

人はロボットの選好を読めるか

吉川聡一郎^{1*} 小嶋秀樹² 池田尊司³ 熊崎博一⁴ 寺田和憲¹

¹ 岐阜大学

² 東北大学

³ 金沢大学

⁴ 国立精神・神経医療研究センター

Abstract: 社会生活では相手の選好を推定し、特定の話題を避ける、相手の趣味に合わせる、適切なプレゼントを渡すなど、「空気を読んで」行動することが求められる。本研究では、人とロボットの間で相互に空気を読んだ行動を実現できるかどうかを調べるために、実在する特定の個人の選好を搭載した自律ロボット Prefer を開発し、人がロボットの選好を推定できるかどうかを確認する実験を行った。選好の対象領域として自動車を選択した。Prefer には特定の個人の選好を搭載した。自動車の選好を説明するための潜在要因を同定するために、112 種類の自動車の画像に対して、好き嫌いとその理由を回答するアンケートを行い、候補となる特徴要因を求めた。次にリッカート法と因子分析を用いて 5 次元の要因を決定した。次に、112 種類の自動車に対して、好き嫌いとは 5 次元の要因それぞれに対する同意の程度を回答するアンケートを行い、ロボットに搭載する選好の候補を作成した。次に決定木 (CART)、ランダムフォレスト、SVM を用いた機械学習手法によって、判別が最も容易な選好を有する個人を同定し、この個人の選好をロボットに搭載した。人を対象として、選好学習と未知刺激に対する選好判別テストを行う実験を実施した。実験参加者は 89 個のミニカーをロボットの目前に順に提示し、ロボットの行動からロボットの選好を推定するように求められた。ロボットは搭載された選好に基づき自動的に接近と回避の行動を生成した。ミニカーの認識は予め学習した CNN によって行った。次に、23 個のミニカーを実験者が実験参加者に対して順に提示し、ロボットの好き嫌いを回答することを求めた。実験には 18 人が参加した。実験の結果、テスト課題の識別精度は 0.70 であった。このことから、人はロボットの選好を推定することが可能であることが分かった。

1 はじめに

1.1 背景

人が社会生活を送る上で、他者の感情や行動の意図を推定することは大変重要である。他者の感情や行動の意図を推定することで円滑なコミュニケーションを図ることができ、他者と協力関係を結ぶことができる。他者と協力関係を結ぶことで、個人ではなく社会集団として作業を行うことができるので、個人よりも効率的に作業に従事することが可能になる。このように、他者の感情や行動の意図の推定は人の社会性を考える上で重要な能力だと言える。人が推定する他者の感情の内、重要な物の 1 つとして好き嫌いを表す選好という感情が挙げられる。社会生活では相手の選好を推定し、特定の話題を避ける、相手の趣味に合わせる、適切なプレゼントを渡すなど、相互に「空気を読んで」行動

することが求められる。ロボットや人工エージェントが人の選好を理解し推定することができれば、これらと人が相互に空気を読んだ行動を行うことが可能になると考えられる。ロボットや人工エージェントは機械であるが、人はしばしばこれらを社会的対象としてみなすことがある。したがって、ロボットや人工エージェントが人と相互に選好を推定し空気を読んで社会生活を送ることで、ロボットや人工エージェントを人が社会的対象とみなす可能性を考えることができる。以上のことから、人の選好について明らかにした上で、ロボットと人との間の選好に関するインタラクションを考えることはヒューマンエージェントインタラクション研究の分野において重要だと言える。しかしながら、何らかの対象領域について選好をモデル化及び推定を行った研究は数多くあるものの、人-ロボットインタラクションに選好推定を用いた研究は我々の知る限り存在しない。

*連絡先：岐阜大学大学院 知能理工学専攻 知能情報学領域
〒501-1193 岐阜県岐阜市柳戸 1-1
E-mail:sou@ai.info.gifu-u.ac.jp

1.2 本研究の目的

本研究では、まず人の選好について明らかにすることを目的とする。対象領域を設定し、対象領域について人の選好を説明するための潜在要因を同定する。同定した要因から人の選好についてモデル化を行い、対象領域に対する人の選好について一般化した視点から議論を行う。

次に、人とロボットの間で相互に選好を推定し空気を read 行動が実現できるか明らかにすることを目的とする。モデル化した人の選好をロボットに搭載し、ロボットとのインタラクションを通して、人がロボットに搭載した選好モデルを推定できるか確認する実験を行う。実験の結果から、人のロボットに対する選好推定能力について明らかにし、ロボットが人と空気を read 行動を取り社会性を獲得できるか議論を行う。

1.3 本研究の対象者

本研究において、選好を説明する潜在要因を同定するためには、研究対象者が対象領域についての選好理由を明確にする必要がある。またロボットに対する選好推定は、研究対象者が持つ認知能力の発達程度に大きく影響を受けるので、研究対象者間で認知能力の発達程度を揃えることが必要になる。以上のことから、選好理由の明示化が十分に可能であり、社会生活を送る上で認知能力が十分に発達している人として、18歳以上の男女を本研究の対象者とした。

1.4 選好の対象領域

本研究で取り扱う選好の対象領域について、対象領域の中に多様な個体が含まれることが望ましいと考えられる。例えばピーカーを対象領域に取った場合を考えると、ピーカーは規格化された計量器であるため、1つ1つのピーカー個体の差異は小さく個体間で選好に差が生じにくいと考えられる。個体や人によって選好に差が生じにくいのであれば、人の選好に影響を与える要素を明らかにすることは難しい。人の選好に影響を与える要素を考えるには、対象領域内の1つ1つの個体に明確な差があり、選好は個体や人によって異なることが望ましいと言える。1つ1つの個体に明確な差があるのであれば、1つの個体について色や形状といった特徴が複数存在し、特徴を人が切り分けることができると言える。また対象領域を明確にすることでモデル化した選好を人がより明確に推定できると考えられるため、対象領域は1つであり人がひと目で見てどのようなものか判別できることも望ましいと言える。

上記で述べた対象領域における基準を満たすものとして、本研究では選好の対象領域に自動車を選択した。

自動車という概念には、乗用車やトラック、バス、緊急車両といった個体差が明らかなものが含まれている。1つの個体に注目すると色や形状、パーツといった切り分け可能な特徴が複数存在していることが分かる。また対象者となる18歳以上の男女にとっては、自動車という概念は認知発達過程において十分獲得できるものであり、他の概念と混同することはないと言える。以上のことから、対象領域として自動車を用いるのは妥当だと考えられる。実験参加者に選好対象として具体的な1つ1つの個体を提示する際には、実験参加者に与える視覚等の刺激の統制のためミニカーを用いて行った。ミニカーは112個を実験に用いた。使用したミニカーの一部を図1に示す。

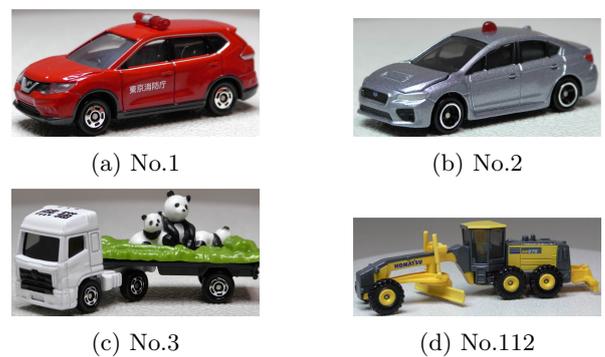


図1: 選好対象領域の提示に用いたミニカーの一部。No.は個体識別番号を示す。

2 実験1

実験1では、どのような特徴が人の選好に影響を与えるかを明らかにするために、ミニカーそれぞれに対する選好と選好理由について調査し、人の選好に影響を与える特徴を同定することを目的とした。本研究ではミニカーの特徴を、まず1) 程度を表す特徴、2) 部分を表す特徴、3) 目的を表す特徴、の3つに分類した。実験1ではミニカーの選好理由として、これら3つの内1つ以上の分類に関する特徴を回答するよう参加者に求めた。調査の結果から参加者の選好理由に多く見られる特徴を3つの分類ごとに同定し、得られた特徴が人の選好に影響を与える特徴とした。

2.1 参加者と実験計画

実験参加者は24歳から76歳までの男性35人、女性8人であった ($M_{age} = 44.63$, $SD_{age} = 10.62$)。

2.2 手順

実験1の手順は以下の通りであった。

1. Web 上でアンケートに参加する人を募集した。
2. 参加者に対して、Web 上で実験についての説明を行い、参加への同意を取得した。
3. 参加への同意が得られた者に対して、参加者情報として性別と年齢の入力を求めた。
4. 画面上でアンケートの回答方法を説明した。
5. アンケートを実施した。

2.3 測定方法

2.3.1 特徴に対する3つの分類

前節で述べたように、1つの自動車は様々な特徴に切り分けることができる。これらの特徴は、主観的な特徴と客観的な特徴に大きく分類することができる。主観的な特徴(例:速い, かわいい)は何らかの程度を表し、特徴の評価は人により異なる。対して客観的な特徴(例:タイヤ, ランプ)は単にその特徴があるかないかという事実を表し、全ての人が特徴について同じ評価をつける。本研究ではこれらの特徴を分けて考えるようにした。また、自動車は何らかの目的のために生産・使用されるため、目的に相当する特徴も重要な特徴だと考えられる。以上のことから、本研究では自動車の特徴をまず1)程度を表す特徴、2)部分を表す特徴、3)目的を表す特徴、の3つに分類した。実験1では、1)をモノの持つ特徴の程度を表す形容語(形容詞, 形容動詞)、2)をモノの部分や部品を表す名詞、3)をモノの目的や機能を表す言葉、とそれぞれ参加者に説明し、これら3つの内1つ以上の分類に関する特徴を回答できるように設定した。

2.3.2 アンケート

実験1の参加者にはWeb 上で行うアンケートへの回答を求めた。参加者の募集はWeb 上でタスクを作成・公開しタスク参加者に報酬を贈呈するサービスであるYahoo クラウドソーシングを用いた。参加者にはYahoo クラウドソーシングのタスク上でアンケート用のWeb ページに移動し、アンケートに回答するよう求めた。アンケートはWeb 上でアンケートの作成と記録を行うサービスであるQualtrics を用いて作成し実施した。アンケートでは図2に示す通り、1つのミニカーにつき1枚の画像と以下の4つの質問を提示した。

1. この画像に写っているモノの好き嫌いを選択してください。
2. その理由をお答えください。
 - (a) モノの持つ特徴の程度を表す形容語(形容詞, 形容動詞)
 - (b) モノの部分や部品を表す名詞
 - (c) モノの目的や機能を表す言葉

実験1の参加者には、提示された1つのミニカーの画像を見て、上記の4つの質問に回答することを求めた。4つの質問の内、問1は「好き」あるいは「嫌い」の選択肢から必ずどちらか一方を選んで回答するよう求めた。問2に含まれる3つの小問は、それぞれ自由記述形式で参加者に回答を求めた。また問2a から問2c までの3つの小問の内、少なくとも1問には必ず回答するよう求めた。1人の参加者に対して、以上の質問を設定したミニカーの分だけ繰り返し回答するよう求めた。

実施したアンケートは自由記述形式で回答する質問が多く、1個のミニカーに対する回答時間は2分以上必要だと予想された。そのため各々の参加者に112個全てのミニカーについて回答を求めると、1人の参加者に対するアンケート全体の回答時間は3時間以上になると考えられた。この場合参加者に過剰な認知負荷を与えてしまい、ミニカーの選好や選好理由が明確に定まらない回答(例:何となく好き)が増加する可能性が考えられた。したがって各々の参加者の認知負荷を軽減し、加えて順序効果の影響を小さくするために、参加者に提示するミニカーは全体の半数をランダムに選出するよう設定した。

この画像に写っているモノの好き嫌いを選択してください。

好き 嫌い

その理由をお答えください。

① モノの持つ特徴の程度を表す形容語(形容詞, 形容動詞)
例)おとなしい, かがやかしい, ウィンターズ, 季節的

② モノの部分や部品を表す名詞
例)USBポート, 開口部, レンズ, 線香

③ モノの目的や機能を表す言葉
例)演奏, 運送, 教育, 販売

図2: 実験1で参加者に提示したアンケート画面

2.3.3 アンケートの分析方法

アンケートの結果から、実験1の参加者の自動車(ミニカー)に対する選好理由として多く見られる特徴を、1) 程度を表す特徴、2) 部分を表す特徴、3) 目的を表す特徴、の3つの分類ごとに同定するため、アンケートの間2aから間2cの3つの小問に対する回答に出現した特徴とその出現回数を計測した。計測は以下の手順で行った。

1. アンケート中の間2aから間2cのそれぞれの回答に対して形態素解析を行い、回答から名詞、動詞、形容詞、副詞を基本形で抽出した。形態素解析は実験1において対象となる1つ1つの回答が短く、解析速度も特に必要としないことから、Pythonにおける日本語の形態素解析エンジンの1つであるJanomeを使用した。
2. 概念辞書データベースの1つである日本語Wordnetを用いて、抽出した単語が持つ概念を検索した。
3. 検索から得られた概念を、人の選好に影響を与える特徴とした。同一の特徴が出現した場合は、その出現回数を合計した。

上記の手順を実験1の全ての参加者のアンケート回答に対して繰り返し行った。

2.3.4 Wordnet

Wordnetとは、英語についての概念辞書である。Wordnetでは同じ概念を持つ複数の単語をsynsetという単位で纏めている。ある1つの単語Aが含まれるsynsetをWordnetで検索すると、検索にヒットしたsynsetから単語Aの同義語を得ることができる。また、Wordnetはsynset間の関係についても述べられている。あるsynset α が他のsynset β を包含する関係にあるとき、synset α は上位、synset β は下位と表現できる。例えばオレンジ色を表すorengenessというsynsetや緑色を表すgreennessというsynsetは、共に色を表すspectral colorというsynsetに包括される。この場合、spectral colorが上位概念、orengenessやgreennessが下位概念となる。上位の概念を表すsynsetを用いることで、より広義の意味として同義語を検索することができる。なおWordnetは英語について記述された概念辞書であるが、国立研究開発法人情報通信研究機構(NICT)によって日本語に対応したWordnet(日本語Wordnet)が作成されている[1]。

実験1では手順2において、形態素解析によってアンケートから抽出した単語を日本語Wordnetで検索し、抽出した単語が含まれるsynsetの1つ上位のsynsetを

検索した。1つ上位のsynsetが見つからない時、すなわち抽出した単語が含まれるsynsetが最上位の概念である時は、抽出した単語が含まれるsynsetをそのまま検索結果として使用した。そして、手順3において得られたsynsetの出現回数を測定した。日本語Wordnetでの検索はNICTが公開しているリレーショナルデータベースを用いて機械的に行った。

2.3.5 適切な特徴の抽出

上述の手順2において、1つの単語から日本語Wordnetによって複数の概念が得られるが、アンケートの回答中の文脈と得られた概念が一致しない場合がある。例えば、「車高が高い」という回答から「高い」という単語を形態素解析で抽出し日本語Wordnetで検索すると単語が持つ概念として「tall」という概念の他に、「expensive」という概念が得られる。この場合、ミニカーの選好に影響を与える概念としては「expensive」よりも「tall」の方が適当だと言える。また「色」、「格好」、「形態」、「表情」という単語から共通して「visual aspect」という概念が得られる。日本語Wordnetではこの概念を「人や物の、外に現れた目に見える様子」と説明している。このように日本語で表現する場合抽象的な文になる概念が、日本語Wordnetから得られることがある。実験1で人の選好に影響を与える特徴と位置付けた物は、以降の実験では人の選好の特徴軸を表現することに用いる。そのため実験1で得られた特徴に対する日本語表現の抽象度が、人の選好の特徴軸の具体性に影響を与えると考えられる。これらの特徴軸の具体性への影響を小さくするために、実験1では選択する概念を日本語で一言で表現可能なものに統一する必要がある。

以上の理由から、測定した概念に対して追加の処理を行った。まず特徴の程度を表す形容詞、部分や部品を表す名詞、目的や機能を表す言葉として相応しくない単語を日本語Wordnetで検索した結果から除外した。次にアンケートの回答中の単語と単語から日本語Wordnetによって得られた概念の意味に齟齬があるものを除外した。更にWordnetから得られた概念の内、日本語の一言で表現できないものは除外した。以上の手順で除外されず得られた概念を人の選好に影響を与える特徴とした。

2.4 実験結果

実験1の結果、人の選好に影響を与える特徴として得られた物の数と、その特徴を得るために用いたアンケート中の単語の出現回数の総数について、特徴の程

	特徴数	単語数
程度	294	3188
部分	33	765
目的	225	2070

表 1: 人の選好に影響を与える特徴数とアンケート中の単語の総数

特徴	単語の例	単語数
pretty	可愛い, きれい	194
tall	高い, 大きい	78
visual propaty	色, 色合い	76
voguish	格好いい, スマート	75
device	機械, メカ	56
strident	うるさい, 騒がしい	51
strong	力強い, 丈夫	40
rock-steadry	頼もしい	39
bad	悪い, 危険	35
quick	速い, 素早い	34
showy	派手, けばけばしい	26
gratifying	楽しい, 面白い	26
increasepretty	先進, 上げる	26
go	働く, 機能	25
funny	変, 面白い	18

表 2: 程度について, 人の選好に特に影響を与える特徴及び単語とその総数

度を表す形容語, 部分や部品を表す名詞, 目的や機能を表す言葉ごとに表 1 に示す.

得られたそれぞれの特徴について, 特徴を得るために用いたアンケート中の単語がその総数の 0.5%以上 (程度), 1%以上 (部分, 目的) になるものを重要な特徴として抽出した. 更に重要な特徴として抽出した物の内, 日本語の一言で表現した時に他の特徴と重複するもの, すなわち他の特徴と重複した概念を表すものについては, アンケート中の単語数が重複した他の概念より多かった場合は残し, それ以外の場合は分析結果から除外した (例: tall, enormous, heavy, overstand, big, great, sizeable の中から tall を残し他の特徴は除外した). このようにして最終的に抽出した特徴を, 人の選好に特に影響を与える特徴と結論付けた. 人の選好に特に影響を与える特徴として, Wordnet から得られた特徴名と, 特徴を得るために用いた形態素解析を通して得たアンケート中の単語の例及び単語の総数を表 2 から表 4 に示す.

表 2 から, 程度を表す特徴としては pretty, tall, visual propaty, voguish, device, strident, strong, rock-steadry, bad, quick, showy, gratifying, increasepretty,

特徴	単語の例	単語数
motor vehicle	自動車	244
hoop	タイヤ	101
lifting device	クレーン, リフト	59
carrier	荷台	56
vessel	バケツ, タンク	45
support	座席, 椅子	39
mechanical device	ポンプ, ローラー	31
movable barrier	ドア, 扉	26
protective covering	屋根, ボンネット	23
hand tool	シャベル	23
source of illumination	ランプ, ライト	23
opening	窓	16
front	前面, フロント	9
motor	エンジン	9
stairs	梯子	9

表 3: 部分について, 人の選好に特に影響を与える特徴及び単語とその総数

特徴	単語の例	単語数
shift	移動	185
carry	輸送, 搬送	182
play	遊ぶ, 遊戯	78
pull through	救助, 救出	67
zip	走る	55
show	展示, 見せる	39
set	乗せる, 入れる	36
do work	労働, 運転	31
secure	安心, 安全	26
protect	警備, 守る	24

表 4: 目的について, 人の選好に特に影響を与える特徴及び単語とその総数

go, funny という 15 個の特徴が人の選好に特に影響を与える特徴だと分かった。また表 3 から、部分を表す特徴としては motor vehicle, hoop, support, movable barrier, source of illumination, opening, front, motor の 9 個の特徴及び lifting device, carrier, vessel, mechanical device, protective covering, hand tool, stairs のような車両に後付できる部品を表す特徴が人の選好に特に影響を与える特徴だと分かった。また表 4 から目的を表す特徴としては shift, carry, play, pull through, zip, show, set, do work, secure, protect という 10 個の特徴が人の選好に特に影響を与える特徴だと分かった。人の選好に特に影響を与えるこれらの特徴が得られたことは、実験 1 の結果として、アンケート調査を通して多くの参加者の選好理由に用いられる特徴を同定することができたことを示す。

2.5 議論

実験 1 では Web 上でミニカーの画像を提示し、ミニカーについて参加者の選好とその選好理由を回答するアンケートを実施した。アンケートの分析結果から、1) 程度を表す特徴、2) 部分を表す特徴、3) 目的を表す特徴、の 3 つの分類それぞれに対して多くの参加者の選好理由に用いられる特徴 (人の選好に影響を与える特徴) を同定することを目的とした。

アンケートの分析結果から、程度を表す特徴としては pretty, tall, visual propaty, vogueish, device, strident, strong, rock-steadry, bad, quick, showy, gratifying, increasepretty, go, funny という 15 個の特徴が人の選好に特に影響を与える特徴だと分かった。このことは、かわいさ、大きさ、色、かっこよさ、機械らしさ、騒音性、強さ、頼もしさ、危険性、速さ、派手さ、楽しさ、先進性、機能性、面白さという特徴が人の選好に特に影響を与えることを意味している。また、部分を表す特徴としては motor vehicle, hoop, support, movable barrier, source of illumination, opening, front, motor の 9 個の特徴及び lifting device, carrier, vessel, mechanical device, protective covering, hand tool, stairs のような車両に後付できる部品を表す特徴が人の選好に特に影響を与える特徴だと分かった。このことは車全体、タイヤ、架装 (車両に後付できる部品)、席、ドア、屋根、ライト、窓、前面、エンジンという部品についての特徴が人の選好に特に影響を与えることを意味している。目的を表す特徴としては shift, carry, play, pull through, zip, show, set, do work, secure, protect という 10 個の特徴が人の選好に特に影響を与える特徴だと分かった。このことは移動、運ぶ、遊ぶ、助ける、走る、見せる、乗せる、運転、安心させる、守るといった特徴が人の選好に特に影響を与えることを意味して

	着目した部分	程度を表す形容語
単語数	10	15
単語	全体	かわいいと思う
	タイヤ・足回り	大きいと思う
	架装	色が良いと思う
	席	かっこいいと思う
	ドア	機械的だと思う
	屋根	静かだと思う
	ライト	強いと思う
	窓	頼もしいと思う
	前面	心地良いと思う
	エンジン	速いと思う
		派手だと思う
		楽しいと思う
		先進的だと思う
		機能的だと思う
		滑稽だと思う

表 5: 実験 2 以降で選好に関わる特徴として用いる単語

いる。ここで、目的を表す特徴として得られた特徴の内、移動、運ぶ、遊ぶ、走る、見せる、乗せる、運転という特徴は自動車或いはミニカー全体に共通する物だと考えられる。そのため、目的を表す特徴は、自動車というモデル全体に関して人の選好に影響を与える可能性がある。すなわち、自動車というモデルに含まれる個々の物体についての選好には、目的を表す特徴は影響しないことが示唆された。

以上のことから実験 1 の結果として、アンケート調査を通して多くの参加者の選好理由に用いられる特徴を同定することができたことが示された。このことは、どのような特徴が人の選好に影響を与えるのかを明らかにすることができたことを示唆している。

実験 1 の結果から、実験 2 以降は個々の自動車 (ミニカー) に対する選好に関わる特徴として、程度を表す特徴と部分を表す特徴を用いた。程度を表す特徴として、実験 1 の結果から日本語で得られた単語について、単語の意味の正負 (ポジティブ、ネガティブ) が選好に影響を与えないよう、単語の意味を正に統一した。具体的にはポジティブな意味を表す単語 (例: かわいい) はそのまま使用し、ネガティブな意味を表す単語はその対義語を使用した (例: 危険性→心地良さ)。このようにして、実験 2 以降で個々の自動車 (ミニカー) の選好を理由付ける内容として、どの部分に着目したか及びその部分の程度を表す形容語を決定した。決定した単語とその数について表 5 に示す。ここで、架装とは車両に後付で装備されているものを指す単語である。

3 実験 2

実験 2 では 1) 選好について人が着目する部分が認知能力の影響を受けるか明らかにする, 2) 人の選好を決定する特徴空間のモデル化, 3) 選好推定が最も容易と思われる参加者の同定, の大きく 3 つの目的を設定した。

1) に対しては実験 1 から得られた部分を表す単語と, 認知能力の指標の 1 つである AQ との関係进行调查した。2) に対しては実験 1 から得られた程度を表す特徴に対して因子分析を行うことで, 人の選好を決定する特徴空間を潜在要因を用いてモデル化した。3) に対しては 2) で得られた特徴空間を用いて参加者個人の選好をどの程度機械的に推定できるか測定し, 測定結果から選好推定が最も容易な者を同定した。

3.1 参加者と実験計画

実験参加者は 19 歳から 77 歳までの男性 286 人, 女性 156 人であった ($M_{age} = 43.69, SD_{age} = 11.40$)。実験参加者の内, 追加で実施したアンケートのために選ばれた参加者については, 25 歳から 71 歳までの男性 16 人, 女性 9 人であった ($M_{age} = 45.56, SD_{age} = 10.45$)。選ばれた参加者について, 実験計画は 1 要因 (AQ: 高 AQ, 低 AQ) 参加者間要因配置であった。

3.2 測定方法

実験 2 の参加者には Web 上で行うアンケートへの回答を求めた。実験 1 と同様に, Qualtrics を用いてアンケートの作成を行い, Yahoo クラウドソーシングを用いて参加者の募集とそのタスク中でアンケートの実施を行った。

3.2.1 AQ の計測

個人の認知能力の指標について重要な物の 1 つに, 自閉症傾向を示す自閉症スペクトラム指数 (AQ) がある。AQ が高い人, すなわち自閉症傾向が強い人は定型発達者と比較して「特定の要因に強く拘る」, 「物事を抽象化しその意図を捉えることが困難」という特徴がある。選好に関しては, 自閉症傾向の強い人は対象の物体の一部分に強く拘り選好を決定する可能性が考えられる。また類似した複数の物体について, 定型発達者はこれらを抽象的に同じ物として捉え同じ選好を持つ可能性が考えられるのに対し, 自閉症傾向の強い人はこれらを別個としてみなすため選好が分かれる可能性が考えられる。このため, 人の選好に影響を与える特

徴を定量的に調査するとき, 実験参加者の AQ による影響を考える必要がある。

AQ によって選好が変化するかを調査するために, 事前調査として参加者の AQ を計測した。先行研究として若林ら [2] が作成したものと同様のアンケートを web 上で実施し, アンケートの回答から参加者の AQ を求めた。アンケートは 50 問の普段の生活にまつわる質問から構成され, それぞれの質問に対して「1. そうである」, 「2. どちらかといえばそうである」, 「3. どちらかといえばそうでない」, 「4. そうでない」の 4 段階の尺度で回答を求めた。1 つの質問に対する回答によって, AQ は 1 点加算されるか変化しないかが決まる。したがって, それぞれの参加者について AQ は 0 点から 50 点までの数値を取る。若林は, AQ が 33 点以上であれば自閉症傾向を持っていると述べている。そのため AQ が 33 点以上の参加者 (高 AQ) と, 対比として AQ が 17 点以下の参加者 (低 AQ) を同程度の人数分選抜することで, AQ 条件についての比較を行った。また高 AQ 群と低 AQ 群の参加者に対して以降の節 3.2.2, 3.2.3 で示すアンケートやクイズを追加で実施することで, AQ の影響を小さくした上で人の選好に影響を与える特徴について調査を行った。

3.2.2 認識における顕著特徴の計測

節 3.2.1 で示した群に選抜した参加者に対して, Web 上で行うアンケートを引き続き実施した。このアンケートでは図 3 に示す通り, 1 つのミニカーにつき 1 つの画像と, 16 問の質問を提示した。第 1 問はミニカーに対する選好を「好き」或いは「嫌い」の選択肢からどちらかを選んで回答するよう求めた。第 2 問から第 16 問では, 実験 1 の結果から得られた程度を表す形容語について, どの程度同意するか 7 軸リッカート尺度で回答を求めた。評価が 1 に近いほど形容語に対して強い不同意を表し, 評価が 7 に近いほど形容語に対して強い同意を表す。また単語への同意の程度について, ミニカーのどの部分に着目したかについて回答を求めた。アンケートに用いた程度を表す形容語と着目した部分についての選択肢は表 5 で示した通りである。また, 第 1 問には必ず回答するよう求めた。第 2 問から第 16 問には, 形容語への同意の程度は選択肢の中から必ず 1 つを選んで回答を求め, 着目した部分については選択肢の中から少なくとも 1 つを選んで回答するよう求めた。ただし, 形容語への同意の程度について「1. 全く同意しない」と回答した場合には, 参加者はミニカー内のいずれの部分に着目しても同意できなかったと考えられることから, 着目した部分について「全体」のみ回答するよう求めた。選抜した参加者それぞれに対して, 以上のアンケート内容を 112 個のミニカー全てについて繰り返し回答するよう求めた。順序効果の

影響を小さくするため、選抜した参加者に提示するミニカーの順序はランダムに設定した。



(a) 第1問.



(b) 第2～16問.

図 3: 実験 2 で選抜した参加者に提示したアンケート画面.

3.2.3 架装

実験 1 の結果から、クレーン、荷台、タンク、ポンプ、シャベル、梯子という部分を表す特徴が人の選好に影響を与えることが分かった。これらの単語に共通する概念として、車両に後付けで装備されている物を指す単語である架装を取り上げた。普段聞き慣れない単語であるため、節 3.2.2 で示すアンケートを開始する直前に選抜した参加者に架装を理解させるためのクイズを行った。具体的には、ミニカーの画像とミニカー内の部品を示す選択肢を提示し、架装が含まれる選択肢を全て回答するように参加者に求めた。なお、架装が含まれないミニカーにはいずれの選択肢も選ばず回答するように求めた。このクイズを 2 問作成し、参加者に各クイズについて正答後に次のクイズまたは節 3.2.2 で示すアンケートに進むよう求めた。クイズの内容を図 4 に示す。クイズで提示したミニカー及び選択肢は選抜した参加者間で同一の物を使用した。

3.2.4 分析方法

AQ と着目した部分について

追加で実施したアンケートについて、車全体或いは車のいずれか一部分に着目したかを計測した。具体的には、アンケート中の単語への同意の程度に対して、ミ



(a) 第1問. 正解は「荷台」及び「前方のシャベル」.



(b) 第2問. 正解は無し (いずれの回答欄にもチェックを入れない).

図 4: 架装について出題した 2 問のクイズとその正解.

ニカーのどの部分に着目したのかについての回答に「全体」と回答したかそれ以外の部分(「タイヤ・足回り」、「架装」、「席」、「ドア」、「屋根」、「ライト」、「窓」、「前面」、「エンジン」のいずれか)を回答したのか計測した。選抜した参加者それぞれについて 112 個のミニカー全てに対する回答を計測対象とした。また、選抜した参加者の群(高 AQ, 低 AQ)間で「全体」あるいはそれ以外の部分についての回答数に差が生じるかを明らかにするために、計測した回答数に対して AQ(高, 低)と着目点(全体, 部分)を要因とした 2 元配置分散分析を行った。

選好を表現する手法

選抜した各参加者の選好を推定する際に、決定木、ランダムフォレスト、サポートベクターマシン(SVM)の 3 つを機械学習の手法として用いた。

決定木とは、いくつかの基準を用いてデータを段階的に分割する手法である。例えば、脊椎動物の分類を図 5 に示す。図 5 で示した例の中で、子の産み方、卵の殻、体温、鱗、という分類の際に基準となるもの説明変数、分類するクラス(魚類、両生類、鳥類、爬虫類、哺乳類)となるものを目的変数という。目的変数は図 5 の例のように複数の説明変数で説明できるので、解析結果を直感的に理解しやすいことが決定木の特徴だと言える。図 5 において四角で囲まれた点のように、決定木の中で分類の途中にある点をノードと呼ぶ。決定木の学習では、1 つのノードに異なるクラスがどの程度の割合で存在するかを示した不純度という指標を用いて、

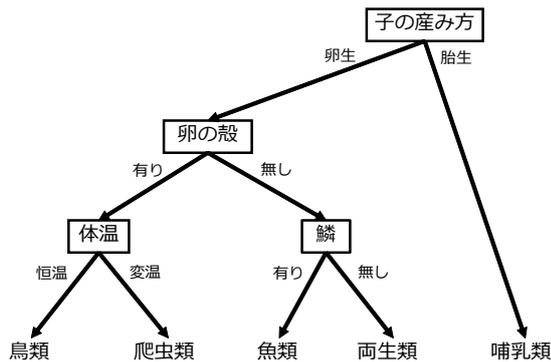


図 5: 決定木の例 (脊椎動物の分類).

不純度が小さくなるようにデータの分割を行う。不純度としてよく用いられるのはエントロピーとジニ不純度である。決定木の手法の中でもエントロピーを用いる物の1つがC4.5(または改善版であるC5.0)で、ジニ不純度を用いる物の1つがCARTである。ノード t におけるエントロピーを $E(t)$ 、ジニ不純度を $G(t)$ 、各クラスを i 、ノード t に存在する全てのクラスを N として、エントロピーは式1、ジニ不純度は式2で表される。データの分割を細かくするほどより高精度にクラス識別が可能になるが、データセットへの過学習を引き起こす恐れもある。そのため決定木の学習においては、不純度に何をを用いるのかに加えデータの分割の程度(決定木の深さ)も重要な指標となる。

$$E(t) = - \sum_{i=1}^N P(i|t) \log_2(P(i|t)) \quad (1)$$

$$G(t) = 1 - \sum_{i=1}^N P(i|t)^2 \quad (2)$$

クラス分類に対して決定木を弱識別器とし、複数の弱識別器をアンサンブル学習する手法がランダムフォレストである。1つ1つの弱学習器作成の際には、データセットから作成に使用するデータをランダムサンプリングする。このように決定木同士の類似性を低くすることで、アンサンブル学習により高精度のクラス識別を可能にしている。アンサンブル学習の精度に関わるため、ランダムフォレストでは決定木の深さに加え、作成する決定木(弱識別器)の数も重要な指標となる。また、ランダムフォレストでは説明変数の重要度を計測することができる。説明変数の重要度はまず1つ1つの弱識別器において、説明変数の値をサンプル(参加者)間でシャッフルした時、どの程度識別精度が減少するかを求める。識別精度が大きく変化すれば重要な説明変数であり、識別精度にあまり変化が無ければ重要な説明変数だと言える。これを弱識別器間で多数

	正解が正	正解が負
予測が正	TP	FP
予測が負	TN	FN

表 6: 二値分類の正解・不正解の分類。

決を取りランダムフォレスト全体での説明変数の重要性を算出する。

SVMは決定木と同じくクラス識別を行うための教師あり学習の手法である。特徴空間上にデータをプロットし、データのクラスを分割する超平面を考える。各クラス間で最も近いベクトルを選択し、選択したベクトル(サポートベクトル)と境界となる超平面との距離(マージン)が最大になるように境界を引く。境界は線形の境界の他に、カーネル法を用いて非線形の境界を考えることができる。非線形の境界を考える際にはRBF(Radial Basis Function)を用いたカーネル法がよく使用される。SVMがどの程度認識誤りを許容するかを示したものとして、正則化パラメータ C がある。 C の値が大きいほど入力データを正確に識別するので、 C の値が大きいほど境界は複雑になり、過学習を起こす可能性が高まる。このため C の値はSVMを考える上で重要な指標となる。また、どの程度境界から離れたベクトルのマージンを考慮するかを示した γ という指標もSVMを考える上で重要である。 γ が大きいほど境界から近い点とのマージンを考慮するので、境界はより複雑になる。

以上3つの手法について、Pythonの機械学習ライブラリであるscikit-learnを用いて機械学習を実行し、選抜した各参加者の選好のモデル化を行った。決定木の手法についてはCARTを使用した。選好モデルの評価はAccuracyを用いた。Accuracyは二値分類(本研究では好き、または嫌い)において、全ての予測に対する正答率を示す。二値分類の正解・不正解を図6に示す4つに分類する。図6においてFPは第1種の誤り、TNは第2種の誤りと呼ぶ。図6で示したTP, FP, TN, FNを用いて、Accuracyは式3で表される。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

選好の推定とモデル化

追加で実施したアンケートについて、アンケート中の程度を表す形容語への同意の程度についての回答に対して因子分析を行った。因子分析の結果から、人の選好に影響を与える潜在要因を同定した。また因子分析の結果から得られる因子得点について、112個のミニカーそれぞれに対して参加者間の平均を算出した。算出した各因子得点の平均に加え、選抜した参加者個々

ハイパーパラメータ	交差検証に用いた値
バリデーション数	5
評価基準 (決定木)	エントロピー, ジニ不純度
最大深さ (決定木)	1, 2, 3, 4, 5, 6
評価基準 (RF)	エントロピー, ジニ不純度
最大深さ (RF)	1, 2, 3, 4, 5, 6
木の数 (RF)	10, 20, 30, 40, 50, 60, 70, 80, 90, 100
カーネル (SVM)	線形, 非線形 (RBF)
C(SVM)	1, 10, 100, 1000
gamma(SVM, RBF)	0.001, 0.0001

表 7: 実験 2 の参加者の選好推定に用いるハイパーパラメータ. RF はランダムフォレストを表す.

人の 112 個のミニカーそれぞれに対する選好を選好推定の対象データセットとした. データセットは選抜した参加者の人数分別々に作成し, 各因子得点の平均を説明変数, 選抜した参加者の内いずれか 1 人について 112 個のミニカーそれぞれに対する選好を目的変数とした. ここで, データセット間で目的変数は異なるが, 説明変数は共通の値を用いた. 各データセットの目的変数と説明変数から決定木, ランダムフォレスト, SVM の手法から選好モデルを作成し, 各データセットに用いた参加者の選好を因子で表現できるか調査した. 選好モデルの作成について, 112 個のミニカーについてのデータセットを 6:4, 7:3, 8:2 のいずれかの割合で学習と予測に分割した. 学習に用いるハイパーパラメータは表 7 に示す値の内から交差検証法を用いて決定した. 作成した選好モデルの選好推定能力について明らかにするために予測データに対する Accuracy を測定した. また作成した選好モデルを参加者間で比較できるよう, 学習の際のランダムサンプリングのシード値は一意に固定して行った.

3.2.5 分析手法

アンケートから得られたデータに対して行った 2 元配置分散分析及び因子分析については統計処理ソフトウェアの 1 つである IBM SPSS Statistics バージョン 25 を用いて行った.

3.3 手順

実験 2 の手順は以下の通りであった.

1. 全ての実験参加者に対して以下の手順を行った.

	高 AQ	低 AQ	それ以外
全ての参加者	58	81	303
選抜した参加者	12	13	0

表 8: 各群の全て及び選抜した参加者の人数

- (a) 実験 2 の参加者に対し, 実験内容を文章で説明した後, Web 上で実験参加の同意を取る.
 - (b) AQ についてのアンケートを実施する.
2. AQ の値に対して 33 以上 (高 AQ) または 17 以下 (低 AQ) の群に同程度の人数を選抜する.
3. 選抜した参加者に対して以下の手順を行う.
 - (a) 節 3.2.3 で示す架装についてのクイズを実施する.
 - (b) 節 3.2.2 で示すアンケートを実施する. なお参加者にはアンケートの途中で適宜休憩を入れることを許可した.

3.4 実験結果

実験 2 の全ての参加者の AQ について, 図 6 に示す. 参加者の AQ の平均は 23.99 になった. 全ての参加者の内, AQ が 33 以上 (高 AQ) または 17 以下 (低 AQ) となる者から一定数を選抜した. 選抜した参加者に対して節 3.2.2, 3.2.3 で示すアンケートやクイズを実施した. 実験 2 全体の参加者数と選抜した参加者数について, 高 AQ 群, 低 AQ 群及びそれ以外の群ごとに表 8 に示す.

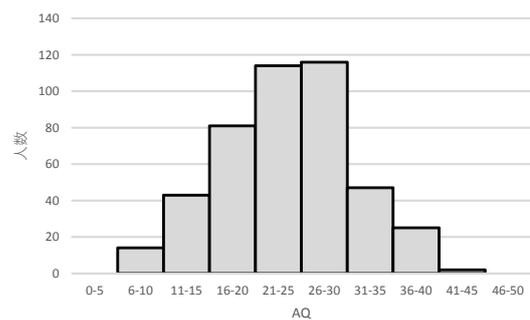


図 6: 参加者の AQ ヒストグラム.

選抜した参加者について, ミニカーについて「全体」またはそれ以外の部分に着目したと答えた回答数と AQ の関係を図 7 に示す. また高 AQ と低 AQ の各群において, 「全体」またはそれ以外の部分についての回答数の平均を図 8 及び表 9 に示す. 高 AQ と低 AQ の群間で「全体」及びそれ以外の部分についての回答数に差が生じ

	全体	部分
高 AQ	1375	516.08
低 AQ	1435.85	287.38

表 9: AQ 要因と着目点要因における回答数の平均

るかを明らかにするため、AQ(高, 低)と着目点(全体, 部分)を要因とした 2 元配置分散分析を行った。分析の結果、AQ 要因については主効果が確認されなかった ($F(1, 46) = 0.51, p = .48$) が、着目点要因には主効果が確認された ($F(1, 46) = 72.97, p < .001$)。また、交互作用は確認されなかった ($F(1, 46) = 1.52, p = .22$)。このことは、選抜した参加者は AQ によらず、ミニカーの一部よりも全体を重視して選好を決定したことを示す。

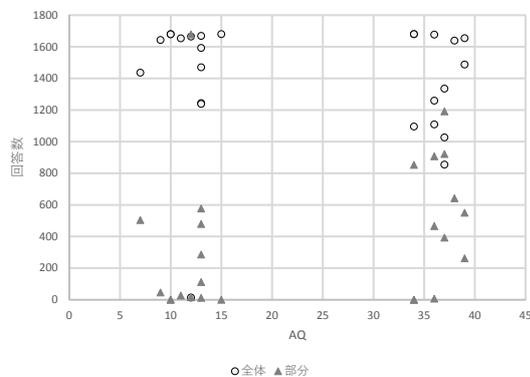


図 7: AQ と選好に関して着目した部分の回答数。

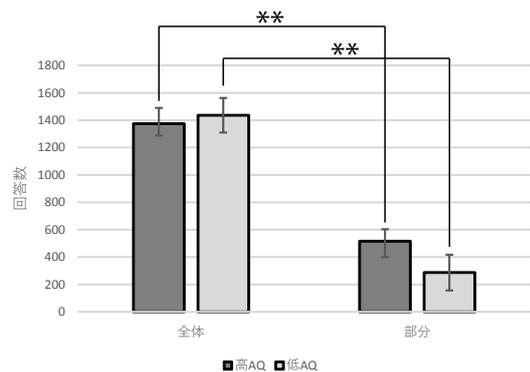


図 8: ミニカーの着目点の対する回答数の平均。エラーバーは標準誤差を示す。有意差は 2 元配置分散分析結果を表す。 $**p < .001$ 。

特徴を表す単語への同意の程度について、選抜した参加者の回答に対して因子分析を行った。因子の抽出には最尤法を用い、回転には Kaiser の正規化を伴うプロマックス法を用いた。因子分析の結果、固有値が 1

因子	固有値	初期解	
		寄与率	累積寄与率
1	6.25	41.67%	41.67%
2	1.85	12.32%	53.99%
3	1.13	7.51%	61.50%
4	1.07	7.11%	68.61%
5	0.95	6.30%	74.91%
6	0.55	3.64%	78.55%
7	0.54	3.61%	82.16%
8	0.49	3.24%	85.39%
9	0.43	2.84%	88.23%
10	0.38	2.51%	90.74%
11	0.37	2.45%	93.19%
12	0.33	2.19%	95.38%
13	0.27	1.81%	97.19%
14	0.23	1.55%	98.74%
15	0.19	1.26%	100.00%

表 10: 固有値表

以上となる因子が 4 つ抽出された。これらの因子を人の選好に影響を与える因子と判断した。固有値表を表 10 に、固有値スクリープロットを図 9 にそれぞれ示す。ここで第 5 因子に着目する。第 5 因子は固有値が 0.95 と 1 に近く、また図 9 の固有値スクリープロットを見ると第 6 因子以降で固有値が大きく減少していることが見て取れる。このことから第 5 因子も人の選好に影響を与える因子と判断し、選好のモデル化に用いた。人の選好に影響を与えるとして抽出した 5 つの因子について、因子パターン行列を表 11 に示す。

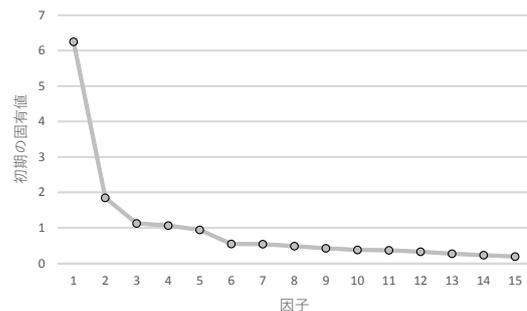


図 9: 因子スクリープロット

第 1 因子について負荷量が高い項目には強い、大きい、機能的といった強さや性能が優れていることを示す単語が並んだ。逆に負の負荷量が高い項目には速い、かわいいという傷つきやすく、また利便性とは別の要素に特化しているような印象を与える単語が並んだ。このことから第 1 因子を「強大性及び機能性」と命名した。第 2 因子について負荷量が高い項目にはかわいい、

変数	因子				
	1	2	3	4	5
強い	0.94	-0.11	0.01	0.04	-0.10
頼もしい	0.88	-0.07	0.07	0.04	-0.16
機械的	0.81	-0.10	-0.05	-0.01	0.07
大きい	0.79	0.03	-0.02	-0.38	0.07
機能的	0.74	0.03	0.12	-0.03	0.07
かわいい	-0.18	0.91	0.11	-0.30	0.06
色が良い	0.11	0.70	0.04	-0.07	-0.19
楽しい	-0.01	0.67	0.18	0.01	0.13
かっこいい	0.11	0.63	-0.12	0.26	-0.29
心地良い	0.13	0.13	0.67	0.15	0.06
静か	-0.02	0.11	0.66	0.08	0.06
速い	-0.20	-0.25	0.14	1.10	-0.02
先進的	0.36	0.18	-0.03	0.36	0.13
滑稽	-0.02	-0.05	0.10	-0.00	0.49
派手	0.20	0.30	-0.21	0.28	0.36

表 11: 因子パターン行列

色が良い、楽しいといった自分や他者共に喜ばせることをイメージさせる単語が並んだ。逆に負の負荷量が高い項目には速い、強い、機械的という競争など一方は喜ぶものの他方はネガティブな感情を抱かせる事柄をイメージさせる単語が並んだ。このことから第2因子を「楽しさ」と命名した。第3因子について負荷量が高い項目には心地よい、静かといった自身や他者に、共に穏やかさを感じさせる単語が並んだ。逆に負の負荷量が高い項目には派手、かっこいい、機械的という落ち着いた印象を与える単語が並んだ。このことから第3因子を「ファミリー性」と命名した。第4因子について負荷量が高い項目には速い、先進的、派手といった単にスピードが秀でているだけでなく、自動車の将来的な発展性を感じさせる単語が並んだ。逆に負の負荷量が高い項目には大きい、かわいいといった遅く、近未来やそれ以上の将来を感じさせない単語が並んだ。このことから第4因子を「スーパーカー性」と命名した。第5因子について負荷量が高い項目には滑稽、派手、先進的といった他者に自動車を強く印象付ける攻撃的なイメージを連想させる単語が並んだ。逆に負の負荷量が高い項目にはかっこいい、色が良い、頼もしいといった他者が与える刺激から自身を守る力があると印象づける単語が並んだ。このことから第5因子を「防衛性」と命名した。以上の因子分析の結果は、人の自動車に対する選好を説明する潜在要因は1) 強大性及び機能性、2) 楽しさ、3) ファミリー性、4) スーパーカー性、5) 防衛性、の5つであることを示している。

因子分析の結果、選抜した参加者のアンケート回答から5つの因子ごとに因子得点を算出した。112個のミニ

因子	ミニカー			
	No.1	No.2	...	No.112
1: 強大性及び機能性	-0.20	-0.07	...	0.52
2: 楽しさ	-0.07	-0.18	...	0.01
3: ファミリー性	0.03	0.40	...	-0.59
4: スーパーカー性	0.10	0.72	...	-0.37
5: 防衛性	-0.01	-0.20	...	0.07

表 12: ミニカーごとの因子得点の参加者間平均。

ニカーそれぞれに対して、選抜した参加者間の各因子得点の平均を算出した。算出した各因子得点の平均について、一部のミニカーにおける値を表12に示す。ここで、112個のミニカーに対する選抜した参加者間の各因子得点の平均を説明変数、112個のミニカーに対する選抜した参加者それぞれの選好を目的変数として、決定木、ランダムフォレスト、SVMの機械学習の手法を用いて、25人の選抜した参加者それぞれの選好をモデル化した。この内予測データのAccuracyが高い物が選好の推定が容易だと判断した。更に112個のミニカーを6:4, 7:3, 8:2のいずれかの割合で学習と予測に分割したことから、いずれの分割割合においても予測データのAccuracyが高くなる選好モデルが選好の推定がより容易な物だと判断した。また提示するミニカーの数を112個から無限大に大きくしていくと、参加者が好きなミニカーも嫌いなミニカーも共に無限大に増加すると考えられる。このため選抜した参加者の選好について、本研究で用いた112個のミニカーに限らず自動車に対する広い選好を考えると、好きな物の数と嫌いな物の数の差は小さくなると考えられる。したがって25人の選抜した参加者の内、好きなミニカーの数と嫌いなミニカーの数の差が小さい方がより選好推定が容易だと判断した。以上の基準から、25人の選抜した参加者の中で、選好の推定が最も容易だと判断した参加者(選好対象者)を選択した。選好対象者について、選好によるミニカーの数、データセットを学習と予測に分割した割合、学習に用いたハイパーパラメータの値、予測データのAccuracyを表13に示す。表13中で学習データのミニカーが89個、予測データのミニカーが23個であることは、112個のミニカーを8:2の割合で学習と予測に分割したことを示す。選好対象者について、選好を説明する決定木を図10に、ランダムフォレストの結果から得た5つの因子の重要度を図11に示す。また選好対象者が好きなミニカー群と嫌いなミニカー群に対して、群ごとにミニカー間の各因子得点の平均を図12に示す。表13から決定木、ランダムフォレスト、SVMのいずれの手法でも予測データの

好きなミニカー	69 個
嫌いなミニカー	43 個
学習データのミニカー	89 個
予測データのミニカー	23 個
学習データのバリデーション数	5
決定木の評価基準	ジニ係数
決定木の深さの最大値	3
決定木の Accuracy	0.87
ランダムフォレストの木の評価基準	ジニ係数
ランダムフォレストの木の深さの最大値	4
ランダムフォレストの木の数	20
ランダムフォレストの Accuracy	0.87
SVM のカーネル	線形
SVM の正規化パラメータ	10
SVM のカーネルのバンド幅	なし
SVM の Accuracy	0.91

表 13: 選好対象者について、選好ごとのミニカーの数と各手法のハイパーパラメータ及び Accuracy

Accuracy が 0.85 以上と高い数値となっていたことが分かる。また図 11 から得られた各因子の重要度の順と、図 10 に示す決定木の最上位のノードから順に分類に用いた因子の順に大きな矛盾はないことが分かる。図 12 から得られるミニカーの選好間の差が大きい因子の順についても同様に決定木や因子の重要度と大きな矛盾はないことが分かる。以上のことは、ロボット (コンピュータ) が選好対象者の選好を理解することができたことを示している。

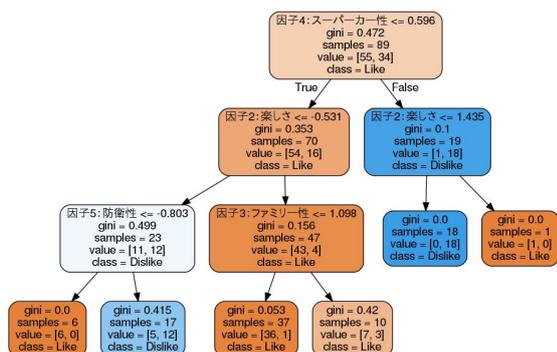


図 10: 選好対象者の選好を説明する決定木

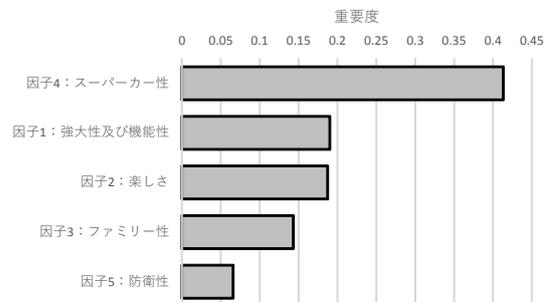


図 11: 選好対象者の選好推定における各因子の重要度

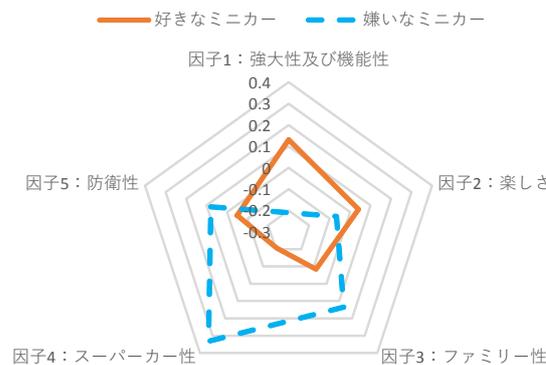


図 12: 選好対象者について、選好による因子得点平均を表したレーダーチャート

3.5 議論

実験 2 では 1) 選好について人が着目する部分が認知能力の影響を受けるか明らかにする, 2) 人の選好を決定する特徴空間のモデル化, 3) 選好推定が最も容易と思われる参加者の同定, の大きく 3 つの目的を設定し

た。これら3つの目的を満たすため、参加者にはAQについてのアンケートや提示されたミニカーに対して実験1で得られた程度と部分に関する特徴にどの程度同意するか回答を求めるアンケートをWeb上で実施した。

1)の目的に対しては、分析の結果選抜した参加者はAQによらず、ミニカーの一部よりも全体を重視して選好を決定したことが示された。このことから、自閉症傾向による認知能力の差は人の選好に影響を与えないことや、人は対象の一部よりも全体を見て選好を決定していることが示唆された。

2)の目的に対しては、因子分析の結果、1)強大性及び機能性、2)楽しさ、3)ファミリー性、4)スーパーカー性、5)防衛性の5つの因子が得られた。したがってこの5つの因子がミニカーについての選好を説明する潜在要因であることが示された。このことから、人の選好を決定する特徴空間がこの5つの因子を特徴軸として表現できることが示唆された。

3)の目的に対しては、決定木やランダムフォレストおよびサポートベクターマシン(SVM)の3つの手法で機械学習を行った結果、ロボット(コンピュータ)が選好推定が最も容易と思われる参加者(選好対象者)の選好を理解できたことが示された。以上のことから、ロボット(コンピュータ)は特定個人の選好理解ができる可能性が示唆された。

実験3では人とロボットが相互に空気を読んだ行動が実現できるか明らかにするために、選好対象者の選好モデルをロボットに搭載し、人がロボットの選好を理解できるか調査する。

4 実験3

実験3では、実験2で選好の推定が最も容易だと判断した参加者(選好対象者)の選好モデルをロボットに搭載し、人がロボットの選好を推定できるか明らかにすることを目的とした。人がロボットとのインタラクションを通して対象の選好を推定することができれば、実験2でロボット(コンピュータ)が特定個人の選好を理解できたことと合わせて、人とロボットが相互に選好を理解し空気を読んだ行動が可能であると明らかにすることが予想された。

4.1 参加者と実験計画

実験参加者は18歳から24歳までの男性22人、女性5人であった($M_{age} = 20.22$, $SD_{age} = 21.15$)。また後述の節4.6から、実験参加者の内分析に使用した参加者については19歳から21歳までの男性13人、女性5人であった($M_{age} = 19.94$, $SD_{age} = 19.89$)。

4.2 装置

4.2.1 自律ロボット Prefer

実験3では実験装置として自律ロボット Prefer を開発した。Prefer は本論文の共著者である小嶋らによって開発された7軸ロボットアームにUSBカメラを3つ取り付けられたものである。Prefer はUSBカメラでミニカーを認識し、搭載された選好に基づき以下のように行動を出力する。

- 好きなものに対する行動: 対象のミニカーに接近
- 嫌いなものに対する行動: 対象のミニカーを回避

また、図13にPreferの行動出力の例を示す。ミニカーの認識はYOLOを用いた。Preferに搭載する選好は、実験2で決定した選好対象者の選好モデルを使用した。



図13: Preferの行動出力。

YOLOを用いたミニカーの認識

YOLO(You Only Look Once)とは物体認識アルゴリズムの1つである。YOLOでは画像の全体をグリッドに分割し、各領域に対してクラスの予測確率とバウンディングボックスを求める。学習や予測に画像全体の情報を用いるため、背景を物体と誤検出する確率が従来手法と比較して低く抑えることを実現している。また、YOLOはクラスとバウンディングボックスの予測を1つのCNN(Convolutional Neural Network)で完結させる。このため従来手法と比較して処理速度に優れており、リアルタイムの物体認識に適している。

実験3ではPreferと参加者間のインタラクションを人同士のインタラクションにより近づけるため、リアルタイムでPreferへのミニカーの提示と提示されたミニカーに対するPreferの反応行動出力が求められた。そのため提示されたミニカーの認識にYOLOを用いることにした。特に最新のアップデートとして用意されているYOLOv3[3]を使用した。したがって本研究では実験3の前処理として、YOLOを用いた112個のミニカーに対する学習と認識を行った。本研究では1個のミニカーを1つのクラスとし、合計112クラスを作成した。作成した112クラスに対して、YOLOを用いて学習と認識を行った。ミニカーを様々な角度から撮影した動画を用

評価指標	値
iteration	90500
mAP	99.3
loss	0.0476

表 14: YOLO の学習終了時の iteration, mAP 及び loss.

意し, これからフレームで切り出した画像を学習データとした. また切り出した画像を 0, 30, 45, 60, 90, 120, 135, 150, 180, 300, 315, 330, 355 の角度でそれぞれ回転させた画像も学習データに用いることで, 学習データを拡張させ角度への頑健性を持たせた. YOLO を用いた 112 クラス分類について, 学習の結果として学習終了時における iteration, mAP(mean Average Precision), loss を表 14 に示す. ここで, iteration は学習の繰り返し数を表す. loss はテストデータに対する損失関数の値を表し, 0 に近いほど汎化性能が出ていると言える. 時点 i で正しく認識した正解クラスの総数を N , 時点 i で現れた正解クラスの内, 正しく認識できた数を H_i , 時点 i で現れた正解クラスの数 n_i を用いて時点 i での平均適合率 AP_i が式 4 で表されるとき, 時間情報も含めた平均的な正答率を表す mAP は AP_i と画素の総数 M を用いて式 5 で表される.

$$AP_i = \frac{1}{N} \sum_{i=1}^I \frac{H_i}{n_i} \quad (4)$$

$$mAP = \frac{1}{M} \sum_{i=1}^M AP_i \quad (5)$$

Prefer は図 14 に示す 2 つの USB カメラから得られたそれぞれの映像に対して, YOLO を用いてリアルタイムで認識を行った. また 1 つのカメラは OpenCV の物体認識アルゴリズムを用いて, YOLO が好きなものに近づきつづける際のトラッキング制御の補助に用いた. 2 つのカメラそれぞれの映像から YOLO を用いて物体を認識し, 認識結果から Prefer の制御を行うフローチャートについて, 図 15 に示す.

4.2.2 AQ の計測

AQ が Prefer の選好推定に影響を及ぼすのかを調査するために, 実験 3 の参加者の AQ を計測した. アンケートは実験 2 で行ったものと同様の内容を Qualtrics を用いて作成した. 実験 3 の参加者には実験環境内のコンピュータから当該 Web ページにアクセスし, アンケートに回答するように求めた.



図 14: Prefer の顔部分. 点灯しているカメラの映像に YOLO を用いる. 点灯していないカメラの映像には OpenCV のみを用いる.

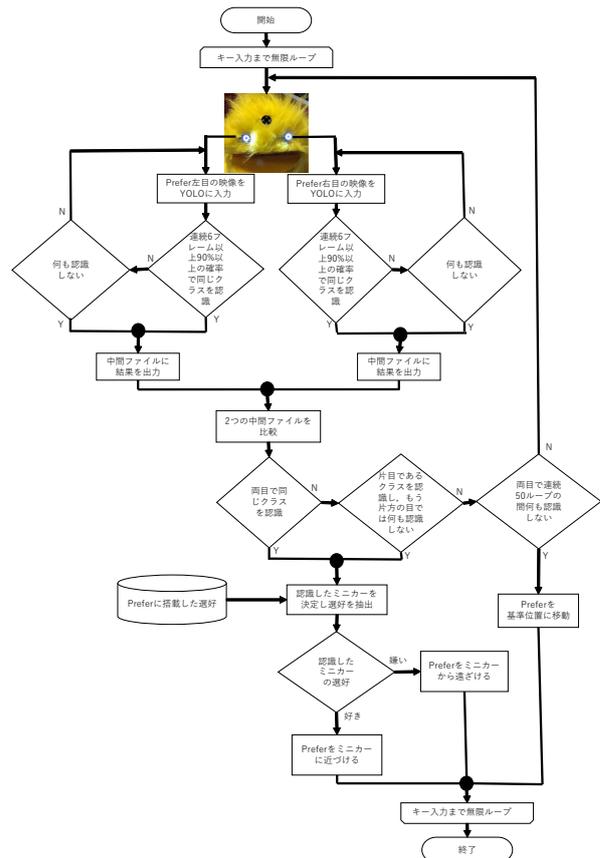


図 15: ミニカーの認識と Prefer 制御のフローチャート

4.2.3 インストラクション

インストラクションとして、実験3の参加者が正常にミニカーを Prefer に提示できるよう、文章及び口頭で説明を行った。更に、説明を正しく理解できたか調べるために、参加者にはミニカーとは別のおもちゃを実際に Prefer に提示するよう求めた。別のおもちゃとして、自動車と同じく1種類の対象領域の中に多様な個体が含まれることやひと目で見てどのようなものなのか判別できることに加え、自動車とは明らかに異なる対象領域であると参加者が認識できる物が好ましいと考えられた。そのため、本研究ではインストラクションとして食品サンプルを選択した。

Prefer はミニカーと同様に、USB カメラを用いて食品サンプルを認識する。食品サンプルの認識はミニカーと同様に YOLO を用いた。Prefer は食品サンプルを認識すると、食品サンプルの種類を問わず口を開く行動を出力する。この行動出力の様子を図16に示す。実験3の参加者には、インストラクション内における Prefer の行動出力は選好に影響しないことを予め説明した。



図 16: Prefer に食品サンプルを提示した時の行動出力。

4.2.4 Prefer に提示する物の数と順序効果

実験3では使用するミニカーを次の2群に分割し、後者について実験参加者が Prefer の選好を推定できるか調査した。

1. 学習群: 実験参加者が Prefer に提示するミニカー。実験参加者は Prefer にミニカーを提示し、Prefer の行動出力を観察するよう求めた。
2. テスト群: 実験者が実験参加者に提示するミニカー。実験参加者は学習群の結果を踏まえ、提示されたミニカーについて Prefer の選好を回答するよう求めた。

実験2の結果において、Prefer に搭載した選好モデルの算出には、表13に示す通り112個のミニカーを8:2の割合で学習と予測に分割した。そのため実験3では同様に112個のミニカーを8:2の割合で学習群

対象物	提示者	被提示者	提示数
食品サンプル	参加者	Prefer	3
ミニカー (学習)	参加者	Prefer	89
ミニカー (テスト)	実験者	参加者	23

表 15: 提示する対象物とその提示数、及び提示者と被提示者

とテスト群に分割し、実験3のテスト群についての参加者の回答と Prefer に搭載した選好を比較するよう設定した。ここで112個のミニカーを8:2の割合で分割すると89個と23個に分割できる。また節4.2.3で述べたように参加者が食品サンプルを Prefer に提示する際、提示数はインストラクションの確認程度であることを踏まえ3つとした。以上で述べた提示数について纏めた物を、表15に示す。また、順序効果の影響を小さくするための統制も行った。食品サンプルは全16個の中から参加者ごとにランダムに3個を選出した。ミニカーは全112個を参加者ごとにランダムに並べ、前半の89個を学習群、後半の23個をテスト群と設定した。

4.2.5 因子の重要性についてのアンケート

実験3の参加者が Prefer の選好を正しく推定できたか調査するために、テスト群のミニカーに対する Prefer の選好推定が終了した後に、書面でアンケートを行った。アンケートの内容の一部を図17に示す。実験2の結果から得られた人の選好に影響を与える5つの因子(例: 強大性及び機能性)をアンケート中に提示し、提示した因子が Prefer の選好を構成する上でどの程度重要視されるかを7軸リッカート尺度で回答するよう参加者に求めた。評価が1に近いほど質問文中の因子に対して強い不同意を表し、評価が7に近いほど質問文中の因子に対して強い同意を表す。なおアンケート中において「因子」という単語は用いず、代わりにより普段の生活で馴染みのある「要因」という単語を用いた。アンケート中では提示した因子の説明として、提示した因子に共通して含まれる概念を提示した。共通して含まれる概念は実験2で程度を表す形容語として使用した単語の内、表11を基に共通して含まれる概念の説明として適切な単語を選択した。アンケート中に提示した因子の更なる説明として、実験2で得られた各因子得点の平均値を基に、提示した因子が強く現れるミニカーと弱く現れるミニカーを適切にそれぞれ5つずつ選択した。アンケート中には選択したミニカーの画像を各因子(要因)の説明のために提示した。

ロボットの好き嫌いを構成する上で、以下の要因がどの程度重視されると思いますか？

強大性及び機能性

強大性及び機能性は強い、頼もしい、機械的、大きい、機能的という概念に共通して含まれる概念です。

例えば以下の車は強大性及び機能性が強いと思われる。



また、以下の車は強大性及び機能性が弱いと思われず、速い、かわいいの概念は強大性及び機能性が弱いという共通点があります。



1. 全く重視しない 2. 重視しない 3. あまり重視しない 4. どちらでもない 5. 少し重視する 6. 重視する 7. 強く重視する



図 17: 実験 3 で参加者に実施したアンケートの一部

4.3 手順

実験 3 の手順は以下の通りであった。

1. 順序効果の影響を小さくするため、食品サンプルをランダムに抽出し、ミニカーをランダムに並べた。ミニカーは前半の 89 個を以降の手順 (6) で使用し、後半の 23 個は以降の手順 (7) で使用した。
2. 実験 3 の参加者に対し、実験内容を説明した後、文書による実験参加の同意を取得した。
3. 参加者の AQ を得るために、実験環境内のコンピュータを用いて web 上でアンケートを行った。
4. 参加者が正常にミニカーを Prefer に提示できるよう、文章及び口頭で説明を行った。
5. 参加者が Prefer へのミニカーの提示方法を理解できたか確認するため、食品サンプルを Prefer に提示し行動出力を観察するよう求めた。
6. 参加者には 89 個のミニカーを 1 個ずつ Prefer に提示するよう求めた。更に、Prefer の行動出力を観察することで、Prefer の選好を推定するよう求めた。参加者にはあるミニカーに対する Prefer の行動出力を観察し、Prefer が基準位置に戻ったことを確認してから、次のミニカーを Prefer に提示するよう求めた。Prefer の行動出力について予め詳細な説明は行わず、「好きな物を見た時と嫌いな物を見た時でロボットの反応は変わる」という程度の説明に留めた。
7. 実験者が図 18 に示すように参加者に 23 個のミニカーを 1 個ずつ提示した。参加者には手順 (6) で推定した Prefer の選好に基づいて、提示されたミニカーに対する Prefer の選好を推定して回答するよう求めた。

8. Prefer の選好を正しく推定できたか調べるため、参加者には因子の重要性についてのアンケートへの回答を求めた。



図 18: 手順 (7) の様子。図の手前が実験者、図の奥が実験参加者である。実験者が手に持っているミニカーが提示対象物を表す。

4.4 実験環境

実験環境について図 19 に示す。図 19 において、設置した黒色の仕切りの内側で Prefer を動作させた。黒色の仕切りは透過しないようになっており、Prefer の動作中実験 3 の参加者は実験環境の外が見えないようになっている。図 19 中における黒色の仕切りの奥にはコンピュータを 2 台設置し、AQ を計測するアンケートの実施及び Prefer の制御にそれぞれ使用した。黒色の仕切りの内側には Prefer、参加者が Prefer に提示するミニカーと食べ物のおもちゃ、一度提示したミニカーをしまうケースを設置した。

また図 19 中黒色の仕切りの左側には、前節の手順 (7) で用いるミニカーを設置した。手順 (7) において、実験者は用いるミニカーを 1 つずつ参加者に提示し、回答を得たら元の位置にミニカーを戻す。黒色の仕切りのため、参加者からは提示されたミニカー以外のミニカーは見えないようにした。手順 (7) で用いるミニカーには実験を開始する前に予め布を被せ、手順 (6) が終了するまでに参加者の目に入らないよう設定した。ミニカーに被せた布は手順 (7) で取り外した。

4.5 測定方法

実験 2 の結果から、Prefer に搭載した選好モデルは 112 個全てのミニカーについて決定されていた。また実験 3 の手順 (7) において、参加者は提示されたミニカーに対する Prefer の選好を推定して回答するよう求めた。Prefer に搭載した選好モデル内にある個々のミ



図 19: 実験 3 の実験環境.

結果	ミニカーの認識	Prefer の行動出力
A	正	正
B	誤	正
C	誤	誤

表 16: 実験 3 の手順 (6) におけるそれぞれのミニカーに対する場合分け

ミニカーについての選好を正解とし、同じミニカーについて実験 3 の手順 (7) における参加者の回答と比較した。手順 (7) で使用した 23 個のミニカーについて同様に回答の合否を計測し、実験 3 の参加者それぞれの正答率を算出した。

Prefer の行動出力が正常に行われたか明らかにするために、実験 3 の手順 (6) において実際に提示したミニカーと YOLO を用いて認識したミニカーを比較することで、ミニカーの認識についての正答率を算出した。YOLO の認識結果を決定するタイミングは図 15 中で「認識したミニカーを決定し選好を抽出」と示す通りである。また実際に提示したミニカーと YOLO で認識したクラスのミニカーについて、Prefer に搭載した選好モデルから得た選好を比較することで、Prefer の行動出力についての正答率を算出した。ミニカーの認識の正誤及び Prefer の行動出力の正誤から実験 3 の手順 (6) における 1 つ 1 つのミニカーに対する結果を表 16 に示す。参加者が実際に提示した 89 個のミニカーの内、そのおよそ 5% となる 4 個以上が表 16 における結果 C となった場合、参加者が正しく Prefer の選好を確認できなかったとして分析対象から除外した。

また、実験 3 の手順 (8) で実施したアンケートの回答について、参加者間の平均を算出した。この結果を実験 2 の結果から Prefer に搭載した選好のレーダーチャート (図 12) や決定木 (図 10) 及び因子の重要度 (図 11) と比較し、実験 3 の参加者が正しく Prefer の選好を推定できたかを測定した。

結果	認識結果	出力結果	件数	割合 (%)
A	正	正	1352	84.39
B	誤	正	215	13.42
C	誤	誤	35	2.18
全体			1602	100

表 17: 表 16 の場合分けについて、実験 3 全体の発生件数と発生割合

4.6 実験結果

実験 3 の手順 (1) において Prefer に実際に提示したミニカーと Prefer が YOLO を用いて認識したミニカー及びこれらのミニカーに対して Prefer に搭載した選好を比較する。表 16 で示したようにそれぞれのミニカーの認識結果と Prefer の出力結果を測定・分類し、実験 3 の参加者ごとに各結果が何件あったのか測定した。測定の結果、実験 3 の参加者 27 人の内 9 人について、表 16 における結果 C となったミニカーが 4 個以上あった。そのため、これら 9 人の参加者は正しく Prefer の選好を確認できなかったと判断し、分析から除外した。除外されなかった 18 人の参加者について、結果 A から結果 C となった件数を表 17 に示す。

表 17 より、1 人あたりの参加者に対して、ミニカーの認識誤り率は結果 B と結果 C の合計である 15.60% だと分かった。また、Prefer の選好による出力誤り率は結果 C の 2.18% ということが分かった。

Prefer に搭載した選好を正解データとし、実験 3 の手順 (7) において参加者の回答と比較した。図 20 に参加者の AQ を横軸、参加者の回答の正答率を縦軸にプロットしたものを示す。図 20 中には比較のため、統計的にコンピュータが出力した正答率として実験 2 の決定木、ランダムフォレスト、SVM の手法から得た予測データの Accuracy も横線で示す。実験 2 の結果から、決定木とランダムフォレストの正答率は 0.87 で、SVM の正答率は 0.91 だった。これらに対して、実験 3 の参加者の正答率は 0.70 だった。

実験 3 の手順 (8) で実施したアンケートの回答について、参加者間の平均を図 21 及び表 18 に示す。この結果を、Prefer に搭載した選好モデルのレーダーチャート (図 12) や決定木 (図 10) 及び因子の重要度 (図 11) と比較したところ、実験 3 の参加者の回答から得られた重要度の高い因子の順は Prefer に搭載した因子の重要度の順と比較して大きな矛盾はないと言える。同様に、実験 3 の参加者の回答から得られた重要度の高い因子の順は、決定木の最上位のノードから順に分類に用いた因子の順や、レーダーチャートにおけるミニカーの選好間の差が大きい因子の順と比較してもこれらに大きな矛盾はないと言える。

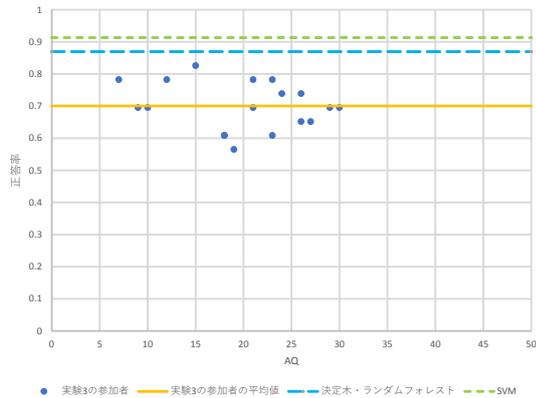


図 20: 実験 3 の参加者について、AQ と手順 (7) における正答率との関係。横線はコンピュータが出力した正答率を表す。

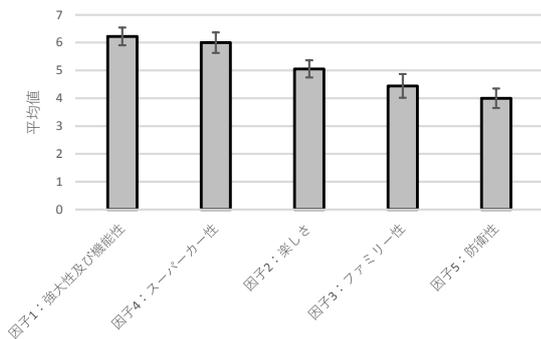


図 21: アンケート回答の平均得点。問題間で降順に並べた。

因子	平均点
1 強性及び機能性	6.22
2 楽しさ	5.06
3 ファミリー性	4.44
4 スーパーカー性	6
5 防衛性	4

表 18: アンケート回答の平均得点。

4.7 議論

実験 3 では、実験 2 で選好の推定が最も容易だと判断した参加者 (選好対象者) の選好モデルをロボットに搭載し、人がロボットの選好を推定できるか明らかにすることを目的とした。実験装置として、認識した物の選好によって行動出力を切り替える自律ロボット Prefer を制作した。実験 3 の参加者には、まず Prefer にミニカーを提示し、Prefer の行動出力から Prefer の選好を推定するよう求めた。次に参加者には推定した Prefer の選好を基に、実験者が提示したミニカーについて Prefer の選好を回答するよう求めた。最後に参加者にはアンケートとして、提示された因子が Prefer の選好を構成する上で、どの程度重要視されるかを回答するよう求めた。

Prefer のミニカー認識及び行動出力の正答率の結果から、1 人あたりの参加者に対して、ミニカーの認識誤り率は 15.60% であり Prefer の選好による出力誤り率は 2.18% ということが分かった。これは表 14 で示す YOLO の学習結果と比較すると、ミニカーの認識誤り率は大きく、YOLO を用いて多くのミニカーをリアルタイムで認識させるのは困難であることが分かる。しかし、本研究ではミニカー 112 クラスの分類精度の向上を目的としていない。たとえミニカーのクラス分類を誤っても、実際に提示したミニカーと認識したミニカーについて Prefer に搭載された選好が合致していれば、Prefer の行動出力に誤りはない。Prefer の行動出力に誤りがなければ実験 3 の参加者が得られる情報に誤りはなく、正常にミニカーを認識した際と同様に Prefer の選好推定を進めることができると考えられる。しかし Prefer の行動出力に誤りがあった場合、参加者が得られる情報に誤りが生じるため、Prefer の選好推定に影響が発生すると考えられる。そのため、本研究ではミニカーの認識誤り率には着目せず、Prefer の選好による出力誤り率のみに着目する。Prefer の行動出力の誤り率は 2.18% であった。これは表 14 で示す YOLO の学習結果と比較しても十分に高い精度だと考えられる。また実験 3 で参加者が Prefer に提示したミニカー数である 89 個に対する 2.18% の割合は 2 個未満の出力誤りとなるので、誤りは十分小さく参加者の Prefer の選好推定に影響は与えないことを示す。以上のことから、Prefer と参加者間のインタラクションは成立していたことが示唆された。

実験 3 の手順 7 における参加者の回答について、正答率の平均値は 0.70 であったことが分かる。もし参加者が Prefer の選好を理解できていなかった場合、参加者は提示されたミニカーについての Prefer の選好をランダムに回答すると考えられる。そのため、もし参加者が Prefer の選好を理解できていなかった場合、正答率の平均値は 0.5 に近づくと推測できる。したがって、

実際の正答率の平均値が 0.70 であることは、値が 0.5 よりも十分に大きいので、参加者は Prefer の選好推定が進んでいたことを示す。また図 20 から、正答率の平均値は実験 2 で算出した決定木、ランダムフォレスト及び SVM による予測データの Accuracy と比較すると小さいことが分かる。このことは参加者は Prefer の選好を完全に推定することはできなかったことを示す。以上のことから、参加者は Prefer の選好についてある程度推定することはできたことが示唆された。

実験 3 の手順 8 において、図 21 に示すアンケート回答の参加者間の平均値に対して、Prefer に搭載した選好モデルのレーダーチャート (図 12) や決定木 (図 10) 及び因子の重要度 (図 11) と比較したところ、これらに大きな矛盾はないことが示された。このことは Prefer に搭載した因子について、因子がどの程度重要視されるかを参加者が正しく理解できたことを意味している。すなわち、参加者は Prefer の選好について理解が進んだことが言える。

以上のことから、実験 3 の参加者は Prefer の選好を理解することができたと示唆された。このことは、人がロボットとインタラクションを通して、ロボットの選好を理解する可能性があることを意味している。

5 総合議論

本研究では人の選好を説明するための潜在要因を同定し、人の選好をモデル化すると共に、人とロボットの間で相互に選好を推定し空気を讀んだ行動が実現できるか明らかにすることを目的とした。本研究においては、18 歳以上の男女の選好を対象とし、選好の対象領域に自動車を設定した。対象領域内の個々の具体的な提示方法には、112 個のミニカーを使用した。まず、自動車のどのような特徴が人の選好に影響を与えるのか明らかにするために、Web 上でアンケート調査を行った。アンケートの分析結果から、このことは、自動車を持つ印象としてかわいさ、大きさ、色、かっこよさ、機械らしさ、騒音性、強さ、頼もしさ、危険性、速さ、派手さ、楽しさ、先進性、機能性、面白さという程度に関する特徴が人の選好に影響を与える要素だと分かった。また、人は車全体の他にタイヤ、架装 (車両に後付できる部品)、席、ドア、屋根、ライト、窓、前面、エンジンという部分に関する特徴に着目して選好を決めることが分かった。次に選好を決める際に部分に関する特徴が、自閉症スペクトラム指数を表す AQ と関係があるのか明らかにするため、また程度に関する特徴を用いて、人の選好を決定する特徴空間や特定個人の選好モデルを明らかにするため、再び Web 上でアンケート調査を行った。アンケートの分析の結果、人は AQ に関係なく自動車の一部よりも全体の印象を見て

選好を決めることが示唆された。また、自動車に対する人の選好を決定する特徴軸として、1) 強大性及び機能性、2) 楽しさ、3) ファミリー性、4) スーパーカー性、5) 防衛性の 5 つの因子が得られた。そして、得られた因子を基に決定木、ランダムフォレスト、SVM の手法によって特定個人 (選好推定が最も容易だと判断された者、選好対象者) の選好を高精度にモデル化することができた。また最後に、人がロボットの選好を推定できるか明らかにするために、選好対象者の選好モデルをロボットに搭載し、人がロボットとのインタラクションを通してロボットに搭載された選好を推定できるか実験を行った。実験の結果、人はロボットの選好推定が可能であることが示唆された。以上のことから、自動車に対する人の選好は、自動車全体から受ける 1) 強大性及び機能性、2) 楽しさ、3) ファミリー性、4) スーパーカー性、5) 防衛性の 5 つの潜在要因を用いて説明できることが示唆された。また、人とロボットがインタラクションを通して相互に選好を推定し空気を讀んで行動する可能性があることが示唆された。

本研究では、選好について影響を与える要因や他者の選好を理解する能力について、成人と同等とみなせる 18 歳以上の男女を対象に行った。成人と比較する対象として、未就学児や小学校低学年の児童のような認知能力の発達途上にある人が挙げられる。今後はこれらの人を対象に同様の実験を行い、選好について影響を与える要因や他者の選好を理解する能力の違いを成人と比較することを通して、人の認知能力やその発達について更なる知見が得られることが予想される。

参考文献

- [1] Francis Bond, Timothy Baldwin, Richard Fothergill, Kiyotaka Uchimoto: Japanese SemCor: A Sense-tagged Corpus of Japanese, *The 6th International Conference of the Global Word-Net Association (GWC-2012)*, Matsue (2012)
- [2] 若林明雄, 東條吉邦, Simon Baron-Cohen, Sally Wheelwright: 自閉症スペクトラム指数 (AQ) 日本語版の標準化-高機能臨床群と健常成人による検討, *心理学研究*, Vol. 75, No. 1, pp. 78-84 (2004)
- [3] Joseph Redmon, Ali Farhadi: YOLOv3: An Incremental Improvement, *arXiv:1804.02767* (2018)