

8. cvičení

Datové struktury I, 20. 11. 2023

<https://iuuk.mff.cuni.cz/~chmel/2324/ds1/>

Úloha 1 (Lehké opakování pravděpodobnosti)

Matt střílí, a snaží se trefit se do terče. Protože je začátečník, pravděpodobnost, že se trefí, je $p \in (0, 1]$, a je nezávislá na jakýchkoliv jeho předchozích pokusech. Nechť X je náhodná veličina, která označuje počet pokusů do Mattovy první trefy (včetně). Ukažte, že $\mathbb{E}[X] = \frac{1}{p}$.

Řešení

Z definice: $\mathbb{E}[X] = p + (1 - p)(1 + \mathbb{E}[X]) = 1 + (1 - p)\mathbb{E}[X] \rightsquigarrow p\mathbb{E}[X] = 1 \rightsquigarrow \mathbb{E}[X] = \frac{1}{p}$.

Úloha 2 (Pravděpodobnost kolize)

Ukažte, že v hashovací tabulce velikosti $m = n^2$ s n prvky dojde ke kolizi s pravděpodobností maximálně $\frac{1}{2}$, předpokládáme-li zcela náhodnou hashovací funkci. (Zkuste to dokázat bez použití přímo padnoucího pozorování z přednášky.)

Řešení

$P[\text{kolize}] = P[\exists i \neq j \in [n] : h(i) = h(j)] = P[\bigcup_{i \neq j \in [n]} (h(i) = h(j))] \leq \sum_{i \neq j \in [n]} P[(h(i) = h(j))] = \binom{n}{2} \cdot \frac{1}{m}$

Úloha 3 (Pevné body permutací)

Mějme uniformně náhodnou permutaci na n prvcích. Určete střední hodnotu počtu pevných bodů této permutace.

Řešení

Použijeme indikátory: je-li F náhodná veličina určující počet pevných bodů náhodné permutace, můžeme psát $F = I_1 + I_2 + \dots + I_n$, kde I_ℓ je indikátor jevu, že $\pi(\ell) = \ell$. Pak $\mathbb{E}[F] = \mathbb{E}[I_1 + I_2 + \dots + I_n] = \mathbb{E}[I_1] + \mathbb{E}[I_2] + \dots + \mathbb{E}[I_n]$ z linearity střední hodnoty, a $\mathbb{E}[I_\ell] = \frac{(n-1)!}{n!} = \frac{1}{n}$, a tedy $\mathbb{E}[F] = 1$.

Úloha 4 (Nezávislost a univerzalita)

Dokažte následující:

- pokud je systém hashovacích funkcí (k, c) -nezávislý, je také $(k - 1, c)$ -nezávislý (pro $k \geq 2$),
- pokud je systém hashovacích funkcí $(2, c)$ -nezávislý, je též c -univerzální.

Řešení • Chceme ukázat $(k - 1, c)$ -nezávislost, tedy máme dané $x_1, \dots, x_{k-1} \in \mathcal{U}, a_1, \dots, a_{k-1} \in [m]$. Zvolme si dále $x \neq x_i \forall i \in [k - 1]$ (takové existuje z k -nezávislosti). Chceme $\Pr_h[h(x_1) = a_1 \wedge \dots \wedge h(x_{k-1}) = a_{k-1}] = \sum_{a \in [m]} \Pr_h[h(x_1) = a_1 \wedge \dots \wedge h(x_{k-1}) = a_{k-1} \wedge h(x) = a] \leq \sum_{a \in [m]} \frac{c}{m^k} = \frac{c}{m^{k-1}}$.

- Mějme tedy $x \neq y \in \mathcal{U}$. Chceme omezit shora $\Pr_h[h(x) = h(y)] = \sum_{a \in [m]} \Pr_h[h(x) = a \wedge h(y) = a] \leq \sum_{a \in [m]} \frac{c}{m^2} = \frac{c}{m}$.

Úloha 5 (Černá krabička)

Dostali jste hashovací funkci $h : \mathcal{U} \rightarrow [m]$. Pokud o této funkci nevíte nic dalšího, kolik vyhodnocení funkce potřebujete, abyste zaručeně našli k -tici prvků, které se všechny zobrazí do téže přihrádky?

Řešení

Princip holubníku: máme m děr, v každé je $k - 1$ holubů, a ještě jeden pokus navíc nám garantuje, že se už opravdu někam musíme trefit, tedy $1 + m(k - 1)$.

Úloha 6 (Vyložene praktické systémy)

Uvažme systém funkcí $\mathcal{H}_1 = \{\text{id}\}$, který obsahuje jedinou funkci, jež zobrazí x na x . Je \mathcal{H}_1 c -univerzální pro nějaké c ? Je \mathcal{H}_1 (k, c) -nezávislý pro nějaká k a c ?

Dále uvažme systém $\mathcal{H}_2 = \{h_a(x) = a : a \in [m]\}$. Dokažte, že tento systém je $(1, 1)$ -nezávislý. Dále ukažte, že \mathcal{H}_2 není $(2, c)$ -nezávislý ani c -univerzální pro žádné c .

Řešení

\mathcal{H}_1 je ε -univerzální pro každé $\varepsilon > 0$. Problém je, že $\Pr[h(x) = x] = 1$, a tedy, pokud $|\mathcal{U}| > 1$, pak nemůže být jakkoliv nezávislá.

U druhého systému: (1,1)-nezávislost plyne z toho, že $\Pr[h_a(x) = b] = \frac{1}{m}$, protože volíme jednu konkrétní volbu a . Na druhou stranu, pro $x \neq y$ máme $\Pr[h_a(x) = b \wedge h_a(y) = b] = \frac{1}{m} > \frac{c}{m^2}$ pro jakoukoliv konstantu, a tedy nezávislost je nemožná. Pro c -univerzalitu, evidentně $\Pr[h_a(x) = h_a(y)] = 1$, a tedy c -univerzalitu také nemáme.

Úloha 7 (Modulo univerzálního systému nemusí být univerzální)

Ukažte, že pokud máme univerzální systém hešovacích funkcí \mathcal{H} , pak systém \mathcal{H}' , kde ke každé fci navíc přidáme modulo m , už nemusí být univerzální. Formálně: Dokažte, že pro každé c a $m > 1$ existuje univerzum \mathcal{U} a systém \mathcal{H} z \mathcal{U} do \mathcal{U} tak, že \mathcal{H} je univerzální, ale \mathcal{H}' už není c -univerzální.

Řešení

Uvažme \mathcal{H}_1 z předchozí úlohy - pak $\mathcal{H}_1 \bmod m$ nemůže být c -univerzální, protože dokud $m < |\mathcal{U}|$, pak prvky 1 a $m + 1$ se vždycky zobrazí na tentýž prvek 1.

Užitečné definice

Definice (c -univerzální systém fcí). Systém \mathcal{H} funkcí $h : \mathcal{U} \rightarrow [m]$ je c -univerzální pro $c > 0$, pokud pro všechna $x \neq y$ platí $\Pr_h[h(x) = h(y)] \leq \frac{c}{m}$.

Systém \mathcal{H} je univerzální, pokud je c -univerzální pro nějaké $c > 0$.

Definice (k -nezávislý systém fcí). Systém \mathcal{H} funkcí $h : \mathcal{U} \rightarrow [m]$ je (k, c) -nezávislý pro nějaká $k \geq 1, c > 0$, pokud $\Pr_{h \in \mathcal{H}}[h(x_1) = a_1 \wedge \dots \wedge h(x_k) = a_k] \leq \frac{c}{m^k}$ pro libovolná x_1, \dots, x_k různá, a_1, \dots, a_k ne nutně různá. Systém \mathcal{H} je k -nezávislý, pokud je (k, c) -nezávislý pro nějakou nezávislou konstantu c .

Opáčko pravděpodobnosti

Tvrzení (Union bound). Pro jevy A_1, A_2 platí, že $P[A_1 \cup A_2] \leq P[A_1] + P[A_2]$.

Tvrzení (Linearita střední hodnoty). Pro náhodné veličiny X, Y a $\alpha, \beta \in \mathbb{R}$ platí: $\mathbb{E}[\alpha X + \beta Y] = \alpha \mathbb{E}[X] + \beta \mathbb{E}[Y]$.

Definice (Indikátor, nezávislost náhodných veličin). Nechť A je jev v diskrétním pravděpodobnostním prostoru. Potom indikátor A je náhodná veličina I_A definovaná: $I_A(\omega) = 0 \Leftrightarrow \omega \notin A$, jinak $I_A(\omega) = 1$.

Náhodné veličiny X, Y na diskrétním pravděpodobnostním prostoru $(\Omega, 2^\Omega, P)$ jsou nezávislé, pokud $\forall \alpha, \beta \in \mathbb{R}$ jsou jevy $\{\omega \in \Omega : X(\omega) \leq \alpha\}, \{\omega \in \Omega : Y(\omega) \leq \beta\}$ nezávislé.

Věta (Markovova nerovnost). Buď X nezáporná náhodná veličina. Pak $\forall \varepsilon > 0$ platí $P[X \geq \varepsilon] \leq \frac{\mathbb{E}[X]}{\varepsilon}$.
Ekvivalentně pro jakékoliv $d \geq 1$, $P[X \geq d \cdot \mathbb{E}[X]] \leq \frac{1}{d}$.

Věta (Chernoffova mez). Mějme $X = \sum_{i=1}^k X_i$, kde X_i jsou nezávislé Bernoulliiovské náhodné veličiny, $\mu = \mathbb{E}[X], c > 1$. Pak $P[X \geq c\mu] \leq \left(\frac{e^{c-1}}{c^c}\right)^\mu$.