



Osnovni podaci u R-u i učitavanje podataka iz fajlova

Dr Nadica Miljković, vanredni profesor
kabinet 68, nadica.miljkovic@etf.bg.ac.rs

ZADACI TIPOVI PODATAKA U R-U

Nizovi

- Proveriti koji su ulazni parametri funkcija `c()`, `vector()` i `is.vector()`?
- Kreirati sledeće nizove:
 - `n1 = [0.6 0.8 0.7 0.7 0.9]`
 - `n2 = [T F F F T T];`
 - `n3 = ["blue" "red" "orange" "pink" "green"];`
 - `n4 = [0.8 T F T "gray"]` **Kog je tipa n4? HINT: koristiti funkciju `class()`.**
- Za ovako kreirane nizove izvršiti eksplicitnu konverziju na sledeći način:
 - niz `n1` pretvoriti u niz karaktera
 - niz `n2` pretvoriti u niz numeričkih promenljivih
 - niz `n3` pretvoriti u kategoričku promenljivu (*factor*)
 - niz `n4` pretvoriti u *boolean* promenljivu **HINT: koristiti `as.logical()`**
Koliko NA se dobija (proveriti funkcijom `is.na()`) i funkcijom za eksplicitno “štampanje” `print()`) i zašto?

Karakteri

```
> c1 <- c("jedan", "dva", "tri", "cetiri", "pet")
> c1
[1] "jedan"  "dva"     "tri"     "cetiri"  "pet"
> class(c1)
[1] "character"
> is.vector(c1)
[1] TRUE
> c2 <- ('jedan', 'dva', 'tri', 'cetiri', 'pet')
Error: unexpected ',' in "c2 <- ('jedan',"
> c2 <- c('jedan', 'dva', 'tri', 'cetiri', 'pet')
> c2
[1] "jedan"  "dva"     "tri"     "cetiri"  "pet"
> class(c2)
[1] "character"
> is.vector(c2)
[1] TRUE
> |
```

- Ove promenljive se u R-u mogu označavati na 2 načina.
- Na slici su prikazani primeri kako se inicijalizuju promenljive tipa karakter u R-u.
- Koliko elemenata imaju *c1* i *c2*? Koja se funkcija koristi za računanje dužine niza?

Matrice

```
> dimnames(m2) <- list(c("red1", "red2", "red3", "red4"), c("kol1", "kol2", "kol3"))
>
```

- Korišćenjem operatora ":" kreirati niz brojeva $m1$ od 1 do 12 (sa korakom 1). R dokumentacija za ovaj operator se dobija za ?':
- Potom primenom funkcije *matrix()* kreirati matricu $m2$ od niza $m1$ sa 4 kolona i 3 reda.
 - Šta se desi ako se umesto sa 3 reda kreira matrica sa 5 redova?
- Proveriti šta funkcija *dimnames()* za matricu $m2$ daje na izlazu.
- Dodeliti nazive redova i kolona matrice $m2$ kao na slici.
- Prikazati implicitno i eksplicitno matricu.
- Proveriti šta daju funkcije *colnames()* i *rownames()* na izlazu za matrice $m1$ i $m2$.
- Ponoviti sve gore navedene zadatke za matricu koja ima elemente u obrnutom redosledu (*HINT*: 12:1).
- **Kako bi se napravio niz sa korakom 0.5?**

• • •

ispitanik	visina [cm]	težina [kg]
1	198	75
2	180	72
3	176	73
4	185	96
5	186	76

- Uneti u R-u matricu sa 3 kolone i 5 redova kao na slici. Tabela sadrži listu ispitanika i njihove podatke o visini i težini.
- Koristeći odgovarajuće funkcije uneti i nazive kolona kao na slici. Rezultujuću matricu prikazati u konzoli R-a.
- Lista ispitanika je preuzeta iz rada:
 - A. Gogić, N. Miljković, Đ. Đurđević. Electromyography-based gesture recognition: Fuzzy classification evaluation, *Proceedings of 3rd International Conference on Electrical, Electronic and Computing Engineering IcETRAN*, ISBN: 978-86-7466-618-0, pp. MEI1.6.1-4, Zlatibor, Serbia, June 13-16, 2016.

Liste

ispitanik	visina [cm]	težina [kg]	dominantna ruka	pol
1	198	75	R	M
2	180	72	R	M
3	176	73	L	F
4	185	96	L	M
5	186	76	R	M

- Na slici je prikazana kompletanija lista ispitanika iz rada:
 - A. Gogić, N. Miljković, Đ. Đurđević. Electromyography-based gesture recognition: Fuzzy classification evaluation, *Proceedings of 3rd International Conference on Electrical, Electronic and Computing Engineering IcETRAN*, ISBN: 978-86-7466-618-0, pp. MEI1.6.1-4, Zlatibor, Serbia, June 13-16, 2016.
- NAPOMENA: Značenje skraćenica u tabeli: R desno (od eng. *right*), L levo (od eng. *left*), M muški pol (od eng. *Male*) i F ženski pol (od eng. *Female*).
- Umesto matrice, kao u prethodnom primeru, kreirati listu */1*.
- Od podataka o polu ispitanika kreirati poseban niz karaktera *p1* i potom kreirati faktorsku promenljivu *p2*.
- Zašto je lista pogodnija od matrice za ovaj tip podataka?
- Koji tip podataka je potrebno odabrat i za podatke sa slike?

Redosled nivoa u *factor* promenljivoj

```
> f1
[1] jan feb mar apr maj jun jul avg sep okt nov dec
12 Levels: jan < feb < mar < apr < maj < jun < jul < avg < ... < dec
> |
```

- Redosled nivoa u faktorskoj promenljivoj je podrazumevano po abecednom redu, ali može se izmeniti sa argumentom *levels* unutar funkcije *factor()*.
- ZADATAK: Napraviti faktorsku promeljivu *f1* koja označava mesecu godini (koristiti prva tri slova za svaki mesec: jan, feb, mar, ...) tako da su nivoi raspoređeni prema redosledu meseci u godini.
- Očekivani rezultat je prikazan na slici.

```
> meseci
[1] "jan" "feb" "mar" "apr" "maj" "jun" "jul" "avg" "sep" "okt" "nov"
[12] "dec"
> f1 = factor(meseci, levels=c("jan", "feb", "mar", "apr", "maj", "jun", "jul",
+ , "avg", "sep", "okt", "nov", "dec"), ordered=TRUE)
> f1
[1] jan feb mar apr maj jun jul avg sep okt nov dec
12 Levels: jan < feb < mar < apr < maj < jun < jul < avg < ... < dec
> |
```

REŠENJE

NA i NaN vrednosti

težina
68
75
NA
73
92
NA
94
67

- Kreirati niz kao sa slike. **HINT:** koristiti *names()* i *c()* funkcije.
- Izračunati automatski koliko ima NA vrednosti u nizu.
- Pogledati kako se koristi funkcija *mean()*.
- Kolika je srednja vrednost težine ispitanika u ovoj studiji?
- Kako se koristi funkcija *mean()* ako se umesto NA upiše NaN?
- Ako su nedostajuće vrednosti, $niz[3] = 86$ i $niz[6] = 76$, koliko se promeni (u procentima) srednja vrednost težine svih ispitanika?
- DODATNO: Primenom *sd()* funkcije utvrditi da li se i koliko promeni i standardna devijacija na ovom uzorku.

NEDOSTAJUĆE VREDNOSTI

Data frame podaci

ispitanik	visina [cm]	težina [kg]	dominantna ruka	pol
1	198	75	R	M
2	180	72	R	M
3	176	73	L	F
4	185	96	L	M
5	186	76	R	M

- Za tabelu sa slike, umesto liste kao u prethodnom zadatku, kreirati *data frame d1*. Iskoristiti *class()* funkciju i proveriti kom tipu podataka pripada *d1*.
- Eksplisitno prikazati na ekranu sadržaj promenljive *d1*.
- Lista ispitanika je preuzeta iz rada:
 - A. Gogić, N. Miljković, Đ. Đurđević. Electromyography-based gesture recognition: Fuzzy classification evaluation, *Proceedings of 3rd International Conference on Electrical, Electronic and Computing Engineering IcETRAN*, ISBN: 978-86-7466-618-0, pp. MEI1.6.1-4, Zlatibor, Serbia, June 13-16, 2016.

Za kraj rada sa tipovima podataka

- Izlistati sve promenljive komandom *ls()*.
- Proveriti koje se promenljive nalaze u memoriji R sesije u kartici *Environment*.
- Dodatno, moguće je proveriti i fajlove u radnom direktorijumu komandama *dir()* i *list.files()*: proveriti R dokumentaciju za ove komande. **Argumenti bilo koje funkcije/komande iz R dokumentacije se mogu dobiti i primenom *args()* funkcije.**

Radni direktorijum

- Za učitavanje podataka iz fajlova, potrebno je da radni direktorijum R-a bude podešen tako da se fajl iz koga se čitaju podaci nalazi u tom radnom direktorijumu.
- Da bi se proverilo koji je aktivan radni direktorijum, moguće je ukucati komandu `getwd()` u kozoli. Moguće je i pogledati u *Files* kartici R Studio interfejsa.
- Radni direktorijum se podešava iz padajućeg menija *Session / Set Working Directory / Choose Directory ...* ili korišćenjem komande `setwd()`.

read.table() funkcija

```
> EMGsignali <- read.table("EMG.txt")
> head(EMGsignali)
  V1      V2  V3  V4  V5  V6  V7  V8  V9  V10  V11  V12  V13  V14  V15  V16
1 -0.060 -0.323  0  0  0  0  0  0  0  0  0  0  0  0  0  0
2 -0.060 -0.319  0  0  0  0  0  0  0  0  0  0  0  0  0  0
3 -0.097 -0.297  0  0  0  0  0  0  0  0  0  0  0  0  0  0
4 -0.129 -0.267  0  0  0  0  0  0  0  0  0  0  0  0  0  0
5 -0.130 -0.239  0  0  0  0  0  0  0  0  0  0  0  0  0  0
6 -0.130 -0.204  0  0  0  0  0  0  0  0  0  0  0  0  0  0
>
```

EMG - Notepad

```
File Edit Format View Help
# snimani su Pectoralis left i Pectoralis right mišići tokom sedenja.
# vidljivi su EKG artefakti.
# U prvoj koloni se nalazi signal sa desnog mišića, a u drugoj sa levog mišića.
# Pojačanje je tokom merenja podešeno na 1000 puta, a frekvencija odabiranja na 1000 odbiraka po sekundi.
# ostalih 14 kolona su prazne - nije bilo nikakvo merenog signala na njima.

-0.060 -0.323  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.060 -0.319  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.097 -0.297  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.129 -0.267  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.130 -0.239  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.130 -0.204  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000
-0.137 -0.192  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000  0.000

Ln 1, Col 1
```

- Potrebno je učitati podatke koji su snimljeni u tekstualni fajl pod nazivom "EMG.txt" i prikazati prvih vrsta učitanog data frame-a pomoću funkcije *head()*.
- Koji radni direktorijum je potrebno odabrati prilikom učitavanja ovih signala?
- Zašto nisu učitani komentari u promenljivu *EMGsignali*?

EMG signali – prikaz

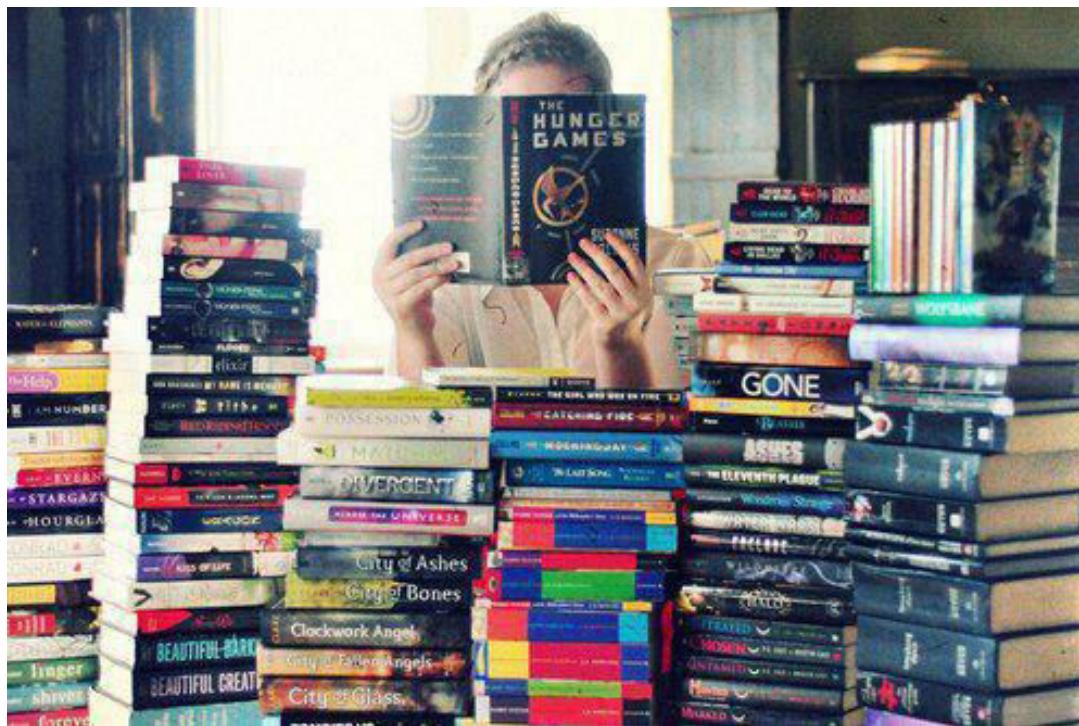
- Kog tipa je promenljiva *EMGsignali*?
- Korišćenjem funkcije *head()* prikazati prve 3 vrste promenljive *EMGsignali*?
- Korišćenjem funkcije *tail()* prikazati poslednje četiri vrste promenljive *EMGsignali*?
- Korišćenjem funkcije *tail()* prikazati poslednjih šest vrsta promenljive *EMGsignali*?



Slika: Parallel Jeny od Lee; Flickr [link](#); CC BY-SA 2.0

read.csv() funkcija

- U dokumentu "tabela.csv" (koji je dostupan na sajtu predmeta: <http://automatika.etf.rs/sr/13m051tobs> pod imenom *csv_tabela*), učitati podatke korišćenjem *read.csv()* funkcije.
- Osim naziva fajla koji se unosi kao ulazni parametar ove funkcije, koji parametar je još potrebno promeniti? **Obrazložiti**.
- Proveriti tip podataka promenljive u kojoj su učitani podaci.



Slika: books od analucia1701m; Flickr [link](#); CC BY-SA 2.0

Procena potrebne memorije

- Za podatke u fajlu “EMG.txt”, proveriti koliko je memorije M_{podaci} potrebno za smeštanje numeričkih podataka.
- Proveriti kolika je RA memorija M_{RAM} na računaru?
- Da li je ispunjen uslov $M_{podaci} < M_{RAM} / 2$?
- Šta će se desiti ako nije ispunjen ovaj uslov?

Modifikovana: Memories od David Hilditch Photography; Flickr <https://www.flickr.com/photos/22775126@N00/31222385170/>; CC BY-NC 2.0



Rešenje

- Podaci u fajlu “EMG.txt” imaju 39166 vrsta i 16 kolona numeričkih podataka.
- Otprilike, memorija koja je potrebna za smeštanje ove količine podataka je:
 - $39166 \times 16 \times 8 \text{ B/numeric} =$
 - $5013248 \text{ B} (\text{/ } 2^{20} \text{ MB}) =$
 - 4.781 MB -> uporediti ovu vrednost sa RAM-om računara (treba da bude manji od RAM/2 ...)

Funkcije i komande za danas

- vector()
- is.vector()
- c()
- as.*()
- length()
- class()
- is.na()
- print()
- ?':'
- matrix()
- dimnames()
- colnames()
- rownames()
- list()
- factors()
- factor()
- names()
- mean()
- sd()
- data.frame()
- ls()
- dir(), list.files()
- args()
- getwd()
- setwd()
- read.table()
- head()
- tail()
- read.csv()
- .Machine

Količina podataka u jedinicama i prefiksima

Multiples of bytes			V · T · E
Decimal		Binary	
Value	Metric	Value	IEC
1000	kB kilobyte	1024	KiB kibibyte
1000^2	MB megabyte	1024^2	MiB mebibyte
1000^3	GB gigabyte	1024^3	GiB gibibyte
1000^4	TB terabyte	1024^4	TiB tebibyte
1000^5	PB petabyte	1024^5	PiB pebibyte
1000^6	EB exabyte	1024^6	EiB exbibyte
1000^7	ZB zettabyte	1024^7	ZiB zebibyte
1000^8	YB yottabyte	1024^8	YiB yobibyte

<https://en.wikipedia.org/wiki/Mebibyte>



Do sledećeg časa ...

- Za domaći (opciono): Pokrenuti SWIRL i uraditi lekciju pod nazivom *Workspace and Files* (u ovom vežbanju postoje i elementi koji se ne rade na TOBS predmetu).
 - NAPOMENA: Pre pokretanja *swirl()* komande potrebno je učitati i biblioteku/paket komandom *library(swirl)*.

ZADATAK