

도시 화재 시뮬레이션에서의 효과적인 화재 대응을 위한 강화학습 적용 솔루션의 설계 및 구현

여상호, 오상윤
아주대학교 인공지능학과
{soboru963, syoh}@ajou.ac.kr

Adopting Reinforcement Learning for Efficient Fire Disaster Response in City Fire Simulation

Sangho Yeo, Sangyoon Oh*
Dept. of Artificial Intelligence, Ajou University
* Corresponding Author

요 약

도시의 인구 밀집도가 증가함에 따라 도시의 단위 면적당 건물 밀집도 역시 증가하고 있으며, 이에 도시 화재는 대규모 화재로 발전할 가능성이 높다. 도시 내 대규모 화재로 인한 인명 및 경제적인 피해를 최소화하기 위해 시뮬레이션 기반의 화재 대응 방안들이 널리 연구되고 있으며, 최근에는 시뮬레이션에서 효과적인 화재 대응 방안을 탐색하기 위해 강화학습 기술을 활용하는 연구들이 소개되고 있다. 그러나, 시뮬레이션의 규모가 커지는 경우, 상태 정보 및 화재 대응을 위한 행위 공간의 크기가 증가함으로써 강화학습의 복잡도가 증가하며, 이에 따라 학습 확장성이 저하되는 문제가 발생한다. 본 논문에서는 시뮬레이션 규모 증가 시 강화학습의 학습 확장성을 유지하기 위해, 화재 상황 정보와 재난 대응을 위한 행위 공간을 변환하는 기법을 제안한다. 실험 결과를 통해 기존에 강화학습 모델의 학습이 어려웠던 대규모 도시 재난 시뮬레이션에서 본 기법을 적용한 강화학습 모델은 학습 수행이 가능하였으며, 화재 피해가 없는 상황의 적합도를 100%로 하고, 이것 대비 99.2%의 화재 대응 적합도를 달성했다.

1. 서론

도시 화재 시뮬레이션은 화재가 발생한 건물에 대하여 발생된 열 에너지의 이동 과정을 물리적 모델을 통해 정의하여 실제 화재 발생 환경과 유사한 시뮬레이션이 수행되도록 한다. 실제 환경과 유사한 물리적 모델을 적용한 기존 도시 화재 시뮬레이션들[1-4]은 도시 지도 데이터를 기반으로 재난 대응 방안을 시험 및 평가할 수 있는 도구로 활용된다.

실제 화재 발생 상황에서 화재의 발생 위치와 시간은 예측 불가능하기 때문에 도시 내 모든 건물은 잠재적인 화재 발생 요인이 된다. 따라서, 도시 화재 시뮬레이션을 강화학습에 활용하기 위해서 화재 발생 가능성이 있는 모든 건물의 특성들을 상태 및 행위 정보에 정의해야 한다. 그러나, 이러한 상태와 행위 정보의 정의는 시뮬레이션 환경 내 도시의 규모가 증가함에 따라 학습 복잡도를 증가시키게 되어 학습을 어렵게 한다.

본 제안 솔루션은 화재 시뮬레이션 내 도시 규모에 증가에 따라 학습 확장성이 저해되는 문제를 해결하

기 위해서 화재 상태 정보 및 행위 공간의 가변성을 고려하여 학습 확장성 한계를 극복할 수 있는 양방향 정보 변환 과정을 정의한다.

2. 관련 연구

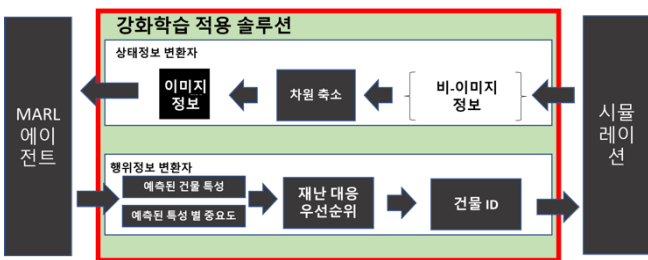
강화학습은 다양한 재난 상황에서 효과적인 재난 대응 방안 탐색을 위해 널리 활용된다. 기존 연구에서는 EMS 팀 배치[5], 홍수 상황에서의 구조 팀 급파[6], 산불 진압 대응[7]과 같은 다양한 상황에서 활용되어진다.

강화학습을 재난 상황에 적용하기 위해 시뮬레이션 환경과 학습 모델 간의 채널들(상태, 행위, 보상)을 정의해야 한다. 기존 연구들[6,7]에서는 재난 시뮬레이션을 강화학습 모델과 같이 구성하여 채널 정의에 어려움이 없지만, 기존 재난 시뮬레이션에 강화학습 모델을 적용하는 경우 재난 시뮬레이션에서 정의되는 정보들을 강화학습 모델에 적합한 채널 정보로 변환하는 과정이 요구된다.

3. 제안 솔루션 구성

본 솔루션의 구성요소는 두 가지로 나누어 정의된다. 첫 번째 구성 요소는 재난 상태 정보 변환자이다. 기존 시물레이션 환경을 학습 모델에 직접 적용하는 경우 대규모 화재는 적은 빈도로 발생함에도[8] 불구하고 예측 불가능한 모든 재난 상황을 고려하기 위해 모든 건물의 상태 정보를 표현해야 한다. 이러한 상태정보 정의는 불필요한 정보를 상당수 포함하게 되어 학습 효율성을 떨어트릴 뿐만 아니라 학습 확장성을 저해하는 요인이 된다. 이 문제를 해결하기 위해 화재 발생 건물들의 상태 정보만을 학습 데이터로 정의하는 경우 불필요한 정보를 포함하지 않게 되지만, 예측 불가능한 화재 발생과 전파 및 화재 진압으로 인해 화재 건물의 수는 지속적으로 변화한다. 이 경우, 일반적으로 강화학습에 활용되는 상태 정보는 고정된 크기로 정의되기 때문에[9] 화재 건물 수에 따른 가변적 크기의 화재 정보는 학습에 적합한 고정 크기 데이터로 변환되어야 한다. 이를 위해 재난 상태 정보 변환자는 차원 축소 기법을 활용하여 가변 크기의 상태정보를 비트맵 형태의 이미지 정보로 변환시킨다.

두 번째 구성 요소는 강화학습 에이전트의 효과적인 행위 선택 과정을 지원하기 위한 행위정보 변환자이다. 기존 도시 화재 시물레이션에 강화학습 기법을 직접 적용한다면 시물레이션 내의 잠재적인 모든 화재 발생 가능성을 고려하기 위해 모든 건물을 행위 공간으로 정의해야 한다. 이 경우, 행위 공간의 크기가 매우 커지게 되고 따라서 학습 복잡도가 증가하는 문제가 발생한다. 본 솔루션은 이 문제를 해결하기 위하여 강화학습 에이전트가 직접적으로 화재 대응을 수행할 건물을 선택하지 않고, 화재 재난 대응의 결정에 필요한 건물 별 특성 정보와 특성 정보 간 중요도를 평가하도록 한다. 이후, 솔루션 내에서 해당 예측 정보 및 중요도를 기반으로 시물레이션 내에서 화재 진압이 우선되어야 할 건물을 선택한다. 그림 1 은 제안 솔루션의 요소 및 상관관계를 보여준다.

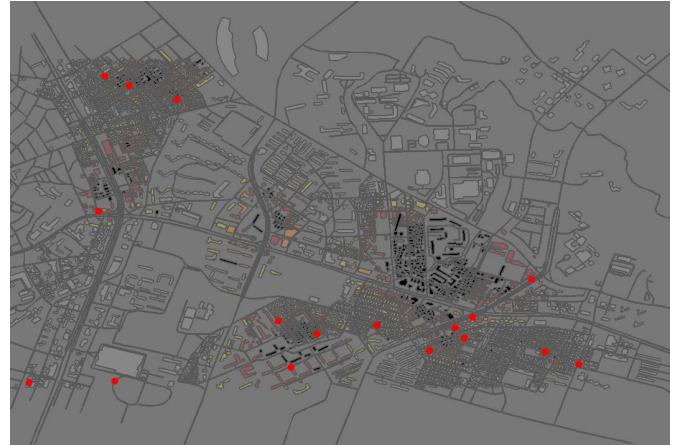


(그림 1) 강화학습 적용 솔루션 개요

4. 실험

본 솔루션의 시험 환경은 한국 과학 기술 정보 연구원(KISTI)의 NEURON 클러스터의 자원[10]을 활용하여 구성하였다. 시험은 수원시 영통구 원천동 인근의 OpenStreetMap 데이터[11]를 활용하였으며, 해당 시물레이션 내에는 3355 개의 건물과 18 개의

화재 대응 에이전트가 정의되었다. 그림 2 는 지도를 활용한 시물레이션의 예시이다. 또한 멀티 에이전트의 학습을 위하여 대표적인 멀티-에이전트 강화학습 모델인 MA-DDPG(Multi-Agent Deep Deterministic Policy Gradient) 모델[12]을 솔루션을 통해 학습하였다. 솔루션 시험 결과, 솔루션을 활용한 학습을 수행 후, 화재에 대한 피해가 없는 경우를 100%로 할 때, 98.2%의 화재 대응 적합도를 확인할 수 있었다.



(그림 2) 수원시 원천동 인근 지도를 활용한 시물레이션

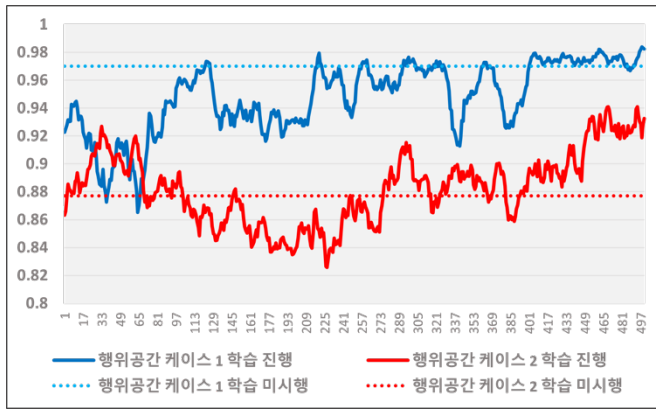
<표 1> 실험 비교군

비교군	설명
행위공간 케이스 1	에이전트의 행위가 건물 특성 및 특성 중요도를 모두 고려하도록 정의됨.
행위공간 케이스 2	에이전트의 행위 공간이 건물의 특성만 고려하도록 정의됨.
거리 기반 탐욕 정책	거리에 따라 가장 가까운 화재 발생 건물 선택
[13]에서의 탐욕 정책	거리, 화재 피해도, 인접 건물의 수에 따른 화재 대응 우선 건물 선택

<표 2> 비교군 별 화재 대응도

비교군	화재 대응도
행위공간 케이스 1 학습 후	98.2%
행위공간 케이스 1 학습 이전	97.0%
행위공간 케이스 2 학습 이후	93.2%
행위공간 케이스 2 학습 이전	87.7%
거리 기반 탐욕 정책	77.2%
[13]에서의 탐욕 정책	57.1%

제안 기법과 타 제안기법의 화재 대응 적합도 비교는 표 1 에 나타나 있으며, 그림 3 은 학습의 진행 과정을 보여준다.



(그림 3) 행위 공간 정의에 따른 학습 그래프

5. 결론

도시 화재 시뮬레이션 내 도시 규모의 증가에 따라 발생한 강화학습의 학습 확장성 저해 문제를 위해 본 솔루션을 제안하였다. 본 논문을 위해 구성된 시뮬레이션의 화재 대응 과정의 난이도를 높여 다양한 도시 및 화재 환경에서 추가 실험을 통해 제안 기법의 성능을 심층 분석할 계획이다.

사사문구

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터지원사업의 연구결과로 수행되었음" (IITP-2021-2018-0-01431)

참고문헌

[1] Iwami, Tatsuya, et al. "Simulation of city fire.", Fire Science and Technology, 23, 2, 132-140, 2004

[2] Nishino, Tomoaki. "Physics-based urban fire spread simulation coupled with stochastic occurrence of spot fires." Stochastic Environment Research and Risk Assessment, 33, 2, 451-463, 2019

[3] Shaham, Yonatan, and Itzhak Benenson. "Modeling fire spread in cities with non-flammable construction." International journal of disaster risk reduction, 31, 1337-1353, 2018

[4] Skinner, Cameron. and Sarvapali Ramchurn. "The robocup rescue simulation." Proceedings of the 9th International Conference on Autonomous Agent and Multiagent Systems, Toronto, 2010, 1647-1648

[5] Lee, Hyun-Rok. and Taesik Lee. "Multi-agent reinforcement learning algorithm to solve a partially-observable multi-agent problem in disaster response.", European Journal of Operational Research, 291, 1, 296-308, 2021.

[6] Yan, Li. Et al. "MobiRescue: Reinforcement Learning based Rescue Team Dispatching in a Flooding Disaster." 2020 IEEE 40th International Conference on Distributed Computing Systems(ICDCS), Singapore, 2020, 111-121.

[7] Haksar, Ravi N., and Mac Schwager. "Distributed deep

reinforcement learning for fighting forest fires with a network aerial robots.", 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (ROS), Madrid, 2018, 1067-1074

[8] U.S Fire Administration, "Operational Lessons Learned in Disaster Response.", 10-11, 2015

[9] Huegle, Maria. et al., "Dynamic input for deep reinforcement learning in autonomous driving.", 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Macau, 2019, 7566-7573

[10] 한국과학기술정보연구원 NEURON 뉴론 클러스터, <https://www.ksc.re.kr/mobile/ggspcpt/neuron>

[11] OpenStreetMap, <https://www.openstreetmap.org>

[12] Lowe, Ryan. et al. "Multi-agent actor-critic for mixed cooperative-competitive environments." arXiv preprint arXiv:1706:02275, 2017

[13] Animesh Goyal, "Multi-Agent Deep Reinforcement Learning for RoboCup Rescue Simulator.", Master dissertation, The University of Texas at Austin, Austin, USA.