Malware Analysis at Scale

～ Defeating EMOTET by Ghidra ～

株式会社サイバーディフェンス研究所　中島将太
トレンドマイクロ株式会社　原弘明

ALLSAFE

> whoami

Shota Nakajima

- 株式会社サイバーディフェンス研究所でマルウェア解析、インシデントレスポンス業務、脅威情報の収集・分析業務に従事。
- JSAC、HITCON CMT、AVAR、CPRCon、Black Hat EUROPE Arsenal、CodeBlue BlueBoxなどで発表経験あり。
- 技術系同人サークルAllsafeのプロデューサー。

Hiroaki Hara

- トレンドマイクロ株式会社にて、マルウェア解析やインシデントレスポンス、スレットリサーチなどに従事。
- 技術系同人サークルAllsafeの澤村・スペンサー・英梨々（アートディレクター）。

ALLSAFE

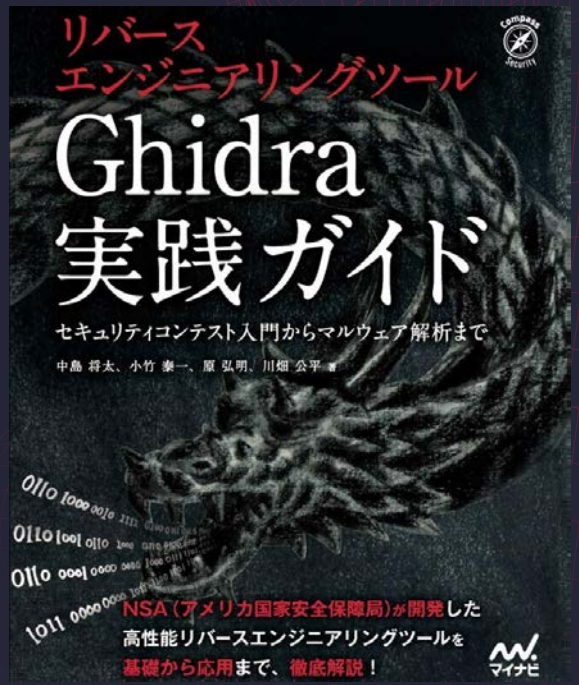

Malware Analysis at Scale

テーマ: いかにして楽に解析を終わらせるか

- 解析者の現状として、次のような課題がある
  - ✓ 静的解析は時間がかかり、根本的につらい
  - ✓ 膨大な数のマルウェアを解析する必要がある
  - ✓ 手動での解析は現実的に不可能

解析の自動化（＝スケールする解析）をめざす

Target

- マルウェア解析経験者
  - C言語、アセンブリ言語を理解している
  - Windowsのプログラミングについて知識がある
  - IDA, Ghidraを使ってマルウェアの静的解析をしたことがある
- Pythonでのプログラミング経験を有する者
  - Pythonの基本的な文法がわかる

TABLE OF CONTENTS

01
Basic of Ghidra

What is Ghidra?

ソフトウェアリバースエンジニアリングツールセット

- 2019年にNSAによってOpen Source Softwareとして公開
  - https://github.com/NationalSecurityAgency/ghidra
- フリーでありながら、豊富な機能を提供

Ghidra's Basic Features

Disassembler/Decompiler

多様なアーキテクチャに対応した
ディスアセンブラに加え、
擬似C言語へ変換するデコンパイラ機能

Ghidra Script

Ghidraの各種機能をスクリプト
(Java/Python)から利用可能

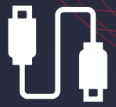

Ghidra Extension

自作プラグインによる
機能拡張をサポート

Headless Analyzer

CLI経由での操作

Ghidra Server

複数ユーザによる共同作業を
サポート

Debugger

GDB/WinDBGをバックエンド
としたデバッグ機能を提供

Ghidra Usage

Code Browser

Listing View

- ディスアセンブル・データを表示

Decompile View

- Listing Viewのデコンパイル結果を表示

Program Tree

- セクション名などを表示

Source Tree

- インポート/エクスポート関数、関数名、クラス名などなどを列挙

Data Type Manager

- 独自構造体などのデータ型を管理
- ヘッダファイルなどの読み込み

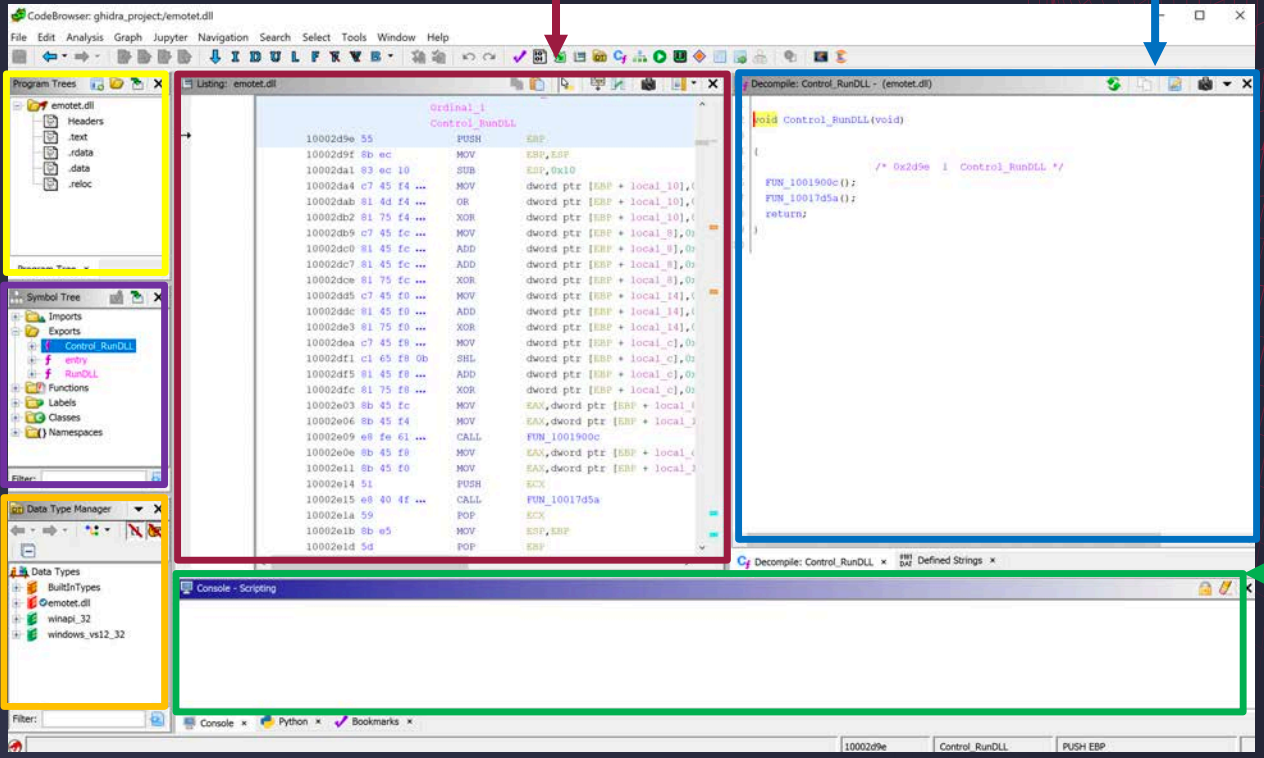

Console

- スクリプトの標準出力結果を表示

Other Windows

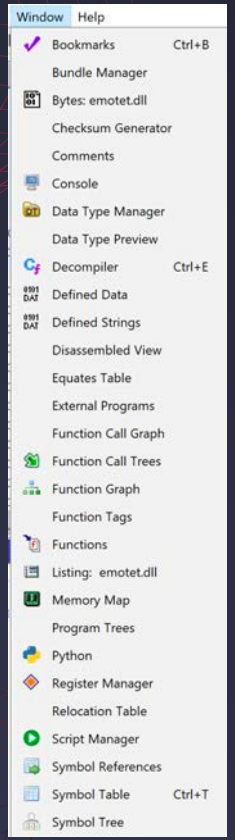

- **Bookmarks**
  - 特定のアドレスに対し、名前をつけてブックマークとして保存
- **Bytes**
  - HEXエディタ
- **Defined Strings**
  - プログラム内で定義された可読文字列
- **Function Graph**
  - ディスアセンブル結果をグラフ形式で表示
- **Python**
  - Pythonインタプリタの起動
- **Script Manager**
  - Ghidra Scriptを管理するマネージャの起動

Name

- Ghidraではバイナリのロード時に自動解析して関数や変数に名前を付ける
  - 関数(FUN_*)
  - 文字列(s_*)
  - ローカル変数(local_*)
  - 変数(*Var*)

```
27  LAB_100037ff:
28    do {
29      if (iVar3 == 0xf4e9d7) {
30        local_94 = FUN_100010cf();
31        iVar3 = 0xacc66de;
32      }
```

```
                    LAB_10003a00                                    XREF[1]:     10003805(j)
10003a00 8b 44 24 30     MOV        EAX,dword ptr [ESP + local_118]
10003a04 8b 84 24 ...    MOV        EAX,dword ptr [ESP + local_bc]
10003a0b e8 bf d6 ...    CALL       FUN_100010cf                          undefined FUN_100010cf(void)
10003a10 89 84 24 ...    MOV        dword ptr [ESP + local_94],EAX
10003a17 be de 66 ...    MOV        ESI,0xacc66de
```

```
                    s_Control_RunDLL_1001e052                       XREF[1]:     1001e040(*)
1001e052 43 6f 6e ...     ds         "Control_RunDLL"

                    s_RunDLL_1001e061                               XREF[1]:     1001e044(*)
1001e061 52 75 6e ...     ds         "RunDLL"
```

Change Name

- リネームして解析結果を反映することで、Ghidraを読みやすくしていく
- 右クリックメニューから選択

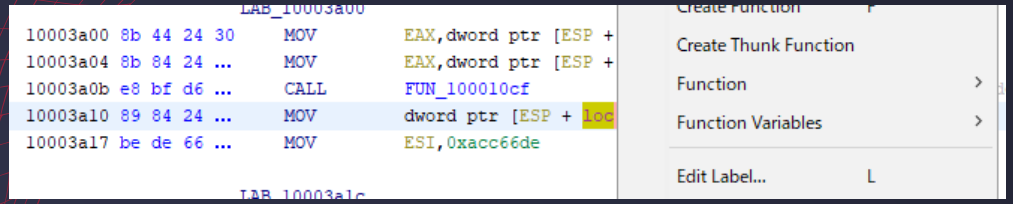

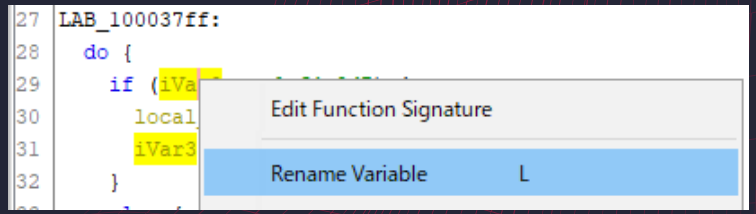

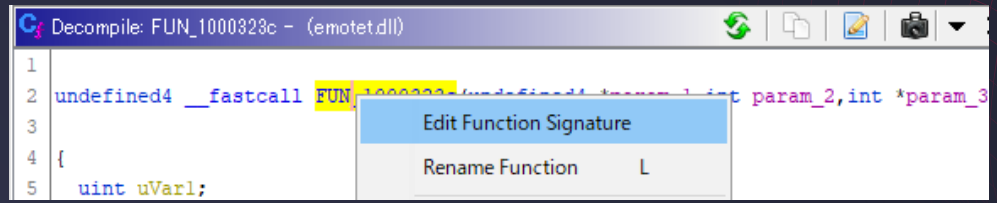

Change Function Signature

- 関数の定義を変更する

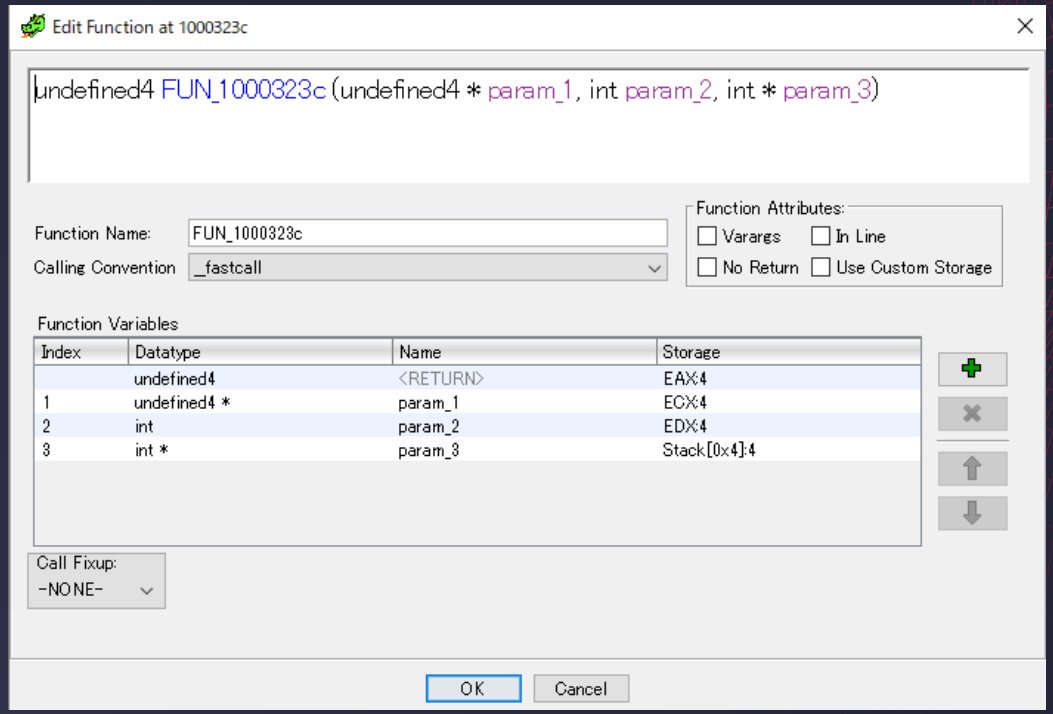

XREF(Cross References)

- データの参照元の表示

```
                undefined __stdcall FUN_1000d26b(undefined4 param_1, und...
undefined         AL:1          <RETURN>
undefined4        Stack[0x4]:4  param_1                          XREF[1]:     1000d27d(R)
undefined4        Stack[0x8]:4  param_2                          XREF[1]:     1000d27a(R)
undefined4        Stack[0xc]:4  param_3                          XREF[1]:     1000d277(R)
undefined4        Stack[0x10]:4 param_4                          XREF[1]:     1000d274(R)
undefined4        Stack[0x14]:4 param_5                          XREF[2]:     1000d271(R),
                                                                              1000d28a(R)
undefined4        Stack[0x18]:4 param_6                          XREF[2]:     1000d26e(R),
                                                                              1000d28d(R)
                FUN_1000d26b                              XREF[1]:     FUN_1000323c:10003a74(c)
```

References to FUN_1000d126 - 4 locations [CodeBrowser: ghidra_project:/emotet.dll]

Help

References to FUN_1000d126 - 4 locations

Location	Label	Code Unit	Context	Function Name
10003916		CALL FUN_1000d126	UNCONDITIONAL_CALL	FUN_1000323c
10003a49		CALL FUN_1000d126	UNCONDITIONAL_CALL	FUN_1000323c
1000c63f		CALL FUN_1000d126	UNCONDITIONAL_CALL	FUN_1000c351
1000e7f8		CALL FUN_1000d126	UNCONDITIONAL_CALL	FUN_1000e6f1

Change Data Type

- 関数や変数の型の変更
  - 右クリックメニューから選択

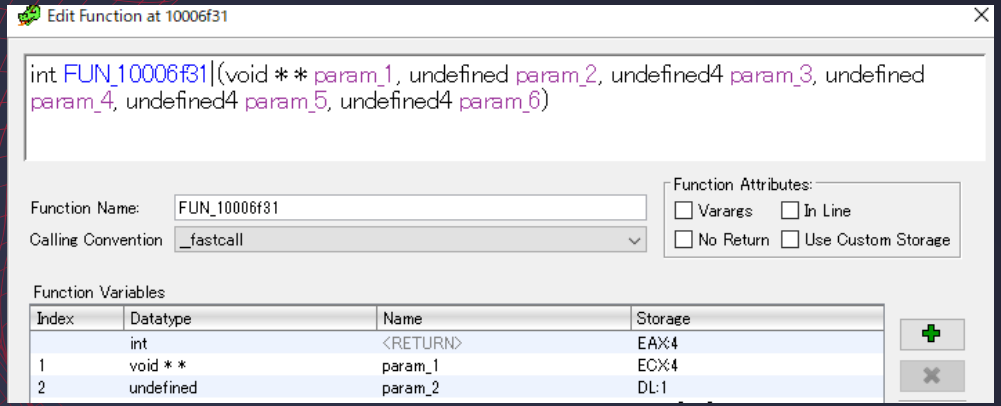

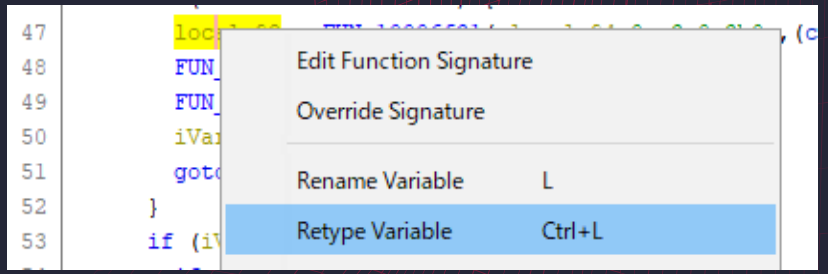

Ghidra Script

Ghidra Script

Ghidraの各種操作を自動化・効率化する機能

- こんなことができる
  - ✓ バイト列の検索やコメントの付与など、手動作業の自動化
  - ✓ 大量のファイルのインポート・解析処理など、反復作業の自動化
  - ✓ 暗号化されたデータや文字列の復号など、解析の自動化
  - ✓ エミュレータによる実行

Ghidra API

- スクリプトからGhidraの機能にアクセスするためのAPI
- JavaとPython (Jython2.7) で実装が可能

Python実装の例

Ghidra > ghidra_9.1.2_PUBLIC > Ghidra > Features > Python > ghidra_scripts > ghidra_basics.py > ...

```
1   # Examples of basic Ghidra scripting in Python
2   # @category: Examples.Python
3
4   # Get info about the current program
5   print
6   print "Program Info:"
7   program_name = currentProgram.getName()
8   creation_date = currentProgram.getCreationDate()
9   language_id = currentProgram.getLanguageID()
10  compiler_spec_id = currentProgram.getCompilerSpec().getCompilerSpecID()
11  print "%s: %s_%s (%s)\n" % (program_name, language_id, compiler_spec_id, creation_date)
```

Type of Ghidra API

- Ghidra APIは大きく3つに分類でき、次のような階層構造になっている
  - ほとんどの場合で FlatProgram API/Script API さえ理解していれば事足りる
  - なにか必要な機能があったらまずはFlatProgramAPIのドキュメントを検索する

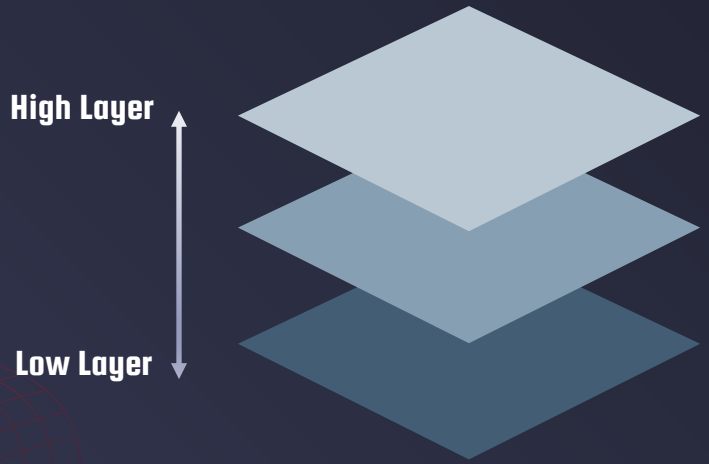

- **Script API**
  https://ghidra.re/ghidra_docs/api/ghidra/app/script/GhidraScript.html
- **FlatProgram API**
  https://ghidra.re/ghidra_docs/api/ghidra/program/flatapi/FlatProgramAPI.html
- **Program API**
  https://ghidra.re/ghidra_docs/api/ghidra/program/model/listing/Program.html

Script Manager

- Ghidra Scriptの実行や管理を行う機能

Script Managerの起動手順

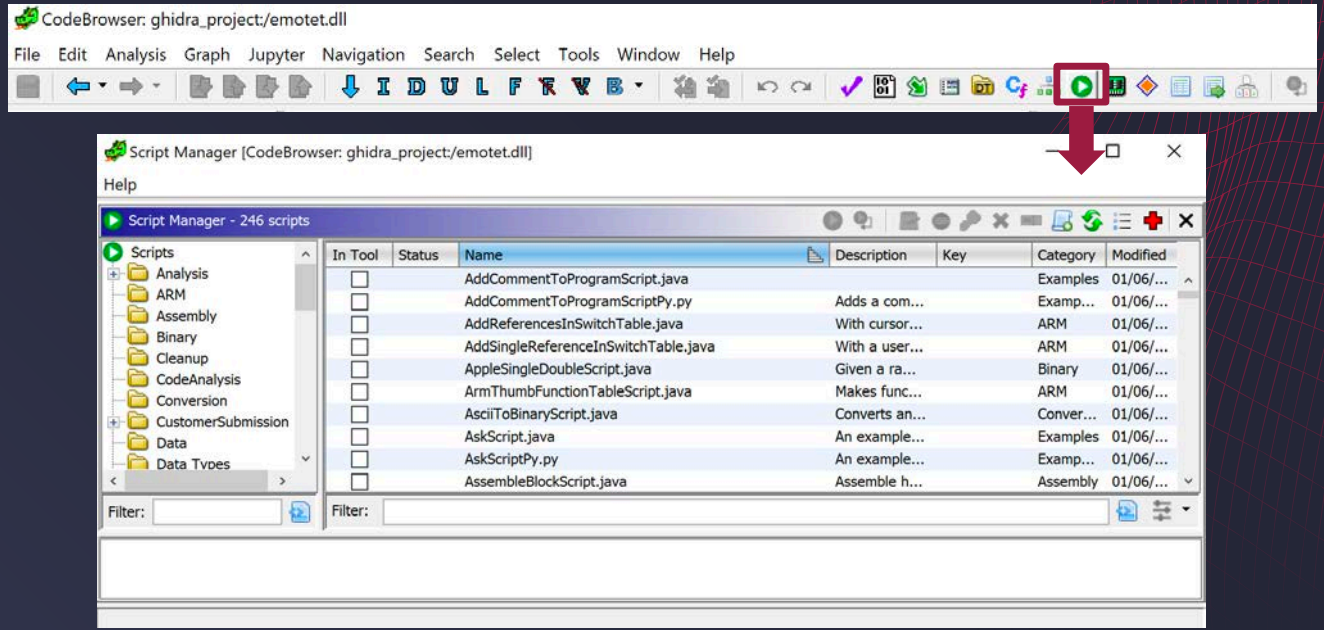

Built-in Python Interpreter

- ビルトインのPythonインタプリタが提供されている
  - メニューの「Window」＞「Python」で起動

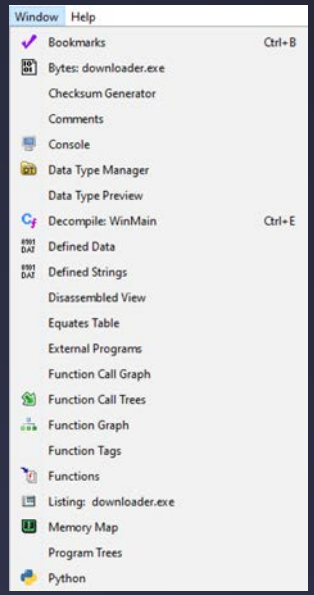

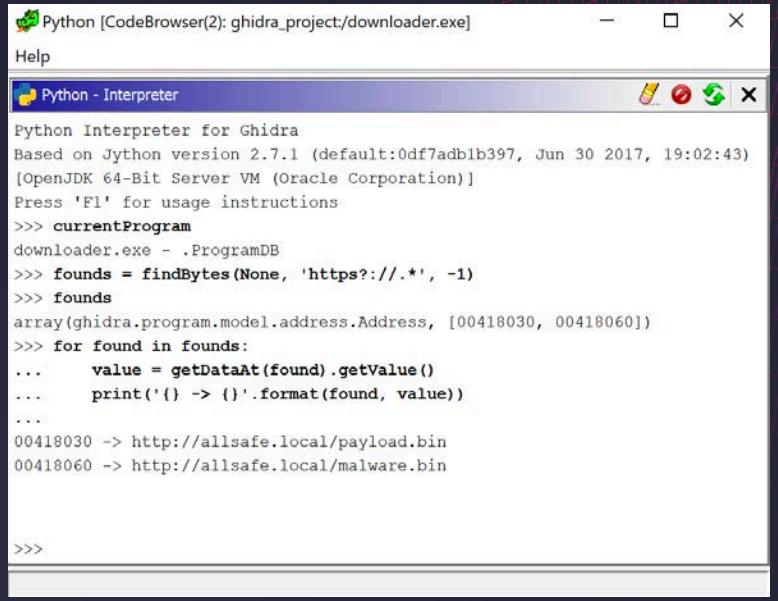

Why Interpreter?

検証のためのトライアンドエラーに便利

Why Interpreter? Pt.I

- 変数内部のデータを都度確認しながら処理を記述できる

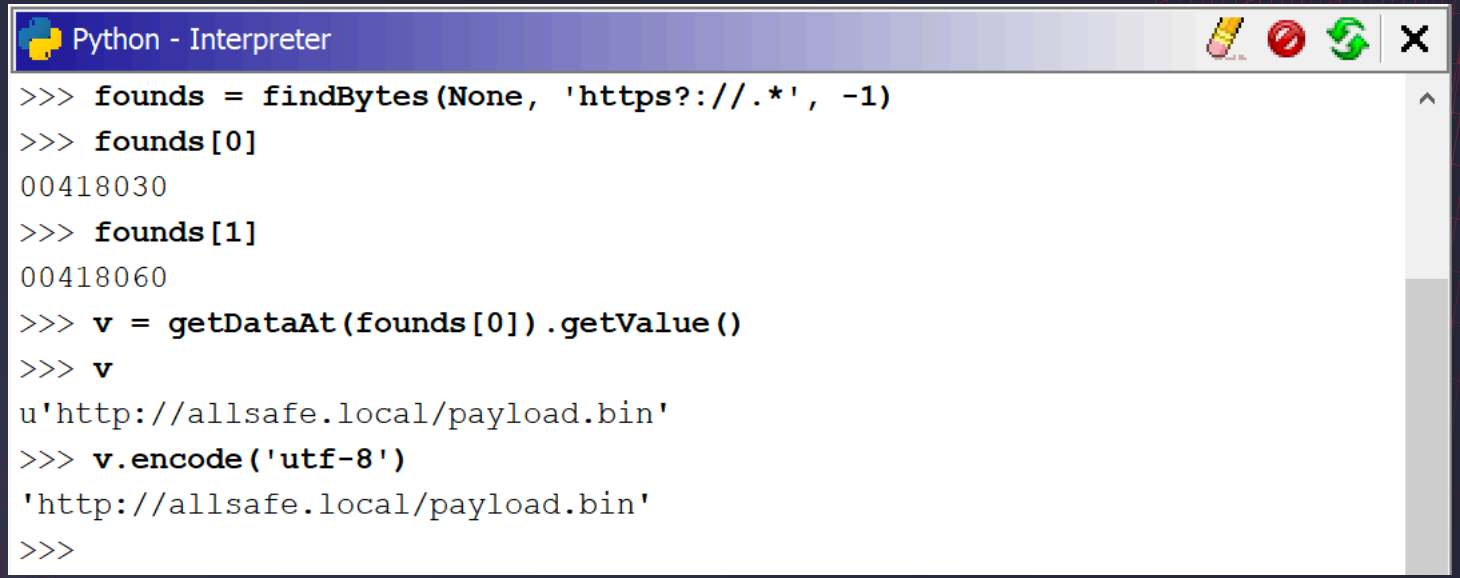

Why Interpreter? Pt.2

- コード補完してくれる
  - 入力中にTabを押すと利用可能なメソッドを表示してくれる

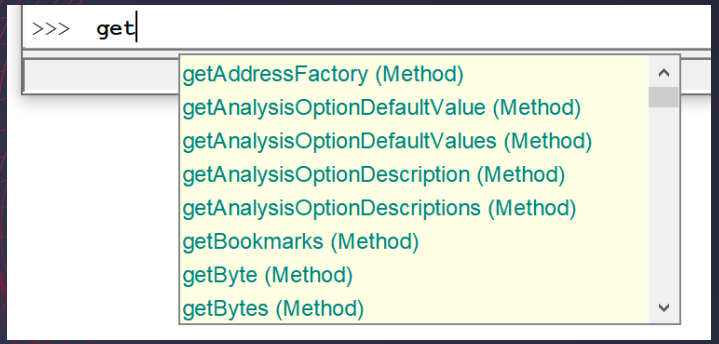

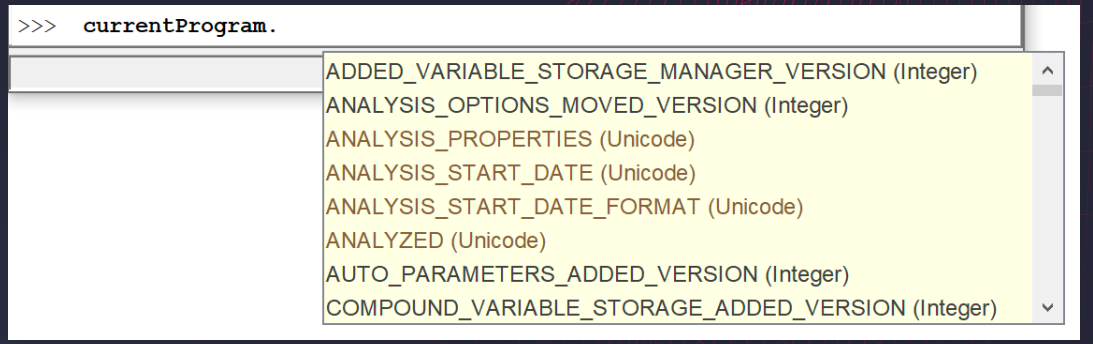

Why Interpreter? Pt.3

- APIのヘルプが参照できる
  - `help` に参照したいオブジェクトを渡す

インターフェイス名がわかれば検索できる

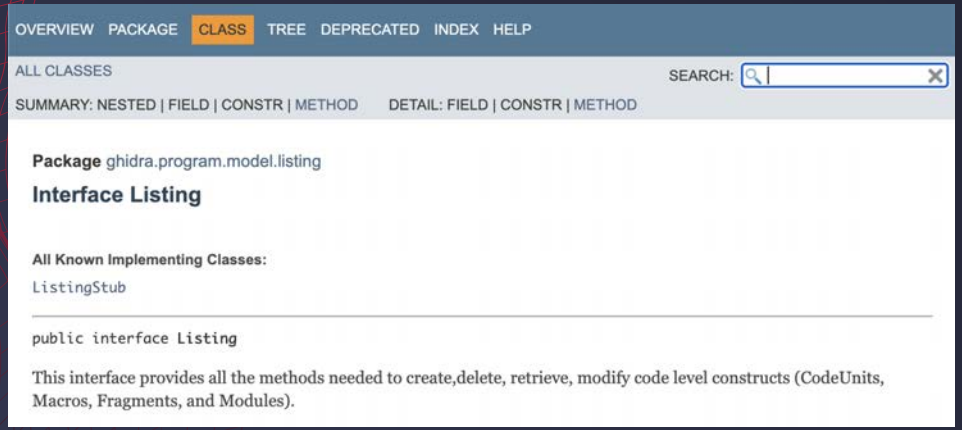

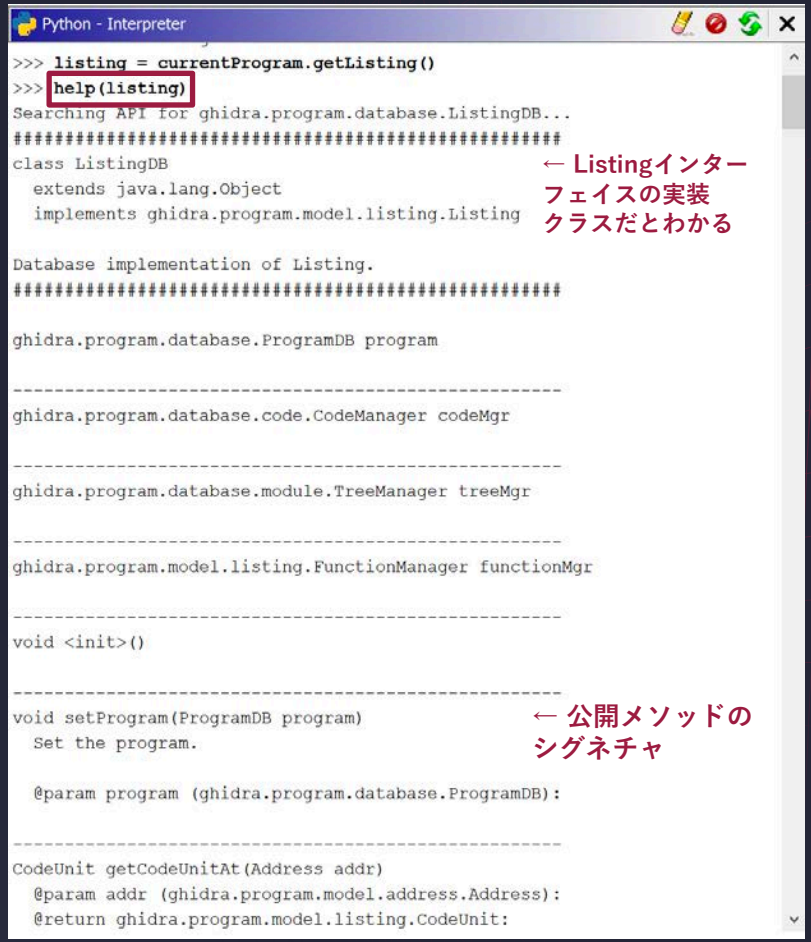

Interpreter Tips ～ import ～

- 複数行にわたるペーストができないので、関数などがコピー＆ペーストできない
- なので、使いたい関数やクラスをスクリプト内で定義しておき、**import** する
  - `import` で読み込めるファイルはScript Directories配下に存在しているファイルのみなので、今回は`C:¥Ghidra¥ghidra_scripts`配下に配置する
  - Script Directoriesに登録された別フォルダに同名のファイルが存在するとエラーの原因になるので、ユニークにする

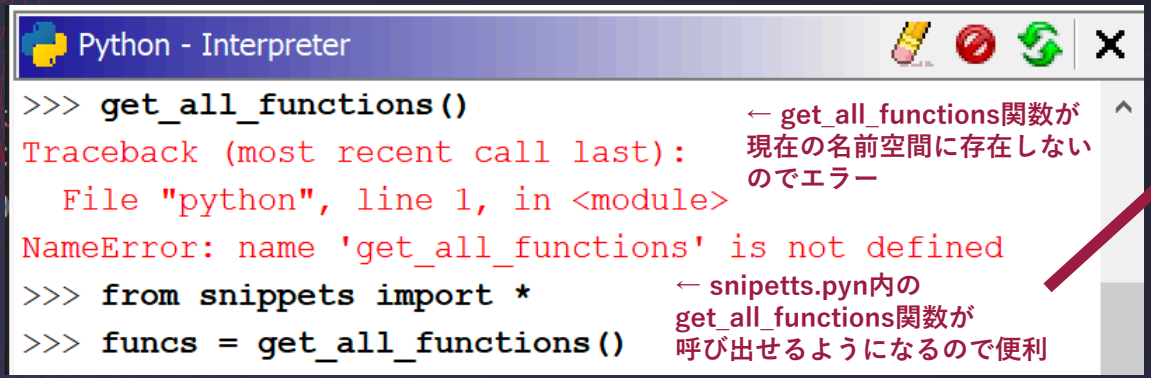

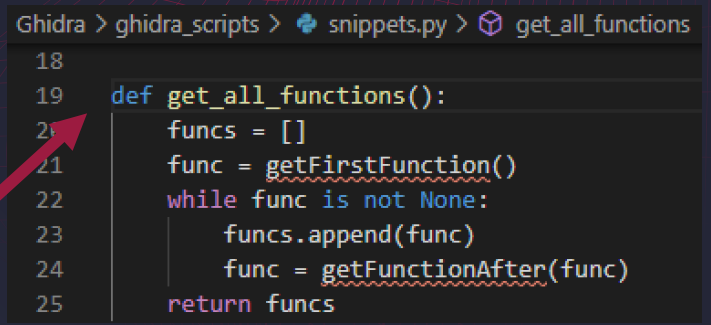

Interpreter Tips ～ import ～

- ただし、そのままだとインポートされたスクリプト側からGhidra APIを参照できないので、次のimport文を必ずスクリプトの最初に記述しておく！（重要）

Ghidra > ghidra_scripts > snippets.py

```
1   from __main__ import *
2
```

Interpreter Tips ～ reload ～

- すでにimport済みのスクリプトを編集した後再度importするには、**reload** を使う
  - 例えば、一度importしたがエラーが出たのでスクリプト内の関数を書き換えた場合など
  - Pythonは一度importしたコードをコンパイルしてキャッシュしているので、importだけでは更新が反映されないのが原因

Python - Interpreter

```
>>> import snippets
>>> snippets.test_func()
'first run'
>>> reload(snippets)
<module 'snippets' from 'C:\Ghidra\ghidra_scripts\snippets.py'>
>>> snippets.test_func()
'reloaded!'
```

← この後のタイミングで編集

← reloadで編集を反映

編集された関数

```
def test_func():
    #return 'first run'
    return 'reloaded!'
```

Interpreter Tips ～ reload ～

- ただし、`from name import *` でimportしている場合、↓のように`sys.module['name']`をreloadしてから再インポートする必要がある

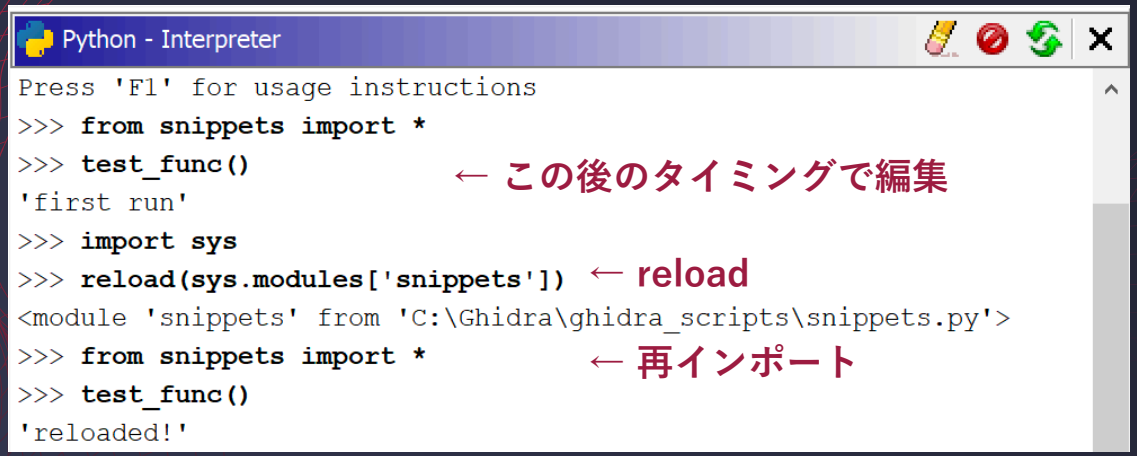

編集された関数

```python
def test_func():
    #return 'first run'
    return 'reloaded!'
```

Headless Analyzer

CLIからGhidra Scriptを操作するための機能

- ユーザインタラクションが不要なので、バッチ処理が可能
- バッチ処理により、ファイルのインポートや解析処理の自動化が可能

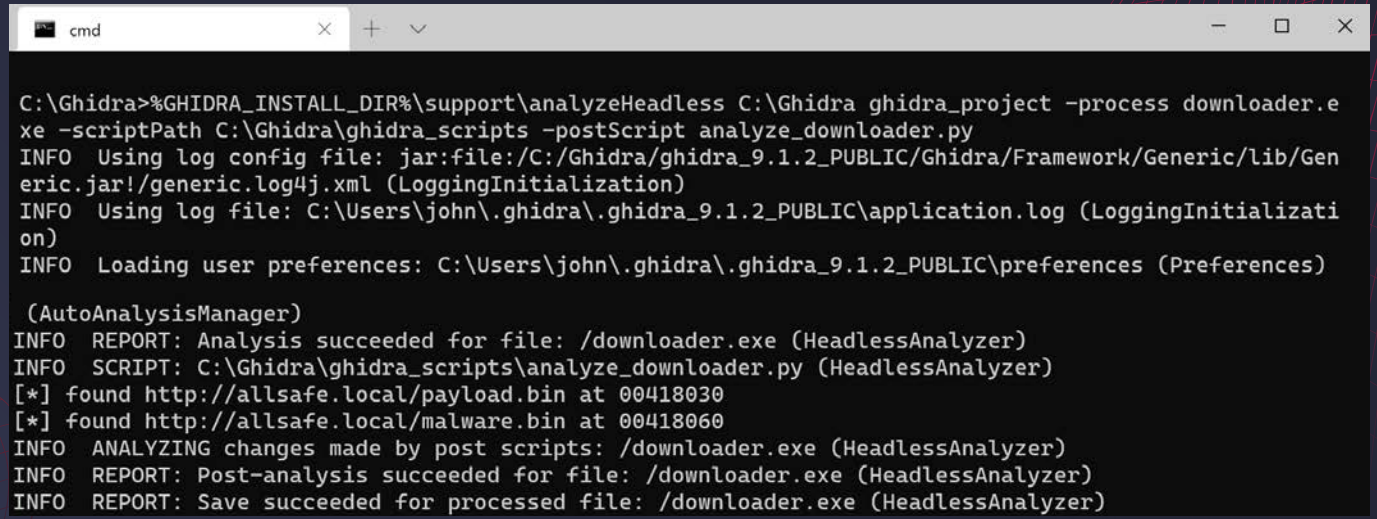

Ghidra API Quick Reference

FlatProgramAPI Class

Program APIのラッパークラス

- https://ghidra.re/ghidra_docs/api/ghidra/program/flatapi/FlatProgramAPI.html

Fields

- `protected Program currentProgram`
  - 現在読み込んでいるプログラムに関する様々な情報を保持するフィールド，Program APIを提供する

Methods

- `Address[] findBytes(Address start, java.lang.String byteString, int matchLimit)`
  - 指定したバイト列（Python2では文字列と同じ）を検索してヒットしたアドレス一覧を返す
- `byte[] getBytes(Address address, int length)`
  - 指定したaddressから指定したlength分をバイト列として取得
- `Function getFirstFunction()`
  - 現在読み込んでいるプログラムの最初の関数を取得
- `Instruction getInstructionAt(Address address)`
  - 指定したaddressの命令を取得
- `Instruction getInstructionBefore(Address address)`
  - 指定したaddressの一つ手前（低位アドレス）の命令を取得，一つ先（高位アドレス）の命令を取得するgetInstructionAfterもある
- `Function getFunctionContaining(Address address)`
  - 指定したaddressを含む関数を取得
- `Reference[] getReferencesTo(Address address)`
  - 指定したaddressの参照元（=addressを参照しているオブジェクト）一覧を取得
- `Address toAddr(int offset)`
  - 指定した値をAddressオブジェクトに変換

FlatProgramAPI Class Use-Case: 01. Address Manipulation

- `Address toAddr(int offset)`
- `Address toAddr(long offset)`
- `Address toAddr(String address)`
  - 指定した値をAddressオブジェクトに変換

数値や文字列をAddressオブジェクトに変換し、比較

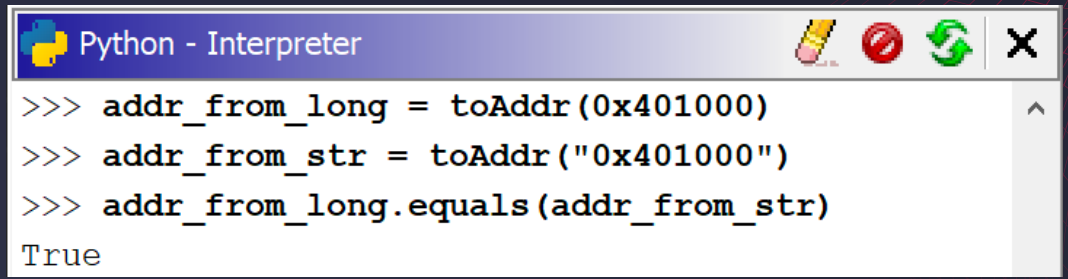

Address Interface

アドレスを表現するインターフェイス

- https://ghidra.re/ghidra_docs/api/ghidra/program/model/address/Address.html

Methods

- `Address add(long displacement)`
  - アドレスを引数displacementのサイズ分加算し、新しいAddressを返す
- `boolean equals(java.lang.Object o)`
  - 引数oとアドレスを比較
- `long getOffset()`
  - アドレスのオフセットをlongで返す
- `Address next()`
  - 次のアドレスを返す

オフセット値の取得

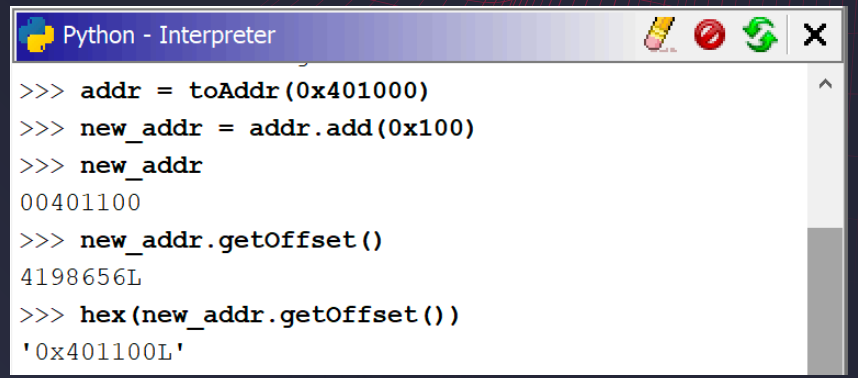

FlatProgramAPI Class Use-Case: 02. Binary Manipulation

- `byte[] getBytes(Address address, int length)`
  - 指定したaddressから指定したlength分をバイト列として取得
- `int getInt(Address address)`
  - 指定したaddressから4バイトをintとして取得

特定のアドレスから、指定したサイズ分バイト列の読み出し

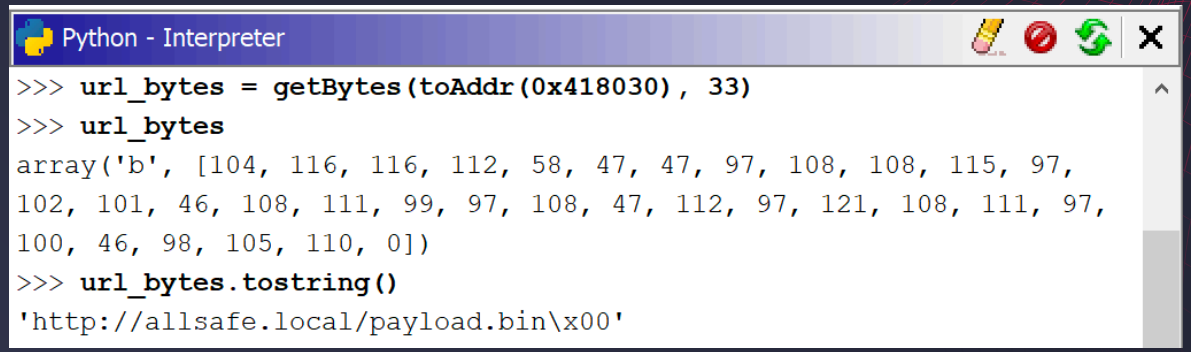

FlatProgramAPI Class Use-Case: 03. Search

- `Address find(java.lang.String text)`
  - プログラム内のコメントやラベル、コードユニットのやオペランドなどから、引数のtextで与えられた文字列を検索
  - 最初にマッチした結果のアドレスが返される
- `Address find(Address start, byte[] values)`
  - 第1引数にAddressオブジェクトが渡されると、引数startで指定したアドレス以降のプログラムのメモリからvalueで指定したバイト列を検索し、最初にマッチした結果のアドレスを1つだけ返す
  - 正規表現はサポートされていない
- `Address[] findBytes(Address start, java.lang.String byteString, int matchLimit)`
  - 引数startで指定したアドレス以降のメモリから、byteStringで指定された値を検索
  - このメソッドは、byteStringで正規表現を使うことも可能、例えば任意の4バイトをマッチさせたい場合「.{4}」といった表現を使用可能

レジスタへの
MOV命令を検索

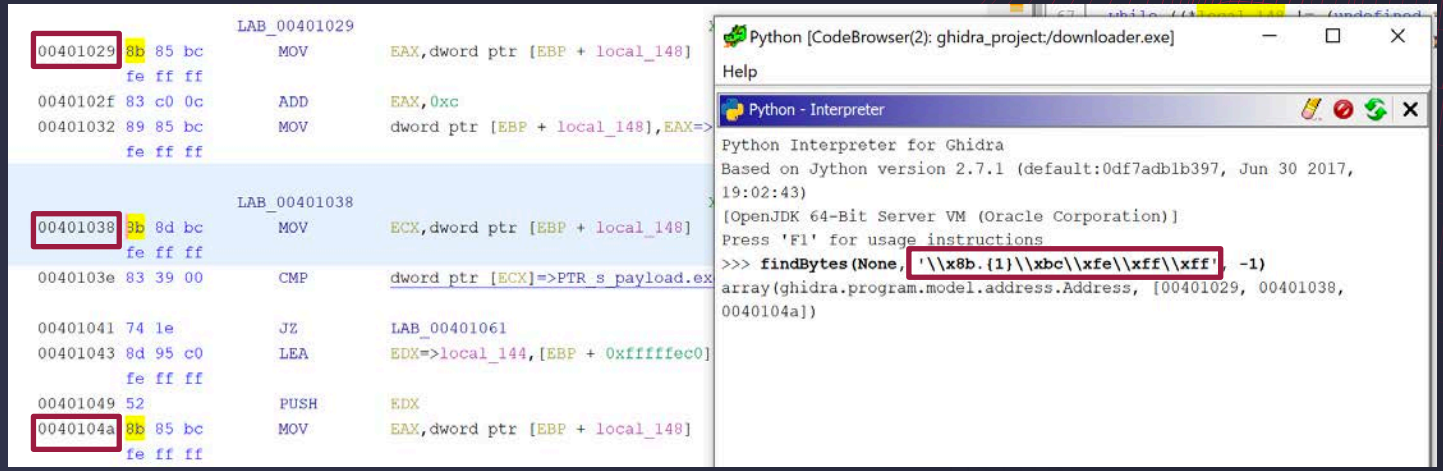

FlatProgramAPI Class Use-Case: 04. Function Manipulation

- `Function getFirstFunction()`
  - 現在のプログラムの最初の関数オブジェクトを取得
- `Function getFunctionAt(Address entryPoint)`
  - 引数entryPointで指定したアドレスから始まる関数オブジェクトを取得
- `Function getFunctionAfter(Address address)`
  - 引数addressで指定したアドレスで始まる関数の次の関数オブジェクトを取得
- `Function getFunctionBefore(Address address)`
  - 引数addressで指定したアドレスで始まる関数の前の関数オブジェクトを取得
- `Function getFunctionContaining(Address address)`
  - 引数addressで指定したアドレスが関数のアドレスレンジに含まれる場合、その関数オブジェクトを取得

プログラム内の全関数を列挙

Python - Interpreter

```
>>> def get_all_functions():
...     func = getFirstFunction()
...     while func is not None:
...         yield func
...         func = getFunctionAfter(func)
...
>>> funcs = get_all_functions()
>>> for func in funcs:
...     print('func: {} at {}'.format(func.getName(), func.getEntryPoint()))
...
func: FUN_00401000 at 00401000
func: FUN_004011e0 at 004011e0
func: FUN_00401220 at 00401220
func: FUN_00401260 at 00401260
```

Function Interface

関数を表現するインターフェイス

- https://ghidra.re/ghidra_docs/api/ghidra/program/model/listing/Function.html

Methods

- `Address getEntryPoint()`
  - 関数のエントリーポイント（先頭アドレス）を取得
- `java.lang.String getName()`
  - 関数の名前を取得
- `Parameter[] getParameters()`
  - 関数の引数を`Parameter`オブジェクトで取得

FlatProgramAPI Class Use-Case: 05. Instruction Manipulation

- `Instruction getFirstInstruction(Function function)`
  - 引数functionで指定した関数オブジェクトに含まれる、最初の命令を取得
- `Instruction getInstructionAt(Address address)`
  - 引数addressで指定したアドレスの命令を取得
- `Instruction getInstructionAfter(Instruction instruction)`
  - 引数instructionで指定した命令の次（高位アドレス）の命令を取得
- `Instruction getInstructionBefore(Instruction instruction)`
  - 引数instructionで指定した命令の1つ前（低位アドレス）の命令を取得
  - 関数呼び出しを行うCALL 命令に対する引数をたどる際などに利用可能

特定の関数内の全ての命令を取得

Python - Interpreter

```
>>> def get_instructions_in_func(func):
...     inst = getFirstInstruction(func)
...     while inst is not None:
...         if getFunctionContaining(inst.getAddress()) == func:
...             yield inst
...             inst = getInstructionAfter(inst)
...
>>> entry_func = getFirstFunction()
>>> insts = get_instructions_in_func(entry_func)
>>> for inst in insts:
...     print('{} {}'.format(inst.getAddressString(True, True), inst))
...
.text:00401000 PUSH EBP
.text:00401001 MOV EBP,ESP
.text:00401003 SUB ESP,0x19c
.text:00401009 MOV EAX,[0x00418090]
.text:0040100e XOR EAX,EBP
```

Instruction Interface

命令を表現するインターフェイス

- https://ghidra.re/ghidra_docs/api/ghidra/program/model/listing/Function.html

Methods

- `java.lang.Object[] getOpObjects(int opIndex)`
  - 命令に渡されているオペランドのうち、opIndexで指定されたインデックスのオブジェクト（Address, Scalarなど）一覧を取得
- `java.lang.String getMnemonicString()`
  - 正確にはCodeUnitインターフェイスのメソッド
  - 命令のニーモニックを文字列として取得
- `PcodeOp[] getPcode()`
  - 命令をP-Codeという中間表現に変換
- `Register getRegister(int opIndex)`
  - 命令に渡されているオペランドのうち、opIndexで指定されたインデックスのレジスタオブジェクトを取得

FlatProgramAPI Class Use-Case: 06. Reference Manipulation

Ghidraはデータやコードなどのオブジェクト間の関係性を「参照」という情報として保持

- `Reference[] getReferencesTo(Address address)`
  - 引数addressで指定したアドレスへの参照を持つコードユニットのアドレス一覧を取得
  - つまり、 後方参照（クロスリファレンス）を取得
- `Reference[] getReferencesFrom(Address address)`
  - 引数addressで指定したコードユニットのアドレスが参照している先のアドレス、つまり前方参照の一覧 を取得

```
Python - Interpreter
>>> config_addr = toAddr(0x418000)
>>> xrefs = getReferencesTo(config_addr)
>>> xrefs
array(ghidra.program.model.symbol.Reference, [From: 0040024c To: 00418000 Type: DATA
Op: 0 DEFAULT, From: 0040101d To: 00418000 Type: DATA Op: 1 ANALYSIS, From: 0040103e
To: 00418000 Type: READ Op: 0 ANALYSIS, From: 00401050 To: 00418000 Type: DATA Op: 0
ANALYSIS])
>>> for xref in xrefs:
...     print('reference from {}'.format(xref.getFromAddress()))
...
reference from 0040024c
reference from 0040101d
reference from 0040103e
reference from 00401050
```

Reference Interface

参照を表現するインターフェイス

- https://ghidra.re/ghidra_docs/api/ghidra/program/model/symbol/Reference.html

Methods

- `Address getFromAddress()`
  - 参照しているコードのアドレス、つまり後方参照のアドレスを取得
- `Address getToAddress()`
  - 参照の「宛先」アドレス、つまり前方参照のアドレスを取得
- `RefType getReferenceType()`
  - 参照のタイプを取得
  - 参照タイプ：https://ghidra.re/ghidra_docs/api/ghidra/program/model/symbol/RefType.html

02
Automated Analysis of EMOTET

Goals of Malware Analysis

「解析」といっても目的（期待されるアウトプット）はさまざま

Detection	不正かどうかの判定、およびマルウェアのファミリ名やカテゴリを特定する。この作業により、マルウェアの目的や関連する攻撃者を認識することができる（可能性がある）。
Indicator of Compromise	ネットワークやホスト内において、侵害の有無を判断するための情報を特定する。作成されるファイル名やレジストリ名、通信先情報などが該当する。
Report	マルウェアの挙動・機能を含む解析レポート。Detection/IoCを含み、マルウェアの目的や背後の攻撃者について言及する。主に顧客向けに文章で記述される。

今回は**通信先情報の抽出**を目的とする

EMOTET

- 近年猛威をふるう、情報窃取兼ダウンローダー型マルウェア
  - 大量のスパム経由で配布されることが知られている
  - Human Operated Ransomwareの起点となることもある
- とにかく数が多い
  - 大量の亜種が短時間で配布される
  - かつそれぞれの検体が大量のC&C通信先をもつ

NICTによるEMOTETスパムの着信数推移

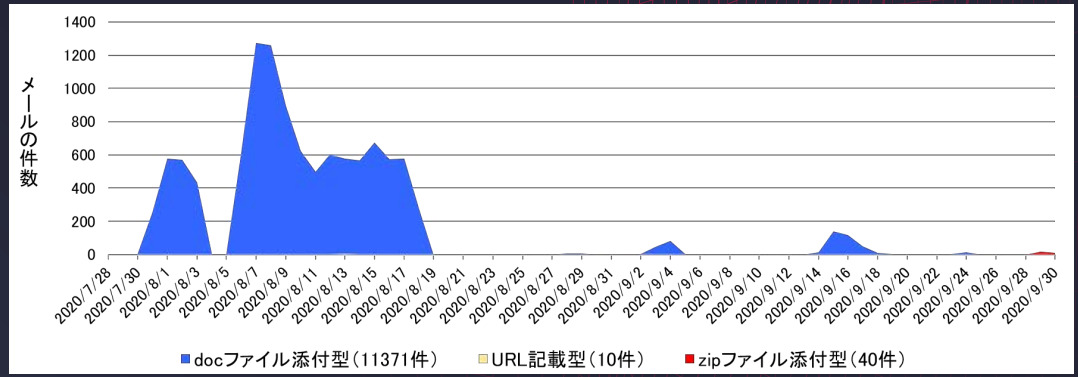

https://blog.nicter.jp/2020/10/emotet-mail-202007-202009/

How EMOTET works

Target

Spam

メール経由で侵入

Macro

マクロ付き
ドキュメント

PowerShell

PowerShellが
実行され、
EMOTET (Loader) をDL

EMOTET (Loader)

Rundll32.exe
経由で実行される

EMOTET (Payload)

C&Cサーバから
ペイロードを取得し、
オンメモリで実行される

Analysis Steps

以下のような点を解析によって明らかにし、スクリプトに落とし込む

✓パックされているか？

✓パッカーのロジック

✓文字列は難読化・暗号化されているか？

✓鍵は？

✓API呼び出しは難読化されているか？

✓C&Cサーバなどの情報はどこに/どのような形式で格納されているか？

✓どうやって自動抽出するか？

Step 0:
Determine Packing Logic and Do Unpack

他の多くのマルウェアと同じく、EMOTETもパックされており、メモリ上で
ペイロードが復号されて実行される

（ある時期の）EMOTETのアンパックロジック

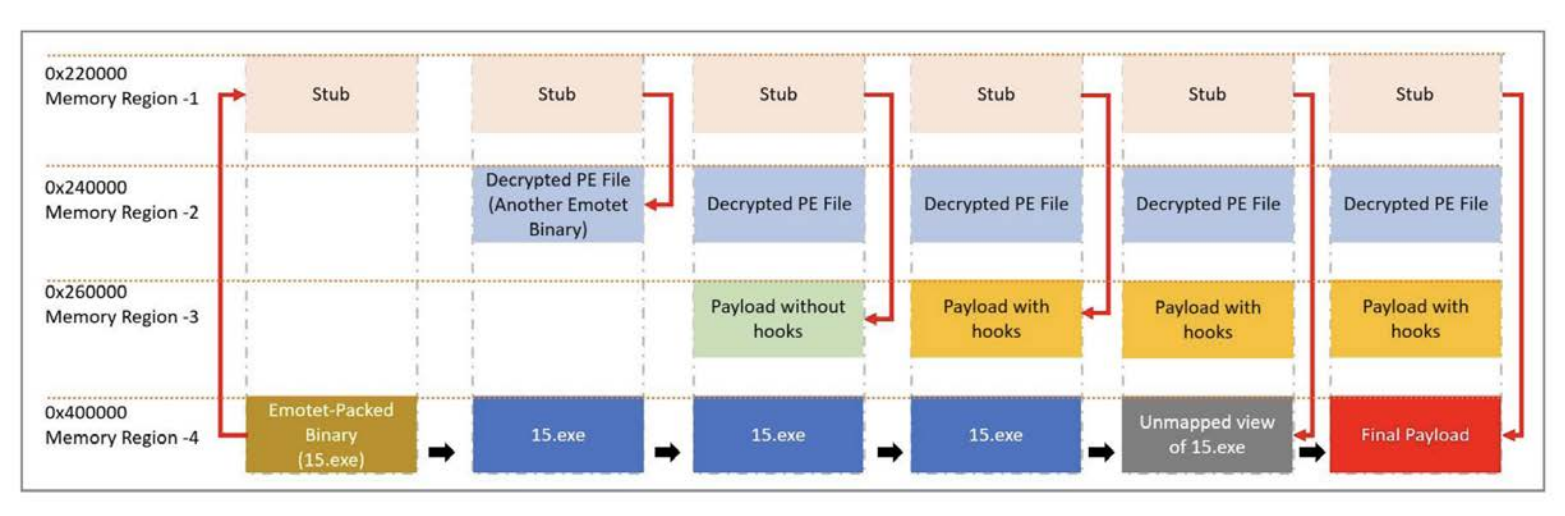

https://www.bromium.com/wp-content/uploads/2019/07/Bromium-Emotet-Technical-Analysis-Report.pdf

Step 0:
Determine Packing Logic and Do Unpack

アンパックの手法はさまざま

- **手動アンパック**
  - デバッガーを使ってアンパック
  - 実行後、マルウェア自身によってアンパックされた領域をダンプ
- **ツールによるアンパック**
  - マルウェアを実行、メモリ上からアンパック後の領域を機械的に抽出
    - ✓ PE-SIEVE / Hollows Hunter
- **自動アンパック**
  - ツールの自動実行
    - ✓ tknk_scanner
    - ✓ CAPE

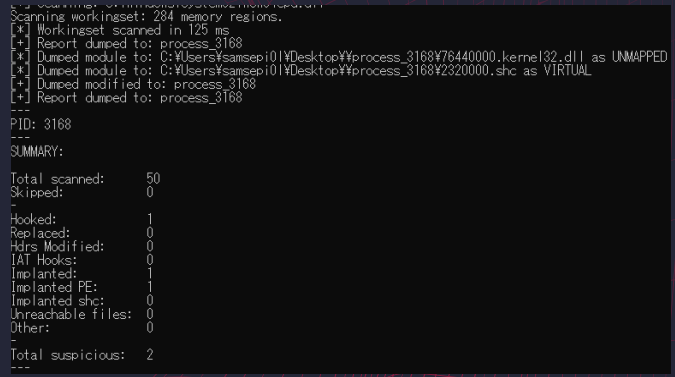

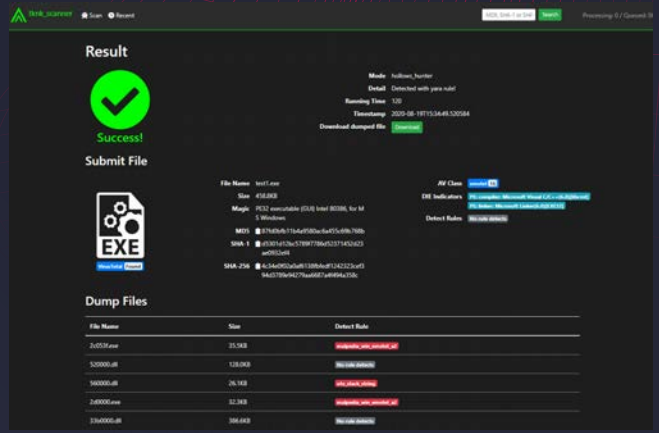

Quick Unpack with Hollows Hunter

- パックされたEMOTETを実行し、Hollows Hunterでアンパック後のEMOTETをダンプ
- 具体的な手順はAppendixを参照

```
C:\Users\john>rundll32.exe C:\Users\john\Desktop\urcwzowo.xck,Control_RunDLL
```

```
C:\Users\john\Desktop>C:\Users\john\Desktop\hollows_hunter.exe /pid 1336
HollowsHunter v.0.2.6 (x64)
Built on: Apr 13 2020

using: PE-sieve v.0.2.6.0
>> Scanning PID: 1336 (rundll32.exe)
[-] Invalid address of relocations
[-] Invalid address of relocations
>> Detected: 1336
--------
SUMMARY:
Scan at: 01/13/21 03:29:17 (1610476157)
Finished scan in: 3516 milliseconds
[+] Total Suspicious: 1
[+] List of suspicious:
[0]: PID: 1336, Name: rundll32.exe
```

Unpacked EMOTET

- 本ワークショップでは、アンパック済みのEMOTETを使用します

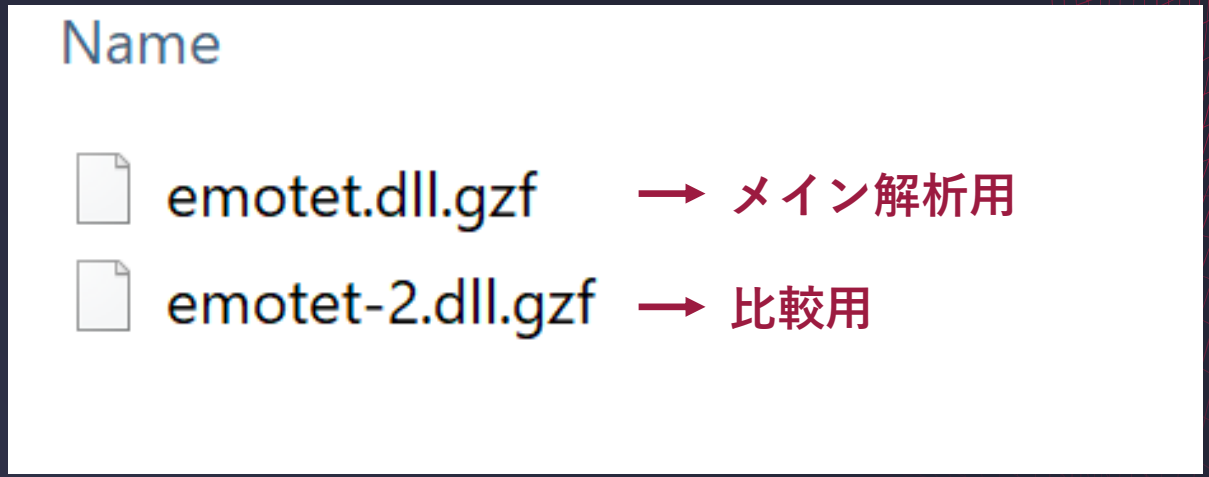

Step 1:
Surface Analysis

Resources

- 使用するサンプル等はJSAC参加者にのみSlackで共有済み
- 共有されたzipを展開し、以下手順を実施

1. **scripts**: 配下のファイルを`C:¥Ghidra¥ghidra_scripts`配下にコピー
   - `scripts¥answers`: 演習の回答なので、極力見ない
2. **emotet.dll.gzf**: Ghidraにドラッグ＆ドロップでインポート
3. **emotet-2.dll.gzf**: Ghidraにドラッグ＆ドロップでインポ
4. **winapi_32.gdt**: `C:¥Ghidra`直下にコピー

`C:¥Ghidra¥ghidra_scripts`配下が
以下のような構成になっていればOK

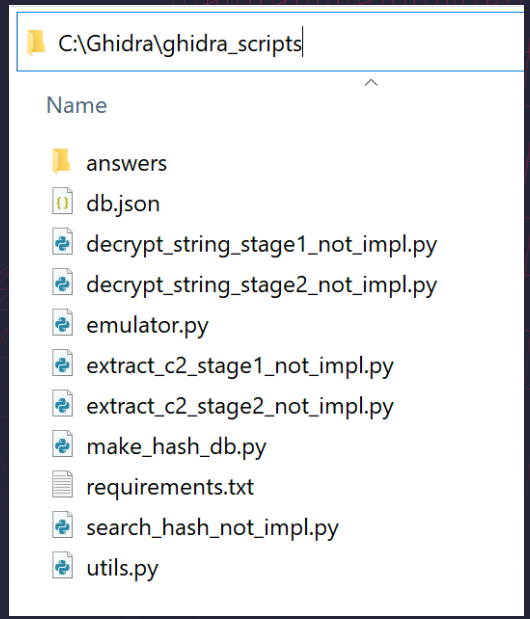

Setup (sample)

- 配布した`emotet.dll.gzf`をGhidraの既存プロジェクトにドラッグ&ドロップしてインポート
  - 途中ポップアップが出たら「OK」

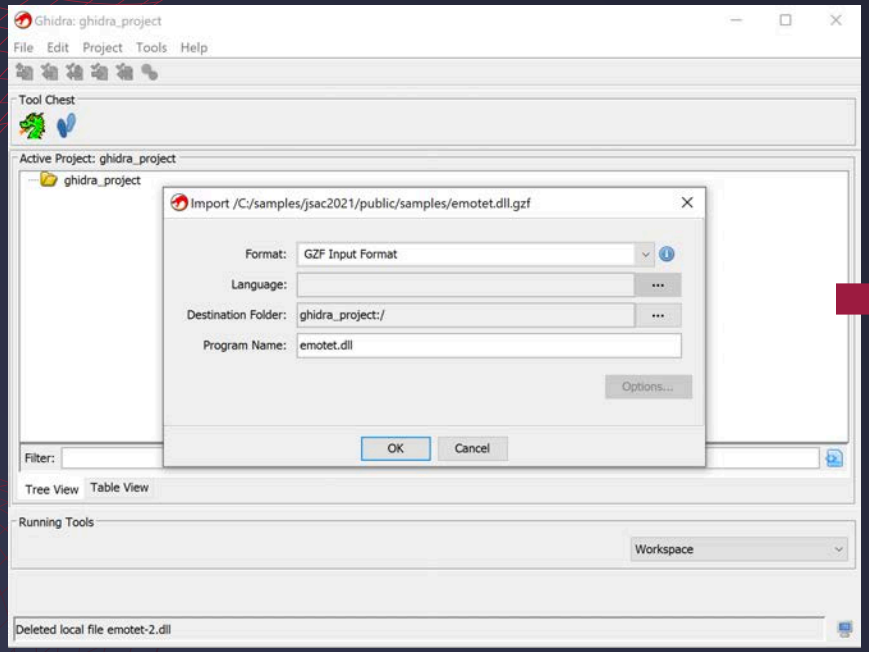

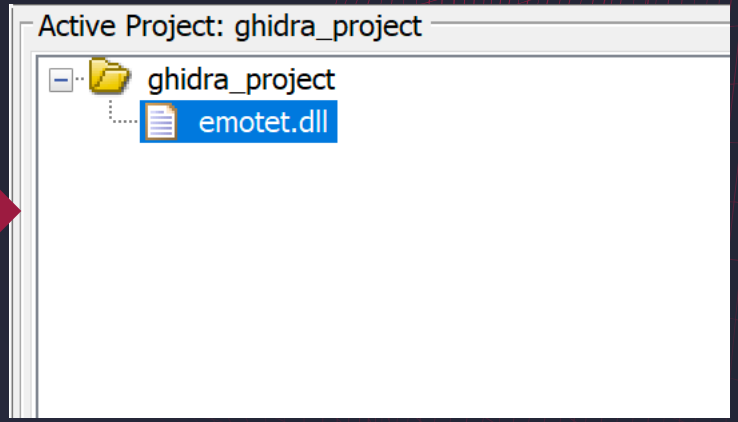

Setup (GDT)

- Ghidraの標準型データにはwininet.h、winhttp.hのAPI情報がない
  - Data Type Managerでwinapi_32.gdtをロード

▼ボタンを押してOpen File Archive

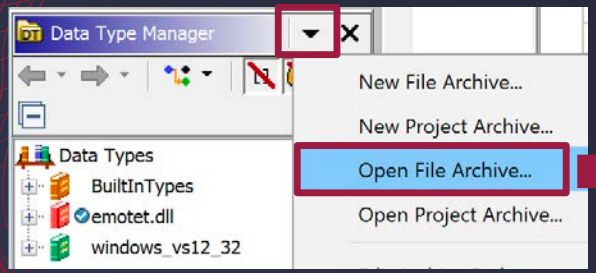

配布したファイルに含まれる
winapi_32.gdtをロード

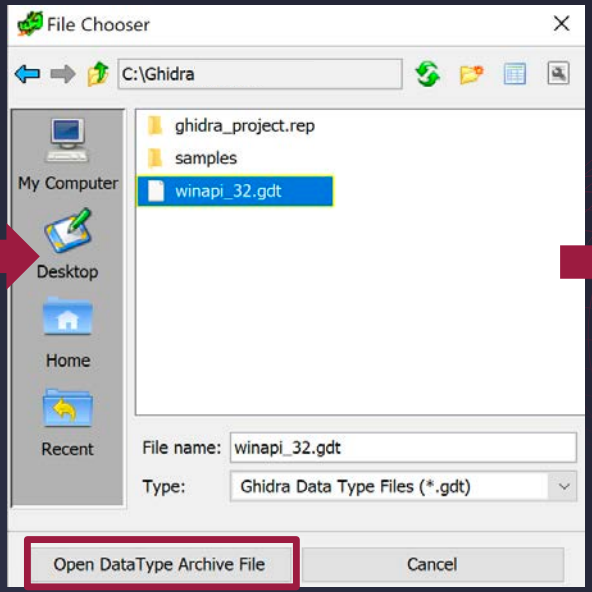

ロード完了後、winapi_32を
右クリックして
Apply Function Data Types

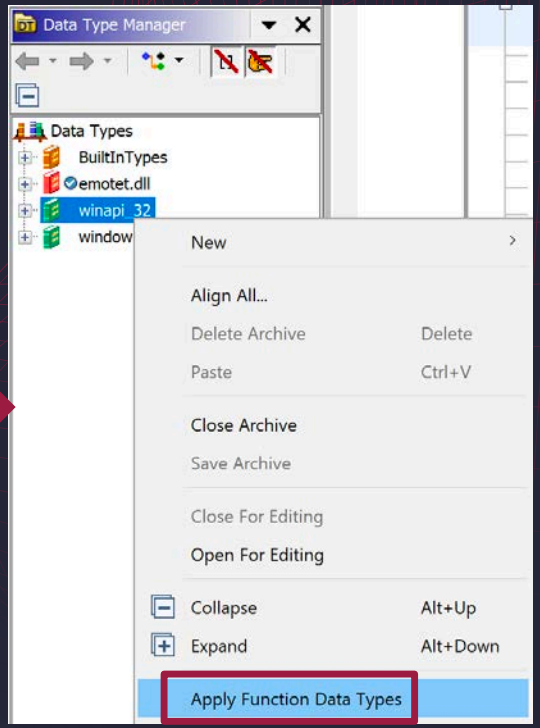

Setup (scripts)

スクリプトの設置

- 以下スクリプトが**C:¥Ghidra¥ghidra_scripts**配下にコピーされているか念のため確認
  1. `utils.py`: 演習等で再利用可能なユーティリティ関数群
  2. `search_hash_not_impl.py`: 演習用穴あきスクリプト
  3. `make_hash_db.py`: APIハッシュ用DB作成スクリプト
  4. `db.json`: APIハッシュ用DB
  5. `emulator.py`: エミュレータを使ったハッシュ計算スクリプト
  6. `decrypt_string_stage1_not_impl.py`: 演習用穴あきスクリプト
  7. `decrypt_string_stage2_not_impl.py`: 演習用穴あきスクリプト
  8. `extract_c2_stage1_not_impl.py`: 演習用穴あきスクリプト
  9. `extract_c2_stage2_not_impl.py`: 演習用穴あきスクリプト

Exports Functions

- DLL verのEmotetはrundll32.exeを使ってエクスポートされた関数から実行される

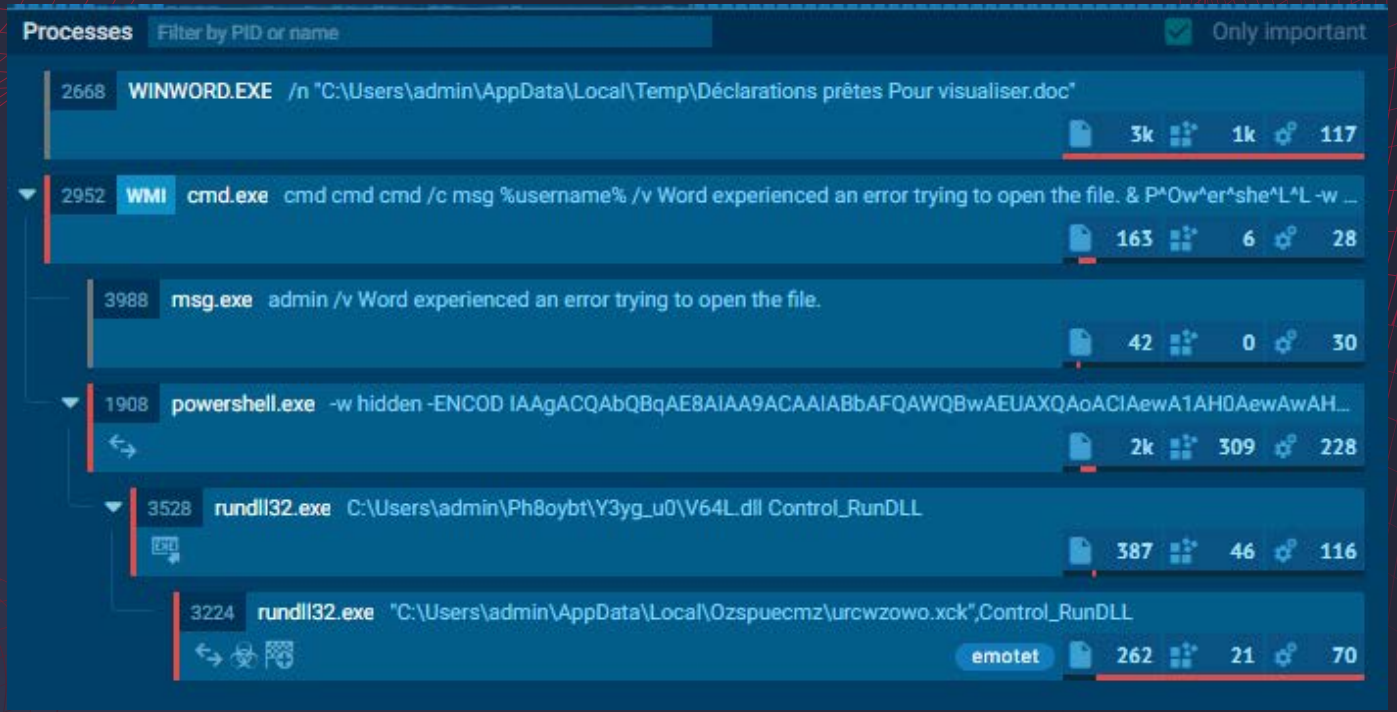

Brief Analysis (code)

- Garbage Code
  - 実行に影響を及ぼさない無駄なコード
  - Ghidraのデコンパイラがいい感じに端折ってくれる

```
                    FUN_1001900c                                    XREF[2]:

1001900c 55              PUSH    EBP
1001900d 8b ec           MOV     EBP,ESP
1001900f 83 e4 f8        AND     ESP,0xfffffff8
10019012 81 ec 40 ...    SUB     ESP,0x240
10019018 83 a4 24 ...    AND     dword ptr [ESP + local_a8+0x4],0x0
10019020 33 d2           XOR     EDX,EDX
10019022 83 a4 24 ...    AND     dword ptr [ESP + local_a0],0x0
1001902a b9 0c 8f ...    MOV     ECX,0x1e08f0c
1001902f c7 84 24 ...    MOV     dword ptr [ESP + local_a8],0x3b3e34
1001903a c7 84 24 ...    MOV     dword ptr [ESP + local_1c4],0x1bd7
10019045 81 8c 24 ...    OR      dword ptr [ESP + local_1c4],0x47dfde1a
10019050 81 84 24 ...    ADD     dword ptr [ESP + local_1c4],0xc6ff
1001905b 6b 84 24 ...    IMUL    EAX,dword ptr [ESP + local_1c4],0x5e
10019063 53              PUSH    EBX
10019064 55              PUSH    EBP
10019065 56              PUSH    ESI
10019066 57              PUSH    EDI
10019067 89 84 24 ...    MOV     dword ptr [ESP + local_1c4],EAX
1001906e 81 b4 24 ...    XOR     dword ptr [ESP + local_1c4],0x647d41bd
10019079 c7 84 24 ...    MOV     dword ptr [ESP + local_bc],0xaf04
10019084 81 8c 24 ...    OR      dword ptr [ESP + local_bc],0xe49f97e0
1001908f 81 b4 24 ...    XOR     dword ptr [ESP + local_bc],0xe49f8db7
1001909a c7 84 24 ...    MOV     dword ptr [ESP + local_148],0x8f5c
100190a5 81 b4 24 ...    XOR     dword ptr [ESP + local_148],0x9f735941
100190b0 c1 a4 24 ...    SHL     dword ptr [ESP + local_148],0x3
100190b8 81 b4 24 ...    XOR     dword ptr [ESP + local_148],0xfb9e8485
100190c3 c7 84 24 ...    MOV     dword ptr [ESP + local_ec],0xbddf
100190ce 81 84 24 ...    ADD     dword ptr [ESP + local_ec],0xffffe86b
100190d9 81 b4 24 ...    XOR     dword ptr [ESP + local_ec],0x8e69
100190e4 c7 84 24 ...    MOV     dword ptr [ESP + local_16c],0x603f
100190ef 6b 84 24 ...    IMUL    EAX,dword ptr [ESP + local_16c],0x30
100190f7 6a 58           PUSH    0x58
```

- Control Flow Flatting
  - Control Flow Obfuscationの手法
  - 直感的に命令フローが識別しづらい

```
  iVar4 = 0x1e08f0c;
  iVar3 = 0x7e01;
  uVar6 = 0x3b3e34;
LAB_1001a182:
  do {
    iVar1 = iVar4;
    if (iVar4 < 0x14cb6629) {
      if (iVar4 == 0x14cb6628) {
        local_98 = FUN_10006f31(&local_94,0xc3,0x3b0a,(char)iVar4,0x5dd7,0x2760);
        FUN_1000e10b(&local_98);
        FUN_10007c8f(0x111b);
        iVar4 = 0x15c12bf9;
        goto LAB_1001a182;
      }
      if (iVar4 < 0xa5688f5) {
        if (iVar4 == 0xa5688f4) {
          iVar4 = FUN_10014032();
          if (iVar4 == 0) {
            return;
          }
          iVar4 = 0x108d7d72;
          goto LAB_1001a182;
        }
        if (iVar4 < 0x4ebc5d3) {
          if (iVar4 == 0x4ebc5d2) {
            free_mem(local_54[0],0x3d,0x59f8,0x72a5);
            iVar4 = 0x2eb577a4;
            goto LAB_1001a182;
          }
          if (iVar4 == 0x13528f8) {
```

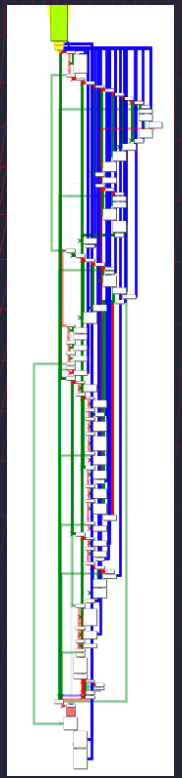

Brief Analysis (API/strings)

- アンパック後のEMOTETは Import Tableが空
  - 動的にAPIを解決している可能性

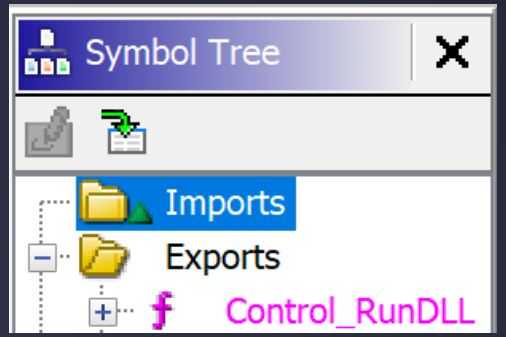

- APIに関連する文字列もなし
  - API含む文字列が暗号化・難読化されている可能性 🥺

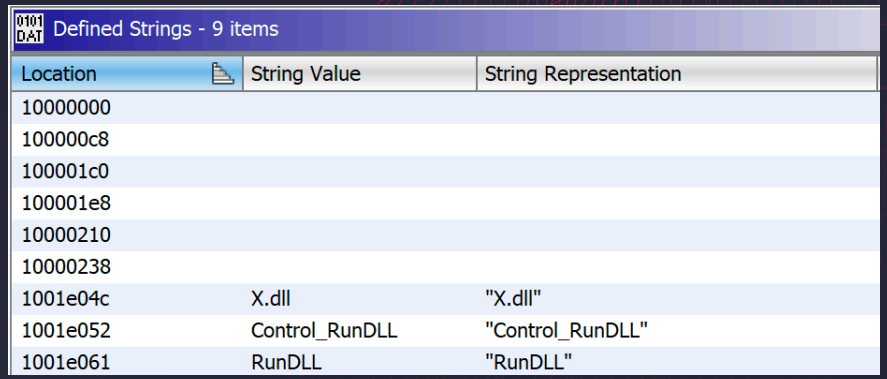

Where to start?

- APIの動的解決や文字列の復号に使用されている関数は実行時に何度も呼び出される
- そのため、まずは各関数が呼び出されている回数を調べて、呼び出し回数が多い関数をみていくことにする

utils.pyに定義済みのget_func_xref_count関数を実行し、
呼び出し回数の多い関数を列挙

Python - Interpreter

```
Python Interpreter for Ghidra
Based on Jython version 2.7.2 (v2.7.2:925a3cc3b49d, Mar 21 2020, 10:03:58)
[OpenJDK 64-Bit Server VM (Oracle Corporation)]
Press 'F1' for usage instructions
>>> from utils import *
>>> top10 = get_func_xref_count(n=10)
```

Python - Interpreter

```
>>> for called_func in top10:
...     print('{} is called {} times'.format(called_func['name'], called_func['count']))
...
FUN_10017e12 is called 160 times
FUN_10007d5b is called 107 times
FUN_10017f68 is called 34 times
FUN_1000d4e0 is called 33 times
FUN_10007c8f is called 28 times
FUN_1000732d is called 22 times
FUN_10002ec6 is called 16 times
FUN_100010cf is called 10 times
FUN_100150ba is called 8 times
FUN_10012199 is called 8 times
```

FUN_10017e12

- 最も多く呼び出されている関数
- RETするだけのジャンク関数
- 「 _ 」 など適当な名前に変えておく

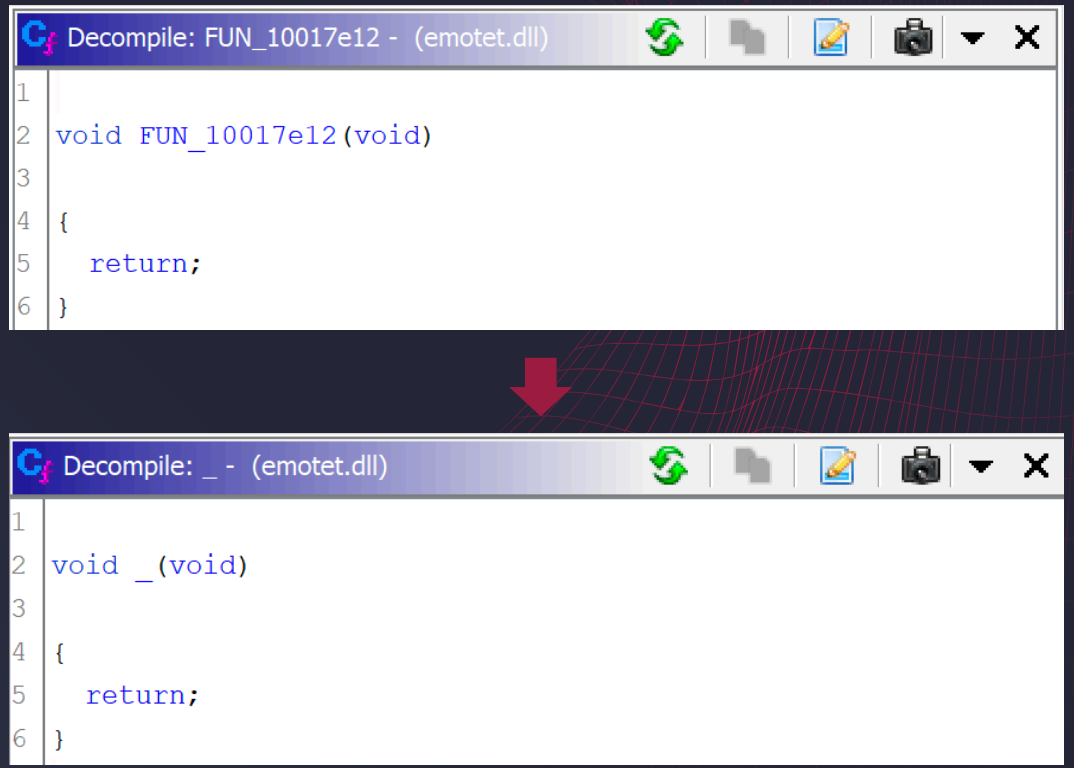

FUN_10007d5b

- 2番目に多く呼び出されている関数
- 4つの引数を受け取るが、実際は第二引数は未使用
- DAT_1001fa20はグローバル変数の配列

FUN_10007d5bの呼び出し例（@0x10017e02）

```
pcVar1 = (code *)FUN_10007d5b(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
```

Decompile: FUN_10007d5b - (emotet.dll)

```
1
2  undefined4 __cdecl FUN_10007d5b(int param_1,undefined4 param_2,uint param_3,uint param_4)
3
4  {
5    int iVar1;
6    char *pcVar2;
7
8    if (*(int *)(&DAT_1001fa20 + param_1 * 4) == 0) {
9      iVar1 = FUN_10004ae6(param_3);
10     pcVar2 = FUN_10012794(0x7ef7,iVar1,0x7a71,param_4);
11     *(char **)(&DAT_1001fa20 + param_1 * 4) = pcVar2;
12   }
13   return *(undefined4 *)(&DAT_1001fa20 + param_1 * 4);
14 }
```

各要素が4バイトの配列？

第一引数は配列のインデックス

FUN_10007d5b

- 変数名・型名の変更

BEFORE	AFTER (name)	AFTER (type)
DAT_1001fa20	g_array	int[0x64]
param_1	index	N/A
param_2	_	N/A
param_3	hex_value1	N/A
param_4	hex_value2	N/A

少し見やすくしたFUN_10007d5b

Decompile: FUN_10007d5b - (emotet.dll)

```
1
2  int __cdecl FUN_10007d5b(int index,undefined4 _,uint hex_value1,uint hex_value2)
3
4  {
5    int iVar1;
6    char *pcVar2;
7
8    if (g_array[index] == 0) {
9      iVar1 = FUN_10004ae6(hex_value1);
10     pcVar2 = FUN_10012794(0x7ef7,iVar1,0x7a71,hex_value2);
11     g_array[index] = (int)pcVar2;
12   }
13   return g_array[index];
14 }
```

Step 2:
API Hashing and Dynamic Call

How Windows APIs are resolved

- **暗黙的な解決**
  - コンパイル時に、必要なAPIがインポートテーブルに定義され、実行時にOSが暗黙的にDLLをロードし、APIを解決する
  - 普通にコンパイルするとこの方法で解決される
- **明示的な解決**（動的API解決）
  - `LoadLibrary / GetProcAddress` を用いて実行時に動的にAPIを呼び出す
  - API名から簡単に利用するAPIが識別されてしまう

`MessageBoxA`を明示的に解決して呼び出す例

```
FARPROC MessageBoxA = GetProcAddress(LoadLibraryA("user32.dll"), "MessageBoxA");
MessageBoxA(NULL, "Hello world", "Hello", MB_OK);
```

API Hashing

- 動的にWindows APIを解決する際に用いられる耐解析手法の一つ
- 既知、もしくは独自実装のハッシュ関数でAPI名をハッシュ化して保持しておき、実行時に、エクスポートされたAPI名を列挙してハッシュ関数の計算結果が同じAPIを動的に呼び出す

例: CRC32を使用してAPI名をハッシュ化し、実行時に比較して動的に解決

擬似コード

```
CreateFileA = resolve_api(0x553B5C78);
CreateFileA(...);
```

FUN_10004ae6

- FUN_10002b48の呼び出し
  - in_FS_OFFSET（=FSレジスタ）へのアクセス
  - x86 の場合、FSレジスタには TEB (Thread Environment Block) へのポインタが格納されている
- FUN_100180eaの呼び出し

Decompile: FUN_10004ae6 - (emotet.dll)

```
1
2  undefined4 __cdecl FUN_10004ae6(uint param_1)
3
4  {
5    int iVar1;
6    uint uVar2;
7    undefined4 *puVar3;
8    undefined4 *puVar4;
9
10   iVar1 = FUN_10002b48();
11   puVar4 = (undefined4 *)(*(int *)(iVar1 + 0xc) + 0xc);
12   puVar3 = (undefined4 *)*puVar4;
13   while( true ) {
14     if (puVar3 == puVar4) {
15       return 0;
16     }
17     uVar2 = FUN_100180ea((ushort *)puVar3[0xc],2,0x639b);
18     if ((uVar2 ^ 0x1fc325da) == param_1) break;
19     puVar3 = (undefined4 *)*puVar3;
20   }
21   return puVar3[6];
22 }
```

Decompile: FUN_10002b48 -...

```
1
2  undefined4 FUN_10002b48(void)
3
4  {
5    int in_FS_OFFSET;
6
7    return *(undefined4 *)(in_FS_OFFSET + 0x30);
8  }
```

Thread Environment Block / Process Environment Block

- **Thread Environment Block** (TEB)
  - 現在のスレッドに関する情報を保持する構造体
  - FSセグメントレジスタからアクセス可能
    (x86 Windowsにおいて)
- **Process Environment Block** (PEB)
  - 現在のプロセスに関する情報を保持する構造体
    - ➢ プロセスに読み込まれているDLLや、
      ヒープの状態、実行ファイルの情報など
  - TEB構造体のオフセット0x30からアクセス可能

FSレジスタ経由でTEBにアクセスし、
そこからPEBにアクセスしている

```
undefined4 FUN_10002b48(void)

{
  int in_FS_OFFSET;

  return *(undefined4 *)(in_FS_OFFSET + 0x30);
```

Thread Environment Block / Process Environment Block

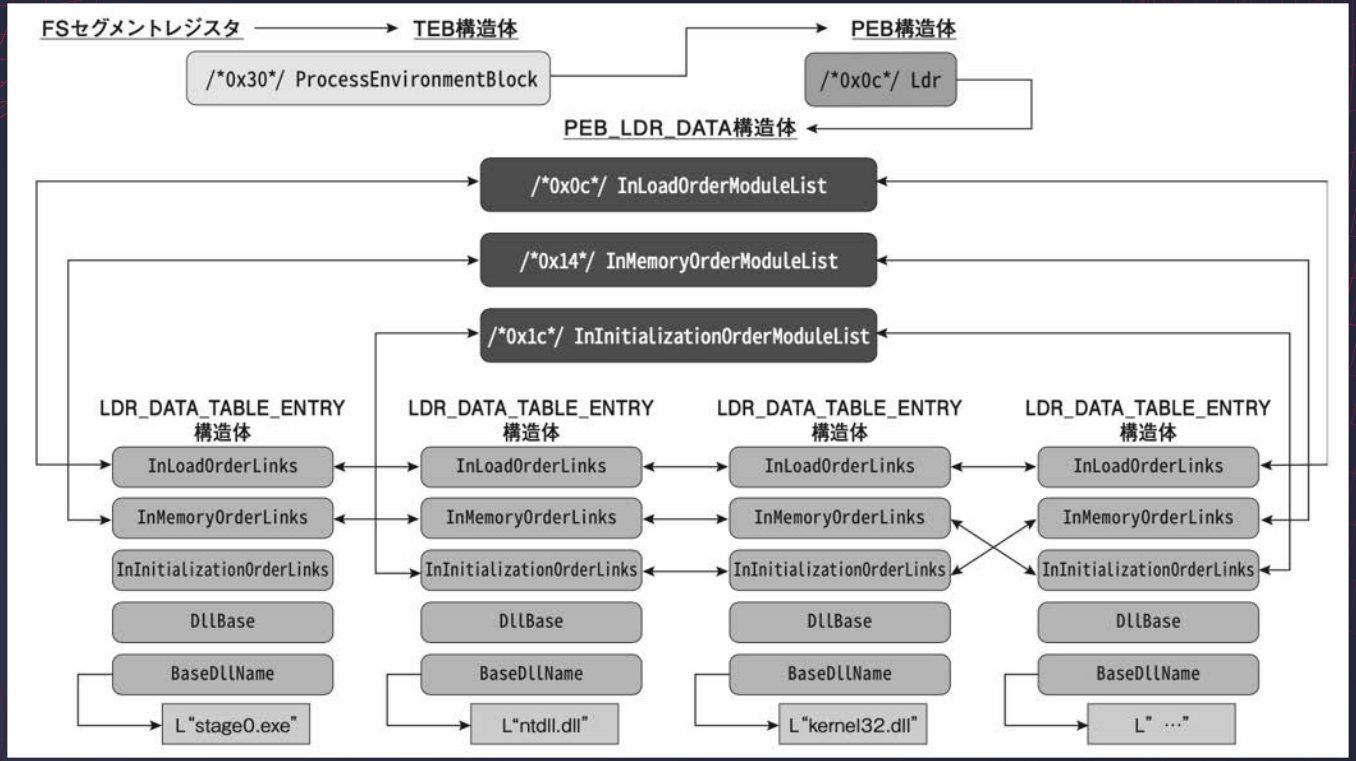

Apply Structure

- PEB構造体を事前定義したヘッダファイルをGhidraにインポート(すでに適用済み)
  - File > 「Parse C Source」 > win_internal.hを選択 >「Parse to Program」

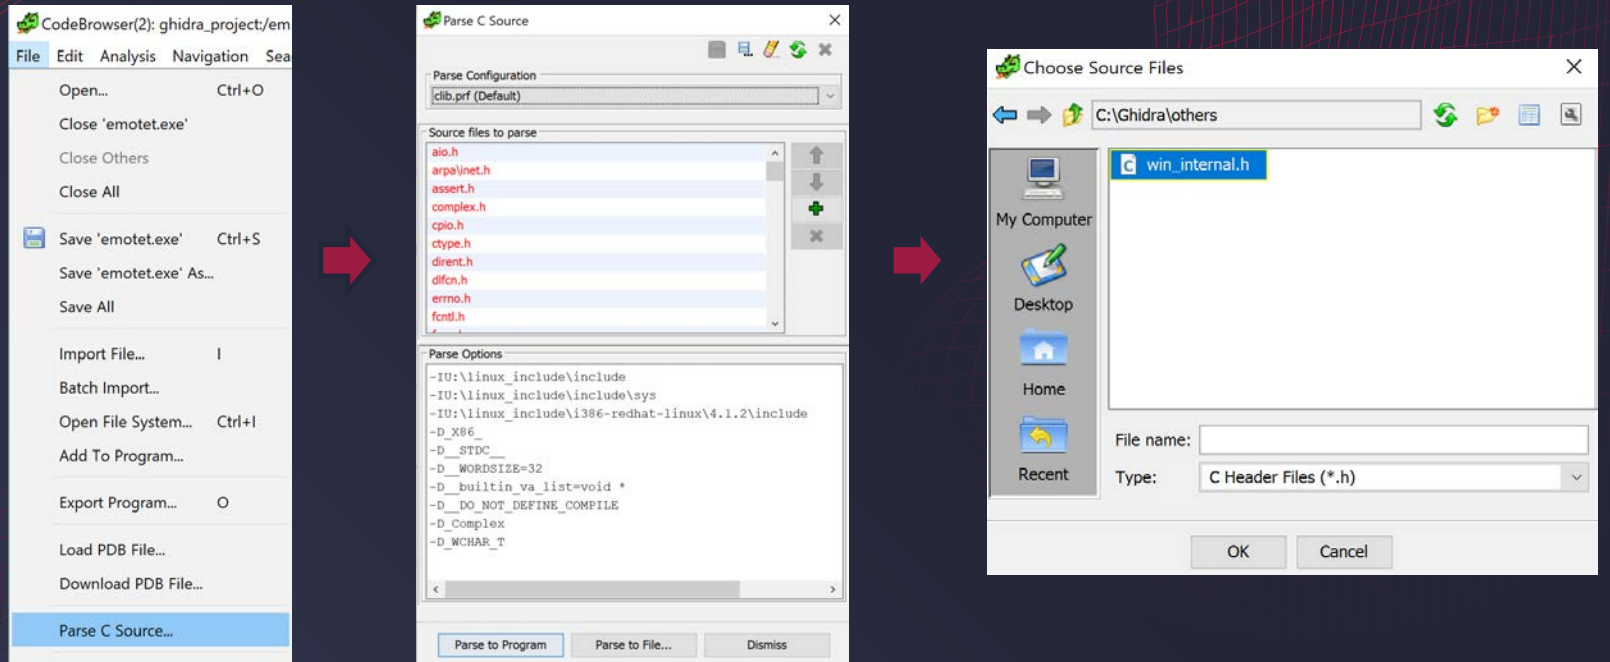

FUN_10002b48

- PEBのポインタを取得する関数
  - in_FS_OFFSETをAuto Create Structure

BEFORE	AFTER (name)	AFTER (type)
FUN_10002b48	get_peb	PEB *
in_FS_OFFSET	teb	TEB *

Decompile: get_peb ...

```
1
2  PEB * get_peb(void)
3
4  {
5    TEB *teb;
6
7    return teb->ProcessEnvironmentBlock;
8  }
```

FUN_10004ae6

- 読み込まれているDLLのベースネームを列挙し、FUN_100180eaに渡している
- FUN_100180eaの戻り値を0x1fc325daとXOR
- その結果を引数の値と比較

BEFORE	AFTER (name)	AFTER (type)
iVar1	peb	PEB *
puVar3	current_module_entry	LDR_DATA_TABLE_ENTRY *
puVar4	next_module_entry	LDR_DATA_TABLE_ENTRY *

Decompile: FUN_10004ae6 - (emotet.dll)

```
1
2  DWORD __cdecl FUN_10004ae6(uint param_1)
3
4  {
5    PEB *peb;
6    uint uVar1;
7    LDR_DATA_TABLE_ENTRY *next_module_entry;
8    LDR_DATA_TABLE_ENTRY *current_module_entry;
9
10   peb = get_peb();
11   current_module_entry = (LDR_DATA_TABLE_ENTRY *)&peb->Ldr->InLoadOrderModuleList;
12   next_module_entry = (LDR_DATA_TABLE_ENTRY *)(current_module_entry->InLoadOrderLinks).Flink;
13   while( true ) {
14     if (next_module_entry == current_module_entry) {
15       return 0;
16     }
17     uVar1 = FUN_100180ea((ushort *)(next_module_entry->BaseDllName).Buffer,2,0x639b);
18     if ((uVar1 ^ 0x1fc325da) == param_1) break;
19     next_module_entry = (LDR_DATA_TABLE_ENTRY *)(next_module_entry->InLoadOrderLinks).Flink;
20   }
21   return next_module_entry->DllBase;
22 }
```

プロセスに読み込まれているDLLの列挙

DLLのベースネーム（ファイル名）を渡している

戻り値をXORして引数と比較

演習

FUN_100180ea

1. この関数はハッシュ関数です、アルゴリズムを解析してください
2. 実際は`FUN_100180ea`の戻り値を`0x1fc325da`とXORして比較していました。よって、次のように、 DLLベースネームとXOR鍵の入力を受け付けて適切なハッシュ値を返す関数(`calc_hash`)をGhidra Scriptで実装してください

Python - Interpreter

```
>>> hex(calc_hash('kernel32.dll', 0x1fc325da))
'0x90bdc3a8L'
```

Decompile: FUN_100180ea - (emotet.dll)

```
1
2  int __fastcall FUN_100180ea(ushort *param_1,undefined param_2,undefined4 param_3)
3
4  {
5    ushort uVar1;
6    int iVar2;
7    uint uVar3;
8
9    _();
10   iVar2 = 0;
11   uVar1 = *param_1;
12   while (uVar1 != 0) {
13     uVar3 = (uint)*param_1;
14     if ((0x40 < uVar3) && (uVar3 < 0x5b)) {
15       uVar3 = uVar3 + 0x20;
16     }
17     param_1 = param_1 + 1;
18     iVar2 = uVar3 + iVar2 * 0x1003f;
19     uVar1 = *param_1;
20   }
21   return iVar2;
22 }
```

FUN_100180ea

- BaseDllName.Bufferの型はwchar_t *(=unsingned short *)
- 1バイトずつ以下処理
  - 大文字ASCII（0x40 < x < 0x5b）の場合、小文字(+0x20)に変更
  - 結果を状態(iVar2)に加算し、0x1003fを乗算
- 結果のint値を返す

ハッシュ関数であると判断できる
(「calc_hash_case_insensitive」に変更)

Decompile: calc_hash_case_insensitive - (emotet.dll)

```
1
2  int __fastcall calc_hash_case_insensitive(ushort *dll_basename,undefined _,undefined4 __)
3
4  {
5    uint char;
6    int value;
7    ushort wchar;
8
9    ::_();
10   value = 0;
11   wchar = *dll_basename;
12   while (wchar != 0) {
13     char = (uint)*dll_basename;
14     if ((0x40 < char) && (char < 0x5b)) {
15       char = char + 0x20;
16     }
17     dll_basename = dll_basename + 1;
18     value = char + value * 0x1003f;
19     wchar = *dll_basename;
20   }
21   return value;
22 }
```

FUN_100180ea

- DLLベースネームとXOR鍵を受け取り、ハッシュ値を返す関数

```
if ((uVar1 ^ 0x1fc325da) == param_1) break;
```

```
def calc_hash_lower(name, key):
    name = name.lower()
    value = 0
    for c in name:
        value = (ord(c) + value * 0x1003f) & 0xffffffff
    return value ^ key
```

```
>>> hex(calc_hash_lower('Kernel32.dll', 0x1fc325da))
'0x90bdc3a8L'
```

```
pcVar1 = (code *)FUN_10007d5b(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
```

FUN_10004ae6

- calc_hash_case_insensitive関数の呼び出し元に戻る
- これまでの結果から、DLL名をハッシュ化した値を受け取り、ロード済みDLLの中から該当するDLLを探してベースアドレスを返す関数だとわかる
  - ベースアドレス: メモリにロードされているDLLのPEヘッダへのポインタ
- 関数名を「find_lib」に変えておく

BEFORE	AFTER (name)	AFTER (type)
param_1	hashed_dllname	N/A
uVar1	hashed	N/A
FUN_10004ae6	find_lib	N/A

Decompile: find_lib - (emotet.dll)

```
1
2  DWORD __cdecl find_lib(uint hashed_dllname)
3
4  {
5    PEB *peb;
6    uint hashed;
7    LDR_DATA_TABLE_ENTRY *next_module_entry;
8    LDR_DATA_TABLE_ENTRY *current_module_entry;
9
10   peb = get_peb();
11   current_module_entry = (LDR_DATA_TABLE_ENTRY *)&peb->Ldr->InLoadOrderModuleList;
12   next_module_entry = (LDR_DATA_TABLE_ENTRY *)(current_module_entry->InLoadOrderLinks).Flink;
13   while( true ) {
14     if (next_module_entry == current_module_entry) {
15       return 0;
16     }
17     hashed = calc_hash_case_insensitive((ushort *)(next_module_entry->BaseDllName).Buffer,2,0x639b);
18     if ((hashed ^ 0x1fc325da) == hashed_dllname) break;
19     next_module_entry = (LDR_DATA_TABLE_ENTRY *)(next_module_entry->InLoadOrderLinks).Flink;
20   }
21   return next_module_entry->DllBase;
22 }
```

PE Header Overview

Windows実行可能形式(PE)のファイルフォーマット

- 実行ファイルに関する様々な情報を保持している
  - **Export Table**
    - エクスポート関数一覧
  - **Import Table**
    - 使用するAPI一覧

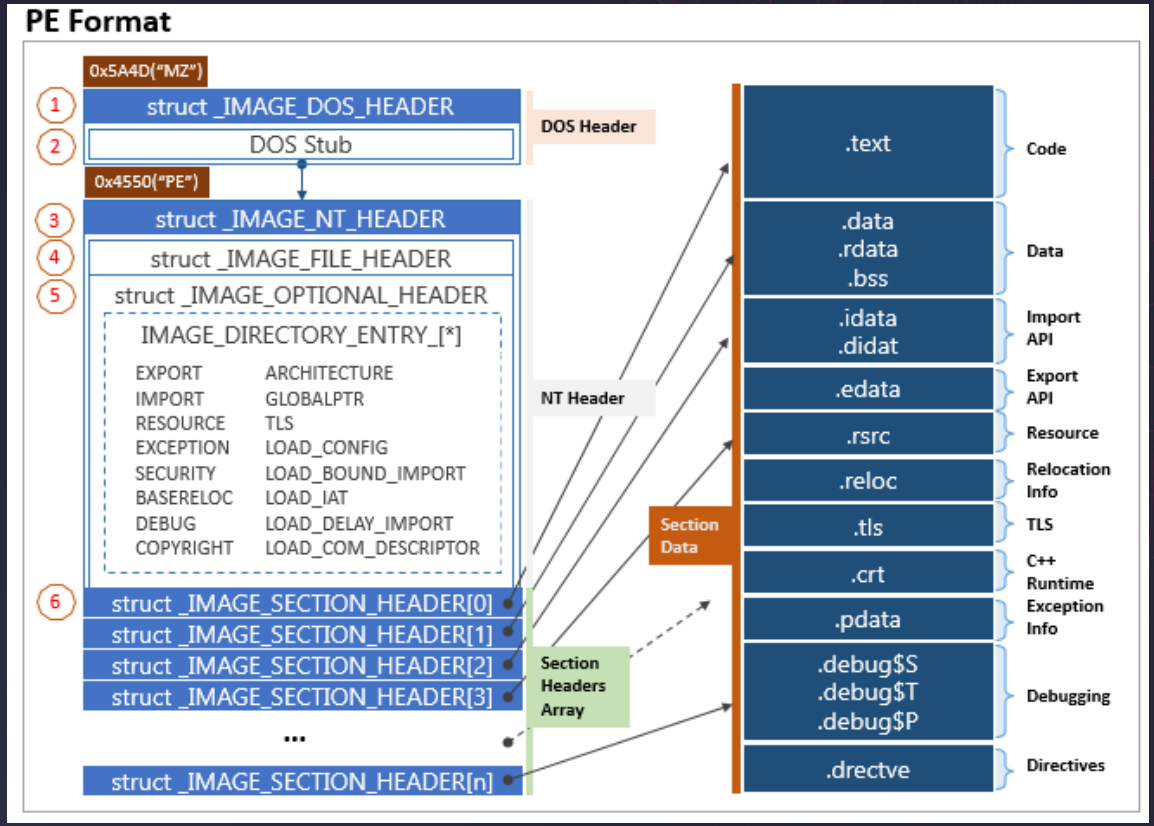

https://tech-zealots.com/malware-analysis/pe-portable-executable-structure-malware-analysis-part-2/

FUN_10012794

なにもわからない

Decompile: FUN_10012794 - (emotet.dll)

```
1
2  char * __fastcall FUN_10012794(undefined4 param_1,int param_2,undefined4 param_3,uint param_4)
3
4  {
5    int iVar1;
6    int iVar2;
7    int iVar3;
8    int iVar4;
9    uint uVar5;
10   uint uVar6;
11   char *pcVar7;
12   char *pcVar8;
13
14   _();
15   uVar6 = 0;
16   iVar1 = *(int *)(param_2 + 0x3c);
17   pcVar8 = (char *)(*(int *)(iVar1 + 0x78 + param_2) + param_2);
18   iVar2 = *(int *)(pcVar8 + 0x1c);
19   iVar3 = *(int *)(pcVar8 + 0x20);
20   iVar4 = *(int *)(pcVar8 + 0x24);
21   if (*(int *)(pcVar8 + 0x18) != 0) {
22     do {
23       uVar5 = FUN_1000df50((char *)(*(int *)(iVar3 + param_2 + uVar6 * 4) + param_2),0x92,0x2f3d,
24                            0x30ee);
25       if ((uVar5 ^ 0x5a80eae) == param_4) {
26         pcVar7 = (char *)(*(int *)(iVar2 + param_2 +
27                                    (uint)*(ushort *)(iVar4 + param_2 + uVar6 * 2) * 4) + param_2);
28         if (pcVar7 < pcVar8) {
29           return pcVar7;
30         }
31         if (pcVar8 + *(int *)(iVar1 + 0x7c + param_2) <= pcVar7) {
32           return pcVar7;
33         }
34         pcVar8 = (char *)FUN_10011d25(pcVar7);
35         return pcVar8;
36       }
37       uVar6 = uVar6 + 1;
38     } while (uVar6 < *(uint *)(pcVar8 + 0x18));
39   }
40   return (char *)0x0;
41 }
```

FUN_10012794

- エクスポート関数の一覧を保持する
  エクスポートテーブルにアクセスしている

型を適用すると都度変数名が変わってしまうので、変更"前"の変数名で表記

BEFORE	AFTER (name)	AFTER (type)
param_2	base_address	N/A
param_4	hashed_api	N/A
iVar1	nt_headers	IMAGE_NT_HEADER32 *
pcVar8	export_table	IMAGE_EXPORT_DIRECTORY *
iVar2	functions_rva	N/A
iVar3	names_rva	N/A
iVar4	ordinals_rva	N/A
uVar5	value	N/A
uVar6	i	N/A
pcVar7	export_func	LPVOID

```
char * __fastcall FUN_10012794(undefined4 _,int base_address,undefined4 __,uint hashed_api)

{
  uint value;
  LPVOID *ppvVar1;
  uint i;
  LPVOID *export_func;
  IMAGE_EXPORT_DIRECTORY *export_table;
  IMAGE_NT_HEADERS32 *nt_header;
  DWORD functions_rva;
  DWORD names_rva;
  DWORD ordinals_rva;

  ::_();
  i = 0;
                    /* e_lfanew */
  nt_header = *(IMAGE_NT_HEADERS32 **)(base_address + 0x3c);
  export_table = (IMAGE_EXPORT_DIRECTORY *)
                 (*(int *)((int)&(nt_header->OptionalHeader).DataDirectory[0].VirtualAddress +
                           base_address) + base_address);
  functions_rva = export_table->AddressOfFunctions;
  names_rva = export_table->AddressOfNames;
  ordinals_rva = export_table->AddressOfNameOrdinals;
  if (export_table->NumberOfNames != 0) {
    do {
      value = FUN_1000df50((char *)(*(int *)(names_rva + base_address + i * 4) + base_address),
                           0x92,0x2f3d,0x30ee);
      if ((value ^ 0x5a80eae) == hashed_api) {
        export_func = (LPVOID *)
                      (*(int *)(functions_rva + base_address +
                                (uint)*(ushort *)(ordinals_rva + base_address) * 4) +
                      base_address);
        if (export_func < export_table) {
          return (char *)export_func;
        }
        if ((LPVOID *)
            ((int)&export_table->Characteristics +
            *(int *)((int)&(nt_header->OptionalHeader).DataDirectory[0].Size + base_address)) <=
            export_func) {
          return (char *)export_func;
        }
        ppvVar1 = (LPVOID *)FUN_10011d25((char *)export_func);
        return (char *)ppvVar1;
      }
      i = i + 1;
    } while (i < export_table->NumberOfNames);
  }
  return (char *)(LPVOID *)0x0;
}
```

DLLのベースアドレス、つまり
IMAGE_DOS_HEADERへの
ポインタが引数に渡されている

OptionalHeader.DataDirectoryは
さまざまなデータを格納する連想配列で
インデックス0にはExport Tableへの
オフセットが格納されている

エクスポート関数のRVAの配列

エクスポート関数名のRVAの配列

エクスポート関数の序数のRVAの配列

エクスポート関数名を列挙

エクスポート関数のアドレスを取得

エクスポート関数のアドレスが
フォワードされたものか確認

FUN_10012794

- 列挙したエクスポート関数を`FUN_1000df50`に渡す
- 戻り値を`0x5a80eae`とXOR
- XORした結果を第四引数と比較
- 合致した場合、対象APIのアドレスを返す
- Export ForwardされたAPIは別途APIを解決

```
25  if (export_table->NumberOfNames != 0) {
26    do {
27      value = FUN_1000df50((char *)(*(int *)(names_rva + base_address + i * 4) + base_address),
28                           0x92,0x2f3d,0x30ee);
29      if ((value ^ 0x5a80eae) == hashed_api) {
30        export_func = (LPVOID *)
31                      (*(int *)(functions_rva + base_address +
32                                (uint)*(ushort *)(ordinals_rva + base_address + i * 2) * 4) +
33                      base_address);
34        if (export_func < export_table) {
35          return (char *)export_func;
36        }
37        if ((LPVOID *)
38            ((int)&export_table->Characteristics +
39            *(int *)((int)&(nt_header->OptionalHeader).DataDirectory[0].Size + base_address)) <=
40            export_func) {
41          return (char *)export_func;
42        }
43        ppvVar1 = (LPVOID *)FUN_10011d25((char *)export_func);
44        return (char *)ppvVar1;
45      }
46      i = i + 1;
47    } while (i < export_table->NumberOfNames);
```

※export forwardとは
https://docs.microsoft.com/en-us/windows/win32/debug/pe-format#export-address-table
https://devblogs.microsoft.com/oldnewthing/20060719-24/?p=30473

FUN_1000df50

- API名が渡される関数
- ほぼcalc_hash_case_insensitiveと同じ（小文字変換処理がない）

Decompile: FUN_1000df50 - (emotet.dll)

```
int __fastcall FUN_1000df50(char *param_1,undefined param_2,undefined4 param_3,undefined4 param_4)

{
  char cVar1;
  int iVar2;

  _();
  iVar2 = 0;
  cVar1 = *param_1;
  while (cVar1 != '\0') {
    iVar2 = (int)*param_1 + iVar2 * 0x1003f;
    param_1 = param_1 + 1;
    cVar1 = *param_1;
  }
  return iVar2;
}
```

Decompile: calc_hash_case_sensitive - (emotet.dll)

```
int __fastcall
calc_hash_case_sensitive(char *api_name,undefined param_2,undefined4 param_3,undefined4 param_4)

{
  char char;
  int value;

  _();
  value = 0;
  char = *api_name;
  while (char != '\0') {
    value = (int)*api_name + value * 0x1003f;
    api_name = api_name + 1;
    char = *api_name;
  }
  return value;
}
```

Calcurate Hash

- Pythonで実装

```
71  def calc_hash(name, key):
72      value = 0
73      for c in name:
74          value = (ord(c) + value * 0x1003f) & 0xffffffff
75      return value ^ key
```

FUN_10012794関数内にハードコードされたXOR鍵

```
if ((value ^ 0x5a80eae) == hashed_api)
```

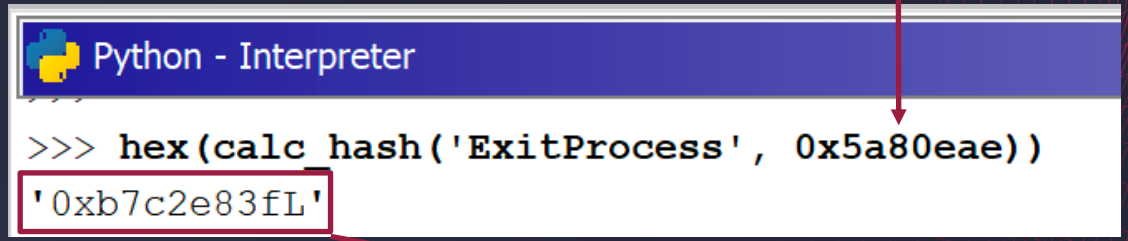

呼び出し元の例 (@0x10017e02)

```
pcVar1 = (code *)FUN_10007d5b(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
```

合致している

(Advanced) Calcurate Hash by Emulator

- アルゴリズムの実装がわからなくても、Emulatorで実行してしまうことも可能

```
1001285a e8 f1 b6 ...     CALL        calc_hash_case_sensitive
1001285f 35 ae 0e ...     XOR         value,0x5a80eae
10012864 59               POP         param_1
10012865 59               POP         param_1
10012866 3b 44 24 34      CMP         value,dword ptr [ESP + hashed_api]
```

1. （エミュレータ内の）ECXに文字列を格納（=引数に渡す）
2. `0x1001285a`から`0x10012864`まで実行
3. EAXに格納されている値（=ハッシュ化済みの文字列）を取得

emulator.py

- Ghidraが提供している`EmulatorHelper`クラスを使用し、エミュレータを実装

```python
from ghidra.app.emulator import EmulatorHelper

def init_emulator():
    # initialize emulator
    emu = EmulatorHelper(currentProgram)

    # initialize stack
    registry_size = emu.getStackPointerRegister().getBitLength()
    stack_address = toAddr((((1 << (registry_size - 1)) - 1) ^ ((1 << (registry_size//2))-1)))
    emu.writeRegister(emu.getStackPointerRegister(), stack_address.getOffset())

    return emu


def emulate_calc_hash(entry_addr, param):
    emu = init_emulator()

    end_address = entry_addr.add(10)
    emu.setBreakpoint(end_address)

    # write parameter string into ECX
    string_address = toAddr(0xa00000)
    emu.writeMemory(string_address, param)
    emu.writeRegister('ECX', string_address.getOffset())

    # set address of entrypoint to execute at EIP
    emu.writeRegister(emu.getPCRegister(), entry_addr.getOffset())

    # run through until breakpoint
    while monitor.isCancelled() is False:
        current_address = emu.getExecutionAddress()
        if current_address == end_address:
            break
        emu.step(monitor)

    # get hashed value in EAX
    result = emu.readRegister('EAX')
    return result
```

(Advanced) Calcurate Hash by Emulator

GhidraのEmulatorでハッシュ関数をエミュレート

Python - Interpreter

```
>>> from emulator import emulate_calc_hash
>>> hashed_dll = emulate_calc_hash(toAddr(0x10004b98), 'kernel32.dll'.encode('utf-16le'))
>>> hex(hashed_dll)
'0x90bdc3a8L'
>>> hashed_api = emulate_calc_hash(toAddr(0x1001285a), 'ExitProcess')
>>> hex(hashed_api)
'0xb7c2e83fL'
```

実際に渡されているハッシュ値

```
pcVar1 = (code *)FUN_10007d5b(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
```

FUN_10007d5b

引数のハッシュ値をもとにAPIを動的解決し、グローバル変数にキャッシュ

変数

BEFORE	AFTER (name)
param_1	index
param_2	hashed_dll_name
param_3	hashed_api_name
g_array	g_api_table
pcVar1	api

関数

BEFORE	AFTER (name)
FUN_10007d5b	resolve_api
FUN_10004ae6	find_lib
FUN_10012794	find_api

Decompile: resolve_api - (emotet.dll)

```
1
2  int __cdecl resolve_api(int index,undefined4 _,uint hashed_dll_name,uint hashed_api_name)
3
4  {
5    int base_address;
6    char *api;
7
8    if (g_api_table[index] == 0) {
9      base_address = find_lib(hashed_dll_name);
10     api = find_api(0x7ef7,base_address,0x7a71,hashed_api_name);
11     g_api_table[index] = (int)api;
12   }
13   return g_api_table[index];
14 }
```

Anti-API Hashing

プログラム内のハッシュ値一覧を取得し、API名を逆解決してコメントをつけたい

1. Hash DBの作成
    1. API Hashに使用するXOR鍵を特定
    2. System32配下の主要なDLLのエクスポート関数名をハッシュ化
2. ハッシュ値とDBを突合
    1. スタックに積まれているスカラー値を全て取得
    2. Hash DBに登録済みのハッシュ値と突合
3. コメントをつける
    1. 呼び出されるAPI名をコード上にコメント

Create Hash DB

`make_hash_db.py`

- `%windir%¥System32¥*.dll` (今回は簡略化のため一部DLLのみ)に定義されているエクスポート関数を列挙
- 検体内にハードコードされていたXOR鍵で関数名をエンコードし、↓形式のjsonで格納
  - *<HASH>: <ORIG_NAME>*

```python
def calc_hash(name, key):
    value = 0
    for c in name:
        value = (ord(c) + value * 0x1003f) & 0xffffffff
    return value ^ key

def get_export_api(dllpath):
    pe = pefile.PE(dllpath)
    if ((not hasattr(pe, "DIRECTORY_ENTRY_EXPORT")) or (pe.DIRECTORY_ENTRY_EXPORT is None)):
        raise RuntimeError(f'{dllpath} doesn\'t have export table')

    for sym in pe.DIRECTORY_ENTRY_EXPORT.symbols:
        if sym.name is not None:
            yield sym.name.decode('utf-8')

def main():
    import argparse

    p = argparse.ArgumentParser()
    p.add_argument('--lib-key', dest='lib_key', default=LIB_XOR_KEY, type=lambda x: int(x, 0), help='XOR key for lib name hashing')
    p.add_argument('--api-key', dest='api_key', default=API_XOR_KEY, type=lambda x: int(x, 0), help='XOR key for API hashing')

    args = p.parse_args()

    # partially apply calc_hash function with XOR key
    emotet_xor_for_lib = partial(calc_hash, key=args.lib_key)
    emotet_xor_for_api = partial(calc_hash, key=args.api_key)

    results = defaultdict(dict)

    # enumerate all .dll files in %windir%\system32
    target_path = os.path.join(os.environ.get('windir'), 'system32')
    for dll_filepath in glob.glob(os.path.join(target_path, '*.dll')):
        dllname = os.path.basename(dll_filepath)

        # filter uninteresting dlls for easy use
        if dllname.lower() not in INTERESTING_DLLS:
            continue

        # calc hash of dll name
        hashed_dllname = emotet_xor_for_lib(dllname.lower())
        results[hex(hashed_dllname)] = dllname

        # calc hash of each API name in DLL
        for api in get_export_api(dll_filepath):
            hashed_api = emotet_xor_for_api(api)
            results[hex(hashed_api)] = api

    # dump tp json file
    with open('db.json', 'w') as f:
        json.dump(results, f, indent=4)
```

Create Hash DB

`make_hash_db.py`

- 出力されたdb.json


```
{
    "0x2de3bdc6": "advapi32.dll",
    "0xfd8a9a46": "A_SHAFinal",
    "0x862245b0": "A_SHAInit",
    "0xf996c519": "A_SHAUpdate",
    "0x4927aac2": "AbortSystemShutdownA",
    "0x4927aa2c": "AbortSystemShutdownW",
    "0xa0ea950a": "AccessCheck",
    "0xf2ea6e16": "AccessCheckAndAuditAlarmA",
    "0xf2ea6e60": "AccessCheckAndAuditAlarmW",
    "0x233ec35b": "AccessCheckByType",
    "0x24dd2927": "AccessCheckByTypeAndAuditAlarmA",
    "0x24dd2931": "AccessCheckByTypeAndAuditAlarmW",
    "0x7e40889e": "AccessCheckByTypeResultList",
    "0xa8efafea": "AccessCheckByTypeResultListAndAuditAlarmA",
    "0xb86cc6eb": "AccessCheckByTypeResultListAndAuditAlarmByHandleA",
    "0xb86cc6f5": "AccessCheckByTypeResultListAndAuditAlarmByHandleW",
    "0xa8efaff4": "AccessCheckByTypeResultListAndAuditAlarmW",
    "0x4fed1fce": "AddAccessAllowedAce",
    "0x3ff7c7d": "AddAccessAllowedAceEx",
    "0x8e1182f": "AddAccessAllowedObjectAce",
    "0x5f75502d": "AddAccessDeniedAce",
    "0x437d50d8": "AddAccessDeniedAceEx",
    "0xeed4718a": "AddAccessDeniedObjectAce",
    "0x73006e2c": "AddAce",
    "0xe5dbf5cb": "AddAuditAccessAce",
    "0xa78fa4f6": "AddAuditAccessAceEx",
    "0xeee7a7a8": "AddAuditAccessObjectAce",
```

Lookup Hashes

- DLL名とAPI名のハッシュ値はresolve_api関数の引数に渡されている
- 値はスタック経由で渡されている
- 雑だが、PUSH命令の引数に渡されているスカラー値が取得できればよさそう

Decompile View at FUN_10017d5a

```
pcVar1 = (code *)resolve_api(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
(*pcVar1)(0,uVar2,uVar3,uVar4,uVar5,uVar6,uVar7,uVar8);
return;
```

```
undefined4 __cdecl resolve_api (int index, undefined4 _, uint hashed_dll_name, uint hashed_api_name)
  undefined4  EAX:4          <RETURN>
  int         Stack[0x4]:4   index
  undefined4  Stack[0x8]:4   _
  uint        Stack[0xc]:4   hashed_dll_name
  uint        Stack[0x10]:4  hashed_api_name
```

Listing View at FUN_10017d5a

```
10017df2 68 3f e8 ...    PUSH    0xb7c2e83f
10017df7 68 a8 c3 ...    PUSH    0x90bdc3a8
10017dfc 51              PUSH    ECX
10017dfd 68 f5 00 ...    PUSH    0xf5
10017e02 e8 54 ff ...    CALL    resolve_api
```

Lookup Hashes

- プログラム内の全命令を列挙
- PUSH命令の引数に渡されたスカラー値を取得
- 値をDB内のハッシュ値と比較
- 合致したらコメント・ブックマークをつける

```
 9  def add_bookmark_comment(addr, comment):
10      cu = currentProgram.getListing().getCodeUnitAt(addr)
11      createBookmark(addr, "hashed_name", comment)
12      cu.setComment(CodeUnit.EOL_COMMENT, comment)
```

```
39  def main():
40      db_path = askFile("DB for hashes", "import").getPath()
41
42      # for Headless usage, you can get arugment via command line
43      # db_path = getScriptArgs()[0]
44
45      db = HashDB(db_path)
46
47      # get all instructions in program
48      instructions = currentProgram.getListing().getInstructions(True)
49
50      # process each instruction
51      for inst in instructions:
52          value = get_scalar_argument(inst)
53          if value is not None:
54              try:
55                  # then lookup DB
56                  orig_name = db.lookup(str(value))
57
58                  # if it exists, add comment and add bookmark
59                  if orig_name:
60                      print('[*] {} at {}: {}'.format(str(value), inst.getAddress(), orig_name))
61                      add_bookmark_comment(inst.getAddress(), orig_name)
62              except Exception as e:
63                  print(e)
```

Lookup Hashes

演習

- 与えられた命令がスカラー値をPUSHするものかチェックする関数を実装し、`search_hash_not_impl.py`を完成させてください

search_hash_not_impl.py

```
28  def get_scalar_argument(inst):
29      ''' **** IMPLEMENT HERE ****
30
31      if given instruction is like 'PUSH <SCALAR>',
32      retrun scalar value.
33          Hint:
34          - check API document of Instruction interface
35      '''
36      raise NotImplementedError('not implemented')
```

Lookup Hashes

演習

- 与えられた命令がスカラー値をPUSHするものかチェックする関数を実装し、`search_hash_not_impl.py`を完成させてください
- ヒント:
  - inst.getMnemonicString()
  - Inst.getOpObjects()

search_hash_not_impl.py

```
28  def get_scalar_argument(inst):
29      ''' **** IMPLEMENT HERE ****
30
31      if given instruction is like 'PUSH <SCALAR>',
32      retrun scalar value.
33          Hint:
34              - check API document of Instruction interface
35      '''
36      raise NotImplementedError('not implemented')
```

Lookup Hashes

演習

- 与えられた命令がスカラー値をPUSHするものかチェックする関数を実装し、`search_hash_not_impl.py`を完成させてください

実装した`search_hash.py`

```
28  def get_scalar_argument(inst):
29      # get mnemonic in one instruction
30      mnemonic = inst.getMnemonicString()
31
32      if mnemonic == 'PUSH':
33          # get operand in index 1
34          value = inst.getOpObjects(0)[0]
35          if isinstance(value, Scalar) and value.bitLength() == 32:
36              return value
```

Run Ghidra Script

- Script Managerで実行

1. Script Manager起動

2．スクリプト名を検索して実行

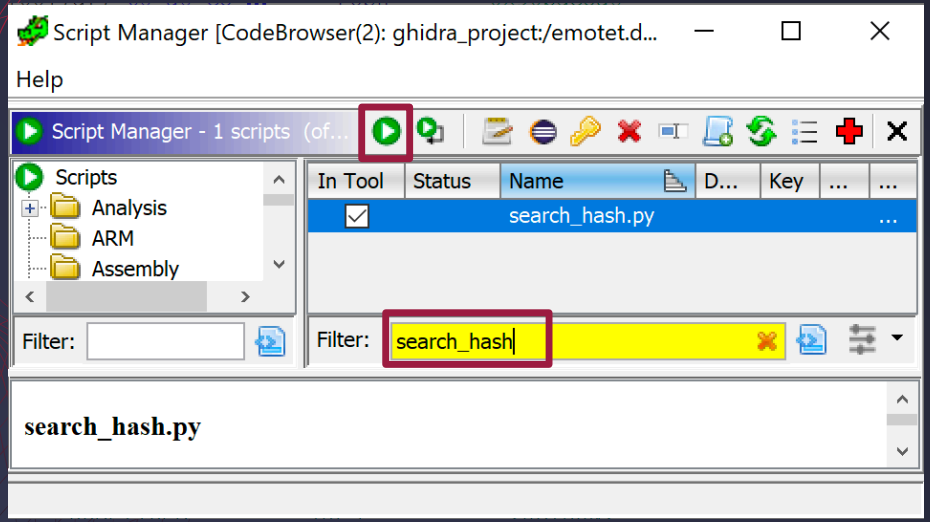

3．参照するDBを指定（make_hash_db.pyで作成したjson）

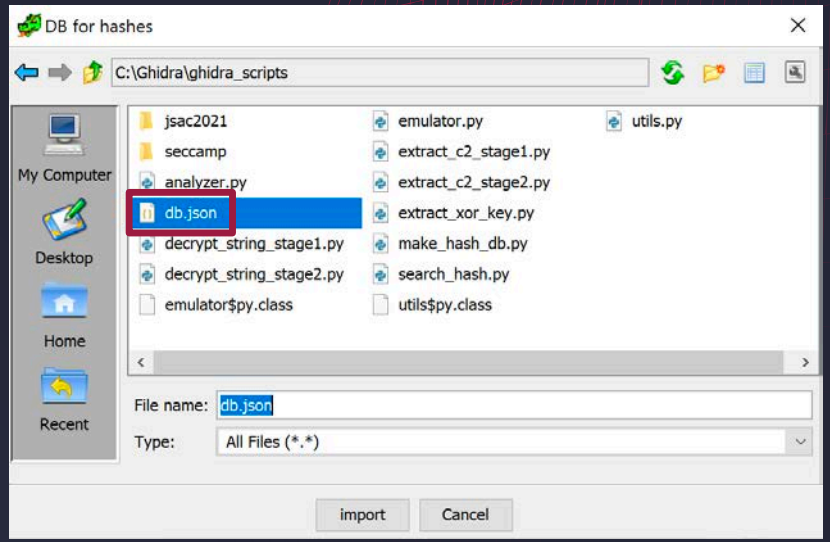

Run Ghidra Script

コンソールに実行結果が表示されている

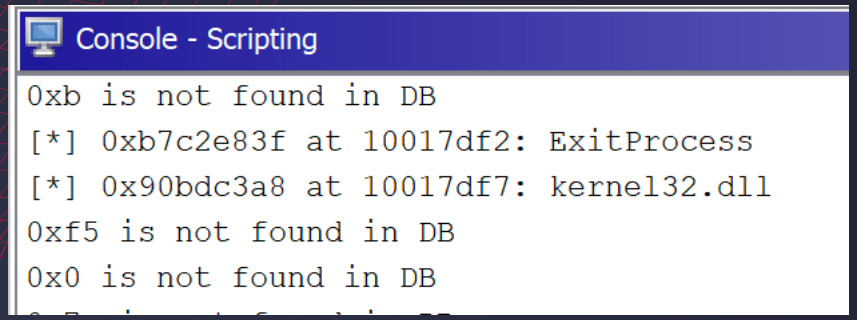

API名・DLL名のコメントがついている

```
10017df2 68 3f e8 ...     PUSH      0xb7c2e83f   ExitProcess
10017df7 68 a8 c3 ...     PUSH      0x90bdc3a8   kernel32.dll
10017dfc 51               PUSH      ECX
10017dfd 68 f5 00 ...     PUSH      0xf5
10017e02 e8 54 ff ...     CALL      resolve_api  undefined4 res
```

```
21                  /* ExitProcess */
22                  /* kernel32.dll */
23  pcVar1 = (code *)resolve_api(0xf5,0xb,0x90bdc3a8,0xb7c2e83f);
24  (*pcVar1)(0,uVar2,uVar3,uVar4,uVar5,uVar6,uVar7,uVar8);
25  return;
```

※コメントが表示されない場合、
Edit > Tool Options > Decompiler > Display の
「Display EOL Comments」が有効化されていない可能性

Other API Hash Search Script

- EMOTETは、ハッシュ関数に使用されるXOR鍵が検体ごとに異なるため、検体ごとにDBを作成する必要があるが、既知のアルゴリズムが使用されている場合は、既成のDBを使用してルックアップすれば、ハッシュ関数の詳細をしらなくてもAPI Hashを解決できる場合がある
  - `shellcode_hash_search.py`（Ghidra）
    - https://github.com/AllsafeCyberSecurity/ghidra_scripts/blob/master/shellcode_hash_search.py
  - `shellcode_hashes_search_plugin.py`（IDA）
    - https://github.com/fireeye/flare-ida/tree/master/shellcode_hashes

Step 3:
Decrypt Strings

Defined Strings

- アンパック後のEMOTETには、不正活動に関連する可読文字列が存在しない
- 文字列も暗号化・難読化されている可能性がある

Window > Defined Strings から
プログラム内の可読文字列を表示できる

Defined Strings - 9 items

Location	String Value	String Representation	Data Type	Byte Count
10000000			char[2]	128
100000c8			char[4]	248
100001c0			char[8]	40
100001e8			char[8]	40
10000210			char[8]	40
10000238			char[8]	40
1001e04c	X.dll	"X.dll"	ds	6
1001e052	Control_RunDLL	"Control_RunDLL"	ds	15
1001e061	RunDLL	"RunDLL"	ds	7

Where is Decryption Function?

- 文字列が暗号化されている場合、実行時に復号関数が呼び出されているはず
- 復号関数は何度も呼び出されているはず

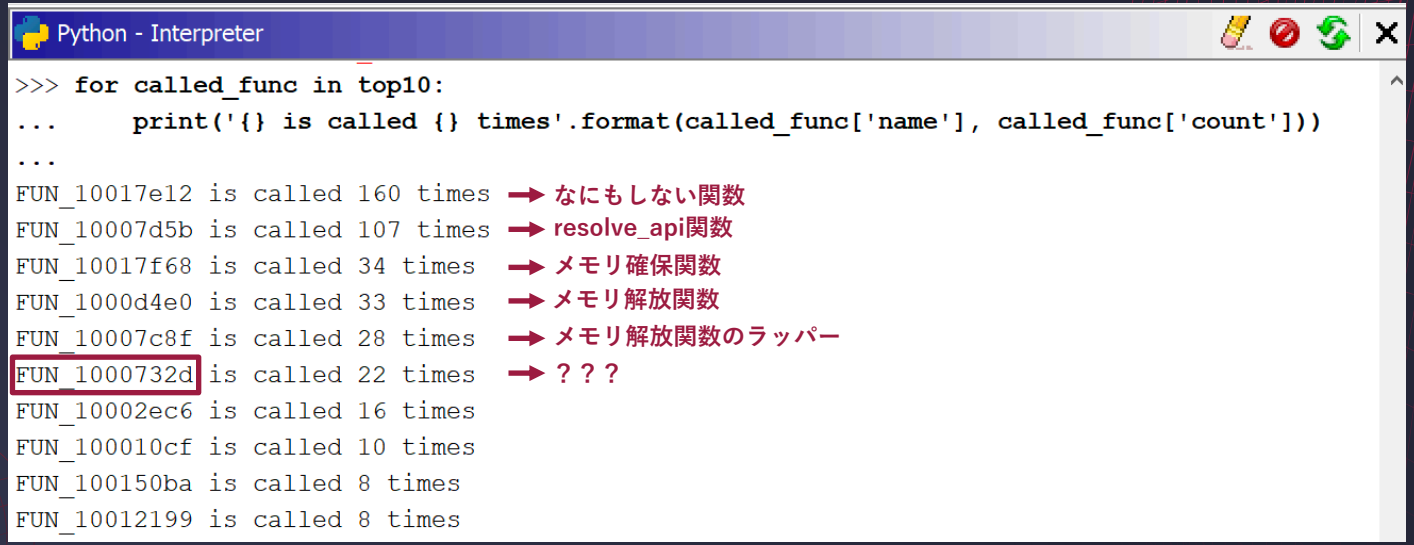

FUN_1000732d

演習

比較的複雑な関数

1. ロジックを解析してください
   - ✓ 17~24、35~50行に集中するといいかも
2. 復号スクリプト `decrypt_string_stage1_not_impl.py`の`decrypt_string`関数を実装してください

Decompile: FUN_1000732d - (emotet.dll)

```
ushort * __fastcall FUN_1000732d(undefined4 param_1,uint *param_2,undefined4 param_3)

{
  uint *puVar1;
  uint uVar2;
  ushort uVar3;
  uint uVar4;
  ushort *puVar5;
  uint uVar6;
  ushort *puVar7;
  uint uVar8;
  uint uVar9;
  uint *puVar10;

  _();
  uVar2 = *param_2;
  puVar10 = param_2 + 2;
  uVar4 = param_2[1] ^ uVar2;
  uVar8 = uVar4 + 1;
  uVar9 = uVar8;
  if ((uVar8 & 3) != 0) {
    uVar9 = (uVar8 & 0xfffffffc) + 4;
  }
  puVar5 = (ushort *)FUN_10017f68(uVar8 & 0xffffff03,(void *)(uVar9 * 2));
  if (puVar5 != (ushort *)0x0) {
    uVar8 = 0;
    puVar1 = (uint *)((int)puVar10 + (uVar9 & 0xfffffffc));
    uVar9 = (uint)((int)puVar1 + (3 - (int)puVar10)) >> 2;
    if (puVar1 < puVar10) {
      uVar9 = 0;
    }
    puVar7 = puVar5;
    if (uVar9 != 0) {
      do {
        uVar6 = *puVar10;
        puVar10 = puVar10 + 1;
        uVar6 = uVar6 ^ uVar2;
        *puVar7 = (ushort)uVar6 & 0xff;
        puVar7[1] = (ushort)(uVar6 >> 8) & 0xff;
        uVar3 = (ushort)(uVar6 >> 0x10);
        uVar8 = uVar8 + 1;
        puVar7[2] = uVar3 & 0xff;
        puVar7[3] = uVar3 >> 8;
        puVar7 = puVar7 + 4;
      } while (uVar8 < uVar9);
    }
    puVar5[uVar4] = 0;
  }
  return puVar5;
}
```

```
def decrypt_string(enc_data_addr):
    ''' **** IMPLEMENT HERE ****
        decrypt string at given address and return it as string
        Hint:
            1. use `getInt` to get 4 bytes in little endian format
            2. use `getBytes` to get specific size of bytes
            3. use `Address#add` method to add/sub address object
                >>> addr = toAddr(0x401000)
                >>> new_addr = addr.add(4)
            4. use `xor_with_multi_bytes` to xor bytes with DWORD
            5. in jython, you can convert array to string by `tostring` method
                >>> getBytes(0x408000)
                array('b', [116, 101, 115, 116])
                >>> getBytes(0x408000).tostring()
                'test'
    '''
    raise NotImplementedError('not implemented')
```

FUN_1000732d

見やすくするヒント ①

- オフセットでアクセスされている場合、構造体を使用している可能性がある
- Ghidraは独自構造体を自動で識別できない
- Auto Create Structureで構造体を自動定義し、指定した変数に適用できる

```
17    uVar2 = *param_2;
18    puVar10 = param_2 + 2;
19    uVar4 = param_2[1] ^ uVar2;
```

param_2を右クリック > Auto Create Structure

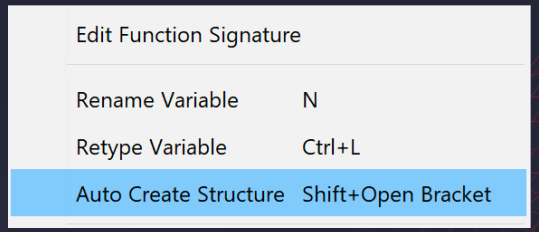

変更後

```
17    uVar2 = param_2->field_0x0;
18    puVar10 = &param_2->field_0x8;
19    uVar4 = param_2->field_0x4 ^ uVar2;
```

FUN_1000732d

見やすくするヒント ②

- 同じレジスタが異なる用途で使いまわされている場合、変数名が付けづらい問題
- Split Out As New Variable で変数を分割すると見やすくなる

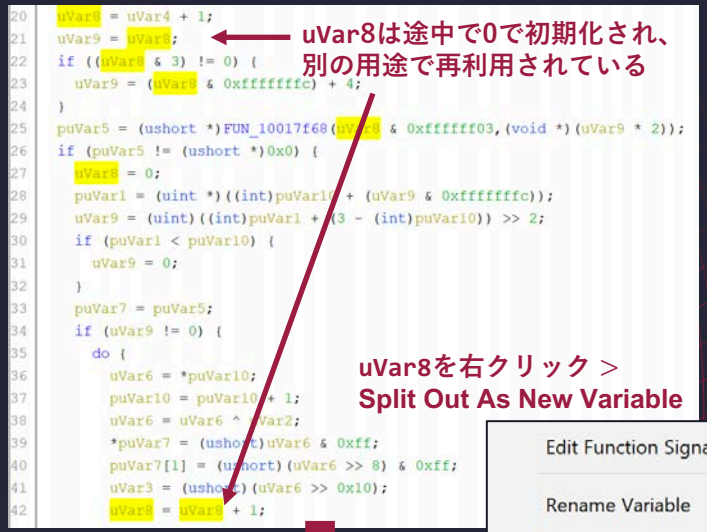

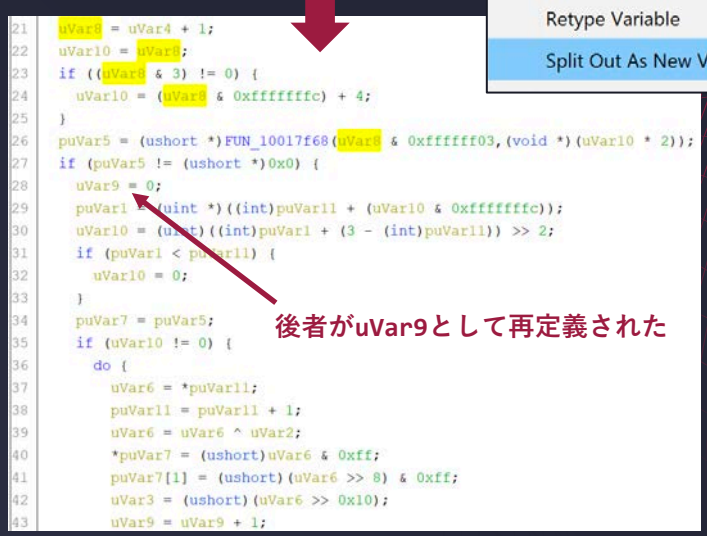

FUN_1000732d

1. 第２引数に、「暗号化された文字列に関する情報を保持する構造体」へのポインタが渡されている
   - オフセット+0: XOR鍵
   - オフセット+4: XOR鍵でエンコードされた、復号後文字列のサイズ
   - オフセット+8: 暗号データ
2. 4バイトで割り切れるサイズに調整
3. 復号文字列を格納するために、②のサイズ*2バイト分のバッファ確保
4. enc_dataがemptyでないかチェック
5. 復号処理
   1. 4バイトを1チャンクとして処理
   2. 4バイト分ポインタを進める
   3. XOR鍵でデコード
   4. 下位バイトから順にバッファにコピー
   5. 4バイト分ポインタを進める
6. 復号後のデータ末尾にNULLを追記し返す

Decompile: FUN_1000732d - (emotet.dll)

```
18  xor_key = data->key;
19  enc_data = &data->enc_data;
20  orig_length = data->xored_length ^ xor_key;
21  uVar8 = orig_length + 1;
22  size = uVar8;
23  if ((uVar8 & 3) != 0) {
24    size = (uVar8 & 0xfffffffc) + 4;
25  }
26  buffer = (ushort *)alloc_memory(uVar8 & 0xffffff03,(void *)(size * 2));
27  if (buffer != (ushort *)0x0) {
28    i = 0;
29    puVar1 = (uint *)((int)enc_data + (size & 0xfffffffc));
30    size = (uint)((int)puVar1 + (3 - (int)enc_data)) >> 2;
31    if (puVar1 < enc_data) {
32      size = 0;
33    }
34    decrypted = buffer;
35    if (size != 0) {
36      do {
37        chunk = *enc_data;
38        enc_data = enc_data + 1;
39        chunk = chunk ^ xor_key;
40        *decrypted = (ushort)chunk & 0xff;
41        decrypted[1] = (ushort)(chunk >> 8) & 0xff;
42        high_chunk = (ushort)(chunk >> 0x10);
43        i = i + 1;
44        decrypted[2] = high_chunk & 0xff;
45        decrypted[3] = high_chunk >> 8;
46        decrypted = decrypted + 4;
47      } while (i < size);
48    }
49    buffer[orig_length] = 0;
50  }
51  return buffer;
```

❶ ❷ ❸ ❹ ❺-❶ ❺-❷ ❺-❸ ❺-❹ ❺-❺ ❻

String Decryption Algorithm

- 先頭4バイトがXOR鍵（keyとする）
- オフセット+4から4バイトがXORされた（平文の）サイズ（xored_lengthとする）
- key ^ xored_length が平文のサイズとなる（orig_lengthとする）
- オフセット+8以降からorig_length分が暗号文

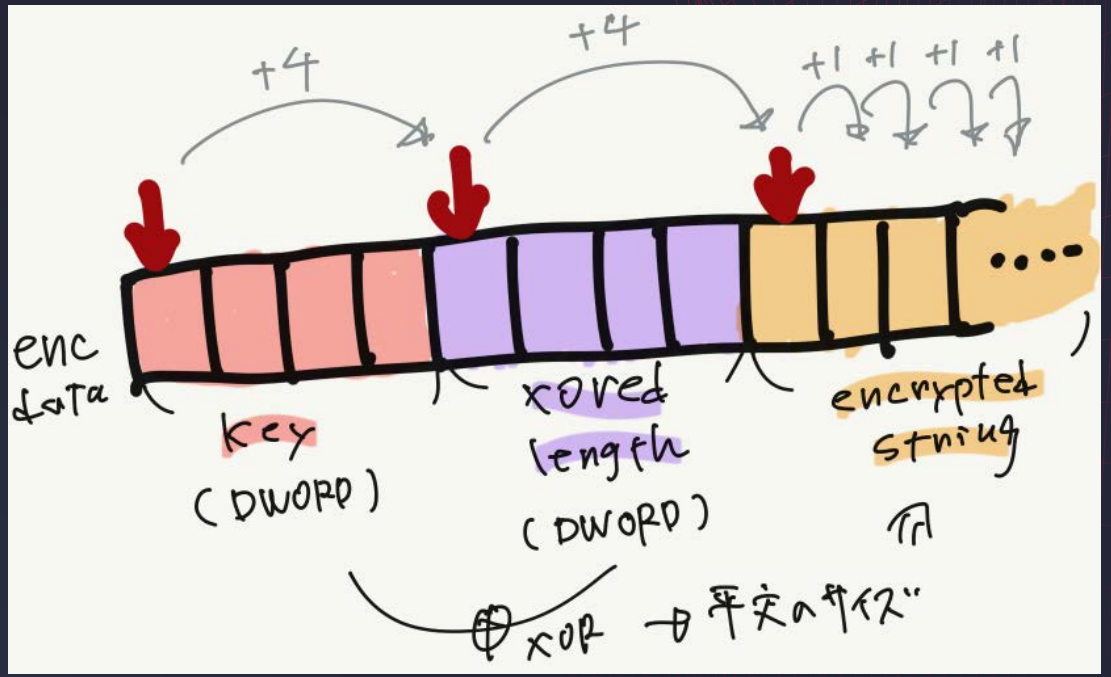

Decrypt Strings: Logic

暗号文字列のデータはEDX経由で復号関数（FUN_1000732d）に渡されている

```
1000ddb9 ba 80 f5 ...      MOV        EDX,DAT_1001f580
1000ddbe e8 6a 95 ...      CALL       FUN_1000732d
```

```
                    DWORD_1001f580
                                  key
1001f580 98 1e 9c 71     ddw      719C1E98h
1001f584 b5 1e 9c 7   xored_length 719C1EB5h
1001f588 cb              ??       CBh
1001f589 51              ??   enc 51h    Q
1001f58a da              ??       DAh
1001f58b 25              ??       25h    %
1001f58c cf              ??       CFh
1001f58d 5f              ??       5Fh    _
1001f58e ce              ??       CEh
1001f58f 34              ??       34h    4
1001f590 c4              ??       C4h
1001f591 53              ??       53h    S
1001f592 f5              ??       F5h
1001f593 12              ??       12h
1001f594 ea              ??       EAh
1001f595 71              ??       71h    q
1001f596 ef              ??       EFh
1001f597 1e              ??       1Eh
```

解析結果をもとにGhidra Scriptで復号処理を実装

Python - Interpreter

```
>>> import struct
>>> from itertools import cycle
>>>
>>> enc_data_addr = toAddr(0x1001f580)
>>> key = getInt(enc_data_addr)
>>> hex(key)
'0x719c1e98'
>>> xored_length = getInt(enc_data_addr.add(4))
>>> hex(xored_length)
'0x719c1eb5'
>>> original_length = key ^ xored_length
>>> original_length
45
>>> enc = getBytes(enc_data_addr.add(8), original_length).tostring()
>>> enc
'\xcbQ\xda%\xcf_\xce4\xc4S\xf5\x12\xeaq\xef\x1e\xfej\xc0&\xf1p\xf8\x1e\xefm\xc02\xedl\xe
>>> ''.join([chr(ord(k) ^ ord(v)) for k, v in zip(cycle(struct.pack('<I', key)), enc)])
'SOFTWARE\\Microsoft\\Windows\\CurrentVersion\\Run'
```

Decrypt Strings: Logic

- 穴埋め部分を実装

実装したdecrypt_string_stage1.pyのdecrypt_string関数

```
def decrypt_string(enc_data_addr):
    key = getInt(enc_data_addr)
    xored_length = getInt(enc_data_addr.add(4))
    original_length = key ^ xored_length
    enc = getBytes(enc_data_addr.add(8), original_length).tostring()
    return xor_with_multi_bytes(enc, key)
```

Decrypt Strings: How to get arguments?

- ここまでで、暗号データのアドレスがわかれば文字列を復号できることがわかった
- 暗号データのアドレスはEDXレジスタ経由で復号関数（FUN_1000732d）の第２引数として渡されている

FUN_1000732dの参照元を辿ると、EDX経由でアドレスが渡されている

```
1000282a ba c0 f5 ...    MOV     EDX,DAT_1001f5c0
1000282f e8 f9 4a ...    CALL    FUN_1000732d
```

```
100156aa ba e0 f9 ...    MOV     EDX,DAT_1001f9e0
100156af 89 b4 24 ...    MOV     dword ptr [ESP + local_44],ESI
100156b6 e8 72 1c ...    CALL    FUN_1000732d
```

```
10001c25 ba 30 f9 ...    MOV     EDX,DAT_1001f930
10001c2a 89 45 e4        MOV     dword ptr [EBP + local_20],EAX
10001c2d 81 75 e4 ...    XOR     dword ptr [EBP + local_20],0x36d9
10001c34 ff 75 fc        PUSH    dword ptr [EBP + local_8]
10001c37 8b 4d f0        MOV     this,dword ptr [EBP + local_14]
10001c3a e8 ee 56 ...    CALL    FUN_1000732d
```

Decrypt Strings: How to get arguments?

ただし、例外もある

- FUN_1000732dの「呼び出し元の関数の引数」としてアドレスが渡されているケース
- 本来は対応すべきだが、今回は無視することにする

```
void __fastcall FUN_10004ccb(uint *param_1,int param_2)

{
  ushort *puVar1;
  undefined4 uVar2;

  puVar1 = FUN_1000732d(0x9aa,(astruct *)param_1,0x3966);
```

暗号データのアドレスが呼び出し元関数の引数として渡されている

```
if (uVar1 == 0x1f775c77) {
  FUN_10004ccb((uint *)&DAT_1001f720,0);
  uVar1 = 0x1eb12525;
  goto LAB_10012bb2;
}
if (uVar1 == 0x4024269) {
  FUN_10004ccb((uint *)&DAT_1001f6c0,3);
  uVar1 = 0x2440893e;
  goto LAB_10012bb2;
}
if (uVar1 == 0x66a140d) {
  FUN_10004ccb((uint *)&DAT_1001f780,2);
  uVar1 = 0x4024269;
  goto LAB_10012bb2;
}
if (uVar1 == 0xe1cbd22) {
  FUN_10004ccb((uint *)&DAT_1001f760,6);
  uVar1 = 0x37073aea;
  goto LAB_10012bb2;
}
if (uVar1 == 0x1eb12525) {
  FUN_10004ccb((uint *)&DAT_1001f740,1);
  uVar1 = 0x66a140d;
  goto LAB_10012bb2;
}
```

Decrypt Strings: How to get arguments?

- 復号関数（FUN_1000732d）の呼び出し元の直前の命令を取得し、EDXにMOVされているアドレスを取得
- 特定のアドレスの直前の命令を取得するためのユーティリティ関数 get_instructions_beforeがutils.pyに定義済み

```
Python - Interpreter
>>> from utils import *
>>> insts = get_instructions_before(toAddr(0x1000ddbe), 3)
>>> for inst in insts[::-1]:
...     print(inst)
...
PUSH dword ptr [ESP + 0x4c]
MOV ECX,dword ptr [ESP + 0x34]
MOV EDX,0x1001f580
```

```
1000ddb1 ff 74 24 4c    PUSH    dword ptr [ESP + local_28]
1000ddb5 8b 4c 24 34    MOV     ECX,dword ptr [ESP + local_44]
1000ddb9 ba 80 f5 ...   MOV     EDX,DWORD_1001f580
1000ddbe e8 6a 95 ...   CALL    FUN_1000732d
```

EDXにMOVしてる命令だけフィルター

```
>>> def is_mov_edx(inst):
...     return str(inst).startswith('MOV EDX,0x')
...
>>> for inst in filter(is_mov_edx, insts):
...     print(inst)
...
MOV EDX,0x1001f580
```

Decrypt Strings: Assemble codes

- 復号関数のアドレスはとりあえずハードコードしておく

decrypt_string_stage1.pyのmain関数

```
36  def main():
37
38      decrypt_string_addr = toAddr(0x1000732d)
39
40      for xref in getReferencesTo(decrypt_string_addr):
41          # get instructions before callee address
42          insts = get_instructions_before(xref.getFromAddress(), 50)
43
44          # find instruction that passes
45          # address of encrypted data via EDX
46          for inst in insts:
47              if is_mov_edx(inst):
48                  # get encrypted data address and decrypt it
49                  data_addr = inst.getAddress(1)
50                  if data_addr:
51                      decrypted_str = decrypt_string(data_addr)
52                      # add comment
53                      print('[*] found at {}: {!r}'.format(inst.getAddress(), decrypted_str))
54                      add_bookmark_comment(inst.getAddress(), decrypted_str)
```

Decrypt Strings: Run

- Script Manager経由で `decrypt_string_stage1.py`を実行

実行結果はコンソールに出力される

Console - Scripting

```
decrypt_string_stage1.py> Running...
[*] found at 1000282a: '%s\\rundll32.exe "%s\\%s",Control_RunDLL'
[*] found at 10004103: '%s\\%s'
[*] found at 10005938: '%s\\%s'
[*] found at 10008d16: '%u.%u.%u.%u'
```

復号後の文字列がコメントされている

```
uVar6 = 0x752c;
            /* SOFTWARE\Microsoft\Windows\CurrentVersion\Run */
puVar1 = FUN_1000732d(0x5eec,(astruct *)&DWORD_1001f580,0x752c);
```

```
          /* %u.%u.%u.%u */
puVar4 = FUN_1000732d(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
```

Window > Bookmark からもコメントを確認できる

Bookmarks - (24 bookmarks)

Type	Category	Description	Location
Note	decrypted_str	%s\rundll32.exe "%s\%s",Control_RunDLL	1000282a
Note	decrypted_str	%s\%s	10004103
Note	decrypted_str	%s\%s	10005938
Note	decrypted_str	%u.%u.%u.%u	10008d16
Note	decrypted_str	DNT: 0Referer: %s/%sContent-Type: multipart/for...	10008e88
Note	decrypted_str	SOFTWARE\Microsoft\Windows\CurrentVersion\Run	1000ddb9
Note	decrypted_str	POST	1001058e
Note	decrypted_str	%s\rundll32.exe "%s\%s",Control_RunDLL	100136d7
Note	decrypted_str	%s\%s	10014329
Note	decrypted_str	%s:Zone.Identifier	1000b3ae
Note	decrypted_str	%s\rundll32.exe "%s",Control_RunDLL %s	1000f2e6
Note	decrypted_str	%s\%s%x	1001c33e
Note	decrypted_str	%s\%s	1001c3c0

Decrypt Strings Stage2

- 復号関数のアドレスは常に固定とは限らない 🤔
- 復号関数を都度手動で解析して特定していては自動化の意味がない 🤔

複数サンプルを解析し、
復号関数内の共通する特徴的な命令列を見つけ出し、
それをもとに復号関数を自動特定する

本演習は自主学習にします。

Appendixに課題と解法が書いてあるので興味のある方はトライしてみてください。

Step 4: Config Structure Analysis

Config Structure Analysis

- EMOTETは通信先を検体内にハードコードしている
- 通信関連のAPIを辿り、ハードコードされた通信先情報の取得を試みる

Bookmarksから、`search_hash.py`でみつけた
通信関連のAPIを確認できる

Bookmarks - (240 bookmarks)

Type	Category	Description	Location
Note	hashed_name	InternetCloseHandle	10018d90
Note	hashed_name	InternetConnectW	10002c02
Note	hashed_name	InternetOpenW	10005e2a
Note	hashed_name	InternetReadFile	10005fd7
Note	hashed_name	InternetSetOptionW	10002550

Find Hostname & Port

- InternetConnectW API

```
void InternetConnectW(
  HINTERNET     hInternet,
  LPCWSTR       lpszServerName,
  INTERNET_PORT nServerPort,
  LPCWSTR       lpszUserName,
  LPCWSTR       lpszPassword,
  DWORD         dwService,
  DWORD         dwFlags,
  DWORD_PTR     dwContext
);
```

- InternetConnectWを呼び出しているFUN_10002b4fの第七引数にホスト名、第４引数にポート番号が渡されている

InternetConnectWの呼び出しもと

Decompile: FUN_10002b4f - (emotet.dll)

```
1
2  void FUN_10002b4f(undefined4 param_1,undefined4 param_2,undefined param_3,undefined4 param_4,
3                    undefined4 param_5,undefined4 param_6,undefined4 param_7,undefined4 param_8,
4                    undefined4 param_9,undefined param_10,undefined4 param_11)
5
6  {
7    code *pcVar1;
8
9    _();
10                   /* InternetConnectW */
11                   /* wininet.dll */
12   pcVar1 = (code *)resolve_api(0x71,0x7b,0x2175dc,0x26e080);
13   (*pcVar1)(param_6,param_7,param_4,0,0,param_8,0,0);
14   return;
15 }
```

pcVar1をRetype Variableで InternetConnectW *型に変更した後、引数名や型を手動で変更する

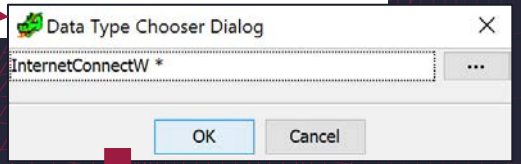

Decompile: call_internetconnectw - (emotet.dll)

```
1
2  void call_internetconnectw
3                 (undefined4 param_1,undefined4 param_2,undefined param_3,INTERNET_PORT port,
4                 undefined4 param_5,HINTERNET param_6,LPCWSTR hostname,DWORD param_8,
5                 undefined4 param_9,undefined param_10,undefined4 param_11)
6
7  {
8    InternetConnectW *pcVar1;
9
10   _();
11                   /* InternetConnectW */
12                   /* wininet.dll */
13   pcVar1 = (InternetConnectW *)resolve_api(0x71,0x7b,0x2175dc,0x26e080);
14   (*pcVar1)(param_6,hostname,port,(LPCWSTR)0x0,(LPCWSTR)0x0,param_8,0,0);
15   return;
16 }
```

Find Hostname & Port

- call_internetconnectw（FUN_10002b4f）の呼び出し元を辿ると、FUN_1000f70cが呼び出していることがわかる
- ホスト名が渡されている第七引数は、FUN_1000f70cの第引数から渡されている
- ポート番号が渡されている第４引数には、in_stack_00000024という変数が渡されている
  - 実際はポート番号もFUN_1000f70cの引数として渡されているのだが、Ghidraが関数の解析に失敗していて、解釈がおかしくなっている

FUN_1000f70c内でcall_internetconnectwを呼び出している部分

```
local_140 = call_internetconnectw                    ↓ポート番号
                    (0x76f3,0x62c4,(char)local_144,in_stack_00000024,0x5b4,local_1c,
          ホスト名→ local_10,3,0x32bd,(char)local_144,0x65b6);
```

call_internetconnectwに渡されているホスト名はFUN_1000f70cの第二引数から渡される

```
undefined4 __fastcall
FUN_1000f70c(undefined4 param_1,int param_2,undefined4 param_3,int **param_4,undefined4 *param_5,
             undefined4 param_6,undefined4 param_7)

{
  undefined4 uVar1;
  int iVar2;
  void *this;
  uint uVar3;
  LPCWSTR pWVar4;
  undefined extraout_CL;
  undefined4 extraout_ECX;
  undefined4 uVar5;
  undefined4 uVar6;
  int iVar7;
  INTERNET_PORT in_stack_00000024;
  void *local_144;
  int local_140;
  int local_1c;
  undefined4 local_18;
  undefined4 local_14;
  LPCWSTR local_10;
  ushort *local_c;
  undefined4 local_8;
  undefined4 local_4;

  local_10 = (LPCWSTR)param_2;
```

Fix Function: FUN_1000f70c

- FUN_1000f70cの引数の解釈にGhidraが失敗している
- そのため、Edit Function Signatureで引数の数を調整する

FUN_1000f70cの呼び出し元を見てみると
ECX, EDX, PUSH*9で引数を渡している

```
10008a0a ff b4 24 ...    PUSH    dword ptr [ESP + local_b2c]
10008a11 83 a4 24 ...    AND     dword ptr [ESP + local_b34],0x0
10008a19 8d 84 24 ...    LEA     EAX=>local_800,[ESP + 0x46c]
10008a20 ff 74 24 50     PUSH    dword ptr [ESP + local_c1c]
10008a24 83 a4 24 ...    AND     dword ptr [ESP + local_b30],0x0
10008a2c 8d 94 24 ...    LEA     EDX=>local_b00,[ESP + 0x170]
10008a33 ff 74 24 7c     PUSH    dword ptr [ESP + local_bf4]
10008a37 ff 74 24 30     PUSH    dword ptr [ESP + local_c44]
10008a3b 50              PUSH    EAX
10008a3c ff b4 24 ...    PUSH    dword ptr [ESP + local_b78]
10008a43 8b 4c 24 6c     MOV     ECX,dword ptr [ESP + local_c14]
10008a47 8d 84 24 ...    LEA     EAX=>local_b3c,[ESP + 0x144]
10008a4e 50              PUSH    EAX
10008a4f 8d 84 24 ...    LEA     EAX=>local_b34,[ESP + 0x150]
10008a56 50              PUSH    EAX
10008a57 8d 84 24 ...    LEA     EAX=>local_a00,[ESP + 0x288]
10008a5e 50              PUSH    EAX
10008a5f e8 a8 6c ...    CALL    FUN_1000f70c
```

FUN_1000f70cを右クリック > Edit Function Signatureで編集
Add Parameterで引数の数が合計11になるまで追加

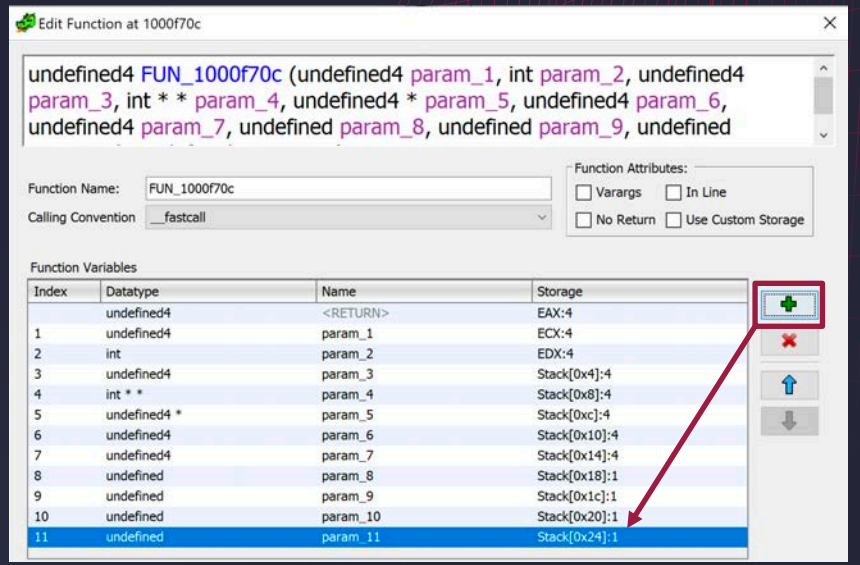

Fix Function: FUN_1000f70c

- 正しく引数の数を調整すると、FUN_1000f70cの第１１引数にポート番号が渡され、call_internetconnectwの第４引数に渡されていることがわかる

```
local_140 = call_internetconnectw
                      (0x76f3,0x62c4,(char)local_144,(INTERNET_PORT)_param_11,0x5b4,
                       local_1c,local_10,3,0x32bd,(char)local_144,0x65b6);
```

- FUN_1000f70cの呼び出し元でも引数が反映されている（名前は手動で変更）

```
iVar7 = FUN_1000f70c(0x58a3,(int)hostname,local_a00,&local_b34,&local_b3c,0x4e48,local_800
                     ,0x98,0x53,0x9b,(char)port);
```

FUN_10007e95

- FUN_1000f70cを呼び出している関数がFUN_10007e95
- portへのアサインは見えるが、hostnameがどこからアサインされているかわからない
- ポート番号はDAT_1001fa08からのオフセット0x24+0x4に格納されている
  - → 構造体として定義しておく

portがアサインされている箇所

```
          /* %u.%u.%u.%u */
puVar4 = decrypt_string(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
bVar1 = *(byte *)(*(int *)(DAT_1001fa08 + 0x24) + 1);
FUN_10017f0f((uint)*(byte *)(*(int *)(DAT_1001fa08 + 0x24) + 2),0x1abe,bVar1,0x62f4,0x16d7
             ,(uint)**(byte **)(DAT_1001fa08 + 0x24),0x57f1,0x190a,0x4e52,(uint)bVar1,
             puVar4,(uint)*(byte *)(*(int *)(DAT_1001fa08 + 0x24) + 3));
FUN_10007c8f(0xcd4);
iVar7 = 0x2351b248;
port = (uint)*(ushort *)(*(int *)(DAT_1001fa08 + 0x24) + 4);
```

DAT_1001fa08に対し、Create Auto Structureで構造体定義

```
          /* %u.%u.%u.%u */
puVar4 = decrypt_string(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
bVar1 = PTR_1001fa08->field_0x24[1];
FUN_10017f0f((uint)PTR_1001fa08->field_0x24[2],0x1abe,bVar1,0x62f4,0x16d7,
             (uint)*PTR_1001fa08->field_0x24,0x57f1,0x190a,0x4e52,(uint)bVar1,puVar4,
             (uint)PTR_1001fa08->field_0x24[3]);
FUN_10007c8f(0xcd4);
iVar7 = 0x2351b248;
port = (uint)*(ushort *)(PTR_1001fa08->field_0x24 + 4);
```

FUN_10017f0f

- フォーマット文字列を第１１引数として受け取る
  - IPアドレスのようなフォーマット
- FUN_10017f0fは、実質_snwprintfを呼び出すだけ

```
int _snwprintf(
   wchar_t *buffer,
   size_t count,
   const wchar_t *format [,
   argument] ...
);
```

IPアドレスのようなフォーマット文字列が渡される

```
          /* %u.%u.%u.%u */
puVar4 = decrypt_string(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
bVar1 = PTR_1001fa08->field_0x24[1];
FUN_10017f0f((uint)PTR_1001fa08->field_0x24[2],0x1abe,bVar1,0x62f4,0x16d7,
             (uint)*PTR_1001fa08->field_0x24,0x57f1,0x190a,0x4e52,(uint)bVar1,puVar4,
             (uint)PTR_1001fa08->field_0x24[3]);
```

Decompile: FUN_10017f0f - (emotet.dll)

```
1
2  void __cdecl
3  FUN_10017f0f(undefined4 param_1,undefined4 param_2,undefined param_3,undefined4 param_4,
4               undefined4 param_5,undefined4 param_6,undefined4 param_7,undefined4 param_8,
5               undefined4 param_9,undefined4 param_10,undefined4 param_11,undefined4 param_12)
6
7  {
8    code *pcVar1;
9    undefined4 extraout_ECX;
10   undefined4 extraout_EDX;
11   undefined4 uVar2;
12   undefined4 uVar3;
13
14   _();
15   uVar3 = 0x40;
16   uVar2 = extraout_EDX;
17                     /* _snwprintf */
18   pcVar1 = (code *)FUN_10018202(extraout_ECX,0x8440e238,0x34c);
19   (*pcVar1)(uVar2,uVar3,param_11,param_12,param_1,param_10,param_6);
20   return;
21 }
```

Fix Function: FUN_10017f0f

- 一見問題ないようだが、実は呼び出し規約と引数の数が間違っている
  - __cdecl -> __fastcall
  - 引数の数 -> 14

Edit Function Signatureで修正

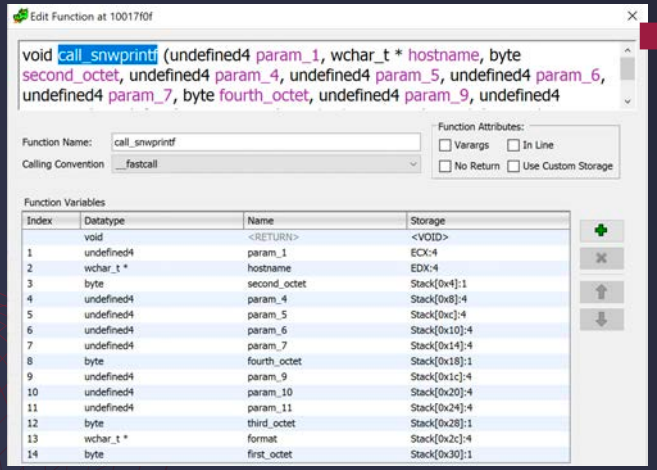

関数シグネチャ修正後、変数名・型を変更した結果
(param_2とextraout_EDXは実際同一だが、変数名が同期されず、今回は無視)

Decompile: call_snwprintf - (emotet.dll)

```
1
2  void __fastcall
3  call_snwprintf(undefined4 param_1,wchar_t *hostname,byte second_octet,undefined4 param_4,
4                 undefined4 param_5,undefined4 param_6,undefined4 param_7,byte fourth_octet,
5                 undefined4 param_9,undefined4 param_10,undefined4 param_11,byte third_octet,
6                 wchar_t *format,byte first_octet)
7
8  {
9    _snwprintf *_snwprintf;
10   undefined4 extraout_ECX;
11   wchar_t *extraout_EDX;
12   undefined3 in_stack_00000005;
13   undefined3 in_stack_00000019;
14   undefined3 in_stack_00000029;
15   undefined3 in_stack_00000031;
16   wchar_t *_Dest;
17   size_t _Count;
18
19   _();
20   _Count = 0x40;
21   _Dest = extraout_EDX;
22                     /* _snwprintf */
23   _snwprintf = (_snwprintf *)FUN_10018202(extraout_ECX,0x8440e238,0x34c);
24   (*_snwprintf)(_Dest,_Count,format,_first_octet,_second_octet,_third_octet,_fourth_octet);
25   return;
26 }
```

Config Structure

- call_snwprintfでホスト名（IP）が生成されることがわかった
- IPアドレスの各オクテットがcall_snwprintfの引数に渡されている
- ここまでの情報から、0x1001fa08には次のような構造体へのポインタが存在していると推測できる
  - ✓ オフセット+0x24にはIPアドレスへのポインタが格納されているはず
  - ✓ IPアドレスはリトルエンディアンの4バイト（1オクテット1バイト）
  - ✓ また、オフセット+0x24+0x4にポート番号が格納されているはず

```
        /* %u.%u.%u.%u */
format = decrypt_string(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
uVar9 = PTR_1001fa08->field_0x24[1];
call_snwprintf(0xc6a,hostname,PTR_1001fa08->field_0x24[2],0x1abe,(uint)uVar9,0x62f4,0x16d7
    *PTR_1001fa08->field_0x24,0x57f1,0x190a,0x4e52,uVar9,(wchar_t *)format,
    PTR_1001fa08->field_0x24[3]);
FUN_10007c8f(0xcd4);
iVar5 = 0x2351b248;
port = (uint)*(ushort *)(PTR_1001fa08->field_0x24 + 4);
```

第２オクテット
第３オクテット
第１オクテット
第４オクテット
ポート番号

Config Structure

- ここまでの情報をまとめて、次のような構造体を定義

擬似構造体

```
typedef struct {
    byte ip_address[4];
    WORD port;
} C2Info;

typedef struct {
    ...
    // at offset 0x24
    C2Info *c2;
} Config;
```

Data Type Manager > emotet.dll 右クリック > New > Structure で`C2Info`を新規作成し、次に`PTR_1001fa08`を右クリック > Edit Data Type からオフセット36を`C2Info*`に変更

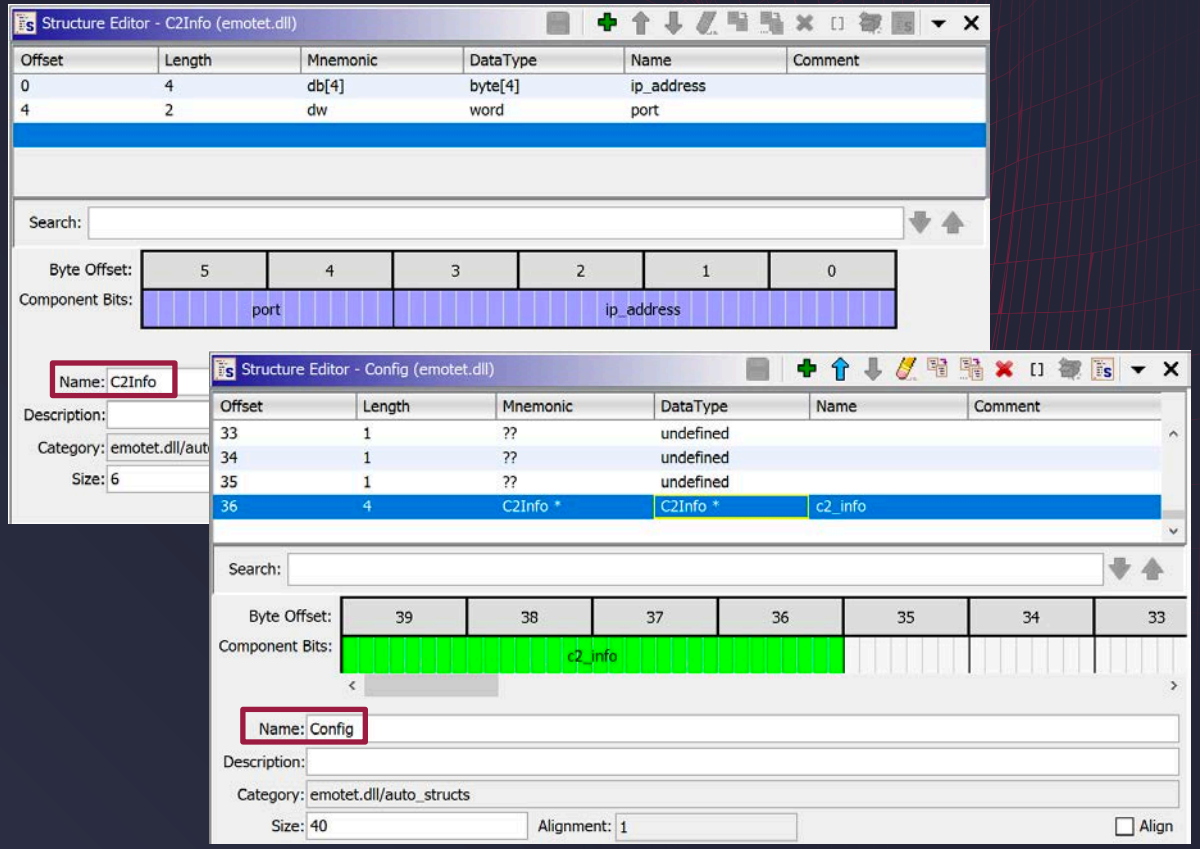

Config Structure

- 構造体が適用されると見やすくなる
- ここで生成されたIPアドレスとポート番号が、先ほど解析したFUN_1000f70cに渡され、通信が発生する
- つまり、これらのIPアドレスとポート番号がC&Cサーバの情報となることがわかる

```
        /* %u.%u.%u.%u */
format = decrypt_string(0x4857,(astruct *)&DAT_1001f7e0,0x2227);
uVar9 = g_config->c2_info->ip_address[1];
call_snwprintf(0xc6a,hostname,g_config->c2_info->ip_address[2],0x1abe,(uint)uVar9,0x62f4,
               0x16d7,g_config->c2_info->ip_address[0],0x57f1,0x190a,0x4e52,uVar9,
               (wchar_t *)format,g_config->c2_info->ip_address[3]);
FUN_10007c8f(0xcd4);
iVar5 = 0x2351b248;
port = (uint)g_config->c2_info->port;
```

Config Structure

- g_config(PTR_1001fa08)はポインタを保持するだけのグローバル変数なので、Config構造体の実態へのポインタは実行時に格納される
- では、いつ・どこで初期化されるのか？

g_configの参照元一覧を確認すると、
WRITEしているのは0x100e258の一箇所のみ

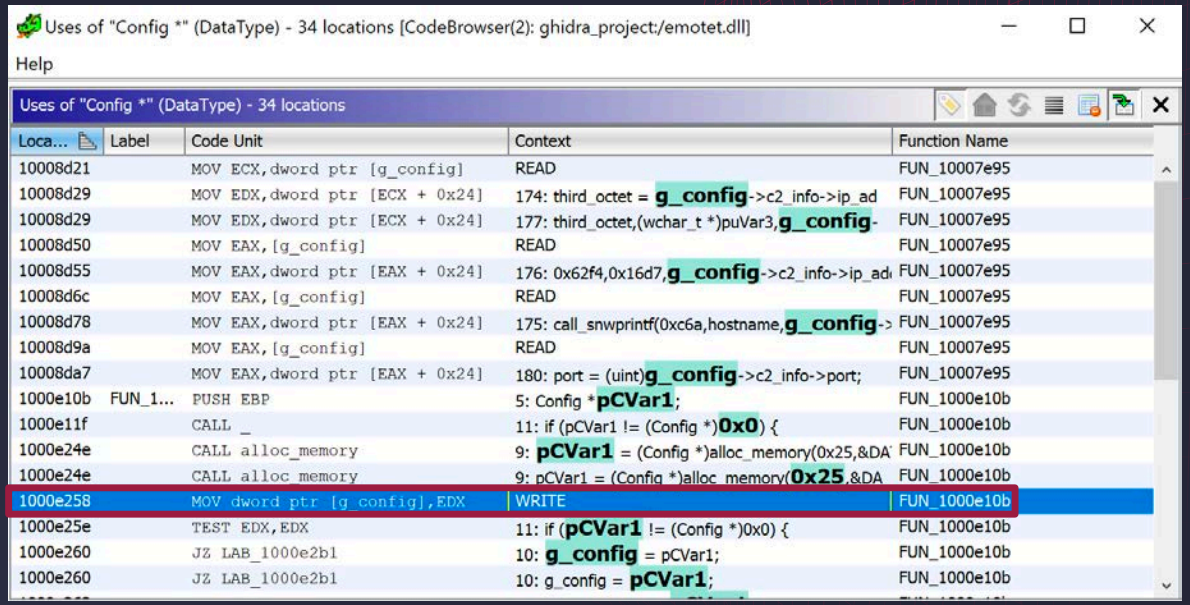

FUN_1000e10b

Config構造体を初期化する関数

1. Config構造体用のバッファを確保し、g_configへポインタをコピー
2. DAT_1001f000からC2Info構造体のポインタをコピー
3. DAT_1001f000には、1要素あたり8バイトの配列が格納されている

pcVar1を右クリック > Auto Fill in Structure して Config構造体をアップデートした後のコード

Decompile: FUN_1000e10b - (emotet.dll)

```
1
2  undefined4 __cdecl FUN_1000e10b(undefined4 *param_1)
3
4  {
5    Config *pCVar1;
6    int iVar1;
7
8    _();
9    pCVar1 = (Config *)alloc_memory(0x25,&DAT_0000002c);
10   g_config = pCVar1;                                    ①
11   if (pCVar1 != (Config *)0x0) {
12     iVar1 = pCVar1->field_0x8;
13     pCVar1->field_0x28 = &DAT_1001f000;
14     pCVar1->c2_info = (C2Info *)&DAT_1001f000;          ②
15     pCVar1->field_0x10 = 0;
16     while (*(int *)(&DAT_1001f000 + iVar1 * 8) != 0) {  ③
17       iVar1 = iVar1 + 1;
18       pCVar1->field_0x8 = iVar1;
19     }
20     iVar1 = FUN_1001829c(param_1,0x35,0x2807,0x110f);
21     if (iVar1 != 0) {
22       return 1;
23     }
24     FUN_1000d4e0(g_config,0xd0,0x3dc4,0x573f);
25   }
26   return 0;
27 }
```

FUN_1000e10b

- 現在C2Info構造体は6バイトなので、（使用用途は不明だが）2バイト分追加しておく

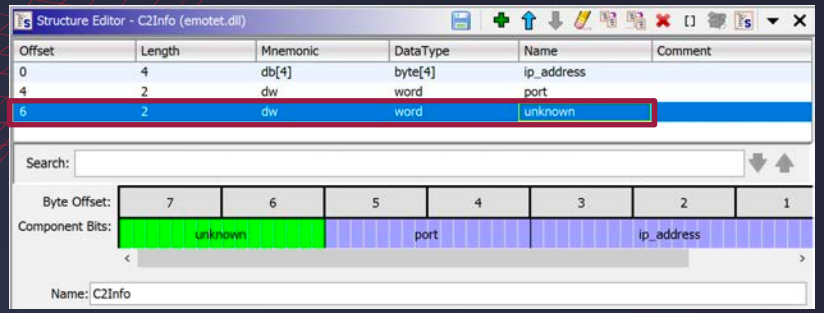

- DAT_1001f000(g_c2info_array)をRetype Globalし、C2Info構造体の配列として定義

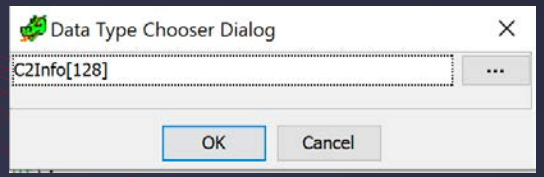

編集後のFUN_1000e10b

Decompile: FUN_1000e10b - (emotet.dll)

```
1
2  undefined4 __cdecl FUN_1000e10b(undefined4 *param_1)
3
4  {
5    Config *tmp;
6    int i;
7
8    _();
9    tmp = (Config *)alloc_memory(0x25,&DAT_0000002c);
10   g_config = tmp;
11   if (tmp != (Config *)0x0) {
12     i = tmp->field_0x8;
13     tmp->field_0x28 = (undefined *)g_c2info_array;
14     tmp->c2_info = g_c2info_array;
15     tmp->field_0x10 = 0;
16     while (*(int *)g_c2info_array[i].ip_address != 0) {
17       i = i + 1;
18       tmp->field_0x8 = i;
19     }
```

Array of C2Info

- DAT_1001f000(g_c2info_array) にはIPアドレス、ポート番号が平文で格納されている
- このデータをパースすれば通信先情報を取得できそう

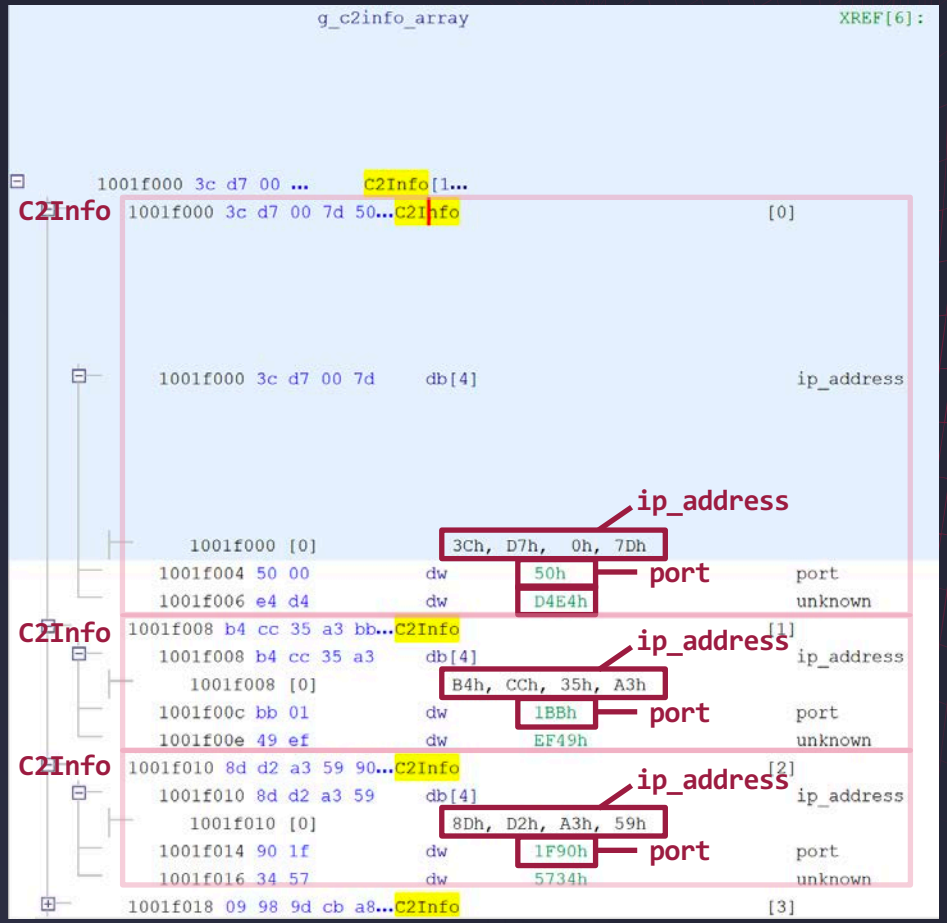

Protocol of Connection

IPとポートは判明したが、プロトコル(HTTP/HTTPS)は？

- HTTPSを使う場合、WinInet系APIではHttpOpenRequestの`dwFlags`で`INTERNET_FLAG_SECURE(0x800000)`が指定される

HttpOpenRequestの関数シグネチャ

```
void HttpOpenRequestW(
  HINTERNET hConnect,
  LPCWSTR   lpszVerb,
  LPCWSTR   lpszObjectName,
  LPCWSTR   lpszVersion,
  LPCWSTR   lpszReferrer,
  LPCWSTR   *lplpszAcceptTypes,
  DWORD     dwFlags,
  DWORD_PTR dwContext
);
```

INTERNET_FLAG_SECURE

0x00800000

Uses secure transaction semantics. This translates to using Secure Sockets Layer/Private Communications Technology (SSL/PCT) and is only meaningful in HTTP requests. This flag is used by HttpOpenRequest and InternetOpenUrl, but this is redundant if https:// appears in the URL.The InternetConnect function uses this flag for HTTP connections; all the request handles created under this connection will inherit this flag.

https://docs.microsoft.com/en-us/windows/win32/api/wininet/nf-wininet-httpopenrequestw

Protocol of Connection

HttpOpenRequestWの呼び出し元を辿ると、INTERNET_FLAG_SECURE(0x800000)のビットは立っていないので、プロトコルはHTTPが使用されることがわかる

```
pWVar4 = (LPCWSTR)call_httpopenrequestw
                            (0x5c18,0x844cc300,local_c,0x7505,0x1cf0,local_140,0x844cc300,
                             0x844cc300,0x3639,0,0x6b8d,param_3);
```

Decompile: call_httpopenrequestw - (emotet.dll)

```
1
2  void __cdecl
3  call_httpopenrequestw
4            (undefined4 param_1,undefined4 param_2,LPCWSTR param_3,undefined4 param_4,
5            undefined4 param_5,HINTERNET param_6,undefined4 param_7,DWORD dwFlags,undefined4 param_9,
6            undefined param_10,undefined4 param_11,LPCWSTR param_12)
7
8  {
9    HttpOpenRequestW *pcVar1;
10   undefined4 _;
11
12   ::_();
13                     /* HttpOpenRequestW */
14                     /* wininet.dll */
15   pcVar1 = (HttpOpenRequestW *)resolve_api(0x379,_,0x2175dc,0x89d4a7f4);
16   (*pcVar1)(param_6,param_3,param_12,(LPCWSTR)0x0,(LPCWSTR)0x0,(LPCWSTR *)0x0,dwFlags,0);
17   return;
18 }
```

演習

Extract C2 in Action

extract_c2_stage1_not_impl.py のparse_single_configを実装してください

- アドレス0x1001f000以降に存在しているIPアドレスとポートを以下形式で出力する
  - http://<*ip-address*>:<*port*>

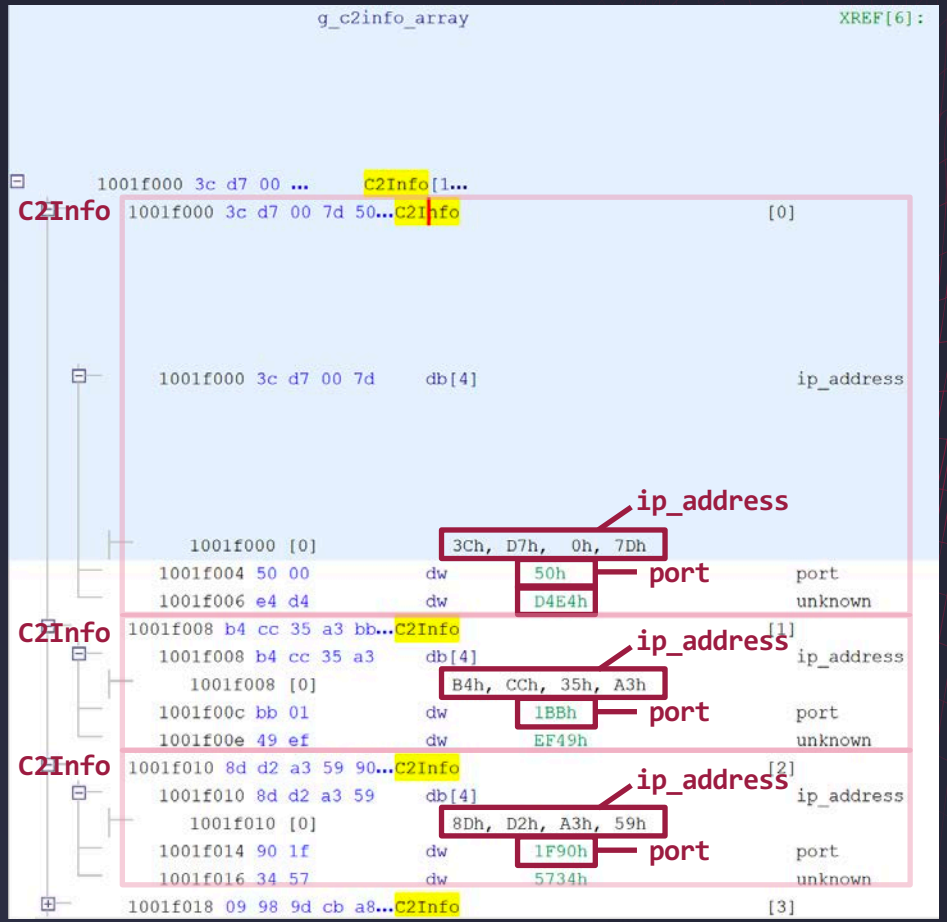

Extract C2 in Action

1. g_c2info_arrayの先頭アドレスから処理を進める
2. 先頭4バイトをIPアドレス、オフセット+4から2バイトをポート番号としてパース
3. 8バイト(C2Info構造体のサイズ)分アドレスを進める

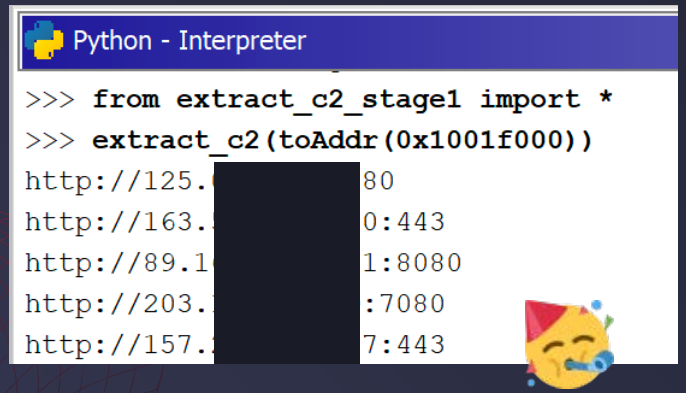

実装したextract_c2_stage1.py

```python
def parse_single_config(addr):
    # get 4 bytes from top of the given address
    # this shuld be IP address
    ip = convert_dword_to_ip(getInt(addr))

    # '0.0.0.0' is a mark of the end of config
    if ip == '0.0.0.0':
        raise InvalidConfig('Invalid Config or found Config end')

    # get 2 bytes from offset 4 of the given address,
    # this should be port number
    port = getShort(addr.add(SIZE_OF_IP))
    return ip, port

def iterate_config(config_addr):
    while True:
        try:
            ip, port = parse_single_config(config_addr)
            config_addr = config_addr.add(SIZE_OF_SINGLE_CONFIG)
            yield (ip, port)
        except InvalidConfig:
            # when parse_single_config throw InvalidConfig exceptoin,
            # it should be that it finished iteration of config
            break
        except Exception as e:
            print('[!] {}'.format(e))

def extract_c2(config_addr):
    for (ip, port) in iterate_config(config_addr):
        print('http://{}:{}'.format(ip, port))
```

Extract C2 Stage2

- コンフィグのアドレスは常に固定とは限らない 🤔
- コンフィグのアドレスを都度手動で解析・特定していては自動化の意味がない 🤔

複数サンプルを解析し、コンフィグ初期化関数内で
共通する特徴的な命令列を見つけ出し、
それをもとにコンフィグのアドレスを自動特定する

How to compare samples?

Version Tracking

- 2つのバイナリの差分を解析するGhidraの機能
  - パッチの差分解析
  - 共通する命令列の可視化

差分表示の例

Version Tracking: Main Window

- Version Trackingで、関数を比較したりする際に使用するウィンドウ
- 最初はなにも表示されない

Ghidraのプロジェクト画面から開く

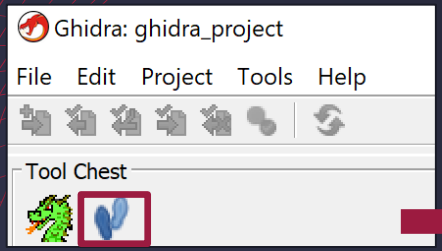

Version Tracking Windowの初期画面

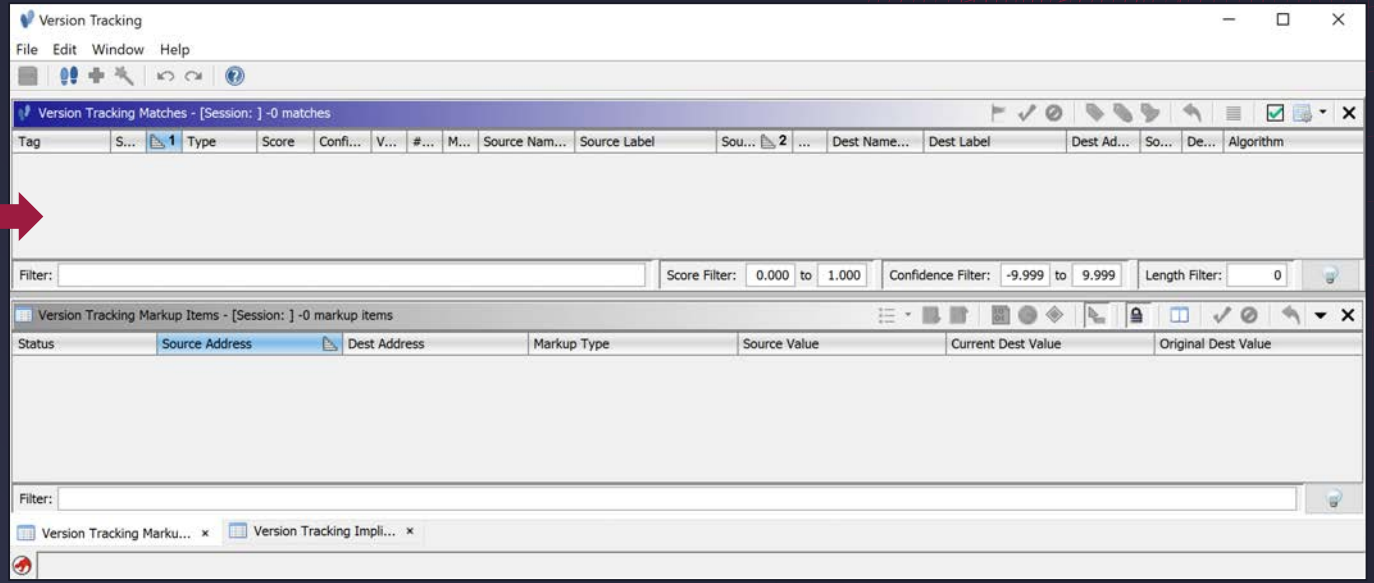

Version Tracking: Session

バイナリの比較結果を**Session**という情報として保持

- Sessionの作成手順
  1. Version Tracking Window > [Create a new Version Tracking Session]
  2. Source ProgramとDestination Programを指定
  3. [Run Precondition Checks]を実行

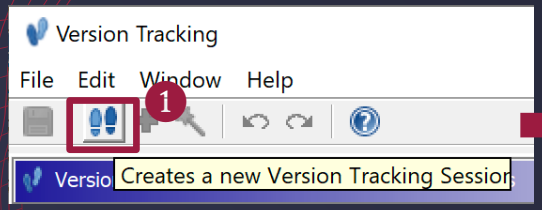

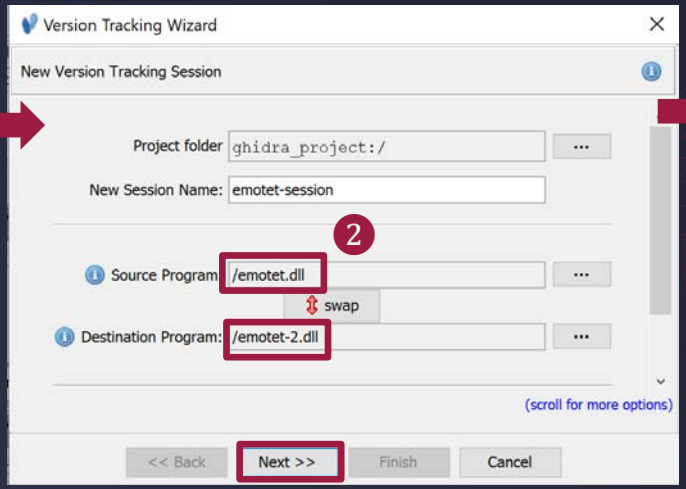

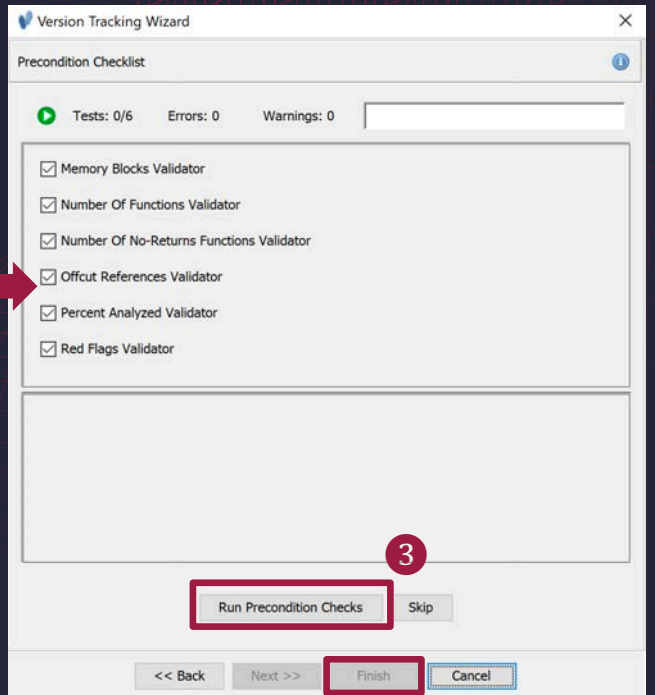

Version Tracking: Compare Functions

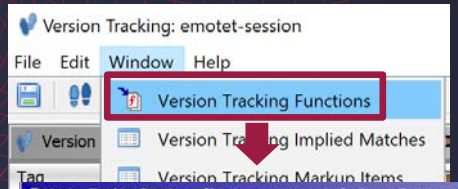

Version Tracking Functionsを使うと、比較したい関数を入力すると差分が可視化できる
(emotet.dllの`0x1000e10b`とemotet-2.dllの`0x1001a094`の比較例)

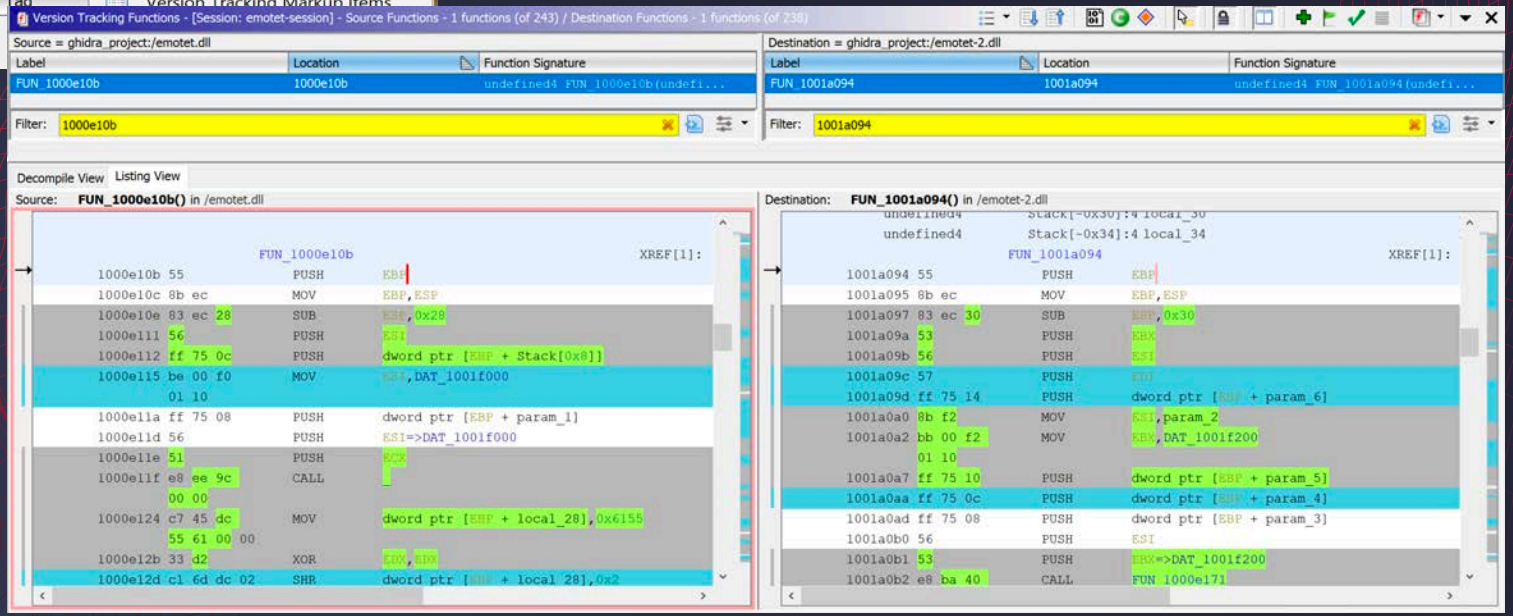

ブルー: 一致していないコードユニット

グレー: 部分的に一致していないコードユニット

グリーン: バイト列、ニーモニック、オペランドのいずれかが異なっている箇所

ホワイト: 完全一致しているコードユニット

Decrypt Strings Stage2: Find Function

演習

`extract_c2_stage2_not_impl.py`の`find_config_addrss`を実装する

1. Version Trackingで複数サンプルの命令列を比較
   - Source -> emotet.dll: `0x1000e10b`（Version Tracking Functionsで検索するときは0xをとる）
   - Destination -> emotet-2.dll: `0x1001a094`（Version Tracking Functionsで検索するときは0xをとる）
2. 共通する“特徴的な”命令列を特定
3. 特徴的な命令列を含む関数一覧をスクリプトで取得

`extract_c2_stage2_not_impl.py`の`find_config_addrss`

```
42  def find_config_address():
43      ''' **** IMPLEMENT HERE ****
44
45      search config embedded address and return address of it.
46      Hint:
47          1. use Version Tracking to configure the characteristic
48              instructions related to config
49          2. use `findBytes` method to search bytes/instructions
50      '''
51      raise NotImplementedError('not implemented')
```

Decrypt Strings Stage2: Find Function

- Version Trackingで複数サンプル内の命令列を比較
- 共通する特徴的な命令列を特定する

たとえばこのあたり

```
1000e267 89 72 28        MOV    dword ptr [EDX + 0x28],ESI=>DAT_1001f000
1000e26a 89 72 24        MOV    dword ptr [EDX + 0x24],ESI=>DAT_1001f000
1000e26d 89 4a 10        MOV    dword ptr [EDX + 0x10],ECX
1000e270 eb 04           JMP    LAB_1000e276
```

```
1001a1d9 89 58 28        MOV    dword ptr [EAX + 0x28],EBX=>DAT_1001f20
1001a1dc 89 58 08        MOV    dword ptr [EAX + 0x8],EBX=>DAT_1001f200
1001a1df 89 78 3c        MOV    dword ptr [EAX + 0x3c],EDI
1001a1e2 eb 04           JMP    LAB_1001a1e8
```

デコンパイル結果

```
*(undefined **)((int)pvVar1 + 0x28) = &DAT_1001f000;
*(undefined **)((int)pvVar1 + 0x24) = &DAT_1001f000;
*(undefined4 *)((int)pvVar1 + 0x10) = 0;
while (*(int *)(&DAT_1001f000 + iVar2 * 8) != 0) {
```

Decrypt Strings Stage2: Find Function

- 特徴的な命令列を検索し、それの命令の引数に渡されているアドレスを取得
  - `Address[] findBytes(Address start, java.lang.String byteString, int matchLimit)`
    - 正規表現をつかった検索が可能
  - `Instruction getInstructionAt(Address address)`
    - 引数addressで指定したアドレスの命令を取得

```
1000e267 89 72 28        MOV     dword ptr [EDX + 0x28],ESI=>DAT_1001f000
1000e26a 89 72 24        MOV     dword ptr [EDX + 0x24],ESI=>DAT_1001f000
1000e26d 89 4a 10        MOV     dword ptr [EDX + 0x10],ECX
1000e270 eb 04           JMP     LAB_1000e276
```

```
Python - Interpreter
>>> asm = b'\\x89.{1}\\x28\\x89.{2}\\x89.{2}\\xeb\\x04
>>> found = findBytes(None, asm, -1)
>>> found
array(ghidra.program.model.address.Address, [1000e267])
>>> inst = getInstructionAt(found[0])
>>> config_addr = inst.getAddress(1)
>>> config_addr
1001f000
```

レジスタや変数など、コンパイラ等によって可変なものは「.」(任意の一文字)にして一般化する

Decrypt Strings Stage2: Fully Automated

find_config_addressを実装したextract_c2_stage2.pyとして保存して実行

```
def find_config_address():
    asm = b'\\x89.{1}\\x28\\x89.{2}\\x89.{2}\\xeb\\x04'
    found = findBytes(None, asm, -1)
    if not found:
        raise RuntimeError('Config not found')
    elif len(found) != 1:
        raise ValueError('False detection of config')

    inst = getInstructionAt(found[0])
    config_addr = inst.getAddress(1)
    return config_addr
```

emotet.dllおよびemotet-2.dllで自動抽出が可能に

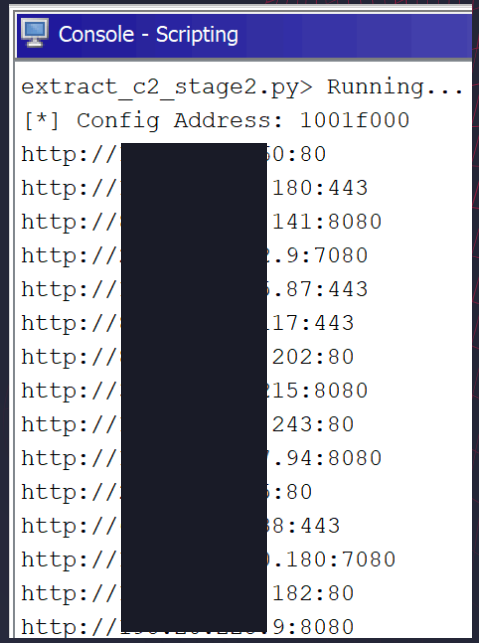

Summary

Ghidra Script for EMOTET

1. APIハッシュの突合
   - search_hash.py
2. 文字列の復号
   - decrypt_string_stage1.py
3. C&C情報の抽出
   - extract_c2_stage1.py
   - extract_c2_stage2.py

(Advanced) It's Automatic!

- extract_c2_stage2.pyをHeadless対応したanalyzer.pyを Headless Analyzerで実行すればバッチ処理も可能 😎

Headless AnalyzerでCLI経由でanalyzer.pyを実行

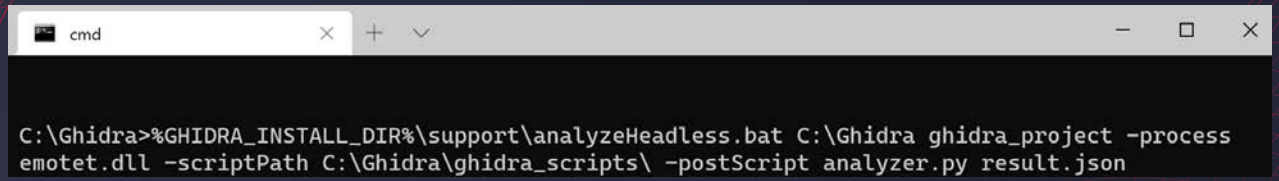

出力されたresolt.json（抜粋）

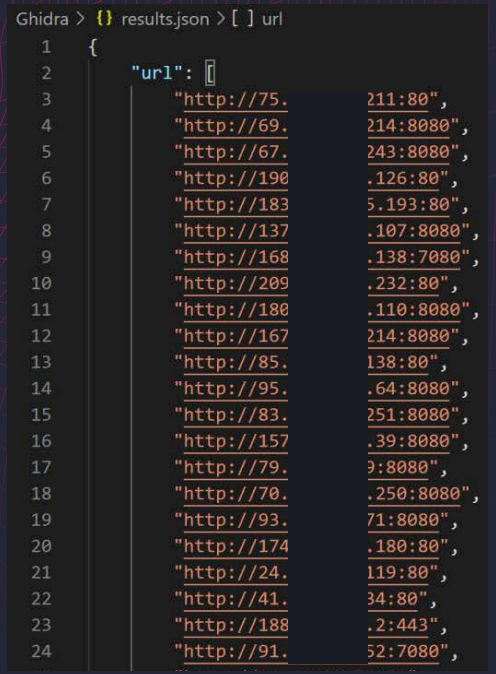

Conclusion

- 解析自体を目的とするのではなく、自動化を目的にするとスケールする
- 解析コードの共有により、知識をサイロ化させない・再利用可能にする
  - 解析結果だけでなく、再利用可能なコードとして共有する（Analysis as a Code）
  - Ghidra Scriptは誰でも再利用可能なので、有効な選択肢の一つ
  - 解析者にもGithubificationが広がると、コミュニティ全体の能力が向上する
    - The Githubification of InfoSec: https://medium.com/@johnlatwc/the-githubification-of-infosec-afbdbfaad1d1

THANKS!

ALLSAFE

if you have any, please let us know, friend.

contact: @PINKSAWTOOTH

CREDITS

- Ghidra Logo by NSA
- Presentation template by Slidesgo
- Icons by Flaticon
- Twemoji by Twitter, Inc and other contributors is licensed under CC-BY 4.0
- Allsafe Logo inspired by Mr.Robot

Appendix

Homework: Decrypt Strings Stage 2

Decrypt Strings Stage2

- 復号関数のアドレスは常に固定とは限らない 🤔
- 復号関数を都度手動で解析して特定していては自動化の意味がない 🤔

複数サンプルを解析し、
復号関数内の共通する特徴的な命令列を見つけ出し、
それをもとに復号関数を自動特定する

Decrypt Strings Stage2: Find Function

演習

decrypt_string_stage2_not_impl.pyのfind_decrypt_string_funcを実装する

1. Version Trackingで複数サンプルの命令列を比較
   - Source -> emotet.dll: `0x1000732d`（Version Tracking Functionsで検索するときは0xをとる）
   - Destination -> emotet-2.dll: `0x10006aba`（Version Tracking Functionsで検索するときは0xをとる）
2. 共通する“特徴的な”命令列を特定
3. 特徴的な命令列を含む関数一覧をスクリプトで取得

decrypt_string_stage2_not_impl.pyのfind_decrypt_string_func

```
32  def find_decrypt_string_func():
33      ''' **** IMPLEMENT HERE ****
34          return list of possible decrypt_string functions
35          Hint:
36              1. use Version Tracking to compare two samples
37              2. use `findBytes` to search instructions/binaries
38              3. use `getFunctionContaining` to get function that contains specific address
39      '''
40      raise NotImplementedError('not implemented')
```

Decrypt Strings Stage2: Find Function

- Version Trackingで複数サンプル内の命令列を比較
- 共通する特徴的な命令列を特定する

たとえばこのあたり

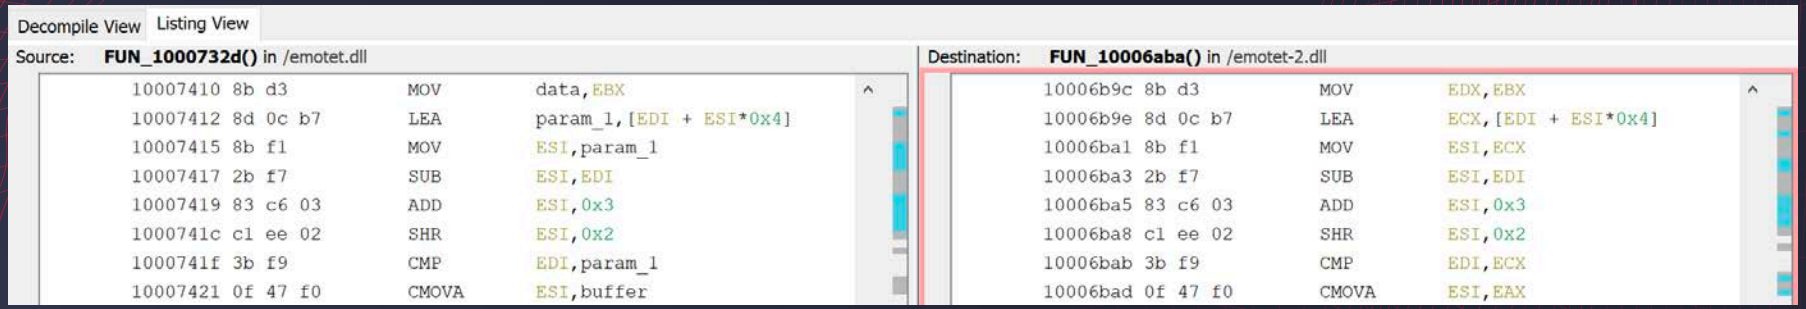

デコンパイル結果

```
puVar1 = (uint *)((int)enc_data + (size & 0xfffffffc));
size = (uint)((int)puVar1 + (3 - (int)enc_data)) >> 2;
```

Decrypt Strings Stage2: Find Function

- 特徴的な命令列を検索し、それらの命令列を含んでいる関数一覧を取得
  - `Address[] findBytes(Address start, java.lang.String byteString, int matchLimit)`
    - 正規表現をつかった検索が可能
  - `Function getFunctionContaining(Address address)`
    - 指定したアドレスを含む関数を取得

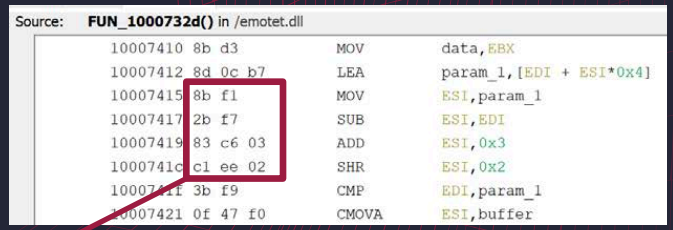

Python - Interpreter

```
>>> asm = b'\\x8b.{1}\\x2b.{1}\\x83.{1}\\x03\\xc1.{1}\\x02'
>>> found = findBytes(None, asm, -1)
>>> found
array(ghidra.program.model.address.Address, [1000704b, 10007415, 1000d219])
>>> suspicious_decrypt_string_func = set([getFunctionContaining(sus_inst) for sus_inst in found])
>>> suspicious_decrypt_string_func
set([FUN_1000732d, FUN_1000d126, FUN_10006f31])
```

レジスタや変数など、コンパイラ等によって
可変なものは「.」(任意の一文字) にして一般化する

Decrypt Strings Stage2: Fully Automated

実装したスクリプトをdecrypt_string_stage2.pyとして保存して実行

```python
def find_decrypt_string_func():
    asm = b'\\x8b.{1}\\x2b.{1}\\x83.{1}\\x03\\xc1.{1}\\x02'
    found = findBytes(None, asm, -1)
    if not found:
        raise RuntimeError('decrypt_string function is not found')
    suspicious_decrypt_string_func = set([getFunctionContaining(sus_inst) for sus_inst in found])
    return list(suspicious_decrypt_string_func)

def main():
    decrypt_string_funcs = find_decrypt_string_func()
    for decrypt_string_func in decrypt_string_funcs:
        print('[*] decrypt_string at {}'.format(decrypt_string_func.getEntryPoint()))
        # get callee address of decrypt_string function
        for xref in getReferencesTo(decrypt_string_func.getEntryPoint()):
            # get instructions before callee address
            insts = get_instructions_before(xref.getFromAddress(), 3)

            # find instruction that passes
            # address of encrypted data via ECX
            for inst in insts:
                if is_mov_edx(inst):
                    # get encrypted data address and decrypt it
                    data_addr = inst.getOpObjects(1)[0].getValue()
                    if data_addr:
                        decrypted_str = decrypt_string(toAddr(data_addr))
                        # add comment
                        print('[*] found at {}: {!r}'.format(inst.getAddress(), decrypted_str))
                        add_bookmark_comment(inst.getAddress(), decrypted_str)
```

複数の復号関数を見つけ、
引数に渡されている文字列を復号している

Console - Scripting

```
decrypt_string_stage2.py> Running...
[*] decrypt_string at 1000732d
[*] found at 1000282a: '%s\\rundll32.exe "%s\\%s",Control_RunDLL'
[*] found at 10004103: '%s\\%s'
[*] found at 10005938: '%s\\%s'
[*] found at 10008d16: '%u.%u.%u.%u'
[*] found at 10008e88: 'DNT: 0\r\nReferer: %s/%s\r\nContent-Type: multipart/form-data; boundary=%s\r\n'
[*] found at 1000ddb9: 'SOFTWARE\\Microsoft\\Windows\\CurrentVersion\\Run'
[*] found at 1001058e: 'POST'
[*] found at 100136d7: '%s\\rundll32.exe "%s\\%s",Control_RunDLL'
[*] found at 10014329: '%s\\%s'
[*] found at 1000f2e6: '%s\\rundll32.exe "%s",Control_RunDLL %s'
[*] found at 1001c33e: '%s\\%s%x'
[*] found at 1001c3c0: '%s\\%s'
[*] found at 100156aa: 'WinSta0\\Default'
[*] found at 10004971: '%s\\%s'
```

How to get unpacked samples by yourself

How to get unpacked samples by yourself

- 必要なもの
  - 仮想環境（VMWare/VirtualBox/Hyper-V等）
  - Windows OS（ゲストOS）
  - ANY.RUNアカウント
  - Process Explorer / Process Monitor (なくても可)
  - Hollow Hunter
    - https://github.com/hasherezade/hollows_hunter/release

- **以後の作業は全て構築した仮想環境内でおこなう**

How to get unpacked samples by yourself

以下ANY.RUNのページを開き、実行されているDLLをダウンロード

- urcwzowo.xck (=packed emotet.dll) MD5:19b0124f2e4f223113bb11a84765a6c3
  - https://app.any.run/tasks/4060b18e-8132-42c0-a0bc-65f398d6bfb2/
- eclh.gfk (=packed emotet-2.dll) MD5:714cdae2b20896e72d92e28dc831b81b
  - https://app.any.run/tasks/b9be3b5e-368d-4248-87c2-e06b3d66769e/

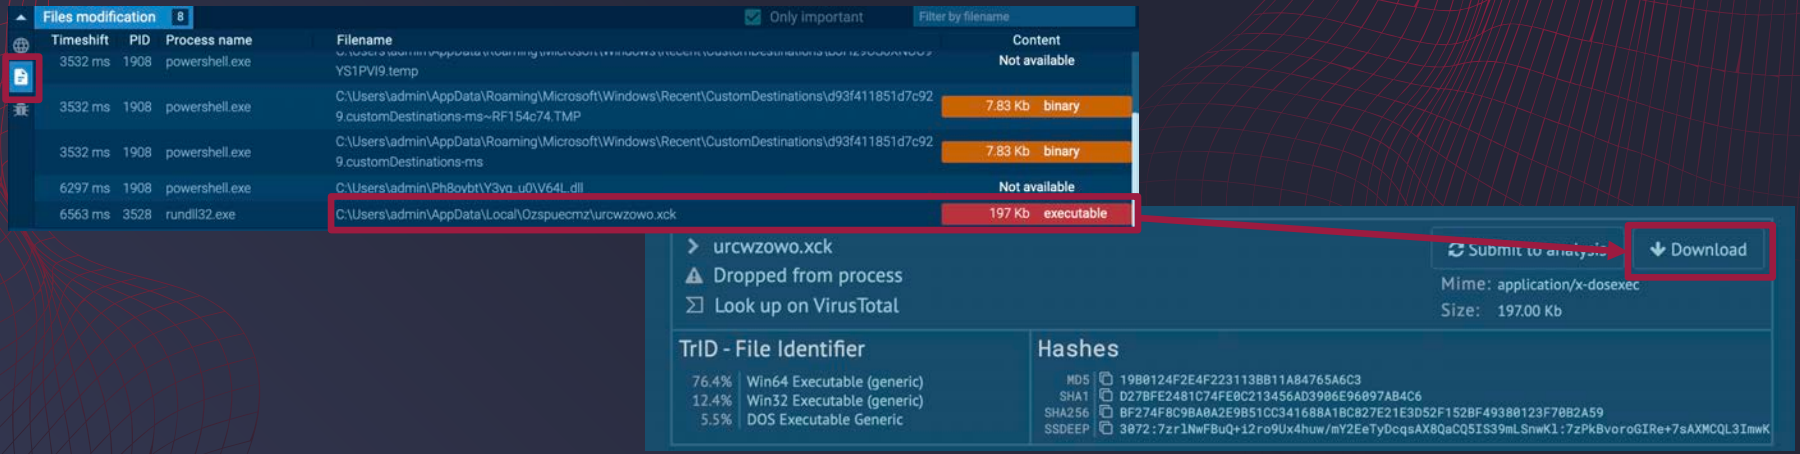

How to get unpacked samples by yourself

仮想環境を外部接続不可な状態にし、EMOTETを適切な引数で実行

```
C:\Users\john>rundll32.exe C:\Users\john\Desktop\urcwzowo.xck,Control_RunDLL
```

このとき、Process ExplorerやProcess Hackerなどで実行されたrundll32.exeのプロセスシーケンスを確認しておく

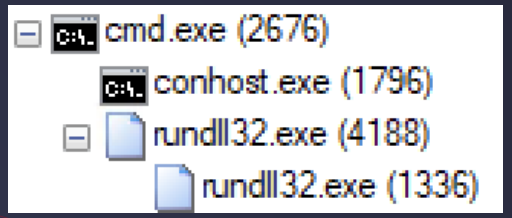

How to get unpacked samples by yourself

実行後5-10秒ほど待機し、子プロセスのPIDをHollows Hunterに渡して実行

- 成功すると実行フォルダ配下にprocess_<PID>フォルダが作成され、中にアンパック後のEMOTETのDLLが保存される

```
C:\Users\john\Desktop>C:\Users\john\Desktop\hollows_hunter.exe /pid 1336
HollowsHunter v.0.2.6 (x64)
Built on: Apr 13 2020

using: PE-sieve v.0.2.6.0
>> Scanning PID: 1336 (rundll32.exe)
[-] Invalid address of relocations
[-] Invalid address of relocations
>> Detected: 1336
--------
SUMMARY:
Scan at: 01/13/21 03:29:17 (1610476157)
Finished scan in: 3516 milliseconds
[+] Total Suspicious: 1
[+] List of suspicious:
[0]: PID: 1336, Name: rundll32.exe
```