Системное программирование в Linux

2021

Системные вызовы

Процессы, потоки и контейнеры

Ввод/вывод в Linux

Выделение/освобождение памяти в Linux

Стандарты и страницы руководства

Системный вызов

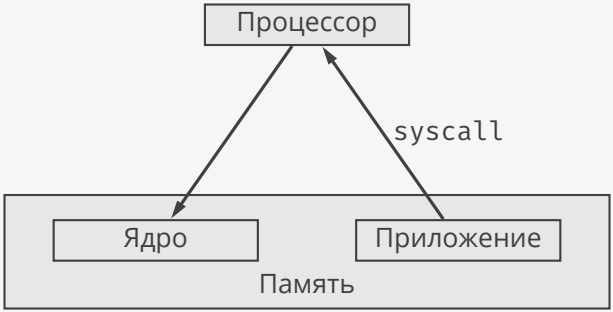

```c
long syscall(long n, ...) {
  va_list ap;        // от 0 до 6
  long a,b,c,d,e,f;  // аргументов
  va_start(ap, n);
  a=va_arg(ap, long);
  ...
  va_end(ap);
  return __syscall_ret(
    __syscall(n,a,b,c,d,e,f)
  );
}

long __syscall_ret(unsigned long r) {
  if (r > -4096UL) { // (-4096,0)
    errno = -r; return -1;
  }
  return r;
}
```

```
.global __syscall
.hidden __syscall
.type __syscall,@function
__syscall:
  movq %rdi,%rax
  movq %rsi,%rdi
  movq %rdx,%rsi
  movq %rcx,%rdx
  movq %r8,%r10
  movq %r9,%r8
  movq 8(%rsp),%r9
  syscall
  ret
```

Источник — библиотека musl libc: syscall.h, syscall_ret.c, syscall_cp.s.

- Каждый системный вызов имеет номер.
- Способ вызова системной функции у каждого процессора свой.

Процессы

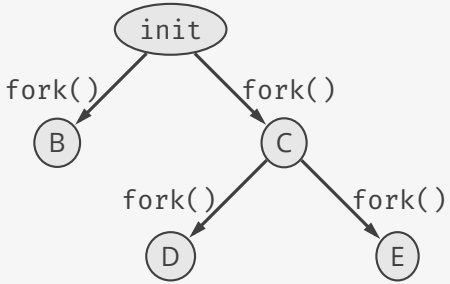


```c
int pid = fork(); // копирует
if (pid == 0) {   // процесс
    // дочерний процесс
}
// родительский процесс
```

Копирование процессов — это медленно!

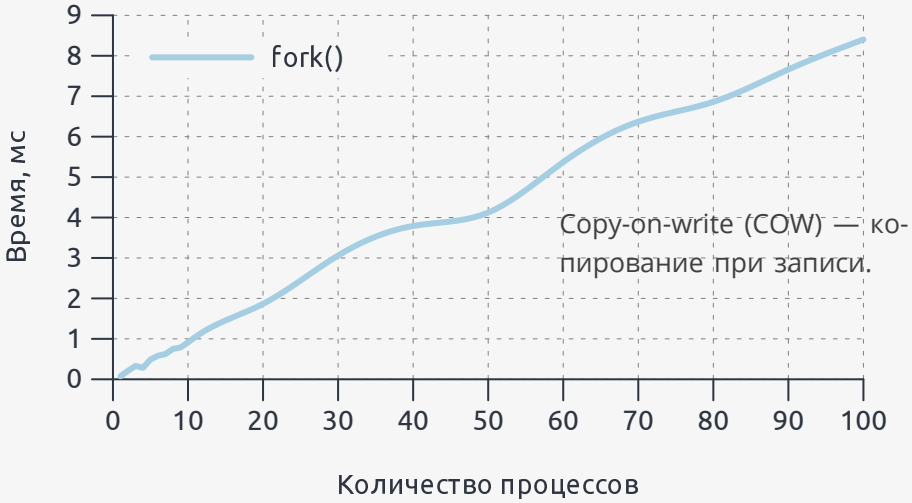

Отслеживание системных вызовов

```
$ strace -e openat ./empty-main # отследить открытие файла
openat(AT_FDCWD, "/etc/ld.so.cache", O_RDONLY|O_CLOEXEC) = 3
openat(AT_FDCWD, "/lib64/libstdc++.so.6", O_RDONLY|O_CLOEXEC) = 3
openat(AT_FDCWD, "/lib64/libm.so.6", O_RDONLY|O_CLOEXEC) = 3
openat(AT_FDCWD, "/lib64/libgcc_s.so.1", O_RDONLY|O_CLOEXEC) = 3
openat(AT_FDCWD, "/lib64/libc.so.6", O_RDONLY|O_CLOEXEC) = 3
```

Создание процесса

Программа:

```
pid_t pid = fork(); // создание дочернего процесса
if (pid == 0) {
    exit(0);        // завершение дочернего процесса
}
int status = 0;
wait(&status);      // подождать завершения дочернего процесса
```

Вывод `strace`:

```
clone(
    child_stack=NULL,
    flags=CLONE_CHILD_CLEARTID | CLONE_CHILD_SETTID | SIGCHLD,
    child_tidptr=0x7f25ede00990
) = 7296
```

Потоки

Программа:

```
std::thread t{[] () {}}; // создание дочернего потока
t.join(); // подождать завершения дочернего потока
```

Вывод `strace`:

```
clone(
    child_stack=0x7f901f84cfb0,
    flags=CLONE_VM | CLONE_FS | CLONE_FILES | CLONE_SIGHAND |
      CLONE_THREAD | CLONE_SYSVSEM | CLONE_SETTLS |
      CLONE_PARENT_SETTID | CLONE_CHILD_CLEARTID,
    parent_tidptr=0x7f901f84d9d0,
    tls=0x7f901f84d700,
    child_tidptr=0x7f901f84d9d0
) = 7345
```

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

Пространства имен

Программа:

```
int child_main(void* ptr) {
  std::string s = "spicy";
  sethostname(s.data(), s.size()));
  return 0;
}

size_t stack_size = 1024*10;
std::unique_ptr<char[]> child_stack(new char[stack_size]);
pid_t pid = clone(child_main, child_stack.get() + stack_size,
  CLONE_NEWUTS | CLONE_NEWUSER | SIGCHLD, 0);
int status = 0;
wait(&status);
```

CLONE_NEWNS	точки монтирования
CLONE_NEWPID	процессы
CLONE_NEWUSER	пользователи и группы
CLONE_NEWNET	сетевые устройства
CLONE_NEWUTS	хост и доменное имя
CLONE_NEWIPC	примитивы сихронизации
CLONE_NEWCGROUP	контрольные группы

Вывод strace:

```
clone(..., flags=CLONE_NEWUTS | CLONE_NEWUSER | SIGCHLD) = 7427
```

Процессы, потоки и контейнеры

- Процесс — единица планирования системных ресурсов.
- Поток — процесс с большим количеством общих с родительским процессом ресурсов.
- Контейнер — процесс, использующий новые пространства имен.

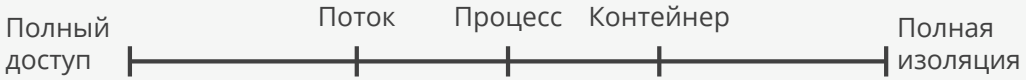

Запуск программ

```
pid_t pid = fork(); // а если здесь создать поток?
if (pid == 0) {
    char* const argv[] = {"ls", "-l", 0}; // аргументы
    execvp(argv[0], argv); // нулевой аргумент — имя программы
    exit(0);
}
int status = 0;
wait(&status);
```

Некоторые системные вызовы

```
getpid()        // номер процесса
getppid()       // номер родительского процесса
getuid()        // номер пользователя
getgid()        // номер группы
getenv()        // переменные среды
getcwd()        // рабочая директория
```

Переменные среды

Программа:

```
char** first = environ;
while (*first) {
    std::cout << *first << '\n';
    ++first;
}
```

Вывод:

```
...
HOME=/home/myuser
LANG=ru_RU.utf8
...
```

Ввод/вывод

Программа:

```
int fd = open("myfile", O_CREAT|O_WRONLY|O_TRUNC, 0644);
const char msg[] = "hello\n";
write(fd, msg, sizeof(msg));
close(fd);
```

Содержимое `myfile`:

```
hello
```

Проверка на ошибки

```
int fd = open("myfile", O_CREAT|O_WRONLY|O_TRUNC, 0644);
if (fd == -1) {
    throw std::system_error(errno, std::generic_category());
}
const char msg[] = "hello\n";
ssize_t nwritten = write(fd, msg, sizeof(msg));
if (nwritten == -1) {
    throw std::system_error(errno, std::generic_category());
}
if (close(fd) == -1) {
    throw std::system_error(errno, std::generic_category());
}
```

Проверка на ошибки

```
template <class T>
inline T check(T ret) {
  if (ret == T(-1))
    throw std::system_error(errno, std::generic_category());
  return ret;
}

auto fd = check(open("myfile", O_CREAT|O_WRONLY|O_TRUNC, 0644));
const char msg[] = "hello\n";
auto nwritten = check(write(fd, msg, sizeof(msg)));
check(close(fd));
```

Работа с памятью

```
size_t size = 4096;
void* ptr = mmap(                  // выделить страницы памяти
    nullptr,                       // адрес
    size,                          // размер в байтах
    PROT_READ|PROT_WRITE,          // права доступа
    MAP_PRIVATE|MAP_ANONYMOUS, // опции
    -1,                            // файловый дескриптор
    0                              // отступ внутри файла
);
munmap(ptr, size);                 // освободить страницы памяти
```

Системный вызов `mmap`

- либо выделяет недоступные другим процессам страницы,
- либо отображает файл на страницы памяти.

```
ptr = mremap(
    ptr,                        // текущий адрес
    size,                       // текущий размер
    size*2,                     // новый размер
    MREMAP_MAYMOVE              // опции
);
size *= 2;
madvise(ptr, size, MADV_SEQUENTIAL); // управление страницами
```

Опции:

MADV_SEQUENTIAL	последовательный
MADV_RANDOM	произвольный
MADV_WILLNEED	скоро понадобится
MADV_DONTNEED	больше не нужен

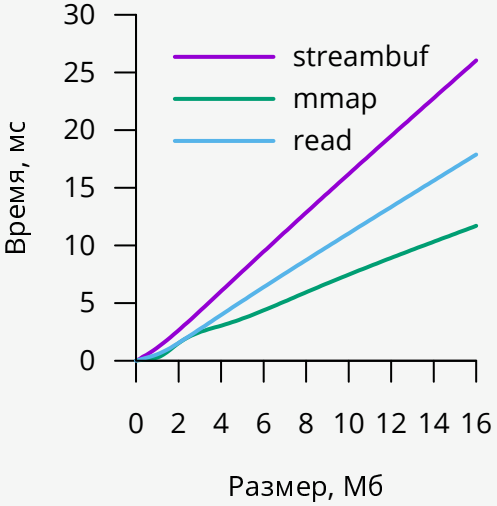
30
25
20
15
10
5
0
Время, мс
streambuf
mmap
read
0 2 4 6 8 10 12 14 16
Размер, Мб

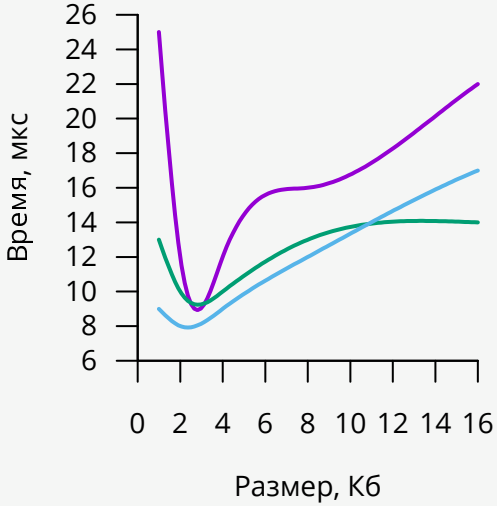
26
24
22
20
18
16
14
12
10
8
6
Время, мкс
0 2 4 6 8 10 12 14 16
Размер, Кб

- Объем выделенной памяти кратен размеру страницы (4Кб).
- При чтении/записи ядро отображает содержимое файлов на страницы памяти, даже если не использовать `mmap`.
- Все считанные файлы попадают в кэш.
- Память можно сделать «видимой» другим процессам.

```
$ free -m
               total        used        free      shared  buff/cache   available
Mem:            7973        1669        3860          64        2442        6140
Swap:           7999          55        7944
```

Стандарты

Немного статистики:

- В Linux около 300 системных вызовов.
- В библиотеке `libc` около 1300 функций.
- Каждая программа использует хотя бы один системный вызов/функцию.
- Обратная совместимость соблюдается строго.

Стандарты:

- System V (SVr4) — устаревший стандарт.
- Single UNIX Specification (SUS).
- Portable Operating System Interface (POSIX).

Страница руководства `socket(7)`:

SO_BSDCOMPAT
Enable BSD bug-to-bug compatibility.

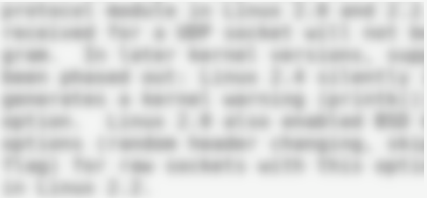

Совместимость с POSIX:

	POSIX1	POSIX2	Год
Linux	62%	33%	2008
MacOS	37%	46%	2001
Windows	*все еще ставятся обновления*		

Сложно портировать OpenGL/OpenCL/CUDA и т.п.

Страницы руководства

Разделы:

1. Исполняемые файлы.
2. Системные вызовы.
3. Библиотечные вызовы.
4. Специальные файлы.
5. Файлы конфигурации.
6. Игры.
7. Общие сведения.
8. Команды для администратора.

В терминале:

```
man 1 ls
man 2 mmap
man 3 realpath
man 4 null
man 5 passwd
man 6 rot13
man 7 tcp
man 8 sudo
```

Онлайн:
www.kernel.org/doc/man-pages/

Ссылки

- The Cathedral and the Bazaar — история открытого исходного кода.
- Сравнение различных libc.
- Страницы руководства Linux.
- Программа для проверки совместимости с POSIX.