

Komentáře k páté sérii třicátého osmého ročníku KSP

38-5-S Hešování řetězců

Úkol 5: Izomorfismus – více dětí

Jedna z oblíbených hešovacích funkcí spočítala heš rodiče z kódů synů $x_1, \dots, x_k$ jako:

$$\sum_{i=1}^k h(x_i) \bmod p$$

kde h je náhodná hešovací funkce do $\mathbb{Z}_p$, kterou jsme dostali v zadání.

Ačkoliv by výše popsaná hešovací funkce fungovala, tak dokázat to o ní se nikomu nepovedlo. Nabízí se totiž velmi jednoduchý (avšak falešný) důkaz jak omezit pravděpodobnost kolize:

Uvažme dva vrcholy s kódy synů $x_1, \dots, x_k$ a $y_1, \dots, y_\ell$:

$$\sum_{i=1}^k h(x_i) \equiv \sum_{i=1}^{\ell} h(y_i) \pmod{p}$$

$$\sum_{i=1}^k h(x_i) - \sum_{i=1}^{\ell-1} h(y_i) \equiv h(y_\ell) \pmod{p}$$

Zafixujeme-li $x_1, \dots, x_k$ a $y_1, \dots, y_{\ell-1}$, tak nám to dává jednu hodnotu, do které se $h(y_\ell)$ musí strejit, aby nastala kolize. A protože je h dokonale náhodná, tak pravděpodobnost kolize je $1/p$.

Nicméně tohle nefunguje. Problém je, že jednotlivé x_i a y_i nejsou nezávislé, a tím, že jsme zafixovali část z nich, jsme už mohli předurčit hodnotu $h(y_\ell)$. Např. když levý podstrom je třívrcholová cesta a pravý dvouvrcholová, tak při výpočtu heše levé cesty $h(h(0))$ jsme už použili hodnotu heše pravé $h(0)$. Obecně se jednotlivé podstromy mohou složitě překrývat, a proto není možné v důkazu používat nezávislost.

Daniel Skýpala