

Information, Calcul et Communication Module 3 : Systèmes



# Information, Calcul et Communication Ordinateur à programme enregistré

Prs. P. lenne, W. Zwaenepoel, A. Ailamaki & P. Janson



#### La question de ce module

Comment **fonctionne** et de quoi est **fait** un ordinateur capable traiter de l'information avec des algorithmes?



#### Les réponses de ce module

Comment fonctionne et de quoi est fait un ordinateur capable traiter de l'information avec des algorithmes?

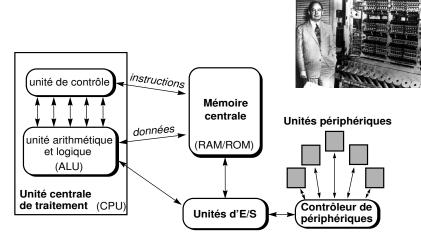
#### À base de trois technologies :

- Des transistors (pour le processeur et la mémoire vive)
   Leçons 1 (Architecture) & 2 (Hiérarchie)
- Des disques et autres Flash (pour les mémoires mortes)
   Leçons 2 (Hiérarchie) & 3 (Stockage)
- Des réseaux (pour les communications entre machines et utilisateurs)
  - Leçon 3 (Réseaux)



#### Architecture de von Neumann







# Objectifs du cours d'aujourd'hui

#### Les objectifs de cette leçon sont de :

- expliquer comment l'on peut effectivement construire des machines pouvant exécuter des programmes (= traductions d'algorithmes)
- présenter avec quelle technologie les ordinateurs actuels sont construits
- présenter les deux principes permettant d'augmenter la rapidité de calcul de tels ordinateurs



# La première question de cette leçon

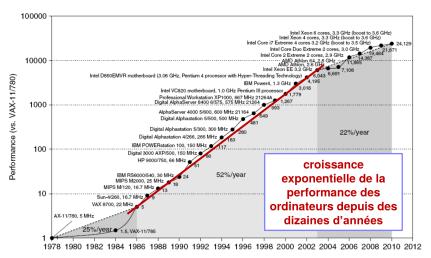
Maintenant que l'on a développé des algorithmes, comment peut-on construire des systèmes pour les exécuter?





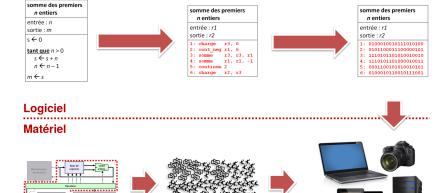
# La deuxième question de cette leçon

Comment peut-on rendre ces systèmes plus rapides?



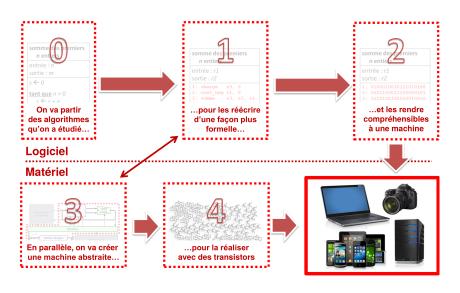


#### Des algorithmes aux ordinateurs





#### Des algorithmes aux ordinateurs

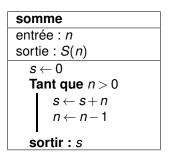




#### Un algorithme

Pour exprimer les algorithmes, nous avons dans le Module 1 utilisé un langage assez intuitif, proches des mathématiques et du langage naturel.

Considérons un exemple :



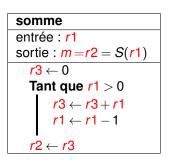


#### **Ecriture plus contrainte**

Pour *simplifier* en vue de construire une machine, essayons de réécrire cet algorithme de façon plus précise, avec **moins de libertés** (tout en gardant quelque chose de plus pratique/expressif qu'une table de transition d'une machine de Turing!)

**Etape 1 :** donner un sens concret à « **Sortir** » : affecter une variable.

**Etape 2 :** restriction des noms de variables : *r*1, ..., *r*6.





#### Les registres



- On a besoin de mémoriser des valeurs.
- Ces valeurs seront stockées dans ce qui est appelé des « registres » : réalisation concrète dans notre machine de la notion de variable.
- On les représente simplement par r1, ..., r6.
- Nous essayerons d'en n'avoir qu'un petit nombre limité (de l'ordre de la dizaine; tout au plus quelques dizaines sur les machines modernes).
- ▶ Pour de plus grosses données (tableaux, listes, etc.) : mémoire externe : voir la leçon de la semaine prochaine.



# **Ecriture plus contrainte (suite)**

**Etape 3 :** identifions chacune des opérations nécessaires à notre machine en les nommant

**3.1**: Par exemple l'affectation : charge

3.2 : Par exemple les opérations arithmétiques : somme

```
somme
entrée: r1
sortie: r2
charge r3, 0
Tant que r1 > 0
somme r3, r3, r1
somme r1, r1, -1
charge r2, r3
```



#### Les opérations ou « instructions »



- On définit un nombre limité d'opérations; p.ex.
  - charge pour l'assignation;
  - somme pour l'addition;
  - soustrais pour la soustraction.
- Toutes les opérations ont un résultat et opèrent sur une ou deux valeurs ou opérandes, jamais plus.
- Les opérandes sont soit des (contenus de) registres, soit des constantes.
- On écrit ces opérations ainsi :

```
somme destination, operande1, operande2
```

- Au lieu d'écrire  $s \leftarrow s + n$ , on écrit somme r3, r3, r1
- ▶ Au lieu d'écrire  $s \leftarrow 0$ , on écrit charge r3, 0
- ▶ Au lieu d'écrire  $s \leftarrow c(a+b)$ , on écrit

```
somme r5, r6, r7
multiplie r5, r5, r8
```

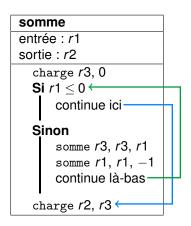


# **Ecriture plus contrainte (suite)**

**Etape 4 :** réduisons les structures de contrôle à une seule : le branchement conditionnel

- Mais comment faire des boucles?
- en ayant des sauts dans le programme :

C'est un peu plus « tordu », mais il est facile de se convaincre que c'est exactement la même chose





# Numérotation des lignes



Pour spécifier les endroits des sauts (conditionnels ou non) : on numérote les lignes

On a donc introduit des instructions supplémentaires :

- les sauts conditionnels : saute à la ligne indiquée si une condition est vérifiée;
   par exemple cont\_ppe
- un saut inconditionnel : saute à la ligne indiquée continue



#### Langage « Assembleur »

# somme entrée : nsortie : S(n) $s \leftarrow 0$ Tant que n > 0 $s \leftarrow s + n$ $s \leftarrow n - 1$ sortir : $s \leftarrow s + n$



#### somme

entrée : *r*1 sortie : *r*2

1: charge *r*3, 0

2: cont\_ppe r1, 0, 6

3: somme *r*3, *r*3, *r*1

4: somme r1, r1, -1

5: continue 2

6 : charge *r*2, *r*3



# Exemple réél de langage assembleur

```
$0, -4(\%rbp)
                                     movl
int somme(int n)
                                 .L3:
                                     cmpl $0, -20(%rbp)
 int s(0);
                                     ile
                                             .L2
 while (n > 0) {
                                             -20(%rbp), %eax
                                     movl
   s += n:
                                     addl %eax, -4(%rbp)
   --n:
                                     subl $1, -20(\%rbp)
                                             . I.3
                                     jmp
 return s:
                                 .1.2:
                                     movl
                                             -4(\%rbp), \%eax
```

```
g++ -S somme.cc -o somme.a
```



#### Résumé à ce stade



- On écrit nos programmes comme des séquences d'actions appelées « instructions »
- La plupart de ces actions indiquent quelles valeurs donner à des variables à la suite d'opérations (p.ex., mathématiques comme somme)
- On utilise seulement un jeu restreint d'opérations préalablement définies (p.ex., on pourrait ne pas avoir de soustraction si on a l'opération d'addition somme et l'opération pour trouver l'opposé oppose)
- On utilise seulement quelques variables comme r1, r2, r3, etc. on les appelle « registres »
- Certaines actions indiquent où continuer dans la séquence (p.ex., continue, si cet endroit est toujours le même, ou cont\_TEST, s'il ne faut y aller que dans certains cas) on les appelle « instructions de saut »



# Essayons de créer une telle machine...

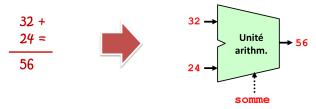
#### Algorithme:



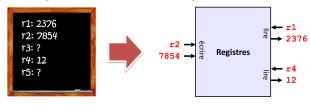


#### De quoi a-t-on besoin?

 L'unité arithmétique et logique (ALU) effectue les opérations arithmétiques

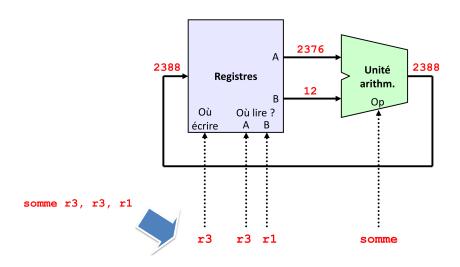


Les registres mémorisent les opérandes et les résultats





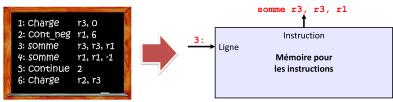
# Le circuit pour les calculs





#### De quoi a-t-on encore besoin?

Le programme doit être enregistré quelque part



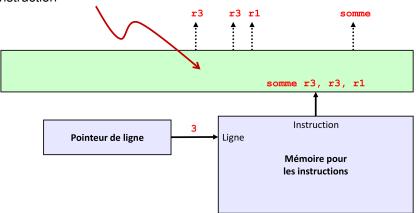
Il faut pouvoir contrôler où on en est





# Une première partie pour contrôler le tout...

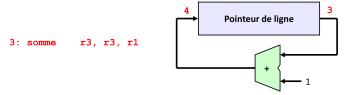
Un circuit assez simple qui répartit les éléments qui constituent une instruction



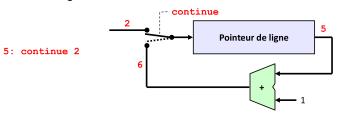


#### En cas de saut?

La plupart du temps on passe simplement à la ligne suivante

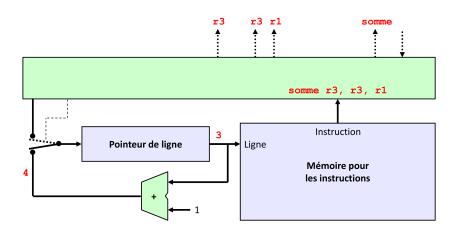


Si on a une instruction de saut (p.ex. continue), on veut imposer une autre ligne



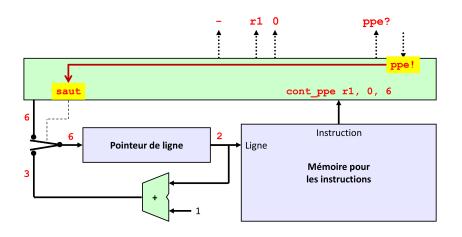


# Le circuit pour le contrôle





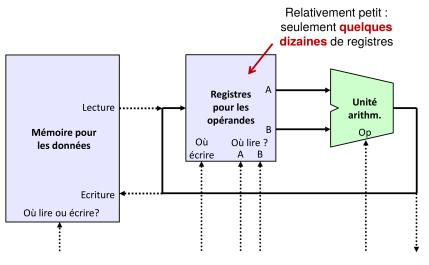
# Le circuit pour le contrôle – en cas de saut





#### De quoi a-t-on encore besoin?

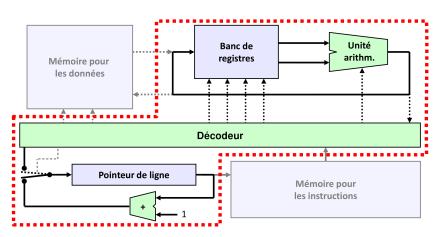
D'une mémoire pour avoir plus de données :





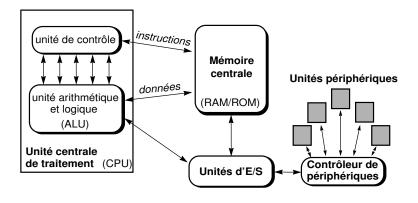
# Un processeur! (CPU)







#### Lien avec l'architecture de von Neumann





#### Comment encoder les instructions?

```
1: charge r3, 0
2: cont_ppe r1, 0, 6
3: somme r3, r3, r1
4: somme r1, r1, -1
5: continue 2
6: charge r2, r3
```

On peut inventer un encodage simple (voir leçon I.4):

- quelques bits pour identifier l'instruction p.ex. 8 bits si on a moins de 256 instructions
- quelques bits pour identifier les opérandes : registres ou constantes ou adresses de lignes p.ex. 5 bits pour les registres ( ⇒ 32 registres max.)



#### Comment encoder les instructions?

Au final chaque ligne du programme en assembleur peut être codée sur typiquement 32 ou 64 bits (alignement avec les « mots mémoire »)

```
      Par exemple « somme r3, r3, r1 » pourrait être représentée sur

      32 bits comme :

      0001001000011000110000100000000

      (compris comme :

      00010010
      00011 00011 00001 0000000

      somme (avec 3 registres) 3 3 1 (inutilisé)
```



#### **Encoder les instructions**

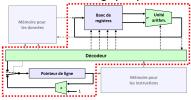


Langage assembleur

Langage machine (binaire)

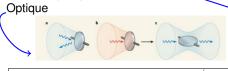
#### **Technologie?**

Notre machine est parfaitement abstraite et totalement indépendante du choix technologique pour son implémentation.





- Même l'encodage binaire n'est nullement une nécessité!
- Toute technologie est possible :
  - Électromécanique (p.ex. relais)
  - Électronique (p.ex. tubes ou transistors)









#### **Un interrupteur**

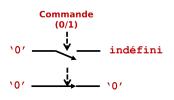
Ne propage rien s'il est ouvert

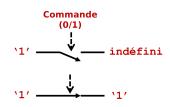


Propage son entrée s'il est fermé



## **Transistors = interrupteur contrôlé (1/2)**

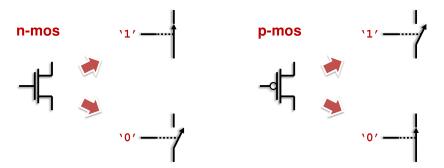






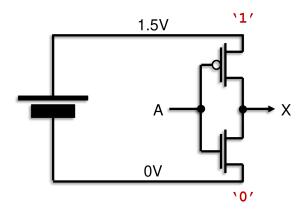
## **Transistors = interrupteur contrôlé (2/2)**





► Ils ne coûtent presque rien : un transistor pour faire un processeur moderne coûte entre 10<sup>-5</sup> et 10<sup>-4</sup> centimes (CHF, USD, EUR...)

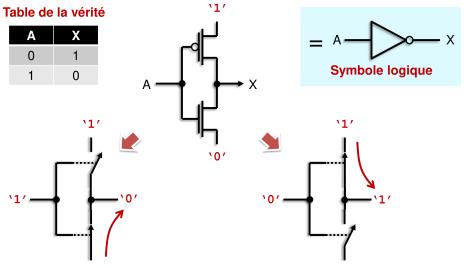
## **Un inverseur (en CMOS)**



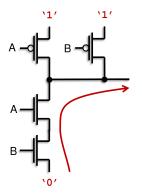


## **Un inverseur (en CMOS)**





#### Un circuit « et » avec sortie inversée

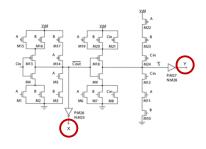


Α	В	A et B inversé
0	0	1
0	1	1
1	0	1
1	1	0

► La seule façon d'obtenir un '0' est de mettre deux '1' aux entrées A et B : la sortie est à '0' seulement si A et B sont à '1'

## On peut réaliser beaucoup de fonctions!

Α	В	С	XY
0	0	0	00
0	0	1	01
0	1	0	01
0	1	1	10
1	0	0	01
1	0	1	10
1	1	0	10
1	1	1	11

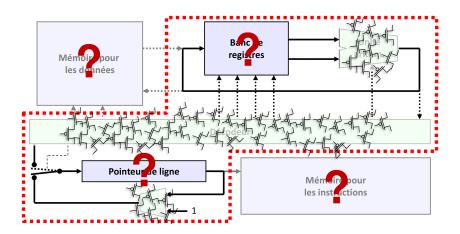


Les sorties XY sont la somme (en représentation binaire) des trois bits A, B et C à l'entrée





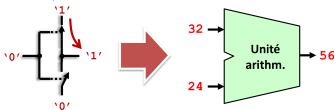
## Et notre processeur, alors?



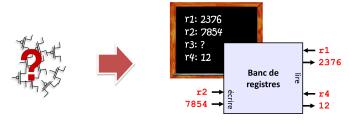


#### Peut-on aussi mémoriser l'information?

Pour les calculs, tout va bien :



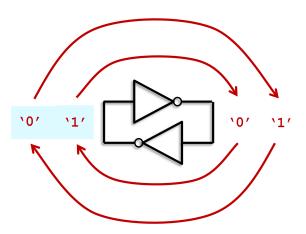
Mais pour mémoriser?...





## Un circuit assez particulier





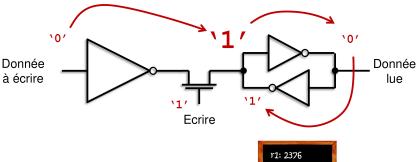
 Un circuit « bistable » c.-à-.d. qui peut être dans un parmi deux états parfaitement stables

un élément mémoire!

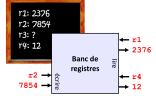


### Comment écrire dans cette mémoire?



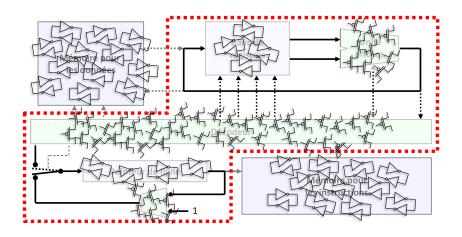


 Avec quelques transistors, on a un circuit mémoire parfait pour notre processeur



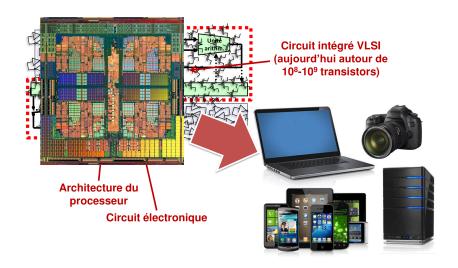


#### Maintenant on sait tout faire!



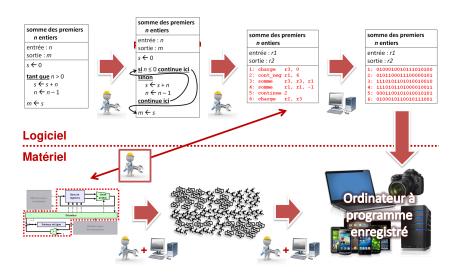


#### On a atteint notre but!



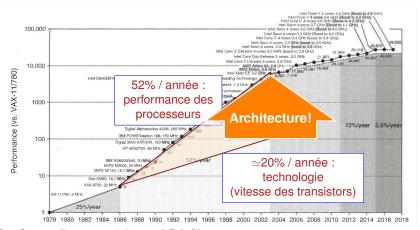


## Des algorithmes aux ordinateurs





## La croissance de la performance



From: Computer architecture: a quantitative approach, Sixth edition,

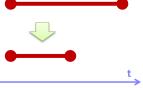
John L. Hennessy & David A. Patterson, page 3, Morgan Kaufmann (Elsevier), 2017.



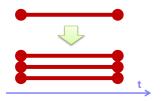
## Augmenter la performance?



# = Réduire le délai temps d'attente pour obtenir un résultat







À suivre : deux exemples simples d'amélioration de la performance :

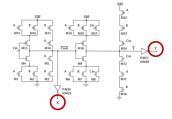
- Au niveau du circuit
   Réduire le délai d'un additionneur
- 2. Au niveau de la structure du processeur Augmenter le débit d'instructions



## Faire des sommes est facile... (1/2)

#### sur 1 bit (avec la retenue!) :

Α	В	С	XY
0	0	0	00
0	0	1	01
0	1	0	01
0	1	1	10
1	0	0	01
1	0	1	10
1	1	0	10
1	1	1	11



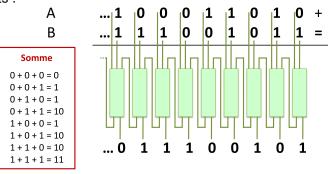
Les sorties XY sont la somme (en représentation binaire) des trois bits A, B et C à l'entrée





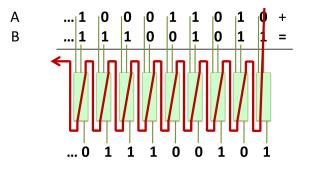
## Faire des sommes est facile... (2/2)

sur n bits:





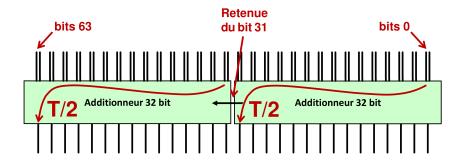
#### Mais ce circuit est lent!



La propagation de la retenue est un aspect fondamental de la somme : ainsi implémenté, le **délai** d'un additionneur est donc *proportionnel au nombre de bits à additionner*.



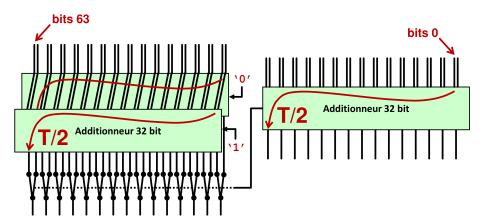
#### Peut-on faire mieux?



On n'a rien gagné : T/2 + T/2 = T



#### Peut-on faire mieux?



Là on a divisé le temps par 2!.. ...mais augmenté le travail/l'énergie par 1.5



## Ingénierie informatique (1/2)

- On peut profondément changer la performance du circuit sans en changer la fonctionnalité.
- On peut investir plus de transistors et plus d'énergie pour obtenir des circuits très rapides.
- On peut ralentir les circuits pour épargner de l'énergie.

Ceci est un exemple de **synthèse logique** qui est une des branches de *l'ingéniérie informatique* (*Computer Engineering*).



## Augmenter la performance?





À suivre : le second exemple simple d'amélioration de la performance :

Au niveau du circuit
 Réduire le délai d'un additionneur

Au niveau de la structure du processeur

Augmenter le débit d'instructions

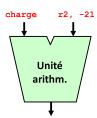


## Notre processeur

```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge r9, r4
109: somme r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme r8, r1, -1
114: divise r4, r1, r7
115: charge r2, r4
```

On exécute approximativement une instruction par cycle

Comment faire mieux?

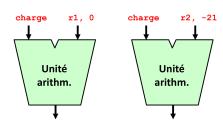




```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge
          r9, r4
109: somme
          r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme r8, r1, -1
          r4, r1, r7
114: divise
115: charge
             r2. r4
```

On peut maintenant exécuter deux instructions par cycle!

#### Problèmes?

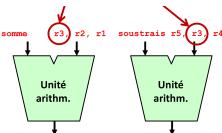




```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge
          r9, r4
109: somme
         r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme r8, r1, -1
          r4, r1, r7
114: divise
115: charge
            r2, r4
```

On peut maintenant exécuter deux instructions par cycle!

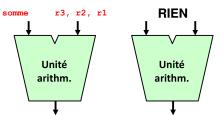
## Problèmes?





```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge
          r9, r4
109: somme
         r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme
           r8, r1, -1
          r4, r1, r7
114: divise
115: charge
            r2. r4
```

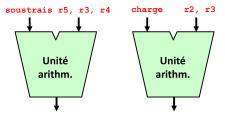
Solution : retarder l'exécution de certaines instructions :





```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge
          r9, r4
109: somme
          r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme
           r8, r1, -1
          r4, r1, r7
114: divise
115: charge
             r2. r4
```

Solution : et n'exécuter en parallèle que des instructions indépendantes :

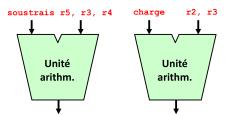




```
103: charge r1, 0
104: charge r2, -21
105: somme r3, r7, r4
106: multiplie r2, r5, r9
107: soustrais r8, r7, r9
108: charge
          r9. r4
109: somme
          r3, r2, r1
110: soustrais r5, r3, r4
111: charge r2, r3
112: somme r1, r2, -1
113: somme
           r8, r1, -1
          r4, r1, r7
114: divise
115: charge
           r2. r4
```

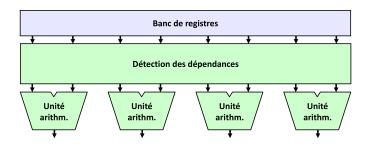
# On exécute maintenant entre une et deux instructions par cycle...

...et le résultat est correct.





## Un processeur « superscalaire »



- Tous les processeurs modernes pour les ordinateurs portables et les serveurs sont de ce type.
- De plus, ils réordonnancent les instructions et en exécutent avant que ce soit sûr qu'elles doivent être exécutées (p.ex. après une instruction comme cont\_neg).



## Ingénierie informatique (2/2)

- On peut modifier la structure du système pour exécuter les programmes plus rapidement.
- On peut ajouter des ressources aux processeurs pour les rendre beaucoup plus rapides.
- On peut utiliser des processeurs très élémentaires pour les rendre économiques et peu gourmands en énergie.

Ceci est un exemple d'architecture des ordinateurs qui est une autre branche de l'ingéniérie informatique (Computer Engineering)



## Ce que j'ai appris aujourd'hui

#### Dans ce cours, vous avez vu

- les principes de fonctionnement des ordinateurs actuels
- basés sur l'architecture de von Neumann :
  - processeur (CPU);
  - mémoire :
  - périphériques;
- comment un ordinateur traduit un langage de programmation dans ses instructions internes (compilation en langage machine);
- les compromis nécessaires entre performances et énergie consommée :
  - jouer sur le délai;
  - et le débit (parallélisme).

