

Procvičování 9 - řešení

- Importujte do **R** tabulkou jmen s daty narození českých občanů *jmena.txt*. Nazvěte ji *jm.data*. Tabulka obsahuje v řádcích všechna jednoslovná křestní jména českých obyvatel, ve sloupcích pak jejich frekvenci v jednotlivých ročnících od r. 1896 do 2013. Tabulka je docela velká, nepokoušejte se ji proto celou zobrazit v **R**, nechejte si raději vypsat jen prvních pár řádků a sloupců. Najdete ji ve studijních materiálech, nebo ji můžete načíst přímo z <http://www.sci.muni.cz/~syrovat/jmena.txt>, to ale bude chvilku trvat.

```
# Mam problem s encodovanim v LyXu, nepodarilo se mi pres LyX nacist spravne jmena
# s diakritikou, coz zpusobuje, ze nektera jmena jsou zdanlive duplikovana.
# Nactu proto dataset bez jmen radku, odstranim duplikovana jmena, a pak teprve definuji
# jmena radku.
# Nastaveni pracovniho adresare:
setwd("D:/My Dropbox/predmety/uvod do R/2014/cv09")
# nacteni jmen bez jmen radku, zabranim vytvoreni faktoru ze jmen a kontrole jmen sloupca:
jm.data<- read.delim('jmena.txt', sep= '\t', check.names= F, stringsAsFactors= F)
# odstraneni radku s duplikovanymi jmeny:
jm.data<- jm.data[!duplicated(jm.data[, 1])], ]
# definovani jmen radku:
jm.data<- data.frame(jm.data, row.names= 1)

## Error: row names contain missing values

# R hlasí, ze mezi jmeny jsou missing values (NA), odstranim i ty:
jm.data<- jm.data[!is.na(jm.data[, 1])], ]
# definovani jmen radku podruhe:
jm.data<- data.frame(jm.data, row.names= 1)
```

- Do vektoru *jm.freq* vypočítejte frekvenci výskytu jednotlivých jmen v české populaci.

```
jm.freq<- rowSums(jm.data)
```

- Do vektoru *jm* si vytáhněte křestní jména z dataframu *jm.data*.

```
jm<- rownames(jm.data)
```

- Seřaďte křestní jména podle abecedy a nechejte si zobrazit prvních a posledních 20.

```
sort(jm)[1:20]

## [1] ""
## [6] "\016AKER"   "\016AKELIN"   "\016AKELINA"  "\016AKELMNA"
## [11] "\016ANET"    "\016ANETA"    "\016ANETKA"   "\016ANETTA"   "\016ANNA"
## [16] "\016ANNETA"  "\016ARKO"    "\016AV"       "\016EANETA"   "\016ELAN"

# Vas vysledek by mel byt jiny (lepsi), me zlobi to kodovani v LyXu.
```

5. Zjistěte nejdélší křestní jméno. Postup: vytvořte si vektor délek jmen, seřaďte jména podle jejich délek od nejvyšších po nejnižší a vyberte první. Délkou rozumíme počet znaků (characters). Funkci, která zjistí délku textového řetězce musíte vyhledat.

```
# Hledame funkci, ktera vrati pocet znaku u nejakem retezci, anglicky "number of characters".
# Nejprve muzeme zkusit hledani funkce uvnitr nasi instalace R pomocí ??
# ???"number of characters"
# mi vratio funkci nchar z baliku base (psano base::nchar).
# Připadne (nebo pokud ?? nefunguje) muzeme primo hledat na googlu. Jeden z prvnich
# odkazu urcite bude smerovat na stejnou funkci.
# Abychom zjistili, jak funkci pouzit, podivame se na její napovedu:
# ?nchar
# Vektor delek jmen (poctu znaku ve jmenech):
jm.nchar<- nchar(jm)
# Ted staci jmena seradit sestupne podle delek a vybrat prvni:
jm[order(-jm.nchar)[1]]
## [1] "ANDRIANANDRAINA"

# Tohle mame snad vsichni stejne.
```

6. Nechejte si vypsat 100 nejkratších jmen.

```
jm[order(jm.nchar)[1:100]]

## [1]   ""     "E"     "A"     "T"     "R"     "I"     "N"     "O"     "P"     "U"     "V"
## [12] "KA"   "AI"   "AJ"   "AL"   "AN"   "IK"   "TI"   "TA"   "AR"   "ES"   "OM"
## [23] "OT"   "BA"   "IR"   "BI"   "BO"   "KO"   "DA"   "JA"   "DE"   "DI"   "DO"
## [34] "DU"   "ED"   "EL"   "AD"   "EK"   "GA"   "HA"   "IM"   "EM"   "HI"   "AM"
## [45] "MK"   "JE"   "JO"   "KE"   "KI"   "AV"   "OF"   "MM"   "LA"   "LE"   "LY"
## [56] "MA"   "MI"   "MO"   "MR"   "MY"   "OK"   "OR"   "OZ"   "PA"   "PE"   "PI"
## [67] "IA"   "RA"   "MD"   "RI"   "RM"   "RU"   "ID"   "RY"   "RJ"   "SA"   "SI"
## [78] "SY"   "ON"   "TE"   "TL"   "TU"   "TZ"   "TY"   "IE"   "UR"   "AK"   "VI"
## [89] "VM"   "VU"   "IN"   "VY"   "WU"   "YA"   "YE"   "YI"   "ZO"   "ABA"  "ABE"
## [100] "ABI"

# opet, vas vysledek bude jiny.
```

7. Nechejte si vypsat 50 nejběžnějších jmen.

```
jm[order(-jm.freq)[1:50]]

## [1] "JIXM"      "JAN"       "MARIE"     "PETR"      "JANA"
## [6] "JOSEF"     "PAVEL"     "MARTIN"    "JAROSLAV"  "EVA"
## [11] "MIROSLAV"  "HANA"      "ANNA"      "ZDENLK"    "MICHAL"
## [16] "LENKA"     "KATEXINA"  "VLRA"      "MILAN"     "KAREL"
## [21] "LUCIE"     "ALENA"     "PETRA"     "JAKUB"     "DAVID"
## [26] "JAROSLAVA" "VLADIMMR"  "VERONIKA"  "MARTINA"   "JITKA"
## [31] "TEREZA"    "LUDMILA"   "HELENA"    "MICHAELA"  "LADISLAV"
```

```
## [36] "ZDERKA"      "ONDXEJ"       "IVANA"        "ROMAN"        "STANISLAV"
## [41] "JARMILA"      "MONIKA"       "MAREK"        "ZUZANA"       "JIXINA"
## [46] "MARKITA"      "RADEK"        "DANIEL"       "ANTONMN"     "MARCELA"

# tady taky vas vysledek bude jiny.
```

8. Zjistěte, zda se Vaše jméno nachází mezi 50 nejběžnějšími.

```
# 50 nejbeznejsich jmen uz umime zjistit, ted se jen zeptame, zda to nase je mezi nimi:
"VIT" %in% jm[order(-jm.freq)[1:50]]

## [1] FALSE

# Pokud bychom neznali %in% operator, muzeme se porovnat nase jmeno
# s kazdym z 50 nejbeznejsich a secist logicke hodnoty uzesle z tohoto porovnani.
# Pokud je jejich suma > 0, pak se moje jmeno vyskytuje mezi temi 50:
sum("VIT" == jm[order(-jm.freq)[1:50]]) > 0

## [1] FALSE
```

9. Zjistěte kolikáté nejběžnější je Vaše jméno.

```
# Muzeme vyuzit toho, ze jmena rozmeru (radku ci sloupcu) se pri vypooctech
# mezi objekty prenaseji. Staci zjistit poradi (rank) frekvenci jmen a vyhledat
# poradi daneho jmena. Zajima nas samozrejme poradi od nejvyssi po nejnizsi prekvenci:
rank(-jm.freq)["VIT"]

## VIT
## 6486

# Stejneho dosahneme i tak, ze ke jmenum pripojime jejich ranky, a pak se podivame na radek
# daneho jmena. Zobrazit muzeme i frekvenci:
jm.dtf<- data.frame(jmena= jm, jm.freq= jm.freq, jm.rank= rank(-jm.freq), row.names= 1)
jm.dtf["VIT", ]

##      jm.freq jm.rank
## VIT         2      6486
```

10. Nainportujte do **R** dataframy *spe* a *env* a vektor korelací abundancí jednotlivých druhů s Froudeho číslem *korelace*. Použijte funkce **read.delim()** a **scan()**. Vše najdete v *dat09.xls*.

```
spe<- read.delim('D:/My Dropbox/predmety/uvod do R/2013/cv09/spe.txt', row.names=1)
env<- read.delim('D:/My Dropbox/predmety/uvod do R/2013/cv09/env.txt', row.names=1)

kor <- scan()
```

11. Nechejte si vypsat zaokrouhlené hodnoty Froudeho čísla (na 2 desetinná místa) seřazené od nejmenší po největší, a pak od největší po nejmenší.

```

sort(round(env$froude, 2))

## [1] 0.00 0.02 0.04 0.05 0.05 0.07 0.07 0.13 0.13 0.14 0.14 0.14 0.14 0.17 0.18
## [15] 0.18 0.22 0.24 0.30 0.30 0.33 0.41 0.43 0.48 0.51 0.52 0.54 0.56

sort(round(env$froude, 2), decreasing=T)

## [1] 0.56 0.54 0.52 0.51 0.48 0.43 0.41 0.33 0.30 0.30 0.24 0.22 0.18 0.18
## [15] 0.17 0.14 0.14 0.14 0.13 0.13 0.07 0.07 0.05 0.05 0.04 0.02 0.00

```

12. Zjistěte 5 nejnižších a 5 nejvyšších hodnot Froudeho čísla.

```

sort(env$froude)[1:5]

## [1] 0.001813 0.020319 0.039662 0.046165 0.051925

sort(env$froude, decreasing= T)[1:5]

## [1] 0.5584 0.5395 0.5225 0.5071 0.4767

# nebo naraz treba takhle:
sort(env$froude)[c(1:5, (length(env$froude)-4) : length(env$froude))]

## [1] 0.001813 0.020319 0.039662 0.046165 0.051925 0.476675 0.507082
## [8] 0.522477 0.539509 0.558432

```

13. Nechcejte si vypsat jména 5 lokalit s nejvyšším Froudeho číslem.

```

rownames(env)[order(env$froude, decreasing=T)][1:5]

## [1] "s24" "s25" "s12" "s21" "s20"

```

14. Do dataframu *env* přidejte proměnné *ind* a *spec* obsahující celkové počty jedinců a druhů pako-mářů na lokalitách.

```

env$ind<- rowSums(spe)
env$spec<- rowSums(spe>0)

```

15. Nechejte si vypsat počty druhů seřazené podle Froudeho čísla od nejmenšího po největší.

```

env$spec[order(env$froude)]

## [1] 31 28 27 19 26 29 25 15 20 16 22 19 17 27 22 21 31 26 30 23 19 17 20
## [24] 28 24 19 31

```

16. Nechejte si vypsat dataframe *env* seřazený podle Froudeho čísla od nejvyššího po nejnižší.

```
env[order(-env$froude),]

##      gr depth   vel  froude ind spec
## s24  Er_VEG 0.300 0.958 0.558432 678  31
## s25      Er 0.139 0.630 0.539509  47  19
## s12  Er_VEG 0.245 0.810 0.522477 450  24
## s21  Er_VEG 0.138 0.590 0.507082 531  28
## s20      Er 0.290 0.804 0.476675 221  20
## s08      Er 0.213 0.618 0.427528 146  17
## s10  Er_VEG 0.353 0.758 0.407331 212  19
## s09      Er 0.243 0.508 0.329023 220  23
## s15  Er_VEG 0.279 0.496 0.299809 738  30
## s07      Er 0.278 0.490 0.296715 258  26
## s18  Er_VEG 0.200 0.340 0.242733 565  31
## s11  Er_VEG 0.236 0.334 0.219511 181  21
## s14      Ep 0.155 0.224 0.181655 150  22
## s02      Ep 0.422 0.358 0.175951 405  27
## s16      Ep 0.501 0.372 0.167799 122  17
## s03      Ep 0.496 0.310 0.140536 146  19
## s01      Ep 0.395 0.274 0.139193 139  22
## s17      Ep 0.454 0.286 0.135520 243  16
## s22      Ep 0.340 0.246 0.134698 122  20
## s23      Ep 0.344 0.234 0.127380 145  15
## s06 Ep_FPOM 0.328 0.126 0.070242 611  25
## s13 Ep_CPOM 0.184 0.088 0.065500 569  29
## s05 Ep_FPOM 0.320 0.092 0.051925 489  26
## s04 Ep_FPOM 0.291 0.078 0.046165 183  19
## s19      Ep 0.162 0.050 0.039662 198  27
## s27 Ep_CPOM 0.478 0.044 0.020319 416  28
## s26 Ep_CPOM 0.124 0.002 0.001813 893  31
```

17. Zjistěte, kolik druhů a kolik jedinců pakomářů bylo na 5 lokalitách s nejvyšším Froudeho číslem (vyberte jen příslušné elementy z proměnných *ind* a *spec* dataframu *env*).

```
env[order(env$froude, decreasing=T)[1:5], c('ind','spec')]

##      ind spec
## s24 678  31
## s25 47   19
## s12 450  24
## s21 531  28
## s20 221  20
```

18. Zjistěte, jaké Froudeho číslo bylo naměřeno na 3 lokalitách s nejvyšším počtem jedinců pakomářů.

```
env$froude[order(env$ind, decreasing=T)[1:3]]

## [1] 0.001813 0.299809 0.558432
```

19. Nechejte si vypsat dataframe *env* s lokalitami seřazenými podle Froudeho čísla.

```
env[order(env$froude),]

##          gr depth   vel  froude ind spec
## s26    Ep_CPOM 0.124 0.002 0.001813 893  31
## s27    Ep_CPOM 0.478 0.044 0.020319 416  28
## s19      Ep 0.162 0.050 0.039662 198  27
## s04    Ep_FPOM 0.291 0.078 0.046165 183  19
## s05    Ep_FPOM 0.320 0.092 0.051925 489  26
## s13    Ep_CPOM 0.184 0.088 0.065500 569  29
## s06    Ep_FPOM 0.328 0.126 0.070242 611  25
## s23      Ep 0.344 0.234 0.127380 145  15
## s22      Ep 0.340 0.246 0.134698 122  20
## s17      Ep 0.454 0.286 0.135520 243  16
## s01      Ep 0.395 0.274 0.139193 139  22
## s03      Ep 0.496 0.310 0.140536 146  19
## s16      Ep 0.501 0.372 0.167799 122  17
## s02      Ep 0.422 0.358 0.175951 405  27
## s14      Ep 0.155 0.224 0.181655 150  22
## s11    Er_VEG 0.236 0.334 0.219511 181  21
## s18    Er_VEG 0.200 0.340 0.242733 565  31
## s07      Er 0.278 0.490 0.296715 258  26
## s15    Er_VEG 0.279 0.496 0.299809 738  30
## s09      Er 0.243 0.508 0.329023 220  23
## s10    Er_VEG 0.353 0.758 0.407331 212  19
## s08      Er 0.213 0.618 0.427528 146  17
## s20      Er 0.290 0.804 0.476675 221  20
## s21    Er_VEG 0.138 0.590 0.507082 531  28
## s12    Er_VEG 0.245 0.810 0.522477 450  24
## s25      Er 0.139 0.630 0.539509  47  19
## s24    Er_VEG 0.300 0.958 0.558432 678  31
```

20. Nechejte si vypsat dataframe *env* s lokalitami seřazenými podle typu habitatu (*gr*) a uvnitř typů podle hloubky vody.

```
env[order(env$gr, env$depth),]

##          gr depth   vel  froude ind spec
## s14      Ep 0.155 0.224 0.181655 150  22
## s19      Ep 0.162 0.050 0.039662 198  27
## s22      Ep 0.340 0.246 0.134698 122  20
## s23      Ep 0.344 0.234 0.127380 145  15
## s01      Ep 0.395 0.274 0.139193 139  22
## s02      Ep 0.422 0.358 0.175951 405  27
## s17      Ep 0.454 0.286 0.135520 243  16
## s03      Ep 0.496 0.310 0.140536 146  19
## s16      Ep 0.501 0.372 0.167799 122  17
## s26    Ep_CPOM 0.124 0.002 0.001813 893  31
## s13    Ep_CPOM 0.184 0.088 0.065500 569  29
```

```
## s27 Ep_CPOM 0.478 0.044 0.020319 416 28
## s04 Ep_FPOM 0.291 0.078 0.046165 183 19
## s05 Ep_FPOM 0.320 0.092 0.051925 489 26
## s06 Ep_FPOM 0.328 0.126 0.070242 611 25
## s25 Er 0.139 0.630 0.539509 47 19
## s08 Er 0.213 0.618 0.427528 146 17
## s09 Er 0.243 0.508 0.329023 220 23
## s07 Er 0.278 0.490 0.296715 258 26
## s20 Er 0.290 0.804 0.476675 221 20
## s21 Er_VEG 0.138 0.590 0.507082 531 28
## s18 Er_VEG 0.200 0.340 0.242733 565 31
## s11 Er_VEG 0.236 0.334 0.219511 181 21
## s12 Er_VEG 0.245 0.810 0.522477 450 24
## s15 Er_VEG 0.279 0.496 0.299809 738 30
## s24 Er_VEG 0.300 0.958 0.558432 678 31
## s10 Er_VEG 0.353 0.758 0.407331 212 19
```

21. Nechejte si vypsat jména pěti nejfrekventovanějších druhů (tedy těch s výskytem na nejvyšším počtu lokalit).

```
names(spe)[order(-colSums(spe>0))[1:5]]
## [1] "orthobum" "synosemi" "corysp." "mictrasp" "thiegrge"
```

22. Nechejte si vypsat jména druhů seřazená podle jejich korelací s Froudeho číslem.

```
names(spe)[order(kor)]
## [1] "micrchgr" "thiegrge" "cromussp" "cladotsp" "apsetrif" "natasp."
## [7] "prodoliv" "polyscgr" "paraalgr" "corysp." "tanytasp" "tanybrun"
## [13] "ablbesp" "phaepssp" "synosemi" "stembrgr" "cricbici" "thellasp"
## [19] "brilmode" "hememarc" "nilodubi" "paratasp" "polyconv" "demisp."
## [25] "mictrasp" "orthobum" "pararufi" "brilflav" "diplcult" "eukisimi"
## [31] "rheofusc" "paracrsp" "pottgaed" "eukigrgr" "eukibrev" "orthfrig"
## [37] "nanoreag" "eukicoer" "eukimino" "parastyl" "cricannu" "critria"
## [43] "polylagr" "orthrubi" "crictrgr" "rheotasp" "pottlong" "orthrigr"
## [49] "eukideil" "tvetbaca" "eukilobi" "cricbigr" "orththie" "tvetdive"
```

23. Zjistěte, kterých 10 druhů nejlépe koreluje s Froudeho číslem. Pozor na to, že korelace může být kladná nebo záporná, zajímají nás druhy, které nejlépe na hydraulické podmínky reagují, tedy ty s nejnižší a nejvyšší korelací (při řazení tedy použijeme absolutní hodnoty korelací).

```
names(spe)[order(-abs(kor))][1:10]
## [1] "micrchgr" "thiegrge" "tvetdive" "cromussp" "orththie" "cricbigr"
## [7] "eukilobi" "cladotsp" "tvetbaca" "apsetrif"
```

24. Vytvořte kopii dataframu *spe*, v níž bude 7 druhů které nejlépe reagovaly na hydraulické podmínky.

```
spe.red<- spe[, order(-abs(kor))[1:7]]
spe.red

##      micrchgr thiegrge tvetdive cromussp orththie cricbigr eukilobi
## s01       25      5       4       0       0       2       3
## s02       31     15       7       0       0       7       1
## s03       31      8       5       0       0       0       0
## s04       14     17       1       0       0       0       0
## s05        3     59       0       1       0       0       0
## s06       31     61       0       4       0       1       1
## s07        0      5       9       0       0       2       2
## s08        0      0       4       0       1       1       1
## s09        0      1       5       0       2       7       2
## s10        0      0      17       0       0       6       4
## s11        0      1      12       0       0       7       2
## s12        0      1      32       0       1      13       4
## s13      213     72       0       2       0       0       0
## s14        0      3       2       1       0       2       1
## s15        9     17      64       0       1       3      14
## s16        0      1       1       0       0       2       1
## s17        1      4       0       0       1       0       1
## s18        0      3      53       0       1       9       6
## s19      25     14       2       1       0       0       8
## s20        0     13      41       0       0       0       3
## s21        0      1     87       0       3       2       7
## s22        8     13       5       6       0       0       0
## s23        5      6       0       7       0       0       0
## s24        0      6     116       0       2       3       7
## s25        0      1       1       0       1       1       1
## s26     287    127       1       5       0       0       0
## s27     126     32       2       2       0       0       0
```

25. Seřaďte sloupce tohoto dataframu podle typu odezvy (kladná nebo záporná korelace), a uvnitř každého typu podle síly korelace (první budou ty s nejvyšší odezvou). Řádky pak seřaďte podle Froudeho čísla.

```
# V predchozim bode jsme vybrali 7 druhu s nejsilnejsi odezvou.
# Techto 7 druhu ted potrebujeme dal seradit podle jejich korelaci, a na to potrebujeme mit
# vytazene korelace jen techto 7 druhu. Vytahneme si je stejne, jako jsme vybrali ty druhy:
kor.red<- kor[order(-abs(kor))[1:7]]
# Nyni mame dataframe s abundancemi 7 vybranych druhu (spe.red)
# a vektor jejich korelace (kor.red).
# Staci tedy seradit radky a sloupce dataframu spe.red a jsme hotovi:
spe.red.sort<- spe.red[order(env$froude), order(kor.red>0, -abs(kor.red))]
spe.red.sort

##      micrchgr thiegrge cromussp tvetdive orththie cricbigr eukilobi
```

## s26	287	127	5	1	0	0	0
## s27	126	32	2	2	0	0	0
## s19	25	14	1	2	0	0	8
## s04	14	17	0	1	0	0	0
## s05	3	59	1	0	0	0	0
## s13	213	72	2	0	0	0	0
## s06	31	61	4	0	0	1	1
## s23	5	6	7	0	0	0	0
## s22	8	13	6	5	0	0	0
## s17	1	4	0	0	1	0	1
## s01	25	5	0	4	0	2	3
## s03	31	8	0	5	0	0	0
## s16	0	1	0	1	0	2	1
## s02	31	15	0	7	0	7	1
## s14	0	3	1	2	0	2	1
## s11	0	1	0	12	0	7	2
## s18	0	3	0	53	1	9	6
## s07	0	5	0	9	0	2	2
## s15	9	17	0	64	1	3	14
## s09	0	1	0	5	2	7	2
## s10	0	0	0	17	0	6	4
## s08	0	0	0	4	1	1	1
## s20	0	13	0	41	0	0	3
## s21	0	1	0	87	3	2	7
## s12	0	1	0	32	1	13	4
## s25	0	1	0	1	1	1	1
## s24	0	6	0	116	2	3	7

26. Exportujte do excelu výsledný dataframe. Použijte funkci `write.table()`.

```
write.table(spe.red.sort, file= 'D:/My Dropbox/predmety/uvod do R/2014/cv09/spe.red.txt',
sep= '\t', col.names = NA, row.names = TRUE)
```