2021年 2月 12日
修士論文発表会

取引履歴の特徴量に基づく Bitcoinアドレスの識別リスクの評価

松本　寛輝

菊池研究室

背景

- Bitcoinの匿名性
  - Bitcoinアドレス(ランダムな文字列)に基づく
  - アドレスとユーザが繋がる情報はない
  - ユーザを特定できない ＝ 匿名性が高い

Bitcoinアドレス

- Bitcoinアドレスの識別
  - 同一ユーザが管理しているアドレスの特定
    - » 例) アドレス a_1, a_2, a_3 は同一のユーザAが管理している
      ※ ユーザAの情報(氏名など)は特定できない

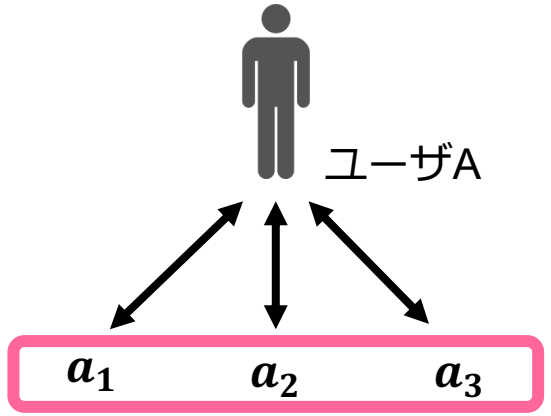

Bitcoinアドレスの識別

Bitcoinの取引例

- 例) ユーザAがユーザBに5BTC送金

所有者	アドレス	送金前の残高	送金後の残高
ユーザA	a_1	3 BTC	1 BTC
	a_2	3 BTC	0 BTC
ユーザB	b_1	0 BTC	5 BTC

a_1は**取引のおつり**を受け取っている

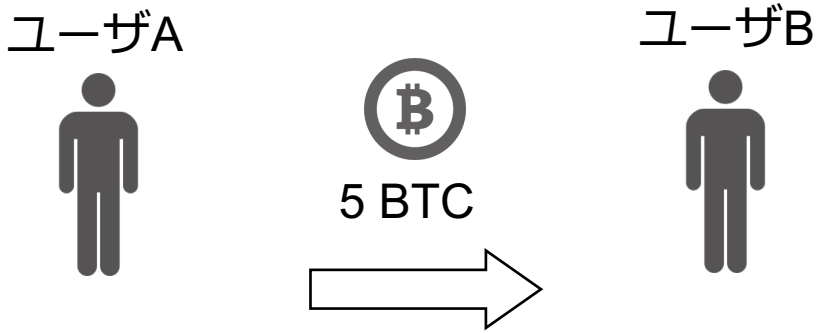

取引情報

Input	Output
a_1 (3 BTC)	b_1 (5 BTC)
a_2 (3 BTC)	a_1 (1 BTC)

Bitcoinアドレスの識別手法(先行研究)

- 永田ら[2018]による**宛先アドレス**を用いたアドレス識別

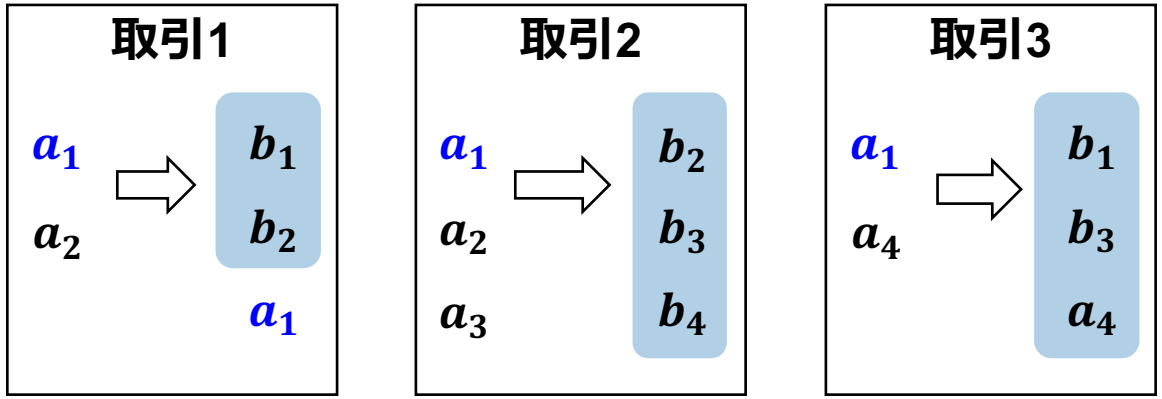

a_1の宛先アドレス集合$S(a_1)$

$$S(a_1) = \{b_1, b_2, b_3, b_4, a_4\}$$

- *Meiklejohn*ら[2013]による**入力アドレス**を用いたアドレス識別

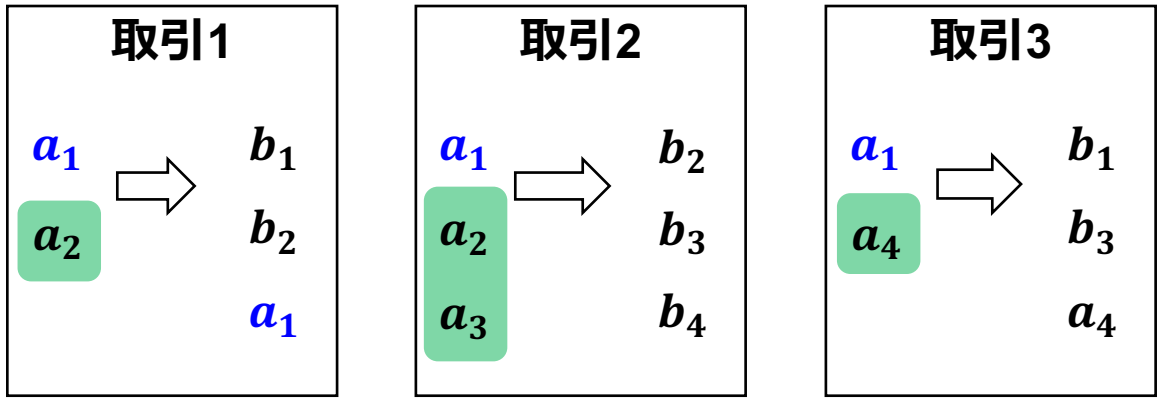

a_1の入力アドレス集合$I(a_1)$

$$I(a_1) = \{a_2, a_3, a_4\}$$

先行研究[永田,2018]の課題と提案手法

- 識別対象のアドレスが取引の送金側(*Input*フィールド)である場合のみ想定
  - 送金に使用するアドレス(a_1)は**ユーザが自身で選択できる**ため識別精度に影響を与える

- **「送金元アドレス」と「出力アドレス」を用いたアドレス識別を提案**
  - 自身のアドレス(a_1)に対して送金を行うアドレスは指定できない

既存手法：アドレスa_1が送金

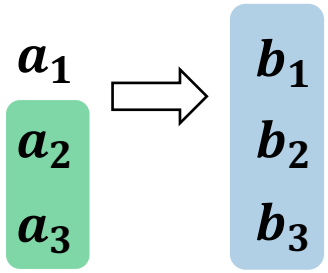

入力アドレス集合$I(a_1)$　**宛先アドレス集合$S(a_1)$**

提案手法：アドレスa_1が受け取り

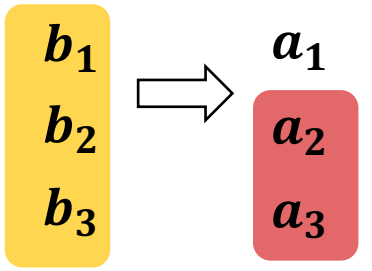

送金元アドレス集合$R(a_1)$　**出力アドレス集合$O(a_1)$**

受け取りに着目したの識別手法(提案手法)

- 提案手法1. **送金元アドレス**を用いたアドレス識別

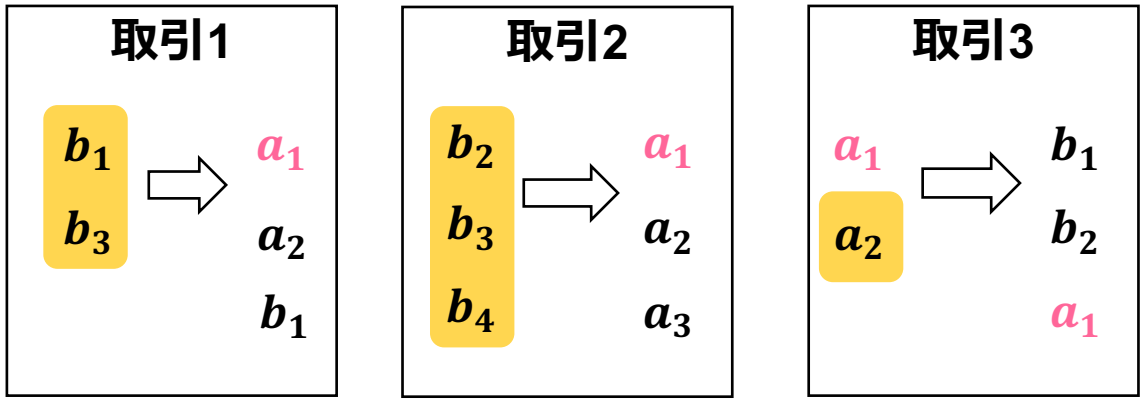

a_1の送金元アドレス集合$R(a_1)$

$$R(a_1) = \{b_1, b_2, b_3, b_4, a_2\}$$

- 提案手法2. **出力アドレス**を用いたアドレス識別

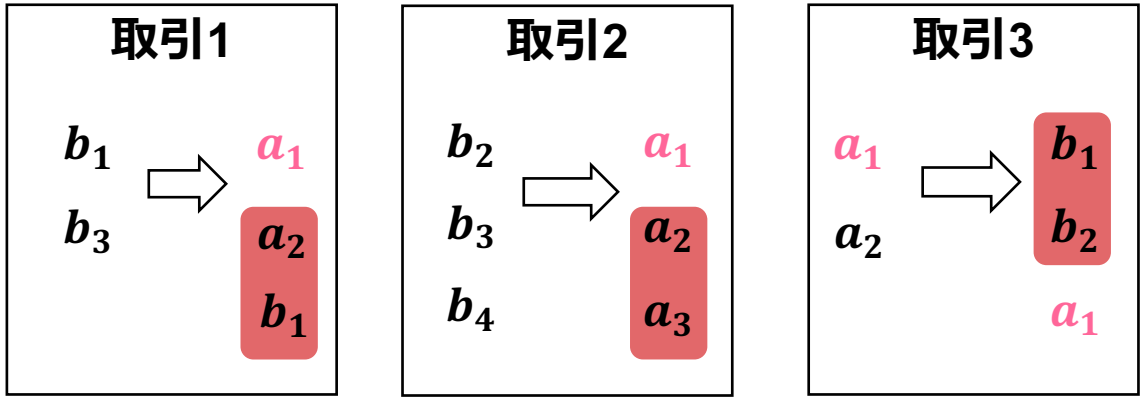

a_1の入力アドレス集合$O(a_1)$

$$O(a_1) = \{b_1, b_2, a_2, a_3\}$$

アドレス識別のアルゴリズム

- 宛先集合Sを用いた未知のアドレスa_iの識別手法 (集合R, I, Oも同様)

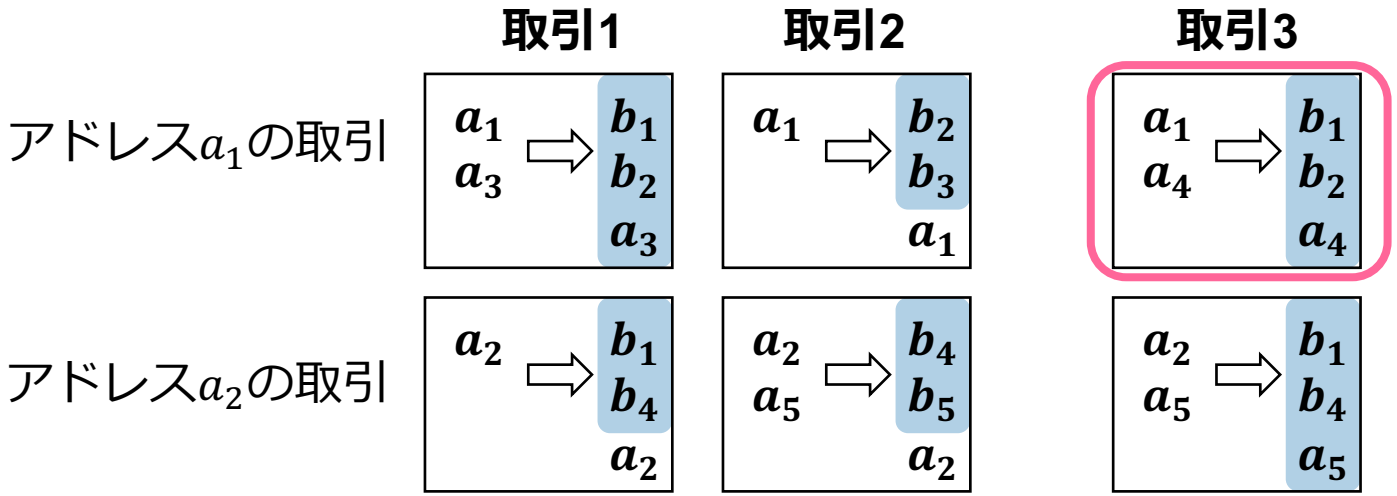

未知のアドレス$a_i = a_1$を
正解アドレスとする

アドレス	学習アドレス集合$S(a)$ (取引1,2)	評価アドレス集合$S'(a_i)$ (取引3)	Jaccard係数 $\frac{\lvert S(a) \cap S'(a) \rvert}{\lvert S(a) \cup S'(a) \rvert}$
a_1	$\{b_1, b_2, b_3, a_3\}$	$\{b_1, b_2, a_4\}$	$\frac{\lvert\{b_1, b_2\}\rvert}{\lvert\{b_1, b_2, b_3, a_3, a_4\}\rvert} = \mathbf{0.40}$
a_2	$\{b_1, b_4, b_5\}$		$\frac{\lvert\{b_1\}\rvert}{\lvert\{b_1, b_2, b_4, b_5, a_4\}\rvert} = 0.20$

Jacarrd係数の値が大きい
$a_1 = a_i$と予測
➔ 正解

研究目的と実験概要

- 研究目的
  - 4つの集合のうち, 識別精度が高いアドレス識別手法を明らかにする
    - » 識別精度を正確に評価することが困難

- 実験概要
  - 実験1. 取引回数に基づく識別
    - » 10年の間で継続して使用されたアドレスの識別リスクを定量的に示す
  - 実験2. 利用目的に基づく識別
    - » 5種類のアドレスを収集し, 最も識別精度が高い利用目的を明らかにする

実験1. 取引回数に基づく識別

- アドレス数
  - 暗号資産の情報交換サイト*Bitcointalk*より収集
  - 2009年1月4日から2019年11月18日の10年分の取引
  - 取引回数が最低2回以上のアドレスを使用

- 実験手順
  1. 取引回数を$\boldsymbol{n}$と定義
     - 21回送金と受け取り取引を行なった($\boldsymbol{n = 21}$)
     - 多くのアドレスの取引回数をまとめて評価する時は10刻みなどに量子化 ($\boldsymbol{n = 21, 22, \ldots, 30 \rightarrow n = 30}$)
  2. 取引回数ごとに100個のアドレスを100回層別サンプリング
  3. 既存手法(集合S, I)と提案手法(集合R, O)を用いてアドレスを識別

取引回数 n	アドレス数	サンプリング数
10	12,493	100
20	4,948	100
30	2,535	100
40	1,408	100
50	842	100
60	499	100
70	335	100
80	211	100
90	153	100
100	117	100
合計	23,541	1,000

実験1.結果 取引回数と識別精度の推移

- 実験結果
  - エラーバーは95%の信頼区間を示す
- 識別精度
  - **集合Oの識別精度が最も高い**
    ($n = 100$ のとき, 78.6)
  - 集合Oの最も低い識別精度
    ($n = 30$ のとき, 37.1)
    - » 集合R, I, Oは$n = 30$の前後で識別精度が最も悪くなる

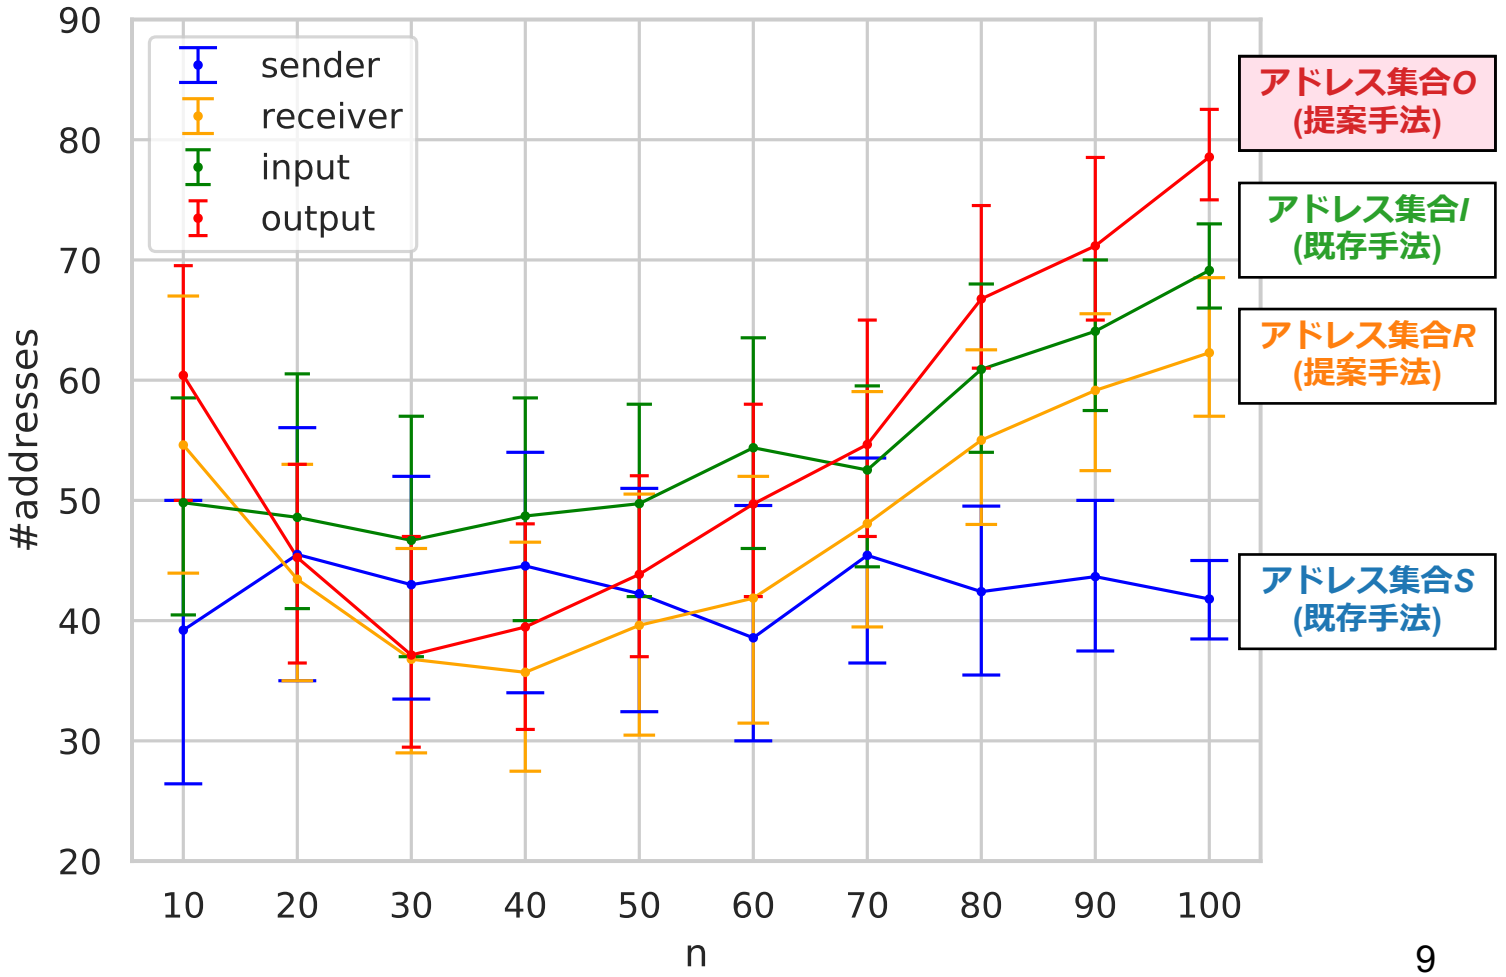

実験1.提案手法の精度が高いことの仮説検定

- 仮説検定
  - 提案方式R, Oの識別精度が既存手法S, Iよりも高いことを確かめる
  - 平均値のt検定を実施
  - 帰無仮説：2つのアドレス集合の識別率は一致する
  - $n = 100$における4つの方式の精度を比較

- 検定結果
  - 集合Oを用いた提案手法の識別精度は
    既存手法S, Iよりも統計的に有意な水準である

提案方式	平均値の差	統計量t	p値
R, S	20.5	57.0	2.2×10^{-16}
R, I	−6.8	-	-
R, O	−16.3	-	-
O, S	36.8	135.1	2.2×10^{-16}
O, R	16.3	45.5	2.2×10^{-16}
O, I	9.5	34.9	2.2×10^{-16}

実験2. アドレスの利用目的に基づく識別

- アドレス数
  - Bitcoinの利用目的のうち, 代表的な5つのサービス(交換所等)を対象
  - 2019年4月1日から9月30日の半年間で取引をおこなったアドレスを収集
  - 取引回数が最低2回以上のアドレスを使用

- 実験手順
  1. 5種類の利用目的ごとに30個のアドレスを100回層別サンプリング
  2. 既存手法(集合S, I)と提案手法(集合R, O)を用いてアドレスを識別

利用目的	概要	アドレス数	サンプリング数
Bitcointalk (BBS)	登録を行っている ユーザのアドレス	844	30
Bitcoin ATM	ATMに預貯金を行うユーザと ATMに登録されているアドレス	106	30
Dark web	違法商品・サービスを 提供, 利用しているアドレス	49	30
Exchange	交換所を利用している ユーザのアドレス	274	30
Mining Pool	マイニング報酬を受け取る アドレス	85	30
合計	-	1,358	150

実験2.結果 利用目的ごとの識別率

- 実験結果
  - Dark webで利用されていたアドレスの識別数が最も高い(平均 22.3)
    - » Dark webはサイトの運営期間が短く, アドレスの利用期間も短いと考えられる
  - アドレス集合Iは総合的な識別精度が最も高い(合計 84個)
    - » 利用目的別にみると**集合S**や**集合O**の識別精度が上回る

識別手法	集合	利用目的					合計
		BBS	ATM	Dark web	Exchange	Mining Pool	
永田ら	S	12.8	**16.6**	**23.9**	4.1	**17.8**	75
提案手法 1.	R	17.2	3.6	22.2	14.7	5.0	63
Meiklejohnら	I	17.6	16.5	22.3	12.6	15.0	84
提案手法 2.	O	**19.5**	4.3	20.9	**22.6**	5.0	72
	平均	16.8	10.2	22.3	13.5	10.7	

結論

- 受け取り取引に注目した新たな2つの識別手法を提案
  - **提案手法の集合O**を用いた識別精度は既存手法の集合S, Iよりも統計的に有意な水準で高い

- 実験結果
  - 実験1. 取引回数に基づく識別
    - » 集合Oでは, $n = 30$のとき,アドレス識別精度が最も低い(37.1個)
    - » 集合Oでは, $n = 100$のとき,アドレス識別精度が最も高い(78.6個)
  - 実験2. 利用目的に基づく識別
    - » 5種類のうち Dark web の識別精度が高い
    - » 集合Iの精度は総合的に高い, 利用目的別では集合S, Oの精度が高い

質疑応答スライド

実験1. $n = 30$付近で識別精度が低下

- $n = 30$付近で識別精度が低下
  - **調査1.アドレスが毎回更新される新しいウォレットが多い**
    - » アドレスの取引開始時期の調査
  - **調査2.学習量が少ないため**
    - » 学習アドレス集合の大きさを調査
  - **調査3.特定の利用目的のものが偏っている**
    - » 収集した10年分のアドレスと利用目的を調査

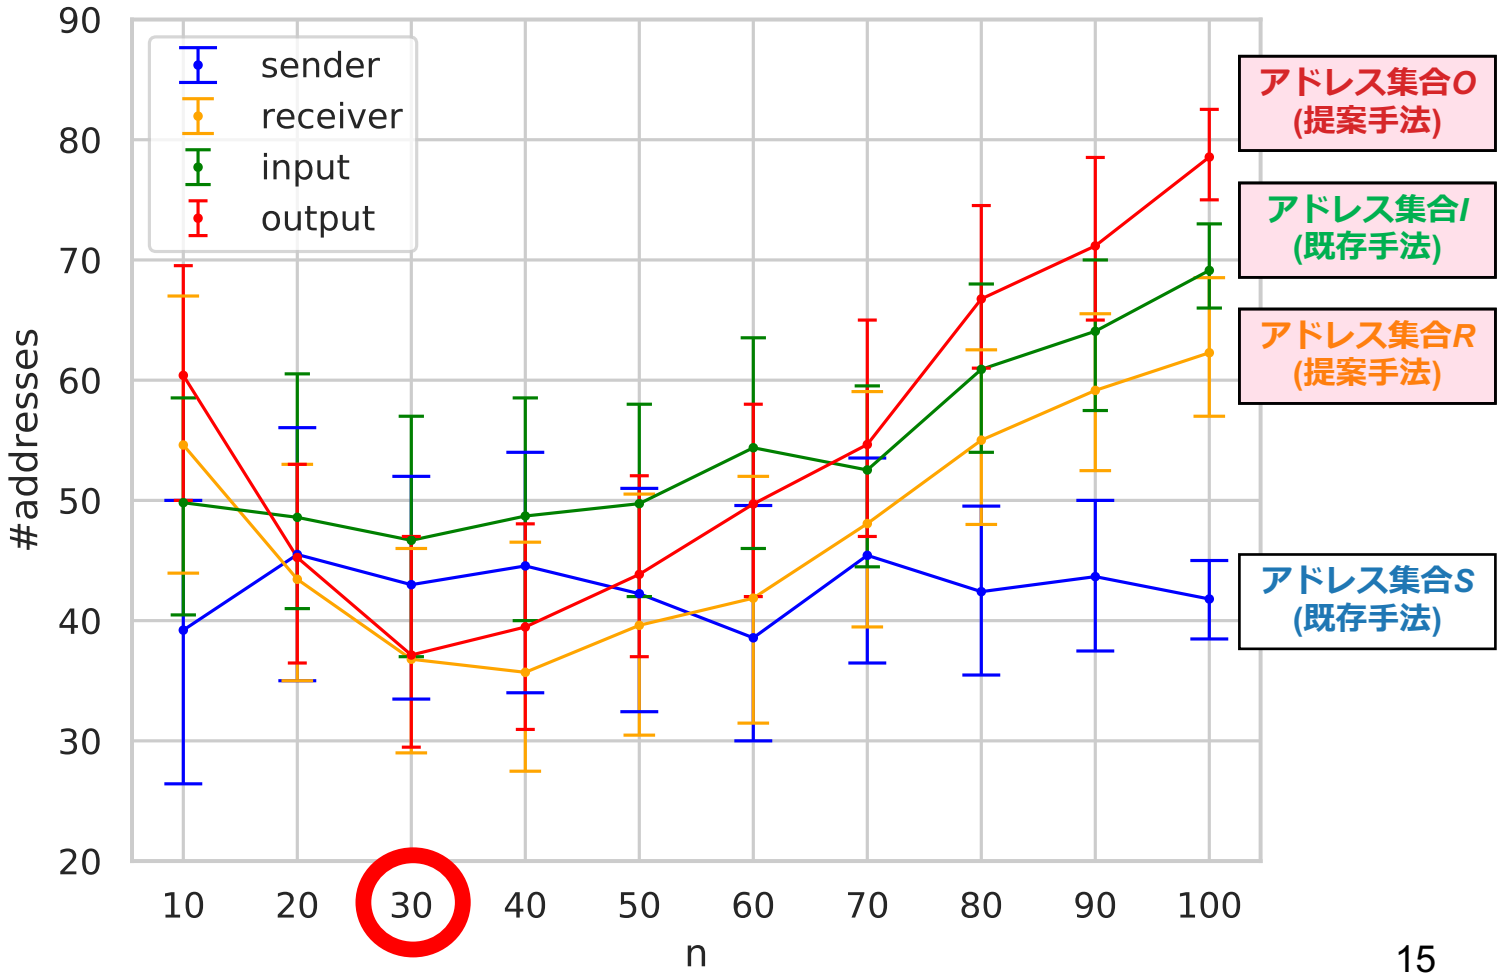

実験1. 識別精度が低下した原因

- **原因「調査3. 特定の利用目的のものが偏っている」**
  - 収集したアドレスのうち交換所(Exchange) で利用されているアドレスを調査
  - $n = 30$の付近で識別精度とは逆の振る舞い(上に凸)となった

- 交換所アドレスが含まれると識別精度が低下する
  - 修士論文中では, 交換所アドレスとBitcointalkアドレスのみを用いた識別実験も実施

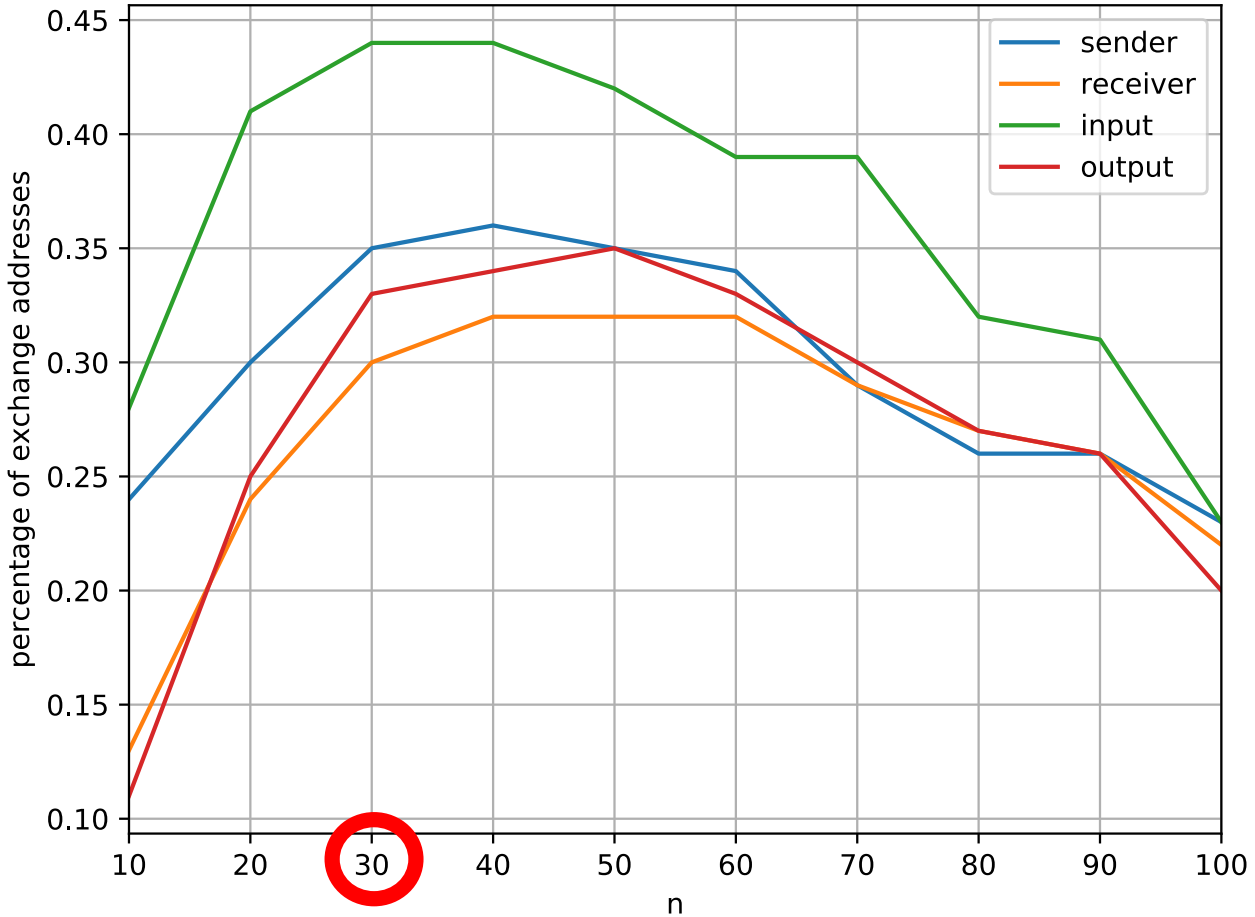

Bitcointalkかつ交換所に属するアドレスの割合

実験1. 識別精度が低下した原因(調査1)

- 調査1.アドレスが毎回更新される新しいウォレットが多い
  - アドレスの取引開始時期の調査
  - 取引回数$n = 30$前後で大きな差はなし

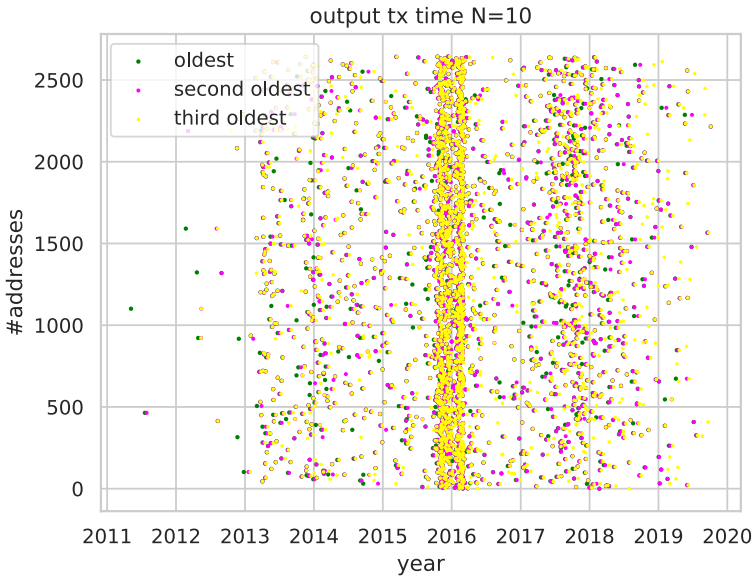

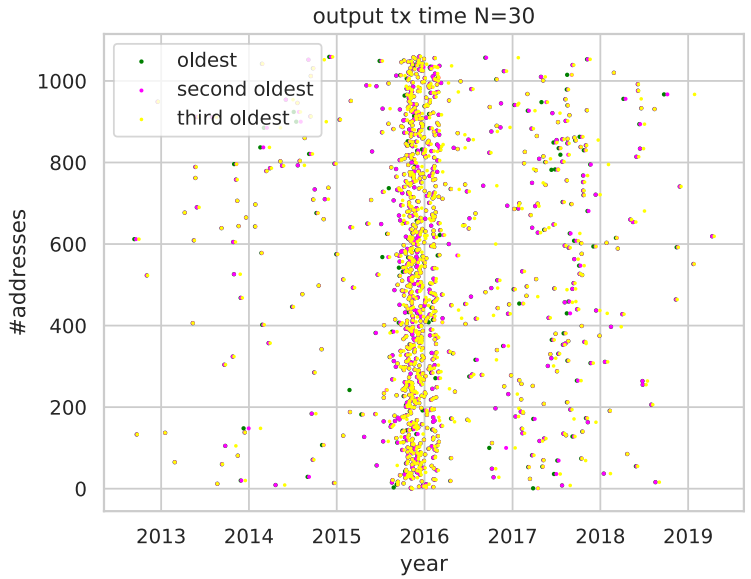

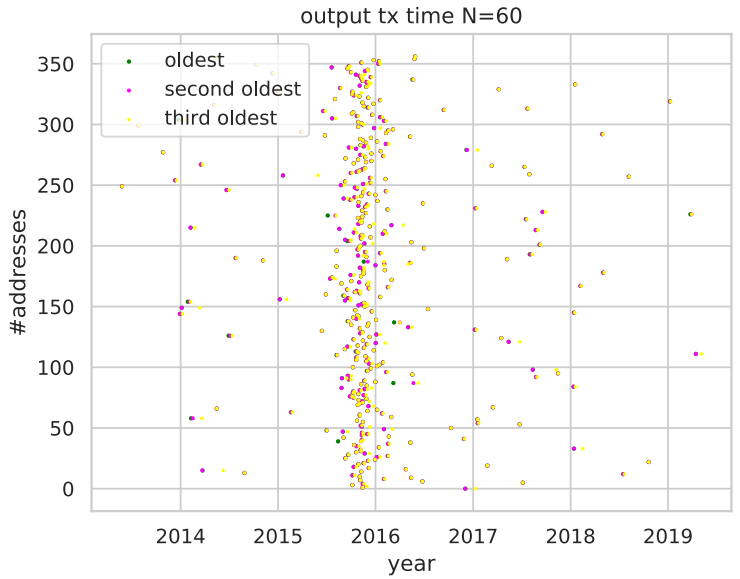

出力アドレス集合Oについて, 左から$n = 10, n = 30, n = 60$における取引開始時期の散布図

参考：10年間の取引数の分布

ピーク(2017年12月, 2019年4月)

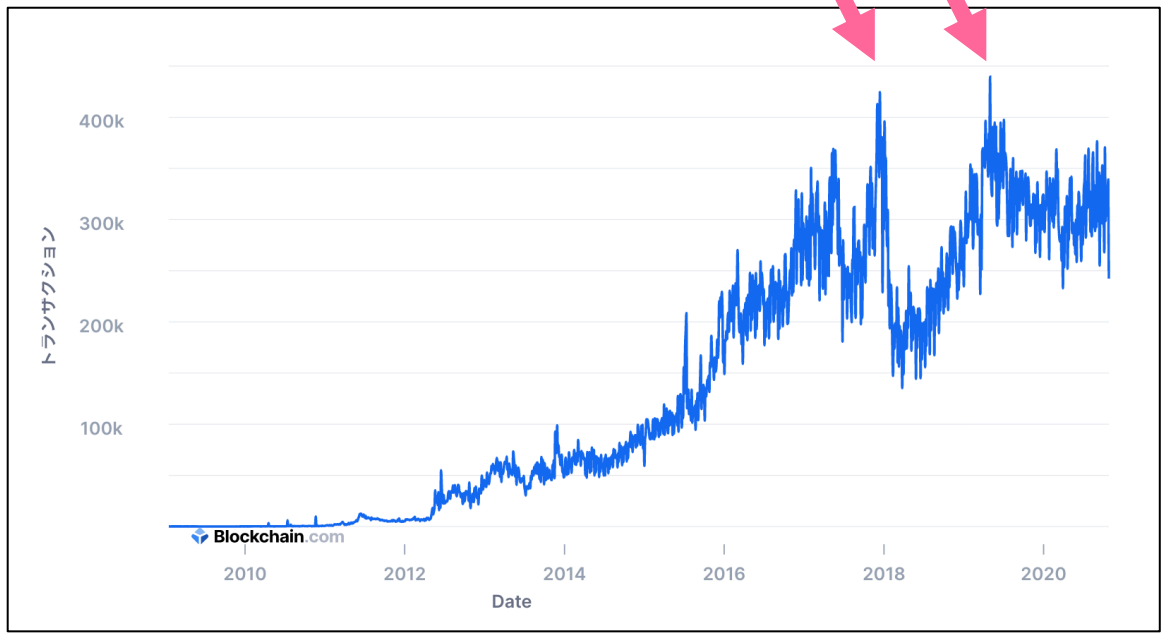

Blockchain.com 1日あたりの確認済みトランザクション数
(https://www.blockchain.com/charts/n-transactions)

ピーク(2016年付近)

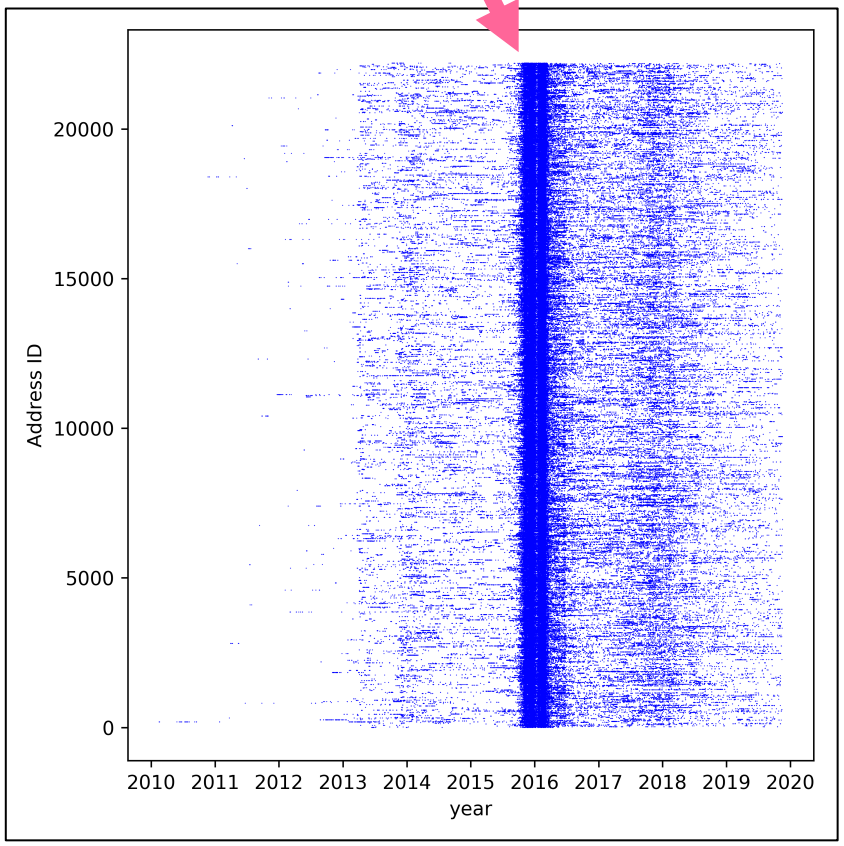

約10年間の取引分布(bitcontalkアドレス)

実験1. 識別精度が低下した原因(調査2)

- 調査2.学習量が少ないため
  - 学習アドレス集合の大きさを調査
  - 取引回数$n = 30$前後で大きな差はなし

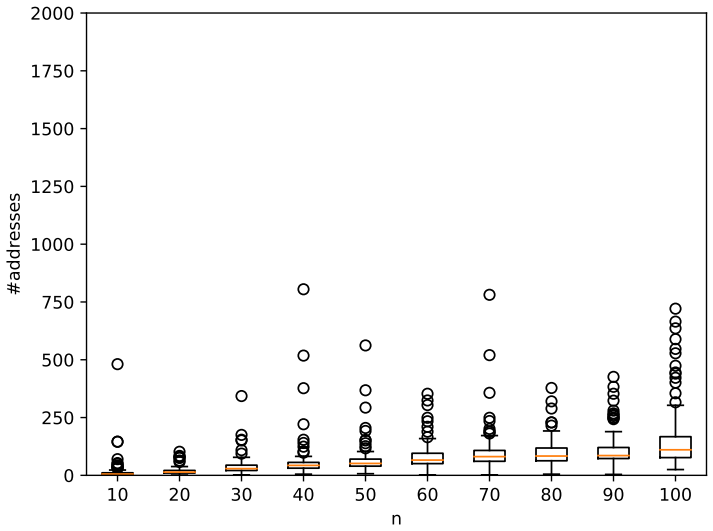

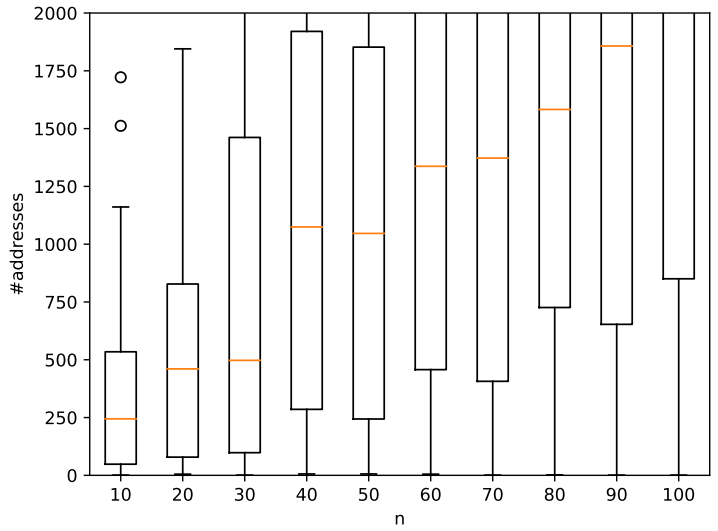

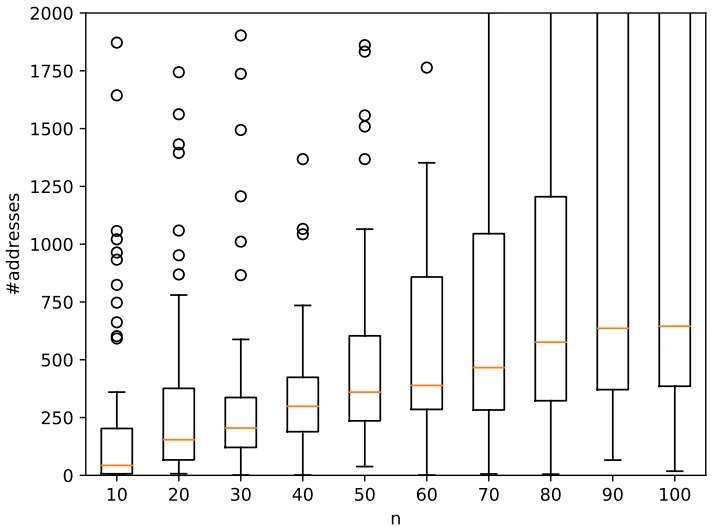

取引回数nについて, 左から集合R, I, Oにおける学習アドレス数の分布

提案手法R, Oで識別精度が低い利用目的

- Bitcoin ATM

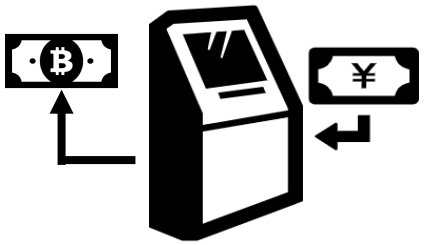

Bitcoinの購入

ATMのアドレスから送金

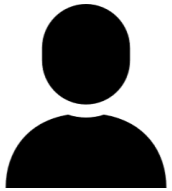

ユーザ

- Mining pool(マイニングプール)

ブロックチェーン
(Bitcoin)

マイニング報酬

マイニングプール
事業者

報酬の分配

マイナー

交換所アドレスが識別精度を低下させる原因

- 交換所アドレスの特殊な取引
  - 登録ユーザのアドレスに保管されているBitcoinを自社のアドレスへ送金する
    - » 分散されたBitcoinを一元に管理する
    - » 一定期間ごとに実施
  - 右図では, 100個のユーザのアドレス(赤枠)から自社のアドレス(青枠)に送金を行う取引

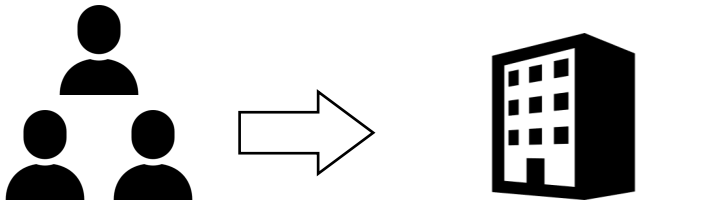

交換所登録ユーザ　　交換所アドレス

交換所アドレスの特殊な取引

https://chainflyer.bitflyer.jp/Transaction/62a0b59372f4c7be314752f278f4f3f64c78ffcc1fad53fd601f45e6f2a855ba

アドレス識別対策

- 集合Oを利用したアドレス識別手法への対策
  - **受け取りアドレス**を1つ定めて再利用する

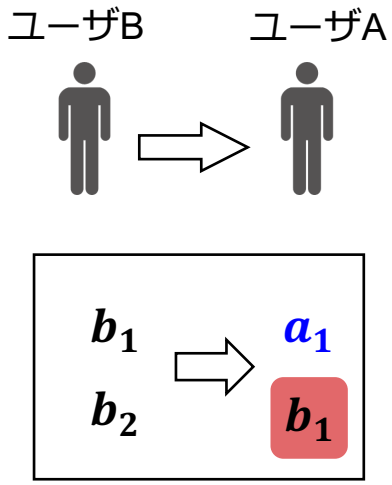

1対1の取引例

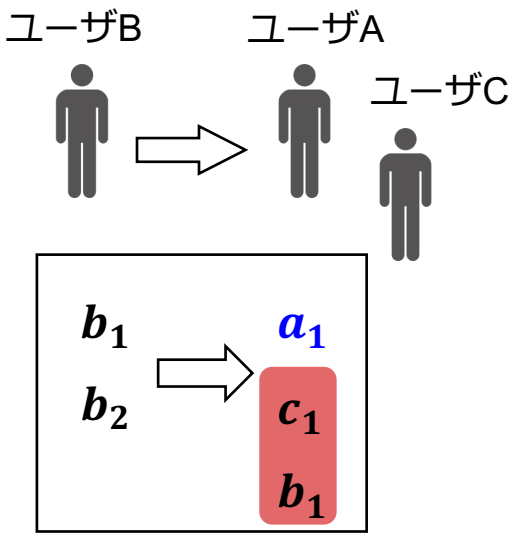

1対多の取引例

a_1の入力アドレス集合$\boldsymbol{O(a_1)}$

$$\boldsymbol{O(a_1) = \{b_1, c_1\}}$$

➔ ユーザAが管理する
他のアドレス(a_2, a_3など)は識別できない

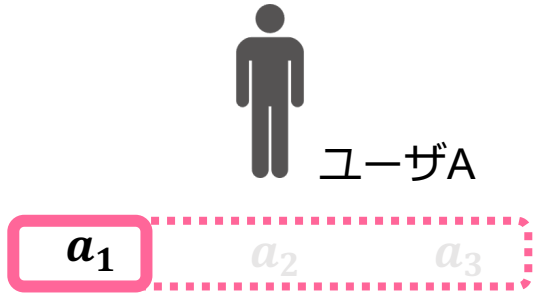

Bitcoinアドレスの識別

収集したアドレスの背景

- アドレスの再利用
  - 開発コミュニティ*では「一度利用したアドレスを再び利用しない」ことを推奨
    - » 実験1で収集したアドレス**23,541個は2回以上取引を行っている**
  - 前提：アドレスは再利用される

- 収集したアドレスの例
  - Bitcointalkでプロフィールページ**にあるアドレス
    - » プロフィールページに書かれているアドレスは頻繁に更新されないはず
  - 送金する際に青枠のアドレスを利用：多？少？
  - 受け取る際に青枠のアドレスを利用：多

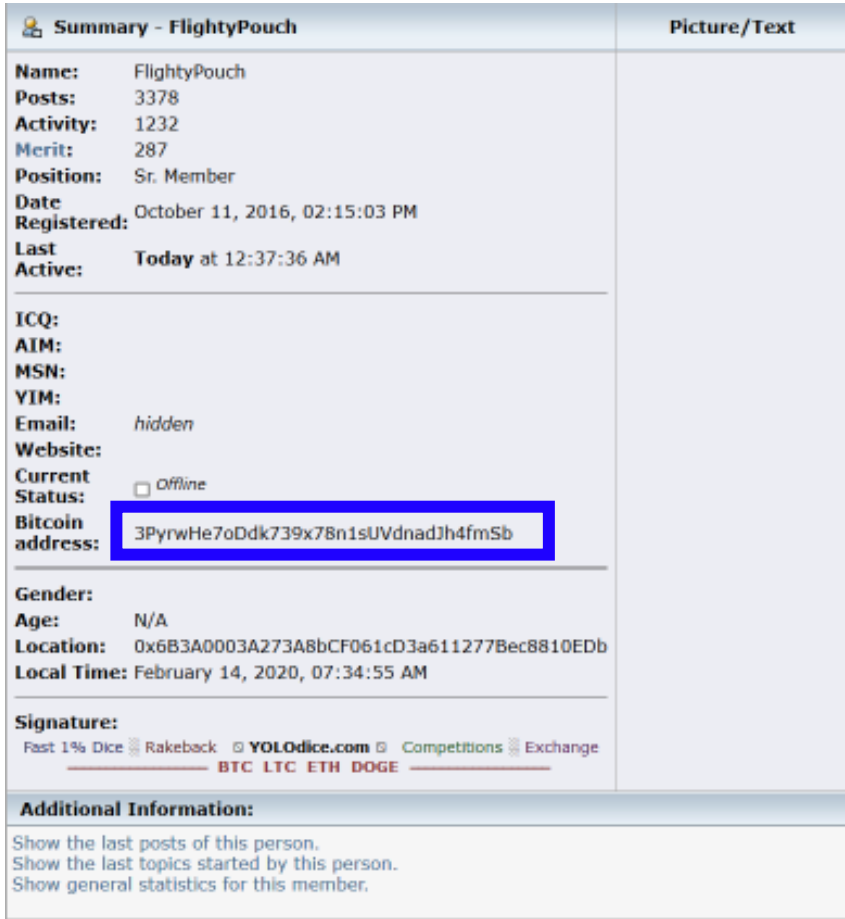

* Bitcoin.org プライバシーの保護 (https://bitcoin.org/ja/protect-your-privacy)
** bitcointalk プロフィールページ (https://bitcointalk.org/index.php?action=profile;u=907855)

実験2. アドレスの利用目的について

- アドレスの利用目的
  - Bitcoinの利用目的のうち, 代表的なサービス(交換所等)を対象

- 5つの代表的なアドレスの利用目的

利用目的	アドレス	考えられるユーザ層	識別精度(予測)
BBS (Bitcointalk)	登録を行っているユーザのアドレス	暗号資産に関心が高いユーザ	△
Bitcoin ATM	ATMに預貯金を行うユーザと ATMに登録されているアドレス	ATMが設置されている地域のユーザ	△
Dark web	違法商品・サービスを 提供, 利用しているアドレス	身元を明かさず取引を行いたいユーザ	✕
Exchange	交換所を利用しているユーザのアドレス	投資目的で利用しているユーザ	○
Mining Pool	マイニング報酬を受け取るアドレス	投資目的で利用しているユーザ	○

アドレス識別と社会への影響

- アドレス識別の影響
  - アドレスの管理者(ユーザ)の追跡や属性推定に利用

- Bitcoinの市場の動き
  - テスラ社がBitcoinへ投資
    - » 将来的にはBitcoinでの販売も検討
  - 特定の商品を購入したアドレスの追跡リスク
    - » 交換所などから個人情報が漏洩する可能性
  - Dark web(闇市場)の追跡
    - » Zcash(より匿名性の高い暗号資産)で追跡を行った研究もある

Coindesk JAPAN テスラ、ビットコインに15億ドルを投資――史上初の4万7000ドル突破【更新】
https://www.coindeskjapan.com/98814/

取引回数と利用目的の識別精度

- 10年間のアドレスのBitcointalkと交換所アドレスの識別
  - エラーバーは95%の信頼区間を示す

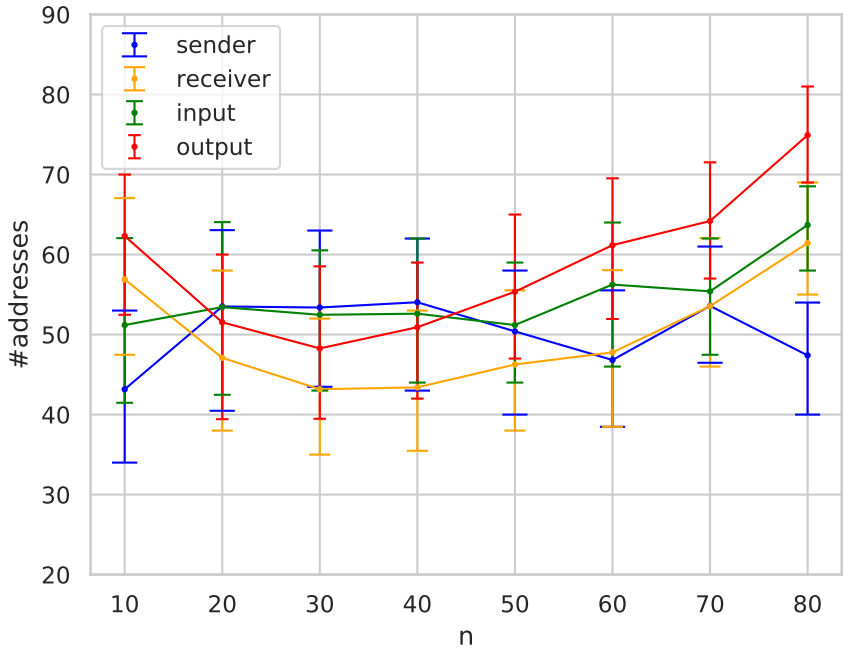

取引回数とBitcointalkの識別精度

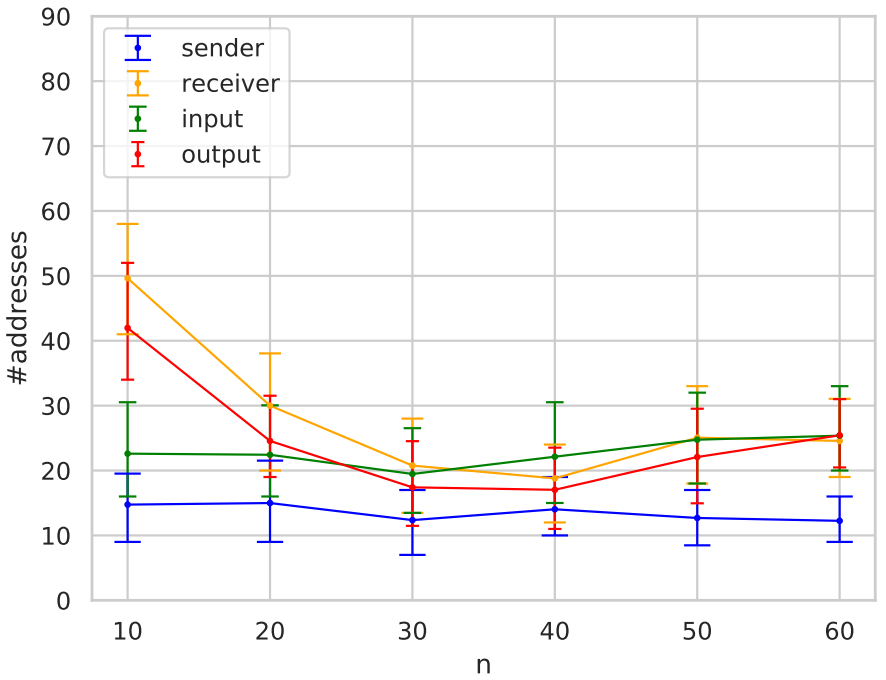

取引回数とExchangeの識別精度