

인공신경망 모형을 이용한 급속혼화공정에서 적정 응집제 주입농도 결정 및 응집처리후 탁도의 예측

정동환 · 박규홍[†]

중앙대학교 토목공학과

Prediction of Turbidity in Treated Water and the Estimation of the Optimum Feed Concentration of Coagulants in Rapid Mixing Process using an Artificial Neural Network Model

Dong-Hwan Jeong · Kyoohong Park[†]

Department of Civil Engineering, Chung-Ang University

(Received 13 August 2004, Accepted 22 October 2004)

Abstract : The training and prediction modeling using an artificial neural network was implemented to predict the turbidity of treated water as well as to estimate the optimized feed concentration of polyaluminium chloride (PACl) in a water treatment plant. The parameters used in the input layers were pH, temperature, turbidity and alkalinity, while those in output layers were PACl and turbidity of treated water. Levenberg-Marquadt method of feedforward back-propagation perceptron in the neural network toolbox of MATLAB program was used in this study.

Correlation coefficients of the training data with the measured data were 0.9997 for PACl and 0.6850 for turbidity and those of the testing data with measured data were 0.9140 for PACl and 0.3828 for turbidity, when four parameters at input layer, 12-12 nodes each at both the first and the second hidden layers, and two parameters(PACl and turbidity) at output layer were used. Although the predictability of PACl was improved, compared to that of the previous studies to use the only coagulant dose as output layer, turbidity in treated water could not be predicted well. Acquisition of more data through several years obtained with the advanced on-line measuring system could make the artificial neural network useful and practical in actual water treatment plants.

keywords : Artificial neural network, Coagulant, Turbidity, Optimization, Rapid mixing

1. 서론

정수장에서 원수의 수질변화에 따른 최적 응집제 주입농도 결정방법은 급속혼화조 운전시의 원수 수질변동에 따라 자테스트(Jar-test) 실험을 통하여 응집제 주입농도를 결정하거나 조절하는 방법이 일반적으로 이용되고 있다. 최근에는 현장에서 응집제 주입후 입자계수기(Particle counter), SCD(Stream current detector), 제타전위 측정장치(Zeta potential detector)를 이용하여 응집제 주입농도를 조절하고 제어하는 방법을 도입하는 단계에 있으며 실용적인 측면에서 그 사용범위가 확대되어 가고 있다. 정수장의 혼화·응집공정은 다양하고 복잡한 물리적·화학적 작용을 거치게 되므로 복합적이고 체계적인 응집제 주입농도를 결정하기 위해 최근 여러 분야에서 연구되고 있는 학습훈련모형인 인공신경망 모형을 도입하는 것에 대해 여러 연구자들이 제안한 바 있다.

인공신경망 모형을 이용한 연구는 상수도 및 정수처리,

하수 및 폐수처리, 하천 수질 및 미생물 관리 등의 물환경 분야에서 다양하게 적용되었다. 상수도 분야에서 급수량(이 등, 1998), 상수도관 노후도(이 등, 2000), THM 등 상수관로 수질(김, 2000) 등을 예측·평가하는 연구가 수행되었다. 하수 및 폐수처리 분야에서는 TOC, COD, 초산, 프로피온산, 부틸산, 메탄 생성(Tay et al., 1999), TOC, 계면활성제, pH, 암모니아, 페놀(Pigram and Macdonald, 2001), 하수처리장으로 들어오는 하수량(EI-Din et al., 2002), 폐수처리공정에서의 TKN(최 등, 2001), COD, SS, 비용(Chen et al., 2001), 고속산화지의 질소 및 인 등의 영양염류(최 등, 2001), 광촉매반응을 이용한 염색폐수 TOC 제거효율(정 등, 2002), pH 중화공정(김 등, 2002), 생물공정의 공정변수 암모니아농도(이, 2000) 등을 예측·평가·감시(monitoring)하는 연구가 수행되었다. 하천 수질관리 분야에서는 하천 수질변화 분석 및 BOD, COD 등의 수질예측(유 등, 2000; 한 등, 1999), 홍수 예·경보 시스템 운영(김 등, 2000) 등의 연구가 수행되었고, 미생물 분야에서는 지표수에서 원생동물 위해도(Neelakantan et al., 2002), 정수장 취수구에서 크립토스포리디움 포낭(Brion et al., 2001) 등을

[†] To whom correspondence should be addressed.

kpark@cau.ac.kr




Fig. 1. Temporal change of temperature of raw water in water treatment plant A in 2002.




Fig. 2. Temporal change of pH of raw water in water treatment plant A in 2002.

예측하는 연구가 수행되었다. 이외에도 대기(Sohn et al., 2000; Djebbar et al., 2002), 토양(Achenie et al., 2001) 등 여러 분야에서 많은 연구가 수행되었다. 환경분야 이외의 인공신경망을 이용한 연구는 전기전자, 식품(Morimoto et al., 1997), 식물(손 등, 1998), 생태, GIS(윤 등, 1996) 등 여러 분야에서 다루어지고 있다.

정수처리 분야에서도 인공신경망 모형을 이용하여 침전지 유출수의 탁도와 alum 주입농도(Zhang et al., 1999), alum, PACI 등 응집제 주입농도(주 등, 1999; 박, 2000; Gagnon et al., 1997; 김, 1996), 정수장에서의 잔류염소 농도(Rodriguez et al., 1999) 등을 예측·평가하는 연구가 수행되었으나, 이러한 연구에서는 응집처리후 탁도를 인공신경망모형의 입력층 매개변수로 놓았을 때 최적 응집제 주입농도를 결정하는 모델링 연구가 많았다. 하지만, 자테스트 실험에 의해 구한 최적 응집제를 주입하는 것은 아직 결정되지 않은 응집처리후 탁도를 가능한 한 최소화하려는 목표를 가지고 있으므로 예측 모델링에서 입력층 매개변수로 사용되기보다는 출력층 매개변수로 고려되어야 한다고 판단되어 본 연구에서는 이를 고려하고자 하였다. 본 연구의 목적은 인공신경망 모형을 이용하여 급속혼화공정의 적정응집제 농도를 결정하고 응집처리후 탁도를 예측하고자 하는 것이다. 즉, 급속혼화공정에 영향을 미치는 원수 수질 인자인 수온, pH, 탁도, 알칼리도를 입력층 매개변수로 사용하고 출력층 매개변수로는 PACI 주입농도 뿐만 아니라 응집처리후 탁도를 사용함으로써, 정수장 운영상의 목표에 더 충실할 수 있는 인공신경망모형의 운용방법론의 유용성을 시험하고자 하였다. 또 기존 연구와 같이 출력층 매개변수를 응집제 주입농도 하나로 놓고 응집처리후 탁도를 원수 수질인자와 함께 입력층 매개변수로 포함시켜 예측 모델링을 수행한 결과를 본 연구의 결과와 비교, 분석하였다.

2. 연구재료와 연구방법

2.1. 원수의 수질인자

A 정수장에서 정수의 수질관리를 위하여 측정하고 있는 원수의 수질인자로는 수온, pH, 탁도, 알칼리도, 전기전도

도, 용존산소, 과망간산칼륨소비량 등이 있으나, 응집제 주입농도에 영향을 미치는 인자로 수온, pH, 탁도, 알칼리도를 선정하였다. A 정수장의 원수는 낙동강 물로 과망간산칼륨소비량을 제외한 탁도, pH, 알칼리도 등이 실시간 측정장치를 이용하여 측정되었다. Fig. 1에서 알 수 있는 바와 같이 원수의 수온은 기온의 계절적 변화와 유사하였는데 이는 기온의 영향을 크게 받기 때문이며, 겨울철인 1월에 가장 낮은 0.8°C, 여름철인 8월에 가장 높은 32.0°C로 나타났다. Fig. 2에서 나타낸 것처럼 원수의 pH는 6.9~9.2의 범위에서 조사되었는데, pH가 봄과 가을에 다소 알칼리성을 띠는 것은 조류의 번식과 광합성에 따라 이산화탄소 가스를 소모하고 산소 가스가 배출되어 물 속에 녹아 pH가 높아지며 여름에는 오히려 pH가 낮은 이유는 집중강우와 흐린 날씨가 조류의 번식과 광합성에 영향을 미친 것으로 판단된다. Fig. 3에 나타낸 것과 같이 원수의 탁도는 강우가 많이 오는 여름철에 다소 높아 8월에 1,200 NTU로 조사되었고, 계절적으로 강우가 오는 것에 따라 탁도가 높게 나타나기도 하였다. Fig. 4에 나타낸 원수의 알칼리도는 탁도의 계절적 변화와는 반대되는 변화를 보여주고 있다. 즉 강우강도가 높아 탁도가 증가할 때 알칼리도는 감소하는 경향을 나타낸다.

2.2. 자테스트 실험

자테스트는 현장에서 원수의 조건변화에 따라 적정 응집제 주입농도를 구하기 위하여 하루에 한번 수행되었다. 준비된 6개의 비이커(jar)에 17±1% PACI을 주입하고 120 rpm으로 1분, 35 rpm으로 5분, 10 rpm으로 5분, 그리고 10분 정치 후 상징액을 채수하여 탁도와 pH를 측정하였다. PACI의 주입농도 단위는 mg/L이며, 알칼리도가 낮은 경우에 부정기적으로 소석회를 주입하여 시험하였다. 응집제의 농도를 다르게 주입한 6개의 비이커에서 탁도가 가장 낮게 조사된 응집제의 농도를 가장 적정한 주입농도로 보았다. 인공신경망 모형에 이용하는 출력층 매개변수의 수질인자인 PACI의 주입농도와 응집처리후 탁도는 2002년 1월 1일부터 11월 26일까지의 자료 330개를 얻었다. Fig. 5에 나타내었듯이 PACI의 주입농도는 11.0~100.0 mg/L로 조사되었으며, pH는 거의 일정하게 6.7~7.7의 범위를 유지하였




Fig. 3. Temporal change of turbidity of raw water in water treatment plant A in 2002.




Fig. 4. Temporal change of alkalinity of raw water in water treatment plant A in 2002.




Fig. 5. Temporal change of feed concentration of PACI at Jar-test.




Fig. 6. Temporal change of turbidity of water treated by feed coagulants.

다. 그리고 Fig. 6에서와 같이 자테스트 응집처리후 탁도는 0.9~2.6 NTU로 조사되었다.

2.3. 인공신경망 모형의 실행

인공신경망(Feedforward back-propagation neural network) 모형의 실행을 위해 매트랩(Matlab) 프로그램을 이용하였는데, 예비시험 결과 전방향 인공신경망의 급속경사법식중 가장 좋게 결과가 도출된 레벤버그-마퀴트 방법(Levenberg-Marquadt method)을 이용하였다. 활성화함수(Activation function or Transfer function)는 선형, 로지스틱(Log sigmoid, Hyperbolic tangent) 함수 등 다양하지만 식 (1)과 같이 예비 시험결과 좋은 결과를 보인 로지스틱 함수(Logsig, Logistic function)를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

역전파 신경망모형에서 출력층 노드와 로지스틱-시그모이드 활성화 함수의 경우에 대하여 오차 항목은 다음 식 (2)와 같이, 은닉층의 노드에 대하여는 식 (3)과 같이 계산된다.

$$\delta_{pi} = (t_{pi} - \alpha_{pi}) \alpha_{pi} (1 - \alpha_{pi}) \quad (2)$$

$$\delta_{pi} = \alpha_{pi} (1 - \alpha_{pi}) \sum_k \delta_{pk} w_{kj} \quad (3)$$

여기서 δ 는 각 노드에 대한 오차항목, t 는 신경망 목표값, α 는 각 노드에 대한 활성화값 또는 출력데이터, w 는 각 노드의 가중치이다. 후반부 표현에서 기호 k 는 아래 방향의 층(출력층 방향으로의 층)에서 모든 노드에 대한 합을 말한다. 기호 i, j 는 각 노드에서 가중치 위치를 말한다. 마지막으로 각 노드에 대한 δ 와 α 는 항목은 증가분을 각 가중치 항목에 계산하기 위하여 사용된다.

$$\Delta w_{ij} = \epsilon (\delta_{pi} \alpha_{pi}) + m w_{ij}(\text{old}) \quad (4)$$

식 (4)에서 항목 ϵ 는 학습률로서 언급되었고, 반복학습 중에 가중치 조정의 크기를 결정한다. 항목 m 은 모멘텀 요소이다.

프로그램을 운용하는데 많은 변수가 있는데, 반복회수, 학습율, 입력층 및 출력층 매개변수의 수, 은닉층의 수 및 뉴런(Node)의 수, 목표 평균제곱오차 등을 변경하여 프로그램을 실행하였다. 주 프로그램은 직접 설계하였으며 필요한 m.file(Trainlm)과 함수(Function)는 주어진 매트랩 프로그램을 이용하였다. 본 연구를 위해 사용된 컴퓨터의 사양은 Pentium III PC로 CPU 속도는 500 MHz이고 RAM은 256 MB이었다.

입력 데이터는 모델링을 실행하기 위하여 얻어진 330개의 데이터를 학습 데이터(Training data) 220개와 검증 데이터(Testing data) 110개로 구분하였는데, 검증 데이터는

실험개시후 3일 간격으로 구분하여 3일중 마지막 1일을 선택하여 사용하였다. 응집제 주입농도와 응집처리후 탁도를 평가하기 위해 두 가지 경우로 나누어 실행하였는데, 먼저 입력층 매개변수가 5개이고 출력층 매개변수가 1개인 경우 최대반복회수는 5,000회, 학습율은 0.01, 은닉층 수는 2개, 뉴런(노드) 수는 은닉층별로 12-8개, 목표 평균제곱오차(MSE, Mean squared error)은 0.01로 입력하였다. Fig. 7에 나타낸 바와 같이 5,000회 반복하여 계산하였으나 목표 평균제곱오차에 도달하지 못하여 1.0098의 평균제곱오차를 얻었으며, 실행시간은 39.8분이 걸렸다. 두 번째의 경우 입력층 매개변수가 4개이고 출력층 매개변수가 2개였는데, 최대반복회수는 2,000회, 학습율은 0.01, 은닉층 수는 2개, 뉴런 수는 은닉층별로 12-12개, 목표 평균제곱오차는 0.01로 입력하였다. Fig. 8에 나타낸 바와 같이 2,000회 반복하여 계산한 후 평균제곱오차는 0.0756로 목표값에 도달하지 못하였으며, 실행시간은 53.9분이 걸렸다. 목표 평균제곱오차에는 도달하지 못하였지만 각각 5000회, 2000회 계산 후에 모형실행을 종료한 것은 반복회수를 높이더라도 수렴속도가 떨어져서 모형실행에 많은 시간이 소요되기 때문이다.

오차계산식에 따른 적합도 평가를 위해 시계열 자료 분석에서 오차 판단기준으로는 많이 사용되고 있는 평균제곱오차를 이용하였으며 식 (5)과 같다. 또한 측정값과 모델링 결과에 대한 예측값을 비교하기 위하여 식 (6)의 상관계수를 이용하였다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - a_i)^2 \quad (5)$$

$$R = \sqrt{\frac{\sum_{i=1}^n (t_i - a_i)^2}{\sum_{i=1}^n (t_i - \bar{a}_i)^2}} \quad (6)$$

여기서, MSE는 평균제곱오차, n은 데이터 개수, t_i 는 목표값, a_i 는 출력 데이터를 말한다. 또한 R은 상관계수이

고, \bar{a}_i 는 출력데이터의 평균값이다.

3. 결과 및 고찰

본 연구에서는 입력층 매개변수는 원수의 pH, 수온, 탁도, 알칼리도, 그리고 출력층 매개변수는 PACI 주입농도를 기본으로 하고, 응집처리후 탁도를 입력층 매개변수로 놓고 모델링을 실행했을 때의 결과와 응집처리후 탁도를 출력층 매개변수로 놓고 모델링을 실행했을 때의 결과를 비교하여 평가하였다. 입력층과 출력층의 매개변수를 정한 후에도 인공신경망모형을 실행하기에 앞서 은닉층의 수와 각 은닉층에 대한 뉴런의 수를 설정하기 위해 여러 경우에 대해 학습 예측 모형을 수행하는 예비시험 과정이 진행되었으나, 그 과정의 결과에 대하여는 지면상의 제약으로 생략하고자 한다.

먼저 5개의 입력층 매개변수(pH, 수온, 원수 탁도, 알칼리도, 응집처리후 탁도)와 1개의 출력층 매개변수(PACI 주입농도)를 이용하고 2개의 은닉층과 각각 12개 및 8개의 뉴런을 갖는 인공신경망모형에 학습시킨 결과, PACI 주입농도의 학습데이터와 차테스트 데이터 사이의 상관계수가 0.9972로 가장 높게 나타났고, PACI 주입농도의 예측 데이터와 차테스트 데이터 사이의 상관계수는 0.9771로 나타났

Table 1. Correlation coefficient of PACI and turbidity after modeling an ANN

Classification	Correlation coefficient	
	Training data(220)	Testing data(110)
PACI (5-12-8-1) [†]	0.9972	0.9771
PACI (4-12-12-2) [‡]	0.9997	0.9140
Turbidity (4-12-12-2) [‡]	0.6850	0.3828

[†] Input parameters: 5; Node numbers of 1st-2nd hidden layer: 12-8; Output parameter: 1

[‡] Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2




Fig. 7. Variation of MSE during training (Input parameters: 5; Node numbers of 1st-2nd hidden layer: 12-8; Output parameter: 1).




Fig. 8. Variation of MSE during training (Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2).

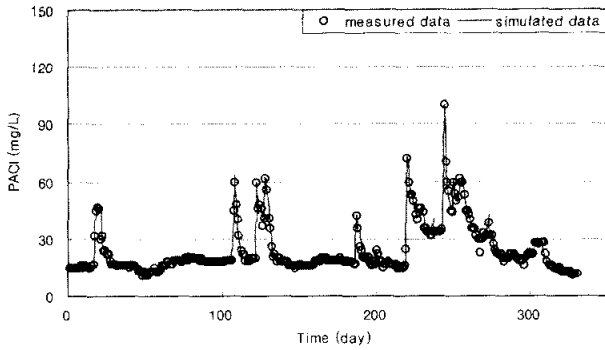


Fig. 9. Simulation results for PACI by feedforward back-propagation method (Input parameters: 5; Node numbers of 1st-2nd hidden layer: 12-8; Output parameter: 1).

다(Fig. 9~Fig. 10, Table 1). Fig. 9에 나타난 시뮬레이션 결과를 학습 및 예측 데이터로 구분하지 않고 연속시간 순으로 그래프를 나타내었는데, Fig. 10을 참고하면 220개에 해당되는 PACI 주입농도의 학습데이터는 시간의 경과에 따라 측정값과 학습데이터가 잘 일치하는 것을 보여주고 있으며, 110개의 측정데이터와 이에 대한 예측데이터가 잘 일치하는 것을 보여주고 있다. Fig. 10은 PACI 주입농도의 목적데이터와 학습데이터 또는 시험데이터 사이의 편차를 나타낸 것으로 8월과 9월에 5 mg/L 이상의 편차를 갖는 데이터 6개 정도를 제외하고는 전반적으로 매우 잘 일치됨을 알 수 있다.

두번째, 4개의 입력층 매개변수(pH, 수온, 원수 탁도, 알칼리도)와 2개의 출력층 매개변수(PACI 주입농도, 응집처리후 탁도)를 이용하여 인공신경망 모형(2개의 은닉층과 각 은닉층에 12개의 뉴런을 사용함)을 적용한 결과를 PACI 주입농도에 관한 것은 Fig. 11과 12에, 응집처리후 탁도에 관하여는 Fig. 12와 14에 나타내었다. Fig. 11에 나타난 모델링 결과에 따르면, 화살표의 좌측에 표시된 PACI 주입농도의 학습데이터는 시간의 경과에 따라 PACI 주입농도의




Fig. 11. Simulation results for PACI by feedforward back-propagation method (Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2).

측정값과 학습데이터의 관계가 잘 일치하는 것을 보여주고 있다. PACI 주입농도의 학습데이터와 자체 테스트 데이터 사이의 상관계수가 0.9997로 가장 높게 조사되었으며, PACI 주입농도의 예측 데이터와 자체 테스트 데이터 사이의 상관계수는 0.9140로 나타내었다. 은닉층의 수와 각 은닉층에 대한 뉴런의 수를 변경함으로써 이러한 상관계수의 변화가 있는지 여러 경우를 조사하여 보았으나, 그리 개선되지 않았다(본 논문에는 이러한 결과들을 제시하지 않았다). Fig. 12의 PACI 주입농도의 학습데이터와 목적데이터 또 시험데이터와 목적데이터 사이의 편차를 나타낸 그림에서 5 mg/L 이상의 예측편차를 보이는 데이터 수가 30여개이지만 상관계수는 0.9997과 0.9140으로써, 4개의 입력층 매개변수와 1개의 출력층 매개변수를 사용한 인공신경망모형의 예측 상관계수보다 향상된 것을 알 수 있었다. 하지만, 출력층 매개변수를 PACI 주입농도 외에 응집처리후 탁도를 사용한 만큼, PACI 주입농도의 예측이 우수해진 것만으로 새로운 인공신경망모형의 적용이 성공적이라고 판단할 수는 없으며, 응집처리후 탁도의 예측에 관한 목적데이터와의 일치도를 함께 검토해야 한다.





Fig. 10. Deviation between target data and training(a) or testing(b) data for PACI (Input parameters: 5; Node numbers of 1st-2nd hidden layer: 12-8; Output parameter: 1).

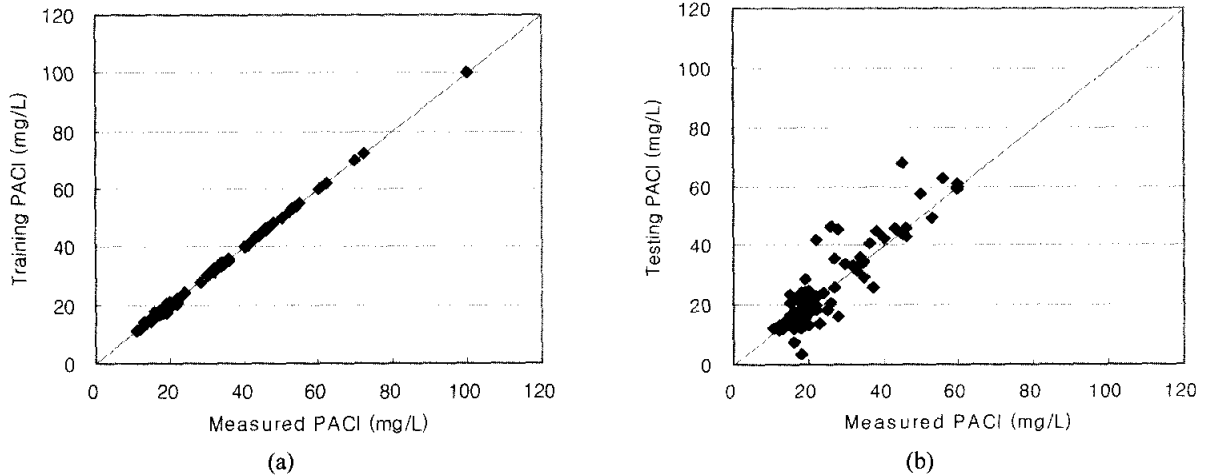


Fig. 12. Deviation between target data and training(a) or testing(b) data for PACI (Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2).




Fig. 13. Simulation results for turbidity by feedforward back-propagation method (Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2).

Fig. 13과 14에 나타내었듯이 응집처리후 탁도의 학습데이터와 예측데이터가 측정데이터와 잘 일치하지 않는 경우가 많은 것을 알 수 있다. Fig. 14는 응집처리후 탁도에 관

한 목적데이터와 학습데이터 또는 예측데이터의 편차를 나타낸 것이며, 또 Table 1은 이 때의 응집처리후 탁도의 학습데이터와 측정데이터의 상관계수가 0.6850이고, 응집처리후 탁도의 예측데이터와 측정데이터간의 상관계수가 0.3828임을 보여준다. 응집처리후 탁도에 관한 상관계수가 이렇게 저조함을 고려하여 판단할 때, 출력층 매개변수로 응집제 주입농도 뿐만 아니라 응집처리후 탁도를 포함하여 인공신경망 모형을 적용한 경우, 응집제 주입농도의 목적데이터와 학습데이터 또는 예측데이터간의 일치도가 증가하는 반면 응집처리후 탁도에 관한 일치도는 매우 감소하는 것을 알 수 있었다.

본 연구를 통해 출력층 매개변수로 PACI 주입농도와 응집처리후 탁도를 동시에 고려하였을 경우 응집처리후 탁도의 예측 데이터와 자테스트 데이터 사이의 상관계수(0.3828)가 저하된 이유로는, 자테스트 실험을 통해 구한 적정 응집제 주입농도와 실제 정수장의 현장에서 응집제를 주입하는 농도가 동일하지 않은 때가 많고, 계절에 따라 원수의 수질변화가 크기 때문에 자테스트 실험을 실시할 때마다

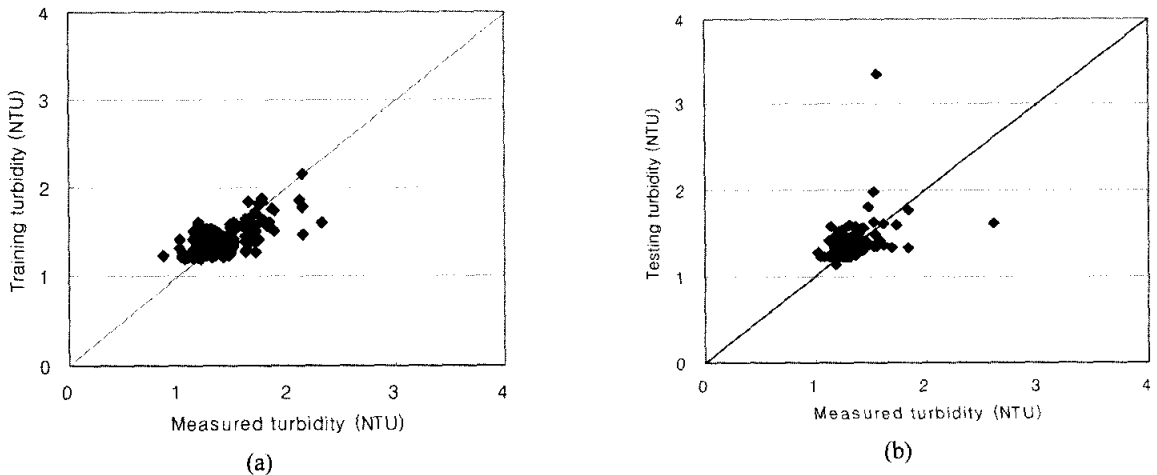


Fig. 14. Deviation between target data and training(a) or testing(b) data for turbidity (Input parameters: 4; Node numbers of 1st-2nd hidden layer: 12-12; Output parameters: 2).

응집처리후 탁도의 경향이 서로 다르기 때문으로 판단된다. 즉, 정수장에서 현재 수행되고 있는 자테스트 실험은 현장의 여러 조건들을 제대로 반영하기 어려운 것으로 보이며, 실험자의 판단에 의해 수동으로 최적 응집제 주입농도가 결정되기 때문에 현장에서 주입되는 응집제 농도와 차이가 있는 것으로 보인다. 또한, 자테스트 실험에서 알칼리도가 낮은 경우에 알칼리도를 높이기 위하여 응집보조제로서 소석회 또는 수산화나트륨을 주입하는 경우가 있는데, 본 연구에서는 주 응집제인 PACI 주입농도만을 매개변수로 고려한 것도 상관관계가 낮은 것에 기여하였다고 판단된다. 이러한 이유로 입자계수기·SCD·제타전위측정장치를 이용한 복합적이고 체계적인 응집제 주입농도 결정방법이 요구되고 있는 상황이며, 인공신경망 모형을 이들 측정장치에서 얻어진 데이터와 결합하여 실행할 경우 더욱 진보된 정수장 운영·제어를 위한 효과적인 방법론이 제시될 것으로 기대된다. 더욱이, Fig. 7과 8에 나타낸 바와 같이 인공신경망 모형의 실행을 위해 설정한 목표평균제곱오차에 도달하지 않고 최대반복계산회수에 도달하여 계산을 멈춘 것을 고려할 때, 본 연구에서 입력층 매개변수로 사용한 pH, 수온, 원수 탁도, 알칼리도 외에 입자의 크기, stream current, 제타전위 등의 매개변수가 추가될 경우 최대반복계산 횟수 내의 계산으로 목표평균제곱오차 이내의 오차값을 갖는 더욱 개선된 예측도를 갖는 인공신경망 모형의 응용이 가능하게 될 것으로 추정된다.

두 번째 이유로는 1월부터 11월말까지의 자료로 약 1년 정도의 자료를 학습자료 220개와 예측(Testing) 자료 110개로 나누어 실시하였기 때문에 계절적 변화가 심한 원수의 특성을 반영하지 못할 수 있을 것으로 판단된다. 즉, 장마기간의 강우로 인한 특이한 데이터가 학습용으로 사용되었으나, 8월과 9월에 단기적으로 발생했던 이상강우로 인해 수질특성을 정확히 예측하는 데에 한계가 있을 개연성이 있다. 이러한 특성을 반영하기 위해서는 3~4년간의 원수 및 응집처리후 수질과 응집제(PACI) 주입농도 데이터를 확보함으로써, 2~3년간의 데이터를 학습자료로 이용하고 나머지 1년간의 데이터를 이용할 경우 그 예측도가 많이 개선될 여지가 있을 것으로 판단되며 이에 관한 추후 연구가 기대된다.

4. 결론

본 연구에서는 출력층 매개변수로 응집처리후 탁도와 PACI 주입농도를 고려한 것으로, 입력층 매개변수는 pH, 수온, 탁도, 알칼리도를 사용한 인공신경망모형을 시험하였다. 기존의 연구와 같이 처리후 탁도를 입력층 매개변수에 포함시키고 출력층 매개변수로 PACI 주입농도만을 사용하여 모형을 실행했을 때의 결과와 본 연구의 결과를 비교하여 평가하였다.

본 연구에서는 맷랩 프로그램의 신경망 툴박스에서 전방향 오차역전파 퍼셉트론의 레벤버그-마퀴트 방법을 이용하였다. 출력층 매개변수가 PACI 주입농도 1개인 경우 기

존의 연구와 유사한 결과를 얻었다. 하지만 출력층 매개변수로 PACI 주입농도 외에 응집처리후 탁도를 사용한 경우, PACI 주입농도의 학습데이터 상관계수는 0.9997, 응집처리후 탁도의 학습데이터 상관계수는 0.6850로 조사되었다. 예측 데이터의 상관계수는 PACI 주입농도의 경우 0.9140, 처리후 탁도의 경우 0.3828로 조사되었다. 목적데이터에 대한 PACI 주입농도의 학습데이터, 예측데이터의 상관계수는 기존 연구에 비해 향상된 것을 확인할 수 있었으나, 응집처리후 탁도의 학습데이터와 예측데이터의 상관계수는 매우 저조한 것으로 나타났다. 정수장에서 현재 수행되고 있는 자테스트 실험은 현장의 여러 조건들을 반영하기 어려운 것으로 보이며, 또한 계절적 변화가 심한 원수의 특성을 반영하기도 어렵고 최근의 이상강우 현상이 잦은 경우는 더욱 그러할 것으로 판단된다. 이런 측면에서 현재 사용한 원수 수질자료와 자테스트 실험 데이터만으로 만족할 만한 인공신경망모형의 응용에는 한계가 있는 것으로 판단되었다. 이러한 현장의 어려운 점을 극복하고 정수처리 효율을 개선하기 위해서는 정수장에 최근 개발된 입자계수기, SCD, 제타전위 측정장치 등의 온라인화된 수질측정시스템을 구축하고 인공신경망모형을 이용하여 응집조건에 관여하는 과거 다년간의 데이터를 수집하고 여러 매개변수를 활용하여 최적 응집제 주입농도를 결정하는 방법론의 개발과 실제 응용이 기대된다.

참고문헌

김종대, 유민수, 퍼지신경망을 이용한 pH 중화공정의 적응 제어 시스템, *공업화학*, **13**(6), pp. 544-550 (2002).
 김주환, 상수 관로계통에서 수질예측을 위한 신경망 모형의 적용, *한국수처리기술연구회지*, **8**(4), pp. 17-27 (2000).
 김중효, 이연길, 박성천, 이관수, 수위결측치 보안을 위한 인공신경망 이론의 적용, *대한토목학회 학술발표회 논문집*, pp. 95-98 (2000).
 김창중, Neural network-based coagulant dosing process in water treatment plant, *수원대학교 산업기술연구소 논문집*, **11**, pp. 83-88 (1996).
 박보영, 신경망이론을 이용한 응집제 주입율 결정 모델에 관한 연구, *전남대학교 토목공학 석사학위논문* (2000).
 손기철, 민덕기, 김미경, 박호준, 신경회로망을 이용한 파키라(Parchira aquatic)의 환경변화에 따른 증산 및 광합성량 예측 모델링, *한국원예학회지*, **39**(6), pp. 854-857 (1998).
 유병로, 한양수, 연인성, 신경망모형을 이용한 하천의 BOD 예측, *대전산업대학교논문집*, **17**, pp. 191-199 (2000).
 윤홍주, 김동술, 오종민, GIS와 신경망을 이용한 공간분석, *대한환경공학회 '96 춘계학술연구발표회 논문집*, pp. 125-127 (1996).
 이경훈, 문병석, 오창주, 역전파 알고리즘을 이용한 상수도 일일 급수량 예측, *대한상하수도학회지*, **12**(4), pp. 43-52 (1998).
 이동수, 신경회로망을 이용한 정수플랜트 약품주입 운전제어에 관한 연구, *한양대학교 산업대학원 석사학위논문* (1998).
 이종일, 인공신경망 제어기에 의한 생물공정에서 암모니아

- 농도의 제어, *한국생물공학회 2000년도 춘계학술발표회 초록집*, pp. 173-176 (2000).
- 이창용, 김용석, 신현석, 김중훈, 확률적 신경망을 이용한 상수도관 노후도 추정에 관한 연구, *대한토목학회논문집*, **20(2-B)**, pp. 197-210 (2000).
- 정효준, 조일형, 이홍근, 인공신경망을 이용한 TiO_2 및 H_2O_2 의 유기물 제거효율 평가, *대한환경공학회지*, **24(10)**, pp. 1785-1795 (2002).
- 주대성, 최동진, 박희경, 인공신경회로망을 이용한, 응집제 최적 주입률 결정, *한국물환경학회지*, **15(1)**, pp. 23-30 (1999).
- 최동진, 박희경, 혼합신경망 모델을 이용한 폐수처리공정의 수질인자의 추정, *한국물환경학회지*, **17(1)**, pp. 87-98 (2001).
- 최우택, 임봉수, 김태웅, 고속산화지에서 영양염류 제거효율 예측을 위한 신경망 입력인자의 선택, *대한상하수도학회지*, **15(2)**, pp. 156-162 (2001).
- 한재석, 김만식, 하천수계의 장기수질예측을 위한 신경망모형, *한국환경관리학회지*, **5(1)**, pp. 145-152 (1999).
- Achenie, L., Butkus, M. A., Grasso, D., Schulthess, C. P., Morris, T., and Hyde J., A comparative study of neural network and mechanistic models for surface complexation, *Advances in Environmental Research*, **5(2)**, pp. 137-143 (2001).
- Brion, G. M., Lingireddy, S., and Neelakantan T. R., Using neural networks to predict peak *Cryptosporidium* concentrations, *Journal of American Water Works Association*, **93(1)**, pp. 99-105 (2001).
- Chen, W. C., Chang, N. B., and Chen J. C., Advanced hybrid fuzzy-neural controller for industrial wastewater treatment, *Journal of Environmental Engineering*, **127(11)**, pp. 1048-1059 (2001).
- Djebbar, Y. and Narbaitz, R. M., Neural network prediction of air stripping KLa, *Journal of Environmental Engineering*, **128(5)**, pp. 451-460 (2002).
- El-Din, A. G. and Smith, D. W., A neural network model to predict the wastewater inflow incorporating rainfall events, *Water Research*, **36(5)**, pp. 1115-1126 (2002).
- Gagnon, C., Grandjean, B. P. A., and Thibault, J., Modelling of coagulant dosage in a water treatment plant, *Artificial Intelligence in Engineering*, **11(4)**, pp. 401-404 (1997).
- Morimoto, T., De Baerdemaeker, J., and Hashimoto, Y., An intelligent approach for optimal control of fruit-storage process using neural networks and genetic algorithms, *Computers and Electronics in Agriculture*, **18(2-3)**, pp. 205-224 (1997).
- Neelakantan, T. R., Lingireddy, S., and Brion, G. M., Effectiveness of different artificial neural network training algorithm in predicting protozoa risks in surface waters, *Journal of Environmental Engineering*, **128(6)**, pp. 533-542 (2002).
- Pigram, G. M. and Macdonald, T. R., Use of neural network models to predict industrial bioreactor effluent quality, *Environmental Science and Technology*, **35(1)**, pp. 157-162 (2001).
- Rodriguez, M. J. and Sérodes, J. B., Assessing empirical linear and non-linear modelling of residual chlorine in urban drinking water systems, *Environmental Modelling & Software*, **14(1)**, pp. 93-102 (1999).
- Sohn, S. H. Oh, S. C., Jo, B. W., and Yeo, Y. K., Prediction of ozone formation based on neural network, *Journal of Environmental Engineering*, **126(8)**, pp. 688-696 (2000).
- Tay, J. H. and Zhang, X. Y., Neural fuzzy modeling of anaerobic biological wastewater treatment systems, *Journal of Environmental Engineering*, **125(12)**, pp. 1149-1159 (1999).
- Zhang, Q. and Stanley, J. S., Real-time water treatment process control with artificial neural network, *Journal of Environmental Engineering*, **125(2)**, pp. 153-160 (1999).