

Odin

Живая миграция контейнеров:
плюсы, минусы, подводные камни

Павел Емельянов

Калуга, 2015

Про что доклад

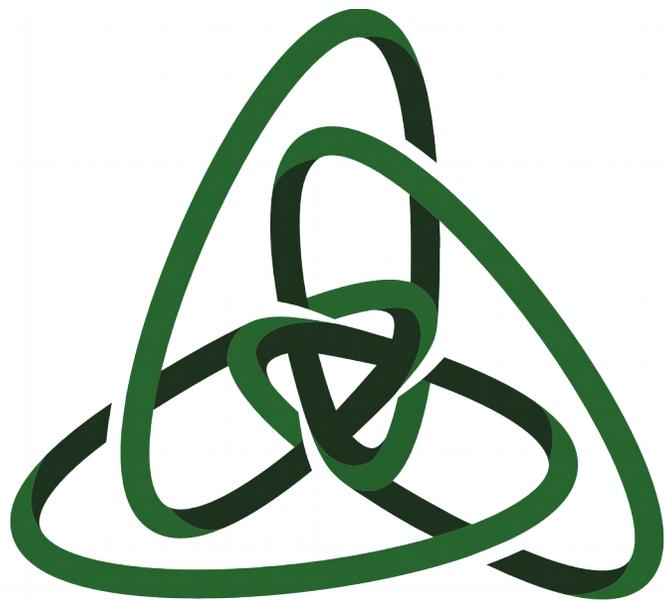
- Почему надо мигрировать контейнеры
- Почему не надо мигрировать контейнеры
- Насколько сложно мигрировать контейнеры

Миграция в общих чретах

- Сохранить состояние
- Скопировать состояние
- Восстановить состояние



Миграция контейнеров



OpenVZ
Virtuozzo Containers

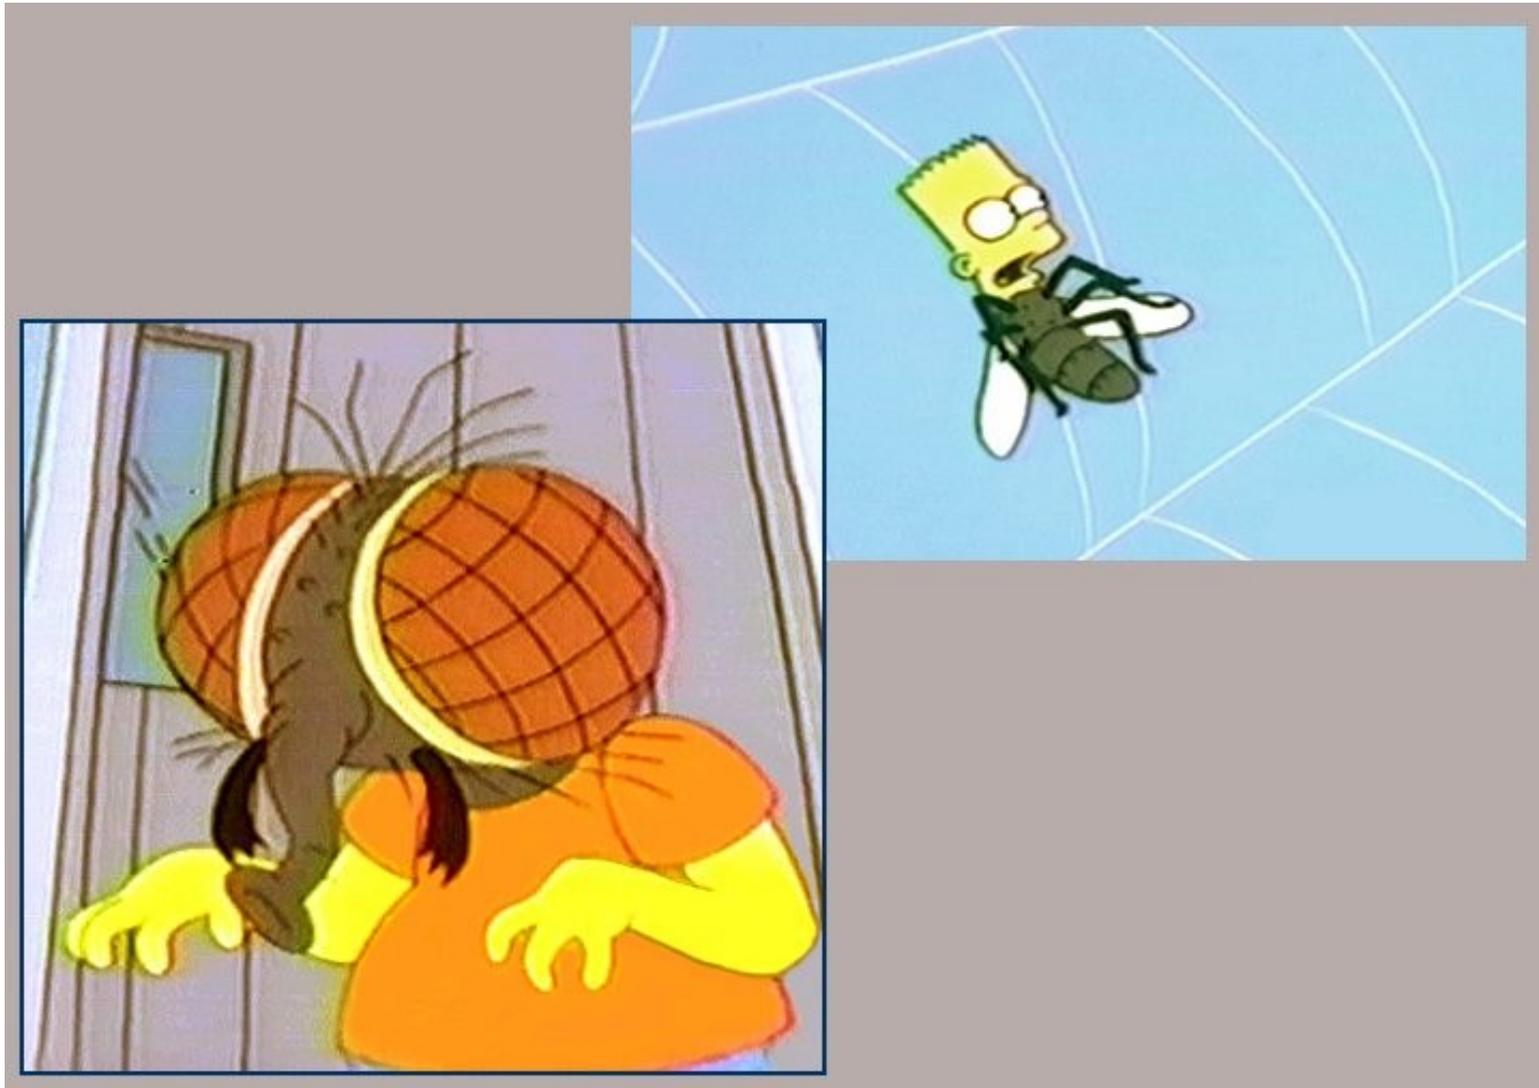


P.Haul

Почему надо мигрировать контейнеры

- Эффектно
- Балансировка нагрузки
- Обновление ядра
 - Можно не мигрировать на самом деле
- Замена оборудования

Почему не надо мигрировать контейнеры



Как не мигрировать контейнеры

- Балансировка сетевого трафика
- Микросервисы
- Crash-driven обновления
- Плановые отключения горячей воды

На самом деле живая миграция

- Пересылку память необходимо исключить из состояния “заморожено”
- Пред-копирование памяти
- Пост-копирование памяти

Живая миграция в деталях

- Пред-копирование: сбор и пересылка памяти (несколько раз)
- Заморозка
- Сохранение состояния
- Копирование состояния
- Восстановление состояния
- Разморозка
- Пост-копирование: подкачка памяти по сети

Подводные камни

VS

Подводные камни

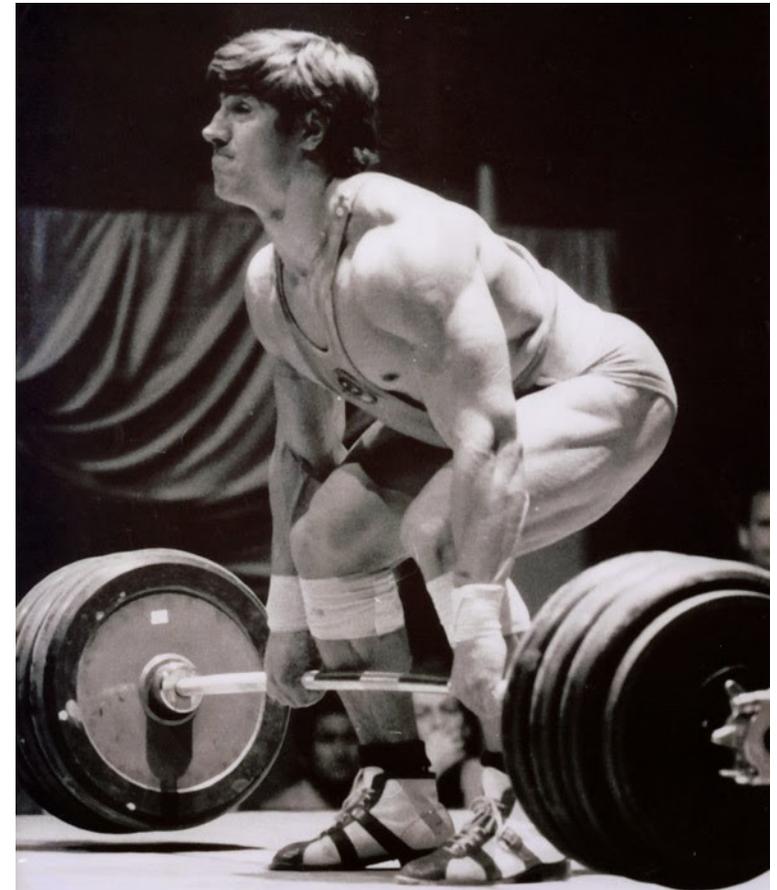


VS

Подводные камни



VS



Что мигрируем

- VM-ка
 - Окружение (виртуальное железо, paravirt)
 - CPU
 - Память
- Контейнер
 - Окружение (cgroups, namespaces)
 - Процессы и другие животные
 - Память

Сбор и пересылка памяти

- VM-ка
 - Вся память “в руках”
- Контейнер
 - Память размазана по процессам, может быть разделена между ними
 - Поэтому надо сначала собрать процессы (см. ниже)
 - А потом собрать память

Заморозка

- VM-ка
 - `Suspend` всех процессоров
- Контейнер
 - Пройти по дереву (`/proc`), переловить процессы и остановить их
 - `Freeze cgroup` помогает, но надо отдельно восстанавливать иерархию

Сохранение состояния

- VM-ка
 - Состояние железа
 - Дерево, 300К, ~70 объектов
- Контейнер
 - Состояние всех объектов
 - Граф, 160К, ~1000 объектов
 - Не для всех объектов есть адекватный API для чтения

Копирование состояния

- VM-ка
 - Можно читать состояние и сразу передавать
- Контейнер
 - Сложно читать и сразу передавать

Восстановление состояния

- VM-ка
 - Воссоздание памяти, запись состояния в устройства и CPU
- Контейнер
 - В ядре: создание большого количества маленьких объектов
 - В CRIU: то же самое, но с использованием не всегда удобного API
 - Требуется вычисление нетривиальной последовательности действий

Разморозка

- VM-ка
 - Resume
- Контейнер
 - Синхронизация восстановления всех процессов, чтобы не разморозить кого не следует раньше времени
 - SIGCONT по дереву
 - “Оттаять” cgroup

Подкачка памяти по сети

- UserfaultFD от Андреа Арканджели
- VM-ка
 - Merged into 4.2
- Контейнер
 - Несовместная работа монитора и процесса – надо доделывать `uffd`

Реализация

- <http://criu.org>
- criu@openvz.org
- +CriuOrg
- @__criu__
- Github: [xemul/criu](https://github.com/xemul/criu)



Реализация

- P.Haul (Пихль)
 - <http://criu.org/P.Haul>
 - Миграция с помощью CRIU



P.Haul

Odin

Бсё.

xemul@openvz.org