Università degli Studi di Milano

Laurea Specialistica in Genomica Funzionale e Bioinformatica

Corso di Linguaggi di Programmazione per la Bioinformatica

Programmi e funzioni in R

Giorgio Valentini

e –mail: *valentini@dsi.unimi.it*

DSI – Dipartimento di Scienze dell' Informazione

Università degli Studi di Milano

Programmi in R

- Un *programma* in linguaggio R è costituito da una *sequenza* di *espressioni*.
- Ogni espressione viene valutata dall' interprete e se l' espressione è sintatticamente completa viene ritornato un valore
- Il valore ritornato può essere assegnato ad una variabile.

Esempi di espressioni:

```
> 3+2

[1] 5

> x <- 3+2

> 3+2- # istruz. non
 # completa

+
```

```
> data.frame(prot=c("P","Q","A"),x=1:3,y=4:6)
  prot x y
1    P 1 4
2    Q 2 5
3    A 3 6
> df <-
data.frame(prot=c("P","Q","A"),x=1:3,y=4:6)
```

Modo di esecuzione dei programmi

- I programmi (sequenze di espressioni) possono essere eseguiti :
  - *Interattivamente*: ogni istruzione viene eseguita direttamente al prompt dei comandi
  - *Non interattivamente*: le espressioni sono lette da un file (tramite la funzione *source*) ed eseguite dall' interprete una ad una in sequenza.
- A meno che i programmi non siano brevissimi è opportuno scrivere la sequenza delle espressioni in un file, utilizzando un text editor (ad esempio *EditPad Lite*, scaricabile gratuitamente da: http://www.EditPadLite.com)

Programmi e funzioni

- Abbiamo già visto molti esempi di funzioni disponibili in R
- Le funzioni in R possono anche definite dagli utenti
- I programmi in R sono realizzati tramite funzioni

Funzioni: sintassi

La sintassi per scrivere una funzione è:

`function (argomenti)  corpo_della_funzione`

- `function` è una parola chiave di R
- `Argomenti` è una lista eventualmente vuota di *argomenti formali* separati da virgole:
  `(arg1, arg2, ..., argN)`
- Un *argomento formale* può essere un simbolo o un'istruzione del tipo '`simbolo=espressione`'
- Il `corpo` può essere qualsiasi espressione valida in R. Spesso è costituito da un gruppo di espressioni racchiuso fra parentesi graffe

Esempi di funzioni (1)

Es.1: Definizione di una funzione di nome `echo`:

```
> echo <- function(x) print(x)
```

Chiamata della funzione `echo`:

```
> echo(6)
[1] 6
```

Es.2 Definizione di una funzione che somma i due suoi argomenti:

```
> sum2 <- function(x,y) x+y
```

argomenti formali

```
> sum2
function(x,y) x+y
```

Chiamata della funzione `sum2` :

argomenti attuali

```
> sum2(1,2)
[1] 3
```

Esempi di funzioni (2)

```
# Funzione per il calcolo della statistica di Golub
# x,y : vettori di cui si vuole calcolare la statistica di golub
# La funzione ritorna il valore della statistica di Golub
golub <- function(x,y)  {
  mx <- mean(x);
  my <- mean(y);
  vx <- sd(x);
  vy <- sd(y);
  g <- (mx-my)/(vx+vy);
  g
}
```

La sequenza di istruzioni del corpo della funzione deve essere racchiusa fra parentesi quadre

Esempi di funzioni (3)

Utilizzo della funzione di Golub:

- La funzione golub è memorizzata nel file “golub.R” (ma potrebbe essere memorizzata in un file con nome diverso)
- Caricamento in memoria della funzione. Due possibilità:

1. `> source("golub")`
2. Dal menu File/Source R code ...

- Chiamata della funzione:

```
> x<-runif(5) # primo argomento della funzione
> x
[1] 0.6826218 0.9587295 0.4718516 0.8284525 0.2080131
> y<-runif(5) # secondo argomento della funzione
> y
[1] 0.6966353 0.0964740 0.4310154 0.1467449 0.2801970
> golub(x,y) # chiamata della funzione
[1] 0.5553528
```

Argomenti delle funzioni

- Argomenti formali e argomenti attuali
- Gli argomenti sono passati per valore
- Modalità di assegnamento degli argomenti:
  - Assegnamento posizionale
  - Assegnamento per nome
- Valori di default per gli argomenti
- L' argomento ...
- Matching degli argomenti

Argomenti formali e attuali

x e y sono *argomenti formali*:

```
> golub <- function(x,y)  { ... }
```

Tali valori vengono sostituiti dagli *argomenti attuali* quando la funzione è chiamata:

```
> d1 <- runif(5)
> d2 <- runif(5)
```

`d1` e `d2` sono gli argomenti attuali che sostituiscono i formali e vengono effettivamente utilizzati all' interno della funzione:

```
> golub(d1,d2)
[1] 0.2218095
> d3 <- 1:5
> golub(d1,d3)
[1] -1.325527
```

Gli argomenti sono passati per valore

Le modifiche agli argomenti effettuate nel corpo delle funzioni non hanno effetto all' esterno delle funzioni stesse:

```
> fun1 <- function(x)  x <- x*2
> y<-4
> fun1(y)
> y
[1] 4
```

In altre parole i valori degli argomenti attuali sono modificabili all' interno della funzione stessa, ma non hanno alcun effetto sulla variabile dell' ambiente chiamante.

Nell' esempio precedente la copia di `x` locale alla funzione viene modificata, ma non viene modificato il valore della variabile `y` passata come argomento attuale alla funzione `fun1`

Modalità di assegnamento degli argomenti: assegnamento posizionale

Tramite questa modalità gli argomenti sono assegnati in base alla loro posizione nella lista degli argomenti:

```
> fun1 <- function (x, y, z, w) {}
> fun1(1,2,3,4)
```

L' argomento attuale 1 viene assegnato a *x*, 2 a *y*, 3 a *z* e 4 a *w*.

Altro esempio:

```
>  sub <- function (x, y) {x-y}
> sub(3,2) # x<-3 e y<-2
[1] 1
> sub(2,3) # x<-2 e y<-3
[1] -1
```

Modalità di assegnamento degli argomenti: assegnamento per nome

Tramite questa modalità gli argomenti sono assegnati in base alla loro nome nella lista degli argomenti:

```
> fun1 <- function (x, y, z, w) {}
> fun1(x=1, y=2, z=3, w=4)
```

L' argomento attuale 1 viene assegnato a *x*, 2 a *y*, 3 a *z* e 4 a *w*.

Quando gli argomenti sono assegnati per nome non è necessario rispettare l' ordine degli argomenti:

```
fun1(y=2, w=4, z=3, x=1) ≡ fun1(x=1, y=2, z=3, w=4)
```

Ad esempio:

```
>  sub <- function (x, y) {x-y}
> sub(x=3,y=2) # x<-3 e y<-2
[1] 1
> sub(y=2,x=3) # x<-3 e y<-2
[1] 1
```

Valori di default per gli argomenti

E' possibile stabilire valori predefiniti per tutti o per parte degli argomenti: tali valori vengono assunti dalle variabili a meno che non vengano esplicitamente modificati nella chiamata della funzione.

Esempio:


```
> fun4 <- function (x, y, z=2, w=1) {x+y+z+w}
> fun4(1,2) # x<-1, y<-2, z<-2, w<-1
[1] 6
> fun4(1,2,5) # x<-1, y<-2, z<-5, w<-1
[1] 9
> fun4(1) # y non ha valore di default !
Error in fun4(1) : Argument "y" is missing, with no
   default
```

L’ argomento ...

L’ argomento speciale ‘...’ rappresenta un numero arbitrario di argomenti: si può quindi usare per funzioni con un numero arbitrario di argomenti.

Esempio:

```
> fun2 <- function (x, ...)  {x + c(...)}
> fun2(1,2)
[1] 3
> fun2(1,4,5)
[1] 5 6
```

Si usa spesso per passare un numero variabile di argomenti ad altre funzioni chiamate nel corpo della funzione stessa.

Matching degli argomenti

Si consideri una semplice funzione che stampa i suoi 4 argomenti:

```
print4 <- function (x=4, y=3, z=2, w=1) {
  cat("x =",x,"\t");
  cat("y =",y,"\t");
  cat("z =",z,"\t");
  cat("w =",w,"\n");
}
```

Gli argomenti attuali possono essere assegnati in modi diversi:

```
> print4(5,6)
x = 5   y = 6   z = 2   w = 1
> print4(y=6,5)
x = 5   y = 6   z = 2   w = 1
> print4(y=6,x=5,w=9)
x = 5   y = 6   z = 2   w = 9
> print4()
x = 4   y = 3   z = 2   w = 1
```

```
> print4(z=0)
x = 4   y = 3   z = 0   w = 1
> print4(1,2,3,4)
x = 1   y = 2   z = 3   w = 4
> print4(1,w=2,3,x=0)
x = 0   y = 1   z = 3   w = 2
> print4(1,2,3,4)
x = 1   y = 2   z = 3   w = 4
```

Scope

- Le regole di scope sono l' insieme delle regole mediante cui un valore viene associato ad un simbolo.
- Dal punto di vista delle regole di scope i simboli presenti nel corpo di una funzione possono essere suddivisi in 3 classi:
  1. Parametri formali
  2. Variabili locali
  3. Variabili libere

Parametri formali

Sono i parametri della lista degli argomenti presenti nella definizione della funzione:

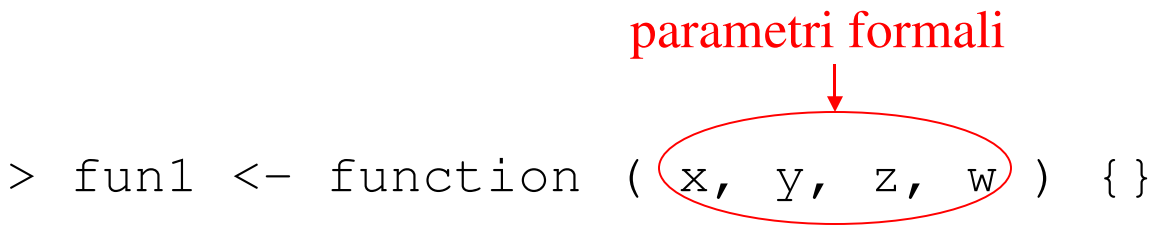

I loro valori sono determinati dal processo di *binding* degli argomenti attuali della funzioni ai rispettivi parametri formali:

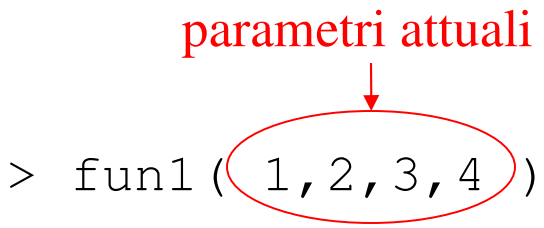

I valori dei parametri attuali sono legati ai rispettivi parametri formali:

```
x<-1, y<-2, z<-3, w<-4
```

Variabili locali

Le variabili locali *sono definite dalla valutazione di espressioni nel corpo di una funzione* ed hanno visibilità solo all' inteno della funzione stessa:

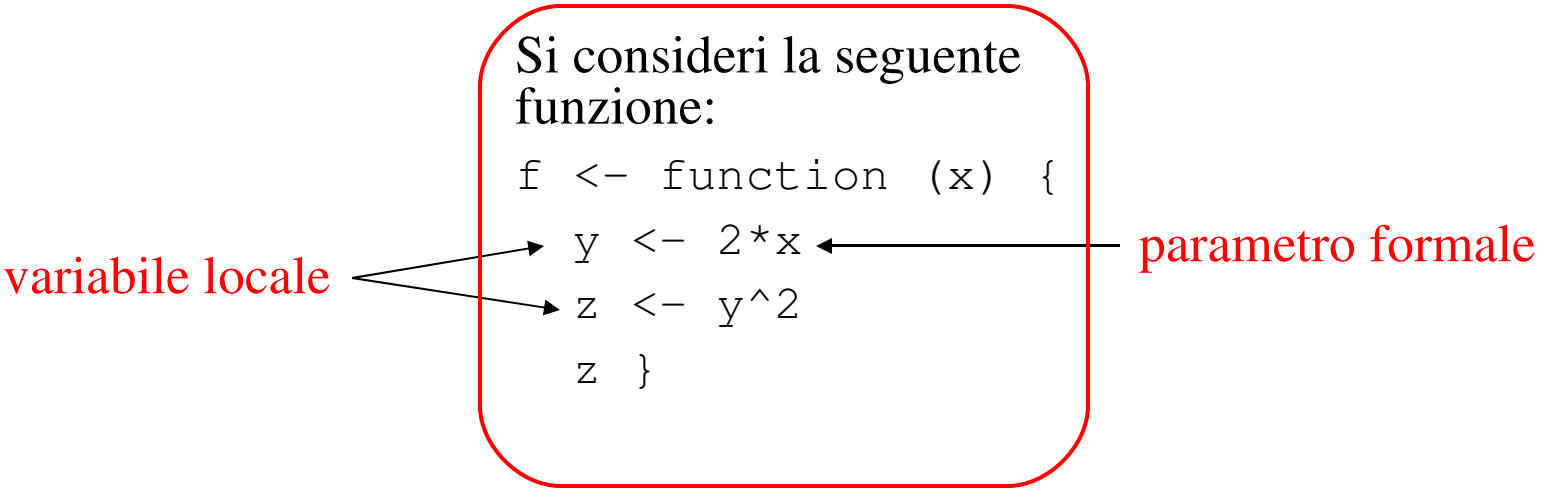


```
> f(3)
[1] 36
> y
Error: Object "y" not found
> z
Error: Object "z" not found
```

Variabili libere

Le variabili che non sono nè parametri formali e nè variabili locali sono chiamate variabili libere.
Il binding delle variabili libere viene risolto cercando la variabile nell' ambiente in cui la funzione è stata creata:

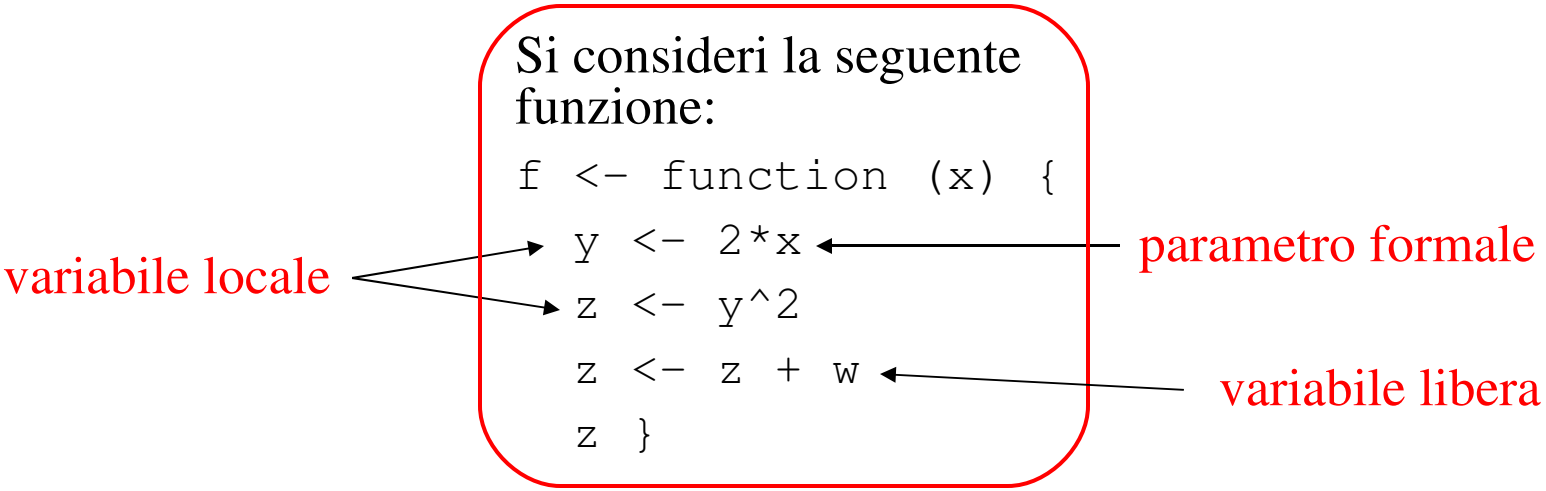


```
> f(3)
Error in f(3) : Object "w" not found
> W <- 3
> f(3)
[1] 39
```

L'operatore di "superassegnamento"

- Il passaggio dei parametri alle funzioni avviene per valore.
- Tramite l' operatore di superassegnamento '<<-' è però possibile modificare il valore della variabile nell' ambiente di livello superiore.
- N.B. Non si tratta di un passaggio di argomenti "by reference"

```
f <- function (x)
{
  y <- x/2;
  z <- y^2;
  x <<- z-1;
}
```

superassegnamento →

Quando la funzione `f` viene chiamata il valore della variabile `x` viene modificato:

```
> x=1; f(x)
> x
[1] -0.75
```

Se la variabile `x` non viene trovata nell' ambiente top-level, `x` viene creata e le viene assegnato il valore calcolato dalla funzione:

```
> rm(x); f(1)
> x
[1] -0.75
```

Programmazione modulare

Le funzioni R possono richiamare altre funzioni, permettendo in tal modo di strutturare i programmi in modo “gerarchico”:

```
# funzioni di "secondo livello" chiamate dalla funzioni
# P1 e P2

S1 <- function (x) {... }

S2 <- function () {... }


# funzioni di primo livello" chiamate dalla funzione
# principale

P1 <- function (x) { S1(x); ... }

P2 <- function (x) { S2(); S1(x); ... }


# funzione principale del programma R

MainProgram <- function(x,y,z) {P1(x); P2(y); P1(z) ... }
```

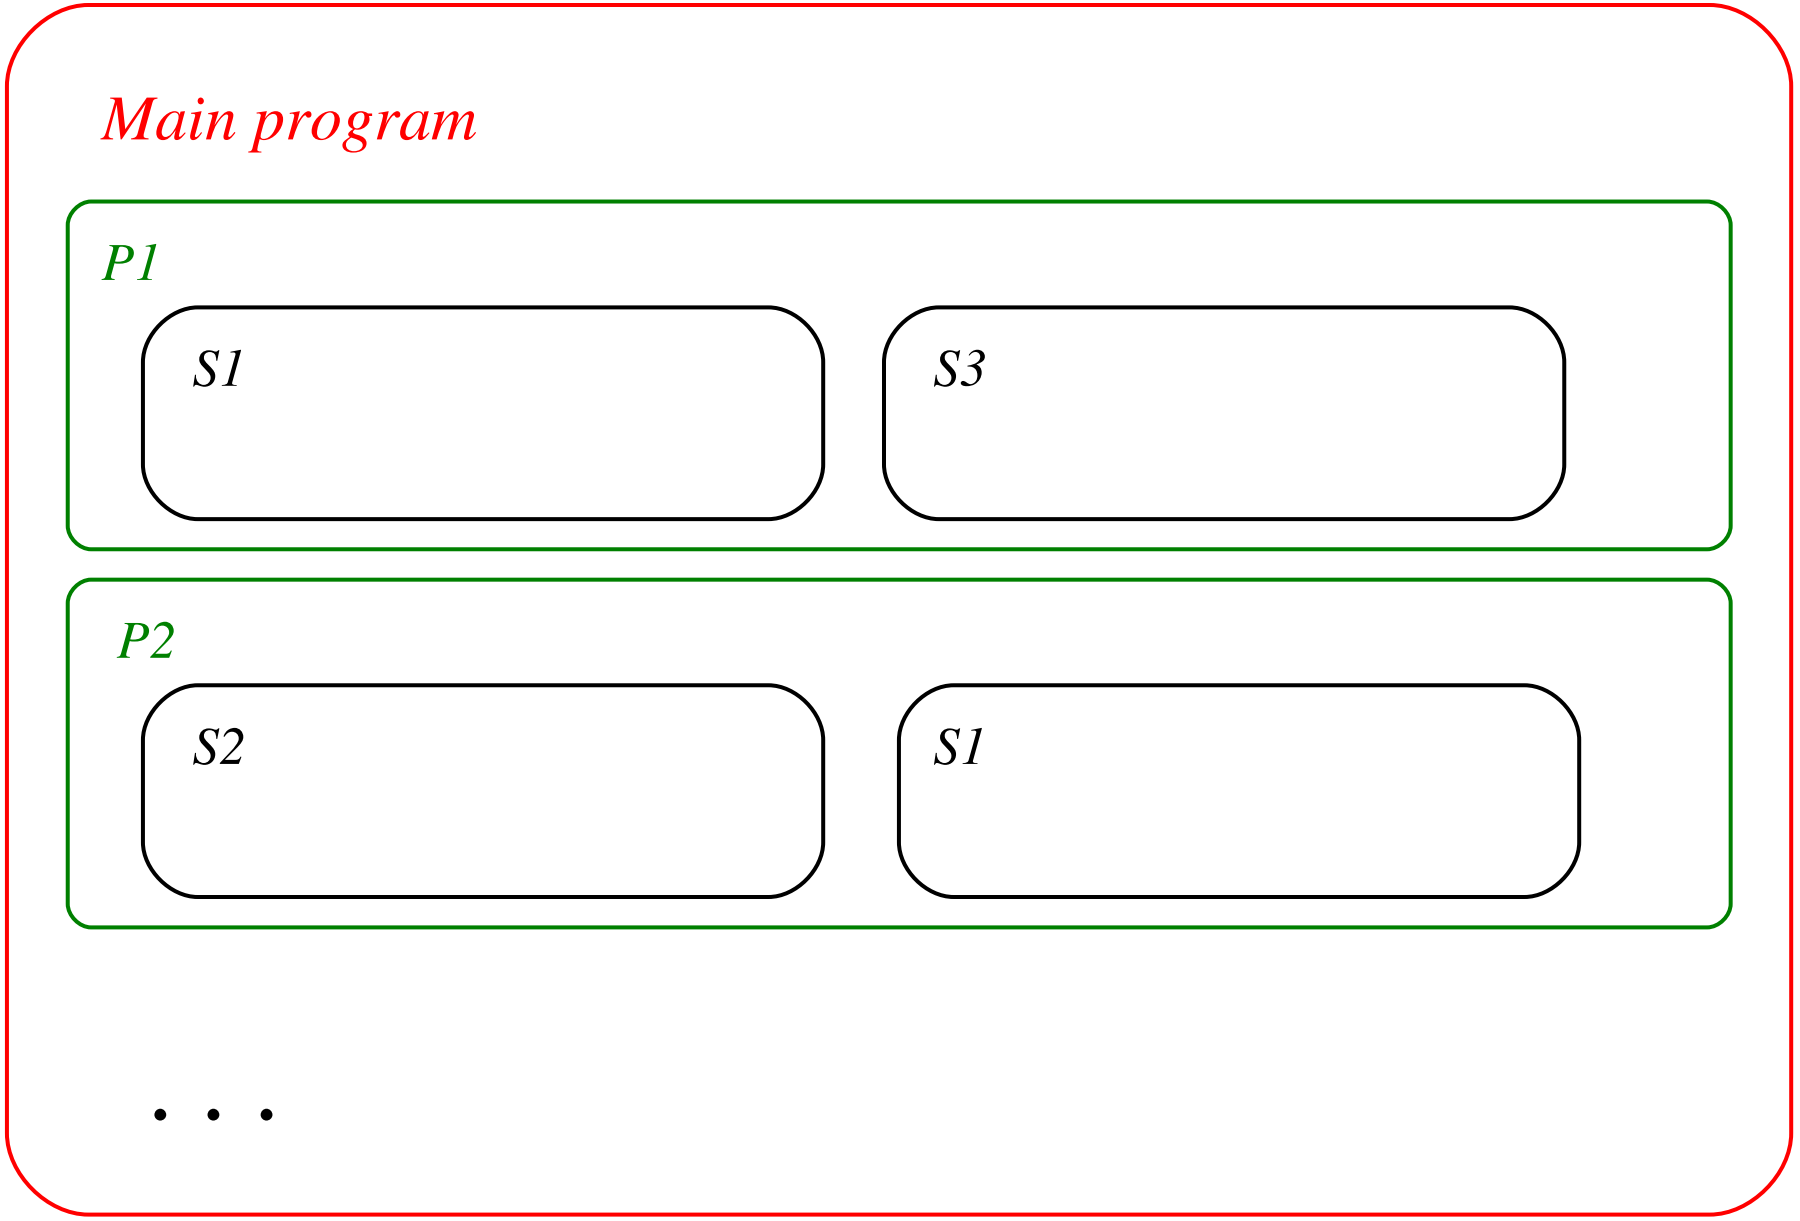
Main program
P1
S1
S3
P2
S2
S1
. . .

Programmazione top-down

- La programmazione modulare consente di affrontare i problemi “dall’ alto al basso” (approccio *top-down*), cercando cioè di partire dal problema principale definito come una funzione (MainProgram nell’ esempio precedente) con determinati ingressi (dati del problema che si vuole risolvere) ed uscite (risposte/soluzioni al problema)
- Dal problema principale si cerca poi di individuare un insieme di sottoproblemi tramite cui sia possibile risolvere il problema principale; i sottoproblemi sono risolti tramite le funzioni P1 e P2.
- A loro volta i sottoproblemi P1 e P2 si possono essere scomposti in sotto-sottoproblemi (implementati tramite le funzioni S1, S2, S3)
- Il processo di scompozione dei problemi “dall’ alto al basso” può proseguire ancora o arrestarsi a seconda della tipologia del problema.
- In generale tale approccio non è lineare, ma richiede raffinamenti successivi
- R consente anche altri tipi di approcci al design del software (ad es: approccio bottom-up, object-oriented)

Esercizi (I)

- Scrivere una funzione *compute.mean.var* che, avendo come argomento una lista di vettori numerici, calcoli la media e la varianza per ciascun elemento della lista.
- Scrivere una funzione find.stop.codon che, ricevuto come argomento un vettore di “triplette” del codice genetico ritorni un messaggio “codon di stop trovato” o “codon di stop non trovato” a seconda che una delle triplette “UAA”, “UAG” o “UGA” sia presente o meno nel vettore di ingresso.
- Scrivere una funzione find.codon che, ricevuto in ingresso un vettore di “triplette” del codice genetico ed una tripletta codon arbitraria, stampi sullo schermo un messaggio di codon trovato e la sua posizione, o un messaggio di codon non trovato.
  In caso pero’ incontri prima un codon di stop deve stampare un messaggio di stop codon trovato, la sua posizione e terminare.

Esercizi (II)

- Scrivere una funzione *analyze_string* che ricevuto in ingresso una stringa arbitraria calcoli la frequenza dei simboli componenti la stringa stessa
- Scrivere una funzione che calcoli i numeri di Fibonacci
- Scrivere un programma *analyze* che calcoli alcune semplici statistiche relative a 5 diverse tipologie di analisi. In particolare analyze deve:
  1. Leggere da un file una matrice con un numero arbitrario di righe (ogni riga rappresenta un campione) e con 5 colonne che rappresentano dati numerici relativi a 5 diverse analisi.
  2. Trasformi la matrice in un data frame con variabili var1,var2,...,var5.
  3. Memorizzi il data frame in un file
  4. Per ogni variabile calcoli media, deviazione standard.
  5. Stampi sullo schermo i valori relativi a media e deviazione standard per ogni variabile
- Scrivere una funzione *CalcCovCor* che calcoli le matrici di covarianza e di correlazione fra *n* variabili i cui valori siano generati casualmente. La funzione deve permettere di specificare il numero delle realizzazioni (campioni) generati casualmente ed il tipo di generazione (secondo la distribuzione uniforme o gaussiana). Le matrici vanno poi memorizzate in 2 diversi file (i cui nomi devono essere specificati dall' utente).