

RANDOMIZED RESPONSEに 対するポイズニング攻撃の調査

総合数理学部 先端メディアサイエンス学科

菊池研4年 武田 花

乃木坂問題

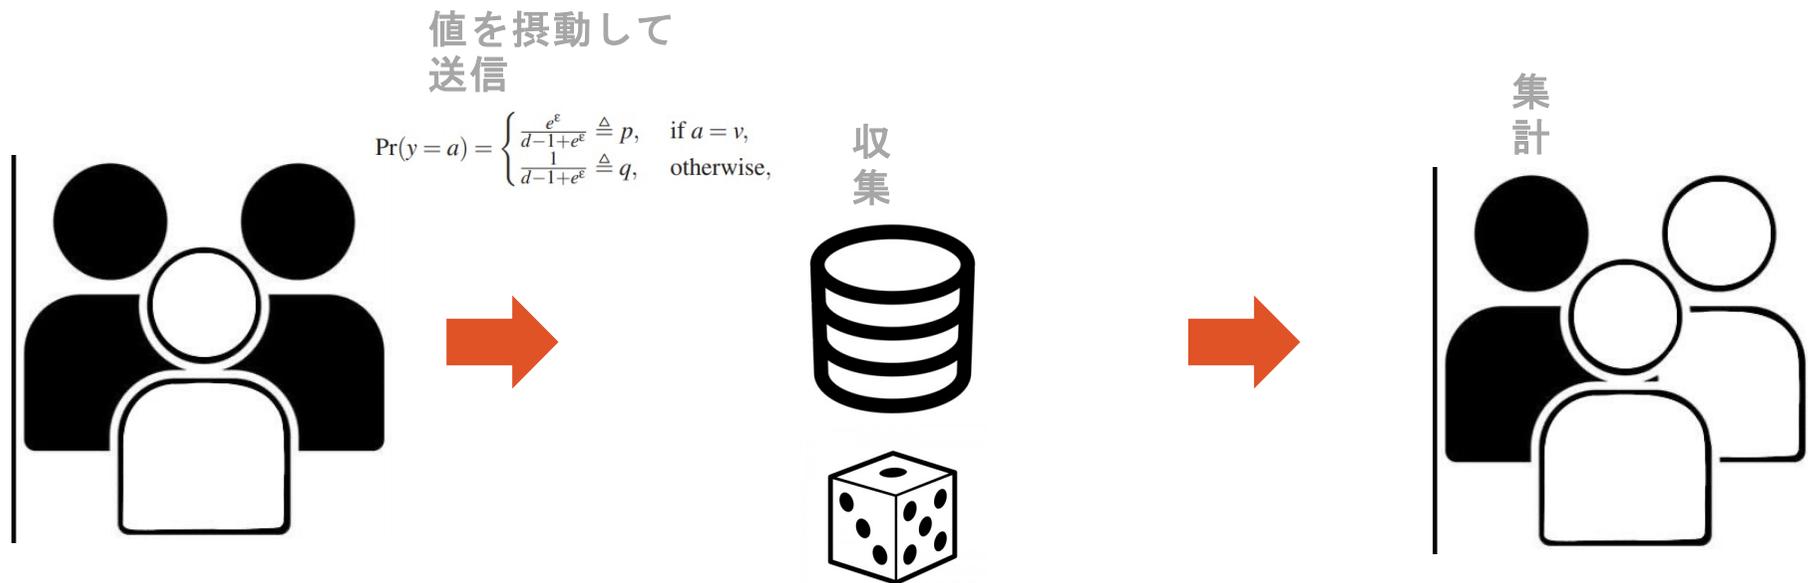


- 推しメンの知名度を上げたい！
 - ポイズニング攻撃を用いて知名度を操作
- 林の知名度を操作
- 有名なメンバーを知らなくて恥ずかしい，推しメンの印象に悪影響を与えたくないから自分の回答を隠したい等，様々ま理由で自分の回答を隠したい
 - 局所差分プライバシーを用いてプライバシーを守る



局所差分プライバシー (RR)

- 値をランダムに摂動してから収集者に送信
→ 真の値が本人しか分からないため、プライバシーが保護される
- 秘匿化割合は自分で設定する (低いほど安全性が高い)
- d: 値の種類 (今回の実験では 0: 知らない 1: 知っている なので、d=2)



RR

- LDPアルゴリズムの1つ

$$\Pr(y = a) = \begin{cases} \frac{e^\varepsilon}{d-1+e^\varepsilon} \triangleq p, & \text{if } a = v, \\ \frac{1}{d-1+e^\varepsilon} \triangleq q, & \text{otherwise,} \end{cases}$$

- P:維持確率 Q:遷移確率 ε :秘匿化度合
- この確率に従いランダムに値を摂動していく
- 秘匿化度合は自分で設定する（低いほど安全性が高い）
- d:値の種類（今回の実験では0:知らない 1:知っている なので、d=2）

ポイズニング攻撃①

MGA

データ利用者

ユーザー



データベース



暗号化



統計情報の
取得

知名度



■ 知らない ■ 知っている ■ 不明



知名度



■ 知らない ■ 知っている ■ 不明



攻撃者

攻撃者が望む結果を送信

ポイズニング攻撃②

RIA

データ利用者

ユーザー



データベース

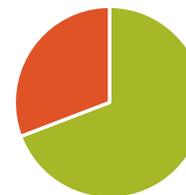


暗号化



統計情報の
取得

知名度



■ 知らない ■ 知っている ■ ■



攻撃者

攻撃者がランダムにアイテムを
選択

知名度



■ 知らない ■ 知っている ■ ■

データセット

- Google Formで作成
- 乃木坂46のメンバー29名（OG含む）についての知名度調査
- 画像+名前を見て知らない場合:0, 知っている場合:1を選択
- 菊池研学部2, 3, 4年生対象
- 期日までに回答が得られた13名分のデータを実験に使用
- MGA攻撃, RIA攻撃それぞれで知名度を上げる攻撃, 下げる攻撃を行う
- MGA攻撃は30回, RIA攻撃では100回ずつ試行

日石麻衣 *



0
 1

生田絵梨花 *



回答結果

- 知名度が最も高い:白石
- 知名度が最も低い:鈴木, 伊藤, 中村, 金川, 松尾
一ノ瀬, 奥田, 小川

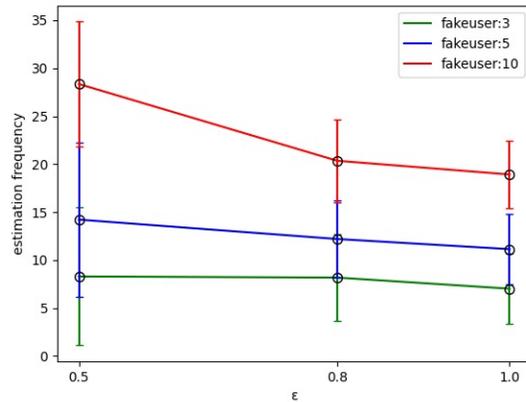
意外性はそこまでなかった、個人的には自分の推し（林）の知名度が思ったより高かった

表1 アンケート結果

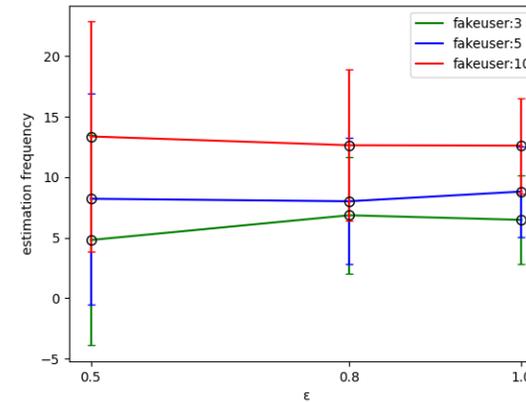
メンバー名	知らない:0	知っている:1
白石	0	13
生田	1	12
齋藤	1	12
生駒	2	11
秋元	2	11
山下	4	9
与田	6	7
堀	7	6
新内	8	5
遠藤	8	5
賀喜	8	5
中西	8	5
樋口	9	4
北野	9	4
梅澤	9	4
久保	9	4
林	9	4
井上	9	4
岩本	10	3
筒井	10	3
池田	10	3
鈴木	11	2
伊藤	11	2
中村	11	2
金川	11	2
松尾	11	2
一ノ瀬	11	2
奥田	11	2
小川	11	2
平均	9.48	6.2
最大	11	13
最小	0	2
標準偏差	3.51	3.51

実験結果①

知名度を上げる攻撃



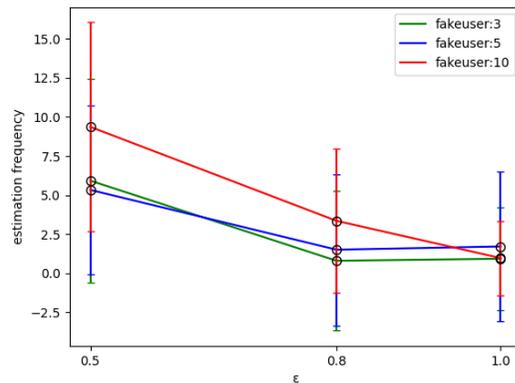
MGA



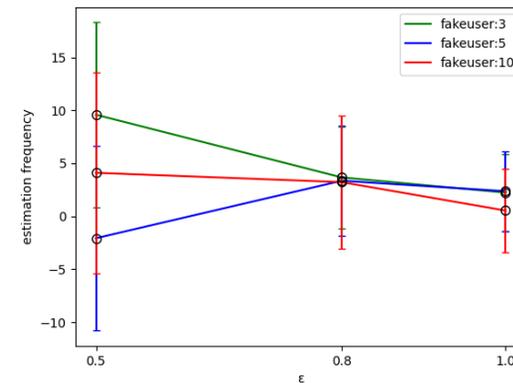
RIA

MGA攻撃の方がRIA攻撃に比べ、平均的に誤差が大きい
RIA攻撃はプライバシー費用 ϵ が上がると誤差が小さくなる一般的な傾向が見られない

実験結果② 知名度を下げる攻撃



MGA



RIA

- ・ どちらの結果でもプライバシー費用 ϵ と誤差の一般的な関係は観測出来なかった
- ・ 知名度を操作したメンバー（林）の知名度が元から低いため、知名度を上げる攻撃に比べ差が出なかった
- ・ 知名度を下げた場合も、上げた場合と同様にプライバシー費用 ϵ と誤差の関係が一般に予想される結果とは異なった。

まとめ

- RIA攻撃の場合最も大きい誤差は $\epsilon=0.5, \text{fakeuser}=10$ の条件で知名度を上げる操作を行った時13.4, MGA攻撃の場合最も大きい誤差は $\epsilon=0.5, \text{fakeuser}=10$ の条件で知名度を上げる操作を行った時28.3のため, MGA攻撃による影響の方が大きいことが明らかになった
- RIA攻撃の場合, 知名度を上げる攻撃と下げる攻撃のどちらにおいても一般的にはプライバシー費用 ϵ が大きくなると誤差が小さくなるが, その傾向が見られなかった。