

Procjena repa i mjere rizika


Bojan Basrak, PMF–MO Zagreb

Financijski praktikum

6. travnja 2016.

Teški repovi

Regularna varijacija



Rep razdiobe F zovemo **regularno varirajućim** ako vrijedi

$$\overline{F}(x) = P(X > x) = \frac{L(x)}{x^\alpha}, \quad x > 0,$$

gdje je $\alpha > 0$ tzv. repni indeks a L je sporo promjenjiva funkcija, odn. za nju vrijedi

$$\lim_{x \rightarrow \infty} \frac{L(cx)}{L(x)} = 1, \quad \text{za sve } c > 0.$$

To su razdiobe vrlo teškog repa popularne u aktuarstvu i financijama, a vrlo važne i u teoriji vjerojatnosti. Poznato je za ovakvu sl. varijablu X ako je npr. nenegativna

$$EX^\delta = \begin{cases} +\infty & \delta > \alpha, \\ < \infty & \delta < \alpha. \end{cases}$$

Primjer

i) Pareto razdioba

$$\overline{F}(x) = \left(\frac{\kappa}{\kappa + x} \right)^\alpha,$$

za $x > 0$ i neke parametre $\alpha, \kappa > 0$. Jednoparameterska Pareto razdioba je $\overline{F}(x) = x^{-\alpha}$, $x > 1$ (to je zapravo log eksponencijalna razdioba).

ii) Fréchetova razdioba

$$\Phi(x) = e^{-x^{-\alpha}},$$

za $x > 0$.

Uvedimo


$$M_n = \max\{X_1, \dots, X_n\},$$

ako su X_i njd i reg. var. tada za $a_n = F^{\leftarrow}(1 - n^{-1})$ vrijedi


$$\frac{M_n}{a_n} \xrightarrow{d} \Phi_\alpha.$$

```
library(evir)
data(danish)
help(danish)


meplot(danish,main="Danish",pch=19,col=4)
```




```
library(car)  
qqPlot(log(danish[danish>2]), dist="exp")
```



```
U <- runif(2000)
pardata <- 1/(1-U) # ~  $F(x) = 1-x^{-1}$ ,  $x > 1$ 
meplot(pardata,main="Pareto data",pch=19,col=4)
```




```
qqPlot(log(pardata), dist="exp")
```



Reg. var. razdiobe mogu imati neobičan limes parcijalnih suma $S_n = X_1 + \dots + X_n$, posebno c.g.t. ne vrijedi ako je $\alpha < 2$.

Asimptotsko repno ponašanje ukupne sume (npr. gubitaka ili šteta) određuje najveća, tj. za $x \rightarrow \infty$

$$P(S_n > x) = n\bar{F}(x)(1 + o(1)).$$

Primjer (nastavak)

iii) Burrova razdioba

$$\bar{F}(x) = \left(\frac{\kappa}{\kappa + x^\tau} \right)^\alpha,$$

za $x > 0$ i neke parametre $\alpha, \kappa, \tau > 0$.

iv) log-gamma, $X = e^Y$, $Y \sim \Gamma(\alpha, \beta)$

Subeksponencijalne razdiobe

Subeksponencijalne razdiobe su razdiobe koje za njd niz (X_i) zadovoljavaju

$$P(S_n > x) = P(M_n > x)(1 + o(1)),$$

za $x \rightarrow \infty$ i sve $n \geq 2$ (dovoljno je zapravo i samo $n = 2$).

Uočite

$$P(M_n > x) = n\overline{F}(x)(1 + o(1)),$$

što dokazuje da su sve reg.var. razdiobe subeksponencijalne.

Za subeksponencijalne razdiobe vrijedi i

$$\lim_{x \rightarrow \infty} \frac{\overline{F}(x+y)}{\overline{F}(x)} = 1$$

za sve y .

Za sve $\varepsilon > 0$ i $x \rightarrow \infty$ vrijedi

$$e^{\varepsilon x} \overline{F}(x) \rightarrow \infty.$$

Tako da je za nenegativnu subeksponencijalnu X funkcija izvodnica momenta

$$m_X(t) = Ee^{tX} = \infty, \quad \text{za sve } t > 0.$$

Primjer

Weibullova razdioba

$$\overline{F}(x) = e^{-cx^\tau},$$

za $x > 0$ i neke parametre $c, \tau > 0$ je subeksponencijalna za $\tau \in (0, 1)$ iako nije reg. varirajuća.

Procjena repa i kvantila

Neparametarska procjena

Pretpostavimo da želimo odrediti rep razdiobe

$$P(X > x) \quad \text{za "velike" } x \text{ ili kvantile}$$

$$F^{\leftarrow}(1 - p) \quad \text{za "male" } p.$$

I rep i kvantile možemo bez dodatnih pretpostavki procijeniti iz empirijske funkcije distribucije (no to je vrlo problematično na rubu empirijske razdiobe).

Intervale pouzdanosti možemo napraviti koristeći asimptotsku normalnost, ili što je realnije u praksi bootstrap metode.

```
quantile(danish,0.99)
```

```
##      99%  
## 26.04253
```

```
bootThetaQuantile <- function(x,i) {  
  quantile(x[i], probs=.99) ### moze i drugi kvantil  
}  
library(boot)
```

```
##  
## Attaching package: 'boot'
```

```
## The following object is masked from 'package:car':  
##  
##      logit
```

```
nboot <- 4000  
theta.boot.VaR <- boot(danish, bootThetaQuantile, R=nboot)
```



```
boot.ci(theta.boot.VaR, conf=0.95,type=c("norm","basic","perc"),"
```

```
## BOOTSTRAP CONFIDENCE INTERVAL CALCULATIONS
```

```
## Based on 4000 bootstrap replicates
```

```
##
```

```
## CALL :
```

```
## boot.ci(boot.out = theta.boot.VaR, conf = 0.95, type = c("nor
```

```
##      "basic", "perc", "bca"))
```

```
##
```

```
## Intervals :
```

```
## Level      Normal      Basic
```

```
## 95%   (21.12, 31.14 )   (20.58, 31.22 )
```

```
##
```

```
## Level      Percentile      BCa
```

```
## 95%   (20.86, 31.51 )   (20.90, 31.51 )
```

```
## Calculations and Intervals on Original Scale
```

```
quantile(pardata,0.99)
```

```
##      99%  
## 114.3508
```

```
bootThetaQuantile <- function(x,i) {  
  quantile(x[i], probs=.99)  ### moze i drugi kvantil  
}  
library(boot)  
nboot <- 4000  
theta.boot.VaR <- boot(pardata, bootThetaQuantile, R=nboot)
```

```
boot.ci(theta.boot.VaR, conf=0.95,type=c("norm","basic","perc"),"
```

```
## BOOTSTRAP CONFIDENCE INTERVAL CALCULATIONS
```

```
## Based on 4000 bootstrap replicates
```

```
##
```

```
## CALL :
```

```
## boot.ci(boot.out = theta.boot.VaR, conf = 0.95, type = c("nor
```

```
##      "basic", "perc", "bca"))
```

```
##
```

```
## Intervals :
```

```
## Level      Normal      Basic
```

```
## 95%    ( 69.0, 174.4 )    ( 60.9, 161.0 )
```

```
##
```

```
## Level      Percentile      BCa
```

```
## 95%    ( 67.7, 167.8 )    ( 67.7, 167.8 )
```

```
## Calculations and Intervals on Original Scale
```

Parametarska procjena

Ako možemo opravdati pretpostavku (teorijski ili na osnovu grafa kvantila npr.) da podaci dolaze iz neke parametarske familije razdioba, možemo prvo procijeniti parametre nepoznate razdiobe i nakon toga odrediti kvantile odn. rep.

Intervale pouzdanosti možemo odrediti tzv. *parametarskom bootstrap* metodom: ako razdioba $F = F_\theta$ ovisi o nepoznatom parametru θ kojeg znamo procijeniti recimo sa $\hat{\theta}$, bootstrap uzorke za $i = 1, 2, 3, \dots, B$

$$X_{i,1}^*, \dots, X_{i,n}^*,$$

simuliramo iz razdiobe $F_{\hat{\theta}}$. A zatim postupimo kao i u običnom bootstrapu.

```
n <- length(pardata)
procjena <- mean(log(pardata))
procjena
```

```
## [1] 0.9795324
```

```
proc.kvant<-function(y) ### pretpostavka podaci su Pareto
{ lamhat<- mean(log(y))
  out<-qexp(0.99,lamhat)
  exp(out)}
x <- exp(rexp(n*1000, 1/procjena))
nboot<- 1000
bootstrap.uzorak = matrix(x, nrow=n, ncol=nboot)
vars.boot<-apply(bootstrap.uzorak, 1, proc.kvant)
proc.kvant(pardata)
```

```
## [1] 110.1008
```

```
quantile(vars.boot,c(0.025,0.975)) ### percentilni CI
```

```
##      2.5%      97.5%
## 84.18468 153.09568
```


Procjena repa za regularno varirajuće razdiobe

Pretpostavka o reg.varijaciji može se smatrati poluparametarskom jer uz razdiobu određuju parametar α i nepoznata funkcija L .


Prisjetmo se uređajnih statistika $X_{(1)} \leq \dots \leq X_{(n)}$. Koristeći k najvećih vrijednosti u uzorku možemo procijeniti repni indeks α tzv. **Hillovim procjeniteljem**

$$\hat{\alpha}_{n,k} = \left(\frac{1}{k} \sum_{j=1}^k \log \frac{X_{(n-j+1)}}{X_{(n-k+1)}} \right)^{-1}$$


```
hill(pardata,main="Pareto data")
```



```
hill(danish,main="Danish data")
```




```
hill(somedata,main="horror Hill F(x)=1-(x*log(x))^-1)")
```



Procjena repa je sad

$$(\overline{F}(x))^{\wedge} = \frac{k}{n} (X_{(n-k+1)})^{\hat{\alpha}} x^{-\hat{\alpha}}$$

A kvantile možemo procijeniti koristeći

$$(F^{\leftarrow}(1-p))^{\wedge} = \left(\frac{n}{k}p\right)^{-1/\hat{\alpha}} X_{(n-k+1)}$$

Odrediti optimalni k je iznimno teško čak i za njd podatke. Obično biramo takav k u čijoj se blizini procjenitelj $\hat{\alpha}_{n,k}$ ponaša "stabilno".


Uz dodatne tehničke uvjete, procjenitelj $\hat{\alpha}_{n,k}$ je asimptotski normalan, što omogućava npr. i izradu intervala pouzdanosti za repni indeks, repne vjerojatnosti i kvantile, no i njih u praksi treba koristiti oprezno.

Graph may look strange !!

##

Suggestion 1: Increase `p` above 0.99308

Suggestion 2: Increase `start` above 22



Graph may look strange !!

##

Suggestion 1: Increase `p` above 0.9925

Suggestion 2: Increase `start` above 21



Mjere rizika

Pretpostavimo da sl. varijabla Y modelira gubitak osiguravatelja ili gubitak investicijskog fonda u nekom periodu.

Razumno je pretpostaviti $EY < 0$. Pitanje je kako mjeriti rizik vezan uz Y . Postoji više mogućnosti:

Varijanca ili alternativno stand. devijacija - imaju niz nedostataka: ne mogu se definirati za neke razdiobe, simetrično tretiraju repove, ne detektiraju diversifikaciju na pravilan način,...

VaR (Value at Risk) - postoji uvijek, definira se jednostavno, za dani $\alpha \in (0, 1)$ definira se kao

$$\text{VaR}_\alpha(Y) = F_Y^{\leftarrow}(1 - \alpha)$$

To je najčešće korištena mjera rizika, što objašnjava važnost procjene kvantila u financijskoj praksi. No i ona ima nedostataka, npr. moguće je

$$\text{VaR}_\alpha(Y_1 + Y_2) > \text{VaR}_\alpha(Y_1) + \text{VaR}_\alpha(Y_2),$$

dakle diverzifikacijom dobijemo veći rizik nego podijelom portfelja – problem za regulatora i risk managera. Dakle VaR nije uvijek razumna mjera rizika.

Očekivani manjak (expected shortfall ili mean excess loss) je treća opcija koja nema problema s diverzifikacijom i predstavlja sve češće korišten izbor u praksi.

$$e_Y(u_\alpha) = E(Y - u_\alpha | Y > u_\alpha) \quad \text{gdje } u_\alpha = \text{VaR}_\alpha(Y).$$

Bez obzira na korištenu mjeru rizika, u praksi je nužno provjeriti i kvalitetu metoda za njihovu procjenu – u tu svrhu obično koristimo *backtesting* procedure. .

Vrlo složen model s puno parametara može čak i opisati podatke vrlo dobro, no takav rezultat nije uvijek moguće proširiti na nove/nekorištene podatke, naime veliki broj parametara izaziva problem koji se naziva *overfitting*, a teorijski se može objasniti uobičajenim rastavom statističke greške na pristranost i varijancu.

John von Neumann:

With four parameters I can fit an elephant, and with five I can make him wiggle his trunk.