第11回のキーワード

アルゴリズム関係

- ハッシュテーブル / ハッシュ表（hash table）
- ハッシュ関数
- ハッシュ値（hash value）/ ハッシュコード（hash code）
- バケット（bucket）
- 衝突（collision）
- チェーン法
- オープンアドレス法
- $O(1)$

Java関係

- 文字コード（Unicode）
- str.charAt(i)
- hashCode
- %演算子の結果の範囲

ハッシュテーブル

- ハッシュテーブル（ハッシュ表）
  - データ自体から，それを格納・探索する場所（配列要素）を即時に計算で決める探索アルゴリズム
  - データを「ハッシュ関数」によって整数 h に変換し，配列の要素 a[h] をデータの格納場所とする
  - 「衝突」がなければ，データ数によらず極めて高速（$O(1)$）
  - 配列の中身を順に埋めるのではなくて，スカスカに使う

- ハッシュ関数
  - データから指定範囲のバラバラな整数を計算する関数
  - 衝突：異なるデータから計算したハッシュ値が偶然に一致すること → 格納場所が重なってしまうので困る…

ハッシュ関数の概念

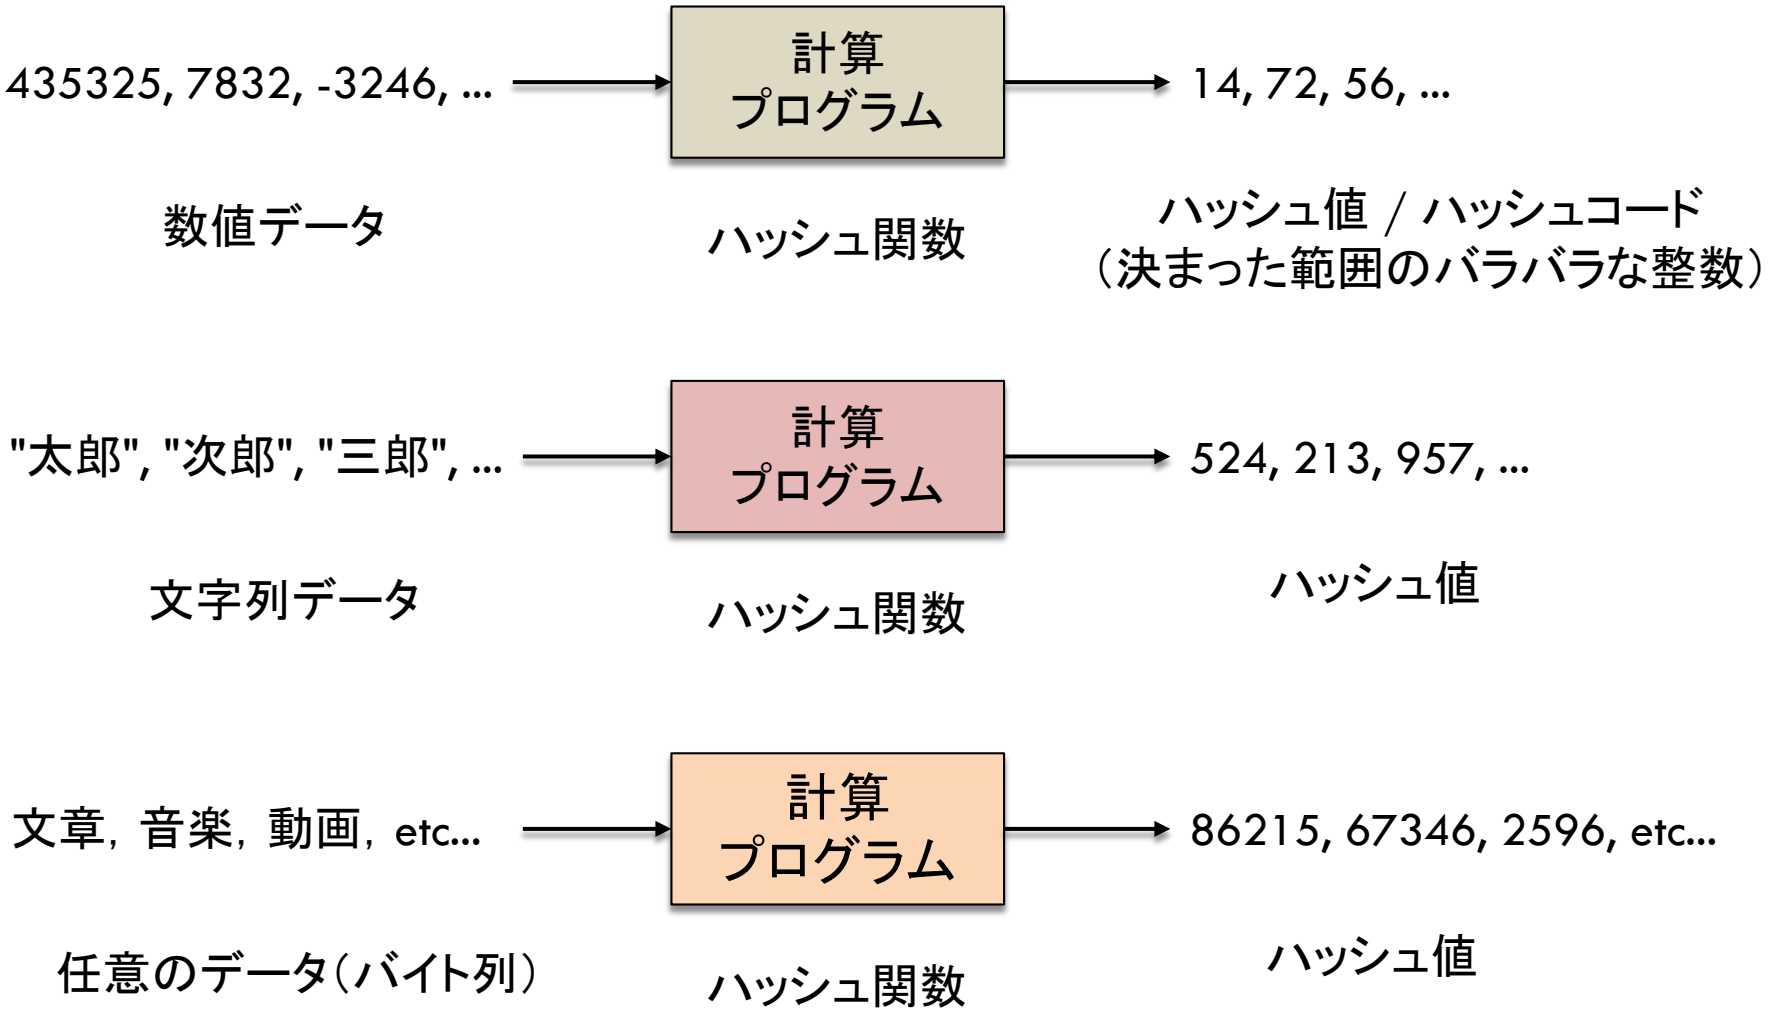
435325, 7832, -3246, ...
計算
プログラム
14, 72, 56, ...
数値データ
ハッシュ関数
ハッシュ値 / ハッシュコード
（決まった範囲のバラバラな整数）
"太郎", "次郎", "三郎", ...
計算
プログラム
524, 213, 957, ...
文字列データ
ハッシュ関数
ハッシュ値
文章，音楽，動画，etc...
計算
プログラム
86215, 67346, 2596, etc...
任意のデータ（バイト列）
ハッシュ関数
ハッシュ値

ハッシュテーブル

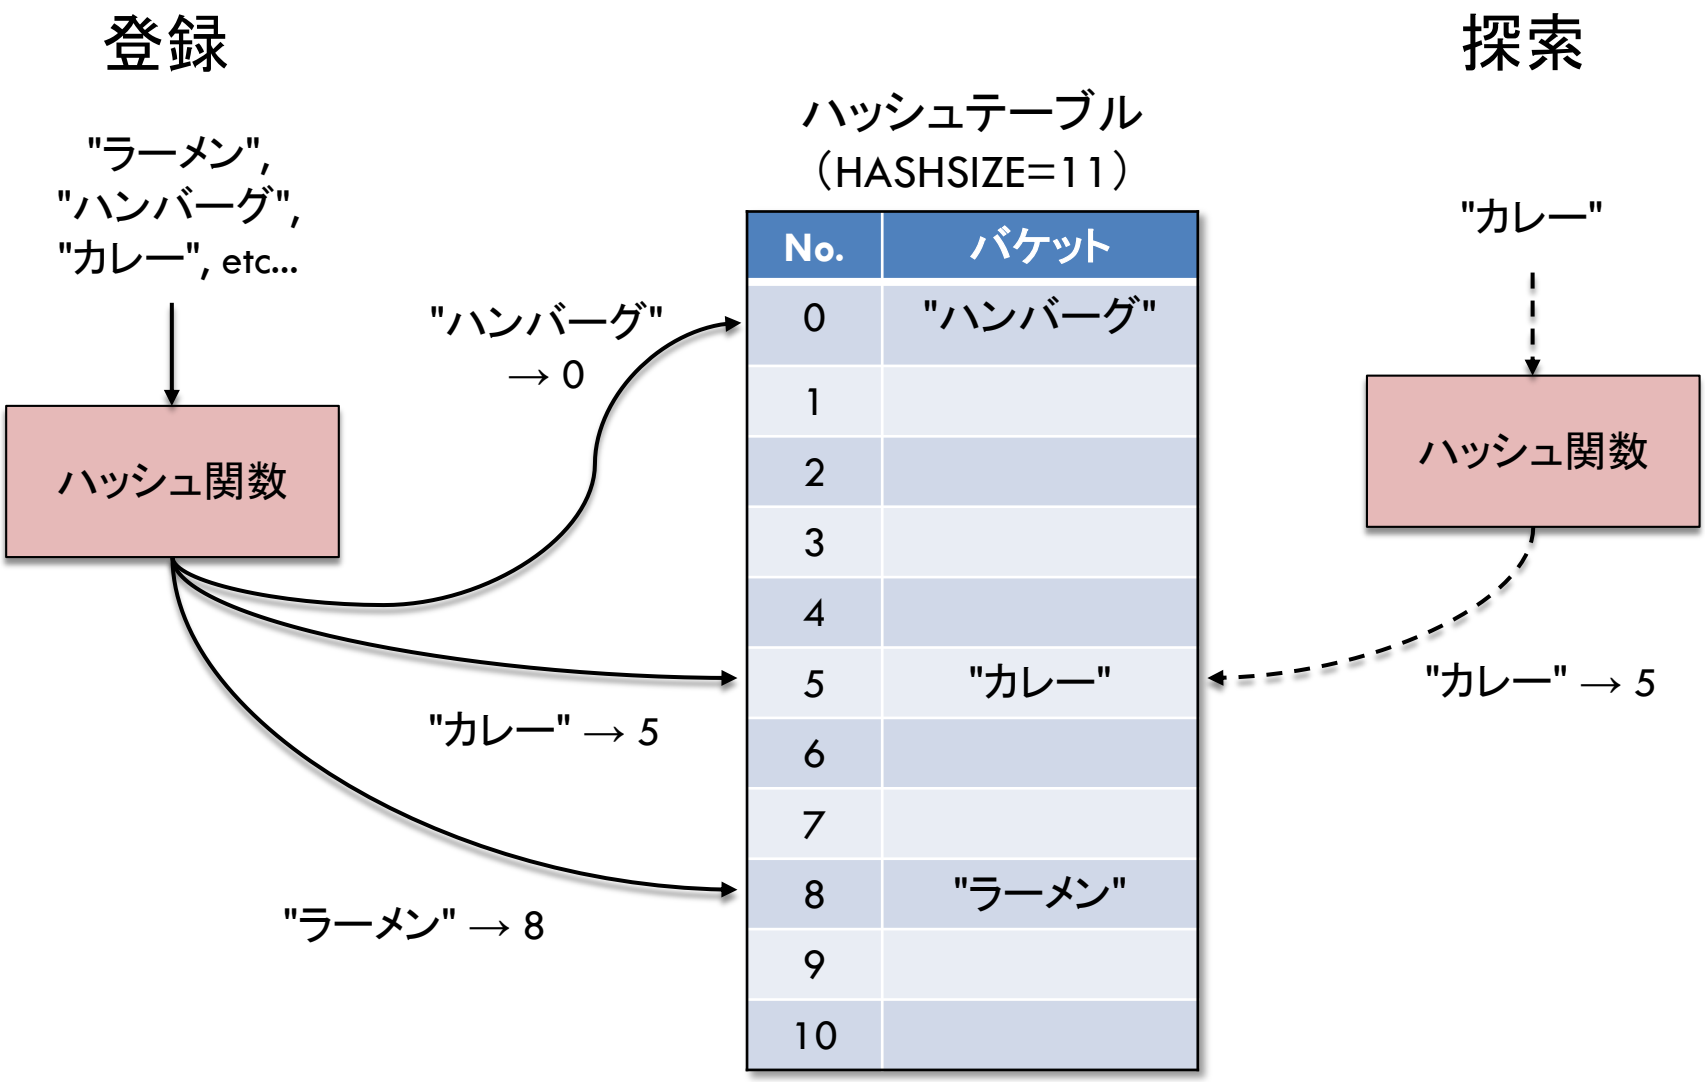
登録
探索
"ラーメン",
"ハンバーグ",
"カレー", etc...
ハッシュテーブル
（HASHSIZE=11）
No.
バケット
0
"ハンバーグ"
1
2
3
4
5
"カレー"
6
7
8
"ラーメン"
9
10
"ハンバーグ"
→ 0
"カレー" → 5
"ラーメン" → 8
ハッシュ関数
"カレー"
ハッシュ関数
"カレー" → 5

ハッシュ関数の作り方

- よいハッシュ関数の条件
  - データが少しでも異なれば，ハッシュ値も異なる
  - ハッシュ値が異なれば，データは必ず等しくない
  - ハッシュ値が分散し，バケットを全体的にまんべんなく使う
- ダメなハッシュ関数の例
  - 先頭文字だけを使う ⇒ 残りの文字が異なっても値が同じ
  - ハッシュ値が必ず偶数になる ⇒ バケットの半数が無駄
- ハッシュ関数の作り方
  - データの全体（または十分な長さ）を使って算出する
  - 値を分散させるには，素数による乗除算を繰り返すとよい

衝突への対処方法

- 完全ハッシュ
  - 全てのデータが分かっている場合に，ハッシュ関数の計算アルゴリズムを，必ず衝突がないように設計しておく
- オープンアドレス法
  - もし衝突が起きたら，別のアルゴリズムで計算しなおした要素（単純な方法の場合，単に次の要素）に格納する
- チェーン法
  - ハッシュテーブルの各要素（バケット）を連結リストにする
  - 要素の例） class Node { String data; Node next; }
  - 配列の例） Node[] hashtable = new Node[HASHSIZE];

チェーン法

- 各バケットを連結リストにして複数の値を格納する