

## 1.はじめに

深層強化学習 (DRL) は、環境との相互作用を通じて累積報酬を最大化する方策を深層ニューラルネットワークで学習する枠組みである。代表的な手法である DQN は、状態  $s$  において行動  $a$  を選択したときの累積報酬の期待値を表す行動価値 (Q 値) をニューラルネットワークで近似する。しかし、実際より Q 値を大きく見積もり、学習が不安定化する問題がある。この問題は、Q 値に含まれる誤差 (推定誤差) とその誤差が増幅されやすい学習構造に起因する。Double DQN (DDQN) [1] は、この学習構造を改善する代表的な手法であるが、推定誤差を直接抑制する手法ではない。そこで本研究では、相互学習 (DML) を DDQN に導入し、学習の安定化を図る Mutual DDQN を提案する。

## 2. DDQN

従来の DQN は、選択した行動の Q 値が目標値  $y$  に近くように学習する。しかし、目標値  $y$  は、次状態  $s'$  における最大の Q 値に依存して求められる構造のため、推定誤差により大きく見積もられた Q 値が目標値  $y$  に反映されやすい。DDQN では、目標値  $y$  を求める際に、行動の選択と Q 値の算出に異なるネットワークを用いる。具体的には、学習によって逐次更新されるオンラインネットワーク  $Q_\theta$  で次状態  $s'$  において Q 値が最大の行動  $a'$  を選択し、更新を遅らせるターゲットネットワーク  $Q_{\theta^-}$  で行動  $a'$  の Q 値を算出し、報酬  $r$  と合わせて目標値  $y$  を求める。目標値  $y$  を式 (1) に示す。

$$y = r + \gamma Q_{\theta^-}(s', \text{argmax}_{a'} Q_\theta(s', a')) \quad (1)$$

行動の選択に影響を与えた推定誤差が、Q 値の算出には反映されないため、推定誤差により大きく見積もられた Q 値を目標値  $y$  に用いる傾向を抑制できる。

## 3. 提案手法：Mutual DDQN

本研究では、異なる初期パラメータを持つ 2 つの独立したネットワーク ( $Q_{\theta_1}, Q_{\theta_2}$ ) が互いの出力を参照しながら学習する DML を DDQN に導入し、推定誤差を直接抑制する Mutual DDQN を提案する。提案手法の概要図を図 1 に示す。ネットワーク  $Q_{\theta_i}$  の学習には、式 (2) や式 (3) で定義する 2 つの損失関数  $L_{MTD}^{(i)}$  と  $L_{KL}^{(i)}$  の和を用いる。ここで  $i \in \{1, 2\}$ ,  $j \neq i$  とする。

$$L_{MTD}^{(i)} = (r + \gamma \text{mean}Q(s', a') - Q_{\theta_i}(s, a))^2 \quad (2)$$

$$L_{KL}^{(i)} = D_{KL}(p_j \| p_i) \quad (3)$$

$L_{MTD}^{(i)}$  は、平均 Q 値を用いた目標値と現在の Q 値の二乗誤差である。ここで Mean TD (MTD) は、DDQN の目標値  $y$  に用いる次状態の Q 値を、2 つのターゲットネットワークで算出した平均 Q 値  $\text{mean}Q(s', a')$  に置き換える手法である。これにより、目標値に含まれる推定誤差を緩和し、学習の安定化を図る。

$L_{KL}^{(i)}$  では、状態  $s$  における 2 つのネットワークの出力に softmax 関数を適用して得られる行動分布  $p_1$  および  $p_2$  の間で KL ダイバージェンスを最小化する。softmax 関数により行動間の相対関係を分布として表現し、すべての行動で Q 値の相対的大さと順位関係を学習する。これにより、ネットワーク間の行動分布を近づけ、行動選択の一貫性を促進する。

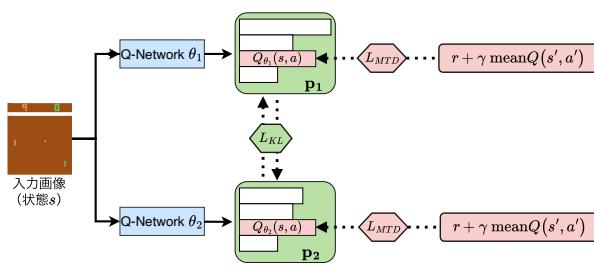


図 1: Mutual DDQN

## 4. 評価実験

### 4.1. 実験概要

行動数が異なる複数の Atari 2600 環境のタスク (Air-Raid, Enduro, Seaquest) を用い、提案手法の評価を行った。比較手法は、標準的な DDQN および提案手法とする。提案手法に導入した損失関数の分析として MTD のみ、KL のみを使用した比較を行う。学習ステップ数は合計 500 万ステップとする。提案手法の評価には、並列に学習された 2 つのネットワークのうち高い累積報酬を達成した単一ネットワークを用いる。報酬は学習、評価ともに -1 から 1 にクリップする。学習過程は DDQN と提案手法の累積報酬の推移を比較し、学習後の評価指標として、複数エピソードの平均累積報酬、および Q 値と実際の累積報酬の差である Q 値の推定誤差を用いる。

### 4.2. 実験結果

図 2 に示した累積報酬の推移より、提案手法は学習初期の立ち上がりが早く、全タスクで DDQN を上回る累積報酬の推移を示した。

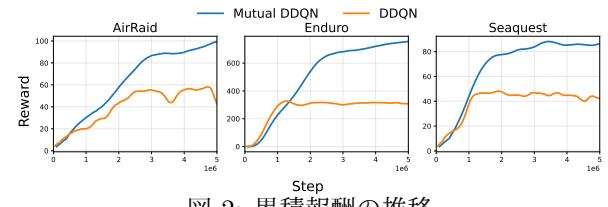


図 2: 累積報酬の推移

表 1 に示すように、全タスクにおいて提案手法は DDQN を上回る平均累積報酬を獲得した。また、MTD のみ、KL のみのいずれも DDQN から性能が向上しており、各損失の導入が有効であることを確認した。

表 1: 平均累積報酬

手法	MTD	KL	AirRaid	Enduro	Seaquest
DDQN			39	323	50
提案手法	✓	✓	88	483	95
		✓	74	834	81
	✓	✓	<b>119</b>	<b>895</b>	<b>101</b>

表 2 に示した Q 値の推定誤差より、全ての条件で推定誤差は正の値を示し、実際の累積報酬よりも推定する Q 値が高くなる傾向を確認した。提案手法は全タスクで推定誤差が最小であり、Q 値を過剰に見積もる傾向を改善している。MTD のみ、KL のみでも、DDQN と比較して推定誤差は小さいが、KL と比べて MTD がより推定誤差の減少に寄与している。

表 2: Q 値の推定誤差

手法	MTD	KL	AirRaid	Enduro	Seaquest
DDQN			2.1	8.2	2.9
提案手法	✓	✓	0.6	2.5	0.9
		✓	1.0	6.7	2.9
	✓	✓	<b>0.4</b>	<b>2.4</b>	<b>0.8</b>

## 5. おわりに

本研究では、Q 値推定を改善するために DDQN に DML を導入した Mutual DDQN を提案した。評価実験では、提案手法は従来手法を上回る累積報酬と推定誤差の改善も見られ、提案手法の有効性が示された。今後の展望として、単一ネットワークではなく複数ネットワークの平均 Q 値に基づく行動選択を DML で改善することや Actor-Critic 等の DRL 手法への応用が考えられる。

## 参考文献

- [1] H. van Hasselt et al., Deep Reinforcement Learning with Double Q-learning, AAAI, 2016.