

Uvod u računarstvo

15. predavanje

Saša Singer

`singer@math.hr`

`web.math.hr/~singer`

PMF – Matematički odjel, Zagreb

Sadržaj predavanja

- Pretraživanje i sortiranje nizova:
 - Razne varijante Selection sorta.
 - Složenost sortiranja — općenito.
 - Složenost Selection sorta.
 - Sortiranje zamjenama susjednih elemenata — Bubble sort.
 - Poboljšana varijanta Bubble sorta.
 - Složenost Bubble sorta.
- Završni primjeri (ponavljanje za kolokvij):
 - Zadatak 1.
 - Zadatak 2.

Pretraživanje i sortiranje (nastavak)


Sadržaj

- Pretraživanje i sortiranje nizova:
 - Pretraživanje — sekvencijalno i binarno (ponavljanje).
 - Sortiranje izborom ekstrema — Selection sort (ponavljanje).
 - Razne varijante Selection sorta.
 - Složenost sortiranja — općenito.
 - Složenost Selection sorta.
 - Sortiranje zamjenama susjednih elemenata — Bubble sort.
 - Poboļšana varijanta Bubble sorta.
 - Složenost Bubble sorta.

Pretraživanje nizova (ponavljanje)

Problem **pretraživanja**: provjeriti nalazi li se zadani element **elt** među članovima zadanog niza

$$x_0, x_1, \dots, x_{n-1}.$$

Ako niz **nije** sortiran (u nizu vlada “**nered**”), koristimo  **sekvencijalno** pretraživanje (“jedan po jedan”).

Sekvencijalno pretraživanje

```
int seq_search(int x[], int n, int elt)
{
    int i;

    for (i = 0; i < n; ++i)
        if (x[i] == elt)
            return 1;

    return 0;
}
```

Sekvencijalno pretraživanje (nastavak)

Složenost mjerimo brojem usporedbi

• “jednak”, odnosno, “različit”.

U najgorem slučaju, moramo provjeriti sve članove niza, tj.

$$\text{broj usporedbi} \leq n.$$

Ova mjera složenosti je dobra procjena za trajanje izvršavanja algoritma sekvencijalnog pretraživanja.

Zapis:

$$T(n) = \mathcal{O}(n).$$

Značenje: trajanje u najgorem slučaju linearno ovisi o n .

Točno značenje zapisa složenosti

Točno matematičko značenje zapisa

$$T(n) = \mathcal{O}(f(n))$$

za neke funkcije T i f (sa \mathbb{N} u \mathbb{R}):

Postoji konstanta $c \in \mathbb{R}$ i postoji $n_0 \in \mathbb{N}$ takvi da za svaki $n \in \mathbb{N}$ vrijedi implikacija

$$n \geq n_0 \implies T(n) \leq c \cdot f(n).$$

Prijevod: T raste sporije od neka konstanta puta f , za sve dovoljno velike n .

Binarno pretraživanje

Ako je niz **uzlazno** ili **silazno sortiran**,

$$x_0 \leq x_1 \leq \dots \leq x_{n-1} \quad \text{ili} \quad x_0 \geq x_1 \geq \dots \geq x_{n-1},$$

koristimo

📍 **binarno** pretraživanje (“raspolavljanje”).

Binarno pretraživanje (nastavak)

```
int binary_search(int x[], int n, int elt)
{
    int l = 0, d = n - 1, i;
    while (l <= d) {
        i = (l + d) / 2;
        if (elt < x[i])
            d = i - 1;
        else if (elt > x[i])
            l = i + 1;
        else
            return 1;
    }
    return 0; }

```

Binarno pretraživanje (nastavak)

Složenost opet mjerimo brojem usporedbi, ali sada koristimo

● “manji (ili jednak)”, odnosno, “veći (ili jednak)”.

U najgorem slučaju, za broj raspolavljanja k vrijedi

$$2^{k-1} \leq n < 2^k,$$

ili

$$k \leq 1 + \lfloor \log_2 n \rfloor.$$

Svako raspolavljanje ima najviše 2 usporedbe, pa je

$$\text{broj usporedbi} \leq 2 \cdot (1 + \lfloor \log_2 n \rfloor).$$

Binarno pretraživanje (nastavak)

Mož se napraviti i varijanta sa **samo jednom** usporedbom u svakom **raspolavljanju** (probajte sami).

Zapis za trajanje:

$$T(n) = \mathcal{O}(\log n).$$

Značenje: trajanje u najgorem slučaju **logaritamski** ovisi o n .

Zaključak: Sortiramo zato da bismo **brže** tražili!

Sortiranje nizova izborom ekstrema

Ideja: Koristimo **usporedbe** i **zamjene** elemenata u nizu.

- Dovedi **najmanji** element niza x_0, x_1, \dots, x_{n-1} na **njegovo** mjesto.
- To mjesto je **prvo** u cijelom nizu, pa je (nakon **zamjene**), **nova** vrijednost elementa x_0 upravo **najmanji** element niza.
- Postupak ponovi na **skraćenom** (nesređenom) nizu x_1, \dots, x_{n-1} (duljine za jedan manje, tj. $n - 1$).
- Niz se “**skraćuje**” sprijeda.
- To ponavljamo sve dok ne “stignemo” na niz sa samo **jednim** elementom (x_{n-1}) — taj je sigurno **sortiran!**

Sortiranje nizova izborom ekstrema (nastavak)

Prva varijanta (prošli puta):

- kod traženja **ekstrema** pamtimo:
 - vrijednost ekstrema,
 - indeks elementa na kojem se ekstrem dostiže.

Skraćena varijanta (po **duljini** kôda, ali **ne mora** biti i **brža**):

- očito je dovoljno pamtiti samo
 - **indeks** elementa na kojem se ekstrem dostiže, i to **iskoristiti** kod usporedbi.

Sortiranje nizova izborom ekstrema (nastavak)

```
void selection_sort(int x[], int n) {
    int i, j, ind_min, temp;
    for (i = 0; i < n - 1; ++i) {
        ind_min = i;
        for (j = i + 1; j < n; ++j)
            if (x[j] < x[ind_min])
                ind_min = j;
        if (i != ind_min) {
            temp = x[i];
            x[i] = x[ind_min];
            x[ind_min] = temp; }
    }
    return; }
```

Složenost sortiranja nizova

Kako ćemo uspoređivati koliko je brzo sortiranje (raznim algoritmima)?

- Možemo mjeriti vrijeme.
- Možemo uspoređivati broj operacija koje program obavlja. Taj broj operacija jedna je od mjera složenosti algoritma.

Primijetite da kod sortiranja imamo dvije bitno različite operacije (koje ne moraju jednako trajati):

- uspoređivanje elemenata,
- zamjene elemenata.

Složenost sortiranja izborom ekstrema

Kod sortiranja izborom ekstrema vrijedi:

- broj usporedbi u svakom koraku jednak je duljini trenutnog niza umanjenoj za 1, jer se svaki element uspoređuje s trenutno najmanjim.

Za sve korake zajedno, broj usporedbi je zbroj:

$$(n - 1) + (n - 2) + \dots + 2 + 1 = \frac{(n - 1) \cdot n}{2} \approx \frac{n^2}{2}.$$

Dakle, broj usporedbi (sigurno) kvadratno ovisi o n .

Složenost sortiranja izborom ekstrema

- u svakom koraku vrši se **najviše jedna zamjena** nekog para elemenata (može je i ne biti, ako je najmanji na pravom mjestu).

Ukupno imamo najviše

$$n - 1 \text{ zamjena.}$$

Dakle, broj **zamjena** (najviše) **linearno** ovisi o n .

Zaključak: za trajanje vrijedi

$$T(n) = \mathcal{O}(n^2).$$

Sortiranje nizova izborom ekstrema (nastavak)

Dosad smo uvijek sortirali dovođenjem **najmanjeg** elementa na **početak**. Isti efekt imat će i dovođenje **najvećeg** na **kraj**.
Ideja:

- Dovedi **najveći** element niza x_0, x_1, \dots, x_{n-1} na **njegovo** mjesto (to je **zadnje** u cijelom nizu).
- Postupak ponovi na **skraćenom** (nesređenom) nizu x_0, \dots, x_{n-2} (duljine za jedan manje, tj. $n - 1$).
- Niz se “**skraćuje**” straga.

Sortiranje nizova izborom ekstrema (nastavak)

```
void selection_sort(int x[], int n) {
    int i, j, ind_max, temp;
    for (i = n - 1; i > 0; --i) {
        ind_max = i;
        for (j = 0; j < i; ++j)
            if (x[j] > x[ind_max])
                ind_max = j;
        if (i != ind_max) {
            temp = x[i];
            x[i] = x[ind_max];
            x[ind_max] = temp; }
    }
    return; }
```

Sortiranje nizova izborom ekstrema (nastavak)

Složenost — ista kao kod dovođenja najmanjeg na početak:

• broj usporedbi:

$$\frac{(n-1) \cdot n}{2} \approx \frac{n^2}{2} = \mathcal{O}(n^2).$$

• broj zamjena je manji ili jednak:

$$n - 1 = \mathcal{O}(n).$$

Sortiranje zamjenama susjeda

Sortiranje **zamjenama susjeda** (engl. **bubble sort**, bubble = mjehurić) bazira se na zamjenama **susjednih elemenata**.

Ideja:

- Ako **dva susjedna** člana niza x_j i x_{j+1} **nisu** u dobrom poretku, zamijeni im mjesto (vrijednost).
- Kad stignemo do **kraja** niza (u prvom prolazu), **ponovimo** postupak.
- **Nije** jasno kada ćemo **stati** (jer se stalno vraćamo na početak!) — to ćemo analizirati nakon primjera.

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.


42	12	55	94	18	44	67
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

42	12	55	94	18	44	67
----	----	----	----	----	----	----



zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	94	18	44	67
----	----	----	----	----	----	----

zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.


12	42	55	94	18	44	67
----	----	----	----	----	----	----

zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	94	18	44	67
----	----	----	----	----	----	----




zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	18	94	44	67
----	----	----	----	----	----	----




zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	18	44	94	67
----	----	----	----	----	----	----



zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	18	44	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	18	44	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.


12	42	55	18	44	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	55	18	44	67	94
----	----	----	----	----	----	----




zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	18	55	44	67	94
----	----	----	----	----	----	----



zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	18	44	55	67	94
----	----	----	----	----	----	----

zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	18	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.


12	42	18	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	42	18	44	55	67	94
----	----	----	----	----	----	----



zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 1

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

zamjena = 0

Sortiranje zamjenama susjednih elemenata

Primjer. Zamjenama susjednih elemenata sortirajte zadano polje.

12	18	42	44	55	67	94
----	----	----	----	----	----	----

Sortiranje zamjenama susjeda (nastavak)

Kada stajemo?

- Primijetimo da smo u prvom prolazu **najveći** element “odgurali” na **kraj** niza (njegovo pravo mjesto).
- I drugi, veći elementi počeli su “putovati” prema kraju niza.
- **Zaključak**: nakon **prvog** koraka niz možemo **skratiti** za **posljednji** element i nastaviti postupak s nizom x_0, \dots, x_{n-2} .

Sortiranje zamjenama susjeda (nastavak)

```
void bubble_sort(int x[], int n) {
    int i, j, temp;

    for (i = 1; i < n; ++i)
        for (j = 0; j < n - i; ++j)
            if (x[j] > x[j + 1]) {
                temp = x[j];
                x[j] = x[j + 1];
                x[j + 1] = temp; }

    return; }
```

Sortiranje zamjenama susjeda (nastavak)

Analiza složenosti algoritma:

- U prvom prolazu uspoređujemo $n - 1$ parova susjeda, u drugom $n - 2, \dots$, i tako redom. Dakle, ukupan broj usporedbi je

$$(n - 1) + (n - 2) + \dots + 2 + 1 = \frac{(n - 1) \cdot n}{2} \approx \frac{n^2}{2} = \mathcal{O}(n^2).$$

- Broj zamjena može drastično varirati od 0 (ako je niz već sortiran) do najviše

$$(n - 1) + (n - 2) + \dots + 2 + 1 = \frac{(n - 1) \cdot n}{2} \approx \frac{n^2}{2} = \mathcal{O}(n^2).$$

To će se dogoditi ako je niz naopako sortiran.

Sortiranje zamjenama susjeda (nastavak)

Dakle, ovakvo sortiranje zamjenama susjeda **ne treba upotrebljavati**, jer je loše (ima **previše zamjena**).

Može li se algoritam **poboljšati**?

- Možemo pamtiti koliko smo zamjena napravili u trenutnom prolazu nizom. Ako nismo napravili **nijednu** — možemo stati.
 - Dovoljno je: “**ima** — **nema**” zamjena u tom prolazu.
- Recimo, za ispravno sortiran niz, potreban je **samo jedan** prolaz da se ustanovi da je niz sortiran.
- U slučaju **naopako** (obratno) sortiranog niza, nismo uštedili ništa (nema spasa).

Sortiranje zamjenama susjeda (nastavak)

```
void bubble_sort(int x[], int n) {
    int i, j, temp, zamjena;
    i = n - 1;
    do {
        zamjena = 0;
        for (j = 0; j < i; ++j)
            if (x[j] > x[j + 1]) {
                temp = x[j];
                x[j] = x[j + 1];
                x[j + 1] = temp;
                zamjena = 1; }
        --i; /* smanji i za sljedeci prolaz. */
    } while (zamjena);
    return; }
```

Sortiranje zamjenama susjeda (nastavak)

Zaključak:

- sortiranje zamjena susjeda se **ne isplati** za opće nizove,
- možda se i može isplatiti za “skoro sortirane nizove”, ali to nije lako definirati što je.

Još o sortiranju

- U “bubble” sortu uvijek napredujemo od početka niza. Ako jednom krenemo od početka, pa zatim na nazad, pa opet naprijed, dobit ćemo tzv. **engl. shaker sort** (u doslovnom prijevodu streseni sort).
- Možemo sortirati na “kontrolirane” udaljenosti, recimo susjede, pa malo dalje članove ... Takav sort zove se **engl. shell sort** (u doslovnom prijevodu školjkasti sort). Analiza složenosti mu je komplicirana, ali algoritam može biti brži od kvadratnog.

Još o sortiranju

- Za sortiranje zamjenama elemenata unutar istog niza korištenjem usporedbi članova, može se pokazati da je

$$\text{broj usporedbi} \geq c \cdot n \log n,$$

(c je pozitivna konstanta) tj. broj usporedbi je reda veličine barem $n \log n$, što može biti **bitno brže** nego n^2 usporedbi (za velike n).

Još o sortiranju

Algoritmi koji se koriste u praksi:

- **Quicksort** – prosječna složenost mu je $n \log n$ za slučajne dobro razbacane nizove, ali u najgorem slučaju i dalje mu je složenost n^2 . Koristi se zbog dobre prosječne brzine i dio je standardne C-biblioteke.
- **Heapsort** – ima i prosječnu i najgoru složenost $n \log n$, ali je u prosjeku sporiji od quicksorta (opis SPA).

Grubi opis quicksorta

Quicksort se temelji na principu **podijeli pa vladaj**.

- Uzmemo jedan element x_k iz niza i dovedemo ga na njegovo pravo mjesto.
- Lijevo od njega ostavimo elemente koji su manji ili jednaki njemu (u bilo kojem poretku).
- Desno od njega ostavimo elemente koji su veći od njega (u bilo kojem poretku).
- Ako smo dobro izabrali, tj. ako je mjesto x_k blizu sredine, onda ćemo morati sortirati dva polja **polovične duljine**.
- U najgorem slučaju, ako smo izabrali “krivi” x_k , morat ćemo sortirati polje duljine $n - 1$.