

マルウェアの通信履歴と 定点観測の相関について

○小堀 智弘、菊池 浩明(東海大)
寺田 真敏(日立製作所)

背景

- ネットワーク上に蔓延するコンピュータウィルスの80%はボットである

<http://www.blackhat.com/presentations/bh-jp-05/bh-jp-05-koyama.pdf>



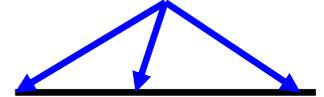
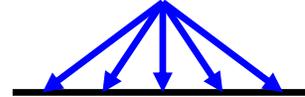
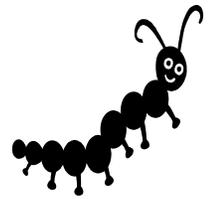
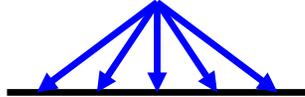
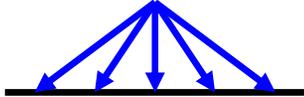
仮説1. ポートスキャンはすべてボットが行っている

ボットとワームの違い

ボット

ワーム

C&C

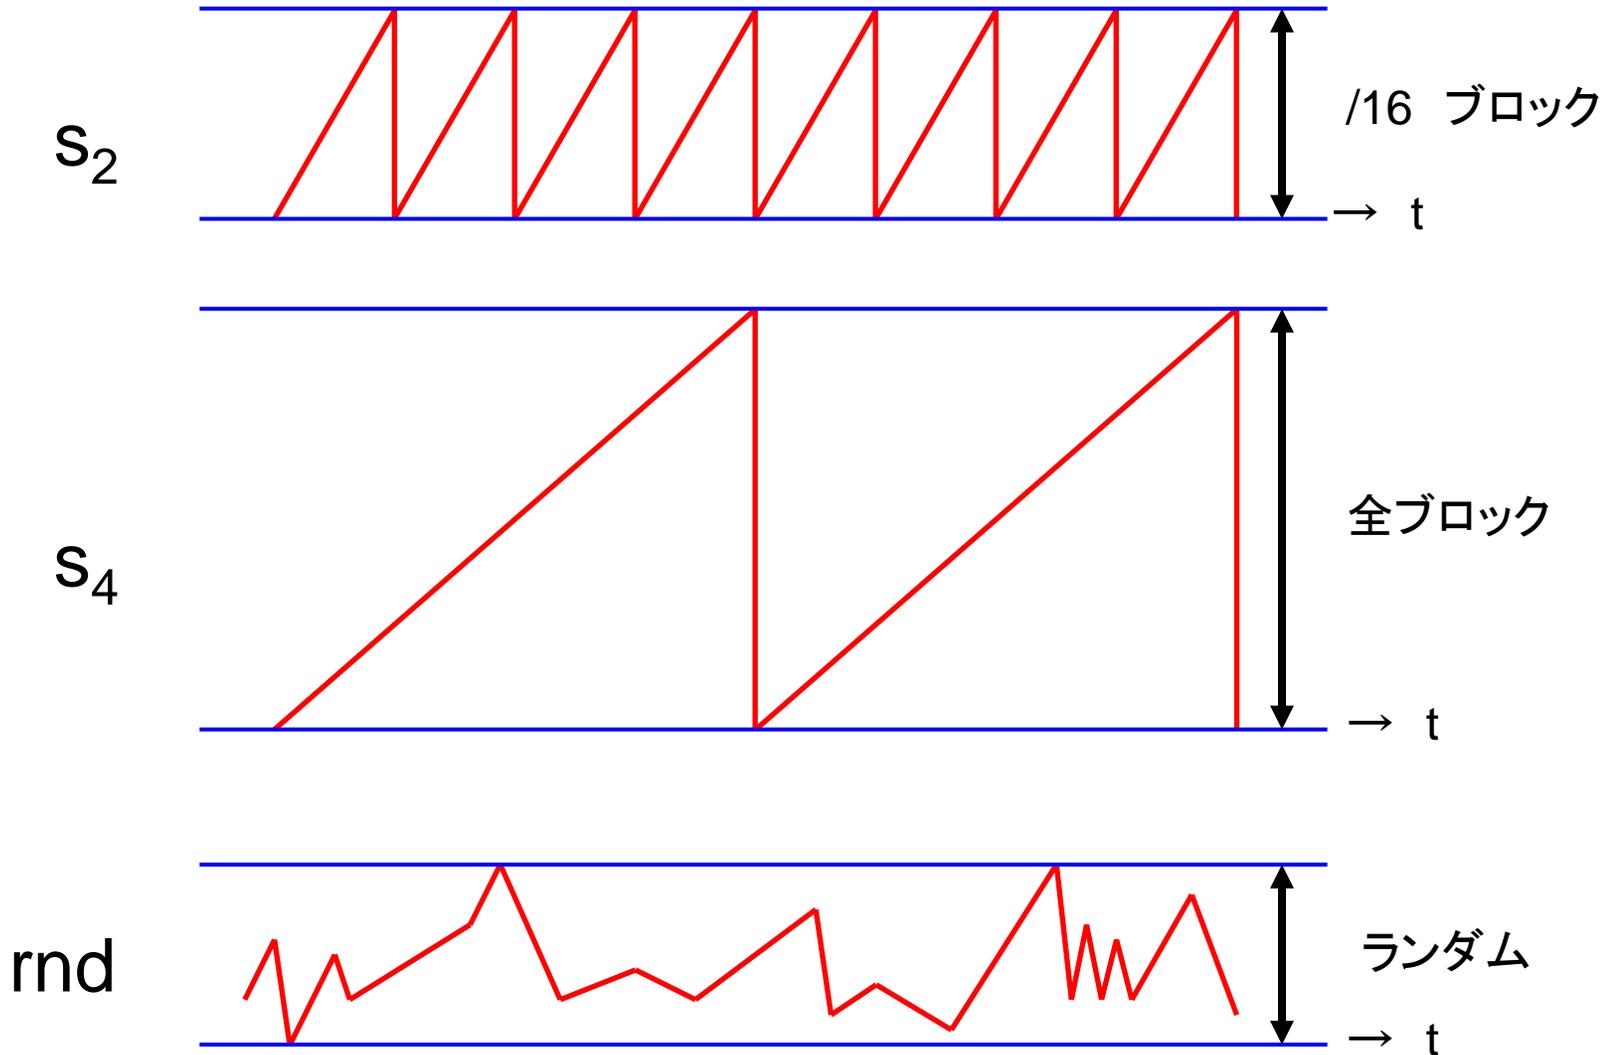


C&Cに依存

ワームによって異なる

仮説2. スキャンパターン \neq MW(依存しない)

スキヤンパターン



研究目的

- 仮説1. ポートスキャンはすべてボット
- 仮説2. スキャンパターン \neq MW

は本当だろうか？

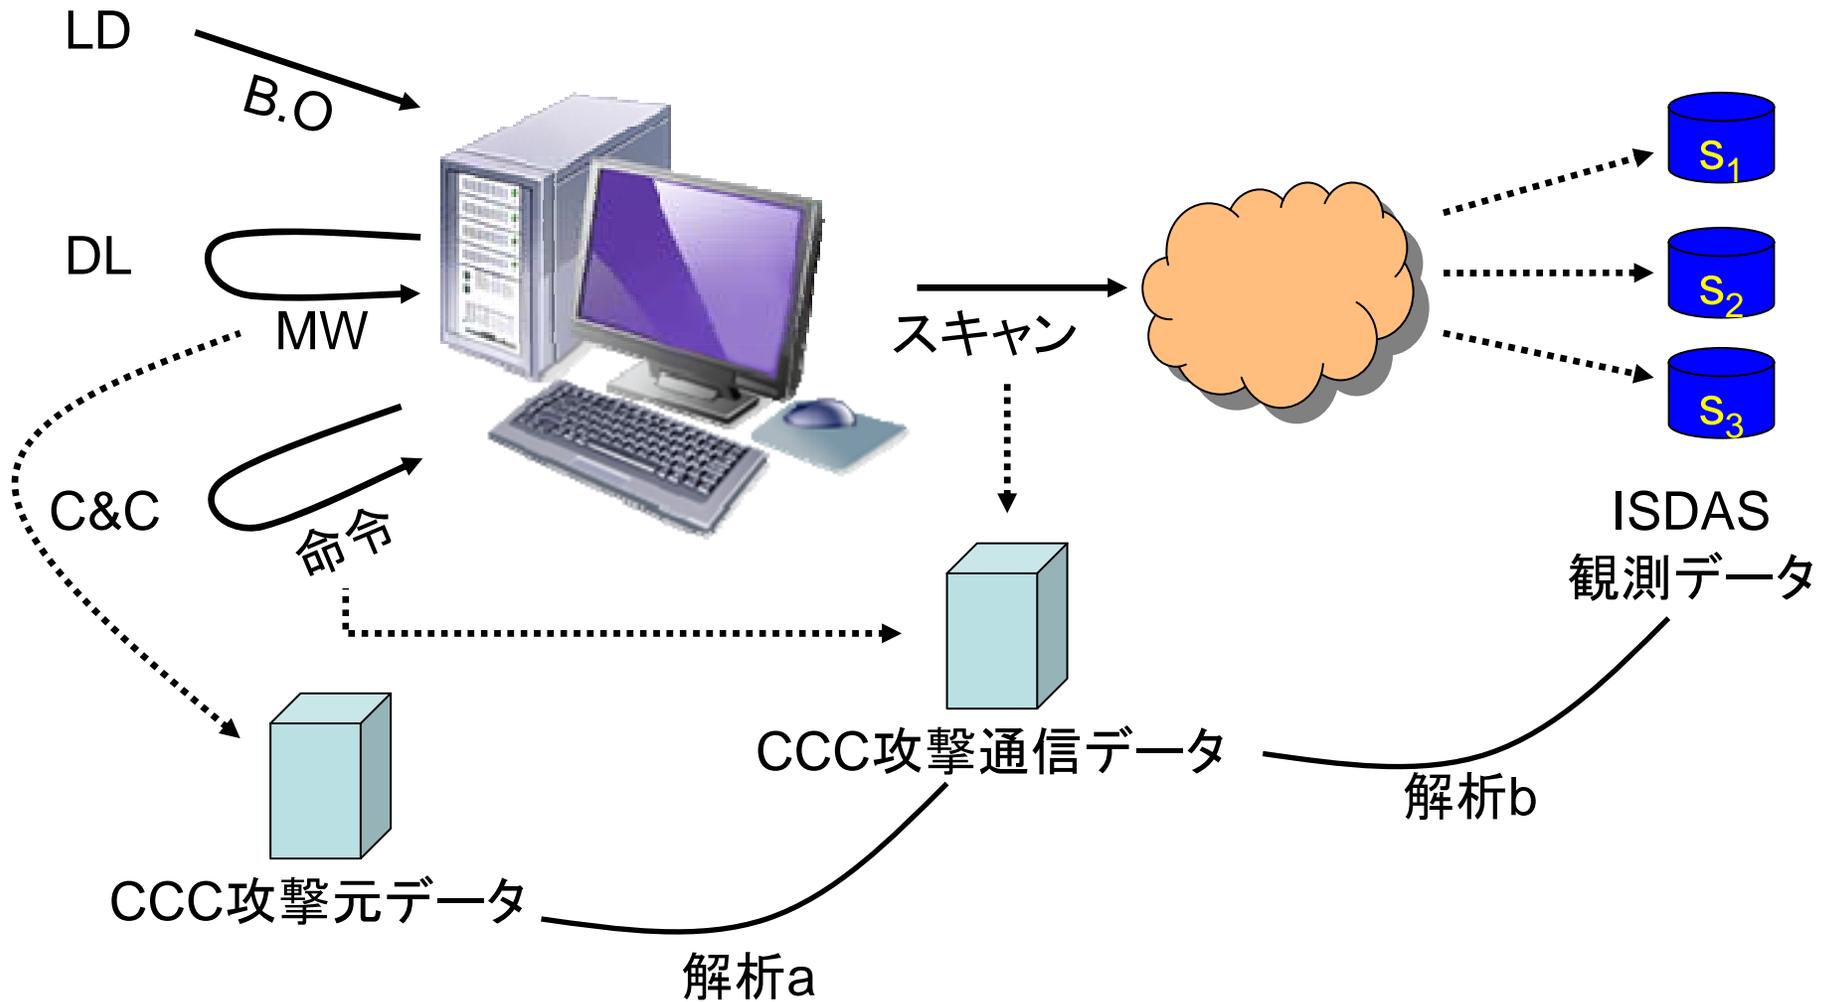
実験的に検証する

研究方法

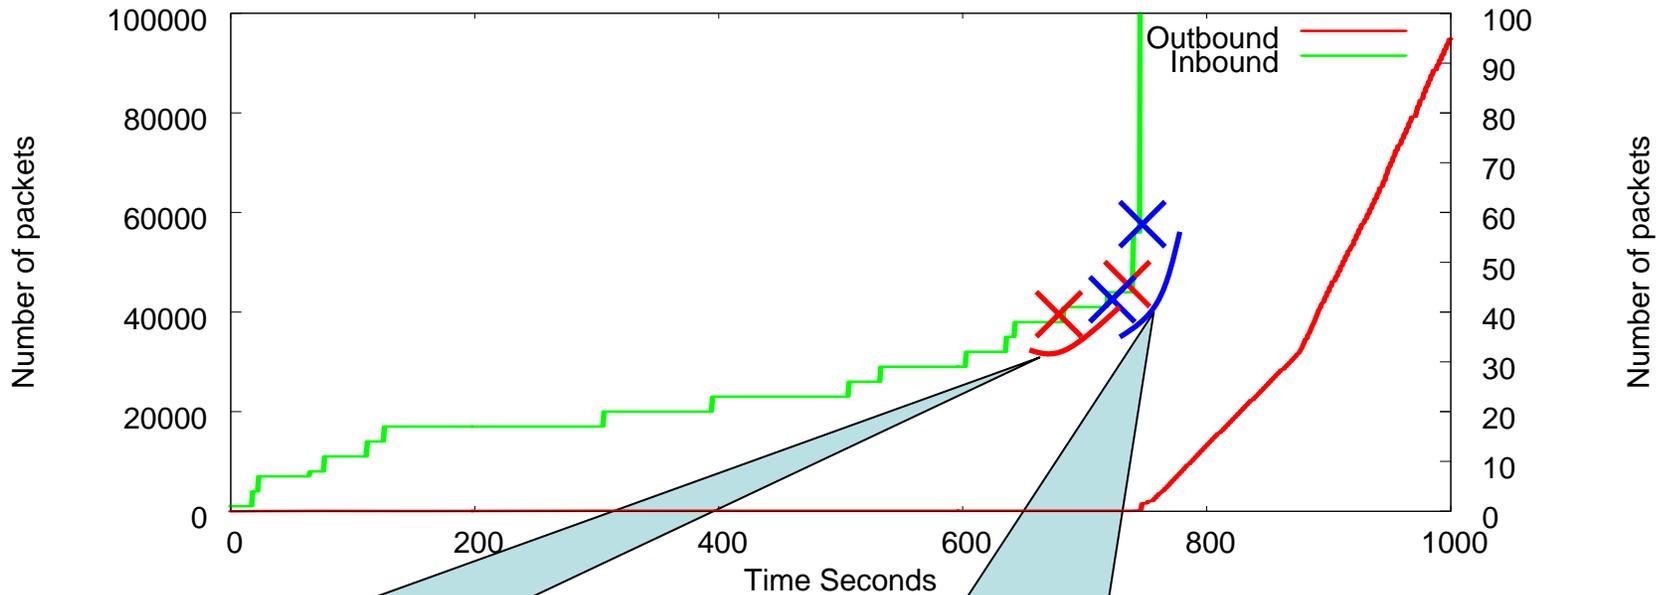
解析 a. CCC攻撃元通信データ(3)と攻撃通信データ(2)の比較

解析 b. 攻撃通信データとISDASの比較

ボットネットのしくみ



実際の通信



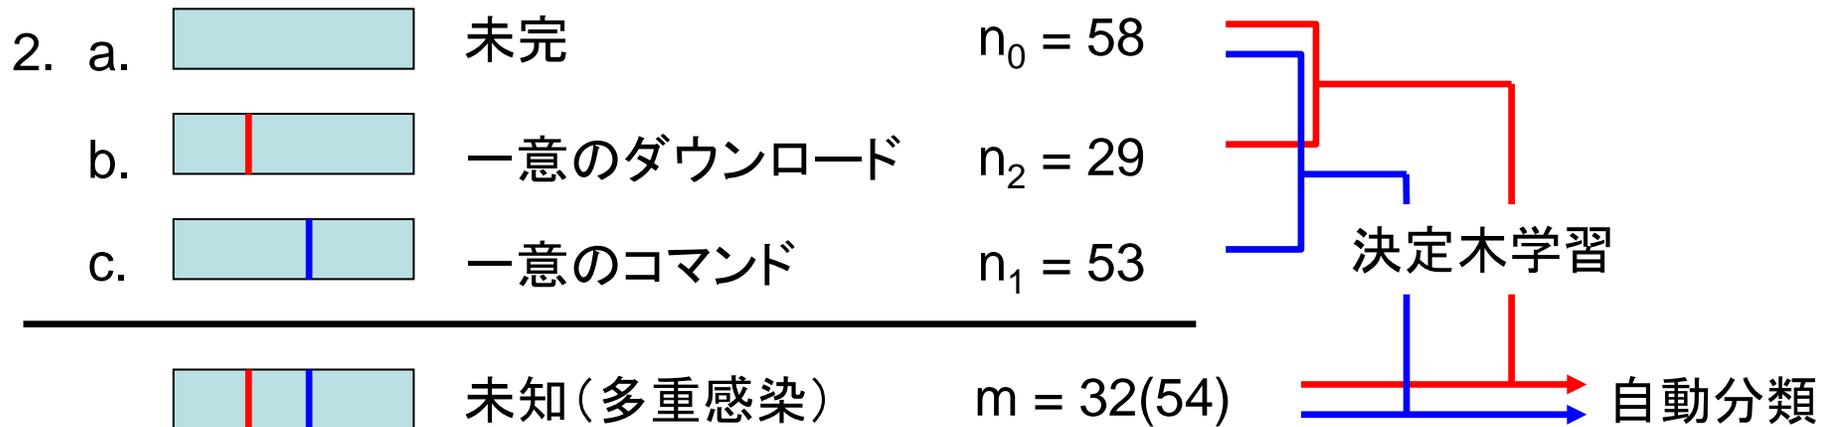
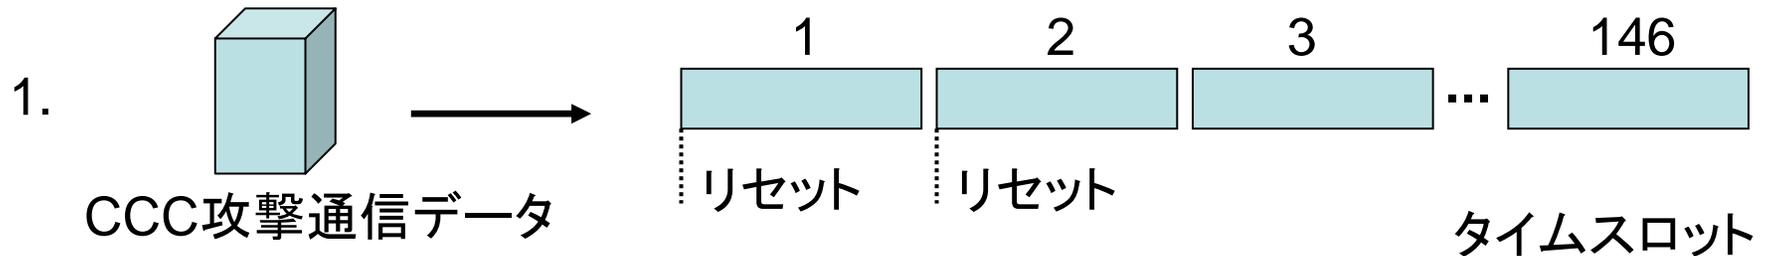
07:18:40 PE_BOBAX.AK
07:18:47 TROJ_PACK.DT

問題1. MWの多重感染(DL)

07:18:46 ipscan s.s.s.s dcom2 -s
07:20:00 ipscan s.s.s.s dcom2 -s

問題2. 多重コマンドとスキャンの一意性

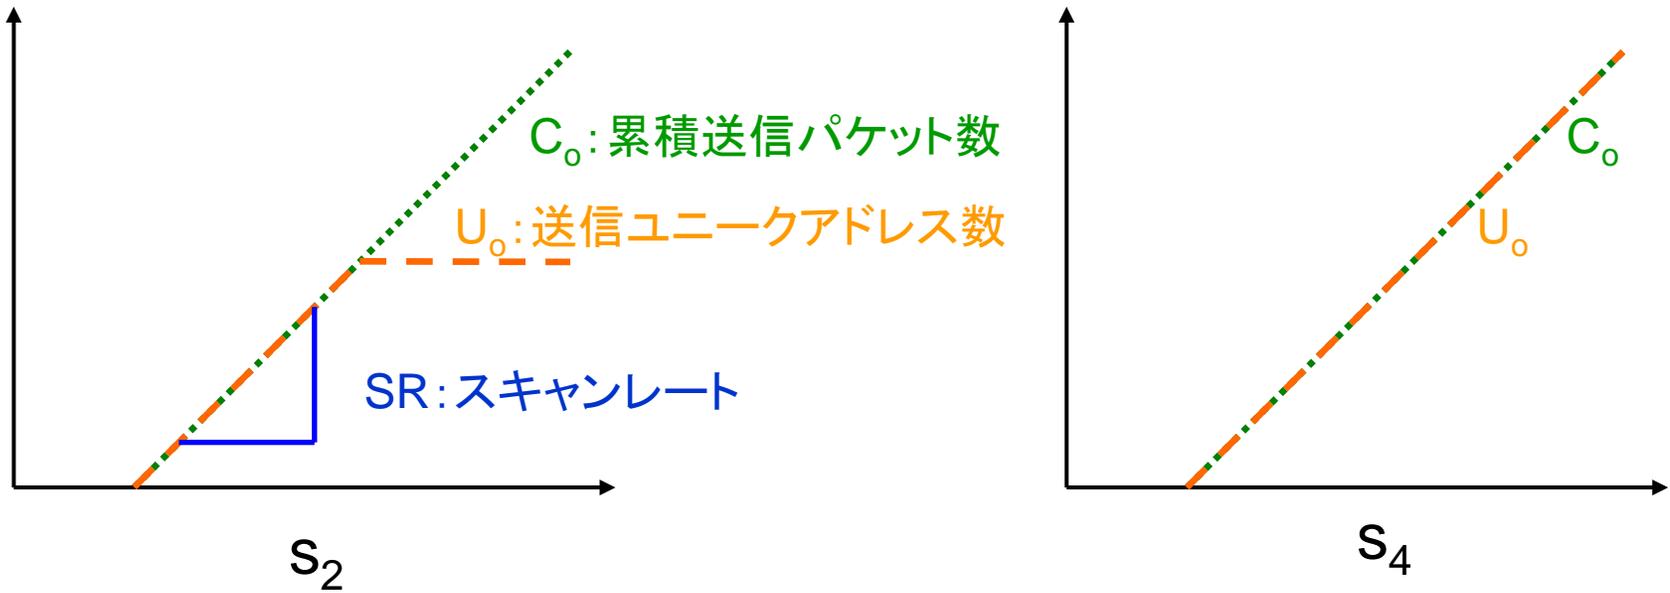
提案方法: 仮説2の検証



決定木

- 機械学習アルゴリズムC4.5
 - 情報量利得に基づいた識別
 - 決定木を作成
 - 連続値に対応

スキャンパターンの特徴量 1/2



スキャンパターンの特徴量

2/2

IN	C_I : 総入力パケット数[pkt] U_I : ユニーク発信元アドレス数 V_{PS} : d_{SP} の標準偏差 MW: マルウェア名 DL: ダウンロードの有無(0,1)	MWを決定
OUT	C_O : 総出力パケット数[pkt] U_O : ユニーク宛先アドレス数 DP: 宛先ポート(135, 445, ICMP) SR: スキャンレート[pkt/s]	スキャンパターンを決定

提案方法：仮説1の検証 ISDASとの比較

- ハニーポットのスキューバで観測しているかを
確認できず

 1. ポートの比率
 2. スキャンレートの比率

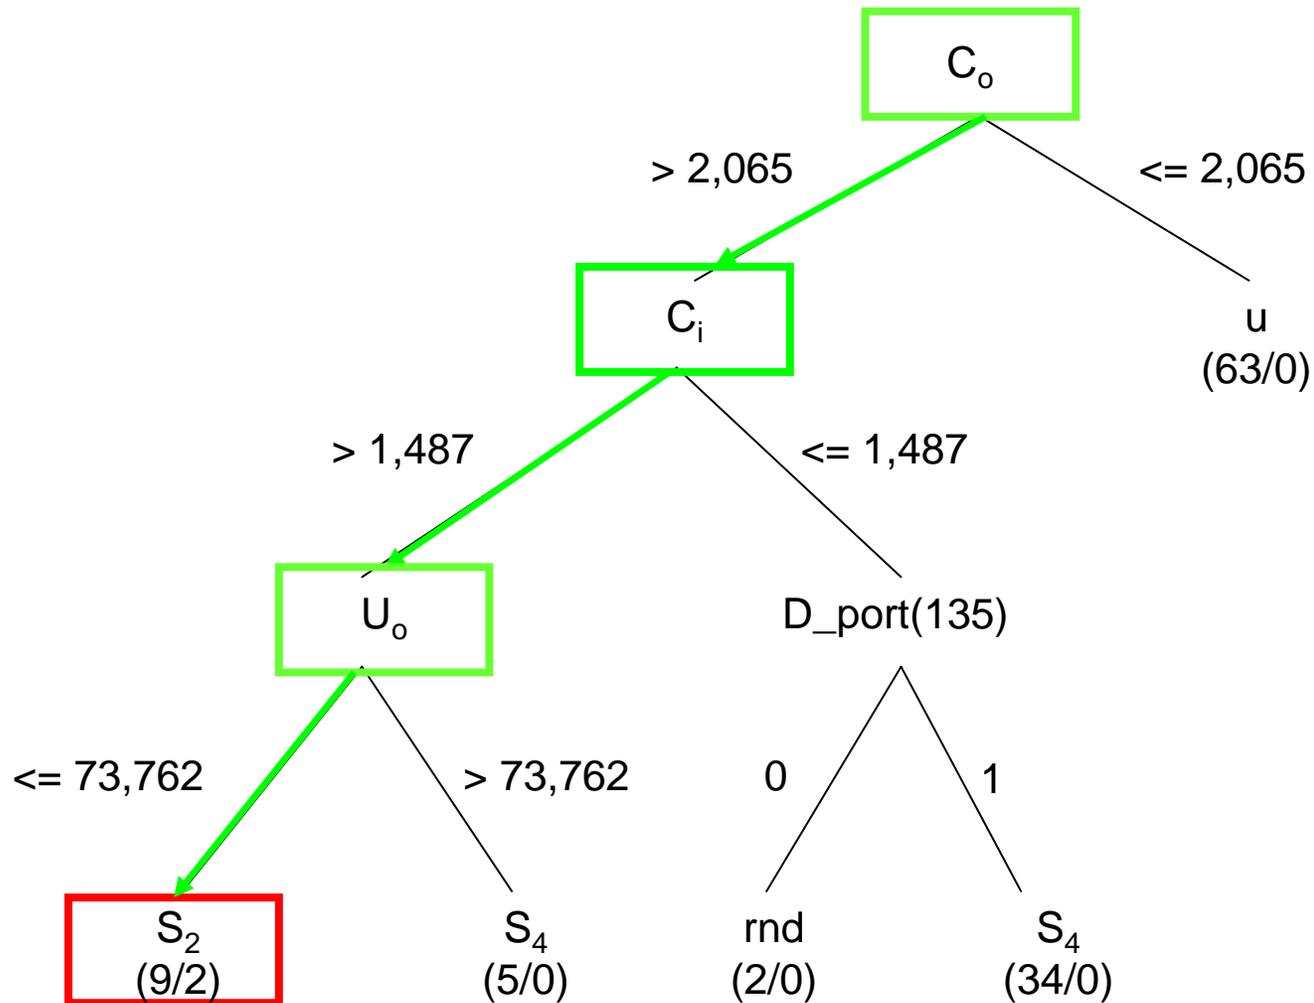
実験方法

実験 1. スキャンパターンの識別

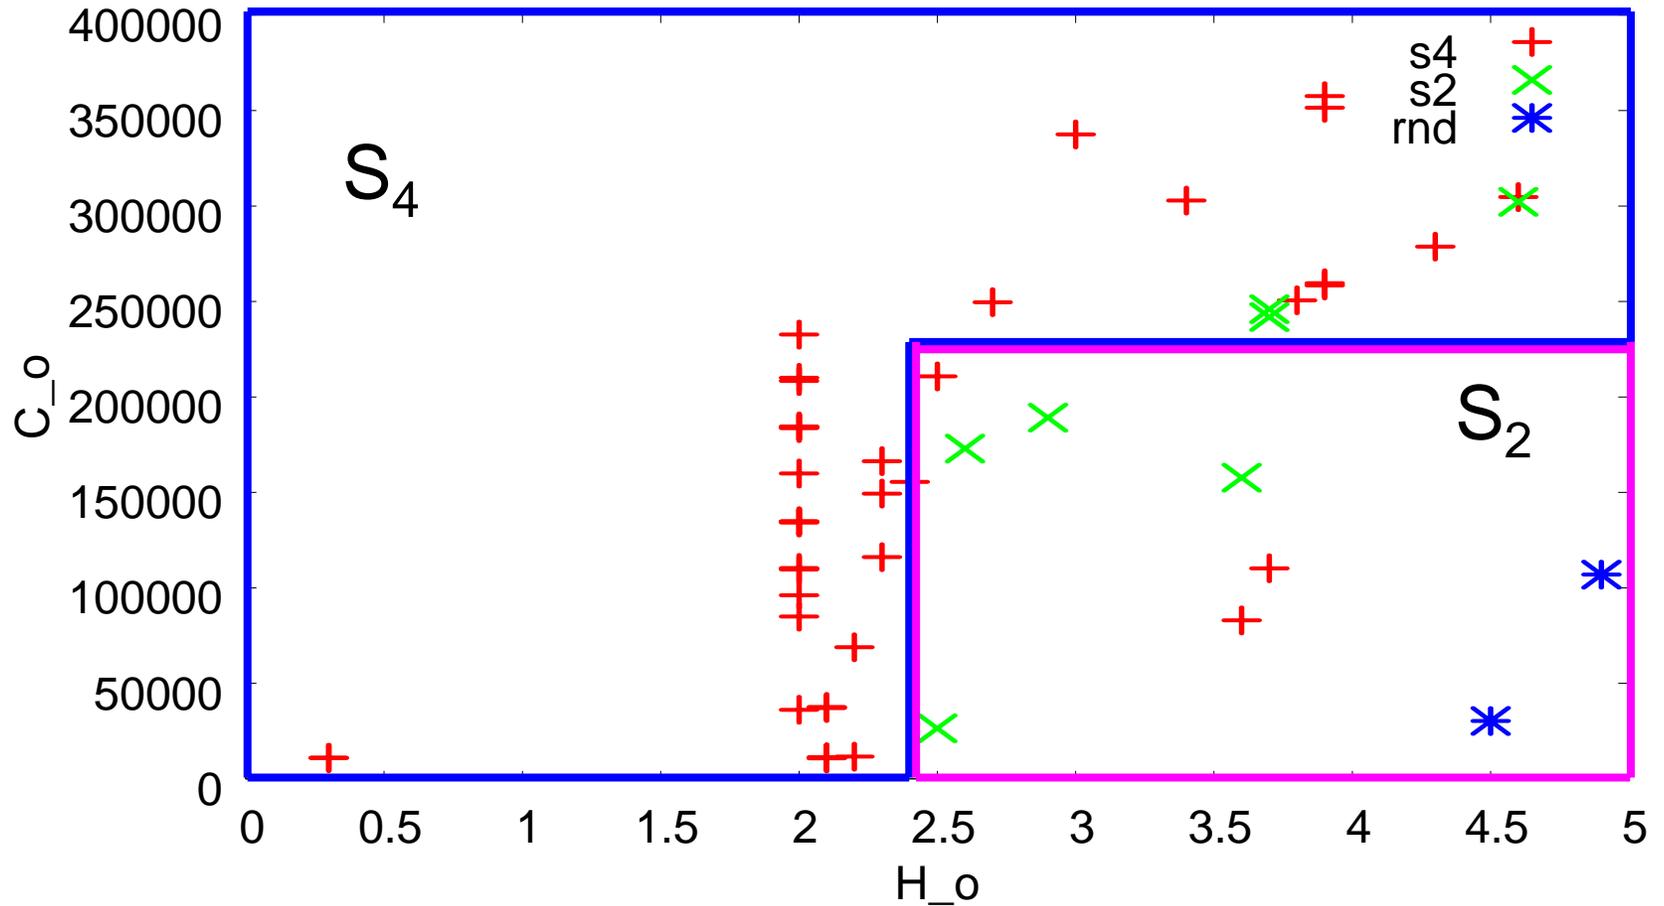
実験 2. MWの識別

実験 3. ISDASとの比較

実験1: C4.5による スキャンパターンの決定木



実験1: スキャンパターンの散布図



実験1: スキャンパターンの 決定木の精度

ST/評価値	rnd	s ₂	s ₄	u	total
未分類 m	2	5	24	1	32
rnd	2				2
s ₂		7		4	11
s ₄		2	38	1	41
u	1			57	58
total	5	14	62	63	144
適合率 P _{ST}	0.67	0.78	1.0	0.92	0.93

- 再現率 0.93、平均適合率 0.94

実験1: マルウェアとスキャンタイプの 相関

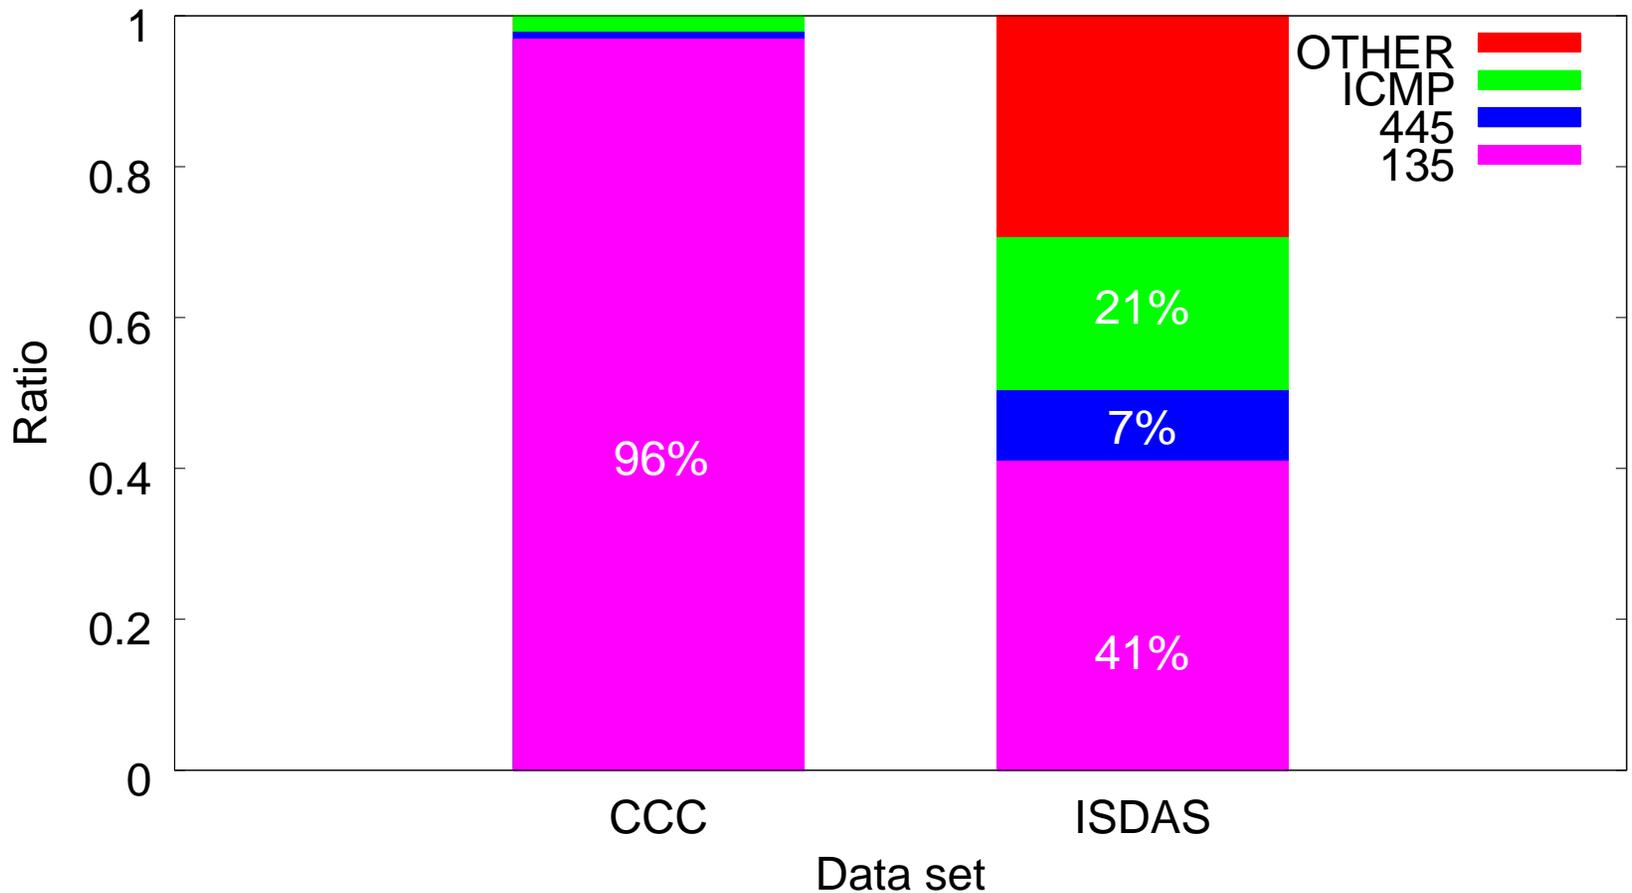
- マルウェアとスキャンタイプ

MW/ST	s_2	s_3	s_4	rnd	total
BOBAX	17	2	28	3	35
KOLABC	7	2	14	5	18
VANBOT	30	4	42	5	58
VIRUT	7	0	20	1	25
OTHER	8	2	20	2	32

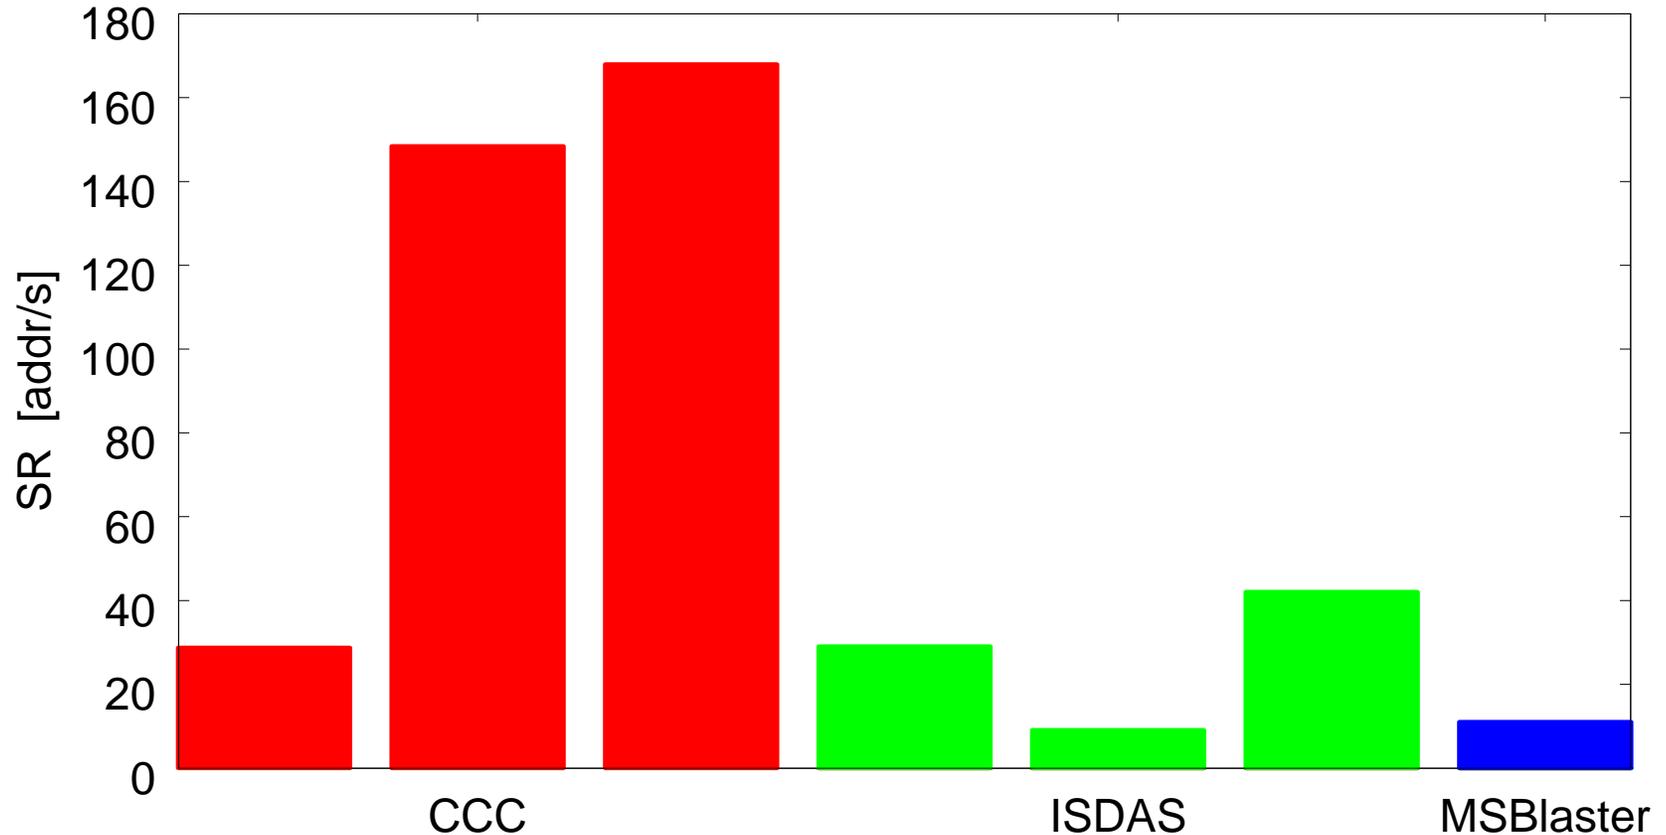
結論: 仮説2成立

実験3: 定点観測との比較

- 宛先ポートの分布の比較



3つの観測データによる スキャンレート SR



結論: 仮説1不成立

まとめ

- 仮説1
「ポートスキャンは全てボットによって行われている」は成立しない
- 仮説2
「ポートスキャンのタイプはマルウェアに依存しない」は成立する
- 決定木学習により、ペイロードを見ることなくスキャンパターンを同定することは可能である

ご清聴ありがとうございました