

인공신경망과 유전자알고리즘의 결합모형을 이용한 수위예측에 관한 연구

Study on Water Stage Prediction Using Hybrid Model of Artificial Neural Network and Genetic Algorithm

여운기* / 서영민** / 이승윤*** / 지홍기****

Yeo, Woon Ki / Seo, Young Min / Lee, Seung Yoon / Jee, Hong Kee

Abstract

The rainfall-runoff relationship is very difficult to predict because it is complicate factor affected by many temporal and spatial parameters of the basin. In recent, models which is based on artificial intelligent such as neural network, genetic algorithm fuzzy etc., are frequently used to predict discharge while stochastic or deterministic or empirical models are used in the past. However, the discharge data which are generally used for prediction as training and validation set are often estimated from rating curve which has potential error in its estimation that makes a problem in reliability. Therefore, in this study, water stage is predicted from antecedent rainfall and water stage data for short term using three models of neural network which trained by error back propagation algorithm and optimized by genetic algorithm and training error back propagation after it is optimized by genetic algorithm respectively. As the result, the model optimized by Genetic Algorithm gives the best forecasting ability which is not much decreased as the forecasting time increase. Moreover, the models using stage data only as the input data give better results than the models using precipitation data with stage data.

Keywords : water stage prediction, neural network, genetic algorithm

요 지

강우-유출 관계는 유역의 수많은 시·공간적 변수들에 의해 영향을 받기 때문에 매우 복잡하여 예측하기 힘든 요소이다. 과거에는 추계학적 예측모형이나 확정론적 예측모형 혹은 경험적 모형 등을 사용하여 유출량을 예측하였으나 최근에는 인공신경망과 퍼지모형 그리고 유전자 알고리즘과 같은 인공지능기반의 모형들이 많이 사용되고 있다. 하지만 유출량을 예측하고자 할 때 학습자료 및 검증자료로써 사용되는 유출량은 수위-유량 관계곡선식으로부터 구하는 경우가 대부분으로 이는 이렇게 유도된 유출량의 경우 오차가 크기 때문에 그 신뢰성에 문제가 있을 것으로 판단된다. 따라서 본 논문에서는 선행우량 및 수위자료로부터 단시간 수위예측에 관해 연구하였으며, 이를 위해 오류역전파알고리즘을 이용한 신경망모형과 인공신경망의 가중치를 유전자 알고리즘에 의해 최적화시킨 모형 그리고 최적화된 상태에서 다시 학습

* 교신저자 · 영남대학교 건설시스템공학과 박사과정 (e-mail: adonas@nafree.net)

Corresponding Author, Ph.D., Student, Department of Civil Engineering, Yeungnam Univ., Gyeongsangbuk-do 712-749, Korea

** 영남대학교 건설시스템공학과 박사과정 (e-mail: elofy@nate.com)

Ph.D., Student, Department of Civil Engineering, Yeungnam Univ., Gyeongsangbuk-do 712-749, Korea

*** 한국수자원공사, K-water 수자원연구원 선임연구원 (e-mail: leesy@kwater.or.kr)

Senior Researcher, K-water Institute, 462-1 Jeonmin-dong, Daejeon 305-730, Korea

**** 영남대학교 건설시스템공학과 교수 (e-mail: hkjee@yu.ac.kr)

Professor, Department of Civil Engineering, Yeungnam Univ., Gyeongsangbuk-do 712-749, Korea

을 진행하는 세 가지 모형에 대하여 적용한 결과 유전자 알고리즘을 사용하여 신경망을 학습시킨 모형이 다른 모형들에 비해 우수한 결과를 보여주고 있으며 예측시간이 길어지더라도 예측력이 크게 떨어지지 않았다. 또한 입력자료로 강우와 수위를 사용한 모형보다는 수위를 사용한 모형에서 조금 더 우수한 결과를 보여주었다.

핵심용어 : 수위예측, 인공신경망, 유전자 알고리즘

1. 서 론

최근의 극심한 기상이변으로 인하여 발생하는 유출량의 예측에 관한 사항은 치수·이수는 물론 방재의 측면에서도 역시 매우 중요한 관심사로 부각되고 있다. 강우-유출 관계는 유역의 수많은 시·공간적 변수들에 의해 영향을 받기 때문에 매우 복잡하여 예측하기 힘든 요소이다. 과거에는 추계학적 예측모형이나 확정론적 예측모형 혹은 경험적 모형 등을 사용하여 유출량을 예측하였으나 최근에는 인공 신경망(Artificial Neural Network)과 퍼지(Fuzzy)모형 그리고 유전자 알고리즘(Genetic Algorithm)과 같은 인공지능기반의 모형들이 많이 사용되고 있다. 하지만 유출량을 예측하고자 할 때 학습자료 및 검정자료로써 사용되는 유출량은 수위-유량 관계곡선식으로부터 구하는 경우가 대부분으로 이는 이렇게 유도된 유출량의 경우 오차가 크기 때문에 그 신뢰성에 문제가 있을 것으로 판단되며, 최근에는 상류의 수문조건을 이용하여 신경망이나 뉴로퍼지(Neuro-Fuzzy) 모형 등을 이용해서 수위를 예측하는 연구들이 진행되고 있다(Wilson and Khondker, 2000; Bazartseren et al., 2003; Chau, 2006).

신경망은 과거자료의 입·출력 패턴에서 정보를 추출하여 지식으로 보유하고, 이를 근거로 새로운 상황에 대한 해답을 제시하도록 하는 인공지능분야의 학습기법으로 인간이 과거의 경험과 훈련으로 지식을 축적하듯이 시스템의 입·출력에 의하여 연결강도를 최적화함으로써 모형의 구조를 스스로 조직화하기 때문에 모형의 구조에 적합한 최적 매개변수를 추정할 수 있다. 따라서 정확한 예측이 어려운 하천수위를 과거의 자료로부터 학습된 신경망의 수학적 알고리즘을 통해 예측에 적용할 수 있다.

이러한 신경망의 구조는 McCulloch and Pitts (1943)에 의해 처음 제시된 이후 델타규칙, 퍼셉트론 등 다양한 학습규칙이 제시되어왔다. Rumelhart et al. (1986)에 의해 제시된 오류 역전파 알고리즘(Error Backpropagation Algorithm)은 다층 퍼셉트론을 학습시킬 수 있어 비선형 특성의 모형에 적합하며, 오늘날 가장 많이 사용하는 학습규칙중의 하나이다. French et al. (1992)은 신경망을 이용하여 1시간 후의 강우사상에 대해 모의한 바 있으며, Kuligowski and Barros (1998)은 강우관측소의 선행강우

량을 이용하여 6시간까지의 누가강우량을 예측한 바 있다. 신경망을 이용한 실시간 유출예측결과 Thirumalaiah and Deo (1998)는 1~3시간까지의 예측에서, Napolitano et al. (2009)은 12시간과 18시간의 예측에서 신경망을 사용하여 만족할만한 결과를 얻은 바 있다.

유전자 알고리즘은 Holland (1975)가 이진 스트링의 개체집단 위에서 모의진화를 일으켜 효율적으로 최적 해를 탐색하는 최초의 유전자 알고리즘을 개발하였으며, Goldberg (1989)는 유전자 알고리즘을 이용하여 비선형 최적화문제를 해결하는 매커니즘과 강인성에 대해 논의하였으며, Montana and Davis (1988), Maniezzo (1994) 그리고 Nasser et al. (2008)은 유전자 알고리즘을 이용하여 오류역전파 신경망의 훈련에 이용한 바 있으며, 우수한 결과를 보인 것으로 나타났다. Sedki et al. (2009)은 장기 강우-유출해석에 실수코딩 유전자 알고리즘(Real-coded Genetic Algorithm)을 사용하여 신경망의 학습을 시킨 결과 오류역전파 알고리즘을 사용했을 때보다 예측력이 우수한 것으로 나타났으며, 특히 저수기의 예측력이 신경망 단일 모형보다 우수하였다(Srinivasulu and Jain, 2006).

1990년대 이후부터 우리나라에서도 인공신경망을 수문수자원 및 환경공학분야에 활발하게 적용해 오고 있다. 오남선과 선우중호(1996)는 신경망을 서울 및 소양강유역의 강우예측모델에 적용한 바 있으며, 이순탁과 김성원(1997)은 역전파알고리즘을 사용하여 신경망 모형의 홍수 유출특성을 분석하였다. 또한, 김성원(2000)은 홍수 유출 예측을 위해 신경망 모형의 학습을 Hestenes-Steifel 공액구배 역전파 알고리즘과 Broyden-Fletcher-Goldfarb-Shanno 의사 뉴턴 역전파 알고리즘을 사용하여 낙동강의 진동수위표지점의 홍수유출량을 예측한 바 있다. 박성천 등(2006)은 신경망을 이용한 홍수유출예측모형을 GUI형태로 구현하여 홍수예보시스템의 적용성을 분석하였다. 최근에는 신경망 모형을 이용하여 수위를 예측하는 연구도 진행되고 있다(박성천 등, 2005; 황현경과 김경호, 2008).

이러한 기존의 연구에서는 하천 유출량을 예측한 연구가 많았으며, 이 때 수위-유량곡선을 이용하여 수위로부터 유출량을 계산하는 경우가 많았다. 특히 홍수의 경우

수위 유량곡선의 외삽을 이용하여 유출량을 산정하는 경우 오차를 많이 포함할 수 있으므로 본 연구에서는 수위를 직접 예측하였으며, 신경망 모형의 학습에 유전자 알고리즘의 적용성을 검토하기 위해 오류역전파 알고리즘을 신경망의 학습에 이용한 모형과 실수코딩 유전자 알고리즘을 신경망의 학습에 이용한 모형 그리고 실수코딩 유전자 알고리즘으로 학습한 상태에서 다시 오류 역전파 알고리즘에 의한 학습을 한 번 더 진행하는 세 가지 모형에 대하여 비교 연구하였다.

2. 인공신경망과 유전자 알고리즘

2.1 인공신경망

인간의 뇌는 뉴런 (Neuron)이라는 최소 단위의 신경 세포들이 시냅스 (Synapse)라는 물질로 연결되어 있으며 이 연결이 복잡해져 거대한 그물망으로 구성되어 있는데 이러한 구조를 단순화하여 만든 연산모형을 인공신경회로망이라고 하며, 이 모델에서는 문제를 해결하기 위한 직접적인 지식이나 방법을 입력하지 않아도 뉴런들의 학습을 통한 최적화로 문제를 해결할 수 있다.

다층 신경망 모델은 일반적으로 Fig. 1과 같이 나타내며, 이 때 입력층, 은닉층, 출력층의 각 노드는 뉴런을 의미하고 노드를 연결하는 링크는 뉴런간의 시냅스 연결강도를 의미한다.

인공신경망의 계산은 입력층에 들어온 외부자극의 가중합을 활성화함수를 통해 적절한 반응을 출력하게 된다. 여기서 외부자극의 가중합은 Eq. (1)과 같이 표현할 수 있다.

$$NET_j = \sum_{i=1}^n x_i w_{ij} \quad (1)$$

여기서, NET_j 는 j 번째 출력뉴런에 들어오는 외부자극의 가중합을 의미하며, x_i 는 외부자극, w_{ij} 는 출력뉴런




Fig. 1. Common Structure of the Artificial Neural Network

과 x_i 사이의 연결강도를 의미한다.

이 때, 출력뉴런의 반응 값은 활성화함수에 의해 결정되는데 아닐로그 출력이 가능한 단극성 시그모이드 (Sigmoid) 함수가 많이 사용되며, 이는 Eq. (2)와 같다.

$$f(NET_j) = \frac{1}{1 + \exp^{-\lambda NET_j}} \quad (2)$$

여기서, λ 값에 따라 시그모이드 함수의 형태가 변하게 되는데 일반적으로는 오버플로우 혹은 언더플로우를 방지하기 위해 $\lambda = 1$ 을 사용한다.

오류역전파 알고리즘에 의한 학습은 신경망의 전 방향 연산 (Feed Forward)에 의해 계산된 값과 학습을 위한 목표값을 비교하여 오차의 제곱의 총합을 최소로 할 수 있도록 연결강도를 조정하게 되며, 오차가 일정 수준 이하가 될 때까지 학습과정을 반복한다. 이 때 연결강도의 조정량은 Eq. (3)과 같다.

$$\Delta w_{ij} = \eta \cdot \delta_{pj} \cdot o_{pi} \quad (3)$$

여기서, η 는 학습률, δ_{pj} 는 현재 층의 오차신호, o_{pi} 는 이전 층의 활성 값이다.

이러한 신경망 모형은 유역 내의 강우 및 상류부의 수위를 입력 자료로 사용하고 그에 따른 일정시간 후의 하류부 수위를 출력으로 하는 한 쌍의 입출력 자료들을 학습시켜 대상 유역의 입력에 따른 출력의 최적 패턴을 찾아내기 위해 연결강도를 조절해 나감으로써 대상 유역에 새로운 미지의 값이 입력되었을 때 몇 시간 후의 하류의 수위를 최적 패턴에 따라 예측해 내게 된다.

2.2 유전자 알고리즘

유전자 알고리즘은 적자생존의 생물학 원리에 바탕을 둔 최적화 기법중의 하나로 자연계의 생명체 중 환경에 잘 적응한 개체가 좀 더 많은 자손을 남길 수 있다는 자연 선택 과정과 유전자의 변화를 통해서 좋은 방향으로 발전해 나간다는 자연 진화의 과정인 자연계의 유전자 메커니즘에 바탕을 둔 탐색 알고리즘이다. 즉, 자연계의 유전과 진화 메커니즘을 공학적으로 모델화함으로써 잠재적인 해의 후보들을 모아 군집을 형성한 뒤 서로간의 교배 혹은 변이를 통해서 최적 해를 찾는 계산 모델이며, 그 과정은 Fig. 2와 같다.

유전자 알고리즘은 목적함수에 따라 유전자와 군집의 크기를 결정하여 초기 유전자 집단을 생성한 후 적합도를 계산하고 이를 바탕으로 다음 세대를 결정한다. 재생산 과정은 선택 (Selection), 교배 (Crossover), 돌연변이 (Mutation) 연산자를 이용하여 해 집단의 다양성을 높이고 적합도가 큰 개체의 발생을 기대하며, 적합도가 기준

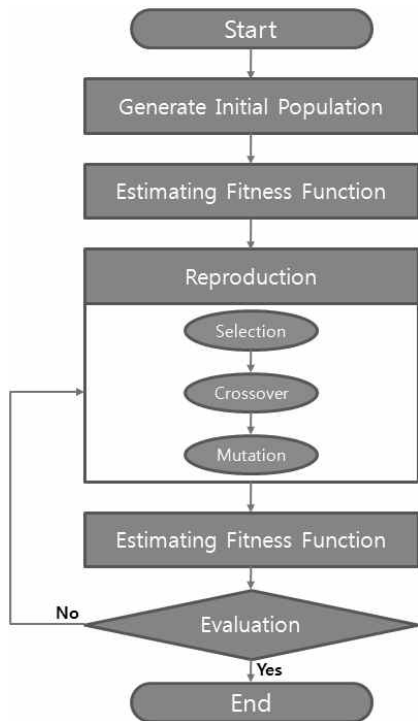


Fig. 2. Flowchart of the Genetic Algorithm

에 만족될 때까지 재생산과정을 반복한다. 일반적으로 최적화에 관련된 유전자 알고리즘은 유전자집단을 0과 1을 사용하는 2진 비트스트링(Bit String)을 사용하는 경우가 많으나 본 연구에서는 유전자 알고리즘을 사용하여 신경망의 연결강도를 최적화하기 위해 2진 비트스트링으로는 한계가 있기 때문에 실수코딩 유전자 알고리즘을 사용하였다.

선택연산자 중에서 많이 사용되고 있는 것은 룰렛-휠 연산자이지만 초기 세대에서 적합도가 다른 개체에 비해 월등히 높은 개체가 발생하면 이 개체의 선택확률이 너무 높아져서 다양성이 감소되고 확률적으로 최적개체가 반드시 선택되지는 않게 되는 문제가 있다. 이에 따라 이러한 단점을 극복할 수 있도록 구배와 유사한 선택자(Gradient-like Selector)가 제안되고 있다(Pham and Jin, 1995; Pham and Jin, 1996). k 세대의 집단을 $P(k) = \{s_1(k), s_2(k), \dots, s_n(k)\}$ 라 정의하고 최적의 벡터를 $x_b(k)$, 최적의 적합도를 $f_b(k)$ 라 할 때 Eq. (4)와 같이 각 개체에 새로운 값이 할당된다.

$$\bar{x}_{ij}(k+1) = x_{ij}(k) + \eta_i \frac{[f_b(k) - f_i(k)]}{f_b(k)} [x_{bj}(k) - x_{ij}(k)] \quad (4)$$

여기서 $x_{ij}(k)$ 와 $x_{bj}(k)$ 는 각각 $x_i(k)$ 와 $x_b(k)$ 의 j 번째 요소이고 $f_i(k)$ 는 i 번째 개체의 적합도이고 η_i 는 양의 상수로써 개체마다 서로 다른 값을 적용할 수 있다.

이렇게 각 개체에 새로운 값이 할당 되면 $\bar{P}(k+1) = \{\bar{s}_1(k+1), \bar{s}_2(k+1), \dots, \bar{s}_n(k+1)\}$ 과 같이 새로운 교배급원을 형성한다. 새로운 탐색점 $\bar{x}_i(k+1)$ 은 $\bar{x}_i(k)$ 와 최적 벡터 $x_b(k)$ 의 일차결합으로 정의 된다. 이는 개체들의 복제를 가급적 피하면서 집단을 최적 개체 쪽으로 유도하는 것이다.

모의진화가 계속되는 동안 재생산과 교배 연산자는 집단을 더욱 강하게 해주고 이로 인하여 염색체들은 서로 닮아가게 되어 유전자의 다양성 결핍으로 전역 해(Global Solution)가 아닌 지역 해(Local Solution)에 빠지게 될 수 있다. 이를 벗어나기 위해 염색체 내의 일부를 확률적으로 다른 값으로 바꿔주는 돌연변이를 일으킴으로써 진화의 초기에 모든 염색체의 특정 부분이 고정되는 것을 방지해주고 탐색영역을 확대해 줄 수 있다. Janikow and Michalewicz (1991), Michalewicz (1996)은 정밀도를 높이기 위해 미세 조정이 가능하도록 동적 돌연변이(Dynamic Mutation)를 고안한 바 있다. 만약 j 번째 유전자에서 돌연변이가 일어난다면 x_j 는 Eq. (5)와 같이 결정된다.

$$x_j = \begin{cases} \tilde{x}_j + \Delta(k, x_j^{(t)} - \tilde{x}_j), & \tau = 0 \text{일 때} \\ \tilde{x}_j - \Delta(k, x_j - x_j^{(L)}), & \tau = 1 \text{일 때} \end{cases} \quad (5)$$

여기서 τ 는 0 혹은 1 중에서 하나를 취하는 난수이다. $\Delta(k, y)$ 는 Eq. (6)과 같은 식을 이용한다.

$$\Delta(k, y) = y \cdot r \cdot \left(1 - \frac{k}{T}\right)^b \quad (6)$$

여기서, r 은 0과 1 사이의 실수난수이며, T 는 알고리즘이 실행되는 최대 세대수, k 는 현재의 세대수 b 는 불균등 정도를 나타내는 매개변수로서 사용자에게 의해 결정된다.

모의 진화과정에서 유전 연산자의 확률적 속성 때문에 한 세대의 최적 개체가 다음 세대에서 선택되지 못하고 소멸되는 경우가 발생할 수 있다. 최적 개체의 소멸은 좋은 특성을 가진 유전자를 잃게 되어 탐색이 침체되는 원인을 제공한다. 집단 내에서 가장 강한 개체가 다음 세대로 변경되지 않고 전달되는 것을 보장하기 위해 엘리트 전략(Elitism)이 고안되었으며, 일반적으로 이 방법은 유전알고리즘의 성능을 개선시키는 것으로 알려져 있다(De Jong, 1975).

2.3 신경망과 유전자 알고리즘의 결합

유전자 알고리즘은 주어진 문제에 대해서 가장 최적의 해를 도출해 내는 탐색 알고리즘으로써 오류 역전파 알고리즘이 경사하강법을 사용하여 계산된 출력값과 관측된 값 사이의 오차가 최소가 되도록 학습하는데 비해 본 연

구에서 사용된 유전자 알고리즘과 신경망 모형이 결합된 모형의 구조는 신경망과 동일한 구조를 가지며, 강우와 상·하류의 수위를 입력자료로 하는 신경망의 학습을 오류역전과 알고리즘이 아닌 유전자 알고리즘을 사용하게 된다. 이 때 연결강도의 집단을 유전자로 사용하며 신경망의 오차가 적합도가 되어 이를 최소가 되도록 진화시켜 나가는 방법이다. 또한, 유전자 알고리즘으로 최적화된 상태의 결과를 오류역전과 알고리즘을 이용하여 2차 학습시킨 모형도 비교하여 신경망과 유전자 알고리즘의 유리한 결합 형태에 대해 검토하였다.

3. 모형의 적용 및 결과

3.1 모형의 적용대상 및 구성

본 연구에서는 Fig. 3과 같이 낙동강의 중류지역에 위치한 감천유역의 선산수위표의 수위를 예측하기 위해 감천 유역내의 강우관측지점과 수위관측지점의 자료를 사용하여 모형을 구성하였다. 감천유역은 유역면적이 1,005 km², 유로연장이 74 km, 본 연구에서 분석에 사용된 지점인 김천수위표지점과 선산 수위표지점이 포함되어 있는 국가하천 구간은 41 km, 유역경사는 30%인 유역으로 낙동강유역의 중앙부에서 서쪽으로 뻗어있는 지류이다.

수위 예측을 위한 모형은 신경망 모형을 기반으로 하여 학습방법에 따라 ① 오류 역전과 알고리즘 (BP)으로 학습시킨 신경망 모형, ② 유전자 알고리즘으로 학습시킨 신경망과 유전자 알고리즘의 결합모형 (GA), ③ 유전자알고리즘에 의해 학습한 후 오류역전과 알고리즘으로 2차 학습시킨 (GA+BP) 3가지 모형을 사용하였다. 또한 각 모형의 입력 자료를 ① 티센망을 이용하여 구한 감천유역의 면적평균강우량과 선산수위표의 상류수위표지점인 김천

수위표의 수위자료를 사용한 모형과, ② 김천 수위표의 수위자료만 사용한 두 가지 모형으로 분류하였다.

홍수 시의 수위자료 예측을 위해 기존의 홍수사상 중에서 선산지점의 수위가 4m를 초과하는 사상의 자료를 입력자료로 사용하여 학습을 진행하였으며, 모형의 검정을 위해 2007년의 사상을 사용하였다. 이 때 입력 자료로 사용할 강우량 및 수위의 지체시간을 선정하기 위해 강우량과 선산지점의 수위 그리고 김천지점의 수위와 선산지점의 수위에 대해 각각 지체시간별로 교차상관분석을 실시하여 선산지점의 수위에 가장 상관도가 높은 시간을 선정하였다. 그 결과 상관도가 가장 높게 나타난 12, 13, 14, 15시간 전의 유역면적강우량과 3, 4, 5, 6시간 전의 김천수위표의 수위를 입력변수로 구성하였으며 은닉층의 노드 수에 따라 결과 값에 미치는 영향을 파악하기 위해 면적강우량과 수위를 입력 자료로 사용한 모형에 대해서는 입력 자료의 수에 비례하여 노드수가 4, 8, 16인 세 가지 모형을 구성하였으며, 수위만을 입력 자료로 사용한 모형에 대해서는 4, 8, 12의 세 가지 모형을 구성하였다. 각 모형의 구성요소는 Table 1과 같다.

Table 1. Application Models

Models	Input Data	Hidden Layer Nodes No.
BP, GA, GA+BP	$P_{t-15}, P_{t-14}, P_{t-13}, P_{t-12}$ $Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	4, 8, 16
BP, GA, GA+BP	$Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}$	4, 8, 12

* BP: Trained by Back-Propogation Algorithm
GA: Trained by Genetic Algorithm
GA+BP: Trained by BP after trained by GA



Fig. 3. Study Basin

3.2 최적모형과 매개변수의 선정

오류 역전과 알고리즘을 사용한 신경망의 학습 시 최적의 학습률을 구하기 위해 0.1~1.0까지 적용해 보았다. 그 결과 계산된 값에 커다란 영향을 미치지 않고 비슷한 결과를 보여주었으나 가장 좋은 결과를 보여준 0.3을 본 연구에서 사용하였으며 계산의 속도를 높이기 위해 모멘텀 상수 0.05를 사용하였다. 총 학습 횟수는 과대적합 (Overfitting)과 과소적합 (Underfitting)을 고려하여 5000 회로 하였으며, 활성화 함수로는 단극성 시그모이드함수를 사용하였으며 학습패턴 p 에 대한 출력층 뉴런의 출력 값 o_{pj} 와 목적 값 t_{pj} 사이의 오차는 Eq. (7)과 같은 평균 제곱오차를 사용하였다.

$$E_p = \frac{1}{2} \sum (t_{pj} - o_{pj})^2 \quad (7)$$

유전자 알고리즘을 이용하여 신경망의 최적 연결강도를 구하는 모형은 유전자 집단에 실수 (Real Number)를 사용한 실수코딩 유전자 알고리즘을 사용하였다. 유전자 집단은 신경망의 각 노드를 연결하는 연결강도를 대상으로 하여 난수 발생시켜 초기집단을 구성하였으며, 이 때 생성 범위는 초기 집단에 높은 적합도를 가질 수 있도록 오류역전파 알고리즘의 학습결과를 고려하여 -5~5로 하였다. 초기 집단을 구성하는 후보유전자 수는 40개로 하였다. 총 세대수는 많을수록 진화를 여러 번 진행하기 때문에 더 좋은 값을 가질 수 있으나 50~1000번까지 적용시켜 본 결과 200세대 이상이 되는 경우 최종적합도의 차이가 그다지 크지 않아 계산속도 등을 고려하여 200세대의 진화연산을 진행하였다.

유전자 집단의 교배급원을 구성하는 연산자인 재생산 연산자는 구배유사선택자를 사용하였다. 해의 탐색범위를 넓혀주고 국소 해에 빠지는 현상을 방지해주는 돌연변이 연산자는 동적 돌연변이를 사용하였으며, 이 때 돌연변이율은 1%로 하였다.

구성된 유전자 집단을 연결강도로 하는 신경망을 구성

하여 Eq. (7)에 의해 계산된 결과에 대한 역수를 적합도로 취하여 이를 최대화시키는 방향으로 진화를 전개하였으며, 적합도에 의해 선택압이 줄어드는 것을 방지하기 위해 스케일링 윈도우 (Scaling Window)를 적용하여 적합도 스케일링을 실시하였다. 또한 진화를 거듭함에 따라 가장 우수한 적합도를 가진 유전자가 사라지지 않도록 엘리트전략을 시행하였다.

본 연구에서 비교에 사용한 모형들은 모두 신경망의 구조를 가지고 있으나 아직까지 신경망을 구성함에 있어 은닉층의 노드수를 어떻게 결정하는 것이 가장 우수한 결과를 도출해 낼 수 있는지에 대한 명확한 기준은 밝혀진 바 없다. 하지만 은닉층의 노드 수가 적을 경우에는 과소적합 (Underfitting)되어 대상구역의 수문현상을 제대로 예측해내지 못할 우려가 생기며 노드 수가 많을 경우에는 과대적합 (Overfitting)되어 새로운 다른 사상을 제대로 예측해 내지 못할 우려가 생긴다. 또한 계산시간이 길어질 뿐만 아니라 훈련해야 할 연결강도의 수가 많아져 모든 연결강도를 제대로 훈련시키지 못할 가능성도 생긴다.

따라서, 은닉층의 노드수가 본 연구의 결과에 미치는 영향을 분석하기 위해 각 경우마다 상관분석을 실시하여 결정계수 (R^2) 값을 구하였다. Figs. 4 and 5에 나타난 바와 같이 전체적으로 결정계수 값은 0.9 이상을 보이고 있

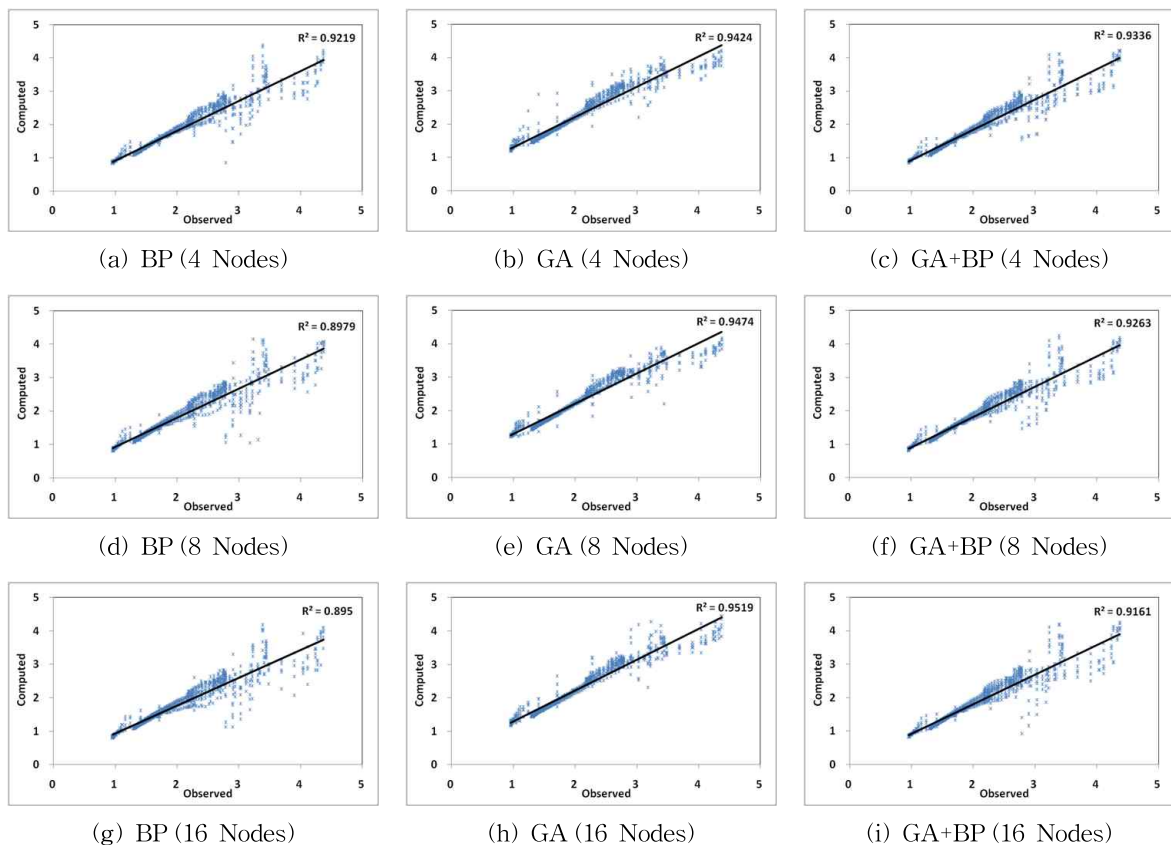


Fig. 4. Compare of R^2 by Different Node Numbers of Hidden Layer (Precipitation+Discharge)

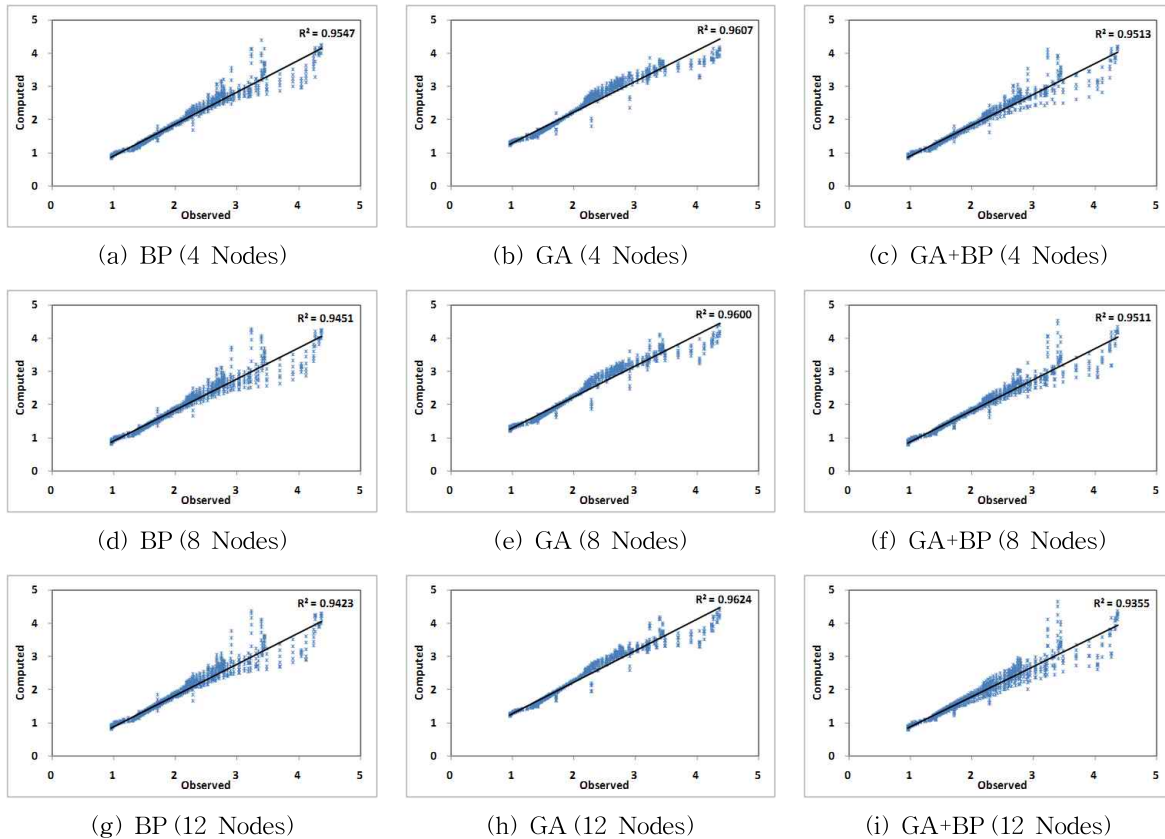


Fig. 5. Compare of R^2 by Different Node Numbers of Hidden Layer (Discharge only)

어 각 모형들의 예측력이 우수함을 알 수 있었다. BP와 GA+BP에서는 노드수가 늘어날수록 결정계수 값이 작아지며, GA모형에서는 노드수가 늘어날수록 결정계수 값이 커지는 것으로 나타났으나 그 차이는 미비하다고 할 수 있다. 따라서 본 연구에서는 각 모형의 비교를 위하여 노드수가 8개인 모형을 사용하였다.

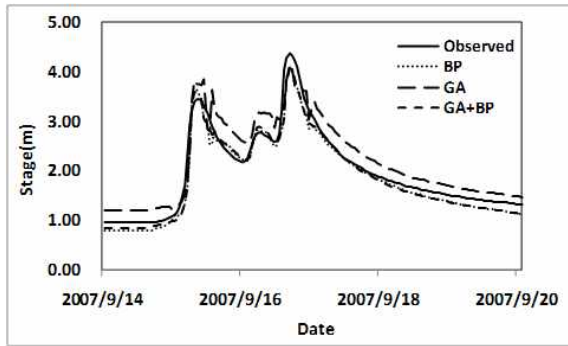
3.3 분석 결과 및 고찰

우선, 유역의 면적평균강우량과 상류지점의 수위를 사용하여 선산지점의 1~6시간 후의 수위를 예측한 경우 Fig. 6과 같은 결과를 얻을 수 있었으며, 1시간 예측의 경우가 가장 실제의 값을 잘 예측하고 있으며 예측시간이 길어질수록 오차가 커지는 것을 알 수 있었다. 특히 BP모형과 GA+BP모형의 경우 검정에 이용된 사상이 두 개의 침투를 포함하고 있는데 뒤의 침투에 대한 예측은 예측시간이 길어져도 오차가 그렇게 커지지 않는 반면 앞의 침투에 대해서는 오차가 갈수록 커지는 양상을 보였다. 특히 앞의 침투 부근에서 예측치의 진동이 점점 커지는 현상을 보였다. 이는 입력에 사용된 강우사상 역시 두 개의 침투를 보이고 있는데 수위의 경우는 뒤쪽 침투가 더 큰 것으로 관측되었으나 강우사상의 경우는 앞 쪽 침투가 더 큰 것으로 관측되었으며, 두 개의 침투 사이에 12시간정


도 강우가 관측되지 않은 기간이 있어 이것이 예측에 영향을 미친 것으로 판단된다. 반면에 GA모형의 예측결과는 1~6시간 예측 모두 비슷한 결과를 보여주어 예측시간이 길어져도 오차가 많이 커지는 것은 아니나 예측시간이 짧은 경우에는 BP모형과 GA+BP모형에 비해 오차가 큰 것을 알 수 있다.

상류지점의 수위만을 사용하여 선산지점의 1~6시간 후의 수위를 예측한 경우 Fig. 7과 같은 결과를 얻을 수 있었으며, 앞의 결과와 마찬가지로 1시간 예측의 경우가 가장 실제의 값을 잘 예측하고 있으며 예측시간이 길어질수록 오차가 커지는 것을 알 수 있었다. BP모형과 GA+BP모형의 경우 앞의 결과와 비슷하게 뒤의 침투에 대한 예측은 예측시간이 길어져도 오차가 그렇게 커지지 않는 반면 앞의 침투에 대해서는 오차가 갈수록 커지는 양상을 보였으나 앞의 경우와 같은 예측치의 진동은 나타나지 않았다. GA모형을 사용하여 예측한 결과는 앞의 경우와 같은 양상으로 나타나 1~6시간 예측 모두 비슷한 결과를 보여주었으며, 예측시간이 길어져도 오차가 많이 커지는 것은 아니나 예측시간이 짧은 경우에는 BP모형과 GA+BP모형에 비해 오차가 큰 것을 알 수 있다.


Table 2에서 각 모형에 대한 결정계수 값을 비교하였으며, 그 결과 단시간 강우예측에서는 각 모형별로 결정



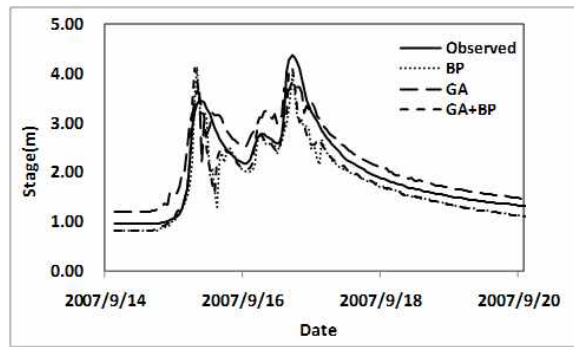
(a) 1hr Prediction




(b) 2hr Prediction




(c) 3hr Prediction



(d) 4hr Prediction



(e) 5hr Prediction



(f) 6hr Prediction

Fig. 6. Prediction Result of Models Using Precipitation and Stage Data

계수의 값이 거의 비슷하게 나타났으나 예측시간이 길어 질수록 유역의 면적 평균 강우량과 상류의 수위를 이용한 모형에서 예측된 값보다 상류의 수위만을 이용한 모형의 값이 더 정확하게 나타났으며, 평균제곱근오차 (RMSE)의 경우도 마찬가지로 상류의 수위만을 이용한 모형의 값이 더 작게 나타나는 것을 알 수 있다.

따라서 면적 평균 강우가 예측에 미치는 영향보다 상류의 수위가 미치는 영향이 더 크다는 것을 알 수 있다. 이는 강우의 평균 면적강우량이 유역의 유출에 정확하게 반영되지 못한 것으로 판단되며, 보다 정확한 예측을 위해서는 면적 평균 강우량이 아닌 각 강우지점의 강우량을 사용할 경우 더 좋은 결과를 보여줄 수 있을 것으로 판단

된다. 또한 GA모형의 경우 결정계수의 값이 크게 나왔으며, 예측시간이 길어져도 결정계수의 값과 평균제곱근 오차의 값의 변화가 다른 모형에 비해 작게 나타나 전체적으로 예측력이 크게 변하지 않는 것을 알 수 있다.

BP모형과 GA+BP 모형의 경우 전체적인 예측형태나 오류의 양상이 비슷한 것으로 나타났으며, 이는 GA모형에 의해 최적화된 상태라 해도 BP모형을 다시 거치면서 BP모형의 결과와 비슷한 형태로 적합(Fitting)된 것으로 판단되며, BP모형에 비해 그다지 향상된 결과를 보여주지 못하였다. 따라서 유전자 알고리즘을 이용하여 신경망의 연결강도를 학습시킨 GA모형에 수위만을 입력 자료로 사용한 모형이 수위예측에 있어서 가장 우수한 결과를

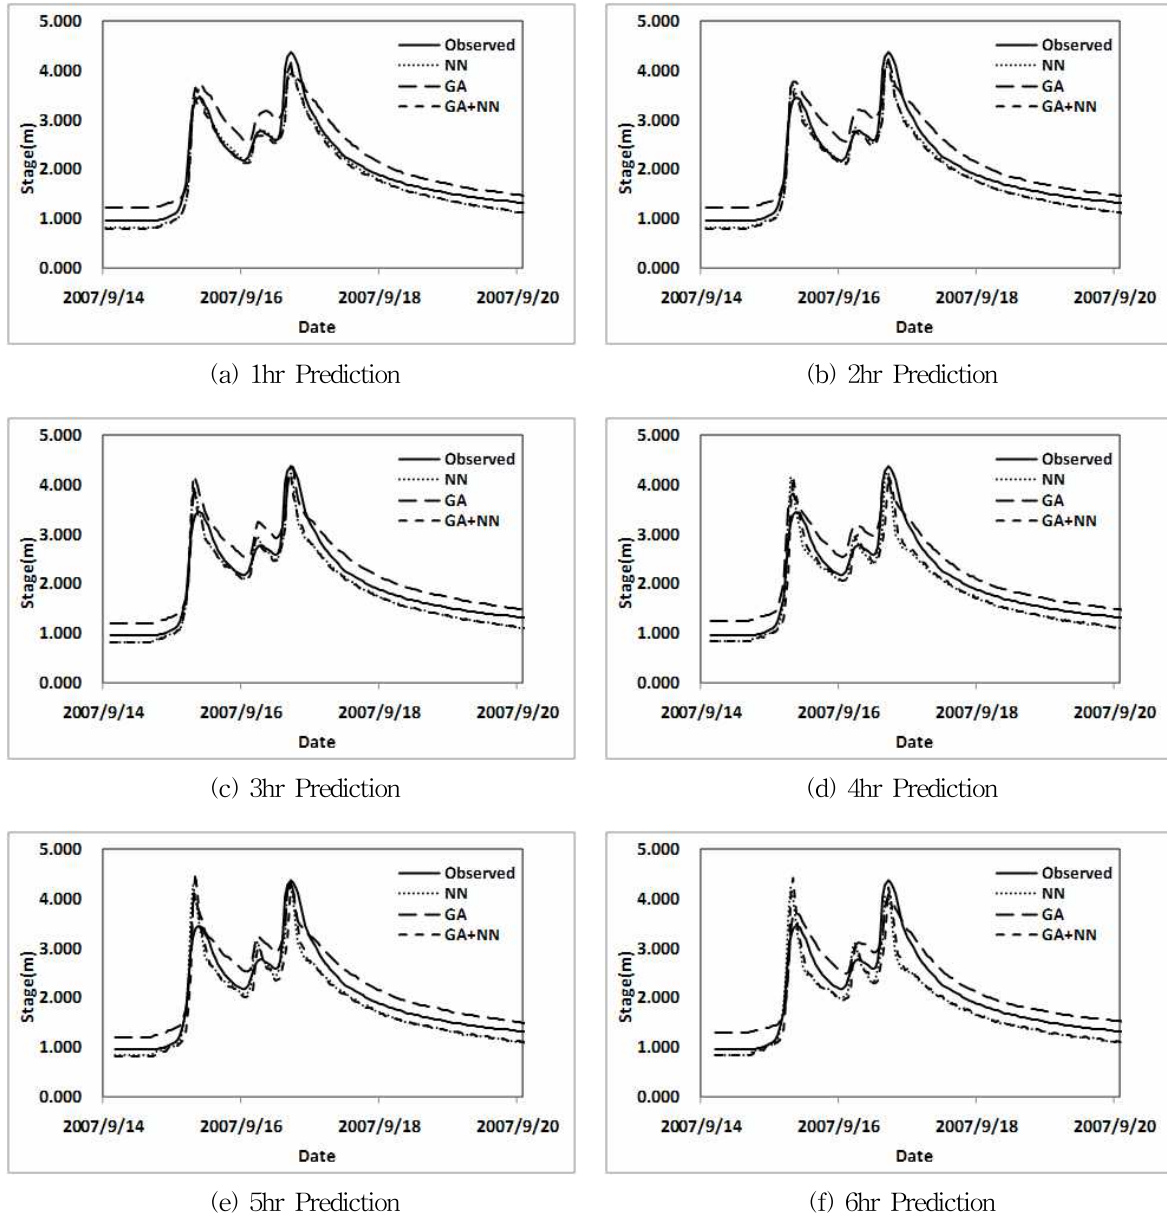


Fig. 7. Prediction Result of Models Using Stage Data

보여주는 것으로 나타났다.

4. 결론

본 연구에서는 인공지능망과 유전자 알고리즘 그리고 두 모형을 결합한 모형을 이용하여 감천유역의 선산 수위 표지점의 수위를 예측하기 위해 감천유역의 과거 강우사상과 감천수위표지점의 수위를 학습시키고 새로운 강우에 대해 1~6시간 후의 수위를 예측해 보았으며, 다음과 같은 결론을 얻을 수 있었다.

- 1) 감천의 면적평균강우량과 감천지점의 수위를 학습시키고 새로운 강우에 대해 1~6시간 후의 수위를

예측한 결과 전체적으로 수위의 변화 추세를 잘 표현하고 있으며, 두 개의 침투 중에서 하나의 침투는 예측의 정도가 매우 높았으나 다른 하나의 침투에 대해서는 예측시간이 길어질수록 오차가 높아짐을 알 수 있었으며, 단일 침투를 가진 사상에 대해서는 예측이 잘 될 것으로 기대된다.

- 2) 감천지점의 수위만을 학습시키고 새로운 강우에 대해 1~6시간 후의 수위를 예측한 결과 전체적으로 면적평균강우량과 수위를 학습시킨 모형보다 수위의 변화추세를 더욱 잘 예측하고 있으며 정도도 더욱 높았다. 또한, 침투부도 더 잘 맞는 것으로 나타났다.

Table 2. Comparison of the R² and RMSE for Each Model

Prediction Time		Models	Precipitation + Stage			Stage Only		
			BP	GA	GA+BP	BP	GA	GA+BP
R ²	1hr		0.97	0.94	0.97	0.97	0.95	0.98
	2hr		0.95	0.96	0.97	0.97	0.96	0.97
	3hr		0.92	0.97	0.94	0.96	0.96	0.96
	4hr		0.90	0.92	0.91	0.94	0.97	0.95
	5hr		0.89	0.95	0.91	0.93	0.96	0.93
	6hr		0.78	0.95	0.88	0.90	0.96	0.92
RMSE	1hr		0.19	0.30	0.17	0.18	0.30	0.19
	2hr		0.24	0.27	0.21	0.19	0.29	0.21
	3hr		0.31	0.26	0.27	0.23	0.27	0.23
	4hr		0.36	0.31	0.32	0.28	0.28	0.27
	5hr		0.37	0.29	0.34	0.28	0.28	0.29
	6hr		0.49	0.28	0.39	0.34	0.28	0.34

- 3) 예측모형에 대한 결정계수와 평균제곱근오차는 각각 0.78~0.98, 0.17~0.49로 나타났으며, 예측시간이 길어질수록 예측력이 조금씩 떨어짐을 알 수 있으나 전체적으로 상당히 큰 값을 보여주고 있어 우수한 예측력을 가진 것을 알 수 있었다. 특히, 면적평균강우량과 수위를 학습시킨 모형보다 수위만 학습시킨 모형이 더욱 우수한 결과를 보여주었다.
- 4) 결정계수와 평균제곱근오차의 값으로부터 GA모형의 경우가 가장 우수한 것으로 나타났으며, 예측시간이 길어져도 결정계수의 값과 평균제곱근오차의 값의 변화가 다른 모형에 비해 작게 나타나 전체적으로 예측력이 크게 변하지 않는 것을 알 수 있다. BP모형과 GA+BP 모형의 경우 전체적인 예측형태나 오류의 양상이 비슷한 것으로 나타났으며 BP모형에 비해 그다지 향상된 결과를 보여주지 못하였다. 이는 GA모형에 의해 최적화된 상태라 해도 BP에 의한 학습을 다시 거치면서 BP모형의 결과와 비슷한 형태로 적합된 것으로 판단된다. 따라서 유전자 알고리즘과 신경망의 결합모형인 GA모형에 수위만을 입력 자료로 사용한 모형이 수위예측에 있어서 가장 우수한 결과를 보여주는 것으로 나타났다.

따라서 단시간 수위예측을 위한 신경망의 모형들은 모두 좋은 결과를 보여주고 있으나 그 학습방법에 있어서 유전자 알고리즘을 사용한 신경망과 유전자모형의 결합모형이 가장 예측력이 우수하였으며, 향후 다양한 유역과 사상에 대한 심화연구를 통해 상류의 수위로부터 하류의 수위를 예측 해 낸다면 단시간 홍수예경보의 정밀도를 더

높일 수 있을 것으로 판단된다.

감사의 글

본 연구는 소방방재청에서 주관하고 있는 자연재해저감기술사업단 연구개발사업(NEMA-자연-08-06)의 일환으로 수행된 “지구단위홍수재해 정보시스템 및 침수저해저감기술개발”의 일부로서 본 연구의 재정지원에 감사드립니다.

참고문헌

김성원 (2000). “하천유역에서 홍수유출량의 예측을 위한 신경망기법의 적용.” **대한토목학회논문집**, 대한토목학회, 제20권, 제6-B호, pp. 801-811.

박성천, 오창열, 김동렬, 진영훈 (2006). “인공신경망 이론을 이용한 홍수유출 예측시스템 개발 -GUI_FFS 개발 및 적용-.” **대한토목학회논문집**, 대한토목학회, 제26권, 제2B호, pp. 145-152.

박성천, 이용, 진영훈, 오창열 (2005). “신경망 이론을 이용한 상·하류지점간의 수위 예측.” **한국수처리학회지**, 한국수처리학회, 제13권, 제3호, pp. 45-54.

오남선, 선우중호 (1996). “신경망이론에 의한 강우예측에 관한 연구.” **한국수자원학회지**, 한국수자원학회, 제29권, 제4호, pp. 109-118.

이순탁, 김성원 (1997). “홍수유출량 예측을 위한 인공신경망모델의 적용에 관한 연구.” **환경연구**, 영남대학교 환경문제연구소, 제16권, 제2호, pp. 47-62.

- 황현경, 김경호 (2008). “신경망 모형을 이용한 무심천 수위 예측.” *건설기술연구논문집*, 충북대학교, 제27권, 제1호, pp. 43-56.
- Bazartseren, B., Hildebrandt, G., and Holz, K.P. (2003). “Short-term water level prediction using neural networks and neuro-fuzzy approach.” *Neurocomputing*, Vol. 55, No. 3-4, pp. 439-450.
- Chau, K.W. (2006). “Particle swarm optimization training algorithm for ANNs in stage prediction of shing mun river.” *Journal of Hydrology*, Vol. 329, No. 3-4, pp. 363-367.
- De Jong, K.A. (1975). *An analysis of the behavior of a class of genetic adaptive systems*. Ph.D dissertation, The University of Michigan, Ann Arbor, Michigan.
- French, M.N., Krajewski, W.F., and Cuykendall, R.R. (1992). “Rainfall forecasting in space and time using a neural network.” *Journal of Hydrology*, Vol. 137, No. 1-4, pp. 1-31.
- Goldberg, D.E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Addison-Wesley.
- Holland, J.H. (1975). *Adaptation in natural and artificial systems*. University of Michigan Press.
- Janikow, C.Z., and Michalewicz, Z. (1991). “An experimental comparison of binary and floating point representations in genetic algorithms.” *Proceedings 4th International Conference on Genetic Algorithms*, California. pp. 31-36.
- Kuligowski, R.J., and Barros, A.P. (1998). “Experiments in short-term precipitation forecasting using artificial neural networks.” *Monthly Weather Review*, Vol. 126, No. 2, pp. 470-482.
- Maniezzo, V. (1994). “Genetic evaluation of the topology and weight distribution of neural network.” *IEEE Transaction of Neural Network*, Vol. 5, No. 1, pp. 39-53.
- McCulloch, W.S., and Pitts, W. (1943). “A logical calculus of the ideas immanent in nervous activity.” *Bulletin of Mathematical Biophysics*, Vol. 5, No. 4, pp. 115-133.
- Michalewicz, Z. (1996). *Genetic algorithms + data structures=evolution programs (3rd ed.)*. Springer-Verlag, Berlin Heidelberg.
- Montana, D.J., and Davis, L. (1988). “Training feed-forward neural networks using genetic algorithms.” *Proceedings 11th International Joint Conference on Artificial Intelligence*, San Mateo, California, Vol. 1, pp. 762-767.
- Napolitano, G., See, L., Calvo, B., Savi, F., and Heppenstall, A. (2009). “A conceptual and neural network model for real-time flood forecasting of the Tiber river in Rome.” *Physics and Chemistry of the Earth*, Vol. 35, No. 3-5, pp. 187-194.
- Nasseri, M., Asghari, K., and Abedini, M.J. (2008). “Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network.” *Expert Systems with Applications*, Vol. 35, No. 3, pp. 1415-1421.
- Pham, D.T., and Jin, G. (1995). “Genetic algorithm using gradient-like reproduction operator.” *Electronics Letters*, Vol. 31, No. 18, pp. 1558-1559.
- Pham, D.T., and Jin, G. (1996). “A hybrid genetic algorithm.” *Proceedings of 3rd World Congress on Expert Systems*, Seoul, Korea, Vol. 2, pp. 748-757.
- Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986). “Learning representations by back-propagating errors.” *Nature*, Vol. 323, pp. 533-536.
- Sedki, A., Ouazar, D., and Mazoudi, E.E. (2009). “Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting.” *Expert Systems with Applications*, Vol. 36, No. 3, pp. 4523-4527.
- Srinivasulu, S., and Jain, A. (2006). “A comparative analysis of training methods for artificial neural network rainfall-runoff models.” *Applied Soft Computing*, Vol. 6, No. 3, pp. 295-306.
- Thirumalaiah, K., and Deo, M.C. (1998). “Real-time flood forecasting using neural networks.” *Computer-Aided Civil and Infrastructure Engineering*, Vol. 13, No. 2, pp. 101-111.
- Wilson, G., and Khondker, M.H. (2000). “Data selection for a flood forecasting neural network.” *Proceedings of the 4th International Conference on Hydroinformatics 2000*, Iowa, USA.

논문번호: 10-060	접수: 2010.07.13
수정일자: 2010.08.04	심사완료: 2010.08.04