

# Algorytmy i struktury danych

## Tablice haszowane

Krzysztof M. Ocetkiewicz

Krzysztof.Ocetkiewicz@eti.pg.edu.pl

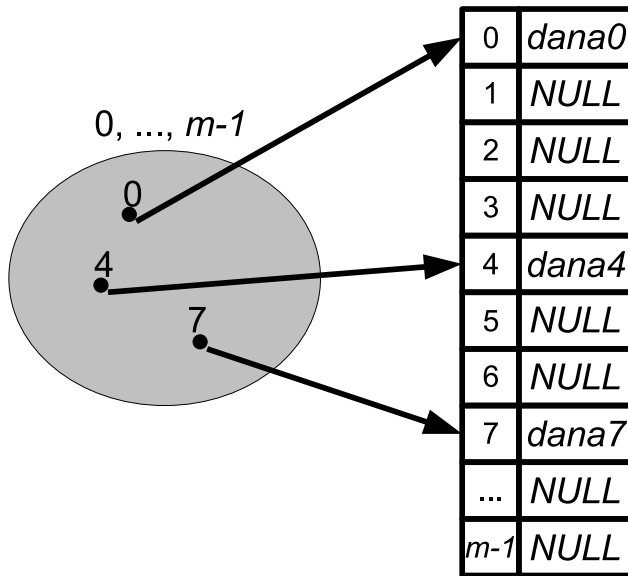
Katedra Algorytmów i Modelowania Systemów, WETI, PG

- pozwalają na szybkie wykonywanie operacji wstawiania, usuwania i wyszukiwania elementu o danym kluczu
- pesymistyczna złożoność każdej z tych operacji wynosi  $O(n)$
- w praktyce, przy rozsądnych założeniach, oczekiwany czas tych operacji wynosi  $O(1)$

# Adresowanie bezpośrednie

- małe uniwersum kluczy z zakresu  $0, \dots, m - 1$
- tablica  $m$ -elementowa  $T$
- jeżeli element o kluczu  $k$  nie należy do tablicy, to  $T[k] = \text{nullptr}$
- wstawianie:  
WSTAW(klucz, wart) {  $T[\text{klucz}] = \text{wart};$  }
- usuwanie:  
USUN(klucz) {  $T[\text{klucz}] = \text{nullptr};$  }
- wyszukiwanie:  
ZNAJDZ(klucz) { return  $T[\text{klucz}];$  }


# Adresowanie bezpośrednie



# Funkcja haszująca

- co gdy uniwersum kluczy jest większe od dostępnej pamięci lub klucze nie są liczbami naturalnymi?
- w komputerze pamięć możemy adresować jedynie liczbami
- rozwiązanie: funkcja haszująca
- jest to funkcja która “przerabia” klucz na liczbę
- $H : \text{klucz} \rightarrow 0, \dots, m - 1$
- np. suma lub iloczyn kodów znaków modulo  $m$  (marne, ale działa)
- np. suma wszystkich wartości liczbowych obiektu modulo  $m$  (j.w.)

# Funkcja haszująca



# Tablica z haszowaniem

- tablica  $m$ -elementowa  $T$
- jeżeli element o kluczu  $k$  nie należy do tablicy, to  $T[H(k)] = \text{nullptr}$
- wstawianie:  
`WSTAW(klucz, wart) { T[H(klucz)] = wart; }`
- usuwanie:  
`USUN(klucz) { T[H(klucz)] = nullptr; }`
- wstawianie:  
`ZNAJDZ(klucz) { return T[H(klucz)]; }`

# Tablica z haszowaniem

0	<i>NULL</i>
1	<i>NULL</i>
2	<i>NULL</i>
3	<i>NULL</i>
4	<i>NULL</i>
5	<i>NULL</i>
6	<i>NULL</i>
7	<i>NULL</i>
...	<i>NULL</i>
$m-1$	<i>NULL</i>



# Tablica z haszowaniem

$T[abc] = dabc$   
 $H(abc) = 0$   
 $\rightarrow T[0] = dabc$

0	<i>dabc</i>
1	<i>NULL</i>
2	<i>NULL</i>
3	<i>NULL</i>
4	<i>NULL</i>
5	<i>NULL</i>
6	<i>NULL</i>
7	<i>NULL</i>
...	<i>NULL</i>
$m-1$	<i>NULL</i>

# Tablica z haszowaniem

$T[abc] = dabc$   
 $H(abc) = 0$   
 $\rightarrow T[0] = dabc$   
 $T[def] = ddef$   
 $H(def) = 4$   
 $\rightarrow T[4] = ddef$

0	<i>dabc</i>
1	<i>NULL</i>
2	<i>NULL</i>
3	<i>NULL</i>
4	<i>ddef</i>
5	<i>NULL</i>
6	<i>NULL</i>
7	<i>NULL</i>
...	<i>NULL</i>
$m-1$	<i>NULL</i>

# Tablica z haszowaniem

$T[abc] = dabc$   
 $H(abc) = 0$   
→  $T[0] = dabc$   
 $T[def] = ddef$   
 $H(def) = 4$   
→  $T[4] = ddef$   
 $T[def] = ?$   
 $H(def) = 4$   
 $T[4] \rightarrow ddef$

0	<i>dabc</i>
1	<i>NULL</i>
2	<i>NULL</i>
3	<i>NULL</i>
4	<i>ddef</i>
5	<i>NULL</i>
6	<i>NULL</i>
7	<i>NULL</i>
...	<i>NULL</i>
$m-1$	<i>NULL</i>


# Tablica z haszowaniem


$T[abc] = dabc$   
 $H(abc) = 0$   
→  $T[0] = dabc$   
 $T[def] = ddef$   
 $H(def) = 4$   
→  $T[4] = ddef$   
 $T[def] = ?$   
 $H(def) = 4$   
 $T[4] \rightarrow ddef$   
 $T[ghi] = ?$   
 $H(ghi) = 7$   
 $T[7] \rightarrow NULL$

0	<i>dabc</i>
1	<i>NULL</i>
2	<i>NULL</i>
3	<i>NULL</i>
4	<i>ddef</i>
5	<i>NULL</i>
6	<i>NULL</i>
7	<i>NULL</i>
...	<i>NULL</i>
$m-1$	<i>NULL</i>

# Właściwości funkcji haszującej

- powinna być prosta (szybka) do obliczenia
- dla tego samego klucza musi zwracać tę samą wartość (inaczej po wstawieniu mielibyśmy problem z ponownym znalezieniem elementu)
- rzeczywiste dane powinna jak najbardziej równomiernie rozkładać (rozpraszać) w przestrzeni adresów
- dla różnych kluczy powinna zwracać różne wartości (ale nie zawsze jest to możliwe — “dużą” przestrzeń kluczy mapujemy w “małą” przestrzeń adresów)
- kolizja — sytuacja, gdy dwa różne klucze mają taką samą wartość funkcji haszującej





- w przypadku kolizji, w jednej komórce należy “upchnąć” więcej niż jedną daną
- razem z daną należy teraz przechowywać także klucz
  - w przypadku kolizji w jednej komórce mamy więcej niż jedną daną
  - szukamy tylko jednej z nich (według klucza), powinniśmy więc wiedzieć, pod jakim kluczem każda z nich jest przechowywana

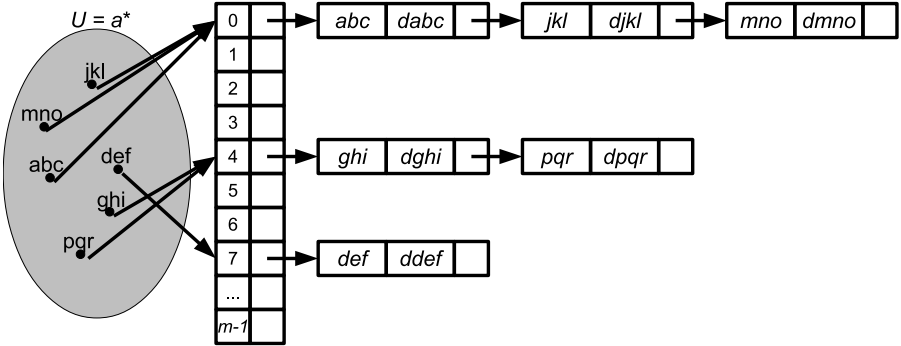


- łańcuchowanie oddzielne
- łańcuchowanie bezpośrednie
- łańcuchowanie z obszarem nadmiarowym
- adresowanie otwarte

- elementy kolidujące ze sobą przechowujemy w oddzielnych listach
- każda komórka tablicy  $T$  jest w rzeczywistości listą par  $(klucz, wartosc)$
- dodając parę  $(klucz, wartosc)$  dodajemy do listy  $T(klucz)$  element  $(klucz, wartosc)$
- usuwając element o kluczu  $klucz$  usuwamy z listy  $T(klucz)$  element zawierający klucz  $klucz$
- wyszukując element o kluczu  $klucz$  poszukujemy go pośród elementów na liście  $T(klucz)$

- oczekiwany czas wyszukiwania zakończonego porażką lub sukcesem:  $O(1 + \alpha)$
- $\alpha$  — współczynnik wypełnienia tablicy,  $\alpha = n/m$ , gdzie  $m$  to rozmiar tablicy,  $n$  to ilość elementów w tablicy
- średnia długość listy wynosi  $n/m$
- w najgorszym przypadku będzie to jednak  $n$

# Łańcuchowanie oddzielne




# Łańcuchowanie oddzielne

$T[abc] = dabc$   
 $H(abc) = 0$

0	
1	
2	
3	
4	
5	
6	
7	
...	
$m-1$	


# Łącuchowanie oddzielne

$T[abc] = dabc$   
 $H(abc) = 0$



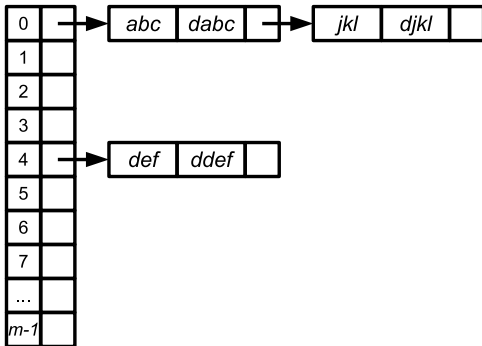
# Łańcuchowanie oddzielne

$T[abc] = dabc$   
 $H(abc) = 0$   
 $T[def] = ddef$   
 $H(def) = 4$



# Łańcuchowanie oddzielne


$T[abc] = dabc$   
 $H(abc) = 0$   
 $T[def] = ddef$   
 $H(def) = 4$   
 $T[jkl] = djkl$   
 $H(jkl) = 0$



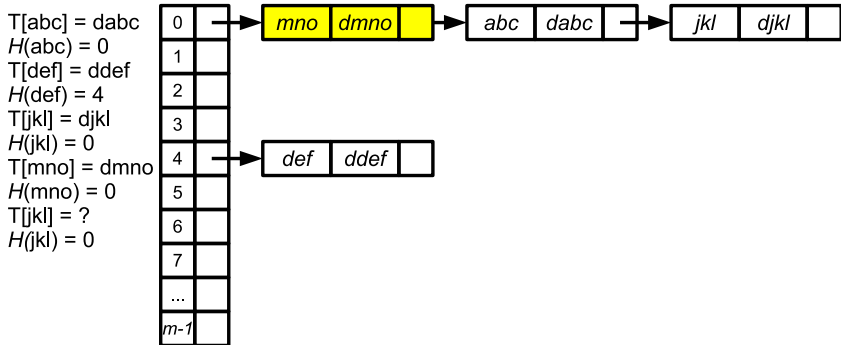


# Łańcuchowanie oddzielne

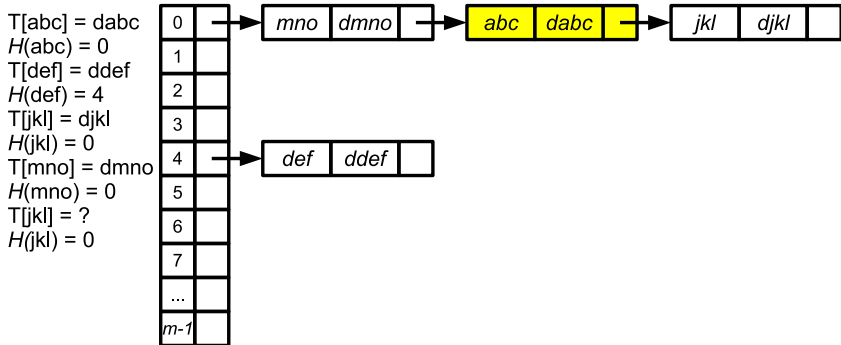
$T[abc] = dabc$   
 $H(abc) = 0$   
 $T[def] = ddef$   
 $H(def) = 4$   
 $T[jkl] = djkl$   
 $H(jkl) = 0$   
 $T[mno] = dmno$   
 $H(mno) = 0$



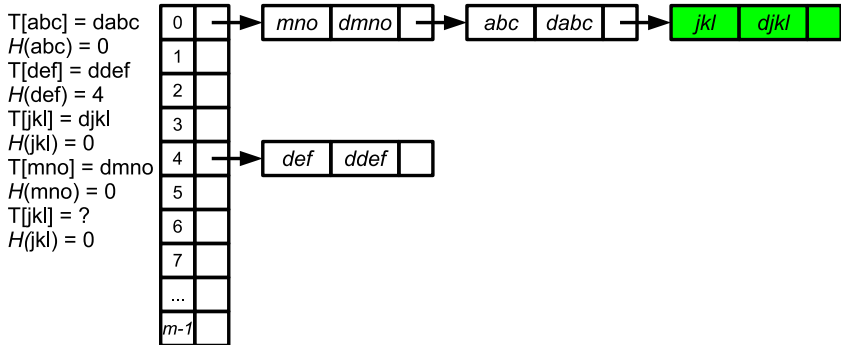
# Łańcuchowanie oddzielne



# Łańcuchowanie oddzielne



# Łańcuchowanie oddzielne

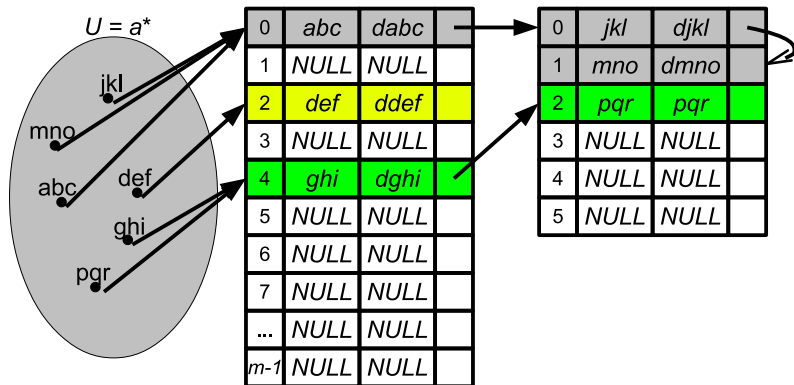


- elementy pamiętamy bezpośrednio w tablicy
- każda komórka tablicy  $T$  poza kluczem i wartością, posiada także wskaźnik na następny element o takiej samej wartości funkcji haszującej
- miejsce na kolidujące elementy przydzielamy nie dynamicznie, ale z puli nazywanej obszarem nadmiarowym
- gdy miejsce w obszarze nadmiarowym wyczerpie się, możemy powiększyć całą tablicę, lub tylko “doalokować” nowy obszar nadmiarowy

- wyszukując element o kluczu *klucz* :
  - rozpoczynamy od pola  $T(\textit{klucz})$
  - przeglądamy kolejne pola (przechodząc po wskaźnikach) w poszukiwaniu tego, które zawiera klucz *klucz*
  - przerywamy gdy: znajdziemy poszukiwany klucz lub dojdziemy do końca listy

- dodając parę (*klucz*, *wartosc*) :
  - jeżeli komórka  $T(\textit{klucz})$  jest pusta, wstawiamy tam parę (*klucz*, *wartosc*)
  - jeżeli komórka jest zajęta, bierzemy nową komórkę z obszaru nadmiarowego i wstawiamy tam parę (*klucz*, *wartosc*)
  - dołączamy tę nową komórkę do listy, której głową jest  $T(\textit{klucz})$  (najłatwiej — za głową, ale można też na końcu)

# Łącuchowanie z obsz. nadmiarowym

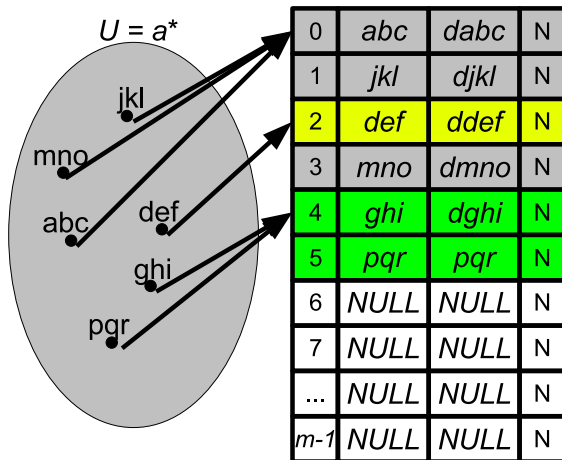




- wszystkie elementy przechowywane są wprost w tablicy
- funkcja haszująca ma dwa parametry: klucz oraz numer próby
- funkcja haszująca wyznacza nam porządek przeszukiwania komórek tablicy
- ciąg  $H(\text{klucz}, 0), H(\text{klucz}, 1), \dots, H(\text{klucz}, m - 1)$  powinien być permutacją ciągu  $0, \dots, m - 1$  — inaczej nie wykorzystamy wszystkich komórek pamięci
- w tablicy przechowujemy parę  $(\text{klucz}, \text{wartosc})$  oraz flagę sygnalizującą, czy zawartość została usunięta

- jeżeli podczas wstawiania komórka  $T(\text{klucz}, 0)$  jest zajęta, próbujemy wstawić w komórkę  $T(\text{klucz}, 1)$ ,  $T(\text{klucz}, 2)$ , itd.
- elementu szukamy w komórkach  $T(\text{klucz}, 0)$ ,  $T(\text{klucz}, 1)$ ,  $T(\text{klucz}, 2)$ , itd. aż dojdziemy do komórki pustej, której zawartość nie została usunięta
- usuwając element, wyszukujemy go, usuwamy i oznaczamy komórkę w której się znajdował jako usuniętą

# Adresowanie otwarte



WSTAW( $T$ ,  $klucz$ ,  $wartosc$ )

```
1:  $i = 0$ 
2: repeat
3:      $j = H(klucz, i)$ 
4:     if  $T[j] = nullptr$  then
5:          $T[j].klucz = klucz$ 
6:          $T[j].wart = wartosc$ 
7:          $T[j].usuniete = Nie$ 
8:         return  $j$ 
9:     else
10:         $i = i + 1$ 
11:    end if
12: until  $i = m$ 
```

ZNAJDZ( $T$ ,  $klucz$ )

1:  $i = 0$

2: **repeat**

3:      $j = H(klucz, i)$

4:     **if**  $T[j].klucz = klucz$  **then**

5:         **return**  $T[j].wart$

6:     **end if**

7:      $i = i + 1$

8: **until**  $i = m$  lub

( $T[j].klucz = nullptr$  i  $T[j].usuniete = Nie$  )

USUN( $T$ ,  $klucz$ )

```
1:  $i = 0$ 
2: repeat
3:      $j = H(klucz, i)$ 
4:     if  $T[j].klucz = klucz$  then
5:          $T[j].klucz = nullptr$ 
6:          $T[j].wart = nullptr$ 
7:          $T[j].usuniete = Tak$ 
8:     return
9:     end if
10:     $i = i + 1$ 
11: until  $i = m$  lub
    ( $T[j].klucz = nullptr$  i  $T[j].usuniete = Nie$ )
```

- adresowanie liniowe:

$$H(\text{klucz}, i) = (H_1(\text{klucz}) + i) \bmod m$$

- proste w implementacji
- wadą jest grupowanie elementów: długie spójne ciągi szybko się powiększają
- jeżeli w tablicy  $\alpha = 0.5$  i zajęte są tylko nieparzyste komórki potrzeba średnio 1.5 porównań aby stwierdzić, że elementu nie ma w tablicy
- jeżeli w tablicy  $\alpha = 0.5$  i zajętych jest pierwszych  $m/2$  komórek średnia liczba porównań jest równa  $m/4$
- w adresowaniu liniowym rozkład elementów częściej przypomina ten drugi

- adresowanie kwadratowe:

$$H(\text{klucz}, i) = (H_1(\text{klucz}) + a_1i + a_2i^2) \bmod m$$

- adresowanie sześciennne:

$$H(\text{klucz}, i) = (H_1(\text{klucz}) + a_1i + a_2i^2 + a_3i^3) \bmod m$$

- wymaga odpowiedniego doboru wartości  $a_1, a_2, a_3$
- wadą jest (mniej groźne) grupowanie wtórne — dla dwóch kluczy o takiej samej wartości  $H_1$  będziemy przeszukiwać komórki w takiej samej kolejności



- w adresowaniu kwadratowym, gdy  $m = 2^k$ , dobrym kandydatem na  $a_1$  i  $a_2$  jest liczba  $\frac{1}{2}$
- odwiedzamy wtedy komórki  $H_1(\text{klucz})$ ,  $H_1(\text{klucz}) + 1$ ,  $H_1(\text{klucz}) + 1 + 2$ ,  $H_1(\text{klucz}) + 1 + 2 + 3$  itd. — po każdej próbie, do indeksu komórki dodajemy numer próby
- można pokazać, że tym sposobem odwiedzimy wszystkie komórki tablicy

- adresowanie dwukrotne:

$$H(\text{klucz}, i) = (H_1(\text{klucz}) + iH_2(\text{klucz})) \bmod m$$

- wymaga obliczenia wartości dwóch funkcji haszujących (oczywiście  $H_1$  i  $H_2$  powinny być różnymi funkcjami)
- $H_2$  powinna być odpowiednio dobrana aby mieć pewność, że zostanie przeszukana cała tablica
  - np. zapewniając, że  $H_2(\text{klucz})$  jest względnie pierwsze z rozmiarem tablicy (inaczej przeszukamy tylko  $m/\text{NWD}(m, H_2(\text{klucz}))$  komórek)
  - np.  $m$  — pierwsze,  $H_2(\text{klucz}) < m$
  - np.  $m$  — parzyste,  $H_2(\text{klucz})$  — zawsze nieparzyste

- adresowanie dwukrotne:
  - grupowanie wtórne jest znikome
  - dla dwóch różnych kluczy o takiej samej wartości  $H_1$  ciągi przeszukiwanych elementów zazwyczaj będą różne (aby były równe kolizja musiałaby wystąpić przy obu funkcjach)

- przy równomiernym (“idealnym”) haszowaniu oczekiwana liczba porównań kluczy:
  - w czasie wyszukiwania elementu nie występującego w tablicy (oraz w czasie wstawiania) jest nie większa niż  $1/(1 - \alpha)$
  - w czasie wyszukiwania elementu występującego w tablicy (oraz w czasie usuwania) jest nie większa niż  $\frac{1}{\alpha} \ln \frac{1}{1-\alpha} + \frac{1}{\alpha}$
  - dla  $\alpha = 0.5$  jest to 2 i  $\approx 3.387$
  - dla  $\alpha = 0.9$  jest to 10 i  $\approx 3.670$

- w przypadku adresowania liniowego:
  - w czasie wyszukiwania elementu nie występującego w tablicy:  
 $1 + \frac{1}{(1-\alpha)^2}$
  - w czasie wyszukiwania elementu występującego w tablicy:  $1 + \frac{1}{1-\alpha}$
  - dla  $\alpha = 0.5$  jest to 4 i 3
  - dla  $\alpha = 0.9$  jest to 100 i 11

- aby czas dostępu był krótki należy utrzymywać wartość współczynnika wypełnienia poniżej określonego progu (zazwyczaj 0.5–0.8)
- jeżeli próg zostanie przekroczony, należy powiększyć tablicę
- wiąże się z ponownym wstawieniem wszystkich przechowywanych elementów (zmienia się  $m$  więc zmieniają się także wartości funkcji haszującej dla kluczy) — kosztuje to  $O(n)$  (lub  $O(m)$  w zależności od implementacji)

- aby zachować średni czas wstawiania  $O(1)$  należy tablicę powiększać wykładniczo (np. każde powiększenie podwaja rozmiar tablicy)
- spadek współczynnika wypełnienia poniżej pewnego progu (np. 0.1 lub 0.25) może być sygnałem do pomniejszenia rozmiaru tablicy (np. o połowę – aby usuwanie działało średnio w stałym czasie)

- przestrzeń wartości powinna być nie mniejsza niż rozmiar tablicy
  - inaczej część tablicy pozostanie niewykorzystana
- każdy legalny klucz powinien być odwzorowany w poprawny adres w tablicy  $T$  (tj. w liczbę z zakresu  $0, \dots, m - 1$ )



- dobra funkcja powinna spełniać (w przybliżeniu) założenie prostego równomiernego haszowania: losowo wybrany klucz jest z jednakowym prawdopodobieństwem odwzorowywany na każdą z pozycji
- klucze nieliczbowe należy najpierw zamienić w pewien sposób na liczbę
- po skonstruowaniu funkcji dobrze jest przetestować ją na danych rzeczywistych (z badać, jak rozrzuca elementy)

- $H(\textit{klucz}) = \textit{klucz} \bmod m$
- działa szybko (jedno dzielenie)
- $m$  nie powinno być potęgą dwójki (wtedy bierzemy najmłodsze  $m$  bitów) – jeżeli nie mamy gwarancji, że ich rozkład jest równomierny, lepiej wybrać funkcję która zależy od wszystkich bitów klucza
- $m$  nie powinno być postaci  $2^p - 1$  — wartość funkcji haszujących różniących się kolejnością dwóch sąsiednich cyfr binarnych będzie taka sama
- podobnie dla innych podstaw (np. 10, czyli  $m \neq 10^p$ ,  $m \neq 10^p - 1$ )
- dobrymi wartościami  $m$  są liczby pierwsze niezbyt bliskie potęgom 2

- mnożymy wartość liczbową klucza przez stałą  $A$  z przedziału  $0 < A < 1$  i wyznaczamy część ułamkową
- wynik mnożymy przez  $m$  i z otrzymanej wartości bierzemy podłogę
- $H(\text{klucz}) = \text{podloga}(m(kA \bmod 1))$
- $m$  może w tym przypadku być dowolne
- jednak często wybiera się  $m$  o postaci  $2^p$  — ułatwia to implementację (mnożymy  $k$  przez  $\text{podloga}(A \cdot 2^w)$  i z wyniku wybieramy bity na pozycjach  $w - p, \dots, w - 1$ , gdzie  $w$  to liczba bitów słowa maszynowego)

- metoda działa dla dowolnej wartości  $A$ , ale pewne wartości dają lepsze rozproszenie niż inne
- szczególnie dobra jest wartość  $A = \frac{\sqrt{(5)}-1}{2} = 0.6180339887\dots$
- np. dla  $m = 10000$ :

$$\begin{aligned}H(123456) &= \lfloor 10000 \cdot (123456 \cdot 0.61803\dots \bmod 1) \rfloor \\ &= \lfloor 10000 \cdot (76300.0041151\dots \bmod 1) \rfloor \\ &= \lfloor 10000 \cdot 0.0041151 \rfloor \\ &= \lfloor 41.151 \rfloor \\ &= 41\end{aligned}$$

# Haszowanie przez randomizację

- obliczamy  $H(\text{klucz}) = \text{Rand}(\text{klucz})$ , gdzie *Rand* to pewna funkcja pseudolosowa
- np. wybieramy z klucza pewną liczbę bitów, traktujemy je jako liczbę binarną i podnosimy do kwadratu
- np. ciąg bitów klucza dzielimy na kilka fragmentów, traktujemy je jako liczby binarne i sumujemy je
- np. ciąg bitów klucza dzielimy na kilka fragmentów, traktujemy je jako liczby binarne i sumujemy je modulo 2
- zazwyczaj należy połączyć tę metodę z haszowaniem modularnym (możemy otrzymać duże liczby)

- jeżeli dane do tablicy wstawiane są przez “złośliwego przeciwnika”, nie możemy wykluczyć sytuacji, gdy wszystkie klucze trafią w tę samą komórkę tablicy
- średni czas wykonywania operacji wynosi wówczas  $O(n)$
- każda ustalona funkcja haszująca jest podatna na takie zagrożenie
- rozwiązaniem jest losowy wybór funkcji haszującej
- oczywiście wszystkie możliwe do wylosowania funkcje powinny odwzorowywać klucze w ten sam zakres adresów  $(0, \dots, m - 1)$

- sumowanie kodów znaków jest złe:
  - kody liter: 97, ..., 122 (małe), 65, ..., 90 (duże)
  - znaki o kodach poniżej 32 prawie nigdy nie występują w napisach
  - małe wartości: 30 znaków da maksymalnie  $30 \cdot 256 = 7680$ ,  
zdecydowanie częściej jednak tylko  $30 \cdot 122 = 3660$
- iloczyn kodów znaków (modulo  $m$ ) jest zły:
  - jeżeli  $m$  jest parzyste — katastrofa
  - częstsze kolizje na indeksach będących dzielnikami  $m$

- konstruując funkcję należy pamiętać o właściwościach operacji matematycznych, np.:
  - operacje takie jak suma, iloczyn, suma modulo 2 są przemienne — zamiana kolejności znaków nie zmienia wartości funkcji mieszającej
  - stosując te funkcje dobrze jest włączyć do wartości znaku jego pozycję
  - np. suma znaków pomnożonych przez wagę kolejnej pozycji, gdzie wagi pozycji to np. 137, 11, 113, 37, 19, ...
  - iloczyn dwóch liczb parzystych, iloczyn liczby parzystej i nieparzystej daje liczbę parzystą; liczbę nieparzystą daje tylko iloczyn dwóch liczb nieparzystych
  - ...



- tablica o rozmiarze  $10^6$  elementów
- kluczem są nazwiska
- wielkość liter nie ma znaczenia — będziemy używać tylko małych liter
- jeżeli spodziewamy się, że polskie znaki będą występować rzadko — możemy je pominąć lub zamienić na łacińskie odpowiedniki
- małe litery: 97, ..., 122
- $H(\text{klucz}) = \sum_{i=0}^{n-1} (\text{klucz}[i] - 97) * 26^{(i \bmod 6)}$

- w przypadku długich napisów, warto rozważyć haszowanie tylko ich początkowych fragmentów
- prawdopodobieństwo, że dwa napisy będą identyczne na pierwszych 20–60 znakach jest znikome (o ile dane nie mają specyficznego formatu)
- w takich sytuacjach warto raczej zgodzić się na kolizję, niż próbować “na siłę” rozróżnić wartości funkcji haszującej — kosztem jednego czy dwóch porównań, raz na jakiś czas, zyskujemy przyspieszenie obliczania funkcji haszującej przy każdym dostępie

```
1: uint32_t hash = 5381
2: for  $i = 1$  do  $n$  do
3:     hash = ((hash << 5) + hash) + bajt[i]
4: end for
5: return hash
```

```
1: uint32_t hash = 0
2: for  $i = 1$  do  $n$  do
3:      $hash = bajt[i] + ((hash \ll 6) + (hash \ll 16)) - hash$ 
4: end for
5: return hash
```

## Przykład — Jenkin's one-at-a-time

```
1: uint32_t hash = 0
2: for  $i = 1$  do  $n$  do
3:     hash = hash + bajt[i]
4:     hash = hash + (hash << 10)
5:     hash = hash xor (hash >> 6)
6: end for
7: hash = hash + (hash << 3)
8: hash = hash xor (hash >> 11)
9: hash = hash + (hash << 15)
10: return hash
```

```
1: uint32_t hash = 2166136261
2: for  $i = 1$  do  $n$  do
3:     hash = hash xor bajt[ $i$ ]
4:     hash = hash * 16777619
5: end for
6: return hash
```

# Przykład — ELF hash

```
1: uint32_t hash = 0, high
2: for  $i = 1$  do  $n$  do
3:     hash = (hash << 4) + bajt[i]
4:     high = hash and 0xF0000000
5:     if high  $\neq$  0 then
6:         hash = hash xor (high >> 24)
7:     end if
8:     hash = hash and not high
9: end for
10: return hash
```

# Przeładowanie całej tablicy

- tablice haszowane nie umożliwiają efektywnego przeładowania wszystkich elementów z tablicy

- “oczywiste” rozwiązanie:

```
for(i = 0; i < m; i++) {  
    if( $T[i] \neq \text{nullptr}$ ) wypisz( $T[i]$ );  
};
```

- co jeżeli elementów jest mało a tablica jest duża? — dużo niepotrzebnych kroków
- rozwiązanie: powiązanie elementów listą (dwukierunkową)
  - dodatkowy narzut na dodawanie i usuwanie elementu to  $O(1)$



# Przeglądanie całej tablicy

