

# Proseminar WS 2016/2017

## Bloom-Filter

**Gegeben:** Eine Menge  $M$  natürlicher Zahlen und  $n \in \mathbb{N}$ .

**Gesucht:** Prüfe in konstanter Zeit, ob  $n \in M$  gilt.

**Naive Methode:** Ist  $N$  die größte Zahl in  $M$ , so erzeugen wir ein Bitarray  $A_M$  der Größe  $N$ . Für  $m = 1, \dots, N$  gilt

$$A_M[m] = \begin{cases} 1, & \text{wenn } m \in M \\ 0, & \text{sonst.} \end{cases}$$

Es gilt  $n \in M \iff A[n] = 1$  gilt.

**Bemerkung:** Je größer  $N$  wird, desto mehr Speicherplatz benötigen wir mit der naiven Methode. Daher benötigen wir eine effizientere Datenstruktur.

**Bloom-Filter:** Seien  $\phi_1, \dots, \phi_k$ ,  $k$ -verschiedene Hashfunktionen (mit gewissen Eigenschaften) und  $A_M$  ein Bitarray der Größe  $l \in \mathbb{N}$ ,  $l \approx |M|^2$ . Für alle  $m \in M$  und  $j = 1, \dots, l$  gilt

$$A_M[j] = 1 \iff \exists m \in M \text{ mit } \phi_i(m) = j.$$

Die Frage ob  $n \in M$  ist, können wir mit einer gewissen Wahrscheinlichkeit ebenfalls in konstanter Zeit beantworten. Ist jedoch  $A_M[\phi_i(n)] = 0$  für ein  $i \in \{1, \dots, k\}$ , so können wir sicher sein, dass  $n$  kein Element aus  $M$  ist.

**Fazit:** Ist  $N \gg |M|$ , so hat die naive Methode erhebliche Nachteile gegenüber dem Bloom-Filter, der unabhängig von  $N$  ist.

In Ihrer Ausarbeitung geht es darum, die nötige Theorie zu entwickeln, um den Bloom-Filter zu beschreiben.

Empfohlene Literatur:

- U. Schöning. Skript zu Algorithmen und Datenstrukturen
- M. Mitzenmacher, E. Upfal. Probability and Computing.