

심층 강화학습을 이용한 지능형 빗물펌프장 운영 시스템 개발★

강 승 호*, 박 정 현**, 주 진 걸***

요 약

하천 인근에 위치한 빗물펌프장은 유수지를 대상으로 적절한 규칙에 따라 펌프를 가동함으로써 도심지 및 농경지 침수 피해를 예방하는 기능을 수행한다. 현재 대부분의 빗물펌프장은 유수지의 수위를 기준으로 단순한 규칙 기반의 펌프운영 정책을 사용하고 있다. 최근 지구온난화로 인한 기후 변화가 예측하기 어려운 강우량의 변화를 발생시키고 있다. 따라서 단순한 펌프 정책으로는 지구온난화로 인한 갑작스러운 유수지 변화에 적절하게 대처하기 어렵다. 본 논문은 강우량과 저수량, 유수지 수위 등의 정보를 이용해 시스템이 적정 유수지 수위를 유지할 수 있도록 펌프 가동을 선택할 수 있는 심층 강화학습 기반의 자동 빗물펌프 운용 방법을 제시한다. 제안한 방법의 타당성을 검증하기 위해 강우-유출 모의 모델인 Storm Water Management Model(SWMM)을 이용해 모의실험을 수행하고 현장에서 사용되고 있는 기존 펌프 정책과 성능을 비교하였다.

A Development of Intelligent Pumping Station Operation System Using Deep Reinforcement Learning

Seung-Ho Kang*, Jung-Hyun Park**, Jin-Gul Joo***

ABSTRACT

The rainwater pumping station located near a river prevents river overflow and flood damages by operating several pumps according to the appropriate rules against the reservoir. At the present time, almost all of rainwater pumping stations employ pumping policies based on the simple rules depending only on the water level of reservoir. The ongoing climate change caused by global warming makes it increasingly difficult to predict the amount of rainfall. Therefore, it is difficult to cope with changes in the water level of reservoirs through the simple pumping policy. In this paper, we propose a pump operating method based on deep reinforcement learning which has the ability to select the appropriate number of operating pumps to keep the reservoir to the proper water level using the information of the amount of rainfall, the water volume and current water level of the reservoir. In order to evaluate the performance of the proposed method, the simulations are performed using Storm Water Management Model(SWMM), a dynamic rainfall-runoff-routing simulation model, and the performance of the method is compared with that of a pumping policy being in use in the field.

Key words : 내수침수, 빗물펌프장, 펌프가동, 심층강화학습, SWMM

접수일(2020년 01월 30일), 수정일(1차: 2020년 03월 11일),
게재확정일(2020년 03월 20일)

* 동신대학교/융합정보안전공

** 동신대학교/토목환경공학과

*** 교신저자/동신대학교/토목환경공학과(교신저자)

★ This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. 2017R1C1B1008998).

1. 서 론

유역에 내린 빗물은 다양한 경로를 거쳐 하천에 도달하게 되는데, 도심의 침수 피해를 방지하기 위해 하천 인근에 빗물펌프장을 설치하고 운영하고 있다. 빗물펌프장은 규모에 따라 여러 대의 펌프를 설치하고 우수지로 유입되는 빗물을 배수하기 위해 적절한 규칙에 따라 펌프를 가동함으로써 침수 피해와 하천 범람을 예방하는 기능을 수행한다. 일반적으로 이러한 빗물펌프장에서는 우수지의 수위를 기준으로 일정 수위에 도달하면 가동 펌프의 수를 증가시키거나 감소시키는 단순한 규칙 기반의 펌프 정책을 사용하고 있다. 하지만 운영자의 관찰과 경험에 의존한 수동적 방식이나 우수지 수위를 기준으로 운영하는 단순 규칙 기반의 자동화는 갑작스러운 강우량의 증가 등으로 인한 우수지 급격한 변화에 적절하게 대처하기 어렵다.

빗물펌프장의 최적 운영을 위해 국내외적으로 다양한 연구가 있었다. 빗물펌프장 운영에 관한 국내 연구로는 우수지 배수펌프 운영조작 모형을 개발한 연구[1, 2], 우수배제 펌프의 적용 제어를 위해 퍼지이론을 활용한 연구[3], 도시 내배수 시스템의 실시간 운영을 위한 모형 개발에 관한 연구들[4] 등이 있다. 빗물 펌프장의 최적 운영에 관한 해외 연구로는 [5]와 [6]등의 연구가 있다. 이들 대부분은 단순 규칙을 이용한 펌프 운용 자동화나 최적 운용에 관한 연구들이다.

최근 딥러닝으로 대변되는 인공지능 및 기계학습 분야의 획기적인 기술발전을 공학분야에서 이용하려는 연구가 활발히 이루어지고 있다[7, 8]. 일반적으로 기계학습 방법은 학습 대상인 데이터의 형태, 라벨의 존재 여부, 학습 방법 등에 따라 지도학습, 비지도학습 및 강화학습으로 구분한다.

빗물 펌프장 운영의 경우 강우 상태나 우수지의 수위 등에 따른 펌프 가동의 최적 정책을 사전에 지도학습에서의 라벨 형태로 부여하는 것이 사실상 불가능하다. 또한 데이터 분포나 구성 분석을 목적으로 하는 비지도학습 방법도 적합하지 않

다. 실시간으로 진행되는 펌프 가동의 최적 정책을 결정하는 것은 주어진 상황에서 우수지의 수위를 최소화하는 등의 목적 달성을 유도하고자 적절한 보상 기재를 사용하는 강화학습 기반의 기계학습 방법을 적용하는 것이 문제에 가장 적합한 것으로 판단된다.

심층 강화학습 기반의 빗물펌프장 운영 시스템이 추구하는 최종 목적은 강우시에 적절한 수의 펌프를 가동해 최대한 우수지의 수위를 낮게 유지하는 것이다. 이때 함께 고려되어야 하는 사항은 전력 손실 및 펌프 마모를 최소화하기 위해 가능한 한 가동하는 펌프 수의 변동을 작게 해야 한다는 것이다.

본 연구는 이러한 여러 가지 목적을 달성하고자 행위 결정을 담당할 4계층의 인공 신경망을 대상으로 정책 강화 (Policy Gradient) 강화학습 방법을 이용해 학습을 진행하였다. 또한 성능 개선을 위해 이전 단계에 선택된 행위를 다음 단계의 의사결정에 활용할 수 있도록 재귀적(recursive) 속성을 가미하였다.

2. 모의 환경

서울특별시 금천구에 위치한 가산 빗물펌프장을 모의 환경으로 사용하였다. 가산 펌프장의 펌프는 100 CMM(cubic meter per minute) 3대와 170 CMM 2대로 구성되어 있다. 따라서 선택 가능한 가동 펌프 조합은 총 12가지임을 알 수 있다.

하지만 모든 펌프 가동 유형을 선택 가능한 펌프 조합으로 사용하지는 않고 이 중 표 1의 6가지만 사용하였다. 이는 실제 가산 펌프장에서 운용하고 있는 펌프 조합이 이들 6가지이고 12가지 모두 사용할 경우 최적해를 구하기 위해 탐색해야 하는 해공간이 지나치게 많아지기 때문이다.

<표 1> 사용한 펌프 조합

실제 사용한 펌프 가동 유형
[0,0,0,0,0], [1,0,0,0,0], [1,1,0,0,0], [1,1,1,0,0], [1,1,1,1,0], [1,1,1,1,1]

가산 펌프장에서 현재 사용하고 있는 펌프 운영방식은 다음과 같다. 우수지의 수위가 6.2m에 도달한 순간부터 펌프를 가동하기 시작한다. 0.1m 간격으로 6.6m까지 단계별로 펌프를 추가해 가동하도록 되어 있어 6.6m에 도달하면 펌프장이 보유하고 있는 5개의 펌프 모두를 가동한다. 반대로 우수지의 수위가 5.9m 아래로 내려가면 0.1m 간격으로 가동 펌프를 하나씩 줄여 5.5m에 도달하면 모든 펌프의 가동을 중단하게 된다.

가산 빗물 펌프장을 모의하기 위해 SWMM(Storm Water Management Model)을 사용하였다. SWMM은 미국 환경보호국(Environment Protection Agency)이 홍수 범람, 하수처리 등의 배수처리 시스템(drainage system)과 관련해서 계획, 분석, 설계를 지원하도록 개발된 모의 시스템이다 [9]. SWMM은 배수 시설 등 배지에 관한 다양한 정보와 강수량 정보를 이용해 주어진 기간의 범람과 오염물질 부하 등을 예측할 수 있다.

EPA는 SWMM5을 랩핑(wrapping)한 파이썬 인터페이스 PySWMM[10]을 제공하고 있다. 본 연구에서는 심층 강화학습 구현을 위해 구글에서 작성한 파이썬 플랫폼인 tensorflow와 모의 시스템 구현을 위해 PySWMM을 사용하였다.

3. 심층 강화학습 기반 펌프 운용 시스템

3.1 빗물펌프장 시스템

3.1.1 문제 정의

강화학습을 이용한 빗물펌프장 시스템이 해결하고자 하는 문제는 사전에 정의된 제약 조건하에서 여러 가지 목적을 만족시켜야 하는 다목적 최적화 문제로 정의할 수 있다.

(펌프조합선택 문제) n 개의 펌프로 구성된 펌프

집합 $P = \{p_1, p_2, p_3, \dots, p_n\}$ 와 k 개의 펌프 조합 모음 $S = \{s_1, s_2, s_3, \dots, s_k\}$, 목적(제약) 함수 $\rho: S \rightarrow Q$ 가 주어졌을 때 임의의 시간 T 분 동안 목적 함수를 최적화하는 분 단위 펌프 조합으로 구성된 최적 서열 $\Pi^* = (s_{1T}, s_{2T}, s_{3T}, \dots, s_{kT})$ 를 찾아라.

펌프 조합을 통해 달성하고자 하는 목적 함수 ρ 를 구성하는 관련된 사항들은 다음과 같다.

- 1) 우수지 최고 수위 최소화
- 2) 펌프 변경 수 최소화
- 3) 선택한 펌프 조합의 가능 펌프량이 현 우수지 수량보다 작아야 함

펌프 변경 최소화란 분 단위로 펌프 조합을 선택할 때 가능하면 가동 중인 기존 펌프 조합을 그대로 유지함으로써 잦은 변경에 따른 전력 소모 및 펌프 마모 방지를 위해 필요한 사항이다. 세 번째 사항은 펌프를 운영할 때 현재 선택된 펌프 조합의 펌프 용량이 현 우수지의 수량보다 크면 펌프의 고장 발생 가능성이 커지기 때문에 이를 방지하기 위한 제약 사항이다.

빗물 펌프장의 펌프조합선택 문제의 해가 갖는 해 공간의 크기는 모든 펌프가 다른 종류일 때를 가정한 정리1로 대강을 알 수 있다. 물론 이 정의에는 강수량이나 우수지 수위 등의 상황적 조건이 고려되지 않은 것으로, 실제 해 공간은 이보다 훨씬 크다는 것을 알 수 있다.

정리1. 모든 펌프 종류가 다른 경우 펌프조합선택 문제의 해 공간의 크기는 이다.

증명. 우선 문제 정의에서 펌프 조합 모음 S 의 색인 k 는 서로 다른 n 개의 펌프로 가능한 조합의 최대 수를 나타내며 $2n$ 개이다. 따라서 매분 마다 $2n$ 개의 조합을 대상으로 시간 T 분 동안 펌프 조합을 선택하게 되면 다음과 같이 선택 가능한 펌프 조합서열의 가지 수는 $2^n T$ 임을 알 수 있다.

$$n = 2^n T \quad \square$$

$$= 1$$

정리1에서 알 수 있듯이 펌프 수(n)가 많아지거나 시간(T)가 커지는 경우 해공간으로부터 최적해를 찾기가 쉽지 않다는 사실을 알 수 있다.

3.2 강화학습 모델

3.2.1 강화학습 개요

강화학습이란 소프트웨어 에이전트가 주어진 환경에서 상태를 관찰하고 행위를 선택해 전체 보상을 최대화하도록 에이전트를 학습시키는 기계학습 방법을 말한다[11-14].

일반적으로 강화학습은 다음과 같이 Markov Decision Process(MDP)로 모델링할 수 있다.

- 환경과 에이전트 상태 집합: S
- 행위 집합: A
- 상태 전이 확률: $P_a(s, s') = \Pr(s_{t+1} = s' | s_t = s, a_t = a)$
- 보상: $R_a(s, s')$

에이전트는 주어진 환경에서 특정한 행위를 선택하고 이를 통해 상태를 변화시키며 이에 따른 보상을 획득한다. 강화학습의 목적은 에이전트가 환경과 상호작용을 통해 보상을 극대화하는 것이다.

3.2.2 모델 구성

펌프조합선택문제를 해결하기 위해 인공신경망 기반의 강화학습 모델을 사용하였다. 학습의 대상이자 상황에 따라 의사결정을 담당하는 인공신경망은 입력층 계층과 2개의 은닉 계층을 구성된 4계층의 완전연결형 신경망 구조이며 각 계층의 노드 수는 각각 17, 15, 20, 6 이다. 출력층의 노드 수 6은 사용 가능한 6가지 펌프 조합을 나타낸다.

펌프조합 문제의 목적과 관련해서 분 단위로 이루어지는 펌프 조합 결정에는 이전에 결정한 펌프 조합과 이전 유수지 수량 등이 고려되어야 한

다. 따라서 이러한 시간적 특성을 반영해 모델의 이전 출력인 펌프 조합 결정을 다시 입력으로 사용될 수 있도록 재귀 방법을 모델에 반영하였다. 신경망의 가중치 초기화에는 He 초기화 방법을 사용하였고 은닉층의 활성화 함수로는 ReLU 함수를 사용하였다.

3.2.3 입력 벡터

빗물펌프장 시스템에 사용할 입력 벡터는 환경으로부터 관찰된 요소와 학습 성능을 향상하고 최적 정책을 찾기 위해 추가된 요소로 구성된다.

환경으로부터 관찰된 입력 벡터의 요소에는 강우량, 유수지 유입량, 유수지 수량, 유수지 수위가 있다. 이들 중 강우량은 모의된 강우 데이터를 사용하고 유수지 유입량은 swmm을 1분 단위로 모의하여 얻은 값이며 유수지 수량과 유수지 수위는 가동하는 펌프조합의 운용 결과가 반영된 값으로 얻어진다.

한편, 모델이 시간성을 갖도록 하려면 재귀적인 입력 요소가 필요하다. 이러한 입력 요소로 최근 두 펌프 조합과 직전 유수지 수량을 사용하였다.

펌프 조합은 출력되면서 동시에 다음번 입력으로 사용되는 범주형 데이터에 속한다. 따라서 출력 때와는 달리 크기 6인 one-hot 벡터 형태로 변환되어 입력에 사용하였다. 이러한 모든 입력 요소를 결합하면 입력 벡터의 크기는 $4 + 1 + 12 = 17$ 이 된다. one-hot 벡터를 제외한 모든 입력 요소는 min-max 정규화를 적용하였다.

3.2.4 학습 알고리즘

신경망의 파라미터 최적화를 위해 REINFORCE 알고리즘[15]으로 알려진 정책 경사하강법(policy gradient descent) 알고리즘을 사용하였다. 알고리즘의 기본작동 방법은 다음과 같다.

- ① 모의된 강우 데이터와 swmm에 의해 생성된 입력 시나리오를 진행하며 1분 단위로 보상과 해

당 결정의 선택 확률을 높이는 경사계산

② 에피소드가 끝나면 경사 벡터와 할인율($\gamma = 0.95$)이 반영된 보상을 곱해 새로운 경사 벡터 계산

③ 경사 업데이트

④ 새로운 시나리오 도입과 함께 ① ~ ③ 반복

학습률은 0.01로, 비용함수는 softmax 함수를 이용한 교차 엔트로피(cross entropy) 방법을 사용하였으며 Adam 최적화 방법을 사용하였다.

강화학습을 이용한 모델이 펌프 변경을 최대한 자제하면서 유수지의 최고 수위를 최소화 하는 펌프 조합을 매분 의사 결정할 수 있도록 보상 방법을 설계하였다.

우선 유수지 수위를 낮추기 위한 보상은 식(1)처럼 이전 유수지 수량(vb)과 현재 선택된 펌프 조합을 가동했을 때의 유수지 수량(vc)과의 차이를 사용하였다.

$$v_reward = vb - vc \quad \text{식(1)}$$

가동하는 펌프 수의 변경을 최소화하기 위해서는 최근 2번의 펌프 조합과 현재 펌프 조합을 사용하여 펌프 변경 수가 작을수록 높은 보상을 받을 수 있도록 하였다.

$$p_rew1 = bit_count(a_pp \oplus a_p) \quad \text{식(2)}$$

$$p_rew2 = bit_count(a_p \oplus a) \quad \text{식(3)}$$

$$p_reward = 10 - (p_rew1 + p_rew2) \quad \text{식(4)}$$

여기서, a_pp는 전전 펌프 조합의 이진 벡터, a_p는 직전 펌프 조합의 이진 벡터, a는 현 펌프 조합의 이진벡터를 각각 나타낸다. bit_count() 함수는 이진 벡터 인수를 대상으로 1의 개수를 계산한다. 식(4)의 상수 10은 p_rew1과 p_rew2에서 각각 최대 가능한 펌프 변경 수의 합이다.

위에서 정의된 두 가지 보상 방법을 가중 결합하여 전체 보상 함수를 다음과 같이 정의한다. 다만, 펌프조합의 방류 가능 수량(ppq)이 현 유수지 수량보다 작아야 하므로 $vb < ppq$ 이면 w_1 값을 0으로 하여 전체 보상에 아래 식처럼 펌프 유지에 따른 보상만 고려하도록 하였다.

$$R = w1 * v_reward + w2 * p_reward, \text{ if } vb \geq ppq \quad \text{식(5)}$$

$$R = w2 * p_reward, \text{ if } vb < ppq \quad \text{식(6)}$$

여기서, ppq는 현재 펌프 방법 a에 의해 1분간 방류 가능한 수량을 나타낸다. 마지막으로 결정된 펌프 조합에 대한 보상은 아래 식과 같이 미래 보상에 대한 할인율 γ 를 적용받게 된다.

$$R(a) = Rt + \gamma * Rt+1 + \gamma^2 * Rt+2 \dots \quad \text{식(7)}$$

4. 실험 및 성능분석

4.1 강우 모의

모형의 학습/적용을 위해서 빗물펌프장 설계에 일반적으로 많이 사용되는 빈도별 확률강수량을 사용하였다. 확률강수량은 강수량, 강우지속기간, 강우재현기간(빈도)로 구성되어 있다. 확률강수량을 시간분포시키는 방법으로 Huff의 무차원 누가곡선 방법을 사용하였다. Huff의 무차원 누가곡선에 의한 방법은 과거의 관측 우량자료를 이용한다는 특징을 가지고 있어 신뢰성을 인정받고 있으며 하천설계기준, 소하천설계기준 등 국내의 실무에서 가장 널리 사용되고 있다.


강우 샘플은 2, 3, 5년 빈도강우를 대상으로 강우지속 기간을 30, 60, 120, 180, 240, 720, 1080, 1440, 2880, 4320(분)의 10개 기간으로 나누어 생성하였다. 각 강우마다 Huff의 1~4분위로 시간분포시켜 4개의 샘플을 생성하였으므로 총 120개의 샘플을 모델의 학습데이터로 사용하였다. 동일한 수의 샘플을 검증데이터로 사용하였다.

4.2 2년 빈도 강우 실험

우선 모의 생성한 2년 빈도 강우 샘플을 이용해 가산 빗물 펌프장에서 현재 운용하고 있는 펌프 조합 선택 방법에 따른 실험을 진행하였다. 그리고 동일한 강우 샘플 44개의 훈련 데이터를 대상으로 3000번의 임의 탐색(exploration)과 200번의 이용(exploitation) 탐색 방법을 이용해 모델

을 학습하였다.

그림(2)는 2년 빈도의 60분 강우 샘플 하나를 대상으로 가산 빗물펌프장의 운영 규칙을 이용했을 때의 결과를 나타낸 것이다. 강우가 종료한 이후 1시간까지 실험을 진행하였고 이때의 강우량, 누적 강우량, 우수지 유입량, 펌프를 통한 유출량 등은 그림(2a)에서 확인할 수 있다. 그림(2b)는 펌프조합을 선택해 운용했을 때 시간의 경과에 따른 우수지 수위를 보여준다. 그림(2c)은 펌프 운영 규칙에 따라 매분마다 선택된 펌프 조합과 펌프 조합의 변경에 따른 펌프 변경 수를 나타내고 있다. 그림(2d)는 우수지에서의 펌프를 통한 유출량과 우수지의 저수량을 나타내고 있다.



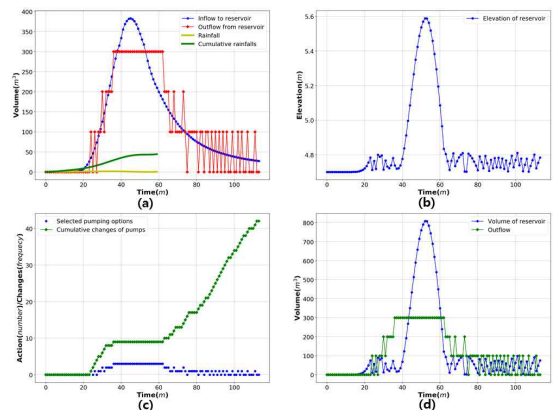
(그림 2) 가산 펌프장 운용 방식에 의한 결과

그림(3)은 동일한 강우 샘플을 대상으로 심층 강화학습 기반의 펌프장 운영 시스템을 모의한 결과를 나타낸 것이며 그림의 의미는 가산 펌프장 운영 규칙에 따른 결과 그림과 같다.

우선 우수지의 최고 수위를 비교해 보면 제안 시스템에 의해 운영했을 때 우수지의 최고 수위가 더 낮다는 사실을 확인할 수 있다. 하지만 펌프 변경 수를 보면 제안 시스템을 사용했을 때의 변경 수가 월등히 크다는 걸 알 수 있다. 이는 펌프장의 현재 운영 규칙은 수위가 6.2m를 넘지 않으면 가동을 하지 않기 때문인데, 이 경우 우수지의 모든 물을 퍼내지 못하는 문제가 발생한다. (그림 (2b), (2c)).

이에 반해 제안 시스템에 따른 펌프장 운영은

우수지 내의 모든 물을 퍼내려 시도하도록 되어있다. 특히 강우가 멈추고 우수지의 수위가 낮아지는 후반부에서 운영 펌프 조합의 잦은 변경 현상이 발생하는데, 이는 시스템이 우수지 내의 유수를 모두 퍼내려고 시도하면서 동시에 펌프 조합의 펌프 용량이 우수지의 유수량을 넘어서는 안된다는 조건을 만족시켜야 하기 때문이다. 특히 이 조건은 보상 정책을 이용한 학습만으로 만족하는 펌프조합을 도출해 내지 못해 강제로 외부에서 조정이 필요하였다. 펌프장의 기존 운영 규칙은 우수지의 수위가 5.5m 이하로 내려왔다가 다시 상승하더라도 6.2m를 넘지 않으면 펌프를 가동하지 않도록 되어 있어 이러한 펌프 변경 수의 차이가 발생한다.



(그림 3) 모의된 2년 빈도 60분 강우를 대상으로 심층 강화학습을 모델에 이용한 빗물 펌프장 운용 사례

표4는 가산 펌프장의 펌프 운영방식과 심층 강화학습 모델을 이용해 2년 강우 샘플 전체 44개의 검증데이터를 사용해 펌프장 운용을 모의하고 평균값을 비교한 것이다. 앞의 개별 사례의 예측대로 최고 수위의 평균은 제안한 시스템의 결과가 1 m 이상 낮게 유지된다는 사실을 알 수 있다. 평균 펌프 변경수가 크게 차이는 이유는 앞에 설명에 따르며, 특히 강우 시간이 큰 경우 펌프 변경수가 급격히 증가함을 알 수 있다.

<표 2> 2년 빈도 강우 실험 결과

	평균 최고 유수지 수위	평균 펌프 변경 횟수
가산 펌프장	6.32	21.97
심층 강화학습	5.18	426.75

4.3 2년, 3년, 5년 빈도의 강우 데이터 실험

이번에는 2년, 3년, 5년 빈도의 강우 데이터 전체를 함께 이용해 4000번의 임의 탐색과 200번의 이용 탐색 방법을 사용해 모의 실험을 실시하였다. 표에서 볼 수 있듯이 2년 빈도의 강우 데이터로 실시한 실험과 마찬가지로 최고 유수지 수위의 평균값은 가산 펌프장 운영방식의 유수지 수위에 비해 1m 이상 차이가 나는 걸 확인할 수 있다. 마찬가지로 펌프 변경 수는 펌프장 운영방식의 변경 수에 비해 훨씬 크다.

<표 3> 2, 3, 5년 빈도 실험 결과

	평균 최고 유수지 수위	평균 펌프 변경 횟수
가산 펌프장	6.32	22.10
심층 강화학습	5.54	419.88

5. 결 론

본 논문은 빗물 펌프장의 펌프 운영방식을 자동화하기 위해 심층 강화학습을 이용해 모델을 설계/구현하였다. 심층 강화학습 기반의 펌프장 운영 시스템의 성능 평가를 위해 실제 가산 빗물 펌프장의 환경과 2, 3, 5년 빈도의 강우 데이터를 준비하고 SWMM을 이용해 모의 실험하였다.

시스템은 유수지의 수위와 운영 펌프의 변경을 최소화 하도록 적절한 보상 정책을 설계하였고 임의 탐색과 이용 탐색 모듈을 활용해 최적화된 운영 방법을 찾도록 학습하였다. 학습된 시스템은 가산 펌프장에서 사용되고 있는 운영 규칙에 비해 최고 유수지의 수위를 1m 이상 낮출 수 있음을 확인하였다. 다만, 유수지 내의 유수를 모두 제거 하도록 시스템이 설계되어 있어서 일정 수위 아래

에 도달하면 펌프 운영을 중단하도록 되어 있는 펌프장의 운영 규칙에 비해 많은 펌프 변경수를 보여주었다.

본 논문은 라벨이 있는 학습 데이터를 얻기 불가능한 빗물 펌프장의 펌프 운영 문제를 대상으로 심층 강화학습을 적용한 최초의 기계학습 기반 펌프 자동화 시스템이라는 점에서 이 분야에 새로운 연구를 유도하는데 크게 기여할 수 있을 것으로 본다. 앞으로 실제 환경을 보다 반영할 수 있도록 적절하게 문제 정의를 해야하는 한편 펌프의 변경 수를 줄이기 위한 개선된 학습 알고리즘과 모델 선정에 대한 연구가 필요하다.

참고문헌

- [1] S. U. Yun and J. T. Lee, "A study on the development of the operation models for storm water pumps in detention pond", J. KWRA, Vol. 28, No. 6, pp. 203-215, 1995
- [2] 추연문, 유도근, 이승엽, 임오성, 주진걸, 김중훈, "도시 빗물펌프장 예측운영시스템의 스마트 운영기법 개발", 한국방재학회 논문집, 17(2), pp. 39-50, 2017.4
- [3] J. H. Sim, W. C. Joo, and W. H. Lee, "An adaptive control of inland pumping station using self-tuning of fuzzy control technique", KWRA Hydro Research Paper, pp. 291-299, 1992.
- [4] 진환돈, 이양재, 이정호, 김중훈, "도시 내배수시스템 실시간 운영모형의 개발", 한국물환경학회지, 23권 5호, pp. 748-755, 2007.
- [5] X. Feng, B. Qiu, X. Yang, and B. Pei, "Optimal methods and its application of large pumping station operation", J. Drainage and Irrigation Machinery Engineering, Vol. 2, No. 10, 2011.
- [6] X. Zhuan, and X. Xiaohua, "Optimal operation scheduling of a pumping station with multiple pumps", Applied Energy, Vol. 104, pp. 250-257, 2013.

- [7] T. Baumeister, S. L. Brunton, and J. N. Kutz, "Deep learning and model predictive control for self-tuning mode-locked lasers", J. Optical Society of America B, Vol. 35, No. 3, pp. 617-626, 2018.
- [8] X. Y. Lee, et al., "A Case Study of Deep Reinforcement Learning for Engineering Design: Application to Microfluidic Devices for Flow Sculpting", J. Mechanical Design, Vol 141, No. 11, 111401(10 pages), 2019.
- [9] <https://www.epa.gov/water-research/storm-water-management-model-swmm>
- [10] https://cfpub.epa.gov/si/si_public_record_report.cfm?Lab=NRMRL&direntryid=335780
- [11] Richard S. Sutton and Andrew G. Barto, "Reinforcement Learning: An Introduction second edition", The MIT Press, 2018.
- [12] K. Arulkumaran, M. P. Deisenroth, M. Brundage, and A. A. Bharath, "Deep Reinforcement Learning: A Brief Survey", IEEE Signal Processing Magazine, Vol. 34, pp. 26-38, 2017.
- [13] T. D. Bruin, J. Kober, K. Tuyls, and R. Babuska, "Experience Selection in Deep Reinforcement Learning for Control", The Journal of Machine Learning Research, Vol. 19, No. 1, pp. 1-56, 2018.
- [14] A. Ilyas, L. Engstrom, S. Santurkar, D. Tsipras, F. Janoos, L. Rudolph, A. Madry, "Are deep policy gradient algorithms truly policy gradient algorithms?", CoRR abs/1811.02553. arXiv:1811.02553.
- [15] R. Williams, "Simple statistical gradient-following algorithms for connectionist reinforcement learning", 1992.

〔 저 자 소 개 〕



강 승 호 (Seung-Ho Kang)
 1994년 8월 전남대학교
 전산학과 (이학사)
 2003년 2월 전남대학교
 전산학과 (이학석사)
 2008년 8월 전남대학교
 전산학과 (이학박사)
 2013년 9월 ~ 현재 동신대학교
 융합정보보안전공 교수
 email : drminor@dsu.ac.kr



박 정 현 (Jung-Hyun Park)
 2010년 2월 동신대학교
 토목공학과 (공학사)
 2016년 2월 동신대학교
 토목공학과 (공학석사)
 2019년 2월 동신대학교
 토목학과 (공학박사수료)
 2019년 3월 ~ 현재 동신대학교
 토목공학과 박사과정
 email : a987987@nate.com



주 진 걸 (Jin-Gul Joo)
 2003년 8월 고려대학교
 토목환경공학과 (공학사)
 2005년 8월 고려대학교
 사회환경시스템공학과
 (공학석사)
 2011년 2월 고려대학교
 사회환경시스템공학과
 (공학박사)
 2014년 3월 ~ 현재 동신대학교
 토목환경공학과 교수
 email : jgjoo@dsu.ac.kr