

강화학습을 이용해 개발한 준능동 제어알고리즘의 성능평가

김현수
선문대학교 건축학부

Performance Evaluation of Semi-Active Control Algorithm Developed by Reinforcement Learning

Hyun-Su Kim
Division of Architecture, Sunmoon University

요약 강화학습은 최근까지 다양한 능동제어 문제에 적용되어 우수한 제어성능을 보여 왔다. 그러나 강화학습을 이용하여 개발한 준능동 제어알고리즘에 대한 연구는 현재까지 거의 수행된 바 없다. 따라서 본 연구에서는 강화학습을 이용하여 준능동 제어알고리즘을 개발하였다. 강화학습은 주어진 환경과 상호작용을 하는 에이전트가 현재의 상태에서 어떤 행동을 취하는 것이 최고의 보상을 받는지 학습하여 누적 보상을 최대화 하는 방향으로 학습이 진행된다. 이러한 강화학습을 적용할 예제 건물로는 MR 감쇠기를 이용하여 구성된 준능동 중간층 면진 시스템이 적용된 26층 빌딩 구조물을 사용하였다. 수치해석을 위해서 인공 지진하중을 생성하였다. 생성된 예제 구조물과 지진하중을 사용해서 강화학습의 환경을 생성하였다. 생성된 환경과 상호작용을 할 에이전트는 준능동 제어알고리즘으로 설정하였다. 강화학습의 보상은 최대 층간변위와 면진층 층간변위를 저감시킬 수 있도록 설계하였다. 스카이훅 (Skyhook)과 그라운드훅 (Groundhook) 제어알고리즘을 이용해서 제어성능을 비교 및 검토 하였다. 수치해석 결과 제안된 제어알고리즘은 준능동 중간층 면진시스템이 설치된 예제구조물의 지진응답을 효과적으로 저감시킬 수 있는 것을 본 연구를 통해서 확인할 수 있었다.

Abstract Reinforcement learning has shown good control performance for various active control problems. However, research has rarely been conducted on a semi-active control algorithm developed using reinforcement learning. In the reinforcement learning process, an agent is trained by interacting with a given environment and learns what actions receive the most rewards in its current state to maximize the sum of the rewards. In this study, a semi-active control algorithm was developed using reinforcement learning. In order to apply reinforcement learning, a 26-story building structure was constructed as an example by using a semi-active mid-story isolation system with a magnetorheological damper. Artificial ground motions were generated for numerical simulation. The example building structure and seismic excitation were used to make an environment for reinforcement learning. An agent interacting with the constructed environment was set as a semi-active control algorithm. The reward of reinforcement learning was designed to reduce the peak story drift and the isolation story drift. Skyhook and groundhook control algorithms were used for comparative study. Based on numerical results, this paper shows that the proposed control algorithm can effectively reduce the seismic responses of building structures with a semi-active mid-story isolation system.

Keywords : Semi-Active Control Algorithm, Reinforcement Learning, Seismic Response Control, Semi-Active Mid-Story Isolation System, Skyhook, Groundhook

본 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임. (과제번호: NRF-2019R1A2C1002385)

*Corresponding Author : Hyun-Su Kim(Sunmoon Univ.)

email: hskim72@sunmoon.ac.kr

Received February 9, 2023

Revised March 15, 2023

Accepted April 7, 2023

Published April 30, 2023

1. 서론

딥러닝으로 대변되는 기계학습 및 인공지능은 2016년 인간과의 대결에서 승리한 알파고[1]의 등장으로 세상을 놀라게 한 이후 최근 ChatGPT[2]의 출현으로 인간이 지식을 습득·보유·유통하는 과정에 일대 혁신을 가져올 것으로 기대되고 있다. 건축구조공학 분야에서는 다양한 문제에서 생산된 데이터를 학습하여 그 속의 패턴을 익힌 후 학습하지 않은 입력 데이터에 대해서 최적의 응답을 예측하는 사례가 다수 보고되고 있다[3-5]. 이에 비하여 강화학습은 주어진 외부 환경(Environment)과 상호작용을 하는 에이전트(Agent)가 현재의 상태(State)에서 어떤 행동(Action)을 취하는 것이 최적인지를 학습하는 것이다. 행동을 취할 때마다 환경에서 보상(Reward)이 주어지는데, 이러한 보상을 최대화 하는 방향으로 학습이 진행된다[6]. 따라서 강화학습은 인공지능경망으로 표현되는 에이전트를 학습시키기 위한 학습데이터가 필요 없고 주어진 환경에서 최적의 선택을 하도록 기계가 스스로 학습하게 된다. 이러한 강화학습은 기계공학 및 제어계측공학 뿐만 아니라 구조공학 분야에서도 주로 능동제어시스템에 적용되어 우수한 성과를 나타내고 있다[7,8]. 그러나 준능동 제어시스템에 강화학습이 적용된 연구는 주로 자동차의 현가장치 시스템에 적용된 사례[9]가 발표되고 있고 건축구조물의 지진응답 제어를 위한 준능동 제어시스템 개발에 강화학습이 적용된 사례는 찾아보기 쉽지 않다.

저자는 선행연구[10]에서 준능동 중간층 면진시스템이 설치된 예제구조물의 제어알고리즘 개발을 위해서 강화학습을 이용하고 예제구조물의 지진응답 예측을 위해서 지도학습을 이용한 바가 있다. 본 연구는 선행연구의 단점을 보완한 연구를 수행하였으며 이는 다음과 같다.

첫째, 선행연구에서는 준능동 중간층 면진시스템과 예제구조물의 비선형 상호작용을 고려하는 해석모형을 지도학습을 이용한 신경망 모델을 사용하여 개발하였다. 이때 유한요소 해석모형을 정확해로 하여 근사해를 예측하는 신경망 모델을 개발한 이유는 강화학습 과정에서 필요한 반복적인 수치해석의 효율성을 높이기 위해서였다. 그러나 대상 예제구조물은 자유도가 26개인 크지 않은 해석모형으로서 해석의 효율성보다는 정확성을 높이는 것이 더 중요하다고 판단되어 본 연구에서는 유한요소해석모형을 기반으로 한 상태공간방정식을 이용하여 예제구조물의 지진거동을 예측하였다.

둘째, 선행연구에서는 강화학습 에이전트를 훈련시킨

지진하중과 에이전트의 준능동 제어성능을 평가할 때 사용한 지진하중이 같아서 객관적인 성능검증이 어려웠다. 본 연구에서는 강화학습시 사용한 지진하중과 제어성능을 평가할 때 사용한 지진하중을 다르게 하여 본 연구에서 개발한 제어기술의 성능을 보다 객관적으로 평가하였다.

셋째, 선행연구에서는 강화학습으로 개발된 준능동 제어알고리즘의 제어성능을 다른 준능동 제어알고리즘과 비교하지 않고 최적 수동제어의 경우와 비교하였다. 본 연구에서는 개발된 준능동 제어알고리즘의 제어성능을 평가하기 위해서 전통적인 준능동 제어알고리즘인 Skyhook과 Groundhook 제어알고리즘을 사용하여 비교하였다.

넷째, 선행연구에서는 강화학습 환경의 상태로서 매 스텝의 지반가속도, 지반속도, 지반변위를 사용하였으나 지반속도 및 지반변위가 매 시간 스텝마다 변화가 크지 않다는 것을 파악하였고 본 연구에서는 이전 스텝의 지반가속도를 묶은 일련의 지반가속도를 상태로 사용하였다. 본 연구에서는 선행연구 대비 이러한 차별점 및 개선점을 적용하여 강화학습을 이용해 개발한 준능동 제어알고리즘의 지진응답 제어성능을 평가하였다.

2. 예제구조물 및 지진하중을 이용한 강화학습 환경 구성

본 연구에서는 강화학습의 에이전트가 지진하중을 받는 예제구조물에 설치된 준능동 중간층 면진시스템을 제어할 알고리즘의 역할을 한다. 강화학습 환경을 구성하기 위해서 선행연구[10]와 동일한 26층 빌딩구조물을 예제구조물로 선택하였고 이를 Fig. 1에 나타내었다. 중간층에 면진층이 있으며 준능동 중간층 면진시스템은 MR 감쇠기를 이용하여 구성된다. 구조물이나 면진시스템의 특성치는 선행연구[10]와 Sueoka et al.[11]의 연구에서 시오도메 스미토모 건물을 모형화하기 위해서 사용한 값을 그대로 사용하였다. 예제구조물의 전체 높이는 126.1m 이고 일반층의 층고는 4.2m이다. 건물은 철골조 구조물이고 면진층은 11층과 12층 사이에 위치하고 있으며 면진층 상부의 14개 층은 일반 오피스 용도로 사용하고 있으며 하부의 11개 층은 호텔로 사용하고 있다. MR 감쇠기의 비선형 동적거동을 표현하기 위해서 널리 사용되고 있는 수치해석모형인 Bouc-Wen 모델을 사용하였다. MR 감쇠기 모델은 0 volt에서 5 volt까지 조절할 수 있고 MR 감쇠기의 최대 감쇠력은 2,750kN으로 하였고

10개의 MR 감쇠기를 이용하여 준능동 중간층 면진시스템을 구성하였다.




Fig. 1. Analytical model of 26-story example structure

강화학습 에이전트의 훈련 및 검증에 사용할 인공지반 가속도를 생성하였고 이를 Fig. 2에 나타내었다.




Fig. 2. Artificial ground acceleration
(a) Earthquake for training (b) Earthquake for verification

인공지반가속도를 생성하기 위해서 백색잡음을 Eq. (1)에 나타낸 필터[12]에 통과시켜서 강진 지반운동(s)을 잘 표현하는 주파수성분을 갖도록 하였다. 백색잡음의 최대지반가속도(Peak ground acceleration, PGA)를 0.7g가 되도록 하였고 생성된 인공지반가속도 시간이력에 포락선(envelope)을 적용시켜 일반적인 지진하중의 형태를 갖도록 하였다.

$$F(s) = \frac{4\zeta_g \omega_g s}{s^2 + \zeta_g \omega_g s + \omega_g^2} \quad (1)$$

Where, $\omega_g = 2\pi \text{ rad/s}$ and $\zeta_g = 0.3$

3. 강화학습을 이용한 준능동 제어알고리즘의 개발

본 연구에서는 다양한 강화학습 알고리즘 중에서 다양한 분야에 적용되어 우수한 성과를 나타내고 있는 DQN(Deep Q-Network)[13] 알고리즘을 사용하였다. DQN은 전통적인 Q-Learning에 심층신경망을 결합하고 학습을 안정화시키고 성능을 향상시키기 위해서 경험 재현(experience replay)과 타겟 네트워크(target network) 분리라는 두 가지 새로운 방법론을 제안하여 발전시켰다[13]. Q-Learning은 순차적 행동 결정문제에 적용되어 매우 우수한 성과를 나타낼 수 있는 방법론이다. Q-Learning에서는 아래의 벨만 방정식을 이용해서 주어진 상태에서 행하는 각 행동들에 대한 보상의 총합(Q-value)을 업데이트하면서 최종적으로 가장 높은 보상을 받을 수 있는 행동을 연속적으로 수행하게 에이전트를 학습한다.

$$Q(s, a) = r + \gamma \max_{a'} Q(s', a') \quad (2)$$

Where, Q denotes value function, s denotes state, a denotes action, a' denotes action of next state, s' denotes next state, r denotes reward, γ denotes discount factor

DQN에서는 Eq. (2)에 나타난 벨만 최적방정식을 신경망으로 나타내기 때문에 $Q_\theta(s, a)$ 로 표기하고 여기서 θ 는 신경망의 파라미터 벡터를 의미한다. 신경망에서는 $r + \gamma \max_{a'} Q_\theta(s', a')$ 이 값과 추측치인 $Q_\theta(s, a)$ 사이의 차이를 줄이는 방향으로 학습을 진행한다. 따라서 DQN의 손실함수는 다음 Eq. (3)과 같이 이 차이의 제곱으로 정의하였다. 이 손실함수를 최소화하는 방향으로 θ 를 계속해서 업데이트해 나가면 $Q_\theta(s, a)$ 는 점점 최적의 액션-가치함수에 가까워진다.

$$L(\theta) = (r + \gamma \max_{a'} Q_\theta(s', a') - Q_\theta(s, a))^2 \quad (3)$$

본 연구에서는 Fig. 3에 나타낸 바와 같이 DQN 학습을 위한 환경을 구성하고 상태, 행동 및 보상을 정의하여 환경과 에이전트가 상호작용하여 학습이 이루어지도록

하였다. 그림에서 볼 수 있듯이 11층 층간변위, 면진층 층간변위, 최상층 변위, 최상층 가속도의 구조물 응답과 이전 4개 스텝을 포함한 총 5개 스텝의 지반가속도를 상태로 정의하였다. 여기서 11층은 최대 층간변위가 발생하는 층이다.

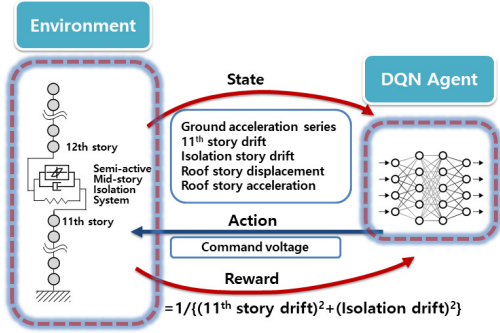


Fig. 3. Configuration of the DQN agent and environment

이러한 상태를 입력받은 DQN 에이전트는 준능동 중간층 면진시스템을 구성하고 있는 MR 감쇠기를 제어할 명령전압을 출력한다. DQN 에이전트의 출력값으로 예제구조물이 적절하게 제어되었는지 여부는 환경에서 제공하는 보상에 의해서 결정된다. 본 연구에서 구성한 강화학습 환경의 목표는 지진하중을 받는 구조물의 동적응답을 최소화하는 것이다.

다양한 지진응답 중에서 구조물의 피해와 직접적으로 연관이 있는 최대 층간변위 및 최대 면진층변위의 저감을 학습의 목표로 결정하였고 이 값들을 줄일수록 높은 보상을 줄 수 있도록 하였다. Fig. 3에 나타난 보상의 식을 보면 최대 층간변위가 발생하는 11층 층간변위와 면진층 층간변위의 제곱의 합을 분모에 두어 두 응답이 커지면 보상이 줄어들고 두 응답이 작아지면 큰 보상을 받도록 설계하였다.

DQN 에이전트를 효과적으로 학습하기 위해서는 적절한 강화학습 하이퍼파라미터를 결정하는 것이 필요하다. 이 값들은 정해져 있는 것들이 아니라 적용하는 문제에 따라서 다르게 튜닝해야한다. 본 연구에서도 이 값들은 여러 번의 반복적인 파라미터 연구를 통해서 결정하였고 이를 Table 1에 나타내었다.

DQN 에이전트를 구성하는 신경망에 너무 과도한 노드를 사용하면 과적합이 발생하여 다른 동적특성을 가진 지진하중에 대한 적응성이 떨어질 수 있다. 이를 고려하여 본 연구에서는 2개의 히든 레이어를 각 레이어는 30

개의 노드를 갖도록 하였다. DQN 신경망의 입력은 9개로서 앞에서 설명한 4개의 구조물 지진응답과 5개의 지반가속도 스텝값으로 구성된 상태변수를 입력한다. 제일 마지막 출력은 MR 감쇠기로 전달되는 명령전압 범위 0-5V를 0.5V 간격으로 나누어 총 11개의 출력 크기를 가진다.

Table 1. Hyperparameters for DQN training

Item	Value
Learning rate	0.001
Target update frequency	4
Discount factor	0.99
Mini batch size	256
Activation function	ReLU
Optimizer	Adam
Gradient threshold	1
Max. episode	10,000

DQN 에이전트와 환경간의 상호작용을 통한 강화학습이 정상적으로 이루어진다면 앞서 설명한 손실함수 Eq. (3)의 값이 에피소드가 증가함에 따라서 줄어드는 경향을 나타내야한다. 이를 확인하기 위해서 학습 에피소드의 증가에 따른 손실함수의 평균제곱오차(Mean Square Error, MSE)의 변화이력을 Fig. 4에 나타내었다.




Fig. 4. History of MSE loss value

학습 초기에는 오차가 너무 커서 숫자로 계산이 안 되는 부분이 존재하고 약 2000 에피소드까지는 오차가 급격히 줄어드는 것을 볼 수 있다. 그 이후 약 8000 에피소드까지는 오차가 완만히 줄어들다가 그 이후에는 거의 변화가 없는 것을 확인할 수 있다. 이러한 변화곡선은 정상적인 강화학습이 이루어진 경우에 나타나는 경향으로 본 연구에서 수행한 준능동 제어알고리즘 개발을 위한 강화학습이 적절하게 수행되었음을 알 수 있다.

4. DQN 기반 제어알고리즘의 성능평가

본 연구에서 개발된 DQN 기반 준능동 제어알고리즘의 제어성능을 객관적으로 평가하기 위해서 두 개의 전통적인 준능동 제어알고리즘을 비교대상으로 사용하였고 이를 Fig. 5에 나타내었다.

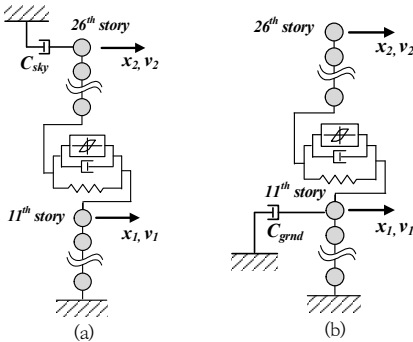


Fig. 5. Idealized semi-active control configurations
(a) Skyhook algorithm (b) Groundhook algorithm

그림에서는 이상적인 준능동 제어시스템을 나타내고 있는데 Fig. 5(a)와 (b)는 구조물과 연결된 감쇠기가 각각 하늘(Skyhook)과 움직이지 않는 지반(Groundhook)에 고정되어 있는 것을 표현한다. 그러나 실제 적용에서는 이러한 구성이 불가능하므로 준능동 제어알고리즘인 Skyhook과 Groundhook은 이러한 이상적인 구성을 준능동 제어장치를 이용해서 모사할 수 있도록 제어한다. Skyhook과 Groundhook 제어알고리즘을 각각 Eq. (4)와 Eq. (5)에 나타내었다. 면진층 상하부 구조물의 상대속도와 제어하고자 하는 층변위의 곱에 의해서 간단히 계산되는 것을 알 수 있다.

$$V = \begin{cases} V_{\max} & \text{if } x_2(v_1 - v_2) \leq 0 \\ V_{\min} & \text{if } x_2(v_1 - v_2) > 0 \end{cases} \quad (4)$$

$$V = \begin{cases} V_{\max} & \text{if } x_1(v_1 - v_2) \geq 0 \\ V_{\min} & \text{if } x_1(v_1 - v_2) < 0 \end{cases} \quad (5)$$

Where, V_{\max} denotes maximum voltage (5V), V_{\min} denotes minimum voltage (0V)

비교적 단순한 이러한 준능동 제어알고리즘은 안정적으로 우수한 제어성능을 나타내고 있다[14]. 본 연구에서 개발한 DQN 기반 준능동 제어알고리즘의 제어성능을 Skyhook, Groundhook 제어알고리즘과 비교하여 Fig. 6-9에 나타내었다. Fig. 6에 나타낸 11층 층간변위를 보

면 Groundhook 제어알고리즘의 결과가 가장 크고 DQN 기반 제어알고리즘에 의한 결과가 가장 작은 것을 알 수 있다. 특히 구조물에 피해를 유발할 수 있는 큰 응답이 발생하는 약7~8초 근처에서 DQN 기반 제어알고리즘이 우수한 성능을 나타내는 것을 알 수 있다. 면진층 층간변위 시간이력은 Fig. 7에 나타낸 바와 같이 Skyhook에 의한 결과가 가장 좋지 않고 DQN 기반 제어알고리즘이 가장 우수한 제어성능을 나타내었다. Skyhook과 Groundhook 제어알고리즘은 개발 원리에 의해서 11층과 면진층 층간변위 제어성능이 서로 상반되는 것을 알 수 있다.




Fig. 6. Comparison of the 11th-story drift time histories




Fig. 7. Comparison of the isolation story drift time histories

Fig. 8과 9에 나타낸 지붕층 변위 및 가속도응답은 Groundhook 보다 Skyhook의 제어성능이 더 우수한 것을 볼 수 있는데 이는 Fig. 5에 나타낸 이상적인 준능동 제어시스템 구성을 보면 알 수 있듯이 Skyhook이 준능동 제어시스템을 지붕층과 하늘을 감쇠기로 연결시킨 것과 같이 거동하도록 제어하기 때문이다. 두 지붕층 응답에서도 DQN 기반 제어알고리즘이 가장 우수한 성능을 나타낸 것을 알 수 있다.




Fig. 8. Comparison of the roof displacement time histories




Fig. 9. Comparison of the roof acceleration time histories

각 제어알고리즘의 제어성능을 보다 정량적으로 비교하기 위해서 제어알고리즘 별 최대응답을 Table 2에 비교하였다. 표에서 Passive로 표현한 것은 실제 존재하는 수동 중간층 면진시스템을 적용한 시오도메 스미토모 건물의 결과를 Sueoka et al.(2004)의 연구에서 제시한 해석모델을 이용해 나타낸 것이다. 각 응답치 아래에 괄호 안에 나타낸 값은 이 Passive 응답을 기준으로 비율로 표현한 것이다.

표에서 Passive-on과 Passive-off 는 각각 준능동 중간층 면진시스템을 제어할 때 최소와 최대의 명령전압, 즉 0 V와 1 V를 일정하게 가한 경우를 의미한다. 수동 중간층 면진시스템을 기준으로 Groundhook은 면진층 층간변위를, Skyhook은 11층 층간변위를 각각 17% 및 14% 더 저감시킬 수 있었다. Groundhook에 비해서 Skyhook이 전반적으로 더 우수한 제어성능을 나타내는 것을 알 수 있다.

Passive-On은 MR 감쇠기의 감쇠력이 가장 크게 가해지는 경우이므로 면진층 층간변위가 매우 효과적으로 저감되는 것을 알 수 있다. Passive-Off의 경우에는 MR 감쇠기의 감쇠력이 가장 작게 가해지므로 격리된 상부층이 마치 동조질량감쇠기와 같이 활발히 움직여서 하부 건물의 지진응답을 효율적으로 저감시키므로 11층 층간

변위가 Passive 대비 25% 줄어드는 것을 알 수 있다. 다만 이경우에 격리된 상부층의 응답이 증가하므로 지붕층 응답의 제어가 어렵고 특히 지붕층 가속도의 경우에는 Passive보다 더 증가하는 것을 알 수 있다.

마지막으로 본 연구에서 개발한 DQN 기반 준능동 제어알고리즘의 경우에는 표에서 비교한 4가지 응답에 대해서 비교 대상 모든 제어알고리즘보다 더 우수한 제어성능을 나타내는 것을 알 수 있다. 검토한 4가지 응답에 대해서 Passive의 경우와 비교하여 DQN 기반 제어알고리즘이 모두 약 30%내외의 응답을 더 줄일 수 있는 것을 볼 수 있다.

Table 2. Comparison of peak responses

Control Algorithm	Peak 11 th Fl. Drift (m)	Peak Iso. Drift (m)	Peak Roof Disp (m)	Peak Roof Acc. (m/s ²)
Passive	0.0861 (1.00)	0.6279 (1.00)	0.7945 (1.00)	11.2183 (1.00)
Groundhook	0.0826 (0.96)	0.5184 (0.83)	0.7205 (0.91)	9.7622 (0.87)
Skyhook	0.0741 (0.86)	0.5995 (0.95)	0.6332 (0.80)	8.5115 (0.76)
Passive-On	0.0837 (0.97)	0.4872 (0.78)	0.7166 (0.90)	9.404 (0.84)
Passive-Off	0.0645 (0.75)	0.8256 (1.31)	0.7430 (0.94)	12.3944 (1.10)
DQN	0.0630 (0.73)	0.4162 (0.66)	0.5331 (0.67)	8.5569 (0.76)

5. 결론

본 연구에서는 강화학습을 이용해서 준능동 제어알고리즘을 개발하고 제어성능을 검토해보았다. 이를 위해서 중간층 면진시스템이 설치된 실제 구조물의 특성을 사용해서 예제구조물을 생성하였고 MR 감쇠기를 사용하여 준능동 구조제어시스템을 구성하였다. 인공지능을 생성하여 예제구조물에 가하였고 이를 활용하여 강화학습의 환경을 구성하였다.

강화학습의 알고리즘으로는 DQN 기법을 사용하였고 DQN 에이전트가 준능동 제어알고리즘의 역할을 하게 하였다. DQN 에이전트의 입력은 4개의 구조물 지진응답과 5개의 지반운동 스텝값으로 하였고 출력은 MR 감쇠기를 제어하는 명령전압으로 하였다. 최대 층간변위 및 면진층 층간변위를 줄이면 큰 보상을 받을 수 있도록 보상식을 설계하여 강화학습을 수행하였다.

강화학습을 통해 생성한 DQN 기반 준능동 제어알고리즘은 비교대상 준능동 제어알고리즘 및 실존하는 수동 제어시스템에 비해서 우수한 제어성능을 나타내는 것을 확인하였다. 따라서 본 연구에서 제안한 강화학습을 활

용하여 구조제어알고리즘을 개발한다면 준능동 제어시스템을 효과적으로 제어할 수 있을 것으로 판단된다.

본 연구에서 사용한 지진하중 및 해석모델과 준능동 제어시스템이 제한적이므로 보다 일반적인 결론을 내기 위해서는 다양한 하중 및 준능동 제어시스템에 적용하여 검증할 필요가 있다고 판단된다. 준능동 제어시스템은 수동 제어시스템에 비하여 설치와 운용에 추가적인 비용이 필요하기 때문에 본 연구의 경우와 같이 30%의 추가적인 응답 저감을 위해서 준능동 제어시스템을 활용하는 것이 필요한지에 대해서는 경제성, 구조안전성 등 다각적인 측면에서 검토가 필요할 것이다.

References

- [1] S. David, H. Aja, M. Chris J., G. Arthur, S. Laurent, D. George, S. Julian, A. Ioannis, P. Veda, L. Marc, D. Sander, G. Dominik, N. John, K. Nal, S. Ilya, L. Timothy, L. Madeleine, K. Koray, G. Thore, H. Demis, "Mastering the game of Go with deep neural networks and tree search", *Nature*, Vol.529, pp.484-489, 2016. DOI: <https://doi.org/10.1038/nature16961>
- [2] OpenAI, ChatGPT: Optimizing Language Models for Dialogue. Available From: <https://openai.com/blog/chatgpt/> (accessed Dec. 23, 2022)
- [3] T. Kim, O. S. Kwon, J. Song, "Response prediction of nonlinear hysteretic systems by deep neural networks", *Neural Networks*, Vol. 111, pp.1-10, 2019. DOI: <https://doi.org/10.1016/j.neunet.2018.12.005>
- [4] H. S. Kim, "Development of seismic response simulation model for building structures with semi-active control devices using recurrent neural network", *Applied Sciences*, Vol. 10, Article ID 3915, June 2020. DOI: <https://doi.org/10.3390/app10113915>
- [5] Z. Wang, N. Pedroni, I. Zentner, E. Zio, "Seismic fragility analysis with artificial neural networks: Application to nuclear power plant equipment", *Engineering Structures*, Vol. 162, pp.213-225, May 2018. DOI: <https://doi.org/10.1016/j.engstruct.2018.02.024>
- [6] L. Buşoniu, T. D. Bruin, D. Tolić, J. Kober, I. Alunko, "Reinforcement learning for control: Performance, stability, and deep approximators", *Annual Reviews in Control*, Vol. 46, pp.8-28, 2018. DOI: <https://doi.org/10.1016/j.arcontrol.2018.09.005>
- [7] A. Khalatbarisoltani, M. Soleymani, M. Khodadadi, "Online control of an active seismic system via reinforcement learning", *Structural Control and Health Monitoring*, Vol. 26, e2298, March 2019. DOI: <https://doi.org/10.1002/stc.2298>
- [8] S. S. Eshkevari, S. S. Eshkevari, D. Sen, S. N. Pakzad, "Active structural control framework using policy-gradient reinforcement learning", *Engineering Structures*, Vol. 274, Article ID 115122, January 2023. DOI: <https://doi.org/10.1016/j.engstruct.2022.115122>
- [9] D. Lee, S. Jin, C. Lee, "Deep reinforcement learning of semi-active suspension controller for vehicle ride comfort", *IEEE Transactions on Vehicular Technology*, Vol. 72, pp.327-339, January 2023. DOI: <https://doi.org/10.1109/TVT.2022.3207510>
- [10] J. W. Kang, H. S. Kim, "Optimal design of semi-active mid-story isolation system using supervised learning and reinforcement learning", *Journal of Korean Association for Spatial Structures*, Vol. 21, pp.91-98, December, 2021. DOI: <https://doi.org/10.9712/KASS.2021.21.4.73>
- [11] T. Sueoka, S. Torii, Y. Tsuneki, "The application of response control design using middle-story isolation system to high-rise building", *Proceeding of The 13th World Conference on Earthquake Engineering*, Vancouver, B.C., Canada, Paper No. 3457, August 1-6, 2004.
- [12] S. Nagarajaiah, S. Narasimhan, "Smart base-isolated benchmark building. Part II: phase I sample controllers for linear isolation systems", *Journal of Structural Control and Health Monitoring*, Vol. 12, pp.589-604, 2006. DOI: <https://doi.org/10.1002/stc.100>
- [13] M. Volodymyr, K. Koray, S. David, A. R. Andrei, V. Joel, G. B. Marc, G. Alex, R. Martin, K. F. Andreas, O. Georg, P. Stig, B. Charles, S. Amir, A. Ioannis, K. Helen, K. Dharshan, W. Daan, L. Shane, H. Demis, "Human-level control through deep reinforcement learning", *Nature*, Vol. 518, pp. 529-533, 2015. DOI: <https://doi.org/10.1038/nature14236>
- [14] J. H. Koo, M. Setareh, T. M. Murray, "In search of suitable control methods for semi-active tuned vibration absorbers", *Journal of Vibration and Control*, Vol. 10, pp.163-174, February 2004. DOI: <https://doi.org/10.1177/1077546304032020>

김 현 수(Hyun-Su Kim)

[정회원]



- 1998년 2월 : 성균관대학교 건축공학과 (공학석사)
- 2002년 8월 : 성균관대학교 건축공학과 (공학박사)
- 2004년 12월 : Texas A&M University, Department of Civil Engineering 박사후 연구원
- 2008년 3월 ~ 현재 : 선문대학교 건축학부 교수

<관심분야>

구조해석, 진동제어, 내진설계, 기계학습