

なじみ深さ, 知識 ~統計モデルによる推論プロセスの検証~

Familiarity, knowledge

~investigations of inference processes by statistics models~

白砂 大[†], 本田 秀仁[†], 松香 敏彦[‡], 植田 一博[†]
Masaru Shirasuna, Hidehito Honda, Toshihiko Matsuka, Kazuhiro Ueda

[†]東京大学, [‡]千葉大学
The University of Tokyo, Chiba University
m.shirasuna1392@gmail.com

Abstract

The present paper investigated the inference processes of familiarity-based (i.e., familiarity-matching) and knowledge-based inferences, using both behavioral experiment and quantitative modeling. We found that participants tended to use a familiarity-matching heuristic and that not only “familiarity” but also “unfamiliarity” of target objects could be a valid inference cue. We also found that, when making inferences, participants tended to use multiple attributes as inference cues in difficult problems and a single attribute in easy problems (like “Take The Best” strategy). The possibility of revealing new human inference processes and extending human inference models is discussed.

Keywords — Heuristic, Familiarity, Familiarity-matching, Knowledge, Inference processes, Modeling

1. Familiarity を利用したヒューリスティック

ヒューリスティックとは、意思決定の際に短時間で近似解を得るための単純・簡便な推論方略のことである。人間の用いるヒューリスティックに関して近年、主観的な記憶(e.g., recognition, familiarity)に基づく推論方略が提唱され、またその合理性も広く議論されてきた(e.g., Goldstein & Gigerenzer, 2002; Honda, Matsuka & Ueda, 2017)。例えば「人口の多い都市は A 市・B 市のどちらか」という二者択一課題が与えられた際、「選択肢を再認できるか」や「どちらの選択肢の方がなじみ深いか」という点を手がかりとし、人間は再認できた方またはよりなじみのある方の選択肢を選ぶ傾向にある。

このような対象に対するなじみ深さ、すなわち familiarity は、正答を導くうえで特に有用な推論手がかりであるとされる(e.g., Honda et al., 2017)。Familiarity を利用したヒューリスティックとして、Shirasuna, Honda, Matsuka & Ueda (in press)は「familiarity-matching」と呼ばれる新たな推論方略を提唱した。Familiarity-matching とは、二者択一課題

において問題文と選択肢の双方で対象が提示された(e.g., 「X という都市がある国は国 A・国 B のどちらか」)際に「問題文で提示された対象に、より近い familiarity を持つ方の選択肢を選ぶ」とする推論方略をいう。すなわち familiarity-matching では、複数の対象に対する「familiarity の類似性」に基づく推論が行われている。

この familiarity-matching について、Shirasuna et al. (in press)では、実際に二者択一課題において familiarity-matching の選択傾向が見られること、また「attribute substitution」という枠組み(e.g., Kahneman & Frederick, 2005; Honda et al., 2017; 詳細は 3.2 節にて後述)に基づき、特に実験参加者が「難しい」と感じた問題に対して familiarity-matching が用いられやすいことをそれぞれ示している。しかしながら、参加者が単に正答を知っていたり(i.e., 都市 X は国 A にある)、具体的な知識や情報を利用して解いたり(i.e., 都市 X は英語圏に属するだろう)した可能性は考慮されていない。そのため、familiarity-matching に関する推論プロセスについて、より詳細に検証する必要があると考えられる。

本研究では、familiarity-matching を利用したと考えられる推論モデル、および知識を利用したと考えられる推論モデルをそれぞれ想定し、各モデルが実際の選択をどの程度予測するか、また「知識を利用した」と考えられるケースを排除したうえでも familiarity-matching が実際の選択を予測しうるかについて、行動実験を通して検証を行った。

2. 方法

2.1 実験参加者

私立大学の学部生 26 名(うち女性は 11 名)が参加した。年齢は、平均 21.15、標準偏差 1.43 であった。

2.2 課題および手続き

参加者は、下記の「二者択一課題」「familiarity 測定課題」および「知識課題」の3つをこの順に回答した。課題はすべて PC 画面上で行われた。所要時間は、教示等も含めて1時間程度であった。

・**二者択一課題**: 「X という都市がある国はどちらか国 A 国 B」という二者択一形式の問題 1 問ずつ画面上に提示され、参加者はどちらか一方の選択肢を選ぶことを求められた。選択後、参加者は「その問題をどの程度難しく感じたか」という主観的困難度(以下「Difficulty」; 後述の attribute substitution の議論に基づき測定)について、「0(非常に易しい)-100(非常に難しい)」の VAS (Visual analog scale)で回答することを求められた。Difficulty に回答したのち、参加者が画面下方の「次へ」ボタンを押すと、次の問題へ移行した。課題は全部で 120 問あり、60 問経過時点で休憩が設けられた。課題開始前と休憩後には、それぞれ 5 問の練習課題も挿入された。なお、課題は Shirasuna et al. (in press)に基づいて作成された。

・**familiarity 測定課題**: 二者択一課題で使用された都市(120 都市)または国(20 か国)が画面上に 1 つずつ提示され、参加者はその都市/国が自身にとってどの程度なじみがあるかを、「0(全くなじみがない)-100(非常になじみがある)」の VAS により回答した。課題は 140 問(120 都市+20 か国)あり、70 問経過時点で休憩が設けられた。また、課題開始前と休憩後にはそれぞれ 4 問の練習試行も導入された。

・**知識課題**: 二者択一課題で使用された都市または国が画面上に 1 つずつ提示された。参加者は、都市については、その都市に合致すると思う「国」「地域」「言語圏」および「宗教」を、国については、その国に合致すると思う「地域」「言語圏」および「宗教」を、それぞれ択一形式で回答した。分からない場合は「分からない」という選択肢を選ぶよう求められた。課題は 140 問(120 都市+20 か国)あり、50 問、100 問経過時点でそれぞれ休憩が設けられた。また、課題開始前と各休憩後にはそれぞれ 4 問の練習試行も導入された。

3. 結果および考察

3.1 familiarity の利用

以下、問題文で提示された対象に対する familiarity を $Fam(Q)$ 、選択肢で提示された対象に対する familiarity を $Fam(A)$ 、 $Fam(B)$ とそれぞれ表記する。

3.1.1 familiarity-matching

まず、二者択一課題において、familiarity-matching による予測と実際の選択パターンとがどの程度一致していたかという「予測の一致率」を、参加者ごとに算出した。Familiarity-matching による予測とは、「 $Fam(A)$ と $Fam(B)$ のうち、より $Fam(Q)$ に近い方の選択肢が選ばれる」ことである¹。例えば、 $Fam(Q) = 60$ 、 $Fam(A) = 75$ 、 $Fam(B) = 20$ である場合、 $Fam(A)$ の方が $Fam(B)$ よりも $Fam(Q)$ に近いため、familiarity-matching では選択肢 A が選ばれる。すなわち familiarity-matching の推論モデル D_{FM} は、下記の式

$$D_{FM} = |Fam(Q) - Fam(A)| - |Fam(Q) - Fam(B)|$$

により定義され、 $D_{FM} < 0$ のときは選択肢 A が選ばれることを、 $D_{FM} > 0$ のときは選択肢 B が選ばれることを、それぞれ予測する。

この予測が、実際に各参加者が行った選択(全 120 問)とどの程度一致しているかを算出した(図 1 上; 横軸は参加者を、縦軸は予測の一致率を、それぞれ示す)。結果として、参加者 26 名における予測の一致率の平均は 86.5%(図 1 上点線)であり、また予測の一致率がチャンスレベルの 50%(図 1 上赤線)を上回った参加者は 26 名中 24 名であった。この結果は参加者の多くが familiarity-matching に従っていたことを示唆するものであり、Shirasuna et al. (in press)の結果にも一致していた。

Familiarity-matching は、「familiarity の類似性」すなわち「 $Fam(Q)$ と、 $Fam(A)$ または $Fam(B)$ との距離」に基づく推論であり、先行研究のような「選択肢間の比較」(e.g., 「人口の多い都市は A 市・B 市のどちらか」という形式の人口推定課題; Goldstein & Gigerenzer, 2002)とは異なる形式の推論であるといえる。 $Fam(Q)$ と、 $Fam(A)$ または $Fam(B)$ との距離が選択の根拠にな

$Fam(B)$ となるものを除外して分析を行った。

¹ 「familiarity-matching を利用できる」ケースに焦点を当てたため、ここでは $|Fam(Q) - Fam(A)| = |Fam(Q) -$

るという点で, familiarity-matching では, 問題文で提示された対象の存在が, Fam(Q)の値の高低によらず最終的な選択に直接関与していると考えられる。そのため familiarity-matching の特色として, 「unfamiliarity」な側面の有用性, すなわち問題文で提示された対象が familiar であっても unfamiliar であってもそれが有用な推論手がかりとして働かうことが挙げられる。

3.1.2 Fam(Q)の閾値に基づく方略との比較

ただし, 「複数の対象に対する familiarity をマッチさせる」という点では, 「Fam(Q)の閾値」に基づく推論, 具体的には「Fam(Q)が一定の閾値以上(以下)であった場合, より familiar(unfamiliar)な選択肢を選ぶ」という方略も想定される。この方略の場合, familiarity-matching とは異なる選択をする可能性がある。例えば Fam(Q)=40, Fam(A)=60, Fam(B)=10 で, Fam(Q)の閾値が 50 であったとする。このとき, Fam(A)の方が Fam(B)よりも Fam(Q)に近いので, familiarity-matching では選択肢 A が選ばれる。一方で Fam(Q)は閾値よりも小さいため, 上述の推論方略ではより familiarity の低い選択肢 B が選ばれる。

Fam(Q)の閾値に基づくこの方略を「Thresholded-familiarity-matching (以下「TFM」と表記)とすると, その推論モデル D_{TFM} は, 下記の式

$$D_{TFM} = \begin{cases} \cdot \max(Fam(A), Fam(B)) & (\text{if } Fam(Q) > \text{threshold}) \\ \cdot \min(Fam(A), Fam(B)) & (\text{if } Fam(Q) < \text{threshold}) \end{cases}$$

により定義され, $D_{TFM} = Fam(A)$ なら選択肢 A が選ばれることを, $D_{TFM} = Fam(B)$ なら選択肢 B が選ばれることを, それぞれ予測する²。以下の分析では, この threshold を「その参加者内における Fam(Q)の中央値」とした。

しかしこの TFM は, Fam(Q)が最終的な選択に直接的には影響しないという点で familiarity-matching とは異なると考えられる。上式からも分かるように, TFM は主に「選択肢間の比較」すなわち「Fam(A)と Fam(B)のどちらがより大きい(小さい)か」という形の推論であり, 問題文で提示された対象は「『より familiar な選択肢』と『より unfamiliar な選択肢』の





図 1 D_{FM} (上)と D_{TFM} (下)の, それぞれによる予測の一致率。いずれのグラフも, 横軸は参加者, 縦軸は予測の一致率, 点線は一致率の平均, それに赤線はチャンスレベルの 50%を, それぞれ示す。

どちらを選ぶか」という方針の決定にしか関与していない。そのため, 問題文で提示された対象の familiarity(unfamiliarity)が持つ推論手がかりとしての有用性は, 比較的低いと考えられる。

Familiarity-matching の方が TFM よりも多く利用されていれば, 人間が「unfamiliarity」な側面を有用な手がかりとして用いている可能性がより支持されるといえるだろう。そこで, 先と同様の形で, TFM による予測(i.e., D_{TFM})の一致率を参加者ごとに算出した(図 1 下; 横軸は参加者を, 縦軸は予測の一致率を, それぞれ示す)。結果として, 参加者 26 名における予測の一致率の平均は 46.8%(図 1 下点線)であり, また予測の一致率がチャンスレベルの 50%(図 1 下赤線)を上回ったのは 26 名中 9 名のみであった。よって, 参加者の多くが「選択肢間の比較」よりも「familiarity の類似性」に基づく推論(i.e., familiarity-matching)をしていたことが示された。このことから, 人間が familiar な側面だけでなく unfamiliar な側面も推論手がかりに利用している可能性が, より強く示唆されたといえる。

² ここでは, 「Fam(Q) = threshold (i.e., 参加者内の中央値) または 「Fam(A) = Fam(B)」となるケースを除外して分析を行った。

3.2 知識の利用

観測データ上は familiarity-matching に従った選択をしていても、参加者が本当に familiarity に基づいて推論していたとは限らない。実際には、参加者は単に正答を知っていたり、何かしらの知識や情報を用いたりしていた可能性もある。

また、先行研究では「attribute substitution」という枠組みが議論されている(e.g., Kahneman & Frederick, 2005; Honda et al., 2017)。Attribute substitution とは、問題に答えることが難しいとき、人間はその問題を、もっともらしい解を導き出してくれそうな属性に置き換えて推論するという考え方である。一般に、Difficulty の高い問題では主にヒューリスティックが利用されやすく、Difficulty の低い問題では主に知識が利用されやすいとされている(Honda et al., 2017)。

以上をふまえて次に、参加者が回答した問題を Difficulty の高い問題と低い問題とに分けた。そのうえで、「具体的な知識を利用した」ことを想定した複数の推論モデルを当てはめ、各モデルが実際の推論パターンをどの程度予測するかを検証した。以下では、二者択一課題で得られた Difficulty の値がその参加者内の中央値よりも高かった問題を「Difficult Problem」、低かった問題を「Easy Problem」とそれぞれ定義する³。

3.2.1 TTB (Take The Best)

TTB (Take The Best; e.g., Goldstein & Gigerenzer, 2002)とは、意思決定者が、選択肢に関するすべての属性を考慮するのではなく、ある属性を一方の選択肢が持ち他方の選択肢が持たないという場合に、その時点でその属性を持つ方の選択肢を選ぶとするヒューリスティックのことである。本分析では、知識課題で得られた回答を用いて、TTBに基づく推論モデル D_{TTB} を下記の式により定義する。

$$D_{TTB} = \begin{cases} \cdot M(\text{CouA}) - M(\text{CouB}) & (\text{if } M(\text{CouA}) - M(\text{CouB}) \neq 0) \\ \cdot w1 * M(\text{RegA}) + w2 * M(\text{LanA}) + w3 * M(\text{RelA}) \\ \quad - w1 * M(\text{RegB}) - w2 * M(\text{LanB}) - w3 * M(\text{RelB}) & (\text{if } M(\text{CouA}) - M(\text{CouB}) = 0) \end{cases}$$

³ Difficult Problem に該当した問題は 1435 問、Easy Problem に該当した問題は 1505 問であった。Difficulty の値がその参加者内の中央値と等しかった問題は分析から除外

ここで、「Cou」「Reg」「Lan」「Rel」は、それぞれ問題文で提示された対象(i.e., 都市)に対する「国」「地域」「言語圏」「宗教」の回答を示し、 $w1$, $w2$, $w3$ は各属性に対する重みづけ係数である。また「 $M(\text{Attribute})$ 」は、括弧内の属性に関して「問題文で提示された対象に対する回答」と「選択肢 A または B に対する回答」とが一致していれば 1 を、一致しなければ 0 をとる(e.g., 「国」での回答が、問題文で提示された対象と選択肢 A とで一致していれば $M(\text{CouA}) = 1$ 、一致していなければ $M(\text{CouA}) = 0$)。このモデルでは、 $D_{TTB} > 0$ なら選択肢 A が選ばれることを、 $D_{TTB} < 0$ なら選択肢 B が選ばれることを、それぞれ予測する。

まず、各属性への重みづけ係数の値を 1 または 0 とし、 D_{TTB} による下記 4 つの推論方略を想定した。

- TTB Country: 「国」で回答した国名が 2 選択肢内にあった場合、その国を選ぶ(i.e., $M(\text{CouA}) - M(\text{CouB}) \neq 0$ のケース)。
- TTB Region: 「TTB Country」を利用できなかった(i.e., 「国」での回答が、2 選択肢内になかった、または「分からない」であった)が、「地域」での回答が問題文で提示された対象と一方の選択肢とで一致(「分からない」を除く)していた場合、その選択肢を選ぶ(i.e., $w1 = 1, w2 = w3 = 0$ のケース)。
- TTB Language: 「TTB Country」を利用できなかったが、「言語圏」での回答が問題文で提示された対象と一方の選択肢とで一致(「分からない」を除く)していた場合、その選択肢を選ぶ(i.e., $w2 = 1, w1 = w3 = 0$ のケース)。
- TTB Religion: 「TTB Country」を利用できなかったが、「宗教」での回答が問題文で提示された対象と一方の選択肢とで一致(「分からない」を除く)していた場合、その選択肢を選ぶ(i.e., $w3 = 1, w1 = w2 = 0$ のケース)。

これらのモデルを、Difficult Problem, Easy Problem ごとに各参加者に対して当てはめ、実際の選択をどの程度予測できたかを示したのが図 2(「TTB Country」から「TTB Religion」まで)である。まず、Difficult Problem と Easy Problem とで顕著な違いが見られた

したため、Difficult Problem と Easy Problem の合計は全 3120 問(=二者択一課題 120 問×参加者 26 名)には一致しない。




図 2 知識を利用した場合の各モデルにおける、予測の一致率の平均(Difficult Problem は $N=21$, Easy Problem は $N=26$)。黒色のバーは Difficult Problem に、灰色のバーは Easy Problem に、それぞれ該当した問題であり、グラフ中の数値は予測の一致率の平均値を、エラーバーは標準偏差を、それぞれ示す。

のは TTB Country モデルであった。TTB Country モデルは、参加者が「選択肢を見なくても、問題文で提示された対象(都市名)を見ただけで正答(その都市が該当する国)が分かった」ケースで適用されやすいと考えられるため、Difficult Problem の多くは「すぐに正答が分からなかった問題」であり、Easy Problem の多くは「すぐに正答が分かった問題」であったといえる。

また、Difficult Problem と Easy Problem のいずれにおいても TTB Region モデル、TTB Religion モデル、TTB Language モデルの順に実際の選択を予測できていたことから、「国」以外のどれか一つの属性に注目する(i.e., TTB 的な推論を行う)場合、参加者は「地域」「宗教」「言語圏」という 3 属性をこの順に重視していたことが示唆される。ただし、これら 3 属性のモデルによる予測の一致率を TTB Country モデルによる予測の一致率と比較した際、Difficult Problem では TTB Country と同程度であったのに対し、Easy Problem では TTB Country の方が顕著に高かった。このことから参加者は、比較的「難しい」と感じた問題では「国」以外の属性も考慮して推論をした一方、比較的「易しい」と感じた問題では「国」以外の属性を考慮しない TTB 的な推論をしたことが示唆される⁴。

3.2.2 Knowledge-matching

続いて、意思決定者が、(正答(国)が分からないとき

に)どれか一つの属性に注目するのではなく 3 属性すべてを考慮に入れるという、下記の「knowledge-matching モデル」を想定する⁵。

- ① 「国」で回答した国名が 2 選択肢内にあった場合、その国を選ぶ(i.e., TTB Country モデル)。
- ② ①を満たさない場合、2 選択肢に対する属性(「地域」「言語圏」「宗教」)の回答が、問題文で提示された対象に対する属性とより多く一致(「分からない」を除く)している方を選ぶ。

すなわちこの knowledge-matching は、 D_{TTB} における $w_1 = w_2 = w_3 = 1$ のケースにあたる。また、①または②を満たした場合を「知識を利用できた」ケース、①も②も満たさなかった場合を「知識を利用できなかった」ケースと定義した。先と同様に、これを Difficult Problem, Easy Problem ごとに各参加者に対して当てはめ、実際の選択をどの程度予測できたかを算出した(図 2; 「Knowledge-matching」)。結果より、Difficult Problem, Easy Problem のいずれにおいても高い一致率となったことから、参加者は、具体的な知識を利用できる状況では何かしらの知識を利用する傾向にあったことが示された。特に Difficult Problem においては、先の 4 つの TTB モデルによる予測の一致率と比べて knowledge-matching モデルによる予測の一致率が

⁴ これら 4 つの推論モデルおよび後述の knowledge-matching モデルにおいては、「何かしらの具体的な知識を利用できた」ケースに絞って分析を行うため、「知識を利用できなかった(後述の knowledge-matching モデルにおいて①にも②にも該当しなかった)」ケースは除外した。これにより、分析対象となった参加者の数は、Difficult Problem で 21 名(5 名除外)、Easy Problem で 26 名(除外者なし)となった。また全体の中で「知識を利用できた(後述の knowledge-

matching モデルにおいて①または②に該当した) ケースは、Difficult Problem で 146 問(平均 6.95 問、標準偏差 6.24)、Easy Problem で 803 問(平均 30.9 問、標準偏差 12.4)であった。

⁵ ただし、そもそも「知識を利用できた」ケースは全体として多くなかったため(脚注 4 参照)、参加者は、この二者択一課題において具体的な知識や情報をあまり使わずに推論を行っていたことも考えられる。

大きく上昇していることから、参加者は、その問題を難しく感じたときには様々な属性を総合的に考慮していた、すなわち「複数ある属性がどの程度一致しているか」という観点から推論していた可能性が示唆される。

続いて、この knowledge-matching モデルにおいて、「国」以外の 3 属性に対する重みづけを変化させた。具体的には、本分析では TTB Region, TTB Language, TTB Religion それぞれにおける予測の一致率の平均値を D_{TTB} の w_1 , w_2 , w_3 にそれぞれ代入し(i.e., Difficult Problem では $w_1 = 0.352$, $w_2 = 0.121$, $w_3 = 0.186$, Easy Problem では $w_1 = 0.106$, $w_2 = 0.034$, $w_3 = 0.055$ として)、同様の分析を行った(図 2; 「Knowledge-matching (weighted)」)。しかし、重みづけありの予測の一致率は重みづけなしの予測の一致率とほぼ等しかった。このことは、複数の属性に関する一致度に注目する(i.e., TTB 的な推論を行わない)場合、参加者は特定の属性を重視または軽視せず、どの属性も同程度に重視していたことを示唆する結果といえる。

3.2.3 「知識を利用できない」状況での familiarity-matching

最後に、「知識を利用できなかった」ケースにおいて familiarity-matching がどの程度利用されていたかを検証した。先に述べたように、familiarity-matching に従った推論パターンが観測されたとしても、実際には参加者は、familiarity ではなく知識に基づく推論をしていた可能性がある。そこで、knowledge-matching モデルにおける①または②に該当しなかったケースに絞って、familiarity-matching による予測(i.e., D_{FM})の一致率を参加者ごとに算出した(図 3)。結果として、一致率の平均は 87.4%であり、一致率がチャンスレベルの




図 3 「知識を利用できなかった」ケースにおける、 D_{FM} による予測の一致率。横軸は参加者、縦軸は予測の一致率、点線は一致率の平均、それに赤線はチャンスレベルの 50% を、それぞれ示す。

50%を上回った参加者は 26 名中 24 名であった。「知識を利用できた」とされる状況を排除してもなお familiarity-matching により多くの選択パターンを予測できたことから、参加者の多くが二者択一課題において familiarity-matching に従った推論をしていたことが、より強く示唆されたといえるだろう。

4. 総合考察

本研究では、二者択一課題で問題文と選択肢の双方で対象が提示された際に、人間が familiarity を利用した場合、および知識や情報を利用した場合におけるそれぞれの推論について、そのプロセスをモデル化することで比較・検証した。

まず、familiarity-matching の推論モデルに関して、参加者の選択パターンをよく予測できたことから、人間は推論の際に familiarity-matching を利用しやすい可能性が示された。さらに、「familiarity の類似性」に基づく推論モデル(i.e., D_{FM})の方が、「Fam(Q)の閾値」に基づく推論モデル(i.e., D_{TFM})よりも予測の一致率が高かったことから、問題文で提示される対象が familiar であることだけでなく unfamiliar であることも、推論に直接影響を与える有用な手がかりとなることが示唆された。

次に、知識を利用した推論モデルに関して、Difficulty が高い問題では knowledge-matching モデルが推論パターンをよく予測できたことから、問題を「難しい」と感じた際に人間は「複数の属性に関する一致度」に基づいて推論していることが、一方 Difficulty の低い問題では TTB Country モデルが推論パターンをよく予測できたことから、問題を「易しい」と感じた際に人間は TTB 的な方略に従って推論していることが、それぞれ示唆された。さらに、「知識を利用できない」と考えられる状況においてもなお familiarity-matching モデルが多くの推論パターンを予測できたことから、知識に基づく回答によって familiarity-matching に従った推論パターンが観察されたわけではないことも示唆された。

本研究は、選択肢で提示される対象だけでなく問題文で提示される対象にも注目したという点で特色があるといえる。問題文で対象が提示される二者択一課題の場合、参加者は選択肢を見ずに問題文を読むだけで正答が分かる場合もあり、「選択肢を見た際にどう推論するか」だけでなく「問題文を読んだだけで正答が分かるか」という 2 つのステップを含む推論モデルを想定

できる。また, familiarity-matching が「familiarity の類似性」に基づく推論方略であることから, 3.1 節でも分析したように, 対象に対する familiar な側面だけでなく, 従来は有用とされていなかった unfamiliar な側面も, 有用な推論手がかりとなりうる。本研究は, 上記 2 つの特徴を持つために, 比較・検証可能な人間の推論モデルを拡張すること, および「よく知らない」場合でも時に合理的推論を行えるという先行研究の知見(e.g., Less is more effect; Goldstein & Gigerenzer, 2002)を拡張することに, それぞれ貢献していると考えられる。

本分析では, モデルが実際の選択をどの程度予測するかという予測の一致率から, 人間の推論プロセスを検証した。今後は, 実験参加者数を増やしたうえで, 各モデルの精度(e.g., Honda et al., 2017; Pachur & Aebi-Forrer, 2013)および Bayesian model weight によるモデル選択の証拠の強さ(e.g., Honda et al., 2017; Kass & Raftery, 1995)などにに基づき, 推論プロセスについてより詳細に検証する必要があるだろう。

謝辞

本研究は, 科学研究費補助金(基盤研究(A), 16H01725; 基盤研究(B), 25280049, 若手研究(B), 16K16070; 新学術領域, 16H06569; 基盤研究(B), 16H02835)からの助成を受けて実施された。また, 福田玄明氏(東京大学)から貴重なコメントを頂戴した。ここに謝意を記す。

参考文献

- Goldstein, D. G., & Gigerenzer, G. (2002). Models of ecological rationality: The recognition heuristic. *Psychological Review*, *109*(1), 75–90. <https://doi.org/10.1037//0033-295X.109.1.75>
- Honda, H., Matsuka, T., & Ueda, K. (2017). Memory-based simple heuristics as attribute substitution: Competitive tests of binary choice inference models. *Cognitive Science*, *41*(S5), 1093-1118. doi: 10.1111/cogs.12395
- Kahneman, D., & Frederick, S. (2005). A model of heuristic judgment. In K. J. Holyoak & R. G. Morrison (Eds.), *Cambridge handbook of thinking and reasoning* (pp. 267–293). New York: Cambridge University Press
- Kass, R. E., & Raftery, A. E. (1995). Bayes Factors. *Journal of the American Statistical Association*, *90*(430), 773–795.
- Pachur, T., & Aebi-Forrer, E. (2013). Selection of Decision Strategies After Conscious and Unconscious Thought. *The Journal of Behavioral Decision Making*, *26*(5), 477-488. doi:10.1002/bdm.1780

Shirasuna, M., Honda, H., Matsuka, T., & Ueda, K. (in press). Familiarity-matching in decision making: Experimental studies on cognitive processes and analyses of its ecological rationality. *Proceedings of the 39th Annual Conference of the Cognitive Science Society*.