Takagi-Sugeno 추론기법과 신경망을 연계한 뉴로-퍼지 홍수예측 모형의 구축 및 적용 (I) : 최적 입력자료 조합의 선정

Establishment and Application of Neuro-Fuzzy Real-Time Flood Forecasting Model by Linking Takagi-Sugeno Inference with Neural Network (I) : Selection of Optimal Input Data Combinations

최 승 용* / 김 병 현** / 한 건 연***

Choi, Seung Yong / Kim, Byung Hyun / Han, Kun Yeun

Abstract

The objective of this study is to develop the data driven model for the flood forecasting that are improved the problems of the existing hydrological model for flood forecasting in medium and small streams. Neuro-Fuzzy flood forecasting model which linked the Takagi-Sugeno fuzzy inference theory with neural network, that can forecast flood only by using the rainfall and flood level and discharge data without using lots of physical data that are necessary in existing hydrological rainfall-runoff model is established. The accuracy of flood forecasting using this model is determined by temporal distribution and number of used rainfall and water level as input data. So first of all, the various combinations of input data were constructed by using rainfall and water level to select optimal input data combination for applying Neuro-Fuzzy flood forecasting model. The forecasting results of each combination are compared and optimal input data combination for real-time flood forecasting is determined.

Keywords : Flood forecasting, Takagi-Sugeno fuzzy inference, Neural network, Optimal input data combination

요 지

본 연구의 목적은 중소하천에서의 홍수예측을 위해 사용되는 기존의 수문학적 모형이 가지고 있는 문제점을 개선한 홍수예측 모형을 개발하는데 있다. 이를 위해 기존의 수문학적 강우-유출 모형에서 사용되는 많은 수문학적 자료 및 매개변수들의 사용 없이 오직 수위 및 강우측정 자료만을 이용하여 홍수를 예측할 수 있는 Takagi-Sugeno 퍼지 추론기법과 신경망을 연계한 뉴로-퍼지 홍수예측 모형을 구축하고자 하였다. 뉴로-퍼지 홍수예측 모형의 예측 정확도는 입력자료로 사용되는 강우와 수위 자료의 시간적 분포 및 자료의 수에 의해 결정된다. 따라서 본 연구에서는 홍수예측 모형 구축을 위한 최적 입력 자료 조합 선정을 위해 다양한 강우와 수위의 입력자료 조합을 구성하여 적용하였고, 이를 통해 홍수예측을 위한 뉴로-퍼지 홍수예측 모형의 최적 입력 자료 조합을 선정하였다.

핵심용어 : 홍수예측, Takagi-Sugeno 퍼지 추론, 신경망, 최적 입력 자료 조합

* 국립방재연구소 책임연구원 (e-mail: ecofriend@korea.kr)

Senior Researcher, National Institute for Disaster Prevention, Seoul 121-719, Korea

** 캘리포니아 어바인 박사후연구원 (e-mail: bhkimc@gmail.com)

Post Doctor, University of California Irvine

*** 교신저자, 경북대학교 공과대학 건축·토목공학부 교수 (e-mail: kshanj@knu.ac.kr)

Corresponding Author, Professor, School of Archi. & Civil Engineering, Kyungpook National Univ., Daegu 702-701, Korea

1. 서론

최근에 들어 지구환경의 변화에 따른 이상기후의 영향으로 태풍 및 집중호우로 인한 하천범람 등 홍수재해에 의한 인명과 재산의 피해가 급증하고 있다. 특히 한반도 지역에서는 집중호우와 태풍과 같은 이상강우로 인한 홍수피해의 발생이 매년 나타나고 있으며 홍수피해의 빈도와 강도는 증가하고 있는 실정이다. 또한 최근의 홍수피해에서 볼 수 있듯이 이상강우로 인한 홍수피해가 급격하게 대형화되어 가고 있다. 집중호우나 태풍으로 인한 피해 복구비용은 피해액보다 약 1.5배 이상의 예산이 소요된다는 점에서 홍수재해에 대한 예방적 투자가 절실하며, 더욱 효율적인 수자원 관리정책 및 방재 대책이 요구되는 실정이다. 이러한 상황에서 극심한 기상이변으로 인하여 발생하는 이상홍수의 예측에 관한 사항은 치수·이수는 물론 친수관점에서 볼 때 자연하천의 관리시에 매우 중요한 관심사로 부각되고 있다. 실질적인 홍수피해를 줄이기 위해서는 하도 정비 및 개수, 홍수 조절지 및 유수지 계획 등의 구조적 대책뿐만 아니라 미래에 발생할 홍수를 사전에 예측할 수 있는 홍수예보 시스템을 개발하는 비구조적 대책의 수립도 절실히 필요하다.

일반적으로 특정 지점에서의 홍수 예측을 하기 위한 일반적인 과정은 우선 강우를 예측하고 수문자료를 실시간 수집하여 전송한 후 예측된 강우와 수집된 수문자료를 입력으로 하여 수문학적 기반의 강우-유출 모형을 이용하여 해당 지점에서의 유출량을 계산하고 계산된 유출량을 수위-유량 관계식을 이용하여 수위로 변환하는 과정을 거친다. 이러한 경우 홍수 예측의 정확도는 강우-유출 모형의 정확도 못지않게 입력된 예측 강우량의 정확도에 의존하게 된다. 또한 대부분의 강우-유출 모형은 비선형성이 강하고 유역의 지형학적 인자와 기후학적 인자의 영향을 포함하기 때문에 매우 불규칙하여 정확한 예측이 어렵다. 또한 현재 실무에서 사용되는 수문학적 기반의 강우-유출 모형은 수문자료로부터 유출량을 계산하기 위한 유역추적, 저수지추적 및 하도추적의 각 추적과정에서 크고 작은 오차들이 발생하고 그것들이 누적되어 유출 모형의 해석 결과에는 많은 오차들이 포함되어 있다는 문제점이 있다. 특히 유역면적이 작아 홍수 도달시간이 짧은 중소하천에서의 수문학적 기반의 강우-유출 모형에 의한 홍수예정보 업무는 더욱 어려운 것이 현실이다.

따라서 본 연구에서는 기존의 홍수예정보를 위해 사용하고 있는 수문학적 강우-유출 모형이 가지고 있는 문제점을 해결하기 위해 수위 및 강우자료만으로도 홍수예측이 가능한 Takagi-Sugeno 퍼지 추론 기법과 신경망을 연계한 뉴로-퍼지 홍수예측 모형을 구축하고자 하였다.

본 연구에서 사용한 퍼지 추론 기법과 신경망을 이용한 수자원 모델링에서의 국외 연구는 강우-유출모의 (Smith and Eli, 1995; Hsu et al., 1995; Shamseldin, 1997; Campolo et al., 1999a,b; Tokar and Johnson, 1999; Zealand et al., 1999; Sudheer et al., 2002; Chang et al., 2002; Jain et al., 2004), 지하수 모델링 (Coulibaly et al., 2001; Daliakopoulos et al., 2005), 하천유량예측 (Imrie et al., 2000; Hu et al., 2001; Kumar et al., 2004; Yurdusev and Firat, 2009), 강우예측 (Luk et al., 2001; Ramirez et al., 2005) 등과 같이 다양한 분야에 적용되었다. 또한 Gautam and Holz (2001)가 적응형 뉴로-퍼지 기법을 강우-유출해석에 적용하였고, Chang et al. (2001)이 비교사학습과 교사학습을 혼합하여 구성한 Counter Propagation 신경망과 퍼지기법을 융합하여 Counter Propagation Neural Network (CFNN)을 구성하고 하천의 전 시간 유량과 강우관측소의 우량자료를 이용하여 수위표지점에서의 홍수위를 예측하여 통계학적 방법인 ARMAX보다 우월한 예측능력을 보임을 검증하였다. Nayak et al. (2005)은 3년간의 호우자료를 이용하여 뉴로-퍼지, 인공신경망, 퍼지 추론시스템을 이용하여 유량을 예측하였다. Aquil et al. (2007)은 유량예측을 위해 Levenberg-Marquardt Feed Forward Neural Network (FFNN), Bayesian Regularization-FFNN, 뉴로-퍼지 모형을 비교한 결과 뉴로-퍼지 모형 사용 결과가 가장 우수하다고 제안하였다. Nasr et al. (2008)은 분포형 강우-유출모형에서 시공간적 변동성을 고려하기 위해 뉴로-퍼지 모형을 이용하였고 Shu and Ouarda (2008)은 적응형 뉴로-퍼지 추론 시스템을 이용한 미계측 유역에서의 빈도 해석을 실시하였다. Kurtulus et al. (2009)는 유출 응답에 대한 신경망과 뉴로-퍼지 모형간의 비교 연구를 수행하였으며 Firat et al. (2009)는 퍼지 추론 기법간의 비교 연구를 수행하였고 Yurdusev and Firat (2009)는 적응형 뉴로-퍼지 추론 시스템의 적응성을 검증하였다.

퍼지이론에 대한 국내 연구로는 심재현 (1992)이 유수지 펌프의 적절한 운영을 위하여 퍼지제어모형을 적용하였으며, 이정규와 이창해 (1996)는 저류함수모형과 퍼지이론을 적용한 시변성 매개변수를 결합하여 하나의 저류함수모형을 제시하였다. 남의석 (1997)은 상수처리의 응집제 주입공정을 위한 모델링에 퍼지-신경망을 적용하였고 황순기 (1999)는 광역상수도 시스템의 수요예측에 적용하였다. 문병석 등 (2000)은 적응형 신경 회로망을 사용하여 상수도 공급량과 평균기온, 급수지역 인구를 입력자료로 하여 광주시의 상수도 1일 급수량을 예측하였고, 진영훈 (2000)은 영산강 수계에 대하여 일단위 및 시단위의 유출량 예측을 실시하여 좋은 결과를 얻었다. 고영준 (2001)은 하천의 시유출량 예측을 위해 퍼지-신경망을 적

용하여 적용성을 검증하였고, 안상진 등 (2001)은 보청천 유역의 수문곡선을 추정하는 연구를 진행하였다. 강일환 (1999, 2005) 또한 인공신경망과 유전자 알고리즘을 이용하여 상수도 1일 급수량을 예측하였고, 신성일 (2002)은 1997~2002년 발생한 홍수사상에 대해서 금호강 중류부에 위치한 금호수위표지점에서 관측된 자료를 사용하여 홍수량 예측을 실시하였다. 또한, Bae et al. (2007)은 적응형 뉴로-퍼지 기법을 이용하여 소양강의 유입량을 예측하였고 이재웅 등 (2008)은 뉴로-퍼지를 이용한 홍수예경보에 관한 연구를 수행한바 있다.

기존의 강우-유출 과정을 수문순환의 수문학적인 이론을 기초로 하여 각 과정을 구체적으로 모의하는 방법과 달리 본 연구에서 사용한 모형과 같이 입·출력 자료의 관계만을 이용하여 홍수를 예측하는 방법은 유역의 물리적, 지형적 특성을 고려하지 않고 강우와 수위 자료만을 이용하여 구축하는 모형으로 유역의 물리적, 지형자료와 같은 방대한 양의 자료 수집이 필요 없고, 일단 모형이 구축되면 수위와 강우 자료 같은 자료 입력만으로 정확도 높은 홍수예측 결과를 빠른 시간 내에 얻을 수 있다는 장점이 있다(이재웅 등, 2008).

그러나 이러한 자료 지향형 모형을 이용한 홍수예측의 경우 입력자료로 사용되는 강우와 수위 자료의 시간적 분포와 자료의 수를 어떻게 결정하는지에 따라 홍수예측의 정확도에 영향을 미치게 된다. 따라서 본 연구에서는 실제 유역에 대한 홍수예측 모형 구축을 위한 최적 입력 자료 조합 선정에 위해 다양한 강우와 수위의 입력자료 조합을 구성하여 적용하였고, 이를 통해 홍수 예측을 위한 뉴로-퍼지 홍수예측 모형의 최적 입력 자료 조합을 선정하고자 하였다.

2. 기본 이론

2.1. 뉴로-퍼지 모형

퍼지 이론과 신경망을 결합한 뉴로-퍼지 모형의 기본 이론은 Jang (1992)에 의해 최초로 제안되었으며 그 이후 Brown and Harris (1994)에 의해 오늘날까지 연구 발전되고 있다.

현재 퍼지 논리 제어 시스템을 설계하는데 체계적인 방법은 없으며 지금까지 많이 사용되고 있는 방법 중에 하나는 전문가의 know-how를 연구하여 주관적인 방법으로 소속 함수와 규칙을 결정하고 만족할만한 결과를 얻는 지 여부를 시험해 보는 것이다. 만약 설계한 제어 시스템이 실제 적용에서 만족할만한 결과를 주지 못할 경우 소속 함수와 규칙들은 재조정 되며, 원하는 제어 시스템을 선정하기 위해서 여러 번의 시행착오와 재조정을 거쳐 소속 함수와 규칙이 결정된다.

이러한 문제를 해결하기 위해서 제시된 모형이 뉴로-퍼지 모형으로 신경망의 구조와 학습능력을 이용하여 제어환경으로부터 얻은 입출력 정보로부터 소속 함수와 규칙을 제어 대상에 맞게 자동으로 조정함으로써 수행된다.

2.1.1 모형의 구조

본 연구에서 사용된 뉴로-퍼지 모형의 구조를 설명하기 위해 퍼지 추론 시스템이 2개의 입력 값과 한 개의 출력 값을 갖는다고 가정하면 1차 Takagi-Sugeno 퍼지 모형은 다음과 같은 2개의 규칙을 갖는다.

Rule 1 : If x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$

Rule 2 : If x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$

Fig. 1. First-order Takagi-Sugeno Fuzzy Inference Scheme

Fig. 2. Structure of Neuro-Fuzzy Model

Fig. 1은 1차 Takagi-Sugeno 추론 시스템을 나타낸 것이고 Fig. 2는 신경망을 도입한 뉴로-퍼지 모형의 구조이다.

뉴로-퍼지의 구조는 $O_{i,i}$ 로 표현되는 각 층(layer) 내에서 노드 출력을 갖는 5개의 층으로 구성되어 있다. 여기서 $O_{i,i}$ 는 층 i 의 i 번째 노드의 출력 값을 나타낸다. Fig. 4의 뉴로-퍼지 구조의 각 층에 대해 자세히 살펴보면 다음과 같다.

Layer 1 : 이 층의 모든 노드는 입력 노드로 단지 다음 층으로 외부적 신호만 보낸다.

Layer 2 : 이층의 모든 노드 i 는 적응형 노드로 소속 함수로 작용한다.

$$\begin{aligned} O_{2,i} &= \mu_{A_i}(x), i=1,2 \\ O_{2,i} &= \mu_{B_{i-2}}(x), i=3,4 \end{aligned} \quad (1)$$

여기서, x 또는 y 는 입력 노드 i 이고, A_i 또는 B_{i-2} 는 이 노드에 관련된 퍼지 집합(언어적 표시)이다. $O_{2,i}$ 는 퍼지 집합(A_1, A_2, B_1, B_2)의 소속 정도를 나타내고 이의 전형적인 소속 함수는 Eq. (2)와 같다.

$$\mu_{A(x)} = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (2)$$

여기서, $\{a_i, b_i, c_i\}$ 를 전건부 매개변수라 한다. 이 함수에서 매개변수 값이 변화함에 따라 퍼지 집합 A 의 소속 함수는 다양하게 표현될 수 있다. 즉, 위의 소속 함수에서 a_i, b_i, c_i 의 값을 변화시킴으로써 소속 함수를 사용자가 원하는 다양한 형태로 나타낼 수 있다는 것이다.

Layer 3 : 이층의 모든 노드는 Prod로 표시된 고정노드이며 출력은 모든 입력 신호의 곱으로 Eq. (3)과 같다.

$$O_{3,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i=1,2 \quad (3)$$

각 노드의 출력 값은 규칙의 연결강도를 나타낸다.

Layer 4 : 이층의 모든 노드는 Norm이라 표시된 고정노드이며 i 번째 노드와 관련된 규칙의 정규화된 연결강도를 나타낸다. 즉, i 번째 노드는 전체 연결강도에 대한 i 번째 노드의 연결강도의 비로 Eq. (4)와 같다.

$$O_{4,i} = \bar{w}_i = \frac{w_i}{\sum w_i} \quad i=1,2 \quad (4)$$

Layer 5 : 이층의 모든 노드는 노드 함수를 갖는 적응형 노드로 Eq. (5)와 같이 가중된 후건부 값을 계산한다.

$$O_{5,i} = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i) \quad (5)$$

여기서, $\bar{w}_i$ 는 층 4에서의 출력 값이고, $\{p_i, q_i, r_i\}$ 는 이 노드의 후건부 매개변수이다.

Layer 6 : 이 층의 노드는 오직 하나로 합으로 표시되며, 전체 시스템에 대한 추론 결과를 계산하기 위해 Eq. (6)과 같이 모든 입력 신호의 합으로 표현된다.

$$O_{6,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

뉴로-퍼지의 최종 출력 값을 나타내는 Eq. 3은 다음과 같이 후건부 파라미터의 선형조합으로도 나타낼 수 있다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \bar{w}_1(p_1 x + q_1 y + r_1) + \bar{w}_2(p_2 x + q_2 y + r_2) \\ &= (\bar{w}_1 p_1 + \bar{w}_2 p_2) x + (\bar{w}_1 q_1 + \bar{w}_2 q_2) y + (\bar{w}_1 r_1 + \bar{w}_2 r_2) \end{aligned} \quad (7)$$

3. 최적 입력자료 조합의 선정

데이터 기반의 뉴로-퍼지 모형을 이용한 홍수예측에 있어서 중요한 사항은 수위에 영향을 미치는 강우와 수위의 시간적 분포를 입력자료 조합에 어떻게 구성할 것인지 또 얼마만큼의 자료를 사용할 것인지를 결정하는 것이다. 예를 들면 현재 시간을 t 시간이라 하면, 선행시간 $t+1$, $t+2$, $t+3$ 시간의 수위를 예측하는데 있어서 수위 자료는 t , $t-1$ 시간의 자료, 강우자료는 t , $t-1$, $t-2$ 시간의 자료를 사용할 것인지 혹은 수위 자료는 t , $t-1$, $t-2$ 시간의 자료, 강우자료는 t , $t-1$ 시간의 자료를 사용하거나 혹은 더 많은 자료들을 사용할 것인지를 결정하는 일은 좀 더 정확한 수위를 예측하는데 있어서 매우 중요하다. 이에 본 연구에서는 수위와 강우자료를 어떻게 구성하는 것이 수위 예측의 정확도가 가장 우수한지에 대한 검토를 통하여 뉴로-퍼지 모형을 이용한 홍수예측의 최적 입력자료의 조합을 선정하고자 하였다.

그러나 이러한 최적 입력자료 조합의 선정을 위해서는 상당한 시간이 소요된다. 대상 유역에 대한 뉴로-퍼지 모형을 구축하기 위한 최적 입력자료 조합을 선정하기 위해 총 입력자료의 개수를 몇 개로 할 것인지 또 그 중 강우자료의 수는 몇 개로 할 것이며 수위자료의 수는 몇 개로 할 것인지 등에 대한 결정을 해야 한다. 또 최적 입력자료 조합 선정을 위해 사용하는 강우와 수위의 시간 간격은 어떻게 할 것인지에 대한 검토도 해야 하는데 대상 유역마다 관측자료의 시간 간격이 상이하므로 이러한 최적 입력자료 조합의 선정과정을 적용하고자 하는 대상유역마다 수행해야 하는 번거로움이 있다.

이에 본 연구에서는 섬강 시험 유역의 강우관측소와 수위 관측소의 10분 간격 관측 자료를 이용하여 최적 입력자료 조합에 대한 결과를 분석하여 최적 입력자료 조합을 선정하고 선정된 최적 입력자료 조합을 왕숙천과 갑천 유역에 적용하여 최적 입력자료 조합의 대표성을 검증하고자 하였다. 물론 유역의 특성이 상이함으로 인해 섬강 유역에 대한 최적 입력자료 조합 결과가 다른 유역을 대표하지 않을 수도 있으나 유역면적과 유로연장이 비슷한 유역의 경우 강우와 수위만을 이용하여 입·출력 자료간의 관계를 통해 모형을 구축하는 뉴로-퍼지 모형의 특성상 자료 조합에 따른 결과가 크게 다르지 않을 것으로 유추할 수 있었고 또 최적 입력자료 조합이 대표성을 가짐으로 인해 향후 비슷한 유역면적의 다른 유역에 대한 뉴로-퍼지 모형 구축이 용이할 것이라 판단하였다. 이를 위해서 섬강 시험 유역의 강우관측소와 수위 관측소의 자료를 이용하여 분석하였다.

Fig. 3. Events

3.1 대상유역의 개황

황성댐 상류에 위치하고 있는 섬강 시험 유역은 남한강의 제 1지류인 섬강의 최상류부에 위치하고 있는 지방하천인 계천이 자리하고 있다. 본 유역에 대한 유역면적은 황성댐 지점을 기준으로 209 km^2 이고 유로 연장은 37 km 로 Fig. 3에 대상 유역에 대한 유역도를 나타내고 있다.

계천의 수원은 황성군 둔내면 태기산 (EL. $1,261.0\text{ m}$)에서 발원하여 남서향으로 유하하다가 황성댐 지점 상류 17.7 km 지점에서 구사천을 합류한 후 하류로 1.7 km 지점인 청일면 초현리 유평교 지점에서 유역 북측의 발교산에서 발원한 유동천을 합류한 후 계속하여 남서향으로 곡류하여 매일수위국에 이른 후 황성댐에 유입된다. 이후 황성댐 지점 하류 약 3.00 km 지점, 갑천면 궁천리 부근에서 하천의 우안측으로부터 대관대천이 유입한 후 약 4 km 하류인 공근면 덕촌리 부근의 금계천과 합류하여 지방1급 하천인 섬강으로 유입된다.

시험유역 내 우량관측소는 Fig. 3에서와 같이 춘당, 봉덕 그리고 매일 관측소의 3개소가 운영되고 있다.

3.2 입력자료 조합의 구성

본 연구에 사용된 강우자료는 2003년부터 2005년의 자료 중 Fig. 4와 같이 4개의 호우사상을 선정하였다. 선정된 4개의 호우 사상 중 두개의 사상은 뉴로-퍼지 모형의 training과 checking을 과정을 위한 입력자료로 사용하였고 나머지 두 사상은 최적 입력자료 조합을 선정하기 위한 검증자료로 활용하였다.

Table 1은 선정된 각 호우사상의 호우 기간과 강우 지속시간, 최대 강우강도, 총 강우량 등의 강우 특성을 나타내고 있으며 향후 모의에 대한 분석 등의 설명에 대한 이해를 돕고 표기를 간단하게 하기 위해 표에서 보는 바와 같이 각 호우사상에 대한 이름을 명기하였다.

홍수예보의 관점에서 입력 자료의 처리 시간을 줄이기

위해 입력자료의 수는 5개로 제한하고 입력 자료 조합을 구성하였다. 최적의 입력자료 조합을 선정하기 위해 강우 관측소의 강우자료와 수위관측소의 관측자료를 이용하여 Table 2와 같이 6개의 입력자료를 구성하였다. 관측된 수위와의 비교를 통해 최적의 입력자료 조합을 선정하기 위한 출력자료의 경우 본 연구에서는 예측 선행시간은 30분으로 하였다. 선행 시간이 짧을수록 예측의 정확도가 향상 될 것이라는 사실은 자명하나 입력자료 조합 구성의 목적이 어떤 조합이 가장 정확도가 높은가를 보기위한 것이므로 선행시간의 선택에 따른 비교는 무의미하다고 판단하였다.

Table 2에서 H는 수위자료를 나타내고 R은 강우자료를 나타내고 H와 R의 숫자들은 입력자료의 시간분포를

의미한다. 0은 현재 시간을 의미하고 1은 현재시간으로부터 한 간격 앞선 시간의 자료를 의미한다. 예를 들어 H01234 자료 조합의 경우 입력 강우 자료는 없고 수위 자료는 t , $t-1$, $t-2$, $t-3$, $t-4$ 시간의 수위 자료를 이용하여 입력 자료를 구성하였음을 의미한다.

3.3 최적 입력 자료 선정과정

뉴로-퍼지 기법 적용시 입력 변수가 많다고 이와 비례하여 모형의 정확도가 증가하는 것은 아니며 또한 입력변수가 증가하면 퍼지 규칙수가 기하급수적으로 증가하기 때문에 모의 시간이 너무 오래 걸린다는 단점이 있다. 만약 어떤 뉴로-퍼지 모형이 n 개의 입력 값을 갖고 각 입력 값마다 2개의 규칙을 가질 경우 규칙의 수는 $2n$ 개가 된다.

Fig. 4. Events

Table 1. Character of Events

Naming	Period	Duration	Rainfall Intensity (mm/hr)	Total Rainfall (mm)	Purpose
S-1	03/7/22 02:20~7/23 12:40	34 hr 20 min	15.6	89.2	Training
S-2	04/7/11 19:00~7/14 05:10	58 hr 10 min	24.0	139	Checking
S-3	05/7/28 01:10~7/29 10:00	32 hr 50 min	24.0	36.2	Testing
S-4	06/7/11 22:00~7/13 20:00	46 hr	36.0	187.2	Testing

Table 2. Combinations of Input Data

Cases	Combination Code	Input Data	
		Rainfall	Water Level
Case 1	H01234	-	$H(t)$, $H(t-1)$, $H(t-2)$, $H(t-3)$, $H(t-4)$
Case 2	R0_H0123	$R(t)$	$H(t)$, $H(t-1)$, $H(t-2)$, $H(t-3)$
Case 3	R01_H012	$R(t)$, $R(t-1)$	$H(t)$, $H(t-1)$, $H(t-2)$
Case 4	R012_H01	$R(t)$, $R(t-1)$, $R(t-2)$	$H(t)$, $H(t-1)$
Case 5	R0123_H0	$R(t)$, $R(t-1)$, $R(t-2)$, $R(t-3)$	$H(t)$
Case 6	R01234	$R(t)$, $R(t-1)$, $R(t-2)$, $R(t-3)$, $R(t-4)$	-

Table 3. Results of Subtractive Clustering

	Case A	Case B	Case C	Case D	Case E
Range of influence	0.5	0.3	0.5	0.5	0.5
Accept ratio	0.5	0.9	0.5	0.3	0.3
Reject ratio	0.15	0.20	0.15	0.15	0.05
Number of membership function	2	3	3	5	8
Training error	0.01344	0.01349	0.01299	0.01101	0.01426
Checking error	0.01887	0.02293	0.01869	0.02567	0.02293
Testing error	0.01470	0.01519	0.01337	0.01732	0.01601

Fig. 5. Comparison of Results (Test 1)

본 적용에서와 같이 입력 값이 5개이고 규칙이 2개 (뉴로-퍼지 모형에서 규칙의 최소수는 2개)이면 규칙의 수는 25개로 총 32개의 규칙이 만들어진다.

따라서 본 연구에서는 입력자료를 퍼지 클러스터링 기법 중의 하나인 subtractive clustering 기법을 사용하여 모형에 적용하였다. Subtractive clustering 기법의 적용을 위해서는 클러스터의 영향 범위와 클러스터의 중심을 결정하기 위한 계수를 결정해야 한다. 그러나 이러한 계수를 결정하기 위한 추천되는 방법은 따로 없고 다만 각 계수의 추천 값이 주어져 있다. 따라서 본 연구에서는 주어진 추천 값을 기준으로 각 계수를 조정하고 그 중 오차가 가장 작게 나타나는 값을 subtractive clustering 기법을 적용하기 위한 최종 매개변수 값으로 선정하였다.

Table 3은 subtractive clustering의 결과를 나타내고 있다. 표에서 보는 바와 같이 매개변수 값에 따른 오차는 크지 않았으나 클러스터의 영향 범위를 0.5, 클러스터의 중심을 결정하기 위한 계수인 accept ratio와 reject ratio를 0.5, 0.15로 했을 때 검증 오차가 가장 작은 것으로 나타났다. 이러한 결과를 통해 최종 계수를 결정하여 subtractive clustering 기법을 적용하였고 이로 인해 불필요한 공간에 대한 공간분할을 피하고 원하고자 하는 부분에서만 규칙을 부여할 수 있었다. 최종적으로 각 입력 변수당 3개의 소속함수와 3개의 규칙이 생성되었다.

3.4 최적 입력 자료 선정결과

앞서 언급한 것과 같이 입력 자료의 조합은 자료 처리 시간을 감안하여 입력 자료의 개수를 5개로 제한한 상태에서 강우와 수위의 총 6개의 입력 자료 조합으로 구성하여 모형을 적용하였다.

우선 Fig. 5는 Test 1 강우에 대한 각 입력 자료의 조합에 대한 수위 예측결과를 도시한 것이다. Fig. 5에서 보는 바와 같이 강우자료만으로 입력 자료를 구성한 H01234의 경우를 제외한 나머지 입력 자료 조합의 경우 약간의 차이는 있으나 예측 수위가 관측 수위와 대체적으로 일치하는 것을 볼 수 있다. 그러나 H01234, R0_H0123, R012_H01 입력 자료 조합의 경우 수위의 상승부와 하강부에서 약간의 진동 현상이 발생한 것을 볼 수 있고 R0123_H0 입력 자료 조합의 경우에는 진동 현상은 거의 없으나 수위 상승부에서 관측 수위와 예측 수위의 오차가 상당히 크게 나타나는 것을 확인할 수 있었다.

좀 더 명확한 파악을 하기 위해 각 입력 자료 조합에 따른 관측수위와 예측수위의 시간별 오차와 각 입력 자료 조합의 적합도를 판정하기 위해서 관측 결과에 대한 예측 결과를 Figs. 6 and 7에 나타내었다. Figs. 6 and 7에서 보는 바와 같이 R01_H012 입력 자료 조합이 모의 전 시간 동안 대체적으로 가장 작은 오차를 보이고 있음을 확인할 수 있었다.

Fig. 6. Error of Results (Test 1)

Fig. 7. Q-Q Plot of Results (Test 1)

Fig. 8은 Test 2 강우에 대한 각 입력 자료의 조합에 대한 수위 예측결과를 도시한 것이다. 그림에서 보는 바와 같이 앞선 모의결과와 마찬가지로 강우자료만으로 입력 자료를 구성한 H01234의 경우를 제외한 나머지 입력 자료 조합의 경우 약간의 차이는 있으나 예측 수위가 관측 수위와 대체적으로 일치하는 것을 볼 수 있다. 그러나 이 경우에도 수위 자료만을 입력자료로 구성한 H01234의 경우에는 앞선 모의와 같은 수위 진동 현상은 발생하지 않았으나 첨두 수위 근처를 포함한 수위 상승부에서 약간의 오차가 발생하는 것을 확인할 수 있었고, R0_H0123, R012_H01 입력 자료 조합의 경우에는 첨두 수위를 지나 하강부 전까지 부근에서 약간의 진동 현상과 오차가 발생한 것을 확인할 수 있었다. R0123_H0 입력 자료 조합의 경우에는 앞선 모의 결과와 달리 첨두 수위 이후에 예측 수위의 진동 현상이 발생하였다.

이 경우에도 좀 더 명확한 파악을 하기 위해 각 입력 자료 조합에 따른 관측수위와 예측수위의 시간별 오차와 각 입력 자료 조합의 적합도를 판정하기 위해서 관측 결과에 대한 예측 결과를 Figs. 9 and 10에 나타내었다. Fig. 9에서 보는 바와 같이 R01_H012 입력 자료 조합이 모의 전 시간 동안 오차가 가장 작게 나타나고 있음을 알 수 있다. 그러나 수위 상승부에서 이전 모의에 비해 관측수위

와 예측수위의 오차가 크게 나타나는 것을 알 수 있는데 이는 상승부의 경사가 급해짐으로 인해 상대적으로 더 적은 수의 관측 값을 갖는 데서 기인한 것으로 판단된다. 또한 Fig. 10에서 보는 바와 같이 R01_H012 입력 자료 조합이 적합도 측면에서도 다른 입력 자료 조합에 비해 우수한 결과를 보이고 있음을 확인할 수 있었다.

정량적 평가를 통한 최적 자료 조합의 선정을 위해 본 연구에서는 각 입력 조합에 따른 관측수위와 예측수위의 평균제곱근오차 (Root Mean Square Error), 상관계수 (Correlation Coefficient), Nash-Sutcliffe 효율계수 (Efficiency Coefficient), 상대첨두오차 (Peak Relative Error), 평균절대편차 (Mean Absolute Deviation), 절대평균편차와 평균값 사이의 비인 RAD를 통계지표로 사용하였다.

Tables 4 and 5는 입력 자료 조합에 따른 Test 1 and Test 2의 결과를 정량적 통계지표로 나타낸 것이다.

Table에서 보는 바와 같이 강우 자료만을 입력자료로 사용한 R01234 입력 자료 조합을 제외한 나머지 입력 자료 조합들의 평균제곱근오차는 Test 1의 경우 0.02m 이하의 값을 보였고 Test 2의 경우 0.09m 이하의 값을 보였다. 상관계수의 경우에도 R01234 입력 자료 조합을 제외한 나머지 입력 자료 조합들은 0.99 이상의 높은 상관관계를 보임을 확인할 수 있었다. 나머지 다른 통계 지표들의

Fig. 8 Comparison of Results (Test 2)

Table 4. Comparison of Statistics for Test 1 Results

	Statistics Index					
	RMSE	CC	NSEC	RPE	RAD	MAD
H01234	0.0132	0.9984	0.9942	2.4195	0.0108	0.0108
R0_H0123	0.0233	0.9985	0.9819	2.8737	0.0218	0.0219
R01_H012	0.0076	0.9995	0.9981	1.4533	0.0057	0.0057
R012_H01	0.0148	0.9973	0.9927	2.6259	0.0129	0.0129
R0123_H0	0.0194	0.9950	0.9875	1.7837	0.0147	0.0147
R01234	0.5647	-0.2589	-9.5975	65.8299	0.5192	0.5201

Fig. 9. Error of Results (Test 2)

Fig. 10. Q-Q Plot of Results (Test 2)

Table 5. Comparison of Statistics for Test 2 Results

	Statistics Index					
	RMSE	CC	NSEC	PRE	RAD	MAD
H01234	0.0844	0.9938	0.9836	3.3637	0.0268	0.0515
R0_H0123	0.0680	0.9947	0.9894	4.2191	0.0236	0.0455
R01_H012	0.0497	0.9972	0.9943	0.5824	0.0163	0.0314
R012_H01	0.0733	0.9939	0.9876	3.4620	0.0251	0.0483
R0123_H0	0.0908	0.9905	0.9810	11.2231	0.0336	0.0647
R01234	0.7785	-0.0597	-0.3933	1.7146	0.3808	0.7328

경우에도 R01234 입력 자료 조합을 제외한 나머지 입력 자료 조합들 간의 차이는 크게 나지 않음을 알 수 있었다. 그러나 Table 4에서 보는 바와 같이 R01_H012의 입력 자료 조합이 나머지 입력 자료 조합에 비해 평균제곱근오차의 경우에는 약 43~67% 정도 작게 나타나고, 첨두 상대 오차의 경우에도 R01_H012의 입력 자료 조합이 나머지 다른 입력 자료 조합에 비해 19~50% 정도 작게 나타나는 것을 확인할 수 있었다. 또한 다른 모든 통계 지표에서도 R01_H012의 입력 자료 조합이 가장 우수한 결과를 나타내고 있음을 확인할 수 있다. Test 2의 결과인 Table 5에서도 정도의 차이는 있지만 R01_H012 입력 자료 조합이 가장 우수한 결과를 보여주고 있음을 알 수 있다. 이와 같은 결과를 통해 본 연구에서는 R01_H012의 입력 자료 조합이 가장 정확한 수위 예측을 하는 것으로 판단하였고 향후 홍수 예측을 위한 최적의 입력 자료로 선정하였다.

(3) 정량적 평가를 통한 최적 자료 조합의 선정을 위해 각 입력 자료 조합에 따른 관측수위와 예측수위의 평균제곱근오차 등을 포함한 6개의 통계지표를 산정하였다. 산정결과 R01_H012의 입력 자료 조합이 나머지 입력 자료 조합에 비해 평균제곱근오차의 경우에는 약 43~67% 정도 작게 나타나고, 첨두 상대 오차의 경우에도 R01_H012의 입력 자료 조합이 나머지 다른 입력 자료 조합에 비해 19~50% 정도 작게 나타나는 것을 확인할 수 있었다. 또한 다른 모든 통계 지표에서도 R01_H012의 입력 자료 조합이 가장 우수한 결과를 나타내고 있음을 확인할 수 있다. 이와 같은 결과를 통해 본 연구에서는 R01_H012의 입력 자료 조합이 가장 정확한 수위 예측을 하는 것으로 판단하였고 향후 홍수 예측을 위한 최적의 입력 자료로 선정하였다.

4. 결 론

본 연구에서는 실제 유역에 대한 뉴로-퍼지 홍수예측 모형 구축을 위한 최적 입력 자료 조합 선정을 위한 연구를 수행하였고 연구결과는 다음과 같다.

- (1) 홍수예측을 위한 뉴로-퍼지 모형 구축을 위해 예측의 정확도에 영향을 미치는 강우와 수위의 개수를 5개로 제한하고 6개의 입력자료 조합을 구성하였다. 또한 subtractive clustering기법을 적용하여 입력자료의 효율적인 분할과 계산시간을 줄일 수 있었다.
- (2) 최적 입력 자료 조합 선정을 위해 2개의 검증 사상을 이용하여 각 입력 자료 조합에 따른 예측수위와 관측수위를 비교하여 도시하였다. 강우자료만으로 입력 자료를 구성한 R01234의 경우를 제외한 나머지 입력 자료 조합의 경우 대체적으로 홍수예측 결과가 우수한 것으로 확인되었다.

감사의 글

본 연구는 국토해양부가 출연하고 한국건설교통기술평가원에서 위탁 시행한 건설기술혁신사업 (08기술혁신F01)에 의한 차세대홍수방어기술개발연구단의 연구비 지원에 의해 수행되었습니다.

참고문헌

- 강일환 (1999). **ANFIS 이론을 이용한 상수도 일일 급수량 예측**. 석사학위논문, 전남대학교. pp. 22-43.
- 강일환 (2005). **뉴로 퍼지와 뉴로 유전자 알고리즘을 이용한 상수도 1일 급수량 예측**. 박사학위논문, 전남대학교.
- 고영준 (2001). **하천의 시유출량 예측을 위한 퍼지신경 회로망의 적용**. 석사학위논문, 전남대학교. pp. 1-6, pp. 14-17.

- 남의석 (1997). **상수처리시스템의 응집제 주입공정을 위한 지능형 모델링에 관한 연구**. 박사학위논문, 연세대학교.
- 문병석, 이경훈, 강일환 (2000). 상수도 1일 급수량 예측을 위한 ANFIS 적용. **대한상하수도학회지**, 대한상하수도학회, 제14권, 제3호, pp. 45-54.
- 신성일 (2002). **신경회로망과 뉴로-퍼지를 이용한 홍수량예측에 관한 연구**. 석사학위논문, 경일대학교.
- 심재현 (1992). **유수지 배수펌프장의 적정운용을 위한 퍼지제어모형에 관한 연구**. 박사학위논문, 연세대학교.
- 안상진, 전계원, 김진국 (2001). 중소하천의 유출수문곡선 예측을 위한 ANFIS의 적용. **건설기술논문집**, 제 20권, 제2호, pp. 95-104.
- 이재웅, 최창원 (2008). Neuro-Fuzzy 추론기법을 이용한 홍수 예·경보. **한국수자원학회논문집**, 한국수자원학회, 제41권, 제3호, pp. 341-351.
- 이정규, 이창해 (1996). 저류함수의 시변성 매개변수 조정 에 퍼지이론 도입에 관한 연구. **한국수자원학회논문집**, 한국수자원학회, 제29권, 제4호, pp. 149-159.
- 진영훈 (2000). **하천의 유출량 예측을 위한 인공 신경망 이론의 적용**. 석사학위논문. 전남대학교.
- 황순기 (1999). **비선형계 시스템의 수요 예측을 위한 뉴로 퍼지 모델에 관한 연구**. 석사학위논문, 연세대학교.
- 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*, Vol. 337, No. 1-2, pp. 22-34
- Bae, D.-H., Jung, D.-M., and Kim, G.-S. (2007). Monthly dam inflow forecasting using weather forecasting information and Neuro-Fuzzy technique. *Hydrologic Science Journal*, Vol. 52, No. 1, pp. 99-113.
- Brown, M., and Harris, C. (1994). *Neuro-fuzzy adaptive modeling and control*. Prentice Hall, New York.
- Campolo, M., Andreussi, P., and Soldati, A. (1999a). River flood forecasting with a neural network model. *Water Resources Research*, Vol. 35, pp. 1191-1197.
- Campolo, M., Soldati, A., and Andreussi, P. (1999b). Forecasting river flow rate during low-flow periods using neural networks. *Water Resources Research*, Vol. 35, pp. 3547-3552.
- 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., Chang, L.C., and Huang, H.L. (2002). Real-time recurrent learning neural network for stream-flow forecasting. *Hydrological Process*, Vol. 16, pp. 2577-2588.
- Coulibaly, P., Anctil, F., Aravena, and R., Bobee, B. (2001). Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, Vol. 37, pp. 885-896.
- Daliakopoulos, I.N., Coulibaly, P., and Tsanis, I.K. (2005). Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*, Vol. 309, pp. 229-240.
- Firat, M., Turan, M.E., and Yurdusev, M.A. (2009). Comparative analysis of fuzzy inference systems for water consumption time series prediction. *Journal of Hydrology*, Vol. 374, pp. 235-241.
- Gautam, D.K., and Holz, K.P. (2001). Rainfall-runoff modeling using adaptive neuro-fuzzy systems, *Journal of Hydroinformatics*, pp. 3-10.
- Hsu, K., Gupta, H.V., and Sorooshian, S. (1995). Artificial neural network modelling of the rainfall-runoff process. *Water Resources Research*, Vol. 31, pp. 2517-2530.
- Hu, T.S., Lam, K.C., and Ng, S.T. (2001). River flow time series prediction with a range-dependent neural network. *Journal of Hydrological Sciences*, Vol. 46, pp. 729-745.
- Imrie, C.E., Durucan, S., and Korre, A. (2000). River flow prediction using artificial neural networks: generalisation beyond the calibration range. *Journal of Hydrology*, Vol. 233, pp. 138-153.
- Jain, A., Sudheer, K.P., and Srinivasulu, S. (2004). Identification of physical processes inherent in artificial neural network rainfall-runoff models. *Hydrologic Process*, Vol. 118, pp. 571-581.
- Jang, J.-S. (1992) Self-learning fuzzy controllers based on temporal backpropagation. *IEEE Trans Neural Netw*, Vol. 3, No. 5, pp. 714-723.
- Kumar, D.N., Raju, K.S., and Sathish, T. (2004). River flow forecasting using recurrent neural networks. *Water Resources Management*, Vol. 18, pp. 143-161.
- Kurtulus, B., and Razack, M. (2009). Modeling daily discharge responses of a large karstic aquifer using soft computing methods Artificial neural network and neuro fuzzy. *Journal of Hydrology*, Vol. 375, pp. 146-162.

- Luk, K.C., Ball, J.E., and Sharma, A. (2001). An application of artificial neural networks for rainfall forecasting. *Math Computer Model*, Vol. 33, pp. 683-693.
- Nasr, A., and Bruen, M. (2008). Development of neuro fuzzy models to account for temporal and spatial variations in a lumped rainfall runoff model. *Journal of Hydrology*, Vol. 349, pp. 277-299.
- 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.
- Ramirez, M.C.P., Velho, H.F.C., and Ferreira, N.J. (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. *Journal of Hydrology*, Vol. 301, pp. 146-162.
- Shamseldin, A.Y. (1997). Application of a neural network technique to rainfall-runoff modelling. *Journal of Hydrology*, Vol. 199, pp. 272-294.
- Shu, C., and Ouarda, T.B.M.J. (2008). Regional flood frequency analysis at ungauged sites using the adaptive neuro fuzzy inference system. *Journal of Hydrology*, Vol. 349, pp. 31-43.
- Smith, J., and Eli, R.N. (1995). Neural network models of the rainfall-runoff process. *Journal of Water Resources Planning and Management*, ASCE, Vol. 121, pp. 499-508.
- Sudheer, K.P., Gosain, A.K., and Ramasastri, K.S. (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models. *Hydrologic Process*, Vol. 16, pp. 1325-1330.
- Tokar, A.S., Johnson, P.A. (1999). Rainfall-runoff modelling using artificial neural networks. *Journal of Hydraulic Engineering*, Vol. 4, pp. 232-239.
- Yarar, M., Onucyildiz, M., and Copt, N.K. (2009). Modelling level change in lakes using neuro fuzzy and artificial neural networks. *Journal of Hydrology*, Vol. 365, pp. 329-334.
- Yurdusev, M.A., and Firat, M. (2009). Adaptive neuro fuzzy inference system approach for municipal water consumption modeling An application to Izmir, Turkey. *Journal of Hydrology*, Vol. 365, pp. 225-234.
- Zealand, C., Burn, D.H., and Simonovic, S.P. (1999). Short-term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, Vol. 214, pp. 32-48.

논문번호: 11-051	접수: 2011.05.17
수정일자: 2011.06.13	심사완료: 2011.06.13