

מבני נתונים ואלגוריתמים – תרגול #11

התאמת מחרוזות

סימונים והגדרות:

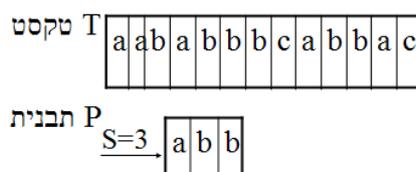
- **טקסט T** (מערך של תווים) באורך n – $T[0, \dots, n-1]$ ו**תבנית P** באורך m – $P[0, \dots, m-1]$ כך ש- $n \leq m$.
- התווים של P ו-T נלקחים מאלפבית סופי Σ . לדוגמא: $\Sigma = \{0,1\}, \{a,b,\dots,z\}$.
- Σ^* – קבוצת כל המחרוזות באורך סופי שניתן להרכיב מ- Σ .
- ε – המחרוזת הריקה. מתקיים ש- $\varepsilon \in \Sigma$.

בעיית התאמת מחרוזות:

- רוצים למצוא את כל המופעים של P ב-T.
- רוצים למצוא את כל האינדקסים (=היסטים) ב-T כך ש-

$$T[i, \dots, i + m - 1] = P[0, \dots, m - 1]$$

לדוגמא:



- תהי X מחרוזת. נסמן ב- X_i את המחרוזת שמכילה את התווים מ-0 עד i ב-X ואורכה i. כלומר $X_i = X[0, \dots, i-1]$.
- **רישא:** x רישא של y אם קיים z כך ש- $xz = y$ (=שרשור של x עם z).
- **סיפא:** x סיפא של y אם קיים z כך ש- $zx = y$.

הגדרה נוספת של הבעיה:

- רוצים למצוא את כל ההיסטים m כך ש-P סיפא של T_m .

האלגוריתם הנאיבי

- בודקים את כל ההיסטים שהאפשריים באמצעות לולאה שרצה מ-0 עד $n-m$.

סיבוכיות: $O((n-m+1)m) \rightarrow O(nm)$.

אלגוריתם רבין-קרפ

- מתייחסים למחרוזת כמספר (לפי ערך ה-ASCII של התווים).
- בגלל שמחרוזות הן מערכים, השוואה בין 2 מחרוזות תלויה באורך n שלהם, ולכן זה לא קבוע – $O(n)$.
- הרעיון – נשתמש בפונקציית hash. נחשב את ערך ה-hash של התבנית, ונשווה אותו לערך ה-hash של כל תתי-המחרוזות בטקסט.

מימוש נאיבי:

- נחשב את $H(P)$ – לוקח $O(m)$ (m-אורך התבנית).
- עוברים על כל תתי המחרוזות t ב-T, מחשבים את $H(t)$ ומשווים ל- $H(P)$. $O(nm)$.

שיפור: נשתמש ב-Rolling Hash

זוהי פונקציית Hash מיוחדת מחשבת את ערך ה-Hash עבור תת-המחרוזת הראשונה ב-T בזמן $O(m)$ (כאורך התבנית), ואז מחשבת את תת המחרוזת הבאה מתוך תת-המחרוזת הראשונה ב- $O(1)$ וכך הלאה.

סיבוכיות - $O(n+m)$.

אלגוריתם KMP

על מנת להימנע מהשוואות מיותרות, נשתמש במידע שיש בתבנית P עצמה. מחשבים את פונקציית Π – פונקציית הרישא עבור תבנית P באורך m.

$\Pi(i) = j$ – האינדקס המקסימלי j ($0 \leq j < i$) המקיים ש- P_j היא סיפא של P_i (לכל $0 \leq i < m$).

דוגמא:

	0	1	2	3	4	5
Π	-1	0	0	1	2	0

$P = a b a b c$

$\Pi(1)$ – צריך למצוא את הרישא הכי ארוכה של $P_0 = \epsilon$ שהיא סיפא של $P_1 = a$. אין - לכן $\Pi(1) = 0$.

$\Pi(2)$ – צריך למצוא את הרישא הכי ארוכה של $P_1 = a$ שהיא סיפא של $P_2 = ab$. אין - לכן $\Pi(2) = 0$.

$\Pi(3)$ – צריך למצוא את הרישא הכי ארוכה של $P_2 = ab$ שהיא סיפא של $P_3 = aba$, לכן $\Pi(3) = 1$.

וכן הלאה.

הרעיון הכללי של האלגוריתם: מחפשים את P ב-T. בכל פעם שיש אי-התאמה, נסיט את P ימינה בהיסט הקטן ביותר האפשרי שמקיים שעדיין יש התאמה של התווים הראשונים ב-P לבין התווים האחרונים ב-T.

דוגמת הרצה:

```
j: 0 1 2 3 4 5 6
p[j]: a b a b a a
b[j]: -1 0 0 1 2 3 1
```

```
0 1 2 3 4 5 6 7 8 9 ...
a b a b b a b a a
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
```

סיבוכיות: $O(m+n)$.

הסברים נוספים:

<http://www.inf.fh-flensburg.de/lang/algorithmen/pattern/kmpen.htm>

בנוסף, KMP יכול לחשב את σ – פונקציית הסיפא.

$\sigma(i) = j - i$ הוא אורך הרישא המקסימלית של התבנית P_j שהיא סיפא של T_i (לכל $0 < i < n$).

לדוגמא:

$T = a a b a a c a a$

	0	1	2	3	4	5	6	7	8	9
σ	0	1	2	2	3	4	5	0	1	2

$P = a a b a a$

נחפש ב- $T_4 = a a a b$ את הסיפא המקסימלית שהיא רישא של $P_3 = a a b$.

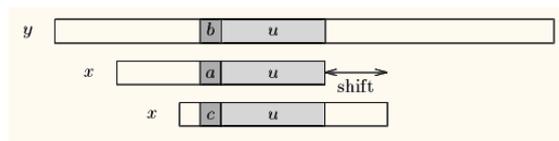
נחפש ב- $T_6 = a a a b a a$ את הסיפא המקסימלית שהיא רישא של $P_5 = a a b a a$.

אלגוריתם BM

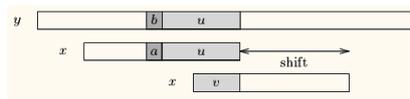
האלגוריתם משווה את התבנית מול תחילת הטקסט אך מתחיל את השוואה של מסוף התבנית עד לתחילתה. האלגוריתם עושה preprocessing על התבנית ויוצר 2 פונקציות. מטרתן לקדם את התבנית תוך כדי "דילוג" על תווים שאנחנו יודעים בודאות שהתבנית לא תימצא בהם.

Good-suffix shift: נבדוק את הסיפא של תת-המחרוזת שבה הייתה התאמה. נקדם את התבנית בבטחה כך שהתווים בהם הייתה התאמה עדיין זהים.

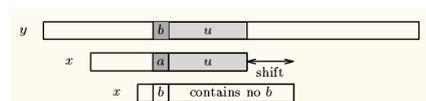
נניח ששי אי-ההתאמה בין $x[i]=a$ לבין $y[i+j]=b$. כלומר יש התאמה בין הטקסט לתבנית מסוף התבנית עד ל- $i+1$ (תת-מחרוזת u). המטרה היא להזיז את התבנית כך שהמופע הבא הימני ביותר של u יהיה מול הטקסט במיקום $j+i+1$.



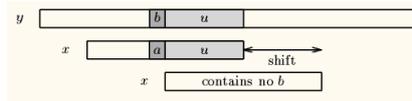
אם אין תת-מחרוזת כזאת, נזיז את התבנית כך שהסיפא הארוכה ביותר v של $y[i+j+1...j+m-1]$ תהיה מול הרישא המתאימה של התבנית.



Bad-char shift: המטרה להזיז את התבנית עד למופע הבא של התו $y[i+j]$ בתבנית.



אם אין, אפשר להזיז את כל התבנית מול $y[i+j+1]$.



האלגוריתם בוחר את ההזזה המקסימלית מבין ה-GSS וה-BCS.

סיבוכיות: $O(n+m)$.

דוגמא והסברים נוספים: <http://www-igm.univ-mlv.fr/~lecroq/string/node14.html>

תרגילים

תרגיל:

הגדרה: נסמן ב- T^R את המחרוזת ההופכית של T (באורך n), כלומר $T^R = T(n-1)T(n-2)...T(0)$.

T פלינדרום אם $T = T^R$.

בהינתן מחרוזת T באורך n , תארו אלגוריתם שמוצא את אורך הרישא המקסימלית של T שהינה פלינדרום.

$T = \text{abaababa}$

לדוגמא-



אז נחזיר $j=6$.

פיתרון:

אם x רישא של T , אז קיים y כך ש- $T = xy$. לכן מתקיים $T^R = y^R x^R$.

אם x פלינדרום אז $T^R = y^R x$ (גם הכיוון השני נכון).

לכן מספיק למצוא את הרישא הארוכה ביותר של T שהיא סיפא של T^R .

← נריץ KMP כך הטקסט שלנו הוא T^R והתבנית היא T ונחזיר $\sigma(n) = j$ ה- j המקסימלית כך ש- T_j סיפא של T^R .

סיבוכיות: $O(n) = O(2n) = O(m+n)$. (נאיבי: $O(n^2)$).

תרגיל:

נתונה מחרוזת T שאורכה $n \geq 10$. תארו אלגוריתם המוצא חלוקה $T = xy$ כך ש- $|y| \geq 10$ והאורך של x מקסימלי.

*הערה – תמיד קיימת חלוקה כזו, כיוון ש- x יכולה להיות ϵ .

דוגמא:
 $T = \text{aaba} \overbrace{\text{aaaaabbcbb}}_{|y|=11} \text{aaaaabaa}$

$x = \text{aaba}$

פיתרון:

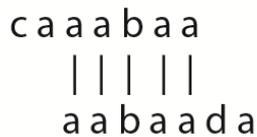
מה יכול להיות האורך המקסימלי של x ? $|x| \leq \lfloor \frac{(n-10)}{2} \rfloor = k$

• בדוגמא : $k = \lfloor \frac{21-10}{2} \rfloor = 5$

רוצים למצוא את הרישא המקסימלית של T באורך לכל היותר k שהיא גם סיפא של T .

← נריץ KMP כאשר התבנית היא T_k והטקסט הוא k התווים האחרונים ב- T .

סיבוכיות: $O(n)$.
 $T = \overset{P}{\text{aabaada}} \overset{T}{\text{abbccccbbacaabaa}}$
— דוגמא



$|x| = 5$

תרגיל:

הגדרה: מחרוזת T' היא סיבוב מעגלי של מחרוזת $T = t_1 t_2 \dots t_n$ אם קיים $1 \leq i \leq n$ כך שמתקיים:

$T' = t_i t_{i+1} \dots t_n t_1 t_2 \dots t_{i-1}$

דוגמא: $\text{car} \leftrightarrow \text{arc}$

נתונות 2 מחרוזות T, T' באורך n . תארו אלגוריתם הבודק האם T' הינה סיבוב של T .

פיתרון:

נשים לב ש- T' סיבוב מעגלי של T אם הם T' מופיע ב- TT .

$TT = t_1 t_2 t_3 \dots t_{i-1} \underbrace{t_i t_{i+1} t_{i+1} \dots t_n t_1 t_2 \dots t_{i-1} t_i}_{T'} \dots t_n$

← נריץ KMP עם טקסט TT ותבנית T' .

סיבוכיות: $O(2n+n) = O(n)$

תרגיל:

נתונות 2 מחרוזות X, Y באורך n . X אנגרמה של Y אם קיימת תמורה $p \in S_{\{0,1,\dots,n-1\}}$ כך שמתקיים

$Y = X[p(0)] X[p(1)] \dots X[p(n-1)]$

כתבו אלגוריתם שמקבל T ו- P ומוצא את כל תתי המחרוזות של T שהן אנגרמות של P .

פיתרון:

נריץ RB עם Rolling hash שמחשב את ערך ה-Hash על המחרוזת ללא תלות בסדר האותיות ואז אם $RH(x) = RH(y)$ הן אנגרמות אז $x = y$.

לדוגמא – לכל אות $a \in \Sigma$ נבחר מספר גדול N_a (כדי שסכום 2 מספרים יהיה ייחודי) ונגדיר:

$$RH(s) = \sum_{i=0}^{len(s)-1} N_{s[i]}$$