



clsync progress: security and porting to freebsd



overview

porting to
FreeBSD

security
features



clsync v0.2
(LVEE 2014 winter)




LVEE 2014


Linux Vacation / Eastern Europe

porting to
FreeBSD

**security
features**



clsync v0.2
(LVEE 2014 winter)




LVEE 2014

Linux Vacation / Eastern Europe

security: aim


Цель:

Минимизация последствий обнаружения и эксплуатации уязвимостей злоумышленником.



security: task



- `clsync` наблюдает за файловым деревом с произвольными правами на объекты внутри.
- Злоумышленник имеет полный доступ к данному файловому дереву.
- `clsync` не наблюдает за файлами, которые представляют интерес для злоумышленника
- `clsync` запускает внешний процесс для осуществления синхронизации




LVEE 2014

Linux Vacation / Eastern Europe


security: clsync v0.3




- **Злоумышленник заперт внутри контейнера**
- **clsync запускается с host-системы.**



security: clsync v0.3





security: clsync v0.4



LVEE 2014

Linux Vacation / Eastern Europe



security: no guarantee



LVEE 2014

Linux Vacation / Eastern Europe

security: surface




LVEE 2014

Linux Vacation / Eastern Europe

security: overview

- Сброс привилегий
- Изоляция в собственные namespace-ы
- Thread splitting
- seccomp
- cgroups
- fork()




LVEE 2014

Linux Vacation / Eastern Europe

security: what is the first?

→ Сброс привилегий

- Изоляция в собственные namespace-ы
- Thread splitting
- seccomp
- cgroups
- fork()



LVEE 2014


Linux Vacation / Eastern Europe

security: drop privileges

Тривиальная процедура с `setuid()/setgid()`.

Проблемы:

- **clsync** должен иметь возможность наблюдать за файловым деревом, что требует либо привилегий `root`, либо `capability` “`CAP_DAC_READ_SEARCH`”.
- В определённых конфигурациях, **clsync** запускает внешнее приложение (например “`rsync`”) для осуществления синхронизации. У данного приложения должны быть достаточные права на чтение всего файлового дерева.



LVEE 2014

Linux Vacation / Eastern Europe

security: CAP_DAC_READ_SEARCH

Решение проблемы №1 (наблюдение):

- Сохранение сарability
“CAP_DAC_READ_SEARCH” для наблюдения.

Новая проблема:

- Данный сарability даёт возможность непрямого доступа на чтение ко всем файлам раздела (через bruteforce handle-ов).



LVEE 2014

Linux Vacation / Eastern Europe

Решение новой проблемы:

- Разделять процесс на два thread-а [thread splitting].

Замечание: `setuid()/setgid()` действует на все thread-ы, а `capabilities` индивидуальны.



LVEE 2014

Linux Vacation / Eastern Europe


security: CAP_SETUID | CAP_SETGID

Решение проблемы №2 (“запуск rsync”):

- Аналогичное решение не работает из-за необходимости активации capability в дочернем процессе. Поэтому предлагается сохранение capabilities “CAP_SETUID” и “CAP_SETGID” и использование `setuid()/setgid()` перед запуском.

Новая проблема:

- Появляется возможность получить привилегии root-а, что полностью ликвидирует защиту



LVEE 2014

Linux Vacation / Eastern Europe

Решения новой проблемы:

- Разделять процесс на два thread-а [thread splitting] с разными привилегиями (используя capabilities).
- Разделять процесс на два полноценных процесса [через fork()]. Более безопасный вариант.

Замечание: атака с thread-а на thread на порядок проще, чем на “fork()-нутый” процесс



LVEE 2014

Linux Vacation / Eastern Europe

security: what is next?

- Сброс привилегий
- **Изоляция в собственные namespaces-ы**
- Thread splitting
- seccomp
- cgroups
- fork()




LVEE 2014

Linux Vacation / Eastern Europe

security: unshare()-ing

unshare() flags (Linux 3.13):

- CLONE_FILES – **File descriptors**
- CLONE_FS – **FS attributes**
- CLONE_NEWIPC – **SysV IPC**
- CLONE_NEWNET – **Network**
- CLONE_NEWNS – **Mounts**
- CLONE_NEWUTS – **UTS**
- CLONE_SYSVSEM – **SysV semaphores**




LVEE 2014

Linux Vacation / Eastern Europe

security: unshare()-ing mountpoints

Наиболее автоматический вариант:

- `chdir(newroot);`
- `mkdir("old_root");`
- **`unshare(CLONE_NEWNS);`**
- `mkdir(newroot_bind, 0700);`
- `mount(newroot, newroot_bind, ..., MS_BIND | ... , NULL);`
- `chdir(newroot_bind);`
- **`pivot_root(".", "old_root");`**
- `chroot(".");`
- **`umount2("old_root", MNT_DETACH);`**



LVEE 2014

Linux Vacation / Eastern Europe

security: problem of unshare()-ing mountpoints

- Включенный capability “CAP_DAC_READ_SEARCH” создаёт уязвимость, за счёт разрешения bruteforce-a handle-ов ФС.
- Но “CAP_DAC_READ_SEARCH” необходим для возможности наблюдения за файловым деревом при сброшенных привилегиях.
- Решение данной проблемы – это thread splitting




LVEE 2014

Linux Vacation / Eastern Europe

security: what is next?

- Сброс привилегий
- Изоляция в собственные namespace-ы
- **Thread splitting**
- seccomp
- cgroups
- fork()





LVEE 2014

Linux Vacation / Eastern Europe

security: what is thread splitting?

Под термином “thread splitting” понимается создание дополнительного thread для обработки syscall-ов, требующих особых привилегий.




LVEE 2014

Linux Vacation / Eastern Europe

security: privileged syscalls list

Список функций, требующий повышенных привилегий:

- `fts_open()`
- `fts_read()`
- `fts_close()`
- `inotify_add_watch()`
- `setuid()/setgid()`




LVEE 2014

Linux Vacation / Eastern Europe

security: problems of the thread splitting

Проблемы данного подхода:


- Требуется использовать блокировки для каждого привилегированного `syscall`, что снижает производительность в несколько раз.
- Требуется защитить привилегированный `thread` от непривилегированного. Для этого используется `seccomp`, о чём будет рассказано позже.



LVEE 2014

Linux Vacation / Eastern Europe



security: the performance problem of the thread splitting



- Проблема вызвана использованием `pthread_mutex_*`(), которые рассчитаны на более медленную блокировку-разблокировку.
- Для быстрых блокировок-разблокировок бывает **spinlock**, однако он не подходит для блокировок и разблокировок с большими интервалами (что является штатной ситуацией для `csync`).
- Было предложено сделать комбинированный механизм блокировок **timed spinlock with fallback on mutex.**



Зависимость времени выполнения initial sync от timeout-a spinlock-a



LVEE 2014

Linux Vacation / Eastern Europe

- После `initial sync` системные вызовы бывают достаточно редко, поэтому использование `spinlock`-а с высоким `timeout` приводит к бесполезным дополнительным затратам ресурсов CPU.
- Оптимальное значение `timeout` зависит от конкретного ядра, окружения и аппаратного обеспечения.
- Было предложено использовать 8192 итерации как нулевое приближение, а далее делать автоматическую калибровку.




LVEE 2014

Linux Vacation / Eastern Europe

Зависимость времени выполнения initial sync от режима cfsync

- simple
- thread splitting (high load locks + auto adjust)
- thread splitting (high load locks)
- thread splitting (mutex)



LVEE 2014

Linux Vacation / Eastern Europe

security: problem of the new locks



- Использование spinlock на одноядерных системах приводит к ещё бóльшей потере производительности.
- Калибровка может работать неточно в системах с существенно неравномерной нагрузкой.



LVEE 2014

Linux Vacation / Eastern Europe

Зависимость времени выполнения Initial sync от spinlock timeout на одноядерной системе




LVEE 2014

Linux Vacation / Eastern Europe

security: what is next?

- Сброс привилегий
- Изоляция в собственные namespace-ы
- Thread splitting
- **seccomp**
- cgroups
- fork()




LVEE 2014

Linux Vacation / Eastern Europe

security: seccomp

- Предлагается использовать seccomp filter для задания whitelist syscall-ов для непривилегированного thread.
- Это запретит использование mprotect, что даёт возможность обеспечить защиту от записи кода и данных привилегированного thread.




LVEE 2014

Linux Vacation / Eastern Europe

Список разрешённых syscall-ов:

- futex
- inotify_init1
- alarm
- stat
- fstat
- lstat
- open
- write
- close
- wait4
- unlink
- nanosleep
- tgkill
- clock_gettime
- rt_sigreturn
- brk
- mmap
- munmap
- wait4
- rmdir
- exit_group
- select
- read
- rt_sigprocmask
- rt_sigaction



LVEE 2014

Linux Vacation / Eastern Europe

security: problems of seccomp in clsync

Проблемы:

- Запрещено применение многопоточности синхронизаций [из-за запрета mprotect() не работает pthread_create()]




LVEE 2014

Linux Vacation / Eastern Europe

security: what is next?

- Сброс привилегий
- Изоляция в собственные namespace-ы
- Thread splitting
- seccomp
- **cgroups**
- fork()



LVEE 2014

Linux Vacation / Eastern Europe

security: cgroups


На данный момент cgroups в cfsync используется только для ограничения доступа к “устройствам” (в /dev).

На запись:

- /dev/console
- /dev/null

На чтение:

- /dev/console
- /dev/zero
- /dev/random
- /dev/urandom




LVEE 2014

Linux Vacation / Eastern Europe

security: what is next?

- Сброс привилегий
 - Изоляция в собственные namespace-ы
 - Thread splitting
 - seccomp
 - cgroups
- **fork()**




LVEE 2014

Linux Vacation / Eastern Europe


security: fork()

- `fork()` используется для запуска внешнего helper-а, выполняющего операции `setuid()/setgid()` и `exec*()`. Что позволяет сбросить capabilities `CAP_SETUID` и `CAP_SETGID` в атакуемом процессе.



porting to
FreeBSD

security
features



clsync v0.2

(LVEE 2014 winter)




LVEE 2014

Linux Vacation / Eastern Europe

porting to freebsd: problems

Задача по портированию включает в себя решение следующих проблем:

- Отсутствие поддержки inotify в ядре.
- Различные мелочи, вызванные использованием другого окружения: компилятор, shell, BSD make и т.п.
- Подготовка и публикация freebsd port.




LVEE 2014

Linux Vacation / Eastern Europe

porting to freebsd: inotify

В качестве альтернативы inotify во FreeBSD для наблюдения за ФС предлагается 3 backend-а:

- kqueue()/kevent()
- BSM API
- dtrace



LVEE 2014


Linux Vacation / Eastern Europe

porting to freebsd: kqueue()/kevent()

Проблемы kqueue()/kevent():

- Требование open() на каждый наблюдаемый объект.
- Недостаточность получаемой информации, необходимость пересканирования директорий и детального слежения за inode-ами.
- Большое количество сложноучитываемых проблем.

Но есть libinotify-kqueue...




LVEE 2014

Linux Vacation / Eastern Europe

porting to freebsd: BSM API

Проблемы BSD API:

- Необходимость глобальной переконфигурации auditd.
- Использование системы не по своему назначению.




LVEE 2014

Linux Vacation / Eastern Europe

porting to freebsd: dtrace


Проблема dtrace:

- dtrace во FreeBSD реализован в “урезанном” варианте (без поддержки некоторых built-in переменных), в результате становится невозможным получать полные пути объектов, соответствующих событиям.



conclusions

- Комбинирование различных Linux API позволяет создать многослойные препятствия для злоумышленника.
- Для FreeBSD не найдено удовлетворительного интерфейса для наблюдения за событиями ФС. Однако рекомендуется использовать `libinotify-kqueue`.



LVEE 2014

Linux Vacation / Eastern Europe

clsync progress: security and porting to freebsd

Q&A

