

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Delo z nizi

Matevž Jekovec

Univerza v Ljubljani
Fakulteta za računalništvo in informatiko

Poletna šola 2014 — Programiranje v višji prestavi

Notacija

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

- ▶ S — vhodni niz znakov ali besedilo (ang. *string*)
- ▶ N — dolžina niza (število znakov)
- ▶ Σ — abeceda
- ▶ σ — velikost abecede

¹Pozor: Dejanska velikost niza v pomnilniku je lahko drugačna (*null-delimited* nizi, različna kodiranja znakov)

Notacija

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

- ▶ S — vhodni niz znakov ali besedilo (ang. *string*)
- ▶ N — dolžina niza (število znakov)
- ▶ Σ — abeceda
- ▶ σ — velikost abecede
- ▶ Primer:
 - ▶ $S = \text{"BANANA"}$
 - ▶ $N^1 = 6$
 - ▶ $\Sigma = \{B, A, N\}$
 - ▶ $\sigma = 3$

¹Pozor: Dejanska velikost niza v pomnilniku je lahko drugačna (*null-delimited* nizi, različna kodiranja znakov)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Oblike besedil:

- ▶ Strukturirana: Besedilo je sestavljeno iz več besed.
Običajno tudi iščemo po besedah. (programska koda,
angleščina, slovenščina)
- ▶ Nestrukturirana: Besedilo nima jasnih besed ali pa je veliko
besed sestavljanek. (nemščina, človeški genom, glasba)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Oblike besedil:

- ▶ Strukturirana: Besedilo je sestavljeno iz več besed. Običajno tudi iščemo po besedah. (programska koda, angleščina, slovenščina)
- ▶ Nestrukturirana: Besedilo nima jasnih besed ali pa je veliko besed sestavljanek. (nemščina, človeški genom, glasba)

Problemi pri strukturiranih besedilih:

- ▶ Ali se beseda P (ang. *pattern*) nahaja v besedilu?
- ▶ Kje in kolikokrat se beseda ponovi?
- ▶ Ali se katera koli beseda začne na P ? Ali je P koren katere koli besede? Ali je P pripona katere koli besede?

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Oblike besedil:

- ▶ Strukturirana: Besedilo je sestavljeno iz več besed. Običajno tudi iščemo po besedah. (programska koda, angleščina, slovenščina)
- ▶ Nestrukturirana: Besedilo nima jasnih besed ali pa je veliko besed sestavljanek. (nemščina, človeški genom, glasba)

Problemi pri strukturiranih besedilih:

- ▶ Ali se beseda P (ang. *pattern*) nahaja v besedilu?
- ▶ Kje in kolikokrat se beseda ponovi?
- ▶ Ali se katera koli beseda začne na P ? Ali je P koren katere koli besede? Ali je P pripona katere koli besede?

Problemi pri nestrukturiranih besedilih:

- ▶ Ali se vzorec P pojavi v besedilu?
- ▶ Kje in kolikokrat se vzorec pojavi?

Kako iskati

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako iščemo?

Kako iskati

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako iščemo? Odvisno od scenarija!

Kako iskati

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako iščemo? Odvisno od scenarija!

- ▶ Besedilo ves čas isto, vzorci se menjajo.
- ▶ Vzorec ves čas isti, besedilo se menja.

Kako iskati

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako iščemo? Odvisno od scenarija!

- ▶ Besedilo ves čas isto, vzorci se menjajo.
- ▶ Vzorec ves čas isti, besedilo se menja.

Ideja: V prvem primeru najprej indeksiramo besedilo, kar traja nekaj časa, vendar bo iskanje po kazalu (in ne neposredno po besedilu) potem bistveno hitreje. V drugem primeru porabimo nekaj časa, da spravimo vzorec v obliko, s katero bi hitreje iskali po besedilu.

Hranjenje besedila

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako shraniti strukturirano besedilo tako, da bomo lahko hitro
iskali po njem?

Hranjenje besedila

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako shraniti strukturirano besedilo tako, da bomo lahko hitro iskali po njem?

Ideja: Slovar, ki preslika iskan ključ na mesta pojavitev ključa v besedilu. Kaj točno uporabiti?

Hranjenje besedila

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako shraniti strukturirano besedilo tako, da bomo lahko hitro iskali po njem?

Ideja: Slovar, ki preslika iskan ključ na mesta pojavitvev ključa v besedilu. Kaj točno uporabiti?

- ▶ Dvojiško iskalno drevo

Hranjenje besedila

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako shraniti strukturirano besedilo tako, da bomo lahko hitro iskali po njem?

Ideja: Slovar, ki preslika iskan ključ na mesta pojavitev ključa v besedilu. Kaj točno uporabiti?

- ▶ Dvojiško iskalno drevo
- ▶ Zgoščevalna tabela

Hranjenje besedila

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako shraniti strukturirano besedilo tako, da bomo lahko hitro iskali po njem?

Ideja: Slovar, ki preslika iskan ključ na mesta pojavitvev ključa v besedilu. Kaj točno uporabiti?

- ▶ Dvojiško iskalno drevo
- ▶ Zgoščevalna tabela
- ▶ Številsko drevo

Dvojiško iskalno drevo (ang. *Binary search tree*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Dvojiško iskalno drevo (ang. *Binary search tree*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Iskalno drevo, vozlišča hranijo nize, manjši niz je tisti, ki je po abecedi (*leksikografsko*) pred drugim.

Dvojiško iskalno drevo (ang. *Binary search tree*)

Delo z nizi

Matevž
Jekovec

Uvod

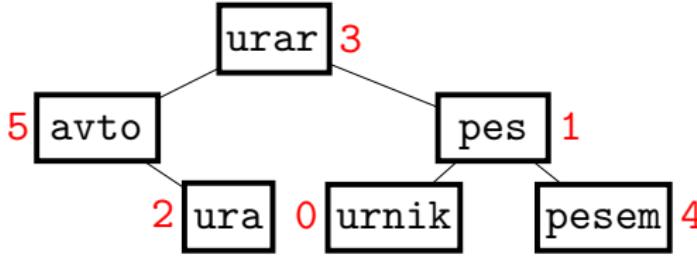
Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Iskalno drevo, vozlišča hranijo nize, manjši niz je tisti, ki je po abecedi (*leksikografsko*) pred drugim.



ključ	vrednost
avto	5
ura	2
urar	3
urnik	0
pes	1
pesem	4

Dvojiško iskalno drevo (ang. *Binary search tree*)

Delo z nizi

Matevž
Jekovec

Uvod

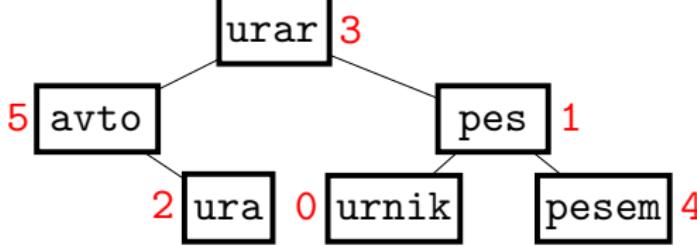
Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Iskalno drevo, vozlišča hranijo nize, manjši niz je tisti, ki je po abecedi (*leksikografsko*) pred drugim.



ključ	vrednost
avto	5
ura	2
urar	3
urnik	0
pes	1
pesem	4

Pozor: Če imamo nize že zložene v tabelo po abecedi, potem namesto iskanja po drevesu iščemo kar po tabeli — bisekcija!

Zgoščevalna tabela (ang. *Hash table*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Zgoščeno vrednost izračunamo za vsako besedo v vhodnem besedilu. Nato vstavimo besedo kot običajni element (npr. število) v zgoščevalno tabelo.

Zgoščevalna tabela (ang. *Hash table*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Zgoščeno vrednost izračunamo za vsako besedo v vhodnem besedilu. Nato vstavimo besedo kot običajni element (npr. število) v zgoščevalno tabelo.

Rabin-Karpova zgoščevalna funkcija:

$$H = c_1 a^{k-1} + c_2 a^{k-2} + \dots + c_k a^0$$

Zgoščevalna tabela (ang. *Hash table*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Zgoščeno vrednost izračunamo za vsako besedo v vhodnem besedilu. Nato vstavimo besedo kot običajni element (npr. število) v zgoščevalno tabelo.

Rabin-Karpova zgoščevalna funkcija:

$$H = c_1 a^{k-1} + c_2 a^{k-2} + \dots + c_k a^0$$

Primer zgoščene vrednosti za $a = 2$: URAR, dolžina je $k = 4$. U je 20. črka, R je 17. črka, A pa 0. črka po abecedi:

$$20 \cdot 2^3 + 17 \cdot 2^2 + 0 \cdot 2^1 + 17 \cdot 2^0 = 160 + 68 + 17 = 245$$

Pozor: Če želimo hraniti več pojavitvev niza, potrebujemo *multimap*.

Zgoščevalna tabela nadal. (ang. *Hash table*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vzemimo velikost polja $M = 8$.

Zgoščevalna tabela nadal. (ang. Hash table)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vzemimo velikost polja $M = 8$.

$$H(\text{"avto"}) = 136 \mod 8 = 0$$

$$H(\text{"ura"}) = 114 \mod 8 = 2$$

$$H(\text{"urar"}) = 245 \mod 8 = 5$$

$$H(\text{"urnik"}) = 534 \mod 8 = 6$$

$$H(\text{"pes"}) = 86 \mod 8 = 0$$

$$H(\text{"pesem"}) = 364 \mod 8 = 0$$

Zgoščevalna tabela nadal. (ang. Hash table)

Delo z nizi

Matevž
Jekovec

Uvod

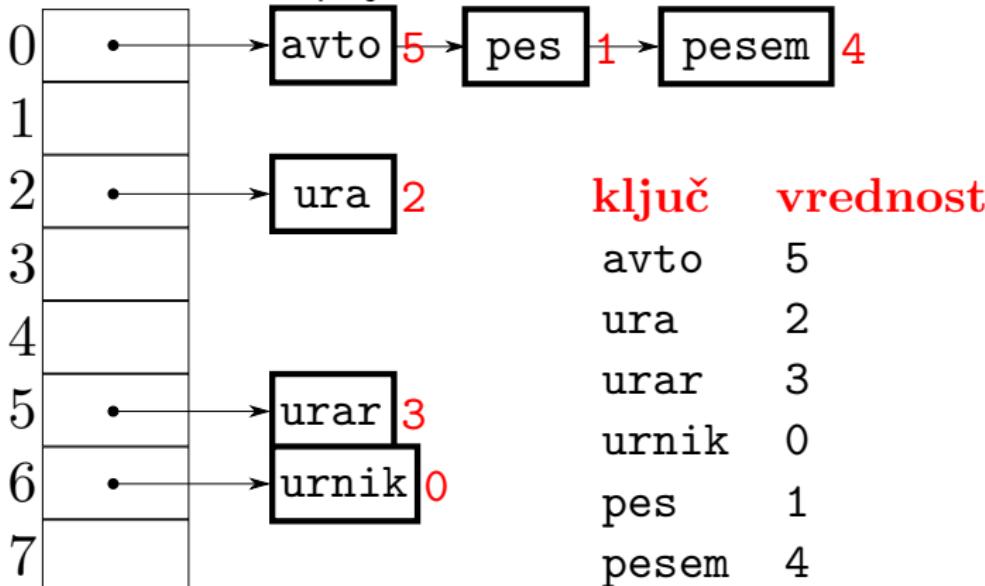
Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vzemimo velikost polja $M = 8$.



Številsko drevo (ang. *trie*)

Delo z nizi

Matevž
Jekovec

Problem iskalnih dreves in zgoščevalne tabele: Ni mogoče iskati po začetkih besed (npr. *search-as-you-type*).

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Številsko drevo (ang. *trie*)

Delo z nizi

Matevž
Jekovec

Uvod

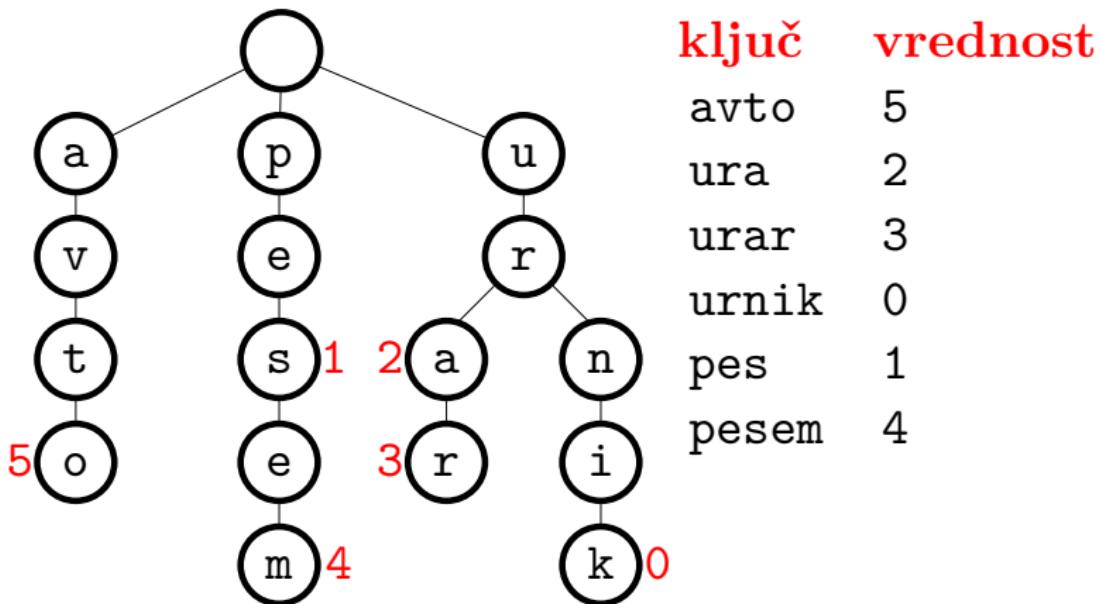
Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Problem iskalnih dreves in zgoščevalne tabele: Ni mogoče iskati po začetkih besed (npr. *search-as-you-type*).
Rešitev: Številsko drevo hrani besede od korena navzdol, razbite po črkah.



Stisnjeno številsko drevo (ang. *compressed trie*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Izboljšava: Namesto svojega vozlišča za vsako črko, vozlišča z enim naslednikom združimo.

Stisnjeno številsko drevo (ang. *compressed trie*)

Delo z nizi

Matevž
Jekovec

Uvod

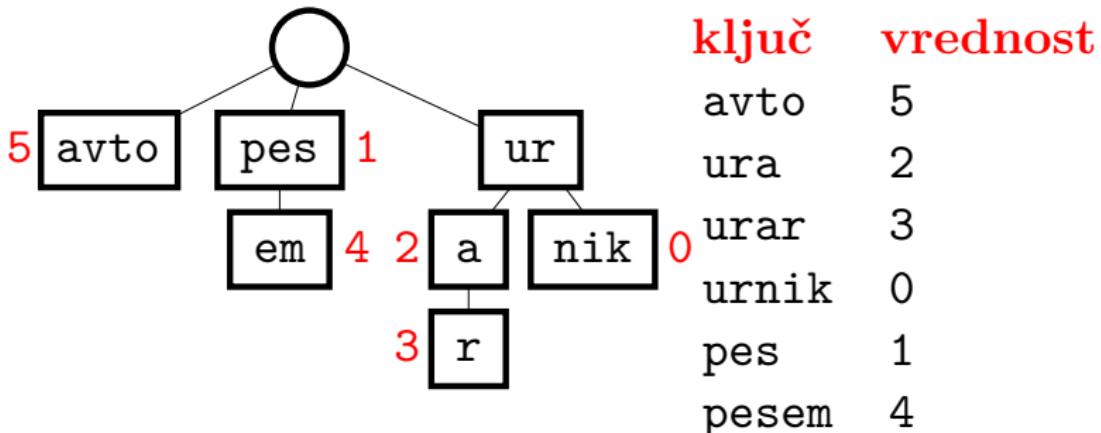
Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Izboljšava: Namesto svojega vozlišča za vsako črko, vozlišča z enim naslednikom združimo.



Programiranje številskih dreves

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako predstaviti vozlišče?

```
1 class TrieNode {  
2     string str;  
3     void *value;  
4     ?         children;  
5 };
```

Programiranje številskih dreves

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako predstaviti vozlišče?

```
1 class TrieNode {  
2     string str;  
3     void *value;  
4     ?         children;  
5 };
```

Do otrok dostopamo prek:

- ▶ povezanega seznama,

Programiranje številskih dreves

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako predstaviti vozlišče?

```
1 class TrieNode {  
2     string str;  
3     void *value;  
4     ?         children;  
5 };
```

Do otrok dostopamo prek:

- ▶ povezanega seznama,
- ▶ polje kazalcev v velikosti abecede σ ,

Programiranje številskih dreves

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Kako predstaviti vozlišče?

```
1 class TrieNode {  
2     string str;  
3     void *value;  
4     ?         children;  
5 };
```

Do otrok dostopamo prek:

- ▶ povezanega seznama,
- ▶ polje kazalcev v velikosti abecede σ ,
- ▶ trojiškega iskalnega drevesa,

Programiranje številskih dreves — povezan seznam

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vozlišče ima kazalec na prvega otroka in na sorojenca.

```
1 class TrieNode {  
2     string      str;  
3     void        *value;  
4     TrieNode   *child;  
5     TrieNode   *sibling;  
6 };
```

Programiranje številskih dreves — povezan seznam

Delo z nizi

Matevž
Jekovc

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

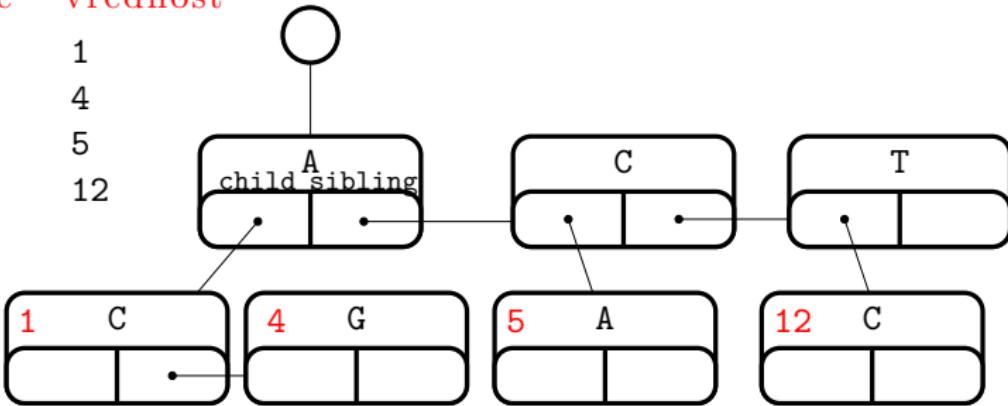
Vaje in naloge

Vozlišče ima kazalec na prvega otroka in na sorojenca.

```
1 class TrieNode {  
2     string      str;  
3     void        *value;  
4     TrieNode   *child;  
5     TrieNode   *sibling;  
6 };
```

ključ vrednost

AC	1
AG	4
CA	5
TC	12



Programiranje številskih dreves — s poljem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vsako vozlišče vsebuje polje σ kazalcev na otroke. Do otroka dostopamo neposredno z indeksom njegove črke.

```
1 class TrieNode {  
2     string str;  
3     void *value;  
4     TrieNode children[ALPHABET];  
5 };
```

Programiranje številskih dreves — s poljem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

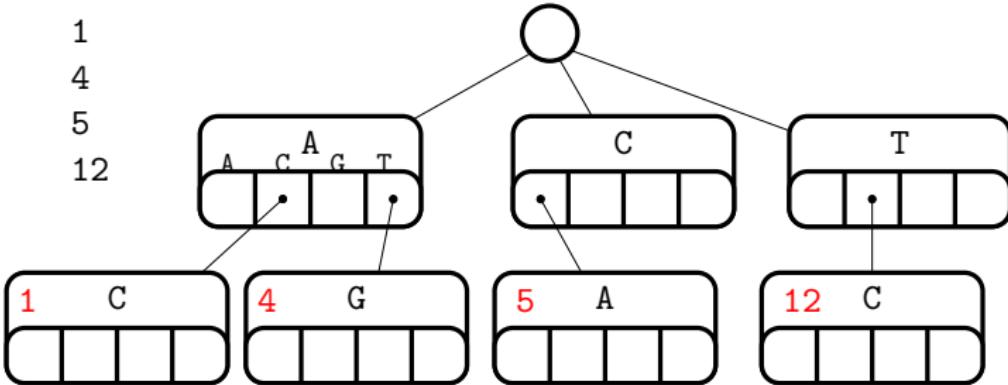
Vaje in naloge

Vsako vozlišče vsebuje polje σ kazalcev na otroke. Do otroka dostopamo neposredno z indeksom njegove črke.

```
1 class TrieNode {  
2     string      str;  
3     void       *value;  
4     TrieNode  children[ALPHABET];  
5 };
```

ključ vrednost

AC	1
AG	4
CA	5
TC	12



Programiranje številskih dreves — TST

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Trojiško iskalno drevo (ang. *Ternary Search Trie*) je kompromis obeh prejšnjih metod: hranimo le kazalce na otroke, ki obstajajo, iskanje pa poteka z bisekcijo.

```
1 class TrieNode {  
2     string      str;  
3     void        *value;  
4     TrieNode   *eq;  
5     TrieNode   *ls;  
6     TrieNode   *gt;  
7 };
```

Programiranje številskih dreves — TST

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

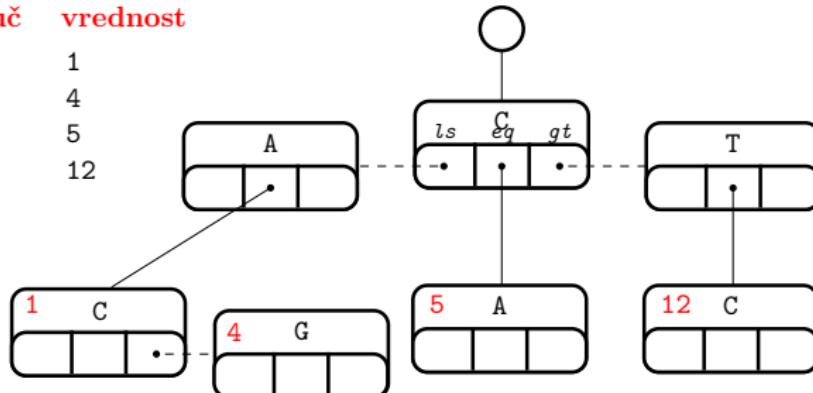
Iskanje z oknom

Podobnost
med nizi

Vaje in naloge

```
1 class TrieNode {
2     string str;
3     void *value;
4     TrieNode *eq;
5     TrieNode *ls;
6     TrieNode *gt;
7 };
```

ključ	vrednost
AC	1
AG	4
CA	5
TC	12



Priponsko drevo (ang. *Suffix tree*)

Delo z nizi

Matevž
Jekovec

Številsko drevo omogoča iskanje po začetkih besed. Kaj pa po korenju ali priponi?

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Pripomsko drevo (ang. *Suffix tree*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Številsko drevo omogoča iskanje po začetkih besed. Kaj pa po korenju ali pripomni?

Pripomsko drevo je stisnjeno številsko drevo, ki hrani vse predpone besedila (ali besed).

Pripomsko drevo (ang. *Suffix tree*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Številsko drevo omogoča iskanje po začetkih besed. Kaj pa po korenju ali pripomni?

Pripomsko drevo je stisnjeno številsko drevo, ki hrani vse predpone besedila (ali besed).

1 2 3 4 5 6 7 8 9 10 11 12
S=ABRAKADABRA\$

Pripomsko drevo (ang. *Suffix tree*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Številsko drevo omogoča iskanje po začetkih besed. Kaj pa po korenju ali pripomni?

Pripomsko drevo je stisnjeno številsko drevo, ki hrani vse predpone besedila (ali besed).

1 2 3 4 5 6 7 8 9 10 11 12
S=ABRAKADABRA\$

1	\$	12
2	A\$	11
3	ABRA\$	8
4	ABRAKADABRA\$	1
5	ADABRA\$	6
6	AKADABRA\$	4
7	BRA\$	9
8	BRAKADABRA\$	2
9	DABRA\$	7
10	KADABRA	5
11	RA\$	10
12	RAKADABRA\$	13

Pripomsko drevo (ang. Suffix tree)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

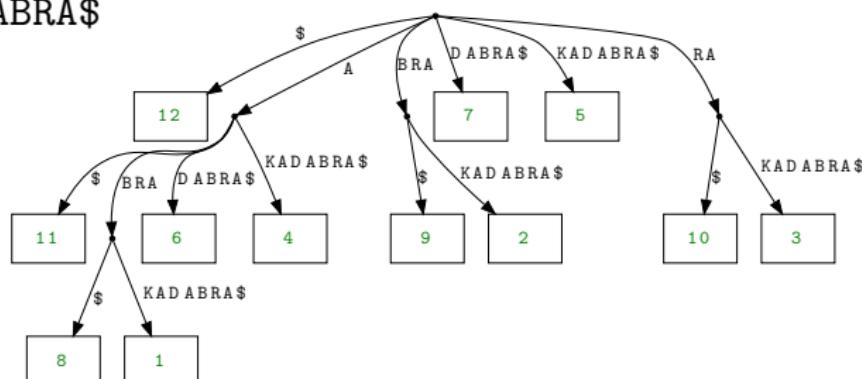
Vaje in naloge

Številsko drevo omogoča iskanje po začetkih besed. Kaj pa po korenju ali pripomni?

Pripomsko drevo je stisnjeno številsko drevo, ki hrani vse predpone besedila (ali besed).

$S = ABRAKADABRA\$$

	1	2	3	4	5	6	7	8	9	10	11	12
1	\$											
2	A\$											11
3	ABRA\$											8
4	ABRAKADABRA\$											1
5	ADABRA\$											6
6	AKADABRA\$											4
7	BRA\$											9
8	BRAKADABRA\$											2
9	DABRA\$											7
10	KADABRA											5
11	RA\$											10
12	RAKADABRA\$											13



Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO BANANE.

P: BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO BANANE.
P: BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO BANANE.
P: BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO BANANE.
P: BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO BANANE.
P: BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P: **BANANA**

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**

P:

BANANA

Vaja: Koliko časa potrebujemo?

Iskanje z drsečim oknom (ang. *sliding window*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

S: NA DREVESU RASTEJO **BANANE.**
P: **BANANA**

Vaja: Koliko časa potrebujemo?

Vsaj N primerjav znakov, če se vedno že prvi znak okna ne ujema in $NM/2$, če je vsak M -ti znak besedila zgrešitev. npr.

$S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$.

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Prva zgrešitev se pojavi, ko je okno na poziciji $i = 0$ in znaku $j = 3$, če štejemo od 0 dalje.

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Prva zgrešitev se pojavi, ko je okno na poziciji $i = 0$ in znaku $j = 3$, če štejemo od 0 dalje.

Ideja: Namesto, da premaknemo okno za 1 znak naprej, ga premaknemo za 4 znake naprej, saj znaka B sploh nimamo v vzorcu!

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Prva zgrešitev se pojavi, ko je okno na poziciji $i = 0$ in znaku $j = 3$, če štejemo od 0 dalje.

Ideja: Namesto, da premaknemo okno za 1 znak naprej, ga premaknemo za 4 znake naprej, saj znaka B sploh nimamo v vzorcu!

Algoritem: Zgradimo tabelo, ki hrani število znakov, ki jih lahko preskočimo glede na trenutni znak besedila.

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Prva zgrešitev se pojavi, ko je okno na poziciji $i = 0$ in znaku $j = 3$, če štejemo od 0 dalje.

Ideja: Namesto, da premaknemo okno za 1 znak naprej, ga premaknemo za 4 znake naprej, saj znaka B sploh nimamo v vzorcu!

Algoritem: Zgradimo tabelo, ki hrani število znakov, ki jih lahko preskočimo glede na trenutni znak besedila. Primera:

- ▶ Vzorec AAAA: vedno lahko preskočimo kar vse 4 znake, če se pojavi kateri koli znak $\neq A$ na vhodu.

Boyer-Moorov algoritmem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Imejmo $S = \text{AAABAAABAAABAAAB}$ in $P = \text{AAAA}$ iz prejšnjega primera.

Prva zgrešitev se pojavi, ko je okno na poziciji $i = 0$ in znaku $j = 3$, če štejemo od 0 dalje.

Ideja: Namesto, da premaknemo okno za 1 znak naprej, ga premaknemo za 4 znake naprej, saj znaka B sploh nimamo v vzorcu!

Algoritem: Zgradimo tabelo, ki hrani število znakov, ki jih lahko preskočimo glede na trenutni znak besedila. Primera:

- ▶ Vzorec AAAA: vedno lahko preskočimo kar vse 4 znake, če se pojavi kateri koli znak $\neq A$ na vhodu.
- ▶ Vzorec ABAB: če se pojavi B na vhodu in pričakujemo A , potem preskočimo le en znak. Isto velja obratno. Če je na vhodu kateri koli drug znak, preskočimo 4 znake.

Boyer-Moorov algoritmom — preskočna tabela

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

$$P = \quad B \quad A \quad N \quad A \quad N \quad A$$

Preskočna tabela vsebuje indekse najbolj desnih pojavitev vseh možnih znakov abecede Σ .

Boyer-Moorov algoritmom — preskočna tabela

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

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

Boyer-Moorov algoritmom — preskočna tabela

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Preskočna tabela vsebuje indekse najbolj desnih pojavitev vseh možnih znakov abecede Σ .

	$P =$	B	A	N	A	N	A
$\Sigma:$		0	1	2	3	4	5
A							
B							
C							
D							
E							
...							
M							
N							
O							
...							

Boyer-Moorov algoritmom — preskočna tabela

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Preskočna tabela vsebuje indekse najbolj desnih pojavitev vseh možnih znakov abecede Σ .

	$P =$	B	A	N	A	N	A
$\Sigma:$		0	1	2	3	4	5
A	-1	-1	1	1	3	3	5
B	-1	0	0	0	0	0	0
C	-1	-1	-1	-1	-1	-1	-1
D	-1	-1	-1	-1	-1	-1	-1
E	-1	-1	-1	-1	-1	-1	-1
...							
M	-1	-1	-1	-1	-1	-1	-1
N	-1	-1	-1	2	2	4	4
O	-1	-1	-1	-1	-1	-1	-1
...							

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

S: **NA DRE**VESU RASTEJO BANANE.

P: **BANANA**

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

S: NA DREVESU RASTEJO BANANE.

P:

BANANA

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

S: NA DREVESU R $\color{red}{A}$ STEJO BANANE.

P:

$\color{red}{BANANA}$

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

S: NA DREVESU RASTEJO **BANAN**E.

P:

BANANA

Boyer-Moorov algoritmom nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Iskanje: Okno postavimo na začetek $i = 0$ in preverjamo znake od desne proti levi $j = |P| - 1$:

- ▶ Če se znak c v besedilu ujema z znakom v oknu, nadaljujemo s preverjanjem naslednjega znaka v oknu in besedilu.
- ▶ Če se c ne ujema in je $\text{right}[c] = -1$, potem premakni okno za $|P|$ znakov naprej.
- ▶ Če se c ne ujema in $\text{right}[c] \neq -1$, potem premaknemo okno za $j - \text{right}[c]$ znakov. V primeru, da bi bila vrednost negativna, okno premaknemo za 1 znak naprej.

S: NA DREVESU RASTEJO BANANE.

P:

BANANA

Rabin-Karpov algoritem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Uporabimo znanje iz zgoščevalnih tabel:

Rabin-Karpov algoritem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Uporabimo znanje iz zgoščevalnih tabel:

1. Najprej izračunamo zgoščeno vrednost vzorca H_P .

Rabin-Karpov algoritem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Uporabimo znanje iz zgoščevalnih tabel:

1. Najprej izračunamo zgoščeno vrednost vzorca H_P .
2. Postavimo okno na začetek $i = 0$ in izračunamo zgoščeno vrednost znakov pod oknom H_S .

Rabin-Karpov algoritem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Uporabimo znanje iz zgoščevalnih tabel:

1. Najprej izračunamo zgoščeno vrednost vzorca H_P .
2. Postavimo okno na začetek $i = 0$ in izračunamo zgoščeno vrednost znakov pod oknom H_S .
3. Če $H_S = H_P$, preverimo vse znake pod oknom, da se prepričamo o enakosti, in vrnemo mesto pojavitve.

Rabin-Karpov algoritem

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Uporabimo znanje iz zgoščevalnih tabel:

1. Najprej izračunamo zgoščeno vrednost vzorca H_P .
2. Postavimo okno na začetek $i = 0$ in izračunamo zgoščeno vrednost znakov pod oknom H_S .
3. Če $H_S = H_P$, preverimo vse znake pod oknom, da se prepričamo o enakosti, in vrnemo mesto pojavitve.
4. Če $H_S \neq H_P$, se premaknemo za en znak naprej, izračunamo novo zgoščeno vrednost znakov pod oknom H_S in gremo na korak 3.

Rabin-Karpov algoritem nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Če imamo pametno zgoščevalno funkcijo, nam ni treba prebrati ponovno vseh znakov pod oknom, ampak le dodamo zgoščeno vrednost novega znaka in odstranimo zgoščeno vrednost najstarejšega znaka. Tako pohitrimo iskanje.

Rabin-Karpov algoritem nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Če imamo pametno zgoščevalno funkcijo, nam ni treba prebrati ponovno vseh znakov pod oknom, ampak le dodamo zgoščeno vrednost novega znaka in odstranimo zgoščeno vrednost najstarejšega znaka. Tako pohitrimo iskanje.
Robin-Karpova zgoščevalna funkcija:

$$H = c_1 a^{|P|-1} + c_2 a^{|P|-2} + \dots + c_{|P|} a^0$$

Rabin-Karpov algoritem nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Ideja: Če imamo pametno zgoščevalno funkcijo, nam ni treba prebrati ponovno vseh znakov pod oknom, ampak le dodamo zgoščeno vrednost novega znaka in odstranimo zgoščeno vrednost najstarejšega znaka. Tako pohitrimo iskanje.
Robin-Karpova zgoščevalna funkcija:

$$H = c_1 a^{|P|-1} + c_2 a^{|P|-2} + \dots + c_{|P|} a^0$$

Ko pride nov znak c' , odstranimo najstarejši znak c_{old} in izračunamo nov

$$H' = H \cdot a - c_{old} \cdot a^{|P|} + c'$$

Podobnost med nizi

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Levenshteinova razdalja ali *urejevalna razdalja* δ med dvema nizoma S_1 in S_2 je najmanjše število vstavljanj, brisanj ali zamenjav posameznih znakov, da spremenimo S_1 v S_2 .

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iškanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

B A N A N A

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iškanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
0	1	2	3	4	5	6
A	1					
N	2					
A	3					
N	4					
A	5					
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iškanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
0	1	2	3	4	5	6
A	1	1	1	2	3	4
N	2					
A	3					
N	4					
A	5					
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3					
N	4					
A	5					
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4					
A	5					
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4	4	3	2	2	1
A	5					
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4	4	3	2	2	1
A	5	5	4	3	2	2
S	6					

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4	4	3	2	2	1
A	5	5	4	3	2	1
S	6	6	5	4	3	2

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Izkanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4	4	3	2	2	1
A	5	5	4	3	2	1
S	6	6	5	4	3	3

2

Levenshteinova razdalja se nahaja spodnjem desnem kotu $\delta(|S_1|, |S_2|)$.

Izračun Levenshteinove razdalje

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Formula za izračun razdalje med nizi $S_1[0..i]$ in $S_2[0..j]$:

$$\delta(i, j) = \min \begin{cases} \delta(i - 1, j) + 1 \\ \delta(i, j - 1) + 1 \\ \delta(i - 1, j - 1) + 1 & \text{če } S_1[i] \neq S_2[j] \\ \delta(i - 1, j - 1) & \text{če } S_1[i] = S_2[j] \end{cases}$$

Izračun razdalje se naredi z Levenshteinovo matriko:

	B	A	N	A	N	A
B	0	1	2	3	4	5
A	1	1	1	2	3	4
N	2	2	2	1	2	3
A	3	3	2	2	1	2
N	4	4	3	2	2	1
A	5	5	4	3	2	1
S	6	6	5	4	3	2

Levenshteinova razdalja se nahaja spodnjem desnem kotu $\delta(|S_1|, |S_2|)$. Pot nam pove, katere ukaze je potrebno izvesti.

Najdaljši skupni podniz (*longest common substr.*)

Delo z nizi

Matevž
Jekovec

Za izračun najdaljšega skupnega podniza lahko uporabimo priponsko drevo obeh nizov in pogledamo najgloblje skupno vozlišče.

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Najdaljši skupni podniz (*longest common substr.*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Za izračun najdaljšega skupnega podniza lahko uporabimo priponsko drevo obeh nizov in pogledamo najgloblje skupno vozlišče.

Lahko pa uporabimo matriko, podobno Levenshteinovi, le da spremenimo pogoj:

$$LCSuff(S_1[1..i], S_2[1..j]) =$$

$$\begin{cases} LCSuff(S_1[1..i - 1], S_2[1..j - 1]) + 1 & \text{če } S_1[i] = S_2[j] \\ 0 & \text{sicer} \end{cases}$$

Najdaljši skupni podniz (*longest common substr.*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Za izračun najdaljšega skupnega podniza lahko uporabimo priponsko drevo obeh nizov in pogledamo najgloblje skupno vozlišče.

Lahko pa uporabimo matriko, podobno Levenshteinovi, le da spremenimo pogoj:

$$LCSuff(S_1[1..i], S_2[1..j]) =$$

$$\begin{cases} LCSuff(S_1[1..i - 1], S_2[1..j - 1]) + 1 & \text{če } S_1[i] = S_2[j] \\ 0 & \text{sicer} \end{cases}$$

	B	A	N	A	N	A
0	0	0	0	0	0	0
A	0	0	1	0	1	0
N	0	0	0	2	0	2
A	0	0	1	0	3	0
N	0	0	0	2	0	4
A	0	0	0	0	3	0
S	0	0	0	0	0	5

Najdaljše skupno podzaporedje (*LCS*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Najdaljše skupno podzaporedje (ang. *longest common sequence*) je podobno najdaljšemu skupnemu podnizu, le da se lahko med posameznimi znaki, ki so prisotni v obeh nizih, vrinjeni tudi tuji znaki.

Najdaljše skupno podzaporedje (LCS)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Najdaljše skupno podzaporedje (ang. *longest common sequence*) je podobno najdaljšemu skupnemu podnizu, le da se lahko med posameznimi znaki, ki so prisotni v obeh nizih, vrinjeni tudi tuji znaki.

$$LCS(S_1[1..i], S_2[1..j]) =$$

$$\begin{cases} LCS(S_1[1..i - 1], S_2[1..j - 1]) + 1 & \text{če } S_1[i] = S_2[j] \\ \max(LCS(S_1[1..i], S_2[1..j - 1]), LCS(S_1[1..i - 1], S_2[1..j])) & \text{če } S_1[i] \neq S_2[j] \end{cases}$$

Najdaljše skupno podzaporedje (*LCS*)

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Najdaljše skupno podzaporedje (ang. *longest common sequence*) je podobno najdaljšemu skupnemu podnizu, le da se lahko med posameznimi znaki, ki so prisotni v obeh nizih, vrinjeni tudi tuji znaki.

$$LCS(S_1[1..i], S_2[1..j]) =$$

$$\begin{cases} LCS(S_1[1..i - 1], S_2[1..j - 1]) + 1 & \text{če } S_1[i] = S_2[j] \\ \max(LCS(S_1[1..i], S_2[1..j - 1]), LCS(S_1[1..i - 1], S_2[1..j])) & \text{če } S_1[i] \neq S_2[j] \end{cases}$$

	B	A	N	A	N	A
0	0	0	0	0	0	0
A	0	0	1	1	1	1
N	0	0	1	2	2	2
A	0	0	1	2	3	3
N	0	0	1	2	3	4
A	0	0	1	2	3	4
S	0	0	1	2	3	4

Delo z nizi

Matevž
Jekovec

Burkhard-Kellerjevo drevo se uporablja pri črkovalnikih in je uporabno za iskanje podobnih besed.

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Burkhard-Kellerjevo drevo se uporablja pri črkovalnikih in je uporabno za iskanje podobnih besed.

Gradnja: Začnemo s poljubnim pojmom. Nato dodamo novo geslo tako, da izračunamo urejevalno razdaljo D med trenutnim vozliščem in novim geslom. Če povezava v smeri razdalje ne obstaja, novo geslo pridnemo obstoječemu vozlišču. Sicer sledimo povezavi in izračunamo urejevalno razdaljo med novim vozliščem in našim gesлом.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Burkhard-Kellerjevo drevo se uporablja pri črkovalnikih in je uporabno za iskanje podobnih besed.

Gradnja: Začnemo s poljubnim pojmom. Nato dodamo novo geslo tako, da izračunamo urejevalno razdaljo D med trenutnim vozliščem in novim gesлом. Če povezava v smeri razdalje ne obstaja, novo geslo pripnemo obstoječemu vozlišču. Sicer sledimo povezavi in izračunamo urejevalno razdaljo med novim vozliščem in našim gesлом.

Iskanje najbolj podobnih besed z urejevalno razdaljo δ :

Začnemo pri korenju in izračunamo urejevalno razdaljo D med iskanim geslom in trenutnim vozliščem. Če je $D \leq \delta$, potem izpišemo trenutno vozlišče. Preiskujemo tiste otroke, ki imajo razdaljo $\geq D - \delta$ ali $\leq D + \delta$.

BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

urar

urnik

avto

pes

pesem

BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

ura

urar

urnik

avto

pes

pesem

BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

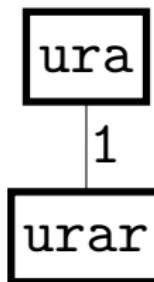
urar

urnik

avto

pes

pesem



BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

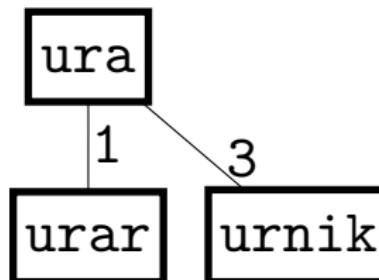
urar

urnik

avto

pes

pesem



BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

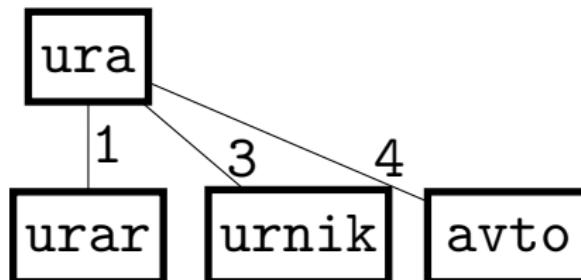
urar

urnik

avto

pes

pesem



BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

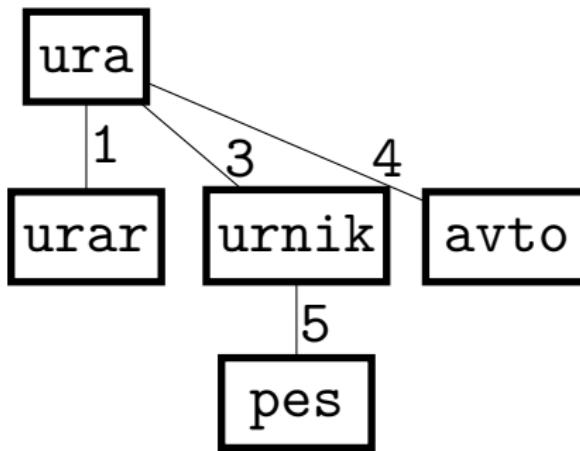
urar

urnik

avto

pes

pesem



BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

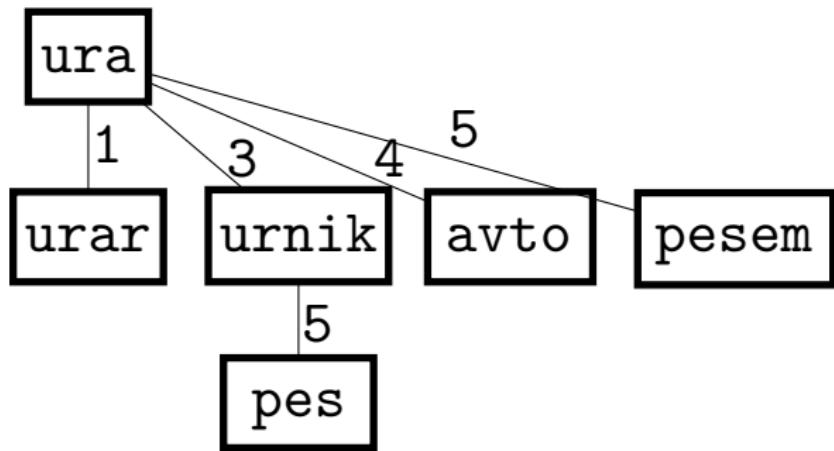
urar

urnik

avto

pes

pesem



BK-drevo nadal.

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

gesla

ura

urar

urnik

avto

pes

pesem

ura $D=1$

urar $D=2$

urnik $D=4$

avto $D=4$

pesem $D=5$

pes $D=3$

iskanje: ira, $\delta=2$

1

3

4

5

5

Delo z nizi

Matevž
Jekovec

Uvod

Indeksiranje
besedila

Iskanje z
oknom

Podobnost
med nizi

Vaje in naloge

Vaje:

- ▶ S pomočjo urejanja (npr. quicksort) uredi vnešene nize po abecedi.
- ▶ Sprogramiraj številsko drevo, ki podpira operaciji vstavljanja in iskanja.
- ▶ Sprogramiraj BK-drevo, ki podpira operaciji vstavljanja in iskanja.
- ▶ Sprogramiraj Edit Distance, Longest Common Substring in Longest Common Subsequence s pomočjo dinamičnega programiranja.

UVa naloge:

499 What's The Frequency, Kenneth?

454 Anagrams

164 String Computer - Edit distance

290 Palindroms ↔ smordnilaP

335 Processing MX Records

455 Periodic Strings