

令和二年度 卒業研究論文

題目 特化型 AI の適応的選択による汎用 AI の
実現に向けた汎用度に関する研究

指導教員 服部 峻

提出者 室蘭工業大学 情報電子工学系学科

氏名 黒野 真澄

学籍番号 17024054

提出年月日 令和 3 年 2 月 12 日

目次

第 1 章	まえがき	1
1.1	人工知能の目標	1
1.2	汎用的な人工知能	1
1.3	汎用性について	2
第 2 章	関連研究	3
第 3 章	提案手法	5
3.1	選択型汎用人工知能の提案	5
3.2	汎用度の提案	6
3.2.1	汎用度の定義式 1	7
3.2.2	汎用度の定義式 2	7
3.2.3	汎用度の定義式 3	8
第 4 章	評価実験	9
4.1	実行環境	9
4.1.1	マルバツゲーム	9
4.1.2	タイルゲーム	10
4.2	各ゲーム AI の学習	11
4.2.1	マルバツゲーム AI	11
4.2.2	タイルゲーム AI	11
4.2.3	選択型汎用人工知能	11
4.3	各ゲーム AI の結果と考察	12
4.3.1	選択型汎用人工知能のターン数による選択の割合	12
4.3.2	各ゲーム AI の評価	13
4.4	ゲーム AI の汎用度の評価	14
4.4.1	アンケートによるゲーム AI の汎用性の評価	14
4.4.2	汎用度によるゲーム AI の汎用性の評価	15
第 5 章	選択型汎用人工知能の精度向上と比較対象の追加	16

5.1	選択型汎用人工知能の改善	16
5.2	選択型汎用人工知能 v2.0 の結果	17
5.3	混合人工知能	19
5.4	混合人工知能の結果	19
5.5	汎用度の評価	20
5.5.1	アンケートによる汎用性の評価	20
5.5.2	汎用度による汎用性の評価	20
5.5.3	汎用度の有用性	23
第 6 章	まとめと今後の研究課題	26
6.1	まとめ	26
6.2	社会的貢献と技術的貢献	26
6.3	今後の研究課題	26
6.4	関連研究から考える選択型汎用人工知能の評価	27
謝辞		28
参考文献		29

目次

2.1	AGI の環境, タスクおよびエージェントの特性 (出典: 文献 [2])	4
3.1	選択型汎用人工知能の概要	5
3.2	適応出来たタスクの種類例	6
4.1	マルバツゲームの流れ	9
4.2	タイルゲームの流れ	10
4.3	切り違えたタイルが消える様子	11
4.4	マルバツゲームにおける特化型 AI の選択	12
4.5	タイルゲームにおける特化型 AI の選択	13
4.6	ゲーム AI の汎用性に関するアンケート結果 (N=15)	14
5.1	選択型 AGIv2.0 によるマルバツゲームにおける特化型 AI の選択	18
5.2	選択型 AGIv2.0 によるタイルゲームにおける特化型 AI の選択	18
5.3	新しい AGI を含めた汎用性に関するアンケート結果 (N=13)	21
5.4	定義式 (1) とアンケート結果の平均得点の順位の散布図	23
5.5	定義式 (2) とアンケート結果の平均得点の順位の散布図	24
5.6	定義式 (1) とアンケート結果の平均得点の散布図	24
5.7	定義式 (2) とアンケート結果の平均得点の散布図	25

表目次

3.1	汎用度の式のパラメータ	6
4.1	各ゲームにおける各ゲーム AI の対戦結果 (勝ち数)	13
4.2	ゲーム AI の汎用性に関するアンケートの集計結果と順位ごとの得点	14
4.3	ゲーム AI の平均得点の差の p 値	15
4.4	各ゲーム AI の汎用度	15
5.1	選択型汎用人工知能 v2.0 の対戦結果 (勝ち数)	17
5.2	各ゲームにおける混合人工知能の対戦結果 (勝ち数)	19
5.3	各ゲームの人工知能の対戦結果 (勝ち数)	20
5.4	図 5.3 の集計結果と順位ごとの得点	21
5.5	各ゲーム AI の汎用性の 10 段階アンケート評価 (N=13)	22
5.6	新しい AGI を加えた各ゲーム AI の汎用度	22

第 1 章

まえがき

1.1 人工知能の目標

複雑な計算を行うことが出来るコンピュータが開発されたことで、人間の知能をコンピュータで再現する試みが行われてきた。イギリスの数学者であるアラン・チューリングは機械が思考を持つことを確認するため、ある機械が人間的であるかを判定するテストとして、チューリングテスト [1] を提唱した。チューリングテストとは、審査員が人間とコンピュータを判別し、間違えたら、そのコンピュータは人間のような振る舞いを出来たと判断するテストである。このテストの合格の基準は審査員の 30% 以上が「人間である」と判断することであるが、2014 年に行われたチューリングテストでは、ウクライナ在住の 13 才の少年という設定の「Eugene Goostman」というプログラムが 30% 以上の審査員を騙し、チューリングテストに合格した。しかし、ウクライナ在住の少年という設定なので、審査員がネイティブな英語が使えず、質問に制限があったこと、そして、5 分程度の質疑ならプログラムが審査員を騙すことが出来ることから、この合格には疑念が残った。これらのことを含め、対話が出来ただけでは、人間並みの知能があるとは言えないことや、話題を限定しない会話は不自然であることから、チューリングテストでは人に近い振る舞いが出来るかを判定するテストとしては不十分であると言える。人工知能の目的が「機械による人間並みの知能の再現」であるとしたら、「知能とは何か」が問題になる。チューリングテストは、「知能とは何か」という問いに対し、一定の定義を与えることによって、これまでの人工知能の研究の具体的な目標となってきた。チューリングテストが合格されたことによって、さらに人間に近い知能に近づくための新しい定義が必要である。

1.2 汎用的な人工知能

近年の人工知能の研究では、DeepLearning の登場により、人工知能が限定的な範囲では人間の知能に勝る結果を残すまでに至った。しかしそれは、あくまで限定的な範囲の話であり、人間の知能のような汎用的な思考を実現出来たわけではない。人間の知能を再現するには汎用的な知能を兼ね備えた人工知能を研究する必要がある。そこで、汎用人工知能の実現に向け

て、複数の課題に対して、特化型人工知能を適応的に選択して処理することによって、汎用性を付与した人工知能の研究を行う。また、汎用人工知能の評価を行うために、人工知能が持つ汎用性の尺度として、本研究では3種類の汎用度を定義する。そして、汎用性を付与した選択型汎用人工知能の汎用性を、定義した汎用度を用いて測り、加えて、汎用度自体の評価も行う。

1.3 汎用性について

「汎用性」とは何か。一般に「汎用」とは、「一つのことを広く諸種の方面に用いること（広辞苑）」である。であるならば、汎用人工知能における汎用性を考えるため、「一つのもの」を「あるプログラム」に置き換えたら、「あるプログラム」を「広く諸種の方面に用いる」ことが出来れば、「あるプログラム」は「汎用」なものであると言える。つまり、「汎用性」とは、「広く諸種の方面に用いる」ことが出来る性質のことである。このとき、どれほど広ければ「広く」、何種あれば「諸種」であるかが、問題である。これらの定義は人によって認識に違いがあるため、「あるもの」が「汎用性」を持つことの定義は人によって異なることがある。

第 2 章

関連研究

人間レベルの汎用人工知能の実現に向けた展望 [2] では、人間レベルの汎用人工知能 (Artificial General Intelligence) の実現に向け、現実的な目標および特性と必要条件に関して基本的な定義を行い、汎用人工知能の備えるべき能力の起点となる展望を示している。汎用人工知能の研究の目標は人間が備える広範な汎用知能を、システムとして開発し、実証することである。しかし、人工知能の研究の多くの努力が「弱い AI」のシステムに注がれており、それらのシステムは特定のタスクでは人間以上の能力を示せても、その能力を他のタスクや問題領域に汎化させることは出来なかった。汎用人工知能の実現のためには複数の研究グループ間の協力、協調が必要不可欠である。そのため、共通の目標やその展望への理解が必要である。

他の研究者による再現や異なるアプローチ、実装との比較、検討を容易にするため、AGI システムの能力を評価するには、知的エージェントが活動する文脈となる環境と、そこで与えられるタスクの特性を明確化する必要がある。図 2.1 で示した特性は、「弱い AI」を排除するように一定のダイナミズムと複雑性を項目として加えられている。

- C1：環境は複雑であり，多様で相互に作用しあう複雑な構造をもつオブジェクトで構成される。
- C2：環境は動的かつ開放的である。
- C3：タスクに関連する規則性が時間のスケールごとに存在する。
- C4：他のエージェントの行動が自身の行動に影響を及ぼす。
- C5：タスクは複雑，多様，かつエージェントが事前知識としてもっていない新規なものであり得る。
- C6：エージェントと環境，タスクとの相互作用は，複雑であるが有限である。
- C7：エージェントの計算リソースは有限である。
- C8：エージェントは長期間・連続的に存在する。

図 2.1 AGI の環境，タスクおよびエージェントの特性（出典：文献 [2]）

第3章

提案手法

本研究では，特化型人工知能を適応的に選択することによって汎用性を付与した人工知能，選択型汎用人工知能を提案する．また，汎用人工知能の評価を行うための，指標としての汎用度の定義について提案を行う．

3.1 選択型汎用人工知能の提案

ある複数のタスクを内包した環境に適応した人工知能を造るため，タスクを複数用意し，各タスクに特化した人工知能を造る．それぞれのタスクに特化した人工知能では，全てのタスクには適応できない．そこで，任意のタスクにおいて，そのタスクに対応した特化型人工知能を選択することにより全てのタスクに適応する人工知能を造る．要は選択することに特化した人工知能によって，全てのタスクに適応する人工知能を造ると言うことである．図 3.1 のように，選択特化人工知能は，任意のタスクにおけるそれぞれのタスクの特化型人工知能の評価値から，一番評価値の高い特化型人工知能を選択し，タスクに適応する．あるタスクのときの特化型人工知能の評価値を学習する．

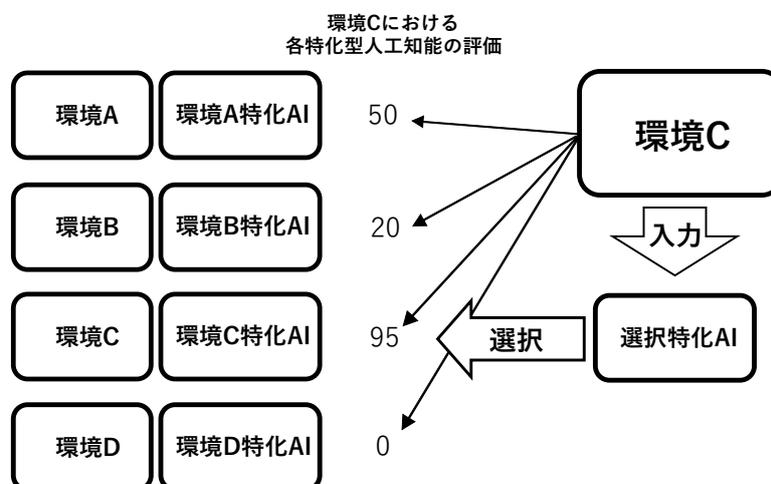


図 3.1 選択型汎用人工知能の概要

3.2 汎用度の提案

汎用人工知能の研究において、成果物の評価を行う際、評価方法を統一する必要がある。しかし、先述した通り、「汎用性」の定義は人の「広く」、「諸種」の認識によって変わるため、汎用性の評価を行う際、統一化することは難しい。そこで、「汎用性」の度合いとして、「汎用度 (iDoG: intelligence's Degree of General purpose)」を定義し、式として表すことによって、汎用人工知能の評価の統一化を目指す。

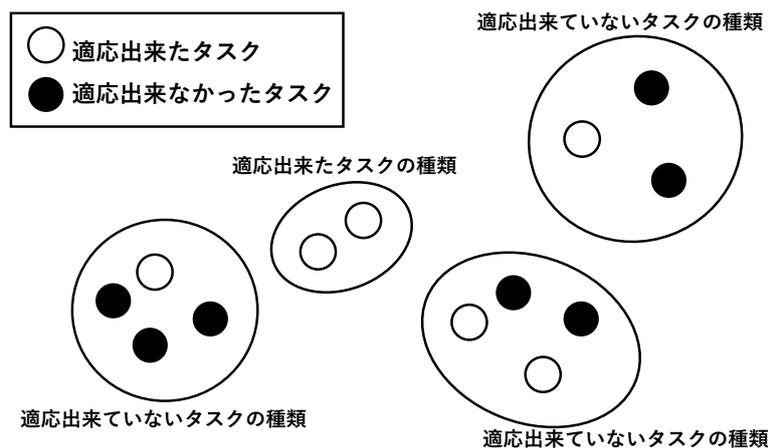


図 3.2 適応出来たタスクの種類例

図 3.2 のように、汎用度を測る対象がある種類のタスクの全てに対して適応している場合、そのタスクの種類は「適応出来たタスクの種類」とする。

汎用度の式のパラメータとして考えられるものを表 3.1 にまとめる。タスクの数を n 、適応出来たタスクの種類を m 、各タスクの難しさを d_1, d_2, \dots, d_n 、各タスクにおける評価値を E_1, E_2, \dots, E_n とする。

表 3.1 汎用度の式のパラメータ

	タスクの数	n
環境の大きさ	適応出来たタスクの種類	m
	各タスクの難しさ	d_1, d_2, \dots, d_n
各タスクにおける評価値		E_1, E_2, \dots, E_n

ある環境は複数のタスクから構成されているとする。汎用度は主に 2 つのパラメータから構成される。それは、「各タスクにおける評価値」と「環境の大きさ」である。さらに、「環境の大きさ」を決めるパラメータとして「タスクの数」、「適応出来たタスクの種類」、「各タスクの難易度」などがある。

「各タスクにおける評価値」は汎用度を測る対象が各タスクにおいてどれだけ適応出来てい

るかの値である。汎用度を測る対象が実際にタスクに適応出来たかを測るために各タスクの評価値は必要であり、各評価値が高い方が汎用度が高くなる。また、異なる評価値のタスクを比べることがあるため、各タスクの評価値を正規化して、比較出来るようにする。正規化する際の最大値はそのタスクで理論的に取ることが出来る最高の値とする。

「環境の大きさ」とは、汎用度を測る対象が適応出来る可能性のある範囲のことである。汎用度を測る対象が適応出来る範囲は汎用度を測るパラメータとして重要であるため、「環境の大きさ」は汎用度に必要なパラメータである。適応出来る範囲が広い方が汎用度が高くなる可能性があるため、汎用度を高くする上で「環境の大きさ」は重要なパラメータである。

環境の大きさを測る上で、「タスクの数」は直接的に環境の大きさに関係する。「タスクの数」が増えれば、環境は大きくなる。

「汎用性」の定義から、「諸種のタスク」に適応出来なければ、「汎用性」を持っているとは言えないため、「環境の大きさ」を測る際、「適応出来たタスクの種類」が必要になる。

複雑なタスクはその内に小さいタスクを複数包括している。そのため、複雑で難しいタスクは、適応出来たとき、簡単なタスクよりも「汎用的」と言える。よって、「タスクの難しさ」は「環境の大きさ」のパラメータとして妥当である。

以上のことを踏まえて「汎用度」の式を3種類、構築する。

3.2.1 汎用度の定義式 1

ある人工知能 a_i の汎用性を測る汎用度 $iDoG(a_i)$ の定義式を考える。汎用度を測る際、用意された環境に対してどれだけ適応出来たかで測る。ある人工知能 a_i がある種類のタスクにおいて、その種類の中のタスクの評価値の平均が7割以上のとき、その人工知能 a_i はその種類のタスクに適応したとする。ベーシックな汎用度 $iDoG^1(a_i)$ の定義式 (1) は、ある人工知能 a_i による各タスク j の評価値 $E_j(a_i)$ とその難しさ d_j を掛け合わせたものの総和に、その人工知能 a_i が適応したタスクの種類の数 $m(a_i)$ を掛け合わせたものになっている。

$$iDoG^1(a_i) = m(a_i) \sum_{j=1}^n d_j E_j(a_i) \quad (1)$$

3.2.2 汎用度の定義式 2

定義式 (1) のように、単にタスクの評価値を足し合わせただけでは、タスクの評価値が極端に偏っていても、汎用度として高く評価される可能性がある。そこで、タスクの評価値が均一に近い（分散が小さい）方が、評価されるよう定義式に改良する。ある人工知能 a_i によるタスクの評価値の平均を $\bar{E}(a_i)$ とする。汎用度 $iDoG^2(a_i)$ の定義式 (2) は、定義式 (1) に加え、各タスク j の評価値 $E_j(a_i)$ がタスクの評価値の平均 $\bar{E}(a_i)$ とかけ離れている程、汎用度を下げようとする。

$$iDoG^2(a_i) = m(a_i) \sum_{j=1}^n d_j (E_j(a_i) - |E_j(a_i) - \bar{E}(a_i)|) \quad (2)$$

3.2.3 汎用度の定義式 3

最後に、「タスクの種類」を同種のタスクは「環境の大きさ」に与える影響が少ないことに注目するならば、「タスクの種類」の数え方を変える必要がある。そこで、同種のタスク群をクラスターでまとめることによって、「タスクの種類」の影響を考えた「汎用度」の定義式を構築する。クラスター数を c 、各クラスターの大きさを C_1, C_2, \dots, C_c 、各クラスターに含まれるタスクの評価値を

$$\begin{array}{ccccccc}
 \text{クラスター 1} & E_{11}(a_i) & E_{12}(a_i) & \dots & E_{1C_1}(a_i) \\
 \text{クラスター 2} & E_{21}(a_i) & E_{22}(a_i) & \dots & E_{2C_2}(a_i) \\
 \vdots & \vdots & \vdots & \ddots & \vdots \\
 \text{クラスター } c & E_{c1}(a_i) & E_{c2}(a_i) & \dots & E_{cC_c}(a_i)
 \end{array}$$

とすると、汎用度の定義式 (3) は

$$\text{iDoG}^3(a_i) = \sum_{j=1}^c \frac{\sum_{k=1}^{C_j} d_{jk} E_{jk}(a_i)}{C_j} \quad (3)$$

となる。

第 4 章

評価実験

特化型人工知能を適応的に選択することによって汎用性を付与した選択型汎用人工知能と汎用度の評価を行う。

4.1 実行環境

特化型人工知能を動かすための環境として、「機械学習が簡単」かつ「学習に入れる入力と同じゲームが複数あるゲーム」を条件にマルバツゲーム [3] とタイルゲーム [4] の 2 つのゲームを用意した。ゲームの説明は以下の通りである。

4.1.1 マルバツゲーム

別名三目並べとも呼ばれ、2 人で行うゲームである。図 4.1 のように、3x3 の盤に交互にマル、バツを空いているところに置いていき、先に縦か横か斜めに 3 つ並べた方が勝ち、どちらも 3 つそろえられなかった場合、引き分けとなるゲームである。

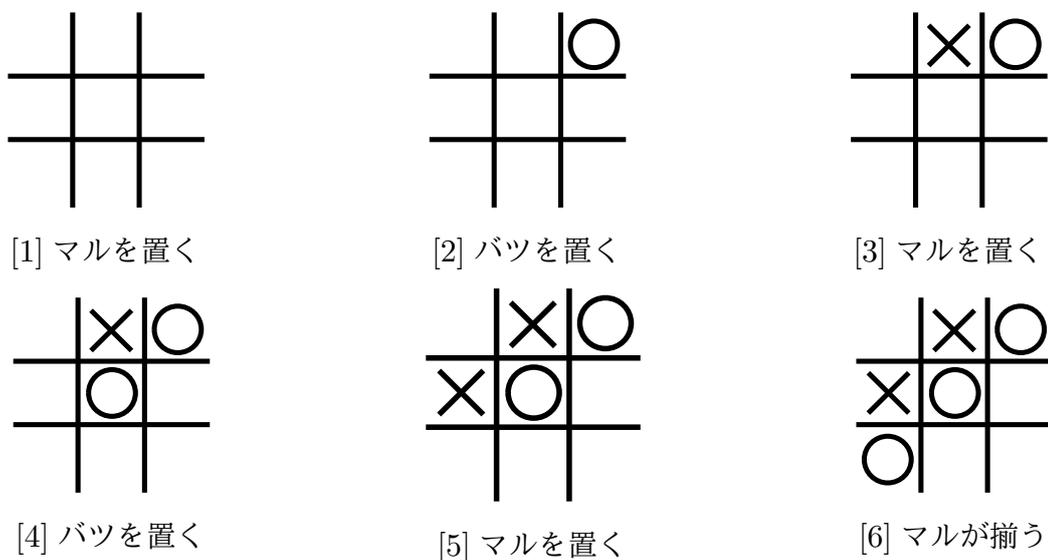


図 4.1 マルバツゲームの流れ

4.1.2 タイルゲーム

3x3の盤で2人で行うゲームである。図4.2のように、盤面の空いたところに交互にマル、バツ（タイル）を置いていき、向かい合った自分の辺と辺を先に繋げた方が勝ちとなる。「繋げる」とは、タイルの縦、横を接した状態にすることである。従って、斜めに並んでいても、繋がった状態ではない。また、図4.3のように、斜めに並んだ相手のタイルを切るように自分のタイルを置くと、相手のタイルを取り除くことが出来る。置くと自分の不利になるようなところしか無い場合でも、自分の手番をパスすることは出来ない。

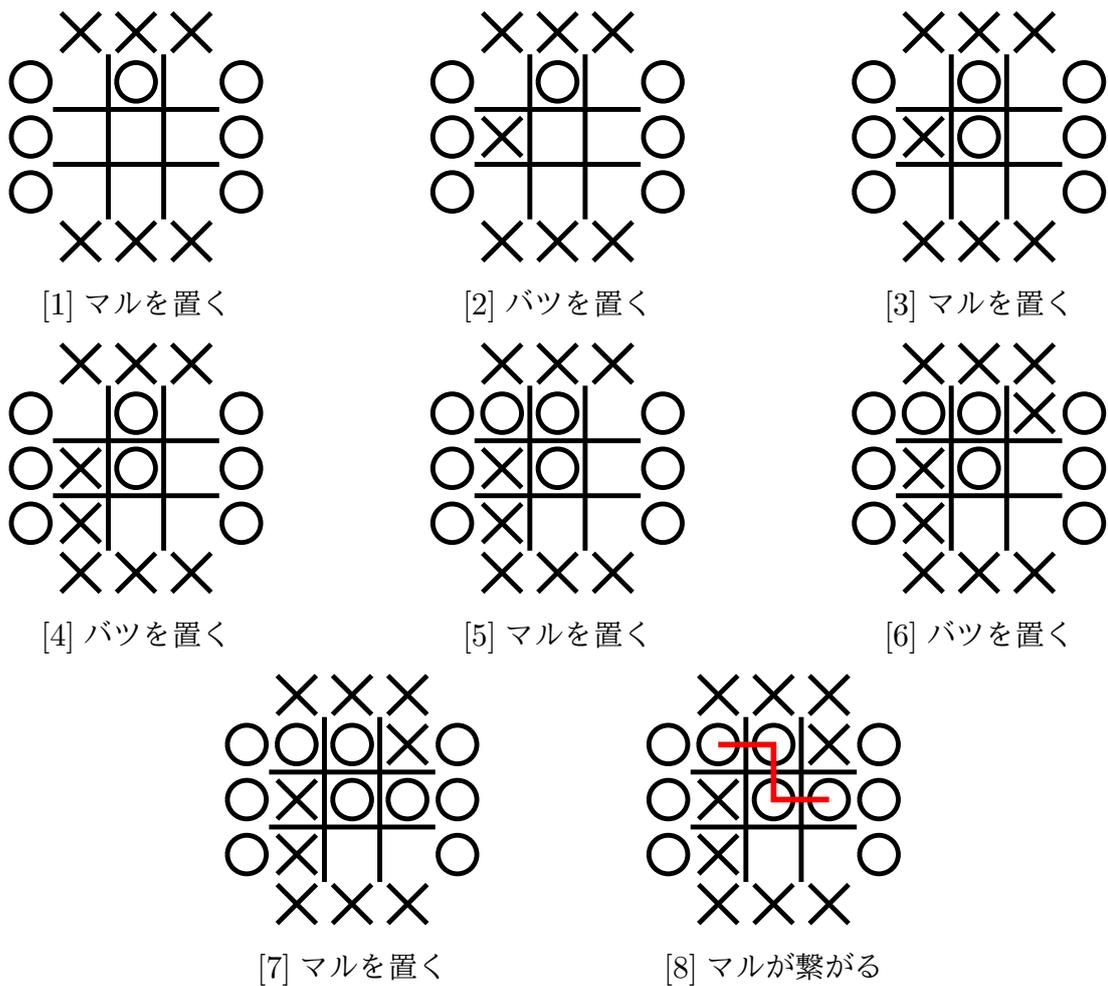
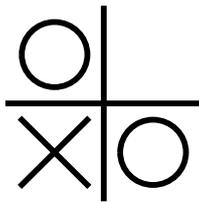
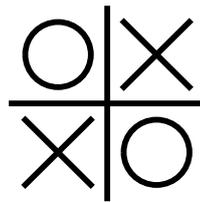


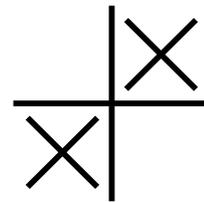
図 4.2 タイルゲームの流れ



[1] 右上にバツを置く



[2] 切り違えた状態



[3] マルが取り除かれる

図 4.3 切り違えたタイルが消える様子

4.2 各ゲーム AI の学習

Deep Q Network[5] (以下, DQN) を用いて, 2 種類のゲームの学習をそれぞれ行う. Python で chainerRL のライブラリを用いて DQN を実装する. DQN とは, DeepLearning を用いて行動価値関数 Q を求めるアルゴリズムである. DeepLearning のネットワーク構成は, 「中間層 2 層」「レイヤー数 81」「活性化関数 leaky_relu」で行う.

4.2.1 マルバツゲーム AI

DQN を用いてマルバツゲームを学習した. DQN 同士で対戦を行い, 徐々に学習していく. 既にマル, バツが置かれているマスに置こうとした場合をミスとし, ミスをするか, どちらかが勝つまでか, 引き分けになるかを 1 試合として, 20,000 試合学習した. 勝った場合はプラスの報酬を得て, 引き分けの場合は報酬を得ず, それ以外の場合はマイナスの報酬を得る.

4.2.2 タイルゲーム AI

DQN を用いてタイルゲームを学習した. DQN 同士で対戦を行い, 徐々に学習する. マルバツゲーム同様, 既に置かれているところに置こうとするとミスになる. マルバツゲームとは違い, 引き分けがないので, ミスをするか, どちらかが勝つまでを 1 試合として, 20,000 試合学習した. 勝った場合はプラスの報酬を得て, それ以外の場合はマイナスの報酬を得る.

4.2.3 選択型汎用人工知能

DQN を用いて学習を行った. マルバツゲームでは学習済みのマルバツゲーム AI が, タイルゲームでは学習済みのタイルゲーム AI が対戦相手となる. マルバツゲームとタイルゲームをランダムで与えて, 任意の盤面において, どちらのゲーム AI を使った方が良いかを学習させる. マルバツゲームとタイルゲームを合わせて 20,000 試合になるよう学習させた. 報酬の与え方はマルバツゲームと同じである.

4.3 各ゲーム AI の結果と考察

4.3.1 選択型汎用人工知能のターン数による選択の割合

選択型汎用人工知能の学習後，マルバツゲーム，タイルゲームで空いているマスにランダムに置くコンピュータと 1,000 回対戦させた．ゲーム開始からのターン数ごとに，マルバツゲーム AI，タイルゲーム AI を選んだ回数の平均を取る．マルバツゲームでは図 4.4 のように，タイルゲームでは図 4.5 のようになった．

選択型汎用人工知能は 1 ターン目はマルバツゲームでも，タイルゲームでも，必ずタイルゲーム AI を選ぶことが分かった．1 ターン目では判断材料が少なく，選択しづらいので，同じ人工知能を選択しているのであると考えられる．2 ターン目ではタイルゲーム AI を選ぶ割合が少し減っている．1 ターン目から 3 ターン目まではマルバツゲーム AI とタイルゲーム AI を選ぶ割合がほぼ同じであるが，4 ターン目以降ではマルバツゲームの方がタイルゲーム AI を選ぶ割合が多くなっている．各ゲームでそれぞれの人工知能を選択した方が勝てるはずなので，マルバツゲームではマルバツゲーム AI を，タイルゲームではタイルゲーム AI を選択するのが理想なのであるが，全体的にタイルゲームを選んでいく傾向がある．ターンが経過するほど判断材料も増えるので，正しく選択出来るようになると予想されるが，マルバツゲームではターンが経過してもマルバツゲームを選択する割合が増えず，タイルゲームではむしろタイルゲーム AI を選択する割合が減っている．

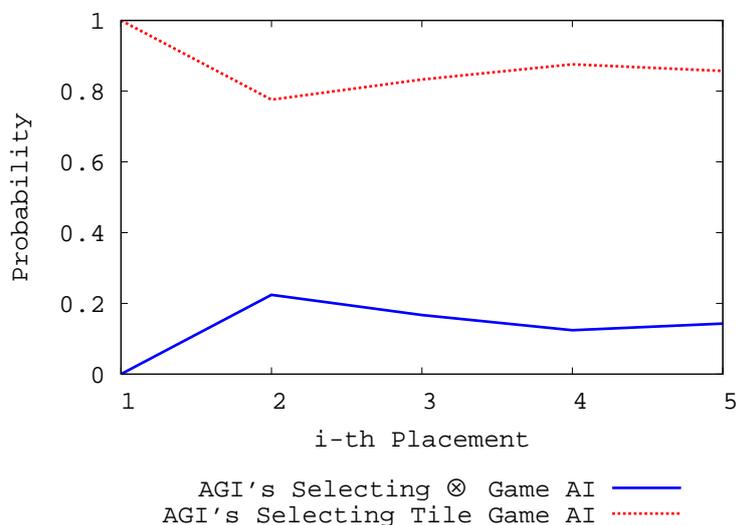


図 4.4 マルバツゲームにおける特化型 AI の選択

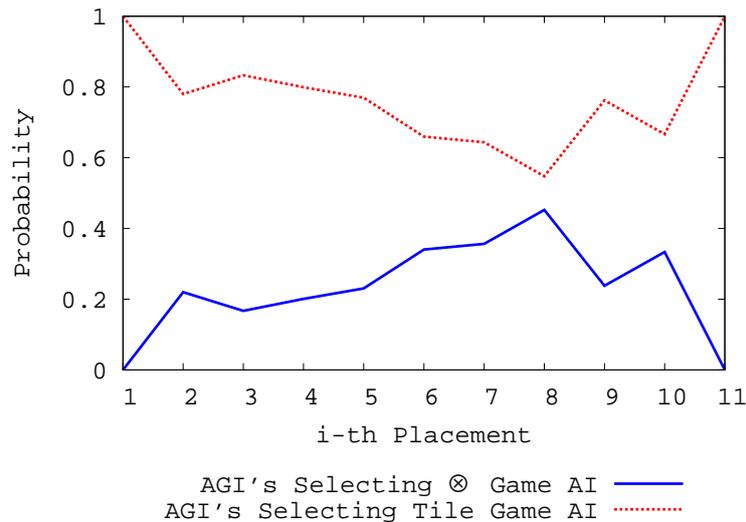


図 4.5 タイルゲームにおける特化型 AI の選択

4.3.2 各ゲーム AI の評価

各ゲーム AI にマルバツゲームとタイルゲームにおいて、空いているところにランダムに置くコンピュータと 1,000 戦ずつ対戦させた。そのうちの各ゲーム AI の勝ち数を表示すると表 4.1 のようになる。マルバツゲーム AI は、マルバツゲームでは勝ち数が 900 回を超えているのに対して、タイルゲームでは 600 回も超えることが出来なかった。タイルゲーム AI はタイルゲームで勝ち数が 980 回以上あり、マルバツゲームでも 600 回を超えた。選択型汎用人工知能はタイルゲームでは勝ち数が 900 回以上あり、マルバツゲームでは 670 回あった。マルバツゲームとタイルゲームのルールが似ていることもあり、マルバツゲーム AI とタイルゲーム AI は互いに学習していないゲームにも関わらず、500 回以上勝った。求める選択型汎用人工知能の勝ち数は、それぞれの特化型ゲーム AI が、900 回以上は勝っているのに、900 回以上であったが、マルバツゲームにおいて、期待するほど勝ち数は得られなかった。その原因として、選択型汎用人工知能が学習をする際、選択型汎用人工知能のマルバツゲーム AI とマルバツゲーム AI が対戦したとき、良くても引き分けにしかならず、マルバツゲームにおいて、マルバツゲーム AI を選択することを学習しなかったことが原因であると考えられる。

表 4.1 各ゲームにおける各ゲーム AI の対戦結果 (勝ち数)

	マルバツゲーム	タイルゲーム
マルバツゲーム AI	925	583
タイルゲーム AI	629	984
選択型汎用人工知能	675	913

4.4 ゲーム AI の汎用性の評価

4.4.1 アンケートによるゲーム AI の汎用性の評価

汎用性の評価を行うため、表 4.1 の結果から、ゲーム AI の名前とゲームの名前を隠して対戦結果から汎用的なゲーム AI はどれかを問う順位形式のアンケートを 15 人に行った。アンケート結果は図 4.6 のようになった。

アンケートを元に順位に得点を付け、平均得点を求め、表 4.2 にまとめた。さらに、各ゲーム AI の平均得点から有意差の p 値を求め、表 4.3 にまとめた。マルバツゲームはタイルゲーム AI、選択型汎用人工知能とそれぞれ有意差があり、タイルゲーム AI と選択型汎用人工知能には有意差が認められないことが分かった。

汎用的なゲーム AI として、選択型汎用人工知能とタイルゲーム AI が選ばれた。マルバツゲーム AI は他 2 つのゲーム AI に比べて、汎用的なゲーム AI に選ばれなかった。選択型汎用人工知能はマルバツゲームにおいて 675 回しか勝てていないが、この値は他 2 つのゲーム AI のタイルゲーム AI は全てのゲームの勝ち数を合わせたとき、一番高い値となるため、汎用性が高いと判定されたと考えられる。

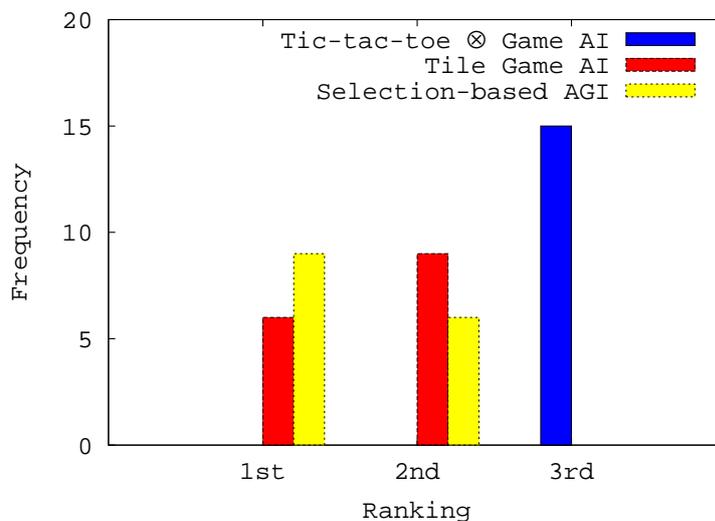


図 4.6 ゲーム AI の汎用性に関するアンケート結果 (N=15)

表 4.2 ゲーム AI の汎用性に関するアンケートの集計結果と順位ごとの得点

	1 位	2 位	3 位	平均得点
マルバツゲーム AI	0	0	15	1.0
タイルゲーム AI	6	9	0	3.8
選択型汎用人工知能	9	6	0	4.2
得点	5	3	1	

表 4.3 ゲーム AI の平均得点の差の p 値

マルバツゲーム AI とタイルゲーム AI	$4.05005 \cdot 10^{-8}$
マルバツゲーム AI と選択型汎用人工知能	$7.40365 \cdot 10^{-9}$
タイルゲーム AI と選択型汎用人工知能	0.289303529

4.4.2 汎用度によるゲーム AI の汎用性の評価

ある人工知能 a_i の汎用性を測る汎用度 $iDoG(a_i)$ の計算に使うパラメータは $n = 2$, $m = 1$ となる。各タスクの評価値は表 4.1 の通りであり、取り得る値は $[0, 1000]$ である。また、タスクの難しさはマルバツゲームもタイルゲームも 1 とする。本研究では、クラスターが出来るほどタスク数が多くないので、定義式 (3) による汎用度の評価は行わない。各ゲーム AI に対する汎用度を測ると表 4.4 のようになった。定義式 (1) の汎用度の測り方では、選択型汎用人工知能よりもタイルゲーム AI の方が汎用度が高い結果となった。その原因は、タイルゲーム AI はマルバツゲームではそれほど高い評価値を出せていないが、タイルゲームの評価値が高かったため、結果として、全体を見たら汎用度の値が大きくなったと考えられる。

定義式 (2) で汎用度を測ったとき、タイルゲーム AI よりも選択型汎用人工知能の方が値が大きくなった。選択型汎用人工知能はバランス良く評価値が出せているため、定義式 (2) の汎用度の測り方で高い評価となった。

アンケートの結果で汎用性があるとされたゲーム AI が汎用度の定義式からも汎用性があると判定された。このことから、汎用度の定義式は汎用性を測る上で有効であると考えられる。また、アンケートで選択型汎用人工知能の方が汎用性が高いことから、選択型汎用人工知能の方を高く評価している定義式 (2) の汎用度の方が汎用度を測る上で有効であると考えられる。

表 4.4 各ゲーム AI の汎用度

	定義式 (1)	定義式 (2)
マルバツゲーム AI	1508	1166
タイルゲーム AI	1613	1258
選択型汎用人工知能	1588	1350

第 5 章

選択型汎用人工知能の精度向上と比較対象の追加

前章の評価実験では、選択型汎用人工知能はタイルゲームにおいては高い評価を出しているが、マルバツゲームでは高い評価が出せていない。

そこで、選択型汎用人工知能の学習相手を替えることによって、マルバツゲームの評価を上げる試みを行う。

また、選択型汎用人工知能の評価を行うための比較対象として、各ゲームの特化型人工知能だけでなく、学習時にマルバツゲームとタイルゲームの両方を与えて、どちらのゲームにも適応する人工知能を用意する。

5.1 選択型汎用人工知能の改善

選択型汎用人工知能は多くの盤面でタイルゲーム AI を選択することによって、タイルゲームにおいては高い評価を出しているが、一方でマルバツゲームの評価が下がっている。その原因として、選択型汎用人工知能の学習相手がそれぞれのゲームを学習した特化型人工知能であることが考えられる。

既に学習した人工知能相手に学習する方法であると、マルバツゲームにおいて、最善の手を指した場合でも、相手が最善の手を指していた場合、良くて引き分けとなる。そうすると、選択型汎用人工知能がマルバツゲームでマルバツゲーム AI を選んでいた場合でも、勝つことがないため、マルバツゲームでマルバツゲーム AI を選択するのを学習できなかった可能性がある。

そこで、選択型汎用人工知能の学習時の対戦相手を各ゲーム AI ではなく、空いているマスにランダムに置くコンピュータにする。そうすることで、マルバツゲームでも勝てるようになるので、マルバツゲームを学習することが出来るようになると思われる。

この選択型汎用人工知能を選択型汎用人工知能 v2.0（選択型 AGIv2.0）として性能評価を行う。

5.2 選択型汎用人工知能 v2.0 の結果

選択型汎用人工知能 v2.0 の対戦相手を空いているマスにランダムに置くコンピュータにして学習する。他の条件は選択型汎用人工知能と同様である。

選択型汎用人工知能の評価と同様に、空いているマスにランダムに置くコンピュータと 1,000 回対戦させた。選択型汎用人工知能 v2.0 の勝ち数と選択型汎用人工知能との比較を表 5.1 にまとめた。

また、1,000 戦の中で選択型汎用人工知能 v2.0 がターンごとにマルバツゲーム AI、タイルゲーム AI を選んだ割合を図 5.1, 図 5.2 にまとめた。図 5.1 はマルバツゲームにおいて、選択型汎用人工知能 v2.0 がマルバツゲーム AI、タイルゲーム AI を選んだ割合を表しており、図 5.2 はタイルゲームにおいて選択型汎用人工知能 v2.0 がマルバツゲーム AI、タイルゲーム AI を選んだ割合を表している。

選択型汎用人工知能 v2.0 のマルバツゲームでの勝ち数は選択型汎用人工知能に比べて、38 回多くなった。また、選択型汎用人工知能 v2.0 のタイルゲームでの勝ち数も選択型汎用人工知能に比べて、8 回多くなった。

選択型汎用人工知能が比較的苦手としていたマルバツゲームでの勝ち数が上がったので、汎用性は上がっていると考えられる。

選択型汎用人工知能 v2.0 において、どちらのゲームでも、1 ターン目は選択型汎用人工知能と同様に、必ずタイルゲーム AI を選択している。2 ターン目は選択型汎用人工知能と比べてマルバツゲーム AI を選択する割合が増えている。全体的に選択型汎用人工知能と比べて、正しく人工知能を選択出来ている。マルバツゲームでは、2 ターン目以降、マルバツゲーム AI を選択する割合が増えてはいないが、あまり減ってもいない。タイルゲームでは、ターンが経過するごとに、タイルゲーム AI を選択する割合が増えていく傾向がある。つまり、ターンが経過するごとに、正しく選択出来ていることになる。

表 5.1 選択型汎用人工知能 v2.0 の対戦結果 (勝ち数)

	マルバツゲーム	タイルゲーム
選択型汎用人工知能	675	913
選択型汎用人工知能 v2.0	713	921

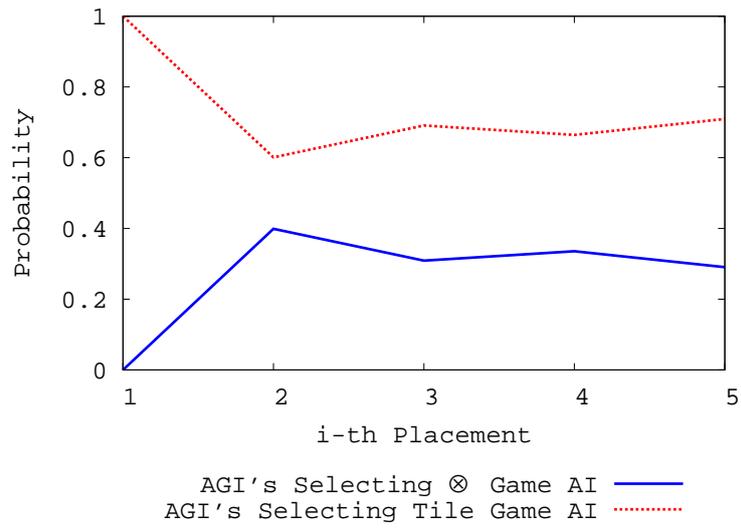


図 5.1 選択型 AGIv2.0 によるマルバツゲームにおける特化型 AI の選択

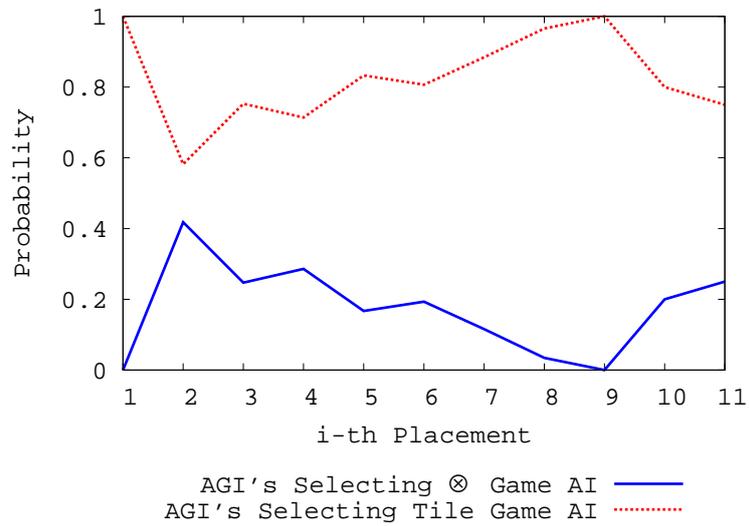


図 5.2 選択型 AGIv2.0 によるタイルゲームにおける特化型 AI の選択

5.3 混合人工知能

選択型汎用人工知能の性能評価のための比較対象として、混合人工知能を用意する。混合人工知能は、マルバツゲームとタイルゲームの両方をマルバツゲーム AI やタイルゲーム AI 同様に、DQN を用いて学習させたものである。マルバツゲーム AI、タイルゲーム AI と同様に DQN 同士で対戦を行い学習させた。学習の方法の違いで4パターンに分類した。それぞれのゲーム AI を mix1, mix2, mix3, mix4 とする。

mix1 マルバツゲームとタイルゲームを交互に学習する。

mix2 マルバツゲームとタイルゲームをランダムに学習する。

mix3 マルバツゲームを 10,000 試合学習後、タイルゲームを 10,000 試合学習する。

mix4 タイルゲームを 10,000 試合学習後、マルバツゲームを 10,000 試合学習する。

5.4 混合人工知能の結果

混合人工知能を他ゲーム AI と同様に、空いているところにランダムに置くコンピュータと 1,000 回対戦させた。各混合人工知能の勝ち数は表 5.2 のようになった。

単純な勝利数の合計では mix2 が一番多いが、マルバツゲームにおいては勝利数が 910 回であり、タイルゲームでは 673 回なので、マルバツゲームに偏って学習している。一方 mix1 はマルバツゲームの勝利数が 820 回であり、他の混合人工知能に比べて少なめであるが、タイルゲームにおいては勝利数が 710 回あり、混合人工知能の中で一番多いので、バランス良く学習している。mix3 はマルバツゲームの勝利数が少ないため、マルバツゲームの学習が上手くいっていないと考えられる。逆に、mix4 はタイルゲームの勝利数が少ないため、タイルゲームの学習が上手くいっていないと考えられる。このことから、mix3, mix4 は半分ずつ偏らせて学習していた内の先に学習していたゲームの学習が上手くいっていないことが分かる。

表 5.2 各ゲームにおける混合人工知能の対戦結果（勝ち数）

	マルバツゲーム	タイルゲーム
mix1	820	710
mix2	910	673
mix3	781	697
mix4	876	643

5.5 汎用度の評価

新しい汎用人工知能の評価を行う。比較を行うために、これまでの人工知能を加えた全ての人工知能の対戦結果を表 5.3 にまとめた。

各人工知能の汎用性を調べるため、各人工知能の汎用性を問うアンケートを行う。また、各人工知能の汎用度を計算して、汎用度による汎用性の評価も行う。

表 5.3 各ゲームの人工知能の対戦結果（勝ち数）

	マルバツゲーム	タイルゲーム
マルバツゲーム AI	925	583
タイルゲーム AI	629	984
選択型汎用人工知能	675	913
選択型汎用人工知能 v2.0	713	921
混合人工知能 mix1	820	710
混合人工知能 mix2	910	673
混合人工知能 mix3	781	697
混合人工知能 mix4	876	643

5.5.1 アンケートによる汎用性の評価

人の観点から考えられる汎用性について知るために、各人工知能の結果についてのアンケートを 13 人に取った。ゲーム名とゲーム AI 名を隠して、各ゲーム AI の結果を表示し、汎用的なゲーム AI について問う順位形式のアンケートを行った。結果は図 5.3 となった。

図 5.3 より、順位ごとに点数を付け、その順位の票数×点数を取り、全ての順位の平均を出し、それぞれの人工知能を比較する。各人工知能の得点は表 5.4 のようになった。平均得点が高いほど汎用性が高いことから、選択型汎用人工知能 v2.0 は一番汎用性が高いと考えられる。

また、各ゲーム AI がどれほど汎用的であるかを 10 段階で問うアンケートも行った。結果は表 5.5 となった。10 に近いほど、汎用性が高いと回答している。

5.5.2 汎用度による汎用性の評価

汎用度によって各人工知能を評価する。汎用度の計算に用いるパラメータは 4.4.2 項と同様である。各人工知能の定義式 (1) と定義式 (2) による汎用度は表 5.6 のようになる。

定義式 (1) で 1 番汎用度が高い人工知能は 1634 で、選択型汎用人工知能 v2.0 である。2 番目に汎用度が高い人工知能は 1613 のタイルゲーム AI なので、選択型汎用人工知能 v2.0 はタイルゲーム AI に比べて、定義式 (1) において汎用度が 21 高い。1 番汎用度が低い人工知能は

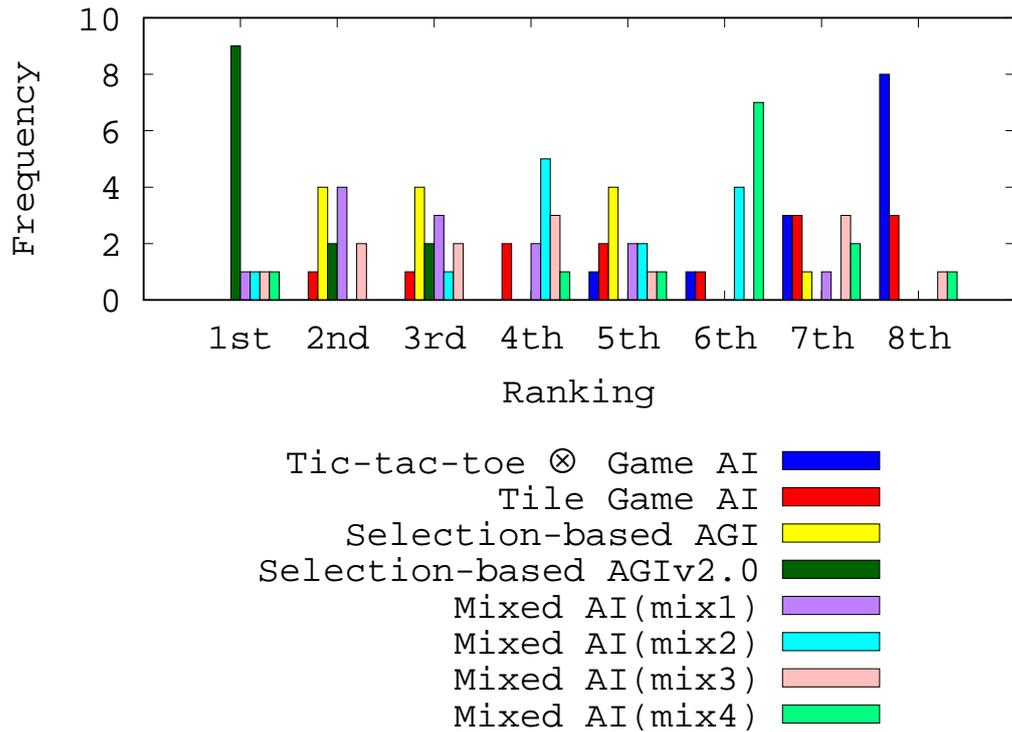


図 5.3 新しい AGI を含めた汎用性に関するアンケート結果 (N=13)

表 5.4 図 5.3 の集計結果と順位ごとの得点

	1 位	2 位	3 位	4 位	5 位	6 位	7 位	8 位	平均得点
マルバツゲーム AI	0	0	0	0	1	1	3	8	1.62
タイルゲーム AI	0	1	1	2	2	1	3	3	3.31
選択型汎用人工知能	0	4	4	0	4	0	1	0	5.38
選択型汎用人工知能 v2.0	9	2	2	0	0	0	0	0	7.54
混合人工知能 mix1	1	4	3	2	2	0	1	0	5.69
混合人工知能 mix2	1	0	1	5	2	4	0	0	4.54
混合人工知能 mix3	1	2	2	3	1	0	3	1	4.62
混合人工知能 mix4	1	0	0	1	1	7	2	1	3.31
得点	8	7	6	5	4	3	2	1	

1478 で mix3 である。つまり、選択型汎用人工知能 v2.0 との汎用度の差は 165 ある。

定義式 (2) で 1 番汎用度が高い人工知能は 1426 で選択型汎用人工知能 v2.0 である。2 番目に汎用度が高い人工知能が 1420 で mix1 なので、選択型汎用人工知能 v2.0 は mix1 に比べて汎用度が 6 高い。また、汎用度が 1 番低い人工知能は 1166 でマルバツゲーム AI である。マルバツゲーム AI の選択型汎用人工知能 v2.0 との汎用度の差は 260 ある。

表 5.5 各ゲーム AI の汎用性の 10 段階アンケート評価 (N=13)

	1	2	3	4	5	6	7	8	9	10	平均
マルバツゲーム AI	1	2	1	5	2	1	1	0	0	0	3.92
タイルゲーム AI	1	1	2	3	3	1	2	0	0	0	4.31
選択型汎用人工知能	0	1	0	2	1	2	3	3	0	1	6.31
選択型汎用人工知能 v2.0	0	0	0	2	0	1	2	3	3	2	7.62
混合人工知能 mix1	1	0	0	1	0	3	5	3	0	0	6.31
混合人工知能 mix2	0	0	0	3	2	4	3	1	0	0	5.77
混合人工知能 mix3	0	2	2	1	2	1	2	1	2	0	5.38
混合人工知能 mix4	1	0	1	4	3	2	2	0	0	0	4.69

現状、汎用度の差がどれほど汎用性を反映しているのかは不明瞭であるが、様々な人工知能に対して汎用度を測ることが出来れば、汎用度と汎用性の関わりを知ることが出来るだろう。

表 5.6 新しい AGI を加えた各ゲーム AI の汎用度

	定義式 (1)	定義式 (2)
マルバツゲーム AI	1508	1166
タイルゲーム AI	1613	1258
選択型汎用人工知能	1588	1350
選択型汎用人工知能 v2.0	1634	1426
混合人工知能 mix1	1530	1420
混合人工知能 mix2	1583	1346
混合人工知能 mix3	1478	1394
混合人工知能 mix4	1519	1286

5.5.3 汎用度の有用性

汎用度とアンケートによる汎用性の比較を行うために、アンケート結果の平均得点と定義式(1)、定義式(2)による汎用度を散布図に表し、比較を行う。

図5.4、図5.5はそれぞれアンケート結果の平均得点と定義式(1)、定義式(2)による汎用度に順位付けを行い、散布図に表したものである。定義式(1)による汎用度の順位とアンケート結果の平均得点の順位の相関係数は0.46であり、弱い相関関係が見られる。定義式(2)による汎用度の順位とアンケート結果の平均得点の順位の相関係数は0.97であり、強い相関関係が見られる。

また、図5.6、図5.7はアンケート結果の平均得点と定義式(1)、定義式(2)による汎用度を散布図に表したものである。定義式(1)による汎用度とアンケート結果の平均得点の相関係数は0.49であり、弱い相関関係が見られる。定義式(2)による汎用度とアンケート結果の平均得点の相関係数は0.92であり、強い相関関係が見られる。

定義式(2)による汎用度は、アンケート結果の汎用性と強い相関関係があることから、人工知能の汎用性を測る上で十分有用であると考えられる。

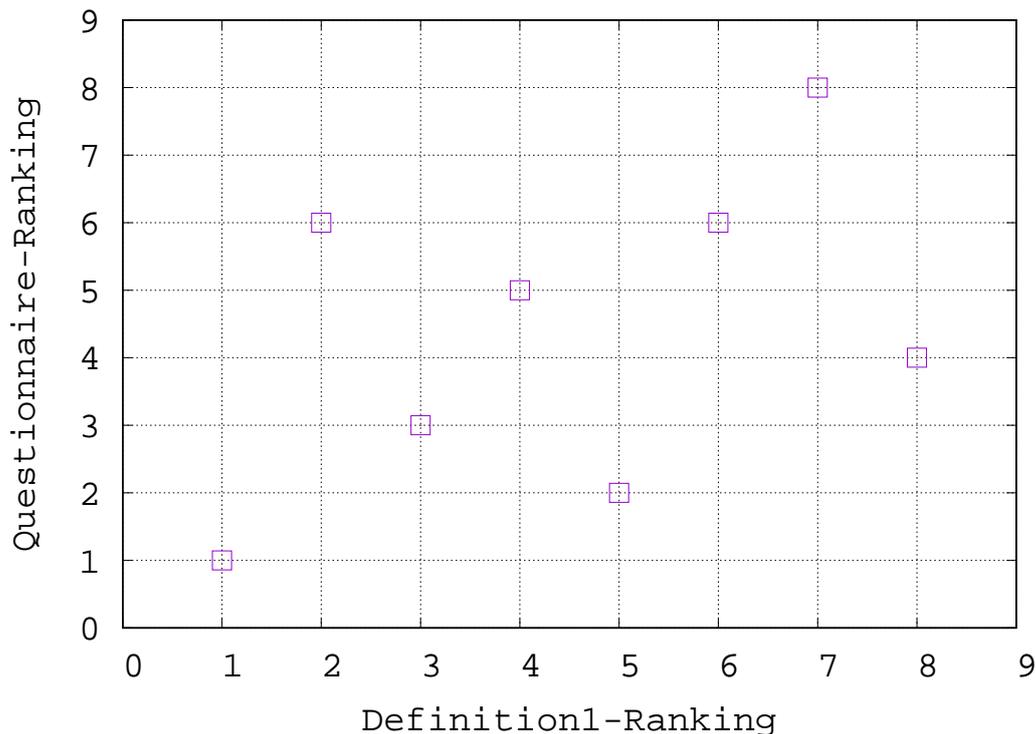


図5.4 定義式(1)とアンケート結果の平均得点の順位の散布図

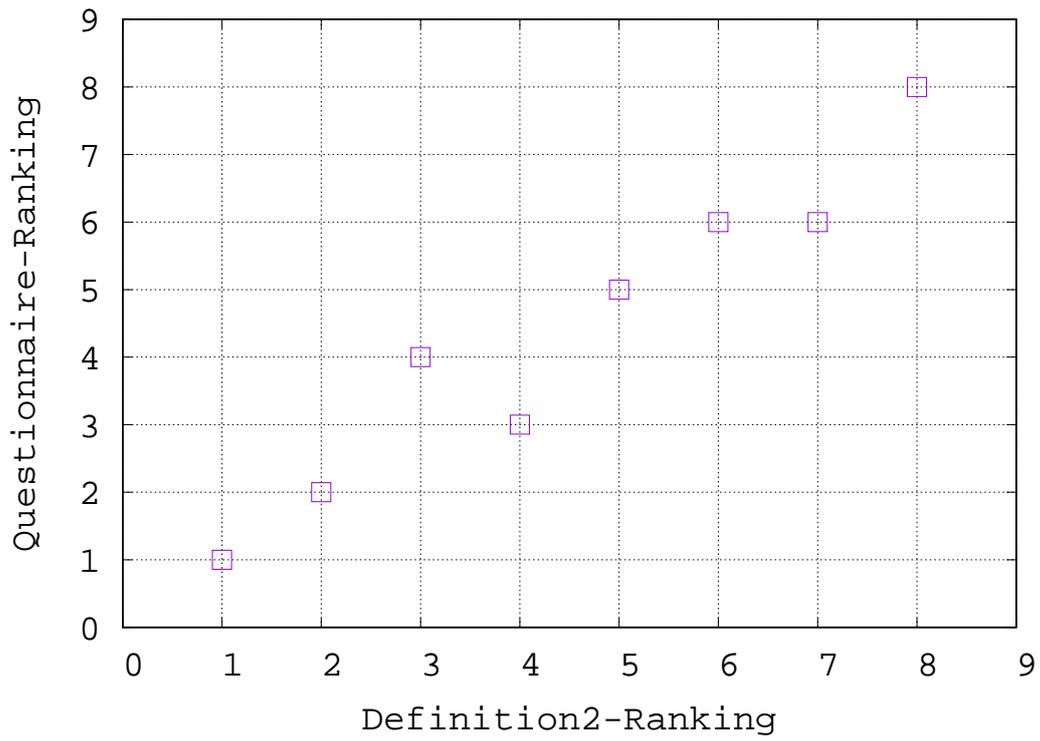


図 5.5 定義式 (2) とアンケート結果の平均得点の順位の散布図

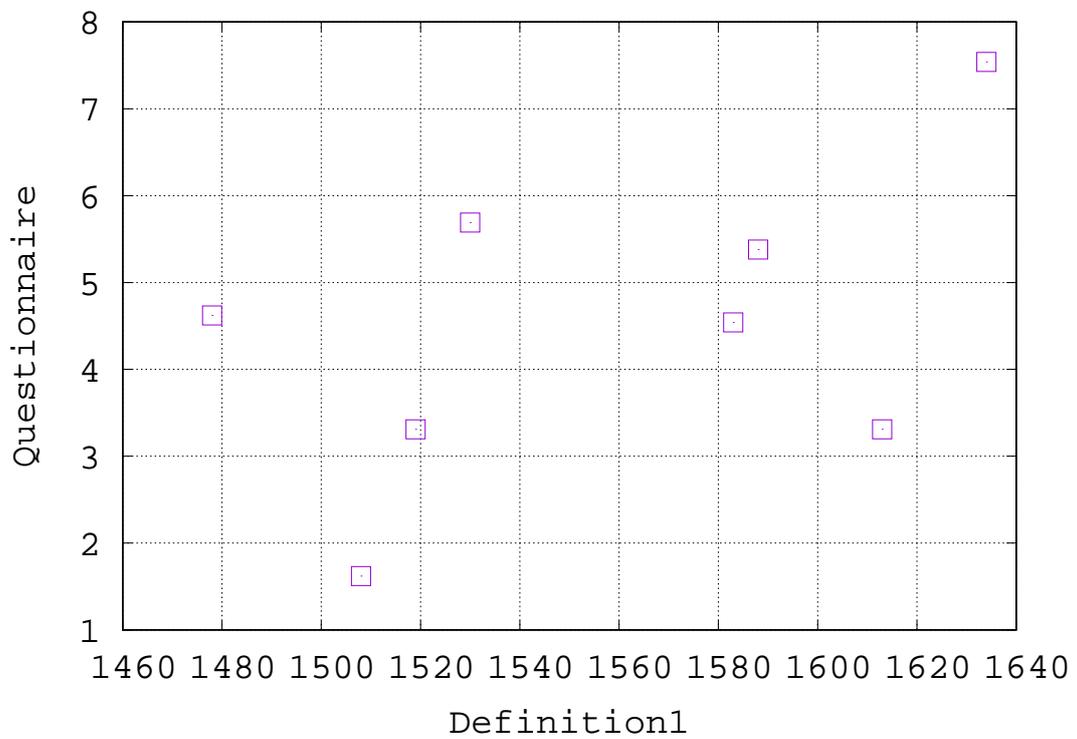


図 5.6 定義式 (1) とアンケート結果の平均得点の散布図

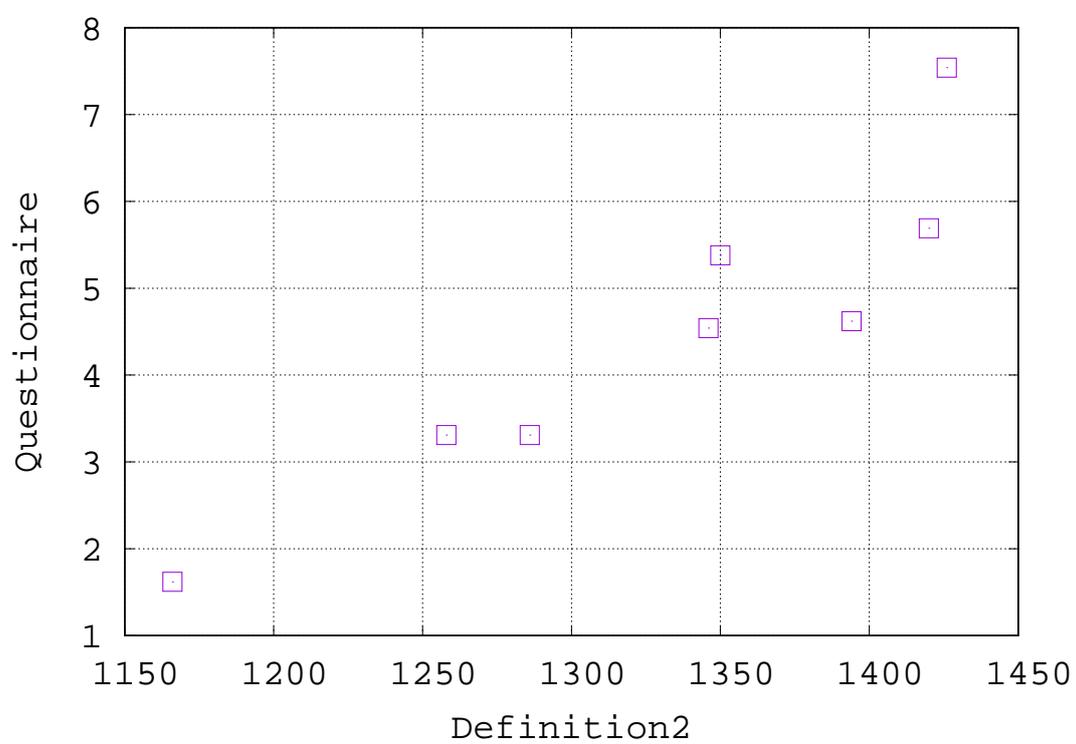


図 5.7 定義式 (2) とアンケート結果の平均得点の散布図

第6章

まとめと今後の研究課題

6.1 まとめ

本研究では、特化型人工知能を適応的に選択することによって汎用性を付与した選択型汎用人工知能の提案と、汎用人工知能の評価を行うための指標としての汎用度の定義の提案を行った。

選択型汎用人工知能はアンケートの結果から、実験した人工知能の中で最も汎用性が高い人工知能であると評価された。

また、汎用度の定義式3種類は一部試せなかった式があるが、汎用性の評価がアンケートの結果と強い相関を持っていることから、本研究において、上手く評価出来ていると考えられる。

6.2 社会的貢献と技術的貢献

近年、特化型人工知能の研究が行われているものの、汎用人工知能についての研究は消極的である。本研究を通して、汎用人工知能の研究を活発にすることが、人工知能分野への貢献であり、ひいては社会的貢献であると考えられる。

本研究の技術的貢献は、汎用人工知能に近づけるための一例として、選択型汎用人工知能の提案、実験を行ったことと、汎用人工知能の評価を行うための指標として汎用度を定義、評価したことである。選択型汎用人工知能の提案、実験は今後の汎用人工知能の研究を行う際の参考になり、汎用度の定義、評価は今後の人工知能の評価の参考となると考えられる。

6.3 今後の研究課題

本研究では、扱うタスクの数が足りず、評価出来なかった汎用度の定義式があるので、タスクの数を増やし、本研究で行えなかった定義式の評価も行う必要がある。また、本研究では触れなかったが、汎用度の式のパラメータの「タスクの難しさ」の定義を決める必要がある。

6.4 関連研究から考える選択型汎用人工知能の評価

最後に、関連研究で説明した「AGIの環境、タスクおよびエージェントの特性」について本研究がどれほど当てはまっているかを1つ1つ確認していく。

1. 環境は複雑であり、多様で相互に作用しあう複雑な構造をもつオブジェクトで構成される。
→ 環境が複雑ではないため当てはまらない。
2. 環境は動的かつ開放的である。
→ 環境は閉じているので当てはまらない。
3. タスクに関連する規則性が時間のスケールごとに存在。
→ ターン性のゲームなので当てはまる。
4. 他のエージェントの行動が自信の行動に影響を及ぼす。
→ 対戦ゲームなので当てはまる。
5. タスクは複雑、多様、かつエージェントが事前知識としてもっていない新規なものであり得る。
→ エージェントはタスクを知っている必要があるので当てはまらない。
6. エージェントと環境、タスクとの相互作用は、複雑であるが有限である。
→ 複雑ではないので当てはまらない。
7. エージェントの計算リソースは有限である。
→ 計算機の計算リソースは有限なので当てはまる。
8. エージェントは長期間・連続的に存在する。
→ エージェントはゲームの間だけ存在するので当てはまらない。

8つの条件中、5つが当てはまらないことが分かった。当てはまらなかった5つの条件も満たせるようにすれば汎用人工知能として、さらに進歩させられるかもしれない。

謝辞

本研究に際して、ご助言、ご指導頂いた服部峻助教に厚く御礼申し上げます。

博士後期課程の荒澤孔明さんには、研究に関する助言や文の間違いの指摘などをして頂きました。ありがとうございます。

また、同研究室の皆様には、研究に関する意見や実験の手伝いをして頂きました。感謝いたします。

そして、本研究のアンケートに答えて下さった皆様に心から感謝します。ありがとうございました。

参考文献

- [1] ledge.ai 編集部 (2019), チューリングテストとは, <https://ledge.ai/turing-test/> (閲覧日:2021年2月3日).
- [2] Sam S. Adams, *et al.*, “人間レベルの汎用人工知能の実現に向けた展望 (<特集>汎用人工知能 (AGI) への招待),” 人工知能, vol.29, no.3, pp.241–257 (2014).
- [3] 高校数学の美しい物語, <https://mathtrain.jp/marupeke>, (閲覧日:2021年2月3日).
- [4] 3 x 3 盤 タイルゲーム for Windows, <http://www2u.biglobe.ne.jp/~shunbook/omocha/tlwin3.htm> (閲覧日:2021年2月3日).
- [5] DQN (Deep Q Network) を理解したので、Gopher さんの図を使って説明, <https://qiita.com/ishizakiiii/items/5eff79b59bce74fdca0d>, (閲覧日:2021年2月3日).