

Gludinošais butstraps

Juris Cielēns

Latvijas Universitāte

2011

Aplūkotie modeļi

Pienēmumi

Pienemsim, ka dota izlase X_1, X_2, \dots, X_n ar sadalījuma funkciju $F_1(x)$ un izlase Y_1, Y_2, \dots, Y_m ar sadalījuma funkciju $F_2(y)$, izlašu apjomi ir attiecīgi n un m .

Definīcija. Par divu izlašu varbūtību - varbūtību grafiku sauc funkciju

$$PP(t) := F_1(F_2^{-1}(t)),$$

kur $t \in [0, 1]$ un $F_2^{-1}(t)$ ir otrās izlases kvantiļu funkcija.

Aplūkotie modeļi

Lokācijas-skalēšanas modelis

Definīcija. Starp divām izlasēm pastāv lokācijas-skalēšanas modelis, ja

$$F_1(x) = F_2\left(\frac{x - \mu}{\sigma}\right), \text{ jeb } F_1^{-1}(t) = \mu + \sigma F_2^{-1}(t).$$

Biežāk sastopamie sadalījumi, kas pieder lokācijas-skalēšanas modeļu klasei:

- Normālais sadalījums: $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
- Vienmērīgais sadalījums: $f(x; a; b) = \frac{1}{b-a}$, ja $a \leq x \leq b$ un 0 - citur
- Košī sadalījums: $f(x; x_0; \gamma) = \frac{1}{\pi} \frac{\gamma}{(x-x_0)^2+\gamma^2}$

Aplūkotie modeļi

Lēmaņa alternatīvu modelis

Definīcija. Starp divām izlasēm pastāv Lēmaņa alternatīvu modelis, ja

$$F_1(x) = 1 - (1 - F_2(x))^{(1/h)}.$$

Sekas. Ja funkcijas F_1 un F_2 pieder Lēmaņa alternatīvu klasei, tad ir spēkā

$$\frac{f_2}{1 - F_2(x)} = h \frac{f_1}{1 - F_1(x)},$$

ko sauc par arī par proporcionālā riska modeli.

Biežāk pieminētais sadalījums ir Veibulla sadalījums:

$$f(x; \lambda; k) = \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-(x/\lambda)^k}, \text{ kad } x \geq 0.$$

Empīriskie procesi

Par empīrisko procesu sauc funkciju

$$EP(t) := \sqrt{n}(PP_n(t) - PP(t)).$$

- Lokācijas-skalēšanas modelim $PP(t) = F_1(\sigma F_2^{-1}(t) + \mu)$
- Lēmaņa alternatīvu modelim $PP(t) = F_1(F_2^{-1}(1 - (1-t)^h))$
- Īpašgadījums: $PP(t) = F_1(F_2^{-1}(t))$

$PP_n(t)$ - atbilstošās funkcijas empīriskā versija ar novērtētiem parametriem.

Ticamības joslas

Kritisko vērtību noteikšanas metodes

- Kritiskās vērtības aprēķināšana izmantojot teorētisko statistikas sadalījumu - šo metodi pielieto, ja asimptotiskais sadalījums ir vienkāršs, piemēram t-sadalījums vai χ^2 sadalījums;
- Kritiskās vērtības iegūšana ar simulāciju palīdzību - pielieto, ja statistikas sadalījums nav atkarīgs no izlases (datiem), tomēr tā aprēķināšana ir samērā sarežģīta
(statistikas $\sup_{-\infty < x < \infty} |F_n(x) - F(x)|$ sadalījums ir $\sup_{0 < t < 1} |B(t)|$, kur $B(t)$ -Brauna tilts);
- Kritiskās vērtības iegūšana ar butstrapa palīdzību - pielieto, ja statistikas sadalījums ir sarežģīts un atkarīgs no datiem

Simulācijas, butstraps un gludinošais butstraps

Simulācijas

- ① No zināma sadalījuma ģenerē gadījuma lielumu izlasi;
- ② Aprēķina testa statistiku un to saglabā;
- ③ Atkārto 1. un 2. soli 10 000 reizes, tādējādi iegūstot statistikas sadalījumu.

Butstraps

- ① Izmantojot dotos datus, ģenerē gadījuma izlasi ar atkārtošanos;
- ② Aprēķina testa statistiku un to saglabā;
- ③ Atkārto 1. un 2. soli 10 000 reizes, tādējādi iegūstot statistikas sadalījumu.

Simulācijas, butstraps un gludinošais butstraps

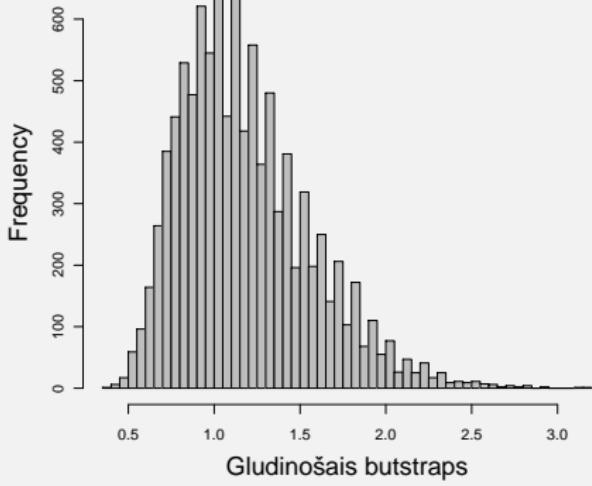
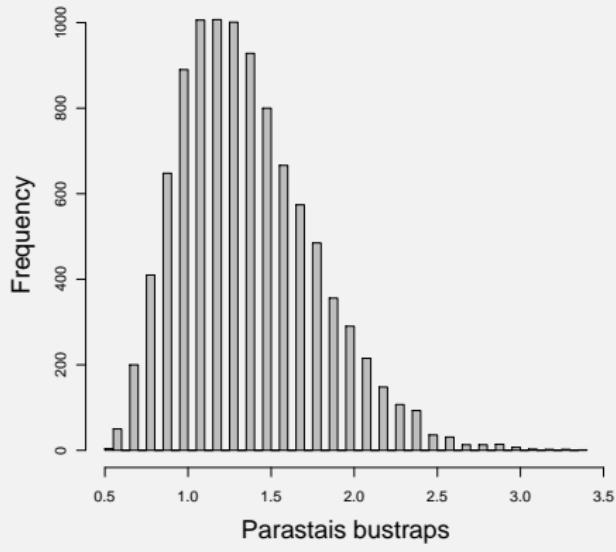
Blīvuma funkcijas un sadalījuma funkcijas kodolu novērtējums

- $\hat{f}_n(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-X_i}{h}\right)$
- $\hat{F}_n(x) = \int_{-\infty}^x \hat{f}_n(y) dy$

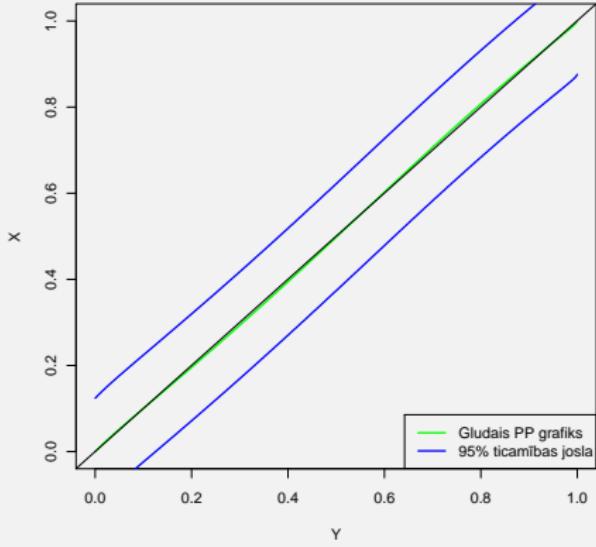
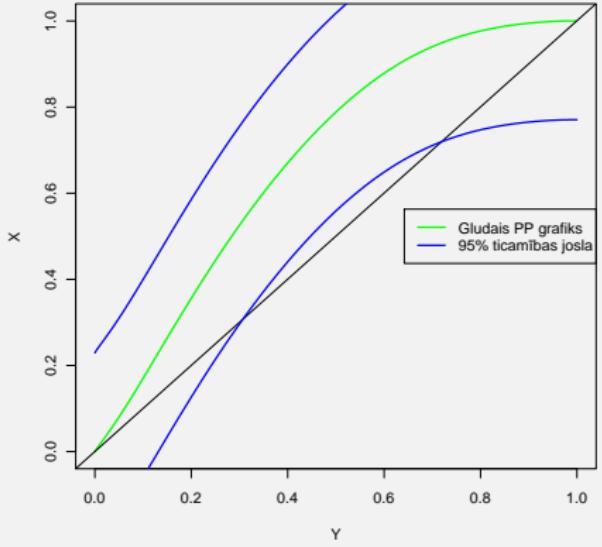
Gludinošā butstrapa algoritms

- ① Izmantojot dotos datus, novērtē sadalījuma funkciju $\hat{F}_n(x)$;
- ② Generē intervālā $[0,1]$ vienmērīgi sadalītu gadījuma lielumu izlasi;
- ③ Ar inversās transformācijas palīdzību iegūst gadījuma izlasi no sadalījuma $\hat{F}_n(x)$;
- ④ Aprēķina interesējošo statistikas vērtību;
- ⑤ Atkārto 2.-4. soli 10 000 reizes, lai iegūtu statistikas sadalījumu un noteiktu kritisko vērtību.

Butstrapa un gludinošā butstrapa salīdzinājums

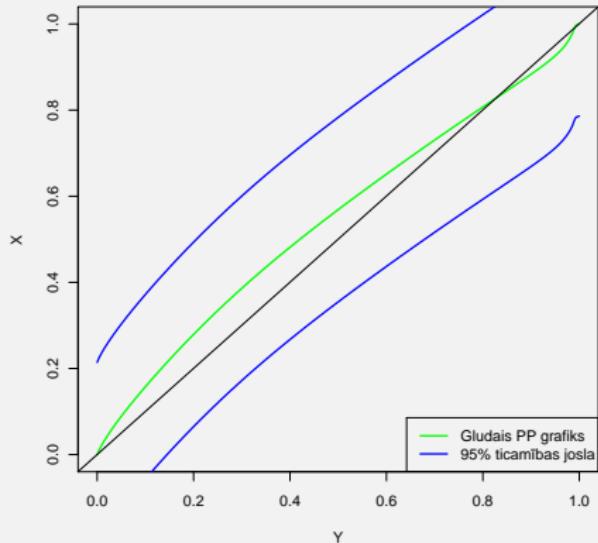
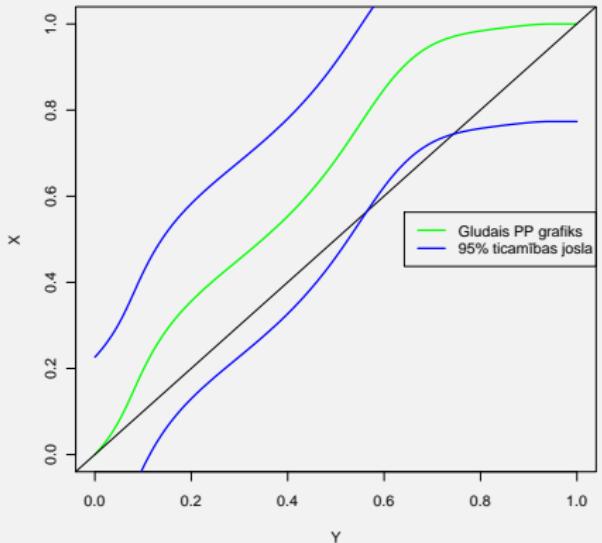


Gludās 95% ticamības joslas Lokācijas skalēšanas modelim



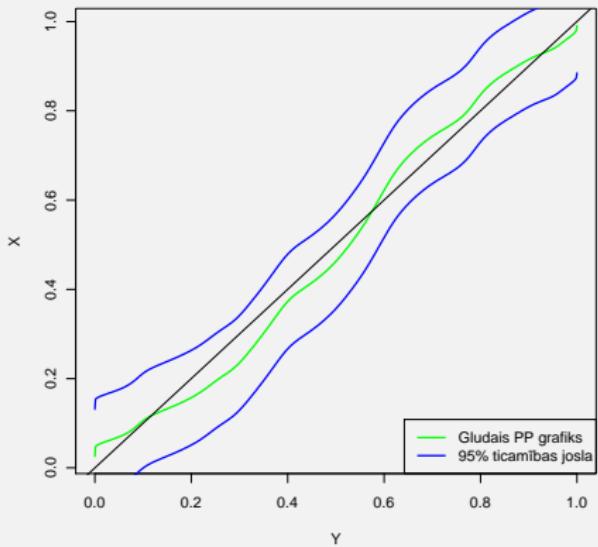
att.: $N(0,1)$ pret $N(1,1.5)$

Gludās 95% ticamības joslas Lēmaņa alternatīvu modelim

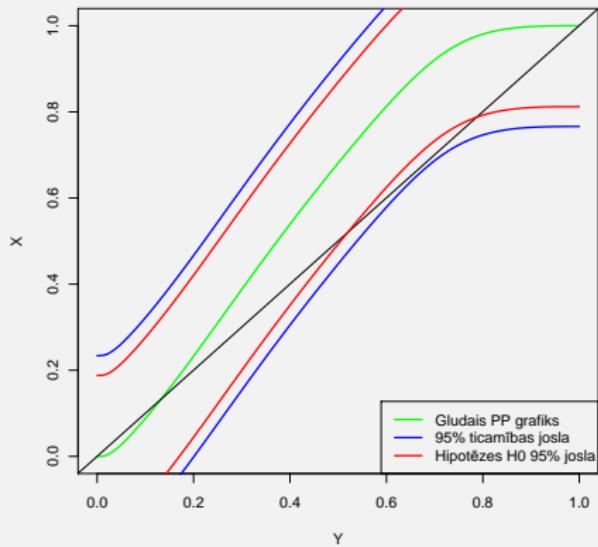


att.: $\text{Weib}(2,6)$ pret $\text{Weib}(2,8)$

Gludās 95% ticamības joslas



att.: $N(0,1)$ pret $U(0,1)$ un $N(0,1)$ pret $N(0.55,1.7)$



Izmantotā literatūra

- ① J. Valeinis. Confidence bands for structural relationship models. Dissertation, Goettingen, 2007.
- ② Z. Horwath, L. Horwath and W. Zhou. Confidence bands for roc curves. Journal of Statistical Planning and Inference, 138:1894-1904, 2008.
- ③ G.R. Shorak and J.A. Wellner. Empirical Processes with Applications to Statistics. John Wiley Sons, New York, 1986.