Research Paper

The Applicability of Conditional Generative Model Generating Groundwater Level Fluctuation Corresponding to Precipitation Pattern

Jiho Jeong¹, Jina Jeong^{1,*}, Byung Sun Lee², Sung-Ho Song²

¹Department of Geology, Kyungpook National University, Daegu, South Korea

²Rural Research Institute, Korea Rural Community Corporation, Ansan, South Korea

*Corresponding author : jeong.j@knu.ac.kr

ARTICLE INFORMATION

Manuscript received 08 January 2021
Received in revised form 26 January 2021
Manuscript accepted 26 January 2021
Available online 26 February 2021

DOI : <http://dx.doi.org/10.9719/EEG.2021.54.1.77>

Research Highlights

- Low-dimensional features of groundwater level (GL) of multiple monitoring wells are extracted.
- Feature of GL under the same precipitation is acquired applying the conditional generative model.
- Statistical consistency of the extracted feature from the conditional generative model is improved.

ABSTRACT

In this study, a method has been proposed to improve the performance of hydraulic property estimation model developed by Jeong *et al.* (2020). In their study, low-dimensional features of the annual groundwater level (GWL) fluctuation patterns extracted based on a Denoising autoencoder (DAE) was used to develop a regression model for predicting hydraulic properties of an aquifer. However, low-dimensional features of the DAE are highly dependent on the precipitation pattern even if the GWL is monitored at the same location, causing uncertainty in hydraulic property estimation of the regression model. To solve the above problem, a process for generating the GWL fluctuation pattern for conditioning the precipitation is proposed based on a conditional variational autoencoder (CVAE). The CVAE trains a statistical relationship between GWL fluctuation and precipitation pattern. The actual GWL and precipitation data monitored on a total of 71 monitoring stations over 10 years in South Korea was applied to validate the effect of using CVAE. As a result, the trained CVAE model reasonably generated GWL fluctuation pattern with the conditioning of various precipitation patterns for all the monitoring locations. Based on the trained CVAE model, the low-dimensional features of the GWL fluctuation pattern without interference of different precipitation patterns were extracted for all monitoring stations, and they were compared to the features extracted based on the DAE. Consequently, it can be confirmed that the statistical consistency of the features extracted using CVAE is improved compared to DAE. Thus, we conclude that the proposed method may be useful in extracting a more accurate feature of GWL fluctuation pattern affected solely by hydraulic characteristics of the aquifer, which would be followed by the improved performance of the previously developed regression model.

Keywords : hydraulic property estimation, groundwater level fluctuation pattern, precipitation pattern, generative model, conditional variational autoencoder

Citation: Jeong, J., Jeong, J., Lee, B.S., Song, S.-H. (2021) The Applicability of Conditional Generative Model Generating Groundwater Level Fluctuation Corresponding to Precipitation Pattern, v.54, p.77-89, doi:10.9719/EEG2021.54.1.77.

✉ Journal homepage: <http://www.kseeg.org/main.html>

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided original work is properly cited.
pISSN 1225-7281; eISSN 2288-7962/©2021 The KSEEG. Printed by Hanrimwon Publishing Company. All rights reserved.

연구논문

조건부 생성모델을 이용한 강수 패턴에 따른 지하수위 생성 및 이의 활용에 관한 연구

정지호¹ · 정진아^{1,*} · 이병선² · 송성호²

¹경북대학교 지질학과

²한국농어촌공사 농어촌연구원

*책임저자 : jeong.j@knu.ac.kr

요 약

본 연구에서는 Jeong *et al.* (2020)의 연구에서 수행된 지하수위 변동 패턴의 저차원 특징추출 과정의 문제점을 분석하고, 이에 대한 개선방안이 제안된다. 해당 연구에서는 Denoising autoencoder (DAE)를 이용해 전국의 연 단위 지하수위 변동 자료로부터 저차원 특징이 추출되며, 추출된 자료를 이용해 대수층의 수리 특성값을 예측하는 회귀 모델이 개발되었다. 그러나 특정 지역의 연도별 강수 패턴이 달라질 경우, 지하수위 변동 패턴 및 저차원 특징 또한 달라지며, 이에 따라 동일 지역임에도 불구하고 저차원 특징으로부터 추정되는 수리 특성값이 다양하게 나타날 수 있다. 이러한 문제를 해결하기 위해, 본 연구에서는 조건부 생성 모델인 Conditional variational autoencoder (CVAE)를 이용하였으며, 전국 71개 지역에서 10년 동안 획득된 지하수위 자료와 강수 자료 간 상관관계가 학습되었다. 학습된 모델을 통해 모든 지역에 대해 동일 강수 조건이 적용될 때의 지하수위 자료가 생성되었으며, 생성된 지하수위 자료로부터 저차원 특징이 추출되었다. CVAE를 이용해 동일 강수 조건으로 생성된 지하수위 자료의 저차원 특징과 기존 DAE를 통해 추출된 저차원 특징이 비교되었으며, 그 결과 CVAE를 이용해 추출된 저차원 특징 간 거리가 저차원 공간상에서 보다 가깝게 분포하는 것이 확인되었다. 따라서 제안된 방법을 이용할 경우 대수층 특성에만 영향을 받는 지역별 지하수위 자료 및 저차원 특징이 효과적으로 추출될 수 있으며, 이를 통해 기존 개발된 회귀 모델의 성능이 개선될 수 있을 것으로 판단된다.

주요어 : 대수층 수리특성 예측, 지하수위 변동 패턴, 강수 패턴, 생성모델, 조건부 변분 오토인코더

1. 서 론

지하수 자원의 효율적인 개발을 위해 대수층의 수리적 특성을 파악하는 일은 필수적이다(Maggirwar *et al.*, 2011; Kumar *et al.*, 2016). 이러한 수리적 특성과 관련된 정보들은 소규모의 실험실 테스트에서부터 현장 규모의 대수층 테스트에 이르기까지 다양한 실험을 기반으로 획득될 수 있다(Smith *et al.*, 1970; Wellings, 1984; Cooper *et al.*, 1990; Price *et al.*, 2000). 그러나 이러한 대수층에 대한 직접적인 실험을 통해 신뢰할 만한 정보를 확보할 수 있지만, 시험 장비의 성능, 정확한 시험 절차 준수 여부 등에 따라 결과가 달라질 수 있다(Yeh and Huang, 2005).

최근에는 다양한 모델링 기법들을 적용해 대수층의 수리 특성값들을 획득하고자 하는 연구들이 이어지고 있다(Jeong and Park, 2017; Jeong *et al.*, 2019). 모델링 기법을 이용한 대수층 특성 연구는 크게 물리적 프로세스 기반(physical process-based) 분석과 자료 기반(data-driven) 분석으로 분류할 수 있다(Felisa *et al.*, 2015; Manzione,

2017). 먼저 물리적 프로세스 기반 분석 방법은 해당 대수층 시스템에 존재하는 다양한 물리적 법칙에 대한 이해를 바탕으로 해당 지역의 수리 특성값을 유추하는 방법이다(Bierkens, 1998; Knotters and Bierkens, 2000; Rai *et al.*, 2006; Park and Parker, 2008; Cuthbert, 2010; Jeong and Park, 2017; Jeong *et al.*, 2019). 이와 관련된 연구들은 대수층 시스템을 간접적으로 지시하는 지하수위 변동 자료에 대한 물리 기반 수학적 모델(physically-based mathematical model)을 이용해서 대수층의 수리적 특성을 예측할 수 있음을 보여준다. 그러나 이러한 모델링 기법은 대수층 시스템에 대한 물리적 해석이 반드시 전제되어야 하므로, 다양한 특성의 대수층 시스템을 해석하는데 제약이 있다(Adamowski and Chan, 2011; Nourani *et al.*, 2015; Han *et al.*, 2015). 반면, 자료 기반 모델링 기법은 대수층으로부터 획득한 모니터링 자료에 대한 통계 분석을 기반함에 따라 대수층 시스템의 물리적 상관관계에 대한 이해가 부족한 경우에도 효과적으로 대수층의 수리학적 특성을 유추할 수 있다(Bakker and Schaars,

2019). 대표적인 자료 기반 연구 주제로는 시계열 분석 및 교차 상관분석을 이용한 불포화 대수층 수분 침투 과정 연구가 있다(Delbart *et al.*, 2014; Neto *et al.*, 2015; Jeong *et al.*, 2017). 이러한 연구들은 대수층 시스템에 대한 사전지식 없이도 대수층 수리 특성을 해석할 수 있다는 자료 기반 분석의 장점을 보여준다.

최근에는 모니터링 기술의 발전으로, 보다 많은 양의 양질의 지하수위 자료를 활용할 수 있게 됨에 따라 자료 기반 모델링을 위한 기계학습 기법 활용 연구 사례가 증가하고 있다(Joo *et al.*, 2009; Coulibaly *et al.*, 2001; Yoon *et al.*, 2011; Nourani *et al.*, 2012; Jeong and Park, 2019). 특히, 인공신경망(Artificial Neural Network, ANN)을 기반으로 하는 딥러닝 기법(예를 들어, 순환신경망)을 활용한 지하 수질 및 수량 평가 연구가 활발하게 진행되고 있다(Coppola *et al.*, 2005; Almasri and Kaluarachchi, 2005; Nayak *et al.*, 2006; Jeong and Park, 2019; Jeong *et al.*, 2020), 그 중, Jeong *et al.* (2020)은 국내 다양한 지역에서 획득한 장기 시계열 지하수위 변동 패턴을 이용하여 보다 효율적으로 수리 특성값을 예측하기 위한 자료 기반 방법을 개발하기 위하여 지하수위 변동 패턴을 입력으로 하고 대수층 수리 특성값을 출력으로 하는 회귀 모델을 개발한 바 있다. 특히, 해당 연구를 통해 지역별 대수층의 수리학적 특성이 달라 지하수위 변동 패턴의 차이가 발생하는 것이 확인되었으며, 이에 따라, 지역별 대수층의 물리적 특성이 지하수위 변동 패턴 분류를 통해 효율적으로 해석 가능성이 검증된 바 있다. 그러나 지하수위 변동 패턴은 해당 지역 대수층의 수리학적 특성뿐만 아니라 강수 패턴에 의해서도 다르게 나타난다. 이에 따라, 연도별 강수량 차이로 인하여 동일 지역임에도 불구하고 지하수위 변동 패턴이 달라질 수 있으며 이

러한 이유로 지하수위 변동 패턴으로부터 추정된 수리 특성값의 불확실성이 증가하게 된다. 또한, 동일시기지만 지역마다 강수 패턴이 달라 지하수위 변동 패턴이 달라지며, 이는 지역별 대수층의 수리학적 특성 비교를 어렵게 한다. 이와 같이 Jeong *et al.*(2020)에서 개발된 기법이 대수층의 물리적 프로세스에 대한 사전정보 없이 효율적으로 대수층의 수리특성을 추정하는 데 유용하나, 다양한 외부 환경적 조건에서 형성된 지하수위 변동 자료를 이용함으로써 인해 개발 모델을 통해 추정된 결과에 대한 불확실성 문제가 존재할 수 있다.

본 연구에서는 위 기술된 Jeong *et al.*(2020)의 연구의 문제점을 해결하기 위한 자료 기반 모델링 기법을 고안 및 이의 성능을 검증하고 연구 결과의 대수층 특성 추정 모델 성능 향상예의 활용성을 평가하였다. 이를 위하여, 외부 기상환경을 고려하여 지하수위 변동 패턴을 생성할 수 있는 조건부 생성 모델(Conditional Generative Model)을 이용하였으며, 이때, 지하수위 변동 패턴은 강수를 기준으로 생성되었다. 본 연구를 통해 고안된 방법은 한국수자원공사 국가지하수관측망을 통해 획득한 일 단위 시계열 지하수위 변동 자료 및 강수량 자료를 이용하여 검증되었다.

2. 연구지역 및 이용 자료

본 연구에 이용된 지하수위 변동 및 강수 자료는 국가 지하수정보센터 한국수자원공사 지하수 관측망으로부터 획득되었다. 분석에는 전국에 걸쳐 분포하는 71개 관측소에서 획득된 10년치 일 평균 자료가 이용되었으며 Fig. 1의 붉은 점은 이용된 관측공의 위치를 나타낸다. 또한, 훈련 모델의 성능을 향상시키기 위해 전체 자료를 대상으로 몇 가지 전처리 단계가 적용되었다. 먼저, 12월-1월

Fig. 1. Location of the applied groundwater monitoring stations.

Table 1. Monthly precipitation rates (P) in South Korea over the last 30 years (M: the mean; Std: the standard deviation)

		Jan.	Feb.	Mar.	Apr.	May	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.
P (mm)	M	31.8	37.5	59.6	83.2	106.7	163.7	293.2	281.1	165.3	52.4	48.1	26.7
	Std	16.0	13.1	20.4	26.9	30.4	40.7	58.4	50.4	33.2	16.7	13.7	14.1

기간은 강수가 거의 일어나지 않으며(Table 1) 지표 토양의 동결 등으로 인해 함양량이 감소하기 때문에(Luo *et al.*, 2002), 강수와 지하수위 변동 간 뚜렷한 관계를 확인하기 어렵다. 따라서 2월 - 11월 기간에 해당되는 지하수위 변동 자료가 선택적으로 이용되어, 최종적으로 300일의 일 평균 지하수위 및 강수 자료가 이용되었다. 다음으로 자료에 존재하는 결측값 보완을 위해 이동 평균 필터(moving average filter)가 적용되었다(Lyandres and Briskin, 1993). 이동 평균 필터는 일정 크기를 갖는 윈도우가 이동하며 주위 값들에 비해 높거나 낮은 값을 탐지하는 기법으로, 본 연구에서는 10일의 윈도우 크기를 갖는 필터가 적용되었으며 탐지된 이상값에 대해서는 해당 값을 제거한 후 선형 보간을 실시하였다. 또한, 모든 자료는 전국의 다양한 관측공으로부터 획득되었기 때문에, 각기 다른 평균 및 분산 값을 나타낸다. 따라서 모델 훈련에 자료를 그대로 이용할 경우 비교적 큰 값을 나타내는 자료에 편향되게 학습이 진행될 수 있기 때문에, 본 연구에서는 훈련 과정에서 있어 모든 자료가 동일한 중요도로 반영될 수 있도록 지하수위 및 강수 자료에 대해 최대-최소 정규화(min-max regularization)를 적용하여 자료의 범위를 0에서 1 사이로 변환 후 분석에 적용하였다.

3. 방법론

Jeong *et al.* (2020)은 Denoising autoencoder (DAE)를 이용해 고차원 지하수위 변동 패턴으로부터 저차원 특징

을 추출한 뒤, 대수층 수리 특성값을 반응변수(response variable) 및 추출된 저차원 특징 자료를 설명변수(explanatory variable)로 이용하는 회귀 모델을 개발한 바 있다(Fig. 2에서 실선 화살표). 그러나 해당 연구는 지하수위 변동 패턴의 다양성이 지역별 대수층의 수리학적 특성에만 기인한다는 해석을 바탕으로 수행되었기 때문에, 지하수위 변동 패턴에 영향을 미칠 수 있는 추가적인 요소인 강수 패턴이 고려되지 않았다. 이에 따라 동일 지역임에도 불구하고 연도별 강수 패턴의 차이로 인해 지하수위 변동 패턴이 달라지며, 최종적으로 이를 이용한 대수층 수리 특성값 예측 결과가 다르게 나타날 수 있다. 이러한 문제점을 해결하기 위해 본 연구에서는 지역별 강수 자료를 이용하여 강수 패턴 변화에 의한 효과를 줄여 줄 수 있는 과정을 기존 연구에 추가하였다(Fig. 2에서 점선 화살표). 해당 과정은 지역별 강수 패턴에 대한 지하수위 변동 패턴을 학습하는 Conditional variational autoencoder (CVAE) 훈련 과정 및 훈련된 CVAE를 기반으로 동일 강수 조건에 대한 지하수위 변동 패턴 저차원 특징을 추출하는 단계로 구성된다. 본 연구에서는 이와 같이 구상된 방법의 대수층 수리 특성값 예측 모델 성능 향상에 대한 효과를 평가하고자 하였으며, 이를 위해 CVAE 모델 훈련 결과에 대한 검증 및 결과에 대한 분석이 수행되었다.

3.1. Conditional Variational Autoencoder

CVAE는 기계학습 기법과 변분 추론(variational inference)

Fig. 2. Comparison between the methods proposed by the previous study (Jeong *et al.*, 2020) and the present study.

Fig. 3. Conceptual diagram of the training process of the proposed CVAE in this study.

을 이용한 잠재 변수 및 조건 변수(latent and conditioning variable) 기반의 확률론적 생성 모델이다(Sohn *et al.*, 2015). 본 연구에서는 전국의 지하수위 관측공을 대상으로 특정 강수 조건이 부여될 때 발생하는 지하수위 변동 패턴을 학습하기 위해 CVAE가 이용되었다. Fig. 3은 연구에 사용된 CVAE 모델의 구조를 나타낸다. 그림에서 CVAE 네트워크는 인코더를 이용해 입력 변수($\mathbf{X}$)를 표현할 수 있는 잠재 변수($\mathbf{Z}$)의 확률분포(평균: μ , 분산: σ^2)를 모델링하고 디코더를 이용해 학습된 분포로부터 새로운 자료($\mathbf{X}'$)를 생성하며, 자료 생성 과정에서 조건 변수($\mathbf{S}$)을 이용해 특정 조건을 부여할 수 있다. 본 연구에서는 연 단위 지하수위 자료를 입력 변수로, 강수 및 지역 번호 자료를 조건 변수로 갖는 네트워크 훈련이 진행되었다. 이에 따라 지역별로 특정 강수 조건에 따른 지하수위 자료를 생성하기 위한 조건부 확률 분포가 학습되었으며, 훈련된 네트워크를 이용해 모든 지역에 동일 강수 조건이 부여될 때의 지하수위 변동 패턴을 생성할 수 있다.

3.2. CVAE 모델 설계

모델의 입력 및 출력으로는 300일의 지하수위 자료($\mathbf{X}$)가 이용되기 때문에, 실험에 사용된 CVAE 모델의 입력층(Input layer)과 출력층(Output layer)에는 300개의 입력 뉴런이 설정되었다. 다음으로 인코딩 및 디코딩층(Encoding and Decoding layer)은 각각 300개의 뉴런으로 구성된 3개의 층으로 구성되어 있으며, 잠재 변수 층은 80개의 뉴런이 구성되었다. 조건 변수($\mathbf{S}$)는 300일의 강수 자료($\mathbf{S}_1$)와 71개 지역에 해당하는 지역 번호($\mathbf{S}_2$)가 적용되어 총

371개의 뉴런으로 구성되었으며, 이때, 지역 번호 자료는 원-핫 인코딩(One-Hot Encoding)을 이용해 구성되었다. 모델 네트워크의 각 층을 연결해주는 활성화 함수(Activation function)는 Leaky ReLU (Leaky rectified linear unit)가 적용되었다. 다음으로 네트워크 훈련을 통해 획득되는 인코딩 파라미터 ϕ 및 디코딩 파라미터 θ 는 목적 함수(Objective function, L)를 최소화하는 과정을 통해 결정되며, 식은 아래와 같다.

$$L_i(\phi, \theta, \mathbf{x}_i) = E_{q_\phi(\mathbf{z}|\mathbf{x}_i)}[\log(p_\theta(\mathbf{x}_i|\mathbf{z}))] + KL(q_\phi(\mathbf{z}|\mathbf{x}_i)||p(\mathbf{z})) \quad (1)$$

식 (1)은 i 번째 입력 변수 $\mathbf{x}_i$ 에 대한 목적 함수 L_i 를 나타낸다. 식 우측의 첫 번째 항은 로그 우도 함수로, 생성 모델을 통해 현재 샘플링된 잠재 변수 $\mathbf{Z}$ 를 통해 입력 변수를 재구성할 수 있다. 또한, 이를 통해 재구성 손실(Reconstruction loss)을 계산할 수 있으며, 오차는 실제 값과 재구성된 자료 간 평균 제곱 오차(Mean squared error, MSE)를 통해 계산된다. 식 우측의 두 번째 항은 Kullback-Leibler (KL) 발산을 나타내며, 두 확률분포($q_\phi(\mathbf{z}|\mathbf{x}_i)$ 및 $p_\theta(\mathbf{x}_i|\mathbf{z})$)의 유사도를 측정한다. 또한, KL 발산을 최소화함으로써 사전 분포와 유사한 잠재 변수 $\mathbf{Z}$ 를 샘플링 할 수 있게 된다. 완성된 목적 함수를 통해 파라미터를 최적화하는 과정에서, 목적 함수의 기울기를 효율적으로 계산하기 위해 Kingma and Welling (2014)이 제안한 Reparameterization trick을 이용했다. CVAE 모델에 대한 보다 자세한 내용은 Shon *et al.* (2015)를 참고할 수 있다. 구성된 CVAE 모델을 이용한 모든 실험은

Intel® Xeon® Gold 6240 CPU 2.60GHz, NVIDIA Quadro P400 GPU, Python-Pytorch 환경에서 진행되었다.

4. 결과 및 논의

4.1. 강수 패턴 변화에 따른 지하수위 변동 자료의 저차원 특징 변화

본 연구에서는 동일한 대수층 시스템에서 발생한 지하수위 변동 패턴이 Jeong *et al.* (2020)에서 이용한 DAE 네트워크를 이용하여 저차원 특징으로 추출되었을 때, 해당 저차원 특징이 강수 패턴 변화에 따라 달라지는지 확인하였다. 이를 위해, PP 모델(Park and Parker, 2008)을 이용하여 동일한 수리학적 특성의 대수층에서 발생하였으나 강수 시점이 다른 세 가지 케이스에 대한 가상 지하수위 자료를 생성하였다. 각 세트는 총 365일의 시계열 자료로 구성되며, Fig. 4a는 이용된 시계열 지하수위 자료를 보여준다. 각 케이스 모두 0.05의 지하수위 저감 계수 및 0.1의 지하수 함양 계수(각각, k 및 αn (Park and Parker, 2008))가 동일하게 적용되었으며, 각 케이스마다 100일, 170일 및 240일에 동일 양의 강수가 발생하였음을 가정하였다. DAE 네트워크 훈련을 위해서, 세 가지의 가상 지하수위 자료에 가우시안 노이즈($\varepsilon \sim N(\mu = 0, \sigma = 1)$)가 추가되어 만들어진 총 900개의 자료(각 케이스별 300개)가 훈련에 이용되었다.

훈련된 DAE 네트워크를 통해 추출된 지하수위 자료의 저차원 특징은 kernel PCA (Scholkopf *et al.*, 1996)을 이용해 2차원 공간에 시각화되었으며, 이는 Fig. 4b에서 확인할 수 있다. 각기 다른 강수 조건에 의해 생성된 900개의 가상 지하수위 변동 패턴은 저차원 공간에서 3개의 군집(C1, C2, 및 C3)으로 구분되는 것을 확인할 수 있다.

이러한 결과는 동일 대수층 특성값을 갖는 지역이라도 강수의 양상에 따라 지하수위 변동 패턴이 달라지며, 추출된 저차원 특징 또한 다르게 나타날 수 있음을 의미한다. 따라서 수리 특성값 예측 회귀 모델의 입력 자료로 사용되는 지하수위 자료에 지역별 강수의 패턴이 반영될 경우 추출된 저차원 특징 자료가 영향을 받게 되며, 이는 회귀 모델의 예측 성능을 감소시키는 원인이 될 수 있다. 이를 해결하기 위하여, 본 연구에서는 CVAE 모델을 이용해 지역별 강수 패턴이 동일한 조건에서의 지하수위 변동 패턴을 생성하고, 생성된 지하수위 자료로부터 추출된 저차원 특징이 최종적으로 연구에 이용되도록 방법을 고안하였다.

4.2. 조건부 생성 모델의 활용

4.2.1. 학습된 조건부 생성 모델의 성능 검증

본 연구를 통해 제안된 CVAE 모델의 지하수위 생성 성능을 검증하기 위하여 특정 강수 패턴 및 지역 번호를 적용하여 얻은 추정 지하수위 값을 실제 값과 비교하였다. 입력 자료로 연 단위 지하수위, 조건 변수로 강수 및 지역 번호 자료가 이용되었으며, 전체 71개 지역에서 10년 동안 획득된 연 단위 자료 710개 중 각 지역별 9년간의 자료(즉, 총 639개 자료)가 CVAE를 훈련하는데 적용되었으며, 각 지역별 나머지 1년간 자료인 총 71개의 지

Table 2. Statistics of the calculated root mean squared error (RMSE) and correlation coefficient (CC) values between the actual and the generated GWL fluctuation patterns

	Mean	Median
RMSE	0.0831	0.0310
CC	0.9370	0.9548

Fig. 4. (a) Three different types of groundwater level (GWL) fluctuation patterns generated from the PP-model with different precipitation patterns. (b) The corresponding low-dimensional features of GWL patterns extracted based on the DAE network.

하수위 변동 자료가 테스트에 이용되었다. 테스트 결과를 정량적으로 평가하기 위해 Root Mean Squared Error (RMSE)와 Correlation Coefficient (CC)를 이용해 실제 지하수위와 생성된 지하수위 자료 간 유사도가 평가되었으

며, 결과는 Table 2에서 확인할 수 있다. 평가 결과, 실제 지하수위 자료와 CVAE를 이용해 생성된 지하수위 자료 간 RMSE는 평균 0.08 (m)이며 상관계수는 평균 0.93 이상으로 나타났다. CVAE를 이용한 지하수위 예측 결과의

Fig. 5. Examples of performance validation results of the proposed CVAE in this study. In the figure, the black and the red solid line indicate the actual and the generated GWL fluctuation pattern from the trained CVAE model, respectively, and the blue solid line shows the precipitation pattern.

Fig. 6. Comparison of the pattern of GWL fluctuations generated from the trained CVAE model using the different precipitation patterns at the same location of (a) monitoring station # 1 and (b) monitoring station # 2.

예시는 Fig. 5에서 확인할 수 있다. X축은 시간, Y축은 지하수위를 나타내며 검은색 실선은 실제 지하수위, 붉은색 실선은 모델을 이용해 재구성된 지하수위이고 푸른색 바는 강수를 나타낸다. 그림에서 보는 바와 같이 CVAE를 이용하여 생성된 지하수위와 실제 지하수위가 굉장히 유사하게 나타나고 있다.

훈련된 CVAE 네트워크를 통한 지하수위 예측 결과에 영향을 미칠 수 있는 요소는 강수와 지역 번호가 있다. 만일 특정 지역의 지하수위가 강수와 높은 상관관계를 보이는 경우, 해당 지역의 강수 변동 패턴이 지하수위 자료 생성에 지배적인 영향을 미치게 된다. 반대로 지하수위와 강수가 낮은 상관관계를 보일 경우, 해당 지역은 강수에 의한 영향보다 지역적인 특성에 영향을 더 많이 받아 지하수위 변동 패턴이 만들어질 가능성이 높다. Fig. 6은 CVAE를 이용한 지하수위 자료 생성에 강수 패턴이 미치는 영향력을 확인하기 위해 실시한 테스트 결과를 보여준다. Fig. 6a와 Fig. 6b의 좌측 그림은 실제 해당 지역의 강수 자료를 이용해 지하수위를 생성한 결과이고, 우측 그림은 강수 자료를 변경했을 때 생성되는 지하수

위 자료이다. 첫 번째 지역(Fig. 6a)의 경우 강수가 변함에 따라 생성되는 지하수위 변동 패턴이 두 번째 지역(Fig. 6b)보다 크게 변화하는 것을 확인할 수 있다. 이러한 경우 해당 지역의 지하수위 변동에 강수가 지배적인 영향을 미치는 것으로 해석할 수 있다. 반면, 두 번째 지역(Fig. 6b)의 경우 강수 자료가 변경되었음에도 불구하고 실제 생성된 지하수위 자료에는 큰 영향을 미치지 않으며, 이는 강수보다 다른 국지적 외부 특성들이 지하수위 생성에 더 큰 영향을 준 것으로 해석할 수 있다(예를 들어, 근거리 하천의 존재).

위 두 결과를 통해 본 연구를 통해 고안된 CVAE를 이용하여 생성된 지하수위 변동 패턴이 지역 특성을 반영하여 실제와 유사하게 나타남을 검증하였다. 따라서 학습된 CVAE 모델을 이용하여 모든 관측점에서 동일한 강수 패턴 조건을 기반으로 지하수위 변동 패턴의 저차원 특성을 추출하였으며, 이의 성능이 지하수위 변동 패턴 기반 대수층 수리 특성값 예측 모델의 성능 향상에 미치는 효과를 평가하였다.

Fig. 7. Several examples of the comparisons between the low-dimensional GWL fluctuation features extracted by DAE and CVAE model. The first panel shows the GWL fluctuation pattern of the exemplified monitoring stations, and the middle and last panel shows the low-dimensional annual GWL fluctuation pattern for 10 years and their distribution (red dots and blue circle) extracted by DAE and CVAE models for the corresponding monitoring station.

4.2.2. 조건부 생성 모델을 이용한 고차원 지하수위 변동 패턴 특징추출

Fig. 7은 특정 지역에 대한 대표 지하수위 변동 패턴, DAE 및 CVAE를 이용하여 추출된 2차원 지하수위 특징

을 보여준다. 71개 관측공에서 10년간 관측된 연 단위 지하수위의 2차원 특징이 검은색 점으로 표현되었으며, 예시로 제시된 특정 관측정의 지하수위 변동 패턴에 대한 2차원 추출 특징은 붉은색 점으로 표현되었다. 총 10년

Table 3. The statistics of the Euclidean distances between the low-dimensional features of the annual GWL fluctuation patterns extracted by the DAE and CVAE models for each monitoring station

Station #	DAE		CVAE		Station #	DAE		CVAE	
	Mean	Median	Mean	Median		Mean	Median	Mean	Median
1	0.1587	0.1499	0.1292	0.1193	37	0.2226	0.1428	0.2671	0.1830
2	0.1238	0.1201	0.0813	0.0797	38	0.2227	0.2144	0.2211	0.1994
3	0.2260	0.2259	0.3294	0.4083	39	0.1937	0.1937	0.1428	0.1364
4	0.2480	0.2882	0.2688	0.2381	40	0.2398	0.1753	0.1924	0.1535
5	0.3012	0.3264	0.3299	0.3235	41	0.2591	0.2703	0.3025	0.3045
6	0.2207	0.2186	0.2756	0.3111	42	0.1741	0.1810	0.1417	0.1622
7	0.1446	0.1483	0.1220	0.0986	43	0.2134	0.1760	0.2723	0.2130
8	0.3339	0.3373	0.1963	0.1863	44	0.1586	0.1502	0.0888	0.0907
9	0.2875	0.2836	0.2445	0.2485	45	0.2164	0.2257	0.1866	0.1692
10	0.2181	0.2050	0.2254	0.1984	46	0.1864	0.1580	0.1505	0.1214
11	0.3032	0.2409	0.2526	0.2364	47	0.2016	0.2323	0.2507	0.2544
12	0.2020	0.1641	0.1893	0.2003	48	0.1956	0.1829	0.1962	0.1651
13	0.3156	0.3222	0.3321	0.3491	49	0.1911	0.1583	0.1812	0.1695
14	0.1875	0.1879	0.1663	0.1501	50	0.1606	0.1730	0.1179	0.1297
15	0.2544	0.2466	0.3145	0.3536	51	0.4506	0.4658	0.5349	0.5328
16	0.2538	0.2086	0.3328	0.2773	52	0.1694	0.1669	0.1979	0.1873
17	0.1607	0.1764	0.1100	0.1084	53	0.1627	0.1645	0.1360	0.1427
18	0.1932	0.1711	0.1882	0.1661	54	0.2193	0.1884	0.1899	0.1522
19	0.2447	0.2093	0.2477	0.2279	55	0.2304	0.2491	0.2634	0.2434
20	0.1663	0.1688	0.1680	0.1522	56	0.3024	0.2820	0.3389	0.3325
21	0.1761	0.1769	0.1298	0.1021	57	0.2801	0.2672	0.2700	0.2878
22	0.3125	0.2809	0.3031	0.2732	58	0.2274	0.2424	0.1637	0.1296
23	0.1560	0.1781	0.1612	0.1230	59	0.2198	0.2075	0.2337	0.2373
24	0.2277	0.2319	0.2642	0.2424	60	0.2340	0.1968	0.1714	0.1443
25	0.1958	0.1800	0.1255	0.1032	61	0.1316	0.1270	0.0807	0.0756
26	0.1800	0.1473	0.1713	0.1540	62	0.1672	0.1908	0.1169	0.1199
27	0.2407	0.1834	0.2338	0.2121	63	0.1453	0.1430	0.1250	0.1081
28	0.2173	0.2084	0.2150	0.2035	64	0.1848	0.1671	0.1634	0.1428
29	0.1598	0.1546	0.1332	0.1133	65	0.2527	0.2383	0.4053	0.3822
30	0.1410	0.1443	0.1391	0.1190	66	0.1896	0.1721	0.1597	0.1640
31	0.2031	0.1965	0.2780	0.2386	67	0.3141	0.2401	0.3225	0.2564
32	0.3682	0.2076	0.4163	0.3764	68	0.1378	0.1519	0.1206	0.0986
33	0.2830	0.2504	0.2378	0.2243	69	0.1285	0.0985	0.1146	0.1019
34	0.2503	0.2116	0.2293	0.2170	70	0.1932	0.1799	0.2697	0.2829
35	0.1615	0.1655	0.1105	0.0910	71	0.1421	0.1487	0.1047	0.1067
36	0.2150	0.2042	0.1739	0.1797					
Mean						0.2162	0.2034	0.2116	0.1984
Median						0.2134	0.1884	0.1924	0.1797

간의 연 단위 지하수위에 대한 저차원 특징임에 따라 총 10개의 붉은색 점이 그림에 도시되며, 저차원 특징들의 분포 범위가 푸른색 원으로 표시되었다. 그림에서 보는 바와 같이 DAE를 이용하여 추출된 10년간의 지하수위 변동 특징이 CVAE를 이용하여 추출된 결과보다 상대적으로 자료 차원상에서 넓게 분포하고 있는 것을 확인할 수 있다. 동일 관측점에서 관측된 지하수위 변동 패턴은 동일한 대수층 시스템으로부터 발생함에 따라 해마다 강수량이 같을 경우, 유사한 패턴으로 나타나게 되어 저차원의 특징 또한 유사하게 나타나게 된다. 그러나 연간 강수 패턴이 해마다 달라질 경우, 동일 대수층에서 관측되었음에도 다른 지하수위 패턴을 보이게 되며, 이러한 이유로 10년 동안의 저차원 연간 지하수위 변동 패턴 특징이 달라져 그림에서 보는 바와 같이 자료 차원상에서 분산되어 분포할 수 있다. 이는 대수층 특성값을 예측하는 회귀 모델을 개발하는 데 있어, 동일한 대수층 시스템을 설명하는 설명변수(즉, 저차원 지하수위 변동 특징)의 통계적 유의성이 낮음을 의미하며 이에 따라 회귀 모델의 예측 성능 또한 저하되는 부정적 효과를 가져오게 된다. 반면, CVAE를 이용한 저차원 특징추출 결과는 동일한 강수 조건에서 생성된 지하수위 변동 패턴을 이용함에 따라 지하수위에 대하여 추출된 저차원 특징값이 유사하게 나타난다. 이는 Fig. 7에서 CVAE를 이용한 차원 축소 결과에서의 붉은색 점 자료가 DAE를 이용한 결과에 비하여 상당히 좁은 공간상에 분포하는 것을 통해 확인할 수 있다. 이는 CVAE를 이용하여 강수 변화에 따른 지하수위 변동 패턴의 특징 변화 현상을 제거함으로써 대수층의 수리학적 특성 차이로 인한 특징을 보다 효과적으로 분류할 수 있음을 의미한다.

CVAE 적용을 통한 대수층 특성 설명변수 통계적 유의성 증가 효과를 정량적으로 확인하기 위하여 DAE 및 CVAE를 이용하여 추출된 연도별 저차원 특징값 간 유클리디안 거리(Euclidean distance)를 산정하고 이에 대한 평균 및 중앙값의 변화를 비교 분석하였다. 총 10년 동안의 연 단위 지하수위 저차원 특징 간 거리를 산정함에 따라 C_2 개의 조합이 가능하며, 이에 각 위치당 총 45개의 유클리디안 거리가 산정 및 분석에 이용되었다. 이를 위해, 각 관측공에서 10년에 해당하는 10개의 연 단위 지하수위 저차원 특징 간 거리를 산정하고 이들의 평균 및 중앙값을 산정하였으며, 이를 DAE 및 CVAE를 이용하여 추출된 저차원 특징에 적용 및 비교하였다. Table 3은 각 관측공에서의 저차원 특징 간 거리의 평균 및 중앙값과 이에 대한 평균 및 중앙값을 보여준다. 전체 관측공에 대한 DAE 기반 저차원 특징 간 평균 거리의 평균값 및 중앙값은 각각 0.2162에서 0.2116으로 나타났으며,

CVAE 기반 산정 평균 거리의 평균 및 중앙값은 이 보다 작은 0.2134에서 0.1924로 나타났다. 저차원 특징 간 거리의 중앙값에 대해서 또한, 평균값에 대한 결과와 동일하게 CVAE를 이용한 경우가 DAE를 이용한 거리 간 평균 및 중앙값이 더 작게 나타났다(평균 및 중앙값에 대하여 CVAE: 0.1884 및 0.1797; DAE: 0.2034 및 0.1984).

이와 같이, 두 경우 모두 강수 컨디셔닝을 실시한 이후 각 지역의 연도별 자료 간 거리가 감소했으며, 강수 컨디셔닝에 의한 저차원 특징 변화는 지하수위 변동 패턴이 강수와 높은 상관관계를 보이는 지역이 그렇지 않은 지역에 비해 크게 나타나는 것을 확인할 수 있었다. 따라서, CVAE를 이용해 모든 지역에 대해 동일 강수 조건을 부여할 경우 지역별로 다른 강수 패턴에 의한 영향 없이 대수층의 수리학적 특성에만 기인한 지역별 지하수위 변동 자료를 얻을 수 있게 된다. 이러한 결과를 통해, CVAE를 이용함으로써 대수층 특성에만 영향을 받는 지역별 대표 지하수위 저차원 특징이 효과적으로 추출될 수 있음을 확인하였으며, 이는 곧 본 연구에서 고안된 방법이 대수층 수리 특성값 예측 모델의 성능 향상에 효과적으로 적용될 수 있음을 의미한다.

5. 결 론

지하수위의 변동 패턴은 대수층의 수리특성을 설명해주는 중요한 간접 정보이다. 이에 따라 Jeong *et al.*(2020)은 전국의 연 단위 지하수위 변동 패턴을 기반으로 대수층의 수리 특성값을 예측하는 자료 기반 회귀 모델을 개발한 바 있다. 특히 해당 연구에서는 지하수위 변동 패턴의 저차원 특징을 이용하는 대수층 수리 특성값 예측을 위한 회귀 모델을 개발하였다. 그러나 연도별 강수 패턴이 달라질 경우, 지하수위 변동 패턴이 달라져 지하수위 변동 패턴의 저차원 특징이 달라지고 이에 따라 동일 지역임에도 불구하고 연도별 다른 대수층 수리 특성값이 측정되는 문제가 발생하는 것을 확인하였다. 따라서, 본 연구에서는 이러한 문제를 해결하기 위한 방법을 고안하고 이의 성능을 검증 및 분석하였다. 이를 위해, CVAE를 이용해 지역별 강수와 지하수위 변동 패턴 간 관계를 학습한 뒤, 모든 지역에 대해 동일 강수 조건에서의 지하수위를 획득하였으며, 이를 기반으로 저차원 특징을 추출하고 회귀 모델에 이용하고자 하였다.

고안된 방법의 성능을 검증하기 위하여 전국 총 71개 관측점에서 10년 동안의 지하수위 및 강수 자료를 획득하고 CVAE 모델을 훈련 및 저차원 특징을 추출하였다. CVAE를 이용하여 추출된 동일 강수 조건에서의 지하수위 저차원 특징을 DAE를 이용하여 추출된 저차원 특징

과 비교하였으며, 그 결과, CVAE를 이용해 추출된 10년 동안의 연간 지하수위 저차원 특징이 자료 공간상에서 서로 간 보다 근거리 존재함을 확인하였다. 이는 본 연구에서 제안된 방법을 통해 대수층의 특성에만 영향을 받는 지역별 대표 지하수위 자료 및 저차원 특징이 효과적으로 추출될 수 있음을 의미한다.

고안된 방법을 통해 추출된 저차원 특징을 입력변수로 이용하고 각 지하수위 패턴에 대하여 현장에서 산정된 대수층 수리특성값을 출력변수로 이용하는 회귀 모델을 개발할 경우, 입력변수와 출력변수 간 통계적 상관성에 대한 불확실성이 감소하게 되어 수리 특성값 예측을 위한 회귀 모델의 성능이 효과적으로 개선될 수 있을 것으로 판단된다. 이에 따라 해당 연구 결과를 기반으로 성능이 개선된 회귀 모델은 추가 관정에 대한 모니터링 자료만을 이용하여, 보다 효율적이고 객관적으로 대수층의 수리특성값을 유추하는데 적용될 수 있을 것이다. 그러나 고안된 모델은 장기간의 지하수위 변동 패턴을 이용하기 때문에 모니터링 기간이 상대적으로 짧은 관측공에 대하여 이용의 제약이 존재한다. 따라서 보다 단기간 지하수위 패턴에 대한 추가적 연구 및 개발이 필요하다.

사 사

본 연구는 2020년도 산업통상자원부의 재원으로 한국 에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(20193210100130).

References

- Adamowski, J. and Chan, H.F. (2011) A wavelet neural network conjunction model for groundwater level forecasting. *J. Hydrol.*, v.407(1-4), p.28-40.
- Almasri, M.N. and Kaluarachchi, J.J. (2005) Modular neural networks to predict the nitrate distribution inground water using the on-ground nitrate loading and recharge data. *Environ. Model. Softw.*, v.20, p.851-871.
- Bakker and Schaars (2019) Solving Groundwater Flow Problems with Time Series Analysis: You May Not Even Need Another Model. *Ground Water*, v.57(6), p.826-833.
- Bierkens (1998) Modeling water table fluctuations by means of a stochastic differential equation. *Water Resour. Res.*, v.34(10), p.2485-2499.
- Cooper, J.D., Gardner, C.M.K. and MacKenzie, N. (1990) Soil controls on recharge to aquifers. *J. Soil Sci.*, v.41, p.613-630.
- Coppola, E., Rana, A.J., Poulton, M.M., Szidarovszky, F. and Uhl, V.V. (2005) A neural network model for predicting aquifer water level elevations. *Ground Water*, v.43(2), p.231-241.
- Coulibaly, P., Anctil, F. and Bobée, B. (2001) Multivariate reservoir inflow forecasting using temporal neural networks. *J. Hydrol. Eng.*, v.6(5).
- Cuthbert, M.O., Mackay, R., Tellam, J.H. and Thatcher, K.E. (2010) Combining unsaturated and saturated hydraulic observations to understand and estimate groundwater recharge through glacial till. *J. Hydrol.*, v.391(3-4), p.263-276.
- Delbart, C., Valdes, D., Barbecot, F. and Tognelli, A. (2014) Temporal variability of karst aquifer response time established by the sliding-windows cross-correlation method. *J. Hydrol.*, v.511, p.580-588.
- Felisa, G., Ciriello, V., Antonellini, M., Federico, V.D. and Tartakovsky, D.M. (2015) Data-driven models of groundwater salinization in coastal plains. *J. Hydrol.*, v.531(1), p.187-197.
- Han, D., Post, V.E.A. and Song, X. (2015) Groundwater salinization processes and reversibility of seawater intrusion in coastal carbonate aquifers. *J. Hydrol.*, v.531(3), p.1067-1080.
- Jeong, J. and Park, E. (2017) A shallow water table fluctuation model in response to precipitation with consideration of unsaturated gravitational flow. *Water Resour. Res.*, v.53(4), p.3505-3512.
- Jeong, J. and Park, E. (2019) Comparative applications of data-driven models representing water table fluctuations. *J. Hydrol.*, v.572, p.261-273.
- Jeong, J., Jeong, J., Park, E., Lee, B.S., Song, S.H., Han, W.S. and Chung, S. (2020) Development of an efficient data-driven method to estimate the hydraulic properties of aquifers from groundwater level fluctuation pattern features. *J. Hydrol.*, v.590, 125453.
- Joo, Y., Brumback, B., Lee, K., Yun, S.T., Kim, K.H. and Joo, C. (2009) Clustering of temporal profiles using a bayesian logistic mixture model: analyzing groundwater level data to understand the characteristics of urban groundwater recharge. *J. Agric. Biol. Environ. Stat.*, v.14(3), p.356-373.
- Kingma, D.P. and Welling, M. (2014) Auto-encoding Variational Bayes. 2nd International Conference on Learning Representations (ICLR2014) arXiv:1312.6114, v.10.
- Knotters, M. and Bierkens, M.F.P. (2000) Physical basis of time series models for water table depth. *Water Resour. Res.*, v.36(1), p.181-188.
- Kumar, T. Jeyavel Raja, Balasubramanian, A., Kumar, R.S., Dushiyanthan, C., Tiruneelakandan, B., Suresh, R., Karthikeyan, K. and Davidraju, D. (2016) Assessment of groundwater potential based on aquifer properties of hard rock terrain in the Chittar-Uppodai watershed Tamil Nadu, India. *Appl. Water Sci.*, v.6, p.179-186.
- Lyandres, V. and Briskin S. (1993) On an approach to moving-average filtering. *Signal Process.*, v.34(2), p.163-178.
- Luo, L., Robock, A., Vinnikov, K.Y., Schlosser, C.A., Slater, A.G., Boone, A., Braden, H., Cox, P., Rosnay, P., Dicknison, R.E., Dai, Y., Duan, Q., Etchevers, P., HendersonSellers, A., Gedney, N., Gusev, Y.M., Habets, F., Kim, J., Kowalczyk, E., Mitchell, K., Nasonova, O.N., Noilhan, J., Pitman, A.J., Schaake, J., Shmakin, A.B., Smirnova, T.G., Wetzel, P., Xue, Y., Yang, Z.L. and Zeng, Q.C. (2002) Effects of frozen soil on soil temperature, spring infiltration, and runoff: results from the PILPS 2(d) experiment atvaldai, russia. *J. Hydrometeorol.*, v.4, p.334-351.
- Maggirwar Bhagyashri, C. and Umrikar Bhavana, N. (2011) Influence of various factors on the fluctuation of groundwater

- level in hard rock terrain and its importance in the assessment of groundwater. *J. Geol. Min. Res.*, v.3(11), p.305-317.
- Manziona, R.L. (2017) Physical-based time series model applied on water table depths dynamics characteristics simulation. *Rev. Bras. Recur. Hídric.*, v.23. <https://doi.org/10.1590/2318-0331.0318170071>
- Nayak, P.C., Satyajit Rao, Y.R. and Sudheer, K.P. (2006) Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resour. Manag.*, v.20(1), p.77-90.
- Neto, D.C., Chang, H.K. and Van genuchten, M. (2015) A Mathematical View of Water Table Fluctuations in a Shallow Aquifer in Brazil. *Ground Water*, v.54(1), p.82-91.
- Nourani, V., Baghanam, A.H., Voutsoughi, F.D. and Alami, M.T. (2012) Classification of groundwater level data using SOM to develop ANN-based forecasting model. *Int. J. Soft Comp. Eng.*, v.2(1), p.464-469.
- Nourani, V., Alami, M.T. and Voutsoughi, F.D. (2015) Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. *J. Hydrol.*, v.524, p.255-269.
- Park, E. and Parker, J.C. (2008) A simple model for water table fluctuations in response to precipitation. *J. Hydrol.*, v.356(3-4), p.344-349.
- Price, M., Low, R.G. and McCann, C. (2000) Mechanisms of water storage and flow in the unsaturated zone of chalk aquifer. *J. Hydrol.* v.233, p.54-71.
- Rai, S.N., Manglik, A. and Singh, V.S. (2006) Water table fluctuation owing to time-varying recharge, pumping and leakage. *J. Hydrol.*, v.324(1-4), p.350-358.
- Scholkopf, B., Smola, A. and Muller, K-R. (1996) Nonlinear Component Analysis as a Kernel Eigenvalue Problem., Max-Planck-Institut für biologische Kybernetik. Technical Report No. 44.
- Smith, D.B., Wearn, P.L., Richards, H.J. and Rowe, P.C. (1970) Water movement in the unsaturated zone of high and low permeability strata by measuring natural tritium. IAEA, p.73-87.
- Sohn, K., Yan, X. and Lee, H. (2015) Learning structured output representation using deep conditional generative models, In: *Proceedings of the Adv. Neural Inf. Process. Syst. NIPS*), p.3483-3491.
- Welling, S.R. (1984) Recharge of the Upper Chalk aquifer at a site in Hampshire, England: 1. Water balance and unsaturated flow. *J. Hydrol.*, v.69(1-4), p.259-273.
- Yeh, H.D. and Huang, Y.C. (2005) Parameter estimation for leaky aquifers using the extended Kalman filter, and considering model and data measurement uncertainties. *J. Hydrol.*, v.302(1-4), p.28-45.
- Yoon, H., Jun, S., Hyun, Y., Bae, G. and Lee, L. (2011) A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *J. Hydrol.*, v.396(1-2), p.128-138.