

# NS3-Gym을 이용한 TCP 혼잡 제어 개선

문형석, 임지호, 김유미, 고한얼

경희대학교

{amin999, koronero01, yumikim1201, heko}@khu.ac.kr

## Improved TCP congestion control using NS3-Gym

Hyeongseok Moon, Jiho Im, Yumi Kim, and Haneul Ko

Kyunghee Univ

요약

최근 네트워크는 이동 통신이 증가하고 많은 데이터 트래픽을 사용하는 콘텐츠가 증가하면서 계속해서 복잡해지고 있다. 이런 환경에서 TCP의 혼잡 제어 성능을 더 높이기 위해 본 논문에서는 패킷의 처리율과 round trip time (RTT)를 고려하여 적절한 패킷 전송량 (즉, cwnd 크기)를 정하는 강화학습 기반 TCP(RLTCP)를 제안한다. openAI Gym과 NS3를 결합한 NS3-gym을 이용하여 RLTCP의 성능 최적화를 진행하였다.

### I. 서론

최근 LTE, 5G의 보급이 대중화되면서 네트워크를 사용하는 모바일 디바이스의 수가 증가하였고, 데이터 트래픽을 많이 사용하는 비디오 스트리밍을 이용하는 사람이 증가하였다. 그뿐만 아니라 소형화된 기지국의 증가 등 모바일 네트워크의 관리 복잡성 또한 증가하였다[1]. 기존의 TCP는 유선 연결을 기준으로 설계되었기 때문에 이와 같은 모바일 네트워크 상황에서는 완벽하게 동작하지 않는다. 그러므로 기존 TCP의 혼잡 제어 방식으로는 한계에 도달했고 기존 방식을 개선한 혼잡 제어 방식이 필요하다.

기계학습의 한 종류인 강화학습은 학습하는 에이전트가 주어진 환경과 상호 작용하면서 특정 목표에 대한 최적의 방법을 학습하는 방법이다. 에이전트는 주어진 환경에서 행동을 수행하고 얻은 결과를 바탕으로 Reward를 얻는다. 이를 통해 에이전트는 누적 보상이 큰 의사 결정 전략을 찾으려고 노력하고 좋은 방향으로 학습이 진행된다.

본 논문에서는 환경에 스스로 적응해 나갈 수 있는 강화학습을 이용하여 복잡한 네트워크 환경에서 효율적으로 작동하는 혼잡 제어 알고리즘 (Reinforcement Learning-based TCP, 이하 RLTCP)을 제안하고 강화학습 툴킷인 openAI Gym과 네트워크 시뮬레이션 프로그램인 NS3를 결합한 NS3-Gym[3]에 적용하여 성능 최적화 및 평가를 진행한다.

### II. NS3-Gym 프레임워크

본 논문에서 사용한 전체 프레임워크는 그림 1과 같다. 강화학습 agent의 역할을 수행하는 Python과 강화학습 환경인 NS3는 각각의 프로세스에서 따로 동작한다. 강화학습의 에이전트가 cwnd 크기를 바꾸면 NS3에서는 바뀐 cwnd를 기준으로 패킷을 보내는 송신 디바이스가 수신 디바이스에 패킷을 전송한다. 이때 수신 디바이스에 성공적으로 전송된 패킷과 RTT에 따라 State와 Reward가 결정되고 이를 에이전트에게 전송한다. 본 프레임워크에서는 ZMQ 소켓 기반으로 강화학습 agent와 환경 사이에 해당 정보들을 교환한다. 즉, protocol buffers 메시지를 통해 강화학습 Python agent로부터 Action을 NS3쪽으로 전달하고, C++ 기반의 NS3에서 State와 Reward 정보를 Python agent로 전달한다.

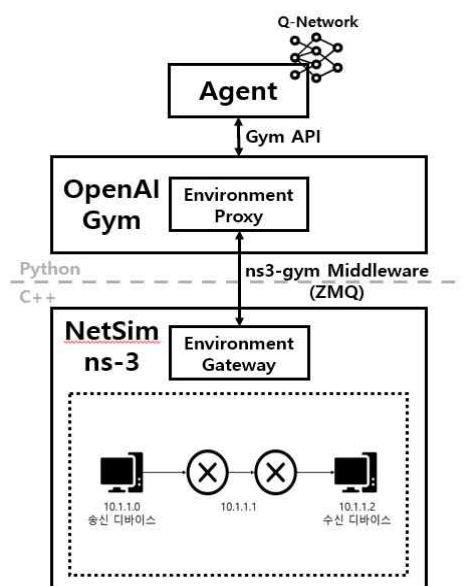


그림 1. NS3-Gym 프레임워크

### III. 강화학습 모델

강화학습의 state space는 다음과 같다.

$$S = \{SI, T, ST, NI, Th, C, SS, SA, B, RT, RP\}$$

각각의 state가 의미하는 바는 Table 1에 정리되어 있다.

Notation	Meaning
SI	TCP 소켓을 구분하는 ID
T	이벤트 기반 or 시간 기간 선택
ST	시뮬레이션 시간
NI	시뮬레이션에서 사용하는 노드의 ID
Th	slow start threshold
C	TCP의 윈도우 크기
SS	TCP 세그먼트의 크기
SA	수신 확인된 세그먼트의 수
B	전송 중인 데이터 크기
RT	왕복 시간
RP	수신된 패킷의 수

Table 1. State 의미

RLTCP에서는 전송자가 cwnd의 크기를 바꾸는 것으로 Action을 정의한다. 이에, Action space는 다음과 같이 정의할 수 있다.

$$A = \{I, D, N\}$$

[*I*: 증가, *D*: 감소, *N*: 변화 없음]

Reward는 에이전트가 네트워크 환경 내에서 Action을 실행한 후 얻은 결과를 바탕으로 얻는 보상이다. 에이전트는 누적 Reward가 커지는 방향으로 학습을 하게 된다. Reward는 처리율, RTT를 가지고 다음과 같이 계산한다. 처리율은 보낸 패킷과 받은 패킷의 비율로 정해진다.

$$R = \alpha * TP - \alpha * RT$$

[*TP*: 처리율, *RT*: RTT]

에이전트가 학습을 잘 진행했다면 네트워크 환경에서 패킷 처리율이 증가하고 RTT는 감소하게 된다. 따라서 Reward는 증가하게 되기 때문에 점점 성능이 증가하는 방향으로 학습이 가능하다.

이번 연구에서 사용한 강화학습 알고리즘은 DQN(Deep Q-Network)[2]이다. DQN은 기존 Q-learning의 문제를 극복하기 위한 알고리즘이다. DQN의 특징은 Replay buffer와 Target network이다. Replay buffer는 action 결과를 즉시 활용하지 않고, 의도적으로 지연시켜 기존 Q-learning에서 발생하는 sample correlation 문제를 극복한다. Target network는 Q-network를 복제하여 이중화 구조를 만듦으로써 moving Q-target 문제를 효과적으로 해결한다.

#### IV. 성능 평가

위와 같이 설정한 강화학습 모델을 NS3-Gym에 적용하여 시뮬레이션을 진행한다. 기본 파라미터 설정은 Table 2에 정리되어 있다.

Parameter	Value
Access Bandwidth	10Mbps
Bottleneck Delay	20ms
Queue management	FIFO
I	300
D	-50
$\alpha$	0.7

Table 2. 기본 파라미터 설정

그림 2, 3의 결과를 확인해 보면 Bottleneck bandwidth가 증가함에 따라 사용 가능한 대역폭도 늘기에 처리율은 증가하고 RTT는 감소했다. 강화학습을 진행한 후와 TCP의 결과를 비교해 보면 일반 TCP에 비해 RLTCP의 처리율이 더 많이 증가하고 RTT는 더 많이 감소한 것을 확인할 수 있다.




그림 2. Bottleneck Bandwidth에 따른 처리율 변화




그림 3. Bottleneck Bandwidth에 따른 RTT 변화

그림 4, 5의 결과를 확인해 보면 패킷을 보내는 노드 수가 증가함에 따라 한정된 대역폭을 여러 노드가 나누어 사용하기에 처리율은 감소하고 RTT는 증가했다. 하지만, 적절한 cwnd 조절로 인하여 일반 TCP에 비해 RLTCP가 더 좋은 성능을 보여주는 것을 확인할 수 있다.




그림 4. 전송 노드 수에 따른 처리율 변화




그림 5. 전송 노드 수에 따른 RTT 변화

#### V. 결론

본 논문에서는 네트워크 환경에 따라 TCP의 혼잡 제어를 더 효율적으로 동작시키도록 cwnd 크기를 조절하는 RLTCP를 제안하였다. 성능평가 결과는 학습하지 않은 TCP와 비교했을 때 처리율을 증가시키고 RTT를 감소시키는 것을 보여주었다. 향후 연구 계획으로는 본 연구의 프레임워크를 기반으로 다른 네트워크 제어의 최적화도 진행해 볼 예정이다.

#### ACKNOWLEDGMENT

본 연구는 2022년 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(과제번호: 2022R1F1A1063183)

#### 참고 문헌

- [1] 한수빈, 백상현. "OpenAIGym을 활용한 지능형 네트워크 시뮬레이션 연구 동향." 한국통신학회지, vol 40, pp. 35-41, Jan. 2023.
- [2] Mohit S. "Deep Q Network (DQN), Double DQN, and Dueling DQN," Deep Reinforcement Learning, pp. 95 - 108, Jun. 2019.
- [3] Gawłowicz P., and Zubow A. "ns-3 meets OpenAI Gym: The Playground for Machine Learning in Networking Research," in Proc. ACM MSWIM 2019, Nov. 2019