

Constrained Policy Optimization

Joshua Achiam, David Held, Aviv Tamar, Pieter Abbeel

Notation

주요 기호 및 의미

- π : 정책 함수 (Policy Function) – 상태에서의 행동 분포를 나타내는 함수. $\pi(a|s)$ 는 상태 s 에서 행동 a 를 선택할 확률.
- π_k : k 번째 반복에서의 정책 – 학습 과정에서 현재 정책을 나타냄. 매 반복마다 정책이 업데이트되어 새로운 정책 π_{k+1} 로 변경.
- S : 상태 집합 (State Space) – 에이전트가 탐색할 수 있는 모든 상태의 집합.
- A : 행동 집합 (Action Space) – 에이전트가 선택할 수 있는 모든 행동의 집합.
- $R(s, a, s')$: 보상 함수 (Reward Function) – 상태 s 에서 행동 a 를 취하고 다음 상태 s' 로 전이할 때 얻는 보상.
- $P(s'|s, a)$: 상태 전이 확률 (Transition Probability Function) – 상태 s 에서 행동 a 를 취할 때 다음 상태가 s' 일 확률.
- μ : 초기 상태 분포 (Starting State Distribution) – 에이전트가 학습을 시작할 때 상태 s 가 선택될 확률 분포.
- τ : 경로 (Trajectory) – 상태 및 행동의 순서인 $(s_0, a_0, s_1, a_1, \dots)$ 로 구성된 에이전트의 전체 이동 경로.
- γ : 감쇠 인자 (Discount Factor) – 미래 보상에 대한 가중치를 나타내는 파라미터로, 0과 1 사이의 값을 가지며 미래 보상에 대한 중요도를 결정.

Notation

가치 함수 및 반환 관련

- $J(\pi)$: 정책의 성능 지표 (**Performance Measure**) – 정책 π 에 따른 기대 총 보상.

$$J(\pi) = \mathbb{E}_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1}) \right]$$

- $R(\tau)$: 경로의 총 보상 (**Total Return of a Trajectory**) – 경로 τ 를 따라 수집된 모든 감쇠된 보상의 합.
- $V^\pi(s)$: 상태 가치 함수 (**State Value Function**) – 주어진 상태 s 에서 정책 π 를 따를 때 기대되는 총 보상.

$$V^\pi(s) = \mathbb{E}_{\tau \sim \pi} [R(\tau) \mid s_0 = s]$$

- $Q^\pi(s, a)$: 상태-행동 가치 함수 (**Action-Value Function**) – 주어진 상태 s 와 행동 a 에서 정책 π 를 따를 때 기대되는 총 보상.

$$Q^\pi(s, a) = \mathbb{E}_{\tau \sim \pi} [R(\tau) \mid s_0 = s, a_0 = a]$$

- $A^\pi(s, a)$: 이점 함수 (**Advantage Function**) – 상태-행동 가치 함수와 상태 가치 함수의 차이를 나타내며, 특정 행동이 얼마나 더 나은지를 나타냄.

$$A^\pi(s, a) = Q^\pi(s, a) - V^\pi(s)$$

Notation

상태 분포 및 제약 관련

- $d^\pi(s)$: 할인된 미래 상태 분포 (**Discounted Future State Distribution**) – 정책 π 를 따를 때, 시간에 따른 감쇠 효과를 고려하여 상태 s 에 있을 확률 분포.

$$d^\pi(s) = (1 - \gamma) \sum_{t=0}^{\infty} \gamma^t P(s_t = s \mid \pi)$$

- C_i : 제약 비용 함수 (**Constraint Cost Function**) – 보상 함수와 유사하게 특정 제약 조건에 대해 비용을 나타냄.
- $J_{C_i}(\pi)$: 제약 비용 반환 (**Constraint Return**) – 정책 π 에 따른 제약 비용 함수의 기대 총 비용.

$$J_{C_i}(\pi) = \mathbb{E}_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t C_i(s_t, a_t, s_{t+1}) \right]$$

- d_i : 제약 비용 상한 (**Constraint Cost Limit**) – 각 제약 비용 함수 C_i 에 대해 만족시켜야 하는 최대 값.
- Π_C : 제약 조건을 만족하는 정책 집합 (**Feasible Policy Set for CMDP**) – 모든 제약을 만족하는 정책들의 집합.

$$\Pi_C = \{ \pi \in \Pi : \forall i, J_{C_i}(\pi) \leq d_i \}$$

Notation

최적화 및 근사 관련

- g : 정책의 기울기 벡터 (**Policy Gradient Vector**) – 보상을 최대화하는 방향을 나타내는 벡터.
- b_i : 제약 조건의 기울기 벡터 (**Constraint Gradient Vector**) – 제약 조건에 대한 기울기 벡터.
- H : 피셔 정보 행렬 (**Fisher Information Matrix**) – 정책의 파라미터화된 분포의 기울기를 나타내는 정보 행렬로, 근사 이차식 제약에 사용됨.
- δ : 정책 업데이트의 신뢰 영역 크기 (**Trust Region Size**) – 정책이 업데이트될 때 새로운 정책과 기존 정책 간의 변화량을 제한하는 파라미터.
- $D_{KL}(\pi \parallel \pi_k)$: **KL-divergence (쿨백-라이블러 발산)** – 새로운 정책 π 와 기존 정책 π_k 간의 차이를 측정하는 지표로, 두 확률 분포 간의 차이.

Introduction

- In reinforcement learning (RL), agents learn to act by trial and error, **gradually improving their performance** at the task as learning progresses.
- In many realistic domains, however, it may be **unacceptable to give an agent complete freedom**.
 - e.g. industrial robot arm learning to assemble a new product in a factory
- In domains like this, **safe exploration for RL agents** is important



robot arm in a factory

Introduction

- To deal with these problem, **Constrained Markov Decision Process (CMDP)** is used.

$$\mathbf{MDP} = (S, A, P, R, \mu)$$

- S: 상태 집합 (State Space)
- A: 행동 집합 (Action Space)
- $P(s' | s, a)$: 상태 전이 확률 (Transition Probability)
- $R(s, a, s')$: 보상 함수 (Reward Function)
- μ : 초기 상태 분포 (Initial State Distribution)



$$\mathbf{CMDP} = (S, A, P, R, \mu, C, d)$$

- C: 제약 비용 함수들 (Constraint Cost Functions)
- d: 제약 상한 값들 (Constraint Limits)

Adding constraint cost functions $C_i(s, a, s')$ and constraint limits d_i

Purpose of MDP: 보상 최대화

$$J(\pi) = \mathbb{E}_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1}) \right]$$

- π : 정책
- τ : 경로 (trajectory)
- γ : 할인 인자 (Discount Factor)



Purpose of CMDP: 보상 최대화 및 제약 조건 만족

$$\max_{\pi} J(\pi) \quad \text{s.t.} \quad J_{C_i}(\pi) \leq d_i, \quad \forall i \in \{1, \dots, m\}$$

$$J_{C_i}(\pi) = \mathbb{E}_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t C_i(s_t, a_t, s_{t+1}) \right]$$

Incorporating constraints into optimization: $J_{C_i}(\pi) \leq d_i$

Introduction

- Although optimal policies for finite CMDPs with known models can be obtained by linear programming, methods for **high-dimensional control are lacking**.
- Therefore, This paper shows the method that solve **CMDP for high-dimensional problem**.
- Proposed method provides **bounds on the difference in rewards or costs** between two policies π and π' .
 - Guarantees **reward increase** and **constraint satisfaction**.

Preliminaries

MDP 정의:

- An MDP is a tuple:

$$(S, A, R, P, \mu)$$

- S : Set of states
- A : Set of actions
- $R : S \times A \times S \rightarrow \mathbb{R}$: Reward function
- $P(s'|s, a) : S \times A \times S \rightarrow [0, 1]$: Transition probability
- μ : Starting state distribution

Value Functions:

- **On-policy Value Function:**

$$V^\pi(s) = \mathbb{E}_{\tau \sim \pi}[R(\tau) \mid s_0 = s]$$

- **On-policy Action-Value Function:**

$$Q^\pi(s, a) = \mathbb{E}_{\tau \sim \pi}[R(\tau) \mid s_0 = s, a_0 = a]$$

- **Advantage Function:**

$$A^\pi(s, a) = Q^\pi(s, a) - V^\pi(s)$$

Stationary Policy:

- A policy $\pi : S \rightarrow P(A)$ maps states to probability distributions over actions.
- $\pi(a|s)$: Probability of selecting action a in state s .
- **Goal:** Find a policy π that **maximizes** the performance:

$$J(\pi) = \mathbb{E}_{\tau \sim \pi} \left[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1}) \right]$$

Discounted Future State Distribution:

- $d^\pi(s)$: Probability of visiting state s under policy π :

$$d^\pi(s) = (1 - \gamma) \sum_{t=0}^{\infty} \gamma^t P(s_t = s \mid \pi)$$

두 정책 간의 성능 차이:

- Difference in performance between policies π' and π :

$$J(\pi') - J(\pi) = \frac{1}{1 - \gamma} \mathbb{E}_{s \sim d^{\pi'}, a \sim \pi'} [A^\pi(s, a)]$$

- Where:

- $a \sim \pi'$: Action sampled from policy π' in state s .

Kakade, Sham and Langford, John.
Approximately Optimal Approximate
Reinforcement Learning. Proceedings of
the 19th International Conference on
Machine Learning, pp. 267-274, 2002.

Method

- TRPO로부터 영감을 받아, Surrogate 함수로써 CPO를 표현함
 - TRPO의 정책 업데이트 함수: KL-divergence 제한을 통해 새로운 정책이 기존 정책에서 크게 변하지 않도록 제약을 둬

$$\pi_{k+1} = \arg \max_{\pi \in \Pi_{\theta}} \mathbb{E}_{s \sim d^{\pi_k}, a \sim \pi} [A^{\pi_k}(s, a)] \quad \text{s.t.} \quad \bar{D}_{KL}(\pi || \pi_k) \leq \delta$$

- CPO의 정책 업데이트 함수: TRPO의 신뢰 영역 최적화 방법을 제약 조건이 있는 상황(CMDP)에서 적용한 방법

$$\pi_{k+1} = \arg \max_{\pi \in \Pi_{\theta}} \mathbb{E}_{s \sim d^{\pi_k}, a \sim \pi} [A^{\pi_k}(s, a)] \quad \text{s.t.} \quad \underline{J_{C_i}(\pi_k) + \frac{1}{1-\gamma} \mathbb{E}_{s \sim d^{\pi_k}, a \sim \pi} [A_{C_i}^{\pi_k}(s, a)] \leq d_i, \forall i, \quad \bar{D}_{KL}(\pi || \pi_k) \leq \delta}$$