

Sia  $\mathcal{U}$  un insieme con  $|\mathcal{U}| = m \gg 1$ . Consideriamo una tabella hash  $T$  di dimensione  $n > 1$  ed una funzione di hash  $h : \mathcal{U} \rightarrow \{0, \dots, n-1\}$ . Supponiamo di memorizzare  $S \subseteq \mathcal{U}$  nella tabella hash usando la funzione  $h$ . Ovvero, memorizziamo ogni  $u \in S$  nella posizione  $h(u)$  di  $T$ . In un'analisi di caso peggiore, ogni ulteriore operazione (ricerca, inserimento o cancellazione) sulla tabella richiederà tempo  $\ell_{\max}$ , dove  $\ell_{\max}$  è il massimo numero di elementi in  $S$  che sono stati mappati da  $h$  nella stessa posizione di  $T$ . Più precisamente,

$$\ell_{\max} = \max_{i=0, \dots, n-1} |\{u \in S : h(u) = i\}|.$$

Idealmente, vorremmo avere  $\ell_{\max} \simeq |S|/n$ , in modo da minimizzare il tempo di esecuzione di un'operazione nel caso peggiore. Vediamo ora come ottenere questo risultato, in valore atteso, tramite la tecnica dello hashing universale.

Una collezione  $\mathcal{H}$  di funzioni  $h : \mathcal{U} \rightarrow \{0, \dots, n-1\}$  è detta una *famiglia universale di funzioni hash* quando

1. Per ogni  $u, v \in \mathcal{U}$  vale  $\mathbb{P}(H(u) = H(v)) \leq \frac{1}{n}$  dove la probabilità è calcolata rispetto all'estrazione casuale della funzione hash  $H$  da  $\mathcal{H}$ .
2. Ogni  $h \in \mathcal{H}$  può essere rappresentata con al più  $\Theta(\log m)$  bit e calcolata in modo efficiente.

Si noti che la condizione 1 è sufficiente a garantire  $\ell_{\max} \leq |S|/n$  in valore atteso rispetto all'estrazione di  $H$  da  $\mathcal{H}$ . Infatti, supponiamo di aver estratto  $H$  a caso da  $\mathcal{H}$  e di averla usata per inserire  $S = \{u_1, \dots, u_s\}$  nella tabella. Sia  $u \in \mathcal{U}$  un elemento arbitrario che vogliamo aggiungere alla tabella. Definiamo le variabili casuali  $X_1, \dots, X_s$  dove

$$X_i = \begin{cases} 1 & \text{se } H(u) = H(u_i) \\ 0 & \text{altrimenti.} \end{cases}$$

Allora, il numero di elementi di  $S$  che sono mappati nella stessa posizione di  $u$  è dato da

$$\sum_{i=1}^s X_i.$$

Il valore atteso di questo numero è calcolato come

$$\begin{aligned}
\mathbb{E} \left[ \sum_{i=1}^s X_i \right] &= \sum_{i=1}^s \mathbb{E} X_i \quad \text{per linearità del valore atteso} \\
&= \sum_{i=1}^s \mathbb{P}(H(u) = H(u_i)) \quad \text{per definizione di } X_i \\
&\leq \sum_{i=1}^s \frac{1}{n} \quad \text{per ipotesi su } H \\
&= \frac{|S|}{n} .
\end{aligned}$$

Ma è possibile trovare classi  $\mathcal{H}$  che soddisfano la condizione 1? Per verificarlo, assumiamo per semplicità che  $\mathcal{U} = \{1, \dots, m\}$  e consideriamo la classe  $\mathcal{H}$  di tutte le funzioni  $h : \{1, \dots, m\} \rightarrow \{0, \dots, n-1\}$ . Ognuna di queste funzioni hash corrisponde a un vettore  $\mathbf{h} = (\mathbf{h}_1, \dots, \mathbf{h}_m) \in \{0, \dots, n-1\}^m$  in modo che  $h(u) = \mathbf{h}_u$ . Allora, il numero di vettori  $\mathbf{h} \in \{0, \dots, n-1\}^m$  tali che  $\mathbf{h}_u = \mathbf{h}_v$  è  $n^{m-1}$ . Quindi, se estraggo  $H$  a caso da  $\mathcal{H}$ ,

$$\mathbb{P}(H(u) = H(v)) = \frac{n^{m-1}}{n^m} = \frac{1}{n}$$

e la condizione 1 è soddisfatta. D'altra parte, la condizione 2 non è soddisfatta in quanto mi servono  $\log |\mathcal{U}| = m \log n$  bit per descrivere ciascuna  $h \in \mathcal{H}$ . Vediamo ora un modo per costruire  $\mathcal{H}$  che soddisfi 1 e 2.

Per semplicità, assumiamo  $\mathcal{U} = \{1, \dots, m\}$  e anche  $n = p$  per un qualche  $p$  primo. Rappresentiamo ciascun elemento  $u \in \{1, \dots, m\}$  come un numero  $[u]_p$  in base  $p$ . Ovvero,  $[u]_p = x = (x_1, \dots, x_r)$  dove  $x_i \in [0, \dots, p-1]$  e  $r$  è il più piccolo intero tale che  $p^r \geq m$ . Ovvero,

$$r = \left\lceil \frac{\log m}{\log p} \right\rceil .$$

Sia  $\mathcal{A} = \{0, \dots, p-1\}^r$  l'insieme usato per rappresentare gli elementi di  $\mathcal{U}$ . Introduciamo ora la famiglia di funzioni hash  $\mathcal{H} = \{h_a : a \in \mathcal{A}\}$  di tipo  $h_a : \mathcal{A} \rightarrow \{0, \dots, p-1\}$  e definite come

$$h_a(x) = \left( \sum_{i=1}^r a_i x_i \right) \mod p .$$

Si noti che posso rappresentare ogni  $h_a$  con  $\Theta(\log m)$  bit, quindi la condizione 2 è soddisfatta. Per verificare la condizione 1 utilizziamo il lemma seguente.

**Lemma 1** *Per ogni primo  $p$ , per ogni  $\alpha, \beta$  e  $z$  interi,*

$$z \not\equiv 0 \mod p \quad e \quad \alpha z \equiv \beta z \mod p \quad \text{implicano} \quad \alpha \equiv \beta \mod p .$$

**DIMOSTRAZIONE.** Chiaramente,  $\alpha z \equiv \beta z \mod p$  se e solo se  $z(\alpha - \beta) \equiv 0 \mod p$ . Inoltre,  $z \not\equiv 0 \mod p$  e  $z(\alpha - \beta) \equiv 0 \mod p$  implicano  $(\alpha - \beta) \equiv 0 \mod p$ . Infatti, se  $p$  è primo e  $z$  non contiene  $p$

come fattore, allora  $\alpha - \beta$  lo deve contenere (se invece  $p$  non fosse primo, allora  $z$  e  $\alpha - \beta$  potrebbero spartirsi i fattori primi di  $p$ ).  $\square$

Siamo ora pronti a dimostrare che per  $\mathcal{H}$  vale la proprietà 1. Dato che, come abbiamo già osservato, per la stessa classe valeva anche la proprietà 2, concludiamo che  $\mathcal{H}$  è una famiglia universale di funzioni hash.

**Teorema 2**  *$\mathcal{H}$  è tale che per ogni  $x, y \in \mathcal{A}$  distinti, la frazione di elementi  $a \in \mathcal{A}$  tali che  $h_a(x) = h_a(y)$  è al più  $\frac{1}{p}$ . Quindi, se  $H$  è estratta a caso da  $\mathcal{H}$ , allora*

$$\mathbb{P}(H(x) = H(y)) \leq \frac{1}{p} .$$

**DIMOSTRAZIONE.** Se  $x \neq y$  allora esiste almeno una coordinata  $j \in \{0, \dots, r\}$  tale che  $x_j \neq y_j$ . Per estrarre  $H$  a caso in  $\mathcal{H}$  prendiamo  $a \in \mathcal{A}$  estraendo a caso ciascuna coordinata  $a_i \in \{0, \dots, p-1\}$ . Per qualunque estrazione dei valori  $a_i$  sulle coordinate  $i \neq j$ , abbiamo che

$$\begin{aligned} h_a(x) = h_a(y) &\iff \left( \sum_{i=1}^r a_i x_i \equiv \sum_{i=1}^r a_i y_i \right) \pmod{p} \\ &\iff a_j \underbrace{(x_j - y_j)}_z \equiv \underbrace{\sum_{i: i \neq j} a_i (x_i - y_i)}_k \pmod{p} \\ &\iff a_j z \equiv k \pmod{p} . \end{aligned}$$

Dimostriamo ora che esiste un unico  $a_j \in \{0, \dots, p-1\}$  tale che la congruenza  $a_j z \equiv k \pmod{p}$  sia soddisfatta. Per assurdo, supponiamo che esistano  $a_j, a'_j$  distinti che soddisfano entrambi la congruenza. Allora avremmo anche che  $a_j z \equiv a'_j z \pmod{p}$ . Dato che  $z \not\equiv 0 \pmod{p}$  per ipotesi, il lemma implica che  $a_j \equiv a'_j \pmod{p}$ . Siccome  $0 \leq a_j, a'_j < p$ , ciò implica che  $a_j = a'_j$  e si ha una contraddizione. Quindi c'è un solo valore della coordinata  $j$  che rende  $h_a(x) = h_a(y)$ . La probabilità di estrarre questo valore è al più  $\frac{1}{p}$ . Se  $x$  e  $y$  differiscono su altre coordinate, allora la probabilità che  $h_a(x) = h_a(y)$  diventa ancora più piccola.  $\square$