

Προηγούμενα γορά

Markov's Inequality

Αν X μη αρνητική τμ. $\forall t$
$$\Pr[X \geq t] \leq \frac{E[X]}{t}$$

Chebyshev's Inequality

Αν X είναι τυχαία μεταβλητή με $\text{Var}[X] = \sigma^2$

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

Hoeffding Inequality

Αν $X = \sum X_i$ με X_i ανεξάρτητες τμ.
στο $[a_i, b_i]$ τότε για κάθε $t > 0$

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


Πιθανότητα ενός κέρματος p

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

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

Με $m = \Theta\left(\frac{1}{\varepsilon^2} \log(1/\delta)\right)$ δείχνεται

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



Εκτίμηση Πλήθους Διαφορετικών Στοιχείων

Πρόβλημα: Μεγάλο stream από δεδομένα
 $x_1, \dots, x_N$

Πόσα είναι διαφορετικά;

Έστω τα διαφορετικά
στοιχεία έχουν πλήθος n

με $O(n)$ μνήμη
μπορώ να τα υπολογίσω
ακριβώς.

Τεχνική: Hash κάθε στοιχείο

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

$$h(x_i) = h(x_8) \quad \text{αν} \\ \text{το} \quad x_i = x_8$$

$$h(x) = \text{md5}(x)$$



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

Now $s_i \sim U[0, 1]$

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

Ans: $E[Y] = \int_0^1 \Pr[Y=t] \cdot t \, dt$

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

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

$$= \int_0^1 (1-t)^n \, dt = \int_0^1 t^n \, dt$$

$$= \frac{1}{n+1} \quad \square$$

$$n = \frac{1}{Y} - 1$$

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

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

Ans: $\{Y\}$.

$$\begin{aligned} E[Y^2] &= \int_0^1 \text{Pr}[Y=t] t^2 dt \\ &= \int_0^1 n(1-t)^{n-1} t^2 dt \\ &= \frac{2}{(n+1)(n+2)} \leq \frac{2}{(n+1)^2} \end{aligned}$$

Ans Chebyshev

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

Μείωση του Variance

Επανάλαβαν το πείραμα t φορές.

$Y_1, Y_2, \dots, Y_t$

$$\bar{Y} = \frac{\sum_{i=1}^t Y_i}{t}$$

$$\rightarrow \begin{cases} E[\bar{Y}] = \frac{1}{t} \sum_{i=1}^t E[Y_i] \\ = \frac{1}{n+1} \\ \text{Var}[\bar{Y}] = \frac{1}{t^2} \text{Var}[\sum_{i=1}^t Y_i] \\ = \frac{\sum_{i=1}^t \text{Var}[Y_i]}{t^2} \\ \leq \frac{1}{t(n+1)^2} \end{cases}$$

And Chebyshev

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

Av $\kappa = 2$ $\frac{1}{\sqrt{6}}$ $\kappa = 1$

$$t = \frac{4}{\varepsilon^2}$$

$$\frac{1}{\sigma \varepsilon^2}$$

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

'Αρα με πιθανότητα $\frac{3}{4}$

$$\frac{1}{n+1} (1-\varepsilon) \leq \bar{Y} \leq (1+\varepsilon) \frac{1}{n+1}$$

$$\hat{n} = \frac{1}{\bar{Y}} - 1 \quad \frac{n+1}{1+\varepsilon} \leq \frac{1}{\bar{Y}} \leq \frac{n+1}{1-\varepsilon}$$

[Flajolet - Martin algorithm]

Πιθανότητα $1-\delta$


Γενική τεχνική για boosting
της πιθανότητας σωστής
εκτίμησης.

Έστω $\hat{A}$ εκτιμήτρια $\hat{A}$ έχω ϵ -αν
ενός μεγέθους A
ώστε $|\hat{A} - A| \leq \epsilon$ με πιθανότητα $3/4$


Μπορώ να αυξήσω την σιδηρότητα
με ανεξάρτητα πειράματα του εκτιμητή

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

$$\text{median}(\hat{A}_1, \dots, \hat{A}_m)$$



Claim: Αν πάρω από $\frac{m}{2}$
των $\hat{A}_i$ ικανοποιούν $|\hat{A}_i - A| \leq \varepsilon$
τότε $|\text{median}(\hat{A}_1, \dots, \hat{A}_m) - A| \leq \varepsilon$



Έστω Z_i είναι η δείκτρια τμ.
 του γεγονότος ότι το $\hat{A}_i$ είναι
 κακό. Δηλαδή:

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


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

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

$$= Pr \left[\left| \sum_{i=1}^m Z_i - \frac{m}{4} \right| \geq \frac{m}{4} \right]$$

$$\leq e^{-\Theta(m)} \leq \delta$$

$$m = \Theta(\log 1/\delta)$$



$$O\left(\frac{\log(1/\delta)}{\epsilon^2}\right)$$

Median - of - Means