


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:

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

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

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
$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$

Würfel 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	$\underbrace{s \dots s}_{i-1} w$	$p_i = q^{i-1} \cdot p$

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

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

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

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

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

(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 $\Omega(m)$

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 der 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. Wenn $u \in m$ Schlüssel mit h eingetriggt und x ein fester Schlüssel, so gilt

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

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 $C_x = \# \text{Kollision mit } x$, 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 .