

수자원 분야에서의 신경망 이론 적용

Application of Neural Network to Water Resources

최 진 규* 강 문 성**
Choi, Jin Kyu, Kang, Moon Seong

1. 머리말

인공신경망(Artificial neural network)은 뉴런(Neuron)들이 거미줄처럼 복잡하게 연결되어 상호작용을 하는 생물학적 신경망의 반응 전달 과정을 수학적으로 모형화한 것이다. 즉, 뇌에 존재하는 생물학적 신경세포와 그것들의 연결관계를 단순화시켜 수학적으로 모델링함으로써 뇌가 나타내는 지능적 형태를 구현한 것이다. 이처럼 그물과 같이 연결된 뇌의 정보 처리과정의 동적 거동을 표현하기 위하여 개발된 인공신경망은 의학, 수학, 공학, 심리학 등 다양한 학문분야에서 연구되고 있다. 특히, 공학분야에서는 연상 및 패턴인식 시스템, 로보틱스, 음성과 영상의 인식 및 처리, 통신제어, 데이터 마이닝(Data mining), 시계열 분석, 카오스 해석, 신호처리, 그리고 시스템 제어 등의 복잡한 자연현상에서의 문제를 해결하기 위하여 광범위하고 효율적으로 사용되고 있다.

인공신경망은 그 모형 자체의 비선형성(Nonlinearity)을 가짐으로써 통계적인 정규성(Normality)과 정체성(Stationarity)의 가정에서 자유롭다. 또한, 인공신경망은 기준에 설정된 신경망 모형을 문제의 목적에 따라 용이하게 변환이 가능한 적응성(Adaptivity)과 전산학적 병렬계산이 가능하여 그 처리가 합리적

인 병렬성(Parallel property) 등의 장점을 지니고 있다(신현석, 1998).

이러한 장점들로 인해 인공신경망 이론은 시간적 및 공간적 변동이 심한 기상이나 수문 등의 비선형 특성을 보이는 자연현상을 적절히 재현할 수 있는 모형화가 가능하다. 최근, 강우-유출 해석과 강우 분포, 가뭄, 지하수 유동과 위성영상의 피복 분류 및 처리 등의 수자원 및 환경분야에서의 적용과 응용이 활발하게 이루어지고 있다.

그러나, 신경망 이론의 수자원 및 환경분야에서의 적용에 있어서는 아직 학습방법에 따른 최적해를 구하는 데 한계가 있으며, 그 적용의 정규화가 미흡하다는 단점도 지니고 있다. 따라서 신경망을 이용한 수자원 및 환경분야의 모형화에서 발생할 수 있는 여러 문제들을 해결하기 위해서는 해당분야의 다양한 적용을 통한 검토가 이루어져야 할 것이다.

본고에서는 수자원과 영상처리 등 여러 분야에 널리 적용되는 신경망 이론을 소개하고, 강우-유출해석, 수문환경 등 신경망 모형의 수자원 및 영상처리 분야에서의 적용 예를 고찰함으로써, 신경망 이론의 수자원 및 영상처리 분야에의 다양한 적용 가능성을 제시하도록 한다.

* 전북대학교 농과대학 (농업과학기술연구소)
** 서울대학교 농업생명과학대학

2. 발전 과정

신경망모형은 McCulloch와 Pitts(1943)가 단순한 형태의 뉴런(Neuron)을 제안하면서 탄생하였다. 이들의 뉴런은 다른 뉴런으로부터의 입력에 대한 가중합을 계산하고 그 값이 임의의 임계값을 경계로 하여 0과 1을 출력하도록 한 단순한 논리를 구현한 형태이다.

Donald Hebb(1949)는 두 뉴런 사이의 연결강도(Synaptic weight)를 조절할 수 있는 학습규칙을 최초로 발표하였다. 이후 Frank Rosenblatt(1958)는 퍼셉트론(Perceptron)이란 최초의 신경망 모형을 발표하면서 많은 연구가 뒤따르게 되었다. 퍼셉트론 모형은 입력층과 출력층으로 구성되며 어떠한 형태의 패턴이 입력층에 주어지면, 신경망내의 연결강도들을 스스로 조정하면서 학습할 수 있도록 한 것이다.

퍼셉트론이 제안된 후에 신경망모형은 큰 기대를 모았다. 그러나 Marvin Minsky와 Seymour Papert(1969)가 저서 "Perceptron"에서 단일층 신경망의 이론적 한계를 지적하였다. 이들은 퍼셉트론 모형을 수학적으로 분석하여, 이 모형이 간단한 XOR(Exclusive-OR) 함수도 모의하지 못하며 선형분리 문제밖에 해결할 수 없는 한계점을 명확히 밝히면서 신경망에 관한 연구는 약 20여년간의 상당히 오랜 암흑기를 거치게 된다.

Rosenblatt이 제안한 단순 퍼셉트론(Simple perceptron)의 한계는 은닉층이 없다는 것이다. 따라서 입력층, 출력층의 단순 퍼셉트론에 하나 이상의 은닉층을 가지는 다층 퍼셉트론(Multi-layer perceptron)과 같은 새로운 모형이 제시되었다. 그러나 이를 학습시킬 수 있는 알고리즘이 개발되지 않아 지속적인 발전은 이루어지지 않았다.

그 후 Hopfield(1982)는 순환신경망 구조와 연상 메모리를 가지는 Hopfield 모델을 발표하

였고, Kohonen(1982)는 비교사학습(Unsupervised learning)의 일종인 SOFM(Self organizing feature map)을 개발하여 음성인식에 이용하였다. Rumelhart, Hinton and Williams(1986)는 강력한 다층 퍼셉트론의 학습을 가능하게 하는 델타규칙의 일원화를 개발하였는데, 그것이 바로 유명한 역전파학습(Back propagation) 알고리즘이다. 역전파 알고리즘은 입력값에 의해서 얻어진 출력값과 목표값과의 오차를 역으로 전파시켜 연결강도를 조절해나가는 방법이다.

역전파 알고리즘이 발표된 이후 신경망이론에 대한 연구가 활발하게 이루어지기 시작하였으며, RBF(Radial-basis function networks) 등과 같은 신경망 모형이 우후죽순처럼 등장하게 된다. 이처럼 발전되어 온 신경망 모형이 현재 응용되고 있는 분야는 매우 다양하며 거의 모든 공학분야, 의학분야, 심지어 경영학 분야에도 이용되고 있으며, 최근 수자원 및 영상처리 분야에도 활발하게 적용되고 있다.

3. 신경망 이론

가. 신경망의 기본 개념

인간의 뇌는 처리의 최소단위인 뉴런(Neuron)이라는 기본소자를 이용하여 정보를 처리한다. 뉴런이라는 신경세포는 세포체(Cell body), 수상돌기(Dendrites), 그리고 축색돌기(Axon)로 이루어져 있다. 그리고, 뉴런들간의 정보전달은 시냅스(Synapse)라는 것을 이용하여 전달하고 있다. 뉴런의 동작원리는 단순하지만 수 많은 신경세포들이 연결망을 이루어 인간의 복잡한 모든 행동을 통제하고 조절하고 있는 것이다.

신경망 모형은 이러한 신경세포의 정보처리 과정을 수학적으로 모델링한 것으로서 입력과 출력을 가지는 자동적인 학습기계라고 말할

수 있다. 즉, 인공신경망은 이러한 인간 두뇌의 구조와 기능을 모방하여 신경세포가 갖는 처리와 특징을 각각 입력과 출력 그리고 정보 처리부분과 기억장소를 가진 매우 간단한 컴퓨터와 동일한 구조를 가지고 연결강도를 이용하여 정보를 출력하여 주는 것이다.

나. 신경망 모형의 종류 및 특징

신경망은 구조와 학습, 연상에 사용된 연산 원리에 따라 여러 가지로 분류된다. 일반적으로 사용되는 신경회로망의 형태는 <표 - 1>과 같이 나타내어 진다. 신경망 모형은 입력자료가 이진수의 형태이거나 연속적인 값을 가지는 실수 형태로 구분되어 진다. 신경망 모형에서 학습은 임의의 초기값에서 시작하여 계속적인 개선을 통하여 적절한 연결강도를 구하는 과정이다. 이러한 학습방법에 따라 신경망 모형은 교사학습(Supervised learning)과 비교학습(Unsupervised learning) 모형으로 나눌 수 있다. 교사학습은 입력자료에 의한 출력값과 비교할 수 있는 목표값(Target value)이 존재하며, 그 오차를 이용하여 학습을 수행하는 것이고, 비교학습은 목표값이 없으며 입력자료와 신호만이 제공되므로 자기조직화에 의해 학습하게 되고 그 결과를 출력하게 된다.

<표 - 1> 신경망의 분류

| 입력형태 | 학습형태 | 모 형 |
|--------|--------------|---|
| Binary | Supervised | -Hopfield network -Boltzmann machine -Hamming network |
| | Unsupervised | -ART(Adaptive Resonance theory) |
| Real | Supervised | -Simple perceptron -Multilayer perceptron |
| | Unsupervised | -Kohonen self organizing |

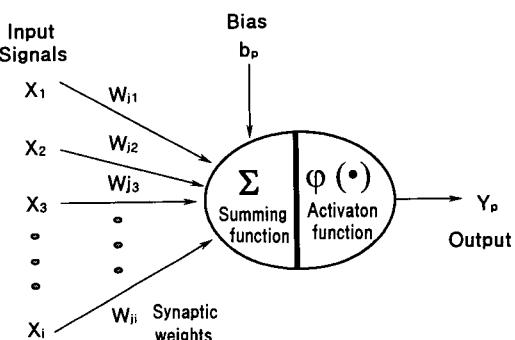
다. 신경망의 기본 연산과정

신경망 모형의 연산과정은 가장 많이 보고

되고 있는 다층 퍼셉트론을 중심으로 소개하도록 한다. 신경망의 연산은 인간 두뇌의 처리 과정을 수학적으로 표현한 처리소자에 의해서 이루어진다. <그림 - 1>은 인간의 두뇌를 모델링한 기본적인 신경망 단일소자인 뉴런의 구조를 보여주고 있다.

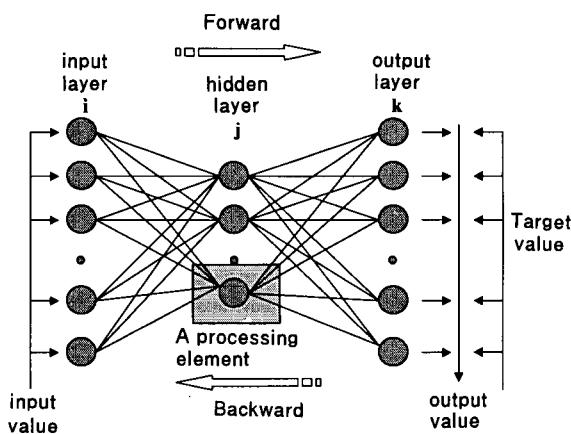
뉴런의 연산과정은 <그림 - 1>에서와 같이 입력자료(Input signal)인 X_i 와 연결강도(Synaptic weight)의 벡터인 W_{ji} 에 의한 곱의 형태로 나타내어지는 결합함수(Summing function)인 Σ 가 계산된다. 이 결합함수로부터 출력이 선형 또는 비선형적인 특성을 가지게 하는 활성함수(Activation function)를 통해 출력의 과정으로 연산이 수행된다.

단지 입력층과 출력층으로만 구성된 단순 퍼셉트론의 한계를 보완하기 위해 입력층과 출력층 사이에 하나 이상의 은닉층을 둔 것이 다층 퍼셉트론이다. <그림 - 2>는 은닉층이 하나인 전형적인 다층 퍼셉트론의 구조를 보여주고 있다.



<그림 - 1> 인공신경망의 연산과정

다층 순방향 신경망(Feed-forward neural networks) 훈련은 실측치와 모의치의 비선형 최소 자승인 가중함수를 최소화하는 것으로서 교사훈련(Supervised training)이라고 한다. <그림 - 2>에서 보여주고 있는 순방향 다층 퍼



〈그림-2〉 다층인공신경망의 구조

셉트론의 기본적인 연산과정은 다음과 같다.

먼저, 신경망 모형의 입력층 노드의 입력자료는 시그모이드 전달함수가 최소값 0과 최대값 1을 전달함으로 이론적인 정규화 범위로 변환하여야 한다. 간단한 정규화 예는 식(1)과 같다.

$$X' = \left[\frac{1}{(X_{\max} - X_{\min})} \right] \times (X - X_{\min}) \quad \dots \dots \dots (1)$$

여기서, X' 은 변환된 입력변수이고, X_{\max} 와 X_{\min} 은 실측 입력자료의 최대값과 최소값이다.

신경망모형에서 입력층의 노드로부터 은닉층으로의 순방향 연결강도의 합과 주로 시그모이드 함수를 이용하는 활성화 함수는 각각 식 (2)와 식 (3)과 같다.

$$net_{pj} = \sum_{i=1}^n W_{ji} x_{pi} \quad \dots \dots \dots (2)$$

$$g(net_{pj}) = \frac{1}{1 + e^{-net_{pj}}} \quad \dots \dots \dots (3)$$

여기서, net_{pj} 는 은닉층과 입력층 사이의 연결강도의 합, N 은 총 입력노드의 수, W_{ji} 는 입

력층과 은닉층 사이의 연결강도, x_{pi} 는 패턴 p 에 대한 i 번째 값, 그리고 $g(net_{pj})$ 는 뉴런의 활성화함수이다.

은닉층에서 출력층으로 연결되는 연결강도와 출력값은 다음의 식 (4)와 식 (5)와 같이 나타내어진다.

$$net_{pk} = \sum_{j=1}^m W_{kj} g(net_{pj}) \quad \dots \dots \dots (4)$$

$$P_{pk} = g(net_{pk}) \quad \dots \dots \dots (5)$$

여기서, m 은 은닉층 노드의 수, W_{kj} 는 출력층의 k 와 은닉층 노드 j 와 연결되는 연결강도, 그리고 P_{pk} 는 k 번째의 예측 출력값으로서 강우-유출 모형의 경우에 모의 유출량값을 나타낸다.

라. 신경망의 학습

신경망의 학습은 기술한 바와 같이 교사학습과 비교학습으로 구분된다. 교사학습은 과거에 수집된 입력패턴과 출력패턴의 짹으로 구성되어지는 학습패턴의 출력값과 목표값과의 오차를 최소화하기 위해 연결강도를 조절해 나아가는 방법이다. 오차는 식 (6)과 같이 계산되어진다.

$$E = \frac{1}{2} \sum_{p=1}^n \sum_{k=1}^m (y_{pk} - p_{pk})^2 \quad \dots \dots \dots (6)$$

여기서, E 는 총오차, n 은 실측치의 패턴 수, m 은 총 출력단위, y_{pk} 는 실측된 반응인 목표출력값, p_{pk} 는 모델에 의한 모의 출력값을 나타낸다.

교사학습으로서 가장 널리 이용되고 있는 것은 오차를 역으로 전파시켜 나가면서 연결강도를 조절하는 오류역전파(Error back

propagation) 알고리즘이다. 오류역전파 알고리즘은 일반화된 델타규칙(Generalized delta rule)으로서, 출력층의 오차를 먼저 계산하고, 오차의 미분으로 표현되는 값을 은닉층으로 역전파시켜(<그림-2>의 Backward 방향) 연결강도를 반복적으로 조정해 나가는 방법이다.

오류역전파 알고리즘을 이용한 신경망 모형에서 계산된 오차를 최소화하기 위한 최적화기법으로는 경사하강법(Gradient descent method)과 Levenberg-Marquardt(LM) 방법이 주로 사용된다.

경사하강법은 Chain rule을 사용하여 오차를 연결강도에 대한 일차 편미분으로 나타내어지며, 연결강도는 급강하방향으로 이동하여 연결강도의 값을 조정해 나간다. 이것을 수식으로 나타내면 식(7)과 같다.

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}} \quad \dots \dots \dots (7)$$

여기서, η 는 학습율로서 스칼라이다.

경사하강법은 학습과정에서 발생할 수 있는 지역 최소값(Local minima value) 문제와 오차를 최소화하기 위한 수렴속도가 길어진다. 이러한 단점을 해결하기 위해 경사하강법에서는 식 (7)에서 제시된 적응학습률(Adaptive learning rate)에 모멘트법(Momentum)을 고려하며, 그 식은 다음과 같다.

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} h_{pj} + \alpha \Delta W_{kj}(t) \quad \dots \dots \dots (8)$$

여기서, $\Delta W_{kj}(t+1)$ 는 연결강도의 조정량, δ_{pk} 는 p번째 패턴에 대한 출력층의 오차, α 는 모멘텀계수이다.

Levenberg-Marquardt 방법은 학습과정에서 발생할 수 있는 지역최소값(Local minima value) 문제와 오차를 작게 해서 수렴속도를

빨리 하여 학습속도를 향상시키기 위해 고안된 방법이다. 이 방법은 연결강도를 조정할 때 Levenberg-Marquardt update rule을 사용하게 되며, 식 (9)와 같이 나타내어진다.

$$\Delta W = (J^T J + \eta I)^{-1} J^T e \quad \dots \dots \dots (9)$$

여기서, J 는 각 연결강도에 대한 오차 미분의 Jacobian 행렬, η 는 적응학습율, I 는 항등행렬, 그리고 e 는 오차벡터이다.

이외에도 널리 이용되고 있는 교사학습은 최적화 기법 및 영상처리에 주로 응용되는 Hopfield 모형과 Radial basis function(RBF) 모형 등이 있다. 다층퍼셉트론이 일반적으로 높은 분류능력을 가지고 있는 반면 학습시간 및 국부 최소값의 문제점을 가지고 있다. 이에 반해 RBF는 학습속도가 빠르고 구성이 간단하며 분류능력이 우수한 장점이 있다. 그리고 은닉층에서 다층퍼셉트론이 시그모이드 함수인 것에 반해 RBF에서는 가우시안 함수(Gaussian function)를 사용한다.

비교사학습은 기존의 수집된 자료없이 신경망 모형 자체적으로 경쟁하거나 자기조직화에 의하여 연결강도를 산정한다. 이는 일반적으로 교사학습에 비하여 더 많은 매개변수를 요구하나 그 학습 시간은 짧다. 비교사학습을 사용하는 신경망 모형은 ART1&2(Grossberg, 1976), 패턴분류에 사용되는 PNN(Probabilistic neural network, Specht, 1991), 공간자료 및 회귀분석 등에 사용되는 Kohonen 모형(Kohonen, 1977) 등이 있다 (신현석, 1998).

4. 수자원 및 영상처리 분야에의 적용

가. 수자원 분야

신경망 모형은 비매개변수법의 일종으로서

입력과 출력으로 구성되는 하나의 시스템을 병렬적이고 비선형적으로 구축할 수 있다는 장점 때문에 불확실한 비선형 자연현상의 모형화에 여러 각도로 응용되고 있다. 수자원분야에의 적용사례는 장단기 강우-유출 해석, 강우량 해석, 가뭄 해석, 저수지 운영, 지하수위 해석 등이 있다. 특히, 1990년 이후부터 신경망 이론을 이용해 유출현상을 해석하는 많은 연구가 발표되었다.

1) 국내

신경망 이론이 국내의 문현상에서 가장 많이 보고되고 있는 수자원 분야는 단기 강우-유출 해석에의 적용이다. 강관원 등(1992)과 김주환(1993)은 홍수시의 일단위와 시단위의 하천유출량을 예측할 수 있는 신경망모형을 구성하여 전이함수모형과 비교하였고, 오경두 등(1994)은 미계측유역의 강우-유출 시뮬레이션에 적용하였다. 안경수 등(1998)은 신경회로망을 이용하여 평창강유역에서의 홍수 유출수문곡선을 모의하고 그의 적용성을 제시하였으며, 안상진 등(1999)은 Radial Basis Function Network(RBFN)를 이용해 유출수문곡선을 예측하였다. 김성원 등(2000)은 하천수위표지점에서 신경망기법인 역전파 알고리즘을 이용하여 홍수위를 예측하였고, 안상진 등(2000)은 Levenberg- Marquardt 방법과 Radial Basis Function Network(RBFN)의 적용성을 검토하였다. 이관수 등(2000)은 역전파 알고리즘을 이용하여 영산강유역에 일유출량 및 시유출량 예측을 실시하였으며, 신현석 등(2000)은 GIS 및 신경망을 이용한 지역 돌발홍수 예측시스템에 관한 연구를 수행하였다.

장기유출해석의 적용 예로는 김주환(1993)이 역전파 알고리즘을 이용하여 하천 일유출량에 대한 비선형 예측을 수행한 바가 있고, 김성원(2000)은 낙동강유역 진동지점의 일유출량 예측을 위해 역전파알고리즘을 개선한 FR-CGBP

(Fletcher-Reeves Conjugate Gradient Back-Propagation)와 SCGBP (Scaled Conjugate Gradient BackPropagation) 알고리즘을 이용하였다. 또한, 강문성 등(2000)은 오류역전파 알고리즘을 이용하여 시간적, 공간적 수문 변동이 심한 소유역에서의 일 유출량을 추정하였으며, 임기석 등(2000)은 낙동강 위천유역에 신경망을 이용한 하천 유출량을 예측하고 탱크모형과 비교하였다.

강우량 및 가뭄 해석에 적용된 예로는 오남선(1996)이 신경망이론을 이용한 강우예측모형을 구성하고 추계학적 모형과 비교 검토한 바 있으며, 신현석 등(1999a, 1999b)은 공간해석을 통하여 연평균 강우량의 해석 및 시공간적 가뭄 해석을 하였으며, 안상진 등(2000b)은 보청천 유역의 강우 결측지점의 보완과 강우를 예측하였다.

저수지 조작을 위해 신경망 이론을 응용한 예는 심순보 등(1998)이 신경망이론에 의한 다목적 저수지의 홍수유입량을 예측하였고, 김만식(1998), 고원준 등(1999), 그리고 심순보 등(1999a)은 신경망 모형을 이용해 실시간으로 저수지의 유입량 예측모형을 구성하여 적용하였다. 이외에도 지하수 흐름과 하수관망의 설계에도 연구가 진행되고 있다.

2) 국외

단기 유출해석에 관한 국외의 연구로는 Karunanithi 등(1994)이 하천의 유출예측에 cascade-correlation 알고리즘을 적용해 유출수문곡선의 해석을 하였고, Hsuh(1995)는 강우-유출과정에 대해 신경망 모형과 ARMAX 모형, SAC-SMA 모형을 적용하였으며, 비교적 신경망 모형의 적용이 좋은 결과를 나타내었다고 보고하였다. 그리고, Mason 등(1996)은 강우-유출 과정을 해석하기 위해 Radial Basis Function을 적용한 바 있으며, Tohma 등(1996)은 홍수유출량 예측을 통해 신경망의 선

행 예측 시간에 대한 적용성을 검토하였다. 또한, Thirumalaiah(1998)는 신경망이론을 실시간 홍수위 예측에 이용하였으며, 이외에도 많은 강우-유출과정에 관한 연구(Smith, 1992 ; Bonafe et al., 1994 ; Karunanthi et al., 1994 ; Isobe et al., 1994 ; Hsu et al., 1995 ; Markus et al., 1995 ; Smith and Eli, 1995 ; Dawson and Wilby, 1998 ; Thirumalaiah and Deo, 1998 ; Zealand et al., 1999)가 수행되어 져 왔다.

또한, 개념적 모형으로부터 생성된 자료에 대한 유출모의(Liong and Chan, 1993 ; Minns and Hall, 1966), 장기간 유출해석(Smith and Eli, 1995 ; Raman and Sunikumar, 1995 ; Tokar and Johnson, 1999) 등의 연구가 이루어져 왔고, Fench 등(1992)은 시공간적 영역에서 신경망모형의 입출력 자료를 구성하여 강우의 공간분포를 예측하였으며, 저수지 운영(Roman and Chandramouli, 1996), 시공간적 가뭄해석(Crespo and Mora, 1993 ; Shin and Salas, 1997) 등에 관한 연구가 수행되었다.

그외 Kao(1996)는 역전파 알고리즘 신경망 모형을 이용하여 DEM 자료로부터 배수패턴을 결정하고 그 결과를 다른 방법과 비교하였으며, Yang, et al.(1997)은 지하수위와 지하배수흐름에 역전파 신경망 알고리즘을 이용하였다. Sanchez, et al.(1998)은 해안 하수시스템의 집수망, 저류탱크, 처리장 등의 설계에 신경망을 이용하였고, Grubert(1995)은 역전파 알고리즘을 이용하여 혼합흐름을 예측하는데 적용하였다. Mase, et al.(1995)은 사석방파제의 안정해석에서 피해정도를 평가하는데 이용하고 그 적용성을 평가하였으며, Vaziri(1997)은 카스피해의 월평균 수면수위의 시계열 자료예측에 인공신경망과 ARIMA 모형을 적용하고 비교하는 등 수자원의 다양한 분야에서의 적용과 응용이 이루어지고 있다.

나. 위성영상처리분야

위성영상은 토지피복 등의 유역 수문환경 특성을 광범위하고 효과적으로 취득할 수 있으므로 최근 모니터링 자료를 얻기 위해 많이 사용되고 있다. 영상처리분야에서의 신경망 모형은 과거의 통계적인 방법에 비해 더 나은 분류정확도를 보이는 것으로 보고되고 있다.

이 분야의 국내 연구로서 임태훈 등(1996)은 역전파 신경회로망과 최대우도법에 의해 위성영상의 토지피복을 분류하고 비교하였으며, 꽈장호 등(1999)은 역전파 신경망을 이용한 분류 네트워크를 구성하고, 그 결과를 평가하는 등 위성영상의 처리에 다각적으로 응용되고 있다.

국외의 경우, Bischof(1992)는 다층 신경망이론, 역전파알고리즘과 Gaussian 최대우도법을 이용한 Landsat TM 영상을 분류하고 그 결과를 비교한 바 있고, Horst 등(1998)은 신경망 모형을 이용하여 다분광 Landsat 영상 분류 문제에 관한 방법을 제시하였으며, Weiyang Zhou(1999)는 역전파 신경망을 이용하여 위성 영상을 분류하고 비매개변수적 특징을 검정하였다. 이상과 같이 위성영상의 분류 향상을 위한 신경망 모형의 응용(Jon et al., 1990 ; Philip et al., 1992 ; Tomoji Yoshida et al., 1994 ; Sebastiano et al., 1995 ; Sucharita Gopal et al., 1996 ; Kumar et al., 1997 ; Zhou, 1999 ; Bruzzone et al., 1999 ; Maria et al., 2000)이 활발히 진행되고 있으며, 과거의 전통적인 방법에 비해 우수한 결과를 보이는 것으로 보고되고 있다.

5. 맷 는 말

본고에서는 인공신경망의 태동에서부터 현재까지의 발전과정을 기술하였고, 신경망 이론의 기본 개념, 종류 및 특징을 소개하였으며, 신경망의 기본적인 연산과정과 가장 널리 이

용되고 있는 학습방법을 정리하였다. 또한, 수자원 및 영상처리 분야에서의 연구사례를 중심으로 적용 예를 정리하였다.

신경망 모형을 이용한 수자원 및 영상처리 분야에서의 이용은 신경망 해석을 위한 상용 프로그램의 개발로 인하여 활발한 연구가 진행되고 있는 실정이다(Sigmon, 1989 ; Demuth and Beal, 1998). 따라서, 신경망모형을 이용한 실시간 유출해석, 장기간 하상 변동 해석, 댐의 최적 운영률 산정, 수공구조물의 신뢰도 평가 등 광범위한 수문, 수리 및 수자원 문제 해결을 위한 지속적인 연구가 이루어져야 할 것이다.

선진국에서는 21세기를 ‘뇌의 세기’라고 부른다. 어쩌면 인류의 마지막 미개척 분야인 뇌의 연구를 수행하는 것은 당연하다고 볼 수 있다. 의학, 수학 분야에서의 뇌에 대한 연구가 완성되어질 때, 이를 공학 분야에 이용한다면 수자원 분야에서도 획기적인 발전을 이루게 될 것이다.

참고문헌

- 의 수문학적 예측에 관한 연구, 인하대학교 박사학위논문.
- 신현석, 1998. 인공신경망의 수자원 및 환경 분야에의 응용, 한국수자원학회지, 제31권 제1호, pp.97~103.
 - 신현석, 박무종, 1999. 신경망 기법을 이용한 연평균 강우량의 공간 해석, 한국수자원학회지논문집, 제32권 제1호, pp.3~13.
 - 신현석, 박무종, 1999. 신경망을 이용한 우리나라의 시공간적 가뭄의 해석, 수자원학회지논문집, 제32권 제1호, pp.15~29.
 - 심순보, 김만식, 심규철, 1998. 신경망이론에 의한 다목적 저수지의 홍수유입량 예측, 한국수자원학회논문집, 제31권 제1호, pp.45~57.
 - 안경수, 김주환, 1998. 신경회로망을 이용한 유출수문곡선 모의에 관한 연구, 수자원학회지논문집, 제31권 제1호, pp.13~25.
 - 안상진, 전계원, 김광일, 2000. 신경망 알고리즘을 적용한 유출수문곡선의 예측, 한국수자원학회논문집, 33(4), pp.505~515.
 - 오남선, 1996. 신경망이론과 Kalman Filter 강우예측모형의 비교연구, 박사학위논문, 서울대학교.
 - 오남선, 선우중호, 1996. 신경망이론에 의한 강우-예측에 관한 연구, 한국수자원학회지, 제29권, 제4호, pp.109~118.
 - 윤여창, 1995. 시계열자료에서 신경망이론의 적용, 성균관대학교 박사학위논문.
 - 이관수외 3인, 2000. 역전파 학습 알고리즘과 적응식 학습율을 적용한 강우-유출 모형에 관한 연구, 전남대학교 공업기술연수지.
 - 전계원, 2000. 신경망 알고리즘을 적용한 유출수문곡선의 예측, 충북대학교 석사학위논문.
 - 정재성, 1996. 실시간 기상자료와 신경망이론에 의한 다지점 강우예측 모형 연구, 전북대학교 박사학위논문.
 - 진영훈, 2000. 하천의 유출량 예측을 위한 인공

- 신경망 이론의 적용, 전남대학교 석사학위논문.
19. Anthony, W. M., 1996. Extended rainfall-runoff modeling using artificial neural networks, Proc. of the 2nd International Conf. on Hydroinformatics, '96, Zurich, Switzerland, pp.207~213.
 20. Bing J. Shen and Joongho Choi, 1995. Neural Information Processing and VLSI, Kluwer Academic Publishers.
 21. Bonofe, A., Galeati, G., and Sforza, M., 1994. Neural networks for daily mean flow forecasting, in Hydraulic Engineering Software V, Vol. 1, edited by W. R. Blain and K. L. Katsifarakis, Water Resources and Distribution, Computational Mechanics Publication, Southampton, UK, pp.131~138.
 22. Broomhead, D. S., and Lowe, D., 1988. Multivariable functional interpolation and adaptive network, Complex Systems, 2, pp. 321~355.
 23. Carpenter, W. C., and Barthelemy, J. F., 1994. Common misconceptions about ANN as approximators, Jour. computing in Civil Eng., ASAE, 8(3), pp.354~358.
 24. Dawson, C. W., and Wilby, R. 1998. An artificial neural network approach to rainfall-runoff modeling, Hydrological Sciences, 43(1), pp.47~66.
 25. Demuth, H., and Beale, M. 1998. Neural network toolbox : for use with MATLAB user's guide, The Math Works Inc.
 26. Flood, I. and Kartam, N., 1994. Neural networks in civil engineering I : Principles and understanding, Journal of Computing in Civil Engineering, ASCE, 8(2), pp.131~148.
 27. Flood, I. and Kartam, N., 1994. Neural networks in civil engineering II: System and application, Journal of Computing in Civil Engineering, ASCE, 8(2), pp.149~162.
 28. Freeman, J. A., and Skapure, D. M., 1991. Neural networks algorithms, applications and programming technology, Addison-Wesley Publishing Co., Reading, MA.
 29. French, M. N., Andrieu, H., and Krajewski, W. F., 1992. Rainfall forecasting in space and time using a neural network, Journal of Hydrology, 31(10), pp.1~31.
 30. Fu, LiMin, 1994. Neural Networks in Computer Intelligence, McGraw-Hill, Inc.
 31. Grubert, J. P., 1995. Application of neural networks in stratified flow stability analysis, Journal of Hydraulic Engineering, ASCE, 121(7), pp.523~532.
 32. Haykin, S., 1999. Neural Networks : A Comprehensive Foundation Second Edition, Prentice Hall, pp.1~317.
 33. Hsu, K., Gupta, H. V., and Soroosian, S., 1995. Artificial neural networks modeling of rainfall-runoff process, Water Resources Research, 31(10), pp.2517~2106.
 34. Hush, 1993. Progress in supervised neural network, IEEE Signal Processing Magazine, pp.8~38.
 35. Isobe, I., Ohkado, T., Hanyuda, H., Oda, S., and Gotoh, Y., 1994. The development of a forecasting system of the water levels of rivers by neural networks, Journal of Japan Society of Hydro. and Water Resources, 7(2), pp.90~97.
 36. Jang, J.S., Sun, C.T., and Mizutani, E., 1997. Neuro-fuzzy and soft computing, Prentice Hall, pp.129~331.
 37. Kao, J.-J., 1996. Neural net for determining DEM-based model drainage pattern, Journal

- of Irrigation and Drainage Engineering, ASCE, 122(2), pp.112~121.
38. Karunaithi, N., Whitley, D., and Malaiya, Y. K., 1992b. Using neural networks in reliability prediction, IEEE Software, 9(4), pp. 53~59.
39. Karunanithi, N., Grenney, W. J., Whitley, D., and Bovee, K., 1994. Neural Networks for river flow prediction, J. of Computing in Civ. Engrg., ASCE, 8(2), pp.201~220.
40. Lachtermacher, G., 1994. Back Propagation in hydrological time series forecasting, Stochastic and Statistical Methods in Hydrology and Environmental Engineering, Vol. 3, Kluwer Academic Publishers, pp.229~242.
41. Mamone, Richard J., 1994. Artificial Neural Networks for Speech and Vision, Chapman & Hall.
42. Markus, M., Shin H. S., and Sala J. D., 1995. Predicting streamflows based on neural networks, 1995 First International Conference on Water Resources Engineering, ASCE, San Antonio, TS.
43. Mase, H., Sakamoto, M., and Sakai, T., 1995. Neural network for stability analysis of rubble-mound breakwaters, Journal of Waterway, Port, Coastal, and Ocean Engineering, ASCE, 121(6), pp.294~299.
44. Mason, J.C., Price, R.K., and TEM'ME, A., 1996. A neural network model of rainfall-runoff using radial basis functions, Journal of Hydraulic Research, 34(4), pp.537 ~548.
45. Mehra, Pankaj and Benjamin W. Wah., 1992. Artificial Neural Networks : Concepts and Theory, IEEE Computer Society Press, Los Alamitos, California.
46. Minns, A. W., and Hall, M. J., 1996. Artificial neural network as rainfall runoff models, Journal of Hydraulic Research, 34(4), pp.537 ~548.
47. Minoru, M., Takashi, T., and Kazuo, M., 1995. Water demand prediction by memory based learning, IWSA Specialized Conf. on Advanced Treatment and Integrated Water System Management into 21st Century, Osaka, Japan, Vol. 1, pp.316~317.
48. Moody, J., and Darken, C. J., 1989. Fast learning in networks of locally-tuned processing units, Neural Computation, Vol. 1, pp.281~294.
49. Raman, H., and Sunikumar, N., 1995. Modeling water resources time series using artificial neural networks, Hydro. Science, 40(2), pp.145~162.
50. Rashid, A., Aziz A., and Wong, K. F., 1992. A neural network approach to the determination of aquifer parameters, Ground Water, 30(2), pp.164~166.
51. Rogers, L. L., and Dowla, F. U., 1994. Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling, Water Resources Research, 30(2), pp.4578~4581.
52. Roman, H. and Chandramouli, V., 1996. Deriving a general operating policy for reservoirs using neural network, J. of Water Resour. Plng. and Mgmt., ASCE, 122(5), pp.342~347.
53. Rosenblatt, F., 1958. The Perceptron : A theory of statistical separability in cognitive system, Report No. VG-1196-1, Cornell Aeronautic Lab., Inc., Buffalo.
54. Rumelhart, D. E., Hinton, G. E., and Williams,

- R. J., 1986. Learning internal representations by error back propagation, Parallel distributed processing, Edited by Rumelhart, D. E., McClelland, J. L. and PDP Research Group, Chapter 8, Cambridge, MA, MIT Press.
55. Sajikumar, N. and Thandaveswara, B. S., 1999. A nonlinear rainfall-runoff model using ANN, Journal of Hydrology, Vol.216, pp.32~55.
56. Sanchez, L., Arroyo, V., Garcia, J., Koev, K., and Revilla, J., 1998. Use of neural networks of coastal sewage systems, Journal of Hydraulic Engineering, ASCE, 124(5), pp.457~464.
57. Skapura, David M., 1996. Building Neural Networks, ACM Press.
58. Smith, J., and Eli, R. N., 1995. Neural network models of rainfall-runoff process, J. of Water Resour. Plng. and Mgmt., ASCE, 121(6), pp.499~508.
59. Sureerattanar, S. and Phien, H. N., 1997. Back-propagation networks for daily stream flow forecasting, Water Resources Journal No.195, pp.1~7.
60. Tawfik, M., Ibrahim, A., and Fahmy, H., 1997. Hysteresis sensitive neural network for modeling rating curves, J. of Computing in Civ. Engrg., ASCE, 11(3), pp.206~211.
61. Thirumalaiah, K., and Deo, M. C., 1998. River stage forecasting using artificial neural networks, Journal of Hydrologic Engineering, ASCE, 3(1), pp.26~32.
62. Tokar, A.S., and Johnson, P. A., 1999. Rainfall-runoff modeling using artificial neural networks, Journal of Hydrologic Engineering, ASCE, 4(3), pp.232~239.
63. Vaziri, M., 1997. Predicting Caspian sea surface water level by ANN and ARIMA models, Journal of Waterway, Port, Coastal, and Ocean Engineering, ASCE, 123(4), pp. 158~162.
64. Vemuri, V. R., 1992. Artificial Neural Network : Concepts and Control Applications, IEEE Computer Society Press, Los Alamitos, California.
65. Yang, C.-C., Prasher, S. O., Lacroix, R., Sreekanth, S., Patni, N. K., and Masse, L., 1997. Artificial neural network model for subsurface-drained farmlands, Journal of Irrigation and Drainage Engineering, ASCE, 123(4), pp.285~292.
66. Zealand, C. M., Burn, D. H., and Simonovic, S. P., 1999. Short term stream flow forecasting using ANN, Journal of Hydrology, Vol.214, pp.32~48.
67. Zhang, S. P., at al., 1994. Prediction of daily water demands by neural networks, Stochastic and Statistical Methods in Hydrology and Environmental Engineering, Vol.3, Kluwer Academic Publishers, pp.217~227.