

Προηγούμενη φόρμα :

Markov's Inequality

Αν X μη-αρνητική τ.μ. $\forall t$
 $P[X \geq t] \leq \frac{E[X]}{t}$

Chebyshev's Inequality

Αν X έχει $\text{Var}[X] = \sigma^2$

$$P_r [|X - E[X]| \geq k\sigma] \leq \frac{1}{k^2} \quad \forall k \geq 1$$

Chernoff Bound

Αν $X = \sum X_i$ με X_i ανεξάρτητες τ.μ.

στο $\{0, 1\}$ τότε

$$P_r [X \geq (1+\epsilon)\mu] \leq e^{-\frac{\epsilon^2 \mu}{2+\epsilon}}$$

$$\text{όπου } \mu = E[X]$$

Hoeffding Inequality

Αν $X = \sum X_i$ με X_i ανεξάρτητες τμ.

στο $[a_i, b_i]$ τότε

$$Pr[|X - \mu| \geq t] \leq 2e^{-\frac{2t^2}{\sum (b_i - a_i)^2}}$$

$$\text{όπου } \mu = E[X]$$


Π, Διωνόγτα ενός κερματός p

$$\text{Αν } \hat{p} = \frac{\sum_{i=1}^m X_i}{m}$$

$$Pr[|\hat{p} - p| > \epsilon] \leq e^{-\Omega(\epsilon^2 m)}$$

$$m = \Theta\left(\frac{1}{\epsilon^2} \log(1/\delta)\right) \quad \text{δειγμάτια}$$

$$|\hat{p} - p| < \epsilon \quad \text{με πιθανότητα } 1 - \delta.$$



Εκτίμηση
Πληθους Διαφορετικών
στοιχείων

Πρόβλημα: Μεγάλο stream από δεδομένα

$$x_1, \dots, x_N$$

Ποσα είναι διαφορετικά;

Εστω n το πλήθος διαφορετικών

με $O(n)$ μνήμη

μπορώ να τα υπολογίσω

Τεχνική: Hash κάθε στοιχείο

$$x_i \rightarrow h(x_i) \sim U[0,1]$$

$$h(x_1) = h(x_8) \text{ αν}$$

$$\text{το } x_1 = x_8$$

$$Y = \min_{i=1}^N h(x_i) \quad (\Leftrightarrow)$$

$$Y = \min_{i=1}^n s_i \quad \text{όπου } s_i \sim U[0,1]$$

$$\text{Claim: } E[Y] = \frac{1}{n+1}$$

$$n = \frac{1}{E[Y]} - 1$$

Proof. $\Pr[Y \geq t] = (1-t)^n$

$$E[Y] = \int_0^1 \Pr[Y \geq t] dt$$

$$= \int_0^1 (-\Pr[Y \geq t])' dt$$

$$= \int_0^1 \Pr[Y \geq t] dt = \int_0^1 (1-t)^n dt$$

$$= \int_0^1 t^n dt = \frac{1}{n+1}$$

Claim: $\text{Var}[Y] \leq \frac{1}{(n+1)^2}$

$$\text{Var}[Y] = E[Y^2] - E[Y]^2$$

Proof.

$$E[Y^2] = \int_0^1 \Pr[Y=t] t^2 dt$$

$$= \int_0^1 n (1-t)^{n-1} t^2 dt$$

$$= \frac{2}{(n+1)(n+2)} \leq \frac{2}{(n+1)^2}$$

$$\text{Var}[Y] \leq \frac{2}{(n+1)^2} - \frac{1}{(n+1)^2} = \frac{1}{(n+1)^2} \quad \square$$

Από Chebyshev

$$\Pr \left[\left| Y - \frac{1}{n+1} \right| \geq \frac{\kappa}{n+1} \right] \leq \frac{1}{\kappa^2}$$



Μείωση του Variance

Εναλλακτικώς το πηγάφι t φορές

Y_1, Y_2, \dots, Y_t

$$\bar{Y} = \frac{\sum_{i=1}^t Y_i}{t} \quad \left\{ \begin{array}{l} E[\bar{Y}] = \frac{1}{t} \sum_{i=1}^t E[Y_i] \\ \qquad \qquad \qquad = \frac{1}{n+1} \\ \text{Var}[\bar{Y}] = \frac{1}{t^2} \text{Var}[\sum Y_i] \\ \qquad \qquad \qquad = \frac{\sum_{i=1}^t \text{Var}[Y_i]}{t^2} \\ \qquad \qquad \qquad = \frac{1}{t} \frac{1}{(n+1)^2} \end{array} \right.$$

$$\Pr \left[\left| \bar{Y} - \frac{1}{n+1} \right| \geq \frac{k}{\sqrt{t}} \frac{1}{n+1} \right] \leq \frac{1}{k^2}$$

Av $k=2$ $\frac{1}{\sqrt{5}}$ $k=1$ $t = \frac{4}{\varepsilon^2}$ $\frac{1}{5\varepsilon^2}$

$$\Pr \left[\left| \bar{Y} - \frac{1}{n+1} \right| \geq \varepsilon \frac{1}{n+1} \right] \leq \frac{1}{4}$$

'Αρα με πιθανότητα $\geq \frac{3}{4}$

$$\frac{1}{n+1} (1-\epsilon) \leq \bar{y} \leq (1+\epsilon) \frac{1}{n+1}$$

$$\hat{n} = \frac{1}{\bar{y}} - 1$$

$$\frac{n+1}{1+\epsilon} \leq \frac{1}{\hat{y}} \leq \frac{n+1}{1-\epsilon}$$

[Flajolet - Martin algorithm]

Πιθανότητα $1 - \delta$

Γενική τεχνική για boosting της
πιθανότητας


Έστω ότι έχω έναν εκτιμητή \hat{A}
ενός μερίδους A ώστε

$$|\hat{A} - A| \leq \varepsilon \quad \text{με πιθανότητα } \frac{3}{4}$$

Μπορώ να αυξήσω την πιθανότητα
επιτυχίας με ανεξάρτητα περάσματα
του εκτιμητή

$$\hat{A}_1, \hat{A}_2, \dots, \hat{A}_m$$


Έστω ότι υπολογίζω το median



Claim: Αν λάνω από τα $\frac{m}{2}$

\hat{A}_i ικανοποιούν $|\hat{A}_i - A| \leq \epsilon$

τότε $|\text{med}(\hat{A}_1, \dots, \hat{A}_m) - A| \leq \epsilon$



Ποια είναι η πιθανότητα σφάλματος;

Έστω Z_i είναι η δλκτρια τ.μ.
του γεγονότος ότι το \hat{A}_i
είναι κακό

$$Z_i = \begin{cases} 1 & \text{αν } |\hat{A}_i - A| > \epsilon \\ 0 & \text{διαφορετικά} \end{cases}$$

$$E[Z_i] \leq \frac{1}{4}$$

$$\Pr \left[\sum_{i=1}^m Z_i \geq \frac{m}{2} \right] \leq$$


$$\Pr \left[\sum_{i=1}^m Z_i \geq 2 E \left[\sum_{i=1}^m Z_i \right] \right]$$

(Chernoff bound)

$$\leq e^{-\frac{m}{3}} = e^{-\frac{m}{12}} \leq \delta$$

$$m = O(\log \frac{1}{\delta})$$

Συνοπτικά : Μνήμη $O(\frac{1}{\epsilon^2} \log(1/\delta))$



Median - of - Means