

Пространства имен Linux

Иван Ганкевич

12 сентября 2018 г.

Outline

С чего все начиналось

Пространства имен

Примеры

Контрольные группы

Что со всем этим можно сделать?

Раздел 1

С чего все начиналось

Создание процесса

```
int pid = fork();  
if (pid == 0) {  
    child_main();  
    exit(0);  
}  
int status = 0;  
check(waitpid(pid, &status, 0));
```

Создание процесса

ВЫВОД

```
clone(child_stack=NULL, flags=CLONE_CHILD_CLEARTID|  
      CLONE_CHILD_SETTID|SIGCHLD, child_tidptr=0  
      x7fb0c43921d0) = 6487
```

```
Hello from a process: pid=6487
```

Создание потока

```
std::thread thr(child_main);  
thr.join();
```

Создание потока

ВЫВОД

```
clone(child_stack=0x7f2bc5cf9fb0, flags=CLONE_VM|  
      CLONE_FS|CLONE_FILES|CLONE_SIGHAND|CLONE_THREAD|  
      CLONE_SYSVSEM|CLONE_SETTLS|CLONE_PARENT_SETTID|  
      CLONE_CHILD_CLEARTID, parent_tidptr=0x7f2bc5cfa9d0,  
      tls=0x7f2bc5cfa700, child_tidptr=0x7f2bc5cfa9d0) =  
      6520
```

```
Hello from a pthread: thread_id=139825979041536
```

Создание потока

опции

Опция	Назначение
CLONE_VM	общая память
CLONE_FS	общие рабочая директория, корень ФС и маска
CLONE_FILES	общие файловые дескрипторы
CLONE_SIGHAND	общие обработчики сигналов
CLONE_SYSVSEM	общие примитивы синхронизации
CLONE_THREAD	добавление в группу потоков
CLONE_SETTLS	выделение локальной памяти потока

СИСТЕМНЫЙ ВЫЗОВ `clone(2)`

```
size_t stack_size = 1024*10;  
char* child_stack = new char[stack_size];  
void* child_stack_end = child_stack + stack_size;  
int pid = 0;  
check(pid=clone(child_main, child_stack_end,  
    CLONE_NEWUTS | CLONE_NEWUSER | SIGCHLD, 0));  
int status = 0;  
check(waitpid(pid, &status, 0));  
delete[] child_stack;
```

Системный вызов clone(2)

ВЫВОД

Host UTS: nodename=storm, domainname=(none)

```
clone(child_stack=0x7f9fbc880000, flags=CLONE_NEWUTS |  
      CLONE_NEWUSER | SIGCHLD) = 6551
```

Hello from a container: uid=65534

Container UTS: nodename=spicy, domainname=salmon

Раздел 2

Пространства имен

Опции функции `clone(2)`

Опция <code>clone(2)</code>	Пространство имен
<code>CLONE_NEWNS</code>	точки монтирования
<code>CLONE_NEWPID</code>	процессы
<code>CLONE_NEWUSER</code>	идентификаторы пользователей и групп
<code>CLONE_NEWNET</code>	сетевые устройства
<code>CLONE_NEWUTS</code>	имя хоста и доменное имя машины
<code>CLONE_NEWIPC</code>	примитивы синхронизации
<code>CLONE_NEWCGROUP</code>	контрольные группы

Пространство UTS

Системный вызов	Назначение
<code>sethostname(2)</code>	получение/изменение имени хоста
<code>gethostname(2)</code>	
<code>setdomainname(2)</code>	получение/изменение NIS домена
<code>getdomainname(2)</code>	
<code>uname(2)</code>	вывод информации о системе

Пространство IPC

Примитивы синхронизации и межпроцессного взаимодействия.

Заголовочный файл	Описание
<code>sys/shm.h</code>	общая память System V
<code>sys/ipc.h</code>	
<code>sys/sem.h</code>	семафоры System V
<code>sys/mman.h</code>	общая память POSIX
<code>semaphore.h</code>	семафоры POSIX
<code>mqqueue.h</code>	очереди сообщений POSIX

Пространство PID

Системный вызов	Назначение
<code>getpid(2)</code>	получение идентификатора
<code>getppid(2)</code>	текущего/родительского процессов

Первый процесс особенный:

- ▶ имеет идентификатор 1,
- ▶ ждет завершения других процессов и процессов-зомби `wait(2)`,
- ▶ обрабатывает сигналы выборочно.

Пространство USER

Системный вызов	Назначение
<code>getuid(2)</code> <code>getgid(2)</code> <code>get*id(2)</code>	получение идентификатора пользователя/группы

Особенности:

- ▶ процесс получает полные привилегии в новом пространстве (`capabilities(7)`),
- ▶ имена пользователей и групп не копируются, только идентификаторы,
- ▶ отображение идентификаторов задается в файлах `uid_map` и `gid_map`.

Пространство NS (точки монтирования)

Системный вызов	Назначение
<code>mount(2)</code>	монтирование/размонтирование файловых систем и каталогов
<code>umount(2)</code>	
<code>umount2(2)</code>	

Опция <code>mount(2)</code>	Назначение
<code>MS_SHARED</code>	применить рекурсию остановить рекурсию
<code>MS_PRIVATE</code>	
<code>MS_SLAVE</code>	
<code>MS_REC</code>	
<code>MS_UNBINDABLE</code>	

Системный вызов `pivot_root(2)`

Для успешного выполнения `pivot_root(2)` следующие объекты монтирования не должны быть совместно используемыми:

- ▶ целевой каталог старого корня файловой системы,
- ▶ текущий родительский каталог нового корня файловой системы (на момент вызова `pivot_root(2)`),
- ▶ родительский каталог нового корня файловой системы.

Источник: `pivot_root` (IBM developerworks)

Пространство NET (сетевые устройства)

Системный вызов	Описание
<code>ip(8)</code>	управление сетевыми устройствами (интерфейс для командной строки)
<code>netlink(7)</code>	управление сетевыми устройствами
<code>rtnetlink(7)</code>	
<code>getifaddrs(3)</code>	получение списка сетевых устройств

Дополнительные системные вызовы

Системный вызов	Описание
<code>unshare(2)</code>	изменение пространств имен без создания нового процесса
<code>setns(2)</code>	войти в пространство имен, указанное с помощью дескриптора
<code>nsenter(1)</code>	то же самое для командной строки

Раздел 3

Примеры

Программа `usersns_child_exec`

Usage: `./usersns_child_exec [options] cmd [arg...]`

- `-i` New IPC namespace
- `-m` New mount namespace
- `-n` New network namespace
- `-p` New PID namespace
- `-u` New UTS namespace
- `-U` New user namespace
- `-M uid_map` Specify UID map for user namespace
- `-G gid_map` Specify GID map for user namespace

Исходный код: `user_namespaces(7)`.

Пространство USER

```
id -u; id -g  
./usersns_child_exec \  
-U -M "0 1000 1" -G "0 1000 1" \  
sh -c "id -u; id -g"
```

1000

1000

0

0

Пространство USER

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' \  
sh -c "touch xyz; ls -l xyz"  
ls -l xyz
```

```
-rw-r--r-- 1 root root 0 сен 12 19:16 xyz  
-rw-r--r-- 1 igankevich igankevich 0 сен 12 19:16 xyz
```


Пространство USER

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' \  
sh -c "ls -ldn /etc"  
ls -ld /etc
```

```
drwxr-xr-x. 185 65534 65534 12288 сен 10 10:16 /etc  
drwxr-xr-x. 185 root root 12288 сен 10 10:16 /etc
```

Пространство USER+UTS

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -u \  
sh -c "hostname; hostname usersns-rocks; hostname;  
uname -nsr"
```

storm

usersns-rocks

Linux usersns-rocks 4.16.8-300.fc28.x86_64

Пространство USER+IPC

```
ipcs --shmems --pid | grep ^[0-9]
./usersns_child_exec \
  -U -M '0 1000 1' -G '0 1000 1' -i \
  sh -c "ipcmk -M 1000; ipcs --shmems --pid | grep ^[0-9]"
```

```
ipcs --shmems --pid | grep ^[0-9]
```

59834368	igankevich	16730	3432
59867137	igankevich	16730	3432
60194819	igankevich	16730	3432
60227588	igankevich	16730	3432
60162053	igankevich	16730	3432
60260358	igankevich	16730	3432
61767688	igankevich	16730	3432
62062601	igankevich	16730	3432
61660386	igankovich	16730	3432

Пространство USER+PID

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -p \  
sh -c "echo \$\$"
```

Пространство USER+PID+NS

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -m -p \  
sh -c "mount -t proc proc /proc &&  
ps -eo args,user,pid"
```

COMMAND	USER	PID
ps -eo args,user,pid	root	1

Пространство USER+NET

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -n \  
sh -c "/sbin/ip addr"
```

```
1: lo: <LOOPBACK> mtu 65536 qdisc noop state DOWN group  
    default qlen 1000  
    link/loopback 00:00:00:00:00:00 brd  
        00:00:00:00:00:00
```

Пространство USER+NET

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -n \  
sh -c "/sbin/ip link set dev lo up; /sbin/ip a"
```

```
1: lo: <LOOPBACK,UP,LOWER_UP> mtu 65536 qdisc noqueue  
state UNKNOWN group default qlen 1000  
link/loopback 00:00:00:00:00:00 brd  
00:00:00:00:00:00  
inet 127.0.0.1/8 scope host lo  
valid_lft forever preferred_lft forever  
inet6 ::1/128 scope host  
valid_lft forever preferred_lft forever
```

Пространство USER+NET+NS

```
./usersns_child_exec \  
-U -M '0 1000 1' -G '0 1000 1' -m -n \  
sh -c "  
mount -t sysfs sysfs /sys  
mount -t tmpfs tmpfs /run  
chmod 777 /run  
/sbin/ip netns add netns1  
/sbin/ip link add veth0 type veth peer name veth1  
/sbin/ip link set veth1 netns netns1  
/sbin/ip netns exec netns1 /sbin/ifconfig veth1  
10.1.1.1/24 up  
/sbin/ifconfig veth0 10.1.1.2/24 up  
ping -c 3 10.1.1.1  
"
```


Пространство USER+NET+NS

```
PING 10.1.1.1 (10.1.1.1) 56(84) bytes of data.
```

```
64 bytes from 10.1.1.1: icmp_seq=1 ttl=64 time=0.034 ms
```

```
64 bytes from 10.1.1.1: icmp_seq=2 ttl=64 time=0.021 ms
```

```
64 bytes from 10.1.1.1: icmp_seq=3 ttl=64 time=0.016 ms
```

```
--- 10.1.1.1 ping statistics ---
```

```
3 packets transmitted, 3 received, 0% packet loss, time 2071ms
```

```
rtt min/avg/max/mdev = 0.016/0.023/0.034/0.009 ms
```

Раздел 4

Контрольные группы

См. документацию (версия 2)

Раздел 5

Что со всем этим можно сделать?

Что можно делать с помощью пространств имен?

- ▶ Создать виртуальную сеть для тестирования распределенных алгоритмов.
- ▶ Установить несколько операционных систем через менеджер пакетов, не имея прав суперпользователя.
- ▶ Создать PAM модуль, который бы менял ОС из предыдущего пункта при входе в систему.
- ▶ Создать систему сборки кода C/C++/Fortran, которая бы автоматически загружала зависимости (как maven, npm, pip, gem и др.).
- ▶ Монтировать корневую файловую систему при запуске задач на кластере, т.е. запускать задачу в том же окружении, в котором она разрабатывалась.

Пространства имен в SystemD

```
[Unit]
```

```
Description=nginx reverse proxy server
```

```
[Service]
```

```
User=nginx
```

```
Group=nginx
```

```
ExecStart=/usr/bin/nginx
```

```
ReadOnlyDirectories=/proc
```

```
PrivateTmp=true
```

```
PrivateDevices=true
```

```
ProtectHome=true
```

```
ProtectSystem=full
```

Контрольные группы в SystemD

[Unit]

Description=Dropbox daemon

[Service]

Type=forking

ExecStart=/usr/bin/dropbox start

ExecStop=/usr/bin/dropbox stop

Nice=19

BlockIOWeight=100

CPUQuota=10%

CPUShares=128

[Install]

WantedBy=default.target

Интеграция с PAM (pam_namespace(8))

В файле namespace.conf:

/tmp	/tmp-inst/	level	root,adm
/var/tmp	/var/tmp/tmp-inst/	level	root,adm
\$HOME	\$HOME/\$USER.inst/inst-	context	

О чем стоит задуматься

- ▶ Новое пространство — это не обязательно новая корневая ФС и новый IP-адрес.
- ▶ Для создания новых пространств не обязательно иметь права суперпользователя.
- ▶ Пространства подходят и для графических приложений.
- ▶ Пространства используются не только в контейнерах приложений.

Литература I

Документация ядра Linux

- ▶ unshare
- ▶ Пространства имен
- ▶ Контрольные группы (версия 2)
- ▶ Контрольные группы (устаревшая версия 1)

Полезные статьи

- ▶ pivot_root (IBM developerworks)

Литература II

Страницы руководства Linux

- ▶ `pid_namespaces(7)`
- ▶ `namespaces(7)`
- ▶ `user_namespaces(7)`
- ▶ `capabilities(7)`
- ▶ Руководство Linux (рус.)

Библиотека для работы с сетевыми устройствами

- ▶ `libnl`