

分析結果の持ち出し 標準的なチェック内容の解説

南 和宏

統計数理研究所、(独)統計センター

オンサイト利用全体の概要

イメージ

秘密情報の
漏洩防止が必要

- ◆ 利用者窓口
- ◆ 利用申出・分析結果提供時の審査
- ◆ データ・システムの管理 等を担当

各府省
(総務省統計局等の調査実施部局)

- ◆ 調査票情報を収録
- ◆ 統計センターに利用者窓口等、
所要の関連業務を委託

オンサイト施設



専用サーバ



オンサイト施設

SINET等

(VPNサービスを利用)

管理者



(中央データ管理施設)

仮想PC

仮想PCを遠隔操作

集計・分析結果を表示
(USBメモリ等の記憶
装置は**使用できない**)

安全性を確認した上で
分析結果の提供を依頼

利用者

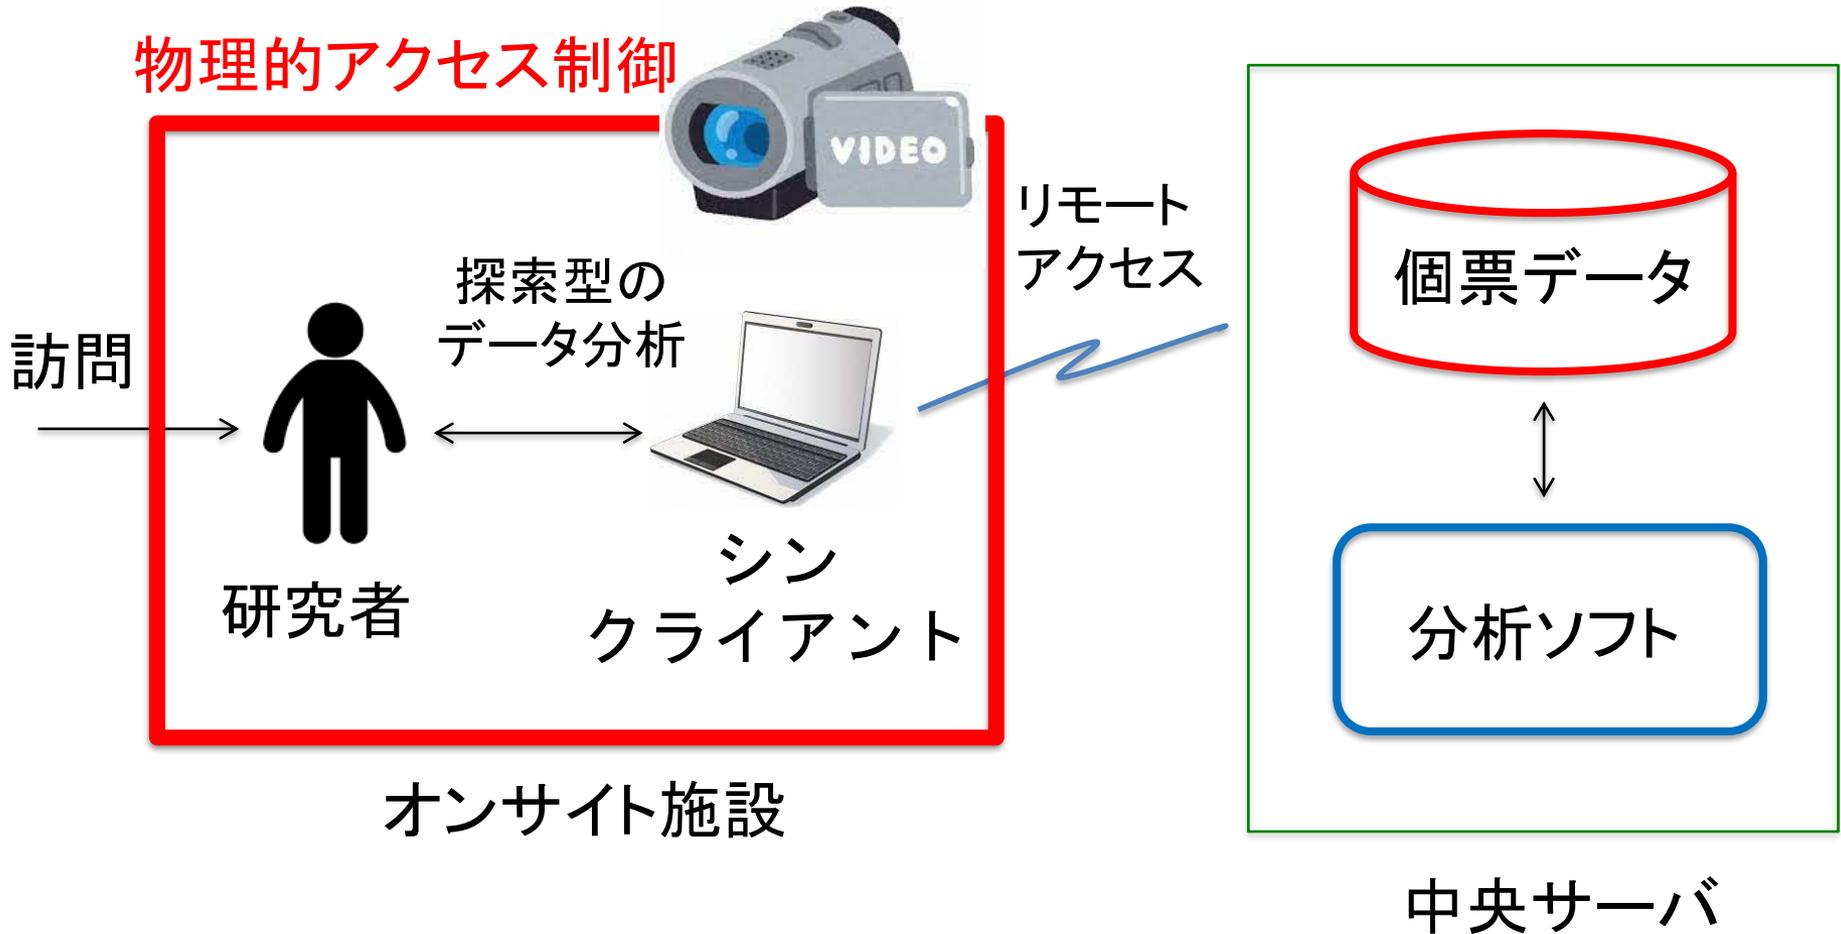


オンサイト施設

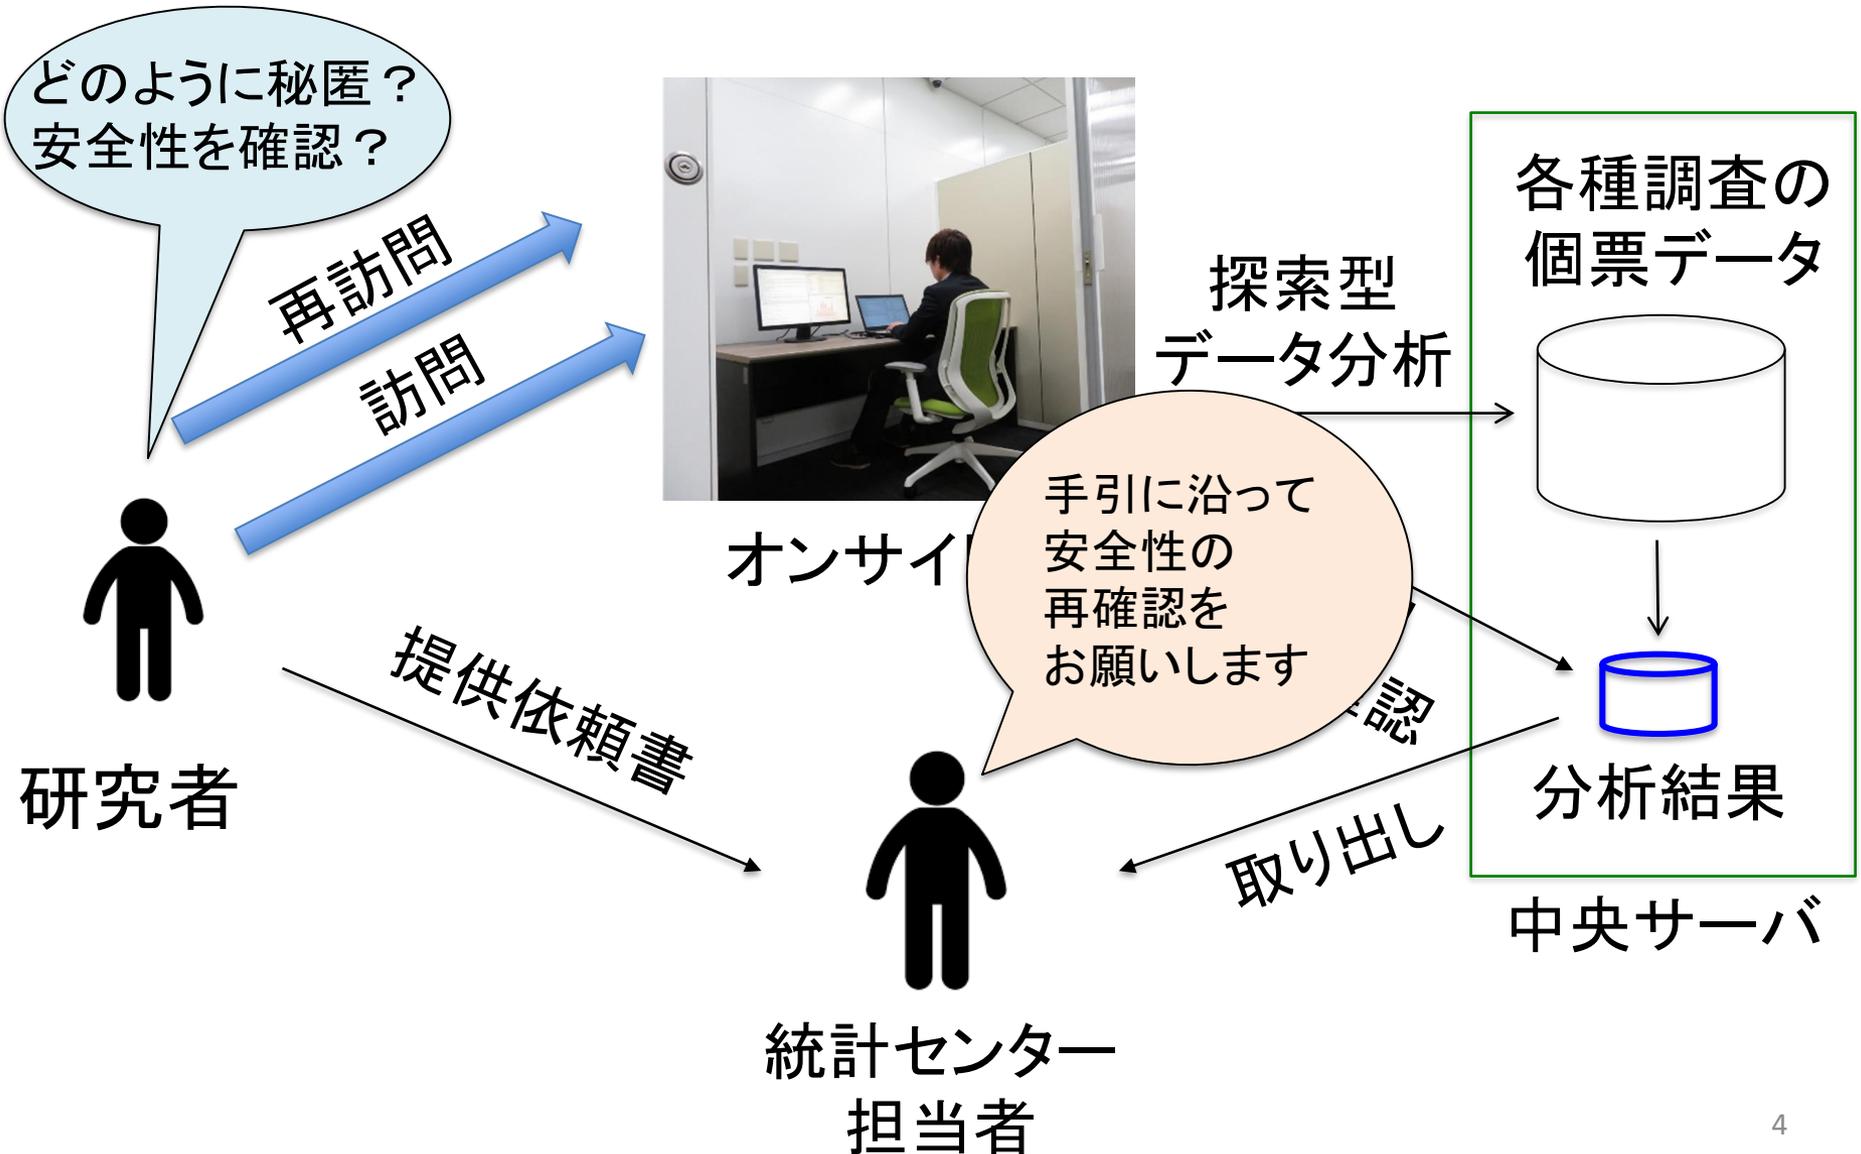
監視カメラ

オンサイト施設

オンサイト施設の利用



分析結果の持ち出しと安全性確認



説明内容

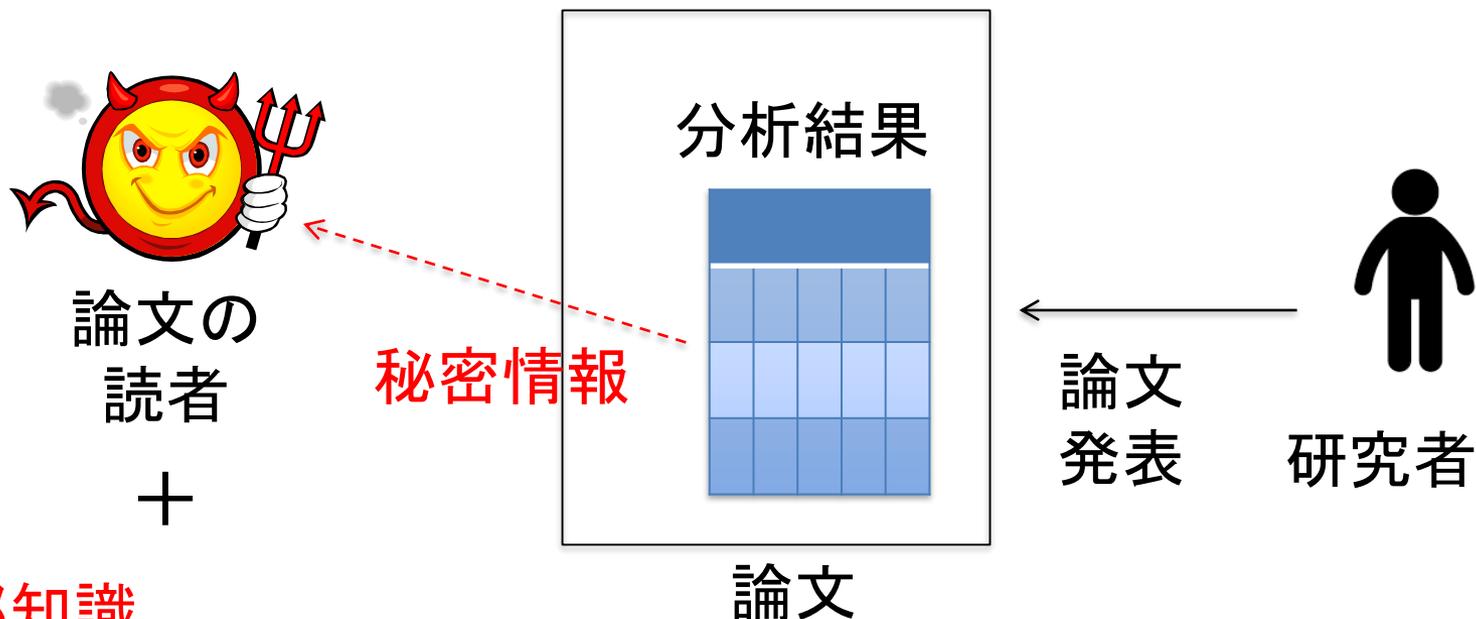
- 安全性確認の目的
- 確認基準の原則
- 標準的なチェック内容
- 統計表の秘匿処理

調査対象者(客体)の 秘密情報保護

- 家計消費状況調査
 - 調査世帯の購入状況
 - 頻度の少ない高額商品
- 全国消費実態調査
 - 家計資産の総合調査
 - 家計の収入、土地等の資産額
- 就業構造基本調査
 - 就業及び不就業の状態
 - 雇用契約期間、仕事内容

情報漏えいシナリオ

- 研究者の **不注意**により論文に掲載される分析結果からの情報漏えいを防止



外部知識
(例: 調査客体の地域情報)

統計表の例

度数表
(職業・地域が
一致する
レコード数)

地域

職業

	P ₁	P ₂	P ₃	P ₄	P ₅	合計
M ₁	20	15	30	20	10	95
M ₂	72	20	1	30	10	133
M ₃	38	38	15	40	2	133
合計	130	73	46	90	22	361

数量表
(収入の総和)

地域

職業

	P ₁	P ₂	P ₃	P ₄	P ₅	合計
M ₁	360	450	720	400	360	2290
M ₂	1440	540	22	570	320	2892
M ₃	722	1178	375	800	363	3438
合計	2522	2168	1117	1770	1043	8620

外部者による攻撃

度数表
(職業・地域が
一致する
レコード数)

地域

職業

	P ₁	P ₂	P ₃	P ₄	P ₅	合計
M ₁	20	15	30	20	10	95
M ₂	72	20	1	30	10	133
M ₃	38	38	15	40	2	133
合計	130	73	46	90	22	361

数量表
(収入の総和)

地域

職業

	P ₁	P ₂	P ₃	P ₄	P ₅	合計
M ₁	360	450	720	400	360	2290
M ₂	1440	540	22	570	320	2892
M ₃	722	1178	375	800	363	3438
合計	2522	2168	1117	1770	1043	8620

調査客体による攻撃

度数表
(職業・地域が一致するレコード数)

職業

地域	職業				
	P ₁	P ₂	P ₃	P ₄	P ₅
M ₁	20	15	1	5	10
M ₂	72	20	15	40	2
M ₃	38	38	15	40	2
合計	130	73	46	90	22

自分の地域・職業は知っている

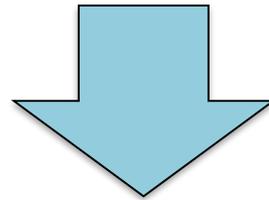
数量表
(収入の総和)

地域	職業					合計
	P ₁	P ₂	P ₃	P ₄	P ₅	
M ₁	1440	540	225	570	320	2290
M ₂	722	1178	375	800	363	2892
M ₃	722	1178	375	800	363	3438
合計	2522	2168	1117	1770	1043	8620

自分の収入を引けばもう1人の収入が分かる

Eurostat基準（SDCハンドブック）を ベースにした安全性基準

- 安全性基準の作成は、「どのような動物がくるか分からない動物園のおりの設計」をするようなもの



- 確認対象は標準的な形式に限定
 - 度数表、数量表
 - 回帰係数、相関
 - 記述統計（平均、分散、etc.）

2つの確認ルール

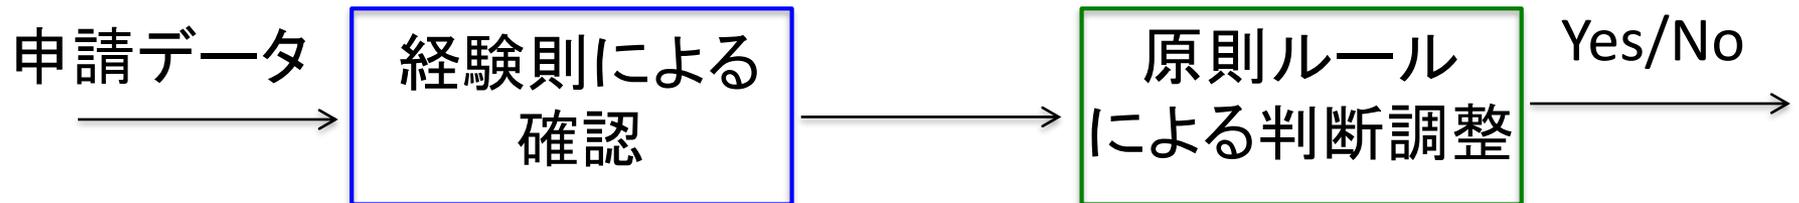
• 経験則

- 明示的に記述されたルール
- 保守的で厳格な基準
- 機械的な確認が可能

標準的なチェック内容

• 原則ルール

- 安全基準の原則を記述し、個別の状況に柔軟に対応
- データの意味(セマンティックス)、特徴を考慮

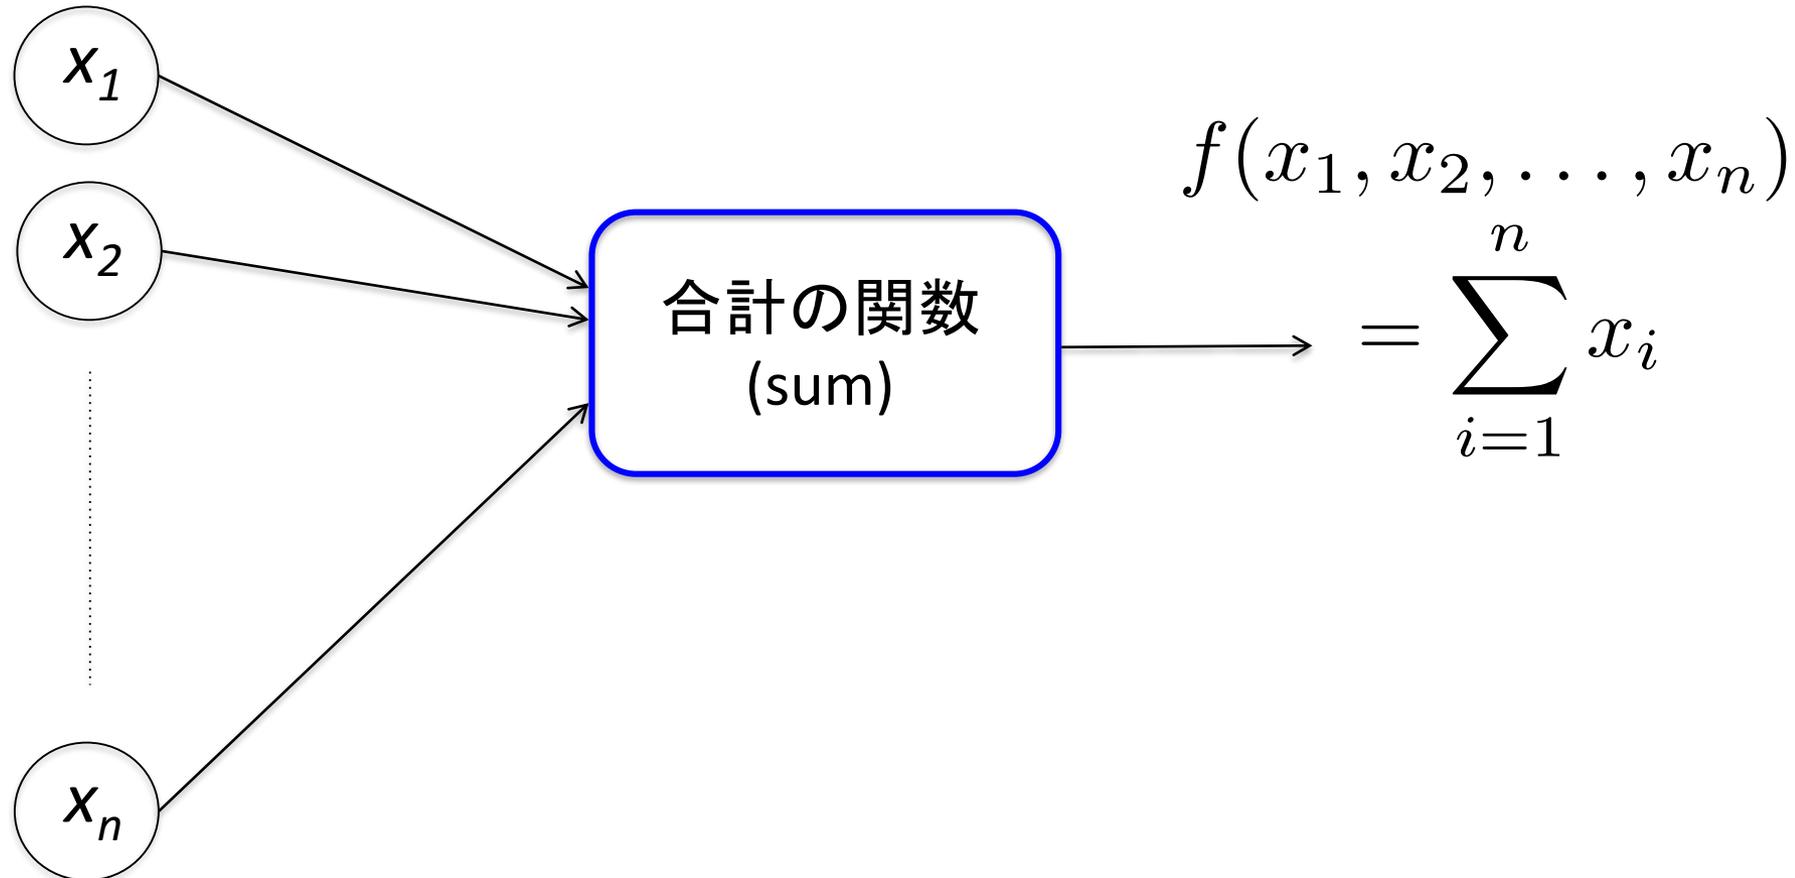


持ち出し基準の原則

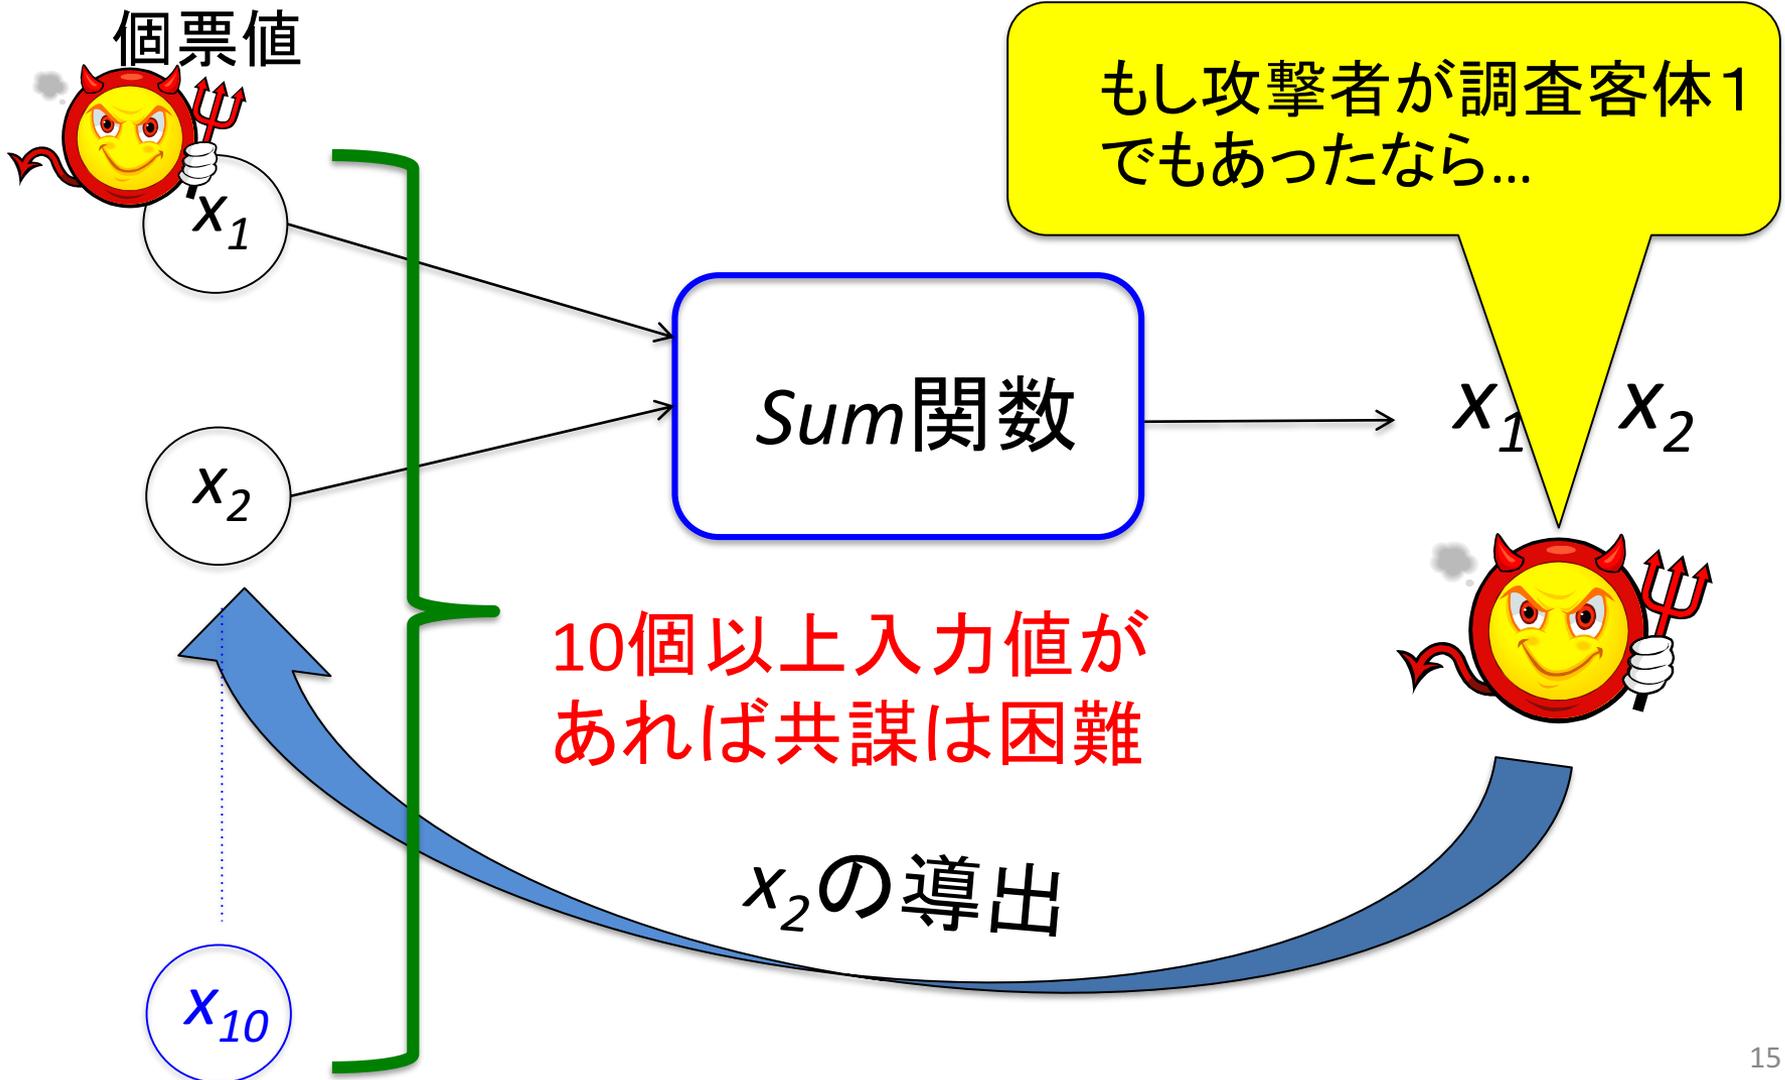
- 個票データは秘密情報
 - 原則、全ての個票データの属性情報は秘密とする
- 客体10の原則
 - 統計値は10個以上の客体から算出されていること
- 占有性の原則
 - 特定の客体の値が合計の70%超を占有しないこと
- グループ開示の防止
 - ある属性でグループ化された個票の90%超が、別の属性に関して同一の区分に属することを防止する

分析結果は複数の個票値を 入力とする関数の出力とみなせる

個票値



客体10の原則



占有性の原則

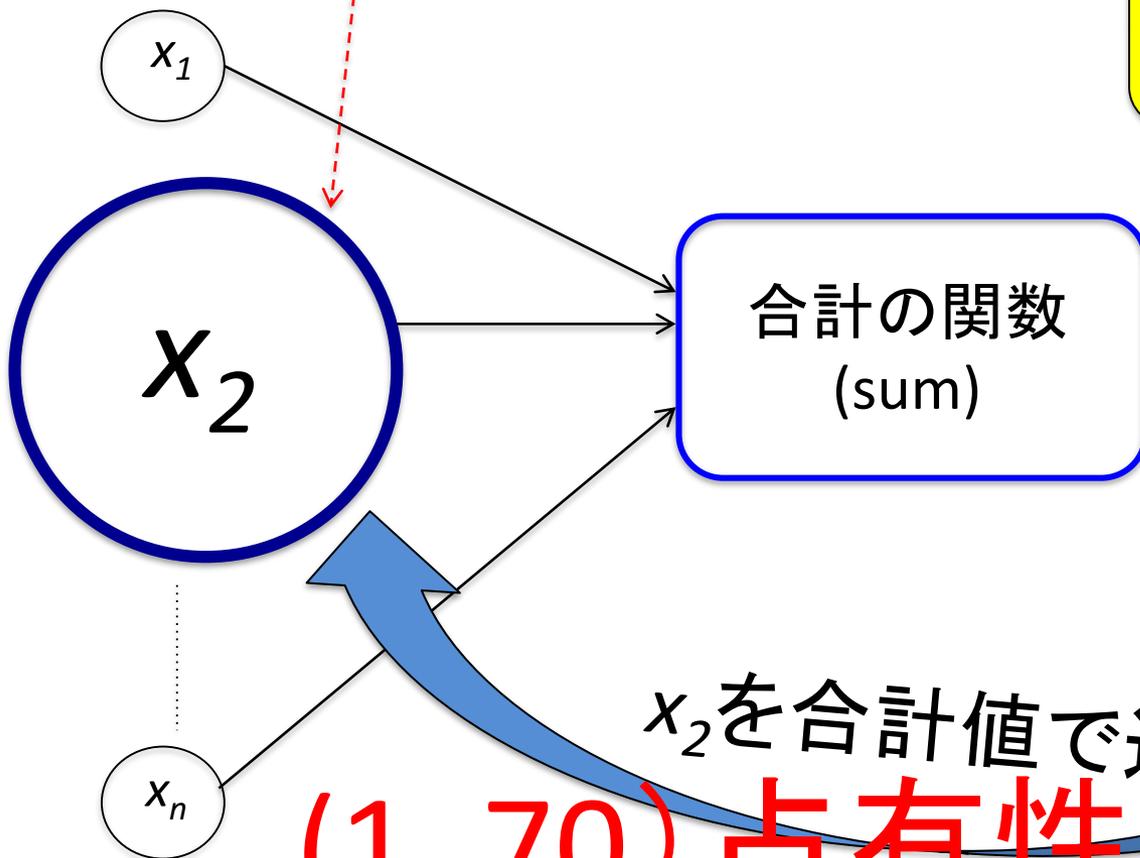
個票値

第1位が全体の70%超を

調査客体2が大差の1位だ

$$f(x_1, x_2, \dots, x_n)$$

$$= \sum_{i=1}^n x_i$$



(1, 70) 占有性ルール



占有性の原則の拡張

個票値

第1位+第2位が全体の85%超を
占めてはいけない

もし攻撃者が第2位でも
あったなら...

$$f(x_1, x_2, \dots, x_n)$$

合計の関数
(sum)

$$= \sum_{i=1}^n x_i$$

x_2 を(合計値- x_1)で近似

(2, 85) 占有性ルール

多くの確認基準は原則の単純な適用

- 個票データは秘密情報
 - 最小値、最大値の持ち出しは不可
- 客体10の原則
 - 度数表 → 各セルの度数は10以上
 - 記述統計量(平均, 回帰係数) → 自由度10以上
- 占有性の原則
 - 数量表 → 第1位寄与率70%以下
 - 第1位 + 第2位寄与率85%以下

標準的なチェック内容が対象とする 分析結果の形式

- 度数表
- 数量表
- 線形回帰係数
- 非線形回帰係数
- 最頻値
- 集中度
- 平均、比率等
- 要約統計量、分布の高次モーメント、相関係数

ただし、提供依頼には 安全性の説明資料が必要

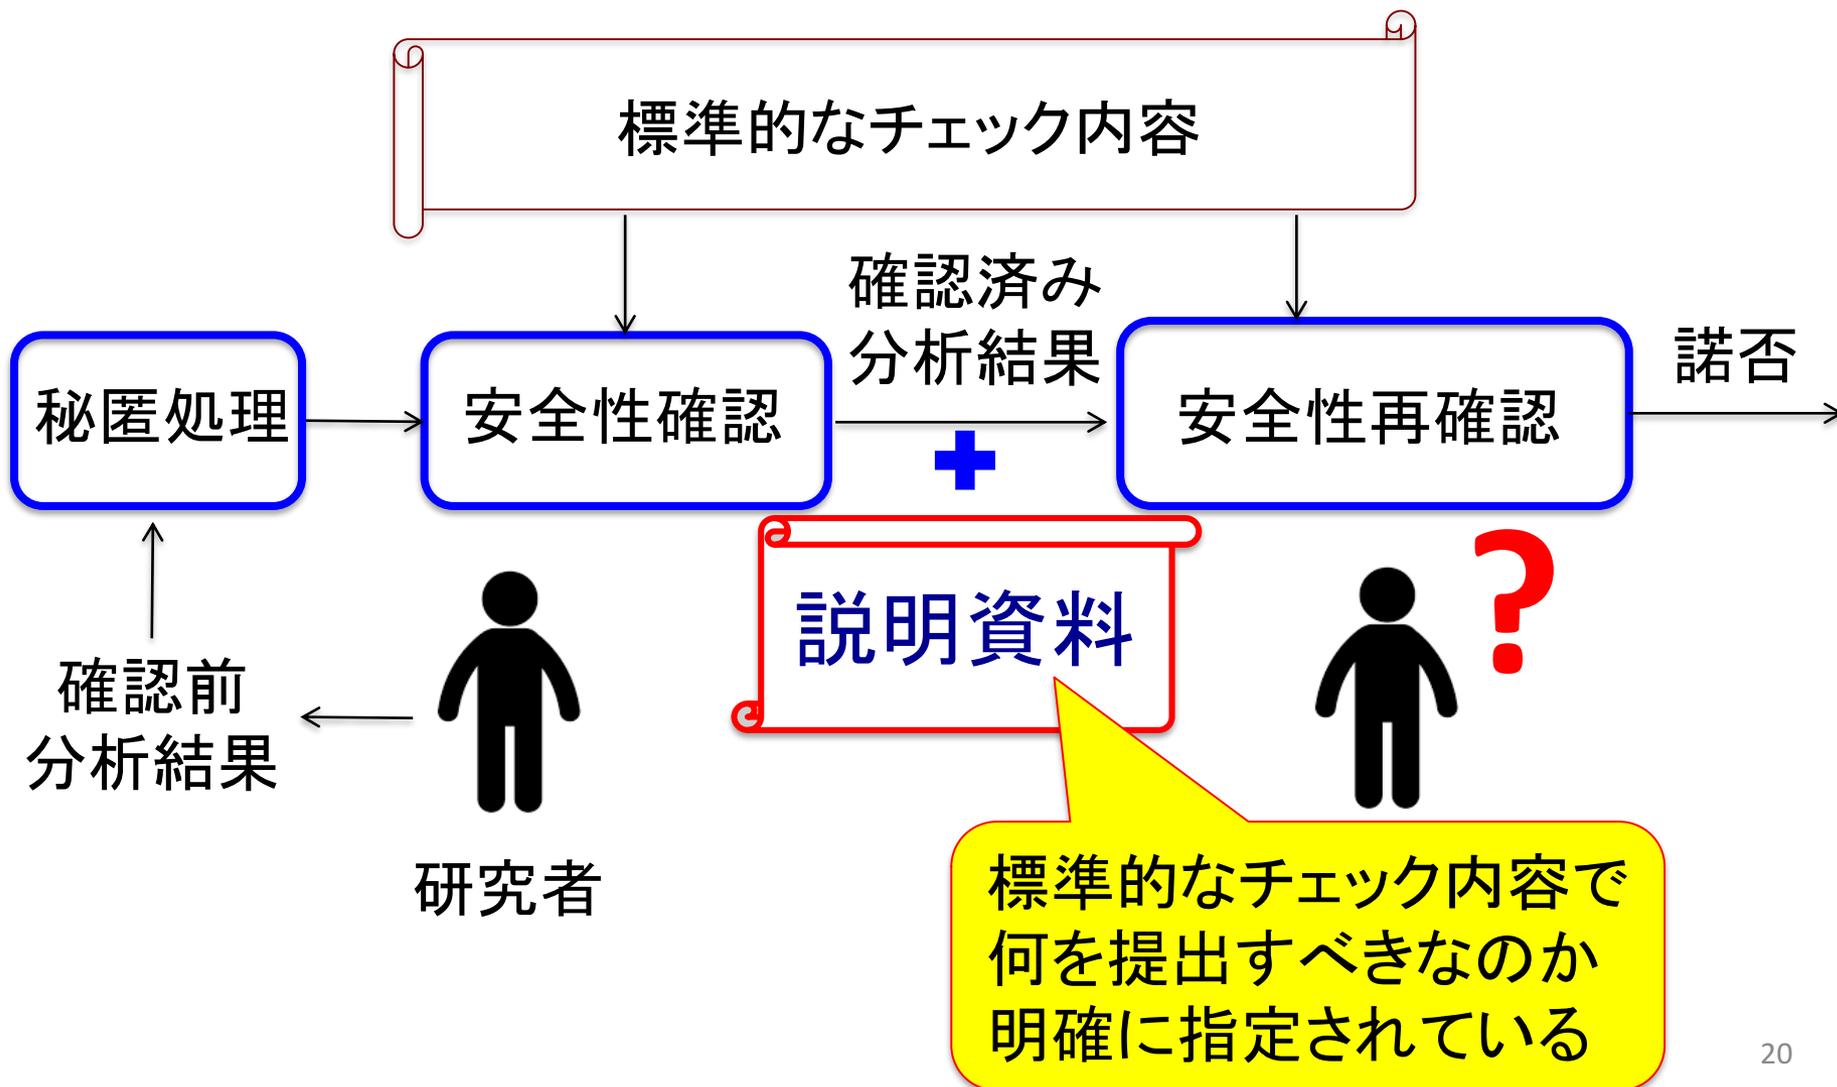


表1 標準的なチェック内容

分析結果等の種類 ^{*1}	チェック内容 ^{*2}	申出者が提示する情報 ^{*7}
一 統計表	①【度数】各セルが1以上10未満の調査客体から算出した値でないこと(加重なし ^{*3})	①【度数】各セルの度数(加重なし ^{*3})
	② ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重なし ^{*3})	② ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重なし ^{*3})
	③ ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重あり ^{*4})	③ ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重あり ^{*4})
2.1 数量表(総和) (個人・世帯調査の場合)	①【度数】各セルが1以上10未満の調査客体から算出した値でないこと(加重なし ^{*3})	①【度数】各セルの度数(加重なし ^{*3})
	② ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重なし ^{*3})	② ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重なし ^{*3})
	③ ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重あり ^{*4})	③ ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重あり ^{*4})
	2.2 数量表(総和) (事業所・企業調査の場合)	①【度数】各セルが1以上10未満の調査客体から算出した値でないこと(加重なし ^{*3})
②【数量】各セルにおいて、70%を超えて寄与する調査客体がないこと(変数変換なし ^{*5})		②【数量】各セルにおいて最も大きく寄与する調査客体の値 x_1 及び x_1 がセルの値 X に占める割合(変数変換なし ^{*5})
③【数量】各セルにおいて、85%を超えて寄与する二つの調査客体の合計値がないこと(変数変換なし ^{*5})		③【数量】各セルにおいて一番目及び二番目に大きく寄与する調査客体の値 x_1, x_2 及び x_1, x_2 の合計値がセルの値 X に占める割合(変数変換なし ^{*5})
④ ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重なし ^{*3})		④ ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重なし ^{*3})
⑤ ^{*6} 【度数】行計又は列計の90%超を占めるセルがないこと(加重あり ^{*4})		⑤ ^{*6} 【度数】各セルの構成比(行計及び列計に占める割合)(加重あり ^{*4})

度数チェック

(1,70)占有性ルール

(2,85)占有性ルール

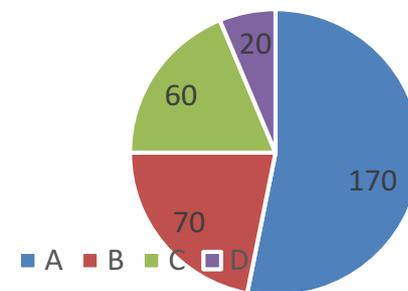
占有性ルールの確認

- 確認には元の個票データが必要

	P ₁	P ₂	P ₃	P ₄	P ₅	合計
M ₁	360	450	720	400	360	2290
M ₂	1440	540	22	570	320	2892
M ₃	722	1178	375	800	363	3438
合計	2522	2168	1117	1770	1043	8620

事業所売上の合計

収入



仮名	業種	地域	売上
A	P5	M2	170
B	P5	M2	70
C	P5	M2	60
D	P5	M2	20

占有性ルールの確認プロセス

研究者

売上	P5
M2	320

1. 集計

2. 分析結果

+ 第一位、第二位の客体の値

仮名	業種	地域	売上
A	P5	M2	170
B	P5	M2	70
C	P5	M2	60
D	P5	M2	20

個票データ

統計センター

売上	P5
M2	320

1位	P5
M2	170

2位	P5
M2	70

+ 寄与率

表2 統計表における秘匿措置

秘匿方法	秘匿措置	
1.集計区分の変更	各セルに集計される区分を変更して再度集計を行い、表1の内容を満たすようにすること。 集計区分の変更方法には、既存の区分の分割、他の区分と統合、新たな区分の設定がある。	
2.集計対象の変更	集計対象の範囲を拡大又は縮小して再度集計を行い、表1の内容を満たすようにすること。 (例：集計対象が、あるグループXに属する調査客体のみから作成した統計表の場合、 ①グループYに属する調査客体を集計対象に加えて新たな統計表を作成する(拡大)。 ②グループXに属する調査客体のうち、他の調査客体から大きく外れた値を持つ調査客体などを除外して新たな統計表を作成する(縮小)。)	
3.セルの値を秘匿	<p>以下の一次秘匿、二次秘匿、秘匿インターバルの各内容を満たすようにすること。</p> <p>①一次秘匿 表1の内容を満たさないセルの値を「X」などのマークに置き換え、具体的な値を掲載しないようにすること。</p> <p>②二次秘匿 一次秘匿を行ったセルの値が他のセルの値や行計・列計等から算出できる場合、これを算出できないように一次秘匿の対象となるセル以外のセルの値を「X」などのマークに置き換え、具体的な値を掲載しないようにすること。</p> <p>③⁶秘匿インターバル(度数表の場合) 一次秘匿した各セルが取り得る値の最大と最小の差(秘匿インターバル)が度数10以上であること。</p> <p>④⁶秘匿インターバル(数量表の場合) 一次秘匿した各セルが取り得る値の最大と最小の差(秘匿インターバル)が、当該セル値の30%以上であること。</p>	<p>申出者が提示する情報⁷⁾</p> <p>①秘匿前の統計表</p> <p>②一次秘匿した各セルの位置を明示する情報</p> <p>③(度数表の場合) 一次秘匿した各セルが取り得る最大値、最小値及び最大値と最小値の差</p> <p>④(数量表の場合) 一次秘匿した各セルが取り得る最大値、最小値及び最大値と最小値の差を当該セル値で除した割合</p>

秘匿セルを含む統計表

集計表

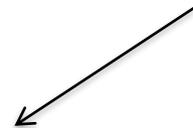
	P ₁	P ₂	P ₃	合計
M ₁	20	24	28	72
M ₂	38	38	40	116
M ₃	40	39	42	121
合計	98	101	110	309

1次
秘匿



	P ₁	P ₂	P ₃	合計
M ₁	20	24	28	72
M ₂	38	38	NA	116
M ₃	40	39	42	121
合計	98	101	110	309

2次
秘匿



	P ₁	P ₂	P ₃	合計
M ₁	NA	24	NA	72
M ₂	NA	38	NA	116
M ₃	40	39	42	121
合計	98	101	110	309

占有性ルール
を侵害

行計、列計の関係式から 秘匿セルの値が復元される可能性あり

- r 行 c 列の表には $(r+c)$ 個の線形制約条件が存在
- 各セル値は非負

		c 列		
	a_{11}	\cdots	a_{1c}	$a_{1(c+1)}$
	\vdots	\ddots	\vdots	\vdots
	a_{r1}	\cdots	a_{rc}	$a_{r(c+1)}$
r 行	$a_{(r+1)1}$	\cdots	$a_{(r+1)c}$	$a_{(r+1)(c+1)}$

$$\sum_{j=1}^c a_{ij} = a_{i(c+1)} \quad i = 1, \dots, r$$

$$\sum_{i=1}^r a_{ij} = a_{(r+1)j} \quad j = 1, \dots, c$$

秘匿セルをもつ統計表への追加要件

- 秘匿セルの取りうる値の幅(秘匿インターバル)がしきい値(度数分布表では10)以上であること

	P ₁	P ₂	P ₃	合計
M ₁	x_{11}	24	x_{13}	72
M ₂	x_{21}	38	x_{23}	116
M ₃	40	39	42	121
合計	98	101	110	309

1. 最小値問題

$$\underline{a}_{23} = \min x_{23}$$

拘束条件: $x_{11} + x_{13} = 72 - 24 = 48$
 $x_{21} + x_{23} = 116 - 38 = 78$
 $x_{11} + x_{21} = 98 - 40 = 58$
 $x_{13} + x_{23} = 110 - 42 = 68$
 $(x_{11}, x_{13}, x_{21}, x_{23}) \geq 0$

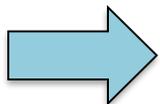
2. 最大値問題

$$\overline{a}_{23} = \max x_{23}$$

拘束条件: $x_{11} + x_{13} = 72 - 24 = 48$
 $x_{21} + x_{23} = 116 - 38 = 78$
 $x_{11} + x_{21} = 98 - 40 = 58$
 $x_{13} + x_{23} = 110 - 42 = 68$
 $(x_{11}, x_{13}, x_{21}, x_{23}) \geq 0$

and

秘匿インターバル $w = \max x_{23} - \min x_{23} = 68 - 20 = 48 > 10$



まとめ

- Eurostatハンドブックをベースにした経験ベース、原則ルール of 2段階確認の枠組みを採用
- 確認基準は4つの原則を具体化した単純なものが多いが、それらを検証する説明資料の要件を明確にすることが重要
- セル間に線形の関係性を内包する統計表については、秘匿インターバルに関する追加の安全性要件を定義
- 安全性の確認や説明資料の具体例は、「標準的なチェック内容の解説と例」で詳しく解説