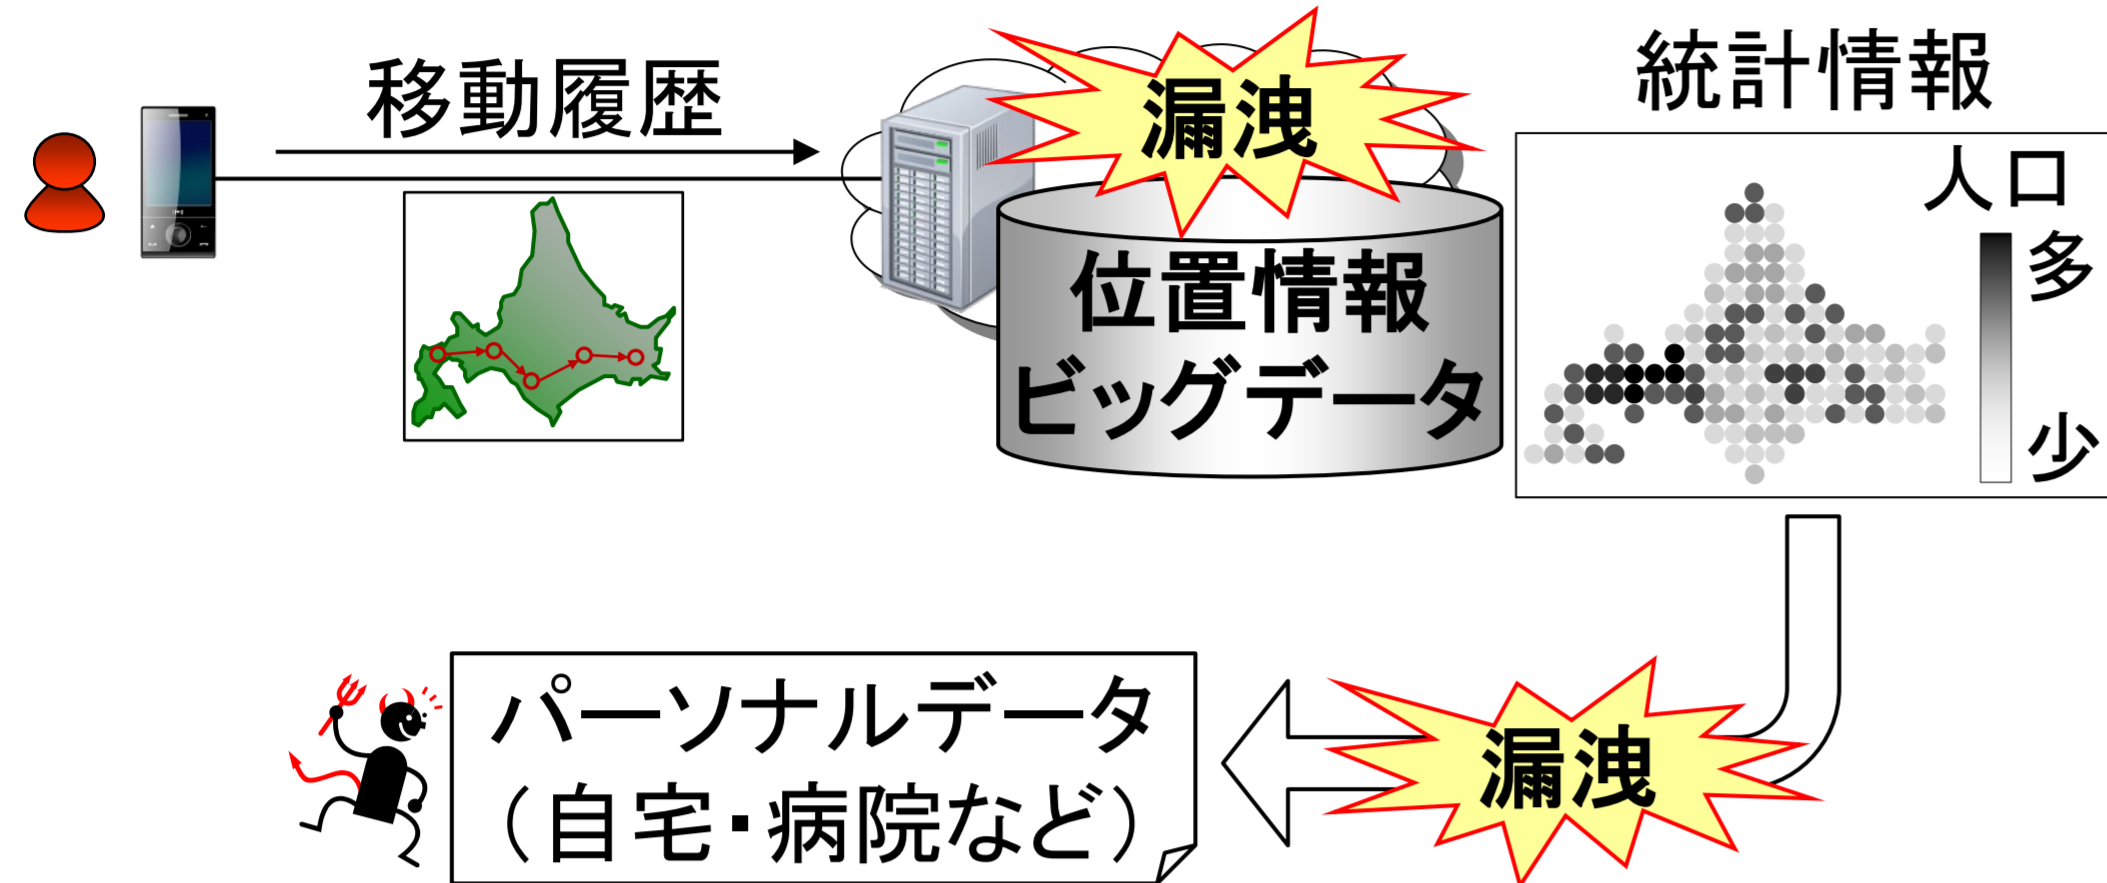


差分プライバシーと統計解析への応用

村上 隆夫 学際統計数理研究系 准教授


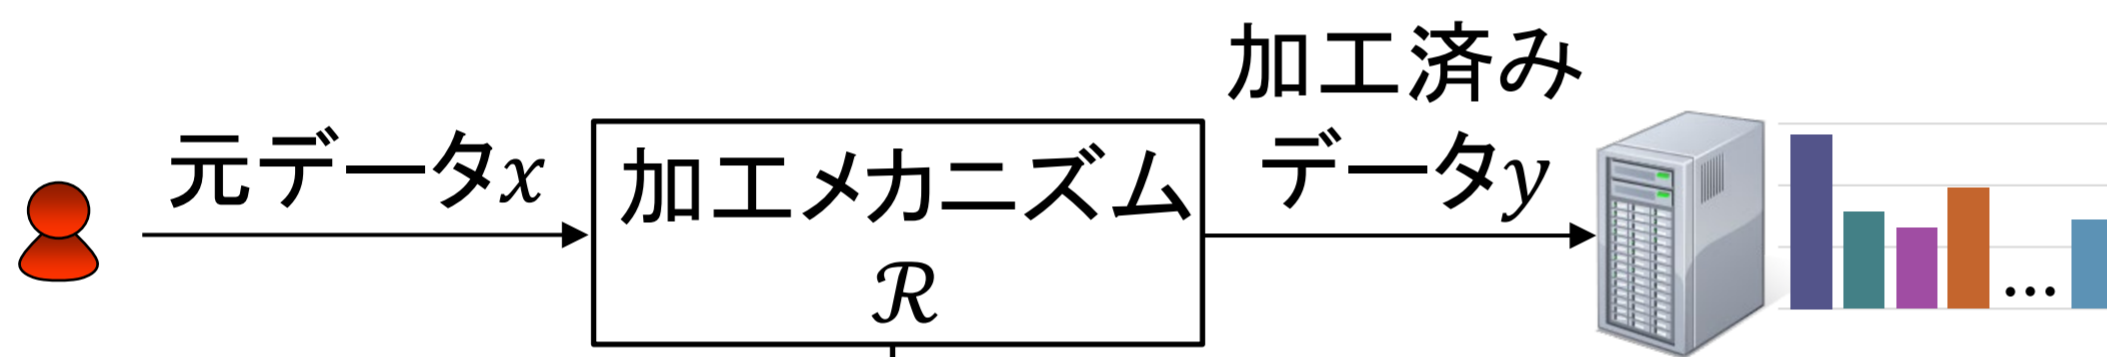
1. プライバシー問題

- IoTなどの普及に伴い、パーソナルデータの統計解析 (例: 人気スポットの分析) への期待が高まっている
- 一方、プライバシーの問題が懸念されている



2. 差分プライバシー

- プライバシー保護技術の安全性指標のデファクト標準
- 近年、ユーザが自分で加工を行う「局所型差分プライバシー」(LDP: Local Differential Privacy) が実用化
- 例: GoogleがChromeの起動ページをLDPで解析



定義(ε-LDP)

あらゆる元データ $x, x' \in \mathcal{X}$ (\mathcal{X} : 定義域) と加工済みデータ $y \in \mathcal{Y}$ (\mathcal{Y} : 値域) に対して

$$\Pr(y|x) \leq e^\epsilon \Pr(y|x')$$


が成立するとき、加工メカニズム \mathcal{R} は ϵ -LDP を満たす (ϵ : privacy budget)

直感的解釈

ϵ が小さいとき (例: 0~1)、 $\Pr(y|x)$ と $\Pr(y|x')$ が近い → 攻撃者が y を見ても、入力値が分からない (安全)

3. LDPの有用性改善[1]

- 新しい安全性指標: **ULDP (Utility-Optimized LDP)**
 - sensitiveな入力値に対しては、LDPと等価な安全性を保証 (安全性)
 - non-sensitiveな出力値からは対応する元データに戻せる (可逆性) → ノイズ量の削減




- GoogleがChromeに実装したLDPメカニズムの有用性 (分布推定精度) を大幅向上

4. LDPに基づくグラフ統計解析[2]


- グラフ統計 (部分グラフ数)

- 「友達の友達が友達である確率」 = $3 \times \frac{\text{\#triangles}}{\text{\#2-stars}}$ → 友達推薦の有効性が分かる
- 但し、秘密の友達情報 (edge) の漏洩は防ぎたい



- LDPに基づくグラフ統計解析

- k -stars に対しては1ラウンド、triangles に対しては2ラウンドのLDPメカニズムを提案



- k -stars は提案が最適、triangles は2ラウンドで MSE (平均二乗誤差) が大幅に減ることを証明

MSE (n : ユーザ数, d_{max} : 最大次数 ($\ll n$))

	1ラウンド		2ラウンド
	下限	上限	上限
k -stars	$\Omega(nd_{max}^{2k-2})$	$O(nd_{max}^{2k-2})$	-
triangles	$\Omega(nd_{max}^2)$	$O(n^4)$	$O(nd_{max}^3)$

[1] Takao Murakami, Yusuke Kawamoto, "Utility-Optimized Local Differential Privacy Mechanisms for Distribution Estimation," Proc. USENIX Security, 2019.

[2] Jacob Imola*, Takao Murakami*, Kamalika Chaudhuri (*: equal contribution), "Locally Differentially Private Analysis of Graph Statistics," Proc. USENIX Security, 2021.