

저수지 제체 월류수위 예측을 위한 Fuzzy Time Series법의 적용성 비교 평가

Comparative Evaluation on Applicability of Fuzzy Time Series Method for Predicting Overtopping of Reservoir Embankment

윤성욱^a · 허 준^b · 유 찬^{c,†}
Yun, Sungwook · Huh, Joon · Yu, Chan

ABSTRACT

An increasing pattern of extreme rainfall recently affected the rural infrastructures with catastrophic damage, especially the overtopping of a fill dam embankment in the Republic of Korea. The overtopping was caused by the sudden increase in reservoir water level over the dam crest level, and it was not easy work to predict a priori because of its non-linear behavior. Fuzzy time series (FTS) is a fuzzy-logic inference procedure and is suited to apply to non-linear prediction methods such as machine learning. This study used the Wangshin reservoir and Goesan-dam cases, which experienced overtopping in 2023 and 2022, respectively. Wangshin Reservoir was a typical agricultural fill dam and needed to stack more available data, with only the daily storage rate (water level) of 7 years, starting on 2 May 2016. Therefore, we used Goesan-dam data to select appropriate variables and compare the analysis result, which was stacked with about 17 years of records. The analyses adapted LSTM to compare with FTS. As a result, the reservoir water level was applied to predict the overtopping water level, and it was shown that the FTS method could predict the actual water levels effectively according to the result of comparison with LSTM. Then, the FTS method was expected to predict reservoir water level a priori to make appropriate countermeasures on overtopping events as one of the alternatives.

Keywords: Fill dam; overtopping prediction; fuzzy-logic theory; fuzzy time series; machine learning; LSTM

1. 서론

최근 국내에서는 전국적으로 극한강우 발생이 빈번해지고, 그로 인한 댐 월류 피해들이 매년 발생하고 있다. 2022년 9월 6일 경상북도 경주 소재 왕신저수지, 2023년 8월 충청북도 괴산군 소재 괴산댐 그리고 2024년에는 충청남도 천안 법문 저수지 월류사고가 연속적으로 발생되고, 인명피해까지 발생되면서 저수지 월류의 위험성이 전 국민적 우려가 고조되고 있다 (Son, 2022; Choi, 2023). 그러나 월류문제는 전 세계적으로도 댐사고의 약 30%를 차지하는 주요 원인의 하나로 보고 있다 (ICOLD WRD, 2020).

우리나라는 전국적으로 17,000여 개소의 농업용 저수지들이 있고 (Choi, 2022). 그 대부분은 필댐형식으로 월류에 매우 취약한 구조적 단점을 가지고 있다 (ICOLD WRD, 2020; Yang et al., 2020; Bae et al., 2024). 따라서 월류 가능성을 사전에 예측하고 대책을 수립하는 방안 마련이 필요하다고 보고 최근에는 이에 대한 연구가 활발히 진행되고 있는 것으로 보인다. 그러나 정량적인 해석을 위해서는 관련 자료축적이 아직은 충분하지 않으며, 해석모델도 기존 ARIMA와 같은 통계적 기반의 예측모델들이 정상성 (stationarity)를 전제하기 때문에 사전에 월류 가능성을 예측하기에는 적합하지 않다 (Silva et al., 2018; Yang et al., 2020).

오히려 이론적으로는 최근 연구가 활발한 시스템 기반의 한 분류인 기계학습 (machine learning) 모델의 적용이 더 적합할 수 있다. 기계학습은 입력과 출력자료만으로 모델을 수립하여 결과를 예측하지만, 시계열 문제에서 물리기반 모델에 비교할 만한 수준의 정확도로 결과를 제공할 수 있는 것으로 알려져 있다 (Kim et al., 2011; Barrera-Animas et al., 2024; Chin and Lloyd, 2024).

실제로 Bae et al. (2024)은 저수지 수위예측을 위해 다양한 선형 및 비선형 모델들을 활용하기 위해서 TPOT (tree-based pipeline optimization tool) 기법을 강원도 오봉저수지에 적용하

^a Agricultural Researcher, Department of Agricultural Engineering, National Institute of Agricultural Sciences

^b Senior Researcher, Rural Research Institute, Korea Rural Community Corp.

^c Professor, Department of Agricultural and Biological Engineering (Inst. of Agri. & Life Sci.), Gyeongsang National University

† Corresponding author

Tel.: +82-55-772-1932, Fax: +82-55-772-1939

E-mail: chanyu@gnu.ac.kr

Received: June 07, 2024

Revised: July 16, 2024

Accepted: August 09, 2024

여 1~12시간 저수위를 높은 정도로 예측할 수 있다고 하였다. KOIS (2023)는 한국농어촌공사가 보유한 저수지 운영 데이터와 기상청의 기상관측·예보 데이터를 활용하여 인공지능 기반의 저수지 수위 예측모델을 2024년 말부터 전국 1,000여 개 저수지 관리에 활용할 예정이라고 밝힌 바 있다. 그 밖에도 Kim et al. (2015)은 저수지 월류에 따른 제방 안정성을 검토하기 위해 초기 변동수위를 고려하는 방안에 대해서 연구를 수행한 바 있다. Kratzert et al. (2019)은 LSTM모델을 적용하여 유역 유출특성과 방류량을 파악하기 위한 연구를 수행한 바 있다.

그러나 이상의 연구들에서는 저수위 변화가 비선형적이고, 강수량과 상류유역 특성 및 각종 유입량 그리고 저수위 조절 관행과 용수량 등 관련 변수들이 너무 많은데, 우리나라에서 농업용 저수지는 이수 측면에서 저수율 (Storage rate, %) 중심적으로만 관리되고 있어 다양한 자료의 취득과 활용이 극히 제한적인 문제점이 있으며, 현재 활용 가능한 자료의 기간도 상대적으로 짧은 아쉬움이 있다.

따라서 Song et al. (2022)은 이러한 문제점 때문에 저수위만으로 유입량과 방류량을 추정하여, 저수지 물수지 부정정 문제를 전문가 지식과 수문 모델링 기술을 활용하는 방안을 제시한 바 있으며, 본 연구도 이런 대안의 하나로써 퍼지논리 이론을 기반으로 한 FTS (fuzzy time series)의 적용을 고려해 보았다.

퍼지논리 (fuzzy logic) 이론은 1965년 L. A. Zadeh 교수 (Zadeh, 1965)에 의하여 소개된 수학 이론으로서 전통적인 집합 (crisp set)을 확장하여 퍼지집합 (fuzzy set) 간 서로 중복 (교집합)을 허용하고 그 소속 정도를 멤버십 함수 (membership function, MF)를 활용해서 [0, 1] 사이 값으로 정의하는 특징이 있다. 여기서 '1'은 원소가 퍼지집합에 완전하게 포함, '0'은 포함되지 않는다는 의미이다. 기존의 집합이론에서는 '0' 혹은 '1'만 인정하였다 (Bárdossy and Fodor, 2004; Zimmermann, 2010; Islam et al., 2017).

즉, 퍼지집합은 특정 원소의 포함 여부의 모호성 (vagueness)을 MF를 이용하여 그 정도 (degree)로 반영해 줄 수 있으며, 여기서 주관적 적용도 가능 하기 때문에 자료부족이나 부정확한 자료에 의존해 결정해야 하는 경우에 적용성이 높다. FTS 방법은 이런 특성을 시계열 자료에 반영하여 특히 이상 저수위를 예측해야 하는 경우에 효과적으로 적용될 수 있는 장점이 있다 (Kecman, 2001; Shang and Hossen, 2013). 최근에 Yang et al. (2020)은 해빙에 인한 비정상적인 저수위 상승이 발생한 사례의 원인 구명을 위해 이 방법을 적용한 사례도 있다.

따라서 본 연구에서도 이상 강우에 의한 저수위 상승으로 저수지 제체 월류 위험성 예측을 위한 대안의 하나로써 FTS 적용 가능성을 분석하여 그 결과를 정리하였다. 연구에서는

최근의 월류발생 사례가 있는 제체의 자료들을 수집하여 분석을 실시하였으며, 동일한 자료를 대상으로 기계학습 (LSTM)에 대한 해석도 실시하여 그 결과를 함께 비교/검토하였다.

II. 자료와 해석법

1. 대상자료

본 연구에서는 최근 월류발생 사례를 대상으로 왕신저수지와 괴산댐 자료를 사용하였다. 왕신저수지는 농업용으로 경상북도 경주시 소재로 1975년에 준공된 중심 코아형 필댐이다. 2022년 9월 6일 오전 5시에서 8시 사이에 월류가 발생된 것으로 예측되었으며 (KRC, 2022), 하류비탈면 침식발생으로 하류지역 주민에 대해 대피령이 발령되었으나, 다행히 인명피해 보고는 없었다. 왕신저수지 관리자료는 시 단위 자료 기준으로 2016년 5월 2일부터 최근까지 한국농어촌공사 (RAWRIS)의 협조를 받아서 취득하였다. 그러나 저수위 및 저수율 관련 자료만 따라서 저수지 자체의 유입량 및 유출량, 용수사용량 등의 다른 관련 자료들은 취득이 불가하였다.

괴산댐은 충청북도 괴산군에 소재한 발전용 콘크리트 중력식 댐으로 1959년에 준공되었으며, 홍수조절 기능은 없다. 괴산댐은 농업용댐은 아니지만 2023년 7월 15일 오전 6시에서 8시 사이에 월류되어 침수피해가 발생되었으며, 괴산댐의 경우에는 시 단위 자료로 2007년 1월 1일부터 최근까지의 저수위, 저수량 (울), 유입량, 방류량, 용수량 그리고 인근 강우량 등의 자료를 활용할 수 있었다 (WAMIS). 그러나 본 연구에서는 괴산댐 자료 중 저수위만 사용하였다. 두 댐의 세부 정보는 Fig. 1과 Table 1, 변수들에 대한 기본 통계분석 결과는 Table 2에 정리하였다 (WAMIS; Jeong, 2020; KRC, 2022).

분석에서 괴산댐 저수위 자료는 다음 Fig. 2와 같이 2007년 9월 1일부터 2023년 1월 31일까지를 학습자료 (train set) 그리고 검증자료 (test set)는 2023년 2월 1일에서 12월 3일까지의 자료를 사용하였다. 왕신저수지의 저수위 자료는 Fig. 3과 같이 학습자료 (train set)는 2016년 5월 2일~ 2022년 6월 30일 그리고 검증자료 (test set)는 2022년 7월 1일~12월 3일까지 나누어 분석에 사용하였다.

2. 해석모델

가. 퍼지시계열 (FTS) 해석법

FTS (fuzzy time series) 해석법은 자료가 주관적 혹은 불확실성이 큰 경우에 비선형 시계열 모델 수립을 위해 Song and Chissom이 제안한 해석법이다 (Song and Chissom, 1993a,



Fig. 1 Site map

Table 1 Specification of dams (WAMIS)

Site	Goesan	Wangshin
Location	Goesan, Chungbuk	Kyeongju, Gyeongbuk
Dam type	Concrete gravity	Earth fill
Dam height (m)	28	19
Dam crest elevation (EL-m)	137.65	59.2 (58.8)*
Watershed area (km ²)	671.0	22
Total reserver capacity (mm ³)	1,500	1.8
Completion	1957. 2	1965

* Field investigation measurement

Table 2 Statistical analysis results

Item	Goesan	Wangshin
	Water level (EL-m)	Water level (EL-m)
Count	142,997	63,793
Mean	133.04	54.55
Standard deviation	6.92	1.72
Minimum	0.00	28.08
25%-Q *	132.63	52.84
50%-Q	133.45	55.02
75%-Q	134.27	56.13
Maximum	138.14	62.09

* quantile

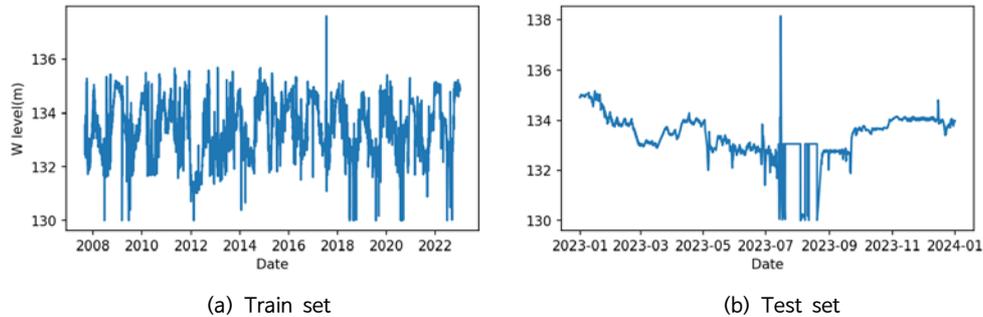


Fig. 2 Train and test data set of Goesan-dam

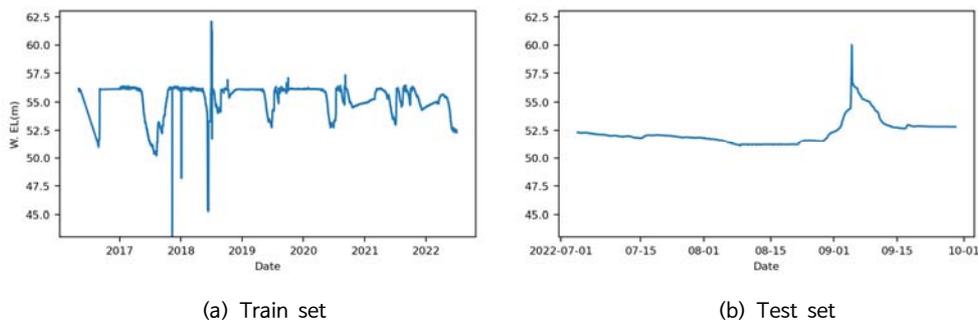


Fig. 3 Train and test data set of Wangshin-dam

1993b, 1994; Chen, 1996; Chen and Hwang, 2000; Yu, 2005).

예측과정을 요약하면 다음과 같다. 임의의 시간 t 에서 결과 $F(t)$ 가 시간 $(t-1)$ 에서 관측값 $F(t-1)$ 에 기인한다면, 이때 퍼지 집합에서 시간 t 와 $(t-1)$ 사이 그리고 그 관계, R 은 다음 식과 같이 나타낼 수 있다.

$$F(t) = F(t-1) \circ R(t-1, t) \tag{1}$$

여기서, $F(t)$ = fuzzy time series, t =시간, R =퍼지논리관계 (fuzzy-logic relationship)이다. 이때 퍼지논리관계의 요소들을 정리하여 그룹 (FLRG)화하면 해석모델이 된다. 이 자세한 방법을 단계별로 설명하면 다음과 같다.

- 1단계: 자료값의 UoD (universe of discourse)를 정의하고 이를 등 간격으로 분할 (partition), 시계열 값들로 정의된 UoD를 우선 n 개의 등 간격으로 분할. Fig. 4에 괴산과 왕신 자료를 삼각형 MF를 적용하여 100개의 등간격으로 분할한 상황 표시, 양쪽 끝단은 20~30%정도의 여유구간을 설정
- 2단계: UoD에서 퍼지집합 정의, 관측 값들을 분할된 영역에 속한 집합으로 정의
- 3단계: 집합의 퍼지화 (fuzzification), 각 집합에 소속된 값들을 삼각형 MF를 적용해 퍼지화.
- 4단계: 퍼지논리관계 (FLR) 작성, 퍼지화된 관측값 사이의 퍼지논리관계 (FLR)를 구별 (예, ‘A46 → A46’, ‘A46 → A47’, ..., ‘A39 → A42’).
- 5단계: 퍼지논리관계그룹 (FLRG) 식별, 중복되는 FLR을 정리하고 그룹 (FLRG)을 식별. Fig. 3 괴산댐 학습자료에

서 저수위 EL-0~EL-137 m Uod를 100개의 등간격으로 나누어 퍼지집합으로 정의하여 퍼지논리관계 (FLR)를 확인 한 후, 이들 중 중복 요소들을 정리하여 Table 3과 같이 퍼지논리관계그룹 (FLRG) 모델을 수립.

Table 4는 Fig. 4 왕신저수지 학습자료 저수위 EL-0~EL-62 m에 대해서 같은 방식으로 퍼지논리관계그룹 (FLRG) 모델을 수립.

Table 3 Rule generation of Goesan

Fuzzy logic relation group:	
A41	→ A39,A40,A41,A42,A43,A44,A45
A39	→ A38,A39,A40,A41,A44,A46,A47
A38	→ A38,A39,A40,A41,A44,A47,A49
A44	→ A38,A40,A41,A42,A43,A44,A45,A46,A47
A42	→ A40,A41,A42,A43,A44,A45,A46
A40	→ A38,A39,A40,A41,A42,A44,A47,A49,A52
A43	→ A38,A41,A42,A43,A44,A45,A47,A48,A51
A45	→ A38,A40,A42,A43,A44,A45,A46,A47, A48,A53
A46	→ A41,A42,A44,A45,A46,A47,A48,A49,A50
A47	→ A38,A40,A43,A44,A45,A46,A47,A48,A49, A50,A51,A53,A54
A49	→ A39,A46,A47,A48,A49,A50,A51
A48	→ A40,A45,A46,A47,A48,A49,A50,A51,A52
A52	→ A43,A44,A50,A51,A52,A53
A51	→ A43,A47,A48,A50,A51,A52,A53
A50	→ A47,A48,A49,A50,A51,A52,A53
A54	→ A46,A47,A53,A54,A55
A53	→ A51,A52,A53,A54
A55	→ A51,A57
A58	→ A55
A57	→ A57,A59
A60	→ A58,A60
A59	→ A60

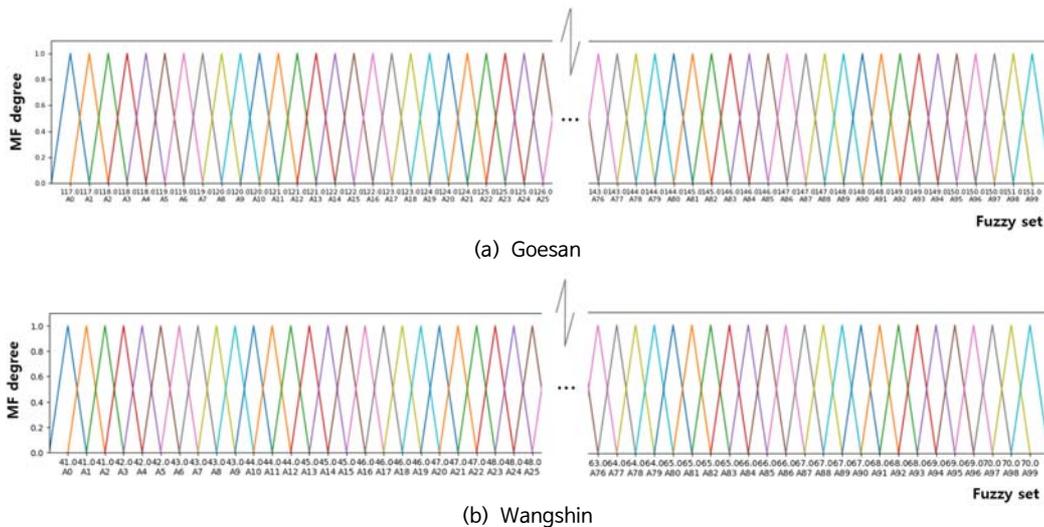


Fig. 4 Partitioning of water level data of Goesan-dam

Table 4 Rule generation of Wangshin

Fuzzy logic relation group:
A16 → A15,A16
A17 → A16
A21 → A17,A22
A23 → A21,A22
A22 → A21,A24
A24 → A23,A24
A25 → A23,A25
A27 → A25,A26
A26 → A26,A27
A28 → A26,A28
A29 → A28
A15 → A15,A42
A30 → A29,A30
A31 → A30
A32 → A31,A32,A33
A33 → A32,A33,A34
A34 → A32,A33,A34,A35
A35 → A34,A35,A36
A36 → A34,A35,A36,A37
A37 → A36,A37,A38
A38 → A37,A38,A39
A39 → A38,A39,A40
A40 → A39,A40,A41
A41 → A40,A41,A42
A69 → A42
A72 → A42
A76 → A42
A43 → A42,A43,A44
A44 → A43,A44,A45
A45 → A44,A45,A46
A46 → A45,A46,A47
A47 → A46,A47,A48
A52 → A37,A51,A52,A53
A48 → A47,A48,A49,A51
A49 → A48,A49,A50,A51
A50 → A49,A50,A51
A51 → A50,A51,A52,A53
A53 → A52,A53,A54
A54 → A53,A54,A55,A56
A55 → A54,A55
A56 → A55,A56
A42 → A40,A41,A42,A43,A44,A52,A69,A71,A73,A76,A78
A78 → A42,A78
A71 → A42,A71,A72
A73 → A42,A72,A73

6단계: 예측결과의 비퍼지화 (defuzzification), 최종적으로는 예측결과를 비퍼지화 하여 출력.

6단계에서는 보통 집량중심법 (the center-of-mass method) 으로 그 평균값을 구하기 때문에 예측값 범위가 정상성을 고려한 모델보다는 더 넓게 설정될 수 있어 특이 극한값의 예측도 가능한 것으로 보인다. Chen (1996)의 연구에서는 행렬계산을 제거하여 단순화함으로써 Song and Chissom (1993a) 모

델보다 퍼지관계 (fuzzy relationship) 결정시간을 크게 단축시켜 계산시간을 현저하게 줄일 수 있었다.

1단계의 UoD 간격을 나누는 경우에 자료특성을 반영할 수 있는 다양한 분할방법에 대한 연구가 최근에 많이 이루어지고 있는데, 본 연구에서 확인한 결과 등간격으로 나누는 방식도 결과에 큰 차이가 없어 그대로 적용하였으며, 이상의 연산 과정을 Google Colab®에서 pyFTS 라이브러리와 공개 코드를 수정 사용하여 실행하였다 (Silva et al., 2018).

나. LSTM 모델

FTS 해석법과 비교를 위해 기계학습 모델 중 LSTM (Long Short-Term Memory Network) 모델을 분석에 포함시켰다 (Keith, 2022). 최근 기계학습 분야에서는 다양한 모델을 조합 (combination 혹은 ensemble)하여 해석하는 방식이 많이 사용되지만, 본 논문에서는 지면의 한계로 LSTM 모델 하나만을 채택하여 대표 모델로 비교하였다. LSTM은 RNN (Recurrent neural network)의 한 알고리즘으로서 Hochreiter and Schmidhuber (1997)에 의해서 소개되어 언어, 음성인식, 시계열 해석 등 다양한 분야에서 사용되고 있다. LSTM은 과거의 사건이 미래에 영향을 주는 장기기억특성을 나타낼 때 직전 자료뿐만 아니라, 좀 더 과거 자료를 고려하여 미래 값을 예측할 수 있는 모델이며, RNN과 구조적으로 유사하지만, 반복 모듈에서 단순히 한 층 (layer) 대신에, 4개의 층들이 서로 정보를 주고받도록 하여 장기간 의존성 (long-term dependency) 문제를 개선한 모델이다 (Park et al., 2021). LSTM은 PyTorch (version 3.0) 기반의 Hogg (2023)의 공개코드를 수정하여 해석을 수행하였으며, 시행방법 등에 따라 다를 수도 있지만 FTS 해석법과 비교에 적당한 좋은 결과를 얻을 수 있었다.

III. 분석결과 및 고찰

1. FTS모델을 이용한 분석

가. 괴산댐 분석결과

괴산댐의 자료 영역을 100개의 등간격으로 분할하여 Table 3처럼 FLRG를 작성하였으나, 저수위는 주로 A38~A60 집합에 소속해 있었으며, A60 집합은 구간 ([137.27, 137.96])으로 댐마루 표고를 포함하는 집합으로서 이 집합에서 시간 경과에 따라서 관계있는 집합은 A58과 A60이라는 사실을 알 수 있으며, A60 집합은 A59 집합과도 관계가 있다.

Fig. 5는 FLRG를 도식화 한 것인데, 각 그룹에서 집합의 범위와 그룹 간 관계를 시각적으로 확인할 수 있었으며, 관계 그룹이 매우 간략하게 구성되어 있는 것으로 보이는데, 이는

괴산댐의 저수위에서 인위적인 저하를 제거 (저수위 EL-130 m 이하의 경우)하면 변동 범위가 10 m 이내로 좁아져서 변동이 크지 않기 때문인 것으로 판단되었다.

Fig. 6은 앞서 설명한 FLRG 모델로 예측한 결과를 다시 비퍼지화 하여 검증 (test)자료와 비교한 것이다. 그림에 나타난 바와 같이 댐마루 높이 (EL-137.65 m)보다는 0.09 m 낮은 EL-137.56 m로 예측되었으나, 큰 차이는 아닌 것으로 판단하였으며, 이는 설계홍수위 (design flood level, D.F.L., EL-137.65 m) 보다 높은 예측된 결과이어서 실제 현장 적용성이 높은 것으로 판단되었다. 다만 전체 시계열 예측의 정확성은 높지 않은 것으로 나타났다.

나. 왕신저수지 분석결과

왕신저수지의 저수위 자료 영역을 100개의 등간격으로 분할하여 Table 4처럼 FLRG를 작성하였는데, 왕신저수지 저수위는 A16~A78집합에 소속되어 괴산댐의 경우에 비해서 소속집합 그룹의 범위가 넓게 퍼져 있었으며, 따라서 집합들 사이의 관계가 다소 복잡할 것으로 되었다. FLRG에서 A78 집합은 구간 (63.62, 64.21)에 해당하는데, 댐마루 표고 EL-59.20 m보다는 많이 높게 나타났으며, 이는 왕신저수위 실제 최대

월류 수위가 높았다는 사실을 말해 주는 것이다. A78 집합은 시간 경과에 따라서 A42에서 시작하여 A40, A41, A42, A43, A44, A52, A69, A71, A73, A76, A78로 상대적으로 긴 관계 그룹을 형성하면서 저수위 상승이 진행되었다는 사실을 알 수 있으며, 또 A62 집합이 구간 (58.87, 59.46)으로 월류가 시작되는 구간인데, 따라서 월류가 발생하는 집합들 A62~A78 중에서는 A69, A71, A73, A76, A78 집합만 이 그룹에서 포함되어 있어 관련 집합들만의 그룹을 모델로 사용하는 해석과정을 확인할 수 있었다.

Fig. 7은 FLRG를 도식화 한 것인데, 괴산댐과 마찬가지로 그룹에서 집합의 범위와 그룹 간 관계를 시각적으로 확인할 수 있다. 그러나 왕신저수지는 저수위 변동이 괴산댐의 2배 정도인 20 m로 변동 폭이 커진 만큼 그림으로도 복잡하게 나타난 것으로 판단되었다.

Fig. 8은 수립된 분석모델로 예측한 결과를 검증자료와 비교한 것이다. 댐마루 높이 (EL-59.20 m)보다는 0.22 m 높게 EL-60.12 m로 예측되어 월류가능성의 결과를 보여주었다. 이는 사고발생 당일 추정되는 1시간 단위의 최고수위 EL. 60.01 m, 10분 단위 최고수위 EL. 60.28 m과 비교해도 큰 차이가 없는 매우 좋은 결과라고 판단되었다 (KSAE, 2022).

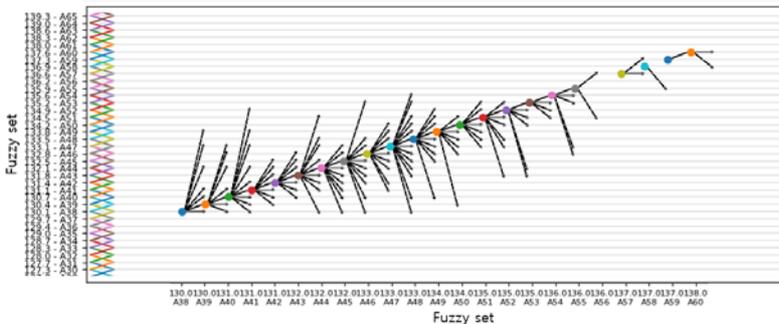


Fig. 5 Fuzzy-logic relation diagram (Goesan)

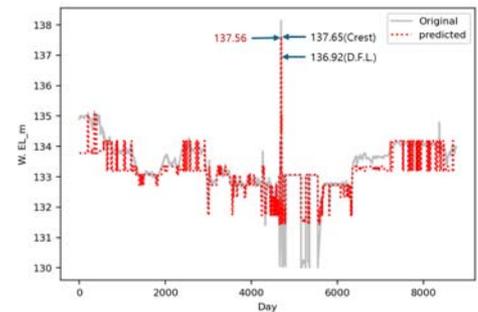


Fig. 6 FTS Prediction results of Goesan-dam

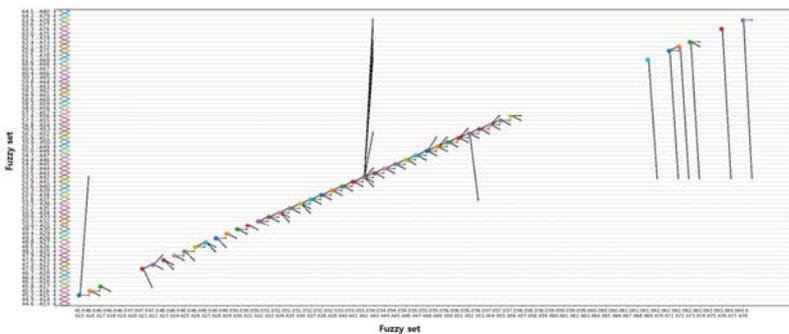


Fig. 7 Fuzzy-logic relation diagram (Wangshin)

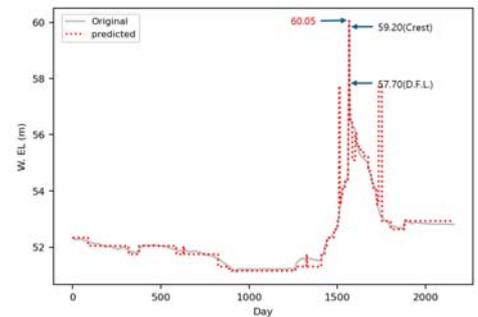


Fig. 8 FTS prediction results on Wangshin

2. LSTM 모델을 이용한 분석

Fig. 9는 LSTM 모델로 분석한 괴산댐과 왕신저수지의 저수위 예측결과이다. 학습자료와 검증자료 모두 FTS해석 시와 동일하게 적용하였다. 해석에서는 다양한 인자들을 반복적인 적용해 시행오차 (trial & error) 방식으로 해석을 실시하였으며, 최종적으로 월류수위 예측을 위해 적용된 인자들은 batch size=16, hidden layre=4, stacked layer=1. learning rate=0.01, epoch=100이었다.

Fig 9(a)는 괴산댐 예측한 결과를 검증자료와 비교한 것이다. 예측결과는 댐마루 (crest) 높이 (EL-137.65 m)보다 0.35 m 높은 EL-138.00 m로서, 실제 월류발생 현장자료에서 추정되는 월류수위 EL-138.14 m와 유사한 결과를 보여주었다. Fig 9(b) 왕신저수지의 경우에는 EL-58.97 m로 예측되어 댐마루 높이 EL-59.20 m보다는 0.23 m 낮았으며, 앞서 살펴보았던 1시간 단위의 최고수위 EL-60.01 m과는 1.04 m 차이가 있었다. 그 주요 원인 중 하나는 왕신저수지 학습자료가 2016년 5월~2022년 6월 (약 6년 1개월)로 상대적으로 짧아 학습이 부족했기 때문이라고 추측되었다.

이상의 결과를 정리하면 Table 5와 같았다. 표에서 괴산댐은 LSTM 분석결과가 조금 좋았고, 왕신저수지 분석에서는 FTS가 더 좋은 결과를 보였다. 그러나 두 해석법의 예측결과 정확성 차이는 크지 않았고, 두 해석법 모두 설계홍수위 (D.F.L; designed flood level)보다는 높은 결과를 제시하였다.

다만 해석 시간에서는 차이가 컸는데, LSTM 해석법에서는 앞서 언급한 바와 같이 예측의 정확도를 높이려면 각종 인자들을 조종하면서 반복시행을 통한 정확도를 개선하는 작업이 필요한데, 왕신저수지보다 자료 갯수가 2배 이상 많은 괴산댐의 경우에는 최소 1~2시간 혹은 그 이상의 시간이 소요된 반면 (PyTorch의 경우, 다른 라이브러리는 훨씬 더 많은 시간이 소요), FTS는 대부분 10분 이내에 계산이 완료되어 결과를 확인할 수 있었다. 계산시간은 작업효율을 높이는 중요한 요소이다. 따라서 FTS는 짧은 계산시간으로 모델링 작업의 효율을 제고할 수 있는 장점이 있는 것으로 기대된다.

3. 선행사건 (antecedent event)의 영향 검토

괴산댐 자료 중에는 2023년 이전인 2017년 7월 15일에도 저수위 급상승 사례가 이미 한차례 기록되어 있었다 (Fig. 2(a) 참조). 따라서 2023년 월류발생 분석결과가 2017년 선행사건의 학습에 의한 영향 여부를 살펴보기 위하여 괴산댐 자료를 2007년 9월 1일에서 2017년 5월 31일까지를 학습시켜 2017년 6월 1일에서 8월 31일까지의 저수위 변화를 다시 FTS 및 LSTM 모델을 이용하여 예측해 보았다.

그 결과를 Fig. 10에 나타내었는데, FTS는 저수위 EL-137.6 m 상승을 정확히 예측하였으며, LSTM 해석 결과는 이보다는 약간 낮은 EL-137.61 m로 예측되었다. 그러나 두 해석법 모두 우수한 결과를 보여주었으며, 실제 선행사례가 없는 경우에

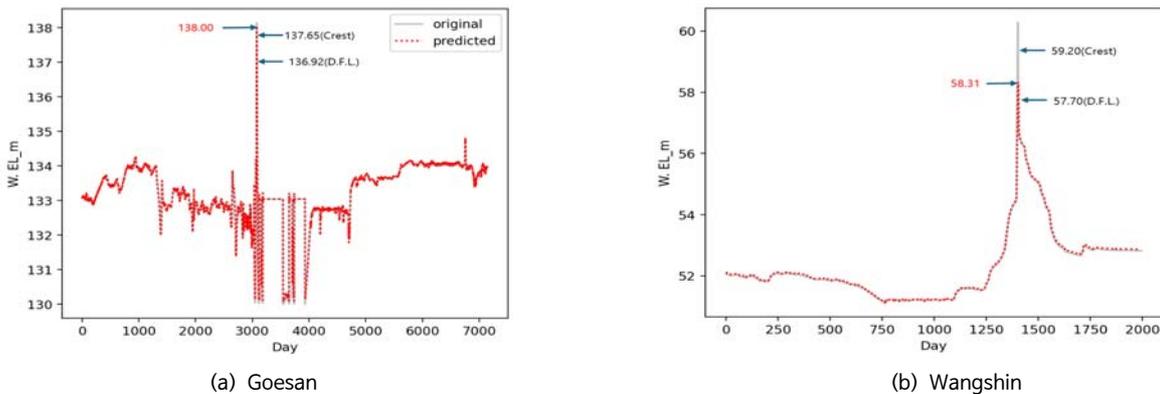


Fig. 9 LSTM prediction results

Table 5 Summary of prediction results

Item	Prediction Goesan (m)	Prediction to actual (%)	Prediction Wangshin (m)	Prediction to actual (%)
Crest level	137.65	-	59.20	-
Actual water level	138.14	-	60.01	-
FTS	137.56	99.67	60.12	100.1
LSTM	138.00	99.99	58.97	98.27

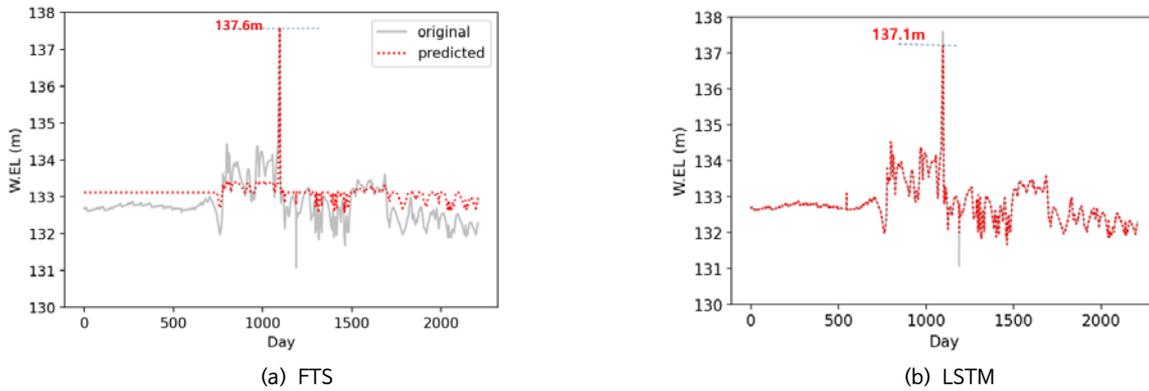


Fig. 10 Comparison of antecedent event at Goesan on July 15, 2017

도 적용성이 높을 것으로 기대되었다.

다만 왕신저수지 저수위에서도 Fig. 3(a)에서 2018년에 급상승 사례가 확인되지만 관측 자료가 너무 부족해 해석을 수행하지는 않았다.

IV. 결론

본 연구에서는 최근의 이상 강우로 인한 농업용 저수지 월류 사고를 사전에 대비하기 위한 대안의 하나로써 퍼지논리 이론을 활용한 FTS 해석법의 적용성을 평가하여 그 결과를 제시하였다. 기존 월류발생 사례 자료를 적용하였으며, FTS 외에 기계학습 모델 중 LSTM 모델에 대한 해석을 수행하여 그 결과를 함께 비교하여 다음과 같은 결과를 얻었다.

1. 다양한 변수를 제공하는 괴산댐이나, 농업용 저수지로 가용한 자료가 저수율뿐인 왕신저수지 모두 자료특성이 정상성을 나타내고 변동성도 크지 않아 기존 모델들로 월류 수위를 사전에 예측하기 쉽지 않을 것으로 판단되었다.
2. FTS 해석법을 괴산댐과 왕신저수위 자료에 적용한 결과, 괴산댐에서는 2023년 월류수위 보다는 0.09 m 낮게 그리고 2022년 왕신저수지 월류수위 보다는 0.22 m 높은 해석결과를 예측하였으며, 두 경우 모두 설계홍수위 보다는 높은 저수위를 예측하였다.
3. LSTM 해석결과와 비교한 결과, 괴산댐에서는 FTS보다 좋은 결과를 나타냈지만 왕신저수지는 FTS 예측값이 실제와 더 가깝게 나타났다. 그러나 어느 해석법이 우수하다고 판단하기는 그 차이가 작았고 두 해석법 서로 보완적으로 사용한다면 관련 분야에서 효율적인 활용이 가능할 것으로 기대된다.

4. 퍼지논리 추론방식을 적용한 FTS 해석법의 계산시간은 상대적으로 짧았으며, 시스템 기반의 해석법으로서 분석자료 준비도 간단하기 때문에 효율적인 작업 수행의 장점도 있을 것으로 판단되었다. 그리고 기존에 수위 급상승 사례가 없는 경우에도 적용성이 높을 것으로 기대되었다.

감사의 글

본 연구는 한국연구재단의 재원으로 학문균형발전사업 지역대학우수과학자지원사업의 지원을 받아 연구되었음 (과제 번호: 2019R111A3A01041192).

REFERENCES

1. Bae, J. H., W. J. Park, S. Lee, T. S. Park, S. B. Park, J. Kim, and K. J. Lim, 2024. A study on time series cross-validation techniques for enhancing the accuracy of reservoir water level prediction using automated machine learning TPOT. *Journal of Korean Society of Agricultural Engineering* 66(1): 1-13. (in Korean).
2. Bárdossy, G., and J. Fodor, 2004. Evaluation of uncertainties and risks in geology: New mathematical approaches for their handling. Springer.
3. Barrera-Animas, A. Y., L. O. Oyedele, M. Bilal, T. D. Akinosho, J. M. D. Delgado, and L. A. Akanbi, 2024. Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting. *Machine Learning with Applications* 7: 100204.
4. Chen, S. M., 1996. Forecasting enrollments based on

- fuzzy time series. *Fuzzy Sets and Systems* 81: 311-319.
5. Chen, S. M., and J. R. Hwang, 2000. Temperature prediction using fuzzy time series. *Systems, Management and Cybernetics* 30: 263-275.
 6. Chin, S. H., and V. Lloyd, 2024. Predicting climate change using an autoregression long short-term memory model. *Frontiers in Environmental Science* 12: 1301343.
 7. Choi, I. M., 2022. [Topic Presentation] A study on the capacity enhancement of flood damage: Measures to strengthen the safety of agricultural reservoirs in response to extreme floods. *Proceeding of a Parliamentary Debate*. (in Korean).
 8. Choi, M. K., 2023. Overflow at Goesan Dam... residents in low-lying areas are ordered to evacuate early in the morning. *YTN Newspaper*, Accessed on 1 March 2023 from <https://v.daum.net/v/20230715074501429>. (in Korean).
 9. Kratzert, F., M. Herrnegger, D. Klotz, S. Hochreiter, and G. Klambauer, 2019. NeuralHydrology-interpreting LSTMs in hydrology. In *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*, Samek, W., G. Montavon, A. Vedaldi, L. K. Hansen, and K. R. Müller eds., Springer International Publishing, 17p.
 10. Google Colab®, version 3.10.12, <https://colab.research.google.com/>.
 11. Hochreiter, S., and J. Schmidhuber, 1997. Long short-term memory. *Neural Computation* 9(8): 1735-1780.
 12. Hogg, G., 2023. Amazon stock forecasting in PyTorch with LSTM neural network (time series forecasting). *Google Colab*, Accessed on 1 March 2023 from https://colab.research.google.com/drive/1CBIdPxHn_W2ARx4VozRLIptBrXk7ZBoM?usp=sharing.
 13. ICOLD WRD (International Commission on Large Dams World Register of Dams), 2020. World register of dams: General synthesis, Accessed on 1 October 2020 from https://www.icold-cigb.org/GB/world_register/general_synthesis.asp.
 14. Islam, M. S., M. P. Nepal, M. Skitmore, and M. Attarzadeh, 2017. Current research trends and application areas of fuzzy and hybrid methods to the risk assessment of construction projects. *Advanced Engineering Informatics* 33: 112-131.
 15. Jeong, C. S., 2020. A study on the development of a dam operation table using the rainfall matrix. *Journal of Korean Society for Disaster Security* 13(2): 39-51. (in Korean).
 16. Kecman, V., 2001. *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models (Complex Adaptive Systems)*. A Bradford Book.
 17. Keith, M., 2022. Forecast with ARIMA in Python more easily with Scalecast. *Towards Data Science*, Accessed on 1 March 2024 from <https://towardsdatascience.com/forecast-with-arma-in-python-more-easily-with-scalecast-35125fc7dc2e>.
 18. Kim, H. J., G. H. Chung, D. H. Lee, and E. T. Lee, 2011. Application of adaptive network-based fuzzy inference system (ANFIS) for modeling the hourly runoff in the Gapcheon watershed. *KSCE Journal of Civil Engineering* 31(5B): 405-414. (in Korean).
 19. Kim, J. Y., T. H. Kim, Y. S. Kim, and J. H. Kim, 2015. Stability analysis of embankment overtopping by initial fluctuating water level. *Journal of Korean Geotechnical Society* 31(8): 51-62. (in Korean).
 20. KOIS (Korea Ministry of the Interior and Safety), 2023. Accessed on 15 May 2024 from <https://www.korea.kr/news/customizedNewsView.do?newsId=148919556>. (in Korean).
 21. KRC, 2022. Report on the overtopping accident cause analysis on Wangshin reservoir. Report. (in Korean).
 22. Park, G. M., S. R. Oh, G. H. Park, and Y. C. Bae, 2021. Groundwater level prediction using ANFIS algorithm. *Journal of the KIECS* 16(6): 1239-1248.
 23. PyTorch, Copyright © 2024 The Linux Foundation®, Accessed on 1 January 2024.
 24. RAWRIS, <https://rawris.ekr.or.kr/main.do>, Accessed on 25 May 2024. (in Korean).
 25. Shang, K., and Z. Hossen, 2013. Applying fuzzy logic to risk assessment and decision-making. CAS/CIA/SOA Joint Risk Management Section.
 26. Silva, P. C. L., C. A. Severiano Jr., M. A. Alves, R. C. P. Silva, G. L. Vieira, P. de Oliveira e Lucas, H. J. Sadaei, and F. G. Guimarães, 2018. pyFTS: fuzzy time series for Python. Belo Horizonte. doi: 10.5281/zenodo.597359.
 27. Son, D. S., 2022. [Typhoon Hinnamno] the risk of collapse of Wangshin reservoir in Gangdong, Gyeongju... Resident evacuation order. *Yeonhap News*, Accessed on 1 March 2023 from <https://v.daum.net/v/20220906084051074>. (in Korean).
 28. Song, J. H., Y. Her, and M. S. Kang, 2022. Estimating reservoir inflow and outflow from water level observations using expert knowledge: Dealing with an

- ill-posed water balance equation in reservoir management. *Water Resources Research* 58: e2020WR028183. doi: 10.1029/2020WR028183. (in Korean).
29. Song, Q., and B. S. Chissom, 1993a. Fuzzy time series and its model. *Fuzzy Sets and Systems* 54(3): 269-277. DOI: 10.1016/0165-0114(93)90372-O.
30. Song, Q., and B. S. Chissom, 1993b. Forecasting enrollments with fuzzy time series - part I. *Fuzzy Sets and Systems* 54: 1-9.
31. Song, Q., and B. S. Chissom, 1994. Forecasting enrollments with fuzzy time series - part II. *Fuzzy Sets and Systems* 62: 1-8.
32. WAMIS, http://www.wamis.go.kr/wkd/mn_dammain.do, Accessed on 15 May 2024. (in Korean).
33. Yang, K., F. Chen, C. He, Z. Zhang, and A. Long, 2020. Fuzzy risk analysis of dam overtopping from snowmelt floods in the nonstationarity case of the Manas River catchment, China. *Natural Hazards* 104: 27-49.
34. Yu, H. K., 2005. Weighted fuzzy time series models for TAIEX forecasting. *Physica A* 349: 609-624.
35. Zadeh, L. A., 1965. Fuzzy sets. *Information and Control* 8(3): 338-353.
36. Zimmermann, H. J., 2010. Fuzzy set theory. *Advanced Review* 2: 317-332.