

1. [Karetní hra (10 bodů)] V balíku je  $n$  černých karet a  $n$  červených, balík je rovnoměrně náhodně zamíchaný. Ve hře máte následující akce:

- vzít další kartu
- ukončit hru

Začínáte s 0 body. Za každou vzatou červenou kartu dostanete jeden bod, za každou černou ztratíte jeden bod.

- Jaká je nejvyšší střední hodnota výhry pro  $n = 1, 2, 3, 4$ ?
- Popište efektivní algoritmus, který na vstupu dostane  $n$  a určí střední hodnotu výhry a optimální strategii.

2. [Vlastní čísla bipartitní kliky (10 bodů)] Určete vlastní čísla matic sousednosti úplného bipartitního grafu  $K_{m,n}$  (jedna partita má  $n$  vrcholů, druhá  $m$  vrcholů).

3. [Nejdelší orientovaná procházka (10 bodů)]

- Popište silně souvislý orientovaný graf na  $n$  vrcholech, který bude mít co největší hitting time mezi nějakými dvěma vrcholy (*existují* v něm vrcholy  $u, v$ , že střední doba náhodné procházkы z  $u$  do  $v$  je veliká).
- Nápočeda: zkuste například orientovanou cestu rozdělit graf na tři množiny, kde v prvních dvou půjde hrana do počátečního vrcholu, ve třetí půjdou do všech vrcholů první množiny. Za jiné lepší konstrukce můžete dostat bonusové body.
- Zkuste udělat co nejlepší horní odhad na hitting time mezi dvěma vrcholy silně souvislého orientovaného grafu na  $n$  vrcholech. I za triviální (konečný) horní odhad s důkazem budou body.

4. [Streamovací algoritmus na  $k$ -tý moment (30 bodů)]

Připomenutí definic: Uvažujeme algoritmy, které počítají na vstupu  $\sigma = a_1, a_2, \dots, a_m$  kde jednotlivé tokeny jsou čísla  $a_i \in \{1, 2, \dots, n\}$ . Stream dostáváme postupně (online) a chceme spočítat nějakou funkci ze streamu v co nejmenším prostoru vzhledem k  $n, m$  a případně dalším parametry.  $\mathcal{A}(\sigma)$  nechť je výstup randomizovaného streamovacího algoritmu na vstupním streamu  $\sigma$ , který má počítat funkci  $\varphi(\sigma)$ . Řekneme, že  $\mathcal{A}$   $(\varepsilon, \delta)$ -aproximuje  $\varphi$ , pokud:

$$\Pr \left[ \left| \frac{\mathcal{A}(\sigma)}{\varphi(\sigma)} - 1 \right| \geq \varepsilon \right] \leq \delta$$

Někdy nás zajímá nějaká statistika  $\sigma$  jako multimnožiny, pak definujeme frekvenční vektor  $\vec{f} = f_1, f_2, \dots, f_n$  takto:  $f_j = |\{i \mid a_i = j\}|$  (počet výskytů  $j$  v  $\sigma$ ).

Pro  $k \in \mathbb{N}$  definujeme  $k$ -tý moment  $F_k = \sum_{j=1}^n f_j^k = \|f\|_k^k$ . Uvažme algoritmus 11, který má approximovat  $F_k$ , a jeho několik vylepšení:

- Ukažte, že algoritmus je ekvivalentní tomuto:
  - Vyberte jednu hodnotu tokenu  $a \in [n]$  s pravděpodobností  $\Pr[a = j] = f_j/m$  pro každé  $j \in [n]$ .
  - Vyberte jeden výskyt  $a$  ze všech  $f_a$  uniformně náhodně.
- Nechť  $X$  je náhodná proměnná – výstup algoritmu,  $A$  a  $R$  nechť jsou náhodné proměnné určující  $a, r$  z algoritmu po zpracování  $\sigma$ . Ukažte (první pomocí teleskopické sumy):

$$\mathbb{E}[X \mid A = j] = \frac{m}{f_j} (f_j^k - 0^k)$$

$$\mathbb{E}[X] = F_k$$

- Ukažte, že  $\text{Var}[X] \leq \mathbb{E}[X^2] = m \sum_{j=1}^n \sum_{i=1}^{f_j} (i^k - (i-1)^k)^2$

---



---

```

Vstup      : stream  $\sigma$ 
Výstup     : odhad  $F_k$ 
Inicializace:
1  $m = 0$ 
2  $r = 0$ 
3  $a = 0$ 
Zpracuj    : zpracování tokenu  $j$ 
4  $m = m + 1$ 
5  $\beta = \text{random bit with } \Pr[\beta = 1] = \frac{1}{m}$ 
6 if  $\beta == 1$  then
7    $a = j$ 
8    $r = 0$ 
9 if  $a == j$  then
10   $r = r + 1$ 
11 return  $m(r^k - (r - 1)^k)$ 

```

---

- Pomocí  $x^k - (x - 1)^k \leq kx^{k-1}$  (pro  $x \geq 1$ ) ukažte:

$$\text{Var}[X] \leq kF_1 F_{2k-1}$$

- Nechť  $n > 0$ ,  $x_1, \dots, x_n \geq 0$ ,  $k \geq 1$  jsou reálná čísla. Ukažte, že pro  $x_* = \max\{x_i\}$ :

$$x_*^{k-1} \leq \left( \sum x_i^k \right)^{\frac{k-1}{k}}$$

$$\frac{1}{n} \sum x_i \leq \left( \frac{1}{n} \sum x_i^k \right)^{1/k}$$

a z toho hlavní mezivýsledek

$$\left( \sum x_i \right) \left( \sum x_i^{2k-1} \right) \leq n^{1-\frac{1}{k}} \left( \sum x_i^k \right)^2$$

Tedy:  $\text{Var}[X] \leq kn^{1-\frac{1}{k}} F_k^2$

- Nemůžeme použít Čebyševovu nerovnost rovnou, ale můžeme napřed průměrovat a pak použít trik s mediánem.

Formálně: nechť  $X$  je náhodná proměnná taková, že  $\mathbb{E}[X] = Q$ . Nechť  $\{X_{i,j}\}_{i \in [t], j \in [k]}$  jsou nezávislé náhodné proměnné distribuované jako  $X$ , kde

$$t = c \log \frac{1}{\delta}$$

$$k = \frac{3 \text{Var}[X]}{\varepsilon^2 \mathbb{E}[X]^2}$$

Nechť  $Z = \text{median}_{i \in [t]} \left( \frac{1}{k} \sum_{j=1}^k X_{i,j} \right)$  pak máme  $\Pr[|Z - Q| \geq \varepsilon Q] \leq \delta$  (použijte Čebyševovu a Černovovu nerovnost).

- Kolik paměti používá tento výsledný algoritmus, který  $(\varepsilon, \delta)$ -aproxiimuje  $F_k$ ?