

### 畳み込みニューラルネットワークを用いた URL 系列に基づくドライブバイダウンロード攻撃検知

山西宏平<sup>1</sup>, 芝原俊樹<sup>2</sup>, 高田雄太<sup>2</sup>, 千葉大紀<sup>2</sup>, 秋山満昭<sup>2</sup>, 八木毅<sup>2</sup>, 天下裕一<sup>1</sup>, 村田正幸<sup>1</sup>

1 大阪大学大学院情報科学研究科  
2 NTT セキュアプラットフォーム研究所

1

### ドライブバイダウンロード攻撃

- ・ 水面下で悪意のあるコードを実行させる攻撃 (DbD 攻撃)
- ・ 改ざんしたウェブサイトを利用

1 入り口 URL

2 攻撃者によって改ざんされたウェブサイトへアクセス

3 通常通りウェブサイトのコンテンツが表示される

2

### ドライブバイダウンロード攻撃

- ・ 水面下で悪意のあるコードを実行させる攻撃 (DbD 攻撃)
- ・ 改ざんしたウェブサイトを利用

1 入り口 URL

2 踏み台 URL

3 ユーザの環境を識別 更なる転送先の決定

4 改ざんにより見えない部分でリダイレクトが発生

5 通常通りウェブサイトのコンテンツが表示される

3

### ドライブバイダウンロード攻撃

- ・ 水面下で悪意のあるコードを実行させる攻撃 (DbD 攻撃)
- ・ 改ざんしたウェブサイトを利用

1 入り口 URL

2 踏み台 URL

3 攻撃 URL

4 ユーザの環境の脆弱性を突いたコードを実行

5 再度リダイレクトが発生

6 通常通りウェブサイトのコンテンツが表示される

4

### ドライブバイダウンロード攻撃

- ・ 水面下で悪意のあるコードを実行させる攻撃 (DbD 攻撃)
- ・ 改ざんしたウェブサイトを利用

1 入り口 URL

2 踏み台 URL

3 攻撃 URL

4 マルウェア配布 URL

5 マルウェア実行

6 マルウェアの URL にアクセスダウンロードさせる

7 通常通りウェブサイトのコンテンツが表示される

5

### ドライブバイダウンロード攻撃

- ・ 水面下で悪意のあるコードを実行させる攻撃 (DbD 攻撃)
- ・ 改ざんしたウェブサイトを利用

1 入り口 URL

2 踏み台 URL

3 攻撃 URL

4 マルウェア配布 URL

5 DbD 攻撃による被害を抑えるため、近年は攻撃発生時の対策に加えて発生後のログ解析による検知も重要 (本研究の対象領域)

6

### DbD 攻撃の検知

- コンテンツの解析
  - リソースが必要なため限られた環境でしか不可
- プロキシログ等のアクセス履歴の解析
  - 一般企業等でも行われるため早期検知も現実的

↓

- 本研究の目的
  - アクセス履歴情報を用いて DbD 攻撃を早期に検知

↓

- アクセス履歴情報から得られるもの
  - ⇒時系列的なアクセス先 URL の情報 (URL 系列)

7

### URL 系列への着目

8

### URL 系列への着目

9

### URL 系列への着目

10

### URL から抽出される特徴量

ID	特徴量	ID	特徴量	ID	特徴量
1	ドメインの長さ	1	HTTP プロトコル (FQDN)	19	FQDN 数
2	ファイル名の長さ	2	HTTP プロトコル (URL)	20	長さの平均
3	URL の長さ	3	HTTP プロトコル (URL)	21	長さの標準偏差
4	パスの長さ	4	登録数の総数 (FQDN)	22	法度程度の平均 (1-gran)
5	公開プロキシリスト掲載の有無	5	登録数の総数 (SLD)	23	法度程度の中央値 (1-gran)
6	ファイル名内に含まれた悪質なパターンの数	6	登録数の総数 (URL)	24	標準偏差 (1-gran)
7	サブドメインの数	7	IP アドレスの数 (URL)	25	法度程度の平均 (2-gran)
8	URL 中の IP アドレスの有無	8	IP アドレスの数 (URL)	26	法度程度の中央値 (2-gran)
9	URL 中のポート番号の有無	9	組織数 (FQDN)	27	法度程度の標準偏差 (2-gran)
10	ドメインに対応する IP アドレスの数	10	AS 番号の総数 (FQDN)	28	法度程度の平均 (3-gran)
11	AS 番号	11	AS 番号の総数 (URL)	29	法度程度の中央値 (3-gran)
12	IP アドレスに対応した経度	12	AS 番号の総数 (URL)	30	法度程度の標準偏差 (3-gran)
13	TLD	13	レジストリ数 (FQDN)	31	TLD 数
14	IP アドレスに対応した国名	14	レジストリ数 (URL)	32	asn の割合
15	IP アドレスに対応した都市名	15	レジストリ数 (URL)	33	法度程度の平均 (TLD)
		16	登録数の総数 (FQDN)	34	法度程度の中央値 (TLD)
		17	登録数の総数 (URL)	35	法度程度の標準偏差 (TLD)
		18	登録数の総数 (URL)		

11

### URL 系列の分析

- URL 系列の分析方法
  - DbD 攻撃の一連のリダイレクト関係は文章の構文関係と類似
  - 文章解析は畳み込みニューラルネットワーク (CNN) の得意分野の一つ
  - ⇒ URL 系列の分類にも CNN が有効な可能性が高い
- CNN
  - 局所領域の特徴抽出 (畳み込み) を繰り返すネットワーク
  - 教師有り学習を行うことで様々なタスクをこなすモデルが作成可能
  - 画像認識、音声認識や文章解析等

12

### アプローチの全体像

- DbD 攻撃発生時の URL 系列の特徴を学習し、攻撃発生を検知
  - ①～⑤を実行

- ① 攻撃データを含む教師データを収集
- ② 教師データで分類モデルを学習
- ③ 学習した識別モデルを投入
- ④ プロキシから URL 系列を抽出 識別システムへ入力
- ⑤ モデルの識別結果を取得

識別結果が悪性の場合  
オペレータによるマルウェア解析、感染者へのアラートなどを実行

### 攻撃の一連の URL の畳み込み

URL 同士のリダイレクト関係  
⇒リダイレクトとリダイレクトの関係  
⇒攻撃全体のリダイレクト構造と徐々に全体の特徴を捉えていくことが期待できる

アクセス時刻

URL 系列

URL 同士の関係性

攻撃全体の構造

リダイレクト関係性

DbD 攻撃の流れ

### CNN 適用にあたる問題点

- DbD 攻撃発生時の URL 系列の特性
  - 攻撃とは関係のない URL が混在している
- CNN の特性
  - 入力中の一定範囲の情報を畳み込み局所的な特徴量を得る

攻撃に関係する URL と関係しない URL が混在

非攻撃 URL の特徴は改ざん元サイト次第で大きく変化

改ざん元 URL の特徴も含めて学習

攻撃・非攻撃共に近いものを見出し

- 改ざん元サイトが異なる攻撃の見逃し
- 改ざん元と似た特徴の正常サイトの誤検出

### CNN 適用にあたる問題点

- DbD 攻撃発生時の URL 系列の特性
  - 攻撃とは関係のない URL が混在している
- CNN の特性
  - 入力中の一定範囲の情報を畳み込み局所的な特徴量を得る

攻撃に関わる URL の情報のみを選択できる構造が必要

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

リダイレクト元 URL

URL1

URL2

URL3 リダイレクト先 URL

URL4

畳込

入力

URL1 を起点とした URL 組の畳み込みとプーリング

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

リダイレクト元 URL

URL1

URL2

URL3

URL4 リダイレクト先 URL

入力

URL1 を起点とした URL 組の畳み込みとプーリング

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

URL1 を起点とした URL 組の畳み込みとプーリング

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

URL1 を起点とした URL 組の畳み込みとプーリング

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

### Event-Denoising CNN

- 攻撃に関係しない URL の影響を削減するよう CNN を改良した **Event-Denoising CNN (EDCNN)** を提案
- EDCNN における畳み込み
  - 系列中の近くにある 2 つの URL の組を畳み込み
  - 攻撃に関わるリダイレクトの可能性に相当する値を出力
  - 起点のリダイレクト元 URL 毎に最高値の組を抽出 (プーリング)
  - 各 URL から最も攻撃に関わっている可能性が高い組を探索

後半の URL の順序が入れ替わった場合

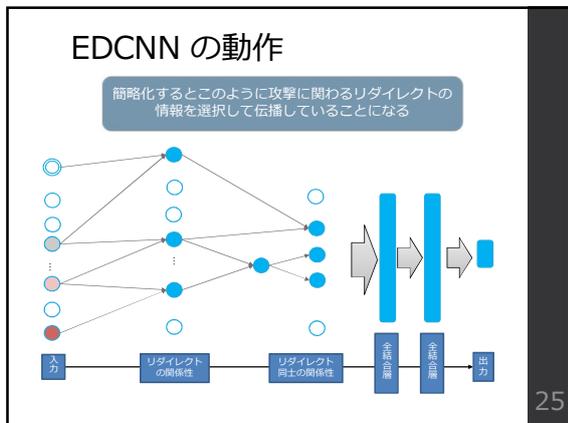
### EDCNN の構造

- 全体構成としては下図の通り
- :  $N$  次元ベクトル (URL の特徴量や畳み込み結果)

前頁で示した部分

### EDCNN の動作

- : 攻撃に関する遷移の情報



### 評価実験

教師データ	教師データ			テストデータ		
	期間	悪性	良性	期間	悪性	良性
1	2015/2~7	1,039	5,045	2015/8	399	967
2	2015/7~8	3,182	3,900	2015/9	352	957
3	2015/8~9	3,126	3,902	2015/10	158	954
4	2015/9~10	2,787	3,893	2015/11	123	978
5	2015/8~11	2,335	3,889	2015/12	155	976
6	2015/7~12	1,906	3,891	2016/1	119	951

各データの収集期間と系列の個数

- データセット
  - 収集元
    - 有名サイトのリストや公開ブラックリストに掲載されたウェブサイト
  - 収集期間
    - 2015年2月~2016年1月
  - 事前にコンテンツ解析を行いラベル付け(良性/悪性)済
  - 収集元の各ウェブサイト一つ一つにアクセスしたときに発生するURL系列のみを使用(一度に複数サイトにアクセスしない)
- 実験内容
  - 以下に示す教師データでモデルを学習させ、テストデータを分類
  - テストデータ
    - 収集元から1か月間に渡り集めたデータ(重複データは削除)
  - 教師データ
    - テストデータの直近6か月間で集めたデータ(重複データは削除)

26

### 評価方法

- 評価指標
  - 識別性能を表す指標 Precision, Recall, F 値 (F-measure)

$$\text{Precision} = \frac{TP}{TP+FP}$$

(誤検知の少なさを指標)

出力\正解	悪性	良性
悪性	TP	FP
良性	FN	TN

$$\text{Recall} = \frac{TP}{TP+FN}$$

(見逃しの少なさを指標)

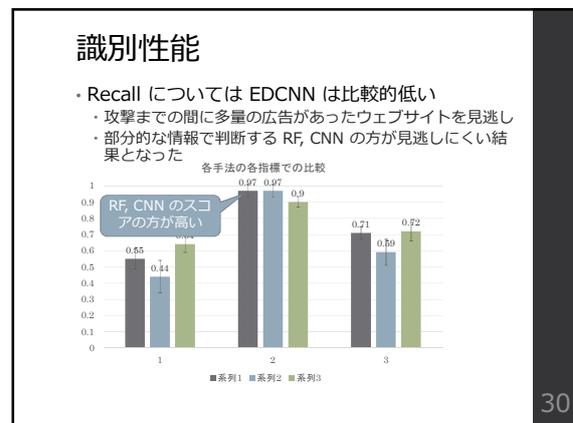
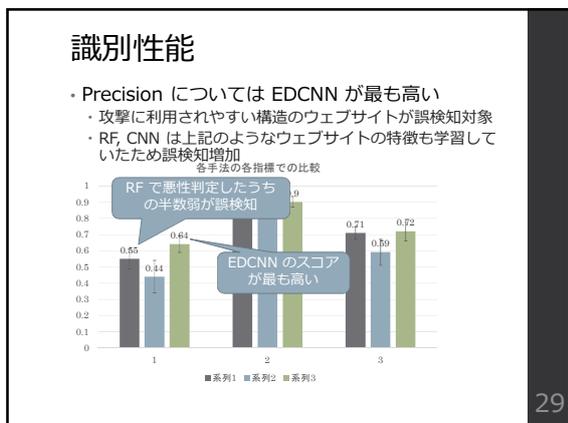
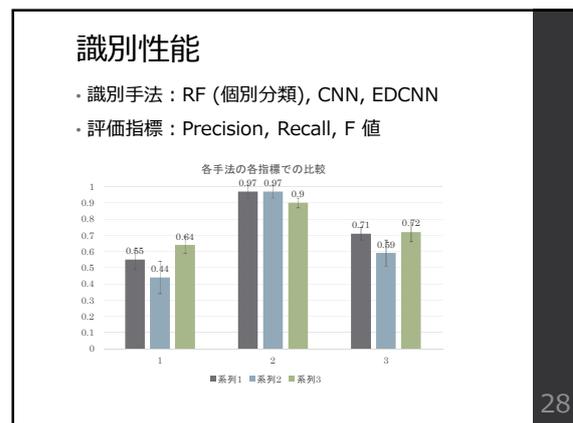
テストデータの各正解ラベルに対し、それぞれの出力を行った数

$$\text{F-measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

(上記両方を評価する指標)

- 使用した学習・識別器
  - 系列中の URL を個別に分類する手法
    - 分類器は Random Forest (RF) を使用
    - URL 系列の中で悪性と判定した URL があれば系列全体を悪性と出力
  - CNN
  - EDCNN

27



### 識別性能

- F 値については EDCNN が最も高い
- 総合的には URL 系列の分類には EDCNN が良いと言える
- ただし Recall の低さを改善する工夫は必要

各手法の各指標での比較

指標	系列1	系列2	系列3
F1	0.55	0.44	0.64
F2	0.97	0.97	0.9
F3	0.71	0.70	0.72

EDCNNのスコアが最も高い

31

### 計算時間

- EDCNN, CNN, RF の順となった
- Random Forest による個別分類より EDCNN は平均 3 倍の速度での識別が可能
- 個別に URL を識別していく手法は時間がかかる
- CNN より EDCNN の方が早い速度で識別することが可能
- 畳み込み層に繋がるリンクの数が CNN より少ないためと考えられる
- 計算時間の面でも EDCNN は CNN より性能向上できているといえる

1 URL 系列あたりの識別に掛かった時間

識別手法	計算時間(秒)
1	0.21
2	0.09
3	0.07

32

### まとめと今後の課題

- まとめ
  - プロキシログに含まれる宛先 URL の系列から、ドライブバイダウンロード攻撃に関する通信が含まれる URL 系列を検知する手法を検討
  - URL 系列の分類に CNN を適用
  - URL 系列の特性に合わせ CNN を拡張した EDCNN を提案
  - 1 年間に渡り収集したデータで EDCNN の識別性能を評価
- 今後の課題
  - EDCNN の識別性能改善
    - 見逃し・誤検知共に改善の余地あり
  - 同時に複数のウェブサイトへの通信が行われそれらの URL が混在した場合における識別の実施と評価
    - 本評価では単一のウェブサイトへのアクセス結果に対してのみ実施

33