

Лекция 3. Коды символов. Системные вызовы. Файлы `stdin`, `stdout`. Разбор работы программы `task3`

NB. Глубокое понимание этой программы является ключом к успешному выполнению всех лабораторных задач нашей дисциплины.

План лекции

- Общая схема работы программы.

- Особенности кодировки символов в текущей версии ОС Linux.

- Системные вызовы. Общие положения

 - Системный вызов `read`

 - Системный вызов `write`

- Файлы `stdin` и `stdout` терминала `shell`

- Взаимодействие клавиатуры терминала `shell` и файла `stdin`

- Макроопределения `Getchar` и `Puts` в файле `my-macro`

 - Макровывозов и макрорасширение `Getchar`

 - Макровывозов и макрорасширение `Puts`

- Разбор исходного файла `task3.S`

- Таблица символов из файла `task3.lst`

Общая схема работы программы

Программа получает байты кодов символов с клавиатуры терминала и после нажатия клавиши `Enter` помещает их в файл стандартного ввода `stdin`, откуда эти байты системным вызовом

read читаются в промежуточный буфер с для анализа.

Если прочитан код цифровой клавиши, то он помещается в очередной байт буфера buf в оперативной памяти. Коды остальных клавиш игнорируются. Программа завершает работу по нажатию комбинации ctrl/D.

Особенности кодировки символов в текущей версии ОС Linux.

Используется версия Unicode — utf-8 (RFC - Request For Comments 3629), код символа занимает 1, 2, 3 или 4 8-битовых байта.

NB. Символы с кодами от 0 до 127 (7F) кода ASCII (стр.184 книги) совпадают с однобайтовыми кодами utf-8. Т.о. в нашей версии ОС однобайтовыми являются коды служебных символов (0A — LF), цифр, прописных и строчных букв английского алфавита.

Одно байтовые коды цифровых символов — от кода «0» - 48 (0x30) до кода «9» - 57 (0x39).

NB. Значение одноцифрового числа = Значение кода — 48 (0x30)

00 00	^@ NUL	16 10	^P DLE	32 20	┌	48 30	0	64 40	@
01 01	^A SOH	17 11	^Q DC1	33 21	!	49 31	1	65 41	A
02 02	^B STX	18 12	^R DC2	34 22	"	50 32	2	66 42	B
03 03	^C ETX	19 13	^S DC3	35 23	#	51 33	3	67 43	C
04 04	^D EOT	20 14	^T DC4	36 24	\$	52 34	4	68 44	D
05 05	^E ENQ	21 15	^U NAK	37 25	%	53 35	5	69 45	E
06 06	^F ACK	22 16	^V SYN	38 26	&	54 36	6	70 46	F
07 07	^G BEL	23 17	^W ETB	39 27	'	55 37	7	71 47	G
08 08	^H BS	24 18	^X CAN	40 28	(	56 38	8	72 48	H
09 09	^I HT	25 19	^Y EM	41 29	)	57 39	9	73 49	I
10 0A	^J LF	26 1A	^Z SUB	42 2A	*	58 3A	:	74 4A	J
11 0B	^K VT	27 1B	^[ESC	43 2B	+	59 3B	;	75 4B	K
12 0C	^L FF	28 1C	^\ FS	44 2C	,	60 3C	<	76 4C	L
13 0D	^M CR	29 1D	^_ GS	45 2D	-	61 3D	=	77 4D	M
14 0E	^N SO	30 1E	^^ RS	46 2E	.	62 3E	>	78 4E	N
15 0F	^O SI	31 1F	^_ US	47 2F	/	63 3F	?	79 4F	O

NB. Численные значения кодов цифровых символов удовлетворяют неравенству:

Значения кодов `ascii` легко получить командой `man ascii`.

ASCII(7)

Linux Programmer's Manual

ASCII(7)

NAME

`ascii` - ASCII character set encoded in octal, decimal, and hexadecimal

DESCRIPTION

ASCII is the American Standard Code for Information Interchange. It is a 7-bit code. Many 8-bit codes (e.g., ISO 8859-1) contain ASCII as their lower half. The international counterpart of ASCII is known as ISO 646-IRV.

The following table contains the 128 ASCII characters.

C program '\X' escapes are noted.

Oct	Dec	Hex	Char	Oct	Dec	Hex	Char
000	0	00	NUL '\0' (null character)	100	64	40	@
001	1	01	SOH (start of heading)	101	65	41	A
002	2	02	STX (start of text)	102	66	42	B
003	3	03	ETX (end of text)	103	67	43	C
004	4	04	EOT (end of transmission)	104	68	44	D
005	5	05	ENQ (enquiry)	105	69	45	E
006	6	06	ACK (acknowledge)	106	70	46	F
007	7	07	BEL '\a' (bell)	107	71	47	G
010	8	08	BS '\b' (backspace)	110	72	48	H
011	9	09	HT '\t' (horizontal tab)	111	73	49	I
012	10	0A	LF '\n' (new line)	112	74	4A	J
013	11	0B	VT '\v' (vertical tab)	113	75	4B	K
014	12	0C	FF '\f' (form feed)	114	76	4C	L
015	13	0D	CR '\r' (carriage ret)	115	77	4D	M

. . .

040	32	20	SPACE	140	96	60	
041	33	21	!	141	97	61	a
042	34	22	"	142	98	62	b
043	35	23	#	143	99	63	c
044	36	24	\$	144	100	64	d
045	37	25	%	145	101	65	e
046	38	26	&	146	102	66	f
047	39	27	'	147	103	67	g
050	40	28	(	150	104	68	h
051	41	29	)	151	105	69	i
052	42	2A	*	152	106	6A	j
053	43	2B	+	153	107	6B	k
054	44	2C	,	154	108	6C	l
055	45	2D	-	155	109	6D	m
056	46	2E	.	156	110	6E	n

057	47	2F	/	157	111	6F	o
060	48	30	0	160	112	70	p
061	49	31	1	161	113	71	q
062	50	32	2	162	114	72	r
063	51	33	3	163	115	73	s
064	52	34	4	164	116	74	t
065	53	35	5	165	117	75	u
066	54	36	6	166	118	76	v
067	55	37	7	167	119	77	w
070	56	38	8	170	120	78	x
071	57	39	9	171	121	79	y
072	58	3A	:	172	122	7A	z
073	59	3B	;	173	123	7B	{
074	60	3C	<	174	124	7C	
075	61	3D	=	175	125	7D	}
076	62	3E	>	176	126	7E	~
077	63	3F	?	177	127	7F	DEL

NOTES

History

An `ascii` manual page appeared in Version 7 of AT&T UNIX.

On older terminals, the underscore code is displayed as a left arrow, called `backarrow`, the caret is displayed as an up-arrow and the vertical bar has a hole in the middle.

Uppercase and lowercase characters differ by just one bit and the ASCII character 2 differs from the double quote by just one bit, too. That made it much easier to encode characters mechanically or with a non-microcontroller-based electronic keyboard and that pairing was found on old teletypes.

The ASCII standard was published by the United States of America Standards Institute (USASI) in 1968.

SEE ALSO

`charsets(7)`, `iso_8859-1(7)`, `iso_8859-10(7)`, `iso_8859-11(7)`, `iso_8859-13(7)`, `iso_8859-14(7)`, `iso_8859-15(7)`, `iso_8859-16(7)`, `iso_8859-2(7)`, `iso_8859-3(7)`, `iso_8859-4(7)`, `iso_8859-5(7)`, `iso_8859-6(7)`, `iso_8859-7(7)`, `iso_8859-8(7)`, `iso_8859-9(7)`, `utf-8(7)`

COLOPHON

This page is part of release 4.16 of the Linux man-pages project. A description of the project, information about reporting bugs, and the latest version of this page, can be found at <https://www.kernel.org/doc/man-pages/>.

Linux

2016-10-08

ASCII(7)

Для обеспечения безопасности в ОС оперативная память разделена на пространство пользователя и пространство ядра. Права обычного пользователя не позволяют выполнять операции в пространстве ядра. В ядре выполняются такие важные функции ОС как управление:

- памятью;
- устройствами;
- файловыми системами;
- процессами.

Т.о прикладному программисту НЕ надо самому разрабатывать программы этих функций.

Прикладной программист может выполнять необходимые ему функции ядра, запуская выполнение в пространстве ядра специальных функций, т. н. *системных вызовов* (syscalls) с помощью приводимого ниже порядка запуска.

Системный вызов выполняется, когда пользовательский процесс (например emacs) требует некоторой службы, реализуемой ядром (например открытие файла), и вызывает специальную функцию (например, системный вызов open). В этот момент пользовательский процесс переводится в режим ожидания. Ядро анализирует запрос, пытается его выполнить и передает результаты пользовательскому процессу, который затем возобновляет свою работу.

Системные вызовы в общем случае защищают доступ к ресурсам, которыми управляет ядро, при этом самые большие категории системных вызовов имеют дело с вводом/выводом (open, close, read, write, poll) и многими другими, процессами (fork, execve, kill и т.д.), временем (time, settimeofday и т.п.) и памятью (mmap, brk и пр.) Под эти категории подпадают практически все

СИСТЕМНЫЕ ВЫЗОВЫ.

Многие команды языка shell просто обращаются к системным вызовам, например `mkdir`, `kill`.

Список всех доступных в конкретной unix системе вызовов находится в файле `/usr/include/asm/unistd_32.h` для архитектуры IA-32 и в файле `/usr/include/asm/unistd_64.h` для архитектуры Intel®64.

```
#ifndef __ASM_X86_UNISTD_32_H
#define __ASM_X86_UNISTD_32_H 1

#define __NR_restart_syscall 0
#define __NR_exit 1
#define __NR_fork 2
#define __NR_read 3
#define __NR_write 4
#define __NR_open 5
#define __NR_close 6
#define __NR_waitpid 7
#define __NR_creat 8
#define __NR_link 9
#define __NR_unlink 10
#define __NR_execve 11
#define __NR_chdir 12
#define __NR_time 13
#define __NR_mknod 14
#define __NR_chmod 15
```

```
#define __NR_lchown 16
```

```
. . .
```

Имя системного вызова (но без префиксов) нужно использовать для получения его описания: `man read.2`. Функции системных вызовов описываются прототипами в стиле языка C.

Порядок запуска системного вызова

Пусть системный вызов с номером N описан прототипом

```
syscall (p1, p2, p3, p4, p5)
```

Передача параметров системному вызову осуществляется через 32-х битовые регистры, в которые следует записать значения параметров, указанные в прототипе, в порядке слева направо. Для запуска системного вызова необходимо выполнить следующую последовательность команд:

```
mov N,%eax      # задать номер системного вызова.
mov p1, %ebx     # задать значение p1
mov p2, %ecx     # ... p2
mov p3, %edx     # ... p3
mov p4, %esi     # ... p4
mov p5, %edi     # ... p5
int $0x80       # прочитать из %eax номер системного
                # вызова и выполнить его
```

По команде `int $0x80` процессор приостанавливает текущий выполняемый процесс, переходит в защищенный режим, читает из `%eax` номер системного вызова и загружает для выполнения соответствующую функцию, реализующую системный вызов. Функция читает из регистров параметры и выполняется.

Системный вызов `read`

```
#include <unistd.h>

ssize_t read(int fd, void *buf, size_t count);
```

Номер системного вызова — 3. `read()` пытается прочитать не более `count` байтов из файла, имеющего файловый дескриптор `fd` в буфер в ОП, заданный указателем `*buf`.

Дескриптор файла это небольшое целое число, которое используется в системных вызовах работы с файлами для ссылки на конкретный файл.

Целое `fd` вычисляет и привязывает к файлу системный вызов `open` при открытии файла.

Если байты прочитались в буфер, в регистре `%eax` возвращается их количество. Если достигнут конец файла (EOF), то в регистре `%eax` возвращается значение ноль.

Системный вызов `write`

```
#include <unistd.h>

ssize_t write(int fd, const void *buf, size_t count);
```

Номер системного вызова — 4. `write()` записывает `count` байт из буфера в ОП, заданного указателем `*buf`, в файл, имеющий файловый дескриптор `fd`.

Если байты записались в файл, в регистре `%eax` возвращается их

количество. При ошибке в регистре %eах возвращается значение - 1.

Файлы `stdin` и `stdout` терминала `shell`

NBNB. В задаче `task3` организован диалог с текущим терминалом `shell` (клавиатура/экран) для которого в ОС назначены файлы и значения их дескрипторов:

- клавиатура — файл `stdin` (только для чтения), `fd = 0`;
- экран — файл `stdout`, (только для записи), `fd = 1`.

NBNB при вводе с клавиатуры системное событие «конец файла» (EOF) `stdin` формируется нажатием комбинации `ctrl/d` (не символ, не имеет кода). Это событие, которое обнаруживают системные вызовы при чтении файла.

Взаимодействие клавиатуры терминала `shell` и файла `stdin`

При нажатии клавиш байты кодов соответствующих символов сначала попадают не в файл `stdin` а в буфер терминала. Только после нажатия клавиши `Enter` байты кодов символов всех клавиш, нажатых после предыдущего нажатия клавиши `Enter`, передаются в файл `stdin`. Системный вызов `read` прочтет из файла заданное параметром `count` количество байтов и разместит их в ОП по адресу `*buf`.

Следующий запуск `read` будет читать еще не прочитанные байты, если они остались в файле `stdin`. Если байтов нет `read` будет ожидать их поступления в `stdin` после очередного нажатия клавиши `Enter`.

Нажатие Enter, ctrl/d, Enter приводит к наступлению события EOF и закрытию файла stdin (он становится недоступным для операций).

Макроопределения Getchar и Puts в файле my-macro

Рассмотрим файл my-macro

```
/*
 * Макроопределение завершения работы.
 * Аргументы:
 *   - код завершения программы
 *
 * После выполнения макровывоза изменяются регистры: %eax, %ebx
 * См. также 'man 2 exit'
 */
.macro Exit ret_val
    movl $1, %eax          # номер сист. вызова exit
    movl \ret_val, %ebx    # код выхода
    int $0x80              # выполнить системный вызов
.endm

/*
 * Макроопределение для считывания одного байта кода символа из
 * стандартного ввода
 * Аргументы:
 *   - адрес буфера для считывания байта
 *
 * Результат:
 *   - в %eax количество считанных байтов
 *   - по адресу buf_addr - считанный байт
 *
 * После выполнения макровывоза изменяются регистры: %eax, %ebx, %ecx, %edx
```

```

* См. также 'man 2 read'
*/

.macro Getchar buf_addr

    movl $3, %eax      # номер сист. вызова read
    movl $0, %ebx      # параметр 1: дескриптор стандартного ввода
    movl \buf_addr, %ecx # параметр 2: адрес буфера (он же – фактический
                        # параметр макровызова)

    movl $1, %edx      # параметр 3: количество байтов для чтения
    int $0x80          # выполнить системный вызов

.endm

```

Макровызов и макрорасширение Getchar (фрагмент файла task3.lst)

Лекционный комментарий.

Появление в исходном файле макровызова Getchar \$c приводит к включению в этот файл макрорасширения (команд тела макроопределения), в котором формальный параметр макроопределения buf_addr заменен на указанный в макровызове фактический параметр \$c, - адрес однобайтового буфера, определенного в секции .bss.

Затем для этого буфера формируются правильные команды запуска системного вызова read.

```

22                               Getchar $c          # макровызов ввода байта из stdin в
22 0018 B8030000      >   movl $3,%eax
22      00
22 001d BB000000      >   movl $0,%ebx
22      00
22 0022 B9640000      >   movl $c,%ecx
22      00
22      >
22 0027 BA010000      >   movl $1,%edx
22      00

```

```
22 002c CD80          >  int $0x80
23                      # промежуточный буфер с
24

/*
 * Макроопределение для вывода строки в файл стандартного вывода
 * Аргументы:
 *   - Строка для вывода.
 *
 * Приметр макровывоза:
 *   Puts "Текст выводимой строки"
 *
 * Результат:
 *   - выводит в стандартный вывод символы заданной строки
 *     и вслед за ними символ перевода строки \n
 *
 * После выполнения макровывоза изменяются регистры: %eax, %ebx, %ecx, %edx
 * См. также 'man puts', 'man 2 write'
 */
.macro Puts string
.data
    str\@:    .ascii "\string\n"  # формирование фактической строки для
вывода
    strlen\@ =    . - str\@      # получение значения длины строки
.text
    movl $4, %eax    # номер сист. вызова write
    movl $1, %ebx    # параметр 1: дескриптор стандартного вывода
    movl $str\@, %ecx    # параметр 2: адрес памяти с выводимыми
символами
    movl $strlen\@, %edx    # параметр 3: количество байтов для вывода
    int $0x80        # выполнить системный вызов
.endm
```

Макровывозов и макрорасширение Puts (фрагмент файла

Лекционный комментарий.

Появление в исходном файле макровывода `Puts "Цифра! Хорошо."` приводит к включению в этот файл макрорасширения (команд тела макроопределения), в котором формальный параметр макроопределения `string` заменен на указанный в макровыводе фактический параметр `"Цифра! Хорошо."`. При этом:

- 1) В секцию `.data` добавляется директива размещения в объектном файле кодов символов подлежащей выводу строки:
`str2: .ascii "Цифра! Хорошо.\n"`
 с присоединением к ней условного кода символа перевода строки `\n`.
- 2) Метка этой строки — `str2`: формируется из конструкции `str\@`, где псевдопеременная `\@` представляют собой счетчик выполненных макровыводов (т. е. до выполнения рассматриваемого макровывода были выполнены макровыводы с номерами 0 и 1).
- 3) Абсолютное символьное имя `strlen2`, также формируемое с помощью псевдопеременной `\@`, получает значение длины строки. Это символьное имя используется затем при формировании команд запуска системного вызова.
- 4) В секции `.text` формируются правильные команды запуска системного вызова `write`.

```

41          Puts "Цифра! Хорошо." # сообщения об успехе вводе
41          > .data
41 002c D0A6D0B8      > str2:.ascii "Цифра! Хорошо.\n"
41          D184D180

```

```

41      D0B02120
41      D0A5D0BE
41      D180D0BE
41      >
41      >  strlen2 =. - str2
41      >
41      > .text
41 005a B8040000    >  movl $4,%eax
41      00
41 005f BB010000    >  movl $1,%ebx
41      00
41 0064 B92C0000    >  movl $str2,%ecx
41      00
41 0069 BA1A0000    >  movl $strlen2,%edx
41      00
41 006e CD80        >  int $0x80

```

Разбор исходного файла task3.S

```

/*
 * Программа ввода кодов цифровых символов в буфер в ОП
 */

.include "my-macro"

.bss
.lcomm buf, 100      # 100 байтовый буфер для кодов прочитанных символов
.lcomm c, 1          # однобайтовый буфер для чтения байта из файла stdin

```

Лекционный комментарий.

Секция `.bss` используется для хранения неинициализированных данных, байты которых при запуске программы имеют нулевые значения. Данные этой секции не хранятся в объектном и исполняемом файлах, память для нее распределяет загрузчик исполняемого файла. Символьные имена в секции `bss` определяются директивой `.lcomm`, задающей имя и длину выделяемой ему области ОП в байтах.

```

.text
.global _start

```

```

_start:

```

sub %esi, %esi # указатель адреса байта в буфере buf (индексный регистр)

show_prompt:

Puts "Вводите цифру, друг мой!" # макровывод строки в
файл stdout (подсказка ввода)

kbd_input:

Getchar \$c # макровывод ввода байта из stdin в
промежуточный буфер c

cmpl \$0, %eax # наступило событие EOF (конец файла stdin) ?
je stop # Да - на завершение программы

cmpb \$'\n', c # это символ перевода строки ?
je kbd_input # ДА - на ввод следующего символа
cmpb \$'9', c # код больше кода символа '9' ?
ja print_err_msg # ДА - на вывод сообщения об ошибке
cmpb \$'0', c # код меньше кода символа '0' ?
jb print_err_msg # ДА - на вывод сообщения об ошибке

movb c, %al # передать код символа цифры из c в al
movb %al, buf(%esi) # передать код символа цифры из al в байт
буфера по адресу &buf + esi
incl %esi # указать на следующий байт буфера для
следующего кода

Лекционный комментарий.

1. Т.к. оба буфера c и buf находятся в ОП, нельзя передать значение из c в buf одной командой, сперва передаем его в %al командой `movb c, %al`.

2. Каждый введенный в цикле код цифрового символа надо записывать в последовательные байты buf, увеличивая в каждом цикле адрес записи на один.

Адрес байта	buf+0	buf+1	buf+2	..	buf+n
Значение %esi	0	1	2		n
№ введенного байта кода	1	2	3		n+1

Для решения таких задач существует механизм *режимов адресации*, частным случаем которого является команда `movb %al, buf(%esi)`.

При такой записи операнда приемника говорят, что `%esi` является базовым регистром, а адрес этого операнда приемника — `A` вычисляется перед каждым выполнением этой команды по формуле $A = \text{*buf} + \%esi$, как это показано в таблице выше. Увеличение значения `%esi` в каждом цикле обеспечивает команда `incl %esi`.

```
Puts "Цифра! Хорошо." # сообщение об успехе вводе

    jmp show_prompt     # на ввод следующего символа

print_err_msg:
    Puts "Не цифровая клавиша. Повторите ввод"      # вывод сообщения об
ошибке
    jmp show_prompt     # на ввод следующего байта

stop:
    Exit $0

.end
```

Таблица символов из файла task3.lst

```
DEFINED SYMBOLS

    task3.S:8      .bss:0000000000000000 buf
    task3.S:8      .bss:0000000000000064 c
    task3.S:14     .text:0000000000000000 _start
    task3.S:17     .text:0000000000000002 show_prompt
    task3.S:18     .data:0000000000000000 str0
    task3.S:18     *ABS*:000000000000002c strlen0
    task3.S:21     .text:0000000000000018 kbd_input
    task3.S:49     .text:000000000000008d stop
    task3.S:45     .text:0000000000000072 print_err_msg
    task3.S:41     .data:000000000000002c str2
    task3.S:41     *ABS*:000000000000001a strlen2
    task3.S:46     .data:0000000000000046 str3
    task3.S:46     *ABS*:0000000000000042 strlen3

NO UNDEFINED SYMBOLS
```

NB. Видно, что определяемые в макрорасширениях `Puts` строки последовательно располагаются в единственной секции `.data`.