

# Machine Learning meets Privacy Research

佐久間淳 筑波CS/JSTさきがけ

データ

発見・予測



# セキュリティとプライバシー

## (通信の)セキュリティ



# セキュリティとプライバシー

## (通信の)セキュリティ



## (データ)プライバシー



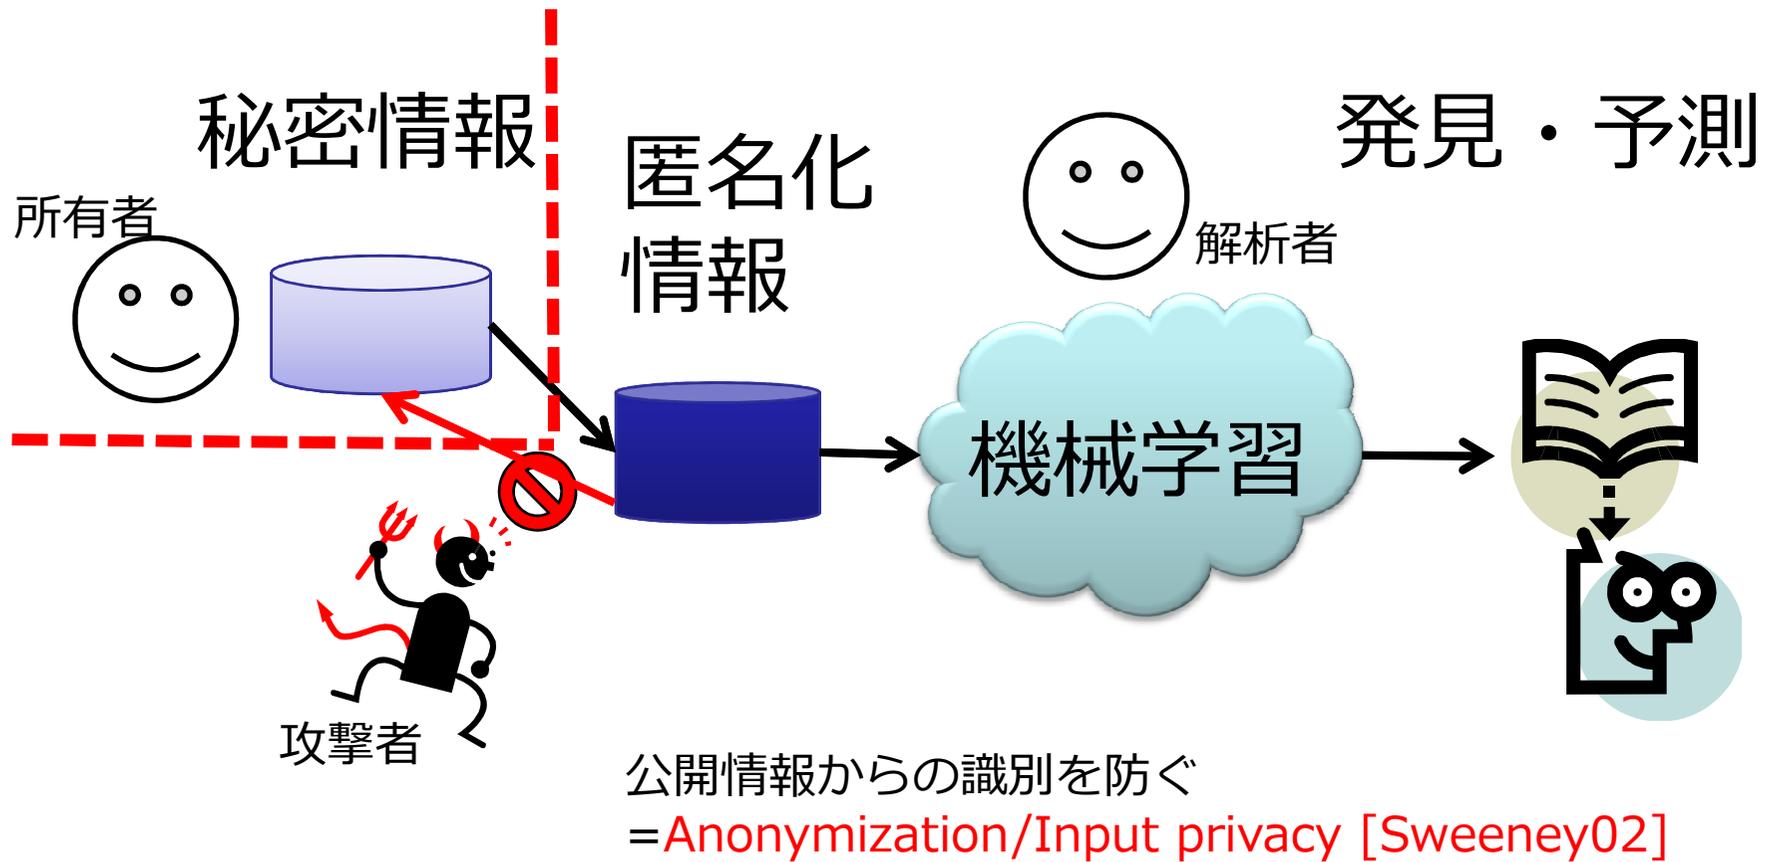
# 機械学習とセキュリティ・プライバシーの接点はどこに？

- 議論としては大きく三つに集約
  - Input privacy (or 匿名化)
  - Privacy-preserving data mining (or 秘密計算)
  - Output privacy (or 摂動, 差分プライバシーなど)
- クラウド利用(=outsourcing)を考慮すると少し事情は変わる
  - 詳細は[佐久間11]参照
  - 今回は立ち入らない

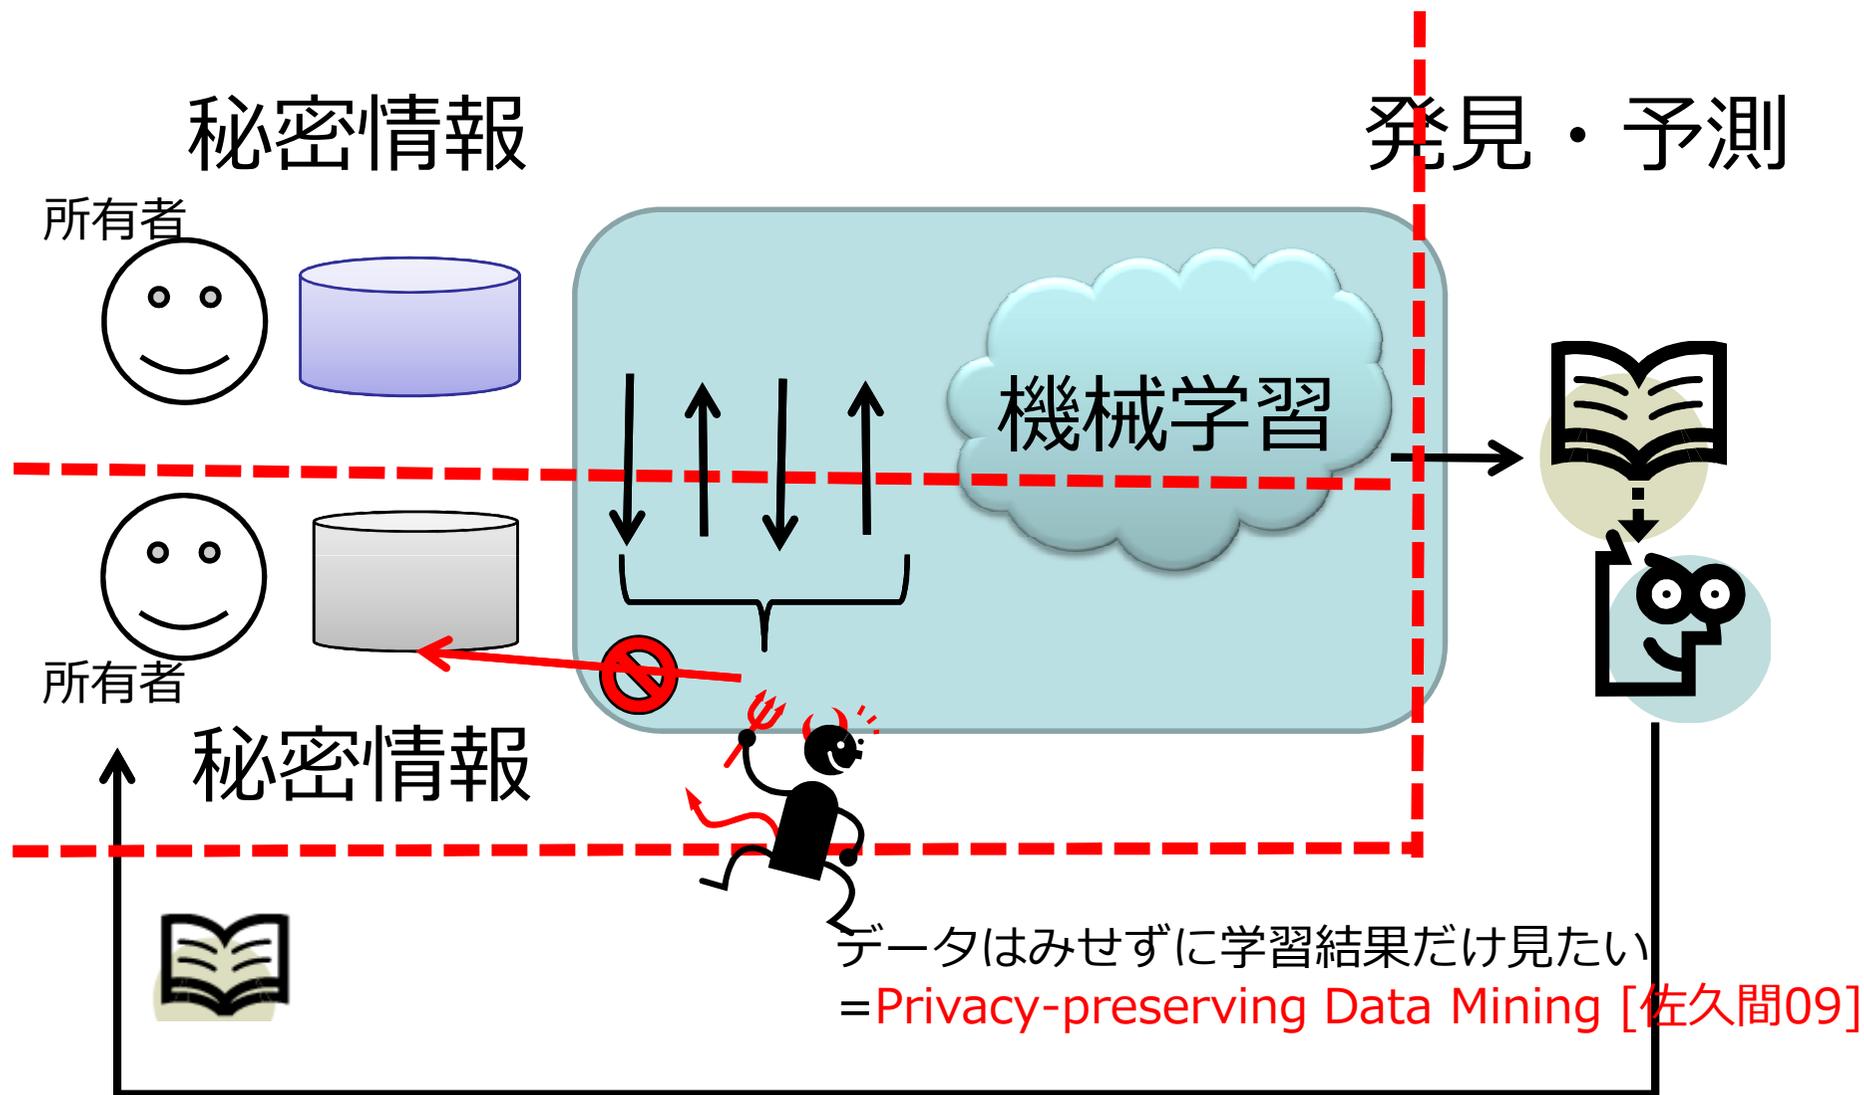
# Adenda

- Privacy researchの三つの方向性
- PPDM : 暗号理論アプローチにおけるいくつかのアルゴリズム
- Differential privacyとMLのかかわり
- MLの応用としてのプライバシー研究

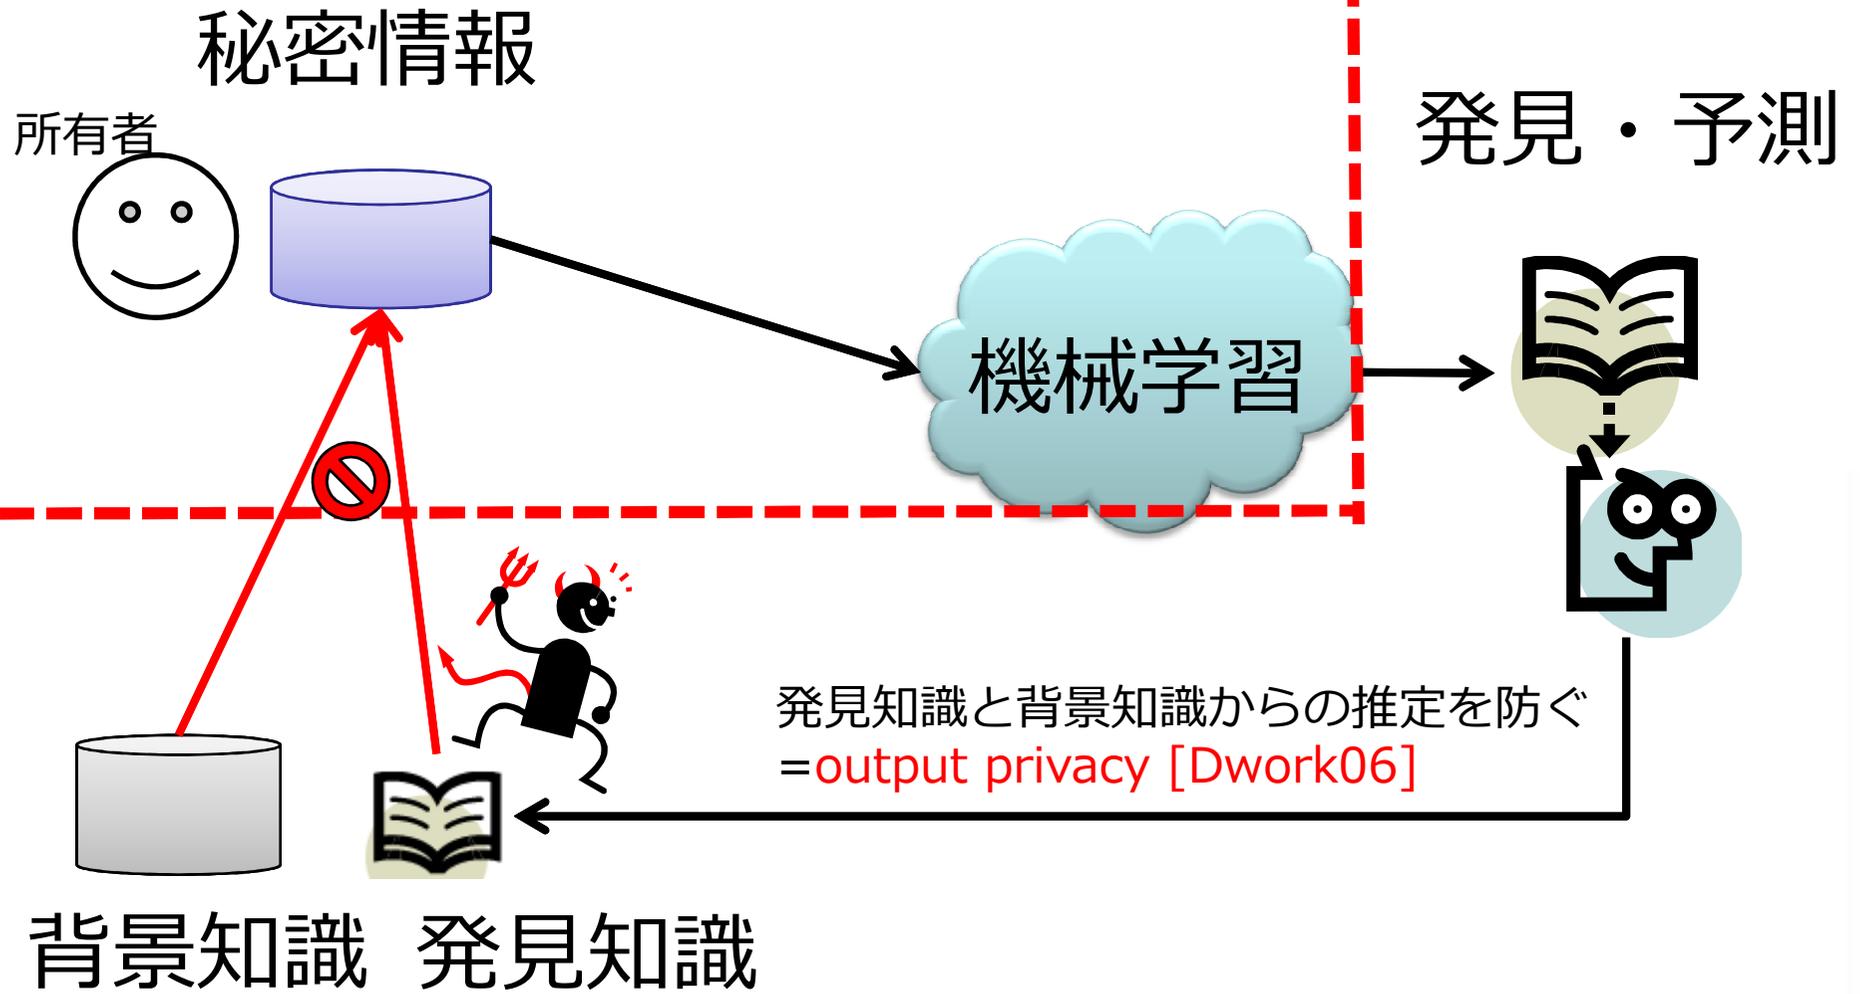
# Input Privacy



# Privacy preserving data mining

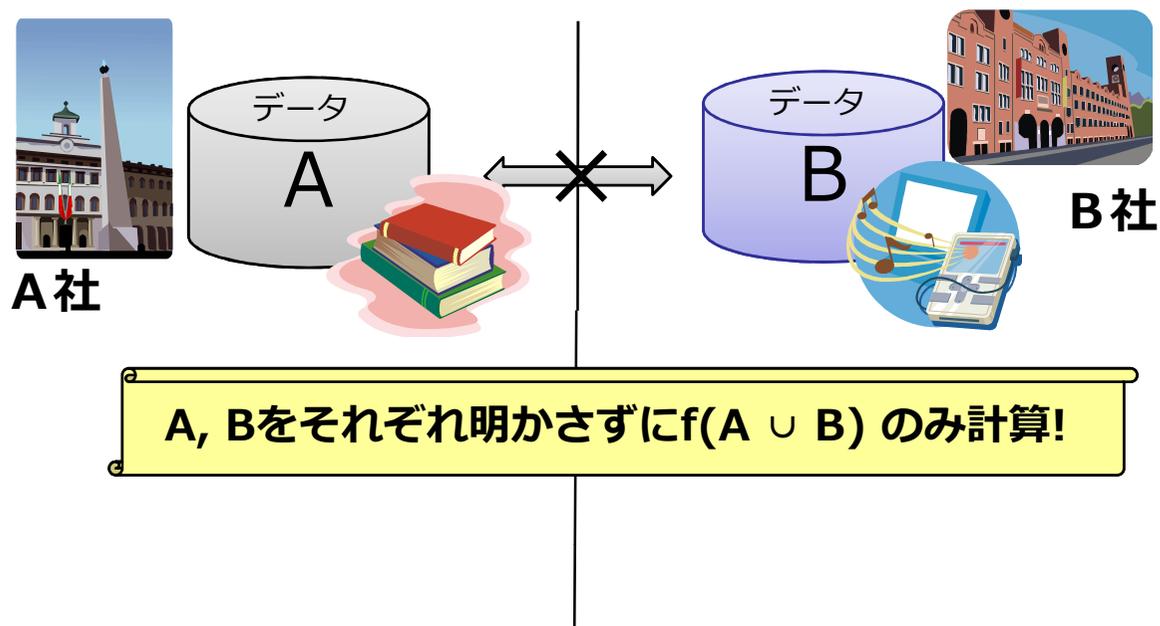


# Output privacy



# Privacy Preserving Data Mining

# Secure function evaluation



- 秘匿関数評価 (Secure function evaluation)
  - AはデータAをBに開示したくない
  - BもデータBをAに開示したくない
  - ただし結合されたデータ $A \cup B$ について $f(A \cup B)$ を知りたい
- $f$ がデータマイニングの場合, いわゆるPPDM

# 準同型性公開鍵暗号

- $m \in Z_N$  をメッセージ,  $r \in Z_N$  を乱数とする

- $(pk, sk)$ : 公開鍵と秘密鍵のペア

- 暗号化:  $c \leftarrow \text{Enc}_{pk}(m_0; r_0)$

- 復号化:  $m_0 \leftarrow \text{Dec}_{sk}(c)$

- $m_0, m_1, r_1, r_2 \in Z_N$

- 暗号系が(加法的)準同系性を持つとき:

- 暗号文の和

$$\text{Enc}_{pk}(m_0; r_0) \cdot \text{Enc}_{pk}(m_1; r_1) = \text{Enc}_{pk}(m_0 + m_1; r_1 \cdot r_2)$$

- 暗号文と平文の積

$$\text{Enc}_{pk}(m_0; r_0)^{m_1} = \text{Enc}_{pk}(m_0 m_1; r')$$

e.g. Paillier暗号 [Damgard01]

# Example: private computation of $ax+y$

**Alice has  $x$**

**Bob has  $y, a$**

Problem: compute random shares of  $ax+y = r^A+r^B \pmod N$

Key pair  $(p_k, s_k)$

Public key  $p_k$

$c \leftarrow \text{Enc}_{p_k}(x)$

$c$

Generate a random number  $r_B$

$c'$

$c' \leftarrow c^a \cdot \text{Enc}_{p_k}(y - r_B)$

$r_A \leftarrow \text{Dec}_{s_k}(c')$

$= \text{Enc}_{p_k}(x)^a \cdot \text{Enc}_{p_k}(y - r_B)$

$= ax + y - r_B$

$= \text{Enc}_{p_k}(ax + y - r_B)$

$$r_A + r_B = ax + y \pmod N$$

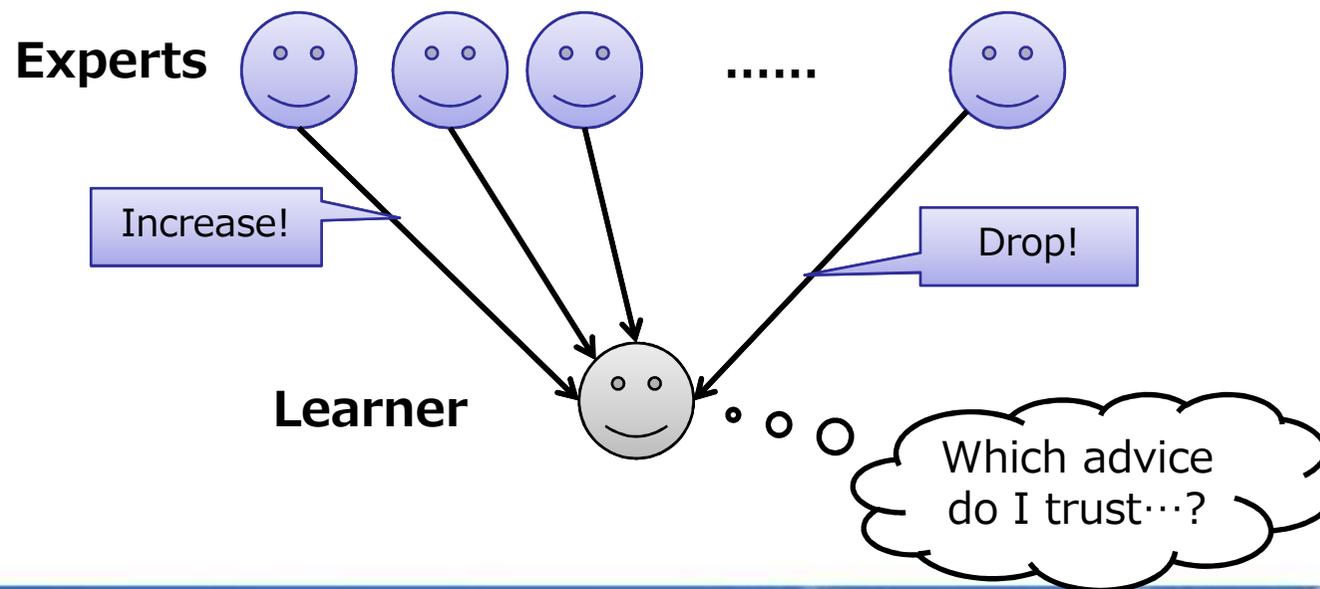
## 動向

- 準同型暗号を使って相当数のアルゴリズムが“privatize”された
- 最近はまだ準同型暗号上で何かのアルゴリズムを privatize するだけではよい会議に通らない
- 情報観測を制限するモデル自体がターゲットアルゴリズムの発展に新しい知見を与えるなど…
  - オンライン予測 [Sakuma and Arai, ICML2010]
  - PageRank[Sakuma and Kobayashi, SIGIR2009]
  - ラベル予測[Arai and Sakuma, ECML2011]
  - 結託耐性 [Yang et al., SIGKDD2010]

# オンライン予測: 株価予測を例に

□ For  $t=1, 2, \dots, T$ :

1. エキスパート: 忠告「株価は“騰がる ( $y_{i,t}=1$ )” or “下がる ( $y_{i,t}=0$ )”」を開示
2. 学習者: エキスパートの忠告を基に予測  $y_{H,t}$  を生成
3. 環境(マーケット): 株価  $y_t$  を開示
4. エキスパート: 自身の予測に対する損失  $l(y_t, y_{i,t})$  を受ける
5. 学習者: 自身の予測に対する損失  $l(y_t, y_{H,t})$  を受ける



# Regret minimization

## □ 評価基準 : regret

- 期間 $T$ において、「結果的に最も少ない損失を被ったエキスパート」に比べて、学習者はどの程度損失が多かったか

$$R_{H,T} = \underbrace{L_{H,T}}_{\text{学習者Hの損失和}} - \underbrace{\min_i L_{i,T}}_{\text{最も少ない損失和を被ったエキスパートの損失和}}$$

学習者Hの損失和      最も少ない損失和を被ったエキスパートの損失和

## □ 目標: $R_{H,T} < O(T)$

- $T \rightarrow \infty$  の極限において  $R_{H,T}$  は消失 (a.k.a. **Hannan consistency**)
- 期間が十分長ければ、最良のエキスパートと同等程度の損失ですむ
- この目標を達成するために、学習者はどのような戦略をとればよいか？

# Exponential Weighting Scheme

## □ 戦略

- よい予測をしているエキスパートは選ばれやすいように
- 悪い予測をしているエキスパートは選ばれにくいように

### 1. 各エキスパートについて重み $w_{it}$ を毎ステップ更新

$$w_{i,t} = \exp\left(-\eta \underbrace{\sum_{s=1}^{t-1} \ell(y_{i,s}, y_s)}_{i\text{番目のエキスパートの累積損失}}\right)$$

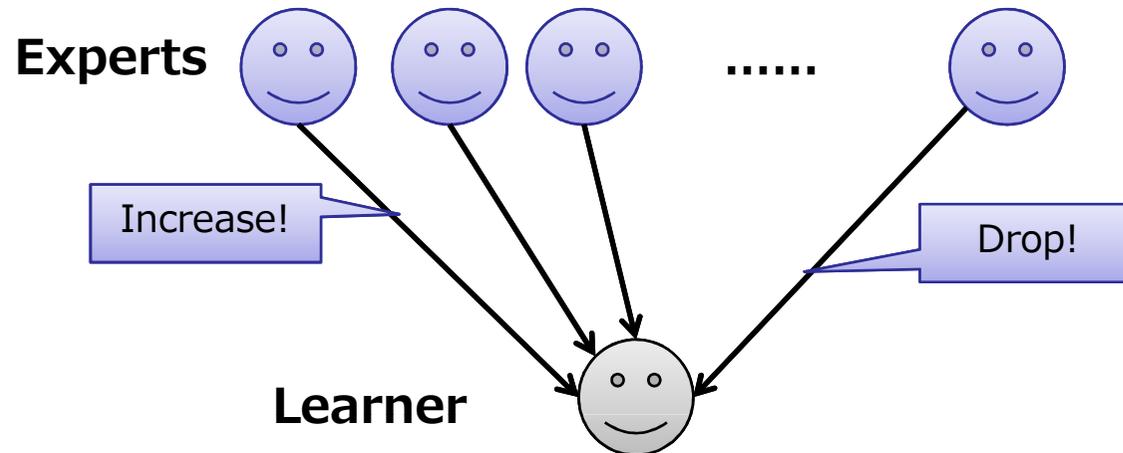
### 2. 重み $w_{it}$ を正規化

$$p_{i,t} = \frac{w_{i,t}}{\sum_{j=1}^N w_{j,t}}$$

### 3. $p_{it}$ による予測の決定

1.  $p_{it}$ に比例する確率でエキスパートを一つ選択 ( $j$ とする)
2.  $y_{jt}$ を時刻 $t$ の学習者の予測とする

# 完全情報モデル



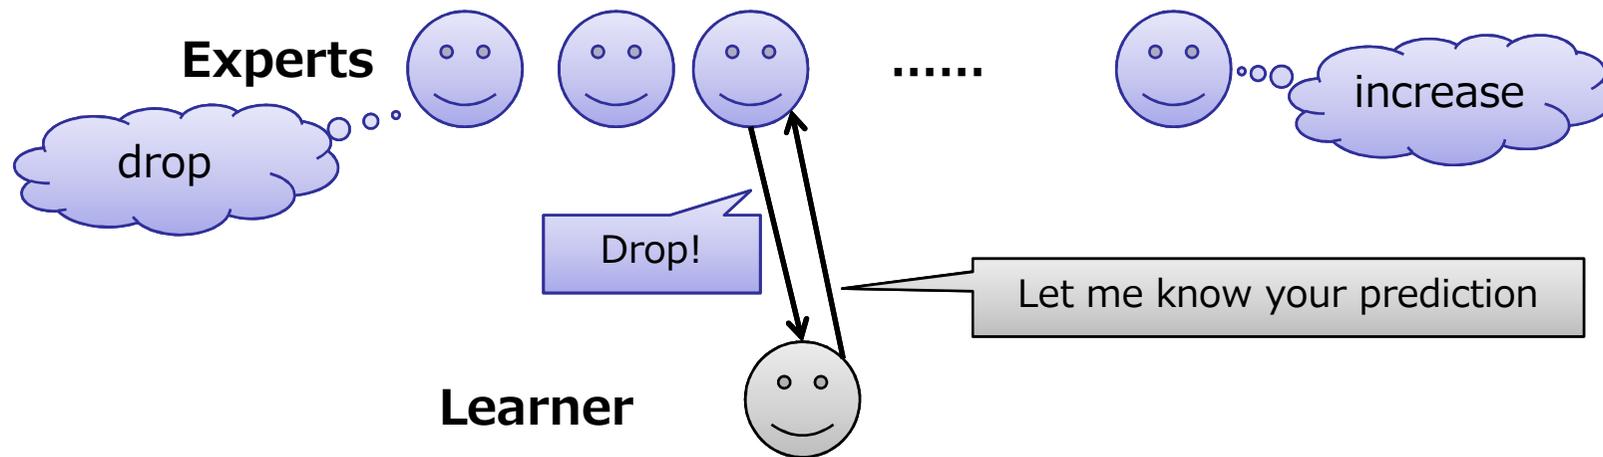
## □ 完全情報モデル (eg. Exponential weighting)

- 学習者はすべてのエキスパートの忠告と損失を観測可能
- Exponential weighting LearnerのRegret bound[Vovk90]

$$R_{EW,T} \leq \sqrt{2T \ln N} \quad \text{Hannan consistent!}$$

T: ラウンド数、N: エキスパート数

# 部分情報モデル



## □ 部分情報モデル (eg. Exp3 [Auer et. al. 2003])

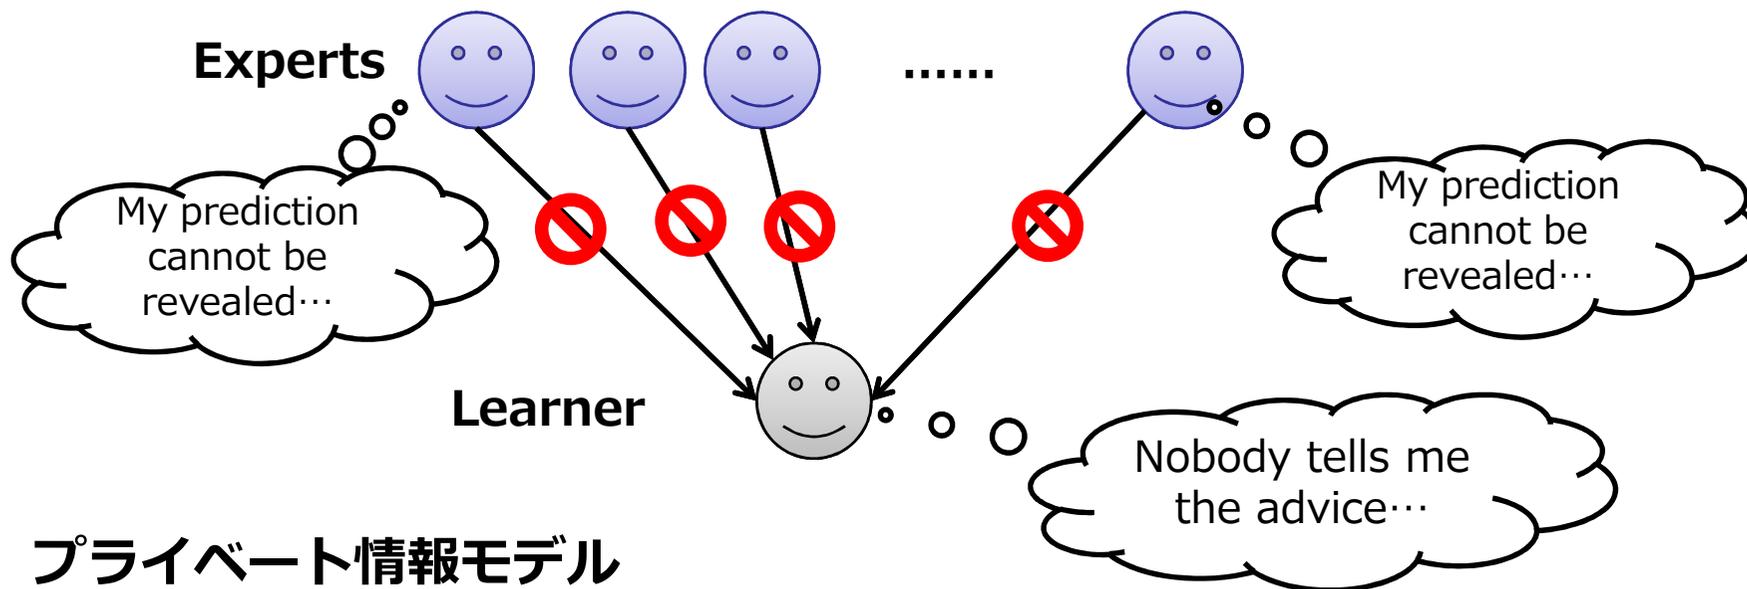
- あらかじめ決めたエキスパートからのみ忠告と損失を観測
- Exp3 learnerのRegret bound

**Hannan consistent!**

$$R_{\text{Exp3}, T} \leq 2\sqrt{e-1}\sqrt{NT \ln N}$$

- エキスパートからの秘密の忠告を扱うにはまだ不足
- 実現したいシナリオはもっと制限の厳しい情報モデル

# プライベート情報モデル

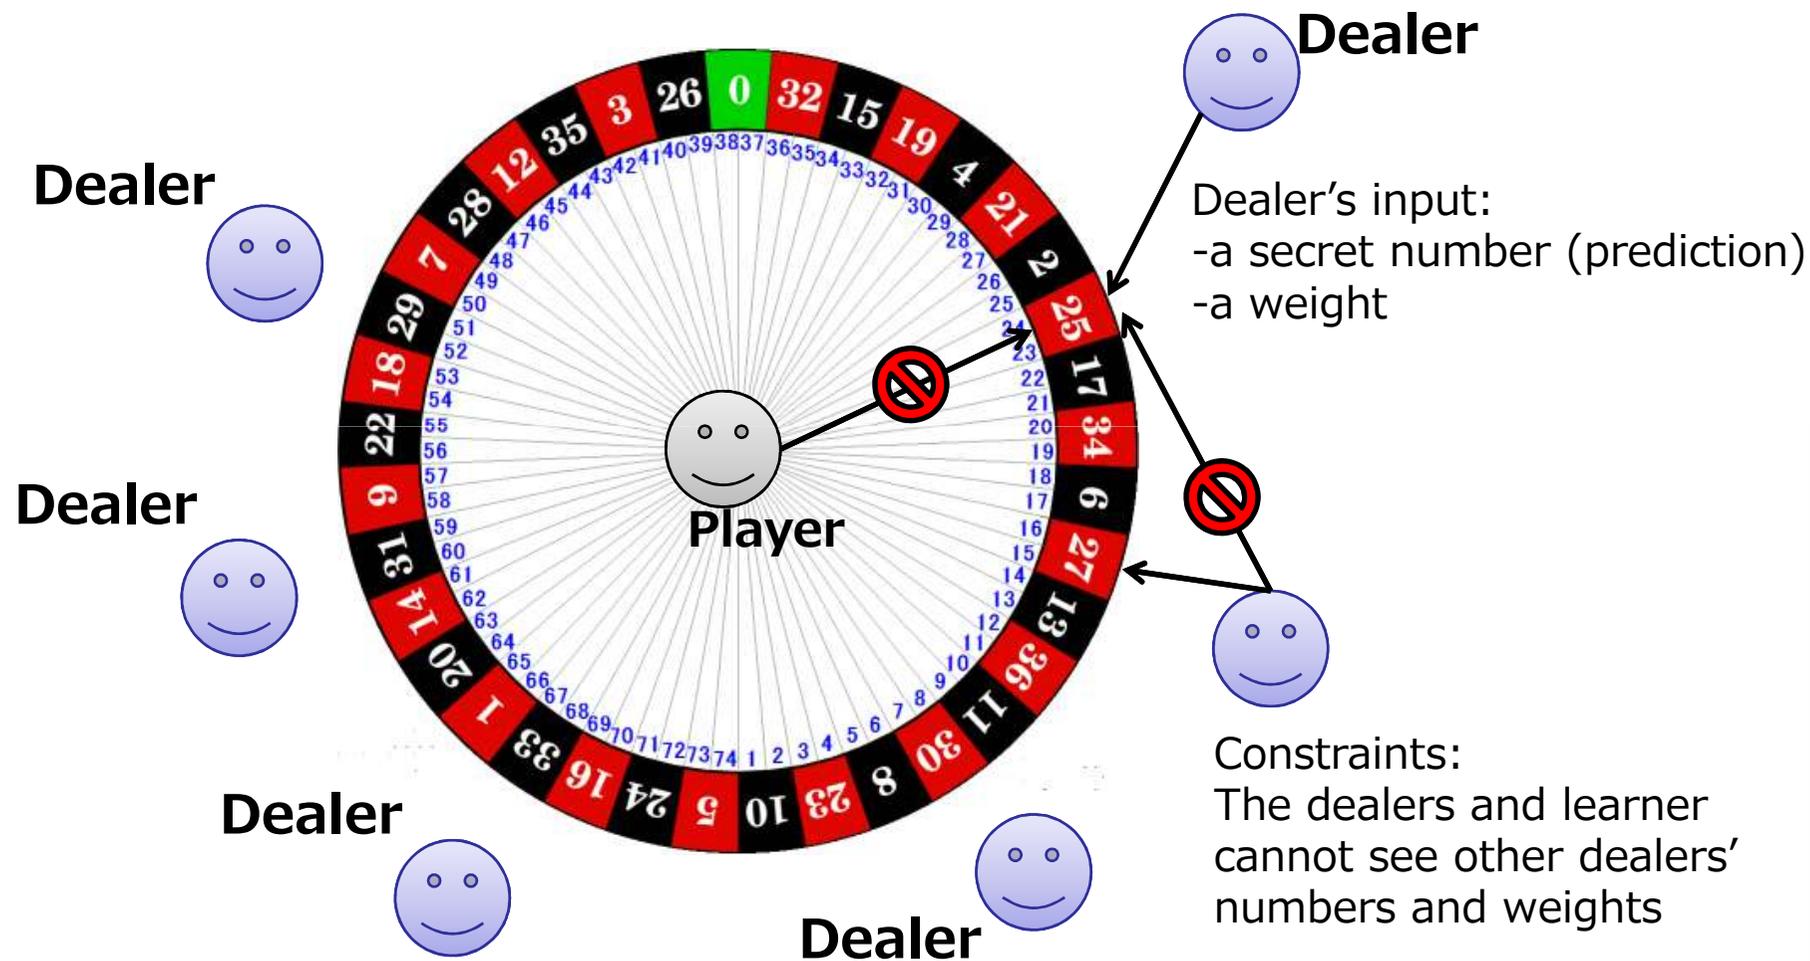


## □ プライベート情報モデル

- エキスパートも学習者も互いに予測と損失を一切開示したくない
- Hannnan consistentなオンライン予測はほとんど不可能に見えるが？

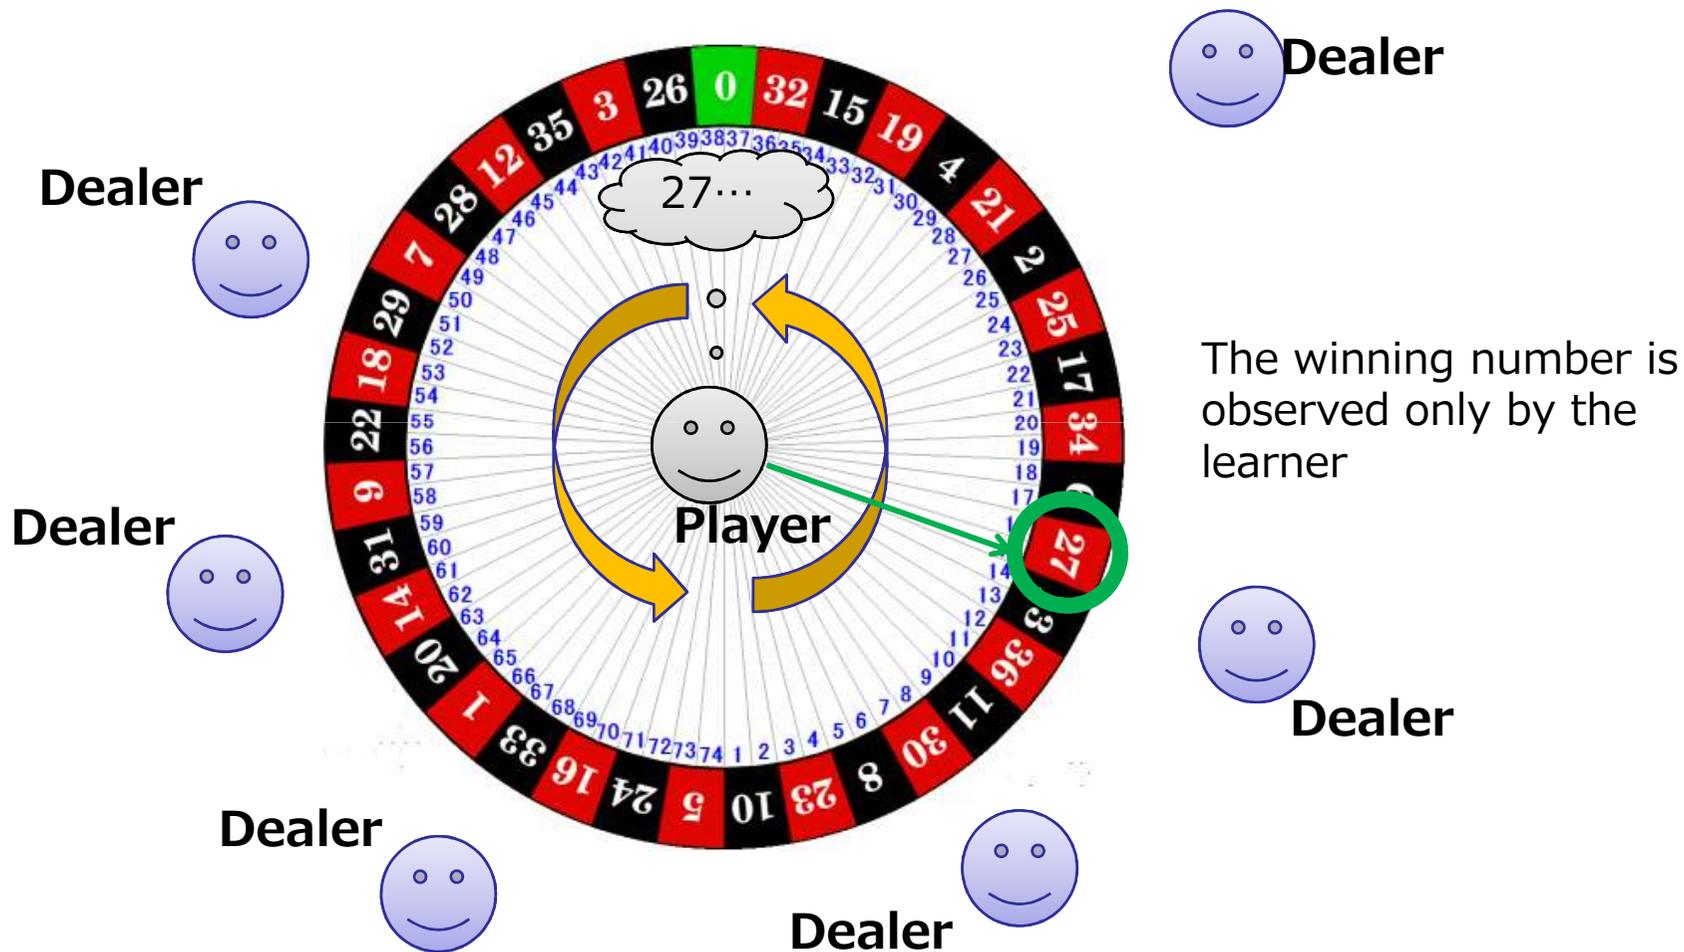
# Oblivious Roulette

- Playing roulette game without seeing the roulette wheel



# Oblivious Roulette

- Playing roulette game without seeing the roulette wheel



# プロトコルの性質

## □ プロトコルの肝

$$c_{i,k} \leftarrow \left( \text{Enc}_{pk}(a_{i,k}) \cdot \text{Enc}_{pk}(-j_k) \right)^{r_{i,k}} \cdot \text{Enc}_{pk}(y_i)$$
$$= \text{Enc}_{pk} \left( \underbrace{(a_{i,k} - j_k)r_{i,k}}_{\text{エキスパートの指名}j_k\text{と学習者の指名が一致すれば0、そうでなければランダムな値をとる}} + \underbrace{y_i}_{\text{エキスパート}i\text{の予測}} \pmod N \right)$$

エキスパートの指名 $j_k$ と学習者の指名が一致すれば0、そうでなければランダムな値をとる

エキスパート $i$ の予測

## □ Oblivious roulette protocol

- エキスパート $i$ の予測が学習者に届く確率は $p_i$
- それ以外ときは乱数のみが届くため、エキスパートは互いの予測や重みを他人に見られない
- 同様に学習者はだれから予測をもらったか、どんな予測を採用したかエキスパートに知られない
- これをつかうとexponential weightingをプライベート情報モデルで実行できる

## この研究の成果

情報モデル	観測可能な情報	Regret bound
完全情報モデル	全エキスパートの損失, 予測	$R_{EW,T} \leq \sqrt{2T \ln N}$
部分情報モデル	指名したエキスパートの損失, 予測	$R_{Exp3,T} \leq 2\sqrt{e-1}\sqrt{NT \ln N}$
プライベート情報モデル	他エキスパートの損失, 予測は観測できない	$R_{EW,T} \leq \sqrt{2T \ln N}$

- プライベート情報モデルにおいても…
  - Hannan consistencyを達成できました
  - しかもregret boundは完全情報モデルと同じオーダーです
- 結論：情報を他のエキスパートと共有しなくとも、学習者は完全情報モデルにおけるexponential weightingと同等の予測ができます

# プライバシー保護半教師つき学習(ECML2011, /w H. Arai)

## □ 伝染病予測のプライバシー

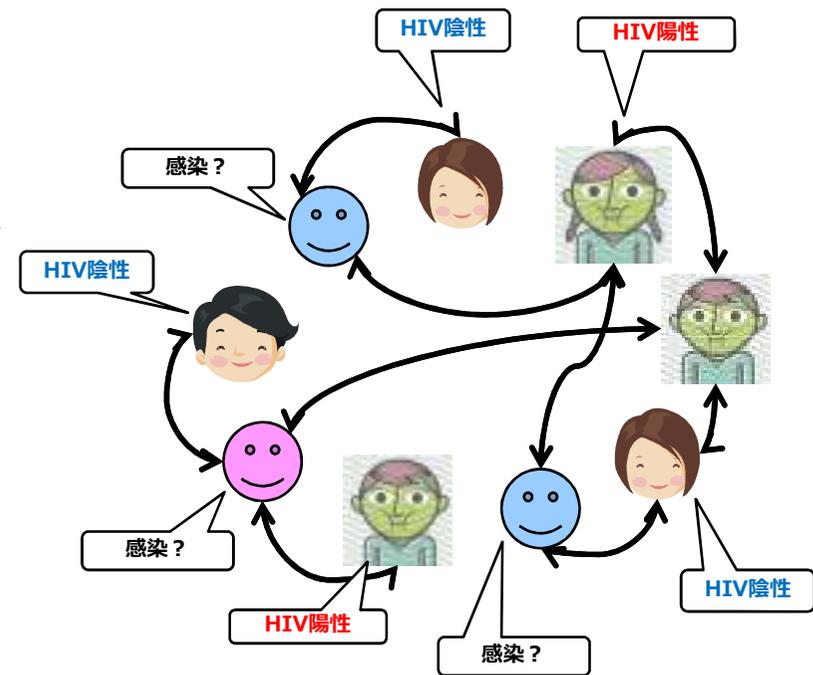
- HIVに感染しているか知りたい, でも検査にいきたくない
- AさんはHIVに感染しているかどうか教えてくれない
- BさんとCさんは過去に性交渉をもったことがあるか教えてくれない

## □ 秘密の入力

- ラベル: AさんはHIV陽性か?
- リンク: BさんとCさんは過去に性交渉をもったか?

## □ 出力

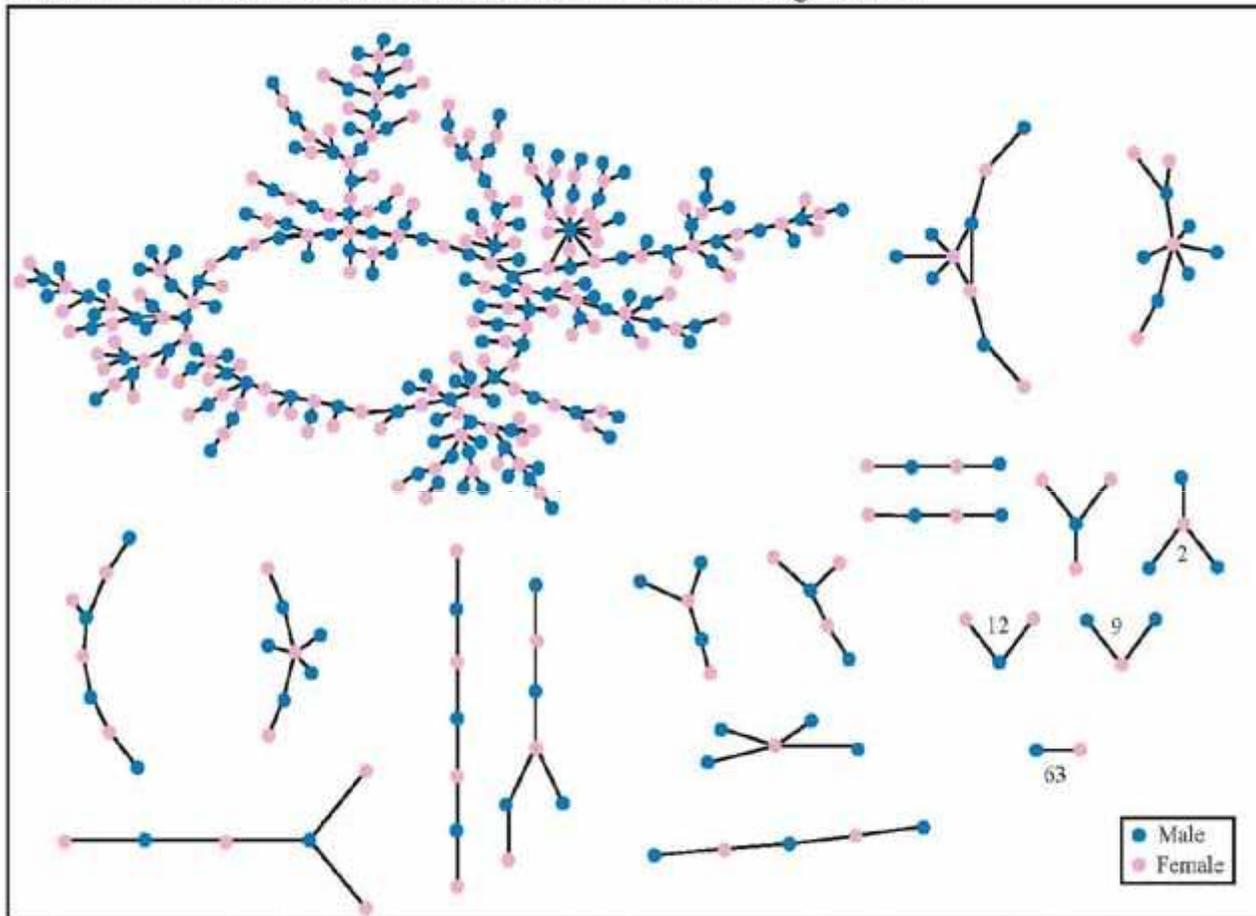
- 私はHIV陽性の可能性があるか?



性的交渉ネットワーク

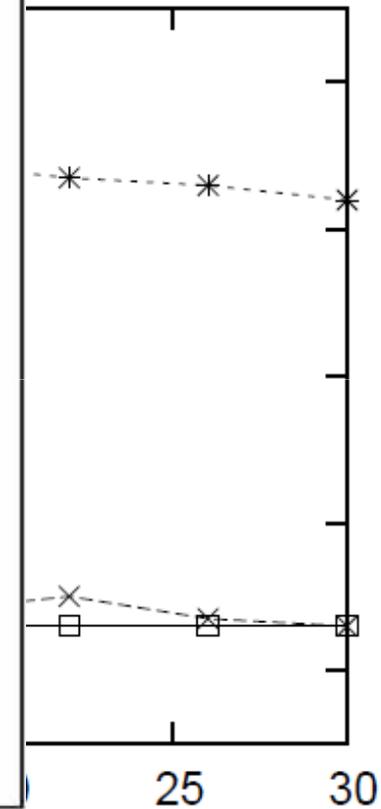
# プライバシー保護半教師つき学習( ECML2011, /w H. Arai)

The Structure of Romantic and Sexual Relations at "Jefferson High School"



Each circle represents a student and lines connecting students represent romantic relations occurring within the 6 months preceding the interview. Numbers under the figure count the number of times that pattern was observed (i.e. we found 63 pairs unconnected to anyone else).

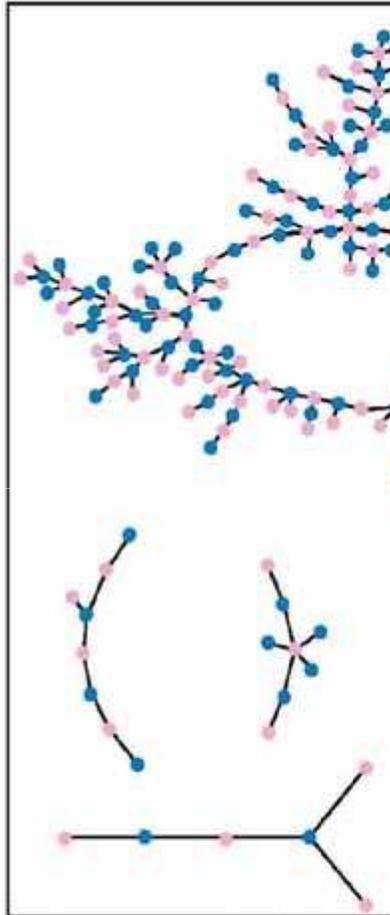
dataset



ages

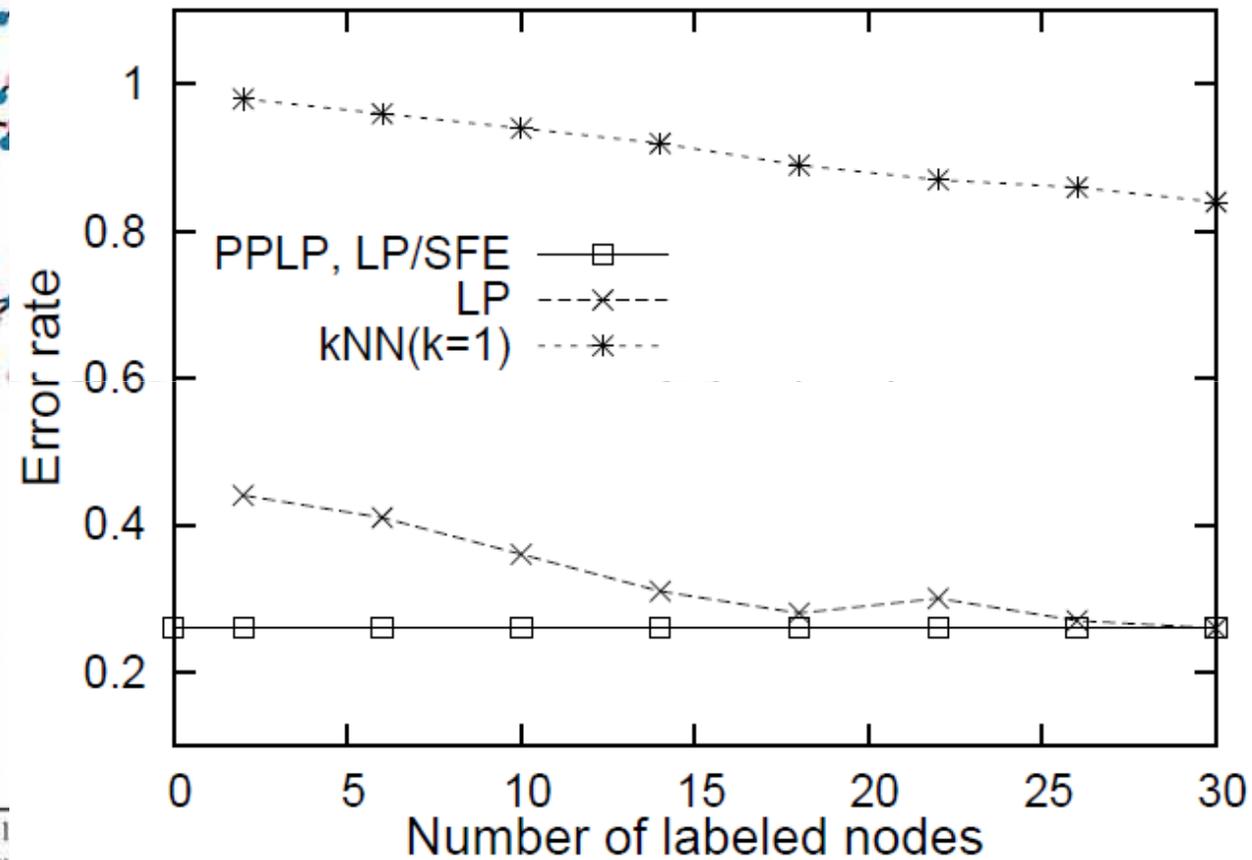
# プライバシー保護半教師つき学習( ECML2011, /w H. Arai)

The Structure of Romantic and Sexual Relations at "Jefferson High School"



Each circle represents a student and 1 preceding the interview. Numbers in pairs unconnected to anyone else).

(a) Error rate in ROMN dataset

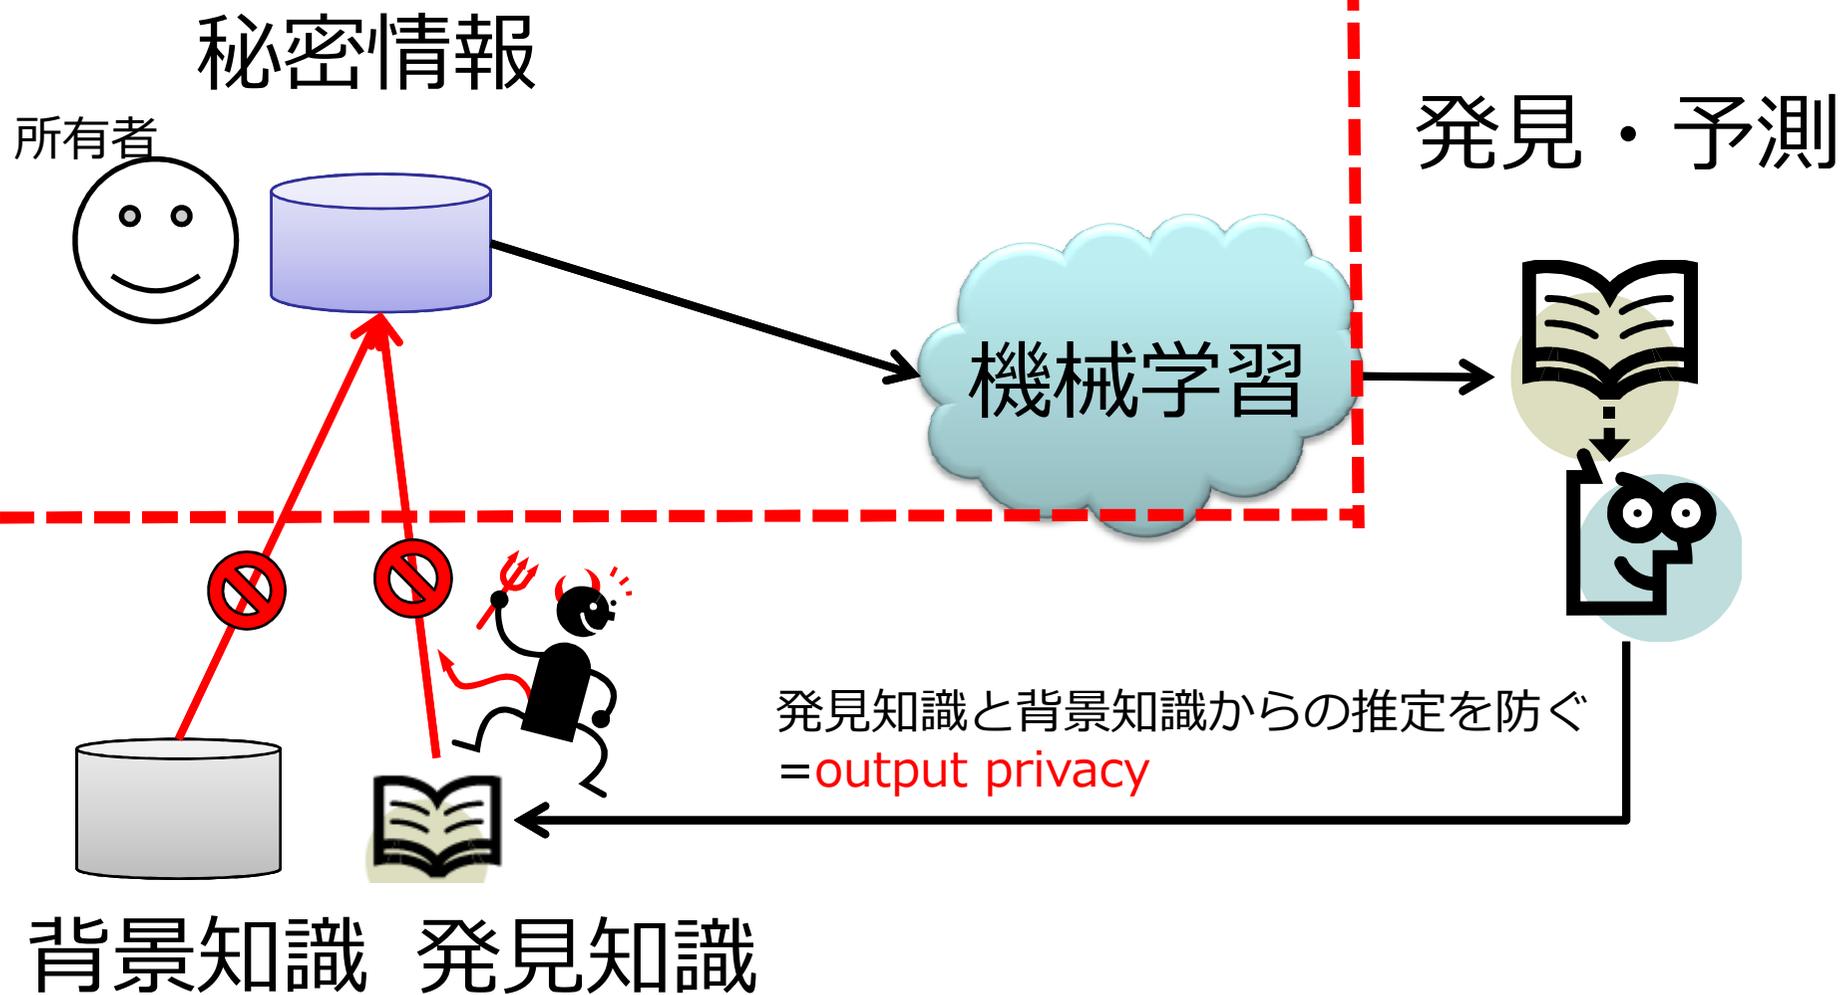


## 今後の展開

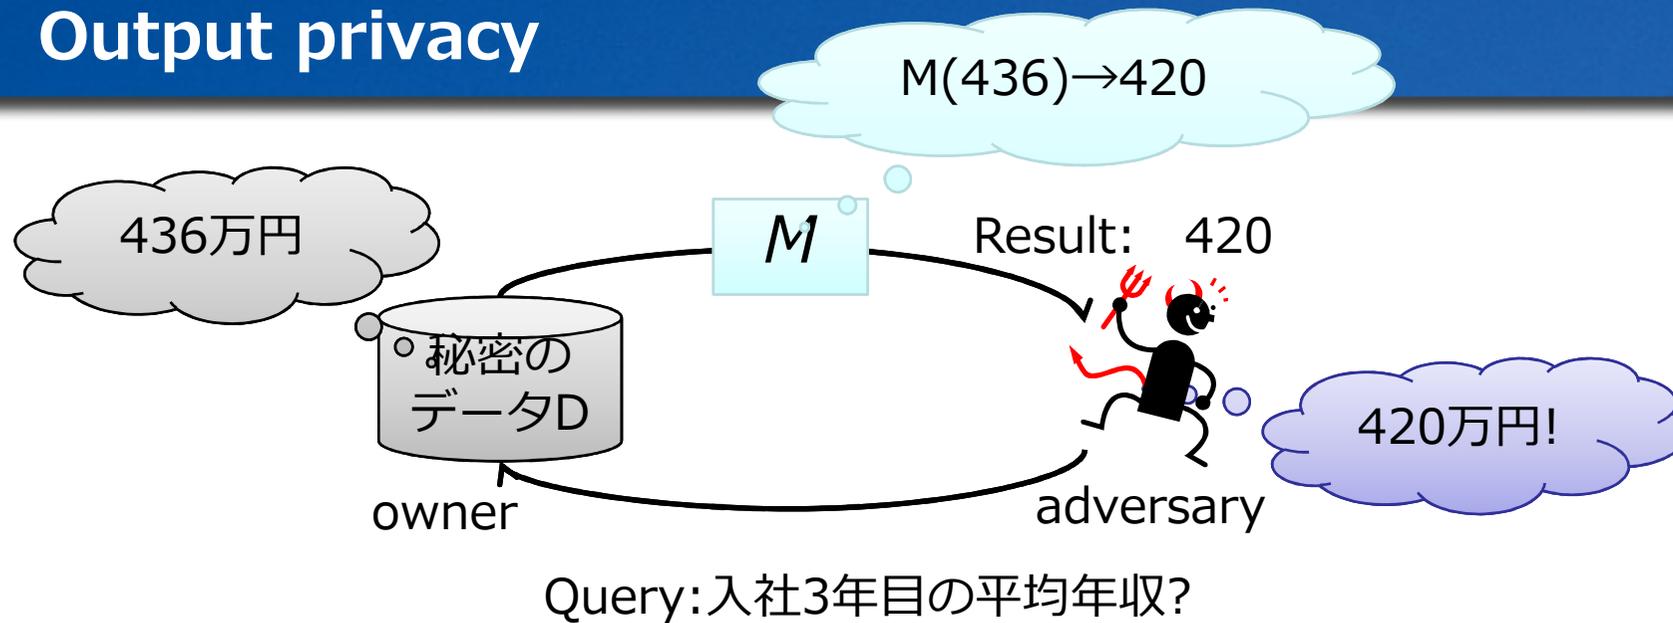
- **利害関係のある複数の主体が出てくるアルゴリズムならなんでも**
  - リンク予測
  - 安定結婚
  - 動的計画法
  - クラウドソーシング
  - 予測市場
  - オンライン学習,ゲーム(均衡解探索)
  - 詳しい方いっしょにやりませんか？
- **実際にうごかすプラットフォームが必要**
  - Androidで実装計画中

# 出カプライバシー

# Output privacy

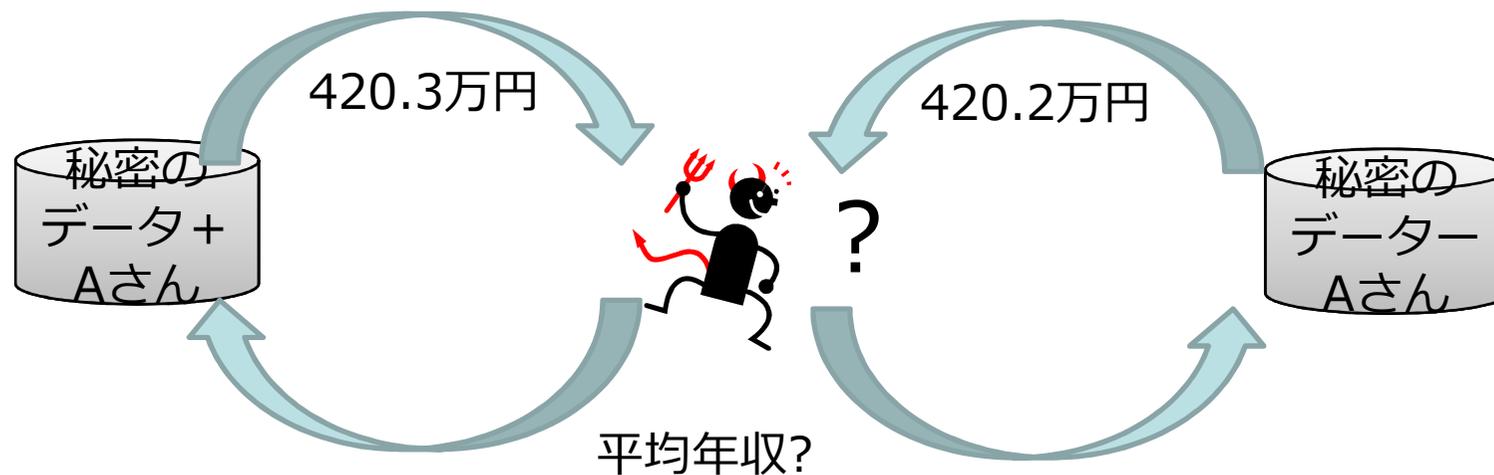


# Output privacy



- 攻撃者はクエリを発行
- オーナーは $f(D)$ を計算
- $D$ の秘密を守るために $f(D)$ に細工 $M$ をしてから開示
- 攻撃者は $M(f(D))$ から $D$ を推測
- 問題：どんな $M$ なら安全なのか？

# Output privacyにおける Semantic security



Aさんin

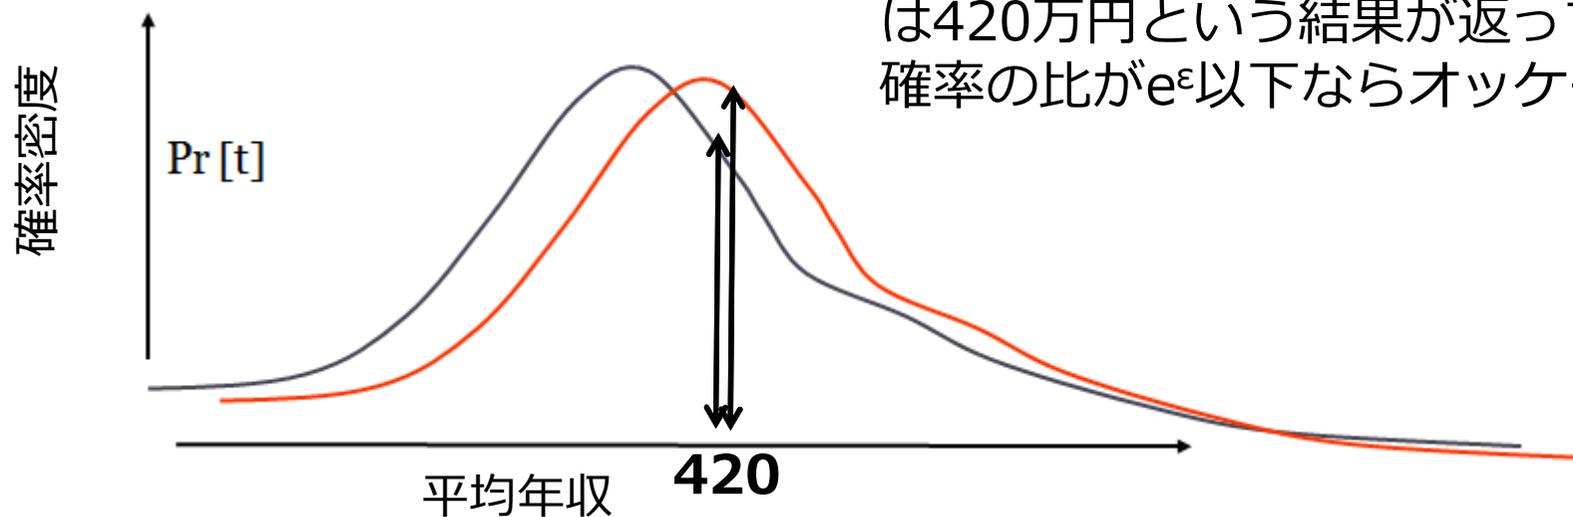
Aさん  
not in

- $f(D+A)$ と $f(D)$ がそんなに変わらなければ、 $f(D+A)$ の開示はAさんのプライバシーを侵害していない(ことにしよう!)

# Differential Privacy[Dwork06]

- そんなに変わらないとは…?
- Differential Privacy[Dwork06]

$$\frac{\Pr[\mathcal{K}(\text{DB} - \text{You}) \in S]}{\Pr[\mathcal{K}(\text{DB} + \text{You}) \in S]} \leq e^\epsilon$$



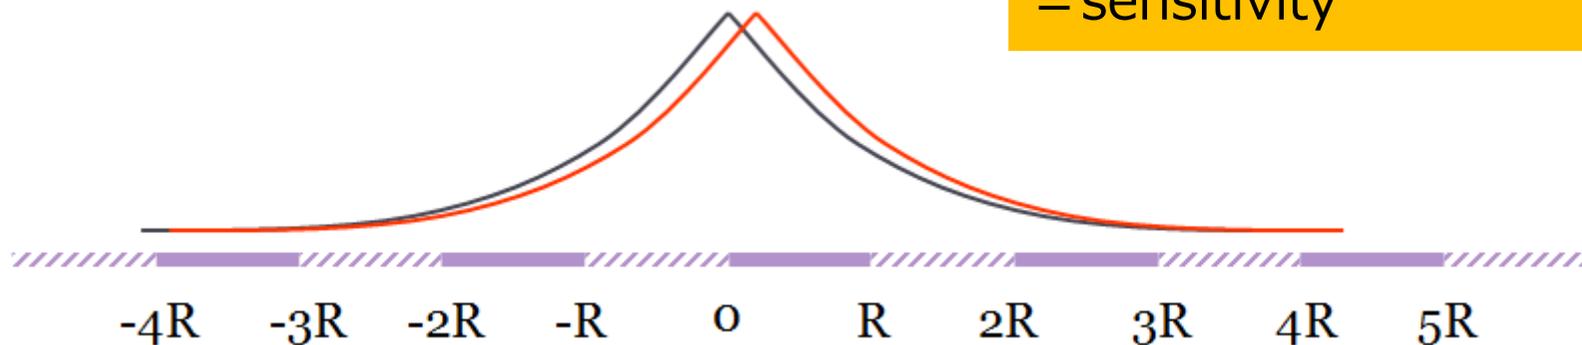
Aさんがいるとしないかで、平均年収は420万円という結果が返ってくる確率の比が $e^\epsilon$ 以下ならオッケー

# どうやってDPを実現するか? Laplaceメカニズム

- $f(\text{DB})$ に加法的ノイズを加えて開示
- 定理：  $R = \Delta f / \epsilon$ としたときに  $\text{Lap}(|x|/R)$ に従うノイズ  $r$ を加えれば  $\epsilon$ -differential privacy
- $\Delta f$  :  $f$ のデータの変化に対する感度

$$\text{Lap}(x; R) = \frac{1}{2R} e^{-\frac{|x|}{R}}$$

Aさんがいるといないとで結果がどれくらい変わるか、で決まる定数 = sensitivity



# Sensitivity

- ある人がいるかいないかで、計算結果は最大でどれだけかわるか？

$$\Delta f = \max_{DB, You} |f(DB+You) - f(DB-You)|$$

- 例

- Countクエリ :  $\Delta f=1$
- 平均クエリ :  $\Delta f=S/N$ , S:値のレンジ、N:人数
- maxクエリ :  $\Delta f=S$ , S:値のレンジ

# 複雑さの抑制とプライバシー保護

## □ 機械学習

- ロス最小化したい
- 学習結果の複雑さを抑制したい：正則化, 低ランク近似, etc

## □ プライバシ保護

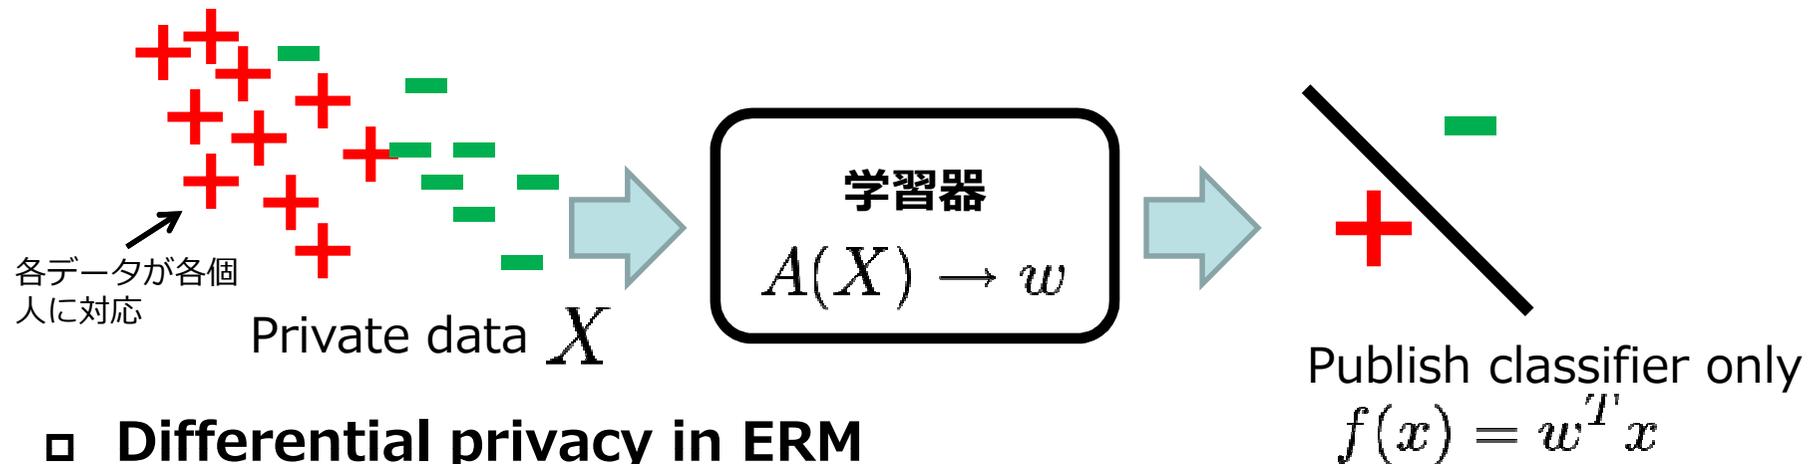
- 出力の秘密情報への適合を抑制したい：匿名化, 差分プライバシー
- データが持っている効用最大化したい

## □ 両者は結構似ている？

- 「複雑さの抑制」と「出力の秘密情報への適合の抑制」は同時に達成できるのでは？
- 機械学習のテクニック(e.g.正則化, 低ランク近似)がプライバシー保護ツールとして有用なのは？

# Differentially private ERM minimization [Chaudhuri11]@JMLR

## Private dataからの分類器学習



## Differential privacy in ERM

- 分類器  $w : f(x) = w^T x$
- あるデータがあろうとなかろうと,  $w$  が学習される確率はあまり変わらない

$$\frac{\Pr[A(X) = w]}{\Pr[A(X') = w]} \leq \exp \epsilon$$

# Differentially private ERM minimization [Chaudhuri11]@JMLR

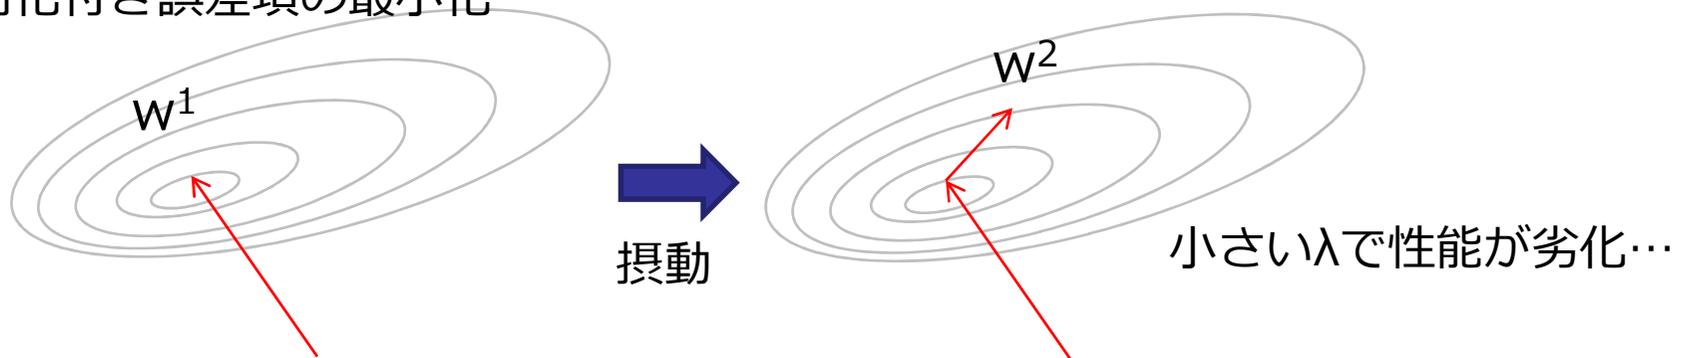
- データ  $D = \{(x_1, y_1), \dots, (x_N, y_N)\}$ ,  $\|x_i\| < 1$ ,  $y_i \in \{-1, 1\}$
- $w^1$ :  $D$  から logistic regression によって求めた分類器

$$\hat{L}(w) = \frac{1}{n} \sum_{i=1}^n \log(1 + e^{-y_i w^T x_i})$$

$$\hat{f}_\lambda(w) = \frac{1}{2} \lambda \|w\|^2 + \hat{L}(w)$$

- $w^1$  の代わりに、differential private な分類器  $w^2$  を開示したい
  - $\Delta f = n\lambda/2$ ,  $R = \Delta f/\epsilon$ ,  $r \sim \text{Lap}(w; R)$  として  $w^2 = w^1 + r$  を開示

正則化付き誤差項の最小化



# Differentially private ERM minimization [Chaudhuri11]@JMLR

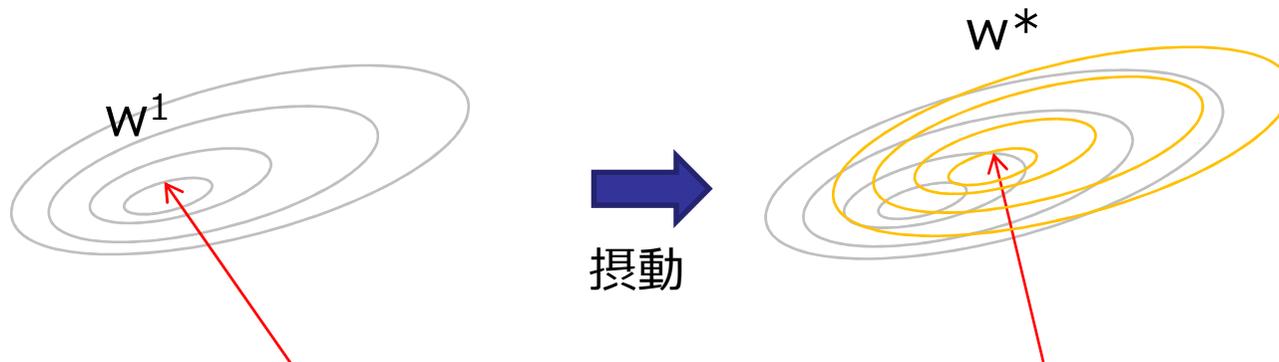
- アイディア: ノイズを加えた目的関数を最適化
- ベクター  $b \sim h(b) \propto e^{-\frac{\epsilon}{2}\|b\|}$
- 以下の問題を解く

$$w^* = \operatorname{argmin}_w \frac{1}{2} \lambda w^T w + \frac{b^T w}{n} + \frac{1}{n} \sum_{i=1}^n \log(1 + e^{-y_i w^T x_i}).$$

$$\text{Cf. } \hat{f}_\lambda(w) = \frac{1}{2} \lambda \|w\|^2 + \frac{1}{n} \sum_{i=1}^n \log(1 + e^{-y_i w^T x_i})$$

- Theorem2.

$w^*$  は  $\epsilon$ -differentially private



# Differentially private ERM minimization

## [Chaudhuri11]@JMLR

- **本質的な解釈**
  - ノイズをのせる→解をぼやけさせる
  - 正則化項を加える→解をなまらせる
  - どうせ似たような事を行っているのならまとめてやって精度の高いものを
- **ERMにおいて $\epsilon$ -differential privacyを与える問題が簡単に定義できるといのはなかなか強い結果**

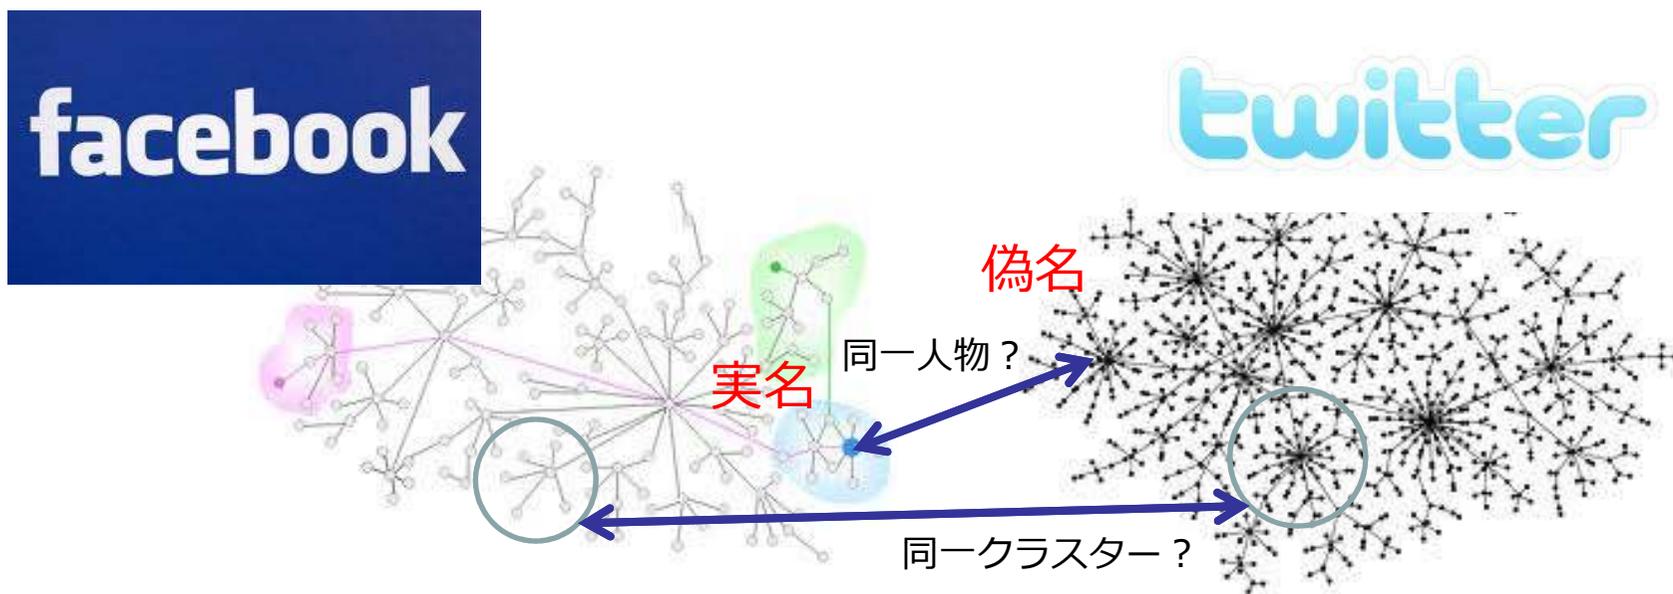
# MLのprivacy researchへの 応用可能性

# Adversaryとadministratorの攻防

	被害	攻撃ツール	防御ツール
暗号	盗聴	数論	数論
ウイルス /malware	感染	システム脆弱性解析	保護ソフトウェア
ネットワーク セキュリティ	侵入	ネットワーク脆弱性解析	保護ソフト/ハードウェア
SNS/web サービス	脱匿名化, 属性推定	クローリング & 機械学習?	機械学習?

- 侵入検知や異常検知, スпамフィルタが機械学習の重要なアプリケーションであったように…
- 脱匿名化や属性推定, anti-脱匿名化やanti-属性推定が機械学習の主要なアプリになるのでは?

# SNS脱匿名化とanti脱匿名化



- facebookでは顕名, twitterでは偽名
- Twitterには実名ノードも多数あり
- 周辺ノードのリンク情報はvisible
- 攻撃側の問題: あるfacebookアカウントに対応するtwitterアカウントを同定できるか?
- 防御側の問題: 自分のfacebookアカウントが同定されないためにはどのような属性やリンクを作ればよいか?

## 推薦のトランザクション推論とantiトランザクション推論

- **“You might also like:” Privacy Risks of Collaborative Filtering, IEEE S&P2010 [Calandrino2011]**
  - Webなどから推薦情報やセールスランキングなどのダイナミクスを収集し、それを目標ユーザの“外部情報”と結び付け、目標ユーザの未知のトランザクションを推論
- **解析例**：Ms. BrownはR&Bのアルバムにa1,a2,a3を含むレビューを書いている。アイテムtは古いR&Bのアルバムである。Day1では70,000位だったが、Day2には15,000位に上昇。Day2では、アイテムtはa1,a2の類似アイテムリストに出現し、a3の類似アイテムリスト内にて類似度が上昇した。これらからMs. Brownはアイテムtを購入したと推測できる。実際、1月以内にMs. Brownはアイテムtのレビューを書いた
- **非常に素朴な推論を使っている**
- **MLを使えばもっと高精度な同定が可能？**
- **トランザクション推論を妨げるにはどんな推薦が有効か？**

## おわりに

- MLとprivacy researchには多様なかわり方がある
- 理論：抽象化・単純化とプライバシー保護の根源的な同一性
- アルゴリズム：privatizationがあたらしい設定のMLを作る
- 応用：SNS/webサービスのanti-XXはpromisingなアプリ？

## 関連文献

- [佐久間11] 佐久間淳,高橋克巳,クラウドストレージにおける個人情報の利活用とプライバシー保護,情報処理, Vol.52 No.6, 2011
- [Sweeney02] Sweeney, L. : k-Anonymity : A Model for Protecting Privacy, World , Vol.10, No.5, pp.557-570 (2002) .
- [佐久間09] 佐久間淳, 小林重信 : プライバシー保護データマイニング, 人工知能学会誌, Vol.24, No.2, pp.283-294 (2009) .
- [Dwork06] Dwork, C., McSherry, F., Nissim, K. and Smith, A. : Calibrating Noise to Sensitivity in Private Data Analysis, Theory of Cryptography , pp.265-284 (2006) .
- [Damgard01] Damgard, I. and Jurik, M. A Generalisation, a Simplification and Some Applications of Paillier's Probabilistic Public-Key System. In Public Key Cryptography, pp. 119–136. Springer, 2001.
- [Sakuma10] Jun Sakuma, Hiromi Arai: Online Prediction with Privacy. ICML 2010: 935-942

- **[Sakuma09] Jun Sakuma, Shigenobu Kobayashi: Link analysis for private weighted graphs. SIGIR 2009: 235-242**
- **[Arai11] Hiromi Arai, Jun Sakuma: Privacy Preserving Semi-Supervised Learning for Labeled Graphs, ECML2011, to appear.**
- **[Yang10] Bin Yang, Hiroshi Nakagawa, Issei Sato, Jun Sakuma: Collusion-resistant privacy-preserving data mining. KDD 2010: 483-492**
- **[Chaudhuri11] Kamalika Chaudhuri, Claire Monteleoni, and Anand Sarwate. Differentially Private ERM , vol. 12, pp. 1069–1109, JMLR, 2011.**
- **[Calandrino2011] Joseph A. Calandrino, Ann Kilzer, Arvind Narayanan, Edward W. Felten, and Vitaly Shmatikov“You Might Also Like:”Privacy Risks of Collaborative Filtering, IEEE S&P 2011, to appear.**