



ランダムタイリングを用いた多次元状態-行動の強化学習

—Gibbs-Samplingを用いた行動選択方法の提案—

木村 元

九州大学 大学院工学研究院海洋システム工学部門



ロボットの知能化

→ 強化学習：試行錯誤を通じて制御規則を獲得

学習アルゴリズムに対する要請：

1) とにかく**単純**な計算処理

- プログラムコードが短いこと
- 自然言語で簡潔に表現できるのが望ましい

} アルゴリズム中に
「微分記号」など
論外！

2) 安定した学習動作

- 問題に依存せずに実装可能であること
- パラメータ設定にセンシティブではないこと



Actor-Critic

Q-learning

ロボットの知能化

→ 強化学習：試行錯誤を通じて制御規則を獲得

学習アルゴリズムに対する要請：


1) とにかく**単純**な計算処理

- プログラムコードが短いこと
- 自然言語で簡潔に表現できるのが望ましい

} アルゴリズム中に
「微分記号」など
論外！

2) 安定した学習動作

- 問題に依存せずに実装可能であること
- パラメータ設定にセンシティブではないこと



Actor-Critic

Q-learning

ロボットの知能化

→ 強化学習：試行錯誤を通じて制御規則を獲得

学習アルゴリズムに対する要請：


1) とにかく**単純**な計算処理

- プログラムコードが短いこと
- 自然言語で簡潔に表現できるのが望ましい

} アルゴリズム中に
「微分記号」など
論外！

2) 安定した学習動作

- 問題に依存せずに実装可能であること
- パラメータ設定にセンシティブではないこと



~~Actor Critic~~

Q-learning

本研究の目的

高次元連続状態-行動空間のロボット強化学習

Q-learning

連続空間
関数近似

ボルツマ
行動選択

- ・これら基礎的な技術と知見をそのまま継承した実装
- ・数万ステップで学習させる（Actor-Criticの数倍程度以

解決すべき課題：

- 1) 状態-行動の評価値(Q値)の表現 ← 膨大な空間の汎化
- 2) 高次元連続行動空間における行動選択は？

本研究の目的

高次元連続状態-行動空間のロボット強化学習

Q-learning

連続空間
関数近似


ボルツマ
行動選択

- ・これら基礎的な技術と知見をそのまま継承した実装
- ・数万ステップで学習させる（Actor-Criticの数倍程度以

解決すべき課題：

- 1) 状態-行動の評価値(Q値)の表現 ← 膨大な空間の汎化
- 2) 高次元連続行動空間における行動選択は？

対象とする学習問題1: Rod in Maze (Moore 1995)



2次元平面中でスタート状態
からゴール領域まで棒を移動

領域中に固定障害物

棒の傾き 0~180度のみ



状態: X, Y座標と角度 θ

行動: 動作目標X,Y, θ 座標


棒が目標座標へ到達するか、
途中で障害物へぶつかると
意思決定のイベント発生

ゴールへ到達すると報酬／
再び初期状態へもどる

スタート
状態




動作例



3次元状態 × 3次元行動の強化学習問題

対象とする学習問題2: Multi-Joint Arm (Moore 1995)



2次元平面中でスタート状態から
ゴール領域までアームを移動

領域中に固定障害物


アームは冗長自由度(8関節)

状態: 関節角度 θ (8次元)

行動: 目標角度 θ (8次元)

アームが目標角度へ到達する
か、途中で障害物へぶつかると
意思決定のイベント発生


ゴールへ到達すると報酬／
再び初期状態へもどる




(1)

(2)

(3)



動作例



8次元状態 × 8次元行動の強化学習問題

Q-learning


連続空間の 関数近似

ボルツマン 行動選択

$$\hat{Q}(s_t, a_t) \leftarrow \hat{Q}(s_t, a_t) + \alpha \left[r_t + \gamma \max_{a \in A} \hat{Q}(s_{t+1}, a) - \hat{Q}(s_t, a_t) \right]$$

状態 S_t で実行した
行動の Q 値を更新

γ は割引率 ($0 \leq \gamma \leq 1$)
 α は学習率 ($0 < \alpha \leq 1$)



Q-learning

連續空間の
関数近似

ボルツマン
行動選択

Q-learningの収束定理(Watkins92)

行動選択において全行動を十分な回数選択し、かつ学習率 α が

$$\sum_{t=0}^{\infty} \alpha'(t) \rightarrow \infty \quad \text{and} \quad \sum_{t=0}^{\infty} \alpha(t)^2 < \infty$$


を満たす時間 t の関数になっているとき、アルゴリズムで得るQ値は確率1で**最適政策の評価値に概収束する。**

ただし環境はエルゴート性を有するMDP

Q-learning



連續空間の
関数近似

ボルツマン
行動選択



このような離散ではない状態空間のvalueを学習するには？


離散状態表現による近似




離散状態表現による近似の問題点

- 粗い近似:
- 価値関数の学習は早い
 - 非マルコフ性が生じる → 最適政策が得られない


- 細かい近似
- 価値関数の学習は指数関数的に遅くなる
 - 特に高次元環境において膨大なメモリーが必要



線形アーキテクチャによる汎化と関数近似



複数タイリングの重ねあわせ(CMAC)による特徴ベクトル生成




複数のタイリングを
ランダムにずらせながら
複数重ねあわせる

ずらせた時に状態空間の
定義域をカバーしない
領域ができるよう注意

各タイリングが粗くても、
多数重ねることで精度良く
近似表現できる

高次元空間では
メモリー空間が爆発

複数タイリングの重ねあわせ(CMAC)による特徴ベクトル生成





複数のタイリングを
ランダムにずらせながら
複数重ねあわせる

ずらせた時に状態空間の
定義域をカバーしない
領域ができるよう注意

各タイリングが粗くても、
多数重ねることで精度良く
近似表現できる

高次元空間では
メモリー空間が爆発


高次元行動空間の扱いの難しさ: 空間の汎化



- 行動空間の各次元毎にQ値設定して合計したら？
- 行動空間の各次元毎に行動選択したら？

依存関係のある行動を
学習できない


高次元行動空間の扱いの難しさ: 空間の汎化




- 行動空間の各次元毎にQ値設定して合計したら？
- 行動空間の各次元毎に行動選択したら？

依存関係のある行動を
学習できない

高次元行動空間の扱いの難しさ: 空間の汎化




余計な場所まで高くなってしまう




- 行動空間の各次元毎にQ値設定して合計したら？
- 行動空間の各次元毎に行動選択したら？

依存関係のある行動を
学習できない

高次元状態・行動空間の汎化： ランダムタイリングによるQ関数表現




高次元状態・行動空間の汎化： ランダムタイリングによるQ関数表現



高次元状態・行動空間の汎化: ランダムタイリングによるQ関数表現

a2



様々な大きさ・次元の超矩形タイルをランダムに配置して特徴量ベクトルを生成


各タイルが特徴量ベクトルの各要素に対応

$$(f_1, f_2, f_3, f_4, f_5, f_6, f_7, f_8, f_9)$$

実験では、各軸あたり0.3の確率で区域を設定

高次元状態・行動空間の汎化： ランダムタイリングによるQ関数表現

a2




様々な大きさ・次元の超矩形タイルをランダムに配置して特徴量ベクトルを生成

ある値が入力されたとき


$$(f_1, f_2, f_3, f_4, f_5, f_6, f_7, f_8, f_9)$$

高次元状態・行動空間の汎化： ランダムタイリングによるQ関数表現



ある状態 s , 行動 a
におけるQ値の求め方

$$Q(s, a) = \frac{1}{T_s T_a} \sum_{j=1}^{2T_a} \sum_{i=1}^{2T_s} F_i G_j W_{ij}$$




Q-learning


連続空間の 関数近似

ボルツマン 行動選択

a2



ランダムタイリングによる
高次元連続空間の汎化



特長


- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

Q-learning


連続空間の 関数近似

ボルツマン 行動選択

a2



ランダムタイリングによる
高次元連続空間の汎化



特長

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

Q-learning

連続空間の 関数近似

ボルツマン 行動選択

ある状態SにおいてQ値のボルツマン分布に従って確率的に行動aを選ぶ

行動選択確率:

$$P(a_i) = \frac{\exp\left(\frac{Q(s, a_i)}{T}\right)}{\sum_{j=1}^A \exp\left(\frac{Q(s, a_j)}{T}\right)}$$

しかし！
全行動空間の $\exp(Q)$ の合計が必要！



Q-learning

連続空間の 関数近似

ボルツマン 行動選択

ある状態 s において Q 値の ボルツマン分布 に従って
確率的に行動 a を選ぶ


行動選択確率:

$$P(a_i) = \frac{\exp\left(\frac{Q(s, a_i)}{T}\right)}{\sum_{j=1}^A \exp\left(\frac{Q(s, a_j)}{T}\right)}$$


しかし！
全行動空間の $\exp(Q)$ の合計が必要！

高次元行動空間の扱いの難しさ: 行動選択


関節1(a1)



関節2(a2)



行動空間の各次元を10分割で離散化




8関節 → 離散行動 1000万通


Q-learningにおける行動選択やQ値の更新の際に
最大のQ値を探す計算に多大な計算コストを要する
従来の計算コストは「次元の呪い」に直面

高次元行動空間の扱いの難しさ: 行動選択


関節1(a1)



関節2(a2)




行動空間の各次元を10分割で離散化



8関節 → 離散行動 1000万通り

Q-learningにおける行動選択やQ値の更新の際に
最大のQ値を探す計算に多大な計算コストを要する
従来の計算コストは「次元の呪い」に直面


高次元行動空間の扱いの難しさ: 行動選択



Q-learning

連続空間の
関数近似

ボルツマン
行動選択




$$P(a_i) = \frac{\exp\left(\frac{Q(s, a_i)}{T}\right)}{\sum_{j=1}^A \exp\left(\frac{Q(s, a_j)}{T}\right)}$$

Q-learning

連続空間の 関数近似


ボルツマン 行動選択



Q-learning

連続空間の 関数近似

ボルツマン 行動選択



Q-learning

連續空間の
関数近似

ボルツマン
行動選択

高次元空間における確率分布に従ったサンプルを
効率よく得るには？ → 統計学的な一般問題

Markov chain Monte-Carlo (MCMC) 法の一種
Gibbsサンプリング

Q-learning

連續空間の 関数近似

ボルツマン 行動選択

高次元空間における確率分布に従ったサンプルを
効率よく得るには？ → 統計学的な一般問題

Markov chain Monte-Carlo (MCMC) 法の一種
Gibbsサンプリング

$$a^1(t+1) \approx P(a^1 | a^2(t), a^3(t), \dots, a^N(t))$$

$$a^2(t+1) \approx P(a^2 | a^1(t), a^3(t), \dots, a^N(t))$$

⋮

$$a^N(t+1) \approx P(a^N | a^1(t), a^2(t), \dots, a^{N-1}(t))$$


計算が簡単な1次元
の条件付確率分布

} このような反復 t を
十分な回数繰返し、
最終的に得た $a(t)$
をサンプルとする

Q-learning

連続空間の
関数近似

ボルツマン
行動選択




先ほどのボルツマン選択を Gibbsサンプリングしてみる

Q-learning

連続空間の 関数近似

ボルツマン 行動選択




a_2 軸を固定し、 a_1 軸についてのみボルツマン選択

Q-learning

連続空間の 関数近似

ボルツマン 行動選択




a_1 軸を先に選択された値に固定し、
今度は a_2 軸についてのみボルツマン選択

Q-learning

連続空間の 関数近似

ボルツマン 行動選択




a_2 軸を先に選択された値に固定し、
再び a_1 軸についてのみボルツマン選択 これを繰返す

Q-learning

連続空間の 関数近似

ボルツマン 行動選択




Gibbsサンプリング：
全行動空間の $\exp(Q)$ の合計を
計算せずに右式に従うサンプルを得る！

Q-learning

連続空間の 関数近似

ボルツマン 行動選択



Gibbsサンプリング：
全行動空間の $\exp(Q)$ の合計を
計算せずに右式に従うサンプルを得る！

Q-learning


連続空間の 関数近似

ボルツマン 行動選択

ただし、
MaxQ を求める
計算が「近似」に

SARSAアルゴリズムなら問題ない

**Gibbsサンプリングによる
行動選択処理**



特長

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

Q-learning


連続空間の 関数近似

ボルツマン 行動選択

ただし、
MaxQ を求める
計算が「近似」に

SARSAアルゴリズムなら問題ない

Gibbsサンプリングによる 行動選択処理



特長

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

Q-learning


連続空間の 関数近似

ボルツマン 行動選択

ただし、
MaxQ を求める
計算が「近似」に

SARSAアルゴリズムなら問題ない

Gibbsサンプリングによる
行動選択処理




特長

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の回数を増やすだけ
- ・分割を細かくしても、計算はあまり変わらない

シミュレーション1： Rod in Maze

状態3次元
行動3次元



特徴ベクトルの設定

1) ランダムタイリング

3次元空間を $10 \times 10 \times 10$ の格子状とし、
タイルの境界をこの格子に合わせた
ランダムな大きさのタイルを200個生成
各次元要素をタイルに選択する確率=0.6

2) 等間隔グリッドタイリング

3次元空間を $5 \times 5 \times 5$ の等間隔グリッドで
分割し、 $5 \times 5 \times 5 = 125$ 個のタイル生成

3次元空間を $6 \times 6 \times 6$ の等間隔グリッドで
分割し、 $6 \times 6 \times 6 = 216$ 個のタイル生成

Q-learning の設定


割引率 $\gamma = 0.9$
温度 $T = 0.4$
学習率 $\alpha = 0.5$

Gibbs-Sampling の設定


反復回数: 15回 × 3次元

ランダムタイルの生成

各次元要素をタイルに選択する確率=0.6



3次元空間を $10 \times 10 \times 10$ の格子状とし、
タイルの境界をこの格子に合わせた
ランダムな大きさのタイルを生成



シミュレーション1結果： Rod in Maze


状態3次元
行動3次元

10試行の平均
ランダムタイリングはそれぞれ異なる

割引率 $\gamma = 0.9$
温 度 $T = 0.4$
学習率 $\alpha = 0.5$

ランダムタイリング
200タイル

等間隔グリッドタイリング
 $5 \times 5 \times 5 = 125$ タイル
 $6 \times 6 \times 6 = 216$ タイル



シミュレーション1結果： Rod in Maze

状態3次元
行動3次元

10試行の平均

ランダムタイリングはそれぞれ異なる

割引率 $\gamma = 0.9$
温 度 $T=0.4$
学習率 $\alpha=0.5$


ランダムタイリング
200タイル

●3次元行動空間を持つ問題に
Gibbs-Samplingテクニックを用いる
ことでQ-learningの適用を実現


●ランダムタイリングを併用しないと
学習できない

●得られた解の質はタイリング依存

等間隔グリッドタイリング
 $5 \times 5 \times 5 = 125$ タイル
 $6 \times 6 \times 6 = 216$ タイル




学習で得られた動作の一例



シミュレーション2: Multi-Joint Arm

状態8次元
行動8次元



特徴ベクトルの設定

1) ランダムタイリング

8次元空間を 10^8 の格子状とし、
タイルの境界をこの格子に合わせた
ランダムな大きさのタイルを200個生成
各次元要素をタイルに選択する確率=0.3

2) 等間隔グリッドタイリング

8次元空間を 2^8 の等間隔グリッドで
分割し、 $2^8=256$ 個のタイル生成

Q-learning の設定


割引率 $\gamma = 0.9$
温度 $T = 0.4$
学習率 $\alpha = 0.5$

Gibbs-Sampling の設定

反復回数: 40回 × 8次元


シミュレーション2結果： Multi-Joint Arm

状態8次元
行動8次元




シミュレーション2結果： Multi-Joint Arm

状態8次元
行動8次元



学習で得られた動作の一例



考察とまとめ

Q-learning

**連続空間の
関数近似**

**ボルツマン
行動選択**

ランダムタイリングによる
高次元連続空間の汎化

Gibbsサンプリング
による行動選択処理

MaxQ を求める
計算が近似に

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

高次元連続状態-行動空間の強化学習問題へ実装

考察とまとめ

Q-learning

**連続空間の
関数近似**

**ボルツマン
行動選択**

ランダムタイリングによる
高次元連続空間の汎化

Gibbsサンプリング
による行動選択処理

MaxQ を求める
計算が近似に

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

高次元連続状態-行動空間の強化学習問題へ実装

考察とまとめ

Q-learning

**連続空間の
関数近似**

**ボルツマン
行動選択**

ランダムタイリングによる
高次元連続空間の汎化

Gibbsサンプリング
による行動選択処理

MaxQ を求める
計算が近似に

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

高次元連続状態-行動空間の強化学習問題へ実装

考察とまとめ

Q-learning



**連続空間の
関数近似**

**ボルツマン
行動選択**

ランダムタイリングによる
高次元連続空間の汎化

Gibbsサンプリング
による行動選択処理

MaxQ を求める
計算が近似に




- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

高次元連続状態-行動空間の強化学習問題へ実装

考察とまとめ


Q-learning



MaxQ を求める
計算が近似に


**連続空間の
関数近似**

ランダムタイリングによる
高次元連続空間の汎化



**ボルツマン
行動選択**

Gibbsサンプリング
による行動選択処理




- ・実装が簡単
- ・空間爆発を回避
- ・足りなければタイルを
増やすだけ
- ・実装が問題に依存しない

- ・実装が簡単
- ・空間爆発を回避
- ・足りなければ計算反復の
回数を増やすだけ
- ・分割を細かくしても、計算
はあまり変わらない

高次元連続状態-行動空間の強化学習問題へ実装

おわりに



高次元連続な強化学習問題に対して、
誰でも実装できて学習させることが可能な
強化学習の基礎的実装方法を提案・実証


Gibbsサンプリング行動選択／ランダムタイリング特徴量生成

- ・学習性能はランダムタイリングの配置に依存
- ・状態空間で生成されたランダムタイルの30%が未使用



- ・タイルの適応的生成・削除へ拡張
- ・教示データを利用した効率的タイル生成


おわりに




高次元連続な強化学習問題に対して、
誰でも実装できて学習させることが可能な
強化学習の基礎的実装方法を提案・実証

Gibbsサンプリング行動選択／ランダムタイリング特徴量生成

- ・学習性能はランダムタイリングの配置に依存
- ・状態空間で生成されたランダムタイルの30%が未使用



- ・タイルの適応的生成・削除へ拡張
- ・教示データを利用した効率的タイル生成



「強化学習ロボット:スタディアス」
愛・地球博
NEDOプロトタイプロボット展

