



## 인공신경망 기법을 이용한 논에서의 지표 유출량 산정

### Estimation of Surface Runoff from Paddy Plots using an Artificial Neural Network

안지현\* · 강문성\*\*† · 송인홍\*\*\* · 이경도\*\*\*\* · 송정현\* · 장정렬\*\*\*\*\*

Ahn, Ji-Hyun · Kang, Moon-Seong · Song, In-Hong · Lee, Kyong-Do · Jang, Jeong-Ryeol

#### ABSTRACT

The objective of this study was to estimate surface runoff from rice paddy plots using an artificial neural network (ANN). A field experiment with three treatment levels was conducted in the NICS saemangum experimental field located in Iksan, Korea. The ANN model with the optimal network architectures, named Paddy1901 with 19 input nodes, 1 hidden layer with 16 neurons nodes, and 1 output node, was adopted to predict surface runoff from the plots. The model consisted of 7 parameters of precipitation, irrigation rate, ponding depth, average temperature, relative humidity, wind speed, and solar radiation on the daily basis. Daily runoff, as the target simulation value, was computed using a water balance equation. The field data collected in 2011 were used for training and validation of the model. The model was trained based on the error back propagation algorithm with sigmoid activation function. Simulation results for the independent training and testing data series showed that the model can perform well in simulating surface runoff from the study plots. The developed model has a main advantage that there is no requirement for any prior assumptions regarding the processes involved. ANN model thus can be a good tool to predict surface runoff from rice paddy fields.

**Keywords:** Artificial neural networks; ANN; paddy plot; surface runoff; water balance

#### 1. 서 론

영농기간 동안 논에서의 유출량은 관개량과 강우량의 영향을 크게 받으며, 이를 정량적으로 파악하기 위해서는 관개와 강우를 고려하여 논에서의 물수지를 파악하여야 한다. 논에서의 물수지를 산정하기 위해서는 모니터링을 통하여 담수심, 강우량, 관개량 및 증발산량 산정에 요구되는 기상자료 등의 현장자료 수집이 요구되며, 현장자료 수집의 한계와 효율성을 고려하여 일단위로 산정하여야 한다 (Kim et al., 2003). 하지만, 지표 유출량의 경우 인위적인 현장 관리나 영농 조건 변화, 기계적 결합 등에 따라 현장 자료 수집에 어려움이 많아 정확한 값을 측정하는데 한계가 있다.

인공신경망 (Artificial Neural Network; ANN)은 시간적, 공간적 변동이 심한 기상이나 수문 등의 비선형 특성을 보이는 자연현상을 적절히 재현할 수 있는 모형화가 가능하며, 최근 강우-유출 해석과 강우 분포, 가뭄, 지하수 유동 등의 수자원 및 환경 분야에서의 적용과 응용이 활발하게 이루어지고 있다 (Choi et al., 2000).

인공신경망은 불확실한 비선형 자연현상을 모형화하기 위한 비매개변수법의 일종으로서, 1990년 이후 수문계의 적용이 활발히 이루어지고 있다. 인공신경망 모형은 그 모형 자체의 비선형성 (nonlinearity)을 갖음으로서 통계적인 정규성 (normality)과 정체성 (stationarity)의 가정에서 자유롭다. 또한, 기존에 설정된 신경망 모형을 문제의 목적에 따라 용이하게 변환이 가능한 적응성 (adaptivity)과 전산학적 병렬계산이 가능하여 그 처리가 합리적인 병렬성 (parallel property) 등의 장점을 지니고 있다 (Kang et al., 2001).

Kang et al. (2001, 2003, 2006)은 장기유출 해석 및 단기 홍수량 예측을 위하여 신경망 모형을 구성하고 그 적용성을 검토하였으며, Odhiambo et al. (2001), Sudheer et al. (2003), Zanetti et al. (2007), Lee et al. (2010)은 온도, 풍속, 일조시간 등 여러 기상인자 중 제한된 인자만을 이용하여 입력자료의 조합을 달리한 ANN 모형을 구성하여 잠재증발산량을 예측하는

\* 서울대학교 농업생명과학대학 생태조경·지역시스템공학부  
 \*\* 서울대학교 농업생명과학대학 조경·지역시스템공학부, 농업생명과학연구원 겸무연구원  
 \*\*\* 서울대학교 농업생명과학연구원 연구교수  
 \*\*\*\* 농촌진흥청 국립식량과학원 연구사  
 \*\*\*\*\*한국농어촌공사 농어촌연구원 새만금연구부 책임연구원  
 † Corresponding author Tel.: +81-2-880-4582  
 Fax: +81-2-873-2087  
 E-mail: mskang@snu.ac.kr

2011년 12월 14일 투고  
 2012년 5월 14일 심사완료  
 2012년 6월 13일 게재확정

연구를 수행하였다. 또한, Kim et al. (2008)과 Oh et al. (2008)은 수문자료의 결측치 추정 및 보정을 위하여 인공신경망을 적용하였으며, Sajikumar et al. (1999)은 대상자료의 빈약성에도 불구하고 신경망을 이용한 학습 과정에서 좋은 결과를 보였다.

그러나 신경망이 수문계의 적용에 있어서는 아직 학습방법에 따른 최적해를 구하는 데 한계가 있으며, 그 적용의 정규화가 미흡하다는 단점도 지니고 있다. 따라서, 신경망의 여러 문제들을 해결하기 위해서는 수문계의 다양한 적용을 통한 검토가 이루어져야 할 것이다 (Kang et al., 2003).

본 연구의 목적은 새만금 내의 논 포장에서의 일별 지표유출량을 추정하기 위하여, 오류역전파 알고리즘 기반의 인공신경망 모형을 구성하고, 시험포장의 모니터링 자료와 물수지식에 의해 산정된 지표유출량 자료를 이용하여 모형의 학습과 적용을 수행함으로써 논에서의 지표유출량 추정을 위한 신경망 모형의 적용성을 평가하는 데 있다.

## II. 재료 및 방법

### 1. 시험포장 및 수문자료 모니터링

전북 익산시 송학동에 위치하고 있는 국립식량과학원 벼백류부 부내 벼 연구 시험포장을 정량적 지표 유출량 추정을 위한 연구대상지로 선정하였다. 본 시험포장은 40 m×50 m 크기로 새만금 유역의 대표 토양종 중 하나인 전복토에 위치하고 있으며, 영농활동 및 시비, 물 관리를 조절할 수 있어 새만금 유역에서 영농활동에 따른 농업비점오염부하의 산정 및 저감효과를 정량

적으로 평가할 수 있는 논 시험포장이다 (Kang et al., 2010; 2011) (Fig. 1).

본 시험포장에서는 질소 무비구 (PT\_1), 맞춤형 비료구 (PT\_2), 완효성 비료구 (PT\_3) 3개의 시험구를 2반복으로 현장 모니터링을 수행하였다. 시험포장에서의 일 유출량을 정량적으로 추정하기 위하여 논 유출량에 영향을 미치는 물수지 요소 즉, 관개량, 강우량, 증발산량, 담수심 등의 값을 활용하였다. 관개량과 담수심은 각각 관개 유입구에 설치된 계량기와 부자식수위계를 이용하여 측정하였으며, 강우량 및 기타 기상인자의 경우 시험포장에서 약 200 m 떨어져 있는 시험포장 내 자동기상장비 (AWS)의 측정값을 활용하였다. 태양복사량의 측정값은 시험포장 인근에 위치한 전주기상청 자료를 이용하였다.

시험포장에서의 지표 유출량은 다음 식 (1)과 같이 산정하였다.

$$Runoff = (Prep + IR) - (ET + INF) - PD \quad (1)$$

여기서, *Prep*은 강우량 (mm), *IR*은 관개량 (mm), *ET*는 증발산량 (mm), *INF*는 침투량 (mm), *PD*는 담수심 (mm), *Runoff*는 지표유출량 (mm)이다.

### 2. 인공신경망 모형

본 연구에서는 신경망 모형에서 가장 널리 사용되고 있는 학습 방법인 오류역전파 (error back propagation, EBP)알고리즘을 이용하였다. 이는 일반화된 델타규칙 (generalized delta rule)으로서, 출력층의 오차를 먼저 계산하고, 오차의 미분으로 표현

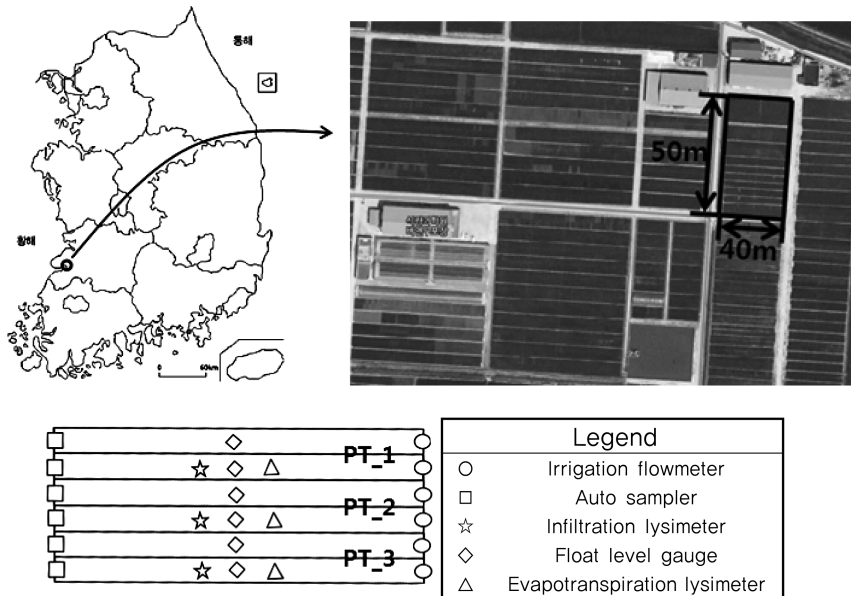


Fig. 1 Schematics diagram and experimental design

되는 값을 은닉층으로 역전파시켜 연결강도를 반복적으로 조정해 나가는 방법이다.

다층 순방향 신경망 (feed-forward neural networks) 훈련은 실측치와 모의치의 비선형 최소 자승인 가중함수를 최소화하는 것으로서 교사훈련 (supervised training)이라고 하며, 다음 식 (2)와 같이 나타내어진다.

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

여기서,  $E$  는 총오차,  $n$  은 실측치의 패턴 수,  $m$  은 총 출력단위,  $y_{pk}$  는 실측된 반응인 목표출력값으로서 일 유출량,  $p_{pk}$  는 모형에 의한 모의 출력값으로서 일 모의유출량을 나타낸다.

식 (2)에 의해 계산된 오차  $E$ 의 최소화는 최적화기법 중에서 경사하강법 (gradient descent method)을 사용하였다.

본 연구에서는 최적화기법인 경사하강법의 학습과정에서 발생할 수 있는 지역 최솟값 (local minima) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위하여 적응학습률 (adaptive learning rate)에 모멘트법을 고려하였으며 (Kang, 2002; Kang et al., 2003), 모멘텀 계수와 학습률을 병행하여 오차의 감소 여부를 확인하고 증감시킴으로서 최적 매개변수를 결정하였다.

은닉층에서의 최적 노드수를 얻기 위한 방법으로 Rissanen (1978)가 제안한 Bayesian Information Criterion (BIC)을 사용하였으며, 식 (3)과 같다.

$$BIC = M \ln(MSE) + P \ln M \quad (3)$$

여기서,  $M$ 은 신경망의 자료수,  $MSE$ 는 평균자승오차, 그리고  $P$ 는 매개변수의 수를 나타낸다.

### 3. 지표 유출량 추정모형

신경망 모형 구축시 입력 변수의 집단 구성 방법에 따라 모형의 성능에 직접적인 영향을 미치므로, 전체 입력변수들 중에서 하나씩 증가시키거나 감소시켜가면서 입력변수를 선택하였다.

논에서의 일 지표 유출량을 연속적으로 추정하기 위한 모형의 입력변수로 물수지 요소인 일 담수심과 관개량, 강우량 및 증발산량 자료를 사용하였다. 증발산량을 산정하는 기상인자는 증발산량에 크게 영향을 미치는 평균기온과 상대습도, 풍속 및 태양복사량만을 이용하였다.

작물 생육기간동안의 강우량 및 관개량은 지표 유출량에 큰 영향을 미치며, 강우 발생 시점과 관개 시작 시점에 따라 유출의 정도가 다를 수 있어 전날의 강우량 및 관개량 자료를 추가적

으로 입력하였다. 기상인자 중 평균풍속과 일조시간 또한 추가적으로 고려하여 모형을 구성하였다.

이를 고려하여 구성한 지표 유출량 추정모형은 식 (4)와 같이 19개의 입력층과 1개의 출력층으로 구성된 모형 (Paddy1901)이며, 입력 변수는 1일 전의 담수심, 5일 전부터의 강우량, 2일 전부터의 관개량, 평균기온, 상대습도 및 평균풍속, 4일 전부터의 일사량이다 (Fig. 3).




Fig. 3 The architecture of the artificial neural network (ANN) model for simulating surface runoff from rice paddy plots

$$Paddy1901; R(t) = f_{untion} \left( \begin{matrix} P(t-1), Prep(t-1), Prep(t-2), \\ Prep(t-3), Prep(t-4), Prep(t-5), \\ I(t-1), I(t-2), RH(t-1), RH(t-2), \\ W(t-1), W(t-2), T_{ave}(t-1), T_{ave}(t-2), \\ S(t-1), S(t-2), S(t-3), S(t-4), \end{matrix} \right) \quad (4)$$

여기서,  $P(t)$ 는  $t$ 일의 담수심,  $Prep(t)$ 는  $t$ 일의 강우량,  $I(t)$ 는  $t$ 일의 관개량,  $RH(t)$ 는  $t$ 일의 상대습도,  $W(t)$ 는  $t$ 일의 풍속,  $T_{ave}$ 은  $t$ 일의 평균기온,  $S(t)$ 는  $t$ 일의 태양복사량을 나타낸다.

모형의 입출력 자료는 구성된 지표 유출량 추정모형의 시그모이드 함수인 최솟값 0과 최댓값 1을 전달하므로 이론적인 정규화 범위로 변환하였으며, 식 (5)와 같다.

$$X' = \left[ \frac{1}{X_{max} - X_{min}} \right] \times (X - X_{min}) \quad (5)$$

여기서,  $X'$ 는 변환된 변수,  $X_{max}$ ,  $X_{min}$ 는 실측자료의 최댓값과 최솟값을 나타낸다.

식 (5)를 변환하여 일 유출량을 모의할 경우, 유출량의 최솟값과 최댓값에 제한요소가 나타나므로, 좀 더 큰 범위를 나타내기 위한 방법들을 사용할 수 있다 (Huynh, 2000; Kang, 2002). 본 연구에서는 최솟값과 최댓값의 범위를  $range [0.05R_{min}, 0.9R_{max}]$ 로 적용하였다.

지표 유출량 예측 모형의 수행 정도를 평가하기 위하여 평균제곱근오차 (root mean square error, RMSE), 상대평균절대오차 (relative mean absolute error, RMAE), Nash와 Sutcliffe (1970)가 제안한 효율지수 (Efficiency Index, EI), 결정계수 ( $R^2$ ), 상관계수 (R) 등의 통계적인 변량을 사용하였다 (Kang et al., 2009).

### III. 결과 및 고찰

#### 1. 수문자료 구축

전북 익산시 송학동에 위치하고 있는 국립식량과학원 벼맥류부 부내 벼 연구 시험포장에서 정량적 지표 유출량을 추정하기 위하여 작물 생육기간동안 현장 모니터링을 수행하였다.

관개량과 담수심은 각각 관개 유입구에 설치된 계량기와 부자식 수위계를 이용하여 측정하였으며, 강우량 및 기타 기상인자는 시험포장 내 자동기상장비의 측정값을 활용하였다. 결측자료는 시험포장 인근에 위치한 전주기상청 자료를 이용하여 보완하였다.

수집한 항목은 담수심, 관개량, 강우량 및 증발산량 산정을 위한 일 기상자료이며, 이를 물수지식에 적용하여 인공신경망 모형의 학습 및 검증자료로 사용될 일 지표 유출량을 산정하였다.

#### 2. 모형의 학습

모형의 학습을 위한 학습자료는 3개의 논포장 중 PT\_1과 PT\_2

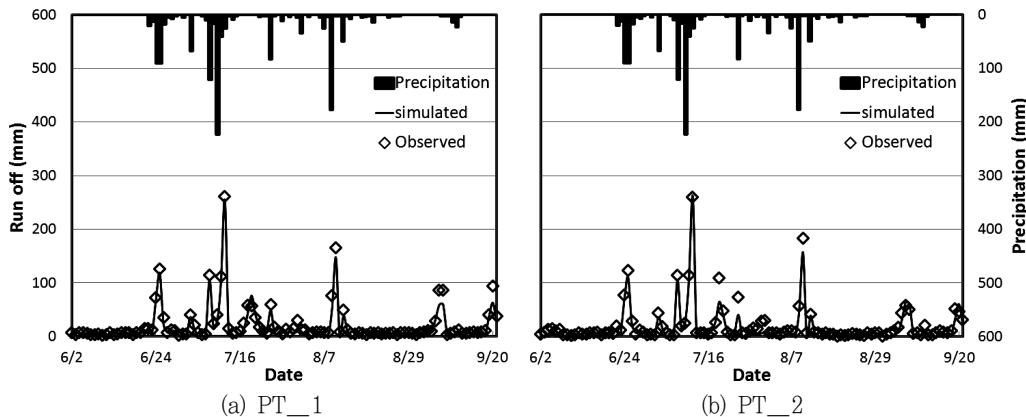


Fig. 5 Time series of observed and simulated daily surface runoff for the calibration period

에서의 현장 모니터링 자료를 이용하였다.

본 연구에서는 구성된 모형에 대한 은닉층의 최적 노드수를 결정하기 위하여 은닉층의 노드수를 1~20까지 변환시키면서 학습을 수행하였다. 총 학습 횟수는 과대적합 (Overfitting)과 과소적합 (Underfitting)을 고려하여 5000회로 하였다.

Fig. 4는 은닉층 노드수에 따른 총오차 (total error, TE), 자승오차 (sum of squared error, SE), 그리고 모형의 효율지수를 보여주고 있다 (Kang et al., 2001).

은닉층 노드수에 따른 Paddy1901모형의 학습 결과는 은닉층의 노드수에 따라 총오차와 자승오차합이 0.069~0.422의 범위를 보였으며, 모형의 효율지수는 0.569~0.937의 값을 보였다 (Fig. 4). 본 모형에서 은닉층에서의 최적 노드수는 16인 것으로 나타났다.

학습을 통해 얻어진 최적 모형은 19개의 입력층과 16개의 노드를 갖는 1개의 은닉층 및 1개의 출력층으로 구성된다.

Fig. 5는 Paddy1901 모형의 학습결과를 PT\_1, PT\_2 각각의




Fig. 4 Training results according to the number of nodes in the hidden layer (Paddy1901)

실측치와 비교하여 보여주고 있으며, Fig. 6은 PT\_1과 PT\_2를 학습한 결과에 대한 실측치와 모의치의 산포도를 나타내고 있다. Fig. 5에서와 같이 모의결과가 실측치의 경향을 잘 나타내고 있다.




Fig. 6 Scatter plots between observed and simulated daily surface runoff for the model calibration

Paddy1901 모형에서 얻어진 실측치와 모의치를 비교한 통계적 결과는 Table 1과 같다. 구성된 모형의 실측치와 모의치를 비교한 결과, RMSE는 8.470 mm/day, RMAE는 0.270 mm/day로 나타났으며, 모형의 효율성을 나타내는 효율지수 EI는 0.951로 나타났었다. 결정계수  $R^2$ 의 값은 0.961 상관계수 R은 0.976을 보임으로써 학습의 결과가 양호한 것으로 나타났다.

Table 1 Statistics of the Paddy1901 calibration results

Model	$N_h^*$	Calibration				
		RMSE (mm/day)	RMAE (mm/day)	EI	$R^2$	R
Paddy1901	16	8.470	0.270	0.951	0.961	0.976

\* Number of nodes in the hidden layer

### 3. 모형의 적용

학습결과를 바탕으로 최적 모형으로 선정된 일별 유출량모형인 Paddy1901의 적용성을 검토하기 위하여 PT\_3에 대한 모니터링 자료를 이용하였다.

Fig. 7에서 보듯이 Paddy1901 모형의 적용결과, 실측치와 모의치의 전체적인 경향성이 잘 나타나고 있다.

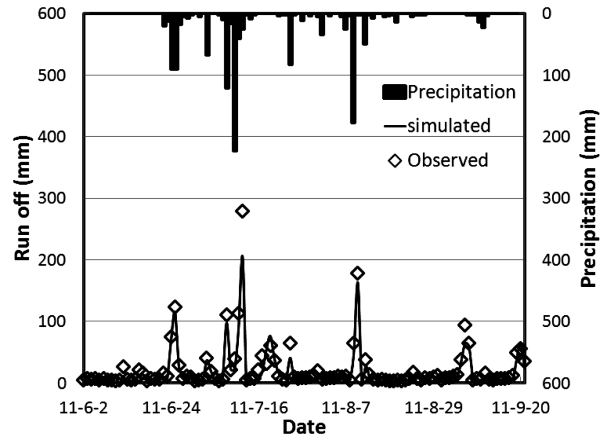


Fig. 7 Time series of observed and simulated daily surface runoff for the validation period

Fig. 8은 작물생육기간 동안 일별 유출량의 실측치와 모의치의 산포도를 보여주고 있다.




Fig. 8 Scatter plots between observed and simulated daily surface runoff for the model validation

모형의 적용 결과는 Table 2와 같이 RMSE는 10.822 mm/day, RMAE는 0.295 mm/day의 값을 나타내었다. 모형의 효율지수 EI

Table 2 Statistics of the Paddy1901 validation results

Model	$N_h^*$	Validation				
		RMSE (mm/day)	RMAE (mm/day)	EI	$R^2$	R
Paddy1901	16	10.822	0.295	0.915	0.945	0.964

\* Number of nodes in the hidden layer

는 0.915 결정계수와 상관계수의 값은 각각 0.945, 0.964의 값을 보임으로서 양호한 결과를 보였다.

#### IV. 요약 및 결론

본 연구에서는 전북 익산에 위치한 시험포장에서 작물생육기간 동안 현장모니터링을 통해 수집한 자료를 활용하여 오류역전파 알고리즘 기반의 일별 지표 유출량 추정모형을 구성하였다. 3개의 시험포장 중 PT\_1과 PT\_2의 모니터링 자료를 이용하여 학습을 수행하였고, 학습이 이루어진 신경망 모형을 PT\_3에 적용하여 모형의 적용성을 평가하였다. 본 연구결과를 요약하면 다음과 같다.

1. 전북 익산에 위치한 시험포장을 대상으로 작물 생육기간 동안 현장 모니터링을 수행하였으며, 담수심, 강우량, 관개량 및 증발산량 등의 자료를 수집하여 물수지식에 적용하여 논에서의 일 지표 유출량을 산정하였다.

2. 일 담수심, 강우량, 관개량 및 제한된 기상인자 즉, 평균기온, 상대습도, 풍속, 태양복사량만을 모형의 입력변수로 활용하여, 신경망 이론의 학습률과 모멘텀 계수를 고려한 오류역전파 알고리즘을 이용한 일 지표유출량 추정모형을 구성하였으며, 입력층의 노드수를 고려하여 Paddy1901 모형을 구성하였다.

3. 은닉층 노드수에 따른 Paddy1901 모형의 학습결과, 은닉층 노드수가 16개일 때의 오차가 가장 작은 0.069로 나타남으로서 학습이 가장 효과적으로 이루어졌다.

4. 은닉층의 최적노드수에 따라 Paddy1901 모형을 학습한 결과, 결정계수  $R^2$ 와 상관계수  $R$ 은 각각 0.961, 0.976으로 나타났다. RMSE는 8.470 mm/day, RMAE는 0.270 mm/day, EI는 0.951로 학습이 효과적으로 수행되었으며, 모형의 모의치가 실측치를 잘 모의하는 것으로 나타났다.

5. 학습결과를 바탕으로 선정된 Paddy1901 모형의 적용결과에 대한 통계적 결과치는  $R^2$ 와  $R$ 은 각각 0.945, 0.964, RMSE 10.822 mm/day, RMAE는 각각 0.295 mm/day, EI는 0.915로 나타났다. 이 결과, Paddy1901 모형을 통해 추정된 유출량의 모의치가 실측치를 잘 반영하는 것으로 나타났다.

본 연구를 통하여 논에서의 지표 유출량을 정량적으로 추정하기 위한 인공신경망 모형의 적용성을 검토하였다. 특히, 제시된 모형은 지속적인 현장 모니터링과 장기간의 수문자료 축적을 통하여 그 성능을 더욱 향상시킬 수 있을 것이며, 대상지에서 오착이나 결측값이 발생할 경우 자료 보정에 활용도가 높을 것으로 보인다. 또한, 동일한 환경의 대상지일 경우 본 연구의 학습을 통해 얻어진 최적 매개변수를 적용한다면, 향후 지표 유출량 추정 시 용이할 것으로 사료된다.

본 연구는 한국농어촌공사 농어촌연구원의 “새만금 유역 농업비점오염 저감기법개발 공동연구 제 4세부 「농업비점오염 저감을 위한 영농방법 개선기법 개발」 과제”의 일부 지원으로 수행되었습니다.

#### REFERENCES

1. Choi, J. K., and M. S. Kang, 2000. (Theory of) Neural network and application to water resources. *Journal of Korean National Committee on Irrigation and Drainage* 7(2): 248-258 (in Korean).
2. Huynh, N. P. and S. Sureerattanan, 2000. Neural networks for filtering and forecasting of daily and monthly streamflows. *Water Resources Publications, LLC, WEESHE, Hydrologic Modeling*, pp. 203-218.
3. Kang, M. S., and S. W. Park, 2001. Forecasting long-term streamflow from a small watershed using artificial neural network. *Journal of the Korean Society of Agricultural Engineers* 43(2): 69-77 (in Korean).
4. Kang, M. S., 2002. Development of total maximum daily loads simulation system using artificial neural networks for satellite data analysis and nonpoint source pollution models. Ph.D. Dissertation, Seoul National University (in Korean).
5. Kang, M. S., and S. W. Park, 2003. Short-term flood forecasting using artificial neural networks. *Journal of the Korean Society of Agricultural Engineers* 45(2): 45-57 (in Korean).
6. Kang, M. S., M. G. Kang, S. W. Park, J. J. Lee, and K. H. Yoo, 2006. Application of grey model and artificial neural networks to flood forecasting. *Journal of American Water Resources Association (JAWRA)* 42(2): 473-486.
7. Kang, M. S., J. P. Cho, J. A. Chun, and S. W. Park, 2009. Assessment of cell based pollutant loadings in an intensive agricultural watershed. *Journal of the Korean Society of Agricultural Engineers* 51(5): 87-94 (in Korean).
8. Kang, M. S., 2010. Development of improved farming methods to reduce agricultural non-point source pollution. Korea Rural Community Corporation Rural Research Institute (in Korea).

9. Kim, S. J., S. J. Kim, C. G. Yoon, H. J. Kwon, and G. A. Park, 2003. Development and application of paddy storage estimation model during storm periods. *Journal of Korea Water Resources Association* 36(6): 901-910 (in Korean).
10. Kim, T. S. K. H. Han, and J. H. Heo, 2008. Calibration of real-time rainfall data using artificial neural network. *Journal of Korea Water Resources Association* 41(10): 1059-1065 (in Korean).
11. Lee, E. J., M. S. Kang, J. A. Park, J. Y. Choi, and S. W. Park, 2010. Estimation of future reference crop evapotranspiration using artificial neural networks. *Journal of the Korean Society of Agricultural Engineers* 52(5): 1-9 (in Korean).
12. Nash, J. E. and J. V. Sutcliffe, 1970. River flow forecasting through conceptual models part I-A discussion of principles. *Journal of Hydrology* 10: 282-290.
13. Odhiambo, L. O., R. E. Yoder, D. C. Yoder, and J. W. Hines, 2001. Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Trans. of ASAE* 44: 1625-1633.
14. Oh, J. W., J. H. Park, and Y. K. Kim, 2008. Missing hydrological data estimation using neural network and real time data reconciliation. *Journal of Korea Water Resources Association* 41(10): 1059-1065 (in Korean).
15. Sajikumar, N. and B. S. Thandaveswara, 1999. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology* 216: 32-55.
16. Sudheer, K. P., A. K. Gosain, and K. S. Ramasastri, 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of Irrigation and Drainage Engineering* 129(3): 214-221.
17. Zanetti, S. S., E. F. Sousa, V. P. S. Oliveira, F. T. Almeida, and S. Bernardo, 2007. Estimation evapotranspiration using neural network and minimum climatological data. *Journal of Irrigation and Drainage Engineering* 133(2): 83-89.