

## 신경망 모형을 이용한 단기조류예측모형 구축에 관한 연구

### Study on Establishing Algal Bloom Forecasting Models Using the Artificial Neural Network

김 미 은\* / 신 현 석\*\*

Kim, Mi Eun / Shin, Hyun Suk

#### Abstract

In recent, Korea has faced on water quality management problems in reservoir and river because of increasing water temperature and rainfall frequency caused by climate change. This study is effectively to manage water quality for establishment of algal bloom forecasting models with artificial neural network. Daecheong reservoir located in Geum river has suitable environment for algal bloom because it has lots of contaminants that are flowed by rainfall. By using back propagation algorithm of artificial neural networks (ANNs), a model has been built to forecast the algal bloom over short-term (1, 3, and 7 days). In the model, input factors considered the hydrologic and water quality factors in Daecheong reservoir were analyzed by cross correlation method. Through carrying out the analysis, input factors were selected for algal bloom forecasting model. As a result of this research, the short term algal bloom forecasting models showed minor errors in the prediction of the 1 day and the 3 days. Therefore, the models will be very useful and promising to control the water quality in various rivers.

**Keywords** : artificial neural network, water quality forecasting, algal bloom, chlorophyll-a

#### 요 지

최근 한국은 기후변화로 인한 기온 및 수온 상승, 빈번한 집중호우와 친수공간 조성에 따른 적극적인 하천의 활용 등으로 인하여 하천 및 저수지 내 수질관리에 있어 해결해야 하는 많은 문제점을 가지고 있다. 본 연구는 효율적인 수질관리를 위하여 인공신경망을 이용한 단기조류예측모형 구축에 관한 연구이다. 대상지역으로 조류가 번식하기 좋은 조건을 지니고 있는 금강유역 내 대청호를 선정하였고 설치되어 있는 수질자동측정망의 일 단위자료를 이용하였다. 다층전방향신경망의 역전파 알고리즘을 이용하여 단기(1일, 3일, 7일) 조류를 예측할 수 있는 모형을 구축하였다. 본 모형에서는 대청호 내 수문 및 수질성분을 교차상관분석을 기초하여 단기조류예측모형의 입력 성분을 선정 한 후 다양한 조류예측 신경망 모형을 구축하여 결과에 대한 검증을 실시하였다. 구축된 단기조류예측모형은 자연발생적인 기작과 유사한 현상을 재현할 수 있는 다양한 수질인자를 고려하여 단기조류예측모형을 구축한 경우 예측의 정확도가 높게 도출되었다. 본 연구는 신경망 모형의 최대 장점인 비선형성 및 간편성 등을 고려하였을 때 우리나라의 수질예측에 적합한 신경망 모형을 구축할 수 있으며 이를 통한 하천 및 호수 내 효율적인 수질관리 방안을 제시할 수 있을 것이다.

**핵심용어** : 인공신경망, 수질단기예측, 조류, 클로로필-a

\* 부산대학교 공과대학 사회환경시스템공학부 박사과정 (e-mail: way8210@naver.com)  
Doctoral Candidate, Dept. of Civil Engrg., Pusan National Univ., Busan 609-735, Korea

\*\* 교신저자, 부산대학교 공과대학 사회환경시스템공학부 교수 (e-mail: hsshin@pusan.ac.kr, Tel: 051-510-2348)  
Corresponding Author, Pfor., Dept. of Civil Engrg., Pusan National Univ., Busan 609-735, Korea

## 1. 서 론

최근 한국은 기후변화로 인한 기온 및 수온 상승, 빈번한 집중호우와 친수공간 조성에 따른 적극적인 하천의 활용 등으로 인하여 하천 및 저수지 내 수질관리에 있어 해결해야 하는 많은 문제점을 가지고 있다. 이에 정부에서도 한국의 5대강 유역을 대상으로 조류의 번식을 사전에 막고자 수질자동측정망 시스템을 설치하여 실시간으로 감시하고 있다. 또한 수치모델링을 이용하여 기상 및 오염원의 변화에 따른 장래의 수질변화를 예측하여 수질 사고에 대처할 수 있도록 하는 방안을 마련하고자 노력하고 있다. 여러 국가에서 비선형성, 학습을 통한 모형의 구축, 반복된 학습에 의한 가중치를 결정하는 비매개변수법으로 입력과 출력의 형태의 변화가 자유로운 인공신경망을 이용하여 수질인자를 예측하는 다양한 연구 사례가 있다.

국외 사례를 살펴보면, Recknagel et al. (1994)은 12년간 관측된 수질 데이터를 인공신경망의 입력 자료로 활용하여 조류발생 예측모형을 구축하였고, Wilson et al. (2001)은 12년 간 관측된 수질 데이터를 인공신경망의 입력자료로 이용하여 조류발생 예측모형을 구축하고 이에 대한 모형 검증을 실시하였으며, Karula et al. (2000)은 여러 가지 수질인자를 고려하여 chl-a를 분석하고 이를 예측하기 위하여 Levenberg-Marquardt (tangent-sigmoid) 구조를 갖는 부영양화 신경망 예측모형을 구축한 사례가 있다. Singh et al. (2009)은 하천의 수질관리를 위하여 DO와 BOD를 각각 예측하고자 BPNN을 이용하여 DO와 BOD 예측 모형을 구축한 바 있다.

국내에서는 Ahn et al. (2001)은 BP 알고리즘 신경망 모형을 이용하여 금강유역 공주지점의 DO, BOD, TN에 대한 월 수질 예측을 수행하고 ARIMA 모형과 비교하여 적용 가능성을 검토하였고, Oh et al. (2002)은 영산강 유역의 DO, BOD, TN, TP 자료로 BP 알고리즘 신경망모형을 이용하여 각 수질요소별 월 단위 수질 예측을 통한 최적수질예측모형을 구축하였다. Lee and Seo (2002)는 대청호의 유입수질에 미치는 영향을 파악하기 위하여 WASP5 모델을 이용하여 BOD, TN, TP 농도를 월 단위 수질 예측을 실시하였다. Park and Ha (2003)은 영산강 나주 지점을 대상으로 Genetic Algorithm and Neural Network (GANN)을 이용하여 DO, BOD, TN, TP 농도를 월 단위 수질 예측하였으며, Cho et al. (2004)은 충주호 유역 내의 내사천 유역과 평창강 유역에 BOD, TN, TP, TOC 농도를 BP 알고리즘 신경망 모형을 이용하여 실시간 예측하였다. 전계원 등은 BP 알고리즘 신경망 모형을 이용하여

한강유역의 달천지점의 각 수질자료를 이용하여 월 수질 예측 지능형 모형을 구축하고 그 적용성을 검증한 바 있으며, Oh et al. (2008)은 영산강 유역 나주지점의 유출량 및 TOC, TOC 부하량을 BPNN 모형을 이용하여 일 단위 예측모형을 개발하였다.

인공신경망을 이용한 다양한 연구사례에서 알 수 있듯이 수질요소 BOD, DO 등에 관한 예측 연구는 있으나 수질과 수문인자를 함께 고려하고 이를 활용하여 부영양화에 직접적인 영향인자가 되는 chl-a 농도를 예측한 연구는 많지 않다. 정확도가 높은 수질단기예측모형을 통한 효율적인 수질관리를 위하여 기본적인 관측 데이터 성분만을 이용하여 단기예측을 가능하게 할 수 있는 역전파 알고리즘 인공신경망을 이용하여 수질단기예측모형을 구축하고자 한다.

본 연구에서는 조류가 빈번히 발생하는 금강유역 내 대청호를 대상으로 수질단기예측모형을 구축하였다. 대청담 유역은 수질자동측정망에서 얻은 2009부터 2010년까지 측정된 일 단위 수질성분과 Wamis (www.wamis.go.kr/)에서 얻은 수문성분 자료를 이용하여 관측자료 간의 관계와 호수 내 조류성장에 영향을 미치는 성분을 규명하고자 교차상관관계 분석을 실시하였다. 교차상관분석 결과를 바탕으로 1, 3, 7일 단위의 다양한 단기조류예측모형을 구축하고 이를 모형 검증방법을 통하여 적합한 단기수질예측모형을 선정하였다.

## 2. 입력자료 및 연구방법

### 2.1 연구대상지역

한국 내의 주요한 대규모 상수원 중의 하나인 대청호는 댐 길이 495m, 댐 체적 1,234천 m<sup>3</sup>, 댐 높이 72m로 구성된 복합형 대청댐에 의해 형성된 것으로 용담호 유역을 제외한 자체 유역면적은 3,204 km<sup>2</sup>이다. 대청호는 연간 1,649 백만 m<sup>3</sup>의 용수공급량을 저류하고 있으며, 그 중 1,300백만 m<sup>3</sup>이 생활 및 공업용수를 공급하는 중요한 공급원으로서 절대적 역할을 하고 있다. 하지만 2011년 최근 대청호는 수위가 낮아짐에 따라 각종 오염물질에 의해 우기가 시작되기 전에 적절한 수질관리를 필요로 하는 곳이 되었다. 본 유역의 강우량은 6~8월에 집중되며 최대강우 발생시기가 7~8월로 분포되는 특징을 가진다. 그리고 갈수기인 1, 2, 3, 4, 11, 12월의 경우, 강우량이 연 강우량의 15% 정도에 불과하기 때문에 계절별 강우량 차이가 큰 전형적인 한국의 강우형태를 보인다.

때문에 오염가능성이 다른 호수에 비하여 큰 편이며 실

시간 수질변화를 감시하기 위한 수질자동측정소를 설치하여 운영하고 있다. 특히 이 지역은 2001년 이후 꾸준히 매년 여름 마다 조류 주의보 및 경보가 여름철에 상습적으로 발생하고 있다. 이러한 현상은 유역 내 물의 체류시간이 길어 오염물질이 장기간 체류되면서 매년 여름철 부영양화 현상을 반복적으로 발생시키는 요인 중 하나가 되고 있다. 국가에서도 대청호를 대상으로 수온(Tw), 용존산소량(DO), 총유기탄소(TOC), pH, 클로로필-a 농도(chl-a), 총인(TP), 총질소(TN)의 수질항목을 조류발생예보제의 기준을 적용하여 시범실시하고 있다. 이에 본 연구에서는 단기조류예측모형을 구축하기 위하여 금강 유역 내 대청호 지점을 대상 유역으로 선정하였다. Fig. 1은 금강유역 내 대상지점인 대청호 유역을 나타내고 있다.

## 2.2 입력자료

본 연구에서 사용된 자료는 대청호 지점의 수질자동측정망에서 얻은 2009년에서 2010년까지의 일 단위의 수질(Tw, DO, TOC, pH, chl-a, TN, TP)자료와 WAMIS(www.wamis.go.kr/)의 수문(대청댐 유입량(If), 유출량(Of), 댐유역평균강우량(Pa), 기온(Ta))자료이다. 환경부의 수질자동측정망 운영을 통한 자료로써 신뢰성이 높으며, 수질 및 수문 자료를 모두 이용하는 것은 조류의 발생에 가장 민감하게 영향을 미치는 요소를 분석하여 자료간의 관계를 규명하고 분석된 결과를 이용하여 수질예측에 가장 적합한 입력성분을 이용하여 모형을 구축하기 위함이다.

## 2.3 연구방법

### 2.3.1 인공신경망

인공신경망은 인간의 뇌에 존재하는 생물학적 신경 세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하여 인간의 두뇌가 나타내는 지능적 형태를 구현하는 것이다. 현재 인공신경망은 시스템 규명, 예측, 패턴 인식, 분류 및 공정 제어 등의 분야에서 많이 활용되고 있다. 신경단위(neuron)들은 일반적으로 Fig. 2와 같이 다층구조(multi-layer structure)로 병렬연결(parallel connection)되어 입력된 신호는 전방향(feed-forward)으로 전달이 가능하다. 이를 다층전방향 신경망(multi-layer feed-forward neural network; MFN)이라고 하며 이 네트워크는 입력층, 출력층, 은닉층으로 구성되어 있다. 입력정보  $X_i$ 는 입력층으로 입력되어 신경단위들은 입력정보를 가중연결(weighted connection)하여 은닉층의 절점들로 전달한다. 각 은닉층의 절점들은 모든 입력층으로부터 각기 다른 연결강도(weight)에 의해 변환된 자료들을 받으며, Fig. 2에서 은닉층 절점으로 가중된 입력,  $h_j$ 는 다음 Eq. (1)로 나타낼 수 있다.

$$h_j = \sum_{i=1}^{N_I} w_{ij} X_i + \theta_j, j=1, \dots, N_H \quad (1)$$

여기서,  $N_H$ 는 은닉층 절점수,  $\theta_j$ 는 은닉층  $j$ 번째 절점의 편차(bias)입력,  $w_{ij}$ 는 입력층  $i$ 번째의 절점과 은닉층  $j$ 번째의 절점사이의 가중치를 나타낸다.

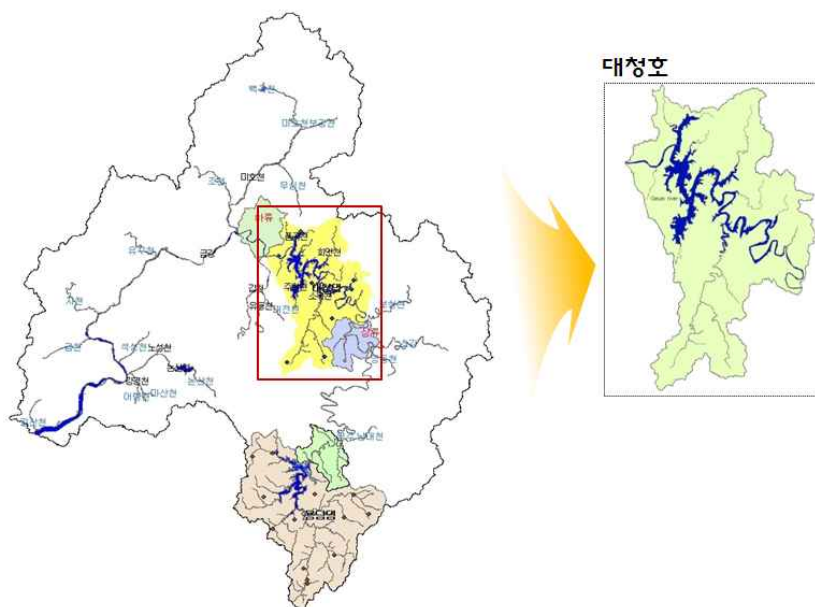


Fig. 1. Study Area

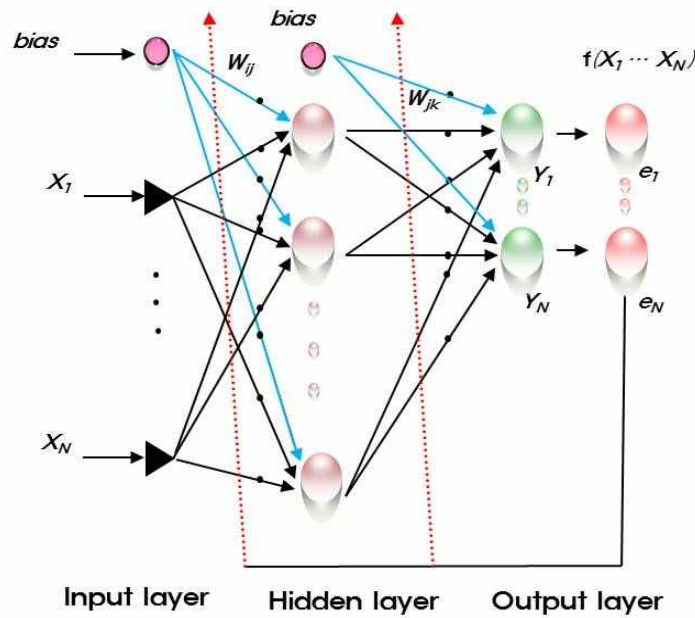


Fig. 2. Structure of Back Propagation Algorithm of Neural Network

은닉층의 각 절점에서는 Eq. (1)에 의해 합산된 자료들을 대표적인 전달함수인 Eq. (2)의 시그모이드(sigmoid) 함수나 Eq. (3)의 하이퍼볼릭탄젠트(hyperbolic tangent) 함수에 의해 비선형적으로 변환하여 가중연결에 의해 출력층으로 전달하며, 은닉층으로 부터의 출력값  $H_j$ 는 전달 함수를 사용하여  $f(H_j)$ 로 나타낼 수 있다.

$$\text{Sigmoid function: } f(u) = \frac{1}{1 + \exp(-u)} \quad (2)$$

$$\text{Hyperbolic tangent: } f(u) = \frac{1 - \exp(-u)}{1 + \exp(-u)} \quad (3)$$

각 출력층의 절점들은 모든 은닉층으로부터 각기 다른 가중치에 의해 변환된 자료들을 받으며, 각 절점은 합산된 자료들을 출력값의 목적에 따라 이전 값의 출력을 위한 결합함수, 즉 연속값의 출력을 위한 선형 또는 비선형 함수에 의해 변환하여 출력하며 그 값이 신경망의 목적하는 출력값이 된다. 출력층으로의 가중된 입력은 Eq. (4)와 같이 나타낼 수 있다.

$$Y_k = \sum_{j=1}^{N_H} w_{jk} H_j + \theta_k, \quad k=1, \dots, N_0 \quad (4)$$

여기서,  $N_0$ 는 출력층 절점수,  $\theta_k$ 는 출력층 k번째 절점의 편차입력,  $w_{jk}$ 는 은닉층 j번째 절점과 출력층 k번째 절점 사이의 가중치이다. 또한 출력층으로 부터의 출력값  $Y_k$ 는 전달함수를 사용하여  $f(Y_k)$ 로 나타낼 수 있으며 이러

한 역전파알고리즘의 특성을 본 연구에 적용하였다.

### 2.3.2 입력자료의 상관관계 분석

조류에 영향을 미치는 수질 및 수문 요소 간의 상관분석을 실시하였다. 우선, 시계열 자료에 내재하는 시점 간의 상관분석을 실시하기 위하여 Serial Correlation Analysis (SCA), 조류발생과 상관성이 있는 항목분석을 위하여 수질항목과 수문항목 간 Cross Correlation Analysis (CCA)를 실시하였다. 시계열 자료의 계절적 변동이나 주기적인 반복성을 검토하기 위한 SCA (rk)분석은 다음의 Eq. (5)와 같다.

$$r_k = \frac{\sqrt{\sum_{i=1}^{n-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5)$$

여기서,  $\bar{x}$ 는 평균,  $n$ 은 분석자료의 수를 뜻한다.

수질 및 수문요소의 독립변수와 종속변수 간의 상관성을 검토하기 위해 사용된 CCA (rxy)는 다음의 Eq. (6)과 같다.

$$r_{xy}(k) = \frac{C_{xy}(k)}{S_x S_y} \quad (6)$$

여기서,  $C_{xy}$ 는  $x, y$ 의 공분산,  $S_x$ 와  $S_y$ 는  $x$ 와  $y$ 의 표준편차를 의미한다.

### 2.3.3 단기조류예측모형 구축

본 연구에서는 역전파알고리즘을 이용하여 단기 조류 예측 신경망 모형을 Fig. 3과 같은 절차를 통하여 구축하였다. 단기조류예측모형의 입력자료는 상관분석 결과를 바탕으로 chl-a와 상관 정도가 높은 수질 및 수문성분을 추출하였다. 이를 이용하여 조류예측모형의 입력요소로 사용하였으며 각 성분들의 민감한 정도를 알아보고자 Table 1과 같이 12가지 chl-a 예측 모형을 구축하여 예측 모형별 1, 3, 7일 예측을 실시하였다. 단기조류예측 모형을 구축하기 위하여 Training 기간을 2010/01/01~2010/12/31, Testing 기간을 2009/01/01~2009/12/31의 자료로 구분하여 사용하였다. 상관분석의 결과로 chl-a와 관련하여

높은 상관 정도를 보이는 수온, pH, TOC, If를 입력데이터로 한 모형을 기준으로 선정하고 각각의 요소의 민감한 정도를 분석하고자 Model 1에서 입력성분을 하나씩 제거 또는 추가하여 Model 1~Model 12 (M1~M12)를 구축하였다.

모형의 검보정을 위하여 Table 2에 나타낸 바와 같이, 제곱근평균자승오차-Root Mean Square Error (RMSE), 결정계수-R-square ( $R^2$ ) 함수를 적용하였다.

### 3. 결 과

우선 기본 관측 수질 및 수문 자료에 대한 SCA와 CCA를 실시하였고 이에 대한 결과는 Tables 3 and 4에 나타

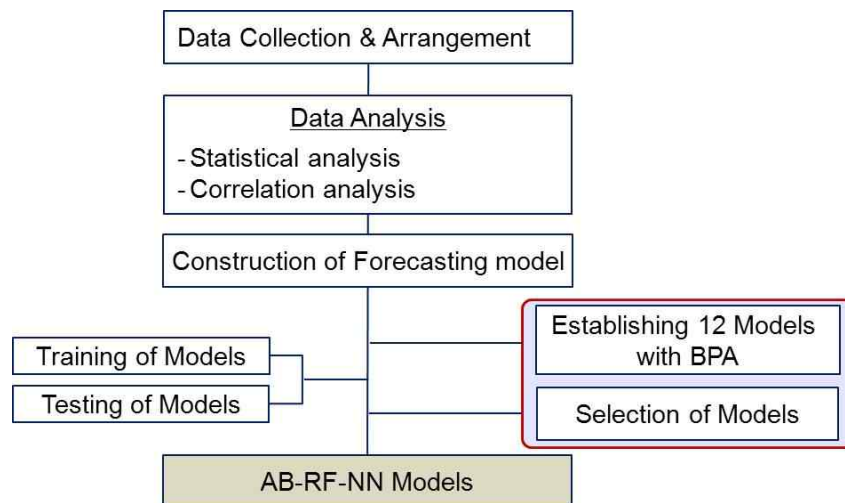


Fig. 3. Flow Chart of This Study

Table 1. Neural Network Models Used for Reasonable Estimation of Output in This Study

| Periods           | Model    | Inflow | Outflow | Tw | pH | DO | TOC | TN | TP | chl-a |
|-------------------|----------|--------|---------|----|----|----|-----|----|----|-------|
| 2009<br>~<br>2010 | Model 1  | -      | ○       | ○  | ○  | ○  | ○   | -  | -  | ○     |
|                   | Model 2  | -      | ○       | ○  | ○  | ○  | ○   | -  | -  | -     |
|                   | Model 3  | -      | -       | ○  | ○  | -  | ○   | -  | -  | -     |
|                   | Model 4  | -      | -       | ○  | -  | -  | ○   | -  | -  | -     |
|                   | Model 5  | -      | -       | ○  | ○  | -  | ○   | -  | -  | ○     |
|                   | Model 6  | ○      | -       | ○  | ○  | ○  | ○   | ○  | ○  | ○     |
|                   | Model 7  | -      | -       | ○  | ○  | ○  | ○   | ○  | ○  | ○     |
|                   | Model 8  | -      | -       | ○  | -  | -  | ○   | -  | ○  | -     |
|                   | Model 9  | -      | ○       | ○  | -  | -  | ○   | -  | ○  | -     |
|                   | Model 10 | -      | ○       | ○  | ○  | ○  | ○   | -  | ○  | ○     |
|                   | Model 11 | -      | ○       | ○  | -  | -  | ○   | -  | ○  | -     |
|                   | Model 12 | -      | -       | ○  | -  | -  | -   | -  | ○  | -     |

낸 바와 같다. Table 3에 나타난 SCA 결과를 살펴보면, 자기상관분석은 모든 수문 및 수질 성분에서 지체시간 (Lag Time, LT)이 1~7일인 경우에 대체적으로 95% 신뢰성을 보였으며 특히 Lag Time이 1~2일 경우 상관정도가 가장 높음을 알 수 있다. Table 4의 CCA 결과는 chl-a에 대하여 댐 방류량(Of), 수온(Tw), pH, TOC가 높은 상관관계를 보였다.

이러한 수문 및 수질성분 간의 상관관계 분석 결과를 이용하여 금강 유역 내 대청호 지점의 12가지 단기조류예측모형을 구축하였다. 각 수문 및 수질성분별 Lag Time과

은닉층 수에 대한 12가지 역전파알고리즘 기반의 인공신경망 모형인 단기조류예측모형의 구조를 살펴보면 Table 5에 제시된 바와 같다. 이는 Table 3의 SCA 분석결과를 잘 반영한 것으로 각 수질 및 수문성분별 Lag Time은 1~2일 경우 단기수문예측모형으로 적합함을 알 수 있다. 모형의 매개변수를 최적화하기 위한 Training 결과를 Scatter plot으로 나타내면 Fig. 4와 같다. Fig. 4는 chl-a를 예측하는 모형을 구축하기 위하여 다양한 입력성분으로 구성된 12가지의 chl-a 단기예측모형의 결과 중 모형 적정성 평가 항목인 RMSE와  $R^2$ 의 결과를 기준으로 하여

Table 2. Model Performances

| Method                 | Basic Equation  | Description of Variables             |
|------------------------|---|--------------------------------------|
| Root Mean Square Error | $SE = \sqrt{\frac{1}{N} \sum^N (\hat{Q}(t) - Q(t))^2}$              | t : time<br>N : the number of data   |
| R-square               | $R^2 = \frac{\sum^N (\hat{Q} - \bar{Q})^2}{\sum^N (Q - \bar{Q})^2}$ | $\bar{Q}$ : average of observed data |

Table 3. Results of Serial Correlation Analysis between Variables in Concern

| LT | If   | Of   | Pa   | Ta   | Tw   | pH   | DO   | TOC  | TN   | TP   | chl-a |
|----|------|------|------|------|------|------|------|------|------|------|-------|
| 1  | 0.69 | 0.92 | 0.26 | 0.98 | 1.00 | 0.98 | 0.95 | 0.96 | 0.94 | 0.84 | 0.96  |
| 2  | 0.65 | 0.84 | 0.28 | 0.97 | 1.00 | 0.95 | 0.89 | 0.92 | 0.89 | 0.66 | 0.91  |
| 3  | 0.56 | 0.80 | 0.25 | 0.96 | 1.00 | 0.92 | 0.83 | 0.89 | 0.85 | 0.59 | 0.87  |
| 4  | 0.44 | 0.75 | 0.14 | 0.94 | 0.99 | 0.89 | 0.79 | 0.86 | 0.81 | 0.52 | 0.82  |
| 5  | 0.41 | 0.66 | 0.30 | 0.94 | 0.99 | 0.87 | 0.75 | 0.85 | 0.79 | 0.48 | 0.79  |
| 6  | 0.38 | 0.59 | 0.19 | 0.92 | 0.99 | 0.86 | 0.72 | 0.83 | 0.75 | 0.43 | 0.75  |
| 7  | 0.25 | 0.56 | 0.14 | 0.92 | 0.99 | 0.85 | 0.69 | 0.82 | 0.73 | 0.37 | 0.72  |
| 8  | 0.20 | 0.53 | 0.09 | 0.91 | 0.98 | 0.79 | 0.66 | 0.81 | 0.72 | 0.12 | 0.69  |
| 9  | 0.16 | 0.49 | 0.10 | 0.90 | 0.98 | 0.79 | 0.64 | 0.79 | 0.73 | 0.14 | 0.66  |
| 10 | 0.13 | 0.46 | 0.08 | 0.89 | 0.98 | 0.78 | 0.63 | 0.79 | 0.73 | 0.14 | 0.65  |

Table 4. Results of Cross Correlation Analysis between Variables in Concern

|        | Of   | Pa   | Ta   | Tw   | pH   | DO    | TOC   | TN    | TP    | chl-a |
|--------|------|------|------|------|------|-------|-------|-------|-------|-------|
| Inf    | 0.49 | 0.47 | 0.27 | 0.26 | 0.10 | -0.04 | 0.09  | 0.05  | 0.01  | 0.20  |
| Outf   |      | 0.17 | 0.35 | 0.33 | 0.32 | 0.23  | 0.19  | 0.11  | 0.04  | 0.40  |
| Precip |      |      | 0.23 | 0.23 | 0.15 | -0.06 | 0.04  | 0.09  | -0.07 | 0.17  |
| Ta     |      |      |      | 0.85 | 0.60 | -0.14 | 0.43  | 0.33  | -0.12 | 0.48  |
| Tw     |      |      |      |      | 0.61 | -0.31 | 0.57  | 0.03  | -0.18 | 0.60  |
| pH     |      |      |      |      |      | 0.36  | 0.55  | 0.06  | -0.03 | 0.53  |
| EC     |      |      |      |      |      | 0.12  | -0.26 | 0.30  | -0.01 | -0.22 |
| DO     |      |      |      |      |      |       | 0.06  | 0.10  | 0.27  | 0.07  |
| TOC    |      |      |      |      |      |       |       | -0.09 | -0.11 | 0.62  |
| TN     |      |      |      |      |      |       |       |       | 0.02  | -0.02 |
| TP     |      |      |      |      |      |       |       |       |       | -0.02 |

Table 5. Architecture of Algal Blooms Forecasting Models by Training

| Model | Lag Time |    |    |    |    |    |    |     |    |    |       | Hidden Layer |
|-------|----------|----|----|----|----|----|----|-----|----|----|-------|--------------|
|       | If       | Of | Pa | Ta | Tw | pH | DO | TOC | TN | TP | chl-a |              |
| 1     |          | 2  |    |    | 2  | 2  | 2  | 2   |    |    | 2     | 12           |
| 2     |          | 2  |    |    | 2  | 2  | 2  | 2   |    |    |       | 20           |
| 3     |          | 2  |    |    | 2  | 2  | 2  |     |    |    |       | 12           |
| 4     |          |    |    |    | 1  |    |    | 1   |    |    |       | 8            |
| 5     |          |    |    |    | 3  | 2  |    | 1   |    |    |       | 20           |
| 6     | 1        |    |    |    | 2  | 2  | 2  | 2   | 1  | 1  | 2     | 26           |
| 7     |          |    |    |    | 2  | 2  | 2  | 1   | 2  | 2  | 1     | 16           |
| 8     |          |    |    |    | 2  |    |    | 2   |    | 1  |       | 8            |
| 9     |          | 2  |    |    | 2  |    |    | 1   |    | 1  |       | 10           |
| 10    |          | 2  |    |    | 2  | 1  | 1  | 2   |    | 2  | 2     | 20           |
| 11    |          | 1  |    |    | 1  |    |    | 1   |    | 1  |       | 8            |
| 12    |          | 2  |    |    | 2  |    |    |     |    | 1  |       | 8            |

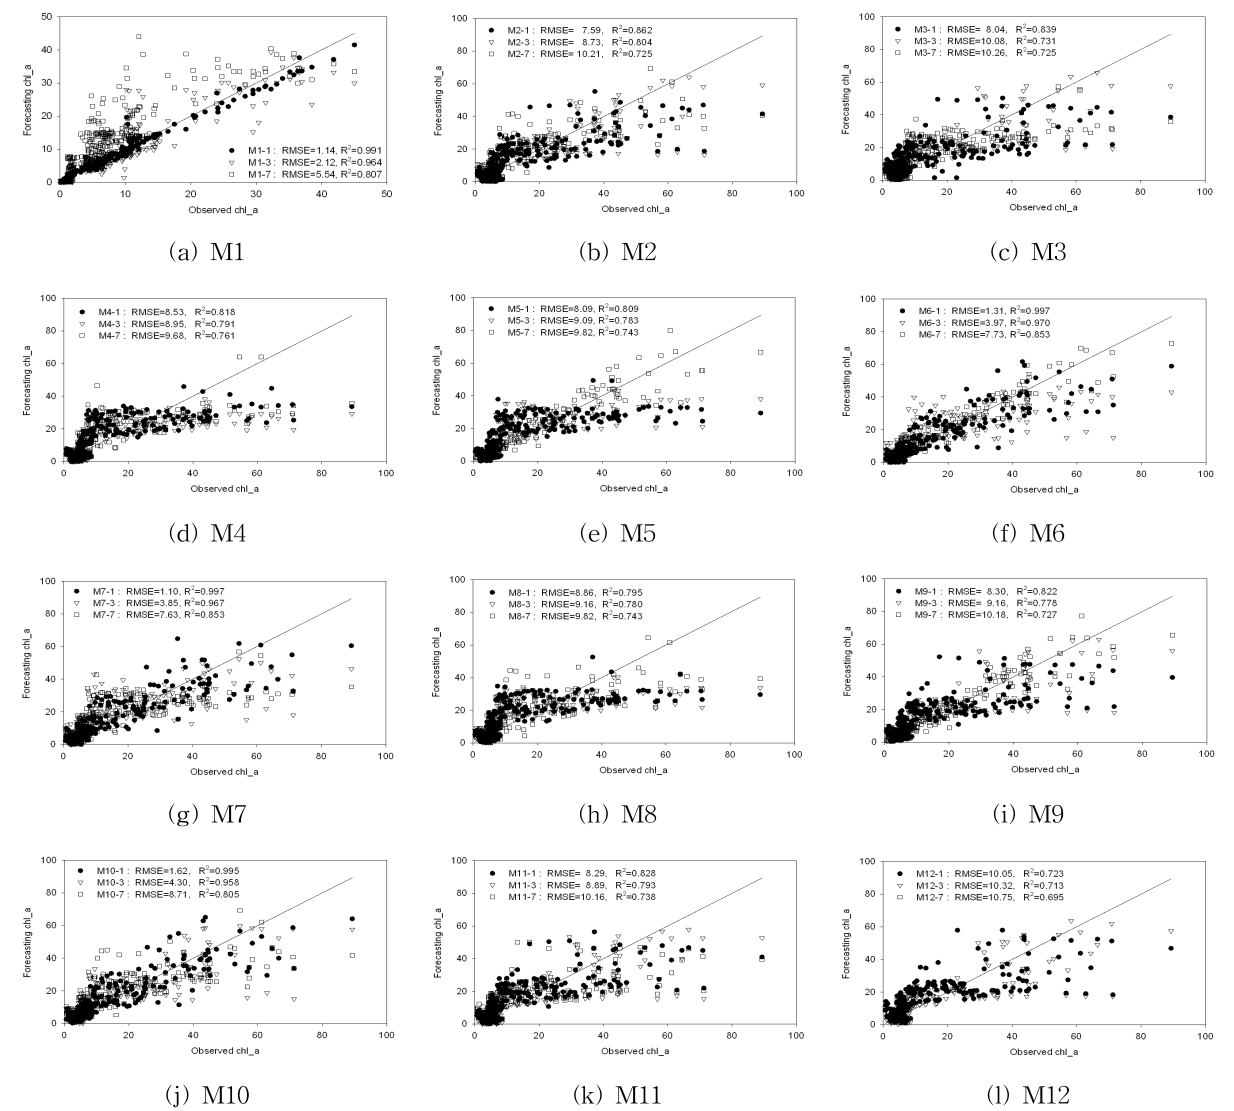


Fig. 4. Results of Algal Bloom Forecasting Models for Training Period using Scatter Plots

Scatter plot으로 나타내었다. Fig. 4와 같이 Training 결과를 기초로 하여 모형의 적정성을 평가하고자 실시한 Testing 결과는 Fig. 5에 나타난 바와 같다. Figs. 5(a)~(l)은 각각의 모형에 대한 1, 3, 7일 예측 결과를 Fig. 5(a)와 같이 M1-1, M1-3, M1-7로 나타낸 것이다. 결과를 분석해보면, 대체적으로 1일 예측의 결과(RMSE와  $R^2$ )는 Model 1, Model 6, Model 7, Model 10에서 RMSE 값 1.14, 1.65, 1.0, 1.88을 보였고  $R^2$ 은 0.991, 0.981, 0.996, 0.956으로 우수한 결과를 보였다. 즉, Figs. 5(a), 5(f), 5(g), 5(j)에서 양호한 결과를 보임을 알 수 있다. 또한 예측기간이 3일인 경우의 결과는 Figs. 5(a), 5(e), 5(f), 5(g), 5(j)에서 RMSE 값이 2.12, 2.61, 3.34, 2.90을 보였고  $R^2$ 은 0.964, 0.953, 0.938, 0.953의 결과를, 7일 예측의 경우 역시 Figs.

5(a), 5(e), 5(f), 5(g), 5(j)에서 RMSE 값이 5.54, 3.32, 4.92, 3.95,  $R^2$ 은 0.807, 0.933, 0.847, 0.918의 결과를 보였다. 1, 3, 7일에 대한 단기간의 조류예측을 위한 모형으로 Model 1, Model 5, Model 6, Model 7, Model 10이 적절함을 알 수 있다. 특히 1, 3, 7일 예측 모두에서 가장 우수한 결과를 보이고 있는 Model 6, Model 7, Model 10을 단기조류예측을 위한 최적모형으로 선정하였다. Fig. 6은 단기조류예측모형으로 Model 6, 7, 10의 Testing 결과를 실측자료와 비교하여 나타내었다. 1일 예측의 경우 모형의 입력 성분과 관계없이 높은 예측정도를 보였으며 3일, 7일로 예측 기간이 길어질수록 예측의 정확성이 1일 예측일 때보다 낮음을 알 수 있었다.

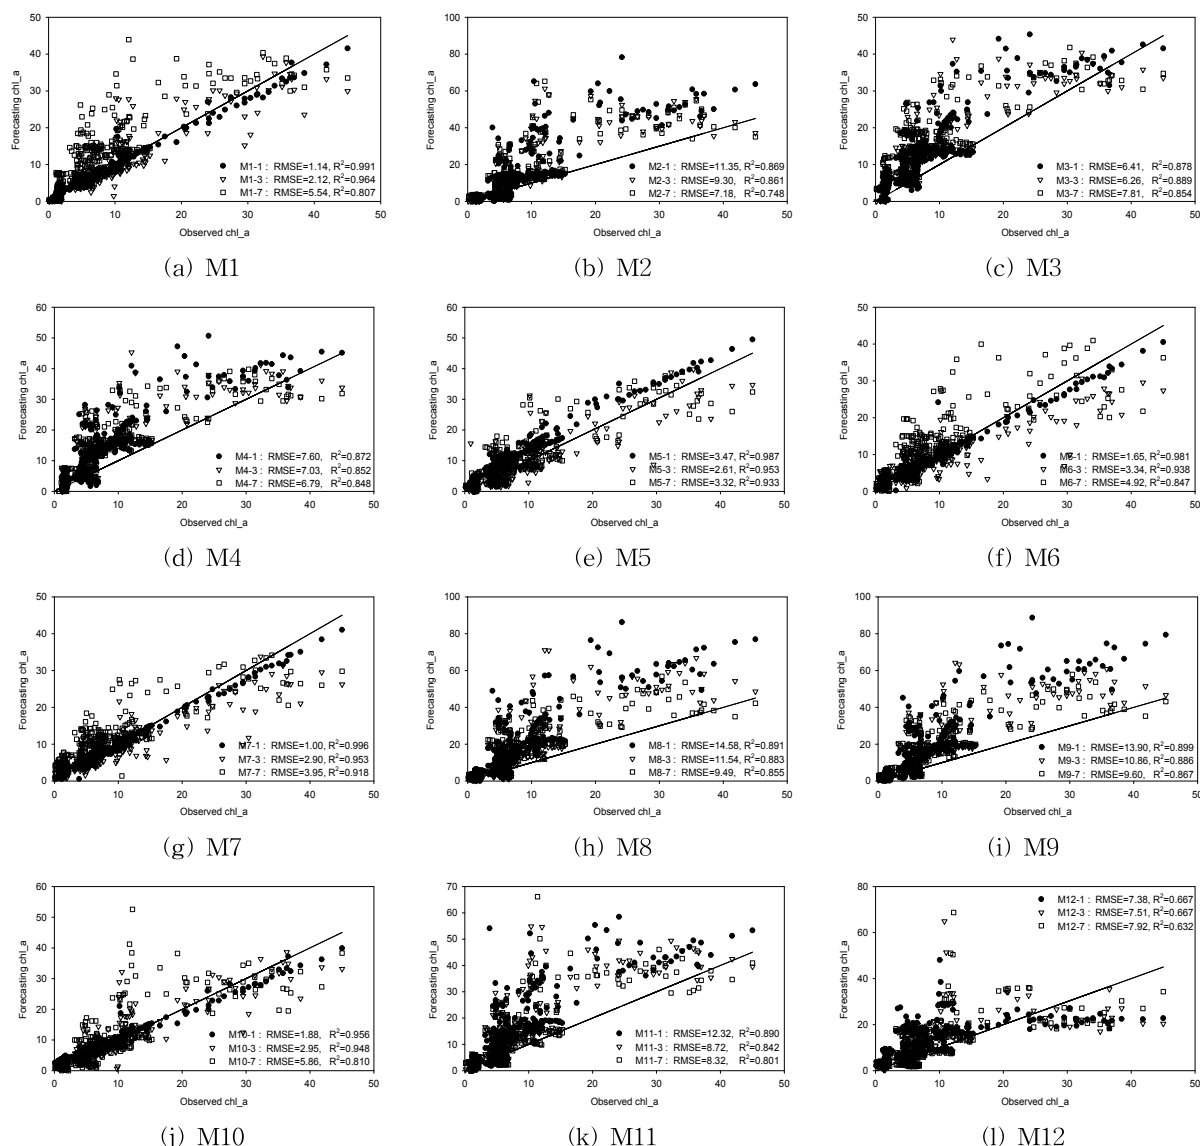


Fig. 5. Results of Algal Bloom Forecasting Models for Testing Period Using Scatter Plots



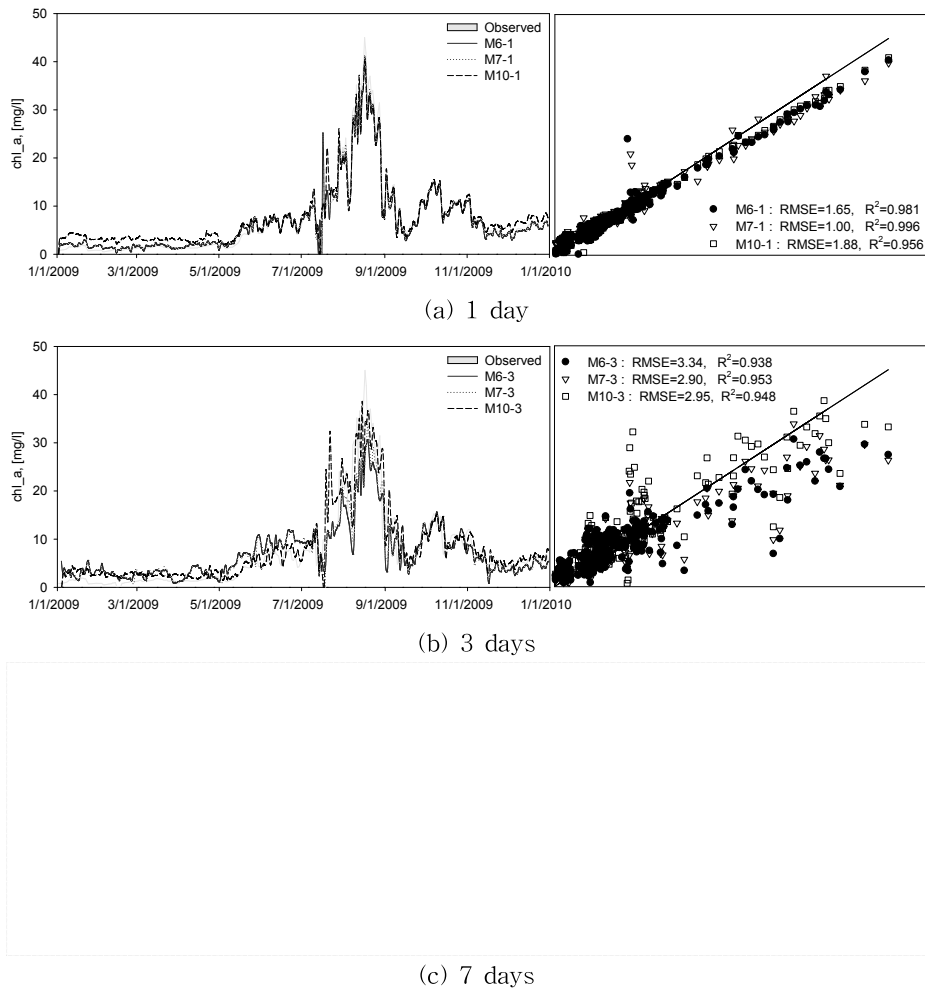


Fig. 6. Results from Selected Algal Bloom Models for Testing Period with High Performance Based on  $R^2$  and RMSE Criteria

#### 4. 고 찰

본 연구는 대청댐의 수질자동측정망에서 얻은 일 단위 수질측정자료를 이용하여 단기조류예측모형을 구축하였다. 단기조류예측모형에 대한 적정성을 평가하고자 RMSE,  $R^2$ 의 분석을 실시하였고, 그 결과 대체적으로 예측기간 1, 3, 7일 예측 중 1일 예측의 경우 결과의 정확도가 가장 높게 나왔으며 다음으로 3일 예측, 마지막으로 7일 예측 결과의 순으로 분석되었다. 조류예측에 관한 수질 및 수문성 분별 예측 결과 및 구축 모형은 chl-a의 과거 관측 자료가 예측 정도를 높여주는 가장 중요한 역할을 하는 성분이며, 영양염류의 경우 구성되는 입력성분에 따라 예측 기간별 정확도가 다르게 나타났다. 모든 수문 및 수질 성분은 교차상관관계로 연결되어 있으므로 모형을 구축하여 민감도 분석을 세부적으로 실시하였으나 결국 모든 인자를 적절

한 지체시간에 따라 고려할 때 가장 좋은 결과가 도출됨을 알 수 있었다. 즉 Table 4의 CCA분석 결과에서 알 수 있듯이 chl-a에 대하여 수문 및 수질성분 중 가장 상관도가 높은 것은 TOC 0.62, Tw 0.60, pH 0.53이었으며, 이들 자료와 함께 Lag Time이 고려된 TN, TP 등의 다양한 수질 성분이 고려되었을 때 우수한 단기조류예측모형이 구축되었다. 본 연구에서는 자동수질측정망의 관측 자료를 이용하여 12가지 단기조류예측모형을 구축하였고 RMSE와  $R^2$ 의 값을 이용하여 적절한 모형을 선정하였다. 그 결과, 우수한 결과를 보인 Model 6, Model 7, Model 10 중에서 특히 수온, pH, DO, TOC, TN, TP, chl-a의 입력성분으로 구성된 Model 7이 조류예측능력이 우수한 모형으로 선정되었다. 본 연구에서 사용된 인공지능망의 단점이라 할 수 있는 자료의 개수에 대한 한계성을 고려할 때, 사용된 수질관측자료의 기간이 2009년부터 2010년의 2년간의 자료를 활용하

여 도출된 결과임을 고려할 때 장기 관측된 수질측정 자료를 활용한다면 1일 뿐 아니라 3일, 7일 또는 그 이상의 예측의 경우에도 예측의 정확도가 상승될 것으로 판단된다.

## 5. 결 론

본 연구의 결론은 다음과 같다.

- 1) 대상유역에 대하여 chl-a 예측의 경우, 자연현상을 과학적으로 모두 이해하고 고려하기란 쉽지가 않다. 따라서 신경망 기반의 chl-a의 예측의 경우, 수문뿐 아니라 기상과 다양한 수질성분이 적절하게 고려되었을 때 가장 예측정도가 높음을 알 수 있다.
- 2) 대청호 유역 내 실시간 수질자동측정망 시스템의 2년 동안의 수집된 자료를 기반으로 수질예측모형을 구축하였다. 신경망의 특성 상 수집된 자료의 개수가 더 많다면 chl-a의 예측모형의 입력성분으로 chl-a의 지체시간을 둔 chl-a 성분을 고려하지 않더라도 예측정도가 높은 수질예측모형의 구축이 가능할 것이다.

본 논문의 결과에서 알 수 있듯이 실시간 수질자동측정망 시스템을 이용한 활용성을 높이고 이를 활용한 신경망 기반의 단기조류예측모형을 함께 구축한다면 조류발생에 의한 부영영화 현상의 피해를 감소시킬 수 있을 것이다. 또한 장기 관측된 자료를 이용하여 조류예측모형을 구축한다면 7일 이상의 장기 예측 모형 역시 구축이 가능할 것으로 사료된다. 향후 물리적인 모형에 의한 예측 결과와의 비교 검증은 통한 시스템 모형의 신뢰성 정도를 분석할 필요가 있을 것이다.

## 감사의 글

본 연구는 한국환경산업기술원에서 주관하는 차세대에코이노베이션기술개발사업의 일원인 통합 비점 유출 모형 개발 및 실용화 연구의 지원으로 수행되었습니다.

## References

Ahn, S.J., Yeon, I.S., Han, Y.S., and Lee, J.K. (2001). "Water quality forecasting at Gongju station in Geum River using neural network model." *Journal of the Korean Society of Civil Engineers*, Vol. 34, No. 5, pp. 701-711.

Cho, Y.J., Yeon, I.S., and Lee, J.K. (2004). "Application of neural network model to the real-time forecasting of water quality." *Journal of Korean Society on Water Quality*, Vol. 18, No. 4, pp. 321-326.

Karula, C., Soyupaka, S., Çilesizc, A.F., Akbayb, N., and Germenb, E. (2000). "Case studies on the use of neural networks in eutrophication modeling." *J. Ecological Modelling*, Vol. 134, pp. 145-152.

Lee, E.H., and Seo, D.I. (2002). "Water quality modelling of the Keum River-Effect of Yongdam Dam." *Journal of Korea Water Resources Association*, Vol. 35, No. 5, pp. 525-539.

Oh, C.R., Jin, Y.H., Kim, D.R., and Park, S.C. (2008). "Study on development of artificial neural network forecasting model using runoff, water quality data." *Journal of Korea Water Resources Association*, Vol. 41, No. 10, pp. 1035-1044.

Oh, C.R., Park, S.C., Lee, H.M., and Pyo, Y.P. (2002). "A forecasting of water quality in the Youngsan River using neural network." *Journal of the Korean Society of Civil Engineers*, Vol. 35, No. 5, pp. 525-539.

Park, S.C., and Ha, S.J. (2003). "Forecasting the water quality of river using GANN." *Journal of the Korean Society of Civil Engineers*, Vol. 23, No. 6B, pp. 507-514.

Recknagel, F., French, M., Harkonen, P., and Yabunaka, K.I. (1994). "Artificial neural network approach for modeling and prediction of algal blooms." *J. Ecological Modelling*, Vol. 96, pp. 11-28.

Singh, K.P., Basant, A., Malik, A., and Jain, G. (2009). "Artificial neural network modeling of the river water quality-a case study." *J. Ecological Modelling*, Vol. 220, pp. 888-895.

Wilson, H., Recknagel, F. (2001). "Towards a generic artificial neural network model for dynamic predictions of algal abundance in freshwater lakes." *J. Ecological Modelling*, Vol. 146, pp. 69-84.

|                              |                  |
|------------------------------|------------------|
| 논문번호: 12-128                 | 접수: 2012.12.26   |
| 수정일자: 2013.03.20/03.30/04.09 | 심사완료: 2013.04.09 |