

신경망 모형을 적용한 금강 공주지점의 수질예측 Water Quality Forecasting at Gongju station in Geum River using Neural Network Model

안 상 진* / 연 인 성** / 한 양 수*** / 이 재 경****

Ahn, Sang Jin / Yeon, In Sung / Han, Yang Su / Lee, Jae Kyung

Abstract

Forecasting of water quality variation is not an easy process due to the complicated nature of various water quality factors and their interrelationships. The objective of this study is to test the applicability of neural network models to the forecasting of the water quality at Gongju station in Geum River. This is done by forecasting monthly water qualities such as DO, BOD, and TN, and comparing with those obtained by ARIMA model. The neural network models of this study use BP(Back Propagation) algorithm for training. In order to improve the performance of the training, the models are tested in three different styles; MANN model which uses the Moment-Adaptive learning rate method, LMNN model which uses the Levenberg-Marquardt method, and MNN model which separates the hidden layers for judgement factors from the hidden layers for water quality data. the results show that the forecasted water qualities are reasonably close to the observed data. And the MNN model shows the best results among the three models tested

keywords : Neural Network, Water Quality, Forecasting, ARIMA(Autoregressive Integrated Moving Average), LMNN(Levenberg-Marquardt Neural Network), MANN(Moment-Adaptive learning rate Neural Network), MNN(Modular Neural Network)

요 지

수질 인자들은 다양하고 관계가 복잡하여 수질 변화를 예측하는데 많은 어려움이 있다. 따라서 입력과 출력이 비교적 용이하고 비선형 예측에 적합한 신경망 모형을 이용하여 금강유역 공주지점의 DO, BOD, TN에 대한 월 수질 예측을 수행하고 ARIMA 모형과 비교하여 적용 가능성을 검토하였다. 사용된 신경망 모형은 학습을 위해 BP(Back Propagation) 알고리즘을 적용하였으며 학습을 향상시키기 위한 모멘트-적용학습율(Moment-

- * 정회원, 충북대학교 토목공학과 교수
Professor, Dept. of Civil Engineering, Chungbuk National University, Cheongju, Chungbuk 361-763, Korea
(E-mail : hydrosys@trut.chungbuk.ac.kr)
- ** 정회원, 충북대학교 대학원 토목공학과 박사과정
Doctoral Student, Dept. of Civil Engineering, Chungbuk National University, Cheongju, Chungbuk 361-763, Korea
- *** 정회원, 경동대학교 토목공학과 전임강사
Full-Time Lecturer, Dept. of Civil Engineering, Kyungdong University, Sokcho, Kangwon 219-832, Korea
- **** 정회원, 대원과학대학 토목공학과 조교수
Assistant Professor, Dept. of Civil Engineering, Daewon Science College, Checheon, Chungbuk 390-702, Korea

Adaptive learning rate) 방법을 이용한 MANN 모형, 레벤버그-마퀴트(Levenberg-Marquardt) 방법을 이용한 LMNN 모형, 그리고 정성적인 판단인자를 첨가하여 정량적인 월 수질 자료와 분별, 학습하도록 은닉층을 분리한 MNN 모형으로 구분하였다. 대체로 신경망 모형의 예측치가 실측치에 근사한 결과를 보였으며, 은닉층을 분리한 MNN 모형이 가장 우수한 결과를 보였다.

핵심용어 : 신경망, 수질, 예측, ARIMA, LMNN, MANN, MNN

1. 서 론

근래에 산업화와 도시화로 인해 하천의 오염원이 증가하고 수원의 자정능력이 감소함에 따라 수질 문제가 심각하게 대두되고 있으며 하천의 수질예측은 직면한 생태문제의 유지유수 및 상수도 급수문제의 해결을 위한 장기적인 수질의 개선 방향과 분석에 필요하다. 수질예측에 대한 많은 연구가 이루어지고 있으며 일반적으로 향후 예측을 위한 방법으로 통계학적 특성을 이용한 추계학적 기법이 사용되었다. 체계적인 모형화 과정을 가진 Box와 Jenkins(1970)에 의해 창안된 기법이 추계학적인 입출력 시계열 모형에 널리 사용되고 있는데 Huck와 Farquhar(1974)에 의해 수질 자료를 이용한 모형에 적용되기 시작하였고 ARIMA(Autoregressive Integrated Moving Average) 모형 등이 여러 연구에서 활용되고 있다. 칼만필터링(Kalman filtering)으로도 알려진 Kalman(1960)이 소개한 상태공간을 이용한 수질예측도 이루어지고 있으며 상태공간 모형은 단변량 시계열과 다변량 시계열에 모두 사용된다. 최근에는 입력과 출력만을 고려하여 복잡한 과정을 거치지 않고 적용할 수 있는 신경망 모형에 대한 연구가 활발히 진행중이며 Maier와 Dandy(1996)가 오스트레일리아 남부에 있는 Murray강의 수질을 예측한 바 있다.

최근 국내의 연구로 류병로(1997)가 시계열 예측모형인 ARIMA 모형을 이용하여 공주지점의 DO 예측을 수행한 바 있으며, 한양수(1999)가 현재의 상태벡터와 미래의 입력벡터를 사용하여 시스템의 미래 출력 벡터를 계산하는 상태공간모형으로 금강유역의 수질을 예측한 바 있다. 신경망 모형을 이용한 연구로는 강두선 등(1998)이 신경망 모형을 이용하여 댐 방류 유량에 따른 BOD와 COD의 변화를 장기예측 하였고, 한재석과 김만식(1999)이 충주 다목적댐으로 유입하는 월 유입량에 따른 수질예측을 수행한 바 있다. 안상진과 연인성(2000)은 용존 산소량(DO) 장기예측을 통해 실제 하천에서의 신경망 모형 적용에 대한 가능성을 검토하였

으며, 김주환과 윤재홍(2001)은 신경망 모형을 적용하여 상수관로내 트리할로메탄 생성에 따른 농도추정 과정을 모형화 하였다.

수질에 영향을 미치는 인자들은 다양할 뿐만아니라 서로간의 관계가 복잡하므로 많은 변수를 고려하여 수질 변화를 예측하는데 많은 어려움이 있다. 1개월 간의 항목별 수질자료를 통계 처리한 월 수질 자료는 장기적인 변화추세를 파악할 수 있는 특성을 가지고 있다. 월 수질 자료는 수량과의 관계보다는 계절적인 요인이 작용하는 경우가 많으며 대체로 불규칙적인 경향을 띄고 있다. 따라서 비선형 예측에 적합하고, 많은 변수들의 복잡한 관계를 단순화하여 출력하는 신경망 모형을 이용하여 수질 예측을 수행하였다. 신경망 모형은 모멘트-적응학습율(Moment-Adaptive learning rate)을 이용한 BP(Back Propagation)알고리즘을 가진 MANN(Moment-Adaptive learning rate Neural Network) 모형, 레벤버그-마퀴트(Levenberg-Marquardt) 방법을 이용한 LMNN(Levenberg-Marquardt Neural Network) 모형, 그리고 정성적인 시간 자료를 입력자료로 추가하여 정량적인 수질 자료와 분별하여 학습하도록 은닉층을 분리한 MNN(Modular Neural Network) 모형으로 구분하였다. 항목별로 각 신경망 모형에 의한 학습과 월 수질 예측을 수행하고 ARIMA 모형과 비교하였으며 실제 하천에서 신경망 모형의 수질예측에 대한 적용성을 검토하고자 한다.

2. 수질예측 모형

2.1 신경망 모형

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. 신경망 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며 출력값을 생성하는 전달함수는 시그모이

드 함수가 많이 사용된다. 학습하는 동안 목표값과 실제 출력값 사이의 계산된 오차 정보는 네트워크를 통하여 역방향으로 전달되며 연결 가중치에 영향을 준다. 입력에서 출력과정을 식 (1)~(7)과 같이 나타낼 수 있다.

$$X = [x_1 \ x_2 \ \cdots \ x_n] \quad (1)$$

$$H = [h_1 \ h_2 \ \cdots \ h_n] \quad (2)$$

$$Y = [y_1 \ y_2 \ \cdots \ y_n] \quad (3)$$

여기서 X는 입력층 벡터, H는 은닉층 벡터, Y는 출력층 벡터이다.

$$u_h = XV^T \quad (4)$$

$$H = f(u_h) = \frac{1}{1 + \exp(-u_h)} \quad (5)$$

여기서 V는 입력층과 은닉층간의 연결강도이고 u_h 는 은닉층의 가중합이며 경사도 $\lambda=1$ 인 단극성 시그모이드 함수를 전달함수로 사용하는 경우이다.

$$u_y = HW^T \quad (6)$$

$$Y = f(u_y) = \frac{1}{1 + \exp(-u_y)} \quad (7)$$

여기서 W는 은닉층과 출력층간의 연결강도, u_y 는 출력층의 가중합이다. 목표치 T와 최종출력 Y를 비교하여 식(8)과 같이 제곱오차 E를 구한다.

$$E = \frac{1}{2} (T - Y)^2 \quad (8)$$

출력층의 오차 δ_y 와 은닉층에 전파되는 δ_h 는 식 (9), 식 (10)과 같이 구한다.

$$\delta_y = (T - Y)Y(1 - Y) \quad (9)$$

$$\delta_h = f'(u_h) \sum_{j=1}^k \delta_{y_j} W_{hj} \quad (10)$$

전파된 오차에 의해서 t 학습단계에서의 은닉층과 출력층간의 연결강도 변화량 $\Delta W(t)$, 입력층과 은닉층

간의 연결강도 변화량 $\Delta V(t)$ 는 은닉층 벡터 H와 입력층 벡터 X에 의해 식 (11), 식 (12)와 같이 구한다.

$$\Delta W(t) = \delta_y H \quad (11)$$

$$\Delta V(t) = \delta_h X \quad (12)$$

t+1 학습단계의 조정된 연결강도 $W(t+1)$ 와 $V(t+1)$ 는 식 (13), 식 (14)와 같이 나타낼 수 있다.

$$W(t+1) = W(t) + \Delta W(t) \quad (13)$$

$$V(t+1) = V(t) + \Delta V(t) \quad (14)$$

계속적으로 연결강도를 변경하며 학습회수에 만족을 하거나 오차가 허용범위에 수렴하면 학습을 종료하게 되며 학습을 마친 연결강도를 사용하여 예측을 수행하게 된다.

2.1.1 모멘트-적응학습율(Moment-adaptive learning rate) 방법

연결강도 조정을 위한 과정에서 발생할 수 있는 국부 최소값(Local minima value)문제 해결과 작은 오차와 빠른 수렴으로 학습 속도를 향상시키기 위해 모멘트-적응학습율 방법을 사용한다. 모멘트법은 학습과정에서 연결강도에 의한 오차의 진동을 막으면서 학습율을 크게 해주는 모멘트 계수를 사용하여 연결강도 조정 시 바로 전 연결강도의 변화량을 고려하는 것으로 식 (15), 식 (16)과 같이 나타낼 수 있다.

$$\Delta W(t+1) = \eta \delta_y H + \alpha \Delta W(t) \quad (15)$$

$$\Delta V(t+1) = \eta \delta_h X + \beta \Delta V(t) \quad (16)$$

여기서 t는 반복횟수, η 는 학습율이고 이 값이 클수록 연결강도의 조정량은 커진다. 그리고 α 와 β 는 연결강도 W와 V의 모멘트 계수이며 0에서 1사이의 값으로서 모멘트계수가 0이면 연결강도 조정량 값이 단지 오차량의 변화에만 영향을 받게된다.

적응학습율은 모멘트법과 병행하여 학습 속도를 향상시키는 방법으로 식 (17)과 같이 적응학습율 η 를 조절한다.

$$\eta(t+1) = \begin{cases} r_1 \eta(t) & E(t+1) < E(t) \\ r_2 \eta(t) & E(t+1) > r_3 E(t) \\ \eta(t) & otherwise \end{cases} \quad (17)$$

r_1, r_2, r_3 는 적응학습율에 영향을 미치는 매개변수로서 각각 1.05, 0.7, 1.04값을 일반적으로 사용하며 학습 후에 진단계에 비해 제곱오차 함수가 감소하였을 때에는 r_1 값을 사용하여 학습율을 일정 비율만큼 증가시키고, 오차 함수가 정해진 비율 이상으로 증가하였을 때에는 r_2 값을 사용하여 학습율을 정해진 비율만큼 감소시켜 최소값 주위에서 연결강도를 조절해 나가게 된다.

2.1.2 레벤버그-마퀴트(Levenberg-Marquardt) 방법

이 방법은 연결강도를 조정할 때 Levenberg-Marquardt update rule을 사용하게 되는데 그 자체가 일련의 선형방정식들의 해인 탐색방향을 사용하며, 행렬 형식으로 된 Levenberg-Marquardt update rule은 식 (18)과 같이 나타낼 수 있다.

$$\Delta W = (J^T J + \eta I)^{-1} J^T e \quad (18)$$

여기서 J 는 각 연결강도에 대한 오차 미분의 Jacobian matrix, η 는 적응학습율 그리고 e 는 오차 벡터이다.

Levenberg-Marquardt 방법은 효율적인 운영을 위해서는 매 반복 계산되는 η 의 크기를 제어하는 것으로 오차함수들 $E(W_i)$ 의 예측된 선형합과 극소값 $E(W_i^*)$ 에 대하여 3차로 내삽된 추정값을 사용하여 $E(W_i)$ 의 상대적인 선형성을 추정하는 것이며 오차함수들의 예측된 선형합은 식 (19)와 같이 계산된다.

$$E(W_i) = J(W_{i-1})^T d_{i-1} + \nabla E(W_i) \quad (19)$$

여기서 d_{i-1} 는 탐사방향이며, $E(W_i^*)$ 는 두 점 $E(W_i)$ 와 $E(W_{i-1})$ 에 대하여 3차로 내삽 함으로써 얻어진다. 만약 $E(W_i)$ 가 $E(W_i^*)$ 보다 크다면 η 는 감소되고, 반대이면 증가된다(김만식, 1998).

2.1.3 Modular 신경망

입력층과 은닉층의 노드(node)를 모두 연결하는 일반적인 신경망 네트워크와는 달리 Modular 네트워크는 전체 네트워크를 부분적인 네트워크(sub-network)로 분류하여 성질이 다른 입력변수를 구분하고 해당 은닉층에만 영향을 미치도록 구성되어 있어 입력 자료별로 나누어서 학습을 진행시키므로 학습 시간을 단축시킬 수 있을 뿐 아니라 정량적인 자료와 정성적인 자료의 특성을 살려 동시에 학습시킬 수 있다. Modular 신경망의 구조를 그림 1에 나타내었다.

연구에 사용된 MNN 모형은 학습을 위해 위의 LMNN 모형과 같은 Levenberg-Marquardt 방법을 사용하였으며 수질 시계열 자료와 자료의 해당 월을 입력한 정성적 자료를 2개의 은닉층으로 구분하여 학습함으로써 입력자료의 특성을 판단하고 인식한다. 계절이나 시간 변화에 많은 영향을 받는 수질 자료의 특성상 보다 정확한 예측을 위해서 정성적인 판단인자(Judgement factor)를 이용한 수질 자료의 월별 특성을 반영하고자 하였다. 여기서 사용되는 정성적인 자료는 독립적으로 연산되어 정규화 및 은닉층의 계산과정에서 시계열 자료에 영향을 주지 않으며 최종 출력값에만 직접 영향을 미치므로 월별 특성값이 강하게 반영된다.

2.2 ARIMA 모형

단일변량 시계열에 대한 Box와 Jenkins의 승법 ARIMA(p,d,q)(P,D,Q)₁₂ 모형은 모형의 식별, 추정,




그림 1. Modular 신경망의 구조

검진의 3단계에 걸쳐 진행되는 시계열분석 및 예측기법이다. 시계열의 구성요소가 시간의 흐름에 따라 빠르게 변동할 때 유용한 모형이다. 승법 ARIMA 모형은 1차, 2차 혹은 일반적으로 d차로 표현되는 단순 ARIMA(p,d,q)모형(비계절성 ARIMA모형)과 주기가 w인 계절계차를 이용한 주기성 ARIMA(P,D,Q)모형(계절성 ARIMA모형)의 결합으로 표현될 수 있다. 주기가 w인 D차 differencing이 고려된 ARMA(P,Q)모형인 ARIMA(P,D,Q)모형은 식 (20)과 같다.

$$\begin{aligned} (1 - \phi_1 B^w - \phi_2 B^{2w} - \dots - \phi_p B^{pw})(1 - B^w)^D Y_t \\ = (1 - \theta_1 B^w - \theta_2 B^{2w} - \dots - \theta_q B^{qw}) a_t \end{aligned} \quad (20)$$

여기서 B는 후향연산자(Backward Operator)로서 $BY_t = Y_{t-1}$, $B^w Y_t = Y_{t-w}$, $B^{pw} Y_t = Y_{t-pw}$ 등을 표시하며, $(1 - \phi_1 B^w - \phi_2 B^{2w} - \dots - \phi_p B^{pw}) = \Phi(B^w)$ 와 $(1 - \theta_1 B^w - \theta_2 B^{2w} - \dots - \theta_q B^{qw}) = \Theta(B^w)$ 는 각각 계절 AR 및 MA 연산자이다. 잔차 a_t 에 적용되는 ARIMA(p,d,q)모형(a_t 계열에 d차 차분이 적용된 ARMA(p,q)모형)은 식 (21)과 같다.

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Y_t \\ = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \end{aligned} \quad (21)$$

여기서 등식 좌우변의 괄호 속의 표현은 각각 $\phi(B)$ 및 $\theta(B)$ 로 표시되고 AR 및 MA 모수이며, a_t 는 독립변수이다. 일반적인 다차항 ARIMA(p,d,q)×(P,D,Q)w모형은 식 (21)의 a_t 를 식 (20)에 대입하여 얻을 수 있으며 일반적으로 표시하면 식 (22)와 같다(안상진과 이재경, 2000).

$$\Phi(B^w)\phi(B)(1 - B^w)^D(1 - B)^d X_t = \Theta(B^w)\theta(B)a_t \quad (22)$$

3. 대상유역 및 자료

3.1 대상유역

대상유역으로 금강수계의 중·하류부에 위치한 공주 지점을 채택하였으며 유역면적은 7155.48km²이고, 유로 연장은 308.5km에 달하며 유역의 평균 폭은 23.19km이다. 그림 2는 공주지점을 포함한 금강유역도를 나타내고 있다.




그림 2. 대상유역 위치도

3.2 자료 선정

모형의 모의를 위해 금강유역의 공주지점과 연기지점의 월 수질 자료를 이용하였으며 표 1에 수질항목별 최대, 평균, 최소값을 나타내었다. DO와 BOD 예측을

표 1. 수질자료

	DO(mg/L)		BOD(mg/L)		TN(mg/L)	
	Gongju	Yeongi	Gongju	Yeongi	Gongju	Yeongi
MAX	14.10	14.10	6.20	6.80	6.77	8.47
MEAN	8.87	8.53	3.19	3.39	2.98	3.00
MIN	3.60	4.00	1.60	1.40	0.69	0.51

위해서 사용된 신경망 모형의 학습자료는 공주지점과 연기지점의 1985년부터 1997년까지, 검증자료는 학습하지 않은 1998년의 자료를 사용하였다. TN 예측을 위해서 사용된 학습자료는 1990년부터 1997년까지 자료이며, 1998년의 자료를 검증자료로 사용하여 예측 결과와 비교·분석하였다.

각 수질 항목별로 시점 t , 지체시간(Lag) n 에 대하여 t 시점의 공주 수질자료와 $t-n$ 시점의 공주 수질자료의 상관계수, 그리고 t 시점의 공주 수질자료와 $t-n$ 시점의 연기 수질자료의 상관계수를 그림 3에 나타내었다.

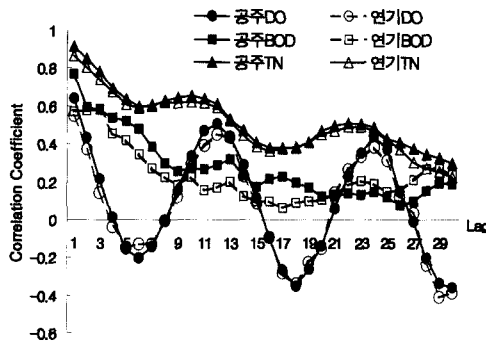


그림 3. 출력자료에 대한 입력자료의 지체시간에 따른 항목별 상관계수

그림 3의 출력자료에 대한 입력자료의 지체시간에 따른 항목별 상관계수에서 알 수 있듯이 수질 항목별로 공주지점의 1개월(Lag-1) 전의 자료가 현재의 시점의 공주지점 자료와 가장 높은 상관관계를 보였으며 상관관계는 DO가 0.64, BOD가 0.77, TN이 0.91로 나타

났다. 또한 연기지점의 자료는 공주지점의 자료와 유사한 경향을 보였으며 공주지점의 자료와 높은 상관성이 있는 것으로 판단되어 입력자료로 선정하였다. 월 DO 자료의 경우 뚜렷한 주기성을 가지고 있으며 현재시점으로부터 2개월(Lag-2) 전의 자료보다는 12개월(Lag-12) 전의 자료가 오히려 높은 상관관계를 나타내었다. BOD와 TN의 경우는 일정한 특성은 있으나 지체시간이 증가할수록 낮은 상관관계를 보였다.

4. 적용 및 결과

4.1 수질예측 모형의 구성

시계열 형태로 구성된 수질예측 신경망 모형은 월 수질 자료를 이용하여 학습하고 예측하도록 되어있으며 자료분석 결과에 따라 t 시점의 자료를 입력자료로 사용하여 향후 $t+1$ 시점 즉, 1개월 후의 수질을 출력하도록 하였다. 표 2에 신경망 모형의 입·출력 자료와 구성을 나타내었다. 모멘트-적응학습을 이용한 MANN (Moment-Adaptive learning rate Neural Network) 모형과 Levenberg-Marquardt 방법을 이용한 LMNN(Levenberg-Marquardt Neural Network) 모형은 은닉층의 노드수가 입력 노드수의 배수인 $2N$ 개의 경우가 모의에 적합하다고 판단되어(연인성, 2000) 은닉층을 입력자료의 2배인 $2N$ 구조로 구성하였다. 신경망 알고리즘의 종류와 학습자료의 종류에 따라 차이는 있었으나 은닉층 노드수의 변화는 예측 모형의 정확도에 다소 영향을 미치며 학습회수의 변화에 따른 영향은 미소한 것으로 판단된다. 그림 4의 a)에 MANN 모형과 LMNN 모형의 구조를 나타내었으며, b)에 MNN(Modular Neural Network) 모형의 구조를 나

표 2. 수질 예측 신경망 모형의 구성 및 입·출력 자료

항목	모형	입력층 노드수	은닉층 노드수	출력층 노드수	입력자료	출력자료
DO	MANN	2	4	1	공주 DO(t), 연기 DO(t)	공주 DO(t+1)
	LMNN	2	4	1	공주 DO(t), 연기 DO(t)	공주 DO(t+1)
	MNN	2-1	4-2	1	공주 DO(t), 연기 DO(t), Month(t+1)	공주 DO(t+1)
BOD	MANN	2	4	1	공주 BOD(t), 연기 BOD(t)	공주 BOD(t+1)
	LMNN	2	4	1	공주 BOD(t), 연기 BOD(t)	공주 BOD(t+1)
	MNN	2-1	4-2	1	공주 BOD(t), 연기 BOD(t), Month(t+1)	공주 BOD(t+1)
TN	MANN	2	4	1	공주 TN(t), 연기 TN(t)	공주 TN(t+1)
	LMNN	2	4	1	공주 TN(t), 연기 TN(t)	공주 TN(t+1)
	MNN	2-1	4-2	1	공주 TN(t), 연기 TN(t), Month(t+1)	공주 TN(t+1)

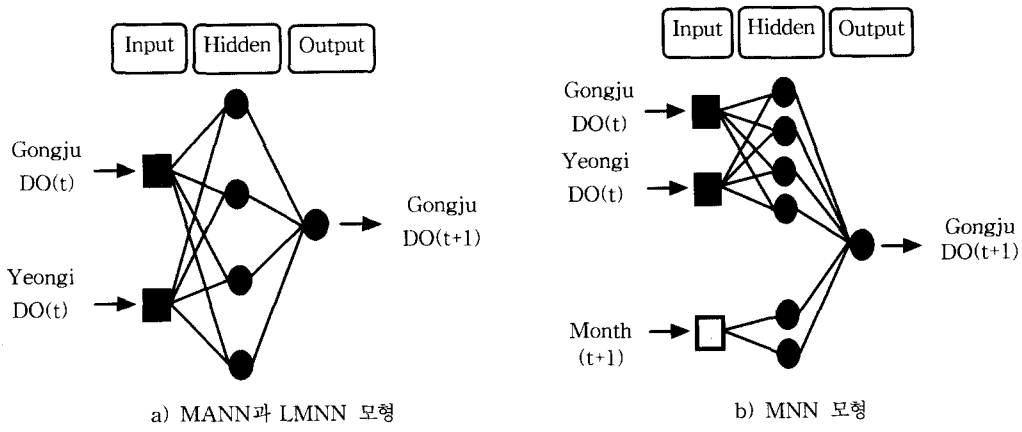
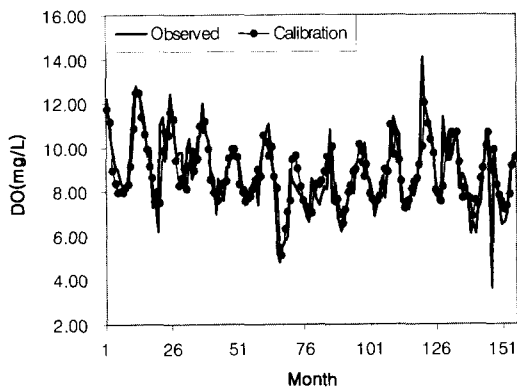
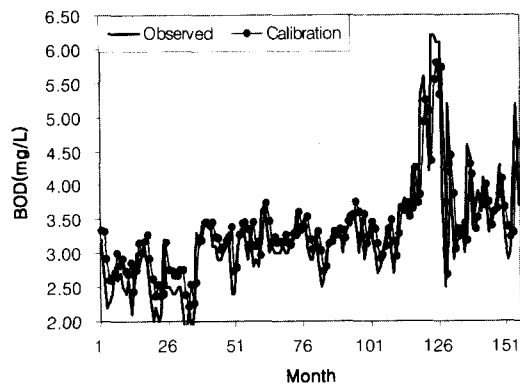


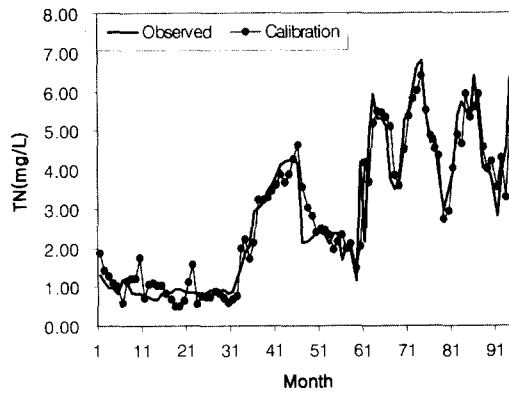
그림 4. 수질예측 모형의 구조



a) DO의 학습결과(1985~1997)



b) BOD의 학습결과(1985~1997)



c) TN의 학습결과(1990~1997)

그림 5. MNN 모형의 수질항목별 학습결과

타내었다. 입출력 자료는 DO 예측을 수행하는 경우의 자료이고, MANN 모형과 LMNN모형은 같은 형태의 구조를 가지며 MNN 모형은 은닉층이 분리된 형태의 구조를 가진다. 은닉층을 분리한 MNN 모형은 입력자료로 시계열 형태의 수질 자료와 특성 판단인자로서 작용하게 되는 정성적인 자료인 해당 예측 월을 사용하였다. 은닉층은 수질 자료에 관계된 층과 정성적 자료에 관계된 층으로 분리되며 출력층에서 다시 조합된다.

신경망 모형과 비교를 위해 수질예측을 위한 ARIMA 모형을 사용하였다. 공주지점에서의 수질항목별 계열의 정상성을 판단하기 위하여 자기상관도(ACF)와 편자기상관도(PACF)를 구하였으며 계차 변환을 하지 않은 자기상관계수가 지속적으로 감소하는 형태를 보이고 있어 비정상시계열로 판단하고 정상화를 위해 비계

차와 계절계차변환을 실시하였다. 최종적으로 DO 예측모형은 ARIMA(1,1,1)×(1,1,1)12모형, BOD 예측모형은 ARIMA(2,1,2)×(2,1,2)12모형, TN 예측모형은 ARIMA (1,1,1)×(1,1,1)12모형으로 결정하였다.

4.2 신경망 모형의 학습결과

신경망 모형의 경우 정확한 예측을 위해서는 양질의 자료를 학습하는 것과 입력자료의 선정이 매우 중요하다. 수질 예측을 위한 학습은 입력자료를 시계열 형태로 구성하고 입력자료와 출력자료의 상관성이 크게 유지된다고 판단되는 1개월 예측을 고려하였다. 유역특성 상 서로 다른 지점의 자료는 다른 변수들의 영향을 받지만 비선형 예측에 장점이 있는 신경망 모형에서는 두 지점의 자료를 모두 활용 가능한 것으로 판단되어 공주




그림 6. 모형별 DO 예측 결과




그림 7. 모형별 BOD 예측 결과

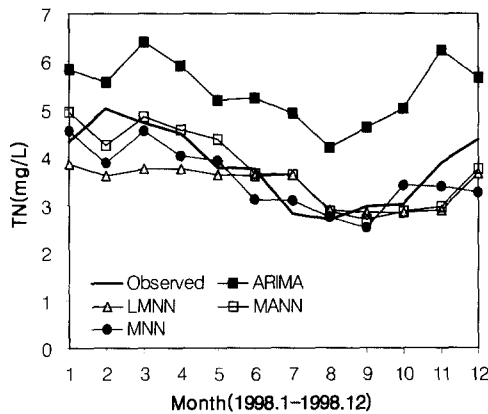


그림 8. 모형별 TN 예측 결과

지점의 자료 외에 상관성이 높은 연기지점의 동일 수질 항목 자료를 입력값으로 첨가하였다. 신경망 모형 중 MNN 모형에 의해 학습된 학습결과를 수질 항목별로 그림 5에 나타내었다. 그림 5의 a)와 b)는 1985~1997년 자료를 학습한 DO, BOD 학습결과이며 c)는 1990~1997년 자료를 학습한 TN의 학습결과이다.

그림 5에서 보는바와 같이 수질예측 신경망 모형은 충분한 학습을 수행하였다. 신경망 모형의 학습 결과는 학습회수가 많을수록 좋은 결과를 보이며 단지 좋은 학습 결과만으로 예측 모형의 적용성을 검토할 수는 없다고 판단된다. 입력값과 출력값의 관계가 선형이거나 절대적인 관계에 있지 않고서는 예측 결과가 학습결과에 반드시 비례하는 것은 아니며 비선형적인 요소가 많은 수질이나 수문 분야에서 모형의 학습시 완전한 수렴(학습)은 어렵기 때문이다.

4.3 수질 예측

학습을 마친 신경망 모형들과 단변량 시계열 모형인

ARIMA 모형을 이용하여 일정한 패턴을 유지하고 있는 공주지점의 DO 항목에 대한 각 모형별 예측결과를 비교하여 그림 6에 나타내었다. 검증자료는 1998년 1월부터 12월까지 자료로서 ARIMA, MANN, LMNN, MNN의 4가지 모형 모두 실측치에 근사한 결과를 보였으나 과소 예측된 경향이 나타났다.

그림 7은 BOD 항목에 대한 각 모형별 예측결과이며 그림 8은 TN 항목에 대한 모형별 예측결과이다.

그림 7~8에서 알 수 있듯이 BOD, TN 예측의 경우 전반적으로 실측치에 근사한 결과를 보인 신경망 모형에 비해 ARIMA 모형은 과대하게 예측한 결과를 보였는데 모형의 검증에서 사용된 DO 수질 자료와 달리 BOD(1985년~1997년), TN(1990년~1997년) 월 자료는 종반부인 1997년으로 진행될수록 증가하는 경향에서 기인한 것으로 판단된다. 신경망 모형들의 예측결과를 비교하여 보면 타 모형에 비해 MNN 모형은 시계열 형태의 예측에서 나타날 수 있는 예측값이 실측값

표 3. 분석 통계지표.

Item	Relation Equation
Root Mean Square Error (RMSE)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2}$
Root Relative Square Error (RRSE)	$\sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{X_i - Y_i}{X_i} \right)^2}$
Correlation Coefficient (CC)	$\frac{\sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sigma_x} \right) \left(\frac{Y_i - \bar{Y}}{\sigma_y} \right)}{n}$

표 4. 각 항목에 대한 모형별 예측 결과

수질항목	모형	ERROR		
		RMSE	RRSE	CC
DO	ARIMA	0.9779	0.1101	0.8915
	MANN	1.0811	0.1104	0.7810
	LMNN	1.0196	0.1023	0.7573
	MNN	0.9456	0.1004	0.9126
BOD	ARIMA	1.8980	0.9218	0.1164
	MANN	0.4082	0.1570	0.7034
	LMNN	0.3868	0.1519	0.7416
	MNN	0.3984	0.1517	0.8043
TN	ARIMA	1.6361	0.4758	0.8247
	MANN	0.5292	0.1424	0.7628
	LMNN	0.7036	0.1695	0.6652
	MNN	0.5707	0.1374	0.7574

의 우측으로 전이되는 시간지연(Time-lag) 현상이 많이 나타나지 않은 것을 알 수 있으며 정성적인 자료의 영향으로 판단된다.

4.4 결과 및 분석

금강유역 공주지점의 월 수질 예측을 위하여 모의된 ARIMA 모형과 3가지로 구분한 신경망 모형들의 수질 예측값을 1998년 실측값과 비교 검증하였다. 모형 예측 결과의 분석을 위해 통계지표로 사용한 RMSE, RRSE, CC는 표 3과 같으며 예측결과를 분석하여 표 4에 나타내었다.

여기서 X_t 는 실측치, \bar{X} 는 실측치의 평균, Y_t 는 계산치, \bar{Y} 는 계산치의 평균, σ_x 는 실측치의 표준편차, σ_y 는 계산치의 표준편차를 나타낸다.

일정한 패턴을 유지하는 DO 항목의 예측에 대한 결과를 보면 RRSE가 0.1004~0.1104로 4가지 모형 모두 유사한 오차가 나타났으나 MNN(Modular Neural Network) 모형이 0.1004로 가장 좋은 결과를 보였으며 상관계수도 91%로 MNN 모형이 가장 좋은 결과를 보였다.

BOD, TN 항목의 예측에 대한 경우도 MNN 모형이 가장 작은 오차를 보였으며 RRSE가 각각 BOD에 대한 예측오차는 0.1517, TN에 대한 예측오차는 0.1374로 나타났다. ARIMA 모형은 상관관계가 지체 시간에 따라 주기성을 갖는 DO에 비해 규칙성이 떨어지는 TN, BOD 순으로 점차 큰 오차를 유발하였다.

5. 결론

입력자료의 위치만을 고려하는 일반적인 형태의 신경망 모형을 학습방법에 따라 모멘트-적용학습을 사용하는 신경망 모형(MANN)과 Levenberg-Marquardt 방법을 사용하는 신경망 모형(LMNN)으로 구분하고, 은닉층이 다수이며 정량적인 수질자료와 정성적인 자료를 동시에 학습할 수 있는 Modular 신경망 모형(MNN)을 구성하여 공주지점의 월 수질 예측을 수행하고 다음과 같은 결론을 얻었다.

- (1) 신경망 모형의 학습과 시계열 형태의 예측을 위해 항목별로 월 수질 자료를 분석해 본 결과, 공주지역의 수질자료는 상류의 연기자료와 많은 연관성이 있었으며, 공주지점의 수질 입력자료와 출력자료를 1개월(Lag-1) 지연시킨 경우에 상호간의 상관관계가 가장 높았고, DO의 경우는 12개월(Lag-12)의 뚜렷한 주기성을 보였다.

- (2) ARIMA 모형과 신경망 모형은 자료의 크기와 주기적인 패턴이 일정한 DO 예측에 있어 모두 유사한 예측 결과를 보였으며, 자료의 변동폭이 심한 BOD, TN 예측의 경우는 신경망 모형이 작은 오차를 나타냈다. ARIMA 모형은 TN 예측에서 높은 상관관계로 실측치의 변동성향을 반영하였으나 자료의 증기추세에 따라 과대 예측하는 경향을 보인 반면 신경망 모형은 복잡한 패턴변화에 대한 적응력으로 실측치에 근사한 것으로 판단된다.

- (3) 시계열 형태로 형성한 입력자료를 이용하여 월 수질 예측을 수행한 신경망 모형들의 예측결과를 비교해 볼 때 정성적인 입력층을 첨가하여 월별특성을 이용한 MNN 모형이 일반적인 형태의 신경망 모형들보다 실측치에 근사하였으며, 시계열 예측에서 예측값이 실측값의 우측으로 전이되어 나타날 수 있는 시간지연(time-lag) 현상이 개선된 결과를 보였다.

참고 문헌

- 강두선, 신현석, 김중훈 (1998). "신경망 모형을 이용한 장기 하천 수질의 예측." 대한토목학회 학술발표회논문집(III), 대한토목학회, pp. 23~26.
- 김만식 (1998). 다목적 저수지의 홍수유출량 예측을 위한 신경망모형. 박사학위논문, 충북대학교
- 김주환, 윤재홍 (2001). "신경망 모형을 이용한 상수관로계통에서의 수질예측." 한국수자원학회 학술발표회논문집(III), 한국수자원학회, pp. 1189~1194.
- 류병로 (1997). "ARIMA모형에 의한 하천수질예측." 대전산업대학교 논문집, 대전산업대학교
- 안상진, 연인성 (2000). "신경망 모형을 이용한 용존산소(DO)의 예측." 충북대학교 산업과학기술연구소논문집, 충북대학교, 제14권, 제1호, pp. 179~187.
- 안상진, 이재경 (2000). "추계학적 모의발생기법을 이용한 월 유출 예측." 한국수자원학회논문집, 한국수자원학회, 제33권, 제2호. pp. 159~167.
- 연인성 (2000). 신경망을 이용한 강우예측. 석사학위논문, 충북대학교
- 한양수 (1999). 상태공간 모형에 의한 하천수질예측, 박사학위논문, 대구대학교
- 한재석, 김만식 (1999). "하천 수계의 장기 수질예측

- 을 위한 신경망 모형." 환경관리학회지, 환경관리 학회, 제5권, 제1호, pp. 145~152.
- Box, G. E. P. & G. M. Jenkins (1970). *Time Series Analysis, Forecasting and Control*. Holden-Day, Inc., San Francisco. pp. 109~118.
- Holger R. Maier and Graeme C. Dandy (1996). "The use of artificial neural networks for the prediction of water quality parameters." *Water Resources Research*, Vol. 32, No. 4, pp. 1013~1022.
- Huck. P.M. and Farquhar G.J. (1974). "Water quality models using the Box-Jenkins method." *J. Environ. Eng. Div.*, Vol. 100, No. 8, pp. 733~751.
- Kalman, R. E (1960). "A new approach to linear filtering and prediction problems." *Trans. ASME. J. Basic. Engrg. Ser. D*, Vol. 82, pp. 35~45.
- Simon Haykin (1999). *Neural Networks A Comprehensive Foundation - Second Edition*, Prentice Hall International. Inc.
- (논문번호:01-058/접수:2001.07.26/심사완료:2001.11.27)