

平成21年度情報大航海プロジェクト
共通技術開発
「パーソナル情報保護・解析基盤」

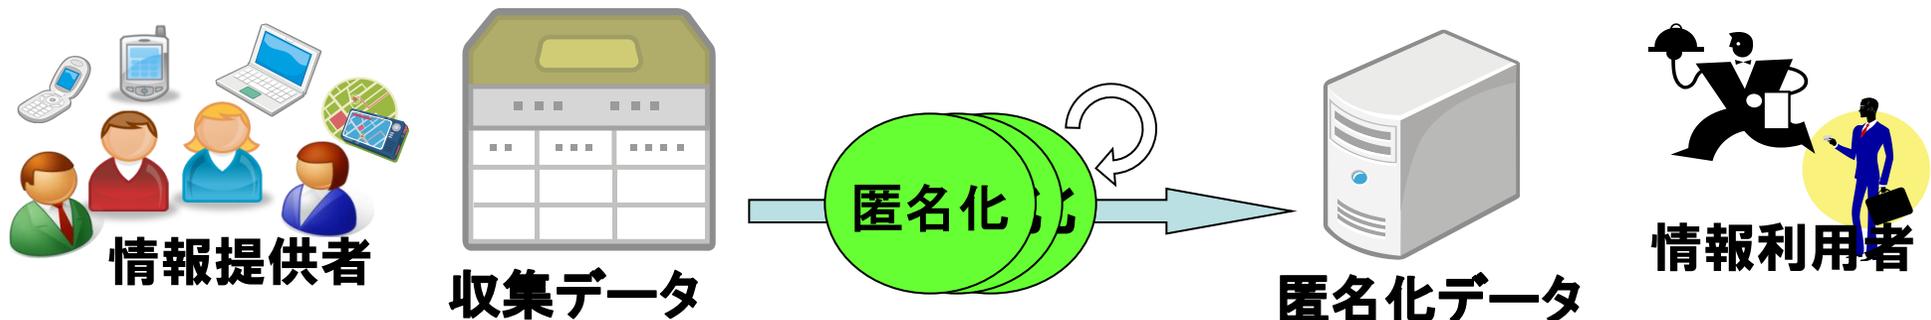
情報大航海プロジェクトにおけるプライバシー保護

山口(繁富)利恵

財団法人日本情報処理開発協会 株式会社三菱総合研究所 独立行政法人産業技術総合研究所
日本電信電話株式会社 NTTソフトウェア株式会社 ジェイエムテクノロジー株式会社 有限責任中間法人PUCC
NTTアドバンステクノロジー株式会社 ビジネスマイニング研究センター有限責任事業組合

情報大航海における匿名化のアプローチ

- ❏ 情報を収集し、その情報を利活用する際のプライバシー保護の**取り扱い基準**を考えましょう
 - ▶ この基準に沿えば、利用者(情報提供者)に対し、**安心を提供**できるような枠組みを。
 - ▶ 情報大航海の中では、あくまでも**集合匿名化**に特化して考察。
- ❏ 集合匿名化の基準として、 k 匿名性を採用
 - ▶ 技術的に評価をするためには、 k 匿名性が**現状取り得ることのできる基準として、適切**である
 - ▶ k 匿名性を満たしたデータであれば、個人情報保護されたということとする
- ❏ この指標を適用するデータに適用するのかを**基盤利用マニュアル**で示す
- ❏ k 匿名性を満たした情報を実現する枠組みの検討 (**確認・認証の枠組み**) が今後必要



基準の定義

母集団一意性を満たすために技術**基準**が必要

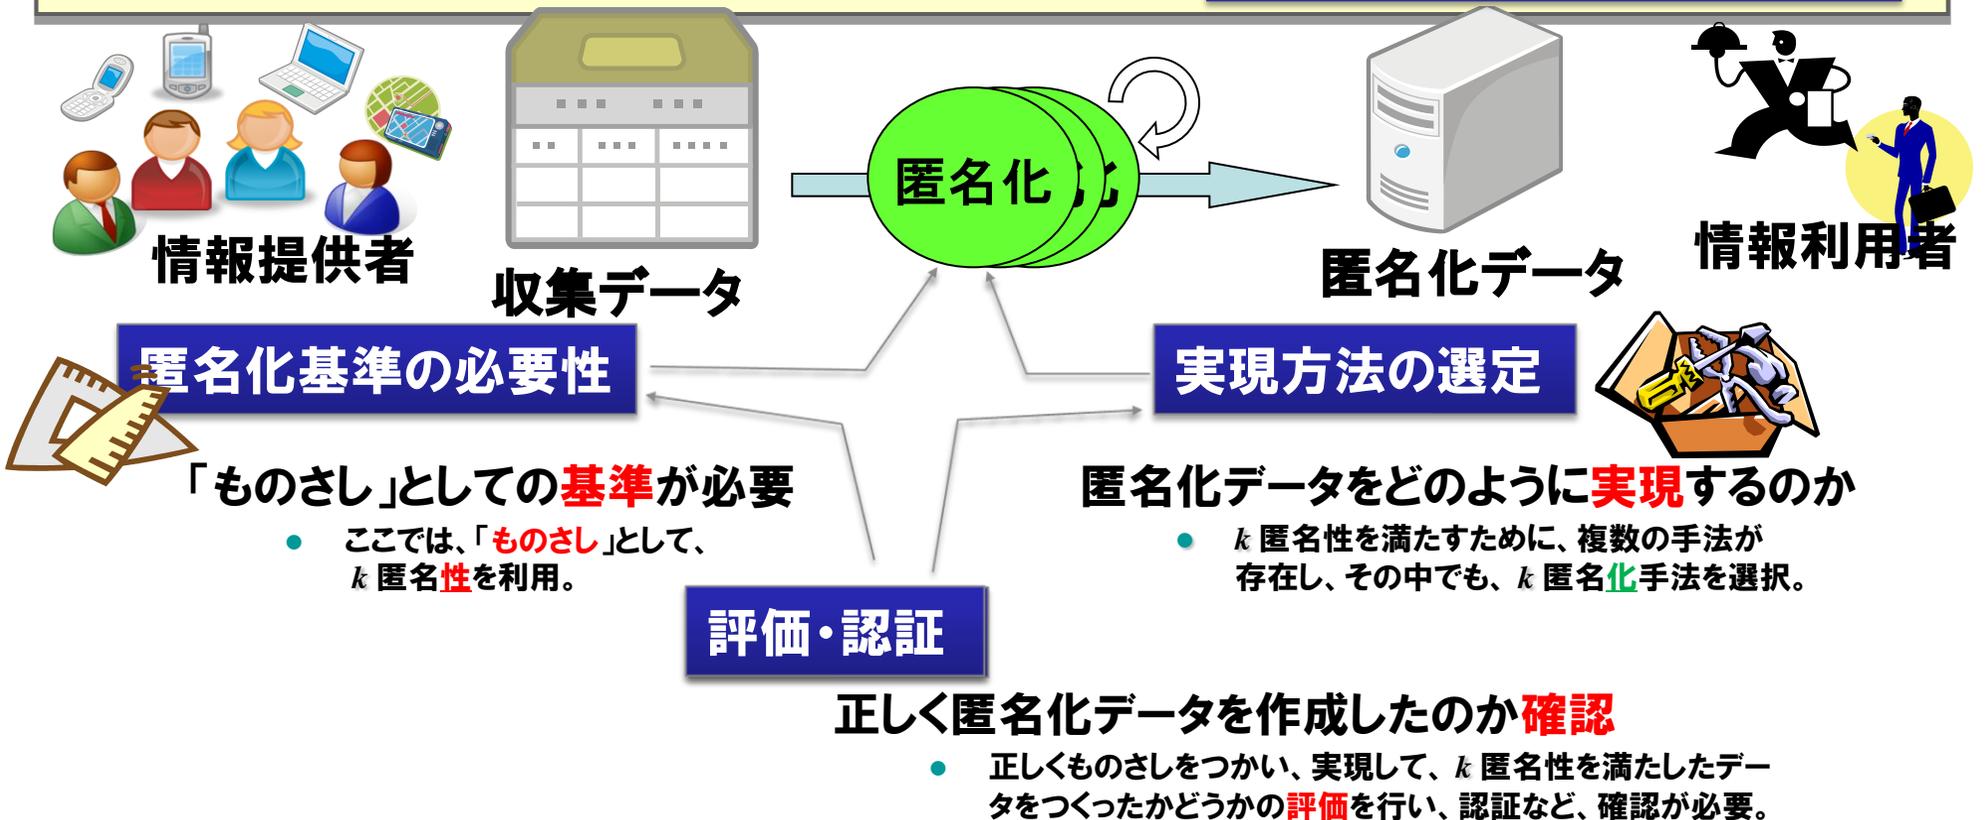
- ▶ ここでは、「**ものさし**」として、 k 匿名性を利用

匿名化データをどのように**実現**するのか

- ▶ k 匿名化を満たすために、複数の手法が存在し、その中でも、 k 匿名化手法を選択
- ▶ 実現するためには、安全性の整理も必須

匿名化したあとのデータの性質についての基準

上の基準を満たすためにどのような技術を利用すべきかを考える



k 匿名化の実現状況

■ k 匿名性を満たしている情報にもいろいろな段階がある。

1. 匿名化データをどのように準識別子の取り方を考えても、k 匿名性を満たしている状態
2. ある準識別子に注目すると、k 匿名性を満たしている状態
3. 技術的には、2.と同義となる場合もあるが、一般的に、個人情報保護法において、個人情報保護された情報であるという状態



匿名化データ

1. どの準識別子だとしても大丈夫

18000**	男	3*
18000**	男	3*
18000**	男	3*
18100**	女	4*
18100**	女	4*
18100**	女	4*
18000**	男	50以上

2. ある準識別子に注目すると、k 匿名性を満たしている

郵便番号	性別	年齢	趣味
18000**	男	3*	アニメ
18000**	男	3*	アニメ
18000**	男	3*	アニメ
18100**	女	4*	映画
18100**	女	4*	アニメ
18100**	女	4*	ドラマ
18000**	男	50以上	映画
18000**	男	50以上	ドラマ
18000**	男	50以上	ドラマ
18000**	男	50以上	時代劇

3. 識別子のみ削除してあるだけで、k 匿名性を一切満たしていない

勤務地	年齢	職業	年収
東京都港区西新橋2丁目	33	船乗り	1,000万円
東京都千代田区霞が関1丁目	21	放送局	2,000万円

この条件を満たす人は一人しかいないが、3つの準識別子に注目すると、3-匿名性を満たしている

匿名化データの作り方

- k 匿名性を満たしたデータを定義したとしても、一意には決まらない
- 準識別子の取り方には複数の種類がある。
 - ▶ ものさしの当て方も、一意には決まらない
- 情報利用者にとって、それぞれに必要な情報が違うので、有用な匿名化方法を利用者自身が見つけなければならない。



匿名化データ



同じデータを利用したとしても、有用性が変わってくるので、利用者にとって、必要な取り方をしなければならない

どんな風にものさしをあてようか？

郵便番号	性別	年齢	趣味
18000**	男	3*	アニメ
18000**	男	3*	アニメ
18000**	男	3*	アニメ
18100**	女	4*	映画
18100**	女	4*	アニメ
18100**	女	4*	ドラマ
18000**	男	50以上	映画
18000**	男	50以上	ドラマ
18000**	男	50以上	ドラマ
18000**	男	50以上	時代劇

趣味	郵便番号	性別	年齢
アニメ	1800001	男	31
アニメ	1800001	男	33
アニメ	1800030	男	35
アニメ	1810045	女	45
ドラマ	1800030	男	53
ドラマ	1800045	男	62
ドラマ	1810045	女	46
映画	18100**	女	4*
時代劇	18000**	男	50以上

このデータは利用できない

基準を満たした実現方法の選択と今後の課題

■ 匿名化データを実現するためにはどのようにしたらよいのか

- ▶ 経験的なやり方として、名前・住所など個人を特定する情報を**削除**という手法は既に存在。
- ▶ 情報を集めないような手法(暗号を利用した検索手法や、匿名認証手法など)は、今回の範囲外。 ← まず、**情報を収集している**、というところからスタート

■ k 匿名性のデータを実現するための手法としては、様々存在する

- ▶ 匿名化データを定義したとしても、実現手法は、**一つには決まらない**。
- ▶ k 匿名化か母集団一意におけるリスク評価にするか
 - ここでの、 k 匿名化か母集団一意か、というのは評価の軸(ものさし)としてではなく、**実現手法**なので、注意

→ 現状では、ある特定サービスについての二次利用処理については、 **k 匿名化が適切**

■ 正しく匿名化を行ったかどうかを確認する認証・制度が必要

- ▶ ものさしを正しくあてることができたのか。
- ▶ あてたものさしを正しく実現したのか。

→ 今後の課題として、認証制度などの**評価の枠組み**の検討が必要