

기상예보정보를 활용한 월 댐유입량 예측 Monthly Dam Inflow Forecasts by Using Weather Forecasting Information

정 대 명* / 배 덕 효**

Jeong, Dae Myoung / Bae, Deg Hyo

Abstract

The purpose of this study is to test the applicability of neuro-fuzzy system for monthly dam inflow forecasts by using weather forecasting information. The neuro-fuzzy algorithm adopted in this study is the ANFIS(Adaptive neuro-fuzzy Inference System) in which neural network theory is combined with fuzzy theory. The ANFIS model can experience the difficulties in selection of a control rule by a space partition because the number of control value increases rapidly as the number of fuzzy variable increases. In an effort to overcome this drawback, this study used the subtractive clustering which is one of fuzzy clustering methods. Also, this study proposed a method for converting qualitative weather forecasting information to quantitative one. ANFIS for monthly dam inflow forecasts was tested in cases of with or without weather forecasting information. It can be seen that the model performances obtained from the use of past observed data and future weather forecasting information are much better than those from past observed data only.

Keywords : Neuro-Fuzzy system, ANFIS, Weather Forecasting Information, Subtractive Clustering

요 지

본 논문에서는 월 댐유입량을 예측하는데 있어서 기상예보정보를 활용한 뉴로-퍼지 시스템의 적용성을 검토하였다. 뉴로-퍼지 알고리즘으로 퍼지이론과 신경망이론의 결합형태인 ANFIS(Adaptive Neuro-Fuzzy Inference System)을 이용하여 모형을 구성하였다. ANFIS의 공간분할에 의한 제어규칙의 선정에 있어 퍼지변수가 증가함에 따라 제어규칙이 기하급수적으로 증가하는 단점을 해결하기 위해 퍼지 클러스터링(Fuzzy Clustering)방법 중 하나인 차감 클러스터링(Subtractive Clustering)을 사용하였다. 또한 본 연구에서는 정성적인 기상예보정보를 정량화 시키는 방법을 제안하였다. ANFIS를 이용하여 월 댐유입량 예측 시, 관측자료만으로 구성된 모형에 의한 예측결과와 관측자료에 기상예보정보를 더하여 구성된 모형에 의한 예측결과를 비교하였다. 그 결과 ANFIS는 기상예보정보를 활용하여 댐유입량을 예측했을 때가 관측자료만으로 예측했을 때보다 예측능력이 더욱 정확함을 보였다.

핵심용어 : 뉴로-퍼지 시스템, ANFIS, 기상예보정보, 차감 클러스터링

* 세종대학교 수운연구소 연구원
Waterway Research Institute, Sejong Univ., 98 Kunja-Dong, Kwangjin-Gu, Seoul 143-747, Korea
(E-mail: sign007@nate.com)

** 세종대학교 수운연구소 · 토목환경공학과 부교수
Associate professor, Dept. of Civil & Environmental Engr., Waterway Research Institute, Sejong Univ., 98 Kunja-Dong, Kwangjin-Gu, Seoul 143-747, Korea
(E-mail: dhbae@sejong.ac.kr)

1. 서론

인류의 역사와 더불어 한정된 수자원을 효율적으로 사용하고자 했던 노력은 계속되고 있다. 특히 도시의 발달과 인구증가로 인해 수자원 계획과 관리는 복잡성과 중요성이 더욱더 커지고 있다. 최근 우리나라를 비롯한 전 세계가 가뭄과 홍수 등, 물과 관련된 재해에 시달리고 있다. 이러한 문제점을 해결하기 위해서는 강우와 유량의 정확한 예측을 토대로 한 수자원의 계획과 관리가 이루어져야만 한다.

댐은 수자원의 효율적인 관리와 안정적인 용수공급을 위해 건설된 것으로서 댐유역의 수문특성에 따라 유출량의 변화가 다양하게 이루어진다. 특히 우리나라와 같이 홍수기와 이수기의 수문특성 차이가 심한 곳에서는 홍수기에 저장된 물을 다음 홍수기까지 각종 용수로서 사용하게 되는데 안정적인 용수공급을 위해서는 댐유역으로 유입되는 예측유입량을 파악하여야 하며 이를 근간으로 각종 용수에 대한 공급계획이 수립될 수 있다. 그러나 미래의 사건을 예측하는 일은 기상 및 유역내 조건 등의 다양성으로 인한 불확실성을 포함하기 때문에 완벽한 예측을 수행하는 일은 언제나 완벽하지 않은 경우가 대부분이다.

지난 수십년간 진행되어온 수문예측에 관한 연구는 서로의 상관관계에 관한 연구부터 예측에 이르기까지 다양하게 이루어져 왔다. 비선형 기법을 이용한 수문현상의 적용은 최근 다양한 접근이 이루어지고 있으며, 기존의 경우 신경망기법을 이용한 강우-유출에 관한 연구 및 강수량의 예측 등이 주를 이루고 있다(Furundzic, 1998; Lange, 1998; Sajikumar와 Thandaveswara, 1999; Bodri와 Cermak, 2000; Luk 등, 2001). 또한 비선형 기법인 퍼지를 수문 및 기상에 적용한 연구 역시 많은 부분 진행되고 있다(Chen, 1996; Franks 등, 1998; Ouenes, 2000). 그러나, 뉴로-퍼지 시스템의 수문에의 적용은 아직 많은 연구가 진행되지 않은 상태이다. Chang과 Chen(2001) 및 Gautam과 Holz(2001)는 뉴로-퍼지 시스템을 이용하여 강우-유출 모형을 적용한 바 있다. 국내에서는 뉴로-퍼지 시스템을 이용하여 이경훈 등(1998)이 상수도 1일 급수량 예측에 적용하였고, 나창진(2001)은 강수량 예측에 적용하였으며, 김원규 등(2001)은 단기 홍수량예측에 적용한 바 있다. 그러나 아직 월단위의 장기 댐유입량 예측에는 적용된 바가 없다.

최근 들어 수문기상학에 근거하여 계절이나 월 유입량의 예측 및 변동에 관한 연구가 활발하게 이루어지고 있으며, 이미 선진국에서는 장기적인 댐운영을 위해 기상예보자료를 활용하여 장기 댐유입량을 예측하고 있

다. 그러나 국내의 경우 현재 기상청에서 월 및 계절강우예보를 "예년에 비해 높다 또는 낮다"식의 정성적인 예보만을 하고 있어 수자원측면에서 장기 댐유입량 예측에 활용하기엔 현실적으로 어려움이 있는 실정이다. 본 연구에서는 이러한 기상청의 정성적인 월강우예보자료를 장기 댐유입량 예측에 이용하기 위하여 최근 여러 예측분야에서 활용도가 높은 뉴로-퍼지 시스템에 과거 월 관측자료 및 장기기상예보자료의 적용방안을 제시하고 적용성을 검토하고자 한다.

2. 뉴로-퍼지 시스템 이론

뉴로-퍼지 시스템은 기존의 퍼지 논리 시스템(fuzzy logic system)에 신경망의 학습능력을 도입한 것이다. 즉, 전문가 지식기반의 퍼지 논리 시스템에 학습이라는 유연한 기능을 부가하여 기존의 개념으로 해결하기 어려운 점들을 풀어가는 방식이다(Jang 등, 1996).

퍼지 시스템은 입력 소속 함수(membership function, MF)와 퍼지규칙(fuzzy rule), 그리고 출력 소속 함수로 구성되어 있다. 퍼지추론(fuzzy inference)은 이러한 구성요소들을 퍼지논리연산을 이용하여 입력변수가 출력에 대응(mapping)하는 과정을 나타낸다. 그림 1은 이러한 퍼지 시스템의 구조를 나타내고 있다.

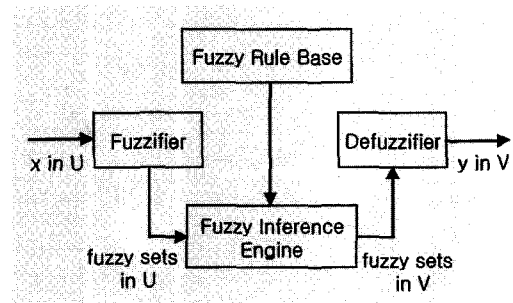


그림 1. 퍼지 시스템의 구조

뉴로-퍼지 시스템이 전통적인 FIS(fuzzy inference system)와 다른 점은 FIS의 구조와 파라미터(parameters)를 학습 알고리즘을 기반으로 가변시킬 수 있다는 점이다.

구조를 학습한다는 것은 입력변수의 개수나 전체집합의 분할(partition) 그리고 규칙의 개수 등을 결정·학습시킨다는 것이고 파라미터를 학습한다는 것은 소속 함수(MF)의 중심, 기울기 등과 파라미터화 시킨 퍼지 연결, 그리고 퍼지규칙의 이득 등을 학습시키는 것이다(Lin과 Lee, 1999).

2.1 Adaptive-Neuro Fuzzy Inference System (ANFIS)

Adaptive-Neuro Fuzzy Inference System(ANFIS)은 Jang(1993)에 의해 제안된 뉴로-퍼지 모델로서 1차 Sugeno 시스템에 관한 퍼지 시스템 파라미터들을 최적화시키기 위한 혼합된 학습 규칙들을 갖는 1차 Sugeno 모형을 말한다. 또한 ANFIS의 사용목적은 인간의 지식이나 경험적 자료를 퍼지 규칙이나 FIS로 전환할 수 있는 특정한 방법이 없는데, 출력의 오차를 줄이고 수행능력을 극대화할 수 있는 소속함수 작성에 ANFIS가 효과적인 방법으로 이용될 수 있다는 것이다.

2.1.1. 퍼지 추론 시스템(Fuzzy Inference System)

퍼지 추론 시스템은 퍼지 시스템에 있어서 가장 중요한 부분이다. 퍼지화를 통한 입력값과 퍼지 규칙 기반에 의해 적절하게 추론하는 논리연산 부분이다. 추론

방법은 그림 2와 같이 크게 3가지 형태로 구분할 수 있으나 본 논문에서는 type 3의 Sugeno 추론 시스템을 이용하였다. Sugeno 추론 시스템의 조건부는 퍼지 집합으로 결론부는 입력 변수에 대하여 선형식으로 이루어져 있다. Sugeno 모델의 전형적인 퍼지 규칙은 다음의 형태를 가진다.

$$\text{If } x \text{ is } A \text{ and } y \text{ is } B, \text{ then } z = f(x, y)$$

여기서, A와 B는 조건부에서의 퍼지 집합이고 $z = f(x, y)$ 는 결론부의 함수이다. 일반적으로 $f(x, y)$ 는 입력 변수 x와 y로 구성된 다항식이다. 그러나 규칙의 조건부에서 명시된 퍼지 영역내에 모델 출력을 적절히 묘사할 수 있지만 하다면 어떠한 함수도 될 수 있다. 이 추론시스템은 Mamdani 추론 시스템에서처럼 각 규칙의 추론 결과를 합하여 비퍼지화하는 과정이 없고 가중치 평균으로 대체된다. Sugeno 추론 시스템은 그림 3과 같다.




그림 2. 퍼지모델의 형태




그림 3. Sugeno 퍼지모델의 형태

2.1.2. ANFIS의 구조

ANFIS의 구조는 아래의 그림 4와 같다. ANFIS는 5개의 Layer로 구성되어 있으며, 각 Layer의 작용은 다음과 같다.

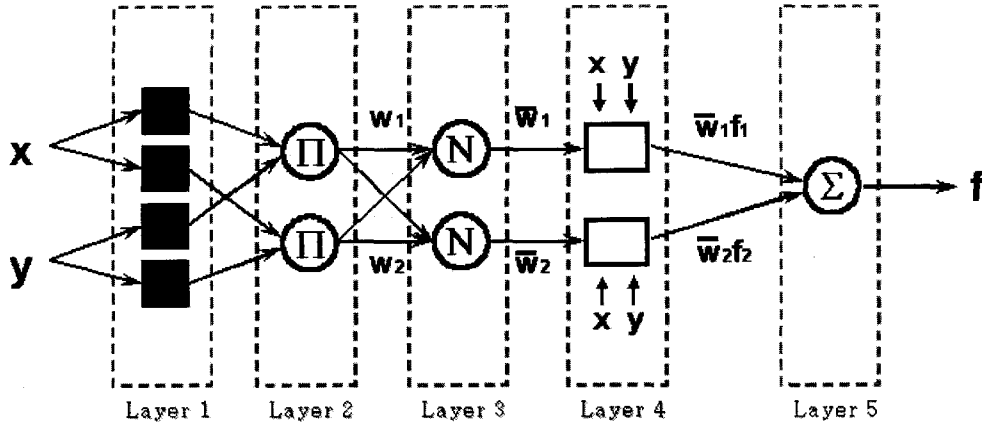


그림 4. ANFIS의 구조

Layer 1에서는 소속 함수의 매개변수들이 결정되며, 입력노드로서 외부의 입력을 다음 층으로 그대로 전달한다.

$$O_i^1 = \mu_{A_i}(x) \quad (1)$$

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{A_i} \right)^{2b_i} \right]}$$
 또는,

$$\mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\}$$

위의 식은 아래의 소속 함수를 표현하고 있으며 소속 함수의 매개변수를 Layer 1에서 결정한다.




그림 5. 소속함수(MF)의 형태

Layer 2는 규칙을 생성하며 생성된 규칙의 충족정도를 결정하는 단계이다. 이는 식 (2)와 같이 나타낸다.

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

그림 4에서 node는 곧 규칙의 개수를 의미한다.

Layer 3은 정규화된 규칙의 충족정도를 나타내는 단계이며, 정규화된 규칙의 충족정도는 식 (3)과 같다.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (3)$$

Layer 4는 최종 규칙을 생성하는 단계로서 식 (4)와 같은 출력을 발생시킨다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (4)$$

여기서, $\{p_i, q_i, r_i\}$ 는 최종 규칙의 파라미터 집합 (parameter set)을 의미한다. Layer 5는 식 (5)와 같이 최종 출력을 발생시킨다.

$$O_i^5 = z = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (5)$$

2.2 Subtractive Clustering 알고리즘과 규칙생성

ANFIS의 공간분할에 의한 제어규칙의 선정에 있어 퍼지 변수가 증가함에 따라 기하급수적으로 제어규칙이 증가하는 단점을 해결하기 위해 퍼지 클러스터링 방법 중 하나인 차감 클러스터링(subtractive clustering)을 사용하였다. 패턴 인식 분야에서 잘 이용되고 있는 클러스터링은 주어진 데이터를 클러스터라고 불리는 몇 개의 집합으로 분류하는 것이다. 통상의 클러스터링은

어느 데이터가 1개의 클러스터에 속하는 정도를 0(속하지 않는다) 또는 1(속한다)로 분류하는 것을 말한다. 그러나 퍼지 클러스터링은 소속도가 [0, 1]의 멤버십 값으로 주어지기 때문에 특성이 같은 데이터끼리 집합의 분할이 보다 유연하게 이루어진다. 특히 차감 클러스터링은 특정공간 내에 주어진 데이터를 좀더 적절하도록 데이터 분할을 수행하고 있다.

M-차원 공간에서 n자료점(x_1, \dots, x_n)의 집합을 고려해 보자. 자료점은 단위입방체 안에서 정규화 되었다고 가정한다. 또한 각 자료의 점은 클러스터 중심이 될 수 있고, 자료점 x_i 에서 밀도 값(density measure)은 다음 식 (6)과 같다.

$$D_i = \sum_{j=1}^n \exp\left(\frac{\|x_i - x_j\|^2}{(r_{a/2})^2}\right) \quad (6)$$

여기서 r_a 는 양의 상수이다. 여기서 만약 자료점이 많이 이웃하는 자료점들을 갖고 있다면 높은 밀도 값(D_i)을 가질 것이다. 각 자료점에서의 밀도 값을 계산한 후에 첫 번째 클러스터 중심으로 밀도 값이 가장 큰 지점을 선택한다. x_{c1} 을 선택하고 그곳의 밀도 값은 D_{c1} 이다. 다음은 각 자료점을 위한 밀도 값을 다음 식 (7)에 의해 바꾼다.

$$D_i = D_i - D_{c1} \exp\left(\frac{\|x_i - x_{c1}\|^2}{(r_{b/2})^2}\right) \quad (7)$$

여기서 r_b 는 양의 상수이다. 식 (7)에서 첫 번째 클러스터 중심 x_{c1} 부근의 자료 집합은 밀도 값이 현저히 감소할 것이다. 이 식에 의해 다음 클러스터 중심이 될 지점을 선택하게 된다. 이때 먼저 결정된 클러스터 중심에 거의 접근해서 클러스터 중심이 위치하는 것을 방지하기 위하여 일반적으로 r_b 는 r_a 보다 큰 값을 갖게 된다.

클러스터 중심 x_{c2} 가 다음 클러스터 중심으로 선택되고 각 자료점을 위한 밀도 값이 다시 식 (7)에 의해 변화된다. 이 과정은 충분한 클러스터 중심이 발생할 때까지 반복된다.

두 개의 입력값과 1개의 출력값을 갖는 모형에서 m개의 시계열 데이터가 계측되고 차감 클러스터링 알고리즘을 통하여 5개의 클러스터로 분할되었다면 그림 6과 같이 나타낼 수 있다. 이렇게 분할된 5개의 클러스

터마다 각각 대응되는 퍼지규칙이 한 개씩 존재한다고 가정하고 클러스터내의 데이터 분포에 따라 멤버십 함수를 생성한다.

차감 클러스터링 알고리즘은 주어진 학습데이터로부터 특성에 따라 입력공간을 분할하고 데이터가 존재하지 않는 공간에 대해서는 퍼지규칙이 생성되지 않도록 함으로써 최적의 규칙 수를 결정할 수 있다. 즉, 입출력 특성이 같은 데이터들을 하나의 클러스터로 분할하고, 그 데이터의 집합에 상응하는 퍼지규칙을 생성하는 것이다. 즉, 차감 클러스터링을 이용하여 모델링을 하면 데이터의 분포가 많은 영역에 규칙이 구성된다. 이것은 필요 없는 영역에 규칙을 생성하지 않게 됨으로써 규칙 수를 감소시키는 효과를 갖는다.




그림 6. 입력자료의 차감 클러스터링 결과

3. 적용사례

3.1 대상지역

뉴로-퍼지 시스템을 이용하여 장기 댐 유입량을 예측하기 위해 소양강댐 유역을 적용대상으로 선정하였다. 소양강 다목적댐은 유역면적 2,703km²로서 연평균 강수량 1,153mm의 풍부한 수자원을 고도로 개발, 한강연안과 서울을 비롯한 수도권지역에 연간 12억 1천 3백만 의 생·공용수 및 관개용수를 공급하고 있다. 또한 5억m³의 홍수조절능력을 갖추고 한강 하류부의 수해방지에 크게 기여하고 있으며, 연간 3억 5천 3백만kWh의 수력에너지를 생산·공급하는 한편, 하류로 방류된 용수를 이용 발전소에서 6천 1백만kWh의 전력생산 효과를 가져오는 등 국가경제발전에도 크게 기여하고 있다(한국대댐회, http://www.kncold.or.kr/korean/dam/k_dam1.html). 특히 소양강댐의 경우 1967년 4월에 착공하여 1973년 12월에 완공되었으며 유입량은 1974년부터 실측되었다. 따라서 댐유입량 자료의 보유기간이 길고 또한 자료의 수집이 용이하므로 뉴로-퍼지 시스템과 같은 통계모형을 이용하여 유입량 예측을 적용하기에 적당한 대상이라고 할 수 있다.

3.2 입력자료 구축

본 연구에서는 ANFIS 모형을 구축하기 위하여 입력 자료로 1981년 1월부터 2003년 10월까지의 수문자료와 기상자료를 각각 수집하였다.

3.2.1. 수문자료

모형입력을 위한 수문자료로 소양강댐유역의 강우자료와 댐유입량 자료를 수집하여 이를 각각 월평균 강우량과 월평균 댐유입량으로 변환하였다.

강우량자료는 그림 8과 같이 건설교통부와 수자원공사에서 운영하는 18개 지점의 강우관측소에서 일자료를 수집하고 유역평균강우량(MAP)을 산정하였다. 유역평균강우량을 산정하기 위해서는 통상 산술평균, 티센(Thiessen) 가중법, 등우선법 등이 이용된다. 본 연구에서는 이 중에서 일반적으로 사용되고 있는 티센 가중법을 이용하여 유역평균강우량을 산정하였다. 각 관측소의 지배면적 및 티센 가중계수는 GIS를 사용하여 그림 8과 같이 산정하였다. 산정된 결과들은 GIS를 사용하여 산출된 것으로써 기존의 다른 연구결과와는 미소한 차이를 보일 수 있음을 밝혀둔다. 위와 같은 방법으로 산정된 일단위의 유역평균강우량을 월자료로 다시 변환하였다.

댐 유입량 자료는 건설교통부에서 운영하는 한강홍수통제소와 수자원공사에서 운영하는 수자원관리 종합시스템(WAMIS)에서 시·일단위의 자료를 수집하여 이를 월단위로 변환하였다.




그림 7. 소양강댐의 위치와 유역도

3.2.2. 기상자료

모형입력을 위한 기상자료로는 과거 실측자료와 기상청의 월예보자료가 요구된다. 과거 실측자료로는 소양강댐 유역내에 있는 기상관측지점인 인제지점의 평균 기온과 상대습도의 일자료를 기상청 홈페이지에서 수집하고 이를 월단위로 변환하여 정리하였다.

한편, ANFIS에 입력자료로 활용하기 위하여 기상청에서 발표되는 1개월 예보자료를 수집하였다. 1개월 예보 및 계절예보와 같은 장기예보는 평년값(1971~2000년의 30년 평균값)에 비해 높고 낮은 정도를 계급별 구분에 대한 표현으로 사용하고 있는데, 현재 인터넷에 발표되는 1개월 예보문은 그림 9와 같으며, 월 및 순별 예보표현 기준은 표 1과 같다.

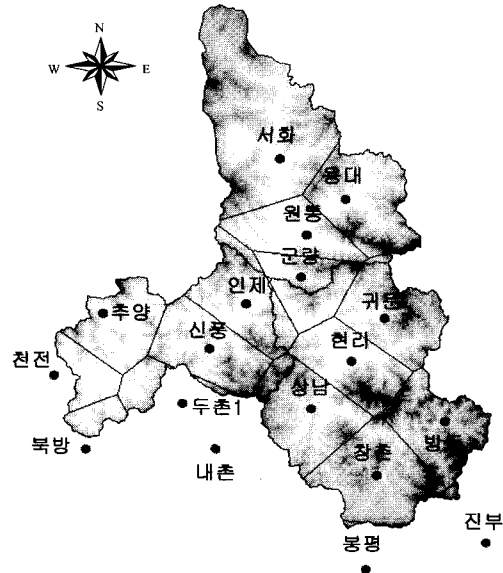


그림 8. 소양강댐유역의 티센망도

그림 9와 같은 과거의 예보문을 분석한 결과 예보표현은 모두 7가지 단계로 “적겠음”, “조금 적겠음”, “비슷하거나 조금 적겠음”, “비슷하겠음”, “비슷하거나 조금 많겠음”, “조금 많겠음”, “많겠음”과 같았다. 이를 ANFIS의 입력자료로 사용하기 위하여 기상청에서 제시하는 예보 표현 기준표의 정량적 기준을 5단계로 분류하고 각 예보 표현별 해당되는 평년값에 평년비를 곱하여 정량화 시켰다. 이는 과거 수집된 과거자료의 총 기간 중 기상예보가 없는 기간에 대해서 과거관측 강우량을 100% 정확한 예보값으로 가정하고 이를 정성적인 예보를 정량적인 예보표현으로 변환하는 방안이 활용하였다. 표 3은 본 연구의 대상유역인 소양강댐유역의 중앙에 위치하고 있는 기상관측지점인 인제지점의 평년값

1. 1개월 예보

2003년 11월 21일 ~ 2003년 12월 20일 2003. 11. 18

- 기 온 : 평년(-3~10℃)보다 낮겠음.
11월 하순과 12월 상순에는 두세 차례 한기 남하로 추운 날씨를 보일 때가 많겠으며, 12월 중순에는 대체로 포근한 가운데 일시적으로 기온이 큰 폭으로 떨어져 기온변화가 크겠음.

요약

- 강수량 : 평년(20~71mm)과 비슷하겠음.
강원도 영동지역 및 서해안지역은 지형적인 영향으로 눈이 오는 곳이 있겠음.

그림 9. 기상청의 1개월 예보문

표 1. 월 및 순별 기온·강수량의 예보 표현 기준표

	예보 확률(%)	기온(℃)		강수량(mm)	
		순	월	순	월
높음(많음)	30%	>0.7	>0.5	>130	>120
비슷	40%	-0.7~0.7	-0.5~0.5	50~130	70~120
낮음(적음)	30%	<-0.7	<-0.5	<50	<70

표 2. 인제지점의 월별 평년값(강수량:mm)

	1	2	3	4	5	6
강수량	14.8	24.4	34.2	67.1	94.5	119.1
	7	8	9	10	11	12
강수량	263	273.4	133.8	37.6	36.7	20.9

표 3. 예보표현을 정량화시키는 방법

예보 표현	평년비(%)	계산 기
적겠음	50	인제지역의 7월 예보문이 “평년보다 조금 적겠음” 과 같다면, 표 2의 7월 평년값 263에 평년비 0.65(65%)를 곱한다.
조금 적겠음	65	
비슷하겠음	100	
조금 많겠음	145	
많겠음	170	

(표 2)을 이용하여 정성적인 예보값을 정량화 시키는 방법을 나타내고 있다.

3.3 모형의 구성

전술한 바와 같이 본 연구에서는 기상 월예보자료의 유무에 따라 다음과 같은 다양한 형태의 모형을 구성하였다. 즉, 정확한 기상예보정보가 입력으로 들어갔을 때 담유입량 예측결과에 미치는 영향을 검토하기 위하여 실제 예보자료가 없는 기간, 즉 가정된 기상예보자료의

기간(1981년 1월~2000년 12월)에 대하여 A, B 그룹으로 나누었다. 또한 앞에서 찾은 예보표현을 정량화시키는 방법에 의하여 실제 예보자료를 정량적으로 수치화시킨 후 실제 예보자료가 있는 기간(2001년 4월~2003년 9월)에 대하여 C, D 그룹으로 나누었다. 각 그룹에 대하여 입력자료의 종류별로 다시 5가지로 구분된 모형은 표 4~7과 같다.

표 4. A 그룹 Model 별 입력층과 출력층의 구성

Model	입력층	출력층
Model_A1	Q(t)	Q(t+1)
Model_A2	P(t), Q(t)	Q(t+1)
Model_A3	P(t), H(t), Q(t)	Q(t+1)
Model_A4	P(t), T(t), Q(t)	Q(t+1)
Model_A5	P(t), H(t), T(t), Q(t)	Q(t+1)
P:강우량, H:상대습도, T:기온, Q:댐유입량		

표 5. B 그룹 Model 별 입력층과 출력층의 구성

Model	입력층	출력층
Model_B1	Q(t), F(t+1)	Q(t+1)
Model_B2	P(t), F(t+1), Q(t)	Q(t+1)
Model_B3	P(t), H(t), F(t+1), Q(t)	Q(t+1)
Model_B4	P(t), T(t), F(t+1), Q(t)	Q(t+1)
Model_B5	P(t), H(t), T(t), F(t+1), Q(t)	Q(t+1)
P:강우량, H:상대습도, T:기온, Q:댐유입량, F:가정된 월간예보값		

표 6. C 그룹 Model 별 입력층과 출력층의 구성

Model	입력층	출력층
Model_C1	Q'(t)	Q'(t+1)
Model_C2	P'(t), Q'(t)	Q'(t+1)
Model_C3	P'(t), H'(t), Q'(t)	Q'(t+1)
Model_C4	P'(t), T'(t), Q'(t)	Q'(t+1)
Model_C5	P'(t), H'(t), T'(t), Q'(t)	Q'(t+1)
P:강우량, H:상대습도, T:기온, Q:댐유입량		

표 7. D 그룹 Model 별 입력층과 출력층의 구성

Model	입력층	출력층
Model_D1	Q'(t), F'(t+1)	Q'(t+1)
Model_D2	P'(t), F'(t+1), Q'(t)	Q'(t+1)
Model_D3	P'(t), H'(t), F'(t+1), Q'(t)	Q'(t+1)
Model_D4	P'(t), T'(t), F'(t+1), Q'(t)	Q'(t+1)
Model_D5	P'(t), H'(t), T'(t), F'(t+1), Q'(t)	Q'(t+1)
P:강우량, H:상대습도, T:기온, Q:댐유입량, F':실제 월간예보값		

위와 같이 구성된 모형은 각각 학습기간과 검정기간으로 나누어 학습기간에는 모형의 매개변수 최적화를, 검정기간에는 최적화된 모형의 매개변수를 검정하는 순으로 연구를 수행하였다. A, B 그룹의 학습기간은 1981년 1월부터 1990년 12월까지이고 검정기간은 1991년 1월부터 2000년 12월까지이며, C, D 그룹의 학습기간은 2001년 4월부터 2002년 9월까지이고 검정기간은 2002년 10월부터 2003년 9월까지이다.

3.4 적용결과 및 분석

3.4.1. A, B 그룹의 예측결과 비교 분석

표 8, 9는 A, B 그룹 모형의 예측결과를 통계적 방법으로 분석하기 위하여 예측값과 관측값의 통계적 지표로서 상관계수와 평균제곱근오차(root mean square error, RMSE)를 각각 구하여 정리한 것이고, 그림 10, 11은 A, B 그룹 모형의 예측결과를 한눈에 비교할 수 있도록 동일 시간축상에 도시한 것이다. 도식적 방법에서의 분석결과와 마찬가지로 통계적 방법의 분석결과

또한 A, B 그룹 모두 입력변수의 개수가 늘어날수록 상관관계수가 증가했으며, RMSE는 줄어드는 추세를 보였다.

또한 A, B 그룹의 예측결과 모두 전년도 12개월의 패턴이 올해 12개월 동안의 패턴과 비슷했을 때 예측결과가 매우 양호함을 보였으나, 1994년, 1995년, 1997년은 다른 해에 비해서 예측 정확도가 떨어졌다. 이는 이

상기후로 인하여 댐유입량이 급격히 증가하거나 감소할 경우에는 본 연구에서 연구한 뉴로-퍼지 모형으로는 정확한 예측에 무리가 있는 것으로 판단된다. 그러나, 그림과 통계적 지표에서 알 수 있듯이 기상예보정보가 입력으로 들어간 B 그룹 모형의 예측결과가 과거 관측자료만으로 구성된 A 그룹의 예측결과보다 정확도가 매우 양호함을 보였다.

표 8. A 그룹 예측결과별 통계지표

	Model_A1	Model_A2	Model_A3	Model_A4	Model_A5
CC	0.4462	0.6188	0.6580	0.6152	0.7050
RMSE	95.1477	86.2875	83.2495	88.0920	77.4296

표 9. B 그룹 예측결과별 통계지표

	Model_B2	Model_B3	Model_B4	Model_B5
CC	0.8432	0.8942	0.9121	0.8956
RMSE	58.8714	50.1072	44.4523	48.0211




그림 10. A 그룹 Model 전체 예측결과




그림 11. B 그룹 Model 전체 예측결과

3.4.2. C, D 그룹의 예측결과 비교분석

전절에서와 같이 C, D 그룹의 모형별 예측결과를 종합적으로 분석하기 위하여 표 10, 11과 같이 C, D 그룹의 예측결과별 상관계수와 RMSE를 계산하여 정리하였고, 그림 12, 13과 같이 예측결과를 한눈에 비교할 수 있도록 동일 시간축상에 도시하였다. 분석 결과, A, B

그룹의 예측결과와 같이 입력자료에 기후자료가 더해질수록 상관계수는 점차 증가하고 RMSE는 점차 감소하는 경향을 보였다. 이는 입력자료의 기간의 장·단 여부에 상관없이 입력자료에 기후자료의 종류가 더해질수록 예측 정확도가 향상됨을 알 수 있다. 또한, B 그룹의 예측결과가 과거 관측자료만으로 예측한 결과보다 훨씬

표 10. C 그룹 예측결과별 통계지표

	Model_C1	Model_C2	Model_C3	Model_C4	Model_C5
CC	0.6825	0.6985	0.9100	0.7262	0.9235
RMSE	104.8478	113.5540	65.5265	100.0919	64.0669

표 11. D 그룹 예측결과별 통계지표

	Model_D1	Model_D2	Model_D3	Model_D4	Model_D5
CC	0.8507	0.8128	0.9226	0.8676	0.9520
RMSE	76.5919	78.6871	71.1878	70.4758	54.5060




그림 12. C 그룹 Model 전체 예측결과 비교




그림 13. D 그룹 Model 전체 예측결과 비교

양호했던 것처럼, 실제 기상예보자료를 활용한 D 그룹의 예측결과가 그렇지 않은 C 그룹의 예측결과에 비해 매우 양호함을 보였다.

종합적으로 볼 때, 뉴로-퍼지 시스템을 이용하여 월 댐유입량 예측 시 과거 관측자료만으로 입력을 구성한 모형보다 기상예보정보가 추가된 입력으로 구성된 모형의 댐유입량 예측능력이 더 우수하였으므로 수문학적 예측에 기상예보정보의 활용 가능성이 매우 높은 것으로 사료된다.

4. 결 론

본 연구에서는 장기 댐유입량을 예측하기 위해 퍼지 이론과 신경망의 학습능력이 결합된 뉴로-퍼지 시스템인 ANFIS를 수문학적으로 적용하는 방법을 제안하고, 소양강댐 유역의 월단위 유역평균강우량, 댐유입량, 상대습도, 평균기온, 기상예보정보자료로 구성된 ANFIS 모형의 적용성을 검토하였다. 또한 본 연구에서는 기존의 기상청 월간예보문의 정성적인 표현을 평년값에 예보표현 단계별 확률개념을 적용하여 정량적인 값으로 변환시키는 방법을 제안하였으며, 수문예측에 활용가능성을 검토하였다.

ANFIS 모형의 최적 모형을 찾기 위하여 차감 클러스터링 기법을 이용하여 멤버십 함수의 개수와 퍼지 규칙의 개수를 결정하였다. 선정된 최적모형을 적용하여 과거 관측자료만으로 구성된 모형에 의한 예측결과와 과거 관측자료에 기상예보정보를 더하여 구성된 모형의 예측결과를 도식적 방법과 통계적 방법을 사용하여 비교·분석하여 다음과 같은 결론을 얻을 수 있었다.

- (1) ANFIS 모형을 구성하는 과정에 있어서 기존방법은 입력의 개수에 따라 멤버십 함수와 퍼지 규칙의 개수가 정해지고 학습이 이루어져 시간이 오래 걸리는 단점이 있으나, 차감 클러스터링 기법을 이용함으로써 학습시간을 줄일 수 있게 하였다.
- (2) 모형 적용결과 수문학적 입력자료만을 이용하여 댐유입량을 예측했을 때보다 온도, 습도와 같은 기후학적 인자를 활용하여 댐유입량을 예측했을 때 더 정확한 결과를 얻을 수 있었다.
- (3) 뉴로-퍼지 시스템과 같이 자료의 상관관계로부터 결과를 예측하는 통계적 모형은 전년도의 유입량 패턴이 올해의 유입량 패턴과 유사한 경우 홍수기의 큰 유입량의 예측 정확도가 높았으나, 이상기후로 인하여 댐유입량이 급격히 증가하거나 감

소할 경우에는 정확한 예측에 한계가 있는 것으로 판단된다.

- (4) 뉴로-퍼지 시스템의 댐유입량 예측능력은 과거 관측자료만으로 입력을 구성하였을 때보다 과거 관측자료에 기상예보정보를 더하여 입력을 구성하였을 때가 훨씬 우수한 결과를 보였다. 따라서 기상예보정보는 댐유입량 예측시 활용성이 매우 높은 것으로 판단된다.

감사의 글

본 연구는 21세기 프론티어연구개발사업인 수자원의 지속적 확보기술개발 사업단의 연구비지원(과제번호 1-3-1)에 의해 수행되었으며 연구비 지원에 감사드립니다. 또한 본 연구에 많은 도움을 주신 건일 엔지니어링의 나창진님께 감사드립니다.

참 고 문 헌

- 김원규, 김병식, 김형수, 서병하 (2001). “뉴로-퍼지를 이용한 홍수량예측에 관한 연구”, **대한토목학회 2001 학술발표회 논문집**, pp. 1-4.
- 나창진 (2001). “강수 예측을 위한 뉴로-퍼지 시스템과 퍼지 시계열의 적용”, **고려대 석사학위논문**, 고려대학교.
- 이경훈, 문병식, 강일환 (1998). “ANFIS를 이용한 상수도 1일 급수량 예측에 관한 연구”, **한국수자원학회 논문집**, Vol. 31, No. 6, pp. 821-832.
- Bodri, L., and Cermak, V. (2000). “Prediction of extreme precipitation using a neural network: application to summer flood occurrence in Moravia”, **Advances in Engineering Software**, Vol. 31, pp. 312-321.
- Chang, F.J., and Chen, Y.C. (2001). “A counter-propagation fuzzy-neural network modeling approach to real time streamflow prediction”, **Journal of Hydrology**, Vol. 245, pp. 153-164.
- Chen, S.M. (1996). “Forecasting enrollments based on fuzzy time series”, **Fuzzy Sets and Systems**, Vol. 81, pp. 311-319.
- Franks, S.W., Gineste, P., Beven, K.J., and Merot, P. (1998). “On constraining the predictions of a distributed model: The incorporation of fuzzy estimates of saturated areas into the calibration process”, **Water Resources Research**, Vol. 34, No.

4, pp. 787-797.

Furundzic, D. (1998). "Application example of neural networks for time series analysis: rainfall-runoff modeling", *Signal Process*, Vol. 64, pp. 383-396.

Gautam, D.K., and Holz, K.P. (2001). "Rainfall-runoff modeling using adaptive neuro-fuzzy systems", *Journal of Hydroinformatics*, March, pp. 3-10.

Jang J.S.R. (1993). "ANFIS: adaptive network-based fuzzy inference system.", *IEEE Trans. on System, Man and Cybernetics*, Vol. 23, No. 3, pp. 665-685.

Jang, J.S.R., Sun, C.T., and Mizutani, E. (1996). *Neuro-fuzzy and soft computing: A Computational Approach to Learning and Machine Intelligence*, Prentice Hall.

Lange, N.T. (1998). "New Mathematical Approach Hydrological modeling-An Application of Artificial Neural Network", *Phys. Chem. Earth*, Vol. 24, No. 1-2, pp. 31-35.

Lin, C.T., and Lee, C.S.G. (1999). *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice Hall.

Luk, K.C., Ball, J.E., and Sharma, A. (2001). "An application of artificial neural networks for rainfall forecasting", *Mathematical and Computer Modeling*, Vol. 33, pp. 683-693.

Ouenes, A. (2000). "Practical application of fuzzy logic and neural networks to fractured reservoir characterization", *Computers Geosciences*, Vol. 26, pp. 953-962.

Sajikumar, N., and Thandaveswara, B.S. (1999). "A non-linear model using an artificial neural network", *Journal of Hydrology*, Vol. 216, pp. 32-55.

(논문번호:04-15/접수:2004.02.23/심사완료:2004.05.01)