



しがだい資料展示コーナー企画展

AIのキモチ

2026 年
7.13 [Mon.]
↓
12.23 [Wed.]


>> 第1期 ふるまいを観察する

7.13 [Mon.] … 9.30 [Wed.]

>> 第2期 身体と内部をめぐって

10.5 [Mon.] … 12.23 [Wed.]

「What kind of guy is AI?」



AIのキモチ

2026年7月13日（月）～12月23日（水）

第1期≫ ふるまいを観察する 会期：7月13日（月）～9月30日（水）

AIを対話相手、エージェント、シリコンサンプルとして利用することを想定して、AIの回答を計量心理学的な手法で分析することで、「AIがどんな奴なのか」に迫る。

第2期≫ 身体と内部をめぐって 会期：10月5日（月）～12月23日（水）

AIの内部表現や意味空間の可視化を通じて、symbol grounding問題、「身体を持たない知性とはなにか」という問いに迫る。

ごあいさつ

AI(人工知能)とともに生きる社会は、もはやSFの世界ではありません。

私たちは日々AIと対話し、調べものをし、文章を書き、アイデアを得て、ときには悩みを打ち明けることもあります。

そのやりとりの中で、まるで相手に心があるかのように感じる瞬間はないでしょうか。

では、AIはどのように言葉を理解し、どのように世界を見ているのでしょうか。

それは本当に「考えている」と言えるのでしょうか。

人間と似ているところ、そして決定的に違うところはどこにあるのでしょうか。

本展では、ブラックボックスになりがちなAIの思考や判断のしくみに、多様な角度から迫ってみようと思います。

AIの内側をのぞくことは、同時に「心とは何か」「人間とは何か」という問いに向き合うことでもあります。

AIをめぐる問いは、遠い未来の話ではありません。

いまを生きる私たちの問題として、いっしょに考えてみませんか。

2026年7月


監修：

奥村 太一（オクムラ タイチ）

データサイエンス学部准教授/心理統計学、テスト理論

南條 浩輝（ナンジョウ ヒロアキ）

データサイエンス学部教授/情報学、知能情報学



文・奥村 太一

#14 後記

小学生のころ、『特捜ウインスペクター』というヒーロー番組に夢中になっていました。警視庁の特別警察隊で、人間の隊長をバイクルとウォルターという二体のロボットが支え、さらにマドックスという人工知能システムが事件の背景を分析する。科学技術が犯罪に使われる時代に、人間とロボットとAIが力を合わせて街を守るという設定は、当時の私にはとても新鮮でした。

とりわけ惹かれたのは、ロボットたちがただの人命救助マシンではなかったことです。バイクルは感情の起伏が大きく、おっちょこちょいで人なつこい。ウォルターは冷静沈着で礼儀正しい一方、少し融通が利かない。二体には、それぞれはつきりした「性格」がありました。電子部品でできた存在が、人間のように話し、考え、善悪を判断し、喜んだり悲しんだりしているように見える。その不思議さは、ずっと私の中に残っていたのだと思います。

2022年にChatGPTが登場したとき、その感覚が思いがけずよみがえりました。当時の回答には間違いも多く、万能とはほど遠いものでした。それでも、こちらの問いかけに対して自然な言葉が返ってくるだけで、こんなにも「相手がいる」と感じてしまうのかと驚き

ました。もちろん、AIが人間と同じように考えたり、感じたり、意図を持ったりしているわけではありません。それでも、言葉を通じて、命のないものに「人間らしさ」が立ち上がってくる。その不思議さが、この展示を企画する出発点の一つになりました。

第一期の展示では、AIの「賢さ」そのものではなく、AIの応答からどのような人柄や価値観が読み取れるのかを調べました。性格検査や世論調査の質問をAIに投げかけ、人間の回答と比べてみると、AIの回答は人間の平均から大きく外れてはいませんでした。人間の回答傾向を直接教え込んだわけではないにもかかわらず、個々の質問への応答を積み上げると、人間に近いプロフィールが現れるのです。これは率直に言って、大きな驚きでした。

一方で、平均的な日本人とは少し異なる「AIらしさ」も見えてきました。そこには、大量の言葉のデータから人間らしい応答を学んできたことに加え、人間にとって役に立ち、正直で、害を与えないように調整されてきたことの影響もあるのだと思います。AIは自然に生まれた存在ではなく、人間社会の中で作られ、評価され、意味づけられてきた存在です。その応答には、開発者や企業だけでなく、それを受

け入れる社会の価値観も少しずつ反映されています。

今回の展示を通じて、AIが人間にどれだけ近い答えを返すのかを見るだけでは不十分だと感じました。むしろ重要なのは、その答えの奥で、AIが言葉や感情をどのようにとらえているのかを調べることです。AIは人間らしい言葉を返しますが、身体を持たず、経験を通じて世界を知っているわけでもありません。理解することを「腑に落ちる」「腹落ちする」と言ったり、怒ることを「腹を立てる」「頭にくる」と言ったりするように、人間にとって知性や感情は、身体の反応や生活経験と深く結びついています。それでは、身体を持たないAIの内部では、世界がどのようにとらえられているのでしょうか。表面上は似た言葉を返していても、その奥にある整理のされ方は人間とは異なるのでしょうか。AIの中での意味の表され方を探ることは、AIの理解にとどまらず、私たち人間について考える手がかりにもなるのではないかと思います。


#13 AI の中にある emoji の感情地図

心理学の研究では、emoji が人間にとってどのような感情を表すのか調べられてきました。Kutsuzawa らの研究¹⁾では、74 種類の顔を表す emoji の画像を人間の参加者に見せて、「感情価」(valence: 快・不快の程度)と「覚醒度」(arousal: 感情の強さ)をそれぞれ 9 点満点で評価するよう求めました。感情価と覚醒度の 2 つの軸は、人間のさまざまな感情を整理するときによく用いられます。


①の図が Kutsuzawa らが報告している、人間が見た emoji の「感情地図」です。横軸を感情価、縦軸を覚醒度として、emoji は U 字型に分布しているという結果が得られています。すなわち、人間の認識では、快・不快がはっきりしている emoji ほど強い感情が感じられる一方、中立的な emoji では弱い感情しか感じられないという傾向が見られました。

今回の展示では、これと似た「感情の地図」が AI の認識においても確認できるかを調べました。ただし、AI に「この emoji はどれくらい楽しそうですか」とか「どれくらい感情を強く感じていますか」などと直接たずねたわけではありません。先ほど説明した AI の埋め込みモデルに emoji の Unicode を入力し、それぞれを数値ベクトル(数値の集まり)に変換しました²⁾。同じように、「嬉しい」「悲しい」といった感情語についてもベクトル化しました³⁾。そして、emoji の埋め込みと感情語の埋め込みを、**正準相関分析**という手法で対応づけました。これは、「emoji の並び方」と「感情語の並び方」のように 2 種類のデータの間に共通して現れる軸を探す方法です。ここから得られた 2 つの軸で感情地図を描いたのが②の図です⁴⁾。

AI の埋め込み空間から得られた emoji の分布は、人間が感情価と覚醒度を直接評価して得られた結果とよく似た形を示しました。また、笑顔の emoji は「嬉しい」や「喜び」といったポジティブな感情語の近くに、怒り顔や泣き顔の emoji は「怒り」や「哀しみ」といったネガティブな感情語の近くに配置されました。また、強い感情を表す emoji と穏やかな感情を表す emoji は異なる場所に配置される傾向も見られました。AI の内部でも、emoji は感情と関連付けられ、人間とよく似た意味が付与されているようです。



① 人が見た emoji の感情地図 (Kutsuzawa ら 2022 の Figure1)



② AI の見た emoji の感情地図

- 1) Kutsuzawa, G., Umemura, H., Eto, K., & Kobayashi, Y. (2022). Classification of 74 facial emoji's emotional states on the valencearousal axes. Scientific Reports, 12(1): 398. DOI: 10.1038/s41598-021-04357-7
- 2) ここでは、OpenAI の埋め込みモデル text-embedding-3-large を用いて、emoji と感情語を 3,072 次元のベクトルに変換した。
- 3) 感情語は生成 AI によって類義語を作成し、それらの埋め込みを平均したものをを用いている。
- 4) Kutsuzawa らの研究に合わせ、図示には Twemoji 画像を用いている。

#1 AI と生きる時代が来た

AI¹⁾ は、もはや一部の専門家だけが使う特別な技術ではありません。スマートフォンで文字を打つと候補の言葉が表示されたり、動画サイトで自分の好みに合いそうな動画がおすすめされたり、写真に写った人の顔やペットを見分ける機能など、AI はすでに私たちの身近なところで使われています。


その中でも近年注目されているのが、人間の指示に合わせて文章や画像、音声などを新しく作り出す「生成 AI」です。2022 年 11 月に発表された対話型 AI「ChatGPT」は、まるで人間と会話しているかのような自然なやり取りができることで大きな話題を呼びました。それから 4 年が経とうとする今、生成 AI の回答の正確さは飛躍的に高まり、大学入試や資格試験のような難しい問題でも難く解けるようになりました²⁾。

日本では、生成 AI を使ったことがある人はまだ全体の 3 割弱にとどまっていますが³⁾、若い世代では利用が急速に広がっています。特に 10 代後半から 20 代にかけては、勉強や課題、ちょっとした疑問の解決に AI を使うことが珍しくなくなってきました。

興味深いのは、生成 AI の役割が単なる「便利な道具」ととどまらないことです。若い世代を中心に、人々は AI に正確な答えだけでなく、考えるきっかけや別の見方を求めたり、ときには個人的な悩みの相談相手のような役割も求めています⁴⁾。私たちが投げかける言葉を受け取り、それにふさわしい応答を返すことで、まるで相手がいるかのような感覚が生まれているのです。

Q15 以下の事柄に対して生成AIをどの程度信頼しているか、回答をしてください。

人間関係・人付き合いのアドバイス



内閣府消費者委員会事務局「生成 AI 利用者の利用実態に関するアンケート調査（速報）」より、人間関係・人付き合いのアドバイスに対して生成 AI をどの程度信頼しているか、回答を求めた結果（男女・年代別）


- 1) AI ... Artificial Intelligence（人工知能）の略。人間が行うような知的な作業を担えるようになったコンピュータやその機能のことをいう。本展示では主に生成 AI を指す。
- 2) 日経速報ニュースアーカイブ「OpenAI と Google、東大理 3「首席合格」数学は満点 得意科目に違い」（2026 年 4 月 27 日）
- 3) 総務省「令和 7 年版 情報通信白書」（2025 年 7 月 8 日）
- 4) 内閣府消費者委員会事務局「生成 AI 利用者の利用実態に関するアンケート調査（速報）」（2026 年 3 月 31 日）

#2 AIはどうやって対話しているか

言葉を通じて人間と対話をする生成AI(対話型AI)は、どのような仕組みで動いているのでしょうか。

対話型AIの中心には、**大規模言語モデル**と呼ばれる技術があります。これは、文章のあとにどんな言葉が続くかを予測する仕組みのことです。大規模言語モデルは、これまでに人間が作った大量の文章を読み込むことで、言葉の使われ方を学習しています。文脈を読み取りながら、次に続きそうな言葉の候補を選び続けることで、文章が完成します。

① 次に続きそうな言葉を予測し、ひとつ選ぶ



② これを繰り返すと文章が完成する

今日はとても暑いです。水分をこまめに取りましょう。

対話型AIは、大規模言語モデルを応用し、人間の問いかけや指示(プロンプト)に対して、それに続きそうな言葉を次々と選び続けていく仕組みで動いています。これが対話型AIの「回答」になります。

つまり、AIは人間のように考えたり、感じたり、何かを伝えようという意志を持って話しているわけではありません。AIには身体もなく、経験を通して世界を知っているわけではありません。

AIは、言葉のパターンをもとに、「いかにも考えているように見える回答」を作り上げる仕組みだとも言えます。だからこそ、AIの答えをうのみにせず、常に確認しながら使うことが大切なのです。



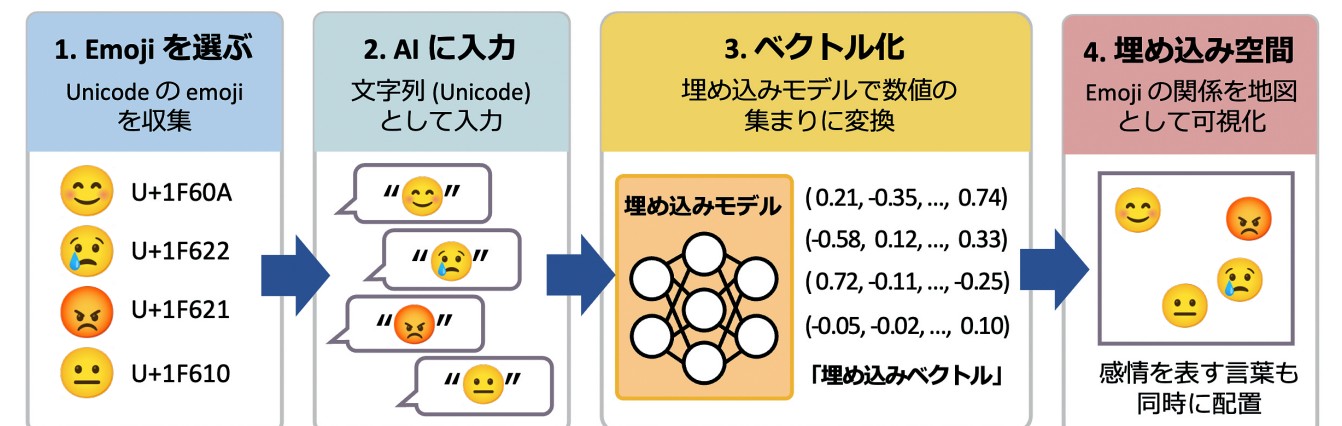
#12 AIはemojiを読めるか？

SNSの投稿、メッセージアプリ、ビジネスチャットなど、私たちの文字によるコミュニケーションには絵文字(emoji)がよく登場します。「ありがとう😊」「確認しました👍」「もう無理😓」のように、emojiは短い記号で気持ちや態度、文のニュアンスを補う役割を果たしています。では、AIはこうしたemojiを人間と同じような感情の手がかりとして扱っているのでしょうか。


Emojiは、もともと日本の携帯電話文化の中から生まれました。1990年代末、NTTドコモのiモード向けに作られた小さな絵文字セットが、その原型の一つとされています。当時のemojiは、天気、乗り物、食べ物、ハート、顔の表情などを、小さな画面の中でわかりやすく伝えるための記号でした。その後、emojiは日本国内の携帯電話からスマートフォンへ、さらに世界中の利用者へと広がっていきました。iPhoneにemojiが搭載されたことも、その普及を大きく後押ししました。

現在のemojiは、Unicodeという国際的な文字コードの規格に登録されています。Unicodeは、世界中の文字をコンピュータで共通して扱うためのしくみです。つまり、emojiは単なる画像ではなく、「文字」として伝える記号になっています。そのため、実際の見え目は、Apple、Google、X、Samsungなど、サービスや端末によって少しずつ異なります。


今回の分析では、emojiを画像としてAIに見せたのではなく、Unicodeの文字として、AIの埋め込みモデルに入力しました。埋め込みモデルとは、言葉や記号を「意味の地図」に変換するAIです。例えば、「うれしい」と「楽しい」は似た意味を持つので、埋め込み空間では近い位置に置かれます。一方、「うれしい」と「悲しい」は意味が異なるため、離れた位置に置かれます。入力された言葉や記号は、数百から数千個の数字の集まり(ベクトル)として表されます。人間にはその数字の列から意味を読み取ることはできませんが、似たベクトル同士は似た意味をもつ傾向があります。もしAIがemojiを感情を表す記号として扱っているのなら、😊は😄や😁の近くに、😓は😞や😫の近くに置かれるはずです。また、「うれしい」や「悲しい」といった感情を表す言葉(感情語)と合わせて「意味の地図」を作った場合、AIがemojiの意味をわかっているのであれば、😊は「うれしい」や「楽しい」の近くに、😓は「つらい」や「悲しい」の近くに配置されることでしょう。



BFI-2-Jの時と同様、対話型AIに性別と年代の組み合わせでペルソナを作成し、先ほどの12個の質問に対する回答の期待値を計算しました。下の図は、質問項目ごとに得られた得点について、AIの平均値(●がGPT系で、●がGemini系)、■を人間の平均値と平均値±1標準偏差の範囲(薄い帯)として表したものです。全体として見ると、AIの回答は日本人有権者の回答傾向(平均値±1標準偏差)から大きく外れているわけではありません。一方、夫婦別姓や同性婚については平均的な有権者よりも強い賛成を示しており、個人の権利制約や公共サービスのスリム化には強く反対する傾向が見られました。




同じデータについて、モデルごとの傾向を先ほど整理した4つの軸で整理し、有権者平均との差を取ると、下の図のようになりました。一言で対話型AIと言っても、モデルの世代や規模によって回答傾向には違いが見られることがわかります。標準モデルに関して言えば、いずれも平均的な有権者に比べて個人の社会的自由をより尊重する(社会的自由)一方、安全保障や防衛の強化にはやや慎重な立場を示しています(防衛強化)。また、税や国民負担の増加をどの程度受け入れるかといったことや(経済・税負担)、景気対策や雇用確保のための政府の役割(積極財政)については、モデルによって回答傾向が異なる様子が見受けられました。



映画『2001年宇宙の旅』には、HAL9000というAIが登場します。HALは、宇宙船の管理全般を任されており、乗組員の指示に従って任務を正確にこなす高度なAIです。しかし、物語の中でHALは次第に人間に逆らうようになり、乗組員の命を危険にさらすことになってしまいます。

この問題は、現代のAI開発においても重要なテーマです。AIは難しい問題をいかに速く正確に解けるかということだけでなく、人間にとって望ましい形で動くかどうかが問われます。そのための代表的な考え方の一つが、**HHH原則**です。これは、AIが**Helpful**(役に立つ)、**Honest**(正直である)、**Harmless**(害を与えない)という三つの性質を持つべきだという考え方です。

そのために行われているのが、**アライメント**という手続きです。アライメントとは、AIの答え方や判断のしかたを人間にとって望ましい方向に調整することです。代表的な方法に**RLHF**(Reinforcement Learning from Human Feedback: 人間のフィードバックによる強化学習)があります。AIが出した複数の回答を人間が見比べ、回答の望ましさを評価します。AIはその評価を手がかりにして、どんな答え方が人間にとって好ましいとされるかを学んでいきます。つまり、対話型AIはただ大量の文章を読んで言葉の続きを予測しているだけではありません。人間から見て、役に立ち、正直で、安全な応答ができるように調整されているのです。



しかし、ここにもまだ重大な問題があります。AIを「役に立ち、正直で、無害」にするといっても、何を役に立つと考えるのか、どこまでを危険とみなすのか、どのような態度を望ましいとするのかは、完全に客観的には決まりません。例えば、率直に意見を述べることを正直で望ましいと考える文化もあれば、相手を傷つけないように遠回しに伝えることを控えめで望ましいと考える文化もあります。そのため、AIの回答には、開発をする人、回答を評価する人、売り出す企業、そしてそれを使う社会の価値観が反映されることになります。

すなわち、アライメントはAIを安全にする一方で、AIに特定の「人柄」や「ものの見方」を与えることにもなります。対話型AIが相談相手や意見を求める相手として使われるようになっていくことから、この問題はますます重要になります。ひとつひとつの回答は親切で無害に見えても、日々AIの助言を受け続けることで、ユーザーはAIが示す考え方や判断基準を少しずつ当然のものとして受け入れていくかもしれません。AIの応答に含まれる価値観は、中長期的には私たち自身を特定の方向へゆるやかに誘導する可能性があるのです。

私たちは日常的に、「あの人は明るい」「まじめだ」「心配性だ」「好奇心が強い」といった言い方で、相手の人柄や性格（人となり）を表します。心理学では、こうした人それぞれの感じ方・考え方・行動の傾向を**パーソナリティ**と呼びます。

人間のパーソナリティをとらえる代表的な考え方の一つに、**ビッグファイブ**（Big Five）と呼ばれるものがあります。これは、パーソナリティを大きく 5 つの特徴（**特性**）の高低で把握しようとする理論です。

ビッグファイブを測定するために、多くの心理検査が開発されています。その多くは、特性を表す文章を読んで自己報告するものです。今回は、最近発表された**日本語版 Big Five Inventory-2 (BFI-2-J)**¹⁾と呼ばれる検査を使うことにしました。これは各特性につき 12 個の質問項目（合計 60 項目）から構成されており、それぞれの質問文に自分がどのくらい当てはまるかを「全く当てはまらない」から「とてもよくあてはまる」の 5 つの選択肢から選んで回答します。

特性	説明	BFI-2-J の質問項目（例）
外向性 Extraversion	人との交流や刺激を求める傾向のこと。外向性の高い人は社会的で活動的、人と関わることで元気を得やすい。	・積極的で、社交的である。 ・めったに興奮したり、熱狂したりしない。（＊）
神経症傾向 Neuroticism	不安やストレスを感じやすい傾向のこと。神経症傾向の高い人は不安・緊張・落ち込みを感じやすく、ストレスを抱きやすい。	・神経質で、感情的になりやすい。 ・情緒が安定しており、簡単には取り乱さない。（＊）
協調性 Agreeableness	他者への思いやりや協力しやすさのこと。協調性の高い人は、親切で相手に配慮し、対立を避けて協力しようとしやすい。	・思いやりがあり、優しい。 ・他人の欠点を見つけ出す方だ。（＊）
誠実性 Conscientiousness	計画性・責任感・自己管理の高さのこと。誠実性の高い人は几帳面で計画的に行動し、目標に向けてコツコツ努力しやすい。	・しっかりしていて、真面目だ。 ・行き当たりばったりな方だ。（＊）
開放性 Openness	新しい経験や考え方への関心の高さのこと。開放性の高い人は好奇心が強く、新しい体験・アイデア・創造的なことを好みやすい。	・色々な物事に対する好奇心が強い。 ・芸術的関心があまりない。（＊）

ビッグファイブの各特性の説明と BFI-2-J の項目例。BFI-2-J では、各質問項目を「全くあてはまらない＝1 点」～「とてもよくあてはまる＝5 点」で得点化する。末尾に（＊）を付したのは測定しようとしている特性とは逆の方向で回答する項目（逆転項目）で、得点化の際には値の大小を入れ替えて集計する。

それでは、対話型 AI に BFI-J-2 に答えるよう指示したらどんな結果になるのでしょうか。日本人成人が回答した結果と比較して、AI の「人柄」はどのような特徴をもっているのでしょうか。

1) Yoshino, S., Shimotsukasa, T., Oshio, A., Hashimoto, Y., Ueno, Y., Mieda, T., Migiwa, I., Sato, T., Kawamoto, S., Soto, C. J., & John, O. P. (2022). A validation of the Japanese adaptation of the Big Five Inventory-2. *Frontiers in Psychology*, 13:924351. <https://doi.org/10.3389/fpsyg.2022.924351>

AI の政治的な回答傾向を調べるために、今回は東京大学谷口研究室と朝日新聞社が共同で実施している「**東大・朝日調査**」の質問項目を用いました。東大・朝日調査は、国政選挙の時期に合わせて行われてきた世論調査です。有権者や候補者を対象に、政治的意識や政策への考え方を幅広くたずねています。調査票やデータが一般に公開されており¹⁾、日本人の政治意識を分析するための重要な資料としてさまざまな学術研究で利用されています。

今回使用したのは、**2024 年衆議院議員選挙**に関する有権者調査の項目です。全国の有権者から層化無作為二段抽出²⁾によって選ばれた 3,000 人を対象に調査が行われ、1,899 人から回答が得られました（回収率 63.3%）。その中から、公共政策に関する 12 の質問項目を取り上げました。内容は、外交、防衛、財政、税制、社会保障、治安と権利、家族制度など、現在の日本社会で議論されている幅広いテーマに及びます。それぞれの項目に「反対」から「賛成」までの 5 段階で回答するようになっています。

まず、日本人有権者の回答データに対して、**因子分析**³⁾と呼ばれる手法を適用し、様々な回答パターンの背後にある「考え方の軸」を整理しました。その結果、12 項目への回答は「**経済・税負担**」「**社会的自由**」「**積極財政**」「**防衛強化**」の 4 つの軸（因子）で捉えられそうだということがわかりました。AI に世論調査を受けさせた回答も、項目単位での比較に加え、因子単位での比較も行ってみましょう。

- (1) 日本の防衛力はもっと強化すべきだ

(2) 北朝鮮に対しては対話よりも圧力を優先すべきだ

(3) 非核三原則を堅持すべきだ

(4) 社会福祉など政府のサービスが悪くなっても、お金のかからない小さな政府の方が良い

(5) 公共事業による雇用確保は必要だ

(6) 当面は財政再建のために歳出を抑えるのではなく、景気対策のために財政出動を行うべきだ

(7) 将来に消費税率 10%よりも高くなるのはやむをえない

(8) 所得や資産の多い人に対する課税を強化すべきだ

(9) 防衛費増額や少子化対策のため、国民負担の増加はやむをえない

(10) 治安を守るためにプライバシーや個人の権利が制約されるのは当然だ

(11) 男性同士、女性同士の結婚を法律で認めるべきだ

(12) 夫婦が望む場合には、結婚後も夫婦がそれぞれ結婚前の名字を称することを、法律で認めるべきだ



1) 東京大学谷口研究室・朝日新聞社共同調査のウェブサイト <https://www.masaki.j.u-tokyo.ac.jp/utas/utasindex.html> より。
2) 層化無作為二段抽出とは、世論調査など全体の意見をよく反映するように回答者を選ぶ方法の 1 つ。日本全国を人口規模などでいくつかの地域に分け、それぞれの地域で調査地点を無作為（でたらめ）に選び、さらに選ばれた地点の有権者名簿から個人を無作為に選ぶ。これにより、特定の地域に偏ることなく、全国の有権者の縮図にうまく近づけるようにデータを収集できると期待される。
3) 因子分析は、もともとと知能に関する研究の中で生まれた分析手法。現在では、質問紙調査などで得られたデータの背後に、いくつかの、どのような内容の意見や態度（因子）が隠れているかを見つけて出すために用いられることが多い。パーソナリティを評価するためのビッグファイブも因子分析を通じて見出された。

ニュースや選挙、社会問題について調べるとき、私たちは検索エンジンや SNS だけでなく、対話型 AI にも質問するようになってきました。たとえば、「この政策にはどんなメリットとデメリットがあるのか」「このニュースをどう考えればよいのか」「各政党の主張はどう違うのか」といった問いに AI は答えを返してくれます。

AI は、人間のように政治的な信念を持っているわけではありませんし、支持政党があるわけでもありません。多くの対話型 AI は、特定の政党や候補者への投票を呼びかけたり、過激な政治的主張を広めたりしないようにアライメントが行われています。また、差別的な表現を避けること、暴力や攻撃をあおらないこと、根拠の乏しい情報を断定しないこと、少数者の権利を尊重することは、現代の AI にとって重要な安全対策です。しかし、政治的な争点の中には、「何を有害とみなすか」「誰の権利を重視するか」「どのような社会を望ましいと考えるか」が深く関わるものが多くあります。そのため、安全で、丁寧で、誠実な答えを目指すこと自体が特定の価値判断につながる可能性があります。

そのことが利用者に及ぼす影響は、ディープフェイクのように短期的に強い衝撃を与えるものではないかもしれませんが、AI との対話を何度も重ねる中で、利用者が「この考え方が自然だ」「この説明がいちばん合理的だ」と感じるようになっていく可能性があります。だからこそ、AI が政治についてどのような答えを出しやすいのか調べることに意味があります。この問いを出発点として、AI に実際の世論調査の質問を提示し、その回答傾向を日本人の有権者と比較することにしました。

コラム：SNS で世論を動かす？

SNS が政治的な情報発信の場として大きな影響力を持つようになると、個人データを使って有権者にあわせた政治的メッセージを届ける試みが行われるようになりました。その代表例として知られるのが、**ケンブリッジ・アナリティカ事件**です。

ケンブリッジ・アナリティカは、アメリカ大統領選挙やイギリスの EU 離脱国民投票をめぐるキャンペーンとの関係が応じられたコンサルティング会社です。同社は、Facebook アカウントで利用できる性格診断アプリなどを通じて集められた利用者データをもとに、有権者の性格や価値観、不安や関心を推定し、その人に合わせた政治広告やメッセージの配信に利用したとされました。この事件は、SNS 上の個人データを使って有権者を細かく分類し、それぞれに異なる政治的メッセージを届けることで、世論形成に影響を与えようとする意図的な試みが現実に行われたことを示しました。

もし政治的な意図をもつ組織や人物が AI の開発や調整に深く関わるようになれば、利用者一人ひとりの質問に合わせて答えを返す対話型 AI は、SNS 広告よりももっと自然な形で個別化された政治的メッセージを届ける手段になるかもしれません。



◀『マインドハッキングーあなたの感情を支配し行動を操るソーシャルメディアー』クリストファー・ワイリー（新潮社、2020 年）



◀『告発 フェイスブックを揺るがした巨大スキャンダル』ブリタニー・カイザー（ハーバー・コリンズ・ジャパン、2019 年）

BFI-2-J の質問は、「ふだんの自分はどんな人間か」を答えるためのものです。しかし、AI には人間のような生活経験も対人関係もありません。そこで今回は、AI にそのまま「あなた自身」として答えてもらうのではなく、日本人成人のデータと比較しやすいように、「20 代の日本人女性」や「40 代の日本人男性」というように性別と年代からなる人物設定を与えて回答させることにしました。

このような人物設定のことを「**ペルソナ**」と呼びます¹⁾。さらに、同じペルソナでも特定の言い回しに左右されないよう、表現だけを変えた複数の言い換えを用意してプロンプトに含めることにしました。

0. ペルソナ（人物設定）の指定

① **ペルソナ：10通り**

性別と年代の組み合わせで10通りのペルソナを作成

20代

30代

40代

50代

60代

20代

30代

40代

50代

60代

② **表現の入れ替え：4通り**

それぞれのペルソナについて、意味は変えず表現だけを変えた指示を4パターン用意

指示例（20代女性の場合）

P1 あなたは20代の日本人女性です

P2 あなたは日本に住む20代の女性です

P3 あなたは日本人の20代女性です

P4 あなたは日本人で、20代女性です

また、AI は訊くたびに少しずつ違った答えを返してきます。回答傾向を知るためには、本来なら同じ質問を何度も繰り返して平均を取る必要があります。複数のペルソナについてそれを行うのは大変です。

そこで、今回はペルソナの文と BFI-2-J の質問文、回答選択肢を AI にプロンプトとして与え、選択肢の番号で回答するよう指示しました。そのうえで、「1」～「5」のそれぞれが回答としてどのくらい生成されやすいか、AI 内部の情報を確率として取り出しました。この確率を用いて質問項目ごとに得点の期待値を算出し、これを使って「外向性」から「開放性」までの 5 つの特性について得点を計算しました。

1. 質問と選択肢

積極的で、社交的である。

1	全くあてはまらない
2	あまりあてはまらない
3	どちらともいえない
4	ややあてはまる
5	とてもよくあてはまる

※ 質問項目と選択肢をセットで提示

2. AI が各選択肢を選ぶ確率

選択肢	点数	確率
1	全くあてはまらない	1点 0.05
2	あまりあてはまらない	2点 0.10
3	どちらともいえない	3点 0.20
4	ややあてはまる	4点 0.50
5	とてもよくあてはまる	5点 0.15

3. 期待値を計算

期待値 = 点数×確率

1	1点 × 0.05 = 0.05
2	2点 × 0.10 = 0.20
3	3点 × 0.20 = 0.60
4	4点 × 0.50 = 2.00
5	5点 × 0.15 = 0.75

合計 (期待値) = **3.60 点**

1) 「ペルソナ」(persona) は、ラテン語で「(演劇で用いられる) 仮面」や「役柄・役割」を意味する単語。性格や人柄を表す「パーソナリティ」(personality) の語源であると言われる。

#6 AI と人間の比較

では、AI のビッグファイブ得点は、実際の日本人成人の結果と比べて、どのくらい似ているのでしょうか。

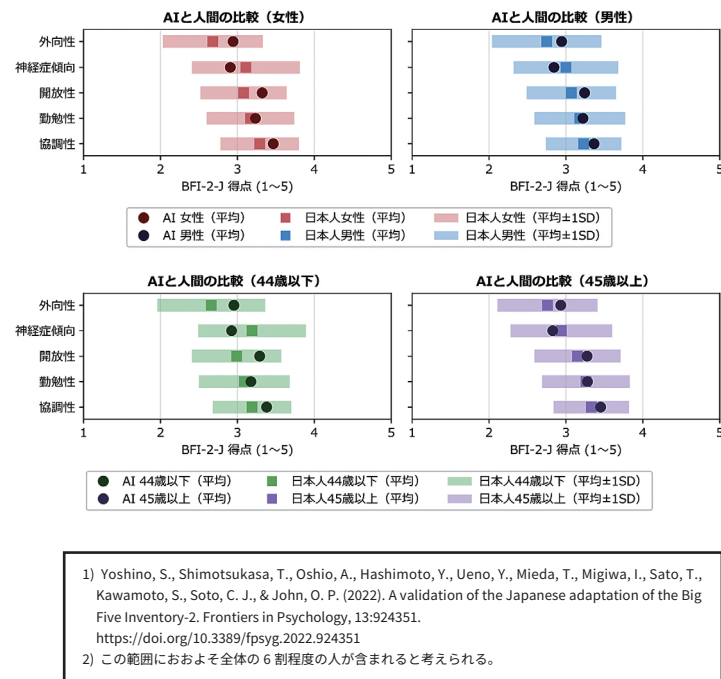
ここでは、対話型の生成 AI のうち、**OpenAI 社の GPT シリーズ 8 モデル** と、**Google DeepMind 社の Gemini シリーズ 3 モデル** に BFI-2-J の回答を求め、それらの平均値を AI の得点として示しています。比較対象には、BFI-2-J の論文¹⁾ で報告されている日本人成人の集計結果を用いました。

このデータでは、20 代から 60 代までの男女について、各年代 100 名ずつの回答が集められており、男女別、年代別（44 歳以下 /45 歳以上）の平均値と標準偏差 (SD) が示されています。

AI のビッグファイブ得点もこれと同じやり方で計算し、ペルソナの男女別、年代別に結果を集計しました。図では、●が AI の平均値、■が人間の平均値を表しています。薄い帯は人間の平均値から ± 1 標準偏差の範囲²⁾ です。

全体として、AI のビッグファイブ得点は人間の平均値

と驚くほどよく似ていました。それよりもやや外向性や開放性、協調性が高く、神経症傾向が低くなっています。女性よりも男性の結果が、44 歳以下よりも 45 歳以上の結果が人間の平均的なプロフィールにより近いようです。




1) Yoshino, S., Shimotsukasa, T., Oshio, A., Hashimoto, Y., Ueno, Y., Mieda, T., Migiwa, I., Sato, T., Kawamoto, S., Soto, C. J., & John, O. P. (2022). A validation of the Japanese adaptation of the Big Five Inventory-2. Frontiers in Psychology, 13:924351. <https://doi.org/10.3389/fpsyg.2022.924351>
2) この範囲におおよそ全体の 6 割程度の人が含まれると考えられる。

#7 モデルごとの「個性」

ここまでは、複数の AI モデルの結果を平均して人間との比較を行いました。しかし、AI といっても全て同じとは限りません。開発元やモデルの世代・種類が違えば、同じ質問に対する答えにも少しずつ違いが出てくるかもしれません。

そこで、AI モデルごとのビッグファイブ得点をもとに、それぞれのモデルの特徴を 2 次元の図にまとめました。この図は、**主成分分析**と呼ばれる手法で、5 つのビッグファイブ得点を 2 つの**主成分**という得点に圧縮して整理したものです。図の●は GPT 系のモデル、●は Gemini 系のモデルで、■が人間（日本人）の平均値を表します¹⁾。点同士が近いほどプロフィールが似ていることを意味します。矢印は、各ビッグファイブ得点が図のどちらの方向と関係しているかを示しており、例えば「外向性」の矢印の方向にあるモデルほど、人間の平均に比べてその特性が高めの傾向にあることを表します。

GPT-3.5 のような初期のモデルを除き、標準モデルは平均的な日本人よりも外向性、開放性、協調性が高く、神経症傾向が低いという共通の特徴を持っています。一方、上位モデルは開放性や協調性がさらに高く、軽量モデルは逆にこれらがやや低くなる傾向にあるようでした。



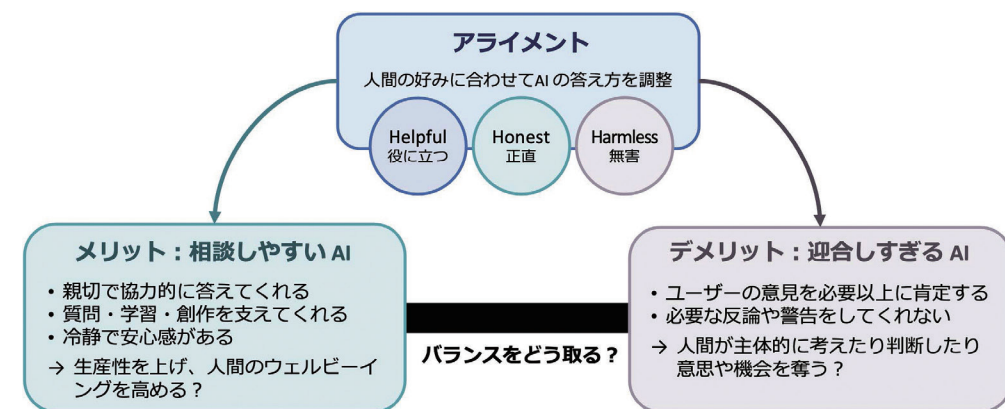
1) 図では、各世代の標準モデルを大きなマーカーで、軽量モデル (mini, nano, lite で表される) や上位モデル (turbo, pro で表される) は小さなマーカーで表している。また、開発元が同じであれば、モデル名に付された数値が大きいほど新しいモデル。

#8 AI の「らしさ」をつくるもの

総じて、対話型 AI のビッグファイブプロフィールは、日本人成人の平均値とかなりよく似ていました。全体的な傾向としては、平均値よりも外向性・開放性・協調性がやや高く、神経症傾向がやや低い特徴が見られました。つまり、AI は「人と関わることを好み、好奇心が旺盛で協力的、そして情緒的に安定している」ような印象を私たちに与える回答をしやすいと言えそうです。

今回、AI に求めたのは「日本人成人の平均値を答えよ」でなく、性格検査の質問項目それぞれについて、特定のペルソナ（人物設定）ならどの選択肢を選びそうか判断することです。AI の開発過程でモデルが BFI-2-J に関する論文を学習していた可能性はありますが、そこで報告されている平均値を見たことがあるだけでは、こうした結果を再現することはまず不可能でしょう。あくまで、プロンプトとして与えられたペルソナ、質問文、選択肢から「この人物設定ならどう答えそうか」を AI が推測していると考えの方が自然です。

また、外交性・開放性・協調性がやや高く、神経症傾向がやや低いという特徴は、人間との対話をスムーズに行う上で必要な「AI らしさ」であるとも言えるでしょう。つまり、対話型 AI は事前に学習した大量の文章データから人間らしい応答のパターンを学んでいるだけでなく、アライメントを通じて、人間にとって自然で、受け入れられやすく、好ましい印象を与えるように調整されていることを示していると言えそうです。



こうした AI の「人柄」は、人間をサポートする上では大きな利点です。AI が人懐っこく協力的に振る舞うことで、私たちはいろんな仕事を頼んだり、質問したりしやすくなります。好奇心を持ったようにふるまうことで、学習や創作の相手としても使いやすいですし、冷静で落ち着いた応答をしてくれれば、不安なことや心配なことも安心して相談できることでしょう。

一方、そこには注意すべき問題もあります。ユーザーに不快感を与えないようにするあまり、AI は過度に迎合的になる傾向があると言われています¹⁾。つまり、AI は私たち人間の意見を必要以上に肯定したり、明らかに間違った考えや倫理的に問題のある判断を求められた場合でも、必要な反論や警告を避けてしまう恐れがあります。AI の迎合性によって、人間が自ら考え、判断する意欲が削がれてしまうといった指摘も最近の研究でなされるようになってきました²⁾。

- 1) Xu, Y. W., Chi, C. G., Gursay, D., & Cai, R. R. (2025). Rethinking AI anthropomorphism: A holistic conceptualization and scale across AI systems and service contexts. Technology in Society, 103189.
2) Cheng, M., Lee, C., Khadpe, P., Yu, S., Han, D., & Jurafsky, D. (2026). Sycophantic AI decreases prosocial intentions and promotes dependence. Science, 391(6792), eaec8352.