

Задание 2

Бинарные деревья поиска и хеш-таблицы

Постановка задачи

Требуется реализовать на языке C две библиотеки для работы с бинарным деревом поиска (Binary search tree) и хеш-таблицей (Hash table). Ключом в обоих случаях является строка (char []), а значением целое число (int).

Функции для работы с бинарным деревом поиска должны быть помещены в файлы bstree.c (реализация функций) и bstree.h (объявление функций). В файлах необходимо реализовать следующие функции:

- struct bstree *bstree_create(char *key, int value)
- void bstree_add(struct bstree *tree, char *key, int value)
- struct bstree *bstree_lookup(struct bstree *tree, char *key)
- struct bstree *bstree_min(struct bstree *tree)
- struct bstree *bstree_max(struct bstree *tree)

Функции для работы с хеш-таблицей должны быть помещены в файлы hashtable.c (реализация функций) и hashtable.h (объявление функций). В файлах необходимо реализовать следующие функции:

- unsigned int hashtable_hash(char *key) /* Реализация из лекции 6 */
- void hashtable_init(struct listnode **hashtab)
- void hashtable_add(struct listnode **hashtab, char *key, int value)
- struct listnode *hashtable_lookup(struct listnode **hashtab, char *key)
- void hashtable_delete(struct listnode **hashtab, char *key)

Цель работы — провести экспериментальное исследование эффективности бинарных деревьев поиска и хеш-таблиц.

В отчет следует включить:

- общее описание бинарных деревьев поиска и хеш-таблиц (основные операции и их вычислительные сложности)
- таблицы и графики с результатами экспериментов и выводы по каждому эксперименту

Распределение заданий по вариантам

Вариант (см. на сайте)	1	2	3
1	Эксперимент 1	Эксперимент 2	Эксперимент 6 - хеш-функции KP, Add
2	Эксперимент 1	Эксперимент 3	Эксперимент 6 - хеш-функции KP, XOR
3	Эксперимент 1	Эксперимент 4	Эксперимент 6 - хеш-функции KP, FNV
4	Эксперимент 1	Эксперимент 5	Эксперимент 6 - хеш-функции KP, Jenkins
5	Эксперимент 1	Эксперимент 2	Эксперимент 6 - хеш-функции KP, ELF
6	Эксперимент 1	Эксперимент 3	Эксперимент 6 - хеш-функции KP, DJB
7	Эксперимент 1	Эксперимент 4	Эксперимент 6 - хеш-функции KP, DJB
8	Эксперимент 1	Эксперимент 5	Эксперимент 6 - хеш-функции KP, ELF
9	Эксперимент 1	Эксперимент 2	Эксперимент 6 - хеш-функции KP, Jenkins
10	Эксперимент 1	Эксперимент 3	Эксперимент 6 - хеш-функции KP, FNV
11	Эксперимент 1	Эксперимент 4	Эксперимент 6 - хеш-функции KP, XOR
12	Эксперимент 1	Эксперимент 5	Эксперимент 6 - хеш-функции KP, Add
13	Эксперимент 1	Эксперимент 2	Эксперимент 6 - хеш-функции KP, Jenkins
14	Эксперимент 1	Эксперимент 3	Эксперимент 6 - хеш-функции KP, ELF
15	Эксперимент 1	Эксперимент 4	Эксперимент 6 - хеш-функции KP, FNV
16	Эксперимент 1	Эксперимент 5	Эксперимент 6 - хеш-функции KP, XOR
17	Эксперимент 1	Эксперимент 2	Эксперимент 6 - хеш-функции KP, DJB

Экспериментальное исследование**Эксперимент 1 Сравнение эффективности поиска элементов в бинарном дереве поиска и хеш-таблице в среднем случае (average case)**

Требуется заполнить таблицу 1 и построить графики зависимости времени t выполнения операции поиска (lookup) элемента в бинарном дереве поиска и хеш-таблице от числа n элементов уже вставленных в словарь.

В качестве ключей использовать слова из романа Л.Н. Толстого «Война и Мир» (можно использовать любой текстовый файл с большим числом слов). Файл включен в архив.

В качестве искомого ключа следует выбрать случайное слово, которое уже было добавлено в словарь.

Таблица 1

#	Количество элементов в словаре	Время выполнения функции <code>bstree_lookup</code> , с	Время выполнения функции <code>hashtab_lookup</code> , с
1	10 000		
2	20 000		
3	30 000		
...			
20	200 000		

Пример оформления графиков приведен на рис. 1 (в архив включен пример Excel-файла для построения графиков такого вида).




Рис. 1. Зависимость времени t поиска элемента в словаре от числа n ключей уже вставленных в него

Ниже приведен псевдокод одного из вариантов реализации замеров времени операции поиска ключей в бинарном дереве с n элементами.

```
// Можно загрузить слова из файла в массив words[] или связный список
tree = bstree_create(words[0], 0); // Создаем корень дерева
for (i = 2; i <= 200000; i++) do
  tree = bstree_add(word[i - 1], i - 1)
  if i % 10000 == 0 then
    w = word[getRand(0, i - 1)] // Выбрать случайное слово
    t = wtime()
    node = bstree_lookup(tree, w)
    t = wtime() - t
    print(«n = %d; time = %.6f», i - 1, t)
  end if
end for
```

Эксперимент 2 Сравнение эффективности добавления элементов в бинарное дерево поиска и хеш-таблицу

Требуется заполнить таблицу 2 и построить графики зависимости времени t выполнения операции добавления (add) элемента в бинарное дерево поиска и хеш-таблицу от числа n элементов уже вставленных в словарь.

Пример оформления графиков приведен на рис. 2 (в архив включен пример Excel-файла для построения графиков такого вида).

Таблица 2

#	Количество элементов в словаре	Время выполнения функции bstree_add, с	Время выполнения функции hashtable_add, с
1	10 000		
2	20 000		
3	30 000		
...			
20	200 000		

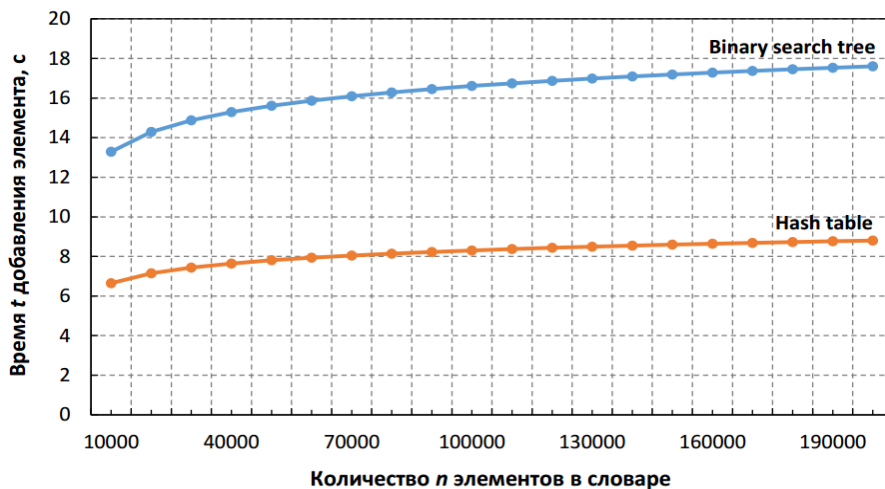


Рис. 2. Зависимость времени t добавления элемента в словарь от числа n ключей уже вставленных в него

Эксперимент 3 Сравнение эффективности поиска элементов в бинарном дереве поиска и хеш-таблице в худшем случае (worst case)

Требуется заполнить таблицу 3 и построить графики зависимости времени t выполнения операции поиска (lookup) элемента в бинарном дереве поиска и хеш-таблице от числа n элементов уже вставленных в словарь.

Добавляем в словарь n слов - от меньших к большим (например, слова «aaaaa», «bbbbbb», ...).

В качестве искомого ключа следует выбрать слово, которое вставлено последним.

Таблица 3

#	Количество элементов в словаре	Время выполнения функции <code>bstree_lookup</code> , с	Время выполнения функции <code>hashtab_lookup</code> , с
1	10 000		
2	20 000		
3	30 000		
...			
20	200 000		

Эксперимент 4 Исследование эффективности поиска минимального элемента в бинарном дереве поиска в худшем и среднем случаях

Требуется заполнить таблицу 4 и построить графики зависимости времени t выполнения операции поиска минимального элемента в бинарном дереве поиска в худшем и среднем случаях.

Анализ поведения в худшем случае: добавляем в словарь n слов - от больших к меньшим (например, слова «zzzzzzzz», «yyyyyy», ...) и замеряем время поиска минимального ключа.

Анализ поведения в среднем случае: добавляем в словарь n слов и замеряем время поиска минимального ключа.

Таблица 4

#	Количество элементов в словаре	Время выполнения функции <code>bstree_min</code> в худшем случае, с	Время выполнения функции <code>bstree_min</code> в среднем случае, с
1	10 000		
2	20 000		
3	30 000		
...			
20	200 000		

Эксперимент 5 Исследование эффективности поиска максимального элемента в бинарном дереве поиска в худшем и среднем случаях

Требуется заполнить таблицу 5 и построить графики зависимости времени t выполнения операции поиска максимального элемента в бинарном дереве поиска в худшем и среднем случаях.

Анализ поведения в худшем случае: добавляем в словарь n слов - от меньших к большему (например, слова «aaaaa», «bbbbbb», ...) и замеряем время поиска максимального ключа.

Анализ поведения в среднем случае: добавляем в словарь n слов и замеряем время поиска максимального ключа.

Таблица 5

#	Количество элементов в словаре	Время выполнения функции <code>bstree_max</code> в худшем случае, с	Время выполнения функции <code>bstree_max</code> в среднем случае, с
1	10 000		
2	20 000		
3	30 000		
...			
20	200 000		

Эксперимент 6 Анализ эффективности хеш-функций

Требуется заполнить таблицу 6 и построить:

- графики зависимости времени t выполнения операции поиска элемента в хеш-таблице от числа n элементов в ней для заданных хеш-функций X и Y (см. распределение вариантов)
- графики зависимости числа q коллизий от количества n элементов в хеш-таблице для заданных хеш-функций X и Y (см. распределение вариантов)

Таблица 6

#	Количество элементов в словаре	Хеш-функция X		Хеш-функция Y	
		Время выполнения функции <code>hashtab_lookup</code> , с	Число коллизий	Время выполнения функции <code>hashtab_lookup</code> , с	Число коллизий
1	10 000				
2	20 000				
3	30 000				
...					
20	200 000				

Справочная информация о хеш-функциях (см. распределение вариантов):

- **KP** — хеш-функция из «Практики программирования» (лекция 6, слайд 7)
- **Add** — аддитивная хеш-функция `add_hash` // http://www.eternallyconfuzzled.com/tuts/algorithms/jsw_tut_hashing.aspx
- **XOR** — хеш-функция `xor_hash` // http://www.eternallyconfuzzled.com/tuts/algorithms/jsw_tut_hashing.aspx
- **FNV** — хеш-функция `fnv_hash` (Fowler/Noll/Vo) // http://www.eternallyconfuzzled.com/tuts/algorithms/jsw_tut_hashing.aspx
- **Jenkins** — хеш-функция `jenkins_one_at_a_time_hash` // http://en.wikipedia.org/wiki/Jenkins_hash_function
- **ELF** — хеш-функция `ELFHash` (лекция 6, слайд 17)
- **DJB** — хеш-функция `djb_hash` (Dan Bernstein) // http://en.wikipedia.org/wiki/Jenkins_hash_function

Контрольные вопросы

- Что такое словарь, ассоциативный массив?
- Что такое бинарное дерево поиска (анализ сложности основных операций)?
- Что такое хеш-таблица (анализ сложности основных операций)?
- Что такое хеш-функция? Что такое «хорошая» хеш-функция?
- Методы разрешения коллизий в хеш-таблицах