

Introduzione alla linea di comando e ai dati di sequenziamento

Fabrizio Mafessoni – Genomica Computazionale, Università di Trieste, Laurea Specialistica di Genomica Funzionale 2025/205


```
I hate programming  
I hate programming  
I hate programming  
    It works!  
I love programming
```



LINUX

Oggi

- Comandi di base della linea di comando
- Formato delle sequenze di DNA dal sequenziatore
- Comandi utili per manipolazione sequenze
- Scriveremo il primo programma complesso/utile



echo

stampa sullo schermo (standard output)

```
~$ echo Ciao Trieste  
Ciao Trieste  
~$ echo "Ciao Trieste"  
Ciao Trieste
```

Definizione di variabili

possiamo assegnare uno specifico valore ad una variabile. Per “richiamare” il valore della variabile, usiamo \$NOME_DELLA_VARIABLEE o \${NOME_DELLA_VARIABLEE}

```
~$ YOURNAME=Fabrizio
~$ echo YOURNAME
YOURNAME
~$ echo $YOURNAME
Fabrizio
~$ echo ${YOURNAME}
Fabrizio
```

Definizione di variabili

possiamo assegnare uno specifico valore ad una variabile. Per “richiamare” il valore della variabile, usiamo \$NOME_DELLA_VARIABLEE

```
~$ YOURNAME=Fabrizio
~$ echo YOURNAME
YOURNAME
~$ echo $YOURNAME
Fabrizio
~$ echo ${YOURNAME}
Fabrizio
```

Per evitare errori, spesso è utile usare le parentesi graffe
`${NOME_DELLA_VARIABLEE}`

```
~$ echo ${YOURNAME}_${YOURNAME}
Fabrizio_Fabrizio
~$ echo $YOURNAME_$YOURNAME
Fabrizio
```

whoami

stampa lo usernameb

```
~$ whoami  
fabrizio
```

whoami

stampa lo username

```
~$ whoami  
fabrizio
```

\$(comando)

esegue il comando, così che possiamo assegnare il suo output ad una variabile

```
~$ YOURUSERNAME=$( whoami )  
~$ echo $YOURUSERNAME  
fabrizio
```

NB: \${VARIABILE} è diverso da \$(COMANDO) !!

date

data di oggi

```
~$ date  
Thu Sep 25 02:32:50 CEST 2025
```

date

data di oggi

```
~$ date  
Thu Sep 25 02:32:50 CEST 2025
```

pwd

cartella in cui vi trovate

```
~$ pwd  
/home/fabrizio
```

Possiamo come prima assegnarla ad una variabile

```
~$ CURRENTFOLDER=$( pwd )  
~$ echo $CURRENTFOLDER  
/home/fabrizio
```

>

redirige l'output verso un file

```
~$ echo $YOURNAME > testfile.txt  
~$
```

ls

elenca file nella cartella

```
~$ ls -lh testfile.txt  
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 02:37 testfile.txt
```

cat

stampa e concatena contenuto di un file

```
~$ cat testfile.txt  
Fabrizio  
~$ cat testfile.txt testfile.txt  
Fabrizio  
Fabrizio  
~$ echo LucioCorsi > testfile.txt  
~$ cat testfile.txt  
LucioCorsi
```

cat

stampa e concatena contenuto di un file

>>

redirige l'output verso un file appendendolo alla fine, e non sovrascrivendo come >

```
~$ cat testfile.txt
Fabrizio
~$ cat testfile.txt testfile.txt
Fabrizio
Fabrizio
~$ echo LucioCorsi > testfile.txt
~$ cat testfile.txt
LucioCorsi
~$ echo $YOURNAME > testfile.txt
~$ echo LucioCorsi >> testfile.txt
~$ cat testfile.txt
Fabrizio
LucioCorsi
```

rm

cancella un file

rm -r

cancella una cartella

```
~$ ls testfile.txt
testfile.txt
~$ rm testfile.txt
~$ ls testfile.txt
ls: cannot access 'testfile.txt': No such file or directory
```

```
~$ mkdir GenomicaComputazionale
~$ ls GenomicaComputazionale/
~$ rm -r GenomicaComputazionale
~$ ls GenomicaComputazionale/
ls: cannot access 'GenomicaComputazionale/': No such file or directory
```

cd

permette di cambiare cartella

. cartella attuale

.. Cartella madre/precedente

../.. Due cartelle precedenti

Notare la differenza tra path relativi e assoluti (preceduti da /).

```
~$ pwd
/home/fabrizio
~$ echo $HOME
/home/fabrizio
~$ mkdir GenomicaComputazionale
~$ cd GenomicaComputazionale
~/GenomicaComputazionale$ pwd
/home/fabrizio/GenomicaComputazionale
~/GenomicaComputazionale$ cd .
~/GenomicaComputazionale$ pwd
/home/fabrizio/GenomicaComputazionale
~/GenomicaComputazionale$ cd ..
~$ pwd
/home/fabrizio
~$ cd ../../
/$ pwd
/
/$ ls
bin          boot  etc  init  lib.usr-is-merged  lost+found  mnt  proc  run  sbinsusr-is-merged  srv  tmp  var
bin.usr-is-merged  dev  home  lib  lib64              media       opt  root  sbin  snap                sys  usr
```

cd

permette di cambiare cartella

. cartella attuale

.. Cartella madre/precedente

../.. Due cartelle precedenti

Notare la differenza tra path relativi e assoluti (preceduti da /).

```
~$ pwd
/home/fabrizio
~$ echo $HOME
/home/fabrizio
~$ mkdir GenomicaComputazionale
~$ cd GenomicaComputazionale
~/GenomicaComputazionale$ pwd
/home/fabrizio/GenomicaComputazionale
~/GenomicaComputazionale$ cd .
~/GenomicaComputazionale$ pwd
/home/fabrizio/GenomicaComputazionale
~/GenomicaComputazionale$ cd ..
~$ pwd
/home/fabrizio
~$ cd ../../
/$ pwd
/
/$ ls
bin          boot  etc  init  lib.usr-is-merged  lost+found  mnt  proc  run  sbin.usr-is-merged  srv  tmp  var
bin.usr-is-merged  dev  home  lib  lib64              media       opt  root  sbin  snap                sys  usr
/$ cd /home/fabrizio/GenomicaComputazionale/
~/GenomicaComputazionale$ pwd
/home/fabrizio/GenomicaComputazionale
~/GenomicaComputazionale$
```

cd ~

è come

cd \$HOME

o semplicemente

cd

```
~/GenomicaComputazionale$ cd ~  
~$ cd GenomicaComputazionale  
mkdir Esercitazione1  
~/GenomicaComputazionale$ cd Esercitazione1  
~/GenomicaComputazionale/Esercitazione1$ echo "Questa cartella contiene l'esercitazione sulla basi di linux fatta il $( date )" > README.txt
```

history

elenca la storia dei comandi.

Utilissimo per creare dei log o semplicemente ricordarci cosa abbiamo fatto.

```
~/GenomicaComputazionale/Esercitazione1$ history >> README.txt
~/GenomicaComputazionale/Esercitazione1$ head README.txt
Questa cartella contiene l'esercitazione sulla basi di linux fatta il Thu Sep 25 02:55:21 CEST 2025
1321  ls -lht .. / | head
1322  vim README_Barack
1323  ls pca_results.eigenvec
1324  less pca_results.eigenvec
1325  vim README_Barack
1326  mkdir results_barack_20250618
1327  vim README_Barack
1328  for phenotype in "gws" "leafarea" "quantomyield" "chlorophyllcontent" "stemheight" "dryweight" "grade"
; plink --bfile GWAS/chra11 --pheno ../phenotype_${phenotype}_20250618.txt --pheno-name $phenotype --linear --a
genvec --covar-number 1-5 --out results_barack_20250618/resPCA_${phenotype}; done
1329  vim README_Barack
```

history

elenca la storia dei comandi.

Utilissimo per creare dei log o semplicemente ricordarci cosa abbiamo fatto.

NB: creare dei README è bellissimo

```
~/GenomicaComputazionale/Esercitazione1$ history >> README.txt
~/GenomicaComputazionale/Esercitazione1$ head README.txt
Questa cartella contiene l'esercitazione sulla basi di linux fatta il Thu Sep 25 02:55:21 CES
1321  ls -lht .. / | head
1322  vim README_Barack
1323  ls pca_results.eigenvec
1324  less pca_results.eigenvec
1325  vim README_Barack
1326  mkdir results_barack_20250618
1327  vim README_Barack
1328  for phenotype in "gws" "leafarea" "quantomyield" "chlorophyllcontent" "stemheight" "dryweight" "grade"
; plink --bfile GWAS/chrall --pheno ../phenotype_${phenotype}_20250618.txt --pheno-name $phenotype --linear --
genvec --covar-number 1-5 --out results_barack_20250618/resPCA_${phenotype}; done
1329  vim README_Barack
```

10
Organizing tips
Marie kondo
says you **must** do!



head e tail

permettono di esplorare l'inizio e la fine dei files

```
~/GenomicaComputazionale/Esercitazione1$ head -3 README.txt
Questa cartella contiene l'esercitazione sulla basi di linux fatta il Thu Sep 25 02:55:21 CEST 2025
1321 ls -lht .. / | head
1322 vim README_Barack
~/GenomicaComputazionale/Esercitazione1$ tail -3 README.txt
2318 echo "Questa cartella contiene l'esercitazione sulla basi di linux fatta il $( date )" > README.txt
2319* history
2320 history >> README.txt
```

WC

conto di righe, parole e caratteri

```
~/GenomicaComputazionale/Esercitazione1$ wc -l README.txt
1001 README.txt
~/GenomicaComputazionale/Esercitazione1$ wc -w README.txt
5118 README.txt
~/GenomicaComputazionale/Esercitazione1$ wc -c README.txt
49987 README.txt
```

Il simbolo * indica «qualsiasi carattere» ed è utilissimo per guardare a piu' file insieme

```
~/GenomicaComputazionale/Esercitazione1$ echo $YOURNAME > testfile.txt
~/GenomicaComputazionale/Esercitazione1$ ls -lh testfile.txt
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
~/GenomicaComputazionale/Esercitazione1$ ls -lh
total 56K
-rw-r--r-- 1 fabrizio fabrizio 49K Sep 25 02:57 README.txt
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
~/GenomicaComputazionale/Esercitazione1$ ls -lh *
-rw-r--r-- 1 fabrizio fabrizio 49K Sep 25 02:57 README.txt
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
~/GenomicaComputazionale/Esercitazione1$ ls -lh *.sh
ls: cannot access '*.sh': No such file or directory
~/GenomicaComputazionale/Esercitazione1$ ls -lh *.txt
-rw-r--r-- 1 fabrizio fabrizio 49K Sep 25 02:57 README.txt
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
~/GenomicaComputazionale/Esercitazione1$ ls -lh te*txt
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
~/GenomicaComputazionale/Esercitazione1$ wc -l *
1001 README.txt
1 testfile.txt
1002 total
~/GenomicaComputazionale/Esercitazione1$ ls -lht *
-rw-r--r-- 1 fabrizio fabrizio 9 Sep 25 03:04 testfile.txt
-rw-r--r-- 1 fabrizio fabrizio 49K Sep 25 02:57 README.txt
~/GenomicaComputazionale/Esercitazione1$ cat *
```

Comandi utili per la bioinformatica



Comandi utili per la bioinformatica



grep

pipe |

just a fancy **grep**



grep PAROLA

trattiene tutte le righe con PAROLA

(o le esclude se con -v)

```
~$ grep date README.txt
1966  sudo apt update && sudo apt -y upgrade
1983  date
2271  date
2318  echo "Questa cartella contiene l'esercitazione sulla basi di linux fatta il $( date )" > README.txt
```

provate anche:

```
grep -v cd README.txt
```

```
grep . README.txt
```

```
grep "\." README.txt
```

Notate come per i caratteri speciali come il punto “.” sia necessario usare la backslash \ per evadere la loro funzione speciale e vederli come un semplice carattere (qui punto).

|
il simbolo «stanghetta» o «pipe»
comando1 | comando2
redirige l'output di comando1 come input per comando2

il simbolo «stanghetta» o «pipe»

comando1 | comando2

redirige l'output di comando1 come input per comando2

```
~$ echo "Olly" > sanremo.txt
echo "Lucio Corsi" >> sanremo.txt
echo "Fedez" >> sanremo.txt
echo "Brunori Sas" >> sanremo.txt
~$ cat sanremo.txt
Olly
Lucio Corsi
Fedez
Brunori Sas
~$ cat sanremo.txt | grep u
Lucio Corsi
Brunori Sas
~$ cat sanremo.txt | grep u | grep L
Lucio Corsi
```



il simbolo «stanghetta» o «pipe»

comando1 | comando2

redirige l'output di comando1 come input per comando2

```
~$ echo "Olly" > sanremo.txt
echo "Lucio Corsi" >> sanremo.txt
echo "Fedez" >> sanremo.txt
echo "Brunori Sas" >> sanremo.txt
~$ cat sanremo.txt
Olly
Lucio Corsi
Fedez
Brunori Sas
~$ cat sanremo.txt | grep u
Lucio Corsi
Brunori Sas
~$ cat sanremo.txt | grep u | grep L
Lucio Corsi
```

```
~$ cat sanremo.txt | grep -v Fedez
Olly
Lucio Corsi
Brunori Sas
```



Se non siete fan di Sanremo (o se volete vedere utilizzi piu' utili)

```
~$ history | grep install
1969  sudo apt -y install build-essential
1970  sudo apt -y install git curl wget ca-certificates nano
1971  sudo apt -y install vim less unzip tar
1972  sudo apt -y install grep gawk sed coreutils diffutils
1973  sudo apt -y install samtools bcftools bedtools tabix
1974  sudo apt -y install fastqc bwa
2350  history | grep install
```

La vostra prima «pipeline»

pipeline: serie di comandi eseguiti uno dopo l'altro in cui l'output del primo diventa l'input del secondo «senza file temporanei»

```
~$ wc -l README.txt
```

```
1001 README.txt
```

```
~$ cat README.txt | wc -l
```

```
1001
```

```
~$ cat README.txt | grep cd | wc -l
```

```
98
```

```
~$ cat README.txt | grep -v cd | grep = | wc -l
```


```
84
```

Scopo ultimo del corso: saper partire da sequenze di DNA fino ad assemblare interi genomi e caratterizzarli funzionalmente

Dal sequenziatore..

..al genoma..

..alla funzione



Formati di file bioinformatici

.fastq

.fasta, .bam, .vcf

.bed, .gff

wget

scarica files dal web

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences1.fastq
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences2.fastq
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences3.fastq
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences4.fastq
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences5.fastq
```

Uso dell'* per nomi di files.

`ls -lt` ordina i file dal piu recente al piu vecchio

```
~$ ls *fastq
sequences1.fastq sequences2.fastq sequences3.fastq sequences4.fastq sequences5.fastq
~$ ls -lth | head
total 2.1G
-rw-r--r--  1 fabrizio fabrizio   35 Sep 25 07:56 sanremo.txt
-rw-r--r--  1 fabrizio fabrizio  47K Sep 25 07:43 README.txt
drwxr-xr-x  3 fabrizio fabrizio  4.0K Sep 25 02:54 GenomicaComputazionale
drwxr-xr-x  2 fabrizio fabrizio  4.0K Sep 25 02:36 empty
-rwxr-xr-x  1 fabrizio fabrizio   613 Sep 25 01:46 create_report_sequences.sh
-rw-r--r--  1 fabrizio fabrizio   575 Sep 25 01:45 report.txt
-rw-r--r--  1 fabrizio fabrizio   162 Sep 25 00:56 adaptors.txt
-rw-r--r--  1 fabrizio fabrizio  25K Sep 25 00:56 sequences.txt
-rw-r--r--  1 fabrizio fabrizio  10K Sep 25 00:56 readnames.txt
```

Le sequenze di DNA: il formato fastq

```
~$ head sequences1.fastq
@A00619:220:HYK7GDRX3:1:2101:13440:1000 1:N:0:ACTATAGA+TGCATACC
NCCCGTGAGATGATGCGCGTCATCCTCAACAAGGCCAAATCTGACCCCAAGCGACTCGTTCTCGCTGAGATCGGAAGAGCACACGTCTGAACTCCAGTCAC
+
#FFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFF
@A00619:220:HYK7GDRX3:1:2101:18629:1000 1:N:0:ACTATAGA+TGCATACC
NGCTGTGGACTCCACCCGAGTTCCGGATCGAACTGGTGAAGTTATCCAGCAGCTCTCGGTCGATCCCCGGGAAGTCTCCCAACACCACTGTTGGAAGACT
+
#FFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFF
@A00619:220:HYK7GDRX3:1:2101:20745:1000 1:N:0:ACTATAGA+TGCATACC
NGGATATCAATCAACTCCACGCAACTCCAACCTCCCTCAGATCGGAAGAGCACACGTCTGAACTCCAGTCACACTATAGAATCTCGGTTTGCGTCTTATG
```

- Riga1: @ riga con il nome della sequenza. Spesso (non obbligatoriamente) informazioni sul sequenziamento
- Riga2: Sequenza ACGT
- Riga3: +, un semplice separatore
- Riga4: Qualità delle sequenze

Riga 1: nome ed esempio di informazioni sulla sequenza

• @A00619:220:HYK7GDRX3:1:2101:13440:1000 1:N:0:ACTATAGA+TGCATACC

• A00619 → instrument ID

• 220 → run number

• HYK7GDRX3 → flowcell ID

• 1 → lane

• 2101 → tile

• 13440:1000 → x:y coordinates of the cluster -> **lo rende unico!!**


• Dopo lo spazio → **informazioni sulla read** (qui *Illumina CASAVA format*):

• 1 → tipo di read (1 = forward read; 2 = reverse read in paired-end sequencing)

• N → filtro (Y = filtro fallito, N = filtro passato)


• 0 → reads di controllo (0 = non una read di controllo)

• ACTATAGA+TGCATACC → sequenze di index/barcode (i7 + i5 adapters) usate per il demultiplexing (quando piu' campioni in uno stesso sequenziamento; ogni campione ha dei barcode diversi).



Riga2

- ACGGGAGGT.....



Riga 4

$$\text{NCCCGTGAGATGATGCGCGTCATCCTCAACAAGGCCAAATCTGACCCCAAGCGACTCGTTCTCGCTGAGATCGGAAGAGCACACGTCTGAACTCCAGTCAC}$$
[illegible]

Qualità codificata come ASCII **Phred+33** → character → Q score → probabilità di errore.

N all'inizio → base **not confidently called** (incerta, “può essere qualsiasi cosa”).

Esempi:

→ ASCII 35 → Q=2 → ~63% accuratezza (bassa, in pratica inutile).

F → ASCII 70 → Q=37 → error probability ≈ 0.0002 (~1 errore in 5000 basi, molto alta).

: $\rightarrow$ ASCII 58 $\rightarrow$ Q=25 $\rightarrow$ errore ≈ 0.003 (~ 1 in 316 basi).

sed

`sed "s/OLD/NEW/"` sostituisce il pattern OLD con NEW

sed

`sed "s/OLD/NEW/"` sostituisce il pattern OLD con NEW

- ESERCIZIO: Creiamo una lista dei nomi delle sequenze

sed

`sed "s/OLD/NEW/"` sostituisce il pattern OLD con NEW

- **ESERCIZIO:** Creiamo una lista dei nomi delle sequenze

```
cat sequences1.fastq | wc -l
```

```
cat sequences1.fastq | grep @ > readnames.txt
```

Ma così includiamo anche adattatori e altre informazioni, che vogliamo rimuovere. Quindi proviamo con:

```
cat sequences1.fastq | grep @ | sed 's/1:N:0:ACTATAGA+TGCATACC//'
```

Esistono più adattatori (verificate con `cat`)! Rimuoviamo allora tutto ciò che viene dopo "1:N:0:" usando `.*`:

```
cat sequences1.fastq | grep @ | sed "s/1:N:0:.*//"
```

```
cat sequences1.fastq | grep @ | sed "s/1:N:0:.*//" > readnames.txt
```

[^X] nega un carattere X dentro sed

- **Esercizio:** contiamo quante basi hanno qualita' F (alta qualita')

Rimuoviamo prima tutti i caratteri che non sono F:

```
cat sequences1.fastq | sed 's/[^F]//g'
```

```
cat sequences1.fastq | sed 's/[^F]//g' | wc -c
```

Problema: le nuove linee (\n) sono contate come un carattere. Quindi `wc -c` conta correttamente tutte le F, ma anche il numero di linee. Rimuoviamo le nuove linee con `tr -d '\n'` (-d per delete)

```
cat sequences1.fastq | sed 's/[^F]//g' | tr -d '\n' | wc -c
```

sort

ordina

uniq

estrae le righe uniche da un file sorted

sort

ordina

uniq

estrae le righe uniche da un file sorted

- **ESERCIZIO:** Creiamo una lista degli adattatori

```
cat sequences1.fastq | grep @ | sed "s/.*1:N:0:/" | uniq
```

```
cat sequences1.fastq | grep @ | sed "s/.*1:N:0:/" | sort | uniq >  
adaptors.txt
```

sort

ordina

uniq

estrae le righe uniche da un file sorted

- **ESERCIZIO:** Creiamo una lista degli adattatori

```
cat sequences1.fastq | grep @ | sed "s/.*1:N:0:/" | uniq
```

```
cat sequences1.fastq | grep @ | sed "s/.*1:N:0:/" | sort | uniq >  
adaptors.txt
```

Notate inoltre che naturalmente sed s/ rimuove solamente la prima istanza del carattere (per linea). Quindi se volessimo ad esempio sostituire tutte le A con delle N, dovremmo aggiungere /g (per sostituzione globale)

```
cat adaptors.txt | sed "s/A/N/"
```

```
cat adaptors.txt | sed "s/A/N/g"
```

Altre espressioni regolari complesse

Esercizio: estraiamo solo le sequenze di DNA

```
cat sequences1.fastq | grep -v @ | grep -v + | less -S
```

Possiamo cominciare con l'estrarre tutte le sequenze che iniziano (^carattere), finiscono con “carattere” (carattere\$)

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '^[ACGTN]'
```

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '[ACGTN]$'
```

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '[ACGTN][ACGTN]$'
```

o entrambi, senza interruzioni

```
cat sequences1.fastq | grep -E '^[ACGTN]+$' > sequences.txt
```

Oppure, possiamo ritenere tutte le sequenze che contengono o A,C,G,T o N ripetute esattamente 101 volte (come possiamo contare con wc -c)

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '[ACGTN]\{101\}'
```

```
cat sequences1.fastq | tail -1 | wc -c
```

```
cat sequences1.fastq | grep '[ACGTN]\{101\}'
```

Altre espressioni regolari complesse

Esercizio: estraiamo solo le sequenze di DNA

```
cat sequences1.fastq | grep -v @ | grep -v + | less -S
```

Possiamo cominciare con l'estrarre tutte le sequenze che iniziano (^carattere), finiscono con "carattere" (carattere\$)

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '^[ACGTN]'
```

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '^[ACGTN][ACGTN]'
```

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '[ACGTN][ACGTN]$'
```

o entrambi, senza interruzioni

```
cat sequences1.fastq | grep -E '^[ACGTN]+$' > sequences.txt
```

Oppure, possiamo ritenere tutte le sequenze che contengono o A,C,G,T o N ripetute esattamente 101 volte (come possiamo contare con wc -c)

```
cat sequences1.fastq | grep -v @ | grep -v + | grep '[ACGTN]\{101\}'
```

```
cat sequences1.fastq | tail -1 | wc -c
```

```
cat sequences1.fastq | grep '[ACGTN]\{101\}'
```

```
cat sequences1.fastq | grep -E '[ACGTN]{101}'
```

..o tutte le sequenze che iniziano e fino alla fine hanno solo

Loops e condizionali: la vera programmazione

Basic of Loops in Java Programming

For Loop

While Loop

Do While



EXPLAINED WITH EXAMPLES

FOR LOOP
IN PYTHON



simplilearn

LOOPS
IN C++



Loops in Java

while
do..while
in Java

} Loop



በአማርኛ

while
loop

do-while
loop

12

JAVA Programming

for VARIABLE in ...;do comando; done

esegue un comando per ogni valore in ...

```
~$ for i in 1 2 3 4 5;do  
echo $i  
done  
1  
2  
3  
4  
5
```

for VARIABILE in ...;do comando; done

esegue un comando per ogni valore in ...

Il **comando** può essere uno o più comandi, anche complessi

```
~$ for i in 1 2 3 4 5;do
echo sequences${i}.fastq
ls -lh sequences${i}.fastq
done
sequences1.fastq
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences1.fastq
sequences2.fastq
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences2.fastq
sequences3.fastq
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences3.fastq
sequences4.fastq
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences4.fastq
sequences5.fastq
-rw-r--r-- 1 fabrizio fabrizio 67K Sep 25 00:44 sequences5.fastq
```


for VARIABILE in;do comando; done

esegue un comando per ogni valore in ...

```
~$ for i in $( seq 1 5 );do
```

Il **comando** può essere uno o più comandi, anche complessi

```
~$ for i in 1 2 3 4 5;do  
echo sequences${i}.fastq  
ls -lh sequences${i}.fastq  
done  
sequences1.fastq  
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences1.fastq  
sequences2.fastq  
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences2.fastq  
sequences3.fastq  
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences3.fastq  
sequences4.fastq  
-rw-r--r-- 1 fabrizio fabrizio 66K Sep 25 00:44 sequences4.fastq  
sequences5.fastq  
-rw-r--r-- 1 fabrizio fabrizio 67K Sep 25 00:44 sequences5.fastq
```



```
for VARIABLE in ...;do comando; done
```

esegue un comando per ogni valore in ...

I valori della variabile possono anche essere specificati come liste di files, o liste di nomi

```
~$ ls sequences*.fastq
sequences1.fastq sequences2.fastq sequences3.fastq sequences4.fastq sequences5.fastq
~$ for i in sequences*.fastq;do echo $i; done
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
```

```
for VARIABLE in ...;do comando; done
```

esegue un comando per ogni valore in ...

I valori della variabile possono anche essere specificati come liste di files, o liste di nomi

```
~$ ls sequences*.fastq
sequences1.fastq sequences2.fastq sequences3.fastq sequences4.fastq sequences5.fastq
~$ for i in sequences*.fastq;do echo $i; done
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
```

```
~$ for i in topolino paperino;do
echo $i | sed "s/o$/a/"
done
topolina
paperina
```

```
if [condizione];then
comando1
else
comando2
fi
```

Esegue **comando1** se condizione è vera, **comando2** se falsa

```
~$ for i in 1 2 3 4 5;do
echo $i
done
1
2
3
4
5
```

> «greater than»

```
for i in 1 2 3 4 5;do
    if [ $i -gt 3 ]; then
        echo $i
    fi
done
4
5
```



```
if [condizione];then
comando1
else
comando2
fi
```

Esegue **comando1** se condizione è vera, **comando2** se falsa

```
~$ for i in 1 2 3 4 5;do
echo $i
done
1
2
3
4
5
```

< «less than»



```
~$ for i in 1 2 3 4 5;do
    if [ $i -lt 3 ]; then
    echo $i
    fi
done
1
2
```

```
if [condizione];then  
comando1  
else  
comando2  
fi
```

```
~$ VINCITORE="LucioCorsi"  
if [ $VINCITORE == "Fedez" ];then  
echo "Nooooo!"  
else  
echo "Yay!"  
fi  
Yay!
```



```
$(( OPERAZIONE MATEMATICA ))
```

```
totale=$(( 2 + 2 ))
```

```
echo $totale
```

```
$(( OPERAZIONE MATEMATICA ))
```

```
totale=$(( 2 + 2 ))
```

```
echo $totale
```

`$(( OPERAZIONE ))` diverso da `${VARIABLE}` diverso da `$( comando )`

while loop

esegue finche' una condizione è verificata

```
~$ i=1
while [ $i -lt 3 ];do
echo $i
i=$(( i + 1))
done
1
2
```

Loops e condizionali: la vera programmazione

Basic of Loops in Java Programming

For Loop

While Loop

Do While



EXPLAINED WITH EXAMPLES

FOR LOOP
IN PYTHON



simplilearn

LOOPS
IN C++



Loops in Java

while
do..while
in Java

} Loop



በአማርኛ


while
loop

do-while
loop

12

JAVA Programming

Stesso concetto in tutti i linguaggi



Concetto	Bash	Python	R	AWK
FOR	<pre>for i in 1 2 3; do echo \$i done</pre>	<pre>for i in [1,2,3]: print(i)</pre>	<pre>for(i in 1:3) { print(i) }</pre>	<pre>for(i=1;i<=3;i++) { print i }</pre>
IF	<pre>if [\$x -eq 5]; then echo "Yes" fi</pre>	<pre>if x == 5: print("Yes")</pre>	<pre>if(x == 5) { print("Yes") }</pre>	<pre>if(x == 5) { print "Yes" }</pre>
WHILE	<pre>while [\$x -lt 3]; do echo \$x x=x+1 done</pre>	<pre>while x < 3: print(x) x += 1</pre>	<pre>while(x < 3) { print(x) x <- x + 1 }</pre>	<pre>while(x < 3) { print x x++ }</pre>

*gestire files e
programmi*

*programmazione
interpretata*

*statistica e
analisi dati*


*uso rapido di
stringhe e tabelle*

Stesso concetto in tutti i linguaggi



Concetto	Bash	Python	Julia	R	AWK	C	C++	Java	Rust
FOR	<pre>for i in 1 2 3; do echo \$i done</pre>	<pre>for i in [1,2,3]: print(i)</pre>	<pre>for i in [1,2,3] println(i) end</pre>	<pre>for(i in 1:3) { print(i) }</pre>	<pre>for(i=1;i<=3;i ++) { print i }</pre>	<pre>for(int i=1;i<=3;i++) { printf("%d",i) ; }</pre>	<pre>for(int i=1;i<=3;i++) { cout << i; }</pre>	<pre>for(int i=1;i<=3;i++) { System.out.p rintln(i); }</pre>	<pre>for i in 1..=3 { println!("{}", i); }</pre>
IF	<pre>if [\$x -eq 5]; then echo "Yes" fi</pre>	<pre>if x == 5: print("Yes")</pre>	<pre>if x == 5 println("Yes") end</pre>	<pre>if(x == 5) { print("Yes") }</pre>	<pre>if(x == 5) { print "Yes" }</pre>	<pre>if(x == 5) { printf("Yes"); }</pre>	<pre>if(x == 5) { cout << "Yes"; }</pre>	<pre>if(x == 5) { System.out.p rintln("Yes"); }</pre>	<pre>if x == 5 { println!("Yes") ; }</pre>
WHILE	<pre>while [\$x -lt 3]; do echo \$x ((x++)) done</pre>	<pre>while x < 3: print(x) x += 1</pre>	<pre>while x < 3 println(x) x += 1 end</pre>	<pre>while(x < 3) { print(x) x <- x + 1 }</pre>	<pre>while(x < 3) { print x x++ }</pre>	<pre>while(x < 3) { printf("%d",x) ; x++; }</pre>	<pre>while(x < 3) { cout << x; x++; }</pre>	<pre>while(x < 3) { System.out.p rintln(x); x++; }</pre>	<pre>while x < 3 { println!("{}", x); x += 1; }</pre>

Stesso concetto in tutti i linguaggi



Concetto	Bash	Python	R	AWK
FOR	<pre>for i in 1 2 3; do echo \$i done</pre>	<pre>for i in [1,2,3]: print(i)</pre>	<pre>for(i in 1:3) { print(i) }</pre>	<pre>for(i=1;i<=3;i++) { print i }</pre>
IF	<pre>if [\$x -eq 5]; then echo "Yes" fi</pre>	<pre>if x == 5: print("Yes")</pre>	<pre>if(x == 5) { print("Yes") }</pre>	<pre>if(x == 5) { print "Yes" }</pre>
WHILE	<pre>while [\$x -lt 3]; do echo \$x x=x+1 done</pre>	<pre>while x < 3: print(x) x += 1</pre>	<pre>while(x < 3) { print(x) x <- x + 1 }</pre>	<pre>while(x < 3) { print x x++ }</pre>

*gestire files e
programmi*


*programmazione
interpretata*

*statistica e
analisi dati*

*uso rapido di
stringhe e tabelle*



Dollari e parentesi



ESEMPIO

- `${VARIABILE}` richiama il valore di una variabile
- `$( COMANDO )` restituisce l'output di un comando
- `$(( OPERAZIONE ))` esegue un'operazione matematica
- `[ CONDIZIONE ]` valuta se CONDIZIONE è vera



```
$ X=Trieste; echo $X
Trieste
$ echo ${X}
Trieste
```

```
$ date
Wed Oct 1 14:03:10 CEST 2025
$ echo date
date
$ echo $( date )
Wed Oct 1 14:03:20 CEST 2025
```


```
$ echo $(( 2 + 2 ))
4
```

```
$ if [ 1 != 2 ]; then echo "sono diversi!"; fi
sono diversi!
```


Eseguire comandi vs scrivere un programma



Eseguire comandi vs scrivere un programma



Eseguire comandi vs scrivere un programma




```
$ for i in $( seq 1 5 );do
> wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences${i}.fastq
> done
--2025-10-02 06:07:34-- https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences1.fastq
Resolving raw.githubusercontent.com (raw.githubusercontent.com)... 185.199.109.133, 185.199.108.133, 185.199.111.133, ...
Connecting to raw.githubusercontent.com (raw.githubusercontent.com)|185.199.109.133|:443... connected.
HTTP request sent, awaiting response... 200 OK
Length: 67422 (66K) [text/plain]
Saving to: 'sequences1.fastq.1'

sequences1.fastq.1          100%[=====>] 65.84K  ---KB/s  in 0.06s

2025-10-02 06:07:35 (1020 KB/s) - 'sequences1.fastq.1' saved [67422/67422]
```

Eseguire comandi vs scrivere un programma




```
$ for i in $( seq 1 5 );do
> wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences${i}.fastq
> done
--2025-10-02 06:07:34-- https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences1.fastq
Resolving raw.githubusercontent.com (raw.githubusercontent.com)... 185.199.109.133, 185.199.108.133, 185.199.111.133, ...
Connecting to raw.githubusercontent.com (raw.githubusercontent.com)|185.199.109.133|:443... connected.
HTTP request sent, awaiting response... 200 OK
Length: 67422 (66K) [text/plain]
Saving to: 'sequences1.fastq.1'

sequences1.fastq.1          100%[=====>] 65.84K  ---KB/s   in 0.06s

2025-10-02 06:07:35 (1020 KB/s) - 'sequences1.fastq.1' saved [67422/67422]
$ ls *fastq
sequences1.fastq sequences2.fastq sequences3.fastq sequences4.fastq sequences5.fastq
```

Eseguire comandi vs scrivere un programma




```
$ for i in $( seq 1 5 );do
> wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences${i}.fastq
> done
--2025-10-02 06:07:34-- https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences1.fastq
Resolving raw.githubusercontent.com (raw.githubusercontent.com)... 185.199.109.133, 185.199.108.133, 185.199.111.133, ...
Connecting to raw.githubusercontent.com (raw.githubusercontent.com)|185.199.109.133|:443... connected.
HTTP request sent, awaiting response... 200 OK
Length: 67422 (66K) [text/plain]
Saving to: 'sequences1.fastq.1'

sequences1.fastq.1          100%[=====>] 65.84K  ---KB/s  in 0.06s

2025-10-02 06:07:35 (1020 KB/s) - 'sequences1.fastq.1' saved [67422/67422]
$ ls *fastq
sequences1.fastq sequences2.fastq sequences3.fastq sequences4.fastq sequences5.fastq
```


Eseguire comandi vs scrivere un programma

Interattivamente




Usando un editor


Editor: VScode, word, etc.



copia e incolla




Terminale: mobaXterm, iTerm




Eseguire comandi vs scrivere un programma

Interattivamente




Usando un editor


Editor: VScode, word, etc.




copia e incolla



Terminale: mobaXterm, iTerm




Eseguire comandi vs scrivere un programma




Usando un editor


Editor: VScode, word, etc.



copia e incolla



Terminale: mobaXterm, iTerm




Eseguire comandi vs scrivere un programma




Esegui (su terminale)

Editor: VScode, word, etc.




copia e incolla o
salva in un file



file



Terminale: mobaXterm, iTerm



Eseguire comandi vs scrivere un programma

Rendete il programma eseguibile con `chmod +x`

```
$ chmod +x issunday.sh  
$ ls -lh issunday.sh  
-rwxr-xr-x 1 fabrizio fabrizio 181 Oct  2 06:59 issunday.sh
```


Owner
Group
Others



Editor: VScode, word, etc.

```
## Programma che dice se e' Domenica  
X is 1 if Sun, 0 otherwise  
X=$( date | grep Sun | wc -l )  
if [ $X == 1 ];then  
    echo "E' Domenica!"  
else  
    echo "No, svegliati!"  
fi  
~  
-- INSERT --
```

copia e incolla o
salva in un file



file



Esegui (su terminale)

```
./issunday.sh  
No, svegliati!
```

Eseguire comandi vs scrivere un programma



Rendete il programma eseguibile con `chmod +x`

```
$ chmod +x issunday.sh
$ ls -lh issunday.sh
-rwxr-xr-x 1 fabrizio fabrizio 181 Oct  2 06:59 issunday.sh
```


Owner
Group
Others



Editor: VScode, word, etc.

```
## Programma che dice se e' Domenica
X is 1 if Sun, 0 otherwise
X=$( date | grep Sun | wc -l )
if [ $X == 1 ];then
    echo "E' Domenica!"
else
    echo "No, svegliati!"
fi
-- INSERT --
```

copia e incolla o
salva in un file



file



Esegui (su terminale)

```
./issunday.sh
No, svegliati!
```

Eseguire comandi vs scrivere un programma

Specificare il linguaggio usato con la *shebang*,
una riga iniziale che inizia con `#!`
(per bash `#!/bin/bash`)

```
#!/bin/bash
### Programma che dice se e' Domenica
#X is 1 if Sun, 0 otherwise
X=$( date | grep Sun | wc -l )
if [ $X == 1 ];then
    echo "E' Domenica!"
else
    echo "No, svegliati!"
fi
```

Rendete il programma eseguibile con `chmod +x`

```
$ chmod +x issunday.sh
$ ls -lh issunday.sh
-rwxr-xr-x 1 fabrizio fabrizio 181 Oct  2 06:59 issunday.sh
```


Owner
Group
Others



Editor: VScode, word, etc.

```
### Programma che dice se e' Domenica
X is 1 if Sun, 0 otherwise
X=$( date | grep Sun | wc -l )
if [ $X == 1 ];then
    echo "E' Domenica!"
else
    echo "No, svegliati!"
fi
-- INSERT --
```

copia e incolla o
salva in un file



file



Esegui (su terminale)

```
./issunday.sh
No, svegliati!
```

Eseguire comandi vs scrivere un programma

Specificare il linguaggio usato con la *shebang*,
una riga iniziale che inizia con `#!`

(per bash `#!/bin/bash`)  LINUX

```
#!/bin/bash
### Programma che dice se e' Domenica
#X is 1 if Sun, 0 otherwise
X=$( date | grep Sun | wc -l )
if [ $X == 1 ];then
    echo "E' Domenica!"
else
    echo "No, svegliati!"
fi
```

 `#!/bin/sh`

`#!/usr/bin/python`


`#!/usr/bin/env Rscript` 

POSIX, un "Linux" piu' basico

Editor: VScode, word, etc.

```
### Programma che dice se e' Domenica
#X is 1 if Sun, 0 otherwise
X=$( date | grep Sun | wc -l )
if [ $X == 1 ];then
    echo "E' Domenica!"
else
    echo "No, svegliati!"
fi
-- INSERT --
```

copia e incolla o
salva in un file



file

Rendete il programma eseguibile con `chmod +x`

```
$ chmod +x issunday.sh
$ ls -lh issunday.sh
-rwxr-xr-x 1 fabrizio fabrizio 181 Oct  2 06:59 issunday.sh
```

Owner
Group
Others



Esegui (su terminale)

```
./issunday.sh
No, svegliati!
```



ESERCIZI



- Scrivete un piccolo programmino con un `for` e/o un `if`

Mettiamo tutto insieme e scriviamo un programma complesso e utile!

Esercizio:

Scriviamo un programma che scriva un report che, per ogni file **fastq** nella nostra cartella, scriva

- 1) il numero delle reads
- 2) il numero delle basi ad alta qualità (F)
- 3) il numero di adattatori

Per ottenere i files:

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences1.fastq
```

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences2.fastq
```

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences3.fastq
```

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences4.fastq
```

```
wget https://raw.githubusercontent.com/fabrimafe/GenomicaComputazionale2025_2026/refs/heads/main/sequences5.fastq
```

Le sequenze di DNA: il formato fastq

```
~$ head sequences1.fastq
@A00619:220:HYK7GDRX3:1:2101:13440:1000 1:N:0:ACTATAGA+TGCATACC
NCCCGTGAGATGATGCGCGTCATCCTCAACAAGGCCAAATCTGACCCCAAGCGACTCGTTCTCGCTGAGATCGGAAGAGCACACGTCTGAACTCCAGTCAC
+
#FFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFF
@A00619:220:HYK7GDRX3:1:2101:18629:1000 1:N:0:ACTATAGA+TGCATACC
NGCTGTGGACTCCACCCGAGTTCCGGATCGAACTGGTGAATTATCCAGCAGCTCTCGGTCGATCCCGGGAACCTCCTCCAACACCACTGTTGGAAGACT
+
#FFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFFF
@A00619:220:HYK7GDRX3:1:2101:20745:1000 1:N:0:ACTATAGA+TGCATACC
NGGATATCAATCAACTCCACGCAACTCCAACCTCCCTCAGATCGGAAGAGCACACGTCTGAACTCCAGTCACACTATAGAATCTCGGTTTGCGTCTTATG
```

- Riga1: @ riga con i nomi delle sequenze ed informazioni sul sequenziamento
- Riga2: Sequenza ACGT
- Riga3: +, un semplice separatore
- Riga4: Qualità delle sequenze

Mettiamo tutto insieme e scriviamo un programma complesso e utile!

Esercizio:


Scriviamo un programma che scriva un report che, per ogni file **fastq** nella nostra cartella, scriva

- 1) il numero delle reads
- 2) il numero delle basi ad alta qualità (F)
- 3) il numero di barcodes (anche chiamati indici o i5 i7 adapters)

```
NOME_REPORT=report.txt
for i in *fastq; do
cat $i | grep @ | wc -l > $NOME_REPORT
cat $i | sed 's/[^F]//g' | tr -d '\n' | wc -c >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0:/" | sort | uniq | wc -l >> $NOME_REPORT
done
```

Come creare un piccolo programma eseguibile

- Aprite il vostro editor, scrivete il vostro codice e salvatelo (possibilmente come file .sh)
- In alternativa, aprite vim e digitatelo/copiatelo dopo essere entrati in modalità INSERT (premere *i*)



```
~$ vim create_report_sequences.sh
```

- Infine uscite e rendete eseguibile il vostro file con

```
chmod +x ILVOSTROFILE
```

```
$ chmod +x create_report_sequences.sh
$ ls -lh create_report_sequences.sh
-rwxr-xr-x 1 fabrizio fabrizio 605 Sep 25 08:44 create_report_sequences.sh
```

- Potete verificare che il vostro file esiste ed è eseguibile con

```
ls -lh
```

create_report



```
~$ vim create_report_sequences.sh
```

o sul vostro editor

```
#!/bin/bash

NOME_REPORT="report.txt"
if [ -f $NOME_REPORT ];then
rm $NOME_REPORT
else
touch $NOME_REPORT
fi

for i in *fastq; do
echo "=====" >> $NOME_REPORT
echo $i >> $NOME_REPORT
echo "-----" >> $NOME_REPORT
#numero reads
echo "number of reads" >> $NOME_REPORT
cat $i | grep @ | wc -l >> $NOME_REPORT
#numero basi buone
echo "number of high quality (F) bases" >> $NOME_REPORT
cat $i | sed 's/[^F]//g' | tr -d '\n' | wc -c >> $NOME_REPORT
#numero adattatori unici
echo "number of barcodes" >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0:/" | sort | uniq | wc -l >> $NOME_REPORT
done
```

```
~$ ./create_report_sequences.sh report.txt
~$ cat report.txt
=====
sequences1.fastq
-----
number of reads
250
number of high quality (F) bases
22881
number of barcodes
9
=====
sequences2.fastq
-----
number of reads
250
number of high quality (F) bases
23064
number of barcodes
3
=====
```

create_report



```
~$ vim create_report_sequences.sh
```

o sul vostro editor

```
#!/bin/bash

NOME_REPORT="report.txt"
if [ -f $NOME_REPORT ];then
rm $NOME_REPORT
else
touch $NOME_REPORT
fi

for i in *fastq; do
echo "======" >> $NOME_REPORT
echo $i >> $NOME_REPORT
echo "-----" >> $NOME_REPORT
#numero reads
echo "number of reads" >> $NOME_REPORT
cat $i | grep @ | wc -l >> $NOME_REPORT
#numero basi buone
echo "number of high quality (F) bases" >> $NOME_REPORT
cat $i | sed 's/[^F]/g' | tr -d '\n' | wc -c >> $NOME_REPORT
#numero adattatori unici
echo "number of barcodes" >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0://" | sort | uniq | wc -l >> $NOME_REPORT
done
```

Questo programma non è molto flessibile. Ad esempio usa sempre lo stesso output file (potremmo non voler sovrascriverlo ogni volta, e invece aggiornare periodicamente il nostro report con i fastq che sequenziamo nuovamente). Proviamo a renderlo piu' flessibile!

Argomenti posizionali in bash

- Per rendere flessibile un programma dobbiamo poter cambiare i suoi input e le sue funzionalità senza ogni volta dover modificare il programma.
- Per questo possiamo definire degli argomenti: dei valori che il nostro programma utilizzerà per le sue funzioni.
- In bash, possiamo definire argomenti posizionali semplicemente con \$POSIZIONE_DELL_ARGOMENTO, ad esempio \$1 per il primo argomento.

```
#!/bin/bash
#---Programma che conta le lettere in una parola---
WORD=$1 #L argomento 1 definisce una parola di input
NUMERO_CARATTERI=$( echo $WORD | wc -c )
echo "La tua parola ha $NUMERO_CARATTERI caratteri"
```

ESEMPIO: contalettere.sh

```
./contalettere.sh panamabananas
La tua parola ha 14 caratteri
```

- Posso anche definire files di input, output, numeri, etc.
- Per piu' argomenti, semplicemente posso usare \$2, \$3 per il secondo e terzo argomento, rispettivamente (e a seguire)
- E' SEMPRE utile **commentare** i programmi con informazioni utili usando # (come nell'esempio), soprattutto per definire gli argomenti, così che non dobbiate decifrare il vostro codice a posteriori

create_report



```
~$ vim create_report_sequences.sh
```

o sul vostro editor

Prende il primo **argomento** (\$1)

```
#!/bin/bash

NOME_REPORT=$1
if [ -f $NOME_REPORT ];then
rm $NOME_REPORT
else
touch $NOME_REPORT
fi

for i in *fastq; do
echo "======" >> $NOME_REPORT
echo $i >> $NOME_REPORT
echo "-----" >> $NOME_REPORT
#numero reads
echo "number of reads" >> $NOME_REPORT
cat $i | grep @ | wc -l >> $NOME_REPORT
#numero basi buone
echo "number of high quality (F) bases" >> $NOME_REPORT
cat $i | sed 's/[^F]//g' | tr -d '\n' | wc -c >> $NOME_REPORT
#numero adattatori unici
echo "number of barcodes" >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0:/" | sort | uniq | wc -l >> $NOME_REPORT
done
```

```
./create_report_sequences.sh 11mioreport_20ttobre2025.txt
```

```
~$ ./create_report_sequences.sh report.txt
~$ cat report.txt
=====
sequences1.fastq
-----
number of reads
250
number of high quality (F) bases
22881
number of barcodes
9
=====
sequences2.fastq
-----
number of reads
250
number of high quality (F) bases
23064
number of barcodes
3
=====
```

create_report



```
~$ vim create_report_sequences.sh
```

o sul vostro editor

Prende il primo **argomento** (\$1)

```
#!/bin/bash

NOME_REPORT=$1
if [ -f $NOME_REPORT ];then
rm $NOME_REPORT
else
touch $NOME_REPORT
fi

for i in *fastq; do
echo "======" >> $NOME_REPORT
echo $i >> $NOME_REPORT
echo "-----" >> $NOME_REPORT
#numero reads
echo "number of reads" >> $NOME_REPORT
cat $i | grep @ | wc -l >> $NOME_REPORT
#numero basi buone
echo "number of high quality (F) bases" >> $NOME_REPORT
cat $i | sed 's/[^F]//g' | tr -d '\n' | wc -c >> $NOME_REPORT
#numero adattatori unici
echo "number of barcodes" >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0:/" | sort | uniq | wc -l >> $NOME_REPORT
done
```

```
./create_report_sequences.sh 11mioreport_20ttobre2025.txt
```

Un create_report migliore



```
cp create_report_sequences.sh create_report_sequences2.sh
vim create_report_sequences2.sh
```

```
#!/bin/bash
INPUTPATH=$1
NOME_REPORT=$2

echo "-----"
echo "Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing $NOME_REPORT for files:
$( ls ${INPUTPATH}*fastq )"
echo "-----"

if [ -f $NOME_REPORT ];then
rm $NOME_REPORT
else
touch $NOME_REPORT
fi

for i in ${INPUTPATH}*fastq; do
echo "===== " >> $NOME_REPORT
echo $i >> $NOME_REPORT
echo "-----" >> $NOME_REPORT
#numero reads
echo "number of reads" >> $NOME_REPORT
cat $i | grep @ | wc -l >> $NOME_REPORT
#numero basi buone
echo "number of high quality (F) bases" >> $NOME_REPORT
cat $i | sed 's/[^F]//g' | tr -d '\n' | wc -c >> $NOME_REPORT
#numero adattatori unici
echo "number of barcodes" >> $NOME_REPORT
cat $i | grep @ | sed "s/.*1:N:0:/" | sort | uniq | wc -l >> $NOME_REPORT
done
```

Messaggio di aiuto che ci dice come usare lo script e cosa farà

./Nome_dello_script

Argomento 1
(nome dei files)

Argomento 2
(nome del report)

Utilizzo:

```
$ ./create_report_sequences2.sh sequences report.txt
```

Un create_report migliore

```
$ pwd  
/home/fabrizio  
$ ./create_report_sequences2.sh sequences report.txt
```

```
-----  
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).  
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt  
Writing report.txt for files:  
sequences1.fastq  
sequences2.fastq  
sequences3.fastq  
sequences4.fastq  
sequences5.fastq
```

Messaggio di aiuto

Un create_report migliore

```
$ pwd
/home/fabrizio
$ ./create_report_sequences2.sh sequences report.txt
-----
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing report.txt for files:
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
-----
$ ./create_report_sequences2.sh sweet_potato/ sweet_potato/report.txt
-----
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing sweet_potato/report.txt for files:
sweet_potato/sweet-potato-chloroplast-illumina-reduced.fastq
sweet_potato/sweet-potato-chloroplast-nanopore-reduced.fastq
-----
```

Messaggio di aiuto

Così possiamo usare lo script su ogni cartella,
o selezionare alcuni file specifici, anche senza
spostarlo o modificarlo

Un create_report migliore

```
$ pwd
/home/fabrizio
$ ./create_report_sequences2.sh sequences report.txt
-----
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing report.txt for files:
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
-----
```

Messaggio di aiuto

Così possiamo usare lo script su ogni cartella,
o selezionare alcuni file specifici, anche senza
spostarlo o modificarlo

```
$ ./create_report_sequences2.sh sweet_potato/ sweet_potato/report.txt
-----
```

```
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing sweet_potato/report.txt for files:
sweet_potato/sweet-potato-chloroplast-illumina-reduced.fastq
sweet_potato/sweet-potato-chloroplast-nanopore-reduced.fastq
-----
```

E' così utile e flessibile che potremmo
pensare di salvarlo in una cartella scripts così
poi da poterlo riutilizzare ogni volta

```
$ mkdir scripts
$ mv create_report_sequences2.sh scripts/
$ scripts/create_report_sequences2.sh sequences report.txt
scripts
$ scripts/create_report_sequences2.sh sequences report.txt
-----
```

```
Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).
Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt
Writing report.txt for files:
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
-----
```



Tenete da conto il lavoro fatto quando può tornare utile!

Può essere utile salvare tutti i vostri scripts in una cartella «scripts», «bin» o «comandi» che potrete riusare sempre

```
$ pwd
/home/fabrizio/sweet_potato
$ ~/scripts/create_report_sequences2.sh ./ report.txt
```

oppure (con lo stesso significato)

```
$ ${HOME}/scripts/create_report_sequences2.sh ./ report.txt
```



```
$ mkdir scripts
$ mv create_report_sequences2.sh scripts/
$ scripts/create_report_sequences2.sh sequences report.txt
scripts
$ scripts/create_report_sequences2.sh sequences report.txt
```

Script that summarize a set of fastq files given an input path with the selected fastq (argument 1) and an output report (argument 2).

Example usage: create_report_sequences2.sh fastq_folder/sequences report.txt

Writing report.txt for files:

```
sequences1.fastq
sequences2.fastq
sequences3.fastq
sequences4.fastq
sequences5.fastq
-----
```

E' cosi utile e flessibile che potremmo pensare di salvarlo in una cartella scripts cosi poi da poterlo riusare ogni volta





```

~$ ./create_report_sequences.sh report.txt
~$ cat report.txt
=====
sequences1.fastq
-----
number of reads
250
number of high quality (F) bases
22881
number of barcodes
9
=====
sequences2.fastq
-----
number of reads
250
number of high quality (F) bases
23064
number of barcodes
3
=====


```

Mais di circa 2000 anni fa dal Venezuela
(Jaimes et al., in revisione)



Esercizi

- Il genoma del mais è ripetuto all'85%
- Tra le ripetizioni piu' abbondanti troviamo le ripetizioni tandem (microsatelliti) di AT e CAC
- Esercizio 1: *Trovate tutte le ripetizioni di almeno due volte di AT e CAC*
- Esercizio 2: *Calcolare la distribuzione di contenuto GC (la proporzione di C e G sul totale delle basi) per ogni sequenza*



Il formato **FASTA**

- Generalmente utilizzato per rappresentare genomi e genomi di riferimento. Il risultato finale di un assemblaggio!
- Il più semplice dei formati

```
>nome_cromosoma_o_sequenza1
```

```
ATGGAATAAGGTATANATTTTAAACCCTTAATATAAT... .
```

```
>nome_cromosoma_o_sequenza2
```

```
GGTTATCCTATATCATTTTTTAACCTAGGGGGGGGGA... .
```

Il formato **FASTA**

- Generalmente utilizzato per rappresentare genomi e genomi di referenza
- Il piu' semplice dei formati
- Non ha informazione su qualità (come i fastq) quindi alcuni caratteri possono essere **soft masked (lettere minuscole)** o **hard-masked (con delle N)**:


```
>nome_cromosoma_o_sequenza1
```

```
atggaataagggtNNNNNNNNNNATTTTAAACCTCT....
```

```
>nome_cromosoma_o_sequenza2
```

```
GGTTATCCTATATCATTTTTAACCTagggggggGGA....
```

Esercizio



- Potete scaricare il primo cromosoma eucariotico sequenziato (1996)

`wget http://hgdownload.soe.ucsc.edu/goldenPath/sacCer3/chromosomes/chrI.fa.gz`

- Il piu' piccolo. Una volta fatti scaricate in un loop gli altri 15 fino a:

`wget http://hgdownload.soe.ucsc.edu/goldenPath/sacCer3/chromosomes/chrXVI.fa.gz`

- Potete poi decomprimerli con

`gunzip chrI.fa.gz`

- oppure visualizzarli con la version di cat per files zippati

`zcat chrI.fa.gz`

- Esercizi:


1. Mascherate con delle N (hard-masking) i microsatelliti con 3 o piu' ripetizioni di TA e AAT per il primo cromosoma
2. Mascherate soft (rendendo le lettere minuscole) i microsatelliti con 3 o piu' ripetizioni di TA e AAT per il primo cromosoma
3. Calcolate la percentuale mascherata per cromosoma e per il genoma
4. Ripetete per tutti i cromosomi in un loop e trovate il cromosoma con piu' microsatelliti
5. Effettuate la stessa operazione per il cromosoma 21 umano:

`wget http://hgdownload.soe.ucsc.edu/goldenPath/hg38/chromosomes/chr21.fa.gz`

TIPS

- Ricordate `tr -d '\n'` e `sed`
- Può esservi utile (non necessariamente) una opzione di `grep`, `grep -o` (stampa solo il pattern trovato e non tutta la riga)

Domande



Per la pratica e lo studio
consiglio di consultare la
«Guida ai comandi Linux»
su Moodle, partendo dall'
«Un esempio istruttivo»



Errata corrige

- In una versione precedente delle slides avevo utilizzato il termine «adaptors» al posto di «barcodes». Questo perché si usano vari termini per indicare i «barcodes» usati per il demultiplexing, tra cui più specificamente «i5-i7 adapters», e a volte «indici». Per evitare confusione con gli adattatori usati in altri contesti ho sostituito il termine con «barcodes».
- Notate che le informazioni sul sequenziamento trovate nel nome della read/prima riga dei file fastq non sono obbligatorie nel formato fastq, e possono variare a seconda della piattaforma di sequenziamento.