

인공신경망 이론을 이용한 충주호의 수질예측

정 호 준 · 이 소 진 · 이 흥 근

서울대학교 보건대학원 환경보건학과

(2001년 10월 16일 접수; 2002년 3월 8일 채택)

Water Quality Forecasting of Chungju Lake Using Artificial Neural Network Algorithm

Hyo-Joon Jeong, So-Jin Lee and Hong-Keun Lee

Dept. of Environmental Health Science, Seoul National Univ., Seoul 110-799, Korea

(Manuscript received 16 October, 2001; accepted 8 March, 2002)

This study was carried out to evaluate the artificial neural network algorithm for water quality forecasting in Chungju lake, north Chungcheong province. Multi-layer perceptron(MLP) was used to train artificial neural networks. MLP was composed of one input layer, two hidden layers and one output layer. Transfer functions of the hidden layer were sigmoid and linear function. The number of node in the hidden layer was decided by trial and error method. It showed that appropriate node number in the hidden layer is 10 for pH training, 15 for DO and BOD, respectively. Reliability index was used to verify for the forecasting power. Considering some outlying data, artificial neural network fitted well between actual water quality data and computed data by artificial neural networks.

Key words : artificial neural networks, back-propagation, transfer function, water quality forecasting

1. 서 론

하천이나 호소에서 일어나는 수질현상의 예측은 향후 수질관리 대책을 수립하는데 있어서 매우 중요한 요소이다. 이러한 수질예측을 위한 도구로서 물질수지방정식을 이용한 다양한 모형들이 개발되어 사용되고 있으며, 현재에도 이들을 보완하기 위한 연구들이 계속되고 있다. 그러나 개발모형의 정확성을 증가시키기 위해 지나치게 많은 파라미터들을 요구하고 있어 실제 적용에 있어서 많은 어려움이 있는 것 또한 사실이다. 한편, 축적된 환경질에 대한 데이터를 이용하여 이들 데이터의 특성을 모형화 하려는 통계적인 기법들이 수질현상의 해석에 많이 도입되어 왔다. 대표적으로 박스-젠킨슨의 ARIMA모형이 유역에서 일어나는 강우사상의 추적이나, 하천이나 호소에서 일어나는 수질현상의 해석

을 위해 사용되고 있다.

그러나 박스-젠킨슨의 시계열 모형은 모형의 차수가 증가하면, 모형식이 지나치게 복잡해지는 문제점이 있어, 모형을 지나치게 단순하게 하려는 시도 때문에 예측한 데이터의 효율이 떨어지는 경향이 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 경영과학에 있어서 고객의 행태를 예측 혹은 분류하는데 많이 이용되고 있는데 Law¹⁾는 인공신경망의 역전파알고리즘을 이용하여 관광객의 수요를 예측을 시도하였다. 이러한 신경망은 환경분야에서 대기중의 질소화합물의 농도 예측,²⁾ 하천에서 cyanobacteria의 도를 신경망으로 해석³⁾ 등의 많은 적용사례가 있다. 또한 Luk⁴⁾ 등은 연속된 강우측정 자료를 이용하여 지연시간에 따른 강

Corresponding Author : Hyo-Joon Jeong Dept. of Environmental Health Science, Seoul National Univ., Seoul 110-799, Korea
Phone : +82-2-740-8871
E-mail : hymr0319@snu.ac.kr

우사상 예측의 효율성 평가를 인공신경망을 이용하여 분석한 바 있고, See⁵⁾ 등은 하천의 홍수위를 신경망이론을 이용해 예측하는 등 수자원 분야에도 응용되고 있다. 또한, 전통적으로 통계적 예측에 많이 이용되어 왔던 ARIMA 모형과 신경망모형과의 효율성을 평가하는 연구⁶⁾ 등이 이루어지고 있다.

본 연구는 충주호의 pH, DO 및 BOD의 수질특성을 신경망이론을 이용해 예측한 것으로, 다층퍼셉트론의 역전파알고리즘을 사용하여 신경망을 학습시켰으며, 학습된 신경망을 이용하여 향후의 수질값을 예측하도록 하였다.

2. 신경망이론

신경망이론은 인간 신경세포인 뉴런의 시스템을 컴퓨터를 이용하여 구현한 인공지능 분야의 하나로써, 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 자기조직화 하는 학습능력을 가지고 있다. 따라서 내부에서 일어나는 일련의 과정보다는 나타나는 결과에 중요성을 둘 경우 신경망은 큰 힘을 발휘하게 된다.

Fig. 1은 인간의 신경망을 나타낸 것으로 각 뉴런은 세포체, 수상돌기, 축삭돌기로 구성되어 있으며 축삭돌기의 연결부를 시냅스라고 한다. 인간의 뇌는 신경세포가 매우 복잡하게 연결된 네트워크로서 외부 혹은 다른 신경세포로부터 시냅스를 통하여 입력신호를 받아 세포체에서 적절한 처리를 하여 그 결과를 축삭돌기를 통해 다른 신경세포에 전달하는 기능을 수행한다. 이를 수학적으로 표현한 것이 인공신경망 모형이다.




Fig. 1. Structure of Neural network.

신경망의 훈련에는 자율학습과 지도학습의 두가지로 구별할 수 있다. 자율학습(self organized learning)은 정확한 정보없이 자기조직화에 의해 훈련을

하게 되고, 지도학습(supervised learning)은 입력데이터를 목표데이터에 근접하도록 훈련시키는 것이다. 전형적인 인공신경망은 뉴런의 수를 나타내는 노드(node)의 집합으로 이루어지며 입력노드는 입력신호를 받고, 출력노드는 출력신호를 내보내며 임의의 개수의 은닉층(혹은 중간층)은 중간노드의 합으로 이루어진다.

2.1. 다층퍼셉트론(multi-layer perceptron)

퍼셉트론은 입력값, 출력값, 가중치 및 임계치 벡터를 구성요소로 한다. 입력값은 가중치와 곱하고 임계값을 더하여 전이함수(transfer function)에 보내지고 전이함수를 통과한 값은 은닉층을 거쳐 출력값으로 보내지게 된다. 가중치는 인간뇌의 뉴런에서 시냅스의 강도에 해당하며 임계값은 전달함수가 0으로부터 벗어나는 역할을 하게 된다. 신경망에서 입력층의 값은 어떠한 작용도 일어나지 않으며, 단순히 값을 다음층에 있는 값에 가중치를 곱하여 전달하는 역할을 하게 된다. 이렇게 입력층과 출력층 사이에 하나의 층만이 존재하는 것을 단층퍼셉트론이라고 하며, 2개 이상의 층으로 구성되어 있는 것을 다층퍼셉트론이라 한다. 단층퍼셉트론은 선형분리 가능한 입력패턴만을 분리할 수 있는 한계로 인해, 1969년 민스키와 파퍼트에 의해 그 한계성이 밝혀진 이후로 거의 사용되지 않고 있으며, 1980년대 이후 등장한 다층퍼셉트론이 최근 연구의 근간을 이루고 있다.⁷⁾

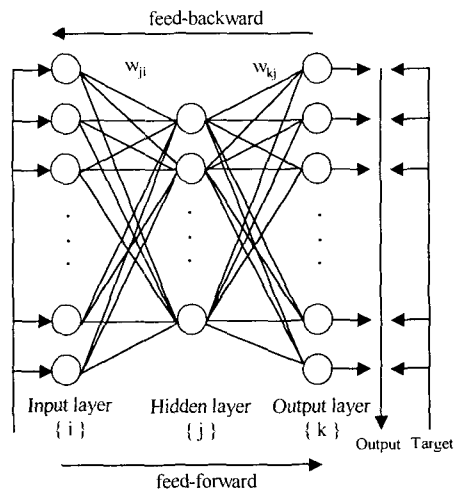


Fig. 2. Schematic diagram of multi-layer perceptron.⁸⁾

Fig. 2는 신경망의 구조를 설명하고 있는 것으로 입력값(I_j)은 아래의 식과 같이 가중치와 임계값을

이용하여 구해진다.

$$I_j = \sum w_{ji} x_i + B_j$$

여기서 x_i : 입력층의 데이터, w_{ji} : 가중치 벡터 즉 연결강도 벡터, B_j : 임계값 벡터를 나타낸다. 이렇게 계산된 값은 미리 설계된 전이함수에 의해 아래의 식과 같이 계산되어 값을 출력하게 된다.

$$y_j = f(I_j)$$

은닉층에서는 y_j 값을 전달받아 아래와 같이 반응 벡터(L_k)가 구해지고, 전이함수를 거쳐 출력층으로 보내지게 된다.

$$L_k = \sum w_{kj} y_j + B_k$$

여기서 y_j : 은닉층의 입력데이터, w_{kj} : 은닉층의 가중치 벡터, B_k : 은닉층에서의 임계값에 해당된다. 이런 다층신경망에 의해 출력된 값은 목표값과 비교하여 아래와 같은 식에 의해 오차의 값을 계산하게 된다.

$$MSE = \frac{1}{n} \sum (O_d - O_p)^2$$

여기서 O_d : 목표값, O_p : 신경망에 의한 계산값, n : 데이터의 수를 나타낸다. 계산된 MSE(mean square error)를 줄이기 위해 가중치벡터($\Delta w(t)$)를 아래와 같이 조정하여 신경망의 학습을 반복하게 된다.

$$\Delta w(t) = -\eta \frac{\partial MSE}{\partial w} + \mu \Delta w(t-1)$$

여기서 η : 학습율, w : 가중치, μ : 모멘트 항을 나타내며, 가중치 벡터의 전향은 일반적인 경사하강법(gradient decent method)을 나타내며, 후향은 학습속도를 증가시키기 위해 모멘트항을 추가시킨 모멘트법(moment method)을 나타내고 있다.

출력값의 가중치들은 가중치에 관한 오차제곱의 음의 기울기에 비례하여 변화하면서 그 값을 역전파하게 되는 것이다. 따라서 신경망의 입력데이터는 전방향(feedforward)으로 진행하고, 신경망의 출력

값과 목표값의 차이를 줄이기 위해서 Δw 의 값은 역전파하게 되는데 이것이 이른바 다층퍼셉트론에 있어서의 역전파(backpropagation) 알고리즘이다.

위의 식에서 학습율 η 의 값이 작으면 신경망은 매우 안정적인 최속강하를 하지만, 값이 지나치게 적으면 신경망의 학습에 걸리는 시간이 증가하는 단점을 가진다.

이러한 역전파알고리즘의 효율을 배가시키기 위하여 가중치와 임계값을 구하는 여러 가지 방법들이 제안되고 있는데 이 중에서 많이 이용되고 있는 것으로는 Levenberg-Marquart Algorithm, Quasi-Newton Algorithm, Scaled Conjugate Gradient Method 등이 있다.

2.2. 전이함수

신경망에서 사용되는 대표적인 전이함수는 시그모이드(sigmoid)형, 계단함수(hard limiter), 임계논리(threshold logic)함수 등이 있다. 이러한 전이함수를 은닉층(hidden layer)에 설계하여 신경망의 훈련에 이용한다. 특히 아래식과 같은 시그모이드 함수는 최대값과 최소값 부근에서는 응답값의 변화가 적고 평균부분에서는 응답값의 변화가 크며 미분가능한 함수이기 때문에 비선형시스템의 구현에 가장 널리 이용되고 있다. Fig. 3은 전이함수의 형태를 표시한 것이다.

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

한편, 시그모이드함수의 미분함수는 다음과 같이 나타낼 수 있다.

$$f'(y) = f(y)(1 - f(y))$$

따라서 신경망의 입력자료는 각 전이함수의 특징에 맞게 적절히 변환하여 줄 필요가 있다.

2.3. 신경망의 적용

신경망은 훈련자료를 준비하여, 적용할 전이함수에 맞게 자료를 변환한 후 입력자료 셋을 구성한다.




Fig. 3. Transfer function of ANNs.

신경망의 입력노드의 수와 출력노드의 수, 그리고 은닉층의 수를 정한 후, 가중치벡터와 임계치 벡터를 초기화시키고, 입력데이터를 학습시켜 목표데이터에 근사시키도록 훈련시킨다. 마지막으로 훈련된 신경망에 새로운 데이터를 입력하여 예측값을 생성해 낸다. 이러한 신경망 학습에서 입력층에서 은닉층을 거쳐 출력층으로 데이터가 출력되어 목표값과 비교되어 MSE를 산출하는 과정을 1주기(epoch)이라고 한다. 신경망의 주기가 증가되면서 MSE값이 미리 설정해 놓은 수렴한계에 도달했을 때 신경망의 학습은 종료하게 된다.

3. 연구결과

3.1. 연구대상유역

충주호는 유역면적 6,648km²로 남한강에 위치하는 가장 큰 다목적댐으로서 강우시 홍수조절기능과 충청권의 광역상수도도 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.

3.2. 자료수집

본 연구에 사용된 시계열 자료는 1991년부터 2000년까지의 충주댐의 방류수질자료(충북 충주시 종인동 댐앞)를 환경연감⁹⁾과 환경부홈페이지¹⁰⁾로부터 월별 측정데이터를 획득하여 신경망의 학습자료로 이용하였다. 신경망의 학습 및 적용은 MATLAB 5.3의 Neural Network Toolbox를 이용하였다.

3.3. 수질예측을 위한 신경망의 구성

본 연구에서 구성한 신경망은 입력층과 2개의 은닉층 그리고 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 나타내고 있지 않는 것으로 나타나,¹¹⁾ 본연구에서도 은닉층의 갯수는 2개로 하였다. 은닉층에 존재하는 노드수를 결정하는 데는 일반적으로 시행착오법(trial and error method)를 통해 구하게 된다. 본 연구에서는 은닉층의 노드수는 5N(N=1,2,...)으로 증가시키면서 MSE를 관찰하여 뉴런의 수를 결정하였다. 첫 번째 은닉층은 전이함수로 시그모이드(sigmoid) 함수를 사용하였으며, 두 번째 레이어에는 선형

(linear)함수를 사용하였다.

3.4. 자료의 변환

본 연구의 은닉층에 사용된 시그모이드 함수의 경우, 최소값과 최대값이 0.0-1.0의 사이를 변동하는 특성을 가지므로 신경망에 입력되는 데이터를 변환하여 시그모이드함수의 특성에 맞도록 전처리(pre-processing)를 할 필요가 있다. 시그모이드 전이함수의 특성을 고려한 입력데이터의 변환에는 입력데이터의 최대값과 최소값을 이용한 선형변환과 대수변환이 사용될 수 있다¹²⁾.

본 연구에서는 pH, DO 및 BOD값을 대수변환을 이용하여 아래의 식과 같이 입력데이터를 변환하여 사용하였다.

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

여기서 z : 변환된 데이터, a : 임의의 상수, b : 입력데이터가 0인 경우를 고려한 0이 아닌 상수이다. a 값은 0.5를 사용하였으며, b 의 값은 1을 사용하였다.

이렇게 변환되어 출력된 값은 다음과 같이 원래의 값으로 환원하였다.

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

아래의 Table 1은 2000년 BOD측정값의 변환예를 제시하였다.

Table 1. Data transformation for transfer function

Mon -th	pH		DO		BOD	
	Actual	Transformed	Actual	Transformed	Actual	Transformed
1	8.2	0.481893	11.4	0.563552	0.9	0.139377
2	7.9	0.474695	14.2	0.604757	0.8	0.127636
3	7.6	0.467249	13.8	0.599328	0.9	0.139377
4	8.5	0.488861	11.8	0.569939	0.9	0.139377
5	8.7	0.493385	9.8	0.535941	1	0.150515
6	7.9	0.474695	11	0.556971	0.8	0.127636
7	8.4	0.486563	5.4	0.434615	0.7	0.115224
8	8.5	0.488861	5.6	0.440406	1.1	0.161111
9	8.4	0.486563	6.1	0.454242	1	0.150515
10	8.4	0.486563	5.8	0.446047	0.9	0.139377
11	7.8	0.472241	4.9	0.419424	0.8	0.127636
12	8.1	0.479520	6.6	0.467249	0.8	0.127636

3.5. 은닉층의 노드수 결정

Table 2는 은닉층의 노드수를 결정하기 위하여 은닉층의 노드수에 따른 MSE의 변화를 나타내는

것으로 Fig. 4에서 6에 나타난 바와 같이, pH의 경우는 은닉층의 노드수 10개가 타당한 것으로 나타났으며, DO와 BOD는 15개가 타당한 것으로 나타났다. 그 이상의 노드수 증가는 MSE의 변화에 큰 영향을 나타내지 못했다.

Table 2. MSE variation of water quality data by hidden layer's node number

Item	Number of node	Epoch					
		1,000	3,000	5,000	7,000	9,000	10,000
pH	5	5.49E-04	3.39E-04	2.55E-04	2.12E-04	1.85E-04	1.75E-04
	10	8.97E-04	1.71E-04	1.14E-04	9.78E-05	8.71E-05	8.25E-05
	15	2.36E-03	8.77E-04	4.15E-04	2.25E-04	1.35E-04	1.08E-04
DO	5	5.43E-04	4.07E-04	3.89E-04	3.73E-04	3.58E-04	3.51E-04
	10	3.59E-04	1.36E-04	8.47E-05	6.69E-05	6.00E-05	5.81E-05
	15	1.67E-04	2.52E-05	9.85E-06	4.27E-06	1.94E-06	1.34E-06
BOD	5	1.05E-03	7.24E-04	6.58E-04	6.04E-04	5.59E-04	5.39E-04
	10	1.53E-03	9.43E-04	7.50E-04	6.16E-04	5.17E-04	4.77E-04
	15	3.18E-03	4.72E-04	9.42E-05	2.83E-05	1.52E-05	1.30E-05




Fig. 4. MSE variation of pH by hidden layer's node number.

3.5. 신경망의 훈련

충주댐지점의 pH, DO 및 BOD수질값을 입력데이터 매트릭스로 아래의 Fig. 7과 같이 구성하였다. 1991년부터 2000년까지 축적된 데이터를 이등분하여 입력층의 지체시간(lag time)은 1991년부터 1994년까지 4년으로 하여 입력매트릭스를 4×12행렬로 구성하였으며, 목표층에는 1995년의 데이터를 1×12행렬로 구성하여 신경망 훈련에 이용하였다. 또한




Fig. 5. MSE variation of DO by hidden layer's node number.




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

신경망을 훈련시키기 전 가중치 행렬과 임계치 행렬은 랜덤행렬을 이용해 초기화 하였다. 이렇게 구성된 신경망을 훈련시켜 가중치와 임계치벡터의 강도를 조정하였으며, 1996년부터 1999년 데이터를 이용하여 2000년의 수질값을 예측하여 신경망모형을 통한 수질데이터의 예측력을 평가하였다.

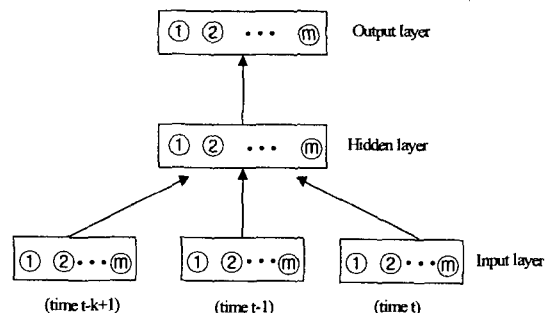


Fig. 7. Data flow of multi-layer perceptron.

인공신경망의 학습에는 역전파알고리즘의 경사하강법(gradient decent method)을 사용하였고, 학습율은 0.05를 적용하고, 오차함의 합이 $1 \times E^{-4}$ 이하가 되면 학습을 종료하도록 하였다.

3.6. 수질예측

훈련된 신경망을 이용하여 위에서 언급한 바와 같이 신경망의 학습시 입력자료 행렬로 사용하지 아니한 1996년부터 1999년의 데이터셋 행렬을 이용하여 2000년의 pH, DO 및 BOD를 예측하여 실측값과의 비교하여 보았다. 한편, 각 수질항목 예측력을 평가하기 위하여 신뢰도계수(Reliability Index)를 이용하였다. 이는 예측된 수질값이 실측된 수질값을 통계적으로 어느 정도 근사시키는지 알아보기 위한 것으로 아래와 같은 식으로 나타내어진다. 실측치와 모의치가 일치하면 1.0이되고 두 값의 차이가 클수록 RI값은 커지게 되는 것이다.¹³⁾

$$RI = \frac{1 + \sqrt{\frac{\frac{1}{N} \sum_{t=1}^T \sum_{n=1}^N \frac{[1 - (Y_{tn}/X_{tn})]^2}{[1 + (Y_{tn}/X_{tn})]^2}}{1 - \sqrt{\frac{1}{N} \sum_{t=1}^T \sum_{n=1}^N \frac{[1 - (Y_{tn}/X_{tn})]^2}{[1 + (Y_{tn}/X_{tn})]^2}}}}}{1 - \sqrt{\frac{1}{N} \sum_{t=1}^T \sum_{n=1}^N \frac{[1 - (Y_{tn}/X_{tn})]^2}{[1 + (Y_{tn}/X_{tn})]^2}}}}$$

여기서 Y는 실측치값, X : 신경망의 계산값, N : 비교된 조의 수, T : 실측횟수를 나타낸다.

Fig. 8부터 10까지는 신경망을 통한 수질예측의 결과를 나타낸 것이다. Fig. 8에 나타난 바와 같이 pH에 대한 신경망데이터와 실측치와의 비교를 보면, 6월부터 10월까지 여름에 해당하는 시기에는 신경망이 예측한 데이터가 실측치 보다는 약간 높게 과대추정(over fitting)하는 경향이 있는 것으로 보이며 신뢰도계수(RI)는 1.1이었다. Fig. 9는 DO를 나타내는 것으로 1월부터 3월까지의 과소추정(under fitting)하는 경향이 있음을 보이고 신뢰도계수(RI)는 2.1로 나타났으며, Fig. 10의 BOD경우는 1월부터 3월의 신경망 예측값이 실측치에 비해서 큰 변동을 보이는 것으로 나타났다. 그 외의 구간은 비교적 신경망의 예측치가 실측치를 잘 반영하고 있는 것으로 나타났으며 신뢰도계수(RI)는 1.97이었다. 한편, 신경망의 예측값과 실측값이 큰 폭으로 차이가 나는 곳은 하천의 수질특성이 과거하고는 다른 특별한 상황이 발생했거나 측정시기상의 편차에 의한 것으로 판단된다.

4. 결론

인공신경망을 다층퍼셉트론으로 구성하고 역전파




Fig. 8. pH comparison of actual and neural network value.




Fig. 9. DO comparison of actual and neural network value.




Fig. 10. BOD comparison of actual and neural network value.

알고리즘을 이용하여 신경망을 학습시켜, 남한강에 위치하는 충주호의 방류수 pH, DO 및 BOD의 수질예측을 수행하여 본 결과 다음과 같은 결론을 얻었다.

- 1) 충주호의 수질예측에 있어서 신경망의 은닉층의 노드수는 pH가 10, DO와 BOD는 15개가 적당한

것으로 나타났으며 더 이상의 노드수 증가는 학습 능력의 향상에 큰 영향을 미치지 못하였다.

2) 학습된 신경망을 이용하여 2000년의 수질값을 예측하여 실측데이터와 비교해 본 결과 pH는 시기적으로 여름에 과대추정하는 결과를 나타냈으며, DO는 1월부터 3월까지의 과소추정하는 경향이 8월부터 10까지는 과대추정하는 경향이 있는 것으로 나타났으며, BOD의 경우는 1월부터 3월 사이의 신경망 예측값이 실측값에 비해서 크게 변동하는 결과를 나타냈다. 그러나 이상점(out lier) 제외하면 신경망의 예측력은 전체적으로 양호한 수준을 나타내었다. 따라서 신경망이론을 이용한 수질현상의 파악은 ARIMA나 Kalman Filtering 등의 비선형 통계모형과 더불어 수질현상의 해석에 양호한 도구가 될 것으로 사료된다.

한편, 인공신경망이론을 통한 수질예측에 있어서 본 연구에서는 과거 수질 결과만을 이용한 수질예측을 실시하였으나, 유역의 특성자료인 오염원자료의 변동사항, 기상자료 등의 연계를 통한 효율적인 신경망 학습에 대한 연구가 추가되어야 할 것으로 보인다.

참 고 문 헌

- 1) Law, R., 2000, Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting, *Tourism Management* 21, 331-340.
- 2) Kolehmainen, M., H. Martikainen and J. Ruuskanen, 2001, Neural networks and periodic components used in air quality forecasting, *Atmospheric Environment*, 35, 815-825.
- 3) Maier, H. R., G. C. Dandy, and M. D. Burch, 1998, Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia, *Ecological Modelling*, 105, 257-272.
- 4) Luk, K. C., J. E. Ball, and A. Sharma, 2000, A study of optimal model lag and spatial input to artificial neural network for rainfall forecasting, *Journal of Hydrology*, 227, 56-65.
- 5) See, L. and R. J. Abrahart, 2001, Multi-model data fusion for hydrological forecasting, *Computer & Geosciences*, 27, 987-994.
- 6) Hwang, H. B. and H. T. Ang, 2001, A simple neural network for ARMA(p, q) time series, *The International Journal of Management Science*, 29, 319-333.
- 7) Skapura, D. M., 1996, *Building Neural Networks*, Addison Wesley, 1-5.
- 8) 김대수, 1999, 신경망이론과 응용(I), 하이테크정보, 92pp.
- 9) 환경부, 1991-2000, 환경연감.
- 10) <http://www.me.go.kr/www/index.html>.
- 11) Kung, 1993, *Digital Neural Networks*, Prentice Hall International Inc, 30-33 pp.
- 12) Balkin, S. D. and J. K. Ord, 2000, Automatic neural network modelling for univariate time series, *International Journal of Forecasting*, 16, 509-515.
- 13) 환경부, 1995, 수역 수질관리를 위한 수질예측 모형과 의사결정 지원시스템 개발에 관한 연구, 84pp.