

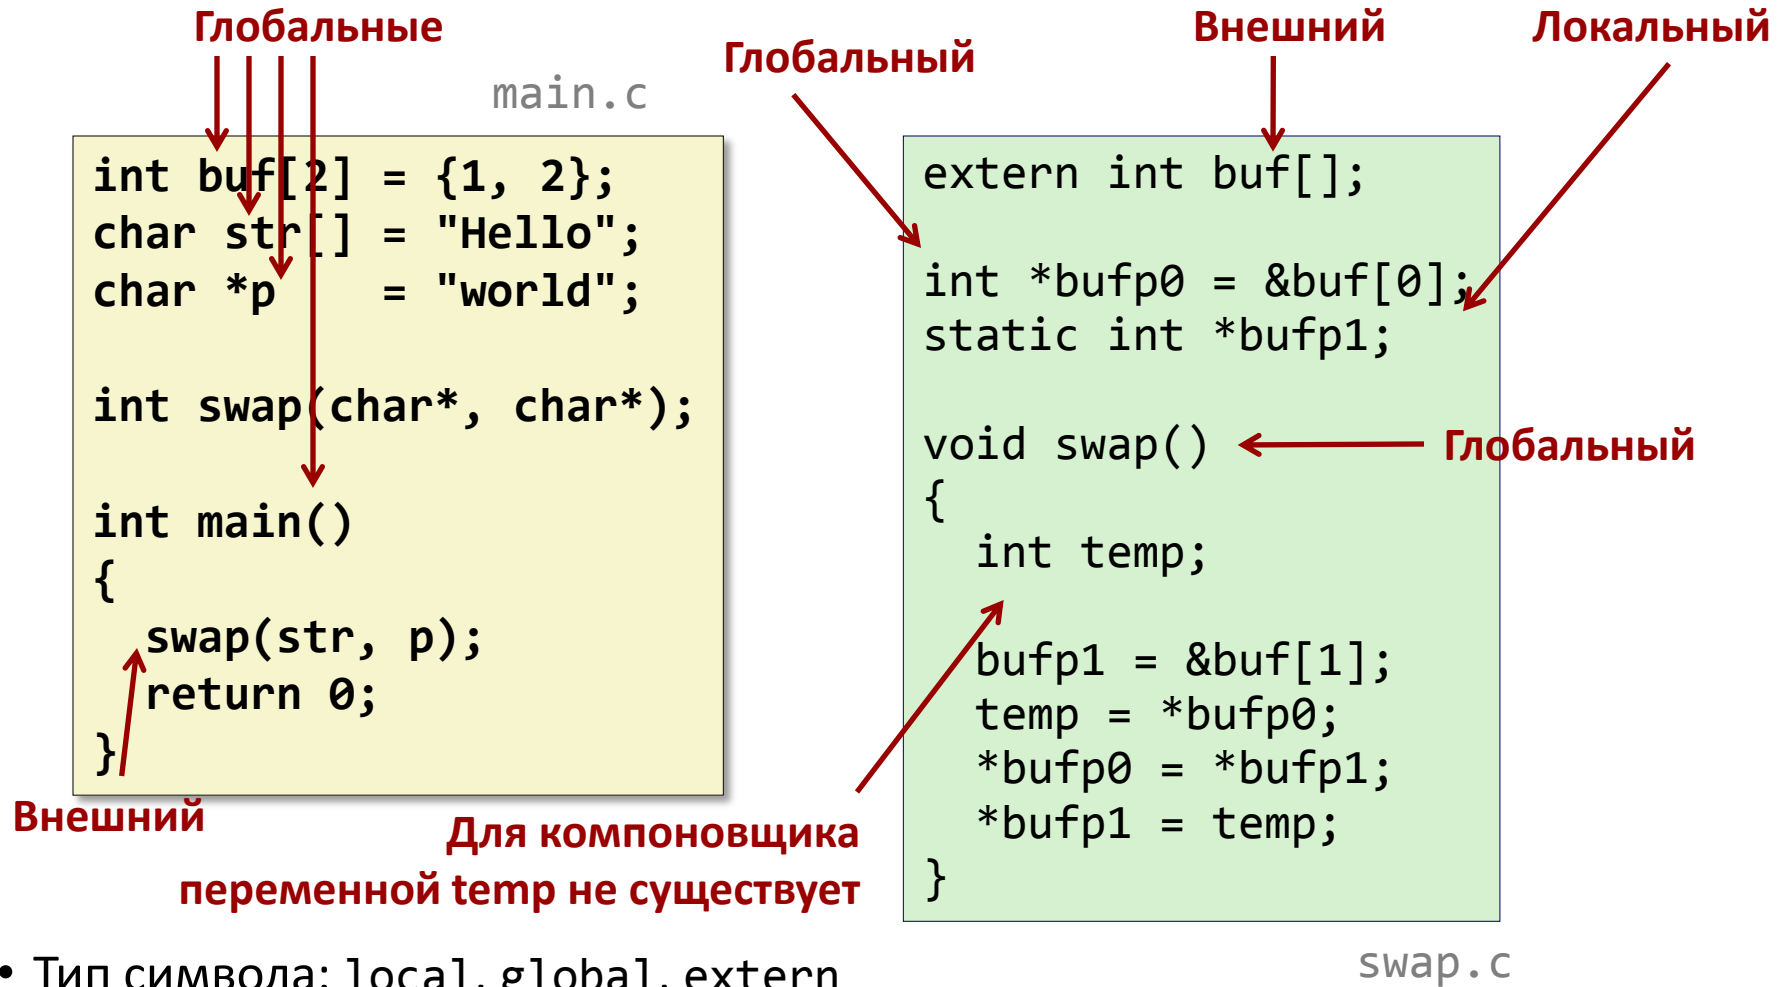
# Лекция 0x12

11 апреля

# Символы в процессе компоновки

- Глобальные символы
  - Символы определенные в одном модуле таким образом, что их можно использовать в других модулях.
  - Например: не-`static` Си-функции и не-`static` глобальные переменные.
- Внешние (неопределенные) символы
  - Глобальные символы, которые используются в модуле, но определены в каком-то другом модуле.
- Локальные символы
  - Символы определены и используются исключительно в одном модуле.
  - Например: Си-функции и переменные, определенные с модификатором `static`.
  - **Локальные символы не являются локальными переменными Си-программы**

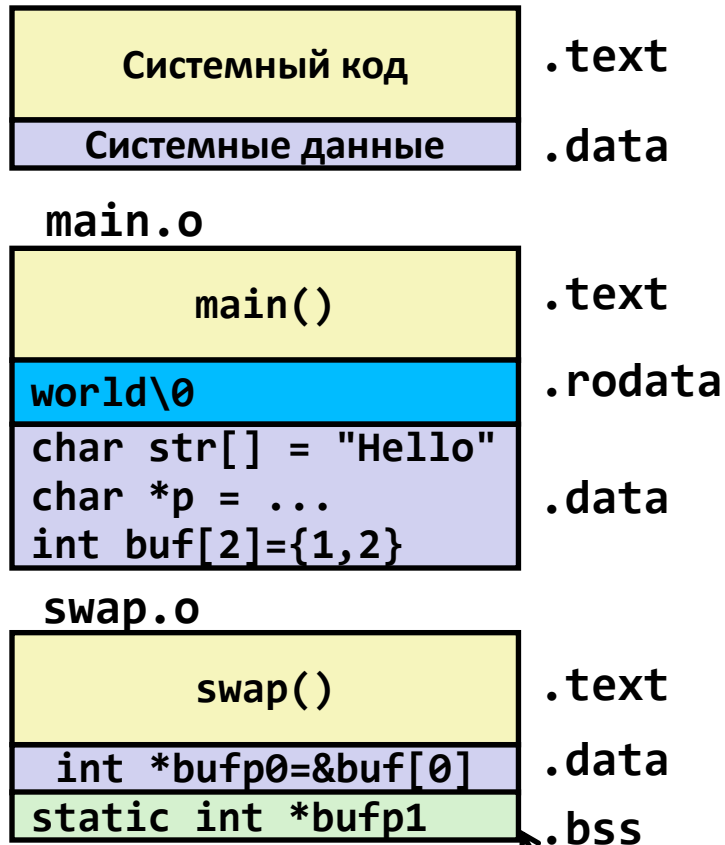
# Задача: разрешение символов



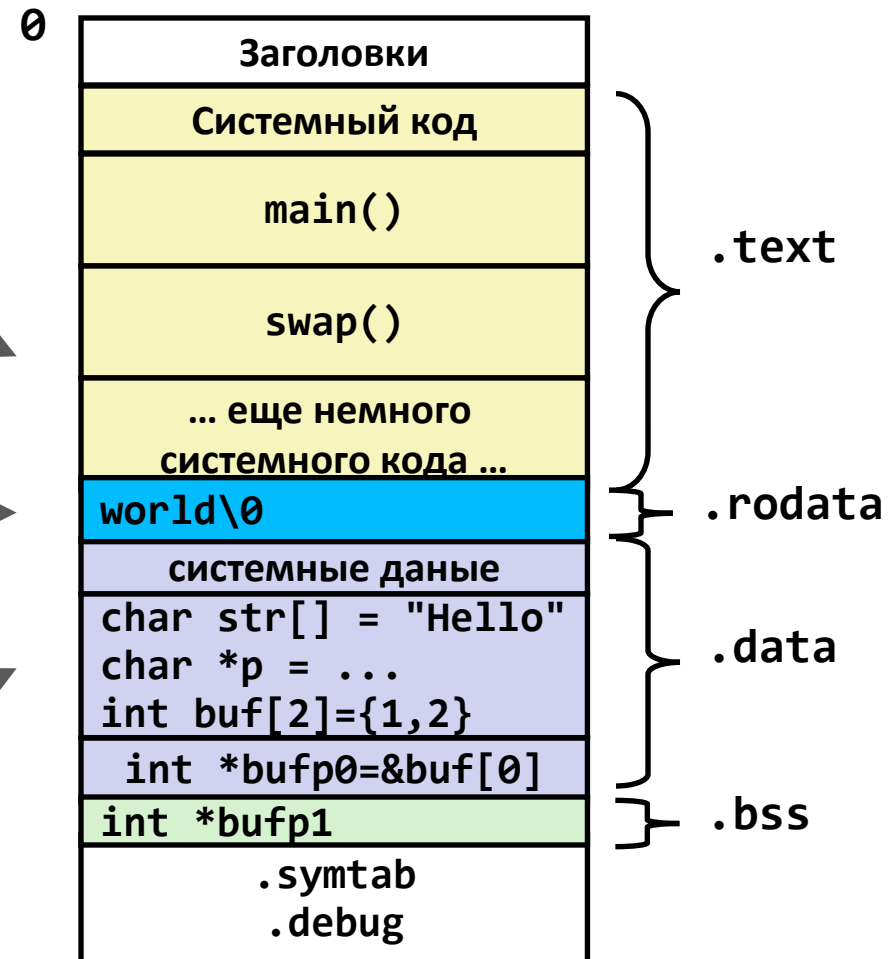
- Тип символа: local, global, extern
- Присутствует ли символ в .symtab?
- Размер?
- Модуль, в котором символ определен?
- Смещение внутри секции?

# Перемещение кода и данных

Перемещаемый объектный файл



Исполняемый объектный файл



Даже приватные данные файла swap, требуют размещения в `.bss`

# Предварительное определение переменных

```
int i1 = 10;      /* определение, внешнее связывание */
static int i2 = 20; /* определение, внутреннее связывание */
extern int i3 = 30; /* определение, внешнее связывание */
int i4;          /* предварительное определение, внешнее связывание */
static int i5;    /* предварительное определение, внутреннее связывание */

int i1;          /* корректное предварительное определение */
int i2;          /* ошибка, неувязка с уже заданным связыванием */
int i3;          /* корректное предварительное определение */
int i4;          /* корректное предварительное определение */
int i5;          /* ошибка, неувязка с уже заданным связыванием */
```

- Связывание имен
  - Внешнее: переменная доступна во всех единицах трансляции
  - Внутреннее: переменная доступна только в текущей единице трансляции
- Определение
  - В отсутствии инициализатора, определение трактуется как «предварительное» (tentative definition). В отсутствии других определений в данной единице трансляции переменной присваивается нулевое значение.

# Сильные и слабые символы

- Каждый символ в программе либо «сильный», либо «слабый»
  - **Сильные**: функции и инициализированные глобальные переменные
  - **Слабые**: неинициализированные глобальные переменные

**сильный** → **p1.c**  
`int foo=5;`  
**сильный** → `p1() {`  
`}`

**p2.c**  
`int foo;` ← **слабый**  
`p2() {` ← **сильный**  
`}`

# Правила работы с символами

- Правило 1: Одинаковые сильные символы запрещены
  - Каждый элемент может быть определен только один раз
  - В противном случае ошибка компоновки
- Правило 2: Один сильный символ и несколько слабых – выбираем сильный символ
  - Ссылки на слабые символы заменяются ссылками на сильный символ
- Правило 3: Если несколько слабых символов, выбираем произвольный
  - Поведение можно поменять: `gcc -fno-common`

```
extern int buf[];

int *bufp0 = &buf[0];
static int *bufp1;

void swap()
{
    int temp;

    bufp1 = &buf[1];
    temp = *bufp0;
    *bufp0 = *bufp1;
    *bufp1 = temp;
}
```

```
snoop@jezek:~/samples/2017/linking$ gcc -c swap.c
snoop@jezek:~/samples/2017/linking$ readelf -s swap.o
```

Symbol table '.symtab' contains 12 entries:

Num:	Value	Size	Type	Bind	Vis	Ndx	Name
...							
10:	00000000	0	NOTYPE	GLOBAL	DEFAULT	UND	buf
...							



```
extern int buf[];

int *bufp0 = &buf[0];
static int *bufp1;
int buf[];
void swap()
{
    int temp;

    bufp1 = &buf[1];
    temp = *bufp0;
    *bufp0 = *bufp1;
    *bufp1 = temp;
}
```

- COMMON-символы в перемещаемом коде не относят к какой-либо реально существующей секции
- Место в памяти для таких символов выделяется при построении исполняемого кода в общей .bss секции
- При «слиянии» COMMON-символов есть возможность проверить их размер

```
snoop@jezek:~/samples/2017/linking$ gcc -c swap.c
snoop@jezek:~/samples/2017/linking$ readelf -s swap.o
```

Symbol table '.symtab' contains 12 entries:

Num:	Value	Size	Type	Bind	Vis	Ndx	Name
...							
10:	00000004	4	OBJECT	GLOBAL	DEFAULT	COM	buf
...							

```
extern int buf[];

int *bufp0 = &buf[0];
static int *bufp1;
int buf[];
void swap()
{
```

- Отказ от механизма COMMON-символов приводит к «принудительному» выделению памяти в для них в секции .bss
- В силу особенностей языка Си и правил построения исполняемого кода, программа выделит в памяти место для каждого предварительно определенного «экземпляра» переменной
- Последствия?

```
snoop@jezek:~/samples/2017/linking$ gcc -fno-common -c swap.c
snoop@jezek:~/samples/2017/linking$ readelf -s swap.o
```

Symbol table '.symtab' contains 12 entries:

Num:	Value	Size	Type	Bind	Vis	Ndx	Name
------	-------	------	------	------	-----	-----	------

• • •

```
10: 00000000      4 OBJECT GLOBAL DEFAULT      5 buf
```

• • •

```
snoop@jezek:~/samples/2017/linking$ readelf -S swap.o
```

There are 13 section headers, starting at offset 0x24c:

## Section Headers:

[Nr]	Name	Type	Addr	Off	Size	ES	Flg	Lk	Inf	Al
------	------	------	------	-----	------	----	-----	----	-----	----

• • •

```
[ 5] .bss          NOBITS          00000000 000070 000008 00  WA  0  0  4
```

• • •

# Задача

```
int x;
p1() {}
```

```
p1() {}
```

Ошибка компоновки: два сильных символа (**p1**)

```
int x;
p1() {}
```

```
int x;
p2() {}
```

Ссылки на **x** будут ссылаться на один и тот же неинициализированный **int**. Но какой?

```
int x;
int y;
p1() {}
```

```
double x;
p2() {}
```

Запись в **x** (**p2**) может поменять **y**!

```
int x=7;
int y=5;
p1() {}
```

```
double x;
p2() {}
```

Запись в **x** (**p2**) *обязательно* **поменяет y**!

```
int x=7;
p1() {}
```

```
int x;
p2() {}
```

Ссылка на **x** будет ссылаться на один и тот же инициализированный **int**.

Наихудший сценарий: два одинаковые «слабые» структуры,  
Откомпилированные разными компиляторами с разными правилами  
выравнивания.

# Глобальные переменные

- Следует избегать, если только есть такая  
ВОЗМОЖНОСТЬ
- В противном случае
  - Используйте `static` если это возможно
  - Если определяете глобальную переменную,  
инициализируйте ее
  - Используйте `extern` если ссылаетесь на внешнюю  
глобальную переменную

```
extern void func();

char *buf = "Hello, world!\n";

int main() {
    int ret_code = 0;
    func();
    return ret_code;
}
```

hello1.c

```
#include <stdio.h>

extern char* buf;

void func() {
    printf("%s", buf);
}
```

hello2.c

```
all: hello


hello: hello1.o hello2.o
    gcc -Xlinker -M -o hello hello1.o hello2.o

hello1.o: hello1.c
    gcc -c -o hello1.o hello1.c

hello2.o: hello2.c
    gcc -c -o hello2.o hello2.c

clean:
    rm -f hello hello1.o hello2.o
```

Makefile



```
extern void func();  
  
char *buf = "Hello, world!\n";  
  
int main() {  
    int ret_code = 0;  
    func();  
    return ret_code;  
}
```

hello1.c

```
snoop@earth:~/samples/2014$ nm hello1.o  
00000000 D buf  
          U func  
00000000 T main
```

```
extern void func();
char *buf = "Hello, world!\n";

int main() {
    int ret_code = 0;
    func();
    return ret_code;
}
```

hello1.c

snoop@earth:~/samples/2014\$ readelf -s hello1.o

Symbol table '.symtab' contains 11 entries:

Num:	Value	Size	Type	Bind	Vis	Ndx	Name
0:	00000000	0	NOTYPE	LOCAL	DEFAULT	UND	
1:	00000000	0	FILE	LOCAL	DEFAULT	ABS	hello1.c
2:	00000000	0	SECTION	LOCAL	DEFAULT	1	
3:	00000000	0	SECTION	LOCAL	DEFAULT	3	
4:	00000000	0	SECTION	LOCAL	DEFAULT	5	
5:	00000000	0	SECTION	LOCAL	DEFAULT	6	
6:	00000000	0	SECTION	LOCAL	DEFAULT	8	
7:	00000000	0	SECTION	LOCAL	DEFAULT	7	
8:	00000000	4	OBJECT	GLOBAL	DEFAULT	3	buf
9:	00000000	28	FUNC	GLOBAL	DEFAULT	1	main
10:	00000000	0	NOTYPE	GLOBAL	DEFAULT	UND	func

```
extern void func();
char *buf = "Hello, world!\n";

int main() {
    int ret_code = 0;
    func();
    return ret_code;
}
```

```
snoop@earth:~/samples/2014$ readelf -r hello1.o
```

```
Relocation section '.rel.text' at offset 0x388 contains 1 entries:
```

Offset	Info	Type	Sym.Value	Sym. Name
00000012	00000a02	R_386_PC32	00000000	func

```
Relocation section '.rel.data' at offset 0x390 contains 1 entries:
```

Offset	Info	Type	Sym.Value	Sym. Name
00000000	00000501	R_386_32	00000000	.rodata

Что будет, если  
поменять код?

```
...
char buf[] = "Hello, world!\n";
...
```



## Напоминание

Диалект Intel-синтаксиса, который используют программы binutils, отличается от диалекта, поддерживаемого nasm.

```
snoop@earth:~/samples/2014$ objdump -M intel -dr hello1.o
```

```
hello1.o:      file format elf32-i386
```

Disassembly of section .text:

```
00000000 <main>:
```

```

0:  55                push    ebp
1:  89 e5             mov     ebp,esp
3:  83 e4 f0          and     esp,0xfffffffff0
6:  83 ec 10          sub     esp,0x10
9:  c7 44 24 0c 00 00 00 mov     DWORD PTR [esp+0xc],0x0
10:  00
11:  e8 fc ff ff ff    call    12 <main+0x12>
12:  R_386_PC32 func
16:  8b 44 24 0c       mov     eax,DWORD PTR [esp+0xc]
1a:  c9               leave
1b:  c3               ret

```

```
snoop@earth:~/samples/2014$ readelf
```

```
Relocation section '.rel.text' at
Offset      Info      Type
00000012    00000a02 R_386_PC32
```

```
Relocation section '.rel.data' at
Offset      Info      Type
00000000    00000501 R_386_32
```

```
snoop@earth:~/samples/2014$ objdump -s -j .data hello1.o
```

```
hello1.o:      file format elf32-i386
```

```
Contents of section .data:
```

```
0000 00000000      ....
```

```
snoop@earth:~/samples/2014$ objdump -s -j .rodata hello1.o
```

```
hello1.o:      file format elf32-i386
```

```
Contents of section .rodata:
```

```
0000 48656c6c 6f2c2077 6f726c64 210a00      Hello, world!..
```

```
snoop@earth:~/samples/2014$ readelf -r hello1.o
```

```
Relocation section '.rel.text' at offset 0x388 contains 1 entries:
```

Offset	Info	Type	Sym.Value	Sym. Name
00000012	00000a02	R_386_PC32	00000000	func

```
Relocation section '.rel.data' at offset 0x390 contains 1 entries:
```

Offset	Info	Type	Sym.Value	Sym. Name
00000000	00000501	R_386_32	00000000	.rodata

```
#include <stdio.h>
extern char* buf;

void func() {
    printf("%s", buf);
}
```

hello2.c

```
snoop@earth:~/samples/2014$ nm hello2.o
                 U buf
00000000 T func
                 U printf
```

```
#include <stdio.h>
extern char* buf;

void func() {
    printf("%s", buf);
}
```

```
snoop@earth:~/samples/2014$ readelf -s hello2.o
```

Symbol table '.symtab' contains 11 entries:

Num:	Value	Size	Type	Bind	Vis	Ndx	Name
0:	00000000	0	NOTYPE	LOCAL	DEFAULT	UND	
1:	00000000	0	FILE	LOCAL	DEFAULT	ABS	hello2.c
2:	00000000	0	SECTION	LOCAL	DEFAULT	1	
3:	00000000	0	SECTION	LOCAL	DEFAULT	3	
4:	00000000	0	SECTION	LOCAL	DEFAULT	4	
5:	00000000	0	SECTION	LOCAL	DEFAULT	5	
6:	00000000	0	SECTION	LOCAL	DEFAULT	7	
7:	00000000	0	SECTION	LOCAL	DEFAULT	6	
8:	00000000	31	FUNC	GLOBAL	DEFAULT	1	func
9:	00000000	0	NOTYPE	GLOBAL	DEFAULT	UND	buf
10:	00000000	0	NOTYPE	GLOBAL	DEFAULT	UND	printf

```
#include <stdio.h>
extern char* buf;

void func() {
    printf("%s", buf);
}
```

```
snoop@earth:~/samples/2014$ readelf -r hello2.o
```

Relocation section '.rel.text' at offset 0x354 contains 3 entries:

Offset	Info	Type	Sym.Value	Sym. Name
00000008	00000901	R_386_32	00000000	buf
0000000d	00000501	R_386_32	00000000	.rodata
00000019	00000a02	R_386_PC32	00000000	printf

```
snoop@earth:~/samples/2014$ objdump -M intel -dr hello2.o
```

```
hello2.o:      file format elf32-i386
```

```
snoop@earth:~/samples/2014$ readelf -r hell
```

```
Relocation section '.rel.text' at offset 0x
Offset      Info      Type          Sym.Val
```

```
Disassembly of section .text:
```

```
00000000 <func>:
```

```

0:  55                push    ebp
1:  89 e5             mov     ebp,esp
3:  83 ec 18          sub     esp,0x18
6:  8b 15             mov     edx,DWORD PTR ds:0x0
                        00 00 00 00
                        8: R_386_32
                        buf
c:  b8             mov     eax,0x0
                        00 00 00 00
                        d: R_386_32
                        .rodata
11: 89 54 24 04       mov     DWORD PTR [esp+0x4],edx
15: 89 04 24          mov     DWORD PTR [esp],eax
18: e8             call    19 <func+0x19>
                        fc ff ff ff
                        19: R_386_PC32
                        printf

1d: c9                leave
1e: c3                ret
```

```
snoop@earth:~/samples/2014$ gcc -Xlinker -M -o hello hello1.o hello2.o
```

```
...
.text          0x00000000080483e4      0x1c hello1.o
               0x00000000080483e4      main
.text          0x0000000008048400      0x1f hello2.o
               0x0000000008048400      func
...
.rodata        0x00000000080484e0      0xf hello1.o
.rodata        0x00000000080484ef      0x3 hello2.o
...
.data          0x000000000804a014      0x4 hello1.o
               0x000000000804a014      buf
.data          0x000000000804a018      0x0 hello2.o
```

```
snoop@earth:~/samples/2014$ nm hello1.o
```

```
00000000 D buf
          U func
00000000 T main
```

```
snoop@earth:~/samples/2014$ nm hello2.o
```

```
          U buf
00000000 T func
          U printf
```

Стандартная  
библиотека языка Си  
*printf.o*

```
snoop@earth:~/samples/2014$ gcc -Xlinker -M -o hello hello1.o hello2.o
...
.text          0x00000000080483e4      0x1c hello1.o
               0x00000000080483e4      main
.text          0x0000000008048400      0x1f hello2.o
               0x0000000008048400      func
...
.rodata        0x00000000080484e0      0xf  hello1.o
.rodata        0x00000000080484ef      0x3  hello2.o
...
.data          0x000000000804a014      0x4  hello1.o
               0x000000000804a014      buf
.data          0x000000000804a018      0x0  hello2.o
```

- Правила пересчета для значений ссылок
  - Тип перебазирувания R\_386\_32  

$$\text{новое значение ссылки} = S + A$$
  - Тип перебазирувания R\_386\_PC32  

$$\text{новое значение ссылки} = S + A - P$$
- $S$  – абсолютный адрес памяти, которому символ соответствует после перемещения
- $A$  – дополнительное слагаемое (addend), хранимое непосредственно в байтах ссылки
- $P$  – абсолютный адрес ссылки



```
snoop@earth:~/samples/2014$ objdump -s -j .data hello
```

```
hello:      file format elf32-i386
```

```
Contents of section .data:
```

```
 804a00c 00000000 00000000 e0840408                .....
```

```
snoop@earth:~/samples/2014$ objdump -d -M intel -s -j .text hello
```

```
...
```

```
080483e4 <main>:
```

```

80483e4:      55                push    ebp
80483e5:      89 e5             mov     ebp,esp
80483e7:      83 e4 f0          and     esp,0xfffffffff0
80483ea:      83 ec 10          sub     esp,0x10
80483ed:      c7 44 24 0c 00 00 00 mov     DWORD PTR [esp+0xc],0x0
80483f4:      00
80483f5:      e8 06 00 00 00   call    8048400 <func>
80483fa:      8b 44 24 0c       mov     eax,DWORD PTR [esp+0xc]
80483fe:      c9               leave
80483ff:      c3               ret

```

Как изменились ссылки, попавшие в  
исполняемый код из файла hello1.o?

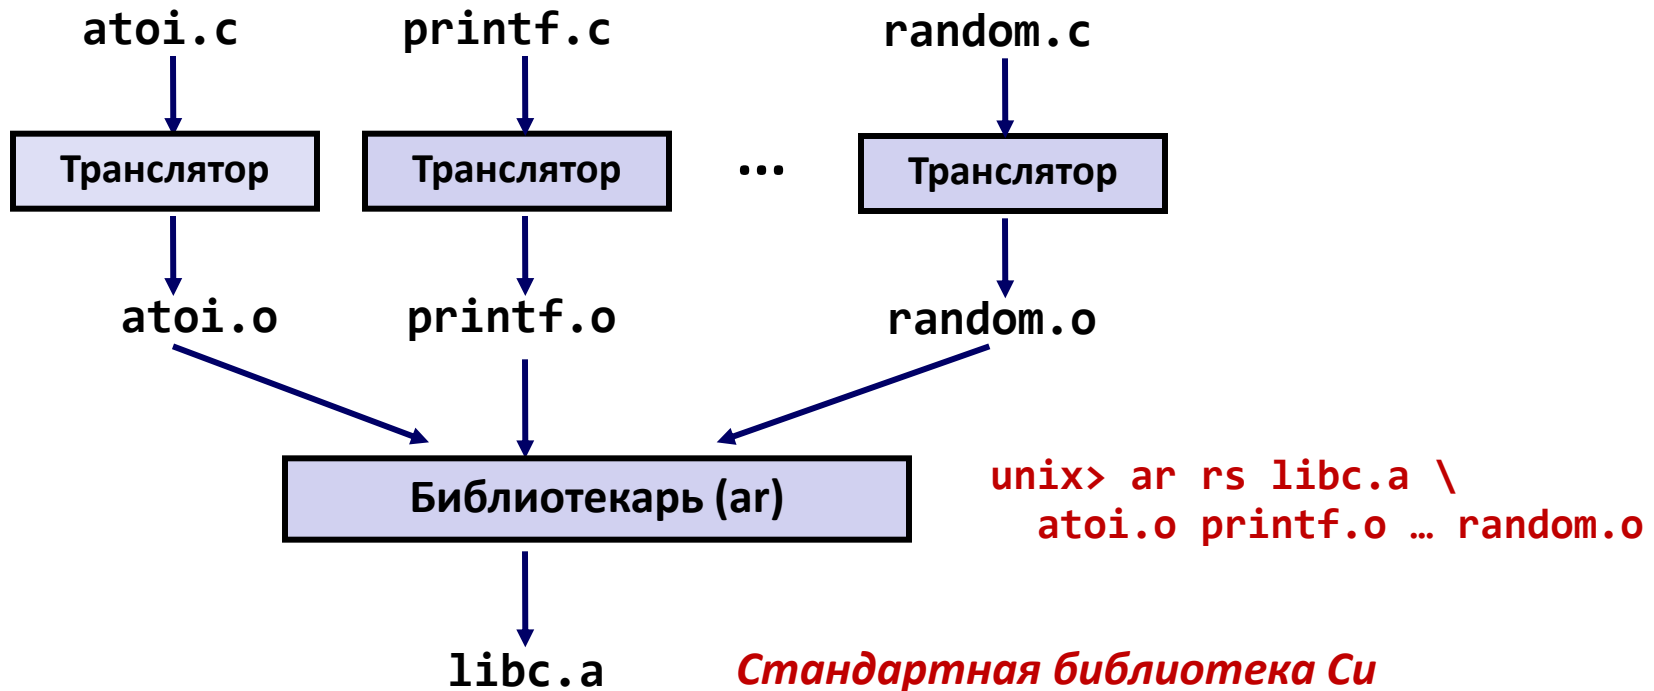
# Работа с общими функциями

- Как следует размещать функции, часто используемые разными программами?
  - Математика, I/O, управление памятью, работа со строками, и т.д.
- Исходя из порядка компоновки:
  - **Вариант 1:** Поместить все функции в один файл
    - Компонуемся с одним большим объектным файлом
    - Неэффективно
  - **Вариант 2:** Поместить каждую функцию в отдельный файл
    - Во время компоновки явно указываем нужные объектные файлы
    - Более эффективно, но крайне неудобно для программиста

## Решение: статические библиотеки

- **Статические библиотеки** (.а – файлы-архивы)
  - Близкие по смыслу перемещаемые объектные файлы группируются в одном файле, в т.н. называемом архиве.
  - Компоновщику указывают набор архивов для того, чтоб он попытался найти в них код с недостающими символами.
  - Если содержащийся в архиве файл помогает разрешить символ, то его автоматически включают в компоновку.

# Создание статической библиотеки



- Библиотекарь позволяет выполнять инкрементальное обновление
- Повторная компиляция функции и замена соответствующего о-файла в библиотеке.

# Часто используемые библиотеки

## libc.a (Стандартная библиотека Си)

- 8 МБ архив из 1392 объектных файлов.
- I/O, управление памятью, работа со строками, даты и время, случайные числа, целочисленные математические функции

## libm.a (Математическая библиотека Си)

- 1 МБ архив из 401 объектных файлов.
- Математические функции над числами с плавающей точкой (sin, cos, tan, log, exp, sqrt, ...)

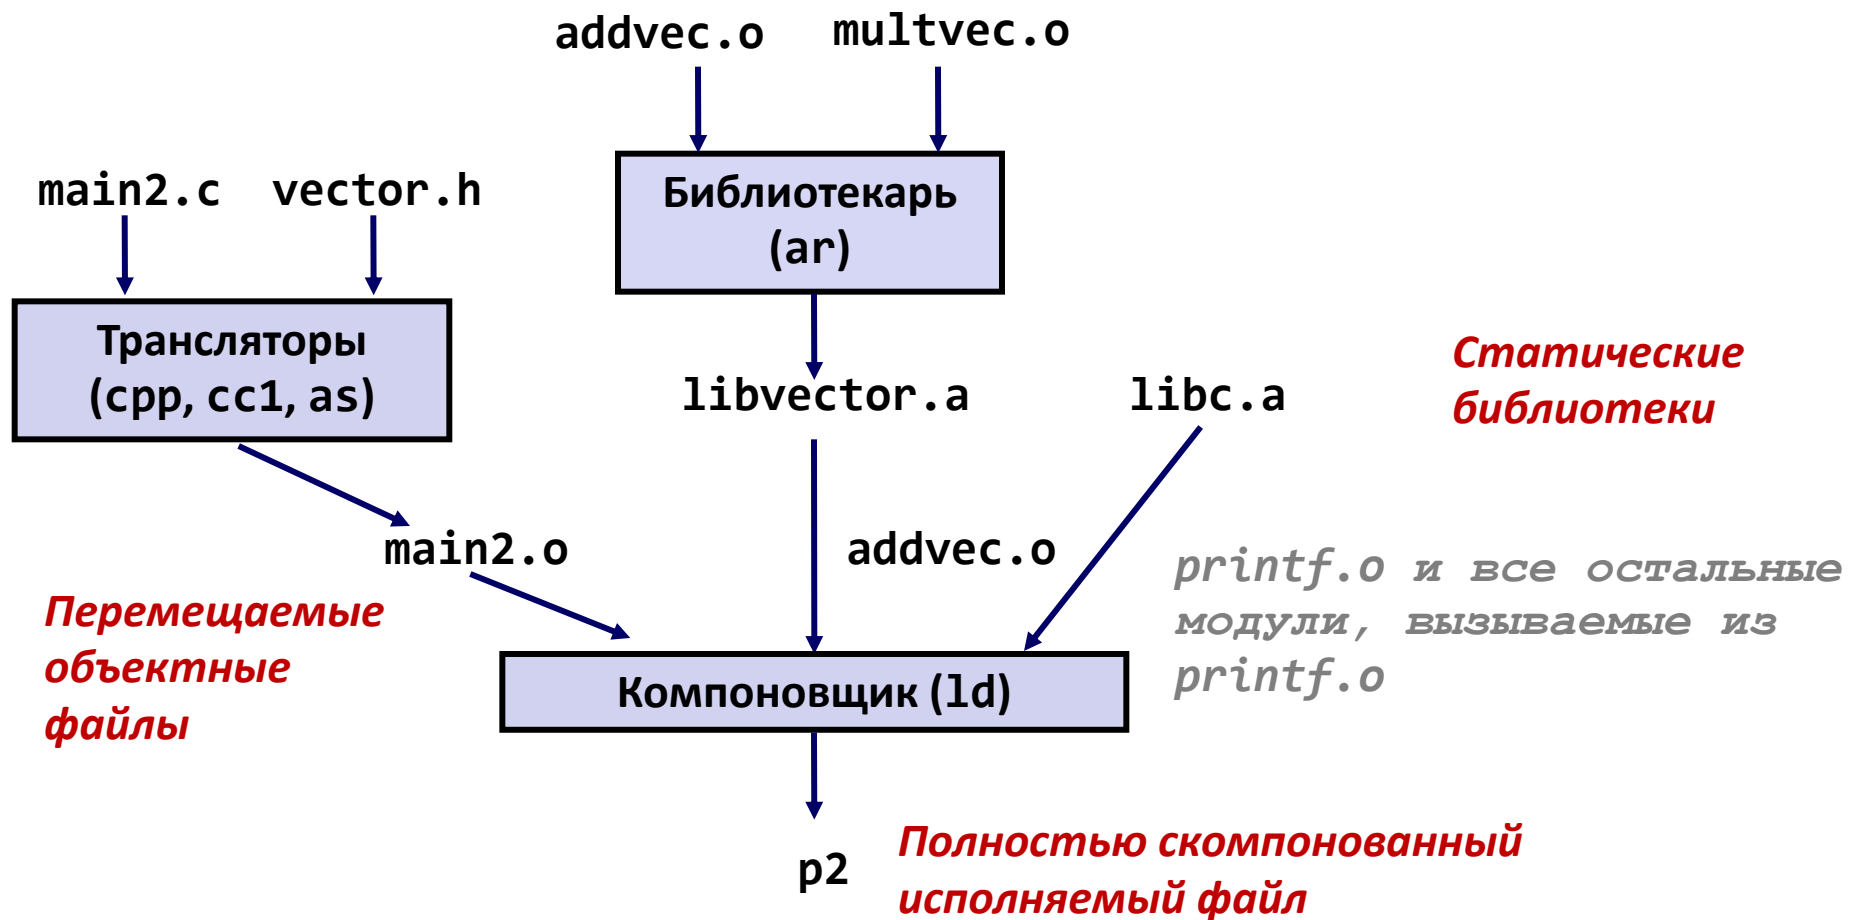
```
% ar -t /usr/lib/libc.a | sort
```

```
...  
fork.o  
...  
fprintf.o  
fpu_control.o  
fputc.o  
freopen.o  
fscanf.o  
fseek.o  
fstab.o  
...
```

```
% ar -t /usr/lib/libm.a | sort
```

```
...  
e_acos.o  
e_acosf.o  
e_acosh.o  
e_acoshf.o  
e_acoshl.o  
e_acosl.o  
e_asin.o  
e_asinf.o  
e_asinl.o  
...
```

# Компоновка со статическими библиотеками



# Использование статических библиотек

- Алгоритм компоновщика для разрешения внешних ссылок :
  - Просматриваем `.o` файлы и `.a` файлы в порядке их следования в командной строке.
  - В процессе просмотра, поддерживаем список неразрешенных в данный момент символов.
  - Как только появляется новый `.o` или `.a` файл, пытаемся разрешить каждый еще неразрешенный символ среди символов, определенных в найденном файле.
  - Ошибка линковки, если по окончании просмотра остался хоть один неразрешенный символ.
- Проблема:
  - Важен порядок объектных файлов в командной строке!
  - Решение: помещать все библиотеки в конец командной строки.

```
unix> gcc -L. libtest.o -lmine
unix> gcc -L. -lmine libtest.o
libtest.o: In function `main':
libtest.o(.text+0x4): undefined reference to `libfun'
```

# Загрузка исполняемого объектного файла

- Подготовка адресного пространства для запускаемой программы
- Просмотр у заданного файла таблицы заголовков сегментов
  - Для каждого сегмента типа LOAD загружаем указанные байты из файла на указанные адреса памяти
- Передаем управление на точку входа в программу (символ `_start`)

```
typedef struct {  
    Elf32_Word p_type;    /* LOAD, DYNAMIC, INTERP, PHDR, NULL, ... */  
    Elf32_Off  p_offset;  /* Смещение от начала файла */  
    Elf32_Addr p_vaddr;   /* Начальный (базовый) адрес в памяти */  
    Elf32_Addr p_paddr;   /* Не используется */  
    Elf32_Word p_filesz;  /* Размер в файле в байтах */  
    Elf32_Word p_memsz;   /* Размер в памяти в байтах */  
    Elf32_Word p_flags;   /* R/W/X */  
    Elf32_Word p_align;   /* Величина выравнивания */  
} Elf32_Phdr;
```



# Связь секций и сегментов

```
snoop@jezek:~/samples/2017/linking$ readelf -l hello-static
```

```
Elf file type is EXEC (Executable file)
```

```
Entry point 0x8048a8d
```

```
There are 6 program headers, starting at offset 52
```

```
Program Headers:
```

Type	Offset	VirtAddr	PhysAddr	FileSiz	MemSiz	Flg	Align
LOAD	0x000000	0x08048000	0x08048000	0xa3a31	0xa3a31	R E	0x1000
LOAD	0x0a3f3c	0x080ecf3c	0x080ecf3c	0x01124	0x02608	RW	0x1000
NOTE	0x0000f4	0x080480f4	0x080480f4	0x00044	0x00044	R	0x4
TLS	0x0a3f3c	0x080ecf3c	0x080ecf3c	0x00010	0x00028	R	0x4
GNU_STACK	0x000000	0x00000000	0x00000000	0x00000	0x00000	RW	0x10
GNU_RELRO	0x0a3f3c	0x080ecf3c	0x080ecf3c	0x000c4	0x000c4	R	0x1

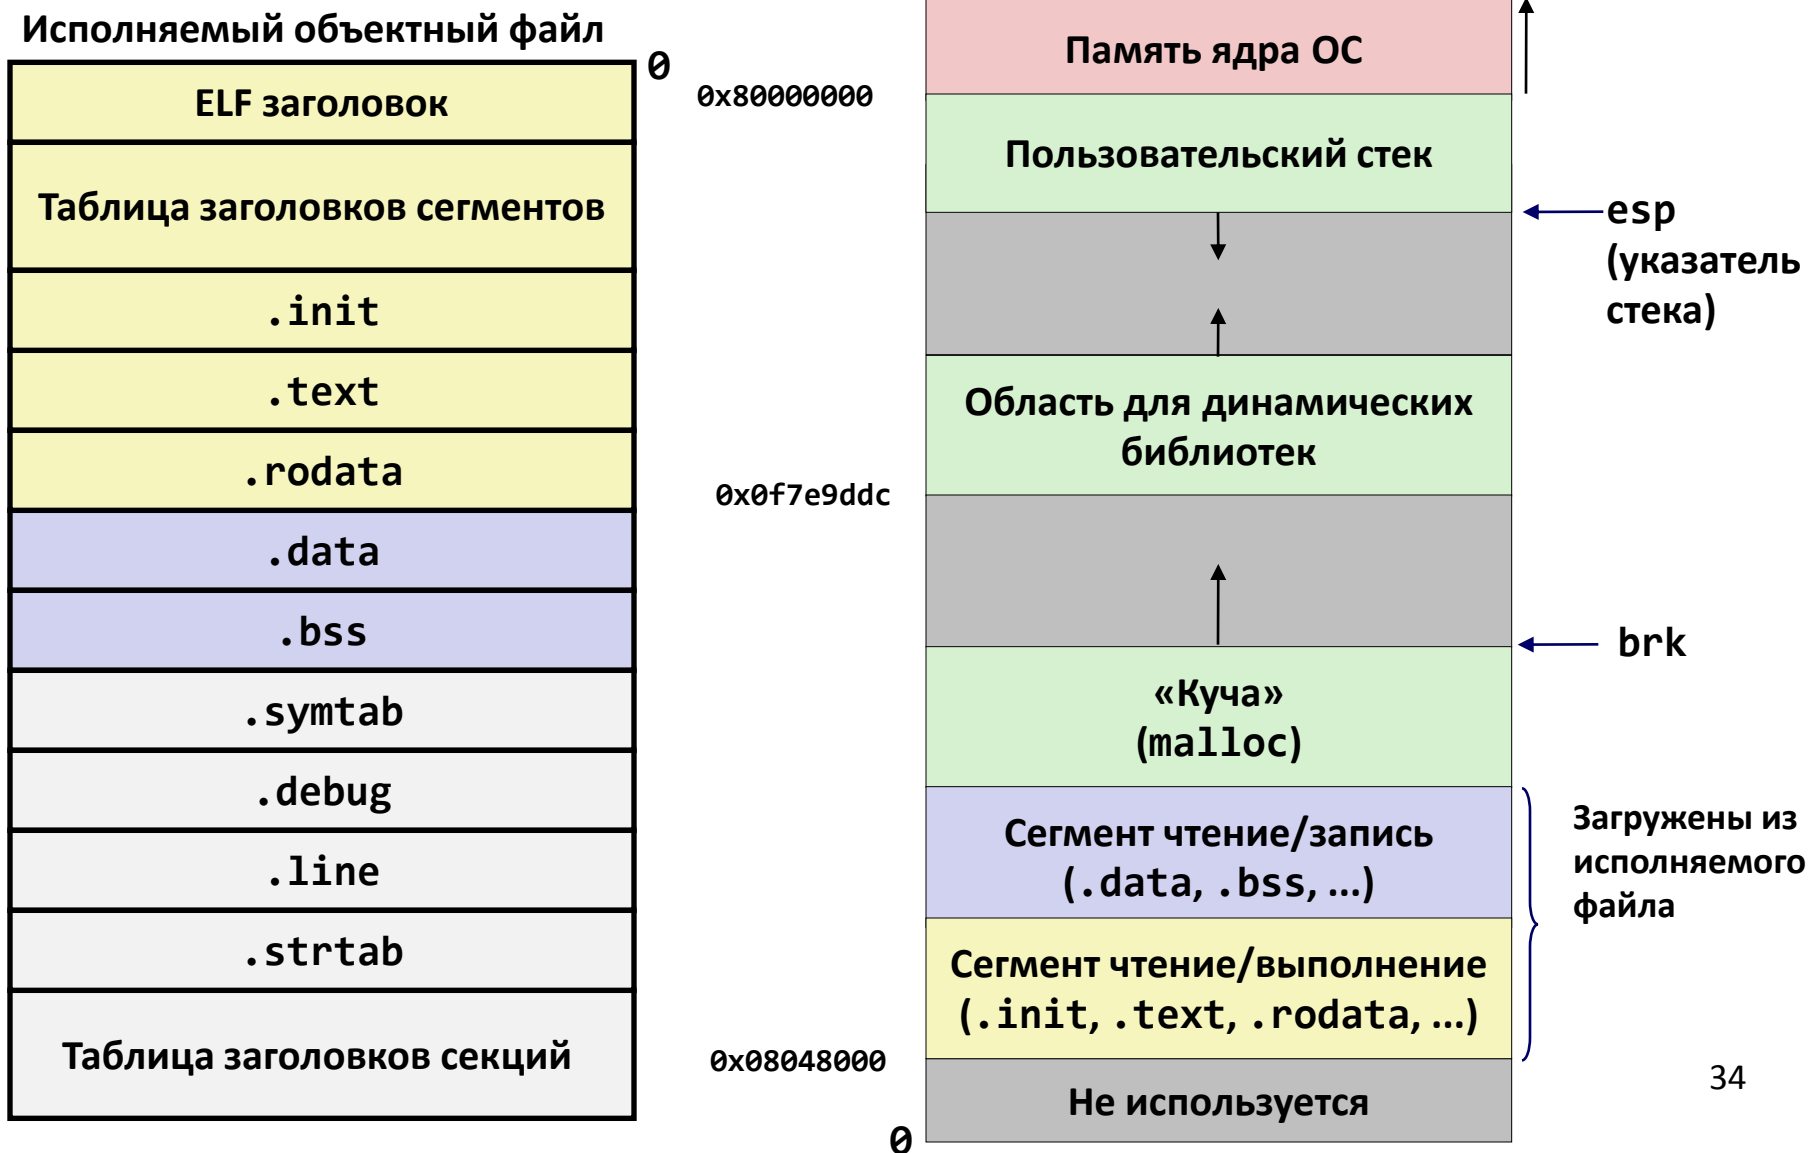
```
Section to Segment mapping:
```

```
Segment Sections...
```

```
00      ... .init .text .fini .rodata ...
```

```
01      ... .init_array .fini_array .data .bss
```

# Загрузка исполняемого объектного файла



# Динамические (разделяемые) библиотеки

- Статические библиотеки имеют следующие недостатки:
  - Многократное копирование кода в построенных исполняемых файлах (всем нужно std libc)
  - Копии кода в исполняющихся программах
  - Любое исправление в системных библиотеках требует повторной компоновки для **всех** приложений

```
snoop@earth:~/samples$ gcc -static -o hello-static hello1.o hello2.o
snoop@jezek:~/samples$ ls -l hello-static
-rwxrwxr-x 1 snoop snoop 743476 Apr 12 09:15 hello-static
snoop@earth:~/samples$ gcc -o hello hello1.o hello2.o
snoop@jezek:~/samples$ ls -l hello
-rwxrwxr-x 1 snoop snoop 7404 Apr 12 09:06 hello
```

- Способ преодолеть эти недостатки: динамические библиотеки (shared libraries)
  - Объектные файлы, в которых содержатся код и данные компонуются с приложением *динамически*, либо во время *загрузки*, либо во время *выполнения*
  - Практикуются названия: DLL-ки, .so-шники

# Динамические (разделяемые) библиотеки

- Динамическая компоновка происходит когда исполняемый файл в первый раз загружается и начинает работать (компоновка во время загрузки).
  - В Linux наиболее распространено, автоматически выполняется динамическим компоновщиком (`ld-linux.so`).
  - Стандартная библиотека языка Си (`libc.so`) обычно компонуется динамически.
- Динамическая компоновка может происходить когда программа уже работает (динамическая загрузка библиотек).

```
#include <dlfcn.h>
void *dlopen(const char *filename, int flag);
```

- Функции динамических библиотек могут одновременно использоваться несколькими процессами.

# Проблемы

- Динамическая библиотека может быть размещена в произвольном месте памяти
- Как обращаться из основной программы к переменным и функциям, размещение которых в памяти будет известно только в момент запуска программы?
  - До момента компоновки неизвестно, куда ведет ссылка – в перемещаемый код другой единицы трансляции или в динамическую библиотеку
  - Перемещаемый код с ссылками уже построен, в нем могут меняться только значения операндов (перебазируемые ссылки)
    - В случае динамической загрузки, адреса размещения будут определены еще позже – в уже работающей программе
- Как строить код динамической библиотеки, когда до момента начала выполнения ее кода неизвестно, по каким адресам будут размещены ее собственные функции и данные