

①

# Programmazione Dinamica (3)

- Alcuni problemi su stringhe

## Sottosequenza Comune massima (LCS longest common substring) (Cap 15.4)

In applicazioni di Biologia e soprattutto di Bioinformatica richiedono spesso algoritmi su **STRINGHE** di dati testuali o numerici.

Ad esempio dati due segmenti di DNA

- A C C G G T C C A G T G C G C G G A A G C C G G C C G A A
- G T C G T T C G G A A T G C C G T T G C T C T G T A A A

possiamo valutarne la **SIMILARITÀ** in vari modi, secondo le esigenze dell'applicazione stessa.

- Per esempio una **SOTTOSEQUENZA** di una stringa di lunghezza  $n$

$$S = s_1, s_2, s_3, \dots, s_{n-1}, s_n$$

è una stringa  $s_i, s_{i_1}, s_{i_2}, \dots, s_{i_k}$  os  $i_1 < i_2 < i_3 < \dots < i_k < n$  che induce quindi è una stringa ottenuta da  $S$  premendo **IN ORDINE** alcuni caratteri di  $S$  **ANCHE NON CONSECUTIVI**.

E.s.

A B C B D A B di lunghezza 7 ha una sottosequenza  
 ||| / / B C D B di lunghezza 4

Def. Una sottosequenza comune di due stringhe  $S_1$  e  $S_2$  è una stringa  $s$  tale che
 

- $s$  è sottosequenza di  $S_1$
- $s$  è sottosequenza di  $S_2$

(2)

Due stringhe possono essere considerate molto simili se hanno una sottosequenza comune molto lunga

PROBLEMA Date due stringhe  $X$  e  $Y$ , trovate una sottosequenza comune di lunghezza massima.

E.s. una sottosequenza comune è visualizzata nell'esempio del DNA

E.s.  $X = A B C B D A B$

$Y = B D C A B A$

- Dalle sottosequenze comuni sono  $BCA, BCBA, BDAB$
- Non ci sono sottosequenze comuni di lunghezza  $\geq 5$

Identifichiamo una sottostruttura ottima della soluzione per impostare un algoritmo

Sia  $z_1, z_2, \dots, z_t$  una sottostringa di lunghezza MASSIMA tra

$$X = x_1 \dots x_m \quad m = |X|$$

$$Y = y_1 \dots y_n \quad n = |Y|$$

- Se  $x_m = y_n$  allora  $z_1, \dots, z_{(t-1)}$  è una LCS di  $x_1 \dots x_{(m-1)}$

perché se ce ne fosse una di lunghezza  $\geq t$  allora la LCS da  $X$  e  $Y$  avrebbe lunghezza  $\geq t+1$

- Se  $x_m \neq y_n$  allora abbiamo  $x_m \neq z_t$  oppure  $y_n \neq z_t$  (o entrambi)




• Se  $x_m \neq z_t$  allora  $Z = z_1 \dots z_{(t-1)}$  è una LCS di  $x_1 \dots x_{(m-1)}$

$y_1 \dots y_n$  Possiamo escludere  $x_m$

- Se  $y_n \neq z_t$  allora  $Z = z_1 \dots z_{(t-1)}$  è una LCS di  $x_1 \dots x_m$

$y_1 \dots y_{(n-1)}$  escludiamo  $y_n$

(3)

Quando  $x_m = y_n$ Se  $x_m \neq y_n$  escludo  $y_n$  due casiOSS Per  $x_m \neq y_n$  i due casi non sono disgiunti

- La stessa soluzione può essere ottima per entrambi i sottoproblemi

OSS Guardate l'esempio

$$X = A B D D C D C$$

$$Y = A B B C$$

osservate che qui  $x_m = y_n$  Tuttavia esistono anche soluzioni ottime ottenibili escludendo  $x_m$ .

A B D D C D C  
|| | /  
A B B C

A B D D C D C  
| /  
A B B C

La nostra caratterizzazione della soluziostruttura ottima non prende in considerazione associazioni come quella a sinistra, ma solo come quella a destra. Eppure l'ottimalità del risultato non è pregiudicata.


## Soluzione ricorsiva

Sia  $c[i, j]$  la lunghezza della LCS di  $X_i - x_i$  e  $Y_j - y_j$   
allora

$$c[i, j] = \begin{cases} 0 & \text{se } i=0 \text{ o } j=0 \\ 1 + c[i-1, j-1] & \text{se } x_i = y_j \\ \max(c[i-1, j], c[i, j-1]) & \text{altrimenti} \end{cases}$$

(4)

## Calcolo Bottom-up della lunghezza ottima



i valori di  $c[i,j]$  possono essere calcolati riga per riga o colonna per colonna, utilizzando spazio  $\Theta(\min\{n,m\})$

## Calcolo della soluzione ottima

Come in altri esempi, una soluzione ottima può essere calcolata tenendo traccia delle scelte fatte durante il calcolo bottom-up

- Calcolando  $c[i,j] =$ 
  - usiamo  $c[i-1,j-1]$  abbiamo preso  $x_i$  e  $y_j$  ↗
  - usiamo  $c[i,j-1]$  abbiamo scartato  $y_j$  ↙
  - usiamo  $c[i-1,j]$  abbiamo scartato  $x_i$  ↑
- Possiamo memorizzare in una seconda matrice B le direzioni ↗, ↘, ↙ del calcolo.
- I caratteri della sottosequenza sono quelli che corrispondono a ↗

	j	0	1	2	3	4	5	6
i	$y_j$	B	D	C	A	B	A	
0	$x_i$	0	0	0	0	0	0	0
1	A	0	0	0	0	1	1	1
2	B	0	1	1	1	1	2	2
3	C	0	1	1	2	2	2	2
4	B	0	1	1	2	2	3	3
5	D	0	1	2	2	2	3	3
6	A	0	1	2	2	3	3	4
7	B	0	1	2	2	3	4	4

$$X = A B C B D A B$$

$$Y = B D C A B A$$

(5)

- Lo spazio necessario per calcolare  $C[m,n]$  è  $\Theta(\min\{n,m\})$   
tuttavia se vogliamo ricostruire la soluzione,

Q quanto spazio è necessario ?

## Implementazione completa in python

```

30 def LCS(X,Y):
31     m = len(X)
32     n = len(Y)
33     C = creatematrix(m+1,n+1,fill=0)
34     B = creatematrix(m+1,n+1,fill=" ")
35     for i in range(1,m+1):
36         for j in range(1,n+1):
37             if X[i-1] == Y[j-1]:
38                 C[i][j] = C[i-1][j-1]+1
39                 B[i][j] = "↖"
40             elif C[i-1][j] >= C[i][j-1]:
41                 C[i][j] = C[i-1][j]
42                 B[i][j] = "↑"
43             else:
44                 C[i][j] = C[i][j-1]
45                 B[i][j] = "←"
46     return extractLCS(B,X,Y)
    
```

→ indici delle stringhe partono da 0

La funzione seguente estrae la sottosequenza visitando la matrice B

```

16 def extractLCS(B,X,Y):
17     i,j = len(B)-1, len(B[0])-1
18     data = []
19     while i>0 and j>0:
20         if B[i][j]== "↖":
21             data.append(X[i-1])
22             i-=1
23             j-=1
24         elif B[i][j]== "↑":
25             i-=1
26         elif B[i][j]== "←":
27             j-=1
28     return "".join(reversed(data))
    
```

(6)

Esercizio Calcolate la LCS di

(15.4.1)

$$X = 10010101 \quad e \quad Y = 010110110$$

Domanda

Qual è la complessità dell'algoritmo LCS?

Esercizio Scrivete una versione top-down di LCS che abbia

(15.4.3)

la stessa complessità (quindi usando la memoizzazione)

Esercizio Mostrate come calcolare la lunghezza della LCS

(15.4.4)

mantenendo in memoria solo

$$2 \cdot \min(m, n) + O(1)$$

celle della tabella C

• Mostrate come farla usando solo  $\min(m, n) + O(1)$  celleEsercizio

(15.2)

Trovate un algoritmo che, data una stringa S  
di n caratteri,trovi la più lunga sottosequenza palindroma

# DISTANZA DI EDITING (esercizio 15-5(a))

(6)

Una forma più complessa per indicare la similarità tra due stringhe è la distanza di editing.

- Date due stringhe  $X$  e  $Y$ , quante operazioni di editing sono necessarie per trasformare  $X$  in  $Y$
- Cosa vuol dire OPERAZIONI DI EDITING va specificato, per dare una risposta

E.g. se le operazioni a disposizione sono la sostituzione di un carattere o la sua cancellazione

- BASTA  $\rightarrow$  CASA con 2 operazioni

BASTA  $\rightarrow$  ~~CAS~~ $A$   $\rightarrow$  CASA

Vediamo una descrizione più sistematica del processo

DATE  $X$  E  $Y$  IMMAGINIAMO UN PROCESSO CHE LEGGA E "CONSUMI" I CARATTERI DI  $X$  E MAN MANO SCRIVA SU UN BUFFER  $Z$  SECONDO UNA SCELTA TRA UN INSIEME DI REGOLE.  $X$  È LETTO, E  $Z$  È SCRITTA, IN MODO PRETTAMENTE SEQUENZIALE. ALLA FINE DEL PROCESSO VOGLIAMO CHE IN  $Z$  CI SIA UNA COPIA DI  $Y$

- ABBIAMO UNA STRINGA  $X = x_1, x_2, \dots, x_m$  [input]
- UN INDICE  $i = 1$  [indice in  $X$ ]
- UN ARRAY  $Z$  DI LUNGHEZZA  $n$  CON  $n = |Y|$  [output]
- UN INDICE  $j = 1$  [indice in  $Z$ ]

E ABBIAMO UNA SERIE DI OPERAZIONI, OGNIUNA CON UN COSTO FISSO

(8)

Le operazioni ammissibili sono alcune o tutte tra le seguenti

**COPIA**: imposta  $Z[j] \leftarrow X[i]$  e incremento i e j di 1

**SOSTITUISCI(c)**: imposta  $Z[j] \leftarrow c$  e incremento i e j di 1

**CANCELLA**: incremento i di 1

**INSERISCI(c)**: imposta  $Z[j] \leftarrow c$  e incremento j

**SCAMBIA**: imposta  $Z[j] \leftarrow X[i+1]$  e incrementa i e j di 2  
 $Z[j+1] \leftarrow X[i]$

**TERMINA**: deve essere l'ultima operazione.  
i è settata a m

Esempio algorithm → altruist

X:	algorithm	Z
<b>copia</b>	al <u>gori</u> thm	a <u>l</u>
<b>copia</b>	al <u>gori</u> thm	a <u>l</u> <u>g</u>
<b>sostituisci t</b>	al <u>gori</u> thm	a <u>l</u> <u>t</u>
<b>cancella</b>	al <u>gori</u> thm	a <u>l</u> <u>t</u>
<b>copia</b>	al <u>gori</u> thm	a <u>l</u> <u>tr</u>
<b>inscrisci u</b>	al <u>gori</u> thm	a <u>l</u> <u>tr</u> <u>u</u>
<b>inscrisci i</b>	al <u>gori</u> thm	a <u>l</u> <u>trui</u>
<b>inscrisci s</b>	al <u>gori</u> thm	a <u>l</u> <u>truis</u>
<b>scambia</b>	al <u>gori</u> thm	a <u>l</u> <u>truisti</u>
<b>inscrisci c</b>	al <u>gori</u> thm	a <u>l</u> <u>truistic</u>
<b>TERMINA</b>	al <u>gori</u> thm	a <u>l</u> <u>truistic</u>

(9)

Lo scopo è partire dalla stringa  $X$  e arrivare alla  $Y$ , minimizzando il costo totale delle operazioni

Ma il costo totale non è definito se non definiamo

- ① Quali operazioni sono permesse
- ② Il costo di ogni operazione

Queste scelte daranno luogo a molte variazioni di questo problema e altri problemi possono essere formalizzati come suoi casi speciali

Esercizio Supponiamo di voler scoprire se  $Y$  è una sottosequenza di  $X$ . Come possiamo usare MINIMUM EDIT DISTANCE per farlo?

Esempi di impostazione dei pesi:

- COPIA  $\rightarrow 0$
- INSERISCI / CANCELLA / SCAMBIA / SOSTITUISCI / TERMINA  $\rightarrow 1$

LCS come variante di MINIMUM EDIT DISTANCE

- COPIA  $\rightarrow -1$
- INSERISCI / CANCELLA  $\rightarrow 0$
- SCAMBIA / SOSTITUISCI / TERMINA  $\rightarrow$  non ammessi

Esercizio Dimostrare che LCS può essere espresso come la variante di Min Edit Distance descritta sopra

Osservazione Il numero possibile di operazioni è finito, poiché in  $\text{INSERISCI}(c) \in \text{SOSTITUISCI}(c)$   $c$  deve essere per forza  $Y[i]$

## SOTTOSTRUTTURA OTTIMA

Impostiamo l'algoritmo per MCD, descrivendo la sottostruttura ottima.

- Definiamo  $D(i, j)$  la minima distanza di editing tra  $x_1 - x_i$  e  $y_1 - y_j$  così  $D(n, m)$  è la risposta cercata.
- Caso base  $D(0, 0) = 0$
- L'ultima azione può essere un termina, ma solo se  $j = n$   
QUESTO CASO LO CONSIDERIAMO DOPPO
- Altrimenti l'ultima azione in una soluzione di costo  $D(i, j)$ 
  - CANCELLAZIONE di  $x_i$ :  
che segue una sequenza ottima che porta  

$$x_1 - x_{(i-1)} \rightarrow y_1 - y_j$$
  - INSERIMENTO che segue l'editing da  $x_1 - x_i$  a  $y_1 - y_{(i-1)}$
  - COPIA SOSTITUISCI che segue l'editing da  $x_1 - x_{i-1}$  a  $y_1 - y_{(j-1)}$
  - SCAMBIA che segue l'editing da  $x_1 - x_{i-2}$  a  $y_1 - y_{(j-2)}$

Vi osservate che alcune di queste azioni di editting possono non essere fattibili (e.g. copia o scambio).

Non abbiamo considerato l'azione TERMINA.

In questo caso l'azione termina si può effettuare solo se in  $Z$  ci sta una copia di  $Y$ , quindi  $j = n$ , e  $i < m$ .

## Impostazione alla ricorsione

$$D(0,0) = 0$$

$D(i,j)$  = Minimo tra:

- $D(i-1, j) + \text{costo}(\text{CANCELLAZIONE})$  se  $i < m$
- $D(i, j-1) + \text{costo}(\text{INSERIMENTO})$
- $D(i-1, j-1) + \text{costo}(\text{SOSTITUISCI})$
- $D(i-1, j-1) + \text{costo}(\text{COPIA})$  se  $X[i] = Y[j]$
- $D(i-2, j-2) + \text{costo}(\text{SCAMBIA})$  se applicabile
- $D(t, j) + \text{costo}(\text{TERMINA})$  per  $t < m$  e  $j = n$

Solo per  $D(m,n)$



Esercizio Completate questo schema e scrivete l'algoritmo

- Valutatene la complessità in termini di tempo
- Valutatene la complessità in termini di spazio

## ALLINEAMENTO DI SEQUENZE DI DNA (esercizio 15-5 (b))

- Un metodo per misurare la similarità di sequenze di DNA è lo studio dell'allineamento di queste sequenze
- Per esempio due sequenze possono essere allineate inserendo spazi nelle due sequenze (anche in cima e in fondo) per poi misurare la loro similarità.

E.s.  $x = \text{GATCGGGCAT}$        $y = \text{CAATGTGAATC}$

allineate

G	A	T	C	G	G	C	A	T	
C	A	A	T	G	T	G	A	A	T
•	•	•	•	•	•	•	•	•	•

- -2 punti (spazio)
- +1 punto (uguali)
- -1 punto (diversi)

Punteggio totale: -4

Esercizio

Trovare un sottoinsieme delle 6 operazioni e degli assegnamenti per i punteggi tali che il problema di trovare un allineamento ottimo si riduca al problema della distanza minima di editing tra le due stringhe.

Esercizio

## Distanza di editing e simmetria.

Normalmente una misura di distanza è tale dal punto di vista matematico se, tra altre cose, è simmetrica.

$$\text{Orveva } \text{dist}(X, Y) = \text{dist}(Y, X)$$

- ① Osservate che a seconda dei punteggi e delle operazioni usate, la distanza minima di editing può essere o non essere simmetrica
- ② Dimostrate che con i pesi appropriati, le regole **COPIA**, **INSERISCI**, **SCAMBIA**, **CANCELLA**, **SOSTUISCI** danno luogo ad una distanza minima simmetrica
- ③ Osservate che qualunque punteggio si dia alla regola "termine", esistono  $X_p, Y_p$  per cui la distanza minima non è simmetrica.