

論文紹介 “KASLR in the age of MicroVMs”

2022/05/27

立命館大学 情報理工学部

穂山 空道 (s-akym@fc.ritsumei.ac.jp)

紹介論文

■ 著者

- Benjamin Holmes (Vassar College), Jason Waterman (Vassar College), Dan Williams (Virginia Tech)

■ タイトル

- KASLR in the age of MicroVMs

■ 出展

- Seventeenth European Conference on Computer Systems (EuroSys), 2022

■ 概要


- カーネルのアドレスランダム化を Micro VM でも使えるようにする

前提知識 1 : Address Space Layout Randomization (ASLR)

- プログラムの配置される仮想アドレスをランダムにする
 - コード再利用攻撃（例：ROP）に利用されるコード片の発見を困難にする
 - バイナリを関数ごとなどに分割し、分割された単位ごとにランダム配置
 - gcc では -ffunction-sections オプションで各関数を別々のセクションにしてくれる

```
00001064 <_start>:
1064:  31 ed      xor  %ebp,%ebp
1066:  49 89 d1    mov  %rdx,%r9
...
...

00001140 <main>:
1140:  55         push %rbp
1142:  48 89 e5    mov  %rsp,%rbp
...
...
```



```
00234568 <main>:
234568:  55         push %rbp
234570:  48 89 e5    mov  %rsp,%rbp
...
...

00521FE00 <_start>:
52FE00:  31 ed      xor  %ebp,%ebp
52FE02:  49 89 d1    mov  %rdx,%r9
...
...
```

前提知識 2： Kernel Address Space Layout Randomization (KASLR)

- ASLR を Linux カーネルにも適用
 - 元々は全体のベースをランダム化、2020 年に関数ごとのランダム化が登場
- 具体的な手順
 - カーネルの ELF ファイルをパースして各関数（セクション）を取り出す
 - 各関数の開始位置にランダムなオフセットを足し配置
 - ランダム化した関数位置に基づき動くよう調整
 - 他の関数を呼び出すコード
 - シンボルテーブル（カーネルモジュールを動的ロードするため）
 - 例外テーブル（ユーザメモリ領域にアクセスしうるカーネル内の命令アドレスの一覧）

参考：

<https://github.com/torvalds/linux/blob/master/Documentation/x86/exception-tables.rst>
Chapter 9 “System Call Handler and Service Routines”, Understanding the Linux Kernel

クラウドの利用モデルの変化

■ 従来の利用モデル


- 普通のサーバと同じようなワークロードを実行
 - 例：データ分析を自前の GPU サーバではなくクラウド上で実行
- 実行が数時間、数日、数年にわたり続く

■ 近年のトレンド

- 単一の関数を実行する
 - いわゆる “Server-less computing”、AWS Lambda が有名
- 数秒や数ミリ秒で実行が終わる

→ 起動の所要時間短縮が重要

アップロードされた画像のリサイズだけを
AWS lambda で実行（一瞬で終わる）



Micro VM

- 軽量で必要最低限の機能のみを持つ VMM
 - 単一の関数を実行するような利用モデルを想定
 - コンテナよりも強固な分離 かつ コンテナ並みの軽量さを目指す
 - コンテナの懸念：セキュリティ（syscall が直接呼べる）、互換性（ホストと同一カーネル）
- 例：Amazon Firecracker [1]
 - Amazon lambda の実装で使われる
 - 様々な工夫で軽量さを実現
 - デバイスはネットワーク、ブロックデバイス、シリアルポートのみ（USB はなし！）
 - ゲストの Linux の起動プロセスを簡略化（次で説明）

Firecracker での Micro VM の起動 (1/3)

- 通常の Linux kernel の起動方式
 - 圧縮したカーネルと起動用プログラム (bootstrap loader) がセット

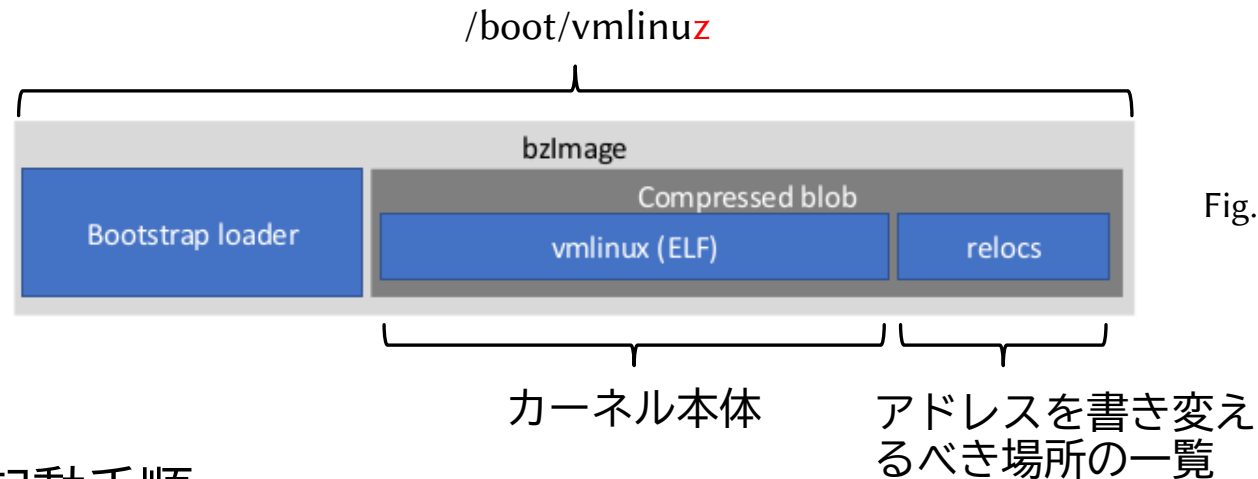


Fig. 2, “KASLR in the age of MicroVMs”

- 起動手順
 - VMM は bootstrap loader に実行を移す
 - Bootstrap loader はカーネルを解凍し適切な場所に配置
 - 配置されたカーネルに実行を移す


Firecracker での Micro VM の起動 (2/3)

- MicroVM の起動方式：Direct Kernel Boot
 - 非圧縮カーネルをそのまま起動し、bootstrap loader を使わない
- 通常方式に比べ起動が高速... なこともある
 - 条件：カーネルイメージがメモリにキャッシュされ disk から読まない
 - 次ページに具体的な実験結果
 - Serverless computing では標準のカーネルをほぼみんな使うので条件が成立
 - 私見：コンテナは互換性が問題と言っていたのにやや矛盾？（みんな同じカーネルを使ったらそのカーネルの上でコンテナを立ち上げれば OK...?）

Firecracker での Micro VM の起動 (3/3)

■ 通常方式と Direct Kernel Boot の起動時間比較

- -bzlimage が通常方式（圧縮あり） -vmlinux が direct kernel boot（圧縮なし）
- lupine、aws、ubuntu はカーネルコンフィグの違い




Takeaways:

- キャッシュなしでは通常方式が高速
 - ディスクからカーネルイメージを読み出すのに時間がかかっている
- キャッシュありでは direct kernel boot が高速
 - Bootstrap loader にかかる時間がなくなっている分速い

Fig. 4, “KASLR in the age of MicroVMs”

Direct kernel boot の課題と対策

- 課題：KASLR が実行されない
 - KASLR は bootstrap loader で実行される
 - 通常方式の起動時の動作の breakdown



Part of Fig. 7, “KASLR in the age of MicroVMs”

- そこで VMM 内で直接 KASLR を実行する

VMM 内での KASRL：脅威モデル

- ポイント：従来型の IaaS 的なモデルとは異なる
 - 従来：攻撃者が好きな VM を起動 → ゲストの特権は攻撃者にあり
 - 今回：攻撃者は Micro VM 上の関数を起動 → ゲストの特権は信頼できる管理者にあり
- 想定
 - Code Injection は不可能
 - ページの書き込みと実行権限の排他設定による
 - ユーザコードの特権モードでの実行は不可能
 - Supervisor Mode Execution Protection による
 - OS の脆弱性を突き Control flow を変えることはできる ← この脅威を KASLR で下げる

提案システムの設計

- ランダム化を VMM 内で行う
 - (この節はあまり大したことは書いていない)
 - 上：通常の KASLR 下：提案する In-monitor KASLR




Fig. 7, “KASLR in the age of MicroVMs”

- 通常の起動方式に比べイメージのコピーが一回減っている
 - 通常：bzImage を VMM がコピーし、bootstrap loader が再度 blob から取り出す

/proc/kallsyms の調整

- カーネル内の全シンボル位置を表示する proc ファイル
 - トレースツールやプロファイラが使う

```
0000000000000000 A fixed_percpu_data
0000000000000000 A __per_cpu_start
0000000000000100 A cpu_debug_store
0000000000000200 A irq_stack_backing_store
0000000000000600 A cpu_tss_rw
0000000000000b00 A gdt_page
0000000000000c00 A exception_stacks
0000000000001000 A entry_stack_storage
0000000000001100 A espfix_waddr
```

手元のマシン（Ubuntu 20.04 LTS, Linux 5.11.0-46-generic）の例

- 表示するアドレスの調整を起動時にせず、はじめて読まれたときまで遅延
 - この調整が起動時間の 22 % を占めた
 - MicroVM では使われないことが多いと思われる
 - “may never been examined” ← 具体的な証拠はなし

実装

- Firecracker v0.26 を改変
 - AWS のプロダクションで利用、起動時間が短い
 - 元の Rust 実装に 1000 行程度のコード追加で実現
 - 基本的に元の bootstrap loader の C コードを参考になっている
- VMM の起動時に relocs 情報を入力
 - カーネルのコンパイル時に生成される




Fig. 8, “KASLR in the age of MicroVMs”

実験の評価軸

- メインの評価軸：起動時間
 - KASLR を実現しかつ高速起動したい
- 具体的な Question
 - In-monitor KASLR により目標の起動時間を達成できるか？ (“achieve its boot targets”)
 - ゲストに割り当てるメモリ量による起動時間への影響は？
 - In-monitor KASLR による起動時間以外のオーバーヘッドは？

実験環境

■ ホストマシン

- Core i7-4790, 8 GB DDR3 1600, SATA SSD, Ubuntu 18.04 (Linux 4.15.0-101-generic)

■ テストするゲストカーネル

kernel	vmlinux size	bzImage size (Compression None, LZ4)	relocs size	config
lupine-nokaslr	20M	22M, 4.1M	N/A	Lupine
lupine-kaslr	20M	22M, 4.2M	95K	Lupine + KASLR
lupine-fgkaslr	22M	24M, 4.7M	304K	Lupine + FGKASLR
aws-nokaslr	39M	41M, 7.9M	N/A	Firecracker
aws-kaslr	39M	41M, 8.3M	348K	Firecracker + KASLR
aws-fgkaslr	42M	45M, 9.8M	1.1M	Firecracker + FGKASLR
ubuntu-nokaslr	45M	47M, 13M	N/A	Ubuntu 18.04.5
ubuntu-kaslr	45M	48M, 14M	1M	Ubuntu + KASLR
ubuntu-fgkaslr	50M	54M, 17M	2.3M	Ubuntu + FGKASLR

-kaslr: 全体のベースのみランダム化
-fgkaslr: 関数ごとにランダム化
(関数ごとに再配置するので relocs が大きい)

■ 起動時間測定方法

- 時刻を取るポイントに目印となる syscall 呼び出しを入れ、perf でトレース

実験結果 (1/3)

■ Q: In-monitor KASLR により目標とする起動時間を達成できるか？




Fig. 9 (b), “KASLR in the age of MicroVMs”

Takeaways:

- 全ケースで提案手法が最も速い起動時間を実現
- AWS 以外のカーネルも同様の傾向（論文に図あり）

Firecracker との比較

- KASLR では AWS で 3.7% 増、FGKASLR では AWS で 2.15 倍（論文にも図なし）

各バーのラベル（本論文はラベルが非常に分かりにくい...）

- **Direct Boot:** 提案手法
- **LZ4:** 通常の圧縮カーネルと bootstrap loader の組み合わせ
- **Compression None:** vmlinuz の中身を非圧縮カーネルイメージに変えたもの（つまり bootstrap loader ありでかつ解凍の手間をなくせる）

各グループのラベル

- **KASLR:** 全体のベースのみランダム化
- **FG_KASLR:** 関数ごとにランダム化

実験結果 (2/3)

■ ゲストに割り当てるメモリ量による起動時間への影響は？




Fig. 10, “KASLR in the age of MicroVMs”

Observation:

- ゲストのメモリ量を変えると Linux boot (Linux に飛んでから init が起動するまで) は伸びる
- 一方 In-monitor でかかる時間は一定
- Linux boot の部分は ASLR あり・なしで変化なし

結論：提案手法を使用した場合の起動時間は、ゲストのメモリ量の影響を受けない

実験結果 (3/3)

- In-monitor KASLR による起動時間以外のオーバーヘッドは？
 - KASLR あり・なしで LEBench の性能を比較 (baseline: aws-noaslr + Firecracker)




Fig. 11, “KASLR in the age of MicroVMs”

- 関数単位でランダム化すると平均約 7% の性能低下
 - L1 キャッシュミスが少し増える ← 書いていないけど I-cache の意味か
 - Hot area を単一セクションにする議論が LKML であり ← セキュリティレベル低下？

まとめ

- VMM 内で動作する KASLR を実現した
 - MicroVM 時代にはゲスト起動の高速化が重要
 - そのため KASLR を行う bootstrap loader が使われない
 - KASLR ができかつ bootstrap loader を使う場合より高速な起動を実現
- 私見：手法的にはやっただけに見えるが目の付け所が重要？
 - MicroVM で KASLR が省略されているという重要な指摘をした