

# *Programiranje 1*

## *4. predavanje — 1. dodatak*

Saša Singer

[singer@math.hr](mailto:singer@math.hr)

[web.math.pmf.unizg.hr/~singer](http://web.math.pmf.unizg.hr/~singer)

PMF – Matematički odsjek, Zagreb

# *Sadržaj predavanja — dodatka*

- Cijeli brojevi — binarni prikaz i prikaz u računalu:
  - Prikaz cijelih brojeva u bazi 2.
  - Algoritam za nalaženje znamenki u prikazu.
  - Prikaz brojeva bez predznaka u računalu.
  - Prikaz brojeva s predznakom u računalu,  
komplementiraj i dodaj 1.
- Realni brojevi — binarni prikaz:
  - Prikaz realnih brojeva u bazi 2 — cjelobrojni i razlomljeni dio.
  - Algoritam za nalaženje znamenki razlomljenog dijela.
  - Normalizirani prikaz realnih brojeva u bazi 2.
  - Algoritam za nalaženje normaliziranog prikaza.

# *Sadržaj predavanja — dodatka (nastavak)*

- Realni brojevi — prikaz u računalu:
  - Izgled prikaza i prikazivi brojevi.
  - Zaokruživanje realnih brojeva u računalu za prikaz.
  - Prikaz u tipovima `float` i `double` — primjeri.
- Prikaz realnih brojeva — zaokruživanje i greške (još nije sređeno!):
  - Nalaženje najbližih prikazivih brojeva.
  - Greške zaokruživanja u prikazu.

# **Binarni prikaz cijelih brojeva, algoritmi i primjeri**

# Sadržaj

- Cijeli brojevi — binarni prikaz i prikaz u računalu:
  - Prikaz cijelih brojeva u bazi 2.
  - Algoritam za nalaženje znamenki u prikazu.
  - Prikaz brojeva bez predznaka u računalu.
  - Prikaz brojeva s predznakom u računalu,  
komplementiraj i dodaj 1.

## Zapis prirodnog broja u bazi 2

Neka je  $B \in \mathbb{N}$  neki prirodan broj.

Tzv. pozicioni zapis broja  $B$  u bazi  $b = 2$  ima sljedeći oblik:

$$B = b_k \cdot 2^k + \cdots + b_1 \cdot 2 + b_0, \quad b_i \in \{0, 1\},$$

gdje su  $b_i$  binarne znamenke ili bitovi broja  $B$ .

Da bismo dobili jednoznačnost prikaza, koristimo da je  $B > 0$  i

- ne dozvoljavamo da vodeće znamenke budu nule,  
tj. zahtijevamo da vodeća znamenka  $b_k$  mora biti pozitivna

$$b_k > 0.$$

## **Normalizirani zapis prirodnog broja u bazi 2**

Prikaz oblika

$$B = b_k \cdot 2^k + \cdots + b_1 \cdot 2 + b_0, \quad b_i \in \{0, 1\}, \quad b_k > 0,$$

zovemo **normalizirani** pozicioni prikaz broja  $B$  u bazi  $b = 2$ .  
Skraćeni zapis ovog prikaza je

$$B = (b_k b_{k-1} \dots b_1 b_0)_2.$$

Broj  $k \in \mathbb{N}_0$  jednoznačno je određen zahtjevom  $b_k > 0$  i vrijedi

$$k = \lfloor \log_2 B \rfloor.$$

Broj binarnih znamenki (“duljina”) broja  $B$  je

$$k + 1 = \lfloor \log_2 B \rfloor + 1.$$

## Računanje znamenki broja u bazi 2

Binarne znamenke  $b_i$  zadatog broja  $B$

$$B = b_k \cdot 2^k + \cdots + b_1 \cdot 2 + b_0 = (b_k b_{k-1} \dots b_1 b_0)_2,$$

dobivamo dijeljenjem s bazom 2.

- Preciznije, koristimo cjelobrojni kvocijent i ostatak.

Kako to ide? Direktno iz Euklidovog teorema, zapisom

$$B = (b_k \cdot 2^{k-1} + \cdots + b_1) \cdot 2 + b_0 = \text{oznaka} = B_1 \cdot 2 + b_0.$$

Zadnju znamenku  $b_0$  dobivamo kao ostatak pri dijeljenju broja  $B$  s bazom 2

$$b_0 = B \bmod 2,$$

pa je  $b_0 \in \{0, 1\}$ , tj.  $b_0$  je korektna binarna znamenka.

## Računanje znamenki broja u bazi 2 (nastavak)

Cjelobrojni kvocijent broja  $B$  s bazom 2 je “novi” broj

$$B_1 = B \text{ div } 2 = b_k \cdot 2^{k-1} + \cdots + b_1.$$

Njegov zapis u bazi 2 je

$$B_1 = (b_k b_{k-1} \dots b_1)_2,$$

tj. dobiva se “brisanjem” znamenke  $b_0$  iz zapisa broja  $B$ .

Znamenku  $b_0$  smo upravo našli, pa je dovoljno naći binarni zapis broja  $B_1$ , a taj broj ima jednu znamenku manje.

Naravno, njegovu zadnju znamenku  $b_1$  nalazimo

- ponavljanjem opisanog postupka, ali na broju  $B_1$ .

## Računanje znamenki broja u bazi 2 (nastavak)

Čitav postupak možemo zapisati na sljedeći način.

Neka je, na početku,  $B_0 := B$ .

U općem —  $i$ -tom koraku, krećemo s brojem  $B_i$  i računamo:

- ostatak — izdvoji (trenutnu) zadnju znamenku u  $B_i$

$$b_i = B_i \bmod 2,$$

- cjelobrojni kvocijent — “obriši” (trenutnu) zadnju znamenku u  $B_i$

$$B_{i+1} = B_i \text{ div } 2,$$

tako da uvijek vrijedi

$$B_i = B_{i+1} \cdot 2 + b_i, \quad i = 0, 1, \dots .$$

## Računanje znamenki broja u bazi 2 (nastavak)

Pitanje je samo — kad treba stati (jer  $k$  ne znamo unaprijed)?

Odgovor: kad “obrišemo” sve znamenke iz broja  $B$ , ostaje nam nula.

Uočite da je

$$B_i = b_k \cdot 2^{k-i} + \cdots + b_i = (b_k b_{k-1} \dots b_i)_2.$$

Za  $i = k$  imamo  $B_k = b_k > 0$ . Nakon dijeljenja dobivamo

$$B_k = B_{k+1} \cdot 2 + b_k, \quad B_{k+1} = 0.$$

Dakle, postupak staje kad prvi put dobijemo kvocijent nula,

$$B_{k+1} = B_k \text{ div } 2 = 0.$$

## Znamenke broja u bazi 2 — algoritam

Ovaj postupak možemo zapisati u obliku **algoritma**.

**Algoritam 1.** Binarne znamenke prirodnog broja.

**Ulaz:** Prirodni broj  $B$ .

**Izlaz:** Broj  $k \geq 0$  i znamenke  $b_k, \dots, b_0$  broja  $B$  u bazi 2.

```
i ← 0; B0 ← B;  
sve dok je Bi > 0 radi {  
    bi ← Bi mod 2;  
    Bi+1 ← Bi div 2;  
    i ← i + 1;  
}  
k ← i - 1;
```

## Korektnost algoritma za računanje znamenki

**Zadatak.** Neka je  $\ell \in \mathbb{N}$ . Dokažite da nakon  $\ell$  koraka opisanog postupka vrijedi (korake brojimo od jedan)

$$B = B_\ell \cdot 2^\ell + (b_{\ell-1} \cdot 2^{\ell-1} + \cdots + b_1 \cdot 2 + b_0).$$

Drugim riječima, vrijedi

$$B \text{ div } 2^\ell = B_\ell,$$

$$B \text{ mod } 2^\ell = b_{\ell-1} \cdot 2^{\ell-1} + \cdots + b_1 \cdot 2 + b_0.$$

Dodatno, možemo uzeti ove tvrdnje vrijede i za  $\ell = 0$ ,

- tj. na početku cijelog postupka — prije prvog koraka.

Algoritam staje kad prvi puta dobije  $B_{k+1} = 0$ . Dokažite da tada vrijedi  $B \text{ mod } 2^{k+1} = B$  i  $b_k = 1$ .

## Zapis cijelog broja u bazi 2

Neka je  $B \in \mathbb{Z}$  neki cijeli broj (smije biti i negativan).

Dogovor za prikaz broja  $B = 0$ .

- U svakodnevnom životu pišemo jednu znamenku:  
 $0 = (0)_2$ , tj.  $k = 0$  i  $b_0 = 0$ .
- Normaliziranom prikazu bi “prije” odgovaralo da nula nema znamenki:  $0 = ()_2$ , uz, na pr.  $k = -1$ .

Na primjer, tako radi Algoritam 1 za ulaz  $B = 0$ .

Izbor ovisi o potrebi u “okolnom” algoritmu.

Za negativne brojeve  $B < 0$ , prikaz dobivamo tako da

- nađemo prikaz pozitivnog broja  $|B| \in \mathbb{N}$  i
- dodamo predznak  $-$  (minus).

## Prikaz broja 1717 u bazi 2

Primjer. Prikaz broja 1717 u bazi 2 dobivamo ovako:

$i$	$B_i$	$b_i = B_i \bmod 2$	$B_{i+1} = B_i \text{ div } 2$
0	$1717 = 858 \cdot 2 + 1$	$1717 \bmod 2 = 1$	$1717 \text{ div } 2 = 858$
1	$858 = 429 \cdot 2 + 0$	$858 \bmod 2 = 0$	$858 \text{ div } 2 = 429$
2	$429 = 214 \cdot 2 + 1$	$429 \bmod 2 = 1$	$429 \text{ div } 2 = 214$
3	$214 = 107 \cdot 2 + 0$	$214 \bmod 2 = 0$	$214 \text{ div } 2 = 107$
4	$107 = 53 \cdot 2 + 1$	$107 \bmod 2 = 1$	$107 \text{ div } 2 = 53$
5	$53 = 26 \cdot 2 + 1$	$53 \bmod 2 = 1$	$53 \text{ div } 2 = 26$
6	$26 = 13 \cdot 2 + 0$	$26 \bmod 2 = 0$	$26 \text{ div } 2 = 13$
7	$13 = 6 \cdot 2 + 1$	$13 \bmod 2 = 1$	$13 \text{ div } 2 = 6$
8	$6 = 3 \cdot 2 + 0$	$6 \bmod 2 = 0$	$6 \text{ div } 2 = 3$
9	$3 = 1 \cdot 2 + 1$	$3 \bmod 2 = 1$	$3 \text{ div } 2 = 1$
10	$1 = 0 \cdot 2 + 1$	$1 \bmod 2 = 1$	$1 \text{ div } 2 = 0$

## Prikaz broja 1717 u bazi 2 (nastavak)

Dobili smo da je  $B_{11} = 0$ , pa je  $k = 10$ .

Vodeća znamenka  $b_{10}$  je na dnu tablice, tj. znamenke treba pisati odozdo prema gore, da ih dobijemo u standardnom poretku  $b_{10}, \dots, b_0$ .

Rješenje. Prikaz broja 1717 u bazi 2 je

$$(1717)_{10} = (11010110101)_2$$

i ima 11 binarnih znamenki.

Primjer. Prikaz broja  $-1717$  u bazi 2 je

$$(-1717)_{10} = (-11010110101)_2$$

i (dogovorno, također) ima 11 binarnih znamenki. Predznak minus smijemo napisati i ispred zgrade (svejedno je).

## Prikaz broja 1717 kao int

Primjer. Prikaz broja 1717 kao `int` i `unsigned int`.

- Za tipove `int` i `unsigned int`, broj bitova za prikaz brojeva je  $n = 32$ .

Rješenje. Za početak, jer je  $k + 1 = 11 < n = 32$ , broj 1717 je **prikaziv** u oba tipa.

Prikazu broja 1717 u bazi 2 samo treba **dodati** potreban broj **vodećih nula**, do broja bitova predviđenog za prikaz u odgovarajućem tipu.

Dakle, prikaz broja 1717 u tim tipovima je

---

0000 0000 0000 0000 0000 0110 1011 0101

---

## Prikaz broja $-1717$ kao int

Primjer. Prikaz broja  $-1717$  kao int.

Krećemo od prikaza broja  $1717$  kao int:

---

0000 0000 0000 0000 0000 0110 1011 0101

---

Komplementiramo (bit-po-bit) i dodamo 1 (modulo  $2^{32}$ ):

---

1111 1111 1111 1111 1111 1001 0100 1010  
+ 1

---

Rezultat je prikaz broja  $-1717$  kao int:

---

1111 1111 1111 1111 1111 1001 0100 1011

---

# Binarni prikaz realnih brojeva, algoritmi i primjeri

# Sadržaj

- Realni brojevi — binarni prikaz:
  - Prikaz realnih brojeva u bazi 2 — cjelobrojni i razlomljeni dio.
  - Algoritam za nalaženje znamenki razlomljenog dijela.
  - Normalizirani prikaz realnih brojeva u bazi 2.
  - Algoritam za nalaženje normaliziranog prikaza.

## Zapis realnog broja u bazi 2

Neka je  $B \in \mathbb{R}$  neki **realan** broj.

Osnovni pristup prikazu sličan je onom za **cijele** brojeve.

Za **negativne** brojeve  $B < 0$ , prikaz dobivamo tako da

- nađemo prikaz **pozitivnog** broja  $|B| \in \mathbb{R}_+$  i
- **dodamo** predznak  $-$  (minus).

Dakle, dovoljno je naći prikaz **nenegativnih** brojeva  $B \geq 0$ .

Njihov prikaz sastoji se iz **2** dijela:

- prikaza **cjelobrojnog** dijela  $\lfloor B \rfloor$  — što znamo naći, i
- prikaza tzv. **razlomljenog** dijela  $B - \lfloor B \rfloor \in [0, 1)$ .

Kako se nalazi prikaz “**razlomljenog**” dijela broja?

## Zapis razlomljenog dijela realnog broja u bazi 2

Neka je  $B \in [0, 1)$  bilo koji razlomljeni dio realnog broja.

Tzv. pozicioni zapis broja  $B$  u bazi  $b = 2$  ima sljedeći oblik:

$$B = \sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i}, \quad b_{-i} \in \{0, 1\},$$

gdje su  $b_{-i}$  binarne znamenke ili bitovi broja  $B$ .

U skraćenom zapisu, znamenke  $b_{-i}$  pišemo iza binarne točke

$$B = (0.b_{-1}b_{-2}\dots)_2.$$

Traži se postupak — koji, za zadani broj  $B \in [0, 1)$ ,

- “generira” pripadni niz binarnih znamenki  $(b_{-i}, i \in \mathbb{N})$ ,  
i to “član-po-član”, za  $i = 1, 2, \dots$

## Računanje znamenki broja u bazi 2 — uvod

Prije opisa postupka za računanje znamenki broja  $B$  u bazi 2, treba uočiti jednu “sitnicu” — vezanu uz

- jednoznačnost rezultata i dozvoljene nizove znamenki.

Naime, za bilo koji niz binarnih znamenki  $(b_{-i}, i \in \mathbb{N})$ , gdje je  $b_{-i} \in \{0, 1\}$ , pripadni red iz zapisa broja

$$\sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i},$$

uvijek konvergira, i suma je neki broj iz zatvorenog intervala  $[0, 1]$  (niz parcijalnih suma monotono raste i ograničen je s 1).

Međutim, različiti nizovi znamenki mogu dati istu sumu pripadnog reda — dakle, zapis pripadnog broja (= sume reda) ne mora biti jednoznačan.

## Dovoljeni nizovi znamenki u bazi 2

Problem nastaje kod onih nizova znamenki  $(b_{-i}, i \in \mathbb{N})$  koji imaju konačno mnogo nula, tj. počev od nekog mjestra  $k \in \mathbb{N}$ , imaju beskonačni niz (uzastopnih) jedinica na “repu”. Zbog

$$\sum_{i=k}^{\infty} 1 \cdot 2^{-i} = 2^{-k+1} = 1 \cdot 2^{-k+1} + \sum_{i=k}^{\infty} 0 \cdot 2^{-i},$$

svaki takav niz znamenki može se “skratiti” na konačan = ima beskonačni niz nula na “repu”, počev od tog istog mjestra  $k$  (te nule, obično, ne pišemo — pa zato kažemo “konačan” niz).

Zbog ove nejedinstvenosti zapisa,

- nizovi znamenki s beskonačnim nizom jedinica na “repu” nisu dozvoljeni kao pozicioni zapis nekog broja u bazi 2.

Slično je i u drugim bazama (niz najvećih znamenki).

## **Problem za $k = 1$ — same jedinice u nizu**

U slučaju kad je  $k = 1$ , “problematični” niz ima **same jedinice**.

Njegov skraćeni zapis je  $(0.1111\dots)_2$ , a pripadna suma reda (tj. broj kojeg prikazuje taj niz) je

$$B = \sum_{i=1}^{\infty} 1 \cdot 2^{-i} = 1.$$

Kod traženja prikaza **razlomljenog** dijela realnog broja, ovo je dodatno **zabranjeno** pretpostavkom na ulazni broj  $B$ .

Naime, **prepostavka**  $B \in [0, 1)$  povlači  $B < 1$ , a to znači da je

- nemoguće da su sve znamenke  $b_{-i}$  jednake 1.

Drugim riječima,

- barem jedna znamenka  $b_{-i}$  je jednaka 0, za neki  $i \in \mathbb{N}$ .

## **Problem za $k > 1$ — nejedinstvenost zapisa**

Dakle, u postupku kojeg tražimo, za “problematični” niz mora vrijediti  $k > 1$ , jer ima **bar jednu nulu**. No, onda je sigurno

- $b_{-k+1} = 0$  **zadnja** nula u tom nizu (jer  $b_{-i} = 1$ , za  $i \geq k$ ).

Skraćeni zapis takvog “problematičnog” niza je

$$(0.b_{-1} \dots b_{-k+2} 0 111 \dots)_2.$$

Za pripadnu sumu reda (= broj kojeg prikazuje taj niz) vrijedi

$$B = \sum_{i=1}^{k-2} b_{-i} \cdot 2^{-i} + \sum_{i=k}^{\infty} 1 \cdot 2^{-i} = \sum_{i=1}^{k-2} b_{-i} \cdot 2^{-i} + 2^{-k+1},$$

pa broj  $B$  ima i **“kraći” konični** zapis

$$(0.b_{-1} \dots b_{-k+2} 1)_2.$$

## Dovoljeni nizovi znamenki u bazi 2 (kraj)

**Zadatak.** Pokažite da samo navedeni “problematični” nizovi binarnih znamenki dovode do nejedinstvenosti zapisa u bazi 2, tj. svi ostali nizovi jednoznačno određuju pripadni broj  $B$ .

U terminima brojeva  $B \in [0, 1]$ , samo brojevi s konačnim binarnim zapisom imaju nejedinstven pozicioni zapis, i to su svi brojevi oblika  $B = m/2^n$ , za  $m, n \in \mathbb{N}$  i  $m < 2^n$ . ■

Ograničenje na dozvoljene nizove znamenki za pozicioni zapis

- nije bitno za postupak (algoritam) — on radi za svaki dozvoljeni ulaz, već samo objašnjava njegov izlaz.

U tom smislu, postupak kojeg ćemo opisati

- nalazi “najkraći” prikaz broja  $B$  u bazi 2,
- tj. izbjegava beskonačni niz jedinica na “repu” prikaza.

## Računanje znamenki broja u bazi 2

Binarne znamenke  $b_{-i}$  zadanog broja  $B \in [0, 1)$

$$\begin{aligned}B &= b_{-1} \cdot 2^{-1} + b_{-2} \cdot 2^{-2} + b_{-3} \cdot 2^{-3} + \dots \\&= (0.b_{-1}b_{-2}b_{-3}\dots)_2,\end{aligned}$$

dobivamo množenjem s bazom 2.

- Preciznije, koristimo množenje i najveće cijelo.

Kako to ide? Kad broj  $B$  pomnožimo s 2, dobijemo broj

$$\begin{aligned}B'_1 &= \text{oznaka } = 2B = b_{-1} + b_{-2} \cdot 2^{-1} + b_{-3} \cdot 2^{-2} + \dots \\&= (b_{-1}.b_{-2}b_{-3}\dots)_2.\end{aligned}$$

Sad iskoristimo da je  $B'_1 = 2B \in [0, 2)$ , tj.  $B'_1 < 2$ .

## Računanje znamenki broja u bazi 2 (nastavak)

Prvu znamenku  $b_{-1}$  dobivamo kao najveće cijelo od  $B'_1 = 2B$

$$b_{-1} = \lfloor B'_1 \rfloor.$$

Zbog  $B'_1 \in [0, 2]$ , mora biti  $b_{-1} \in \{0, 1\}$ , pa je  $b_{-1}$  korektna binarna znamenka.

Kad od  $B'_1$  oduzmemo cijeli broj  $b_{-1}$ , dobivamo “novi” broj

$$B_1 = B'_1 - b_{-1} = B'_1 - \lfloor B'_1 \rfloor = 2B - \lfloor 2B \rfloor.$$

Njegov zapis u bazi 2 je

$$B_1 = (0.b_{-2}b_{-3}\dots)_2,$$

tj. dobiva se “brisanjem” znamenke  $b_{-1}$  iz zapisa broja  $B$ .

## Računanje znamenki broja u bazi 2 (nastavak)

Naravno, prvu znamenku  $b_{-2}$  broja  $B_1$  nalazimo

- ponavljanjem opisanog postupka, ali na broju  $B_1$ .

Po definiciji funkcije najveće cijelo, za novi broj  $B_1$ , također, vrijedi  $B_1 \in [0, 1\rangle$ , pa smijemo nastaviti postupak s brojem  $B_1$ .

**Napomena.** U prethodnom opisu, zadan je samo broj  $B$ .

Njegove znamenke  $b_{-1}, b_{-2}, \dots$  nisu zadane ili poznate, već ih treba naći.

- Napisane su samo za lakši opis postupka.

Ono što stvarno vrijedi nakon opisanog prvog koraka je:

$$B = b_{-1} \cdot 2^{-1} + B_1 \cdot 2^{-1},$$

s tim da smo našli  $b_{-1} \in \{0, 1\}$  i  $B_1 \in [0, 1\rangle$ .

## Računanje znamenki broja u bazi 2 (nastavak)

Čitav postupak možemo zapisati na sljedeći način.

Neka je, na početku,  $B_0 := B$ .

U općem —  $i$ -tom koraku, krećemo s brojem  $B_{i-1}$  i računamo:

- produkt — pomakni (trenutnu) prvu znamenku u  $B_{i-1}$  ispred binarne točke

$$B'_i = 2B_{i-1},$$

- najveće cijelo — izdvoji tu prvu namenku u  $B'_i$

$$b_{-i} = \lfloor B'_i \rfloor,$$

- razlika — “obriši” (trenutnu) prvu znamenku u  $B_{i-1}$  ( $B'_i$ )

$$B_i = B'_i - b_{-i} = 2B_{i-1} - \lfloor 2B_{i-1} \rfloor.$$

## Računanje znamenki broja u bazi 2 (nastavak)

Onda uvijek vrijedi

$$B_{i-1} = b_{-i} \cdot 2^{-1} + B_i \cdot 2^{-1}, \quad i = 1, 2, \dots,$$

s tim da je

- $b_{-i} \in \{0, 1\}$  nova **binarna** znamenka i
- $B_i \in [0, 1)$  novi “razlomljeni dio” za nastavak postupka.

**Zadatak.** Neka je  $\ell \in \mathbb{N}$ . Dokažite da **nakon**  $\ell$  koraka opisanog postupka vrijedi (korake brojimo od jedan)

$$B = b_{-1} \cdot 2^{-1} + \cdots + b_{-\ell} \cdot 2^{-\ell} + B_\ell \cdot 2^{-\ell}.$$

Dodatno, možemo uzeti ove tvrdnje vrijede i za  $\ell = 0$ ,

- tj. na **početku** cijelog postupka — prije prvog koraka.

## Računanje znamenki broja u bazi 2 (nastavak)

U principu, zadani broj  $B$  može imati **beskonačno** dug prikaz,

- pa ovaj postupak možemo ponavljati “do u nedogled”.

Da bismo dobili **algoritam**, potrebno je zadati

- $j = \text{maksimalni}$  broj znamenki koje želimo izračunati.

S druge strane, kako se **prepoznaže** da  $B$  ima **konačan** prikaz?

- Ako u nekom koraku  $k$  **prvi puta** dobijemo da je  $B_k = 0$ , onda je prikaz **konačan**

$$B = (0.b_{-1}b_{-2}\dots b_{-k})_2.$$

Sve znamenke **iza**  $b_{-k}$  su jednake **0**, pa ih, obično, **ne pišemo**. To se može dogoditi i na **početku**, ako je  $B = 0 = (0.)_2$ .

## Znamenke broja u bazi 2 — algoritam

Algoritam 2. Binarne znamenke razlomljenog dijela realnog broja.

Uzorak: Realni broj  $B \in [0, 1)$  i cijeli broj  $j \geq 0$ .

Izlaz: Broj  $k \geq 0$  i znamenke  $b_{-1}, \dots, b_{-k}$  broja  $B$  u bazi 2.

$i \leftarrow 0; B_0 \leftarrow B; k \leftarrow j;$

sve dok je  $B_i > 0$  i  $i < k$  radi {

$i \leftarrow i + 1;$

$B'_i \leftarrow 2 \cdot B_{i-1};$

$b_{-i} \leftarrow \lfloor B'_i \rfloor;$

$B_i \leftarrow B'_i - b_{-i};$

}

ako je  $B_i = 0$  onda  $k \leftarrow i;$

## Prikaz broja 0.46875 u bazi 2

Primjer. Nadimo prikaz broja 0.46875 u bazi 2.

Počinjemo s  $B_0 = 0.46875$ , a zatim izlazi

$i$	$B'_i = 2 \cdot B_{i-1}$	$b_{-i} = \lfloor B'_i \rfloor$	$B_i = B'_i - b_{-i}$
1	$0.46875 \cdot 2 = 0.9375$	$\lfloor 0.9375 \rfloor = 0$	$0.9375 - 0 = 0.9375$
2	$0.9375 \cdot 2 = 1.875$	$\lfloor 1.875 \rfloor = 1$	$1.875 - 1 = 0.875$
3	$0.875 \cdot 2 = 1.75$	$\lfloor 1.75 \rfloor = 1$	$1.75 - 1 = 0.75$
4	$0.75 \cdot 2 = 1.5$	$\lfloor 1.5 \rfloor = 1$	$1.5 - 1 = 0.5$
5	$0.5 \cdot 2 = 1.0$	$\lfloor 1.0 \rfloor = 1$	$1.0 - 1 = 0.0$

Dobili smo da je  $B_5 = 0$ , pa broj 0.46875 ima konačan prikaz u bazi 2.

## Prikaz broja 0.46875 u bazi 2 (nastavak)

Prva znamenka  $b_{-1}$  je na vrhu tablice, tj. znamenke treba pisati odozgo prema dolje, da ih dobijemo u standardnom poretku  $b_{-1}, b_{-2}, \dots$ .

Rješenje. Prikaz broja 0.46875 u bazi 2 je

$$(0.46875)_{10} = (0.01111)_2$$

i ima 5 binarnih znamenki iza binarne točke.

## Prikaz broja 0.1 u bazi 2

Primjer. Nadimo prikaz broja 0.1 u bazi 2.

Počinjemo s  $B_0 = 0.1$ , a zatim izlazi

$i$	$B'_i = 2 \cdot B_{i-1}$	$b_{-i} = \lfloor B'_i \rfloor$	$B_i = B'_i - b_{-i}$
1	$0.1 \cdot 2 = 0.2$	$\lfloor 0.2 \rfloor = 0$	$0.2 - 0 = 0.2$
2	$0.2 \cdot 2 = 0.4$	$\lfloor 0.4 \rfloor = 0$	$0.4 - 0 = 0.4$
3	$0.4 \cdot 2 = 0.8$	$\lfloor 0.8 \rfloor = 0$	$0.8 - 0 = 0.8$
4	$0.8 \cdot 2 = 1.6$	$\lfloor 1.6 \rfloor = 1$	$1.6 - 1 = 0.6$
5	$0.6 \cdot 2 = 1.2$	$\lfloor 1.2 \rfloor = 1$	$1.2 - 1 = 0.2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$

Dobili smo da je  $B_5 = B_1$ . Zato se “blok” od 4 reda tablice (od drugog do petog) nadalje ponavlja do u beskonačnost.

## Prikaz broja $0.1$ u bazi $2$ (nastavak)

To znači da  $0.1$  ima beskonačan periodički prikaz u bazi  $2$ ,

- a znamenke  $b_{-2}, b_{-3}, b_{-4}, b_{-5}$  čine jedan period.

Rješenje. Prikaz broja  $0.1$  u bazi  $2$  je

$$(0.1)_{10} = (0.0\ 0011\ 0011\dots)_2 = (0.0\ \dot{0}01\dot{1})_2.$$

Time smo **završili** priču o prikazu realnih brojeva  $B \in [0, 1]$ , tj. sad znamo naći i prikaz

- razlomljenog dijela bilo kojeg **nenegativnog** realnog broja.

Vratimo se onda prikazu “općih” realnih brojeva  $B \in \mathbb{R}$ .

## Zapis bilo kojeg realnog broja u bazi 2

Neka je  $B \in \mathbb{R}$  neki **realan** broj.

Prikaz broja  $B$  u **bazi  $b = 2$**  dobiva se tako da nađemo prikaz njegove absolutne vrijednosti — **nenegativnog** broja  $|B|$ .

Prikaz broja  $|B|$  dobiva se **spajanjem** prikaza

- njegovog **cjelobrojnog** dijela  $\lfloor |B| \rfloor$  i
- njegovog **razlomljenog** dijela  $|B| - \lfloor |B| \rfloor \in [0, 1)$ ,

a između ta dva dijela pišemo **binarnu** točku.

Na kraju, ako je  $B < 0$ , dobivenom prikazu broja  $|B|$

- na početak dodamo predznak **–** (minus).

## Zapis realnog broja u bazi 2 (nastavak)

Podloga je **pozicioni** zapis nenegativnog broja  $|B|$  u **bazi**  $b = 2$ :

$$|B| = \underbrace{\sum_{i=0}^k b_i \cdot 2^i}_{\text{cijeli dio}} + \underbrace{\sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i}}_{\text{razlovljeni dio}}, \quad b_i, b_{-i} \in \{0, 1\},$$

gdje su  $b_i, b_{-i}$  binarne znamenke ili **bitovi** broja  $|B|$  i broja  $B$ , a **cijeli dio** broja je **normaliziran**. Ako je  $\lfloor |B| \rfloor \neq 0$ , onda je  $b_k > 0$ , a u protivnom pišemo znamenku  $b_0 = 0$ .

Skraćeni zapis, uz eventualni predznak broja  $B$ , je

$$B = \pm(b_k b_{k-1} \dots b_1 b_0.b_{-1} b_{-2} \dots)_2.$$

Ako je  $B$  **cijeli** broj, tj.  $B \in \mathbb{Z}$ , onda se  $B$  prikazuje baš kao **cijeli** broj, a **razlovljeni** dio mu je jednak **nula** i ne piše se.

## Prikaz broja $-10.25$ u bazi 2

Primjer. Nadimo prikaz broja  $-10.25$  u bazi 2.

Cjelobrojni dio absolutne vrijednosti broja  $B$  je

$$B_0 = \lfloor |B| \rfloor = 10.$$

Prikaz u bazi 2:

$i$	$B_i$	$b_i = B_i \bmod 2$	$B_{i+1} = B_i \text{ div } 2$
0	$10 = 5 \cdot 2 + 0$	$10 \bmod 2 = 0$	$10 \text{ div } 2 = 5$
1	$5 = 2 \cdot 2 + 1$	$5 \bmod 2 = 1$	$5 \text{ div } 2 = 2$
2	$2 = 1 \cdot 2 + 0$	$2 \bmod 2 = 0$	$2 \text{ div } 2 = 1$
3	$1 = 0 \cdot 2 + 1$	$1 \bmod 2 = 1$	$1 \text{ div } 2 = 0$

Dakle, prikaz cjelobrojnog dijela je  $(10)_{10} = (1010)_2$ .

## Prikaz broja $-10.25$ u bazi 2 (nastavak)

Razlomljeni dio absolutne vrijednosti broja  $B$  je

$$B_0 = |B| - \lfloor |B| \rfloor = 0.25.$$

Prikaz u bazi 2:

$i$	$B'_i = 2 \cdot B_{i-1}$	$b_{-i} = \lfloor B'_i \rfloor$	$B_i = B'_i - b_{-i}$
1	$0.25 \cdot 2 = 0.5$	$\lfloor 0.5 \rfloor = 0$	$0.5 - 0 = 0.5$
2	$0.5 \cdot 2 = 1.0$	$\lfloor 1.0 \rfloor = 1$	$1.0 - 1 = 0.0$

Dakle, prikaz razlomljenog dijela je  $(0.25)_{10} = (0.01)_2$ .

Kad spojimo ove prikaze i dodamo predznak, izlazi

$$(-10.25)_{10} = (-1010.01)_2.$$

## **Normalizirani zapis realnog broja u bazi 2**

Normalizirani prikaz realnog broja  $B$  u bazi  $b = 2$  odgovara tzv. “znanstvenom” zapisu tog broja u obliku

$$B = \text{predznak} \cdot \text{mantisa} \cdot 2^{\text{eksponent}},$$

s tim da je

- predznak  $\in \{-1, 1\}$ , a značenja su, redom, minus i plus.

Umjesto predznaka, mogli bismo koristiti i funkciju sign, no standardno je  $\text{sign}(0) = 0$ , što nepotrebno komplificira stvar.

Čisto matematički, bez obzira na prikaz brojeva u računalu, da bismo osigurali jednoznačnost ovog zapisa, moramo:

- precizirati oblik mantise i eksponenta
- i uvesti neki dogovor za prikaz broja  $B = 0$ .

## **Normalizirani zapis realnog broja u bazi 2**

Dogovor za “normalizirani” prikaz nule je:  $0 = 1 \cdot 0.0 \cdot 2^0$ , tj.

- $\text{predznak}(0) = 1$ ,  $\text{mantisa}(0) = 0.0$ ,  $\text{eksponent}(0) = 0$ .

Standardna ograničenja na mantisu i eksponent su:

- eksponent je cijeli broj,
- mantisa je pozitivan realni broj s jednoznamenkastim cjelobrojnim dijelom, tj. nalazi se u intervalu  
$$\text{mantisa} \in [1, 2).$$

Uz ova ograničenja, svaki realni broj  $B \neq 0$

- ima jednoznačan normalizirani prikaz u bazi 2.

Za  $B = 0$  to ne vrijedi i zato nam treba raniji dogovor.

## Normalizirani zapis $B \neq 0$ u bazi 2

U nastavku koristimo **skraćene** oznake

- $s$ ,  $m$  i  $e$  za predznak, mantisu i eksponent broja, po ugledu na oznake kod prikaza brojeva u računalu.

Ako je  $B \neq 0$ , onda njegov **normalizirani** prikaz u bazi  $b = 2$  ima sljedeći oblik:

$$B = s \cdot \left( \underbrace{b_0 + \sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i}}_m \right) \cdot 2^e, \quad b_0, b_{-i} \in \{0, 1\}, \quad b_0 > 0,$$

gdje su  $b_0, b_{-i}$  binarne znamenke ili **bitovi** mantise  $m$  broja  $B$ .

Posebno, u bazi 2, **prva** (cjelobrojna) znamenka mantise mora biti  $b_0 = 1$ .

## Normalizirani zapis $B \neq 0$ u bazi 2 (nastavak)

Skraćeni zapis ovog prikaza je

$$B = s \cdot (b_0.b_{-1}b_{-2}\dots)_2 \cdot 2^e.$$

Dogovorno, kad **mantisu** zapisujemo **znamenkama**, uvijek pišemo njezin **najkraći** oblik (to ne vrijedi u računalu).

Ponekad se za **bitove** mantise koriste **nenegativni** indeksi, uz oznaku  $m_i := b_{-i}$  (na pr., kod prikaza brojeva u računalu).

Nadalje pretpostavljamo da je  $B \neq 0$ . Sljedeći problem je:

- Kako naći **normalizirani** prikaz broja  $B$  u bazi **2**, tj. njegovu **mantisu** i **eksponent**?

S predznakom je lako.

## **Normalizirani zapis $B \neq 0$ u bazi 2 (nastavak)**

Odgovor ovisi o tome što već znamo:

- samo broj  $B$ ,
- ili već imamo njegov “obični” prikaz u bazi 2.

Ako znamo “obični” prikaz broja  $B$  u bazi 2, onda je lako:

- pomaknemo binarnu točku za odgovarajući broj mjesta na pravu stranu,
- tako da dobiveni broj ima jednoznamenkasti cjelobrojni dio, tj. “padne” u traženi interval  $[1, 2)$  za mantisu.

Eksponent je broj mjesta za koje smo pomakli binarnu točku:

- pomak udesno daje negativan eksponent, a
- pomak ulijevo daje pozitivan eksponent.

## **Normalizirani prikaz iz običnog — primjeri**

Primjer. Nadimo normalizirani prikaz broja 1717 u bazi 2.

Obični prikaz broja 1717 u bazi 2 je (v. ranije)

$$(1717)_{10} = (11010110101)_2$$

i ima 11 binarnih znamenki. Binarna točka ne piše, jer je broj cijeli, ali nalazi se odmah iza zadnje znamenke.

Očito je da binarnu točku treba pomaknuti odmah iza prve znamenke 1, tj. za 10 mesta ulijevo.

Rješenje. Normalizirani prikaz broja 1717 u bazi 2 je

$$(1717)_{10} = 1 \cdot (1.1010110101)_2 \cdot 2^{10}.$$

Po dijelovima:  $s = 1$ ,  $m = (1.1010110101)_2$  i  $e = 10$ .

## **Normalizirani prikaz iz običnog — primjeri**

Primjer. Nadimo normalizirani prikaz broja  $-10.25$  u bazi 2.

Obični prikaz broja  $-10.25$  u bazi 2 je (v. ranije)

$$(-10.25)_{10} = (-1010.01)_2.$$

Binarnu točku opet treba pomaknuti odmah iza prve napisane znamenke 1, tj. za 3 mesta ulijevo.

Rješenje. Normalizirani prikaz broja  $-10.25$  u bazi 2 je

$$(-10.25)_{10} = -1 \cdot (1.01001)_2 \cdot 2^3.$$

Po dijelovima:  $s = -1$ ,  $m = (1.01001)_2$  i  $e = 3$ .

## **Normalizirani prikaz iz običnog — primjeri**

Primjer. Nadimo normalizirani prikaz broja 0.1 u bazi 2.

Obični prikaz broja 0.1 u bazi 2 je beskonačan (v. ranije)

$$(0.1)_{10} = (0.0\ 0011\ 0011\dots)_2 = (0.0\ \dot{0}01\dot{1})_2.$$

Binarnu točku sad treba pomaknuti odmah iza prve napisane jedinice, tj. za 4 mesta udesno.

Rješenje. Normalizirani prikaz broja 0.1 u bazi 2 je

$$\begin{aligned}(0.1)_{10} &= 1 \cdot (1.1001\ 1001\dots)_2 \cdot 2^{-4} \\ &= 1 \cdot (1.\dot{1}00\dot{1})_2 \cdot 2^{-4}.\end{aligned}$$

Po dijelovima:  $s = 1$ ,  $m = (1.\dot{1}00\dot{1})_2$  i  $e = -4$ .

## **Normalizirani zapis $B \neq 0$ u bazi 2 (nastavak)**

Uzmimo sad da **znamo** samo broj  $B$ .

U tom slučaju, ranije operacije:

- pomakni binarnu točku za odgovarajući broj mesta na **pravu** stranu,
- tako da dobiveni broj ima jednoznamenkasti cjelobrojni dio, tj. “padne” u traženi interval  $[1, 2)$  za mantisu, treba obaviti “bez gledanja prikaza”,
- koristeći samo **operacije na brojevima**.

Već smo rekli da se predznak  $s$  lako nalazi — testom  $B > 0$ , pa je dovoljno raditi s brojem  $|B| > 0$ . Idemo redom.

## **Normalizirani zapis $B \neq 0$ u bazi 2 (nastavak)**

Uočimo da pomak binarne točke u broju za jedno mjesto

- udesno — odgovara množenju broja s 2,
- ulijevo — odgovara dijeljenju broja s 2.

Cilj pomicanja binarne točke u broju  $|B|$  je dobiti mantisu,

- tj. treba “natjerati” broj u traženi interval  $[1, 2)$ .

Usput, da bi polazni broj  $|B|$  ostao isti, za svaki pomak točke, eksponent baze 2 treba pomaknuti na “suprotnu” stranu:

- točka udesno — smanji eksponent za 1,
- točka ulijevo — povećaj eksponent za 1.

Dakle, kostur algoritma se nazire.

## Normalizirani zapis $B \neq 0$ u bazi 2 (nastavak)

Ovaj postupak, zapravo, rastavlja  $|B|$  u produkt dva faktora

$$|B| = \text{broj} \cdot 2^e, \quad \text{broj} = |B| \cdot 2^{-e},$$

mijenjajući broj i eksponent  $e$ , sve dok ne dobije broj  $\in [1, 2)$ .

Fali nam još samo početak, tj. **inicijalizacija** postupka.

Krećemo s  $\text{broj} = |B|$ . Onda, očito,  $e$  treba staviti na **nulu**.

I zadnja stvar — “**pravu**” stranu za pomak binarne točke nalazimo usporedbom broja  $|B|$  s **rubovima** željenog intervala:

- $|B| \geq 2$  — **ulijevo**: smanjuj broj (dijeljenje), **povećavaj**  $e$ ,
- $|B| < 1$  — **udesno**: **povećavaj** broj (množenje), **smanjuj**  $e$ ,
- inače — onda je  $|B| \in [1, 2)$  pa smo odmah **gotovi**.

## **Normalizirani zapis broja u bazi 2 — algoritam**

Algoritam 3. Normalizirani binarni zapis realnog broja.

Ulaz: Realni broj  $B$ .

Izlaz: Predznak  $s$ , mantisa  $m$  i eksponent  $e$  u normaliziranom zapisu broja  $B$  u bazi 2.

```
/* Prvo sredimo  $B = 0$ . */  
ako je  $B = 0$  onda {  
     $s \leftarrow 1$ ;  $m \leftarrow 0.0$ ;  $e \leftarrow 0$ ;  
} inače {  
    /* Ovdje je  $B \neq 0$ . */  
    ako je  $B > 0$  onda  $s \leftarrow 1$ ; inače  $s \leftarrow -1$ ;  
     $m \leftarrow |B|$ ;  $e \leftarrow 0$ ;
```

## **Normalizirani zapis broja u bazi 2 — algoritam**

```
ako je  $m \geq 2$  onda {  
    /* Smanjuj  $m$  dijeljenjem, povećavaj  $e$ . */  
    ponavlja {  
         $m \leftarrow m/2; e \leftarrow e + 1;$   
    } sve dok je  $m \geq 2$ ;  
} inače ako je  $m < 1$  onda {  
    /* Povećavaj  $m$  množenjem, smanjuj  $e$ . */  
    ponavlja {  
         $m \leftarrow m \cdot 2; e \leftarrow e - 1;$   
    } sve dok je  $m < 1$ ;  
}  
}
```

Ovdje, na kraju, brojevi  $s$ ,  $m$  i  $e$  imaju tražene vrijednosti.

## **Normalizirani zapis broja u bazi 2 — komentar**

Ovaj algoritam radi samo s brojevima, pa su i

- njegovi rezultati — “obični” brojevi.

Ako je  $B \neq 0$ , onda je  $B = s \cdot m \cdot 2^e$ , uz

$$s \in \{-1, 1\}, \quad m \in [1, 2), \quad e \in \mathbb{Z}.$$

Drugim riječima, ne dobivamo binarne prikaze brojeva  $m$  i  $e$

- kao nizove njihovih znamenki u bazi 2.

U ovom obliku normaliziranog zapisa realnog broja  $B$ , baza 2 se pojavljuje samo na dva mesta:

- kao baza za eksponent broja,  $B = s \cdot m \cdot 2^e$ ,
- kao desni rub intervala  $[1, 2)$  za mantisu, ako je  $B \neq 0$ .

## Normalizirani zapis broja u bazi 2 — znamenke

Ako želimo **prikaz** dobivenih brojeva  $m$  i  $e$  u bazi 2, tj.

- ako želimo naći i **nizove njihovih znamenki**, onda ima još posla.

Mantisa  $m = (b_0.b_{-1}b_{-2}\dots)_2$ :

- prvo izdvojimo cjelobrojnu znamenkku  $b_0$  iz broja  $m$ ,  
 $b_0 = \lfloor m \rfloor$  (ako je  $B \neq 0$ , u bazi 2 je  $b_0 = 1$ ),
- pozovemo **Algoritam 2** na razložljenom dijelu mantise,  
tj. na broju  $m - b_0 \in [0, 1)$ .

Eksponent  $e = (\pm e_\ell \dots e_0)_2$ :

- izdvojimo predznak i pozovemo **Algoritam 1** na broju  $|e|$ .

## Normalizirani prikaz broja $-10.25$ u bazi 2

Primjer. Nadimo normalizirani prikaz broja  $-10.25$  u bazi 2.

Prvo nađemo predznak: iz  $B = -10.25 < 0$  slijedi  $s = -1$ .

U nastavku radimo s absolutnom vrijednošću  $|B| = 10.25$ .

Na početku je  $m = |B|$  i  $e = 0$ . Zbog  $m = 10.25 \geq 2$ ,

- binarnu točku u broju  $m$  treba pomicati ulijevo, tj.
- $m$  treba dijeliti s 2, a  $e$  povećavati za 1.

korak	$m \leftarrow m/2$	$e \leftarrow e + 1$
1	$10.25 / 2 = 5.125 \geq 2$	$0 + 1 = 1$
2	$5.125 / 2 = 2.5625 \geq 2$	$1 + 1 = 2$
3	$2.5625 / 2 = 1.28125 < 2$	$2 + 1 = 3$

## **Normalizirani prikaz broja $-10.25$ u bazi 2**

Rješenje. Normalizirani prikaz broja  $-10.25$  u bazi 2 je

$$(-10.25)_{10} = -1 \cdot 1.28125 \cdot 2^3.$$

Po dijelovima:  $s = -1$ ,  $m = 1.28125$  i  $e = 3$ .

Binarni prikaz mantise:

- $b_0 = 1$ , a Algoritam 2 na broju  $m - b_0 = 0.28125$  daje

$$0.28125 = (0.01001)_2$$

(provjerite), pa je  $m = 1.28125 = (1.01001)_2$ .

Binarni prikaz eksponenta:

- Algoritam 1 na broju  $|e| = 3$  daje  $3 = (11)_2$ , pa je  $e = 3 = (11)_2$ .

## Normalizirani prikaz broja 0.1 u bazi 2

Primjer. Nadimo normalizirani prikaz broja 0.1 u bazi 2.

Prvo nađemo predznak: iz  $B = 0.1 \geq 0$  slijedi  $s = 1$ .

Na početku je  $m = |B|$  i  $e = 0$ . Zbog  $m = 0.1 < 1$ ,

- binarnu točku u broju  $m$  treba pomicati udesno, tj.
- $m$  treba množiti s 2, a  $e$  smanjivati za 1.

korak	$m \leftarrow m \cdot 2$	$e \leftarrow e - 1$
1	$0.1 \cdot 2 = 0.2 < 1$	$0 - 1 = -1$
2	$0.2 \cdot 2 = 0.4 < 1$	$-1 - 1 = -2$
3	$0.4 \cdot 2 = 0.8 < 1$	$-2 - 1 = -3$
4	$0.8 \cdot 2 = 1.6 \geq 1$	$-3 - 1 = -4$

## Normalizirani prikaz broja 0.1 u bazi 2

Rješenje. Normalizirani prikaz broja 0.1 u bazi 2 je

$$(0.1)_{10} = 1 \cdot 1.6 \cdot 2^{-4}.$$

Po dijelovima:  $s = 1$ ,  $m = 1.6$  i  $e = -4$ .

Binarni prikaz mantise:

- $b_0 = 1$ , a Algoritam 2 na broju  $m - b_0 = 0.6$  daje

$$0.6 = (0.\dot{1}00\dot{1})_2$$

(provjerite), pa je  $m = 1.6 = (1.\dot{1}00\dot{1})_2$ .

Binarni prikaz eksponenta:

- Algoritam 1 na broju  $|e| = 4$  daje  $4 = (100)_2$ , pa je  $e = -4 = (-100)_2$ .

# Prikaz realnih brojeva u računalu i primjeri

# *Sadržaj*

- Realni brojevi — prikaz u računalu:
  - Izgled prikaza i prikazivi brojevi.
  - Zaokruživanje realnih brojeva u računalu za prikaz.
  - Prikaz u tipovima `float` i `double` — primjeri.

# Prikaz realnih brojeva u računalu — uvod

Prikaz realnih brojeva u računalu sličan je normaliziranom prikazu realnih brojeva u bazi 2

$$B = s \cdot m \cdot 2^e.$$

Bitne razlike:

- za svaki od tri dijela  $s$ ,  $m$  i  $e$  imamo na raspolaganju konačan broj binarnih znamenki (bitova) za prikaz,
- umjesto eksponenta, pamti se karakteristika  $k$ , koja je pomaknuti eksponent,  $k = e + bias$  (engl. bias = pomak),
- umjesto mantise, pamti se signifikand (oznaka je isto  $m$ ), a dobiva se nakon zaokruživanja mantise,
- vodeći bit  $b_0$  mantise se, najčešće, ne pamti (hidden bit).

Dodatno, neki brojevi se prikazuju u denormaliziranom obliku.

# *Realni brojevi u računalu — duljine dijelova*

Svaki od **tri dijela** broja ima svoju **duljinu** — broj bitova predviđenih za prikaz tog dijela.

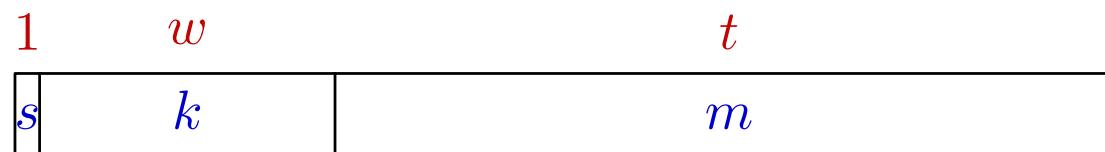
- predznak  $s$  — uvijek zauzima **jedan** bit, i to **najviši**;
- karakteristika  $k$  — zauzima sljedećih  $w$  bitova;
- signifikand  $m$  — zauzima sljedećih
  - $t$  bitova, ako se pamti samo **razlomljeni** dio mantise,
  - $t + 1$  bit, ako se pamti i njezin **vodeći cjelobrojni** bit.

U nastavku, radi jednostavnosti, uzimamo da se u računalu

- sprema samo **razlomljeni** dio mantise,
- kao u standardnim **IEEE 754** tipovima **binary32** i **binary64** (tipovi **float** i **double** u C-u).

# Realni brojevi u računalu — izgled i predznak

Cijeli **prikaz** realnog broja u **računalu** onda ima sljedeći oblik:



Bit **predznaka**  $s$  uvijek se kôdira tako da je

- $s = 0$  — za **pozitivan** broj ili **+0**,
- $s = 1$  — za **negativan** broj ili **-0**.

tj., u ranijim oznakama je predznak  $= (-1)^s \in \{-1, 1\}$ .

Po bitovima, **karakteristika** i **signifikand** imaju sljedeći izgled:

karakteristika					signifikand (mantisa)				
$k_{w-1}$	$k_{w-2}$	$\cdots$	$k_1$	$k_0$	$b_{-1}$	$b_{-2}$	$\cdots$	$b_{-t+1}$	$b_{-t}$

gdje su  $k_i, b_{-i} \in \{0, 1\}$ . Precizan opis značenja ide u nastavku.

# Karakteristika

Karakteristika  $k$

karakteristika

$k_{w-1}$	$k_{w-2}$	$\cdots$	$k_1$	$k_0$
-----------	-----------	----------	-------	-------

se interpretira kao cijeli broj bez predznaka,

$$k = \sum_{i=0}^{w-1} k_i \cdot 2^i,$$

tako da je  $k \in \{0, \dots, 2^w - 1\}$ .

“Rubne” vrijednosti za  $k$  označavaju tzv. posebna stanja:

- $k_{\min} = 0$  — nula i denormalizirani brojevi,
- $k_{\max} = 2^w - 1$  — beskonačno (**Inf**) i “nije broj” (**NaN**).

## **Karakteristika i stvarni eksponent**

Sve ostale vrijednosti  $k \in \{1, \dots, 2^w - 2\}$  koriste se za prikaz **normaliziranih** brojeva (različitih od nule).

U tom slučaju, veza između **karakteristike**  $k$  i stvarnog **eksponenta**  $e$  prikazanog broja je

$$k = e + bias, \quad bias = 2^{w-1} - 1.$$

Uočite da je  $bias =$  polovina najveće dozvoljene karakteristike.

Dakle, eksponenti  $e$  prikazivih **normaliziranih** brojeva nalaze se između

$$e_{\min} = -(2^{w-1} - 2) \quad \text{i} \quad e_{\max} = 2^{w-1} - 1.$$

Stvarni eksponent  $e$  svih prikazivih **denormaliziranih** brojeva je  $e = e_{\min} = -(2^{w-1} - 2)$ , a pripadna karakteristika je  $k = 0$ .

# Signifikand

Signifikand  $m$  ima oblik

signifikand (mantisa)

$b_{-1}$	$b_{-2}$	$\cdots$	$b_{-t+1}$	$b_{-t}$
----------	----------	----------	------------	----------

Katkad se ovi bitovi indeksiraju **pozitivnim** indeksima, tako da je  $m_i = b_{-i}$

signifikand (mantisa)

$m_1$	$m_2$	$\cdots$	$m_{t-1}$	$m_t$
-------	-------	----------	-----------	-------

Ako je  $k < k_{\max} = 2^w - 1$ , onda se signifikand  $m$  interpretira

- kao razlomljeni dio  $m_r$  stvarne mantise prikazivog broja

$$m_r = \sum_{i=1}^t b_{-i} \cdot 2^{-i} = \sum_{i=1}^t m_i \cdot 2^{-i} \in [0, 1].$$

## **Signifikand i stvarna mantisa**

Stvarna mantisa dobiva se dodavanjem “skrivenog bita”  $b_0$  (engl. “hidden bit”), kao cjelobrojnog dijela mantise broja:

$$m = b_0 + m_r = b_0 + \sum_{i=1}^t b_{-i} \cdot 2^{-i} = (b_0.b_{-1}b_{-2} \dots b_{-t})_2,$$

s tim da je “skriveni bit”

- $b_0 = 1$  — za normalizirane brojeve, tj. mantisa im je

$$m = 1 + \sum_{i=1}^t b_{-i} \cdot 2^{-i} = (1.b_{-1}b_{-2} \dots b_{-t})_2,$$

- $b_0 = 0$  — za denormalizirane brojeve, tj. mantisa im je

$$m = 0 + \sum_{i=1}^t b_{-i} \cdot 2^{-i} = (0.b_{-1}b_{-2} \dots b_{-t})_2.$$

# *Skupovi prikazivih realnih brojeva u računalu*

Skup svih **prikazivih** realnih brojeva u **računalu** je **konačan** i parametriziran je s **dva** parametra:

- duljinom  $t$  signifikanda ili mantise,
- duljinom  $w$  karakteristike ili eksponenta.

Označavamo ga s  $\mathbb{R}(t, w)$ .

Možemo ga prikazati kao uniju **dva** disjunktna podskupa:

$$\mathbb{R}(t, w) = \mathbb{F}(t, w) \cup \mathbb{D}(t, w),$$

gdje je

- $\mathbb{F}(t, w)$  = skup svih **normaliziranih** prikazivih brojeva, ili skup svih prikazivih brojeva u normaliziranom **rasponu**,
- $\mathbb{D}(t, w)$  = skup svih **denormaliziranih** prikazivih brojeva.

## Normalizirani prikazivi brojevi

Normalizirani prikazivi brojevi  $B \in \mathbb{F}(t, w)$  prepoznaju se po karakteristici  $k$  za koju vrijedi  $k_{\min} < k < k_{\max}$ . Imaju oblik

$$B = (-1)^s \cdot m \cdot 2^e,$$

gdje je:

- bit predznaka  $s \in \{0, 1\}$ ,
- stvarna mantisa  $m = (1.b_{-1}b_{-2}\dots b_{-t})_2$ ,
- stvarni eksponent  $e = k - 2^{w-1} + 1$ , a nalazi se između  $e_{\min}$  i  $e_{\max}$ , tj. vrijedi  $e \in \{-(2^{w-1} - 2), \dots, 2^{w-1} - 1\}$ .

Skup normaliziranih prikazivih brojeva  $\mathbb{F}(t, w)$  ima točno

$$2 \cdot 2^t \cdot (2^w - 2) = 2^{p+1} \cdot bias$$

elemenata (uz oznaku  $p = t + 1$ ).

## **Normalizirani prikazivi brojevi — primjeri**

Primjer. Najveći pozitivni normalizirani broj je

$$\begin{aligned}v_{\max} &= (1.\underset{1}{\underset{\uparrow}{1}}\underset{t}{\underset{\uparrow}{1}}1\dots111)_2 \cdot 2^{e_{\max}} \\&= (1 + (1 - 2^{-t})) \cdot 2^{e_{\max}} = 2(1 - 2^{-t-1}) \cdot 2^{e_{\max}} \\&= (1 - 2^{-p}) \cdot 2^{e_{\max}+1} = (1 - 2^{-p}) \cdot 2^{2^w-1}.\end{aligned}$$

Primjer. Najmanji pozitivni normalizirani broj je

$$\begin{aligned}v_{\min} &= (1.\underset{1}{\underset{\uparrow}{0}}\underset{t}{\underset{\uparrow}{0}}0\dots000)_2 \cdot 2^{e_{\min}} \\&= 2^{e_{\min}} = 2^{-(2^w-1)-2}.\end{aligned}$$

## **Normalizirani prikazivi brojevi — izbor pomaka**

Već smo rekli da za **normalizirane** prikazive brojeve vrijedi sljedeća veza između karakteristike  $k$  i stvarnog eksponenta  $e$

$$k = e + \text{bias}, \quad \text{bias} = 2^{w-1} - 1.$$

U ovoj vezi, pomak  $\text{bias}$  je **namjerno izabran** tako da vrijedi

$$e_{\min} + e_{\max} = 1,$$

odnosno,  $e_{\max} = 1 - e_{\min} > -e_{\min}$ , a **ne** obratno!

**Razlog.** Ovaj izbor povlači da je

$$\frac{1}{v_{\min}} = 2^{-e_{\min}} \in \mathbb{F}(t, w),$$

tj. **recipročna** vrijednost **najmanjeg** pozitivnog **normaliziranog** broja je, također, **normalizirani** broj.

## *Denormalizirani prikazivi brojevi*

Denormalizirani prikazivi brojevi  $B \in \mathbb{D}(t, w)$  prepoznaju se po karakteristici  $k$  za koju vrijedi  $k = k_{\min} = 0$ . Imaju oblik

$$B = (-1)^s \cdot m \cdot 2^e,$$

gdje je:

- bit predznaka  $s \in \{0, 1\}$ ,
- stvarna mantisa  $m = (0.b_{-1}b_{-2}\dots b_{-t})_2$ , što uključuje i nule oba predznaka — za mantise  $m = 0$ ,
- stvarni eksponent  $e = e_{\min} = -(2^{w-1} - 2)$ .

Skup denormaliziranih prikazivih brojeva  $\mathbb{D}(t, w)$  ima točno

$$2 \cdot 2^t = 2^p$$

elemenata (uz oznaku  $p = t + 1$ ).

## *Denormalizirani prikazivi brojevi — primjeri*

Primjer. Najveći pozitivni denormalizirani broj je

$$\begin{aligned}v_{\max}^d &= \underset{1}{\overset{\uparrow}{(0.111\dots111)_2}} \cdot 2^{e_{\min}} \\&= (1 - 2^{-t}) \cdot 2^{e_{\min}} = (1 - 2^{-t}) \cdot 2^{-(2^{w-1}-2)}.\end{aligned}$$

Primjer. Najmanji pozitivni denormalizirani broj je

$$\begin{aligned}v_{\min}^d &= \underset{1}{\overset{\uparrow}{(0.000\dots001)_2}} \cdot 2^{e_{\min}} \\&= 2^{-t} \cdot 2^{e_{\min}} = 2^{-(t+2^{w-1}-2)}.\end{aligned}$$

## Karakteristika $k_{\max}$ — beskonačno i “nije broj”

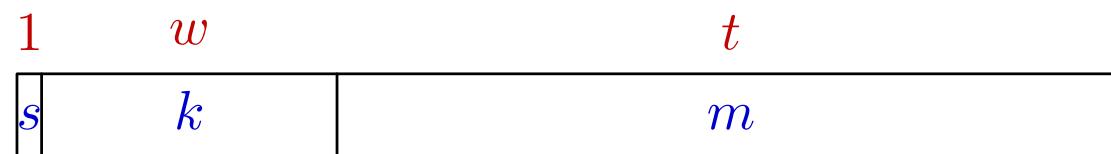
Maksimalna vrijednost karakteristike  $k = k_{\max} = 2^w - 1$  označava posebna stanja koja ne odgovaraju “običnim” brojevima, a mogu se dogoditi prilikom zaokruživanja ili kao rezultat aritmetičkih operacija.

Interpretacija “stanja” ovisi o vrijednosti signifikanda  $m$ .

- $m = 0$ , tj. svi bitovi su nula — spremljena vrijednost se interpretira kao beskonačno (**Inf**), a ovisi o predznaku
  - $s = 0$  — prikaz  $+\infty$ , skraćena oznaka **+Inf**,
  - $s = 1$  — prikaz  $-\infty$ , skraćena oznaka **-Inf**.
- $m \neq 0$ , tj. postoji bit različit od nule — vrijednost se interpretira kao “nije broj” (**NaN**, engl. “Not a Number”). Nastaje kao rezultat nedozvoljene aritmetičke operacije i uvejk označava grešku.

# Prikaz realnih brojeva u računalu — sažetak

Uzmimo da **prikaz** realnih brojeva u **računalu** ima oblik



Uz oznake

$$k_{\max} = 2^w - 1, \quad e_{\max} = bias = 2^{w-1} - 1, \quad e_{\min} = 1 - e_{\max},$$

vrijednost prikazanog broja je

$$v = \begin{cases} (-1)^s * 2^{(k-e_{\max})} * (1.m) & \text{ako je } 0 < k < k_{\max}, \\ (-1)^s * 2^{e_{\min}} * (0.m) & \text{ako je } k = 0 \text{ i } m \neq 0, \\ (-1)^s * 0 & \text{ako je } k = 0 \text{ i } m = 0, \\ (-1)^s * \text{Inf} & \text{ako je } k = k_{\max} \text{ i } m = 0, \\ \text{NaN} & \text{ako je } k = k_{\max} \text{ i } m \neq 0. \end{cases}$$

# Prikaz realnih brojeva u računalu i zaokruživanje

Sada znamo točno kako izgledaju svi prikazivi brojevi u računalu — skup  $\mathbb{R}(t, w)$ .

Međutim, u praksi obično ne krećemo od prikazivih brojeva, već od standardnih realnih brojeva iz skupa  $\mathbb{R}$ , čak  $\mathbb{R} \cup \{-0\}$  (v. stranicu iza). A onda nam fali još jedna, ali ključna stvar:

- Što se događa kad imamo zadan realni broj  $B \in \mathbb{R}$  — kako se on “prikazuje” u računalu?

Naime, broj  $B$ , naravno, ne mora biti prikaziv — pripadati skupu  $\mathbb{R}(t, w)$ !

Ukratko, ako broj  $B$  nije prikaziv, onda se u računalu spremi

- njegova najbolja prikaziva aproksimacija, u oznaci  $f\ell(B)$ ,
- a dobiva se zaokruživanjem polaznog broja.

## **Proširenje polaznog skupa na $\mathbb{R} \cup \{-0\}$ i označke**

U nastavku, uzimamo da polazni broj  $B$  pripada većem skupu  $\mathbb{R} \cup \{-0\}$ . Zašto smo dodali i mogućnost da je  $B = -0$ ? Ako zamislimo da se broj  $B$  učitava, onda

- svakom realnom broju smijemo napisati predznak, pa to vrijedi i za nulu, tj. smijemo napisati i broj  $B = -0$ .

Ovo učitavanje zaista korektno radi, zbog načina pretvaranja zapisa broja na ulazu u prikazivi broj. Naime, ako napišemo

- predznak “ $-$ ” — to se uredno zapamti pri čitanju, i na kraju spremi kao predznak dobivenog prikazivog broja.

Kao rezultat toga, uvedimo još i sljedeće označke:

- $B$  ima predznak “minus” —  $B \leq -0$ ,
- $B$  ima predznak “plus” —  $B \geq +0$ .

# Zaokruživanje realnih brojeva u računalu

Za precizniji opis, zgodno je zaokruživanje gledati kao funkciju

$$f\ell : \mathbb{R} \cup \{-0\} \rightarrow \overline{\mathbb{R}}(t, w) = \mathbb{R}(t, w) \cup \{-\text{Inf}, +\text{Inf}\}.$$

Prvi korak u dobivanju prikazive aproksimacije  $f\ell(B)$  je

- nalaženje najbližeg lijevog i desnog prikazivog susjeda, tj. najbližih brojeva  $B_-$ ,  $B_+ \in \overline{\mathbb{R}}(t, w)$  za koje vrijedi

$$B_- \leq B \leq B_+.$$

Preciznije rečeno,

- $B_-$  = najveći broj iz  $\overline{\mathbb{R}}(t, w)$  manji ili jednak  $B$ ,
- $B_+$  = najmanji broj iz  $\overline{\mathbb{R}}(t, w)$  veći ili jednak  $B$ .

Onda vrijedi: broj  $B$  je prikaziv ako i samo ako je  $B_- = B_+$ !

## Zaokruživanje realnih brojeva u računalu (nast.)

Zbog toga što skup “prikazivih” brojeva  $\overline{\mathbb{R}}(t, w)$  sadrži brojeve  $+0$ ,  $-0$ ,  $+\text{Inf}$  i  $-\text{Inf}$ , ova dva broja  $B_-$ ,  $B_+$

- uvijek **postoje** i jednoznačno su definirani,
- imaju **isti** predznak kao i broj  $B$ .

Za pozitivne brojeve može biti  $B_- = +0$  ili  $B_+ = +\text{Inf}$ .

Analogno za negativne brojeve, samo na suprotnu stranu.

Kako se stvarno **nalaze** brojevi  $B_-$ ,  $B_+$  — o tome malo kasnije.

Kad **imamo** najbliže prikazive susjede  $B_-$ ,  $B_+ \in \overline{\mathbb{R}}(t, w)$ , za prikazivu aproksimaciju broja  $B$ , tj. za **zaokruženi** broj  $B$

- uvijek se uzima **jedan** od ta dva broja, ovisno o **vrsti** ili **tipu** zaokruživanja.

# Vrste zaokruživanja realnih brojeva u računalu

Po IEEE 754 standardu, postoje četiri vrste zaokruživanja.

Standardno (engl. “default”) zaokruživanje za sve procesore je

- prema najbližem broju, a ako su dva najbliža, onda prema “parnom” (engl. “ties to even”) — oznaka  $f\ell$ ,

$$f\ell(B) = \text{“bliži” od brojeva } B_-, B_+.$$

Ako su oba susjeda  $B_-$  i  $B_+$  jednako “udaljena” od  $B$ ,

- izabire se onaj koji ima parni zadnji bit, tj. zadnji bit mu je jednak 0 (točno jedan od brojeva je takav).

Napomena. Ako je neki od brojeva  $B_-$  i  $B_+$  jednak  $\pm\text{Inf}$ , “udaljenost” se mjeri po tome koliko treba dodati ili oduzeti od  $B$  u aritmetici računala da dobijemo  $\pm\text{Inf}$  (v. malo iza).

## Vrste zaokruživanja realnih brojeva (nastavak)

Preostale tri vrste zaokruživanja možemo “zatražiti” opcijama prevoditelju, ili postavljanjem kontrolnih bitova u procesoru:

- prema dolje, ili prema  $-\infty$  — oznaka  $f\ell_-$

$$f\ell_-(B) = B_-,$$

- prema gore, ili prema  $+\infty$  — oznaka  $f\ell_+$

$$f\ell_+(B) = B_+,$$

- prema nuli — oznaka  $f\ell_0$

$$f\ell_0(B) = \begin{cases} B_-, & \text{ako je } B \geq +0, \\ B_+, & \text{ako je } B \leq -0. \end{cases}$$

Ovo odgovara odbacivanju “viška” znamenki u  $B$ .

# *Uvod u primjere za standardno zaokruživanje*

Za potpuni opis zaokruživanja realnih brojeva trebalo bi još:

- opisati kako se za zadani broj  $B \in \mathbb{R} \cup \{-0\}$ ,
- stvarno nalaze najbliži prikazivi susjedi  $B_-$  i  $B_+$ ,

uključivo i pripadne algoritme.

Nažalost, precizan opis nije jednostavan i zahtijeva dosta “tehničkog” posla na detaljima.

Prije toga, zgodno je “neformalno” prikazati

- kako se radi standardno zaokruživanje *fl* u računalu, i
- ilustrirati to na primjerima standardnih tipova **float** i **double** u C-u.

# **Standardno zaokruživanje — kratki opis**

Definiciju funkcije  $f\ell$  možemo ugrubo podijeliti u **tri** grupe. Podjela ovisi o odnosu broja  $|B|$  i dozvoljenog **raspona** za **normalizirani** prikaz broja u računalu. Preciznije, o odnosu

- eksponenta  $e$  i “graničnih” eksponenata  $e_{\min}$  i  $e_{\max}$ .

Imamo **tri** mogućnosti.

- Ako je  $e > e_{\max}$ , onda je  $|B|$  prevelik (tzv. “**overflow**”), pa je  $f\ell(B) = s \cdot \text{Inf}$ .
- Ako je  $e_{\min} \leq e \leq e_{\max}$ , onda je  $|B|$  unutar raspona za normalizirani prikaz, pa se **stvarna** mantisa  $m$  zaokružuje na  $t$  mesta. Usput, onda definiramo  $m' = m$ .
- Ako je  $e < e_{\min}$ , onda je  $|B|$  premali (tzv. “**gradual underflow**”), pa se broj **denormalizira** na eksponent  $e_{\min}$ , a tako **dobivena** mantisa  $m' < 1$  zaokružuje na  $t$  mesta.

## **Standardno zaokruživanje — malo neprecizno**

Standardno zaokruživanje  $f\ell$  brojeva u računalu (do na pravilo o “dva najbliža”) možemo i ovako opisati.

Broj  $f\ell(B)$  dobivamo zaokruživanjem iz broja  $B$  na sljedeći način: ako je prva **odbačena** znamenka  $b_{-t-1}$  mantise  $m'$

- jednaka 1 — zaokruži  $m'$  nagore,
- jednaka 0 — zaokruži  $m'$  nadolje.

Kod zaokruživanja **nagore**, može se desiti da dobiveni broj treba “**renormalizirati**” (i tada možemo dobiti rezultat  $\pm\text{Inf}$ ).

Ovo “**neprecizno**” pravilo može biti **pogrešno** samo ako je

- $b_{-t-1} = 1$  **zadnja** ne-nula znamenka mantise  $m'$ .

Tad vrijedi pravilo o dva najbliža: zaokruži prema “**parnom**”.

## Prikaz broja 0.1 kao float

Primjer. Prikaz broja 0.1 kao float ( $t = 23$ ,  $w = 8$ ).

$$(0.1)_{10} = +(\underbrace{1.1001\ 1001\ \dots\ 1001\ 1001\dots}_\text{23})_2 \cdot 2^{-4}.$$

Zaokruživanje iza  $t = 23$  bita razlomljenog dijela (naviše) daje

$$s = 0$$

$$k = e + 2^{w-1} - 1 = -4 + 127 = (123)_{10} = 0111\ 1011$$

$$m = 1001\ 1001\ 1001\ 1001\ 1001\ 101$$

---

Prikaz broja      0.1 [float] u racunalu:

0 01111011 10011001100110011001101

---

## Prikaz broja 0.1 kao float (*nastavak*)

Na IA-32 se viši bitovi nalaze na višim adresama, pa prikaz po byteovima (odnosno, riječima = 4 bytea) izgleda ovako:

---

Prikaz broja 0.1 [float] u racunalu:

1. byte: 1100 1101
2. byte: 1100 1100
3. byte: 1100 1100
4. byte: 0011 1101

---

1. rijec: 0011 1101 1100 1100 1100 1100 1100 1101

## Prikaz broja 0.1 kao double

Primjer. Prikaz broja 0.1 kao **double** ( $t = 52$ ,  $w = 11$ ).

$$(0.1)_{10} = +(\underbrace{1.1001\ 1001\ \dots\ 1001\ 1001\dots}_\text{1} \cdot \underbrace{1001\ 1001\dots}_\text{52})_2 \cdot 2^{-4}.$$

Zaokruživanje iza  $t = 52$  bita razlomljenog dijela (naviše) daje

$$s = 0$$

$$k = e + 2^{w-1} - 1 = -4 + 1023 = (1019)_{10} = 011\ 1111\ 1011$$

$$m = 1001\ 1001\ 1001\ 1001\ 1001\ 1001\ 1001$$

$$\quad\quad\quad 1001\ 1001\ 1001\ 1001\ 1001\ 1010$$

---

Prikaz broja 0.1 [double] u racunalu:

0 0111111011 10011001100110011001  
10011001100110011001100110011010

---

## *Prikaz broja 0.1 kao double (nastavak)*

Prikaz po byteovima (odnosno, riječima) izgleda ovako:

---

Prikaz broja 0.1 [double] u racunalu:

1. byte: 1001 1010
2. byte: 1001 1001
3. byte: 1001 1001
4. byte: 1001 1001
5. byte: 1001 1001
6. byte: 1001 1001
7. byte: 1011 1001
8. byte: 0011 1111

1. rijec: 1001 1001 1001 1001 1001 1001 1001 1001 1010
  2. rijec: 0011 1111 1011 1001 1001 1001 1001 1001 1001
-

# Prikaz realnih brojeva — zaokruživanje i greške

# *Sadržaj*

- Prikaz realnih brojeva — zaokruživanje i greške (još nije sređeno!):
  - Nalaženje najbližih prikazivih brojeva.
  - Greške zaokruživanja u prikazu.

## Nalaženje prikazivih susjeda $B_-$ i $B_+$

Na kraju, opišimo još **kako** se za zadani broj  $B \in \mathbb{R} \cup \{-0\}$

- stvarno **nalaze** najbliži prikazivi susjedi  $B_-$  i  $B_+$ .

Polazna točka je **normalizirani** prikaz broja  $B$  u bazi 2.

Jednostavnim **proširenjem** ranije definicije, svaki “ulazni” broj  $B \in \mathbb{R} \cup \{-0\}$  ima **jednoznačan normalizirani** prikaz u bazi 2

$$B = s \cdot |B|, \quad |B| = (1) \cdot m \cdot 2^e,$$

s tim da je predznak  $s \in \{-1, 1\}$ , a za **egzaktnu** mantisu  $m$  i eksponent  $e$  vrijedi

- ako je  $|B| > 0$ , onda je  $m \in [1, 2)$  i  $e \in \mathbb{Z}$ ,
- ako je  $|B| = 0$ , onda je  $m = 0.0$  i  $e = 0$ .

Dodavanje broja  $-0$  daje potpunu **simetriju** skupa oko **nule!**

## *Predznak prikazivih susjeda $B_-$ i $B_+$*

Ponovimo, najближи prikazivi susjedi broja  $B$  su definirani kao

- $B_-$  = najveći broj iz  $\overline{\mathbb{R}}(t, w)$  manji ili jednak  $B$ ,
- $B_+$  = najmanji broj iz  $\overline{\mathbb{R}}(t, w)$  veći ili jednak  $B$ .

Skup  $\overline{\mathbb{R}}(t, w)$  sadrži brojeve  $-0$  i  $+0$ , pa traženi susjedi

- $B_-$  i  $B_+$  uvijek imaju isti predznak  $s$  kao i broj  $B$ .

Osim toga,  $\overline{\mathbb{R}}(t, w)$  je, također, potpuno simetričan oko nule.

Neka su  $|B|_-$  i  $|B|_+$  najблиži prikazivi susjedi broja  $|B|$ . Za sve “negativne” brojeve  $B \leq -0$  onda vrijedi

$$B_- = -(|B|_+), \quad B_+ = -(|B|_-),$$

pa njihove absolutne vrijednosti  $|B_-|$  i  $|B_+|$  možemo naći iz broja  $|B|$ .

## Nalaženje $B_-$ i $B_+$ iz $|B|_-$ i $|B|_+$

Zato nalaženje najbližih prikazivih susjeda  $B_-$  i  $B_+$  broja  $B$

- kreće od broja  $|B|$  i prvo se nalaze njegovi prikazivi susjedi  $|B|_-$  i  $|B|_+$ .

To su, ujedno, i **apsolutne** vrijednosti najbližih prikazivih susjeda broja  $B$ . Njih nalazimo koristeći **predznak** od  $B$ .

- Ako je  $B \geq +0$ , onda je

$$B_- = |B|_-, \quad B_+ = |B|_+.$$

- Ako je  $B \leq -0$ , onda je

$$B_- = -|B|_+, \quad B_+ = -|B|_-.$$

Dakle, na samom kraju, ako je  $B \leq -0$ , nađenim brojevima  $|B|_-$  i  $|B|_+$  se dodaje negativan predznak i “okreće” značenje.

## Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$

Za svaki broj  $B \in \mathbb{R} \cup \{-0\}$ , njegova **apsolutna vrijednost**  $|B|$  ima **jednoznačan normalizirani prikaz u bazi 2** (uz  $s = 1$ )

$$|B| = m \cdot 2^e,$$

s tim da za **egzaktnu mantisu**  $m$  i eksponent  $e$  vrijedi

- ako je  $|B| > 0$ , onda je  $m \in [1, 2)$  i  $e \in \mathbb{Z}$ ,
- ako je  $|B| = 0$ , onda je  $m = 0.0$  i  $e = 0$ .

Brojevi  $B$  i  $|B|$  imaju **iste** mantise i **iste** eksponente, a mogu se **razlikovati** samo u **predznaku**  $s$ .

Za početak, ako je  $|B| = 0$ , tj.  $m = 0.0$ , onda je

$$|B|_- = |B|_+ = +0 \in \mathbb{D}(t, w).$$

Broj  $B$  je **egzaktно** prikaziv i tu nema greške zaokruživanja.

## Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)

Prepostavimo nadalje da je  $|B| \neq 0$ . Onda je

$$|B| = m \cdot 2^e, \quad m \in [1, 2\rangle, \quad e \in \mathbb{Z}.$$

Nalaženje brojeva  $|B|_-$  i  $|B|_+$  ovisi o odnosu eksponenta  $e$  i “graničnih” eksponenata  $e_{\min}$  i  $e_{\max}$ . Imamo tri mogućnosti.

- Ako je  $e > e_{\max}$ , onda je  $|B|$  prevelik (tzv. “overflow”). Ovaj slučaj razmatramo na kraju.
- Ako je  $e_{\min} \leq e \leq e_{\max}$ , onda je  $|B|$  unutar raspona za normalizirani prikaz.
- Ako je  $e < e_{\min}$ , onda je  $|B|$  premali (tzv. “gradual underflow”), pa se broj denormalizira na eksponent  $e_{\min}$

$$|B| = m' \cdot 2^{e_{\min}}, \quad m' = m \cdot 2^{e - e_{\min}} \in \langle 0, 1\rangle.$$

## **Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)**

Uzmimo da broj  $|B|$  nije prevelik, tj. da je  $e \leq e_{\max}$  i neka je  $|B|$  već denormaliziran (ako je  $e < e_{\min}$ ), tako da je

$$|B| = m' \cdot 2^{e'},$$

s tim da vrijedi:

- za  $e \geq e_{\min}$  —  $m' = m$  i  $e' = e$ ,
- za  $e < e_{\min}$  —  $m' = m \cdot 2^{e - e_{\min}}$  i  $e' = e_{\min}$ .

Prikazive susjede  $|B|_-$  i  $|B|_+$  dobivamo iz ovog zapisa  $|B|$ ,

- zaokruživanjem njegove “mantise”  $m'$ , odnosno, njezinog razlomljenog dijela, na  $t$  mjesta iza binarne točke,
- i to: nadolje — za  $|B|_-$ , a nagore — za  $|B|_+$ , uz eventualnu dodatnu normalizaciju broja  $|B|_+$ .

## Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)

Za ovako dobivenu egzaktnu “mantisu”  $m'$  od  $|B|$  vrijedi

- $m' \in [1, 2)$ , za  $e \geq e_{\min}$ ,
- $m' \in \langle 0, 1 \rangle$ , za  $e < e_{\min}$ , nakon denormalizacije broja  $|B|$ .

U bazi 2, realni broj  $m'$  onda možemo prikazati u obliku

$$m' = b_0 + \sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i}, \quad b_0, b_{-i} \in \{0, 1\}.$$

Ovaj zapis služi samo za ilustraciju, jer znamenke ne znamo (trebalo bi ih naći nekim algoritmom).

Stvarno, znamo samo cjelobrojni bit  $b_0$  — iz granica za  $m'$ :

- $b_0 = 1$ , za  $e \geq e_{\min}$ ,
- $b_0 = 0$ , za  $e < e_{\min}$ , tj. ako je  $|B|$  bio denormaliziran.

## **Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)**

Pogledajmo sad razloženi dio broja  $m'$

$$m'_r = \sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i} = (0.b_{-1}b_{-2}\dots)_2.$$

Tu imamo dvije mogućnosti, ovisno o broju znamenki u  $m'_r$ .

Ako  $m'_r$  ima najviše  $t$  binarnih znamenki iza točke, onda

• zaokruživanje  $m'_r$  na  $t$  mesta ništa ne mijenja,

tj. zaokruživanje nije potrebno i nema greške, pa je

$$|B|_- = |B|_+ = |B| = m' \cdot 2^{e'}.$$

Dakle, broj  $|B|$  (a onda i  $B$ ) je egzaktno prikaziv u računalu, a karakteristika i signifikand se dobivaju direktno iz  $e'$  i  $m'_r$ .

## Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)

Ako  $m'_r$  ima više od  $t$  binarnih znamenki iza točke, onda

- broj  $|B|$  nije egzaktno prikaziv u računalu, pa dolazi do zaokruživanja i pripadne greške.

Razlomljeni dio  $m'_r$  onda ima oblik

$$m'_r = \sum_{i=1}^t b_{-i} \cdot 2^{-i} + \sum_{i=t+1}^{\infty} b_{-i} \cdot 2^{-i} = (0.b_{-1} \dots b_{-t} b_{-t+1} \dots)_2.$$

s tim da je druga suma pozitivna

$$\sum_{i=t+1}^{\infty} b_{-i} \cdot 2^{-i} > 0.$$

Najbliže prikazive brojeve broju  $|B|$  dobivamo zaokruživanjem  $m'_r$  nadolje i nagore na  $t$  mesta iza binarne točke.

## Prikazivi manji susjed $|B|_-$ za $|B|$

Zaokruživanjem  $m'_r$  nadolje na  $t$  mesta iza binarne točke, tj. odbacivanjem drugog pozitivnog člana, dobivamo

$$(m'_r)_- := \sum_{i=1}^t b_{-i} \cdot 2^{-i} = (0.b_{-1} \dots b_{-t})_2 < m'_r.$$

Ovo je **signifikand** broja  $|B|_-$ , a pripadna **prikaziva mantisa** je

$$m'_- := b_0 + (m'_r)_- = (b_0.b_{-1} \dots b_{-t})_2 < m'.$$

Na kraju, najблиži prikazivi **manji** susjed  $|B|_-$  broja  $|B|$  je

$$|B|_- := m'_- \cdot 2^{e'} < |B|.$$

Njegova **karakteristika** se dobiva direktno iz eksponenta  $e'$ .

## **Primjer — Prikazivi manji susjed** $|B|_- = +0$

Primjer. Može se dogoditi da je  $|B|_- = +0$ , iako je  $|B| > 0$ . To se događa **ako i samo ako** je

$$0 < |B| < v_{\min}^d,$$

gdje je  $v_{\min}^d \in \mathbb{D}(t, w)$  **najmanji pozitivni denormalizirani broj**.

Ranije smo pokazali da je  $v_{\min}^d = 2^{-t} \cdot 2^{e_{\min}}$ . Ako je  $|B| < v_{\min}^d$ , onda je broj sigurno **premali** za normalizirani prikaz. Nakon denormalizacije broja  $|B|$  na eksponent  $e_{\min}$ , dobivamo

$$|B| = m' \cdot 2^{e_{\min}}, \quad 0 < m' < 2^{-t}, \quad b_0 = 0.$$

Onda je

$$m' = m'_r = (0.\underset{1}{0}00\dots\underset{t}{0}00\dots)_2,$$

odakle odmah slijedi  $(m'_r)_- = m'_- = 0$ , pa je  $|B|_- = +0$ .

## Prikazivi veći susjed $|B|_+$ za $|B|$

Za zaokruživanje nagore koristimo ocjenu druge sume **odozgo**

$$\sum_{i=t+1}^{\infty} b_{-i} \cdot 2^{-i} < 2^{-t}.$$

Zaokruživanje  $m'_r$  nagore na  $t$  mesta iza binarne točke odgovara povećanju “zadnjeg prikazivog” bita  $b_{-t}$  za 1, pa je

$$(m'_r)_+ := \sum_{i=1}^t b_{-i} \cdot 2^{-i} + 2^{-t} > m'_r.$$

Nakon ovog **zbrajanja**, može se dogoditi da je  $(m'_r)_+ = 1$ , pa

❸ ovaj broj  $(m'_r)_+$  više **nije signifikand** prikazivog broja.

Zato mu ne pišemo znamenke u bazi 2. Međutim,  $(m'_r)_+$  je uvijek **egzaktno** prikaziv pa nastavljamo konstrukciju.

## Prikazivi veći susjed $|B|_+$ za $|B|$ (nastavak)

Analogno ranijem, pripadna “mantisa” broja  $|B|_+$  je

$$m'_+ := b_0 + (m'_r)_+ > m'.$$

Na kraju, najблиži prikazivi veći susjed  $|B|_+$  broja  $|B|$  je

$$|B|_+ := m'_+ \cdot 2^{e'} > |B|.$$

Ako je  $(m'_r)_+ = 1$ , onda je  $m'_+ = b_0 + 1$ , pa su brojevi  $m'_+$  i  $|B|_+$  uvijek egzaktno prikazivi.

Posebno, ako dobijemo da je  $m'_+ = 2$ , onda broj  $|B|_+$  treba dodatno normalizirati povećanjem eksponenta za 1

$$|B|_+ = 1 \cdot 2^{e'+1},$$

i tad se može dogoditi da je  $|B|_+ = +\text{Inf.}$

## **Primjer — Gornji razlomljeni dio** $(m'_r)_+ = 1$

**Primjer.** Nađimo za koje brojeve  $|B| > 0$  se dobiva da je  $(m'_r)_+ = 1$ , odnosno,  $m'_+ = b_0 + 1$ .

To znači da u razlomljenom dijelu  $m'_r$  broja  $|B|$

• povećanjem “zadnjeg prikazivog” bita  $b_{-t}$  za 1 dobivamo broj koji je veći od 1, ili

$$1 = (m'_r)_+ = \sum_{i=1}^t b_{-i} \cdot 2^{-i} + 2^{-t} > m'_r > \sum_{i=1}^t b_{-i} \cdot 2^{-i}$$

pa je  $m'_r > 1 - 2^{-t}$ .

$$m'_r > 1 - 2^{-t} = (0.\overset{\uparrow}{1}\underset{1}{1}\underset{t}{1}\dots\underset{1}{1})_2.$$

# *Primjer — Renormalizacija većeg susjeda $|B|_+$*

## **Primjer — Prikazivi veći susjed $|B|_- = +\text{Inf}$**

Primjer. Može se dogoditi da je  $|B|_+ = +\text{Inf}$ , iako je  $|B|$  unutar raspona za normalizirani prikaz.

# *Nalaženje brojeva $|B|_-$ i $|B|_+$ iz $|B|$ (nastavak)*

# Zaokruživanje realnih brojeva — komentar (!)

Napomena. Binarne znamenke brojeva  $m'$  i  $m'_r$  ne znamo!

Provjeru imamo li  $m'$  ili  $m'_r$  više od  $t$  binarnih znamenki iza binarne točke treba napraviti

- nekim algoritmom koji radi samo s brojevima.

Na primjer, formiramo realni broj  $m'_r \cdot 2^t$  i njegovo “najveće cijelo”, a zatim provjeravamo razliku  $m'_r \cdot 2^t - \lfloor m'_r \cdot 2^t \rfloor$ .

Umjesto  $m'_r$ , možemo to isto napraviti i s brojem  $m'$  (samo je  $m' \cdot 2^t$  malo veći).

## Zaokruživanje realnih brojeva — zadatak (!)

**Zadatak.** Dokažite da kod zaokruživanja razlomljenog dijela  $m'_r$  broja  $|B|$  nadolje i nagore na  $t$  mesta iza binarne točke vrijede formule

$$(m'_r)_- = \lfloor m'_r \cdot 2^t \rfloor \cdot 2^{-t}, \quad (m'_r)_+ = \lceil m'_r \cdot 2^t \rceil \cdot 2^{-t}.$$

Obje formule uključuju i slučaj da je  $|B|$  egzaktno prikaziv, što je ekvivalentno s tim da je  $m'_r \cdot 2^t$  cijeli broj.

## Greške zaokruživanja (nastavak) — staro

Za početak, ako je  $B = 0$  onda je  $f\ell(B) = +0 \in \mathbb{D}(t, w)$  i tu nema nikakve greške zaokruživanja.

Pogledajmo sad razlomljeni dio broja  $m'$

$$m'_r = \sum_{i=1}^{\infty} b_{-i} \cdot 2^{-i}.$$

Tu imamo dvije mogućnosti, ovisno o broju znamenki u  $m'$ .

Ako  $m'_r$  ima najviše  $t$  binarnih znamenki, onda je

- broj  $B$  egzaktno prikaziv u računalu, pa je  $f\ell(B) = B$ , tj. zaokruživanje nije potrebno (nema greške).

Karakteristika i signifikand od  $B$  dobivaju se odmah iz  $e'$  i  $m'$ .

Ako  $m'_r$  ima više od  $t$  binarnih znamenki, onda

- broj  $B$  nije egzaktno prikaziv u računalu, pa dolazi do zaokruživanja (i pripadne greške).

# Zaokruživanje realnih brojeva — komentar (!)

Napomena. Binarne znamenke brojeva  $m'$  i  $m'_r$  ne znamo!

Provjeru imamo li  $m'$  ili  $m'_r$  više od  $t$  binarnih znamenki iza binarne točke treba napraviti

- nekim algoritmom koji radi samo s brojevima.

Na primjer, formiramo realni broj  $m'_r \cdot 2^t$  i njegovo “najveće cijelo”, a zatim provjeravamo razliku  $m'_r \cdot 2^t - \lfloor m'_r \cdot 2^t \rfloor$ .

Umjesto  $m'_r$ , možemo to isto napraviti i s brojem  $m'$  (samo je  $m' \cdot 2^t$  malo veći).

## Primjer

Primjer. Recipročna vrijednost  $1/v_{\max}$  najvećeg pozitivnog normaliziranog broja

- nije egzaktno prikaziva — zaokruživanjem dobivamo denormalizirani broj.

$$\begin{aligned}v_{\max} &= (1.\underset{1}{\overset{\uparrow}{1}}\underset{t}{\overset{\uparrow}{1}}1\dots111)_2 \cdot 2^{e_{\max}} \\&= (1 + (1 - 2^{-t})) \cdot 2^{e_{\max}} = 2(1 - 2^{-t-1}) \cdot 2^{e_{\max}} \\&= (1 - 2^{-p}) \cdot 2^{e_{\max}+1} = (1 - 2^{-p}) \cdot 2^{2^{w-1}}.\end{aligned}$$