

ARCHI – Architecture des ordinateurs

Sylvain Brandel

2025 – 2026

sylvain.brandel@univ-lyon1.fr

Partie 3

CODAGE DES DONNÉES EN MACHINE

Codage des entiers

Codage des nombres rationnels

Information

- (Transistors : plus tard)
- Détection de **deux états**
 - Haut $\geq$ réf. haute
 - Bas $\leq$ réf. basse
- Physique : différence de 1V (ordre de grandeur)
- Convention
 - L'un : 0
 - L'autre : 1
- Représentation **binaire**
 - bit
 - Par mots de 4 bits : représentation hexadécimale
 - Mot de 8 bits : octet (Byte)
 - Mb : Mega bit MB : Mega Byte

Codage des entiers naturels

Notation positionnelle

- $\beta \in \mathbb{N}, \beta > 1$: **base**
- **Représentation positionnelle en base β** de $n \in \mathbb{N}$:

$$(x_{p-1}x_{p-2} \dots x_1x_0)_\beta := \sum_{i=0}^{p-1} x_i \beta^i$$

- $x_i \in \{0, 1, \dots, \beta - 1\}$: **chiffres** de l'écriture de n en base β
 - $\beta = 2$: chiffres 0 et 1
 - $\beta = 10$: chiffres de 0 à 9
 - $\beta = 16$: **chiffres** de 0 à F
- p : nombre de chiffres nécessaires pour écrire n
- Ex : $(5134)_{10} = 5 \cdot 10^3 + 1 \cdot 10^2 + 3 \cdot 10^1 + 4 \cdot 10^0$

Codage des entiers naturels

Changement de base

- Avec notation positionnelle
- $\beta \in \mathbb{N}, \beta > 1$: base de départ, $\gamma \in \mathbb{N}, \gamma > 1$: base d'arrivée
- Toujours possible :
 - Conversion x_i et β vers écriture en base γ
 - Calcul de $\sum_{i=0}^{p-1} x_i \beta^i$ avec opérations en base γ
- Ecriture de n en base γ : calcul dans la base d'arrivée γ
- Ex : Conversion **binaire vers décimal** de $n = (10100)_2$:
 - Ajout des puissances de 2 correspondant aux bits non nuls

Chiffre	1	0	1	0	0
Position	4	3	2	1	0
Poids	2^4	0	2^2	0	0

- Donc $(10100)_2 = 2^4 + 2^2 = 20$
- Ex : Conversion **décimal vers binaire** de $n = (95)_{10}$ et $(423)_{10}$

Codage des entiers naturels

Changement de base

- Avec **divisions euclidiennes successives**
- Reste de la division euclidienne de n par β :
 - Chiffre de poids faible dans l'écriture de n en base β

$$\begin{aligned} n &= x_{p-1}\beta^{p-1} + x_{p-2}\beta^{p-2} + \dots + x_2\beta^2 + x_1\beta^1 + x_0 \\ &= \underbrace{(x_{p-1}\beta^{p-2} + x_{p-2}\beta^{p-3} + \dots + x_2\beta^1 + x_1)}_{\text{quotient}} \beta + \underbrace{x_0}_{\text{reste}} \end{aligned}$$

avec $0 \leq x_0 \leq \beta$

- En d'autres termes, $n \bmod \beta = x_0$
 - Les chiffres de n sont obtenus par divisions euclidiennes successives
 - Arrêt au premier quotient nul. Chiffres de poids faible d'abord !
- Ex : Conversion **décimal vers binaire** de $(95)_{10}$ et $(423)_{10}$
- Ex : Conversion **décimal vers octal** de $(3452)_{10}$

Codage des entiers naturels

Changement de base

- Entre bases 2, 8, 16 : **conversions directes**
- $8 = 2^3 \rightarrow$ chiffre octal : entier sur trois bits

$$(x_8x_7x_6x_5x_4x_3x_2x_1x_0)_2 = \underbrace{(x_8x_7x_6)_2}_{y_2} 8^2 + \underbrace{(x_5x_4x_3)_2}_{y_1} 8^1 + \underbrace{(x_2x_1x_0)_2}_{y_0} 8^0 = (y_2y_1y_0)_8$$

- Ex : Conversion **octal vers binaire** de $(34521)_8$
- Ex : Conversion **hexadécimal vers binaire** de $(9A6E)_{16}$

Entiers naturels

Représentation *machine*

- Nombre de bits p fixé pour chaque format de codage (8, 16, 32, 64)
- Si résultat sur plus de p bits :
 - Obtenu : p bits de poids faible du résultat exact
 - Drapeau de dépassement de capacité de l'UAL
- Les calculs continuent !
- m codé sur $q \geq p$ bits

$$m = \sum_{i=0}^{q-1} m_i 2^i = \underbrace{\left(\sum_{i=p}^{q-1} m_i \right) 2^p}_{\text{quotient de } m \text{ par } 2^p} + \underbrace{\sum_{i=0}^{p-1} m_i 2^i}_{\text{reste}}$$

- Opération arithmétique sur entiers naturels
 - Résultat m placé sur p bits
 - Du coup résultat obtenu : $m \bmod 2^p$

Codage des entiers relatifs

- Mots de n bits $\rightarrow$ différents états $w = b_{n-1} \dots b_2 b_1 b_0$
- Non signés :
 - Notation positionnelle : $\llbracket w \rrbracket = \sum_{i=0}^{n-1} b_i 2^i$
- Signés :
 - Signe + valeur absolue : $\llbracket w \rrbracket = (-1)^{b_{n-1}} \sum_{i=0}^{n-2} b_i 2^i$
 - Complément à 1 : $\llbracket v \rrbracket = -\llbracket w \rrbracket = \overline{b_{n-1}} \dots \overline{b_2} \overline{b_1} \overline{b_0}$
 - Complément à 2 : $\llbracket w \rrbracket = -b_{n-1} 2^{n-1} + \sum_{i=0}^{n-2} b_i 2^i$
 - Biais N : $\llbracket w \rrbracket = \sum_{i=0}^{n-1} b_i 2^i - N$

Codage des entiers relatifs

Complément à 2

- n entier relatif, $-2^{p-1} \leq n \leq 2^{p-1} - 1$, à coder sur p bits
- Notation en complément à 2 sur p bits

$$n = (c_{p-1}c_{p-2} \dots c_1c_0)_2$$

$$(c_{p-1}c_{p-2} \dots c_1c_0)_2 := -c_{p-1}2^{p-1} + \sum_{i=0}^{p-2} c_i 2^i$$

- Propriétés :
 - $n \geq 0$ ssi $c_{p-1} = 0$
 - $n \leq 0$ ssi $c_{p-1} = 1$

Codage des entiers relatifs

Complément à 2

- Interprétation
 - Considérer le bit le plus à gauche de **poids négatif** (-2^{p-1})

- Ex : $p = 8$, **valeur décimale** codée par $(10000011)_2$

$$(10000011)_2 = -128 + 3 = (-125)_{10}$$

- Ex : $p = 8$, coder $(-120)_{10}$ en **complément à 2**

$$(-120)_{10} = -128 + 8 = (10001000)_2$$

Entiers relatifs

Complément à 2

- $m = (c_m)_{\bar{2}}$ et $n = (c_n)_{\bar{2}}$ en complément à 2 sur p bits
- Addition
 - Sans dépassement : codage de $m + n = \text{codage de } (c_m + c_n) \bmod 2^p$ en tant qu'**entier naturel**
 - Avec dépassement : résultat faux
 - Dépassement
 - m et n de signes opposés : dépassement impossible
 - m et n de même signe : dépassement ssi signe résultat $\neq$ signe de n
- Opposé
 - Sans dépassement : codage de $-n$ en complément à 2 sur p bits
$$(\overline{c_{p-1}} \dots \overline{c_1} \overline{c_0})_2 + 1 \bmod 2^p$$
comme **entier naturel**
- Ex : $p = 7$, $(36)_{10} = (0100100)_{\bar{2}}$ $(-36)_{10} = (1011100)_{\bar{2}}$

Rationnels

- Nombre de la forme $\frac{p}{q}$ avec $p \in \mathbb{Z}$ et $q \in \mathbb{N} - \{0\}$
- Format de longueur fixe là où écriture binaire potentiellement infinie
→ Approximation
- Tout $x \in \mathbb{Q}$ positif décomposé en
 - Partie entière $[x] \in \mathbb{N}$ telle que $[x] \leq x < [x] + 1$
 - Partie fractionnaire $\{x\} = x - [x]$ avec $0 \leq \{x\} < 1$

- Notation positionnelle pour l'écriture de $\{x\}$: s'il existe $q \in \mathbb{N}$ tq

$$\{x\} = (0, x_{-1} \dots x_{-q})_{\beta} = \sum_{i=0}^q x_{-i} \beta^{-i}$$

- Alors $(x_{p-1} \dots x_1 x_0, x_{-1} \dots x_{-q})_{\beta}$ écriture de x en base β
- Écriture en base β pas forcément finie mais forcément périodique
- Ex : $\beta = 10$, écriture de $13/7$ en notation partie entière - fractionnaire

$$13/7 = (1, \underline{857142})_{10}$$

Rationnels

Changement de base

- $0 \leq x < 1$ écrit en base 10

- Décimal vers binaire

$$x = (0, x_{-1} \dots x_{-q})_2$$

– Or $2 \times x = (x_{-1}, x_{-2} \dots x_{-q})_2$, donc $x_{-1} = \lfloor 2 \times x \rfloor$

- Multiplications successives par 2

→ extraction bits écriture binaire de x

- Ex : Convertir $1/10 = (0,1)_{10}$ en écriture binaire

$$(0,1)_{10} = (0, \underline{00011})_2$$

Rationnels

Changement de base

- $0 \leq x < 1$ écrit en base 2
- Binaire vers décimal
- Multiplications successives par $(10)_{10} = (1010)_2$
→ en calculant en binaire : chiffres décimaux de x
- Fastidieux à la main
- Si pas trop de bits, il suffit d'additionner les poids de ces bits :
 - $2^{-1} = 0,5$ $2^{-2} = 0,25$ $2^{-3} = 0,125$ $2^{-4} = 0,0625$
- Ex : Convertir $(0,1011)_2$ en **écriture décimale**

$$0,5 + 0,125 + 0,0625 = 0,6875$$

Rationnels

Représentation en machine ?

- On n'a pas réellement les rationnels
- Un **nombre flottant normalisé** x est
 - Soit zéro
 - Soit un rationnel de la forme $x = (-1)^s \times \underbrace{(1, b_1 \dots b_{p-1})_2}_{p \text{ bits de précision } (b_0 = 1)} \times 2^e$
 - $s \in \{0,1\}$: signe
 - $(1, b_1 \dots b_{p-1})_2$: mantisse fractionnaire
 - $e \in \mathbb{Z}$: exposant tel que $e_{\min} \leq e \leq e_{\max}$
- On parle de **nombre à virgule flottante**, ou **nombre flottant**, ou **flottant**
- Le **1**, en tête garantit l'unicité de la représentation
- Types `float` et `double` en C

Nombres à virgule flottante

- On ne les a pas tous !
- P. ex $(0,1)_{10}$ pas dans l'exemple suivant ...
- Ex : flottants ≥ 0
avec 3 bits de précision,
 $e_{\min} = -1$, $e_{\max} = 2$
 $-1 \leq e \leq 2$

e	Binaire	Décimal
-	0	0
e = -1	$(1,00)_2 \times 2^{-1}$ $(1,01)_2 \times 2^{-1}$ $(1,10)_2 \times 2^{-1}$ $(1,11)_2 \times 2^{-1}$	0,5 0,625 0,75 0,875
e = 0	$(1,00)_2 \times 2^0$ $(1,01)_2 \times 2^0$ $(1,10)_2 \times 2^0$ $(1,11)_2 \times 2^0$	1 1,25 1,5 1,75
e = 1	$(1,00)_2 \times 2^1$ $(1,01)_2 \times 2^1$ $(1,10)_2 \times 2^1$ $(1,11)_2 \times 2^1$	2 2,5 3 3,5
e = 2	$(1,00)_2 \times 2^2$ $(1,01)_2 \times 2^2$ $(1,10)_2 \times 2^2$ $(1,11)_2 \times 2^2$	4 5 6 7

Nombres à virgule flottante

- Ex : $(0,1)_{10}$ avec 8 bits de précision

- $(0,1)_{10} = (0,00011)_2$
 $= (0,00011001100110011)_2$
 $= (\underbrace{1,1001100110011}_{8 \text{ bits de précision}})_2 \times 2^{-4}$

- On doit tronquer à 7 bits de mantisse

$$\text{Donc } (1,1001100)_2 \times 2^{-4} \leq (0,1)_{10} \leq (1,1001101)_2 \times 2^{-4}$$

- Il faut faire un choix → **arrondi**
 - Le milieu de cet intervalle est $(1,10011001)_2 \times 2^{-4}$
 - Ici on choisit d'arrondir au plus proche
 - $(0,1)_{10}$ est supérieur au milieu de l'intervalle, donc

L'approximation $(0,1)_{10} \approx (1,1001101)_2 \times 2^{-4}$

Nombres à virgule flottante – norme IEEE-754

- Codage en précision p :

$c =$	1 bit	k bits	p-1 bits
	Signe	Code de l'exposant : c_e	Code de la mantisse : c_m

- Pour un flottant **normal**, la valeur codée est

$$f(c) = (-1)^{s(c)} \times m(c) \times 2^{e(c)}$$

- $s(c)$: signe du flottant
- $m(c) = (1, c_m)_2$ (le 1, est implicite)
- $e(c) = (c_e)_2 - (2^{k-1} - 1)$

Nombres à virgule flottante – norme IEEE-754

- Codage en précision p :

$c =$	1 bit	k bits	p-1 bits
	Signe	Code de l'exposant : c_e	Code de la mantisse : c_m

- $(c_e)_2 = 0$ et $(c_m)_2 = 0$: nombre représenté est **zéro** (2 codages)
- $(c_e)_2 = 2^k - 1$: valeur **exceptionnelle** (+Inf, -Inf, NaN)
- $1 \leq (c_e)_2 \leq 2^k - 2$: nombre représenté **normal**, alors

$$m(c) = (1, c_m)_2 \quad \text{et} \quad e(c) = (c_e)_2 - \underbrace{(2^{k-1} - 1)}_{\text{biais}}$$

Nombres à virgule flottante – norme IEEE-754

- Simple précision

- codé sur 32 bits
- type `float` en C)

31	30 ... 23	22 ... 0
Signe	c_e	c_m

- Précision $p = 24$ bits, $k = 8$, biais = 127, $e_{\min} = -126$, $e_{\max} = 127$
- $\llbracket w \rrbracket = (-1)^{b_{31}} \times (1, b_{22} \dots b_1 b_0)_2 \times 2^{(\sum_{i=23}^{30} b_i 2^{(i-23)-127})}$
- Valeurs représentables $[\pm 2^{-126}, (2 - 2^{-23}) \times 2^{127}]$

- Double précision

- codé sur 64 bits
- type `double` en C

63	62 ... 52	51 ... 0
Signe	c_e	c_m

- Précision $p = 53$ bits, $k = 11$, biais = 1023, $e_{\min} = -1022$, $e_{\max} = 1023$
- $\llbracket w \rrbracket = (-1)^{b_{63}} \times (1, b_{51} \dots b_1 b_0)_2 \times 2^{(\sum_{i=52}^{62} b_i 2^{(i-52)-1023})}$
- Valeurs représentables $[\pm 2^{-1022}, (2 - 2^{-52}) \times 2^{1023}]$

Nombres à virgule flottante – norme IEEE-754

- Rationnel ou réel : représentation **arrondie** en général
- 4 modes d'arrondis
 - Arrondi au plus proche : $RN(c)$
 - Si c équidistant de deux flottants consécutifs, on prend celui dont la mantisse termine par 0
 - Arrondi vers $-\infty$ (RD), $+\infty$ (RU), 0 (RZ)
- La norme impose **l'arrondi correct** pour $+$, $-$, $\times$, $\div$, $\sqrt{}$:
 - Résultat calculé = **résultat exact arrondi** selon le mode d'arrondi courant
 - Mode d'arrondi par défaut : **arrondi au plus proche** en général

Les float NE SONT PAS les réels