

RADAR 강우예측자료와 ANFIS를 이용한 충주댐 유입량 예측 Inflow Estimation into Chungju Reservoir Using RADAR Forecasted Precipitation Data and ANFIS

최 창 원* / 이 재 응**

Choi, Changwon / Yi, Jaeung

Abstract

The interest in rainfall observation and forecasting using remote sensing method like RADAR (Radio Detection and Ranging) and satellite image is increased according to increased damage by rapid weather change like regional torrential rain and flash flood. In this study, the basin runoff was calculated using adaptive neuro-fuzzy technique, one of the data driven model and MAPLE (McGill Algorithm for Precipitation Nowcasting by Lagrangian Extrapolation) forecasted precipitation data as one of the input variables. The flood estimation method using neuro-fuzzy technique and RADAR forecasted precipitation data was evaluated. Six rainfall events occurred at flood season in 2010 and 2011 in Chungju Reservoir basin were used for the input data. The flood estimation results according to the rainfall data used as training, checking and testing data in the model setup process were compared. The 15 models were composed of combination of the input variables and the results according to change of clustering methods were compared and analysed. From this study was that using the relatively larger clustering radius and the biggest flood ever happened for training data showed the better flood estimation. The model using MAPLE forecasted precipitation data showed relatively better result at inflow estimation Chungju Reservoir.

Keywords : RADAR, MAPLE, ANFIS, flood estimation

요 지

최근 국지성 집중호우, 돌발홍수와 같은 급격한 기상변화로 인한 피해가 증가함에 따라, 레이더와 위성영상 등 원격탐측 방법을 사용한 강우 예측 및 관측에 대한 관심이 높아지고 있다. 본 연구에서는 자료지향형 모형의 하나인 뉴로-퍼지기법(ANFIS : Adaptive Neuro Fuzzy Inference System)을 사용하여 유역 유출량을 산정하였고, 레이더 단기 강우예측 모형인 MAPLE(McGill Algorithm for Precipitation Nowcasting by Lagrangian Extrapolation; Germann et al., 2002, 2004) 강우예측자료를 입력변수의 하나로 사용하였다. 뉴로-퍼지기법 및 레이더 강우예측자료를 사용한 홍수량 산정의 적용성 평가를 위해 충주댐 상류유역의 2010년 및 2011년 홍수기에 발생한 6개의 강우사상을 사용하여 모형 생성 시 사용한 강우자료의 종류에 따른 결과를 비교하고, 입력변수 조합에 따른 15개 모형을 구성하여, 모형 구성과정의 군집화 방법을 변화시키며 이에 따른 결과를 비교 분석하였다. 연구 결과, 기 발생한 홍수사상 중 가장 큰 홍수사상을 사용하여 모형을 생성할 경우 홍수량 산정의 정확도가 높아지는 것으로 나타났고, 모형의 생성이 가능한 범위 안에서 비교적 clustering 반경이 클수록 홍수량 산정의 정확도가 높아지는 것으로 나타났다. 충주댐 유역의 홍수량 예측에서는 t+6~t+16시간의 예측에서 MAPLE 강우예측자료를 사용한 모형의 홍수량 산정 결과의 정확도가 상대적으로 높은 것으로 나타났다.

* 아주대학교 건설교통공학과 공학박사 (e-mail: itsme99@ajou.ac.kr)

Ajou Univ. Division of Civil and Trans. Engineering, Ph.D., Ajou University, Suwon 443-749, Korea

** 교신저자, 아주대학교 건설시스템공학과 교수 (e-mail: jeyi@ajou.ac.kr, Tel: 82-31-219-2507)

Corresponding Author, Ajou University, Division of Construction Engineering, Professor, Ajou Univ., Suwon 443-749, Korea

1. 서 론

지구온난화로 인한 기후변화는 전 지구적인 규모로 발생하고 있으며 세계 각국의 생활에 영향을 미치고 있다. 특히 강수량의 경우 대륙별 지역별 증감 추세가 상이하여 지역별로 각기 다른 영향을 미치고 있다. 우리나라의 경우 1950년대 후반 이후 전국 14개 주요 관측 지점의 평균 강수패턴 분석에 따르면, 연 강수량은 증가하고 있으나 강수일수(강수량 0.1 mm 이상)는 줄어들고 있어서 강수 일의 강수강도가 증가하는 것으로 나타났다(Meteorological Research Institute, 2004). 또한, 전통적으로 시기나 양적인 측면에서 장마기간에 국한되던 강우 집중현상이 과거와는 달리 특정 기간에 상관없이 발생하고 있으며, 단기간에 국지적으로 많은 비를 발생시키는 국지성 집중호우의 형태를 보여 집중호우로 인한 피해가 커지고 있다. 우리나라는 유역면적이 작고 유로연장이 짧을 뿐만 아니라 하천경사가 급한 곳이 많은 유역특성으로 인해, 강수강도의 증가는 유역 하류의 하천유출량의 급격한 증가 및 홍수피해를 유발시킨다. 따라서 최근 홍수예보의 정확성을 높이고자 실시간 기상자료 및 강수예보자료를 활용한 홍수량 예측연구에 대한 필요성이 증대되고 있다.

최근 실시간 기상자료를 홍수 예·경보에 사용하기 위한 연구로는 Jung (2006), Kim (2007), Kim (2009a), Park (2009), Kim (2009b) 등이 수행한 RADAR (Radio Detecting And Ranging) 강우자료와 지상강우관측소의 관측강우자료의 오차를 줄이기 위한 연구와, Yun (2009), Lee (2010a), Kim (2011a), Lee (2010b) 등이 수행한 연구와 같이 ModClark (Daniel and Arlen, 1998), SWAT (Srinivasan and Arnold, 1994), Vflo (Vieux, 2001) 등의 상용소프트웨어나 직접 개발한 분포형 강우-유출모형에 RADAR 강우자료를 적용하여 그 활용성을 평가하는 연구가 주로 수행되고 있다. 강수예보 자료를 홍수 예·경보에 적용한 연구는 아직 활발히 이루어지지 않고 있으며 Byun (2009)은 단기수치예보모형 중 RDAPS (Regional Data Assimilation and Prediction System; NIMR, 2000)의 자료를 사용하여 한강유역의 강우량을 예측하고 HEC-1 모형(U.S. ACD, 1968)에 적용하여 한강유역의 댐 유입량 예측에 적용하였다.

현재 일반적으로 사용되고 있는 강우-유출 모형은 수리·수문학적 이론을 바탕으로 하는 물리적 모형이 대부분

을 차지하고 있다. 현재 국내에서 단기 홍수해석에 널리 이용하는 모형은 RRL (Road Research Laboratory; Watkins 1962), ILLUDAS (Illinois Urban Drainage Area Simulator; Michael and John, 1974), SWMM (Storm Water Management Model; Metcalf & Eddy Inc., 1971), STORM (U.S. ACE, 1974), HEC-HMS (U.S. ACE, 1999), HEC-RAS (U.S. ACE, 1998), DWOPER (Dynamic Wave Operational Model; Fread, 1985) 등이 있다(Won, 2007). 물리적 모형은 강우에서부터 차단, 지표저류, 지표수 유출, 침투와 침투, 중간 유출, 지하수 유출, 하도 추적 등의 과정을 통한 유출량 해석까지의 전 과정을 수리·수문학적인 해석을 통해 모의하는 모형으로 오랜 기간의 연구와 적용을 거치는 동안 보완과 검증의 과정을 거치며 그 적합성을 어느 정도 인정받고 있다. 그렇지만 이와 같은 물리적 모형들은 수문 순환 각 과정의 이론들을 모형화한 것으로 수문학적 요소들이 내포하고 있는 애매모호함과 불확실성으로 인해 실제 유역의 특성을 그대로 반영한다는 것은 불가능하며, 모의된 유량과 관측된 유량의 비교를 통해 모형의 정확성을 판단할 수 있다. 이러한 단점을 극복하기 위해 인공지능, 전문가 시스템, 인공신경망, 최적화와 진화 알고리즘, 퍼지기법 등을 이용한 홍수량 산정기법이 지속적으로 연구되고 있다(Abrahart et al., 2008). 최근에는 다양한 기법들을 적용한 연구가 이루어지고 있는데, Dastorani et al. (2010)은 ANN (Artificial Neural Network) 모형과 ANFIS 모형을 이란 중부 Yazd 유역의 강우관측소 강우량 예측에 적용하였다. Ko (2010)는 신경회로망 모형인 Artificial Neural Network, GRNN (Generalized Regression Neural Network), NFM (Neuro-Fuzzy Model) 모형을 이용하여 내성천 지점에 적용하였다. Shin et al. (2011)은 단기 물 수요예측을 위해 ARMA (Auto Regressive Moving Average), MR (Multi Regression), KF (Kalman Filtering), MLP (Multi-Layered Perceptron), ELM (Extreme Learning Machine)과 ANFIS 모형을 적용하였다. Kim (2011b)은 저수지 운영에 적응형 퍼지기법, 동적계획법, 신경회로망기법을 적용하였다. 본 연구와 유사한 연구로, Bae et al. (2007)은 월간 기상예보자료와 ANFIS를 이용하여 월간 댐유입량 예측 연구를 수행하였다.

본 연구에서는 6시간 이내의 초단기예보에서 우수성을 나타내는 것으로 알려진 MAPLE 강우예측 자료를 ANFIS

모형에 적용하여 충주댐 유입량을 예측하였다. 6개의 강우 사상을 사용하여 모형 생성에 사용한 강우자료의 특성에 따른 유입량 예측 결과를 비교하고, 강우예측자료의 사용 유무에 따른 유입량 예측 정확도를 예측 선행시간에 따라 비교하였으며, ANFIS 모형의 군집화 방법에 따른 예측 정확도를 비교하였다.

2. 기본 이론

2.1 ANFIS 모형

퍼지이론은 “yes”나 “no”와 같이 이분법으로만 나눌 수 없는 인간의 모호한 사고 작용을 수학적인 함수를 통해 명확히 표현하기 위한 이론으로, Zadeh (1965)에 의해 제안된 퍼지집합 이론을 기초로 하고 있다. 일반적인 집합에서는 특정 요소의 집합에 대한 소속 정도는 포함되거나 포함되지 않는 경우가 명확히 구분되어 존재하지만, 퍼지집합에서는 애매모호함을 인정하기 때문에 상당부분 포함되거나 조금 포함되는 것과 같은 다양한 경우의 수가 존재한다. 현실에서 다루어야 하는 집합은 퍼지집합에서와 같이 특정 집합에 대한 소속 정도가 명확하지 않은 경우가 대부분이다. 특히 수자원 관리에 필요한 많은 목적함수와 제약조건들에는 정확하지 못한 측정이 많이 존재하기 때문에 수자원의 관리에 불확실성과 애매모호함을 제어하기 위한 퍼지이론을 도입하여 효율성을 높일 수 있다.

본 연구에서는 Jang (1993)에 의해 제안된 퍼지이론에 신경회로망 이론을 도입한 적응형 퍼지 신경회로망 추론 기법인 ANFIS를 사용해 관측기상자료(강우자료)와 관측 수문자료(유량자료) 및 예측기상자료(강우자료)와 예측 수문자료(유량자료) 사이의 상관관계 분석을 통해 유출량을 예측하였다. ANFIS 모형은 물리적인 유역의 특성자료를 고려하지 않고 입력자료(관측 강우자료, 관측 유입량자료, 예측 강우자료)와 출력자료(유입량자료)의 상관성 분석을 통해서만 구축되는 모형이기 때문에 입력자료와 출력자료의 구성이 모형의 정확도에 큰 영향을 미치게 된다. ANFIS 모형에서는 모형 학습을 위한 입·출력자료를 어떻게 구성하는가에 따라서 모형의 예측 정확도는 상당한 차이를 나타낸다. ANFIS를 사용한 댐 유입량 예측 연구에서는 모형의 학습을 위한 입력자료로 댐 유입량에 직접적인 영향을 미칠 것으로 생각되는 관측기상자료 및 관측수문자료를 사용하는 것이 일반적이다. 본 연구에서는 최근 위성 및 레이더 관측 기술의 발달에 힘입어 활발히 연구가 진행되고 정확도가 향상되고 있는 기상예보 자료

를 모형의 추가적인 입력자료로 사용하여 댐 유입량 예측 연구를 수행하였다.

2.2 MAPLE 강우예측

MAPLE은 캐나다 McGill 대학의 기상 레이더 그룹에서 개발한 단시간 강우예측 모형으로 현재와 과거 시간의 레이더 영상 차이를 통하여 강수에코의 이동벡터를 산출하는 변분 에코 추적 기법을 이용하고 있으며 라그랑지 연속성(Lagrangian persistence)에 기반을 두고 수 시간 이내의 강수 에코 위치에 대한 예측정보를 제공한다. 변분 에코 추적기법(Variational Echo Tracking, VET)은 레이더 강수의 에코뿐만 아니라 위성 영상 등 시간에 따라 이동하는 모든 영상에 적용할 수 있으며, 강수 에코 위치에 대한 예측정보를 제공하는 라그랑지 연속성은 현재까지 강우패턴의 단기예측을 위한 최적의 방법으로 알려져 있으며 0~6시간 범위에 대한 수치모델의 기술은 다른 방법을 적용한 실황예보보다 우수한 결과를 보이는 것으로 나타났다. Lagrangian 외삽법은 다른 시간에서의 강우 패턴들 사이의 교차상관과 같은 기법을 이용하여 강우패턴의 움직임을 결정하고 예보시간에서의 강수 에코 위치를 산출하기 위해 결정된 강우패턴의 움직임을 따라 이류시키는 형태이다.

MAPLE 예측결과는 강우의 생성과 소멸을 예측할 수 없고 레이더 관측장의 오류로 인한 비정상 에코 등의 발생으로 예측장의 오차를 발생시키는 문제점을 안고 있다. 특히 강우의 생성 및 소멸을 모의하지 못하고 관측된 강수에코의 이동만을 모의하는 방법으로 벡터의 이동 역시 일괄적으로 변화하게 되므로 시간이 지날수록 상관성이 떨어지는 것을 볼 수 있다. 또한, 강우 예측자료가 갑작스런 강수에코의 생성, 소멸 등이 공존하는 조건에서 어느 정도의 예측이 가능한지에 대해 살펴보면, 동일시간대에 대한 과거 예측자료에서는 2시간 전까지는 유사하게 나타나지만 그 강도나 분포에 차이가 발생하고, 3시간 이후에는 생성 혹은 소멸에 의한 에코의 분포를 제대로 예측하지 못하는 것으로 나타났다(Kim et al., 2009). 그렇지만 Jang (2009)의 자료(Fig. 1)에 나타난 것과 같이 MAPLE은 KLAPS (Korea Local Analysis and Prediction System; NIMR, 2006), VDRAS (Variational Doppler Radar Analysis System; Sun and Crook, 1997, 2001), KWRF (Weather Research & Forecasting Model; KMA, 2005), UM (Unified Model; Davies et al., 2005) 등의 모형에 비해 초단기예보에서 우수한 예측 성능을 보이는 것을 알 수 있다.

국립기상연구소 예보연구팀에서는 2008년 6월부터 MAPLE 모형을 시험운영하고 있으며 기상청 종합 기상 정보시스템을 통하여 매 10분마다 예보관들에게 6시간 이내의 초단기 예측을 위한 정보를 제공하고 있는데, 특히, 3시간 이내에서 높은 예측성을 가지는 것으로 분석되고 있다(Lee, 2008). MAPLE을 통한 예측결과는 강수 에코 이동벡터를 산출하기 위하여 사용되는 시차를 가지는 3개의 레이더 합성영상과 3종류의 레이더 합성영상으로 구분되어 총 6가지의 형태로 제공되고 있으며, 예측결과의 제공시간은 관측 시간 기준으로 30분 이내에 모든 예측 결과를 제공하고 강수 에코가 적은 경우에는 예측결과가 제공되지 않는다.

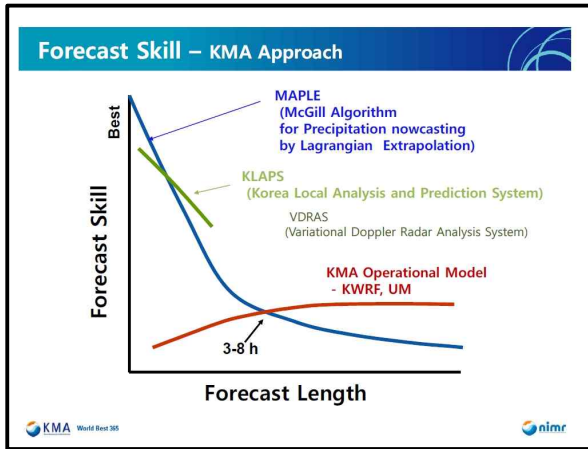


Fig. 1. Forecast Skill Comparison

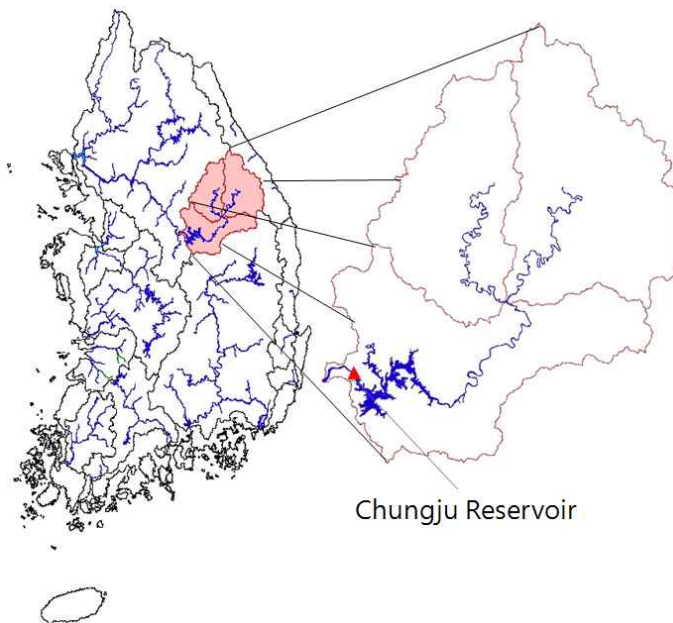


Fig. 2. Map of Pilot Basin

3. 시험유역 적용

3.1 시험유역 선정

기상예보자료를 활용한 유출량 예측 모형의 적용성을 평가하기 위해 충주댐 유역을 시험유역으로 하여 연구를 수행하였다. 충주댐 유역은 남한강의 홍수 조절을 담당하고 있는 유일한 다목적댐으로 남한강 유역의 면적에 비해 상대적으로 작은 홍수조절 능력을 갖고 있는 것으로 평가되어 추가적인 홍수 조절 방안에 대한 연구가 수행되고 있다. 또, 2006년과 같은 중부지방 집중호우 발생 시에는 홍수기 제한수위로부터 약 6m 가량 수위를 낮추어 운영하는 등 홍수 대응에 어려움을 겪고 있다. 본 연구에서는 충주댐 홍수 대응능력 향상을 위한 비구조적인 대안의 하나로, 충주댐 홍수유입량의 정확도를 향상을 통해 충주댐 운영의 효율성과 안전성을 높이고자 하였다.

충주댐 상류 유역은 남한강 유역의 상류에 위치하고 있으며, 남한강 상류유역(2,447.85 km²)과 평창강 유역(1,773.39 km²) 및 충주댐 유역(2,483.83 km²)의 세 개 중권역으로 구성되어 있으며 충주댐 하류 조정지댐 유역면적 43.48 km²를 제외하여 6,661.58 km²의 면적을 가진다(Fig. 2). 모형의 입력자료로 사용되는 관측 강우량 자료를 구축하기 위해 충주댐 상류유역에 위치한 수자원공사에서 운영 중인 33개 강우관측소의 지점강우량을 Thiessen 면적 가중치를 사용하여 평균강우량으로 환산하였다(Table 1).

Table 1. Thiessen Weight Factor for Rainfall Station

Station	Thiessen	Station	Thiessen	Station	Thiessen
Jinbu	0.041	Mitan	0.031	Bongyang	0.018
Hoenggye	0.024	Jeongseon	0.031	Jecheon	0.029
Bongpyung	0.041	Dukam	0.023	Youngwol 1	0.03
Suhang	0.029	Hajang	0.035	Sangdong	0.026
Oangsan	0.02	Anheung	0.017	Hadong	0.044
Daehoa	0.035	Suju	0.029	Chungjudam	0.019
Yucheon	0.021	Yeunduk	0.017	Cheongpung	0.025
Imgye	0.035	Mungok	0.032	Eosangcheon	0.034
Unhak	0.026	Sabuk	0.044	Youngchun	0.032
Banglim	0.032	Sinlim	0.029	Deoksan	0.041
Pyungchang	0.022	Baekun	0.029	Danyang	0.054

3.2 MAPLE 강우예측 자료 추출

MAPLE 강우예측자료는 10분 간격으로 예보를 수행하여 예측자료를 생성하게 되며 한반도 주변 1,024 × 1,024 km의 범위에 대해 10분 간격의 36개의 예측값(6시간)과 1개의 초기값(예보시점의 레이더 관측값)을 저장하고 있는 binary 형태의 gzip 압축 파일 형태로 구성되어있다. 본 연구에서는 MAPLE 자료의 예측 정확도 감소(3시간 이내의 정확도가 높음)와 자료 제공에 소요되는 시간(30분)을 감안하여, MAPLE 예측자료로부터 충주댐 상류유역에 대한 초기값과 예보시간으로부터 1시간 후, 2시간 후의 예보값을 1시간 간격으로 추출한 자료를 사용하였다.

MAPLE 자료는 지도의 좌표체계와 달리 1 km 격자의 행렬 좌표로 구성되어 있으며 동경 128°, 북위 36° 지점을 기준점으로 1,024행 1,024열의 범위를 가진다. 기준점은 격자로 환산할 경우 (x, y) 좌표로 (427, 771)의 위치에 해당되고, 행렬좌표로 고려할 경우 y좌표를 역순치환하여 253행 427열의 위치로 변환되어 진다(Fig. 3). 본 연구에서는 각 격자의 위치를 계산하고 각 격자로부터 강우량을 추출하고 평균하는 과정을 간소화하기 위해 5 × 5 km 크기로 격자의 크기를 변경하여 25 km² 면적의 격자를 생성하고 이에 대한 자료를 추출하여 각 시험유역에 대한 평균강우량을 산정하였다.

본 연구에서 사용하게 될 MAPLE 강우예측자료의 정확도를 평가하기 위해 MAPLE의 현재 시간과 1~3시간 후 예측자료와 지상강우관측소 관측자료 사이의 결정계수를 산정하여 상관성을 분석하였다. 상관관계 분석은 2010년과 2011년의 홍수기 전 구간에 대한 동시간의 자료를 1

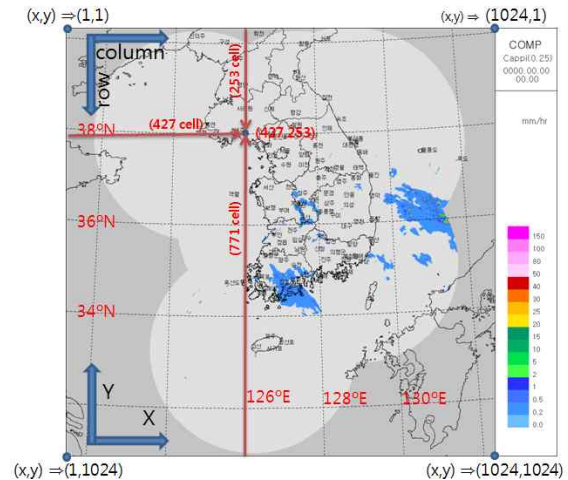


Fig. 3. Reference Point of MAPLE

대1로 비교하였다. 2010년의 경우 결정계수는 1대1 비교와 누적강우량의 비교결과 각각 0.6677~0.3713, 0.9895~0.9721이었으며, 2011년의 경우 0.6242~0.005 및 0.9969~0.9955로 나타났다(Table 2). 예측자료의 상관성은 예측 선행시간이 길어질수록 급격히 떨어지며 2010년의 경우 3시간 후, 2011년의 경우 2시간 후의 자료의 결정계수가 0.5이하로 상관관계가 낮은 것으로 나타났다. 2011년의 경우 2시간 후 강우예측자료의 결정계수가 낮지만 연구의 전체적인 맥락을 고려하여 t+1 및 t+2 시간의 강우예측자료를 그대로 사용하였다.

3.3 ANFIS 모형의 입력자료 구성

자료지향형모형인 ANFIS 모형을 구성하기 위해서는 학습과 보정 및 검증을 위해 3개 set의 자료(training data,

checking data, testing data)가 필요하다. 본 연구에서는 모형의 구성에 필요한 3개 set의 자료 구성이 홍수량 예측 결과에 미치는 영향을 분석하기 위해 입력 자료를 다양하게 변화시켜 홍수량 산정 결과를 비교했다. 모형의 구성에 필요한 3개 set의 자료 구성에 따른 모형의 결과 분석을 위해서는 비교하고자 하는 자료를 제외한 나머지 2개의 자료를 고정한 상태에서 비교 대상 자료만을 변화시켜가며 비교하는 것이 가장 좋은 방법이지만, 본 연구에서 사용한 강수량 예측자료인 MAPLE 자료 사용을 위해 2010년 및 2011년 홍수기 자료만을 사용하여 아래에 제시한 3개 CASE와 몇 가지 추가 CASE에 대해서만 검토하였으며 그 중 3개의 CASE의 결과를 제시하였다. ANFIS 모형 구동을 위한 자료는 2010년(6~9월), 2011년(5~9월) 홍수기의 충주댐 상류유역 강수량, 충주댐 유입량 관측 자료 및 MAPLE 강수량 예측 자료를 사용하였다. 모형에 사용할 홍수사상은 충주댐 유입량이 큰 구간을 위주로 선정하였으

며 유입량의 변동을 고려하여 매 5일 단위의 간격을 기준으로 6개의 홍수 event를 선정하였다(Table 3).

일반적으로 모형의 학습에 사용되는 training data는 자료의 길이가 길고 ANFIS 모형에 적용하는 시스템을 대표할 수 있는 자료의 형태를 갖는 것이 좋은 것으로 알려져 있다(The Math Works, Inc., 2006). 선정한 6개의 홍수 event 중 관측된 강수량 및 첨두홍수량이 가장 크고, 가장 긴 홍수사상이 발생한 기간은 2011년 6월 15일부터 7월 25일까지 40일 동안으로 이 기간의 자료(event 4)를 모형의 학습(training) 자료로 사용하였다. 나머지 홍수 event 자료를 첨두유입량과 총 유입량의 크기를 고려해 조합하여 보정(checking) 및 검증(testing) 자료로 사용하였다. 본 논문에서는 그 중 event 1, event 2, event 6을 조합한 3개의 CASE에 대해 비교하였다(Table 4).

CASE 1은 모형의 학습, 보정, 검증과정에 사용한 홍수사상의 첨두홍수량의 크기가 학습자료가 가장 크고, 검증

Table 2. Coefficient of Determination for MAPLE due to lead time

R^2	Instant Value		Cumulative Value	
	2010	2011	2010	2011
t	0.6677	0.6242	0.9895	0.9969
t+1	0.6721	0.6009	0.9832	0.9953
t+2	0.5646	0.0054	0.9806	0.996
t+3	0.3713	0.005	0.9721	0.9955

Table 3. Flood Event Selection

	Start	End	Period (day)	Total Inflow (MCM)	Peak Inflow (m^3/s)	Aver. Inflow (m^3/s)	Cause of Rainfall
event 1	2010-09-04	2010-09-18	15	1,330.6	6,050	1,026.7	SF
event 2	2010-09-19	2010-09-28	10	939.7	6,518	1,087.6	PT
event 3	2011-05-06	2011-05-20	15	615.8	2,120	475.2	SF + LP
event 4	2011-06-15	2011-07-24	40	4,441.0	7,624	1,285.0	RS+TP1 +RF+TP2
event 5	2011-07-25	2011-08-08	15	911.5	3,342	703.3	SF
event 6	2011-08-14	2011-08-28	15	1,052.7	4,332	812.3	SF+PT&LP

SF: stationary front(정체전선), PT: pressure trough(기압골), LP: low pressure(저기압), RS: rainy spell(장마), RF: rainy front(장마전선), TP1: Typhoon Meari(태풍 메아리), TP2: Typhoon Ma-on(태풍 망운)

Table 4. Input Data Composition

	Training Data	Checking Data	Testing Data
CASE 1	event 4(1)	event 1(3)	event 2(2)
CASE 2	event 4(1)	event 6(4)	event 1~2(2)
CASE 3	event 4(1)	event 2(2)	event 1(3)

()안의 숫자는 각 홍수사상의 첨두홍수량의 크기에 따른 순서를 의미함.

자료가 학습자료 다음으로 크며, 보정자료의 침투홍수량이 가장 작은 자료로 구성되었다. 모형의 학습에 사용된 침투홍수량 값보다는 작지만 보정에 사용된 홍수사상보다 침투홍수량이 큰 홍수사상이 발생하는 상황을 가정하였다. CASE 2는 모형의 생성에 사용한 자료의 침투홍수량의 크기순서가 CASE 1과 동일하게 학습자료, 검증자료, 보정자료의 순서로 구성되었다. CASE 2와 CASE 1과의 차이는 보정자료의 침투홍수량의 크기가 검증자료보다 현저히 작고, 검증자료가 2개의 peak를 가지고 있는 복잡한 홍수사상이 발생할 경우에 해당된다. CASE 3은 모형의 생성에 사용한 자료의 침투홍수량의 크기의 순서가 학습자료, 보정자료, 검증자료 순으로 구성되었다. CASE 3은 일반적인 크기의 홍수사상이 발생할 경우에 해당된다.

ANFIS 모형은 각 입력변수와 출력변수의 관계에 따라 생성되는 모형이기 때문에 입력변수의 조합에 따라 모형의 결과가 크게 영향을 받게 된다. 본 연구에서는 MAPLE 강우예측자료와 기상관측자료, 수문관측자료의 조합에 따라 1~24시간 후의 댐 유입량을 예측할 수 있는 15개의 모형을 생성하고 각 모형을 통해 모의한 홍수량의 예측결과를 비교하였다(Table 5). 15개 모형은 강우예측자료의 사용 유무와 예측시간에 따라 크게 M0, M1, M2 모형의 3가지 모형으로 분류하였다. 강우예측자료를 사용하지 않은 A~E 모형을 M0 모형으로, 1시간 후 강우예측자료를

입력자료로 사용한 M1A~M1E 모형을 M1 모형으로, 1시간 및 2시간 후 강우예측자료를 입력자료로 사용한 M2A~M2E 모형을 M2 모형으로 분류하였다. R_t, R_{t-1} 은 현재시간 및 현재시간으로부터 한 시간 전의 관측강우량을 나타내고, Q_t, Q_{t-1} 은 현재시간 및 현재시간으로부터 한 시간 전의 관측유입량을 나타낸다. M_{1t} 는 현재 예측한 1시간 후 MAPLE 강우예측값을 사용한 것을 나타내고, M_{2t} 는 현재로부터 1시간 및 2시간 후의 MAPLE 강우예측값을 사용한 것을 의미한다. $FQ_{t+1} \sim FQ_{t+24}$ 는 현재시간으로부터 1~24시간 후의 댐 유입량 예측값을 의미한다.

3.4 ANFIS 모형의 자료 군집화 방법 적용

ANFIS 모형과 같은 자료지향형 모형의 초기 연구에서는 주로 물리적 모형과의 상호 비교가 주로 수행되었으나, 최근에는 모형 생성과정의 설정에 따른 모형의 예측 성능 향상에 관한 연구가 수행되고 있다. 본 연구에서는 모형의 정확도 향상을 위한 연구로, 모형의 구성과정에서 모형의 군집화 방법에 따른 예측정확도를 비교하였다.

군집화 방법에는 fuzzy c-means clustering과 subtractive clustering 그리고 grid partitioning의 방법이 있다. Fuzzy c-means clustering (Bezdek, 1981)은 각 변수의 소속함수의 크기 정도에 따라 자료를 군집화하는 방법으로, 소속함수의 크기와 입력자료를 몇 개의 군집으로 구분할

Table 5. Data Configuration for ANFIS Model

Model		Antecedent Data			Consequent Data
		MAPLE	Obs. Weather Data	Obs. Inflow Data	Forecasted Inflow Data
M0	A		R_t, R_{t-1}	Q_t	$FQ_{t+1} \sim FQ_{t+24}$
	B		R_t, R_{t-1}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	C		R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	D		R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$
	E		$R_t, R_{t-1}, R_{t-2}, R_{t-3}$	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$
M1	M1A	M_{1t}	R_t, R_{t-1}	Q_t	$FQ_{t+1} \sim FQ_{t+24}$
	M1B	M_{1t}	R_t, R_{t-1}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	M1C	M_{1t}	R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	M1D	M_{1t}	R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$
	M1E	M_{1t}	$R_t, R_{t-1}, R_{t-2}, R_{t-3}$	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$
M2	M2A	M_{1t}, M_{2t}	R_t, R_{t-1}	Q_t	$FQ_{t+1} \sim FQ_{t+24}$
	M2B	M_{1t}, M_{2t}	R_t, R_{t-1}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	M2C	M_{1t}, M_{2t}	R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}	$FQ_{t+1} \sim FQ_{t+24}$
	M2D	M_{1t}, M_{2t}	R_t, R_{t-1}, R_{t-2}	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$
	M2E	M_{1t}, M_{2t}	$R_t, R_{t-1}, R_{t-2}, R_{t-3}$	Q_t, Q_{t-1}, Q_{t-2}	$FQ_{t+1} \sim FQ_{t+24}$

것인가를 결정할 수 있다는 장점이 있지만 사용자가 이 값들을 직접 결정하기 어려운 경우가 많고, 퍼지 추론 시스템의 초기값을 직접 설정해 주어야 한다는 운영상의 어려움이 있다. 이에 비해 subtractive clustering (Chiu, 1994)은 군집의 수나 소속함수의 크기 등의 사항에 대한 확실한 정보가 없더라도 clustering 반경만을 입력하면 학습자료(training data)의 조건부 자료와 결과부 자료의 상관관계에 따라 자동으로 군집화를 수행하는 방법으로 퍼지 추론 시스템의 초기값이 결정된다는 장점이 있다. Grid partitioning은 입력 자료의 특성과는 상관없이 학습자료(training data)의 조건부 자료와 결과부 자료를 동일한 간격으로 분할하여 격자 형태로 분리하고 시스템의 초기값을 반환하는 방법이다.

Subtractive clustering을 수행하는데 있어서는 clustering 반경을 결정하는 것은 모형의 결과를 결정하는 중요한 요소 중 하나이다. Subtractive clustering은 입력 자료의 각 변수들 중, 조건부 자료와 결과부 자료를 1대1로 조합하여 각각의 조합에서 최소값과 최대값을 0~1의 값으로 표준화시킨 후 입력받은 clustering 반경의 크기에 따라 자료를 군집화시키고 그 중심점을 결정하게 된다. 조건부와 결과부 자료를 1대1로 조합하기 때문에 조건부 변수와 결과부 변수의 수만큼의 subtractive clustering 과정이 필요하다.

Clustering 반경을 작게 설정하면 각각의 자료들이 개별적으로 군집화 되는 형태가 되어 clustering의 효과가 줄어들게 되고 각 변수의 소속함수(membership function)와 퍼지규칙의 수가 증가하게 된다. 반면 clustering 반경을 크게 설정하면 각각의 값들은 개별적인 의미가 감소하고 하나의 군집 내에서 의미를 갖게 되어 clustering의 효과가 증가되며 각 변수의 소속함수와 퍼지규칙의 수는 감소하게 된다.

4. 적용 결과 및 분석

본 연구에서 개발한 홍수량 산정 모형의 홍수량 산정결과를 비교 분석하였다. 홍수량 산정결과를 모형을 생성 과정에 사용한 홍수사상의 종류(CASE)에 따른 결과 분석과 군집화 방법에 따른 분석 및 강우예측자료 사용유무에 따른 분석을 각각 수행하였다.

ANFIS 모형을 사용한 홍수량 산정결과를 비교하기 위해 산정된 유량과 실측유량을 평균제곱근오차(RMSE : Root Mean Square Error)와 결정계수(R^2 , coefficient of determination)를 사용하여 비교 및 평가하였다. RMSE와 결정계수의 계산에는 각각 Eqs. (1) and (2)를 사용하였

다. 식에서 x_t 는 t 시간에서의 홍수량 예측값, X_t 는 t 시간에서의 관측값이며, \hat{x} 는 회귀식에 의한 X_t 에 대한 추정값이고, \bar{x} 는 x 의 평균값이다.

$$SE = \sqrt{\left(\frac{1}{k-1}\right) \sum_{t=1}^k (x_t - X_t)^2} \quad (1)$$

$$R^2 = \frac{\sum (\hat{x} - \bar{x})^2}{\sum (x_t - \bar{x})^2} \quad (2)$$

4.1 CASE별 홍수량 예측결과 비교

입력자료 구성에 따른 CASE별 홍수량 예측결과를 비교를 위해 각 CASE별 입력자료를 사용하여 생성한 45개 모형(3개의 clustering 반경(0.2, 0.3, 0.4)과 15개 모형)의 홍수량 예측결과를 이용하여 실측유량에 대한 RMSE와 결정계수를 산정한 후 선행시간 별로 각 값을 평균하여 비교하였다. RMSE를 사용한 비교에서는 t+1시간을 제외한 전 시간에서 CASE 3이 가장 우수한 결과를 보였으며, CASE 2가 다음으로 좋은 결과를 보였다(Table 6, Fig. 4). 결정계수를 사용한 비교에서는 t+1~t+5시간에서 CASE 1, t+6~t+12시간에서는 CASE 2, t+13시간 이후에서는 CASE 3의 자료 구성이 가장 우수한 결과를 보였다(Table 7). 그러나 Fig. 5와 같이 t+1~t+5시간의 결정계수의 차이는 극히 미미하며 전 시간 동안 CASE 2와 CASE 3의 결과가 높은 정확도를 나타내었다. 예측값과 실측값의 상관관계는 정확도가 높은 CASE 3의 경우 t+11시간 예측까지 결정계수 0.8 이상의 높은 상관관계를 나타내었고, t+17시간 예측까지 결정계수 0.5 이상의 상관관계를 보였다. RMSE와 결정계수를 사용한 비교를 종합하면 CASE 3의 경우가 가장 좋은 예측 정확도를 나타내었으며, 모형의 학습과 보정에 사용한 자료에 비해 검증 과정에 사용한 홍수사상의 침투홍수량이 작을 경우 예측의 정확도가 높은 것으로 판단된다.

4.2 모형의 학습자료 군집화 방법에 따른 홍수량 예측 결과 비교

군집화 방법에 따른 모형의 결과를 비교하기 위해 ANFIS 모형의 입·출력자료 군집화 방법 중 grid partitioning 방법과, subtractive clustering 방법을 사용한 결과를 비교하였다. Subtractive clustering 방법을 사용한 모형은 clustering 반경을 0.2, 0.3, 0.4로 변화시키며 그 결과를 비교하였다. 군집화 방법에 따른 홍수량 예측결과 비교를 위해, 군집화 방법의 변화에 따른 홍수량 예측값과 관측홍수량을 이용하여 RMSE와 결정계수를 산정한 후 45개 모형

Table 6. RMSE Comparison according to CASE

	CASE1	CASE2	CASE3	best
t+1	58.63	64.29	67.21	CASE1
t+2	102.18	101.43	99.43	CASE3
t+3	162.34	153.10	145.78	CASE3
t+4	230.77	212.54	199.52	CASE3
t+5	309.70	277.87	253.64	CASE3
t+6	389.00	338.31	305.51	CASE3
t+7	463.46	399.39	360.06	CASE3
t+8	536.26	452.12	398.05	CASE3
t+9	603.20	503.29	434.00	CASE3
t+10	665.25	551.53	466.03	CASE3
t+11	720.60	593.91	490.87	CASE3
t+12	782.22	639.28	520.27	CASE3
t+13	847.02	690.24	557.08	CASE3
t+14	911.21	746.72	599.97	CASE3
t+15	971.71	811.66	650.12	CASE3
t+16	1,033.81	881.60	702.57	CASE3
t+17	1,092.46	945.48	764.32	CASE3
t+18	1,154.78	988.08	827.86	CASE3
t+19	1,209.45	1,028.08	883.94	CASE3
t+20	1,273.68	1,070.45	938.99	CASE3
t+21	1,320.08	1,113.46	981.23	CASE3
t+22	1,349.45	1,146.95	1,013.97	CASE3
t+23	1,367.11	1,175.37	1,039.88	CASE3
t+24	1,374.41	1,195.02	1,048.15	CASE3




Fig. 4. RMSE Comparison according to CASE

(3개 CASE와 15개 모형)의 결과를 선행시간별로 평균하여 비교하였다(Table 8, Figs. 6 and Fig. 7).

RMSE를 사용한 비교에서는 grid partitioning 방법을 사용한 결과의 오차가 subtractive clustering 방법을 사용한 결과의 오차에 비해 과도하게 크게 나타났다(Table 8). 즉, subtractive clustering 방법을 사용한 결과가 grid partitioning 방법을 사용한 결과에 비해 월등히 좋은 것으로 나타났다. Subtractive clustering 방법의 결과는

Table 7. R^2 Comparison according to CASE

	CASE1	CASE2	CASE3	best
t+1	0.9981	0.9966	0.9966	CASE1
t+2	0.9943	0.9923	0.9923	CASE1
t+3	0.9857	0.9826	0.9826	CASE1
t+4	0.9712	0.9673	0.9671	CASE1
t+5	0.9482	0.9475	0.9465	CASE1
t+6	0.9183	0.9242	0.9221	CASE2
t+7	0.8847	0.8963	0.8919	CASE2
t+8	0.8459	0.8738	0.8681	CASE2
t+9	0.8054	0.8515	0.8431	CASE2
t+10	0.7626	0.8263	0.8196	CASE2
t+11	0.7205	0.804	0.8002	CASE2
t+12	0.6694	0.7764	0.7748	CASE2
t+13	0.6118	0.7405	0.7406	CASE3
t+14	0.5513	0.69	0.6953	CASE3
t+15	0.4824	0.6583	0.6667	CASE3
t+16	0.4326	0.5507	0.5822	CASE3
t+17	0.3805	0.481	0.5118	CASE3
t+18	0.3276	0.4216	0.4388	CASE3
t+19	0.2784	0.3666	0.3754	CASE3
t+20	0.234	0.3114	0.3142	CASE3
t+21	0.195	0.2657	0.2671	CASE3
t+22	0.1626	0.2278	0.2324	CASE3
t+23	0.1363	0.197	0.2034	CASE3
t+24	0.1116	0.1793	0.1882	CASE3




Fig. 5. R^2 Comparison according to CASE

clustering 반격의 크기가 큰 경우 전체 예측 시간에서 우수한 결과를 보였다(Table 8, Fig. 6). Fig. 6에서는 군집화방법에 따른 예측 선행시간별 RMSE의 변화를 그래프로 나타내었으며, grid partitioning 방법의 오차는 subtractive clustering 방법의 오차에 비해 과도하게 크게 산정되어 생략하였다.

결정계수를 사용한 비교에서도 grid partitioning 방법을 사용한 결과가 subtractive clustering 방법을 사용한 결과

에 비해 과도하게 낮은 상관관계를 나타냈다(Table 9). 즉, subtractive clustering 방법을 사용한 결과가 grid partitioning 방법을 사용한 결과에 비해 월등히 좋은 것으로 나타났다. Subtractive clustering 방법의 결과 역시 결정계수를 사용한 결과와 유사하게 clustering 반경의 크기가 큰 경우 전체 예측 시간에서 우수한 결과를 보였다(Table 9, Fig. 7).

Table 8. RMSE Comparison according to Clustering Method

	GP	R=0.2	R=0.3	R=0.4	best
t+1	11,298	64	64	62	R=0.4
t+2	20,238	103	102	98	R=0.4
t+3	22,621	157	155	150	R=0.4
t+4	36,075	218	216	209	R=0.4
t+5	40,046	287	281	273	R=0.4
t+6	45,846	358	341	334	R=0.4
t+7	53,783	425	403	395	R=0.4
t+8	61,694	482	456	449	R=0.4
t+9	76,763	536	506	499	R=0.4
t+10	88,572	583	554	546	R=0.4
t+11	104,249	623	595	587	R=0.4
t+12	121,841	670	640	632	R=0.4
t+13	135,647	722	691	681	R=0.4
t+14	153,954	774	749	735	R=0.4
t+15	167,700	836	808	790	R=0.4
t+16	185,213	892	870	856	R=0.4
t+17	192,496	945	935	922	R=0.4
t+18	209,875	1,001	994	975	R=0.4
t+19	232,978	1,066	1,041	1,015	R=0.4
t+20	262,042	1,120	1,090	1,073	R=0.4
t+21	277,475	1,174	1,145	1,095	R=0.4
t+22	289,330	1,222	1,168	1,120	R=0.4
t+23	304,387	1,249	1,188	1,146	R=0.4
t+24	316,373	1,254	1,199	1,165	R=0.4




Fig. 6. RMSE Comparison according to Clustering Method

4.3 강우예측자료 사용 유무에 따른 홍수량 예측 결과 비교

강우예측자료 사용 유무에 따른 홍수량 예측 결과를 위해 입력자료 사용에 따른 3개 CASE와, 3개 clustering 반경에 따른 모형의 결과를 관측값과 비교하여 RMSE와 결정계수를 산정한 후, Table 5의 A~M2E까지 15개

Table 9. R^2 Comparison according to Clustering Method

	GP	R=0.2	R=0.3	R=0.4	best
t+1	0.3688	0.9971	0.9971	0.9972	R=0.4
t+2	0.3032	0.9927	0.9928	0.9933	R=0.4
t+3	0.2831	0.9831	0.9834	0.9845	R=0.4
t+4	0.2406	0.9672	0.9681	0.9703	R=0.4
t+5	0.2223	0.9449	0.9472	0.9501	R=0.4
t+6	0.1929	0.9155	0.9226	0.9265	R=0.4
t+7	0.1779	0.8814	0.8934	0.8981	R=0.4
t+8	0.1611	0.8505	0.8659	0.8712	R=0.4
t+9	0.1453	0.8179	0.8376	0.8443	R=0.4
t+10	0.1452	0.7843	0.8085	0.8157	R=0.4
t+11	0.1323	0.756	0.781	0.7877	R=0.4
t+12	0.129	0.7201	0.7468	0.7538	R=0.4
t+13	0.1213	0.676	0.7047	0.7123	R=0.4
t+14	0.1063	0.6267	0.6475	0.6625	R=0.4
t+15	0.1103	0.5834	0.6039	0.62	R=0.4
t+16	0.1017	0.5031	0.5229	0.5395	R=0.4
t+17	0.0832	0.4459	0.453	0.4745	R=0.4
t+18	0.0794	0.3835	0.3901	0.4144	R=0.4
t+19	0.0807	0.3159	0.3389	0.3656	R=0.4
t+20	0.0806	0.2619	0.2872	0.3105	R=0.4
t+21	0.0773	0.2123	0.2386	0.2769	R=0.4
t+22	0.0707	0.172	0.2048	0.2459	R=0.4
t+23	0.0661	0.144	0.1764	0.2163	R=0.4
t+24	0.0638	0.1292	0.1552	0.1947	R=0.4




Fig. 7. R^2 Comparison according to Clustering Method

Table 10. RMSE Comparison according to Using Forecasted Precipitation Data (1)

	M0	M1	M2	best
t+1	62.2	63.8	64.1	M0
t+2	101.0	101.0	101.0	M0
t+3	152.4	153.0	155.8	M0
t+4	212.5	213.9	216.5	M0
t+5	277.8	280.7	282.7	M0
t+6	344.9	346.0	341.9	M2
t+7	406.7	409.8	406.5	M2
t+8	460.2	466.6	459.6	M2
t+9	512.7	519.1	508.6	M2
t+10	561.4	566.3	555.1	M2
t+11	607.6	609.1	588.7	M2
t+12	655.9	656.0	629.9	M2
t+13	704.2	710.1	680.0	M2
t+14	757.5	766.7	733.7	M2
t+15	814.2	826.5	792.8	M2
t+16	873.1	886.4	858.5	M2
t+17	927.1	953.2	921.9	M2
t+18	973.3	1010.4	987.0	M0
t+19	1017.5	1057.6	1046.4	M0
t+20	1062.4	1116.5	1104.2	M0
t+21	1108.2	1150.4	1156.2	M0
t+22	1138.9	1182.0	1189.5	M0
t+23	1167.1	1200.8	1214.5	M0
t+24	1186.1	1210.6	1220.9	M0

모형별로 각각 평균하고 2가지 방법으로 비교하였다. 첫 번째는 15개 모형별로 평균한 값을 M0, M1, M2 모형으로 분류하여 다시 평균하여 비교하였으며(Table 10, Table 12), 두 번째는 15개 모형별로 평균한 값을 M0, M1, M2 모형 별로 최적모형을 선정된 후 선정된 3개 모형을 비교하였다(Tables 11 and Table 13).

RMSE를 사용한 비교 중 평균값을 이용한 비교(Table 10)에서는 t+6~t+17시간 예측에서는 M2 모형이 가장 우수한 결과를 보였고, 나머지 시간에서는 M0 모형이 우수한 결과를 나타내었다. RMSE를 사용한 비교 중 M0, M1, M2 모형별 최적모형의 비교(Table 11)에서 t+4시간에서는 M1 모형이 우수한 결과를 보였고, t+6시간과 t+8~t+18시간에서는 M2 모형이 우수한 결과를 보였으며, 나머지 시간에서는 M0 모형이 우수한 결과를 나타내었다. 결정계수를 사용한 비교 중 평균값을 이용한 비교(Table 12)에서는 t+6시간과 t+9~t+15시간 예측에서 M2 모형이 가장 우수한 결과를 보였고, 나머지 시간에서는 M0 모형이 우수한 결과를 보였다. 결정계수를 사용한 비교 중 M0, M1, M2 모형별 최적모형의 비교(Table 13)에서는 t+6~t+18시간 예측에서 M2 모형이 가장 우수한 결과를 보였고, 나머지 시간에서

Table 11. RMSE Comparison according to Using Forecasted Precipitation Data (2)

	M0	M1	M2	best	RMSE
t+1	C	M1E	M2E	C	61.2
t+2	C	M1C	M2C	C	96.7
t+3	C	M1C	M2C	C	145.6
t+4	C	M1C	M2C	M1C	205.8
t+5	C	M1E	M2C	C	267.1
t+6	C	M1E	M2C	M2C	327.4
t+7	C	M1C	M2C	C	392.2
t+8	C	M1C	M2C	M2C	446.2
t+9	C	M1C	M2C	M2C	498.9
t+10	C	M1C	M2B	M2B	540.4
t+11	C	M1C	M2A	M2A	577.1
t+12	C	M1A	M2A	M2A	614.3
t+13	C	M1A	M2A	M2A	655.1
t+14	C	M1A	M2A	M2A	706.
t+15	C	M1A	M2A	M2A	764.1
t+16	C	M1C	M2A	M2A	824.9
t+17	B	M1C	M2A	M2A	890.4
t+18	C	M1A	M2A	M2A	943.6
t+19	C	M1A	M2A	C	994.8
t+20	C	M1A	M2A	C	1,035.8
t+21	C	M1A	M2A	C	1,076.2
t+22	C	M1A	M2A	C	1,109.7
t+23	C	M1B	M2A	C	1,137.9
t+24	C	M1A	M2A	C	1,153.7

는 M0 모형이 우수한 결과를 나타내었다. 예측값과 관측값과의 상관관계는 대체적으로 t+10시간까지 결정계수 0.8 이상의 높은 상관성을 보였고, t+16시간 예측까지 결정계수 0.5 이상의 상관성을 보였다. 결정계수 0.5 이하의 값은 상관성이 없다고 판단할 경우 홍수량 예측 결과가 관측값과의 상관성을 보이는 t+16시간까지의 홍수량 예측 범위에서는 대체적으로 t+5시간 이내의 홍수량예측에서는 강우예측자료를 사용하지 않는 모형의 정확도가 비교적 높게 나타났으며, t+6~t+16시간의 홍수량 예측에서는 강우예측자료를 사용한 모형의 정확도가 비교적 높게 나타났다.

Fig. 8을 통해 유입량 예측에서 가장 좋은 결과를 보였던 CASE3의 clustering 반경 0.4 모형의 결과 중, 홍수량 예측의 상관성이 0.5 이상이며 홍수예측 선행시간이 가장 길었던 t+16시간의 유입량 예측 결과를 그래프로 나타내었다.

4.4 결과 분석

본 연구를 통한 CASE별 결과를 RMSE와 결정계수를 통해 종합적으로 분석해보면, 모형의 생성을 위한 학습, 보정, 검증자료의 구성에 따른 CASE별 RMSE 비교에서

Table 12. R^2 Comparison according to Using Forecasted Precipitation Data(1)

	M0	M1	M2	best
t+1	0.9973	0.9971	0.997	M0
t+2	0.9931	0.9929	0.9929	M0
t+3	0.9842	0.9837	0.983	M0
t+4	0.9694	0.9685	0.9677	M0
t+5	0.9483	0.9475	0.9464	M0
t+6	0.9209	0.9214	0.9222	M2
t+7	0.8916	0.8903	0.891	M0
t+8	0.8637	0.861	0.8631	M0
t+9	0.833	0.8308	0.836	M2
t+10	0.803	0.7996	0.8059	M2
t+11	0.773	0.7681	0.7837	M2
t+12	0.7378	0.7324	0.7505	M2
t+13	0.699	0.6858	0.7082	M2
t+14	0.6486	0.6302	0.6579	M2
t+15	0.5968	0.5918	0.6188	M2
t+16	0.5297	0.5067	0.5291	M0
t+17	0.4691	0.4419	0.4624	M0
t+18	0.409	0.3821	0.3968	M0
t+19	0.3548	0.3315	0.3341	M0
t+20	0.3053	0.2778	0.2766	M0
t+21	0.2535	0.2404	0.234	M0
t+22	0.2183	0.2064	0.1981	M0
t+23	0.1887	0.1796	0.1683	M0
t+24	0.1675	0.1637	0.1479	M0

Table 13. R^2 Comparison according to Using Forecasted Precipitation Data(2)

	M0	M1	M2	best	R^2
t+1	C	M1D	M2D	C	0.9973
t+2	C	M1B	M2E	C	0.9934
t+3	C	M1E	M2C	C	0.9852
t+4	C	M1C	M2C	C	0.9707
t+5	C	M1E	M2C	C	0.9514
t+6	E	M1E	M2C	M2C	0.9284
t+7	C	M1C	M2C	M2C	0.8994
t+8	C	M1C	M2C	M2C	0.8733
t+9	E	M1C	M2C	M2C	0.8459
t+10	C	M1C	M2C	M2C	0.8161
t+11	C	M1C	M2C	M2C	0.7939
t+12	C	M1C	M2C	M2C	0.7625
t+13	C	M1C	M2C	M2C	0.7208
t+14	C	M1C	M2C	M2C	0.6734
t+15	B	M1C	M2A	M2A	0.6327
t+16	C	M1C	M2A	M2A	0.5538
t+17	A	M1C	M2A	M2A	0.4876
t+18	C	M1A	M2A	M2A	0.4319
t+19	C	M1A	M2A	C	0.3719
t+20	C	M1A	M2A	C	0.3209
t+21	C	M1A	M2A	C	0.2736
t+22	C	M1A	M2A	C	0.2356
t+23	C	M1B	M2A	C	0.2041
t+24	C	M1A	M2A	C	0.1823

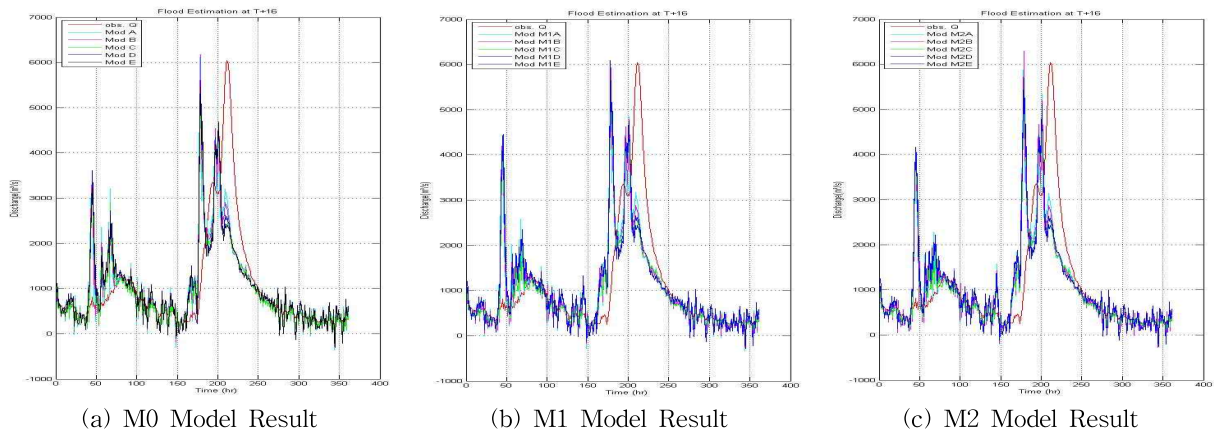


Fig. 8. Flood Estimation Result of CASE3 t+16

는 CASE 3의 자료 구성이 전 시간에 걸쳐 우수한 결과를 나타내었다. 결정계수 비교에서는 짧은 예측 선행시간(t+1~t+5시간)에서는 CASE 1이 우수한 결과를 보였으며, t+6~t+12시간 예측에서는 CASE 2가 우수한 결과를 보이고, t+13시간 이후의 예측에서는 CASE 3이 우수한 결과를 보였다. 결정계수의 값은 CASE 2와 CASE 3은 전체적으로 유사하게 높은 값을 나타내었고, 가장 좋은 결과를

보인 CASE 3의 결정계수는 t+11시간까지 0.8 이상의 높은 상관관계를 보였으며, t+17시간까지 0.5의 상관관계를 나타내었다. 모형의 생성과정(학습 및 보정과정)에 사용한 홍수사상의 침투홍수량의 크기가 검증과정에 사용한 홍수사상의 침투홍수량의 크기보다 클 경우 좀 더 정확한 홍수량 예측을 수행하는 것으로 판단된다.

자료의 군집화 방법에 따른 비교에서는 grid partition-

ing에 비해 subtractive clustering의 결과가 우수한 것으로 나타났다. clustering 반경은 모형이 생성되는 범위 안에서 비교적 큰 값을 가질 때 우수한 모형을 생성하는 것으로 나타났다. 본 연구에서는 clustering 반경을 0.2, 0.3, 0.4로 설정하여 모형을 생성하였다. clustering 반경이 0.5일 때는 A~E, M1A~M1E, M2A~M2E 중 일부 모형(주로 A~M1E까지 입력 변수의 개수가 비교적 적은 모형)에서는 모형이 생성되었지만, M2C~M2E 모형에서는 모형 생성이 불가능했다. 이것은 clustering 반경을 크게 설정할 경우 각 입력변수의 군집화 범위가 넓어지게 되기 때문에, 범위 안의 데이터를 하나의 cluster로 처리하게 되고 이로 인해 fuzzy rule을 생성할 수 없게 되어 발생하는 문제이다. 본 연구에서 clustering 반경은 0.2, 0.3, 0.4의 세 가지 값에 대해서만 비교하였기 때문에 이후 좀 더 넓은 범위와 세세한 변화에 대해 추가적인 비교가 필요할 것으로 보인다.

MAPLE 예측자료의 사용에 따른 RMSE 비교에서는 24시간의 홍수 예측 선행시간 중 중반부(t+6~t+17시간)의 경우 MAPLE 강우예측자료를 사용한 모형(M2 모형)의 홍수량 예측 결과가 비교적 우수한 것으로 나타났으며, 결정계수를 사용한 비교에서도 이와 유사하게 중반부(t+6, t+9~t+15시간)의 홍수량 예측에서 M2 모형의 홍수량 예측 결과가 비교적 우수한 결과를 보였다. 모형의 홍수량 예측값과 관측값 사이에 상관성이 있다고 판단되는 0.5 이상의 결정계수를 갖는 구간은 t+1~t+16시간의 범위였으며, 이 구간만을 고려하여 강우예측자료의 사용에 따른 모형의 결과를 평가할 경우 전반부(t+1~t+5시간) 예측에서는 강우예측자료를 사용하지 않는 모형의 정확도가 높고, 후반부(t+6~t+16시간) 예측에서는 강우예측자료를 사용한 모형의 정확도가 높은 것으로 판단된다.

5. 결 론

본 연구에서는 ANFIS 모형의 입력자료로 강우예보자료, 강우관측자료 및 유량관측자료를 사용하여 충주댐의 유입량을 예측하였다. 강우예보자료는 RADAR 자료를 사용한 초단기 예보인 MAPLE 강우예측자료 중 1시간 및 2시간 후 강우예측자료를 사용하였다. 모형 생성에 사용된 자료에 따른 결과의 비교를 위해 홍수사상의 조합을 다르게 하여 3가지 CASE의 모형을 생성하고 그 결과를 비교하였다. 자료의 군집화 방법에 따른 모형의 결과 비교를 위해 grid partitioning과 subtractive clustering에 따른 결과를 비교하였으며, subtractive clustering 방법을

사용한 모형에서는 clustering 반경의 변화에 따른 결과를 비교하였다. 강우예측자료의 사용 유무에 따른 비교를 위해서는 입력자료의 조합을 달리하여 15개 모형을 생성하여 ANFIS 모형의 홍수량 예측결과 비교하였다.

자료의 구성에 따른 결과의 비교에서는 학습자료와 보정자료에 비해 검증자료에 사용된 홍수사상의 침투홍수량이 작은 경우 우수한 홍수량 예측 결과를 보였다. 이는 모형의 생성과정에서 기존에 관측된 홍수사상 중 가장 큰 홍수사상을 학습자료와 보정자료로 사용하여 모형을 생성하는 것이 보다 정확한 홍수 예측에 도움이 된다는 것을 나타낸다. 자료의 군집화 방법에 따라서는 subtractive clustering을 사용한 방법이 grid partitioning을 사용한 방법에 비해 우수한 결과를 나타냈으며, clustering 반경은 비교적 큰 값을 가질 때 우수한 결과를 보이는 것으로 나타났지만 이후 넓은 범위의 세부적인 반경 변화가 결과에 미치는 영향에 대한 연구가 필요할 것으로 생각된다. MAPLE 강우예측자료의 사용 유무에 따른 비교에서는 t+6~t+16시간의 홍수예측에서는 강우예측자료를 사용한 모형이 우수한 결과를 보였으며, 그 시간 전·후 시간의 홍수량 예측에서는 강우예측자료를 사용하지 않은 모형이 우수한 결과를 보였다. 모형의 홍수량 예측결과와 관측유량의 상관성분석을 위한 결정계수 산정결과 t+16시간 이내의 홍수량 예측 결과는 0.5 이상의 상관성을 갖는 것으로 나타났으며, 이를 고려할 경우 단기간의 홍수량 예측에서는 강우예측자료를 사용하지 않은 모형이 우수하며 장기간의 홍수량 예측에서는 강우예측자료를 사용한 모형이 우수한 것으로 나타났다. 정확성이 높은 강우예측자료를 사용할 경우 정확도 높은 홍수량 예측 수행에 도움이 될 수 있을 것으로 판단되며, 홍수량 예측 선행시간을 확장할 수 있을 것으로 판단된다.

감사의 글

이 논문은 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2012-0008716).

References

Abrahart, R.J., See, Linda M, Solomatine, and Dimitri, P. (2008). Practical Hydroinformatics: Computational Intelligence and Technological Developments in Water Applications. Springer.

- Bae, D.H., Jeong, D.M., and Kim, G. (2007) "Monthly dam inflow forecasting using weather forecasting information and neuro-fuzzy technique." *Hydrological Sciences Journal*, Vol. 52, No. 22, pp. 99-113.
- Bezdek, J.C. (1981) *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York.
- Byun, D.H. (2009). *Dam Inflow Forecasts Using Short-Term Numerical Weather Forecast Data*. MS. thesis, Sejong University, Korea.
- Chiu, S. (1994) "Fuzzy Model Identification Based Cluster Estimation." *Journal of Intelligent & Fuzzy Systems*, Vol. 2, No. 3, 1994.
- Daniel, W.K., and Arlen, D.F. (1998) "Evolution of Clark's Unit Graph Method to Spatially Distributed Runoff." *Journal of Hydrologic Engineering*. Vol. 3, No. 1, pp. 9-19
- Dastorani, M.T., Afkhami, H., Sharifidarani, H., and Dastorani, M. (2010). "Application of ANN and ANFIS Models on Dryland Precipitation Prediction (Case Study: Yazd in Central Iran)" *Journal of Applied Sciences, Asian Network for Scientific Information*, Vol. 10, No. 20, pp. 2387-2394.
- Davies, T., Cullen, M.J.P., Malcolm, A.J., Mawson, M.H., Staniforth, A., White, A.A., and Wood, N. (2005) "A new dynamical core for the Met Office's global and regional modeling of the atmosphere." *Q. J. R. Meteorol. Soc.*, Vol. 131, pp. 1759-1782.
- Fread, D.L. (1985) *National Weather Service Operational Dynamic Wave Model*, Hydrologic Research Laboratory, NWS.
- Germann, U., and Zawadzki, I. (2002) "Scale-dependence of the predictability of precipitation from continental RADAR images. Part I: Description of the methodology." *Monthly Weather Review*, Vol. 130, Issue 12, pp. 2859-2873.
- Germann, U., and Zawadzki, I. (2004) "Scale-dependence of the predictability of precipitation from continental RADAR images. Part II: Probability forecasts." *Journal of Applied Meteorology*, Vol. 43, Issue 1, pp. 74-89.
- Jang, D.E. (2009). *Present Condition and Plan for Very Short-Term Precipitation Forecasting at KMA*. 10th RADAR Workshop, National Institute of Meteorological Research, Korea.
- 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.
- Jung, S.H. (2006). *Improvement of Radar Rainfall Intensity and Real-Time Estimation of Areal Rainfall*. MS. thesis, Kyongpook National University, Korea.
- Kim, B.K., Jang, D.W., Yang, D.M., and Yoo, C.S. (2009). "Accuracy Consideration of MAPLE Data Vary Short-Term Forecasting Model." *Water for Future, Korea Water Resources Association*, Korea, Vol. 42, No. 12, pp. 52-64.
- Kim, J.H. (2007). *The Development and Application of Algorithm for Real-Time Z-R Relationship by Precipitation Type*. Ph.D. dissertation, Pukyong National University, Korea.
- Kim, J.H. (2009a). *Comparative Analysis of Radar Image Rainfall and Point Rainfall*. MS. thesis, University of Suwon, Korea.
- Kim, J.H. (2011b). *Optimal Operation of Daechung Dam Using Adaptive Neuro-Fuzzy Inference System*. MS. thesis, Kyung Hee University, Korea.
- Kim, K.J. (2009b). *Improvement of the accuracy of radar rainfall measurement for hydrological application and the optimization of ground rain gage network*. Ph.D. dissertation, Korea University, Korea.
- Kim, K.P. (2011a). *Applicability of the Distributed Rainfall-Runoff Model in Nam-River Basin*. MS. thesis, GyeongSang National University, Korea.
- Ko, K.Y. (2010). *Study on Runoff Prediction using Artificial Neural Network*. MS. thesis, Kyungbuk University, Korea.
- Korea Meteorological Administration (2005). *Construction and Test-Operation of Korea Weather Research & Forecasting Model*.
- Lee, H.C. (2008). "Test Operation Implementation of Very Short-Term Forecasting Model." *News Letter, National Institute of Meteorological Research*, Korea, No. 49, p. 6.
- Lee, M.H. (2010a). *A Study of a Distributed Flood Runoff Model for Its Application*. Ph.D. dissertation, Ajou University, Korea.
- Lee, W.G. (2010b). *Estimation of Resonable Radar Grid*

- Size Using SWAT Model*. MS thesis, Yonsei University, Korea.
- Metcalf & Eddy Inc. Palo Alto (1971). *Storm water management model*. Vol. I-IV, U.S.EPA report.
- Meteorological Research Institute (2004). *Development of Regional Climate Change Scenario for the National Climate Change Report*. Korea Meteorological Association, Korea.
- Michael, L.T., and John, B.S. (1974) *The Illinois Urban Drainage Area Simulator*, ILLUDAS, Bulletin 58.
- National Institute of Meteorological Research (2000). Development of the numerical medium-long range forecast system.
- National Institute of Meteorological Research (2006). Study on improving the skill of precipitation forecast in a short-range.
- Park, K.N. (2009). *A Study on the Rainfall Estimation Using Radar Satellite Image in Ungaged Watershed*. MS. thesis, University of Suwon, Korea.
- Shin, G.W., Kim, J.H., Yang, J.R., and Hong, S.T. (2011). "Development of Water Demand Forecasting Simulator and Performance Evaluation." *Journal of Korean Society of Water and Wastewater, Korean Society of Water and Wastewater*, Korea, Vol. 25, No. 4, pp. 581-589.
- Srinivasan, R., and Arnold, J.G. (1994) "Integration of a Basin-Scale Water Quality Model with GIS." *Journal of the American Water Resources Association*, Vol. 30, Issue 3, pp. 453-462.
- Sun, J., and Crook, N.A. (1997) "Dynamical and micro-physical retrieval from Doppler RADAR observation using a clou model and its adjoint. Part I: Model development and simulated data experiments." *J. Atmos. Sci.*, Vol. 54, pp. 1642-1661.
- Sun, J., and Crook, N.A. (2001). "Real-time low-level wind and temperature analysis using single WSR-88D data." *Weather Forecasting*, Vol. 15, pp. 117-132.
- The Math Works, Inc. (2006). *Fuzzy Logic Toolbox User's Guide*. pp. 2-107~2-110.
- U.S. Army Corps of Engineers. (1968). *Hydrologic Engineering Methods for Water Resource Development*, Hydrologic Engineering Center, Davis, California.
- U.S. Army Corps of Engineers. (1974). *Urban storm-water runoff - STORM*. Computer Program 723-58 I2520, Hydrologic Engineering Center, Davis, California.
- U.S. Army Corps of Engineers. (1998). *HEC-RAS River Analysis System User's Manual*. Hydrologic Engineering Center, Davis, California.
- U.S. Army Corps of Engineers. (1999). *HEC-HMS User's Manual*.
- Vieux. (2001). Vflo. Vieux & Associates, Inc.
- Watkins, L.H. (1962). *The design of urban sewer systems*. Road Research Lab., Technical Paper 55, p. 96.
- Won, Y.S. (2007). *Development of Long Term Rainfall-Runoff Model of Combined Surface and Ground Water*. Ph.D. dissertation, Ajou University, Korea, p. 7.
- Yun, J.S. (2009). *The Correction of Mean-Field Bias and Estimation of its Application to Rainfall-Runoff Analysis*. MS. thesis, Korea University, Korea.
- Zadeh, R. (1965). "Fuzzy Set Theory." *Information and Control*, Vol. 8, pp. 338-353. Elsevier

논문번호: 13-035	접수: 2013.03.13
수정일자: 2013.06.03/06.17	심사완료: 2013.06.17