



ANTI MALWARE ENGINEERING WORKSHOP

MWS



MWS 2021 ポストミーティング

MWSをやってて博士とったら NISTで研究までやってきた話

畑田 充弘

NTT Com-SIRT

- NIST Guest Researcher (2019.3 – 2021.9)
 - Computer Security Division, Information Technology Laboratory
 - ボットネットによる攻撃の予兆検知(NIST TN 2111)、NVD Analysis
- NTTコム (2003.4 – 2018.5、2021.12 -)、日本電信電話 (2018.6 – 2021.11)
 - サイバーセキュリティの研究開発、人材育成、NTT Com-SIRT立ち上げ、Team V、国際イベントでのThreat Hunting、team enu
- 博士(工学) (2018.2)、早稲田大学招聘研究員 (2018.12 – 現在)
- ICT-ISAC Japan国内外連携WG/情報共有WGメンバ、CSDE Steering Committee
- IEICE ICSS研究会専門委員、IPSJ CSEC研究会専門委員、MWS組織委員/実行委員
- NTT Group Certified Security Principal、CISSP、RISS

アジェンダ

1. MWSのはじまり
2. 博士課程へ
3. NISTへ
4. ふりかえり

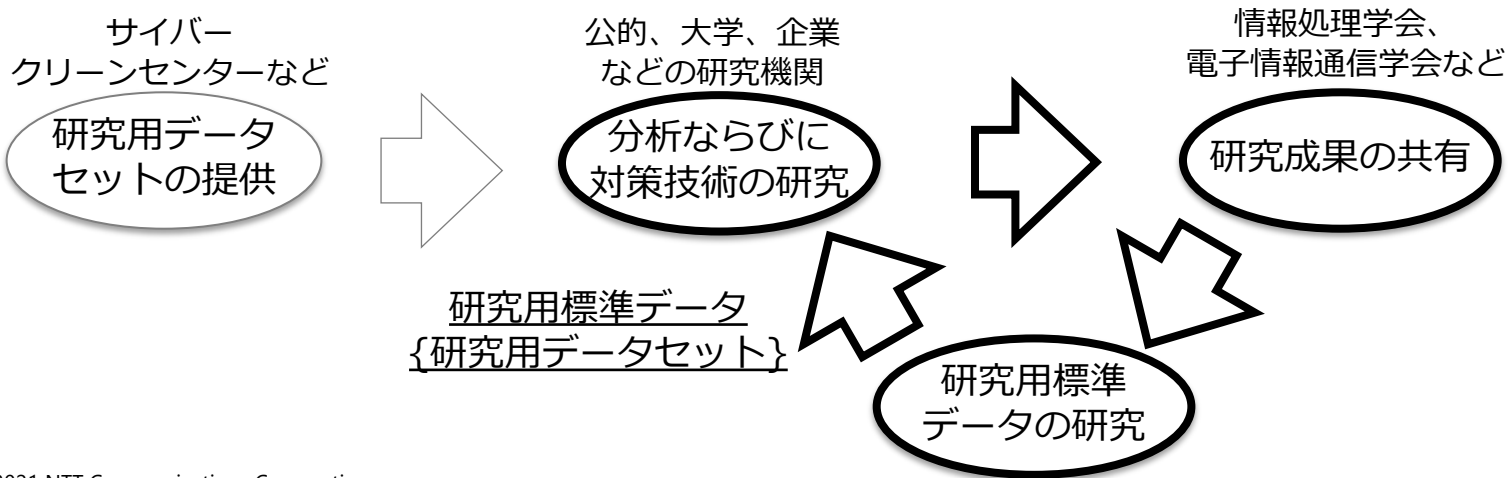
1. MWSのはじまり

仕組み作るか？



マルウェア対策研究人材育成ワークショップ（2008～）

- マルウェアの機能や運用の高度化、インシデントの把握が困難
- 先端研究者に限らず、CSIRT等の実務者もマルウェアに関する知識が必要
- 教材となる共通のデータセットがない、研究用データの収集が困難



Cyber Clean Center

Cyber Clean Center サイバークリーンセンター

サイバークリーンセンター活動実績



注意喚起活動実績

◀ 前月までの注意喚起活動実績 ▶

2007年5月度の注意喚起活動実績

2007/04/21修正版

1 収集検体総数

当月: 557,893体 累計: 2,110,154体
 『おとりマシン』に対する検体の収集の中から収集した、
 ボットウイルス等の検体数(バイナリファイル)

2 同定検体数

当月: 14,176体 累計: 58,083体
 同じ検体が多数収集されるため、検体のサイズや
 外部的特徴の重なりを基に一括検体数(バイナリファイル)

3 未知検体数

当月: 960体 累計: 3,840体
 同定した検体を参照したウイルス対策ソフトで検出さ
 れなかった検体数

4 注意喚起数

メール通知
 当月: 22,674通 累計: 54,209通
 対象者数
 当月: 9,661人 (内総数 6,054人)
 累計: 18,864人
 参加IPから感染者に送った
 注意喚起メール数及び人数

5 被注意喚起者駆除ツールダウンロード率

29% (累計)



6 駆除ツール作成検体数

当月: 1,073体 累計: 3,032体
 危険度が高く、感染者の多い
 検体について駆除ツールを
 作成した検体数

7 駆除ツール

累計更新回数: 18回
 駆除ツールは毎週更新

一般公開サイト駆除ツールダウンロード総数

当月: 21,928回 累計: 109,486回


※同時刻等に複数回ダウンロードされたものは数回した数字

ボットウイルス等の収集状況

- ・おとりマシン (ハニーポット) によって収集したボットウイルス等の検体を1日分を収集し終了後、
 専用のウイルス対策ソフトにて、まとめてスキャンを実施し、検出検体 (Detectable)、不可検体
 (Undetectable)を分類している。
- ・ウイルス対策ソフトで検出されないボットウイルスに関しては、バイナリのハッシュ値が同じもののみ
 を同種として扱う。

1 ウイルス対策ソフトで検出等、不明のボットウイルス等の検体数変動の推移

■ 収集検体数の推移




【調査対象期間: 2007/03/01~2007/05/31】

収集検体数は3月以降急激に増加傾向にある。またウイルス対策ソフト
 も増加傾向にある。

また増減の周期は1週間であり、毎週末に増加し、平日に減少している。2
 月が週末に多く利用される(=ネットワークに接続している) からのではな

■ 収集検体数の推移




【調査対象期間: 2007/03/01~2007/05/31】

収集検体総数の推移は、収集検体数の推移に比べるとその割合は小さい
 。

ウイルス対策ソフトで検出できない検体 (赤で示す) については、全体と

2 検出ボットウイルス等の分析

■ 検体種類別比率




※収集数上位20位までと
 それ以下 (other) に関する集計

【調査対象期間: 2007/05/01~2007/05/31】

ウイルス対策ソフトにて検出可能なボットウイルス等についての内容に上記の通り、ファイル感染
 型 (PE-) が上位5種のうち3種を占めている。ファイル感染型は一般的に発見が難しく、また検出しても
 駆除が困難という特徴がある。


■ 上位5種類の動向観測



【調査対象期間: 2007/05/01~2007/05/31】

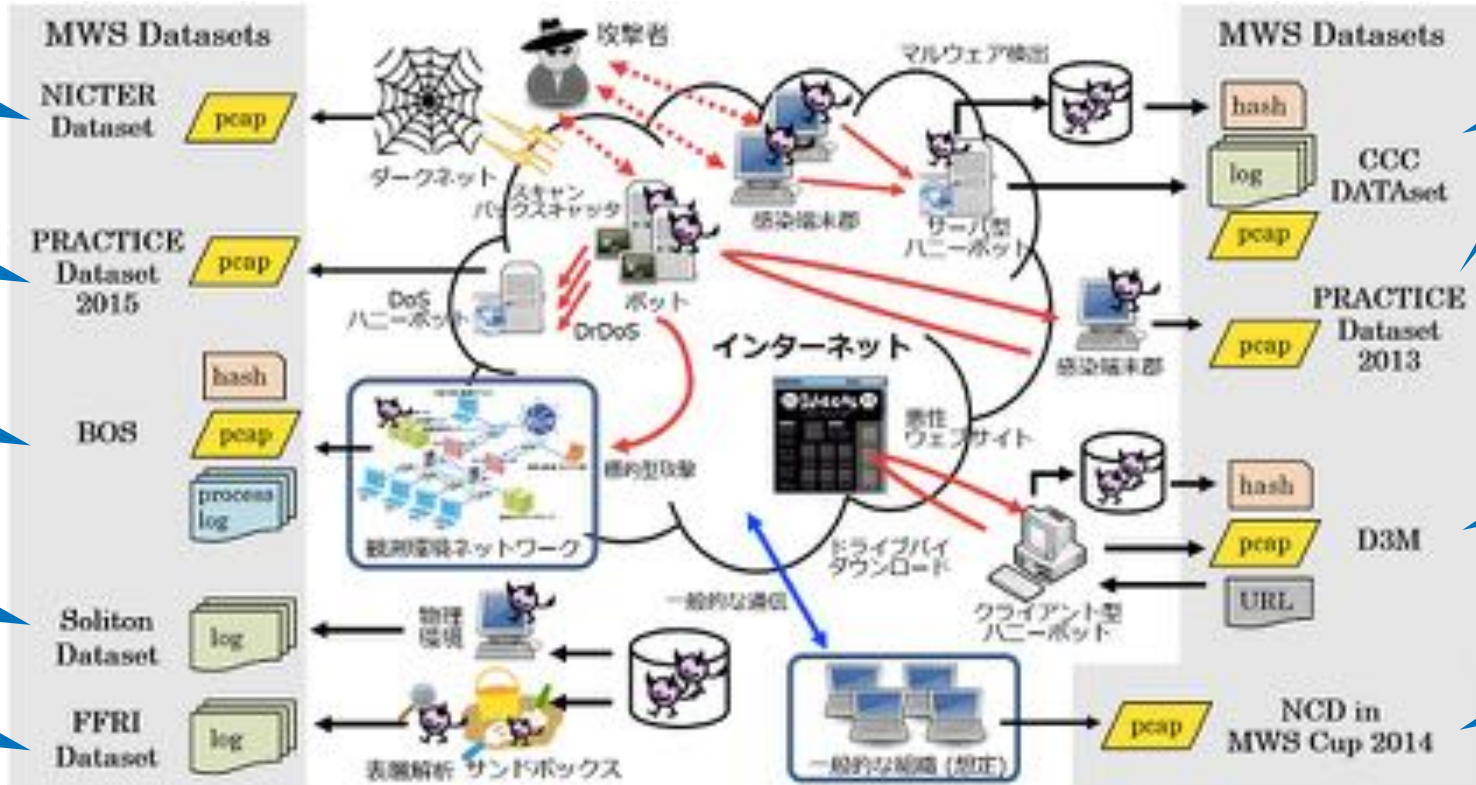
定期的に(長期間に渡って)感染活動を継続するものが多い中で、数日間だけ暴発的に活動を活性化し
 て、すぐに消えてしまったTROJ_POEBOT.XRの動向が際立っている。その他は組み込み良質な詳細につ
 いては現時点で調査中である。

CCC DATASET



MWS Datasets 2021

- NICT
- 横国大
- 日立
- Soliton
- FFRI



- NTTコム
- NTT研
- MWS

MWS Cup 2009 (第1回)

■ 課題1： 攻撃通信データを探し出せ。

競技用CD-ROMに収められている (W) が5個、(B) と (B') で5個の合言 (apファイル) のうち、(B) と (B') を探し出し、その番号を解答欄に記入せよ。括弧を除いた数字を用いよ。

(注:)

(W) = マルウェアに感染していないPCの通信データ。攻撃を受けても感染していないPCの通信データ。 (B) = マルウェアに感染しているPCの通信データ。攻撃を受けても感染しているPCの通信データ。

■ 課題2： マルウェア名を言え。

課題1で探し出した各通信データファイルにおいて、「ホストが感染したPCから選び、それぞれの解答欄に記入せよ。尚、各解答欄には一つの選択肢がある。 (m0) BKDR_MYBOT.AH (m1) BKDR_RBOT.ASA (m2) PE_BO

■ 課題3： 今後の通信パターンを予測せよ

課題1で探し出した通信データファイルの、「今後の通信パターン」の中から一つを選び、解答欄に記入せよ。(注:) 一つの選択肢が、複数の選択肢がある。

- (a0) 何もしない
- (a1) ICMPスキャン
- (a2) 位置情報データベース
- (a3) C&C接続
- (a4) C&C接続、特定ホストへのポートスキャン
- (a5) Microsoft Update を実行
- (a6) 連鎖感染、外部へシステム
- (a7) 連鎖感染、外部 Webサイトへ DoS攻撃
- (a8) 連鎖感染、C&C接続、外部へ DNSクエリ(MXレコード)
- (a9) 連鎖感染、TCP(135)スキャン、C&C接続

MWS Cup 2009 総合優勝：東京電機大学三原チーム



MWS Cup 2009 技術賞：東海大学人海戦術チーム



MWS Cup 2009 芸術賞：Internet Security Centerチーム

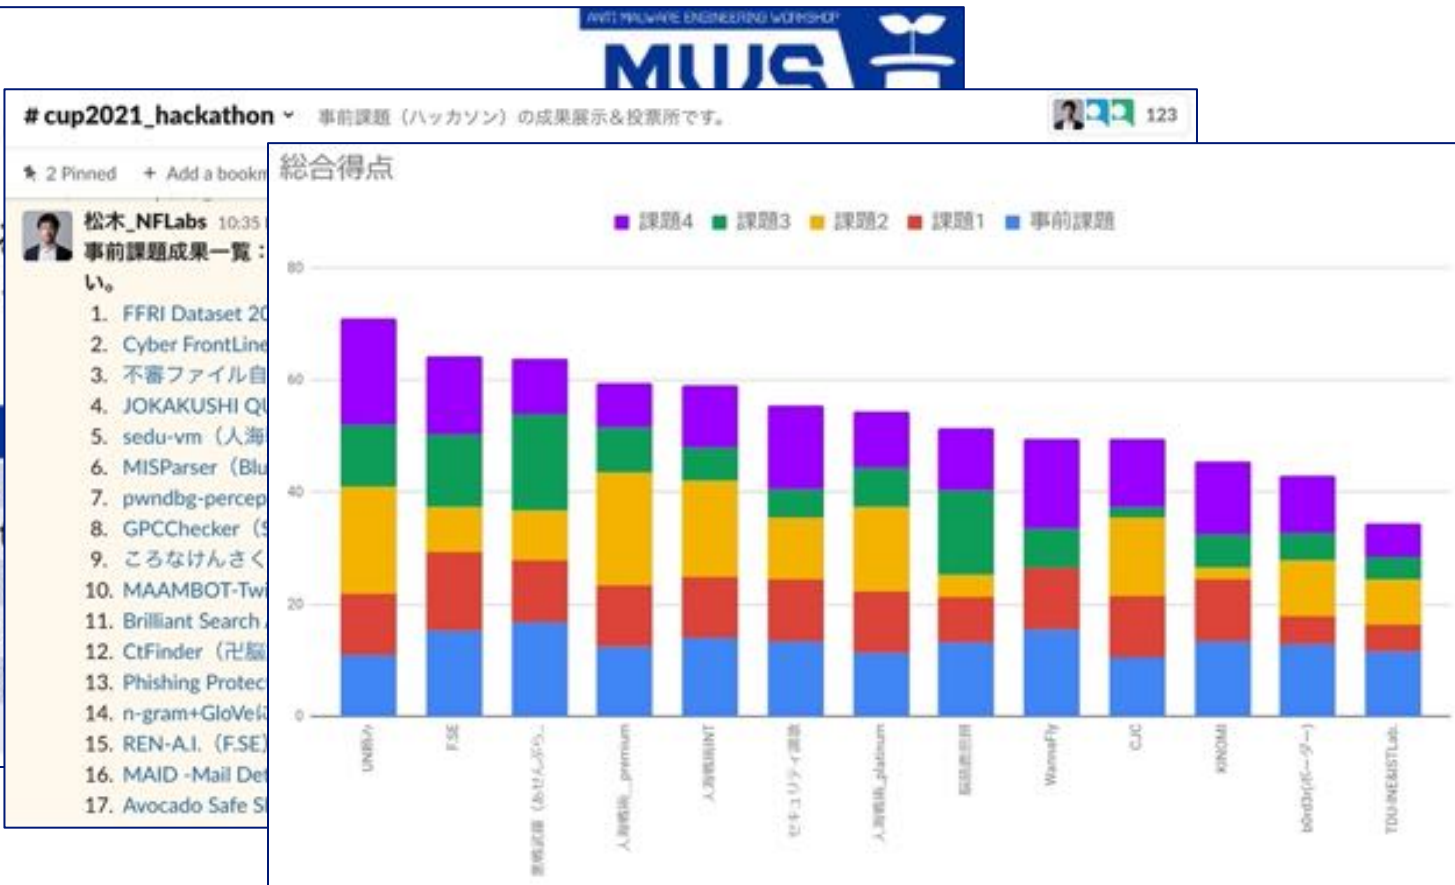


MWS Cup 2021

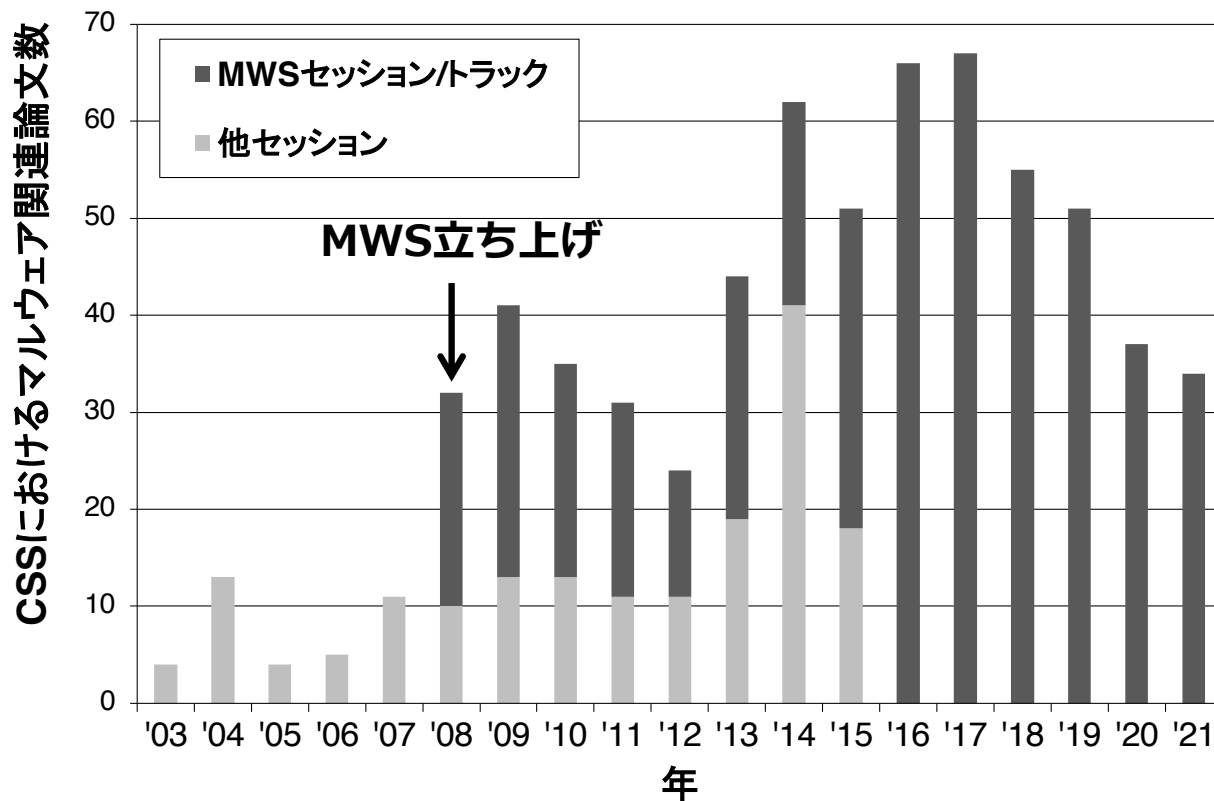
MWS Cup

- マルウェアによる脅威
- MWS Datasets
- 課題構成

種別	内容
事前課題	ツール
課題1	Exploit
課題2	マルウェア
課題3	マルウェア
課題4	フォレンジック



CSSにおけるマルウェア対策系論文数



2. 博士課程へ

「お前、(試験的に)博士行くか？」

学位論文: 博士 (工学)

- Towards Efficient Incident Handling Triage: Automated Threats Classification and Data-centric Talent Development
 - インシデント対応の効率的なトリアージに向けた脅威分類の自動化とデータ主導の人材育成
 - 脅威分類の自動化では、マルウェアが行う通信のモデル化による新種マルウェアの分類、ならびにアクセスするドメイン群の類似度に着目したPUAの分類
 - データ主導の人材育成では、実用的なデータセットの整備により、マルウェア対策に関わる人材育成

博士の価値

- やりぬく力（問題設定、調査、計画、実装、評価、プレゼン）
- グローバルな信用（専門家による査読を複数本クリア）

モチベーション

- これまでの業務経験をもとに、がっつり研究したかった
 - 現実を感じてきた問題
 - 真に未知のマルウェアをどう判定するか
 - グレーなものにどう優先順位をつけるか
 - 新たなロールモデルの開拓

- 休止したこと
 - 都リーグ社会人サッカー
 - 読書
 - CTF (SECON/DEFCON(は例外))
- 始めたこと
 - 水泳 (息子のスクール中)
- 変化
 - 体重+2kg

これから博士を目指す人へ

- なぜ学位をとりたいか、その後どうするかを明確に
- 5～10年目くらいがよさげ
 - 実務を経験した上での研究への欲求
- 実行可能な計画と自信が必要
 - 博士取得要件の把握、国際会議・ジャーナルの査読プロセス
 - 入学前の研究業績、先生との研究計画相談
- 履修科目・必要単位・研究室行事を加味した行き先選択
- 1-2年目は業務2:研究3、3年目は業務3:研究2

3. NIST^

「そんなん、想像できるやろ？」

NISTのミッション

National Institute of Standards and Technology

- 米国国立標準技術研究所、商務省配下の研究機関
- 1901年にNational Bureau of Standardsとして設立

経済安全保障と生活品質向上に資する方法で、計測、標準、技術を進歩させることによって、米国の技術革新と産業競争力を強化

<https://youtu.be/2j9BGVKbzS4>

概観




本部：メリーランド州
ゲイザースバーグ市



職員：3,400+

協力：3,500+



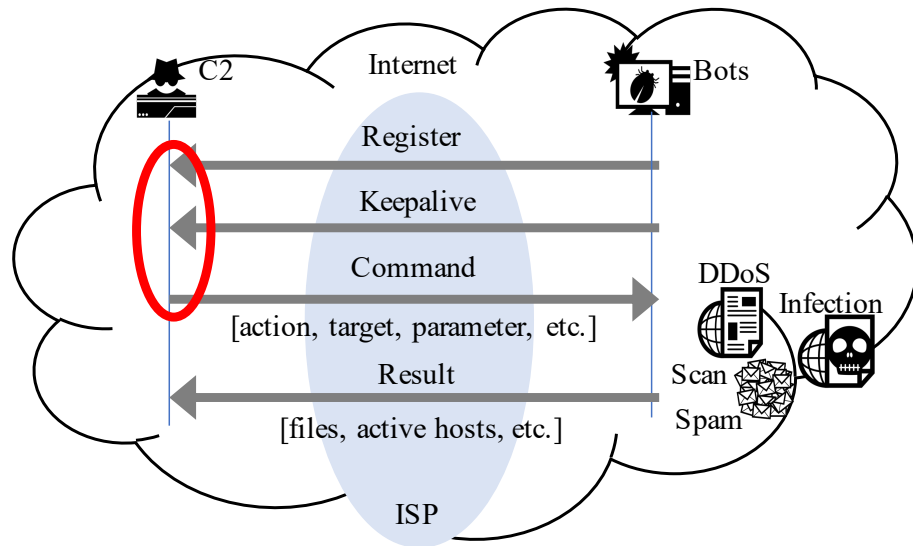


フロー分析でボットネット攻撃予兆検知

NIST Technical Note 2111

ISPのフローデータを利用して、
既知のC2を出入りするトラ
フィックの変化から、スパム
メール増加の予兆を77%の精度
で検知

- アノテーション自動化
- LSTM、GPUクラスタ (Enki)
- Explainable (SHAP)





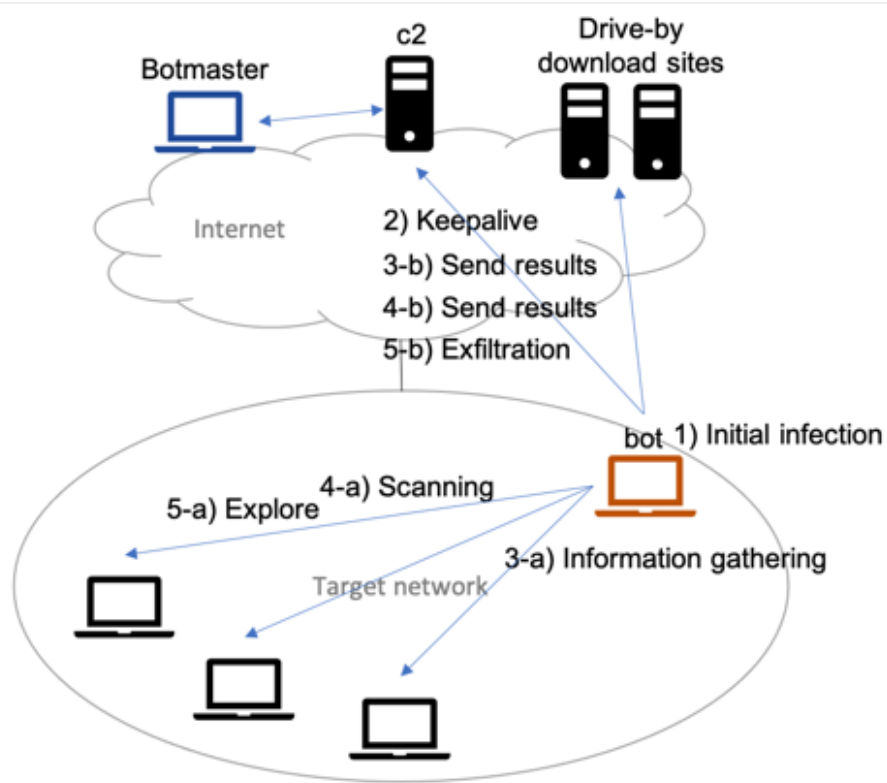


アノマリ検知の評価フレームワーク

NIST Technical Note 2142

- 悪性トラフィックの生成と各種ラメータ
- 良性トラフィックと悪性トラフィックの混合
- アノマリ検知システムの評価指

組織内NWでのボット感染から情報漏洩の性トラフィック生成シミュレータも開発し
上記TNの拡張で論文投稿中











セキュリティ自動化のための標準



資産管理

- Software identification (SWID) tag
- Common Platform Enumeration (**CPE**)



脆弱性管理

- National Vulnerability Database (**NVD**)
- Common Vulnerability Scoring System (CVSS)
- Vulntology



設定管理

- Security Content Automation Protocol (SCAP)
- National Checklist Program (NCP)
- Common Configuration Enumeration (**CCE**)



計画・評価


- Open Security Control Assessment Language (OSCAL)

National Vulnerability Database

標準に基づく脆弱性管理データの米国政府のリポジトリ

- CVE-ID
- 脆弱性の説明
- CVSS v3/v2 ベーススコア
- 参考情報、タグ（URL、種別：ベンダアドバイザリー等）
- CWE: Common Weakness Enumeration（共通脆弱性タイプ）
- CPE: Common Platform Enumeration（共通プラットフォーム一覧）

NVD: CVE件数 (CVSS v2ベーススコア)



<https://nvd.nist.gov/general/visualizations/vulnerability-visualizations/cvss-severity-distribution-over-time> as of Dec. 15, 2021

NVD: チームの役割

<https://github.com/CVEProject/cvelist>

MITRE/CNAから
CVEデータを受領

- ・ CVE-ID
- ・ 脆弱性の説明
- ・ 参考情報

NVD分析

- ・ CVSS
- ・ CWE
- ・ CPE
- ・ 参考情報、タグ

データフィード

- ・ JSON
- ・ RSS
- ・ API
- ・

<https://nvd.nist.gov/vuln/data-feeds>

NVD分析プロセス

MITRE/CNAから
CVEデータを受領

NVD分析

データフィード

- アナリストへの分析対象CVEの割り当て
 1. CVEデータのレビュー、参考情報のサイト確認・追加、タグ
 2. CWE選択
 3. CVSS 2.0/3.1スコア算出
 4. CPE割り当て
- シニアアナリストによるレビュー

1. 参考情報、タグ

脆弱性の内容をできるだけ正確に把握し、CWE/CVSS/CPEの分析に必要な情報を揃える（透明性担保のため公開情報のみを参照）

例: CVE-2021-44228

Hyperlink	Resource
http://packetstormsecurity.com/files/165225/Apache-Log4j2-2.14.1-Remote-Code-Execution.html	Third Party Advisory VDB Entry
http://packetstormsecurity.com/files/165260/VMware-Security-Advisory-2021-0028.html	
http://packetstormsecurity.com/files/165261/Apache-Log4j2-2.14.1-Information-Disclosure.html	
http://packetstormsecurity.com/files/165270/Apache-Log4j2-2.14.1-Remote-Code-Execution.html	
http://www.openwall.com/lists/oss-security/2021/12/10/1	Mailing List Mitigation Third Party Advisory
http://www.openwall.com/lists/oss-security/2021/12/10/2	Mailing List Mitigation Third Party Advisory

2. CWE

単純化した脆弱性のカテゴリのビュー（CWE-1003）から選択
 分析当時に情報不足やカテゴリにマッチしないものもある

例: CVE-2021-44228

Weakness Enumeration

CWE-ID	CWE Name	Source
CWE-502	Deserialization of Untrusted Data	 NIST  Apache Software Foundation
CWE-20	Improper Input Validation	 Apache Software Foundation
CWE-400	Uncontrolled Resource Consumption	 Apache Software Foundation

3. CVSS 2.0/3.1スコア

対応の優先度判断の指標となることも多い脆弱性の深刻度

CVEデータ、参考情報をもとに各要素を選択しベーススコア算出

例: CVE-2021-44228

Severity CVSS Version 3.x CVSS Version 2.0

CVSS 3.x Severity and Metrics:

 NIST: NVD

Base Score: **10.0 CRITICAL**

Vector: CVSS:3.1/AV:N/AC:L/PR:N/UI:N/S:C/C:H/I:H/A:H

4. CPE

CVEデータ、参考情報をもとにベンダ名、プロダクト名からCPE辞書を検索し、CPEを組み合わせて割り当て

- 命名規則: NIST IR 7695 (CPE v2.3)
 - *cpe:2.3:part:vendor:product:version:update:edition:sw_edition:target_sw:target_hw:language:other*
- Configurations
 - 単体、特定のHW上で動作するOS、インストール済のソフトウェア
- CPE Match String Range: バージョンの範囲指定
 - ["From"、"Up to"] x ["including"、"excluding"]

開発環境で1.5ヶ月間、日々分析

アナリストリーダーからのレクチャ

CVSS、CWE、CPEの仕様をあらためて知る

1日十数件の分析、都度チャットで質問

後日、公開されたNVDと比較して答え合わせ





問題提起、分析

3点の問題提起を行いチームで議論

1. CPEで表現できる粒度の適正化

- Windowsで特定のCU以前に脆弱性がある場合、CPEの“update”でCUを識別しているため、単体の修正パッチ（KB）適用有無が表現できない

2. 同一端末に関連する複数の脆弱性がある場合のCVSS考慮

- ローカルでの権限昇格の脆弱性がある端末に、RCEの脆弱性があった場合に、CVSS環境スコアのModified Attack VectorをNetworkにするといった関連付けにCPEを活用

3. CPE割り当ての効率化

理想 : CVEデータ->CPE

```

{
  "data_type": "CVE",
  "data_format": "MITRE",
  "data_version": "4.0",
  "CVE_data_meta": {
    "ID": "CVE-2020-10002",
    "ASSIGNER": "product-security@apple.com",
    "STATE": "PUBLIC"
  },
  "affects": {
    "vendor": {
      "vendor_data": [
        {
          "vendor_name": "Apple",
          "product": {
            "product_data": [
              {
                "product_name": "watchOS",
                "version": {
                  "version_data": [
                    {
                      "version_affected": "<"
                      "version_value": "7.1"
                    }
                  ]
                }
              }
            ]
          }
        }
      ]
    }
  }
}

```

```

"description": {
  "description_data": [
    {
      "lang": "eng",
      "value": "A logic issue was addressed with improved state management. This issue is fixed in macOS Big Sur 11.0.1, watchOS 7.1, iOS 14.2 and iPadOS 14.2, iCloud for Windows 11.5, tvOS 14.2, iTunes 12.11 for Windows. A local user may be able to read arbitrary files."
    }
  ]
}

```



<p>🚩 cpe:2.3:o:apple:watchos:*:*:*:*:*</p> <p>Show Matching CPE(s) ▼</p>	<p>Up to (excluding) 7.1</p>
---	-------------------------------------

現実：“version_value”の例

"Android-8.0"

"18.3R2-S4"

"See provided reference"

"V500R001C30"

"10 Version 1803 for x64-based Systems"

"All versions before 9.0.2"

"All Versions < V1.04"

"Ver.1.6"

"12.1.0-12.4.0"

"See advisory <https://www.>(略)"



CPE検索自動化の試み

versionの表記方法はベンダ固有も多く、正確な抽出は困難

“vendor_name”と“product_name”から部分CPE

(*cpe:2.3:part:vendor:product:*) の候補を自動的にリストアップするだけでも実作業は大幅に楽になる

1. 編集距離による類似度を用いた検索
2. 自然言語処理と機械学習を用いた他クラス分類

編集距離による類似度を用いた検索

同日取得のCPE辞書が検索対象

NVDのCPEとの一致率で評価

一致率

- ほぼ完全一致検索

13.4%

- 大文字を小文字に、" "を"_"に置換

- ファジー検索

36.3%

- + "corporation"等ストップワード、
レーベンシュタイン距離

類似度が高いが不一致



CPE辞書のメンテナンス対象








Product Detail

Product Detail	Face Value (¥ JPY)	Face Value (USD) 1 USD= (JPY) ¥103.06	Handling Fee (\$USD)	Unit Price (\$USD)	Price Cat.	Qty	Total (\$USD)
TOFBL29 Football Men's Quarterfinal Saturday, 7/31/2021, 19:00 - 22:00 Venue: Saitama Stadium	¥5,800	\$56.28	\$11.26	\$67.53	D	4	\$270.12

TICKET PURCHASER AGREES THAT TICKETS MAY NOT BE RE-SOLD OR USED TO PROMOTE ANY PERSON, ENTITY PRODUCT OR SERVICE.



0.12



NLP/MLを用いた他クラス分類

“vendor_name”、“product_name”、“version_value”の文字列を連結、置換とストップワードを適用、TF-IDFベクトル化

NVDのデータから、部分CPE群を正解クラスとして、ランダム・フォレストで学習・テスト

```
"ID": "CVE-2020-2585",
"vendor_name": "Oracle Corporation",
"product_name": "Java",
"version": {
  "version_data": [
    {
      "version_value": "Java SE: 8u231",
```

仮説)ソフトウェアコンポーネントを複数のプロダクトに流用していることが多いと考えられるため、部分CPEは同じパターン

Known Affected Software Configurations

Configuration 1 (hide)

※ cpe:2.3:a:oracle:jdk:1.8.0:update231:*:*:*:*

[Hide Matching](#)

- cpe

※ cpe:2.3:a:

[Hide Matching](#)

部分CPE群 (クラス)
 cpe:2.3:a:oracle:jdk:
 cpe:2.3:a:oracle:jrd:

No Matching CPE(s) found in CPE Dictionary

"ID": "CVE-2020-14621",

"ID": "CVE-2020-14664",

1クラスに含まれるデータ数	CVE数	クラス数	正解率
1	10,601	3,712	62.8%
2	8,127	1,238	82.4%
3	7,113	731	87.9%
4	6,477	519	88.3%
5	6,013	403	89.3%

継続的な評価



一貫性あるCPE割り当て

NVDに携わってみて

自動化できる範囲を広げていく

- 100%を求めない


継続的なMeasurement（測定）は重要

- 自動化に向けたデータ品質 *1
- 自動化の効果

理想と現実のはざまにはチャンスがたくさん

- 脆弱性情報の共有は世界への貢献
- より良い使い方のためのフィードバック

平日のある日の過ごし方



Cooking in the US
アイテム564件



週末のある日の過ごし方

研究、ドラマ

睡眠

夕食

買物、


ピアノ

朝食

ゴルフ

昼食

サッカー



4. ふりかえり

思いがあったからきっかけを掴める

- MWS: 仕組み作るか？
 - 膨大なデータを有効活用したい
- 博士: 行くか？
 - ガッツリ研究したい
- NIST: 想像できるやろ？
 - 世界に挑戦したい、入社動機を実現したい

実績の積み上げが自信になる

- MWS
 - データセット整備・分析、コミュニティ運営

- 博士
 - 機械学習、論文、GRIT

- NIST
 - フロー分析、NVD、米国生活

その他

- 生活全般

- 1年目：試行錯誤
- 2年目：活動の幅の拡大
- 3年目：日常

- 英語

- 当初、ミーティング前に喋る内容を考えたり下書き
- そのうち、適当に喋って、適当に聞き流すように

mitsuhiro.hatada@ntt.com