

Пакет *sampling* у R-у

Токай Мелинда

`writesample(n,N)`

- Ова команда даје матрицу чије су врсте вектори (са елементима 0 или 1) свих узорака фиксног обима, узорак без понављања
- n обим узорка
- N обим популације

```

> M=writeSample(2,6)
> t(apply(M,1,function(x) (1:ncol(M))[x==1]))
 [,1] [,2]
[1,] 5 6
[2,] 4 6
[3,] 4 5
[4,] 3 6
[5,] 3 5
[6,] 3 4
[7,] 2 6
[8,] 2 5
[9,] 2 4
[10,] 2 3
[11,] 1 6
[12,] 1 5
[13,] 1 4
[14,] 1 3
[15,] 1 2
> |
> M
 [,1] [,2] [,3] [,4] [,5] [,6]
[1,] 0 0 0 0 1 1
[2,] 0 0 0 1 0 1
[3,] 0 0 0 1 1 0
[4,] 0 0 1 0 0 1
[5,] 0 0 1 0 1 0
[6,] 0 0 1 1 0 0
[7,] 0 1 0 0 0 1
[8,] 0 1 0 0 1 0
[9,] 0 1 0 1 0 0
[10,] 0 1 1 0 0 0
[11,] 1 0 0 0 0 1
[12,] 1 0 0 0 1 0
[13,] 1 0 0 1 0 0
[14,] 1 0 1 0 0 0
[15,] 1 1 0 0 0 0
> |

```

srswor(n,N)

- Ова комада даје SRSWOR узорак (узорак фиксне дужине, једнаких вероватноћа, без понављања).
- Враћа вектор дужине N са елементима 0 односно 1 у зависности да ли је k -та јединица популације изабрана у узорак (ако је на k -тој позицији 1 јединица је изабрана, односно није изабран ако је 0)

```
> u=srswor(3,8)
> u
[1] 0 0 1 1 0 0 0 1
> uzorak=(1:8)[u==1]
> uzorak
[1] 3 4 8
> |
```

```
>  
>  
> ##baza koja sadrzi podatke o populaciji u Belgiji  
> #podaci iz jula 2004. god  
> #podaci iz jula 2003. god  
> #vrsti se poredjenje medju njima  
> #sadrzi i neke podatke o finansijama gradova na kraju 2001.  
> data(belgianmunicipalities)  
>  
> total=belgianmunicipalities$Tot04  
> #Tot04 broj stanovnika po gradovima jula2004.  
>  
> #Commune imena gradova  
> ime=belgianmunicipalities$Commune  
>  
> n=200 #obim uzorka  
> uz=srswor(n, length(total)) #izaberemo uzorak  
>  
> #sa komandom as.vector(ime[uz==1])  
> #dobijamo vektor sa imenima gradova koji su u uzorku  
>  
  
> # za "laksi" prikaz uzećemo n=10  
> n=10  
> uz=srswor(n,length(total))  
> as.vector(ime[uz==1])  
[1] "Hove"          "Oud-Turnhout"  "Lennik"        "Rotselaar"      "Zwevegem"  
[6] "Moorslede"     "Wichelen"      "Heron"         "Gedinne"       "Fernelmont"
```

srswor1(n,N)

- Ради скоро исто што и претходна ϕ -ја али ова користи selection-rejection методу
 - Selection-rejection procedure for SRS/SRSWOR

Definition $k, j : \text{Integer}$;

$j = 0$

For $k = 1, 2, \dots, N$ do

са вероватноћом $\frac{n-j}{N-(k-1)}$ одабери јединицу k ; $j = j + 1$

```
>
> s=srswor1(3,10)
> #uzorak je
> (1:10)[s==1]
[1] 1 2 5
>
```

srswr(n,N)

- Ова комада даје SRSWR узорак (узорак фиксне дужине, једнаких вероватноћа, са понављањем). Враћа вектор дужине N , при чему елементи овог вектора представљају број понављања јединице k у узорку.

```
> s=srswr(6,15)
> #izabrane jedinice su
> (1:15)[s!=0]
[1]  5  8 10 13
> #sa brojem ponavljanja
> s[s!=0]
[1] 2 1 2 1
>
```

getdata(data, m)

”Извлачи” сам узорак из базе. Ова ф-ја се користи након што добијемо узорак тј. вектор који нам представља узорак.

```
> getdata(belgianmunicipalities, uz)
   ID_unit    Commune  INS Province Arrondiss Men04 Women04 Tot04 Men03 Women03 Tot03 diffmen
11      11        Hove 11021       1      11  3979   4170  8149  3987   4183  8170     -8
62      62  Oud-Turnhout 13031       1      13  6285  6245 12530  6227  6182 12409     58
123     123       Lennik 23104       2      23  4319  4413  8732  4328  4408  8736     -9
146     146     Rotselaar 24094       2      24  7423  7517 14940  7366  7430 14796     57
215     215     Zwevegem 34042       3      34 11648 11933 23581 11583 11822 23405     65
229     229     Moorslede 36012       3      36  5279  5356 10635  5278  5344 10622     1
264     264      Wichenen 42026       4      42  5405  5676 11081  5365  5659 11024     40
385     385       Heron 61028       6      61  2156  2229  4385  2122  2221  4343     34
557     557      Gedinne 91054       9      91  2108  2282  4390  2078  2252  4330     30
579     579   Fernelmont 92138       9      92  3269  3383  6652  3240  3355  6595     29
   Diffwom diffTOT TaxableIncome Totaltaxation averageincome medianincome
11      -13     -21  132669412  43230689    35549    23678
62       63     121  165508600  44215801    29093    21752
123      5      -4  128811484  39468852    31069    22594
146     87     144  208830522  61405448    29388    21202
215     111     176  286243776  74587242    25013    19515
229      12      13  110035596  26842210    22895    18912
264      17      57  137211259  37095577    25860    20825
385       8      42  47186894  12265221    24666    19846
557      30      60  39888308  8725768    21138    17510
579      28      57  73030853  20480526    27200    20986
>
```

UPmultinomial(pik)

- Користи *Hansen-Hurwitz*-ову методу за избор узорка (узорак фиксне дужине, неједнаких вероватноћа).
- Враћа вектор дужине N са елементима 0 односно 1 у зависности да ли је k -та јединица популације изабрана у узорак (ако је на k -тој позицији 1 јединица је изабрана, односно није изабран ако је 0)

```
>  
> x=c(0.2,0.7,0.8,0.5,0.4,0.4)  
> #uzimamo uzorak  
> uz=UPmultinomial(x)  
> #uzorak je  
> (1:length(x))[uz==1]  
[1] 3 5 6  
>
```

UPpoisson(pik)

- Извлачи Пуасонов узорак користећи вектор вероватноћа укључивања првог реда (узорак произвољне дужине, неједнаких вероватноћа, без понављања).
- Враћа вектор дужине N са елементима 0 односно 1 у зависности да ли је k -та јединица популације изабрана у узорак (ако је на k -тој позицији 1 јединица је изабрана, односно није изабран ако је 0)

```
>
> # definisemo vektor verovatnoca ukljucivanja
> x=c(1/3,1/3,1/3)
> # izaberemo uzorak
> s=UPpoisson(x)
> #uzorak je
> (1:length(x))[s==1]
[1] 2 3
> # izaberemo drugi uzorak
> s=UPpoisson(x)
> #uzorak je
> (1:length(x))[s==1]
integer(0)
> #dobili smo uzorak obima 0
```

```

>
> total=belgianmunicipalities$Tot04
> ime=belgianmunicipalities$Commune
> n=20
> x=inclusionprobabilities(total,n)
> # izaberemo uzorak
> s=UPpoisson(x)
> #uzorak je
> getdata(ime,s)

ID_unit           data
1      2           Anvers
2     16           Mortsel
3    42 sint-Katelijne-Waver
4     76           Evere
5     77           Forest
6     91           Beersel
7     93           Dilbeek
8     94   Gammerages
9    113          vilvorde
10   124          Affligem
11   143          Louvain
12   271          Zelzate
13   320   Charleroi
14   375          Rumes
15   376          Tournai
16   402  chaudfontaine
17   409           Liege
18   471 Herck-la-Ville
> |

```

- Пуасонов узорак – на сваку јединицу популације се примењује Бернулијев експеримент (независно) на основу чега ће се одредити да ли та јединица улази у узорак или не

`inclusionprobabilities(a,n)`

- Рачуна вероватноће укључивања прве врсте користећи вектор позитивних бројева (за план узорковања са вероватноћама пропорционалним величини)

```
>  
> # vector pozitivnih brojeva  
> a=1:20  
> # racunanje verovatnoca ukljucivanja  
> # za uzorak obima n=12  
> x=inclusionprobabilities(a,12)  
> x  
[1] 0.05882353 0.11764706 0.17647059 0.23529412  
0.29411765 0.35294118 0.41176471 0.47058824  
[9] 0.52941176 0.58823529 0.64705882 0.70588235  
0.76470588 0.82352941 0.88235294 0.94117647  
[17] 1.00000000 1.00000000 1.00000000 1.00000000  
[18] . . . .
```

`inclusionprobastrata(strata,nh)`

- Рачуна вероватноће укључивања за стратификовани план узорковања
- *strata* вектор који дефинише стратуме
- *nh* вектор са бројевима јединица колико желимо да узмемо у сваком од стратума

```
> # stratum
> strata=c(1,1,1,1,1,2,2,2,2,2,3,3,3,3,3,3)
> # obim uzorka u svakom od stratuma
> nh=c(2,3,3)
> inclusionprobastrata(strata,nh)
[1] 0.4000000 0.4000000 0.4000000 0.4000000 0.4000000 0.5000000 0.5000000
[8] 0.5000000 0.5000000 0.5000000 0.5000000 0.4285714 0.4285714 0.4285714
[15] 0.4285714 0.4285714 0.4285714 0.4285714
>
```

`strata(data, stratanames, size, method, pik, description=F)`

- Овом ф-јом извлачимо стратификован узорак
- *stratanames* је облежје у бази по којој се врши стратификација (има неколико категорија)
- *size* вектор који представља обим стратума који се извлачи из сваке од категорија
- *method* може бити: "srswor", "srswr", "poisson" или "systematic"
- *pik* вектор вероватноћа укључивања или помоћних информација, овај аргумент се користи код узорака неједнаких вероватноћа ("poisson" или "systematic")

Console ~/ ↗

```
> # Koristimo bazu 'iris' kao populaciju za uzimanje uzorka
> data(iris)
> # oblezje 'Species' ima 3 kategorija
> # ovo cemo koristiti za stratifikaciju
> # racuna stratuma populacije
> table(iris$Species)

  setosa versicolor virginica
      50          50         50

>
> # velicine stratuma uzorka su date sa size=c(6,4,3)
> # koristimo metodu SRSWOR (jednake verovatnoce, bez ponavljanja)
> st=strata(iris,stratanames=c("Species"),
+            size=c(6,4,3),
+            method="srswor")
> # izvlaci sam uzorak iz baze
> getdata(iris, st)
   Sepal.Length Sepal.Width Petal.Length Petal.Width    Species ID_unit Prob Stratum
11        5.4       3.7        1.5       0.2     setosa    11 0.12     1
19        5.7       3.8        1.7       0.3     setosa    19 0.12     1
23        4.6       3.6        1.0       0.2     setosa    23 0.12     1
26        5.0       3.0        1.6       0.2     setosa    26 0.12     1
33        5.2       4.1        1.5       0.1     setosa    33 0.12     1
42        4.5       2.3        1.3       0.3     setosa    42 0.12     1
53        6.9       3.1        4.9       1.5 versicolor  53 0.08     2
59        6.6       2.9        4.6       1.3 versicolor  59 0.08     2
71        5.9       3.2        4.8       1.8 versicolor  71 0.08     2
79        6.0       2.9        4.5       1.5 versicolor  79 0.08     2
130       7.2       3.0        5.8       1.6 virginica 130 0.06     3
133       6.4       2.8        5.6       2.2 virginica 133 0.06     3
142       6.9       3.1        5.1       2.3 virginica 142 0.06     3
>
> # prikazivanje rezultata pomocu tabele kontigencije
> table(st$Species)

  setosa versicolor virginica
      6          4         3

>
```

UPsystematic(*pik*,*eps*=1e-6)

- Узима узорак користећи систематски метод (као што је узорак са вероватноћом пропорционалном величини)
- Враћа вектор дужине N са елементима 0 односно 1 у зависности да ли је k -та јединица популације изабрана у узорак (ако је на k -тој позицији 1 јединица је изабрана, односно није изабран ако је 0)
- pik вектор вероватноћа укључивања
- eps контролна вредност, по дефолту 1e-6

```
>
> #definiseo verovatnoce ukljucivanja
> pik=c(0.2,0.7,0.8,0.5,0.4,0.4)
> #izaberemo uzorak
> s=UPsystematic(pik)
> #uzorak je
> (1:length(pik))[s==1]
[1] 2 3 6
>
```

UPsystematicpi2(pik)

- Рачуна заједничку вероватноћу укључивања (друге врсте) за систематски узорак
- Враћа матрицу $N \times N$ при чему се на главној дијагонали налазе вероватноће укључивања прве врсте, а на позицијама (k, l) су заједничке вероватноће укључивања
- pik вектор вероватноћа укључивања прве врсте

```
>
> #definisemo verovatnoce ukljucivanja
> pik=c(0.2,0.7,0.8,0.5,0.4,0.4)
> #matrica verovatnoca druge vrste
> UPSystematicpi2(pik)
     [,1] [,2] [,3] [,4] [,5] [,6]
[1,]  0.2  0.0  0.2  0.2  0.0  0.0
[2,]  0.0  0.7  0.5  0.2  0.4  0.3
[3,]  0.2  0.5  0.8  0.3  0.4  0.2
[4,]  0.2  0.2  0.3  0.5  0.0  0.3
[5,]  0.0  0.4  0.4  0.0  0.4  0.0
[6,]  0.0  0.3  0.2  0.3  0.0  0.4
>
```

$HTestimator(y, pik)$

- Рачуна Horvitz-Thompson-ову оцену за тотал популације
- y вектор обележја коју испитујемо њена дужина је једнака обиму узорка
- pik вектор вероватноћа укључивања прве врсте (дужина као обим узорка)

```
<
>
> data(belgianmunicipalities)
> attach(belgianmunicipalities)
> # racunamo verovatnoce ukljucivanja
> pik=inclusionprobabilities(Tot04,200)
>
>
> # definisemo velicinu koju ispitujemo
> y=TaxableIncome
> # uzimamo Puasonov uzorak
> s=UPpoisson(pik)
> # racunamo Horvitz-Thompson-ovu ocenu
> HTestimator(y[s==1],pik[s==1])
[1,]
[1,] 114635195908
>
>
> |
```

HTstrata(y,pik,strata,description=F)

- Рачуна Horvitz-Thompson-ову оцену за тотал популације при стратификованом плану узорковања
- y вектор обележја који испитујемо њена дужина је једнака обиму узорка n
- pik вектор вероватноћа укључивања прве врсте (дужине n)
- $strata$ вектор дужине n , са јединицама популације који се налазе у стартумима
- $description$ ако је $TRUE$ оцена се штампа за сваки стратум

```
>
> # Koristimo bazu 'iris' kao populaciju za uzimanje uzorka
> data(iris)
> # obeleze 'Species' ima 3 kategorija
> # ovo cemo koristiti za stratifikaciju
> # racuna stratum populacije
> table(iris$Species)

      setosa versicolor virginica
      50          50          50

>
> # velicine stratuma uzorka su date sa size=c(6,4,3)
> # koristimo metodu SRSWOR (jednake verovatnoce, bez ponavljanja)
> st=strata(iris,stratanames=c("Species"),
+            size=c(6,4,3),
+            method="srswor")
> # izvlaci sam uzorak iz baze
> x=getdata(iris, st)
>
> # racunanje HT ocene za obeleze Petal.Length
> HTstrata(x$Petal.Length,x$Prob,x$Stratum,description=TRUE)
For stratum 1 ,the Horvitz-Thompson estimator is: 79.16667
For stratum 2 ,the Horvitz-Thompson estimator is: 225
For stratum 3 ,the Horvitz-Thompson estimator is: 253.3333
The Horvitz-Thompson estimator is:
[1] 557.5
> |
```

`balancedtwostage(X,selection,m,n,PU, comment=TRUE,method=1)`

- Даје балансирали двофазни узорак
- Φ -ја враћа вектор са следећим колонама: јединице изабране у другој фази (0-није изабрана, 1-изабрана), коначне вероватноће укључивања, јединице изабране у првој фази, вероватноће укључивања у првој фази, вероватноће укључивања у другој фази
- X матрица помоћних променљивих на основу којих се узорак балансира
- *selection*: 1 – за SRSWOR у свакој фази
 2 – sa self-weighting двофазни узорак
- m обим узорка у првој фази
- n обим узорка у другој фази
- PU вектор који дефинише узорак у првој фази
- *comment* пише се коментар извршавања ако је *TRUE*

```
>data(MU284)
>X=cbind(MU284$P75,MU284$CS82,
+           MU284$SS82,MU284$ME84)
>N=dim(X)[1]
>PU=MU284$CL
>m=20
>n=60
>res=balancedtwostage(X,1,m,n,PU,TRUE)
#uzorak i verovatnoce ukljucivanja
>res
```

`poststrata(data, postnames)`

- Ова команда врши постстратификацију на основу неколико критеријума. Даје објекат који садржи коначну базу са новом колоном '*poststratum*' (јединице постстратума) и број постстратума
- *data* база података, број врста је једнак п (обим узорка)
- *postnames* вектор обележја по којем се врши постстратификација

```
> data=rbind(matrix(rep("nc",165),165,1,byrow=TRUE) ,  
+             matrix(rep("sc",70),70,1,byrow=TRUE))  
> data=cbind. data.frame(data,c(rep(1,100), rep(2,50), rep(3,15),  
+                               rep(1,30),rep(2,40)),1000*runif(235))  
> names(data)=c("state","region","income")  
> table(data$region,data$state)  
  
      nc   sc  
1 100   30  
2   50   40  
3   15    0  
> # poststratifikacija koriscenjem kriterija 'state' i 'region'  
> poststrata(data,postnames=c("state","region"))
```

```
postest(data, y, pik, NG,  
        description=FALSE)
```

- Рачуна оцену за тотал популације при постстратификације
- $data$ база података, број врста је једнак n (обим узорка)
- y вектор обележја који испитујемо њена дужина је једнака обиму узорка n
- pik вектор вероватноћа укључивања прве врсте (дужине n)
- NG вектор фреквенције популације у свакој групи G ; за стратификовани узорак са постстратификацијом NG је матрица фреквенција популације у сваком пољу GH
- $description$ ако је $TRUE$ штампа се оцена за сваки постстратум

```
>
> data(swissmunicipalities)
> attach(swissmunicipalities)
> table(swissmunicipalities$REG)

 1   2   3   4   5   6   7
589 913 321 171 471 186 245
> st=strata(swissmunicipalities,stratenames=c("REG"),
+             size=c(30,20,45,15,20,11,44), method="srswor")
> x=getdata(swissmunicipalities, st)
> px=poststrata(x,"REG")
> ct=unique(px$data$REG)
> yy=numeric(length(ct))
> for(i in 1:length(ct))
+ {xx=swissmunicipalities[REG==ct[i],]
+  yy[i]=nrow(xx)
+ }
> yy
[1] 171 589 321 913 471 186 245
> postest(px$data,y=px$data$Pop020,pik=px$data$Prob,
+          NG=diag(yy),description=FALSE)
[1] 1534257
> HTstrata(x$Pop020,x$Prob,x$stratum)
[1] 1534257
>
```

ratioest(y,x,Tx,pik)

- Рачуна количничку оцену за тотал популације
- у вектор обележја који испитујемо њена дужина је једнака обиму узорка n
- x вектор помоћних података дужине n
- Tx тотал популације за x
- pik вектор вероватноћа укључивања прве врсте (дужине n)

```
> data(MU284)
> # postoji 3 outliera koji se brisu iz populacije
> MU281=MU284[MU284$RMT85<=3000,]
> attach(MU281)
> # racuna verov ukljuc koristeci oblezje P85; obim uzorka 120
> pik=inclusionprobabilities(P85,120)
> # definisemo oblezje koje posmatramo
> y=RMT85
> # definisemo popocni podatak
> x=C582
> # izvlaci sistematicni uzorak obima 120
> s=UPSsystematic(pik)
> # racuna kolicnicku ocenu
> ratioest(y[s==1],x[s==1],sum(x),pik[s==1])
[1] 53330.48
> |
```

`ratioest_strata(y,x,TX_strata,pik,strata, description=FALSE)`

- Рачуна количничку оцену за тотал популације за стратификован план узорковања
- y вектор обележја који испитујемо њена дужина је једнака обиму узорка n
- x вектор помоћних података дужине n
- TX_strata вектор који садржи тотале популације x на сваком стратуму
- pik вектор вероватноћа укључивања прве врсте (дужине n)
- $strata$ вектор дужине n , са јединицама популације који се налазе у стартумима
- $description$ ако је $TRUE$ штампа се оцена за сваки стратум

```
> data(MU284)
> # postoji 3 outliera koji se brisu iz populacije
> MU281=MU284 [MU284$RMT85<=3000,]
> attach(MU281)
> # racuna verov ukljuc koristeci oblezje P85; obim uzorka 120
> pik=inclusionprobabilities(P85,120)
> # definisemo oblezje koje posmatramo
> y=RMT85
> # definisemo popocni podatak
> x=CS82
> table(MU281$REG)

 1  2  3  4  5  6  7  8
24 48 32 37 55 41 15 29
> # izvlaci sistematicni uzorak obima 120
> s=strata(MU281,c("REG"),size=c(4,10,8,4,6,4,6,7),
+           method="systematic",pik=P85)
> #izdvojimo uzorak
> MU281sample=getdata(MU281,s)
> # racuna x total populacije u svakom stratumu
> TX_strata=as.vector(tapply(CS82,list(REG),FUN=sum))
> # racuna kolicnicku ocenu
> ratioest_strata(MU281sample$RMT85,MU281sample$CS82,TX_strata,
+                   MU281sample$Prob,MU281sample$stratum)
[1] 56501.81
>
```

```
regest(formula,Tx,weights,pikl,n,  
       sigma=rep(1,length(weights)))
```

- Рачуна регресиону оцену тотала популације
- $formula$ регресиони модел ($y \sim x$)
- Tx тотал популације за обележје x
- $weights$ вектор тежина дужине n
- $pikl$ матрица вероватноћа укључивања друге врсте узорка
- $sigma$ вектор позитивних бројева који се односи на *heteroscedasticity* (то је када подпопулација има нека другачија обележја него што има цела популација)

Ф-ја враћа листу која садржи следеће аргументе

- *regest* вредност регресионе оцене
- *coefficients* вектор бета коефицијената
- *std_error* стандардна грешка коефицијената
- *t_value* t-вредност која је придружена коефицијентима
- *p_value* p-вредност која је придружена коефицијентима
- *cov_mat* коваријациона матрица коефицијената
- *weights* назначене тежине.
- *y* резултирајућа променљива
- *x* матрица модела

```
>
> data(MU284)
> # ima 3 outliera koje izbacujemo iz populacije
> MU281=MU284[MU284$RMT85<=3000,]
> attach(MU281)
> # racuna verov ukljuc koristeci obelezje P85; obim uzorka 40
> pik=inclusionprobabilities(P85,40)
> # verov ukljuc druge vrste za sistematski uzorak
> pikl=UPsystematicpi2(pik)
> # izvlaci uzorak obima 40
> s=UPsystematic(pik)
> # definisemo obelezje od vaznosti
> y=RMT85[s==1]
> # definisemo pomocne podatke
> x1=CS82[s==1]
> x2=SS82[s==1]
> # verov ukljuc druge vrste za s
> pikls=pikl[s==1,s==1]
> # verov ukljuc prve vrste za s
> piks=pik[s==1]
> # racuna regresionu ocenu za model y~x1+x2-1
> r=regest(formula=y~x1+x2-1,
+           Tx=c(sum(CS82),sum(SS82)),weights=1/piks,pikl=pikls,n=40)
> |
```

```
> r
$call
regest(formula = y ~ x1 + x2 - 1, Tx = c(sum(cs82), sum(ss82)),
       weights = 1/piks, pikl = pikls, n = 10)

$formula
y ~ x1 + x2 - 1

$x
  x1 x2
1 24 8
2 14 33
3 19 38
4 15 39
5 13 30
6 12 30
7 11 19
8 15 35
9  5 24
10 4 19
attr(,"assign")
[1] 1 2

$y
  1   2   3   4   5   6   7   8   9   10
241 488 807 431 275 396 208 965 249  54

$weights
[1] 25.117857 10.820000  6.572897 11.721667 20.094286 15.289130
[7] 21.978125  5.960169 18.507895 78.144444

$regest
[1] 64660.81

$coefficients
  xx1      xx2
10.893502 7.073114
```

```
$std_error
[1] 0.4362238 0.6255010

$t_value
  xx1      xx2
24.97228 11.30792

$p_value
  xx1      xx2
1.271414e-09 1.275042e-06

$cov_matrix
[,1]      [,2]
[1,] 0.1902912 -0.1037101
[2,] -0.1037101  0.3912516

attr(,"class")
[1] "regest"
> |
```

```
regest_strata(formula,weights,Tx_strata,strata,pikl,  
sigma=rep(1,length(weights)),description=FALSE)
```

- Рачуна регресиону оцену тотала популације за стратификовани узорак, исти регресиони модел се користи за сваки стратум
- *formula* регресиони модел ($y \sim x$)
- *weights* вектор тежина дужине n
- *Tx_strata* тотал популације за обележје x
- *strata* вектор идентификатора страума (vector of stratum identifier)
- *pikl* матрица вероватноћа укључивања друге врсте узорка
- *sigma* вектор позитивних бројева који се односи на *heteroscedasticity*
- *description* ако је TRUE за сваки страм се штампа : Horvitz-Thompson-ова оцена, бета коефицијенти, њихове стандардне грешке, t вредности, p вредности и ковариациони матрица
- Ф-ја враћа регресиону оцену као суму оцена по стратумима

```
>
>
> # dajemo neke nase podatke
> y=rgamma(10,3)
> x=y+rnorm(10)
> stratum=c(1,1,2,2,2,3,3,3,3,3)
> # obim populacije
> N=200
> # obim uzorka
> n=10
> # proporcionalna raspodela, nh/Nh=n/N
> pikl=matrix(0,n,n)
> for(i in 1:n)
+ {for(j in 1:n)
+   if(i!=j)
+     pikl[i,j]=pikl[j,i]=n*(n-1)/(N*(N-1))
+   pikl[i,i]=n/N
+ }
> regest_strata(formula=y~x-1,weights=rep(N/n,n),
+                 Tx_strata=c(50,30,40),
+                 strata=stratum,pikl,description=TRUE)
```

Излаз

```
Stratum 1 , the regression estimator is: 48.16086
Number of units: 2
Beta coefficient(s): 0.9781678
Std. error: 0.01336873
t-value: 73.16832
p_value: 0.008700215
cov_matrix:
      [,1]
[1,] 0.000178723
Stratum 2 , the regression estimator is: 27.39036
Number of units: 3
Beta coefficient(s): 0.7903391
Std. error: 0.05614442
t-value: 14.0769
p_value: 0.005008571
cov_matrix:
      [,1]
[1,] 0.003152196
Stratum 3 , the regression estimator is: 35.62239
Number of units: 5
Beta coefficient(s): 0.8107618
Std. error: 0.1126522
t-value: 7.197034
p_value: 0.001975194
cov_matrix:
      [,1]
[1,] 0.01269052
The regression estimator is:
[1] 111.1736
> |
```



НÁЈЕК-ова оцена

- Нека се врши узорковање са вероватноћама пропорционалним величин, нека су π_i вероватноће укључивања i -те јединице. Тада је Hájek-ова оцена средине популације:

$$\hat{Y}_{\text{Haj}} = \frac{\sum_{i=1}^n \frac{Y_i}{\pi_i}}{\sum_{i=1}^n \frac{1}{\pi_i}}$$

- Слично, оцена за тотал популације је

$$\bar{Y}_{\text{Haj}} = N \frac{\sum_{i=1}^n \frac{Y_i}{\pi_i}}{\sum_{i=1}^n \frac{1}{\pi_i}}$$

```
Hajekestimator(y,pik,N=NULL,  
type=c("total","mean"))
```

- Рачуна Hajek-ову оцену за тотал популације или средиште популације
- y вектор обележја чију оцену тражимо, њена дужина је једнака обиму узорка n
- pik вектор вероватноћа укључивања прве врсте (дужине n)
- N обим популације, овај аргумент је дат само када се рачуна оцена за тотал, иначе је $NULL$
- $type$ тип оцене: "total" или "mean"

```
>
> data(belgianmunicipalities)
> # verovatnoce ukljucivanja
> pik=inclusionprobabilities(belgianmunicipalities$Tot04,200)
> N=length(pik)
> n=sum(pik)
> # obelezje za koju racunamo ocenu
> y=belgianmunicipalities$TaxableIncome
> # uzima Puasonov uzorak obima 200
> s=UPpoisson(pik)
> # Hajek-ova ocena za sredinu populacije
> Hajkestimator(y[s==1],pik[s==1],type="mean")
[1]
[1,] 207251898
Warning message:
In Hajkestimator(y[s == 1], pik[s == 1], type = "mean") :
  by default the mean estimator is computed
> # Hajek-ova ocena za total populacije
> Hajkestimator(y[s==1],pik[s==1],N=N,type="total")
[1]
[1,] 122071367886
> |
```