

Assemblaggio del genoma di cloroplasto di patata dolce

Genomica Computazionale 2025/2026, Laurea Specialistica in Genomica Funzionale, Università di Trieste, Fabrizio Mafessoni, Tutor Daniela Eugenia Nerelli

In questo tutorial guarderemo all'assemblaggio di un genoma di cloroplasto usando dati da un articolo scientifico ([Zhou et al., 2018](#))

1. Scaricare i dati

Potete scaricare i dati (delle sequenze lunghe oxford nanopore) con

```
wget https://zenodo.org/record/3567224/files/sweet-potato-chloroplast-nanopore-reduced.fastq
```

Sono anche disponibili delle sequenze corte illumina (che non useremo qui, ma per le quali potete effettuare “polishing del genoma”, non trattato a lezione ma secondo le indicazioni di questo [tutorial online](#)) scaricabili con

```
wget https://zenodo.org/record/3567224/files/sweet-potato-chloroplast-illumina-reduced.fastq
```

Queste sono reads fastq, che come visto a lezione è un formato caratterizzato da

@AFAFAHFA	nome sequenza e qualità
ACACTA	sequenza
+	un separatore visuale, +
#FFFFFFF : qualità	qualità base per base

Potete visualizzarle con

```
cat sweet-potato-chloroplast-nanopore-reduced.fastq
```

Notate come le sequenze nanopore siano ben piu' lunghe di quelle illumina

```
cat sweet-potato-chloroplast-illumina-reduced.fastq
```

Invece di visualizzare tutto il file potete usare il comando `head`, oppure `less`.

Soprattutto per le sequenze nanopore, può essere comodo visualizzare le sequenze con l'opzione `less -S`, che non fa andare a capo la linea e vi permette di scorrere a destra con le frecce.

```
less -S sweet-potato-chloroplast-nanopore-reduced.fastq
```

Opzionalmente potete esplorare i files fastq con `fastqc`. Il programma `fastqc` è installabile sia con `conda`

```
conda install -c bioconda fastqc
```

che con `apt` e `brew`.

Ubutu/windows: `sudo apt install fastqc`

Mac: `brew install fastqc`

Fastqc si utilizza soprattutto per esplorare reads illumina, generando un file html che potete aprire con qualsiasi browser. Nel nostro caso non le useremo, quindi questa esplorazione è opzionale. Per generare l'html:

```
fastqc sweet-potato-chloroplast-illumina-reduced.fastq -o  
Illumina_fastq
```

2. Assemblare il genoma

2.1 Installazione programmi di assemblaggio

Per assemblare possiamo utilizzare vari assembleri, con algoritmi leggermente differenti. Idealmente, installate Flye ed assemblete utilizzando questo programma. Nel caso otteniate errori durante l'installazione o durante l'esecuzione (potrebbe accadere per mancanza di memoria) usate raven o miniasm:

Flye:

approccio ibrido di De Bruijn e Overlap-graphs;

in teoria piu' accurato ma richiede piu' tempo e memoria (potrebbe darvi errori std_alloc dovuti alla mancanza di memoria sul computer;

installabile con conda

```
conda install Flye
```

raven:

Basato su Overlap-graphs;

buona performace e piu' leggero di flye.

Installabile con conda:

```
conda install -c bioconda raven-assembler
```

miniasm:

Basato su Overlap-Graph;

molto rapido e leggero, ma richiede cura, "polishing" e non accuratissimo

Installabile con conda, ma anche direttamente con apt o brew. Nello specifico, con conda:

```
conda install -c bioconda minimap2 miniasm
```

Su windows o Ubuntu, usando apt:

`sudo apt install -y minimap2 miniasm` (ricordate la password quando usate `sudo`. Consiglio (non strettamente necessario) per questo anche l'installazione di `racon`:

```
sudo apt install -y racon
```

Usando invece `brew` sul mac:

```
brew install minimap2
```

```
minimap2 -version
```

```
brew tap brewsci/bio
```

```
brew install miniasm
```

```
miniasm 2>&1 | head -n1 # per controllare
```

Su `brew` potreste necessitare di dover prima eseguire:

```
xcode-select --install
```

2.2 Esecuzione dell'assemblaggio

Con i rispettivi programmi potete usare i seguenti comandi:

Flye¹

```
flye --nano-raw sweet-potato-chloroplast-nanopore-reduced.fastq --genome-size 160000 -o Assembly_
```

Raven

```
raven -t 4 sweet-potato-chloroplast-nanopore-reduced.fastq > raven.fasta
```

¹ Flye potrebbe darvi errori di memoria, del tipo

```
....  
ERROR: Caught unhandled exception: std::bad_alloc [2025-10-09 15:21:34] ERROR: flye-modules(+0x3bf6d) [0x5b30aa884f6d]  
[2025-10-09 15:21:34] ERROR: /home/wsl--install/miniconda3/envs/Assembly/bin/.../lib/libstdc++.so.6(+0xbb747)  
[0x7bde25876747]  
....
```

In quel caso potete provare a cambiare alcune opzioni aggiungendo la flag (`--asm-coverage 30` o meno) o evitare limiti preimpostati di memoria che potreste avere sul vostro computer con `ulimit -v unlimited`, o forzando il sistema ad usare una cartella temporanea piu' grande (`export TMPDIR=$HOME/tmp; mkdir -p "$TMPDIR"`). Ma è possibile anche semplicemente che non riesca sul vostro computer!!! Usate a quel punto `raven` o `miniasm` senza rimorsi :D.

Miniasm²

```
minimap2 -x ava-ont -t4 sweet-potato-chloroplast-nanopore-reduced.fastq sweet-potato-chloroplast-nanopore-reduced.fastq > reads.paf
```

```
miniasm -f sweet-potato-chloroplast-nanopore-reduced.fastq reads.paf > asm.gfa
```

```
awk '/^S/{print ">"$2"\n"$3}' asm.gfa > asm.raw.fasta
```

3. Esplorazione dei risultati

Per i vari programmi di assemblaggio, avrete ottenuto dei risultati in formato fasta e (per Flye e miniasm in gfa). Il risultato principale sono le sequenze dei contig assemblati. Questi sono presentati in formato fasta, e potete semplicemente visualizzarli con `cat`, `head` o `less`. Il formato fasta rappresenta infatti semplicemente il nome di una sequenza (preceduto da `>`) e a seguire la sequenza, ed è tipicamente il formato utilizzato le sequenze genomiche. Spesso, se scaricate genomi da NCBI, troverete questi file con un'estensione di fatto equivalente (.fna). Un esempio di file in formato fasta (o .fna, per cui tipicamente le sequenze sono contigs o cromosomi interi):

```
>Nome_sequenza  
ACGGGTAA...
```

Quindi, potete ad esempio esplorare il numero di contigs in un filefasta chiamato filefasta con

```
cat filefasta | grep '>' | wc -l
```

e la loro lunghezza totale con

```
cat filefasta | grep -v '>' | wc -c
```

² Sarebbe successivamente consigliabile con miniasm fare *polishing* delle reads per migliorare l'assemblaggio con:

```
minimap2 -x map-ont -t4 asm.racon1.fasta sweet-potato-chloroplast-nanopore-reduced.fastq > map2.paf  
racon -t4 sweet-potato-chloroplast-nanopore-reduced.fastq map2.paf  
asm.racon1.fasta > asm.racon2.fasta
```

```
(Assembly) fabrizio@asusfabri:~/PraticaAssemblaggio$ head /home/fabrizio/PraticaAssemblaggio/Assembly_/assembly.fasta
>contig_1
CITTCGTTGTTGTACTAATTAACAAAATTTTCGCTTTCTACAATTGATGAAAGGAAGG
AATCAAAACAAATTTTCTTACTTCTCATCCCTTTGAATCAGAAAATACTATGTTATTTC
TACAATTCTATTGTGTTTGTAACTTTGTAATTGGATTCTAGAATTCCAAGGAGCTTG
GTTTCAATCTCGACATCTTAACCCAATGGTTACATCCTGCTATTTATCTTTGGATCACAC
TAATTCAACAGATTTAGCTGAGTTCTTAAAGCATACGGTAATTTCCGTGGGATTGCTTAT
TGCGGAATATTTATAGCATTTTATTATATAAACCCACCTATTCGTCTTTCAAAGTTTCT
ATTAATTAAATTCGTTTCATCAAAAAGCCTTAGAGAGTTATTCGTGACAAAATAGTCTTTG
TGATATATGACTGGACCTATAATCGTGTATATAGATACTTTTAAAGAAATTTTGTGTTT
GCCAAGTGCGAAGGTTTCTCAAATATTCTGTTGTTTGAATTTAAATTATTGATCTAATAT

(Assembly) fabrizio@asusfabri:~/PraticaAssemblaggio$ cat /home/fabrizio/PraticaAssemblaggio/Assembly_/assembly.fasta | grep '>'
>contig_1
>contig_2
>contig_3
>contig_6

(Assembly) fabrizio@asusfabri:~/PraticaAssemblaggio$ cat /home/fabrizio/PraticaAssemblaggio/Assembly_/assembly.fasta | grep -v '>' | wc -c
206203
```

Il formato gfa descrive invece la struttura completa del genoma assemblato, incluse le potenziali connessioni tra i vari contigs (indicati come *edges*). Ad esempio, nel caso di Flye, possiamo vedere con

```
less assembly.fasta
```

le sequenze dei vari contigs ricostruiti, mentre nel file gfa dovreste notare una struttura del genere

```
cat assembly_graph.gfa | less -S
```

```
H      VN:Z:1.0
S      edge_1  CTTCGTTGTTGTGTACTAATTAACAAAATTTTCGCTTTCTACAATTGATGAAAGGAAGGA
S      edge_2  GCAATACTTGAAGCGGCGATCCAGAAAACCCAATACTAAGATCGGCTAAACAAGCTTATAA
S      edge_3  TTTTAAATAGATGATAGATATATATGTATGATAGATATATATGAACAGTAAGAACTAGCAT
S      edge_4  AATACTCCTGGGTGACCGATAGCGAAGTAGTACCGTGAGGAAGGGTGAAAGAACCCAGCGG
S      edge_5  AAGGCTAAATACTCCTGGGTGACCGATAGCGAAGTAGTACCGTGAGGGAAGGGTGAAAAGAA
S      edge_6  TCCC GTTGGACTTCTTATGTCCGGATATGGATCAAATAATAAATATTCTTTTAGAGAGAA
L      edge_2  +      edge_3  -      0M      RC:i:51
L      edge_2  +      edge_3  +      0M      RC:i:73
L      edge_2  -      edge_6  -      0M      RC:i:86
L      edge_2  -      edge_6  +      0M      RC:i:64
P      contig_1      edge_1+ *
P      contig_3      edge_2+,edge_3+,edge_2- *
P      contig_6      edge_2-,edge_6+,edge_2+ *
P      contig_2      edge_2+ *
P      contig_4      edge_4+ *
P      contig_5      edge_5+ *
( END )
```

Qui gli edges rappresentano delle sequenze assemblate. Le potenziali connessioni tra due edges sono rappresentate in *links* (L nella prima colonna) e quando organizzate in contigs, potenzialmente anche coinvolgendo più edges, come *paths* (P nella prima colonna). I links rappresentano potenziali connessioni tra due edges successivi (ad esempio per il primo link, edge_2 ed edge_3, il primo in direzione forward (+) ed il secondo reverse (-), con 51 sequencing reads in supporto di questo link. I paths corrispondono ai contigs riportati nel file fasta, e descrivono “percorsi” tra edges.

Un modo carino per visualizzare questi files è con Bandage. Bandage può essere installato con conda o mamba

```
mamba install -c bioconda bandage
```

o su windows/ubuntu con apt:

```
sudo apt install bandage
```

o su mac con brew

```
brew install --cask bandage
```

Come molti programmi grafici, potrebbe dare qualche problema nell'installazione e richiedere altre dipendenze. Nel caso abbiate problemi, molte delle librerie necessarie sono incluse in chrome³.


Per eseguire Bandage

```
Bandage image assembly_graph.gfa grafo_cloroplasto.svg
```

(Bandage) **studente1@ladybug:~/Assembly\$** Bandage image assembly_graph.gfa grafo_cloroplasto.svg

★ Io ho salvato l'immagine in formato .svg, ma Bandage crea anche immagini .png, scegliete voi quale preferite.

In questo caso Bandage vuole solo due file: il primo deve essere sempre l'input e il secondo sempre l'output.



Come interpretiamo il grafo?

C'è una lunga regione a singola copia (A) connessa ad una inverted repeat (B) connessa ulteriormente ad una regione a singola copia breve (C). Nel grafo, ogni loop alle estremità è a singola copia mentre la parte centrale è la ripetizione inversa, collassata in un'unica sequenza, che ha circa il doppio del coverage. Le barre al di sotto (D) sono le sequenze che Flye è riuscito ad assemblare in dei contig abbastanza lunghi ma che non sapeva dove posizionare all'interno del grafo.

³ Per installare chrome:

```
wget -qO- https://dl.google.com/linux/linux_signing_key.pub | sudo gpg --dearmor -o /usr/share/keyrings/google-chrome.gpg
echo "deb [arch=amd64 signed-by=/usr/share/keyrings/google-chrome.gpg] http://dl.google.com/linux/chrome/deb/ stable main" | sudo tee /etc/apt/sources.list.d/google-chrome.list
sudo apt update; sudo apt install -y google-chrome-stable
```

o su mac, con homebrew

```
brew install --cask google-chrome
```

or download the .dmg from Google and install normally