

정수장 전염소 공정 제어를 위한 침전지 잔류 염소 농도 예측모델 개발

Prediction Models of Residual Chlorine in Sediment Basin to Control Pre-chlorination in Water Treatment Plant

이경혁 · 김주환* · 임재림 · 채선하

Kyung-Hyuk Lee · Ju-Hwan Kim* · Jae-Lim Lim · Seon Ha Chae

한국수자원공사 수자원연구원

(2007년 8월 2일 논문 접수; 2007년 8월 20일 최종 수정논문 채택)

Abstract

In order to maintain constant residual chlorine in sedimentation basin, It is necessary to develop real time prediction model of residual chlorine considering water treatment plant data such as water qualities, weather, and plant operation conditions. Based on the operation data acquired from K water treatment plant, prediction models of residual chlorine in sediment basin were accomplished. The input parameters applied in the models were water temperature, turbidity, pH, conductivity, flow rate, alkalinity and pre-chlorination dosage. The multiple regression models were established with linear and non-linear model with 5,448 data set. The correlation coefficient (R) for the linear and non-linear model were 0.39 and 0.374, respectively. It shows low correlation coefficient, that is, these multiple regression models can not represent the residual chlorine with the input parameters which varies independently with time changes related to weather condition. Artificial neural network models are applied with three different conditions. Input parameters are consisted of water quality data observed in water treatment process based on the structure of auto-regressive model type, considering a time lag. The artificial neural network models have better ability to predict residual chlorine at sediment basin than conventional linear and nonlinear multi-regression models. The determination coefficients of each model in verification process were shown as 0.742, 0.754, and 0.869, respectively. Consequently, comparing the results of each model, neural network can simulate the residual chlorine in sedimentation basin better than mathematical regression models in terms of prediction performance. This results are expected to contribute into automation control of water treatment processes.

Key words: Pre-chlorination, Residual chlorine prediction, Multiple regression model, Neural network model

주제어: 전염소, 잔류염소 예측, 중회귀모형, 신경망모형

1. 서 론

현재 국내 정수장에서 소독 공정은 대부분 염소를 이용하여 실시하고 있으며 염소 공정은 투입 위치에 따라 전염소, 중염소, 후염소 공정으로 분류된다. 이 중 후염소 공정의 경우 최종 정수 처리된 물에 대한 소독 및 배급수 관망에서 염소의 잔류 농도를 유지하기 위하여 실시한다. 정수장 원수에 대해 염소를 투입하는 전염소 공정의 경우 국내 정수장의 약 43%정도가 실시중인 것으로 조사되었으며 전염소 공정을 실시하는 목적은 정수장의 상황마다 다양하다(윤 등, 2001). 우선 전염소는 조류의 제거를 위해 적용될 수 있다. 전염소 처리 후 일부 조류에서는 응집, 침전 공정에서 제거율이 높아질 수 있다(전 등, 2001). 또한 전염소는 원수 내 철, 망간, 암모니아 등의 처리에 적용될 수 있다. 하지만 실제 정수장에서 전염소 공정을 실시하는 주된 목적은 침전지에서 생기는 부착성 조류 및 이끼류의 제거 하는 것이며, 또한 후염소 공정에서 일정한 잔류 염소 농도를 안정적으로 유지시키기 위해 전염소 공정에서 염소 요구량을 미리 감소시키는 목적이 있다. 하지만 전염소 공정으로 침전지까지 잔류 염소농도를 일정하게 유지하기가 현실적으로 매우 어렵다. 이유는 원수의 수질이 변화하며 수온 등의 환경의 변화에 의해 염소 소비량이 변하며, 유입 원수의 유량이 일정하지 않을 경우 염소 투입 지점부터 침전지 유출부분까지의 수리학적 체류시간 또한 변하기 때문에 이를 예측하기가 어려운 실정이다.

현재 정수처리 과정에서 염소 농도를 예측하는 모델의 개발은 국내외적으로 배급수 관망에서 잔류 염소 예측에 한정되어 모델 개발이 진행되어 왔다.(하성룡, 박상영, 1999, Broad et al., 2005) 하지만 전염소 공정을 목적으로 하는 침전지내 잔류 염소 농도 연구는 활발히 진행되고 있지 않다. 따라서 본 연구에서는 정수장 침전지 유출수에서 잔류 염소 농도를 일정하게 유지시키기 위한 전염소 투입량을 예측하기 위하여 현장에서 연속 측정이 가능하면서 염소 분해 속도에 영향을 주는 인자들을 이용하여 침전지 유출수의 잔류 염소 농도를 예측하기 위한 모델을 개발하였다.

2. 적응이론

2.1. 중회귀 모형

중회귀 모형(Multiple Regression Model)은 2개 이상의 독립변수를 사용하여 종속변수 y 를 산정하는 방법으로 선형다중회귀모형과 지수형 다중회귀모형 등 여러 가지 형태의 관계가 가능하다. 본 연구에서는 선형과 지수형 모형을 모두 검토하였으며, 모형의 일반식은 다음과 같이 표현된다.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1)$$

$$y = \beta_0 \cdot x_1^{\beta_1} \cdot x_2^{\beta_2} \cdot \dots \cdot x_n^{\beta_n} \quad (2)$$

여기서, $\beta_0, \beta_1, \dots, \beta_n$ 는 중회귀 분석을 통해 산정되는 매개변수이며, x_1, x_2, \dots, x_n 는 독립변수, ϵ 은 잔차, 그리고 y 는 종속변수를 나타낸다.

2.2. 신경망 모형

신경망은 인간의 두뇌를 수학적으로 모사한 모형이며, 가장 광범위하게 사용되어온 신경망 모형은 Rumelhart et al.(1986)에 의해 소개된 다층퍼셉트론(Multi-Layer Perceptron) 신경망이다. 신경망 이론을 이용한 모형의 개발은 회귀모형과 같은 특별한 구조나 매개변수의 산정 및 자료의 변화 등이 필요치 않고 자료의 축적에 따라 모형의 능력을 향상시킬 수 있는 장점을 가지고 있다.

다층퍼셉트론은 여러 개의 처리소자를 각 계층, 즉 입력자료를 받아들이는 입력층과, 결과를 나타내는 출력층 그리고 두 개의 층 사이에 중간층을 두어 각 패턴마다 필요한 정보를 학습시킬 수 있도록 한 것이다. 각 층을 구성하는 뉴런은 뉴런간의 연결강도를 합해주는 결합함수와 자료의 범위에 따라 뉴런의 동작범위를 결정해 주는 전달함수(Transfer Function)로 구성된다. 입력자료와 출력자료의 비선형 관계를 구축하기 위한 신경망 즉, 다층퍼셉트론의 학습방법으로는 여러 가지 알고리즘이 있으나 본 연구에서는 역전파 알고리즘(Back Propagation: BP)을 사용하였다. 다층퍼셉트론의 각 층을 구성하는 뉴런은 뉴런간의 연결강도를 합해주는 결합함수와 자료의 범위에 따라

뉴런의 동작범위를 결정해 주는 전달함수로 구성되어 있는데 본 연구에서는 식 (3)의 형태로 표현되는 시그모이드(Sigmoid) 함수를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

역전과 알고리즘은 입력패턴과 출력패턴의 집합으로 구성되는 학습패턴을 신경망에 입력하여 계산값과 관측값의 차이가 설정된 오차의 범위까지 최소화 하도록 모형의 매개변수인 각 층간의 가중치를 변화시켜 가는 방법으로 식 (4)와 같이 제곱오차의 합이 최소가 되는 방향으로 반복적으로 진행되어 신경회로망 모형의 연결강도를 최적화시킴으로써 모형을 적용시켜 나가는 것이다.

$$E_p = \frac{1}{2} \sum_{k=1}^l (y_{pk} - o_{pk})^2 \quad (4)$$

여기서, y_{pk} 는 p 번째 입력패턴에 대한 k 번째 처리소자의 관측값이며 o_{pk} 는 p 번째 입력패턴에 대한 출력층의 k 번째 처리소자의 출력값이다. 하나의 패턴 p 에 대한 오차 E_p 와 모든 패턴에 대한 총오차를 최소화 시킨다. 총오차를 최소화시키기 위한 연결강도의 조정은 p 번째 패턴의 입력값 x_p 와 출력층의 델타값 δ_{pk} 에 의하여 다음과 같이 표현된다.

$$\Delta W = \eta \delta_{pk} x_p \quad (5)$$

각 층간의 연결강도는 위 식으로 표현되는 현재 단계에서의 조정량과 전 단계에서의 조정량 ΔW 에 모멘텀(momentum) 상수 α 를 곱하여 다음 식 (6)와 같이 조정된다.

$$\Delta W(t+1) = \eta \delta_{pk} x_p + \alpha \Delta W(t) \quad (6)$$

여기서 t 는 반복회수, η 는 학습율, α 는 모멘텀 상수를 나타내며 반복과정에서 다음단계의 반복을 위해 조정된 연결강도는 다음 식 (7)에 의해 계산된다.

$$W(t+1) = W(t) + \Delta W(t) \quad (7)$$

또한 중간층과 출력층간 연결강도의 조정도 입력층과 중간층간의 조정방식과 유사하게 진행되며 이 과정은 신경망이 안정될 때까지 또는 목적함수가 허용오차의 범위내에 이를 때까지 반복된다.

3. 실험자료 분석 및 적용

3.1. 실험 대상

본 연구에서는 국내 K정수장을 대상으로 전염소 투입시 수질 및 수량 조건 변화에 따른 침전지 유출수의 잔류 염소 농도를 예측하기 위한 모델을 수립하고 평가하였다. K정수장은 시설 용량 70만톤/일 규모의 정수장으로 Y댐의 저류수를 원수로 이용하고 있다. 하천수에 비해 상대적으로 원수의 수질 변화가 적은 댐수를 사용하나 전염소 공정으로 침전지에서의 잔류 염소를 일정하게 제어하기 위해 실시간으로 정수장 운영자가 경험에 의해 염소 투입량을 조절하고 실정이다.

3.2. 자료 분석

수중에 잔류하는 염소 분해에 영향을 미치는 인자는 다양하다. 이 중 대표적인 인자로는 탁도, 유기물 농도, pH, 온도, 체류시간(유입 유량), 염소 주입량 등이 있다(Uber 등, 2003). 본 연구에서는 현장에서 자료 모니터링이 가능하면서 염소 소비 특성과 관련 있는 측정 인자들을 선정하여 염소 소비 특성을 평가하였다. 현장에서 모니터링이 가능한 수온, pH, 탁도, 전기전도도, 알칼리도, 유입 유량 및 전염소 주입량을 본 연구의 입력 변수로 선정하였다. 수집된 데이터는 2006년 5월부터 2006년 12월까지의 시간별 측정 데이터 중 계측기기 및 정수장 유지관리 기간의 데이터를 제외한 5,448개를 사용하였다.

침전지 유출수의 잔류염소 농도 예측을 위하여 사용된 모형은 선형 및 비선형 중회귀모형과 신경망모형이 적용되었으며, 신경망 모형의 경우 개발된 모형의 검증에 위해서 총 관측 시료수 5,448개중에서 균등분포(uniform distribution)에 의한 난수(random number)를 발생시켜 240개의 자료를 추출하여 개발된 모형에 적용하여 검증하였다.

입력 변수들에 대한 기초 통계 분석결과는 Table 1에 나타내었다. Table 1에서 나타난 바와 같이 유입

Table 1. Basic statistics for input variables.

| Factors | Mean | Max. | Min. | Standard Deviation | Correlation Coefficient(R) |
|-----------------------------------------|-------|---------|-------|--------------------|----------------------------|
| Temperature (°C) | 18.3 | 23.8 | 5.42 | 4.06 | -0.508 |
| pH | 6.77 | 7.42 | 5.42 | 0.28 | 0.353 |
| Turbidity (NTU) | 3.75 | 43.62 | 0.43 | 3.86 | -0.364 |
| Conductivity (μmhos/cm) | 71.28 | 99.92 | 45.64 | 9.20 | 0.070 |
| Alkalinity (mg/L as CaCO ₃) | 19.1 | 25.0 | 15.0 | 2.75 | 0.075 |
| Flow Rate (m ³ /d) | 9138 | 13423.8 | 920.3 | 2892.7 | 0.407 |
| Chlorine Doasge (mg/L) | 1.64 | 3.84 | 0.68 | 0.51 | -0.528 |




Fig. 1. Prechlorination dosage and chlorine residual at sedimentation basin along with time.

유량이 상대적으로 큰 편차를 나타내고 있었으며, 각 변수들과 잔류 염소와의 상관성을 분석한 결과 유입 유량, pH는 잔류 염소 농도와 비례적 상관성을 가지고 있으며, 탁도, 온도 및 염소 주입량은 반비례적 상관성을 나타내는 것을 알 수 있었다.

Fig. 1에는 수집된 자료 중 실제 정수장에서 주입한 전염소 주입 농도와 침전지 유출수의 시간별 잔류 농도를 나타내었다. 침전지 잔류염소 농도를 일정하게 유지하기 위하여 경험적으로 주입 농도를 조절하는 운전 방식의 운전 결과 잔류 염소농도는 대체로 일정하게 유지되는 반면 염소 주입 농도는 계절별, 기후 조건별로 차이가 나타나는 것을 알 수 있었다. 주입 염소 농도와 잔류 염소 농도의 차로 계산될 수 있는 염소 요구량의 경우 겨울철에 해당하는 수집 자료 후반부에서는 염소 요구량이 작은 반면 여름철에 해당하는 중반부에서는 크게 나타나는 것을 알 수 있다. 따라서 이러한 염소 요구량 변화 특성은 계절적 환경

요인이 크게 작용하는 것으로 판단된다. 또한 환경적 요인뿐만 아니라 **Table 1**에 나타난 분석 결과에서도 알 수 있듯이 정수장의 운영 조건 즉, 유입 유량의 변동에도 큰 차이가 나타나는 것을 알 수 있다. 이는 유량 변동에 따라 침전지 체류시간이 변하므로 이에 따른 잔류 염소의 변화가 있을 수 있다.

4. 결과 고찰

4.1. 회귀 분석 모형

현장에서 수집된 7개의 입력 변수를 대상으로 선형 회귀 분석과 비선형 회귀 분석 모델을 평가한 결과 선형 회귀 분석의 경우 식 (8)과 같은 잔류염소 농도 예측 결과를 도출할 수 있었다. 실제 잔류 염소 농도와 예측값의 상관계수(R)은 0.39로 상당히 낮은 유의 수준을 나타내었다.

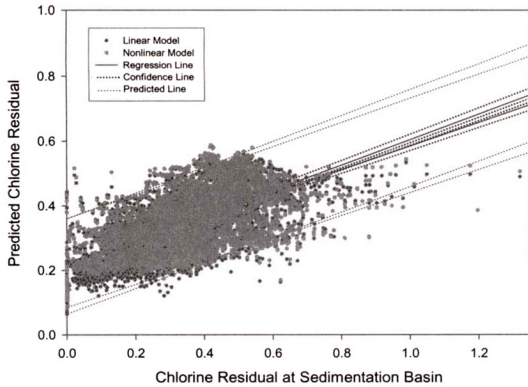


Fig. 2. Prediction of chlorine residual at sedimentation basin with linear and non-linear regression models.

$$\begin{aligned} \text{침전지 잔류염소 농도(mg/L)} = & 0.703 + 0.0051[\text{알칼리도(mg/L)}] - 0.005[\text{유입 유량(m}^3/\text{d)}] \\ & - 0.00139[\text{탁도(NTU)}] - 0.00789[\text{온도(}^\circ\text{C)}] - 0.033[\text{pH}] + 0.00078[\text{전기전도도}(\mu\text{mhos/cm)}] \\ & - 0.10[\text{염소 투입량(mg/L)}] \end{aligned} \quad (8)$$

비선형 회귀 분석의 경우도 마찬가지로 침전지 잔류 염소 농도에 대한 예측식을 분석한 결과 다음 식(9)와 같이 나타낼 수 있다. 이 경우에도 선형 모델과 유사하게 낮은 상관관계(R=0.374)를 갖는 것으로 나타났다.

$$\begin{aligned} \text{침전지 잔류염소 농도(mg/L)} = & 0.020 \times [\text{알칼리도(mg/L)}]^{0.262} \times [\text{유입 유량(m}^3/\text{d)}]^{0.381} \\ & \times [\text{탁도(NTU)}]^{-0.056} \times [\text{온도(}^\circ\text{C)}]^{-0.173} \times [\text{pH}]^{-0.545} \\ & \times [\text{전기전도도}(\mu\text{mhos/cm)}]^{0.090} \times [\text{염소 투입량(mg/L)}]^{-0.395} \end{aligned} \quad (9)$$

Fig. 2에서는 선형 및 비선형 회귀 분석에 의해 예측된 침전지 잔류 염소 농도와 실측된 결과 값을 비교하여 나타내었다. 이렇게 선형 및 비선형 회귀 모델의 상관성이 낮게 나타나는 이유는 침전지내에서 염소의 소비 특성이 여러 입력 변수들에 대해 상당히 복잡한 관계가 있다는 것을 의미하며 이는 계절별 수질 특성에 따라 염소 소비 특성이 다양한 영향을 받기 때문이다.

4.2. 인공지능 신경망 모형

신경망 모형 분석의 경우 모형을 구성한 각 3가지 경우에 대하여 개발하였다. 본 연구에서 신경망 모형은 시계열 분석을 통해 자기회귀형태의 모형 입력변수를 선정하여 구성하였다. 각 Case에 대한 모형구성 입력변수는 다음 Table 2과 같다. 모형의 검증은 총 관측기간 5,448개 중에서 균등분포(uniform distribution)에 의한 난수(random number)를 발생시켜 240개의 데이터를 추출하여 사용하였다. 따라서 추출한 240개 데이터를 랜덤 자료들을 이용하여 각각의 신경망 모형에 학습시켰으며 샘플링된 240개의 데이터를 검증에 이용하였다. Table 2에서 입력 변수에 표현한 t는 시간을 나타내는 것으로서 t-2와 t-1은 현재시점 t에서 2시간, 1시간 전에서 관측된 변수값을 나타내며 이를 입력변수로 t+1시점에서 침전지 잔류 염소량 침전지 잔류 염소(t+1)을 예측하는 것으로 모형을 구성하였다.

Case I에서는 회귀 모형에서 적용된 7개의 변수가 침전지 유출수 잔류염소농도를 예측하기 위한 입력변수로 사용하였다. 또한 모든 입력 변수에 대하여 1시간 전 관측치까지 반영하여 예측하였다. 학습 결과를 이용하여 무작위 240개의 자료 검증 결과 실제값

Table 2. Configuration of input parameters

| Case | Input Parameters | R ² |
|----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------|
| Case I | 탁도(t-1), 탁도(t), 온도(t-1), 온도(t), pH(t-1), pH(t), 유입 유량(t-1), 유입 유량(t), 알칼리도(t-1), 알칼리도(t), 전기 전도도(t-1), 전기 전도도(t), 전염소 주입량(t-1), 전염소 주입량(t), 침전지 잔류염소(t-1), 침전지 잔류염소(t) | 0.742 |
| Case II | 탁도(t), 온도(t), 유입 유량(t-2), 유입 유량(t-1), 유입 유량(t), 전염소 주입량(t-1), 전염소 주입량(t), 침전지 잔류 염소(t-2), 침전지 잔류 염소(t-1), 침전지 잔류 염소(t) | 0.754 |
| Case III | 탁도(t), 온도(t), 유입 유량(t), 전염소 주입량(t-1), 전염소 주입량(t), 침전지 잔류 염소(t-2), 침전지 잔류 염소(t-1), 침전지 잔류염소(t) | 0.869 |




Fig. 3. Comparison of sampled residual chlorine at sediment basin with case III for model validation.

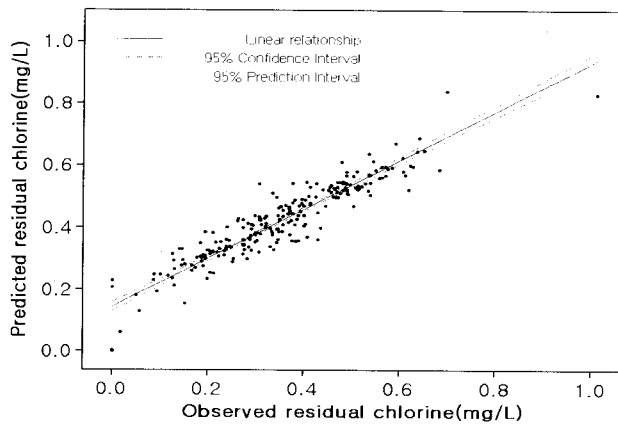


Fig. 4. Relationship of prediction residual chlorine and observed residual chlorine with case III.

과 예측값의 상관 관계(R^2)는 0.742로 나타났다.

Case II와 III에서는 유입 유량의 영향범위를 교차 상관함수를 도식한 결과 및 Rodriguez and Serodes (1999)의 연구결과를 참고로 입력 인자별 영향 시간을 변경하였다. Case II에서는 유입 유량과 침전지 잔류 염소 농도에 대하여 3시간 변화를 반영하였고, 전염소 주입량은 2시간동안의 변화를 반영하였다. 또한 입력 인자 중 일반적인 침전지 내 체류 시간인 3시간 정도의 범위내에서 염소 소비에 영향이 적다고 판단되는 알칼리도, 전기전도도, pH의 인자를 제외하였다. 결과적으로 Case II의 경우 실제값과 예측값의 상관 관계는 0.754로 Case I에 비하여 다소 높은 상관 관계를 나타냄을 볼 수 있었다. Case III에서는 전염소 주입량은 2시간의 변화를 반영하고 침전지 잔류 염소의 농도는 3시간 변화를 고려하여 Case II와 동일한 조건에서 유입 유량의 변화를 실시간만 예측하였다.

모형의 학습 결과를 검증한 결과 예측값과 실측값의 상관 계수(R^2)는 0.869로 이전의 Case II에 비해 상관성이 크게 높아지는 결과를 얻을 수 있었다. 따라서 침전지에서 잔류 염소의 변화는 전염소 주입량의 경우 2시간 정도 내에서 영향을 미치는 것으로 나타났다. 침전지 잔류 염소는 약 3시간 범위까지 영향을 미치는 것을 알 수 있었다.

개발된 3가지 모델중에서 Case III의 예측능력이 가장 양호한 이유는 입력변수로 고려된 유입유량의 변동영향을 예측시점 전단계인 t시간의 유입유량만으로 모델을 구성하였기 때문으로 판단된다. 이는 유입 유량자료의 편차기상관함수(PACF: Partial Auto-Correlation Function)를 산정, 일차 편차기상관함수값만으로 유입유량의 변화모의가 가능한 것으로 분석된 결과를 반영하였다. 이를 증명하기 위하여 Case II와 같이 모델을 구성하였으며, 여기에서는 예측시점

$t+1$ 로부터 $t-2$, $t-1$, t 시간에 해당되는 유입유량을 고려한 결과를 제시한 것으로 Table 2에서와 같이 Case III보다 낮은 모델 성능을 보여주고 있다. 이는 보다 세밀한 시계열분석을 통하여 가장 적절한 모델 차수를 결정하여야 할 것이다.

Fig. 3은 Case III의 학습결과를 바탕으로 난수에 의해 발생된 240개의 자료를 예측하여 실제값과 도시한 결과이다.

결과에서 나타난 바와 같이 잔류 염소 농도에 대한 예측값은 실제값과 유사한 양상을 나타내었으나 실제 잔류 염소 농도의 변화가 클수록 예측값과의 오차가 크게 발생하는 경향을 나타내었다.

Fig. 4은 Case III에 대한 검증결과로서 모형과 실측된 침전지 잔류염소량과의 관계를 신뢰구간과 예측구간을 함께 도시한 것으로 구간의 폭이 좁을수록 예측 성능이 양호한 것으로 판단할 수 있다. 몇 개의 예측 결과를 제외하고 대부분의 예측치는 95% 예측 구간 범위 내에 포함되는 것으로 나타났다. 이러한 결과로 볼 때 인공지능 모형에 의한 예측에서 오차가 발생하는 경우 잔류 염소의 농도와 상관성을 갖지않고 다양한 조건에서 나타나는 것을 볼 수 있었다.

5. 결 론

본 연구에서는 침전지 유출수에서 잔류 염소농도를 일정하게 유지시키기 위해 주입되는 전염소 투입량 예측을 위하여 선형 및 비선형 중회귀 모형과 입력변수의 종류 및 시계열분석을 달리한 세 종류 신경망 모형을 적용하였다. 따라서 이러한 5가지 경우에 대하여 잔류 염소 농도 예측치를 비교하여 예측성능을 평가하였다. 신경망 모형에 의한 검증단계에서는 미학습된 자료를 균등분포 난수를 발생시켜 240개의 자료를 추출하여 사용하였으며 그 결과 수학적 모형인 중회귀 모형보다 신경망 모형의 예측성능이 매우 우수한 것으로 평가되었다 이는 수학적 분석을 통한 중회귀모형은 정수장에서 수질예측을 위해 간편하게 활용될 수 있으나 자연현상을 재현하는 데는 많은 한계점을 가지고 있기 때문으로 판단된다.

신경망 모형의 경우 정수장에서 모니터링이 가능한 모든 입력 변수를 이용하여 학습 시키는 것보다는 영향력이 높은 입력변수를 선정하여 학습하는 경우

예측값이 실측값과 상관성이 높게 나타났으며, 특히 시계열 분석의 경우 유입 유량보다 전염소 주입량과 침전지의 잔류염소 농도를 고려할 때 모형의 예측값이 실측치를 잘 반영 하는 것을 알 수 있었다. 따라서 본 연구에서 개발된 신경망 모형의 경우 정수장의 환경변화 및 수질 변화에도 전염소에 의한 침전지 잔류 염소 농도 예측이 가능할 것으로 판단된다. 그러므로 실공정 에서 전염소 투입량을 실시간으로 예측하여 침전지 유출수에서 잔류 염소 농도를 일정하게 유지할 수 있는 전염소 주입량을 실시간으로 제어 할 수 있을 것으로 판단된다.

참고문헌

1. 김주환 (1993) *신경회로망을 이용한 하천유출량의 수문학적 예측에 관한 연구*, 박사학위논문, 인하대학교.
2. 윤재용, 변석중, 최유식 (2001) 전염소 투입 및 정수지 구조가 정수장 총소독능에서 갖는 중요성 평가, *한국물환경학회지*, 17(3), pp. 327-337.
3. 전항배, 이영주, 이병두, 이종대 (2001) 전염소처리각 구조류의 응집에 미치는 영향, *한국물환경학회지*, 17(3), pp. 347-355.
4. 하성룡, 박상영 (1999) 인공지능경망을 이용한 배수 관로 내 잔류염소농도의 실시간 예측, *대한토목학회지*, 19(6), pp. 773-783.
5. Broad, D.R., Dany G.C., and Maier H.R. (2005) Water Distribution System Optimization Using Metamodels. *J. Water Resources Planning and Management*, 131(3), pp. 172-180.
6. Kim J.H., Kang K.W. and Park C.Y. (1992) Nonlinear Forecasting of Streamflows by Pattern Recognition Method. *Korean J. of Hydroscience, Korean Ed.*, 25(3), pp. 105-113.
7. Lisboa, P.G.J. (1992) *Neural networks*. Chapman & hall, London, pp. 5-6.
8. Manuel J. Rodriguez and Jean-B Serodes (1999) Assessing Empirical Linear and Non-linear Modeling of Residual Chlorine in Urban Drinking Water Systems, *Environmental Modeling & Software* 14, pp. 93-102.
9. D.E. Rumelhart, G.E. Hinton, and R.J. Williams (1986) Learning Internal Representations by Error Back Propagation, Ch. 8 in *Parallel Distributed Processing*, Cambridge, MA: MIT Press.
10. J.G. Uber, D.L. Boccelli, R.S. Summers, and M.E. Tryby (2003) Maintaining Distribution System Residuals Through Booster Chlorination, *AWWARF*, pp. 42-47.