aligned}$$

$$\begin{aligned}
 CE(n) &= E(n) - E(n-1) \\
 CCE(n) &= CE(n) - CE(n-1)
 \end{aligned}$$

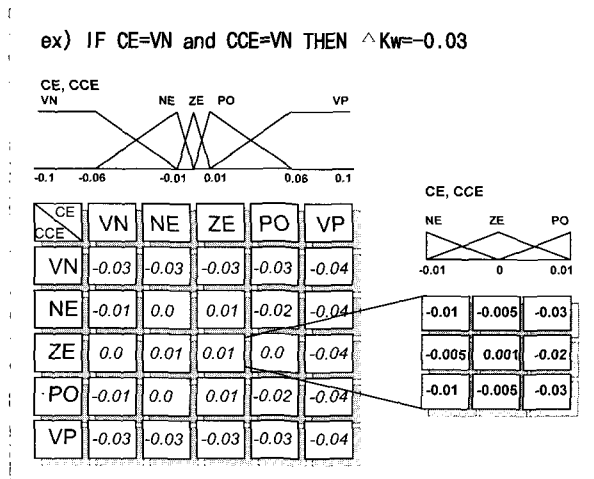


그림 5. 퍼지 규칙.
Fig. 5. Nested fuzzy rule.

Algorithm FCM

step 1 : select cluster number(c),
exponential weight(m)
choose an initial partition matrix($U^{(0)}$),
a termination criterion(ϵ)

step 2 : calculate fuzzy cluster center(v_i^l)
by using $U^{(0)}$ and eq.(10)

step 3 : calculate new partition matrix $U^{(l+1)}$
by using v_i^l and eq.(11)

step 4 : calculate $\Delta = \|U^{(l+1)} - U^{(l)}\|$
if $\Delta > \epsilon$ goto step 2
if $\Delta < \epsilon$ stop

END FCM

그림 6. 적용된 퍼지 C 평균 알고리즘.
Fig. 6. Algorithms for fuzzy C-means.

CCE는 학습의 가속상태를 나타내며 그 절대치가 큰 경우 그 사이에 진동이 있음을 예측하는 것이 가능하다. 이상과 같은 학습률을 결정하기 위한 학습률 조정용 퍼지 제어기에 사용된 멤버쉽 함수와 퍼지 규칙을 그림 5에 나타내었다.

2. 전건부 멤버쉽 함수의 초기설정

데이터의 집합은 데이터의 구조에 따라서 몇 개의 그룹으로 분리할 수 있으며 소속 정도를 다르게 함으로서 2개 이상의 소속에 속할 수도 있다. 퍼지 클러스터링은 1개의 데이터가 2개 이상의 클러스터에 속할 수 있기 때문에 각각의 소속정도를 그림 6과 같은 알고리즘을 지닌 fuzzy C-means를 사용하였다.

Fuzzy C-means와 학습률의 동적제어를 통하여 얻어진 자료를 기준으로 퍼지 신경망으로 학습 시킨 후에 학습된 내용을 기준으로 현장 내 상부 계측제어의 EWS에 입력시킨 후에 정수장으로 유입되는 5개의 수질인자들로부터 주기적인 간격으로 응집제 투입률을 결정하는 것이 가능하게 된다.

IV. 수처리공정

수처리 공정은 착수정, 혼화지, 응집지, 침전지, 여과지, 정수지로 크게 나눌 수 있으며 이중에서도 혼화지, 응집지, 침전지는 원수에 적당량의 응집제를 넣은 후에 혼화시키고 이때 형성된 미세한 플록을 점차 큰 플록으로 성장시키는 응집공정을 거쳐서 플록이 중력가속도에 의해서 가라앉도록 하는 침전공정을 거쳐서 슬러지의 형태로 침전지에서 제거하고 있다. 이들 수처리 공정을 그림 7에 나타내었다.

1. 응집원리

수중의 불순물 중 $1 \mu m$ 로부터 $1 nm$ 정도 크기의 콜로이드 성분을 그대로 직접 처리하는 일반적인 방법은 없다. 수중에 있는 콜로이드는 그 표면에 전하를 띠고 있다. 전술한 자연수중에서 제거해야 할 여러 가지 콜로이드성분은 일반적으로 \ominus 전하를 띠고 있다.

콜로이드입자는 상호의 \ominus 전하 때문에 2개의 입자가 접근하여도 서로 반발하면서 안정된 분산 상태로 수중에 존재하게 된다. 콜로이드의 안정 상태를 왜해시켜 상호 접촉하고 결합되도록 하는 조작이 응집조작이다. 즉, 콜로이드 입자를 불안정화되도록 행하는 조작이다. 이를 위해 콜로이드 입자가 지니고 있는 전하와 반대의 \oplus 이온의 미립자를 처리대상의 물에 투여한다. 이것을 응집제라고 부르며, 이러한 공정을 혼화공정이라고 한다. 그림 8은 입자와 입자 간에 발생하는 반데르발스의 힘에 의하여 입자 간에 반발하는 상태를 나타내고 있다.

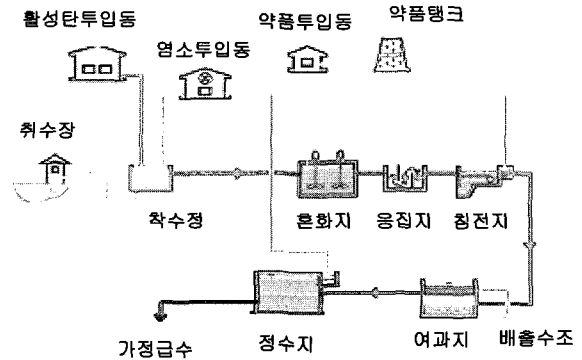


그림 7. 정수처리공정.
Fig. 7. Water treatment process.




그림 8. 콜로이드의 결합영역.
Fig. 8. Bonding range of colloid.

전기적인 반발력을 상실한 콜로이드입자가 일정한 크기로 성장하여 중력에 의하여 가라앉도록 제거 가능한 크기까지 콜로이드를 걸집시키기 위하여 적당한 강도의 기계적인 교반에 의해 입자 상호간의 반복적인 충돌을 유도하고 큰 걸집체로 만들 필요가 있다. 이것을 혼화라고 한다.

2. 응집제 투입률 영향인자

응집제 투입률에 미치는 수질인자는 다양한 형태로 나타낼 수 있다. 일반적으로 탁도, 알카리도, pH, 수온, 전기전도도 등의 5개 인자들이 응집제 투입률에 영향을 미친다. 이들 중에서 영향이 큰 탁도, 알카리도, pH, 수온에 대한 실험 결과를 기술하면 다음과 같다[1][6].

2.1 탁도와 응집제 투입률

응집제 투입률을 결정할 때에 가장 중요한 원수 수질인자는 원수탁도이며, 원수탁도가 증가됨에 따라서 응집제 투입률은 선형적으로 증가되는 경향을 보인다.

2.2 알카리도와 응집제 투입률

응집제 투입률은 원수의 알카리도가 증가함에 따라 증가하는 것으로 나타났으며, 이는 알카리제를 사용할 때에 필요량보다 과량으로 주입하는 경우 응집제도 그만큼 더 많이 소비되므로 알카리제 사용에 보다 세심한 주의를 기울여야 한다. 원수의 알카리도 증가에 따라서 응집제 투입률은 기울기가 급하지 않은 상태로 비례하여 증가되는 것을 알 수 있다.

2.3 pH와 응집제 투입률

응집제를 투입할 때에 수중의 알루미늄 이온은 물의 pH에 따라 수산이온을 매체로 하여 분자량이 큰 각종 중합체를 형성하면서 응집에 관여하므로 응집반응에 있어서 반드시 고려해야할 인자이다. pH 증가에 따라서 응집제 투입률은 거의 일정하거나 약간 상승되는 경향을 나타낸다.

2.4 수온과 응집제 투입률

온도는 물리·화학적 반응에 있어서 매우 중요한 영향인자 중의 하나이다. 수온이 낮을 때는 응집제의 용해도와 가수분해 반응의 화학적 성질을 변화시키며 이로 인해 응집 메카니즘과 응집 최적 pH범위에 영향을 미친다.

저수온 시 액체 황산알루미늄을 사용하여 생성된 플록의 침강속도는 매우 느린 반면 고분자화된 알루미늄 응집제로부터 생성된 응집체는 수온에 상관없이 침강성이 좋다. 원수내 수온의 증가에 따라서 응집제 투입률은 상대적으로 선형적으로 감소되는 경향을 나타낸다. 원수가 저 수온, 저 탁도의 특징을 나타내는 동절기의 경우에는 플록의 성장상태가 다른 계절에 비해 불량하여 침강에 의한 분리 및 제거가 곤란한 경우도 있다.

V. 자기조직형 Fuzzy Neural Network에 의한 응집제 투입률 결정

그림 2에 나타난 퍼지 신경망에 퍼지 제어기에서 결정된 학습률 값과 퍼지 C 평균에 의해서 결정된 초기 멤버십 함수가 입력되면 퍼지 신경망은 미리 학습된 결과에 따라서 약품 투입률을 자동으로 결정하게 된다.

그림 9는 한강 수계에 의치하고 있는 B정수장의 약품투입실적을 나타낸 것이다. 응집제 투입률에 영향을 미치는




그림 9. B 정수장의 수질자료와 응집제 투입률.
Fig. 9. Water quality data & coagulant dosing rate of B water treatment plant.

인자들 중에서 탁도, pH, 알카리도, 수온의 날짜별 변화량과 이때의 수질인자들에 대해서 인력으로 결정된 자 테스트에 의한 응집제 투입률을 각각 나타내고 있다.

그림 9에 나타난 수질자료와 응집제 투입률로부터 응집제 투입률 규칙을 생성한 후 퍼지 신경망으로 학습한 결과 그림 10과 같이 전건부 멤버십 함수와 퍼지 규칙을 생성하였다. 이는 수질에 급격한 변화가 생겨서 이전에 학습된 자료의 활용이 어려워 재학습이 요구되기 이전에는 B정수장의 약품 투입률 예측에 활용될 수 있다.

미리 학습된 퍼지 신경망의 학습결과를 기준으로 하여 실제로 자 테스트에 의하여 결정된 응집제 투입률과 퍼지 신경망에 의하여 예측된 응집제 투입률과의 상관관계를 그림 11에 나타내었다. 그림 11에 나타난 바와 같이 실제로 결정된 투입률과 예측된 결과는 약품의 안전을 고려할 때, 안정화된 시스템으로 볼 수 있다.

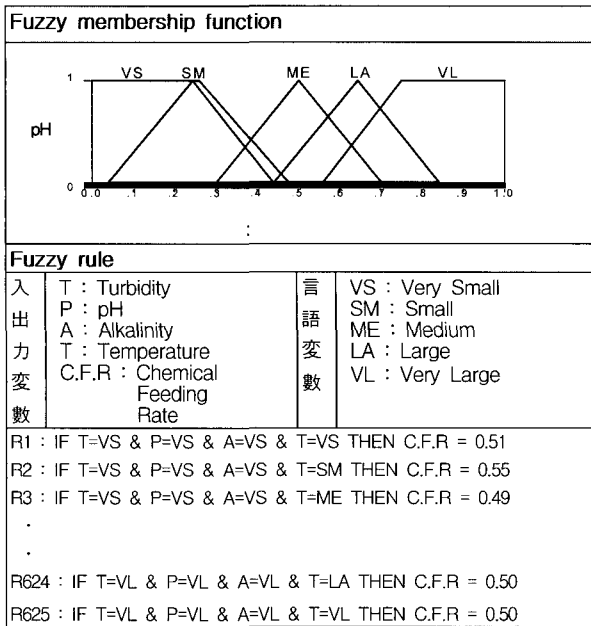


그림 10. 퍼지신경망에 의해 결정된 퍼지규칙.
Fig. 10. Fuzzy rule obtained by FNN.

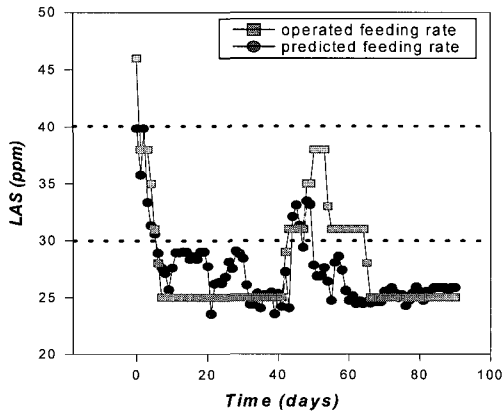


그림 11. 응집제 투입률의 예측.
Fig. 11. Estimation of coagulant feeding rate.




그림 12. 하부설비의 구성도.
Fig. 12. Schematic diagram of facility.

정수장에서 약품투입의 정량성을 확보하기 위해서는 제어용 컴퓨터, 컴퓨터의 신호를 받아 하부설비를 제어하


기 위한 PLC, 전자유량계, 콘트롤 밸브 등으로 구성된 하드웨어를 중심으로 그림 12와 같이 실제로 프로세스에 투입된 응집제 투입량을 전자유량계에서 계측한 후, 이들 값과 퍼지 신경망에서 결정된 응집제 투입률에 정수장으로 유입되는 유입 원수량을 곱하여 얻은 목표 투입량과 비교하여 되먹임제어(feed back control)를 하도록 한다. 또한, 처리된 수질을 SCD에 의한 유동전류 값으로 확인하여 소폭의 미량제어도 가능한 복합제어방식을 고려하는 방안도 함께 추진할 필요가 있다.

VI. 결론

본 연구에서는 자기조직형 퍼지 신경망을 개발하여 퍼지 신경망에서는 구현하기 어려운 학습률의 동적인 조정을 위하여 퍼지 신경망의 전단에 학습률 조정용 퍼지 제어를 설치하여 수속성의 증진과 더불어 안정적인 학습이 가능하도록 하였다. 퍼지 C 평균을 이용한 초기 멤버십 함수의 초기 설정 후에 퍼지 신경망을 통한 미세조정으로 안정적인 학습이 가능하였으며, 비선형의 다변수적인 특성을 지닌 응집제 투입률의 결정에 자기조직형 퍼지 신경망을 적용하여 수질변화에 능동적으로 대처할 수 있게 하였다. PLC와 전자유량계, 콘트롤 밸브로 구성된 약품투입 시스템에 본 알고리즘을 적용하고 이로부터 얻어진 응집제 투입률에 원수 유입량을 곱하여 얻은 목표 응집제 투입량과 유량계에서 계측된 투입량과를 비교하여 되먹임제어를 통한 약품투입 신뢰성을 도모하였다. 처리된 수질은 유동전류값(SCD)으로 검증하고 보정할 수 있는 설비 구성을 통하여 응집제 투입률의 안정적인 제어가 가능할 것이다.


참고문헌

- [1] 김홍석, 김수현, "Jar-Test를 이용한 응집제 주입률 결정에 관한 실험적 연구", 대한상하수도학회, 제2호, pp. 39-46, 6. 1993.
- [2] 오석영, "정수장의 응집제 투입률 자동연산을 위한 신경회로망의 적용" 한국수도협회지, 제22권, 제6호 12. 1996.
- [3] 정우섭, 오석영, "Fuzzy neural network에 의한 응집제 투입률의 자동결정", 한국정밀공학회 논문집, 제14권, 제1호, 1. 1997.
- [4] 하대원, 고택범, 황희수, 우광방, "상수처리 수질제어를 위한 약품주입 자동연산", '한국자동제어 학술회의 논문집, pp. 772-777, 1993.
- [5] S.-Y. OH, J.-H. Kim, "A study on application of neural network to the automatic calculation of chemicals dosing for water treatment process", 10th IWSA-ASPAC Resional Conference, 11. 1996.
- [6] M. Estaben, P. Labat, "Control of an anaerobic digester from the on-line sensors:A fuzzy hier-archical solution", 7th IAWQ Specialist Group on Instrumentation, Control and Automation, 7. 1997.



변 두 균

1955년 8월 14일생. 1977년 광운대학교 전기공학과 졸업. 1991년 광운대학교 전기공학과 공학석사. 2003년 광운대학교 전기공학과 박사과정 수료. 1979년~현재 한국수자원공사 IT 사업처장. 관심분야는 공정자동화.



오 석 영

1959년 10월 2일생. 1986년 한밭대학교 기계공학과 졸업. 1991년 숭실대학교 기계공학과 공학석사. 1996년 숭실대학교 기계공학과 공학박사. 1986년~현재 한국수자원공사 IT사업처 설비기술과장. 관심분야는 수도설비 제어로직 구성.

어로직 구성.