



Long reads

come *minimizzarne* i problemi



Fabrizio Mafessoni, Genomica Computazionale 2025/2026,
Laurea Specialistica in Genomica Funzionale, Università di Trieste



Long reads


come *minimizzarne* i problemi



Fabrizio Mafessoni, Genomica Computazionale 2025/2026,
Laurea Specialistica in Genomica Funzionale, Università di Trieste

Dal sequenziatore..

..al genoma..



Formati di file bioinformatici

.fastq

.fasta, .bam

short reads

come utilizzarne una marea



sequenze

assemblaggio
De Bruijn graphs

mappatura
Burrow-wheeler



Come uso una
marea di sequenze
cortissime?



come utilizzarne una marea

Costruzione degli indici

panamabananas\$	panamabananas\$	Partial Suffix Array
\$panamabananas ₁	\$panamabananas ₁	13
a ₁ bananas\$panam ₁	a ₁ bananas\$panam ₁	5
a ₂ mabananas\$pan ₁	a ₂ mabananas\$pan ₁	3
a ₃ nambananas\$ _p ₁	a ₃ nambananas\$ _p ₁	1
a ₄ nanas\$panamab ₁	a ₄ nanas\$panamab ₁	7
a ₅ nas\$panamaban ₂	a ₅ nas\$panamaban ₂	9
a ₆ s\$panamabanan ₃	a ₆ s\$panamabanan ₃	11
b ₁ ananas\$panama ₁	b ₁ ananas\$panama ₁	6
m ₁ abananas\$pana ₂	m ₁ abananas\$pana ₂	4
n ₁ amabananas\$pa ₃	n ₁ amabananas\$pa ₃	2
n ₂ anas\$panamaba ₄	n ₂ anas\$panamaba ₄	8
n ₃ as\$panamabana ₅	n ₃ as\$panamabana ₅	10
p ₁ anamabananas\$ ₁	p ₁ anamabananas\$ ₁	0
s ₁ \$panamabanan ₆	s ₁ \$panamabanan ₆	12



ACGTGAC



sfruttando proprietà First-Last di BWT
fino al massimo degli **errori**

[illegible]

short reads

come utilizzarne una marea

Costruzione degli indici
suffix array e trasformata Burrow-Wheeler

panamabananas\$	panamabananas\$	Partial Suffix Array
\$1panamabananas1	\$1panamabananas1	13
a1bananas\$panam1	a1bananas\$panam1	5
a2mabananas\$pan1	a2mabananas\$pan1	3
a3namabananas\$pa1	a3namabananas\$pa1	1
a4nanas\$panamab1	a4nanas\$panamab1	7
a5nas\$panamaban2	a5nas\$panamaban2	9
a6s\$panamabanan3	a6s\$panamabanan3	11
b1ananas\$panama1	b1ananas\$panama1	6
m1abananas\$pana2	m1abananas\$pana2	4
n1amabananas\$pa3	n1amabananas\$pa3	2
n2anas\$panamaba4	n2anas\$panamaba4	8
n3as\$panamabana5	n3as\$panamabana5	10
p1anamabananas\$1	p1anamabananas\$1	0
s1\$panamabananag	s1\$panamabananag	12



Partenza da un seed

ACGTTGAC

TGACCGA

Estensione del seed

sfruttando proprietà First-Last di BWT
fino al massimo degli **errori**

TCTTTGAC

bwa index genome.fa

bwa mem genome.fa sequences.fq

short reads

come utilizzarne una marea

Costruzione degli indici
suffix array e trasformata Burrow-Wheeler

panamabananas\$	panamabananas\$	Partial Suffix Array
\$1panamabananas1	\$1panamabananas1	13
a1bananas\$panam1	a1bananas\$panam1	5
a2mabananas\$pan1	a2mabananas\$pan1	3
a3namabananas\$pan1	a3namabananas\$pan1	1
a4nanas\$panamab1	a4nanas\$panamab1	7
a5nas\$panamabana2	a5nas\$panamabana2	9
a6s\$panamabanan3	a6s\$panamabanan3	11
b1ananas\$panama1	b1ananas\$panama1	6
m1abananas\$pana2	m1abananas\$pana2	4
n1amabananas\$pa3	n1amabananas\$pa3	2
n2anas\$panamaba4	n2anas\$panamaba4	8
n3as\$panamabana5	n3as\$panamabana5	10
p1anamabananas\$1	p1anamabananas\$1	0
s1\$panamabananana6	s1\$panamabananana6	12



Partenza da un seed

ACGTTGAC

TGACCGA

TC TTTGAC

Estensione del seed
sfruttando proprietà First-Last di BWT
fino al massimo degli **errori**

bowtie2-build genome.fa indices

bowtie2 -x indices sequences.fq

short reads

come utilizzarne una marea

Mappatura

Costruzione degli indici
suffix array e trasformata Burrow-Wheeler

panamabananas\$	panamabananas\$	Partial Suffix Array
\$ ₁ panamabananas ₁	\$ ₁ panamabananas ₁	13
a ₁ bananas\$panam ₁	a ₁ bananas\$panam ₁	5
a ₂ mabananas\$pan ₁	a ₂ mabananas\$pan ₁	3
a ₃ namabananas\$pa ₁	a ₃ namabananas\$pa ₁	1
a ₄ nanas\$panamab ₁	a ₄ nanas\$panamab ₁	7
a ₅ nas\$panamaban ₂	a ₅ nas\$panamaban ₂	9
a ₆ s\$panamabanan ₃	a ₆ s\$panamabanan ₃	11
b ₁ ananas\$panama ₁	b ₁ ananas\$panama ₁	6
m ₁ abananas\$pana ₂	m ₁ abananas\$pana ₂	4
n ₁ amabananas\$pa ₃	n ₁ amabananas\$pa ₃	2
n ₂ anas\$panamaba ₄	n ₂ anas\$panamaba ₄	8
n ₃ as\$panamabana ₅	n ₃ as\$panamabana ₅	10
p ₁ anamabananas\$ ₁	p ₁ anamabananas\$ ₁	0
s ₁ \$panamabanan ₆	s ₁ \$panamabanan ₆	12



Partenza da un seed



ACGTTGAC

TGACCGA



Estensione del seed

sfruttando proprietà First-Last di BWT
fino al massimo degli **errori**


TCTTTGAC



Costruzione del De Bruijn Graph



Ricerca del «ciclo Euleriano»*




Assemblaggio



*con l'algoritmo di Leo la formica

short reads

come utilizzarne una marea



Come uso una
marea di sequenze
cortissime?



Due soluzioni principali:

- Comprimere il genoma (con Burrow-Wheeler)
- k-mers/de Bruijn graphs (per assemblare i kmers)

short reads

come utilizzarne una marea



sequenze

assemblaggio
De Bruijn graphs

mappatura
Burrow-wheeler



Un sacco di dati e
sequenze
economiche!



come utilizzarne una marea



sequenze

Un sacco di dati e
sequenze
economiche!

*Ma tante **ripetizioni** e
varianti strutturali!!*

short reads


come utilizzarne una marea



sequenze

assemblaggio
De Bruijn graphs

mappatura
Burrow-wheeler



Ma tante **ripetizioni** e
varianti strutturali!!



**SIZE
MATTERS**



Zone complesse del genoma
solo **risolvibili con long-reads**

Un sacco di dati e
sequenze
economiche!



short reads


come utilizzarne una marea



sequenze

assemblaggio
De Bruijn graphs

mappatura
Burrow-wheeler



Ma tante **ripetizioni** e
varianti strutturali!!



Come usare **long-reads**?

Un sacco di dati e
sequenze
economiche!




Quali sono (alcune del)le difficoltà' di usare long reads?



Quali sono (alcune del)le difficoltà' di usare long reads?

- Molte basi da comparare tra reads
- Ogni reads ha molti errori, inclusi indels




Moltissima
memoria
necessaria

- Oltre agli errori, variazione strutturale tra individui (inserzioni, lunghe regioni delete, trasposte e riorganizzate)

Moltissimi
calcoli/tempo
necessari

Quali sono (alcune del)le difficoltà' di usare long reads?

- Molte basi da comparare tra reads
- Ogni reads ha molti errori, inclusi indels, quindi:
 - per assemblare con De Bruijn:
 - moltissime “bolle” da risolvere
 - dobbiamo spezzare in **moltissimi k-mers corti** per far sì che la maggior parte dei k-mer sia “corretto”
 - per mappare (o assemblare con overlap-graphs):
 - dobbiamo esplorare molte **biforcazioni durante l'estensione**
 - ogni read è molto lunga e contiene **moltissimi potenziali seeds**
- Oltre agli errori, variazione strutturale tra individui (inserzioni, lunghe regioni delete, trasposte e riorganizzate)



Moltissima
memoria
necessaria

Moltissimi
calcoli/tempo
necessari

Le sequenze lunghe possono:

- avere molti errori
- rappresentare zone molte differenze tra genomi (variazione strutturale)

Single Nucleotide Variant



Deletion



Insertion



Tandem Duplication



Interspersed Duplication



Inversion



Translocation



Copy Number Variant




Types of Variants

Le sequenze lunghe possono:


- avere molti errori
- rappresentare zone molte differenze tra genomi (variazione strutturale)

Quindi servirebbero **moltissimi seeds** diversi!!

La trasformata di Burrow-Wheeler è efficiente, ma l'estensione non molto. E servirebbe estendere molti seeds diversi attraverso molti mismatch tollerati!




Che tipo di seeds potremmo usare per una sequenza lunga?



Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



Due soluzioni principali:

- Comprimere il genoma (con Burrow-Wheeler)
- k-mers/de Bruijn graphs (per assemblare i kmers)

Come uso una
marea di sequenze
cortissime?



Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



Run-length encoding

L'immagine è rappresentabile come:

000000000111111100001100001010101



Visto che gli 0 e gli 1 sono in lunghe file, potremmo comprimerla ricordando quanti 0 abbiamo, e poi quanti 1: 908140....

Due soluzioni principali:


- Comprimere il genoma (con Burrow-Wheeler)
- k-mers/de Bruijn graphs (per assemblare i kmers)

Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



Conto tutti i tipi di
segmento (kmer) e
ne faccio un istogramma



Due soluzioni principali:

- Comprimere il genoma
(con Burrow-Wheeler)
- k-mers

Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



kmers


- sommarizzano i dati in modo **lossy** (perdo informazione) ma **conveniente**

Trasformata di Burrow-Wheeler

(compressione **lossless**, senza perdita di informazione)



Conto tutti i tipi di segmento (kmer) e ne faccio un istogramma



Istogramma dei kmers

Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



kmers


- sommarizzano i dati in modo **lossy** (perdo informazione) ma **conveniente**
- Metodo di **sketching**, non compressione

Trasformata di Burrow-Wheeler

(compressione **lossless**, senza perdita di informazione)



Conto tutti i tipi di segmento (kmer) e ne faccio un istogramma



Istogramma dei kmers

Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



kmers


- sommarizzano i dati in modo **lossy** (perdo informazione) ma **conveniente**
- possono persino **aumentare la dimensione del dato**: per una sequenza lunga S posso avere un massimo di $S-k+1$ kmers, quindi se salvati interamente circa $S \cdot k$ caratteri!

Trasformata di Burrow-Wheeler

(compressione **lossless**, senza perdita di informazione)



Conto tutti i tipi di segmento (kmer) e ne faccio un istogramma



Istogramma dei kmers

Come avevamo risolto il problema dei «tanti dati» per le short reads?

come utilizzarne una marea



kmers

- sommarizzano i dati in modo **lossy** (perdo informazione) ma **conveniente**:


cioè kmer1, kmer2, ...

- Se assegno un «ordine» ai kmers, posso rappresentare l'istogramma anche solo come un vettore di conti:

esempio:

102, 49, 42, 36...

Conto tutti i tipi di
segmento (kmer) e
ne faccio un istogramma





Se doveste sommarizzare questa immagine anche perdendo informazione (sketching), come fareste?

- Se volete approfondire l'argomento (assolutamente non necessario per il corso) consiglio: Information Theory, A tutorial Introduction, James V Stone



Possiamo ridurre il numero di kmers che dobbiamo ricordare/la nostra gamma di colori/alfabeto. Ma come?

- Se volete approfondire l'argomento (assolutamente non necessario per il corso) consiglio: Information Theory, A tutorial Introduction, James V Stone




Possiamo ridurre il numero di kmers che dobbiamo ricordare/la nostra gamma di colori/alfabeto. Ma come?

Usare solo alcuni kmers

Sequenza lunga originale



Sequenza lunga originale





Spezzo interamente in
k-mers (che terrò tutti)

Sequenza lunga originale



Spezzo interamente in
k-mers (che terrò tutti)




Estraggo solo dei k-mers
rappresentativi per descrivere
la sequenza originale

Ma quali k-mers usare per
rappresentare long-reads?

o

Quali seed usare per mappare long-
reads?



Minimizers

- Un **minimizer** in una finestra di dimensione L è **il k -mer più piccolo secondo un ordinamento** (in genere una funzione di hashing).



Minimizers

- Un **minimizer** in una finestra di dimensione L è il **k -mer più piccolo secondo un ordinamento** (in genere una funzione di hashing).
- L'idea è di rappresentare una sequenza con pochi **k -mers sparsi che rappresentino la struttura generale della sequenza** senza dover ricordarla ed esaminarla per intero.



Minimizers

- Un **minimizer** in una finestra di dimensione L è il ***k -mer*** più piccolo secondo un ordinamento
- **Esempio:** genoma **ATGCCGTACGT**, $L=6$, $k=3$

Minimizers

- Un **minimizer** in una finestra di dimensione L è il ***k-mer*** più piccolo secondo un ordinamento
- **Esempio:** genoma **CTGCCGTAC**, $L=6$, $k=3$

012345

 - Prendiamo una prima sequenza di **6** basi: **CTGCCG**. Abbiamo 4 possibili **3mers**:
 - Posizione 0-2: CTG
 - Posizione 1-3: TGC
 - Posizione 2-4: GCC
 - Posizione 3-5: CCG

3-mers

Minimizers

- Un **minimizer** in una finestra di dimensione L è il ***k*-mer** più piccolo secondo un ordinamento

- **Esempio:** genoma CTGCCGTAC, $L=6$, $k=3$

012345

- Prendiamo una prima sequenza di 6 basi: CTGCCG. Abbiamo 4 possibili 3mers:

- Posizione 0-2: CTG
- Posizione 1-3: TGC
- Posizione 2-4: GCC
- Posizione 3-5: CCG

Ordine alfanumerico

CCG < CTG < GCC < TGC

Il minimizer è CCG in posizione 3

3-mers

Minimizers

- Un **minimizer** in una finestra di dimensione L è il *k -mer* più piccolo secondo un ordinamento

- **Esempio:** genoma **CTGCCGTAC**, $L=6$, $k=3$

1 2 3 4 5 6

- Prendiamo una seconda sequenza di **6** basi: **TGCCGT**. Abbiamo 4 possibili **3mers**:

- Posizione 1-3: TGC
- Posizione 2-4: GCC
- Posizione 3-5: CCG
- Posizione 4-6: CGT

Minimizers

- Un **minimizer** in una finestra di dimensione L è il **k -mer** più piccolo secondo un ordinamento

Stesso minimizer!!!

- **Esempio:** genoma **CTGCCGTAC**, $L=6$, $k=3$

1 2 3 4 5 6

- Prendiamo una seconda sequenza di **6** basi: **TGCCGT**. Abbiamo 4 possibili 3mers:

- Posizione 1-3: TGC
- Posizione 2-4: GCC
- Posizione 3-5: CCG
- Posizione 4-6: CGT

3-mers

Ordine alfanumerico

CCG < CGT < GCC < TGC

Il minimizer è CCG in posizione 3

Minimizers

- Un **minimizer** in una finestra di dimensione L è il **k -mer** più piccolo secondo un ordinamento

Nuovamente stesso
minimizer!!!

- **Esempio:** genoma CT**GCCG**TAC, $L=6$, $k=3$

234567

- Prendiamo ora una **terza** sequenza di **6** basi: **GCCGTA**. Abbiamo 4 possibili **3mers**:

- Posizione 2-4: GCC
- Posizione 3-5: CCG
- Posizione 4-6: CGT
- Posizione 5-7: GTA

3-mers

Ordine alfanumerico

CCG < CGT < GCC < GTA

Il minimizer è **CCG** in posizione 3

Minimizers

- Un **minimizer** in una finestra di dimensione L è il **k -mer** più piccolo secondo un ordinamento

Ancora lo stesso minimizer!

- **Esempio:** genoma CTG**CCGTAC**, $L=6$, $k=3$

3 4 5 6 7 8

- Prendiamo ora una **quarta** sequenza di **6** basi: **CCGTAC**. Abbiamo 4 possibili **3mers**:

- Posizione 3-5: CCG
- Posizione 4-6: CGT
- Posizione 5-7: GTA
- Posizione 6-8: TAC

3-mers

Ordine alfanumerico

CCG < CGT < GTA < TAC

Il minimizer è **CCG** in posizione 3

Minimizers

- Un **minimizer** in una finestra di dimensione L è il ***k-mer*** più piccolo secondo un ordinamento

Ancora lo stesso minimizer!

- **Esempio:** genoma CTG**CCG**TAC, $L=6$, $k=3$
 - Rappresentiamo l'intera sequenza CTGCCGTAC con un solo kmer **CCG**:

Minimizers

- Un **minimizer** in una finestra di dimensione L è il k -mer più piccolo secondo un ordinamento (in genere una funzione di hashing).
- L'idea è di rappresentare una sequenza con pochi **k-mers sparsi che rappresentino la struttura generale della sequenza** senza dover ricordarla ed esaminarla per intero.
- **Molti k-mer sovrapposti sono rappresentati dallo stesso minimizer!**



Stesso minimizer!!!

Minimizers

- Un **minimizer** in una finestra di dimensione L è il k -mer più piccolo secondo un ordinamento (in genere una funzione di hashing).
- L'idea è di rappresentare una sequenza con pochi **k-mers sparsi che rappresentino la struttura generale della sequenza** senza dover ricordarla ed esaminarla per intero.
- **Molti k-mer sovrapposti sono rappresentati dallo stesso minimizer!**
- **Perdiamo informazione, ma comprimiamo molto e la maggior parte degli errori non distruggono il minimizer**

Minimizers


Una tecnica per rappresentare sequenze (qui con perdita di informazione!)* con una frazione minima dello spazio



*La trasformata di Burrow-Wheeler è invece **lossless**, cioè l'intera sequenza può essere ricostruita

Minimizers

Errori



ACGTGAGGGTGAGTG AACAT GGCGAGCAATA
CGTGAC **C**GTGAGTG AACAT GGCGAGCAATAG
GTGACG---AGTG AACAT GGCGAGCAA---C
TGACGGTGAGTG AACAT GGC **C**AGCAATAGCT
GACGGT **CC**GTG AACAT GGCGAGCAATAGCTA


- **Perdiamo informazione, ma comprimiamo molto e la maggior parte degli errori non distruggono il minimizer**

Minimizers

Errori

```
ACGTGAGGGTGAGTGAAAATGGCGAGCAATA
CGTGACCGTGAGTGAAAATGGCGAGCAATAG
GTGACG---AGTGAAAATGGCGAGCAA---C
TGACGGTGAGTGAAAATGGCCAGCAATAGCT
GACGGTCCGTGAAAATGGCGAGCAATAGCTA
```


Mapping con minimizers:



- Questo permette di “allineare” e “mappare” rapidamente reads solo sulla base della presenza/assenza di specifici minimizers

Minimizers

Mapping con minimizers:



- Questo permette di “allineare” e “mappare” rapidamente reads solo sulla base della presenza/assenza di specifici minimizers

Minimizers

Errori

```
ACGTGAGGGTGAGTGAAAATGGCGAGCAATA
CGTGACCGTGAGTGAAAAATGGCGAGCAATAG
GTGACG---AGTGAAAATGGCGAGCAA---C
TGACGGTGAGTGAAAATGGCCAGCAATAGCT
GACGGTCCGTGAAAATGGCGAGCAATAGCTA
```

Mapping con minimizers:

Costruzione di
Minimizers e
«dimentico» la
Sequenza originale




- Questo permette di “allineare” e “mappare” rapidamente reads solo sulla base della presenza/assenza di specifici minimizers

Minimizers

Errori

```
ACGTGAGGGTGAGTGAAAATGGCGAGCAATA
CGTGACCGTGAGTGAAAAATGGCGAGCAATAG
GTGACG---AGTGAAAATGGCGAGCAA---C
TGACGGTGAGTGAAAATGGCCAGCAATAGCT
GACGGTCCGTGAAAATGGCGAGCAATAGCTA
```

Mapping con minimizers:



- Questo permette di “allineare” e “mappare” rapidamente reads solo sulla base della presenza/assenza di specifici minimizers


I minimizer sono robusti ad errori, variazioni strutturali

- Uno può essere mancare in una delle due sequenze corrispondenti (a causa di errori o variazioni) ma per reads lunghe la struttura generale dei minimizers non cambia
- Possono essere utilizzati come dei «**seed**» **dispersi** per ancorare lunghe reads con molti errori e variazioni
- Utilizzati in assemblaggio, mappatura, metagenomica, etc.

Application of minimizers in read alignment

Seeding with minimizers

Storing reference minimizers in hash table



I minimizer sono robusti ad errori, variazioni strutturali

- Uno può essere mancare in una delle due sequenze corrispondenti (a causa di errori o variazioni) ma per reads lunghe la struttura generale dei minimizers non cambia
- Possono essere utilizzati come dei «**seed**» **dispersi** per ancorare lunghe reads con molti errori e variazioni
- Utilizzati in assemblaggio, mappatura, metagenomica, etc.

Application of minimizers in read alignment




Fig. 4 Application of minimizers in read alignment. A typical read aligner that follows the seed-chain-align approach first finds reference minimizers and stores them in a hash table. Seeds are substrings (minimizers) from the reference or the read. Seeds that match between the read and the reference are called anchors, which are found by querying the read minimizers in the hash table. Then, anchors are chained together and finally bases are aligned

Calcolare i minimizers con $k=4$ e $L=8$ per la sequenza ATTCAATACATAAC



Sequenza originale

A T T C A A T A C A T A A C

minimizza dello
line da 8

1	A	T	T	C	A	A	T	A	}	AATA
2	T	T	C	A	A	T	A	C		AATA
3	T	C	A	A	T	A	C	A		AATA
3	C	A	A	T	A	C	A	T		AATA
4	A	A	T	A	C	A	T	A		AATA
5	A	T	A	C	A	T	A	A		ACAT
6	T	A	C	A	T	A	A	C	ACAT	

AATA

Ⓢ

ACAT


solo i possibili minimizza
ne K=4 a L=8

Questi sarebbero tutti i possibili
K mer per questa line da 8


A T T C A A T A

ATTC, TTCA, TCAA, CAAT, AATA

L'ordine lexicografico/alfabetico/alfanumerico ha qualcosa di speciale? E' buono o ideale?



Un minimizer ideale



Assolutamente arbitrario! Ma in effetti raramente usato perché subottimale!

L'ordine lexicografico/alfabetico/alfanumerico ha qualcosa di speciale? E' buono o ideale?



Assolutamente arbitrario! Ma in effetti raramente usato perché **subottimale**:
I minimiers tendono ad essere accorpati, mentre li vorremmo piu' distanti possibili

AGCATGCA**AA**TGGCATTACGTACGA**AA**ACGT**CAG**TTGC**AA**AA**TGT**GCATACACAAAG

Vari schemi per trovare «ordini» ideali

- In genere un ordine casuale (predefinito con pseudocasualmente) garantisce una distanza media ed una dispersione maggiore dei minimizers





Fig. 3 An example implementation of a minimizers scheme using a hash function for ordering. In this case, the hash function calculates the remainder of the values assigned to each k-mer divided by 13. The k-mer with the lowest hash value in a window is selected as the minimizer. For the last window, we break the tie between ⁷ACC and ⁹CTT with hash value of 5, by selecting the one starting at the leftmost position resulting in ⁷ACC

Piu' è grande L piu' sparsi sono i minimizers



Applicazioni dei minimizers: *mapping*



Application of minimizers in read alignment

Seeding with minimizers

Storing reference minimizers
in hash table


Reference genome
minimizers



Hash Table


key	value
reference minimizer	positions
—	1000
—	1100
—	2000
—	1120
—	1700
⋮	

minimizers
Sequencing read



Query read minimizers
in hash table

Finding anchors



Chaining and aligning



Fig. 4 Application of minimizers in read alignment. A typical read aligner that follows the seed-chain-align approach first finds reference minimizers and stores them in a hash table. Seeds are substrings (minimizers) from the reference or the read. Seeds that match between the read and the reference are called anchors, which are found by querying the read minimizers in the hash table. Then, anchors are chained together and finally bases are aligned

Applicazioni dei minimizers: *mapping*

- Softwares:
- *minimap2* (standard, usatissimo)


Per HiFi (lunghe e precise) reads

```
minimap2 -ax map-hifi ref.fa sequences.fq
```

Per paired-end Illumina reads

```
minimap2 -ax sr ref.fa R1.fastq.gz R2.fastq.gz
```

Short Reads. `-ax` definisce i parametri ideali per quel tipo di reads



Applicazioni dei minimizers: *mapping*

- Softwares:
- *minimap2* (standard, usatissimo)

Per HiFi (lunghe e precise) reads


```
minimap2 -ax map-hifi ref.fa sequences.fq
```

Per paired-end Illumina reads

```
minimap2 -ax sr ref.fa R1.fastq.gz R2.fastq.gz
```

Short Reads. `-ax` definisce i parametri ideali per quel tipo di reads

- *winnowmap* (come *minimap2* ma piu' adatto per genomi ripetuti)



Applicazioni dei minimizers: *mapping*

- Softwares:
- *minimap2* (standard, usatissimo)

Per HiFi (lunghe e precise) reads


```
minimap2 -ax map-hifi ref.fa sequences.fq
```

Per paired-end Illumina reads

```
minimap2 -ax sr ref.fa R1.fastq.gz R2.fastq.gz
```

Short Reads. `-ax` definisce i parametri ideali per quel tipo di reads

- *winnowmap* (come *minimap2* ma piu' adatto per genomi ripetuti)



Applicazioni dei minimizers: *assembly*

- Softwares:
- *minimap2* + *miniasm*
- *Esempio da lezione assemblaggio:*

1) Usiamo minimap2 per mappare tutte le reads contro tutte (trovare gli overlap); ax ont perché usavamo reads ONT nanopore

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



Applicazioni dei minimizers: *assembly*

- Softwares:
- *minimap2* + *miniasm*
- *Esempio da lezione assemblaggio:*

1) Usiamo minimap2 per mappare tutte le reads contro tutte (trovare gli overlap); ax ont perché usavamo reads ONT nanopore

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

2) Usiamo miniasm per combinare gli overlaps trovati da minimap2 in contigs/unitigs (Layout)

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

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



Applicazioni dei minimizers: *assembly*

Questo processo a steps viene anche definito **OLC** (overlap-layout-consensus) ed è in pratica il processo con cui vengono risolti gli overlap-graph : si trovano gli **Overlap**, si risolve il **Layout** creando i contigs piu' apparenti, e poi si stabilisce un **Consensus** (con altri programmi) per raffinare l'assemblaggio

- Softwares:
- *minimap2 + miniasm*
- *Esempio da lezione assemblaggio:*

3) Usiamo minimap2 e racon per fare «polishing»: mappare reads sul genoma assemblato per correggere iterativamente errori

```
minimap2 -x map-ont -t4 asm.raw.fasta sweet-potato-chloroplast-nanopore-reduced.fastq > map1.paf
```

```
racon -t4 sweet-potato-chloroplast-nanopore-reduced.fastq map1.paf  
asm.raw.fasta > asm.racon1.fasta
```

Ulteriori rounds opzionali

```
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
```

Applicazioni dei minimizers: *assembly*

Questo processo a steps viene anche definito **OLC** (overlap-layout-consensus) ed è in pratica il processo con cui vengono risolti gli overlap-graph : si trovano gli **Overlap**, si risolve il **Layout** creando i contigs piu' apparenti, e poi si stabilisce un **Consensus** (con altri programmi) per raffinare l'assemblaggio

- Softwares:
- *minimap2 + miniasm*
- *Esempio da lezione assemblaggio:*

4) Possiamo anche usare reads corte (quindi bwa) e pilon per fare polishing:

```
bwa index asm.racon2.fasta
```

```
bwa mem -t8 asm.racon2.fasta sweet-potato-chloroplast-illumina-reduced.fastq\  
  | samtools view -b -F 0x904 - | samtools sort -@8 -o illumina.pe.sorted.bam  
samtools index illumina.pe.sorted.bam
```

```
pilon --genome asm.racon2.fasta \  
      --frags illumina.pe.sorted.bam \  
      --fix snps,indels --mindepth 5 \  
      --threads 8 --output asm.pilon1
```

Applicazioni dei minimizers: *assembly*

- Softwares:
- *minimap2 + miniasm*
- *Esempio da lezione assemblaggio:*

4) Possiamo anche usare reads corte (quindi bwa) e pilon per fare polishing:

```
bwa index asm.racon2.fasta
```

```
bwa mem -t8 asm.racon2.fasta sweet-potato-chloroplast-illumina-reduced.fastq\  
| samtools view -b -F 0x904 - | samtools sort -@8 -o illumina.pe.sorted.bam  
samtools index illumina.pe.sorted.bam
```

```
pilon --genome asm.racon2.fasta \  
--frags illumina.pe.sorted.bam \  
--fix snps,indels --mindepth 5 \  
--threads 8 --output asm.pilon1
```

Le reads corte permettono di raffinare l'assemblaggio di un genoma, riducendone gli errori, e la rappresentazione di individui e popolazioni. Ma è opportuno che siano guidate dalle long-reads (in fase di assemblaggio) altrimenti da sole non riescono e portano fuori strada.



Applicazioni dei minimizers: *assembly*

Questo processo a steps viene anche definito **OLC** (overlap-layout-consensus) ed è in pratica il processo con cui vengono risolti gli overlap-graph : si trovano gli **Overlap**, si risolve il **Layout** creando i contigs piu' apparenti, e poi si stabilisce un **Consensus** (con altri programmi) per raffinare l'assemblaggio

- Softwares:
- *raven*
- *Esempio da lezione assemblaggio:*

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

Applicazioni dei minimizers: *metagenomica*



The Importance of the **MICROBIOME**

By the Numbers



10-100 trillion

Number of symbiotic microbial cells harbored by each person, primarily bacteria in the gut, that make up the human microbiota

90%



Up to 90% of all disease can be reached in some way back to the gut and health of microbiome

>10,000

Number of different microbe species researchers have identified living in the human body

10X



There are 10 times as many outside organisms as there are human cells in the human body

100 to 1


The genes in our microbiome outnumber the genes in our genome by about 100 to 1

22,000

Approximate number genes in the human gene catalog

3.3 million

Number of non-redundant genes in the human gut microbiome



99.9%

Percentage individual humans are identical to one another in terms of host genome



80%- 90%

Percentage individual humans are different from another in terms of the microbiome

Applicazioni dei minimizers: *metagenomica*

- **Competitive mapping**

Mappaggio delle sequenze su una referenza concatenata

Pros:

- La “disambiguazione” è built-in alla mappatura: semplice concettualmente
- Assegna una reads direttamente ad una specie o gruppo di specie
- Pulisce da “contaminazione” rispetto a mapping su una sola specie

Cons:


- Necessita di molti calcoli e memoria
- Bias dovuto alle specifiche referenze incluse

Applicazioni dei minimizers: *metagenomica*

- Competitive mapping

Article

A 2-million-year-old ecosystem in Greenland uncovered by environmental DNA



Kjaer et al., 2022, *Nature*

- Competitive BLASTing (Megan)

PALEOGENOMICS

Neandertal and Denisovan DNA from Pleistocene sediments





Fig. 1. Ancient taxa detected in Late Pleistocene (LP) and Middle Pleistocene (MP) sediment samples from seven sites. For each time period, the fraction of samples containing DNA fragments that could be assigned to a mammalian family and authenticated to be of ancient origin is indicated. The shaded symbols representing each family are not to scale.

Applicazioni dei minimizers: *metagenomica*

- **Assemblaggio di metagenomi**

Assemblare direttamente utilizzando short e long-reads da comunità. Minimizers sono usati per facilitare l'assemblaggio, di fatto trovando overlap tra reads dello stesso organismo



Applicazioni dei minimizers: *metagenomica*

- **Assemblaggio di metagenomi**

Assemblare direttamente utilizzando short e long-reads da comunità. Minimizers sono usati per facilitare l'assemblaggio, di fatto trovando overlap tra reads dello stesso organismo

Pros:

- Permette di scoprire specie nuove
- No bias dovuti alla referenza

Cons:

- Più difficile computazionalmente e richiede idealmente anche long-reads
- Non tutti i genomi vengono ricostruiti

Applicazioni dei minimizers: *metagenomica*

- **Assemblaggio di metagenomi**

Assemblare direttamente utilizzando short e long-reads da comunità. Minimizers sono usati per facilitare l'assemblaggio, di fatto trovando overlap tra reads dello stesso organismo

Pros:

- Permette di scoprire specie nuove
- No bias dovuti alla referenza




Cons:

- Più' difficile computazionalmente e richiede idealmente anche long-reads
- Non tutti i genomi vengono ricostruiti

- **In pratica:**

- minimap2 ➡ miniasm ➡ metaProb2 (calcola proporzioni di specie)


Applicazioni dei minimizers: *metagenomica*



- metaMDBG (minimizers per raggruppare reads e poi De Bruijn graphs)

Applicazioni dei minimizers: *metagenomica*

Assemblaggio di metagenomi> diversi genomi hanno diverse percentuali di GC




Wey et al., 2020, G3

Genoma di *Leptolipina heterotoma*, una vespa parassitoide di larva di *Drosophila*

Applicazioni dei minimizers: *metagenomica*

Assemblaggio di metagenomi > diversi genomi hanno diverse percentuali di GC



Wey et al., 2020, G3

Genoma di *Leptolipina heterotoma*, una vespa parassitoide di larva di *Drosophila*

Applicazioni dei minimizers: *metagenomica*

- **Metodi basati su k-mers (Kraken)**


Ogni k-mer viene associato ad un gruppo tassonomico di cui quel k-mer è distintivo.

Pros:

- Potente
- Esplora sistematicamente tutti i k-mer distintivi

Cons:

- Database gigantesco di tutti i k-mer di molte specie
- Necessari oltre 70Gb di memoria (almeno) che aumenta con piu' genomi inclusi



Applicazioni dei minimizers: *metagenomica*

- **Metodi basati su minimizers (Kraken2)**


Simile a kraken ma non viene salvato ogni k-mer ma minimizers rappresentativi

Pros:

- Necessita molta meno memoria (10Gb)
- Può includere database piu' estesi

Cons:

- In principio leggermente piu' impreciso di Kraken perché non tutti i k-mer sono usati



come utilizzarne una marea




Costruzione degli indici suffix array e trasformata Burrow-Wheeler

ACGTTGAC

←
TCTTTGAC

Figure 1 illustrates the evolution of a 10-nucleotide sequence (S10) from an ancestral state (S0) through a series of mutations. The sequence is represented as a 10x10 grid of nucleotides (A, C, G, T) at each position. The sequence is labeled 'ana' at the top and bottom. The sequence is shown at three stages: S0 (top), S1 (middle), and S2 (bottom). The sequence is shown at three stages: S0 (top), S1 (middle), and S2 (bottom). The sequence is shown at three stages: S0 (top), S1 (middle), and S2 (bottom).

Ricerca del «ciclo Euleriano»*



*con l'algoritmo di Leo la formica

Mappatura con Burrow-Wheeler – ideale per Illumina short reads

Costruzione degli indici
suffix array e trasformata Burrow-Wheeler

panamabananas\$	panamabananas\$	Partial Suffix Array
\$1panamabananas1	\$1panamabananas1	13
a1bananas\$panam1	a1bananas\$panam1	5
a2mabananas\$pan1	a2mabananas\$pan1	3
a3namabananas\$pan1	a3namabananas\$pan1	1
a4nanas\$panamab1	a4nanas\$panamab1	7
a5nas\$panamabab2	a5nas\$panamabab2	9
a6s\$panamababan3	a6s\$panamababan3	11
b1ananas\$panama1	b1ananas\$panama1	6
m1abananas\$pana2	m1abananas\$pana2	4
n1amabananas\$pa3	n1amabananas\$pa3	2
n2anas\$panamaba4	n2anas\$panamaba4	8
n3as\$panamabana5	n3as\$panamabana5	10
p1anamabananas\$1	p1anamabananas\$1	0
s1\$panamabananaa6	s1\$panamabananaa6	12



Partenza da un seed


ACGTTGAC

Estensione del seed

sfruttando proprietà First-Last di BWT
fino al massimo degli errori



TGACCGA

TCTTTGAC



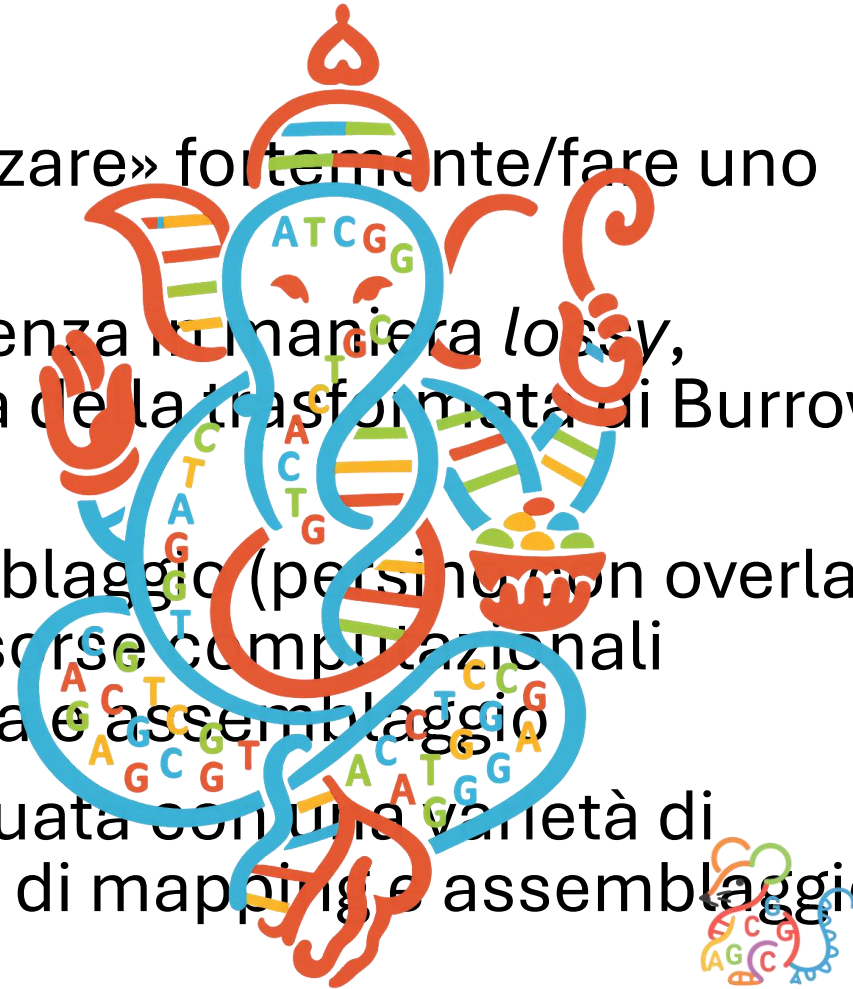
Assemblaggio/Mappatura con minimizers – ideale per long reads

Genoma di riferimento o altra read



Conclusioni


- I minimizers permettono di «sintetizzare» fortemente/fare uno sketch di sequenze
- I minimizers rappresentano la sequenza in maniera *lossy*, perdendo informazione, a differenza della trasformata di Burrow-Wheeler
- Permettono la mappatura e l'assemblaggio (persino non overlap-graph) di long-reads riducendo le risorse computazionali necessarie per risolverne mappatura e assemblaggio
- La metagenomica può essere effettuata con una varietà di approcci, basata su metodi ordinari di mapping e assemblaggio, k-mers e minimizers



Quasi ogni analisi di genomica necessita mappatura

Espressione genica

Quali geni sono espressi in questa linea tumorale?




Assemblaggio di genomi

«Polishing» con short reads



GWAS e genetica di popolazione

Quali varianti causano il diabete?



Paleogenomica e genetica forense

Questo osso è autentico ed antico?

Metagenomica

Quali specie sono presenti in questo campione?

Biologia molecolare, chip-seq ed epigenomica

Che geni regola questo fattore di trascrizione?

Quali regioni hanno questa modifica della cromatina?

