



FFRI Dataset 2024の ご紹介

株式会社 F F R I セキュリティ
<https://www.ffri.jp>



FFRI Datasetについて

概要と特徴

FFRI Datasetは動的・表層解析データを提供



例年マルウェアの解析データをご提供しています

	2013 - 2017	2018 - 2023	2024
データの 種類	動的解析	表層解析	本資料で 解説
使用 ツール	yarai Analyzer Cuckoo Sandbox 等	LIEF pehash 等	
特徴	動かさないと分から ない情報を提供可能	再現性が高い 大量の件数のデータ を提供可能	

FFRI Dataset 2024の特徴



FFRI Dataset 2024は表層解析データセットです

特徴	概要
提供の種類	マルウェアとクリーンウェアの両方のデータを提供
再現性と拡張性	一般的なツール・手法を使用 データセットの作成スクリプトを公開
データ量	マルウェア・クリーンウェア合わせて 15万件を提供

FFRI Dataset 2024は“ML-ready”
なデータセット



FFRI Dataset 2024

スペック

FFRI Dataset 2024の概要



	クリーンウェア	マルウェア
データの形式	JSON Lines (1行1検体分のレコード)	
件数	75000件	75000件
展開前サイズ	約27GB	
展開後サイズ	約108GB	約15GB
期間 (収集日)	2023/01/01- 2023/12/31	

データソース

クリーンウェア

AV-TEST社のクリーンウェア提供サービス
FLARE※により提供されたファイルのうち
PE形式のものから無差別に抽出

マルウェア

弊社が収集したマルウェアのうち
PE形式のものを無作為に抽出

※ [AV-TEST | Antivirus & Security Software & AntiMalware Reviews](#)

FFRI Dataset 2024の特徴



FFRI Dataset 2023と要素は同じ

	要素	概要
検体に適用したツールの出力	id	検体のSHA-256ハッシュ値
	file_size	ファイルサイズ
	hashes	各種ハッシュ値
	peid	pypeidの出力
	lief	LIEFの出力
	trid	TrIDの出力
	strings	stringsの出力
	die	DIEの出力
	manalyze_plugin_packer	ManalyzeのPackerプラグインの出力
検体外の情報	label	ラベル (1=マルウェア、0=良性ファイル)
	date	収集日
	version	データセットのバージョン

FFRI Dataset 2024の特徴（続き）



使用したツール・ライブラリは以下の通り

ツール・ライブラリ	version	URL
ssdeep	3.4	https://pypi.org/project/ssdeep/
TLSH	96536e3 (※1)	https://github.com/trendmicro/tlsh
pehash	0.91	https://github.com/knownmalware/pehash
impfuzzy	b30548d (※1)	https://github.com/JPCERTCC/impfuzzy
LIEF	Patched (※2)	https://pypi.org/project/lief/
TrID	2.24	https://mark0.net/soft-trid-e.html
strings	2.38	https://www.gnu.org/software/binutils/
pypeid	0.1.3	https://github.com/FFRI/pypeid
pefile	ceab92e (※1)	https://pypi.org/project/pefile/
Manalyze	b6800ff (※1)	https://github.com/JusticeRage/Manalyze
Detect-It-Easy	3.09	https://github.com/horsicq/DIE-engine

※1 これはshort commit hash

※2 573c885より改変

FFRI Dataset 2024に関連するOSS



OSSによりデータセットの作成・拡張・利用を促進

	作成・拡張	利用
OSS名	<p>ffridataset-scripts https://github.com/FFRI/ffridataset-scripts</p>	<p>FEXRD https://github.com/FFRI/FEXRD</p>
概要	<p>FFRI Datasetの作成に用いたスクリプト</p>	<p>FFRI Dataset（と同形式）のデータから特徴量を抽出できるライブラリ</p>
想定するユースケース（一例）	<p>FFRI Datasetにない検体から同じ形式のデータを抽出し、Concept DriftやDomain Shiftの研究に用いる</p>	<p>FFRI Dataset 2024を用いた機械学習研究のベースラインに用いる</p>

昨年度との差異

注意点

FFRI Dataset 2023との差異



ライブラリのアップデートによる差異がある

ライブラリ・ツール

変更点

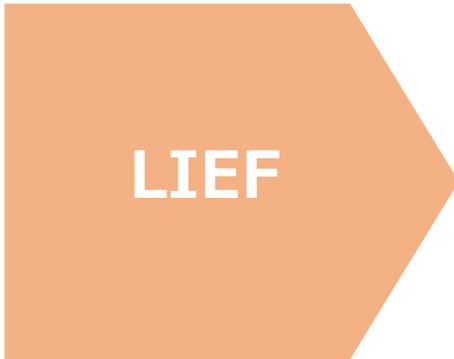
スキーマ 変更なし	TrID	定義ファイルの更新
	TLSH	アップデート
	pypeid	アップデート
	pefile	アップデート
	Manalyze	アップデート
	Detect-It-Easy	アップデート
スキーマ 変更あり	LIEF	アップデートによるスキーマ変更・ スキーマの改善

スキーマの変更の詳細及び注意点

昨年度以前のデータセットとの比較の際は以下に注意し検討のこと

ライブラリ・ツール

変更点



- Load Configurationのスキーマの改善 (※)
- Load Configurationのversionの定数の形式を一部変更
 - WIN10_0_9879=>WIN_10_0_9879のような形に統一
- Resource Managerのversionがないケースも考慮

※ Load ConfigurationはSDKのバージョンが上がることで項目が追加されているケースがある
 これまでは特定のバージョン（以降）に存在する項目はnullableとして扱っていた
 今回から各バージョンのLoad Configurationごとにスキーマを定義し、そのunionとしてLoad Configurationのスキーマを定義した

FFRI Datasetを使用した 論文紹介

利用事例

FFRI Dataset 2013~2017を使用した論文



ここに載せた論文はごく一部です

	Automatically generating malware analysis reports using sandbox logs	Malware function classification using apis in initial behavior
使用データセット	2013~2015	2014
概要	Sandboxのログとベンダーのレポートからhuman readableなレポートを生成	呼ばれたAPIからマルウェアの機能を推定
Cite	Sun, Bo, et al. "Automatically generating malware analysis reports using sandbox logs." IEICE TRANSACTIONS on Information and Systems 101.11 (2018): 2622-2632.	Kawaguchi, Naoto, and Kazumasa Omote. "Malware function classification using apis in initial behavior." 2015 10th Asia Joint Conference on Information Security. IEEE, 2015.

FFRI Dataset 2018~2023を使用した論文



ここに載せた論文はごく一部です

	Evaluation of printable character-based malicious PE file-detection method	Robust detection model for portable execution malware
使用データセット	2019~2021	2018
概要	文字列を用いてマルウェアとクリーンウェアを分類。時系列的な影響も調査	次元削減により Adversarial Attack に対しRobustな分類器を作成
Cite	Mimura, Mamoru. "Evaluation of printable character-based malicious PE file-detection method." Internet of Things 19 (2022): 10052	Zheng, Wanjia, and Kazumasa Omote. "Robust detection model for portable execution malware." ICC 2021-IEEE International Conference on Communications. IEEE, 2021.

おわりに

FFRI Datasetに関するご意見・ご要望はお気軽に！！

「こういう情報も取ってほしい」「この検体の情報も欲しい」
Slack #dataset @ko.nakagawa

OSSへのコントリビューション
(issue/pull request) も大歓迎です！！

[Issues · FFRI/FEXRD \(github.com\)](#)
[Issues · FFRI/ffridataset-scripts \(github.com\)](#)
[Issues · FFRI/pypeid \(github.com\)](#)