

# 신경회로망을 이용한 상수처리시스템의 응집제 주입공정 최적화

## Optimization of Coagulant Dosing Process in Water Purification System using Neural Network

남 의 석, 박 종 진, 장 석 호, 차 상 업, 우 광 방, 이 봉 국, 한 태 환, 고 택 범

(Eui seok Nahm, Jong jin Park, Seok ho Jang, Sang yeop Cha, Kwang bang Woo, Bong kuk Lee, Tae han Han, Taek Beom Koh)

**Abstract** : In the water purification plant, chemicals are injected for quick purification of raw water. It is clear that the amount of chemicals intrinsically depends on water quality such as turbidity, temperature, pH and alkalinity. However, the process of chemical reaction to improve water quality (e.g., turbidity) by chemicals is not yet fully clarified nor quantified. The feedback signal in the process of coagulant dosage, which should be measured (through the sensor of the plant) to compute the appropriate amount of chemicals, is also not available. Most traditional methods focus on judging the conditions of purifying reaction and determine the amounts of chemicals through manual operation of field experts using Jar-test data.

In this paper, a systematic control strategy is proposed to derive the optimum dosage of coagulant, PAC(Polymerized Aluminium Chloride), using Jar-test results. A neural network model is developed for coagulant dosing and purifying process by means of six input variables (turbidity, temperature, pH, alkalinity of raw water, PAC feed rate, turbidity in flocculation) and one output variable, while considering the relationships to the reaction of coagulation and flocculation. The model is utilized to derive the optimum coagulant dosage (in the sense of minimizing turbidity of water in flocculator). The ability of the proposed control scheme validated through the field test has proved to be of considerable practical value.

**Keywords** : water purification system, coagulant dosing process, back-propagation, neural network, jar-test

### I. 서론

급속한 산업 발달과 더불어 처리되지 않는 하수나 폐수의 양적 증가가 하천수질 오염의 주요 원인이 되고 있다. 다목적 댐 등 대형의 저수지들이 축조되어 강우와 함께 오염물질들이 상당 기간동안 댐에 정체된 물과 각종 영양균류의 혼입으로 부영양화 되는 수질오염 현상이 발생한다. 이러한 극심한 원수의 수질저하가 심각한 사회적 문제를 야기시키고 있어 효과적이고 체계적 정수처리가 시급히 요구된다[1].

일반적으로 원수는 많은 양의 탁질을 함유하고 있고 이의 제거를 위해 원수는 여과, 응집과 침전 및 분리과정을 거친다. 응집의 효과는 탁질 유발 물질과 이러한 탁질의 종류 및 양, 원수의 수온, 알칼리도, pH 등에 영향을 받는다. 응집제는 이러한 탁질의 효과적 제거를 위해 주입되며 응집제 주입율은 상수처리 플랜트로 유입되는 원수의 수질에 따라 결정된다. 그러나 상수처리 플랜트는 강이나 호수 원수의 수질이 급격한 변화 등의 외부적인 환경요인에 영향을 받는다. 또한 1)원수수질 측정(탁도, 알칼리도, pH, 수온 등)의 복잡성과 다양성, 2)극심한 부하변화(기후, 시각 및 계절에 따르는 원수 수량·수질의 큰 변화), 3)비선형 다변수 시스템, 4)원수의 프로세스 체류시간이 길고 피드백이 없음 등의 특성으로 인하여 응집제 주입율을 효과적으로 결정하지 못하고 있다[2].

일반적인 정수처리 공정은 응집, 침전, 여과, 살균소독 처리 과정을 거치며, 약품주입에 의한 응집·침전 및 살균소독 처리는 상수처리시스템의 가장 핵심 부분이 된다. 상수처리

에서 기존의 약품 주입제어는 응집·침전을 위한 응집제 주입공정과 살균·소독을 위한 염소 주입공정을 포함한다. 여기서 기존의 응집제 주입은 Jar-test에 의한 조건표 작성 또는 통계 팩키지에 의한 선형 모델링 기법에 의하고 있다[3]. Jar-test는 5, 6개의 비이커에 원수를 넣고 응집제의 비율을 서로 다르게 주입하여 탁질의 침전 상태를 측정하여 최적의 응집제 주입율을 결정한다. 이 방법은 매우 효과적이거나 테스트 시간이 오래 걸린다. 장마철에는 원수의 수질이 급격하게 변하기 때문에 테스트 시간이 길다는 단점이 있다. 또한 운전원의 기술과 경험에 크게 의존하기 때문에 운전원이 바뀌는 경우 공정의 효과적 운용이 되지 못한다. 통계 팩키지에 의한 방식은 통계팩키지에 의해 구해진 응집제 주입 공정 모델식의 부정확성 때문에 이에 따른 응집제 주입율의 오차가 크다. 과거의 운전실적 데이터를 토대로 수학적 모델식을 구하는 방법은 모델식이 기후, 시각 및 계절에 따르는 원수수량, 수질의 큰 변화에 정확히 그리고 효과적 약품주입 공정을 기술하지 못하며 비선형 다변수의 약품주입 공정에는 적합하지 않다[3][5].

본 논문에서는 Jar-test 데이터를 이용하여 응집제 주입공정을 신경회로망 기법에 의해 구축하고 이 모델로부터 처리수 탁도를 최소로 하는 응집제 주입율 설정 기법을 제안한다. Jar-test에서 응집제 주입율의 선택은 숙련의 전문가에 의존하기 때문에 Jar-test 데이터는 전문가의 전문 지식을 내포한다. 따라서 본 논문에서는 응집제 주입의 결과, 현재의 주입율에 대한 처리수의 탁도(피이드백)가 없는 필드 데이터를 이용하는 것이 아니라 전문가의 지식이 내포된 Jar-test 데이터를 이용하여 응집제 주입공정의 모델링을 추진하고 이 모델로부터 응집제 주입율을 설정하여 Jar-test의 소요 시간을 해결하였다. 또한 플랜트 운전에서 결정

은 숙련된 조작자 경험에 의존하기 때문에 전문가 지식을 컴퓨터 상에서 실제적인 사용으로 변환하는 지식-베이스 시스템은 매우 유용하다[4]. 신경회로망은 운전자의 지식이 포함된 데이터로부터 실제적인 운전 지식을 제공하므로 플랜트 운전 보조가 가능하며 매우 유용하다. 본 논문에서는 응집제 주입공정 모델링을 위해 신경회로망 기법을 이용하고, Jar-test 데이터로부터 응집제 주입공정을 학습하여 플랜트 운전자에게 학습 결과를 제공하며 효과적인 제어 기법을 제안하고 통계패키지에 의한 기법의 문제점을 해결한다.

제안된 기법은 수도권 상수처리장을 대상으로 선택하여 기법을 적용토록 하였다. 신경회로망 모델링을 위해 1년간의 Jar-test 데이터가 사용된다.

**II. 상수처리시스템의 응집제 주입공정**

상수처리 플랜트는 양질의 안전 식수 및 공업용수를 공급한다. 이 목적을 위한 원수의 근원은 지하수, 강, 또는 호수의 표면수 등이다. 최근에는 표면수가 수원 보호를 위하여 주로 사용되며 다량의 불순물을 포함하고 있어 수질 변화폭이 크다. 응집제는 이러한 불순물을 완전 또는 효과적 처리를 위해 주입되며 응집제 주입율은 정수장에 흘러 들어오는 원수의 수질변화에 따라 변한다. 그러나 응집제에 의해 불순물을 응집하는 과정은 복잡하고 단지 제한된 항목만이 On-line 수질센서에 의해서 측정 가능하다. 이에 따라 응집제 주입율을 고정을 위한 어떠한 실용적인 방법보다는 경험 많은 작업자의 판단에 근거를 두고 적용된다.




그림 1. 상수처리시스템 개요도.  
Fig. 1. The scheme of water purification system.

상수처리시스템의 정수처리공정(그림 1)에서 침전과 여과 공정은 가장 기본적인, 정수장의 핵심적인 역할을 담당한다. 침전지는 물의 불순물을 가라앉게 한다. 응집제는 침전 작용 증진을 위하여 주입된다. 응집제는 물속의 불순물이 응집되어 무거워지게 함으로서 불순물을 빨리 가라앉게 한다. 플록(Floc)이라고 하고 이러한 불순물의 형성은 자연 침전을 위해서 필수적이며, 이는 응집제 추가 투입의 기준을 마련해 준다. 원수의 탁도는 일반적인 경우 30[NTU (Nephelometric Turbidity Units)] 이하이고, 수백 [NTU]까지 증가하기도 한다. 불순물은 대부분 침전지에서 제거되며, 출구에서의 유출수는 단지 몇 [NTU]의 탁도만을 가진다. 잔여 불순물은 탁도를 1[NTU] 이하로 떨어뜨리기 위해 모래 여과를 통해 제거된다. 만약 부적절하게 침전된 불순물이 여과지로 투입된다면, 여과지는 즉시 막히게 되며 따라서 여과작용을 수행할 수 없게 된다[6][7][8].

약품 주입은 알칼리제, 응집제 그리고 염소 주입계로 각각 구성된다. 석회나 부식성 소다가 pH 조절을 위하여 알칼리제로 사용된다. 알루미늄 황산염이나 PAC(Polymerized Aluminum Chloride)는 응집제로서 사용된다. 이 모든 것들은 침전 효율을 높이기 위하여 불순물 응집을 향상시키는데

사용된다. 이와 같은 화학약품에 대한 적절한 주입율은 미리 고정된다. 그리고 주입량은 원수의 양에 비례하여 결정된다. 알칼리제와 염소의 주입율은 약간의 수질 변동에도 일정하게 유지될 필요가 있다. 따라서 이러한 약품주입에는 큰 문제가 없다. 반면, 응집제 주입은 불순물에 상당히 복잡한 방법으로 영향을 미치기 때문에 공정 모델링이 상당히 까다롭다. 이러한 응집제 주입 공정은 매우 복잡하여 공정을 일반적 수학적식으로는 모델링하기가 어렵고, 1)원수의 수질이 4계절 환경 변화와 하천에 따라 다르고, 2)응집제의 반응 프로세스는 탁질 이외에도 수온, 알칼리도 등도 관계하고, 그 반응 자체가 잘 알려져 있지 않고, 3)원수의 프로세스 체류 시간이 길고 피이드백이 없고, 4)프로세스의 출력이 음료수이기 때문에 제어 실패가 허용되지 않는 특징이 있다. 따라서 효과적인 정수공정을 위해서는 현재에 수질에 대응하여 최적의 응집제 주입율 계산 방법이 필요하다.

정수처리공정에서 5개의 독립변수의 측정 위치는 그림 2와 같다.




그림 2. 응집제 주입공정의 수질항목 측정변수.  
Fig. 2. The measurements of water quality in the coagulant dosing process.

**III. 응집제 주입공정의 신경회로망 모델링**

**1. 신경회로망**

본 논문에서는 응집제 주입공정의 신경회로망 모델을 구축하기 위하여 Rumelhart, Hinton 등에 의해 제안된 역전파(B.P. : Back-propagation) 알고리즘을 이용하여 모델을 반복 학습하여 연결하중을 결정하도록 한다.

모델의 수렴성 증가를 위하여 수정된 모멘트법을 이용하고, 또한 입력계층의 입력단은 실험을 통하여 얻은 입력데이터를 받아들이며 입력 계층의 출력단은 입력데이터의 값을 정규화한 값으로, 데이터  $X_t = \{x_1(t), x_2(t), \dots, x_n(t), y(t)\}$ 에 대하여 (1)과 같이 정규화 함으로써 입력변수의 출력변수에 대한 영향력을 균등화하였다.

$$\hat{x}_i(t) = \frac{(x_i(t) - (x_{i, \min} + x_{i, \max})/2.0)}{(x_{i, \max} - x_{i, \min})/2.0} \quad (1)$$

여기서,  $x_i(t)$ 는  $i$ 번째 입력변수의  $t$ 번째 데이터를 의미하고  $x_{i, \min}$ ,  $x_{i, \max}$ 는 각각  $i$ 번째 입력변수의 최소값과 최대값을 의미한다.  $\hat{x}_i(t)$ 는 계구간  $[-1.0, 1.0]$ 으로 정규화된  $i$ 번째 입력변수의  $t$ 번째 데이터를 의미하고,  $y(t)$ 는 출력변수의  $t$ 번째 데이터를 나타낸다.

중간계층의 입력단은 (2)와 같이 연결 하중치와 정규화된 입력들의 곱의 총합에다 문턱치(Threshold)값을 합한 값으로 표현된다.

$$net_j = \sum_{i=1}^n \hat{x}_i(t) \cdot w_{ij} + \theta_{th} \quad (2)$$

여기서,  $n$ 은 입력변수의 수를 나타낸다.

또한 중간계층의 출력단은 (2)의 활성화 함수 값으로 (3)과 같이 표현된다.

$$o_j = f(net_j), \quad f(x) = \frac{1}{2}(1 + \tanh(\frac{x}{a})) \quad (3)$$

여기서,  $a$ 는 활성화 함수의 기울기를 결정하는 인자이다.

출력계층의 입력단과 출력단은 중간계층의 출력단에서 얻은 값을 입력으로 (4)에 의해 얻어진다.

$$net_k = \sum_{j=1}^m o_j \cdot w_{jk}, \quad net_k = \hat{y}(t) \quad (4)$$

여기서,  $m$ 은 출력변수의 수,  $\hat{y}(t)$ 는 신경회로망으로부터 계산된  $t$ 번째 값을 나타낸다.

만약 상당 방향으로 계산된 (4)의 출력값과 실험에서 얻은 출력 패턴이 일치하면 학습이 종료되나 그렇지 못할 경우 이 차이를 감소시키기 위해 하단 방향으로 경사법(Gradient descent method)을 사용하여 연결하중치와 문턱치를 보정한다. (5)는 실제값  $y(t)$ 와 신경회로망 모델로부터 계산된 값  $\hat{y}(t)$ 와의 오차를 나타내는 식이다. 연결하중과 문턱치는 (5)를 최소화하기 위해 보정된다. 연결하중의 보정은 (6),(7)로 표시되고 문턱치는 (8)에 의해 보정된다. 여기서 학습률은  $0 < \eta < 1$ 의 값을 갖는다.

$$E(t) = \frac{1}{2}(y(t) - \hat{y}(t))^2 \quad (5)$$

$$w_{jk}(t+1) = w_{jk}(t) + \eta w_{jk}(t) + \nabla w_{jk}(t) \quad (6)$$

$$\begin{aligned} \nabla w_{jk}(t) &= -\alpha \cdot \frac{\partial E(t)}{\partial w_{jk}(t)} = -\alpha \cdot \frac{\partial E(t)}{\partial \hat{y}(t)} \cdot \frac{\partial \hat{y}(t)}{\partial w_{jk}(t)} \\ &= -\alpha(y(t) - \hat{y}(t)) \cdot o_j \end{aligned}$$

$$w_{ij}(t+1) = w_{ij}(t) + \eta w_{ij}(t) + \nabla w_{ij}(t) \quad (7)$$

$$\begin{aligned} \nabla w_{ij}(t) &= -\alpha \cdot \frac{\partial E(t)}{\partial w_{ij}(t)} \\ &= -\alpha \cdot \frac{\partial E(t)}{\partial net_k(t)} \cdot \frac{\partial net_k(t)}{\partial o_j(t)} \cdot \frac{\partial o_j(t)}{\partial net_j(t)} \cdot \frac{\partial net_j(t)}{\partial w_{ij}(t)} \\ &= -\alpha \cdot (y(t) - \hat{y}(t)) \cdot w_{jk}(t) \cdot \frac{2}{a} \cdot f(net_j) \cdot (1 - net_j) \cdot \dot{x}_j(t) \end{aligned}$$

$$\theta_{ih}(t+1) = \theta_{ih}(t) + \eta \theta_{ih}(t) + \nabla \theta_{ih}(t) \quad (8)$$

$$\begin{aligned} \nabla \theta_{ih}(t) &= -\beta \cdot \frac{\partial E(t)}{\partial \theta_{ih}(t)} \\ &= -\beta \cdot \frac{\partial E(t)}{\partial net_k(t)} \cdot \frac{\partial net_k(t)}{\partial o_i(t)} \cdot \frac{\partial o_i(t)}{\partial net_i(t)} \cdot \frac{\partial net_i(t)}{\partial \theta_{ih}(t)} \\ &= -\beta \cdot (y(t) - \hat{y}(t)) \cdot w_{jk}(t) \cdot \frac{2}{a} \cdot f(net_i) \cdot (1 - net_i) \end{aligned}$$

최소자승오차는 (9)과 같이 정의된다.

$$Error = \frac{\sum(\hat{y}(t) - y(t))^2}{N} \quad (9)$$

여기서,  $\hat{y}(t)$ 는 실제 출력 데이터이고  $y(t)$ 는 신경회로망 모델로부터 추론된 값이다.

(9)는 반복학습에 의해 추론된 출력값과 실제의 출력데이터의 오차이며 이 값이 일정범위안에 들면 학습이 종료되고 모델링이 끝나게 된다.

## 2. 응집제 주입공정 신경회로망 모델링

### 2.1 입출력변수 선정

일반적으로 상수처리에서 응집과 침전 반응 고려시, 4개의 독립변수 원수 탁도, 수온, pH, 알칼리도가 응집제 프로세스에서 상대적 관련 정도가 크다. 따라서 이들 4개의 독립변수들을 응집 프로세스에 입력변수로 하여 공정을 모델링 하게 되고, 처리수의 탁도는 응집효과를 확인할 수 있는

변수가 된다.

응집제 주입을 결정시 고려해야 할 가장 중요한 수질 인자는 원수 탁도이다. 응집제로 PAC를 사용할 경우, 적정 주입을 범위가 넓고 저수온, 저탁도 또는 고탁도와 같은 처리하기 어려운 환경에도 비교적 응집 효과가 좋은 것으로 알려져 있고, 일반적으로 원수 탁도의 증가에 따른 응집제 주입율의 변화는 지수함수적으로 증가하는 형태를 보인다. 원수 탁도가 유사한 범위에 있고 알칼리도가 다른 원수에 대하여 Jar-test 실험 결과를 살펴보면 응집제 주입율은 원수의 알칼리도가 증가하면 따라서 증가하는 것으로 나타나며, 이는 알칼리제를 사용할 때 필요량 보다 과량으로 주입되는 경우 응집제도 그만큼 더 많이 소비되므로 알칼리제 사용에 세심한 주의를 기울여야 한다. 응집제 주입시 수중의 알루미늄 이온(III)은 물의 pH에 따라 수산이온(OH-)을 모체로 하여 분자량이 큰 각종 중합체를 형성하면서 응집에 관여하는 수질 인자이다[9][10][12]. 그러나 응집은 수중의 각종 용존인자에 의해서 복잡한 영향을 받으므로 실제 pH의 측정만으로 응집조건을 결정할 수 없다. 원수의 pH에 따른 응집제 주입율의 변화는 일반적으로 비례하는 것으로 알려져 있다. 또한 온도는 물리화학반응에 있어서 매우 중요한 환경인자 중에 하나이다[11][13][14][15]. 온도는 응집 반응에 있어서 매우 중요한 환경인자로서 화학적 특성을 변화시킨다고 하였으며 저수온은 응집제의 용해도와 가수분해 반응의 화학적 성질을 변화시키며 따라서 응집 메카니즘과 응집 최적 pH범위에 영향을 미치는 것으로 알려져 있다. 물리적 현상에 미치는 영향에 대해서는 온도가 응집 입자의 크기 분포에 영향을 미치는 것으로 알려져 있다. 저수온에서 플록의 침강속도는 매우 느린 반면 고분자화된 (Prepolymerized) 알루미늄 응집제로부터 생성된 응집물은 수온에 관계없이 침강성이 좋은 것으로 알려져 있다. 또한 수온에 따른 응집제 주입율의 변화는 원수의 수온이 증가함에 따라 다소 감소하는 경향을 나타낸다[15]. 따라서 본 논문에서는 이러한 독립변수들을 입출력 변수로 하여 응집제 주입공정을 모델링한다.

### 2.2 모델링 데이터

본 논문에서는 숙련된 운전자의 Jar-test 결과를 이용하여 처리수의 탁도를 최소로 하는 최적 응집제 양을 결정하는 알고리즘 제안한다. 즉, 상수처리에서 응집과 침전 반응을 고려할 때, 6개의 변수(원수 탁도, 수온, pH, 알칼리도, 응집제 주입율, 처리수 탁도)를 응집제 주입공정을 모델링하기 위해 선택하고, 이 변수들을 입출력변수로 하여 응집제 주입공정을 신경회로망을 이용하여 모델링하고, 이 모델로부터 최적의 응집제 주입율을 결정해야 한다.

이와 같은 응집제 주입공정 신경회로망 모델의 구축에 있어서 필드 데이터를 이용하는 경우는 다음과 같은 문제가 있다. 1)동일 원수에 대하여 각각 다른 응집제 주입율을 주입한 경우의 처리수의 탁도의 변화를 알 수 없고, 2)필드 데이터의 경우 원수 수질 센서의 기계적인 오차가 존재하고, 3)처리수 탁도가 응집제 주입율과의 상관도 낮다. 표 1은 Jar-test한 예를 보여준다.

### 2.3 응집제 주입공정 신경회로망 모델

본 논문에서의 신경회로망은 5개의 입력 뉴런과 15개의 중간 뉴런 및 1개의 출력 뉴런으로 구성된다.

또한 5개의 독립변수인 원수의 탁도, 수온, pH, 알칼리도, 응집제 주입율을 입력 뉴런으로 할당하고 처리수의 탁도를 신경회로망 모델의 출력 뉴런에 할당하여(그림 3) 마치 Jar-test와 같은 형태의 처리수 탁도 신경회로망 모델(모델

I) 그리고 원수의 탁도, 수온, pH, 알칼리도, 처리수 탁도를 입력 뉴런으로 할당하고 응집제 주입율을 출력 뉴런에 적용시킨(그림 4) 응집제 주입율 신경회로망 모델(모델 II)로 구분된다.

표 1. Jar-test 데이터.  
Table 1. Jar-test data.

시험일시	94.4.7.	시험번호	PAC (ppm)	21 분후			판정
				탁도	pH	알칼리도	
채수지점	한강	1	8	2.2	7.5	45	
천기	맑음	2	10	1.9	7.5	45	
탁도	1.7	3	12	2.0	7.4	44	
수온	28.2	4	14	1.6	7.4	44	
pH	7.5	5	16	1.2	7.4	43	●
알칼리도	49	6	18	1.2	7.3	43	

급속교반(100 rpm)(1 분간), 완속교반(50 rpm)( 5 분간), 침수시간(15 분간)




그림 3. 신경회로망 모델 I.  
Fig. 3. NN model I.




그림 4. 신경회로망 모델 II.  
Fig. 4. NN model II.

2.4 응집제 주입율 설정

구축된 신경회로망 모델은 주기적으로 Jar-test 데이터에 의해 학습된다. 학습된 신경회로망 모델로부터 최적의 응집제 주입율을 찾는다. 원수의 수질 상태를 나타내는 필드 데이터는 10분마다 상위 컴퓨터로 전해진다. 모델 I로부터의 응집제 주입율 설정은 아래와 같다.

Step 1 : 현재의 수질값 원수탁도, 수온, pH, 알칼리도를

읽는다.

Step 2 : 최소 응집제 주입율을 현재의 응집제 주입률로 설정.

Step 3 : 원수탁도, 수온, pH, 알칼리도, 응집제 주입률을 입력으로 하여 모델로부터 처리수 탁도 계산.

Step 4 : 현재의 응집제 주입율을 1[NTU] 증가.

Step 5 : 만약 현재의 응집제 주입율이 최대응집제 주입율보다 작으면 Go To [Step 3] 그렇지 않으면 종료.

모델 II의 경우는 출력변수가 응집제 주입율이기 때문에 모델로부터 현재에 입력 수질상태에 대응하는 응집제 주입율이 곧바로 결정된다. 이렇게 찾아진 응집제 주입율이 필드의 Actuator로 전송된다. 전체적인 응집제 주입율의 설정 방법의 흐름이 그림 5에 보여진다.

원수의 수질 상태가 정상인 경우와 장마철과 같은 비정상인 경우에 운전자의 제어 행동이 다르기 때문에 응집제 주입공정 신경회로망 모델도 정상인 경우와 비정상인 경우 2가지로 나누어 구축된다. Jar-test 데이터는 정상태와 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. 따라서 응집제 주입공정 신경회로망 모델링 효과적이기 위해서는 수질의 변화폭을 크게 하면서 Jar-test 이루어진 데이터를 만들어야 하며 모델도 2가지로 나누어 구현되어야 한다.

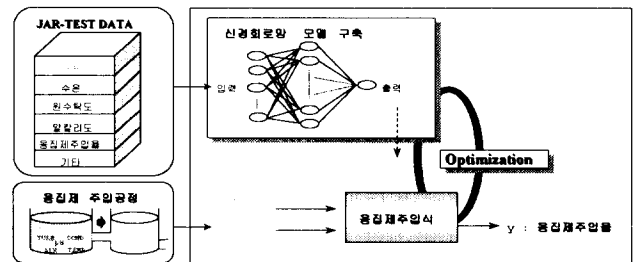


그림 5. 응집제 주입율 설정 방법 흐름도.

Fig. 5. The flowchart of fixing coagulant dosing rate.

IV. 시뮬레이션

대상 플랜트의 1년치 Jar-test 데이터를 가지고 응집제 주입공정의 신경회로망 모델 I과 모델 II를 구현하였다. 신경회로망의 파라미터들은 표 2와 같다. 중간층의 뉴런의 수는 일반적으로 입력변수의 2배에서 +2~+5가 정도로 정하는 것이 보편적이어서 본 논문에서는 15개로 정하였다. 학습율과 모멘텀계수는 여러번의 시행착오를 거쳐 경험적으로 설정하였다. 연결하중의 초기 값은 입력값을 정규화 하였기 때문에 랜덤함수를 이용하여 ±0.005~±2의 범위에서 발생하도록 하였다.

표 2. 신경회로망 파라미터.

Table 2. Parameters of neural network.

파라미터	범위
중간층의 뉴런 수	15
학습율	0.00025
모멘텀 계수	0.09
초기 연결하중 범위	±0.005~±2
시그모이드 함수 기울기	0.8

1. 모델 I의 성능평가

모델 I에 대하여 일년간의 Jar-test 데이터를 이용하여 응집제 주입공정을 모델링하고 실제 주입율과 비교하였다. 신경회로망의 모델 오차를 (10)으로 계산하여 그 결과를 표 3에 나타내었다.

$$Error = \frac{\sum(\hat{y}(t) - y(t))^2}{N} \quad (10)$$

여기서,  $\hat{y}(t)$ 는 실제 출력 데이터,  $y(t)$ 는 모델로부터 추론된 값,  $N$ 은 전체 데이터 수를 나타낸다.

표 3. 모델의 최소 자승 오차(모델 I).  
Table 3. The least square errors(NN model I).

METHOD		Errors
Neural Network	Normal	0.13
	Abnormal	0.25

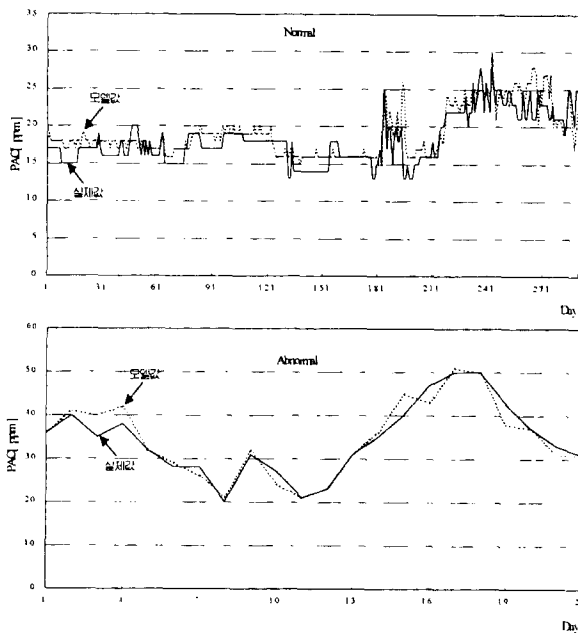


그림 6. 실제 주입율과 모델 주입율의 비교(모델 I).  
Fig. 6. The comparison of the results of actual system and neural network model (NN model I).

표 3에서 모델의 오차가 정상상태와 비정상상태 모두 매우 작으므로 모델의 성능은 검증되었다. 그림 6은 성능이 검증된 모델 I으로부터 출력변수인 처리수의 탁도를 최소로 하는 응집제 주입율을 찾고 이를 실제 주입율과 비교하였다. 여기서, 제안된 기법에 의해 예측된 주입율이 효과적임을 알 수 있다. 일반적으로 응집과 침전 프로세스의 특성을 고려할 때, Jar-test 결과에 의한 응집제 주입율의  $\pm 2[NTU]$  내에서는 처리수 탁도 변화가  $\pm 0.1[NTU]$  정도이고, 이 범위 내로 모델로부터 계산된 응집제 주입율이 적용된다면 효과적이다. 즉, (11)의 조건을 만족한다면 모델의 정확도가 인정된다.

$$\text{if } |\hat{y}(t) - y(t)| < 2, \text{ then acceptable} \quad (11)$$

여기서,  $\hat{y}(t)$ 는 실제 주입율,  $y(t)$ 는 모델로부터 추론된 주입율이다.

표 4는 (10)의 오차식과 (11)에 따른 모델의 정확도를

(12)의 퍼센트 오차로 표시하였다. 표 4에서 정상상태인 경우는 실제 응집제 주입율과 평균 74.1%, 비정상상태인 경우는 84.9%가 일치한다. 하지만 모델로부터 추론된 값으로 응집제 주입율을 설정하면 처리수의 탁도는 현재값보다 감소하여 정수효과를 증진시킬 것이다.

$$\% Error = \frac{A}{N} \times 100 \quad (12)$$

여기서,  $A$ 는 (11)을 만족하는 데이터 개수,  $N$ 은 전체 데이터 수이다.

표 4. 모델의 오차 비교(모델 I).

Table 4. The comparisons of the errors of actual system and neural network model(NN model I).

METHOD		Errors	% Error
Neural Network	Normal	0.13	74.1 %
	Abnormal	0.25	84.9 %

2. 모델 II의 성능평가

모델 II에 대하여 일년간의 Jar test 데이터를 이용한 응집제 주입공정 모델링과 실제 주입율의 비교에서, 표 5는 실제 주입율과 모델로부터 계산된 응집제 주입율의 식(10)에 의해 계산된 최소자승오차를 나타낸다. 표 5에서 정상상태인 경우는 실제 응집제 주입율과 평균 90%, 비정상상태인 경우는 100%가 일치하므로 제안된 응집제 주입율 설정 방식이 매우 효과적임을 알 수 있다. 모델 II가 모델 I보다 성능이 더 우수한 것은 원수 수질이 변화폭이 상대적으로 작은 것에 기인한다. 그림 7은 실제 주입율과 신경회로망 모델로부터 계산된 주입율을 나타낸다. 그림 7에서 보듯이 제안된 기법에 의해 예측된 주입율이 효과적임을 알 수 있다.




그림 7. 실제 주입율과 모델 주입율의 비교(모델 II).  
Fig. 7. The comparison of the results of actual system and neural network model (NN model II).

표 5. 모델의 오차(모델 II).

Table 5. The errors of model (NN model II).

METHOD		Errors	% Error
Neural Network	Normal	0.801	90 %
	Abnormal	0.0001	100 %

응집제 주입공정의 신경회로망 모델 I과 II에 대한 성능평가 결과, 신경회로망 모델 I의 경우는 실공정과 모델 자체의 오차는 매우 작으나 Jar-test 데이터 자체가 처리수 탁도가 1.0 이하에 대한 응집제 주입율의 경우의 데이터는 거의 없으므로 필요 이상의 응집제 주입을 설정 가능성이 높다. 따라서 필드 테스트는 모델 II에 대해서 수행하였다.

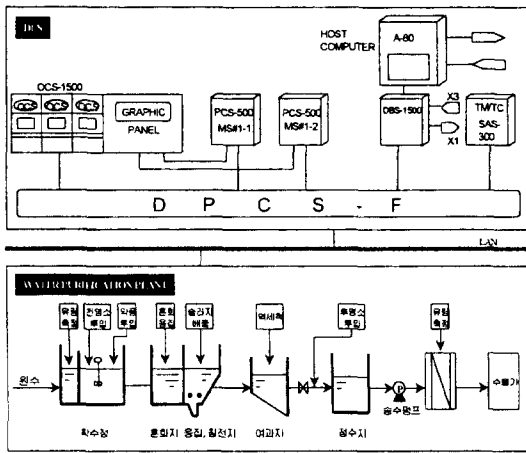


그림 8. 정수 처리 계통.  
Fig. 8. The scheme of water purification process.

V. 현장 실험

1. 대상 플랜트

제안된 기법의 검증을 위해 서울시 상수처리 플랜트 중의 하나를 모델로 하여 테스트를 하였다. 이 플랜트는 하루에 평균 132만톤의 처리 능력과 최신의 분산제어시스템을 갖추고 있다. 응집제로는 PAC를 사용하고 있다. 그림 8은 대상시스템의 정수처리 계통을 나타낸다. 대상 플랜트의 약품주입공정은 Jar-test 기법과 통계적 기법을 병행하고 있으며 약품주입 Flow는 그림 9와 같다.

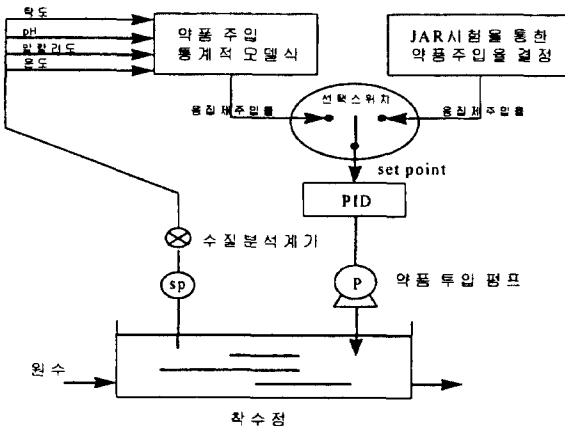


그림 9. 대상 시스템의 응집제 주입 흐름도.  
Fig. 9. The flow of coagulant dosing in the system.

2. 현장실험

시뮬레이션 결과, 모델 II가 응집제 주입공정에 더 효과적임을 알 수 있었다. 따라서 실제 플랜트에서 적용은 모델 II에 대해서 수행되었다.

장마철의 경우 원수의 탁도 변화는 매우 심하다. 따라서 최적 응집제 주입을 설정치의 변경도 매우 자주 발생하고, Jar-test도 매우 자주 하게 된다. 이러한 경우의 현장 실험은 제안된 기법의 성능을 평가하기 위한 필수적 요소이다. 따라서 현장 실험은 원수의 탁도 변화가 매우 심한 장마철(7,8월)에 실제 현장 데이터를 이용하여 실제 필드상에서 수행되었다.

착수정으로 유입되는 원수의 수질 측정 변수(탁도, 알칼리도, pH, 수온 등)와 과거의 Jar-test에 의한 처리수 탁도를 입력변수로 하며 응집제 주입율을 출력 변수로 하는 응집제 주입공정 신경회로망 에뮬레이터로부터 역전파 기법을 이용하여 공정을 학습 제어하는 신경회로망형 공정제어를 수행한다. 최적의 응집제 주입율을 학습을 하여 현재의 유입되는 원수 수질상태(탁도, 알칼리도, pH, 수온)에 최적인 응집제 주입율을 결정한다.

그림 10은 응집제 주입을 자동연산 및 제어를 위한 하드웨어 구성도를 나타낸다. 착수정으로 유입되는 원수의 수질 항목인 탁도, 알칼리도, pH, 수온 값을 센서로부터 읽어 들이고, 또한 침전지의 탁도도 센서로부터 읽어 들인다. 이러한 센서로부터 입력된 값들을 과거의 Jar-test 데이터에 의해 구축된 응집제 주입공정 신경회로망 에뮬레이터의 입력변수로 하여 응집제 주입을 결정한다. 결정된 주입율을 응집제 주입제어기(PID제어기)의 설정치로 설정한다.

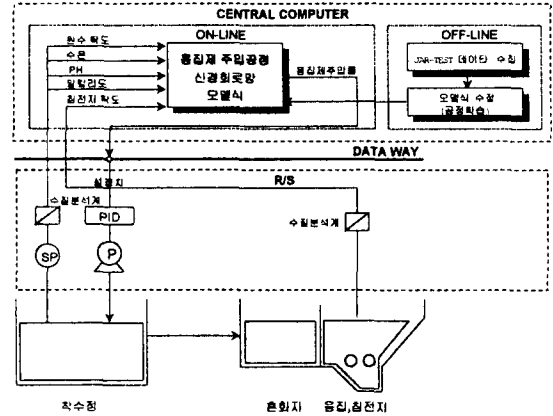


그림 10. 응집제 주입을 자동연산 및 제어를 위한 하드웨어 구조.

Fig. 10. Hardware scheme for fixing coagulant dosing rate in water purification system.

그림 11은 S/W 운영 흐름을 나타낸다. 상위 컴퓨터는 여러가지 프로세스를 수행한다. 응집제 주입 프로세스도 그 중에 하나이다. 프로세스는 일정주기마다 수행되며 한 프로세스가 수행을 마치면 다음 프로세스가 진행된다. 응집제 주입 프로세스의 진행 다음과 같은 식으로 진행된다. 먼저 착수정으로 유입되는 원수의 수질항목인 탁도, 알칼리도, pH, 수온 값을 센서로부터 읽어 들이고, 또한 침전지의 탁도도 센서로부터 읽어 들인다. 이러한 값들을 기초로 응집제 주입공정 신경회로망 에뮬레이터로부터 응집제 주입을 결정한다. 결정된 주입율을 응집제 주입제어기(PID제어기)의 설정치로 설정하고, 이러한 운전 결과 데이터를 저장한다. 또한 주기적으로 Jar-test 데이터를 이용하여 공정을 재학습 하여 모델식을 수정하여 공정의 효율을 증가시킨다.

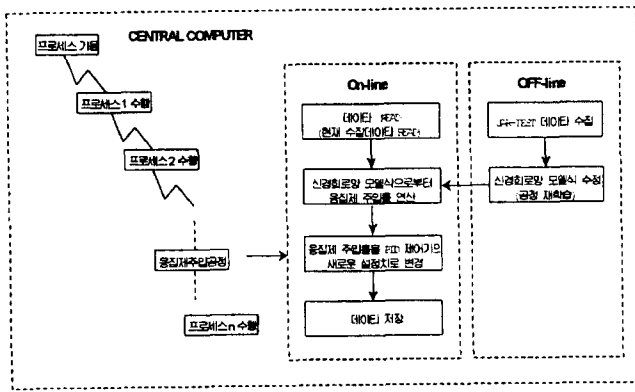


그림 11. 응집제 주입을 자동연산 소프트웨어 운영 흐름도.  
 Fig. 11. The operation flowchart of fixing coagulant dosing rate in water purification system.




그림 12. 실제 주입율과 모델 주입율의 비교(모델 II).  
 Fig. 12. The comparison of the results of actual system and neural network model (NN model II).

이상의 필드 테스트 환경하에서 대상 정수장에 대하여 응집제 주입을 제어를 수행하였다. 실제 주입율과 신경회로망 모델 II로부터 계산된 주입율을 비교하여 그림 12에 나타내었다. (12)에 의해 계산한 % 오차는 97.45%로 거의 실제값과 유사하였다. 그림 12에서 실제 주입율과 계산된 주입율이 약간의 차이를 보이는 부분은 실제 원수의 수질 변화에도 불구하고 실제 주입을 자체가 수정되지 않은 경우로 해석된다. 실제 주입율과 신경회로망 모델 II로부터 계산된 주입율 및 기존의 응집제주입을 공식에 의한 결과치도 같이 비교하여 그림 12에 나타내었다. 기존에 이용되는 응집제주입을 공식은 (13)과 같다.

$$P = (4.03 - 0.05t)A^{0.21}T^{0.36} \quad (13)$$

여기서,  $P$ 는 응집제주입율,  $t$ 는 수온,  $A$ 는 알칼리도,  $T$ 는 탁도를 나타낸다.

**VI. 결론**

본 논문에서는 상수처리시스템의 효율적이고 체계적인 수질제어를 목적으로 상수처리시스템 응집제 주입공정을 신경회로망 기법을 이용하여 모델링 하였고, 구축된 모델로부터 현재 수질 상태에 최적의 응집제 주입율을 설정하는 기법이 제안된다.

제안된 기법은 숙련된 조작자의 지식이 내포된 Jar-test 데이터를 이용하여 모델링함으로써 데이터의 정확성과 모델의 견실성을 증가시켰다. 또한 모델의 입력변수에 처리수 탁도(침전지 탁도) 항목을 추가함으로써 일종의 조작자 모델(Operator Model)과 같은 형태의 모델을 제공함으로써 숙련된 조작자가 하는 것과 같은 효과를 낼 수 있도록 하였다.

제안된 기법 검증을 위하여 대상 플랜트의 운전 데이터를 이용하여 기법의 유용성 및 성능을 검토하였고, 또한 가장 문제가 되는 장마철에 현장 적용 결과 97.45%라는 우수한 결과를 보였다. 또한 정수장 내의 효과적인 통합 운용 소프트웨어를 구현함으로써 장래의 수질변화에 능동적 대응이 가능하도록 하였다. 본 연구에서의 결론은 아래와 같다.

- 1) 신경회로망 모델링은 기존의 방법보다 우수한 모델링 기능을 가짐.
- 2) 효과적인 응집제 주입공정에서, 입력변수로는 원수 탁도, 수온, 알칼리도, pH, 처리수 탁도, 출력변수로 응집제 주입율을 택하는 것이 효과적임.
- 3) 제안된 알고리즘을 약품주입 공정중 알칼리제 주입, NaOH 주입 공정 등에도 활용이 가능.
- 4) 통합 운용 소프트웨어의 제공에 의하여 현장 운전자에 의한 약품주입 공정 최적제어가 가능함.

본 논문에서 제안된 알고리즘은 DCS(Distributed Control System)과 연결된 ACS(Advanced Control Station)내에서 작동되며, 수처리와 같은 명확한 목표치를 갖지 않고, 예측에 따른 제어를 필요로 하는 모든 시스템에 적용이 가능하다.

**참고문헌**

- [1] 박중현 외, 상수도공학, 동명사, 1989.
- [2] O. Yagishita, O. Itoh and M. Sugeno, "Application of fuzzy theory to the control of coagulant injection in a water purification plant," *System and Control*, vol. 28, 1984.
- [3] 김홍석, 김성현, "Jar-test를 이용한 응집제 주입을 결정에 관한 실험 연구," 상수도학회논문지, 제 2호, pp. 39-45, 1993. 6.
- [4] Baba K., Enbutsu I., Matsuzaki H. and Nogita S., "Intelligent support system for water sewage treatment plants which includes a past history learning function - coagulant injection guidance system using neuralnet algorithm instrumentation," *Control and Automation of Water and Wastewater Treatment and Transport Systems*, pp. 227-234. 1994.
- [5] Yagishita and Tanaka, "Estimation of chemicals feed rate by fuzzy reasoning," *34th National Water Service Research Presentation and Lecture Meeting*, pp. 365-367, 1983.
- [6] Baba K., Enbutsu I. and Yoda M., "Explicit representation of knowledge acquired from plant historical data using neural network," *Proceedings of IJCNN '90*, San Diego, 1990.
- [7] Enbutsu I., Baba K. and Hara N., "Fuzzy rule extraction from a multilayered neural network," *Proceedings of IJCNN '91 Seattle*, 1991.
- [8] A. P. Black and Hannah S. A., "Electrophoretic

studies if turbidity removal coagulant with aluminum sulfate, *J. AWWA*, vol. 53, p. 438, 1961.

[9] 조영일, "환경관리의 이론과 계산," *환경과 공해*, vol. 4, no. 1, pp. 1-37, 1981.  
 [10] J. W. Clark, W. Viesman, Jr. and M. J. Hammer, "Water supply and pollution control," *International Textbook Co.*, 1971.  
 [11] 정규영, "수질변화에 대한 정수처리의 실험적 연구," 박사학위논문, 한양대학교 대학원, 1979.  
 [12] 건설부, 상수도 시설기준, 건설부, 1984.

[13] Michael Carney, "European drinking waer standards," *J. AWWA*, vol. 83, no. 6, pp. 48, 1991.  
 [14] O'Melia, CR. et al., "Raw water quality, coagulant selection, and solid-liquid separation," *Preconf. Seminar on Influence of Coagulation on the Selection, Operation, and Performance of Water Treatment Facilities.*, 1987.  
 [15] Van Benschoten, J. E., "Separation and fate of aluminum in water treatment," Univ. of Mass, Amhert, 1988.

**남 의 석**

제어 · 자동화 · 시스템공학회 논문지 제 3권 제 2호 참조.




**장 석 호**

1988년 연세대 전기과 졸업. 동대학원 석사(1990). 1997-현재 연세대학교 전기공학과 박사과정. 관심분야 반도체 공정 자동화, 모델링, 자동제어.

**박 종 진**

제어 · 자동화 · 시스템공학회 논문지 제 3권 제 2호 참조.



**차 상 업**

1991년 연세대 전기과 졸업. 동대학원 석사(1993). 1997-현재 연세대학교 전기공학과 박사과정. 관심분야 공정모델링, 최적화, 인공지능.


**우 광 방**

제어 · 자동화 · 시스템공학회 논문지 제 3권 제 2호 참조.



**한 데 환**

1980년 한양대 전기과 졸업. 동대학원 석사(1986). 1997-현재 LG 산전산업플랜트 영업부장. 충북대 박사과정. 관심분야 공정제어, 공정 모델링.



**이 봉 국**

1983년 인하대 전기과 졸업. 동대학원 석사(1986) 및 박사(1993). 1997-현재 LG산전 연구소 환경플랜트 연구실. 관심분야 인공지능, 공정 자동화, 수운용 제어.



**고 택 범**

1955년 출생. 1981년 연세대학교 전기공학과 졸업(학사). 1983년 연세대학교 전기공학과 졸업(석사). 1983년-1991년 LG 산전 연구소 선임 연구원. 1996년 연세대학교 전기공학과 졸업(박사). 1996년-현재 LG하나웰 연구소 책임연구원. 관심분야 반도체공정제어, 반도체 공정최적화, 신경회로망, 퍼지시스템, 지능제어.