

適応アルゴリズム理解におけるバイアスの役割

寺田 和憲^{1,a)} 山田 誠二² 伊藤 昭¹

概要: 人-コンピュータ協調作業において、人がコンピュータのアルゴリズムを理解する認知過程はよくわかっていない。本研究では最も容易に理解できる適応アルゴリズムとして知られる most recently used アルゴリズムがどのように理解されるかを調べた。実験によって、履歴の注目範囲を限定するための決定論バイアスやマルコフ性バイアスなどの帰納的バイアスだけでなく、事前知識に基づく演繹的推論によってアルゴリズム理解がなされることが分かった。

1. はじめに

情報技術の進歩により人がコンピュータと協調的に仕事を行う機会が増えている。ユーザに対して適応するシステムを実現することは、ヒューマンコンピュータインタラクションや人工知能、機械学習研究者の主要研究課題の一つであるが [4], [9], [18], 明確な設計指針は未だに定義されていない [11], [15], [20]。また、人-コンピュータ協調作業において人がコンピュータのアルゴリズムをどのように理解するかについての認知モデルの研究は十分になされていない。

人同士の協調タスクにおいては、相互に意図を理解することが協調タスクを成功させる鍵になる [5], [6]。しかし人とコンピュータの協調タスクにおいて必要な相手の振舞いの抽象化粒度は人-人のタスクにおいて要求されるものと異なる [8]。人-コンピュータの協調タスクでは目的（意図）に基づく振舞いの抽象化は必要とされない。なぜなら、タスクの目的は人とコンピュータの間で明示的に共有されているからである。人-コンピュータの協調タスクにおいては、人がコンピュータの振舞いを予測する必要があるため、コンピュータがどのようなアルゴリズムで動作しているかを同定することが重要である。

対象の将来の振舞いを予測するための一つの方法は系列学習に基づいて獲得された入出力関係を利用することである [7], [23], [26]。典型的な系列学習の問題では、人は与えられた実行例から繰り返される行為系列を学習する [17]。その結果、同一の行為系列に対する反応時間は減少する。

この学習は明示的に行われる場合と暗黙的に行われる（感覚-行動出力学習）場合の両方が存在し、暗黙的な系列学習の方がより多く研究されている [22]。表面的な行動系列が観測されるという点では系列学習もアルゴリズム理解も同じであるが、アルゴリズム理解においてはコンピュータの内部状態を考慮した上で生成される手続きを学習する必要がある。これは、系列学習が系列をパターンとして学習することと本質的に異なる。アルゴリズム理解においては、観察者は振舞いを説明するための多くのアルゴリズムを仮説として考慮しなければならない。そのために、アルゴリズム理解は系列学習よりも困難な課題となっている。この困難さのために、アルゴリズム理解には何らかのバイアスが用いられていると考えられる。さらに我々の対象としている適応アルゴリズム理解では、系列学習と異なる特徴としてインタラクティブ性を考慮しなければならない。人-コンピュータの協調作業においては、コンピュータは人に対して適応するので、コンピュータの振舞いは人の振舞いに依存して変化する。一方で系列学習においては、系列は物理的刺激として人に提示される。

本研究の目的は、人-コンピュータ協調タスクにおいて、人がコンピュータのアルゴリズムを理解する際の認知過程をモデル化することである。そのために、最も簡単な人-コンピュータ協調タスクである協調記号合わせゲームを用いた。このゲームでは、コンピュータは人に適応する振舞いを生成し、人はその適応アルゴリズムを同定することを求められる。具体的には、最も簡単な適応アルゴリズムとして知られている most recently used (MRU) アルゴリズム [9], [11], [16] を実験参加者がどのように理解するかを調べた。MRU アルゴリズムでは、コンピュータはユーザの最後の入力をそのまま出力する。MRU アルゴリズムの例として、ソフトウェアアプリケーションでよく見られる「最

¹ 岐阜大学
Gifu University, Yanagido 1-1, Gifu 501-1193, Japan
² 国立情報学研究所/総合研究大学院大学/東京工業大学
National Institute of Informatics, SOKENDAI, Tokyo Institute of Technology
a) kazunori.terada@acm.org

近使用したファイル」[1]のように直近に使用されたファイルのリストを表示することや、「最近使用されたメニュー」のリストを表示すること（適応メニュー）[2]が知られている。

MRU アルゴリズムは適応ユーザインタフェースを含む有用なインタラクティブソフトウェアを実現することに貢献してきた [9]。MRU アルゴリズムの成功の一つの理由は MRU アルゴリズムがユーザに簡単に理解されることである。もしユーザが見るたびに順番が変わるファイルやメニューのリストに対して意味を見出すことができなければ、ユーザはストレスしか感じないだろう。しかし、ユーザはその順序の変化が自分自身の過去の履歴に依存していると分かるので、そのリストをタスクの効率を向上させることに利用できる。ユーザが MRU アルゴリズムを理解できるのは、MRU アルゴリズムが「最近使用されたメニュー」などの明示的な記述とともに実装されているからである。本研究では、我々はそのような明示的な知識が与えられない状況において、MRU アルゴリズムがどのように理解されるかを調べた。

ルール発見が帰納的推論プロセスであると考えられているように [13], [19], [21], [25], アルゴリズム理解も帰納的な推論に基づいていると考えることができる。一般的に帰納的推論は少数事例に対して行われるが、有限の事例から無限の現象を説明するための適切なルールを発見することは困難である。なぜなら、事例を説明可能な仮説ルールの集合が膨大な数になるからである。したがって、人は仮説の集合を適当に制限するためにヒューリスティックス（帰納的バイアス）を用いていると考えられる。アルゴリズム理解においては、人は高々数十の事例からコンピュータのアルゴリズムを推論しなければならないので、アルゴリズム理解においても強力なバイアスが働いていると考えられる。本稿では、人のアルゴリズム理解の認知過程をモデル化するために、我々はバイアスの存在を仮定し、心理実験を通じて検証する。

2. 適応アルゴリズム理解のための認知モデル

適応アルゴリズム理解はアルゴリズム理解のサブクラスである。ヒューマンコンピュータインタラクションにおける適応とは、与えられた目標のもとで、コンピュータの戦略が人の入力に合わせて動的に変化するようなアルゴリズムの特徴を有することである。この場合の目標は協調だけでなく、競合も含まれる [12] が本研究では協調を扱う。ここで人-コンピュータ協調タスクを一般化するために協調記号合わせゲームを紹介する。

2.1 協調記号合わせゲーム

このゲームは二人のプレーヤによって行われる繰り返しゲームである。プレーヤは各ラウンドにおいて、記号セッ

トの中から一種類の記号を選択し、同時に見せ合う。記号セットは例えば、♠, ♠, ♠ のようなものである。記号が一致していれば両方のプレーヤに得点が与えられ、一致しなければ両者ともに得点は与えられない。記号を一致させるためには双方が相手の次の手を読み、なおかつそれらが一致している必要がある。本研究においては片方のプレーヤはコンピュータである。

協調記号合わせゲームは適応ユーザインタフェースなどのユーザ適応システムにおける適応問題を適切にモデル化したタスクになっている。ユーザがユーザ適応的なシステムを使用する場合、システムはユーザの次の行動を予測しなければならない。例えば、適応メニュー [9] においてはシステムは次にユーザがどのメニューをクリックするかを予測し、ユーザインタフェースの配置を改変することなど [9] によってユーザ適応しなければならない。もし、予測が正しい場合にはユーザ側は利便性を得ることができ、システム側はシステムが有効であるという評価を得ることができる。これは協調することによって両者が利益を得るという非ゼロ和ゲームでモデル化可能である。適応メニューを例に考えると、選択可能な記号の数は選択可能なメニューの数に相当する。しかしながら、協調記号合わせゲームと適応ユーザインタフェースには違いがある。その違いとは、ソフトウェアを使った作業ではユーザはタスクに応じてメニューを選ばなければならないが、協調記号合わせゲームでは参加者は完全に自由に記号を選択することができる。従って協調記号合わせゲームは適応ユーザインタフェースにおいて、ユーザの文脈非依存な状況の近似をしていることになる。

協調ゲームにおいて最も単純な戦略は、直近に最も大きな報酬を得ることができた手を出すことである。これは強化学習アルゴリズムとして知られている [24]。しかしながら、より洗練された戦略は、相手の手の履歴に基づいて相手の手の出し方の統計モデルを構成し、それを用いて相手の次の手を予測することである。ゲーム理論 [10][3] や時系列学習 [23] などの対戦相手がいる状況での意思決定に関する研究では、対戦相手の戦略は純粋戦略ではなく混合戦略として同定されるることが示されている。混合戦略とは単一の戦略を用いるのではなく、いくつかの純粋戦略の中から確率的に一つの戦略を選択することである。

2.2 統計モデル

前述の通り、コンピュータの戦略に対するレベルの高い抽象化はバイアスに基づいて行われると考えられる。我々は議論の開始点として、人がコンピュータの振舞いを理解する際に同定すべき統計モデルを考える。アルゴリズム認知の問題は、同定すべきアルゴリズムに対して探索しなければならない空間が広いということである。人が得ることができる情報はコンピュータとユーザ自身の行動履歴

表 1 MRU アルゴリズムと確率的 MRU アルゴリズムの条件付き確率

		a_{t-1}^h		
		♡	♠	◇
a_t^s	♡	1	0	0
	♠	0	1	0
	◇	0	0	1

(a) D-MRU

		a_{t-1}^h		
		♡	♠	◇
a_t^s	♡	.9	.05	.05
	♠	.05	.9	.05
	◇	.05	.05	.9

(b) P-MRU

のみである。そのために、振舞い予測はコンピュータの次の選択に関する条件付き確率を同定することと定式化できる。この条件付き確率は次の式で表現される。

$$p(a_t^s | a_{t-1}^s, \dots, a_{t-j}^s, a_{t-1}^h, \dots, a_{t-k}^h) \quad (1)$$

ここで、 $a^h, a^s \in A$ とする。A は人とシステムが選択可能な選択肢である。記号合わせゲームでは記号の集合に相当する。 $a_{t-1}^s, \dots, a_{t-j}^s$ と $a_{t-1}^h, \dots, a_{t-k}^h$ はそれぞれシステムと人が選択した手の履歴である。j と k は考慮する履歴の長さであり、どれぐらい過去の手を参照するかというスコープに依存して変化する。

しかしながら、観測した時系列からコンピュータのアルゴリズムを同定することは不良設定逆問題である。なぜなら、人はコンピュータの現在の手がどれぐらいの長さの履歴に依存しているかを知るすべがなく、また、異なるアルゴリズムが同じような履歴を生成する可能性があるからである。従って、我々は、人がシステムのアルゴリズムを同定するためにシステムの振舞いを探索する際に、何らかのバイアスを用いて探索範囲を制限するのではないかと考える。

MRU アルゴリズムは式 (1) の履歴長を $1(j=1)$ に限り、またコンピュータ自身の振舞い ($a_{t-1}^s, \dots, a_{t-j}^s$) を無視することで次のように定式化される。

$$p(a_t^s | a_{t-1}^h) \quad (2)$$

協調記号合わせゲームにおいて、MRU アルゴリズムを用いて生成される手の実際の確率分布は表 1(a) のようになる。システムの選択 a_t^s は人の直近の選択 a_{t-1}^h のみに依存している。例えば、人がひとつ前のラウンドにおいてハートを選択したとすると、システムの次の選択はハートになる。これは $p(a_t^s = \heartsuit | a_{t-1}^h = \heartsuit) = 1$ のように表現される。

理論的には、この確率分布を同定するために無限回の試行を必要とする。しかしながら、もし人が**決定論バイアス**や**マルコフ性バイアス**を使うことができるならば、数回の

試行によってもシステムのアルゴリズムが MRU アルゴリズムであることを同定できる。決定論バイアスとはシステムが生成する手が決定論的に決定していると考えられることである。決定論バイアスを使えば、観測された単一の随伴関係をそのまま直接的な証拠として使える。マルコフ性バイアスとはシステムの現在の手がひとつ前の過去の手に依存していると仮定することである。マルコフ性バイアスを用いることによって、ひとつ前以外の過去の手を考慮する必要がなくなり、探索範囲を大幅に絞ることができる。重要なことは、システムのアルゴリズムに決定性やマルコフ性が存在することはユーザにとって自明ではなく、また、観測結果から推測することが困難なため、トップダウンにそれらのバイアスを用いない限り MRU アルゴリズムでさえ同定が難しいということである。

3. 実験

人-コンピュータ協調タスクにおいて人がコンピュータの適応アルゴリズムをどのように理解するかを調べる参加者実験を行った。タスクは前述の協調記号合わせゲームを用いた。コンピュータの適応アルゴリズムとしては通常の決定論的 MRU(D-MRU) と MRU アルゴリズムにノイズを加えた確率的 MRU(P-MRU) アルゴリズムを用いた。参加者はコンピュータと協調してゲームを行うように教示された。また、実験の後で参加者が理解したコンピュータのアルゴリズムを答えるように求められた。

次に示す、異なる 2 つの確率分布を用いて、50 ラウンドの繰り返し記号合わせゲームを行った。

決定論的 (D-MRU) 条件

コンピュータの選択は直近の人の手に完全に一致する。すなわち一般的な MRU アルゴリズムである。以下 D-MRU アルゴリズムと呼ぶ。具体的な確率分布は表 1(a) の通りである。

確率的 (P-MRU) 条件

コンピュータの選択する手の 90% は MRU アルゴリズムによって生成し、残りの 10% は異なるものを出す。以下 P-MRU アルゴリズムと呼ぶ。具体的な確率分布は表 1(b) の通りである。

P-MRU 条件は MRU アルゴリズム理解における帰納的推論過程に与えるノイズの影響を調査するために設けた。特に我々は、決定論バイアスはノイズによって強く影響され、その結果 P-MRU 条件では参加者のパフォーマンスが落ちると予想する。もし、実験参加者がアルゴリズム理解という高次の抽象化を行うのではなく、単に統計モデルを同定するだけなら、P-MRU 条件におけるパフォーマンスは D-MRU 条件よりも高々 10% 悪くなるだけだと予想される。また、P-MRU 条件は MRU アルゴリズムに対して不確実性を加えることによって、コンピュータに対する印

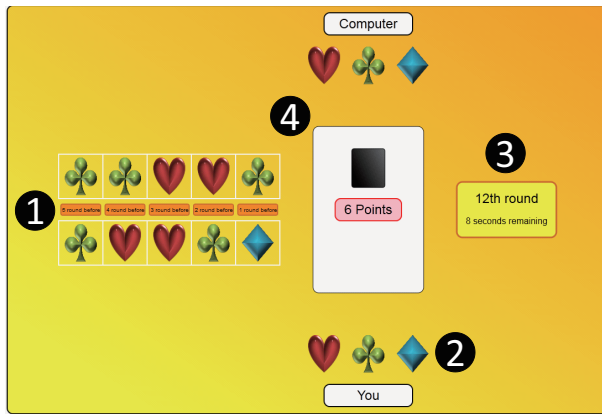


図 1 実験に用いたインタフェース: 1) 両方のプレーヤが過去に選択したマークの履歴, 2) マークの選択肢. クリック可能になっている, 3) ラウンド数と残り時間, 4) プレーヤの選択結果と点数を表示する場所. 両者の選択が出揃うまで黒いカードが表示される.

象や実験参加者の態度が変化するかどうかを調べる目的も持つ.

3.1 実験手順と観測項目

協調記号合わせゲームは JavaScript, PHP, HTML によって作成された. 実験は Firefox Web ブラウザで行われた. 図 1 はゲームのインタフェース画面である. コンピュータの手は JavaScript プログラムによって各条件の確率分布に従って自動的に選択された. 手の選択タイミングはラウンド開始後一定時間にならないようにした. 実験参加者は各ラウンドで 10 秒以内にハート, クラブ, ダイヤモンドのいずれかのマークをクリックして自分の記号を決定するように求められた. 双方の選択した記号は黒く覆われたまま図 1 中 4 の場所に表示され, 双方の選択が完了したら直ちに覆いが外され選択した記号が参加者に対して明らかになる. 双方の過去 5 ラウンドの選択が表示された.

参加者に対して, 記号が一致していればコンピュータ, 参加者双方の得点となり, 一致しなければ双方ともに得点を得られない, 最終的な獲得ポイントが高くなるように記号を選択することを指示した.

実験は一要因二水準, 参加者間計画で行われた. 男性 41 人女性 9 人の計 50 人 (19 歳から 47 歳, 平均年齢 28 歳) の被験者が実験に参加した. 参加者は著者らの知人にダイレクトメールを送ることで募集した. すべての参加者は Firefox を問題なく使用できる程度にコンピュータの扱いに慣れていて, 参加者は D-MRU 条件と P-MRU 条件にランダムに振り分けられた. 参加者には, この実験の目的はオンラインゲームシステムのユーザビリティを調査することであると伝えられた. また, コンピュータは協調的に振舞うと伝えられた. また, 得点に応じた価格帯のコンピュータ周辺機器が得られると伝えられた (20 点以下は 500 円, 21 点から 44 点は 1,500 円, 45 点以上は 3,000 円程度).

P-MRU 条件では, MRU アルゴリズムによる記号選択に対して 10% のノイズが混入した 50 ラウンドの系列を用いた. これは, 実験開始時に参加者ごとにノイズが混入するラウンドを決定することで行った. ただし, 最初と最後の 5 ラウンドにノイズ混入ラウンドが現れる系列は排除した. コンピュータの第一ラウンドの選択は参加者の選択と一致しないように決定された. しかし, 参加者は黒いカードが選択された時点でコンピュータの記号が決定すると思っているので, この後出しに気付くことはない.

50 ラウンド全ての結果を記録した. 参加者が残りの全てのラウンドで同一記号を選択し始めたラウンドをこのゲームに対する最適解を発見したラウンドとして扱った.

条件間でコンピュータに対する印象や実験参加者自身の態度に違いがあるかを調べるために次の 7 項目の質問を行った. これらの質問には, 1. 全く思わないから 7. 強く思うまでの 7 段階で答えることを求めた.

- Q1 コンピュータは「あなたに対して協力的」だった
- Q2 コンピュータは「ゲームをする上で良いパートナー」だった
- Q3 コンピュータは「有能」だった
- Q4 コンピュータは「自分勝手」だった
- Q5 あなたは「コンピュータに合わせようとした」
- Q6 コンピュータは「あなたに合わせようとしていた」
- Q7 コンピュータは「戦略 (規則) に従って」手を出していた

MRU アルゴリズムに対して高得点を取る方法は全てのラウンドで同一記号を選択し続けることである. しかし, このゲームの特徴として, アルゴリズムが MRU であることを同定しなくても, 単に同一手を選択し続けるだけでも高得点が取れる. したがって, 参加者が最適解を発見したとしても, それが正しくアルゴリズムを同定したことによるものかどうかは分からない. そのため, Q7 では参加者がアルゴリズムを同定したか否かを問う質問を行った. さらに, この質問に 5 から 7 と答えた参加者に対して「それはどのような戦略 (規則) だと思いましたか?」と具体的な戦略の記述を求めた.

3.2 実験結果

平均得点は D-MRU 条件で 43.7 (SD = 7.0), P-MRU 条件で 31.4 (SD = 7.5) であった. 1 元配置分散分析の結果, 条件間で平均得点に有意な差が観測された ($F(1, 48) = 33.99, p < 0.01$). 条件間の平均得点の差は 12.3 である. 得点差が 5(10%) 以上あることから実験参加者は決定論バイアスを使用していたと考えられる. この差は勝率の増加割合によっても説明できる. D-MRU 条件の勝率はゲーム開始後すぐに高くなっている. 例えば, 6 ラウンド目で勝率は 80% を越えている. 一方で P-MRU 条件では勝率は 30 ラウンド近くまで 60% 程度で推移し, 35

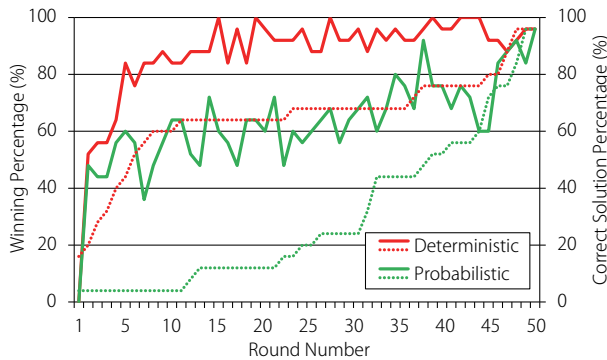


図 2 各ラウンドで得点を得た参加者の割合 (実線) と、そのラウンド以降正しくアルゴリズムを同定し戦略を固定していた参加者の割合 (破線).

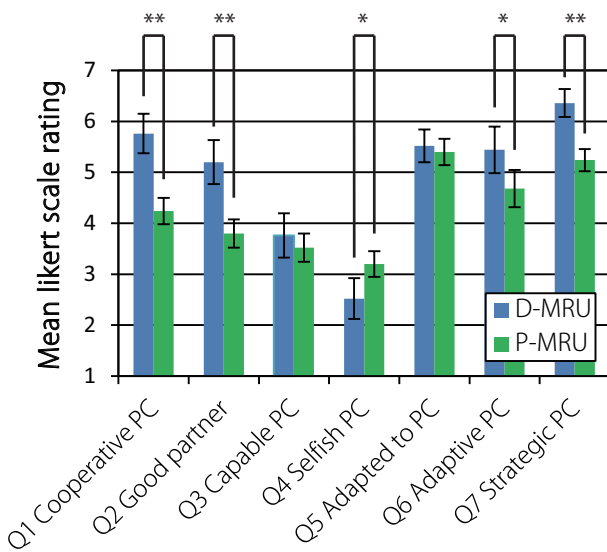


図 3 アンケート結果. エラーバーは標準誤差. ** $p < .01$, * $p < .05$




図 4 実験参加者が報告したコンピュータのアルゴリズム

ラウンドでやっと 80%を越えている。P-MRU 条件の遅い勝率の増加から、MRU アルゴリズムに対して加えられた 10%のノイズがコンピュータのアルゴリズム同定を困難にしたとすることができる。しかし、P-MRU 条件においても勝率は漸次増加していること、このゲームのチャンスレベルの勝率は 16.67%であるのに両条件ともに最初の数ラウンドを除いて 16.67%を越えていることから、何らかの戦略理解がなされたものとみなすことができる。

図 2 の実線は各ラウンドで勝った (コンピュータの選択した記号と参加者の選択した記号が一致した) 参加者の割合である (数値は左縦軸を参照)。図 2 の点線は同一記号戦略を取り始めた参加者の割合、すなわちこのゲームにお

る最適戦略を発見した参加者の割合を示している (数値は右縦軸を参照)。ただし、MRU アルゴリズムを同定しなくても、考えなしに単に同一手を選択し続けるだけでも同一の結果になるため、必ずしも参加者が MRU アルゴリズムを発見したとは限らない。

図 3 にアンケート結果を示す。条件間で評価値の平均値に違いがあるかをマン・ホイットニーの U 検によって検定した結果、Q1 ($U = 144, z = 3.35, p < .01$), Q2 ($U = 177.5, z = 2.66, p < .01$), Q7 ($U = 115.5, z = 4.02, p < .01$) では 1%以下で有意な差が確認された。また、Q4 ($U = 211, z = 2.01, p < .05$), Q6 ($U = 196, z = 2.32, p < .05$) については 5%以下で有意な差が確認された。Q3 ($U = 308.5, z = 0.08, p = .93$), Q5 ($U = 276.5, z = 0.73, p < .47$) では有意な差が確認されなかった。

図 4 は参加者が同定したアルゴリズムの分布である。これは参加者の記述から実験者が本質的なアルゴリズムを抽出することで作成した。D-MRU 条件では 72%の参加者が MRU アルゴリズムを正しく同定しているが P-MRU 条件では 52%の参加者しか同定できなかった。しかし、カイ 2 乗検定の結果、条件間で同定されたアルゴリズムの分布に有意な差は確認できなかった ($\chi^2(4) = 3.41, p = 0.49$)。

4. 考察

本実験は MRU アルゴリズム理解の認知過程を明らかにするための実験である。特に我々は、MRU アルゴリズム理解に決定論バイアスやマルコフバイアスが使われることを予想した。以下では、それらのバイアスが使われたか否かについて議論する。また、MRU アルゴリズムに対するノイズの付加がコンピュータに対する印象や実験参加者自身の態度にどのように影響を与えたかについても考察する。

4.1 帰納的アルゴリズム理解

実験結果は多くの参加者が帰納的にアルゴリズムを理解したことを示している。

図 2 の赤い破線は D-MRU 条件における 60%の参加者 (15 人) が 10 ラウンド以内に最適戦略を発見したことを意味している。この 15 人の参加者のうち 13 人がコンピュータのアルゴリズムを MRU であると答え、一人が戦略なし、一人が同一記号戦略であると答えた。このような参加者の典型的な手を図 5(a) に示す。このタイプの参加者はゲームの最初で統計モデルを構築しそのモデルに従ってコンピュータの戦略を同定したと考えられる。しかしながら、理論的には、相手の戦略を統計に基づいて同定するために無限回の試行を必要とするために、10 ラウンド以内で相手の戦略を同定するためには何らかのバイアスが用いられたと考えられる。ここで用いられたバイアスは決定論バイアスとマルコフ性バイアスであると考えられる。もし、アル



図 5 D-MRU 条件における典型的な振舞いパターン. C: computer, H: human.

ゴリズムが決定論的であると仮定するならば, 参加者は表 1(a) のゼロで埋められた欄の確率について無視することができる. そして最低 3 回の試行でコンピュータのアルゴリズムを同定することができる. また, マルコフ性バイアスがなければ, 参加者は 1 ラウンド前だけでなく, それより以前の履歴も考慮に入れなければならない, アルゴリズム同定のためにさらなる時間が必要となる.

決定論的バイアスは P-MRU 条件のパフォーマンスの悪さを説明することができる. もし, 参加者が単に確率分布を推定していただければ, P-MRU 条件のような混合戦略に対する最適解は, その確率分布に対応した混合戦略をとることである. そのような場合は高々 10% の成績の悪さに留まる. P-MRU 条件の成績が D-MRU 条件よりも 10% 以上悪いということは, 参加者が決定論的バイアスに従ってコンピュータのアルゴリズムを同定しようとしていたにもかかわらず, 予期せぬノイズが混入したために, どのような戦略が同定しきれなかったことを意味する.

50 人の参加者のうち最低得点は 19 であった. これは理論的に導出可能なチャンスレベルの勝率 (単にランダムに記号を選択した場合) である 16.67 よりも高い. これは, ほとんどの参加者が何らかのアルゴリズムを恣意的にコンピュータの戦略に対して帰属していたことを意味する. 実際に, このゲームに対しては MRU アルゴリズム以外のアルゴリズムの帰属も可能である. 例えばある参加者は「コンピュータは単に同じ記号を出し続けていた」と答えた. また別の参加者は「コンピュータは二つの記号を交互に出していた」と答えた. さらに「♠♥♣♦のように同一記号を連続する回数を段階的に増やしていった」という複雑なアルゴリズムを読みとって答えた参加者もいた. MRU アルゴリズムは一つ前の人の手をそのまま模倣するために, 参加者自身の選択によってその振舞いを生成して

いるにも関わらず, そのようなアルゴリズムがコンピュータに実装されていると知られたことは興味深い.

4.2 演繹的アルゴリズム理解

実験結果はまた, 少数の参加者が演繹的にアルゴリズムを理解したことを示している.

D-MRU 条件における 16%(4 人) の参加者と P-MRU 条件における 4%(1 人) の参加者は選択する記号を第一ラウンドで固定し, 50 ラウンド全て同じ記号を選択した (具体例は図 5(c) 参照). しかし, 彼/彼女ら全てがコンピュータのアルゴリズムを MRU であると記述した. 一切の探索をせずにこのようなアルゴリズム理解がなされる理由は彼/彼女らが **トップダウン適応バイアス** を持っていたからにほかならない. すなわち, 教示によってコンピュータが協調的に振舞うと知らされていたために, 「協調的に振舞うコンピュータは人の選択に従順に対応するものだ」という論理的な推論を行い, それを探索によって確かめることなく最後まで信じてゲームを行ったと思われる. 実際に D-MRU 条件でコンピュータは彼/彼女らの仮説を覆す選択を行わなかったため, 彼/彼女らが自身の信念に疑念を挟む余地はなかったものと思われる. このように, 負事例の探索をすることなく, 正事例のみを用いて仮説を検証することは **確認バイアス** として知られる [14]. ただ, 我々の実験設定では, 2-4-6 課題のようなルール発見が目的ではなく高得点を得ることが目的なので, 仮説が覆される事例が現れない限り, 自ら負事例を用いて検証するインセンティブはさらに低い. 確認バイアスがノイズによって破壊されたことは, P-MRU 条件における 3 人の参加者が第一ラウンドから選択する記号を固定し, ゲーム開始直後は同一記号戦略を採用していたにもかかわらず, 2 人の参加者がノイズラウンドが出現した段階で同一記号戦略をとることをやめた

ことから分かる。これは、トップダウン適応バイアスがノイズに対してそれほど強くないことを意味する。

4.3 アルゴリズム同定不能

MRU アルゴリズムは最も理解が容易な適応アルゴリズムとして知られているのにもかかわらず、D-MRU 条件における 2 人の参加者と P-MRU 条件における 3 人の参加者は、50 ラウンドを経てもいかなるアルゴリズムも理解することはなかった（典型的な振舞いは図 5(d) 参照のこと）。インタフェースの履歴領域に表示された視覚刺激はコンピュータの出力が参加者の一つ前の出力に一致していることを示す強いキューになっている。しかし、彼らはそのような刺激をゲーム中にずっと見続けながらアルゴリズムを同定することができなかった。このような参加者の認知機構を調べるためにさらなる実験が必要である。

4.4 コンピュータに対する印象と参加者の態度

アンケート Q1 結果から、MRU アルゴリズムで動作するコンピュータに対しては協力的であると感じる傾向が強いが、10%のノイズを入れることによって、評定が「どちらでもない」に近づき、その傾向が消失することが分かった。また、同様の概念である Q2 の「良いパートナーであった」に対する評定も D-MRU 条件では平均が 5(そう思う)以上であるのに対し、P-MRU 条件では平均が 4(どちらでもない)を下回っている。しかし、コンピュータが参加者に合わせようとしていたかについての印象評定(Q6)の両条件間の平均値の差は Q1, Q2 ほど大きくなく、P-MRU 条件でもある程度合わせようとしていたものと思われる。そのことは、P-MRU 条件の参加者の半数がコンピュータの戦略を MRU アルゴリズムだと理解していたことと整合する。実験参加者自身がコンピュータに合わせようとしていたかどうか(Q5)については条件間で差がなく、ともに平均値は 4(どちらかと言えばそう思う)以上であった。P-MRU 条件で実験参加者がコンピュータに合わせようとしていたのにも関わらず、コンピュータが期待に沿う振舞いをしなかったことが、Q1, Q2 の評定が MRU 条件より大きく低くなることに繋がったものと考えられることができる。

コンピュータに対する印象の中で Q3 の「有能であると思うか」についての評定の平均値だけ両条件では差がなく平均値は 4(どちらでもない)を少し下回る程度であった。このことは、適応的であるかどうかは有能さの印象と関係がないことを意味する。

「自分勝手であったか」についての評定は両条件で差があるものの、P-MRU 条件でも 3(どちらかと言えばそう思わない)を少し上回る程度なので、例え P-MRU 条件の振舞いのように、期待に沿わない行動を生成しても、それほど自分勝手に振舞っている印象を持たないと思われる。自

分勝手に振舞うという印象は自己利益だけを追求するような対象に対して付与されるものなので、自己利益を追求するほどの知性や意図性を感じなかったことが原因だと考えられる。このことは、Q3 の「有能であると思うか」に対する評定値がそれほど高くないことから支持される。

5. おわりに

我々の知る限り、本研究は適応アルゴリズムの認知過程におけるバイアスの存在を示した初めての試みである。理論的なモデルでは、人は帰納的バイアスによってコンピュータの振舞い履歴の特定の部分に焦点を絞り、アルゴリズムを表現するための統計モデルを構築することによってアルゴリズムを理解していると考えられる。我々の実験によって実際にそのような理解がなされていることが示された。今後は統計モデルの構築からアルゴリズムの記号的記述へと至るプロセスについての詳細なモデルを構築する予定である。

参考文献

- [1] Amer, A. and Oommen, B. J.: Lists on Lists: A Framework for Self-organizing Lists in Environments with Locality of Reference, *Proceedings of the 5th International Workshop on Experimental Algorithms*, WEA 2006, pp. 109–120 (2006).
- [2] Arcuri, M., Coon, T., Johnson, J., Manning, A. and van Tilburg, M.: Adaptive menus, (US Patent: 6,121,968) (2000).
- [3] Berger, U.: Fictitious Play in $2 \times N$ Games, *Journal of Economic Theory*, Vol. 120, pp. 139–154. (2005).
- [4] Bigdelou, A., Schwarz, L. and Navab, N.: An adaptive solution for intra-operative gesture-based human-machine interaction, *Proceedings of the 17th International Conference on Intelligent User Interfaces*, pp. 75–84 (2012).
- [5] Byrne, R. W. and Whiten, A.: *Machiavellian Intelligence: Social Expertise and the Evolution of Intellect in Monkeys, Apes, and Humans*, Oxford Science Publications (1988).
- [6] Call, J. and Tomasello, M.: Does the chimpanzee have a theory of mind? 30 years later., *Trends in Cognitive Sciences*, Vol. 12, No. 5, pp. 187–192 (online), DOI: 10.1016/j.tics.2008.02.010 (2008).
- [7] Clegg, B. A., DiGirolamo, G. J. and Keele, S. W.: Sequence learning, *Trends in Cognitive Sciences*, Vol. 2, No. 8, pp. 275–281 (online), DOI: 10.1016/S1364-6613(98)01202-9 (1998).
- [8] Dennett, D. C.: *The Intentional Stance*, Cambridge, Mass, Bradford Books/MIT Press (1987).
- [9] Findlater, L. and McGrenere, J.: A comparison of static, adaptive, and adaptable menus, *Proceedings of the 11th international conference on Intelligent user interfaces*, pp. 89–96 (2004).
- [10] Fudenberg, D. and Levine, D. K.: *The Theory of Learning in Games*, MIT Press, Cambridge, MA (1998).
- [11] Gajos, K. Z., Everitt, K., Tan, D. S., Czerwinski, M. and Weld, D. S.: Predictability and accuracy in adaptive user interfaces, *Proceeding of the 26th annual SIGCHI conference on Human factors in computing systems*, pp.

- 1271–1274 (2008).
- [12] Hampton, A. N., Bossaerts, P. and O’Doherty, J. P.: Neural correlates of mentalizing-related computations during strategic interactions in humans, *Proceedings of the National Academy of Sciences*, Vol. 105, No. 18, pp. 6741–6746 (2008).
- [13] Haverty, L. A., Koedinger, K. R., Klahr, D. and Alibali, M. W.: Solving Inductive Reasoning Problems in Mathematics: Not-so-Trivial Pursuit, *Cognitive Science*, Vol. 24, No. 2, pp. 249–298 (online), DOI: 10.1207/s15516709cog2402.3 (2000).
- [14] Klayman, J. and won Ha, Y.: Confirmation, disconfirmation, and information in hypothesis testing, *Psychological Review*, Vol. 94, No. 2, pp. 211–228 (online), DOI: 10.1037/0033-295X.94.2.211 (1987).
- [15] Lavie, T. and Meyer, J.: Benefits and costs of adaptive user interfaces, *International Journal of Human-Computer Studies*, Vol. 68, pp. 508–524 (2010).
- [16] Lee, D., Choi, J., Kim, J.-H., Noh, S. H., Min, S. L., Cho, Y. and Kim, C. S.: On the existence of a spectrum of policies that subsumes the least recently used (LRU) and least frequently used (LFU) policies, *Proceedings of the 1999 ACM SIGMETRICS international conference on Measurement and modeling of computer systems*, SIGMETRICS ’99, New York, NY, USA, ACM, pp. 134–143 (online), DOI: 10.1145/301453.301487 (1999).
- [17] Nissen, M. and Bullemer, P.: Attentional requirements of learning: Evidence from performance measures, *Cognitive psychology*, Vol. 19, No. 1, pp. 1–32 (1987).
- [18] Oviatt, S., Swindells, C. and Arthur, A.: Implicit user-adaptive system engagement in speech and pen interfaces, *Proceedings of the 26th annual SIGCHI conference on Human factors in computing systems*, pp. 969–978 (online), DOI: 10.1145/1357054.1357204 (2008).
- [19] Schmid, U. and Kitzelmann, E.: Inductive rule learning on the knowledge level, *Cognitive Systems Research*, Vol. 12, No. 3–4, pp. 237–248 (2011).
- [20] Shneiderman, B. and Maes, P.: Direct manipulation vs. interface agents, *Interactions*, Vol. 4, No. 6, pp. 42–61 (online), DOI: 10.1145/267505.267514 (1997).
- [21] Simon, H. A. and Kotovsky, K.: Human acquisition of concepts for sequential patterns, *Psychological Review*, Vol. 70, No. 6, pp. 534–546 (online), DOI: 10.1037/h0043901 (1963).
- [22] Sun, R. and Giles, C.(eds.): *Sequence learning: Paradigms, algorithms, and applications*, Vol. 1828, Springer (2001).
- [23] Sun, R. and Giles, C. L.: Sequence Learning: From Recognition and Prediction to Sequential Decision Making, *IEEE Intelligent Systems*, Vol. 16, No. 4, pp. 67–70 (2001).
- [24] Sutton, R. S. and Barto, A. G.: *Reinforcement Learning: An Introduction*, MIT Press (1998).
- [25] Verguts, T., Maris, E. and Boeck, P. D.: A Dynamic Model for Rule Induction Tasks, *Journal of Mathematical Psychology*, Vol. 46, No. 4, pp. 455–485 (online), DOI: 10.1006/jmps.2001.1400 (2002).
- [26] Winkler, I., Denham, S. L. and Nelken, I.: Modeling the auditory scene: predictive regularity representations and perceptual objects, *Trends in Cognitive Sciences*, Vol. 13, No. 12, pp. 532–540 (online), DOI: 10.1016/j.tics.2009.09.003 (2009).