



## Estimation of river discharge using satellite-derived flow signals and artificial neural network model: application to imjin river

Li, Li<sup>a</sup> · Kim, Hyunglok<sup>a</sup> · Jun, Kyungsoo<sup>a</sup> · Choi, Minha<sup>a\*</sup>

<sup>a</sup>Graduate Student, Dept. of Water Resources, Graduate School of Water Resources, Sungkyunkwan Univ., Suwon 16419, Korea

Paper number: 16-041

Received: 20 April 2016; Revised: 9 May 2016 / 13 May 2016; Accepted: 13 May 2016

### Abstract

In this study, we investigated the use of satellite-derived flow (SDF) signals and a data-based model for the estimation of outflow for the river reach where in situ measurements are either completely unavailable or are difficult to access for hydraulic and hydrology analysis such as the upper basin of Imjin River. It has been demonstrated by many studies that the SDF signals can be used as the river width estimates and the correlation between SDF signals and river width is related to the shape of cross sections. To extract the nonlinear relationship between SDF signals and river outflow, Artificial Neural Network (ANN) model with SDF signals as its inputs were applied for the computation of flow discharge at Imjin Bridge located in Imjin River. 15 pixels were considered to extract SDF signals and Partial Mutual Information (PMI) algorithm was applied to identify the most relevant input variables among 150 candidate SDF signals (including 0~10 day lagged observations). The estimated discharges by ANN model were compared with the measured ones at Imjin Bridge gauging station and correlation coefficients of the training and validation were 0.86 and 0.72, respectively. It was found that if the 1 day previous discharge at Imjin bridge is considered as an input variable for ANN model, the correlation coefficients were improved to 0.90 and 0.83, respectively. Based on the results in this study, SDF signals along with some local measured data can play an useful role in river flow estimation and especially in flood forecasting for data-scarce regions as it can simulate the peak discharge and peak time of flood events with satisfactory accuracy.

**Keywords:** Satellite-Derived Flow Signals, Artificial Neural Network, River Flow Estimation, Imjin River, Ungauged Basin

## Satellite-derived flow 시그널 및 인공신경망 모형을 활용한 임진강 유역 유출량 산정

Li, Li<sup>a</sup> · 김형록<sup>a</sup> · 전경수<sup>a</sup> · 최민하<sup>a\*</sup>

<sup>a</sup>성균관대학교 수자원대학원 수자원학과

### 요 지

본 연구에서는 임진강 상류유역과 같이 수리수문학적 분석에 필요한 측정데이터가 존재하지 않거나 혹은 데이터의 확보가 어려운 유역에 대하여 위성 데이터와 데이터 기반 모형을 활용하여 유출량을 산정하였다. SDF 시그널(Satellite-derived Flow Signal)은 하도내의 유량변화에 따른 하천 폭의 변화를 반영할 수 있다고 알려져 있으며, 그 상관관계는 하도단면의 형태와 밀접한 관계가 있다. SDF 시그널 데이터와 유출량 간의 비선형 상관관계를 반영할 수 있는 인공신경망 모형을 활용하여, 모형의 입력변수인 SDF 시그널 데이터로부터 임진강의 임진교 지점에서의 유출량을 추정하였다. 15개의 위성 이미지 픽셀의 SDF 시그널 값이 0~10일의 lag가 되어 활용되었으며, lag된 데이터를 포함하여 총 150개의 변수 중 유출량과 가장 큰 관계가 있는 변수 선정을 위해 PMI(Partial Mutual Information) 기법이 활용되었다. 인공신경망 모형을 통해 산정된 유출량은 임진교에서 측정된 지점 유출량과 비교·분석되었으며, 학습(training)과 검증(validation)을 통한 상관계수는 각각 0.86, 0.72로 좋은 결과를 보여주었다. 추가적으로 SDF 시그널 데이터 외에 임진교의 1일 전 측정유량이 인공신경망 입력변수로 추가되었을 때 상관계수가 0.90, 0.83으로 증가함을

\*Corresponding Author. Tel: +82-31-290-7539  
E-mail: mhchoi@skku.edu (M. Choi)

보였다. 결과로부터 계측수문자료가 부족하거나 접근 불가능한 유역에 대하여 하천 유량 변화에 대한 추정치인 SDF 시그널 데이터와 지상 데이터가 결합되었을 때 신뢰성 높은 유역의 유출량을 산정할 수 있으며, 큰 유량이 발생하는 홍수사상에 대해서도 침투 유량과 침투 발생시간을 잘 모의할 수 있음을 알 수 있었다. 향후 위성 데이터와 지점 데이터를 활용하여 미계측 유역의 홍수발생에 대하여 높은 정확도로 예측 가능할 것으로 기대한다.

**핵심용어:** Satellite-derived Flow Signal, 인공신경망, 유출량 산정, 임진강, 미계측 유역

## 1. 서론

홍수 예측은 수자원 확보와 이용에 중요한 역할을 하며 인명과 재산의 피해를 최소화하고 홍수 발생 시 빠른 대처를 할 수 있도록 정보를 제공한다. 홍수 예측을 위하여 많은 물리적 모형들이 개발되어 왔으며, 데이터 기반 기법들도 지속적으로 연구되고 있다. 물리적 모형은 조도계수, 단면자료 등 많은 측정 데이터를 필요로 하는데, 이러한 데이터들은 보통 시공간적인 변동성을 갖고 있기에 정확한 측정이 어렵다(Akhtar et al., 2009). 반면 데이터 기반 모형은 제한된 입력변수만 존재할 경우라도 사례의 반복학습을 통하여 신뢰성 있는 결과를 산정할 수 있기에 널리 사용되고 있다. 특히, 인공 신경망 기법(artificial neural network; ANN)은 다양한 형태의 변수들과의 관계를 분석하는데 용이하고, 물리적 현상의 근본적인 해석과 상관없이 비선형 상관관계에 대한 분석이 가능하여 수자원·수문분야 뿐만 아니라 다양한 분야에서 활발히 이용되고 있다(Park and Kim, 2011; ASCE, 2000a, b).

본 연구지역과 같이, 일부 지역의 경우 관측소가 없거나 상류와 하류간의 데이터 교류가 없어 홍수해석에 필요한 지점 측정 데이터를 얻는데 한계점이 존재하는데, 이러한 경우에 위성데이터와 같은 대체정보를 이용하여 하류에서의 유출량을 산정할 수 있다(Birkinshaw et al., 2010; De Groeve, 2010; Hirpa et al., 2013).

Brankenridge et al. (2007)은 NASA의 Aqua 위성에 탑재된 AMSR-E (Advanced Microwave Scanning Radiometer – Earth Observing System) 센서에서 측정되는 유량과 관련된 데이터와 지상데이터를 결합하여 하천유량의 변화, 하천의 빙결 상태, 유역 유출량을 추정할 수 있는 방법을 제시하였다. Brankenridge et al. (2007)은 AMSR-E에서 측정 가능한 H-polarization의 36.5 GHz (14\*8 km 공간해상도) 밴드에서 측정된 야간 밝기 온도(night time brightness temperature)를 이용하였으며, 특정 픽셀에서 육지와 물에 의한 야간 밝기 온도의 차이로부터 하천유량에 의해 변하는 하천 폭의 작은 변화에도 민감하게 반응하는 시그널을 얻었다.

Hirpa et al. (2013)은 위성 센서에서 얻은 SDF 시그널 데이터를 하폭의 추정치로 간주하여 하류지점에서의 유출량을 예

측하였다. 또한 Hirpa et al. (2013)은 일부 지점에서 하폭이 큰 유량 변화에도 상대적으로 작은 변화를 보이는 한계점을 극복하기 위하여 유량변동에 민감한 하폭변화가 있는 지점들을 선택하였다. Hirpa et al. (2013)의 연구에서는 교차검증 회귀모형을 적용하여 회귀 변수를 선정하고 선형회귀 관계를 얻어 유출량을 계산하였다.

본 연구에서는 미계측 유역인 임진강 유역의 유출량을 산정하기 위하여 위성으로부터 얻은 SDF 시그널 데이터를 활용하였으며, 선형적 방법이 아닌 인공 신경망 기법을 활용하여 입력 데이터와 출력값의 비선형 상관관계를 산정하였다. 인공 신경망 기법으로부터 얻은 결과 값은 임진강 관측소의 측정치와 비교함으로써 연구 결과의 유효성을 검증하였다. 위성데이터를 활용한 북한 접경유역의 유출량 산정은 임진강 유역의 효율적인 하천유역 관리를 할 수 있고, 또한 남한측 하류유역의 홍수예·경보를 가능하게 하며 이를 통해 대응 및 조치에 충분한 시간을 확보할 수 있을 것이라 기대한다.

## 2. 인공 신경망(ANN) 기법

현재 활발히 사용되고 있는 인공 신경망 기법은 McCulloch and Pitts (1943)에 의하여 개발되었으며 신경망 기법의 적용에 대한 관심은 여러 분야에서 빠르게 증대되고 있다. 예를 들어, 강우 예측(Hall et al., 1999), 홍수 예측(Kim and Barros, 2001), 유출량 예측(Chang and Chen, 2001), 수질 예측(Maier and Dandy, 1996) 등 수자원 분야의 문제해결에 있어 인공 신경망기법의 활용성이 입증되었다. 이러한 연구들은 신경망 기법이 수문현상들의 비선형 상관관계를 해석하는데 있어서 활용 될 수 있는 기법임을 증명하였다(Kim, 2003).

인공신경망은 회귀분석보다 계산되는 가중치(weights)의 개수가 월등히 많기에 회귀분석보다 더 유연하게 독립변수와 종속변수들 간의 비선형관계를 모델링(modeling)할 수 있지만, 반면에 복잡한 관계로 인해 변수간의 해석이 어렵고, 쉽게 과적합(overfitting)을 발생시킨다.

신경망 구조는 Fig. 1과 같이 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer)으로 구성되었다. 입력

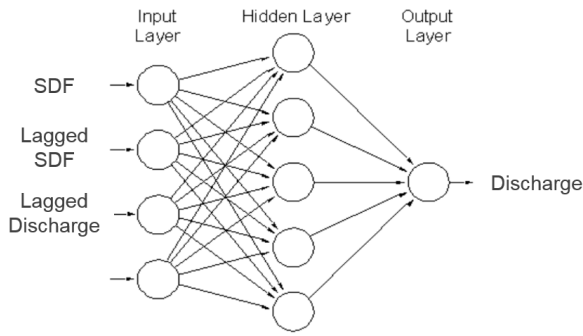


Fig. 1. Multi-layer perceptron (source: Abrahart and See, 2000)

데이터는 입력층의 노드를 통해 은닉층과 출력층의 노드들에 차례로 계산을 통해 전달된다. 각 노드들 사이에는 연결가중치(weight)가 있고 입력층을 구성하고 있는 노드들은 함수를 포함하지 않으며 은닉층과 출력층을 구성하고 있는 노드들은 합산함수와 전이함수를 가지고 있다(Kim and Son, 2006). 인공신경망은 다수의 노드들의 상호작용을 통해 지속적인 학습 과정에서 가중치를 변화시키면서 우수한 예측력을 지닌 적합한 모델을 만든다.

본 연구에서는 신경망의 학습(training)을 위해 다층 퍼셉트론(multi-layer perceptron; MLP) 신경망에 경사 하강법(gradient based method)를 이용한 오차역전파법을 사용하였다. 오차역전파법은 “사용자가 지정한 목표값과 학습에 의한 출력값의 차이에서 만들어진 오차값을 이용하여, 오차를 줄여나가는 방향으로 학습하는 법칙”을 기초로 하고 있다(Jung, 2004).

본 연구에서는 학습단계에서 Levenberg-Marquardt 알고리즘을 적용하여 유출량의 실제 측정값과 계산값의 평균 제곱오차를 줄이면서 신경망 모형의 가중치를 결정하였다(Levenberg, 1944). Levenberg-Marquardt 알고리즘은 비선형방정식의 최적해를 최소자승법으로 구하는 방법으로, Gauss-Newton 방법과 경사 하강법의 조합으로 구성되어 있다(Park and Kim, 2013).

### 3. 연구대상 하천구간 적용

#### 3.1 연구대상 하천구간

임진강은 북한에서 발원하여 군사분계선(DMZ)을 지나 한강하류와 합류하여 황해로 흘러 들어간다. 임진강 유역 중 62.9%가 북한지역에 포함되어 있으며, 이 지역에서는 각종 수문인자 획득이 불가능하여 본 지역에 대한 수리수문학적인 분석이 거의 이루어지지 못하고 있는 실정이다(Kim et al.,

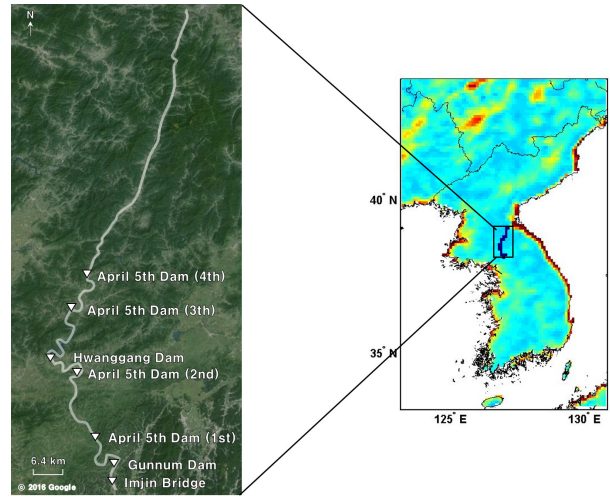


Fig. 2. Study river: upstream of Imjin Bridge

2003). 1996년, 1998년, 1999년 세 차례에 걸친 임진강 유역 대홍수로 인하여 9천억원의 재산피해와 123명의 인명피해가 발생하였다. 이러한 홍수피해를 줄이기 위해서는 북한지역의 수문자료 확보가 중요하지만, 군사분계선 이북지역에 대한 제한적인 자료획득으로 인해 신뢰도 높은 홍수예·경보에 한계가 있다. 이러한 미계측 유역의 유출량을 추정할 수 있도록 위성데이터를 활용하는 것은 큰 의미가 있다. 본 연구의 대상 하천구간은 대부분은 미계측 유역을 포함하고 있는 임진교 상류구간으로써 유역면적은 4,260.0 km<sup>2</sup>이고 하천연장은 193.1 km이다(Fig. 2). 임진강 중상류에는 총 4호기의 중소형 발전용 댐인 4월5일 댐이 위치해 있고, 군사분계선으로부터 42.3 km 북쪽에는 다목적댐인 황감댐이 있으며, 임진교와 가까운 위치에는 군남댐이 건설되어 있다.

#### 3.2 SDF 시그널 및 관측소 측정 유량

본 연구에 이용된 SDF 시그널 데이터는 TRMM (Tropical Rainfall Measuring Mission; 1998-2014)/AMRS-E (2002-2011)/AMSR2 (Advanced Microwave Scanning Radiometer 2; 2013-present)에서 산출된 병합된 데이터이며, GDACS (Global Disaster and Alert Coordination System, Joint Research Center-Ipsra, European Commission)의 Global Flood Detection System을 통해 일별 자료를 획득할 수 있다. AMSR2 센서의 경우 토양수분 데이터를 측정하기 위해 AMSR-E의 후속 센서로 일본의 Japan Aerospace Exploration Agency (JAXA)에서 개발된 센서이다(Kim et al., 2015; Kim et al., 2016; Cho et al., 2015). SDF 시그널을 얻기 위해 각각의 픽셀에서의 밝기온도는 36.5 GHz의 주파에서 얻을 수 있으며 10\*10 km의 격자크기로 나누어 진다(Revilla-Remero et al., 2014).




Fig. 3. Brightness temperature of wet pixel (M) and brightness temperature of dry pixel (C) (source: Global Flood Detection System)

SDF 시그널은 하천구간을 중심으로 한 측정픽셀의 밝기 온도(M)와 하천구간이 포함된 픽셀에서 가장 가까이 위치한 육지만 포함한 픽셀의 밝기 온도(C)의 비를 나타낸다(Fig. 3). 하천구간을 포함한 픽셀의 밝기 온도는 수위에 따른 하천 폭의 변화에 따라 변화하며, 따라서 SDF 시그널은 하천 폭(물로 덮여있는 지표)의 추정치로 다음의 식과 같이 계산 될 수 있다 (Brakenridge et al., 2007).

$$s = \frac{M}{C} = \frac{T_{b, measurement}}{T_{b, calibration}} \quad (1)$$

$$= \frac{T_{measurement}((1-w)\xi_{land} + w\xi_{water})}{T_{calibration}\xi_{land}} \approx 1 - w + w \frac{\xi_{water}}{\xi_{land}} = f(w)$$

여기서,  $T_{b, measurement}$  는 하천을 포함한 픽셀의 밝기온도,  $T_{b, calibration}$  는 육지만 포함한 픽셀의 밝기온도,  $T_b$  는 온도  $T$ (physical temperature)와 방사율  $\xi$ (emissivity)에 의해 결정되며  $T_b = \xi T$ 로 나타낼 수 있고,  $w > 0$ 은 하나의 픽셀(wet pixel)에서 하천이 차지하는 비율이고,  $w = 0$ 은 육지만 포함된 픽셀(dry pixel)에 해당한다. 식에서 볼 수 있듯이 SDF 시그널(s)은 최종  $w$ 의 함수로써 수위변화에 따른 하천 폭의 추정치로 나타낼 수 있다. 위성으로부터 SDF 시그널을 산출하는 자세한 방법은 De Groeve (2010)과 Brakenridge et al. (2007)에서 제시하고 있다.

본 연구에서는 위성으로부터 얻은 SDF 시그널 값을 활용하여 임진교에서의 유출량 산정을 위한 모델을 제시하였다. 본 연구방법의 제한점은 하도 내의 유량변화가 클 경우, 일부 위치에서 원격 탐사된 하천 폭이 상대적으로 작은 변화를 보일 수 있다는 것인데(Brakenridge et al., 2007), 이러한 한계점을 극복하기 위하여, 유량변화에 따라 하천 폭에 가장 큰 변화




Fig. 4. The pixel locations of SDF data set

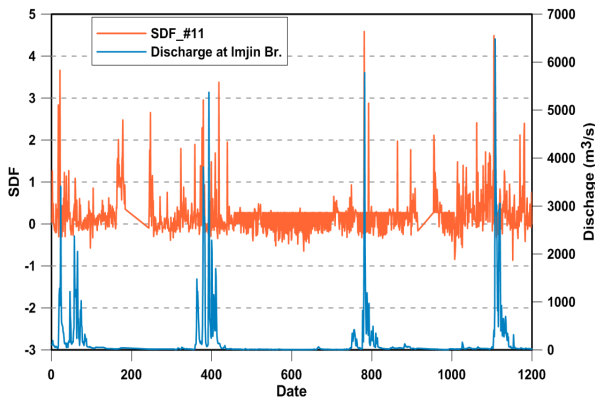
Table 1. The latitude and longitude of the satellite-derived flow signals

Pixel No.	Latitude (N)	Longitude (E)	Pixel No.	Latitude (N)	Longitude (E)
1	38.507	126.797	11	38.777	126.977
2	38.417	126.797	12	38.687	126.977
3	38.327	126.797	13	38.147	126.977
4	38.687	126.887	14	38.057	126.977
5	38.597	126.887	15	39.047	127.067
6	38.507	126.887	16	38.957	127.067
7	38.417	126.887	17	38.867	127.067
8	38.327	126.887	18	38.777	127.067
9	38.237	126.887	19	38.147	127.067
10	38.147	126.887	20	39.047	127.157

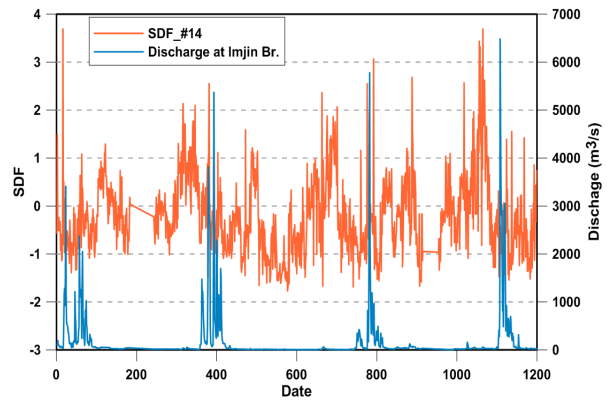
를 보이는 픽셀 위치를 선정하였다(3.3.1 참조).

본 연구에서 사용된 SDF 데이터는 Joint Research Center (JCR-Ispira, <http://www.gdacs.org/floodmerge/>)에서 획득하였다. Fig. 4와 같이 총 20개의 픽셀이 연구대상 하천구간을 포함하고 있지만, 가장 상류단에 위치한 5개의 픽셀의 데이터 개수가 불충분한 관계로, 상류단 5개의 픽셀을 제외한 15개 픽셀의 SDF 시그널 데이터를 분석에 활용하였다. 측정위치의 자세한 지형자료는 Table 1과 같다. 2010년 7월부터 2014년 6월 사이의 일 SDF 시그널 데이터를 모형의 학습과 검증의 입력자료로 사용하였다.

임진교 관측소에서 측정된 유량데이터는 한강홍수통제소에서 획득하였으며, 수위-유량 곡선 관계식으로부터 얻은 2010년 7월부터 2014년 6월 사이의 일 유량데이터를 신경망 모형의 학습 및 검증에 사용하였다.



(a) SDF signals at 11th pixel and discharge



(b) SDF signals at 14th pixel and discharge

Fig. 5. Relations between SDF signals and discharge time series at Imjin Bridge

Fig. 5는 11번째와 14번째 픽셀의 SDF 시그널 데이터와 임진교에서 측정된 유출량의 시계열 그래프를 나타낸다. 그림에서 볼 수 있듯이 SDF 시그널 값은 실제 유출량과 일정한 상관관계가 있음을 알 수 있으며, SDF 시그널 데이터로부터 유출량 추정 될 수 있음을 짐작 할 수 있다.

### 3.3 신경망 모형의 구축

#### 3.3.1 입력변수의 선정

인공신경망을 적용하는데 있어서, 인공 신경망 학습에 사용되는 입력 데이터와 추정될 데이터 간의 상관 정도는 매우 중요한 고려요소가 된다. 즉, 신경망의 학습을 위해서 사용되는 입력 자료가 추정될 자료의 특성을 반영하고 있는가에 대한 정도는 매우 중요한 요소가 되는 것이다(Han et al., 2010). 선형회귀분석 범주 안에서 개발된 여러 가지의 변수선택방법으로 채택된 변수들은 인공신경망의 입력인자로는 적합하지 않다(May et al., 2011). 왜냐하면 선형기반의 변수선택방법으로 선택된 변수는 종속변수와 독립변수간의 비선형 관계를 파악하는데 적합하지 않기 때문이다. 최근에는 인공신경망 입력변수 선택기법으로 상호정보량(Mutual information; MI) 기법이 많이 사용되고 있다(Han et al., 2010; May et al., 2008). 하지만 다중 예측인자의 식별은 예측변수와 예측인자 집합사이의 부분 종속성(partial dependence)에 대한 척도(measure)가 필요하다(Kang, 2013). Sharma (2000)는 자료사이의 부분 종속성의 척도로서 MI 판단기준은 적합하지 않음을 지적하고, 부분 상호정보량 기법(parital mutual information; PMI)의 사용을 제안하였다. 이미 존재하는 입력변수들의 집합  $z$ 에 대하여 종속변수  $y$ 와 독립변수  $x$ 사이의 PMI는 다음과 같이 표현된다.




Fig. 6. The number of times (including the lagged observations) data from a SDF site is used in the model

$$PMI = \iint f_{X',Y'}(x',y') \ln \left[ \frac{f_{X',Y'}(x',y')}{f_{X'}(x')f_{Y'}(y')} \right] dx' dy' \quad (2)$$

여기서  $x' = x - E[x|z]$ ,  $y' = y - E[y|z]$  이고,  $E[\cdot]$ 는 기대연산자(expectation operator)이다. PMI 기법(Galelli et al., 2014; Bowden et al., 2005)은 새로운 입력변수가 추가 되었을 때 기존의 예측모형에 더해지는 부분 종속성의 척도를 제공한다(Bowden et al., 2005)

15개 지점의 SDF 시그널을 최대 10일까지 지체(lagged) 시켰을 때 총 150개의 예비변수를 얻을 수 있다. 이 중에서 유출량 예측능력이 우수한 인자를 선정하지 위하여 PMI 기법을 적용하였으며 최종 30개의 입력변수를 선정하였다(Fig. 6).

3.3.2 신경망 모형의 구축

신경망 모형의 구축에서 중요한 것은 최적 학습조건 및 은닉층의 노드 수를 결정하는 것이다. 신경망 구축에서 입력층과 출력층의 노드 수는 실제 입력변수 및 목표변수의 개수에 의해 쉽게 결정할 수 있지만 최적 은닉층의 개수 및 은닉층의 노드 수의 결정에 대해서는 현재까지 많은 연구들이 진행되고 있다. 은닉층의 개수와 은닉층의 노드 수를 임의로 정할 경우 과적합(overfitting) 혹은 과소적합(underfitting) 문제가 발생할 수 있다(Gnana Sheela and Deepa, 2013). 또한 Panchal et al. (2011)은 대부분의 문제에 대하여 하나의 은닉층은 충분함을 밝혔다. 신경망 모형에서 두 개의 은닉층을 사용할 경우 지역 최적해(local minima)에 수렴할 리스크가 더 크게 되기 때문이다(Yilmaz, 2013). 많은 선행 연구들은 은닉층의 노드 수를 결정함에 있어서 시행착오법(trial and error method)을 적용하였으며 반복 연산을 통하여 실제 값과 가장 근접한 결과를 주는 구조를 선택하였다(i.e. Yilmaz, 2012; Karimi et al., 2013). 그 외에도 신경망 모형의 은닉층 노드 수를 결정하는 여러 가지 방법들이 제안되었다(Baily and Thompson, 1990; Katz, 1992; Aldrich et al., 1994; Barron, 1994; Kaastra and Boyd, 1996; Kanellopoulos and Wilkinson, 1997; Neuralware, 2001; Witten and Frank, 2005). 본 연구에서 은닉층은 하나로 구성하였으며 노드 수는 다음의 식(Neuralware, 2001)에 의하여 결정하였다.


$$N_h = T / (5 * (N + M)) \tag{3}$$

여기서,  $N$ 은 입력변수의 개수,  $N_h$ 는 싱글 은닉층의 노드 수,  $M$ 은 출력변수의 개수이며  $T$ 는 학습에 사용된 데이터 벡터의 개수이다. 은닉층의 각 절점에서는 가중합산된 입력자료들을 전달함수인 시그모이드(sigmoid)함수를 활용하여 비선형적으로 변환하여 가중연결을 통해 출력층으로 전달하게 된다.


3.4 적용 및 결과

전체 데이터를 학습용(75%)과 검증용(25%)으로 구분하여 사용하였으며 학습용 데이터는 3개의 홍수사상, 검증용 데이터는 하나의 홍수사상을 포함하고 있게 설계하였다. SDF 시그널 및 Lagged SDF 시그널을 입력변수로 할 경우 입력층은 총 30개의 입력변수가 들어가도록 동일한 수의 노드를 주었고, 출력층은 1개의 노드를 주었으며, 은닉층의 노드 수는 Eq. (3)를 적용하여 5개로 하였다.

Fig. 7은 모형의 학습 및 검증을 통해 구한 유량과 관측유량을 시계열로 도시한 결과이다. 결과에서 볼 수 있듯이 SDF 시



(a) Results of model training



(b) Results of model validation

Fig. 7. Comparisons between observed and estimated discharge





Fig. 8. Correlations between estimated and targeted data (input data: SDF)


그를 입력변수로 한 신경망모형은 침투 유량과 침투 발생시간을 비교적 정확히 추정함을 알 수 있다. Fig. 8은 임진교의 관측유량과 신경망모형에서 산정된 유량을 각각 x축과 y축에 도시하여 1:1 plot을 작성한 것이다. Fig. 8에서 실선은 관측 유량에 대응하는 산정유량을 나타내는 점들을 직선에 회귀시킨 것이며, 점선은 산정유량의 값이 관측유량의 값과 일치하는 경우를 나타낸다. 모형의 학습 및 검증결과 관측 값과 계산 값의 상관관계는 각각 0.86, 0.72로 분석되었다.

Akhtar et al. (2009)은 1일 전 유출량은 99%의 현재 유출량 정보를 포함하고 있기 때문에, 유출량 산정을 위한 신경망 모형의 입력자료로 포함되어야 함을 강조하였다. 1일 전 유출량을 입력함수로 포함하여 입력층의 노드 수를 31개로 변화시켰으며, 출력층 및 은닉층은 앞서 언급된 모형과 같은 구조를 활용하였다. Fig. 9은 신경망모형의 학습 및 검증 결과를 통해 계산

된 유량과 관측유량을 나타내고 있다. 결과에서 볼 수 있듯이 침투 유량은 다소 작게 추정되었지만, 침투 발생시간은 잘 일치함을 볼 수 있다. 또한 유량이 작은 경우에 전 모형보다 정확한 결과를 보여주고 있음을 알 수 있었다. 신경망 모형의 학습 및 검증결과를 보면 추정값과 관측값의 상관관계수가 각각 0.90, 0.83으로 높은 상관관계를 보여주고 있음을 알 수 있다 (Fig. 10).



(a) Results of model training



(b) Results of model validation

Fig. 9. Comparisons between observed and estimated discharge when 1 day lagged discharge at Imjin Bridge is considered as an input variables




Fig. 10. Correlations between estimated and targeted data (input data: SDF+Q)

#### 4. 결론

본 연구는 임진강과 같이 정치적 문제로 인해 수문계측이 불가능하거나 수문자료가 부족한 유역에 대하여 위성기반 데이터 및 인공 신경망 기법이 유역유출량 산정에 활용 가능성을 보여주었다. SDF 시그널 데이터를 활용하고자 할 때, 위성기반의 하천 폭의 추정치가 관측된 유량과 상관관계가 있는 지점을 적절히 선택하는 것도 중요함을 알 수 있었다.

본 연구에서는 유역 유출량과 가장 관계가 있는 SDF 시그널 관측 지점을 선정하고, 또한 인공 신경망모형의 성능을 향상시키기 위하여 부분 상호정보량 기법을 활용하였다. SDF 시그널을 입력변수로 한 인공 신경망모형을 구축하였으며, 산정된 유량은 실제 관측유량과 높은 상관관계를 보여주었으며, 침투 유량과 침투 발생시간 추정에 활용 될 수 있음을 보여주었다. 임진교 관측소의 1일 전 유량을 신경망모형의 입력변수로 추가할 경우에 산정유량과 관측유량의 상관관계수가 높아짐을 알 수 있으며, 유량이 작은 경우에도 우수한 산정결과를 얻을 수 있음을 알 수 있었다.

위성 기반 유량산정에 있어서 본 연구에서는 SDF 시그널 데이터와 관측유량만을 입력변수로 고려하였지만, 향후 토양수분과 식생인자와 같은 수문자료가 추가 입력 자료로 활용되어, 유출 모델 결과의 정확도가 높아질 수 있을 것이라 사료된다. 또한 향후 위성 기반 유출량 분석을 통해, 북한지역의 직접적인 영향을 받는 남한 측 하류유역의 홍수에 경보 정확도 향상에 본 연구의 결과가 기여 될 수 있을 것으로 본다.

#### 감사의 글

본 연구는 국토교통부 물관리연구사업의 연구비지원(11 기술혁신C06)에 의해 수행되었습니다. 또한 “성균관대학교 공과대학 연구 지원인력 지원사업”에 의해 수행되었습니다.

## References

- Abrahart, R.J., and See, L. (2000). "Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments, *Hydrological Processes*, Vol. 14, pp. 2157-2172.
- Akhtar, M.K., Corzo, G.A., van Andel, S.J., and Jonoski, A. (2009). "River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin." *Hydrology and Earth System Sciences*, Vol. 13, pp. 1607-1618.
- Aldrich, C., Van Deventer, J.S.J., and Reuter, M.A. (1994). "The application of neural nets in the metallurgical industry." *Minerals Engineering*, Vol. 7, pp. 793-809.
- ASCE: Task Committee on Application of Artificial Neural Networks in Hydrology (2000a). "Artificial Neural Networks in Hydrology, I: Preliminary Concepts." *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 115-123.
- ASCE: Task Committee on Application of Artificial Neural Networks in Hydrology (2000b). "Artificial Neural Networks in Hydrology, II: Hydrology Application." *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 124-136.
- Bailey, D.L., and Thompson, D.M. (1990). "Developing neural-network applications." *AI Expert*, Vol. 5, No. 9, pp. 34-41.
- Barron, A.R. (1994). "Approximation and estimation bounds for artificial neural networks." *Machine Learning*, Vol. 14, No. 1, pp. 115-133.
- Birkinshaw, S.J., O'Donnell, G.M., Moore, P., Kilsby, C.G., Fowler, H.J., and Berry, P.A.M. (2010). "Using satellite altimetry data to augment flow estimation techniques on the Mekong River." *Hydrological Processes*, Vol. 24, No. 26, pp. 3811-3825.
- Bowden, G.J., Dandy, G.C., and Maier, H.R. (2005). "Input determination for neural network models in water resources applications. Part 1-background and methodology." *Journal of Hydrology*, Vol. 301, No. 1-4, pp. 75-92.
- Brakenridge, G.R., Nghiem, S.V., Anderson, E., and Mic, R. (2007). "Orbital microwave measurement of river discharge and ice status." *Water Resources Research*, Vol. 43, W04405.
- Chang, F., and Chen, Y. (2001). "A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction." *Journal of Hydrology*, Vol. 245, No. 1-4, pp. 153-164.
- Cho, E., Moon, H., and Choi, M. (2015). "First Assessment of the Advanced Microwave Scanning Radiometer 2 (AMSR2) Soil Moisture Contents in Northeast Asia." *Journal of the Meteorological Society of Japan*, Vol. 93, No. 1, pp. 117-129.
- De Groeve, T. (2010). "Flood monitoring and mapping using passive microwave remote sensing in Namibia." *Geomatics, Natural Hazards and Risk*, Vol. 1, No. 1, pp. 19-35.
- Galelli, S., Humphrey, G.B., Maier, H.R., Castelletti, A., Dandy, G.C., and Gibbs M.S. (2014). "An evaluation framework for input variable selection algorithms for environmental data-driven models." *Environmental Modelling & Software*, Vol. 65, pp. 33-51.
- Gnana Sheela, K., and Deepa, S.N. (2013). "Review on methods to fix number of hidden neurons in neural networks." *Mathematical Problems in Engineering*, Vol. 2013.
- Hall, T., Brooks, H.E., Doswell III, C.A. (1999). "Precipitation forecasting using neural network." *Weather Forecast*, Vol. 14, pp. 338-345.
- Han, K.H., Ryu, Y.J., Kim, T.S., and Heo, J.H. (2010). "Input variables selection of artificial neural network using mutual information." *Journal of the Korean Water Resources Association*, Vol. 43, No. 1, pp. 81-94.
- Hirpa, F.A., Hopson, T.M., De Groeve, T., Brakenridge, G.R., Gebremichael, M., and Restrepo, P.J. (2013). "Upstream satellite remote sensing for river discharge forecasting: Application to major rivers in South Asia." *Remote Sensing of Environment*, Vol. 131, pp. 140-151.
- Hopson, T.M., and Webster, P.J. (2010). "A 1-10-day ensemble for forecasting scheme for the major river basins of Bangladesh: Forecasting severe floods of 2003-07." *Journal of Hydrometeorology*, Vol. 11, pp. 618-641.
- Jung, S. (2004). *Artificial Intelligence System I Neural Network Structure and Instruction*. Chungnam National University Press.
- Kaastr, I., and Boyd, M. (1996). "Designing a neural network for forecasting financial and economic time series." *Neurocomputing*, Vol. 10, pp. 215-236.
- Kanellopoulos, I., and Wilkingson, G.G. (1997). "Strategies and best practice for neural network image classification." *International Journal of Remote Sensing*, Vol. 18, No. 4, pp. 711-725.
- Kang, J.W. (2013). "Forecasting of seasonal inflow to reservoir using multiple linear regression." *Journal of Environmental Science International*, Vol. 22, No. 8, pp. 953-963.
- Karimi, S., Kisi, O., Shiri, J., and Makarynsky, O. (2013). "Neuro-fuzzy and neural network techniques for forecasting sea level in Darwin Harbor, Australia." *Computers and Geosciences*, Vol. 52, pp. 50-59.
- Katz, J.O. (1992). "Developing neural network forecasters for trading." *Technical Analysis of Stocks and Commodities*, Vol. 10, No. 4, pp. 160-168.
- Kim, C.Y., and Son, J.H. (2006). "A study on the model of artificial neural network for construction cost estimation of educational facilities at conceptual stage." *Korea Journal of Construction Engineering and Management*, Vol. 7, No. 4, pp. 91-99.
- Kim, G.S. (2013). "Flood forecasting for a ungauged mountainous region using satellite data and ground multi-sensor data." *KSCE Annual Conference*, Korean Society of Civil Engineers, pp. 2165-2168.
- Kim, G.S., and Brros, A.P. (2001). "Quantitative flood forecasting



- using multisensor data and neural networks.” *Journal of Hydrology*, Vol. 246, No. 1-4, pp. 45-62.
- Kim, H., and Choi, M. (2015). “Evaluation of satellite-based soil moisture retrieval over the Korean peninsula: using AMSR2 LPRM algorithm and ground measurement data.” *Journal of Korean Society of Hazard Mitigation*, Vol. 15, No. 4, pp. 53-58.
- Kim, J.H., Lee, K.D., and Bae, D.H. (2003). “The coupled satellite rainfall-streamflow analysis on Imjin River basin.” *KSCE Annual Conference*, Korean Society of Civil Engineers, pp. 2305-2308.
- Kim, S., Kim, H., and Choi, M. (2015). “An Inter-comparison of Active and Passive satellite Soil Moisture Products in East Asia for Dust-Outbreak Prediction.” *Journal of Korea Water Resources Association*, Vol. 49, No. 5, pp. 423-429.
- Levenberg, K. (1944). “A method for the solution of certain non-linear problems in least squares.” *Quarterly of Applied Mathematics*, Vol. 2, No. 2, pp. 164-168.
- Maier, H.R., and Dandy, G.C. (1996). “The use of artificial neural networks for the prediction of water quality parameters.” *Water Resources Research*, Vol. 32, No. 4, pp. 1013-1022.
- May, R., Dandy, G., and Maier, H. (2011). “Review of Input Variable Selection Methods for Artificial Neural Networks.” *Artificial Neural Networks-Methodological Advances and Biomedical Applications*, Edited by Suzuki, K., InTech, India, pp. 19-44.
- May, R.J., Maier, H.R., Dandy, G.C., and Fernando, T.M.K.G. (2008). “Non-linear variable selection for artificial neural networks using partial mutual information.” *Environmental Modelling & Software*, Vol. 23, No. 10-11, pp. 1312-1326.
- McCulloch, W., Pitts, W. (1943). “A logical calculus of ideas immanent in nervous activity.” *Bulletin of Mathematical Biophysics*, Vol. 5, No. 4, pp. 115-133.
- Neuralware, Inc. (2001). *The reference guide*. Pittsburgh, PA.
- Panchal, G., Ganatra, A., Kosta, Y.P., and Panchal, D. (2011). “Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers.” *International Journal of Computer Theory and Engineering*, Vol. 3, No. 2, pp. 332-337.
- Park, J.A., and Kim, G.S. (2011). “Estimation of spatial distribution of soil moisture at Yongdam dam watershed using artificial neural networks.” *Journal of the Korean Geographical Society*, Vol. 46, No. 3, pp. 319-330.
- Park, J.E., and Kim, S.H. (2013). “Application of Levenberg Marquardt method for calibration of unsteady friction model for pipeline system.” *Journal of the Korea Water Resources Association*, Vol. 46, No. 4, pp. 389-400.
- Revilla-Remero, B., Thielen, J., Salamon, P., De Groeve, T., and Brankenridge, G.R. (2014). “Evaluation of the satellite-based Global Flood Detection System for measuring river discharge: influence of local factors.” *Hydrology and Earth System Sciences*, Vol. 18, pp. 4467-4484.
- Sharma, A. (2000). “Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: Part 1 – A strategy for system predictor identification.” *Journal of Hydrology*, Vol. 239, pp. 232-239
- Witten, I.H., and Frank, E. (2005). *Data mining: Practical machine learning tools and techniques*. Morgan Kaufmann, San Francisco, CA, pp. 560.
- Yilmaz, M. (2013). “Artificial neural networks pruning approach for geodetic velocity field determination.” *Boletim de Ciências Geodésicas*, Vol. 19, No. 4, pp. 558-573.