

Q学習手法の学習における4,1,2-ゲーム使用の提案

山下 明 博

Proposal for Using 4,1,2-Games on Learning Q-learning

Akihiro YAMASHITA

安田女子大学家政学部造形デザイン学科

要 旨

Q学習は、代表的な強化学習手法の1つである。この手法を学ぶときに、従来、3,3,3-ゲームと呼ばれる三目並べが題材として選ばれることが多かった。しかし、三目並べでQ学習を理解しようとすると、棋譜データ量が膨大なことがその理解を妨げるという問題点があった。本稿は、m,n,k-ゲームを複数回実行するプログラムを開発するとともに、勝ち、負け、引き分けがすべて現れるm,n,k-ゲームの中で、最も棋譜データ量が少ないゲームを選定し、選定した4,1,2-ゲームを、Q学習手法の学習のために使用することを提案するものである。

キーワード：Q学習、強化学習、m,n,k-ゲーム、Bellman最適方程式、三目並べ

はじめに

Q学習は、代表的な強化学習方法の1つである。この手法を学ぶときに、従来、3,3,3-ゲームと呼ばれる三目並べが題材として選ばれることが多かった。しかし、三目並べでQ学習の手法を理解しようとすると、棋譜データ量やQテーブルの大きさが巨大であることにより、その理解が妨げられるという問題点があった。

本稿は、勝ち、負け、引き分けがすべて現れるm,n,k-ゲームの中で、最も棋譜データ量が少ない4,1,2-ゲームを、三目並べの代わりに、Q学習の理解のために使用することを提案するものである。

I. Q学習における三目並べ

1. 強化学習

強化学習 (Reinforcement Learning) は機械学習 (Machine Learning) 手法の一つで、システムが自ら試行錯誤しながら最適な制御を実現する手法である。強化学習の考え方自体は、すでに1950年代から存在していたが、強化学習が注目されるようになったのは、2016年、強化学習を用いたGoogle DeepMindの囲碁AI「AlphaGo」が、囲碁のトップ棋士に完勝するという成果を挙げたときからである。そして、その後も囲碁AIの研究は続き、「AlphaZero」は、過去の棋譜やビッグデータを必要とせず、自己対局によって強化学習を行い、全くの初心者の状態から、人間がまったく勝利できない水準まで8時間で到達するという成果を挙げている。

強化学習では、環境とエージェントの相互作用を考える。図1に、強化学習におけるエージェントと環境の相互作用を示す。エージェントは、環境の状態 s を見て、行動 a を実行する。環境は、エージェントの行動 a に応じて状態 s を更新し、行動の結果として報酬 r をエージェントに返す。



図1 強化学習におけるエージェントと環境の相互作用

レイヤーと同じ手を打つものである。

(3) Q学習プレイヤー (Qlearning)

Q学習プレイヤーは、ランダムプレイヤーと200万回対戦し、状態sと行動aに対応するQ値を更新する学習を繰り返すことにより、強いゲームプレイヤーとして成長させたものである。Q学習の初期には、 ϵ -greedy法でランダム性を加えて選ぶようにした。

200万回対戦し学習した後、他のプレイヤーと対戦するときは、 $\epsilon = 0$ で、最善手を選択するようにしている。

4. プログラム実行例

今回開発したm,n,k-ゲームプログラムにより、三目並べの場合、各プレイヤーをそれぞれ対戦させた場合、どのような戦績になるかについて述べる。

(1) Random、(2) LookAheadRandom、(3) Qlearningの各プレイヤーを相互に10万回ずつ対戦させた結果は以下の通りである。1が先攻、2が後攻を示す。

その結果、先攻のほうが後攻より勝利する対戦が多いこと、プレイヤーの強さではRandom < LookAheadRandom < Qlearningの順であること、Q学習同士で両プレイヤーが最善手を打ち続けた場合、すべて引き分けになることを読み取ることができた。

5. プログラムの制限

今回、m,n,k-ゲームのルールに従って対戦するプログラムを開発するにあたり、 $m \leq 4$ 、 $n \leq 4$ 、 $k \leq 4$ という条件を設定した。これは、Q学習を行

う上で、m,n,k-ゲームの中で扱う状態sの数が高々3のm*n乗通り、行動aの数がk通りであり、m、n、kが大きくなるにつれて、必要なメモリーの容量および収束までの計算量が爆発してしまい計算不可能になるからである。

本プログラムでは、afterstateを作成することにより状態sと行動aの組み合わせを集約したり、状態と行動をPythonの辞書機能で保持したりする工夫を行い、 $m \leq 4$ 、 $n \leq 4$ 、 $k \leq 4$ の範囲で動作するようにした。

Ⅲ. m,n,k-ゲームの性質の定義

m,n,k-ゲームは、2プレイヤー間で対戦するゲームであるが、両プレイヤーが最善手を打ち続けた場合、先手必勝か、後手必勝か、引き分けに分類することができる。これを、m,n,k-ゲームの性質と呼ぶことにする。

最善手を打ち続けるプレイヤーは、Q学習プレイヤー (Qlearning) で $\epsilon = 0$ を指定した場合である。そこで、m,n,k-ゲームプログラムを使用し、 $m \leq 4$ 、 $n \leq 4$ 、 $k \leq 4$ という条件の下で、Q学習プレイヤー同士で対戦を10万回ずつ行うことにより、両プレイヤーが最善手を打ち続けた場合、先手必勝か、後手必勝か、引き分けになるかというm,n,k-ゲームの性質を検討する。

ただし、mとnは交換可能であるので、検討の簡略化のために、 $m \geq n$ と仮定する。

m,n,k-ゲームにおける先手必勝、後手必勝、引き分けという性質を表1にまとめた。「先」が先手必勝、「後」が後手必勝、「引」が引き分けを示している。

k=1の場合、すべて先手必勝である。また、

100000回試行結果	Random1	:58533	Random2	:28666	引分: 12801	
100000回試行結果	Random1	:39688	LookAheadRandom2	:52015	引分: 8297	
100000回試行結果	Random1	:	0	Qlearning2	:91698 引分: 8302	
100000回試行結果	LookAheadRandom1	:81379	Random2	:11919	引分: 6702	
100000回試行結果	LookAheadRandom1	:68548	LookAheadRandom2	:27070	引分: 4382	
100000回試行結果	LookAheadRandom1	:	0	Qlearning2	:91587 引分: 8413	
100000回試行結果	Qlearning1	:99453	Random2	:	0 引分: 547	
100000回試行結果	Qlearning1	:99460	LookAheadRandom2	:	0 引分: 540	
100000回試行結果	Qlearning1	:	0	Qlearning2	:	0 引分:100000

表1 m,n,k-ゲームの性質

k=1					k=2					k=3					k=4				
m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4
1	先	先	先	先	1	-	引	先	先	1	-	-	引	引	1	-	-	-	引
2	先	先	先	先	2	引	先	先	先	2	-	-	引	引	2	-	-	-	引
3	先	先	先	先	3	先	先	先	先	3	引	引	引	先	3	-	-	-	引
4	先	先	先	先	4	先	先	先	先	4	引	引	先	先	4	引	引	引	引

k=2のときも、盤面が小さ過ぎるときを除き、先手必勝である。k=3のときは、引き分けが多くなるが、mやnがともに大きいときは先手必勝になる。k=4のときは、すべて引き分けになる。

出すことにより、m,n,k-ゲームの理解、およびQ学習の理解を深めることが、本稿の目的である。

IV. Q学習の理解のための4,1,2-ゲームの提案

1. 提案の目的

Q学習の理解に三目並べを題材として選ぶ場合、棋譜データ量が膨大になるという問題点はすでに述べた。そこで、棋譜データ量が三目並べより小さく、かつ、勝ち、負け、引き分けのパターンがすべて現れるm,n,k-ゲームが何であるかを見

2. 探索手法

棋譜データ量が小さく、かつ、勝ち、負け、引き分けのパターンがすべて現れるm,n,k-ゲームを探索する手法として、ランダムプレイヤー同士で対戦させることにする。これは、最善手を打ち続けるQ学習プレイヤーが決して打たないような、負けるかもしれない手を含めて、すべてのパターンを調べるためである。

表2に、 $m \leq 4, n \leq 4, k \leq 4$ という条件の下で、ランダムプレイヤー同士による対戦の結果を、先手勝利確率、後手勝利確率、引き分け確率

表2 ランダムプレイヤー同士による対戦結果

先攻勝利確率 (%)	k=1					k=2					k=3					k=4				
	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4
	1	100	100	100	100	1	-	0	67	50	1	-	-	0	0	1	-	-	-	0
	2	100	100	100	100	2	0	67	78	75	2	-	-	10	23	2	-	-	-	3
	3	100	100	100	100	3	67	78	71	68	3	0	10	59	59	3	-	-	-	8
	4	100	100	100	100	4	50	75	68	66	4	0	23	59	59	4	0	3	8	31
後攻勝利確率 (%)	k=1					k=2					k=3					k=4				
	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4
	1	0	0	0	0	1	-	0	0	17	1	-	-	0	0	1	-	-	-	0
	2	0	0	0	0	2	0	0	22	24	2	-	-	0	14	2	-	-	-	0
	3	0	0	0	0	3	0	22	29	31	3	0	0	29	38	3	-	-	-	6
	4	0	0	0	0	4	17	24	31	33	4	0	14	38	41	4	0	0	6	27
引き分け確率 (%)	k=1					k=2					k=3					k=4				
	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4	m \ n	1	2	3	4
	1	100	100	100	100	1	-	100	33	33	1	-	-	100	100	1	-	-	-	100
	2	100	100	100	100	2	100	33	0	0	2	-	-	90	63	2	-	-	-	97
	3	100	100	100	100	3	33	0	0	0	3	100	90	13	3	3	-	-	-	86
	4	100	100	100	100	4	33	0	0	0	4	100	63	3	0	4	100	97	86	41

に分けて示す。

先手勝利確率、後手勝利確率、引き分け確率のすべてに対し、確率が0%か100%以外である(m,n,k)の組み合わせは、

(m,n,k)=(4,1,2), (1,4,2), (3,3,3), (4,3,3), (3,4,3), (4,3,4), (3,4,4), (4,4,4) の8通りである。

そして、これらの組み合わせの中で、m×nが最も小さいのは、(m,n,k) = (4,1,2), (1,4,2) の2通りである。これらは、縦と横を交換すれば、同じm,n,k-ゲームであるので、棋譜データ量が三目並べより小さく、かつ、勝ち、負け、引き分けのパターンがすべて現れるm,n,k-ゲームは、4,1,2-ゲームとなる。

4,1,2-ゲームは、4×1の盤面をもち、各マス目ごとに、「○」、「×」、「」 という3つの状態を取ることができ、3つの行動を取ることがある。したがって、取りうる状態と行動の数は、3の4乗に3をかけて243である。しかし、4,1,2-ゲームが、異なるプレイヤーが交互に手を打つゲームであるため、すべて「○」といった、存在しえないパターンもある。実際には、前掲の図3に示した通り、4,1,2-ゲームのすべての棋譜は、24通りで

ある。

4,1,2-ゲームの場合、棋譜の数が少ないので書き出すことが可能であるが、3,3,3-ゲーム(三目並べ)の場合、取りうる棋譜の数が、3の9乗に3をかけた59049になる。これは、とても書き出すことができないほど膨大なデータである。

また、4,1,2-ゲームの場合、Q値の総数も少ないので書き出すことが可能である。図4に、4,1,2-ゲームの200万回Q学習実施後のQ値を示す。盤面に置かれたパターンは、[a,b,c,d] (0 ≤ a ≤ 2, 0 ≤ b ≤ 2, 0 ≤ c ≤ 2, 0 ≤ d ≤ 2) で表し、その下の数値は、盤面の状態でのQ値を示している。なお、次に打つのは必ず○側(数値では1)になるように、先攻、後攻が入れ替わるとき、盤面の1と2を交換している。

結 論

本稿では、Q学習によるm,n,k-ゲームの性質を調べたり、棋譜データ量が小さく、かつ、勝ち、負け、引き分けのパターンがすべて現れるm,n,k-ゲームを探索するために、m,n,k-ゲームプログラ

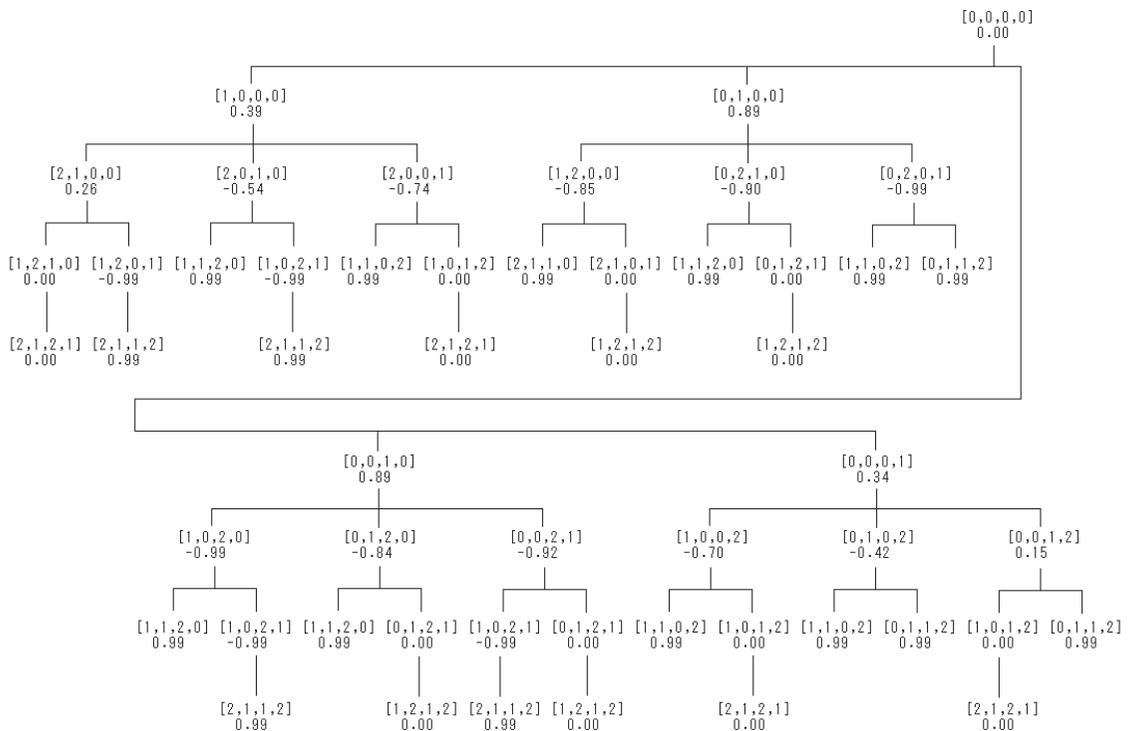


図4 4,1,2-ゲームの200万回Q学習実施後のQ値

ムを開発した。人間プレイヤー、ランダムプレイヤー、先読みランダムプレイヤー、Q学習プレイヤーを用意し、プレイヤーを組み合わせて複数回対戦させることができるため、m,n,k-ゲームを比較するのに大変役立った。

課題としては、Q学習の抱える問題でもあるが、盤面を構成するmとnを大きくすると、必要なメモリーの容量および収束までの計算量が爆発してしまい計算不可能になることが挙げられる。これについては、Q関数をニューラルネットワークで実装することで解決することができる。将来、DQNプレイヤーを実装することによって回避したいと考える。

また、Q学習の理解に使われることが多い三目並べの代わりに、棋譜データ量が三目並べより小さく、かつ、勝ち、負け、引き分けのパターンがすべて現れる4,1,2-ゲームを使うことを提案し、図3ですべての棋譜を、図7で200万回Q学習実施後のQ値を示した。これは、4,1,2-ゲームが単純であるから可能なことであり、三目並べでは大変困難な作業になる。Q学習を理解しようとする人の指針となれば幸いである。

[2021. 9. 16 受理]

コントリビューター：染岡 慎一 教授
(造形デザイン学科)

注

1. Watkins, C.J.C.H.(1989), Learning from Delayed Rewards, PhD thesis, Cambridge University, Cambridge, England.
2. ϵ -greedy法は、強化学習において最適なアクションを効率よく学習するための手法であり、学習初期は学習結果(Q値)に基づいた行動を行わず、できるだけランダムに行動を行い行動に対する結果を広く確認し、学習が進むと、次第に学習結果に基づいた行動を行う手法のことである。
3. 1899年、黒岩涙香が、禁手のない初期ルールの五目並べの必勝法を発表している。
4. 二人零和有限確定完全情報ゲームは、ゲーム理論によるゲームの分類の1つであり、
 - ・二人：プレイヤーの数が二人
 - ・零和：プレイヤー間の利害が完全に対立し、一方のプレイヤーが利益を得ると、他方のプレイヤーがそれと同量の損失を受ける
 - ・有限：ゲームが必ず有限の手番で終了する
 - ・確定：ランダムな要素が存在しない
 - ・完全情報：全ての情報が両方のプレイヤーに公開されている
 という特徴を満たすゲームのことである。岡田章(1996),「ゲーム理論」, 東京:有斐閣参照。

