

公募企画

公募企画シンポジウム6

安心・安全なビッグデータの流通プラットフォームとセキュリティ基盤技術

2017年11月22日(水) 08:45 ～ 10:45 C会場 (10F 会議室1001)

[3-C-1-PS6-3] プライバシに配慮したデータ流通のための基盤技術

清本 晋作（株式会社KDDI総合研究所）

本発表では、JST CREST「ビッグデータ統合利活用促進のためのセキュリティ基盤技術の体系化」の研究成果である、プライバシーに配慮しつつデータの共有・流通を実現するための基盤技術について紹介する。

プライバシーに配慮したデータ流通基盤技術

- 実用的な Personal Data Store (PDS) 実現に向けて -

清本晋作^{*1}、中村徹^{*1}、三本知明^{*1}
^{*1} 株式会社 KDDI 総合研究所

Privacy-Conscious Data Distribution Platform - Towards Practical Personal Data Store -

Shinsaku Kiyomoto^{*1}, Toru Nakamura^{*1}, Tomoaki Mimoto^{*1}

^{*1} KDDI Research Inc.

In this paper, we present a conceptual architecture for privacy-respecting data distribution and then design a platform based on the architecture. The platform consists of Personal Data Stores (PDSs) including Privacy Policy Manager (PPM) functionality, generation of datasets, privacy risk analysis, and anonymization algorithms for datasets. The architecture is a reference model for Information Bank.

Keywords: Privacy, Data, Personal Data Store, Security, Data Market, Privacy Policy Manager (PPM)

1. はじめに

情報通信技術の発展により、多種多様かつ大量のデータの収集・分析が可能となっており、それにより新たなサービスが生み出されてきている。パーソナルデータの利活用を通して、社会変革を進める試みが検討されている。情報銀行コンソーシアム¹⁾ などでは、プライバシーセンシティブな個人の情報を集積し積極的に活用しようという方針のもと、様々な検討がなされている。そうした、プライバシーセンシティブな情報の利活用においては、プライバシー・バイ・デザイン²⁾のもと、プライバシーに配慮した適切な運用が求められる。一方、個人のデータは個人のコントロールに委ねるという考えのもと、Personal Data Store (PDS)が検討されているが、個人でPDSを準備し運用することは容易ではない。本稿では、プライバシーに配慮しつつ、データの利活用を推進するデータ流通基盤技術について述べる。

2. データ流通基盤のコンセプト

本節では、我々が検討を進めているデータ流通基盤のコンセプトを説明する。図1にアーキテクチャを示す。本流通基盤で想定しているのは、個人 PDS がクラウドサービス上で集積された集合型 Personal Data Store である。このコンセプトは、いわゆる「情報銀行」の具体的な実現モデルの 1 つとして位置づけられ、各個人が PDS を個別に構築運用するよりも実現性が高いアーキテクチャである。個人 PDS は、パーソナル情報の第三者提供に特化したデータ格納領域であり、クラウドサービス上で、セキュアに分割され構成される。個人 PDS には、様々なデータソースから、データ所有者(個人)が許可した情報のみが格納される。その際、データ所有者の希望を考慮して、個人特定性を低減するような加工を施して格納するケースも考えられる。また、データ所有者は、どのようなサービスであれば(さらなる集合匿名化を行った後に)第三者提供して良いか、どのような加工をすれば提供しても良いか、等の情報を、プライバシープリファレンスとして個人 PDS に登録しておく。集合型 PDS では、複数の個人 PDS から提供されたデータを結合させて集合データ(データセット)を生成し、データセットのプライバシーリスクを評価し、リスクが基準を満たしていなければ適切に集合匿名化を施し、データを利用したい事業




図1: データ流通基盤のコンセプト

者に提供する。また、上記の個人 PDS から情報を提供する際に、それぞれ設定されたプライバシープリファレンスが考慮され、データの提供可否が判断される仕組みとなる。左記については、Privacy Policy Manager (PPM)²⁾機能を具備することで実現される。次節では、データ流通基盤を構成する各機能について、説明を行う。

3. データ流通基盤システム

データ流通基盤システムは、図 2 に示す通り、以下の機能が含まれる。各機能の詳細については、次節で説明する。

- 匿名化レベルによる匿名化機能:
本機能は、PDS にデータを投入する前に加工を行う機能である。
- プライバシープリファレンス管理機能:
本機能は、データ所有者のプライバシープリファレンスを管理し、プリファレンス情報を集合データ生成、匿名化処理等の際に提供する機能である。
- プライバシーリスク評価・再匿名化機能:

力する。学習データは、 $m \times n$ の行列であり、 m が被験者、 n が質問 ID を表し、行列の値は対応する被験者のプリファレンスとなる。以下のように推測モデルの生成を行う。

- ① 設定ファイルで定義されているモデル生成に使用する学習データ数、モデル生成 に使用する評価データ数にしたがって、学習データからサンプルを抽出する（以後前者をモデル生成学習データ、後者をモデル生成評価データと呼ぶ）。
- ② 設定ファイルで定義されている質問数にしたがって、質問 ID を選択する。
- ③ モデル生成学習データのうち、選択された質問 ID に対応するデータを用いて、選択されなかった質問 ID に対応するデータを推測する SVM モデルを生成する。
- ④ 生成された SVM モデルと、モデル生成評価データのうち選択された質問 ID に該当するデータを用いて、選択されなかった各質問 ID に対応する推測値を算出する。推測値と実際のモデル生成評価データの値を比較し、精度を算出する。
- ⑤ 全ての質問 ID の組み合わせについて、②-④を繰り返す。
- ⑥ 最も精度がよかった場合の質問 ID の組み合わせを最適な質問の組み合わせとし、 そのときの SVM モデルを推測モデルとして出力する。




図 3: プライバシプリファレンスの推測決定機能

プリファレンス推測機能は、生成された最適な質問の組み合わせを入力として、入力に用いた質問 ID 以外のプリファレンスを推測する機能である(図3)。本機能では次のように推測値を出力する。なお、本機能の詳細については、別稿³⁾を参照されたい。

- ① 入力された回答と、各質問 ID に対応する SVM モデルを用いて、各質問 ID に対応する推測値を取得する。
- ② 取得した推測値を出力する。
- ③ 出た所有者が出力された推測値なるプライバシープリファレンスの確認を行い、問題が無ければ個人 PDS に登録する。

2.3 プライバシリスク評価・再匿名化機能

プライバシーリスク評価・再匿名化機能は、複数のユーザの匿

名化済みのデータの集合(データセット)において、個人が再識別されるリスクを自動で評価するとともに、リスクが基準を満たしていなければデータセットの再匿名化を行う機能である。例えば、入力したデータセットは K-匿名性が保たれているかどうかを評価するとともに、データセットの各個人情報情報を匿名化させることで、より匿名化の強度を高めることが出来る。本機能は、プライバシー評価機能と、再匿名化機能というサブコンポーネントから構成され、大規模な集合データに対しても適応可能となっている。また、匿名化処理については、複数の匿名化手法を組み合わせることで適用できるようになっており、さらに複数の匿名化手法を組み合わせた場合でも、個人が再識別されるリスクを適切に評価できるようになっている。以下、リスク評価手法について述べる。

従来手法では、匿名化後のデータの一般公開を想定しているため、攻撃者の背景知識を想定することが困難であると仮定しており、非常に強い攻撃者を想定する必要があった。このような攻撃者の仮定のもと十分な安全性を維持しようとした場合、データの有用性を同時に維持することは困難であり、匿名化データの有効活用が思うように進まないことが考えられる。しかし匿名化したデータセットは、流通経路を明確にする、匿名化データへのアクセスを権限のあるユーザのみにするなど十分安全に運用することにより、攻撃者の背景知識を抑えることができることが知られている。我々は、このような現実的な仮定のもとに攻撃者が知り得る情報が限定されている場合についてのリスクを評価するためシミュレーションベースのリスク評価手法を導入する。リスク評価を行うにあたり、匿名化シミュレータを構築する必要がある。シミュレータは内部関数として匿名化機能(匿名化処理をシミュレートする機能)を呼び出す構成となるが、実際にどのような匿名化を実施したか、また想定される攻撃者がその加工手段を知り得るかどうかによって大きく異なる。我々の評価手法では複数の匿名化手法に対応するため、複数のシミュレータを構築し、それぞれに対してシミュレーションを実施して評価できるようにした。シミュレータの構築方法は多種多様であるが、実際の加工手段とあまりにも乖離しているシミュレータを用いた評価は実施する意味を持たないため、あくまで妥当なシミュレータを構築している。本手法の詳細については、別稿⁴⁾を参照されたい。

4. おわりに

本稿では、プライバシーに配慮しながら安全なデータ流通を実現するデータ流通基盤技術について述べた。今後は、本基盤を実装し、実証実験を行っていく予定である。

謝辞: 本研究は、JST CREST の支援を受けたものである。

参考文献

- 1) 情報銀行コンソーシアム, <http://www.information-bank.net/>
- 2) S. Kiyomoto, T. Nakamura, H. Takasaki, R. Watanabe, Y. Miyake, PPM: Privacy Policy Manager for Personalized Services, CD-ARES 2013: Security Engineering and Intelligence Informatics pp 377-392, 2013.
- 3) T. Nakamura, S. Kiyomoto, W. B. Tesfay, and J. Serna, Personalised Privacy by Default Preferences - Experiment and Analysis. In proc. of ICISSP 2016, pp. 53-62, 2016.
- 4) T. Mimoto, S. Kiyomoto, K. Tanaka, A. Miyaji, (p, N) - identifiability: Anonymity Under Practical Adversaries, Proc. of IEEE TrustCom 2017, to appear.