

신경망과 유동전류계를 이용한 정수장 응집제 주입제어에 관한 연구

A Study on the Coagulant Dosing Control Based on Neural Network and Streaming Current Detector for Water Treatment Plant

김기평, 김용열, 유준, 강이석

(Gi-Pyeong Kim, Yong-Yeol Kim, Joon Lyou, and E-Sok Kang)

Abstract : Coagulation process is one of the most important processes in water treatment procedures for stable and economical operation, and coagulant dosing of this process for most plants is generally determined by the jar test. However, this method does not only take a long time to analyze and get the result but also has difficulties in applying to automatic control. This paper shows the feasibility of applying neural network to control the coagulant dosing automatically in water treatment plant. To be specific, the predicted results of the neural network model is shown to be similar to that of jar test. The input variables for learning the neural network are turbidity, water temperature, pH, and alkalinity. Combining the neural network and SCD(Streaming Current Detector) for feedforward and feedback control of injecting coagulant, a rapid change of the raw water quality can be accommodated.

Keywords : neural network, SCD(Streaming Current Detector), water treatment, coagulant feeding rate

I. 서론

문화수준이 향상됨에 따라 사람들의 상수도에 관한 인식과 요구는 날로 높아지고 있으며 급격한 산업의 발달로 수원의 부족과 원수의 수질 저하 등 많은 문제를 야기하고 있다. 이러한 문제에 대처하여 안전하고 깨끗한 물을 저렴한 가격으로 풍부하게 공급하기 위하여 체계적이고 효율적인 정수처리기술을 필요로 하고 있다[1].

일반적으로 원수는 많은 양의 탁질을 함유하고 있고 이의 제거를 위해 응집과 침전 및 여과과정을 거친다. 정수처리 공정 중 응집공정은 약품주입과 교반으로 구성되어 탁질의 대부분을 제거하여 정수처리공정의 성패를 좌우한다. 또한 후속되는 정수공정의 안정적인 운전에 대단히 큰 영향을 미치기 때문에 경제적인 면은 물론, 전체 정수장의 신뢰성면에서 볼 때 매우 중요하다. 향후 음용수의 검사항목이나 수질기준이 강화될 것이 예상됨으로 기존 정수장 성능을 향상시키기 위한 효율적인 운영기술의 개발을 필요로 하고 있다.

응집의 효과는 탁질 유발 물질과 이러한 탁질의 종류 및 양, 원수의 수온, 일칼리도, pH 등에 영향을 받는다. 응집제는 이러한 탁질의 효과적 제거를 위해 주입되며 응집제주입률은 정수장으로 유입되는 원수의 수질에 따라 결정된다.

일반적으로 정수장의 응집공정에서 응집제주입률을 결정은 하루에 1회 이상 원수에 대해 정수처리 모의 실험인 자실험(jar test)을 실시하여, 응집제주입량을 선정하고 있다. 자실험은 일정 시간이 소요되는 작업이므로 원수의 수질이 급

변할 때는 즉각적인 조치가 어렵고, 결과가 단속적으로 출력되며, 수동실험이므로 불편하여 응집제주입제어의 자동화를 어렵게 하고 있다.

정수처리공정의 약품주입률 결정에 대한 연구동향은 응집제 주입 직후의 상태를 센서를 이용한 측정으로 체류시간 후의 결과를 예측함으로써 실시간 피드백 제어를 실현하고자하는 방안으로 Bean 등[2]은 응집제주입에 따른 제타 전위값의 변화를, Dental 등[3]은 정수장에서의 유동전류측정기(Streaming Current Detector)에 대해서 기술하였고, 또한 통계적인 방법, 원수 수질에 따른 계산식 산출 및 과거운전자료나 자실험 자료의 학습에 의한 최적주입률 결정 등과 같은 피드포워드 제어를 실현하고자하는 방안으로 우광방 등[4]과 박희경 등[5]은 과거운전자료로 신경망을 학습하여 결과를 운전실적자료와 비교하였고, 김용열, 강이석[6]은 유전알고리즘-퍼지를 이용하여 최적화 퍼지시스템을 구하였고, 결과를 운전주입률과 비교 분석하였다. 정우섭 등[7]은 뉴로-퍼지에 의한 응집제주입률을 구하였다.

본 논문에서는 기존의 제어방식을 근간으로 실제 적용 가능한 방법을 모색하게 되었다.

즉, 정수장 약품 주입 공정의 응집제 자동주입 제어를 위하여 신경망(neural network)을 구성하여 자실험에 의한 과거 정수장 운영 데이터로 학습하고 원수 수질의 변화에 따라 신경망에 의한 응집제주입률을 결정함으로써 피드포워드제어를 실현하고 유동전류측정기(SCD)로 피드백제어를 실시하여 수질의 변동에 적응도록 구상하여 응집제주입공정의 자동화 가능성을 확인하였다.

II. 이론적 고찰

1. 정수시설

정수시설이란 수질기준에 적합한 수돗물을 필요한 양만

* 책임저자(Corresponding Author)

논문접수 : 2004. 1. 16., 채택학정 : 2004. 3. 24.

김기평, 김용열 : 한국수자원공사 수자원교육원

(yukim@kowaco.or.kr/kim503@kowaco.or.kr)

유준 : 충남대학교 전자공학과(jlyou@cnu.ac.kr)

강이석 : 충남대학교 기계설계공학과(eskang@cnu.ac.kr)

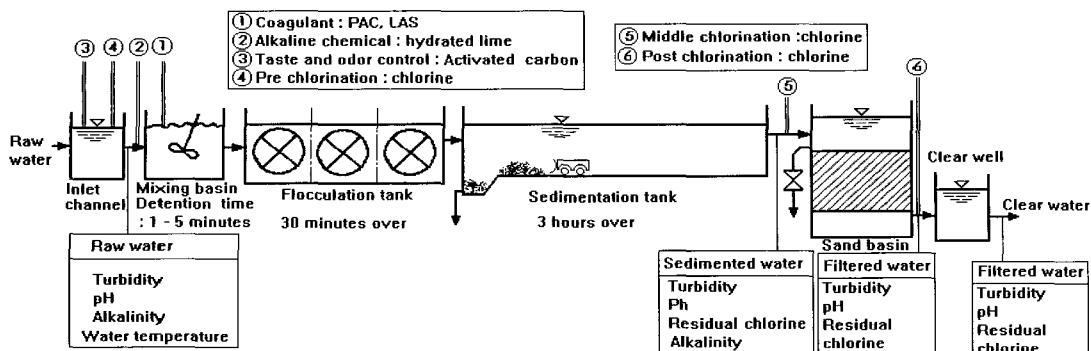


그림 1. 정수처리공정도.

Fig. 1. The schematic diagram of the water treatment process.

큼 생산하기 위한 시설이며 응집, 침전, 여과, 소독 등의 공정이 근간을 이루고 있다. 정수방법에는 크게 간이처리방식, 완속여과방식, 급속여과방식 및 특수처리를 포함한 방식의 4가지로 구별할 수 있으나 우리나라에서 가장 보편적으로 운영되고 있는 방식은 급속여과 방식이다. 급속여과 시설에는 착수정, 약품저장 및 투입설비, 약품 혼화지, 풀록 형성지, 침전지, 여과지, 소독설비 및 배출수 처리설비로 구성되어 있다[8]. 이들 공정들의 상호연계성은 그림 1에 표시하였다.

2. 유동전류계

유동전류(SC : streaming current)는 수중의 입자표면에 형성된 전기적 이중층 중 분산층을 기계적, 순간적으로 파괴하여 분산층내에 전기적 인력에 의해 이온들을 분리시켜 분산층 밖의 평형상태에 있는 배경용액과의 이온농도 차에 의해 발생하는 전류를 의미하며, 이 전류를 측정하는 기기가 유동전류측정기이다.

SCD는 센서와 신호처리부분으로 구성되어 있으며, 그림 2는 SCD 센서부의 단면을 나타내는 그림으로서, 그 측정원리는 상하왕복운동을 하는 작은 피스톤을 가진 챔버 안으로 일정량의 샘플의 물(1.0~3.0 ℓ/min)이 통과하면서, 물 속에 전기적으로 전하를 띠는 입자들에 의해 전류가 발생하게 되는데, 이러한 전류를 띠는 입자들이 순간적으로 피스톤에 달라붙게 되어 전극(electrodes)에 의해 측정되는 원리이다. SC는 제타전위(zeta potential)와 같이 수중에 부유하는 콜로이드 성 물질의 표면전위의 크기를 표현하는 것으로, 측정하는 방법이 제타 전위와 다르기 때문에 절대적인 값은 차이가 있지만 두 전위는 수학적인 관계식으로 표현할 수 있다. 제타 전위는 입자의 하전량에 따라 결정되고, SC는 motor 회전속도와 실린더와 피스톤 간격 및 왕복 행정 길이에 따라 제타 전위와 직선적인 관련성을 갖고 있다. SC와 제타 전위의 관계는 다음 식과 같다[9].

$$I = \frac{\epsilon p R^2 \zeta}{4\mu l} \quad (1)$$

단, I : 유동전류 (streaming current)

ϵ : 유전상수 (dielectric constant of water)

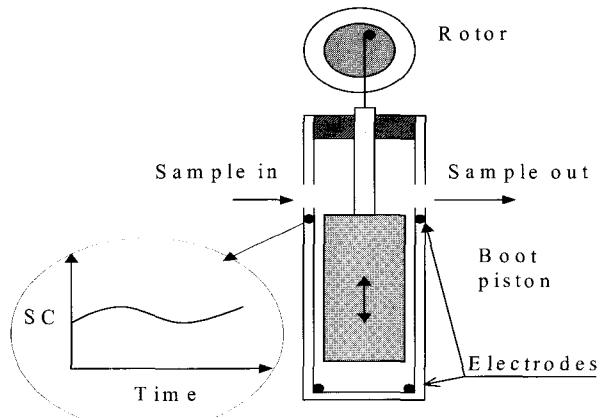


그림 2. 유동전류계의 작동원리.

Fig. 2. The schematic diagram of SCD probe and it's working theory.

p : 작용압력 (applied pressure)

R : 시료수의 통과반경 (passage radius)

ζ : 제타 전위 (zeta potential)

μ : 물의 점성 (viscosity of water)

l : 시료수의 통과길이 (length of passage)

3. 역전파 알고리즘

비선형시스템 제어에 효과적이며 복잡분산학습능력을 가진 신경회로망은 다변수시스템으로 적용이 쉽고 학습력과 적응력을 갖추고 있어, 학습데이터에 의하여 학습된 신경회로망은 학습데이터에 포함되지 않은 입력에 대해서도 일반적으로 추정할 수 있다. 또한 독립된 입력의 상호작용에 의해서 출력력을 산출하는 구조로 되어 있으므로 다변수시스템으로 적용이 간단하다.

신경회로망에는 많은 종류가 있지만 학습능력을 갖는 역전파 알고리즘(back propagation algorithm)을 적용하였다. 역전파알고리즘은 (2)에서와 같이 오차함수의 기울기가 0인 곳으로 학습이 진행되는 기울기 감소법(gradiant descent method)을 이용한다.

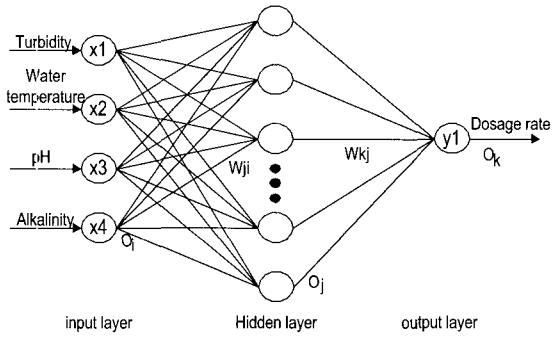


그림 3. 신경망 모델.

Fig. 3. The neural network model.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (2)$$

역전파알고리즘을 도입한 신경망의 학습과정은 다음을 반복하는 과정에 가중치를 변경하여 최적화시킨다.

$$\Delta w_{ji}(n) = \eta(\delta_j O_i) + \alpha \Delta w_{ji}(n-1) \quad (3)$$

$$\Delta w_{kj}(n) = \eta(\delta_k O_j) + \alpha \Delta w_{kj}(n-1) \quad (3)$$

$$\delta_k = (t_k - O_k)O_k(1 - O_k)$$

여기서 w_{ji} 는 j 층과 i 층 사이의 가중치, η : 학습률, t_k 는 목표값, α : 모멘텀 계수, n : 학습회수를 나타낸다[10].

신경회로망시스템은 초기에 충간 가중치를 임의로 설정하여 시스템을 구축한다. 구축된 시스템에 원수수질데이터를 입력하여 출력값을 계산하고, 원하는 출력값과의 오차를 계산하여 이 오차가 작아지는 방향으로 초기 가중치가 조절되어간다. 이와 같이 출력오차가 최소화되도록 충간 가중치를 반복학습에 의해 조절하여 최적화시킨다. 따라서 각각의 학습자료에서 구한 응집제주입률을 오차에 의하여 학습이 진행되고, 모든 데이터를 반복 학습하면 결국에는 최적화 시스템이 되는 것이다.

III. 모델링 및 시뮬레이션

1. 응집제 주입공정 신경망 모델링

본 논문에서는 자-실험에 의해 실제 운영한 정수장 데이터를 이용하여 응집제 주입공정을 신경망으로 구축하고 이 모델로부터 처리수 탁도를 최소로

하는 응집제주입률을 결정방법을 제안한다. 자-실험에 의한 응집제주입률의 결정이 최적의 주입률이라는 것은 모두 인정하는 사항이므로 자-실험 데이터를 적용하여 운영한 정수장 운영자료를 이용하여 응집제주입공정의 모델링을 실시하고 이 모델로부터 최적의 응집제주입률을 결정해야 한다.

신경망 구성에 있어서 입력층 자료의 선택이 아주 중요하다. 입력자료의 선택에 따라 예측결과에 큰 영향을 미치기 때문이다. 본 논문에서는 신경망의 입력변수로 탁도, 수온, pH, 알칼리도를 선정하였다.

신경망의 입력변수 각각의 영향을 일정하게 하기 위하여 입출력자료를 정규화 하는 과정이 필요하다.

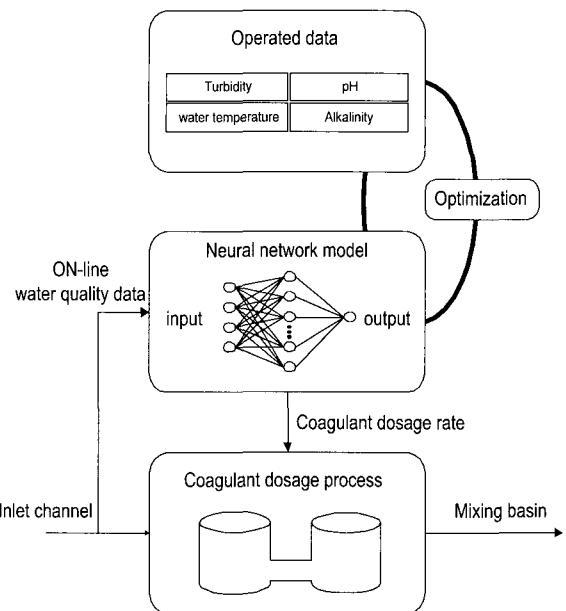


그림 4. 응집제 주입율 설정 방법 흐름도.

Fig. 4. The flowchart of fixing coagulant dosing rate.

정규화 함수 X_i 를 산출하기 위하여 각 수질별로 (4)를 사용하였으며 0과 1 범위 내에서 출력한다. 따라서 각각 자료의 최대값과 최소값을 구하여 0과 1사이에 분포시켜야 한다.

$$X_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

본 논문에서의 신경망은 4개의 입력 노드와 1개의 출력 노드로 구성하였으며 중간 노드의 수는 여러 가지 수를 적용하여 가장 오차가 적은 것을 선택하였다. 또한 4개의 독립변수인 원수의 탁도, 수온, pH, 알칼리도를 입력 노드로 할당하고 응집제 주입률을 출력 노드에 적용시켰다. 신경망 모델은 그림 3과 같다.

구축된 신경망 모델은 주기적으로 정수장 운영자료에 의해 학습되며 최적의 응집제주입률을 찾는다.

응집제주입 공정은 다음과 같이 진행된다.

착수정으로 유입되는 원수의 수질항목인 수온, pH, 탁도, 알칼리도값을 센서로부터 읽어들이고, 이러한 값을 기초로 구축된 응집제주입공정 신경망으로부터 응집제주입률을 결정한다.

결정된 주입률은 응집제주입 제어기의 설정치로 설정하여 운영하고, 운영결과 데이터를 저장한다.

또한 주기적으로 신경망을 재학습하여 모델을 수정하고 공정의 효율을 증가시킨다. 전체적인 응집제 주입률의 설정 방법이 그림 4에 나타내었다.

2. 시뮬레이션

학습평가에 사용된 자료는 한국수자원공사 군산정수장에서 2000년부터 2002년 말까지 응집제로 액체황산알루미늄(LAS)을 사용한 일간 운전실적자료를 사용하였다.

군산정수장은 금강하구둑에서 취수하므로 원수수질이 좋

표 1. 군산정수장 응집제 주입 운영자료 예.

Table 1. The example of jar-test data at goonsan water treatment plant.

Water temperature	pH	Turbidity	Alkalinity	feeding rate
12	7.9	4.4	60	27.57
13	7.4	5	60	27.58
13	7.3	5.8	60	22.9
14	7	4.8	40	25.14
14	6.9	7.6	61	24.15
15	6.9	8.4	61	20.11
15	7	11	61	33.16
14.5	7	11	61	25.05
14.5	7	9.2	61	28.44
16	6.8	8.9	62	24.92

표 2. 입력자료의 최대 및 최소값.

Table 2. The maximum and minimum values of the input data.

	Water temperature	pH	Turbidity	Alkalinity	Feeding rate
Max	29.0	9.5	140.0	65	70.25
Min	3.5	6.2	2.4	20	16.80

지 않은 특성이 있어 성능평가에 좋은 조건을 갖추고 있다. 대상 플랜트의 3년간 자실험에 의해 실제 운영한 데이터를 가지고 응집제 주입공정의 신경망 모델을 구현하였다. 입력자료의 예는 표 1과 같다.

응집제주입률 예측을 위한 신경망의 정규화를 위하여 사용된 입력 자료의 최대 및 최소값은 표 2에 나타내었다.

은닉층의 노드 수는 오차를 최소화하기 위하여 몇 가지의 수를 변경하여 시험하였다. 오차의 판단기준으로는 자료의 일부 시점에서 변동이 크고, 추세가 있는 경우 독특한 값에 영향을 덜 받는다고 알려진 평균절대오차(MAE:Mean Absolute Error)를 사용하였으며 (5)와 같다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - o_i| \quad (5)$$

여기서 n은 자료의 수, y_i 는 목표값, o_i 는 출력값이다. 학습결과 은닉층 노드의 수에 따른 절대평균 오차는 표 3과 같이 나타났으며 30개 이상에서는 거의 수렴함을 알 수 있다. 본 논문에서는 미소한 차이지만 절대평균오차가 가장 최소로 나타난 45개로 정하였고 신경망 모델의 파라미터는 표 4와 같다. 학습률과 모멘텀 계수는 여러 번의 시행착오를 거쳐 경험적으로 0.001과 0.7을 설정하였으며 결합강도의 초기값은 랜덤함수를 이용하여 $-0.5 \sim +0.5$ 의 범위에서 발생하도록 하였다.

IV. 결과 및 고찰

군산정수장의 과거 3년간 자실험에 의한 일간 약품주입

표 3. 은닉층에 따른 오차 비교.

Table 3. The comparison of the errors by the number of hidden layer.

Hidden layer node no	10	20	30	40	45
Absolute mean error	2.76	4.01	2.83	2.72	2.65

표 4. 신경망 파라미터.

Table 4. Parameters of neural network.

Parameter	Range
Hidden layer node no	45
Learning rate	0.001
Momentum coefficient	0.7
Weight initial range	$-0.5 \sim +0.5$
Sigmoidal function gradient	1

표 5. 응집제 주입 평가 결과 예.

Table 5. Estimated result using the neural network.

input data	taget value	calculated value	error			
water temp'	pH	turbidity	alkalinity			
25	6.8	9	40	28.23	27.8	0.43
26	6.9	9.2	40	28.85	29.7	-0.85
25	6.8	6.8	40	25.1	28.16	-3.06
25	6.9	5	40	28.44	29.11	-0.67
25	6.9	6.4	40	34.45	28.73	5.72
23	7	9.2	44	35.03	25.56	9.47
24	7	11	45	25.8	26.52	-0.72
25	7	11	42	26.61	27.74	-1.13
26	6.8	11	46	29.74	27.37	2.37
26	6.8	9.1	46	32.48	26.97	5.51
27	6.5	9.4	43	31.68	28.07	3.61
27	6.5	9.2	44	35.95	27.91	8.04
27	6.3	12	35	33.06	32.01	1.05
27	6.3	8.9	33	31.69	35	-3.31
27	6.3	15	32	33.27	31.97	1.31
28	6.4	12	31	32.74	32.61	0.13
29	6.5	7.9	23	32.52	32.72	-0.2
23	6.4	9.7	31	34.25	31.49	2.76
21	7.2	140	32	60.51	65.7	-5.19
25	7.3	110	35	72.32	60.16	12.16

운영자료 400개 중 300개는 신경망의 학습자료로 이용하고 평가를 위하여 학습에 사용하지 않은 100개 자료로 응집제 주입률을 결정하고 실제 주입률과 비교검토 하였다.

오차를 최소화하기 위한 은닉층 노드 수의 결정과정에서 은닉층 노드의 수와 오차율이 일치하지는 않지만 대체로 30개 이상에서 수렴하고 있으며 미소한 차이지만 은닉층 노드의 수가 많아질수록 오차가 감소하는 것으로 나타났으며 절대평균오차가 가장 적게 나타난 은닉층 노드의 수 45개를 적용하여 응집제주입률을 결정하였다.

학습된 신경망을 평가한 결과 절대평균오차가 3.02ppm으

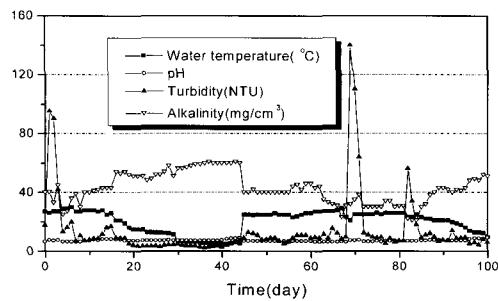


그림 5. 신경망의 주입률 계산을 위한 입력자료.

Fig. 5. The input data of the neural network model.

로 학습시의 절대평균오차 2.65ppm보다 약간 증가하였으며, 최대오차는 12.16ppm, 최소오차는 0.13ppm이었다.

표 5는 학습된 결합강도를 이용하여 시험한 결과이다. 이 중에서 최대오차가 발생한 20번째 데이터에서 오차가 12.16ppm이 발생했는데 전일 데이터와 비교하여 수온은 21°C에서 25°C로 상승하였으므로 응집제의 응집효과가 양호해지는 특성이 있어 응집제주입률은 저하 요인이다. pH는 비슷하고, 탁도는 140 NTU에서 110 NTU로 낮아져 응집제 주입률의 저하요인이나 알칼리도가 32 mg/cm³에서 35 mg/cm³로 높아져 응집제 주입률 증가 요인이 된다고 분석할 수 있다.

전체적으로 볼 때 응집제 주입률의 변화는 신경망에서 계산된 결과와 같이 변화가 거의 없는 것이 타당하다. 실제 운전주입률에서는 응집제주입률이 12ppm 정도가 증가하였다. 따라서 결과만으로 판단할때는 신경망에서 계산된 값이 더 최적값이라 판단될 수 있다. 그러나 입력 데이터 4가지 외에 다른 요인이 있거나, 비 온 후 응집이 잘 안 되는 특성이 있어 안전하게 운영했을 가능성 등으로 추정할 수 있다. 설사 응집제주입률이 다소 적게 계산되었다 하더라도 응집제 자체의 응집효과에 어느 정도 범위가 있으므로 침전수 수질에는 큰 변화가 없을 것으로 판단된다.

그림 5는 시험에 사용한 원수수질 데이터를 보여주고 있다. 수질 데이터에서 탁도와 알칼리도가 급격히 변화한 경우에는 강우가 있었다고 볼 수 있으며, 그림 6은 학습된 신경망을 이용해 학습에 사용하지 않은 데이터를 시험한 결과로 신경망에 의해 예측한 주입률이 운전주입률을 대체로 잘 추적함을 알 수 있다. 학습에 사용된 자료는 근본적으로 자실험에 의한 응집제주입률 결정과 근무자에 의한 조정에 의하여 운전되는 운전설적자료이므로 어느 정도의 오차를 포함하고 있고, 이러한 데이터를 이용한 최적화이며, 4가지 수질인자가 모든 수질을 대변하고 있으므로 응집제주입률에 반영이 안된 수질인자는 오차로 작용한다. 따라서 유동전류측정기와 신경망을 조합하여 피드백 및 피드포워드 제어 시스템을 구성하여 사용하는 것이 바람직할 것으로 본다. 그림 7에 응집제주입률 자동연산 및 제어를 위한 하드웨어 구성을 나타내었다. 차수정으로 유입되는 원수의 수질항목인 탁도, 알칼리도, pH, 수온 및 침전지 탁도

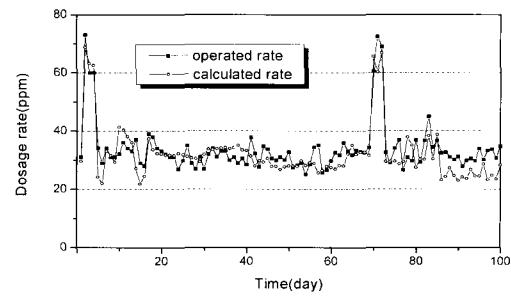


그림 6. 신경망의 주입률 계산 결과 비교.

Fig. 6. The comparison of the results of actual system and neural network model.

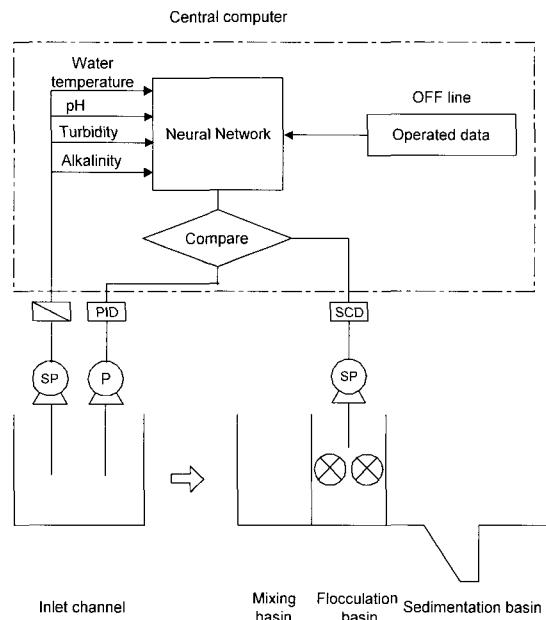


그림 7. 응집제 자동주입을 위한 하드웨어구조.

Fig. 7. Hardware scheme for the coagulant dosing control in water treatment plant.

를 센서로부터 읽어 들인다. 이러한 센서로부터 입력된 값들을 자실험을 기본으로 하는 과거의 정수장 운전데이터에 의해 구축된 응집제 주입공정의 신경회로망시스템의 입력변수로 하여 응집제주입률을 결정한다. 결정된 주입률을 응집제 주입제어기(PID제어기)의 설정치로 설정한다.

응집제주입률의 겹중을 위하여 응집지 유입부의 수질을 샘플링하여 응집상태를 SCD로 전류값을 측정하여 신경망의 주입률 변화와 비교하여 주입률을 보정한다. 예를 들어 신경망에서 응집제주입률이 증가이고 SCD 값이 증가하거나 혹은 신경망의 주입률이 감소하고 SCD 값이 감소하면 신경망의 주입률을 적용하고 서로의 값이 다를 경우 근무자가 확인하여 비교 또는 자실험 후 주입률을 결정하는 등의 보완이 필요하다. 또한 주기적으로 자실험 데이터나 성공적으로 운영된 운영데이터를 이용하여 재학습을 통해 모델을 수정하여 공정의 효율을 증가시킨다.

V. 결론

본 논문에서는 정수장의 응집제주입공정의 자동제어를 목적으로 응집제주입률 예측에 신경망 모델의 적용을 제안하였다. 실제 정수장 운영 데이터를 이용하여 신경망 학습을 하였고, 구축된 신경망 모델로부터 현재 수질 상태에 최적화된 응집제주입률을 예측하는 것이다. 본 논문을 통하여 다음과 같은 결론을 얻었다.

- 1) 응집제 주입을 위한 신경망 모델의 예측 결과가 기존 정수장 운영 데이터에 잘 추적함을 확인하였다.
- 2) 신경망 모델의 입력변수로 탁도, 수온, pH, 알칼리도를 사용하여 응집제 주입 공정의 자동화 가능성을 확인하였다.
- 3) 응집제 주입의 자동화에 신경망과 유동전류측정기(SCD)를 조합하여 상호보완적으로 사용하면 급격한 수질 변화에 효율적으로 대처할 수 있을 것으로 본다.
- 4) 정수장의 수질은 국민의 건강과 관련되는 민감한 사항이므로 오프-라인으로 안전성 검증을 거친 후 실용화하여야 할 것이다.

응집제 주입공정의 불확실성 및 문제점을 해결하기 위하여 응집제주입률의 오차 원인파악 및 수질변수에 대한 심도 있는 연구와 좀 더 오차를 줄일 수 있는 방안에 대한 연구가 필요하다고 판단된다.

참고문헌

- [1] 박중현, 상하수도공학, 동명사, 1988.
- [2] E. L. Bean, S. J. Campbell, F. R. Anspach, "Zeta

potential measurements in the control of coagulation chemical doses", *J. AWWA*, vol. 56, no.2, pp. 214-227, 1964.

- [3] S. K. Dental and K. M. Kingery, "Using streaming detectors in water treatment", *J. AWWA*, vol. 81, no.3, pp. 85-94, 1989.
- [4] 남의석, 박종진, 장석호, 차상엽, 우광방, 이봉국, 한태환, 고택범, "신경회로망을 이용한 상수처리시스템의 응집제 주입 공정 최적화", 제어·자동화·시스템공학회 논문지, 제3권, 제6호, pp. 644-651, 1997.
- [5] 주대성, 최동진, 박희경, "인공신경회로망을 이용한 응집제 최적주입률 결정", 한국물환경학회지, 제15권, 제1호, pp. 23-30, 1999.
- [6] 김용열, 강이석, "유전-퍼지를 이용한 정수장 응집제 주입률 결정에 관한 연구", 제어·자동화·시스템공학 논문지, 제5권, 제7호, pp. 876-882, 1999.
- [7] 정우섭, 오석영, "지능형 응집제 투입 시스템의 개발", 제어·자동화·시스템공학논문지, 제3권, 제6호, pp. 652-658, 1997.
- [8] 한국수도협회, 상수도시설기준, 1997.
- [9] AWWA Manual M37, "Operational Control of Coagulation and Filtration Processes", *AWWA*, pp. 42~44, 1992.
- [10] Yoh-Han Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Company, 1989.

김기평

1960년 9월 27일생, 1988년 경남대 전자공학과 졸업(공학사). 2004년 충남대 산업공학과 졸업(공학석사). 1988년~현재 한국수자원공사 재직중. 주관심분야는 계측제어, 수도시설자동화



김용열

1962년 5월 16일생, 1984년 한양대 기계공학과 졸업(공학사). 1996년 충남대 기계설계 공학과 졸업(공학석사). 1998년~현재 충남대학교 기계설계공학과 박사과정. 1989~현재 한국수자원공사 재직중. 주관심분야는 인공지능, 진동, 유체기계, 공장자동화.



유준

1956년 3월 22일생. 1978년 서울대 전자공학과 졸업. 한국과학기술원 전기 및 전자공학과 박사(1984). 1984년~현재 충남대학교 정보통신공학부 교수. 관심분야는 산업공정제어, 센서 신호처리, 항법시스템 등.



강이석

1952년 2월 14일생, 1974년 서울대 기계공학과 졸업(공학사). 1983년 아주대 기계공학과 졸업(공학석사). 1994년 한국과학기술원 기계공학과 졸업(공학박사). 1991~1992년 MIT 대학 방문연구원. 1981~현재 충남대학교 기계설계공학 교수. 주관심분야는 제어이론의 응용, 로보틱스, 인공지능, 유압공학, 공장자동화.

