

機械学習によるプライバシー設定推測手法の 精度向上に関する一考察

中村 徹¹ 清本 晋作¹ ウェルデルファエル B. テスファイ² ジュザベル サーナ-オルベラ²

概要: 本論文では、サポートベクトルマシン (SVM) に基づくプライバシー設定推測手法について、属性情報や回答傾向により分割した学習データを用いて、各属性、各傾向を持つユーザに対して個別に推測モデルを生成することによる推測精度の変化を評価する。属性情報については、性別、年代、使用している携帯電話端末の種類に基づいて分割した学習データから生成した推測モデルを用いて精度の評価を行ったが、精度の向上は得られなかった。一方で、クラスタリングにより回答傾向に基づいて分割した学習データから生成した推測モデルを用いた場合には、精度が向上することが明らかになった。

キーワード: プライバシー, 機械学習, プライバシーポリシー

Discussion on Improvement of a Machine Learning Approach for Prediction of Privacy Preference

TORU NAKAMURA¹ SHINSAKU KIYOMOTO¹ WELDERUFEL B. TESFAY² JETZABEL SERNA-OLVERA²

Abstract: This paper evaluates the improvement of accuracy of a privacy setting prediction scheme based on Support Vector Machine (SVM) when learning datasets which are separated from users' attributes (gender, age, or kinds of mobile phones which users use) or tendency of settings. In the case that the learning datasets are separated from users' attributes, the accuracy is not improved. On the other hand, in the case that the learning datasets are separated from users' tendency of setting, the accuracy is improved.

Keywords: Privacy, Machine learning, Privacy Policy

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、デフォルト設定は非常に重要である。なぜなら、ほとんどのユーザは最適な設定を行うために労力をかけることはないからである。パーソナルデータの提供を制限する設定をデフォルトにした場合、ユーザが享受できるサービスに制約を受けてしまうが、一方で制限を緩めていた場合には、ユーザの意に反してプライバシーを損なう恐れがある。ゆえに、各ユーザの指向に合わせてデフォルト設定を最適化することが有用である。しかしながら、サービス事業者がユーザに合わせたデフォルト設定を提供することは困難である。

我々の研究グループでは、パーソナライズされたプライ

¹ KDDI 総合研究所
KDDI Research, Inc.

² Goethe University Frankfurt

バシ設定を自動的に生成する手法について研究を行ってきた [3]. [3] では、ユーザが利用登録を行う際にプライバシー設定に関する少数の質問を行い、この回答に基づいて最適なプライバシー設定を推測する手法について検討し評価を行った。[3] では、サポートベクトルマシン (SVM) に基づいた 2 つのプライバシー設定推測手法を提案した。また、評価データとして、80 の項目からなるアンケート調査をインターネット調査で実施し、10,000 人の被験者から回答を得た。

類似の既存研究として、Fang らの研究 [4] や、Lin らの研究 [5] がある。Fang ら [4] は、ソーシャルネットワークサービスのための Privacy Wizard と呼ばれる機能の提案を行っている。Privacy Wizard は、既存ユーザの公開設定を訓練データとして推測モデルを生成し、新規ユーザに対して公開設定に関する少数の質問から推測した推奨設定を提供する。Lin ら [5] は、Android のパーミッション機能について、アクセスを許可する傾向に基づいてクラスタリングを行った結果、4 つのクラスタに分類できることを示した。本研究では、より一般的なデータタイプと利用目的に関する傾向について推測を行うことを目的としている。

本論文では、被験者のデータを、被験者の属性や回答傾向に基づくクラスタリングにより分割し、分割されたデータごとに個別に設定推測モデルを生成した場合の精度の変化について評価を行う。まず、性別、年代別、使用している携帯電話端末の種類などの被験者の属性情報に基づいてデータを分割した場合の評価を行う。次に、K-means アルゴリズムにより、回答傾向に基づいてデータを分割した場合の評価を行う。

本論文の構成は以下の通りである。2 章で、我々の研究グループで研究を行ってきた、SVM に基づくプライバシー設定推測手法を紹介する。3 章で、本研究で手法の評価用に用いるアンケート結果を紹介する。4 章で、本研究での評価に向けて、最適なパラメータを決定するための予備実験について述べる。5 章で、被験者の属性情報に基づいてデータを分割した場合の、推測精度の評価について述べる。6 章で、被験者の回答傾向に基づいてデータを分割した場合の、推測精度の評価について述べる。7 章で、本研究で得られた結果についての考察を述べ、8 章でまとめる。

2. 機械学習によるプライバシー設定推測手法

我々はこれまでに、サポートベクトルマシン (SVM) に基づいた 2 つのプライバシー設定推測手法を提案した [3]. 1 つ目の手法は、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。2 つ目の手法は、まず既存ユーザに

対して、設定データに基づいてクラスタリングを行い、各クラスタの重心を各設定項目の代表値とする。次に 1 つ目の手法と同様に少数の設定項目に対する設定値を特徴ベクトルとして、どのクラスタに属するか判定する SVM モデル生成し、プライバシー設定の推薦時には同様に、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、属するクラスタを推測し、そのクラスタの代表値を推測値とする。

本論文では、1 つ目の手法について、属性ごと、及び回答傾向ごとにデータセットを分割した場合の精度の変化について調査を行う。用いる評価用のデータセットは [3] と同等のデータセットを用いる。評価用データセットの詳細については、3 で述べる。

我々の提案したプライバシー設定手法の概要について、図 1 に示す。プライバシー設定推測手法の手順は以下の通りである。

- (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、最適な質問セットと推測モデルを生成する。
- (2) ユーザに質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) プライバシ設定 DB に格納されている既存の設定データを、学習用データと評価用データに分割する。
- (2) 設定項目からランダムに、推測に利用する複数の項目を選択する。
- (3) 学習用データのうち、前ステップで選択された項目の設定値を用いて、残りの各項目について SVM モデルを生成する。
- (4) 評価用データを用いて前ステップで生成したモデルの精度評価を行う。
- (5) ランダムに選択した、推測に利用する設定項目の組み合わせについて、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質問セットとして採用する。

3. アンケート調査の解析

我々の研究グループは、[3] にて、提案するプライバシー設定推測手法の評価を行うため、パーソナルデータの提供に関する受容性に関するアンケート調査を実施した。

3.1 アンケートの概要

アンケート項目は、性別、年代、使用している携帯電話端末の種類などの被験者の属性について回答する項目と、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

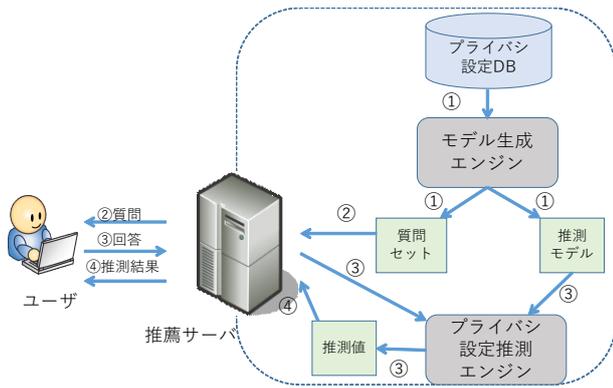


図 1 プライバシ設定推測手法の概要

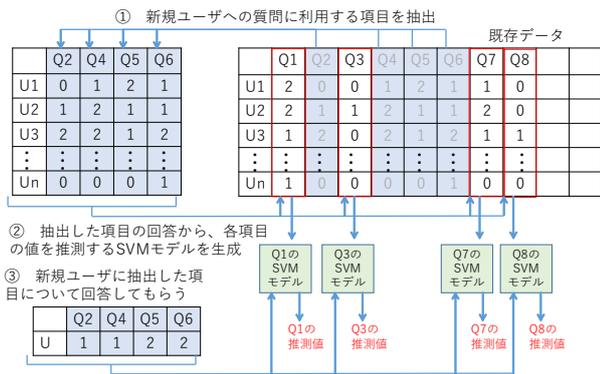


図 2 プライバシ設定推測アルゴリズム

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

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。パーソナルデータのデータタイプと利用目的は、P3P [6] で定義されたパーソナルデータの種類、及び利用目的をもとに、一部一般の方に理解し難いと判断した項目を削除して決定した。調査はインターネット調査で実施し、約 10,000 人の被験者から回答を得た。

被験者の性別と年代の分布については、表 3 に示すように、全てのカテゴリで一様分布とした。被験者の使用して

表 2 パーソナルデータの利用目的

No.	利用目的
1	本来のサービス提供
2	システム管理
3	マーケティング調査
4	利用者の行動分析
5	利用者への推薦

表 3 被験者の性別と年代の分布

性別	年齢	割合 (%)
男性	20 代	10.0
男性	30 代	10.0
男性	40 代	10.0
男性	50 代	10.0
男性	60 歳以上	10.0
女性	20 代	10.0
女性	30 代	10.0
女性	40 代	10.0
女性	50 代	10.0
女性	60 歳以上	10.0

いる携帯電話端末の種類については、表 4 に示す。パーソナルデータの提供に対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) から選択する形式とした。回答の分布を図 3 に示す。本論文では、評価を単純にするため、2 つの尺度をマージし (1 と 2 を “0”, 3 と 4 を “1”, 5 と 6 を “2” とする), 3 段階の尺度での評価を行うこととした。

表 4 被験者の利用している携帯電話端末の分布

項目	割合 (%)
iPhone	23.5
Android	30.0
その他のスマートフォン	1.71
スマートフォンではない携帯電話	44.9

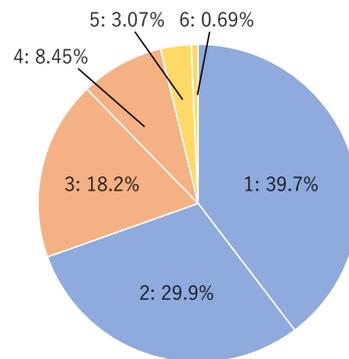


図 3 パーソナルデータ提供の受容度に関する回答分布

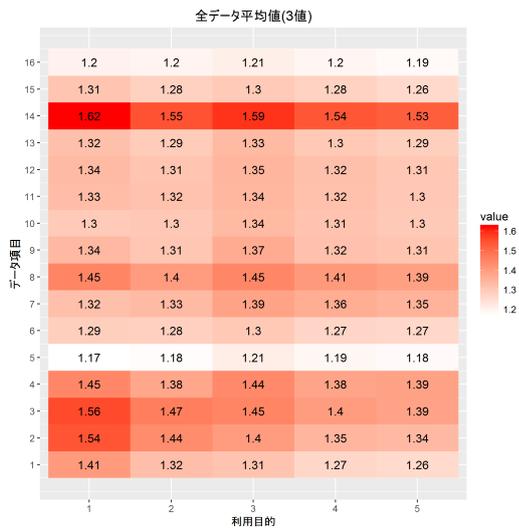


図 4 設問ごとの回答の平均

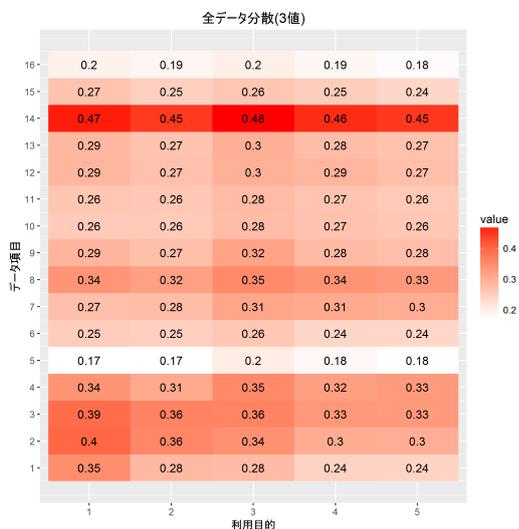


図 5 設問ごとの回答の分散

3.2 設問ごとの平均及び分散

設問ごとの回答の平均及び分散について、それぞれのヒートマップを図 4, 5 に示す。図 4 については、提供について否定的な回答が多い設問については薄い色で、肯定的な回答が多い設問については濃い色で示している。図 5 については、分散の小さい設問については薄い色で、大きい設問については濃い色で示している。設問ごとの回答の平均については、データタイプ「財務情報」、「政府発行の識別子」に関して、特に提供に対して否定的な回答が多い傾向にあることがわかる。また、「嗜好情報」が最も提供に対して肯定的な回答が多く、次いで「オンライン連絡先情報」、「ユニークな識別子」、「購買情報」などが比較的肯定的な回答が多い。利用目的については、データタイプほど項目間での差異は見られなかった。分散についても、ほぼ平均と同様の傾向となった。

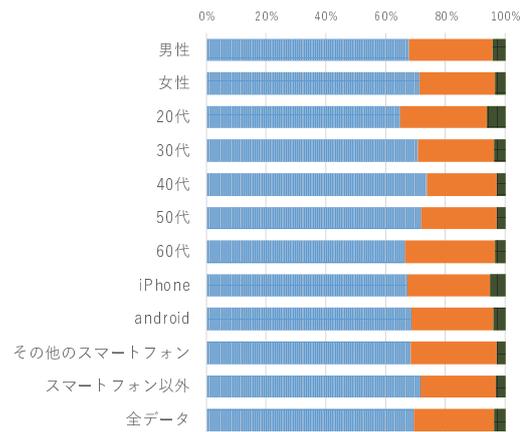


図 6 属性ごとの回答傾向

3.3 属性ごとの回答傾向

被験者の属性ごとの回答傾向を図 6 に示す。性別では、男性は女性と比較して、2(提供に対して肯定的) と回答した割合、1(中間的) と回答した割合が、それぞれ約 1%, 約 2% 高い傾向がある。年代別では、最も提供に対して肯定的なのは 20 代であり、逆に否定的なのは 40 代であった。20 代は 40 代と比較して、2 と回答した割合、1 と回答した割合が、それぞれ約 3%, 6% 高い傾向がある。使用している携帯電話端末の種類別では、iPhone ユーザは android ユーザと比較して、2 と回答した割合が 1% ほど高いが、それ以外は同様の傾向であった。

4. 予備実験

評価を行うにあたり、学習データ数、評価データ数、推測に用いる設定項目の数、及び推測に用いる設定項目の組み合わせ数を決定する必要がある。一般的に、学習データ数、推測に用いる設定項目数、評価する組み合わせ数が多いほど精度が向上することが期待できるが、一方で評価に要する処理時間が増加する。また、評価データ数が多いほど精度の分散が小さくなることが期待できるが、同様に評価に要する処理時間が増加する。以上から、多様な条件で評価を行うためには、上記について適切なパラメータを探索する必要があるため、我々は上記のパラメータを決定するために、予備実験を実施した。実験環境を表 5 に示す。本実験は、2 台の計算機を用いて並列処理で実施した。また、本実験では、SVM のパラメータチューニングは実施しておらず、常にデフォルトの設定値である $\gamma = 0.2$, $cost = 1$ を用いた。

まず、推測に用いる設定項目の組み合わせ数について検討するため、学習データ数を 100、評価データ数を 50、推測に用いる設定項目数を 5 に固定して、推測に用いる設定項目の組み合わせ数を 1000 から 10000 まで 1000 刻みで変動させて精度の評価を行った。学習データと評価データについては、ランダムに 2 回選択し、それぞれデータセット

表 5 実験環境

	計算機 1	計算機 2
OS	Windows10	Windows8.1
メモリ	16GB	8GB
CPU	intel core i7-6700K CPU @ 4.00GHz	intel core i7-4770 CPU @ 3.40GHz
使用言語	R	
使用ライブラリ	e1071(SVM), doSNOW(マルチコア処理)	

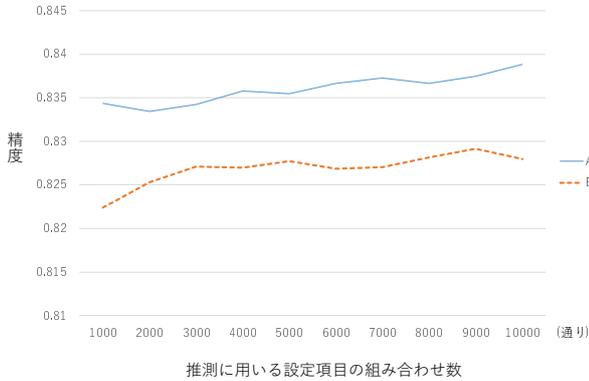


図 7 推測に用いる設定項目の組み合わせ数の影響

A, B とする。各データセットに対し、該当する件数の設定項目の組み合わせをランダムに 5 回選択し、最も高くなる場合の精度の平均値を用いて評価を行った。評価結果を図 7 に示す。評価の結果、データセット A, B については、最も精度の差が大きい場合であってもそれぞれ約 0.46%、約 0.67% の差であり、10000 件評価すれば十分であると判断できる。

次に、評価データ数について検討するため、学習データ数を 100、推測に用いる設定項目数を 5、設定項目の組み合わせ数を 10000 に固定して、評価データ数を 500 から 5000 まで変化させて精度の分散の評価を行った。学習データ、設定項目の組み合わせについては、ランダムに 14 回選択し、それぞれデータセット A-N とする。各データセットに対して、該当する件数の評価データをランダムに 10 回選択し、最も高くなる場合の精度の平均を導出し、データセット間における分散の評価を行った。各データセットの、評価データ数と精度の関係を図 8 に示す。評価データ数が 750 のとき、分散が約 0.00007 に対し、1000 のとき、分散は約 0.00001 となり、以後大きな変化はないため、評価データ数は 1000 で十分であると考えられる。

次に、学習データ数について検討するため、評価データ数を 1000、推測に用いる設定項目数を 5、設定項目の組み合わせ数を 10000 に固定して、学習データ数を 100 から 2000 まで変化させて精度の評価を行った。評価データ、設定項目の組み合わせについてはランダムに 5 回選択し、それぞれデータセット A-E とする。各データセットに対して、該当する件数の学習データをランダムに 10 回選択し、最も高くなる場合の精度の平均値を用いて評価を行った。

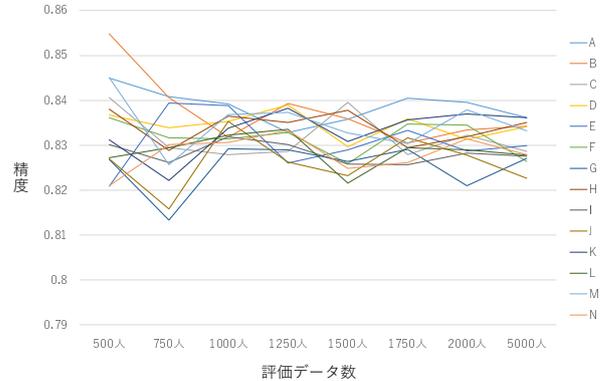


図 8 評価データ数の影響

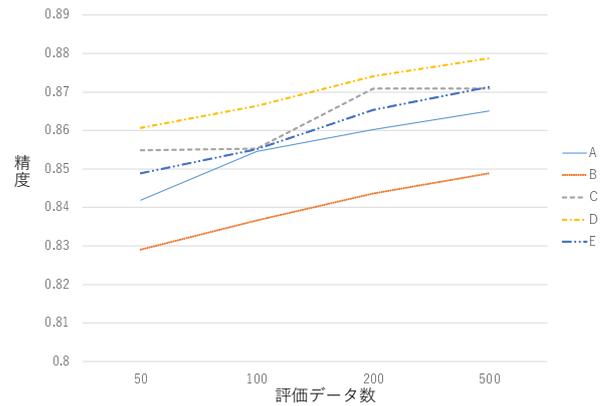


図 9 学習データ数の影響

各データセットの、評価データ数と精度の関係を図 9 に示す。評価結果から、単純に学習データ数が増加するにつれて精度が向上していることがわかる。本研究では、評価に要する処理時間を考慮し、学習データ数を 100 とすることとした。

最後に、推測に用いる設定項目数について検討するため、学習データ数を 100、評価データ数を 1000、設定項目の組み合わせ数を 10000 に固定して、推測に用いる項目数を 2 から 10 まで変化させて精度の評価を行った。学習データ、評価データ、設定項目の組み合わせについてはランダムに 5 回選択し、それぞれについてももっとも高くなる場合の精度を算出し、5 回の平均値を用いて評価を行った。設定項目数と精度の関係を図 10 に示す。項目数を 6 以上に増加した場合、精度の向上が鈍化しているため、本研究では項目数を 5 とする。

以上の結果から、本研究で用いるパラメータを表 6 の

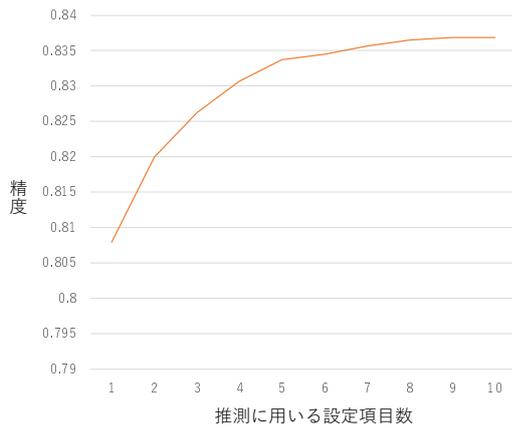


図 10 推測に用いる設定項目数の影響

ように決定した。また、5 及び 6 で実施する評価についても、本章と同様に、SVM のパラメータチューニングは実施せず、常にデフォルトの設定値である $\gamma = 0.2$, $cost = 1$ を用いることとした。

表 6 本研究で用いるパラメータ

学習データ数	100
評価データ数	1000
推測に用いる設定項目数	5
設定項目の組み合わせ数	10000
γ (SVM のパラメータ)	0.2
$cost$ (SVM のパラメータ)	1.0

5. 属性で分割した場合の評価

本章では、性別、年代別、使用している携帯電話端末の種類別に回答データを分割し、分割された各データから個別に推測モデルを生成した場合の精度を評価する。評価に用いるパラメータについては、分割された各データに対して、前章で設定したパラメータを適用する。すなわち、分割した場合であっても、学習データ数や評価データ数を削減することはしない。評価は各分割されたデータに対して、学習データ、評価データ、推測に用いる設定項目の組み合わせをランダムに 10 回選択して精度を導出し、精度の平均値を評価する。性別、年代別、使用している携帯電話端末の種類別に分割した場合の精度を、図 7 に示す。使用している携帯電話端末について、「その他スマートフォン」については、該当する被験者数が少ないため割愛する。

評価の結果、男女別、年代別、使用している携帯電話端末の種類別に分割したいずれの場合も、分割しない場合と比較して、精度が向上しているカテゴリも存在するが、全体では精度が悪化した。

6. 回答傾向で分類した場合の評価

6.1 クラスタごとの回答傾向

被験者の回答について、K-means アルゴリズムを用い

表 7 属性別に分類した場合の精度

分割しない場合	全体	精度
		0.8415
男女別、評価結果	男	0.8364
	女	0.8348
	全体	0.8356
年齢別に分割	20 代	0.8073
	30 代	0.8421
	40 代	0.8519
	50 代	0.8511
	60 代以上	0.8243
	全体	0.8353
携帯端末別、評価結果	iPhone	0.8248
	Android	0.8282
	その他スマートフォン	0.8445
	スマートフォン以外	0.8445
	全体	0.8325

て、クラスタ数を 1 から 10 まで変化させてクラスタリングを行い、各クラスタについて回答傾向を調査した。結果を図 11 に示す。

その結果、大半の質問に対して 0 と回答するクラスタ (クラスタ 1) と、同様に大半の質問に対して 1 と回答するクラスタ (クラスタ 4) が存在することがわかった。これらのクラスタに属するユーザについては、直接そのようなプライバシー志向であるかどうか質問すれば十分であると考えられる。

そこで、本章では、回答データをクラスタ 1、クラスタ 4、及びそれ以外 (クラスタ 2, 3) に分割し、分割された各データから個別に推測モデルを生成した場合の精度を評価する。

6.2 クラスタ別に分割する場合の評価結果

評価に用いるパラメータについては、5 章同様、分割された各データに対して、4 章で示したパラメータを適用する。評価は各分割されたデータに対して、学習データ、評価データ、推測に用いる設定項目の組み合わせをランダムに 10 回選択して精度を導出し、精度の平均値を評価する。全データから学習データを抽出して生成した推測モデルを使った場合の各クラスタにおける精度と、クラスタ別に分割したデータから、それぞれのクラスタに対応する推測モデルを使った場合の精度を、図 8 に示し比較する。

クラスタ 1 及びクラスタ 2+3 については、1%未満の精度向上であったが、クラスタ 4 については約 5%精度が向上した。さらに、全体としても約 1%精度が向上した。

7. 考察

6 章の結果から、回答傾向でデータを分割して、それぞれ

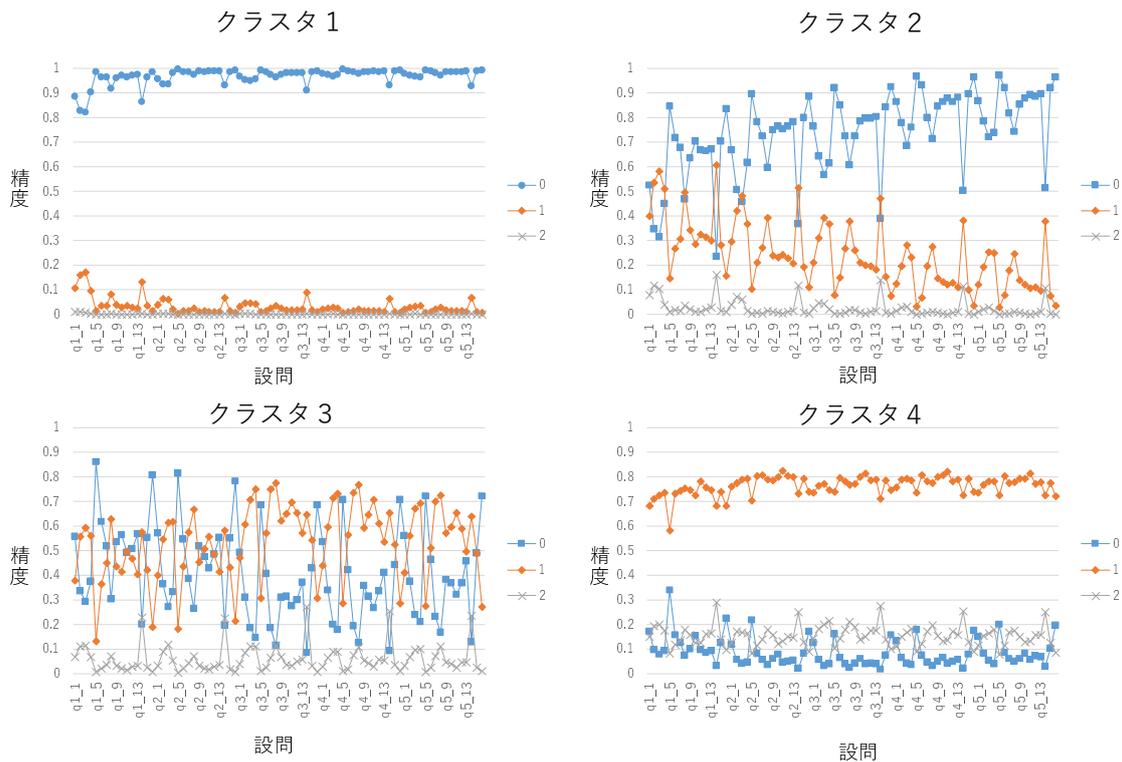


図 11 クラスタごとの回答傾向

表 8 クラスタ別に分割した場合の評価

クラスタ	従来手法 (全データから推測モデルを 1 つ生成)			クラスタごとに推測モデルを生成		
	精度	割合	精度×割合	精度	割合	精度×割合
1	0.9698	47.10%	0.456776	0.9738	47.10%	0.45866
2+3	0.7088	38.50%	0.272888	0.7126	38.50%	0.274351
4	0.7767	14.40%	0.111845	0.8237	14.40%	0.118613
		全体	0.841509		全体	0.851624

のクラスタに対して個別に推測モデルを生成することで、推測精度を向上させることができることが明らかになった。実システムに適用する場合にも、例えば設定を推薦するための質問をする前に、「基本的に全て提供しない設定にしたい」などの質問を行うことで、ユーザを適切なクラスタに分類できることが期待できる。

属性で分割した場合に精度の向上が得られなかった原因として、今回注目した属性では回答傾向には顕著な差が見られなかったことが考えられる。例えば、図 12 に、20 代と 40 代の被験者の回答傾向を示す。図 6 で示したように、20 代と 40 代では回答の割合は比較的差があるが、回答の傾向には顕著な差が見られないため、本手法が有効ではなかったことが推測される。

クラスタ別に分割した場合に、クラスタ 4 では精度が向上したが、クラスタ 1 及び 2+3 では顕著な向上は得られなかった。クラスタ 1 で精度向上が得られなかった原因としては、0 と回答している割合が約 96.8% と非常に高い割合を占めており、既に全データから生成した推測モデルでも十分高い精度が得られていたことが考えられる。一方で、

クラスタ 2+3 で精度向上が得られなかった原因としては、異なる回答傾向を示すクラスタ 2 と 3 が混在するデータをもとに推測モデルを生成していることが考えられる。表 9 に、6 章で実施した評価から、さらにクラスタ 2 と 3 を分割して評価した結果を示す。この結果から、クラスタ 2 については約 2.4%、クラスタ 3 については約 3.4% 精度の向上が見られる。以上から、回答傾向によるクラスタリングを細分化することで、より精度を向上できることが明らかになった。しかしながら、本来クラスタ 2 または 3 に属するユーザに、自身のクラスタを事前に申告してもらうことは容易ではないため、実システムに適用するためには、各クラスタごとの典型的な設定傾向などを提示して選択してもらうなどの工夫が必要になると考えられる。

8. 終わりに

本論文では、被験者のデータを、被験者の属性や回答傾向に基づくクラスタリングにより分割し、分割されたデータごとに個別に設定推測モデルを生成した場合の精度の変化について評価を行った。まず、性別、年代別、使用して

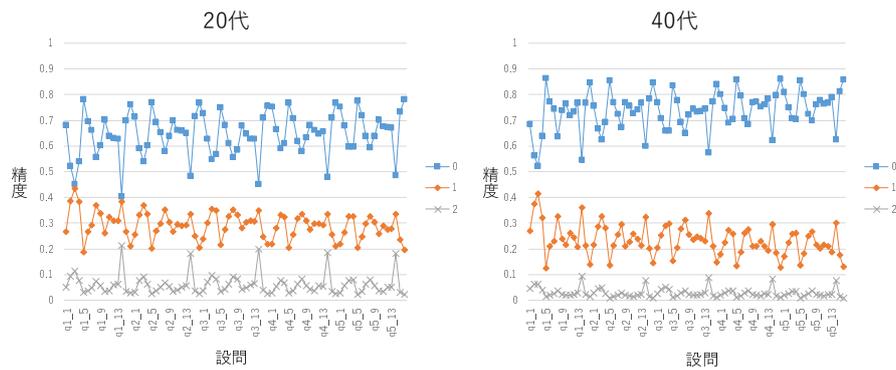


図 12 20代と40代の回答傾向

表 9 クラスタ 2 と 3 を分割した場合の評価

クラスタ	従来手法 (全データから推測モデルを 1 つ生成)			クラスタごとに推測モデルを生成		
	精度	割合	精度×割合	精度	割合	精度×割合
1	0.9698	47.10%	0.4568	0.9738	47.10%	0.4587
2	0.7617	21.50%	0.1638	0.7855	21.50%	0.1689
3	0.6420	17.00%	0.1091	0.6768	17.00%	0.1151
4	0.7767	14.40%	0.1118	0.8237	14.40%	0.1186
		全体	0.8415		全体	0.8612

いる携帯電話端末の種類別などの被験者の属性情報に基づいてデータを分割した場合の評価を行った。属性情報に基づいてデータを分割した場合には、精度の向上は得られなかった。次に、K-means アルゴリズムにより、回答傾向に基づいてデータを分割した場合の評価を行った。回答傾向に基づいてデータを分割した場合には、精度の向上が得られた。

謝辞

本研究は、JST、CREST の支援を受け、得られた成果によるものです。また、本調査を実施するにあたり、アンケートへの回答にご協力を頂きました皆様に感謝いたします。

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シンポジウム (SCIS2016), 1C1-3, 2016.
- [4] Lujun Fang and Kristen LeFevre, “Privacy wizards for social networking sites”, In Proceedings of the 19th international conference on World wide web, pp. 351–360. ACM, 2010.
- [5] Jiali Lin, Bin Liu, Norman Sadeh, and Jason I. Hong, “Modeling Users’ Mobile App Privacy Preferences: Restoring Usability in a Sea of Permission Settings”, In Proceedings of 10th Symposium on Usable Privacy and

Security (SOUPS2014), pp. 199–212, 2014.

- [6] W3C., “The platform for privacy preferences 1.0 (P3P1.0) specification”, Platform for Privacy Preferences (P3P) Project, 2002.