

ARIMA모형과 인공신경망모형의 BOD예측력 비교

정효준 · 이홍근[†]
서울대학교 환경보건학과

Comparison of the BOD Forecasting Ability of the ARIMA model and the Artificial Neural Network Model

Hyo June Jeong · Hong Keun Lee[†]

Dept. of Environmental Health Science, Graduate School of Public Health, Seoul National University
(Received 2 July, 2002; Accepted 15 August, 2002)

ABSTRACT

In this paper, the water quality forecast was performed on the BOD of the Chungju Dam using the ARIMA model, which is a nonlinear statistics model, and the artificial neural network model. The monthly data of water quality were collected from 1991 to 2000. The most appropriate ARIMA model for Chungju dam was found to be the multiplicative seasonal ARIMA(1,0,1)(1,0,1)₁₂ model. While the artificial neural network model, which is used relatively often in recent days, forecasts new data by the strength of a learned matrix like human neurons. The BOD values were forecasted using the back-propagation algorithm of multi-layer perceptrons in this paper. Artificial neural network model was composed of two hidden layers and the node number of each hidden layer was designed fifteen. It was demonstrated that the ARIMA model was more appropriate in terms of changes around the overall average, but the artificial neural network model was more appropriate in terms of reflecting the minimum and the maximum values.

Keywords : ARIMA, Artificial neural networks, Back-propagation, Forecasting

I. 서 론

하천의 특정지점에서 나타나는 수질변화의 특성을 관측하고 그 특성을 파악하여 향후 수질변동을 예측하는 것은 수질관리에 있어서 매우 중요한 요소 중의 하나이다. 연속측정된 데이터를 이용한 장단기 수질예측은 데이터마이닝(data mining)기법의 일종으로 전이함수 모형이나 칼만필터링 모형 및 ARIMA모형등이 일반적으로 사용되고 있다. 단변량 자료에 있어서는 Box-Jenkins모형으로 불리는 ARIMA모형이 널리 사용되고 있다. 이는 1970년 Box와 Jenkins가 일반적으로 관측되는 시계열을 독립적이 아닌 연속적인 시계열로 생각하고 모수(parameter)의 수가 작고 간단한 추계학적모형을 제시한 이래 경제학, 공학 및 자연과학의 여러분야에 널리 적용하고 있다. 수문 및 수질분야에서도 이

에 대한 많은 연구가 있어왔다. Ahmad(2001)는 수질자료의 예측에 있어서 추계학적모형의 예측력을 비교하였는데, 여기서는 ARIMA모형과 Thomas-fiering 모형 중 수질데이터의 장기예측에는 ARIMA모형이 Thomas-fiering모형보다 뛰어난 것을 보였다.¹⁾ 한편 Hameed(1996)는 관개수로 내에서 물의 유실에 대해 시계열적 분석을 통하여 계절에 따른 물의 손실모형을 구축하고, 장래 물 손실량의 예측을 실시하였다.²⁾ 이러한 수질 및 수문데이터에 대한 ARIMA모형의 구축 및 적용과정은 박스-젠킨슨 및 Montanari(1997)이 지적하였듯이 모형의 식별, 모수의 추정, 예측의 과정을 따르게 된다.³⁾ 한편, 최근에는 인간의 신경회로망을 모방한 인공신경망모형이 수질 및 수문학분야에도 활발히 응용되어, 수질관리를 위한 의사결정 도구로 사용되고 있다. 인공신경망은 인간의 두뇌를 모형화한 것으로 반복된 학습을 통해 시냅스의 강도를 조절하여 동일하거나 비슷한 사상이 발생했을 때, 학습된 논리에 의하여 반응을 보이는 과정을 수학적으로 수식화한 데이터마이닝(data mining) 기법의 일종이다. 이러한 신경망이론은 경영과

[†]Corresponding author : Dept. of Environmental Health Science, Graduate School of Public Health, Seoul National Univ. Tel: 02-740-8871, Fax : 02-762-8760 E-mail : leehk@snu.ac.kr

학에 있어서 고객의 행태를 예측 혹은 분류하는데 많이 이용되고 있는데 Law(2000)는 인공신경망의 역전파 알고리즘을 이용하여 관광객의 수요 예측을 시도하였다.⁴⁾ 이러한 신경망이론은 Kolehmainen(2001)이 대기 중의 질소화합물의 농도 예측에 적용하였으며,⁵⁾ Maier(1998)는 하천에서 cyanobacteria의 밀도를 인공신경망으로 해석하는 등 환경관리 분야에 많이 적용되고 있다.⁶⁾ 또한 Luk(2000)등은 연속된 강우측정 자료를 이용하여 지연시간에 따른 강우사상 예측의 효율성 평가를 인공신경망을 이용하여 분석한 바 있고,⁷⁾ See(2001)는 하천의 홍수위를 신경망이론을 이용해 예측하는 등 수자원 분야에도 응용되고 있다.⁸⁾ 또한, Hwang(2001)은 전통적으로 통계적 예측에 많이 이용되어 왔던 ARIMA 모형과 신경망모형과의 효용성을 평가하는 연구를 한 바 있다.⁹⁾ 본 연구는 충주호의 BOD수질특성을 파악하기 위해 비선형통계모형중 ARIMA모형과 인공신경망모형을 이용하여 BOD 예측력을 평가하였다.

II. 연구방법

1. 수질자료

본 연구에 사용된 BOD시계열자료는 1991년부터 2001년까지의 충주댐의 방류수질자료(충북 충주시 종인동 댐앞)를 환경연감과 환경부홈페이지로부터 월별 수질측정자료를 획득한 것이다.^{10,11)} 충청북도에 위치한 충주호는 유역면적이 6,648 km²로 남한강에 위치하는 가장 큰 다목적댐으로서 강우시 홍수조절기능과 충청권의 광역상수도로 이용되는 댐이다. 현재까지는 다른 유역에 비해 상류에 오염원이 비교적 적게 분포하기 때문에 1급수 정도의 양호한 수질을 유지하고 있다. 충주댐의 수량 및 수질은 남한강 전체의 수질에 큰 영향을 미치고 있으며, 현재까지는 비교적 양호한 수질로 인해 남한강의 희석용수로서 중요한 역할을 하고 있다. ARIMA모형의 구축 및 수질의 예측은 통계 전산프로그램인 SPSS 10.0의 시계열 분석 모듈을 이용하였으며 인공신경망의 훈련 및 수질값의 예측에는 Matlab 5.3의 Neural Network Toolbox를 이용하였다.

2. ARIMA모형의 구축

시계열분석에서 모형을 선택하는 방법으로는 Box와 Jenkins가 제안한 모형의 식별(model identification), 모형의 추정(model estimation), 모형의 진단(model diagnostic checking)의 세단계를 한주기(cycle)로 한 방법이 일반적으로 사용되고 있다. 모형의 식별단계에서는 자기회귀의 차수 p 와 이동평균의 차수 q 를 정하는

것으로 시계열도표(time series plot), 자기상관함수(ACF), 편자기상관함수(PACF) 등을 이용해서 AR의 차수 p 와 차분차수 d , MA차수 q 를 결정하였다. 수질값 시계열의 정상성 여부를 조사한 후 비정상적인 경우에는 변수 변환이나 차분법 혹은 계절성분의 제거 등을 사용해서 정상시계열을 만든 후에 ACF와 PACF를 통해 p , q 를 결정하였다. 한편 모형식별에 사용되는 통계량으로는 AIC(Akaike Information Criterion)와 SBC(Schwartz's Information Criterion)를 사용하였으며 가능한 모형 중에 AIC와 SBC를 최소화하는 p , q 를 모형의 차수로 결정하였다. 모형의 추정 단계에서는 모형식별단계에서 잠정적으로 선택된 ARIMA(p , d , q)시계열 모형의 모수를 추정하는 것이다. 일반적으로 많이 쓰이는 모수의 추정 방법으로는 최적우도추정법(maximum likelihood estimation), 비조건부 최소제곱추정법(unconditional least squares estimation), 조건부 최소제곱추정법(conditional least squares estimation)이 있으며 이외에도 베이지추정법(Bayesian estimation) 등이 있는데, 본 연구에서는 비조건부 최소제곱추정법을 모형의 모수추정에 이용하였다. 모형의 검진단계는 추정된 시계열의 모형이 오차항에 대한 가정, 다시 말해 오차항이 백색잡음과정을 만족하는 지를 검토하는 것이다. ARIMA 모형의 기본가정은 잔차의 시계열(a_t)이 백색잡음과정을 따르는 것으로, 수립한 모형이 실제 시계열에 적합하면 추정 후의 잔차가 백색잡음과정에 따른다. 따라서 본연구에서 잔차들이 백색잡음과정을 따르는지를 확인하기 위해서 95%의 신뢰구간에서 잔차의 ACF와 PACF를 통해 모형의 적합정도를 판단하였다.

위와 같은 모형의 식별(identification), 모수의 추정(estimation), 검진(diagnosis)의 단계를 반복하여 모형을 확정하고, 확정된 모형을 이용하여 장래의 BOD값을 예측하였다.

3. 인공신경망모형의 구축

신경망이론은 인간 신경세포인 뉴런의 시스템을 컴퓨터를 이용하여 구현한 인공지능 분야의 하나로서, 패턴 인식, 식별 및 분류, 의사결정 등에 응용되고 있는 기술이다. 이러한 신경망은 인간의 두뇌와 비슷한 병렬처리(parallel processing)기능으로 인해 분명하지 않은 애매모호한 정보를 외부 목표인자에 맞도록 자신을 변화시켜 자기조직화하는 학습능력을 가지고 있다. 따라서 내부에서 일어나는 일련의 과정보다는 나타나는 결과에 중요성을 둘 경우 신경망은 큰 힘을 발휘하게 된다. 본 연구에서 구성한 신경망은 1개의 입력층과 2개

의 은닉층 그리고 1개의 출력층을 가지는 다층신경망으로 구성하였다. 은닉층의 갯수와 노드수를 결정하는 뚜렷한 이론은 아직까지 밝혀지지 않았으나 대부분의 경우 1개 혹은 2개로 설계하고 있고, 경험적으로 2개 이상의 은닉층에서는 학습의 증가효과를 거의 나타내지 않는 것으로 나타나, 본 연구에서도 은닉층의 갯수는 2개로 하였다.¹²⁾ 은닉층에 존재하는 인간의 뉴런수에 해당하는 노드수를 결정하는 데는 일반적으로 시행오차법(trial and error method)을 통해 구하게 된다. 노드수가 지나치게 작으면 효율적으로 학습이 일어나지 않으며, 지나치게 많으면 학습의 효율이 급격히 떨어지는 역효과를 나타내기도 한다. 따라서 본 연구에서는 은닉층의 노드수는 $5N(N=1, 2, \dots)$ 으로 증가시켜 가면서 MSE를 관찰하여 뉴런의 수를 결정하였다. 신경망에서 사용되는 대표적인 전이함수는 시그모이드(sigmoid)형, 계단함수(hard limiter), 임계논리(threshold logic)함수 등이 있다. 본 연구에서는 첫 번째 은닉층은 전이함수로 시그모이드(sigmoid)함수를 사용하였으며, 두 번째 레이어에는 선형(linear)함수를 사용하였다. 이러한 연속된 두 개의 전이함수를 은닉층(hidden layer)에 설계하여 신경망의 훈련에 이용하였다. 시그모이드함수는 최대값과 최소값 부근에서는 응답값의 변화가 적고 평균부근에서는 응답값의 변화가 크며 미분가능한 함수이기 때문에 비선형시스템의 구현에 가장 널리 이용되고 있다. 신경망학습을 위해서 학습자료를 준비하여, 적용할 전이함수에 맞게 자료를 변환한 후 입력자료 셋을 구성하였다. 신경망의 입력노드의 수와 출력노드의 수, 그리고 은닉층의 수를 정한 후, 가중치벡터와 임계치 벡터를 랜덤함수를 이용하여 초기화시키고, 입력데이터를 학습시켜 목표데이터에 근사시키도록 훈련시켰다. 마지막으로 훈련된 신경망에 새로운 데이터를 입력하여 예측값을 생성해 냈다. 이러한 신경망 학습에서 입력층에서 은닉층을 거쳐 출력층으로 데이터가 출력되어 목표값과 비교되어 MSE(Mean Square Error)를 산출하는 과정을 1주기(epoch)이라고 한다. 신경망의 주기가 증가되면서 MSE값이 미리 설정해 놓은 수렴한계에 도달했을 때 신경망의 학습은 종료하게 된다. 인공신경망의 학습시 MSE의 합이 1×10^{-4} 이 될 때 신경망의 학습을 종료하도록 하였다.

III. 결과 및 고찰

1. ARIMA 모형

ARIMA모형과 인공신경망이론을 이용한 충주호의 BOD예측에 대한 결과는 다음과 같다. Fig. 1은 1991




Fig. 1. Time series plot of BOD from 1991 to 1999.




Fig. 2. Trend analysis of BOD using roess smoothing.

년부터 1999년까지의 충주호의 BOD시계열을 순차도표로 나타낸 것이다. 90년대 초반에 비해서 90년대 후반으로 갈수록 연도별 BOD값의 변동폭이 줄어들음을 알 수 있다. Fig. 2는 BOD시계열을 Loess Smoothing함수에 의해 추세를 살펴본 것으로서 충주호의 BOD는 유역 상류의 지속적인 수질관리 대책에 힘입어 완만하게 감소하는 추세를 나타내고 있는 것으로 관찰되었다. BOD값은 최고 2.0에서 최저 0.6까지 분포하고 있으며, 원시계열을 자연로그 변환하고 ACF와 PACF를 관찰한 결과 Fig. 3에 나타난 바와 같이 BOD값은 계절적인 변동을 나타내고 있어 계절성분을 고려한 계절모형과 ARIMA모형을 승법으로 결합시킨 계절ARIMA모형을 이용하여 원시계열의 모형을 적합시켰다. 모형의 형태로는 $ARIMA(1,0,1)(1,0,1)_{12}$, $ARIMA(1,1,1)(1,0,1)_{12}$ 및 $ARIMA(1,0,1)(1,1,1)_{12}$ 가 가능했다. 따라서 Table 1과 같이 AIC 및 SBC를 비교하여 ARIMA




Fig. 3. ACF and PACF of log-transformed time series data.

Table 1. Statistical summary of tentative model

| Model | AIC | SBC | Standard error | Log likelihood |
|-----------------------------------|--------|--------|----------------|----------------|
| ARIMA(1,0,1)(1,0,1) ₁₂ | -46.78 | -33.37 | 0.19 | 28.39 |
| ARIMA(1,1,1)(1,0,1) ₁₂ | -29.77 | -16.94 | 0.18 | 19.88 |
| ARIMA(1,0,1)(1,1,1) ₁₂ | -44.54 | -31.18 | 0.19 | 27.27 |

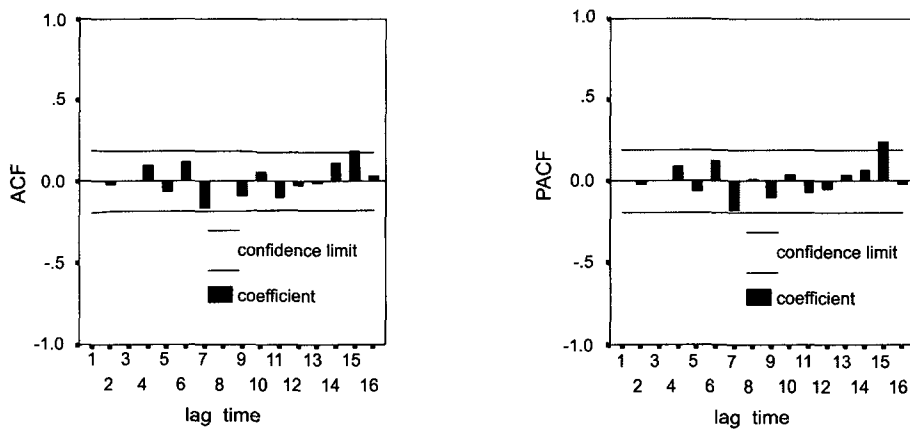


Fig. 4. ACF and PACF of residual time series.

(1,0,1)(1,0,1)₁₂으로 모형을 잠정 결정하였다.

ARIMA(1,0,1)(1,0,1)₁₂의 모수추정 결과 AR1성분은 0.4137, MA1성분은 -0.0953으로 나타났으며 계절성분의 SAR1은 0.8307, SMA는 0.6539 그리고 상수항은 -0.1095로 었다. ARIMA(1,0,1)(1,0,1)₁₂은 차분의 차수가 모두 0이므로 다음과 같이 나타낼 수 있다.

$$(1 - \phi_1 B)(1 - \Phi_1 B^{12})Z'_t = (1 - \theta_1 B)(1 - \Theta_1 B^{12})a_t \quad (1)$$

$$Z'_t = -0.1095 + 0.4137Z_{t-1} - 0.0953Z_{t-12} + 0.0394Z_{t-13} + a_t - 0.6539a_{t-12} - 0.8307a_{t-1} + 0.5432a_{t-13} \quad (2)$$

추정한 모형의 원시계열 적합성을 알아보기 위해서 잔차의 ACF와 PACF를 이용하였다. 추정된 모형에 의해서 얻어진 잔차의 plot이 Fig. 4에 나타난 바와 같이 95% 신뢰한계 내에서 추정된 모형들의 잔차가 모두 백색잡음과정(white noise process)를 따르고 있으므로 위




Fig. 5. Comparison of actual and computed value by ARIMA.

에서 제시한 충주댐의 BOD모형이 실측데이터를 양호하게 근사시킴을 알 수 있다.

위와 같이 구축된 모형을 이용하여 2000년 1월부터 12월까지 실측치와 ARIMA모형이 예측한 값의 비교는 Fig. 5와 같다. ARIMA모형으로 계산된 값이 전체적으로 과소추정하는 경향이 있는 것으로 나타났다. 한편, 1월과 4월 및 7월의 결과는 관측치와 실측치의 경향이 다소 차이가 있는 것으로 나타났다. 이는 1개월 수질의 대표치를 특정한 날에 측정하여 제시하는 한계에서 비롯되는 것으로 판단된다.

2. 인공신경망 모형

BOD수질값을 학습시키기 위해 구성된 인공신경망의 은닉층에 사용된 시그모이드 함수의 경우, 최소값과 최대값이 0.0~1.0의 사이를 변동하는 특성을 가지므로 신경망에 입력되는 데이터를 변환하여 시그모이드함수의 특성에 맞추도록 전처리(preprocessing)를 할 필요가 있다. 신경망의 훈련시 입력데이터의 변화율이 지나치게 커지면 학습율이 현저하게 감소하는 경향이 있으며, 또한 목표로 하는 MSE에 도달하지 못하는 경우도 많다. 시그모이드 전이함수의 특성을 고려한 입력데이터의 변환에는 입력데이터의 최대값과 최소값을 이용한 선형 변환과 대수변환이 사용될 수 있다.¹³⁾ 본 연구에서는 BOD값을 대수변환을 이용하여 식 (3)과 같이 입력데이터를 변환하여 사용하였다.

$$z = a \log_{10}(x + b) \tag{3}$$

여기서 z : 변환된 데이터, a : 임의의 상수, b : 입력 데이터가 0인 경우를 고려한 0이 아닌 상수, a 값은 0.5를 사용하였으며, b 의 값은 1을 사용하였다. 이렇게 변환되어 출력된 값은 식 (4)와 같이 원래의 값으로 환원

Table 2. Data transformation for transfer function(2002)

| Month | BOD | |
|-------|--------|-------------|
| | Actual | Transformed |
| 1 | 0.9 | 0.139377 |
| 2 | 0.8 | 0.127636 |
| 3 | 0.9 | 0.139377 |
| 4 | 0.9 | 0.139377 |
| 5 | 1 | 0.150515 |
| 6 | 0.8 | 0.127636 |
| 7 | 0.7 | 0.115224 |
| 8 | 1.1 | 0.161111 |
| 9 | 1 | 0.150515 |
| 10 | 0.9 | 0.139377 |
| 11 | 0.8 | 0.127636 |
| 12 | 0.8 | 0.127636 |




Fig. 6. MSE variation of BOD by hidden layer's node number.

하였다.

$$x = 10^{(z/a)} - b \tag{4}$$

Table 2는 2000년 BOD측정값의 변환예를 제시하였다.

인공신경망의 은닉층의 노드수를 결정하기 위해 노드수의 변화에 따른 MSE의 변화를 Fig. 6에 나타내었다. Fig. 6에 의하면 은닉층의 노드수는 15개가 타당한 것으로 나타났다. 그 이상의 노드수 증가는 MSE의 변화에 큰 영향을 나타내지 못했다.

충주댐지점의 BOD수질값을 입력데이터 매트릭스로 이용하기 위해 1991년부터 2000년까지 측정된 데이터를 이등분하여 입력층의 지체시간(lag time)을 1991년부터 1994년까지 4년으로 하여 입력매트릭스를 4×12행렬로 구성하였으며, 목표층에는 1995년의 데이터를 1×12행렬로 구성하여 신경망 훈련에 이용하였다. 또한 신경망을 훈련시키기 전 가중치 행렬과 임계치 행렬은




Fig. 7. Comparison of actual and computed value by artificial neural networks.

랜덤행렬을 이용해 초기화하였다. 이렇게 구성된 신경망을 훈련시켜 가중치와 임계치벡터의 강도를 조정하였으며, 1996년부터 1999년 데이터를 이용하여 2000년의 수질값을 예측하였다. 인공신경망의 학습에는 역전파알고리즘의 경사하강법(gradient descent method)을 사용하였고, 학습율은 0.05를 적용하고, 오차함의 합이 $1 \times E-4$ 이하가 되면 학습을 종료하도록 하였다. 훈련된 인공신경망을 이용하여 2000년 1월부터 12월까지 실측치와 인공신경망모형이 예측한 값의 비교는 Fig. 7과 같다.

ARIMA모형 및 인공신경망모형을 통한 BOD예측값과 실측값을 이용하여 MSE와 MAPE를 산정하였다. 실제 관측값(Y_t)와 예측값(\hat{Y}_t)의 차이를 예측오차라고 하며 이 예측오차의 절대값의 평균의 백분율을 평균절대편차비(MAPE)라고 한다.

$$MAPE = \frac{\sum_{t=1}^n |e_t|}{n} = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \times 100 \quad (5)$$

한편, 평균제곱오차(Mean Squared Error)는 예측오차의 제곱을 평균한 값으로 일반적으로 가장 많이 이용하는 예측평가의 방법이다.

$$MSE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|^2 \quad (6)$$

ARIMA모형의 MSE는 0.025를 나타내었으며, 인공신경망 모형은 0.030으로 ARIMA모형보다는 다소 큰 값을 나타내었다. 마찬가지로 MAPE 경우 ARIMA모형이 14.76, 인공신경망 모형이 14.78로 나타났다. 예측력을 평가하는 인자들의 비교에서는 ARIMA모형이 인공

신경망 모형에 비해 장래 예측에 있어서 약간 양호하다고 평가할 수 있으나, 최대값과 최소값을 예측하는 능력은 인공신경망모형이 ARIMA모형에 비해 더 나은 결과를 보였다.

IV. 결 론

비선형통계모형 중 ARIMA모형과 인공신경망모형을 적용하여 충주호의 BOD를 예측하여 그 예측력을 평가하여 본 결과 다음과 같은 결론을 얻었다.

1. 인공신경망모형은 모형의 구축시 데이터의 fitting 면에서는 ARIMA모형에 비해서 양호한 결과를 나타내지만 예측력은 반드시 비례하여 증가하는 것은 아니었다. 충주호의 BOD예측결과 ARIMA모형이 인공신경망모형에 비해 근소하게나마 더 나은 예측결과를 나타내었다.

2. 충주호의 BOD수질현상에 대한 ARIMA모형은 승법계절 ARIMA모형인 $ARIMA(1,0,1)(1,0,1)_{12}$ 가 적당한 것으로 나타났다. 또한 인공신경망 모형의 경우, 은닉층을 두 개로 하고, 전이함수로 시그모이드 함수와 선형함수를 설계한 결과 BOD의 학습에 적합한 은닉층의 노드수는 15개로 나타났다.

3. 장기적으로 측정된 시계열 데이터의 통계적 해석에는 ARIMA모형이나 인공신경망모형과 같은 비선형통계모형을 통하여 수질현상을 해석하는 것이 타당한 것으로 보이며, 수질데이터의 해석시 인공신경망모형의 학습능력향상을 위한 적절한 전처리가 학습소요 시간의 감소 뿐만 아니라 데이터의 예측력 향상에도 기여하는 것으로 나타났다.

참고문헌

1. Ahmad, S., Khan, I. H. and Parida, B. P.: Performance of stochastic approaches for forecasting river water quality. *Wat. Res.*, **35**, 4261-4266, 2001.
2. Hameed, T. Marino, M. A. and Cheema, M. N.: Time series modeling of channel transmission losses. *Agricultural Water Management*, **29**, 283-298, 1996.
3. Montanari, A. and Rosso, R.: Fractionally differenced ARIMA models applied to hydrologic time series (Identification, estimation, and simulation). *Water Resources Research*, **33**, 1035-1044, 1997.
4. Law, R.: Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting. *Tourism Management*, **21**, 331-340, 2000.
5. Kolehmainen, M., Martikainen, H. and Ruuskanen, J.: Neural networks and periodic components used in air quality forecasting. *Atmospheric Environment*, **35**, 815-825, 2001.

6. Maier, H. R., Dandy, G. C., and Burch, M. D. : Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. *Ecological Modelling*, **105**, 257-272, 1998.
7. Luk, K. C., Ball, J. E. and Sharma, A. : A study of optimal model lag and spatial input to artificial neural network for rainfall forecasting. *Journal of Hydrology*, **227**, 56-65, 2000.
8. See, L. and Abrahart, R. J. : Multi-model data fusion for hydrological forecasting. *Computer & Geosciences*, **27**, 987-994, 2001.
9. Hwang, H. B. and Ang, H. T. : A simple neural network for ARMA(p, q) time series. *The International Journal of Management Science*, **29**, 319-333, 2001.
10. 환경부, 환경연감, 1990-2000.
11. <http://www.me.go.kr/www/index.html>.
12. Kung, S. Y. : Digital Neural Networks, Prentice Hall International Inc. 30-33, 1993.
13. Balkin, S. D. and Ord, J. K. : Automatic neural network modelling for univariate time series. *International Journal of Forecasting*, **16**, 509-515, 2000.