



I 7 ponti di Kaliningrad o Come assemblare un genoma


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

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

L'assemblaggio

Dal sequenziatore..

..al genoma



sequenze

assemblaggio



Formati di file bioinformatici

.fastq

.fasta

Cosa vedremo oggi

- Perché è difficile assemblare
- Algoritmi per assemblare:
 - Overlap-graphs
 - De Bruijn graphs
- Concetti generali delle scienze computazionali (“Teoria dei grafi”, algoritmi polinomiali ed intrattabili)
- Applicazioni specifiche a tipologie di dati di sequenziamento e problemi dei “genomi veri”
 - Il problema delle ripetizioni
 - Scaffolding
 - Assemblare con sequenze lunghe e corte

La prossima lezione

- Pratica di assemblaggio di genomi con strumenti bioinformatici

Cosa vedremo oggi


- Perché è difficile assemblare
- Algoritmi per assemblare:
 - Overlap-graphs
 - De Bruijn graphs
- Concetti generali delle scienze computazionali (“Teoria dei grafi”, algoritmi polinomiali ed intrattabili)
- Applicazioni specifiche a tipologie di dati di sequenziamento e problemi dei “genomi veri”
 - Il problema delle ripetizioni
 - Scaffolding
 - Assemblare con sequenze lunghe e corte

Importanti in altri ambiti, ad esempio pangenomica, genomica comparativa (ricostruzione di sintenia e ortologia), reti metaboliche e di regolazione genica, struttura 3D del genoma, etc.



La prossima lezione

- Pratica di assemblaggio di genomi con strumenti bioinformatici




Materiale didattico

La lezione è basata su questo capitolo dal libro «Bioinformatics Algorithms» e un paio di review allegate su Moodle.


Li e Durbin, 2024, Nature Reviews Genetics
Rise e Green, 2019, Annu.Rev.Anim.Bio.



© Burrard-Lucas.com



Argomento difficile..ma alla base degli sforzi internazionali per comprendere tutto questo








FIGURE 3.3 The first mammals with sequenced genomes.

Library schematic	Output
Illumina 	Sequenze corte (50-250 bp) e relativamente accurate. Economico quindi alta coverage. Ad oggi ancora il 75% circa dei dati presenti.

Library schematic	Output
Illumina 	Sequenze corte (50-250 bp) e relativamente accurate. Economico quindi alta coverage. Ad oggi ancora il 75% circa dei dati presenti.
PacBio 	Sequenze HiFi accurate (errore < 0.5%) e lunghe >10kb.
Oxford Nanopore 	Sequenze ultra-lunghe di anche >100kb ma con errore <10%

Library schematic	Output
Illumina 	Sequenze corte (50-250 bp) e relativamente accurate. Economico quindi alta coverage. Ad oggi ancora il 75% circa dei dati presenti.
PacBio 	Sequenze HiFi accurate (errore < 0.5%) e lunghe >10kb.
Oxford Nanopore 	Sequenze ultra-lunghe di anche >100kb ma con errore <10%
Hi-C ed altre tecnologie	Informazioni a lungo raggio, fino a 10Mb






FIGURE 3.1 Don't try this at home! Crazy as it may seem, the Newspaper Problem serves as an analogy for the computational framework of genome assembly.



Genomic DNA

Reads

Draft Genome
Sequence

Closed Genome
Sequence

Caratteristiche del Newspaper Problem

atshirt, approx
e have not yet named a
information is welc

shirt, approximately 6'2" 18
t yet named any suspects
is welcomed. Please call


FIGURE 3.2 In the Newspaper Problem, we need to use overlapping shreds of paper to figure out the news.

- Copie multiple del giornale, quindi alcune frasi possono essere ripetute
- Nell'esplosione alcune parti possono essere andate distrutte
- Alcune lettere possono essere lette erroneamente

Shakespearomics

- ***Reads***

ds, Romans, count
ns, countrymen, le
Friends, Rom
send me your ears;
crymen, lend me



Shakespeareomics


Strategia 1: cerchiamo le parti di parola sovrapposte (overlaps)

- **Reads**

ds, Romans, count
ns, countrymen, le
Friends, Rom
send me your ears;
crymen, lend me

- **Overlaps**

Friends, Rom
ds, Romans, count
ns, countrymen, le
crymen, lend me
send me your ears;




Shakespearomics

Strategia 1: cerchiamo le parti di parola sovrapposte (overlaps) e correggiamo gli errori prendendo la lettera piu' comune (consensus)

- **Reads**

ds, Romans, count
ns, countrymen, le
Friends, Rom
send me your ears;
crymen, lend me

We have a
consensus!




- **Overlaps**

Friends, Rom
ds, Romans, count
ns, countrymen, le
crymen, lend me
send me your ears;


- **Majority consensus**

Friends, Romans, countrymen, lend me your ears;

Multiple identical
copies of a genome



Shatter the genome
into reads



Sequence the reads

AGAATATCA

TGAGAATAT

GAGAATATC

Assemble the
genome using
overlapping reads

AGAATATCA

GAGAATATC

TGAGAATAT

...TGAGAATATCA...

Evviva, abbiamo risolto il problema! Basta trovare gli overlap e correggere gli errori con un consenso. Lezione finita!



Evviva, abbiamo risolto il problema! Basta trovare gli overlap e correggere gli errori con un consenso. Lezione finita!

Ma non è
così
semplice..



La ricostruzione di una stringa

- Assemblare equivale a ricostruire una stringa (ad esempio **TAATGTT**) a partire da dei suoi frammenti:

T AA AA GTT GTT AATG TGTT AA TT G
ATG TAAT AAT ATG T ATGTT G TT A T

La ricostruzione di una stringa

- Assemblare equivale a ricostruire una stringa (ad esempio **TAATGTT**) a partire da dei suoi frammenti:

T AA AA GTT GTT AATG TGTT AA TT G
ATG TAAT AAT ATG T ATGTT G TT A T

- Per iniziare, semplifichiamo il problema assumendo che:
 - I suoi frammenti abbiano tutti la stessa lunghezza
 - Ogni frammento sia ripetuto una sola volta

La ricostruzione di una stringa

- Assemblare equivale a ricostruire una stringa (ad esempio **TAATGTT**) a partire da dei suoi frammenti:

T AA AA GTT GTT AATG TGTT AA TT G
ATG TAAT ATG T ATGTT G TT A T

- Per iniziare, semplifichiamo il problema assumendo che:
 - I suoi frammenti abbiano tutti la stessa lunghezza
 - Ogni frammento sia ripetuto una sola volta

AAT ATG GTT TAA TGT

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare?

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare? Nessun 3-mero finisce con TA, quindi TAA deve essere all'inizio.

TAA

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare? Nessun 3-mero finisce con TA, quindi TAA deve essere all'inizio.

TAA

TAA

AAT**T**

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare? Nessun 3-mero finisce con TA, quindi TAA deve essere all'inizio.

TAA

TAA

TAA

AAT**T**

AAT**T**

AT**G**

Un esempio semplice **TAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare? Nessun 3-mero finisce con TA, quindi TAA deve essere all'inizio.

TAA

TAA

TAA

TAA

AAT**T**

AAT**T**

AAT**T**

AT**G**

AT**G**

TGT**T**

Un esempio semplice **TAAATGTT**

- Possiamo suddividerla nei 3-meri

AAT ATG GTT TAA TGT

- Da dove iniziare? Nessun 3-mero finisce con TA, quindi TAA deve essere all'inizio.

TAA

TAA

TAA

TAA

TAA

AAT**T**

AAT**T**

AAT**T**

AAT**T**

AT**G**

AT**G**

AT**G**

TGT**T**

TGT**T**

GTT**T**

TAAATGTT



Il nostro primo assemblaggio di DNA!

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT

- Cominciamo ad assemblare i nostri 3meri da TAA come prima, visto che nessuno termina con TA.

TAA

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT

- Cominciamo ad assemblare i nostri 3meri da TAA come prima, visto che nessuno termina con TA.
- Il prossimo 3mero dovrebbe cominciare con AA, quindi abbiamo solo AAT. E poi, AAT puo' essere esteso solo da ATG.

TAA
AAT
ATG
TAATG

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC TGG TGT**

- Cominciamo ad assemblare i nostri 3meri da TAA come prima, visto che nessuno termina con TA.
- Il prossimo 3mero dovrebbe cominciare con AA, quindi abbiamo solo AAT. E poi, AAT puo' essere esteso solo da ATG.
- Ora possiamo scegliere vari che iniziano con TG. Avete un preferito?

TAA
 AAT
 ATG
 TAATG

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT

- Cominciamo ad assemblare i nostri 3meri da TAA come prima, visto che nessuno termina con TA.
- Il prossimo 3mero dovrebbe cominciare con AA, quindi abbiamo solo AAT. E poi, AAT puo' essere esteso solo da ATG.
- Ora possiamo scegliere vari che iniziano con TG. Avete un preferito? Scegliamo TGT.

TAA
AAT
ATG
TAATG

TAA
AAT
ATG
TGT
TAATGT

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC** **TGG** **TGT**

- Cominciamo ad assemblare i nostri 3meri da TAA come prima, visto che nessuno termina con TA.
- Il prossimo 3mero dovrebbe cominciare con AA, quindi abbiamo solo AAT. E poi, AAT puo' essere esteso solo da ATG.
- Ora possiamo scegliere vari che iniziano con TG. Avete un preferito? Scegliamo TGT. A poi continuiamo..oopps, bloccati!!!

TAA
AAT
ATG
TAATG

TAA
AAT
ATG
TGT
TAATGT

TAA
AAT
ATG
TGT
GTT
TAATGTT

← Non abbiamo nessun 3mero che comincia con TT!!

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC** TGG TGT

- Torniamo indietro

TAA
AAT
ATG
TAATG

TAA
AAT
ATG
TGC
TAATGC

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC** TGG TGT

- Torniamo indietro
- Proseguendo, possiamo completare l'assemblaggio della sequenza

TAA
AAT
ATG
TAATG

TAA
AAT
ATG
TGC
TAATGC



TAA
AAT
ATG
TGC
GCC
CCA
CAT
ATG
TGG
GGA
GAT
ATG
TGT
GTT
TAATGCCATGGATGTT

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC** TGG **TGT**

- Perché questa sequenza ci ha causato questo problema? Perché abbiamo dovuto riniziare?

TAA
AAT
ATG
TGT
GTT
TAATGTT

TAA
AAT
ATG
TGC
GCC
CCA
CAT
ATG
TGG
GGA
GAT
ATG
TGT
GTT
TAATGCCATGGATGTT

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA **TGC** **TGG** **TGT**

- Perché questa sequenza ci ha causato questo problema? Perché abbiamo dovuto riniziare?
- Il trimero ATG (e quindi ATG) era ripetuto tre volte, portandoci a percorsi alternativi.

TAA
AAT
ATG
TGT
GTT
TAATGTT

TAA
AAT
ATG
TGC
GCC
CCA
CAT
ATG
TGG
GGA
GAT
ATG
TGT
GTT
TAATGCCATGGATGTT

Un esempio leggermente piu' realistico

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT


- Perché questa sequenza ci ha causato questo problema? Perché abbiamo dovuto riniziare?
- Il trimero ATG (e quindi ATG) era ripetuto tre volte, portandoci a percorsi alternativi.
- Per casi semplici è risolvibile (as esempio nel nostro esempio o nel gioco Triazzle).

Immaginate però per milioni e milioni di ripetizioni..




Come risolvere efficientemente il nostro esempio leggermente piu' realistico?

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT



L'assemblaggio come un percorso nell' "overlap graph"

AAT ATG ATG ATG CAT CCA GAT GCC GGA GGG GTT TAA TGC TGG TGT



Qualche definizione/sinonimo:


path: *percorso*

overlap graph: *grafo delle sovrapposizioni*


Possiamo rappresentare la nostra stringa come un
“overlap graph” che unisce i 3meri “sovrapposti”




Possiamo rappresentare la nostra stringa come un “overlap graph” che unisce i 3meri “sovrapposti”




Possiamo rappresentare la nostra stringa come un “overlap graph” che unisce i 3meri “sovrapposti”




Possiamo rappresentare la nostra stringa come un “overlap graph” che unisce i 3meri “sovrapposti”




Possiamo rappresentare la nostra stringa come un “overlap graph” che unisce i 3meri “sovrapposti”



Voi potreste dirmi «OK, basta seguire le frecce dritte e dimenticarsi delle altre per trovare la soluzione»..




..tuttavia non sappiamo a priori l'ordine dei trimeri. Quindi la nostra situazione è piu' simile a:




Grafo con trimeri ordinati alfabeticamente

Una definizione formale del nostro problema: **Trovare il percorso «giusto*» nell' «overlap graph».**




Una definizione formale del nostro problema: **Trovare il percorso «giusto*» nell' «overlap graph».**



*** se siete interessati ai termini:**

«giusto»: anche chiamato percorso Hamiltoniano, un percorso che passa per tutti i nodi una volta sola.

Una definizione formale del nostro problema: **Trovare il percorso «giusto*» nell' «overlap graph».**



E abbiamo già il nostro algoritmo per trovare le soluzioni:

- 1) Troviamo un trimero iniziale (che ha un prefisso che non è suffisso di nessun altro trimero).
- 2) Connettiamo il nostro trimero ad uno sovrapposto (la cui fine o «suffisso» sia uguale al prefisso del trimero successivo)
- 3) Ripetiamo per tentativi finché troviamo un percorso «giusto» (Hamiltoniano)

Nell'esempio:


TAA, perché nessun altro trimero finisce con TA

*Suffisso(TAA)=AA=Prefisso(AAT)
quindi AAT segue TAA*

*** se siete interessati ai termini:**


«giusto»: anche chiamato percorso Hamiltoniano, un percorso che passa per tutti i nodi una volta sola.

Ecco le soluzioni (seguendo il nostro algoritmo). E nel nostro caso c'erano persino due percorsi potenzialmente giusti (o Hamiltoniani)!!



Gli «overlap graphs» sono alla base di vari assemblatori moderni

(specializzati in sequenze molto lunghe e accurate).



ARTICLES

<https://doi.org/10.1038/s41592-020-01056-5>

nature | methods

Haplotype-resolved de novo assembly using phased assembly graphs with hifiasm

Haoyu Cheng^{1,2}, Gregory T. Conception³, Xiaowen Feng^{1,2}, Haowen Zhang⁴ and Heng Li^{1,2}



Method

HiCanu: accurate assembly of segmental duplications, satellites, and allelic variants from high-fidelity long reads


Sergey Nurk,^{1,6} Brian P. Walenz,^{1,6} Arang Rhie,¹ Mitchell R. Vollger,² Glennis A. Logsdon,² Robert Grothe,³ Karen H. Miga,⁴ Evan E. Eichler,^{2,5} Adam M. Phillippy,¹ and Sergey Koren¹



Svantaggi degli overlap-graphs

Tuttavia abbiamo anche visto dei problemi negli overlap graph:

- molteplici percorsi Hamiltoniani/soluzioni potenzialmente giuste
- **grafi complessi**, che diventano rapidamente* (con sequenze corte e genomi lunghi/ripetuti) **intrattabili**



Svantaggi degli overlap-graphs

Tuttavia abbiamo anche visto dei problemi negli overlap graph:

- molteplici percorsi Hamiltoniani/soluzioni potenzialmente giuste
- **grafi complessi**, che diventano rapidamente* (con sequenze corte e genomi lunghi/ripetuti) **intrattabili**





FIGURE 3.45 (Left) Hamilton's icosian game, with a winning placement of the pegs shown. (Right) The winning placement of the pegs can be represented as a Hamiltonian cycle in a graph. Each node in this graph represents a peghole on the board, and an edge connects two pegholes that are connected by a line segment on the board.



* *Trovare un percorso Hamiltoniano ad un overlap-graph è un problema NP-completo o intrattabile, cioè al crescere dei dati il tempo per risolverlo cresce esponenzialmente e non è mai stato trovato un algoritmo per risolverlo in tempo polinomiale! Se lo trovate vincerete 1 milione di dollari dal Clay Mathematics Institute!*

Proviamo a riformulare il problema

Ripartiamo dalla nostra sequenza

TAATGCCATGGATGTT

estrando i trimeri

TAA AAT ATG TGC GCC CCA CAT ATG TGG GGG GGA GAT ATG TGT GTT

Proviamo a riformulare il problema


Ripartiamo dalla nostra sequenza

TAATGCCATGGGATGTT

estrando i trimeri

TAA AAT ATG TGC GCC CCA CAT ATG TGG GGG GGA GAT ATG TGT GTT

Ora invece di assegnare i 3-meri ai nodi assegniamoli agli archi, mentre ai nodi assegniamo i 2-meri sovrapposti



Proviamo a riformulare il problema

Ripartiamo dalla nostra sequenza

TAATGCCATGGGATGTT

estrando i trimeri

TAA AAT ATG TGC GCC CCA CAT ATG TGG GGG GGA GAT ATG TGT GTT


Ora invece di assegnare i 3-meri ai nodi assegniamoli agli archi, mentre ai nodi assegniamo i 2-meri sovrapposti




Prima (nell'overlap-graph) avevamo invece






Proviamo a riformulare il problema






Proviamo a riformulare il problema






Ora, «incolliamo» i nodi uguali. Partiamo da **AT**:






Proseguiamo «**incollando**» TG..






Proseguiamo «**incollando**» **TG**..






e poi **GG**:




Proseguiamo «**incollando**» TG..




e poi **GG**.



..e allora?!




Overlap graph




De Bruijn graph

FIGURE 3.17 The overlap graph (top) and de Bruijn graph (bottom) for the same collection of 3-mers.



Overlap graph

*Voi quale
preferireste
risolvere?*




De Bruijn graph

FIGURE 3.17 The overlap graph (top) and de Bruijn graph (bottom) for the same collection of 3-mers.

I grafi di De Bruijn sono apparentemente piu' «semplici»*


*possono essere risolti
in tempo breve (polinomiale)



Il percorso per ricostruire la sequenza **TAATGCCATGGGATGTT** è indicato dai numeri dall'1 al 15. Notate che il percorso non passa mai dalla stessa freccia.

I grafi di De Bruijn sono apparentemente piu' «semplici»*


*possono essere risolti
in tempo breve (polinomiale)



Il percorso per ricostruire la sequenza **TAATGCCATGGGATGTT** è indicato dai numeri dall'1 al 15. Notate che il percorso non passa mai dalla stessa freccia.

I grafi di De Bruijn sono apparentemente piu' «semplici»*

*possono essere risolti
in tempo breve (polinomiale)






(Parentesi storica che non dovete necessariamente ricordare ma che è carina)



FIGURE 3.47 Leonhard Euler (left), William Hamilton (center), and Nicolaas de Bruijn (right).

Euler (1707-1783)



..la notazione $f(x)$ per le funzioni;


..la notazione i per la radice quadrata di -1;

..essere diventato cieco dall'occhio destro nel 1735, aver continuato a lavorare ininterrottamente, e dopo aver perso l'occhio sinistro nel 1766 aver commentato «Ora avrò meno distrazioni» ed aver continuato a pubblicare centinaia di pubblicazioni.


I 7 ponti di Königsberg



Come posso passare per i 7 ponti della città una sola volta e tornare indietro senza ripassare dallo stesso ponte?



I nodi
indicano
le **4 aree**
della città
da visitare,
e gli archi i
7 ponti




I 7 ponti di Königsberg




Il ciclo Euleriano


Come posso passare per i 7 ponti della città una sola volta e tornare indietro senza ripassare dallo stesso ponte?



I nodi
indicano
le **4 aree**
della città
da visitare,
e gli archi i
7 ponti




I 7 ponti di Königsberg



Il ciclo Euleriano


Come posso passare per i 7 ponti della città una sola volta e tornare indietro **senza ripassare dallo stesso ponte?**




E' un problema simile al nostro!

Il percorso per ricostruire la sequenza **TAATGCCATGGGATGTT** è indicato dai numeri dall'1 al 15.



Il percorso **non ripassa mai dalla stessa freccia**



I 7 ponti di Königsberg



Il ciclo Euleriano



E' un problema simile al nostro!

Il percorso per ricostruire la sequenza **TAATGCCATGGATGTT** è indicato dai numeri dall'1 al 15.


Il percorso **non ripassa mai dalla stessa freccia***

*il teorema di Eulero dimostra come sia sempre possibile trovare un ciclo Euleriano in un grafo «bilanciato», cioè dove per ogni nodo ci siano lo stesso numero di frecce che puntano dentro e fuori

Ma come
lo troviamo
questo
percorso??




Ora te lo
spiego io!




Ma come
lo troviamo
questo
percorso??




La formica Leo cerca il suo ciclo Euleriano per cercare da mangiare ovunque



La formica Leo cerca il suo ciclo Euleriano per cercare da mangiare ovunque




Ogni tanto si blocca..




..e si blocca


La formica Leo cerca il suo ciclo Euleriano per cercare da mangiare ovunque



Ogni tanto si blocca..



..e si blocca




..e si riblocca...


Cosa notate?




La formica Leo cerca il suo ciclo Euleriano per cercare da mangiare ovunque



Ogni tanto si blocca..



..e si blocca




..e si riblocca...


...tornando sempre al nodo di partenza!*

*se il grafo è bilanciato


La formica Leo cerca il suo ciclo Euleriano per cercare da mangiare ovunque



Ogni tanto si blocca..



..e si blocca



..e si riblocca...




...tornando sempre al nodo di partenza!




Questo ci suggerisce una strategia/algoritmo per aiutare Leo!!

Una strategia per aiutare Leo




Una strategia per aiutare Leo




Partendo dal nodo n_0
Leo prova un primo
percorso (Ciclo₀)

Una strategia per aiutare Leo




Partendo dal nodo n_0
Leo prova un primo
percorso (Ciclo₀)




Ritorna poi sui suoi passi,
fino al primo nodo n_1 da
cui poteva prendere piu'
di una strada

Una strategia per aiutare Leo

*Notate: Ora riparte da n_1 (non piu' da n_0),
quindi il tratto 2 del percorso
precedente diventa il tratto 1*




Partendo dal nodo n_0
Leo prova un primo
percorso (Ciclo₀)




Ritorna poi sui suoi passi,
fino al primo nodo n_1 da
cui poteva prendere piu'
di una strada

Una strategia per aiutare Leo


*Notate: Tornato ad n_1 puo' ora
proseguire per la strada non percorsa
precedentemente (in blu)*




Partendo dal nodo n_0
Leo prova un primo
percorso (Ciclo₀)




Ritorna poi sui suoi passi,
fino al primo nodo n_1 da
cui poteva prendere piu'
di una strada




Una strategia per aiutare Leo



Partendo dal nodo n_0
Leo prova un primo
percorso (Ciclo₀)




Ritorna poi sui suoi passi,
fino al primo nodo n_1 da
cui poteva prendere piu'
di una strada




Da n_1 percorre un nuovo
ciclo Ciclo₁ piu' largo,
composto dal vecchio
Ciclo₀ (ma partendo
invece da n_1) piu' il nuovo
percorso (blu)

Una strategia per aiutare Leo




Leo è nuovamente
bloccato (questa
volta ad n_1).


Una strategia per aiutare Leo



Leo è nuovamente bloccato (questa volta ad n_1).




Ripete l'operazione, ripartendo dal nodo successivo con biforcazione (n_2). Rinizia il nuovo ciclo Ciclo_2 dalla parte «rimanente» di Ciclo_1 (quindi l'8 di Ciclo_1 diventa ora 1 di Ciclo_2).



Leo ha finalmente percorso tutti i nodi con Ciclo_2 , che quindi è il ciclo Euleriano!

Quanto è «complesso» questo algoritmo?




Quanto è «complesso» questo algoritmo?



Abbiamo esplorato 3 potenziali nodi di partenza (che sono al max il numero di nodi totali).

Quindi al crescere dei dati (del grafo) il tempo impiegato cresce **SOLO polinomialmente***

*a differenza della ricerca del percorso (Hamiltoniano) nell'overlap-graph che cresceva esponenzialmente!



Quanto è «complesso» questo algoritmo?




Abbiamo esplorato 3 potenziali nodi di partenza (che sono al max il numero di nodi totali).


Quindi al crescere dei dati (del grafo) il tempo impiegato cresce **SOLO polinomialmente***

*a differenza della ricerca del percorso (Hamiltoniano) nell'overlap-graph che cresceva esponenzialmente!

Ottimo, abbiamo un algoritmo per risolvere il problema di Leo!!! Ma il nostro? Era proprio lo stesso problema?




Differenza 1: Nel caso di Leo cercavamo un ciclo Euleriano, ma per genomi lineari non abbiamo un ciclo




Non importa, basta congiungere inizio e fine della sequenza per avere un «grafo bilanciato»: ora il problema equivale a cercare un ciclo.

Differenza 2: Eravamo partiti da una grafo di De Bruijn con sequenza già conosciuta. Ma generalmente non la conosciamo. Come costruirla?



*Basta
incollare i
nodi
uguali!!!*

Differenza 3: nei dati di sequenziamento la “coverage” non è uniforme



Differenza 3: nei dati di sequenziamento la “coverage” non è uniforme

ATGCCGTATGGACAACGACT
ATGCCGTATG
GCCGTATGGA
GTATGGACAA
GACAACGACT

3 sequenze ↑

1 sequenza ↑





Figure S3.2: Coverage in bins of GC content according to a sliding window of 51bp length along the genome. Dashed lines show the average coverage over all bins and the 95% central part in this distribution. Legend: the number next to the line indicates the GC bin (5 indicates 5-9 G or C bases per 51bp window, 10 indicates 10-14, etc.); Percentages in brackets give the percentage of mappable bases that reside in each bin.

Esempio di coverage per dati reali (un genoma di Neanderthal) da Mafessoni et al., 2020, *PNAS*

Differenza 3: nei dati di sequenziamento la “coverage” non è uniforme, e le sequenze differiscono in lunghezza




Rompere in kmeri più corti risolve (parzialmente)!!

Differenza 4: abbiamo errori nelle sequenze (o bolle)




Una “bolla” causata da un errore di sequenziamento (una T letta come **C**)

Differenza 4: abbiamo errori nelle sequenze (o bolle)



In dati reali ci sono molti errori di sequenziamento (quindi molte bolle)!

Differenza 4: abbiamo errori nelle sequenze (o bolle)



In dati reali ci sono molti errori di sequenziamento (quindi molte bolle)!


Assemblatori moderni correggono queste bolle sulla base di alcune “euristiche”:

- rimuovere i **kmers rari*** prima della costruzione del grafo
- costruire il grafo e poi rimuovere i percorsi che creano bolle e sono supportati da **kmers rari**


*gli errori di sequenziamento avvengono perlopiu' casualmente, quindi è abbastanza improbabile che molti errori avvengano nella stessa posizione. Pertanto generalmente gli errori originano kmer unici o molto rari

Due approcci per assemblare un genoma


Esplorazione degli **Overlap-graph** per «forza bruta» ed usando al più delle «euristiche»



Costruzione del **De Bruijn Graph**



Ricerca del «ciclo Euleriano»*




*con l'algoritmo di Leo la formica



Gli «overlap graphs» sono alla base di vari assemblatori moderni

(specializzati in sequenze molto lunghe e accurate).



ARTICLES

<https://doi.org/10.1038/s41592-020-01056-5>

nature | methods

Check for updates

Haplotype-resolved de novo assembly using phased assembly graphs with hifiasm

Haoyu Cheng^{1,2}, Gregory T. Conception³, Xiaowen Feng^{1,2}, Haowen Zhang⁴ and Heng Li^{1,2} 



Method

HiCanu: accurate assembly of segmental duplications, satellites, and allelic variants from high-fidelity long reads

Sergey Nurk,^{1,6} Brian P. Walenz,^{1,6} Arang Rhie,¹ Mitchell R. Vollger,² Glennis A. Logsdon,² Robert Grothe,³ Karen H. Miga,⁴ Evan E. Eichler,^{2,5} Adam M. Phillippy,¹ and Sergey Koren¹




Assemblatori basati su De Bruijn graphs possono usare anche short reads

SPAdes

Aimed at short reads, small genomes, metagenomes, single-cell data



Human
Microbiome
Project



Montoliu-Nerin et al., 2020

Verkko2 integrates proximity-ligation data with long-read De Bruijn graphs for efficient telomere-to-telomere genome assembly, phasing, and scaffolding

Dmitry Antipov,^{1,4} Mikko Rautiainen,^{2,4} Sergey Nurk,³ Brian P. Walenz,¹ Steven J. Solar,¹ Adam M. Phillippy,¹ and Sergey Koren¹



High-quality metagenome assembly from long accurate reads with metaMDBG

Nature Biotechnology **42**, 1378–1383 (2024)

Gaëtan Benoit, Sébastien Raguideau, Robert James, Adam M. Phillippy, Rayan Chikhi & Christopher Quince

LJA

Multiplex de Bruijn graphs enable genome assembly from long, high-fidelity reads



Anton Bankevich , Andrey V. Bzikadze, Mikhail Kolmogorov, Dmitry Antipov & Pavel A. Pevzner 

Nature Biotechnology **40**, 1075–1081 (2022) | [Cite this article](#)

Fast and feasible for large repeated genomes like barley

Due approcci per assemblare un genoma



Esplorazione degli **Overlap-graph** per «forza bruta» ed usando al più delle «euristiche»




Applicazioni

Applicabili solo a sequenze ultralunghe e accurate, ad esempio per genomi ultracompleti (Telomere 2 Telomere).

Costruzione del **De Bruijn Graph**



Ricerca del «ciclo Euleriano»*





*con l'algoritmo di Leo la formica

Metagenomi, genomi microbici, dati vari incluse sequenze corte (illumina), ma anche phasing e genomi complessi

Due approcci per assemblare un genoma




Applicazioni

Esplorazione degli **Overlap-graph** per «forza bruta» ed usando al più delle «euristiche»



Costruzione del **De Bruijn Graph**

Ricerca del «ciclo Euleriano»*




*con l'algoritmo di Leo la formica




Come mai i De Bruijn Graphs non funzionino meglio in ogni circostanza?

- Anche se il problema diventa piu' trattabile dobbiamo necessariamente rompere in k-mers
- Per sequenze ripetute i k-mers possono introdurre molte ambiguità, risolte solamente da tecnologie in grado di dare informazione a lungo raggio o sequenze molto lunghe

Il genoma (umano) è altamente ripetitivo




Short Tandem Repeat (STR) o microsatelliti



I problemi introdotti dalle ripetizioni



- Le zone ripetute sono ricostruite erroneamente




- Piu' in generale, diventa impossibile ricostruire un genoma in modo ragionevole a causa dei molti «percorsi» errati nell'overlap graph



Tuttavia alcune regioni ripetute sono $>10\text{kb}$ e possono essere risolte solo con sequenze lunghissime e accurate (o con lo scaffolding)



In pratica, gli assemblaggi vengono ridotti a contigs non ambigui




Reads, contigs and scaffolds (in genomic context)

Genome

Reads

Contigs

Scaffold




Assemblaggio

generalmente con grafi
di de Bruijn


Scaffolding

Con informazione a lungo
raggio

Lo scaffolding permette di «unire» piu' contigs




- Proximity ligation (Hi-C)
- Linked-read sequencing (10x), amplificazione delle sequenze dentro droplets
- Enzimi che attaccano marcatori fluorescenti (BioNano)
- Approcci basati su sintenia che usano altri genomi come referenza



L'arrivo di alcune tecnologie (Hi-C) ha portato a miglioramenti nella contiguità, ma il grosso dei genomi è stato finora limitato (dalle lunghe sequenze ripetute).

Contiguità dei genomi



L'arrivo di alcune tecnologie (Hi-C) ha portato a miglioramenti nella contiguità, ma il grosso dei genomi è stato finora limitato (dalle lunghe sequenze ripetute).

Solo dal 2019 circa le sequenze accurate ultralunghe hanno permesso i primi genomi T2T con overlap-graphs

Contiguità dei genomi

Misurare la contiguità di un assemblaggio: N50

Definizione: la lunghezza del contig piu piccolo nel piu' piccolo insieme di contig che contiene il 50% del
genoma

O

Cercando di selezionare solo i contigs piu' lunghi, il valore del contig piu' piccolo con il quale riesco ancora a rappresentare almeno il 50% del genoma. Il numero di quei contigs viene definito **L50**

Esempio con 1Mb:



N50 size = 30 kbp

(300k+100k+45k+45k+30k

= 500kbp)

Alto N50, basso N50: pochi contigs molto lunghi



Basso N50, Alto L50: molti contigs corti



Misurare la contiguità di un assemblaggio: N50

Definizione: la lunghezza del contig piu piccolo nel piu' piccolo insieme di contig che contiene il 50% del
genoma

O

Cercando di selezionare solo i contigs piu' lunghi, il valore del contig piu' piccolo con il quale riesco ancora a rappresentare almeno il 50% del genoma. Il numero di quei contigs viene definito **L50**

Esempio con 1Mb:



Alto N50, basso N50: pochi contigs molto lunghi




Basso N50, Alto L50: molti contigs corti



Un tipo di ripetizioni «quasi» inevitabile: i genomi diploidi!!

- Il nostro intero genoma è ripetuto almeno una volta



Un tipo di ripetizioni «quasi» inevitabile: i genomi diploidi!!

- Una prima semplice soluzione sperimentale: non usare diploidi!
Usare individui «inbred» od omozigoti



Generazione 1



Generazione 2



Generazione 3

Un tipo di ripetizioni «quasi» inevitabile: i genomi diploidi!!

- Una prima semplice soluzione sperimentale: non usare diploidi! Usare individui «inbred» od omozigoti





Generazione 1



Generazione 2



Generazione 3




Ottenuto da una **mole idatiforme*** interamente **omozigote e con cariotipo 46XX**.

*un embrione anomalo che cresce come massa nell'utero in cui spesso uno dei due «genomi» parentali viene espulso, e che non sviluppa in un feto

Un tipo di ripetizioni «quasi» inevitabile: i genomi diploidi!!

- Una seconda strategia: utilizzo di alberi genealogici (o trio). Sequenziare anche i genitori per inferire la “fase” dei cromosomi!



Un tipo di ripetizioni «quasi» inevitabile: i genomi diploidi!!

- Un'altra strategia molto usata: ignorare il problema.



Le recenti tecnologie di sequenziamento ultra-lungo permettono oggi di affrontare il problema (siamo agli inizi)




Fig.2 | Types of phased assembly of diploid samples. The initial assembly graph can be further processed into different types of assemblies. If only accurate long-read sequence data are available, a primary–alternate assembly pair or a dual assembly pair can be generated. If long-range data (such as trio, Hi-C or strand-seq data) are available, chromosome-phased assemblies can be generated. **a**, In a primary–alternate assembly pair, the primary assembly represents a complete haploid genome with occasional phase switches whereas the alternate assembly

is fragmented and contains no homozygous regions longer than the read length. **b**, In a pair of dual assemblies, each assembly is similar to a primary assembly. **c**, In a pair of chromosome-phased assemblies, long-range data are used to partition contigs from the same haploid chromosome to the same assembly. **d**, In a pair of chromosome-phased assemblies with scaffolding, Hi-C data are used to join contigs into chromosomes across assembly gaps (marked by thick grey arrows). hap, haplotype; trio data, sequencing data on an individual and both its parents.


Un tipo di «ripetizione» totalmente inevitabile

Il DNA è a doppio filamento!!!

Di conseguenza per ogni filamento **GATGTCATA** avremo anche **TATGACATC**


Per risolvere questo problema, vengono usate euristiche:

- 1) Creazione per ogni sequenza del suo reverse complement
- 2) Risoluzione del «doppio grafo» a posteriori



I grafi si possono rappresentare come matrici o liste


Graph



Adjacency List

a is adjacent to *b* and *e*
b is adjacent to *c* and *d*
c is adjacent to *a*
d is adjacent to *a*
e is adjacent to *b*, *c*, and *d*



Graph




Adjacency List


a is adjacent to *b* and *x*
b is adjacent to *c* and *x*
c is adjacent to *a*
x is adjacent to *a*, *b*, *c*, and *x*

I grafi si possono rappresentare come matrici o liste



Le rappresentazioni matriciali possono anche rappresentare operazioni come «l'incollamento» dei grafi di De Bruijn

[illegible]

[illegible]

Cosa abbiamo visto oggi

- Perché è difficile assemblare
- Algoritmi per assemblare:
 - Overlap-graphs
 - De Bruijn graphs
- Concetti generali delle scienze computazionali (“Teoria dei grafi”, algoritmi polinomiali ed intrattabili)
- Applicazioni specifiche a tipologie di dati di sequenziamento e problemi dei “genomi veri”
 - Il problema delle ripetizioni
 - Scaffolding
 - Assemblare con sequenze lunghe e corte

La prossima lezione

- Pratica di assemblaggio di genomi con strumenti bioinformatici