Хеширование

Алексей Владыкин

СПбГУ ИТМО

1 марта 2010

Определения

- Преобразование данных произвольной длины и типа в битовую строку фиксированной длины (n-битное число).
- От англ. «to hash» — рубить, крошить, перемешивать.
- Hash — американское блюдо из говядины, картошки и лука.

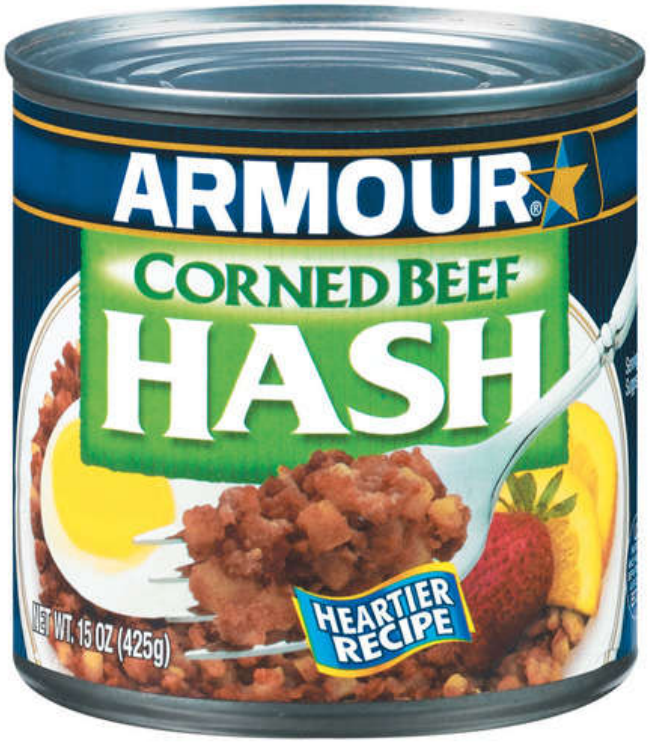

Применения

- Хеш-таблицы
  - Реализация множеств
  - Реализация отображений
  - Фильтр Блума
- Хеш-функции
  - Алгоритм Рабина — Карпа (см. лекцию про строки)
  - Контроль целостности данных

Множество и отображение

```
public interface Set<T> {
    void add(T element);
    void remove(T element);
    boolean contains(T element);
    int size();
}
```

```
public interface Map<K, V> {
    void put(K key, V value);
    V get(K key);
    void remove(K key);
    boolean contains(K key);
    int size();
}
```

- В каких задачах требуются эти типы данных?
- Как реализовать множество через отображение?

Отображения в языках программирования

- **PHP**, **JavaScript**: все массивы являются хеш-таблицами.
- **Perl**, **Python**: хеш — самостоятельный встроенный тип данных.
- **Java**, **C++**: реализации множеств и отображений есть в стандартной библиотеке.
- **C**: «сделай сам».

Listing 1: Perl

```
my %hash;
$hash{'foo'} = 'bar';
print "$hash{'foo'}\n";
```

Listing 2: Java

```
Map<String, String> map =
        new HashMap<String, String>();
map.put("foo", "bar");
System.out.println(map.get("foo"));
```

Реализация отображения: идея хеш-таблицы

- Ключ отображения — целое или вещественное число, строка, структура — имеет бесконечное или очень большое конечное множество значений.
- В каждый момент времени отображение содержит лишь небольшое подмножество ключей и соответствующих им значений.
- При помощи хеш-функции можно отобразить множество ключей в множество чисел $\{0, \ldots, n-1\}$ и использовать обычный массив из n элементов.
- Каков тип элемента массива?
- Основная проблема — коллизии, когда $h(k_1) = h(k_2)$.

Стратегии разрешения коллизий

- В i-й ячейке массива хранится связный список элементов с хеш-кодами ключей $h(k) = i$.
- В i-й ячейке массива хранится только один элемент, а новые элементы с тем же хеш-кодом размещаются в других ячейках, выбираемых по какому-либо алгоритму.
  Пример: линейная последовательность проб: $h_j(k) = h(k) + js$

Эффективность хеш-таблиц

- Хорошая хеш-функция и заполненность массива меньше 80% дают среднюю эффективность всех операций $O(1)$.
- По мере заполнения массив следует увеличивать.
- Качество хеш-функции:
  - равномерное распределение значений;
  - изменение значения при изменении любого бита ключа.
- Разобрать примеры хеш-функций.

Фильтр Блума

- Отсеивает заведомо безуспешные операции поиска данных по ключу.
- Хеш-коды ключей, имеющихся в хранилище, заносятся в побитно упакованную таблицу.
- По таблице можно быстро определить, что ключа нет в хранилище, и не надо тратить время на поиск.
- Наличие хеш-кода ключа в таблице не гарантирует присутствие данных в хранилище, т.к. может иметь место коллизия.

Контроль целостности данных

- Контрольная сумма (checksum) — значение некоторой хеш-функции, используемое для проверки неизменности данных.
- Если контрольная сумма не сходится, то данные испорчены.
- Если контрольная сумма сходится, то данные, скорее всего, верны.
- Примеры: CRC-32, MD5, SHA*.
- Если данные защищаются от преднамеренной подделки, а не просто случайных ошибок, то хеш-функция называется криптографической, и должна быть криптостойкой.