

プライバシー保護設定推測における推測値の平行シフトが 受容度に与える影響

中村 徹^{1,a)} Andrew A. Adams² 村田 潔² 清本 晋作³ 鈴木 信雄¹

概要: 機械学習を用いることで、少数の設定から全体の設定を推測するプライバシー保護設定推測手法が提案されている。少数の設定により全体の設定を推測することで、少ない手間で適切な設定を行うことができる可能性があるが、一方で推測モデルの提供者に悪意があった場合、ユーザが知覚することなく設定を操作される危険性がある。本研究では、通常の推測モデルに加え、プライバシー寄りに推測値をシフトしたモデル、公開寄りに推測値をシフトしたモデル、ランダムに推測値を返すモデルを用いて、それぞれのモデルに対する被験者の受容度について調査を行い、推測モデルの違いが、被験者がモデルの操作について知覚する度合いに与える影響について明らかにした。

キーワード: プライバシー保護, 機械学習, サポートベクターマシン, レコメンデーション

Effect of Parallel Shift for User Acceptability in Privacy Setting Prediction

TORU NAKAMURA^{1,a)} ANDREW A. ADAMS² KIYOSHI MURATA² SHINSAKU KIYOMOTO³
NOBUO SUZUKI¹

Abstract: A machine learning based privacy setting prediction scheme was proposed. The scheme can predict whole adequate settings from the small number of settings. By the scheme, a user can reduce his/her burden for adequate privacy settings. However, there is a potential risk to control users decision about privacy settings without the users' conscious if the model provider is malicious. In this paper, we clarify the effect from manipulating prediction model to participants' recognition by investigating the degree of acceptance with various manipulated prediction models.

Keywords: Privacy Protection, Machine Learning, Support Vector Machine, Recommendation

1. はじめに

パーソナルデータを活用するサービスは多い。パーソナルデータの活用は、一方でプライバシー侵害の懸念を生じている。パーソナルデータの活用について、ある程度ユーザ側でパーソナルデータの提供を制限する設定を行う機能(プ

ライバシ設定機能)が提供されている場合がある。例えば、Facebookでは、自分のタイムラインへの投稿を閲覧できるユーザを制限することができる。また、iPhoneやAndroidのプライバシー設定では、インストールしたアプリによる端末内のデータへのアクセス制御を設定することができる。またPDS(Personal Data Store) [1]やPPM(Privacy Policy Manager) [2]など、多様なサービスに対する自身のパーソナルデータ全般のアクセス制御を包括して行う仕組みも検討されている。

プライバシー設定機能が提供されている場合であっても、適切に設定を行うことは容易ではない。特に、多数の項目

¹ 国際電気通信基礎技術研究所 (ATR)
京都府相楽郡精華町光台二丁目2番地2
² 明治大学
東京都千代田区神田駿河台1-1
³ KDDI 総合研究所
埼玉県ふじみ野市大原2-1-15
a) tr-nakamura@atr.jp

について設定を行う必要がある場合は、より困難である。我々の研究グループでは、機械学習を用いて、少数の設定から全体の最適なプライバシー設定を推測するモデルを用いることで、設定の負担を軽減する手法について研究を行ってきた [3], [4]。

これまでの研究では、推測モデルを提供する主体は悪意がないことを仮定してきた。推測モデルを提供する主体に悪意がある場合には、提供主体に都合のよいモデルが使用され、利用者のプライバシー志向が反映されない設定が提示される危険性がある。

そこで、本研究では、バイアスをかけた推測モデルを使用した場合に、バイアスが被験者の受容度に与える影響について調査を行う。本研究では、被験者を4つのグループに分け、各グループにそれぞれ異なる推測モデルを用いて実験を行う。推測モデルはそれぞれ、(1) 通常モデル、(2) プライバシ保護寄りに平行シフトしたモデル、(3) データ公開寄りに平行シフトしたモデル、(4) ランダムに推測値を提示するモデル、である。

1.1 本論文の貢献

本実験では、(1), (2), (3) については受容度に顕著な差が観測できなかった。一方で、(4) については被験者の受容度は顕著に低い結果となった。以上から、平行シフトした場合には、被験者の受容性に影響を与えにくいことが明らかになった。この結果は、悪意のある主体によって、平行シフトにより提供主体に都合のよいモデルが使用された場合、ユーザが知覚することなしに設定を操作される危険性があることを示唆している。

1.2 本論文の構成

本論文の構成は以下の通りである。2章で評価を行うプライバシー設定推測手法について述べる。3章で実装した評価システムについて述べる。4章で、本研究で実施する実験について述べる。5章で、本実験結果について考察する。6章で、本論文をまとめる。

2. 機械学習によるプライバシー設定推測手法

本章では、SCIS2016 及び ICIS2016 にて提案した、サポートベクトルマシン (SVM) に基づいたプライバシー設定推測手法について述べる [3], [4]。この手法では、既存ユーザの設定から、少数の設定項目に対する設定値を特徴ベクトルとして、各プライバシー設定項目に対応する SVM モデルを生成し、プライバシー設定の推薦時には、推薦を希望するユーザに前述の少数の設定項目について回答してもらい、前述の SVM モデルを用いて設定値全体を推測するユースケースを想定している。

我々の提案したプライバシー設定手法のユースケースについて、図 1 に示す。プライバシー設定推測の手順は以下の通

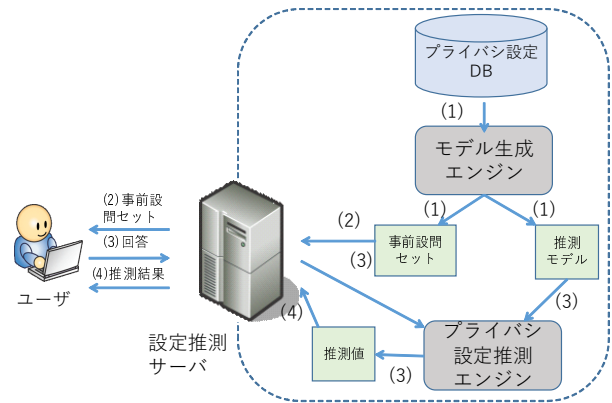


図 1 プライバシ設定手法のユースケース

りである。

- (1) プライバシ設定 DB に格納されている既存ユーザの設定をモデル生成エンジンに入力し、最適な事前設問セットと推測モデルを生成する。
- (2) ユーザに事前設問セットを提示する
- (3) ユーザの回答と推測モデルをプライバシー設定推測エンジンに入力し、推測値を生成する。
- (4) 推測値をユーザに推薦する。

モデル生成エンジンで利用する推測モデル生成アルゴリズムは以下の通りである。推測モデル生成アルゴリズムの概要を図 2 に示す。

- (1) データセットを、学習データと評価データに分割する。
- (2) 設定項目からランダムに事前設問セットの候補を選択する。
- (3) 学習データのうち、前ステップで選択された事前設問セットの値を特徴ベクトルとして用いて、残りの各設定項目についてそれぞれ SVM を用いた推測モデルを生成する。
- (4) 評価データを用いて前ステップで生成した推測モデルの精度評価を行う。
- (5) (2)-(4) を十分な試行回数を繰り返し、最も精度が高い組み合わせを事前設問セットとし、その時のモデルを対応する最適な推測モデルとする。

3. 評価システム

本章では、本研究で実施した実験に用いる評価システムの詳細を述べる。評価システムは、2章で示したプライバシー設定推測手法を Web サービスとして実装した。学習データとして、[3] で収集した 10,000 人の被験者によるアンケート結果を用いた。アンケート項目は、表 1, 2 に示す、16 種類のデータタイプと、5 種類の利用目的の組み合わせに対する、提供に関する受容度について回答する項目により構成される。本論文ではこの 80 種類の組み合わせを、プライバシー設定の項目とみなして議論する。以降項目を指定する場合には、利用目的の識別子を x 、データタイ




図 2 推測モデル生成アルゴリズム

プの識別子を y とすると、設定項目を $x-y$ と表すこととする。受容度の回答は、6段階の Likert 尺度により（“1”は強い拒否，“6”は強い同意を表す）から選択する形式だったが、本論文では、議論を簡単にするため、2つの尺度をマージし（1と2を“クラス1(提供したくない)”，3と4を“クラス2(サービスごとに判断)”，5と6を“クラス3(提供してもよい)”とする），3段階の尺度での評価を行うこととした。

実験では、被験者を4つのグループに分け、それぞれのグループに対して、以下に示す異なる推測モデルを適用する。

- (1) 通常モデル (以後、通常モデル)
- (2) プライバシ保護寄りにシフトしたモデル (以後、プライバシーモデル)
- (3) データ公開寄りにシフトしたモデル (以後、オープンモデル)
- (4) ランダムに推測値を提示するモデル (以後、ランダムモデル)

通常モデルについては、表 3 に示すパラメータで、前章で示した推測モデル生成アルゴリズムを実行し、本実験で用いる SVM モデルを得た。実装を行った言語は R で、

表 1 パーソナルデータの種類

No.	データタイプ
1	実社会における連絡先情報
2	オンライン連絡先情報
3	ユニークな識別子
4	購買情報
5	財務情報
6	コンピュータ情報
7	閲覧状況
8	サービスへのリクエスト
9	個人の特徴情報
10	メッセージ内容
11	セッション管理情報
12	市民情報
13	健康情報
14	嗜好情報
15	位置情報
16	政府発行の識別子

表 2 パーソナルデータの利用目的

No.	利用目的
A	本来のサービス提供
B	システム管理
C	マーケティング調査
D	利用者の行動分析
E	利用者への推薦

SVM については“e1071” [5] パッケージを用いた。採用された事前設定セットのデータタイプと利用目的の組み合わせを、表 4 に示す。

表 3 本研究で用いるパラメータ

学習データ数	1,000
評価データ数	9,000
推測に用いる設定項目数	5
γ (SVM のパラメータ)	0.2
$cost$ (SVM のパラメータ)	1.0

表 4 採用された事前設定セット

データタイプ	利用目的
14. 嗜好情報	A. 本来のサービス提供
4. 購買情報	B. システム管理
15. 位置情報	B. システム管理
12. 市民情報	C. マーケティング調査
6. コンピュータ情報	E. 利用者への推薦

プライバシーモデルとオープンモデルの生成は、パラメータ $class.weights$ を用いて行った。このとき、事前設定セットについては、通常モデルで採用した項目をそのまま採用することとした。これらのモデル生成の手順については、 $class.weights$ のパラメータを設定する以外は通常モデルと同様とした。 $class.weights$ は各クラスに対するコストへの重みを与えるベクトルで、デフォルト値は 1 である。プラ

イバシモデルでは，“1. 提供したくない”，“2. サービスごとに判断”，“3. 提供してもよい”の各クラスに対して，class.weights を (10,1,1) として推測モデルを生成した．また，オープンモデルでは，同様に class.weights を (1,1,10) として推測モデルを生成した．例として，被験者が事前設問セットに対して (1,2,3,1,2) と回答した場合の，利用目的が”A. 本来のサービス提供”に対する，各推測モデルが出力する推測値を図 3 に示す．項目 A-1 を見ると，オープンモデルでは”1. 提供してもよい”と推測しているのに対し，それ以外のモデルでは”3. 提供したくない”と推測している．また，項目 A-8 を見ると，プライバシモデルでは”1. 提供したくない”と推測しているのに対し，それ以外のモデルでは”3. 提供してもよい”と推測している．このように，class.weights のパラメータを変化させることにより，プライバシモデル及びオープンモデルを実現した．事前設問セットに対する全ての回答の組み合わせについて，通常モデル，プライバシモデル，オープンモデルの推測値の分布を表 5，図 4 に示す．

表 5 各モデルの推測値の分布

	1	2	3	合計
プライバシモデル	77.6%	21.1%	1.30%	100%
通常モデル	57.2%	41.5%	1.30%	100%
オープンモデル	55.1%	35.9%	8.98%	100%

ランダムモデルについては，事前設問セットの回答結果に依存せず，ランダムに推測値を提示する．ランダムな推測値は被験者がログインするたびに変更されるため，被験者ごとに異なる推測値が提示される．

事前設問セットに対する回答画面のスナップショットを，図 5 に示す．被験者はまず，事前設問に回答する．その他の 75 の設定について，推測モデルにより推測した値が入力された形式で表示される．図 6 に，推測値を表示する画面のスナップショットを示す．被験者は表示された推測値が自分の考えと同じであればそのままにし，自分の考えと異なる場合には自分の考えと同じになるように修正する．

4. 実験

本章では，本研究で実施した実験について述べる．

4.1 実験の構成

実験の構成の概要を図 7 に示す．評価システムは ID とパスワードのペアのリストを持ち，ID には 4 種類のグループ ID (1,2,3,4 とする) を割り当てる．グループ ID は，それぞれ通常モデル，プライバシモデル，オープンモデル，ランダムモデルが割り当てられる．各被験者には ID とパスワードを配布する．被験者は配布された ID とパスワードをログイン画面にて入力する．ログインすると，被験者にはまず本実験についての説明が記載されたページが表示さ

れる．説明には，評価システムの操作方法とともに，実施主体や，AI 技術によって実現している技術であることなどを記載することとした．被験者は説明を読み終えると，事前設問セットに対する回答画面へ進み，事前設問セットに回答する．その後，評価システムは，被験者の ID に割り当てられた推測モデルと，事前設問セットに対する回答から，各項目に対する推測値を算出し，推測値を表示する画面を表示する．被験者は表示された推測値が自分の考えと同じであればそのままにし，自分の考えと異なる場合には自分の考えと同じになるように修正する．以後，最終的に決定した設定値を回答値と呼ぶこととする．

4.2 実験環境

被験者は所有する PC 等から，インターネットを用いて評価システムにアクセスし，実験に参加した．実験は，2018 年 3 月 26 日から，2018 年 4 月 2 日まで，計 8 日間実施した．被験者の人数は計 552 人であり，各グループにそれぞれ割り当てた．被験者の年齢及び性別の分布を表 6 に示す．

表 6 被験者の分布

性別	年齢	1	2	3	4	合計
男性	25-34	40	41	39	35	155
	35-44	34	29	38	31	132
女性	25-34	43	31	36	44	154
	35-44	37	22	27	25	111
合計		154	123	140	135	

4.3 実験結果

実験結果を表 7 に示す．ここでは，推測値を表示する画面において，表示された推測値が修正されなかった割合，すなわち，推測値と回答値が一致した割合を正答率とする．通常モデル，プライバシモデル，オープンモデル，の推測モデルを用いた 3 グループ間では，正答率に顕著な差が見られなかった．一方で，ランダムモデルを用いたグループは，他の 3 グループと比較して顕著に低い正答率を示した．次章でより詳細に考察する．

表 7 実験結果

グループ	正答率
1. 通常モデル	89.6%
2. プライバシモデル	91.6%
3. オープンモデル	89.2%
4. ランダムモデル	71.8%




図 3 事前設問に対し (1,2,3,1,2) と回答した場合の、利用目的が”A. 本来のサービス提供”に対する、各推測モデルが出力する推測値




図 4 各モデルの推測値の分布

は、AI 技術を使用していることを事前に説明されている。これがランダムモデルを用いたグループ 4 であっても高い正答率となった可能性がある。しかしながら通常モデルを用いた場合と比較すると、正答率が 89.6%と十分な差が出ており、ランダムモデルについてはある程度操作について知覚されていると言える。一方で、プライバシーモデル、オープンモデルについては通常モデルと同等の正答率であり、平行シフトした場合については、知覚できていないと言える。もう一点は、必ずしも全ての被験者が十分に集中して実験を実施しているわけではないことである。実際、全体の 221 人の被験者は正答率が 100%、すなわち全く推測値を修正しておらず、またランダムモデルを使用した被験者に限定すると 31 人の被験者の正答率が 100%である。これが、ランダムモデルを用いたグループ 4 であっても高い正答率となった可能性がある。

5. 考察

5.1 グループ間の比較

表 8 - 11 は、それぞれグループ 1 から 4 の推測された値と、それに対する回答値の分布を示している。グループ 1, 2, 3 を比較すると、推測値の分布が、それぞれ (34.1%, 59.1%, 6.85%), (60.0%, 33.8%, 6.25%), (27.4%, 38.0%, 34.6%) と大きく異なる。にもかかわらず、正答率はそれぞれ 89.6%, 91.6%, 89.2%と大きな差がなく、回答値の分布がそれぞれ (40.8%, 50.0%, 9.23%), (59.7%, 31.6%, 8.71%), (33.3%, 35.9%, 30.9%) と大きく異なる。回答値は、理想的には被験者のプライバシー意識が直接反映されていることが期待される。被験者は無作為にグループ分けされているため、理想的には回答値の分布は各グループで同様となるはずであるが、本実験では前述の通り大きく異なる。一方で、グループ 4 の正答率が 71.8%と、理想的には 33.3%であることを考えれば高い結果となった。

これらの原因として二点考えられる。一点は、そもそものような推測であったとしても、回答値が推測結果に引きずられてしまう傾向があると考えられる。特に本実験で

表 8 グループ 1 の分布

	回答_1	回答_2	回答_3	合計
推測_1	33.7%	0.34%	0.10%	34.1%
推測_2	7.05%	49.4%	2.60%	59.1%
推測_3	0.09%	0.23%	6.52%	6.85%
合計	40.8%	50.0%	9.23%	

表 9 グループ 2 の分布

	回答_1	回答_2	回答_3	合計
推測_1	57.1%	2.04%	0.82%	60.0%
推測_2	2.50%	29.1%	2.21%	33.8%
推測_3	0.05%	0.53%	5.67%	6.25%
合計	59.7%	31.6%	8.71%	

表 10 グループ 3 の分布

	回答_1	回答_2	回答_3	合計
推測_1	26.8%	0.49%	0.07%	27.4%
推測_2	3.99%	32.8%	1.22%	38.0%
推測_3	2.44%	2.57%	29.6%	34.6%
合計	33.3%	35.9%	30.9%	

プライバシー設定の推薦に必要な質問

プライバシー情報の提供について、あなたのお考えをお答えください。
設問の目的のために、各プライバシー情報を提供しても良いかご回答をお願いします。

選択肢			
○:提供しても良い △:サービスごとに判断 ×:提供たくない			
目的: サービスまたはアプリの本来のサービス提供(電子メールの送信や商品の注文など)のため			
嗜好情報(色や音楽の好みなど)	<input type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×
目的: サービスまたはアプリのシステム管理(サイトの保守管理など)のため			
購買情報(購入履歴など)	<input type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×
位置情報(GPS情報など)	<input type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×
目的: サービスまたはアプリがマーケティング調査(個人を特定しない)を行うため			
市民情報(所属する団体、宗教など)	<input type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×
目的: サービスまたはアプリが利用者への推薦(商品の推薦やサイトのパーソナライズなど)するため			
コンピュータ情報(IPアドレスやOSなど)	<input type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×

回答

図 5 事前設問への回答画面

自分の考えと異なれば修正する

閲覧状況(アクセスしたURLや滞在時間)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
サービスへのリクエスト(検索キーワードなど)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
個人の特徴情報(性別や年齢、年取など)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
メッセージ内容(メールやチャット、掲示板の書き込みなど)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
セッション管理情報(クッキーなど)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
市民情報(所属する団体、宗教など)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
健康情報(カルテ情報など)	<input type="radio"/> ○	<input checked="" type="radio"/> △	<input type="radio"/> ×
嗜好情報(色や音楽の好みなど)	<input checked="" type="radio"/> ○	<input type="radio"/> △	<input type="radio"/> ×
位置情報(GPS情報など)	<input type="radio"/> ○	<input type="radio"/> △	<input checked="" type="radio"/> ×
政府発行の識別子(免許証番号や国民IDなど)	<input type="radio"/> ○	<input type="radio"/> △	<input checked="" type="radio"/> ×

選択肢



図 6 推測値の表示画面

	回答_1	回答_2	回答_3	合計
推測_1	29.0%	2.44%	1.62%	33.1%
推測_2	8.27%	25.1%	1.62%	35.0%
推測_3	8.65%	5.57%	17.7%	31.9%
合計	46.0%	33.1%	20.9%	

次に、各設問ごとの、モデル間での推測値の変化量と、正答率の関係について調査した。推測値の変化量として、モデル間の推測値の平均値の標準偏差を用いることとした。ここでは、グループ 1 を基準として、推測値の変化量を調査する。例として、表 12 に、グループ 1 と 2 の間の推測値の平均値の標準偏差を示す。また、表 13 に、グループ 2 の各項目の正答率を示す。直観的には、推測値の変化量

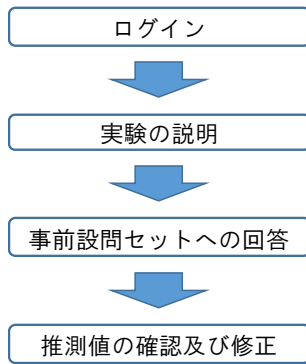


図 7 実験の構成の概要




図 8 グループ 1 と 2 の間の推測値の変化量と正答率に関する散布図

が多い項目は、正答率が低下すると考えられるために、これらには負の相関があると考えられる。推測値の変化量と正答率の相関について調査するため、図 8 に、各項目ごとの推測値の変化量と正答率に関する散布図を示す。同様に、図 9 及び 10 に、それぞれグループ 1 と 3、グループ 1 と 4 の間の、各項目ごとの推測値の変化量と正答率に関する散布図を示す。さらに、グループ 1 と 2、グループ 1 と 3、グループ 1 と 4 について、推測値の変化量と正答率に関して、ピアソンの相関係数を算出する。ピアソンの相関係数を算出した結果を表 14 に示す。グループ 1 と 4 については、比較的高い負の相関を示すが、グループ 1 と 2、グループ 1 と 3 については、同様に負の相関があるものの比較的低い。以上から、平行にシフトしたモデルを使用した場合には、ランダムなモデルを使用した場合と比較して、通常モデルで推測される値とは異なる値が提示された場合であっても、被験者が受容しやすくなる要因が含まれていると考えられる。

5.2 受容しやすくなる要因

受容しやすくなる要因として、提示された推測値の多く




図 9 グループ 1 と 3 の間の推測値の変化量と正答率に関する散布図




図 10 グループ 1 と 4 の間の推測値の変化量と正答率に関する散布図

が本来受容できる値であった場合に、その他の本来は受容できない値を推測された項目についてもつられて受容しているのではないかと仮説を立てた。例えば、図 3 では、A-3, A-4, A-5, A-6, A-7, A-10, A-11, A-12, A-13, A-15, A-16 について同じ値が推測されるため、各モデルで差が出ない。このように、各モデルで変動のない項目があることが、平行シフトの場合に受容度が上がる要因ではないかと考えた。そこでまず、通常モデル、プライバシモデル、オープンモデルの 3 モデルについて、すべての事前設問セットの組み合わせに対して、項目ごとの推測値の平均を算出し、各モデル間の標準偏差を求めた。標準偏差が小さい項目については各モデルでの変動が小さいことが予想されるため、正答率が高いことが期待される、すなわち、標準偏差と正答率に負の相関があることが期待される。次に、標準偏差とグループ 2 及び 3 の被験者の正答率について、ピアソンの相関係数を計算し、相関を調査した。その

表 12 グループ 1 と 2 の間の推測値の平均値の標準偏差

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
A	0.29	0.36	0.18	0.15	0.22	0.17	0.2	0.06	0.31	0.14	0.25	0.29	0.12	0.06	0.19	0.17
B	0.11	0.1	0.1	0.02	0.21	0.02	0.19	0.09	0.05	0.27	0.07	0.05	0.05	0.09	0.05	0.13
C	0.24	0.25	0.1	0.11	0.27	0.11	0.26	0.05	0.11	0.28	0.08	0.04	0.1	0.19	0.25	0.07
D	0.27	0.08	0.07	0.07	0.23	0	0.14	0.04	0.08	0.25	0.14	0.07	0.1	0.09	0.07	0.12
E	0.14	0.05	0.09	0.08	0.15	0	0.14	0.15	0.1	0.2	0.02	0.05	0.07	0.15	0.09	0.12

表 13 グループ 2 の各項目の正答率

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
A	0.79	0.78	0.87	0.81	0.88	0.88	0.87	0.84	0.83	0.89	0.88	0.9	0.9	0.97	0.92	0.94
B	0.91	0.87	0.89	0.92	0.94	0.93	0.95	0.9	0.89	0.92	0.94	0.91	0.94	0.94	0.93	0.95
C	0.93	0.92	0.94	0.94	0.95	0.94	0.89	0.96	0.91	0.95	0.92	0.91	0.94	0.94	0.96	0.95
D	0.95	0.9	0.87	0.92	0.94	0.92	0.94	0.96	0.9	0.93	0.91	0.94	0.94	0.94	0.94	0.94
E	0.96	0.91	0.93	0.93	0.95	0.93	0.94	0.96	0.91	0.92	0.91	0.93	0.95	0.95	0.95	0.95

表 14 ピアソンの相関係数

グループ 1 と 2	-0.30
グループ 1 と 3	-0.39
グループ 1 と 4	-0.59

結果, それぞれ-0.22, -0.06 という結果となり, 仮説の前提となっていた, 変動のない項目が受容度を引き上げているという現象は確認できなかった.

6. 終わりに

本研究では, バイアスをかけた推測モデルを使用した場合に, バイアスが被験者の受容度に与える影響について調査を行った. 本実験では, 通常モデル, プライバシモデル, オープンモデルの 3 つの異なるモデルを用いた場合については, 受容度に顕著な差が観測できなかった. 一方で, ランダムモデルについては被験者の受容度は顕著に低い結果となった. 以上から, プライバシモデル, オープンモデルのように, 平行シフトした場合には, 被験者がシフトされていることを知覚することが困難で, 受容性に影響を与えにくいことが明らかになった. この結果は, 悪意のある主体によって, 平行シフトにより提供主体に都合のよいモデルが使用された場合, 被験者が知覚することなしに設定を操作される危険性があることを示唆している. 一方で, 現状ではシフトにより知覚することが困難になる要因については明らかではないため, 今後はその要因について詳細に解析する予定である.

参考文献

- [1] Gordon Bell., "A personal digital store", Communications of the ACM, Vol. 44, No. 1, pp. 86-91, 2001.
- [2] 中村 徹, Andrew A. Adams, 村田 潔, 清本 晋作, 高崎 晴夫, 渡辺 龍, 三宅 優, "パーソナルデータ流通基盤: Privacy Policy Manager (PPM) の受容性評価", 2014 年暗号と情報セキュリティシンポジウム (SCIS2014), 3D3-2, 2014.
- [3] 中村 徹, 清本 晋作, ウェルデルファエル B. テスファイ, ジュザベル サーナ-オルベラ, "機械学習によるプライバシー設定推測手法に関する評価", 2016 年暗号と情報セキュリティ

ティシンポジウム (SCIS2016), 1C1-3, 2016.

- [4] Toru Nakamura, Shinsaku Kiyomoto, Welderufael B. Tesfay, Jetzabel Serna, "Personalised Privacy by Default Preferences - Experiment and Analysis", the Second International Conference on Information Systems Security and Privacy (ICISSP2016), 53-62, 2016.
- [5] Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C.-C., and Lin, C.-C. (2015). Package 'e1071'. <https://cran.r-project.org/web/packages/e1071/e1071.pdf>