

# Soft computing 기법을 활용한 유량예측



김 태 순 |  
 세종대학교 전임연구교수  
 chaucer@sejong.ac.kr

하고, 결과값을 얻기까지의 계산시간 역시 많이 소요되지 않는 장점을 가지고 있다. 본 고에서는 이와 같은 soft computing 기법들 중에서 주로 하천유량의 예측을 위해서 사용되는 기법을 중심으로 살펴보았으며, 현재 국내의 하천유량예측을 위해서 가장 합리적으로 사용될 수 있는 soft computing 기법을 도출하고자 노력하였다.

## 1. 개요

Soft computing이란 기존에 개발된 hard computing에 대응되는 개념으로써, 인간이 생각하는 것과 같이 부정확하고(imprecision) 불확실하며(uncertainty) 부분적으로 참(partial truth)이면서 동시에 유사성(approximation)을 가지고 있는 문제 풀이 기법을 활용하는 컴퓨터 인공지능 분야이다. Soft computing의 근간을 이루는 기본적인 이론들의 개발은 Lofti Zadeh에 의해서 주로 이루어졌으며(Zadeh 1965; Zadeh 1973; Zadeh 1979), 초기에는 주로 퍼지집합이론(fuzzy set theory)을 중심으로 발전되다가 이후에 인공신경망(artificial neural network)이나 유전자알고리즘(genetic algorithm)과 같은 분야가 추가되었다.

Soft computing의 범주안에 드는 많은 기법들은 최근에는 data driven model이라는 이름으로도 불리우고 있으며 이런 모형들은 기존의 모형과 비교해서 물리적인 성질이 완전히 밝혀지지 않은 비선형(nonlinear)이거나 동적(dynamic)인 모형의 잡음자료(noisy data)를 처리하는데 용이하며, 모형을 구축하는데 있어서 복잡한 수학적 지식이 필요하지 않기 때문에 상대적으로 모형구성을 위한 절차가 간단

## 2. 인공신경망(artificial neural network)

현재 유량예측을 위해서 가장 활발히 사용되고 있는 soft computing 분야는 인공신경망을 활용한 분야라고 할 수 있다. 일반적으로 사용되는 유출모형인 개념적 모형(conceptual model)이나 물리적 모형(physically-based model)은 유역의 전체적인 수문학적 현상을 재현한다는 점에서 중요한 분야이지만, 유역내에 위치한 특정지점의 유량을 예측하기 위해서는 입력자료와 출력자료 사이의 물리적인 현상을 모의하지 않고 바로 두 자료간의 관계를 이용해서 출력값을 구해내는 black box모형이 좋은 대안이 될 수 있으며, 이런 점에서 입-출력자료간의 비선형적인 관계를 찾아내는데 있어서 효율적이라고 알려진 인공신경망 이론이 널리 사용되고 있다(Dibike and Solomatine 2001).

인공신경망중에서 널리 사용되는 다층인공신경망(multi-layer artificial neural network)은 기본적으로 그림 1과 같이 입력층, 은닉층, 그리고 출력층으로 이루어진다. 각 층(layer)은 연결강도 혹은 가중치(weight)를 이용해서 연결되어 있으며, 입력층과 출력층간의 가중치를 계산하기 위해서는 그림 2와 같

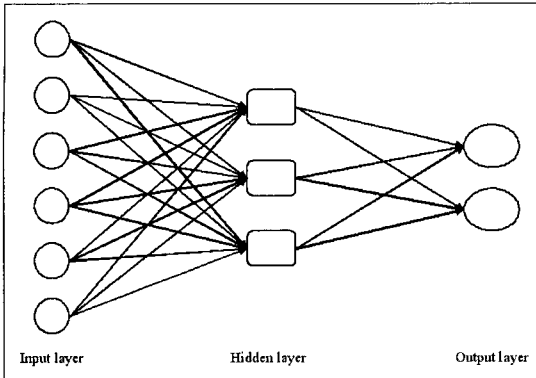


그림 1. 입력층 6개, 은닉층 3개, 출력층 2개로 구성된 다층인공신경망(multi-layer artificial neural network)

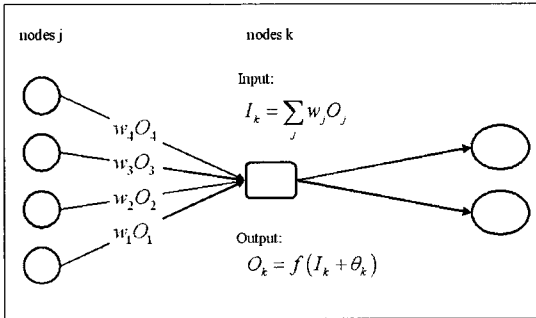


그림 2. 절점 j와 k를 연결하는 연결강도 혹은 가중치의 역할과 총별 출력값의 계산




그림 3. 입력층과 출력층간의 변환에 사용되는 Sigmoid 함수

은 과정을 거친다. 즉, 각각의 입력자료와 가중치를 이용해서 계산된 값을 변환함수(transformation function)를 이용해서 출력값으로 변환하고 다시 다음층의 입력값으로 이 값을 이용하여 출력값을 얻어 내는 형태로 구성되어 있다. 이때 사용되는 변환함수

로서 많이 사용되는 함수는 sigmoid 함수이며 그림 3에 기본적인 형태를 나타내었다.

유량예측을 위해서 사용된 초기의 인공신경망 이론은 주로 기존 방법들과의 비교를 통해서 인공신경망이 유량예측에 사용될 수 있음을 보여주는데 주력하고 있다. 이 경우에 사용된 예측시간의 단위는 15분부터 1달간의 장기간에 걸쳐서 사용되고 있으며, 인공신경망의 결과와 비교하기 위해서 사용한 모형도 단순한 지수형태의 모형(power model)부터(Karunanithi et al. 1994), SAC-SMA(Sacramento soil moisture accounting)모형까지(Tokar and Markus 2000) 다양하게 사용되고 있다. 인공신경망과 관련된 연구들을 사용한 자료기간별로 정리하면, 월간자료(Anmala et al. 2000; Tokar and Markus 2000), 일간자료(Hsu et al. 1995; Karunanithi et al. 1994; Liong et al. 2000; Minns and Hall 1996; Tokar and Markus 2000), 그리고 시간자료(Dawson and Wilby 1998; Fernando and Jayawardena 1998; Wu et al. 2005)를 사용한 경우로 나눌 수 있다.

이중에서 Tokar and Markus(2000)는 일간모형과 월간모형을 인공신경망을 이용해서 구축한 후에 그 결과를 기존의 유출모형과 비교하였는데 사용된 자료기간은 1951년~1983년, 1987년~1993년 사이에 관측된 자료이고, 월간모형의 경우 현재 월의 유량을 예측하기 위해서 이전 달의 관측유량, 강우량, 적설물당량(snow-water equivalent), 그리고 기온을 이용하였고, 일간모형의 경우 최대 4일 선행강우량과 기온 그리고 관측유량값을 이용하여 현재의 유량을 예측하였다. 인공신경망으로부터 구한 유량값을 비교하기 위한 모형으로는 월간모형의 경우 Watbal 모형(Leaf and Brink 1973; Leaf and Brink 1975)을 이용하였고, 일간모형은 SAC-SMA 모형(Burnash et al. 1973)을 이용하였다.

Wu et al.(2005)은 예측시간(lead time)을 1시간보다 단기간인 15분 단위로 적용하여서 인공신경망을 구축하였으며, 모형의 입력자료로 사용된 강우자

료와 유량자료는 모두 3개의 관측지점에서 관측되었고 사용한 자료기간은 1998년 9월~2001년 12월이다. 인공신경망 모형은 모두 두 가지를 구성하였는데 계측지점(gauged station)의 유량을 현재시간부터 15분 간격으로 1시간까지 예측하는 모형(ANN-WRP)과 관측지점에서 발생한 침투유량이 하류의 임의지점에 도달할 때의 유량을 예측하는 모형(ANN-SFF)을 구축하여서 실제관측유량과의 차이를 비교하였다. Dawson and Wilby(1998) 역시 15분 간격의 강우량 및 유량 자료를 이용하여서 유량을 예측하였다. 이 연구에서는 강우량 및 유량 자료간의 상관성을 분석하여서 모형에 적용할 변수들의 지체시간(lag time)을 결정하였으며 유량예측은 6시간 선행시간을 가지는 값을 예측하였다. 위에 언급한 두 가지 논문은 모두 사용한 자료기간이 비교적 단기간인 것이 특징이며, 특히 Dawson and Wilby(1998)는 현재 해당구역에서 사용하고 있는 홍수정보모형인 FFS(Severn-Trent Environment Agency's flood forecasting system)의 결과와 비교하여서 인공신경망의 효용성을 검토하였다.

인공신경망을 이용한 유량예측기법은 기존의 방법들에 비해서 효율성이나 해를 구하는데 걸리는 시간 측면에서 더 뛰어난 모습을 보여주고 있지만, 반대로 인공신경망이 가지고 있는 한계점들 역시 뚜렷하게 보여주고 있다. 예를 들어 비교적 예측기간이 단기간인 경우에 인공신경망을 적용하는 경우에 대해서, 최근에 Han et al.(2007)은 인공신경망을 이용해서 예측한 유량값이 선형 transfer function(TF) 모형보다 정확도가 크게 떨어진다는 것을 보였다. 이 연구에서는 6시간 간격으로 예측을 수행했을 때 예측시간이 5단계인 30시간까지의 예측결과가 선형 TF 모형보다 RMSE(root mean squared error) 값에서 훨씬 더 좋지 않은 값을 보인다고 언급하고 있으며, 장기간의 예측을 시행하는데 있어서도 인공신경망이 학습집합(training set)에 따라서 유량예측의 정확도가 가지는 불확실성이 매우 높다고 언급하고 있다.

이와 같은 인공신경망의 문제는 최근의 문헌조사

결과를 통해서도 확인할 수 있으며(Govindaraju and Rao 2000; Maier and Dandy 2000), 특히 ASCE Task Committee on Application of Artificial Neural Networks in Hydrology(ASCE Task Committee on Application of Artificial Neural Networks in Hydrology 2000)는 인공신경망을 수문학 분야에 적용하는데 있어서 발생할 수 있는 문제점들을 언급한 후, 향후 인공신경망을 이용한 수문학 분야의 연구에서 수행되어야 할 분야로 다음의 5가지 사항을 언급하고 있다.

1. 인공신경망이 주어진 문제의 물리적인 현상을 설명하도록 할 수 있는가? (Can ANNs be made to reveal any physics?): 주어진 문제에 인공신경망을 적용해서 해를 얻어낼 때, 대부분의 경우 어떤 절차(basic process)를 거쳐서 주어진 문제의 해가 구해지는가를 체계적으로 설명하지 못한다. 물리적인 모형의 경우 해당 모형의 한 부분이 주어진 물리적인 현상의 특정 부분을 설명하도록 함으로써 해를 구하는 절차를 보여줄 수 있지만, 인공신경망을 적용하는 경우 이런 설명이 불가능한 경우가 대부분이다. 더군다나, 인공신경망을 연구하는 다른 분야 중에서는 이미 지식기반 인공신경망(knowledge-based ANNs)이나 규칙추출법(rule extraction technique) 등을 이용한 다양한 시도가 이루어지고 있지만, 수문학과 관련해서는 이런 시도가 매우 미미한 실정이다.
2. 최적학습집합을 구성하는 것이 가능한가? (Can an optimal training set be identified?): 인공신경망을 학습시키기 위한 최적학습집합(optimal training set)은 모형이 가질 수 있는 영역(model domain)을 모두 포함하면서 동시에 가장 최소한의 자료를 가지고 있는 집합을 의미한다. 또한, 이런 최적학습집합은 학습을 끝낸 인공신경망이 실제로 예측(prediction)을 수행할 때도 잘 동작할 수 있도록 만들어야만

한다. 최적학습집합과 함께 인공신경망을 학습시킬 때 어떤 학습자료가 들어가면 인공신경망이 발산(fail)하는지를 아는 것도 중요하다. 이를 위해서는 주어진 문제와 관련된 변수들의 변화범위를 아는 것이 중요하며, 이는 앞서 말한 물리적인 의미를 가지는 인공신경망을 만드는 것과 밀접하게 관련되어 있다.

3. 인공신경망은 시계열모형을 향상시킬 수 있을까? (Can ANNs improve on time series analysis?) : 인공신경망이 과거 관측치로부터 미래의 유량이나 수위를 예측할 때 쓰이는 경우, 그 결과를 비교하기 위해서 시계열모형이 사용되고 있으며 그 결과의 정확도나 효용성 또한 높은 것으로 나타나고 있다. 하지만, 이런 결과 비교를 위한 목적외에 인공신경망과 시계열모형간의 상호보완적인 관계를 직접 연구한 사례는 매우 드물다. 만약 자료가 가지는 기억구조(memory structure)를 모형화하는 시계열모형의 특징을 인공신경망의 학습구조에 도입한다면, 네트워크 학습과정에 시간종속성을 도입하는 연구가 될 수 있다.
4. 인공신경망을 adaptive로 학습시킬 수 있는가? (Can training of ANNs be made adaptive?) : 인공신경망을 학습시키는 것은 매우 중요한 절차이며, 인공신경망을 활용한 결과에도 큰 영향을 미치는 것으로 알려져 있다. 일반적으로 이런 학습을 위해서는 많은 시간이 필요하며, 이런 일련의 학습과정은 새로운 자료가 추가되면 전체 과정을 모두 다시 수행해야 하는 단점을 가지고 있다. 만약 네트워크를 구성하는 각각의 층(layer)간의 가중치(weight value)와 임계값(threshold value)이 물리적인 혹은 통계적인 해석이 가능한 식의 형태로 만들어진다면 기존의 자료를 이용해서 다시 전체 네트워크를 학습시키는 시간을 소모할 필요 없이 새로 추가된 정보만을 이용해서 adaptive로 학습시키는 것이 가능해질 것이다.

5. 인공신경망을 이용한 효과적인 외삽법(extrapolation)이 가능한가? (Are ANNs good extrapolators?) : 인공신경망은 기본적으로 학습집합과 유사한 자료에 대해서 좋은 결과를 보여주고, 학습집합과 전혀 다른 자료를 입력자료로 사용하는 경우에는 그 결과값이 좋지 못한 것으로 알려져 있다. 즉, 원래 자료외의 자료에 대한 값을 구하는 외삽법의 경우 인공신경망을 적용하는 것이 효율적이지 못한 것이다. 원래의 학습집합과 다른 자료에 대해서 결과값을 얻는 외삽법의 문제도 결국은 최적학습집합을 어떻게 구성할 것인가라는 문제로 귀결된다. 학습집합이 '모든 가능한' 집합을 효과적으로 대표할 수 있다면, 이런 학습집합을 이용해서 학습시킨 인공신경망을 기존의 자료가 아닌 외삽된 자료(실제로는 최적학습집합내에 존재하는 자료이다)에 대해서도 좋은 결과를 보여줄 것이다.

현재까지는 위에 언급한 5가지 연구과제들 중 주로 학습집합을 보다 효율적으로 구성하는 방법과 관련한 연구가 진행되어 왔으며, 기존의 인공신경망과 관련된 연구에서는 주로 상관계수(correlation coefficient)를 사용해서 입력자료간의 상관성을 분석한 후 출력자료와 가장 큰 상관계수를 가지는 입력 자료들을 선택하는 비교적 간단한 필터링(filtering) 방법을 사용했지만, 최근에는 상관계수뿐만 아니라 좀더 다양한 통계량을 이용해서 입력자료를 선택한 후 학습집합을 구성하는 연구가 진행되고 있다.

Stokelj et al.(2002)은 기존에 개발한 6시간의 선행시간을 가지는 유량예측모형을 2일까지 예측이 가능하도록 개선하였다. 여기서 사용한 자료는 3개소의 우량국, 2개소의 유량국, 그리고 1개소의 유입량 관측지점의 자료들이고 추가적으로 48시간 예측시간을 가지는 기상예측자료가 사용되었다. 사용한 모형은 크게 두 가지 형태로 구성하였는데, 첫 번째는 현재 유역내에 존재하는 우량국에서 들어오는 자료를 활용하여 예측하는 초단기예측모형(very-short-term

module)이고, 또 다른 하나는 기상예측자료를 활용하는 단기예측모형(short-term module)이다. 초단기예측모형은 선행시간이 2시간 간격으로 8시간까지이고, 단기예측모형은 3시간 간격으로 향후 45시간까지의 유량을 예측하는 형태로 구성하였다.

여기서 입력자료를 필터링하기 위해서 사용한 통계량은 평균상호정보량(average mutual information; AMI)으로 가용한 자료에 따라서 표현되는 출력자료의 불확실성(uncertainty)을 측정하는 다음의 엔트로피  $H(Y)$ 를 이용해서 정의된다.

$$H(Y) = -\sum_{y \in I} p(y) \log p(y) \quad (1)$$

주어진 입력변수의 부분집합  $\mathbf{X}_i$ 가 주어졌을 때의 평균불확실성은 다음의 조건부 엔트로피로 계산된다.

$$H(Y | \mathbf{X}_i) = -\sum_{\mathbf{x}_i \in \mathbf{X}_i} \sum_{y \in I} p(y, \mathbf{x}_i) \log_2 p(y | \mathbf{x}_i) \quad (2)$$

위의 두 식으로부터 평균상호정보량은  $I(Y; \mathbf{X}_i)$  다음과 같이 정의된다.

$$I(Y; \mathbf{X}_i) = H(Y) - H(Y | \mathbf{X}_i) \\ I(Y; \mathbf{X}_i) = -\sum_{y \in I} p(y) \log p(y) + \sum_{\mathbf{x}_i \in \mathbf{X}_i} \sum_{y \in I} p(y, \mathbf{x}_i) \log p(y | \mathbf{x}_i) \quad (3)$$

따라서, 평균상호정보량은 사용된 입력변수의 부분집합이 출력과 관련된 불확실성을 얼마나 감소시키는지를 나타내는 통계량이 된다. Stokelj et al. (2002)은 평균상호정보량을 이용해서 초단기예측모형에서는 주어진 30개의 입력자료 중에 유량예측을 위해서 구성한 인공신경망의 출력치에 가장 효과적인 정보를 제공하는 15개의 입력변수를 선택하였으며, 단기예측모형에서는 모두 11개의 입력자료를 선택하여서 인공신경망의 입력자료로 사용하였다.

인공신경망을 위한 학습집합을 효과적으로 구성하기 위한 보다 최근의 연구는 Chandramouli et al. (2007)의 연구가 있다. 여기서는 앞선 Stokelj et al. (2002)의 연구에서처럼 입력변수를 선택하는 방법보다는 주어진 학습집합을 과연 몇 회나 반복해서

수행하는 것이 최적의 학습효과를 가져오는데 주목하고 있다. 이것은 학습집합을 이용한 인공신경망의 학습효과가 주어진 출력값에 과다학습(overfitting)되거나 과소학습(underfitting)되는 가능성을 최소화하기 위한 것으로, 다음의 상대강도지수(relative strength index; RSI)를 이용하여서 계산한다. 주어진 집합  $S = \{m_1, m_2, m_3, \dots, m_j, \dots, m_r\}$  이고, 여기서,  $m_j = \{X, Y\}$ 이며 각각의  $X$ 와  $Y$ 는  $X = \{x_1, x_2, x_3, \dots, x_p\}$ ,  $Y = \{y_1, y_2, y_3, \dots, y_p\}$  이라고 한다면 다음의 식으로 RSI를 정의할 수 있다.

$$RSI_{ik} = \sum_{j=1}^r \left[ \frac{\exp^{-\eta}}{(1 + \exp^{-\eta})^2} \right] \sum_{j=1}^r w_{jk} \left[ \frac{\exp^{-\zeta}}{(1 + \exp^{-\zeta})^2} \right] \frac{1}{C} \quad (4)$$

여기서,  $RSI_{ki}$ 는  $i$  번째 입력과 출력층의  $k$  번째 뉴런에 대한 RSI이고,  $C$ 는 표준화상수이다. 위의 식을 이용하면  $k$  번째 변수에 대한 RSI는 다음의 식으로 표현된다.

$$RSI_k = \frac{1}{r} \sum_{i=1}^r RSI_{ki} \quad (5)$$

여기서,  $r$ 은 학습을 위해서 사용된 자료의 개수이다. 학습집합을 몇 회나 반복해서 학습시켜야 하는지는, 입력자료로 임의의 가상변수(dummy variable)를 포함시켜서 인공신경망을 학습시킨 후에 전체 학습기간에 대한 가상변수의 RSI값을 도출해서, 이렇게 구한 RSI가 초기의 진동현상을 끝낸 후 다시 0에 근접해갈 때를 최적의 학습회수로 결정하였다. 이와 같은 방법으로 학습시킨 인공신경망을 이용해서 구한 결과값과 이보다 많거나 적은 회수까지 학습시킨 인공신경망을 이용한 결과값을 평균제곱오차(mean squared error)와 상관계수를 통해서 서로 비교한 결과 상관계수는 충분히 크면서 평균제곱오차가 가장 최소가 되는 반복회수를 찾아낼 수 있는 것으로 나타났다.

유량예측을 위한 인공신경망의 입력자료를 구성하는데 있어서 기존의 연구들은 주로 강우나 기온 등의 자료와 함께 과거 유출량 자료를 사용한 반면에 최근

에는 과거에 발생한 유출량 자료만을 이용해서 유량을 예측하려는 연구도 보고되고 있다(Pulido-Calvo and Portela 2007; Wang et al. 2006). 이 중에서 Pulido-Calvo and Portela(2007)는 포르투갈에 위치한 유역의 유량을 예측하는데 인공신경망을 적용하였는데 이 연구는 기존의 연구와 비교해서 1) 적용한 유역의 유역면적이 1685km<sup>2</sup>와 3718km<sup>2</sup>에 달하는 대유역이고 2) 사용한 입력자료가 강우나 기온 등의 자료는 사용하지 않은 일유량 자료라는 점에서 차이가 있다고 할 수 있다. 특히, 이 연구에서는 인공신경망을 임의의 유역에 대해서 학습시킨 후에 연평균유량깊이(mean annual flow depth) 값이 유사한 다른 유역의 유출량을 예측하는데 있어서 학습 없이 기존의 인공신경망을 그대로 적용한 결과도 보여주고 있는데, 상관계수나 평균제곱근오차 값에서 모두 만족할 만한 결과를 보여주는 것으로 나타났다.

과거의 유량자료를 이용해서 미래의 유량을 예측하는 것은 기존의 시계열모형(time series modeling)에서 미래의 자료를 예측하는 것과 기본적으로 동일한 것이라고 할 수 있다. 앞서 인공신경망을 이용해서 향후 연구되어야 할 분야중의 하나로, 인공신경망을 이용해서 시계열모형을 어떤 식으로 발전시킬 수 있을지에 관한 분야가 언급되었던 것처럼, 다양한 형태로 인공신경망을 시계열모형과 결합하려는 연구가 시도되고 있다. 하지만 이런 연구들도 기존의 시계열모형의 매개변수를 추정하는데 인공신경망을 이용하거나(Chon and Cohen 1997), 시계열모형에 사용되는 자료의 주기성(seasonality)이나 경향성(trend)를 제거해서 인공신경망을 적용하는(Ashu and Avadhnam Madhav 2007) 정도의 연구가 진행되고 있을 뿐, 앞서 언급한 것과 같이 인공신경망의 주요한 특징중의 하나인 입-출력자료간의 비선형성을 추출하는 특성을 충분히 활용한 연구결과는 아직 보고되어 있지 못하다고 할 수 있다.

인공신경망이 최적학습집합을 어떻게 구성하느냐에 따라서 전체적인 효율성이 결정되는 것과 함께 앞서 Chandramouli et al.(2007)의 연구결과에서도

언급한 것과 같이, 주어진 학습집합을 이용해서 과연 어느 정도까지 반복회수를 증가시켜야 과다학습(overfitting)이나 과소학습(underfitting)이 이루어지지 않은 최적의 인공신경망을 구성할 수 있는지 역시 주요한 연구분야중의 하나라고 할 수 있다. 이와 관련해서는 매개변수의 선행확률분포함수(prior probability distribution function)를 알고 있는 상태에서 주어진 관측치로부터 후행확률분포함수(posterior probability distribution function)를 구하는 베이즈정리(Bayes' theorem)에 기초한 인공신경망을 구성하는 것이 좋은 대안이 될 수 있을 것이다(Khan and Coulibaly 2006).

### 3. 퍼지추론시스템 (fuzzy inference system)

인공신경망을 이용한 유량예측이 활발히 진행되고 있는 것과는 다르게, soft computing의 또 다른 한 분야를 이루고 있는 퍼지추론시스템을 이용한 유량예측연구결과는 상대적으로 적다. 이 분야는 기존의 퍼지집합이론(fuzzy set theory)이나 퍼지규칙(fuzzy-rule)을 이용한 기법들과 함께 neuro-fuzzy라는 비교적 새로운 기법이 많이 사용되고 있다. Neuro-fuzzy는 퍼지논리(fuzzy logic) 시스템과 인공신경망이론이 가지고 있는 장점을 결합하여, 퍼지논리로는 주어진 자료에 대한 정보를 논리적인 방법으로 표현하고 인공신경망으로는 학습이론을 이용하여 해당 매개변수를 최적화하는 형태로 구성되어 있다. Neuro-fuzzy를 이용한 기법은 기존의 방법에 비해서 모형구성에 필요한 차원(dimension)이 상대적으로 작고 주어진 문제와 관련해서 매개변수의 초기값을 정할 수 있다는 장점 때문에 학습시간이 비교적 단시간에 이루어지는 장점이 있으며, 특히 Jang(1993)에 의해서 개발된 ANFIS(adaptive neuro-fuzzy inference system)가 많이 적용되고 있다.

ANFIS는 그림 4와 같이 5개의 층으로 구성되어

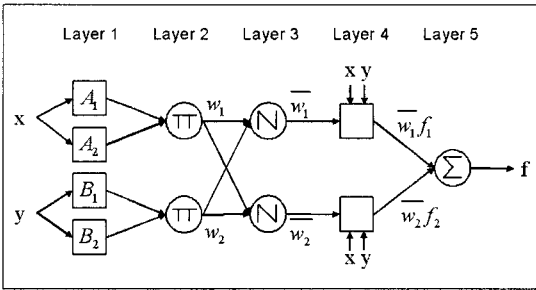


그림 4. ANFIS의 구조도

있다. Layer 1에서는 멤버십함수(membership function)의 매개변수들이 결정되는 입력노드로서 외부의 입력을 다음 층으로 그대로 전달한다. Layer 2는 규칙을 생성하며 생성된 규칙의 충족정도를 결정하는 단계이며, Layer 3은 정규화된 규칙의 충족정도를 나타내는 단계이다. Layer 4는 최종 규칙을 생성하는 단계이며, 마지막으로 Layer 5는 최종 출력을 발생하는 단계이다.

Neuro-fuzzy를 이용한 연구들 중에서 Aqil et al.(2007)은 일유량 및 시유량자료의 예측을 위해서 Levenberg-Marquardt feed forward neural network(FFNN), Bayesian regularization-FFNN, 그리고 neuro fuzzy모형을 구성한 후 그 결과값의 비교를 통해서 유량예측 측면에서는 neuro-fuzzy를 사용한 기법이 더 좋은 결과를 보여준다고 언급하고 있다. 이 연구의 대상유역은 유역면적 60.17km<sup>2</sup>인 자바섬에 위치한 지역이고 사용한 자료는 6분 간격으로 측정된 자료를 1시간 혹은 1일 간격으로 변환한 자료로서 자료기간은 2001~2003년이다. 이와 같이 구축된 3년간의 자료를 2001~2002년의 2년간은 학습을 위해서 사용하고 2003년의 자료는 검정을 위해서 사용하였다. 이 연구에서는 지수변환식의 형태로 구성된 변환식을 이용하여 입력자료를 정규화시킨 후 사용하였는데, 이런 변환과정을 거치더라도 전체적인 시스템의 효율성을 높이는 데는 크게 효과적이지 못한 것으로 나타났다.

Neuro-fuzzy기법중의 하나인 ANFIS를 이용한 유량예측 결과값을 인공신경망이나 퍼지추론시스템

의 결과값과 보다 체계적인 방법을 써서 비교한 연구 결과로는 Nayak et al.(2005)의 연구를 볼 수 있다. 여기서는 유역면적이 903.87km<sup>2</sup>인 대상지역에서 구축한 3년간(1987~1989년)의 장마기(7~9월) 시간 자료를 이용해서 각각 ANFIS, 인공신경망, 그리고 퍼지추론시스템을 이용해서 유량을 예측한 후 그 결과값을 비교하였는데, 상당히 많은 수의 통계량을 이용하여서 세 가지 모형 사이의 효율성을 비교 검토하였다.

우선 전체적인 유량예측의 정확도를 평가하기 위해서는 평균제곱근오차(root mean squared error: RMSE), 신호대비잡음비율(noise to signal ratio: NSR), 모형효율계수(coefficient of efficiency: COE), 상관계수(coefficient of correlation: COC), 그리고 과거자료의 평균, 표준편차, 왜곡도를 얼마나 충실히 재현하는가를 살펴보았는데 모든 통계량 값에서 ANFIS로 구한 유량값이 다른 두 가지 기법들에 비해서 더 좋은 결과값을 보여주는 것으로 나타났다. 특히, 1~6시간까지의 예측시간별로 각각의 통계량을 구한 결과를 살펴보면 예측시간이 길어지더라도 ANFIS로 구한 예측유량값은 다른 기법들로 구한 예측유량값에 비해서 그 정확도의 감소가 크게 증가하지 않는 것으로 나타났으며, 상관계수의 경우 예측시간 6시간인 경우에 대해서도 그 값이 약 0.83으로 나타날 정도로 상당히 큰 값을 보여주고 있고, 과거자료의 통계량을 재현하는데도 평균이나 표준편차 뿐만 아니라 왜곡도계수 역시 충실히 재현하는 것으로 나타났다. 같은 연구에서는 전체기간에 대한 모형의 효율성 뿐만 아니라 고수위(high-flow) 영역에 대한 결과값을 살펴보기 위해서 percentage error in predicted peak flow를 살펴보았으며, 개개의 강우-유출 사상(event)에 대한 유출총량에 대한 오차를 살펴본 결과 모두 ANFIS로 구한 결과값이 다른 두 기법들보다 더 우수한 것으로 나타났다. 마지막으로, 1개의 사상에 대해서 전 기간에 걸친 모형예측오차와 관측값을 비교한 결과에서도 ANFIS로 구한 값이 다른 두 기법들보다 안정적인 예측값을 보여주는

것으로 나타났다.

ANFIS를 이용해서 보다 장기간인 월평균유량을 예측한 연구로는 El-Shafie et al.(2007) 와 Bae et al.(2007)의 연구가 있다. El-Shafie et al.(2007)은 Aswan High Dam에 대한 이전의 연구에서 multilayer perceptron neural network(MLP-NN)모형을 이용해서 유량을 예측하는 경우 극한유입량이 발생하는 사상(extreme inflow event)에 대해서 오차가 커지는 현상을 해결하기 위해서 ANFIS모형을 구축하였다. 여기서 사용된 자료는 나일강에 대해서 구축된 130년간의 월유입량 자료이며, 3개월 전의 유입량 자료를 이용한 다음의 모형을 이용하여서 유량예측을 실시하였다.

$$Q_f(t) = f(Q_m(t-1), Q_m(t-2), Q_m(t-3)) \quad (6)$$

여기서,  $Q_f$  는 예측유량을 의미하고  $Q_m$  은 관측유량을 의미한다. 현재 시간인  $t$  보다 1, 2개월 앞선 유량은 다음의 식으로 예측하였다.

$$\begin{aligned} Q_f(t+1) &= f(Q_f(t), Q_m(t-1), Q_m(t-2)) \\ Q_f(t+2) &= f(Q_f(t+1), Q_f(t), Q_m(t-1)) \end{aligned} \quad (7)$$

즉,  $t+1$ ,  $t+2$ 에서의 유량을 예측하기 위해서는 각각 바로 앞 단계에서 예측된 유량값인  $Q_f(t)$ 와  $Q_f(t+1)$ 을 연속적으로 사용하는 방법을 사용하였다. ANFIS를 이용해서 구한 예측유량값을 MLP-NN을 이용한 예측유량값과 비교한 결과 극한 사상이 나타날 때도 ANFIS를 이용한 예측유량값의 오차는 거의 변화가 없었고, 1961~2000년에 걸쳐서 1, 2, 3달 선행시간을 가지는 예측유량값을 구한 후 오차를 비교해 본 결과 역시 ANFIS를 이용한 결과가 큰 오차의 변화 없이 비교적 일정한 정확도를 유지하는 것으로 나타났다.

Bae et al.(2007)은 정성적으로 제공되는 월간 기상예보자료를 이용하여 월간 저수지유입량예측 모형의 정확도를 향상시키는 연구를 진행하였는데, 대

상지역은 소양강댐 유역으로 유역면적은 2,703km<sup>2</sup>이고 월유입량, 강우, 상대습도, 기온자료와 기상예보정보를 사용하여 모형을 구축하였고, 크게 기상예보정보를 사용한 경우와 그렇지 않은 경우에 대해서 결과값을 살펴보았다.

여기서 사용한 기상예보정보는 기상청에서 제공되는 월간 기상예보자료로서 실제로는 모두 7단계로 제공되는 자료를 모형구축을 위해서 lower, slightly lower, similar, slightly higher, higher의 5단계로 나눈 후에 사용하였으며, 관측된 강우자료를 가상의 예보자료로 활용하는 경우(artificial forecast)와 실제로 기상청에서 제공되는 정성적인 기상예보자료를 이용한 경우(actual forecast)로 모형을 구성하였다. ANFIS모형의 학습을 위해서는 2001년 4월~2002년 9월까지의 월간 기상예보자료를 사용하였고, 모형의 검정을 위해서는 2002년 10월~2003년 9월까지의 자료를 이용하였다. 모형의 적합성은 상관계수와 평균제곱근오차(RMSE)를 통하여 검토하였는데, 기상예보자료를 활용한 경우가 그렇지 않은 경우보다 상관계수나 평균제곱근오차 모두에서 더 좋은 결과를 보여주었다.

#### 4. 유전자알고리즘(genetic algorithm)

유전자알고리즘(genetic algorithm; GA)은 다수의 해 또는 개체(chromosome)를 이용하여 해의 집합인 군(population)을 구성한 후 군내의 해를 이용한 교배(crossover), 돌연변이(mutation), 선택(selection)이라는 세 가지의 기본적인 유전자연산자(genetic operator)를 이용하는 최적화기법으로써, 시스템의 적합도를 결정하는 목적함수(objective function)를 사용하여 이미 구성된 모형의 최적화를 수행한다는 점에서 앞서 언급한 인공지능망이나 퍼지 추론시스템과는 그 성질이 상이하다고 할 수 있다. 즉, 유전자알고리즘은 입력자료와 출력자료간에 존재할 수 있는 비선형적인 특성을 찾아내는 기법이라기



보다는 주어진 목적에 맞는 최적의 시스템을 구축하기 위한 일련의 매개변수를 찾아내는 기법이라고 할 수 있으며, 이런 유전자알고리즘의 특징 때문에 인공 신경망이나 퍼지추론시스템 그리고 기타 많은 강우-유출모형과 혼합한 형태로 결과값을 도출하는 연구가 주로 진행되었다.

아래의 그림 5는 유전자알고리즘의 기본적인 순서도를 나타내고 있는 것으로서, 군대의 개체수, 교배율, 그리고 돌연변이율을 결정하는 단계를 시작으로, 임의의 난수를 이용하여서 초기군을 형성하고 이 중에서 부모세대를 결정한 후에 교배 및 돌연변이를 거쳐서 자식세대를 구성하고, 구성된 자식세대의 적합도를 결정하는 단계를 거쳐서 가장 좋은 개체를 찾아내고 일정한 시행횟수 동안 반복하는 순서를 나타내고 있는 것이다.

강우-유출모형과 관련하여 유전자알고리즘을 적용한 처음 사례로 흔히 소개되는 것이 Wang(1991)의 연구이다. 여기서는 개념적인 강우-유출모형(conceptual rainfall-runoff models)을 구성한 후 매개변수를 추정하기 위해서 유전자알고리즘을 적용하였는데, 매개변수는 이진코딩(binary coding)으로 이산화시켰고 선택법은 룰렛휠 선택법(roulette wheel selection)을 응용한 형태를 사용하였다. 사용한 강우-유출모형은 토양수분을 고려한 연속유출모형인 Xinanjiang모형을 사용하였고 6년간의 일간 자료를 이용하였다. 이 연구는 초기의 연구이니만큼 정확도나 효율성 면에서는 기존의 방법들과 비교하여 크게 향상되었다고 할 수는 없지만 유전자알고리즘을 활용하여 강우-유출모형의 매개변수를 찾아내는 것이 충분히 가능한 것임을 보여준 연구결과라고 할 수

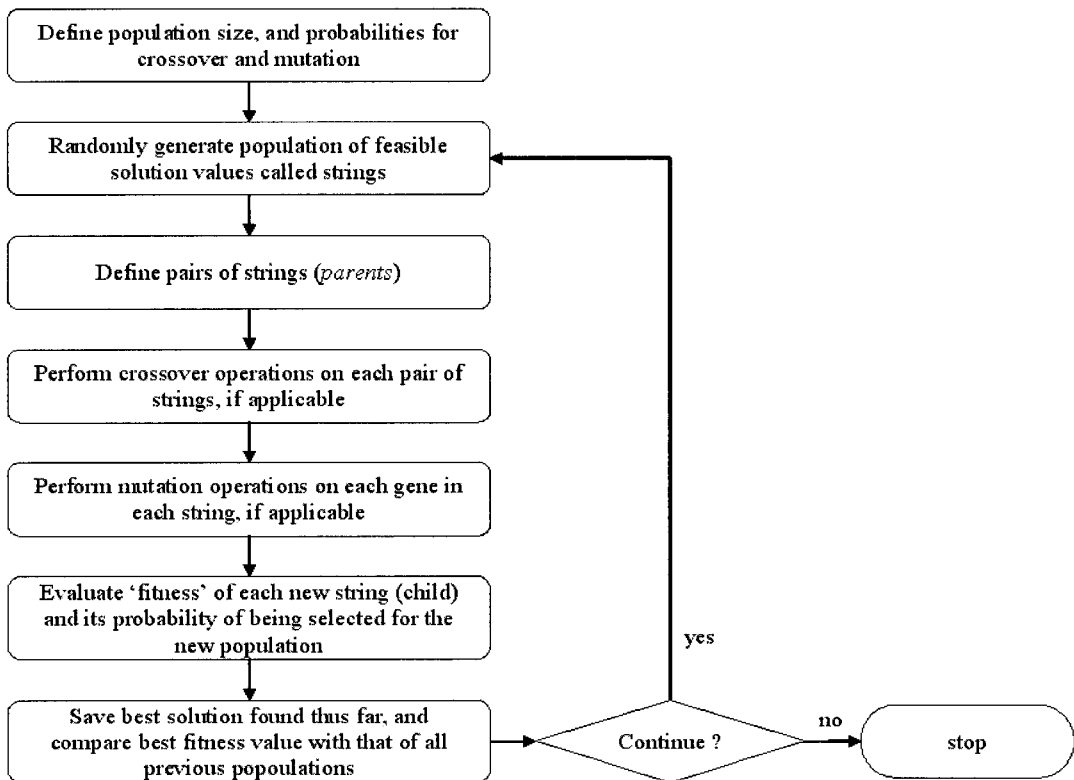


그림 5. 유전자알고리즘의 기본순서도

있을 것이다.

개념적인 강우-유출모형보다 좀더 복잡한 형태의 매개변수를 가지고 있는 SWMM(storm water management model) 모형의 매개변수를 최적화한 연구는 Liong et al.(1995)과 김충수(2002)의 연구 결과가 있다. 두 연구 모두 매개변수의 코딩기법은 이진코딩을 사용하였고 사용한 목적함수는 각각 침투치에 관한 오차를 최소화시키는 형태와 전체기간에 대한 잔차제곱합(residual sum of squares)을 최소화하는 형태로 구성하였다. 하지만, 위의 연구들은 너무 작은 수의 반복회수, 즉 세대수(generation number)를 사용하거나 혹은 너무 작은 수의 개체를 사용하였기 때문에 유전자알고리즘이 가지는 전역탐색(global search) 능력을 충분히 활용하였다고 말하기는 어렵다.

최근에는 하나의 목적만을 고려한 최적화보다는 여러 개의 목적을 동시에 고려한 다목적최적화(multiobjective optimization) 기법을 적용한 유전자알고리즘 기법이 널리 사용되고 있으며, 유전자알고리즘을 활용한 다목적최적화 기법들 중에서 가장 활발하게 적용되고 있는 것이 파레토지배(Pareto-dominance) 개념을 활용한 기법들이다(Van Veldhuizen and Lamont 2000). 유량예측분야 역시 이런 다목적최적화 기법을 적용한 유전자알고리즘과 관련한 연구결과들이 많이 보고되고 있다(Cheng et al. 2002; di Pierro et al. 2005; Madsen 2000).

파레토지배를 이용하여 다목적최적화를 수행하는 경우, 2개 이상의 목적함수를 사용하게 되면 필연적으로 굉장히 많은 수의 동일한 순위(rank)를 지니는 해(chromosome)가 도출되게 된다. 이렇게 같은 순위를 지니는 여러 개의 해로부터 사용자가 원하는 좀더 우월한(dominate) 해를 선택하는 기법 중의 하나로 선호도순서화(preference ordering) 기법(Das 1999)을 들 수 있다. 선호도순서화는  $(n)$  차원에서 구한 다수의 파레토최적해를 대상으로  $(n-1)$  차원에서의 지배(dominate), 피지배(non-dominated) 관계를 계산하여서, 상위차원인  $(n)$  차원의 해들 중 하위

차원인  $(n-1)$  차원에서도 여전히 파레토최적해인 해를 찾아내는 것이다. 이와 같은 선호도순서화기법을 유출모형의 매개변수를 추정하는데 적용한 연구는 Khu et al.(2006)과 di Pierro et al.(2005)의 연구가 있다.

앞서 언급한 다목적최적화 기법들과 아울러 최근에는 유전자알고리즘을 다른 최적화 기법들과 혼합하여 적용한 연구들이 역시 많이 보고되고 있다(Chau et al. 2005; Khu et al. 2004). Chau et al.(2005)은 상류에서 관측한 수위를 이용해서 하류지점의 수위를 예측하는 모형을 구성하였는데, 사용한 자료는 일평균수위자료(daily average water-level)를 사용하였고 상류지점에서 하류지점까지의 유하시간이 약 24시간이기 때문에 2일 선행자료까지를 사용하였다. 여기서는 유전자알고리즘을 이용해서 인공신경망의 가중치(weight value)와 임계값(threshold value)을 구하기 위한 학습을 실시하였는데, 앞서 언급한 ANFIS와의 비교를 통해서 국부적으로 예측을 하는데 있어서는 ANFIS를 이용한 모형이 더 좋지만 좀더 넓은 탐색범위에 걸친 해를 탐색하는데는 유전자알고리즘을 적용한 것이 더 좋은 결과를 보여준다고 언급하고 있다.

유전자알고리즘을 인공신경망과 혼합하여 사용하는데 있어서, 다른 모형과의 비교를 비교적 심도있게 진행한 최근의 연구로는 Srinivasulu and Jain(2006)의 연구를 들 수 있다. 여기서는 back-propagation algorithm으로 학습시킨 인공신경망(ANN-BPA)을 기본형태로 하고, 실수코딩(real-coding)을 사용한 유전자알고리즘으로 학습시킨 모형(ANN-RGA)과 self-organizing map기법을 적용해서 입-출력자료를 군집해석한 후에 각각의 군에 인공신경망을 적용한 모형(ANN-SOM)을 비교하여서 각 모형의 적용성을 평가하였다. 연구에 사용한 대상유역의 유역면적은 약 10,249이고 사용한 자료는 5개 강우관측지점의 일평균강우자료와 1개소의 일평균유출량 자료이며 최대 2일전까지의 자료를 사용해서 모형을 구축하였다.

각각의 모형을 비교하기 위해서 7개의 다양한 통계량을 이용해서 각 모형의 적용성을 비교하였는데, 일반적으로 사용되는 ANN-BPA 모형의 경우 가장 나쁜 결과를 보여주었고, ANN-RGA와 ANN-SOM은 학습자료를 이용한 경우에는 비슷한 결과를 보여주었으나 학습시킨 매개변수를 이용해서 학습자료와 다른 자료에 적용한 결과 ANN-RGA가 모든 통계량값에서 ANN-SOM보다 좋은 결과를 보여주었다. 이 연구는 비록 1개의 유역에 대한 자료를 이용한 결과이기는 하지만, 유전자알고리즘을 학습기법으로 이용한 인공신경망이 다른 기법을 학습기법으로 이용한 인공신경망보다는 학습자료에 의존하는 경향이 덜함을 보여주는 의미있는 결과라고 할 수 있을 것이다.

## 5. 결론

여기서는 기존의 유출모형인 개념적 모형(conceptual model)이나 물리적 모형(physically-based model)과는 다른 black-box적인 특성을 지니고 있는 soft computing 기법을 활용한 유출량 예측모형을 살펴보았으며, 크게 인공신경망, 퍼지추론시스템, 그리고 유전자알고리즘의 3가지 분야별로 유출량을 예측하는데 주로 사용되고 있는 기법들과 현재까지 알려진 문제점들, 그리고 향후에 진행될 수 있는 연구들을 중심으로 살펴보았다.

유량예측 분야에 인공신경망을 적용하기 위해서는 본문에서 언급한 대로 원하는 출력자료에 의미있는 영향을 미치는 입력자료를 적절한 기준을 통해서 선정하고, 학습집합을 구성하는데 있어서 주어진 문제에서 요구하는 전체 영역(domain)에 관한 자료의 대표성을 가지도록 해야 하며, 학습집합을 이용해서 인공신경망을 학습시키는데 있어서도 과다학습이나 과소학습이 이루어지지 않도록 주의해야 하는 등 여러 가지 한계점이나 문제점들이 있는 것은 분명하지만, 최근의 여러 논문집에서 특별세션을 구성하여서 연구

결과들을 보고할 만큼(Govindaraju and Rao 2000; See et al. 2007) 상당히 폭넓은 분야에 걸쳐서 활발히 연구가 진행되고 있는 실정이다. 여기에서 언급한 여러 가지 연구결과들이 비록 이런 연구성과들을 모두 집약하고 있는 것은 아니지만, 유량예측을 위한 인공신경망과 관련된 최근의 연구결과들을 살펴보는 데는 큰 무리가 없을 것으로 생각된다.

퍼지추론시스템은 퍼지규칙을 결정하는 멤버십함수를 구성하는 것이 가장 핵심적인 절차라고 할 수 있는데, 현재까지의 연구결과를 살펴보면 아직까지 어떤 형태의 퍼지멤버십함수가 유량예측을 위해서 가장 적합한 형태인지를 말하기는 어려울 것으로 생각된다. 또한, 유량예측을 위해서 사용할 멤버십함수를 결정하는 것과 더불어서, 퍼지추론시스템은 기본적으로 'if A, then B'와 같은 입출력자료간의 규칙성을 찾아나가는 것이므로 인공신경망에서 언급한 것과 같이 규칙을 추론하기 위해서 사용하는 자료를 어떻게 구성할 것인지에 대한 연구가 좀더 진행되어야 할 것으로 생각된다. 유전자알고리즘은 앞서 언급한 인공신경망이나 퍼지추론시스템과는 달리 주로 이미 구성된 모형의 매개변수를 추정하는데 있어서 더 효율적인 기법이라고 말할 수 있으며, 따라서 다른 기법들과 혼합된 형태로 유량을 예측하는 모형이 많이 적용되고 있다. 특히, 인공신경망의 학습방법으로 유전자알고리즘을 적용하는 분야가 최근에 활발히 연구되고 있는 실정이다.

Soft computing 기법들은 생물체의 진화나 행동양태를 연구하는 생물학에 그 기본을 두고 개발된 기법들이 대부분이며, 상호배타적인 기법이라기보다는 서로간의 단점을 보완할 수 있는 상호보완적인 기법들이기 때문에, 각 기법의 장단점을 보다 확실히 파악한 후에 서로간의 혼합기법을 만들어 낸다면 보다 효율적인 모형을 구축하는 것이 가능하다. 최근에는 본문에서 언급한 인공신경망, 퍼지추론시스템, 그리고 유전자알고리즘 외에 유전자프로그래밍(genetic programming), ant-colony theory optimization, 그리고 cellular automata같은 분야의 연구들도 진

행되고 있으며, 현재는 이와 같은 비교적 새로운 soft computing 기법들을 수공학의 각 분야에 적용한 후 기존의 기법들과의 비교를 수행하고 있는 단계라고 할 수 있으며, 향후에는 각 기법들중에서 수공학의 여러 가지 문제들을 보다 효율적으로 해결할 수 있는 기법이 무엇인지에 대한 연구와 더불어 기존의 모형들과의 보다 유기적인 결합을 이루어내는 것이 요구된다고 할 수 있다.

### 참고문헌

- 김충수. (2002). “도시유출 모의모형의 매개변수 추정,” 석사학위논문, 서울대학교 대학원 지구환경시스템공학부.
- Anmala, J., Zhang, B., and Govindaraju, R. S. (2000). “Comparison of ANNs and empirical approaches for predicting watershed runoff.” *Journal of Water Resources Planning and Management*, 126(3), 156-166.
- Aqil, M., Kita, I., Yano, A., and Nishiyama, S. (2007). “A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff.” *Journal of Hydrology*, 337(1-2), 22-34.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). “Artificial Neural Networks in Hydrology. II: Hydrologic Applications.” *Journal of Hydrologic Engineering*, 5(2), 124-137.
- Ashu, J., and Avadnam Madhav, K. (2007). “Hybrid neural network models for hydrologic time series forecasting.” *Applied Soft Computing*, 7(2), 585-592.
- Bae, D.-H., Jeong, D. M., and Kim, G. (2007). “Monthly dam inflow forecasts using weather forecasting information and neuro-fuzzy technique.” *Hydrological Sciences Journal*, 52(1), 99-113.
- Burnash, R. J., Ferral, R. L., and CMcGuire, R. A. (1973). “A generalized streamflow simulation system: conceptual modeling for digital computers.” Tech. Rep., Joint Federal-State River Forecast Center, U.S. National Weather Service and California Department of Water Resources, Sacramento, CA.
- Chandramouli, V., Lingireddy, S., and Brion, G. M. (2007). “Robust training termination criterion for back-propagation ANNs applicable to small data sets.” *Journal of Computing in Civil Engineering*, 21(1), 39-46.
- Chau, K. W., Wu, C. L., and Li, Y. S. (2005). “Comparison of several flood forecasting models in Yangtze River.” *Journal of Hydrologic Engineering*, 10(6), 485-491.
- Cheng, C. T., Ou, C. P., and Chau, K. W. (2002). “Combining a fuzzy optimal model with a genetic algorithm to solve multi-objective rainfall-runoff model calibration.” *Journal of Hydrology*, 268(1-4), 72-86.
- Chon, K. H., and Cohen, R. J. (1997). “Linear and nonlinear ARMA model parameter estimation using an artificial neural network.” *Biomedical Engineering, IEEE Transactions on*, 44(3), 168-174.
- Das, I. (1999). “A preference ordering among various Pareto optimal alternatives.” *Structural and Multidisciplinary Optimization*, 18(1), 30-35.
- Dawson, C. W., and Wilby, R. (1998). “An artificial neural network approach to rainfall-runoff modelling.” *Hydrological*

- Sciences Journal, 43(1), 47–66.
- di Pierro, F., Djordjevic, S., Kapelan, Z., Khu, S. T., Savic, D. A., and Walters, G. A. (2005). "Automatic calibration of urban drainage model using a novel multi-objective genetic algorithm." *Water Science & Technology*, 52(5), 43–52.
- Dibike, Y. B., and Solomatine, D. P. (2001). "River flow forecasting using artificial neural networks." *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26, 1–7.
- El-Shafie, A., Taha, M. R., and Noureldin, A. (2007). "A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam." *Water Resources Management*, 21(3), 533–556.
- Fernando, D. A. K., and Jayawardena, A. W. (1998). "Runoff forecasting using RBF networks with OLS algorithm." *Journal of Hydrologic Engineering*, 3(3), 203–209.
- Govindaraju, R. S., and Rao, A. R. (2000). "Editorial." *Journal of Hydrologic Engineering*, 5(3), 225–226.
- Han, D., Kwong, T., and Li, S. (2007). "Uncertainties in real-time flood forecasting with neural networks." *Hydrological Processes*, 21(2), 223–228.
- Hsu, K.-L., Gupta, H. V., and Sorooshian, S. (1995). "Artificial neural network modeling of the rainfall-runoff process" *Water Resources Research*, 31(10), 2517–2530.
- Jang, J. S. R. (1993). "ANFIS: adaptive-network-based fuzzy inference system." *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665–685.
- Karunanithi, N., Grenney, W. J., Whitley, D., and Bovee, K. (1994). "Neural networks for river flow prediction." *Journal of Computing in Civil Engineering*, 8(2), 201–220.
- Khan, M. S., and Coulibaly, P. (2006). "Bayesian neural network for rainfall-runoff modeling." *Water Resources Research*, 42(doi:10.1029/2005WR003971).
- Khu, S.-T., Liu, Y., Savi, D. A., and Madsen, H. (2004). "A fast calibration technique using a hybrid genetic algorithm-neural network approach: application to rainfall-runoff models." *Proceedings of the 6th International Conference on Hydroinformatics*.
- Khu, S. T., di Pierro, F., Savic, D., Djordjevic, S., and Walters, G. A. (2006). "Incorporating spatial and temporal information for urban drainage model calibration: An approach using preference ordering genetic algorithm." *Advances in Water Resources*, 29(8), 1168–1181.
- Leaf, C. F., and Brink, G. E. (1973). "Hydrologic simulation model of Colorado subalpine forest." *USDA Forest Service Res. Paper RM-107*, Washington, D.C.
- Leaf, C. F., and Brink, G. E. (1975). "Land use simulation model of the subalpine coniferous forest zone." *USDA Forest Service Res. Paper RM-135*, Washington, D.C.
- Liong, S.-Y., Chan, W. T., and ShreeRam, J. (1995). "Peak-flow forecasting with genetic algorithm and SWMM." *Journal of Hydraulic Engineering*, 121(8), 613–617.
- Liong, S.-Y., Lim, W.-H., and Paudyal, G. N. (2000). "River stage forecasting in Bangladesh: neural network approach." *Journal of Computing in Civil Engineering*, 14(1), 1–8.

- Madsen, H. (2000). "Automatic calibration of a conceptual rainfall-runoff model using multiple objectives." *Journal of Hydrology*, 235(3-4), 276-288.
- Maier, H. R., and Dandy, G. C. (2000). "Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications." *Environmental Modelling and Software*, 15(1), 101-124.
- Minns, A. W., and Hall, M. J. (1996). "Artificial neural networks as rainfall-runoff models." *Hydrological Sciences Journal*, 41(3), 399-418.
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., and Ramasastri, K. S. (2005). "Short-term flood forecasting with a neurofuzzy model." *Water Resources Research*, 41(4), W04004, doi:10.1029/2004WR003562.
- Pulido-Calvo, I., and Portela, M. M. (2007). "Application of neural approaches to one-step daily flow forecasting in Portuguese watersheds." *Journal of Hydrology*, 332(1-2), 1-15.
- See, L., Solomatine, D., Abraham, R., and Toth, E. (2007). "Hydroinformatics: computational intelligence and technological developments in water science applications-Editorial." *Hydrological Sciences Journal*, 52(3), 391-396.
- Srinivasulu, S., and Jain, A. (2006). "A comparative analysis of training methods for artificial neural network rainfall-runoff models." *Applied Soft Computing*, 6(3), 295-306.
- Stokelj, T., Paravan, D., and Golob, R. (2002). "Enhanced artificial neural network inflow forecasting algorithm for run-of-river hydropower plants." *Journal of Water Resources Planning and Management*, 128(6), 415-423.
- Tokar, A. S., and Markus, M. (2000). "Precipitation-runoff modeling using artificial neural networks and conceptual models." *Journal of Hydrologic Engineering*, 5(2), 156-161.
- Van Veldhuizen, D. A., and Lamont, G. B. (2000). "Multiobjective evolutionary algorithms: analyzing the state-of-the-art." *Evolutionary Computation*, 8(2), 125-147.
- Wang, Q. J. (1991). "The genetic algorithm and its application to calibrating conceptual rainfall-runoff models." *Water Resources Research*, 27(9), 2467-2471.
- Wang, W., Gelder, P. H. A. J. M. V., Vrijling, J. K., and Ma, J. (2006). "Forecasting daily streamflow using hybrid ANN models." *Journal of Hydrology*, 324(1-4), 383-399.
- Wu, J. S., Han, J., Annambhotla, S., and Bryant, S. (2005). "Artificial neural networks for forecasting watershed runoff and stream flows." *Journal of Hydrologic Engineering*, 10(3), 216-222.
- Zadeh, L. A. (1965). "Fuzzy sets." *Information and Control*, 8, 338-353.
- Zadeh, L. A. (1973). "Outline of a new approach to the analysis of complex systems and decision processes." *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3, 28-44.
- Zadeh, L. A. (1979). "Fuzzy sets and information granularity." *Advances in Fuzzy Set Theory and Applications*, M. Gupta, R. Ragade, and R. Yager, eds., Amsterdam, The Netherlands: North-Holland, 3-18. 