




Онлайн-образование



Меня хорошо видно && слышно?

Ставьте , если все хорошо
Напишите в чат, если есть проблемы

НЕ ЗАБЫТЬ ВКЛЮЧИТЬ
ЗАПИСЬ!!!

Дисковая подсистема Linux

О себе

Test Automation Engineer

- более 10 лет опыта работы в среде Linux
- тестировал Cluster File Systems



Преподаватель

- в OTUS
- и другие (курс “Основы администрирования Linux”)

Викентий Лапа

Правила вебинара

- Активно участвуем: выполняем задания, отвечаем на вопросы
- Если возникли сложности задаем вопрос в чат
- На вопросы постараюсь отвечать сразу, но возможны паузы

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - Утилиты для администрирования дисков
 - Планировщики ввода/вывода (I/O Schedulers)
 - Создаем разделы
- Массив дисков
 - Типы RAID
- Примеры обслуживания.
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

После занятия вы сможете

1. Добавить новый диск в систему и найти его (в том числе NVMe)
2. Разбить диск на разделы вручную или скриптом
3. Поменять конфигурацию блочного устройства
4. Выбрать тип RAID и создать программный RAID

Зачем вам это уметь

ВАШ ВАРИАНТ?

Зачем вам это уметь


МОЙ ВАРИАНТ

1. Сможете быстрее разобраться в конфигурации на сервере от другого админа
2. Повысите отказоустойчивость дисковой подсистемы
3. Меньше волнения при замене вылетевшего диска

Маршрут вебинара.

- **Драйвера устройств**
- **Блочные устройства**
 - Утилиты для администрирования дисков
 - Планировщики ввода/вывода (I/O Schedulers)
 - Создаем разделы
- **Массив дисков**
 - Типы RAID
- **Примеры обслуживания.**
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Дисковая подсистема



Файлы блочных устройств

```
# lsblk
NAME                MAJ:MIN RM   SIZE RO TYPE MOUNTPOINT
/dev/loop1           7:1      0  100M  0 loop
sda                  8:0      0    8G  0 disk
├─sda1               8:1      0    1G  0 part /boot
└─sda2               8:2      0    7G  0 part
   ├─cl-root         253:0     0   6.2G  0 lvm  /
   └─cl-swap         253:1     0   820M  0 lvm  [SWAP]
sdb                  8:16     0   250M  0 disk
sr0                 11:0     1   597M  0 rom
/dev/pmem2          259:0     0   676M  0 disk
nvme0n1             259:0     0 317.6M  0 disk
└─nvme0n1p1         259:1     0 316.6M  0 part
nvme0n2             259:2     0 113.9M  0 disk
```

Файлы устройств

Два типа:

- блочные (block special files)
- символьные (character special files).

```
# ls -l /dev/sda1
brw-rw----. 1 root disk 8, 1 Jan 28 20:03 /dev/sda1
# cat /proc/devices
Block devices:
8 sd
9 md
```

b - класс устройства, **8** - старший номер устройства **1** - младший номер устройства.

Файлы блочных устройств

```
ls /sys/block/  
dm-0  dm-1  nvme0n1  nvme0n2  sda  sdb  sr0
```

```
find /dev/disk/  
/dev/disk/by-label/CentOS-8-1-1911-x86_64-dvd  
/dev/disk/by-uuid/292c16ad-881f-40b0-8d18-12930be29bca  
/dev/disk/by-partuuid/8c24099b-02  
/dev/disk/by-path/pci-0000:00:1f.2-ata-1-part2  
/dev/disk/by-path/pci-0000:00:1f.2-ata-2  
/dev/disk/by-path/pci-0000:00:0e.0-nvme-1-part1  
/dev/disk/by-id/ata-VBOX_CD-ROM_VB2-01700376  
/dev/disk/by-id/nvme-eui.c5e83ad72b43394bb88a41462df57f1e-part1
```

Как создаются эти имена файлов?

Найдем контроллеры дисков

Команда `lspci`

```
0000:00:1f.2  
00:1f.2
```

B/D/F (bus/device/function)

(шина / устройство / функции).

```
# Опции команды  
lspci -v -vv -vvv # больше деталей  
lspci -tv # дерево соответствует физической структуре  
lspci -D # показывает домен  
lspci -nnA # показывает ID производителя  
lspci -v -s 00:1f.2 # показать только одно устройство
```

Пример правил системы udev

```
cat /usr/lib/udev/rules.d/60-persistent-storage.rules
```

файлы с описанием правил правил `man 7 udev`

- system rules directory `/usr/lib/udev/rules.d`
- volatile runtime directory `/run/udev/rules.d`
- local administration directory `/etc/udev/rules.d`

Пример добавления правил

Создадим еще одно имя для диска sda

```
udevadm info -n /dev/sda  
udevadm info -n /dev/sda | grep ID_SERIAL_SHORT
```

Создаем файл с правилом

```
# cat /etc/udev/rules.d/69-disk.rules  
ACTION=="add", KERNEL=="sd[a-z]", \  
ENV{ID_SERIAL_SHORT}=="VBca5e42b9-32e027c5", SYMLINK+="my_virtual
```

Тестируем правило, применяем правило

```
udevadm test $(udevadm info \  
--query=path --name=/dev/sda)  
sudo udevadm trigger --action=add
```

Система udev

- правила именования устройств
- постоянно закрепленные за устройствами имена, которые не зависят от того, какое положение они занимают в дереве устройств
- уведомление внешних по отношению к ядру программ, если устройство было заменено

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - **Утилиты для администрирования дисков**
 - Планировщики ввода/вывода (I/O Schedulers)
 - Создаем разделы
- Массив дисков
 - Типы RAID
- Примеры обслуживания.
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Настройка блочных устройств

- Утилиты
 - hdparm
 - sdparm (SCSI)
 - smartctl
- Файловая система sys

Утилита `hdparm`

`hdparm` - позволяет получить/установить параметры устройств SATA/IDE и тестировать производительность

- кэши дисков (drive caches)
- режим сна (sleep mode)
- управлять питанием (power management)
- уровнем шума (acoustic management)
- настройки DMA (Direct Memory Access)

Примеры использования Утилита hdparm

```
# Тест производительности
hdparm -Tt --direct /dev/nvme1n1
# Отключаем энергосбережение
/usr/bin/hdparm -B 254 -S 0 /dev/sda
```

Применяем после перезагрузки

```
ACTION=="add", SUBSYSTEM=="block", KERNEL=="sda",
RUN+="/usr/bin/hdparm -B 254 -S 0 /dev/sda"
```

Утилита smartctl

упрвление и мониторинг дисков использующих технологию SMART (Self-Monitoring, Analysis and Reporting Technology System)

- поддерживает ATA/SATA, SCSI/SAS and NVMe
- работает в системах Linux, FreeBSD, NetBSD, OpenBSD, Darwin (macOS), Solaris, Windows, Cygwin, OS/2, eComStation or QNX

Пример использования smartctl

Две стратегии поведения диска при обнаружении ошибки:

- **standalone/desktop** — пытаться прочитать до последнего
- **RAID** — не ждать пометить диск как сбойный
Разные производители называют по разному
 - SCT ERC (SMART Command Transport Error Recovery Control)
 - TLER (Time-Limited Error Recovery)
 - CCTL (Command Completion Time Limit)

Error Recovery Control (ERC) - количество времени которое контроллеру диска разрешено потратить на восстановление от ошибки чтения или записи.

Пример использования утилиты smartctl

Узнать значение ERC

```
smartctl -l scterc /dev/sda
SCT Error Recovery Control:
  Read: Disabled
  Write: Disabled
```

Установить значение ERC

```
smartctl -l scterc,150,150 /dev/sda
SCT Error Recovery Control:
  Read: 150 (15.0 seconds)
  Write: 150 (15.0 seconds)
```

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - Утилиты для администрирования дисков
 - **Планировщики ввода/вывода (I/O Schedulers)**
 - Создаем разделы
- Массив дисков
 - Типы RAID
- Примеры обслуживания.
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Планировщик системы ввода/ вывода

I/O Scheduling — очередью операций ввода-вывода к жесткому диску

Увеличение производительности дисков

Как это работает:

- слияние запросов
- установка приоритета выполнения

Планировщики системы ввода/вывода

Non-multiqueue I/O schedulers

noop

deadline

cfq

Multiqueue

mq-deadline

kyber

bfq

Узнаем какие поддерживаются

```
# cat /sys/block/sda/queue/scheduler  
[mq-deadline] kyber bfq none
```

Пример смены планировщика

```
# echo none >/sys/block/sda/queue/scheduler  
# cat /sys/block/sda/queue/scheduler  
[none] mq-deadline kyber bfq
```

Рекомендации по выбору. Их нет. Тестируйте.

- NVMe
 - любой из Multiqueue
 - none для уменьшения нагрузки на процессор.
- HDD
 - сервер - mq-deadline
 - desktop - bfq

Навязчивое повторение

КАКИМИ КОМАНДАМИ МОЖНО?

- найти сколько дисков в системе
- определить тип дисков
- поменять настройки

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - Утилиты для администрирования дисков
 - Планировщики ввода/вывода (I/O Schedulers)
 - **Создаем разделы**
- Массив дисков
 - Типы RAID
- Примеры обслуживания.
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Разбиваем диск на разделы

Зачем ?


Какие схемы разметки?

Директория	Раздел
/	/dev/sda1
/boot	/dev/sda2
/home	/dev/sda3

Разделы MBR

- Преимущества MBR
 - совместима с большинством систем.
- Недостатки MBR
 - четыре раздела, дополнительные подразделы на основном
 - размер раздела два терабайта
 - информация о разделе хранится только в одном месте

Разделы GPT



Разделы GPT

- Преимущества GPT
 - неограниченное количество разделов.
 - контрольные суммы CRC32 позволяют обнаружить ошибки и повреждения заголовка и таблицы разделов.
 - сохраняет заголовок резервной копии и таблицу разделов в конце диска.
- Недостатки GPT
 - Может быть несовместима со старыми системами.

Утилиты для создания разделов

Интерактивные	Для скриптов
fdisk	sfdisk
gdisk	sgdisk
parted	parted

Пример интерактивного создания разделов

- `gdisk /dev/nvme0n2`

Number	Start (sector)	End (sector)	Size	Code	Name
1	2048	104447	50.0 MiB	8300	Linux fi

Command (? for help): ?

b back up GPT data to a file

c change a partition's name

d delete a partition

i show detailed information on a partition

l list known partition types

n add a new partition

Пример создания разделов скриптом

```
for i in {1..40} do
    sgdisk -n ${i}:0:+10M /dev/nvme0n1
done
lsblk
```

Опции могут совпадать с интерактивной версией

```
sgdisk --help
sgdisk -o /dev/nvme0n2 # очистка разделов
```

Пример создания разделов parted

Интерактивно

```
parted /dev/nvme0n3
```

Скрипт

```
parted --script /dev/nvme0n3 mklabel gpt\  
mkpart primary 2048s 10MiB\  
mkpart primary 10MiB 20MiB
```

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - Утилиты для администрирования дисков
 - Планировщики ввода/вывода (I/O Schedulers)
 - Создаем разделы
- **Массив дисков**
 - Типы RAID
- Примеры обслуживания.
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Типы RAID

- аппаратный
 - internal
 - external
- программный

Аппаратный RAID

Преимущества

- + Аппаратное решение, не влияющее на производительность основной системы
- + Выделенный CPU
- + Выделенная память для Кэшей
- + Возможность использовать BBU (Battery Backup Unit)
- + Возможность подключения большого количества дисков
- + Прозрачность для загрузчиков (возможность грузиться с любого массива)

Недостатки

- Высокая стоимость
- Высокая сложность
- Разнообразие интерфейсов управления и драйверов
- Низкая «мобильность» /переносимость
- Привязка к железу
- Бóльший простой по времени при аварии
- Очень дорогой ремонт, необходимость закупать впрок контроллеры, которые потом могут прекратить выпускать

Программный RAID


Преимущества

- + Бесплатно
- + Отсутствие привязки к конкретному железу
- + Прозрачность конфигурации
- + Примерно одинаковый интерфейс управления в любом linux.
- + Легкая переносимость между компьютерами.
- + Гибкость конфигурации

Недостатки

- Отсутствие BBU
- Отсутствие выделенного кэша
- Отсутствие службы поддержки :-)

RAID0



RAID0


Преимущества

- + Самое быстрое чтение
- + Очень простой
- + Максимальная эффективность использования дискового пространства

Недостатки

- Не «настоящий» RAID, нет отказоустойчивости: отказ одного диска влечет за собой потерю всех данных массива

RAID1



RAID1


Преимущества

- + Простота реализации
- + Простота восстановления:
перекопировать все данные с
«выжившего» диска
- + Высокая скорость на чтение

Недостатки

- Высокая стоимость на единицу
объема: 100% избыточность

RAID5



RAID5


Преимущества

- + Высокая скорость записи данных
- + Достаточно высокая скорость чтения данных
- + Высокая производительность при большой интенсивности запросов чтения/записи данных
- + Малые накладные расходы для реализации избыточности

Недостатки

- Низкая скорость чтения/записи данных малого объема при единичных запросах
- Достаточно сложная реализация
- Сложное восстановление данных

RAID6



RAID6

Преимущества

- + Высокая отказоустойчивость
- + Достаточно высокая скорость обработки запросов
- + Относительно малые накладные расходы для реализации избыточности



Недостатки

- Очень сложная реализация
- Сложное восстановление данных
- Очень низкая скорость записи данных

RAID10

RAID-0 (RAID-1 = RAID-10)
RAID-0

Data Chunks



$$V_t = V_1 * N/2$$

RAID10

Преимущества

- + Самая высокая отказоустойчивость
- + Самая высокая производительность
- + Сочетает в себе преимущества R0 и R1

Недостатки

- Двойная стоимость пространства

Маршрут вебинара

- Драйвера устройств
- Блочные устройства
 - Утилиты для администрирования дисков
 - Планировщики ввода/вывода (I/O Schedulers)
 - Создаем разделы
- Массив дисков
 - Типы RAID
- **Примеры обслуживания.**
 - Создаем RAID 1 уровня - зеркало.
 - Остановка и старт массива
 - Старт когда один диск полностью поврежден
 - Создаем RAID10, RAID5

Создание программного RAID

На блочных устройствах

- тома LVM
- разделы (позволяют выравнивать диски разных размеров)
- диски

Метаданные (superblock)

- 0.9, 1.0 - конец устройства (необходимо для загрузки в некоторых случаях)
- 1.1 - начало
- 1.2 - 4K от начала устройства

Создание программного RAID

- Подготовка к созданию, “занулить суперблок”
 - `mdadm --zero-superblock $dev_list`
- Создание массива
 - `mdadm --create $raiddev -l $level -n $numdev $dev_list`
- Остановка массива
 - `mdadm --stop $raiddev`

Опции утилиты mdadm

- Информация о массиве
 - `mdadm --detail $raiddev`
- Информация о массиве
 - `cat /proc/mdstat`
- Генерация данных для конфигурационного файла
 - `mdadm --examine --scan`
 - `mdadm --detail --scan`

Файлы блочных устройств NVMe

```
/dev/nvme0n1    # контроллер 0 устройство 1  
/dev/nvme0n1p1 # контроллер 0 устройство 1 раздел 1
```

```
yum search nvme  
yum install nvme-cli  
nvme list    # покажет все устройства  
nvme list-ns /dev/nvme0
```

Рефлексия



Отметьте 3 пункта, которые вам запомнились с вебинара



Что вы будете применять в работе из сегодняшнего вебинара?

The background of the slide is an aerial photograph of a city with many skyscrapers, overlaid with a semi-transparent blue layer. A network of white lines connects various points across the blue area, creating a digital or technological feel.

Заполните, пожалуйста,
опрос о занятии по ссылке в чате