

## 유량과 수질을 연계한 실시간 인공지능 경보시스템 개발

### (I) 유량 - 수질 예측모형의 적용

#### A Development of Real Time Artificial Intelligence Warning System Linked Discharge and Water Quality

#### (I) Application of Discharge - Water Quality Forecasting Model

연 인 성\* / 안 상 진\*\*

Yeon, In Sung / Ahn, Sang Jin

---

#### Abstract

It is used water quality data that was measured at Pyeongchanggang real time monitoring stations in Namhan river. These characteristics were analyzed with the water quality of rainy and nonrainy periods. TOC (Total Organic Carbon) data of rainy periods has correlation with discharge and shows high values of mean, maximum, and standard deviation. DO (Dissolved Oxygen) value of rainy periods is lower than those of nonrainy periods. Input data of the water quality forecasting models that they were constructed by neural network and neuro-fuzzy was chosen as the reasonable data, and water quality forecasting models were applied. LMNN, MDNN, and ANFIS models have achieved the highest overall accuracy of TOC data. LMNN (Levenberg-Marquardt Neural Network) and MDNN (MoDular Neural Network) model which are applied for DO forecasting shows better results than ANFIS (Adaptive Neuro-Fuzzy Inference System). MDNN model shows the lowest estimation error when using daily time, which is qualitative data trained with quantitative data. The observation of discharge and water quality are effective at same point as well as same time for real time management. But there are some of real time water quality monitoring stations far from the T/M water stage. Pyeongchanggang station is one of them. So discharge on Pyeongchanggang station was calculated by developed runoff neural network model, and the water quality forecasting model is linked to the runoff forecasting model. That linked model shows the improvement of waterquality forecasting.

**keywords** : neural network, neuro-fuzzy, discharge, water quality, forecasting

---

#### 요 지

평창강 수질자동측정망 실시간 자료를 이용하여 강우시와 무강우시로 구분하여 분석하였다. 강우시에 측정된 TOC 자료는 무강우시 측정된 자료에 비해 평균값, 최대값, 표준편차가 크게 나타났으며, 강우시의 DO 자료는 무강우시에 측정된 자료보다 낮아 유량이 수질변화에 영향을 미치는 것으로 분석되었다. 신경망 모형과 뉴로-퍼지 모형으로 수질예측 모형을 구성하고, 적용하였다. LMNN, MDNN, ANFIS 모형은 TOC 모의에서 DO 예측에서는

---

\* 정희원 · 충북대학교 토목공학과 강사, 공학박사  
Part-time Lecturer, Dept. of Civil Eng., Chungbuk National Univ., Cheongju, Chungbuk 361-763, Korea  
(e-mail: isyeon@chungbuk.ac.kr)

\*\* 정희원 · 충북대학교 토목공학과 교수, 공학박사  
Professor, Dept. of Civil Eng., Chungbuk National Univ., Cheongju, Chungbuk 361-763, Korea

LMNN, MDNN 모형이 ANFIS 모형보다 좋은 결과를 보였으며, 정량적 자료에 정성적 자료인 시간을 학습한 MDNN 모형이 가장 작은 오차를 보였다. 하천의 실시간적 관리를 위해서는 유량과 수질의 측정이 동일한 지점에서 동시적으로 이루어져야 보다 효과적이다. 그러나 수질자동측정망 지점과 T/M 수위관측소가 원거리에 위치한 경우들이 있으며, 평창강 수질자동측정망 지점이 그 중 하나이다. 연구에서는 평창강 수질자동측정망 지점의 유출예측을 위한 신경망 모형을 구성하여 수질예측 모형과 연계하였으며, 연계된 모형은 수질예측에 개선된 결과를 보였다.

**핵심용어** : 신경망, 뉴로-퍼지, 유량, 수질, 예측

## 1. 서론

하천의 수질은 시·공간적으로 지속적인 변화를 보이기 때문에 효과적인 수질관리를 위해서는 연속적인 하천수질 측정과 분석이 요구된다. 또한 오염원의 이송량은 유량에 의해 영향을 받으므로 유량과 수질 관계를 고려해야 한다. 그러나 일별, 월별 대표값으로 산출되는 수질자료 들은 유량의 측정 시각 및 기간이 다르거나 동일 지점에서 측정된 양질의 자료가 부족하여 유량과의 관계성이 모호한 실정이다. 뿐만 아니라 유량과 수질관리에 대한 주체의 이원화로 인해 연속측정시설인 수질자동측정망과 T/M 수위관측소의 측정지점 또한 일치하지 않아 정확한 실시간 유량, 수질자료를 획득하기에 어려운 지점이 많다. 유량과 수질측정이 동일지점에서 동일시각에 이루어져야 수질과 유량을 연계하는 보다 정확하고 유익한 자료를 공유할 수 있다.

유량과 수질 인자들간의 상호관계 분석(McMichael과 Hunter, 1972; 정상만 등, 2000)으로부터 수질변화를 예측하고 관리하기 위해 많은 모형들과 새로운 방법론이 제시되어 왔다. 수질변동 해석 및 예측을 위한 모형은 크게 개념적인 확정론적 모형과 통계 및 추계학적 기법을 이용한 모형으로 분류할 수 있다. 확정론적 수치모형은 다양한 입력 자료가 요구되어 많은 노력이 수반되며, 최적의 매개변수들을 추정하기 어렵고, 추정과정에서 사용자의 주관이 많이 개입된다. 추계학적 기법들은 수질자료의 시계열적 특성을 이용(Hahn, 1972; Thomann, 1976; 류병로와 한양수, 1998)하여 수체의 물리적, 화학적, 생물학적 특성을 구체화하지 않고도 최적 매개변수를 추정할 수 있으며, 비교적 자유로운 입·출력의 구성으로 장기 및 단기간의 예측에 적용할 수 있는 장점이 있다. 최근에는 비선형적 예측에 적합한 인공지능 알고리즘을 수질예측에 적용하여 매개변수 산정시에 개입되는 사용자의 주관을 배제하기 위한 시도(Maier와 Dandy, 1996; Noh, 1996; Ken-ichi, 1997; Tay와 Zhang, 2000; 신현석 등, 1998; 김만식 등, 2001)가 국내외에서 진행되어 왔다. 또한 인공지능 모형들은 유출예측에 관한 연구(Karunanithi, 1994;

Zhang과 Govindaraju, 1998; 강관원 등, 1992)에도 많이 적용되고 있는 추세이다. 실시간으로 측정할 수 있는 자동측정 항목에는 한계가 있으며, 필요한 여러 가지 입력변수들을 모두 취득하는 것은 어렵다. 따라서 연속적인 측정 및 실시간적 관리가 요구되는 수질자동측정망이나 취수장, 그리고 상습 침수구역에서 수질과 유량의 변화를 분석하고 예측하는 데 있어 추계학적 모형은 유효 적절한 방법이라 할 수 있다.

남한강 유역내 평창강 자동측정망 지점은 유량측정 지점이 원거리에 위치하여 수질예측을 위해서는 보다 정확한 실시간적 유량산정이 요구되는 지점이다. 또한 하류에 급수인구 10만명 이상의 취수장이 위치하고 있어 상수원수의 수질감시 및 조기경보체계 구축이 필요한 지점이며, 주요 모니터링 항목은 DO (Dissolved Oxygen)와 TOC (Total Organic Carbon) 이다.

연구에서는 남한강 유역의 평창강 수질자동측정망 지점에서 5분단위로 측정되고 있는 DO, TOC의 원시 수질자료를 수집하여 시간 대표값을 산출하고 강우시와 무강우시로 구분하여 특성을 분석하였다. 분석결과에 따라 입력자료를 선정하여 수질예측을 위한 신경망 모형과 뉴로-퍼지 모형을 구성하였으며, 실시간으로 측정된 수질 자료를 바탕으로 수질예측에 대한 적용성을 검토하였다. 수질변화에 있어 유량이 매우 큰 영향을 미치는 인자임에도 불구하고 국내 여건상 수질과 유량의 연속측정지점이 대부분 동일한 지점에서 운영되지 않고 있다. 이를 감안하여 T/M 수위관측소와 수질자동측정망 지점이 원거리에 위치한 평창강 수질자동측정망 지점을 대상으로 미세측 지점에서 유출산정이 가능하도록 신경망 모형을 구성하였으며, 이를 수질예측 모형과 연계하여 보다 정확한 예측시스템을 구축하고 효율성을 검토하였다.

## 2. 기본이론

### 2.1 신경망 모형

신경망은 은닉층의 수에 따라 단층신경망과 다층신경망으로 구분된다. 입력으로부터 은닉층 없이 출력층

만을 갖는 형태의 신경망을 단층신경망이라고 하고 출력층외에 은닉층들이 존재하여 다수 개의 층으로 이루어진 신경망을 다층신경망이라고 한다. 입력층과 출력층만을 갖는 단층 신경망은 출력값을 생성하는 활성화 함수( $\varphi$ )로 계단함수를 사용하여 복잡한 과정을 생략하고 빠르게 계산할 수 있다. 입력층, 은닉층, 출력층을 갖는 다층신경망은 활성화 함수( $\varphi$ )로 시그모이드(sigmoid) 함수와 이로부터 변형된 로그-시그모이드(log-sigmoid) 함수 등을 사용한다.

신경망 모형에서 가장 많이 이용되는 다층신경망 모형은 주로 BP (Back Propagation, 오차 역전파) 알고리즘을 이용하여 학습을 수행하는데 입력패턴을 이용해 신경망 네트워크가 계산한 출력값과 목표값과의 오차를 최소화시키는 방향으로 연결강도를 조절하는 방법이다. BP 알고리즘에서는 미분값을 사용하며, 학습하는 동안 목표값과 실제 출력값 사이의 계산된 오차 정보는 네트워크를 통하여 역방향으로 전달되고, 연결 가중치에 영향을 준다.

경사도  $\lambda=1$ 인 단극성 시그모이드 함수를 전달함수로 사용하는 경우, 출력층의 가중합  $u_y$ 로부터 출력층에서의 출력  $Y$ 는 식 (1)과 같이 계산된다. 식 (2)에 나타난 출력층의 오차신호  $\delta_y$ 는 식 (3)의 미분결과로부터 식 (4)와 같이 목표값  $T$ 와 출력값  $Y$ 로 표현되며, 식 (5)와 같이 은닉층 출력  $H$ 와 연산되어 연결강도 조절에 영향을 미친다.

$$Y = \varphi(u_y) = \frac{1}{1 + \exp(-u_y)} \quad (1)$$

$$\delta_y = (T - Y) \varphi'(u_y) \quad (2)$$

$$\varphi'(u_y) = \frac{\exp(-u_y)}{[1 + \exp(-u_y)]^2} \quad (3)$$

$$\begin{aligned} &= \frac{1}{1 + \exp(-u_y)} \times \frac{1 + \exp(-u_y) - 1}{1 + \exp(-u_y)} \\ &= \varphi(u_y) [1 - \varphi(u_y)] \\ &= Y(1 - Y) \end{aligned}$$

$$\delta_y = (T - Y) Y(1 - Y) \quad (4)$$

$$\Delta W = \delta_y H \quad (5)$$

여기서  $\Delta W$ 는 은닉층과 출력층간의 연결강도 변화량

이다. 출력층과 은닉층에서 지속적인 연결강도의 갱신을 통해 모형을 최적화하며, 오차가 지정한 범위내로 만족하거나 학습회수에 도달하면 학습을 종료하고, 학습을 마친 연결강도를 사용하여 예측을 수행하게 된다.

일반적인 BP 알고리즘에 비해 우수성이 여러 연구를 통해 입증된 Levenberg-Marquardt 방법은 연결강도를 조절할 때 식 (6)과 같은 Levenberg-Marquardt update rule을 사용하여 반복 계산되는  $\eta$ 의 크기를 효율적으로 제어하는 방법이다.

$$\Delta W = (J^T J + \eta I)^{-1} J^T e \quad (6)$$

여기서  $J$ 는 각 연결강도에 대한 오차 미분의 Jacobian matrix,  $\eta$ 는 적응학습율,  $e$ 는 오차벡터이다.

일반적인 신경망 모형의 연결강도는 보통 모든 뉴런에 연결되어져 연산되나 Modular 방법은 전체 네트워크를 부분적인 네트워크(sub-network)로 분류할 수 있다. 성질이 다른 입력변수를 구분하고 해당 은닉층에만 영향을 미치도록 구성되어 있어 입력 자료별로 나누어서 학습을 진행시키므로 학습 시간을 단축시킬 수 있을 뿐만 아니라 정량적인 자료와 정성적인 자료의 특성을 살려 동시에 학습시킬 수 있다. 시간 변화에 많은 영향을 받는 수질 자료의 특성을 고려하여 정성적 자료인 시간항목을 독립적으로 연산하고 최종 출력값에만 영향을 미치도록 할 수 있다.

유량예측 및 수질예측, 수질오염 경보를 위해 사용된 신경망 모형은 단층신경망인 다중퍼셉트론, 다층신경망 모형 중 은닉층을 분리하지 않은 LMNN (Levenberg-Marquardt Neural Network) 모형, 은닉층을 분리한 MDNN (MoDular Neural Network) 모형이며, 구조를 그림 1에 나타내었다.

## 2.2 ANFIS 모형

ANFIS (Adaptive Neuro-Fuzzy Inference Systems)는 신경회로망과 퍼지이론이 결합된 형태로서 신경회로망의 구조와 학습능력을 이용하여 제어환경으로부터 얻은 입출력 정보로부터 소속함수와 제어규칙을 제어 대상에 맞게 자동 조절하는 방식의 모형이다(Jang, 1993). ANFIS의 기본적인 학습방법은 각 노드의 출력에 대한 제공된 오차의 미분 즉, 오차 신호를 계산하는 역전파 알고리즘에 의해 후방향 경로에서 전제부 매개변수를 조정한다. 소속함수의 모양이 전제부 매개변수에 의해 정의되어지기 때문에 제공오차  $E$ 는 결론부 매개변수가 고정된다면 소속함수의 폭과 중심을 계산하는  $\{a_i,$

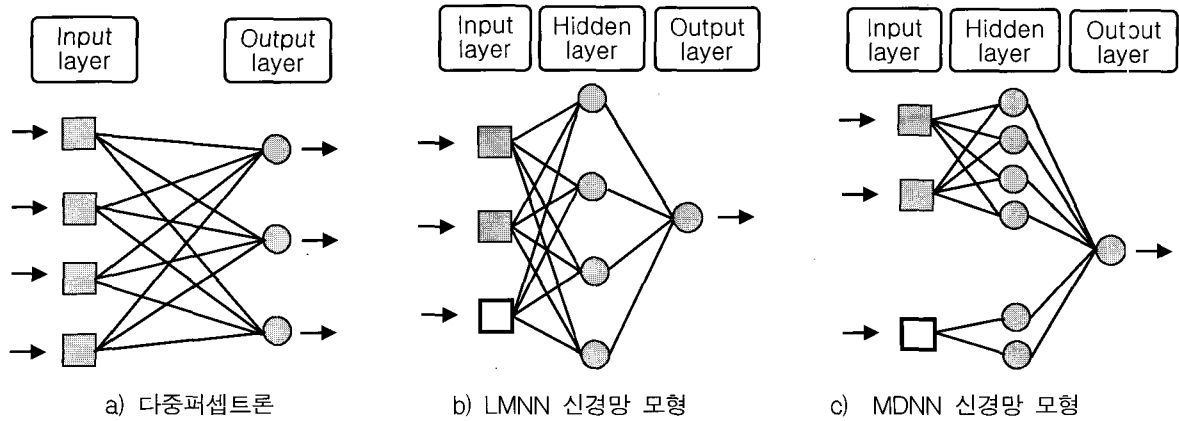


그림 1. 신경망의 모형의 구조

$c_i$ )의 매개변수로 결정되어진다.  $E$ 의 값을 감소시키기 위해서는 전체부 매개변수에 대해서 다음과 같이 최대경사법(steepest descent method)에 의해 반복적으로 이루어진다.

$$a_i(t+1) = a_i(t) - \eta \frac{\partial E}{\partial a_i} \quad (7)$$

$$c_i(t+1) = c_i(t) - \eta \frac{\partial E}{\partial c_i} \quad (8)$$

$$\eta = \frac{k}{\sqrt{\sum_a \left(\frac{\partial E}{\partial a}\right)^2}} \quad (9)$$

여기서  $a$ 는 전체부 매개변수이고,  $k$ 는 매개변수 공간에서 경사벡터의 이동한 거리로 수렴 속도 변화에 영향을 미친다. 전체부 매개변수가 주어질 때 전체적인 출력  $f$ 는 결론부 매개변수인  $\{p_i, q_i, r_i\}$ 의 선형적인 조합에 의해 식 (10)과 같이 표현되어질 수 있다.

$$\begin{aligned} f &= \overline{w_1} f_1 + \overline{w_2} f_2 \\ &= (\overline{w_1} x) p_1 + (\overline{w_1} y) q_1 + (\overline{w_1} r_1) \\ &\quad + (\overline{w_2} x) p_2 + (\overline{w_2} y) q_2 + (\overline{w_2} r_2) \end{aligned} \quad (10)$$

### 3. 대상유역 및 자료

대상유역은 평창강 유역으로 14개의 T/M 강우관측소가 운영중에 있으며, 판운과 영월1 T/M 수위관측소가 운영중에 있다. 유량 미계측 지점인 평창강 수질자동측정망 지점은 주천강과 평창강의 합류부로부터 하류에 위치한 충북 제천시 송학면 장곡리에 있다. 이 곳에

는 취수장이 위치하고 있으며, TOC와 DO가 수질감시를 위한 주요 항목으로 모니터링되고 있다. 평창강 수질자동측정망 지점으로부터 약 11km 하류에 영월1 T/M 수위관측소가 위치하고 있어 유량측정 지점과 수질 자동측정 지점 사이로 지천들이 유입하고 있다. 그림 2에 평창강 유역도를 나타내었다.




그림 2. 평창강 유역도

수질예측을 위해 사용한 자료는 2003년 1월, 4월, 7월의 자료이며, 강우 유무에 따른 항목별 자료 특성을 표 1에 나타내었다. 강우시에 측정된 DO 농도는 무강우시에 측정된 자료보다 최소값, 평균값, 최대값이 모두 낮았으며, 강우시에 측정된 TOC 자료는 무강우시 측정된 자료에 비해 최소값, 평균값, 최대값, 표준편차가 크게 나타났다. 하천수질은 강우에 따른 유량의 변동으로 많은 변화가 나타나므로 취득된 자료를 강우시와 무강우시로 구분하여 적용하였다. 강우의 발생에 의해 기저 유출로부터 하천 유량이 변화한 기간을 강우시로, 강우

표 1. 자료 특성

통계	항목	수온(°C)		DO(mg/L)		TOC(mg/L)		유량(cms)	
		강우시	무강우시	강우시	무강우시	강우시	무강우시	강우시	무강우시
Min.		10.20	0.40	4.20	7.00	0.60	0.20	22.72	3.73
Mean		17.50	6.82	9.60	11.62	1.30	0.60	304.29	16.29
Max.		23.40	24.10	10.80	14.50	2.24	0.90	1308.94	55.35
Std-Dev.		3.16	8.34	1.19	1.76	0.41	0.11	261.39	13.97

에 의한 영향이 없는 기간을 무강우시로 구분하였다. 수온, DO, TOC 자료는 평창강 수질자동측정망 지점에서 5분단위로 수집되었으며, 유량 자료는 영월1 수위관측 지점에서 산정된 자료이다. 유출예측 신경망 모형의 학습시에는 1995년 7월 ~ 2001년 7월 중 선정된 5개의 홍수유출 사상을 사용하였다.

#### 4. 적용 및 결과

##### 4.1 적용 절차

인공지능 모형의 구성을 위해서는 학습절차를 거쳐야 하며, 적절한 은닉층의 노드수와 학습회수 등을 조정해야 하는 반복적인 과정이 요구된다. 자료의 형태와 특성에 따라 적정 노드수는 달라질 수 있으며, 선형 관계와 달리 비선형적인 관계를 갖는 자연현상 및 수문현상을 모의할 때에 과도한 학습은 학습하지 않은 사상에 대한 모형의 검증시에 큰 오차를 유발한다. 그러나 지금까지 노드수와 학습회수에 대해 연구된 바는 있으나 확정된 결론을 얻지는 못하였다. 따라서 학습되지 않은 사상을 통하여 그 유역에 적합한 모형의 구조를 결정하는 것이 타당하다고 판단된다(연인성, 2005).

연구에서는 은닉층의 노드수와 학습회수를 변화해가며 학습하지 않은 검증사상에 적용하여 최소의 오차를 갖는 구조를 찾도록 하였고, 수동적인 반복과정을 피하기 위해 검증절차를 자동화하였다. 인공지능 모형의 자동화된 매개변수 산정과정을 그림 3에 나타내었다.

##### 4.2 수질자료의 전처리

연구를 위해 사용된 평창강 지점의 수온, DO, TOC 자료는 5분단위로 수집된다. 취득 가능한 유량 자료와 연계하여 모의 및 예측을 수행하기 위해서는 자료들간의 시간간격을 일치시켜야 한다. 수위관측소로부터 산정된 유량 자료는 시단위 자료이므로 수질자동측정망에서 매 5분마다 취득된 자료들을 시단위 대표값으로 산출하는 과정을 거쳤다. 안정화된 대표값을 산출하기 위해서 중앙(median)값을 추출한 후 이동평균(moving

average)법을 이용하여 평활화 과정을 수행되었다. 시단위 대표값은 평균값으로 산출될 경우 순간적인 기기의 오작동에 의한 부정확한 자료를 포함할 수 있으며, 중앙값은 이를 배제하기 위한 적절한 방법이 될 수 있다. 그림 4에 중앙값 추출결과를 나타내었다.

중앙값 추출을 통해 전반적으로 양질의 시단위 자료를 취득하였으나, 부분적으로 불안정한 구간이 존재하여 2차적인 안정화 과정이 요구되었다. 5분단위 원시자료가 1시간 동안 모두 소멸된 구간에서는 전후 자료를 통해 보간되었으며, 취득된 시단위 대표값이 진동하는 구간에서는 자기중심 이동평균법을 통해 평활화 과정이 수행되었다. 그림 5에 DO와 TOC의 평활화 결과를 나타내었다.

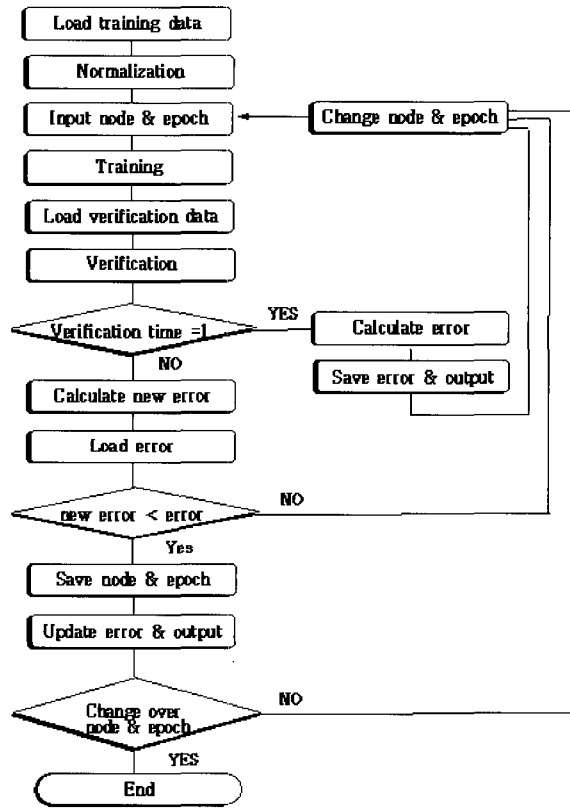
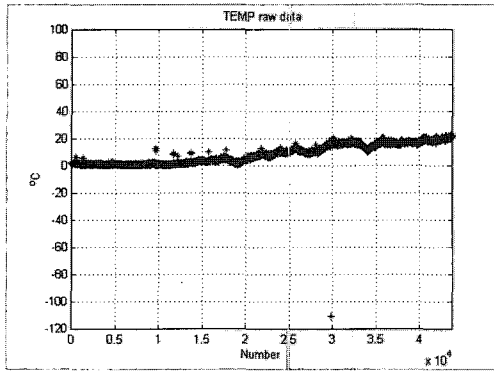
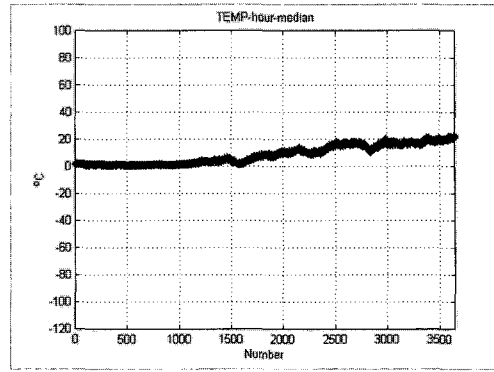



그림 3. 인공지능 모형의 자동화된 매개변수 산정 과정




a) 5분단위 수온 원시데이터




b) 시간위 수온 대표값



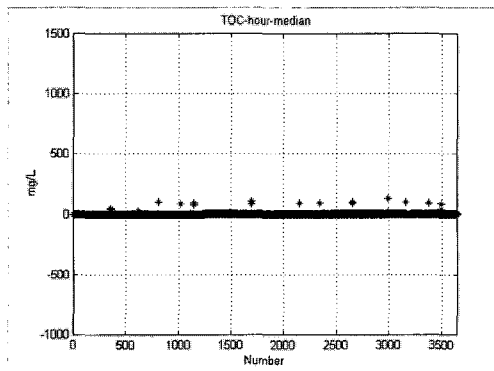
c) 5분단위 DO 원시데이터



d) 시간위 DO 대표값



e) 5분단위 TOC 원시데이터



f) 시간위 TOC 대표값

그림 4. 수온, DO, TOC의 중앙값 추출 결과





그림 5. 평활화 결과(---○--- : 중앙값, —\*— : 평활화)

### 4.3 수질예측 모형의 적용

평창강 수질자동측정망 지점의 DO와 TOC는 교차상관 분석을 통해 강우시에는 유량변화의 영향이 크고, 무강우시에 수온의 영향이 큰 것으로 나타났다. 따라서 수질의 변화양상과 인자들간의 영향, 실시간적인 실제 예측 상황을 고려하여 수질예측 모형의 입력자료를 구성하였다. 실시간 모형의 운영을 위해서는 상관성이 높은 소수의 입력 자료가 보다 효과적이거나, 1개 항목만을 입력자료로 사용할 경우에는 자료의 비선형성 때문에 수렴과 예측에 큰 오차를 발생할 우려가 있다. 또한 실시간으로 측정된 무강우시 수질자료는 1일을 주기로 일정한 주기성을 갖는 것으로 분석되었으며 시간을 이용한 정성적 자료를 활용하여 개선된 결과를 얻을 수 있을 것으로 판단된다(연인성, 2005). 따라서 모형의 구성은 수질항목에 대한 상관분석과 모형의 구동시간을 고려하여 표 2와 같이 결정하였다.

LMNN 모형과 ANFIS 모형은 2개의 입력값을 사용하였으며  $t$ 시간의 수질자료와 함께  $t$ 시간의 유량 혹은 수온 자료를 입력값으로 사용하여  $t+1$ 시간에서의 수질을 출력하도록 하였다. 은닉층을 분리한 MDNN 모형은 정성적 자료인 시간개념을 추가하여  $t+1$ 시간에서의 수

질을 출력하도록 하였다. 정성적 자료로서 강우시에는 강우발생후 경과시간을 이용하였으며, 무강우시에는 일조 및 일몰의 영향을 고려하여 수질 및 유량이 측정된 시간을 이용하였다.

구성된 모형들은 학습회수와 은닉층의 노드수를 변화해가며, 스스로 적절한 구조를 찾도록 학습되었다. 그림 6에 적용한 모형 중 MDNN 모형의 학습 결과를 나타내었다. 강우시와 무강우시의 DO, TOC의 시간위 자료의 변화양상을 학습하였으며, 수질변화에 대한 충분한 학습이 이루어졌음을 알 수 있다.

학습된 LMNN, MDNN, ANFIS 모형을 적용하여 학습되지 않은 사상의 수질변화를 예측하였으며, 강우시와 무강우시의 DO, TOC에 대한 예측결과를 분석하여 표 3, 그리고 그림 7과 8에 나타내었다.

평창강 지점에서 TOC 예측을 위해 적용된 두 신경망 모형과 뉴로-퍼지 모형의 예측값은 모두 실측값에 근사하였고, 상관관계가 매우 큰 것으로 나타났다. 평균 제곱근 오차인 RMSE는 LMNN 모형이 0.100 mg/L, MDNN 모형이 0.090 mg/L, ANFIS 모형이 0.090 mg/L로 산정되어 좋은 결과를 보였다. 적용된 모형들은 무강우시 TOC 예측에서도 실측값에 근사하였다. 오차는 강우시 TOC의 예측결과에 비해 작았으나, 상관계수

표 2. 수질예측 모형의 입출력 구성

구분	항목	모형	입력	출력
강우시	DO	LMNN	DO( $t$ ), 유량( $t$ )	DO( $t+1$ )
		ANFIS	DO( $t$ ), 유량( $t$ )	
		MDNN	DO( $t$ ), 유량( $t$ ), 강우발생후 경과시간	
	TOC	LMNN	TOC( $t$ ), 유량( $t$ )	TOC( $t+1$ )
		ANFIS	TOC( $t$ ), 유량( $t$ )	
		MDNN	TOC( $t$ ), 유량( $t$ ), 강우발생후 경과시간	
무강우시	DO	LMNN	DO( $t$ ), 수온( $t$ )	DO( $t+1$ )
		ANFIS	DO( $t$ ), 수온( $t$ )	
		MDNN	DO( $t$ ), 수온( $t$ ), 1일 진행시간(측정시간)	
	TOC	LMNN	TOC( $t$ ), 수온( $t$ )	TOC( $t+1$ )
		ANFIS	TOC( $t$ ), 수온( $t$ )	
		MDNN	TOC( $t$ ), 수온( $t$ ), 1일 진행시간(측정시간)	

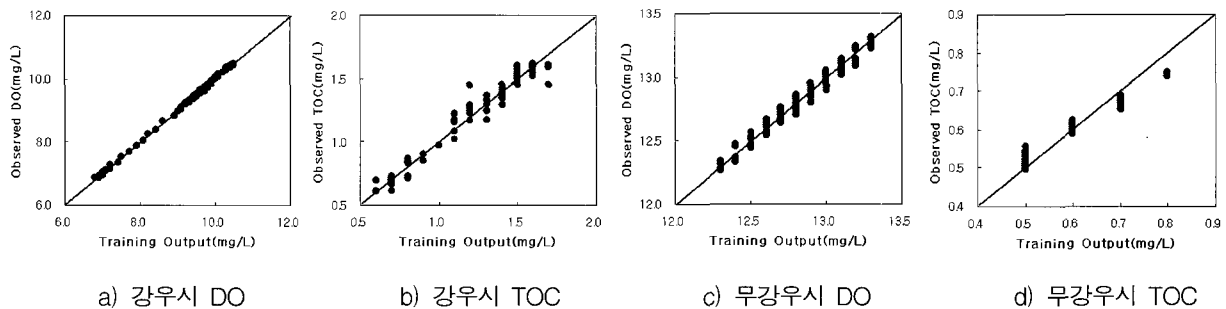


그림 6. 학습 결과

표 3. 각 모형별 수질예측 결과

모형	강우시				무강우시			
	DO		TOC		DO		TOC	
	RMSE (mg/L)	CC	RMSE (mg/L)	CC	RMSE (mg/L)	CC	RMSE (mg/L)	CC
LMNN	0.124	0.986	0.100	0.990	0.418	0.929	0.035	0.709
MDNN	0.120	0.977	0.090	0.990	0.388	0.944	0.035	0.743
ANFIS	0.372	0.901	0.090	0.990	0.499	0.818	0.036	0.723





그림 7. 강우시 DO와 TOC의 예측결과(2003. 07. 22 사상)





그림 8. 무강우시 DO(2003. 07. 05 사상)와 TOC(2003. 07. 05, 2003. 07. 14 사상)의 예측결과

(CC)는 낮은 것으로 나타났다. 강우의 영향이 없었던 무강우시에는 TOC의 변동이 매우 작았으므로 상대적으로 상관관계수가 낮아졌을 것으로 판단된다. MDNN 모형이 RMSE 0.035 mg/L, 상관관계수 0.743으로 타 모형에 비해 좋은 결과를 보였다.

LMNN, MDNN 모형을 이용한 강우시 DO 예측은 실측값에 근사하고, 상관관계수가 0.977~0.986로 높은 상관성을 보였다. LMNN 모형과 MDNN 모형의 RMSE는 각각 0.124 mg/L, 0.120 mg/L로 나타났으며, ANFIS 모형은 상관관계수가 0.901, RMSE는 0.372 mg/L로 신경망 모형에 비해 오차가 크게 나타났다. 무강우시에도 두 신경망 모형에 비해 ANFIS 모형이 큰 오차와 낮은 상관성을 보였으며, LMNN 모형의 RMSE는 0.418 mg/L, MDNN 모형은 0.388 mg/L로 나타나 두 신경망

모형 중 MDNN 모형이 보다 좋은 결과를 보였다. 주기가 일정한 항목의 예측에서는 정성적 자료의 활용이 보다 효과적인 것으로 판단된다.

#### 4.4 유출예측 모형의 적용

수질예측에서 안정적인 적용성을 보인 MDNN 신경망 모형을 이용하여 유출예측을 수행하였다. 실시간 수위기록이 이루어지지 않는 수질자동측정망 지점에서의 유출량을 계산하기 위하여 상하류의 유출특성과 미계측 유역의 시간당 총강우량의 크기를 고려하였다. 시간당 총강우량은 시우량 자료로부터 산정된 면적평균강우량에 유역면적을 곱하여 계산하였으며, 임의유역에서 1시간동안 강하한 강우의 체적으로 유역면적의 크기와 유출량의 관계를 학습하고자 하였다.



표 4. 신경망 모형의 입출력 구성

입력 1	입력 2	입력 3	출력
관운지점 유량(t)	영월1 지점 유량(t)	미계측 지점의 총강우량(t)	미계측 지점의 유량(t+1)




그림 9. 유출예측 모형의 학습 결과

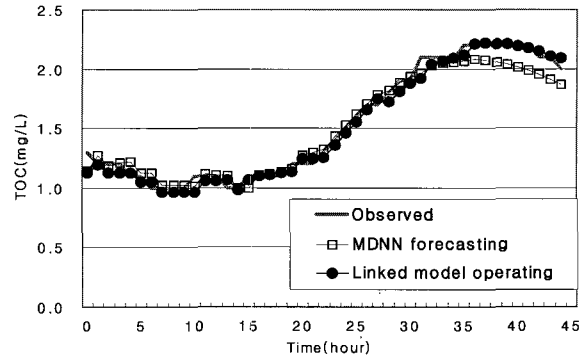


그림 10. 연계모형의 개선 효과

평창강 수질자동측정망 지점은 영월1 T/M 수위관측소와 원거리에 있으므로 정확한 유량 산정이 실시간적으로 이루어질수 없다. 미계측지점인 수질자동측정망 지점에서 취득할 수 있는 것은 T/M 강우관측소의 강우기록이므로 강우량의 크기에 따른 유출예측이 이루어져야 한다. 따라서 수질자동측정망 지점으로부터 상류에 위치한 관운 지점에서의 유량(t), 하류에 위치한 영월1 지점에서의 유량(t), 수질자동측정망 지점의 총강우량(t)을 입력 자료로 하였으며 수질자동측정망 지점에서의 유량(t+1)을 출력하도록 구성하였다. 유출예측 신경망 모형의 입출력 구성을 표 4에 나타내었으며, 학습오차 0.01을 기준으로 학습된 결과를 그림 9에 나타내었다.

미계측지점인 수질자동측정망 지점은 유출량 자료가 없으므로 원하는 목표값인 유출량에 대한 학습을 할 수 없다. 따라서 표 4의 입력 3과 목표값인 출력을 대신하여 유출량 자료가 존재하는 관운 지점의 총강우량을 입력으로 유출량을 학습하고, 또한 영월1 지점에서의 총강우량을 입력으로 유출량을 학습하도록 하였다. 또한 유출량의 시간적 변화량을 학습하기위해 예측시점(t+1)에서 한단계 이전(t)인 관운과 영월1 지점의 유량자료를 입력항에 추가하여 학습하였다(안상진 등, 2005).

#### 4.5 유출예측 모형과 수질예측 모형의 연계

실시간적인 수질예측 및 관리를 위해서는 수질자료

뿐만아니라 유량자료도 연속적인 취득이 이루어져야 한다. 그러나 국내 여건상 수질자동측정망과 T/M 수위관측소의 측정지점 또한 일치하지 않아 정확한 실시간 유량, 수질자료를 획득하기에 어려운 지점이 많다. 평창강 수질자동측정망 지점에서도 감시 및 관리시스템을 위해서 보다 정확한 실시간적 유량산정이 선행되어야 한다. 따라서 이를위한 방편으로 수질예측 모형과 연계가 원활한 유출예측 모형을 구성하여 유량의 미계측 지점인 평창강 수질자동측정망 지점에 적용하였다.

강우량의 총량과 유출량과의 관계를 해석하도록 학습된 유출예측 모형으로 유량을 예측하고, 예측된 유량은 수질예측 모형의 입력자료로 사용되었다. 평창강 수질자동측정망에서 산정된 유량을 사용하여 학습된 연계 모형의 TOC 예측값과 하류의 영월1 지점에서의 유량을 사용하여 학습된 MDNN 모형의 TOC 예측값을 비교하여 그림 10에 나타내었으며, 예측값에 대한 분석 결과를 표 5에 나타내었다.

평창강 자동측정망 지점에서의 TOC 예측 결과, 보다 정확한 유출량을 산정한 연계모형이 작은 오차를 보였으며, 실측값에 근사하는 것으로 나타났다. RMSE는 MDNN 모형이 0.093 mg/L, 연계모형이 0.068 mg/L로 분석되어 개선된 결과를 보였다.

표 5. 연계모형의 강우시 TOC 예측값에 대한 분석 결과

모형	평균수질 (mg/L)	RMSE (mg/L)	CC
실측값	1.54	-	-
MDNN	1.53	0.093	0.990
연계모형	1.53	0.068	0.992

## 5. 결 론

평창강 수질자동측정망에서 측정된 실시간 수질 자료를 이용하여 인공지능 모형들을 학습하고, 수질예측에 대한 적용성을 검토하였다. 유량의 미계측지점인 평창강 수질자동측정망 지점을 대상으로 신경망 모형에 의한 유출예측을 수행하고, 수질예측 모형과 연계하여 개선효과를 검토하였으며, 다음과 같은 결론을 얻었다.

- (1) 수질자료를 강우의 유무에 따라 분석한 결과, 강우시에 측정된 DO 농도는 무강우시에 측정된 자료보다 최소값, 평균값 등이 낮았으며, 강우시에 측정된 TOC 자료는 무강우시 측정된 자료에 비해 평균값, 최대값, 표준편차가 크게 나타나 유량의 변화가 유역의 수질 변화에 크게 영향을 미치는 것으로 분석되었다.
- (2) 강우시와 무강우시의 TOC 예측에 적용한 LMNN, MDNN, ANFIS 모형은 평창강 지점에서 모두 실측값에 근사하고, 작은 오차를 보였으며, MDNN 모형이 비교적 가장 좋은 결과를 보였다. 강우시의 DO 예측 결과에서는 적용한 세 모형 모두 안정적인 것으로 나타났으나, 일정한 주기성을 갖는 무강우시의 DO에 대한 예측 결과에서는 ANFIS 모형에 비해 LMNN, MDNN의 두 신경망 모형 예측값이 상관성이 크고, 오차 또한 작게 나타났다. 두 신경망 모형 중 MDNN 모형의 적용 결과가 보다 우수한 것으로 나타남으로써 주기성이 일정한 경우에는 정성적 자료의 활용이 효과적인 것으로 판단된다.
- (3) 유출예측 모형과 수질예측 모형을 연계하고 보다 정확한 유량산정을 통해 TOC를 예측한 결과, RMSE가 0.093 mg/L에서 0.068 mg/L로 개선되었다. 따라서 수질자동측정망 지점에서 연속적인 유량측정시설의 운영이나 효과적인 유출량 산정 방법이 요구되며, 수질변동이 큰 지점에서도 안정적으로 모의하도록 예측모형의 구조개선 및 정확도 향상이 필요하다고 판단된다.

## 참 고 문 헌

강관원, 박찬영, 김주환 (1992). "폐탄인식방법을 적용한 하천유출의 비선형 예측." **한국수문학회지**, 제25권, 제3호, pp. 105-113.

김만식, 이요상, 심규철, 심순보 (2001). "신경망모형을 이용한 하천의 수질예측 연구." **한국수자원학회 학술발표회 논문집**, pp. 925-930.

류병로, 한양수 (1998). "ARIMA 모형에 의한 하천수질 예측." **한국환경과학회지**, 제7권, 제4호, pp. 433-440.

신현석, 최시중, 김중훈 (1998). "신경망을 이용한 도시유역 유출 및 비점원 오염물 배출 모형화 연구." **대한토목학회논문집**, 제18권, 제5-B호, pp. 437-448.

안상진, 최병만, 연인성, 광현구 (2005). "미계측 지점에서의 유출 모의 및 예측." **한국수자원학회 논문집**, 제38권, 제6호, pp. 485-494.

연인성 (2005). 실시간 유량-수질관리를 위한 인공지능 시스템 개발. 박사학위논문, 충북대학교

정상만, 임경호, 최정현 (2000). "금강지류 유역에서의 유출량과 오염부하량의 상관관계 분석." **한국수자원학회 논문집**, 제33권, 제5호, pp. 527-536.

Hahn, R.L. (1972). *Time series analysis of daily measurements of water quality parameters of the passaic river at little falls, new Jersey*. M.S. Thesis, Rutgers Univ., New Brunswick, N.J.

Jang, J.S.R. (1993). "ANFIS: Adaptive-Neural based Fuzzy Inference System." *IEEE transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685.

Karunanithi, N. (1994). "Neural Networks for River Flow Prediction." *Journal of Computing in Civil Engineering, ASCE*, Vol. 8, No. 2, pp. 201-219.

Ken-ichi, Y., Masaaki, H. and Akihiho, M. (1997). "Novel Application of a Back-propagation Artificial Neural Network Model Formulated to Predict Algal Bloom." *Water Science and Technology*, Vol. 36, pp. 89-97.

Maier, H.R. and Dandy, G.C. (1996). "The use of artificial neural networks for the prediction of water quality parameters." *Water Resources Research*, Vol. 32, No. 4, pp. 1013-1022.

McMichael, F.C. and Hunter, Y.S. (1972). "Stochastic modeling of temperature and flow in rivers." *Water Resources Research*, Vol. 8, No. 1, pp. 87-93.

Nouh, M. (1996). "Simulation of Water Quality in Sewer Flow by Neural Networks." *Hydroinformatics '96, Proceedings of the 2nd International Conference on Hydroinformatics*, Zurich, Switzerland, pp. 885-891.

Tay, J.H. and Zhang, X. (2000). "A fast prediction neural fuzzy model for high-rage anaerobic wastewater treatment systems." *Water Resources Research*, Vol. 34, No. 11, pp. 2849-2860.

Thomann, R.V. (1976). "Time series analysis of water quality data." *ASCE*, Vol. 93, No. 1, pp. 1-23.

Zhang, B. and Govindaraju, R.S. (1998). "Using Modular Neural Networks to Predict Watershed Runoff." *Water Resource Engineering Conference, ASCE*, Vol. 1, pp. 897-902.

(논문번호:05-26/접수:2005.2.7/심사완료:2005.06.20)