

Enajste vaje APS2: Tabela najdaljših skupnih predpon

Tabela najdaljših skupnih predpon (angl. longest common prefix array, LCP) je tesno povezana s priponsko tabelo (angl. suffix array, SA) podanega niza T dolžine n , ki smo jo spoznali na predavanjih. Spomnimo se, da je i -ti element priponske tabele za niz T enak indeksu začetka pripone, ki se v leksikografsko urejenem zaporedju vseh pripon niza T nahaja na i -tem mestu. To pomeni, da je $\mathcal{U}(T) = \langle T[SA[1] :], T[SA[2] :], \dots, T[SA[n] :] \rangle$ leksikografsko urejeno zaporedje vseh pripon.

Tabela 1 prikazuje priponsko tabelo (in še nekaj drugih reči) za niz **abrakadabra**. Leksikografsko urejeno zaporedje pripon za ta niz je $\mathcal{U} = \langle \mathbf{a}, \mathbf{abra}, \mathbf{abrakadabra}, \mathbf{adabra}, \mathbf{akadabra}, \mathbf{bra}, \mathbf{brakadabra}, \mathbf{dabra}, \mathbf{kadabra}, \mathbf{ra}, \mathbf{rakadabra} \rangle$.

Najdaljša skupna predpona nizov A in B je najdaljši niz C , ki je tako predpona niza A kot predpona niza B ; dolžino takšnega niza C bomo označili z $L(A, B)$. Tabela najdaljših skupnih predpon pa je definirana takole:

- $LCP[1] = 0$.
- Pri $i \geq 2$ je $LCP[i]$ dolžina najdaljše skupne predpone pripon, ki v zaporedju $\mathcal{U}$ nastopata na mestih i in $i - 1$. Velja torej

$$LCP[i] = L(T[SA[i - 1] :], T[SA[i] :]).$$

Tabela 1: Priponska tabela in njene sorodnice za niz **abrakadabra**.

i	$SA[i]$	$T[SA[i] :]$	$R[i]$	$bp(i)$	$LCP[i]$
1	11	a	3	—	0
2	8	abra	7	6	1
3	1	abrakadabra	11	7	4
4	6	adabra	5	8	1
5	4	akadabra	9	9	1
6	9	bra	4	10	0
7	2	brakadabra	8	11	3
8	7	dabra	2	2	0
9	5	kadabra	6	4	0
10	10	ra	10	1	0
11	3	rakadabra	1	5	2

Izračun

Da si olajšamo notacijo, definirajmo tabelo R kot inverz tabele SA . Vrednost $R[i]$ je torej mesto pripone $T[i :]$ v zaporedju $\mathcal{U}$. Definirajmo še funkcijo

$$bp(i) = R[SA[i] + 1].$$

Vrednost $bp(i)$ je torej indeks tiste pripone v zaporedju $\mathcal{U}$, ki je enaka priponi $T[SA[i] :]$ brez prvega znaka. V našem primeru je $bp(2) = 6$: v zaporedju $\mathcal{U}$ se na drugem mestu nahaja pripona **abra**, pripona **bra** (**abra** brez prvega znaka) pa se v zaporedju $\mathcal{U}$ nahaja na šestem mestu. Vrednost $bp(i)$ je definirana za vse $i \in \{1, \dots, n\}$ razen za $i = R[n]$ ($R[n]$ je položaj pripone $T[n :]$ v zaporedju $\mathcal{U}$, ta pripona pa je en sam znak).

Tabelo LCP lahko izdelamo neposredno po definiciji, a za to potrebujemo $O(n^2)$ časa. K sreči pa obstaja tudi algoritem, ki tabelo zgradi v času $O(n)$. Algoritem temelji na razmeroma preprostem opažanju:

Trditev 1. Za vsak $i \neq R[n]$ velja $LCP[bp(i)] \geq LCP[i] - 1$.

Dokaz. Če je $LCP[i] \leq 1$, lastnost iz trditve trivialno velja, zato lahko predpostavimo $LCP[i] \geq 2$.

Za lažjo predstavo se zopet obrnimo na niz **abrakadabra**. Vzemimo $i = 3$. Ker sta druga in tretja pripona v zaporedju $\mathcal{U}$ enaki $T[SA[i-1] :] = \mathbf{abra}$ in $T[SA[i] :] = \mathbf{abrakadabra}$, je $LCP[i] = 4$. Ker velja $bp(i) = 7$, $T[SA[bp(i)] :] = \mathbf{brakadabra}$ in $T[SA[bp(i)-1] :] = \mathbf{bra}$, je $LCP[bp(i)] = L(\mathbf{brakadabra}, \mathbf{bra}) = 3$. Vsaj v tem primeru je res $LCP[bp(i)] \geq LCP[i] - 1$.

Po definiciji funkcije bp je $T[SA[bp(i)] :] = T[SA[i] + 1 :]$. Če je $LCP[i] = L(T[SA[i] :], T[SA[i-1] :]) = \ell$, potem je torej $L(T[SA[bp(i)] :], T[SA[i-1] + 1 :]) = \ell - 1$; če nizoma z dolžino skupne predpone $\ell \geq 2$ odbijemo prvi znak, bo dolžina skupne predpone seveda $\ell - 1$. Žal pa ne iščemo

$$L(T[SA[bp(i)] :], T[SA[i-1] + 1 :]) = \ell - 1,$$

pač pa

$$LCP[bp(i)] = L(T[SA[bp(i)] :], T[SA[bp(i)-1] :]).$$

Niz $T[SA[i-1] + 1 :]$ je pripona na mestu $(i-1)$ v zaporedju $\mathcal{U}$, ki ji odbijemo prvi znak, niz $T[SA[bp(i)-1] :]$ pa je pripona, ki jo dobimo tako, da priponi na i -tem mestu odbijemo prvi znak in poiščemo njeno predhodnico v zaporedju $\mathcal{U}$. V primeru $i = 3$ gre sicer za eno in isto pripono (**bra**), pri $i = 11$ pa to ni res: pripona **rakadabra** je neposredna naslednica pripone **ra** v zaporedju $\mathcal{U}$, pripona **akadabra** pa ni neposredna naslednica pripone **a**. V vsakem primeru pa velja sledeče:

- Ker je $T[SA[i-1] :] < T[SA[i] :]$, je tudi $T[SA[i-1] + 1 :] < T[SA[bp(i)] :]$. Jasno: če je niz A leksikografsko pred nizom B , bo niz $A[2 :]$ prav tako leksikografsko pred nizom $B[2 :]$ (ob predpostavki, da sta vsaj prva znaka nizov A in B med seboj enaka).
- Pripona $T[SA[i-1] :]$ (npr. **ra**) je po definiciji priponske tabele neposredna predhodnica pripone $T[SA[i] :]$ (npr. **rakadabra**), pripona $T[SA[i-1] + 1 :]$ (npr. **a**) pa v splošnem ni nujno neposredna predhodnica pripone $T[SA[bp(i)] :]$ (npr. **akadabra**); lahko bi v zaporedju $\mathcal{U}$ obstajale še kakšne vmesne pripone (npr. **abra**, **abrakadabra** in **adabra**). Vendar pa bo za vsako tako vmesno pripono P dolžina najdaljše skupne predpone niza P in niza $T[SA[bp(i)] :]$ enaka najmanj $L(T[SA[i-1] + 1 :], T[SA[bp(i)] :]) = \ell - 1$. (Na primer, niz **post** ni nujno neposredni predhodnik niza **potnik**, vendar pa za vse morebitne vmesne nize S (**pošta**, **pot**, **potnica**, ...) velja $L(\text{potnik}, S) \geq L(\text{potnik}, \text{post})$.)

Lastnost iz trditve je tako dokazana. □

Kako nam lahko trditev 1 pomaga pri računanju najdaljše skupne predpone med zaporednimi priponami v zaporedju $\mathcal{U}$? Če za pripono $A = T[SA[i] :]$ (in njeno predhodnico $B = T[SA[i-1] :]$ v zaporedju $\mathcal{U}$) ugotovimo, da je $L(A, B) = \ell$ (torej $LCP[i] = \ell$), potem se bomo v naslednjem koraku ukvarjali s pripono $A' = A[2 :] = T[SA[bp(i)] :]$, saj bomo vedeli, da je dolžina najdaljše skupne predpone med A' in njeno predhodnico $B' = T[SA[bp(i)-1] :]$ v zaporedju $\mathcal{U}$ najmanj $\ell - 1$, kar pomeni, da bomo med seboj primerjali le znake pripon A' in B' od ℓ -tega naprej. Na ta način bomo učinkovito določili $LCP[bp(i)]$.

Ni težko ugotoviti, da nas to opažanje privede do časovne zahtevnosti $O(n)$ (skupno število medsebojnih primerjav znakov je kvečjemu $2n$). Algoritem za izračun tabele LCP je prikazan kot algoritem 1.

V primeru niza **abrakadabra** bi se prve štiri iteracije algoritma odvile takole:

- Pričnemo s pripono **abrakadabra**. Njena predhodnica v zaporedju $\mathcal{U}$ je **abra**. Velja $L(\text{abrakadabra}, \text{abra}) = 4$, zato je $\ell \leftarrow LCP[R[1]] = LCP[3] = 4$.
- Nadaljujemo s pripono **brakadabra**. Njena predhodnica v zaporedju $\mathcal{U}$ je **bra**. Po trditvi 1 vemo, da je $L(\text{brakadabra}, \text{bra}) \geq \ell - 1 = 3$, zato se lahko omejimo na primerjave istoležnih znakov od četrtega naprej. Vidimo, da ujemajočih znakov ni več (saj je pripona **bra** dolga zgolj 3), zato nastavimo $\ell \leftarrow LCP[R[2]] = LCP[7] = 3$.
- Pri priponi **rakadabra** si spet pomagamo s trditvijo 1 in dobimo $\ell \leftarrow LCP[R[3]] = LCP[11] = L(\text{rakadabra}, \text{ra}) = 2$.
- Naslednja pripona je **akadabra**. Njena predhodnica v zaporedju $\mathcal{U}$ je **adabra**, po trditvi 1 pa vemo, da je $L(\text{akadabra}, \text{adabra}) \geq L(\text{akadabra}, \text{a}) = \ell - 1 = 1$. Primerjamo istoležne znake od drugega naprej in ugotovimo, da se nič ne ujema. Zato nastavimo $\ell \leftarrow LCP[R[4]] = LCP[5] = 1$.

Algoritem 1 Izračun tabele LCP .

```

function SKUPNA-PREDPONA( $S, i, j$ )
     $\triangleright$  Vrne  $L(S[i:], S[j:])$ .  $\triangleleft$ 
     $n \leftarrow |S|$ 
     $d \leftarrow 0$ 
    while  $i + d \leq n \wedge j + d \leq n \wedge S[i + d] = S[j + d]$  do
         $d \leftarrow d + 1$ 
    return  $d$ 

function LCP( $S$ )
     $n \leftarrow |S|$ 
    ustvari tabelo  $LCP[1 : n]$ 
     $\ell \leftarrow 0$ 
     $LCP[1] \leftarrow 0$ 
    for  $i \leftarrow 1$  to  $n$  do  $\triangleright i$  teče po indeksih v nizu  $S$ 
        if  $R[i] \geq 2$  then
             $j \leftarrow SA[R[i] - 1]$   $\triangleright T[j:]$  je predhodnica  $T[i:]$  v zaporedju  $\mathcal{U}$ 
             $\ell \leftarrow \max(0, \ell - 1)$ 
             $d \leftarrow \text{SKUPNA-PREDPONA}(S, i + \ell, j + \ell)$ 
             $\ell \leftarrow \ell + d$ 
             $LCP[R[i]] \leftarrow \ell$ 
    return  $LCP$ 

```

Uporaba

S tabelo LCP lahko neposredno pridobimo dolžino najdaljšega ponovljenega podniza podana niza: to je preprosto maksimalna vrednost v tabeli. Na primer, pri nizu **abrakadabra** je dolžina najdaljšega ponovljenega podniza enaka 4 (to je podniz **abra**). V okviru domače naloge boste ugotovili, da je razmeroma enostavno mogoče pridobiti tudi dolžino najdaljšega skupnega podniza dveh ločenih nizov (namig: lahko dva niza združimo v en niz?). Z nekoliko več truda lahko tabelo LCP uporabimo tudi za to, da časovno zahtevnost iskanja

vseh k pojavitev vzorca dolžine m v besedilu dolžine n zmanjšamo z $O(m \log n + km)$, kot potrebujemo zgolj z uporabo priponske tabele, na $O(m + \log n + k)$.