Введение в язык программирования C.

Лекция 5

Массивы. Указатели. Динамическая память.

Сергей Леонидович Бабичев

Указатели и массивы

- Настало время подробнее понять, что происходит, когда мы пишем, например, `int a[100];`.
- Мы называли такие массивы *простыми*.
- Под него выделяется память на момент его создания.
- Оказывается, имя массива (в данном случае a) не что иное, как указатель на выделенную системой память.
- Так a — массив или указатель?
- Если a — указатель, то как с ним работать?
- Что у нас имеется кроме операции * для обращения к той памяти, на которую указатель показывает?
- В обращении к элементам массива нам помогает *адресная арифметика*.

Адресная арифметика

- Пусть начальным адресом нашего массива a будет 10000.
- Тогда обращение `*a` разрешено и это будет нулевым элементом массива.
- К нулевому элементу массива можно обратиться и как `a[0]`.
- Давайте запишем первое выражение немного по-другому: `*(a+0)`. Тогда `a[0]` есть синоним к `*(a+0)`.
- Память под массивы гарантированно выделяется *непрерывным куском*, поэтому элемент под номером 1, `a[1]` будет находиться по адресу 10004, если размер одного элемента типа `int` равен четырём.
- `a[1]` есть синоним к `*(a+1)`, `a[i]` — для `*(a+i)`.
- Арифметика становится не совсем обычной: к указателю, равному 10000 прибавили единицу и он стал равен 10004.
- Для всех ли типов данных подобное верно?
- Для всех с одной поправкой: степень увеличения адреса зависит от размера элемента массива.

Адресная арифметика

Указатели допускают следующие операции:

- сложение указателя с целым `ptr + i`. Результат показывает на элемент того же типа, отстоящий на `i` элементов дальше `ptr`;
- вычитание из указателя целого `ptr - i`. Результат показывает на элемент того же типа, находящийся за `i` элементов перед `ptr`;
- вычитание указателей одного типа `ptr2 - ptr1`. Результат — количество элементов этого типа между адресами.

Массивы и функции

- Можно ли передавать массивы в функции?
- Да, конечно!
- Для совсем наивных можно описывать аргументы функций как массивы:

```
int sum_elems(int array[100]) {
   int i, sum = 0;
   for (i = 0; i < 100; i++) {
      sum += array[i];
   }
   return sum;
}
```

Массивы и функции

- Почему «для наивных»?
- Потому, что в Си массив как целое передать в функцию невозможно.
- Имя массива — просто указатель на нечто, который нельзя изменить.
- Пока мы в области определения простого массива, видимости точки его создания, компилятор знает его размер.
- После того, как массив, точнее, указатель на него, переданы в функцию, никто внутри функции не способен определить его размер.

```c
#include <stdio.h>

void bar(int b[100]) {
   int sizebar = sizeof b / sizeof b[0];
   printf("sizebar = %d\n", sizebar);
}

void func() {
   int arr[100];
   int sizearr = sizeof arr / sizeof arr[0];
   printf("sizearr = %d\n", sizearr);
   bar(arr);
}

int main() {
   func();
}
```

```
sizearr = 100
sizebar = 2
```

Массивы и функции

- В функцию передан указатель на массив, размер указателя здесь 8 байт, размер типа `int` здесь четырём байтам, отсюда `sizebar = 2`.
- Обман? Зачем всё это?
- Чтобы не отпугнуть тех, кто хотел мигрировать с FORTRAN на Си.
- Функция не может отличить указатель на отдельную переменную от указателя на кусок памяти (массив).
- Число в квадратных скобках, которое, вроде бы, должно показать нам количество элементов массива, для одномерных массивов игнорируется.
- Следующие три объявления функции эквивалентны:

```
int add_elems(int arr[10000000]);
int add_elems(int arr[]);
int add_elems(int *arr);
```

Массивы и функции

- Теперь у нас есть универсальная функция, которая готова вычислить сумму элементов любого целочисленного массива любой длины.
- Нужно только, чтобы она знала количество элементов.
- В классическом `Pascal` такую функцию написать было невозможно.
- Математикам такие функции позарез необходимы, для линейной алгебры, для векторов и матриц.

Массивы и функции

- Наша функция `add_elems` пока не знает количество элементов массива для суммирования.
- Нужно добавить в неё ещё один аргумент.
- Обычно в Си его добавляют после имени массива.
- А какой у этого аргумента тип?
- Это тот тип, который может содержать любые размеры для массивов.
- Это не `int`, появилось бы ограничение на размеры массивов.
- В современных компьютерах памяти много и массив может содержать триллионы элементов.
- Для размеров массивов и индексов лучше применять тип `size_t`.
- Он описан в файле `<stddef.h>`, или `<stdlib.h>` или `<stdio.h>`
- Рядом имеется тип `ptrdiff_t`, который может иметь знак, в отличие от `size_t`.

```c
#include <stdio.h>
#include <stdlib.h>

void add_elems(int *b, size_t n) {
    int sum = 0;
    for (size_t i = 0; i < n; i++) {
        sum += b[i];
    }
    return sum;
}

int main() {
    int arr[] = {3, 1, 4, 1, 5, 9, 2, 6};
    int sum_arr = add_elems(arr, sizeof arr / sizeof arr[0]);
}
```

Инициализация простых массивов

Простой массив можно объявить с его инициализацией. Его размер будет известен при компиляции по количеству инициализаторов.

```
int x[] = {1,2,3,4,5,6,7,8,9,10}; // OK
int y[10] = {1,2,3,4,5,6,7,8,9,10}; // OK
int z[20] = {1}; // OK, z[1..19] = 0
int t[5] = {1, 2, 3, 4, 5, 6, 7, 8, 9, 10}; // Error.
```

```c
#include <stdio.h>
int sum_matrix(int m[3][3]) {
  int sum = 0;
  for (size_t i = 0; i < 3; i++) {
    for (size_t j = 0; j < 3; j++) {
      sum += m[i][j];
    }
  }
  printf("sizeof m=%zu\n", sizeof m);
  return sum;
}
int main() {
  int matrix[3][3];
  for (size_t i = 0; i < 3; i++) {
    for (size_t j = 0; j < 3; j++) {
      scanf("%d", &matrix[i][j]);
    }
  }
  int s = sum_matrix(matrix);
  printf("sizeof matrix=%zu sum=%d\n", sizeof matrix, s);
}
```

Простые двумерные массивы

- Размер `m` в `sum_matrix` равен 8, а `matrix` в `main` равен 36.
- Таким образом, `m` — указатель.
- Но попытка передать его явным образом

  ```
  int sum_matrix(int *m) { ...
  ```

  даст ошибку: что тогда означает `m[i][j]`, если `m[i]` — `int`?
- Приходится сохранять *двумерность* синтаксически.
- Можно писать так:

  ```
  int sum_matrix(int m[][3]) { ...
  ```
- Это читается так: мы будем использовать двойную индексацию и строка состоит из трёх элементов.

Простые двумерные массивы

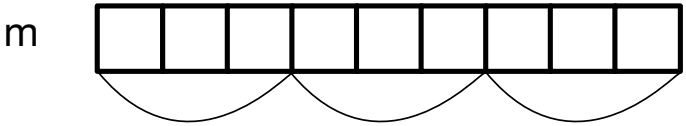

- Теперь компилятор знает, как получить доступ к нужному элементу.
- Это позволяет вычислять адрес любого из элементов массива `m[i][j]` по формуле `m+i*3+j`. Фактически компилятор превращает нашу функцию в

```
int sum_matrix(int *m) {
    int sum = 0;
    for (size_t i = 0; i < 3; i++) {
        for (size_t j = 0; j < 3; j++) {
            sum += m[i*3+j];
        }
    }
    return sum;
}
```

Простые многомерные массивы

Простые многомерные массивы хранятся в Си в *линеаризованном виде*, строка за строкой. В функцию передаётся адрес занятой памяти. Разрешается (только в аргументах функции!) оставить пустые `[]` для самого левого измерения массива, например, вместо `double x[5][5][5]` писать `double x[][5][5]`. Заметьте, что принимаемые в функции двумерные и многомерные массивы должны содержать *константные выражения* в каждой из квадратных скобок.

Куча

- Пока мы знаем массивы с временем жизни, равным времени жизни всей программы (статические и глобальные), или время жизни, равное времени жизни блока, а котором они описаны (автоматические или стековые).
- Можно создавать и такие объекты, которые не существуют при входе в функцию и сохраняются при выходе из неё.
- Это не статические массивы — они существую и *до* входа в функцию.
- Это не автоматические массивы тоже на подходят — они уничтожаются *после* выхода из функции.
- Это — *динамические* массивы, которые создаются в области памяти под названием *куча* или по английски *heap*.

Куча. Тип `void *`

- Запрос памяти из кучи ещё называют «заказ памяти»).
- Функция должна где-то выделить нужное место и вернуть на него указатель.
- Специальный тип указателя, который может хранить любой адрес — `void *`.
- `int *` может оказаться или адресом отдельной переменной, или массивом типа `int`, адрес чего даёт указатель `void *`?
- Массивов и переменных такого типа не бывает. Нельзя написать:

```
int f(void *arg) {
   return arg[0];
}
```

Ценность этого указателя в том, что указатель такого типа можно присвоить указателю нужного типа — и далее работать с тем, как обычно.

```
int f(void *arg) {
  int *a = arg;
  return a;
}
```

Функции, выделяющие память

- Прототипы таких функций находятся в <stdlib.h>.
- Самая простая функция — malloc.
- Один аргумент — количество запрашиваемых байтов.
- Возвращаемое значение — указатель на выделенную память.
- При неуспехе вернётся NULL.

```
int *a = (int *)malloc(n * sizeof(int));
```

- Теперь указатель a хранит адрес места, где можно разместить n переменных типа int, что соответствует массиву из n элементов int.

Выделение памяти — ответственность

- Тот, кто получил этот указатель, несёт ответственность за жизнь этого указателя — этот указатель — единственный способ обратиться к памяти из кучи.
- Потеряем указатель — потеряем эту память.
- Возникнет ситуация, известная, как *утечка памяти* или *memory leak*.
- Она крайне неприятна и в ряде случаев приводит к ситуациям, когда программа становится неработоспособной.
- Потерять память — проще простого:

```
int foo(int n) {
   int *bar = (int *)malloc(n * sizeof (int));
   return 0;
}
```

- Переменная `bar`, содержащая адрес свежевыделенного системой куска памяти, после достижения закрывающей фигурной скобки исчезает.
- Вся выделенная память внезапно становится недоступной. Она как бы есть, но её как бы и нет.

Выделение памяти и её освобождение

- Освободить память, то есть вернуть её в систему, можно функцией `free`.

```
int foo(int n) {
    int *bar = (int *)malloc(n * sizeof (int));
    // ....
    free(bar);
    return 0;
}
```

В корректных программах каждый заказ памяти по `malloc/calloc/realloc` должен иметь парный вызов `free`.

Другие способы выделения памяти

- Память, выделенная `malloc`, неинициализирована. Чтобы получить инициализированный нулями кусок памяти, используйте `calloc`. Он требует два аргумента: количество заказываемых элементов и размер единичного элемента: `int *s = (int *)calloc(n, sizeof(int));`
- Количество заказанной памяти можно изменить функцией `realloc`.

```
    int *bar = (int *)malloc(n * sizeof (int));
    // ....
    bar = realloc(bar, 2*n*sizeof(int));
    return 0;
}
```

- Мы расширили массив в два раза, скопировав старые элементы.

Куча: двумерные массивы

- Все `alloc` функции возвращают адрес куска памяти.
- Но массивы бывают и многомерными.
- Как работать с многомерными массивами?
- Мы знаем, что простые двумерные массивы (`m[3][3]`) в функцию передаются *линеаризованными*.
- Передаётся указатель на область непрерывной памяти, в которой помещается 9 элементов.
- Повторим такой же путь создания.
- Будем работать с двумерным массивом с `n` строками, в каждой из которых по `m` элементов, или, другими словами, с матрицей $n \times m$.

Куча: двумерные массивы

- Закажем память один раз сразу под все элементы матрицы:

```
double *matr = (double *)calloc(n*m, sizeof(double));
```

- Вызовом `calloc` мы обеспечили, что все элементы матрицы стали нулевыми.
- Теперь мы *обязаны* помнить про этот указатель всё: сколько в матрице, которая представлена этим указателем, строк и сколько столбцов.
- В другую функцию нужно будет передавать всё, что мы о ней знаем.
- Получим сумму элементов k-го столбца матрицы:

```
double column_sum(double *matr, size_t n, size_t m, size_t k) {
  double sum = 0.;
  for (size_t i = 0; i < m; i++) {
    sum += matr[i*m+k];
  }
  return sum;
}
```

- Доступ к элементу матрицы $matr[i, j]$, обязан иметь вид `matr[i*m+j]`.
- Если это неудобно, можно использовать другой метод хранения.

Указатели указателей: разреженное представление матриц

- Указатели могут показывать на произвольные объекты.
- Указатели могут показывать на другие указатели.
- Для строк матрицы создадим много одномерных массивов.
- Каждый массив будет представлен указателем.
- Все такие указатели свяжем в массив указателей.

```
double **matr = (double **)calloc(n, sizeof(double *));
for (size_t i = 0; i < n; i++) {
  matr[i] = (double *)calloc(m, sizeof(double));
}
```

Указатели указателей: разреженное представление матриц

- Как это выглядит в памяти для матрицы m 3×3:

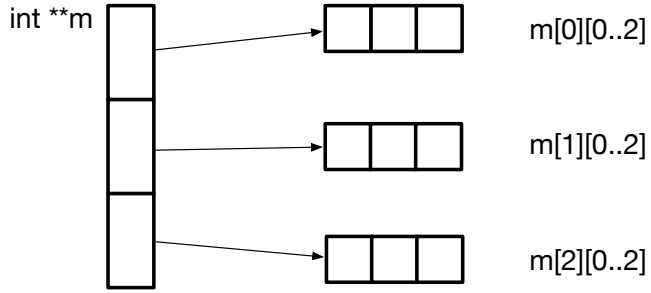

- Что стало удобнее?

```
double column_sum(double **matr, size_t n, size_t m, size_t) {
  double sum = 0.;
  for (size_t i = 0; i < m; i++) {
    sum += matr[i][k];
  }
  return sum;
}
```

Указатели указателей: разреженное представление матриц

- Операция `matr[i][k]` расшифровывается так: сначала операция `matr[i]` даёт нам какой-то указатель, который мы трактуем как массив, так как знаем, что он показывает на память, достаточную для хранения `m` элементов типа double.
- Ну а раз это массив, индексируем его и получаем результат.

Указатели указателей: разреженное представление матриц

- Что удобнее, линеаризованное или разреженное представление?
- Это зависит и от того, кто реализует набор функций под конкретную задачу, и от особенностей самой задачи.
- В первом приближении они равнозначны.

> Не забывайте освобождать память после того, как поработали с матрицей и подобными объектами, возникшими на этапе исполнения программы.

- Освобождаем память для разреженного представления.

```
for (int i = 0; i < n; i++) {
  free(matr[i]);
}
free(matr);
```

- Попытка освободить сначала `matr`, а потом `matr[i]` приведёт к катастрофе.

Строки

Строки

- *Строки* — единственный составной тип данных в Си, имеющий собственные литералы.
- Литерал *строка* формирует непрерывную область памяти, заполненную значениями символов, адресуемую указателем `const char *`.
- Во многих языках строка — отдельный тип данных.
- В Си любой указатель на `char` может оказаться строкой.

> Любая последовательность символов типа `char`, заканчивающаяся символом с кодом 0, то есть содержащим все нулевые биты, может рассматриваться как носитель текстовой информации — строку.

- Строки в Си — данные чрезвычайно низкого уровня.
- Все операции над строками производятся исключительно с указателями.
- Низкий уровень строк служит основой довольно высокой эффективности алгоритмов работы с ними.
- Однако, работать со строками трудно и легко совершать ошибку.

Строки

- Так как строка — просто указатель на начало данных, нет простого способа определить количество символов в ней — нахождение длины строки.
- В стандартной библиотеке языка Си имеется заголовочный файл, посвящённый операциям над строками <string.h>.
- Рассмотрим некоторые операции из него на примерах.

```
int main() {
   const char *s1 = "Hello";
}
```

- В памяти выделено место под 6 символов — 'H', 'e', 'l', 'l', 'o', 0.
- Создан указатель, который просто содержит адрес данного места.
- Это просто указатель, и он может быть *переставлен* на другой адрес в памяти.
- Этот указатель нельзя отдать в `free` для освобождения памяти.

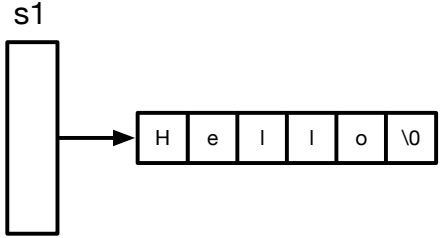

Некоторые из функций, имеющихся в файле string.h

```
// Заказать память для хранения нужного количества
// символов и скопировать туда источник
char *s = strdup("Hello"); // Не забудьте сделать free после использования!
size_t len = strlen(s); //  Длина строки.  Сейчас 5.
char *t = malloc(1000); // Скоро там появится строка.
strcpy(t,s); // Скопировать "Hello" в первые 5 байтов t и добавить к концу \0
strcat(t, " "); // Теперь в t лежит "Hello "
strcat(t, "world!"); // "Hello world!"
strncat(t, " very long string", 1000);  // 1000 --- максимальная длина приёмника
char q[10];
strncpy(q,"Try to copy very-long-string", 10);
// Будет скопировано первые 10 символов.
// Но нулевого байта может не оказаться!!!
size_t len = strlen(q); // Что угодно >= 10! Осторожно!
char p[10];
strcpy(p,"Try to copy very-long-string"); //  Катастрофа!!!
```

Некоторые из функций, имеющихся в файле string.h

- Функция strcmp — одна из полезнейших.

  ```
  int strcmp(const char *src, const char *dst);
  ```

- Строки, которые подаются как аргументы, могут быть произвольной длины.
- Функция может выдать ответ исключительно быстро.
- Упорядочиваются функции *лексикографически*.
- Алгоритм сравнения строк прост: символы двух строк сравниваются попарно до тех пор, пока они совпадают.
- После чего возвращается разность кодов несовпавших символов.
- Сравнении "cadabra" и "cadence" функция вернёт -4.
- Строки могут совпасть тогда и только тогда, когда они имеют одинаковую длину и одинаковое содержимое.
- Тогда функция (внимательно!) возвратит ноль.
- Если первая строка больше второй, то результатом будет что-то положительное.

Функция `strcmp` сравнения двух строк возвращает значение 0, если строки равны. Поэтому типичный код такой:

```
if (strcmp(op, "div") == 0) ...
```

Функция `strlen`, возвращающая длину строки-аргумента.

Функция `strlen(const char *s)` возвращает длину строки без завершающего нулевого байта, то есть `strlen("Hello")` = 5.

Время исполнения функции `strlen` исполнения прямо пропорционально длине строки.

Пишем функции работы со строками самостоятельно

- Попробуем написать аналог функции `strlen`.
- Алгоритм прост: мы бежим по строке до тех пор, пока не встретим нулевой байт.

```
size_t mystrlen(const char *s) {
    size_t i = 0;
    while (s[i] != 0) {
        i++;
    }
    return i;
}
```

Пишем копирование строк

- Примитивно, но работает: сначала находим длину строки, которую копируем и в цикле производим копирование.

```
void mystrcpy(char *d, const char *s) {
   size_t len = mystrlen(s);
   for (size_t i = 0; i <= len; i++) {
      d[i] = s[i];
   }
}
```

- Сначала мы скопировали `len` символов самой строки, а затем поместили нулевой байт для её завершения.

Внимание! При копировании строк в обязаны быть уверенным, что указатель `char *d` указывает на кусок реальной памяти не менее `len + 1` байтов длиной. Её можно получить, например, вызовом `calloc`/`malloc` или объявлением вида `char dest[100];`

Пишем копирование строк

- Наша функция неэффективна.
- Для получения длины строки s мы пробежали до её конца и при копировании бежим по ней ещё раз.
- Давайте воспользуемся циклом с завершением по нулевому байту.

```
void mystrcpy(char *d, const char *s) {
   size_t i = 0;
   while (s[i] != 0) {
      d[i] = s[i];
      i++;
   }
   d[i] = 0;
}
```

Пишем копирование строк

- Сложность функции уменьшилась.
- Давайте ещё попробуем улучшить код.
- Возможное место улучшения — цикл.
- В цикле мы производим две операции — сравнения очередного символа правой строки с нулём, и если он не равен нулю, копируем.
- Можно попробовать записать по-другому.

```
void mystrcpy(char *d, const char *s) {
   size_t i = 0;
   while ((d[i] = s[i]) != 0) {
      i++;
   }
}
```

Пишем копирование строк

Самая изящная реализация функции `mystrcpy`:

```
void mystrcpy(char *d, const char *s) {
   while (*d++ = *s++)
      ;
}
```

Попробуйте в ней разобраться и убедиться в том, что всё работает корректно.

Несколько советов при работе со строками

Работа со строками требует большой аккуратности. Основные проблемы, которые возникают в безопасности программ — переполнение места, предназначенного для хранения строки и запись в постороннюю память. Это может быть из-за отсутствия нулевого байта в нужном месте.

Не рекомендуется дублировать системные функции работы со строками. Проблема не в том, что вы не правильно это сделаете, а в том, что современные компиляторы знают, что эта функция используется очень часто и *генерируют* код, который работает быстрее, чем то, что мы написали.