

16.06.2021

Zadanie Na podstawie losowej próby szacujemy procent dorosłych, którzy potrafią pisać i czytać. Wiadomo na pewno, że jest to powyżej 90% dorosłej populacji. Chcemy, aby błąd był mniejszy niż 0.01 z prawdopodobieństwem 0.9. Ile osób musi liczyć próba?

CTG: $\{X_n\}$ i.i.d., $\mathbb{E}X_n < \infty$, $\text{Var} X_n < \infty$.

$$\frac{X_1 + \dots + X_n - nm}{\sqrt{n} \sigma} = \frac{S_n - \mathbb{E}S_n}{\sqrt{\text{Var} S_n}} \xrightarrow{d} \mathcal{N}(0, 1)$$

Rozwiązanie zadania

Chcemy znaleźć $p \approx \frac{\text{osoby, które potrafią pisać}}{\text{wielkość próbki}}$
 n -l. testowanych osób

$X_i = \begin{cases} 1 & \text{i-te osoba czyta} \\ 0 & \text{w p.w.} \end{cases}$

$S_n = X_1 + \dots + X_n$ - l. osób, każde czyta

$$P \approx \frac{S_n}{n}, P\left[\left|\frac{S_n}{n} - p\right| \leq 0,01\right] \geq \frac{9}{10}$$

S_n ma rozkład $\text{Bin}(n, p)$

$EX_1 = p, \text{Var} X_1 = p(1-p)$. Chcemy

skorzystać z CTG.

$$P\left[\left|\frac{S_n - np}{\sqrt{np(1-p)}}\right| \leq \frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right] \geq \frac{9}{10}$$

Z CTG $\sim \mathcal{N}(0,1)$

tu się też generuje pewien błąd

Szukamy x_0 t.że

$$\frac{9}{10} \leq P\left[|Y| \leq x_0\right] = \int_{-x_0}^{x_0} \varphi(x) dx = \Phi(x_0) - \Phi(-x_0)$$

$\mathcal{N}(0,1)$

$$= \Phi(x_0) - 1 + \Phi(x_0) = 2\Phi(x_0) - 1$$

Gdyż $\Phi(x_0) \geq 0,95 \Rightarrow x_0 \geq 1,65$

$$\text{Zatem } \frac{\sqrt{n}}{100\sqrt{p(1-p)}} \geq 1.65$$

$$\sqrt{n} \geq 165\sqrt{p(1-p)}$$

Wiemy, że $p \geq 0.9$. Wtedy $p(1-p) \leq 0.09$.

$$\text{Czyli } \sqrt{n} \geq 0.3 \cdot 165 = 49.5$$

$$\text{Zatem } n \geq 49.5^2 = 2450.25$$

$$\text{Czyli } n \geq 2451.$$

Tw. 11.2 (Berry-Essen)

Jeżeli $\{X_n\}$ i.i.d., $\mathbb{E}X_1^3$, $\mathbb{E}X_1 = 0$,

$\sigma^2 = \text{Var } X_1$, to

$$\sup_{t \in \mathbb{R}} \left| \mathbb{P} \left[\frac{X_1 + \dots + X_n}{\sqrt{n}\sigma} < t \right] - \Phi(t) \right| \leq \frac{C \cdot \mathbb{E}|X_1|^3}{\sigma^3 \sqrt{n}}$$

gdzie $\Phi(t)$ jest dystrybucją rozkładu

normalnego $\mathcal{N}(0,1)$, a C jest

ustalona stała (niezależna od rozkładu X_1)

Przykład Niech U_n będzie ciągiem Bernoulliego,
 tj. $P[U_n = \pm 1] = 1/2$. Wówczas dla powyższych
 wartości n :

$$\left| P\left[\frac{U_1 + \dots + U_n}{\sqrt{n \operatorname{Var} U_n}} < 0\right] - \Phi(0) \right| = \left| P[U_1 + \dots + U_n < 0] - \frac{1}{2} \right|$$

$$= \left| \frac{1}{2} P[U_1 + \dots + U_n < 0] + \frac{1}{2} P[U_1 + \dots + U_n > 0] - \frac{1}{2} \right|$$

$$= \left| \frac{1}{2} (1 - P[U_1 + \dots + U_n = 0]) - \frac{1}{2} \right|$$

$$= \frac{1}{2} P[U_1 + \dots + U_n = 0]$$

$$= \frac{1}{2} \cdot \frac{\binom{n}{n/2}}{2^n} \stackrel{\text{stirling}}{\sim} \frac{1}{2} \frac{1}{\sqrt{\pi n/2}} = \frac{1}{\sqrt{2\pi} \cdot \sqrt{n}}$$

Tw. M.3 (Lindeberg - Feller)

Niech $\{X_{n,k}\}$ będzie schematem serii

spatniejącym:

- $E X_{n,k} = 0$ dla $n \geq 1, k \leq n$

- $\lim_{n \rightarrow \infty} s_n^2 = \sigma^2 > 0$, gdzie $s_n^2 := \operatorname{Var} \sum_{k=1}^n X_{n,k} = \sum \operatorname{Var} X_{n,k}$

• (warunek Lindeberga) dla każdego $\epsilon > 0$

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \mathbb{E} \left[X_{n,k}^2 \mathbb{1}_{\{|X_{n,k}| > \epsilon\}} \right] = 0$$

Wówczas $\sum_{k=1}^n X_{n,k} \xrightarrow{d} \mathcal{N}(0, \sigma^2)$

Przykład liczba cykli w losowej permutacji:

$$\begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 \\ 3 & 9 & 6 & 8 & 2 & 1 & 5 & 4 & 7 \end{pmatrix} = (136)(2975)(48)$$

Problem: losujemy permutację $\pi_n \in S_n$.

C_n - l. cykli tej permutacji.

Cel: $\frac{C_n - \log n}{\sqrt{\log n}} \xrightarrow{d} \mathcal{N}(0, 1)$

Definiujemy $Z_{n,k} = \begin{cases} 1 & \text{jeżeli po } k \text{ tej} \\ & \text{liczbie w rozkł.} \\ & \text{na cykle pojawił się ")}" \\ 0 & \text{w p.w.} \end{cases}$

Zauważmy, że $C_n = \sum_{k=1}^n Z_{n,k}$

hmat: dla ustalonego n $Z_{n,k}$ są n.z.l.

$$\text{oraz } \mathbb{P}[Z_{n,k} = 1] = \frac{1}{n-k+1}.$$

Sprawdźmy warunki Lindeberga.

Zdef. $Y_{n,k} = Z_{n, n-k+1}$. Znowu $Y_{n,k}$ są n.z.l.

$$\text{oraz } \mathbb{P}[Y_{n,k} = 1] = \frac{1}{k}.$$

$$\mathbb{E} Y_{n,k} = \frac{1}{k}, \quad \text{Var } Y_{n,k} = \frac{1}{k} - \frac{1}{k^2}$$

$$\mathbb{E} C_n = \sum_{k=1}^n \mathbb{E} Y_{n,k} = \sum_{k=1}^n \frac{1}{k} \sim \log n$$

$$\text{Var } C_n \sim \log n$$

Niech $X_{n,k} = \frac{Y_{n,k} - \frac{1}{k}}{\sqrt{\log n}}$. $\{X_{n,k}\}$ - schemat serii.

$$1) \mathbb{E} X_{n,k} = 0$$

$$2) S_n^2 = \sum_{k=1}^n \text{Var } X_{n,k} = \sum_{k=1}^n \text{Var} \left(\frac{Y_{n,k}}{\sqrt{\log n}} \right) = \frac{1}{\log n} \sum_{k=1}^n \left(\frac{1}{k} - \frac{1}{k^2} \right)$$

$$\longrightarrow 1 = \sigma^2$$

$$3) \sum_{k=1}^n \mathbb{E} \left[X_{n,k}^2 \mathbb{1}_{\{|X_{n,k}| > r\}} \right]$$

$$= \sum \mathbb{E} \left[X_{n,k}^2 \mathbb{1}_{\left\{ \frac{Y_{n,k} - \frac{1}{k}}{\sqrt{\log n}} > r \right\}} \right] \xrightarrow{n \rightarrow \infty} 0$$

$\frac{2}{\sqrt{\log n}} > r$
 $\rightarrow 0$ dla dużych n
 ten zbiór pusty

\mathcal{L} CTG L-F $\sum_{k=1}^n X_{n,k} \xrightarrow{d} \mathcal{N}(0, 1)$

Czyli

$$\frac{C_n - \log n}{\sqrt{\log n}} + \frac{\log n - \sum \frac{1}{k}}{\sqrt{\log n}} = \frac{\sum Y_{n,k} - \sum \frac{1}{k}}{\sqrt{\log n}}$$

$\downarrow^d \mathcal{N}(0, 1)$

$\downarrow 0$

$\xrightarrow{d} \mathcal{N}(0, 1)$

KONIEC