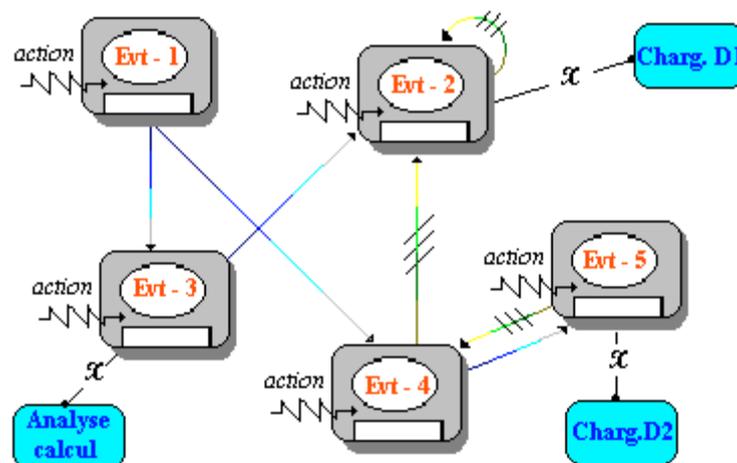


Les bases de l'informatique et de la programmation



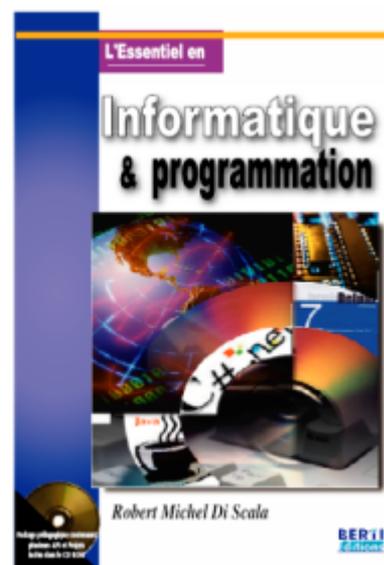
Le contenu de ce livre pdf de cours d'initiation à la programmation est inclus dans un ouvrage papier de 1372 pages édité en Novembre 2004 par les éditions Berti à Alger.

<http://www.berti-editions.com>

L'ouvrage est accompagné d'un CD-ROM contenant les assistants du package pédagogique.

Rm di Scala

Corrections du 04.01.05



SOMMAIRE

Introduction	4
Chapitre 1.La machine	
■ 1.1.Ordinateur et évolution	6
■ 1.2.Les circuits logiques	14
■ 1.3.Codage et numération	44
■ 1.4.Formalisation de la notion d'ordinateur	55
■ 1.5.Architecture de l'ordinateur	66
■ 1.6.Système d'exploitation	100
■ 1.7.Les réseaux	126
■ Exercices avec solutions	145
Chapitre 2.Programmer avec un langage	
■ 2.1.Les langages	147
■ 2.2.Relations binaires	155
■ 2.3.Théorie des langages	161
■ 2.4.Les bases du langage Delphi	177
■ Exercices avec solutions	219
Chapitre 3.Développer du logiciel avec méthode	
■ 3.1.Développement méthodique du logiciel	223
■ .Machines abstraites : exemple	259
■ 3.2.Modularité	269
■ 3.3.Complexité, tri, recherche	278
■ tri à bulle	286

■ tri par sélection	292
■ tri par insertion	300
■ tri rapide	306
■ tri par tas	316
■ recherche en table	331
■ Exercices avec solutions	336

Chapitre 4. Structures de données

■ 4.1.spécifications abstraites de données	355
■ 4.2 types abstraits TAD et implantation	371
■ exercice TAD et solution d'implantation	379
■ 4.3 structures d'arbres binaires	382
■ Exercices avec solutions	413

Chapitre 5. Programmation objet et événementielle

■ 5.1.Introduction à la programmation orientée objet	445
■ 5.2.Programmez objet avec Delphi	462
■ 5.3.Polymorphisme avec Delphi	489
■ 5.4.Programmation événementielle et visuelle	523
■ 5.5.Les événements avec Delphi	537
■ 5.6.Programmation défensive	564
■ Exercices avec solutions	582

Chapitre 6. Programmez avec des grammaires

■ 6.1.Programmation avec des grammaires	605
■ 6.2.Automates et grammaires de type 3	628
■ 6.3.projet de classe mini-interpréteur	647
■ 6.4.projet d'indentateur de code	667
■ Exercices avec solutions	691

Chapitre 7. Communication homme-machine

■ 7.1. Les interfaces de communication logiciel/utilisateur	707
■ 7.2. Grammaire pour analyser des phrases	714
■ 7.3. Interface et pilotage en mini-français	734
■ 7.4. Projet d'IHM : enquête fumeurs	754
■ 7.5. Utilisation des bases de données	766
■ Exercices avec solutions	802

Chapitre 8. Les composants sont des logiciels réutilisables

■ 8.1. Construction de composants avec Delphi	861
■ 8.2. Les messages Windows avec Delphi	902
■ 8.3. Création d'un événement associé à un message	923
■ 8.4. ActiveX avec la technologie COM	930
■ Exercices avec solutions	948

Annexes

□ Notations mathématiques utilisées dans l'ouvrage	982
□ Syntaxe comparée LDFA- Delphi-Java/C#	988
□ Choisir entre agrégation ou héritage	990
□ 5 composants logiciels en Delphi, Java swing et C#	995

Introduction

☀ Issu d'un cours de programmation à l'université de Tours en premier cycle scientifique, en DESS, Master Sciences et technologie compétence complémentaire informatique et en Diplôme Universitaire (DU) compétence complémentaire informatique pour les NTIC (réservés à des non-informaticiens), cet ouvrage est une synthèse (non exhaustive) sur les minima à connaître sur le sujet.

☀ Il permettra au lecteur d'aborder la programmation objet et l'écriture d'interfaces objets événementielles sous Windows en particulier.

☀ Ce livre sera utile à un public étudiant (IUT info, BTS info, IUP informatique et scientifique, DEUG sciences, licence pro informatique, Dess, Master et DU compétence complémentaire en informatique) et de toute personne désireuse de se former par elle-même (niveau prérequis Bac scientifique).

☀ Le premier chapitre rassemble les concepts essentiels sur la notion d'ordinateur, de codage, de système d'exploitation, de réseau, de programme et d'instruction au niveau machine.

☀ Le second chapitre introduit le concept de langage de programmation et de grammaire de chomsky, le langage pascal de Delphi sert d'exemple.

☀ Le chapitre trois forme le noyau dur d'une approche méthodique pour développer du logiciel, les thèmes abordés sont : algorithme, complexité, programmation descendante, machines abstraites, modularité. Ce chapitre fournit aussi des outils de tris sur des tableaux. ☀ montre comment utiliser des grammaires pour programmer en mode génération ou en mode analyse.

☀ Le chapitre quatre définit la notion de types abstraits. Il propose l'étude de type abstrait de structures de données classiques : liste, pile, file, arbre avec des algorithmes classiques de traitement d'arbres binaires.

☀ Le chapitre cinq contient les éléments fondamentaux de la programmation orientée objet, du polymorphisme d'objet, du polymorphisme de méthode, de la programmation événementielle et visuelle, de la programmation défensive. Le langage Delphi sert de support à l'implantation pratique de ces notions essentielles.

☀ Le chapitre six montre comment utiliser la programmation par les grammaires avec des outils pratiques comme les automates de type 3 et les automates à piles simples. Deux projets complets sont traités dans ce chapitre.

☀ Le chapitre sept correspond à la construction d'interface homme-machine, et à l'utilisation des bases de données avec des exemples pratiques en Delphi et Access.

☀ Le chapitre huit commence avec Delphi, puis aborde le traitement des messages dans Windows et comment programmer des applications utilisant les messages système pour communiquer. Il fournit aussi une notice pratique pour construire un composant ActiveX et le déployer sur le web avec Delphi.

Chapitre 1 : La machine

1.1. Ordinateur et évolution

- les 3 grandes lignes de pensées
- les générations d'ordinateurs
- l'ordinateur
- information-informatique

1.2. Les circuits logiques

- logique élémentaire pour l'informatique
- algèbre de Boole
- circuits booléens

1.3. Codage numération

- codage de l'information
- numération

1.4. Formalisation de la notion d'ordinateur

- machine de Turing théorique
- machine de Turing physique

1.5. Architecture de l'ordinateur

- les principaux constituants
- mémoires, mémoire centrale
- une petite machine pédagogique

1.6. Système d'exploitation

- notion de système d'exploitation
- systèmes d'exploitation des micro-ordinateurs

1.7. Les réseaux

- les réseaux d'ordinateurs
- liaisons entre réseaux

1.1 Ordinateur et évolution

Plan du chapitre: 

1. Les 3 grandes lignes de pensée

- 1.1 Les machines à calculer
- 1.2 Les automates
- 1.3 Les machines programmables

2. Les générations de matériels

- 2.1 Première génération 1945-1954
- 2.2 Deuxième génération 1955-1965
- 2.3 Troisième génération 1966-1973
- 2.4 Quatrième génération à partir de 1974

3. L'ordinateur

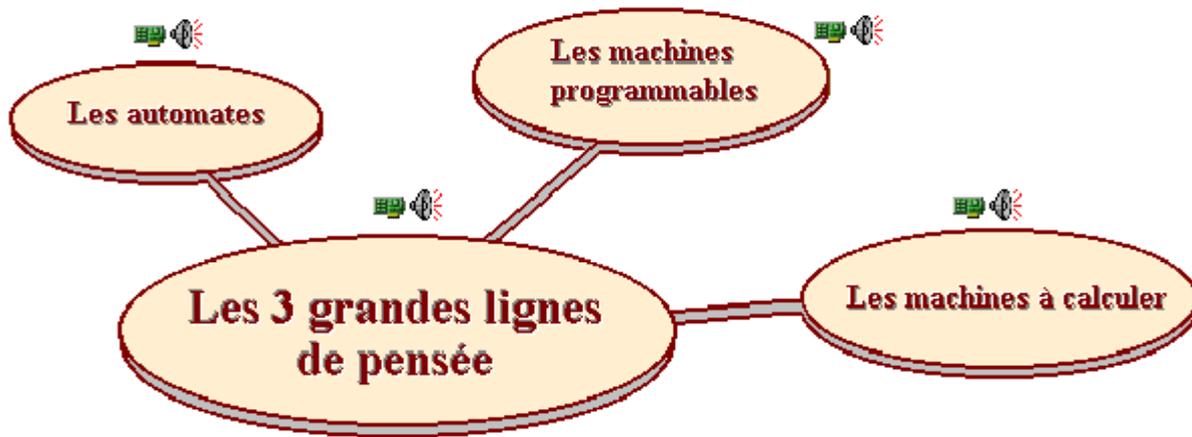
- 3.1 Utilité de l'ordinateur
- 3.2 Composition minimale d'un ordinateur
- 3.3 Autour de l'ordinateur : les périphériques
- 3.4 Pour relier tout le monde

4. Information - Informatique

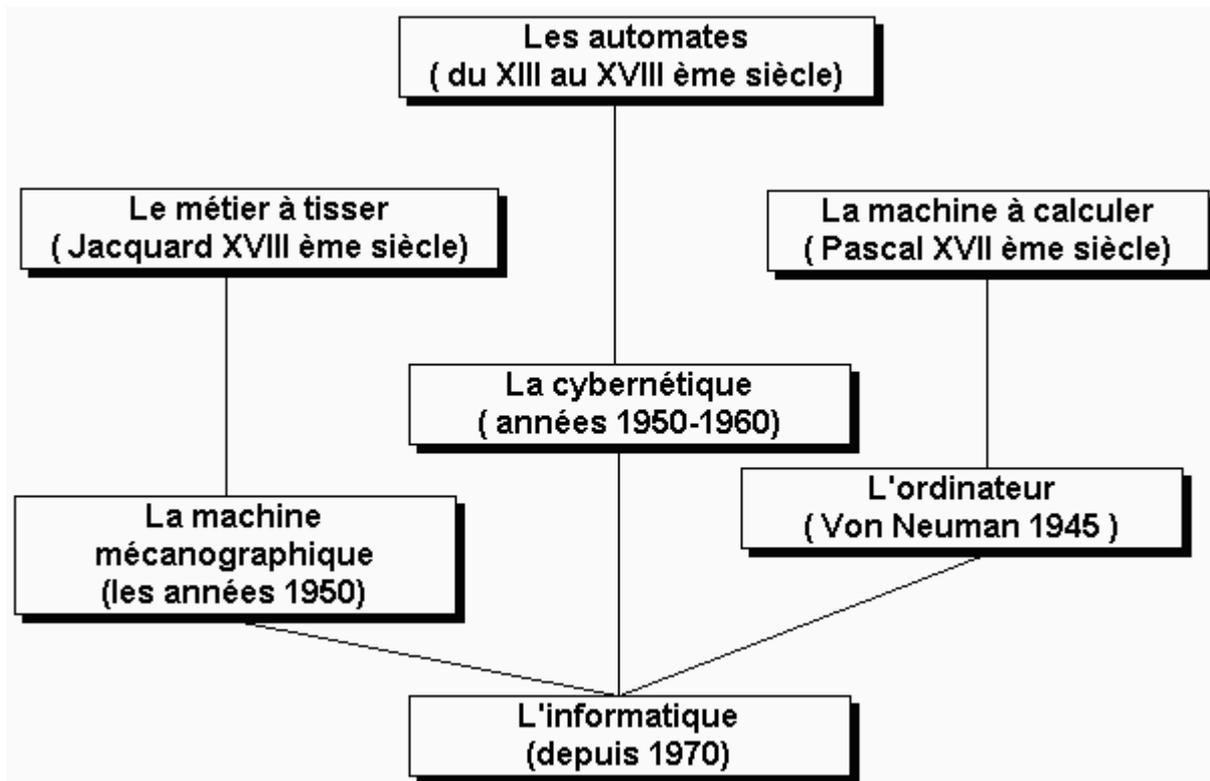
- 4.1 Les définitions
- 4.2 Critère algorithmique élémentaire



1. Les 3 grandes lignes de pensée



L'histoire de l'informatique débute par l'invention de machines (la fonction crée l'organe) qui au départ correspondent à des lignes de pensée différentes. L'informatique résultera de la fusion des savoirs acquis dans ces domaines. Elle n'est pas une synthèse de plusieurs disciplines, mais plutôt une discipline entièrement nouvelle puisant ses racines dans le passé. Seul l'effort permanent du génie créatif humain l'a rendue accessible au grand public de nos jours.



1.1 Les machines à calculer

La Pascaline de Pascal, 17^{ème} siècle. Pascal invente la Pascaline, première machine à calculer (addition et soustraction seulement), pour les calculs de son père.

La machine multiplicatrice de Leibniz, 17^{ème} siècle. Leibniz améliore la machine de Pascal pour avoir les quatre opérations de base (+,-,*,/).

1.2 Les automates

Les automates, les horloges astronomiques, les machines militaires dès le 12^{ème} siècle.

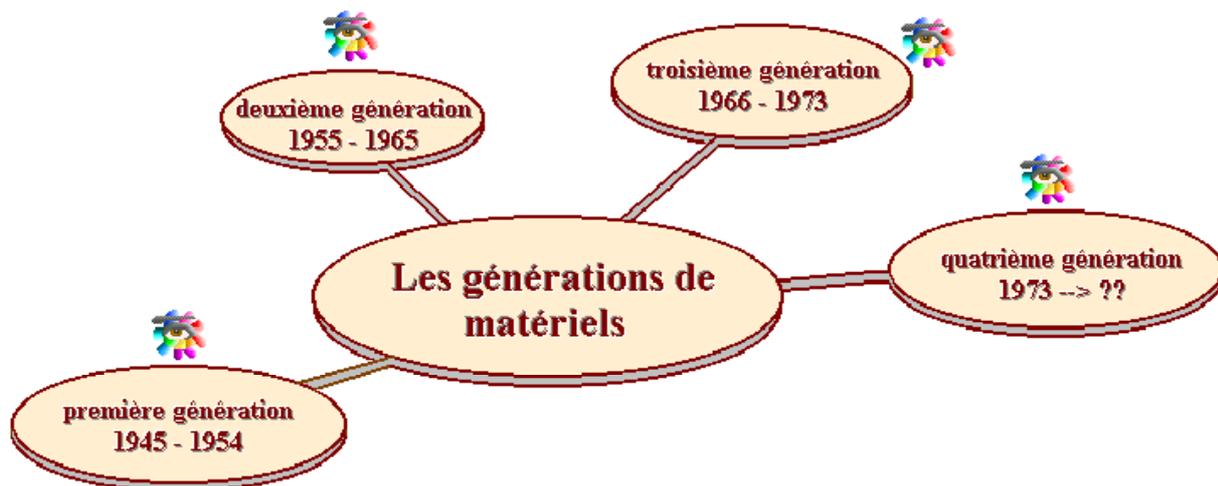
1.3 Les machines programmables

Le métier à tisser de **Jacquard**, 1752-1834

Début de commercialisation des machines mécaniques scientifiques (usage militaire en général).

Babage invente la première machine analytique programmable.

2. Les générations de matériels



On admet généralement que l'ère de l'informatique qui couvre peu de décennies se divise en plusieurs générations essentiellement marquées par des avancées technologiques

2.1 Première génération 1945 - 1954

Informatique scientifique et militaire.

Il faut résoudre les problèmes des calculs répétitifs.

Création de langages avec succès et échecs dans le but de résoudre les problèmes précédents.
Technologie lourde (Tube et tore de ferrite), qui pose des problèmes de place et de consommation électrique.

Les très grandes nations seules possèdent l'outil informatique.

2.2 Deuxième génération 1955-1965

Naissance de l'informatique de gestion.

Nouvelle technologie basée sur le transistor et le circuit imprimé. Le langage **Fortran** règne en maître incontesté. Le langage de programmation **Cobol** orienté gestion, devient un concurrent de **Fortran**.

Les nations riches et les très grandes entreprises accèdent à l'outil informatique.

2.3 Troisième génération 1966-1973

Naissance du circuit intégré.

Nouvelle technologie basée sur le **transistor** et le circuit intégré.

Les ordinateurs occupent moins de volume, consomment moins d'électricité et sont plus rapides. Les ordinateurs sont utilisés le plus souvent pour des applications de gestion.

Les PME et PMI de tous les pays peuvent se procurer des matériels informatiques.

2.4 Quatrième génération à partir de 1974

Naissance de la micro-informatique

La création des microprocesseurs permet la naissance de la micro-informatique (le micro-ordinateur Micral de R2E est inventé par un français **François Gernelle** en 1973). Steve Jobs (Apple) invente un nouveau concept vers la fin des années 70 en recopiant et en commercialisant les idées de Xerox par le MacIntosh et son interface graphique.

Un individu peut actuellement acheter son micro-ordinateur dans un supermarché.

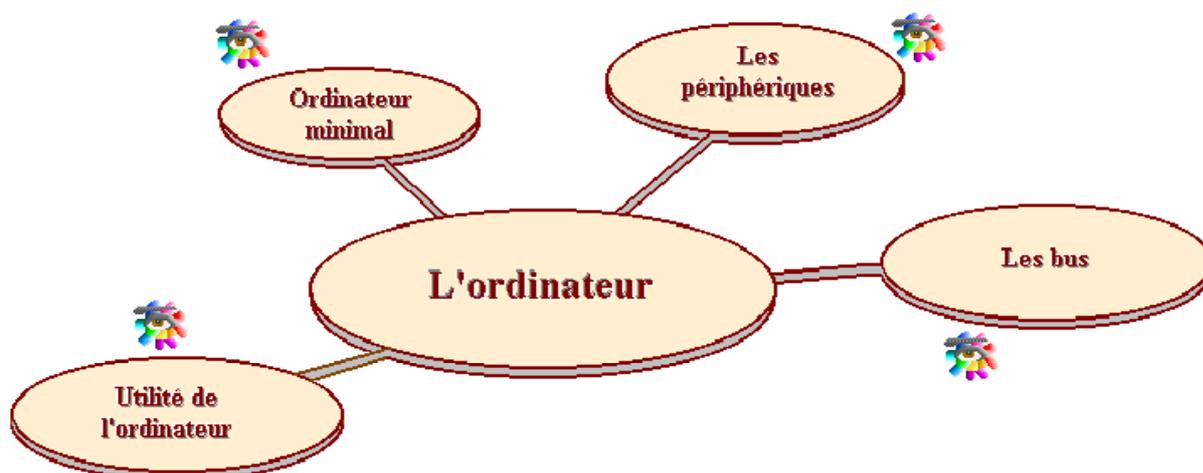
Nous observons un phénomène fondamental :

La démocratisation d'une science à travers un outil. L'informatique qui à ses débuts était une affaire de spécialistes, est aujourd'hui devenue l'affaire de tous; d'où l'importance d'une solide formation de tous aux différentes techniques utilisées par la science informatique, car la banalisation d'un outil ou d'une science a son revers : l'assouplissement de l'attention envers les inconvénients inhérents à tout progrès technique.

Tableau synoptique des générations d'ordinateurs :

	1ère Génér. 45 - 54	2ème Génér. 55 - 65	3ème Génér. 66 - 73	4ème Génér. 74 ---> ?
composants	tubes radios	transistor	circuit intégré	VLSI
mémoires	tubes/ tores de ferrite	tors de ferrite	circuit intégré	VLSI
temps de traitement	10⁻² s	10⁻³ s	10⁻⁶ s	10⁻⁹ s
système d'exploitation	rudimentaire	monoprogram -mation	multiprogram -mation	temps-partagé
rendement %	3 %	10%	30 %	60 %

3. L'ordinateur



3.1 Utilité de l'ordinateur

Un ordinateur est une machine à traiter de l'information.

L'information est fournie sous forme de données traitées par des programmes (exécutés par des ordinateurs).

3.2 Composition minimale d'un ordinateur : le cœur

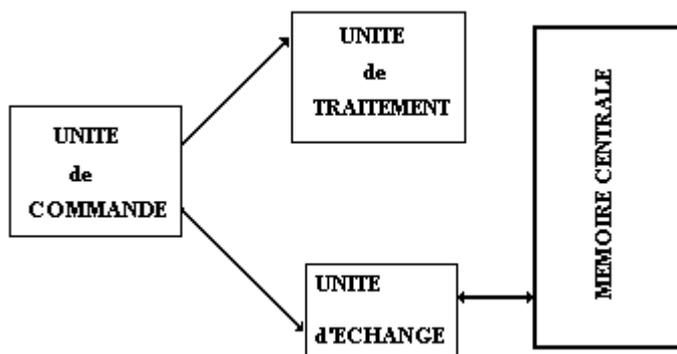
Une mémoire Centrale .

Une unité de traitement avec son UAL (unité de calcul).

Une unité de commande ou contrôle.

Une ou plusieurs unités d'échanges.

Schéma simplifié du cœur de l'ordinateur



3.3 Autour de l'ordinateur : les périphériques

Les périphériques sont chargés d'effectuer des tâches d'entrées et/ou de sortie de l'information. En voici quelques uns.

Périphériques d'entrée

Clavier, souris, crayon optique, écran tactile, stylo code barre, carte son, scanner, caméra, etc.

Périphériques de sortie

Ecran, imprimante, table traçante, carte son, télécopie, modem etc.

Périphériques d'entrée sortie

Mémoire auxiliaire (sert à stocker les données et les programmes):

1. Stockage de masse sur disque dur ou disquette.
2. Bande magnétique sur dérouleur (ancien) ou sur streamer.
3. Mémoire clef USB
4. CD-Rom, DVD, disque magnéto-électrique etc...

3.4 Pour relier tout le monde : Les Bus

Les Bus représentent dans l'ordinateur le système de communication entre ses divers constituants. Ils sont au nombre de trois :

le **Bus d'adresses**, (la notion d'adresse est présentée plus loin)

le **Bus de données**,

le **Bus de contrôle**.

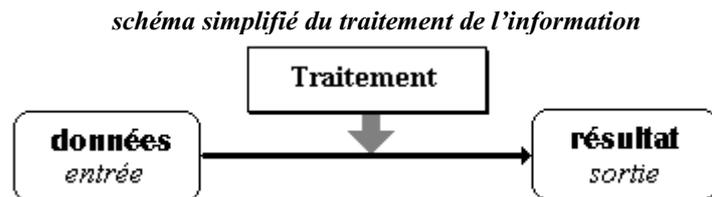
4. Information - informatique

4.1 Les définitions

L'**information** est le support formel d'un élément de connaissance humaine susceptible d'être représentée à l'aide de conventions (codages) afin d'être conservée, traitée ou communiquée.

L'**informatique** est la science du traitement de l'information dans les domaines scientifiques, techniques, économiques et sociaux.

Une **donnée** est la représentation d'une information sous une forme conventionnelle (codée) destinée à faciliter son traitement.



4.2 Critère algorithmique élémentaire

Une application courante est justiciable d'un traitement informatique si :

Il est possible de définir et de décrire parfaitement les données d'entrée et les résultats de sortie.

Il est possible de décomposer le passage de ces données vers ces résultats en une suite d'opérations élémentaires dont chacune peut être exécutée par une machine.

Nous pouvons considérer ce critère comme une définition provisoire d'un algorithme.

Actuellement l'informatique intervient dans tous les secteurs d'activité de la vie quotidienne :

démontrer un théorème (*mathématique*)
faire jouer aux échecs (*intelligence artificielle*)
dépouiller un sondage (*économie*)
gérer un robot industriel (*atelier*)
facturation de produits (*entreprise*)
traduire un texte (*linguistique*)
imagerie médicale (*médecine*)
formation à distance (*éducation*)
Internet (*grand public*)...etc

1.2 Les circuits logiques

Plan du chapitre: 

1. Logique élémentaire pour l'informatique

- 1.1 Calcul propositionnel naïf
- 1.2 Propriétés des connecteurs logiques
- 1.3 Règles de déduction

2. Algèbre de Boole

- 2.1 Axiomatique pratique
- 2.2 Exemples d'algèbre de Boole
- 2.3 Notation des électroniciens

3. Circuits booléens ou logiques

- 3.1 Principaux circuits
- 3.2 Fonction logique associée à un circuit
- 3.3 Circuit logique associé à une fonction
- 3.4 Additionneur dans l'UAL
- 3.5 Circuit multiplexeur
- 3.6 Circuit démultiplexeur
- 3.7 Circuit décodeur d'adresse
- 3.8 Circuit comparateur
- 3.9 Circuit bascule
- 3.10 Registre
- 3.11 Mémoires SRAM et DRAM
- 3.12 Afficheur à LED
- 3.13 Compteurs
- 3.14 Réalisation électronique de circuits booléens

1. Logique élémentaire pour l'informatique

1.1 Calcul propositionnel naïf

Construire des programmes est une activité scientifique fondée sur le raisonnement logique. Un peu de logique simple va nous aider à disposer d'outils pratiques mais rigoureux pour construire des programmes les plus justes possibles. Si la programmation est un art, c'est un art rigoureux et logique. La rigueur est d'autant plus nécessaire que les systèmes informatiques manquent totalement de sens artistique.

Une proposition est une propriété ou un énoncé qui peut avoir une valeur de vérité vraie (notée **V**) ou fausse (notée **F**).

" 2 est un nombre impair " est une proposition dont la valeur de vérité est **F**.

Par abus de langage nous noterons avec **le même symbole une proposition et sa valeur de vérité**, car seule la valeur de vérité d'une proposition nous intéresse ici.

Soit l'ensemble $P = \{ \mathbf{V}, \mathbf{F} \}$ des valeurs des propositions.

On le munit de trois opérateurs appelés connecteurs logiques : \neg , \wedge , \vee .

\wedge : $P \times P \rightarrow P$ (se lit " **et** ")

\vee : $P \times P \rightarrow P$ (se lit " **ou** ")

\neg : $P \rightarrow P$ (se lit " **non** ")

Ces connecteurs sont définis en extension par leur tables de vérité :

p	q	$\neg p$	$p \wedge q$	$p \vee q$
V	V	F	V	V
V	F	F	F	V
F	V	V	F	V
F	F	V	F	F

1.2 Propriétés des connecteurs logiques

- Nous noterons $p = q$, le fait la proposition p et la proposition q ont la même valeur de vérité.
- Le lecteur pourra démontrer à l'aide des tables de vérité par exemple, que \vee et \wedge possèdent les propriétés suivantes :
 - $p \vee q = q \vee p$
 - $p \wedge q = q \wedge p$
 - $p \vee (q \vee r) = (p \vee q) \vee r$
 - $p \wedge (q \wedge r) = (p \wedge q) \wedge r$
 - $p \vee (q \wedge r) = (p \vee q) \wedge (p \vee r)$
 - $p \wedge (q \vee r) = (p \wedge q) \vee (p \wedge r)$
 - $p \vee p = p$
 - $p \wedge p = p$
 - $\neg\neg p = p$
 - $\neg(p \vee q) = \neg p \wedge \neg q$
 - $\neg(p \wedge q) = \neg p \vee \neg q$
- Nous notons $p \Rightarrow q$, la proposition : $\neg p \vee q$ (l'implication).

Table de vérité du connecteur \Rightarrow :

p	q	$p \Rightarrow q$
V	V	V
V	F	F
F	V	V
F	F	V

- Il est aussi possible de prouver des " égalités " de propositions en utilisant des combinaisons de résultats précédents.

Exemple : Montrons que : $p \Rightarrow q = \neg q \Rightarrow \neg p$ (implication contraposée), par définition et utilisation évidente des propriétés :

$$p \Rightarrow q = \neg p \vee q = q \vee \neg p = \neg(\neg q) \vee \neg p = \neg q \Rightarrow \neg p$$

1.3 Règles de déduction

Assertion :

c'est une proposition construite à l'aide des connecteurs logiques (\neg , \wedge , \vee , **en particulier**) dont la valeur de vérité est toujours V (vraie).

Les règles de déduction permettent de faire du calcul sur les *assertions*. Nous abordons ici le raisonnement rationnel sous son aspect automatisable, en donnant des règles d'inférences extraites du modèle du raisonnement logique du logicien **Gentzen**. Elles peuvent être une aide très précieuse lors de la construction et la spécification d'un programme.

Les règles de déduction sont séparées en deux membres. Le premier contient les prémisses ou hypothèses de la règle, le deuxième membre est constitué par une conclusion unique. Les deux membres sont séparés par un trait horizontal. Gentzen classe les règles de déduction en deux catégories : les règles d'introduction car il y a utilisation d'un nouveau connecteur, et les règles d'éliminations qui permettent de diminuer d'un connecteur une proposition.

Syntaxe d'une telle règle :

$$\frac{p_1, p_2, \dots, p_n}{q}$$

Quelques règles de déductions pratiques :

Règle d'introduction du \wedge :

$$\frac{p, q}{p \wedge q}$$

Règle d'introduction du \vee :

$$\frac{p, q}{p \vee q}$$

Règle d'introduction du \Rightarrow :

$$\frac{p, q}{p \Rightarrow q}$$

Règles d'élimination du \wedge :

$$\frac{p \wedge q}{q}, \quad \frac{p \wedge q}{p}$$

Règle du modus ponens :
$$\frac{\mathbf{p}, \mathbf{p} \Rightarrow \mathbf{q}}{\mathbf{q}}$$

Règle du modus tollens :
$$\frac{\neg \mathbf{q}, \mathbf{p} \Rightarrow \mathbf{q}}{\neg \mathbf{p}}$$

Le système de **Gentzen** contient d'autres règles sur le **ou** et sur le **non**. Enfin il est possible de construire d'autres règles de déduction à partir de celles-ci et des propriétés des connecteurs logiques. Ces règles permettent de prouver la valeur de vérité d'une proposition. Dans les cas pratiques l'essentiel des raisonnements revient à des démonstrations de véracité d'implication.

La démarche est la suivante : pour prouver qu'une implication est vraie, il suffit de supposer que le membre gauche de l'implication est vrai et de montrer que sous cette hypothèse le membre de droite de l'implication est vrai.

Exemple :

soit à montrer que la règle de déduction **R₀** suivante est exacte :

R₀ :
$$\frac{\mathbf{p} \Rightarrow \mathbf{q}, \mathbf{q} \Rightarrow \mathbf{r}}{\mathbf{p} \Rightarrow \mathbf{r}} \quad (\textit{transitivité de } \Rightarrow)$$

Hypothèse : p est vrai

nous savons que : $\mathbf{p} \Rightarrow \mathbf{q}$ est vrai et que $\mathbf{q} \Rightarrow \mathbf{r}$ est vrai

- $$\frac{\mathbf{p}, \mathbf{p} \Rightarrow \mathbf{q}}{\mathbf{q}}$$
- En appliquant le **modus ponens** : $\frac{\mathbf{p}, \mathbf{p} \Rightarrow \mathbf{q}}{\mathbf{q}}$ nous déduisons que : **q** est vrai.
 - En appliquant le **modus ponens** à $(\mathbf{q}, \mathbf{q} \Rightarrow \mathbf{r})$ nous déduisons que : **r** est vrai.
 - Comme p est vrai (par hypothèse) on applique la **règle d'introduction de \Rightarrow** sur (\mathbf{p}, \mathbf{r}) nous déduisons que : **$\mathbf{p} \Rightarrow \mathbf{r}$ est vrai (cqfd)**.

Nous avons prouvé que **R₀** est exacte. Ainsi nous avons construit une nouvelle règle de déduction qui pourra nous servir dans nos raisonnements.

Nous venons d'exhiber un des outils permettant la construction raisonnée de programmes. La logique interne des ordinateurs est encore actuellement plus faible puisque basée sur la logique booléenne, en attendant que les machines de 5^{ème} génération basées sur la logique du premier ordre (logique des prédicats, supérieure à la logique propositionnelle) soient définitivement opérationnelles.

2. Algèbre de Boole

2.1 Axiomatique pratique

Du nom du mathématicien anglais **G.Boole** qui l'inventa. Nous choisissons une axiomatique compacte, l'axiomatique algébrique :

On appelle algèbre de Boole tout ensemble E muni de :

deux lois de compositions internes notées par exemple : \bullet et \oplus ,

■ une application involutive f ($f^2 = \text{Id}$) de E dans lui-même, notée $f: a \longrightarrow \bar{a}$

■ chacune des deux lois \bullet , \oplus , est associative et commutative,

■ chacune des deux lois \bullet , \oplus , est distributive par rapport à l'autre,

■ la loi \bullet admet un élément neutre unique noté e_1 ,

$$x \in E, x \bullet e_1 = x$$

■ la loi \oplus admet un élément neutre noté e_0 ,

$$x \in E, x \oplus e_0 = x$$

■ tout élément de E est idempotent pour chacune des deux lois :

$$x \in E, x \bullet x = x \text{ et } x \oplus x = x$$

■ axiomes de complémentarité :

$$\forall x \in E, x \bullet \bar{x} = e_0$$

$$\forall x \in E, x \oplus \bar{x} = e_1$$

■ lois de Morgan :

$$(x,y) \in E^2, \overline{x \bullet y} = \bar{x} \oplus \bar{y}$$

$$(x,y) \in E^2, \overline{x \oplus y} = \bar{x} \bullet \bar{y}$$

2.2 Exemples d'algèbre de Boole

a) L'ensemble $P(E)$ des parties d'un ensemble E , muni des opérateurs intersection \cap , union \cup , et l'application involutive complémentaire dans $E \rightarrow C_E$, (si $E \neq \emptyset$), si E est fini et possède n éléments, $P(E)$ est de cardinal 2^n .

Il suffit de vérifier les axiomes précédents en substituant les lois du nouvel ensemble E aux lois \bullet , \oplus , et \bar{x} . Il est montré en mathématiques que toutes les algèbres de Boole finies sont isomorphes à un ensemble $(P(E), \cap, \cup, C_E)$: elles ont donc un cardinal de la forme 2^n .

b) L'ensemble des propositions (en fait l'ensemble de leurs valeurs $\{\mathbf{V}, \mathbf{F}\}$) muni des connecteurs logiques \neg (l'application involutive), \wedge , \vee , est une **algèbre de Boole minimale à deux éléments**.

2.3 Notation des électroniciens

L'algèbre des circuits électriques est **une algèbre de Boole minimale à deux éléments** :

L'ensemble $E = \{0,1\}$ muni des lois " \bullet " et " $+$ " et de l'application complémentaire $f: a \longrightarrow \bar{a}$.

Formules pratiques et utiles (résultant de l'axiomatique) :

$a + 1 = 1$	$a.1 = a$
$a + 0 = a$	$a.0 = 0$
$a + a = a$	$a.a = a$
$a + \bar{a} = 1$	$a . \bar{a} = 0$
$\overline{a + b} = \bar{a} . \bar{b}$	$\overline{a . b} = \bar{a} + \bar{b}$
$\bar{\bar{0}} = 1$	$\bar{\bar{1}} = 0$

Formule d'absorption :

$$\mathbf{a+(b.a) = a.(a+b) = (a+b).a = a+b.a = a}$$

Montrons par exemple : $a+(b.a) = a$

$$a+(b.a) = a+a.b = a.1+a.b = a.(1+b) = a.1 = a$$

Le reste se montrant de la même façon.

Cette algèbre est utile pour décrire et étudier les schémas électroniques, mais elle sert aussi dans d'autres domaines que l'électricité. Elle est étudiée ici parce que les ordinateurs actuels sont basés sur des composants électroniques. Nous allons descendre un peu plus bas dans la réalisation interne du cœur d'un ordinateur, afin d'aboutir à la construction d'un additionneur en binaire dans l'UAL.

Tables de vérité des trois opérateurs :

x	y	\bar{x}	$x \cdot y$	$x + y$
1	1	0	1	1
1	0	0	0	1
0	1	1	0	1
0	0	1	0	0

3. Circuits booléens ou logiques

Nous représentons par une variable booléenne $x \in \{0,1\}$ le passage d'un courant électrique.

Lorsque $x = 0$, nous dirons que x est à l'état 0 (**le courant ne passe pas**)

Lorsque $x = 1$, nous dirons que x est à l'état 1 (**le courant passe**)

Une telle variable booléenne permet ainsi de visualiser, sous forme d'un bit d'information (0,1) le comportement d'un composant physique laissant ou ne laissant pas passer le courant.

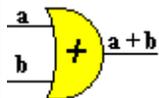
Nous ne nous préoccupons pas du type de circuits électriques permettant de construire un circuit logique (les composants électriques sont basés sur les circuits intégrés). Nous ne nous intéresserons qu'à la fonction logique (booléenne) associée à un tel circuit.

En fait un circuit logique est un opérateur d'une algèbre de Boole c'est-à-dire une combinaison de symboles de l'algèbre $\{0,1\}, \cdot, +, \bar{x}$.

3.1 Principaux circuits

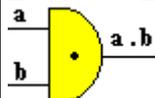
Nous proposons donc 3 circuits logiques de base correspondant aux deux lois internes et à l'opérateur de complémentation involutif.

Le circuit OU associé à la loi " + " :



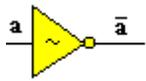
La table de vérité de ce circuit est celle de l'opérateur +

Le circuit ET associé à la loi " • " :



La table de vérité de ce circuit est celle de l'opérateur •

Le circuit NON associé à la loi " \bar{x} " :



la table de vérité est celle de l'opérateur involutif \bar{x}

On construit deux circuits classiques à l'aide des circuits précédents :

L'opérateur XOR = " ou exclusif " :

$a \oplus b = \bar{a}.b + a.\bar{b}$	dont voici le schéma :
--------------------------------------	----------------------------

Table de vérité du ou exclusif :

a	b	$a \oplus b$
1	1	0
1	0	1
0	1	1
0	0	0

L'opérateur NAND (le NON-ET):

$a \otimes b = \overline{a.b} = \bar{a} + \bar{b}$	dont voici le schéma :
--	----------------------------

Table de vérité du Nand :

a	b	$a \otimes b$
1	1	0
1	0	1
0	1	1
0	0	1

L'opérateur NOR (le NON-OU):

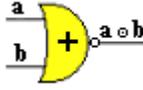
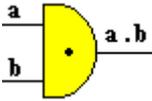
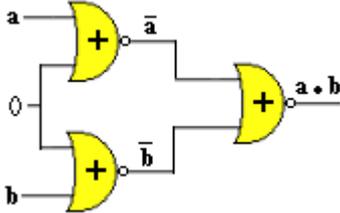
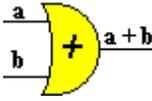
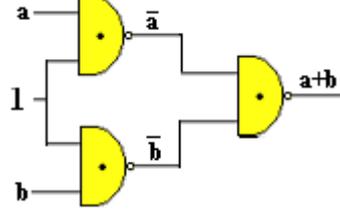
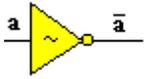
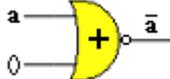
$a \oplus b = \overline{a+b} = \bar{a} \cdot \bar{b}$	dont voici le schéma : 
---	---

Table de vérité du Nor :

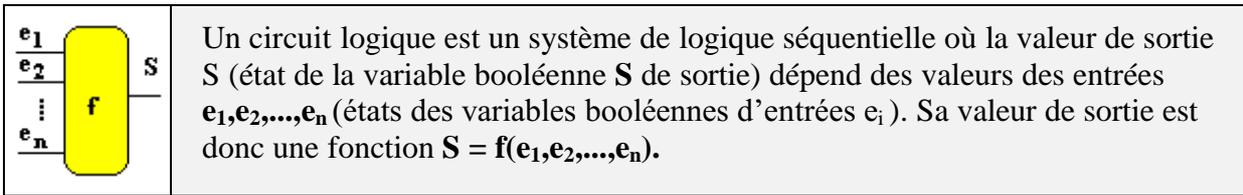
<i>a</i>	<i>b</i>	<i>a ⊕ b</i>
1	1	0
1	0	0
0	1	0
0	0	1

L'on montre facilement que les deux opérateurs NAND et NOR répondent aux critères axiomatiques d'une algèbre de Boole, ils sont réalisables très simplement avec un minimum de composants électroniques de type transistor et diode (voir paragraphes plus loin). Enfin le NOR et le NAND peuvent engendrer les trois opérateurs de base **non**, **et** , **ou** . :

Opérateur de base	Réalisation de l'opérateur en NAND ou en NOR
 circuit ET	
 circuit OU	
 circuit NON	

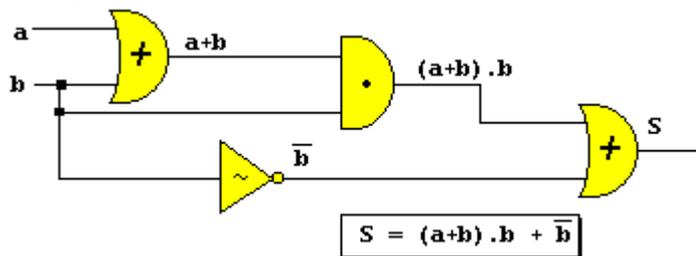
Expression des 3 premiers opérateurs (\bar{x} , + , .) à l'aide de NAND et de NOR

3.2 Fonction logique associée à un circuit



Pour calculer la fonction f à partir d'un schéma de circuits logiques, il suffit d'indiquer à la sortie de chaque opérateur (circuit de base) la valeur de l'expression booléenne en cours. Puis, à la fin, nous obtenons une expression booléenne que l'on simplifie à l'aide des axiomes ou des théorèmes de l'algèbre de Boole.

Exemple :



En simplifiant $S : (a+b) \cdot b + \bar{b} = b + \bar{b}$ (formule d'absorption)
 $b + \bar{b} = 1$.

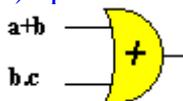
3.3 Circuit logique associé à une fonction

A l'inverse, la création de circuits logiques à partir d'une fonction booléenne f à n entrées est aussi simple. Il suffit par exemple, dans la fonction, d'exprimer graphiquement chaque opérateur par un circuit, les entrées étant les opérandes de l'opérateur. En répétant l'action sur tous les opérateurs, on construit un graphique de circuit logique associé à la fonction f .

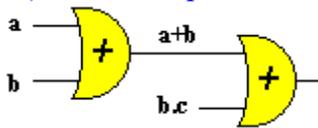
Exemple : Soit la fonction f de 3 variables booléennes, $f(a,b,c) = (a+b) + (b \cdot c)$

Construction progressive du circuit associé.

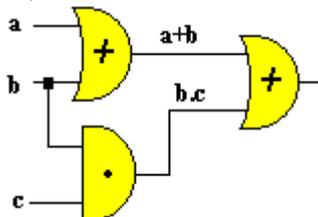
1°) opérateur "+" :



2°) branche supérieure de l'opérateur " + " :



3°) branche inférieure de l'opérateur " + " :



Les électroniciens classent les circuits logiques en deux catégories : les circuits combinatoires et les circuits séquentiels (ou à mémoire).

Un circuit combinatoire est un circuit logique à **n** entrées dont la fonction de sortie ne dépend uniquement que des variables d'entrées.

Un circuit à mémoire (ou séquentiel) est un circuit logique à **n** entrées dont la fonction de sortie dépend à la fois des variables d'entrées et des états antérieurs déjà mémorisés des variables de sorties.

Exemple de circuit à mémoire

<p style="text-align: center;">$f(a, b, S_3) = \bar{S}_3$</p>	<p>La sortie intermédiaire S_2 est évaluée en fonction de la sortie S_3 : $S_2 = b \cdot S_3$ (valeur de S_3 un temps avant)</p> <p>Si $b=0$ alors $S_2 = 0$ Si $b=1$ alors $S_2 = S_3$ Nous avons $S_3 = S_1 + S_2$</p> <p>En notant S'_3 la valeur au temps t_0 et S_3 la valeur au temps t_0+dt, il vient que $S_3 = S_1 + b \cdot S'_3$</p>
--	---

Table de vérité associée à ce circuit :

a	b	S_1	S_2	S_3	$f(a,b,S_3)$
1	1	0	S'_3	S'_3	\bar{S}'_3
1	0	0	0	0	1
0	1	1	S'_3	1	0
0	0	1	0	1	0

Dans le cas $a=1$ et $b=1$ ce circuit fictif fournit le complément de la valeur antérieure.

Quelques noms de circuits logiques utilisés dans un ordinateur

Circuit combinatoire : *additionneur, multiplexeur, décodeur, décaleur, comparateur.*
Circuit à mémoire : *bascules logiques.*

3.4 Additionneur dans l'UAL (circuit combinatoire)

a) Demi-additionneur

Reprenons les tables de vérités du " \oplus " (*Xor*), du "+" et du " \bullet " et adjoignons la table de calcul de l'addition en numération binaire.

Tout d'abord les tables comparées des opérateurs booléens :

<i>a</i>	<i>b</i>	$a \oplus b$	$a+b$	$a \cdot b$
1	1	0	1	1
1	0	1	1	0
0	1	1	1	0
0	0	0	0	0

Rappelons ensuite la table d'addition en numération binaire :

+	0	1
0	0	1
1	1	0(1)

0(1) représente la retenue 1 à reporter.

En considérant une addition binaire comme la somme à effectuer sur deux mémoires à un bit, nous observons dans l'addition binaire les différentes configurations des bits concernés (notés *a* et *b*).

Nous aurons comme résultat un bit de *somme* et un bit de *retenue* :

bit <i>a</i>		bit <i>b</i>		bit <i>somme</i>	bit de <i>retenue</i>
1	+	1	=	0	1
1	+	0	=	1	0
0	+	1	=	1	0
0	+	0	=	0	0

Si l'on compare avec les tables d'opérateurs booléens, on s'aperçoit que l'opérateur " \oplus " (*Xor*) fournit en sortie les mêmes configurations que le bit de somme, et que l'opérateur " \bullet " (*Et*) délivre en sortie les mêmes configurations que le bit de retenue.

Il est donc possible de simuler une addition binaire (arithmétique binaire) avec les deux opérateurs " \oplus " et " \bullet ". Nous venons de construire un demi-additionneur ou additionneur sur un bit. Nous pouvons donc réaliser le circuit logique simulant la fonction complète d'addition binaire, nous l'appellerons " additionneur binaire "(somme arithmétique en binaire de deux entiers en binaire).

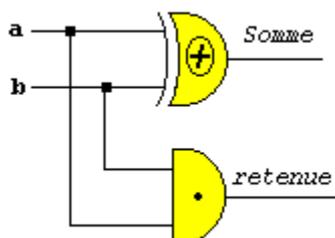
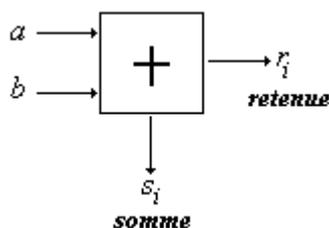


schéma logique d'un demi-additionneur

Ce circuit est noté :

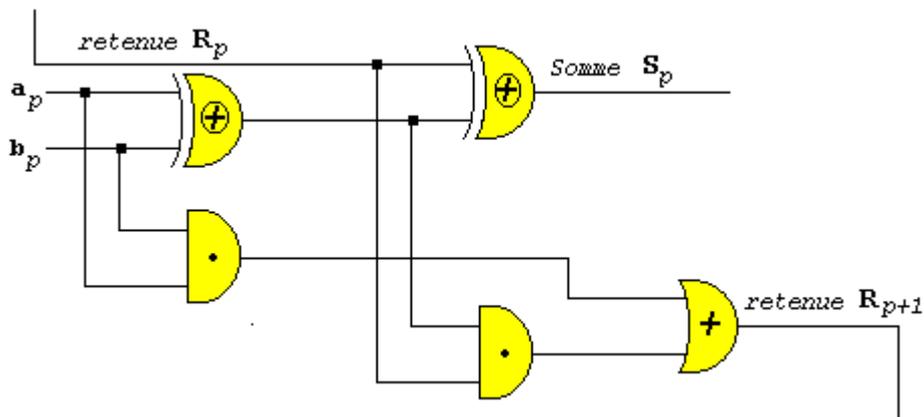


b) Additionneur complet

Une des constructions les plus simples et la plus pédagogique d'un additionneur complet est de connecter entre eux et en série des demi-additionneurs (additionneurs en cascade). Il existe une autre méthode dénommée " diviser pour régner " pour construire des additionneurs complets plus rapides à l'exécution que les additionneurs en cascade. Toutefois un additionneur en cascade pour UAL à 32 bits, utilise 2 fois moins de composants électroniques qu'un additionneur diviser pour régner.

Nous concluons donc qu'une UAL n'effectue en fait que des opérations logiques (algèbre de Boole) et simule les calculs binaires par des combinaisons d'opérateurs logiques

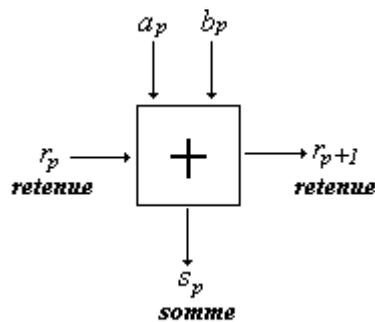
Soient a et b deux nombres binaires à additionner dans l'UAL. Nous supposons qu'ils sont stockés chacun dans une mémoire à n bits. Nous notons a_p et b_p leur bit respectif de rang p . Lors de l'addition il faut non seulement additionner les bits a_p et b_p à l'aide d'un demi-additionneur, mais aussi l'éventuelle retenue notée R_p provenant du calcul du rang précédent.



additionneur en cascade (addition sur le bit de rang p)

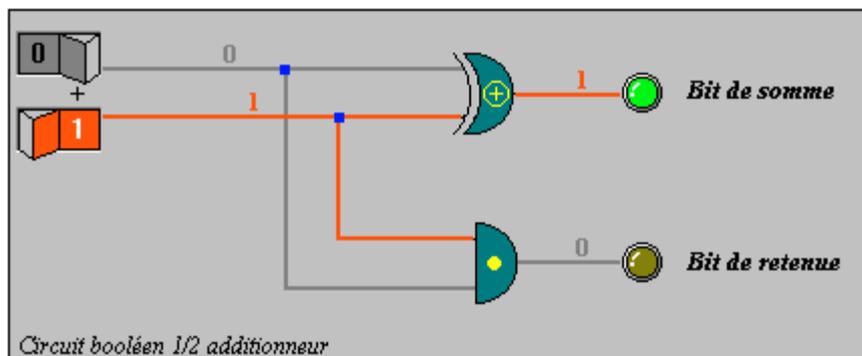
On réadditionne R_p à l'aide d'un demi-additionneur à la somme de a_p et b_p et l'on obtient le bit de somme du rang p noté S_p . La propagation de la retenue R_{p+1} est faite par un "ou" sur les deux retenues de chacun des demi-additionneurs et passe au rang p+1. Le processus est itératif sur tous les n bits des mémoires contenant les nombres a et b.

Notation du circuit additionneur :



Soit un exemple fictif de réalisation d'un demi-additionneur simulant l'addition binaire suivante :

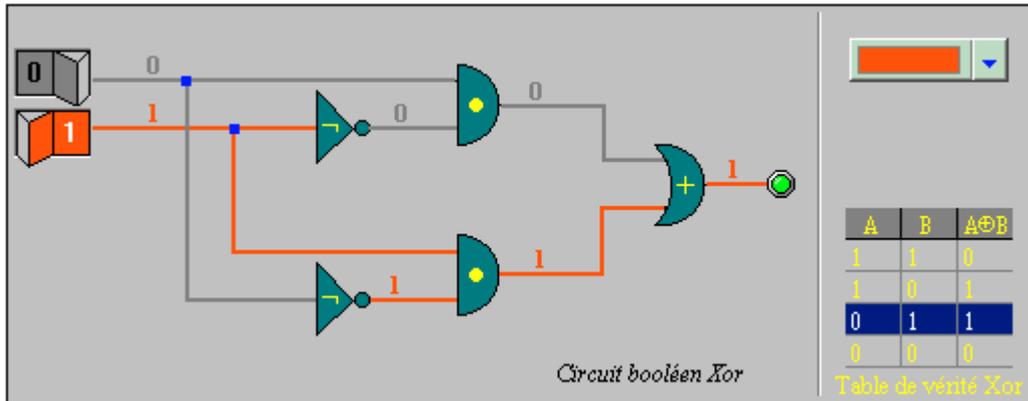
$0 + 1 = 1$. Nous avons figuré le passage ou non du courant à l'aide de deux interrupteurs (valeur = 1 indique que l'interrupteur est fermé et que le courant passe, valeur = 0 indique que l'interrupteur est ouvert et que le courant ne passe pas)



Le circuit « et » fournit le bit de retenue soit : $0 \bullet 1 = 0$

Le circuit « **Xor** » fournit le bit de somme soit : $0 \oplus 1 = 1$

Nous figurons le détail du circuit Xor du schéma précédent lorsqu'il reçoit le courant des deux interrupteurs précédents dans la même position (l'état électrique correspond à l'opération $0 \oplus 1 = 1$)

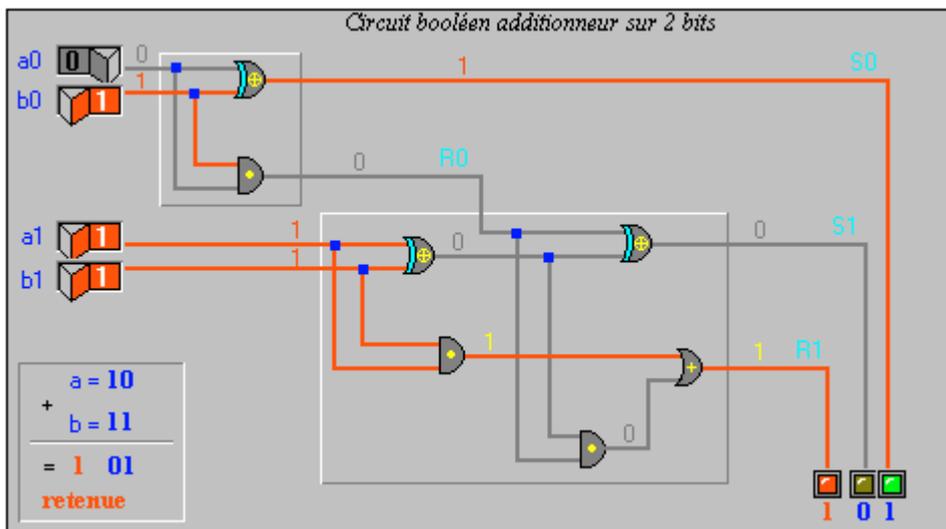


Si l'UAL effectue des additions sur 32 bits, il y aura 32 circuits comme le précédent, tous reliés en série pour la propagation de la retenue.

Un exemple d'additionneur sur deux mémoires **a** et **b** à 2 bits contenant respectivement les nombres 2 et 3 :

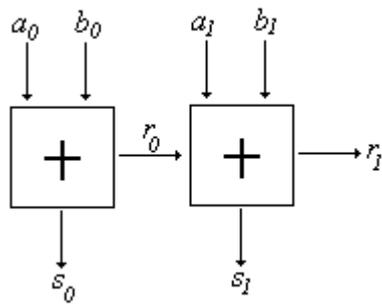
a = 1 0

b = 1 1



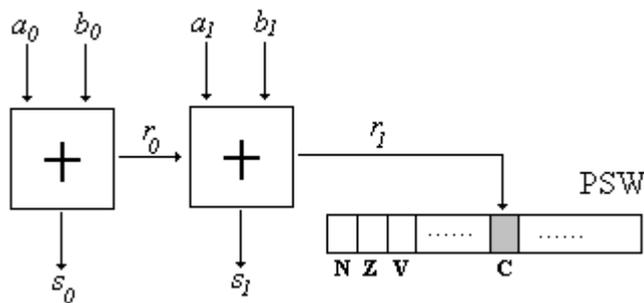
Les 4 interrupteurs figurent le passage du courant sur les bits de même rang des mémoires **a=2** et **b=3**, le résultat obtenu est la valeur attendue soit $2+3 = 5$.

Notation du circuit additionneur sur 2 bits :



Remarque :

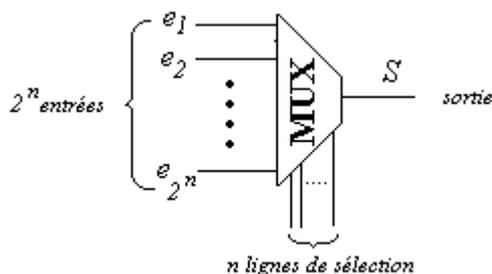
Ce circuit d'addition sur 2 bits engendre en fait en plus des bits de somme un troisième bit de retenue qui sera généralement mémorisé dans le bit de retenue (bit de carry noté C) du mot d'état programme ou PSW (Progral Status Word) du processeur. C'est le bit C de ce mot qui est consulté par exemple afin de savoir si l'opération d'addition a généré un bit de retenue ou non.



3.5 Circuit multiplexeur (circuit combinatoire)

C'est un circuit d'aiguillage comportant 2^n entrées, n lignes de sélection et une seule sortie. Les n lignes de sélection permettent de "programmer" le numéro de l'entrée qui doit être sélectionnée pour sortir sur une seule sortie (un bit). La construction d'un tel circuit nécessite 2^n circuits "et", n circuits "non" et 1 circuit "ou".

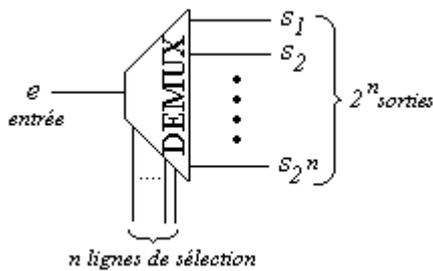
Notation du multiplexeur :



3.6 Circuit démultiplexeur (circuit combinatoire)

C'est un circuit qui fonctionne à l'inverse du circuit précédent, il permet d'aiguiller une seule entrée (un bit) sur l'une des 2^n sorties possibles, selon la "programmation" (l'état) de ses n lignes de sélection.

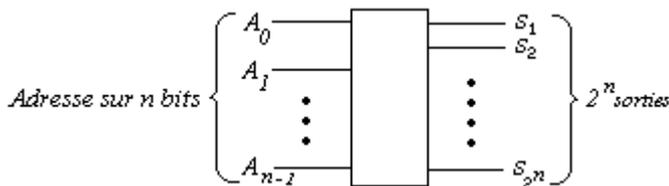
Notation du démultiplexeur :



3.7 Circuit décodeur d'adresse (circuit combinatoire)

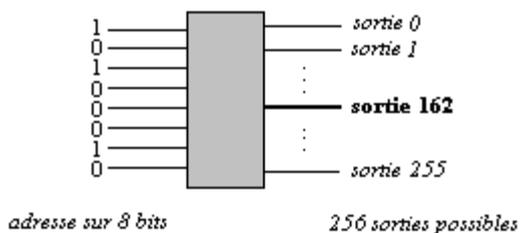
C'est un circuit composé de n lignes d'entrées qui représentent une adresse sur n bits et de 2ⁿ lignes de sortie possibles dont une seule est sélectionnée en fonction de la "programmation" des n lignes d'entrées.

Notation du décodeur d'adresse :



Exemple d'utilisation d'un décodeur d'adresse à 8 bits :

On entre l'adresse de la ligne à sélectionner soit 10100010 (A₀=1 , A₁= 0, A₂= 1, ... , A₇= 0) ce nombre binaire vaut 162 en décimal, c'est donc la sortie S₁₆₂ qui est activée par le composant comme le montre la figure ci-dessous.

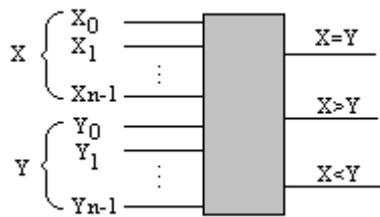


La construction d'un circuit décodeur d'adresse à n bits nécessite 2ⁿ circuits "et", n circuits "non". Ce genre de circuits très fréquent dans un ordinateur sert à sélectionner des registres, des cellules mémoires ou des lignes de périphériques.

3.8 Circuit comparateur (circuit combinatoire)

C'est un circuit réalisant la comparaison de deux mots X et Y de n bits chacun et sortant une des trois indication possible X=Y ou bien X>Y ou X<Y. Il possède donc 2n entrées et 3 sorties.

Notation du comparateur de mots à n bits :



3.9 Circuit bascule (circuit à mémoire)

C'est un circuit permettant de mémoriser l'état de la valeur d'un bit. Les bascules sont les principaux circuits constituant les registres et les mémoires dans un ordinateur.

Les principaux types de bascules sont RS, JK et D, ce sont des dispositifs chargés de "conserver" la valeur qu'ils viennent de prendre.

Schéma électronique et notation de bascule RS minimale théorique

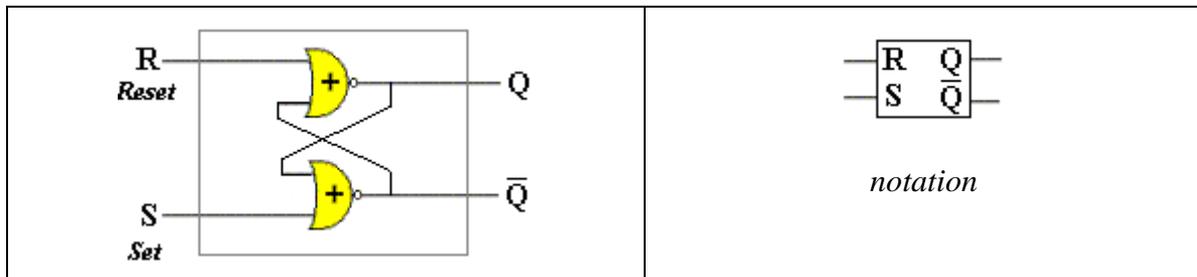


Table de vérité associée à cette bascule :

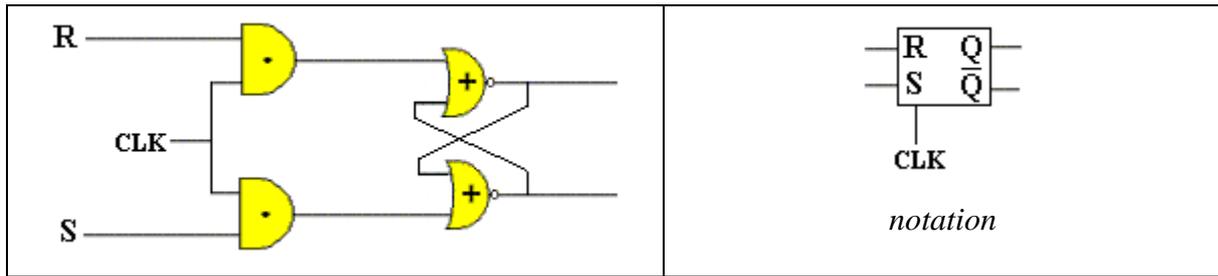
R	S	Qt+dt	
1	1	-----	Qt représente la valeur de la sortie au temps t, Qt+dt représente la valeur de cette même sortie un peu plus tard au temps t+dt.
1	0	0	L'état R=1 et S=1 n'est pas autorisé
0	1	1	
0	0	Qt	L'état R=0 et S=0 fait que Qt+dt = Qt, la sortie Q conserve la même valeur au cours du temps, le circuit "mémorise" donc un bit.

Si l'on veut que le circuit mémorise un bit égal à 0 sur sa sortie Q, on applique aux entrées les valeurs R=1 et S=0 au temps t₀, puis à t₀+dt on applique les valeurs R=0 et S=0. Tant que les entrées R et S restent à la valeur 0, la sortie Q conserve la même valeur (dans l'exemple Q=0).

En pratique ce sont des bascules RS synchronisées par des horloges (CLK pour clock) qui sont utilisées, l'horloge sert alors à commander l'état de la bascule. Seule la sortie Q est considérée.

Dans une bascule RS synchronisée, selon que le top d'horloge change d'état ou non et selon les valeurs des entrées R et S soit d'un top à l'autre la sortie Q du circuit ne change pas soit la valeur du top d'horloge fait changer (basculer) l'état de la sortie Q.

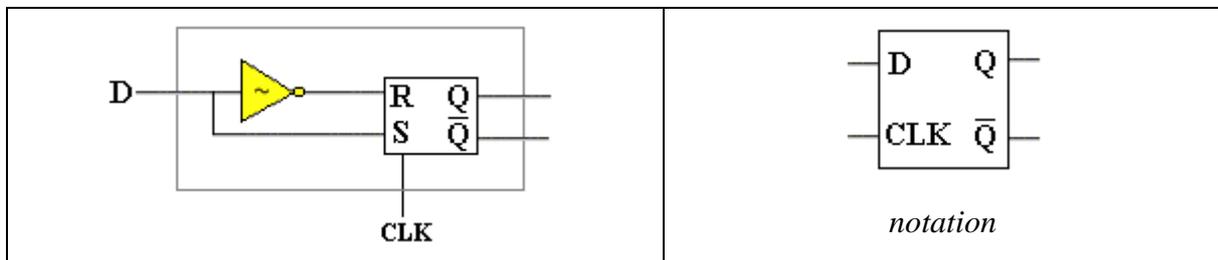
Schéma électronique général et notation d'une bascule RS synchronisée



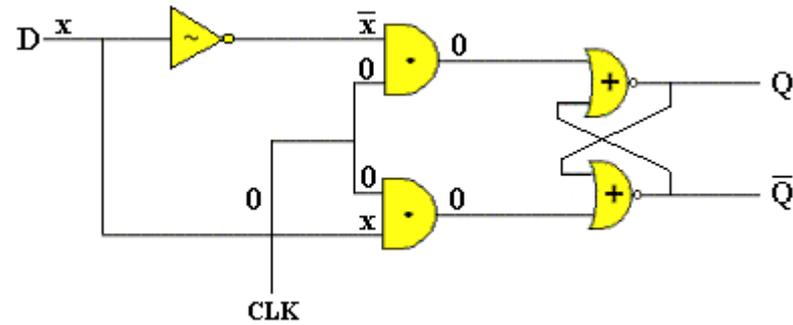
Remarque

Certains types de mémoires ou les registres dans un ordinateur sont conçus avec des variantes de bascules RS (synchronisées) notée JK ou D.

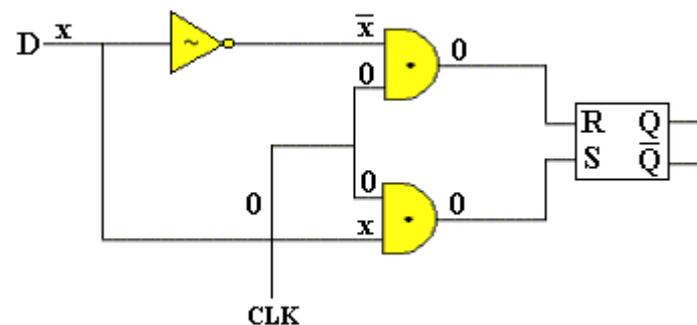
Schéma électronique général et notation d'une bascule de type D



Fonctionnement pratique d'une telle bascule D dont les entrées sont reliées entre elles. Supposons que la valeur de l'entrée soit le booléen x ($x=0$ ou bien $x=1$) et que l'horloge soit à 0.



En simplifiant le schéma nous obtenons une autre présentation faisant apparaître la bascule RS minimale théorique décrite ci-haut :



Or la table de vérité de cet élément lorsque les entrées sont égales à 0 indique que la bascule conserve l'état antérieur de la sortie Q :

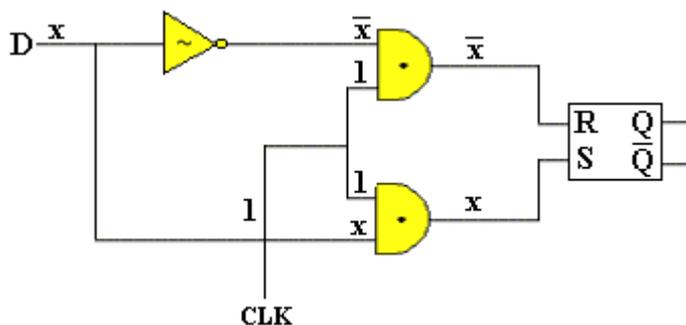
R	S	Qt+dt
0	0	Qt

Conclusion pour une bascule D

Lorsque l'horloge est à 0, quelque soit la valeur de l'entrée D (D=0 ou D=1) une bascule D conserve la même valeur sur la sortie Q.

Que se passe-t-il lorsque lors d'un top d'horloge celle-ci passe à la valeur 1 ?

Reprenons le schéma simplifié précédent d'une bascule D avec une valeur d'horloge égale à 1.



Nous remarquons que sur les entrées R et S nous trouvons la valeur x et son complément \bar{x} , ce qui élimine deux couples de valeurs d'entrées sur R et S (R=0, S=0) et (R=1, S=1). Nous sommes sûrs que le cas d'entrées non autorisé par un circuit RS (R=1, S=1) n'a jamais lieu dans une bascule de type D. Il reste à envisager les deux derniers couples (R=0, S=1) et (R=1, S=0). Nous figurons ci-après la table de vérité de la sortie Q en fonction de l'entrée D de la bascule (l'horloge étant positionnée à 1) et pour éclairer le lecteur nous avons ajouté les deux états associés des entrées internes R et S :

x	R	S	Q
0	1	0	0
1	0	1	1

Nous remarquons que la sortie Q prend la valeur de l'entrée D (D=x), elle change donc d'état.

Conclusion pour une bascule D

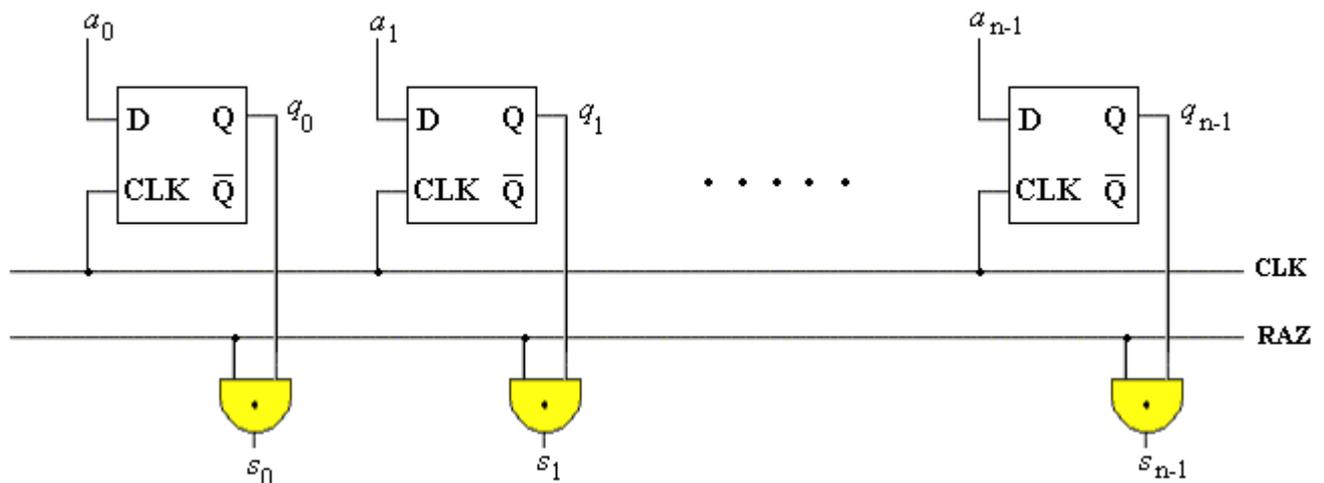
Lorsque l'horloge est à 1, quelque soit la valeur de l'entrée D (D=0 ou D=1) une bascule D change et prend sur la sortie Q la valeur de l'entrée D.

3.10 Registre (circuit à mémoire)

Un registre est un circuit qui permet la mémorisation de n bits en même temps. Il existe dans un ordinateur plusieurs variétés de registres, les registres parallèles, les registres à décalage (décalage à droite ou décalage à gauche) les registres séries.

Les bascules de type D sont les plus utilisées pour construire des registres de différents types en fonction de la disposition des entrées et des sorties des bascules : les registres à entrée série/sortie série, à entrée série/sortie parallèle, à entrée parallèle/sortie parallèle, à entrée parallèle/sortie série.

Voici un exemple de registre à n entrées parallèles (a_0, a_1, \dots, a_{n-1}) et à n sorties parallèles (s_0, s_1, \dots, s_{n-1}) construit avec des bascules de type D :



Examinons le fonctionnement de ce "registre parallèle à n bits"

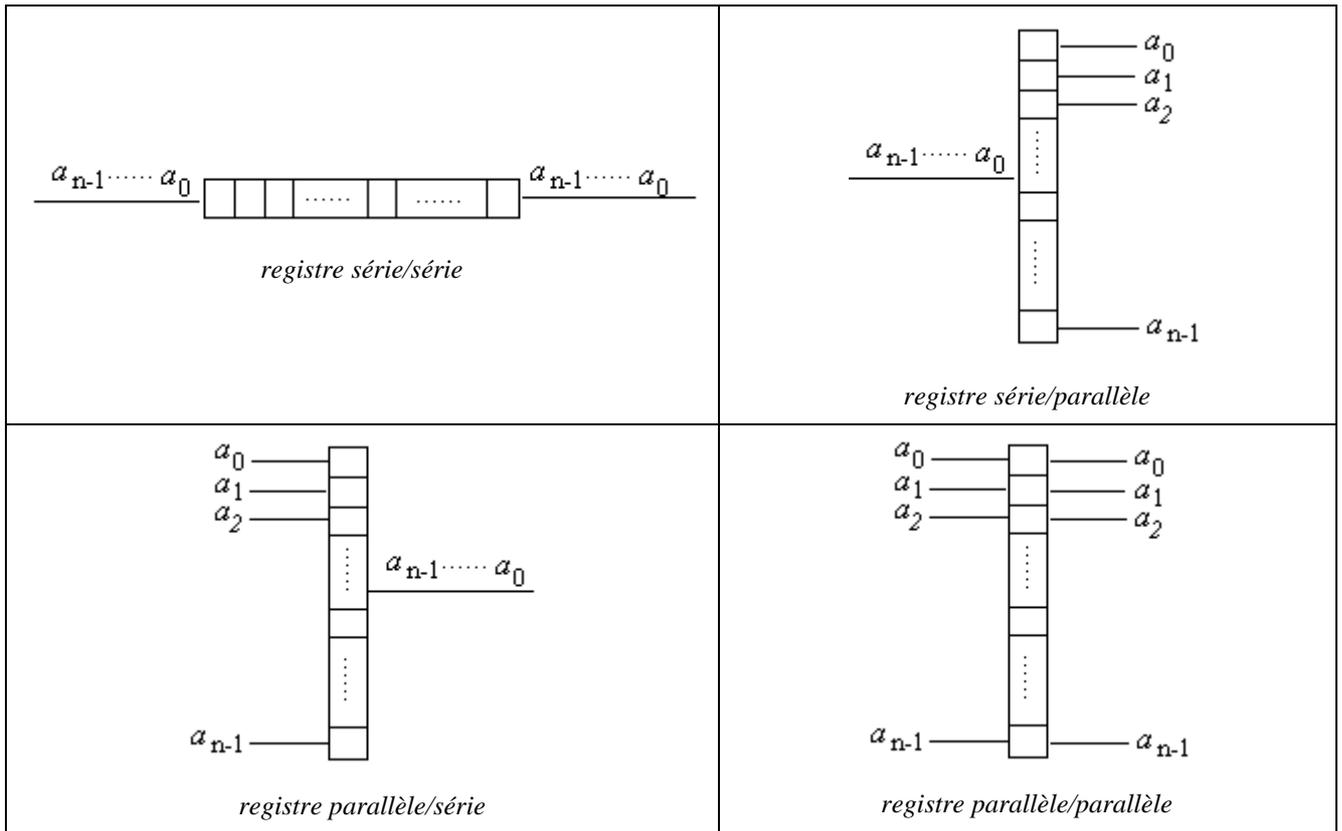
La ligne CLK fournit le signal d'horloge, la ligne RAZ permet l'effacement de toutes les sorties s_k du registre, on dit qu'elle fournit le **signal de validation** :

Lorsque RAZ = 0 on a ($s_0=0, s_1=0, \dots, s_{n-1}=0$)
Lorsque RAZ = 1 on a ($s_0= q_0, s_1= q_1, \dots, s_{n-1}= q_{n-1}$)

Donc RAZ=0 sert à effacer tous les bits de sortie du registre, dans le cas où RAZ=1 qu'en est-il des sorties s_k . D'une manière générale nous avons par construction $s_k = \text{RAZ} \cdot q_k$:

- Tant que CLK = 0 alors, comme RAZ=1 nous avons $s_k = q_k$ (q_k est l'état antérieur de la bascule). Dans ces conditions on dit que l'on "lit le contenu actuel du registre".
- Lorsque CLK = 1 alors, tous les q_k basculent et chacun d'eux prend la nouvelle valeur de son entrée a_k . Comme RAZ=1 nous avons toujours $s_k = q_k$ (q_k est le nouvel état de la bascule). Dans ces conditions on dit que l'on vient de "charger le registre" avec une nouvelle valeur.

Notations des différents type de registres :



Registre à décalage

C'est un registre à entrée série ou parallèle qui décale de 1 bit tous les bits d'entrée soit vers "la droite" (vers les bits de poids faibles), soit vers "la gauche" (vers les bits de poids forts). Un registre à décalage dans un ordinateur correspond soit à une multiplication par 2 dans le cas du décalage à gauche, soit à une division par 2 dans le cas du décalage à droite.

Conclusion mémoire-registre

Nous remarquons donc que les registres en général sont des mémoires construites avec des bascules dans lesquelles on peut lire et écrire des informations sous forme de bits. Toutefois dès que la quantité d'information à stocker est très grande les bascules prennent physiquement trop de place (2 NOR, 2 AND et 1 NON). Actuellement, pour élaborer une mémoire stockant de très grande quantité d'informations, on utilise une technologie plus compacte que celle des bascules, elle est fondée sur la représentation d'un bit par 1 transistor et 1 condensateur. Le transistor réalise la porte d'entrée du bit et la sortie du bit, le condensateur selon sa charge réalise le stockage du bit.

Malheureusement un condensateur ne conserve pas sa charge au cours du temps (courant de fuite inhérent au condensateur), il est alors indispensable de restaurer de temps en temps la charge du condensateur (opération que l'on dénomme **rafraîchir la mémoire**) et cette opération de rafraîchissement mémoire a un coût en temps de réalisation. Ce qui veut donc dire que pour le même nombre de bits à stocker un registre à bascule est plus rapide à lire ou à écrire qu'une mémoire à transistor, c'est pourquoi les mémoires internes des processeurs centraux sont des registres.

3.11 Mémoire SRAM et mémoire DRAM

Dans un ordinateur actuel coexistent deux catégories de mémoires :

1°) Les mémoires statiques SRAM élaborées à l'aide de bascules : très rapides mais volumineuses (plusieurs transistors pour 1 bit).

2°) Les mémoires dynamiques DRAM élaborées avec un seul transistor couplé à un condensateur : très facilement intégrables dans une petite surface, mais plus lente que les SRAM à cause de la nécessité du rafraîchissement.

Voici à titre indicatif des ordres de grandeur qui peuvent varier avec les innovations technologiques rapides en ce domaine :

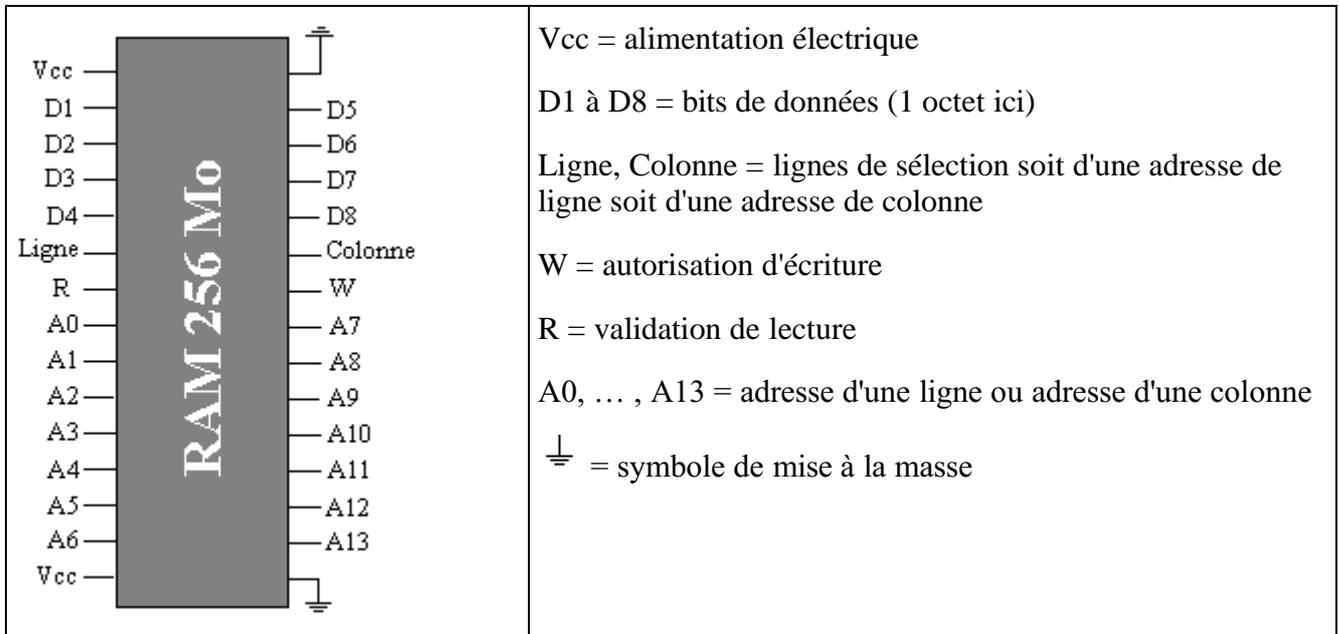
SRAM temps d'accès à une information : 5 nanosecondes
DRAM temps d'accès à une information : 50 nanosecondes

Fonctionnement d'une DRAM de 256 Mo fictive

La mémoire physique aspect extérieur :



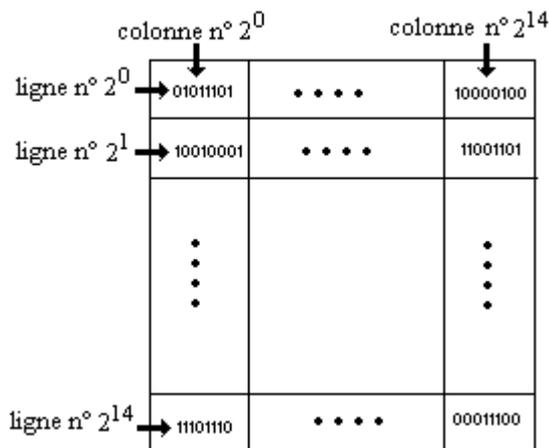
Le schéma général de la mémoire :



Nous adoptons une vision abstraite de l'organisation interne de cette mémoire sous forme d'une matrice de 2^{14} lignes et 2^{14} colonnes soient en tout $2^{14} \cdot 2^{14} = 2^{28}$ cellules de 1 octet chacune (2^{28} octets = $2^8 \cdot 2^{20} \text{ o} = 256 \cdot 2^{20} \text{ o} = 256 \text{ Mo}$, car $1 \text{ Mo} = 2^{20} \text{ o}$)

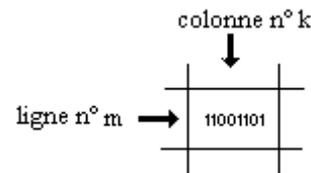
Ce qui donne une matrice de 16384 lignes et 16384 colonnes, numérotées par exemple de $2^0 = 1$

jusqu'à $2^{14} = 16384$, selon la figure ci-dessous :

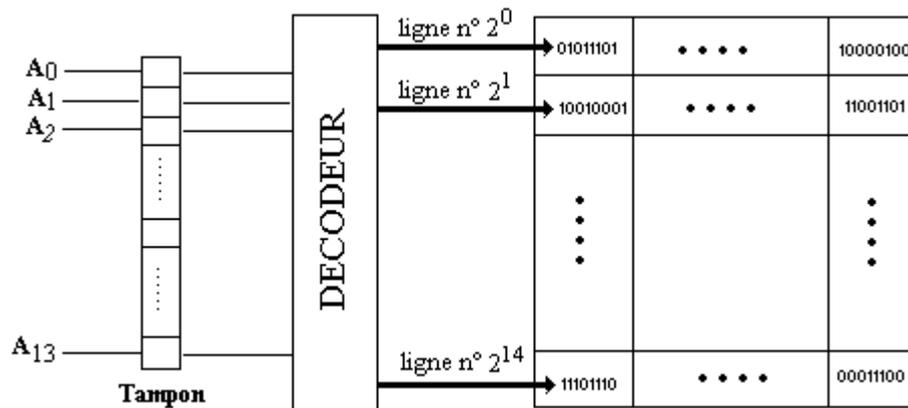


Dans l'exemple à gauche :

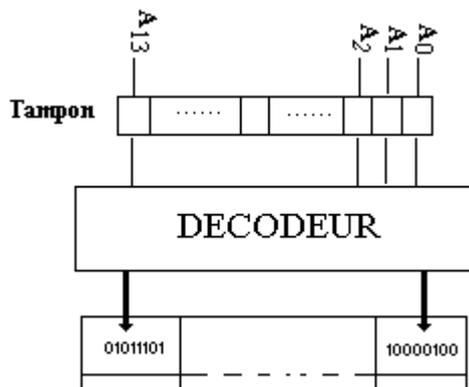
La sélection d'une ligne de numéro m donné (d'adresse $m-1$ donnée) et d'une colonne de numéro k donné (d'adresse $k-1$ donnée) permet de sélectionner directement une cellule contenant 8 bits.



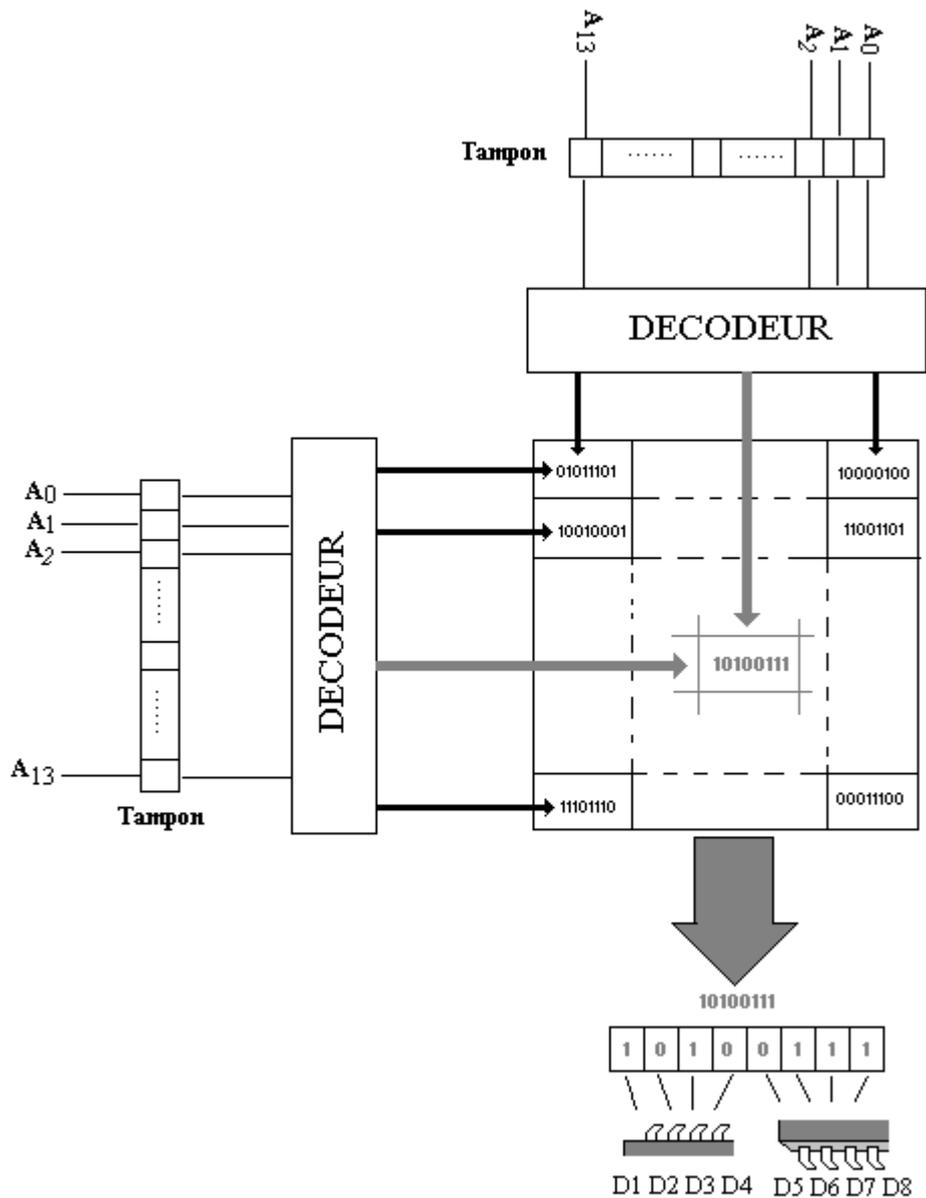
Exemple de sélection de ligne dans la matrice mémoire à partir d'une adresse (A_0, \dots, A_{13}), dans notre exemple théorique la ligne de numéro $2^0 = 1$ a pour adresse $(0,0,\dots,0)$ et la ligne de numéro $2^{14} = 16384$ a pour adresse $(1,1,\dots,1)$. Lorsque l'adresse de sélection d'une ligne arrive sur les pattes (A_0, \dots, A_{13}) de la mémoire elle est rangée dans un registre interne (noté tampon) puis passée à un circuit interne du type décodeur d'adresse à 14 bits (14 entrées et $2^{14} = 16384$ sorties) qui sélectionne la ligne adéquate.



Il en va de même pour la sélection d'une colonne :



La sélection d'une ligne, puis d'une colonne permet d'obtenir sur les pattes D, D2, ..., D8 de la puce les 8 bits sélectionnés. Ci dessous une sélection en mode lecture d'une cellule de notre mémoire de 256 Mo :

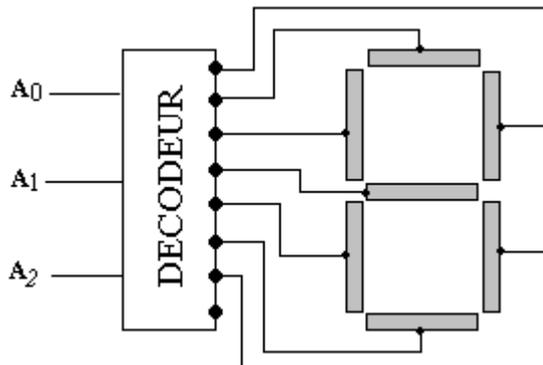


Il est possible aussi d'écrire dans une cellule de la mémoire selon la même démarche de sélection. Pour opérer une lecture il faut que la ligne de validation **R** de la mémoire soit activée, pour opérer une écriture, il faut que la ligne de validation **W** de la mémoire soit activée.

En attendant une nouvelle technologie (optique, quantique, organique,...) les constituants de base d'un ordinateur sont fondés sur l'électronique à base de transistor découverts à la fin des années quarante. De nos jours deux technologie de transistor sont présentes sur le marché : la technologie TTL (Transistor Transistor Logic) la plus ancienne et la technologie MOS (Metal Oxyde Semiconductor).

3.12 Afficheur LED à 7 segments

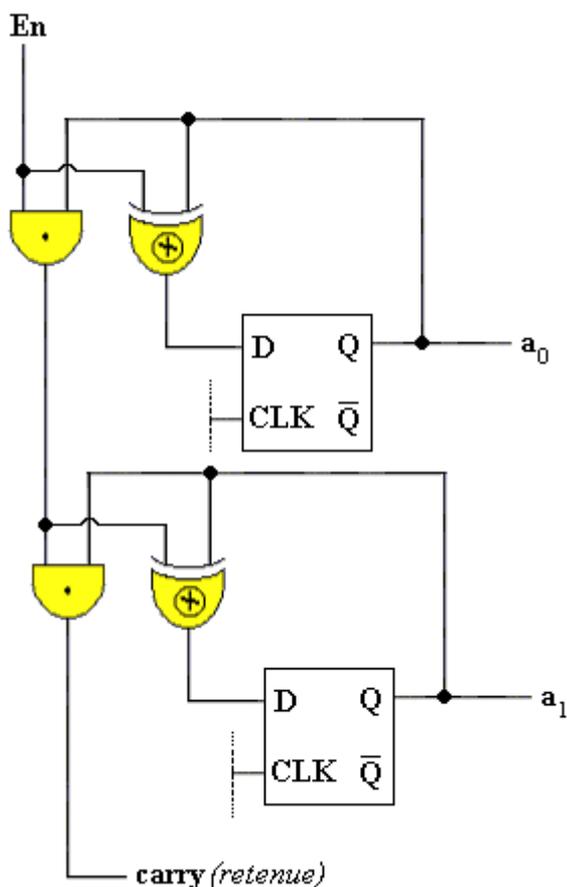
On utilise dans les ordinateurs des afficheurs à LED, composés de 7 led différentes qui sont allumées indépendamment les unes des autres, un circuit décodeur à 3 bits permet de réaliser simplement cet affichage :



3.13 Compteurs

Ce sont des circuits chargés d'effectuer un comptage cumulatif de divers signaux.

Par exemple considérons un compteur sur 2 bits avec retenue éventuelle, capable d'être activé ou désactivé, permettant de compter les changements d'état de la ligne d'horloge CLK. Nous proposons d'utiliser deux demi-additionneurs et deux bascules de type D pour construire le circuit.

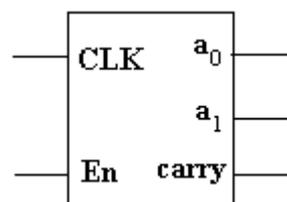


Le circuit compteur de gauche possède deux entrées **En** et **CLK**, il possède trois sorties a_0 , a_1 et carry.

Ce compteur sort sur les bits a_0 , a_1 et sur le bit de carry le nombre de changements en binaire de la ligne CLK (maximum 4 pour 2 bits) avec retenue s'il y a lieu.

La ligne d'entrée **En** est chargée d'activer ou de désactiver le compteur

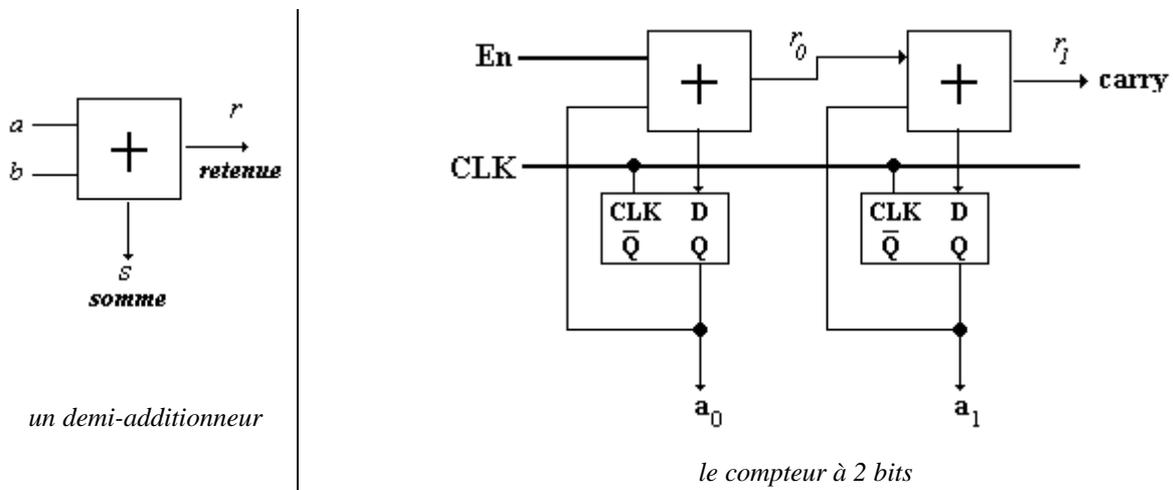
Notation pour ce compteur :



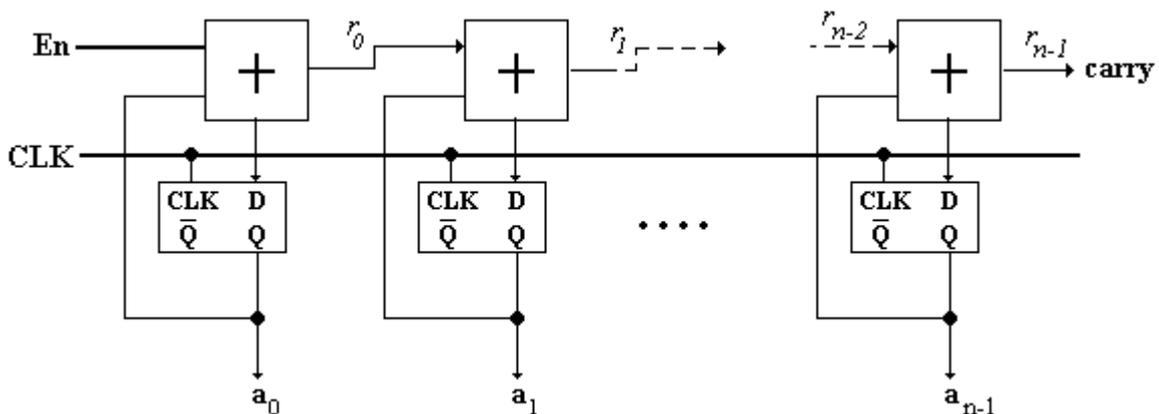
Fonctionnement de l'entrée **En** (enable) du compteur précédent :

- Lorsque $En = 0$, sur la première bascule en entrée D nous avons $D = a_0 \oplus 0$ (or nous savons que : $\forall x, x \oplus 0 = x$), donc $D = a_0$ et Q ne change pas de valeur. Il en est de même pour la deuxième bascule et son entrée D vaut a_1 . Donc quoiqu'il se passe sur la ligne CLK les sorties a_0 et a_1 ne changent pas, on peut donc dire que le comptage est **désactivé lorsque le enable est à zéro**.
- Lorsque $En = 1$, sur la première bascule en entrée D nous avons $D = a_0 \oplus 1$ (or nous savons que : $\forall x, x \oplus 1 = \bar{x}$), donc Q change de valeur. On peut donc dire que le comptage est **activé lorsque le enable est à un**.

Utilisons la notation du demi-additionneur pour représenter ce compteur à 2 bits :



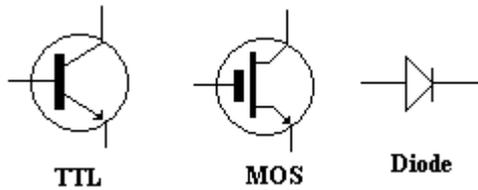
En généralisant à la notion de compteur à n bits nous obtenons le schéma ci-après :



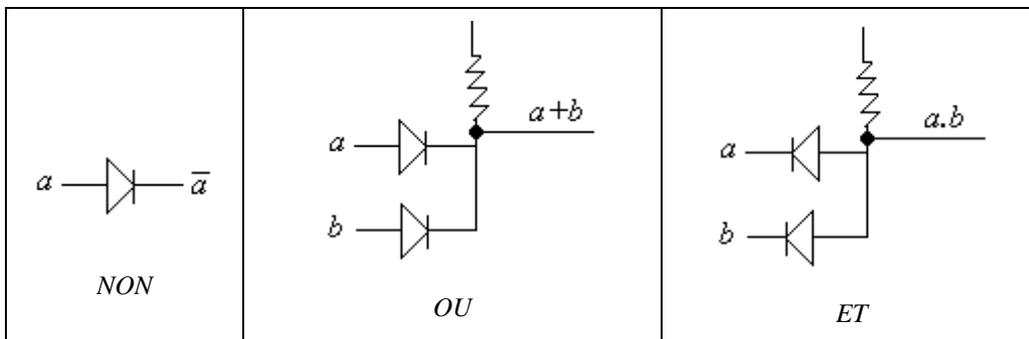
3.14 Réalisation électronique de circuits booléens

Dans ce paragraphe nous indiquons pour information anecdotique au lecteur, à partir de quelques exemples de schémas électroniques de base, les réalisations physiques possibles de différents opérateurs de l'algèbre de Boole.

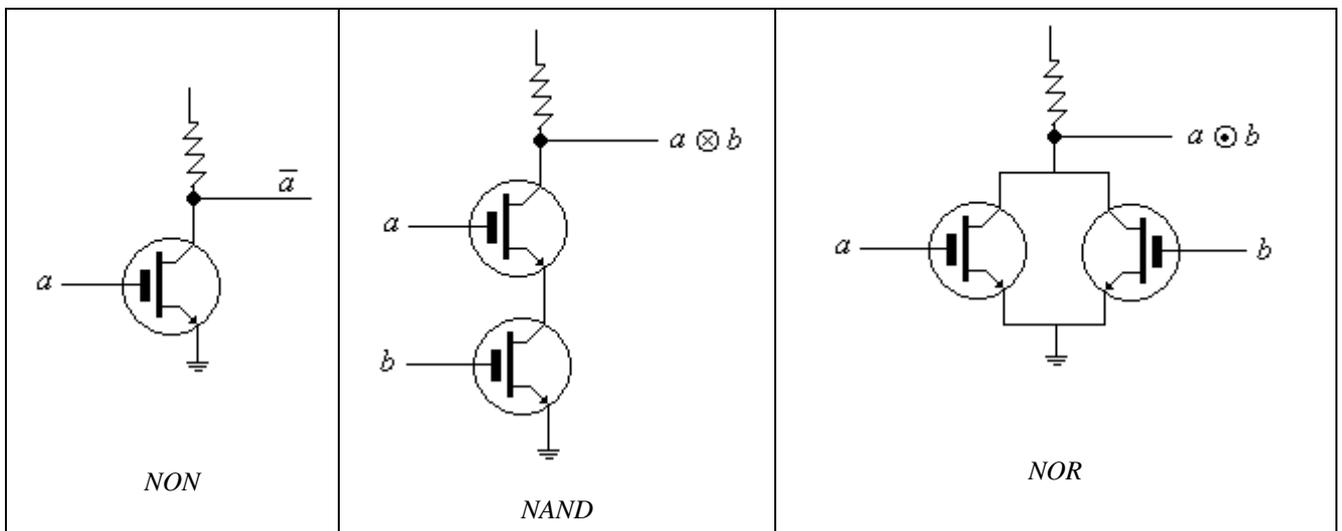
Le transistor est principalement utilisé comme un interrupteur électronique, nous utiliserons les schémas suivants représentant un transistor soit en TTL ou MOS et une diode.



Circuits (ET, OU, NON) élaborés à partir de diodes :

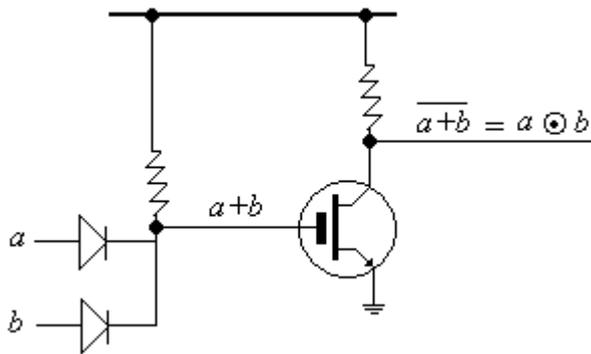


Circuits (NOR, NAND, NON) élaborés à partir de transistor MOS :



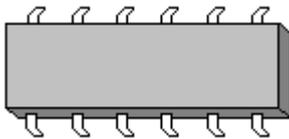
Ce sont en fait la place occupée par les composants électroniques et leur coût de production qui sont les facteurs essentiels de choix pour la construction des opérateurs logiques de base.

Voici par exemple une autre façon de construire une circuit NOR à partir de transistor et de diodes :

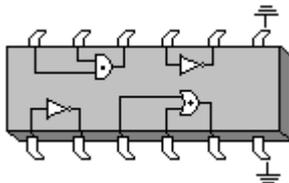


Le lecteur intéressé consultera des ouvrages d'électronique spécialisés afin d'approfondir ce domaine qui dépasse le champ de l'**informatique** qui n'est qu'une **simple utilisatrice** de la technologie électronique en attendant mieux !

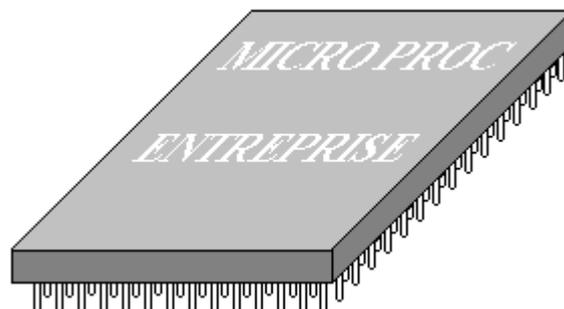
Finissons ce paragraphe, afin de bien fixer nos idées, par un schéma montrant comment dans une puce électronique sont situés les circuits booléens :



Supposons que la puce précédente permette de réaliser plusieurs fonctions et contienne par exemple 4 circuits booléens : un OU, un ET, deux NON. Voici figuré une possible implantation physique de ces 4 circuits dans la puce, ainsi que la liaison de chaque circuit booléen avec les pattes du composant physique :



Pour information, le micro-processeur pentium IV Northwood de la société Intel contient environ 55 000 000 (55 millions) de transistors, le micro-processeur 64 bits Opteron de la société concurrente AMD plus récent que le pentium IV, contient 105 000 000 (105 millions) de transistor.



1.3 Codage numération

Plan du chapitre: 

1. Codage de l'information

- 1.1 Codage en général : le pourquoi
- 1.2 Codage des caractères : code ASCII
- 1.3 Codage des nombres entiers : numération
- 1.4 Les entiers dans une mémoire à n+1 bits
- 1.5 Codage des nombres entiers
- 1.6 Un autre codage des nombres entiers

2. Numération

- 2.1 Opérations en binaire
- 2.2 Conversions base quelconque \leftrightarrow décimal
- 2.3 Exemple de conversion décimal \rightarrow binaire
- 2.4 Exemple de conversion binaire \rightarrow décimal
- 2.5 Conversion binaire \rightarrow hexadécimal
- 2.6 Conversion hexadécimal \rightarrow binaire

1. Codage de l'information

1.1 Codage en général : le pourquoi

- Dans une machine, toutes les informations sont codées sous forme d'une suite de "0" et de "1" (langage binaire). Mais l'être humain ne parle généralement pas couramment le langage binaire.
- Il doit donc tout "traduire" pour que la machine puisse exécuter les instructions relatives aux informations qu'on peut lui donner.
- Le codage étant une opération purement humaine, il faut produire des algorithmes qui permettront à la machine de traduire les informations que nous voulons lui voir traiter.

Le **codage** est une opération établissant une bijection entre une **information** et une **suite de "0" et de "1"** qui sont représentables en machine.

1.2 Codage des caractères : code ASCII

Parmi les codages les plus connus et utilisés, le codage **ASCII** (American Standard Code for Information Interchange) étendu est le plus courant (version **ANSI** sur Windows).

Voyons quelles sont les nécessités minimales pour l'écriture de documents alphanumériques simples dans la civilisation occidentale. Nous avons besoin de :

Un alphabet de lettres minuscules = {a, b, c, ..., z}
soient 26 caractères

Un alphabet de lettres majuscules = {A, B, C, ..., Z}
soient 26 caractères

Des chiffres {0, 1, ..., 9}
soient 10 caractères

Des symboles syntaxiques {?, ;, (, " ...
au minimum 10 caractères

Soit un total minimal de *72 caractères*

Si l'on avait choisi un code à 6 bits le nombre de caractères codables aurait été de $2^6 = 64$ (tous les nombres binaires compris entre **000000** et **111111**), nombre donc insuffisant pour nos besoins.

Il faut au minimum 1 bit de plus, ce qui permet de définir ainsi $2^7 = 128$ nombres binaires différents, autorisant alors le codage de 128 caractères.

Initialement le code **ASCII** est un code à 7 bits ($2^7 = 128$ caractères). Il a été étendu à un code sur 8 bits ($2^8 = 256$ caractères) permettant le codage des caractères nationaux (en France les caractères accentués comme : ù,à,è,é,â,...etc) et les caractères semi-graphiques.

Les pages HTML qui sont diffusées sur le réseau Internet sont en code ASCII 8 bits.

Un codage récent dit " universel " est en cours de diffusion : il s'agit du codage **Unicode** sur 16 bits ($2^{16} = 65536$ caractères).

De nombreux autres codages existent adaptés à diverses solutions de stockage de l'information (DCB, EBCDIC,...).

1.3 Codage des nombres entiers : numération

Les nombres entiers peuvent être codés comme des caractères ordinaires. Toutefois les codages adoptés pour les données autres que numériques sont trop lourds à manipuler dans un ordinateur. Du fait de sa constitution, un ordinateur est plus " habile " à manipuler des nombres écrits en numération binaire (qui est un codage particulier).

Nous allons décrire trois modes de codage des entiers les plus connus.

Nous avons l'habitude d'écrire nos nombres et de calculer dans le système décimal. Il s'agit en fait d'un cas particulier de numération en base 10.

Il est possible de représenter tous les nombres dans un système à base b (b entier, $b \geq 1$). Nous ne présenterons pas ici un cours d'arithmétique, mais seulement les éléments nécessaires à l'écriture dans les deux systèmes les plus utilisés en informatique : le binaire ($b=2$) et l'hexadécimal ($b=16$).

Lorsque nous écrivons **5876** en base 10, la position des chiffres 5,8,7,6 indique la puissance de 10 à laquelle ils sont associés :

5 est associé à 10^3
8 est associé à 10^2
7 est associé à 10^1
6 est associé à 10^0

Il en est de même dans une base b quelconque ($b=2$, ou $b=16$). Nous conviendrons de mentionner la valeur de la base au dessus du nombre afin de savoir quel est son type de représentation.

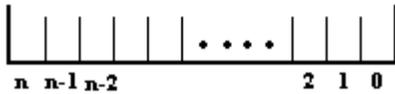
Soit $\overset{b}{x_n x_{n-1} \dots x_0}$ un nombre x écrit en base b avec $n+1$ symboles.

- " x_k " est le symbole associé à la puissance " b^k "
- " x_k " $\in \{0, 1, \dots, b-1\}$

Lorsque $b=2$ (numération binaire)

Chaque symbole du nombre x , " x_k " $\in \{0,1\}$; autrement dit les nombres binaires sont donc écrits avec des 0 et des 1, qui sont représentés physiquement par des bits dans la machine.

Voici le schéma d'une mémoire à $n+1$ bits (au minimum 8 bits dans un micro-ordinateur) :



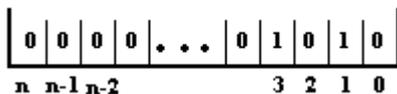
Les cases du schéma représentent les bits, le chiffre marqué en dessous d'une case, indique la puissance de 2 à laquelle est associé ce bit (on dit aussi le *rang* du bit).

Le bit de rang 0 est appelé le bit de **poinds faible**.
Le bit de rang n est appelé le bit de **poinds fort**.

1.4 Les entiers dans une mémoire à $n+1$ bits : binaire pur

Ce codage est celui dans lequel les nombres entiers **naturels** sont écrits en numération binaire (en base $b=2$).

Le nombre " dix " s'écrit **10** en base $b=10$, il s'écrit **1010** en base $b=2$. Dans la mémoire ce nombre dix est codé en binaire ainsi:



Une mémoire à $n+1$ bits ($n>0$), permet de représenter sous forme binaire (en binaire pur) tous les entiers naturels de l'intervalle $[0, 2^{n+1} - 1]$.

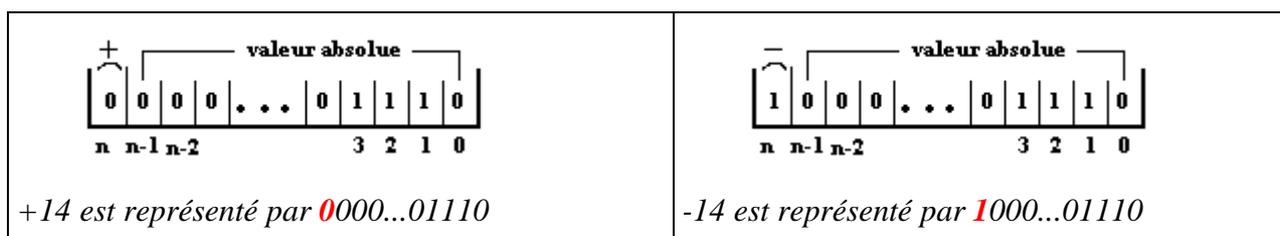
- soit pour $n+1=8$ bits, tous les entiers de l'intervalle $[0, 255]$
- soit pour $n+1=16$ bits, tous les entiers de l'intervalle $[0, 65535]$

1.5 Codage des nombres entiers : binaire signé

Ce codage permet la représentation des nombres entiers relatifs.

Dans la représentation en binaire signé, le bit de poids fort (*bit de rang n associé à 2^n*) sert à représenter le signe (0 pour un entier positif et 1 pour un entier négatif), les n autres bits représentent la valeur absolue du nombre en binaire pur.

Exemple du codage en binaire signé des nombres **+14** et **-14** :



Une mémoire à $n+1$ bits ($n > 0$), permet de représenter sous forme binaire (en binaire signé) tous les entiers naturels de l'intervalle $[-(2^n - 1), (2^n - 1)]$

- soit pour $n+1=8$ bits, tous les entiers de l'intervalle **[-127 , 127]**
- soit pour $n+1=16$ bits, tous les entiers de l'intervalle **[-32767 , 32767]**

Le nombre zéro est représenté dans cette convention (dites du zéro positif) par : **0000...00000**

Remarque : Il reste malgré tout une configuration mémoire inutilisée : **1000...00000**. Cet état binaire ne représente à priori aucun nombre entier ni positif ni négatif de l'intervalle $[-(2^n - 1), (2^n - 1)]$. Afin de ne pas perdre inutilement la configuration " **1000...00000** ", les informaticiens ont décidé que cette configuration représente malgré tout un nombre négatif parce que le bit de signe est 1, et en même temps la puissance du bit contenant le "1", donc par convention -2^n .

L'intervalle de représentation se trouve alors augmenté d'un nombre :
il devient : $[-2^n, 2^n - 1]$

- soit pour $n+1=8$ bits, tous les entiers de l'intervalle **[-128 , 127]**
- soit pour $n+1=16$ bits, tous les entiers de l'intervalle **[-32768 , 32767]**

Ce codage n'est pas utilisé tel quel, il est donné ici à titre pédagogique. En effet le traitement spécifique du signe coûte cher en circuits électroniques et en temps de calcul. C'est une version améliorée qui est utilisée dans la plupart des calculateurs : elle se nomme le complément à deux.

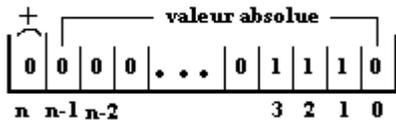
1.6 Un autre codage des nombres entiers : complément à deux

Ce codage, purement conventionnel et très utilisé de nos jours, est dérivé du binaire signé ; il sert à représenter en mémoire les entiers relatifs.

Comme dans le binaire signé, la mémoire est divisée en deux parties inégales; le bit de poids fort représentant le signe, le reste représente la valeur absolue avec le codage suivant :

Supposons que la mémoire soit à $n+1$ bits, soit x un entier relatif à représenter :

si $x > 0$, alors c'est la convention en *binaire signé* qui s'applique (le bit de signe vaut 0, les n bits restants codent le nombre), soit pour le nombre +14 :

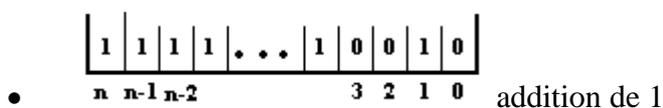
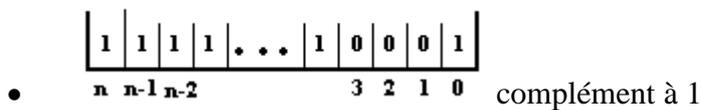
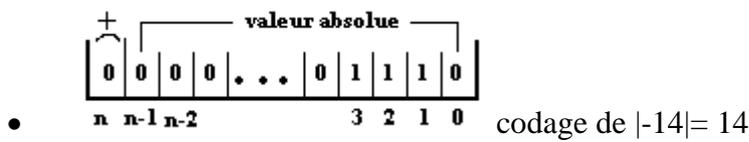


+14 est représenté par **0000...01110**

si $x < 0$, alors (3 étapes à suivre)

- On code la valeur absolue du nombre x , $|x|$ en binaire signé.
- Puis l'on complémente tous les bits de la mémoire (complément à 1 ou complément restreint). Cette opération est un **non** logique effectué sur chaque bit de la mémoire.
- Enfin l'on additionne +1 au nombre binaire de la mémoire (addition binaire).

Exemple, soit à représenter le nombre -14 en suivant les 3 étapes :



Le nombre -14 s'écrit donc en complément à 2 : **1111..10010**.

Un des intérêts majeurs de ce codage est d'intégrer la soustraction dans l'opération de codage et de ne faire effectuer que des opérations simples et rapides (non logique, addition de 1).

Nous venons de voir que le codage utilisait essentiellement la représentation d'un nombre en binaire (la numération binaire) et qu'il fallait connaître les rudiments de l'arithmétique binaire. Le paragraphe ci-après traite de ce sujet.

2. Numération

Ce paragraphe peut être ignoré par ceux qui connaissent déjà les éléments de base des calculs en binaire et des conversions binaire-décimal-hexadécimal, dans le cas contraire, il est conseillé de le lire.

Pour des commodités d'écriture, nous utilisons la notation indicée pour représenter la base d'un nombre en parallèle de la représentation avec la barre au dessus. Ainsi 145_{10} signifie le nombre 145 en base dix; 1101011_2 signifie 1101011 en binaire.

2.1 Opérations en binaire

Nous avons parlé d'addition en binaire ; comme dans le système décimal, il nous faut connaître les tables d'addition, de multiplication, etc... afin d'effectuer des calculs dans cette base. Heureusement en binaire, elles sont très simples :

+	0	1
0	0	1
1	1	0(1)

*	0	1
0	0	0
1	0	1

0(1) représente la retenue 1 à reporter.

Exemples de calculs ($109+19=128_{10}=10000000_2$) et ($22 \times 5=110$) :

addition

multiplication

$\begin{array}{r} 1101101 \\ + 10011 \\ \hline 10000000_2 = 128_{10} \end{array}$	$\begin{array}{r} 10110 \\ \times 101 \\ \hline 10110 \\ 10110. \\ \hline 1101110_2 = 110_{10} \end{array}$
---	---

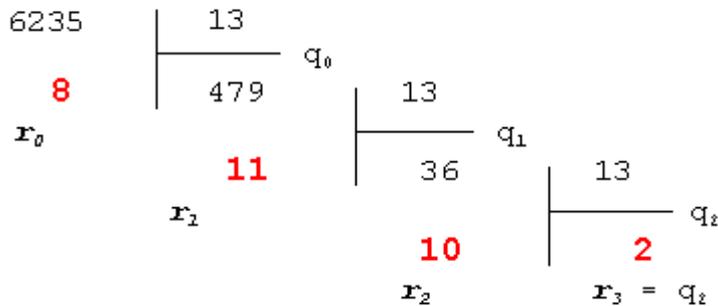
Vous noterez que le procédé est identique à celui que vous connaissez en décimal. En hexadécimal (b=16) il en est de même. Dans ce cas les tables d'opérateurs sont très longues à apprendre.

Etant donné que le système classique utilisé par chacun de nous est le système décimal, nous nous proposons de fournir d'une manière pratique les conversions usuelles permettant d'écrire les diverses représentations d'un nombre entre les systèmes décimal, binaire et hexadécimal.

Cet algorithme permet d'obtenir une représentation de a dans la base b.

Exemple :

$\overline{6235}^{10}$ à convertir en base $b=13$
 les symboles de la base 13 sont: $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C\}$



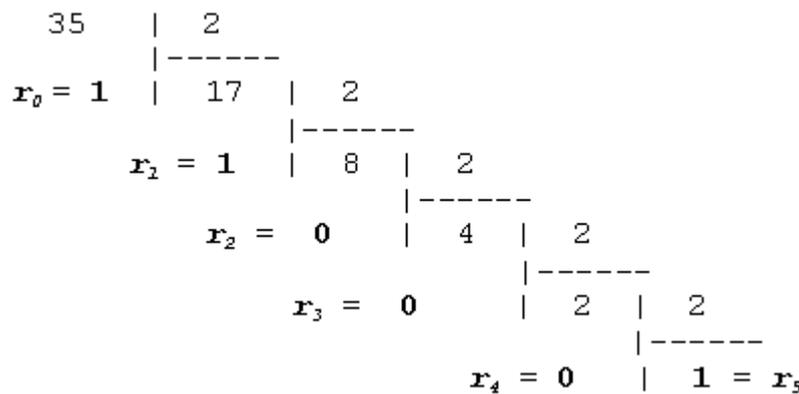
Les p_i équivalents en base 13 sont:

$r_0 = 8 \rightarrow p_0 = 8$
 $r_1 = 11 \rightarrow p_1 = B$
 $r_2 = 10 \rightarrow p_2 = A$
 $r_3 = 2 \rightarrow p_3 = 2$ Donc $6235_{10} = 2AB8_{13}$

Dans les deux paragraphes suivants nous allons expliciter des exemples pratiques de ces méthodes dans le cas où la base est 2 (binaire).

2.3 Exemple de conversion décimal → binaire

Soit le nombre décimal 35_{10} , appliquons l'algorithme précédent afin de trouver les restes successifs :



Donc : $35_{10} = 10011_2$

2.4 Exemple de conversion binaire → décimal

Soit le nombre binaire : 1101101_2
sa conversion en décimal est immédiate :

$$1101101_2 = 2^6 + 2^5 + 2^3 + 2^2 + 1 = 64 + 32 + 8 + 4 + 1 = 109_{10}$$

Les informaticiens, pour des raisons de commodité (manipulations minimales de symboles), préfèrent utiliser l'hexadécimal plutôt que le binaire. L'humain, contrairement à la machine, a quelques difficultés à fonctionner sur des suites importantes de 1 et de 0. Ainsi l'hexadécimal (sa base $b=2^4$ étant une puissance de 2) permet de diviser, en moyenne, le nombre de symboles par un peu moins de 4 par rapport au même nombre écrit en binaire. C'est l'unique raison pratique qui justifie son utilisation ici.

2.5 Conversion binaire → hexadécimal

Nous allons détailler l'action de conversion en 6 étapes pratiques :

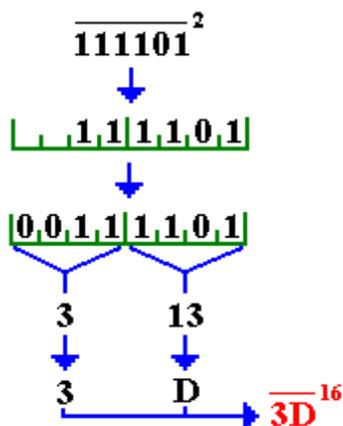
- Soit a un nombre écrit en **base 2** (*étape 1*).
- On décompose ce nombre par tranches de 4 bits à partir du bit de poids faible (*étape 2*).
- On complète la dernière tranche (celle des bits de poids forts) par des 0 s'il y a lieu (*étape 3*).
- On convertit chaque tranche en son symbole de la **base 16** (*étape 4*).
- On réécrit à sa place le nouveau symbole par changements successifs de chaque groupe de 4 bits, (*étape 5*).
- Ainsi, on obtient le nombre écrit en hexadécimal (*étape 6*).

Exemple :

Soit le nombre 111101_2
à convertir en hexadécimal.

Résultat obtenu :

$$111101_2 = 3D_{16}$$



2.6 Conversion hexadécimal → binaire

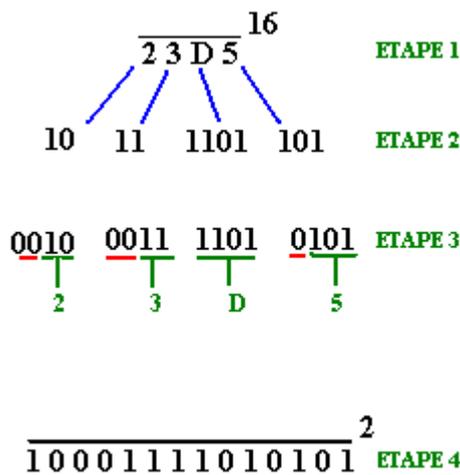
Cette conversion est l'opération inverse de la précédente. Nous allons la détailler en 4 étapes :

- Soit a un nombre écrit en **base 16** (*ETAPE 1*).
- On convertit chaque symbole hexadécimal du nombre en son écriture binaire (nécessitant au plus 4 bits) (*ETAPE 2*).
- Pour chaque tranche de 4 bits, on complète les bits de poids fort par des 0 s'il y a lieu (*ETAPE 3*).
- Le nombre " a " écrit en binaire est obtenu en regroupant toutes les tranches de 4 bits à partir du bit de poids faible, sous forme d'un seul nombre binaire (*ETAPE 4*).

Exemple :

Soit le nombre $23D5_{16}$

à convertir en binaire.



Résultat obtenu :

$23D5_{16} = 10001111010101_2$

1.4 Formalisation de la notion d'ordinateur

Plan du chapitre: 

1. Machine de Turing théorique

- 1.1 Définition : machine de Turing
- 1.2 Définition : Etats de la machine
- 1.3 Définition : Les règles de la machine

2. La Machine de Turing physique

- 2.1 Constitution interne
- 2.2 Fonctionnement
- 2.3 Exemple : machine de Turing arithmétique
- 2.4 Machine de Turing informatique

1. La Machine de Turing théorique

Entre 1930 et 1936 le mathématicien anglais A.Turing invente sur le papier une machine fictive qui ne pouvait effectuer que 4 opérations élémentaires que nous allons décrire. Un des buts de Turing était de faire résoudre par cette " machine " des problèmes mathématiques, et d'étudier la classe des problèmes que cette machine pourrait résoudre.

Définitions et notations (modèle déterministe)

Soit A un ensemble fini appelé *alphabet* défini ainsi :

$$A = \{ a_1, \dots, a_n \} \quad (A \neq \emptyset)$$

Soit $\Omega = \{ D, G \}$ une paire

1.1 Définition : machine de Turing

Nous appellerons machine de Turing toute application T :

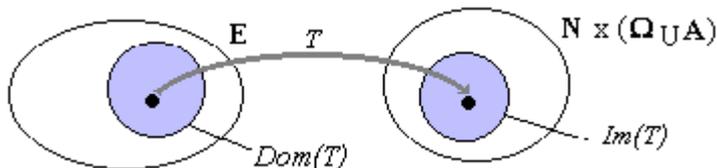
$$T : E \rightarrow \mathbf{N} \times (\Omega \cup A)$$

où E est un ensemble fini non vide : $E \subset \mathbf{N} \times A$

1.2 Définition : Etats de la machine

Nous appellerons E_t ensemble des états intérieurs de la machine T:

$$E_t = \left\{ q_i \in \mathbf{N} , (\exists a_i \in A / (q_i, a_i) \in \text{Dom}(T)) \quad \text{où} \quad (\exists x \in \Omega / (q_i, x) \in \text{Im}(T)) \right\}$$



$\text{Dom}(T)$: domaine de définition de T.

$\text{Im}(T)$: image de T (les éléments $T(a)$ de $\mathbf{N} \times (\Omega \cup A)$, pour $a \in E$)

Comme E est un ensemble fini, E_t est nécessairement un ensemble fini, donc il y a un nombre fini d'états intérieurs notés q_i .

1.3 Définition : Les règles de la machine

Nous appellerons " ensemble des règles " de la machine T, le graphe G de l'application T. Une règle de T est un élément du graphe G de T.

On rappelle que le graphe de T est défini comme suit :

$$G = \{ (a, b) \in E \times [E_t \times (\Omega \cup A)] / b = T(a) \}$$

- **Notation** : afin d'éviter une certaine lourdeur dans l'écriture nous conviendrons d'écrire les règles en omettant les virgules et les parenthèses.
- **Exemple** : la règle $((q_i, a), (q_k, b))$ est notée : $q_i a q_k b$

2. La Machine de Turing physique

2.1 Constitution interne

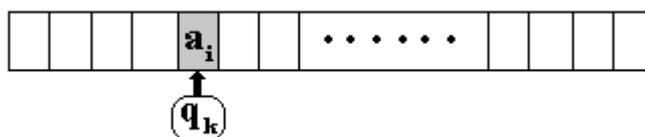
Nous construisons une machine de Turing physique constituée de :

- Une boîte notée UC munie d'une tête de lecture-écriture et d'un registre d'état.
- Un ruban de papier supposé sans limite vers la gauche et vers la droite.
- Sur le ruban se trouvent des cases contiguës contenant chacune un seul élément de l'alphabet A.
- La tête de lecture-écriture travaille sur la case du ruban située devant elle ; elle peut lire le contenu de cette case ou effacer ce contenu et y écrire un autre élément de A.
- Il existe un dispositif d'entraînement permettant de déplacer la tête de lecture-écriture d'une case vers la **Droite** ou vers la **Gauche**.
- Dans la tête lecture-écriture il existe une case spéciale notée *registre d'état*, qui sert à recevoir un élément q_i de E_t .

Cette machine physique est une représentation virtuelle d'une machine de Turing théorique T, d'alphabet A, dont l'ensemble des états est E_t , dont le graphe est donné ci-après :

$$G = \{ (a, b) \in E \times [E_t \times (\Omega \cup A)] / b = T(a) \}$$

Donnons une visualisation schématique d'une telle machine en cours de fonctionnement. La tête de lecture/écriture pointe vers une case contenant l'élément a_i de A, le registre d'état ayant la valeur q_k :



2.2 Fonctionnement

Départ :

On remplit les cases du ruban d'éléments a_i de A .

On met la valeur " q_k " dans le registre d'état.

On positionne la tête sur une case contenant " a_i ".

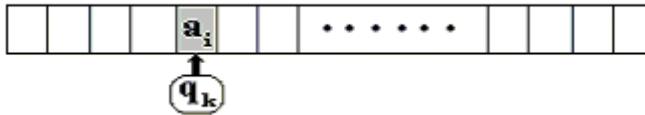
Actions : (la machine se met en marche)

La tête lit le " a_i ". L'UC dont le registre d'état vaut " q_k ", cherche dans la liste des règles si le couple $(q_k, a_i) \in \text{Dom}(T)$.

Si la réponse est *négative* on dit que la machine "bloque" (elle s'arrête par blocage).

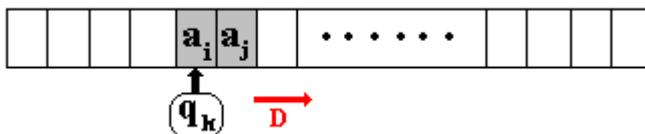
Si la réponse est *positive* alors le couple (q_k, a_i) a une image unique (machine déterministe) que nous notons (q_n, y) . Dans ce couple, y ne peut prendre que l'un des 3 types de valeurs possibles a_p, D, G :

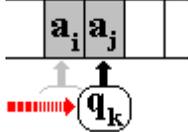
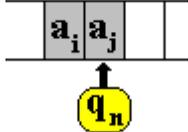
- *a)* soit $y = a_p$, dans ce cas la règle est donc de la forme $q_k a_i q_n a_p$



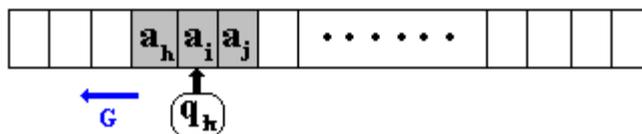
<p>a.1) L'UC fait effacer le a_i dans la case et le remplace par l'élément a_p.</p>	
<p>a.2) L'UC écrit q_n dans le registre d'état en remplacement de la valeur q_k.</p>	

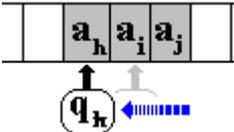
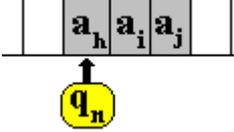
- *b)* soit $y = D$, ici la règle est donc de la forme $q_k a_i q_n D$



<p>b.1) L'UC fait déplacer la tête vers la droite d'une case.</p>	
<p>b.2) L'UC écrit q_n dans le registre d'état en remplacement de la valeur q_k.</p>	

- c) soit $y = G$, dans ce cas la règle est donc de la forme $q_k a_i q_n G$



<p>c.1) L'UC fait déplacer la tête vers la gauche d'une case.</p>	
<p>c.2) L'UC écrit q_n dans le registre d'état en remplacement de la valeur q_k.</p>	

Puis la machine continue à fonctionner en recommençant le cycle des actions depuis le début : lecture du nouvel élément a_k etc...

2.3 Exemple : machine de Turing arithmétique

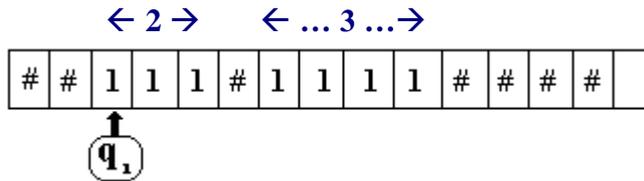
Nous donnons ci-dessous une machine T_1 additionneuse en arithmétique unaire.

$$A = \{\#, 1\}$$

$$\Omega = \{D, G\}$$

un entier n est représenté par $n+1$ symboles " 1 " consécutifs (de façon à pouvoir représenter " 0 " par un unique " 1 ").

Etat initial du ruban avant actions :



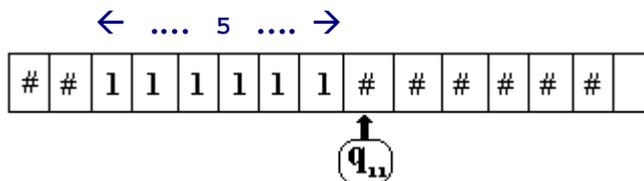
2 est représenté par 111
3 est représenté par 1111

Règles T₁: (application des règles suivantes pour simulation de 2+3)

q ₁ 1 q ₂ D	q ₆ 1 q ₇ D	q ₁₁ 1 q ₁₂ #
q ₂ 1 q ₃ D	q ₇ 1 q ₈ D	q ₁₂ # q ₁₃ G
q ₃ 1 q ₄ D	q ₈ 1 q ₉ D	q ₁₃ 1 q ₁₄ #
q ₄ # q ₅ 1	q ₉ 1 q ₁₀ D	
q ₅ 1 q ₆ D	q ₁₀ # q ₁₁ G	

En démarrant la machine sur la configuration précédente on obtient :

Etat final du ruban après actions : (Cette machine ne fonctionne que pour additionner 2 et 3)



Généralisation de la machine additionneuse

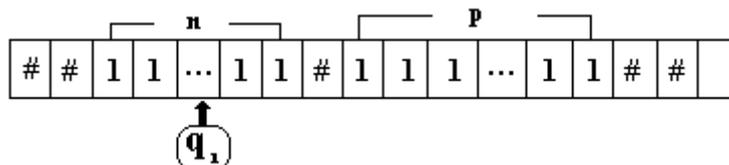
Il est facile de fournir une autre version plus générale T₂ fondée sur la même stratégie et le même état initial permettant d'additionner non plus seulement les nombres 2 et 3, mais des nombres entiers quelconques n et p. Il suffit de construire des nouvelles règles.

Règles de T₂:

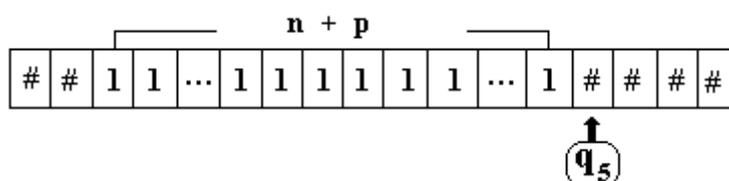
q ₁ 1 q ₁ D	q ₃ 1 q ₃ #
q ₁ # q ₂ 1	q ₃ # q ₄ G
q ₂ 1 q ₂ D	q ₄ 1 q ₅ #
q ₂ # q ₃ G	

Cette machine de Turing T_2 appliquée à l'exemple précédent (addition de 2 et 3) laisse le ruban dans le même état final, mais elle est construite avec moins d'états intérieurs que la précédente.

En fait elle fonctionne aussi si la tête de lecture-écriture est positionnée sur n'importe lequel des éléments du premier nombre n . et les nombres n et p sont quelconques :



Etat initial sur le nombre de gauche



Etat final à la fin du nombre calculé (il y a $n+p+1$ symboles " 1 ")

Nous dirons que T_2 est plus " puissante " que T_1 au sens suivant :

- T_2 a moins d'états intérieurs que T_1 .
- T_2 permet d'additionner des entiers quelconques.
- Il est possible de démarrer l'état initial sur n'importe lequel des " 1 " du nombre de gauche.

On pourrait toujours en ce sens chercher une machine T_3 qui posséderait les qualités de T_2 , mais qui pourrait démarrer sur n'importe lequel des " 1 " de l'un ou l'autre des deux nombres n ou p , le lecteur est encouragé à chercher à écrire les règles d'une telle machine.

Nous voyons que ces machines sont capables d'effectuer des opérations, elles permettent de définir la classe des **fonctions calculables** (par machines de Turing).

Un ordinateur est fondé sur les principes de calcul d'une machine de Turing. J. Von Neumann a défini la structure générale d'un ordinateur à partir des travaux de A.Turing. Les éléments physiques supplémentaires que possède un ordinateur moderne n'augmentent pas sa puissance théorique. Les fonctions calculables sont les seules que l'on puisse implanter sur un ordinateur. Les périphériques et autres dispositifs auxiliaires extérieurs ou intérieurs n'ont pour effet que d'améliorer la " puissance " en terme de vitesse et de capacité. Comme une petite voiture de série et un bolide de formule 1 partagent les mêmes concepts de motorisation, de la même manière les différents ordinateurs du marché partagent les mêmes fondements mathématiques.

2.4 Machine de Turing informatique

Nous faisons évoluer la représentation que nous avons de la machine de Turing afin de pouvoir mieux la programmer, c'est à dire pouvoir écrire plus facilement les règles de fonctionnement d'une telle machine.

Nous définissons ce qu'est un algorithme pour une machine de Turing et nous proposons une description graphique de cet algorithme à l'aide de schémas graphiques symboliques décrivant des actions de base d'une machine de Turing.

A) Une machine de Turing informatique est dite normalisée au sens suivant :

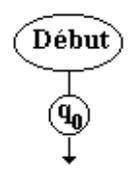
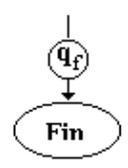
- L'alphabet A contient toujours le symbole " # " .
- L'ensemble des états E contient toujours deux états distingués q_0 (état initial) et q_f (état final).
- La machine démarre toujours à l'état initial q_0 .
- Elle termine sans blocage toujours à l'état q_f .
- Dans les autres cas on dit que la machine " bloque " .

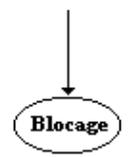
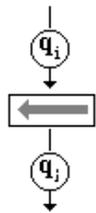
B) Algorithme d'une machine de Turing informatique

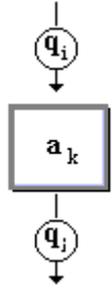
C'est l'ensemble des règles précises qui définissent un procédé de calcul destiné à obtenir en sortie un " **résultat** " déterminé à partir de certaines " **données** " initiales.

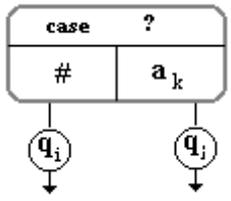
C) Algorithme graphique d'une machine de Turing

Nous utilisons cinq classes de symboles graphiques

	Positionne la tête de lecture sur le symbole voulu, met la machine à l'état initial q_0 et fait démarrer la machine.
	Signifie que la machine termine correctement son calcul en s'arrêtant à l'état final q_f .

	<p>Aucune règle de la machine ne permettant la poursuite du fonctionnement, arrêt de la machine sur un blocage.</p>
	<p>Déplacer la tête d'une case vers la gauche (la tête de lecture se positionne sur la case d'avant la case actuelle contenant le symbole a_p). Correspond à la règle : $q_i a_p q_j G$</p>

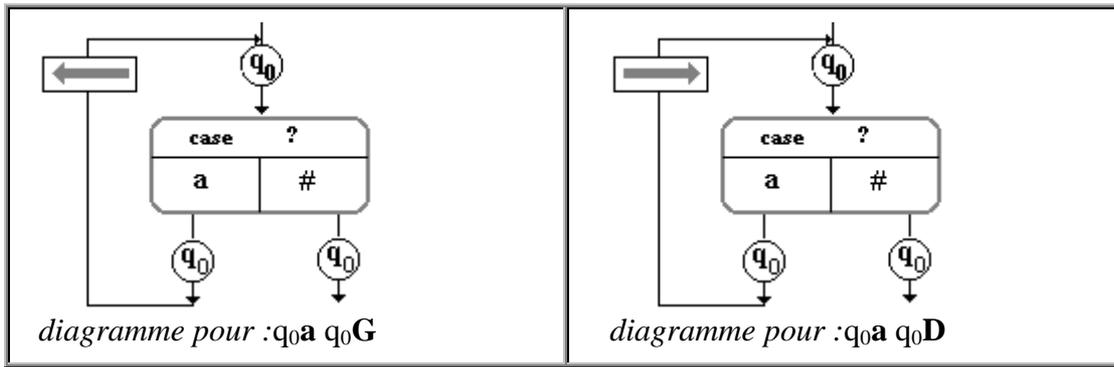
	<p>Correspond à l'action à exécuter dans la deuxième partie de la règle :</p> <p>$q_i a_p q_j a_k$ (la machine écrit a_k dans la case actuelle et passe à l'état q_j).</p>
--	---

	<p>Correspond à l'action à exécuter dans la première partie de la règle :</p> <p>$q_j a_k \dots$ ou $q_i \# \dots$ (la machine teste le contenu de la case actuelle et passe à l'état q_j ou à l'état q_i selon la valeur du contenu).</p>
---	--

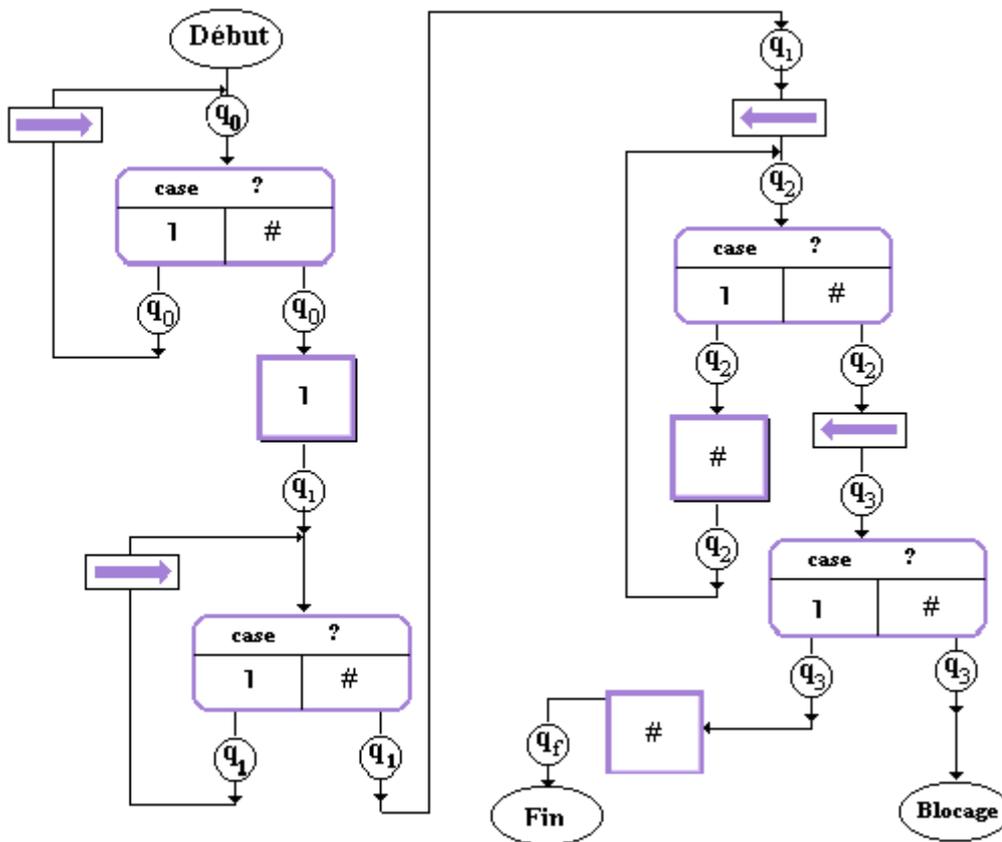
D) Organigramme d'une machine de Turing

On appelle organigramme d'une machine de Turing T, toute représentation graphique constituée de combinaisons des symboles des **cinq classes précédentes**.

Les règles de la forme $q_n a_k q_n G$ ou $q_n a_k q_n D$ se traduisent par des schémas " bouclés " ce qui donne des organigrammes non linéaires.



Exemple : organigramme de la machine T_2 normalisée (additionneuse $n+p$)



Règles de T_2 normalisée :

$q_0 \ 1 \ q_0 \mathbf{D}$	$q_2 \ 1 \ q_2 \#$
$q_0 \ # \ q_1 \mathbf{1}$	$q_2 \ # \ q_3 \mathbf{G}$
$q_1 \ 1 \ q_1 \mathbf{D}$	$q_3 \ 1 \ q_1 \#$
$q_1 \ # \ q_2 \mathbf{G}$	

Nous voyons que ce symbolisme graphique est un outil de description du mode de traitement de l'information au niveau machine. C'est d'ailleurs historiquement d'une façon semblable que les premiers programmeurs décrivaient leur programmes.

1.5 Architecture de l'ordinateur

Plan du chapitre: 

Les principaux constituants

- 1.1 Dans l'Unité Centrale : l'unité de traitement
- 1.2 Dans l'Unité Centrale : l'unité de commande
- 1.3 Dans l'Unité Centrale : les Unités d'échange
- 1.4 Exemples de machine à une adresse : un micro-processeur simple
- 1.5 Les Bus
- 1.6 Schéma général d'une micro-machine fictive
- 1.7 Notion de jeu d'instructions-machine
- 1.8 Architectures RISC et CISC
- 1.9 Pipe line dans un processeur
- 1.10 Architectures super-scalaire
- 1.11 Principaux modes d'adressages des instructions machines

2. Mémoires : Mémoire centrale - Mémoire cache

- 2.1 Mémoire
- 2.2 Les différents types de mémoires
- 2.3 Les unités de capacité
- 2.4 Mémoire centrale : définitions
- 2.5 Mémoire centrale : caractéristiques
- 2.6 Mémoire cache (ECC, associative)

3. Une petite machine pédagogique 8 bits " PM "

- 3.1 Unité centrale de PM (pico-machine)
- 3.2 Mémoire centrale de PM
- 3.3 Jeu d'instructions de PM

4. Mémoire de masse (auxiliaire ou externe)

- 4.1 Disques magnétiques - disques durs
- 4.2 Disques optiques compacts - CD / DVD

1. Les principaux constituants d'une machine minimale

Un ordinateur, nous l'avons déjà noté, est composé d'un centre et d'une périphérie. Nous allons nous intéresser au cœur d'un ordinateur fictif mono-processeur. Nous savons que celui-ci est composé de :

Une Unité centrale comportant :

- Unité de traitement,
- Unité de contrôle,
- Unités d'échanges.
- Une Mémoire Centrale.

Nous décrivons ci-après l'architecture minimale illustrant simplement le fonctionnement d'un ordinateur (machine de Von Neumann).

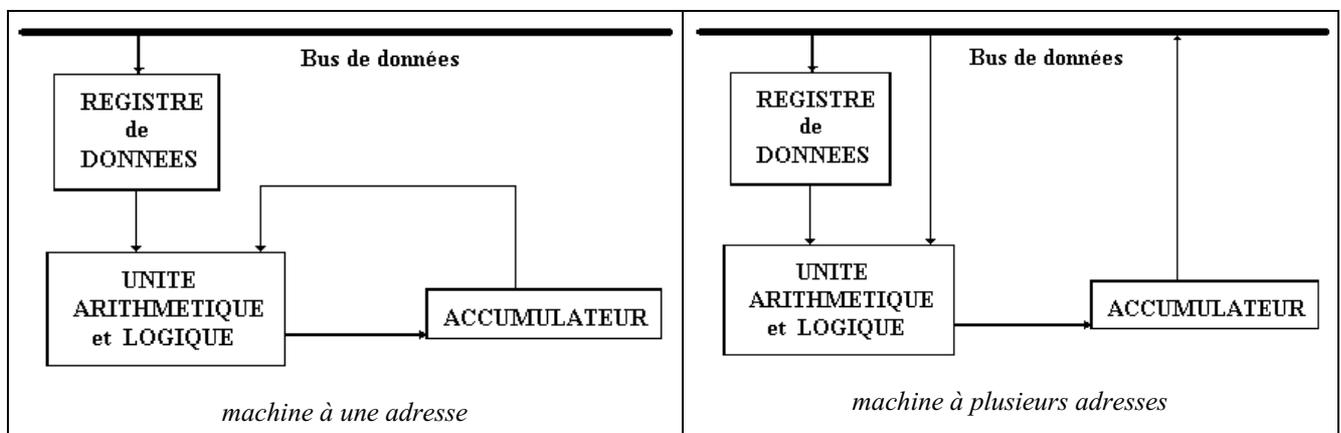
1.1 Dans l'Unité Centrale : l'Unité de Traitement

Elle est chargée d'effectuer les traitements des opérations de types arithmétiques ou booléennes. L'UAL est son principal constituant.

Elle est composée au minimum :

- d'un registre de données **RD**
- d'un accumulateur **ACC** (pour les machines à une adresse)
- des registres spécialisés (pour les machines à plusieurs adresses)
- d'une unité arithmétique et logique : **UAL**

Schéma général théorique de l'unité de traitement :



La fonction du registre de données (mémoire rapide) est de contenir les données transitant entre l'unité de traitement et l'extérieur.

La fonction de l'accumulateur est principalement de contenir les opérandes ou les résultats des opérations de l'UAL.

La fonction de l'UAL est d'effectuer en binaire les traitements des opérations qui lui sont soumises et qui sont au minimum:

- Opérations arithmétiques binaires: addition, multiplication, soustraction, division.
- Opérations booléennes : et, ou, non.
- Décalages dans un registre.

Le résultat de l'opération est mis dans l'accumulateur (Acc) dans le cas d'une machine à une adresse, dans des registres internes dans le cas de plusieurs adresses.

1.2 Dans l'Unité Centrale : l'Unité de Contrôle ou de Commande

Elle est chargée de commander et de gérer tous les différents constituants de l'ordinateur (contrôler les échanges, gérer l'enchaînement des différentes instructions, etc...)

Elle est composée au minimum de :

- d'un registre instruction **RI**,
- d'un compteur ordinal **CO**,
- d'un registre adresse **RA**,
- d'un décodeur de fonctions,
- d'une horloge.

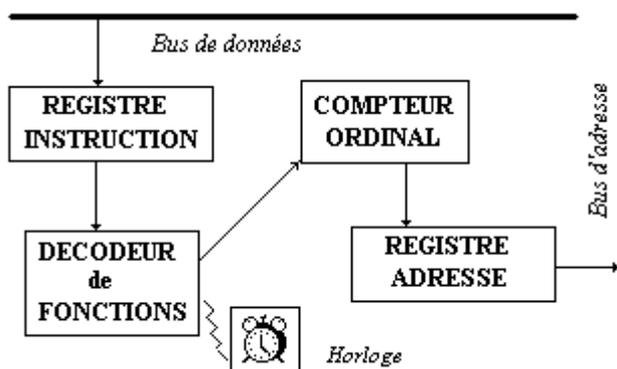


Schéma général de l'unité de contrôle

Vocabulaire :

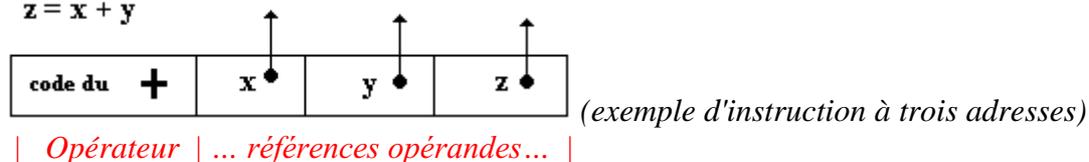
Bit = plus petite unité d'information binaire (un objet physique ayant deux états représente un bit).

Processeur central = unité de commande + unité de traitement. IL a pour fonction de lire séquentiellement les instructions présentes dans la mémoire, de decoder une instruction, de lire, écrire et traiter les données situées dans la mémoire.

Instruction = une ligne de texte comportant un code opération, une ou plusieurs références aux opérandes.

Soit l'instruction fictive d'addition du contenu des deux mémoires x et y dont le résultat est mis dans une troisième mémoire z :

$$z = x + y$$



Registre instruction = contient l'instruction en cours d'exécution, elle demeure dans ce registre pendant toute la durée de son exécution.

Compteur ordinal = contient le moyen de calculer l'adresse de la prochaine instruction à exécuter.

Registre adresse = contient l'adresse de la prochaine instruction à exécuter.

Décodeur de fonction = associé au registre instruction, il analyse l'instruction à exécuter et entreprend les actions appropriées dans l'UAL ou dans la mémoire centrale.

Au début, la différenciation des processeurs s'effectuait en fonction du nombre d'adresses contenues dans une instruction machine. De nos jours, un micro-processeur comme le pentium par exemple, possède des instructions une adresse, à deux adresses, voir à trois adresses dont certaines sont des

registres. En fait deux architectures machines coexistent sur le marché : l'architecture RISC et l'architecture CISC, sur lesquelles nous reviendrons plus loin. Historiquement l'architecture CISC est la première, mais les micro-processeur récents semblent utiliser un mélange de ces deux architectures profitant ainsi du meilleur de chacune d'elle.

Il existe de très bons ouvrages spécialisés uniquement dans l'architecture des ordinateurs nous renvoyons le lecteur à certains d'entre eux cités dans la bibliographie. Dans ce chapitre notre objectif est de fournir au lecteur le vocabulaire et les concepts de bases qui lui sont nécessaires et utiles sur le domaine, ainsi que les notions fondamentales qu'il retrouvera dans les architectures de machines récentes. L'évolution matérielle est actuellement tellement rapide que les ouvrages spécialisés sont mis à jour en moyenne tous les deux ans.

1.3 Dans l'Unité Centrale : les Unités d'échange

- Une unité d'échange est spécialisée dans les entrées/sorties.
- Ce peut être un simple canal, un circuit ou bien un processeur particulier.
- Cet organe est placé entre la mémoire et un certain nombre de périphériques (dans un micro-ordinateur ce sont des cartes comme la carte son, la carte vidéo, etc...).

Une unité d'échange soulage le processeur central dans les tâches de gestion du transfert de l'information.

Les périphériques sont très lents par rapport à la vitesse du processeur (rapport de 1 à 10^9). Si le processeur central était chargé de gérer les échanges avec les périphériques il serait tellement ralenti qu'il passerait le plus clair de son temps à attendre.

1.4 Exemple de machine à une adresse : un micro-processeur simple

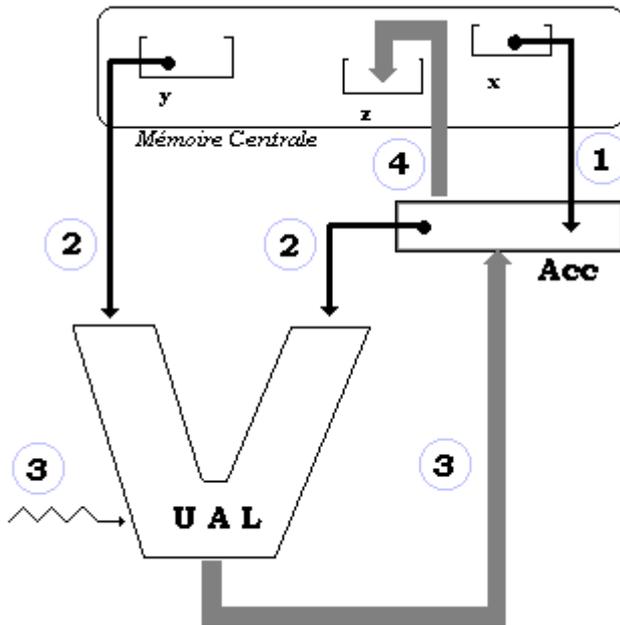
Un micro-processeur simple a les mêmes caractéristiques que celles d'un processeur central avec un niveau de complexité et de sophistication moindre. Il faut savoir que plus une instruction machine contient d'adresses (de références à des opérandes), plus le processeur est complexe. En effet avec les instructions à une adresse, le processeur est moins complexe en contre partie les programmes (listes d'instructions machines) contiennent beaucoup d'instructions et sont donc plus longs à exécuter que sur un matériel dont le jeu d'instruction est à plusieurs adresses.

Un micro-processeur simple est essentiellement une machine à une adresse, c'est à dire une partie code opérande et une référence à un seul opérande. Ce genre de machine est fondé sur un cycle de passage par l'accumulateur.

L'opération précédente $z = x + y$, se décompose dans une telle machine fictivement en 3 opérations distinctes illustrées par la figure ci-après :

LoadAcc x	{ chargement de l'accumulateur avec x : (1) }
Add y	{ préparation des opérandes x et y vers l'UAL : (2) }
	{ lancement commande de l'opération dans l'UAL : (3) }
	{ résultat transféré dans l'accumulateur : (3) }
Store z	{ copie de l'accumulateur dans z : (4) }

L'accumulateur gardant son contenu au final.



Comparaison de "programme" réalisant le calcul de l'opération précédente "z = x + y" avec une machine à une adresse et une machine à trois adresses :

Une machine à une adresse (3 instructions)	Une machine à trois adresses (1 instruction)
<p>The diagram shows three instruction boxes for a one-address machine. Each box is divided into two parts: the instruction name and a register identifier. The first box is 'LOAD' with 'X' above it. The second box is 'ADD' with 'Y' above it. The third box is 'STO' with 'Z' above it. Arrows point from the register identifiers to the corresponding registers in the machine diagram above.</p>	<p>The diagram shows a single instruction box for a three-address machine. The box is divided into four parts: the instruction name 'ADD' and three register identifiers 'X', 'Y', and 'Z' above it. Arrows point from the register identifiers to the corresponding registers in the machine diagram above.</p>

1.5 Les Bus

Un bus est un dispositif destiné à assurer le transfert simultané d'informations entre les divers composants d'un ordinateur.

On distingue trois catégories de Bus :

Bus d'adresses (unidirectionnel)

il permet à l'unité de commande de transmettre les adresses à rechercher et à stocker.

Bus de données (bi-directionnel)

sur lequel circulent les instructions ou les données à traiter ou déjà traitées en vue de leur rangement.

Bus de contrôle (bi-directionnel)

transporte les ordres et les signaux de synchronisation provenant de l'unité de commande vers les divers organes de la machine. Il véhicule aussi les divers signaux de réponse des composants.

Largeur du bus

Pour certains Bus on désigne par largeur du Bus, le nombre de bits qui peuvent être transportés en même temps par le Bus, on dit aussi transportés en parallèle.

Les principaux Bus de données récents de micro-ordinateur

Les Bus de données sont essentiellement des bus "synchrones", c'est à dire qu'ils sont cadencés par une horloge spécifique qui fonctionne à une fréquence fixée. Entre autres informations commerciales, les constructeurs de Bus donnent en plus de la fréquence et pour des raisons psychologiques, le débit du Bus qui est en fait la valeur du produit de la fréquence par la largeur du Bus, ce débit correspond au nombre de bits par seconde transportés par le Bus.

Quelques chiffres sur des Bus de données parallèles des années 2000

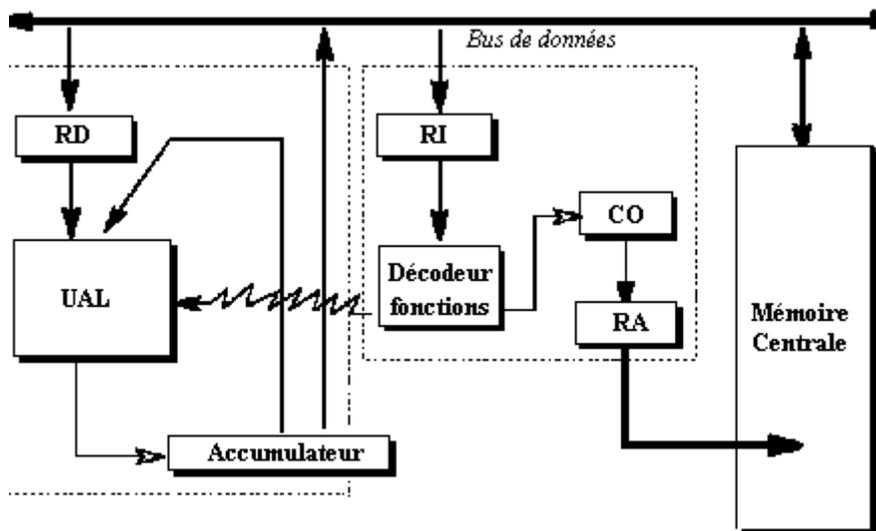
BUS	Largeur	Fréquence	Débit	Utilisation
PCI	64 bits	66 MHz	528 Mo/s	Processeur/périphérique non graphique
AGP	32 bits	66 MHz x 8	4 Go/s	Processeur/carte graphique
SCSI	16 bits	40 MHz	80 Mo/s	Echanges entre périphériques

Il existe aussi des "Bus série" (Bus qui transportent les bits les uns à la suite des autres, contrairement aux Bus parallèles), les deux plus récents concurrents équipent les matériels de grande consommation : USB et Firewire.

BUS	Débit	Nombre de périphériques acceptés
USB	1,5 Mo/s	127
USB2	60 Mo/s	127
Firewire	50 Mo/s	63
FirewireB	200 Mo/s	63

Ces Bus évitent de connecter des périphériques divers comme les souris, les lecteurs de DVD, les GSM, les scanners, les imprimantes, les appareils photo, ..., sur des ports spécifiques de la machine

1.6 Schéma général d'une micro-machine fictive à une adresse



1.7 Notion de jeu d'instructions-machine : *Les premiers programmes*

Comme défini précédemment, une instruction-machine est une instruction qui est directement exécutable par le processeur.

L'ensemble de toutes les instructions-machine exécutables par le processeur s'appelle le " jeu d'instructions " de l'ordinateur. Il est composé au minimum de quatre grandes classes d'instructions dans les micro-processeurs :

- instructions de traitement
- instructions de branchement ou de déroutement
- instructions d'échanges
- instructions de comparaisons

D'autres classes peuvent être ajoutées pour améliorer les performances de la machine (instructions de gestion mémoire, multimédias etc..)

1.8 Architectures CISC et RISC

Traditionnellement, depuis les années 70 on dénomme processeur à architecture CISC (Complex Instruction Set Code) un processeur dont le jeu d'instructions possède les propriétés suivantes :

- Il contient beaucoup de classes d'instructions différentes.
- Il contient beaucoup de type d'instructions différentes complexes et de taille variable.
- Il se sert de beaucoup de registres spécialisés et de peu de registres généraux.

L'architecture RISC (**R**educed **I**nstruction **S**et **C**ode) est un concept mis en place par IBM dans les

années 70, un processeur RISC est un processeur dont le jeu d'instructions possède les propriétés suivantes :

- Le nombre de classes d'instructions différentes est réduit par rapport à un CISC.
- Les instructions sont de taille fixe.
- Il se sert de beaucoup de registres généraux.
- Il fonctionne avec un pipe-line

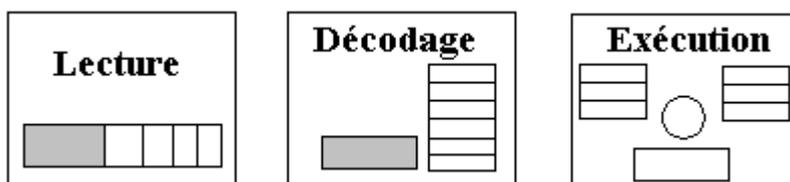
Depuis les décennies 90, les microprocesseur adoptent le meilleur des fonctionnalités de chaque architecture provoquant de fait la disparition progressive de la différence entre RISC et CISC et le inévitables polémiques sur l'efficacité supposée meilleure de l'une ou de l'autre architecture.

1.9 Pipe-line dans un processeur

Soulignons qu'un processeur est une machine séquentielle ce qui signifie que le cycle de traitement d'une instruction se déroule séquentiellement. Supposons que par hypothèse simplificatrice, une instruction machine soit traitée en 3 phases :

- 1 - lecture : dans le registre instruction (RI)
- 2 - décodage : extraction du code opération et des opérandes
- 3 - exécution : du traitement et stockage éventuel du résultat.

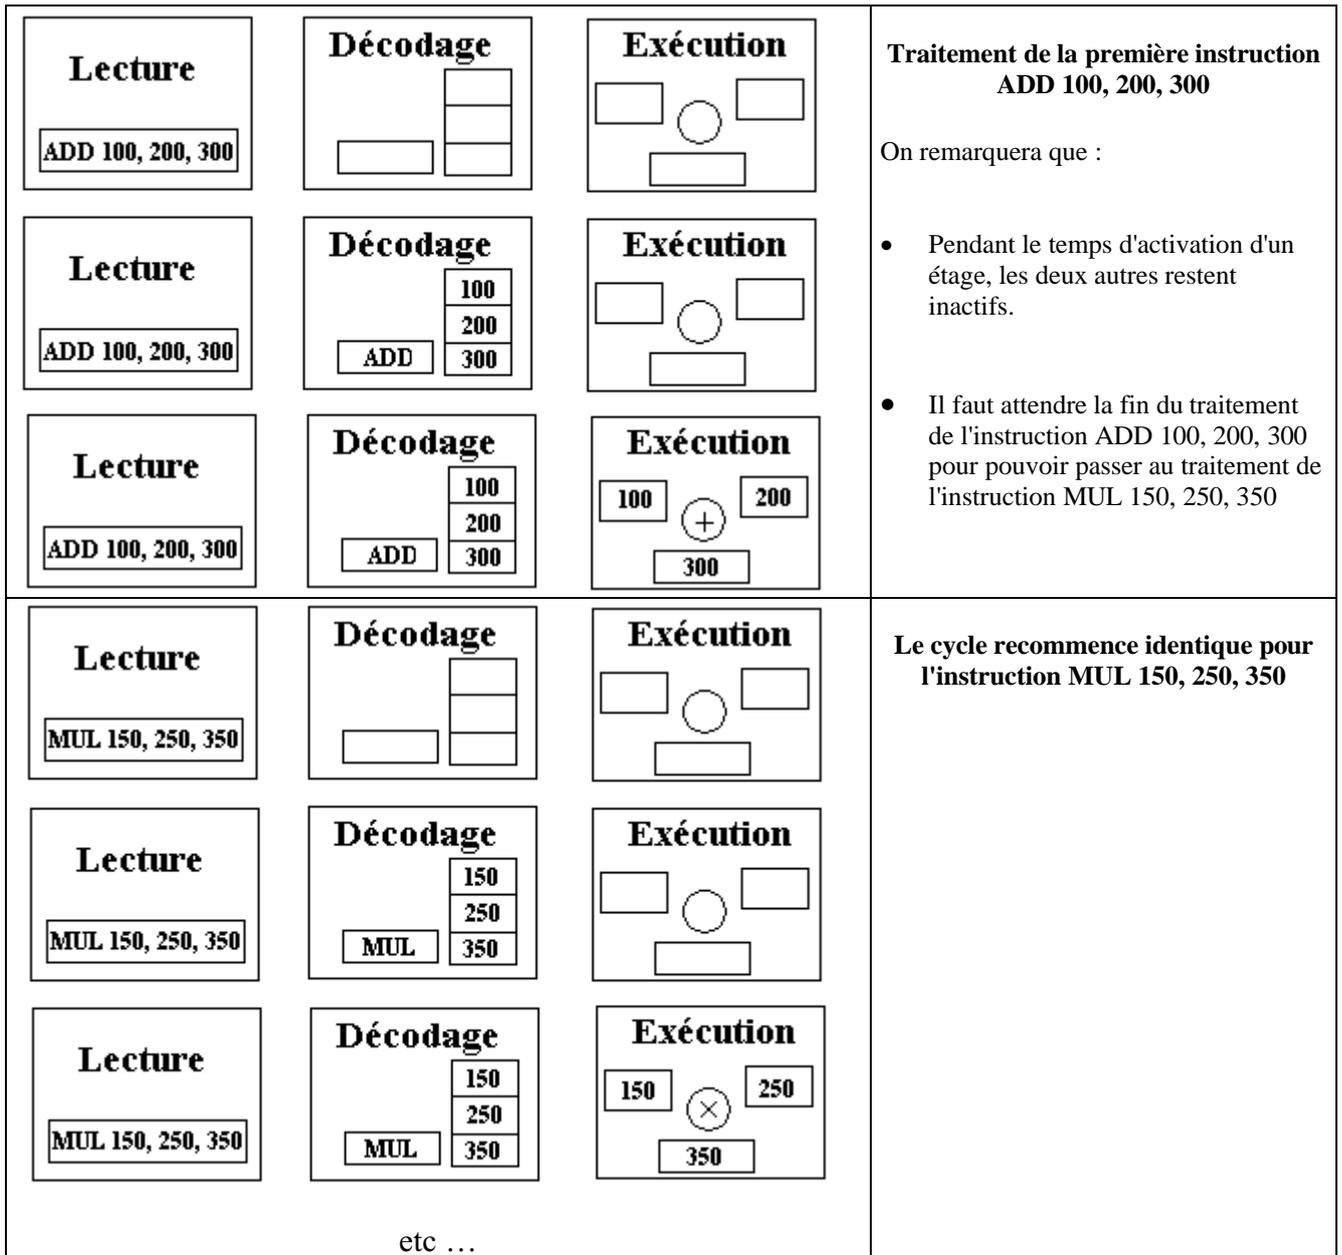
Représentons chacune de ces 3 phases par une unité matérielle distinctes dans le processeur (on appelle cette unité un "étage") et figurons schématiquement les 3 étages de traitement d'une instruction :



Supposons que suivions pas à pas l'exécution des 4 instructions machines suivants le long des 3 étages précédents :

```
ADD 100, 200, 300
MUL 150, 250, 350
DIV 300, 200, 120
MOV 100, 500
```

Chacune des 4 instruction est traitée séquentiellement en 3 phases sur chacun des étages; une fois une instruction traitée par le dernier étage (étage d'exécution) le processeur passe à l'instruction suivante et la traite au premier étage et ainsi de suite :

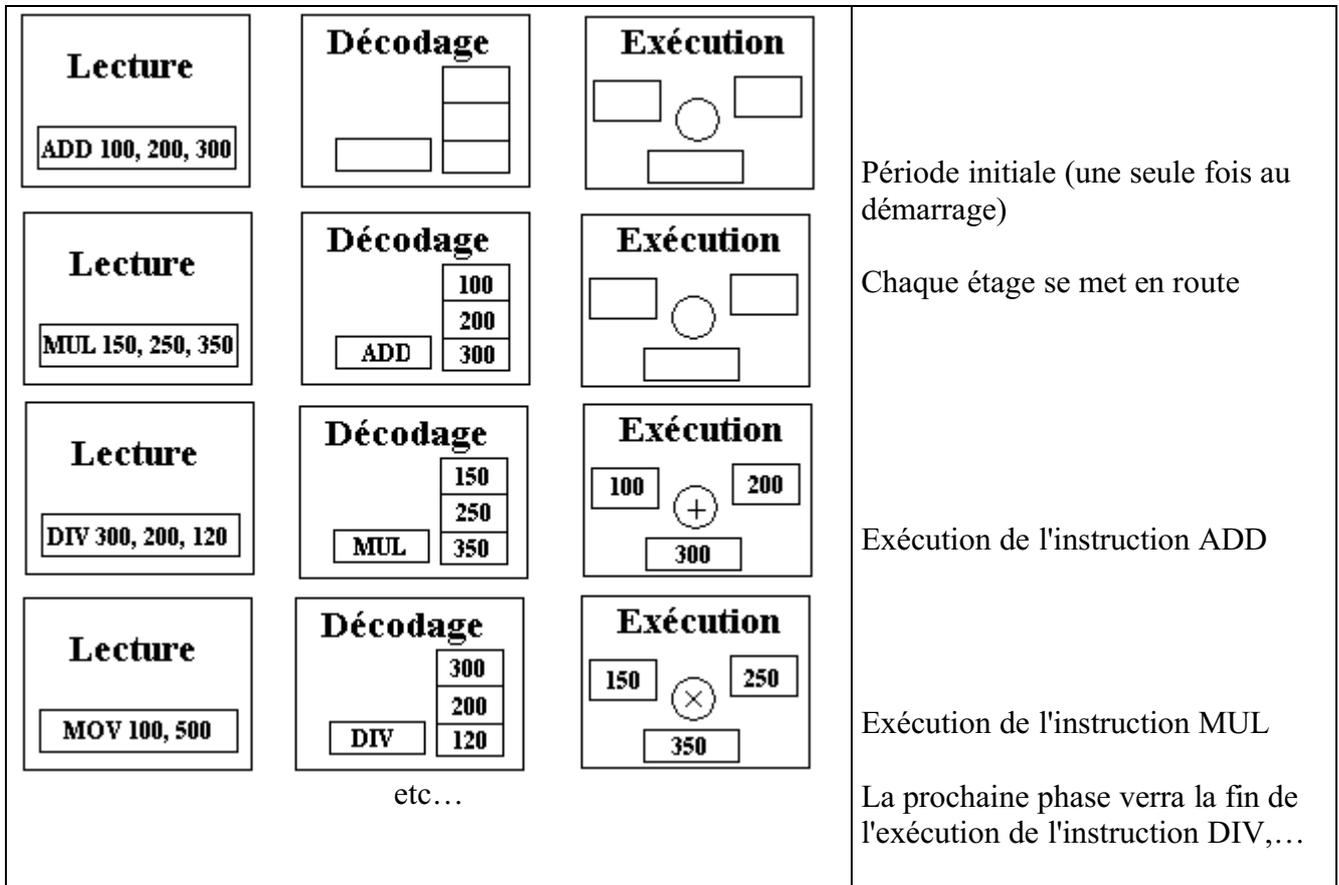


L'architecture pipe-line consiste à optimiser les temps d'attente de chaque étage, en commençant le traitement de l'instruction suivante dès que l'étage de lecture a été libéré par l'instruction en cours, et de procéder identiquement pour chaque étage de telle façon que durant chaque phase, tous les étages soient occupés à fonctionner (chacun sur une instruction différente).

A un instant t_0 donné l'étage d'exécution travaille sur les actions à effectuer pour l'instruction de rang n , l'étage de décodage travaille sur le décodage de l'instruction de rang $n+1$, et l'étage de lecture sur la lecture de l'instruction de rang $n+2$.

Il est clair que cette technique dénommée **architecture pipe-line** accélère le traitement d'une instruction donnée, puisqu'à la fin de chaque phase une instruction est traitée en entier. Le nombre d'unités différentes constituant le pipe-line s'appelle le **nombre d'étages du pipe-line**.

La figure ci-dessous illustre le démarrage du traitement des 4 instructions selon un pipe-line à 3 étages (lecture, décodage, exécution) :



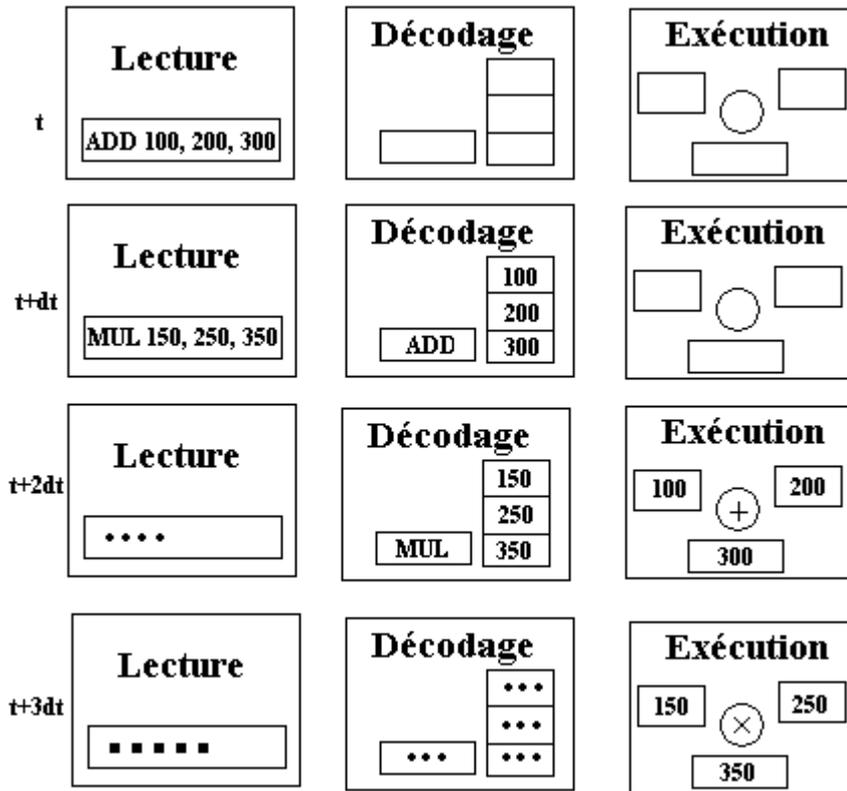
1.10 Architecture super-scalaire

On dit qu'un processeur est super-scalaire lorsqu'il possède plusieurs pipe-lines indépendants dans lesquels plusieurs instructions peuvent être traitées simultanément. Dans ce type d'architecture apparaît la notion de parallélisme avec ses *contraintes de dépendances* (par exemple lorsqu'une instruction nécessite le résultat de la précédente pour s'exécuter, ou encore lorsque deux instructions accèdent à la même ressource mémoire,...).

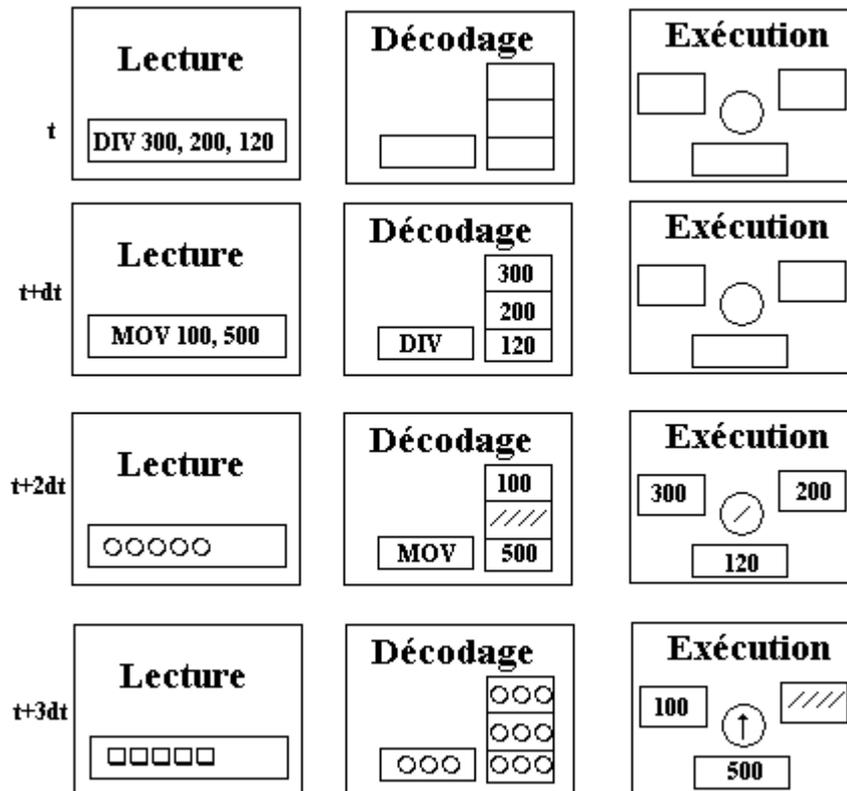
Examinons l'exécution de notre exemple à 4 instructions sur un processeur super-scalaire à 2 pipe-lines. Nous supposons nous trouver dans le cas idéal pour lequel il n'y a aucune dépendance entre deux instructions, nous figurons séparément le schéma temporel d'exécution de chacun des deux pipe-lines aux t , $t+dt$, $t+2dt$ et $t+3dt$ afin d'observer leur comportement et en sachant que les deux fonctionnent en même temps à un instant quelconque.

Le processeur envoie les deux premières instructions ADD et MUL au pipe-line n°1, et les deux suivantes DIV et MOV au pipe-line n°2 puis les étages des deux pipe-lines se mettent à fonctionner.

PIPE-LINE n°1



PIPE-LINE n°2



nous remarquerons qu'après de $t+dt$, chaque phase voit s'exécuter 2 instructions :

à $t+2dt$ ce sont ADD et DIV

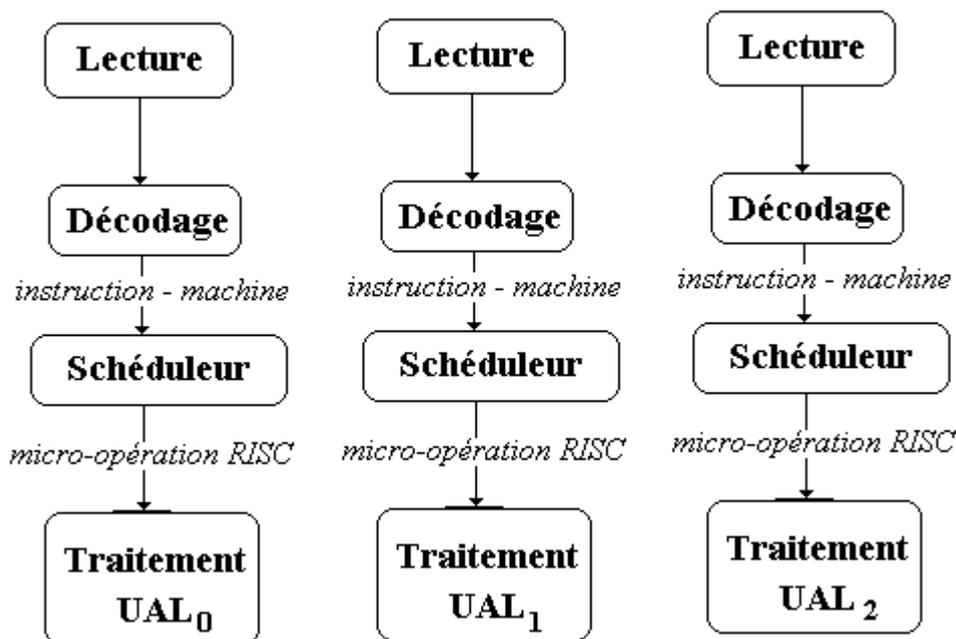
à $t+3dt$ se sont MUL et MOV

Rappelons au lecteur que nous avons supposé par simplification de l'explication que ces 4 instructions sont indépendantes et donc leur ordre d'exécution est indifférent. Ce n'est dans la réalité pas le cas car par exemple si l'instruction DIV 300, 200, 120 utilise le contenu de la mémoire 300 pour le diviser par le contenu de la mémoire 200, et que l'instruction ADD 100, 200, 300 range dans cette mémoire 300 le résultat de l'addition des contenus des mémoires 100 et 200, alors l'exécution de DIV dépend de l'exécution de ADD. Dans cette éventualité à $t+2dt$, le calcul de DIV par le second pipe-line doit "attendre" que le calcul de ADD soit terminé pour pouvoir s'exécuter sous peine d'obtenir une erreur en laissant le parallélisme fonctionner : un processeur super-scalaire doit être capable de **désactiver le parallélisme** dans une telle condition. Par contre dans notre exemple, à $t+3dt$ le parallélisme des deux pipe-lines reste efficace MUL et MOV sont donc exécutées en même temps.

Le pentium IV de la société Intel intègre un pipe-line à 20 étages et constitue un exemple de processeur combinant un mélange d'architecture RISC et CISC. Il possède en externe un jeu d'instruction complexes (CISC), mais dans son cœur il fonctionne avec des micro-instructions de type RISC traitées par un pipe-line super-scalaire.

L'AMD 64 Opteron qui est un des micro-processeur de l'offre 64 bits du deuxième constructeur mondial de micro-processeur derrière la société Intel, dispose de 3 pipe-lines d'exécution identiques pour les calculs en entiers et de 3 pipe-lines spécialisés pour les calculs en virgules flottante. L'AMD 64 Opteron est aussi un mélange d'architecture RISC-CISC avec un cœur de micro-instructions RISC comme le pentium IV.

Nous figurons ci-dessous les 3 pipe-lines d'exécution (sur les entiers par exemple) :



Chacune des 3 UAL effectue les fonctions classiques d'une UAL, plus des opérations de multiplexage, de drapeau, des fonctions conditionnelles et de résolution de branchement. Les multiplications sont traitées dans une unité à part de type pipe-line et sont dirigées vers les pipe-lines

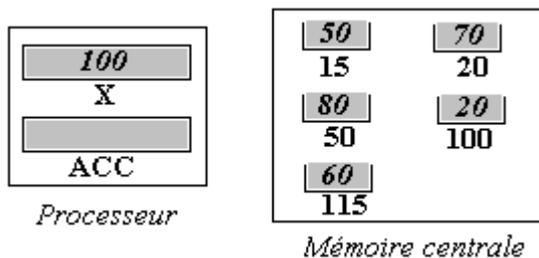
UAL0 et UAL1.

1.11 Principaux modes d'adressage des instructions machines

Nous avons indiqué précédemment qu'une instruction machine contenait des adresses d'opérandes situées en mémoire centrale. En outre, il a été indiqué que les processeurs centraux disposaient de registres internes. Les informaticiens ont mis au point des techniques d'adressages différentes en vue d'accéder à un contenu mémoire. Nous détaillons dans ce paragraphe les principales d'entre ces techniques d'adressage. Afin de conserver un point de vue pratique, nous montrons le fonctionnement de chaque mode d'adressage à l'aide de schémas représentant le cas d'une instruction LOAD de chargement d'un registre nommé ACC d'une machine à une adresse, selon 6 modes d'adressages différents.

Environnement d'exécution d'un LOAD

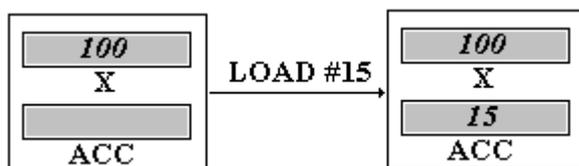
Soit à considérer un processeur contenant en particulier deux registres X chargé de la valeur entière 100 et ACC (accumulateur de machine à une adresse) et une mémoire centrale dans laquelle nous exhibons 5 mots mémoire d'adresses 15, 20, 50, 100, 115. Chaque mot et contient un entier respectivement dans l'ordre 50, 70, 80, 20, 60, comme figuré ci-dessous :



L'instruction "LOAD Oper" a pour fonction de charger le contenu du registre ACC avec un opérande Oper qui peut prendre 6 formes, chacune de ces formes représente un mode d'adressage particulier que nous définissons maintenant.

Adressage immédiat

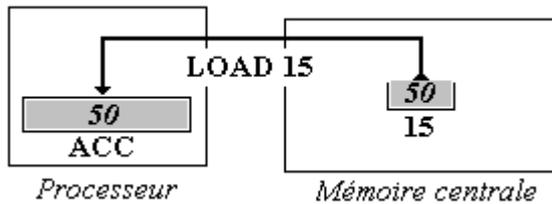
L'opérande Oper est considéré comme une valeur à charger immédiatement (dans le registre ACC ici). Par exemple, nous noterons LOAD #15, pour indiquer un adressage immédiat (c'est à dire un chargement de la valeur 15 dans le registre ACC).



Adressage direct

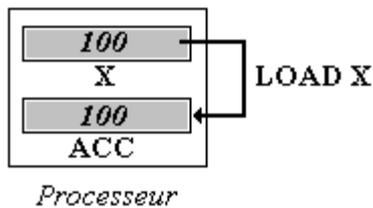
L'opérande Oper est considéré comme une adresse en mémoire centrale. Par exemple, nous noterons LOAD 15, pour indiquer un adressage direct (c'est à dire un chargement du contenu 50 du mot

mémoire d'adresse 15 dans le registre ACC).



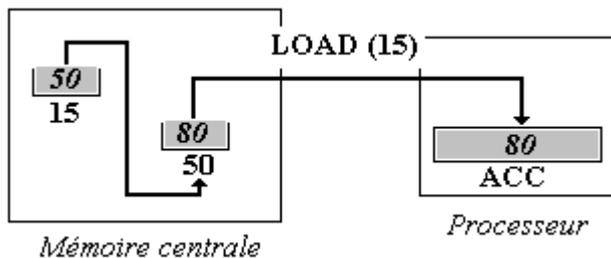
Adressage direct avec registre

L'opérande Oper est un registre interne du processeur (noté X dans l'exemple), un tel mode d'adressage indique de charger dans ACC le contenu du registre Oper. Par exemple, nous noterons LOAD X, pour indiquer un adressage direct avec registre qui charge l'accumulateur ACC avec la valeur 100 contenue dans X.



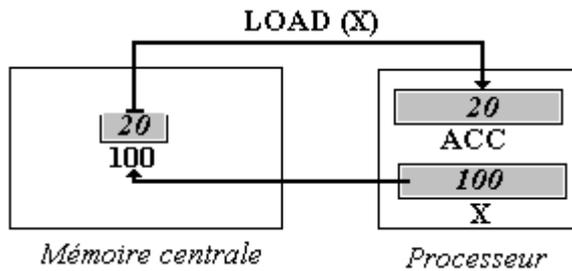
Adressage indirect

L'opérande Oper est considéré comme l'adresse d'un mot₁ en mémoire centrale, mais ce mot₁ contient lui-même l'adresse d'un autre mot₂ dont on doit charger le contenu dans ACC. Par exemple, nous noterons LOAD (15), pour indiquer un adressage indirect (c'est à dire un chargement dans le registre ACC, du contenu 80 du mot₂ mémoire dont l'adresse 50 est contenue dans le mot₁ d'adresse 15).



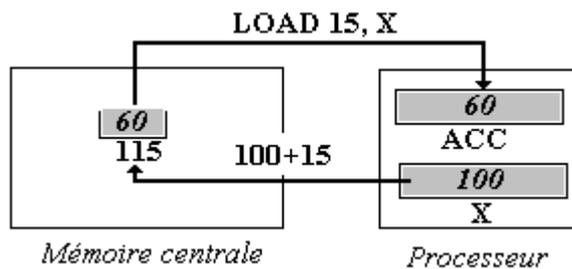
Adressage indirect avec registre

L'opérande Oper est considéré comme un registre dont le contenu est l'adresse du mot dont on doit charger la valeur dans ACC. Par exemple, nous noterons LOAD (X), pour indiquer un adressage indirect avec le registre X (c'est à dire un chargement dans le registre ACC, du contenu 20 du mot mémoire dont l'adresse 100 est contenue dans le registre X).



Adressage indexé

L'opérande Oper est un couple formé par un registre **R** et une adresse **adr**. La connaissance de l'adresse du mot dont on doit charger la valeur est obtenue par addition de l'adresse **adr** au contenu du registre **R**. Par exemple, nous noterons **LOAD 15, X**, pour indiquer un adressage indexé par le registre X (c'est à dire un chargement dans le registre ACC, du contenu 60 du mot mémoire dont l'adresse 115 est obtenue par addition de 15 et du contenu 100 du registre X).



Quelques remarques sur les différents modes d'adressages (avec l'exemple du LOAD) :

- Le mode direct correspond à des préoccupations de chargement de valeur à des emplacements fixés.
- Les modes indirects permettent à partir d'un emplacement mémoire quelconque d'atteindre un autre emplacement mémoire et donc autorise des traitements sur les adresses elles-mêmes.
- Le mode indexé est très utile lorsque l'on veut atteindre une famille de cellules mémoires contiguës possédant une adresse de base (comme pour un tableau). L'instruction **LOAD 15,X** permet si l'on fait varier le contenu du registre X de la valeur 0 à la valeur 10 (dans une itération par exemple) d'atteindre les mots d'adresse 15, 16, ... , 25.

Les registres sont très présents dans les micro-processeurs du marché

Le processeur AMD 64 bits Optéron travaille avec 16 registres généraux de 64 bits et 16 registres généraux de 128 bits.

Le processeur pentium IV travaille avec 8 registres généraux 32 bits et 8 registres généraux 80 bits.

L'architecture IA 64 d'Intel et HP est fondée sur des instructions machines très longues travaillant avec 128 registres généraux 64 bits et 128 registres généraux 82 bits pour les calculs classiques.

Il en est des processeurs comme il en est des moteurs à explosion dans les voitures, quelle que soit leur sophistication technique (processeur vectoriel, machine parallèle, machine multi-processeur, ...) leurs fondements restent établis sur les principes d'une machine de Von Neumann (mémoire, registre, adresse, transfert).

2. Mémoires : mémoire Centrale , mémoire cache

2.1 Mémoire

Mémoire :c'est un organe (électronique de nos jours), capable de contenir, de conserver et de restituer sans les modifier de grandes quantités d'information.

2.2 Les différents types de mémoires

La mémoire vive RAM (Random Access Memory)

- Mémoire dans laquelle on peut lire et écrire.
- Mémoire *volatile* (perd son contenu dès la coupure du courant).

La mémoire morte ROM (Read Only Memory)

- Mémoire dans laquelle on **ne** peut **que** lire.
- Mémoire *permanente* (conserve indéfiniment son contenu).

Les PROM (Programmable ROM)

- Ce sont des mémoires vierges programmables une seule fois avec un outil spécialisé s'appelant un programmeur de PROM.
- Une fois programmées elles se comportent dans l'ordinateur comme des ROM.

Les EPROM (Erasable PROM)

- Ce sont des PROM effaçables (généralement sous rayonnement U.V),
- elles sont reprogrammables avec un outil spécialisé,
- elles se comportent comme des ROM en utilisation courante.
- Les EEPROM (Electrical EPROM) sont effaçables par signaux électriques.
- Les FLASH EEPROM sont des EEPROM effaçables par bloc.

2.3 Les unités de capacité

Les unités de mesure de stockage de l'information sont :

Le bit (pas de notation)
L'octet = 2^3 bits = 8 bits. (noté 1 o)
Le Kilo-octet = 2^{10} octets = 1024 o (noté 1 Ko)
Le Méga-octet = 2^{20} octets = $(1024)^2$ o (noté 1 Mo)
Le Giga-octet = 2^{30} octets = $(1024)^3$ o (noté 1 Go)
Le Téra-octet = 2^{40} octets = $(1024)^4$ o (noté 1 To)...

Les autres sur-unités sont encore peu employées actuellement.

2.4 Mémoire centrale : définitions

Mot : c'est un regroupement de **n** bits constituant une case mémoire dans la mémoire centrale. Ils sont tous numérotés.

Adresse : c'est le numéro d'un mot-mémoire (case mémoire) dans la mémoire centrale.

Programme : c'est un ensemble d'*instructions* préalablement codées (en binaire) et enregistrées dans la mémoire centrale sous la forme d'une liste *séquentielle* d'instructions. Cette liste représente une suite d'actions élémentaires que l'ordinateur doit accomplir sur des *données* en entrée, afin d'atteindre le *résultat* recherché.

Organisation : La mémoire centrale est organisée en bits et en mots. Chaque mot-mémoire est repéré bijectivement par son **adresse** en mémoire centrale.

Contenu : La mémoire centrale contient en binaire, deux sortes d'informations

- des *programmes*,
- des *données*.

Composition : Il doit être possible de lire et d'écrire dans une mémoire centrale. Elle est donc habituellement composée de mémoires de type **RAM**.

Remarques

- Un ordinateur doté d'un programme est un automatisme apte seulement à répéter le même travail (celui dicté par le programme).
- Si l'on change le programme en mémoire centrale, on obtient un nouvel automatisme.

2.5 Mémoire centrale : caractéristiques

La mémoire centrale peut être réalisée grâce à des technologies différentes. Elle possède toujours des caractéristiques générales qui permettent de comparer ces technologies. En voici quelques unes :

La capacité représente le nombre maximal de mots que la mémoire peut stocker simultanément.

Le temps d'accès est le temps qui s'écoule entre le stockage de l'adresse du mot à sélectionner et l'obtention de la donnée.

Le temps de cycle ou cycle mémoire est égal au temps d'accès éventuellement additionné du temps de rafraîchissement ou de réécriture pour les mémoires qui nécessitent ces opérations.

Le débit d'une mémoire : c'est l'inverse du cycle mémoire en octet par seconde

La volatilité, la permanence.

Terminons ce survol des possibilités d'une mémoire centrale, en indiquant que le mécanisme d'accès à une mémoire centrale par le processeur est essentiellement de type séquentiel et se décrit selon trois phases :

- stockage,
- sélection,
- transfert.

Pour l'instant :

Un ordinateur est une machine séquentielle de Von Neumann dans laquelle s'exécutent ces 3 phases d'une manière immuable, que ce soit pour les programmes ou pour les données et aussi complexe que soit la machine.

La mémoire centrale est un élément d'importance dans l'ordinateur, nous avons vu qu'elle est composée de RAM en particulier de RAM dynamiques nommées DRAM dont on rappelle que sont des mémoires construites avec un transistor et un condensateur. Depuis 2004 les micro-ordinateurs du commerce sont tous équipés de DRAM, le sigle employé sur les notices techniques est DDR qui est l'abréviation du sigle DDR SDRAM dont nous donnons l'explication :

Ne pas confondre SRAM et SDRAM

Une SRAM est une mémoire statique (SRAM = Statique RAM) construite avec des bascules, une SDRAM est une mémoire dynamique DRAM qui fonctionne à la vitesse du bus mémoire, elle est donc synchrone avec le fonctionnement du processeur le "S" indique la synchronicité (SDRAM = Synchrone DRAM).

Une DDR SDRAM

C'est une SDRAM à double taux de transfert pouvant expédier et recevoir des données deux fois par cycle d'horloge au lieu d'une seule fois. Le sigle DDR signifie **D**ouble **D**ata **R**ate.

Les performances des mémoires s'améliorent régulièrement, le secteur d'activité est très innovant, le lecteur retiendra que les mémoires les plus rapides sont les plus chères et que pour les comparer en ce domaine, il faut utiliser un indicateur qui se nomme le cycle mémoire.

Temps de cycle d'une mémoire ou cycle mémoire : le processeur attend

Nous venons de voir qu'il représente l'intervalle de temps qui s'écoule entre deux accès consécutifs à la mémoire toutes opérations cumulées. Un processeur est cadencé par une horloge dont la fréquence est donnée actuellement en MHz (Méga Hertz). Un processeur fonctionne beaucoup plus rapidement que le temps de cycle d'une mémoire, par exemple prenons un micro-processeur cadencé à 5 MHz auquel est connectée une mémoire SDRAM de temps de cycle de 5 ns (ordre de grandeur de matériels récents). Dans ces conditions le processeur peut accéder aux données selon un cycle qui lui est propre $1/5\text{MHz}$ soit un temps de $2 \cdot 10^{-1}$ ns, la mémoire SDRAM ayant un temps de cycle de 5 ns, le processeur doit **attendre** $5\text{ns} / 2 \cdot 10^{-1} \text{ ns} = \mathbf{25 \text{ cycles propres}}$ entre deux accès aux données de la mémoire. Ce petit calcul montre au lecteur l'intérêt de l'innovation en rapidité pour les mémoires.

C'est aussi pourquoi on essaie de ne connecter directement au processeur que des mémoires qui fonctionnent à une fréquence proche de celle du processeur.

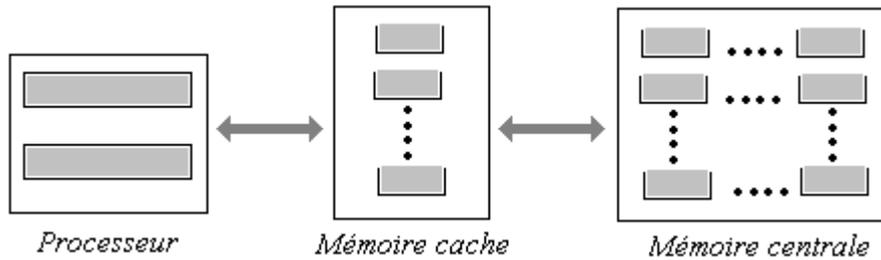
Les registres d'un processeur sont ses mémoires les plus rapides

Un processeur central est équipé de nombreux registres servant à différentes fonctions, ce sont en général des mémoires qui travaillent à une fréquence proche de celle du processeur, actuellement leur architecture ne leur permet pas de stocker de grandes quantités d'informations. Nous avons vu au chapitre consacré aux circuits logiques les principaux types de registres (registres parallèles, registres à décalages, registres de comptage, ...)

Nous avons remarqué en outre que la mémoire centrale qui stocke de très grandes quantités d'informations (relativement aux registres) fonctionne à une vitesse plus lente que celle du processeur. Nous retrouvons alors la situation classique d'équilibre entre le débit de robinets qui

remplissent ou vident un réservoir. En informatique, il a été prévu de mettre entre le processeur et la mémoire centrale une sorte de réservoir de mémoire intermédiaire nommée la **mémoire cache**.

2.6 Mémoire cache



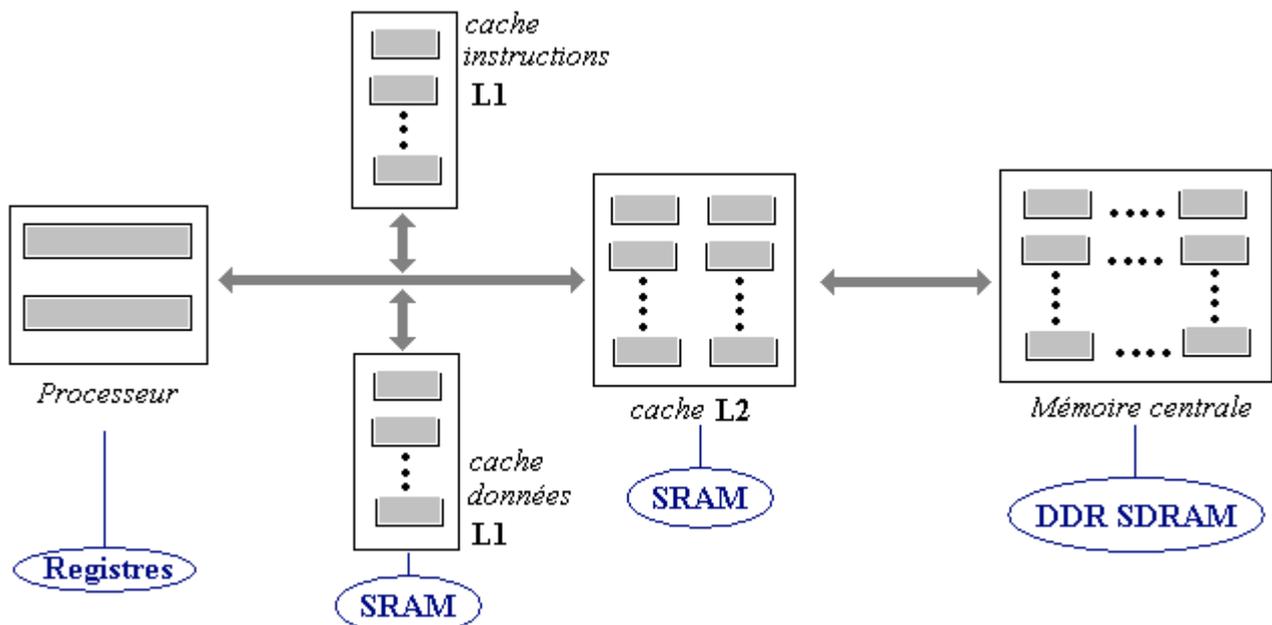
La mémoire cache (on dit aussi le cache) est une variété de mémoire plus rapide que la mémoire centrale (un peu moins rapide que les registres). La particularité technique actuelle de la mémoire cache est que plus sa taille est grande plus son débit a tendance à ralentir.

La caractéristique fonctionnelle du cache est de servir à stocker des instructions et des données provenant de la mémoire centrale et qui ont déjà été utilisées les plus récemment par le processeur central.

Actuellement le cache des micro-processeurs récents du marché est composé de deux niveaux de mémoires de type SRAM la plus rapide (type de mémoire RAM statique semblable à celle des registres) : le cache de niveau un est noté L1, le cache de niveau deux est noté L2.

Le principe est le suivant :

Le cache L1 est formé de deux blocs séparés, l'un servant au stockage des données, l'autre servant au stockage des instructions.



Si un étage du processeur cherche une donnée, elle va être d'abord recherchée dans le cache de donnée L1 et rapatriée dans un registre adéquat, si la donnée n'est pas présente dans le cache L1, elle sera recherchée dans le cache L2.

Si la donnée est présente dans L2, elle est alors **rapatriée** dans un registre adéquat et **recopiée** dans le bloc de donnée du cache L1. Il en va de même lorsque la donnée n'est pas présente dans le cache L2, elle est alors **rapatriée** depuis la mémoire centrale dans le registre adéquat et **recopiée** dans le cache L2.

Généralement la mémoire cache de niveau L1 et celle de niveau L2 sont regroupées dans la même puce que le processeur (**cache interne**).

Nous figurons ci-dessous le facteur d'échelle relatif entre les différents composants mémoires du processeur et de la mémoire centrale (il s'agit d'un coefficient de multiplication des temps d'accès à une information selon la nature de la mémoire qui la contient). Les registres, mémoires les plus rapides se voient affecter la valeur de référence 1 :



L'accès par le processeur à une information située dans la DDR SDRAM de la mémoire centrale est 100 fois plus lente qu'un accès à une information contenue dans un registre.

Par exemple, le processeur AMD 64 bits Optéron travaille avec un cache interne L1 de 64 Ko constitué de mémoires associatives (type ECC pour le bloc L1 de données et type parité pour le bloc L1 d'instructions), le cache L2 de l'Optéron a une taille de 1 Mo constitué de mémoires 64 bits associatives de type ECC, enfin le contrôleur de mémoire accepte de la DDR SDRAM 128 bits jusqu'à 200 Mhz en qualité ECC.

Définition de mémoire ECC (mémoire à code correcteur d'erreur)

Une mémoire ECC est une mémoire contenant des bits supplémentaires servant à détecter et à corriger une éventuelle erreur ou altération de l'information qu'elle contient (par exemple lors d'un transfert).

La technique la plus simple est celle du bit de parité (Parity check code), selon cette technique l'information est codée sur n bits et la mémoire contient un n+1 ème bit qui indique si le nombre de bits codant l'information contenue dans les n bits est pair (bit=0)ou impair(bit=1). C'est un code détecteur d'erreur.

Exemple d'une mémoire à 4 bits plus bit de parité (**le bit de poids faible contient la parité**) :

Information 10010 → bit de parité = 0 , car il y a deux bits égaux à 1 (nombre pair)
Information 11110 → bit de parité = 0 , car il y a quatre bits égaux à 1 (nombre pair)
Information 11011 → bit de parité = 1 , car il y a trois bits égaux à 1 (nombre impair)

Une altération de deux bits (ou d'un nombre pair de bits) ne modifiant pas la parité du décompte ne sera donc pas décelée par ce code :

Supposons que l'information 10010 soit altérée en 01100 (le bit de parité ne change pas car le nombre de 1 de l'information altérée est toujours pair, il y en a toujours 2 !). Ce code est simple peu

coûteux, il est en fait un cas particulier simple de codage linéaire systématique inventés par les spécialistes du domaine.

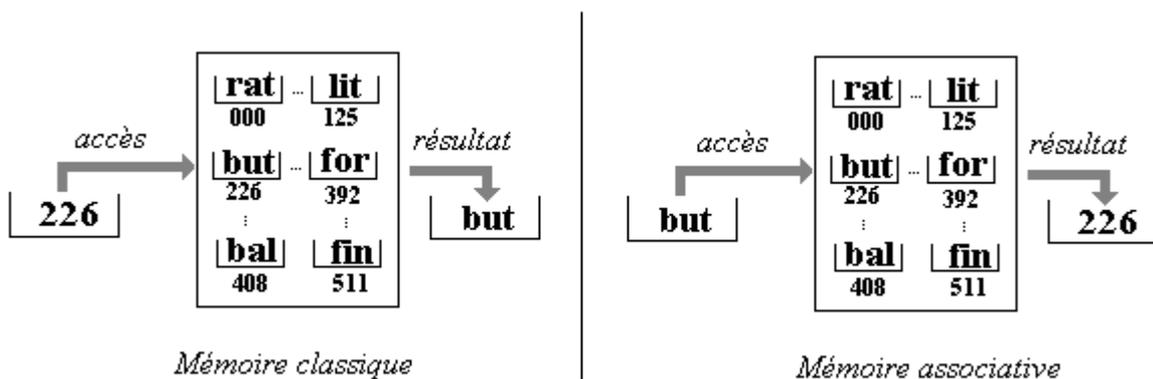
Mémoire ECC générale

Les mathématiciens mis à contribution à travers la théorie des groupes et des espaces vectoriels fournissent des modèles de codes détecteur et correcteur d'erreurs appelés codes linéaire cycliques, les codes de Hamming sont les plus utilisés. Pour un tel code permettant de corriger d'éventuelles erreur de transmission, il faut ajouter aux n bits de l'information utile, un certain nombre de bits supplémentaires représentant un polynôme servant à corriger les n bits utiles.

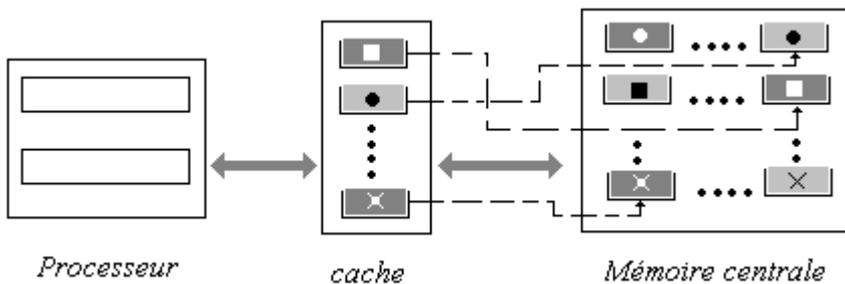
Pour une mémoire ECC de 64 bits utiles, 7 supplémentaires sont nécessaires pour le polynôme de correction, pour une mémoire de 128 bits utiles, 8 bits sont nécessaires. Vous remarquez que l'Optéron d'AMD utilise de la mémoire ECC pour le cache L1 de données et de la mémoire à parité pour le cache instruction. En effet, si un code d'instruction est altéré, l'étage de décodage du processeur fera la vérification en bloquant l'instruction inexistante, la protection apportée par la parité est suffisante; en revanche si c'est une donnée qui est altérée dans le cache L1 de données, le polynôme de correction aidera alors à restaurer l'information initiale.

Mémoire associative

C'est un genre de mémoire construit de telle façon que la recherche d'une information s'effectue non pas à travers une adresse de cellule, la mémoire renvoyant alors le contenu de la cellule, mais plutôt en donnant un "contenu" à rechercher dans la mémoire et celle-ci renvoie l'adresse de la cellule.

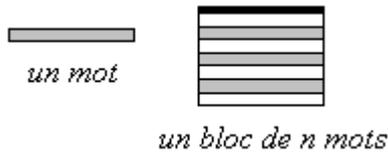


Une mémoire cache est une mémoire associative, ainsi elle permet d'adresser directement dans la mémoire centrale qui n'est pas associative.



On peut considérer une mémoire cache comme une sorte de table de recherche contenant des morceaux de la mémoire centrale. La mémoire centrale est divisée en blocs de n mots, et la mémoire cache contient quelques un de ces blocs qui ont été chargés précédemment.

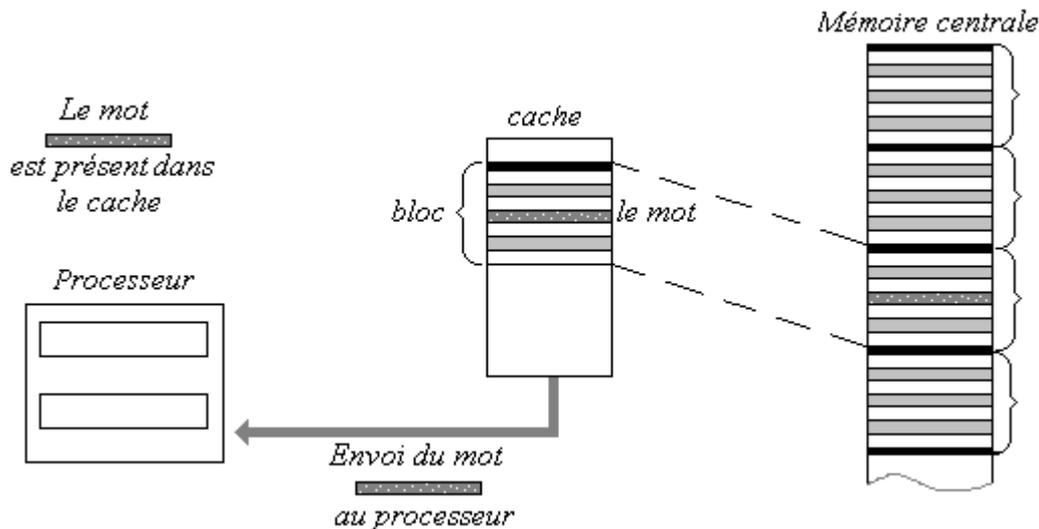
Notation graphiques utilisées :



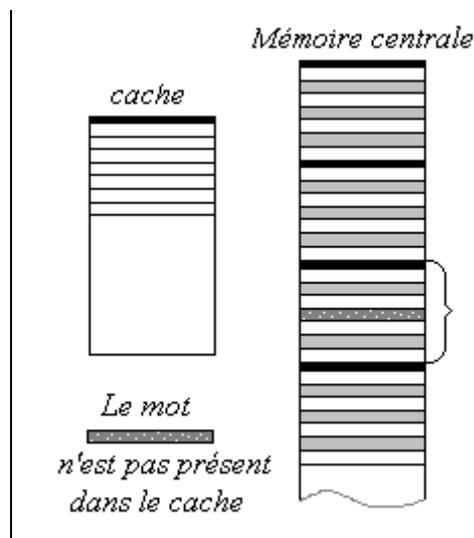
Mécanisme synthétique de lecture-écriture avec cache :

Le processeur fournit l'adresse d'un mot à lire :

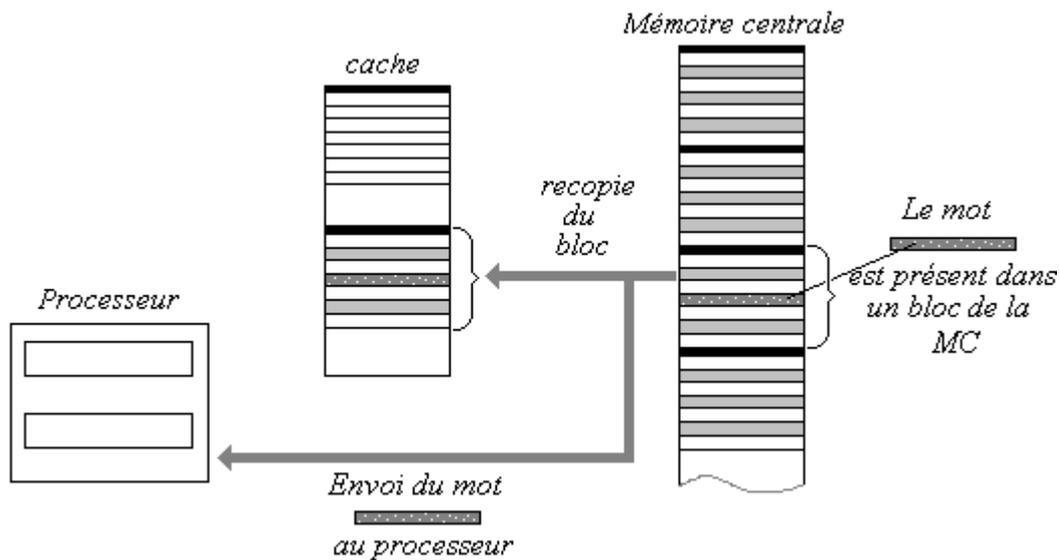
1°) Si ce mot est présent dans le cache, il se trouve dans un bloc déjà copié à partir de son original dans le MC (mémoire centrale), il est alors envoyé au processeur :



2°) Si ce mot n'est pas présent dans le cache, l'adresse porte alors sur un mot situé dans un bloc présent dans la MC (mémoire centrale).

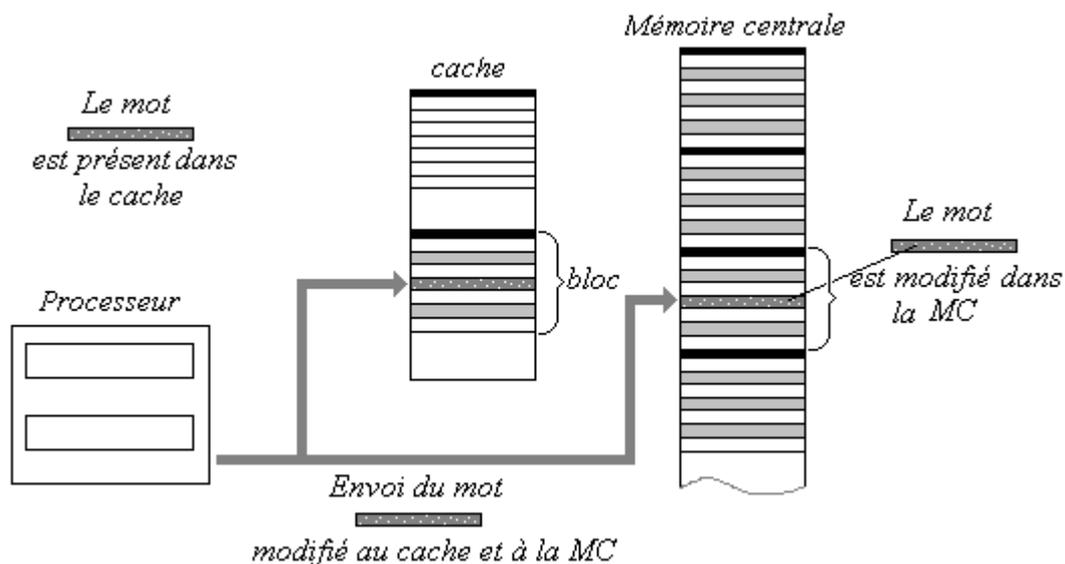


Dans cette éventualité le bloc de la MC dans lequel se trouve le mot, se trouve recopié dans le cache et en même temps le mot est envoyé au processeur :



Pour l'écriture l'opération est semblable, selon que le mot est déjà dans le cache ou non.

Lorsque le mot est présent dans le cache et qu'il est modifié par une écriture il est modifié dans le bloc du cache et modifié aussi dans la MC :



Ce fonctionnement montre qu'il est donc nécessaire que la mémoire cache soit liée par une correspondance entre un mot situé dans elle-même et sa place dans la MC. Le fait que la mémoire cache soit constituée de mémoires associatives, permet à la mémoire cache lorsqu'un mot est sélectionné de fournir l'adresse MC de ce mot et donc de pouvoir le modifier.

3. Une petite machine pédagogique 8 bits

(assistant du package pédagogique présent sur le CD-ROM)

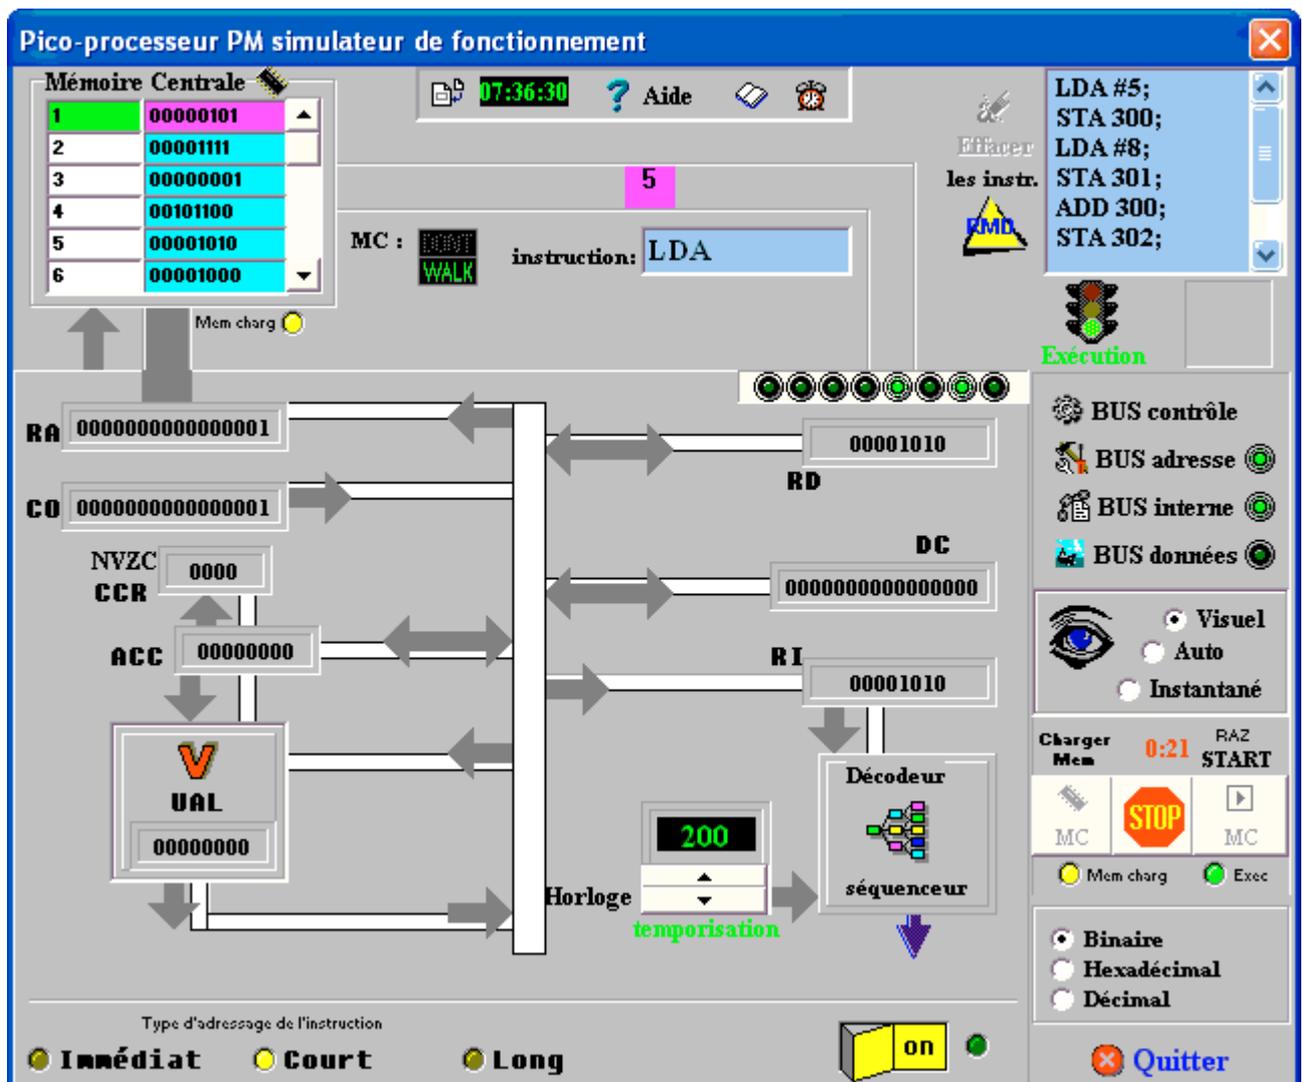
3.1 Unité centrale de PM (pico-machine)

Objectif:

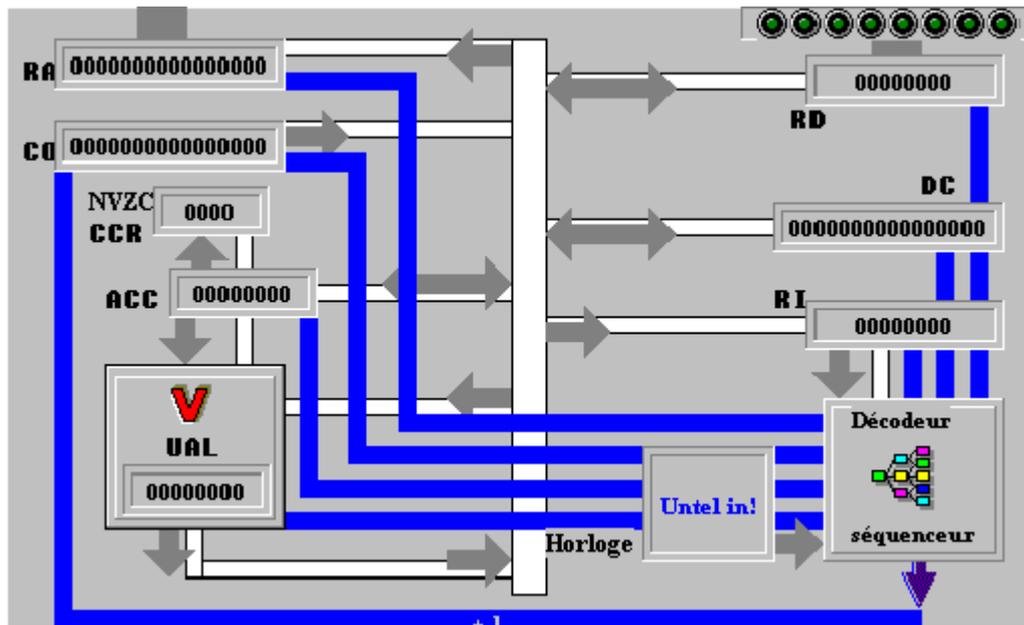
Support pédagogique interactif destiné à faire comprendre l'analyse et le cheminement des informations dans un processeur central d'ordinateur fictif avec accumulateur.

- La mémoire centrale est à mots de 8 bits, les adresses sont sur 16 bits.
- le processeur est doté d'instructions immédiates ou relatives.
- Les instructions sont de 3 types à 1 octet (immédiat), 2 octets (court) ou 3 octets (long).
- Les instructions sont à adressages immédiat et adressage direct.

Interface utilisateur de l'assistant :



Description générale de l'unité centrale de PM simulée sur le tableau de bord ci-dessous :



- RA** = Registre Adresse sur 16 bits
- CO** = Compteur Ordinal sur 16 bits
- DC** = Registre de formation d'adresse sur 16 bits
- RD** = Registre de Données sur 8 bits
- UAL** = Unité Arithmétique et Logique effectuant les calculs sur 8 bits avec possibilité de débordement.
- Acc** = Accumulateur sur 8 bits (machine à une adresse).
- RI** = Registre Instruction sur 8 bits (instruction en cours d'exécution).
- Décodeur de fonction.**
- séquenceur**
- Horloge**
- CCR** = un Registre de 4 Codes Condition N, V, Z, C,
- BUS** de contrôle (bi-directionnel)
- BUS** interne (circulation des informations internes).

3.2 Mémoire centrale de PM

La mémoire centrale de PM est de 512 octets, ce qui permet dans une machine 8 bits de voir comment est construite la technique d'adressage court (8 bits) et d'adressage long (16 bits).

Mémoire Centrale	
0	11111111
1	11111111
2	11111111
3	11111111
4	11111111
5	11111111

/adresse/contenu/

Elle est connectée à l'unité centrale à travers deux bus : un bus d'adresse et un bus de données.

3.3 Jeu d'instructions de PM

PM est doté du jeu d'instructions suivant :

L'adressage **immédiat** d'une instruction INSTR est noté : INSTR #<valeur>

L'adressage **direct** d'une instruction INSTR est noté : INSTR <valeur>

addition avec l'accumulateur

ADD #<valeur> 2 octets code=16

ADD <adr 16 bits> 3 octets code=18

ADD <adr 8 bits> 2 octets code=17

chargement de l'accumulateur

LDA #<valeur> 2 octets code=10

LDA <adr 16 bits> 3 octets code=12

LDA <adr 8 bits> 2 octets code=11

rangement de l'accumulateur

STA <adr 16 bits> 3 octets code=15

STA <adr 8 bits> 2 octets code=14

positionnement indicateurs CNVZ

STC (C=1) 1 octet code=100

STN (N=1) 1 octet code=101

STV (V=1) 1 octet code=102

STZ (Z=1) 1 octet code=103

CLC (C=0) 1 octet code=104

CLN (N=0) 1 octet code=105

CLV (V=0) 1 octet code=106

CLZ (Z=0) 1 octet code=107

branchement relatif sur indicateur

BCZ (brancht.si C=0) 2 octets code=22
BNZ (brancht.si N=0) 2 octets code=23
BVZ (brancht.si V=0) 2 octets code=24
BZZ (brancht.si Z=0) 2 octets code=25
END (fin programme) 1 octet code=255

Dans le CCR les 4 bits indicateurs sont dans cet ordre : N V Z C.
Ils peuvent être :

- soit positionnés automatiquement par la machine:

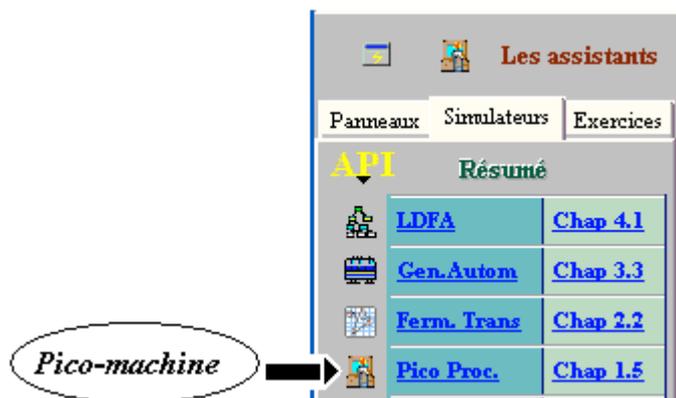
N = le bit de poids fort de l'Accumulateur
V = 1 si overflow (dépassement capacité) 0 sinon
Z = 1 si Accumulateur vaut 0
Z = 0 si Accumulateur <0
C = 1 si retenue (dans l'addition) sinon 0

- soit positionnés par programme.

Exemple de programme en PM

```
LDA #18 ; {chargement de l'accumulateur avec la valeur 18}  
STA 50 ; {rangement de l'accumulateur dans la mémoire n° 50}  
LDA #5 ; {chargement de l'accumulateur avec la valeur 5}  
STA 51 ; {rangement de l'accumulateur dans la mémoire n°51}  
ADD 50 ; {addition de l'accumulateur avec la mémoire n°50}  
STA 52 ; {rangement de l'accumulateur dans la mémoire n°52}  
END
```

Le lecteur est encouragé à utiliser le logiciel d'assistance Pico-machine du package pédagogique qui se trouve accessible à travers l'onglet simulateur et met en œuvre :



4. Mémoire de masse (externe ou auxiliaire)

Les données peuvent être stockées à des fins de conservation, ailleurs que dans la mémoire centrale volatile par construction avec les composants électroniques actuels. Des périphériques spécialisés sont utilisés pour ce genre de stockage longue conservation, en outre ces mêmes périphériques peuvent stocker une quantité d'information très grande par rapport à la capacité de stockage de la mémoire centrale.

On dénomme dispositifs de **stockage de masse**, de tels périphériques.

Les mémoires associées à ces dispositifs se dénomment mémoires de masse, mémoires externes ou encore mémoires auxiliaires, par abus de langage la mémoire désigne souvent le dispositif de stockage.

Les principaux représentant de cette famille de mémoires sont :

- Les bandes magnétiques (utilisés dans de très faible cas)
- Les disques magnétiques : les disquettes (en voie d'abandon), les disques durs (les plus utilisés).
- Les CD (très utilisés mais bientôt supplantés par les DVD)
- Les DVD

Des technologies ont vu le jour puis se sont éteintes (tambour magnétique, cartes magnétiques, mémoires à bulles magnétiques,...)

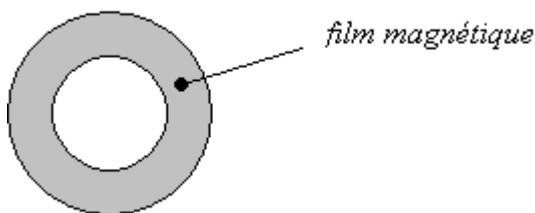
A part les bandes magnétiques qui sont un support ancien encore utilisé à fonctionnement séquentiel, les autres supports (disques, CD, DVD) sont des mémoires qui fonctionnent à accès direct.

4.1 Disques magnétiques - disques durs

Nous décrivons l'architecture générale des disques magnétiques encore appelés disques durs (terminologie américaine hard disk, par opposition aux disquettes nommées floppy disk) très largement employés dans tous les types d'ordinateur comme mémoire auxiliaire.

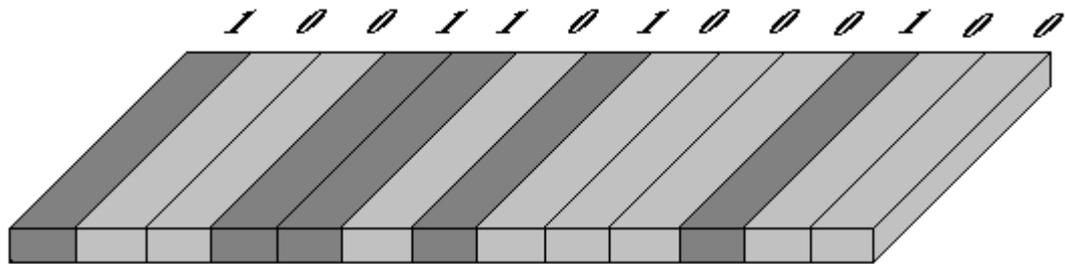
Un micro-ordinateur du commerce dispose systématiquement d'un ou plusieurs disques durs et au minimum d'un lecteur-graveur combiné de CD-DVD permettant ainsi l'accès aux informations extérieures distribuées sur les supports à faible coût comme les CD et les DVD qui les remplacent progressivement.

Un disque dur est composé d'un disque métallique sur lequel est déposé un film magnétisable, sur une seule face ou sur ses deux faces :



Ce film magnétique est composé de grains d'oxyde magnétisable et c'est le fait que certaines zones du

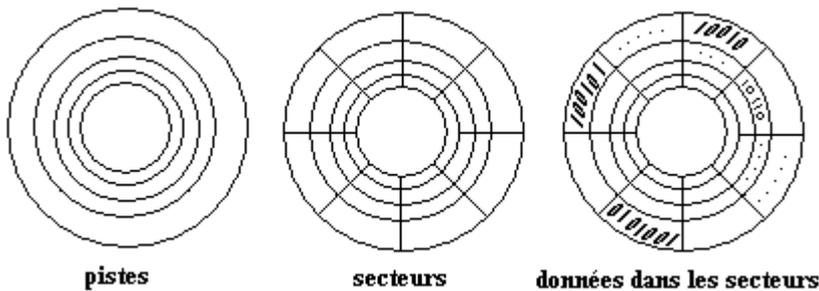
film conservent ou non un champ magnétique, qui représente la présence d'un bit à 0 ou bien à 1.



Coupe d'une tranche de disque et figuration de zones magnétisées interprétées comme un bit

Organisation générale d'un disque dur

Un disque dur est au minimum composé de pistes numérotées et de secteurs numérotés, les données sont stockées dans les secteurs.

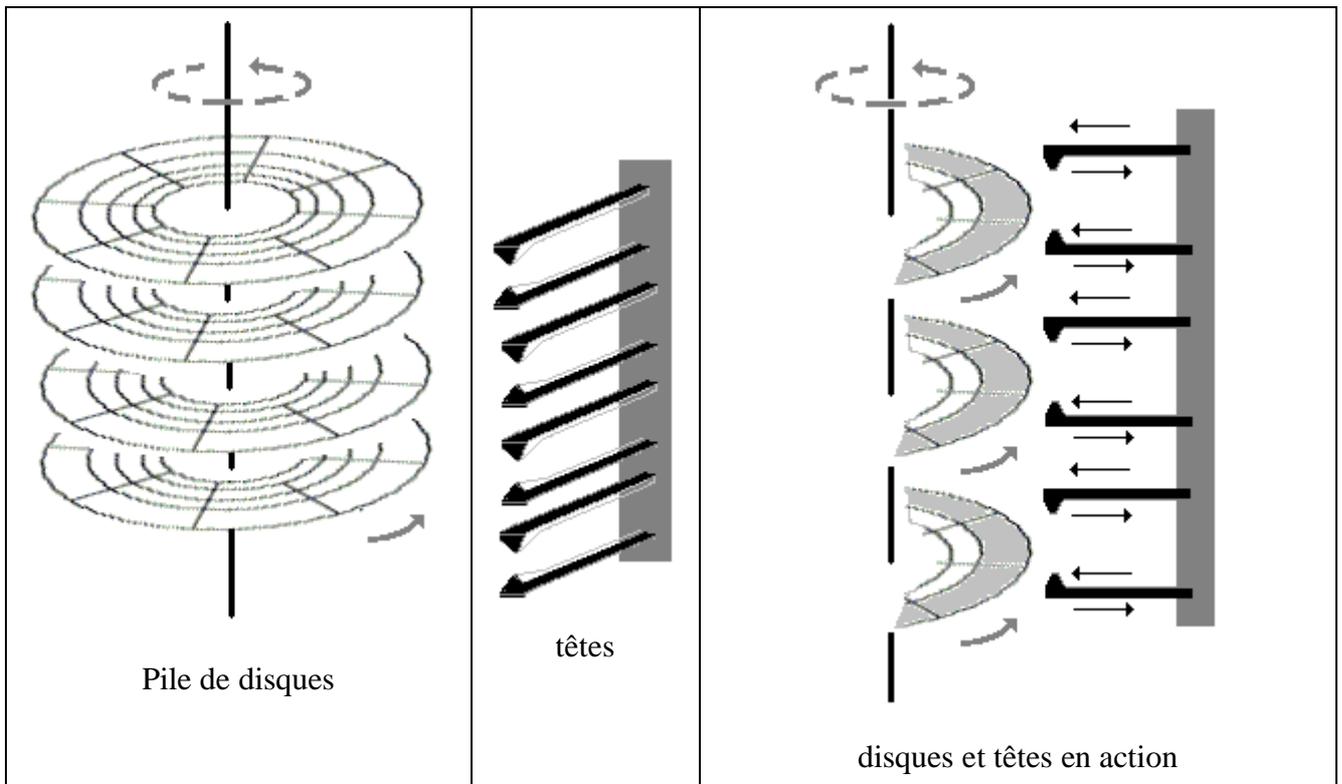


Le disque tourne sur son axe à vitesse d'environ 7200 tr/mn et un secteur donné peut être atteint par un **dispositif mobile appelé tête de lecture-écriture**, soit en lecture (analyse des zones magnétiques du secteur) ou en écriture (modification du champ des zones magnétiques du secteur). Opération semblable à celle qui se passe dans un magnéscope avec une bande magnétique qui passe devant la tête de lecture. Dans un magnéscope à une tête, seule la bande magnétisée défile, la tête reste immobile, dans un disque dur le disque tourne sur son axe de symétrie et la tête est animée d'un mouvement de translation permettant d'atteindre n'importe quelle piste du disque.

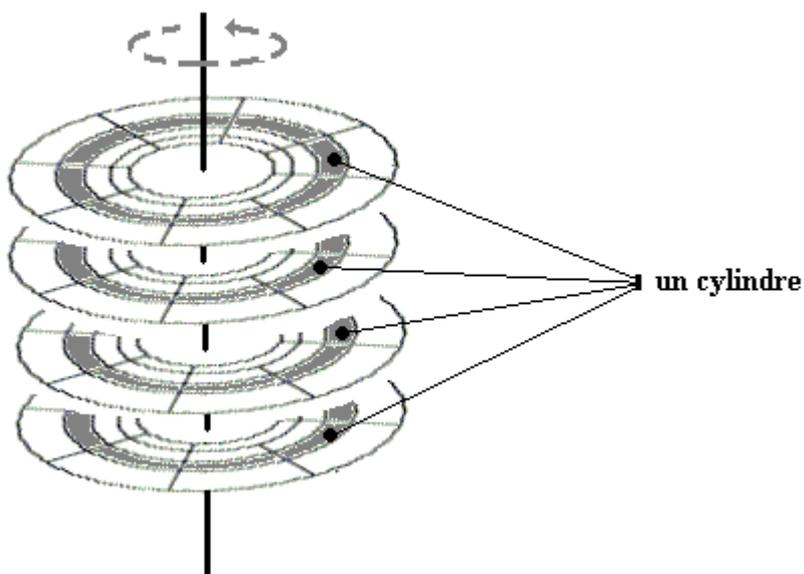
	<p>La tête "flotte" sur un coussin d'air engendré par la rotation très rapide du disque, ce qui la maintient à une hauteur constante de la surface du disque adéquate pour l'enregistrement du champ magnétique du film.</p>
--	--

Afin d'augmenter la capacité d'un "disque dur" on empile plusieurs disques physique sur le même axe et on le muni d'un dispositif à plusieurs têtes de lecture-écriture permettant d'accéder à toutes les faces et toutes les pistes de tous les disques physiques. La **pile de disques** construite est encore

appelée un disque dur.



Dans une pile de disques on ajoute la notion de cylindre qui repère toutes les pistes portant le même numéro sur chaque face de chacun des disques de la pile.



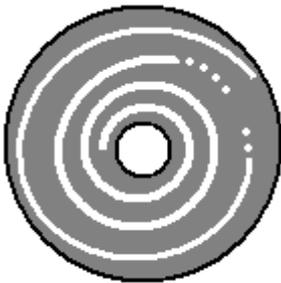
Formatage

Avant toute utilisation ou bien de temps à autre pour tout effacer, les disques durs doivent être "formatés", opération qui consiste à créer des pistes magnétiques et des secteurs vierges (tous les bits à 0 par exemple). Depuis 2005 les micro-ordinateurs sont livrés avec des disques durs dont la

capacité de stockage dépasse les 200 Go, ces disques sont pourvu d'un système de mémoire cache (semblable à celui décrit pour la cache du processeur central) afin d'accélérer les transferts de données. Le temps d'accès à une information sur un disque dur est de l'ordre de la milliseconde.

4.2 Disques optique compact ou CD (compact disk)

Un tel disque peut être en lecture seule (dans ce cas on parle de CD-ROM) ou bien en lecture et écriture (dans ce cas on parle de CD réinscriptible). Il est organisé à peu près comme un disque magnétique, avec une différence notable : il n'a qu'une seule piste qui se déroule sous la forme d'une spirale.

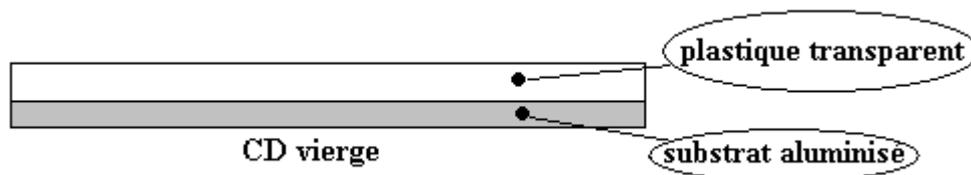


une piste en spirale

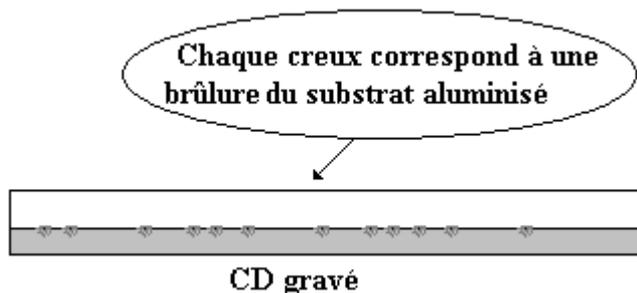
Si sur un disque magnétique les bits codant l'information sont représentés par des grains magnétisables, dans un CD ce sont des creux provoqués par brûlure d'un substrat aluminisé réfléchissant qui représentent les bits d'information.

Gravure d'un CD-ROM

Comme pour un disque dur, le formatage appelé gravure du CD crée les secteurs et les données en même temps. Plus précisément c'est l'absence ou la présence de brûlures qui représente un bit à 0 ou à 1, le substrat aluminisé est protégé par une couche de plastique transparent.

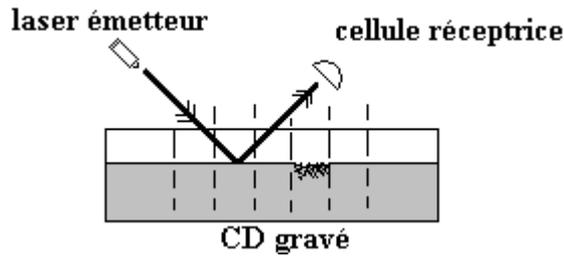


Après gravure avec le graveur de CD, les bits sont matérialisés :



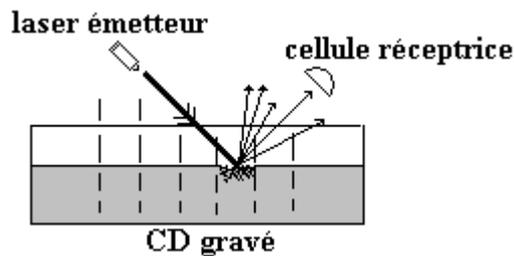
Principe de lecture d'un CD :

Lorsque le substrat est lisse (non brûlé) à un endroit matérialisant un bit, le rayon lumineux de la diode laser du lecteur est réfléchi au maximum de son intensité vers la cellule de réception.



On dira par exemple que le bit examiné vaut 0 lorsque l'intensité du signal réfléchi est maximale.

Lorsque le substrat est brûlé à un endroit matérialisant un bit, la partie brûlée est irrégulière et le rayon lumineux de la diode laser du lecteur est mal réfléchi vers le capteur (une partie du rayonnement est réfléchi par les aspérités de la brûlure dans plusieurs directions). Dans cette éventualité l'intensité du signal capté par réflexion est moindre.



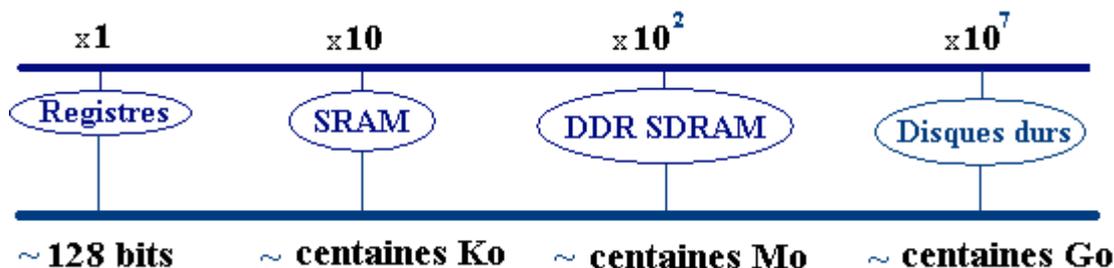
On dira par exemple que le bit examiné vaut 1 lorsque l'intensité du signal réfléchi n'est pas maximale.

La vitesse du disque est variable contrairement à un disque dur qui tourne à vitesse angulaire fixe. En effet la lecture de la piste en spirale nécessite une augmentation au fur et à mesure de l'éloignement du centre. Le temps d'accès à une information sur un CD 54x est de l'ordre de 77 millisecondes.

Le temps d'accès sur un CD ou un DVD est 10 fois plus lent que celui d'un disque dur et environ 100 fois moins volumineux qu'un disque dur.

Toutefois leur coût très faible et leur facilité de transport font que ces supports sont très utilisés de nos jours et remplacent la disquette moins rapide et de moindre capacité.

Nous pouvons reprendre l'échelle comparative des temps d'accès des différents types de mémoires en y ajoutant les mémoires de masse et en indiquant en dessous l'ordre de grandeur de leur capacité :



1.6 Système d'exploitation

Plan du chapitre: 

1. Notion de système d'exploitation

- 1.1 Les principaux types d' OS
 - monoprogrammation
 - multi-programmation
 - temps partagé
- 1.2 Systèmes d'exploitations actuels

2. Processus et multi-threading dans un OS

- 2.1 Les processus agissent grâce au système
- 2.2 Le multi-threading
- 2.3 Relation entre threads et processus
- 2.4 L'ordonnancement pour gérer le temps du processeur
- 2.5 Un algorithme classique non préemptif (cas batch processing)
- 2.6 Deux algorithmes classiques préemptifs (cas interactif)

3. Gestion de la mémoire par un OS de multi-programmation

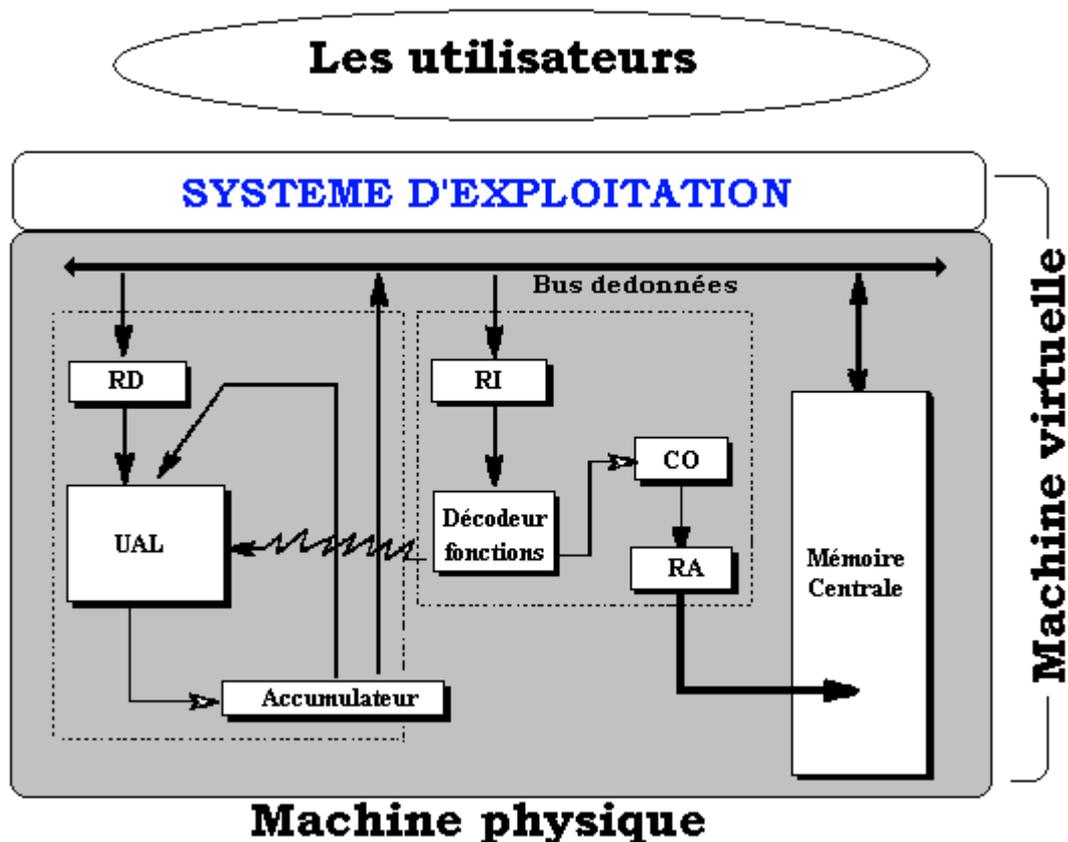
- 3.1 Mémoire virtuelle et segmentation
- 3.2 Mémoire virtuelle et pagination

4. Les OS des micro-ordinateurs

- 4.1 Le système d'exploitation du monde libre : Linux
- 4.2 Le système d'exploitation Windows de Microsoft

1. Notion de système d'exploitation

Un ordinateur est constitué de **matériel** (hardware) et de **logiciel** (software). Cet ensemble est à la disposition de un ou plusieurs utilisateurs. Il est donc nécessaire que quelque chose dans l'ordinateur permette la communication entre l'homme et la machine. Cette entité doit assurer une grande souplesse dans l'interface et doit permettre d'accéder à toutes les fonctionnalités de la machine. Cette entité douée d'une certaine intelligence de communication se dénomme " la machine virtuelle ". Elle est la réunion du matériel et du système d'exploitation (que nous noterons OS par la suite pour Operating System).



Le système d'exploitation d'un ordinateur est chargé d'assurer les fonctionnalités de communication et d'interface avec l'utilisateur. Un OS est un logiciel dont le grand domaine d'intervention est la gestion de toutes les ressources de l'ordinateur :

- mémoires,
- fichiers,
- périphériques,
- entrée-sortie,
- interruptions, synchronisation...

Un système d'exploitation n'est pas un logiciel unique mais plutôt une famille de logiciels. Une partie de ces logiciels réside en mémoire centrale (nommée **résident** ou **superviseur**), le reste est stocké en mémoire de masse (disques durs par exemple).

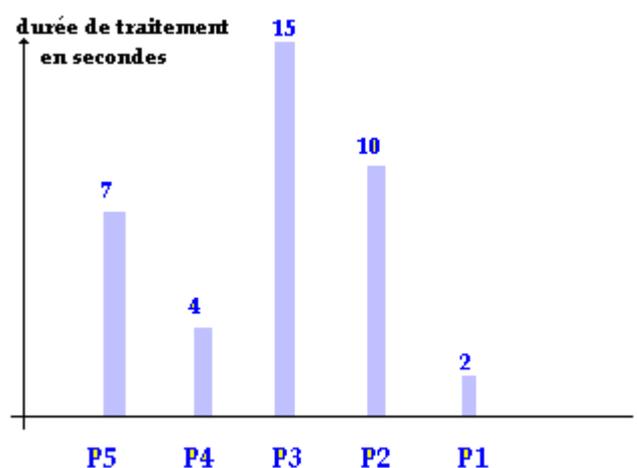
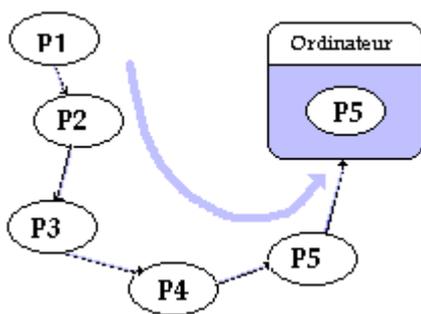
Afin d'assurer une bonne liaison entre les divers logiciels de cette famille, la cohérence de l'OS est généralement organisée à travers des tables d'interfaces architecturées en couches de programmation (niveaux abstraits de liaison). La principale tâche du superviseur est de gérer le contrôle des échanges d'informations entre les diverses couches de l'OS.

1.1 Historique des principaux types d' OS

Nous avons vu dans le tableau synoptique des différentes générations d'ordinateurs que les OS ont subi une évolution parallèle à celle des architectures matérielles. Nous observons en première approximation qu'il existe trois types d'OS différents, si l'on ignore les systèmes rudimentaires de la 1^{ère} génération.

MONOPROGRAMMATION : La 2^{ème} génération d'ordinateurs est équipée d'OS dits de "monoprogrammation" dans lesquels un seul utilisateur est présent et a accès à toutes les ressources de la machine pendant tout le temps que dure son travail. L'OS ne permet le passage que d'un seul programme à la fois.

A titre d'exemple, supposons que sur un tel système 5 utilisateurs exécutent chacun un programme P_1, P_2, P_3, P_4, P_5 :



Dans l'ordre de la figure ci-haut, chaque P_i attend que le P_{i+1} précédent ait terminé son exécution pour être exécuté à son tour.

Exemple de diagramme des temps d'exécution de chaque programme P_i de la figure de gauche.

L'axe des abscisses du diagramme des temps d'exécution, indique l'ordre de passage précédent (P_5 , puis P_4 etc...) nous voyons que les temps d'attente d'un utilisateur ne dépendent pratiquement pas de la durée d'exécution de son programme mais surtout de l'ordre du passage (les derniers sont pénalisés surtout si en plus leur temps propre d'exécution est faible comme P_1 par exemple).

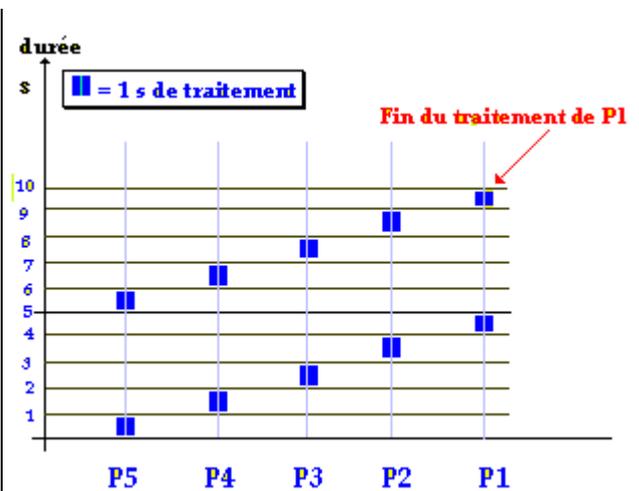
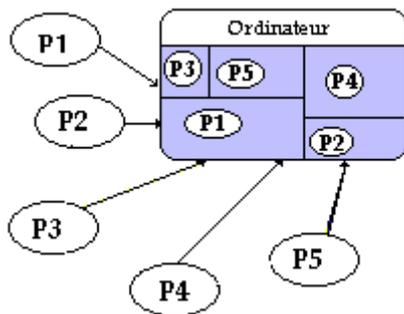
Une vision abstraite et synthétique d'un tel système est de considérer que 5 tables suffisent à le décrire. La table :

- des unités logiques,
- des unités physiques,
- des états,
- de ventilation des interruptions,
- des canaux.

Relativement aux temps d'attente, un système de monoprogrammation est injuste vis à vis des petits programmes.

MULTIPROGRAMMATION : La 3^{ème} génération d'ordinateur a vu naître avec elle les OS de multiprogrammation. Dans un tel système, plusieurs utilisateurs peuvent être présents en " même temps " dans la machine et se partagent les ressources de la machine pendant tout leur temps d'exécution.

En reprenant le même exemple que précédemment, P₁, P₂, P₃, P₄, P₅ sont exécutés cycliquement par l'OS qui leur alloue les ressources nécessaires (disque, mémoire, fichier,...) pendant leur tranche de temps d'exécution. Nous exposons dans l'exemple ci-dessous uniquement des exécutions ne nécessitant jamais d'interruptions, ni de priorité, et nous posons comme hypothèse que le temps fictif alloué pour l'exécution est de 1 seconde :



Dans la figure ci-haut, chaque P_i se voit allouer une tranche de temps d'exécution (1 seconde), dès que ce temps est écoulé, l'OS passe à l'exécution du P_{i+1} suivant etc...

Exemple de diagramme des temps d'exécution cyclique de chaque programme P_i de la figure de gauche.

Nous observons dans le diagramme des temps d'exécution que le système exécute P₅ pendant 1 seconde, puis abandonne P₅ et exécute P₄ pendant 1 seconde, puis abandonne P₄..., jusqu'à l'exécution de P₁, lorsqu'il a fini le temps alloué à P₁, il recommence à parcourir cycliquement la liste (P₅, P₄, P₃, P₂, P₁) et réalloue 1 seconde de temps d'exécution à P₅ etc... jusqu'à ce qu'un programme ait terminé son exécution et qu'il soit sorti de *la table des programmes à exécuter*.

Une vision abstraite déduite du paragraphe précédent et donc simplificatrice, est de décrire un tel système comme composé des 5 types de tables précédentes en y rajoutant de nouvelles tables et en y incluant la notion de priorité d'exécution hiérarchisée. Les programmes se voient affecter une priorité qui permettra à l'OS selon les niveaux de priorité, de traiter certains programmes plus complètement ou plus souvent que d'autres.

Relativement aux temps d'attente, un système de multiprogrammation rétablit une certaine justice entre petits et gros programmes.

TEMPS-PARTAGE : Il s'agit d'une amélioration de la multiprogrammation orientée vers le transactionnel. Un tel système organise ses tables d'utilisateurs sous forme de files d'attente. L'objectif majeur est de connecter des utilisateurs directement sur la machine et donc d'optimiser les temps d'attente de l'OS (un humain étant des millions de fois plus lent que la machine sur ses temps de réponse).

La 4^{ème} génération d'ordinateur a vu naître les réseaux d'ordinateurs connectés entre eux et donc de nouvelles fonctionnalités, comme l'interfaçage réseau, qui ont enrichi les OS déjà existants. De nouveaux OS entièrement orientés réseaux sont construits de nos jours.

1.2 Systèmes d'exploitation actuels

De nos jours, les systèmes d'exploitation sont des systèmes de multi-programmation dirigés vers certains type d'applications, nous citons les trois types d'application les plus significatifs.

Système inter-actif

Un tel système a vocation à permettre à l'utilisateur d'intervenir pratiquement à toutes les étapes du fonctionnement du système et pendant l'exécution de son programme (Windows Xp, Linux sont de tels systèmes).

Système temps réel

Comme son nom l'indique, un système de temps réel exécute et synchronise des applications en tenant compte du temps, par exemple un système gérant une chaîne de montage de pièces à assembler doit tenir compte des délais de présentation d'une pièce à la machine d'assemblage, puis à celle de soudage etc...

Système embarqué

C'est un système d'exploitation dédié à des applications en nombre restreint et identifiées : par exemple un système de gestion et de contrôle des mesures à l'intérieur d'une sonde autonome, un système pour assistant personnel de poche, système pour téléphone portables se connectant à internet etc...

Les principales caractéristiques d'un système d'exploitation de multi-programmation sont fondées sur la gestion des processus et la gestion de la mémoire à allouer à ces processus.

2. Processus et multi-threading dans un OS

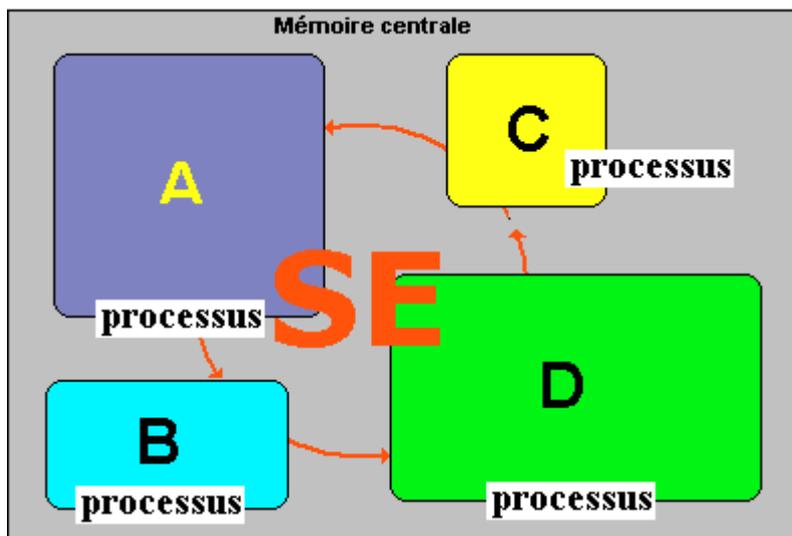
Contexte d'exécution d'un programme

Lorsqu'un programme qui a été traduit en instructions machines s'exécute, le processeur central lui fournit toutes ses ressources (registres internes, place en mémoire centrale, données, code,...), nous nommerons cet ensemble de ressources mises à disposition d'un programme son contexte d'exécution.

Programme et processus

Nous appelons en première analyse, processus l'image en mémoire centrale d'un programme s'exécutant avec son contexte d'exécution. Le processus est donc une abstraction synthétique d'un programme en cours d'exécution et d'une partie de l'état du processeur et de la mémoire.

Lorsque l'on fait exécuter plusieurs programmes "en même temps", nous savons qu'en fait la simultanéité n'est pas réelle. Le processeur passe cycliquement une partie de son temps (quelques millisecondes) à exécuter séquentiellement une tranche d'instructions de chacun des programmes selon une logique qui lui est propre, donnant ainsi l'illusion que tous les programmes sont traités en même temps parce que la durée de l'exécution d'une tranche d'instruction est plus rapide que notre attention consciente.



Le SE (système d'exploitation) gère 4 processus

2.1 Les processus agissent grâce au système

Processus

Nous donnons la définition précise de processus proposée par A.Tannenbaum, spécialiste des systèmes d'exploitation : c'est un programme qui s'exécute et qui possède **son propre espace mémoire**, ses registres, ses piles, ses variables et son propre processeur virtuel (simulé en multi-programmation par la commutation entre processus effectuée par le processeur unique).

Un processus a donc une vie propre et une existence éphémère, contrairement au programme qui lui est physiquement présent sur le disque dur. Durant sa vie, un processus peut agir de différentes manières possibles, il peut se trouver dans différents états, enfin il peut travailler avec d'autres processus présent en même temps que lui.

Différentes actions possibles d'un processus

- Un processus est **créé**.
- Un processus est **détruit**.
- Un processus **s'exécute** (il a le contrôle du processeur central et exécute les actions du programme dont il est l'image en mémoire centrale).
- Un processus est **bloqué** (il est en attente d'une information).
- Un processus est **passif** (il n'a plus le contrôle du processeur central).

On distingue trois actions particulières appelées états du processus

- **Etat actif** : le processus contrôle le processeur central et s'exécute).
- **Etat passif** : le processus est temporairement suspendu et mis en attente, le processeur central travaille alors avec un autre processus.
- **Etat bloqué** : le processus est suspendu toutefois le processeur central ne peut pas le réactiver tant que l'information attendue par le processus ne lui est pas parvenue.

Que peut faire un processus ?

- Il peut créer d'autre processus
- Il travaille et communique avec d'autres processus (notion de synchronisation et de messages entre processus)
- Il peut posséder une ressource à titre exclusif ou bien la partager avec d'autre processus.

C'est le rôle de l'OS que d'assurer la gestion complète de la création, de la destruction, des transitions d'états d'un processus. C'est toujours à l'OS d'allouer un espace mémoire utile au travail de chaque processus. C'est encore l'OS qui assure la synchronisation et la messagerie inter-processus.

Le système d'exploitation implémente cette gestion des processus à travers une table des processus qui contient une entrée par processus créé par le système sous forme d'un bloc de contrôle du processus (PCB ou **Process Control Block**). Le PCB contient lui-même toutes les informations de contexte du processus, plus des informations sur l'état du processus.

Lorsque la politique de gestion de l'OS prévoit que le processus P_k est réactivable (c'est au tour de P_k de s'exécuter), l'OS va consulter le PCB de P_k dans la table des processus et restaure ou non l'activation de P_k selon son état (par exemple si P_k est bloqué, le système ne l'active pas).

Afin de séparer les tâches d'un processus, il a été mis en place la notion de **processus léger** (ou **thread**).

2.2 Le multithreading

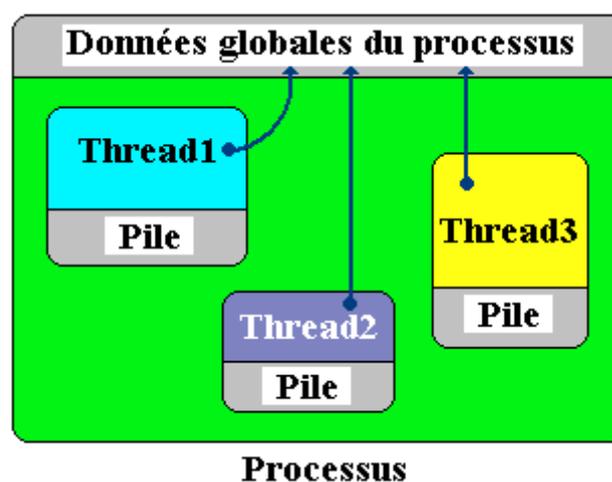
Nous pouvons voir le multithreading comme un changement de facteur d'échelle dans le fonctionnement de la multi-programmation.

En fait, chaque processus peut lui-même fonctionner comme le système d'exploitation en lançant des sous-tâches internes au processus et par là même reproduire le fonctionnement de la multi-programmation. Ces sous-tâches sont nommées "flux d'exécution" "processus légers" ou **Threads**.

Qu'est exactement un thread

- Un processus travaille et gère, pendant le quantum de temps qui lui est alloué, des ressources et exécute des actions sur et avec ces ressources. Un thread constitue la partie exécution d'un processus alliée à un minimum de variables qui sont propres au thread.
- Un processus peut comporter plusieurs threads.
- Les threads situés dans un même processus partagent les mêmes variables générales de données et les autres ressources allouées au processus englobant.
- Un thread possède en propre un contexte d'exécution (registres du processeur, code, données)

Cette répartition du travail entre **thread** et **processus**, permet de charger le **processus de la gestion des ressources** (fichiers, périphériques, variables globales, mémoire,...) et de dédier le **thread à l'exécution** du code proprement dit sur le processeur central (à travers ses registres, sa pile lifo etc...).



Le processus applique au niveau local une multi-programmation interne qui est nommée le multithreading. La différence fondamentale entre la multi-programmation et nommée le multithreading se situe dans l'indépendance qui existe entre les processus, alors que les threads sont liés à minima par le fait qu'ils partagent les mêmes données globales (celles du processus qui les

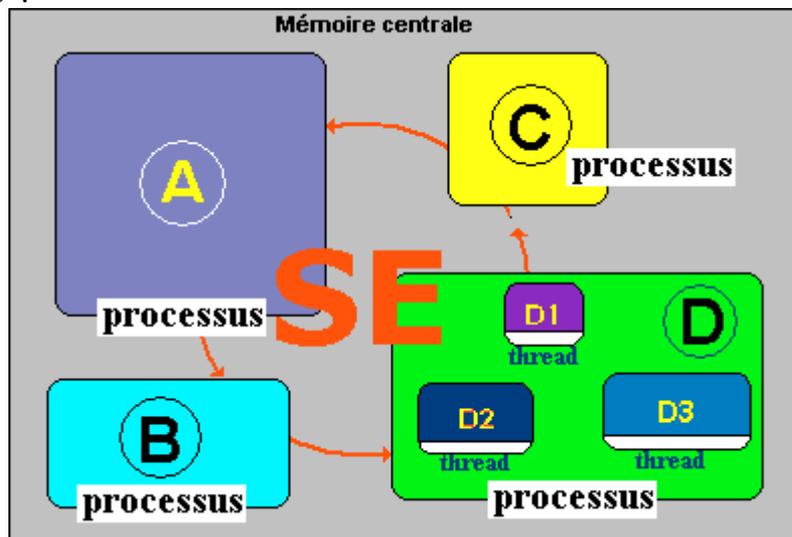
contient).

2.3 Relations entre thread et processus

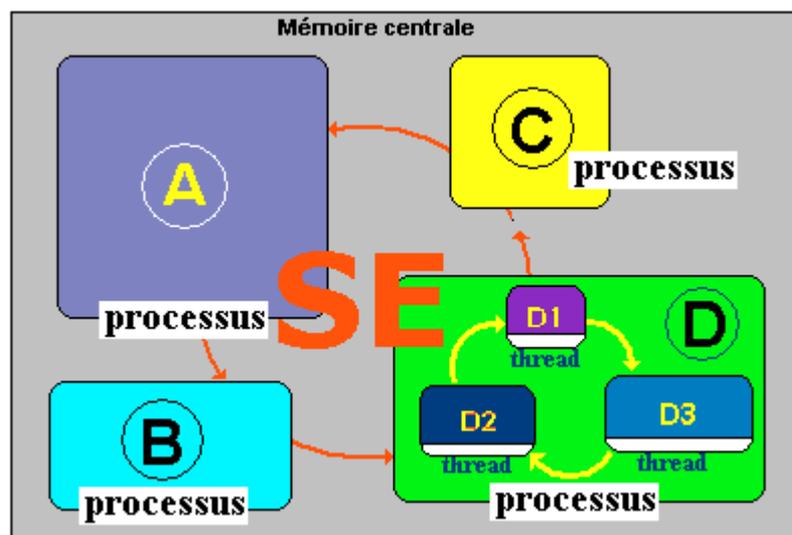
Ci-dessous nous supposons que le processus D assigné à l'application D, exécute en même temps les 3 Threads D1, D2 et D3 :



Soit par exemple 4 processus qui s'exécutent "en même temps" dont le processus D précédant possédant 3 threads :

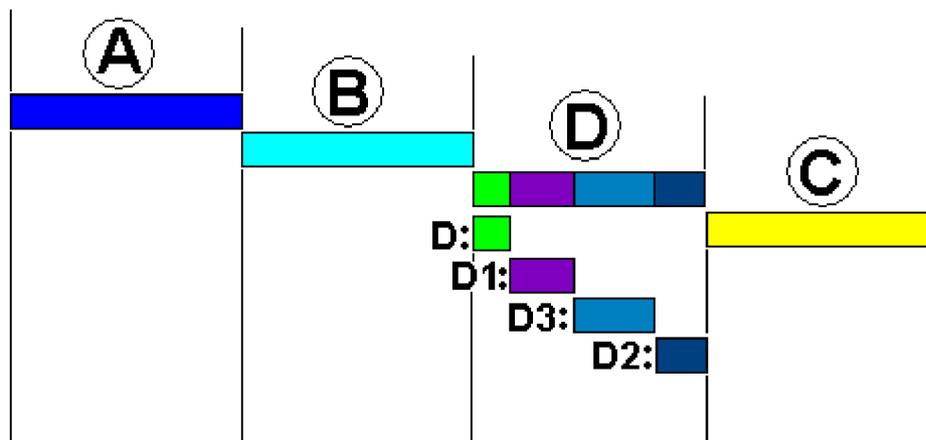


La commutation entre les threads d'un processus fonctionne identiquement à la commutation entre les processus.



Chaque thread se voit alloué cycliquement, lorsque le processus D est exécuté une petite tranche de temps dans le quantum de temps alloué au processus. Le partage et la répartition du temps sont effectués **uniquement** par le système d'exploitation.

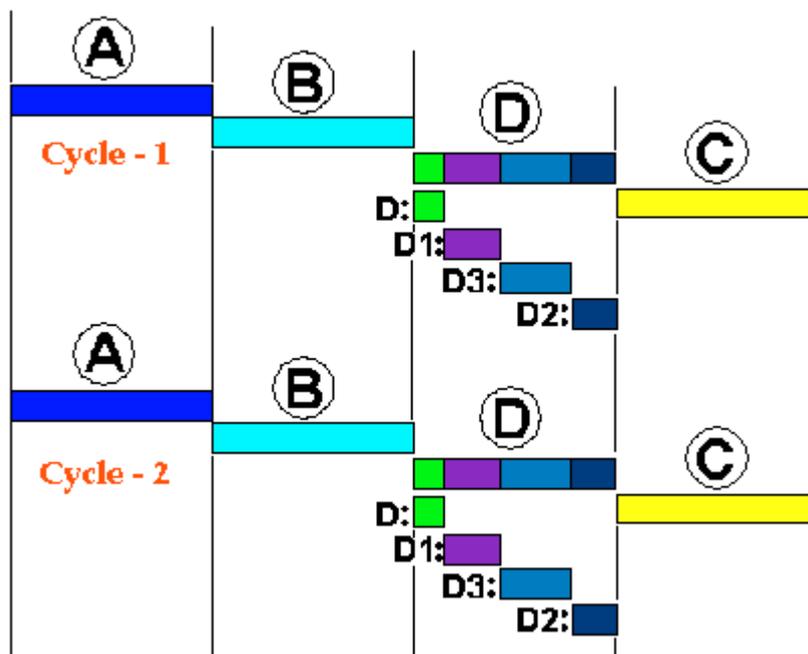
Dans l'exemple ci-dessous, nous figurons les processus A, B, C et le processus D avec ses threads dans un graphique représentant un quantum de temps d'exécution alloué par le système et supposé être la même pour chaque processus.



Tranches de temps allouées pendant l'exécution

Le système ayant alloué le même temps d'exécution à chaque processus, lorsque par exemple le tour vient au processus D de s'exécuter dans son quantum de temps, il exécutera pendant une petite sous-tranche de temps D1, puis D2, enfin D3 et attendra le prochain cycle.

Voici sous les mêmes hypothèses de quantum de temps égal d'exécution alloué à chaque processus A, B, C et D, le comportement de l'exécution sur 2 cycles consécutifs :



La majorité des systèmes d'exploitation (Windows, Unix, MacOS,...) supportent le **Multithreading**.

Différences et similitudes entre threads et processus :

- La communication entre les threads est **plus rapide** que la communication entre les processus.
- Les Threads possèdent les mêmes états que les processus.
- Deux processus peuvent travailler sur une même donnée (un tableau par exemple) en lecture et en écriture, dans une situation de **concurrency** dans laquelle le résultat final de l'exécution dépend de l'ordre dans lequel les lectures et écritures ont lieu, il en est de même pour les threads.

Les langages de programmation récents comme Delphi, Java et C# disposent chacun de classes permettant d'écrire et d'utiliser des threads.

Concurrence en cas de données partagées

Un OS met en place les notions de **sections critiques**, de **verrou**, de **sémaphore** et de **mutex** afin de gérer les situations de concurrence des processus et des threads dans le cadre de données partagées.

Mais il existe aussi une autre situation de concurrence inéluctable sur une machine mono-processeur, lorsqu'il s'agit de partager le temps d'activité du processeur central entre plusieurs processus. Une solution à cette concurrence est de gérer au mieux la répartition du quantum de temps alloué aux processus.

2.4 L'ordonnancement pour gérer le temps du processeur

Dans un système d'exploitation, c'est l'ordonnanceur (scheduler ou logiciel d'ordonnancement) qui établit la liste des processus prêts à être exécutés et qui effectue le choix du processus à exécuter immédiatement selon un algorithme d'ordonnancement. Dans ce paragraphe le mot tâche désigne aussi bien un processus qu'un thread.

Ordonnancement coopératif ou préemptif

- Un algorithme d'ordonnancement est dit préemptif lorsqu'une tâche qui s'exécute peut être interrompue après un délai d'horloge fixé appelé quantum de temps, même si la tâche est en cours d'exécution.
- Un algorithme d'ordonnancement est dit coopératif lorsqu'une tâche s'exécute soit jusqu'au terme de son exécution, soit parce qu'elle libère de son propre chef l'activité du processeur

Remarque

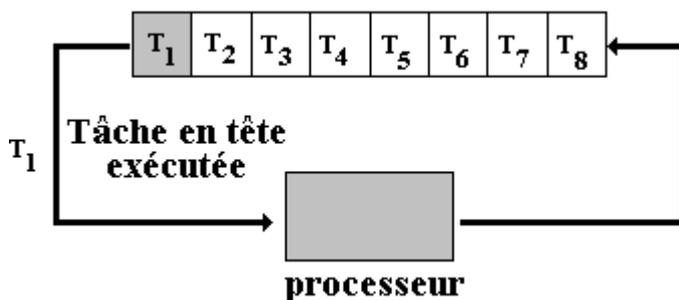
Dans les deux cas préemptif et coopératif, la tâche peut suspendre elle-même son exécution si elle reconnaît que le temps d'attente d'une donnée risque d'être trop long comme dans le cas d'une entrée-sortie vers un périphérique ou encore l'attente d'un résultat communiqué par une autre tâche. La différence importante entre ces deux modes est le fait qu'une tâche peut être suspendue après un délai maximum d'occupation du processeur central.

Dans un OS interactif comme Windows, Linux, Mac OS par exemple, la préemption est fondamentale car il y a beaucoup d'intervention de l'utilisateur pendant l'exécution des tâches. Une des premières versions de Windows (Windows 3) était coopérative et lorsqu'une tâche buggait elle pouvait bloquer tout le système (par exemple le lecteur de CD-ROM ouvert en cours d'exécution en attente d'une lecture impliquait un gel du système), ce n'est plus le cas depuis les versions suivantes de Windows (98, Xp, ...)

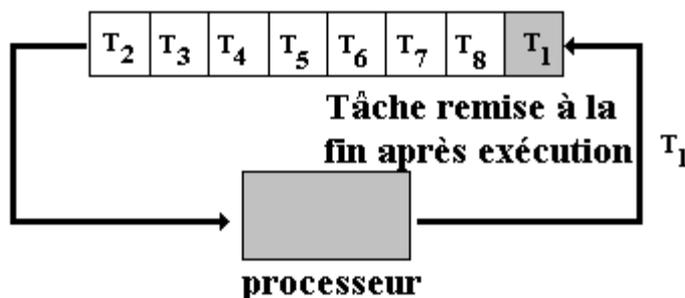
2.5 Un algorithme classique non préemptif dans un OS de batch processing: FCFS (First Come First Served)

Dans un OS de traitement par lot (batch processing) qui est un système dans lequel les utilisateurs n'interagissent pas avec l'exécution du programme (mise à jour et gestion des comptes clients dans une banque, calculs scientifiques,...), multi-programmation avec préemption n'est pas nécessaire, la coopération seule suffit et les performances de calcul en sont améliorées.

Un algorithme d'ordonnancement important et simple purement coopératif de ce type d'OS se nomme **First Come First Served** (premier arrivé, premier servi). Toutes les tâches éligibles (prêtes à être exécutées) sont placées dans une file d'attente unique, la première tâche T_1 en tête de file est exécutée :



jusqu'à ce qu'elle s'interrompe elle-même (entrée-sortie, résultat,...) elle est alors remise en queue de liste et c'est la tâche suivante T_2 de la liste qui est exécutée et ainsi de suite :

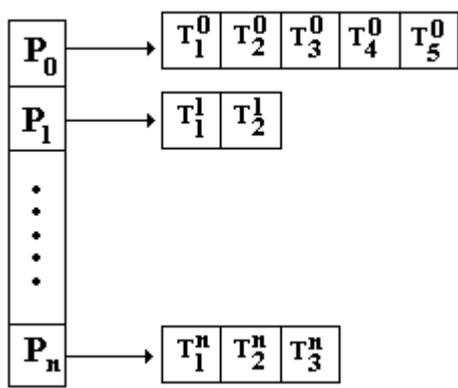


2.6 Deux algorithmes classiques préemptifs dans un OS interactif

Dans un OS interactif comme Windows par exemple, ce sont les threads qui sont ordonnancés puisque ce sont les threads qui sont chargés dans un processus, de l'exécution de certaines actions du processus qui sert alors de conteneur aux threads et aux ressources à utiliser. Comme précédemment nous nommons tâche (soit un thread, soit un processus) l'entité à ordonnancer par le système.

Algorithme de plus haute priorité

Les tâches T_i se voient attribuer un ordre de priorité P_k et sont rangées par ordre de priorité décroissant dans une liste de tâches toutes prêtes à être exécutées. Cette liste est organisée comme une file d'attente, il y a une file d'attente par niveau de priorité, dans la file de priorité P_k toutes les tâches T_i^k ont le même ordre de priorité P_k :



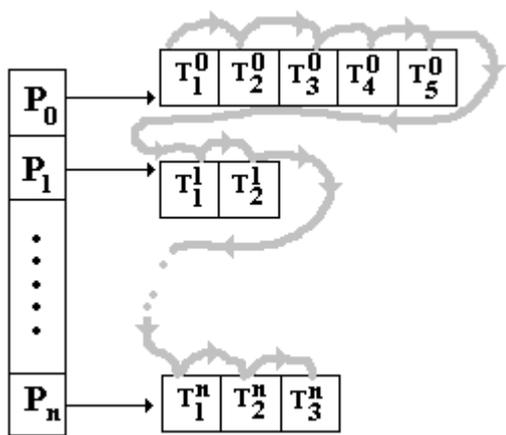
Dans l'exemple ci-contre P_0 représente la priorité la plus haute et P_n la priorité la plus basse.

Une tâche est exécutée pendant au plus la durée du quantum de temps qui lui est alloué (elle peut s'interrompre avant la fin de ce quantum de temps).

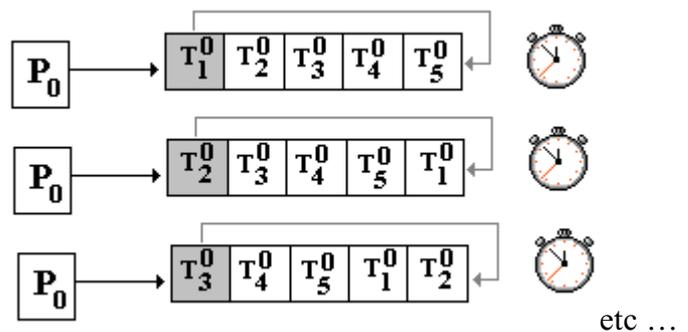


Les tâches de plus haute priorité sont exécutées d'abord depuis celles de priorité P_0 jusqu'à la priorité P_n .

Les tâches T_i^k de même priorité P_k sont exécutées selon un mécanisme de tourniquet, les unes à la suite des autres jusqu'à épuisement de la file, dès qu'une tâche a fini d'être exécutée, elle est remise en fin de liste d'attente de sa file de priorité :



Chemin d'exécution des tâches



Exécution des tâches de la file de priorité P_0

(une fois exécutée, une tâche est rangée à la fin de la file)

Le système peut changer les priorités d'une tâche après l'exécution du quantum de temps qui lui a été alloué.

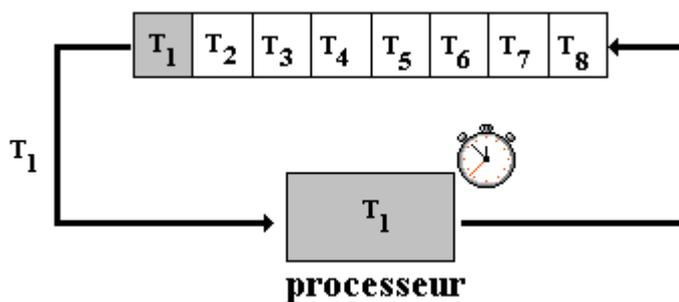
Algorithme du tourniquet (Round Robin)

C'est le premier algorithme qui a été utilisé en multi-programmation. Il ressemble à l'algorithme FCFS utilisé dans le cas d'un OS de batch processing, le système alloue un quantum de temps identique à chaque tâche ou selon le cas une tranche de temps variable selon le type de tâche.

Toutes les tâches éligibles sont placés dans une file d'attente unique, la première tâche T_1 en tête de file est exécutée, jusqu'à ce que :

- Soit elle s'interrompt elle-même (entrée-sortie, résultat,...)
- Soit le quantum de temps qui lui était alloué a expiré.

Dans ce cas, elle est remise en fin de file d'attente et c'est la tâche suivante T_2 de la file qui est exécutée selon les mêmes conditions et ainsi de suite :



3. Gestion de la mémoire par un OS de multi-programmation

Puisque dans un tel OS, plusieurs tâches sont présentes en mémoire centrale, à un instant donné, il faut donc que chacune dispose d'un espace mémoire qui lui est propre et qui soit protégé de toute interaction avec une autre tâche. Il est donc nécessaire de partitionner la mémoire centrale MC en plusieurs sous-ensembles indépendants.

Plusieurs tâches s'exécutant en mémoire centrale utilisent généralement plus d'espace mémoire que n'en contient physiquement la mémoire centrale MC, il est alors indispensable de mettre en place un mécanisme qui allouera le maximum d'espace mémoire physique utile à une tâche et qui libérera cet espace dès que la tâche sera suspendue. Le même mécanisme doit permettre de stocker, gérer et réallouer à une autre tâche l'espace ainsi libéré.

Les techniques de segmentation et de pagination mémoire dans le cadre d'une gestion de mémoire nommée mémoire virtuelle, sont une réponse à ces préoccupations d'allocation et de désallocation de mémoire physique dans la MC.

Du fait de la multi-programmation, les tâches sont chargées (stockées) dans des parties de la MC dont l'emplacement physique n'est déterminé qu'au moment de leur exécution. Sans entrer très profondément dans les deux mécanismes qui réalisent la répartition de la mémoire allouée aux tâches, la segmentation et la pagination mémoire, nous décrivons d'une manière générale ces deux méthodes ; les ouvrages spécialisés en la matière cités en bibliographie détaillent exhaustivement ces procédés.

3.1 Mémoire virtuelle et segmentation

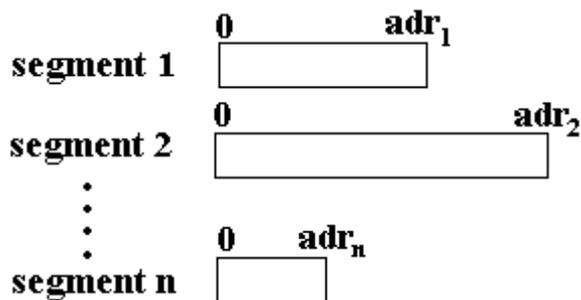
On désigne par mémoire virtuelle, une méthode de gestion de la mémoire physique permettant de faire exécuter une tâche dans un espace mémoire plus grand que celui de la mémoire centrale MC.

Par exemple dans Windows et dans Linux, un processus fixé se voit alloué un espace mémoire de 4 Go, si la mémoire centrale physique possède une taille de 512 Mo, le mécanisme de **mémoire virtuelle** permet de ne mettre à un instant donné dans les 512 Mo de la MC, que les éléments strictement nécessaires à l'exécution du processus, les autres éléments restant stockés sur le disque dur, prêts à être ramenés en MC à la demande.

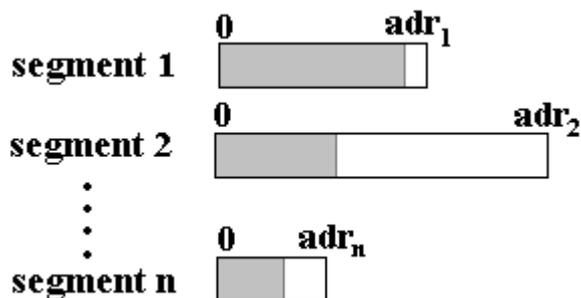
Un moyen employé pour gérer la topographie de cette mémoire virtuelle se nomme la segmentation, nous figurons ci-après une carte mémoire segmentée d'un processus.

Segment de mémoire

- Un segment de mémoire est un ensemble de cellules mémoires contiguës.
- Le nombre de cellules d'un segment est appelé la taille du segment, ce nombre n'est pas nécessairement le même pour chaque segment, toutefois tout segment ne doit pas dépasser une taille maximale fixée.
- La première cellule d'un segment a pour adresse 0, la dernière cellule d'un segment adr_k est bornée par la taille maximale autorisée pour un segment.



- Un segment contient généralement des informations de même type (du code, une pile, une liste, une table, ...) sa taille peut varier au cours de l'exécution (dans la limite de la taille maximale), par exemple une liste de données contenues dans un segment peut augmenter ou diminuer au cours de l'exécution.
- Les cellules d'un segment ne sont pas toutes nécessairement entièrement utilisées.



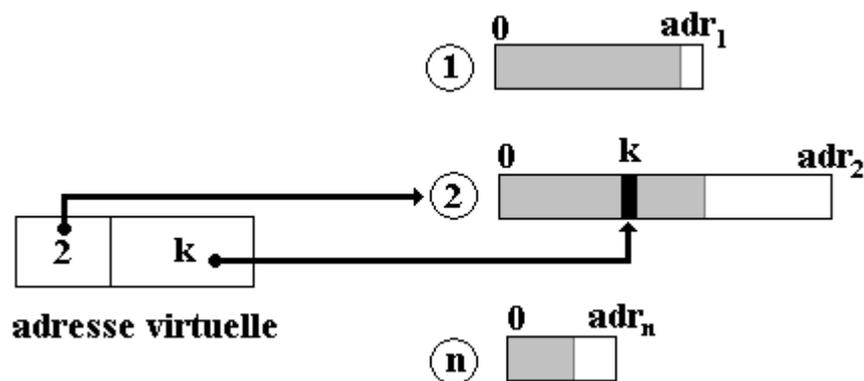
- L'adresse d'une cellule à l'intérieur d'un segment s'appelle l'**adresse relative** (au segment) ou **déplacement**. On utilise plus habituellement la notion d'**adresse logique** permettant d'accéder à une donnée dans un segment, par opposition à l'**adresse physique** qui représente une adresse effective en mémoire centrale.

C'est un ensemble de plusieurs segments que le système de gestion de la mémoire utilise pour allouer de la place mémoire aux divers processus qu'il gère.

Chaque processus est **segmenté** en un nombre de segments qui dépend du processus lui-même.

Adresse logique ou virtuelle

Une **adresse logique** aussi nommée **adresse virtuelle** comporte deux parties : le numéro du segment auquel elle se réfère et l'adresse relative de la cellule mémoire à l'intérieur du segment lui-même.



Remarques

Le nombre de segments présents en MC n'est pas fixe.

La taille effective d'un segment peut varier pendant l'exécution

Pendant l'exécution de plusieurs processus, la MC est divisée en deux catégories de blocs : les blocs de **mémoire libre** (libéré par la suppression d'un segment devenu inutile) et les blocs de **mémoire occupée** (par les segments actifs).

Fragmentation mémoire

Le partitionnement de la MC entre blocs libres et blocs alloués se dénomme la fragmentation mémoire, au bout d'un certain temps, la mémoire contient une multitude de blocs libres qui deviendront statistiquement de plus en plus petits jusqu'à ce que le système ne puisse plus allouer assez de mémoire contiguë à un processus.

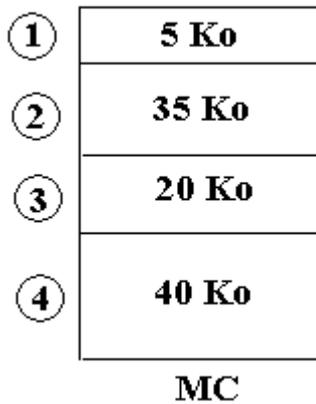
Exemple

Soit une MC fictive de 100 Ko segmentable en segments de taille maximale 40 Ko, soit un processus

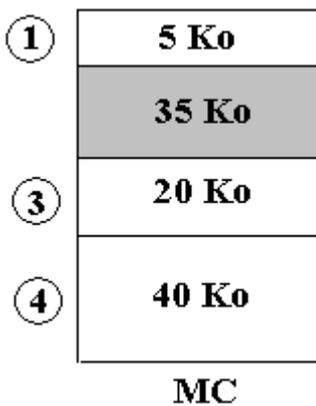
P segmenté par le système en 6 segments dont nous donnons la taille dans le tableau suivant :

Numéro du segment	Taille du segment
1	5 Ko
2	35 Ko
3	20 Ko
4	40 Ko
5	15 Ko
6	23 Ko

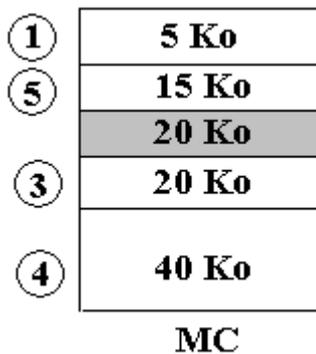
Supposons qu'au départ, les segments 1 à 4 sont chargés dans la MC :



Supposons que le segment n°2 devenu inutile soit désalloué :

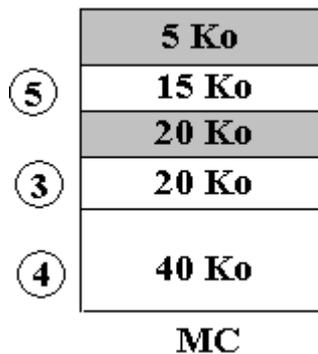


Puis chargeons en MC le segment n°5 de taille 15 Ko dans l'espace libre qui passe de 35 Ko à 20 Ko :



La taille du bloc d'espace libre diminue.

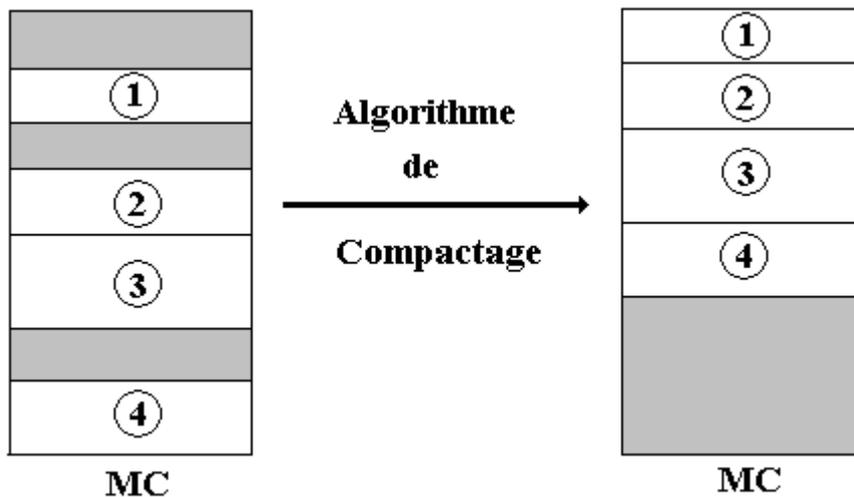
Continuons l'exécution du processus P en supposant que ce soit maintenant le segment n°1 qui devienne inutile :



Il y a maintenant séparation de l'espace libre (fragmentation) en deux blocs, l'un de 5 Ko de mémoire contiguë, l'autre de 20 Ko de mémoire contiguë, soit un total de 25 Ko de mémoire libre. Il est toutefois impossible au système de charger le segment n°6 qui occupe 23 Ko de mémoire, car il lui faut 23 Ko de mémoire contiguë. Les système doit alors procéder à une réorganisation de la mémoire libre afin d'utiliser "au mieux" ces 25 Ko de mémoire libre.

Compactage

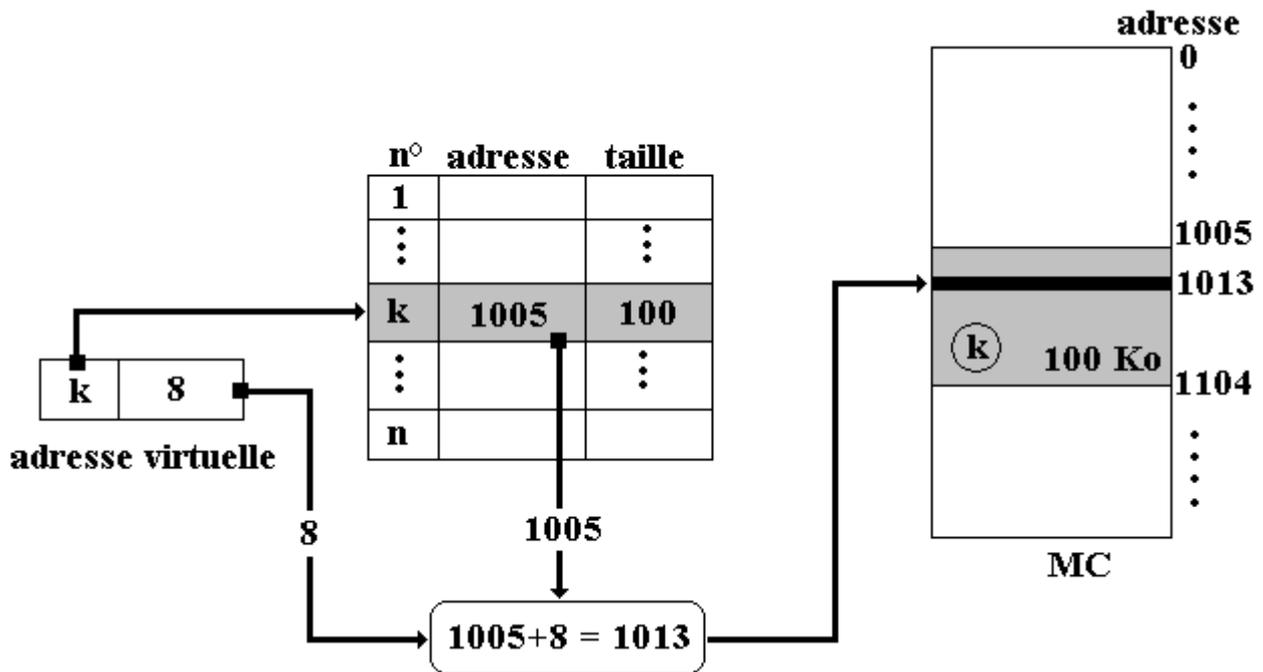
Dans le cas de la gestion de la MC par segmentation pure, un algorithme de compactage est lancé dès que cela s'avère nécessaire afin de ramasser ces fragments de mémoire libre éparpillés et de les regrouper dans un grand bloc de mémoire libre (on dénomme aussi cette opération de compactage sous le vocable de ramasse miettes ou garbage collector)



La figure précédente montre à gauche, une mémoire fragmentée, et à droite la même mémoire une fois compactée.

Adresse virtuelle - adresse physique

Nous avons parlé d'adresse logique d'une donnée par exemple, comment le système de gestion d'une mémoire segmentée retrouve-t-il l'adresse physique associée : l'OS dispose pour cela d'une table décrivant la "carte" mémoire de la MC.



La segmentation mémoire n'est pas la seule méthode utilisée pour gérer de la mémoire virtuelle, nous proposons une autre technique de gestion de la mémoire virtuelle très employée : la pagination mémoire. Les OS actuels employant un mélange de ces deux techniques, le lecteur se doit donc d'être au fait des mécanismes de base de chaque technique.

3.2 Mémoire virtuelle et pagination

Comme dans la segmentation mémoire, la pagination est une technique visant à partitionner la mémoire centrale en blocs (nommés ici **cadres de pages**) de taille fixée contrairement aux segments de taille variable.

Lors de l'exécution de plusieurs processus découpés chacun en plusieurs pages nommées **pages virtuelles**. On parle alors de **mémoire virtuelle paginée**. Le nombre total de mémoire utilisée par les pages virtuelles de tous les processus, excède généralement le nombre de cadres de pages disponibles dans la MC.

Le système de gestion de la mémoire virtuelle paginée est chargé de gérer l'allocation et la désallocation des pages dans les cadres de pages.

La MC est divisée en un nombre de cadres de pages fixé par le système (généralement la taille d'un cadre de page est une puissance de 2 inférieure ou égale à 64 Ko).

La taille d'une page virtuelle est exactement la même que celle d'un cadre de page.

Comme le nombre de pages virtuelles est plus grand que le nombre de cadres de pages on dit aussi que l'espace d'adressage virtuel est plus grand que l'espace d'adressage physique. Seul un certain nombre de pages virtuelles sont présentes en MC à un instant fixé.

A l'instar de la segmentation, l'adresse virtuelle (logique) d'une donnée dans une page virtuelle, est composée par le numéro d'une page virtuelle et le déplacement dans cette page. L'adresse virtuelle est transformée en une adresse physique réelle en MC, par une entité se nommant la MMU (Memory

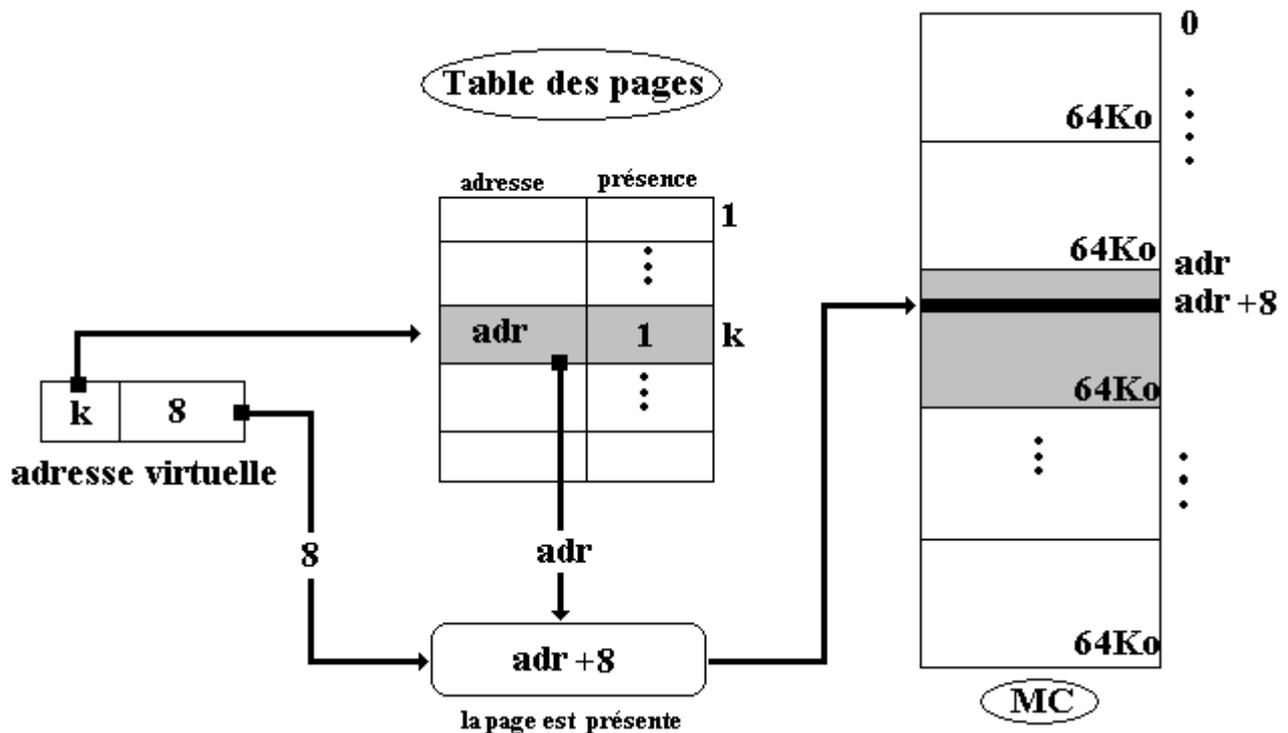
Management Unit) assistée d'une table des pages semblable à la table des segments.

La table des pages virtuelles

Nous avons vu dans le cas de la segmentation que la table des segments était plutôt une liste (ou table dynamique) ne contenant que les segments présents en MC, le numéro du segment étant contenu dans l'entrée. La table des pages virtuelles quant à elle, est un vrai tableau indicé sur les numéros de pages. Le numéro d'une page est l'indice dans la table des pages, d'une cellule contenant les informations permettant d'effectuer la conversion d'une adresse virtuelle en une adresse physique.

Comme la table des pages doit référencer toutes les pages virtuelles et que seulement quelques unes d'entre elles sont physiquement présentes en MC, chaque page virtuelle se voit attribuer un drapeau de présence (représenté par un bit, la valeur 0 indique que la table est actuellement absente, la valeur 1 de ce bit indique qu'elle est actuellement présente en MC).

Schéma simplifié d'une gestion de MC paginée (page d'une taille de 64Ko) illustrant le même exemple que pour la segmentation, soit accès à une donnée d'adresse 8 dans la page de rang k, le cadre de page en MC ayant pour adresse 1005, la page étant présente en MC :

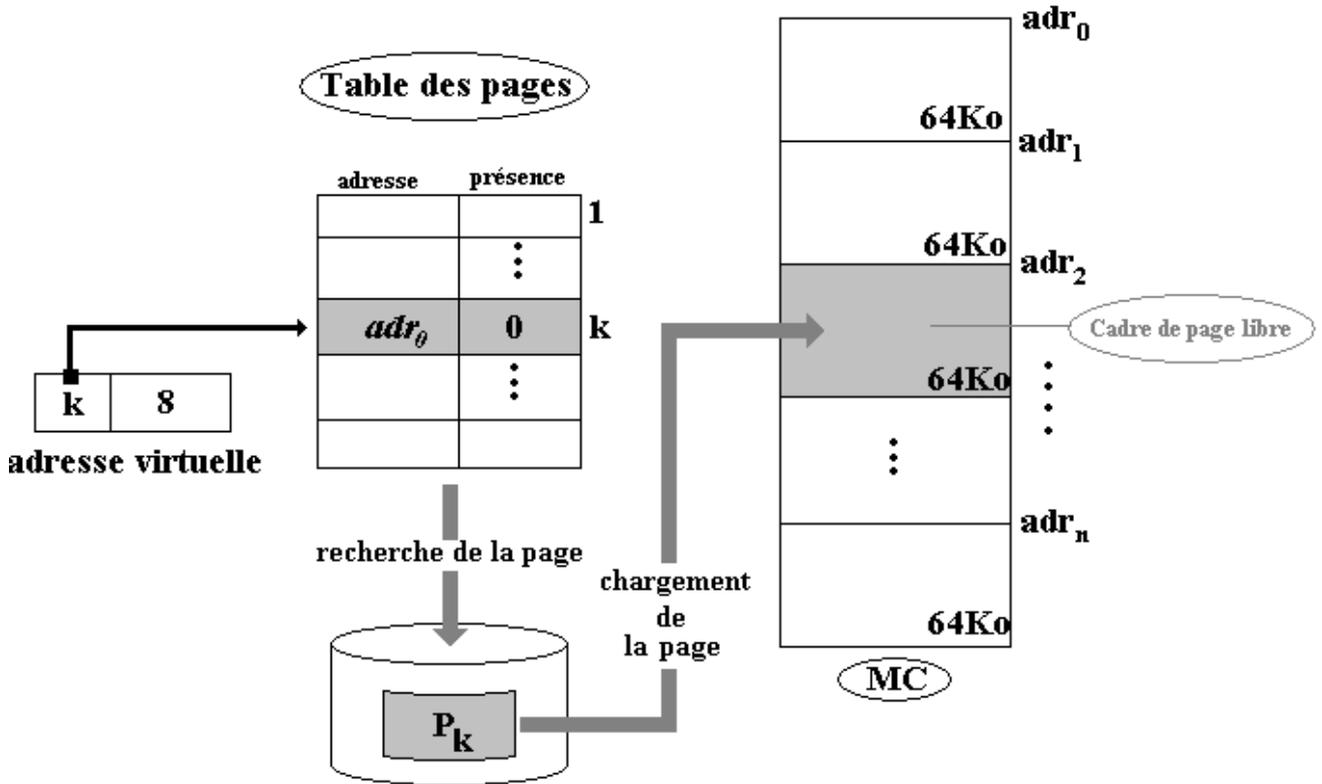


Lorsque la même demande d'accès à une donnée d'une page a lieu sur une page qui n'est pas présente en MC, la MMU se doit de la charger en MC pour poursuivre les opérations.

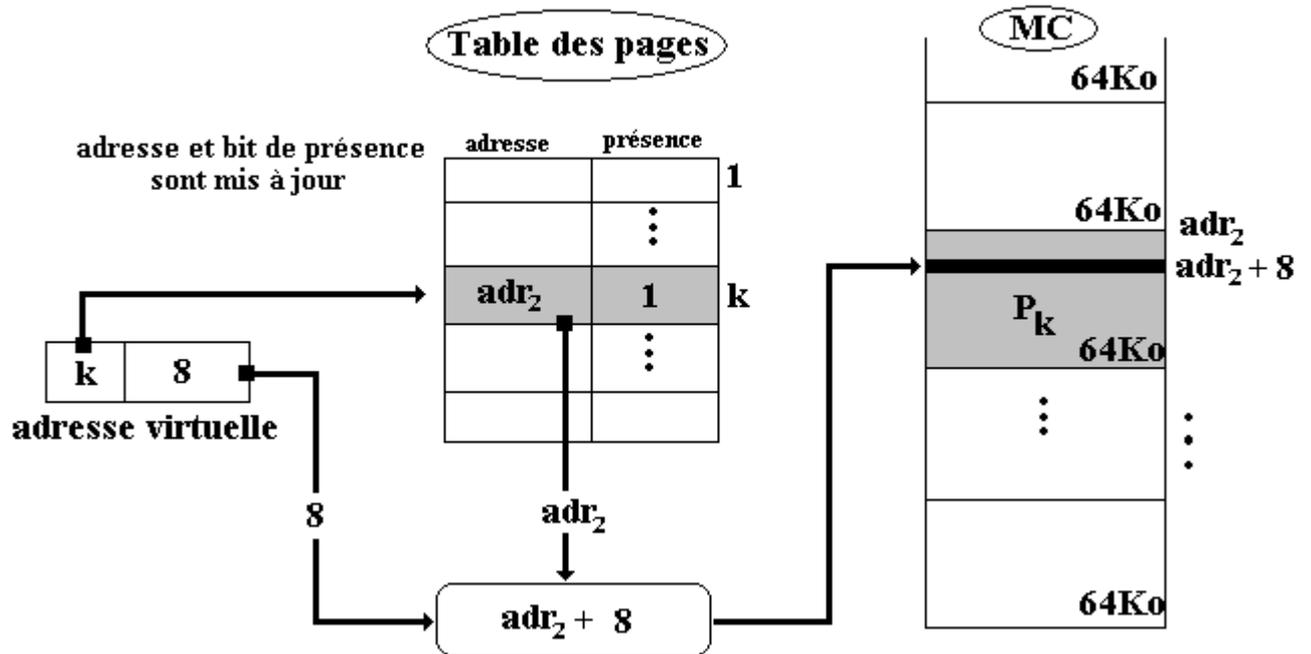
Défaut de page

Nous dirons qu'il y a défaut de page lorsque le processeur envoie une adresse virtuelle localisée dans une page virtuelle dont le bit de présence indique que cette page est absente de la mémoire centrale. Dans cette éventualité, le système doit interrompre le processus en cours d'exécution, il doit ensuite lancer une opération d'entrée-sortie dont l'objectif est de rechercher et trouver un cadre de page libre

disponible dans la MC dans lequel il pourra mettre la page virtuelle qui était absente, enfin il mettra à jour dans la table des pages le bit de présence de cette page et l'adresse de son cadre de page.



La figure précédente illustre un défaut de page d'une page P_k qui avait été anciennement chargée dans le cadre d'adresse adr_0 , mais qui est actuellement absente. La MMU recherche cette page par exemple sur le disque, recherche un cadre de page libre (ici le bloc d'adresse adr_2 est libre) puis charge la page dans le cadre de page et l'on se retrouve ramené au cas d'une page présente en MC :



En fait, lorsqu'un défaut de page se produit tous les cadres de pages contiennent des pages qui sont marquées présentes en MC, il faut donc en sacrifier une pour pouvoir caser la nouvelle page demandée. Il est tout à fait possible de choisir aléatoirement un cadre de page, de le sauvegarder sur disque et de l'écraser en MC par le contenu de la nouvelle page.

Cette attitude qui consiste à faire systématiquement avant tout chargement d'une nouvelle page une sauvegarde de la page que l'on va écraser, n'est pas optimisée car si la page que l'on sauvegarde est souvent utilisée elle pénalisera plus les performances de l'OS (car il faudra que le système recharge souvent) qu'une page qui est très peu utilisée (qu'on ne rechargera pas souvent).

Cette recherche d'un "bon" bloc à libérer en MC lors d'un défaut de page est effectuée selon plusieurs algorithmes appelés algorithmes de remplacement. Nous donnons une liste des principaux noms d'algorithmes utilisables en cas de défaut de page. Tous ces algorithmes diffèrent par la méthode qu'ils emploient pour choisir la page de remplacement (bloc libre) selon sa fréquence d'utilisation ou bien selon le temps écoulé depuis sa dernière utilisation :

NRU (Not Recently Use)
LRU (Last Recently Use)
LFU (Last Frequently Use)
MFU (Most Frequently Use)
NFU (Not Frequently Use)
FIFO (First In First Out)

L'algorithme LRU semble être le plus performant dans le maximum de cas et il est celui qui est le plus utilisé. Cet algorithme nécessite une gestion supplémentaire des pages libres en MC selon une liste d'attente : la page la plus récemment utilisée est la première de la liste, elle est suivie par la deuxième page la plus récemment utilisée et ainsi de suite jusqu'au dernier élément de la liste qui est la page la moins récemment utilisée.

Le fondement pratique de cet algorithme se trouve dans le fait qu'une page qui vient d'être utilisée a de bonne chance d'être réutilisée par la suite très rapidement.

Dans les OS, les concepteurs élaborent des variantes personnalisées de cet algorithme améliorant tel ou tel aspect.

4. Les OS des micro-ordinateurs

Les micro-ordinateurs apparus dans le grand public dès 1978 avec le Pet de Commodore, l'Apple et l'IBM-PC, ont répété en accéléré les différentes phases d'évolution des générations d'ordinateurs. Les OS des micro-ordinateurs ont suivi la même démarche et sont partis de systèmes de monoprogrammation comme MS-DOS et MacOS pour évoluer en systèmes multi-tâches (version affaiblie de la multiprogrammation) avec OS/2, windows et Linux.

De nos jours un OS de micro-ordinateur doit nécessairement adopter des normes de convivialité dans la communication homme-machine sous peine d'être rejeté par le grand public. Là, gît à notre sens, un des seuls intérêts de l'impact puissant du marché sur l'informatique. La pression des masses de consommateurs a fait sortir l'informatique des milieux d'initiés, et s'il n'y avait pas cette pression, les OS seraient encore accessibles uniquement par des langages de commandes textuels dont les initiés raffolent (la compréhension d'un symbolisme abstrus dénotant pour certains la marque d'une supériorité toute illusoire et assez insignifiante). Notons aussi que la réticence au changement, la résistance à la nouveauté et la force de l'habitude sont des caractéristiques humaines qui n'ont pas favorisé le développement des interfaces de communication. La communication conviviale des années 90-2000 réside essentiellement dans des notions inventées dans les années 70-80 à Xerox PARC (Palo Alto Research Center of Xerox), comme la souris, les fenêtres, les menus déroulants, les icônes, et que la firme Apple a commercialisé la première dans l'OS du MacIntosh dès 1984. Windows de Microsoft et OS/2 d'IBM se sont d'ailleurs ralliés à cette ergonomie.

Outre le système Mac OS (un Unix-like version OS X) du MacIntosh d'Apple qui ne représente qu'une petite part du marché des OS vendus sur micro-ordinateurs (environ 3% du marché), deux OS se partagent en proportion très inégale ce même marché Windows de Microsoft (environ 90% du marché) et Linux OS open source du monde libre (moins de 10% du marché), Linux représentant presque 50% des OS installés pour les serveurs Web. Le BeOs est un autre système Unix-like développé pour micro-ordinateur lui aussi fondé sur des logiciels GNU mais il est officiellement payant (le prix est modeste et équivalent aux distributions de Linux).

4.1 Le système d'exploitation du monde libre Linux

A.Tannenbaum écrit en 1987 pour ses étudiants, un système d'exploitation pédagogique baptisé MINIX fondé sur le système **UNIX** : c'est la naissance d'un système d'exploitation fondé sur Unix sans droit de licence. Linus Thorvalds reprend l'OS Minix et en 1994, la première version opérationnelle et stable d'un nouveau système est accessible gratuitement sous le nom de LINUX.

UNIX est un OS de multi-programmation commercial fondé lui-même sur les concepts du système MULTICS et construit par des chercheurs du MIT et des laboratoires Bell. Il s'agissait d'une version allégée de MULTICS qui a fonctionné durant les années 1960-1970 sur de très gros ordinateurs. Les centres de calculs inter-universitaires français de cette décennie fonctionnaient sous MULTICS. L'OS Unix a été largement implanté et distribué sur les mini-ordinateurs PDP-11 de la société DEC et sur les VAX successeurs des PDP-11 de la même société.

Unix se voulait un système d'exploitation portable et universel, malheureusement des versions différentes et incompatibles entre elles ont été développées et cet état de fait perdure encore de nos jours. Nous trouvons actuellement des Unix dérivés de BSD (de l'université de Berkeley) le plus connu étant FreeBSD et des Unix dérivés du System V (de la société ATT).

Points forts de Linux

- ❑ Linux n'étant pas soumis aux contraintes commerciales, reste unique puisque les enrichissements qui lui sont apportés ne peuvent être propriétaires.
- ❑ Linux contient tout ce qu'une version commerciale d'Unix propose, sauf la maintenance système qui n'est pas garantie.
- ❑ Linux rassemble et intègre des fonctionnalités présentes dans les deux Unix BSD et System V.
- ❑ Vous pouvez modifier Linux et le revendre, mais vous devez obligatoirement fournir toutes les sources à l'acheteur.
- ❑ Linux supporte le multithreading et la pagination mémoire.

Points faibles de Linux

- ❑ Utiliser le système Linux, même avec une interface comme KDE ou Gnome demande une compétence particulière à l'utilisateur, car Linux reste encore orienté développeur plutôt qu'utilisateur final.
- ❑ Plusieurs distributions de Linux coexistent. Une distribution comporte un noyau commun, portable et standard de Linux accompagné de diverses interfaces, de programmes et d'outils systèmes complémentaires et de logiciels d'installations, nous citons quelques distributions les plus connues : Mandrake, Red Hat, Debian, Suse, Caldera,... Cette diversité donne au final un éventail de "facilités" qui semble être trop large parce que différentes entre elles et pouvant dérouter l'utilisateur non informaticien.

Linux essaie de concurrencer le système Windows sur PC, le match est encore inégal en nombre de logiciels installés fonctionnant sous cet OS, malgré un important battage médiatique effectué autour de ce système dans la fin des années 90 et les rumeurs récurrentes de la disparition de Windows voir même de la société Microsoft.

4.2 Le système d'exploitation Windows de Microsoft

Le premier système d'exploitation de PC (Personal Computer) conçu par la société Microsoft dans le début des années 1980 se nomme MS-DOS (système de mono-programmation) qui a évolué en véritable système de multi-programmation (avec processus, mémoire virtuelle, multi-tâches préemptif...etc) à partir de Windows 95, puis Windows 98, Me. La première version de Windows non basée sur MS-DOS a pour nom de code Windows NT au début des années 1990, depuis Windows 2000 qui est une amélioration de Windows NT, les successeurs comme Windows 2003, Xp et longhorn sont des systèmes d'exploitation à part entière, qui possèdent les mêmes fonctionnalités fondamentales qu'Unix et donc Linux.

Une grande différence entre Linux et Windows se situe dans la manière de gérer l'interface utilisateur (partie essentielle pour l'utilisateur final qui n'est pas un administrateur système). Cette remarque peut expliquer l'écart important d'installation de ces deux systèmes sur les PC. En outre les démarches

intellectuelles qui ont sous-tendu la construction de chacun de ces deux systèmes sont inverses.

En effet, Linux est dérivé d'un système d'exploitation inventé pour les gros ordinateurs des années 70, système auquel il a été rajouté un programme utilisateur non privilégié appelé interface de communication (KDE, Motif, Gnome, ...) de cette architecture découle le foisonnement d'interfaces différents déroutant l'utilisateur de base.

Windows à l'inverse, est parti d'un OS primitif et spécifique à un PC pour intégrer au cours du temps les fonctionnalités d'un OS de mainframe (gros ordinateur). L'interface de communication (le fenêtrage graphique) est intégré dans le cœur même du système. Le mode console (interface en ligne de commande genre MS-DOS ou ligne de commande Linux) est présent mais est très peu utilisé, les fonctionnalités de base du système étant assurées par des processus fenêtrés.

Les deux systèmes Linux et Windows fonctionnent sur les plates-formes basées sur les principaux micro-processeurs équipant les PC du marché (Intel majoritairement et AMD) aussi bien sur l'architecture 32 bits que sur l'architecture 64 bits toute récente.

Etant donné la remarquable croissance de l'innovation en technologie, les systèmes d'exploitation évoluent eux aussi afin d'adapter le PC aux différents outils inventés. Enfin, il y a bien plus d'utilisateurs non informaticiens qui achètent et utilisent des PC que d'informaticiens professionnels, ce qui implique une transparence et une convivialité obligatoire dans les communications homme-machine. Un OS idéal pour PC grand public doit convenir aussi bien au professionnel qu'à l'utilisateur final, pour l'instant Windows l'emporte très largement sur Linux, mais rien n'est dit, le consommateur restera l'arbitre.

Nous avons abordé ici des fonctionnalités importantes d'un système d'exploitation, nous avons indiqué qu'un OS assurait d'autres grandes fonctions que nous n'avons pas abordées, comme la gestion des entrées-sorties, l'interception des interruptions, la gestion des données sur des périphériques comme les disques durs dévolue au module de gestion des fichiers de l'OS. Ici aussi le lecteur intéressé par l'approfondissement du domaine des systèmes d'exploitation peut se référer à la bibliographie, en particulier un ouvrage de 1000 pages sur les OS par le père de MINIX A.Tannebaum.

1.7 Réseaux

Plan du chapitre: 

1. Les topologies physiques des réseaux d'ordinateurs

- 1.1 Les différentes topologies de réseaux
- 1.2 Réseau local

2. Liaisons entre réseaux

- 2.1 Topologie OSI à 7 couches
- 2.2 Réseau à commutation de paquets

3. Internet et le protocole TCP/IP

- Protocole, adresse IP
- Routage
- Protocole IP
- Protocole TCP
- Petite histoire d'Internet
- Intranet

Nous nous proposons dans ce chapitre, d'étudier les définitions théoriques nécessaires à la compréhension des notions fondamentales de réseau numérique informatique. L'objectif principal d'un réseau d'ordinateurs est de relier et de permettre l'exploitation à distance de systèmes informatiques à l'aide des télécommunications dans le cadre de réseaux à grande distance (les réseaux locaux emploient une technologie de câblage interne à l'entreprise).

Nous classons les réseaux informatiques en deux grandes catégories :

- ❑ Les réseaux locaux LAN (Local Area Network) de quelques centaines de mètres d'étendue au maximum, élaborés soit avec des fils, soit sans fil.
- ❑ Le grand réseau international Internet concernant toute la planète.

Les raisons principales pour la mise en place d'un réseau informatique, sont de pouvoir partager des données entre plusieurs ordinateurs et si possible partager le même traitement sur plusieurs ordinateurs.

Dans ce chapitre, après avoir énoncé les principes fondateurs des réseaux, nous concentrerons notre attention sur un réseau mondial incontournable de nos jours : Internet et son architecture logicielle fondée sur l'environnement logiciel TCP/IP mondialement utilisé et présent dans les OS Unix et Windows.

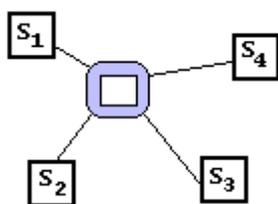
1. Les topologies physiques des réseaux d'ordinateurs

Il existe différentes manières d'interconnecter des systèmes informatiques à distance. On les nomme topologies physiques de réseaux.

1.1 Les différentes topologies physiques de réseaux

A) Le point à point simple

- n liaisons pour n systèmes S_i interconnectés,
- 1 seul point de connexion.

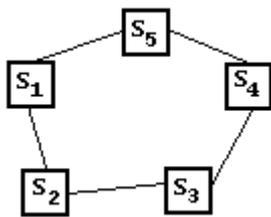


Architecture étoile

B) Le point à point en boucle

- n liaisons pour n systèmes S_i interconnectés,

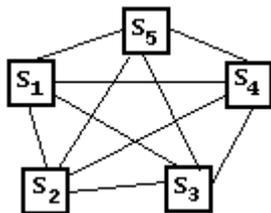
- Chaque S_i passe l'information au S_i suivant.



Architecture anneau

C) Le point à point complet

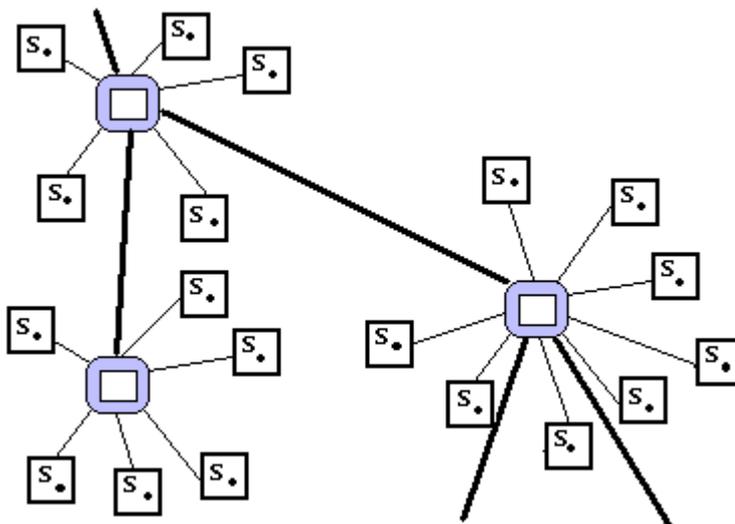
- $n(n-1)/2$ liaisons pour n systèmes S_i interconnectés,
- tous les S_i sont reliés entre eux.



Architecture maillée

D) Le point à point arborescent

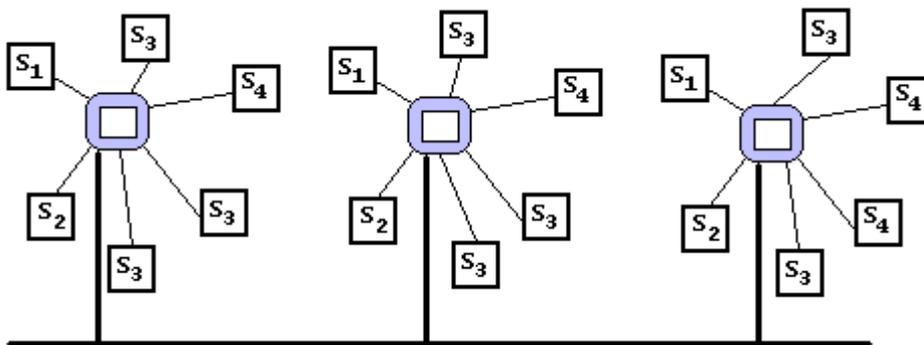
- n liaisons pour n systèmes S_i interconnectés à un même noeud,
- 1 liaison pour chaque noeud vers ses descendants, (topologie étoile à chaque noeud).



Architecture hiérarchique

E) Le multipoint

- n liaisons pour n systèmes S_i interconnectés à un même noeud,
- les points de connexion sont reliés par une même voie.



Architecture en bus

Il existe aussi des réseaux construits selon des combinaisons de ces topologies entre elles.

1.2 Réseau local

C'est un réseau dont les distances de liaison sont très faibles (entreprise, établissement scolaire, une salle,...).

Les réseaux locaux peuvent comporter ou non des *serveurs* (système informatique assurant la répartition et la gestion de ressources communes aux utilisateurs) et utiliser l'une des cinq architectures précédentes.

Ils sont composés de liaisons hertziennes ou établies par câble. Lorsqu'il y a plusieurs serveurs, chaque serveur peut être un poste de travail comme les autres ou bien être un *serveur dédié* (ne faisant office que de serveur). Signalons que la partie réseau local des micro-ordinateurs dotés d'un OS comme Windows ne nécessite aucun serveur dédié mais fonctionne aussi avec une version du système de type serveur.

Les deux principaux standards qui se partagent l'essentiel du marché des réseaux locaux sont Ethernet (topologie en bus) et token-ring (topologie en anneau). Les protocoles (loi d'échange d'information entre les systèmes informatiques) sont très nombreux. Le plus utilisé quantitativement dans le monde est TCP/IP (Transfert Control Protocol/Internet Protocol) qui est un protocole synchrone orienté bit (les informations sont des suites de bits).

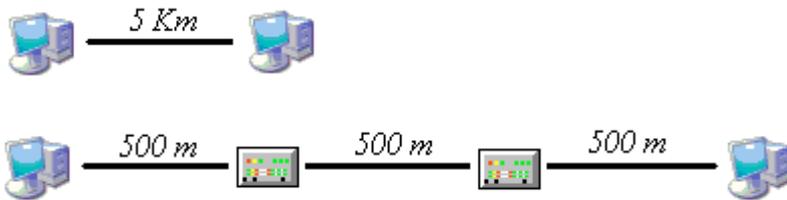
L'Ethernet comme moyen de transport et d'accès

- ❑ Le câblage Ethernet est le plus utilisé dans le monde, il est fondé sur la méthode "détection de porteuse à accès multiple et détection de collisions".
- ❑ Ethernet permet de raccorder entre eux au plus $2^{10} = 1024$ ordinateurs.
- ❑ Il est supporté physiquement selon le débit souhaité soit par du câble coaxial, soit de la paire de

fils torsadés, soit de la fibre optique; ces différents supports peuvent coexister dans un même réseau.

Quelques exemples de débits délivrés par un câblage Ethernet :

L'Ethernet classique (10 BaseT) transportant l'information à la vitesse de 10 Mbits/s (10 millions de bits par seconde). Avec l'Ethernet classique, la distance maximale théorique d'éloignement de deux machines avec un même câble est de 5 Km. La pose de Hub (sorte de prise multiple régénérant le signal entrant) est nécessaire : au maximum 2 Hub qui sont séparés par une distance théorique maximale de 500 m.

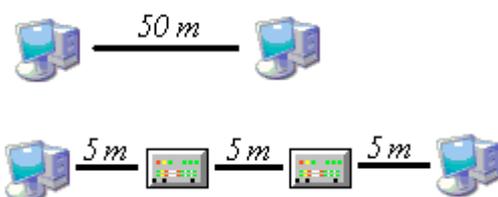


Cette contrainte ramène la distance maximale d'éloignement entre deux machines connectées grâce à des Hub à 1,5 Km, des techniques particulières permettent malgré tout d'atteindre les 5 Km avec des Hub en utilisant de la fibre optique.

Le Fast Ethernet (100 BaseT) est une extension du 10 BaseT, il permet de transporter de l'information à la vitesse de 100 Mbits/s (100 millions de bits par seconde) avec un même câble sur une distance maximale de 500 m qui correspond à la limitation imposée par la vitesse de transmission du signal physique dans le conducteur. Dans la pratique selon le nombre de Hub, la distance théorique maximale d'éloignement entre deux machines est réduite d'environ la moitié.



Le Gigabit Ethernet (1000 BaseT) qui permet de transporter de l'information à la vitesse de 1000 Mbits/s (1000 millions de bits par seconde) par câble ou fibre optique, est une évolution récente de l'Ethernet, l'augmentation de la vitesse de transmission réduit drastiquement la distance maximale théorique d'éloignement de deux machines avec un même câble à environ 50 m et à quelques mètres si elles sont connectées par des Hub.



Les chiffres qui sont donnés sur les figures précédentes concernant les distances, ne sont pas à prendre au pied de la lettre, car ils peuvent varier selon les technologies ou les combinaisons de

techniques utilisées. Ce qu'il est bon de retenir, c'est le fait que dans cette technique Ethernet, la longueur des connexions diminue avec la vitesse du débit.

2. Liaisons entre réseaux d'ordinateurs

Il existe diverses techniques d'interconnexion de réseaux entre eux. Nous renvoyons le lecteur à des ouvrages spécialisés sur les réseaux. Nous allons brosser un tableau simple et général du réseau mondial le plus connu de nos jours au niveau du grand public, le réseau Internet. Nous verrons ensuite comment il est adapté par les spécialistes à des architectures locales sous la forme d'Intranet. En premier lieu donnons quelques explications techniques sur un mode classique de transmission de l'information utilisé par de nombreux réseaux.

Vocabulaire de base employé

Dans un réseau informatique on distingue trois niveaux de description :

- ❑ La topologie physique
- ❑ La topologie logique
- ❑ Les protocoles de transmission

La topologie physique décrit l'infrastructure d'interconnexion des systèmes informatiques.

La topologie logique est une architecture logicielle normalisant les critères de qualité et les modalités "d'emballage" et de transmission des informations par la topologie physique.

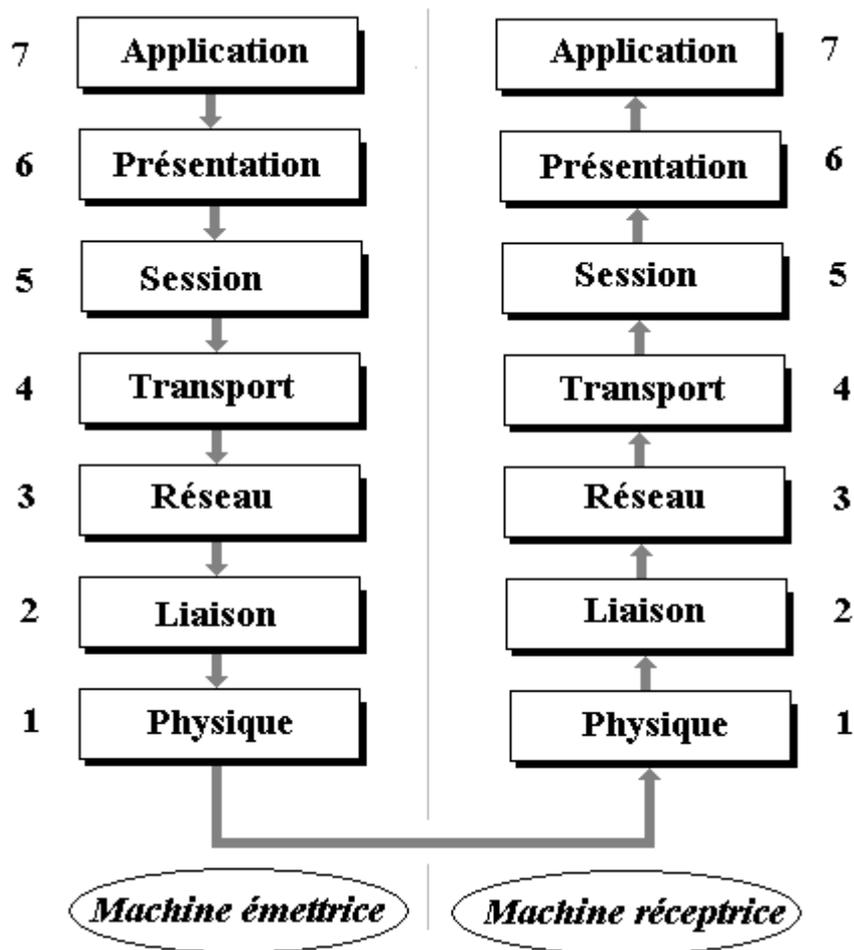
Un protocole est un ensemble de règles décrivant l'émission et la réception de données sur un réseau ainsi que la liaison entre une application externe et la topologie logique du réseau.

Nous avons déjà examiné au paragraphe précédent les différentes topologies physiques (on dit aussi architecture physique), nous proposons maintenant, la description du modèle de référence le plus répandu d'une architecture (topologie) logique, mis en place depuis les années 1980 par l'organisation internationale de standardisation (ISO). Ce modèle logique est appelé **Open System Interconnection** (OSI).

2.1 Topologie OSI à 7 couches

Le modèle OSI sert de base à la théorie générale des réseaux, c'est un modèle théorique présentant la circulation des données dans un réseau, il est décrit en 7 couches : les plus hautes sont abstraites et les plus basses sont concrètes.

Ce modèle décrit très précisément la liaison qui existe entre deux nœuds successifs d'un réseau (deux ordinateurs, par exemple) d'un manière descendante et décomposée :



Modèle OSI à 7 couches numérotées

Chaque couche rend un service décrit dans la documentation de l'ISO et géré par un protocole permettant de réaliser ce service lorsque la couche est abstraite. Lorsque la couche est matérielle la documentation décrit comment le service est rendu par le composant matériel.

Chaque couche de niveau **n** communique avec la couche immédiatement supérieure **n+1** (lorsqu'elle existe) et la couche immédiatement inférieure **n-1** (lorsqu'elle existe).

La couche physique la plus basse est la plus concrète elle est numérotée 1, la couche application la plus haute est la plus abstraite, elle est numérotée 7.

Cette organisation en couche d'abstractions descendantes va se retrouver aussi dans la notion de programmation structurée par abstractions descendantes, il s'agit donc d'un fonctionnement constant de l'esprit des informaticiens.

Nous décrivons brièvement chacune des 7 couches du modèle OSI :

Nom de la couche	Description du service rendu par la couche
7 - Application	Transfert des fichiers des applications s'exécutant sur l'ordinateur.
6 - Présentation	Codage des données selon un mode approprié.
5 - Session	Gestion des connexions entre les ordinateurs.

4 - Transport	Gestion du transfert des données vers le destinataire.
3 - Réseau	Schéma général d'interconnection (adressage) afin d'assurer le repérage physique du destinataire.
2 - Liaison	Règles permettant d'effectuer le réassemblage et l'acheminement des données vers le matériel physique de la couche 1.
1 - Physique	Description physique du transport des données à travers des câbles, des hubs...

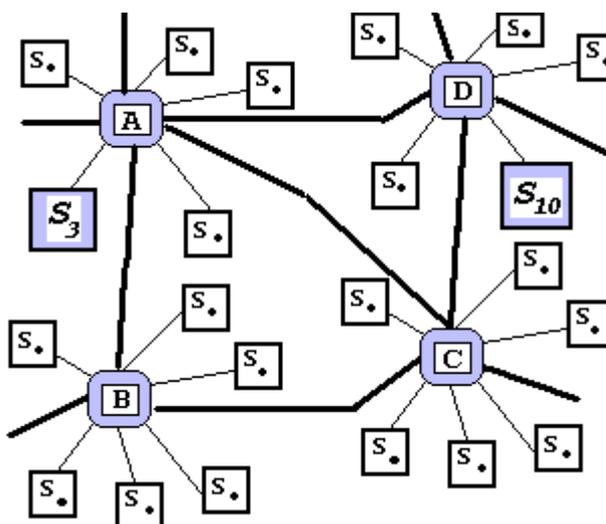
2.2 Réseau à commutation de paquets

Dans un tel type de réseau nous avons besoin de définir au moins **trois** concepts :

- **le message** : l'information échangée entre deux systèmes informatiques.
- **les paquets** : des petites suites de bits constituant une partie d'un message, (le message est découpé en plusieurs paquets).
- **le routage** : c'est l'action (effectuée par le routeur) qui permet la transmission, l'aiguillage et la redirection des informations circulant sur le réseau à un instant donné.

Un tel réseau est architecturé selon une topologie plus ou moins fortement maillée, entre les divers concentrateurs. Les utilisateurs S_i se connectent selon leur proximité géographique au concentrateur le plus proche.

Dans le schéma suivant, représentant une maille du réseau, nous supposons que l'utilisateur S_3 veuille envoyer un message M (image, fichier, son, etc...) à S_{10} . Nous allons suivre le chemin parcouru par les paquets p_i du message M pour aller de S_3 à S_{10} .



S_3 est directement connecté au concentrateur [A], S_{10} est directement connecté au concentrateur [D]. Supposons aussi que le message M soit composé de 4 paquets : $M = (p_1, p_2, p_3, p_4)$.

Le routage de départ s'effectue à partir du concentrateur [A] et de la charge et de l'encombrement actuels du réseau. Ce sont ces deux critères qui permettent au routeur de prendre la décision d'émission des paquets.

Principe du routage :

Les paquets dans un tel réseau sont envoyés dans n'importe quel ordre et indépendamment les uns des autres vers des destinations diverses ; chaque paquet voyage bien sûr, avec l'adresse du destinataire du message.

- a) Supposons que p_1 aille directement vers [D], puis que l'encombrement oblige d'envoyer p_2 à [B] puis p_3, p_4 à [C].
- b) Puis [C] peut router directement p_3, p_4 vers [D] (qui a déjà reçu p_1).
- c) Enfin [B] envoie p_2 à [C] et celui-ci le redirige vers [D] (qui avait déjà reçu p_1, p_3 et p_4).
- d) Lorsque p_2 arrive au concentrateur [D], le message M est complet, il peut être reconstitué $M = (p_1, p_2, p_3, p_4)$ et expédié à son destinataire S_{10} .

3. Internet et le protocole TCP/IP

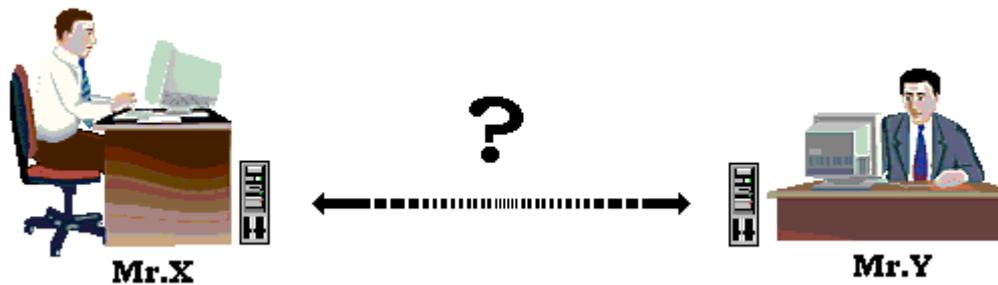
Le réseau le plus connu se dénomme **Internet**. Chaque pays peut avoir mis en place un réseau national, (par exemple en France, il existe un réseau national public TRANSPAC fonctionnant par commutations de paquets sous protocole X25), le réseau Internet quant à lui est international et fonctionne par commutations de paquets sous protocole TCP/IP.

C'est actuellement le réseau mondial de transmission de données le plus utilisé avec plusieurs centaines de millions d'utilisateurs.

- C'est un réseau à commutation de paquets.
- Il est basé sur le protocole TCP/IP.
- Il permet à des milliers d'autres réseaux locaux ou non de se connecter entre eux à distance.

Explication pratique de la transmission de données sur Internet

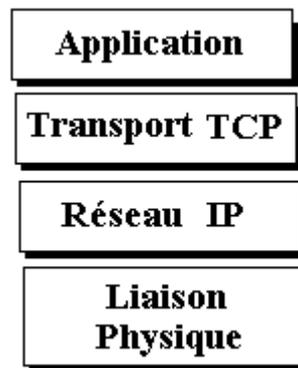
Prenons un exemple pratique, M^f . X situé à Moscou désire envoyer le message suivant "*Bonjour cher ami comment allez-vous ?*" à M^f . Y situé à Ankara, via le réseau Internet.



Protocole, adresse IP

La communication entre deux machines distantes implique une normalisation des échanges sous forme de règles. Un tel ensemble de règles est appelé un **protocole de communication**. Un protocole décompose la communication en sous-problèmes simples à traiter dénommé **couche** du protocole. Chaque couche a une fonction précise et fait abstraction du fonctionnement des couches supérieures et inférieures.

Le protocole de communication TCP/IP utilisé par Internet, est fondé sur le modèle OSI, il intervient essentiellement sur 4 couches du modèle OSI : **application, transport, réseau et interface**



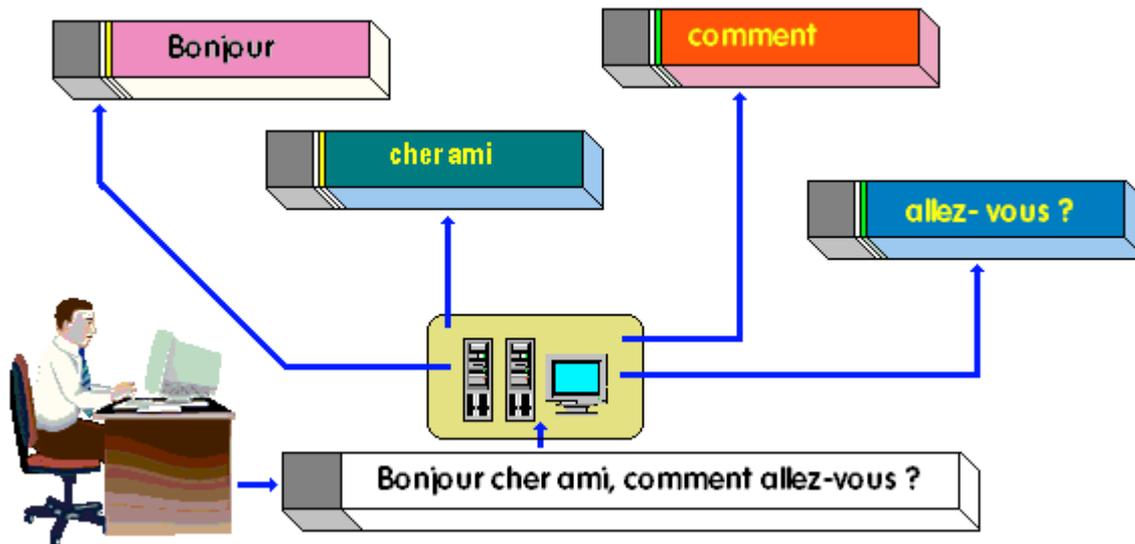
Un individu est identifiable par son numéro de sécurité sociale (deux personnes différentes n'ont pas le même numéro de sécurité sociale), de même chaque ordinateur branché sur Internet se voit attribuer un numéro unique qui permet de l'identifier.

On dénomme **adresse IP** un tel identifiant. Une adresse IP se présente sous la forme de 4 nombres (entre 0 et 255) que l'on sépare par des points pour des raisons de lisibilité, exemple : **163.85.210.8**.

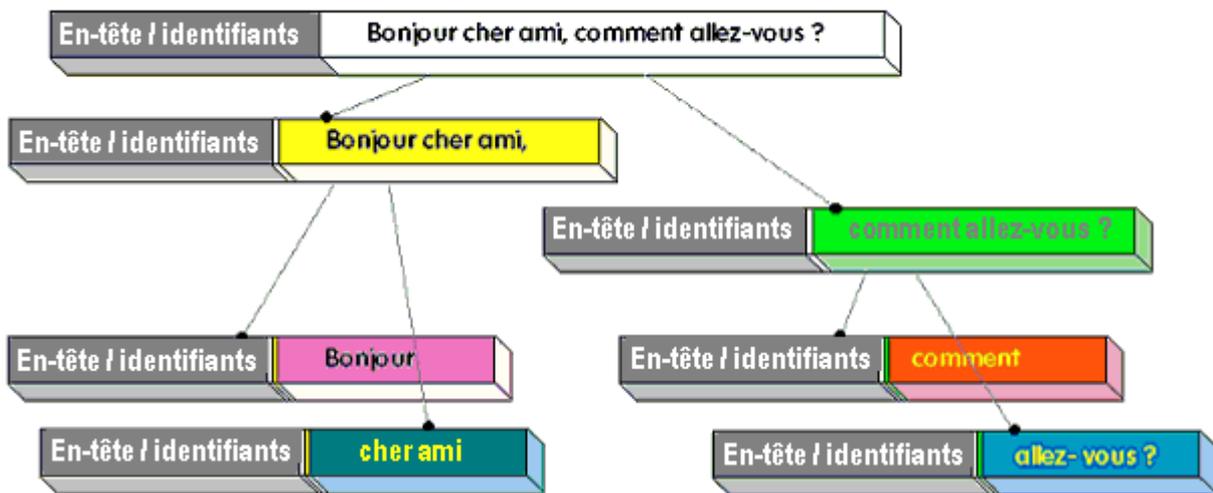
Donc l'ordinateur de M^r. X situé à Moscou est connecté à Internet possède une adresse IP (par exemple : **195.114.12.58**), celui de Mr.Y possède aussi une adresse IP (par exemple : **208.82.145.124**)



Le message initial de M^f.X va être découpé par TCP/IP, fictivement pour les besoins de l'exemple en quatre paquets (en fait la taille réelle d'un paquet IP est d'environ 1500 octets) :



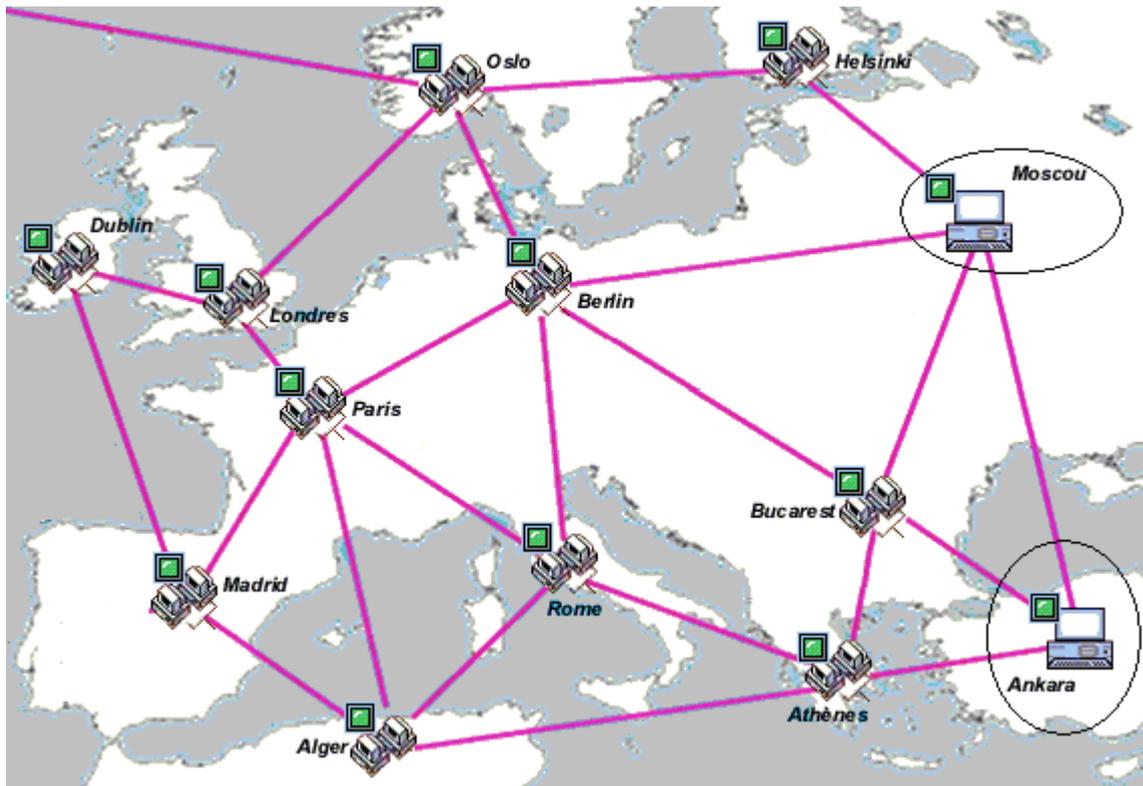
Le message initial de MrX est donc découpé avec les en-têtes adéquates :



(chaque en-tête/identifiant de paquet contient l'adresse de l'ordinateur de l'expéditeur M^f.X soit : **195.114.12.58** et celle du destinataire M^f.Y soit : **208.82.145.124**)

Le routage

Supposons que nous avons la configuration de connexion figurée ci-après :



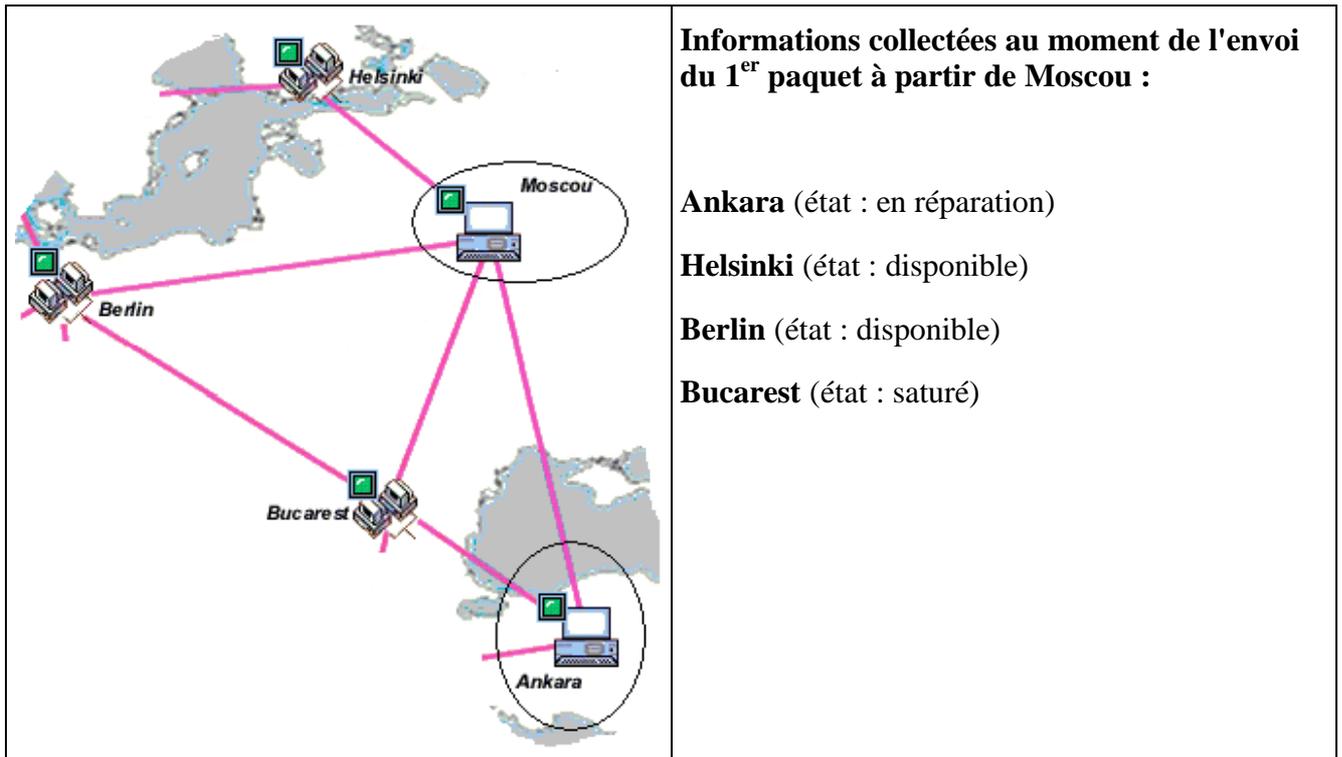
Le schéma précédent représente les points de routage fictifs du réseau Internet au voisinage de Moscou et Ankara.

Le routage sur Internet est l'opération qui consiste à trouver **le chemin le plus court** entre deux points du réseau en fonction en particulier de l'**engorgement** et de l'**état** du réseau.

Cette opération est effectuée par un routeur qui peut être soit un matériel spécifique raccordé à un ordinateur, soit un ordinateur équipé d'un logiciel de routage.

Chaque routeur dispose d'une **table** l'informant sur l'état du réseau, sur le routeur suivant en fonction de la destination et sur le nombre de routeurs nécessaires pour aller vers la destination.

Dans notre exemple, nous avons supposé que le routeur de Moscou soit branché avec les quatre routeurs d'**Ankara**, d'**Helsinki**, de **Berlin** et de **Bucarest** :



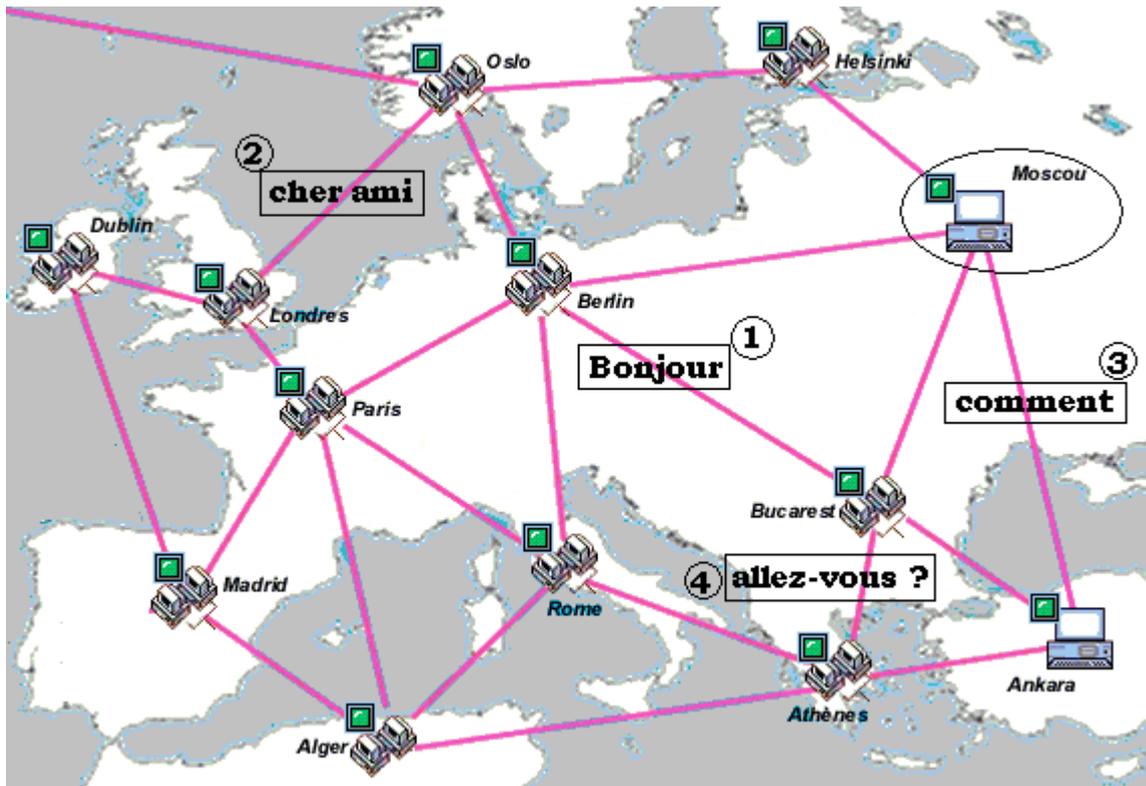
La table de routage aura à peu près cette allure :

Routeur	Destination	Nombre de routeurs	Routeur suivant	Etat
Moscou	Ankara	5	Helsinki	libre
Moscou	Ankara	2	Bucarest	saturé
Moscou	Ankara	3	Berlin	libre
Moscou	Ankara	1	Ankara	indisponible

Il est évident que d'après la table précédente seules deux destinations immédiates sont libres : le routeur d'Helsinki ou le routeur de Berlin.

Comme le nombre de routeurs restant à parcourir est moindre en direction de Berlin vers Ankara (3 routeurs : Berlin-Bucarest-Ankara) comparé à celui de la direction Helsinki vers Ankara (5 routeurs : Helsinki-Oslo-Berlin-Bucarest-Ankara), c'est le trajet Berlin qui est choisi pour le premier paquet "Bonjour".

Au bout de quelques instants, les 4 paquets obtenus à partir du message de M'.X voyagent sur **Internet** indépendamment les uns des autres vers des destinations diverses (n'oublions pas que chaque paquet voyage avec l'adresse du destinataire du message qui est située à **Ankara**).

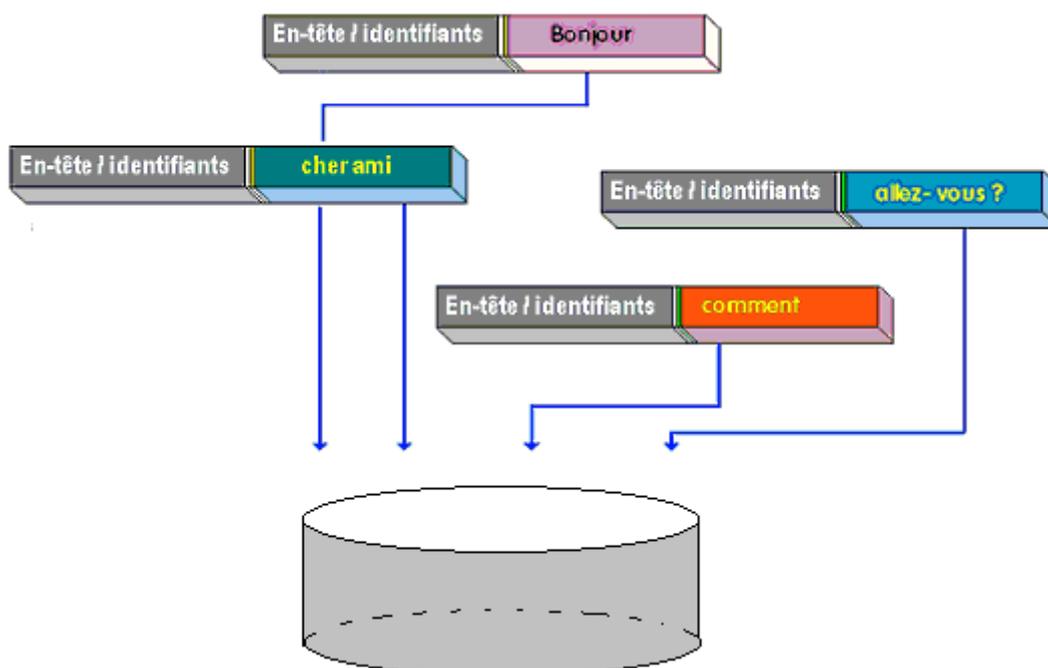


Carte : Le voyage des paquets

Sur cette carte :

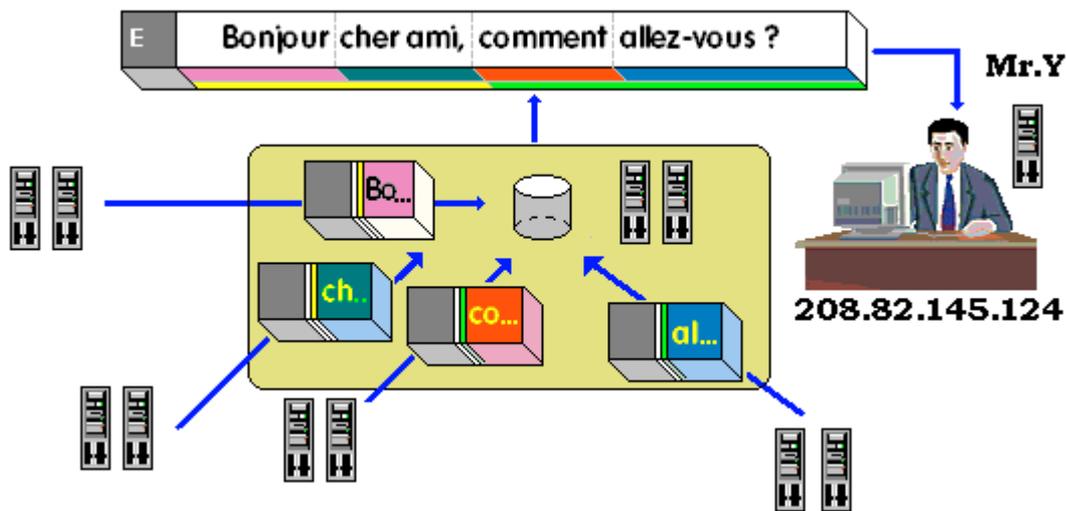
Le paquet n°1 "Bonjour", voyage vers le routeur de Bucarest.
 Le paquet n°2 "cher ami", voyage vers le routeur de Londres.
 Le paquet n°3 "comment", voyage vers le routeur d'Ankara.
 Le paquet n°4 "allez-vous ?", voyage vers le routeur d'Athènes.

A l'arrivée à Ankara, le routeur d'Ankara reçoit les paquets en ordre dispersés et en des temps différents et les stocke en attendant que le message soit complet :



Le routeur d'Ankara vérifie que les paquets sont tous bien arrivés, il redemande éventuellement les paquets manquants, il envoie un accusé de réception pour prévenir chaque routeur expéditeur que les données sont bien arrivées.

Au final il y a réassemblage des paquets pour reconstituer le message original avant de le distribuer au logiciel de lecture du message de M^r.Y :



En savoir un peu plus sur : adressage IP et transport TCP

Le protocole TCP/IP est en fait un vocable pour un ensemble de protocoles de transport des données sur Internet (passerelles, routage, réseau), fondés sur deux protocoles pères IP et TCP.

IP = Internet Protocol

TCP = Transmission Control Protocol

Le protocole IP :

permet à des ordinateurs reliés à un réseau géré par IP de dialoguer grâce à la notion d'adresse actuellement avec la norme IPv4 sous la forme de 4 nombres (entre 0 et 255) d'un total de 32 bits, ce numéro permet d'identifier de manière unique une machine sur le réseau, comme une adresse postale avec un numéro de rue (la nouvelle norme IPv6 étend le nombre d'adresses possibles).

Le protocole IP génère donc des paquets nommés des **datagrammes** contenant une en-tête (l'adresse IP) et des données :



Ces datagrammes sont remis à une **passerelle** (opération de routage) à destination d'un hôte.

Toutefois, si une adresse postale permet d'atteindre son destinataire précisément c'est parce qu'elle contient en plus du nom et du numéro de la rue, le nom de la personne à qui elle est adressée. Il en est de même pour une transmission sur Internet :

Action externe : M^r. X situé à Moscou envoie un message à M^r. Y situé à Ankara.

Action informatique : L'ordinateur de M^r. X envoie un message très précisément au logiciel de mail de l'ordinateur de M^r. Y, il est donc nécessaire que le logiciel de mail puisse être identifié, c'est un numéro dans l'ordinateur récepteur qui va l'identifier " **le numéro de port**".

Ainsi il devient facile d'envoyer à une même machine identifiée par son adresse IP, plusieurs données destinées à des applications différentes s'exécutant sur cette machine (chaque application est identifiée par son numéro de port).

Le protocole TCP permet de :

Gérer les ports
Vérifier l'état du destinataire pour assurer la réception des paquets
Gérer les paquets IP :
<input type="checkbox"/> Découpe des paquets
<input type="checkbox"/> Vérification de la réception de tous les paquets
<input type="checkbox"/> Redemande des paquets manquants
<input type="checkbox"/> Assemblage des paquets arrivés

La **Donnée** initiale de chacun des 4 paquets ("*Bonjour*", "*cher ami*", "*comment*", "*allez-vous ?*") est modifiée par chaque couche du protocole TCP/IP par l'ajout d'une **En-tête** spécifique nécessaire à la réalisation de la fonction de cette couche.



Plusieurs protocoles plus généraux sont fondés sur TCP/IP : DNS, SMTP, FTP, POP3, HTTP.

DNS (**D**omain **N**ame **S**ervice) est un protocole permettant de convertir un nom de domaine Internet en une adresse IP (nom de domaine : www.machin.org, adresse obtenue : **203.54.145.88**)

SMTP (**S**imple **M**ail **T**ransfert **P**rotocol) est un protocole d'envoi de messages électroniques (mails) vers un destinataire hébergeant la boîte aux lettres.

POP3 (**P**ost **O**ffice **P**rotocol version **3**) est un protocole permettant de rapatrier sur votre machine personnelle le courrier qui a été déposé dans la boîte aux lettres de l'hébergeur.

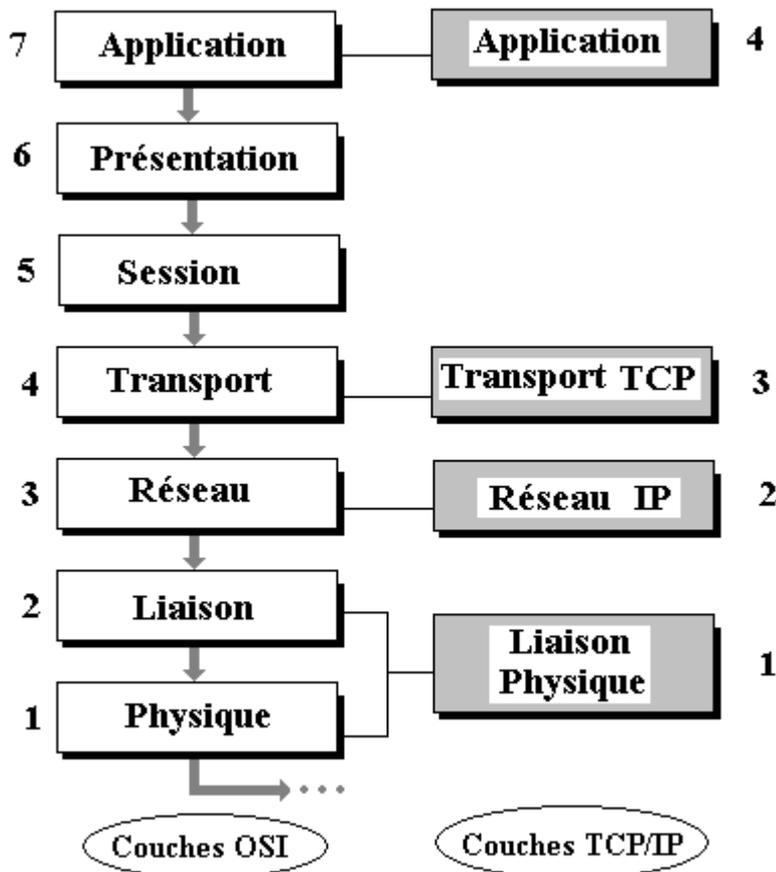
FTP (**F**ile **T**ransfert **P**rotocol) est un protocole permettant de rapatrier sur votre machine ou d'expédier à partir de votre machine des fichiers binaires quelconques.

HTTP (**H**yper **T**ext **T**ransfert **P**rotocol) est un protocole permettant d'envoyer et de recevoir sur votre machine des fichiers HTML au format ASCII.

Dans le cas d'HTTP, le paquet construit contient alors une partie identifiant supplémentaire :



Ci-dessous la comparaison entre le modèle théorique OSI et TCP/IP :



La petite histoire d'Internet

Le concept d'Internet n'est pas récent. Il prend naissance en effet à la fin des années soixante dans les rangs des services **militaires américains** qui ont peur de voir leurs systèmes d'information détruits par l'effet électro-magnétique induit par une explosion nucléaire. Il demande à leurs chercheurs de concevoir un moyen sûr de transporter des informations qui ne dépendrait pas de l'état général physique du réseau, voir même qui supportera la destruction physique partielle tout en continuant d'acheminer les informations.

Officieusement dès les années cinquante au USA, dans le plus grand secret est mis au point un réseau de transmission de données militaires comme le réseau SAGE uniquement réservé aux militaires. Les chercheurs du MIT vont mettre au point en 1969 la commutation de paquets dont nous venons de parler, et concevrons l'architecture distribuée qui sera choisie pour le réseau.

Officiellement, la première installation effective sera connu sous le nom d'**ARPANET** aura lieu en

1970 en raccordant les 4 universités américaines de Santa Barbara, de l'Utah, de Stanford et de Los Angeles. Plusieurs universités américaines s'y raccorderont et continueront les recherches jusqu'en 1974 date à laquelle V.Cerf et R.Kahn proposent les protocoles de base IP et TCP. En 1980 la direction de l'ARPA rendra public les spécifications des ces protocoles IP et TCP. Pendant vingt ans ce réseau a servit aux militaires et aux chercheurs.

Il faut attendre 1990 pour voir s'ouvrir le premier service de fourniture d'accès au réseau par téléphone. Au même moment, ARPANET disparaît pour laisser la place à **Internet**. Un an plus tard, les principes du Web sont établis.

Le world wide web : www

C'est la partie d'Internet la plus connue par le grand public. A l'origine, le World Wide Web (WWW) a été développé en 1990 au CERN, le Centre Européen pour la Recherche Nucléaire, par R.Caillau et T.Berners-Lee. Il autorise l'utilisation de textes, de graphiques, d'animations, de photographies, de sons et de séquences vidéo, avec des liens entre eux fondés sur le modèle hypertextuel.

Le Web est un système hypermédias du genre client/serveur.

C'est sur ces spécifications qu' a été élaboré le langage de description de document du web **HTML** (Hyper Text Markup Language).

Pour lire et exécuter ces hypermédias, il faut un logiciel que l'on dénomme un navigateur. Mosaic est l'un des premiers navigateurs Web, distribué gratuitement au public. Depuis 1992, les utilisateurs de micro-ordinateurs peuvent alors se connecter à Internet à partir de leur PC. Internet Explorer de Microsoft et Netscape sont les deux principaux navigateurs les plus utilisés dans le monde.

Les points forts d'Internet :

Il permet à un citoyen de se connecter n'importe où en disposant de :

- Un micro-ordinateur du commerce,
- Un système d'exploitation supportant les protocoles adéquats, tous les SE de micro-ordinateur depuis 1997 disposent d'un moyen simple de se connecter à Internet (Windows, Linux en sont deux exemples),
- Un modem (se branchant sur une ligne téléphonique ordinaire) à 56000bps ou plus (ADSL) ou bien le câble en attendant de nouveaux produits de transport des signaux.
- Un abonnement chez un fournisseur d'accès à Internet (noeud de communication concentrateur),
- Enfin un navigateur permettant de dialoguer avec les différents serveurs présents sur Internet.

Le revers de médaille d'Internet :

L'inorganisation totale de cette gigantesque et formidable banque de données qu'est un tel réseau mondial qui contient le meilleur et le pire, peut engendrer des dangers pour le citoyen et même pour une démocratie si l'on ne reste pas vigilant.

Enfin, selon les pays, les coûts d'utilisation restent importants (abonnement chez le fournisseur et durée de communication téléphonique pour la connexion), la concurrence des fournisseurs d'accès gratuit permet une baisse du coût général de la connexion. La connexion illimitée et gratuite reste

l'objectif à atteindre.

Internet est devenu un problème de société

Trois courants de pensée s'affrontent quant à l'impact d'Internet sur les sociétés humaines :

- **Le courant du tout-Internet** qui prône un nouveau monde virtuel où Internet intervient à tous les niveaux de la vie privée, publique, professionnelle, culturelle voir spirituelle.
- **Le courant des Internetophobes** qui rejette ce nouveau monde virtuel vu comme une accentuation encore plus marquée entre les "riches" et les "pauvres" (la richesse ne s'évaluant plus uniquement en bien matériels, mais aussi en informations).
- **Le courant des "ni-ni"**, ceux qui considèrent que tout outil mérite que l'on s'en serve avec réflexion pour le plus grand nombre, mais qui pensent qu'un outil n'est pas une révolution sociale en lui-même, seul l'homme doit rester au centre des décisions qui le concernent.

La tendance au début du XXI siècle est de renforcer l'aspect commercial (e-business) de ce type de produit sous la poussée des théories ultra-libérales, au détriment de l'intérêt général pour une utilisation plus citoyenne au service de tous.

Intranet

Les entreprises conscientes du danger de pillage, de sabotage et d'espionnage industriel ont repris les avantages de la conception d'Internet en l'adaptant à la notion de réseau local.

C'est le nom d'Intranet qui s'est imposé. Ce genre de réseau local d'entreprise est fondé sur les mêmes techniques, les mêmes procédés qu'Internet, mais fonctionne localement avec un certain nombre d'acteurs bien identifiés :

- Il peut donc être organisé selon la démarche interne de l'entreprise.
- Il n'est accessible qu'aux personnes autorisées si l'entreprise le souhaite.
- Il est connectable à Internet par des passerelles *contrôlées*.
- Il concerne toutes les activités logistiques, commerciales et de communication de l'entreprise.
- Il permet de mettre en œuvre des activités de groupware (travaux répartis par tâches identifiées sur des systèmes informatiques).

Il peut être organisé en Extranet, permettant la communication entre Intranets de différentes et bien sûr, un Intranet peut être connecté à Internet.

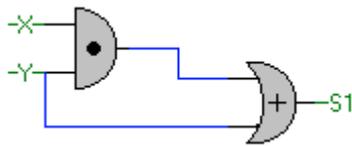
Le lecteur pourra se spécialiser sur tous les types de réseaux de télécommunication autres, auprès de l'ouvrage de référence de 1100 pages du spécialiste français G.Pujolle : "Les réseaux" cités en bibliographie.

Exercices chapitre 1

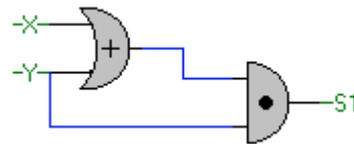
Questions :

On suppose que X, Y et Z sont des variables booléennes, donnez pour chaque circuit ci-dessous l'expression de sa fonction logique S1(X,Y) ou S1(X,Y,Z), évaluez la table de vérité de S1, puis simplifiez par calcul S1.

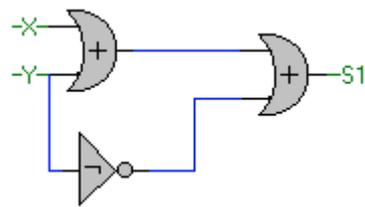
Ex-1 :



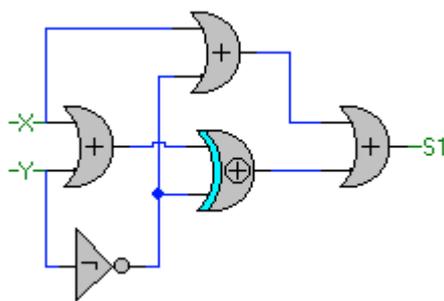
Ex-2 :



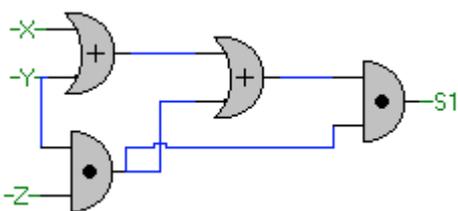
Ex-3 :



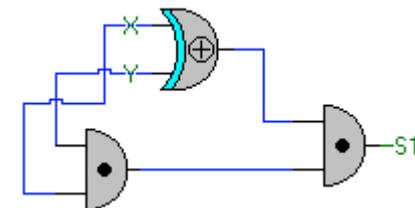
Ex-4 :



Ex-5 :



Ex-6 :



Ex-7 : Lorsque l'on additionne deux entiers positifs en binaire signé dans un ordinateur, le calcul s'effectue dans l'UAL en propageant la retenue sur tous les bits y compris le bit de signe.

Soient deux mémoires à 7 bits Mx et My, contenant respectivement l'entier x et l'entier y représentés en binaire signé avec convention du zéro positif :

- 1°) Quel est le nombre entier positif maximal que l'on peut stocker dans Mx ou My ?
- 2°) Quel est le nombre entier négatif minimal que l'on peut stocker dans Mx ou My ?
- 3°) Donnez le résultat de l'addition de Mx+My dans une mémoire Mz du même type que Mx et My, dans les deux cas suivants :

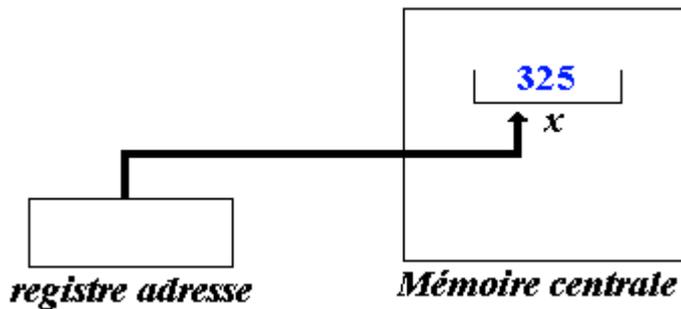
3.1) Mx contient l'entier x = 12, My contient l'entier x = 25

3.2) Mx contient l'entier x = 42, My contient l'entier x = 25

Ex-8 : Soit l'entier $x = 325$:

- 1°) Donnez sa représentation en codage binaire pur
- 2°) Donnez sa représentation en codage Ascii étendu
- 3°) Quel est en nombre de bits le codage le plus court ?
- 4°) D'une manière générale pour un entier positif x à n chiffres en représentation décimale donnez un majorant du nombre de bits dans la représentation de x en binaire pur, vérifiez le calcul pour $x = 325$.

Ex-9 : Soit une mémoire centrale et un registre adresse contenant l'adresse d'une case quelconque de la mémoire centrale :



- On suppose que le registre adresse soit une mémoire à 12 bits.
- On suppose que la taille du mot dans la mémoire centrale est de 16 bits.
- On suppose que la case x contient en binaire en complément à deux le nombre 325.

- 1°) Combien de mots (de cases) au maximum peut contenir cette mémoire centrale ?
- 2°) Quel est l'entier positif le plus grand représentable en complément à deux dans un mot de cette mémoire centrale ?
- 3°) Indiquez si les nombres suivants peuvent être l'adresse d'un mot dans cette mémoire centrale ;
 - 3.1) le nombre 683
 - 3.2) le nombre 2AB
 - 3.3) le nombre 2AB0
 - 3.4) le nombre -5

Réponses :

- Ex-1 : $S1 = x \cdot y + y$ simplifiée $\rightarrow S1 = y$
 Ex-2 : $S1 = (x + y) \cdot \bar{y}$ simplifiée $\rightarrow S1 = y$
 Ex-3 : $S1 = x + y + \bar{y}$ simplifiée $\rightarrow S1 = 1$
 Ex-4 : $S1 = (x + \bar{y}) + (x + y) \oplus \bar{y}$ simplifiée $\rightarrow S1 = 1$
 Ex-5 : $S1 = (x + y + y \cdot z) \cdot (y \cdot z)$ simplifiée $\rightarrow S1 = y \cdot z$
 Ex-6 : $S1 = (x \oplus y) \cdot (y \cdot x)$ simplifiée $\rightarrow S1 = 0$

- Ex-7 : 1°) le nombre maximum = $2^6 - 1$ (soit 63)
 2°) le nombre minimum = -2^6 (soit -64)
 3.1) $Mx + My = 37$ (car: $0001100 + 0011001 = 0100101$)
 3.2) $Mx + My = -3$ (car: $0101010 + 0011001 = 1000011$, le bit de signe a été écrasé)

- Ex-8 : 1°) $x = 101000101$
 2°) $x = 00110011 \cdot 00110010 \cdot 00110101$ (car chaque symbole est codé sur 8 bits)
 3°) Le codage binaire pur du nombre x occupe 9 bits alors que son codage Ascii occupe 24 bits.
 4°) Soit k le nombre de bits (nombre de chiffres binaires) de l'entier x , en décimal x est composé de n chiffres décimaux $\Leftrightarrow x < 10^n$, en binaire x se compose de k chiffres binaires $\Leftrightarrow x < 2^k$, dès que $2^k \sim 10^n$ ou encore $k \sim n \log_2 10$, soit donc le nombre de bits est de l'ordre de la partie entière du nombre approché $n \log_2 10$, soit $k \sim 3,32 \cdot n$. Pour un nombre à 3 chiffres $k \sim 9$, donc 9 bits suffiront pour coder ce nombre en binaire pur.

- Ex-9 : 1°) cette mémoire centrale peut contenir au maximum $2^{12} = 4096$ mots.
 2°) le plus grand entier vaut : $2^{15} - 1$ (soit 32737).
 3°) 683 (oui), 2AB (oui), 2AB (non plus de 12 bits), -5 (non, une adresse est un nombre positif ou nul)