

Теорија узорака

Јован Самарџић, 13/2019

Професор: Милан Јовановић

■ - дефиниције

Година курса: 2021/22

■ - ознаке

Молим да ми све грешке пријавите
 преко мејла или друштвених мрежа.

■ - теореме

■ - докази

■ - примери

0.

Популација и узорак

Деф. Популација је скуп који се посматра. Састоји се од јединки ω .

Обим популације је број јединки популације, у означи N . Он је познат.

Деф. Обележје је карактеристика коју придржанујемо свакој јединки популације.
(најчешће нумеричка, а ако није - „кодирамо“)

Са x_1, \dots, x_N означавамо реализације вредности обележја популације.

Циљ нам је да сазнамо како се обележје понаша, тј. заима нас какву расподелу има.
Пошто није практично гледати све x_i засебно, уводимо следећи појам:

Деф. Параметар обележја је реална функција вредности обележја популације.

Пример: 1) укупна (тотална) сума: $t := \sum_{i=1}^N x_i$;

2) средња вредност: $\bar{x} := \frac{1}{N} \sum_{i=1}^N x_i$;

3) дисперзија/ варијанса: $s^2 := \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$;

4) стандардна девијација: $s := \sqrt{s^2}$;

5) пропорција неког својства: $P := \frac{\text{бр. јед. са тим својством}}{\text{укупан број јединки}} = \frac{A}{N}$.

Како прикупљамо податке?

Деф. Попис је опређивање реализ. вр. за све јединке популације. (подијамо x_1, \dots, x_N)

У пракси, то је тешко изводљиво. Зато не испитујемо целу популацију.

Деф. Узорак је било који подскуп популације.

Обим узорка је број јединки узорка, у означи n . Он је познат.

Напомена: узорак мора бити репрезентативан

Како се бира узорак?

1. корак: **узорачки оквир** - листа/списак свих јединки популације.

Ип. држављане поређамо у листу по ЈМБГ.

Ипак, узорачки оквир и циљна популација се често не поклопе (ип. неко нема ЈМБГ)

2. корак: **план узорковања** - правило по ком се од свих могућих узорака фиксираног обима и бира један узорак

При томе, јављају се грешке и то два типа:

a) **неузорачке грешке** - не зависе од избора плана узорковања.

Примери: - узорачки оквир и популација се разликују;
- двосмислена питања на упитницима;
- мултиплекција (телефонска анкета + више фиксних телефона у истој кући);
- проблем мерења.

б) **узорачке грешке** - настају јер закључујемо на основу узорка, а не целе популације.

Напомена: некад можемо да их контролишемо.

Постоје два типа планова узорковања:

деф. Вероватносни план узорковања је онај код кога је позната вероватноста избора било ког узорка фиксиране величине.

Самим тим, позната је вероватноста појављивања било које јединке у извученом узорку. Због тога је могуће контролисати узорачку грешку.

Постоје 4 типа: 1) прост случајан узорак;

2) статификовани узорак;

3) кластер узорак;

4) систематски узорак.

У супротном, имамо невероватносни план узорковања

На пример: - узорковање само из дела доступне популације;
- узорковање одокативно
- узорковање само оних који то желе, а не свих.

Пример: Имамо оквир $\mathcal{U} = \{1, 2, 3, 4\}$.

Узорци обима 2 су: $S_1 = \{1, 2\}$ $S_4 = \{2, 3\}$
 $S_2 = \{1, 3\}$ $S_5 = \{2, 4\}$
 $S_3 = \{1, 4\}$ $S_6 = \{3, 4\}$

Скуп свих узорака S се састоји од S_1, \dots, S_6 . Нама треба један од њих:

$$\left. \begin{array}{l} P(S_1) = 1/3 \\ P(S_2) = 1/6 \\ P(S_3) = P(S_4) = P(S_5) = 0 \\ P(S_6) = 1/2 \end{array} \right\} S: \begin{pmatrix} S_1 & S_2 & S_3 & S_4 & S_5 & S_6 \\ 1/3 & 1/6 & 0 & 0 & 0 & 1/2 \end{pmatrix} \quad \text{- ово је пример једног вероватносног плана узорковања}$$

$\Pi_i := \sum_{S: i \in S} P(S)$ - вероватност да се јединка i нађе у узорку који изаберемо

$$\Pi_1 = P(S_1) + P(S_2) + P(S_3) = 1/2 ;$$

$$\Pi_2 = P(S_1) + P(S_4) + P(S_5) = 1/3 ;$$

$$\Pi_3 = P(S_2) + P(S_4) + P(S_6) = 2/3 ;$$

$$\Pi_4 = P(S_3) + P(S_5) + P(S_6) = 1/2 .$$

Оцена и особине оцена.

$$\mathbb{R}^n \rightarrow \mathbb{R}$$

Деф. Статистика је било која Борелова функција која не зависи од непознатих параметара.

Деф. Оцена је статистика која процењује параметар.

Пример: Настављамо претк. пример.

За оцену статистике t (укупна сума), предлаже се оцена $\hat{t} = N \cdot \bar{x}$.

i	1	2	3	4
x_i	2	5	3	6

(ми овде знајмо да је $t=16$)

$$\begin{aligned}\bar{x}_{S_1} &= \frac{2+5}{2} = 3.5 & \Rightarrow \hat{t}_{S_1} &= 4 \cdot 3.5 = 14 & \text{и } P(S_1) &= 1/3 ; \\ \bar{x}_{S_2} &= 2.5 & \Rightarrow \hat{t}_{S_2} &= 10 & \text{и } P(S_2) &= 1/6 ; \\ \bar{x}_{S_3} &= 4 & \Rightarrow \hat{t}_{S_3} &= 16 & \text{и } P(S_3) &= 0 ; \\ \bar{x}_{S_4} &= 4 & \Rightarrow \hat{t}_{S_4} &= 16 & \text{и } P(S_4) &= 0 ; \\ \bar{x}_{S_5} &= 5.5 & \Rightarrow \hat{t}_{S_5} &= 22 & \text{и } P(S_5) &= 0 ; \\ \bar{x}_{S_6} &= 4.5 & \Rightarrow \hat{t}_{S_6} &= 18 & \text{и } P(S_6) &= 1/2 .\end{aligned}$$

$\hat{t}: \begin{pmatrix} 10 & 14 & 16 & 18 & 22 \\ 1/6 & 1/3 & 0 & 1/2 & 0 \end{pmatrix}$ - ово је узорачка расподела оцене \hat{t} .

Приметимо $E\hat{t} = 15 \frac{1}{3} \neq 16$, tj. $E\hat{t} \neq t$.

деф. Нека је $S: \begin{pmatrix} s_1 & \dots & s_v \\ P(s_1) & \dots & P(s_v) \end{pmatrix}$ један план узорковања.
Оцена $\hat{\theta}$ је непристрасна оцена параметра θ ако $E(\hat{\theta}) = \theta$. ($E(\hat{\theta}) = \sum \hat{\theta}(s_i) \cdot P(s_i)$)

Пакле, оцена \hat{t} из примера није непристрасна, тј. пристрасна је.

деф. Пристрасност оцене је $B(\hat{\theta}) := E(\hat{\theta}) - \theta$.

деф. Средње квадратна грешка оцене је $MSE(\hat{\theta}) = E((\hat{\theta} - \theta)^2)$.

$$\begin{aligned} \text{Приметимо: } MSE(\hat{\theta}) &= E((\hat{\theta} - \theta)^2) = E((\hat{\theta} - E\hat{\theta} + E\hat{\theta} - \theta)^2) \\ &= E((\hat{\theta} - E\hat{\theta})^2 + 2(\hat{\theta} - E\hat{\theta})(E\hat{\theta} - \theta) + (E\hat{\theta} - \theta)^2) \\ &= E(\hat{\theta} - E\hat{\theta})^2 + 2(E\hat{\theta} - \theta)E(\hat{\theta} - E\hat{\theta}) + E(E\hat{\theta} - \theta)^2 \\ &= D(\hat{\theta}) + 2(E\hat{\theta} - \theta)(E\hat{\theta} - \underbrace{E(E\hat{\theta})}_{E\hat{\theta}}) + (E\hat{\theta} - \theta)^2 \\ &= D(\hat{\theta}) + (B(\hat{\theta}))^2 \end{aligned}$$

Лема 1: $MSE(\hat{\theta}) = D(\hat{\theta}) + (B(\hat{\theta}))^2$.

Доказ: управо извели

Последица: Ако је $\hat{\theta}$ непристрасна $\Rightarrow MSE(\hat{\theta}) = D(\hat{\theta})$.

Напомена: Од две оцене, боља она са мањим MSE.

Ideo

деф. **Прост случајан узорак** има најједноставнији план узорковања.

У овом случају, вероватноће избора било ког узорка обима n су једнаке.

Одавде следи и да је једнака вероватноћа да било која јединка буде у узорку.
У другим речима, сви π_i су једнаки.

Обрнуто не вали: постоје планови узорковања са истим π_i ,
али различитим вероватноћама избора било ког узорка обима n . (пример: стр. 22)

1.

Прост случајан узорак без понављања

деф. **Прост случајан узорак без понављања** је онај у коме су све јединке у узорку различите.

Својства: - укупан број узорака: $\binom{N}{n}$ ($\{1,2\}$ и $\{2,1\}$ су исти узорак)

- вероватноћа избора узорка: $\frac{1}{\binom{N}{n}}$

$$-\pi_i = \frac{\binom{N-1}{n-1}}{\binom{N}{n}} = \frac{n}{N} \quad \text{не зависи од } i \Rightarrow \text{сви } \pi_i \text{ јесу једнаки.}$$

$$-\pi_{ij} = \frac{\binom{N-2}{n-2}}{\binom{N}{n}} = \frac{n(n-1)}{N(n-1)} \quad (\pi_{ij} = P\{\text{појављивање } i\text{-те и } j\text{-те}\})$$

(*) $x_1, \dots, \boxed{x_i}, \dots, x_n$
с онома га
дијагно

Како извлачимо овај узорак?

I начин: одједном од N извучемо n : $\{x_1, \dots, x_n\}$;

II начин: један по један, са избацувањем.

$$\xrightarrow{\text{коректност}} P(\{x_1, \dots, x_n\}) = \frac{n}{N} \cdot \frac{n-1}{N-1} \cdot \dots \cdot \frac{1}{N-n+1} = \frac{n!}{\frac{N!}{(N-n)!}} = \frac{1}{\binom{N}{n}}$$

У пракси, дијање ПСУ се врши помоћу **таблици случајних бројева**.

Оне су већ генериране (рачунарски) и прошли су све тестове случајности.

Теорема 1: 1) За ПСУ без понављања, оцена $\bar{x}_n = \frac{1}{n} \sum_{i \in S} x_i$ је непристрасна оцена за \bar{x} ; (S-узорак)

2) За дисперзију те оцене важи: $D(\bar{x}_n) = \frac{s^2}{n} (1 - \frac{n}{N})$;

3) Непристрасна оцена те дисперзије је $\widehat{D}(\bar{x}_n) = \frac{s_n^2}{n} (1 - \frac{n}{N})$, где $s_n^2 = \frac{1}{n-1} \sum_{i \in S} (x_i - \bar{x}_n)^2$.

Доказ: 1) $\bar{x}_n = \frac{1}{n} \sum_{i \in S} x_i = \frac{1}{n} \sum_{i=1}^N x_i \cdot I_i$, при чему су индикатори зависни (ако их је n, остали су 0)

$$I_i : \begin{pmatrix} 0 & 1 \\ 1-\pi_i & \pi_i \end{pmatrix}, \text{ где } \pi_i = \frac{n}{N}$$

$$E(\bar{x}_n) = E\left(\frac{1}{n} \sum_{i=1}^N x_i \cdot I_i\right) = \frac{1}{n} \sum_{i=1}^N x_i \cdot E(I_i) = \frac{1}{n} \sum_{i=1}^N x_i \cdot \frac{n}{N} = \frac{1}{N} \sum_{i=1}^N x_i = \bar{x} \Rightarrow \text{јесте непристрасна};$$

$$2) D(\bar{x}_n) = D\left(\frac{1}{n} \sum_{i=1}^N x_i \cdot I_i\right) = E\left(\left(\frac{1}{n} \sum_{i=1}^N x_i \cdot I_i\right)^2\right) - \left(E\left(\frac{1}{n} \sum_{i=1}^N x_i \cdot I_i\right)\right)^2 \stackrel{!}{=} \frac{1}{n^2} E\left(\sum_{i=1}^N x_i I_i\right)^2 - \bar{x}^2$$

$$= \frac{1}{n^2} E\left((x_1 I_1 + \dots + x_N I_N)(x_1 I_1 + \dots + x_N I_N)\right) - \bar{x}^2$$

$$\stackrel{(*)}{=} \frac{1}{n^2} E\left(\sum_{i=1}^N x_i^2 I_i^2 + \sum_{i=1}^N \sum_{j \neq i} x_i x_j I_i I_j\right) - \bar{x}^2$$

$$= \frac{1}{n^2} \left(\sum_{i=1}^N x_i^2 \cdot E(I_i^2) + \sum_{i=1}^N \sum_{j \neq i} x_i x_j E(I_i I_j) \right) - \bar{x}^2$$

$$\stackrel{(**)}{=} \frac{1}{n^2} \left(\sum_{i=1}^N x_i^2 \cdot \frac{n}{N} + \sum_{i=1}^N \sum_{j \neq i} x_i x_j \cdot \frac{n(n-1)}{N(N-1)} \right) - \left(\frac{1}{N} \sum_{i=1}^N x_i \right)^2$$

$$= \frac{1}{nN} \left(\sum_{i=1}^N x_i^2 + \frac{N-1}{N-1} \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right) - \frac{1}{N^2} \left(\sum_{i=1}^N x_i^2 + \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right)$$

$$\underset{\text{извлачимо заједнички}}{\stackrel{\rightarrow}{=}} \frac{1}{nN^2} \left[(N-n) \sum_{i=1}^N x_i^2 + \left(\frac{N(n-1)}{N-1} - n \right) \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right]$$

$$= \frac{1}{nN^2} \left[(N-n) \sum_{i=1}^N x_i^2 - (N-n) \frac{1}{N-1} \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right] = \frac{N-n}{nN^2} \left[\sum_{i=1}^N x_i^2 - \frac{1}{N-1} \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right]$$

$$\stackrel{(*)}{=} \frac{N-n}{nN^2} \left[\sum_{i=1}^N x_i^2 - \frac{1}{N-1} \sum_{i=1}^N \sum_{j \neq i} x_i x_j - \frac{1}{N-1} \sum_{i=1}^N x_i^2 + \frac{1}{N-1} \sum_{i=1}^N x_i^2 \right]$$

$$= \frac{1}{nN} \left(1 - \frac{n}{N} \right) \left[\frac{N}{N-1} \sum_{i=1}^N x_i^2 - \frac{1}{N-1} \left(\sum_{i=1}^N x_i^2 + \sum_{i=1}^N \sum_{j \neq i} x_i x_j \right) \right]$$

$$= \frac{1}{nN} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[N \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i \right)^2 \right] = \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - \frac{N}{N^2} \left(\sum_{i=1}^N x_i \right)^2 \right]$$

$$= \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - N \left(\frac{1}{N} \sum_{i=1}^N x_i \right)^2 \right] = \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - N \bar{x}^2 \right]$$

$$= \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - 2N \bar{x}^2 + N \bar{x}^2 \right] \stackrel{(***)}{=} \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \left[\sum_{i=1}^N x_i^2 - 2\bar{x} \sum_{i=1}^N x_i + \underbrace{\sum_{i=1}^N \bar{x}^2}_{N \text{ исти сабирака}} \right]$$

(****) $N \bar{x} = \sum_{i=1}^N x_i$

Битан трен (користи се и касније)

$(N-1)s^2 = (\sum_{i=1}^N x_i^2 - N \bar{x}^2)$

$$= \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \sum_{i=1}^N [x_i^2 - 2x_i \bar{x} + \bar{x}^2]$$

$$= \frac{1}{n} \left(1 - \frac{n}{N} \right) \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$$

$$= \frac{s^2}{n} \left(1 - \frac{n}{N} \right)$$

$N \bar{x}^2 = \bar{x}^2 + \dots + \bar{x}^2$

(β^2 је параметар популације, па је у пракси непознат, па зато га оцењујемо)

$$3) E(\widehat{D}(\bar{x}_n)) = E\left(\frac{\beta^2}{n}(1 - \frac{n}{N})\right) = \frac{1}{n}(1 - \frac{n}{N}) E(\beta_n^2) = \frac{\beta^2}{n}(1 - \frac{n}{N}) = D(\bar{x}_n) \Rightarrow \text{јесте непристрасна.}$$

Овде смо користили непристрасност оцете β_n^2 , па то морамо да докажнемо:

Лема 1: За лсу без понављања, β_n^2 је непристрасна оцена за β^2 .

Доказ: Доказујемо $E(\beta_n^2) = \beta^2$.

$$\begin{aligned} E((n-1)\beta_n^2) &= E\left(\sum_{i \in S} (x_i - \bar{x}_n)^2\right) \stackrel{\substack{\text{КВ.} \\ \text{днома}}}{=} E\left(\sum_{i \in S} (x_i^2 - 2x_i\bar{x}_n + \bar{x}_n^2)\right) \\ &= E\left(\sum_{i \in S} x_i^2 - 2\bar{x}_n \sum_{i \in S} x_i + \sum_{i \in S} \bar{x}_n^2\right) \\ &\quad \text{надирка (исто као пре)} \\ &= E\left(\sum_{i \in S} x_i^2 - 2n \frac{1}{n} \bar{x}_n \sum_{i \in S} x_i + n \cdot \bar{x}_n^2\right) \\ &= E\left(\sum_{i \in S} x_i^2 - 2n \frac{\bar{x}_n^2}{n} + n \bar{x}_n^2\right) = E\left(\sum_{i \in S} x_i^2 - n \bar{x}_n^2\right) \\ &= E\left(\sum_{i \in S} x_i^2 I_i - n \bar{x}_n^2\right) = E\left(\sum_{i \in S} x_i^2 I_i\right) - n E(\bar{x}_n^2) \\ &= \sum_{i \in S} x_i^2 E(I_i) - n E(\bar{x}_n^2) \stackrel{EX^2 = DX - (EX)^2}{=} \sum_{i \in S} x_i^2 \frac{n}{N} - n(D(\bar{x}_n) + (E(\bar{x}_n))^2) \\ &= \frac{n}{N} \sum_{i \in S} x_i^2 - n \left(\frac{\beta^2}{n}(1 - \frac{n}{N}) + \bar{x}^2\right) = \frac{n}{N} \sum_{i \in S} x_i^2 - n \bar{x}^2 - \beta^2 \left(1 - \frac{n}{N}\right) \\ &= \frac{n}{N} \left(\sum_{i \in S} x_i^2 - N \bar{x}^2\right) - \beta^2 \left(1 - \frac{n}{N}\right) = \frac{n}{N} (N-1) \beta^2 - \beta^2 \left(1 - \frac{n}{N}\right) \\ &= \beta^2 (n-1) \end{aligned}$$

$N\bar{x} = \sum_{i \in S} x_i$
и пишемо $-2+1$
на наместимо на β^2
(као у ***) узада

$$\text{Дакле: } E((n-1)\beta_n^2) = \beta^2(n-1) \Rightarrow E(\beta_n^2) = \beta^2.$$

деф. Стандардна грешка оцете $\hat{\theta}$ је $SE(\hat{\theta}) := \sqrt{MSE(\hat{\theta})}$

Последица: Стандардна грешка оцете \bar{x}_n је $\frac{\beta}{\sqrt{n}} \sqrt{1 - \frac{n}{N}}$.

Напомена: За оцену стандардне грешке, узима се $\frac{\beta_n}{\sqrt{n}} \sqrt{1 - \frac{n}{N}}$.

Ова оцена није непристрасна! (Без обзира што је $E(\beta_n^2) = \beta^2$, не вали $E(\beta_n) = \beta$)

Теорема 2: 1) За ПСУ без понављања, оцена $\hat{t} = N \cdot \bar{x}_n$ је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\hat{t}) = N^2 \cdot \frac{s^2}{n} \left(1 - \frac{n}{N}\right)$;

3) Непристрасна оцена те дисперзије је $D(\hat{t}) = N^2 \cdot \frac{s_n^2}{n} \left(1 - \frac{n}{N}\right)$.

Показ: тривијално следи из Т1 и чињенице $t = N \cdot \bar{x}$.

2.

Оцена пропорције на основу ПСУ без понављања

Подсетимо се из [0]: $P = \frac{A}{N}$.

деф. Узорачка пропорција је $P_n := \frac{a}{n}$, а - др. јединки узорка са датим својством.

Копирање: Ово ватни универзално! (без и са понављањем).

$$x_i = \begin{cases} 1, & \text{има то својство} \\ 0, & \text{нема} \end{cases} \quad - \text{ оделеште које користимо} \Rightarrow A = \sum x_i$$

$$* P = \frac{\sum x_i}{N} = \bar{x}$$

$$* D^2 = \frac{1}{N-1} \sum (x_i - \bar{x})^2 = \frac{1}{N-1} \left(\sum x_i^2 - \bar{x}^2 \right)$$

$$\stackrel{x_i^2 = x_i}{=} \frac{1}{N-1} \left(\sum x_i - N\bar{x}^2 \right) = \frac{1}{N-1} (Np - Np^2)$$

$$= \frac{N}{N-1} p(1-p)$$

- Теорема 1:**
- 1) За ПСУ без понављања, оцена $P_n = \frac{a}{n}$ је непристрасна оцена за p ;
 - 2) За дисперзију те оцене важи: $D(P_n) = \frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}$;
 - 3) Непристрасна оцена те дисперзије је $\widehat{D}(P_n) = \frac{N-n}{N} \cdot \frac{p_n(1-p_n)}{n-1}$.

Доказ: 1) По ТТ1.1: $E(\bar{x}_n) = \bar{x}$ $\xrightarrow{\text{кој}}$ $E(P_n) = p$ \Rightarrow јесте непристрасна;

$$2) D(P_n) = \frac{s^2}{n} (1 - \frac{n}{N}) = \frac{1}{n} \cdot \frac{N}{N-1} p(1-p) (1 - \frac{n}{N}) = \frac{N-n}{N-1} \cdot \frac{p(1-p)}{n};$$

$$3) \widehat{D}(P_n) = \frac{s^2}{n} (1 - \frac{n}{N}) \stackrel{\text{јед}}{=} \frac{n}{n-1} \cdot \frac{p_n(1-p_n)}{n} \cdot \frac{N-n}{n} = \frac{N-n}{N} \cdot \frac{p_n(1-p_n)}{n-1} \Rightarrow \text{јесте непристрасна.}$$

Лема 1: $s_n^2 = \frac{n}{n-1} p_n(1-p_n)$

$$\begin{aligned} \text{Доказ: } s_n^2 &= \frac{1}{n-1} \sum_{i \in S} (x_i - \bar{x}_n)^2 = \frac{1}{n-1} (\sum_{i \in S} x_i^2 - n\bar{x}_n^2) \\ &= \frac{1}{n-1} (\sum_{i \in S} x_i - n\bar{x}_n^2) = \frac{1}{n-1} (np_n - np_n^2) \\ &= \frac{n}{n-1} p_n(1-p_n). \end{aligned}$$

- Теорема 2:**
- 1) За ПСУ без понављања, оцена $\hat{A} = N \cdot p_n$ је непристрасна оцена за A ;
 - 2) За дисперзију те оцене важи: $D(\hat{A}) = N^2 \cdot \frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}$;
 - 3) Непристрасна оцена те дисперзије је $\widehat{D}(\hat{A}) = N \cdot (N-n) \cdot \frac{p_n(1-p_n)}{n-1}$.

Доказ: тривијално следи из Т1 и чињенице $A = N \cdot p$.

3.

Прост случајан узорак са понављањем

деф. Прост случајан узорак са понављањем је онај у коме се јединке у узорку могу понављати.

Својства: - укупан број узорака: N^n

- вероватноћа избора узорка: $\frac{1}{N^n} \quad \left(= \frac{1}{N} \cdot \dots \cdot \frac{1}{N} \right)$

Напомена: Редослед је дитан! (нпр. (1, 3, 4, 5) и (5, 1, 3, 4) су различити узорци)
Зато кажемо да су ово уређени узорци.

Такође, нпр. $P(\{1, 1, 1, 1\}) \neq P(\{1, 3, 4, 5\})$.

↳ само $(1, 1, 1, 1)$ ↳ може бити $(1, 3, 4, 5), (5, 1, 3, 4) \dots$

Теорема 1: 1) За ПСУ са понављањем, оцена $\bar{x}_n = \frac{1}{n} \sum x_i$ је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи: $D(\bar{x}_n) = \frac{s^2}{n} \left(1 - \frac{1}{n}\right)$;

3) Непристрасна оцена те дисперзије је $\hat{D}(\bar{x}_n) = \frac{s_n^2}{n}$.

Показ: Имамо узорак обима n : (x_1, \dots, x_n) - x_i су независне и имају исту расподелу као обележје X .

$$X: \begin{pmatrix} x_1 & \dots & x_n \\ 1/N & \dots & 1/N \end{pmatrix}$$

Рачунамо: * $EX = \frac{1}{N} \cdot \sum x_i = \bar{x}$;

случайно \Rightarrow све једнако $\Rightarrow \frac{1}{N}$

$$* DX = EX^2 - (EX)^2 = \frac{1}{N} (x_1^2 + \dots + x_n^2) - \bar{x}^2$$

$$= \frac{1}{N} \left[\sum x_i^2 - N\bar{x}^2 \right] = \frac{N-1}{N} \cdot s^2. \quad \text{опет: } (N-1)s^2 = (\sum x_i^2 - N\bar{x}^2)$$

$$1) E(\bar{x}_n) = E\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n} \cdot \sum E x_i = \frac{1}{n} \sum EX = \frac{1}{n} \cdot n \cdot EX = \bar{x} \Rightarrow \text{јесте непристрасна};$$

$$2) D(\bar{x}_n) = D\left(\frac{1}{n} \sum x_i\right) \stackrel{\text{нез.}}{=} \frac{1}{n^2} \sum D(x_i) = \frac{n}{n^2} DX = \frac{s^2}{n} \left(1 - \frac{1}{n}\right);$$

$$3) E(\widehat{D(\bar{x}_n)}) = E\left(\frac{s_n^2}{n}\right) = \frac{1}{n} E(s_n^2) \stackrel{\text{JM}}{=} \frac{1}{n} \cdot \frac{N-1}{N} s^2 = D(\bar{x}_n) \Rightarrow \text{јесте непристрасна.}$$

Лема 1: За ПСУ са понављањем: $E(s_n^2) = \frac{N-1}{N} \cdot s^2$

$$\begin{aligned} \text{Доказ: } E(s_n^2) &= E\left(\frac{1}{N-1} \sum (x_i - \bar{x}_n)^2\right) = \frac{1}{N-1} E\left(\sum x_i^2 - N \bar{x}_n^2\right) = \frac{1}{N-1} (N E(x^2) - N E(\bar{x}_n^2)) \\ &= \frac{1}{N-1} [n(Dx + (Ex)^2) - n(\underline{D\bar{x}_n} + \underline{(E\bar{x}_n)^2})] \\ &\stackrel{1,2)}{=} \frac{n}{N-1} \left[\frac{N-1}{N} s^2 + \bar{x}^2 - \frac{s^2}{N} \left(1 - \frac{1}{N}\right) - \bar{x}^2 \right] \\ &= \frac{N-1}{N} \cdot \frac{n}{N-1} \cdot s^2 \left(1 - \frac{1}{N}\right) = \frac{N-1}{N} \cdot s^2. \end{aligned}$$

Теорема 2: 1) За ПСУ са понављањем, оцена $\hat{t} = N \cdot \bar{x}_n$ је непристрасна оцена за t ;

2) За дисперзију те оцене вали: $D(\hat{t}) = \frac{N(N-1)}{n} \cdot s^2$;

3) Непристрасна оцена те дисперзије је $\widehat{D(\hat{t})} = \frac{N^2 s_n^2}{n}$.

Доказ: тривијално следи из Т1 и чињенице $\hat{t} = N \cdot \bar{x}$.

* Упоређујемо оцене за случајеве ПСУ без и са понављањем:

Знамо да је боља оцена која има мање MSE.

Како су наше оцене непристрасне, гледамо која има мању дисперзију.

$$D_{BP}(\bar{x}_n) = \underbrace{\frac{N-n}{N-1}}_{<1} D_{SP}(\bar{x}_n) \Rightarrow D_{BP}(\bar{x}_n) < D_{SP}(\bar{x}_n);$$

Закључак: Оцене без понављања су боље од оцена са понављањем код коначних популација.
 $N < \infty$

4.

Оцена пропорције на основу ПСУ са понављањем

Копирање: исто као у [2].

- Теорема 1:**
- 1) За ПСУ са понављањем, оцена $\hat{p}_n = \frac{a}{n}$ је непристрасна оцена за p ;
 - 2) За дисперзију те оцене важи: $D(\hat{p}_n) = \frac{p(1-p)}{n}$;
 - 3) Непристрасна оцена те дисперзије је $\hat{D}(\hat{p}_n) = \frac{\hat{p}_n(1-\hat{p}_n)}{n-1}$.

Доказ: 1) $E(\bar{x}_n) = \bar{x} \xrightarrow{\text{кој}} E(\hat{p}_n) = p$;

$$2) D(\hat{p}_n) = \frac{\sigma^2}{n} \left(1 - \frac{1}{N}\right) \stackrel{\text{кој}}{=} \frac{N}{N-1} \cdot \frac{p(1-p)}{n} \cdot \frac{N-1}{N} = \frac{p(1-p)}{n};$$

$$3) \hat{D}(\hat{p}_n) = \frac{\hat{\sigma}^2}{n} \stackrel{[2] \text{ кој}}{=} \frac{n}{n-1} \cdot \frac{\hat{p}_n(1-\hat{p}_n)}{n} = \frac{\hat{p}_n(1-\hat{p}_n)}{n-1}.$$

- Теорема 2:**
- 1) За ПСУ са понављањем, оцена $\hat{A} = N \cdot \hat{p}_n$ је непристрасна оцена за A ;
 - 2) За дисперзију те оцене важи: $D(\hat{A}) = N^2 \cdot \frac{p(1-p)}{n}$;
 - 3) Непристрасна оцена те дисперзије је $\hat{D}(\hat{A}) = N^2 \cdot \frac{\hat{p}_n(1-\hat{p}_n)}{n-1}$.

Доказ: тривијално следи из Т1 и чинилице $A = N \cdot p$.

5.

Интервали поверења на основу ПСУ без понављања

До сада смо гледали искључиво тачкасте оцене, а сад гледамо интервалне.

деф. Са I означавамо **интервал поверења**, а $1-\alpha$ нам је **ниво поверења**.

То значи $P\{\theta \in I\} = 1-\alpha$, где је θ непознато.

Интервал поверења за \bar{x}

Хајек је доказао (један облик) ЦГТ за ПСУ без понављања:

За доволно велико $n, N, N-n$ кол ПСУ без понављања вали:

$$n \geq 30$$

$$X^* = \frac{\bar{X}_n - \bar{X}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2}} \approx N(0,1).$$

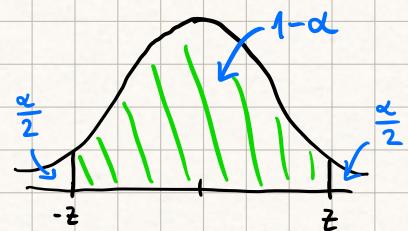
Наравно, постоји ∞ интервала поверења, па морамо неки да изадеремо.

Посматрамо тзв. центрирани интервал поверења:

$$P\{|X^*| \leq z\} = P\{-z \leq X^* \leq z\} = 1-\alpha$$

$$P\left\{-z \leq \frac{\bar{X}_n - \bar{X}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2}} \leq z\right\} = 1-\alpha$$

$$P\left\{\bar{X}_n - z \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2} \leq \bar{X} \leq \bar{X}_n + z \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2}\right\}$$



$$\Rightarrow I_{\bar{X}} = \left[\bar{X}_n - z \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2}, \bar{X}_n + z \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{X}_i - \bar{X})^2} \right], \text{ где } F_{X^*}(z) = 1 - \frac{\alpha}{2}.$$

Ово је **интервал поверења величине $1-\alpha$ за ср. вр. обележја популације**.

Проблем: λ је параметар популације и непознат је. Зато га оцењујемо са s_n :

$$I_{\bar{X}} = \left[\bar{X}_n - z \cdot \sqrt{\frac{s_n}{n}}, \bar{X}_n + z \cdot \sqrt{\frac{s_n}{n}} \right], \text{ где } F_{X^*}(z) = 1 - \frac{\alpha}{2}. \quad (*)$$

Ово је **апроксимативни интервал поверења за ср. вр. обележја популације**.

За $n < 30$: користимо Студентову t_{n-1} расподелу. ($n-1$ степена слободе)

$$I_{\bar{X}} = \left[\bar{X}_n - t \cdot \sqrt{\frac{s_n}{n}}, \bar{X}_n + t \cdot \sqrt{\frac{s_n}{n}} \right], \text{ где } F_{t_{n-1}}(t) = 1 - \frac{\alpha}{2}.$$

Интервал поверења за \hat{t}

Користимо чињеницу да је $\hat{t} = N \cdot \bar{x}_n$.

Зато интервал (*) множимо са N : $I_{N\bar{x}} = [N \cdot \bar{x}_n - z \cdot \frac{Ns_n}{\sqrt{n}} \sqrt{1-\frac{n}{N}}, N \cdot \bar{x}_n + z \cdot \frac{Ns_n}{\sqrt{n}} \sqrt{1-\frac{n}{N}}]$,

$$\Rightarrow I_t = [\hat{t} - z \cdot \frac{Ns_n}{\sqrt{n}} \sqrt{1-\frac{n}{N}}, \hat{t} + z \cdot \frac{Ns_n}{\sqrt{n}} \sqrt{1-\frac{n}{N}}]$$

При томе, за $n \geq 30$: $F_{x^*}(z) = 1 - \frac{\alpha}{2}$;

за $n < 30$: $F_{t_{n-1}}(t) = 1 - \frac{\alpha}{2}$.

Напомена: исти резултат бисмо добили истим поступком као за \bar{x} , само крећемо од $\frac{\hat{t} - t}{\frac{s}{\sqrt{n}} \sqrt{N(n-n)}}$ $\approx N(0,1)$.

Интервал поверења за p

Аналогно почетном поступку, добија се:

$$I_p = \left[p_n - z \cdot \sqrt{\frac{p_n(1-p_n)}{n-1} \left(1 - \frac{n}{N}\right)} - \frac{1}{2n}, p_n + z \cdot \sqrt{\frac{p_n(1-p_n)}{n-1} \left(1 - \frac{n}{N}\right)} + \frac{1}{2n} \right].$$

✳ - корекција (x_n - непрекидно, p_n дискретно)

Множењем I_p са N добијамо интервал поверења за A :

$$I_A = \left[\hat{A} - z \cdot \sqrt{\frac{p_n(1-p_n)}{n-1} (N-n)} - \frac{N}{2n}, \hat{A} + z \cdot \sqrt{\frac{p_n(1-p_n)}{n-1} (N-n)} + \frac{N}{2n} \right].$$

6.

Одређивање обима ПСЧ без понављања

Ако имамо већи обим, имамо и прецизније резултате.

Са друге стране, јављају се веће неизорачке грешке, као и трошкови.

Наш циљ је да одредимо оптимално n .

Уведимо ознаке: θ : параметар који оцењујемо;

$\hat{\theta}$: оцена параметра;

d : "подношљиво" одступање ($d > 0$);

α : ризик да се премаши d (обично мало: 0.05, 0.01, 0.1).

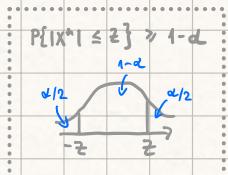
} унапред задати

Дакле: $P\{|\hat{\theta} - \theta| > d\} \leq \alpha$

Одређивање обима за оцењивање \bar{x}

$$P\{|\bar{x}_n - \bar{x}| > d\} \leq \alpha \Rightarrow P\{|\bar{x}_n - \bar{x}| \leq d\} \geq 1 - \alpha \Rightarrow P\left\{\frac{|\bar{x}_n - \bar{x}|}{\frac{s}{\sqrt{n}} \sqrt{1 - \frac{n}{N}}} \leq \frac{d}{\frac{s}{\sqrt{n}} \sqrt{1 - \frac{n}{N}}}\right\} \geq 1 - \alpha$$

$x^* \sim N(0,1)$



$$\begin{aligned} &\Rightarrow \frac{d}{\frac{s}{\sqrt{n}} \sqrt{1 - \frac{n}{N}}} \geq z, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2} \Rightarrow \frac{d}{z} \geq \frac{s}{\sqrt{n}} \sqrt{1 - \frac{n}{N}} \\ &\Rightarrow \frac{d^2}{z^2} \geq \frac{s^2}{n} \left(1 - \frac{n}{N}\right) \\ &\Rightarrow \frac{d^2}{z^2} \geq \frac{s^2}{n} - \frac{s^2}{N} \Rightarrow \frac{s^2}{n} \leq \frac{d^2}{z^2} + \frac{s^2}{N} \end{aligned}$$

Теорема 1: $n \geq \frac{1}{\frac{d^2}{s^2 z^2} + \frac{1}{N}}$, где $\Phi(z) = 1 - \frac{\alpha}{2}$

Напомена: d, α, N су познати, ћемо прочитати из таблице.

Проблем: s^2 је непознато.

Не можемо га оценити са s_n^2 , јер узорак још немамо.

Решење: Узимамо узорак из сличних истраживања из прошлости или направимо прелиминарно истраживање.

Тако добијамо s_n^2 .

Одређивање обима за оцењивање \hat{t}

$$P\{|\hat{t} - t| > d\} \leq \alpha \Rightarrow P\{|\hat{t} - t| \leq d\} \geq 1 - \alpha \Rightarrow P\left\{\frac{|\hat{t} - t|}{\sqrt{\frac{N}{N-1} \cdot \frac{n}{n-1}}} \leq \frac{d}{\sqrt{\frac{N}{N-1} \cdot \frac{n}{n-1}}}\right\} \geq 1 - \alpha$$

$\sim N(0,1)$

$$\Rightarrow \frac{d}{\sqrt{\frac{N}{N-1} \cdot \frac{n}{n-1}}} \geq z, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2} \Rightarrow \frac{d}{z} \geq \frac{\sqrt{N}}{\sqrt{n-1}} \sqrt{1 - \frac{n}{N}}$$

$$\Rightarrow \frac{d^2}{z^2} \geq \frac{N^2 n^2}{n(n-1)}$$

$$\Rightarrow \frac{d^2}{z^2} \geq \frac{N^2 n^2}{n(n-1)} - N^2 \Rightarrow \frac{N^2 n^2}{n(n-1)} \leq \frac{d^2}{z^2} + N^2$$

Теорема 2: $n \geq \frac{1}{\frac{d^2}{z^2} + \frac{1}{N}}, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2}$

Напомена: Проблем непознатог t решавамо на исти начин.

Одређивање обима за оцењивање p

$$P\{|p_n - p| > d\} \leq \alpha \Rightarrow P\{|p_n - p| \leq d\} \geq 1 - \alpha \Rightarrow P\left\{\frac{|p_n - p|}{\sqrt{\frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}}} \leq \frac{d}{\sqrt{\frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}}}\right\} \geq 1 - \alpha$$

$\sim N(0,1)$

$$\Rightarrow \frac{d}{\sqrt{\frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}}} \geq z, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2} \Rightarrow \frac{d}{z} \geq \sqrt{\frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}}$$

$$\Rightarrow \frac{d^2}{z^2} \geq \frac{N-n}{N-1} \cdot \frac{p(1-p)}{n}$$

$$\Rightarrow \frac{d^2}{z^2} \geq \frac{N}{N-1} \cdot \frac{p(1-p)}{n} - \frac{p(1-p)}{N-1} \Rightarrow \frac{N p(1-p)}{(N-1)n} \leq \frac{d^2}{z^2} + \frac{p(1-p)}{N-1}$$

Теорема 3: $n \geq \frac{1}{\frac{d^2}{z^2} \cdot \frac{N}{N-1} \cdot \frac{p(1-p)}{n} + \frac{1}{N}}, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2}$

Напомена: p нам је непознато. Може као и пре, а може и на други начин:

Искористимо да вади $p(1-p) \leq 1/4$.

Мало грубља апроксимација, али олакшава рачун

Тада је: $n \geq \frac{1}{\frac{4d^2}{z^2 \cdot \frac{N}{N-1}} + \frac{1}{N}}, \quad \text{где } \Phi(z) = 1 - \frac{\alpha}{2}$

Овим смо завршили ПСУ.

Поставља се питање када треба користити ПСУ?

У случајевима када имамо добар узорачки оквир,
али скоро никакве додатне информације по којим бисмо јединке могли да групишемо.

Пример: Имамо списак студената целог универзитета,
али само по имену и презимену.

7.

Методи избора узорка са неједнаким вероватноћама избора јединки

деф. Уводимо помоћно обележје: свакој јединки додељујемо величину M_i . ($i = 1, N$)

При томе, $\sum_{i=1}^N M_i = M$.

деф. $P_i := \frac{M_i}{M}$ је вероватноћа избора i -те јединке у једном бирању.

Напомена: При томе, очигледно вакви $\sum_{i=1}^N P_i = 1$.

a) **са понављањем:** - узмемо, па вратимо;
- тиме почетна расподела p_i -ева остаје иста ($p_i = \frac{M_i}{M}$)

б) **дез понављања:** - извучена i -та ($p_i = \frac{M_i}{M}$)
- избацимо је
- извлачимо j -ту ($p_j = \frac{M_j}{M-M_i}$)
- избацимо је
⋮

Наводимо методе избора оваквог узорка:

1) Метод кумуланте:

Из таблице случ. др. бирајмо број $B = \overline{1, M}$.

- | | | |
|---|---------------|------------------------|
| $B \in [1, M_1]$ | \Rightarrow | извукли смо јединку 1; |
| $B \in [M_1+1, M_1+M_2]$ | \Rightarrow | извукли смо јединку 2; |
| \vdots | | \vdots |
| $B \in [M_1+\dots+M_{k-1}+1, M_1+\dots+M_k]$ | \Rightarrow | извукли смо јединку k; |
| \vdots | | \vdots |
| $B \in [M_1+\dots+M_{n-1}+1, \underbrace{M_1+\dots+M_n}_M]$ | \Rightarrow | извукли смо јединку n. |

Границе се зову **кумуланте**. $(M_1, M_1+M_2, M_1+M_2+M_3, \dots)$

Метод је коректан: $P_i = \frac{M_1 + \dots + M_i - (M_1 + \dots + M_{i-1})}{M} = \frac{M_i}{M}$.

Напомена: Све ово је за узорак са понављањем.

За без понављања: ако извучемо неки од раније - одбацијемо га.

Мана: код великих популација, тешко рачунамо кумуланте.

Зато уводимо други метод.

2) Лахиријев метод:

Означимо са $K = \max M_i$.

Бирајмо уређени пар: (i, R) - где $i \in \{1, 2, \dots, N\}$ и $R \in \{1, 2, \dots, K\}$

Ако је $R \leq M_i \Rightarrow i$ -та јединка је ушла у узорак;
 $R > M_i \Rightarrow$ није ушла.

Поступак понављамо док не добијемо N јединки. (различитих, ако је без понављања)

Метод је коректан:

$\underset{\text{оно старо}}{p_i} = \sum_{s=1}^{\infty} p_i(s)$, где је $p_i(s)$ вероватноћа да i -то јединка буде извучена у s -том покушају
 $(s-1$ није једна, па s -ти покушај је i -ту)

Вашти: $p_i(1) = \frac{1}{N} \cdot \frac{M_i}{K}$ ($\begin{array}{l} \text{оранж} - \text{морамо извукти } i\text{-ту јединку од } N \\ \text{син} - \text{нора } R < M_i, \text{ а } R = i, K \end{array}$)

$$p_i(2) = \left(1 - \underbrace{\sum_{l=1}^N \frac{1}{N} \cdot \frac{M_l}{K}}_q \right) \cdot \frac{1}{N} \cdot \frac{M_i}{K}$$

⋮ q (није извучена јединка) (тј. пропало)

Уочимо правило: $p_i(s) = q^{s-1} \cdot \frac{1}{N} \cdot \frac{M_i}{K}$.

Удацимо то: $\underset{\text{оранж}}{p_i} = \sum_s^{\infty} \left(q^{s-1} \cdot \frac{1}{N} \frac{M_i}{K} \right) = \frac{1}{N} \frac{M_i}{K} \cdot \frac{1}{1 - \left(1 - \frac{1}{N} \frac{M_i}{K} \right)}$

$$= \frac{1}{N} \frac{M_i}{K} \cdot \frac{1}{\frac{N}{NK} \sum M_i}$$

$$= \frac{M_i}{M}$$

Hansen - Hurwitz - ове оцене

Гледамо како изгледају оцене код јединки са неједнаким вероватноћама избора, са понављањем.
Нове оцене ће у индексу имати ознаку **HH**.

Теорема 1: Нека је p_i вероватноћа избора i -те јединке у извлачењу код узорковања са понављањем.

1) Оцена $\hat{t}_{HH} = \frac{1}{n} \sum_{i \in S} \frac{x_i}{p_i}$ је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\hat{t}_{HH}) = \frac{1}{n} \sum_{i=1}^N p_i \left(\frac{x_i}{p_i} - t \right)^2$;

3) Непристрасна оцена те дисперзије је $D(\hat{t}_{HH}) = \frac{1}{n(n-1)} \sum_{i \in S} \left(\frac{x_i}{p_i} - \hat{t}_{HH} \right)^2$.

y_i iid
иста расп. као y

Доказ: 1) $E(\hat{t}_{HH}) = E\left(\frac{1}{n} \sum_{i \in S} \frac{x_i}{p_i}\right) = \frac{1}{n} E\left(\sum_{i \in S} \frac{x_i}{p_i}\right) = \frac{1}{n} E\left(\sum_{i \in S} y_i\right) \stackrel{\downarrow}{=} \frac{1}{n} \sum_{i \in S} E y_i$
 $\stackrel{(*)}{=} \frac{1}{n} \cdot n \cdot t = t \quad \Rightarrow \text{јесте непристрасна}$

(*) $y_i: \left(\frac{x_1}{p_1}, \dots, \frac{x_N}{p_N} \right) \Rightarrow EY = \sum x_i - t$

И имамо да $i \in S$ (узорак) $\Rightarrow n \cdot t$
(не популацији)

2) $D(\hat{t}_{HH}) = D\left(\frac{1}{n} \sum_{i \in S} \frac{x_i}{p_i}\right) \stackrel{iid}{=} \frac{1}{n^2} \sum_{i \in S} Dy_i = \frac{1}{n^2} \cdot n \cdot Dy = \frac{1}{n} Dy$
 $\stackrel{(**I)}{=} \frac{1}{n} \sum_{i=1}^N \left(\frac{x_i}{p_i} - t \right)^2 \cdot p_i$

(**) Рачунамо на два начина:

I) $Dy = E(y - EY)^2 = \sum \left(\frac{x_i}{p_i} - t \right)^2 \cdot p_i$
II) $Dy = EY^2 - (EY)^2 = \sum \frac{x_i^2}{p_i} - t^2$

3) $E(D(\hat{t}_{HH})) = E\left[\frac{1}{n(n-1)} \sum_{i \in S} \left(\frac{x_i}{p_i} - \hat{t}_{HH} \right)^2\right] = \frac{1}{n(n-1)} E\left[\sum_{i \in S} \left(\frac{x_i}{p_i} - \frac{1}{n} \sum_{i \in S} \frac{x_i}{p_i} \right)^2\right]$
 $= \frac{1}{n(n-1)} E\left[\sum_{i \in S} \left(\frac{x_i^2}{p_i^2} - 2 \frac{x_i}{p_i} \frac{1}{n} \sum_{i \in S} \frac{x_i}{p_i} + \frac{1}{n^2} \left(\sum_{i \in S} \frac{x_i}{p_i} \right)^2 \right)\right]$
 $= \frac{1}{n(n-1)} E\left[\sum_{i \in S} \frac{x_i^2}{p_i^2} - \frac{2}{n} \left(\sum_{i \in S} \frac{x_i}{p_i} \right)^2 + \frac{n}{n^2} \left(\sum_{i \in S} \frac{x_i}{p_i} \right)^2\right] = \frac{1}{n(n-1)} E\left[\sum_{i \in S} \frac{x_i^2}{p_i^2} - \frac{1}{n} \left(\sum_{i \in S} \frac{x_i}{p_i} \right)^2\right]$
 $= \frac{1}{n(n-1)} \left[\sum_{i \in S} E\left(\frac{x_i^2}{p_i^2}\right) - \frac{1}{n} E\left(\sum_{i \in S} \frac{x_i}{p_i}\right)^2 \right] = \frac{1}{n(n-1)} \left[\sum_{i \in S} E(y_i^2) - \frac{1}{n} E\left(\sum_{i \in S} y_i\right)^2 \right]$
 $\stackrel{EY^2 = Dy + (EY)^2}{=} \frac{1}{n(n-1)} \left[n \cdot \sum_{i=1}^N \frac{x_i^2}{p_i^2} \cdot p_i - \frac{1}{n} (D(\sum y_i) + E(\sum y_i)^2) \right]$
 $\stackrel{iid}{=} \frac{1}{n(n-1)} \left[n \cdot \sum_{i=1}^N \frac{x_i^2}{p_i^2} - \frac{1}{n} (n Dy + (n EY)^2) \right]$
 $\stackrel{(*)}{=} \frac{1}{n(n-1)} \left[n \cdot \sum_{i=1}^N \frac{x_i^2}{p_i^2} - Dy - nt^2 \right]$
 $= \frac{1}{n(n-1)} \left[n \cdot \left(\sum_{i=1}^N \frac{x_i^2}{p_i^2} - t^2 \right) - Dy \right] \stackrel{(**II)}{=} \frac{1}{n(n-1)} [n \cdot Dy - Dy]$
 $= \frac{1}{n} \cdot Dy \stackrel{(**I)}{=} D(\hat{t}_{HH}) \quad \Rightarrow \text{јесте непристрасна}$

Теорема 2: Нека је p_i вероватноћа избора i -те јединке у извлачењу код узорковања са понављањем.

1) Оцена $\bar{X}_{\text{нн}} = \frac{1}{Nn} \sum_{i \in S} \frac{x_i}{p_i}$ је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\bar{X}_{\text{нн}}) = \frac{1}{n} \sum_{i=1}^N p_i \left(\frac{x_i}{Np_i} - \bar{X} \right)^2$;

3) Непристрасна оцена те дисперзије је $\hat{D}(\bar{X}_{\text{нн}}) = \frac{1}{n(n-1)} \sum_{i \in S} \left(\frac{x_i}{Np_i} - \bar{X}_{\text{нн}} \right)^2$.

Доказ: тривијално следи из Т1 и чињенице $\bar{X} = \frac{1}{N} \cdot t$.

Напомена: Оцене за ПСУ са понављањем су специј. случај НЧ.

Доказ: Користимо да је у ПСУ $p_i = \frac{1}{N}$.

$$\bar{X}_{\text{нн}} = \frac{1}{N \cdot n} \sum_{i \in S} \frac{x_i}{p_i} = \frac{1}{Nn} \sum_{i \in S} x_i \cdot N = \frac{1}{n} \sum_{i \in S} x_i = \bar{X}_n$$

Остале такође тривијално

Напомена: Предности оцене $\hat{t}_{\text{нн}}$ у односу на ПСУ са понављањем:

- није потребно знати N ;

- није потребно знати све p_i , већ само за оне i које су упале у узорак.

9.

Horvitz - Thompson - ове оцене

За неједнаке вероватноће избора, без понављања, оцене нису неке + су компликоване.

Ми ћемо радити Horvitz - Thompson - ове, које могу да се користе за сваки план узорковања. (и со и без)

Теорема 1: Нека је π_i вероватноћа избора i -те јединке.

Нека је π_{ij} ($i \neq j$) вероватноћа избора i -те и j -те јединке.

Такође, нека $\pi_i > 0$, $\pi_{ij} > 0$. ($\forall i, j = 1, N$, $i \neq j$)

1) Оцена $\hat{t}_{HT} = \sum_{i=1}^J \frac{x_i}{\pi_i}$ је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\hat{t}_{HT}) = \sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot X_i^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} X_i X_j$;

3) Непристрасна оцена те дисперзије је $\hat{D}(\hat{t}_{HT}) = \sum_{i=1}^J \frac{1-\pi_i}{\pi_i^2} \cdot X_i^2 + \sum_{i=1}^J \sum_{j \neq i} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{X_i X_j}{\pi_i \pi_j}$;

Напомена: J је број различитих јединки у узорку.

Пол \sum мисли се да узимамо различите, што не мора да значи првих J !

Другим речима: $\hat{t}_{HT} = \sum_{i=1}^J \frac{x_i}{\pi_i} = \sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i$

Букв. исто
што и $i \in S$

ако се нека понови,
због ове суне та се
рачунати само једном

$I_i: \begin{pmatrix} 0 & 1 \\ 1-\pi_i & \pi_i \end{pmatrix}$, $I_{ij}: \begin{pmatrix} 0 & 1 \\ 1-\pi_{ij} & \pi_{ij} \end{pmatrix}$

↑
i-та јединка
улао у узорак

За узорак без понављања важи $J = n$.

Напомена: $\hat{D}(\hat{t}_{HT})$ има проблем: $\pi_{ij} - \pi_i \pi_j$ може бити негативно.

Тада је ова оцена бескорисна и праве се (компликованије) пристрасне модификације.

Исто ће важити у $\boxed{10}$ за $\widehat{D}_{sys}(\hat{t}_{HT})$.

$$\text{Доказ: 1) } E(\hat{t}_{\text{HT}}) = E\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i\right) = \sum_{i=1}^N \frac{x_i}{\pi_i} E I_i = \sum_{i=1}^N \frac{x_i}{\pi_i} \pi_i = \sum_{i=1}^N x_i = t \Rightarrow \text{јесте непристрасна;}$$

$$\begin{aligned} 2) D(\hat{t}_{\text{HT}}) &= D\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i\right) = E\left[\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i - E\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i\right)\right)^2\right] \\ &= E\left[\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i - \sum_{i=1}^N \frac{x_i}{\pi_i} E I_i\right)^2\right] = E\left[\left(\sum_{i=1}^N \frac{x_i}{\pi_i} \cdot I_i - \sum_{i=1}^N \frac{x_i}{\pi_i} \pi_i\right)^2\right] \\ &= E\left[\left(\sum_{i=1}^N \frac{x_i}{\pi_i} (I_i - \pi_i)\right)^2\right] \\ &\stackrel{(A)}{=} E\left[\sum_{i=1}^N \frac{x_i^2}{\pi_i^2} (I_i - \pi_i)^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{x_i}{\pi_i} \frac{x_j}{\pi_j} (I_i - \pi_i)(I_j - \pi_j)\right] \\ &= \sum_{i=1}^N \frac{x_i^2}{\pi_i^2} E(I_i - EI_i)^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{x_i}{\pi_i} \frac{x_j}{\pi_j} E(I_i I_j - I_i \pi_j - \pi_i I_j + \pi_i \pi_j) \\ &= \sum_{i=1}^N \frac{x_i^2}{\pi_i^2} D I_i + \sum_{i=1}^N \sum_{j \neq i} \frac{x_i x_j}{\pi_i \pi_j} (E(I_i I_j) - \pi_j E I_i - \pi_i E I_j + \pi_i \pi_j) \\ &= \sum_{i=1}^N \frac{x_i^2}{\pi_i^2} \pi_i(1-\pi_i) + \sum_{i=1}^N \sum_{j \neq i} \frac{x_i x_j}{\pi_i \pi_j} (\pi_i \pi_j - \pi_j \pi_i - \pi_i \pi_j + \pi_i \pi_j) \\ &= \sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot x_i^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} x_i x_j; \end{aligned}$$

$$(A) (a_1 + \dots + a_n)^2 = \sum_{i=1}^n a_i^2 + 2 \sum_{i < j} a_i a_j$$

$$\begin{aligned} 3) E(D(\hat{t}_{\text{HT}})) &= E\left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{x_i x_j}{\pi_i \pi_j}\right] \\ &= E\left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 \cdot I_i + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{x_i x_j}{\pi_i \pi_j} I_i I_j\right] \\ &= \sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 \cdot E I_i + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{x_i x_j}{\pi_i \pi_j} E(I_i I_j) \\ &= \sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 \pi_i + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{x_i x_j}{\pi_i \pi_j} \cdot \pi_i \pi_j \\ &= D(\hat{t}_{\text{HT}}) \Rightarrow \text{јесте непристрасна.} \end{aligned}$$

Теорема 2: 1) Оцена $\bar{x}_{\text{HT}} = \frac{1}{N} \sum_{i=1}^N \frac{x_i}{\pi_i}$ је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене вали: $D(\bar{x}_{\text{HT}}) = \frac{1}{N^2} \sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} x_i x_j$;

3) Непристрасна оцена те дисперзије је: $\hat{D}(\bar{x}_{\text{HT}}) = \frac{1}{N^2} \left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot x_i^2 + \sum_{i=1}^N \sum_{j \neq i} \frac{\pi_i \pi_j - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{x_i x_j}{\pi_i \pi_j} \right]$;

Доказ: тривијално следи из т1 и чињенице $\bar{x} = \frac{1}{N} \cdot t$.

10.

Sen-Yates-Grundy - јеве оцене

Постоји боља оцена за $D(\hat{t}_{HT})$ од $\widehat{D}(\hat{t}_{HT})$. Доказатећмо да је и она непристрасна.

Ова оцена се користи за фиксирани $\lambda = n$ (тј. код узорка без понављања, и различитих)

Лема 1: 1) $\sum_{i=1}^n \pi_i = n$;

2) $\sum_{\substack{i=1 \\ j \neq i}}^n \pi_{ij} = (n-1) \pi_i$.

I_i из [9]

Доказ: 1) Тривијално $(\sum_{i=1}^n \pi_i = \sum_{i=1}^n EI_i = E(\sum_{i=1}^n I_i) = EI = \lambda = n)$;

$$\begin{aligned} 2) \sum_{\substack{i=1 \\ j \neq i}}^n \pi_{ij} &= \sum_{j=1}^n E(I_i I_j) = E(I_i \sum_{\substack{j=1 \\ j \neq i}}^n I_j) = E(I_i (n - I_i)) \\ &= E(nI_i - I_i^2) = E(nI_i - I_i) = (n-1) EI_i = (n-1) \pi_i. \end{aligned}$$

Теорема 1: Непристрасна оцена за $D(\hat{t}_{HT})$ је: $\widehat{D}_{SYG}(\hat{t}_{HT}) = \sum_{i \in S} \sum_{\substack{j \in S \\ j \neq i}} \frac{\pi_i \pi_j - \pi_{ij}}{\pi_{ij}} \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2$, $\pi_i, \pi_j, \pi_{ij} > 0$.

Доказ: Запишимо $D(\hat{t}_{HT})$ у алт. облику:

$$\begin{aligned} D(\hat{t}_{HT}) &= \sum_{i=1}^n \frac{1 - \pi_i}{\pi_i} \cdot X_i^2 + \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} X_i X_j = \sum_{i=1}^n \frac{\pi_i (1 - \pi_i)}{\pi_i^2} \cdot X_i^2 - \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n \frac{\pi_i \pi_j - \pi_{ij}}{\pi_i \pi_j} X_i X_j \\ &\stackrel{(*)}{=} \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n (\pi_i \pi_j - \pi_{ij}) \left(\frac{x_i}{\pi_i} \right)^2 - \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n (\pi_i \pi_j - \pi_{ij}) \left(\frac{x_i}{\pi_i} \cdot \frac{x_j}{\pi_j} \right) \\ &\stackrel{(**)}{=} \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n (\pi_i \pi_j - \pi_{ij}) \left(\left(\frac{x_i}{\pi_i} \right)^2 + \left(\frac{x_j}{\pi_j} \right)^2 \right) - \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n (\pi_i \pi_j - \pi_{ij}) \cdot 2 \left(\frac{x_i}{\pi_i} \cdot \frac{x_j}{\pi_j} \right) \\ &= \sum_{i=1}^n \sum_{\substack{j=1 \\ j > i}}^n (\pi_i \pi_j - \pi_{ij}) \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 \end{aligned}$$

(*) $\sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n (\pi_i \pi_j - \pi_{ij}) = \sum_{i=1}^n \pi_{ij} - \pi_i \sum_{i=1}^n \pi_j$
 $\stackrel{(*)}{=} (n-1) \pi_i - \pi_i (n - \pi_i) = \pi_i (1 - \pi_i)$

$$E(\widehat{D}_{SYG}(\hat{t}_{HT})) = E \left[\sum_{i \in S} \sum_{\substack{j \in S \\ j \neq i}} \frac{\pi_i \pi_j - \pi_{ij}}{\pi_{ij}} \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 \right]$$

(**) Нпр. $n=4$:

12	21	31	41
13	23	32	42
14	24	34	44

Остали су исти

$$= \sum_{i=1}^n \sum_{\substack{j=1 \\ j > i}}^n \frac{\pi_i \pi_j - \pi_{ij}}{\pi_{ij}} \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 E(I_i I_j)$$

алт. облик

$$= \sum_{i=1}^n \sum_{\substack{j=1 \\ j > i}}^n \frac{\pi_i \pi_j - \pi_{ij}}{\pi_{ij}} \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 \pi_{ij} = \sum_{i=1}^n \sum_{\substack{j=1 \\ j > i}}^n (\pi_i \pi_j - \pi_{ij}) \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 \stackrel{\downarrow}{=} D(\hat{t}_{HT}) \Rightarrow \text{јесте непристрасна.}$$

Теорема 2: Непристрасна оцена за $D(\bar{x}_{HT})$ је: $\widehat{D}_{SYG}(\bar{x}_{HT}) = \frac{1}{N^2} \left[\sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n \frac{\pi_i \pi_j - \pi_{ij}}{\pi_{ij}} \left(\frac{x_i}{\pi_i} - \frac{x_j}{\pi_j} \right)^2 \right]$;

Доказ: тривијално из Т1

II **дeо**

11.

Стратификовани узорак.

Веза укупне оцене и оцена по стратумима

* Имамо популацију коју поделимо на делове/слојеве који се зову **стратуми**.

У оквиру једног стратума, вредности обележја треба да буду што хомогенија, а између стратума што хетерогенија.



$N = N_1 + \dots + N_L$: популација подељена на L стратума.

Проблем: Не знамо вредност обележја. Како направити стратуме онда?

Тражи се нека особина јединки коју знамо и да је у корелацији са вредностима обележја.

(нпр. обележје: плата, особина: ниво студија)

Бр. елем. у стратуму мора бити ≥ 2 .

Када направимо стратуме, валимо узорак обима $n = n_1 + \dots + n_L$ (n_h - независни)

Тако добијамо **стратификовани узорак**.

Стратификовани случајан узорак је онај стр. уз. код ког се узорци из сваког стратума воде као ПСУ.

Напомена: Са страт. уз. се добијају боље оцене него код ПСУ, јер имамо податне информације.

Постављају се питања: - на колико стратума поделити популацију, тј. које L узети?

- коју особину изабрати за поделу?

- како изабрати n_h -ове?

* деф. N - обим популације;

n - обим узорка

L - број стратума;

N_h - обим h -тог стратума;

n_h - обим узорка из h -тог стратума.

деф. Обележја јединки h -тог стратума: x_{hi} , $i \in \{1, \dots, N_h\}$;

деф. Средња вредност обележја на h -том стратуму: $\bar{x}_h = \frac{\sum_{i=1}^{N_h} x_{hi}}{N_h}$;

деф. Укупна сума обележја на h -том стратуму: $t_h = \sum_{i=1}^{N_h} x_{hi}$;

деф. Пропорција јединки стратума са неким својством на h -том стратуму: $p_h = \frac{A_h}{N_h}$;

деф. Дисперзија на h -том стратуму: $s_h^2 = \frac{1}{N_h-1} \sum_{i=1}^{N_h} (x_{hi} - \bar{x}_h)^2$.

деф. Узорачка средина на h -том стратуму: $\bar{x}_{n_h} = \frac{\sum_{i \in S_h} x_{hi}}{n_h}$;

деф. Оцена укупне суме на h -том стратуму: $\hat{t}_h = \sum_{i=1}^{n_h} x_{hi}$;

деф. Пропорција јединки стратума са својством p_h на узорку из h -тог стратума: $p_{n_h} = \frac{a_{n_h}}{n_h}$.

деф. Оцена дисперзије на h -том стратуму: $s_{n_h}^2 = \frac{1}{n_h-1} \sum_{i=1}^{n_h} (x_{hi} - \bar{x}_{n_h})^2$.

Следеће две теореме су „опште“: вати за сваки стратификовани узорак (не само случајни).

Теорема 1: Нека је у сваком стратуму \hat{t}_h непристрасна оцена за t_h .
и нека је у сваком стратуму $D(\hat{t}_h)$ непристрасна оцена за $D(t_h)$.

- 1) Оцена $\hat{\tau} = \sum_h^L \hat{t}_h$ је непристрасна оцена за t ;
- 2) За дисперзију те оцене важи: $D(\hat{\tau}) = \sum_h^L D(\hat{t}_h)$;
- 3) Непристрасна оцена те дисперзије је $D(\hat{\tau}) = \sum_h^L D(\hat{t}_h)$.

Показ: 1) $E(\hat{\tau}) = E\left(\sum_h^L \hat{t}_h\right) = \sum_h^L E(\hat{t}_h) = \sum_h^L t_h = t \Rightarrow$ јесте непристрасна;

$$2) D(\hat{\tau}) = D\left(\sum_h^L \hat{t}_h\right) \stackrel{\text{нез.}}{=} \sum_h^L D(\hat{t}_h);$$

$$3) E(D(\hat{\tau})) = E\left(\sum_h^L D(\hat{t}_h)\right) = \sum_h^L E(D(\hat{t}_h)) = \sum_h^L D(\hat{t}_h) = D(\hat{\tau}) \Rightarrow$$
 јесте непристрасна.

Теорема 2: Нека је у сваком стратуму \hat{x}_h непристрасна оцена за \bar{x}_h .
и нека је у сваком стратуму $D(\hat{x}_h)$ непристрасна оцена за $D(\bar{x}_h)$.

- 1) Оцена $\hat{x} = \frac{1}{N} \sum_h^L N_h \hat{x}_h$ је непристрасна оцена за \bar{x} ;
- 2) За дисперзију те оцене важи: $D(\hat{x}) = \frac{1}{N^2} \sum_h^L N_h^2 D(\hat{x}_h)$;
- 3) Непристрасна оцена те дисперзије је $D(\hat{x}) = \frac{1}{N^2} \sum_h^L N_h^2 D(\hat{x}_h)$;

Показ: 1) $E(\hat{x}) = E\left(\frac{1}{N} \sum_h^L N_h \hat{x}_h\right) = \frac{1}{N} \sum_h^L N_h E(\hat{x}_h) = \frac{1}{N} \sum_h^L N_h \bar{x}_h = \frac{1}{N} \sum_h^L t_h = \frac{t}{N} = \bar{x} \Rightarrow$ јесте непристрасна;

$$2) D(\hat{x}) = D\left(\frac{1}{N} \sum_h^L N_h \hat{x}_h\right) \stackrel{\text{нез.}}{=} \frac{1}{N^2} \sum_h^L N_h^2 D(\hat{x}_h);$$

$$3) E(D(\hat{x})) = E\left(\frac{1}{N^2} \sum_h^L N_h^2 D(\hat{x}_h)\right) = \frac{1}{N^2} \sum_h^L N_h^2 E(D(\hat{x}_h)) = \frac{1}{N^2} \sum_h^L N_h^2 D(\hat{x}_h) = D(\hat{x}) \Rightarrow$$
 јесте непристрасна.

12.

Стратификован случајан узорак са и без понављања

Сва тврђења у овом питању су последица / спец. случај претходне две „опште“ теореме.

Следеће три теореме ване за узорак без понављања.

Теорема 1: Ако се из сваког стратума вади ПСУ без понављања:

- 1) Оцена $\hat{t}_{STR} = \sum_h^L N_h \cdot \bar{x}_{n_h}$ је непристрасна оцена за t ;
- 2) За дисперзију те оцене вани: $D(\hat{t}_{STR}) = \sum_h^L \frac{N_h^2 \cdot s_{n_h}^2}{n_h} \left(1 - \frac{n_h}{N_h}\right)$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\hat{t}_{STR}) = \sum_h^L \frac{N_h^2 \cdot s_{n_h}^2}{n_h} \left(1 - \frac{n_h}{N_h}\right)$.

Теорема 2: Ако се из сваког стратума вади ПСУ без понављања:

- 1) Оцена $\bar{x}_{STR} = \frac{1}{N} \sum_h^L N_h \cdot \bar{x}_{n_h}$ је непристрасна оцена за \bar{x} ;
- 2) За дисперзију те оцене вани: $D(\bar{x}_{STR}) = \frac{1}{N^2} \sum_h^L \frac{N_h^2 \cdot s_{n_h}^2}{n_h} \left(1 - \frac{n_h}{N_h}\right)$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\bar{x}_{STR}) = \frac{1}{N^2} \sum_h^L \frac{N_h^2 \cdot s_{n_h}^2}{n_h} \left(1 - \frac{n_h}{N_h}\right)$.

Теорема 3: Ако се из сваког стратума вади ПСУ без понављања:

- 1) Оцена $\hat{p}_{STR} = \frac{1}{N} \sum_h^L N_h \cdot p_{n_h}$ је непристрасна оцена за p ;
- 2) За дисперзију те оцене вани: $D(\hat{p}_{STR}) = \frac{1}{N^2} \sum_h^L \frac{N_h^2 (N_h - n_h)}{n_h (N_h - 1)} p_h (1 - p_h)$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\hat{p}_{STR}) = \frac{1}{N^2} \sum_h^L \frac{N_h (N_h - n_h)}{n_h - 1} p_{n_h} (1 - p_{n_h})$.

Следеће три теореме важе за узорак са понављањем.

Теорема 4: Ако се из сваког стратума вали ПСУ са понављањем:

- 1) Оцена $\hat{t}_{STR} = \sum_h^L N_h \cdot \bar{x}_{n_h}$ је непристрасна оцена за t ;
- 2) За дисперзију те оцене вали: $D(\hat{t}_{STR}) = \sum_h^L \frac{N_h(N_h-1)}{n_h} \cdot s_h^2$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\hat{t}_{STR}) = \sum_h^L N_h^2 \cdot \frac{s_{m_h}^2}{n_h}$.

Теорема 5: Ако се из сваког стратума вали ПСУ са понављањем:

- 1) Оцена $\bar{X}_{STR} = \frac{1}{N} \sum_h^L N_h \cdot \bar{x}_{n_h}$ је непристрасна оцена за \bar{x} ;
- 2) За дисперзију те оцене вали: $D(\bar{X}_{STR}) = \frac{1}{N^2} \sum_h^L \frac{N_h(N_h-1)}{n_h} \cdot s_h^2$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\bar{X}_{STR}) = \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{s_{m_h}^2}{n_h}$.

Теорема 6: Ако се из сваког стратума вали ПСУ са понављањем:

- 1) Оцена $\hat{P}_{STR} = \frac{1}{N} \sum_h^L N_h \cdot p_{n_h}$ је непристрасна оцена за p ;
- 2) За дисперзију те оцене вали: $D(\hat{P}_{STR}) = \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{p_{n_h}(1-p_{n_h})}{n_h}$;
- 3) Непристрасна оцена те дисперзије је $\widehat{D}(\hat{P}_{STR}) = \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{p_{m_h}(1-p_{m_h})}{n_{h-1}}$.

Напомена: У наставку подразумевамо ПСУ без понављања, осим ако не нагласимо другачије.

13.

Пропорционални избор обима узорка по стратумима

У наредна три питања гледамо избор обима по стратумима.

* За почетак, гледамо случај када су n_h -ови пропорционални N_h -овима: $\frac{n_1}{N_1} = \dots = \frac{n_L}{N_L} = \frac{n}{N}$ $\Rightarrow n_h = \frac{n}{N} \cdot N_h$

Означимо са \hat{t}_{PROP} специјални случај за \hat{t}_{STR} под овим условима.

Од две оцене, дола је она са мањим MSE.

Како су и \hat{t}_{PROP} и \hat{t} непристрасне, довољно је да им упоредимо дисперзије.

$$D(\hat{t}_{\text{PROP}}) \stackrel{\text{II T4.2}}{=} \sum_h^L N_h^2 \cdot \frac{\beta_{n_h}^2}{n_h} \left(1 - \frac{n_h}{N_h}\right) \stackrel{n_h}{=} \sum_h^L \frac{N}{n} N_h \cdot \beta_n^2 \left(1 - \frac{n}{N}\right) = \frac{N}{n} \left(1 - \frac{n}{N}\right) \sum_h^L N_h \beta_n^2;$$

$$\begin{aligned} D(\hat{t}) &\stackrel{\text{II T4.2}}{=} \frac{N^2 \beta_n^2}{n} \left(1 - \frac{n}{N}\right) = \frac{N}{n} \left(1 - \frac{n}{N}\right) \cdot N \cdot \frac{1}{N-1} \sum_i^n (x_{hi} - \bar{x})^2 \\ &\stackrel{(*)}{=} \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \sum_h^L \sum_{i=1}^{N_h} (x_{hi} - \bar{x}_h)^2 \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \sum_h^L \sum_{i=1}^{N_h} (x_{hi} - \bar{x}_h + \bar{x}_h - \bar{x})^2 \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \sum_h^L \sum_{i=1}^{N_h} [(x_{hi} - \bar{x}_h)^2 + 2(x_{hi} - \bar{x}_h)(\bar{x}_h - \bar{x}) + (\bar{x}_h - \bar{x})^2] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \left[\sum_h^L (N_h - 1) \beta_{n_h}^2 + 2 \sum_h^L (\bar{x}_h - \bar{x}) \sum_i^{N_h} (x_{hi} - \bar{x}_h) + \sum_h^L N_h \cdot (\bar{x}_h - \bar{x})^2 \right] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \left[\sum_h^L (N_h - 1) \beta_{n_h}^2 + 2 \sum_h^L (\bar{x}_h - \bar{x}) (N_h \cdot \bar{x}_h - N_h \cdot \bar{x}_h) + \sum_h^L N_h \cdot (\bar{x}_h - \bar{x})^2 \right] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{N}{N-1} \left[\sum_h^L (N_h - 1) \beta_{n_h}^2 + \sum_h^L N_h \cdot (\bar{x}_h - \bar{x})^2 \right] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \left(1 + \frac{1}{N-1}\right) \left[\sum_h^L N_h \beta_{n_h}^2 - \sum_h^L \beta_{n_h}^2 + \sum_h^L N_h (\bar{x}_h - \bar{x})^2 \right] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \left[\sum_h^L N_h \beta_{n_h}^2 - \sum_h^L \beta_{n_h}^2 + \frac{1}{N-1} \sum_h^L (N_h - 1) \beta_{n_h}^2 + \frac{N}{N-1} \sum_h^L N_h (\bar{x}_h - \bar{x})^2 \right] \\ &= \frac{N}{n} \left(1 - \frac{n}{N}\right) \sum_h^L N_h \beta_{n_h}^2 + \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{1}{N-1} \left[-(N-1) \sum_h^L \beta_{n_h}^2 + \sum_h^L (N_h - 1) \beta_{n_h}^2 + N \sum_h^L N_h (\bar{x}_h - \bar{x})^2 \right] \\ &= D(\hat{t}_{\text{PROP}}) + \frac{N}{n} \left(1 - \frac{n}{N}\right) \frac{1}{N-1} \left[N \sum_h^L N_h (\bar{x}_h - \bar{x})^2 - \sum_h^L (N - N_h) \beta_{n_h}^2 \right] \end{aligned}$$

(*) Често да бројимо редом од x_1 до x_n , преbroјавамо све у првом стратуму, па све у другом, па у трећем итд.

$$\text{Пакле: } D(\hat{t}_{\text{PROP}}) \leq D(\hat{t}) \quad \text{АККО} \quad N \sum_h^L N_h (\bar{x}_h - \bar{x})^2 \geq \sum_h^L (N - N_h) s_h^2 \Rightarrow \sum_h^L N_h (\bar{x}_h - \bar{x})^2 \geq \sum_h^L \left(1 - \frac{N_h}{N}\right) s_h^2$$

ФИКС.
↑ што веће
што мање

Закључак:

\hat{t}_{PROP} ће бити боља од \hat{t} када је:

→ дисперзија у сваком стратуму **што мања** (што хомогенији у оквиру стратума)

→ ср. вр. на стратумима **што различитије** од ср. вр. целе популације (што хетерогеније између стратума)

→ N_h да буде **што веће**.

14.

Оптимални избор обима узорка по стратумима

Када су дисперзије стратума s_h^2 приближно једнаке, пропорц. избор n_h -ова ради добар посао.
Ако ипак s_h^2 -ови варирају - користимо тзв. оптимални избор - тиме се сада давимо.

* Видели смо шта се дешава ако су величине узорака из сваког стратума пропорционалне.

Сада нас заинима: колики узорак узети из сваког од стратума како би оцена била што боља?

За непристрасне оцене вани да су боље ако имају мању дисперзију.

Имамо проблем условног екстремума: за унапред задате трошкове, тражимо најмању дисперзију. (самим тим и најбољу оцену)

$$(*) \text{ Подсетимо се: } D(\hat{t}_{STR}) = \sum_h^L \frac{n_h^2}{n_h} \cdot s_h^2 \left(1 - \frac{n_h}{N_h} \right) = \sum_h^L \frac{n_h^2}{n_h} \cdot s_h^2 - \sum_h^L N_h \cdot s_h^2$$

деф. $(**)$ $C = C_0 + \sum_{h=1}^L c_h \cdot n_h$, где: C - укупни трошкови;
 C_0 - фиксни трошкови узорковања;

c_h - трошкови по јединки h -тог стратума, променљиво
 n_h - обим узорка из h -тог стратум - познато;
- непознато.

Лакле: тражимо минимум дисперзије, тј. функције $(*)$ уз услов о трошковима $(**)$.

То радимо тако што правимо Лагранџијеву Φ -ју за тражење условног екстремума за Φ -ју више променљивих.
При томе, тражимо непознате n_1, \dots, n_L .

$$L(n_1, \dots, n_L, \lambda) = \sum_h^L \frac{n_h^2}{n_h} \cdot b_h^2 - \sum_h^L N_h \cdot b_h^2 + \lambda \left(\sum_h^L C_h \cdot n_h + c_0 - C \right)$$

$$= \sum_h^L \frac{n_h^2}{n_h} \cdot b_h^2 \left(1 - \frac{N_h}{n_h} \right) + \lambda \left(\sum_h^L C_h \cdot n_h + c_0 - C \right)$$

(Ф-ја чији се минимум тражи
+ λ услов)

$$\frac{\partial L}{\partial n_h} = -\frac{N_h b_h^2}{n_h^2} + \lambda C_h = 0, \quad h=1, \dots, L$$

$$\frac{\partial L}{\partial \lambda} = \sum_h^L C_h n_h + c_0 - C = 0$$

} систем $(L+1)$ једначина

$$\lambda C_h = \frac{N_h b_h^2}{n_h^2} \Rightarrow n_h = \frac{N_h b_h}{\sqrt{\lambda} \sqrt{C_h}}$$

$$\sum_h^L C_h n_h = \sum_h^L C_h \frac{N_h b_h}{\sqrt{\lambda} \sqrt{C_h}} = C - c_0 \Rightarrow \frac{1}{\sqrt{\lambda}} \cdot \sum_h^L \sqrt{C_h} N_h b_h = C - c_0 \Rightarrow \sqrt{\lambda} = \frac{\sum_h^L \sqrt{C_h} N_h b_h}{C - c_0}$$

бројач ће бити k
вршто је било k засете

$$\Rightarrow n_h = \frac{N_h b_h}{\frac{\sum_k^L \sqrt{C_k} N_k b_k}{C - c_0} \sqrt{C_h}} \Rightarrow n_h = \frac{(C - c_0) \frac{N_h b_h}{\sqrt{C_h}}}{\sum_k^L \sqrt{C_k} N_k b_k}$$

$$n = \frac{(C - c_0) \sum_h^L \frac{N_h b_h}{\sqrt{C_h}}}{\sum_h^L \sqrt{C_h} N_h b_h}$$

Ова стационарна тачка је кандидат за минимум. То морамо да проверимо.
Зато рачунамо и друге парцијалне изводе (који иду у матрицу Φ):

$$\begin{aligned} \frac{\partial^2 L}{\partial n_h^2} &= \frac{2 N_h b_h^2}{n_h^3} \\ \frac{\partial^2 L}{\partial n_i \partial n_j} &= 0, \quad i \neq j \end{aligned} \quad \Rightarrow \quad \Phi = \begin{bmatrix} \frac{2 N_1^2 b_1^2}{n_1^3} & & & 0 \\ & \ddots & & \\ 0 & & \frac{2 N_L^2 b_L^2}{n_L^3} \end{bmatrix}$$

(Ф поз. дефинитна \Rightarrow минимум;
Ф нег. дефинитна \Rightarrow максимум.)

Како је Φ позитивно дефинитна \Rightarrow у тој тачки јесте минимум.

Напомена: Може се десити $n_h > N_h$.

Тада се за n_h проглашава да је $n_h = N_h$, а онда поновимо процес, или без тог стратума.

15.

Нейман-ов избор обима узорка по стратумима

- * Помаграмо специј. случај оптималног узорковања, када је $c_1 = \dots = c_L = c$. Такав избор зове се **Нейманов избор узорка**.

Изводимо цео поступак поново.

$$C = C_0 + \sum_h^L c_h n_h, \text{ па кад наметнемо услов: } C = C_0 + c \cdot n.$$

Како су трошкови унапред познати, то значи и да ће n бити познато (тј. фиксно).

Опет тражимо минимум по n_h за $D(\hat{t}_{STR}) = \sum_h^L \frac{N_h^2}{n_h} \Delta_h^2 \left(1 - \frac{n_h}{N_h}\right)$, уз услов $n_1 + \dots + n_L = n$.

$$L(n_1, \dots, n_L, \lambda) = \sum_h^L \frac{N_h^2}{n_h} \Delta_h^2 \left(1 - \frac{n_h}{N_h}\right) + \lambda(n_1 + \dots + n_L - n) = \sum_h^L \frac{N_h^2}{n_h} \Delta_h^2 - \sum_h^L N_h \cdot \Delta_h^2 + \lambda(n_1 + \dots + n_L - n)$$

$$\frac{\partial L}{\partial n_h} = -\frac{N_h^2 \Delta_h^2}{n_h^2} + \lambda = 0, \quad h=1, \dots, L \quad \Rightarrow \quad n_h = \frac{N_h \Delta_h}{\sqrt{\lambda}};$$

$$\frac{\partial L}{\partial \lambda} = n_1 + \dots + n_L - n = 0 \quad \Rightarrow \quad n = \sum_h^L \frac{N_h \Delta_h}{\sqrt{\lambda}} \quad \Rightarrow \quad \sqrt{\lambda} = \frac{\sum_h^L N_h \Delta_h}{n} \quad \Rightarrow \quad n_h = \frac{N_h \Delta_h}{\sum_k^L N_k \Delta_k} \cdot n$$

Нашли смо стационарну тачку (n_h) , па проверавамо да ли је минимум:

$$\left. \begin{aligned} \frac{\partial^2 L}{\partial n_h^2} &= \frac{2 N_h^2 \Delta_h^2}{n_h^3} \\ \frac{\partial^2 L}{\partial n_i \partial n_j} &= 0, \quad i \neq j \end{aligned} \right\} \Rightarrow \Phi = \begin{bmatrix} \frac{2 N_1^2 \Delta_1^2}{n^3} & 0 & \cdots & 0 \\ 0 & \frac{2 N_2^2 \Delta_2^2}{n^3} & & \\ & & \ddots & \\ & & 0 & \frac{2 N_L^2 \Delta_L^2}{n^3} \end{bmatrix}$$

Како је Φ позитивно дефинитна \Rightarrow у тој тачки јесте минимум.

$$\text{Када то уврстимо: } D(\hat{t}_{STR}) = \sum_h^L \frac{N_h^2}{n_h} \Delta_h^2 - \sum_h^L N_h \cdot \Delta_h^2 = \sum_h^L \frac{\frac{N_h^2 \Delta_h^2}{N_h \Delta_h}}{\frac{\sum_h^L N_h \Delta_h}{n}} - \sum_h^L N_h \cdot \Delta_h^2$$

$$D(\hat{t}_{NEY}) = \frac{1}{n} \left(\sum_h^L N_h \Delta_h \right)^2 - \sum_h^L N_h \Delta_h^2.$$

* **Проблем:** Да бисмо знали колики узорак бирајмо, морамо да знамо Δ_h -ове.

Решење: Исто као овај пут: Нпр. прелиминарно истраживање.

* Како се све ове оцене пореде међусобно?

\hat{t}^{ney} , \hat{t}^{prop} , \hat{t}_{ney} могу да се пореде, зато што је и унапред познато.

Оцена добијена оптималним узорковањем не може да се пореди са њима, јер и није познато.

Лема 1: $D(\hat{t}_{ney}) \leq D(\hat{t}_{prop})$.

$$\begin{aligned}
 \text{Доказ: } D(\hat{t}_{prop}) - D(\hat{t}_{ney}) &= \frac{N-1}{n} \sum_h^L N_h \delta_h^2 - \frac{1}{n} \left(\sum_h^L N_h \delta_h \right)^2 + \cancel{\sum_h^L N_h \delta_h^2} \\
 &= \frac{N}{n} \sum_h^L N_h \delta_h^2 - \frac{N}{n} \cdot \frac{1}{N} \left(\sum_h^L N_h \delta_h \right)^2 \quad \frac{n}{N^2} = \frac{\sum_h N_h}{N^2} \\
 &= \frac{N}{n} \left[\sum_h^L N_h \delta_h^2 - \frac{2}{N} \left(\sum_h^L N_h \delta_h \right)^2 + \frac{1}{N} \left(\sum_h^L N_h \delta_h \right)^2 \right] \\
 &= \frac{N}{n} \left[\sum_h^L N_h \delta_h^2 - \frac{2}{N} \left(\sum_h^L N_h \delta_h \right) \left(\sum_k^L N_k \delta_k \right) + \frac{\sum_h N_h}{N^2} \left(\sum_k^L N_k \delta_k \right)^2 \right] \\
 &= \frac{N}{n} \sum_h^L N_h \left[\delta_h^2 - 2\delta_h \cdot \frac{1}{N} \sum_k^L N_k \delta_k + \left(\frac{1}{N} \sum_k^L N_k \delta_k \right)^2 \right] \\
 &= \frac{N}{n} \sum_h^L N_h \left[\delta_h - \frac{1}{N} \sum_k^L N_k \delta_k \right]^2 \geq 0
 \end{aligned}$$

Закључак: $D(\hat{t}_{ney}) \leq D(\hat{t}_{prop}) \stackrel{(15)}{\leq} D(\hat{t})$

$\uparrow_{\text{у век}} \quad \uparrow_{\text{у главном (хомог. + хетерог.)}}$

III
дeо

Количничко оцењивање

* За почетак, објаснимо шта је количничко оцењивање.

Већ код стратификовања смо имали неку помоћну променљиву / обележје.

Боље оцене можемо добити на два начина:

a) узорковање вршимо на основу те помоћне променљиве - дакле, стратификован узорак;

б) на основу те помоћне променљиве правимо боље оцене у оквиру ПСУ.

Ово се зове **количничко оцењивање** и **линеарно - регресиона оцењивање**.

Код количничког оцењивања, имамо главно обележје x и помоћно обележје y .

Оцена на основу количничког оцењивања ће бити боља ако:

→ x, y су у корелацији;

→ ако из $y=0$ следи и $x=0$.

Пример: x - бр. животиња у шуми
 y - површина шуме

Контрапример: x - принос китарице
 y - загађеност ваздуха

Јесу у корелацији, или ако је $y=0$, принос расте.

21.

Количничко оцењивање на основу ПСУ без понављања

Имамо узорак: $(x_1, y_1), \dots, (x_n, y_n)$ обима n .

Напомена: За количничко оцењивање, увек морамо да знамо колико је $t_y = \sum_{i=1}^n y_i$

деф. Количник популације је $R := \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^n y_i} = \frac{t}{t_y} = \frac{\bar{x}}{\bar{y}}$

деф. Количничка оцена за R је узорачки количник $\hat{R} := \frac{\sum_{i=1}^n \hat{x}_i}{\sum_{i=1}^n \hat{y}_i} = \frac{\bar{\hat{x}}_n}{\bar{\hat{y}}_n}$

деф. Количничка оцена за t је $\hat{t}_R = \hat{R} \cdot t_y$. (t_y је познато)

Количничка оцена за \bar{x} је $\bar{\hat{x}}_R = \hat{R} \cdot \bar{y}$. ($\bar{y} = \frac{t_y}{N}$ је познато)

Када се користи количничко оцењивање?

- за оцењивање количника R ;
- за оцењивање t када N није познато, или t_y јесте познато;
- некад добијемо боље оцене за t и \bar{x} . [22]

* Испитујемо пристрасност ових оцена. Испоставите се да су асимптотски непристрасне.

Због тога, за велико n , за меру њиховог квалитета се опет користи дисперзија, уместо MSE.

Теорема 1: \hat{R} је асимптотски непристрасна.

$$\text{Доказ: } \hat{R} - R = \frac{\bar{x}_n}{\bar{y}_n} - R = \frac{\bar{x}_n - \bar{y}_n \cdot R}{\bar{y}_n} \approx \frac{\bar{x}_n - R \cdot \bar{y}_n}{\bar{y}}$$

за велико n : $\bar{y}_n \approx \bar{y}$

$$E(\hat{R} - R) \approx E\left(\frac{\bar{x}_n - R \cdot \bar{y}_n}{\bar{y}}\right) = \frac{1}{\bar{y}} E(\bar{x}_n - R \cdot \bar{y}_n) = \frac{1}{\bar{y}} [E(\bar{x}_n) - R \cdot E(\bar{y}_n)] \stackrel{\text{ПСУ}}{=} \frac{\bar{x} - R \bar{y}}{\bar{y}} = 0$$

$$\Rightarrow E(\hat{R}) \approx R.$$

Последица: \hat{t}_R и $\bar{\hat{x}}_R$ су асимптотски непристрасне оцене. (јер $t_y = \text{const}$)

Теорема 2: За велико n , важе следеће апроксимације:

$$1) \text{MSE}(\hat{R}) \approx D(\hat{R}) = \frac{(1-\frac{n}{N})}{n\bar{y}^2} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - R\bar{y}_i)^2;$$

$$2) \text{MSE}(\hat{t}_R) \approx D(\hat{t}_R) = \frac{N^2(1-\frac{n}{N})}{n} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - R\bar{y}_i)^2;$$

$$3) \text{MSE}(\bar{x}_R) \approx D(\bar{x}_R) = \frac{(1-\frac{n}{N})}{n} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - R\bar{y}_i)^2.$$

Доказ: 1) Због Т1, јасно је да важи $\text{MSE} \approx D$.

$$\text{MSE}(\hat{R}) = E(\hat{R}-R)^2 \approx E\left(\frac{\bar{x}_n - R\bar{y}_n}{\bar{y}}\right)^2 = \frac{1}{\bar{y}^2} [E(\bar{x}_n - R\bar{y}_n)^2]$$

$$= \frac{1}{\bar{y}^2} \left[E(\bar{x}_n - R\bar{y}_n)^2 - \underbrace{[E(\bar{x}_n - R\bar{y}_n)]^2}_{=0, \text{ па може}} \right] = \frac{1}{\bar{y}^2} D(\bar{x}_n - R\bar{y}_n) = \frac{1}{\bar{y}^2} D(\bar{d}_n)$$

$$\stackrel{\text{Ита}}{=} \frac{1}{\bar{y}^2} \left(1 - \frac{n}{N}\right) \frac{\bar{d}_n^2}{n} = \frac{1}{\bar{y}^2} \left(1 - \frac{n}{N}\right) \cdot \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i=1}^n (d_i - \bar{d})^2 = \frac{(1-\frac{n}{N})}{n\bar{y}^2} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - R\bar{y}_i)^2;$$

2) Тривијално (стрелица);

3) Тривијално (стрелица).

Напомена: За ове дисперзије предлажемо следеће оцене:

$$\widehat{D}(\hat{t}_R) := \frac{N^2(1-\frac{n}{N})}{n} \cdot \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \hat{R}\bar{y}_i)^2;$$

$$\widehat{D}(\bar{x}_R) := \frac{(1-\frac{n}{N})}{n} \cdot \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \hat{R}\bar{y}_i)^2;$$

Ове оцене су асимптотски непристрашне. (зато што код ПСУ без пон. важи $E(s_n^2) = b_j^2$, па ће важити $E(s_{n,j}^2) = b_j^2$.)

22.

Упоређивање количничке оцене и оцене на основу ПСУ без понављања

* Подсетимо се: Кофицијент корелације мери лин. зав. између обележја ($|r| \approx 1 \Rightarrow y \approx kx + n$)

$$\rho_{x,y} := \frac{E[(x - Ex)(y - Ey)]}{\sqrt{Dx} \cdot \sqrt{Dy}} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{N-1}{N} \cdot s_x^2} \cdot \sqrt{\frac{N-1}{N} \cdot s_y^2}} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{(N-1) s_x s_y}$$

$$x = \left(\begin{array}{c} x_1 \\ \vdots \\ x_N \end{array} \right) \Rightarrow Ex = \frac{1}{N} \sum_{i=1}^N x_i, \quad Ex^2 = \frac{1}{N} \sum_{i=1}^N x_i^2$$

↓
псуз д.п.

$$Dx = Ex^2 - (Ex)^2 = \frac{1}{N} \sum_{i=1}^N x_i^2 - \bar{x}^2 = \frac{1}{N} \left(\sum_{i=1}^N x_i^2 - N\bar{x}^2 \right) = \frac{N-1}{N} s_x^2$$

(***), вр. 11

* Поредимо оцене \hat{t}_R и \hat{t} (ПСУ без понављања)

Како су обе непристрасне (\hat{t}_R асимптотски), поредимо им дисперзије:

$$\begin{aligned} \rightarrow D(\hat{t}) &\stackrel{[1]}{=} N^2 \left(1 - \frac{n}{N}\right) \frac{1}{n} s_x^2 \\ \rightarrow D(\hat{t}_R) &\stackrel{[24]}{=} \frac{N^2 \left(1 - \frac{n}{N}\right)}{n} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - Ry_i)^2 \stackrel{\substack{\text{правилно} \\ \text{врт. облик}}}{=} \frac{N^2 \left(1 - \frac{n}{N}\right)}{n} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - Ry_i - (\bar{x} - R\bar{y}))^2 \\ &= \frac{N^2 \left(1 - \frac{n}{N}\right)}{n} \cdot \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \bar{x} - R(y_i - \bar{y}))^2 \\ &= \frac{N^2 \left(1 - \frac{n}{N}\right)}{n} \cdot \frac{1}{N-1} \cdot \left(\sum_{i=1}^N (x_i - \bar{x})^2 + \sum_{i=1}^N R^2 (y_i - \bar{y})^2 - 2R \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) \right) \\ &= \frac{N^2 \left(1 - \frac{n}{N}\right)}{n} \left(s_x^2 + R^2 s_y^2 - 2R \rho s_x s_y \right) \end{aligned}$$

погледати деф. ρ
 $\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) = \rho \cdot (N-1) \cdot s_x s_y$

$$\hat{t}_R \text{ је већа од } \hat{t} \Leftrightarrow D(\hat{t}_R) - D(\hat{t}) = N^2 \left(1 - \frac{n}{N}\right) \frac{1}{n} (R^2 s_y^2 - 2R \rho s_x s_y) < 0$$

$$\Leftrightarrow R^2 s_y^2 - 2R \rho s_x s_y < 0$$

$$\Leftrightarrow R > 0 \quad \rho > \frac{1}{2} R \frac{s_y}{s_x}$$

$$\Leftrightarrow \rho > \frac{1}{2} \cdot \frac{CV_y}{CV_x}, \quad CV_x := \frac{s_x}{\bar{x}} \text{ је кофицијент варијације.}$$

Закључак: \hat{t}_R је већа од \hat{t} када је ρ што веће, тј. што је већа лин. зав. између x и y .

23.

Количничко оцењивање на основу узорка са неједнаким вероватноћама избора

Користимо Horvitz - Thompson - ове оцене. ^[1]

леф. За оцену R , користимо $\hat{R}_{HT} := \frac{\hat{t}_{HT}(x)}{\hat{t}_{HT}(y)} = \frac{\sum x_i}{\sum \frac{y_i}{\pi_i}}$. (писаћемо ове само \hat{R})

леф. $\hat{t}_R := \hat{R}_{HT} \cdot t_y$.

$\bar{x}_R := \hat{R}_{HT} \cdot \bar{y}$.

Радимо аналогно као у [2]:

Теорема 1: \hat{R}_{HT} је асимптотски непристрасна.

$$\text{Доказ: } \hat{R} - R = \frac{\hat{t}_{HT}(x)}{\hat{t}_{HT}(y)} - R = \frac{\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)}{\hat{t}_{HT}(y)} \approx \frac{\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)}{t_y}$$

за велико n : $\hat{t}_{HT}(y) \approx t_y$

$$E(\hat{R} - R) \approx E\left(\frac{\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)}{t_y}\right) = \frac{1}{t_y} \left[E(\hat{t}_{HT}(x)) - R \cdot E(\hat{t}_{HT}(y)) \right] \stackrel{[3]}{=} \frac{1}{t_y} (t_x - R t_y) = 0.$$

Последица: \hat{t}_R и \bar{x}_R су асимптотски непристрасне оцене.

Теорема 2: За велико n , ватије следеће апроксимације:

$$\begin{aligned}
 1) \quad \text{MSE}(\hat{R}_{HT}) &\approx D(\hat{R}_{HT}) = \frac{1}{t_y^2} \left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot (x_i - R \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} (x_i - R \cdot y_i)(x_j - R \cdot y_j) \right]; \\
 2) \quad \text{MSE}(\hat{t}_R) &\approx D(\hat{t}_R) = \sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot (x_i - R \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} (x_i - R \cdot y_i)(x_j - R \cdot y_j); \\
 3) \quad \text{MSE}(\bar{x}_R) &\approx D(\bar{x}_R) = \frac{1}{N^2} \left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot (x_i - R \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} (x_i - R \cdot y_i)(x_j - R \cdot y_j) \right].
 \end{aligned}$$

Показ: 1) Због Т1, јасно је да ватни $\text{MSE} \approx D$.

$$\begin{aligned}
 \text{MSE}(\hat{R}) &= E(\hat{R} - R)^2 \approx E\left(\frac{\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)}{t_y}\right)^2 = \frac{1}{t_y^2} [E(\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y))^2] \\
 &= \frac{1}{t_y^2} \left[E(\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y))^2 - \underbrace{(E(\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)))^2}_{=0, \text{ па може}} \right] = \frac{1}{t_y^2} D(\hat{t}_{HT}(x) - R \cdot \hat{t}_{HT}(y)) \\
 &= \frac{1}{t_y^2} D\left(\sum_{i=1}^N \frac{x_i}{\pi_i} - R \cdot \sum_{i=1}^N \frac{y_i}{\pi_i}\right) = \frac{1}{t_y^2} D\left(\sum_{i=1}^N \frac{x_i - R \cdot y_i}{\pi_i}\right) = \frac{1}{t_y^2} D(\hat{t}_{HT}(x - R \cdot y)) \\
 &= \frac{1}{t_y^2} \left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i} \cdot (x_i - R \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} (x_i - R \cdot y_i)(x_j - R \cdot y_j) \right]
 \end{aligned}$$

2) Тривијално (стрелица);

3) Тривијално (стрелица).

Напомена: За ове дисперзије предлажемо следеће оцене:

$$\begin{aligned}
 \widehat{D}(\hat{t}_R) &:= \sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot (x_i - \hat{R} \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{(x_i - \hat{R} \cdot y_i)(x_j - \hat{R} \cdot y_j)}{\pi_{ij}}; \\
 \widehat{D}(\bar{x}_R) &:= \frac{1}{N^2} \left[\sum_{i=1}^N \frac{1-\pi_i}{\pi_i^2} \cdot (x_i - \hat{R} \cdot y_i)^2 + \sum_{i=1}^N \sum_{j \neq i}^N \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{(x_i - \hat{R} \cdot y_i)(x_j - \hat{R} \cdot y_j)}{\pi_{ij}} \right].
 \end{aligned}$$

24.

Количничко оцењивање на основу стратификованог узорка без понављања комбинована оцена

деф. За оцену R , користимо $\hat{R}_c := \frac{\hat{t}_{STR}(x)}{\hat{t}_{STR}(y)} = \frac{\sum_{h=1}^L N_h \cdot x_{nh}}{\sum_{h=1}^L N_h \cdot y_{nh}} = \frac{\bar{x}_{STR}}{\bar{y}_{STR}}$. (писаћемо овеј само \hat{R})

деф. $\hat{t}_{RC} := \hat{R}_c \cdot t_y$.

$$\bar{x}_{RC} := \hat{R}_c \cdot \bar{y}$$

Овеј исто.

Теорема 1: \hat{R}_c је асимптотски непристрасна.

за велико n : $\bar{y}_{STR} \approx \bar{y}$

$$\text{Доказ: } \hat{R} - R = \frac{\bar{x}_{STR}}{\bar{y}_{STR}} - R = \frac{\bar{x}_{STR} - R \cdot \bar{y}_{STR}}{\bar{y}_{STR}} \approx \frac{\bar{x}_{STR} - R \cdot \bar{y}_{STR}}{\bar{y}}$$

$$E(\hat{R} - R) \approx E\left(\frac{\bar{x}_{STR} - R \cdot \bar{y}_{STR}}{\bar{y}}\right) = \frac{1}{\bar{y}} [E(\bar{x}_{STR}) - R \cdot E(\bar{y}_{STR})] \stackrel{(17.2)}{=} \frac{1}{\bar{y}} (\bar{x} - R \cdot \bar{y}) = 0.$$

Последица: \hat{t}_{RC} и \bar{x}_{RC} су асимптотски непристрасне оцене.

Теорема 2: За велико n , ватије следеће апроксимације:

$$\begin{aligned}
 1) \quad \text{MSE}(\hat{R}_c) &\approx D(\hat{R}_c) = \frac{1}{t_y^2} \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_h^2(x) + R^2 \Delta_h^2(y) - 2R p_h \cdot \Delta_h(x) \Delta_h(y)) \right]; \\
 2) \quad \text{MSE}(\hat{t}_{RC}) &\approx D(\hat{t}_{RC}) = \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_h^2(x) + R^2 \Delta_h^2(y) - 2R p_h \cdot \Delta_h(x) \Delta_h(y)); \\
 3) \quad \text{MSE}(\bar{x}_{RC}) &\approx D(\bar{x}_{RC}) = \frac{1}{N^2} \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_h^2(x) + R^2 \Delta_h^2(y) - 2R p_h \cdot \Delta_h(x) \Delta_h(y)) \right].
 \end{aligned}$$

Доказ: 1) Због Т1, јасно је да ватни $\text{MSE} \approx D$.

$$\begin{aligned}
 \text{MSE}(\hat{R}) &= E(\hat{R} - R)^2 \approx E\left(\frac{\bar{x}_{STR} - R \cdot \bar{y}_{STR}}{\bar{y}}\right)^2 = \frac{1}{\bar{y}^2} [E(\bar{x}_{STR} - R \cdot \bar{y}_{STR})^2] \\
 &= \frac{1}{\bar{y}^2} \left[E(\bar{x}_{STR} - R \cdot \bar{y}_{STR})^2 - \underbrace{(E(\bar{x}_{STR} - R \cdot \bar{y}_{STR}))^2}_{=0, \text{ па може}} \right] = \frac{1}{\bar{y}^2} D(\bar{x}_{STR} - R \cdot \bar{y}_{STR}) \\
 &= \frac{1}{\bar{y}^2} D\left(\frac{1}{N} \sum_h^L N_h \bar{x}_{n_h} - R \cdot \frac{1}{N} \sum_h^L N_h \bar{y}_{n_h}\right) = \frac{1}{\bar{y}^2} D\left(\frac{1}{N} \sum_h^L N_h \frac{\sum_{i \in S} (x_{n_i} - R y_{n_i})}{n_h}\right) = \frac{1}{\bar{y}^2} D((\bar{x} - R \bar{y})_{STR}) \quad \text{ново обележје} \\
 &\stackrel{[2]}{=} \frac{1}{\bar{y}^2} \cdot \frac{1}{N^2} \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \cdot \frac{1}{N_h - 1} \sum_{i \in S} (x_{n_i} - R y_{n_i} - (\bar{x}_h - R \bar{y}_h))^2 \\
 &= \frac{1}{t_y^2} \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \frac{1}{N_h - 1} \sum_{i \in S} ((x_{n_i} - \bar{x}) - R(y_{n_i} - \bar{y}_h))^2 \\
 &= \frac{1}{t_y^2} \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \frac{1}{N_h - 1} \sum_{i \in S} ((x_{n_i} - \bar{x}_h))^2 + R^2 (y_{n_i} - \bar{y}_h)^2 - 2R(x_{n_i} - \bar{x})(y_{n_i} - \bar{y}_h) \\
 &= \frac{1}{t_y^2} \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_h^2(x) + R^2 \Delta_h^2(y) - 2R p_h \cdot \Delta_h(x) \Delta_h(y)) \right]
 \end{aligned}$$

2) Тривијално (стрелица);

3) Тривијално (стрелица).

Напомена: Предланетмо следећу оцену:

$$\begin{aligned}
 \widehat{D}(\hat{t}_{RC}) &:= \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_{nh}^2(x) + \hat{R}^2 \Delta_{nh}^2(y) - 2\hat{R} p_h \cdot \Delta_{nh}(x) \Delta_{nh}(y)). \\
 \widehat{D}(\bar{x}_{RC}) &:= \frac{1}{N^2} \cdot \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) (\Delta_{nh}^2(x) + \hat{R}^2 \Delta_{nh}^2(y) - 2\hat{R} p_h \cdot \Delta_{nh}(x) \Delta_{nh}(y)) \right].
 \end{aligned}$$

25.

Количничко оцењивање на основу стратификованог узорка без понављања посебна по стратумима оцена

* На сваком стратуму оцењујемо укупну суму и онда их саберемо. (зато име \sum_h^L)

$$\text{леф. } \hat{R}_h := \frac{\hat{t}_h(x)}{\hat{t}_h(y)} = \frac{\bar{x}_{n_h}}{\bar{y}_{n_h}}; \quad - \quad \text{по [21], ово је асимптотски непристрасно} \quad (\text{стратум} = \text{псу})$$

$$\text{леф. } \hat{t}_{rs} := \sum_h^L \hat{R}_h \cdot t_h(y) = \sum_h^L \frac{\sum_{x \in S_h} x_{n_h}}{\sum_{y \in S_h} y_{n_h}} \cdot t_h(y)$$

$$\bar{x}_{rs} := \frac{1}{N} \cdot \hat{t}_{rs}$$

Теорема 1: \hat{t}_{rs} је асимптотски непристрасна.

$$\text{Доказ: } E(\hat{t}_{rs}) = \sum_h^L t_h(y) \cdot E(\hat{R}_h) \approx \sum_h^L t_h(y) \cdot R_h = \sum_h^L t_h(x) = t$$

Теорема 2: За велико n , важи следеће апроксимације:

$$1) \text{MSE}(\hat{t}_{rs}) \approx D(\hat{t}_{rs}) = \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\Delta_h^2(x) + R_h^2 \Delta_h^2(y) - 2 R_h \cdot p_h \cdot \Delta_h(x) \Delta_h(y) \right);$$

$$2) \text{MSE}(\bar{x}_{rs}) \approx D(\bar{x}_{rs}) = \frac{1}{N^2} \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\Delta_h^2(x) + R_h^2 \Delta_h^2(y) - 2 R_h \cdot p_h \cdot \Delta_h(x) \Delta_h(y) \right) \right].$$

$$\text{Доказ: } 1) \text{MSE}(\hat{t}_{rs}) \approx D(\hat{t}_{rs}) = D\left(\sum_h^L t_h(y) \cdot \hat{R}_h\right) = \sum_h^L D(t_h(y) \cdot \hat{R}_h) = \sum_h^L D(\hat{t}_{r_h}(x))$$

користимо волт. облик за $D(\hat{t}_r)$ из [22] $\approx \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\Delta_h^2(x) + R_h^2 \Delta_h^2(y) - 2 R_h \cdot p_h \cdot \Delta_h(x) \Delta_h(y) \right);$

2) Тривијално (стремила).

Напомена: За ове дисперзије предлажемо следеће оцене: (Δ_{n_h} уместо Δ_h)

$$\widehat{D}(\hat{t}_{rs}) := \sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\Delta_{n_h}^2(x) + R_h^2 \Delta_{n_h}^2(y) - 2 R_h \cdot p_h \cdot \Delta_{n_h}(x) \Delta_{n_h}(y) \right);$$

$$\widehat{D}(\bar{x}_{rs}) := \frac{1}{N^2} \left[\sum_h^L \frac{N_h^2}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\Delta_{n_h}^2(x) + R_h^2 \Delta_{n_h}^2(y) - 2 R_h \cdot p_h \cdot \Delta_{n_h}(x) \Delta_{n_h}(y) \right) \right].$$

* Када користимо комбиновану оцену, а када посебну по стратумима?

1° n_h велико, а нису сви n_h велики: комбинована;

2° n_h велики, а R_h -ови слични: комбинована;

3° n_h велики, а R_h -ови различити: посебна.

* Ако имамо помоћну променљиву у о којој знато све, да ли помоћу ње да стратификујемо или да правимо количничку оцену?

Некад једно, некад друго - нема правила.

Најчешће, ако постоји веза која није линеарна \Rightarrow стратификујемо.

Ако веза јесте линеарна

\Rightarrow правимо количничку оцену.

↓ због закључка у [22]

Линеарно - регресионо оцењивање

* Као и код количничког, и овде имамо помоћну променљиву

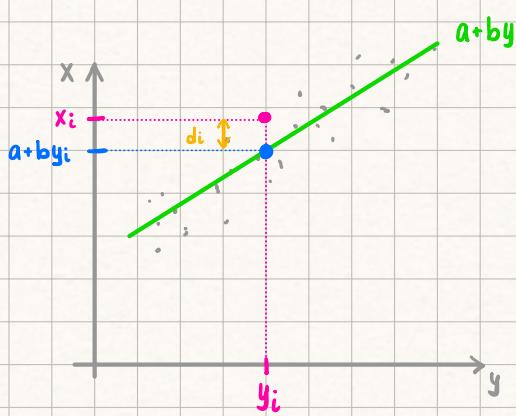
Потребно је: $\rightarrow x, y$ су у корелацији;

\rightarrow из $y=0$ не следи и $x=0$.

Пример: x - принос житарице
 y - загађеност ваздуха

Јесу у корелацији, али ако је $y=0$, принос расте.

* Вадимо узорке: $(x_1, y_1), \dots, (x_n, y_n)$.



Узорачки коef. корелације: $\hat{r} := \frac{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{s_x(x) \cdot s_y(y)}$.

Вали: $-1 \leq \hat{r} \leq 1$.

Ако је близу -1 или 1,
онда има смисла правити праву лин. регресије.

Напомена: $d_i := x_i - (a + b y_i)$

27.

Регресионо оцењивање на основу ПСУ без понављања када се в оцењује

Конструишемо праву линеарне регресије $x = a + b \cdot y$, користећи методу најмањих квадрата.

Нејлимо да збир квадрата одступања ($\sum_{i \in S} d_i^2$) буде што мањи.

Пругим речима, тражимо минимум ϕ -је $f(a, b) = \sum_{i \in S} (x_i - (a + b y_i))^2$. (на ста. начин)

$$\frac{\partial f}{\partial a} = 2 \sum_{i \in S} (x_i - a - b y_i) \cdot (-1) = 0$$

$$\frac{\partial f}{\partial b} = 2 \sum_{i \in S} (x_i - a - b y_i) \cdot (-y_i) = 0$$

$$\sum_{i \in S} x_i - \sum_{i \in S} a - \sum_{i \in S} b y_i = 0$$

$$\Rightarrow n \cdot a = \sum_{i \in S} x_i - b \sum_{i \in S} y_i$$

:n

$$a = \bar{x}_n - b \cdot \bar{y}_n$$

$$\sum_{i \in S} x_i y_i - \sum_{i \in S} a y_i - \sum_{i \in S} b y_i^2 = 0$$

$$\left. \begin{array}{l} a \cdot n + b \cdot \sum_{i \in S} y_i = \sum_{i \in S} x_i \\ a \cdot \sum_{i \in S} y_i + b \cdot \sum_{i \in S} y_i^2 = \sum_{i \in S} x_i y_i \end{array} \right\}$$

решавамо систем по a, b

(преко Крамера: $b = \frac{\Delta_b}{\Delta}$)

\checkmark
[a]
 Δ
лева

$$b = \frac{\begin{vmatrix} n & \sum_{i \in S} x_i \\ \sum_{i \in S} y_i & \sum_{i \in S} x_i y_i \end{vmatrix}}{\begin{vmatrix} n & \sum_{i \in S} y_i \\ \sum_{i \in S} y_i & \sum_{i \in S} y_i^2 \end{vmatrix}} = \frac{n \cdot \sum_{i \in S} x_i y_i - \sum_{i \in S} x_i \cdot \sum_{i \in S} y_i}{n \cdot \sum_{i \in S} y_i^2 - (\sum_{i \in S} y_i)^2} = \frac{\frac{1}{n} \sum_{i \in S} x_i y_i - \bar{x}_n \bar{y}_n}{\frac{1}{n} \sum_{i \in S} y_i^2 - (\bar{y}_n)^2} = \frac{\frac{1}{n} \left[\sum_{i \in S} x_i y_i - n \cdot \bar{x}_n \bar{y}_n \right]}{\frac{1}{n} \sum_{i \in S} y_i^2 - (\bar{y}_n)^2}$$

$$\begin{aligned} (*) &= \frac{\frac{1}{n} \left[\sum_{i \in S} (x_i - \bar{x}_n)(y_i - \bar{y}_n) \right]}{\frac{1}{n} \left[\sum_{i \in S} (y_i - \bar{y}_n)^2 \right]} = \frac{(n-1) \hat{P} s_n(x) s_n(y)}{(n-1) s_n^2(y)} \\ (***) &= \end{aligned}$$

 \Rightarrow

$$b = \hat{P} \cdot \frac{s_n(x)}{s_n(y)}$$

$$(*) \sum_{i \in S} (x_i - \bar{x}_n)(y_i - \bar{y}_n) = \sum_{i \in S} x_i y_i - \bar{x}_n \sum_{i \in S} y_i - \bar{y}_n \sum_{i \in S} x_i + \sum_{i \in S} \bar{x}_n \bar{y}_n$$

$$= \sum_{i \in S} x_i y_i - n \bar{x}_n \bar{y}_n - n \bar{y}_n \bar{x}_n + n \bar{x}_n \bar{y}_n = \sum_{i \in S} x_i y_i - n \bar{x}_n \bar{y}_n$$

$$(**) \frac{1}{n} \sum_{i \in S} (y_i - \bar{y}_n)^2 = \frac{1}{n} \sum_{i \in S} y_i^2 - \underbrace{2 \bar{y}_n \frac{1}{n} \sum_{i \in S} y_i}_{\bar{y}_n} + \underbrace{\frac{1}{n} \sum_{i \in S} \bar{y}_n^2}_{n \cdot \bar{y}_n^2} = \frac{1}{n} \sum_{i \in S} y_i^2 - (\bar{y}_n)^2$$

Ово је стационарна тачка, па треба проверити да ли је и минимум.

$$\left. \begin{array}{l} \frac{\partial^2 f}{\partial a^2} = 2n =: A \\ \frac{\partial^2 f}{\partial a \partial b} = 2 \sum_{i \in S} y_i =: B \\ \frac{\partial^2 f}{\partial b^2} = 2 \sum_{i \in S} y_i^2 =: C \end{array} \right\} \begin{bmatrix} A & B \\ B & C \end{bmatrix} \Rightarrow \begin{array}{ll} AC - B^2 > 0 & \text{(екстремум)} \\ A > 0 & \text{(минимум)} \end{array}$$

$$A > 0 \Leftrightarrow 2n > 0, \quad \text{тј. } n > 0 \quad \checkmark$$

$$\begin{aligned} AC - B^2 > 0 &\Leftrightarrow 4n \sum_{i \in S} y_i^2 - 4(\sum_{i \in S} y_i)^2 > 0 \Leftrightarrow n(y_1^2 + \dots + y_n^2) > (y_1 + \dots + y_n)^2 \\ &\Leftrightarrow (n-1)(y_1^2 + \dots + y_n^2) > \underbrace{2y_1 y_2}_{< y_1^2 + y_2^2} + \dots + \underbrace{2y_{n-1} y_n}_{< y_{n-1}^2 + y_n^2} \Rightarrow \checkmark \\ &\quad (\text{сваки се појави } n-1 \text{ пут}) \end{aligned}$$

Доказ, по методу најмањих квадрата, оцене за a и b су: $\hat{b} = \hat{p} \cdot \frac{s_n(x)}{s_n(y)}$, $\hat{a} = \bar{x}_n - \hat{b} \cdot \bar{y}_n$.
Тиме добијамо праву лин. регресије: $x = \hat{a} + \hat{b} \cdot y$.

Ово све значи да $x_i \approx \hat{a} + \hat{b} y_i$.

Када сумирамо за целу популацију: $\sum x_i \approx N \cdot \hat{a} + \hat{b} \sum y_i \stackrel{n}{\Rightarrow} \bar{x} \approx \hat{a} + \hat{b} \cdot \bar{y} \stackrel{\hat{a}}{\Rightarrow} \bar{x} \approx \bar{x}_n - \hat{b} \bar{y}_n + \hat{b} \bar{y}$.

Закључак: Ако се бира ПСУ без понављања, при чему b није унапред познат, имамо оцену:

$$\bar{x}_{LR} = \hat{a} + \hat{b} \cdot \bar{y}_n = \bar{x}_n + \hat{b}(\bar{y} - \bar{y}_n)$$

мотив

Теорема 1: Нека се бира ПСУ без понављања. Оцена \bar{x}_{LR} је непристрасна оцена за \bar{x}

$$\underline{\text{Доказ}}: E(\bar{x}_{LR}) = E(\bar{x}_n) + \hat{b}(E(\bar{y}) - E(\bar{y}_n)) \stackrel{\text{нсг}}{=} \bar{x} + \hat{b}(\bar{y} - \bar{y}) = \bar{x};$$

Напомена: Може се показати да за велико n : $D(\bar{x}_{LR}) \approx (1 - \frac{1}{n}) \cdot \frac{1}{n} \cdot s_x^2 \cdot (1 - p^2)$;

26.

Регресионо оцењивање на основу ПСУ без понављања када је b_0 познат

деф. Због мотива из [27], за познато b_0 дефинишемо оцене:

$$\bar{x}_{LR} := \bar{x}_n + b_0(\bar{y} - \bar{y}_n);$$

$$\hat{t}_{LR} := N \cdot \bar{x}_{LR}.$$

Теорема 1: Нека се бира ПСУ без понављања и b_0 познато. (претх. искуство)

1) Оцена \bar{x}_{LR} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи: $D(\bar{x}_{LR}) = \frac{1}{n} \left(1 - \frac{n}{N}\right) (\Delta_x^2 - 2b_0 \Delta_x \Delta_y + b_0^2 \Delta_y^2);$

3) Непристрасна оцена те дисперзије је $\widehat{D}(\bar{x}_{LR}) = \frac{1}{n} \left(1 - \frac{n}{N}\right) (\Delta_n(x) - 2b_0 \Delta_n(x) \Delta_n(y) + b_0 \Delta_n^2(y)).$

Доказ: 1) $E(\bar{x}_{LR}) = E(\bar{x}_n) + b_0(E(\bar{y}) - E(\bar{y}_n)) \stackrel{\text{нез}}{=} \bar{x} + b_0(\bar{y} - \bar{y}) = \bar{x};$

$$\begin{aligned} 2) D(\bar{x}_{LR}) &= D(\bar{x}_n + b_0(\bar{y} - \bar{y}_n)) \stackrel{(*)}{=} D(\bar{e}_n) \stackrel{\text{нсу}}{=} \boxed{(1 - \frac{n}{N}) \frac{1}{n} \Delta_e^2} \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} (e_i - \bar{e})^2 \stackrel{e_i}{=} (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i + b_0(\bar{y} - y_i)) - \bar{x}]^2 \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i - \bar{x}) - b_0(y_i - \bar{y})]^2 \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i - \bar{x})^2 - 2b_0(x_i - \bar{x})(y_i - \bar{y}) + b_0^2(y_i - \bar{y})^2] \\ &= (1 - \frac{n}{N}) \frac{1}{n} [\Delta_x^2 - 2b_0 \Delta_x \Delta_y + b_0^2 \Delta_y^2] \end{aligned}$$

$$\begin{aligned} (*) & e_i = x_i + b_0(\bar{y} - y_i) \\ \bar{e} &= \bar{x} + b_0(\bar{y} - \bar{y}) = \bar{x} \\ \bar{e}_n &= \bar{x}_n + b_0(\bar{y} - \bar{y}_n) \end{aligned}$$

$$\begin{aligned} 3) (1 - \frac{n}{N}) \frac{1}{n} \Delta_e^2 &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} (e_i - \bar{e}_n)^2 \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i + b_0(\bar{y} - y_i)) - (\bar{x}_n + b_0(\bar{y} - \bar{y}_n))]^2 \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i - \bar{x}_n) - b_0(\bar{y} - \bar{y}_n - \bar{y} + y_i)]^2 \\ &= (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i \in S} [(x_i - \bar{x}_n)^2 - 2b_0(x_i - \bar{x}_n)(y_i - \bar{y}_n) + b_0^2(y_i - \bar{y}_n)^2] \\ &= (1 - \frac{n}{N}) \frac{1}{n} [\Delta_n(x) - 2b_0 \Delta_n(x) \Delta_n(y) + b_0^2 \Delta_n^2(y)] \\ &= \widehat{D}(\bar{x}_{LR}) \end{aligned}$$

(***) $(1 - \frac{n}{N}) \frac{1}{n} \Delta_e^2$ јесте непристрасна оцена за $D(\bar{x}_{LR})$ јер је би непристрасна оцена за Δ_e^2 код ПСУ ЕП

ми доказујемо да је та оцена иста као наша

28.

Упоређивање регресионе оцене

* Прво поредимо лин-рег и ПСУ оцене:

$$D(\bar{x}_{LR}) \stackrel{[2]}{\approx} \left(1 - \frac{n}{N}\right) \cdot \frac{1}{n} s_x^2 \underbrace{(1-p^2)}_{-1 \leq p \leq 1}, \quad \text{за велико } n$$

$$D(\bar{x}_n) \stackrel{[1]}{=} \left(1 - \frac{n}{N}\right) \cdot \frac{1}{n} s_x^2$$

Закључак: За велико n , \bar{x}_{LR} је боља од \bar{x}_n , осим ако је $p=0$.

* Сада поредимо лин-рег и количничку:

$$D(\bar{x}_R) \stackrel{[2]}{\approx} \left(1 - \frac{n}{N}\right) \cdot \frac{1}{n} (s_x^2 + R^2 s_y^2 - 2R\rho s_x s_y), \quad \text{за велико } n$$

$$\begin{aligned} \Rightarrow D(\bar{x}_R) - D(\bar{x}_{LR}) &= \left(1 - \frac{n}{N}\right) \cdot \frac{1}{n} \cdot ((s_x p)^2 + (R s_y)^2 - 2R s_y s_x p) \\ &= \underbrace{\left(1 - \frac{n}{N}\right) \cdot \frac{1}{n}}_{>0} \cdot \underbrace{(s_x p - R s_y)^2}_{\geq 0} \geq 0 \end{aligned}$$

Закључак: За велико n , \bar{x}_{LR} је боља од \bar{x}_R , осим ако је $p s_x = R s_y$.

Може се доказати да то вали ако је веза линеарна и пролази кроз коорд. почетак, а већ смо рекли да тада користимо количничку.

Закључак: Линеарно-регресиона оцена је боља и од ПСУ оцене и од количничке оцене.

29.

Регресиона оцењивање на основу стратификованог узорка без понављања комбинована оцена

деф. Комбинована линеарно - регресиона оцена:

$$\bar{x}_{LRC} := \bar{x}_{STR} + b(\bar{y} - \bar{y}_{STR})$$

Теорема 1: Нека се бира стратификован узорак и бо познато. (претх. искуство)

1) Оцена \bar{x}_{LRC} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи:

$$D(\bar{x}_{LRC}) = \frac{1}{N^2} \sum_h^L \frac{1}{n_h} \cdot N_h^2 \left(1 - \frac{n_h}{N_h}\right) \left(\lambda_h^2(x) - 2b_0 p_h \lambda_h(x) \lambda_h(y) + b_0^2 \lambda_h^2(y) \right);$$

3) Непристрасна оцена те дисперзије је

$$\widehat{D}(\bar{x}_{LRC}) = \frac{1}{N^2} \sum_h^L \frac{1}{n_h} \cdot N_h^2 \left(1 - \frac{n_h}{N_h}\right) \left(\lambda_{n_h}^2(x) - 2b_0 \hat{p}_h \lambda_{n_h}(x) \lambda_{n_h}(y) + b_0^2 \lambda_{n_h}^2(y) \right).$$

Доказ: 1) $E(\bar{x}_{LRC}) = E(\bar{x}_{STR}) + b_0(E(\bar{y}) - E(\bar{y}_{STR})) \stackrel{STR}{=} \bar{x} + b_0(\bar{y} - \bar{y}) = \bar{x};$

$$2) D(\bar{x}_{LRC}) = D(\bar{x}_{STR} + b_0(\bar{y} - \bar{y}_{STR})) = D\left[\frac{1}{N} \sum_h^L N_h \bar{x}_{n_h} + b_0(\bar{y} - \frac{1}{N} \sum_h^L N_h \bar{y}_{n_h})\right]$$

$$= D\left[\frac{1}{N} \sum_h^L N_h \cdot (\bar{x}_{n_h} + b_0(\bar{y} - \bar{y}_{n_h}))\right] \stackrel{(*)}{=} D\left[\frac{1}{N} \sum_h^L N_h \cdot \bar{e}_{n_h}\right]$$

независност стратума
↓

$$= \frac{1}{N^2} \sum_h^L N_h^2 \cdot D[\bar{e}_{n_h}] =$$

$$\stackrel{PCG}{=} \boxed{\frac{1}{N^2} \sum_h^L N_h^2 \cdot \left(1 - \frac{n_h}{N_h}\right) \cdot \frac{1}{n_h} \cdot \lambda_h^2(e)}$$

$$= \frac{1}{N^2} \sum_h^L N_h^2 \cdot \left(1 - \frac{n_h}{N_h}\right) \cdot \frac{1}{n_h} \cdot \frac{1}{N_h-1} \sum_{i=1}^{n_h} (e_{hi} - \bar{e}_h)^2$$

$$= \frac{1}{N^2} \sum_h^L N_h^2 \cdot \left(1 - \frac{n_h}{N_h}\right) \cdot \frac{1}{n_h} \cdot \frac{1}{N_h-1} \sum_{i=1}^{n_h} (x_{hi} + b_0(\bar{y} - y_{hi}) - (\bar{x}_h + b_0(\bar{y} - \bar{y}_h)))^2$$

$$= \frac{1}{N^2} \sum_h^L N_h^2 \cdot \left(1 - \frac{n_h}{N_h}\right) \cdot \frac{1}{n_h} \cdot \frac{1}{N_h-1} \sum_{i=1}^{n_h} (x_{hi} - \bar{x}_h - b_0(y_{hi} - \bar{y}_h))^2$$

$$= \frac{1}{N^2} \sum_h^L N_h^2 \cdot \left(1 - \frac{n_h}{N_h}\right) \cdot \frac{1}{n_h} \cdot \boxed{\lambda_h^2(x) - 2b_0 p_h \lambda_h(x) \lambda_h(y) + b_0^2 \lambda_h^2(y)};$$

$$(x) e_{hi} = x_{hi} + b_0(\bar{y} - y_{hi})$$

$$\bar{e}_h = \bar{x}_h + b_0(\bar{y} - \bar{y}_h)$$

$$\bar{e}_{n_h} = \bar{x}_{n_h} + b_0(\bar{y} - \bar{y}_{n_h})$$

$$\begin{aligned}
3) \quad & \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} b_{n_h}^2(e) = \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} \cdot \frac{1}{n_h-1} \sum_{i \in S} (e_i - \bar{e}_{n_h})^2 \\
& = \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} \frac{1}{n_h-1} \sum_{i \in S} \left(x_{hi} + b_0(\bar{y} - y_{hi}) - (\bar{x}_{n_h} + b_0(\bar{y} - \bar{y}_{n_h})) \right)^2 \\
& = \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} \frac{1}{n_h-1} \sum_{i \in S} \left((x_{hi} - \bar{x}_{n_h}) - b_0(\bar{y} - \bar{y}_{n_h} - \bar{y} + y_{hi}) \right)^2 \\
& = \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} \frac{1}{n_h-1} \sum_{i \in S} \left[(x_{hi} - \bar{x}_{n_h})^2 - 2b_0(x_{hi} - \bar{x}_{n_h})(y_{hi} - \bar{y}_{n_h}) + b_0^2(y_{hi} - \bar{y}_{n_h})^2 \right] \\
& = \frac{1}{N^2} \sum_{n=1}^L N_n^2 \left(1 - \frac{n_h}{N_h}\right) \frac{1}{n_h} \left[\underbrace{\sum_{i \in S_h} (x_{hi} - \bar{x}_{n_h})}_{\hat{p}_h} \underbrace{\sum_{i \in S_h} (y_{hi} - \bar{y}_{n_h})}_{\hat{b}_0} \underbrace{b_{n_h}^2(y)}_{+ b_0^2 \sum_{i \in S_h} (y_{hi} - \bar{y}_{n_h})^2} \right] \\
& = \widehat{D}(X_{LR})
\end{aligned}$$

Напомена: Ако b_0 није познато, оцењујемо га са:

$$\hat{b}_0 := \frac{\sum_{n=1}^L \left[\frac{N_h^2 (1 - \frac{n_h}{N_h})}{n_h \cdot (n_h-1)} \cdot \sum_{i \in S_h} (x_{hi} - \bar{x}_{n_h})(y_{hi} - \bar{y}_{n_h}) \right]}{\sum_{n=1}^L \left[\frac{N_h^2 (1 - \frac{n_h}{N_h})}{n_h \cdot (n_h-1)} \cdot \sum_{i \in S_h} (y_{hi} - \bar{y}_{n_h})^2 \right]}$$

30.

Регресионо оцењивање на основу стратификованог узорка без понављања посебна по стратумима оцена

лед. Посебна линеарно - регресиона оцена:

$$\bar{X}_{LRS} := \frac{1}{N} \sum_h^L N_h \cdot \underbrace{\left(\bar{x}_{n_h} + b_h (\bar{y}_h - \bar{y}_{n_h}) \right)}_{= \bar{x}_{LR}(h)} \quad (\text{стратум} = \text{псу})$$

Теорема 1: Нека се бира стратификован узорак и b_h познати. (претх. искуство)

1) Оцена \bar{X}_{LRS} је непристрасна оцена за \bar{X} ;

2) За дисперзију те оцене важи:

$$D(\bar{X}_{LRS}) = \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{1}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\beta_{n_h}^2(x) + b_h^2 \beta_{n_h}^2(y) - 2 b_h p_h \beta_{n_h}(x) \beta_{n_h}(y) \right);$$

3) Непристрасна оцена те дисперзије је

$$\widehat{D}(\bar{X}_{LRS}) = \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{1}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\beta_{n_h}^2(x) + b_h \widehat{\beta}_{n_h}^2(y) - 2 b_h \widehat{p}_h \beta_{n_h}(x) \beta_{n_h}(y) \right).$$

Доказ: 1) $E(\bar{X}_{LRS}) = \frac{1}{N} \sum_h^L N_h \left[E(\bar{x}_{n_h}) + b_h (\bar{y}_h - E(\bar{y}_{n_h})) \right] \stackrel{\text{нез. страт.}}{=} \frac{1}{N} \sum_h^L N_h \left[\bar{x}_h + b_h (\bar{y}_h - \bar{y}_h) \right] = \frac{1}{N} \sum_h^L N_h \bar{x}_h = \bar{X};$

$$\begin{aligned} 2) D(\bar{X}_{LRS}) &= \boxed{\frac{1}{N^2} \sum_h^L N_h^2 D(\bar{x}_{LR}(h))} \\ &\stackrel{(26)}{=} \frac{1}{N^2} \sum_h^L N_h^2 \cdot \frac{1}{n_h} \left(1 - \frac{n_h}{N_h} \right) \left(\beta_{n_h}^2(x) + b_h^2 \beta_{n_h}^2(y) - 2 b_h p_h \beta_{n_h}(x) \beta_{n_h}(y) \right); \end{aligned}$$

$$\begin{aligned} 3) \widehat{D}(\bar{X}_{LRS}) &= \frac{1}{N^2} \sum_h^L N_h^2 \widehat{D}(\bar{x}_{LR}(h)) \\ &\stackrel{(**)}{=} \widehat{D}(\bar{X}_{LRS}) \end{aligned}$$

(**) исти трик као у 26

Напомена: Ако b_h -ови нису познати, оцењујемо их са: $\widehat{b}_h := \widehat{p}_h \cdot \frac{\beta_{n_h}(x)}{\beta_{n_h}(y)}$.

* Када користимо комбиновану оцену, а када посебну по стратумима?

1° b_h -ови слични: комбинована;

2° b_h -ови различити: посебна.

II

дeо

НАСТАВАК

Кластер узорак

Идеја је да узорак делимо на дисјунктне подскупове - **кластере**, тј. **примарне јединке**.

Јединке унутар кластера се зову **секундарне јединке**.

1	2	...	N
:			
:			
:			
:			
:			
:			
:			
:			

Од N кластера,
бирамо њих n.

Напомена: у пракси, бирамо сек. јединке
и онда узмемо цео кластер ком она припада.

Пакле, узоркује се тако што бирамо целе кластере,
тј. све секундарне јединке из кластера које смо изабрали.

N - број примарних јединки;

M_i - број секундарних јединки у i-том кластеру ($i = \overline{1, N}$)

M_n = $\sum M_i$ - укупан број секундарних јединки

Кластер узорак користимо када немамо добар узорачки оквир.
Такође, знатно је јефтинији. Ипак, оцене ће бити доста слабије.

Пример: број мобилних телефона у једној кући у Аустралији: кластер = град.

Често целу државу да обиђемо, бирамо само градове које обилазимо \Rightarrow јефтино.

Ипак, неки градови су сиромашнији од других \Rightarrow можда слабије оцене.

Кластери треба да буду што хетерогенији унутар себе, а што хомогенији између себе.
Пакле, супротно од стратума.

16.

Кластер узорак

прим. јед. - ПСУ без понављања

1	2	3	...	N
X_{11}	X_{21}	X_{31}	...	X_{N1}
X_{12}	X_{22}	:	...	X_{N2}
:	X_{23}	X_{3M_3}	...	:
X_{1M_1}	:		...	X_{NM_N}
	X_{2M_2}		...	
			...	
\uparrow	\uparrow	\uparrow	\uparrow	\uparrow
M_1	M_2	M_3		M_N

деф. $t_i := \sum_j^{M_i} X_{ij}$ - тотална сума i-тог кластера

То значи: $t = \sum_i^N t_i = \sum_i^N \sum_j^{M_i} X_{ij}$.

деф. $\hat{t} := \frac{N}{n} \cdot (\sum_{i \in S} t_i)$

Теорема 1: 1) Оцена \hat{t} је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\hat{t}) = N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_i^n (t_i - \frac{t}{N})^2$;

3) Непристрасна оцена те дисперзије је: $\hat{D}(\hat{t}) = N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{n-1} \sum_{i \in S} (t_i - \frac{1}{n} \sum_{i \in S} t_i)^2$.

Показ: Следи из теорије за ПСУ без понављања. (само $X_i \mapsto t_i$)

$$1) E\left(\frac{N}{n} \sum_{i \in S} t_i\right) = N \cdot E\left(\frac{1}{n} \sum_{i \in S} t_i\right) \stackrel{\text{ncy}}{=} N \cdot \frac{1}{N} \sum_i^n t_i = t;$$

$$2) D(\hat{t}) \stackrel{\text{ncy}}{=} N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \Delta^2 = N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{N-1} \sum_i^n (t_i - \frac{t}{N})^2;$$

$$3) \hat{D}(\hat{t}) \stackrel{\text{ncy}}{=} N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \Delta_n^2 = N^2 \cdot (1 - \frac{n}{N}) \frac{1}{n} \cdot \frac{1}{n-1} \sum_{i \in S} (t_i - \frac{\sum_{j \in S} t_j}{n})^2.$$

деф. $\hat{x} := \frac{1}{M_u} \cdot \hat{t}$

Теорема 2: 1) Оцена \hat{x} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи: $D(\hat{x}) = \frac{1}{M_u^2} \cdot D(\hat{t})$;

3) Непристрасна оцена те дисперзије је: $\hat{D}(\hat{x}) := \frac{1}{M_u^2} \cdot \hat{D}(\hat{t})$.

Показ: следи из Т1.

* Осим ове оцене, постоји и количничка оцена:

Како и до сада, први кластер посматрамо као прву јединку, други као другу итд.
Од N кластера, бирамо n .

Ако изаберемо i -ти кластер, као главно обележје (x) узимамо t_i .
Као помоћно обележје (y), узимамо M_i .

Ово можемо да урадимо: \rightarrow јесу у корелацији

$$\rightarrow y=0 \Rightarrow x=0$$

(ако кластер има нула елемената
нема шта да се сабере)

Количник популације је: $R = \frac{\sum t_i}{\sum M_i} = \frac{t}{M_u}$

Његова оцена је: $\hat{R} = \frac{\sum_{i \in s} t_i}{\sum_{i \in s} M_i}$

Количничке оцене су: 1) $\hat{t}_R = \hat{R} \cdot \sum_{i \in s} M_i = \hat{R} \cdot M_u$

$$2) \bar{x}_R = \frac{1}{M_u} \cdot \hat{t}_R = \hat{R}$$

→ јер су кол. оцене асимт. неприс.

Ове оцене су асимптотски непристрасне, па за велико n вали:

$$D(\hat{t}_R) \approx N^2 \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i=1}^N (t_i - RM_i)^2$$

Оцена ове дисперзије је:

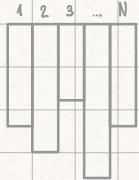
$$\hat{D}(\hat{t}_R) = N^2 \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i=1}^N (t_i - \hat{R}M_i)^2$$

17.

Кластер узорак

прим. јед. - пропорционално

деф. $P_i = \frac{M_i}{M_u}$ је вероватноћа избора i -тог кластера.



Видимо да су вероватноће избора пропорционалне величинама кластера.

Узорак може бити: са понављањем или без понављања.

I) са понављањем - НН оцена.

$$\text{деф. } \hat{t}_{\text{HH}} := \frac{M_u}{n} \cdot \sum_{i \in s} \frac{t_i}{M_i}.$$

Теорема 1: 1) Оцена \hat{t}_{HH} је непристрасна оцена за t ;

2) За дисперзију те оцене важи: $D(\hat{t}_{\text{HH}}) = \frac{M_u}{n} \cdot \sum_{i \in s} M_i \cdot \left(\frac{t_i}{M_i} - \bar{x} \right)^2$;

3) Непристрасна оцена те дисперзије је: $\hat{D}(\hat{t}_{\text{HH}}) := \frac{1}{n(n-1)} \sum_{i \in s} \left[\frac{M_u}{M_i} \cdot t_i - \hat{t}_{\text{HH}} \right]^2$.

Доказ: $P_i = \frac{M_i}{M_u}$ у изразима НН оцена.

$$\text{деф. } \bar{x}_{\text{HH}} := \frac{1}{M_u} \cdot \hat{t}_{\text{HH}}$$

Теорема 2: 1) Оцена \bar{x}_{HH} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи: $D(\bar{x}_{\text{HH}}) = \frac{1}{M_u^2} \cdot D(\hat{t}_{\text{HH}})$

3) Непристрасна оцена те дисперзије је: $\hat{D}(\bar{x}_{\text{HH}}) := \frac{1}{M_u^2} \cdot \hat{D}(\hat{t}_{\text{HH}})$

Доказ: следи из Т1.

II) без понављања - немамо адекватну теорију, па користимо НТ оцене (које чврк ване)

деф. $\hat{t}_{HT} := \sum_i \frac{t_i}{\pi_i}$.

Теорема 3: 1) Оцена \hat{t}_{HT} је непристрасна оцена за t ;

2) За дисперзију те оцене вани: $D(\hat{t}_{HT}) = \sum_i \frac{1-\pi_i}{\pi_i} \cdot t_i^2 + \sum_i \sum_{j \neq i} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} t_i t_j$;

3) Непристрасна оцена те дисперзије је: $\widehat{D}(\hat{t}_{HT}) = \sum_i \frac{1-\pi_i}{\pi_i^2} \cdot t_i^2 + \sum_i \sum_{j \neq i} \frac{\pi_{ij} - \pi_i \pi_j}{\pi_i \pi_j} \cdot \frac{t_i t_j}{\pi_i \pi_j}$.

Показ: $p_i = \frac{m_i}{M_u}$ у изразима НТ оцена.

деф. $\bar{x}_{HT} := \frac{1}{M_u} \cdot \hat{t}_{HT}$

Теорема 4: 1) Оцена \bar{x}_{HT} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене вани: $D(\bar{x}_{HT}) = \frac{1}{M_u^2} \cdot D(\hat{t}_{HT})$;

3) Непристрасна оцена те дисперзије је: $\widehat{D}(\bar{x}_{HT}) = \frac{1}{M_u^2} \cdot \widehat{D}(\hat{t}_{HT})$.

Показ: следи из ТЗ.

Напомена: Нама требају π_i и π_{ij} , а знамо само $p_i = \frac{m_i}{M_u}$

За узорковање са понављањем, вани:

1) $\pi_i = 1 - (1-p_i)^n$; (травијално)

2) $\pi_{ij} = \pi_i + \pi_j - (1 - (1-p_i-p_j)^n)$ (формулa укуп. и искљ: $P(AB) = P(A) + P(B) - P(A \cup B)$)

18.

Упоређивање оцена

ПСУ без понављања и кластер узорак

Претпоставимо да су сви кластери исте величине $M = M_1 = \dots = M_N$.

То значи да је обим популације $N \cdot M$, а обим узорка $n \cdot M$.

Лев. Унутркластерни коef. корелације је коef. корел. између парова јединки у истом кластеру:

$$\rho_{uk} = \frac{\sum_i^N \sum_{j=k,j}^M (x_{ij} - \bar{x})(x_{ik} - \bar{x})}{(M-1)(N \cdot M - 1) s^2}.$$

Лема 1: 1) $\rho_{uk} > 0$: кластери су хомогени унутар сеbe;

2) $\rho_{uk} < 0$: кластери су хетерогени унутар сеbe.

Доказ: 1) $\rho_{uk} > 0 \Rightarrow (x_{ij} - \bar{x})(x_{ik} - \bar{x}) > 0 \Rightarrow$ истог су знака (++ или --) $\Rightarrow x_{ij}, x_{ik}$ су са исте стране \bar{x}

2) различит знак \Rightarrow са различитих страна \bar{x} .

Лема 2: $D(\hat{t}) = \frac{N^2(1 - \frac{n}{N})}{n} \cdot \frac{NM-1}{N-1} \cdot s^2 (1 + (M-1)\rho_{uk})$. (алтернативни облик)

$$\begin{aligned}
 \text{Доказ: } D(\hat{t}) &\stackrel{(T4.2)}{=} N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \sum_i^N (t_i - \frac{\hat{t}}{N})^2 = N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \sum_i^N \left(\sum_j^M x_{ij} - M \cdot \frac{\bar{x}}{N \cdot M} \right)^2 \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \sum_i^N \left(\sum_j^M x_{ij} - M \cdot \bar{x} \right)^2 = N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \sum_i^N \left(\sum_j^M (x_{ij} - \bar{x}) \right)^2 \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \sum_j^M \left[\sum_i^N (x_{ij} - \bar{x})^2 + \sum_i^N \sum_{k \neq j}^M (x_{ij} - \bar{x})(x_{ik} - \bar{x}) \right] \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \left[\sum_j^M \sum_i^N (x_{ij} - \bar{x})^2 + \sum_j^M \sum_{k \neq j}^M \sum_i^N (x_{ij} - \bar{x})(x_{ik} - \bar{x}) \right] \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \left[(NM-1) \cdot \frac{1}{NM-1} \cdot \sum_i^N \sum_j^M (x_{ij} - \bar{x})^2 + \sum_i^N \sum_j^M \sum_{k \neq j}^M (x_{ij} - \bar{x})(x_{ik} - \bar{x}) \right] \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{1}{N-1} \left[(NM-1) \cdot s^2 + (M-1)(NM-1) \rho_{uk} \right] \\
 &= N^2(1 - \frac{n}{N}) \frac{1}{n} \frac{NM-1}{N-1} \cdot s^2 [1 + (M-1)\rho_{uk}]
 \end{aligned}$$

Пакле, за велико N (самим тим и велико NM)

$$D(\hat{t}_k) \stackrel{n^2}{=} \frac{N^2(1-\frac{n}{N})}{n} \cdot \frac{NM}{N} \cdot S^2(1+(M-1)p_{uk}) = N^2(1-\frac{n}{N}) \frac{1}{n} MS^2(1+(M-1)p_{uk})$$

$$D(\hat{t}_{psu}) \stackrel{1}{=} N^2 M \cancel{(1-\frac{n}{NM})} \cdot \frac{1}{nM} \cdot S^2 = N^2(1-\frac{n}{N}) \frac{1}{n} MS^2$$

Закључак: $D(\hat{t}_{psu}) < D(\hat{t}_k) \Leftrightarrow p_{uk} > 0$. (тј. појм: ако су кластери хомогени унутар седе)
 лоше

19.

Систематски узорак

деф. Нека је N обим популације, n обим узорка и нека је $k = \frac{N}{n}$.

Од првих k бирајмо једну јединку (нпр. i -ту),
а онда бирајмо сваку k -ту јединку након ње ($i+k, i+2k, \dots$).

Овако добијен узорак зове се **систематски узорак**.

Пример: Ако $\frac{N}{n}$ није цео број, оцене ће бити благо пристрасне

На даље, претпостављамо да јесте цео број, тј. $N = n \cdot k$. Тада су оцене непристрасне.

Приметимо да ово подсећа на стратификован узорак.

Ипак, то није исто - овде имамо неслучајно бирање (остали зависе од првог).

Систематски узорак јесте кластер узорак (имамо k кластера и бирајмо један).
↑ први елем.

деф. **Средина систематског узорка** је $\bar{x}_{sis} : \left(\begin{array}{cccc} \bar{x}_1 & \bar{x}_2 & \dots & \bar{x}_k \\ \frac{1}{k} & \frac{1}{k} & \dots & \frac{1}{k} \end{array} \right)$.
(\bar{x}_i - сп. вр. i -тог могућег сис. узорка)

деф. $s_{sis}^2 := \frac{1}{k(n-1)} \sum_i^k \sum_j^n (x_{ij} - \bar{x}_i)^2$.
(x_{ij} је j -ти елемент i -тог узорка)

Теорема 1: 1) Оцена \bar{x}_{sis} је непристрасна оцена за \bar{x} ;

2) За дисперзију те оцене важи: $D(\bar{x}_{sis}) = \frac{N-1}{N} s^2 - \frac{k(n-1)}{N} s_{sis}^2$.

Показ: 1) $E(\bar{x}_{sis}) = \frac{1}{k} \cdot \sum_i^k \bar{x}_i = \frac{1}{k} \cdot \sum_i^k \frac{1}{n} \sum_j^n x_{ij} = \frac{1}{kn} \sum_i^k \sum_j^n x_{ij} = \frac{1}{n} \cdot t = \bar{x}$;

2) * $D(\bar{x}_{sis}) \stackrel{\text{деф.}}{=} E((\bar{x}_{sis} - \bar{x})^2) \stackrel{\text{деф.}}{=} \frac{1}{k} \cdot \sum_i^k (\bar{x}_i - \bar{x})^2$

* $(N-1)s^2 = \sum_i^k \sum_j^n (x_{ij} - \bar{x})^2 = \sum_i^k \sum_j^n (x_{ij} - \bar{x}_i + \bar{x}_i - \bar{x})^2$

= $\sum_i^k \sum_j^n (x_{ij} - \bar{x}_i)^2 + \sum_i^k \sum_j^n (\bar{x}_i - \bar{x})^2 + 2 \cdot \sum_i^k (\bar{x}_i - \bar{x}) \cdot \sum_j^n (x_{ij} - \bar{x}_i)$

= $\stackrel{(*)}{k(n-1)} s_{sis}^2 + n k \cdot D(\bar{x}_{sis}) + 0 = k(n-1) s_{sis}^2 + N \cdot D(\bar{x}_{sis})$

$\Rightarrow D(\bar{x}_{sis}) = \frac{N-1}{N} s^2 - \frac{k(n-1)}{N} s_{sis}^2$

(*) $\sum_i^k (\bar{x}_i - \bar{x}) = \sum_i^k \frac{\sum_j^n x_{ij}}{n} - k \cdot \bar{x} = \frac{1}{n} \sum_i^k \sum_j^n x_{ij} - \frac{N}{n} \cdot \bar{x} = \frac{t}{n} - \frac{t}{n} = 0$

Последица: \bar{x}_{sis} је боља оцена од \bar{x}_n ако $s^2 < s_{sis}^2$.

Програм речима, \bar{x}_{sis} је боља ако је дисперзија унутар систематских узорака већа, што значи да су систематски узорци (њих k) хетерогенији унутар седе.

- што су хомогенији \Rightarrow дају мању информацију о популацији;
- што су хетерогенији \Rightarrow дају бољу информацију.

$$\begin{aligned}\text{Доказ: } D(\bar{x}_{sis}) &< D(\bar{x}_n) \Leftrightarrow \frac{\frac{N-1}{N} s^2 - \frac{k(n-1)}{N} s_{sis}^2}{\frac{N-1}{N} - \frac{N-n}{Nn}} < (1 - \frac{n}{N}) \frac{1}{n} s^2 \\ &\Leftrightarrow \left(\frac{N-1}{N} - \frac{N-n}{Nn} \right) s^2 < \frac{k(n-1)}{N} s_{sis}^2 \\ &\Leftrightarrow \left(1 - \frac{1}{N} - \frac{1}{n} + \frac{1}{N} \right) s^2 < \frac{k(n-1)}{N} s_{sis}^2 \\ &\Leftrightarrow \frac{\frac{N-1}{N} s^2}{k = N-n} < \frac{k(n-1)}{N} s_{sis}^2 \\ &\Leftrightarrow s^2 < s_{sis}^2\end{aligned}$$

* Сада повезујемо ову причу са причом о кластерима.

Теорема 2: $D(\bar{x}_{sis}) = \frac{s^2}{n} \cdot \frac{N-1}{N} \cdot (1 + (n-1) p_{uk})$. (алтернативни облик)

Доказ: Као што смо рекли: систематски = кластер узорак где он k кластера димензија 1.

$$\Rightarrow \hat{t}_k = \frac{1}{k} \sum_{i=1}^k t_i \quad , \quad \bar{x}_{sis} = \frac{\sum_{i=1}^k t_i}{n} = \frac{\hat{t}_k}{nk} = \frac{\hat{t}_k}{N}.$$

$$\begin{aligned}D(\bar{x}_{sis}) &= D\left(\frac{\hat{t}_k}{N}\right) = \frac{1}{N^2} D(\hat{t}_k) \stackrel{(16.12)}{=} \frac{k^2}{N^2} \left(1 - \frac{1}{k}\right) \cdot \frac{1}{1} \cdot \frac{kn-1}{k-1} s^2 (1 + (n-1) p_{uk}) \\ &= \frac{1}{N^2} \cdot \frac{k^2(k-1)}{k} \cdot \frac{kn-1}{k-1} s^2 (1 + (n-1) p_{uk}) = \frac{1}{n^2 k^2} \cdot k \cdot (N-1) s^2 (1 + (n-1) p_{uk}) \\ &= \frac{s^2}{n} \cdot \frac{N-1}{N} \cdot (1 + (n-1) p_{uk}).\end{aligned}$$

(*)	$N \rightarrow k$
M	$\rightarrow n$
n	$\rightarrow 1$

Напомена: $D(\bar{x}_{sis})$ мање ако је p_{uk} мање \Rightarrow кластери што хетерогенији

* Што нисмо трајнили $\widehat{D}(\bar{x}_{sis})$?

Систематско = кластер за $n=1$.

У кластер оцени $\widehat{D}(\bar{x})$ $\stackrel{(16.12)}{=}$ се појављује члан $\frac{1}{n-1}$ \Rightarrow дрљење нулом \Downarrow

20.

Квалитет оцене добијене на основу систематског узорка

Први случај

Имамо узорачки списак који је одређен случајно.

(нпр. меримо плату људи, а они су поређани од 1-9999 по последње 4 цифре броја телефона).

Тада ће систематски узорак вероватно дати исти квалитет оцене као и ПСУ.

Други случај

Ако је списак направљен и види се да постоји неки линеарни тренд: $x_i = a + b \cdot i$

$$\left. \begin{array}{l} D(\bar{x}_n) = \dots = \frac{(k-1)(N+1)}{12} \cdot b^2; \quad (*) \\ D(\bar{x}_{\text{SIS}}) = \dots = \frac{(k-1)(k+1)}{12} \cdot b^2; \quad (***) \\ D(\bar{x}_{\text{STR}}) = \dots = \frac{(k-1)(k+1)}{12n} \cdot b^2. \quad (***) \end{array} \right\} \Rightarrow D(\bar{x}_{\text{STR}}) \leq D(\bar{x}_{\text{SIS}}) \leq D(\bar{x}_n)$$

↓ због н
 у имениницу

↑ $k \in N$

Пакле, најбољу оцену даје стратификовани узорак.

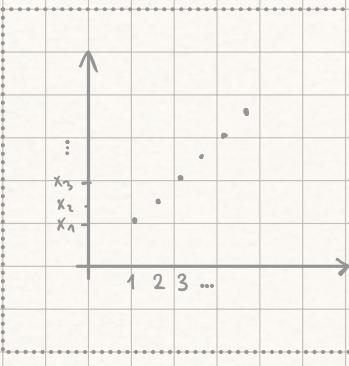
Трећи случај

Имамо списак јединки и очавамо да се вредности обележја периодично понављају.

Има ли смисла користити систематски узорак? Зависи од k .

Нпр. 3 1 2 3 1 2 ... и $k=3$: 2 2 2 ... \rightarrow нема смисла;
 $k=4$: 2 3 1 2 3 1 \rightarrow дукв. идеалан узорак.

Пакле, квалитет оцене зависи од k .



$$x_i = a + b \cdot i, \quad \forall i \Rightarrow \bar{x} = a + b \cdot \frac{n+1}{2}$$

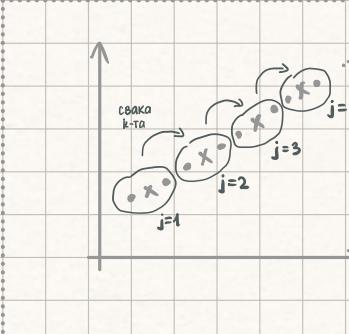
$N = n \cdot k$ - укупан број јединки

n - обим узорка

k - корак код систематског узорка

$$\begin{aligned}
 (*) D(\bar{x}_n) &= \left(1 - \frac{n}{N}\right) \frac{b^2}{n} = \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 = \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} b^2 \sum_{i=1}^N \left(i - \frac{n+1}{2}\right)^2 \\
 &= \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} b^2 \left[\sum_{i=1}^N i^2 - 2 \frac{n+1}{2} \sum_{i=1}^N i + N \cdot \frac{(N+1)^2}{4} \right] \\
 &= \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} b^2 \left[\frac{n(n+1)(2N+1)}{6} - \frac{N(N+1)^2}{2} + \frac{N(N+1)^2}{4} \right] \\
 &= \left(1 - \frac{n}{N}\right) \frac{1}{n} \cdot \frac{1}{N-1} b^2 \cdot \frac{n(n+1)}{42} [2(2N+1) - 6(N+1) + 3(N+1)] = \frac{N-n}{N} \cdot \frac{1}{n} \cdot \frac{1}{N-1} b^2 \cdot \frac{n(n+1)}{42} \cdot (N-1) \\
 &= (nk-n) \frac{1}{n} b^2 \frac{N+1}{12} = \frac{(k-1)(N+1)}{12} b^2
 \end{aligned}$$

(**)



$$j=1: x_{i+0 \cdot k}$$

$$j=2: x_{i+1 \cdot k}$$

$$j=3: x_{i+2 \cdot k}$$

⋮

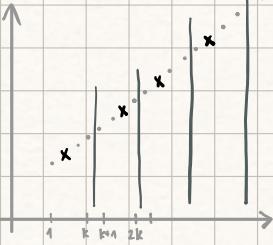
$$x_{i+(j-1) \cdot k}$$

Подсетимо се из 19:

$$\bar{x}_{SIS}: \left(\frac{\bar{x}_1}{1/k}, \dots, \frac{\bar{x}_k}{1/k} \right)$$

$$\begin{aligned}
 D(\bar{x}_{SIS}) &= E(\bar{x}_{SIS} - \bar{x})^2 = \frac{1}{k} \sum_i^k (\bar{x}_i - \bar{x})^2 = \frac{1}{k} \sum_i^k \left[\frac{1}{n} \sum_j^n x_{i+(j-1) \cdot k} - (a + b \cdot \frac{n+1}{2}) \right]^2 \\
 &= \frac{1}{k} \sum_i^k \left[a + \frac{bni}{n} + \frac{bk \sum_{j=1}^{k-1} j}{n} - \bar{x} - b \cdot \frac{n+1}{2} \right]^2 \\
 &= \frac{1}{k} b^2 \sum_i^k \left[i + \frac{k}{2} \cdot \frac{n(n-1)}{2} - \frac{n+1}{2} \right]^2 = \frac{1}{k} b^2 \sum_i^k \left[i + \frac{n-k-N-1}{2} \right]^2 = \frac{1}{k} b^2 \sum_i^k \left(i - \frac{k+1}{2} \right)^2 \\
 &= \frac{1}{k} b^2 \left[\sum_{i=1}^k i^2 - 2 \cdot \frac{k+1}{2} \sum_{i=1}^k i + k \cdot \frac{(k+1)^2}{4} \right] = \frac{1}{k} b^2 \left[\frac{k(k+1)(2k+1)}{6} - \frac{k(k+1)^2}{2} + \frac{k(k+1)^2}{4} \right] \\
 &= \frac{1}{k} b^2 k(k+1) \cdot \frac{k-1}{12} = \frac{(k-1)(k+1)}{12} b^2
 \end{aligned}$$

(***)



Како правимо страт. узорак?

Имамо N стратума величине k
и из сваког од њих бирајмо узорак обима 1

$$\Rightarrow N_h \rightarrow k, L \rightarrow n, n_h \rightarrow 1$$

Ако бирајмо из h -тог стратума, $(h-1) \cdot k$ елемената је прошло и ако узимамо j -ти

$$\Rightarrow X_{(h-1) \cdot k + j}$$

Знамо $D(\bar{x}_{STR}) = \frac{1}{N^2} \sum_h^L N_h^2 \frac{\delta_h^2}{n_h} \left(1 - \frac{n_h}{N_h}\right)$ \Rightarrow морамо још да одредимо $\delta_h^2 \rightarrow ?$
(све остало познато)

$$\begin{aligned}
 * \delta_h^2 &= \frac{1}{k-1} \sum_j^k \left[X_{(h-1)k+j} - \frac{1}{k} \sum_l^k X_{(h-1)k+l} \right]^2 \\
 &= \frac{1}{k-1} \sum_j^k \left[a + b((h-1)k+j) - \frac{1}{k} \sum_l^k (a + b((h-1)k+l)) \right]^2 \\
 &= \frac{1}{k-1} \sum_j^k \left[a + b(h-1)k + bj - \frac{1}{k} \cdot ka - \frac{1}{k} \cdot kb(h-1)k + \frac{1}{k} b \sum_l^k l \right]^2 = \frac{1}{k-1} b^2 \sum_j^k \left(j - \frac{k+1}{2} \right)^2 \\
 &= \frac{1}{k-1} b^2 \left[\sum_j^k j^2 - 2 \frac{k+1}{2} \sum_j^k j + k \frac{(k+1)^2}{2} \right] \\
 &= \frac{b^2}{12} k(k+1)
 \end{aligned}$$

$$\begin{aligned}
 * D(\bar{x}_{STR}) &= \frac{1}{N^2} \sum_h^L N_h^2 \frac{\delta_h^2}{n_h} \left(1 - \frac{n_h}{N_h}\right) = \frac{1}{N^2} \sum_h^L k^2 \cdot \frac{k(k+1)}{12} b^2 \left(1 - \frac{1}{k}\right) \\
 &= \frac{1}{n^2 k^2} \cdot n \cdot k^2 \cdot \frac{k(k+1)}{12} \cdot b^2 \cdot \frac{k-1}{k} \\
 &= \frac{(k^2-1)}{12n} \cdot b^2
 \end{aligned}$$