

Progetto ASD 2018/19

DNA \rightarrow "sequenziazione"
sequencing


DNA and sequence over alphabet

$$\Sigma = \{A, C, G, T\}$$


basi

HTS = High-throughput sequencing

k -mero = sequenza di k simboli di Σ ($N = \text{simbolo incerto}$)
 k -mer



$k \approx 10^2 - 10^3$ ordine $\#$ basi \rightarrow milioni di basi.



Nostra terminologia:

INPUT = file contenente un numero elevato di stringhe
sull'alfabeto Σ , ciascuna di lunghezza k


Scopo del progetto:

► grafo di de Bruijn : Σ, k

$G = (V, E)$ orientato

$$V = \Sigma^k$$

$E = \{ (x, y) : x, y \in \Sigma^k \text{ e } \begin{cases} \text{suffisso}(x) = \text{prefisso}(y) \\ \text{di lunghezza } k-1 \end{cases} \}$




$L : E \rightarrow \Sigma$

$$L(x, y) = c \quad \text{t.c. } x = c' \alpha, | \alpha | = k-1$$

Esempio :

$K=4$



Grapho regolare in cui ogni nodo ha $|Σ|$ archi uscenti e $|Σ|$ archi entranti


Dato $G = (V, E)$ è un sottousieme $V' \subseteq V$

sottografo indotto $G[V'] = (V', E[V'])$

t.c. $E[V'] = \{(x, y) \in E : x, y \in V'\}$


(nota: alcuni nodi potrebbero essere isolati e quindi parola essere scartati e puoi)

$|Σ| = 2$



NOTA :
 V' è dato dal file di INPUT

Una tecnica comune di depuramento percorre un opportuno cammino (con nodi ripetuti) nel grafo, sovrapponendo i rispettivi termini.



$\alpha c_1 c_2$

$$\begin{cases} |\alpha| = k \\ |\alpha'| = k-1 \end{cases}$$

$$|\alpha''| = k-2$$

In realtà ci sono diverse complicazioni.

Task Dato il file di input:

- ① Costruire il grafo di de Bruijn dall'input
- ② Usare opportune strutture di dati per rispondere alle seguenti richieste (query):

2.a. Dato una stringa P su Σ , di lunghezza arbitraria m , stabilire se P appare lungo un qualche cammino (il problema è interessante per $m > k$)

2.b. Dato P su Σ , trovare il più lungo prefisso di P che soddisfa 2.a (chiaramente se P appare, abbiamo che è lei la risposta)

2.c. Risolvere le 2.a dove P può avere un errore: uno dei simboli di P non corrisponde, ma gli altri sì.

ATCC comprende el A Gcc