




■ Mintaillesztő algoritmusok

- **Feladat:** egy adott **P minta** összes előfordulásának megtalálása egy adott **T szöveg**ben. P és T karakterei egyaránt a véges elemű Σ **ábécé** jelei.
- **Input:**
 - **T szöveg**, pl.: T= "**lelkes labdarúgók**"
 - $n = \text{hossz}(T) = 17$
 - **P minta**, pl.: P= "**labda**"
 - $m = \text{hossz}(P) = 5$
- **Output:**
 - **s eltolás**értékek, melyeknél a P minta a T szövegben megtalálható:
 $T[s+1..s+m] = P[1..m] \quad 0 \leq s \leq n-m;$






■ Vizsgált algoritmus típusok

- Egyszerű mintaillesztő algoritmus
- Rabin-Karp mintaillesztő algoritmus
- Knuth-Morris-Pratt mintaillesztő algoritmus

■ Egyszerű mintaillesztő algoritmus

- Minden s eltolást megvizsgál a $0 \leq s \leq n$ intervallumban.
- Egyszerű_mintaillesztő(T, P)
 - $n \leftarrow \text{hossz}(T)$
 - $m \leftarrow \text{hossz}(P)$
 - for** $s \leftarrow 0$ **to** $n-m$ **do**
 - $j \leftarrow 1$
 - while** $j \leq m$ **and** $T[s + j] = P[j]$ **do**
 - $j \leftarrow j + 1$
 - if** $j = m+1$ **print** s

■ Példák az Egyszerű mintaillesztő algoritmus működésére





■ Az Egyszerű mintaillesztő algoritmus elemzése


- **Legrosszabb eset**
 - For ciklus: $(n-m+1)$
 - While ciklus: (m) elem-összehasonlítás
 - Összes elem-összehasonlítás: $(n-m+1)*m$
 - Elem-összehasonlítás arányos futási idő $\Theta((n-m+1)*m)$
- **Legjobb eset**
 - For ciklus: $(n-m+1)$
 - While ciklus: (1) elem-összehasonlítás
 - Összes elem-összehasonlítás: $(n-m+1)*1$
 - Elem-összehasonlítás arányos futási idő $\Theta((n-m+1))$
- **Átlagos eset**
 - A szöveg és a minta karakterei egyenletes véletlen eloszlásúak
 - $O(n-m)$, elég hatékony

Lásd 2.



■ Rabin-Karp mintaillesztő algoritmus

- **Alapgondolat:** ha a szöveg és a minta is csak számokból állna, valamint a minta számjegyekaraktereit egyetlen többjegyű számnak tekinthetnénk, hasonlóan a szöveg mintahossznyi részeit is egy-egy számértékkel reprezentálhatnánk, akkor a mintakeresés $n-m+1$ lépésben elvégezhető lenne.





■ Rabin-Karp mintaillesztő algoritmus ..

- **Jelölések:**

- **Az ábécé** $\Sigma = \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$, $|\Sigma| = 10$
- A minta számjegyekaraktereit számértékre átszámító függvény:
 $f(P)$ a Horner séma alkalmazásával $O(m)$ időben kiszámítható,
 $f(P) = P[m] + 10 \cdot (P[m-1] + 10 \cdot (P[m-2] + \dots + 10 \cdot (P[2] + 10 \cdot (P[1])) \dots))$
Pl.: $f("01027") = 7 + 10 \cdot (2 + 10 \cdot (0 + 10 \cdot (1 + 10 \cdot (0)))) = 1027$
- Ha adott, vagy az előző módszerrel számítva rendelkezésre áll a T szöveg s eltolású, mintahosszúságú részének számértéke f_s , akkor f_{s+1} $O(1)$ idő alatt számítható:
 $f_{s+1} = 10 \cdot (f_s - 10^{m-1} \cdot T[s+1]) + T[s+m+1]$

Pl.: $T = "10223010272"$; $s=2$; $f_s = 22301$; $f_{s+1} = 10 \cdot (22301 - 10^4 \cdot 2) + 0 = 23010$


A teljes T szöveg értékekre való átalakításának ideje tehát $O(m+n-m)$
Mivel a keresés $O(n-m+1)$ idejű, a teljes algoritmus ideje
 $= O(m + n + n-m+1) = O(2n+1)$



■ Rabin-Karp mintaillesztő algoritmus ..

- **Az algoritmus**

```
Rabin_Karp(T, P)
  fp ← f(P)
  fs ← f(T[1..m])
  for s ← 0 to n – m do
    if fp = fs print s
    if s < n-m then
      fs = 10*(fs – 10m-1 * T[ s+1 ]) + T[ s+m+1 ]
```



- **Probléma:** ha m elég nagy, az $f()$ függvényértékek ábrázolása külön algoritmust igényel, $f()$ kiértékelése nem $O(1)$ idejű.
- **Megoldás:** az $f()$ értékek helyett számítsuk és használjuk azok q -ra vett modulóját, q célszerűen olyan prímszám, hogy $|\Sigma|^m \cdot q$ még éppen ábrázolható. Ha $fp \bmod q \neq fs \bmod q \Rightarrow fp \neq fs$ de $fp \bmod q = fs \bmod q \Rightarrow fp = fs$.
Pl.: $65 \bmod 11 = 10 \neq 89 \bmod 11 = 1 \Rightarrow 65 \neq 89$
de $65 \bmod 11 = 10 = 87 \bmod 11 = 10 \not\Rightarrow 65 = 87$, azaz a maradékegyezések további vizsgálatot kívánnak.



■ Meggondolások

- **Felhasznált modulo azonosságok**

- $(a+b) \bmod q = (a \bmod q + b \bmod q) \bmod q$
- $(a * b) \bmod q = (a \bmod q) * (b \bmod q) \bmod q$

- **Előfeldolgozás**

- $d = |\Sigma|$, 'számrendszer alapszáma' = ábécé elemszáma, $q > d$
- $fpm = (P[m] + d*(P[m-1] + d*(P[m-2] + \dots$
 $\dots + d*(P[2] + d*P[1]) \dots)) \bmod q =$
 $(d*((d*\dots((d*((d*0+P[1]) \bmod q)+P[2]) \bmod q)+\dots$
 $\dots + P[m-1]) \bmod q)+P[m]) \bmod q$
- Hasonlóan számítandó fsm a $T[1..m]$ szövegrészletből.
- Pl.: $P="1234"$; $d=10$; $q=11$; $1234 \bmod 11 = 2 =$
 $(10*((10*((10*(1 \bmod 11)+2) \bmod 11)+3) \bmod 11)+4) \bmod 11 = 2$

- **Keresés**, $T[s+1]$ kiléptetése, $T[s+m+1]$ beléptetése

- $fsm_{s+1} = (d*(fsm_s - h * T[s+1]) + T[s+m+1]) \bmod q$,
ahol a $h = d^{m-1} \bmod q$ számítható az előfeldolgozásban.



■ A módosított Rabin-Karp mintaillesztő algoritmus

- Rabin_Karp_Modulo(T, P, d, q)
 $m \leftarrow \text{hossz}(P)$
 $n \leftarrow \text{hossz}(T)$
 $h \leftarrow d^{m-1} \bmod q$ *// valójában $(d \bmod q)$ szorzása önmagával ciklusban*
 $fpm \leftarrow 0$ *// a minta értékének modulója*
 $fsm \leftarrow 0$ *// a szöveg s eltolású része értékének modulója*
 for $i \leftarrow 1$ **to** m **do**
 $fpm \leftarrow (d \cdot fpm + P[i]) \bmod q$
 $fsm \leftarrow (d \cdot fsm + T[i]) \bmod q$
 for $s \leftarrow 0$ **to** $n-m$ **do** *// keresés*
 if $fpm = fsm$ **then** *// csak lehetőség, ellenőrizni kell*
 $j \leftarrow 1$ *// szerencsére csak ritkán kell ellenőrizni*
 while $j \leq m$ **and** $T[s+j] = P[j]$ **do**
 $j \leftarrow j + 1$
 if $j = m+1$ **print** s
 if $s < n-m$ **then**
 $fsm \leftarrow (d \cdot (fsm - h \cdot T[s+1]) + T[s+m+1]) \bmod q$ *// léptetés*




- **Legrosszabb eset**

- **Általános eset**

- Általános esetben az érvényes eltolások száma kicsi
- Futási idő $O(n) + O(m^*(v+n/q))$, ahol v az érvényes eltolások száma
- Ha $q \geq n$, ez az idő $O(n)$

- **Megjegyzés**

- Az algoritmus könnyen kiterjeszthető kétdimenziós mintakeresésre





■ Knuth-Morris-Pratt mintaillesztő

- Cél: a szöveg minden egyes karakterét **csak egyszer** felhasználni összehasonlításban
- Az Egyszerű mintaillesztő **elfelejti** a külső ciklus előző lépésében talált részleges illeszkedés során birtokába került információkat:

Pl.: T="kirándulnak a kirándulók a hegyekbe"

P="kiránduló"

Mivel csak egy 'k' van P-ben, az első eltérést adó pozícióba ugorhatunk az eltolással.

T="blablablablalakban"

P="blabla**l**ak"

Mekkora a legnagyobb ugrás P eltolásában, mely nem hagy ki esetleges egyezést? Toljuk rá hátulról a P mintát a T text feltárt részére, hogy a legnagyobb egyezést kapjuk:

T="blablablablalakban"

P="blabla**l**ak"

- Ezek, a mintának önmaga kezdeteire hátulról való rátolthatóságára vonatkozó információk az előkészítési fázisban előállíthatók!



■ A π prefix függvény

- A $\pi(q)$ prefix függvény megadja, hogy a P minta q hosszúságú első részére a mintát hátulról nem teljesen rátolva az legfeljebb hány karakterrel hozható fedésbe.

$\pi(1)$ legyen 0.

- Példa:**

P="blab^lalak"

$$\pi(1) = 0$$

$$\pi(2) = 0$$

$$\pi(3) = 0$$

$$\pi(4) = 1$$

1 2 3 4 5 6 7 8 9
b l a b l a l a k

b l a b l a l a k

$$\pi(5) = 2$$

1 2 3 4 5 6 7 8 9
b l a b l a l a k

b l a b l a l a k

$$\pi(6) = 3$$

1 2 3 4 5 6 7 8 9
b l a b l a l a k

b l a b l a l a k

$$\pi(7) = 0$$

$$\pi(8) = 0$$

$$\pi(9) = 0$$



■ A π prefix függvény algoritmus

- A prefix függvény értékei a P minta ismeretében az előkészítő fázisban meghatározhatók
- Prefix_függvény_számitás(P)
 $m \leftarrow \text{hossz}(P)$
 $\pi[1] \leftarrow 0$
 $k \leftarrow 0$
 for $q \leftarrow 2$ **to** m **do**
 while $k > 0$ **and** $P[k+1] \neq P[q]$ **do**
 $k \leftarrow \pi[k]$
 if $P[k+1] = P[q]$ **then**
 $k \leftarrow k+1$
 $\pi[q] \leftarrow k$
 return π
- A Prefix függvény számítás futási ideje $O(m)$.



■ A Knuth-Morris-Pratt mintaillesztő algoritmus

- A prefix függvény értékeinek ismeretében az algoritmus átugorhatja azon eltolások vizsgálatát, melyek eleve érvénytelenek.
- KMP_mintaillesztő
 $m \leftarrow \text{hossz}(P)$
 $n \leftarrow \text{hossz}(T)$
 $\pi \leftarrow \text{Prefix_függvény_számítás}(P)$
 $q \leftarrow 0$
 for $i \leftarrow 1$ **to** n **do**
 while $q > 0$ **and** $P[q+1] \neq T[i]$ **do**
 $q \leftarrow \pi[q]$
 if $P[q+1] = T[i]$ **then**
 $q \leftarrow q+1$
 if $q = m$ **then**
 print $i-m+1$
 $q \leftarrow \pi[q]$
- A KMP mintaillesztő futási ideje $O(m+n)$, igen kedvező.