
数量化理論とCCCDATASET2009を利用したボット ネットのC&Cサーバの特定手法の 提案と評価


東京電機大学大学院
情報セキュリティ研究室

三原 元 佐々木 良一

1. はじめに
2. CCCDATASET2009の解析結果
3. 実験
4. 提案システム概要
5. まとめと今後

1. はじめに
 1. 背景
 2. 多段追跡システム概要
2. CCCDATaset2009の解析結果
3. 実験
4. 提案システム概要
5. まとめと今後


現在問題となっている「ボットネット」




1.1 ボットネットに対する既存対策手法の問題点

代表的な既存対策手法: アンチウイルスソフト

➡ 感染PCの駆除が目的




- ボットネットの問題点
 - ▶ ボットPCのみの対策では解決しない
 - ▶ ハーダー, C&Cサーバ等を対処しなければ無効が困難



➡ ボットネットに対する根本的な解決手法が必要

ネットワーク管理者同士が情報共有を行い、
3つの特定を行う




ボットネットの多段追跡システムを構想




ボットネットの根本的な解決を目指す


1.2 多段追跡システム概要




1.2 多段追跡システム概要




1.2 多段追跡システム概要



1.2 多段追跡システム概要



1.2 多段追跡システム概要




第三段トレースバック

第二段トレースバック

第一段トレースバック

第二段トレースバックシステムの実現のため CCCDATASet2009を解析

解析結果を用いたシステムの特定手法確立 が目的



1. はじめに
2. **CCCDATASET2009の解析結果**
3. 実験
4. まとめと今後


今回著者らはC&Cサーバの「ドメイン情報」に着目

調査対象データ

- ・ボットネットに関するドメイン情報 : ボットネットドメイン
- ・ボットネットに関係しないドメイン情報 : ノーマルドメイン

調査対象項目

- ・既存研究より5項目を選別



各調査項目ごとに2つのデータを比較
ボットネットの特徴を掴む

■ 調査対象データ

▶ ボットネットドメイン

- CCCDATASET2009の通信データ中DNS通信から取得したドメイン
- 個数: 24個

▶ ノーマルドメイン

- 本研究室の通信データ中DNS通信から取得したドメイン
- 個数: 50個

| | |
|-----------|-------------------|
| PC台数 | 20台(OS:WindowsXP) |
| 通信データ取得時間 | 24時間 |
| パケット数 | 約50万パケット |

調査対象項目

逆引き

DNSサーバに対する「IPアドレス→ドメイン名」の問い合わせ調査

SOALレコード

WHOIS

mail.wwwサーバの有無

同ドメイン上にMail,Webサーバが登録されているかの調査

TTL値

DNSサーバの各管理ドメインに設定されるTTL値

参考文献:

「フィールド調査によるボットネットの挙動解析」高橋正和, 村上純一, 須藤年章,
平原伸昭, 佐々木良一, 情報処理学会論文誌, Vol.47, No.8, 2007

「DNS通信の挙動から見たボット感染検知方式の検討」東角芳樹, 鳥居悟
CSS2008

- SOA (Start Of Authority) レコード
 - ▶ 各DNSサーバが管理
 - ▶ ドメインに関する設定情報
 - ▶ SOAレコードの構成
 - ゾーン名
 - ネームサーバホスト名
 - 管理者メールアドレス
 - Refresh値
 - Retry値
 - Expire値
 - Minimum値

■ SOALレコード

- ゾーン名
- ネームサーバホスト名
- 管理者メールアドレス
- Refresh値
- Retry値
- Expire値

■ Minimum値 (ネガティブTTL値)

 Minimum値を調査対象とした

■ WHOIS情報

- ▶ JPNIC等のレジストリが管理
- ▶ 各ドメインに関する管理者情報
- ▶ WHOIS情報の主な構成
 - 登録ドメイン名
 - レジストラ名
 - ドメインが登録されているDNSサーバ名
 - ドメイン登録者の名前・住所
 - ドメインの登録年月日
 - ドメインの登録有効期限

■ WHOIS情報

- ▶ 登録ドメイン名
- ▶ レジストラ名
- ▶ ドメインが登録されているDNSサーバ名
- ▶ ドメイン登録者の名前・住所
- ▶ **ドメインの登録年月日**
- ▶ **ドメインの登録有効期限**

 上記2つの他, 2つのデータから判明する「ドメイン登録期間」の3つを調査

- 調査結果
 - ▶ 逆引き
 - ▶ SOAレコード
 - ▶ WHOIS
 - ▶ mail. wwwサーバの有無
 - ▶ TTL値

逆引きの調査結果


| | ノーマルドメイン | ボットネットドメイン |
|-------------|------------------|------------------|
| 逆引き結果が正しい | 9個 (18%) | 2個 (8%) |
| 逆引き結果が正しくない | 34個 (68%) | 5個 (21%) |
| 返答なし | 7個 (14%) | 17個 (71%) |
| 合計 | 50個 (100%) | 24個 (100%) |

2つのデータに明らかな差がみられた

- 調査対象項目
 - ▶ 逆引き
 - ▶ Minimum値 (SOAレコード)
 - ▶ WHOIS
 - ▶ mail. wwwサーバの有無
 - ▶ TTL値

2. Minimum値 (SOALレコード) の調査結果


Minimum値の調査結果グラフ



ボットネットドメイン： 特徴は見られなかった
ノーマルドメイン： 特徴が見つかった

- 調査対象項目
 - ▶ 逆引き
 - ▶ SOALレコード
 - ▶ WHOIS
 - ドメイン登録年月日
 - ドメイン登録終了年月日
 - ドメイン登録期間
 - ▶ mail. wwwサーバの有無
 - ▶ TTL値

ドメイン登録期間の調査結果グラフ



ボットネットドメインの登録期間が比較的短い

- 調査対象項目
 - ▶ 逆引き
 - ▶ SOALレコード
 - ▶ WHOIS
 - ▶ mail. wwwサーバの有無
 - ▶ TTL値

2. mail. wwwサーバの有無


| | ノーマルドメイン | ボットネットドメイン |
|-----------|------------|------------|
| Mailサーバ有 | 36個 (72%) | 14個 (59%) |
| Mailサーバ無し | 10個 (20%) | 3個 (12%) |
| 返答なし | 4個 (8%) | 7個 (29%) |
| 合計 | 50個 (100%) | 24個 (100%) |

| | ノーマルドメイン | ボットネットドメイン |
|----------|------------|------------|
| ウェブサーバ有 | 45個 (90%) | 13個 (54%) |
| ウェブサーバ無し | 2個 (4%) | 4個 (16%) |
| 返答なし | 3個 (6%) | 7個 (30%) |
| 合計 | 50個 (100%) | 24個 (100%) |

2つのデータに特長は見られなかった

- 調査対象項目
 - ▶ 逆引き
 - ▶ SOAレコード
 - ▶ WHOIS
 - ▶ mail. wwwサーバの有無
 - ▶ TTL値

TTL値の調査結果グラフ



ノーマルドメインのTTL値が特定の値に集中しているという傾向が見つかった

調査結果をまとめると


- 逆引き
- Minimum値(SOALレコード)
- ドメイン登録期間(WHOIS)
- mail.wwwサーバの有無
- TTL値



C&Cサーバ等の特定が可能となるような特徴的データは得られなかった

調査結果をまとめると


- 逆引き
- Minimum値(SOALレコード)
- ドメイン登録期間(WHOIS)
- mail.wwwサーバの有無
- TTL値



C&Cサーバ等の特定が可能となるような特徴的データは得られなかった

 **そこで...**

調査結果データを入力データとし、数式処理を試行する



数式処理によりC&Cサーバ等の判別が可能か実験
実験では、数式処理に数量化理論2類を使用


2. 数量理論2類とは

各対象に対し、パラメータにより求められる判別式、判別値を境界値と比較し、2つのグループに分ける

例：喫煙者と非喫煙者の判別

- タイプA: 喫煙者
- タイプB: 非喫煙者

| | | | | |
|-------|--|---|--|--------|
| 判別式: | (年齢) | + | (飲酒歴) | =「判別値」 |
| パラメータ | $\begin{pmatrix} 20\text{才以上: }1 \\ 20\text{才未満: }0 \end{pmatrix}$ | | $\begin{pmatrix} \text{ある: }1 \\ \text{ない: }0 \end{pmatrix}$ | |




タイプBの可能性が高い

2. 数量化理論2類の使用に必要なデータ

36

喫煙者の判別には喫煙者のデータが必要

| | | | |
|-------|--|---|--|
| 判別式: | (年齢) | + | (飲酒歴), 「境界値」 |
| パラメータ | $\begin{pmatrix} 20才以上:1 \\ 20才未満:0 \end{pmatrix}$ | | $\begin{pmatrix} ある:1 \\ ない:0 \end{pmatrix}$ |



C&Cサーバ等の判別にもC&Cサー等のデータが必要

例

| | | | |
|-------|--|---|--|
| 判別式: | (TTL値) | + | (逆引き結果), 「境界値」 |
| パラメータ | $\begin{pmatrix} 900以上:1 \\ 900未満:0 \end{pmatrix}$ | | $\begin{pmatrix} 返答有:1 \\ 返答無:0 \end{pmatrix}$ |

- パラメータに5つの調査結果を使用
- 実験により, 調査結果データ用いた最適パラメータを選択

1. はじめに
2. CCCDATASET2009の解析結果
3. **実験**
4. システム概要
5. まとめと今後

3. 7つのパラメータ(5つの調査結果)

調査結果5項目を以下のように数量化理論2類のパラメータとして設定

| ドメイン登録期間 | 設定値 |
|---------------|-----|
| 1-2500 (日) | 1 |
| 2501-5000 (日) | 2 |
| 5001-8000 (日) | 3 |
| NA | 4 |

| ドメイン登録終了 年月日 | 設定値 |
|-----------------|-----|
| -2010.09.13 | 1 |
| 2010.09.14- | 2 |
| NA | 3 |

| 逆引き | 設定値 |
|----------|-----|
| 返答無し | 1 |
| 返答が正しくない | 2 |
| 返答が正しい | 3 |

| TTL値 | 設定値 |
|----------------|-----|
| 1-1000 | 1 |
| 1001-100000 | 2 |
| 100001-1000000 | 3 |
| NA | 4 |

| Minimum値 | 設定値 |
|-------------|-----|
| 1-100 | 1 |
| 101-1000 | 2 |
| 1001-100000 | 3 |
| NA | 4 |

| Mailサーバ | 設定値 |
|---------|-----|
| あり | 1 |
| なし | 2 |

| ウェブサーバ | 設定値 |
|--------|-----|
| あり | 1 |
| なし | 2 |

パラメータ設定実験

目的

7つのパラメータを数量化理論2類に適応
最も検知精度の高いパラメータの最小の組合わせを決定

検証実験

目的

パラメータ設定実験で決定したパラメータ使用
設定実験と別のドメインデータ入力し, 判別式と境界値の
検知精度を検証

パラメータ設定実験

ボットネットに関するドメイン

➡ CCCDATASet2009より**10**個

ボットネットに無関係のドメイン

➡ 本研修室の通信データより**20**個

検証実験

ボットネットに関するドメイン


➡ CCCDATASet2009より**10**個

ボットネットに無関係のドメイン

➡ 本研修室の通信データより**20**個

3. 実験結果


- 最適なパラメータの組み合わせを選択した
 - ▶ ドメイン登録期間 (WHOIS)
 - ▶ 逆引き




検知数の累積グラフ

3. 実験結果

単独でのC&Cサーバ等特定には信頼性が低い



単独でのC&Cサーバ等特定には信頼性が低い



➔ ブラックリスト方式と併用
特定精度の向上を狙う

ブラックリスト方式：概要

C&Cサーバ等ボットネットに関するホストのドメイン名を取得
通信データ中ホストのドメイン名と照合し検知を行う

ブラックリスト方式：検証

検証対象ドメイン

CCCDATASet2009の攻撃通信データから取得した
ドメイン24個

ブラックリスト取得サイト(2009年6月20日取得)

SRI Malware Threat Center

<http://www.mtc.sri.com/>

DNS-BH

<http://www.malwaredomains.com/>

ブラックリスト方式：検証結果

ブラックリストドメインとの一致数

| | 一致 | 不一致 | 合計 |
|----------|---------|--------|----------|
| ドメイン数(%) | 20(80%) | 4(20%) | 24(100%) |

数量化理論2類を用いた検知方式での誤検知ドメイン

zonetech.info, www.getmyip.org

ブラックリスト方式での誤検知ドメイン

ftp.newaol.com, ftp.scarlet.be, ftp.icq.com


www.if.ee,

ブラックリスト方式と数量化理論2類を用いた方式の併用で
全てのドメインを検知することができた

1. はじめに
2. CCCDATASET2009の解析結果
3. 実験
- 4. 提案システム概要**
5. まとめと今後


4. 第二段トレースバックシステム構成

47




- ・ IPアドレス, ドメイン名が記載されたリスト4種
 - ・ 通信データを記録するデータベース2種
- 計6種で構成

4. 第二段トレースバックシステム フロー



4. 第二段トレースバックシステム フロー


① 通信データ取得



4. 第二段トレースバックシステム構成

50


1. ネットワークを通過する通信データを取得
通信先IPアドレス, DNS通信中のドメイン名を抽出



通信データの取得方法

ルータからのポートミラーリング等によりコピーされた通信データを使用


4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成

2. 取得したIPアドレスとホワイトリストを照合

- 一致する 安全な通信であるとみなす
- 一致しない 次の処理に移行



4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成

54

3. 取得したIPアドレスとBot-BLを照合


- 一致する 通信データをB-DATAに記録・管理者通達
- 一致しない 次の処理に移行



Bot-BL

第二段トレースバックシステムがC&Cサーバ/DLであると判別したIPアドレスリスト

4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成

56

4. 取得したIPアドレスとBot-GLを照合


- 一致する 通信をB-DATAに記録・管理者通達
- 一致しない 次の処理に移行



Bot-GL

第二段トレースバックシステムが疑わしいと判別した
ホストのIPアドレスリスト

4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成

58

5. ボットリストを用いたブラックリスト検知処理


- 検知 通信をB-DATAに記録/IPをBot-GLに記録/ 管理者通達
- 無検知 次の処理に移行



ブラックリスト

インターネット上から取得したボットネットに関するドメインのリスト

4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成


60

6. 数量化理論2類を用いた検知処理

- 検知 IPアドレスをBot-GLに登録/ 管理者通達
通信データをB-DATAに記録
- 無検知 次の処理に移行



4. 第二段トレースバックシステム フロー




4. 第二段トレースバックシステム構成


62

7. 全ての通信データの記録

H-DATAに全ての通信記録を一定時間記録
第一段からの攻撃連絡時に対応




4. 第二段トレースバックシステム フロー



第三段トレースバックとの連携①

Bot-BLに登録されたホスト処理



- ・NW管理者βはNW管理者αに強い警告を行う
- ・NW管理者βは自NW内のBot-BLと通信したホストの調査を行う

第三段トレースバックとの連携②

Bot-GLに登録されたホスト処理



NW管理者αからの確認の返答

- ・該当ホストは正常(誤検知)
➡ 該当するホストをBot-GLから削除
- ・該当ホストはC&Cサーバ/DLである
➡ 該当するホストをBot-BLに登録
➡ 該当ホストと通信を行った自NW内ホストの調査

第一段トレースバックとの連携


攻撃ホスト連絡時の処理



- ・NW管理者γから攻撃の通達を受けたNW管理者βは通達を受けた時点で調査を行う

➡ B-DATA及びH-DATAの通信記録にて対応

4. 多段追跡システム概要



1. はじめに
2. CCCDATASET2009の解析結果
3. 実験
4. 提案システム概要
5. まとめと今後

■ まとめ

- ▶ 多段追跡システムの, 第二段トレースバックシステムを提案
- ▶ 数量化理論2類に用いる最適なパラメータの選定, その有用性を確認

■ 今後

- ▶ 第二段トレースバックシステムの実装と評価
- ▶ 数量化理論2類以外の方法を用いた結果の比較

御清聴ありがとうございました