



Εισαγωγή στη Βιοπληροφορική

Μερικές διαφάνειες από διαφάνειες βιβλίου [Neil C. Jones, Pavel A. Pevzner, Εισαγωγή στους Αλγορίθμους Βιοπληροφορικής](#)

[Και από το βιβλίο: Dan Gusfield Algorithms on Strings, Trees and Sequences, Cambridge University Press,](#)

<http://bix.ucsd.edu/bioalgorithms/slides.php>

RABIN-KARP ALGORITHM

Karp, Richard M.; Rabin, Michael O. (March 1987). "Efficient randomized pattern-matching algorithms". IBM Journal of Research and Development. 31 (2): 249–260. CiteSeerX 10.1.1.86.9502. doi:10.1147/rd.312.0249.

Slides from Can Alkan


<http://www.cs.bilkent.edu.tr/~calkan/teaching/cs481/>

using a presentation from Saltenis.

Fingerprint idea

■ Assume:

- We can compute a fingerprint $f(P)$ of P in $O(m)$ time.
- If $f(P) \neq f(T[s .. s+m-1])$, then $P \neq T[s .. s+m-1]$
- We can compare fingerprints in $O(1)$
- We can compute $f' = f(T[s+1.. s+m])$ from $f(T[s .. s+m-1])$, in $O(1)$




Algorithm with Fingerprints

- Let the alphabet $\Sigma = \{0,1,2,3,4,5,6,7,8,9\}$
- Let fingerprint to be just a decimal number, i.e.,
 $f("1045") = 1*10^3 + 0*10^2 + 4*10^1 + 5 = 1045$

- **Fingerprint-Search(T, P)**

```
01 fp ← compute f(P)
02 f ← compute f(T[0..m-1])
03 for s ← 0 to n - m do
04     if fp = f return s
05     f ← (f - T[s]*10m-1)*10 + T[s+m]
06 return -1
```



- Running time $2O(m) + O(n-m) = O(n)$

Using a Hash Function

- Problem:
 - we can not assume we can do arithmetics with m-digits-long numbers in $O(1)$ time
- Solution: Use a hash function $h = f \bmod q$
 - For example, if $q = 7$, $h(\text{"52"}) = 52 \bmod 7 = 3$
 - $h(S1) \neq h(S2) \Rightarrow S1 \neq S2$
 - But $h(S1) = h(S2)$ does not imply $S1=S2$
 - For example, if $q = 7$, $h(\text{"73"}) = 3$, but $\text{"73"} \neq \text{"52"}$
- Basic “mod q ” arithmetics:
 - $(a+b) \bmod q = (a \bmod q + b \bmod q) \bmod q$
 - $(a*b) \bmod q = (a \bmod q)*(b \bmod q) \bmod q$

Rabin-Karp Algorithm

Rabin-Karp-Search(T, P)

```
01  $q \leftarrow$  a prime larger than  $m$ 
02  $c \leftarrow 10^{m-1} \bmod q$  // run a loop multiplying by 10 mod  $q$ 
03  $fp \leftarrow 0$ ;  $ft \leftarrow 0$ 
04 for  $i \leftarrow 0$  to  $m-1$  // preprocessing
05      $fp \leftarrow (10*fp + P[i]) \bmod q$ 
06      $ft \leftarrow (10*ft + T[i]) \bmod q$ 
07 for  $s \leftarrow 0$  to  $n - m$  // matching
08     if  $fp = ft$  then // run a loop to compare strings
09         if  $P[0..m-1] = T[s..s+m-1]$  return  $s$ 
10      $ft \leftarrow ((ft - T[s]*c)*10 + T[s+m]) \bmod q$ 
11 return -1
```



Semi-Numerical Algorithms

Wu, Sun; Manber, Udi (20–24 January 1992). Agrep -- a fast approximate pattern-matching tool. 1992 Winter USENIX Conference. San Francisco, California.
CiteSeerX 10.1.1.89.5424

Udi Manber, Sun Wu. "Fast text search allowing errors." Communications of the ACM, 35(10): pp. 83–91, October 1992, doi:10.1145/135239.135244.

Ο αλγόριθμος Shift-Or

- Ο αλγόριθμος χρησιμοποιεί αριθμητικές τεχνικές:
 1. Έστω για κάθε char $c \in \Sigma$, το διάνυσμα S_c μεγέθους $m=|P|$, που αποθηκεύει τις εμφανίσεις του c μέσα στο πρότυπο (με $0 \leq p < m$ προσδιορίζεται η εμφάνιση),
 2. Ο πίνακας $R[m \times n]$: bit-array όπου $R[i,j]$ είναι 0 αν και μόνο αν οι πρώτοι i χαρακτήρες του P ταιριάζουν με τους i χαρακτήρες που τελειώνουν στο j -οστό χαρακτήρα του T .
 3. $R_{j+1} = \text{Shift}(R_j) \text{ OR } S_{T[j+1]}$

Ας δούμε τον αλγόριθμο στην πράξη

1ο βήμα: Υπολογίζω τα διανύσματα S_c για το πρότυπο $x=gcagagag$

	S_a	S_c	S_g	S_t
g	1	1	0	1
c	1	0	1	1
a	0	1	1	1
g	1	1	0	1
a	0	1	1	1
g	1	1	0	1
a	0	1	1	1
g	1	1	0	1

$$R_{j+1} = \text{Shift}(R_j) \text{ Or } S_{T[j+1]}$$
[illegible]


Ανάλυση του αλγορίθμου Shift-Or σε χρόνο

- Πολυπλοκότητα μεθόδου: $O(n+m)$, όπου $|T|=n$ & $|P|=m$
 1. Σε χρόνο $O(m \cdot \sigma)$ υπολογίζω, τα διανύσματα S_c

Ακριβής Εύρεση για ένα σύνολο προτύπων

Ορισμός: «έστω μια ακολουθία χαρακτήρων Y . Αναζητούμε τις θέσεις εμφάνισης ενός συνόλου προτύπων P μέσα στην ακολουθία».

$P = \{acg, taaaca\}$






Aho, Alfred V.; Corasick, Margaret J. (June 1975). "Efficient string matching: An aid to bibliographic search". Communications of the ACM. **18** (6): 333–340. doi:10.1145/360825.360855. MR 0371172. S2CID 207735784.

Το Αυτόματο Aho-Corasick

Έστω $P = \{ca, tca, cgt, cat\}$



goto function

Η Συνάρτηση “goto”

- $g(s, a) = s'$: το αυτόματο μεταπηδά στην κατάσταση s' και ο επόμενος χαρακτήρας της ακολουθίας διαβάζεται στην είσοδο,
- $g(s, a) = \text{fail}$, το αυτόματο μεταβαίνει στην κατάσταση $s' = f(s)$ σύμφωνα με τη failure function. Η αναζήτηση συνεχίζεται με τρέχουσα κατάσταση την s' και σύμβολο εισόδου το χαρακτήρα που ήδη έχει διαβαστεί στην είσοδο $\rightarrow a$.

Η Συνάρτηση “failure-function”

- $f(s) = 0$, για κάθε κατάσταση s , βάθους 1.
- Για να υπολογίσεις το $f(s)$, για κάθε κατάσταση s , βάθους d , θεώρησε όλες τις καταστάσεις r , βάθους $d-1$:
 - Αν $g(r, a) = \text{fail}$, κάθε a , μην κάνεις τίποτα,
 - Διαφορετικά, για κάθε σύμβολο a , έτσι ώστε $g(r, a) \neq \text{fail}$, τότε:
 - ο $\text{state} = f(r)$
 - ο Εκτέλεσε την εντολή $\text{state} \leftarrow f(\text{state})$, έως ότου $g(\text{state}, a) \neq \text{fail}$
- Θέσε $f(s) = g(\text{state}, a)$




Figure 3.16: Keyword tree showing the failure links.

Ο αλγόριθμος Aho-Corasick (1)

- $l := 1; c := 1; w := \text{root};$
- ΕΠΑΝΑΛΑΒΕ
- ΕΝΟΣΩ υπάρχει ακμή (w, w') με ετικέτα $T(c)$
- ΕΑΝ ο κόμβος w' έχει ετικέτα i ανέφερε την εμφάνιση του p_i
- $w := w';$ και $c := c + 1;$
- ■ Διαφορετικά $w := \text{failure_link}(w); l := c - \text{βαθος}(w).$
- ΜΕΧΡΙ $c > n$

Ο αλγόριθμος Aho-Corasick (2)

$P = \{acatt, ca\}$ and $T = acatg$

Αν πρότυπα είναι υποσυμβολοσειρά άλλων αλλαγή αλγορίθμου:

- $l := 1; c := 1; w := \text{root};$
- ΕΠΑΝΑΛΑΒΕ
- ΕΝΟΣΩ υπάρχει ακμή (w, w') με ετικέτα $T(c)$
- ΕΑΝ ο κόμβος w' έχει ετικέτα i ή υπάρχει αλυσίδα από failure links σε
- κόμβο με ετικέτα i , ανέφερε την εμφάνιση του p_i
- $w := w';$ και $c := c + 1;$
 - Διαφορετικά $w := \text{failure_link}(w); l := c - \text{βαθος}(w).$
- ΜΕΧΡΙ $c > n$

Αντικατάσταση αλυσίδας failure links με ένα output link.

Συνολικός χρόνος $O(m)$

από το βιβλίο: Dan Gusfield Algorithms on Strings, Trees and Sequences, Cambridge University Press,

Εφαρμογές εύρεσης προτύπων σε προβλήματα Βιοπληροφορικής

- Αναζήτηση ***Sequence-tagged-site (STS) & Expressed Sequence Tags (ESTs)*** σε ακολουθίες γονιδιωμάτων.
 - ***STS***: τμήματα του DNA μήκους 200-300 νουκλεοτιδίων
 - ***ESTs***: τμήματα mRNA & cDNA ακολουθίες που αντιπροσωπεύουν τα τμήματα κωδικοποίησης μιας πρωτεΐνης σε μια ακολουθία γονιδίων.
- Αναζήτηση transcription factors
- Αναζήτηση "***κανονικών εκφράσεων***" (regular expressions)
 - [ED]-[EN]-L-[SAN]-x-x-[DE]-x-E-L $\Rightarrow$ **ENLSSEDEEL**
PROSITE