Data mining and machine learning lab

25 ore (circa 19 effettive).

Lezioni:

23/03/18:	13:30 - 15,	15:15 - 16:45	aula Delta, via Mercalli 21(ent. Via S.Sofia)
06/04/18:	13:30 - 15,	15:15 - 16:45	
13/04/18:	13:30 - 15,	15:15 - 16:45	
20/04/18:	13:30 - 15,	15:15 - 16:45	
27/04/18:	13:30 - 15		
04/05/18:	13:30 - 15		
11/05/18:	13:30 - 15		
18/05/18:	13:30 -15	**15:15 – 16:00**	

Sito del corso :

http://frasca.di.unimi.it/MDSBF18/mdsbf18.html

Trovate:

Slide e materiale didattico di ogni lezione, collegamenti a manuali R, eventuali avvisi

Data mining and machine learning lab

Argomenti del corso:

Esercitazioni pratiche circa i contenuti dei corsi:

- Elements of computational statistics and statistical learning
- Machine learning and data mining

➢Useremo il linguaggio **R**

Ambiente R

- Software gratuito disponile al repository CRAN (Comprehensive R Archive Network)
  - Oltre all'ambiente R, fornisce documentazione e package R aggiornati
  - Disponibile per piattaforme UNIX, Windows and MacOS
- Linguaggio ad alto livello
- User-Friendly
- Disponibili numerosi package che implementano algoritmi in diversi ambiti: statistica, machine learning, bioinformatica, economia, medicina, etc.

Ambiente R

- Linguaggio interpretato
  - I comandi vengono eseguiti direttamente dall'interprete
  - Il codice non deve essere compilato
  - Carico aggiuntivo per la CPU (passaggio intermedio)
- Ottimo per l'elaborazione di dati statistici
  - Praticamente è tutto già implementato, nelle librerie base di R o in package installabili semplicemente con un comando (quasi sempre)
- Per avviare R:
  - Linux/Mac: digita '`R`' dalla linea di comando
  - Windows: apri R dalla GUI (Graphical User Interface)

Ambiente R

- Uscire da R
  - `q()`
- Chiedere aiuto ad R
  - `help()` # chiede l'help generale
  - `help(`*nomecomando*`)` # chiede l'help del comando
  - `?`*nomecomando* # chiede l'help del comando
  - `help.start()` # lancia l'help in un browser

Ambiente R

- `ls()` # mostra il contenuto del workspace
- `rm(i)` # rimuove dal workspace la variabile i
- `rm(list=ls())` # rimuove tutto (dati, funzioni) dal workspace
- `save(a, b ,file="prova.rda")` # salva le variabili *a* e *b* nel file binario compresso 'prova.rda'
- `load("prova.rda")` # ricarica nel workspace i dati salvati in precedenza
- `setwd(nome_directory)` # sposta il controllo di R nella directory specificata
- `getwd()` # visualizza la directory corrente

Strutture dati fondamentali in R: Vettori

- Nei linguaggi di programmazione ad alto livello non si ha accesso diretto alla memoria fisica, ma ad una sua astrazione (*struttura dati*)
- Prescinde dai dati realmente utilizzati
- Specifica come sono organizzati i dati e come accedervi

Vettori

- I vettori rappresentano sequenze di elementi omogenei accessibili direttamente mediante un indice
- Un vettore v è rappresentabile tramite una struttura unidimensionale:

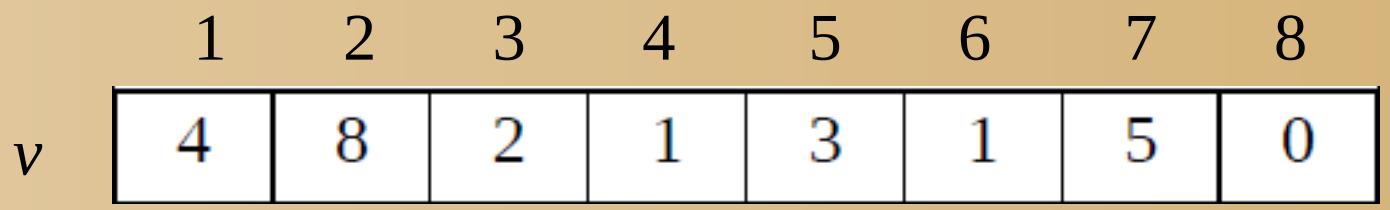

- Gli indici partono da 1. Ad es. 6 è l'indice dell'elemento 1

Tipi elementari di vettori

- Numerici: numeri interi o in virgola mobile (floating point)
- Caratteri: singoli caratteri o stringhe (sequenze) di caratteri
- Logici: `TRUE` o `FALSE`

Comando c

```
> c(1,4,5)                    # crea un vettore di interi
> c("A","B","C")              # crea un vettore di  caratteri
> c("gatto","topo", "12")     # crea un vettore di stringhe
```

La *funzione* `c(arg1, arg2, arg3, ...)` concatena i suoi argomenti

- Un vettore può essere *assegnato* ad una *variabile*

Variabili ed assegnamenti

```
> X <- c(1, 4, 5)          # il vettore <1 4 5> è assegnato alla variabile X
> X
[1] 1 4 5
```

La variabile X rappresenta ora il vettore <1 4 5>: si può pensare come un "contenitore" del vettore stesso

Un nuovo assegnamento cancella il contenuto precedente

```
> X <- c(4, 7)             # il vettore <4 7> è assegnato alla variabile X
> X
[1] 4 7
> Y <- 100                 # vettore formato da 1 solo elemento
> Y
[1] 100
```

Operazioni con vettori aritmetici

- Le operazioni usuali dell' aritmetica vengono eseguite sui vettori **elemento per elemento**:

Addizione e sottrazione

```
> x <- c(1,2,3)
> y <- c(4,5,6)
> z <- x + y
> z
[1] 5 7 9
> d <- y - x
> d
[1] 3 3 3
```

Moltiplicazione e divisione

```
> x <- c(1,2,3)
> y <- c(4,5,6)
> p <- x * y
> p
[1] 4 10 18
> q <- y / x
> q
[1] 4.0 2.5 2.0
```

Esempi di funzioni applicate a vettori numerici

```
> x <- c(1, 3, 2, 5)
> max(x)
[1] 5
> min(x)
[1] 1
> range(x)
[1] 1 5
> sum(x)
[1] 11
> prod(x)
[1] 30
```

```
> sort(x)  # ordinamento
[1] 1 2 4 5
> order(x)  # indici corrispondenti
            all'ordinamento
[1] 1 3 2 4
```

Generazione di sequenze regolari

- R dispone di diversi comandi per generare automaticamente sequenze di numeri:

```
> 1:7
[1] 1 2 3 4 5 6 7
> 5:1
[1] 5 4 3 2 1
> seq(1,7)
[1] 1 2 3 4 5 6 7
> seq(from=1,to=2.5,
      by=0.5)
[1] 1.0 1.5 2.0 2.5
```

- La funzione `seq()` può avere 5 argomenti (si veda l' help).
- Un'altra funzione per generare repliche di vettori è `rep()`:

```
> rep(c(1,2), times=4)
[1] 1 2 1 2 1 2 1 2
> rep(x,times) # ripete il vettore x, times volte
```

Vettori ed operatori logici

- Sono vettori i cui elementi possono assumere valore `TRUE` o `FALSE`
- Si ottengono dall'applicazione di operatori logici
  `<`, `<=`, `>`, `>=`, `==` (uguaglianza), `!=` (disuguaglianza)
- Possibile trasformarli in valori numerici mediante il comando **`as.numeric()`**

```
> as.numeric(FALSE)
[1] 0
> as.numeric(TRUE)
[1] 1
```

Vettori ed operatori logici

```
> x <- 3:8
> x > 5
[1] FALSE FALSE FALSE TRUE TRUE TRUE
> x <= 5
[1] TRUE TRUE TRUE FALSE FALSE FALSE
> x == 5
[1] FALSE FALSE TRUE FALSE FALSE FALSE
> x != 5
[1] TRUE TRUE FALSE TRUE TRUE TRUE
> x != c(5,6) # vale la “regola del riciclo”!
[1] TRUE TRUE FALSE FALSE TRUE TRUE
```

Vettori: selezione e accesso a sottoinsiemi di elementi

Esistono diverse modalità di accesso a singoli elementi o a sottoinsiemi di elementi di un vettore. In generale la selezione e l' accesso avviene tramite l' operatore [] (parentesi quadre) :

- sottoinsiemi di elementi di un vettore sono selezionati collegando al nome del vettore un vettore di indici in parentesi quadre. Esistono 4 diverse *modalità di selezione/accesso*:

1. Vettori di indici interi positivi
2. Vettore di indici interi negativi
3. Vettore di indici logici
4. Vettori di indici a caratteri

Selezione ed accesso tramite vettori di indici interi positivi

- Gli elementi di un vettore `x` sono selezionati tramite un vettore `y` di indici positivi racchiuso fra parentesi quadre: `x[y]`
- I corrispondenti elementi vengono selezionati.

```
> x <- 5:10
> x[1] # selezione di un singolo
       elemento
[1] 5
> x[5]
[1] 9
```

```
>length(x) # numero elementi nel vettore
[1] 6
> x[7] # accesso "fuori range"
[1] NA
> x[2:4]
[1] 6 7 8
> x[c(1,3,5)]
[1] 5 7 9
```

Selezione ed accesso tramite vettori di indici interi negativi

- Sono selezionati gli elementi di un vettore `x` che devono essere esclusi tramite un vettore *y* di indici negativi racchiuso fra parentesi quadre : `x[y]`

```
> y <- rep(c("G","A","T","T"), times=3)
> y
[1]"G" "A" "T" "T" "G" "A" "T" "T" "G" "A" "T" "T"
> z <- y[-(1:5)]   # selezionati tutti gli elementi di y
                     eccetto primi 5
> z
[1] "A" "T" "T" "G" "A" "T" "T"
>z<-z[-length(z)] # cancellazione dell' ultimo elemento di z
> z
[1] "A" "T" "T" "G" "A" "T"
```

Selezione ed accesso tramite vettori indice logici

- Il vettore degli indici deve essere della stessa lunghezza del vettore i cui elementi devono essere selezionati. Sono selezionati gli elementi corrispondenti a TRUE ed omessi gli altri

```
> x <- c(1:5,NA,NA); x
[1] 1 2 3 4 5 NA NA
>i<-c(rep(TRUE,times=3),rep(FALSE,times=4))
> i                 # i è il vettore indice logico
[1] TRUE TRUE TRUE FALSE FALSE FALSE FALSE
> x[i]  # selez. elementi tramite vett. indice logico
[1] 1 2 3
> x[!is.na(x)]# selezione elementi che non sono NA
[1] 1 2 3 4 5
> x[!is.na(x) & x > 2]
[1] 3 4 5
```

& AND logico
| OR logico
elemento per elemento

&& AND
|| OR
Apllicato a tutta l'espressione

Selezione ed accesso tramite vettori di indici a caratteri

- E’applicabile quando è stato impostato l'attributo *names* del vettore
- Associa una stringa ad ogni elemento
- Un sottovettore di *names* seleziona le componenti corrispondenti

```
> campione <- c(45, 180, 70, 2007, 3)
>names(campione)<-
c("Eta","Altezza","Peso","AnnoIns","Ricoveri")
> campione
     Eta    Altezza       Peso    AnnoIns    Ricoveri
      45     180           70       2007        3
> Eta.Anno <- campione[c("Eta","AnnoIns")]
> Eta.Anno
     Eta   AnnoIns
     45    2007
```

Comandi utili

- **sample**(x, n, replace=FALSE) *# estrae* n *elementi dal vettore* x *in maniera uniforme e senza reinserimento* ----> *n ≤ length(x).*
  - *Se replace=TRUE*, allora può accadere n > **length**(x)

```
> sample(1:6, 3)
[1] 4 1 3
> sample(1:6, 7) # errore!
> sample(1:6, 7, replace=TRUE)
[1] 6 3 6 1 1 5 3
```

- **floor**(x), **ceiling**(x), **trunc**(x), **round**(x, digits=3)
- **paste**("stringa1","stringa2",sep="-") # concatenazione di stringhe

```
[1] "stringa1-stringa2"
```

- **setdiff**(*vettore1, vettore2*) # differenza insiemistica, elementi in *vettore1* non in *vettore2*
- **which**(x == a); which(x > b) # indici che soddisfano la condizione

Esercizi

1) Usando la funzione **`runif(n)`**, che genera un vettore di lunghezza `n` di numeri uniformemente estratti in `[0,1]`, generare tre distinti vettori e

   a) Calcolare minimo e massimo del primo vettore

   b) Calcolare la somma degli elementi di ciascun vettore

   c) Calcolare la somma dei primi due vettori

   d) Calcolare la differenza dei tre vettori

   e) Calcolare il prodotto degli elementi del secondo vettore

   f) Concatenare i tre vettori ed estrarre due campioni casuali disgiunti (verificarlo con **`intersect`**`()`) pari al 30% degli elementi ciascuno

Esercizi

2) I seguenti dati rappresentano il numero di giorni in cui ciascuno di `20` lavoratori si è assentato per malattia nelle ultime sei settimane:

2, 2, 0, 0, 5, 8, 3, 4, 1, 0, 0, 7, 1, 7, 1, 5, 4, 0, 4, 0

- I codici dei lavoratori sono “Lav0”, “Lav1”, …, “Lav19”

Quindi

a) Creare un vettore contenente i giorni di malattia e nel campo *names* i corrispondenti codici

b) Selezionare il numero di giorni di malattia del lavoratore “Lav6”

c) Determinare quanti lavoratori hanno fatto `0` giorni di malattia e stamparne i codici

d) Estrarre il sottovettore contenente i giorni di malattia di tutti i lavoratori eccetto “Lav2” e “Lav11”

Usare il comando **`print`**`(x)` per stampare a video il valore della variabile `x`