

지능형 응집제 투입 시스템의 개발

Development of Intelligent Coagulant Feeding System

정우섭, 오석영
(Woo Seop Chung, Sueg Young Oh)

Abstract : Coagulant feeding control is very important in the water treatment process. Coagulant feeding is related to the raw water quality such as turbidity, alkalinity, water temperature, pH and so on. However, since the process of chemical reaction has not been clarified so far, coagulant dosing rate has been decided by jar-test. In order to overcome the difficulty mentioned above, Fuzzy Neural Network to fuse fuzzy logic and neural network was proposed, and the scheme was applied to the automatic determination of coagulant dosing rate. This algorithm can automatically identify the if-then rules, tune the membership functions by utilizing expert's experimental data. The proposed scheme is evaluated by computer simulation and interfaced with coagulant feeder operated by magnetic flowmeter, control valve and PLC. It is shown that coagulant feeding according to real time sensing of water quality is very effective.

Keywords : coagulant dosing rate, coagulant feeder, fuzzy neural network, intelligent coagulant feeding system, water quality, water treatment

I. 서론

최근 계속되는 가뭄과 상수원 오염원이 증가함에 따라 먹는 물에 대한 관심이 점점 높아지고 있다. 정수장은 이러한 원수를 취수하여 먹는 물을 생산하는 일종의 공장이며, 그 생산과정에서 가장 중요한 공정 중의 하나가 응집처리이다. 현재 정수과정에 있어서 응집처리를 위한 응집제 투입률 결정은 대부분 자 테스트(jar-test)에 의해 수동으로 정해지고 있으며 응집제의 투입도 대부분 다이아프램식 정량펌프에 의존하고 있는 실정이다. 일종의 모형실험인 자 테스트에 의하여 응집제 투입률을 결정하면 측정에 많은 시간이 소요되어 수질변화에 능동적으로 대처하기 어려우므로 실시간으로 응집제 투입률을 결정하는 방법이 요구된다. 한편 정수처리공정에서는 응집제 투입지점인 혼화지와 탁질제거 효과를 판단할 수 있는 침전지 간에 수시간의 체류시간이 존재하므로 피드백 제어는 쉽지 않다. 이러한 문제점을 해결하기 위해 과거 자 테스트에 의해 운전되었던 응집제 투입률과 수질데이터를 Fuzzy Neural Network로 학습시키고 이때 생성되는 가중값을 이용하여 응집제 투입률을 결정할 수 있도록 하였다.

퍼지추론은 제어에는 적합한 도구이지만, 언어적 형태의 규칙을 만들기 어려운 경우가 많다. 이러한 경우는 시행착오적으로 규칙을 생성하여야 하며, 멤버십함수의 조정도 재어대상에 대한 정확한 고찰을 필요로 한다. 본 연구의 대상인 정수처리에 있어서도, 수계별 수질인자의 성질이 다르므로 각 정수장에서 소장하고 있는 수질 데이터를 학습하여 각 정수장에 적합한 응집제 투입 규칙을 자동적으로 생성할 수 있는 설계수법이 요구되고 있다.

응집제투입장치의 개발에 있어서는 우선 내부식성을 고려하여야 하고 석출에 대비해 부품의 교환 및 보수가 용이하도록 구성하여야 한다. 현재 대부분의 정수장에서는 다이아프램 펌프를 이용하여 약품을 투입하고 있으나 투입량의 정밀도가 떨어지고 정밀도 및 제어기능을 향상시키기 위해서는 장치구성이 복잡해지는 문제점이 있으므로 본 연구에서는 전자유량제, 콘트롤 밸브 및 PLC를 연동시켜 약품투입

하는 계장설비를 개발하였다.

본 연구는 Fuzzy Neural Network에 의한 응집제 투입률 결정 알고리즘과 정량투입이 가능한 응집제 투입장치를 개발하여 정수처리시 응집제 투입공정의 자동화를 추진하고 신뢰성을 향상시키고자 한 것이다.

II. 정수처리

정수처리시설은 원수의 수질이 악화되더라도 먹는 물 수질기준에 적합한 정수를 안전하게 공급할 수 있는 기능을 갖추어야 한다. 우리나라 정수처리방법의 경우 그 처리조건이 비교적 유사하여 그림 1과 같은 일반적인 공정으로 구성되어 있다.

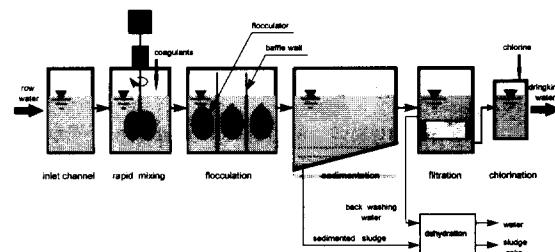


그림 1. 일반적인 정수처리 프로세스.

Fig. 1. General process of water treatment.

그림 1과 같은 정수처리시스템은 크게 혼화, 플럭형성(응집), 침전, 급속여과, 살균의 5가지 기본 프로세스로 구성된다. 혼화지에서는 약품을 주입한 후 급속교반하여 균등히 혼합해주는 역할을 하고, 플럭형성지에서는 완속교반하여 입자 사이의 충돌을 유발하여 플럭을 크게 만드는 역할을 한다. 침전지에서는 약품주입, 혼화 및 플럭형성의 단계를 거쳐 크고 무겁게 성장한 플럭의 대부분을 침전분리작용에 의해 제거하는 역할을 하며 여과지에서는 침전으로 제거되지 않는 미세한 입자를 여과에 의해 제거하게 된다.

이상과 같은 프로세스 중 혼화지와 플럭형성지에서 이루어지는 응집과정은 그 처리과정이 어떻게 이루어지는가에 따라 그 후에 생성되는 플럭의 크기, 밀도, 강도 등의 성질을 좌우하게 되어 침전이나 여과의 효율이 크게 달라진다.

따라서 어떤 조건으로 어떠한 응집제를 주입하느냐는 그 이하의 모든 처리 시스템을 결정하는 기본이 된다.

응집과정에 있어서 주요 제거대상인 콜로이드는 그 표면에 (-)전하를 띠고 있어 2개의 입자가 접근하여도 서로 반발하면서 안정된 분산상태로 존재하며 이와 같은 콜로이드의 안정상태를 와해시켜 상호 결집하도록 하는 조작이 응집조작이다. 이를 위해 (+)이온을 가진 응집제를 처리대상의 물에 투여한 후, 실제 침전지에서 제거가능한 큰 결집체로 만들 필요가 있다. 한편 응집제를 과량으로 투입하여 재안정화 상태가 되면 콜로이드 입자는 다시 상호 반발하게 되며, 침전지에는 탁도물질의 부유현상이 나타나고 처분해야 할 슬러지의 양도 증가하게 된다. 그러므로 적정약품주입이 경제적 운전이나 공정의 효율성 확보에 절대적으로 필요하다.

1. 응집에 영향을 미치는 인자

응집에 영향을 미치는 인자로는 페응집성분의 종류, 응집제의 종류 및 농도, pH, 알칼리도, 온도, 교반조건 등으로 알려져 있으며 각각의 영향에 대해 간단히 살펴보면 다음과 같다.

① 응집제 투입률

원수의 수질에 따라 어느 정도의 폭을 가진 적정 응집제 투입률 범위가 존재한다. 혼화지에서 응집제 투입량이 부족하면 큰 플럭이 형성되지 않을 뿐 아니라 과투입되더라도 응집효과가 악화되는 경우가 많다.

② 탁도

탁하다는 것은 빛의 통과를 방해하거나 가시심도를 제한하는 부유물질을 포함하고 있다는 뜻으로 수질에 있어서 탁도는 여러 가지 부유물질에 의한 물의 혼탁정도를 의미하는 것이다. 탁도가 높으면 응집제의 투입률이 증가하게 되고 반대로 탁도가 너무 낮아도 플럭형성이 어렵게 된다.

③ 수온

수온은 응집제의 수화반응 속도에 직접적으로 영향을 미치는 인자로 수온이 낮은 경우 수산화알루미늄의 생성반응 속도가 느려지고 점성이 커져 전단현상이 발생하게 되므로 다른 조건이 모두 만족되어도 좀처럼 양호한 플럭이 형성되지 않는다.

④ pH

수질을 파악하기 위해서는 탁도, 수온과 같은 물리적 검사 뿐만 아니라 pH, 알칼리도와 같은 화학적 검사가 요구된다. pH는 물의 알칼리성, 중성, 산성의 정도를 표시한 것으로 수소이온농도의 역수를 상용대수로 표시한 값이다. 물의 급격한 pH변화는 오염의 징후이며 아주 높거나 낮으면 응집에 장해를 주게 된다.

⑤ 알칼리도

물의 알칼리도는 산을 중화할 수 있는 능력의 척도로 수중에 수산화물, 탄산염, 중탄산염으로 존재하는 알칼리도를 탄산칼슘(CaCO_3)으로 환산하여 1l중의 mg량으로 나타낸 것이다. 원수 중에 알칼리도가 부족하면 소석회와 같은 알칼리제를 주입하여 알칼리분을 보충해야 하지만 알칼리도가 너무 높으면 이를 조절하기 위하여 응집제를 여분으로 더 투여해야 하므로 비경제적이며, 응집에 적합한 알칼리도는 원수의 탁도가 100도 이하일 때 30~50mg/l 정도이다.

그림 2는 한강수계의 B 정수장에서 측정된 각 수질인자의 년중 변동폭과 경향을 도시한 것으로 탁도와 높은 상관관계를 보이고 있다. 그러나 현재까지 각 인자의 반응과정이 화학적으로 명확히 규명되지 않았기 때문에 다음 절에서 설명하는 자 테스트를 실행하여 응집제 투입률을 결정하고 있다.

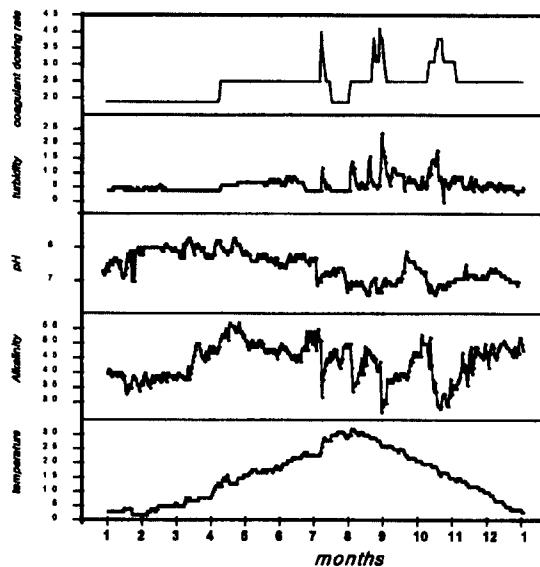


그림 2. 수질인자의 연간 경향.

Fig. 2. Annual trend of water quality parameters.

2. 기존의 응집제 투입률 결정방법

정수처리공정에서 응집제 투입률 결정 및 투입 방법의 최적화는 경제적 운전이나 공정의 효율성 확보에 절대적으로 필요하다. 그러나 적정 응집제 투입량을 이론적으로 결정하는 방법은 현재까지 없으며 「어느 정도의 약품을 어떤 pH영역에서 가하면 되는가」를 실험적으로 결정하는 방법에 의해 투입률을 결정하고 있다. 기존의 응집제 투입률 결정방법은 그림 3처럼 5~6개의 원수를 담은 비이커에 응집제의 비율을 서로 다르게 투입하여 탁질의 침전상태를 측정한 후 탁도가 최소인 응집제 투입율을 선택하여 최적 응집제 투입률로서 결정하는 방식이다. 이러한 자 테스트에 의해 측정된 잔류탁도와 pH를 축으로 그래프를 도시하면 어떤 pH 범위, 어느 정도의 응집제 투입률에서 최소의 응집제량으로 탁질제거가 가능한지를 명확하게 확인할 수 있으며, 선정된 응집제 투입률과 유량계에 의해 측정된 원수유량에 의해 응집제 투입량이 결정된다.

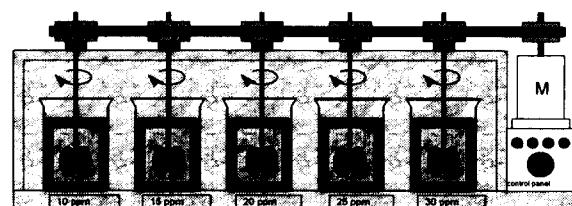


그림 3. 자 테스트 장치.

Fig. 3. Jar test instrument.

III. Fuzzy neural network에 의한 응집제 투입률의 결정

1. FNN의 학습법

최근 지능제어 알고리즘의 연구동향은 주로 Fuzzy logic, Neural Network, Genetic Algorithms, Chaos theory 등의 융합방법에 관심이 집중되고 있다. 본 연구의 지능형 응집제 투입 시스템을 구축하기 위해 퍼지규칙베이스 및 멤버십함수를 자동으로 구성할 수 있는 Fuzzy Neural Network 제어기를 구현하였으며 그 구조는 기존의 신경회로망에 간략화된 퍼지추론법(1)을 융합한 것이다. 전건부 멤버십함수는 그림 4와 같은 삼각형 형태를 사용하였고 언어변수의 각파라미터는 (2)와 같다.

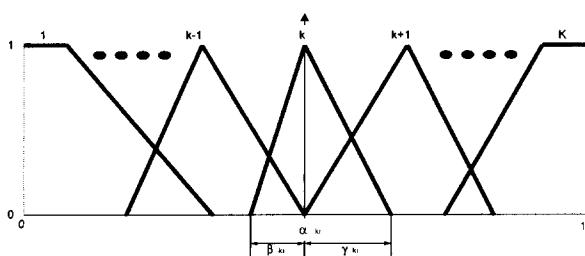


그림 4. 멤버십 함수.

Fig. 4. Membership function.

Rule k IF x_1 is A_{k1} and ... x_m is A_{km} THEN y is W_k (1)

$$k = 1 \quad (2)$$

$$\begin{aligned} A_{k1}(x_i) &= 1 & : x_i \leq \alpha_{ki} \\ &= d_{ki} \cdot x_i + c_{ki} & : \alpha_{ki} \leq x_i \leq \alpha_{ki} + \gamma_{ki} \\ &= 0 & : \alpha_{ki} + \gamma_{ki} \leq x_i \end{aligned}$$

$$k = 2, 3, \dots, K-1$$

$$\begin{aligned} A_{k1}(x_i) &= 0: \alpha_{ki} - \beta_{ki} \geq x_i \\ &= b_{ki} \cdot x_i + a_{ki} & : \alpha_{ki} - \beta_{ki} \leq x_i \leq \alpha_{ki} \\ &= d_{ki} \cdot x_i + c_{ki} & : \alpha_{ki} \leq x_i \leq \alpha_{ki} + \gamma_{ki} \\ &= 0 & : \alpha_{ki} + \gamma_{ki} \leq x_i \end{aligned}$$

$$k = K$$

$$\begin{aligned} A_{k1}(x_i) &= 1 & : x_i \geq \alpha_{ki} \\ &= b_{ki} \cdot x_i + a_{ki} & : \alpha_{ki} - \beta_{ki} \leq x_i \leq \alpha_{ki} \\ &= 0 & : \alpha_{ki} + \gamma_{ki} \leq x_i \end{aligned}$$

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

이때 각 추론 규칙의 전건부 적합도와 퍼지역변환의 결과는 (4), (5)처럼 나타난다.

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

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

학습법은 backpropagation을 이용하여, 1조의 입출력 데이터($x_1, \dots, x_m ; y$)에 대해 각 파라미터($a_{ki}, b_{ki}, c_{ki}, d_{ki}, w_h$)를 변경시킨다. 출력자승오차(6)를 평가함수로 하면 학습식은 (8)과 같이 나타난다.

$$E_p = \frac{1}{2} (y^p - y^*)^2 \quad (6)$$

$$\frac{\partial E_p}{\partial a_{ki}} = \frac{\partial E_p}{\partial c_{ki}} = -(y^p - y^*) (w_h - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h} \frac{1}{A_{hi}(x_i)} \quad (7)$$

$$\frac{\partial E_p}{\partial b_{ki}} = \frac{\partial E_p}{\partial d_{ki}} = -(y^p - y^*) (w_h - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h} \frac{1}{A_{hi}(x_i)} x_i$$

$$\frac{\partial E_p}{\partial w_h} = -(y^p - y^*) \frac{\mu_h}{\sum_{h=1}^H \mu_h}$$

$$\begin{aligned} a_{ki}(s+1) &= a_{ki}(s) - K_a \cdot \frac{\partial E_p}{\partial a_{ki}} \\ b_{ki}(s+1) &= b_{ki}(s) - K_b \cdot \frac{\partial E_p}{\partial b_{ki}} \\ c_{ki}(s+1) &= c_{ki}(s) - K_c \cdot \frac{\partial E_p}{\partial c_{ki}} \\ d_{ki}(s+1) &= d_{ki}(s) - K_d \cdot \frac{\partial E_p}{\partial d_{ki}} \\ w_h(s+1) &= w_h(s) - K_w \cdot \frac{\partial E_p}{\partial w_h} \end{aligned} \quad (8)$$

학습의 종료는 다음의 조건에 의한다.

$$\frac{1}{N} \sum_{i=1}^N (y_i^* - y_i)^2 \leq \epsilon \quad (9)$$

2. FNN에 의한 과거 수질데이터의 학습

그림 5는 기존 정수장에서 수집되어온 수질 데이터와 테스트에 의해 운전된 응집제 투입률을 학습시킨 후 수질 데이터(원수의 탁도, 수온, pH, 알칼리도, 전기전도도)를 계측하여 응집제 투입률을 실시간으로 제어하는 개략도이다.

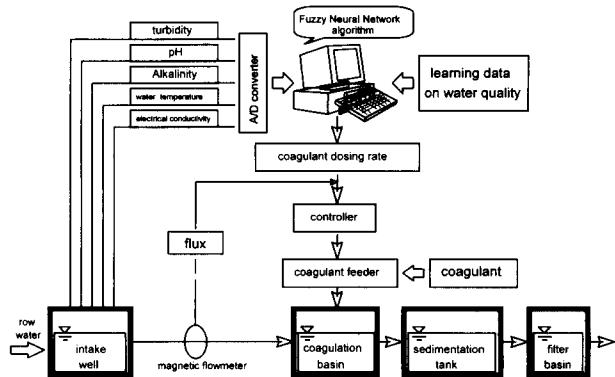


그림 5. 자동 응집제 투입 시스템의 개념도.

Fig. 5. Schmetic diagram of automatic coagulant feeding system.

그림 6은 탁도, 수온, 알칼리도, pH, 전기전도도를 입력으로 하고 응집제 투입률을 출력으로 한 퍼지 신경회로망 모델이며, 이 경우 동정가능한 제어규칙의 수는 $5^5 = 3125$ 개로 된다. 입력층의 변수는 학습용 데이터의 최소값 및 최대값을 인식하여 정규화된 상태로 입력된다. 제1중간층에서는 결합하증 $a_{ki}, b_{ki}, c_{ki}, d_{ki}$ 에 의해 멤버십함수의 형태가 결정되고 제2중간층에서는 min연산에 의해 전건부 적합도가 계산된다. 출력층에서는 제2중간층의 출력과 결합하증 w_h 를 이용하여 추론치(y^*)가 계산된다.

그림 7은 창원수도내의 정수장에서 자 테스트에 의해 결정된 실제 운전투입률과 Fuzzy Neural Network에 의해 선정된 투입률을 비교한 것이다. 학습계수는 $k_a = k_b = k_c = k_d = 0.001, k_w = 0.5$ 로 설정하였을 때 (9)에 의한 학습곡선은 그림 8처럼 우수한 수렴속도를 나타내었고, 상대평균오차(10)에 의해 모델의 정도를 계산한 결과 $E=1.02\%$ 정도로 나타났으며 전체적인 패턴이 실험 데이터와 유사하게 추론되고 있다.

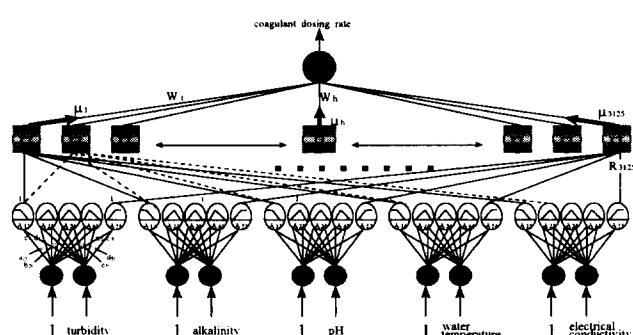


그림 6. 퍼지신경회로망 응용.

Fig. 6. Fuzzy neural network application.

$$E = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - y_i^*|}{y_i} \times 100 (\%) \quad (10)$$

퍼지신경회로망 추론의 우수성을 입증하기 위해 수치데이터를 활용할 수 있는 Multi Regression Model과 Neural Network Model에 의한 비교결과를 그림 9, 그림 10에 나타내었으며, 각 모델의 정도는 5.48% 및 3.93%로 나타났다. 실제 일본의 몇몇 정수장에서는 수계의 특징에 적당한 수질인자를 선정하여 다중회귀방법에 의해 응집제 투입률을 설정하고 있는 예가 있다[1][3].

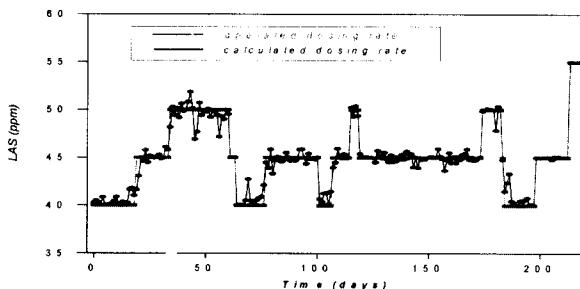


그림 7. 퍼지신경회로망의 결과.

Fig. 7. Result of fuzzy neural network.

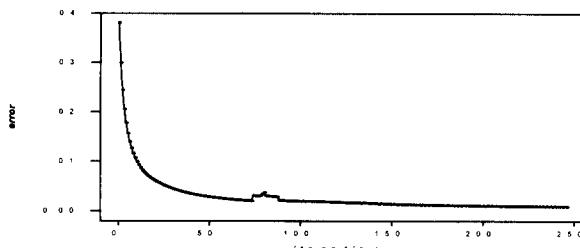


그림 8. 학습곡선.

Fig. 8. Learning curve.

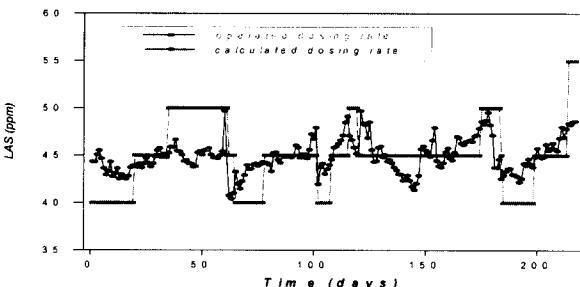


그림 9. 다중회귀모델의 결과.

Fig. 9. Result of multi regression model.

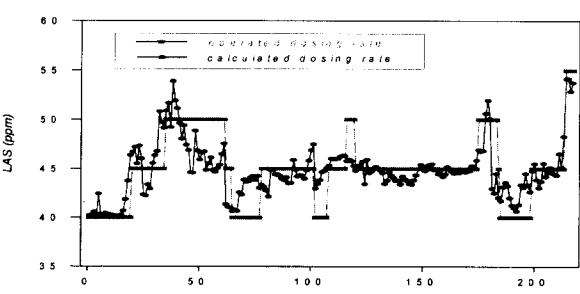


그림 10. 신경회로망의 결과.

Fig. 10. Result of neural network.

3. FNN에 의한 계절별 수질데이터의 학습

전절의 내용은 1년 동안의 수질데이터를 전처리하여 학

습을 실행한 것이지만 응집제 투입률의 추론정도를 더욱 향상시키기 위해서는 계절별로 수년간의 데이터를 취합하여 학습하는 것이 바람직할 것으로 판단된다. 그림 11은 한강수계의 B정수장에서 측정된 1992년 3월-5월의 수질데이터와 1993년 3월-5월의 수질데이터를 취합하여 Fuzzy Neural Network로 응집제 투입률을 추론한 결과이며, 계절별로 데이터를 처리함으로써 학습용 데이터를 일반화할 수 있기 때문에 학습에 사용되지 않았던 데이터에 대해서도 양호하게 추론할 수 있게 된다.

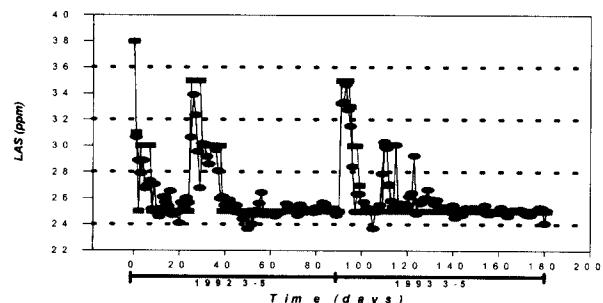


그림 11. 계절별 데이터를 이용한 추론.

Fig. 11. Inference using seasonal data.

이상의 내용은 학습 데이터의 입력을 재이용한 검증이었지만 실제 요구되는 사항은 학습단계에서 사용되지 않았던 데이터에 대해서도 정확한 응집제 투입량을 추론하는 것으로 이하에 앞으로 발생할 수질에 대해 응집제 투입률을 예측하는 방법을 제시한다.

우선 한강수계 B정수장의 경우 탁도, pH, 알칼리도, 수온의 4가지 수질인자가 검출되고 있으므로 이들을 Fuzzy

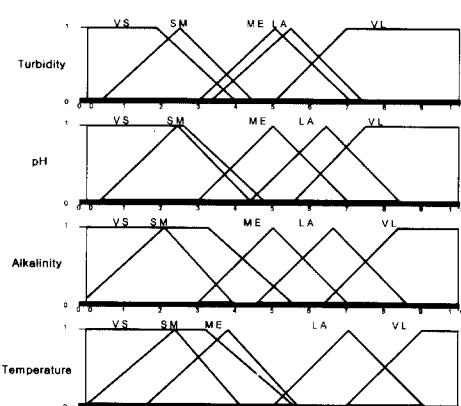


그림 12. FNN에 의해 생성된 멤버십 함수.

Fig. 12. Membership function obtained by FNN.

표 1. FNN에 의해 생성된 퍼지규칙.

Table 1. Fuzzy rule obtained by FNN.

R1 : IF Tur=VS & pH=VS & Alka=VS & Tem=VS THEN C.D.R = 0.5120
R2 : IF Tur=VS & pH=VS & Alka=VS & Tem=SM THEN C.D.R = 0.5490
R3 : IF Tur=VS & pH=VS & Alka=VS & Tem=ME THEN C.D.R = 0.4960
⋮
R624 : IF Tur=VL & pH=VL & Alka=VL & Tem=LA THEN C.D.R = 0.5000
R625 : IF Tur=VL & pH=VL & Alka=VL & Tem=VL THEN C.D.R = 0.5000
Tur→탁도, Alka→알칼리도, Tem→수온, C.D.R.→응집제 투입률

Neural Network의 입력인자로 사용하였고, 1992년 3월-5월의 수질데이터와 1993년 3월-5월의 수질데이터를 취합·학습한 결과로부터 그림 12와 같은 전건부 멤버십 함수와 표 1과 같은 퍼지규칙을 생성한다. 전건부 멤버십 함수와 625개의 퍼지규칙은 수질데이터의 학습

에 의해 스스로 생성된 것이며 앞으로 한강수계의 B정수장에 가장 적합한 제어규칙으로 사용되는 것이다.

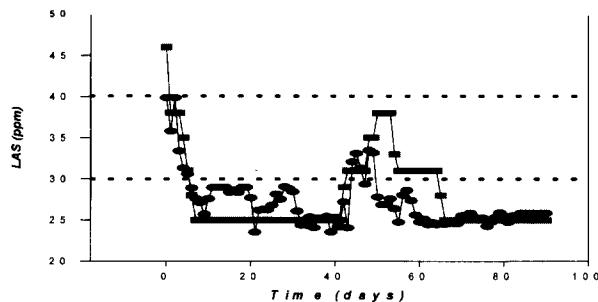


그림 13. 계절별 데이터를 이용한 추론(테스트 데이터의 비교).

Fig. 13. Inference using seasonal data (comparison of test data).

그림 13은 생성된 제어규칙을 바탕으로 미래 데이터(1994년 3월~5월의 한강수계 B정수장 수질 데이터)와 비교한 결과로서 비교적 양호한 응집제 투입률의 예측이 가능함을 보이고 있다. 만일 학습용 데이터로부터 생성된 가중값에 의해 추론한 결과가 테스트 데이터의 실제값과 잘 일치하지 않으면 학습계수를 조정하거나 학습용 데이터의 전처리를 통해 데이터의 일반화를 선행해야 한다. 한편 적절한 학습계수의 설정이 이루어지지 않으면 오차가 발생하거나 진동하게 되어 제대로 학습이 되지 않으므로 경험 또는 시행착오를 통해 최적의 학습계수를 설정할 필요가 있다. 전전부 멤버십함수의 형상은 시스템에 대한 설계자의 의도가 포함되어 있기 때문에 학습후의 형상이 크게 변화하면 전혀 다른 평지규칙이 생성될 가능성이 있다. 즉 전전부 멤버십함수에 관련된 파라메터($a_{ki}, b_{ki}, c_{ki}, d_{ki}$)를 미세하게 조정할 수 있도록 K_a, K_b, K_c, K_d 는 K_w 에 비해 아주 작게 설정하는 것이 효과적이다.

IV. 응집제 투입장치

현재 정수처리시 약품 투입량에 대한 제어는 대부분 다이나프램식 정량펌프에 의해 구현되고 있지만, 이 방법은 모터의 회전속도에 의해 환산된 양과 설정값과의 비교차에 의해 간접적으로 수행되므로 실측량과는 큰 오차를 보인다. 이러한 오차의 보정을 위해 정량펌프의 스트로크를 조정할 수 있으나 원수량이 수시로 변화하는 경우 계속하여 스트로크를 조정하는데는 한계가 있다. 그리하여 본 연구에서는 전자유량계, 콘트롤 밸브 및 PLC를 사용하여 PID 알고리즘으로 제어하는 약품 투입설비를 개발하였다.

정수장의 약품탱크 배관과 약품투입 라인에 응집제 투입장치의 inlet, outlet 파이프만 연결시키면 사용할 수 있도록 패키지화 된 장치로 개발하였고, 그림 14에 나타낸 것처럼 상부에는 응집제 투입률 결정을 위한 PC, PID 알고리즘과 기타설비를 제어하는 PLC가 설치되어 있고 하부에는 그림 15와 같은 전자유량계, 콘트롤 밸브, 펌프, 체크밸브 및 CPVC 파이프 등으로 구성되어 있다.

유량계측은 정밀도 유지를 위해 패러데이 법칙을 응용한 전자식 유량계를 사용하였고, 전폐에서 전개까지의 속응성을 높이기 위해 AC서보모터를 채용한 콘트롤 밸브를 이용하였다. 일반적으로 응집제는 feed line으로 투출되지만, 응집제에 회석수를 섞어 펌프 가압시스템으로 급속분사시킬 수 있도록 구성하였고, 배관은 정기적인 유지관리를 쉽게 하기 위해 플랜지 접속으로 이루어져 있다.

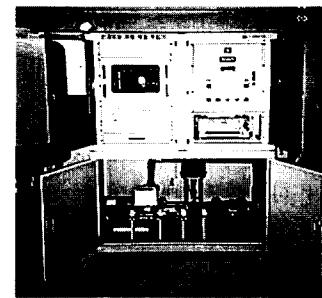


그림 14. 응집제 투입장치.

Fig. 14. Coagulant feeder.

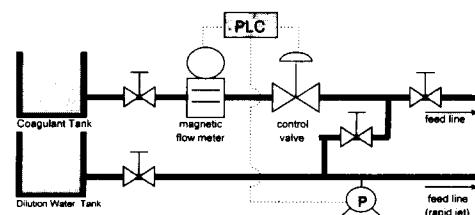


그림 15. 응집제 투입장치의 하부설비.

Fig. 15. The lower equipment of coagulant feeder.

응집제 투입장치의 운영은 데이터 베이스부, 그래프 도시부, 데이터 모니터링, 자료보고 기능 등으로 구성되며 그 구성 및 흐름도를 그림 16 및 그림 17에 나타내었다.

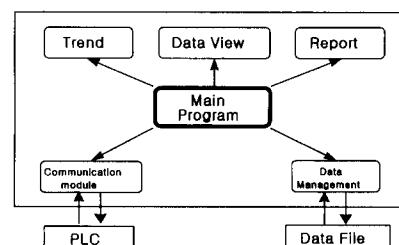


그림 16. 응집제 투입장치의 운영 프로그램.

Fig. 16. Operating program of coagulant feeding system.

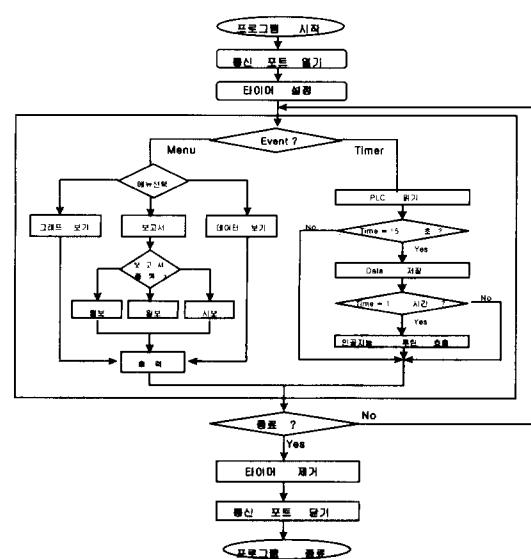


그림 17. 운영 프로그램의 흐름도.

Fig. 17. Flowchart of operating program.

V. 모의실험 및 고찰

원수가 정수장에 유입되어 착수정에 도달하면 펌프에 의해 수질실험실로 일부 이송되어 원수 수질값이 계측된다. 이러한 데이터는 분배기에 의해 중앙제어실 및 약품투입실 등으로 전송되며, 지능형 응집제 투입 시스템도 이 데이터를 받아 응집제 투입률을 결정한 후 원수유량에 비례하여 정량투입을 실현하게 된다. 그림 18은 이상에서 설명한 응집제 투입의 전과정을 나타낸 것으로, Fuzzy Neural Network에 의한 피드포워드 제어를 위주로 응집제 투입률을 결정한 후 침전지의 유출수 타도를 피드백시켜 응집제 투입률을 보정할 수 있도록 하였다. 이러한 복합방식에 의해 제어를 하게 되면 점차 정확한 수질데이터가 축적될 수 있어 응집제 투입률의 결정 능력은 점진적으로 향상될 것이다.

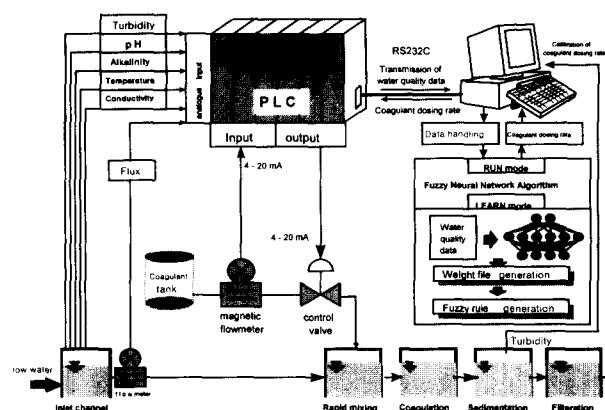


그림 18. 응집제 투입공정의 자동화.

Fig. 18. Automation of coagulant feeding process.

그림 19는 지능형 응집제 투입 시스템에 의해 응집제 투입률의 결정에서부터 정량투입을 실현하는 것을 나타낸 그림이다. 실제상황을 모의실험하기 위해 1995년 12월 26일 대청수도 청주정수장에서 측정되었던 수질값을 이용하였고 타도, pH, 알칼리도, 수온과 같은 수질값은 PLC에서 1995년 12월 26일 대청수도 청주정수장에서 측정되었던 수질과 동일하게 발생시켜 RS232C를 통해 지능형 응집제 투입 시스템으로 전송하였다.

청주정수장에서 당시 자 테스트에 의해 측정·실험된 항목은 표 2와 같다. 자 테스트 결과 결정된 최적투입률은 10ppm이며, PLC로부터 동일 수질을 지능형 응집제 투입 시스템에 전송하였을 때 응집제 투입률은 Fuzzy Neural Network 알고리즘에 의해 10.20ppm으로 정확하게 계산되며 설정된 투입률과 원수량의 적산에 의해 응집제 투입 요구량이 설정된다.

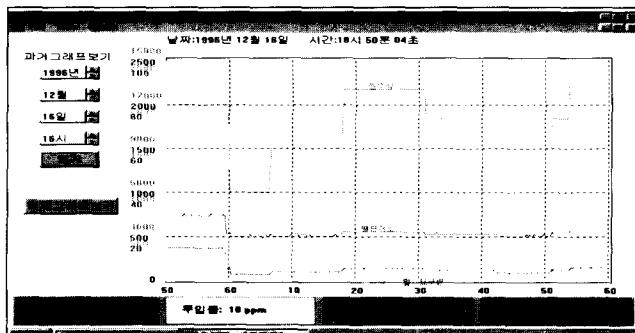


그림 19. 응집제 투입의 제어상태.

Fig. 19. Control situation of coagulant feeding.

그림 19는 수질의 변화 뿐만 아니라 원수량의 변화 ($6,000\text{m}^3/\text{h} \rightarrow 9,000\text{m}^3/\text{h} \rightarrow 13,000\text{m}^3/\text{h} \rightarrow 11,000\text{m}^3/\text{h} \rightarrow 8,000\text{m}^3/\text{h}$)에 따라 응집제 투입량이 자동적으로 조절되고 응집제 투입 요구량과 실제 투입량이 거의 완벽하게 일치하는 정량투입성을 나타내고 있다.

표 2. 수질일지에 기록된 jar-test 결과.

Table 2. Results of jar test recorded in the water quality diary.

날짜	jar - test 성적				
	최적 투입률 Ca(OH) ₂ (mg/l)	PACS (mg/l)	원수 수질	pH	타도 (NTU)
12/26	10	8.1	7.3	1.3	28
		수처리 결과			취수탑
		침전수			원수
		타도 (NTU)	pH	알칼리도 (mg/l)	유입량 (m ³ /d)
		0.6	7.1	25	210,370

정수장으로 유입되는 원수의 수량 및 수질은 시간에 따라 변화하는데 반해, 하루 1회 또는 그 이하로 실시되고 있는 자 테스트에 의해 응집제 투입률을 결정할 경우 수질의 변동에 능동적으로 대처할 수 없는 문제점이 있으므로 운영자의 축적된 경험과 지식을 적극 활용한 본 연구는 수처리 공정의 자동화 및 신뢰성 향상에 기여할 것으로 생각된다.

최근 정수장에서는 중앙감시실에서 현장 데이터를 수집하고 제어하기 위해 DCS(Distributed Control System) 기술을 도입·운영하고 있지만, 외국기술 도입시 소스 코드 등을 제공받지 못함에 따라 상위레벨과 월드기기 간의 연계가 효과적으로 운영하지 못하는 등의 몇 가지 문제점이 지적되고 있다. 본 연구의 결과도 상위레벨과의 통신이 필수적이며, 그림 20과 같이 기존 시스템에 설치 운영할 수 있을 것으로 판단된다. 약품투입실에서 PC와 PLC를 연결한 퍼스컴 계장 시스템으로 분산제어를 실현하고 중앙감시실의 미니 컴퓨터 혹은 마이크로 컴퓨터와의 통신에 Ethernet을 사용하여 주요 데이터를 상호 교환하는 방법이 효과적일 것으로 판단된다. 약품투입실에서는 PCS(Process Control Station)로서 PLC를 사용하고 OCS(Operator Control Station)에 PC를 사용하는 것으로 PLC 래더 등의 작업도 PC를 이용해 직접 사용할 수 있을 것이다.

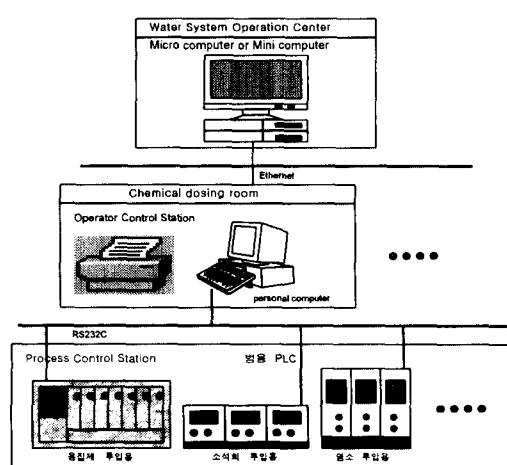


그림 20. 수처리의 분산제어.

Fig. 20. Distributed control of water treatment.

VI. 결론

본 연구에서는 정수처리시 응집제 투입 공정의 자동화를 추진하기 위해 응집제 투입률 자동결정과 정량투입이 가능한 지능형 응집제 투입 시스템을 제안하였으며, 본 연구에서 얻은 결론을 정리하면 다음과 같다.

1. Fuzzy Neural Network를 이용하여 각 정수장에서 소장하고 있는 과거 운전데이터로부터 최적 응집제 투입률 결정 규칙을 자동적으로 생성하여 운전할 수 있다.

2. 과거 수질데이터를 일반화하기 위해 수년동안의 계절별 데이터를 취합하여 학습하는 것이 바람직하며, 이 경우 학습에 사용되지 않았던 데이터에 있어서도 실제 적용 가능한 수준으로 추론가능하였다.

3. 응집제 투입률 결정 알고리즘을 전자유량계, 콘트롤밸브, PLC로 연동되는 응집제 투입장치와 조합하여 지능형 응집제 자동투입장치의 구성이 가능하였다.

이상과 같은 연구는 기존자료의 정확성과 수질계측기의 신뢰도가 선행되어야 하며 취수원의 환경이 변할 경우를 대

비해서 운전데이터들을 계속 누적하여 정기적으로 재학습시킨 후 사용되어야 할 것이다.

참고문헌

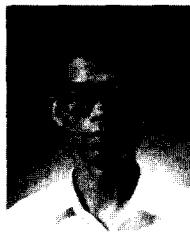
- [1] 정우섭, 오석영, 응집제 투입량 자동결정 시스템 개발 연구, 한국수자원공사 연구보고서, 1996.
- [2] 오석영, 정우섭, 전용약품투입기 개발 연구, 한국수자원공사 연구보고서, 1996.
- [3] Industrial Applications of Fuzzy Control, Elsevier Science Publishing Company, 1985.
- [4] 古橋 武, “ファジイニューラルネットワークの構成法と學習法,” 日本ファジイ學會誌, vol. 4, no. 5, pp. 906-928, 1992.
- [5] Chihipin Huang, Chi Bing Liu, “Automatic control for chemical dosing in laboratory-scale coagulation process by using an optical monitor,” Wat. Res., vol. 30, no. 8, pp. 1924-1929, 1996.

정우섭



1990년 부산대 생산기계공학과 졸업. 동대학원 석사(1992), 동대학 박사(1996). 1996-현재 수자원연구소 선임연구원. 관심분야는 지능제어 및 메카트로닉스.

오석영



1986년 대전공업대 기계공학과 졸업. 충실대학교 대학원 기계공학과 석사 (1991), 동대학 박사(1995). 1991-현재 수자원연구소 선임연구원. 관심분야는 지능제어, 고장진단 및 수처리설비.