

앙상블 유량예측의 정확도 향상을 위한 강우-유출모형에 대한 연구

- I. 신경망 강우-유출모형 -

A Study on Rainfall-Runoff Models for Improving Ensemble Streamflow Prediction

- I. Rainfall-runoff Models Using Artificial Neural Networks-

정대일* · 김영오** · 조성준*** · 신현정****

Jeong, Dae-Il · Kim, Young-Oh · Cho, Sung-Zoon · Shin, Hyun-Jung

Abstract

The previous ESP (Ensemble Streamflow Prediction) studies conducted in Korea reported that the modeling error is a major source of the ESP forecast error in winter and spring (i.e. dry seasons), and thus suggested that improving the rainfall-runoff model would be critical to obtain more accurate probabilistic forecasts with ESP. This study used two types of Artificial Neural Networks (ANN), such as a Single Neural Network (SNN) and an Ensemble Neural Networks (ENN), to improve the simulation capability of the rainfall-runoff model of the ESP forecasting system for the monthly inflow to the Daecheong dam. Applied for the first time to Korean hydrology, ENN combines the outputs of member models so that it can control the generalization error better than SNN. Because the dry and the flood season in Korea shows considerably different streamflow characteristics, this study calibrated the rainfall-runoff model separately for each season. Therefore, four rainfall-runoff models were developed according to the ANN types and the seasons. This study compared the ANN models with a conceptual rainfall-runoff model called TANK and verified that the ANN models were superior to TANK. Among the ANN models, ENN was more accurate than SNN. The ANN model performance was improved when the model was calibrated separately for the dry and the flood season. The best ANN model developed in this article will be incorporated into the ESP system to increase the forecast capability of ESP for the monthly inflow to the Daecheong dam.

Keywords : daechung dam, ensemble neural networks, ensemble streamflow prediction, rainfall-runoff model, TANK model

요 지

앙상블 유량예측기법을 국내에 적용할 경우 유출량이 적은 겨울과 봄 등 갈수기 예측오차는 일반적으로 강우-유출모형의 불확실성에 기인한다. 이러한 문제점을 해결하기 위해 앙상블 유량예측기법의 핵심인 강우-유출모형의 근본적인 개선이 시급한 과제이다. 본 연구에서는 대청댐 월 유입량 앙상블 유량예측에 사용할 수 있는 강우-유출모형을 단일 신경망모형과 앙상블 신경망모형을 이용하여 구성하였다. 앙상블 신경망모형은 복수의 멤버 모델들의 결과를 조합함으로써 단일 신경망에 비해 더 좋은 일반화 성능을 보인다고 알려져 있는 방법으로, 본 연구를 통해 국내 수문현상 해석을 위해 처음으로 소개 되었다. 또한, 신경망 강우-유출모형의 모의능력을 향상시키기 위해 유출현상이 상이한 갈수기와 홍수기로 나누어 신경망 강우-유출모형을 구성하는 방안도 시도되었다. 따라서 신경망모형의 종류와 갈수기-홍수기 유출현상의 고려여부에 따라 총 4가지 강우-유출모형이 본 연구를 통해 개발되었다. 개발된 신경망 강우-유출모형은 대표적 개념모형인 TANK모형과의 비교를 통해 모의능력의 우수함을 증명하였으며 적용가능성을 입증하였다. 앙상블 신경망모형과 단일 신경망모형의 비교에서는 본 연구를 통해 새롭게 소개된 앙상블 신경망모형의 모의능력이 더 우수하였다. 갈수기와 홍수기로 나누어 구성한 강우-유출모형이 이를 고려하지 않은 모형보다 정확한 모의를 할 수 있었으며, 신경

*정회원 · 서울대학교 지구환경시스템공학부 · 박사과정(E-mail: jung922@snu.ac.kr)

**정회원 · 서울대학교 지구환경시스템공학부 · 조교수(E-mail: yokim05@snu.ac.kr)

***서울대학교 산업공학과 · 조교수(E-mail: zoon@snu.ac.kr)

****서울대학교 산업공학과 · 박사과정(E-mail: hjshin72@snu.ac.kr)

망을 이용한 강우-유출모형을 구성할 경우에는 유출특성을 고려할 경우 좀더 정확한 모의를 할 수 있음을 확인하였다. 본 연구를 통해 개발된 강우-유출모형은 대청댐 월 유입량을 위한 앙상블 유량예측기법에 이용되어 겨울철 유량예측의 정확성을 크게 향상시킬 것으로 기대한다.

핵심용어 : 강우-유출모형, 대청댐, 앙상블 유량예측, 앙상블 신경망모형, TANK모형

1. 서 론

미국 기상청인 National Weather Service에서는 확률론적 예측기법의 하나인 Ensemble Streamflow Prediction (ESP; 이하 앙상블 유량예측)이 21세기 수문학적 예측시스템의 핵심기법으로 이용되고 있다(Fread, 1998). 국내에서는 김영오 등(2001)이 건설교통부와 한국건설기술연구원이 매월 초 발간하는 ‘물공급전망’의 개선을 위해 공주 지점에 앙상블 유량예측기법을 적용한 이후 다양한 적용 사례를 통해 적용 가능성과 개선방향이 현재 모색되고 있다. 특히 ‘21세기 프론티어연구개발사업’인 수자원의 지속적 확보기술개발사업단의 ‘실시간 물관리 운영시스템 구축 기술개발’에서는 앙상블 유량예측을 체계학적 최적화 모형인 sampling stochastic dynamic programming에 접목하여 저수지 연계운영에 이용할 수 있는 방안을 연구하고 있다. 그러므로 저수지 연계운영의 성공 여부는 앙상블 유량유량예측의 정확성에 의해 상당 부분 좌우될 것으로 전망되고 있다.

앙상블 유량예측은 강우-유출모형에 미래에 일어날 가능성이 있는 모든 강우 시나리오를 입력하고 그 결과물로서 다수의 유량 시나리오를 발생시켜 확률예측을 실시하는 예측기법이다. 정대일과 김영오(2002)는 충주댐의 유입량 확률예측을 위해 적용한 앙상블 유량예측기법의 결과분석을 통해 앙상블 유량예측의 정확성을 향상시키기 위해서 겨울철에는 강우-유출모형의 모의능력을 개선해야 하며, 여름철에는 강우량 예측과 같은 기상예보를 효율적으로 이용해야 한다고 지적한 바 있다. 즉 유출량이 적은 겨울철에는 대부분의 오차가 강우-유출모형의 오차이며, 상대적으로 유출이 많은 여름철에는 강우-유출모형의 오차 비율은 줄어드는 반면, 예측기간의 강우량을 과거의 강우 앙상블에만 의존함으로써 발생하는 오차가 지배적임을 확인하였다. 따라서 겨울철 앙상블 유량예측의 정확성 향상을 위해서는 앙상블 유량예측기법의 핵심인 강우-유출모형의 근본적인 개선이 시급하며 이것이 본 연구의 목적이다.

일반적으로 앙상블 유량예측에서는 개념적 강우-유출모형이 사용되었다. 그러나 현재 국내에서 사용 중인 개념적 강우-유출모형은 많은 연구사례에도 불구하고 정확도가 떨어지는 것이 사실임을 인정하지 않을 수 없다. 이를 개선하기 위해서는 사용 중인 강우-유출모형의 근본적인 개선에 노력을 경주해야 할 것이다. 그러나 국내 수문학자들의 꾸준한 노력에도 불구하고 복잡한 매개변수 추정

과 입력자료 구성 등의 어려움으로 인하여 가까운 장래에 정확도를 높이는 어렵다고 보여진다. 그러므로 본 연구에서는 강우-유출 모의에 적합한 장점을 가지고 있는 신경망모형을 이용하여 앙상블 유량예측에 이용할 수 있는 방안을 강구하였다. 본 논문에서 제시된 신경망모형은 이어지는 후속논문(정대일 등, 2003)에서 기존의 개념적 모형과 결합되는 방안을 통해 유출의 모의능력을 궁극적으로 향상시키고자 시도되었다.

신경망모형은 입력과 출력으로 구성되는 시스템을 병렬적이고 비선형적으로 구축할 수 있다는 장점이 있어 1990년 이후부터 강우-유출 모의에 많이 사용되고 있다. 대표적인 적용사례로서 Hsu *et al.*(1995)은 신경망모형을 이용하여 강우-유출모형을 구성하여 모의한 후 ARMAX 모형과 SAC-SMA모형의 모의능력과 비교하여 신경망모형이 좀더 좋은 결과를 나타냄을 확인한 바 있다. Thirumalaiah(1998)는 신경망모형을 실시간 홍수위 예측에 이용하였으며, Coulibaly *et al.*(2000)은 일 저수지 유입량예측을 위해 early stoping 기법을 이용한 신경망모형을 적용한 바 있다. 국내 적용사례로서 신현석과 박무중(1999)은 신경망모형을 이용하여 우리나라의 가뭄을 시공간적으로 해석하였고, 안상진 등(2000)은 유출수문곡선의 예측을 위해 신경망모형을 적용하였으며, 김성원(2000)은 풍수년, 평수년, 갈수년 등 유출 특성에 따라 자료를 구분하고 신경망을 적용하여 특성이 상이한 유출현상도 신경망모형으로 모형화가 가능함을 확인한 바 있다. 언급된 연구사례 이외에도 신경망모형은 강우-유출현상을 모의하기 위해 최근 활발히 적용되고 있다.

본 연구에서는 일반적인 다층 신경망 모형으로 구성된 단일 신경망(Single Neural Network, SNN)모형과, 두개 이상의 다층 신경망 모형의 출력값을 조합하는 방법인 앙상블 신경망(Ensemble model of Neural Networks, ENN)모형을 대청댐 월 유입량 모의에 적용하였다. 앙상블 신경망모형은 다수의 모형을 조합함으로써 일반화(generalization) 성능을 향상시키는 기능이 뛰어난 신경망모형의 종류 중 하나이다. 여기서 일반화란 신경망모형의 학습에 이용된 자료가 아닌 새로운 자료에 대한 신경망모형의 모의능력을 의미한다. Cannon and Whitfield(2002)는 ENN기법 중 하나인 bagging(또는 bootstrap aggregation)기법을 이용하여 기상조건과 유출조건간의 관계를 downscaling할 수 있는 모형을 구성하여 수문분야에 소개한 바 있다. 국내 수문분야에서는 ENN기법이 아직 적용된 사례가 없으

며 본 연구를 통해 유출현상 모의를 위해 처음으로 적용 가능성을 살펴보았다.

갈수기 유출은 주로 지하수 유출이 대부분이나, 홍수기 유출은 지표수 유출의 비율이 크다. 따라서 두 유출현상의 특성은 상당히 다른 함수관계에 있다고 생각할 수 있다. 신경망의 경우 특성이 다른 자료들을 기간별로 분리하여 학습할 경우 조금 더 좋은 결과를 기대할 수 있다. 그러므로 본 연구에서는 갈수기와 홍수기로 분리하여 두 개의 모형으로 구성하는 방법에 대해서도 연구하였다.

본 연구는 대청댐 월 유입량 확률예측을 위해 앙상블 유량예측기법에 이용할 수 있는 강우-유출모형을 단일 신경망모형(SNN)과 앙상블 신경망모형(ENN)을 이용하여 구성하였다. 이 모형들은 다시 전체 월(1월~12월) 자료를 이용한 모형(SNN_{all}, ENN_{all})과 갈수기(10월~5월)와 홍수기(6월~9월)로 분리한 모형(SNN_{d-f}, ENN_{d-f})으로 나누어 총 4개의 강우-유출모형을 본 연구에서 개발하였으며 각 모형의 모의 정확도를 비교 평가하였다. 또한 한국수자원공사에서 현재 대청댐에 사용 중인 대표적 개념모형인 TANK모형과 비교하여 대청댐 월 유입량 모의를 위하여 신경망 강우-유출모형의 적용 가능성을 살펴보았다.

2. 신경망이론

신경망이론은 인간의 정보처리 과정을 수학적으로 표현하여 병렬 분산 처리가 가능하며, 다양한 환경에 적용할 수 있는 학습능력을 보유하고 있다. 이러한 특성으로 영상 신호처리, 패턴 인식, 시스템 제어, 시계열분석 및 다양한 예측분야에서 널리 사용되고 있다(Haykin, 1999). 특히 수문학 분야에서는 입력과 출력으로 표현되는 강우-유출모형에 널리 사용되고 있다. 여기서는 신경망 이론의 일반사항은 생략하고 본 연구에서 사용된 심화이론을 중심으로 서술하겠다.

2.1 단일 신경망(SNN)모형

단일 신경망모형은 이후 설명될 앙상블 신경망모형과 구별하기 위한 용어로서 일반적으로 1개의 네트워크로 구성된 다층 신경망모형(multilayer neural network)을 의미한다. 다층 신경망모형은 입력층(input layer), 출력층(output layer), 그리고 두 층 사이에 은닉층(hidden layer)으로 구성되어 있다. 각 층에는 노드(node)가 존재하며, 층과 층사이의 노드는 방향성과 연결강도를 가진 시냅스(synapse)에 의해 연결된다. 연결강도에 따라 입력에 대한 출력값이 결정되며 연결강도는 전달함수에 의해 조정된다.

출력성분은 O_k , 은닉층의 성분은 V_j , 그리고 입력성분은 I_i 라고 하고 입력층에서 은닉층으로의 연결강도와 은닉층에서 출력층으로의 연결강도는 각각 w_{ji} , w_{kj} , 입력층 bias(편의)를 I_0 , 은닉층의 편의를 V_0 라고 정의하면 은닉층이




그림 1. 다층 신경망모형의 구조

하나인 다층 신경망모형은 그림 1과 같이 표현될 수 있으며 각 연결강도에 의한 출력값은 식 (1)과 같다.

$$O_k = g_2 \left(\sum_j w_{kj} g_1 \left(\sum_i w_{ji} I_i + w_{j0} \right) + w_{k0} \right) \quad (1)$$

여기서, 전달함수 $g_1(x)$, $g_2(x)$ 는 은닉층과 출력층의 값을 산출하는 전달함수로서 미분가능하고 적용이 용이한 sigmoid 함수를 많이 사용하고 있다.

다층 신경망모형의 학습에는 주로 입력패턴을 이용해 신경망 네트워크가 계산한 출력값과 목표값의 오차를 최소화시키는 방향으로 연결강도를 조정해가는 학습 알고리즘이 사용된다. 본 연구에서는 학습 알고리즘으로 Levenberg-Marquardt 방법을 이용하였다. 이 방법은 출력값의 오차 제곱합(sum of square error)을 최소화하는 최적화 기법을 사용하여 학습속도의 향상과 지역최소값 수렴 문제를 개선하였다. 이 방법은 연결강도 조정을 위해 Levenberg-Marquardt 갱신률(ΔW)을 사용하며 식 (2)와 같다.

$$\Delta W = (J^T J + \mu I)^{-1} J^T e \quad (2)$$

여기서 J 는 Jacobian 매트릭스로서 신경망 오차를 식 (1)의 각 가중값과 bias로 1차 미분한 값들로 이루어져 있다. e 는 오차벡터, 상수 μ 는 적용학습률이다. μ 가 매우 크면 경사하강(gradient descent)법으로 근사되고, μ 가 작으면 Gauss-Newton으로 근사된다. 또한 μ 가 0이면 Hessian 매트릭스를 이용하여 근사하는 Newton 기법이 된다. 가우스-뉴턴 방법은 오차공간상의 최소점 근방에서 다른 방법에 비하여 더 빠르고 정확하게 수렴해 나간다. 따라서 적용학습률에서 μ 를 조정하여 가능하면 Gauss-Newton으로 근사하도록 한다(Demuth and Beale, 1998).

Early stopping 기법은 일반화기능을 향상시키기 위한 방법으로, 학습에 사용될 자료집합(data set)을 training 집합과 validation 집합으로 나누어 이용하는 방법이다. training 집합은 신경망을 학습시키는데 사용되며, validation 집합은 학습에 직접 사용되지 않으나 신경망이 과적합(overfitting)되지 않게 하기 위해 사용된다. 학습이 진행되면서 training 집합과 validation 집합의 오차는 함께 감

소하다가, 과적합이 발생하면 training 집합의 오차는 계속해서 감소하는데 비해 validation 집합의 오차는 오히려 증가하게 된다. 즉, 과적합은 학습 자료에 대한 모의오차는 매우 작고 반대로 학습에 이용되지 않은 새로운 자료에 대한 모의오차는 매우 큰 상태를 나타내는 말이다. validation 집합의 오차가 증가하기 시작하면 미리 설정한 목표오차에 도달하지 않아도 학습을 멈추게 되는데 이런 이유로 early stopping 기법으로 불린다(Haykin, 1999).

2.2 앙상블 신경망(ENN)모형

앙상블 신경망모형은 출력변수가 같은 복수의 신경망모형의 출력값을 조합함으로써 최종 출력값을 결정하는 모형이다. 앙상블 신경망모형은 독립된 단일 신경망모형에 비해 일반화 성능을 향상시킬 수 있다고 알려져 있다. 그림 2는 앙상블 신경망모형을 그림으로 나타낸 것이다. 그림의 각 멤버모델은 하나하나가 독립된 신경망모형들이다. 멤버모델들의 집합이 앙상블을 이루므로 앙상블 신경망모형이라고 한다. 여기서 '앙상블 유량예측'에서의 '앙상블'은 강우나 유량 시나리오의 집합을 의미하나, '앙상블 신경망모형'에서의 '앙상블'은 목적변수가 같은 멤버모델들의 집합을 의미하므로 구별하기 바란다.

$O_i(x)$ 를 i 멤버모델의 출력값, $t(x)$ 를 목표값 그리고 ε_i 를 오차($O_i(x)-t(x)$)라하면 i 멤버모델의 오차제곱합의 기대값 E_i 는 식 (3)과 같이 쓸 수 있다. 각 멤버모델은 입출력 구조와 연결강도를 가진 독립된 하나의 신경망모형으로 고유의 학습방법, 연결강도, 전달함수를 가지므로 출력값 역시 서로 다른 다양성을 지니고 있다.

$$E_i = E[(O_i(x) - t(x))^2] = E[\varepsilon_i^2] \quad (3)$$

여기서 $E[\cdot]$ 는 기대값 연산자로서 E_i 와는 구별하기 바란다.

앙상블 신경망모형의 일반화 성능이 단일 신경망에 비해 우수한 이유는 식 (4)를 통해 설명할 수 있다. E_{com} 은 L 개의 멤버모델로 구성된 앙상블 신경망모형의 오차제곱합의 기대값, E_{AV} 는 L 개의 멤버모델 각각의 오차제곱합의 기대값이라면, 이 두 값의 관계는 식 (4)와 같이 정리할 수 있다.

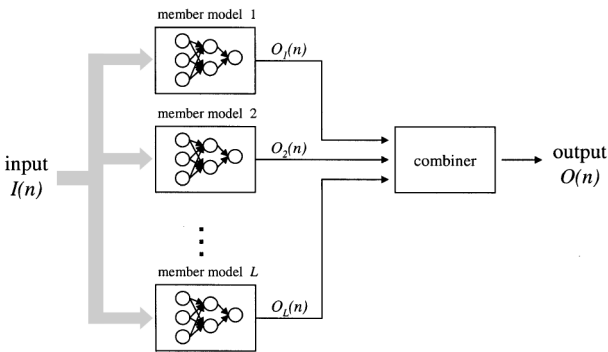


그림 2. 앙상블 신경망모형의 block diagram

$$\begin{aligned} E_{com} &= E[(O_{com}(x) - t(x))^2] \\ &= E\left[\left(\frac{1}{L} \sum_i O_i(x) - t(x)\right)^2\right] \\ &= \frac{1}{L^2} E\left[\left(\sum_i O_i(x) - Lt(x)\right)^2\right] \\ &= \frac{1}{L^2} E\left[\left(\sum_i \varepsilon_i\right)^2\right] \\ &\leq \frac{1}{L^2} E\left[L \left(\sum_i \varepsilon_i\right)^2\right] = E_{AV} \end{aligned} \quad (4)$$

만일 이 식에서 각 오차들 간에 상관성이 없다면 즉, 서로 다른 i, j 에 대하여 $E[\varepsilon_i \varepsilon_j] = 0$ 이면 식 (4)는 식 (5)와 같이 정리된다.

$$E_{com} = \frac{1}{L^2} E\left[\left(\sum_i \varepsilon_i\right)^2\right] = \frac{1}{L^2} \sum_i E[\varepsilon_i^2] = \frac{1}{L} E_{AV} \quad (5)$$

결과적으로 E_{com} 은 E_{AV} 의 $1/L$ 배가 되는데 그 이유는 평균하는 과정에서 오차의 분산이 감소하기 때문이다. 따라서 앙상블 신경망모형은 bias(편의)가 작고 variance(분산)이 큰 현상을 모의하기에 적합한 방법이다.

앙상블 방법은 멤버모델들의 다양성을 확보하는 방법에 따라 몇 가지 종류로 나눌 수 있는데 가장 흔히 사용되는 방법은 Breiman(1996)이 제안한 bagging 기법이다. 이 기법은 멤버모델의 다양성을 확보하기 위해서 입력자료(그림 2에서 $I(n)$)를 bootstrap 기법으로 복원추출하여 여러 개의 학습자료를 재구성한다. 재구성된 입력자료는 각 멤버모델의 입력자료로 사용되어 서로 다른 연결강도를 가진, 완전히 다른 모형으로 학습된다. 최종 출력값($O(n)$)은 각 멤버모델의 다양한 출력값을 평균함으로써 얻을 수 있다. bagging 기법에서 분산을 감소시키기 위한 가장 중요한 요소는 멤버모델의 개수인데 Breiman은 적어도 25개 이상의 멤버모델로 앙상블 신경망모형을 구성할 것을 제안하였다.

3. 모형의 적용

3.1 모형구성의 개요

단일 신경망(SNN)모형과 bagging 기법을 이용한 앙상블 신경망(ENN)모형을 이용하여 대청댐 월 유입량 모의를 위한 강우-유출모형을 구성하였다. 신경망을 이용하여 구성된 강우-유출모형은 개념적 모형의 입력변수로 흔히 사용되는 대청댐 유역의 월 총강우량(R_t, R_{t-1}, \dots), 월 총증발량(E_t, E_{t-1}, \dots), 모의 이전의 월 평균유입량(I_{t-1}, I_{t-2}, \dots)을 입력변수로 선정하였고, 모의하고자 하는 월의 평균유

입량(I_t)을 출력변수로 설정하여 식 (6)의 입출력 구조를 갖도록 하였다. 학습을 위해 이용된 자료는 1981년부터 1995년까지의 월 자료들이며, 1996년부터 2001년까지 모의를 실시하고 TANK모형의 모의유입량과 비교하여 그 적용가능성을 살펴보았다. 식 (6)은 강수량, 증발량 등을 이용하여 유입량(I_t)을 모의하는 개념적 강우-유출모형과 기본원리는 동일하다.

$$T_t = f((R_t, R_{t-1}, \dots), (E_t, E_{t-1}, \dots), (I_{t-1}, I_{t-2})) \quad (6)$$

TANK모형은 '수문자료비도분석 및 일유출 모의시스템 구축용역'(한국수자원공사, 2001)에서 단순3단 TANK모형과 이산맥동 응답함수를 조합하여 개선한 모형을 본 연구에서도 이용하였다. 이 TANK모형의 매개변수는 1981년에서 1988년까지 8년간의 자료를 이용하여 추정되었으며 본 연구에서도 보고서에 제시된 매개변수를 그대로 사용하였다. TANK모형은 집중형(lumped) 강우-유출모형의 하나로 강우와 유출 현상에 내재된 물리적 유사성을 표현할 수 있다는 장점이 있다.

식 (6)에서 t 시점의 예측된 강수량(R_t)과 증발량(E_t)을 입력하면 예측유입량(\hat{I}_t)을 모의함으로써 유량예측이 가능하다. 앙상블 유량예측은 R_t 와 E_t 의 과거자료를 다수 입력하여 같은 수의 유출량 시나리오를 얻는 기법이다. 따라서 신경망을 이용하여 식 (6)의 입출력 구조를 가지는 강우-유출모형을 구성하고 이를 앙상블 유량예측기법의 강우-유출모형으로 대체하여 이용할 수 있다. 또한 예측시점 이전 월의 실측강수량(R_{t-1}, \dots), 증발량(E_{t-1}, \dots), 유입량(I_{t-1}, \dots)이 입력변수에 포함되어 있으므로 예측시점의 초기조건을 강우-유출모형에 반영할 수 있다.

그림 3은 대청댐의 월별 유입량의 box-plot을 그린 것이다. 평균유입량 100 CMS를 기준으로 그 이상을 홍수기(6월~9월), 이하를 갈수기(10월~5월)로 구분하였다. 그림에서 갈수기와 홍수기의 유입량에 상당한 차이가 있음을 확인할 수 있다. 단, 6월의 경우 5월과 유량에 있어 큰 차이가 있지는 않으나, 홍수기에 신경망을 적용하여 학습하기 위해서는 최소 4개월 정도의 자료는 필요하였으므로 6월




그림 3. 대청댐 월별 유입량 box-plot(1981년~2001년)

을 홍수기에 포함시켰다. 따라서 단일 신경망(SNN)모형과 앙상블 신경망(ENN)모형은 다시, 입력 자료를 모든 월(1월~12월)로 학습시킨 전월 모형과(SNN_{all}, ENN_{all}), 갈수기(10월~5월)와 홍수기(6월~9월)로 나누어 학습시킨 갈수기-홍수기모형(SNN_{d-f}, ENN_{d-f})으로 구성하여 총 4가지 방법으로 강우-유출모형을 구성하고 모의능력을 비교·평가하였다.

3.2 단일 신경망(SNN)모형의 적용

단일 신경망모형을 이용한 강우-유출모형은 다음과 같은 방법을 통해 구성하였다. 먼저 신경망의 효율을 높이고 왜곡이나 잡음에 의해 변형된 자료를 바로 잡으며 입력과 출력의 차원을 일원화하기 위하여 모든 입력자료는 0~1 사이로 정규화 하였으며, 학습알고리즘으로는 Levenberg-Marquardt 알고리즘을 사용하였다. 입력층에서 은닉층으로의 전달함수는 수문학 분야에서 많이 사용되는 log-sigmoid 함수를 사용하였으며, 은닉층에서 출력층으로의 전달함수는 출력변수가 유입량이라는 연속변수임을 감안하여 linear 함수를 이용하였다. 그리고 학습효율을 높이고 과적합을 막기 위해 early stopping 방법을 사용하였다.


입력변수와 은닉층 노드 수를 결정하기 위해서는 경험적 방법을 이용하였다. 먼저, SNN_{all}모형의 입력변수 결정에 대해 설명하면 다음과 같다. 학습에 이용될 1981년에서 1995년까지의 각 입력변수들의 4개월 지체자료($(R_t, \dots, R_{t-4}), (E_t, \dots, E_{t-4}), (I_{t-1}, \dots, I_{t-4})$)와 목표값(I_t)의 상

표 1. 출력변수(\hat{I}_t)와 입력변수들의 상관계수


	실측유입량(I)	강수량(R)	증발량(E)
t	1.000	0.929	0.223
t-1	0.408	0.503	0.350
t-2	0.164	0.190	0.428
t-3	-0.090	-0.058	0.316
t-4	-0.157	-0.228	-0.273

표 2. 입력변수 변화에 대한 신경망모형의 입출력 관계식

모형	입출력 관계식
model1	$\hat{I}_t = f((R_t, \dots, R_{t-4}), (E_t, \dots, E_{t-4}), (I_{t-1}, \dots, I_{t-4}))$
model2	$\hat{I}_t = f((R_t, \dots, R_{t-4}), (E_t, \dots, E_{t-4}), (I_{t-1}, \dots, I_{t-3}))$
model3	$\hat{I}_t = f((R_t, \dots, R_{t-3}), (E_t, \dots, E_{t-4}), (I_{t-1}, \dots, I_{t-3}))$
model4	$\hat{I}_t = f((R_t, \dots, R_{t-3}), (E_t, \dots, E_{t-3}), (I_{t-1}, \dots, I_{t-3}))$
model5	$\hat{I}_t = f((R_t, \dots, R_{t-3}), (E_t, \dots, E_{t-3}), (I_{t-1}, \dots, I_{t-2}))$
model6	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, \dots, E_{t-3}), (I_{t-1}, I_{t-2}))$
model7	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}, I_{t-2}))$
model8	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}))$
model9	$\hat{I}_t = f((R_t, R_{t-1}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}))$
model10	$\hat{I}_t = f((R_t, R_{t-1}), (E_t, E_{t-1}), (I_{t-1}))$



(a) 상관계수




(b) RMSE


그림 4. 입력구조 변화에 대한 단일 신경망(SNN_{all})모형의 모의능력 비교

관계수를 계산하였으며 결과는 표 1과 같다. 입력변수와 출력변수(I_t)의 상관계수와 지체시간을 고려하여 지체시간이 길고 상관계수가 낮은 입력변수들을 하나씩 탈락시켜가며 표 2와 같은 여러 가지 모형을 구성한 후 검증(test)하였다. 이때 처음 은닉층 노드 수는 10개로 고정하였다. 강우-유출 현상은 비선형적이고 복잡한 함수관계에 있으므로 상관계수가 입력변수를 결정하는 결정적 근거라고 할 수는 없으나, 보조적인 역할은 충분히 할 수 있기 때문에 입력변수 포함여부의 기준으로 이용하였다. 각 모형의 모의능력 비교지표로는 실측유입량(I_t)과 모의유입량(\hat{I}_t)의 상관계수와 평균제곱오차(Root Mean Square Error, RMSE)를 사용하였고 이를 그림 4에 도시하여 비교하였다. training 기간은 1981년에서 1992년까지, validation 기간은 1993년에서 1995년까지, test 기간은 1996년에서 2001년까지이다. 일반적으로 training 과 validation을 합한 기간을 calibration 기간, test 기간을 verification 기간이라고 한다. 그림 4에서의 비교결과 model8은 validation 구간과 test 구간 모두에서 상관계수가 가장 높고, RMSE가 가장 낮은 것을 확인 할 수 있다. 따라서 SNN_{all} 모형은 model8의 입력구조를 갖도록 결정하였다.

은닉층 노드 수는 다음과 같이 결정되었다. 먼저 model8의 입력구조를 가진 신경망 모형에서 은닉층 노드 수를 변화시켜 가며 실측유입량과 모의유입량의 상관계수와 RMSE의 변화를 살펴보았다. 그 결과 그림 5에서 보는 바와 같이 은닉층 노드 수가 4일 때 validation과 test 구간 모두에서 상관계수가 가장 높고 평균제곱오차는 낮음



(a) 상관계수



(b) RMSE

그림 5. 은닉층 노드 수 변화에 대한 model8의 모의능력 비교 (SNN_{all}모형)


을 확인할 수 있었다. 신경망모형은 연결강도와 bias의 초기값을 난수로 결정함으로써 학습에 따라 조금씩 다른 출력값을 가진다. 따라서 본 연구에서는 표 2에 제시한 각각의 입력력 모형에 대해 20번의 학습결과에 따른 validation과 test 구간의 상관계수와 RMSE를 평균한 값을 비교하여 최적모형을 결정하였다.

단일 신경망모형의 갈수기-홍수기모형(SNN_{d-f})도 입출력 변수를 갈수기(10월~5월)와 홍수기(6월~9월)로 나눈 후 SNN_{all}모형의 방법과 같은 절차를 거쳐 최적모형을 결정하였다.


3.3 앙상블 신경망(ENN)모형의 적용

앙상블 신경망모형을 이용한 강우-유출모형은 Levenberg-Marquardt 역전파 알고리즘, 입력층에서 은닉층으로의 log-sigmoid 함수, 은닉층에서 출력층으로의 linear 전달함수, early stopping기법을 사용하여 단일 신경망모형과 동일한 방법으로 구성하였다. 앙상블 신경망모형에서 결정해야하는 멤버모델의 개수는 Breiman(1996)이 제시한 25개보다 5개 많은 30개로 결정하였다.

그림 6은 ENN_{all}모형의 입력변수를 결정하기 위해 표 2에 나타난 입력력 구조를 가진 앙상블 신경망모형의 모의능력을 상관계수와 RMSE로 비교한 그림이다. 그림에서 calibration기간의 상관계수와 RMSE는 bagging기법에 의해 이미 학습된 ENN_{all}모형에, 학습에 이용되었던 원시계열자료(1981년에서 1995년까지)를 입력하여 모의한 모의유입량과 실측유입량과 비교한 것이다. 그림 6을 근



(a) 상관계수




(b) RMSE

그림 6. 입력구조 변화에 대한 앙상블 신경망(ENN_{all})모형의 모의능력 비교


거로 본 연구에서는 calibration 오차와 test 오차를 최소로 하는 model5를 선택 하였다.

그림 7은 model5의 은닉층의 노드 수 변화에 따른 상관계수와 RMSE의 변화를 나타고 있으며 이로부터 model5의 앙상블 신경망모형은 은닉층 노드를 10개로 선택하였다. 앙상블 신경망모형의 갈수기-홍수기(ENN_{d-f})모형의 최적구조 결정도 위 방법과 동일한 과정을 거쳐 구성하였다.

SNN_{all}모형의 오차지표(그림 4)와 ENN_{all}모형의 오차지표(그림 6)의 test 구간 모의능력(그림 6의 'Δ')를 비교해 보면 ENN_{all}모형이 입력변수의 변화에 상대적으로 둔감한 반응을 보이며, 전반적인 모의능력이 개선되었음을 알 수 있다. 이러한 현상은 은닉층 노드 수의 변화에 대한 두 모형의 오차지표 변화에서도 확인할 수 있는데, 그림 5와 그림 7을 비교해 보면 SNN_{all}모형은 은닉층 노드 수에 대해 민감하게 반응하는 반면 ENN_{all}모형은 둔감한 반응을 보이며 전체적인 모의능력 역시 상당히 개선되었음을 확인할 수 있다. 이러한 결과는 반복실험의 불안정성 해



(a) 상관계수



(b) RMSE

그림 7. 은닉층 노드 수 변화에 대한 model8의 모의능력 비교 (ENN_{all}모형)

소측면에서 SNN_{all}모형보다 ENN_{all}모형의 일반화 성능이 우수함을 증명하는 일례라 할 수 있다.

3.4 방법별 최적모형의 모의능력 비교

3.2와 3.3절에 설명한 최적모형 결정방법을 거쳐 선택된 4가지 강우-유출모형을 정리하면 표 3과 같다. SNN_{dry}(갈수기 단일 신경망)모형과 SNN_{flood}(홍수기 단일 신경망)모형, 그리고 ENN_{dry}(갈수기 앙상블 신경망)모형과 ENN_{flood}(홍수기 앙상블 신경망)모형은 입력구조와 은닉층 노드 수가 서로 다른 모형으로 구성되었다. 표 3을 보면 ENN모형은 SNN모형에 비해 은닉층 노드 수가 일반적으로 많은 것을 볼 수 있는데, ENN모형에서는 각 멤버모델들이 어느 정도 과적합되어야 좋은 일반화 기능을 발휘할 수 있기 때문이다.

각 모형별로 결정된 최적모형에서 20번의 학습과 test를 수행한 후 모의능력이 가장 좋은(best fit)모형의 모의유입량을 TANK모형의 모의유입량과 비교하였다(표 4, 그림 8). 각 모형의 모의값과 실측값의 Relative Bias(RB)와 Relative

표 3. 각 모형별 최적 입출력관계식 및 은닉층 노드 수

모형		입출력관계식	은닉층 노드 수
SNN _{all}		$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}))$	4
SNN _{d-f}	SNN _{dry}	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, \dots, E_{t-3}), (I_{t-1}, I_{t-2}))$	2
	SNN _{flood}	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}, I_{t-2}))$	3
ENN _{all}		$\hat{I}_t = f((R_t, \dots, R_{t-3}), (E_t, \dots, E_{t-3}), (I_{t-1}, I_{t-2}))$	10
ENN _{d-f}	ENN _{dry}	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, \dots, E_{t-3}), (I_{t-1}, I_{t-2}))$	4
	ENN _{flood}	$\hat{I}_t = f((R_t, R_{t-1}, R_{t-2}), (E_t, E_{t-1}, E_{t-2}), (I_{t-1}))$	8

표 4. 4가지 최적 신경망 강우-유출모형과 TANK모형의 모의결과 비교

	모형	연간	봄	여름	가을	겨울
relative bias (RB)	TANK	0.061	-0.145	0.020	0.240	0.279
	SNN _{all}	0.048	-0.062	0.033	0.048	0.493
	SNN _{d-f}	-0.025	-0.013	-0.050	-0.031	0.257
	ENN _{all}	-0.017	-0.122	-0.003	0.005	0.013
	ENN _{d-f}	-0.006	-0.018	-0.023	0.025	0.078
relative RMSE (R-RMSE)	TANK	0.393	0.281	0.277	0.396	0.977
	SNN _{all}	0.346	0.304	0.249	0.339	0.602
	SNN _{d-f}	0.328	0.317	0.235	0.339	0.327
	ENN _{all}	0.319	0.336	0.221	0.352	0.294
	ENN _{d-f}	0.307	0.313	0.224	0.294	0.261

주) **ENN_{d-f}**은 5가지 모형 중에서 최저 RB와 R-RMSE를 의미함

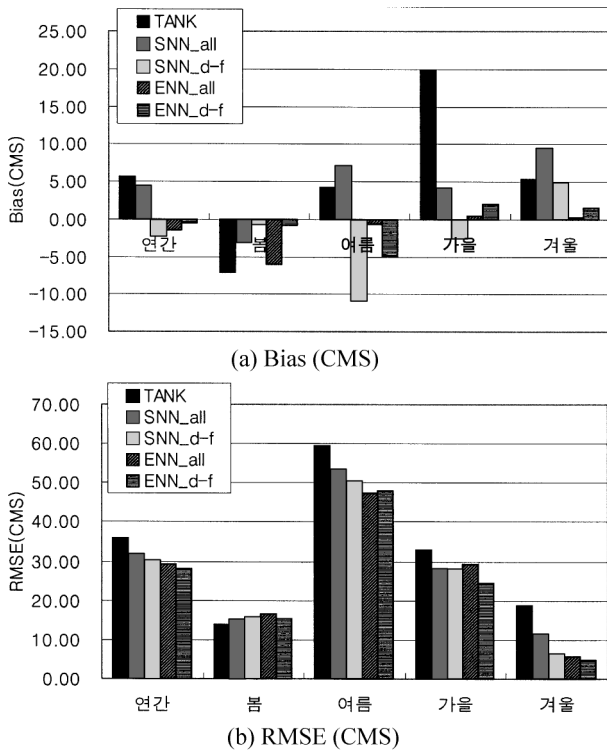


그림 8. 4가지 최적 신경망 강우-유출모형과 TANK모형의 모의 능력 비교

RMSE(R-RMSE)를 평가지표로 이용하였으며, 연간(1월~12월)과 계절별로 각 평가지표를 계산하여 비교하였다. RB와 R-RMSE는 편의와 평균제곱오차를 실측유량의 평균으로 나누어 산정한 값이다. 편의는 systematic 오차 정도를 나타내는 지표이며, 최소제곱오차는 systematic 오차와 random 오차를 종합적으로 나타내는 지표이다.

연간 RB와 R-RMSE의 경우 신경망을 이용한 4가지 강우-유출모형 모두가 TANK모형에 비해 작은 값을 보였다. 특히 ENN_{d-f}모형이 가장 좋은 모의능력을 보였는데 연간 RB가 0.006으로 TANK모형의 연간 RB 0.061 보

다 큰 폭으로 감소되었으며, R-RMSE 역시 TANK모형보다 0.086 감소하여 전체적으로 TANK모형에 비해 모의능력이 우수함을 확인할 수 있었다.

본 연구는 앙상블 유량예측기법의 겨울철 유량예측의 정확성이 강우-유출모형의 모의능력에 크게 좌우됨으로 겨울철의 모의능력 개선이라는 목적으로 시작되었다. 이러한 관점에서 볼 때 ENN_{all}모형과 ENN_{d-f}모형의 겨울철 RB와 R-RMSE가 TANK모형에 비해 눈에 띄게 감소하였음을 확인 할 수 있었다. 특히 이 두 신경망모형의 겨울철 R-RMSE는 TANK모형의 R-RMSE보다 0.68 이상 감소하였는데 이를 유량단위로 환산하면 약 13 CMS 정도이다. 상대적으로 유출이 크지 않은 겨울철의 평균유입량이 약 23 CMS 정도임을 고려한다면 이 두 모형의 겨울철 모의능력은 TANK모형에 비해 매우 우수함을 알 수 있다.

SNN모형과 ENN모형의 모의능력을 비교해 보면 전반적으로 ENN모형이 우수함을 확인할 수 있다. 특히 ENN모형의 여름, 가을, 겨울철의 RB와 겨울, 여름철의 R-RMSE가 SNN모형에 비해 상당히 작게 나타났다. 따라서 ENN모형이 SNN모형보다 일반적으로 우수함을 확인하였다. 또한 모든 월을 입력자료로 학습한 ENN_{all}모형과 SNN_{all}모형에 비해 갈수기와 홍수기로 학습자료를 분리하여 모형을 구성한 ENN_{d-f}모형과 SNN_{d-f}모형이 조금 더 우수하였다. 특히 SNN_{all}모형과 SNN_{d-f}모형의 겨울철 RB와 R-RMSE를 보면 SNN_{d-f}모형의 모의능력이 훨씬 우수하였다. 따라서 유출특성이 완전히 다른 갈수기와 홍수기 등의 계절적 요인을 고려할 경우 신경망모형의 모의능력은 개선됨을 확인하였다.

이러한 결과에도 불구하고 신경망모형이 TANK모형에 비해 절대적으로 우수하다고 말하기는 힘들다. 먼저 앞서서도 언급한 바 있으나 TANK모형은 물리적 모형으로서 강우·유출 현상을 물리적으로 설명할 수 있다는 장점이 있다. 또한 본 연구에서 사용한 TANK모형은 매개변수 보




그림 9. ENN_{d-f}모형 및 TANK모형의 모의유입량과 실측유입량 비교

정을 위해 8년간의 관측자료를 이용한 반면 신경망모형은 1981년부터 1995년까지 15년간의 관측자료를 이용하였으므로 calibration 기간이 다르다는 점을 들 수 있다. 유량 모의의 정확성 측면에서도, 봄철 R-RMSE의 경우 근소한 차이기는 하나 TANK모형이 신경망모형보다 작으며, 여름철의 RB 역시 SNN_{all}모형이나 SNN_{d-f}모형 보다 작다. 따라서 신경망모형과 TANK모형의 모의능력의 차이점과 특성을 파악하고 이들을 적절히 선택하거나 혼합하여 사용한다면 모의결과는 더욱 개선될 것이며 이를 이 어지는 후속논문(정대일 등, 2003)에서 서술하고자 한다.

그림 9는 대청댐 실측유입량과 TANK모형 및 신경망모형 중 가장 좋은 모의결과를 보인 ENN_{d-f}모형의 모의유입량을 검증기간인 1996년에서 2001년까지 그린 것이다. 대부분의 기간에 걸쳐 ENN_{d-f}모형이 실측유입량에 가장 가까운 모의를 하고 있음을 알 수 있다.

4. 결론 및 향후연구

겨울철 양상불 유량예측의 정확성을 개선하기 위해서는 먼저 강우-유출모형의 모의능력이 향상되어야 한다는 필요성에서 본 연구는 시작되었다. 대청댐 월 유입량 확률예측을 위해 양상불 유량예측기법에 이용할 수 있는 강우-유출모형을 단일 신경망모형(SNN)과 양상불 신경망모형(ENN)으로 구성하였다. 이 모형들은 다시 전체 월 자료를 이용한 모형(SNN_{all}, ENN_{all})과 갈수기와 홍수기로 분리한 모형(SNN_{d-f}, ENN_{d-f})으로 나누어 총 4개의 강우-유출모형을 생성하였다. 대표적 개념모형인 TANK모형과 4가지 신경망 강우-유출모형을 비교하고 대청댐 월 유입량 모의를 위하여 신경망모형을 적용가능성을 살펴보았다.

TANK모형과 4가지 신경망 강우-유출모형의 모의유입량에 대한 연간 RB와 R-RMSE의 분석에서 ENN_{d-f}모형이 모의능력이 가장 우수하였다. 단일 신경망모형과 양상불 신경망모형의 비교에서는 양상불 신경망모형의 모의능력이

단일 신경망모형보다 우수함을 확인하였다. 모든 월을 입력자료로 학습한 ENN_{all}모형과 SNN_{all}모형에 비해 갈수기와 홍수기로 학습자료를 분리하여 모형을 구성한 ENN_{d-f}모형과 SNN_{d-f}모형이 조금 더 정확한 모의를 하였다.

본 연구의 목적인 겨울철의 모의능력 개선이라는 관점에서 볼 때 ENN_{all}모형과 ENN_{d-f}모형의 겨울철 RB와 R-RMSE가 TANK모형에 비해 크게 감소하였으며 이 두 모형을 이용하여 양상불 유량예측을 실시할 경우 겨울철 유입량예측의 정확성 개선이 가능할 것으로 기대된다. TANK모형의 모의능력이 신경망 강우-유출모형에 비해 열등한 것은 아니므로 TANK모형의 모의특성을 파악하여 신경망모형과 적절히 선택적으로 이용할 경우 모의의 정확도 향상에 큰 도움을 줄 수 있을 것으로 전망한다.

감사의 글

본 연구는 21세기 프론티어연구개발사업인 수자원의 지속적 확보기술개발사업단의 연구비지원(과제번호: 1-6-1), 2003년도 두뇌한국21사업, 그리고 서울대학교 공학연구소에 의하여 지원되었으며 이에 감사드립니다. 본 연구에 조언을 아끼지 않으신 부산대학교 신현석 교수님께도 감사드립니다.

참고문헌

- 김성원(2000) 다층신경망모형에 의한 일 유출량의 예측에 관한 연구. 한국수자원학회논문집, 한국수자원학회, 제 33권, 제 5호, pp. 537-550.
- 김영오, 정대일, 김형섭, 이길성(2001) 양상불 예측을 통한 물 공급전망 개선방안. 2001년 학술발표회 논문집(1), 한국수자원학회, pp. 304-308.
- 신현석, 박무중(1999) 신경망을 이용한 우리나라의 시공간적 가뭄의 해석. 한국수자원학회논문집, 한국수자원학회, 제 32권, 제 1호, pp. 3-13.
- 안상진, 전계원, 김광일(2000) 신경망 알고리즘을 적용한 유출

- 수문곡선의 예측 한국수자원학회논문집, 한국수자원학회, 제 33권, 제 4호, pp. 505-515.
- 정대일, 김영오(2002) 앙상블 예측을 이용한 충주댐 월 유입량 예측, 대한토목학회논문집, 제22권, 제 3-B호, pp. 321-331.
- 정대일, 김영오, 고익환(2003) 앙상블 예측을 위한 강우-유출 모형에 대한 연구: 2. 강우-유출모형의 결합. 대한토목학회 논문집, 제23권, 제6-B호, pp. 531-540.
- 한국수자원공사(2001) 수문자료빈도분석 및 일유출 모의시스템 구축용역.
- Breiman, L. (1996) Bagging predictors. *Machine Learning* Vol. 24, No. 2, pp. 123-140.
- Cannon, A.J. and Whitfield, P.H. (2002) Downscaling recent streamflow conditions in British Columbia, Canada using ensemble neural network models. *Journal of Hydrology*, Vol. 259, pp. 136-151.
- Coulibaly, P., Anctil, F. and Bobée, B. (2000) Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology* Vol. 230, pp. 244-257.
- Demuth, H. and Beale, M. (1998) *Neural network toolbox: for use with MATLAB user's guide*. The Math Works Inc.
- Fread, D.L. (1998) A perspective on hydrologic prediction trends. *Special Symposium on Hydrology, American Meteorological Society*, Phoenix, Arizona, pp. J1-J6.
- Haykin, S. (1999) *Neural networks: A comprehensive foundation, second edition*. Prentice Hall.
- Hsu, K., Gupta, H.V. and Sorooshian, S. (1995) Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*. Vol. 31, No. 10, pp. 2517-2530.
- Thirumalaiah, K. (1998) River stage forecasting using artificial neural networks. *Journal of Hydrologic Engineering*, Vol. 3, No. 1, pp. 26-32.
- (접수일:2003.6.20/심사일:2003.9.29/심사완료일:2003.9.29)