

Universelles Hashing

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:

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

Satz: Wählt man $h \in H$ zufällig und gleichverteilt und ist $n \leq m$, so ist
 $E(\# \text{Kollisionen mit } x) < 1$ für alle x .

Frage: Existiert so eine universelle Klasse H ?

Antwort: Ja

Wähle zunächst Primzahl $p \geq n \forall x$.

Für $a \in \mathbb{Z}_p^* = \{1, \dots, p-1\}$ und $b \in \mathbb{Z}_p = \{0, 1, \dots, p-1\}$ definiere

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

Satz: Dann ist $H = \{h_{a,b} \mid a \in \mathbb{Z}_p^*, b \in \mathbb{Z}_p\}$ universell bezüglich m .

Beweis: Betrachte zwei Schlüssel $x \neq y$ aus $\{0, \dots, p-1\}$ und $h_{a,b} \in H$. Definiere

$$\left. \begin{array}{l} r := a \cdot x + b \bmod p \\ s := a \cdot y + b \bmod p \end{array} \right\} (*)$$

Beh: $x \neq y \Rightarrow r \neq s$

Bew: Annahme: $r = s \Rightarrow a \cdot x + b \equiv a \cdot y + b \pmod{p}$
 $\stackrel{a \in \mathbb{Z}_p^*}{\implies} x \equiv y \pmod{p}$
 $\implies x = y. \quad \square$

Beh: a und b sind eindeutig durch x, y, r, s bestimmt.

Bew.: Aus (*) folgt

$$(r-s) \equiv a \cdot \underbrace{(x-y)}_{\in \mathbb{Z}_p^*} \pmod{p}$$

$$\implies a = (x-y)^{-1} \cdot (r-s) \in \mathbb{Z}_p$$

$$\text{Zu } b: r = a \cdot x + b \implies b = r - (x-y)^{-1} \cdot (r-s) \cdot x \quad \square$$

Es gibt $(p-1) \cdot p$ Möglichkeiten für die Wahl von a und b .

Es gibt $(p-1) \cdot p$ Paare $r, s \in \{0, \dots, p-1\}$ mit $r \neq s$.

\implies Es gibt Bijektion zwischen möglichen Paaren (a, b) und (r, s) .

\implies Wählt man eine zufällige Hashfkt. aus H , also ein zufälliges Paar (a, b) , so erhält man ein zufälliges Paar (r, s) .

Es gilt:

$$\Pr(h_{a,b}(x) = h_{a,b}(y)) = \Pr(r \equiv s \pmod{m})$$

Für festes r gibt es $\leq \left\lceil \frac{p}{m} \right\rceil - 1$
mögliche $s \neq r$ mit $r \equiv s \pmod{m}$.
Es gilt

$$\left\lceil \frac{p}{m} \right\rceil - 1 \leq \frac{p+m-1}{m} - 1 = \frac{p-1}{m}$$

Daraus folgt: Die W'keit dafür,
dass ein zufälliges $s \in \{0, \dots, p-1\} \setminus \{r\}$ zu
einer Kollision führt ist $\leq \frac{1}{m}$.

$\Rightarrow H$ ist universell bezüglich m . \square

Perfektes Hashing:

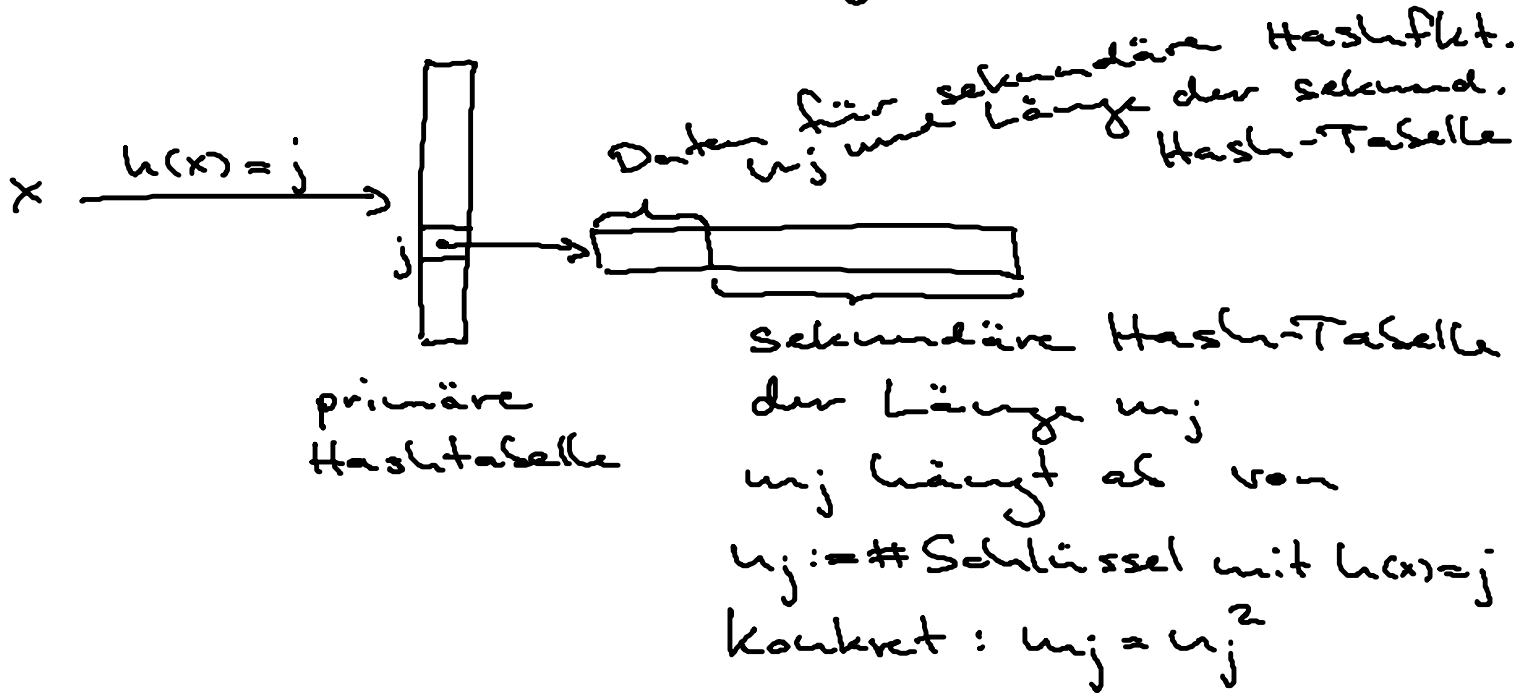
Nehme an, dass Schlüsselmenge
statisch und a priori bekannt ist:

- z.B.:
- reservierte Worte in Java
(Compiler verwendet Hashing)
 - Namen aller Dateien auf DVD.

Ziel: Verbessere Worst-Case Aufwand
für die Suche (im Mittel Aufwand $O(n)$).

Def.: Ein Hashing-Verfahren heißt
perfekt \Leftrightarrow Worst Case Aufwand für
das Suchen ist $O(1)$.

Wir realisieren ein solches Hashing-Verf. mittels eines zweistufigen Verfahrens.



Bem.: m_j kann man vorab (nach Wahl von h) bestimmen, da alle Schlüssel bekannt.

Primäre Hashfkt. h und sekundäre Hashfkt. $h_j, j=1, \dots, m$, sind aus universeller Klasse gewählt.

Konkret:

$$h(x) = ((a \cdot x + b) \bmod p) \bmod m$$

$$\uparrow \in H_{p,m}$$

Länge primärer Hash-Tabelle
 \downarrow

Primzahl $> x \forall$ Schlüssel x

$$h_j(x) = ((a_j \cdot x + b_j) \bmod p) \bmod m_j$$

$$\uparrow \in H_{p, m_j}$$

$$m_j = u_j^2$$

Spezialfall: Falls $u_j = 1$, wähle $a_j = b_j = 0$,
 $m_j = u_j^2 = 1$

Zwei mögliche Probleme:

A: Wie stellt man sicher, dass beim sekundären Hashing keine Kollision auftritt?

B: Kann der benötigte Speicherplatz sinnvoll beschränkt werden?

zu A:

Satz: (Eigenschaft der sek. Hashfkt mit $u = u_j$,
 $u = u_j$)
 u Schlüssel werden mit zufällig gewählten Hashfkt. $h \in H_{p, m}$ in Hash-Tabelle der Länge $m = u^2$ gespeichert. Dann ist die Wahrscheinlichkeit dafür, dass eine Kollision auftritt $< \frac{1}{2}$.

Dieser Satz besagt, dass bei wiederholten zufälliger Wahl von $h \in H_{p,m}$ nach wenigen Wiederholungen eine kollisionsfreie Hashfkt. gefunden wird.
mit großer Wahrscheinlichkeit.

Beweis des Satzes:

Es gibt $\binom{m}{2}$ mögliche Kollisionen.

$H_{p,m}$ universell $\Rightarrow x \neq y$ kollidieren mit
W'keit $\leq \frac{1}{m}$.

Sei X Anzahl der Kollisionen, dann gilt

$$\begin{aligned} E(X) &= E\left(\sum_{x \neq y} C_{x,y}\right) = \sum_{x \neq y} E(C_{x,y}) \leq \binom{m}{2} \cdot \frac{1}{m} \\ &= \frac{m \cdot (m-1)}{2} \cdot \frac{1}{m} < \frac{1}{2} \end{aligned}$$

Markov'sche Ungleichung:

Für eine Zufallsgröße $X \geq 0$ und
Zahl $t > 0$ gilt:

$$\Pr(X \geq t) \leq \frac{E(X)}{t}$$

In unserem Fall:

$$\Pr(X \geq 1) \leq \frac{E(X)}{1} < \frac{1}{2} \quad \square$$

→ Problem A gelöst!
