


Kollisionsbehandlung beim Hashing:

2) open addressing

$$h: U \times \{0, \dots, m-1\} \rightarrow \{0, \dots, m-1\}$$

$h(k, i) \hat{=}$  Adresse nach  $i$  erfolglosen Versuchen beim Einfügen von  $k$ .



## Analyse von open addressing

Mache hierzu „Gleichverteilungsannahme“: Die jeweils nächste Adresse wird zufällig und gleichverteilt aus  $\{0, \dots, m-1\}$  gewählt.

Satz: Bei Anlastung  $\alpha = \frac{u}{m} < 1$  ist  
 $E(\# \text{ Sondierungen beim Einfügen}) \leq \frac{1}{1-\alpha}$ .

Für Beweis betrachte Urnenmodell:

$m$  Kugeln,  $w$  weiße,  $s$  schwarze ( $m = w + s$ )

Ziehe gleichverteilt mit Zurücklegen

$E(\# \text{ Ziehungen bis weiße Kugel gezogen}) = \frac{m}{w}$

Bsp:

$E(\# \text{ Würfelwürfe bis 6 gewürfelt}) = \frac{6}{1} = 6$

$E(\# \text{ „ u 1 oder 2 u “}) = \frac{6}{2} = 3$

Begriffe aus der W-Theorie:

diskrete Zufallsgröße  $X$  (endlicher Fall)  
 hat Werte  $x_1, x_2, \dots, x_n$  die mit  
 W'keiten  $p_1, p_2, \dots, p_n$  auftreten.

Bsp. 1 Würfel

1	2	3	4	5	6
$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$

Würfeln mit 2 Würfeln,  $X = \sum$  Augenzahl

Werte	2	3	4	5	6	7	8	9	10	11	12
	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{3}{36}$							$\frac{2}{36}$	$\frac{1}{36}$

Erwartungswert der Zufallsgröße  $X$  ist

$$E(X) = \sum_{i=1}^n x_i \cdot p_i$$

1 Würfel: 3,5  
 2 Würfel: 7

Analog für den abzählbar unendlichen  
 Fall:

$X$  hat Werte  $x_1, x_2, x_3, \dots, x_i, \dots$   
 mit W'keiten  $p_1, p_2, p_3, \dots, p_i, \dots$

$$E(X) = \sum_{i=1}^{\infty} x_i \cdot p_i \quad \text{falls Reihe absolut konverg.}$$

Anwendung auf das Urnenmodell.

Kugel ist weiß mit W'keit  $\frac{w}{m} =: p$   
 " " schwarz " "  $\frac{s}{m} = 1 - p =: q$

$X = \#$  Ziehungen bis weiße Kugel gezogen

Werte von X		W'keit dafür
1	w	$p_1 = p$
2	sw	$p_2 = q \cdot p$
3	ssw	$p_3 = q^2 \cdot p$
...		
i	$\underbrace{s \dots s}_i w$	$p_i = q^{i-1} \cdot p$

$$\sum_{i=1}^{\infty} p_i = \sum_{i=1}^{\infty} q^{i-1} \cdot p = p \cdot \sum_{i=0}^{\infty} q^i = p \cdot \frac{1}{1-q} = \frac{p}{p} = 1$$

$$E(X) = \sum_{i=1}^{\infty} i \cdot q^{i-1} \cdot p = p \cdot \underbrace{\sum_{i=1}^{\infty} i \cdot q^{i-1}}_{S}$$

$$S = 1 \cdot q^0 + 2 \cdot q^1 + 3 \cdot q^2 + 4 \cdot q^3 + \dots$$

$$\begin{aligned}
&= q^0 + q^1 + q^2 + q^3 + \dots \quad \left\{ 1 \cdot \sum_{i=0}^{\infty} q^i \right. \\
&\quad + q^1 + q^2 + q^3 + \dots \quad \left\{ q \cdot \sum_{i=0}^{\infty} q^i \right. \\
&\quad \quad + q^2 + q^3 + \dots \quad \left\{ q^2 \cdot \sum_{i=0}^{\infty} q^i \right. \\
&\quad \quad \quad + q^3 + \dots \quad \left\{ q^3 \cdot \sum_{i=0}^{\infty} q^i \right. \\
&\quad \quad \quad \quad \vdots
\end{aligned}$$

$$= \left( \sum_{i=0}^{\infty} q^i \right) \cdot \left( \sum_{i=0}^{\infty} q^i \right) = \frac{1}{p} \cdot \frac{1}{p} = \frac{1}{p^2}$$

(beachte: Reihe ist absolut konvergent)

$$\Rightarrow E(X) = \frac{1}{p} = \frac{1}{p}$$

Anwendung auf open addressing:

Sondierungen  $\hat{=}$  ziehen aus Urne

$E(\# \text{Ziehungen bis freier Platz gefunden})$

$$= \frac{m}{m-n} = \frac{1}{1-\frac{n}{m}} = \frac{1}{1-\alpha}$$


$\Rightarrow$  Satz.

□

Einfügen: im Mittel konstant (falls  $\alpha < 1$   
konstant)

Suchen: dieselbe Folge von Sondierungen wie beim Einfügen (sofern in der Einfügefølge nicht bereits Elemente gelöscht wurden).

Löschen bereitet daher Schwierigkeiten!




Daher: open addressing meistens beschränkt auf Hashing ohne Löschen.

Zusammenfassung:

Anfand pro Operation  $O(1)$  im Mittel, aber im Worst Case  $\Omega(n)$

Vergleich zu Suchbäumen:

- im Worst Case  $O(\log n)$
- Mittlerer Aufwand  $\Omega(\log n)$ , denn:



Beobachtung: Mindestens die Hälfte aller Knoten liegen in Tiefe  $\geq \log n$   
 $\Rightarrow$  Average Case Aufwand für Suchen ist  $\Omega(\log n)$ .

---

Noch zwei weitere Aspekte von Hashing:

- 1) Universelles Hashing
  - 2) Perfektes Hashing
- (nicht im Skript, siehe daher CLRS (Cormen et al.))

## 1) Universelles Hashing:

Idee: Vermeide Worst Case. Wir stellen uns einen bösen Gegenspieler vor, der unser Hashing-Verfahren kennt und durch Auswahl spezieller Schlüssel in den Worst Case treibt.

→ Randomisieren zur Laufzeit des Verfahrens, d.h. wir wählen eine zufällige Hash-Fkt. Diese wird dann für gesamte Dauer des Verfahrens verwendet.

Def.: Eine Klasse  $H$  von Hash-Fkt. heißt universell bezüglich Größe  $m$  der Hash-Tabelle falls:

$\forall$  Schlüsselpaare  $x, y \in U$  mit  $x \neq y$  gilt:

$$|\{h \in H \mid h(x) = h(y)\}| \leq \frac{|H|}{m}$$

Idee: Wähle  $h \in H$  zufällig und gleichverteilt, dann ist die W'keit für Kollision von  $x$  und  $y$   $\leq \frac{1}{m}$ .

Frage: Existiert eine solche universelle Klasse? ( $\rightarrow$  später)

Satz:  $H$  sei universell für  $m$ ,  $h \in H$  zufällig und gleichverteilt gewählt. Werden nun  $n \leq m$  Schlüssel mit  $h$  eingetriggt und ist  $x$  ein fester Schlüssel, so gilt

$$E(\# \text{Kollisionen mit } x) < 1.$$

Beweis: Für Schlüsselpaar  $y \neq z$  sei

$$C_{yz} = \begin{cases} 1 & \text{falls } h(y) = h(z) \leftarrow \text{W'keit} \leq \frac{1}{m} \\ 0 & \text{sonst} \leftarrow \text{---} \geq \frac{m-1}{m} \end{cases}$$

$$E(C_{yz}) \leq \frac{1}{m}$$

Sei  $C_x = \# \text{Kollisionen mit } x$ , d.h.

$$C_x = \sum_{y \neq x} C_{yx}$$

$$E(C_x) = E\left(\sum_{y \neq x} C_{yx}\right) = \sum_{y \neq x} E(C_{yx}) \leq \frac{m-1}{m} < 1 \quad \square$$

Angewendet auf Hashing mit chaining:

Mittlere Listlänge  $< 2$ .

$\Rightarrow$  worst case tritt im Erwartungswert nicht auf, Absicherung gegen bösen Gegenspieler klappt.

Zeige noch: Es gibt universelle Klasse von Hashfunktionen für beliebiges  $m$ :



Wähle dazu zunächst Primzahl  $p$   
mit  $p > x$  für alle  $x \in U$ .

Für beliebiges  $a \in \mathbb{Z}_p^* = \{1, \dots, p-1\}$  und  
 $b \in \mathbb{Z}_p = \{0, 1, \dots, p-1\}$  sei Hash-Fkt.  $h_{a,b}$   
wie folgt definiert:

$$h_{a,b}(x) = ((a \cdot x + b) \bmod p) \bmod m$$

Es sei  $H = \{h_{a,b} \mid a \in \mathbb{Z}_p^*, b \in \mathbb{Z}_p\}$

Bsp:  $p = 17$ ,  $m = 6$ ,  $a = 3$ ,  $b = 4$

$$h_{3,4}(8) = \underbrace{(3 \cdot 8 + 4) \bmod 17}_m \bmod 6 = 5$$

Satz:  $H$  ist universell bezüglich  $m$ .