

CSS2020@オンライン
2B5-2 : ブロックチェーンプラットフォーム

Bitcoin取引履歴の特徴量に基づく アドレス識別リスクの評価

松本 寛輝¹ 菊池 浩明²

1. 明治大学大学院先端数理科学研究科
2. 明治大学総合数理学部

背景

■ Bitcoinの匿名性

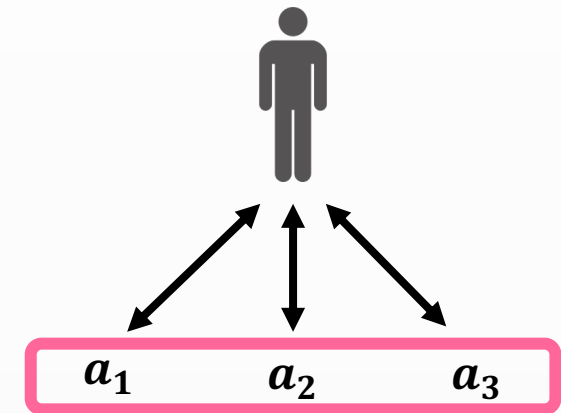
- Bitcoinアドレス(ランダムな文字列)に基づく
- アドレスとユーザが繋がる情報はない
- ユーザを特定できない = 匿名性が高い

■ 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 は同一のユーザが管理している
 - ※ ユーザの情報(氏名など)は特定できない



Bitcoinアドレス



Bitcoinアドレスの識別

Bitcoinの取引構造

■ 例) ユーザAがユーザBに5BTC送金

送金前のアドレス


- ユーザAのアドレス

$$a_1 = 3 \text{ (BTC)}$$

$$a_2 = 3 \text{ (BTC)}$$

- ユーザBのアドレス

$$b_1 = 0 \text{ (BTC)}$$



a_1 (3BTC)

a_2 (3BTC)

Input

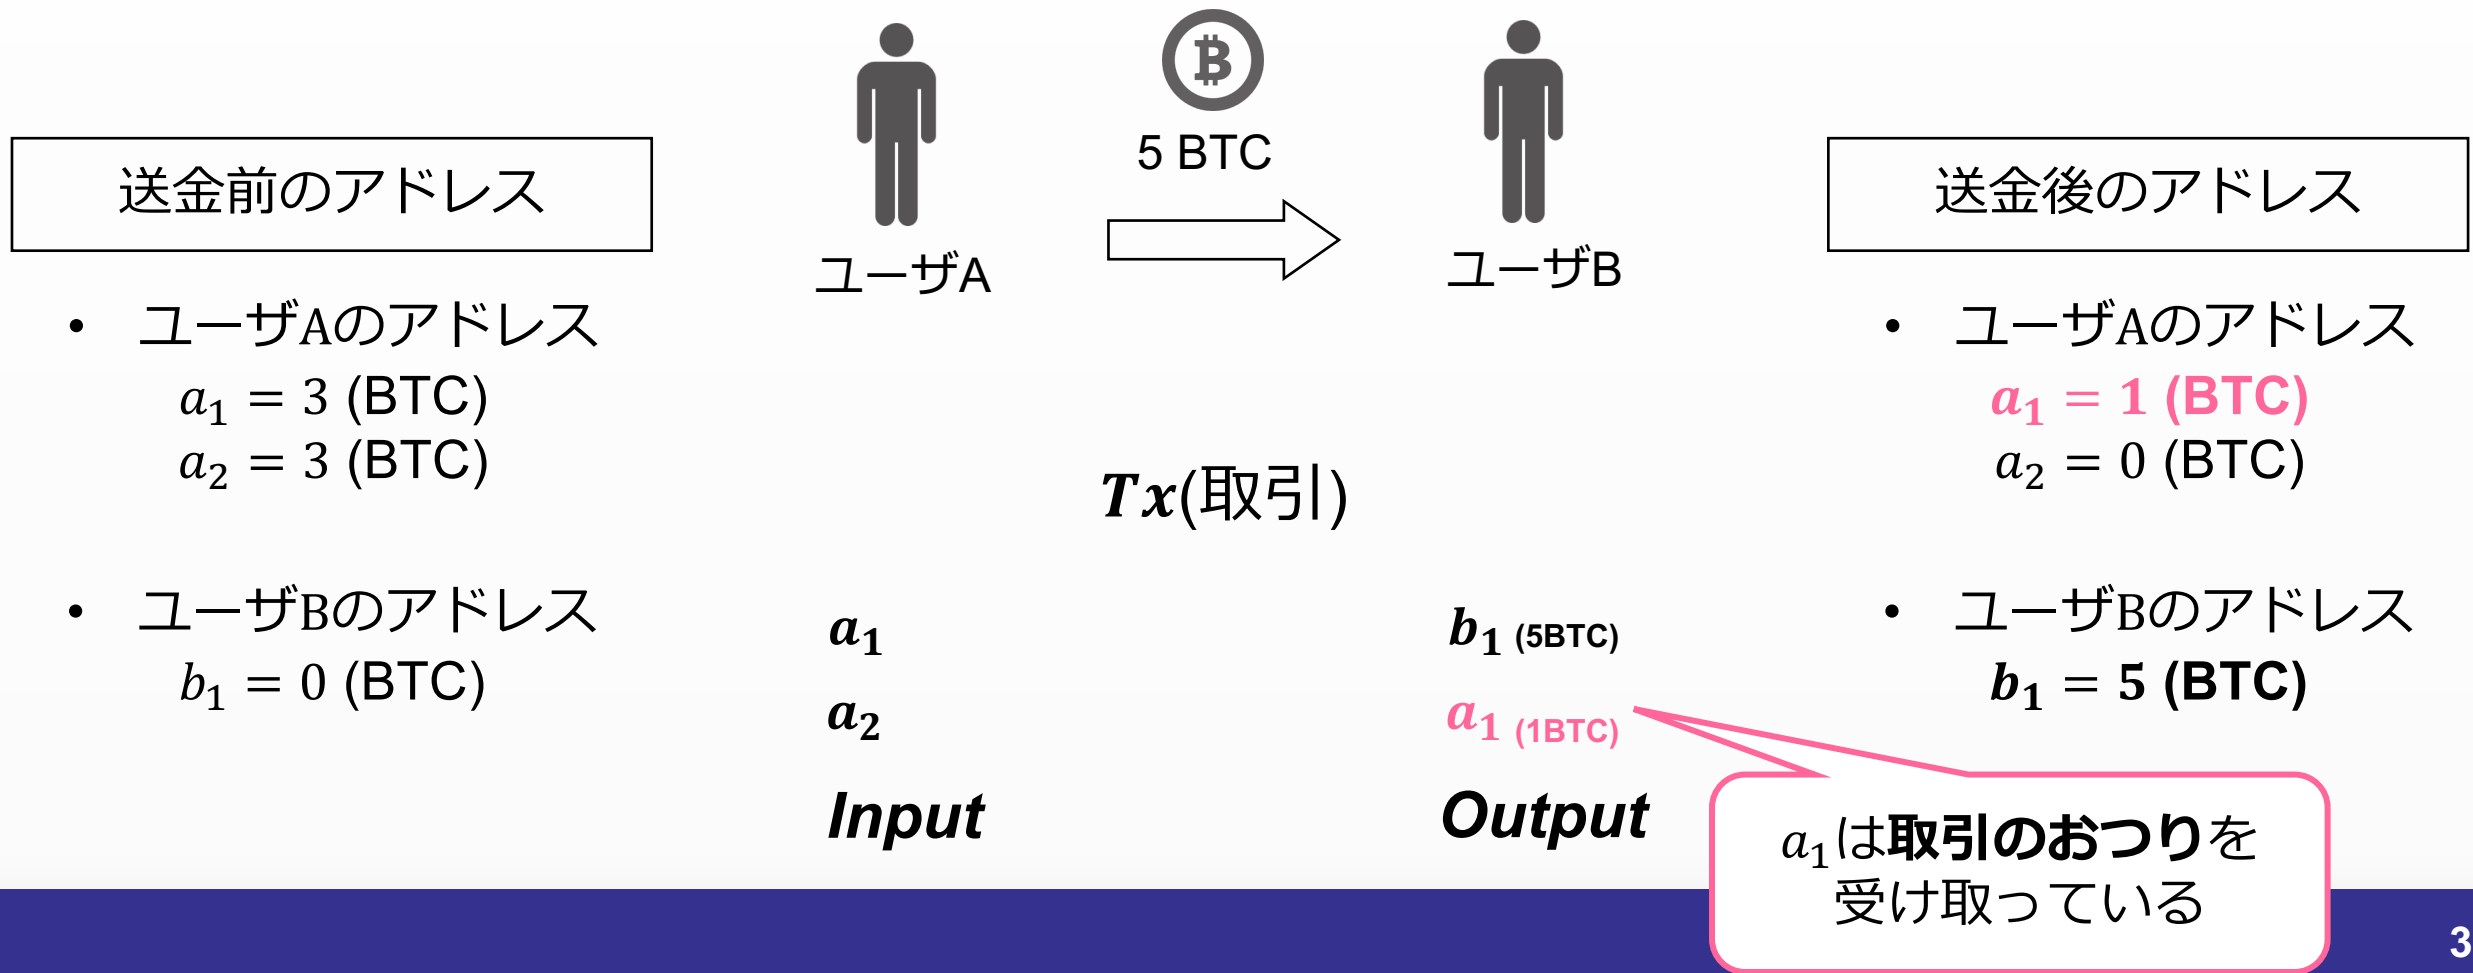
b_1

a_1

Output

Bitcoinの取引構造

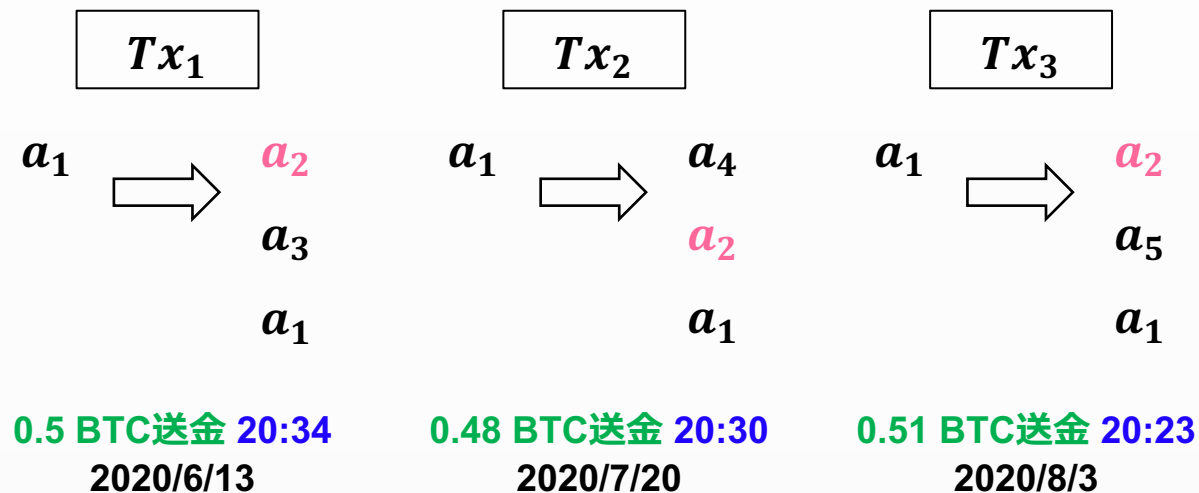
■例) ユーザAがユーザBに5BTC送金



Bitcoinアドレスの識別リスク

■ Bitcoinアドレスの識別リスク

- 取引(T_x)の回数が増加 = アドレスの特徴量が学習される
- 例) 金額, 時間帯, 送金を行う相手(宛先アドレス)



アドレス a_1 は...

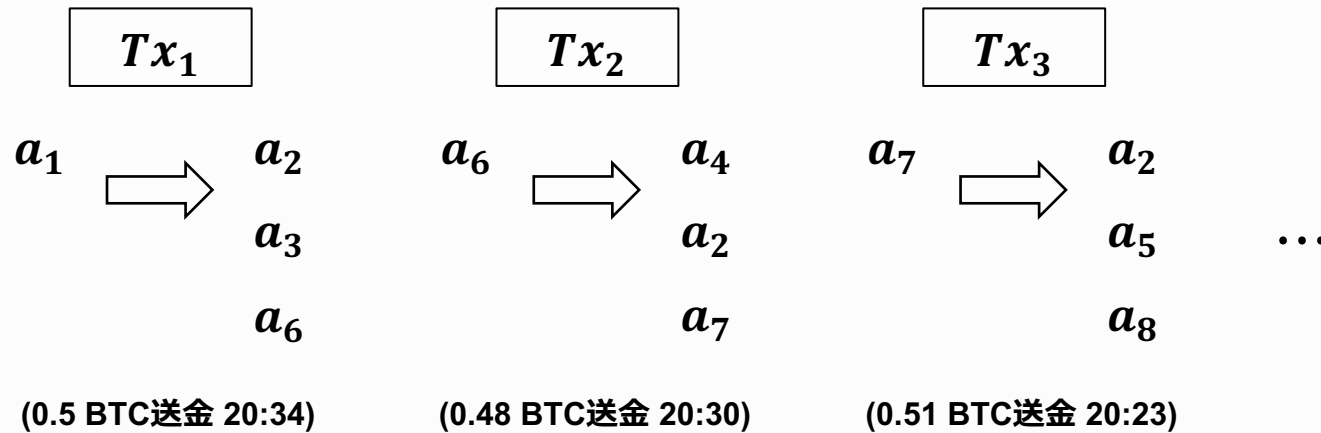
- 20時30分前後で取引
- アドレス a_2 によく送金する
- 毎回0.5 BTCほど送金する



プライバシーの保護と課題

■ Bitcoinアドレスとプライバシーの保護

- 開発コミュニティ Bitcoin.org は「一度利用したアドレスを再び利用しない」ことを推奨
- アドレス a_1 は取引毎に新しいアドレス(a_6, a_7, a_8)を作成・利用する



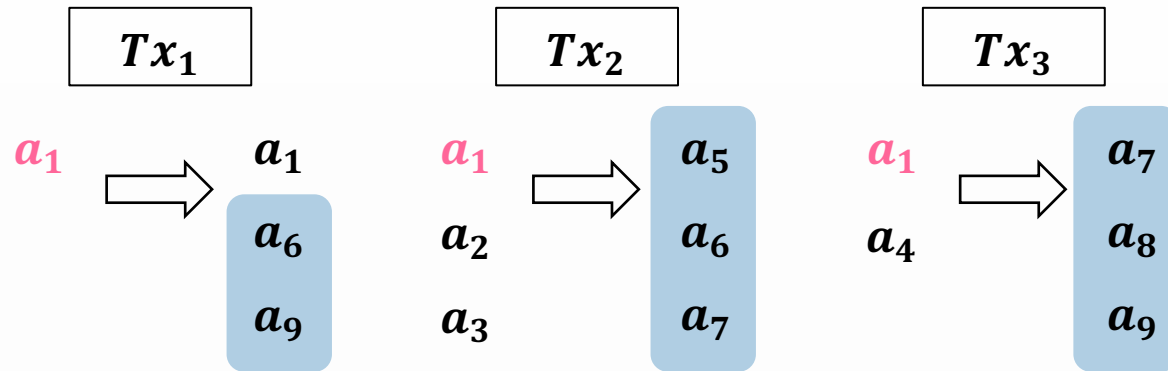
アドレス a_1 の特徴はわからない

■ Bitcoinアドレスを長期期間・繰り返し利用する

- SNSへの公開(寄付), 一部営利目的で利用されるアドレス, 等

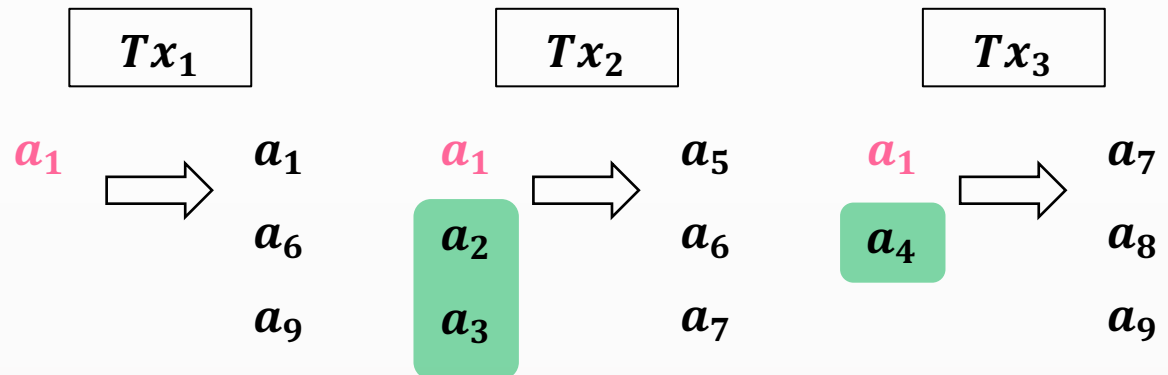
先行研究 Bitcoinアドレスの識別

■ 永田ら[2018]による「送金先アドレス」(宛先アドレス)を用いたアドレス識別



アドレス a_1 の
宛先アドレス集合 S
 $S(a_1) = \{a_5, a_6, a_7, a_8, a_9\}$

■ Meiklejohnら[2013]による「入カアドレス」を用いたアドレス識別



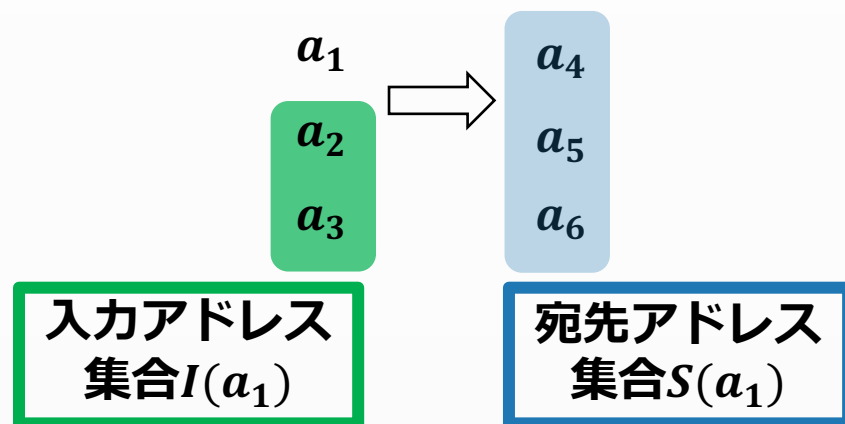
アドレス a_1 の
入カアドレス集合 I
 $I(a_1) = \{a_2, a_3, a_4\}$

先行研究[永田ら, 2018]の課題

- 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はユーザが自身で選択できるため識別率に影響を与える

既存手法

アドレス a_1 が送金



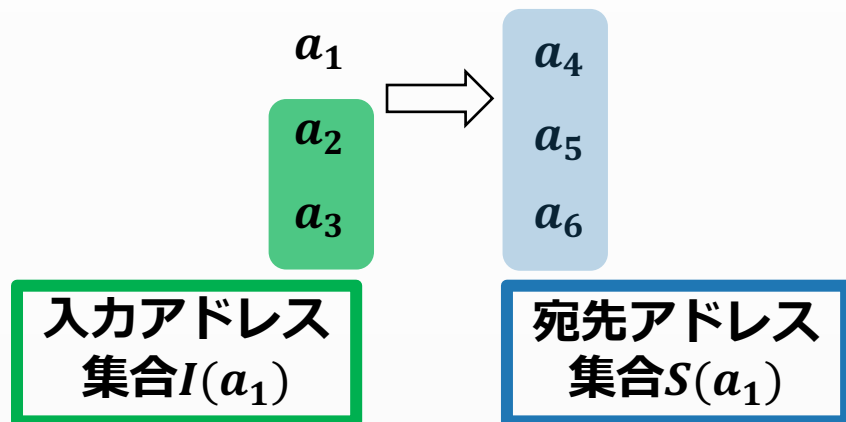
提案方式

■ 「送金元アドレス」と「出カアドレス」を用いたアドレス識別を提案

- 識別対象のアドレスが取引の受け取り側(*Output*フィールド)にある
- 自身のアドレスに対して送金を行うアドレスは指定できない

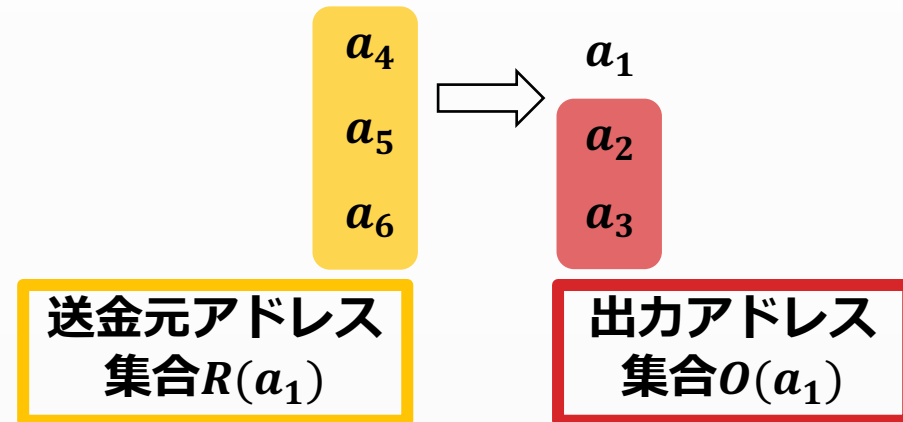
既存手法

アドレス a_1 が送金



提案手法


アドレス a_1 が受け取り



研究目的と研究課題

■ 4つの識別方式のうち最も識別精度が高い手法はどれか？

- **取引回数を与えるアドレス識別率への影響**を明らかにする
 - » 長期間, 繰り返し利用されたアドレスは識別されやすいのか？



2回取引したアドレス a_1
100回取引したアドレス b_1

アドレスの識別率
 $a_1 < b_1$

- **アドレス利用目的を与える識別率への影響**を明らかにする

- » アドレスの利用目的(交換所, マイニング等)で識別率は変化するのか？

実験1 アドレス識別：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～2019年11月18日の約10年分の取引

■ 識別アドレスの選択

- 取引回数 n を基準に層別サンプリング
 - » 100個のアドレスを抽出
- 100個のアドレスのうち識別に成功した個数を求める

取引回数 n	アドレス数
2 - 10	12,493
11 - 20	4,948
21 - 30	2,535
31 - 40	1,408
41 - 50	842
51 - 60	499
61 - 70	335
71 - 80	211
81 - 90	153
91 - 100	117
合計	23,541

実験1 アドレス識別：実験手法

■ アドレスの識別実験手法

- i. 各アドレス集合を7対3となるように分割する
(学習アドレス集合を7, 評価アドレス集合を3と定義)
- ii. 100個のアドレス集合間の距離を *Jaccard* 係数を用いて求める
- iii. *Jaccard* 係数の値が最も高い集合のアドレス一致していた場合,
「識別に成功した」と定義する


実験1 結果：取引回数とアドレス識別率の推移

■ 取引回数 n とアドレス識別率

- $n = 40$ 識別率が最も低い(35.7)
- $n = 100$ 識別率が最も高い(78.6)

■ アドレス識別率と識別手法

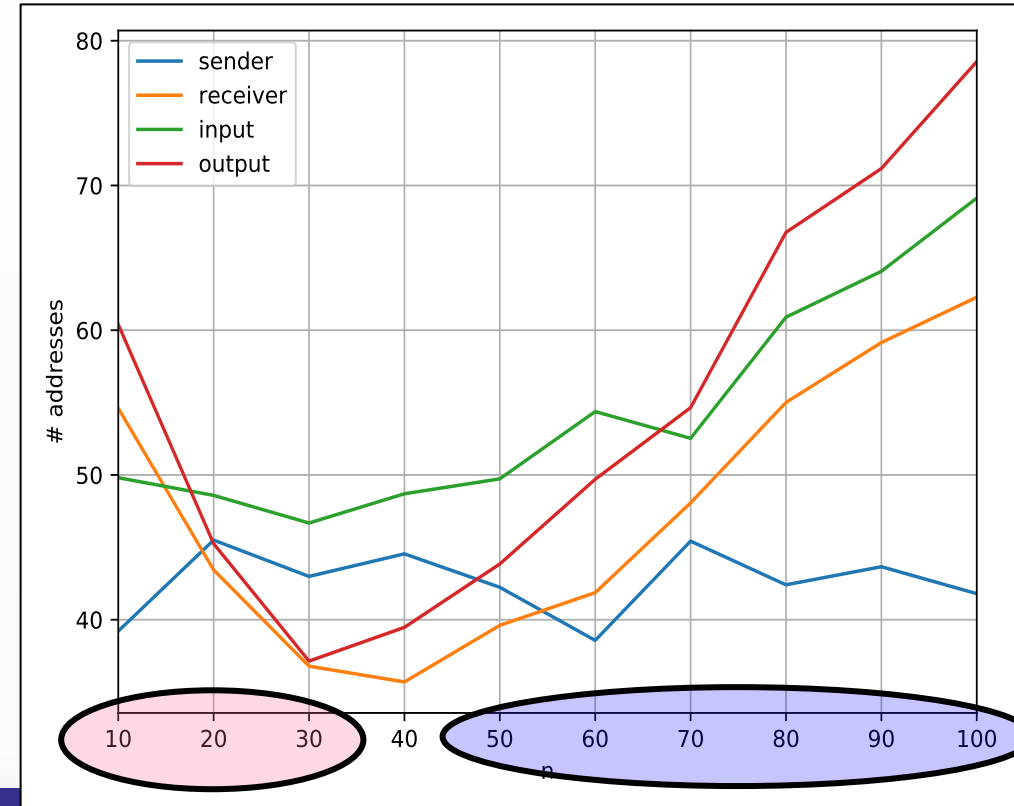
- 出力アドレス集合O(提案手法)が最も識別率が高い(平均:54.7)
- 宛先アドレス集合S(既存手法)が最も識別率が低い(平均:42.6)



実験1 結果：n=10~30のアドレス識別が低下

- 利用されているアドレスの属性が異なる
 - ウォレットアプリ：Bitcoinに興味がある人(ライトユーザ)
 - 交換所：投資家などBitcoin取引を頻繁に行う人(ヘビーユーザ)

	ウォレットアプリ	交換所
アドレスの更新	○	×
長期間の利用	△	○
送金方法	自分で送金	複数のユーザの送金をまとめて実施
利用方法	スマホアプリ等で誰でもインストール可能	本人確認手続きなどを行う必要あり
取引頻度	少ない	多い

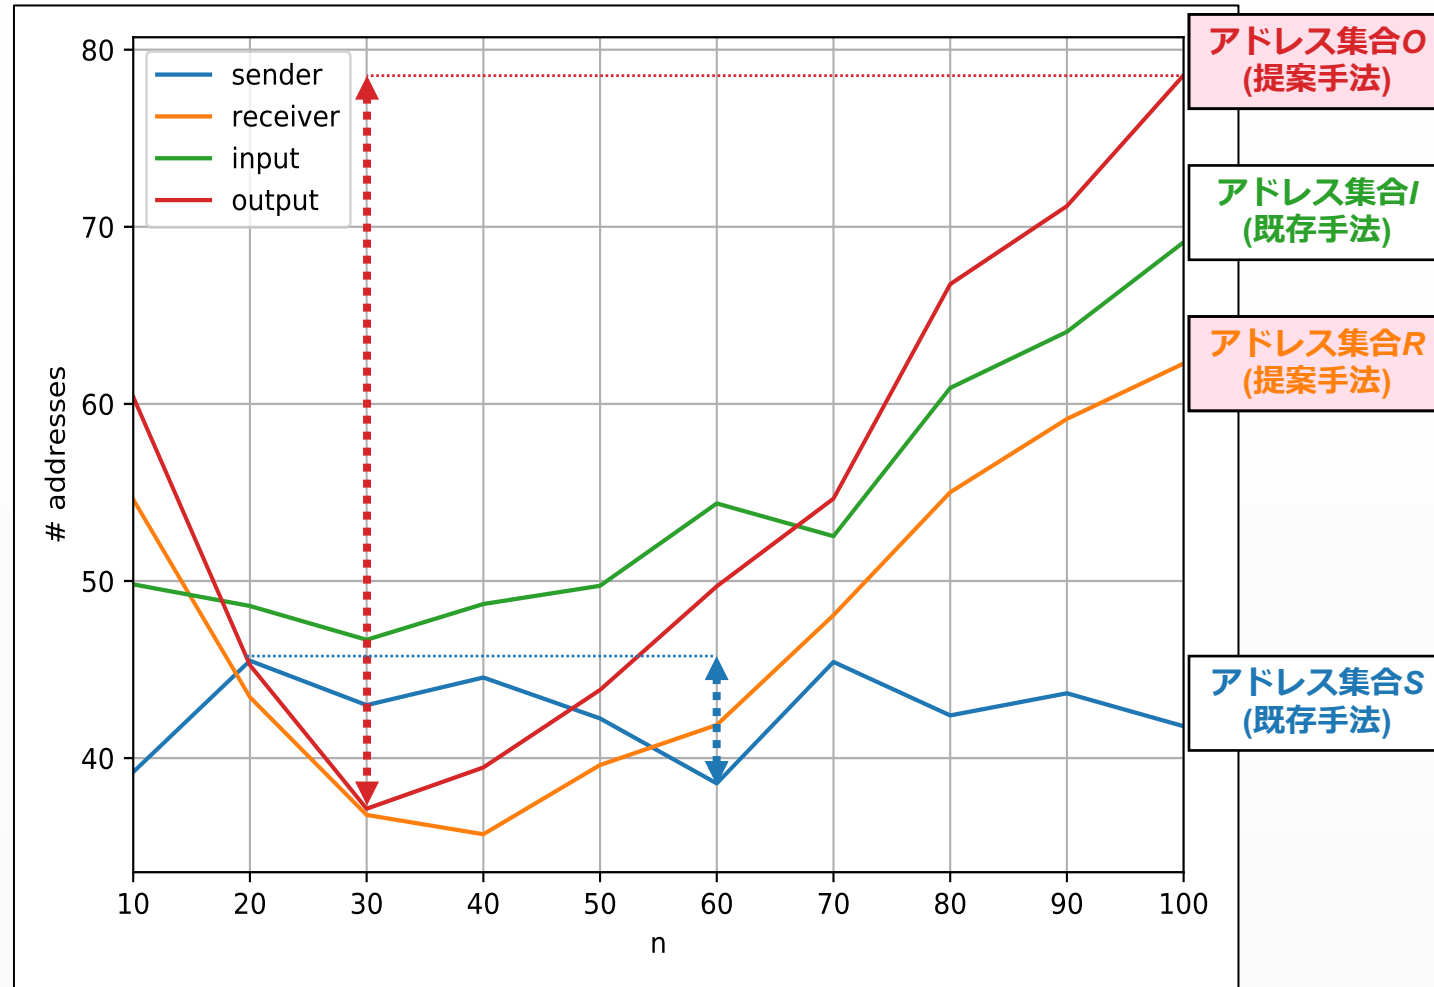


実験1 結果：取引回数と識別率の相関関係

■ 取引回数と識別率の相関関係

- 10段階の取引回数のうち識別率が最も高い回数と低い回数の標準偏差を求めることで評価
- 集合Oは相関関係が最も強い
- 集合Sは相関関係が最も弱い

アドレス集合	標準偏差
S	2.2
R	9.1
I	7.2
O	13.4



実験2 アドレス識別：アドレスの利用目的

■ 長期間のアドレス識別とアドレスの利用目的

- 識別結果に偏り(Bitcointalkアドレス固有の特性)が生じる可能性
- 代表的なアドレスの利用目的・サービス(交換所等)で使用されたアドレスに対してアドレス識別を行う

■ 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	アドレス識別率(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	△
ATM (BitcoinATM)	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	△
Darkweb	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	○

実験2 アドレス識別：5種類のアドレス識別

■ アドレス数

- 2019年4月1日～9月30日の半年間で取引をおこなったアドレスを使用
- 利用方法別にサンプリング
 - » 25個のアドレスを抽出

■ 実験手法

- 前述の実験と同様の方法でアドレス識別実験を実施

利用方法	アドレス数
Bitcointalk BBS	844
Bitcoin ATM	106
Darkweb	49
Exchange	274
Mining Pool	85
合計	1,385

実験2 結果：5種類のアドレス利用方法と識別率

■ 実験結果

□ Darkwebで利用されていたアドレスの識別率が最も高い(平均 0.74)

アドレス 集合	利用方法 [%]					合計
	BBS	ATM	Darkweb	Exchange	Mining Pool	
S	0.43	0.55	0.80	0.14	0.59	75
R	0.57	0.12	0.74	0.49	0.17	63
I	0.59	0.55	0.74	0.42	0.50	84
O	0.65	0.14	0.70	0.75	0.17	72
平均	0.56	0.34	0.74	0.45	0.36	

結論

- 新たなアドレス集合を特徴量としたアドレス識別手法の提案
 - アドレス識別に影響が現れにくい送金元アドレス集合 R , 出カアドレス集合 O の提案

- 4つのアドレス集合を用いたアドレス識別実験を実施
 - 出カアドレス集合 O (提案手法)はアドレス識別率が最も高い(54.7)
 - 4つの集合のうち3つの集合 R, I, O において取引回数と識別率の相関関係が見られた
 - アドレスの利用目的別の識別率ではDarkwebの値が最も高い(0.74)

- 今後の課題
 - アドレスの利用目的を特徴量に含めた識別実験の実施