Programmazione dinamica (V parte)

Progettazione di Algoritmi a.a. 2020-21

Matricole congrue a 1

Docente: Annalisa De Bonis

Allineamento di sequenze

- Quanto sono simili le due stringhe seguenti ?
  - **ocurrance**
  - **occurrence**

- Allineamo i caratteri
- Ci sono diversi modi per fare questo allineamento

- Qual e` migliore?

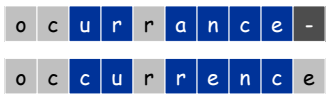

6 mismatch, 1 gap

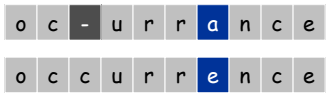

1 mismatch, 1 gap

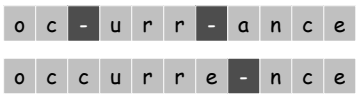

0 mismatch, 3 gap

Edit Distance

- Applicazioni.
  - Base per il comando Unix diff.
  - Riconoscimento del linguaggio.
  - Biologia computazionale.
- Edit distance. [Levenshtein 1966, Needleman-Wunsch 1970]
  - Gap penalty δ;
  - Mismatch penalty α_{pq}. Si assume $\alpha_{pp}=0$

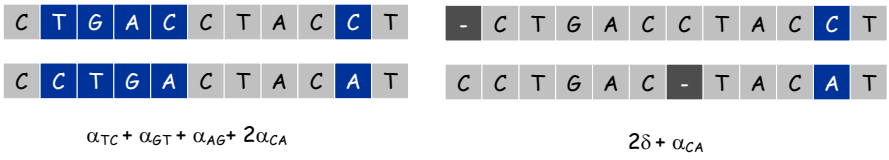

$\alpha_{TC} + \alpha_{GT} + \alpha_{AG} + 2\alpha_{CA}$

$2\delta + \alpha_{CA}$

96

Applicazione del problema dell'allineamento di sequenze

- I problemi su stringhe sorgono naturalmente in biologia: il genoma di un organismo è suddiviso in molecole di DNA chiamate cromosomi, ciascuno dei quali serve come dispositivo di immagazzinamento chimico.
- Di fatto, si può pensare ad esso come ad un enorme nastro contenente una stringa sull'alfabeto {*A*,*C*,*G*,*T*}. La stringa di simboli codifica le istruzioni per costruire molecole di proteine: usando un meccanismo chimico per leggere porzioni di cromosomi, una cellula può costruire proteine che controllano il suo metabolismo.

97

Applicazione del problema dell'allineamento di sequenze

- Perche` le somiglianze tra stringhe sono rilevanti in questo scenario?
- Le sequenze di simboli nel genoma di un organismo determinano le proprieta` dell'organismo.
- Esempio. Supponiamo di avere due ceppi di batteri X e Y che sono strettamente connessi dal punto di vista evolutivo.
- Supponiamo di aver determinato che una certa sottostringa nel DNA di X sia la codifica di una certa tossina.
- Se scopriamo una sottostringa molto simile nel DNA di Y, possiamo ipotizzare che questa porzione del DNA di Y codifichi un tipo di tossina molto simile a quella codificata nel DNA di X.
- Esperimenti possono quindi essere effettuati per convalidare questa ipotesi.
- Questo e` un tipico esempio di come la computazione venga usata in biologia computazionale per prendere decisioni circa gli esperimenti biologici.

Allineamento di sequenze

- Abbiamo bisogno di un modo per allineare i caratteri di due stringhe
  - Formiamo un insieme di coppie di caratteri, dove ciascuna coppia e` formata da un carattere della prima stringa e uno della seconda stringa.
- Def. insieme di coppie è un matching se ogni elemento appartiene ad al più una coppia
- Def. Le coppie (x_i,y_j) e $(x_{i'},y_{j'})$ si incrociano se $i < i'$ ma $j > j'$.
  - (x_1, y_2) e (x_4,y_3) non si incrociano

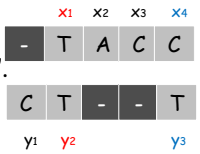

Def. Un allineamento M è un insieme di coppie (x_i,y_j) tali che
- M e` un matching
- M non contiene coppie che si incrociano

Esempio: CTACCG **VS.** TACATG

Allineamento:

M = (x_2,y_1), (x_3,y_2), (x_4,y_3), (x_5,y_4), (x_6,y_6).

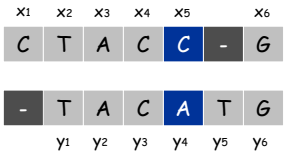

Allineamento di sequenze

- Obiettivo: Date due stringhe X = $x_1 x_2 \ldots x_m$ e Y = $y_1 y_2 \ldots y_n$ trova l'allineamento di minimo costo.

$$\text{cost}(M) = \underbrace{\sum_{(x_i,y_j)\in M} \alpha_{x_i y_j}}_{\text{mismatch}} + \underbrace{\sum_{i:x_i \text{ unmatched}} \delta + \sum_{j:y_j \text{ unmatched}} \delta}_{\text{gap}}$$

- Affermazione.
- Dato un allineamento M di due stringhe X = $x_1 x_2 \ldots x_m$ e Y = $y_1 y_2 \ldots y_n$, se in M non c'è la coppia (x_m,y_n) allora o x_m non e` accoppiato in M o $y_n$ non e` accoppiato in M.
- Dim. Supponiamo che x_m e y_n sono entrambi accoppiati ma non tra di loro. Supponiamo che x_m sia accoppiato con y_j e y_n sia accoppiato con x_i. In altre parole M contiene le coppie (x_m,y_j) e (x_i,y_n). Siccome i<m ma n>j allora si ha un incrocio e ciò contraddice il fatto che M è allineamento.

Allineamento di sequenze: struttura del problema

- Def. OPT(i, j) = costo dell'allineamento ottimo per le due stringhe $x_1 x_2 \ldots x_i$ e $y_1 y_2 \ldots y_j$.
  - Caso 1: x_i e y_j sono accoppiati nella soluzione ottima per $x_1 x_2 \ldots x_i$ e $y_1 y_2 \ldots y_j$
    - OPT(i, j) = Costo dell'eventuale mismatch tra x_i e y_j + costo dell'allineamento ottimo di $x_1 x_2 \ldots x_{i-1}$ and $y_1 y_2 \ldots y_{j-1}$
  - Caso 2a: x_i non e` accoppiato nella soluzione ottima per $x_1 x_2 \ldots x_i$ e $y_1 y_2 \ldots y_j$
    - OPT(i, j) = Costo del gap x_i + costo dell'allineamento ottimo di $x_1 x_2 \ldots x_{i-1}$ e $y_1 y_2 \ldots y_j$
  - Case 2b: y_j non e` accoppiato.nella soluzione ottima per $x_1 x_2 \ldots x_i$ e $y_1 y_2 \ldots y_j$
    - OPT(i, j) = Costo del gap y_j + costo dell'allineamento ottimo di $x_1 x_2 \ldots x_i$ e $y_1 y_2 \ldots y_{j-1}$

$$OPT(i,j) = \begin{cases} j\delta & \text{se } i = 0 \\ \min \begin{cases} \alpha_{x_i y_j} + OPT(i-1, j-1) \\ \delta + OPT(i-1, j) \\ \delta + OPT(i, j-1) \end{cases} & \text{altrimenti} \\ i\delta & \text{se } j = 0 \end{cases}$$

Allineamento di sequenze: algoritmo

```
Sequence-Alignment(m, n, x1x2...xm, y1y2...yn, δ, α) {
   for i = 0 to m
      M[i, 0] = iδ
   for j = 0 to n
      M[0, j] = jδ

   for i = 1 to m
      for j = 1 to n
         M[i, j] = min(α[xi, yj] + M[i-1, j-1],
                       δ + M[i-1, j],
                       δ + M[i, j-1])
   return M[m, n]
}
```

- Analisi. Tempo e spazio $\Theta(mn)$.
- Parole inglesi: m, n $\leq$ 10.
- Applicazioni di biologia computazionale: m = n = 100,000.
- Quindi mxn=10 miliardi . OK per il tempo ma non per lo spazio (10GB)

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

- Vogliamo individuare la sottosequenza crescente piu` lunga in una sequenza di numeri. La sottosequenza non deve essere necessariamente formata da elementi contigui nella sequenza input. La sequenza input è memorizzata in un array A.
- Indichiamo con A[0,…,i] il segmento di A degli elementi con indice da 0 a i.
- Esempio: A=<3 12 9 4 12 5 8 11 6 13 10>
- La sottosequenza crescente piu` lunga e` <3 4 5 8 11 13>

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

- OPT(i) = lunghezza della sottosequenza crescente più lunga che termina in i (l'ultimo elemento della sottosequenza è A[i])

- Una volta che abbiamo calcolato OPT(i) per ogni i, andiamo a calcolare il massimo di tutti i valori OPT(i) per ottenere la lunghezza della sottosequenza crescente piu` lunga.

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

- Osserviamo che nella sottosequenza crescente piu` lunga che termina in i, l'elemento A[i] e` preceduto

  dalla piu` lunga sottosequenza crescente che termina in un certo j tale che j<i e A[j]<[A[i].

  - Quale di questi j bisogna prendere?
    - Quello per cui la lunghezza della sottosequenza è massima, cioe` l'indice j per cui si ottiene il massimo valore OPT(j) in questo insieme: { OPT(j): $0 \leq j \leq i-1$ e $A[j]<A[i]$ }

Si ha quindi

$OPT(i)=\max\{OPT(j)+1: 0 \leq j \leq i-1 \text{ e } A[j] < A[i]\}$

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

- Esempio: A=<3 12 9 4 12 5 8 11 6 13 10>
- per calcolare OPT(10) consideriamo j=0, j=2, j=3, j=5, j=6, j=8
- per calcolare OPT(9) consideriamo j=0, j=2, j=3,j=4 j=5, j=6,j=7,j=8
- per calcolare OPT(8) consideriamo j=0, j=3,j=5
- per calcolare OPT(7) consideriamo j=0, j=2, j=3, j=5, j=6
- per calcolare OPT(6) consideriamo j=0, j=3, j=5,
- per calcolare OPT(5) consideriamo j=0, j=3
- per calcolare OPT(4) consideriamo j=0, j=2, j=3
- per calcolare OPT(3) consideriamo j=0
- per calcolare OPT(2) consideriamo j=0
- per calcolare OPT(1) consideriamo j=0
- OPT(0)=1 → OPT(1)=OPT(2)=OPT(3)=2
- OPT(0)=1 e OPT(2)=OPT(3)=2 → OPT(4)=3
- OPT(0)=1 e OPT(3)=2 → OPT(5)= 3
- OPT(0)=1 , OPT(3)=2 , OPT(5)= 3 → OPT(6)=4
- OPT(0)=1 , OPT(2)=OPT(3)=2 , OPT(5)= 3 , OPT(6)=4 → OPT(7)=5
- OPT(0)=1 , OPT(3)=2 , OPT(5)= 3 --> OPT(8)=4
- OPT(0)=1 , OPT(2)=OPT(3)=2 , OPT(4)=3, OPT(5)= 3 , OPT(6)=4, OPT(7)=5→ OPT(9)=6
- OPT(0)=1 e OPT(3)=2 , OPT(5)= 3, OPT(6)=OPT(8)=4 → OPT(10)=5

106

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

Questo algoritmo trova la lunghezza della sottosequenza crescente piu` lunga che termina in i

```
LIS(A,i):
  if i<0 return 0
  if i=0
     P[0]=-1, M[0]=1, return 1
  if M[i]!=empty return M[i]
  M[i]=1
  P[i]=-1      //serve nel caso alla fine M[i]=1
  for( j=0; j<i; j++)
      m=LIS(A,j)
      if (A[j]<A[i] && M[i]<m+1)
        M[i]=m+1
        P[i]=j
  return M[i]
```

M globale
P globale: mi serve per la stampa
P[i]= indice dell'elemento che precede i nella sottosequenza crescente piu` lunga che termina in i

tempo $O(n^2)$

Per trovare la sottosequenza crescente piu` lunga dell'array occorre prima invocare LIS(A,n-1) e poi trovare il massimo dell'array M.

107

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

Analisi dell'algoritmo ricorsivo:

1. Sia 1<i<n. Se escludiamo il tempo per le chiamate ricorsive al suo intermo LIS(A,i) richiede tempo O(i) se M[i] è vuoto e O(1) altrimenti. LIS(A,i) viene invocata in tutte le chiamate LIS(A,k) con i<k<n, e quindi in totale n-i-1 volte ma solo la prima volta richiede tempo O(i). Quindi tutte le chiamate a LIS(A,i) richiedono in totale tempo O(n).
2. LIS(A,0) viene invocata in tutte le chiamate LIS(A,k) con 0<k<n e ogni volta richiede O(1) . Quindi il tempo delle n-1 chiamate a LIS(0) è O(n).
3. Dalla 1 e dalla 2 il tempo per eseguire tutte le chiamate a LIS(A,i) per ciascun $0 \leq i \leq n-1$ è O(n) per un tempo totale pari a $O(n^2)$

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

Questo algoritmo stampa la sottosequenza crescente piu` lunga. Indichiamo con max l'indice in cui si trova l'elemento massimo di M, cioe` M[max]=max{OPT(i): 0<=i<=n-1}

```
PrintLIS(A,i):                    prima chiamata con i=max
if i >= 0                         M e P costruiti in precedenza
    PrintLis(A,P[i])
    print(A[i])
```

Sottosequenza crescente piu` lunga

elementi non necessariamente contigui

Questa e` la versione iterativa dell'algoritmo LIS

```
ITLIS(A)
   n = A.length
   for i=0 to n-1
      M[i]=1
      P[i]=-1
   for (int i = 0; i < n; i++) //ogni iterazione computa OPT(i), i=0,...,n-1
      for (int j = 0; j < i; j++) //ogni iterazione computa OPT(j) , j<i e A[j]<A[i]
         if (A[j] < A[i])
            if M[j] + 1 >M[i]
               M[i]=M[j]+1
               P[i]=j
  max= M[0]
   for i=0 to n-1
      if M[i]>max
         max=A[i]
   return max
```

M[i]=lunghezza sottosequenza crescente piu` lunga che termina in A[i]
P[i]= indice predecessore di A[i] nella sottosequenza crescente piu` lunga che termina in A[i]

Parentesizzazione di valore massimo

- Si scriva un algoritmo che trova il valore massimo ottenibile con una parentesizzazione completa della seguente espressione: $x_1/x_2/.../x_{n-1}/x_n$
- Una parentesizzazione completa di $x_1/x_2/.../x_{n-1}/x_n$ si ottiene racchiudendo ciascun '/' insieme alle due sottoespressioni a cui esso si applica tra una coppia di parentesi. La coppia di parentesi piu` esterna puo` essere omessa.
- Ad esempio: le parentesizzazioni complete di 24/6/2 sono

  I. (24/6)/2=2, II. 24/(6/2)=8. La II produce il valore massimo
- Un approccio potrebbe essere quello di considerare tutti i possibili modi di parentesizzare l'espressione e di calcolare il valore dell'espressione risultante.
  - Questo approccio e` inefficiente perche` il numero di parentesizzazioni complete e` esponenziale.

Parentesizzazione di valore massimo

- Il costo C(P) di una parentesizzazione P e` il valore dell'espressione quando le divisioni sono eseguite nell'ordine dettato dalle parentesi nella parentesizzazione.
- Ad esempio: 24/6/2

  I. (24/6)/2=2, II. 24/(6/2)=8

  2 e` il costo della I parentesizzazione; 8 e` il costo della II parentesizzazione

Parentesizzazione di valore massimo

- Soluzione basata sulla programmazione dinamica.
- Sia i<j e sia P(i,...,j) una parentesizzazione della sottoespressione $x_i/x_{i+1}/.../x_j$. Supponiamo che questa parentesizzazione a livello piu` esterno sia formata da una certa parentesizzazione P(i,...,k) di $x_i/x_{i+1}/.../x_k$ e una certa parentesizzazione P(k+1,...,j) di $x_{k+1}/x_{k+2}/.../x_j$, per un certo $i \leq k \leq j-1$
- Il costo C(P(i,...,j)) di P(i,...,j) e` quindi C(P(i,...,k)) / C(P(k+1,...,j))
- Esempio: la parentesizzazione ((100/5)/20)/(15/3) contiene a livello piu` esterno le parentesizzazioni ((100/5)/20) e (15/3) mentre (100/5)/(20/(15/3)) contiene a livello piu` esterno le parentesizzazioni (100/5) e (20/(15/3)).

Parentesizzazione di valore massimo

- MAX(i, j) = costo massimo di una parentesizzazione per la sottoespressione $x_i/x_{i+1}/.../x_j$
- min(i,j) = costo minimo di una parentesizzazione per la sottoespressione $x_i/x_{i+1}/.../x_j$
- Sia P'(i,...,j) la parentesizzazione di $x_i/x_{i+1}/.../x_j$ di costo massimo
- A livello piu` esterno, P'(i,...,j) contiene una certa parentesizzazione P'(i,...,k) di $x_i/x_{i+1}/.../x_k$ e una certa parentesizzazione P'(k+1,...,j) di $x_{k+1}/x_{k+2}/.../x_j$, per un certo intero k compreso tra i e j-1.
- P'(i,...,j) e` di costo massimo se e solo se P'(i,...,k) e` la parentesizzazione di costo massimo di $x_i/x_{i+1}/.../x_k$ e P'(k+1,...,j) e` la parentesizzazione di costo minimo di $x_{k+1}/x_{k+2}/.../x_j$.
  - si ha quindi MAX(i,j) = MAX(i,k) / min(k+1,j) per un certo k, $1 \le k \le j-1$
- Siccome non sappiamo in corrispondenza di quale indice k compreso tra i e j-1 si ottiene la parentesizzazione di costo massimo di $x_i/x_{i+1}/.../x_j$ allora dobbiamo calcolaare il massimo su tutti i k compresi tra i e j-1 di MAX(i,k)/min(k+1,j).

EsercizioParentesizzazione di valore massimo

- Ho bisogno anche di una formula per min(i,j)
- Sia P''(i,...,j) la parentesizzazione di $x_i/x_{i+1}/.../x_j$ di costo minimo
- A livello piu` esterno, P''(i,...,j) contiene una certa parentesizzazione P''(i,...,k) di $x_i/x_{i+1}/.../x_k$ e una certa parentesizzazione P''(k+1,...,j) di $x_{k+1}/x_{k+2}/.../x_j$, per un certo intero k compreso tra i e j-1.
- P''(i,...,j) e` di costo minimo se e solo se P''(i,...,k) e` la parentesizzazione di costo minimo di $x_i/x_{i+1}/.../x_k$ e P''(k+1,...,j) e` la parentesizzazione di costo massimo di $x_{k+1}/x_{k+2}/.../x_j$.
  - si ha quindi che min(i,j) = min(i,k) /MAX(k+1,j)
- Siccome non sappiamo in corrispondenza di quale indice k compreso tra i e j-1 si ottiene la parentesizzazione di costo minimo di $x_i/x_{i+1}/.../x_j$ allora dobbiamo calcolare il minimo su tutti i k compresi tra i e j-1 di min(i,k)/MAX(k+1,j).

Esercizio

```
CatenaDiDivisioni (x) // x array t.c. x[i]=xi
 n=length(x)
 for i←1 to n
     M[i, i]←m[i, i]←x[i]
 for lung←2 to n //ogni iterazione calcola M[i,j] ed m[i,j] per
                 //i,j tali che i<j e j-i=lung
  for i←1 to n-lung+1
     j=i+lung-1
     M[i, j]←0
     m[i, j]←∞
     for k←i toj–1
          vM←M[i, k]/m[k+ 1, j]
         vm←m[i, k]/M[k+ 1, j]
          if M[i, j]< vM then M[i, j]←vM
          if m[i, j]> vm then m[i, j]← vm
 return M[1, n]
```

M[i,j]=MAX(i,j)
m[i,j]=min(i,j)

$O(n^3)$

vengono calcolati M[i,j] e m[i,j] per ogni (i,j), con i<j, in questo ordine:
(1,2),(2,3), … ,(n-1,n)
(1,3),(2,4),…,(n-2,n)
…
(1,n-1),(2,n)
(1,n)

116