


Text Processing

Campi Applicativi

- text editing



- web searching



- computational biology (e.g., *DNA analysis*)



- vision
- ...

Definizioni

Stringa P

$P \equiv P[0]P[1] \dots P[m-1]$ (lunghezza m)

$P[i]$ = singolo carattere $\in \Sigma$, Σ = alfabeto finito

Sottostringa

$P[i \dots j] \equiv P[i]P[i+1] \dots P[j]$, per qualche $0 \leq i, j < m$

- Si dice *propria* se $i > 0$ o $j < m - 1$
- Si dice *vuota* se $i > j$

Prefisso di P

$P[0 \dots i]$, per qualche $0 \leq i < m$

Suffisso di P

$P[i \dots m-1]$, per qualche $0 \leq i < m$

In Java: la classe `String` viene usata per stringhe non modificabili, mentre la classe `StringBuilder` viene usata per stringhe modificabili.

Pattern Matching Problem

Dati:

- *testo* T (stringa) di lunghezza n su Σ
- *pattern* P (stringa) di lunghezza $m \leq n$ su Σ

trovare, se esiste, l'indice $i \in [0, n - m]$ tale che $P = T[i \dots i + m - 1]$ o, equivalentemente, tale che $P[j] = T[i + j], \forall j : 0 \leq j < m$.

Problema Computazionale Π

$\mathcal{I} = \{(T, P) : T, P \text{ stringhe su } \Sigma \text{ con } |P| \leq |T|\}$

$\mathcal{S} = \{\text{interi} \geq -1\}$

Π = insieme delle coppie $(T, P), i$ con $(T, P) \in \mathcal{I}$ e $i \in \mathcal{S}$, tali che

- se P è sottostringa di T allora $i \geq 0$ e $P = T[i \dots i + m - 1]$
- altrimenti $i = -1$.

Algoritmo findBrute (approccio banale)

Algoritmo findBrute(T, P)

Input: T, P su Σ , $|T| = n$, $|P| = m$

Output: i t.c. $P = T[i \dots i + m - 1]$ se esiste, -1 altrimenti

for $i \leftarrow 0$ **to** $n - m$ **do**

$\text{/* verifica se } P = T[i \dots i + m - 1]$ */

$j \leftarrow 0$;

while $((j < m) \text{ AND } (T[i + j] = P[j]))$ **do** $j \leftarrow j + 1$;

if $j = m$ **then return** i ;

return -1

Osservazione: la correttezza dell'algoritmo è banale.

Esempio

T = ABACADABRAC

P = ABRA

i	j	$i+j$	0	1	2	3	4	5	6	7	8	9	10
		$T \rightarrow$	A	B	A	C	A	D	A	B	R	A	C
0	2	2	A	B	R	A	$\leftarrow P$						
1	0	1		A	B	R	A						
2	1	3			A	B	R	A					
3	0	3				A	B	R	A				
4	1	5					A	B	R	A			
5	0	5						A	B	R	A		
6	4	10							A	B	R	A	

in rosso = mismatches

in grigio = non confrontati

in nero = match

quando $j=m$: return i

match completo

Complessità

Per quanto riguarda la complessità osserviamo che:

- $\leq n - m + 1$ iterazioni del for
- $\leq m$ iterazioni del while in ciascuna iterazione del for
- numero costante di operazioni in ciascuna iterazione del for (oltre al while) e in ciascuna iterazione del while.

$$\Rightarrow t(n, m) \in O((n - m + 1)m)$$

È *tight* (Esercizio C-12.14 [GTG14])?

Si consideri la seguente istanza

- $T = AA \dots AB$
- $P = AA \dots AB$

i	j	i+j	0	1	2	3	4	5	6	7	8	9
		$T \rightarrow$	A	A	A	A	A	A	A	A	A	B
0	4	4	A	A	A	A	B	$\leftarrow P$				
1	4	5		A	A	A	A	B				
2	4	6			A	A	A	A	B			
3	4	7				A	A	A	A	B		
4	4	8					A	A	A	A	B	
5	5	10						A	A	A	A	B
									$\uparrow$ match completo			

esattamente $m - 1$ iterazioni del while in ciascuna iterazione del for

$$\Rightarrow t(n, m) \in \Omega((n - m + 1) m) \Rightarrow t(n, m) \in \Theta((n - m + 1) m)$$

Osservazioni

- se $m \leq cn$ con $c \in (0, 1)$ costante $\Rightarrow t(n, m) \in \Theta(nm)$
- se $m = cn$ con $c \in (0, 1)$ costante $\Rightarrow t(n, m) \in \Theta(n^2)$

Esercizio

Si consideri un testo T e un pattern P , con $|T| = n$, $|P| = m \leq n$ e si supponga che $P[0] \neq P[i], \forall 1 \leq i \leq m-1$.

- 1 Modificare `findBrute` per risolvere efficientemente le istanze del problema di pattern matching che soddisfano queste ipotesi. L'algoritmo modificato deve contenere un solo ciclo e deve avere complessità $O(n)$.
- 2 Analizzare la complessità dell'algoritmo
- 3 Identificare un opportuno invariante che serva per provare la correttezza del ciclo.

Soluzione: intuizione



Osservazione. Le ipotesi su P implicano che se per un certo allineamento di P sotto T si trova il primo mismatch confrontando $P[j]$ e $T[i]$ ($j = 5$ e $i = 6$ nell'esempio), il prossimo confronto utile è tra $P[0]$ e $T[i]$

Soluzione: algoritmo

Algoritmo FBPlus(T, P)

Input: T, P su Σ , $|T| = n$, $|P| = m$: $P[0] \neq P[i]$ per $i \neq 0$

Output: [il solito]

$i \leftarrow 0$; $j \leftarrow 0$;

while $i < n$ **do**

if $P[j] = T[i]$ **then**

$i \leftarrow i + 1$; $j \leftarrow j + 1$;

if $j = m$ **then return** $i - j$;

else

if $j > 0$ **then** $j \leftarrow 0$;

else $i \leftarrow i + 1$;


return -1

Soluzione: analisi

Complessità:

- proporzionale al numero di iterazioni del while
- i aumenta di 1 almeno ogni 2 iterazioni e non decresce mai
 $\Rightarrow O(n)$
- tempo è $\Omega(n)$: $P = T[n - m \dots n - 1] \Rightarrow \Theta(n)$

Invariante per il while:



- $P \neq T[\ell \dots \ell + m - 1], \forall 0 \leq \ell < i - j$
- $P[0 \dots j - 1] = T[i - j \dots i - 1]$.

Algoritmo findKMP (di Knuth-Morris-Pratt)


Idea

- generalizza in modo intelligente il caso particolare dell'esercizio precedente
- simile all'approccio banale
- se la verifica di una posizione iniziale per P in T fallisce, salta posizioni successive che possono essere *sicuramente escluse* e sfrutta l'informazione acquisita rimanendo fermo su T



Idea principale

Supponiamo che $P[j] \neq T[i]$ e $T[i - j + s] = P[s]$ per $0 \leq s < j$:



Sia h il *massimo* valore per cui $P[0 \dots h-1] = P[j-h \dots j-1]$

$\Rightarrow$ posso shiftare P verso destra di $j-h$ posizioni evitando di considerare tutti gli allineamenti in cui $P[0]$ è sotto $T[r]$ con $i-j < r < i-h$

Failure Function

Definizione

Failure function f per un pattern P :

- $f(0) = 0$
- per $j > 0$: $f(j)$ = lunghezza del più lungo prefisso di P che è suffisso di $P[1 \dots j]$

N.B. $f(j) \leq j$

Definizione equivalente, più matematica

Definizione

$$f(j) = \begin{cases} 0 & j = 0 \\ \max\{h : 0 \leq h \leq j \wedge P[0 \dots h-1] = P[j-h+1 \dots j]\} & j > 0 \end{cases}$$

Esempio

$P =$

0	1	2	3	4	5
A	B	A	C	A	B

$f(0) = 0$

$f(1) = 0$

A	B
A	NO

$f(2) = 1$

A	B	A
A	B	NO
A	SI	

$f(3) = 0$

A	B	A	C
A	B	A	NO
A	B	NO	
A	NO		

$f(4) = 1$

A	B	A	C	A
A	B	A	C	NO
A	B	A	NO	
A	B	NO		
A	SI			

$f(5) = 2$

A	B	A	C	A	B
A	B	A	C	A	NO
A	B	A	C	NO	
A	B	A	NO		
A	B	SI			

N.B. La failure function $f(i)$ è definita per tutti i valori $0 \leq i < m$, tuttavia $f(m-1)$ non verrà utilizzata da findKMP

Altro Esempio

	0	1	2	3	4
$P =$	A	A	A	A	B

$$f(0) = 0$$

$$f(1) = 1$$

$$f(2) = 2$$

$$f(3) = 3$$

$$f(4) = 0$$

Algoritmo findKMP(T, P)

Input: T, P su Σ , $|T| = n$, $|P| = m$

Output: i t.c. $P = T[i \dots i + m - 1]$ se esiste, -1 altrimenti

$f \leftarrow \text{computeFailKMP}(P);$

$i \leftarrow 0; j \leftarrow 0;$

while $i < n$ **do**

if $P[j] = T[i]$ **then**

/* caso 1 */

$i \leftarrow i + 1; j \leftarrow j + 1;$

if $j = m$ **then return** $(i - m);$

else

if $j > 0$ **then** $j \leftarrow f(j - 1);$

/* caso 2 */

else $i \leftarrow i + 1;$

/* caso 3 */

return -1

Complessità

- Escludendo il calcolo di f , la complessità risulta essere proporzionale al numero di iterazioni del while.
- Definiamo $\ell(i, j) = i - j$ e osserviamo che:
 - ① “ $0 \leq i \leq n$ ” $\wedge$ “ $j \geq 0$ ” $\wedge$ “ i non decresce mai”
 - ② “ $\ell(i, j)$ non decresce mai” $\wedge$ “ $\ell(i, j)$ parte da 0”
 - ③ 1) e 2) $\Rightarrow 0 \leq \ell(i, j) \leq n$
 - ④ in ciascuna iterazione: i o $\ell(i, j)$ (o entrambi) crescono di 1

Si ha che 1), 3), 4) $\Rightarrow$ num. iterazioni $\leq 2n$

$$\Rightarrow t_{\text{KMP}} \in O((\text{calcolo di } f) + n)$$

Esempio

$P =$ 0 1 2 3 4 5
A B A C A B

j	0	1	2	3	4	5
f(j)	0	0	1	0	1	2

$T =$ 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14
A B A C A C B A B A B A C A B

$P =$ 0 1 2 3 4 5
A B A C A B
 A B A C A B
 A B A C A B
 A B A C A B
 A B A C A B
 A B A C A B
 A B A C A B
 A B A C A B

(dopo 5 casi 1)

(dopo 3 casi 1)



confronto e match



confronto e mismatch


i	j	CASO
5	5	2
5	1	2
5	0	3
6	0	3
10	3	2
10	1	FINE

(dopo 5 casi 1)

Correttezza

Assumiamo computeFailKMP corretta

Determiniamo un invariante che valga alla fine di una generica iterazione del while (prossimo confronto $T[i]$ vs $P[j]$)



L'invariante è il seguente

- $P \neq T[\ell \dots \ell + m - 1], \forall \ell : 0 \leq \ell < i - j$
- $P[0 \dots j - 1] = T[i - j \dots i - 1]$

Prova dell'invariante

- è vero all'inizio: per vacuità
- da una iterazione alla successiva: mantenuto
 - casi 1 e 3: ovvi
 - caso 2: grazie alla failure function
- alla fine dell'ultima iterazione
 - $i \leq n$ e $j = m \Rightarrow$ return i
 - $i = n$ e $j < m \Rightarrow$ return -1

In entrambi i casi, l'invariante assicura la correttezza

Aggiungere i dettagli dei passaggi per **esercizio**

Esercizio

Si consideri un testo T di n caratteri e un pattern P di $m \leq n$ caratteri dove

$$T = AA \dots A$$

$$P = AA \dots AB$$

- 1 Determinare la failure function di P
- 2 Descrivere l'esecuzione di `findKMP` per $n = 9$ e $m = 5$
- 3 Per n, m generici, determinare il numero di confronti che coinvolgono ciascun $T[i]$.

Soluzione

- ① Determinare la failure function di P

Esempio: $m=5$

	0	1	2	3	4
P	A	A	A	A	B

$$f(0) = 0; f(1) = 1; f(2) = 2; f(3) = 3; f(4) = 0$$

In generale:

- $f(0) = 0$
- Per $1 \leq j \leq m-2$: $f(j) = j$. Infatti
 - $P[1 \dots j] = AA \dots A$ (j volte A)
 - $P[0 \dots j-1] = AA \dots A$ (j volte A)
- $f(m-1) = 0$ (nessun prefisso proprio di P finisce con B)

Soluzione (continua)

- ② Descrivere l'esecuzione di findKMP per $n = 9$ e $m = 5$

0	1	2	3	4	5	6	7	8
A	A	A	A	A	A	A	A	A

0	1	2	3	4	5
A	A	A	A	B	

0	1	2	3	4	5	6	7	8
A	A	A	A	A	A	A	A	A

0	1	2	3	4
A	A	A	A	B

0	1	2	3	4	5	6	7	8
A	A	A	A	A	A	A	A	A

0	1	2	3	4
A	A	A	A	B

i	j
0	0
1	1
2	2
3	3
4	4
4	3
5	4
5	3
6	4
⋮	



confronto e match



confronto e mismatch

Soluzione (continua)

- ③ Per n, m generici, determinare il numero di confronti che coinvolgono ciascun $T[i]$.

i	j
0	0
$\vdots$	$\vdots$
$m-1$	$m-1$
$m-1$	$m-2$
m	$m-1$
m	$m-2$
$m+1$	$m-1$
$m+1$	$m-2$
$m+2$	$m-1$
$m+2$	$m-2$
$m+3$	$m-1$
$\vdots$	$\vdots$


- $\forall i : 0 \leq i < m-1$ l'algoritmo fa **1** solo confronto con $T[i]$
- $\forall i \geq m-1$ l'algoritmo fa **2** soli confronti con $T[i]$

N.B.: arrivato al mismatch sull'ultimo carattere di P , non deve riprendere i confronti da $P[0]$ ma sfrutta il fatto che $P[0 \dots m-2]$ andava bene e $f(m-2) = m-2$.

Calcolo della Failure Function per un pattern P

Idea

Ho calcolato $f(i-1), f(i-2), \dots, f(1), f(0)$. Calcolo di $f(i)$:




Supponiamo che $f(i-1) = j$, e quindi $f(i) \leq j+1$. Abbiamo allora 3 casi (analoghi a quelli di `findKMP`):

- **Caso 1:** $P[i] = P[j]$. Allora, ovviamente $f(i) = j+1$

Calcolo della Failure Function per un pattern P

- **Caso 2:** $P[i] \neq P[j]$ e $j > 0$. Sia $h = f(j - 1)$.



per definizione di f le **sottostringhe in blu**, che hanno lunghezza h , sono uguali e quindi il prossimo valore candidato per $f(i)$ è $h + 1$. Imposto quindi j a h (ovvero a $f(j - 1)$) e reitero il procedimento

- **Caso 3:** $P[i] \neq P[j]$ e $j = 0$. IN questo caso, semplicemente imposto $f(i)$ a 0 e passo al calcolo di $f(i + 1)$.

Algoritmo computeFailKMP(P)

Input: pattern P , $|P| = m$

Output: failure function f for P

$i \leftarrow 1$; $j \leftarrow 0$; $f(0) \leftarrow 0$;

while $i < m$ **do**

if $P[j] = P[i]$ **then**

/* caso 1 */

$f(i) \leftarrow j + 1$;

$i \leftarrow i + 1$;

$j \leftarrow j + 1$

else

if $j > 0$ **then** $j \leftarrow f(j - 1)$;

/* caso 2 */

else

/* caso 3 */

$f(i) \leftarrow 0$;

$i \leftarrow i + 1$

return f

Esempio

$P = AAABACD$

	0	1	2	3	4	5	6				
$P =$	A	A	A	B	A	C	D	i	j	$f(i)$	CASO
		A						1	0	1	1
		A	A					2	1	2	1
		A	A	A				3	2	-	2
			A	A				3	1	-	2
				A				3	0	0	3
					A			4	0	1	1
					A	A		5	1	-	2
						A		5	0	0	3
							A	6	0	0	3

Complessità

- Proporzionale al numero di iterazioni del while
- Definiamo $\ell(i, j) = i - j$ e osserviamo che
 - ① “ $1 \leq i \leq m$ ” $\wedge$ “ $j \geq 0$ ” $\wedge$ “ i non decresce mai”
 - ② $\ell(i, j)$ non decresce mai e parte da 1
 - ③ 1), 2) $\Rightarrow 1 \leq \ell(i, j) \leq m$
 - ④ in ciascuna iterazione uno dei due valori i o $\ell(i, j)$ (o entrambi) crescono di 1

Si ha che 1), 2), 4) $\Rightarrow$ num. iterazioni $\leq 2m$

$\Rightarrow$ complessità $\in O(m)$

N.B. Il ciclo non può durare meno di $m - 1$ iterazioni

$\Rightarrow$ complessità $\in \Theta(m)$

Ripresa: complessità di findKMP

$t_{\text{findKMP}}(n, m) \in O(n + m) = O(n)$ (dato che nel problema computazionale: $m \leq n$)


$t_{\text{findKMP}}(n, m) \in \Omega(n)$?

Sì!

Se P non è sottostringa di T il ciclo while termina con $i = n$
 $\Rightarrow \Theta(n)$ iterazioni.

Correttezza di computeFailKMP

Determiniamo un invariante che vale alla fine di una generica iterazione del while (prossimo confronto $P[i]$ vs $P[j]$)



L'invariante è il seguente

- $f(0), f(1), \dots, f(i-1)$: calcolati correttamente
- $f(i) \leq j + 1$
- $P[0 \dots j-1] = P[i-j \dots i-1]$

Esercizio

Sfruttando l'invariante specificato sopra, dimostrare la correttezza di computeFailKMP

Esercizi

Esercizio (C-12.19 [GTG14])

Dati un testo T e un pattern P , con $|T| = n$, $|P| = m$, si vogliono trovare inizio e lunghezza del più lungo prefisso di P in T in tempo $O(n + m)$.

- 1 Modificare l'algoritmo `findKMP` per risolvere il problema.
- 2 Far vedere che la complessità dell'algoritmo è $\Theta(n + m)$

Esercizio

Dati un testo T e un pattern P , con $|T| = n$, $|P| = m \leq n$, si vogliono trovare *tutte* le occorrenze di P in T .

- 1 Modificare l'algoritmo `findKMP` per risolvere il problema.
- 2 Analizzare la complessità dell'algoritmo.

Esercizi

Esercizio

Dati un testo T e un pattern P , con $|T| = n$, $|P| = m \leq n$, si vuole determinare se P è *sottostringa circolare* di T , cioè se:

- P è sottostringa (“normale”) di T ; oppure
- P si può ottenere concatenando un suffisso di T a un prefisso di T .

(Ad esempio, DBA è sottostringa circolare di ABCDDB.)

Progettare un algoritmo che risolva il problema in tempo $O(n)$.

Riepilogo

- Definizioni: stringa, sottostringa, prefisso, suffisso
- Pattern matching come problema computazionale
- Algoritmo findBrute
 - complessità
 - correttezza
- Algoritmo findKMP
 - failure function
 - complessità
 - correttezza
- Algoritmo computeFailKMP
 - complessità
 - correttezza

Esempio domande prima parte

- Determinare la failure function per il pattern $P = \text{STATISTA}$.
- Mostrare un'istanza (T, P) su cui l'algoritmo `findBrute` esegue $\Theta((n - m + 1)m)$ operazioni.
- Analizzare la complessità di `findKMP` supponendo che il calcolo della failure function sia fatto con complessità lineare.
- Si consideri l'algoritmo `findKMP` e si supponga che in una certa iterazione del while si trovi $T[i] \neq P[j]$ con $j > 0$. Dire quale confronto farà l'algoritmo nella successiva iterazione, spiegando perché ciò è corretto.

Errata

Cambiamenti rispetto alla prima versione dei lucidi:

- Lucido 34: modificata la seconda domanda del secondo esercizio