

경험적 모드분해법을 이용한 시계열 모형의 예측력 개선에 관한 연구

A Study on the Predictive Power Improvement of Time Series Model with Empirical Mode Decomposition Method

김 태 립* / 신 흥 준** / 남 우 성*** / 허 준 행****

Kim, Taereem / Shin, Hongjoon / Nam, Woosung / Heo, Jun-Haeng

Abstract

The analysis of hydrologic time series data is crucial for the effective management of water resources. Therefore, it has been widely used for the long-term forecasting of hydrologic variables. In tradition, time series analysis has been used to predict a time series without considering exogenous variables. However, many studies using decomposition have been widely carried out with the assumption that one data series could be mixed with several frequent factors. In this study, the empirical mode decomposition method was performed for decomposing a hydrologic time series data into several components, and each component was applied to the time series models, autoregressive moving average (ARMA). After constructing the time series models, the forecasting values are added to compare the results with traditional time series model. Finally, the forecasted estimates from ARMA model with empirical mode decomposition method showed better performance than sole traditional ARMA model indicated from comparing the root mean square errors of the two methods.

Keywords : empirical mode decomposition, intrinsic mode function, sifting algorithm, time series analysis, autoregressive moving average (ARMA) model, dam inflow forecasting

요 지

수문 시계열의 분석은 수문자료를 활용한 수자원의 효율적인 운영 및 관리에 필수적인 부분이며, 특히 장기적인 수문량 예측에 널리 활용되고 있다. 이러한 수문 시계열 분석은 전통적으로 하나의 자료계열을 하나의 요인으로 파악하여 자료를 분석하고 예측해왔지만 시계열 자료가 여러 가지 요인으로 혼합되어 하나의 자료계열로 나타내질 수 있다는 가정 하에 각 요인들을 분해하여 분석하는 방법도 널리 연구되고 있다. 본 연구에서는 경험적 모드분해법을 이용하여 주어진 수문 시계열을 다중 성분으로 분해하고 분해된 각 요소를 시계열 모형으로 재구축한 후, 구축된 요소별 시계열 모형으로부터 예측된 값을 합하여 시계열을 예측하는 방법을 이용하였으며 이를 국내 댐 유입량에 적용한 후 그 결과를 나타내었다. 기존 시계열 모형과 경험적 모드분해법을 이용한 방법의 정확도를 비교한 결과, 기존의 시계열 모형을 이용하여 자료를 예측한 결과보다 경험적 모드분해법을 적용하여 자료를 분해한 후 시계열 자료를 예측한 결과가 주어진 시계열 자료를 더 잘 나타내는 것을 알 수 있었다.

핵심용어 : 경험적 모드분해법, 내재모드함수, 체거름 알고리즘, 시계열 분석, 자기회귀이동평균모형, 댐 유입량 예측

* 연세대학교 대학원 토목공학과 통합과정 (e-mail: taereem@yonsei.ac.kr)

Ph.D. Candidate, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea.

** 연세대학교 대학원 토목공학과 박사후과정 (e-mail: sinong@yonsei.ac.kr)

Post-Doctoral Fellow, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea.

*** 수문기상협력센터 연구원 (e-mail: wsnam77@gmail.com)

Researcher, K-water Seoul Metropolitan Regional Division (2F), 11 Gyooyokwon-ro, Gwacheon-si, Gyeonggi-do 13481, Korea

**** 교신저자, 연세대학교 공과대학 토목공학과 교수 (e-mail: jhheo@yonsei.ac.kr, Tel: 82-2-2123-2805)

Corresponding Author, Professor, School of Civil and Environmental Engineering, Yonsei Univ., Seoul 120-749, Korea.

1. 서론

수자원의 운영 및 관리를 위하여 수문자료의 예측 및 분석은 필수적인 절차이며, 특히 대표적인 수공구조물인 댐의 경우 홍수조절, 하천유지용수, 전력생산 등에 직접적인 영향을 미치므로 댐 유입량의 전반적인 흐름 파악 및 예측은 매우 중요한 과정이라 할 수 있다. 이에 따라 다양한 수문 예측 모형이 개발되고 수행되어져 왔으며 그 중에서도 시계열 모형을 활용한 댐 유입량 예측은 과거 관측된 수문자료만으로 모형을 구축하므로 비교적 용이하게 모형을 구축할 수 있어 널리 사용되어오고 있다. 시계열 모형을 이용하여 예측을 수행한 기존의 연구들을 살펴보면, Ahn and Lee (2000)은 시계열 모형인 multiplicative ARIMA (autoregressive integrated moving average) 모형과 상태공간모형으로 계절별 월 유출량을 모의하여 비교하였고, Kang and Heo (2006)은 ARMA (autoregressive moving average), ARMAX (autoregressive moving average model with exogenous inputs), TF (transfer function), TFN (transfer function noise), SARIMA (seasonal ARIMA) 등의 단변량 및 다변량 시계열 모형을 통하여 한강수계 주요 댐인 소양강댐, 충주댐, 화천댐의 월별 유입량을 예측하고 이를 비교하였다. Yoon et al. (2009)은 댐 유입량 예측을 위하여 장기유출모형인 TANK 모형과 시계열 모형인 계절형 ARIMA 모형을 결합하여 연구를 진행하고 구축한 모형이 수자원의 증장기 전략수립에 도움이 될 것이라 판단하였다. Musa (2013)는 나이지리아의 Shiroro강 유량을 산정하기 위해 ARMA 모형을 구축하고 모형 분석과 평가를 통해 구축된 모형이 효율적으로 사용될 수 있음을 확인하였고, Valipour et al. (2013)은 ARMA, ARIMA, autoregressive artificial neural network 등의 모형을 이용하여 이란의 Dez댐 월유입량 예측을 수행하고 비교하였다. 하지만 이러한 시계열 모형은 한 시계열을 하나의 요소로 파악하고 주어진 시계열의 행태로부터 모형을 구축하여 예측을 수행하기 때문에 과거 관측계열이 규칙적이지 않고 복잡할 경우 모형이 고려해야 할 차수가 높아지고 이에 따라 예측의 불확실성이 높아질 가능성이 있다.

본 연구에서는 이러한 시계열 모형으로부터 댐 유입량을 더욱 효과적으로 예측하고자 Huang et al. (1998)이 개발한 경험적 모드분해법(empirical mode decomposition, EMD)을 이용한 연구를 진행하였다. 경험적 모드분해법은 효과적인 신호처리를 위해 고안된 방법으로, 하나의 신호가 여러 가지 신호의 혼합으로 이루어졌다는 가정 하에 이러한 신호를 분해하여 각각의 요소를 추출하는 방법

이다. 경험적 모드분해법을 활용하여 연구한 사례를 살펴보면, Wu and Huang (2004)은 경험적 모드분해법으로 분해된 내재모드함수(intrinsic mode function, IMF)가 통계적으로 유의한지를 구분하기 위한 방법을 개발하기 위하여 백색잡음의 특성에 의거하여 에너지밀도확산함수를 유도하였고, Kim and Oh (2006)은 경험적 모드분해법을 소개하고 잡음에 의해 자료가 오염되었을 경우 이를 보완하기 위하여 기존의 경험적 모드분해법에 기초한 새로운 계층적 평활방법을 제시하였다. 또한 수문기상학적 자료를 이용한 경험적 모드분해법의 연구는 최근 들어 활발해지는 추세를 보이는데, Lee and Ouarda (2010)는 미래 장기적 진동 패턴을 예측하기 위하여 경험적 모드분해법을 활용하여 자료를 분해한 후 중요 요소를 nonstationary oscillation resampling (NSOR) 기법으로 모델링하여 극한 사상을 가진 비정상성 수문자료의 장기적 패턴이 경험적 모드분해법과 NSOR을 통해 잘 예측됨을 확인하였고, Lee and Ouarda (2011)는 이러한 방법을 불규칙적인 진동을 보이는 지구 표면 온도의 장기적 비정상성 변동 예측을 위하여 활용하였다. 또한 Lee and Ouarda (2012)는 경험적 모드분해법과 비매개변수적 모의 기법을 활용하여 관측된 수문기상학적 자료에서의 비정상성 진동 과정을 모의하기 위한 모형을 제시하고 실제 북대서양 진동지수(North Atlantic Oscillation index) 자료를 적용하여 모형의 가용성을 확인하였다. Karthikeyan and Kumar (2013)은 비정상성 수문 시계열을 예측하기 위한 방법으로 웨이블릿과 경험적 모드분해법에 기초한 auto regressive 모형을 해석하는 방법을 제시하고 이를 비교하였다. 두 방법 모두 주어진 시계열을 유한개의 요소로 분해하고 이를 재구축하여 미래 값을 예측하는 방법이며, 웨이블릿을 이용한 방법이 극값의 예측에서 더 높은 예측력을 보이는 것을 확인하였다. Sang et al. (2014)은 수문자료의 경향성 여부를 판단하기 위하여 기존의 Mann-Kendall 방법과 경험적 모드분해법을 이용한 경향성 테스트 방법을 실제 경향성을 보이는 강우와 유입량 자료에 적용하여 이를 비교하였으며, Wang et al. (2015)은 경험적 모드분해법을 개선한 앙상블 경험적 모드분해법을 이용하여 자료를 분해한 후 auto regressive integrated moving average (ARIMA) 모형으로 유출량 예측의 적용성에 관한 연구를 수행하였다.

본 연구에서는 경험적 모드분해법을 이용한 시계열 모형을 활용하여 국내 댐 유입량 자료를 통한 예측력 개선을 검토하고자 하였다. 이에 따라 실제 국내 한강수계 댐인 화천댐과 소양강댐의 유입량 자료를 분해하고 각각의 분해된 자료를 시계열 모형으로 구축한 후 구축된 모형으

로부터 발생된 예측 유입량을 합하여 동일한 자료를 기존의 단변량 시계열 모형인 ARMA 모형으로부터 예측된 유입량과 비교·분석 하고 두 모형 간 예측력을 검토하였다.

2. 기본이론

2.1 경험적 모드분해법

경험적 모드분해법은 Huang et al. (1998)에 의해 개발된 새로운 분해분석법으로 체거름 알고리즘(sifting algorithm)을 통해 하나의 자료를 일련의 고유한 내재모드함수로 분해하는 방법이다. 기존의 분해분석법으로 알려진 방법들과는 다르게 경험적 모드분해법은 경험적이고 자료 적응적인(data-adaptive) 방법이므로 자료가 비정상성, 비선형 시계열인 경우 더욱 효과적으로 분해할 수 있다(Huang et al., 1998; Huang and Wu, 2008, Kim and Oh, 2008; Sang et al., 2012). 이러한 경험적 모드분해법은 다음과 같은 세 가지 가정을 만족해야 한다(Huang et al., 1998).

- (1) 자료 계열에는 최소 2개의 극값(최댓값, 최솟값)이 존재해야 한다.
- (2) 특성 시간 규모는 극값 사이의 시간의 경과에 의해 정의된다.
- (3) 자료 계열에 극값이 없지만 변곡점이 포함되어 있다면, 극값을 나타내기 위해서 차분이 가능하다.

체거름 알고리즘은 주어진 하나의 시계열 자료를 유한한 개수의 내재모드함수로 분해하는 과정을 나타내는 순서화된 절차로 n 개의 시계열 자료 계열을 $y(t)$, $t=1,2,3,\dots,n$ 이라 할 경우 아래와 같은 과정으로 이루어진다(Huang et al., 1998; Sang et al., 2014; Wang et al., 2015)

- (1) 초기설정 $i=1$, $s=y(t)$
- (2) 주어진 시계열 자료계열 s 의 극값(국소 최댓값 및 최솟값)을 식별한다.
- (3) 극값인 국소 최댓값과 국소 최솟값을 각각 삼차 스플라인(cubic spline) 보간법을 이용하여 연결하는 선(envelope)을 만들고 이 선들을 각각 상위선(upper envelope, s_u)과 하위선(lower envelope, s_l)이라 한다.
- (4) (3)에서 구한 상위선과 하위선을 Eq. (1)과 같이 평균하여 평균선(mean envelope, s_m)을 구한다.

$$s_m = \frac{s_u + s_l}{2} \quad (1)$$

- (5) 원자료계열 s 에서 평균선을 공제($s - s_m$)하고, 이를 추출된 새로운 계열인 내재모드함수 IMF_i 라 한다.

- (6) (5)에서 추출된 내재모드함수를 제거한 후 시계열 자료계열 s 를 $s = y(t) - IMF_i$ 라 재설정하고, 남은 자료계열이 단조함수 또는 하나의 극값만 존재하여 더 이상 새로운 계열이 추출되지 않을 때까지 (2)-(5)의 과정을 반복한다.
- (7) 최종적으로 분해된 자료 계열들은 Eq. (2)와 같이 나타낼 수 있다.

$$y(t) = \sum_{i=1}^N IMF_i + R_N \quad (2)$$

여기서, N 은 시계열 자료계열 $y(t)$ 로부터 추출된 내재모드함수의 개수, R_N 은 시계열 자료계열을 분해하고 남은 잔여값이다.

분해된 IMF_i 의 개수는 전체 자료 개수 n 에 대하여 $\log_2 n$ 에 근접한 개수로 분해되며(Wu et al., 2007), 체거름 알고리즘을 통해 분해된 내재모드함수는 다음과 같은 두 가지 조건을 만족해야 한다(Huang et al., 1998).

- (1) 전체 자료 계열에서 극값(최댓값 및 최솟값)의 개수와 부호변화점(zero crossing)의 개수는 같거나 최대 1이어야 한다.
- (2) 어느 지점에서든 상위선과 하위선의 평균은 0이어야 한다.

따라서 분해된 내재모드함수는 모두 1차 정상성 계열로 나타내어진다.

2.2 자기회귀이동평균 모형

자기회귀이동평균 모형은 Box and Jenkins (1976)에 의해 소개된 시계열 모형으로 주어진 시계열 자료가 가지고 있는 법칙성을 확률적, 통계적으로 해석하여 모형화하는 시계열 분석의 대표적인 모형이다. 자기회귀이동평균 모형은 시계열이 자기회귀항(AutoRegressive, AR)과 이동평균항(Moving Average, MA)의 결합으로 이루어져 있는 경우의 형태이며, 자기회귀항의 차수가 p 이고 이동평균항의 차수가 q 라 할 때 ARMA(p, q) 모형은 다음 Eq. (3)과 같이 나타난다.

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3)$$

Eq. (3)을 후진연산자(B)를 이용하여 다시 정리하면 Eq. (4)와 같다.

$$\phi(B)y_t = \theta(B)\varepsilon_t \quad (4)$$

여기서, y_t 는 주어진 시계열을 의미하고, $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ 및 $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ 은 각각 자기회귀항과 이동평균항의 매개변수를 포함한 연산자이며, ε_t 는 평균이 0이고 분산이 σ_ε^2 인 백색잡음과정이다.

3. 방법론

본 연구에서는 주어진 하나의 시계열 자료를 경험적 모드분해법을 이용한 시계열 모형 및 기존의 전통적인 시계열 모형 간의 예측 값을 비교하였으며 연구진행 방법은 Fig. 1에 나타나있다.

경험적 모드분해법을 이용한 시계열 모형 구축의 경우, Fig. 1의 왼쪽과 같은 과정으로 구축하게 된다. 먼저 주어진 시계열 y_t 를 경험적 모드분해법을 이용하여 내재모드 함수들과 잔여값으로 분해하고, 각 분해된 요소들을 독립된 시계열 성분이라 가정하 뒤 각 요소별로 자기회귀이동평균모형을 이용하여 시계열 모형을 구축한다. 구축된 모형별로 예측 값을 산정하고, 산정된 예측 값들을 합하여 주어진 시계열의 예측 값을 구하게 된다. 이를 Fig. 1의 오른쪽에 나타나 있는 기존의 시계열 모형인 자기회귀이동평균 모형으로 구축하여 산정된 예측 값과 비교하였다.

4. 적용 및 결과

4.1 대상지점 및 자료

본 연구의 적용을 위해서는 주어진 수문자료를 경험적

모드분해법으로 자료를 분해한 후 각 요소별로 시계열 모형을 구축하게 되므로 인위적인 변화가 없는 지점에서 통일된 시간단위의 자료가 사용되어야 한다. 이에 따라 한강수계 상류에 위치한 화천댐 및 소양강댐의 연간 총 유입량 자료를 대상으로 모형을 구축하고 결과를 비교하였다. 화천댐의 유역면적은 3,901 km²로 상류에 평화의 댐이 위치하고 있지만 평화의 댐은 인위적인 홍수 조절 기능을 목적으로 하지 않기 때문에 영향이 미비하므로 인위적인 변화가 없는 댐이라 가정하고 연구를 진행하였으며 소양강댐은 유역면적 2,703 km²로 상류에 인위적인 영향이 없으므로 연구를 진행하기에 적절하다고 판단하였다.

구축된 모형의 예측력 검증을 위하여 모형 구축을 위한 기간을 총 자료 길이의 85%로 선정하고, 이를 모형훈련자료(model training data)로 활용하였고 나머지 15%의 기간을 모형검증자료(model validation data)로 사용하였다. 따라서 화천댐의 경우 1967년부터 2006년까지의 자료를 이용하여 모형을 구축한 후 2007년부터 2014년까지를 검증 구간으로 설정하였고, 소양강댐의 경우 1974년부터 2008년까지를 모형 구축 기간으로 설정하고 2009년부터 2014년까지를 검증 구간으로 설정하였다. 댐별 유입량 자료는 국가수자원관리종합정보시스템으로부터 수집하였고, 각 댐에 관한 정보 및 기본 통계치는 Table 1에 나타내었다.

4.2 시계열 자료 분해 및 모형 구축

화천댐 및 소양강댐의 연 유입량 시계열 자료를 경험적

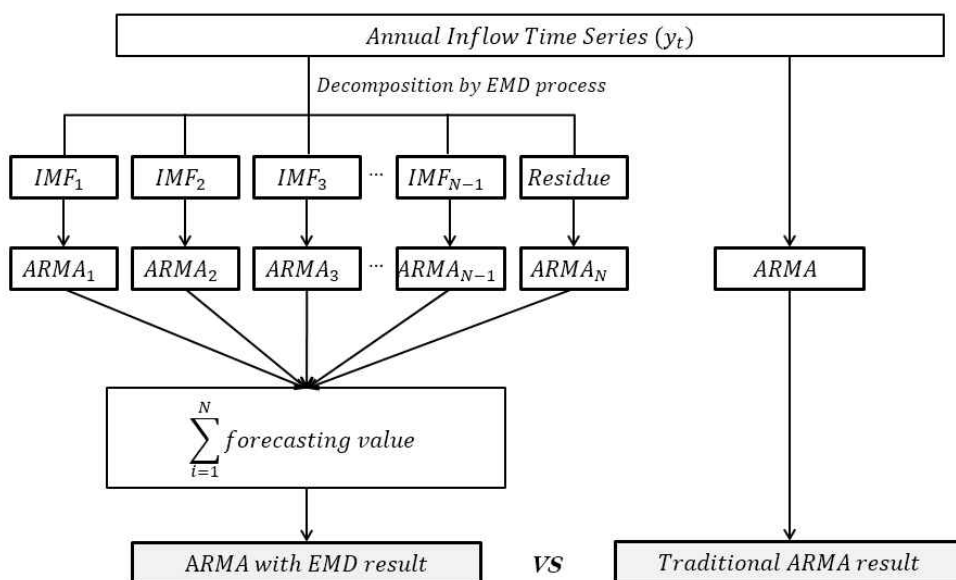


Fig. 1. The Flow Chart of ARMA with EMD and Traditional ARMA Processes

모드분해법의 체거름 알고리즘을 통하여 내재모드함수로 분해한 결과는 Fig. 2와 같다. 화천댐의 경우 총 6개의 요소인 내재모드함수($IMF_1 - IMF_5$)와 잔여값($Residue$)으로

분해되었고, 소양강댐의 경우 총 5개의 요소인 내재모드함수($IMF_1 - IMF_4$)와 잔여값($Residue$)으로 분해되었다. 각 분해된 내재모드함수는 처음에는 비교적 큰 진폭과 높

Table 1. Details of Applied Dam

Name	Length (years)		Mean (10^6 m ³)	Std. dev. (10^6 m ³)	Skewness Coefficient
Hwacheon dam	48 (1967-2014)	Model training data	2633.19	1059.96	0.86
		40 (1967-2006)			
		Model validation data			
		8 (2007-2014)			
Soyanggang dam	41 (1974-2014)	Model training data	2209.38	715.01	0.71
		35 (1974-2008)			
		Model validation data			
		6 (2009-2014)			




Fig. 2. Decomposed Component Results of Annual Inflow Time Series in Hwacheon Dam and Soyanggang Dam

은 주기성을 가지는 요소들로 나타나나 과정을 반복할수록 이러한 현상이 벌어지는 양상을 보이며 마지막에 얻어진 잔여값은 단조 함수 형태로 나타났다.

주어진 자료를 시계열 모형으로 구축하기 위한 차수선택 방법은 일반적으로 Box and Jenkins (1976)의 방법을 참고하여 전체 자료길이의 1/4에 해당하는 구간의 PACF (partial autocorrelation function)와 ACF (autocorrelation function)를 구하고 95%의 확률한계(probability limits)를 기준으로 차수 p, q 를 선정한다. 하지만 이 방법은 매우 개략적인 방법이므로 본 연구에서는 PACF의 절단점으로부터 예비적으로 차수 p 를 선정하고 차수 q 의 경우 ACF의 절단점으로부터 판단하기에는 부정확한 부분이 많으므로 차수 10까지의 경우를 고려하여 모형을 구축하였다. 최적 모형을 선정하기 위하여 다양한 모형간의 비교를 통하여

적정 모형 선택의 기준이 되는 AIC(Akaike information criteria) 값을 사용하였으며 Eq. (5)에 나타내었다.

$$AIC = -2\log(ML) + 2(p+q) \quad (5)$$

여기서, ML 은 최대우도함수, p 와 q 는 각각 ARMA 모형의 차수를 의미하며 최적 모형은 AIC값이 가장 작은 값을 가지는 경우를 가장 적절한 모형이라 판단한다. 따라서 AIC값을 통한 적정 차수 선택은 차수 p 와 q 가 커짐에 따라 AIC값도 커지기 때문에 차수의 크기를 고려하여 적정 모형을 선택할 수 있는 방법이며 매개변수는 자연세계의 진화과정을 기반으로 한 최적화 기법인 유전자알고리즘(genetic algorithm)을 이용하여 추정하였다.

첫 번째 대상지점인 화천댐의 원자료 및 분해된 요소들의 PACF 및 ACF는 Fig. 3에 나타내었고, PACF의 절단

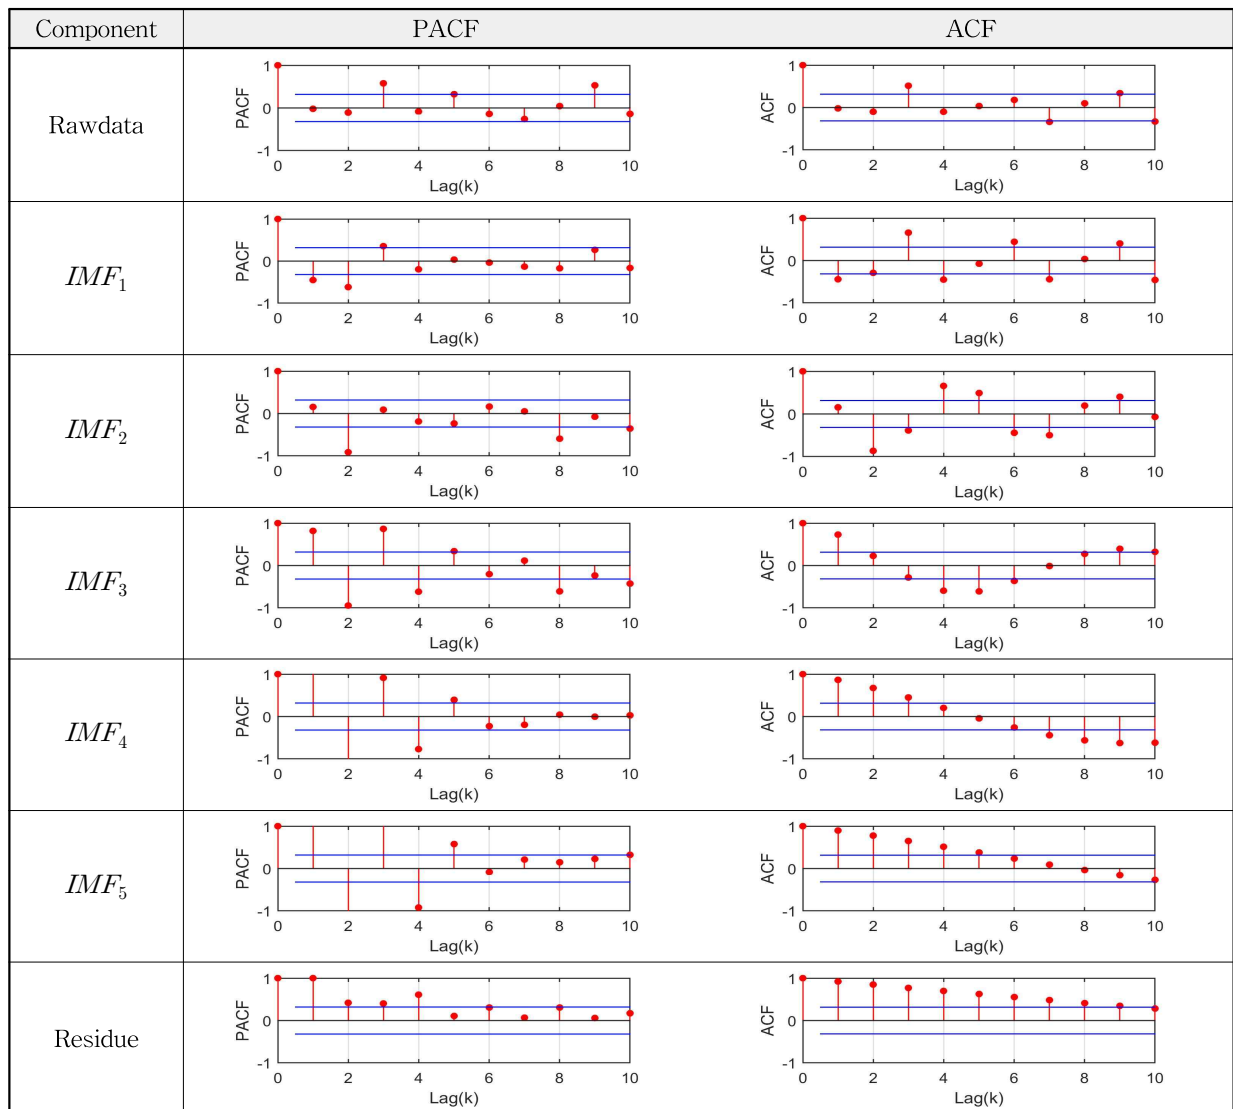


Fig. 3. PACF and ACF of Decomposed Component of Hwacheon Dam

점을 기준으로 한 p 와 차수 10까지 고려한 q 에 대하여 각각 차수에 해당하는 AIC값은 Table 2에 나타내었다. 화천댐 연 유입량 원자료를 시계열 모형으로 구축한 결과 최소 AIC값을 가지는 ARMA(3,8) 모형이 적정 모형으로 선택되었으며 첫 번째 내재모드함수인 IMF_1 도 ARMA(3,8) 모형이 적절하다고 판단되었다. Fig. 2에서 볼 수 있듯이 두 자료의 형태가 비슷함에 따라 두 모형의 차수가 동일

하게 구축되었음을 알 수 있으며 체계를 알고리즘을 걸친 내재모드함수들의 경우 형태가 달라지면서 각각 다른 형태의 시계열 모형이 구축되었다. 화천댐의 원자료 및 분해된 요소들의 시계열 모형과 매개변수 추정에 따른 최종 모형 식은 Table 3에 나타내었다. 분해된 요소들로부터 구축된 시계열 모형을 살펴보면 요소들이 분해될수록 자기회귀를 나타내는 $AR(p)$ 항이 높은 차수를 나타내는데

Table 2. AIC Values of Hwacheon Dam

	$p \backslash q$	1	2	3	4	5	6	7	8	9	10
Rawdata	1	507.12	510.29	506.81	494.56	494.32	492.77	495.20	497.78	497.83	496.30
	2	510.50	503.94	496.99	488.78	491.07	495.88	494.78	493.15	497.79	486.59
	3	504.31	494.96	490.83	497.52	493.96	496.72	500.07	485.70	488.89	491.18
	4	505.80	503.75	505.81	496.96	507.70	499.64	490.20	493.22	494.42	495.61
IMF_1	1	485.24	468.10	470.96	474.55	468.98	469.72	472.83	461.66	471.71	474.65
	2	473.22	475.18	477.00	471.47	467.59	474.99	462.53	471.63	466.80	467.85
	3	475.10	477.09	479.03	466.36	463.62	466.03	465.01	461.44	464.92	462.70
	4	477.50	461.49	465.42	471.04	467.74	465.64	466.80	465.25	463.62	470.52
IMF_2	1	431.41	415.46	413.31	409.90	400.30	391.11	388.71	391.92	386.01	395.19
	2	394.99	393.57	385.73	384.82	380.03	380.33	386.81	384.31	381.37	379.36
	3	394.03	393.09	386.89	383.31	395.19	382.51	396.65	380.03	379.84	380.96
IMF_3	1	387.83	376.84	375.67	375.20	365.85	361.89	359.62	358.14	374.08	368.00
	2	365.24	360.86	358.87	356.74	356.08	343.18	350.04	357.75	348.68	358.94
	3	357.65	356.38	356.83	347.28	341.68	346.54	344.83	343.40	342.51	355.26
	4	359.66	357.97	359.16	349.14	345.21	345.13	344.25	356.03	351.55	360.87
	5	360.60	356.11	358.94	353.27	346.94	348.84	351.97	349.19	350.97	348.61
	6	358.53	359.26	360.17	364.02	362.78	347.95	349.18	344.34	356.05	350.72
IMF_4	1	333.81	314.63	302.71	294.60	293.66	285.98	286.17	291.15	294.21	300.56
	2	331.36	314.78	303.61	296.37	295.71	287.75	288.59	292.98	298.26	302.49
	3	268.99	263.39	264.14	253.76	248.44	242.29	248.48	242.38	244.84	245.35
	4	266.98	257.81	256.32	259.47	251.38	238.19	238.50	240.83	245.35	246.20
	5	256.56	246.44	245.06	247.08	247.46	233.67	236.46	244.68	243.09	253.06
	6	259.17	246.71	247.16	251.72	253.12	243.83	245.45	244.05	251.07	251.77
IMF_5	1	308.63	289.76	278.15	270.58	264.76	258.35	255.14	249.88	249.42	246.27
	2	310.40	291.91	280.06	272.17	265.41	257.45	252.99	245.63	246.32	248.12
	3	214.99	197.88	187.84	178.84	178.25	177.65	167.62	179.61	174.80	186.42
	4	200.36	186.13	180.94	177.02	174.86	175.63	164.45	163.21	172.24	178.91
	5	191.79	178.43	171.66	170.51	167.05	169.12	157.19	164.73	163.73	191.60
	6	177.67	159.52	151.92	148.43	149.22	150.37	150.59	155.84	155.81	156.45
Residue	1	144.04	130.53	126.19	141.37	128.26	131.90	144.83	150.58	157.01	134.83
	2	142.11	131.68	127.54	145.21	141.38	158.88	146.69	167.47	188.88	179.46
	3	66.14	141.86	76.31	156.60	0.30	142.48	224.49	503.89	216.59	172.25
	4	-142.84	12.79	-17.89	-71.95	118.56	129.86	152.18	140.56	187.51	211.86
	5	340.36	-65.59	-203.83	63.12	78.39	-16.33	165.67	123.46	185.29	216.39

이는 요소가 분해되면서 점차 주기가 길어지는 것을 반영한 것으로 판단된다. 또한 이동평균을 나타내는 MA(q)항은 처음에는 높은 차수를 보이다가 요소가 분해되면서 점차 낮은 차수로 모형을 구축하였다. 최종적으로 각 시계열 모형으로부터 예측을 수행하여 경험적 모드분해법을 이용한 ARMA 모형 예측값의 합과 기존의 ARMA 모형

으로부터 구축된 모형 예측값의 비교는 Fig. 4에 도시하였다. 시계열 모형을 구축하고 예측값을 산정할 경우 예측의 시작점은 차수의 영향을 받게 되는데, 이는 과거 관측 자료가 예측을 위한 입력값이 되므로 예측을 위한 최소 관측 자료가 확보되어야 예측을 수행할 수 있다. 따라서 예측 시작점은 차수에 따라 주어진 과거 관측 자료보다 이후부

Table 3. ARMA Model of Annual Inflow Time Series and Intrinsic Mode Functions Decomposed by Empirical Mode Decomposition in Hwacheon Dam

Component	ARMA(p,q)	Model
Rawdata	ARMA(3,8)	$y_t = -0.0941y_{t-1} + 0.0639y_{t-2} + 0.9599y_{t-3} + \varepsilon_t - 0.0095\varepsilon_{t-1} - 0.4169\varepsilon_{t-2} - 0.8527\varepsilon_{t-3} - 0.0067\varepsilon_{t-4} + 0.1726\varepsilon_{t-5} - 0.9538\varepsilon_{t-6} - 0.1361\varepsilon_{t-7} + 0.1936\varepsilon_{t-8}$
IMF1	ARMA(3,8)	$y_t = -0.2927y_{t-1} - 0.2075y_{t-2} + 0.4970y_{t-3} + \varepsilon_t - 0.2789\varepsilon_{t-1} - 0.0257\varepsilon_{t-2} - 0.5973\varepsilon_{t-3} - 0.7544\varepsilon_{t-4} + 0.5492\varepsilon_{t-5} - 0.4111\varepsilon_{t-6} - 0.6955\varepsilon_{t-7} + 0.2014\varepsilon_{t-8}$
IMF2	ARMA(2,10)	$y_t = +0.5989y_{t-1} - 0.7010y_{t-2} + \varepsilon_t - 0.5335\varepsilon_{t-1} - 0.9999\varepsilon_{t-2} - 0.2899\varepsilon_{t-3} + 0.9306\varepsilon_{t-4} - 0.4175\varepsilon_{t-5} - 0.5439\varepsilon_{t-6} - 0.3291\varepsilon_{t-7} + 0.3606\varepsilon_{t-8} + 0.8343\varepsilon_{t-9} - 0.4988\varepsilon_{t-10}$
IMF3	ARMA(3,5)	$y_t = +0.9999y_{t-1} + 0.1600y_{t-2} - 0.6726y_{t-3} + \varepsilon_t + 0.9999\varepsilon_{t-1} - 0.3882\varepsilon_{t-2} - 0.9999\varepsilon_{t-3} - 0.9998\varepsilon_{t-4} - 0.9999\varepsilon_{t-5}$
IMF4	ARMA(5,6)	$y_t = +0.9999y_{t-1} + 0.9155y_{t-2} - 0.7521y_{t-3} - 0.6719y_{t-4} + 0.3499y_{t-5} + \varepsilon_t + 0.9756\varepsilon_{t-1} + 0.9999\varepsilon_{t-2} + 0.5412\varepsilon_{t-3} - 0.4983\varepsilon_{t-4} - 0.9999\varepsilon_{t-5} - 0.8339\varepsilon_{t-6}$
IMF5	ARMA(6,4)	$y_t = +0.9999y_{t-1} + 0.9999y_{t-2} - 0.2489y_{t-3} - 0.7745y_{t-4} - 0.8131y_{t-5} + 0.8242y_{t-6} + \varepsilon_t + 0.9999\varepsilon_{t-1} + 0.9995\varepsilon_{t-2} + 0.9979\varepsilon_{t-3} + 0.5206\varepsilon_{t-4}$
Residue	ARMA(4,1)	$y_t = +0.7175y_{t-1} + 0.7854y_{t-2} + 0.2857y_{t-3} - 0.7886y_{t-4} + \varepsilon_t + 0.8178\varepsilon_{t-1}$




Fig. 4. Forecasting Results of Traditional ARMA(3,8) Model and ARMA with EMD Model in Hwacheon Dam

터 나타나게 되며 Fig. 4에서 기존 ARMA 모형 및 경험적 모드분해법을 이용한 ARMA 모형의 최대 차수가 각각 8 및 10이므로 차수의 영향을 받아 1967년으로부터 8년, 10년 이후의 시작점부터 예측이 시작됨을 볼 수 있다.

본 연구에서는 모형의 예측력 검증을 위하여 전체 자료 길이의 85%를 모형훈련자료로 하여 모형을 구축하고 나머지 15%를 모형검증자료로 예측 검증을 위한 자료로 활용하였다. 구축된 두 모형의 모형훈련자료에 대한 예측 값을 실제 관측 유입량과 비교한 결과, 전반적으로 경험적 모드분해법을 이용한 ARMA 모형의 예측 유입량이 실제 관측 유입량을 더 잘 나타내는 것을 볼 수 있다. 또한 15%의 모형검증자료에 대한 예측 값을 비교한 결과 역시 전반적으로 두 모형 모두 모형훈련자료의 기간보다 예측력이 떨어지는 양상을 보였지만 경험적 모드분해법을 이용한 ARMA 모형의 예측 유입량이 기존 ARMA 모형보다 실제 관측 유입량을 더 잘 나타내는 것을 확인할 수 있었다. 이러한 차이는 관측 유입량의 시계열이 상대적으로 평균에 비해 높은 값을 나타낼 때 주로 나타났는데, 이는 자료 계열의 전반적인 흐름을 파악하여 모형을

구축하는 기존 ARMA 모형에서의 오차가 경험적 모드분해법을 이용하였을 경우 하나의 주어진 시계열 자료를 분해 후 분해된 자료 계열을 각 요소별로 모형을 구축하기 때문에 감소할 수 있음을 보여주는 결과라 할 수 있다. 따라서 경험적 모드분해법을 이용하여 자료 계열을 분해 후 시계열 모형을 구축하고 각 예측 값을 합하여 최종적으로 예측 유입량을 산정할 경우, 기존 ARMA 모형이 가지고 있는 불확실성이 감소됨을 확인할 수 있었다.

두 번째 대상지점인 소양강댐의 원자료 및 분해된 요소들의 PACF 및 ACF는 Fig. 5에 나타내었고 화천댐과 같은 방법으로 고려한 각 요소별 차수의 AIC값은 Table 4와 같다. 소양강댐 연 유입량 원자료는 ARMA(2,3) 모형이 적정 모형으로 선택되었으며 첫 번째 내재모드함수의 경우 ARMA(3,9) 모형이 적정 모형으로 선택되어 화천댐의 양상과는 다르게 비슷한 형태의 자료더라도 다른 차수가 선택될 수 있음을 보여주었다. 같은 방법으로 선택된 소양강댐의 원자료 및 분해된 요소들의 시계열 모형과 매개변수 추정에 따른 최종 모형 식은 Table 5와 같다. 구축된 시계열 모형을 살펴보면 화천댐과 같은 양상으로 요소들이

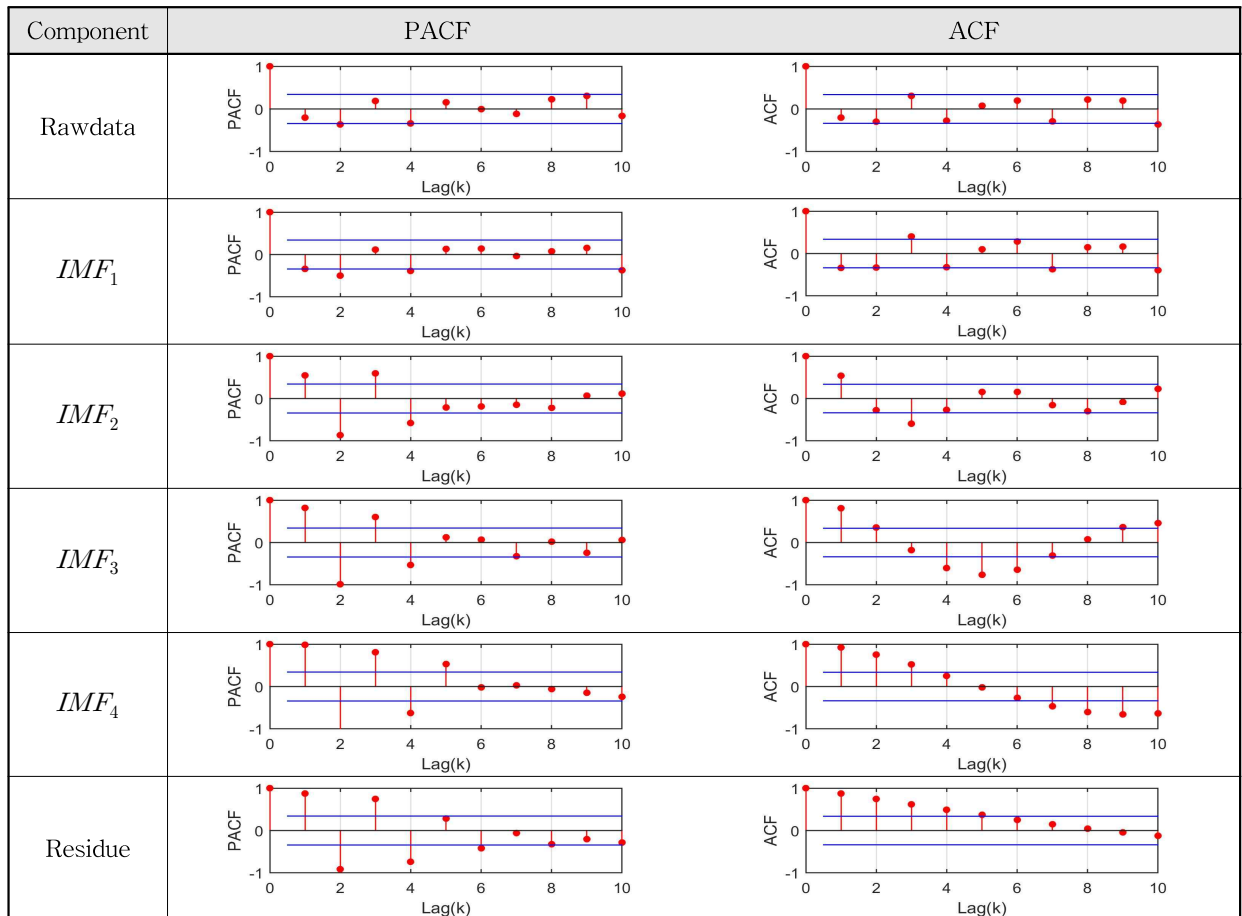


Fig. 5. PACF and ACF of Decomposed Component of Soyanggang Dam

Table 4. AIC Values of Soyanggang Dam

	p \ q	1	2	3	4	5	6	7	8	9	10
Rawdata	1	409.62	406.03	402.58	400.60	407.09	408.57	408.18	414.24	415.24	413.93
	2	406.44	403.46	394.75	409.53	402.90	409.07	406.92	410.42	412.11	412.31
	3	404.52	397.85	399.14	410.15	408.92	398.57	405.08	410.43	402.26	405.65
IMF ₁	1	395.71	391.98	387.90	385.58	389.28	390.16	386.10	389.33	382.62	401.62
	2	393.47	392.91	389.59	388.97	389.38	392.09	397.58	388.36	391.26	394.64
	3	397.19	388.77	391.84	389.97	392.35	393.56	388.23	397.85	380.92	395.45
IMF ₂	1	334.69	336.26	324.53	314.61	319.33	318.92	321.03	317.95	320.68	326.55
	2	316.71	316.33	308.81	309.24	309.18	316.22	310.12	309.55	305.29	312.74
	3	317.70	317.94	314.59	309.96	310.34	321.73	314.96	314.57	303.71	323.99
IMF ₃	1	303.02	288.96	284.81	285.20	275.27	271.11	270.04	269.52	272.98	289.25
	2	284.10	268.35	265.76	268.03	257.38	255.81	254.75	255.19	256.34	266.07
	3	250.17	242.38	243.25	238.87	230.81	239.75	236.86	234.13	230.22	249.19
	4	243.49	239.28	242.30	238.73	227.24	232.97	237.81	237.94	239.57	257.55
	5	253.69	241.15	242.64	241.95	238.20	235.13	246.09	242.99	236.95	260.78
IMF ₄	1	245.37	228.80	218.80	214.28	209.74	210.56	209.45	210.80	219.87	230.57
	2	243.74	227.67	217.03	212.34	207.35	208.07	203.55	205.73	220.38	236.68
	3	152.60	143.26	145.83	142.55	142.99	145.65	137.75	149.19	139.55	169.37
	4	159.42	149.89	148.54	144.12	145.94	137.31	129.67	139.74	139.58	171.73
	5	154.13	142.82	144.38	146.98	148.16	145.51	161.87	147.05	140.45	184.90
	6	161.37	152.94	149.90	145.70	142.04	134.35	131.96	157.83	169.34	179.09
Residue	1	175.53	160.75	150.54	136.91	141.79	136.60	124.96	128.51	122.76	186.55
	2	197.38	196.13	200.44	247.84	229.56	241.03	293.81	329.22	320.38	196.05
	3	100.00	87.59	76.82	178.63	81.71	134.82	204.71	149.90	213.03	175.88
	4	116.84	108.72	97.28	85.01	88.21	82.55	55.52	81.23	146.30	83.10
	5	122.13	95.50	85.72	81.79	79.96	108.62	74.94	85.58	85.77	78.74

분해될수록 자기회귀를 나타내는 AR(p)항이 높은 차수를 나타내며, 이동평균을 나타내는 MA(q)항은 처음에는 높은 차수를 보이다가 요소가 분해되면서 점차 낮은 차수로 모형을 구축하였다. Fig. 6은 경험적 모드분해법을 이용한 ARMA 모형 예측값의 합과 기존 ARMA 모형으로부터 구축된 모형 예측값을 실제 유입량과 비교한 결과이며 경험적 모드분해법을 이용한 ARMA 모형이 예측 유입량이 실제 유입량을 더 잘 나타내는 것을 볼 수 있었다. 이를 통해 경험적 모드분해법을 이용한 시계열 예측이 기존 시계열 모형의 예측력을 향상시킬 수 있음을 확인하였다.

4.3 모형의 검증 및 예측

각 댐별로 구축된 모형 간의 비교를 위해 실제 관측 유

입량과 모형을 통해 산정된 예측 유입량 간의 평균제곱근 오차(root mean square error, RMSE) 및 상대평균제곱근 오차(relative root mean square error, RRMSE)를 이용하여 정확도를 검증하였다. 정확도는 각각 모형훈련자료와 모형검증자료로 구분하여 수행하였으며 RMSE 및 RRMSE는 Eqs. (6) and (7)을 통해 계산되었다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (f_t - y_t)^2} \quad (6)$$

$$RRMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n \left(\frac{f_t - y_t}{y_t} \right)^2} \quad (7)$$

여기서, n은 전체 자료 길이, y_t는 실제 관측 유입량, f_t는

Table 5. ARMA Model of Annual Inflow Time Series and Intrinsic Mode Functions Decomposed by Empirical Mode Decomposition in Soyanggang Dam

Component	ARMA(p,q)	Model
Rawdata	ARMA(2,3)	$y_t = +0.4760y_{t-1} + 0.5401y_{t-2} + \varepsilon_t - 0.9434\varepsilon_{t-1} - 0.9472\varepsilon_{t-2} + 0.6206\varepsilon_{t-3}$
IMF1	ARMA(3,9)	$y_t = -0.1926y_{t-1} - 0.1156y_{t-2} + 0.6670y_{t-3} + \varepsilon_t - 0.7332\varepsilon_{t-1} - 0.0738\varepsilon_{t-2} - 0.0217\varepsilon_{t-3} + 0.6392\varepsilon_{t-4} + 0.9883\varepsilon_{t-5} - 0.3394\varepsilon_{t-6} - 0.9995\varepsilon_{t-7} - 0.3340\varepsilon_{t-8} + 0.9279\varepsilon_{t-9}$
IMF2	ARMA(3,9)	$y_t = +0.9961y_{t-1} - 0.9655y_{t-2} + 0.1441y_{t-3} + \varepsilon_t + 0.6854\varepsilon_{t-1} - 0.0926\varepsilon_{t-2} - 0.8864\varepsilon_{t-3} - 0.5301\varepsilon_{t-4} - 0.3596\varepsilon_{t-5} - 0.3501\varepsilon_{t-6} - 0.3860\varepsilon_{t-7} - 0.9976\varepsilon_{t-8} - 0.9279\varepsilon_{t-9}$
IMF3	ARMA(4,5)	$y_t = +0.9148y_{t-1} + 0.3715y_{t-2} - 0.9776y_{t-3} + 0.1618y_{t-4} + \varepsilon_t + 0.8093\varepsilon_{t-1} - 0.5241\varepsilon_{t-2} - 0.9998\varepsilon_{t-3} - 0.9946\varepsilon_{t-4} - 0.7541\varepsilon_{t-5}$
IMF4	ARMA(4,7)	$y_t = +0.9739y_{t-1} + 0.2388y_{t-2} + 0.1955y_{t-3} - 0.7054y_{t-4} + \varepsilon_t + 0.9172\varepsilon_{t-1} + 0.9984\varepsilon_{t-2} + 0.6464\varepsilon_{t-3} - 0.1914\varepsilon_{t-4} - 0.9973\varepsilon_{t-5} - 0.9984\varepsilon_{t-6} - 0.6631\varepsilon_{t-7}$
Residue	ARMA(4,7)	$y_t = +0.9439y_{t-1} + 0.9194y_{t-2} - 0.7276y_{t-3} - 0.1368y_{t-4} + \varepsilon_t + 0.9921\varepsilon_{t-1} + 0.9952\varepsilon_{t-2} + 0.9938\varepsilon_{t-3} + 0.9878\varepsilon_{t-4} + 0.9871\varepsilon_{t-5} + 0.9962\varepsilon_{t-6} + 0.9702\varepsilon_{t-7}$

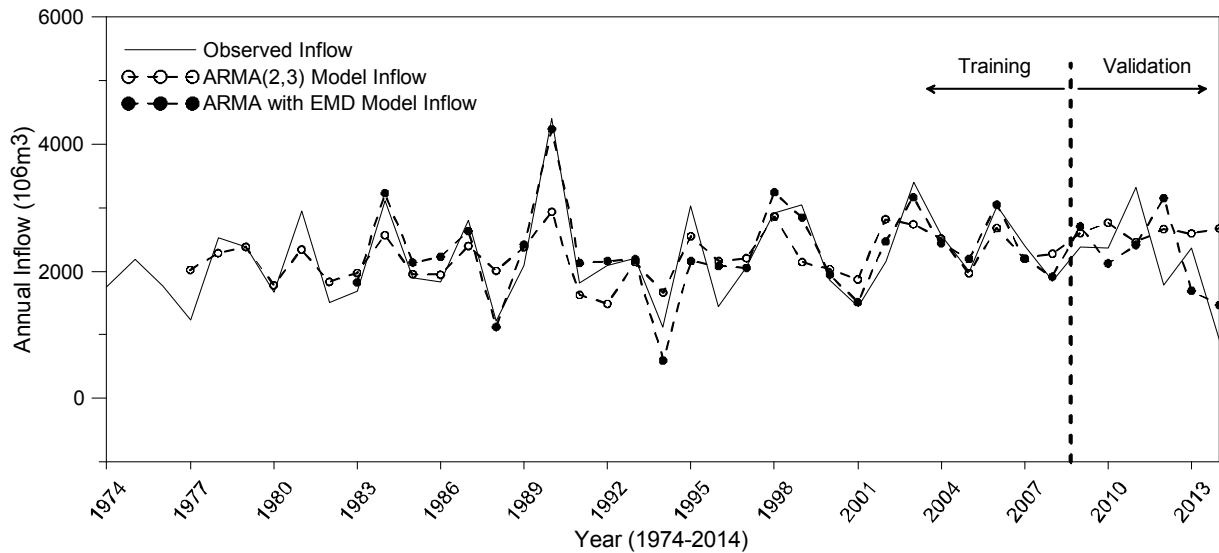


Fig. 6. Forecasting Results of Traditional ARMA(2,3) Model and ARMA with EMD Model in Soyanggang Dam

모형으로부터 산정된 예측 유입량을 나타낸다.

비교 결과 두 대상지점 모두 모형훈련자료의 예측은 모형검증자료의 예측보다 더 나은 예측력을 보였고 두 자료 기간 모두 경험적 모드분해법을 활용한 ARMA 모형으로부터 산정된 예측 유입량의 RMSE 및 RRMSE 값이 더 낮게 나타났다. 따라서 기존의 ARMA 모형보다 경험적 모드분해법을 활용하여 주어진 시계열을 분해한 후 각각의 요소를 ARMA 모형으로 구축하여 예측된 유입

량을 합하는 과정을 이용한 방법이 더 정확하게 주어진 시계열을 예측하는 것을 확인할 수 있었다(Table 6).

5. 결론

본 연구에서는 주어진 수문자료를 경험적 모드분해법을 이용하여 분해된 내재함수로부터 시계열 모형을 구축하고 각 모형으로부터 산정된 예측 값을 합하여 예측 유

Table 6. RMSE and RRMSE Results between Traditional ARMA and ARMA with EMD Models

Name	Period	RMSE		RRMSE	
		ARMA	ARMA with EMD	ARMA	ARMA with EMD
Hwacheon dam	Model training data	555.393	372.079	0.235	0.163
	Model validation data	763.889	692.760	0.688	0.368
Soyanggang dam	Model training data	509.513	301.420	0.259	0.164
	Model validation data	899.435	778.017	0.808	0.432

입량을 산정하는 방법과 기존의 시계열 모형으로 예측된 유입량과 비교하였으며, 다음과 같은 결론을 얻었다.

경험적 모드분해법으로 주어진 시계열을 분해할 경우 초기에는 원자료와 비슷한 형태로 진폭과 주기가 높은 내재모드함수가 분해되고, 체거름 알고리즘이 반복되면서 점차 진폭과 주기성이 낮아지는 요소들로 분해되었으며 분해된 요소는 AR차수가 점차 줄어들고 MA차수가 점차 늘어나는 모형으로 구축되었다.

경험적 모드분해법을 이용한 예측 유입량과 기존 ARMA 모형의 예측 유입량을 실제 관측 유입량과의 차이를 도시하여 비교한 결과 관측 유입량이 전체적인 시계열의 흐름과 다른 양상을 보이는 시점에서 경험적 모드분해법을 이용한 예측 유입량이 관측 유입량을 더 잘 나타내는 것을 확인하였고 이를 통해 기존의 시계열 모형이 가지고 있는 한계 및 불확실성을 분해를 통한 모형 구축으로 감소시킬 수 있음을 알 수 있었다.

RMSE 및 RRMSE를 통하여 두 모형간의 정확도를 비교한 결과, 모형훈련자료가 모형검증자료보다 낮은 값을 나타내며 두 기간 모두 경험적 모드분해법을 이용한 시계열 모형의 예측 유입량이 기존의 시계열 모형보다 더 낮은 RMSE 및 RRMSE 값을 보였다. 이에 따라 경험적 모드분해법을 이용한 시계열 모형이 기존의 시계열 모형보다 더 정확하게 예측 유입량을 산정하는 것을 알 수 있었다.

또한 한 시계열을 하나의 요소로 파악하고 모형을 구축하는 기존의 시계열 모형보다 주어진 시계열을 여러 요소로 분해한 후, 분해된 요소를 이용하여 시계열 모형을 구축하는 것이 기존의 시계열 모형이 가지고 있는 불확실성을 줄여줄 수 있으며 더 향상된 예측력을 보임을 확인하였다.

따라서 경험적 모드분해법을 활용한 시계열 예측으로 기존의 시계열 모형을 활용한 중장기적 시계열 예측 수립의 정확도 향상에 기여할 수 있을 것이며 경험적 모드분해법을 개선한 앙상블 경험적 모드분해법의 적용, 다른 수문자료의 적용 등 다양한 방면으로 추후 연구되어야 할

것이라 판단된다.

감사의 글

이 논문은 2014년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 한국연구재단에서 부여한 과제번호 : 2014006671).

References

Ahn, S.J., and Lee, J.K. (2000). "The Forecasting of Monthly Runoff using Stochastic Simulation Technique." *Journal of Korea Water Resources Association*, Vol. 33, No. 2, pp. 159-167.

Box, G.E.P., Jenkins, G.M., and Reinsel, G.C. (1976). *Time Series Analysis : Forecasting and Control*, Prentice-Hall International Inc.

Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N.C., Tung, C.C., and Liu, H.H. (1998). "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis." *Proceedings of the Royal Society of London. Series A*, Vol. 454, pp. 903-995.

Huang, N.E., and Wu, Z. (2008). "A review on Hilbert-Huang transform: method and its applications to geophysical studies." *Review of Geophysics*, Vol. 46, RG2006.

Kang, K.S., and Heo, J.H. (2006). "Comparative Study on Method of Stochastic Modeling in Han River Basin." 2006 Korea Water Resources Conference, Jeju, Korea, pp. 669-673.

Karthikeyan, L., and Kumar, D.N. (2013). "Predictability of nonstationary time series using wavelet and EMD

- based ARMA models.” *Journal of Hydrology*, Vol. 502, pp. 103–119.
- Kim, D.H., and Oh, H.S. (2006). “Hierarchical Smoothing Technique by Empirical Mode Decomposition.” *The Korean Journal of Applied Statistics*, Vol. 19, No. 2, pp. 319–330.
- Kim, D.H., and Oh, H.S. (2008). “EMD: A Package for Empirical Mode Decomposition and Hilbert Spectrum.” *The R Journal*, Vol. 1/1, pp. 40–46.
- Lee, T., and Ouarda, T.B.M.J. (2010). “Long-term prediction of precipitation and hydrologic extremes with nonstationary oscillation processes.” *Journal of Geophysical Research*, Vol. 115, D13107.
- Lee, T., and Ouarda, T.B.M.J. (2011). “Prediction of climate nonstationary oscillation processes with empirical mode decomposition.” *Journal of Geophysical Research*, Vol. 116, D06107.
- Lee, T., and Ouarda, T.B.M.J. (2012). “Stochastic simulation of nonstationary oscillation hydroclimatic processes using empirical mode decomposition.” *Water Resources Research*, Vol. 48, W02514.
- Musa, J.J. (2013). “Stochastic Modelling of Shiroro River Stream flow Process.” *American Journal of Engineering Research*, Vol. 2, Issue. 6, pp. 49–54.
- Sang, Y.F., Wang, Z., and Liu, C. (2012). “Period identification in hydrologic time series using empirical mode decomposition and maximum entropy spectral analysis.” *Journal of Hydrology*, Vol. 424–425, pp. 154–164.
- Sang, Y.F., Wang, Z., and Liu, C. (2014). “Comparison of the MK test and EMD method for trend identification in hydrological time series.” *Journal of Hydrology*, Vol. 510, pp. 293–298.
- Valipour, M., Banihabib, M.E., and Behbahani, S.M.R. (2013). “Comparison of the ARMA, ARIMA and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir.” *Journal of Hydrology*, Vol. 476, pp. 433–441.
- Wang, W.C., Chau, K.W., Xu, D.M., and Chen, X.Y. (2015). “Improving Forecasting Accuracy of Annual Runoff Time Series Using ARIMA Based on EEMD Decomposition.” *Water Resources Management*, Vol. 29, pp. 2655–2675.
- Wu, Z., and Huang, N.E. (2004). “A study of the characteristics of white noise using the empirical mode decomposition method.” *Proceedings of the Royal Society of London. Series A*, Vol. 460, pp. 1597–1611.
- Wu, Z., Huang, N.E., Long, S.R., and Peng, C.K. (2007). “On the trend, detrending, and variability of nonlinear and nonstationary time series.” *Proceedings of the National Academy of Science*, Vol. 104, No. 38, pp. 14889–14894.
- Yoon, S.K., Ahn, J.H., Kim, J.S., and Moon, Y.I. (2009). “Application to Evaluation of Hydrologic Time Series Forecasting for Long-Term Runoff Simulation.” *Journal of Korea Water Resources Association*, Vol. 42, No. 10, pp. 809–824.

paper number : 15-051

Received : 9 July 2015

Revised : 17 September 2015 / 8 October 2015

Accepted : 8 October 2015