

**Neuro-Fuzzy 추론기법을 이용한 홍수 예·경보****Flood Forecasting and Warning Using Neuro-Fuzzy Inference Technique**

이재응\* / 최창원\*\*

Yi, Jaeung / Choi, Changwon

**Abstract**

Since the damage from the torrential rain increases recently due to climate change and global warming, the significance of flood forecasting and warning becomes important in medium and small streams as well as large river. Through the preprocess and main processes for estimating runoff, diverse errors occur and are accumulated, so that the outcome contains the errors in the existing flood forecasting and warning method. And estimating the parameters needed for runoff models requires a lot of data and the processes contain various uncertainty. In order to overcome the difficulties of the existing flood forecasting and warning system and the uncertainty problem, ANFIS(Adaptive Neuro-Fuzzy Inference System) technique has been presented in this study. ANFIS, a data driven model using the fuzzy inference theory with neural network, can forecast stream level only by using the precipitation and stream level data in catchment without using a lot of physical data that are necessary in existing physical model. Time series data for precipitation and stream level are used as input, and stream levels for  $t+1$ ,  $t+2$ , and  $t+3$  are forecasted with this model. The applicability and the appropriateness of the model is examined by actual rainfall and stream level data from 2003 to 2005 in the Tancheon catchment area. The results of applying ANFIS to the Tancheon catchment area for the actual data show that the stream level can be simulated without large error.

**keywords** : ANFIS, neural network, data driven model, flood forecasting

**요 지**

최근 지구 온난화로 인한 이상기후의 영향으로 계절성 집중호우의 피해가 증가하고 있으므로 대하천뿐만 아니라 중·소하천에서도 홍수 예·경보의 중요성이 높아지고 있다. 기존의 홍수 예·경보 체계의 경우 유출량을 계산하는 전처리과정과 주 계산과정을 거치는 동안 많은 오차들이 발생하고, 누적되어 그 결과물(예측된 유출량) 속에 오차들이 내포되어 있다. 또한 유출모형의 적용에 필요한 매개변수들을 추정하기 위해서도 많은 실측자료가 필요하고, 많은 불확실성이 내재되어 있다. 본 연구에서는 기존의 홍수 예·경보 시스템의 문제점과 불확실성을 최대한 감소시키기 위해 ANFIS(Adaptive Neuro-Fuzzy Inference) 기법을 사용하였다. ANFIS는 신경회로망 기법을 사용한 data driven 모형으로 기존의 물리적 모형의 구축과정에서 필수적이었던 방대한 양의 물리적 자료를 배제하고 유역의 강우자료와 수위자료만으로 모형을 구축하고 수위 예측을 실시할 수 있다. 입력자료로는 시계열 강우자료와 수위자료를 사용하였고, 모형을 통하여  $t+1$ ,  $t+2$ ,  $t+3$  시간 후의 수위를 예측하였다. 탄천유역의 2003년부터 2005년까지의 강

\* 아주대학교 공과대학 건설교통공학과 부교수

Associate Prof., Dept. of Civil & Transportation Engrg., Ajou Univ., Suwon 422-749, Korea  
(e-mail: jeyi@ajou.ac.kr)

\*\* 아주대학교 대학원 건설교통공학과 석사과정

Graduate Student, Dept. of Civil & Transportation Engrg., Ajou Univ., Suwon 442-749, Korea  
(e-mail: itsme99@ajou.ac.kr)

우사상을 이용하여 모형의 적용성과 타당성을 검토하였고, 2006년 실제 강우에 모형을 적용한 결과 실제 수위를 큰 오차 없이 모의할 수 있었다.

**핵심용어** : ANFIS, 신경회로망, data driven 모형, 홍수예보

## 1. 서론

생물의 생존에 필수적인 물은 자연의 순환과정 속에서 효율적으로 이용하고 안전하게 관리하기 위한 노력은 인류가 시작된 이래로 계속 되어왔다. 물 관리의 영역에 있어서 치수와 관계되는 부분은 사람들에게 편리함을 주는 것이 목적이 아니라 위협으로부터 생명을 지키고 생활의 공간을 마련해 준다는 점에서, 이수나 친수의 영역에 비해 그 중요성이 한층 높게 평가되고 있다. 특히 우리나라의 경우 대부분의 하천은 유역면적이 작고 유로연장이 짧을 뿐만 아니라 산지가 많기 때문에 하천의 경사가 급한 곳이 많다. 또, 강우량의 대부분이 여름철인 6월에서 9월 사이에 집중호우나 태풍 등의 형태로 편중되어 나타나기 때문에 치수의 중요성이 더 부각되고 있다.

또한 최근 들어 그 심각성을 더하고 있는 지구 온난화에 따른 현상들을 보면 치수의 중요성을 실감할 수 있다. 특히 지구 온난화가 주요 원인으로 알려진 게릴라성 집중호우의 피해는 매우 심각하며, 1998년 지리산에서 시작된 집중호우로 324명의 인명피해와 1조 2천 500억원의 재산피해가 발생하였다. 1999년에는 경기도 북부 지역의 집중 호우로 64명의 인명피해와 2만 5천여 명의 이재민이 발생했으며, 2002년 8월 우리나라를 강습한 태풍 루사로 강릉지역에 하루에만 870mm의 강우가 발생하여 일 최대강수량 기록을 경신했다. 이 강우로 246명의 인명피해가 발생했고 5조원이 넘는 재산피해가 발생했다. 2006년 7월은 46일간 지속된 장마기간에 많은 인명과 재산 피해가 발생했다. 강원도 홍천에는 7월 한 달에만 1,244.5mm의 비가 쏟아졌다. 이렇듯 해가 갈수록 치수에 대한 중요성은 날로 커지고 있다.

지금까지 사용해 왔던 홍수 예경보 과정에서는 특정 지점에서의 유출량을 예측하기 위해서 전처리과정과 주계산과정을 거치는 동안 다양한 오차들이 발생하고 그것들이 누적되어 결과물(유출량) 속에 오차들이 내포되어 있다. 또한 모형의 운영에 필요한 매개변수의 결정에서도 자료의 질과 양에 따라 어려움이 발생하고, 많은 불확실성을 포함하고 있다. 본 연구에서는 이러한 기존의 홍수 예경보 시스템의 한계를 극복하고 불확실성을 해결하여 모형의 정확도를 높이기 위한 방법으로,

불확실성을 적극적으로 인정하고 수학적으로 해석하려는 퍼지이론과 신경망을 도입한 뉴로-퍼지이론을 홍수량 예측에 적용하였다.

본 연구에서는 뉴로-퍼지이론을 적용하여 관측 강우자료와 하천 수위 자료로부터 미래의 하천 수위를 예측하기 위한 모형을 개발하였다. 수위를 예측하는데 있어서, 기존의 물리적 모형 구축과정에서 필요한 유역의 물리적, 지형자료와 같은 방대한 양의 자료를 배제하고, 유역의 강우 자료와 과거의 수위 자료만으로 모형을 구축하고, 유역상황의 변화 시에도 쉽게 적용할 수 있도록 자료 지향형 모형의 한 형태인 ANFIS (Adaptive Neuro-Fuzzy Inference System)를 사용하였다. 본 모형은 도시하천인 경기도의 탄천 유역에 적용되어 강우 발생 시 유역의 하류에 위치하는 대곡교의 수위를 예측하였다.

## 2. 연구동향

지금까지 수문학 분야의 연구에서 강우-유출 과정의 모형화를 위해 많은 연구가 진행되고 있다. 연구의 방향을 사용 모형의 종류에 따라 구분하면 크게 물리적 모형과 실험적 모형을 적용하는 방향으로 구분할 수 있다. 물리적 모형은 강우-유출과정을 물리적인 식을 사용하여 구체적으로 나타내는 방법이고 자료 지향형 모형은 신경망이나 ANFIS와 같이 입력값과 출력값과의 관계만을 이용하여 강우-유출과정의 최적 매개변수를 추정하는 방법이다.

기존의 연구에 많이 사용되었던 물리적 모형과 달리 본 연구에서 사용한 자료 지향형(data driven) 모형은 유역의 물리적, 지형적 특성을 고려하지 않고, 강우와 같은 입력자료와 유출과 같은 출력자료만을 고려하여 구축되는 모형이므로, 유역의 물리적, 지형 자료와 같은 방대한 양의 자료 수집이 필요 없고, 일단 모형이 구축되면 자료의 입력만으로 신뢰성 높은 결과를 단시간 내에 효율적으로 획득할 수 있는 장점이 있다. 따라서 유역 내의 물리적 상황이 변화하면, 이들의 영향을 반영하여 쉽게 모형을 갱신할 수 있다. 그러나 자료지향형 모형의 경우 입출력 자료의 품질에 따라 그 결과가 좌우되므로 양질의 자료가 확보되지 않은 유역에는 적용하기 어렵고, 모형 구축과정에서 수학적, 물리적 논리성

이 부족하다는 단점을 가지고 있다. 이와 같은 장단점이 있지만, 모형의 구축 과정이 물리적 모형에 비해 쉽고, 신속하다는 장점으로 인해 최근 여러 분야에서 사용되고 있다.

본 연구에서는 사용하려는 ANFIS의 기본인 fuzzy 이론은 Zadeh (1965)가 제안한 fuzzy알고리즘과 복잡한 시스템의 언어모델링을 이용하여 Mamdani and Assilian (1975)이 제어에 응용 한 것이 fuzzy 제어의 시초이다. 그 후 1980년경부터 일본을 중심으로 fuzzy 제어에 관한 연구와 실용화가 활발하게 시작되었다.

1970년경부터는 퍼지이론이 토목분야에 적용되기 시작하였고, 이후 퍼지 기법에 적합한 소속함수를 찾기 위해 신경회로망 이론을 도입한 퍼지신경회로망기법도 토목분야에 적용되었다. 최근 Gautam and Holz (2001)가 ANFIS를 강우-유출해석에 적용하였고, Chang *et al.* (2001)이 미세측 하천유량의 확충에 뉴로-퍼지 기법을 적용한 사례가 있다. Nayak *et al.* (2005)은 3년간의 호우자료를 이용하여 ANFIS, 인공신경망, 퍼지추론시스템을 이용하여 유량을 예측하였다. 특히 Aquil *et al.* (2007)은 유량예측을 위해 Levenberg-Marquardt feed forward neural network(FFNN), Bayesian regularization-FFNN, Neuro-Fuzzy 모형을 비교한 결과 Neuro-Fuzzy 모형 사용 결과가 가장 우수하다고 제안하였다.

우리나라에서도 최근 퍼지신경회로망을 토목분야에

적용하기 위한 연구가 활발히 진행되고 있다. 강일환 (1999)은 광주광역시의 급수량 시계열자료를 입력자료로 ANFIS모형을 통해 일일 급수량을 예측하였다. 고영후(2001)는 1998~1999년 사이에 발생한 4번의 대표적인 홍수사상의 강우와 유출 자료를 이용하여 영산강 유역의 시유출을 예측하고, 2002년 신성일은 1997~2002년 홍수사상의 자료를 이용하여 금호강 유역의 유출을 예측하였다. 또한, 정대명(2003)은 ANFIS모형을 통하여 소양강의 유입량을 예측하는 등 국내에서도 퍼지신경회로망에 대한 연구가 많이 시도되고 있다.

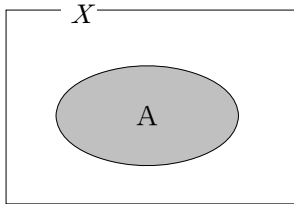
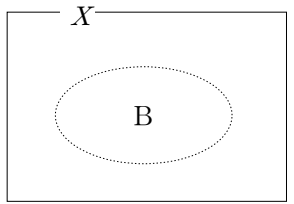
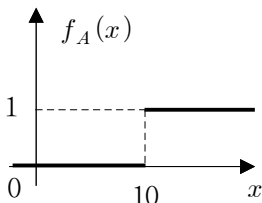
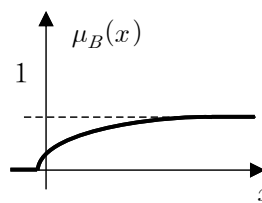
### 3. ANFIS의 기본 이론

#### 3.1 퍼지 집합과 퍼지 추론

퍼지란 어느 집합의 원소가 그 집합에 속하는지 또는 속하지 않는지에 대하여 명확히 구분할 수 없는, 부정확성을 의미한다(Zadeh, 1965). 일반적인 집합(crisp 집합)의 경우에는 소속함수와 nonmembership이 명확히 구분되어 나타나지만, 퍼지 집합에서는 membership의 정도가 0~1사이의 어떤 값을 갖는다. 우리가 현실에서 다루어야 하는 집합은 퍼지 집합과 같이 membership의 경계가 명확하지 않은 경우가 대부분이다. 일반집합과 퍼지 집합의 차이점을 다음의 Table 1을 통해 제시하였다(강일환, 1999).

퍼지 추론이라는 것은 몇 개의 퍼지 명제로부터, 어

Table 1. Difference between Crisp Set and Fuzzy Set

	crisp set	fuzzy set
boundary of set		
rate of membership	0 or 1	0 ~ 1
expression	characteristic function $F_A(x)$	membership function $\mu_B(x)$
example	$A = \{x   x \geq 10\}, x \in X$ 	$B = \{x   x \text{ is stabilized water supply}\}$ 

는 한 개의 명제를 도출해 내는 추론법이고, 인간이 행하고 있는 추론법과 매우 유사하므로 최근 크게 주목받고 있는 분야이다. 가장 단순한 퍼지 추론에서는 하나의 전제와 하나의 결과만을 갖지만, 일반적인 추론에서는 좀 더 복잡한 구조를 지닌다. 보통 몇 가지 전제들이 교집합이나 합집합의 형태를 가지고 있고 이를 통해 결론을 얻는 경우가 대부분이다. 각각의 퍼지 추론으로부터 얻은 결과값을 종합하기 위해서는 각 결과값을 종합하여 도심을 구하는 방법으로 최종 결과값을 출력하는 방법을 주로 사용한다. 이 과정을 탈퍼지화(defuzzify) 과정이라고 한다. 일반적으로 사용되는 퍼지추론 과정을 정리하면 다음과 같다(Table 2).

Table 2. Process of Fuzzy Inference

	steps
step 1	fuzzification of input
step 2	application of fuzzy operation
step 3	application of consent method
step 4	sum of all output
step 5	defuzzification

### 3.2 신경회로망의 구조와 역전파 학습 알고리즘

인공 신경회로망은 정보가 들어오는 입력층, 뉴런에 미치는 영향의 크기를 조절하는 연결 강도, 입력과 연결 강도를 결합하는 결합 함수, 그리고 결합 함수로부터 나온 결과를 변환하여 출력값을 결정하게 되는 활성화 함수로 구성된다. 아래의 Fig. 1은 신경회로망의 수리 모델이며, n개의 입력을 받아 각각의 연결 강도를 곱한 총합에서 임계치를 뺀 값을 활성화 함수에 의해 변형하여 출력치를 계산한다.




Fig. 1. Neuron Structure of Artificial Neural Network

역전파와 신경회로망은 Fig. 3과 같이 다층 퍼셉트론(multi-layered perceptron)의 구조를 갖고 있으며, 학습 단계와 산출 단계로 동작한다. 학습 단계에서는 입

력 양상과 목적 양상이 다수의 입·출력 쌍으로 주어지고, 각 입력 양상에 대해 출력을 먼저 계산(전방향 진행)한 후, 의도하는 출력과 실제 출력과의 차이를 감소시키는 방향으로 연결 강도를 조정(역방향 진행)한다. 조정 과정이 끝나면 같은 과정으로 학습을 반복함으로써 최적의 연결 강도를 구한다. 산출 단계에서는 입력만 주어지면 연결 강도와 계산에 의해 적절한 출력이 계산된다.




Fig. 2. Activation Function

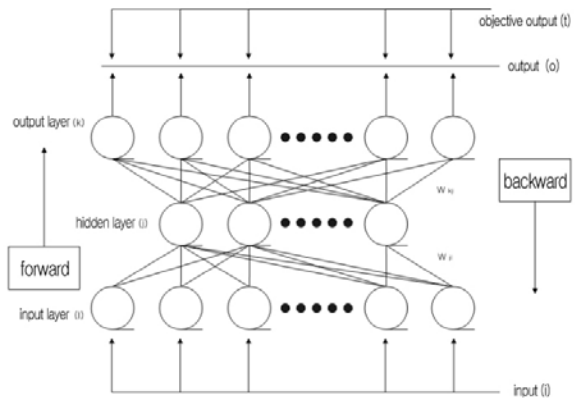


Fig. 3. Structure of Multi-layered Perceptron

### 3.3 ANFIS구조와 학습 알고리즘

신경회로망과 퍼지 논리의 장점을 최대한 이용하고, 각각의 기술이 가지고 있는 단점을 보완하기 위해 여러 가지 형태의 뉴로-퍼지 회로망이 활발히 이용되고 있다. 퍼지이론과 신경망 이론은 모두 특정 분야에 대해서 인간처럼 판단할 수 있는 시스템을 구축하는 것이 목적이지만, 두 이론이 강점을 갖는 분야는 조금 차이가 있다.

ANFIS는 신경회로망과 퍼지이론을 동시에 활용하는 방법으로 신경회로망의 구조와 학습능력을 이용하여 제어환경에서 획득한 입·출력 정보로부터 언어변수의 membership 함수와 제어규칙을 제어 대상에 적합하도록 자동으로 조종하는 기법이다. 신경회로망을 이용하여 membership 함수를 결정하면 다음과 같은 장점이 있다. 첫째, 사용자가 직접 개입되지 않아도 member-

ship 함수에 대한 학습이 자동으로 이루어지기 때문에 시스템의 개발 시간이 단축될 수 있다. 둘째, 신경회로망은 비선형성을 가지기 때문에, 비선형 membership 함수를 결정할 수 있다. 셋째, 신경회로망의 학습기능을 이용하여 전문가로부터 규칙을 자동으로 획득할 수 있다. 넷째, 신경회로망의 학습기능에 의해 추론 환경에 능동적으로 적응할 수 있다.(강일환, 1999)

### 3.4 퍼지 클러스터링 기법

일반적으로 ANFIS의 퍼지 제어기 구성방법은 입력 변수 공간을 격자 형태로 분할하고, 분할된 공간마다 해당되는 결론부 규칙을 한 개씩 할당하여 퍼지 특성으로 표현한다. 그러나 입력공간을 격자형으로 분할할 경우 비선형 시스템에 유연하게 적용될 수 없으며, 퍼지 제어에 사용되는 입출력 변수가 많아지고 퍼지집합으로 표현되는 퍼지변수의 수가 많아짐에 따라 퍼지 규칙의 수는 기하급수적으로 증가하게 된다. 분할 개수가 많다고 해서 결코 좋은 분할은 아니므로 최적의 공간분할 방법이나 불필요한 규칙을 제거하여야 하는 문제가 제기된다. 따라서 본 연구에서는 퍼지 클러스터링 방법을 이용하여 입력공간을 분할하고, 분할된 공간에서 퍼지 규칙을 자동으로 생성할 수 있는 방법을 사용하였다.

## 4. 모형의 적용

### 4.1 탄천 유역

본 연구에서는 경기도의 탄천 유역을 대상으로 ANFIS를 이용하고 과거 및 현재의 강우와 수위 사상을 사용하여 미래의 하천 수위를 예측하였다. 탄천은 경기도 용인시에서 발원해서 성남시와 서울특별시 송파구·강남구를 거쳐 한강으로 흘러드는 한강의 지류로서, 절반이 넘는 약 25km 구간이 성남시의 중심부에 걸쳐 있는 전형적인 도시하천이다. 총 유역면적 302km<sup>2</sup>, 총 연장 35.6km이며 유역의 동서간 최대길이는 17.5km, 남북간 최대길이는 29.7km 이다(Fig.4). 유역의 중심이 속해있는 성남시점의 11년간 강우량 자료를 통해 살펴보면 연 평균 강우량은 약 1238.3mm 정도이고, 6월~9월 중에 약 959mm의 강우(77.4%)가 집중되어 발생한다.

## 4.2 모형구축과 검증

### 4.2.1 입력자료 구축

본 연구에서는 탄천 유역 하류의 하천 수위를 예측하기 위해 두 개의 강우관측소(하대원동, 서현동 강우관측소)와 하천 수위자료(구미교 수위자료)를 이용하였다. 성남시 중원구 하대원동에 위치한 강우관측소와 성남시 분당구 서현동에 위치한 강우관측소에서 2003년부터 2005년까지의 강우자료 중, 단일 호우사상이 100mm 이상의 강우량을 가지면서 10시간 이상의 강우 지속시간을 가지는 강우를 각각 세 개 선정하였다. 각 관측소 별로 사용된 강우자료는 다음과 같다(Table 3과 4). 모형의 구축과정에서는 강우와 유출 자료의 시간적인 관계를 판단하여 입력자료를 구축하기 위해서 각각 하나의 강우관측소와 수위관측소 자료를 이용하여 비교하였다.



Fig. 4. Tancheon Basin

Table 3. Rainfall Data of Hadaewon-Dong Observation Station

data	start date and time	end date and time	maximum intensity	maximum water level
training data	2003.08.27.10:30	2003.08.28.07:00	70mm/hr	170.88cm
checking data	2005.09.13.05:10	2005.09.13.22:10	15mm/hr	160.41cm
testing data	2005.09.17.07:50	2005.09.18.04:00	8mm/hr	129.46cm

**Table 4. Rainfall Data of Seohyeon-Dong Observation Station**

data	start date and time	end data and time	maximum intensity	maximum water level
training 자료	2004.07.11.17:50	2004.07.13.06:10	8.5mm/hr	161.14cm
checking 자료	2005.06.30.23:50	2005.07.01.10:40	12.5mm/hr	143.83cm
testing 자료	2005.09.13.12:30	2005.09.13.23:20	23.0mm/hr	160.41cm

**4.2.2 자료의 구성**

수위예측 모형 구축에 있어서 중요한 인자들 중의 하나는 수위에 영향을 미치는 강우와 수위의 시간적 분포를 입력자료 집합과 관련하여 어떤 방식으로 구성할 것인가이다. 수위와 강우자료를 어떻게 구성하는 것이 미래의 수위를 가장 우수하게 예측하는지를 비교 분석하는 것은 본 연구의 수행에서 가장 중요한 부분 중의 하나이다.

어떤 방식의 입력자료 구성이 가장 적합한가를 찾기 위해 두 곳의 강우관측소에 대해, 6가지 코드 구성, 2가지의 자료의 시간간격(lag time), 3가지의 예보시간(lead time)을 설정, 조합하여 각각의 강우 관측소 자료마다 36가지의 경우에 대해 수위를 예측하고 비교하였다

(Table 5). 어떻게 자료를 구성하는 것이 가장 우수인가를 비교, 분석하기 위해서 Table 6과 같이 자료를 구성하였다.

**Table 5. Mixing of All Data Set**

observatory	set code	lag time	lead time
Hadaewon	P01 -Q01	10 min	t+1
	P01 -Q012		
	P012 -Q01		
Seohyeon	P012 -Q012	30 min	t+2
	P0123-Q01		
	P0123-Q012		

**Table 6. Set of Input Data**

set code	input data	output data	$\Delta t$
P <sub>1</sub> 01 -Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), Q(t), Q(t-1),	Q(t+3)	10min
P <sub>1</sub> 01 -Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>1</sub> 012 -Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), Q(t), Q(t-1),	Q(t+3)	
P <sub>1</sub> 012 -Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>1</sub> 0123-Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), P <sub>1</sub> (t-3), Q(t), Q(t-1),	Q(t+3)	
P <sub>1</sub> 0123-Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), P <sub>1</sub> (t-3), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>1</sub> 01 -Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), Q(t), Q(t-1),	Q(t+3)	30min
P <sub>1</sub> 01 -Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>1</sub> 012 -Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), Q(t), Q(t-1),	Q(t+3)	
P <sub>1</sub> 012 -Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>1</sub> 0123-Q01	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), P <sub>1</sub> (t-3), Q(t), Q(t-1),	Q(t+3)	
P <sub>1</sub> 0123-Q012	P <sub>1</sub> (t), P <sub>1</sub> (t-1), P <sub>1</sub> (t-2), P <sub>1</sub> (t-3), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 01 -Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), Q(t), Q(t-1),	Q(t+3)	10min
P <sub>2</sub> 01 -Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 012 -Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), Q(t), Q(t-1),	Q(t+3)	
P <sub>2</sub> 012 -Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 0123-Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), P <sub>2</sub> (t-3), Q(t), Q(t-1),	Q(t+3)	
P <sub>2</sub> 0123-Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), P <sub>2</sub> (t-3), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 01 -Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), Q(t), Q(t-1),	Q(t+3)	30min
P <sub>2</sub> 01 -Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 012 -Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), Q(t), Q(t-1),	Q(t+3)	
P <sub>2</sub> 012 -Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), Q(t), Q(t-1), Q(t-2)	Q(t+3)	
P <sub>2</sub> 0123-Q01	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), P <sub>2</sub> (t-3), Q(t), Q(t-1),	Q(t+3)	
P <sub>2</sub> 0123-Q012	P <sub>2</sub> (t), P <sub>2</sub> (t-1), P <sub>2</sub> (t-2), P <sub>2</sub> (t-3), Q(t), Q(t-1), Q(t-2)	Q(t+3)	





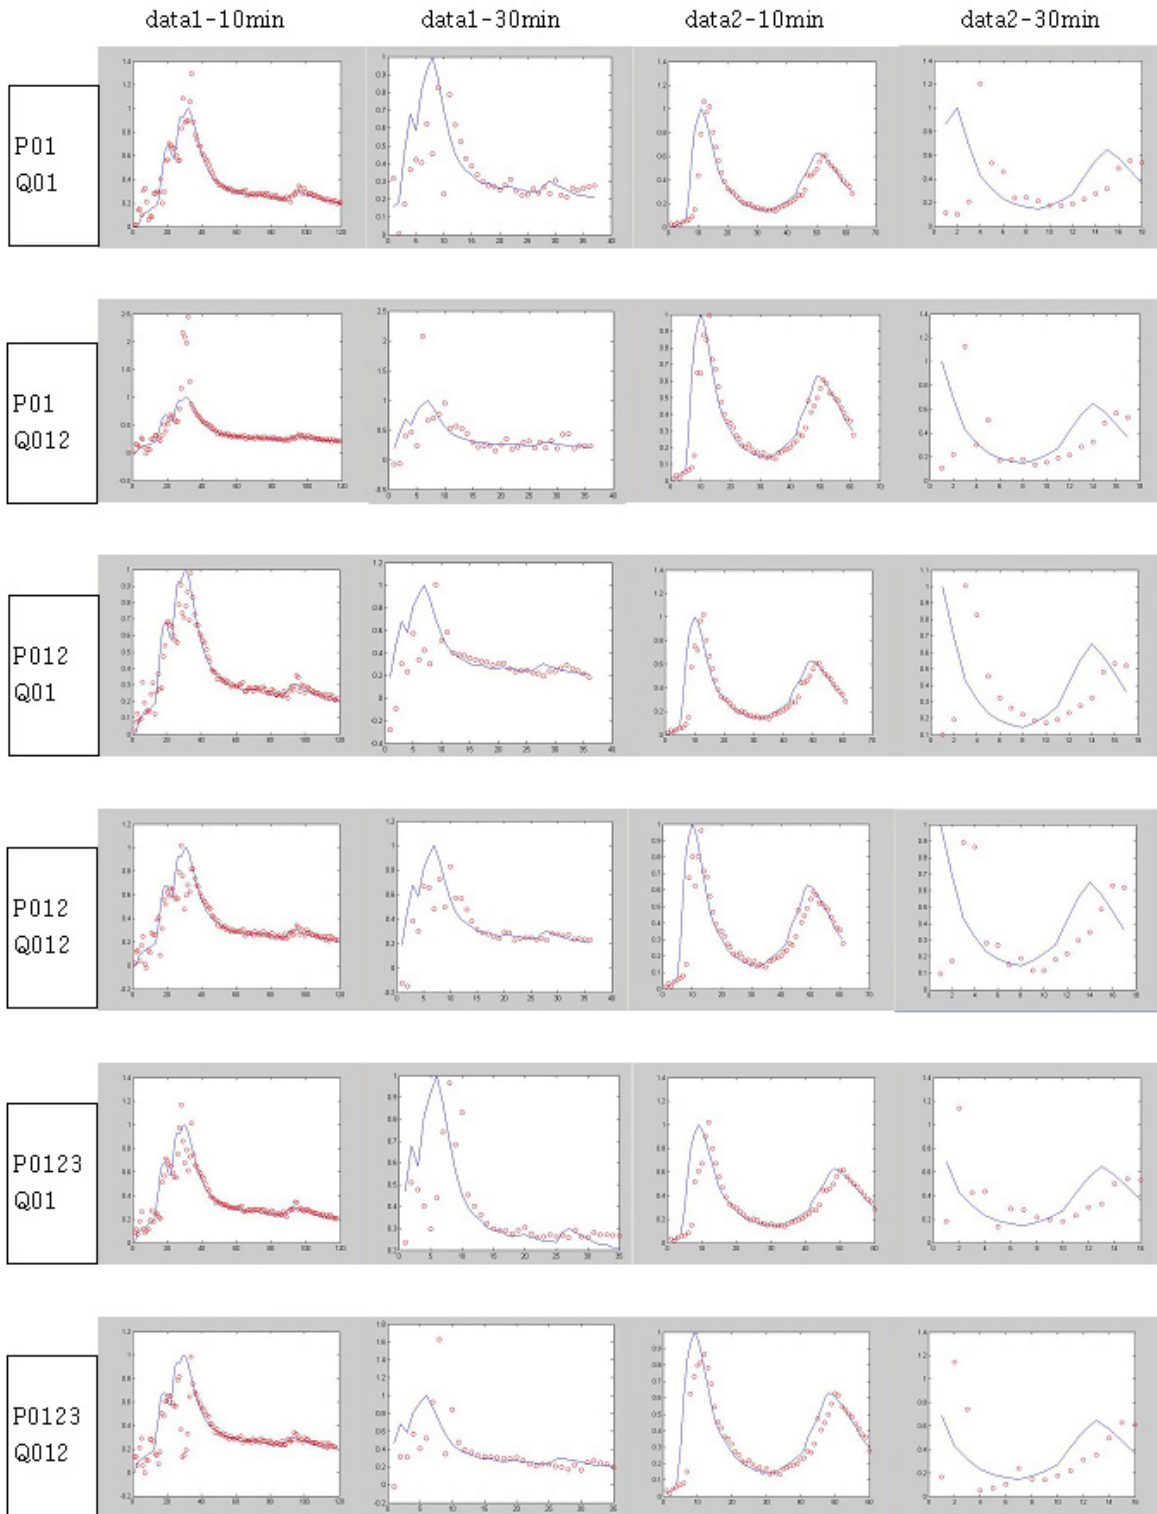


Fig. 7. Testing Data

$$RMSE = \sqrt{\frac{\sum(D_i - \bar{D})^2}{n-1}} \quad (1)$$

여기서  $D_i$ 는  $i$ 번째 자료,  $\bar{D}$ 는 자료의 평균,  $n$ 은 총 자료의 개수를 나타낸다.

$$RD = \frac{|D_{r,peak} - D_{p,peak}|}{D_{r,peak}} \quad (2)$$

여기서  $RD$ 는 첨두수위비,  $D_{r,peak}$ 는 실측첨두수위,  $D_{p,peak}$ 는 예측첨두수위를 나타낸다.



산정된 RMSE 값을 Table 7에 제시하였다. 전체적인 추세는 10분 간격으로 측정하여 수위값을 예측한 자료 가, 30분 간격의 자료보다 약 2배 정도 우수한 결과를 보인다는 것을 확인할 수 있다. 또한 data1의 예측값이 data2의 예측값보다 더 양호하지만, 강우관측소의 종류, 또는 자료의 측정 간격(10분 간격과 30분 간격)에 따라 모두 상이한 자료 구성에서 가장 우수한 값들이 발생하였다.

Table 8에서 침두수위비를 검토하면, 전체적인 추세는 비교할 수 없을 정도로 각각의 편차가 크게 발생한다. 그러나 RMSE의 경우와는 달리, 전체적으로 강우자료는 t, t-1, t-2의 자료를 사용하고, 수위자료는 t, t-1의 자료를 입력값으로 사용한 자료 set(set code: P012-Q01)의 경우가 가장 양호한 예측결과를 나타낸다. 서현동 강우관측소 10분 간격의 강우데이터를 사용했을 경우는 P01-Q012의 경우가 우수하지만 상대적으로 서현동 10분 간격 데이터를 제외하고는 모두 상당한 편차를 나타낸다. 이 경우에도 P012-Q01의 예측값이 상당히 양호한 값을 갖기 때문에, 모든 경우에 P012-Q01의 자료 구성이 가장 우월하다고 판단할 수 있다.

RMSE 값의 경우는 전체적인 예측값이 실측값과 얼마나 큰 편차를 가지고 있는가 하는 전체적인 추이를

나타내는 값이고, 침두수위비는 실측값과 예측값의 침두수위값을 비교하기 위한 척도이다. 홍수 예경보 시스템 구축에서 침두수위의 정확한 예측은 가장 중요한 요소 중의 하나이므로, 앞에서 판단한 것처럼 RMSE 값을 통해서만은 전체적인 추세를 판단하고, 침두수위비를 통해서 어떻게 자료를 구성하는 것이 가장 적합한가를 찾아내는 방법이 옳다고 판단된다.

결국 그래프, RMSE, 침두수위비를 통해서 자료의 구성을 비교해보았을 때, P012-Q01의 자료 set이 가장 우수한 수위 예측을 하는 것으로 판단된다.

#### 4.3 대곡교 수위 예측

2006년 7월 15일을 기준으로 수위관측소는 본 연구 수위예측의 목표지점인 대곡교 지점을 최종 선정하였고, 강우관측소는 수위 관측지점인 대곡교 지점을 제외하고, 삼각형을 이루고 있는 3곳의 강우관측소(서현동 지점, 하대원동 지점, 운중동 지점)를 최종 강우관측점으로 선정하였다. 모형을 구성하기 위한 입력자료로는 10분 간격의 강우자료와 수위자료를 사용하였다. 탄천 유역은 총 유역면적 302km<sup>2</sup>로 비교적 소규모 유역에 속하므로 세 곳 관측소의 지점강우량을 디센망을 이용하여 유역의 면적강우량으로 환산하여 사용하였다.

Table 7. Comparison of RMSE (t+3)

set code	Seongnam observatory #1 (Hadaewon)		set code	Seongnam observatory #2 (Seohyeon)	
	10min interval	30min interval		10min interval	30min interval
P <sub>1</sub> 01 -Q01	0.091283	0.178441	P <sub>2</sub> 01 -Q01	0.145711	0.381445
P <sub>1</sub> 01 -Q012	0.223225	0.270284	P <sub>2</sub> 01 -Q012	0.140135	0.331887
P <sub>1</sub> 012 -Q01	0.087176	0.235900	P <sub>2</sub> 012 -Q01	0.143179	0.342845
P <sub>1</sub> 012 -Q012	0.094875	0.183858	P <sub>2</sub> 012 -Q012	0.141167	0.337234
P <sub>1</sub> 0123-Q01	0.091627	0.188485	P <sub>2</sub> 0123-Q01	0.153003	0.263516
P <sub>1</sub> 0123-Q012	0.172326	0.246418	P <sub>2</sub> 0123-Q012	0.139399	0.287313

Table 8. Comparison of Peak Ratio (t+3)

(Unit : %)

set code	Seongnam observatory #1 (Hadaewon)		set code	Seongnam observatory #2 (Seohyeon)	
	10min interval	30min interval		10min interval	30min interval
P <sub>1</sub> 01 -Q01	11.909	15.506	P <sub>2</sub> 01 -Q01	5.857	19.402
P <sub>1</sub> 01 -Q012	120.811	96.060	P <sub>2</sub> 01 -Q012	0.709	11.808
P <sub>1</sub> 012 -Q01	0.923	0.656	P <sub>2</sub> 012 -Q01	1.915	0.345
P <sub>1</sub> 012 -Q012	4.902	15.156	P <sub>2</sub> 012 -Q012	3.564	10.226
P <sub>1</sub> 0123-Q01	12.760	3.059	P <sub>2</sub> 0123-Q01	1.906	13.127
P <sub>1</sub> 0123-Q012	0.970	55.891	P <sub>2</sub> 0123-Q012	12.661	13.420

우선 검토자료가 검증자료의 일부이기 때문에 수위 예측 모형자체가 만들어진 과정에서 overfitting전의 최적화된 매개변수 추정에 사용된 자료임을 배제하고 순수하게 하나의 검토자료로만 판단하였다. 분석 결과, Table 9에서와 같이 RMSE값과 첨두수위비 모두 Table 7과 Tabel 8에서 제시한 RMSE값과 첨두수위비보다 우수한 결과를 나타내고 있다. Fig. 8과 Table 10에서는 최종 모형을 통해 대곡교의 수위를 예측한 결과를 제시하였다(Fig. 9에서 x축은 시간, y축은 수위를 나타냄). 수위를 예측한 결과 Table 10에 제시한 것과 같이 실측값과 예측값의 차이가 1.4~3cm에 불과하였다.

Table 9. RMSE, Peak Ratio and Peak Error of Final Model

	RMSE	rate of peak (%)	error of peak
t+1	0.026152	0.103054	-0.004586
t+2	0.031655	0.351987	0.015663
t+3	0.043210	0.001796	0.000080

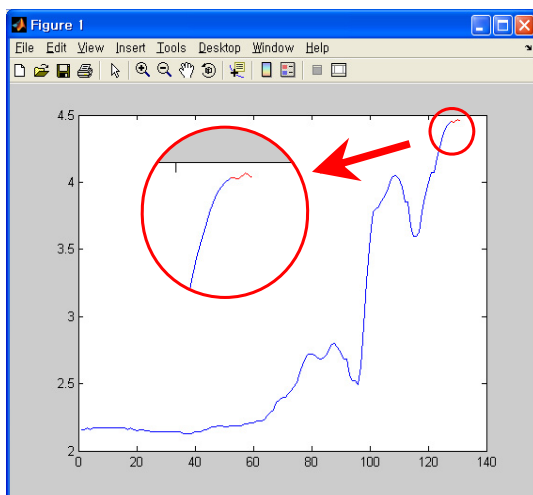


Fig. 8. Test of Water Level Forecasting

Table 10. Comparison Real with Forecast Data

	observation data	forecasting data	error(m)
t+1	4.47	4.445414	-0.02459
t+2	4.48	4.465663	-0.01434
t+3	4.48	4.45008	-0.02992

그리고 이번 예측의 경우 lead time에 따른 RMSE값을 비교해보면 예측시간이 t+1인 경우가 t+2의 경우보다, t+2의 경우가 t+3인 경우보다 우수하다는 것을 알

수 있다. 검증자료가 전체적으로 상승하는 형태를 보이고 있기 때문에 첨두수위값 자체가 측정 데이터의 마지막 관측값에서 t+1, t+2, t+3으로 갈수록 증가하고 있고, 각각의 마지막 데이터가 첨두수위를 갖고 있기 때문에 첨두수위비의 경우 서로 비교하는 것이 무의미하다고 판단된다.

## 5. 결론

본 연구에서는 탄천유역의 대곡교 지점의 수위를 예측하기 위해 퍼지이론과 신경망 이론이 결합된 뉴로-퍼지 시스템인 ANFIS를 이용하여 수위 예측 모형을 구성하고, 비교, 검토하였다. ANFIS는 자료 지향형 모형으로 기존에 널리 사용되던 개념적 모형이나 물리적 모형과는 차이가 있다. 자료 지향형 모형은 정확한 개념이나 정밀한 모형을 구성하기 어려운 자연현상을 대상으로 구축할 때 더 큰 장점을 나타낸다. 본 연구를 통해 다음과 같은 결론을 얻을 수 있었다.

- 1) ANFIS 모형을 구축하는데 있어서 입력자료의 개수가 많다고 항상 우수한 모형을 구축하는 것은 아니다. 관측 자료의 특성에 맞추어 적절하게 입력자료가 조합되었을 때 가장 우수한 예측 모형을 구축할 수 있다. 그러나 자료로 사용하는 각각의 강우 사상의 자료 길이가 긴 것이 좀 더 우수한 모형을 구축하거나, 구축 후 좀 더 정확한 예측을 하는데 도움이 된다고 판단된다.
- 2) 수위를 예측할 때 수위의 변화 양상, 특히 상승부와 하강부의 형상에 따라서 정확도의 차이가 발생한다. 상승부나 하강부의 형상이 완만한 경사를 가지고 천천히 증감하는 형태를 보일 때 산정값이 실측치를 좀 더 유사하게 예측하였다. 반면, 수위의 형상이 급격한 경사를 가지거나 갑작스런 상승이나 하강을 할 경우 완만한 경사를 갖는 경우보다 동일한 변동폭에 대해 적은 자료를 가지기 때문에 더 큰 편차를 보이는 것으로 사료된다.
- 3) 탄천 유역의 수위 예측에서는 P012-Q01의 형태로 입력자료가 구성되었을 때 가장 우수한 예측을 하였다.

Neuro-Fuzzy 추론기법을 이용하면 유역 내 강우와 수위자료를 이용할 수 있을 때 신뢰성 높은 수위의 예측이 가능하므로 홍수 예·경보 시 수위 예측을 위한 하나의 대안으로 사용될 수 있을 것으로 판단된다. 또한, 기존의 물리적 모형과의 비교, 검토를 통해 보완적 측면에서 상호 지원이 가능할 것이다.

## 참 고 문 헌

- 강일환 (1999). ANFIS이론을 이용한 상수도 일일 급수량 예측, 전남대학교 토목공학과 석사학위 논문, pp. 22-43.
- 고영후 (2001). 하천의 시유출량 예측을 위한 퍼지신경회로망의 적용, 전남대학교 토목공학과 석사학위 논문, pp. 1-6, pp. 14-17.
- 신성일 (2002). 신경회로망과 뉴로-퍼지를 이용한 홍수량예측에 관한 연구, 경일대학교 도시정보, 측지지적공학과 석사학위 논문.
- 정대명 (2003). 월 댐유입량 예측을 위한 뉴로-퍼지시스템의 적용, 세종대학교 토목환경공학과 석사학위 논문, pp. 2-5.
- Aquil, 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 behavior of runoff." *Journal of Hydrology*, 337(1-2), 22-34.
- Chang, F.J., and Chen, Y.C. (2001). "A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction." *Journal of Hydrology*, Vol. 245, pp. 153-164.
- Chang, F.J., Hu, H.F and Chen, Y.C. (2001). "Counterpropagation fuzzy-neural network for streamflow reconstruction." *Hydrological Processes*, 15, pp. 219-232.
- Gautam, D.K., and Holz, K.P. (2001). "Rainfall-runoff modeling using adaptive neuro-fuzzy systems." *Journal of Hydroinformatics*, March, pp. 3-10.
- Mamdani, E.H., and Assilian, S. (1975). "An experiment in linguistic synthesis with a fuzzy logic controller." *International Journal of Man-Machine Studies*, Vol. 7, No. 1, pp. 1-13.
- 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*, Vol. 41, No. 4, W04004.
- Zadeh L.A. (1965). "Fuzzy Sets." *Information and Control*, Vol. 8, pp.338-353.

(논문번호:07-101/접수:2007.10.01/심사완료:2008.02.14)