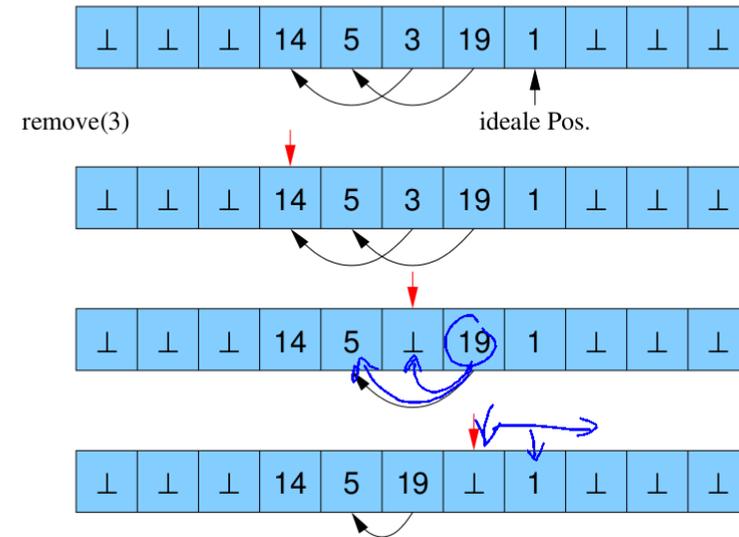
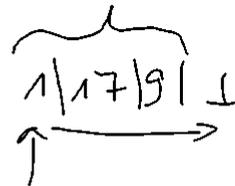


Hashing with Linear Probing

Löschen / Aufrechterhaltung der Invariante



Übersicht



5 Hashing

- Hashtabellen
- Hashing with Chaining
- Universelles Hashing
- Hashing with Linear Probing
- Anpassung der Tabellengröße
- Perfektes Hashing
- Diskussion / Alternativen

Dynamisches Wörterbuch

Problem: Hashtabelle ist **zu groß** oder **zu klein**
(sollte nur um konstanten Faktor von Anzahl der Elemente abweichen)

Lösung: Reallokation

- Wähle geeignete Tabellengröße
- Wähle neue Hashfunktion
- Übertrage Elemente auf die neue Tabelle

Dynamisches Wörterbuch

Problem: Tabellengröße m sollte **prim** sein (für eine gute Verteilung der Schlüssel)

Lösung:

- Für jedes k gibt es eine Primzahl in $[k^3, (k+1)^3]$
- Jede Zahl $z \leq (k+1)^3$, die nicht prim ist, muss einen Teiler $t \leq \sqrt{(k+1)^3} = (k+1)^{3/2}$ haben.
- Für eine gewünschte ungefähre Tabellengröße m' (evt. nicht prim) bestimme k so, dass $k^3 \leq m' \leq (k+1)^3$

Dynamisches Wörterbuch

- Hilfsmittel: Wachstum der harmonischen Reihe

$$\ln n \leq H_n = \sum_{i=1}^n \frac{1}{i} \leq 1 + \ln n$$

- insgesamt:

$$\begin{aligned} \sum_{2 \leq j \leq (k+1)^{3/2}} O\left(\frac{k^2}{j}\right) &\leq k^2 \sum_{2 \leq j \leq (k+1)^{3/2}} O\left(\frac{1}{j}\right) \\ &\in k^2 \cdot O(\ln((k+1)^{3/2})) \\ &\in O(k^2 \ln k) \in o(k^3 \log k) \in o(k) \\ &\in \underline{o(m)} \end{aligned}$$

⇒ Kosten zu vernachlässigen im Vergleich zur Initialisierung der Tabelle der Größe m (denn m ist kubisch in k)

Dynamisches Wörterbuch

Problem: Tabellengröße m sollte **prim** sein (für eine gute Verteilung der Schlüssel)

$$(a+b)^n = \binom{n}{0} a^n b^0 + \binom{n}{1} a^{n-1} b^1 + \dots$$

Lösung:

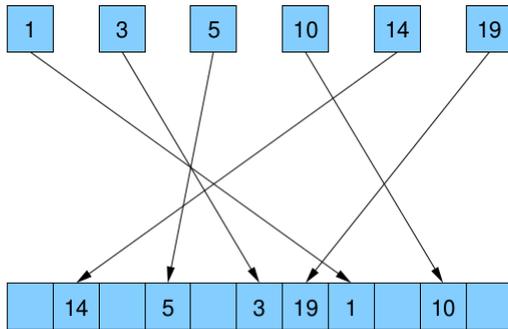
- Für jedes k gibt es eine Primzahl in $[k^3, (k+1)^3]$
- Jede Zahl $z \leq (k+1)^3$, die nicht prim ist, muss einen Teiler $t \leq \sqrt{(k+1)^3} = (k+1)^{3/2}$ haben.
- Für eine gewünschte ungefähre Tabellengröße m' (evt. nicht prim) bestimme k so, dass $k^3 \leq m' \leq (k+1)^3$
- Größe des Intervalls:
 $(k+1)^3 - k^3 + 1 = (k^3 + 3k^2 + 3k + 1) - k^3 + 1 = 3k^2 + 3k + 2$
- Für jede Zahl $j = 2, \dots, (k+1)^{3/2}$:
 streiche die Vielfachen von j in $[k^3, (k+1)^3]$ $\leftarrow o(k^2)$
- Für jedes j kostet das Zeit $((k+1)^3 - k^3 + 1) / j \in O(k^2/j)$

Übersicht

- 5 Hashing
 - Hashtabellen
 - Hashing with Chaining
 - Universelles Hashing
 - Hashing with Linear Probing
 - Anpassung der Tabellengröße
 - Perfektes Hashing
 - Diskussion / Alternativen

Perfektes Hashing für statisches Wörterbuch

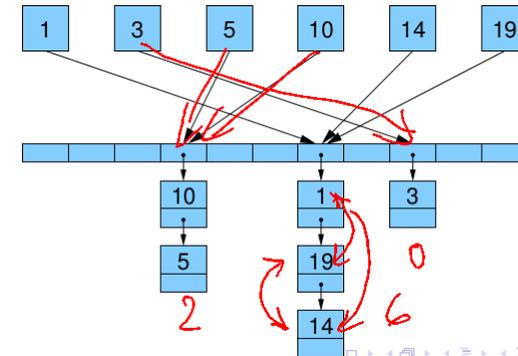
- bisher: konstante *erwartete* Laufzeit falls m im Vergleich zu n genügend groß gewählt wird (nicht ausreichend für Real Time Szenario)
- Ziel: konstante Laufzeit im **worst case** für find() durch perfekte Hashtabelle ohne Kollisionen
- Annahme: statische Menge S von n Elementen



Statisches Wörterbuch

- **S**: feste Menge von n Elementen mit Schlüssel k_1 bis k_n
- **H_m** : c -universelle Familie von Hashfunktionen auf $\{0, \dots, m-1\}$ (Hinweis: 2-universelle Familien existieren für alle m)
- **$C(h)$** für $h \in H_m$: Anzahl Kollisionen in S für h , d.h.

$$C(h) = |\{(x, y) : x, y \in S, x \neq y, h(x) = h(y)\}|$$



Beispiel:

$$C(h) = 2 + 6 = 8$$

Statisches Wörterbuch

Lemma

Es gilt

$$\mathbb{E}[C(h)] \leq cn(n-1)/m$$

Statisches Wörterbuch

Lemma

Es gilt

$$\mathbb{E}[C(h)] \leq cn(n-1)/m$$

Beweis.

- Definiere $n(n-1)$ Indikator-Zufallsvariablen $X_{ij}(h)$: Für $i \neq j$ sei $X_{ij}(h) = 1 \Leftrightarrow h(k_i) = h(k_j)$.
- Dann ist $C(h) = \sum_{i \neq j} X_{ij}(h)$

$$\mathbb{E}[C] = \mathbb{E}\left[\sum_{i \neq j} X_{ij}\right] = \sum_{i \neq j} \mathbb{E}[X_{ij}] = \sum_{i \neq j} \Pr[X_{ij} = 1] \leq \frac{n(n-1) \cdot c/m}{m} \in \Theta(n^2)$$

\Rightarrow Für **quadratische Tabellengröße** ist die erwartete Anzahl von Kollisionen (und damit die erwartete worst-case-Laufzeit für find) eine **Konstante**. □

Markov-Ungleichung

Satz (Markov-Ungleichung)

Für jede nichtnegative Zufallsvariable X und Konstante k gilt:

$$\Pr[X \geq k \cdot \mathbb{E}[X]] \leq \frac{1}{k}$$

Markov-Ungleichung

Satz (Markov-Ungleichung)

Für jede nichtnegative Zufallsvariable X und Konstante k gilt:

$$\Pr[X \geq k \cdot \mathbb{E}[X]] \leq \frac{1}{k}$$

Beweis.

$$\begin{aligned} \mathbb{E}[X] &= \sum_{z \in \mathbb{R}} z \cdot \Pr[X = z] \\ &\geq \sum_{z \geq k \cdot \mathbb{E}[X]} z \cdot \Pr[X = z] \geq \sum_{z \geq k \cdot \mathbb{E}[X]} k \cdot \mathbb{E}[X] \cdot \Pr[X = z] \\ &\geq k \cdot \mathbb{E}[X] \cdot \Pr[X \geq k \cdot \mathbb{E}[X]] \end{aligned}$$

Handwritten green notes: A green arrow points from the final inequality back to the definition of expectation. Another green arrow points from the final inequality to the handwritten note $\frac{1}{k} \geq \Pr[\dots]$ with a small square symbol at the end, indicating the proof is complete.

Statisches Wörterbuch

Lemma

Für mindestens **die Hälfte** der Funktionen $h \in H_m$ gilt:

$$C(h) \leq 2cn(n-1)/m$$