

自然言語処理
—強化学習入門—

<https://satoyoshiharu.github.io/nlp/>

強化学習入門

代表的なアルゴリズム



価値学習

価値の漸化式的な関係(ベルマン等式)を利用する

アルゴリズム例: DQN

ゴール: $Q(s,a)$ を見つける

最適ポリシー:
 $a = \operatorname{argmax} Q(s,a)$

応用例: Googleのレコメ
ンド

ポリシー学 習

ポリシーを直接最適化する

アルゴリズム例: PG

ゴール: $\pi(s)$ を直接見
つける

最適ポリシー $\pi(s)$ は確率
的に a を決める

応用例: AlphaGo

Actor- Critic

価値学習とポリシー学習
のいいとこどりハイブリッ
ド



ベルマン等式

- ある時刻の選択とそれ以降の決定問題の価値との関係(後ろ向き再帰)を示すことで、単純な部分問題に分割する

$$\text{状態価値 } V(s_t) = \max_a \{ \text{即時報酬 } r(s_t, a_t) + \gamma V(s_{t+1}) \}$$



TD(時間的差分)学習

- ベルマン等式を使い、次の状態 s' の価値と $r + \gamma V(s')$ との差を使って、学習する。



状態価値 $V(s_t)$

\leftarrow 状態価値 $V(s_t)$

$$+ \alpha \{ \boxed{\text{即時報酬 } r_t + \gamma * \text{次の状態の価値 } V(s_{t+1})} - \boxed{\text{状態価値 } V(s_t)} \}$$

次の時刻の推定値、より正しい

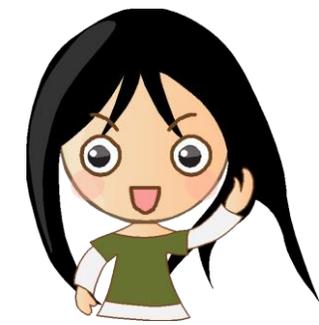
現在の推定値



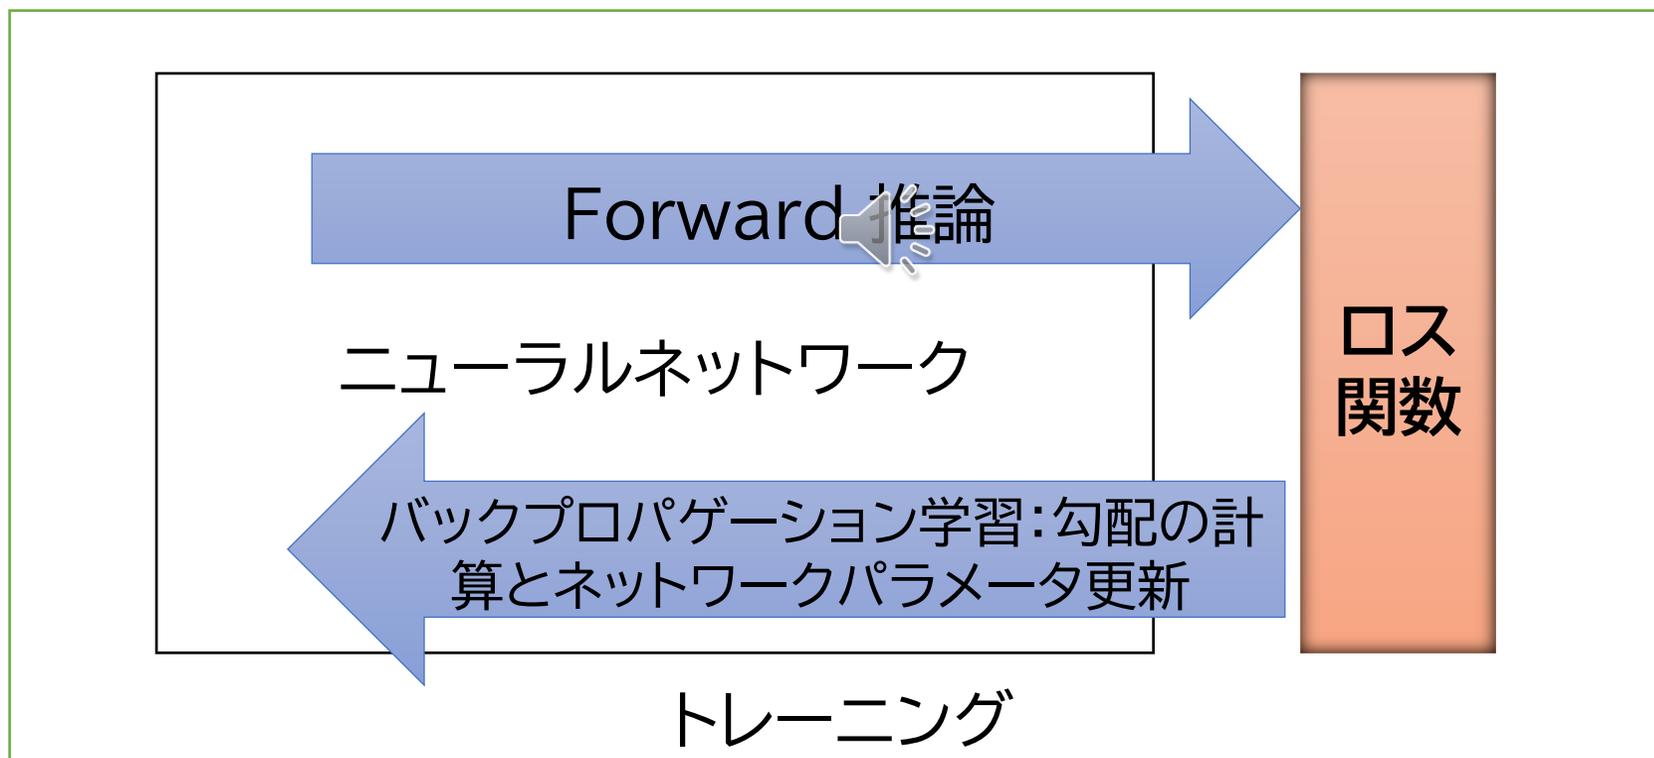
強化学習は ニューラルネット による関数 近似を利用

強化学習: 経験から
学ぶという考え方・
枠組み

ニューラルネット: 価
値やポリシー関数を
近似する

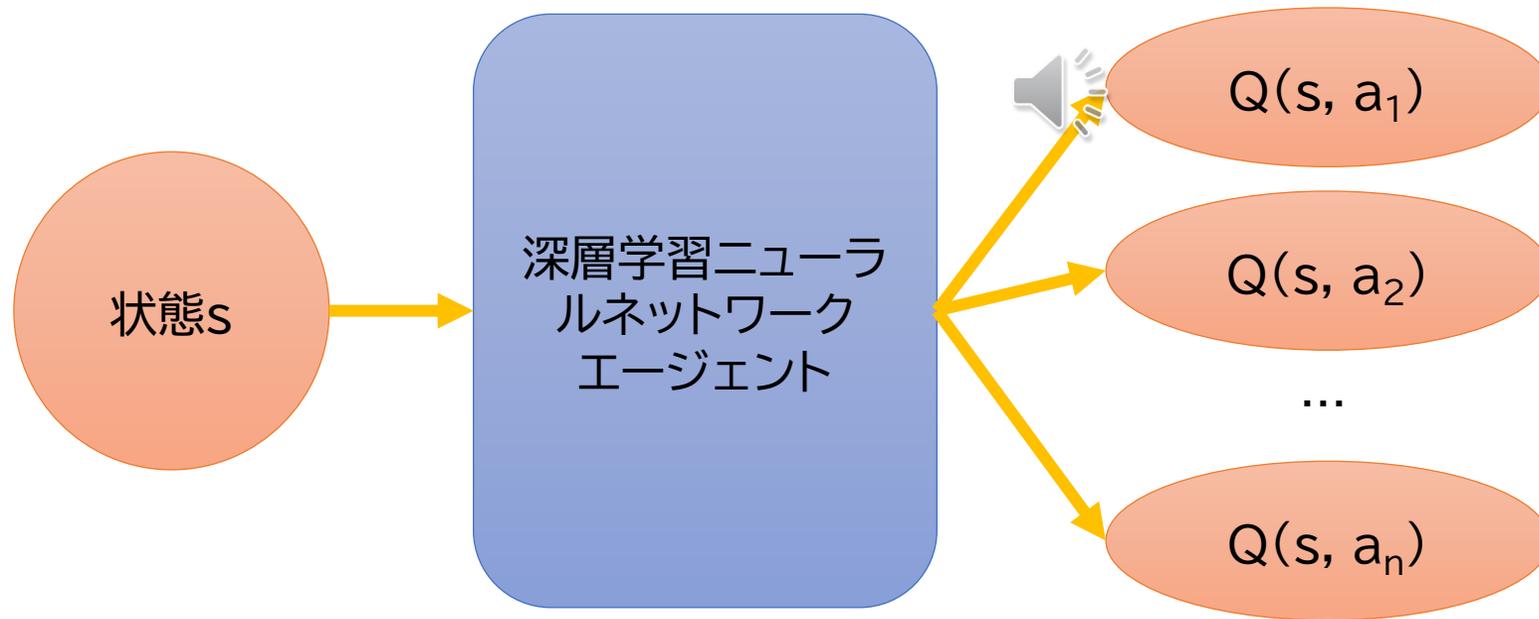


ネットワークの学習 バックプロパゲーション(逆伝播)



DQN

課題設定： 入力 (s,a) から $Q(s,a)$ の関数を得たいところ、以下のように変更する。



$$\begin{aligned} \text{最適ポリシー } \pi^*(s) \\ = \operatorname{argmax} Q(s,a) \end{aligned}$$



DQN: 価値ネットワークのトレーニング

- 以下のQロスを使い、バックプロパゲーション学習させる


$$\text{Qロス} = || \text{target} - \text{prediction} ||^2$$

$$\text{target} = r + \gamma \max Q(s_{t+1}, a_{t+1})$$

$$\text{prediction} = Q(s_t, a_t)$$

TD

- targetとpredictionで別々のQ表を持つのがDouble DQN。targetのQ表の更新を1000回に1回などと遅らせることで、トレーニングを安定させる。



離散アクション空間

- 右左への移動など、有限個のアクションからなる空間

連続アクション空間

- 右へ3.5の力で、左へ1.2の力で、などと、実数値で表現できるアクションからなる空間。



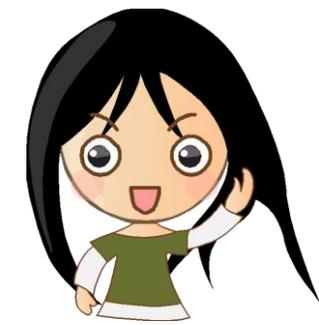
確定的ポリシー

- アクション空間が、上下左右へのどれかへの移動、といった、有限個な世界におけるポリシー

Exploit-Explore必要

確率的ポリシー

-  左へは確率0.8, 右へは確率0.05, などと、アクションを確率分布で持っておくポリシー。

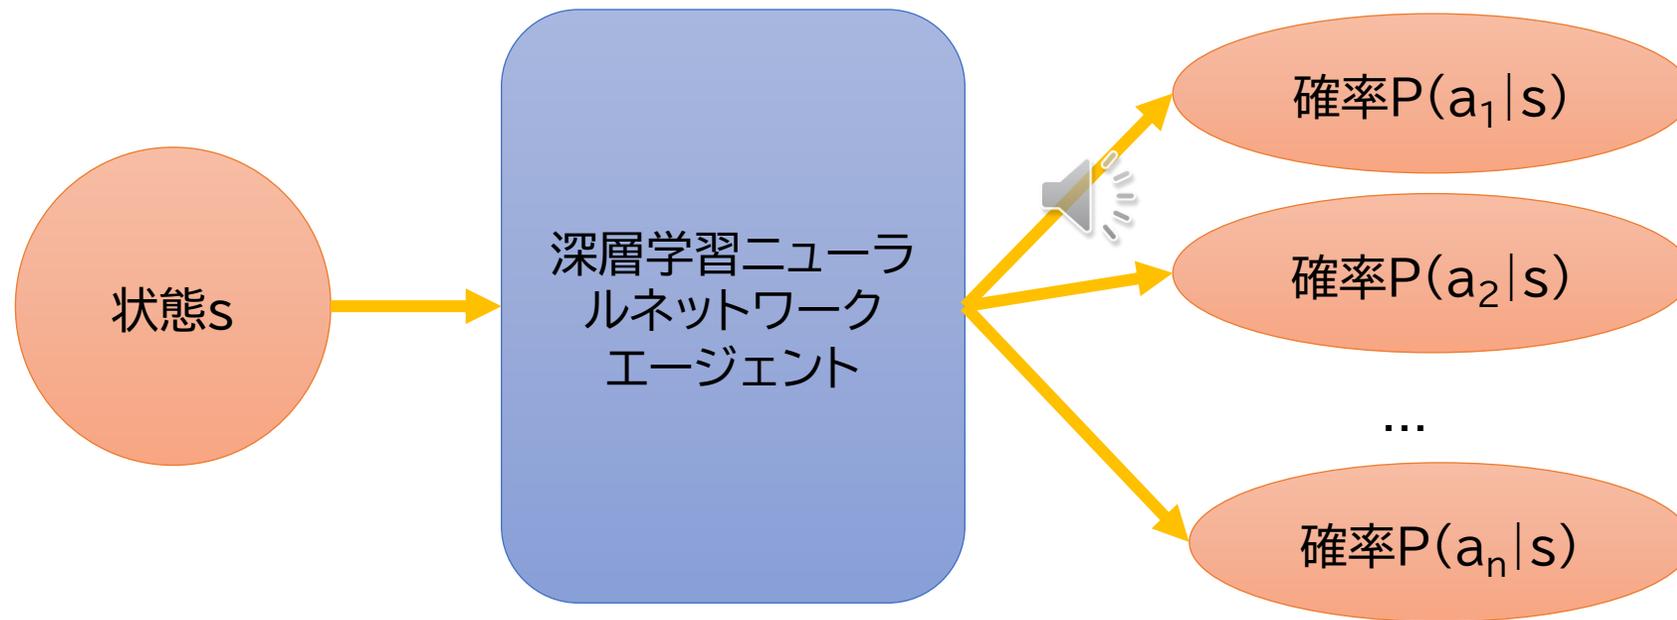


DQNの欠点

- 離散で小さなアクション空間しか対応できない。
- DQNのポリシーは、確定的なもの。



Policy Gradient (REINFORCE)



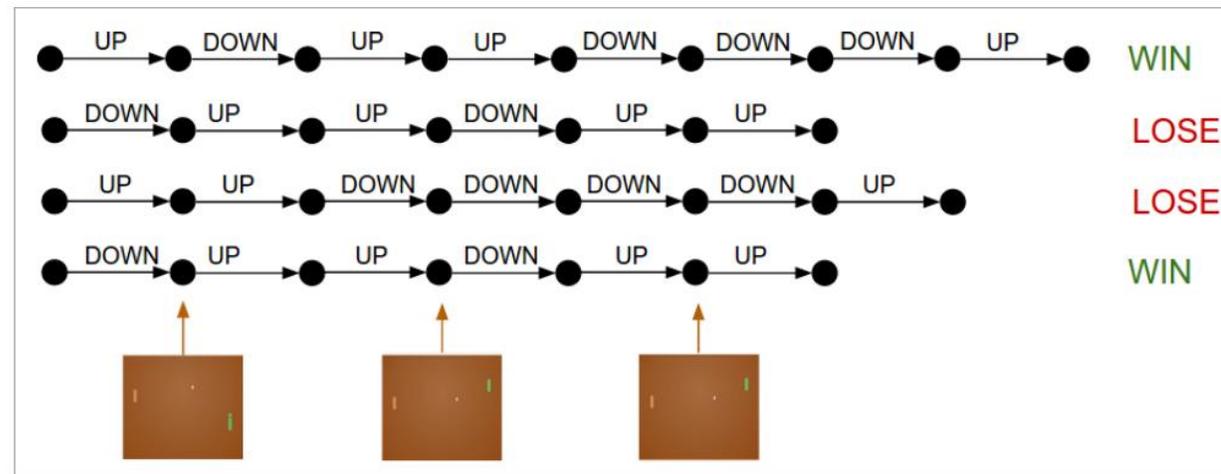
$\pi^*(s) : P(a|s)$
確率に沿ってアクションをサンプルする

$\sum P(a_i|s) = 1$ 、
アクション空間は連続値でもよく、その場合 $\int P = 1$



PG: ポリシーネットワークのトレーニング

- 初期化後、以下を繰り返す
- ポリシーを使い、終了状態まで実行する。
- 全(状態、アクション、報酬)を記録。
- ポリシー更新: 失敗したエピソードの全アクションの確率を低くし、成功したエピソードの全アクションの確率を高くする



<http://karpathy.github.io/2016/05/31/rl/>

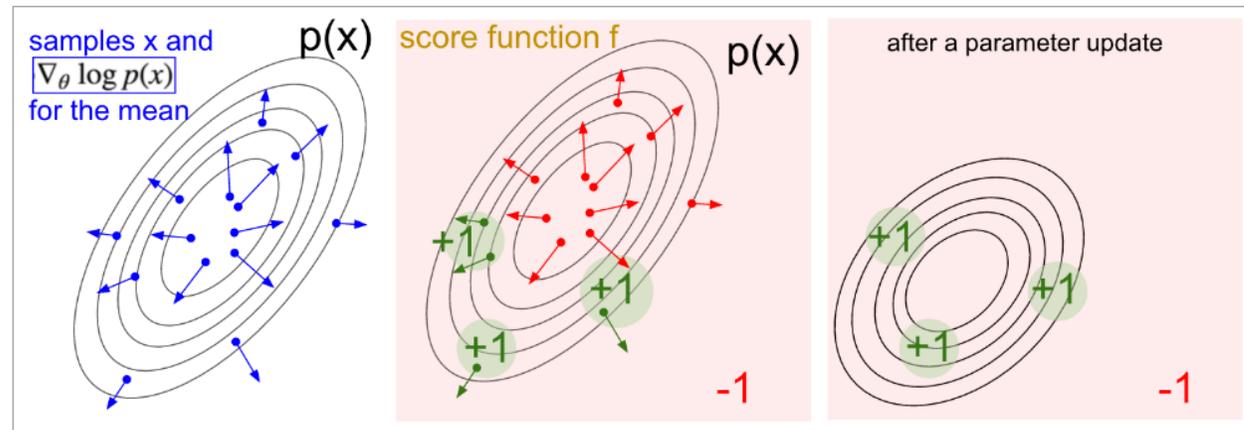


PG: ポリシーネットワークのトレーニング

- 報酬が大きいほど確率を大きくするために、ロス関数は、アクション確率の対数尤度 $\log P(a_t | s_t)$ にディスカウント総報酬 R_t をかけた以下のものとし、バックプロパゲーション学習させる。

$$\text{ロス} = - \log P(a_t | s_t) R_t$$

報酬の大きいほうへ
ポリシー(とるべきア
クションの確率分布)
が寄っていく様子

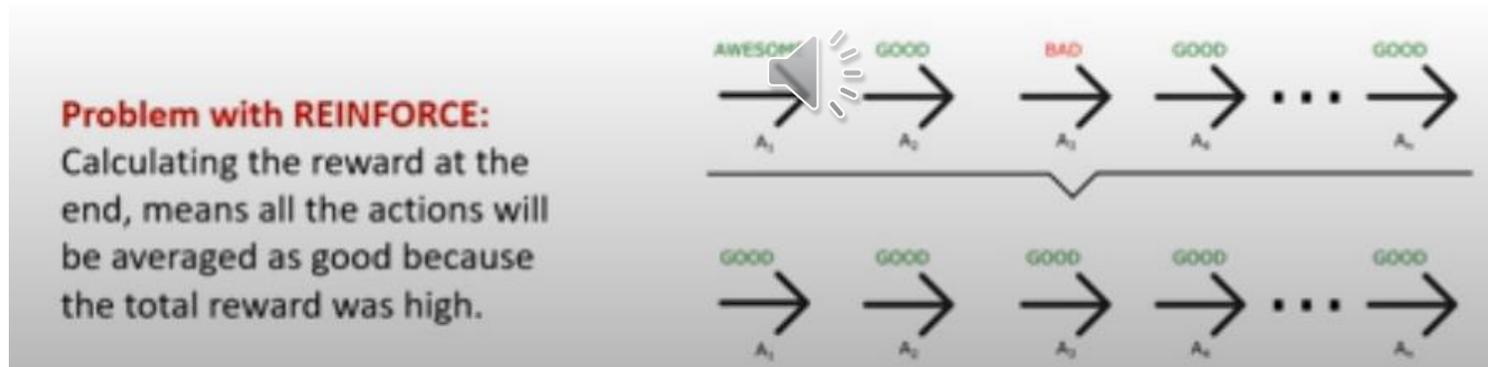


<http://karpathy.github.io/2016/05/31/rl/>



PGの欠点

- それぞれのアクションがどれくらい結果に貢献したか明確でない。



[MIT 6.S091: Introduction to Deep Reinforcement Learning \(Deep RL\)](#)



Advantage Actor-Critic (A2C)

- 二つのニューラルネットワークを持つ
- Actor: ポリシー学習 
 - $w \leftarrow w + \nabla \log P(a|s)R$ で、確率勾配に重みを与えるRの代わりに $Q(s,a)$ を使うことで、各アクションのポリシー確率に対し、最終結果にどのくらい貢献したかの個別の重みづけを与える
- Critic: Q学習



強化学習のアルゴリズムのまとめ

- 強化学習アルゴリズムは、ポリシー学習、価値学習、Actor-Criticという3つに分類されます。
- 価値学習はベルマン等式や時間的差分学習を基礎とします。
- 価値学習の代表はDQN、ポリシー学習の代表は、ポリシーグラディエントです。どちらも、ニューラルネットによる深層学習を関数近似に利用します。

<https://yo-sato.com/>
<https://satoyoshiharu.github.io/nlp/>