Компьютерные основы программирования
Представление программ
часть1

Лекция 4, 9 марта 2017

Лектор: Чуканова Ольга Владимировна
Кафедра информатики
602 АК
ovcha@mail.ru

Машинный уровень

- Краткая история изделий Интел
- Си, ассемблер, машинный код
- Основы ассемблера: регистры, операнды, пересылки
- Немного об x86-64
- Полная адресация, вычисление адреса (leal)
- Арифметические операции
- Управление: флаги условий
- Условные переходы и пересылки
- Циклы
- Операторы переключения

Процессоры Intel x86

- Подавляющее доминирование на рынках настольных ПК, ноутбуков, серверов
- Эволюционное конструирование
  - Обратно совместимы до 8086, выпущенного в 1978
  - Функции добавляются с ходом времени
- Complex instruction set computer (CISC)
  - Много команд во многих форматах
    - Но, лишь немногие встречаются в Linux программах
  - Трудно конкурировать по быстродействию с Reduced Instruction Set Computers (RISC)
  - Однако, Intel сделал именно это!
    - В терминах быстродействия. Но не энергопотребления.

Вехи эволюции Intel x86

Имя	*Дата*	*Транзисторов*	*МГц*
8086	1978	29K	5-10
386	1985	275K	16-33
Pentium 4F	2004	125M	2800-3800
Core i7	2008	731M	2667-3333

- 1-й 16-битный процессор. Основа для IBM PC & DOS
- 1MB адресного пространства
- 1-й 32-битный процессор, известен как IA32
- Добавлена “плоская адресация”
- Способен исполнять Unix
- 32-битный Linux/gcc не использует более поздние команды
- 1-й 64-битный процессор, известен как x86-64
- Современные машины

Рис. 3.1. Закон Мура

Процессоры Intel x86 : Обзор

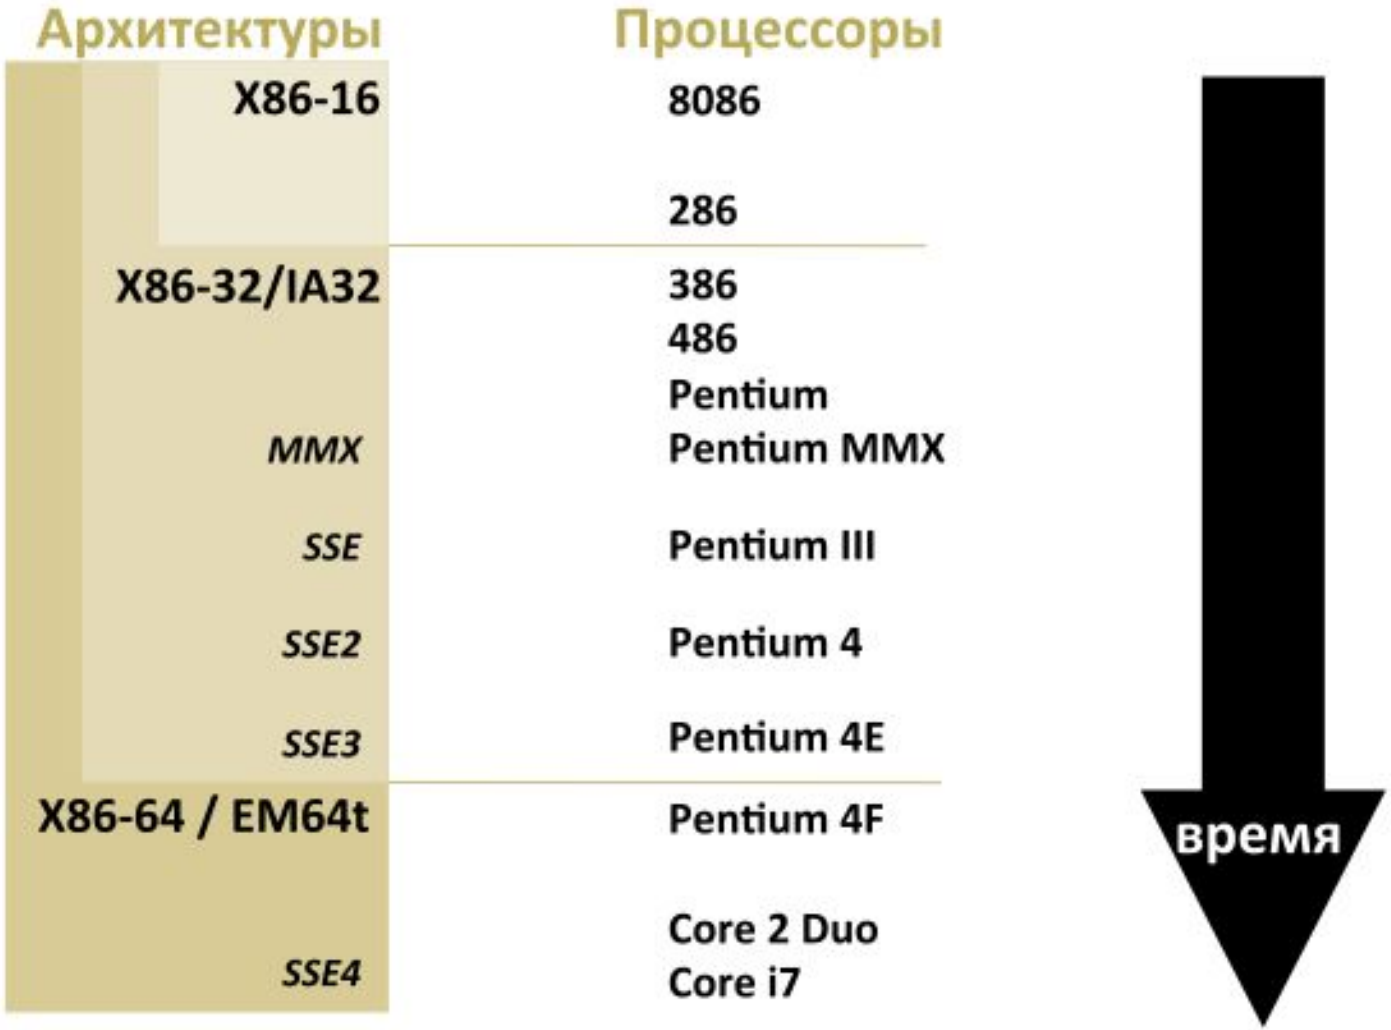

IA: часто переопределяется как последняя архитектура Intel

Процессоры Intel x86, далее

- Эволюция машин

386	1985	0.3M
Pentium	1993	3.1M
Pentium/MMX	1997	4.5M
PentiumPro	1995	6.5M
Pentium III	1999	8.2M
Pentium 4	2001	42M
Core 2 Duo	2006	291M
Core i7	2008	731M

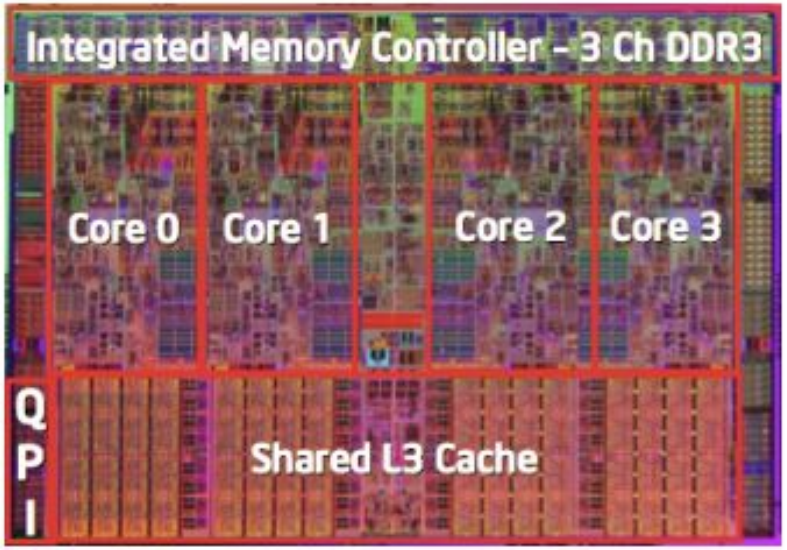

- Добавленные возможности
  - Команды обработки данных мультимедиа(multimedia)
    - Параллельные операции с 1, 2, 4-байтовыми данными, целыми и с плавающей точкой
  - Команды для более эффективной условной обработки
- Эволюция Linux/GCC
  - Два главных шага: 1) 32-битный 386. 2) 64-битный x86-64

x86 Clones: Advanced Micro Devices (AMD)

- Сначала
  - AMD догоняла Intel
  - Немного медленнее, много дешевле
- Потом
  - Привлекла лучших аппаратчиков из Digital Equipment Corp. И других компаний
  - Создала Opteron: сильного соперника Pentium 4
  - Разработала x86-64, собственное 64-битное расширение

64-битный Intel

- Intel попытался радикально сменить IA32 на IA64
  - Полностью другая архитектура (Itanium)
  - Исполнение кода IA32, только как устаревшего
  - Разочаровывающее быстродействие
- AMD вышла с эволюционным решением
  - x86-64 (сейчас известна как “AMD64”)
- Intel нарушил обязательство сосредоточения на IA64
  - Трудно признавать ошибки и превосходство AMD
- 2004: Intel аноносировал EM64T расширение к IA32
  - 64-битная технология расширенной памяти
  - Почти идентична x86-64!
- Сейчас все “low-end” процессоры x86 содержат x86-64
  - Однако большинство кода - всё ещё в 32-битном режиме

Определения

- Архитектура(системы команд), также instruction set architecture: ISA. Часть конструкции процессора которую надо знать для понимания ассемблерного кода.
  - Примеры: описание набора команд, регистры.

- Микроархитетура: Реализация архитектуры.
  - Примеры: размер кеша и частота ядра.

Классификация архитектур системы команд

Классификация по составу и сложности команд

- **Архитектуры с полным набором команд: CISC (Complex Instruction Set Computer)**
- **Архитектуры с сокращенным набором команд: RISC (Reduced Instruction Set Computer)**
- **Архитектуры с параллелизмом на уровне команд: ILP (Instruction Level Parallelism)**

Классификация архитектур системы команд

Классификация по месту хранения операндов

- **Регистровая**
- **Стековая**
- **С выделенным доступом к памяти**
- **Комбинированная**

Выбор той или иной архитектуры влияет на принципиальные моменты: сколько адресов будет содержать адресная часть команд, какова длина этих адресов, насколько просто будет происходить доступ к операндам и какой, в конечном итоге, будет длина команд

Программная модель ассемблера

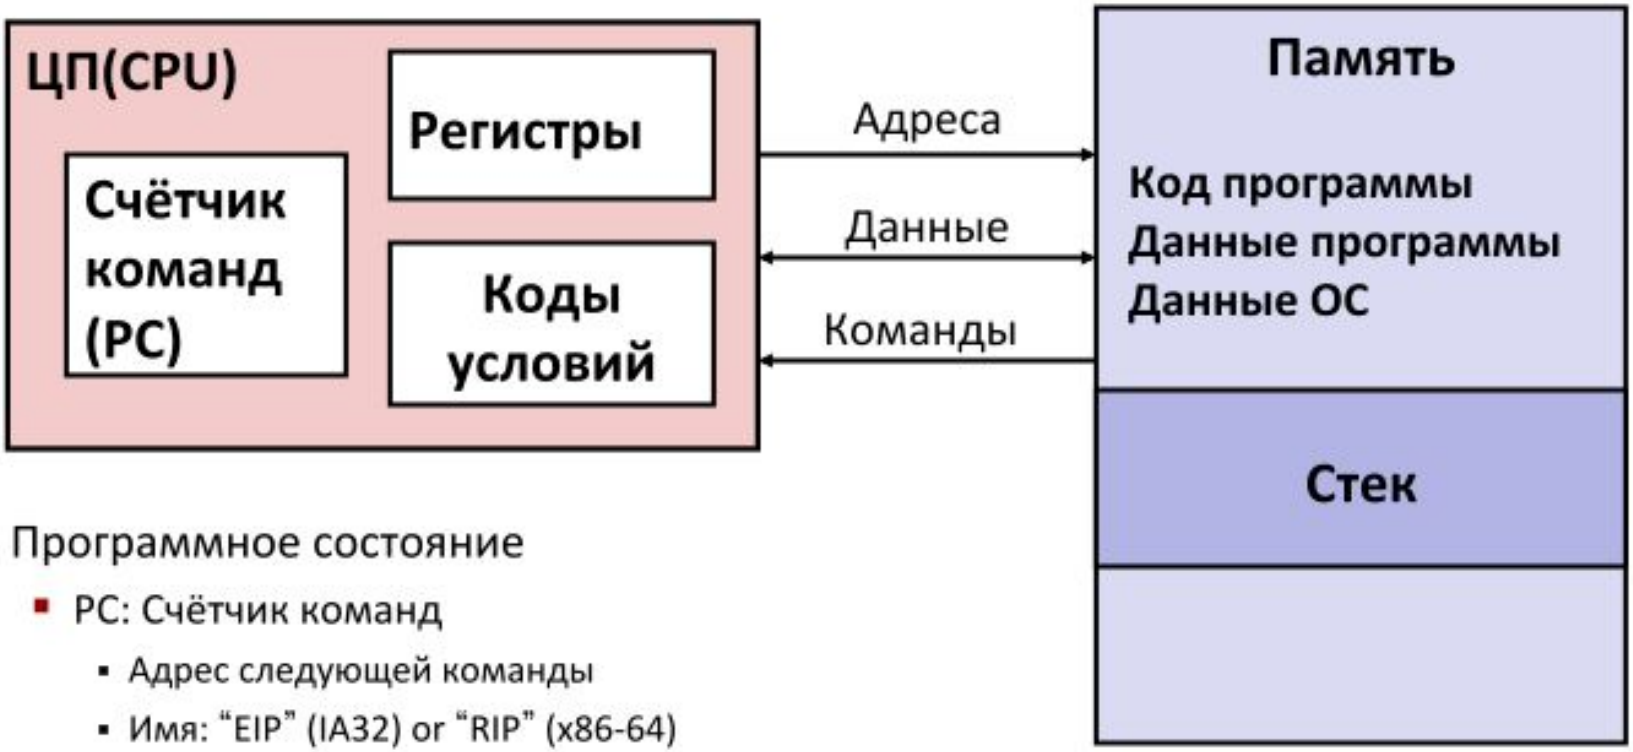

- Программное состояние
  - PC: Счётчик команд
    - Адрес следующей команды
    - Имя: “EIP” (IA32) or “RIP” (x86-64)
  - Набор регистров
    - Наиболее используемые данные
  - Коды условий
    - Хранят информацию о состоянии самой последней арифм. команды
    - Используются для условных переходов

- **Память**
  - Массив адресованных байт
  - Код, данные пользователя, (некоторые) данные ОС
  - Включая стек для поддержки процедур

Форматы команд

Операционная часть	Адресная часть

- **Длина команды**

  Для ускорения выборки из памяти желательно, чтобы команда была как можно короче, а ее длина была равна или кратна ширине шины данных

- **Количество адресов в команде**

  Четырехадресные, трехадресные, двухадресные, одноадресных, нульадресные

- **Разрядность полей команды**
- **Способы адресации**

Трансляция Си кода в объектный

- Код в файлах `p1.c p2.c`
- Компилируем командой: `gcc –O1 p1.c p2.c -o p`
  - Используем минимальную оптимизацию (`–O1`)
  - Помещаем результирующий двоичный код в файл `p`

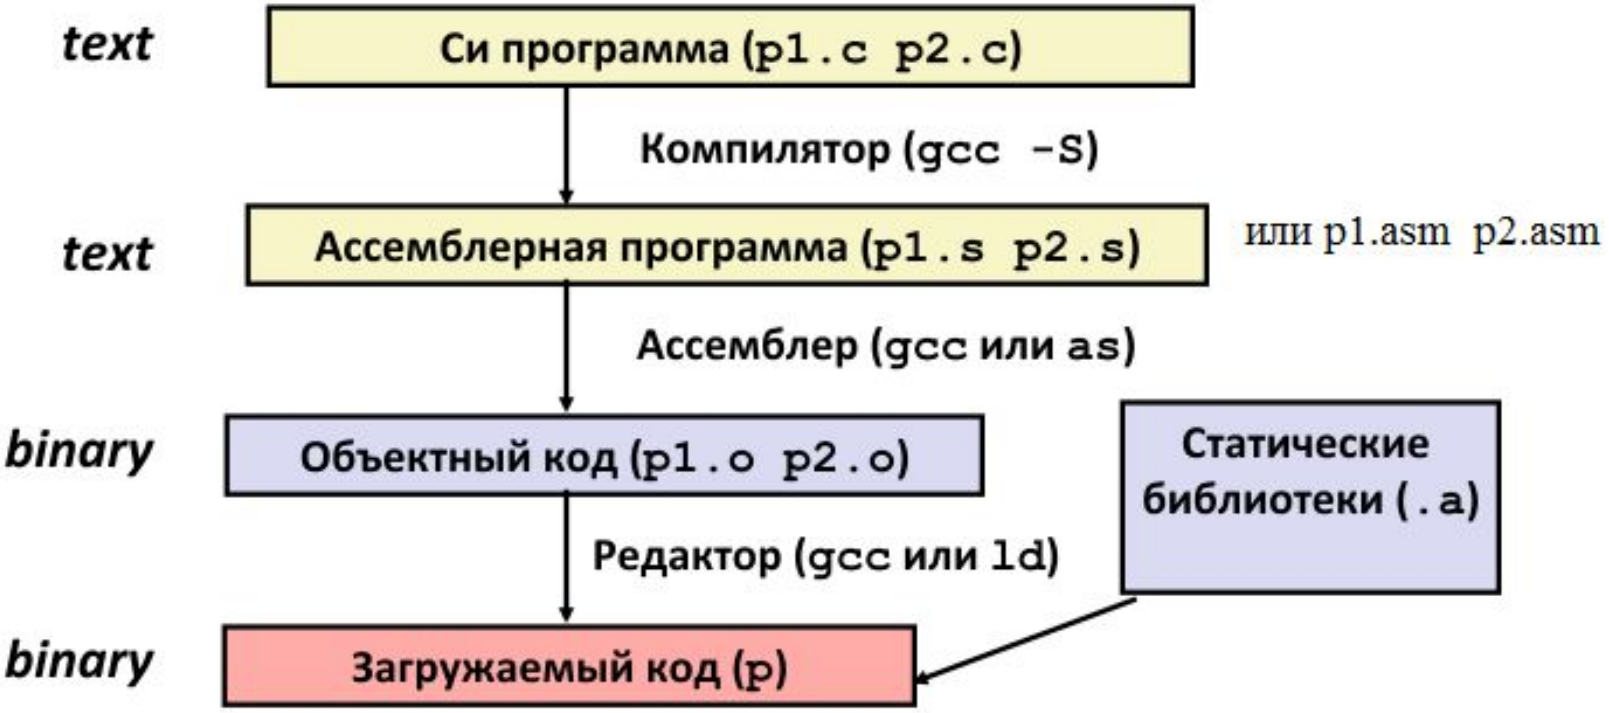

Компиляция в ассемблер

Си - код

```
int sum(int x, int y)
{
  int t = x+y;
  return t;
}
```

Сгенерированный код ассемблера IA32

```
sum:
    pushl %ebp
    movl %esp,%ebp
    movl 12(%ebp),%eax
    addl 8(%ebp),%eax
    popl %ebp
    ret
```

Некоторые компиляторы используют команду "leave"

Получается командой

```
/usr/local/bin/gcc -O1 -S code.c
```

Создаёт файл code.s

```
sum proc    near
      push    bp
      mov     bp,sp
      mov     ax, word ptr [bp+4]
      add     ax, word ptr [bp+6]
      pop     bp
      ret
```

Типы данных ассемблера

- “Целые” 1-, 2-, или 4- байтные данные
  - Значения данных
  - Адреса (нетипизованные, байтные указатели)
- 4-, 8-, или 10- байтные данные с плавающей точкой
- Никаких сложных типов как массивы или структуры
  - Просто байты расположенные в памяти рядом

Операции ассемблера

- Выполняют арифметические операции с данными в регистрах или в памяти
- Передают данные между памятью и регистрами
  - Загружают данные из памяти в регистры
  - Выгружают данные из регистров в память
- Передача управления
  - Безусловные переходы
  - Условные переходы
  - Вызов процедур и возврат из них

Объектный код

Код `sum`

```
0x401040 <sum>:
    0x55
    0x89
    0xe5
    0x8b
    0x45
    0x0c
    0x03
    0x45
    0x08
    0x5d
    0xc3
```

- **Всего 11 байт**
- **Каждая команда 1, 2, or 3 bytes**
- **Старт по адресу `0x401040`**

- Ассемблер
  - Транслирует `.s` into `.o`
  - Кодирует команды двоичным кодом
  - Почти готовый к загрузке год
  - Межфайловых связей кода
- Редактор (связей)
  - Выполняет ссылки между файлами
  - Компонует со статическими библиотеками
    - Например, код для **`malloc`**, **`printf`**
  - Некоторые библиотеки *связываются динамически*
    - Связывание происходит при исполнении

Форматы команд

Операционная часть	Адресная часть

- **Длина команды**

  Для ускорения выборки из памяти желательно, чтобы команда была как можно короче, а ее длина была равна или кратна ширине шины данных

- **Количество адресов в команде**

  Четырехадресные, трехадресные, двухадресные, одноадресных, нульадресные

- **Разрядность полей команды**
- **Способы адресации**

Пример машинных команд

```
int t = x+y;
```

```
addl 8(%ebp),%eax
```

Аналогично выражению:

```
x += y
```

Более точно:

```
int eax;
int *ebp;
eax += ebp[2]
```

```
0x80483ca:  03 45 08
```

- Си код
  - Сложить два знаковых
- Ассемблер
  - Сложить 2 4-байтных целых
    - "Long" слова в манере GCC
    - те-же команды и для signed и для unsigned
  - Операнды:
    - **x:** Регистр **%eax**
    - **y:** Память **M[%ebp+8]**
    - **t:** Регистр **%eax**
      - Возвращает в **%eax**
- Объектный код
  - 3-байтные команды
  - по адресу **0x80483ca**

Дизассемблирование объектного кода

Дизассемлированный код

```
080483c4 <sum>:
 80483c4:   55          push   %ebp
 80483c5:   89 e5       mov    %esp,%ebp
 80483c7:   8b 45 0c    mov    0xc(%ebp),%eax
 80483ca:   03 45 08    add    0x8(%ebp),%eax
 80483cd:   5d          pop    %ebp
 80483ce:   c3          ret
```

- Дизассемблер

  `objdump -d p`

  - Полезный инструмент для анализа объектного кода
  - Анализирует битовые последовательности наборов команд
  - Приблизительно восоздаёт ассемблерный код
  - Может обрабатывать файлы `a.out` (загрузочные) или `.o`

Вариант дизассемблирования

Объектный код

```
0x401040:
    0x55
    0x89
    0xe5
    0x8b
    0x45
    0x0c
    0x03
    0x45
    0x08
    0x5d
    0xc3
```

Дизассемблированный код

```
Dump of assembler code for function sum:
0x080483c4 <sum+0>:     push   %ebp
0x080483c5 <sum+1>:     mov    %esp,%ebp
0x080483c7 <sum+3>:     mov    0xc(%ebp),%eax
0x080483ca <sum+6>:     add    0x8(%ebp),%eax
0x080483cd <sum+9>:     pop    %ebp
0x080483ce <sum+10>:    ret
```

- С отладчиком gdb

  gdb p

  disassemble sum

  - Дизассемблируемая процедура

  x/11xb sum

  - Просмотреть 11 байт начиная с `sum`

Что удастся дизассемблировать?

- Всё, что имеет смысл исполняемых команд
- Дизассемблер только принимает предложенные байты и воспроизводит их как ассемблерный код

```
1   int simple(int *xp, int y)
2   {
3       int t = *xp + y;
4       *xp = t;
5       return t;
6   }
```

```
  .file       "simple.c"
  .version    "01.01"
gcc2_compiled.:
.text
  .align 4
.globl simple
   .type simple,@function
simple:
   pushl    %ebp
   movl     %esp,%ebp
   movl     8(%ebp),%eax
   movl     (%eax),%edx
   addl     12(%ebp),%edx
   movl     %edx,(%eax)
   movl     %edx,%eax
   movl     %ebp,%esp
   popl     %ebp
   ret
.Lfe1:
```

```
1   int simple(int *xp, int y)
2   {
3       int t = *xp + y;
4       *xp = t;
5       return t;
6   }
```

```
1   simple:
2       pushl   %ebp            Сохранить указатель фрейма
3       movl    %esp,%ebp       Установить новый указатель фрейма
4       movl    8(%ebp),%eax    Взять xp
5       movl    (%eax),%edx     Извлечь *xp
6       addl    12(%ebp),%edx   Прибавить y, чтобы получить t
7       movl    %edx,(%eax)     Сохранить t по адресу *xp
8       movl    %edx,%eax       Установить t как возвращаемое значение
9       movl    %ebp,%esp       Переустановить указатель стека
10      popl    %ebp            Переустановить указатель фрейма
11      ret                     Возврат результата
```

```
1   int simple(int *xp, int y)
2   {
3       int t = *xp + y;
4       *xp = t;
5       return t;
6   }
```

```
mov     bp,sp   ;установить новый указатель
ечь  адрес xp
ечь значение по адресу - *xp
ибавить y, чтобы получить t
сохранить t по адресу xp
ак возвращаемое значение
едыдущее значение указателя
```

```
simple   proc      near
     push      bp      ;сохранить предыдущее значение указателя
     mov       bp,sp   ;установить новый указатель
     mov       si, word ptr [bp] ; извлечь  адрес xp
     mov       dx, word ptr [si] ; извлечь значение по адресу - *xp
     add       dx, word ptr [bp+6]  ;прибавить y, чтобы получить t
          mov       word ptr [si], dx   ;сохранить t по адресу xp
     mov       ax, dx   ;установить t как возвращаемое значение
     pop       bp   ; восстановить предыдущее значение указателя
     ret        ; возврат
```