
Effiziente Algorithmen und Datenstrukturen I

Letzter Abgabetermin: 25. November 2002 (vor der Übung)

Aufgabe 1

In dieser Aufgabe soll eine Folge S von Zahlen aus $[0..999]$ in eine Hash-Tabelle der Größe n eingetragen werden. Hierbei wird offenes Hashing mit den drei folgenden Hashfunktionen verwendet.

$$\begin{aligned}h_1(x, i) &= (x + i) \bmod n \\h_2(x, i) &= (x + i^2) \bmod n \\h_3(x, i) &= (x + i \cdot (1 + (x \bmod (n - 1)))) \bmod n\end{aligned}$$

Geben Sie für die folgenden Belegungen von n und S , jeweils für alle Hashfunktionen, die resultierende Hash-Tabelle sowie die Anzahl der auftretenden Kollisionen beim Einfügen von S in eine anfangs leere Hash-Tabelle an. Begründen Sie, warum die Funktion h_2 als Hashfunktion ungeeignet ist.

n	S
10	253, 401, 5, 693, 75, 134, 713
15	914, 811, 2, 87, 898, 933, 222, 563, 719, 781, 256, 938
20	56, 39, 61, 371, 287, 896, 603, 290, 678, 856, 600, 778, 671, 500, 998, 644, 418

Aufgabe 2

Im Folgenden werde für das offene Hashing ein Array T der Länge m betrachtet, in dem $n < m$ Werte gespeichert sind. Es gelte die Annahme, dass die Sequenz $[h(x, i)]$ mit $i = 0, 1, \dots, m - 1$ eine zufällige Permutation über der Menge $\{0, 1, \dots, m - 1\}$ ist. Die Kosten für die Operation $\text{INSERT}(x)$ sei $1 + \min\{i \mid T[h(x, i)] \text{ noch nicht besetzt}\}$.

Zeigen Sie folgende Aussage:

Die erwarteten Kosten für eine INSERT-Operation in eine Hash-Tabelle mit Füllgrad $\beta = \frac{n}{m} < 1$ ist $\frac{m+1}{m-n+1} \approx \frac{1}{1-\beta}$.

Aufgabe 3

Es gelten die Voraussetzungen aus Aufgabe 2. Zeigen Sie nun folgende Behauptung.

Die erwarteten Kosten für eine erfolgreiche SEARCH-Operation in einer Hash-Tabelle mit Füllgrad $\beta = \frac{n}{m}$ ist $\mathcal{O}\left(\frac{1}{\beta} \log\left(\frac{1}{1-\beta}\right)\right)$.

Hinweis: Die Aussage aus Aufgabe 2 kann zur Lösung dieser Aufgabe verwendet werden.

Aufgabe 4

Sei $\text{rep}_s : \{0,1\}^s \rightarrow [0 .. 2^s - 1]$ (mit $s \in \mathbb{N}$) die Funktion, die einen binären Vektor der Länge s auf die Zahl aus \mathbb{Z} abbildet, die entsteht, wenn man den Vektor als Binärzahl interpretiert, d.h. $\text{rep}_s(a_{s-1}, \dots, a_0) = \sum_{i=0}^{s-1} a_i 2^i$.

Sei $N = 2^r$. Die Grundmenge $[0 .. m - 1]$ soll in einer Hash-Tabelle der Größe $m = 2^s$ gespeichert werden sollen. Die Hashfunktion $h_A : [0 .. N - 1] \rightarrow [0 .. m - 1]$ ist, für eine $s \times r$ Matrix A mit Einträgen aus $\{0,1\}$, definiert als $h_A(x) = \text{rep}_s(A \cdot \text{rep}_r^{-1}(x))$, d.h. $h_A(x)$ berechnet das Matrixprodukt (über den Körper \mathbb{Z}_2) von A und dem Ziffernvektor der Binärdarstellung von x und interpretiert das Ergebnis als Binärzahl. Die Menge $\mathcal{H} = \{h_A \mid A \in \{0,1\}^{s \times r}\}$ beinhalte alle diese Funktionen.

In der Vorlesung wurde eine Menge \mathcal{F} von Hashfunktionen $f : [0 .. N - 1] \rightarrow [0 .. m - 1]$ als universell definiert, wenn für alle Werte $x, y \in [0 .. N - 1]$ mit $x \neq y$ gilt:

$$|\{f \in \mathcal{F} \mid f(x) = f(y)\}| \leq \frac{|\mathcal{F}|}{m}$$

a) Zeigen Sie, dass \mathcal{H} eine universelle Menge von Hashfunktionen ist.

Hinweis: Seien $x, y \in [0 .. N - 1]$ mit $x \neq y$. Dann gilt $h_A(x) = h_A(y)$ genau dann, wenn $A(\vec{x} - \vec{y}) = 0$ (mit $\vec{x} = \text{rep}_r^{-1}(x)$ und $\vec{y} = \text{rep}_r^{-1}(y)$). Da die Vektoren der Dimension r einen Vektorraum über \mathbb{Z}_2 bilden, kann man aus $A(\vec{x} - \vec{y}) = 0$ schließen, dass alle Zeilen von A orthogonal zu $\vec{x} - \vec{y}$ sind.

b) Sei $S \subseteq [0 .. N - 1]$, $|S| = n$ und $x \in [0 .. N - 1]$. Berechnen Sie mittels des Ergebnisses aus Teilaufgabe a) den Erwartungswert

$$\mu = \frac{\sum_{h \in \mathcal{H}} \delta_h(x, S)}{|\mathcal{H}|}$$

für die erwartete Anzahl der Kollisionen $\delta_h(x, S)$, die beim Einfügen von x in eine Hash-Tabelle (in der bereits die Menge S gespeichert ist) auftreten, wenn die zufällig gewählte Hashfunktion $h \in \mathcal{H}$ verwendet wird.