

Sisteme de numerație

F.Boian, Bazele matematice ale calculatoarelor, UBB Cluj-Napoca, 2002

Sistem de numerație - totalitatea regulilor folosite pentru scrierea numerelor cu ajutorul unor simboluri (cifre).

1. Sistemul de numerație roman

- sistem aditiv

Cifre:

I	V	X	L	C	D	M
1	5	10	50	100	500	1000

Reguli:

a) mai multe cifre de aceeași valoare, scrise consecutiv, reprezintă suma acestor cifre:

$$XX=20 \quad MMM=3000$$

b) o pereche de cifre diferite, cu cifra mai mare aflată în fața cifrei mai mici, reprezintă suma acestor cifre:

$$XIII=10+3=13 \quad VII=5+2=7 \quad DX=500+10=510$$

c) o pereche de cifre diferite, cu cifra mai mică în fața cifrei mai mari, reprezintă diferența acestor cifre:

$$IV=5-1=4 \quad IX=10-1=9 \quad IL=50-1=49$$

d) pentru scrierea unor numere mai mari se folosește o bară orizontală deasupra simbolurilor, bară care indică înmulțirea valorii corespunzătoare simbolului cu 1000

$$\overline{V} = 5000$$

Dezavantaje:

- ✚ scriere greoaie
- ✚ reprezentări multiple ale numerelor (ex: 490=CDXC=XD)
- ✚ numere lungi
- ✚ operații lente
- ✚ nu există simbol pentru valoarea zero

Exemple

$$1989=MCMLXXXIX \quad 2010=M M X$$



Palatul Josika (Casa cu picioare) este înălțat pe locul fostei reședințe clujene a principilor Transilvaniei. Clădirea a devenit reședința lui Anton Josika, comite al Clujului, la mijlocul secolului al XVIII-lea. Clădirea în stil neoclasicist a căpătat înfățișarea de astăzi în anul 1828, când a fost refăcută de Josika Janos, guvernator al Transilvaniei. Elementul caracteristic în fațadă este porticul sobru cu coloanele dorice. Atica poartă inscripția MDCCCXXVIII (1828), anul renovării clădirii.

2. Sistemul de numerație arab

- sistem pozițional

Aportul unei cifre în stabilirea valorii unui număr depinde de valoarea cifrei și de poziția ocupată în șirul de cifre folosit.

Regulă:

- Fiecare grup de 10 elemente (unități, zeci, sute, etc.) formează o grupă de rang superior (zece, sută, mie, etc.)

Sistemul de numerație cu baza 10 (zecimal)

Cifre: 0 1 2 3 4 5 6 7 8 9

Sistemul de numerație octal - baza 8

cifre: 0 1 2 3 4 5 6 7

Sistemul de numerație binar - baza 2

cifre: 0 1

Sistemul de numerație hexazecimal - baza 16

cifre: 0 1 2 3 4 5 6 7 8 9 A (=10)
B(=11) C(=12) D(=13) E(=14) F(=15)

Reprezentarea numerelor naturale într-o bază oarecare b

Orice număr natural x poate fi scris sub forma:

$$x = c_0 + c_1b + c_2b^2 + \dots + c_{n-1}b^{n-1} + c_nb^n$$

unde $c_i < b$, $i=0,1,\dots,n$ se numesc cifrele numărului în baza b.

Exemple:

$$\text{Numărul } (\overline{xyz})_b = z \cdot b^0 + y \cdot b^1 + x \cdot b^2$$

$$(271)_{10} = 1 + 7 \cdot 10 + 2 \cdot 100$$

Conversia dintr-o bază oarecare b în baza 10

$$(1101)_2 = 1 \cdot 2^0 + 0 \cdot 2 + 1 \cdot 2^2 + 1 \cdot 2^3 = 13$$

$$(A3C)_{16} = 12 \cdot 16^0 + 3 \cdot 16 + 10 \cdot 16^2 = 2620$$

Pentru transformarea unui număr dintr-o bază oarecare b în baza 10 se înmulțește ultima cifră a numărului cu baza la puterea 0, penultima cifră se înmulțește cu baza la puterea a 1-a, antepenultima cu baza la puterea a 2-a, etc. și se adună rezultatele acestor înmulțiri.

Pentru a face astfel de transformări trebuie cunoscute cifrele numărului care se transformă. Mai jos este dat ca exemplu un program care determină numărul de cifre ale unui număr natural în baza 10 și valorile cifrelor acestui număr.

Cifrele numărului sunt resturile împărțirii întregi a numărului la baza sistemului de numerație în care este scris. După fiecare împărțire, noul număr care se împarte este câtul împărțirii precedente. Împărțirile continuă până când câtul devine 0.

Program exemplu: determinarea numărului de cifre ale unui număr natural

```
//Determina numarul de cifre ale unui numar natural
//Numarul trebuie sa fie <=32767 (de tip int)
//Cifrele numarului sunt stocate ca elemente ale sirului sirc
#include <stdio.h>
#include <conio.h>
```

```
void main()
{
    int c,r,nr,N,j,sirc[100];
```

```

printf("\nProgramul determina numarul de cifre ale unui numar natural\n");
printf("\nNumarul trebuie sa fie <=32767 (de tip int)\n\n\a");
do
{
    printf("\nIntroduceti un nr pozitiv: ");
    scanf("%d",&nr);
}
while(nr<0);

j=0;
do
{
    c=nr/10;
    r=nr-c*10;
    sirc[j]=r;
    nr=c;
    j++;
}
while(nr>0);

N=j-1;
printf("\nNumarul are %d cifre. Sirul format din cifrele sale este\n\t",j);
for(j=N;j>=0;j--)
    printf("\n%d",sirc[j]);
}

```

Pentru determinarea cifrelor zecimale unui număr real se procedează în felul următor:

Fie nr numărul real dat.

1. se determină prima cifră zecimală a numărului ca și
 $cif = [10 * (nr - \text{floor}(nr))]$ //floor returneaza cel mai mare întreg $\leq nr$
//[] – semnifica partea întreaga a numărului
2. $nr = nr * 10$
3. dacă $nr \neq \text{floor}(nr)$ continuă la 1
4. stop

Program exemplu: determinarea numărului de cifre zecimale ale unui număr real

```

//Determina numarul de cifre zecimale ale unui numar real
//si construiesc un sir cu aceste cifre

#include <iostream.h>
#include <stdio.h>
#include <math.h>
#include <conio.h>

void main()
{
    double nr;
    long int j,N,sir[100],cif;

    printf("\nProgramul determina numarul de cifre zecimale ale unui numar real\n");
    printf("si construiesc un sir avand ca elemente cifrele zecimale ale numarului
    dat\n");

    do
    {
        printf("\nIntroduceti un numar real:\t");
        // fflush(stdin);
    }
    while(scanf("%lf",&nr)!=1);

    j=0; // contor pentru sirul care va contine cifrele zecimale ale numarului real

```

```

while(nr!=floorl(nr))
//sau while((nr-floorl(nr))>1e-6)
{
    //determina cifra actuala
    cif=(long int) (10*(nr-floorl(nr)));
    sir[j]=cif;
    nr=nr*10.0;
    j++;
}
N=j;
printf("\nNumarul are %d cifre zecimale, iar sirul format din cifrele sale
este:\n",N);

for(j=0;j<N;j++)
    cout<< sir[j];
getch();
}

```

Conversia din baza 10 în alte baze

24	2				
24	12	2			
0	12	6	2		
	0	6	3	2	
		0	2	1	2
			1	0	0
					1

$$(24)_{10} = (11000)_2$$

256	8		
256	32	8	
0	32	4	8
	0	0	0
		4	

$$(256)_{10} = (400)_8$$

2653	16		
16	165	16	
105	160	10	16
96	5	0	0
93		10	
80			
13			
0			
	5		
		A	

$$(2653)_{10} = (A5D)_{16}$$

Pentru transformarea unui număr natural din baza 10 într-o bază oarecare b se împarte numărul respectiv la bază, obținându-se un cât și un rest mai mic decât b . Apoi se împarte câtul obținut la b obținându-se un nou cât și un nou rest mai mic decât b . Împărțirea continuă până când se obține câtul 0. Cifrele numărului în baza b sunt resturile împărțirilor, citite de la ultimul rest către primul.

Program exemplu: tipărirea unui număr natural în baza 10 introdus de la tastatură, în bazele 10, 8 și 16, folosind specificatorii de tip %d, %o și %x

```

//Tipareste un numar natural introdus de la tastatura
//in bazele 10, 8 si 16
#include <iostream.h>
#include <stdio.h>

void main()
{
    int n;

    cout << "Introduceti un nr. natural n (in baza 10) : ";
    cin >> n;
    cout << "Baza 10: " << n;
    printf("\nBaza 8: %o", n);
    printf("\nBaza 16: %X", n);
}

```

Program exemplu: transformarea unui număr din zecimal în binar

```

//Transforma un numar natural din zecimal in binar

#include <stdio.h>
#include <conio.h>

```

```

void main()
{
    int c,r,nr,i,j,bin[100];
    printf("\nProgramul face transformarea in binar a unui numar natural\n");
    printf("\nNumarul trebuie sa fie <=32767 (de tip int)\n\n\a");
    do
    {
        printf("\nIntroduceti un nr pozitiv:  ");
        scanf("%d",&nr);
    }
    while(nr<0);
    j=0;

    do
    {
        c=nr/2;
        r=nr-c*2;
        bin[j]=r;
        j++;
        nr=c;
    }
    while(nr>0);

    printf("\nNumarul transformat in binar este:\t");
    for(i=j-1;i>=0;i--)
        printf("%d",bin[i]);
}

```

Conversia unui număr real între două baze de numerație

2 pași

1. conversia părții întregi prin metoda împărțirilor succesive
 - se fac împărțiri până când câtul devine zero, iar numărul se obține din șirul resturilor scris în ordine inversă
2. conversia părții fracționare prin metoda înmulțirilor succesive
 - se fac înmulțiri până când:
 - a) - partea de după virgulă devine zero
 - b) - se ajunge la un număr prestabilit de cifre
 - c) - se ajunge la o periodicitate
 - cifrele părții fracționare sunt cifrele care, în urma înmulțirilor succesive, ajung în fața punctului zecimal

Partea fracționară a unui număr scris într-o bază b se poate scrie sub forma:

$$c_{-1}/b + c_{-2}/b^2 + c_{-3}/b^3 + \dots$$

unde c_{-1} este cifra aflată imediat după virgulă, c_{-2} este a doua cifră a părții zecimale, etc.

Exemplu:

Fie numărul 0.369140625 în baza 10 care va fi convertit în baza 8. Vom înmulți mereu părțile fracționare cu 8

0	3	6	9	1	4	0	6	2	5	x	8
2	9	5	3	1	2	5					
7	6	2	5								
5	0										

S-a îndeplinit criteriul a), obținându-se zero după virgulă

Așadar: $(0.369140625)_{10} = (0.275)_8$

Verificare: $(0.275)_8 = \frac{2}{8} + \frac{7}{8^2} + \frac{5}{8^3} = \frac{128+56+5}{512} = \frac{189}{512} = 0.369140625$

Temă: Transformați numărul 0.369140625 în baza 2.

Fie numărul 0.416382 pe care îl vom converti tot în baza 8, reținând numai primele 3 cifre:

0	4	1	6	3	8	2	x	8
3	3	3	1	0	5	6		
2	6	4	8	4	4	8		
5	1	8	7	5	8	4		
.	.	.	.	.	.	.		

Așadar: $(0.416382)_{10} = (0.325...)_{8}$

Convertind acum numărul $(0.325)_8$ în baza 10 obținem:

$$(0.325)_8 = \frac{3}{8} + \frac{2}{8^2} + \frac{5}{8^3} = \frac{192+16+5}{512} = \frac{213}{512} = 0.416015625 \neq 0.416382$$

adică am obținut o eroare de trunchiere. Astfel de erori apar frecvent în cazul conversiilor duble, atunci când se reține un număr prestabilit de cifre semnificative.

Temă: Transformați numărul 0.3741 în baza 2, reținând primele 6 cifre binare apoi faceți transformarea inversă. Care este diferența dintre numărul inițial și cel obținut prin transformarea inversă?

Algoritm pentru conversia părții fracționare dintr-o bază p în altă bază q, prin metoda înmulțirilor succesive:

Fie f partea fracționară. După obținerea cifrei de rang -1 cu relația $c_{-1}=[q \cdot f]$ ($[]$ semnifică partea întreagă) în baza b se efectuează din nou înmulțirea înlocuind pe f cu qf , etc.

1. citește f în baza p
2. $i=0$;
3. dacă $f=0$ sau s-au obținut suficiente cifre continuă la pasul 8
4. $c_i=\text{int}(f \cdot q)$ // partea întreagă a lui $f \cdot q$
5. $f=\text{partea fractionară a lui } f \cdot q$ adică $f = f \cdot q - [f \cdot q]$
6. $i++$
7. continuă la pasul 3
8. $n=i$
9. scrie c_i , $i=0, 1, \dots, n-1$
10. stop

Program exemplu: Conversia părții fracționare a unui număr scris în baza 10 într-o bază oarecare q

```
//Programul converteste partea fractionara a unui numar scris in baza 10
//intr-o alta baza q. Numarul se va introduce sub forma 0.xxxxxxx...

#include <iostream.h>
#include <stdio.h>
#include <math.h>

void main()
{
    double f;
    int i,n, c[20],q,nmax=15,cond;

    cout << "Introduceti partea fractionara a numarului, sub forma: 0.xxxxxxx...:
";
    cin >> f;
```

```

cout << "Noua baza: ";
cin>> q;
i=0;
do
{
    c[i]=floor(f*q);
    f=f*q-floor(f*q);
    i++;
    //Stabilirea conditiei de incheiere: fie f=0, fie s-a
    // ajuns la numarul de cifre impus
    if(f==0.0)
        cond=1;
    else
        if(i==nmax)
            cond=1;
        else cond=0;
}
while(!cond);
n=i;
cout<<"Cifrele partii fractionare in baza " << q << " sunt: ";
for(i=0;i<n;i++)
    cout << c[i];
}

```

Reprezentarea numerelor

Reprezentarea numerelor întregi cu semn în complement față de 2

Definiții

1. Bit - unitatea de informație
2. Byte (octet) - unitatea de adresare (8 biți)
3. Locație de memorie - unitatea de reprezentare a unei date, formată din unul sau mai mulți octeți
4. Word – număr de octeți prelucrați simultan de către procesor (numerele reale se reprezintă de obicei pe un cuvânt) = lățimea de bandă

În memoria computerelor, numerele sunt reprezentate ca și numere binare, pe un anumit număr (finit) de biți. Valorile care pot fi reprezentate depind de numărul de biți folosiți pentru respectiva reprezentare.

Spre exemplu, pe 2 biți poate fi reprezentată valoarea maximă $3 = (11)_2$, iar pe 8 biți poate fi reprezentată valoarea maximă $255 = (11111111)_2$.

Dacă trebuie reprezentate numere întregi cu semn, atunci un bit din numărul total de biți ai reprezentării va fi folosit pentru semnul numărului. Bitul de semn va fi bitul de rang maxim (cel mai din stânga):



În reprezentarea în complement față de 2, un număr pozitiv se reprezintă pe cei n biți, cu bitul de semn 0. Valoarea maximă reprezentabilă pe n biți va fi:

pe patru biți:

0	1	1	1
---	---	---	---

 $(111)_2 = 7 = 2^3 - 1$

pe opt biți:

0	1	1	1	1	1	1	1
---	---	---	---	---	---	---	---

 $(1111111)_2 = 127 = 2^7 - 1$

Așadar, pe n biți, valoarea maximă reprezentabilă este: $2^{n-1} - 1$

În reprezentarea în complement față de 2, numerele negative se obțin scăzând în binar, numărul pozitiv din 2^n . Bitul de semn pentru numerele negative va fi 1.

Așadar, în acest cod, dacă X este pozitiv se reprezintă ca atare pe $n-1$ biți, iar dacă este negativ, se reprezintă valoarea $2^n - |X|$.

Exemplu:

Numărul +18, reprezentat pe 8 biți este:

0	0	0	1	0	0	1	0
---	---	---	---	---	---	---	---

Numărul -18 se obține scăzând din 2^n în binar valoarea +18 în binar (vezi figura de mai jos):

2^8 :	1	0	0	0	0	0	0	0
								-
+18:	0	0	0	1	0	0	1	0
								=
-18:	1	1	1	0	1	1	1	0

Reprezentarea numerelor întregi în complement față de 2

sau același lucru, se scade în zecimal +18 din 2^8 (din 2^8) și se reprezintă rezultatul scăderii în binar:

$$2^8 - 18 = 256 - 18 = 238$$

$$(238)_{10} = (11101110)_2$$

O metodă mai rapidă de deducere a reprezentării numerelor întregi negative în complement față de 2 pe n biți rezultă din discuția precedentă și este dată de următoarea *regulă*:

Pentru a reprezenta în complement față de 2 un număr întreg negativ se reprezintă modulul său după care, începând de la bitul de ordin zero spre stânga toți biții 0 și primul bit 1 se păstrează și toți ceilalți își inversează valoarea (0 $\rightarrow$ 1 și 1 $\rightarrow$ 0).

Acest lucru este echivalent cu faptul că valoarea oricărui număr negativ, cu excepția celui mai mic se obține pornind de la numărul pozitiv reprezentat în binar după care se răstoarnă toți biții (1 $\rightarrow$ 0 și 0 $\rightarrow$ 1), adăugându-se apoi valoarea 1. Analog se procedează pentru a trece de la numărul negativ reprezentat în binar la numărul pozitiv corespunzător (vezi ca exemplu tabelul alăturat).

Valoarea -1 (cel mai mare număr negativ) reprezentată pe n biți se obține setând toți cei n biți pe valoarea 1.

Valoarea celui mai negativ număr pe n biți se obține setând toți biții, cu excepția celui de semn (cel mai reprezentativ bit) pe valoarea 1 și apoi răsturnarea tuturor biților. Astfel se obține numărul negativ al cărui modul este dat de biții astfel obținuți, fără a se ține cont de semn. Implicit rezultă că în cod complementar față de 2, valoarea minimă reprezentabilă pe n biți este -2^{n-1} .

Exemple de reprezentare a numerelor întregi pe 8 biți

0	1	1	1	1	1	1	1	127
0	1	1	1	1	1	1	0	126
...								
0	0	0	0	0	0	1	1	3
0	0	0	0	0	0	1	0	2
0	0	0	0	0	0	0	1	1
0	0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1	-1
1	1	1	1	1	1	1	0	-2
1	1	1	1	1	1	0	1	-3
...								
1	0	0	0	0	0	1	0	-126
1	0	0	0	0	0	0	1	-127
1	0	0	0	0	0	0	0	-128

În schimb, 243.270751953125 are reprezentarea binară (11110011,010001010101) și partea întreagă a numărului este mai mare decât valoarea maximă reprezentabilă pe cei 6 biți alocați părții întregi. Astfel, acest număr se va reprezenta sub forma:

0	1	1	0	0	1	1	0	1	0	0	0	1	0	1	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

producându-se o așa-numită depășire, adică pierzându-se 2 biți cei mai semnificativi, numărul reprezentat fiind de fapt 51. 270751953125.

Reprezentarea în virgulă mobilă a numerelor reale este un tip superior de reprezentare, astfel concepută încât la depășire se pierd cifrele cele mai puțin semnificative. Această reprezentare se bazează pe faptul că orice număr real x se poate scrie sub forma:

$$x = \pm 0.m \cdot b^e$$

unde m este mantisa numărului, b este baza de numerație, iar e este exponentul.

În notația științifică, numerele reale se notează sub forma:

$$\pm \text{mantisa} \cdot \text{baza}^{\text{exponent}}$$

Exemple:

Valoare reală	Notație științifică
125,7323	$1.257323 \cdot 10^2$
-10,375	$-1.0375 \cdot 10^1$
-0,00642	$-6.42 \cdot 10^{-3}$

Scrierea valorilor reale sub forma $x = \pm 0.m \cdot b^e$ este o scriere cu mantisă subunitară, în baza 10. Orice valoare reală poate fi scrisă însă și sub forma:

$$x = \pm 1.m \cdot 2^e$$

care înseamnă scrierea numărului în baza 2, cu mantisă între 1 și 2, m fiind partea fracționară a mantisei.

Valorile date mai sus ca exemplu se scriu în baza 2 sub următoarea formă:

Zecimal	Binar	Semn
125,7323	1111101.101110110111	+
-10,375	1010.011	-
-0,00642	0.00000001101001001	-

Zecimal	Reprezentarea cu mantisă între 1 și 2
125,7323	$1.111101101110110111 \cdot 2^6$
-10,375	$-1.010011 \cdot 2^3$
-0,00642	$-1.101001001 \cdot 2^{-8}$

Astfel, din exemplele de mai sus rezultă că pentru reprezentarea valorilor reale în virgulă flotantă trebuie folosit un anumit număr de biți, care să permită reprezentarea:

- semnului numărului
- mantisei
- exponentului
- semnului exponentului

Pentru aceasta, se folosește standardul IEEE (**I**nstitute of **E**lectrical and **E**lectronics **E**ngineers), pentru reprezentarea numerelor în simplă precizie (pe 32 biți) sau în dublă precizie (pe 64 biți).

Bitul de semn:

- 0 corespunde unui număr pozitiv și 1 corespunde unui număr negativ

Exponential

Pe numărul de biți rezervați pentru exponent trebuie reprezentate atât numere pozitive cât și negative. În acest scop, exponentului propriu-zis al numărului care se reprezintă i se adaugă o anumită valoare care depinde de tipul de precizie folosită (simplă sau dublă), numită caracteristică. În standardul IEEE simplă precizie aceasta are valoarea de 127 (2^7-1) și în dublă precizie are valoarea 1023 ($2^{10}-1$). Astfel, pentru un număr al cărui exponent este 0, pe biții alocați exponentului se stochează valoarea 127 (în binar 01111111).

O valoare de 200 (în binar 11001000) stocată pe biți exponențului înseamnă de fapt exponențului $200-127=73$.

Exponenții cu toți biții 0 sau toți biții 1 sunt rezervați pentru numere speciale.

Pentru standardul dublă precizie se alocă 11 biți pentru exponent, iar caracteristica este 1023.

Mantisa

Mantisa reprezintă biții de precizie ai unui număr. Aceasta este compusă dintr-un bit implicit principal (întotdeauna 1 în scrierea cu mantisă între 1 și 2) și biții fracției.

Pentru a afla bitul implicit principal se ține cont de faptul că în notația științifică orice număr poate fi reprezentat în mai multe feluri. Astfel, numărul 5 poate fi reprezentat într-unul din modurile următoare:

$$\begin{array}{l} 5.00 \cdot 10^0 \\ 0.05 \cdot 10^2 \\ 5000 \cdot 10^{-3} \end{array}$$

În scopul maximizării cantității de numere reprezentabile, numerele floating point sunt stocate în formă normalizată, formă care se obține punând punctul zecimal după prima cifră nenulă. În formă normalizată, numărul 5 este reprezentat sub forma: $5 \cdot 10^0$. În baza 2, singura cifră nenulă nu poate fi alta decât cifra 1, astfel încât nu este necesar ca ea să fie reprezentată explicit și în simplă precizie de exemplu, toți cei 23 de biți sunt folosiți pentru reprezentarea părții fracționare a mantisei, obținându-se practic o precizie de 24 biți folosind doar 23 de biți.


In zecimal, precizia corespunzătoare obținută este:

$$\frac{24}{\log_2 10} = 7.2 \text{ adică de 7 cifre în simplă precizie și}$$

$$\frac{52}{\log_2 10} = 15.65 \text{ adică } 15 \text{ cifre în dublă precizie.}$$

Astfel, în simplă precizie, cei 32 biți alocați reprezentării unui număr în virgulă flotantă sunt:

- 1 bit pentru semnul mantisei (bitul de rang 31)
- 8 biți pentru exponent (care va include și semnul exponentului, biții de rang 23-30)
- 23 de biți pentru mantisă (biții de rang 0-22)



În cazul reprezentării cu mantisă între 1 și 2, cifra 1 din stânga virgulei nu are bit rezervat, cifra adăugându-se numai în timpul calculelor.

nr.biți[rangul biților]	Semn	Exponent	Fracție	Caracteristică
Simplă precizie	1 [31]	8 [30-23]	23 [22-00]	127
Dublă precizie	1 [63]	11 [62-52]	52 [51-00]	1023

Valoarea V reprezentată pe un astfel de cuvânt de 32 biți se obține în felul următor (E reprezintă e +caracteristica):

- Dacă $0 < E < 255$ atunci $V = (-1)^S \cdot 2^{E-127} \cdot 1.F$ unde "1.F" reprezintă numărul binar creat prin adăugarea la partea fracționară a părții întregi 1.
- Dacă $E = 255$ (toți biții exponentului sunt setați pe valoarea 1) și F este nenul, atunci $V = \text{NaN}$ ("Not a number")
- Dacă $E = 255$ (toți biții exponentului sunt setați pe valoarea 1), F este nul și $S = 1$, atunci $V = -\infty$
- Dacă $E = 255$ (toți biții exponentului sunt setați pe valoarea 1), F este nul și $S = 0$, atunci $V = +\infty$
- Dacă $E = 0$ (toți biții exponentului sunt 0), F este zero (toți biții părții fracționare sunt 0) și $S = 1$, atunci $V = -0$
- Dacă $E = 0$ (toți biții exponentului sunt 0), F este zero (toți biții părții fracționare sunt 0) și $S = 0$, atunci $V = +0$

Așadar, ca reguli sunt stabilite reprezentările pentru valoarea zero, precum și pentru valorile $\pm\infty$ și respectiv pentru "valorile NaN.

În figura de mai jos sunt date câteva valori reprezentate în virgulă flotantă în standardul IEEE simplă precizie.

Exemplu de valori reprezentate în simplă precizie

Valoare în zecimal	bitul de semn	exponentul $E=e+c$	fracția rezultată din mantisă normalizată
	1 bit	8 biți	23 biți
7/4	0	0 1 1 1 1 1 1 1	1 1 0
-34.432175	1	1 0 0 0 0 1 0 0	0 0 0 1 0 0 1 1 0 1 1 1 0 1 0 1 0 0 0 1 1 0 0
-959818	1	1 0 0 1 0 0 1 0	1 1 0 1 0 1 0 0 1 0 1 0 1 0 0 1 0 1 0 0 0 0 0
+ 0	0	0 0 0 0 0 0 0 0	0 0
- 0	1	0 0 0 0 0 0 0 0	0 0
cel mai mic număr reprezentabil	0	0 0 0 0 0 0 0 0	0 1
cel mai mare număr reprezentabil	0	1 1 1 1 1 1 1 0	1 1
infini	0	1 1 1 1 1 1 1 1	0 0
NaN	0	1 1 1 1 1 1 1 1	Nu toți biții 0 sau 1

	Simplă precizie	Dublă precizie
Cel mai mic nr. pozitiv	2^{-126} sau 1.175×10^{-38}	2^{-1022} sau 2.225×10^{-308}
Cel mai mare nr. pozitiv	$(2 - 2^{-23}) 2^{127}$ sau 3.403×10^{38}	$(2 - 2^{-52}) 2^{1023}$ sau 1.798×10^{308}
Valoarea ϵ a mașinii	2^{-23} sau 1.192×10^{-7}	2^{-52} sau 2.220×10^{-16}
Precizia zecimală	6 cifre semnificative	15 cifre semnificative

Cel mai mic număr real pozitiv care poate fi reprezentat în simplă precizie are reprezentarea:

0 00000001 000000000000000000000000000000000000

care înseamnă: $1.0 \cdot 2^e$.

Partea fracționară este zero deoarece toți cei 23 de biți folosiți pentru reprezentarea acesteia sunt setați pe zero. La partea fracționară se adaugă partea întreagă corespunzătoare bitului "ascuns" 1 (care nu se reprezintă în acest format simplă și dublă precizie).

Valoarea exponentului e se deduce ținând cont că pe biții exponentului este reprezentată valoarea $e+127$. Cum E este $(00000001)_2 = 1_{10}$, rezultă $e=-126$. Așadar, valoarea celei mai mici valori reale care poate fi reprezentată este:

$$1.0 \cdot 2^{-126} = 1.175494351 \cdot 10^{-38}$$

Analog se deduce ușor valoarea celui mai mare număr real care poate fi reprezentat în simplă precizie, aceasta având reprezentarea binară:

0 11111110 111111111111111111111111111111111111

Atenție, nu putem folosi toți biții exponentului setați pe 1 deoarece acest caz este utilizat pentru reprezentarea valorilor speciale $\pm\infty$ și Nan.

Din reprezentarea de mai sus rezultă că $E=2^8-1-1=2^8-2$, adică $e=2^8-2-127=2^8-2-2^7-1=2(2^7-1)-2^7-1=2^7-1=127$.

A, această valoare va fi: $(1.111111111111111111111111111111111111)_2 \cdot 2^{127}$.

Valoarea părții fracționare este: $2^{-1}+2^{-2}+\dots+2^{-23} =$

$$S_n = b_1 \cdot (1 + q + q^2 + \dots + q^{n-1}) = b_1 \cdot (q^n - 1) / (q - 1), \text{ dacă } q \neq 1, \text{ altfel } S_n = n \cdot b_1.$$

$$= 2^{-1} \cdot (2^{-23}-1)/(2^{-1}-1) = 1-2^{-23}$$

Așadar, cel mai mare număr pozitiv reprezentabil este:

$$(1+1-2^{-23}) \cdot 2^{127} = 3.402823467 \cdot 10^{38}$$

Precizia reprezentării numerelor este dată de următoarele exemple:

Valoarea 1.0 se reprezintă:

0 01111111 000000000000000000000000000000000000

Următoarea valoare reprezentabilă, imediat mai mare ca 1.0 va avea reprezentarea:

0 01111111 000000000000000000000000000000000001

Diferența dintre aceste valori este dată de prezența pe poziția cel mai puțin semnificativă din biții mantisei, a bitului 1. Poziția și valoarea acestui bit înseamnă în zecimal valoarea 0.0000001192. Această valoare dă precizia acestei reprezentări. Așadar, în acest format, numerele reale nu sunt reprezentate continuu ci discret, cu un pas de $1.1192 \cdot 10^{-7}$.

Valoarea "Not A Number"

Valoarea NaN este folosită pentru a reprezenta valori care nu reprezintă un număr real. Aceste valori NaN sunt reprezentate printr-o succesiune de biți cu exponentul având toți biții 1 și o fracție nenulă.

Există două feluri de valori Nan: QNaN (Quiet NaN) și SNaN (Signalling NaN).

QNaN este un NaN cu cei mai semnificativi biți ai fracției setați și rezultă din operații aritmetice când rezultatul matematic nu este definit.

SNaN este un NaN cu cei mai semnificativi biți a fracției șterși și astfel de valori sunt folosite pentru a semnaliza excepții. Semantic, QNaN semnifică operație nedeterminată, iar SNaN semnifică operație invalidă.

Exemplu:

Care va fi reprezentarea numărului -10.375, în virgulă flotantă, simplă precizie?

1. Numărul pozitiv se transformă în binar și se obține: 1010.011
2. Se scrie numărul obținut în binar sub formă normalizată: $1.010011 \cdot 2^3$
3. Se determină valoarea exponentului: $3+127=130$
4. Se transformă noul exponent în binar: $(130)_{10}=10000010$
5. Se determină bitul de semn al mantisei: 1
6. Se scrie numărul:

[illegible]

Observație: Numărul real 18.0 nu are reprezentare identică cu cea a numărului întreg 18.