
k-匿名が使えない事例

Suicaの乗降履歴はなぜ匿名化できないのか？

菊池浩明
明治大学

Suicaの中に格納されているデータ

■ レコード

□ ID

□ 種別

□ 日付

□ 入駅ID

□ 出駅ID

□ 残高

IDm: 01010212360a7e13

端末種:改札機 処理:運賃支払 10/03/26 入:d2/2 出:d0/35 残高:5474 連番:351
端末種:改札機 処理:運賃支払 10/03/26 入:25/8 出:25/7 残高:5764 連番:349
端末種:改札機 処理:運賃支払 10/03/26 入:25/7 出:25/8 残高:5894 連番:347
端末種:改札機 処理:運賃支払 10/03/26 入:d0/35 出:d2/2 残高:6024 連番:345
端末種:車載端末 処理:バス 10/03/24 入:c6a/0 残高:6314 連番:343
端末種:車載端末 処理:バス 10/03/24 入:c6a/0 残高:6424 連番:342
端末種:物販 処理:物販 10/03/22 21:19 入:35/ea 残高:6634 連番:341
端末種:??? 処理:チャージ 10/03/21 入:e0/2e 出:0/0 残高:6912 連番:340
端末種:改札機 処理:運賃支払 10/03/19 入:92/4 出:92/c 残高:1912 連番:339
端末種:改札機 処理:運賃支払 10/03/19 入:92/c 出:92/4 残高:2132 連番:337
端末種:改札機 処理:運賃支払 10/03/17 入:92/a 出:92/c 残高:2352 連番:335
端末種:車載端末 処理:バス 10/03/17 入:c71/0 残高:2522 連番:333
端末種:改札機 処理:運賃支払 10/03/17 入:92/c 出:92/a 残高:2712 連番:332
端末種:車載端末 処理:バス 10/03/14 入:c6a/0 残高:2882 連番:330
端末種:改札機 処理:運賃支払 10/03/13 入:e0/2e 出:e0/32 残高:3092 連番:329
端末種:改札機 処理:運賃支払 10/03/12 入:e0/32 出:e0/2e 残高:3272 連番:328
端末種:車載端末 処理:バス 10/03/12 入:c6a/0 残高:3452 連番:326
端末種:車載端末 処理:バス 10/03/11 入:c6a/0 残高:3662 連番:325
端末種:車載端末 処理:バス 10/03/11 入:c6a/0 残高:3772 連番:324
端末種:車載端末 処理:バス 10/03/10 入:c6a/0 残高:3982 連番:323

匿名化の処理

■ 処理

- 1. 仮名化 (IDを除くだけ)
- 2. 属性削除 (列削除)
- 3. レコード削除 (行削除)
- 4. 一般化
- 5. 統計化

■ 注意.

- k -匿名化, t -多様化などの性質はまだ考えない. 2,3,4の組み合わせはNP完全.
- 他にも, ノイズデータを加える (摂動化), 確率的にデータを交換する (swap), 統計情報を基にサンプリング (re-sampling), 合成 (synthesis) などもある.

匿名化例

列削除

氏名	仮ID	日付	乗駅	降駅	残高
菊池	3	10/14	新宿	中野	1200
高橋	4	10/14	新宿	三鷹	840
佐藤	5	10/14	新宿	御茶ノ水	600
菊池	3	10/15	中野	御茶ノ水	1020

駅数
s=4

ユーザ
数
n=3

仮ID	駅1	駅2
3	新宿	中野
4	新宿	中野
5	新宿	御茶ノ水
3	中野	御茶ノ水

駅3	4駅
中野	御茶ノ水
三鷹	新宿
御茶ノ水	新宿

「再識別化」の種類

(1) 特定個人
再識別可能

菊池	3
----	---

仮ID	駅1	駅2
3	新宿	中野
4	新宿	中野
3	中野	御茶ノ水
4	中野	御茶ノ水
6	新宿	信濃町

(2) 識別非特定
(仮IDが同じ人を
リンク出来る)

(3) 一意識別
(その駅に降りた人が
一人しかいない)

SUICAの案件は(2)を見落としている。
k-匿名性で議論しているのは(3)だけ。

基本データ

■ 人口

- 東京 930万, 神奈川 448, 千葉395, 埼玉 291, 栃木, 群馬
- $n = 42,598,300$
 $= 4 \times 10^7$
(2012年4月1日,
Wikipedia)
- Suica 発行枚数
42,470,000

■ 駅数

- 総数 9,262件
- 関東地方(東京 930, 神奈川 448, 千葉 395)
 $m = 2,497$
 $= 2.5 \times 10^3$
<http://info.jmc.or.jp/ekiensen.html>)
- JR西日本 811駅,
Pasmo 1,291駅, JR
東海 149, JR西日本
430駅

評価1 (仮名化の評価)

■ 問題

□各カードにs個の駅名があるとする、(全員が)再識別できるsはいくらか。

■ 仮定

□m個の駅乗降は一様に分布する独立事象

■ 解

□ $m^s \geq n$ (全ユーザ数) を解いて、 $s = 2.237$ 駅. (3駅あれば全利用者が再識別できる)

乗降数

■ JR, メトロ, 私鉄

□ 上位100駅

□ 1日平均乗降数
(のべ回数)

■ JR

□ 100駅平均
114,697


東日本旅客鉄道株式会社
▶ サイトマップ
えきねっと

[JR 東日本 トップ](#) |
 [鉄道・駅のご利用案内](#) |
 [Suica](#) |
 [企業・IR・採用情報](#) |
 [取](#)

各駅の乗車人員

JR東日本エリア内の1日平均の乗車人員を把握できる駅を掲載しています。
駅名をクリックするとその駅の情報を見ることができます。

※東日本大震災の影響により運転を見合わせていた区間の駅については掲載しておりません。

[▶ 2012年度](#)
 [▶ 2011年度](#)
 [▶ 2010年度](#)
 [▶ 2009年度](#)
 [▶ 2008年度](#)
 [▶ 2007年度](#)
 [▶ 2006年度](#)
 [▶ 2005年度](#)
 [▶ 2004年度](#)
 [▶ 2003年度](#)
 [▶ 2002年度](#)
 [▶ 2001年度](#)
 [▶ 2000年度](#)
 [▶ 1999年度](#)

▶ **ベスト100**
▶ ベスト100以外の駅 [\(1\)](#) [\(2\)](#) [\(3\)](#) [\(4\)](#) [\(5\)](#)
▶ [新幹線駅別乗車人員](#)


順位	駅名	1日平均		
		定期外	定期	合計
1	新宿	346,974	395,859	742,833
2	池袋	229,055	321,700	550,756
3	渋谷	194,407	217,602	412,009
4	東京	189,621	212,655	402,277
5	横浜	154,250	246,404	400,655
6	品川	138,788	190,890	329,679
7	新橋	96,129	154,552	250,682
8	大宮	88,408	151,735	240,143
9	秋葉原	126,688	107,503	234,187
10	高田馬場	77,501	124,263	201,765
11	北千住	50,498	148,126	198,624

順位	駅名	1日平均	
		定期外	定期
51	浦和	27,715	
52	仙台	42,006	
53	武蔵溝ノ口	28,098	
54	川口	26,236	
55	登戸	25,279	
56	鶴見	25,461	
57	巢鴨	30,586	
58	原宿	47,354	
59	新小岩	23,309	
60	代々木	36,224	
61	舞浜	39,871	

数理モデル

■ Zipf則

□乗降数 $y = f(x) = 9 \times 10^5 / x^{0.632}$ [回/日]




評価2 (k-匿名化の評価)


■ 駅の確率分布 (一様分布仮定を外す)

$$\square N = \int_1^m 9 \cdot 10^5 / x^{0.632} dx = [2.5 x^{0.4}]^m = 3 \cdot 10^7$$


$$\square p(x) = f(x)/N = x\text{位の駅が選ばれる確率}$$



s>1の場合



sに対する再識別順位 x^*



結論

- 列削除(仮名化)のみの匿名化では, 3駅 (=s)で再識別可能である.
 - 3回の利用ごとに仮名IDを付け替える必要.
- 行削除をして $k=2$ -匿名性を保証しても, $s=2$ の時に99.9%のレコードを削除する必要がある.

再識別確率となる順位 x^*

- $s=1$ の時 (単一の駅から攻撃)

- $k =$ 同じ駅列を持つ利用者数

- $= 1 =$ 存在的再識別可能 (一人でも特定できる)

- $1 = n p(x^*)$ (k の期待値)を満たす順位

- $x^* = (n \cdot 9e^5 / N)^{10/6} = 5 e^9 \gg m$

- (そんなに駅名はないので, 特定不能 = **安全**)

- $s = 2$ (2駅分の情報から攻撃)

- $p'(x) = p(x)^2$ (駅選択が独立の仮定)

- $x^* = (n/N \cdot 9e^5)^{1/0.63 s} = 23698$

匿名化

■ 列削除

□ 日付, 降りる駅, 金額

□ ID, 駅1, 駅2, ..., 駅s

□ 例)

ID=1, 新宿, 池袋, 新宿

ID=2, 新宿, 渋谷

» レコードをつなぎ, 駅名の重複を許す

» ID当りの長さsは可変とする