Histoires de temps en informatique

Concurrence, parallélisme, synchronisation

Sacha Krakowiak

Université de Grenoble & Aconit

Le temps

- Le temps, une notion familière ?

  « Qu'est-ce donc que le temps ? Si personne ne m'interroge, je le sais ; si je veux répondre à cette demande, je l'ignore »

  saint Augustin

- Le temps en informatique, une notion multiforme
  - temps physique ou temps logique(s) ?
  - temps continu ou temps discret ?
  - temps linéaire ou temps ramifié ?
- Histoire de 3 aspects liés au temps
  - concurrence
  - parallélisme
  - synchronisation

Synchronisation

Vidéo

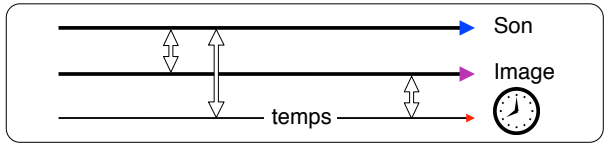

alignement strict

Banque

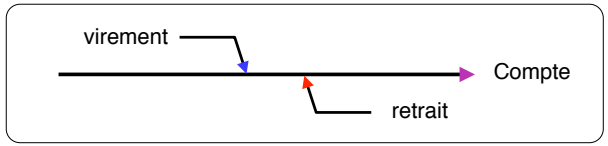

ordre de précédence

Time Machine

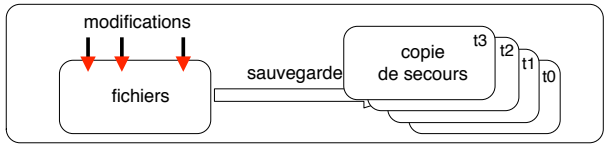

événements datés

Activités et concurrence

- Activité

  séquence linéaire d'*actions*, dont chacune modifie l'*état* du système

  l'organe qui exécute les actions est un *processeur*
  (pas nécessairement celui d'un ordinateur)

  l'organe qui mesure la progression est une *horloge*
  (pas nécessairement physique)

  une activité a un début et (éventuellement) une fin

- Concurrence

  deux activités sont *concurrentes* si (à un point de leur progression) elles sont en cours (commencées et non terminées)

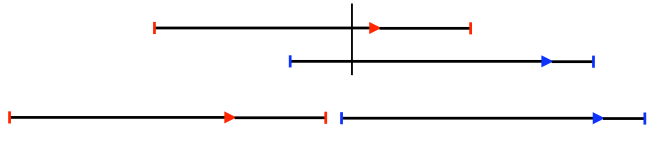

concurrentes

non concurrentes

Parallélisme

- Activités parallèles
  - deux activités sont *parallèles* si elles sont concurrentes *et* s'exécutent sur des processeurs différents
  - les horloges peuvent être ou non synchrones
- Parallélisme et pseudo-parallélisme
  - deux activités peuvent être concurrentes sans être parallèles (s'il n'y a qu'un seul processeur)

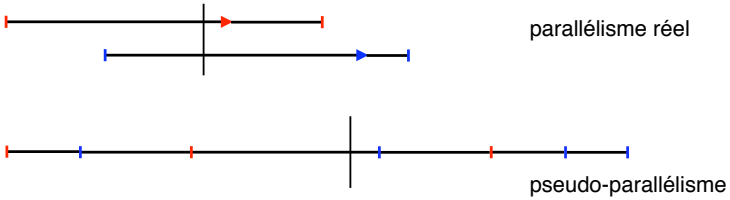

Le temps en informatique

- Performances du matériel

	Temps d'accès à la mémoire	Fréquence d'horloge
1950	200 μs	0,5 KHz
2014	10 ns (2.10^4)	10 GHz (2.10^7)

- Temps de réponse d'une requête

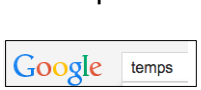

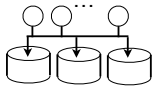

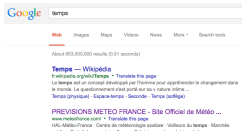

0,45 s

- Divers aspects du temps
  - mesure d'efficacité (ci-dessus)
  - garanties et preuve de propriétés
    - outils pour la cohérence et la synchronisation (exemples antérieurs)
    - base pour la modélisation (logique temporelle, etc.)

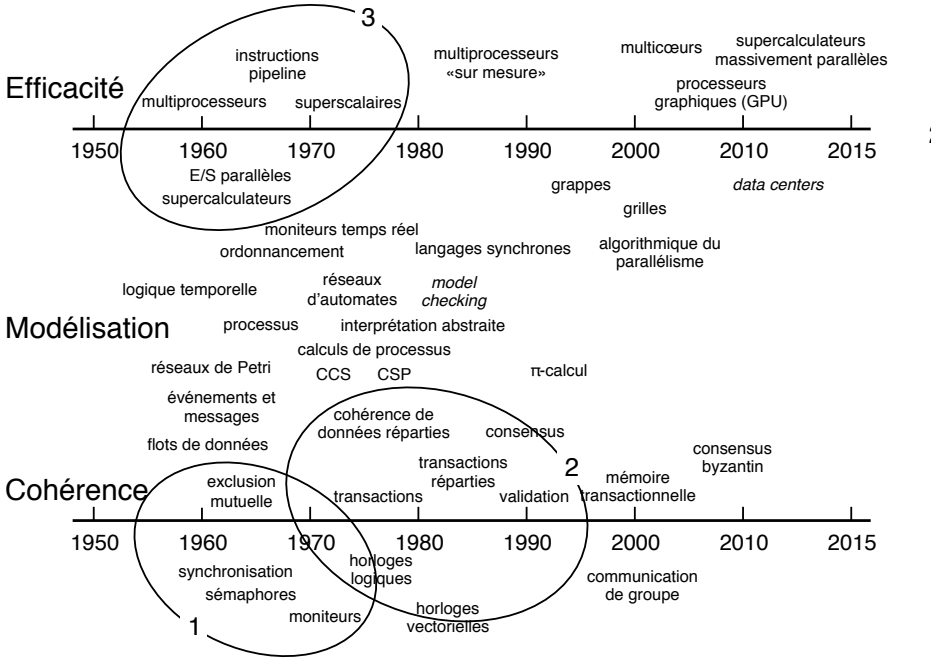

Les débuts de la synchronisation

Les débuts de la programmation concurrente

- Début des années 1960…
  - premiers systèmes d'exploitation multiprogrammés
  - premières entrées-sorties en parallèle
  - premiers multiprocesseurs
- La concurrence : une notion très mal comprise…
  - pas de modèle conceptuel
  - des instruments mal maîtrisés
    - matériels : les interruptions (1955-56)
    - logiciels : les instructions *fork-join* (1963)

explications plus loin

- … et des conséquences désastreuses
  - comportement non reproductible
  - pannes inexpliquées

Programmer la concurrence (1)

- Entrées-sorties asynchrones

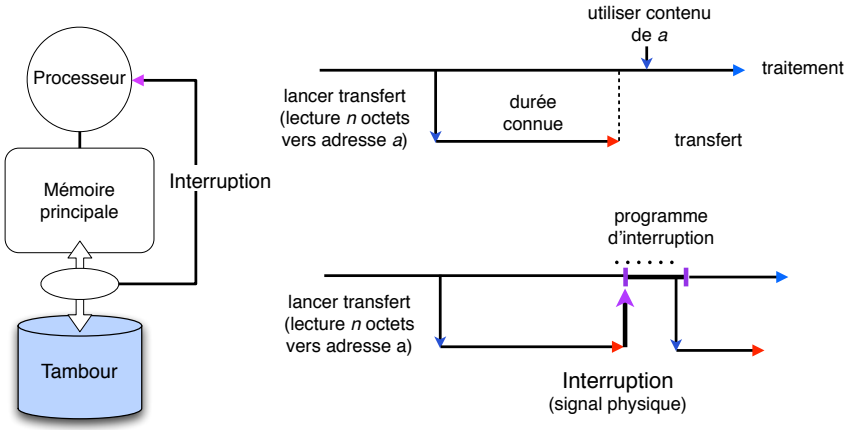

Programmer la concurrence (2)

- Programmer un multiprocesseur
  - premières idées (1963) : instructions *fork* et *join*

usage raisonné…

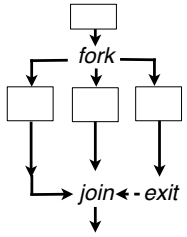

… mais dévoiement possible (analogue au *go to*)

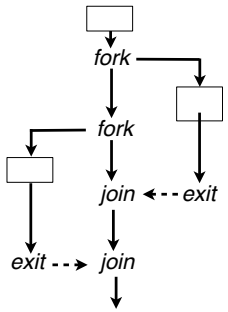

Mécanisme de l'interruption

L'origine du signal est extérieure au processeur interrompu (horloge, fin d'entrée-sortie, capteur externe, etc.). Des classes («niveaux») d'interruption distinguent les différentes causes.

Un niveau peut être «masqué» (l'interruption sera ignorée)

L'interruption est prise en compte en un «point interruptible» (en général entre deux instructions)

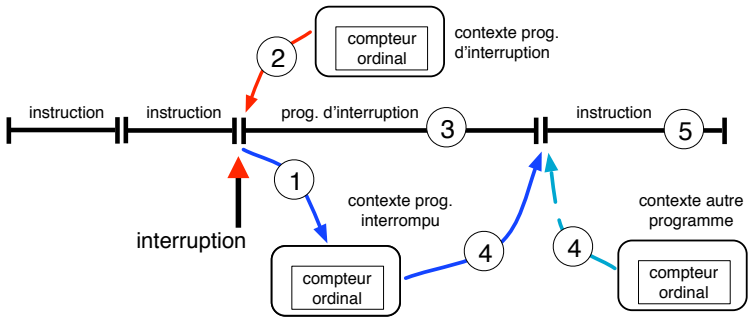

Dangers des interruptions (1)

«C'était une grande invention, mais aussi une boîte de Pandore.»

Edsger Dijkstra

- Effet d'une interruption (en l'absence de précautions)

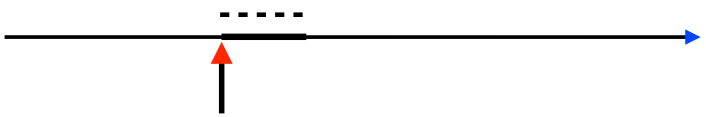

insérer une séquence d'instructions «n'importe où» dans le corps d'un programme

l'exécution du programme devient indéterministe (non reproductible)

il devient difficile (voire impossible) de raisonner sur l'effet du programme

Danger des interruptions (2)

- Exécution pseudo-parallèle

les changements de programme sont déclenchés par des interruptions d'horloge

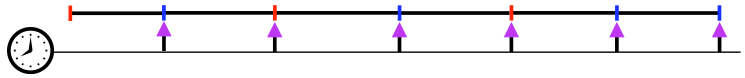

exemple : deux opérations de dépôt sur un même compte bancaire

activité 1	activité 2
1.1: courant$_1$ = lire_compte (867A)	2.1: courant$_2$ = lire_compte (867A)
1.2: nouveau$_1$ = courant$_1$ + 1000	2.2: nouveau$_2$ = courant$_2$ + 3000
1.3: ecrire_compte (867A, nouveau$_1$)	2.3: ecrire_compte (867A, nouveau$_2$)

un scénario d'exécution : 1.1 ; 1.2 ; 2.1 ; 2.2 ; 2.3 ; 1.3

résultat net ?

le compte est crédité de 1 000 € au lieu de 4 000 € !

Un problème de synchronisation

- Comment éviter la perte de mise à jour ?

un remède : imposer une exécution séquentielle des deux opérations de dépôt (A1 et A2)

soit A1 puis A2, soit A2 puis A1 : tout entrelacement est interdit

autrement dit : une seule des activités (au plus) peut exécuter à un instant donné l'opération en cause (dite section critique)

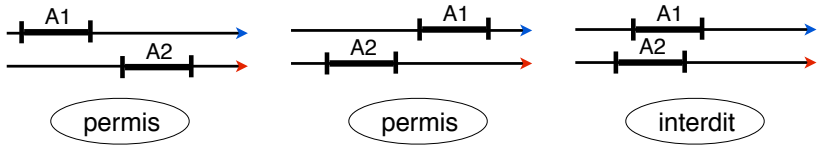

Cette condition s'appelle l'exclusion mutuelle ; c'est le premier problème de synchronisation explicitement formulé (Dijkstra, 1965)

La notion de processus

- Un pas vers l'abstraction…

qu'y a-t-il de commun entre les exécutions d'activités suivantes ?

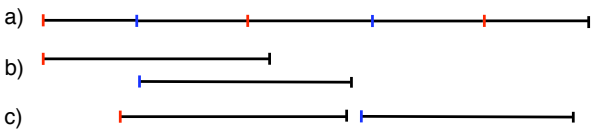

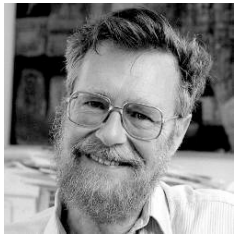

Edsger W. Dijkstra
(1930 - 2002)
crédit : University of Texas at Austin

réponse : les deux activités considérées comme séquences d'actions, indépendamment des conditions de leur exécution.

on arrive ainsi à la notion de **processus** (séquentiel), indépendant du processeur (et des autres ressources)

avantage : séparer les aspects logiques des aspects d'allocation de ressources

exemple : l'exclusion mutuelle est une contrainte logique

Exclusion mutuelle

- Spécifications

  un ensemble de processus, une section critique dans chacun ; un processus reste un temps fini dans sa section critique

  - ✦ Exclusion : à un instant donné, un processus au plus exécute sa section critique
  - ✦ Pas d'interblocage : si plusieurs processus essaient d'entrer en section critique, l'un d'entre eux finira par y parvenir
  - ✦ Pas de privation : si un processus tente d'entrer en section critique, il finira par y parvenir

- Principes de réalisation

  il faut faire attendre des processus. Deux moyens :

  - ✦ Attente active : le processus boucle sur un test
  - ✦ Blocage : le processus est placé dans un état inactif, où il attend d'être réveillé

Les débuts de l'exclusion mutuelle

(univers centralisé)

Support matériel (*test-and-set)*

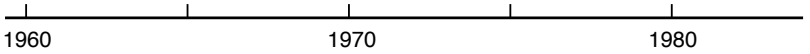

Fausses «solutions»

1965

Formulation précise du problème

Solution par attente active (Th. J. Dekker)

Solution par sémaphore binaire (verrou) (E. W. Dijkstra)

Sémaphores généraux (E. W. Dijkstra, C. S. Scholten)

1971

Régions critiques conditionnelles (C. A. R. Hoare)

1973-74

Moniteurs, (P. Brinch Hansen, C. A. R. Hoare)

1974

Algorithme de la boulangerie (L. Lamport)

1981

Solution simplifiée par attente active (G. Peterson)

Exclusion mutuelle par attente active (2 processus)

P1 — enter1 := **false** ; enter2 := **false** ; turn := 1 ; — P2

```
begin   A1 : enter1 := true ;
        L1 : if enter2 then
                 begin if turn = 1 then goto L1 ;
                     enter1 := false ;
                 B1 : if turn = 2 then goto B1 ;
                     goto A1 ;
                 end ;
    section critique;
    turn := 2 ; enter1 := false ;
    section non critique ; goto A1 ;
end ;
```

hypothèse : lecture et écriture d'une variable indivisibles

Dekker 1965

```
begin   A2 : enter2 := true ;
        L2 : if enter1 then
                 begin if turn = 2 then goto L2 ;
                     enter2 := false ;
                 B2 : if turn = 1 then goto B2 ;
                     goto A2 ;
                 end ;
    section critique;
    turn := 1 ; enter2 := false ;
    section non critique ; goto A2 ;
end ;
```

P1 — enter1 := **false** ; enter2 := **false** ; turn := 1 ; — P2

```
loop
    enter1 := true ;
    turn := 2;
    while (enter2 and turn = 1) { } ;
    section critique;
    enter1 := false ;
    section non critique ;
end ;
```

hypothèse : lecture et écriture d'une variable indivisibles

Peterson 1981

```
loop
    enter2 := true;
    turn := 1;
    while (enter1 and turn = 2) { } ;
    section critique;
    enter2 := false ;
    section non critique ;
end ;
```


Algorithme de la boulangerie

(Leslie Lamport, 1974)

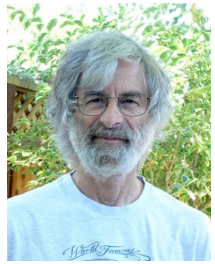

Principe : chaque processus prend un ticket numéroté
(ordre non décroissant)
L'entrée se fait par ordre croissant des tickets
(égalité résolue par n° de processus)

```
number[1] := 0; ...; number[n] := 0 ;
choosing[1] := false, ..., choosing[n] := false ;

choosing[i] := true ;
number[i] := 1 + max(number[1], ..., number[n]) ;
choosing[i] := false ;
forall j ≠ i do
   while choosing[j] { }
   while number[j] ≠0 and (number[j],j) < (number[i],i) { }
end
section critique
number[i] := 0
```

prise du ticket par processus n° *i*

entrée processus n° *i*

Intérêt : pas d'hypothèse sur accès atomique aux emplacements de mémoire

Support matériel pour l'exclusion mutuelle

✤ Idée de base : (test + modification) indivisibles

Exemple : `test-and-set (mem, val)`

indivisible
```
temp := *mem
*mem := val
result := temp
```
mem : adresse de mémoire
val : valeur
**mem* : contenu de *mem*

Réalisation d'un verrou

`*m := 1` condition initiale

attente active
```
while test-and-set(m, 0) = 0 { }   si libre, prendre le verrou
section critique
*m := 1                            relâcher le verrou
```

autres opérations : compare-and-swap, fetch-and-add

Verrous logiciels : sémaphore binaires

Dijkstra, 1965

✤ Idée : supprimer l'attente active

un processus peut transiter entre l'état actif et l'état «bloqué» (inactif)

sémaphore binaire *s* : une valeur *val(s)* : *0 [occupé]* ou *1 [libre]* ; deux opérations : *prendre*, *relâcher* ; une queue de processus bloqués sur *s* : *file(s)*

`demander(s)` appelés par processus *p* `libérer(s)`

indivisible
```
if val(s) = 0 then
   état(p) := bloqué ;
   entrer p dans file(s)
else val(s) := 0 ;
```

indivisible
```
if file(s) non vide then
   sortir un processus q de file(s) ;
   état(q) := actif
val(s) := 1 ;
```

✤ Exclusion mutuelle condition initiale : val(s) = 1

```
demander(s)          demander(s)
section critique     section critique
libérer(s)           libérer(s)
```


Risque du verrouillage : l'interblocage (1)

Verrouillage de fichiers : *verrouiller(f)* assure l'accès exclusif au fichier *f*, jusqu'au déverrouillage.

Les processus *p1* et *p2* partagent deux fichiers *f1* et *f2*, et les utilisent en accès exclusif.

```
processus p1                    processus p2
...                             ...
(1a) verrouiller (f1)           (2a) verrouiller (f2)
     accès à f1                      accès à f2
...                             ...
(1b) verrouiller (f2)           (2b) verrouiller (f1)
     accès à f1 et f2                accès à f1 et f2
déverrouiller (f2)              déverrouiller (f1)
déverrouiller (f1)              déverrouiller (f2)
```

p1 et *p2* s'exécutent en parallèle ; pour une exécution particulière, la séquence est :
1a ; 1b ; 2a ; 2b ; ...
pour une autre exécution :
1a ; 2a ; 1b ; 2b ; ...

Que se passe-t-il dans chaque cas ?

Risque du verrouillage : l'interblocage (2)

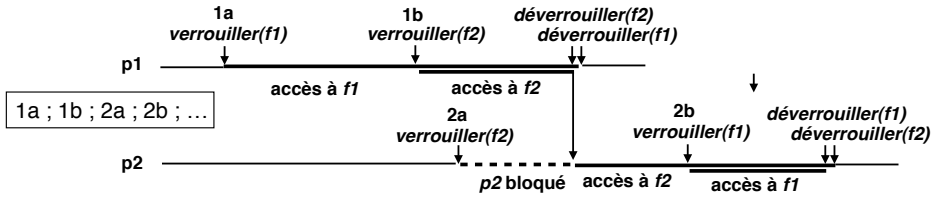

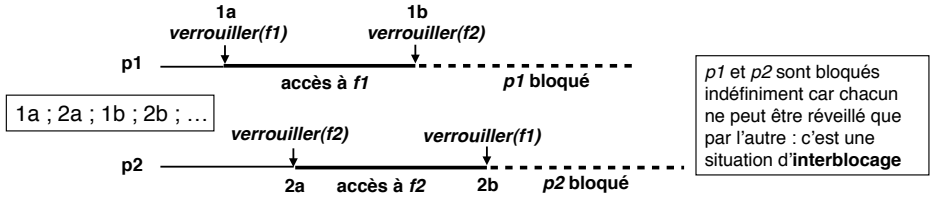

p1 et *p2* sont bloqués indéfiniment car chacun ne peut être réveillé que par l'autre : c'est une situation d'**interblocage**

L'interblocage : prévenir ou guérir

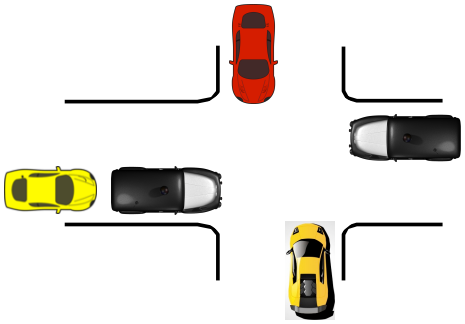

Questions :
- quelles sont ici les ressources ?
- comment sortir de l'interblocage ?

Prévention
- mettre des feux (chaque processus demande en bloc toutes les ressources dont il a besoin) - réduit le parallélisme
- mettre un rond-point giratoire (tous les processus demandent leurs ressources dans le même ordre, avec priorité)

Guérison
- on ne peut pas sortir de l'interblocage sans perdre quelque chose

De l'exclusion mutuelle à la synchronisation

- Les sémaphores compteurs (Dijkstra, Scholten, 1965)

généralisent les sémaphores binaires : *val(s)* est un entier relatif (positif ou négatif)

	demander(s)	libérer(s)
indivisible	val(s) := val(s) - 1 ; **if** val(s) < 0 **then** état(p) := bloqué ; entrer p dans file(s) ;	
indivisible		val(s) := val(s) + 1 ; **if** val(s) ≤ 0 **then** sortir un processus q de file (s) ; état(q) := actif

appelés par processus *p*

une analogie : le portillon automatique

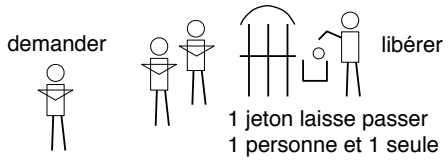

si val(s) < 0 : - longueur de la file
si val(s) > 0 : nombre de jetons d'avance

Un exemple de synchronisation

- Mémoire tampon pour une imprimante

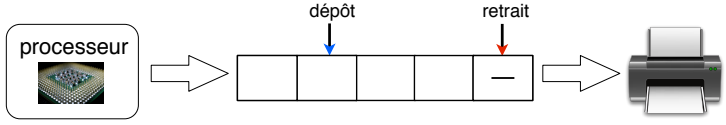

processus éditeur — processus imprimeur

sémaphore nvide := 5, nplein := 0 ;

```
page := suivante ;                  demander (nplein) ;
demander (nvide) ;                  sortir (page) ;
entrer (page) ;                     libérer (nvide) ;
libérer (nplein) ;                  imprimer (page)
```

Schéma producteur - consommateur

Noter la symétrie : l'éditeur produit des cases pleines, consomme des cases vides
l'imprimeur consomme des cases pleines, produit des cases vides

Synchronisation et communication (1)

- Les messages peuvent réaliser la synchronisation

envoyer(message, destinataire)
recevoir(message) bloquant en attente de message

- Comparaison avec sémaphores

capacité d'expression équivalente
les messages fonctionnent aussi en univers réparti

- De nombreuses variantes…

désignation du destinataire
directe (processus), indirecte (boîte aux lettre)
mode de synchronisation
envoi non bloquant (message) ou bloquant (rendez-vous)
persistance des messages
message transitoire (perdu si non attendu) ou persistant (conservé)

Synchronisation et communication (2)

- Messages et événements
  - un événement peut être vu comme un message au contenu vide (la seule information est qu'il s'est produit)
  - la synchronisation par événement-réaction est apparue très tôt (fin années 50)
  - à l'époque, outil peu maîtrisé (cf interruptions)
- Flots de données
  - une manière duale de voir la synchronisation (1961)
  - l'événement : «toutes les données attendues sont arrivées» déclenche une action (le traitement de ces données)

Un outil de plus haut niveau : les moniteurs

- Idée
  - encapsuler une structure de données et ses fonctions d'accès synchronisées
  - un niveau d'abstraction supérieur à celui des sémaphores
- Exemple : le tampon
  - 2 opérations :

    tampon.déposer
    tampon.retirer

  - réalisent la synchronisation
  - cachent les détails de la mise en œuvre

Tony Hoare
(1934 -)
by Rama, Wikimedia Commons

Per Brinch Hansen
(1938 - 2007)
Wikimedia Commons

Les moniteurs : structure interne

```
tampon : moniteur ;
    var n : 0..N ;
    non_plein, non_vide : condition ;
    procédure déposer (m : message) ;
      if n = N then
        non_plein.attendre
      n := n + 1 ;
      mettre (m) ;
      non_vide.signaler ;
    procédure retirer (var m : message) ;
      if n = 0 then
        non_vide.attendre
      prendre (m) ;
      n := n - 1 ;
      non_plein.signaler ;
    initialisation  n := 0 ;
```

À noter :

les conditions
les opérations sur les conditions

attendre : bloquer le processus, qui entre dans une file d'attente associée à la condition

signaler : réveiller un processus de la file associée à la condition

Les procédures du moniteur sont exécutées en exclusion mutuelle

Bilan des débuts de la programmation concurrente

1965-75

- Avancées …
  - La notion de processus
  - Le problème de l'exclusion mutuelle et ses solutions
  - Compréhension et solution de l'interblocage
  - Des outils de synchronisation : sémaphores, messages, moniteurs
- Limites …
  - Preuve de programmes parallèles
    - première réponse en 1976 (Owicki-Gries)
  - Intégration dans les langages de programmation
    - premières réponses à partir de 1975 (Concurrent Pascal, Mesa, ...)
  - Prise en compte des défaillances
    - transactions, à partir de 1976
  - Prise en compte de la répartition
    - horloges logiques, 1978

X X

Synchronisation en univers réparti et non fiable

Les défaillances, source d'incohérence

- Exemple : transfert bancaire

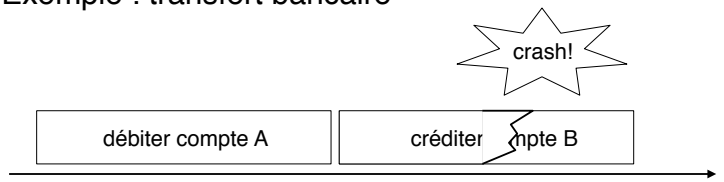

état incohérent :
A débité, B non crédité

- Un remède
  - rendre indivisible la séquence *débiter-créditer*
  - exécution «tout ou rien»
  - analogie avec exclusion mutuelle, mais une différence :
    - en cas de défaillance, il faut restaurer l'état initial
    - cela revient à «remonter le temps»

Redéfinir l'atomicité

- … vis-à-vis des défaillances
  - Exécution «tout ou rien»
    - pas de défaillance : l'action est exécutée
    - défaillance : on revient à l'état initial
  - On peut mieux faire …
    - point de validation

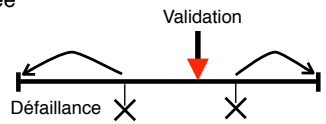

- … vis-à-vis de la concurrence
  - Une notion déjà vue
    - exécution concurrente de A et B :
      - équivaut à A ; B ou B ; A

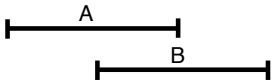

  - Une reformulation
    - exécution concurrente de A et B :
      - A n'a pas accès à l'état de B, B n'a pas accès à l'état de A
      - c'est la notion d'isolation

Les transactions

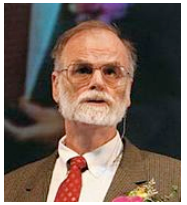

Jim Gray
1944-2007
©Microsoft

- Dans le contexte des bases de données
  - Deux propriétés requises pour une action composée
  - Cohérence
    - Propriété de l'état, dépendante de l'application, à maintenir
  - Durabilité (ou permanence)
    - Après validation, les modifications de l'état sont préservées
      - Propriété garantie par le support de stockage (mémoire stable)
- La notion de transaction ACID
  - Une action composée (séquence d'actions élémentaires) avec
  - Atomicité (tout ou rien en cas de défaillances)
  - Cohérence (maintien de propriétés spécifiées)
  - Isolation (non-interférence de transactions indépendantes)
  - Durabilité (préservation des résultats après validation)

Réaliser les transactions

- Un système de gestion de transactions
  - Si l'utilisateur assure la cohérence (C), le système garantit atomicité (A), isolation (I), durabilité (D)
  - La durabilité (D) est assurée par la mémoire stable. Restent A et I
- Garantir l'isolation
  - Isolation = sérialisabilité (équivalence à une exécution séquentielle)
  - Principe : verrouillage des données (pour la durée nécessaire)
  - Une propriété : le verrouillage à deux phases assure la sérialisabilité
    - phase 1 : verrouiller (progressivement) ; phase 2 : déverrouiller
- Garantir l'atomicité
  - Principe : conserver un journal (liste des opérations), pour pouvoir «défaire» en cas de besoin (défaillance)
  - Le journal est en mémoire stable ; les actions sont enregistrées avant leur exécution

Le temps en univers réparti

- Qu'est-ce qu'un système réparti ?

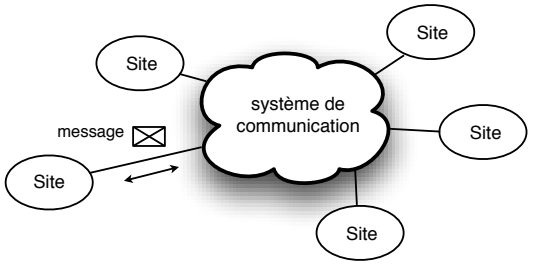

Pas de mémoire commune
Pas d'horloge commune

- Propriétés du système de communication
  - Types possibles de défaillances
    - perte de messages (détectée ou non)
    - altération de messages, création de messages
  - Synchrone ou asynchrone ?
    - durée de transmission bornée ou non

Raisonner en univers réparti

- Motivations
  - On veut coordonner des activités, donc parler d'ordre
  - On veut définir des propriétés, donc parler d'état
- Hypothèses sur la communication
  - fiable (pas de perte ou d'altération de messages)
  - asynchrone (pas de borne sur le délai de transmission)
    - dans la pratique, on fixe souvent une limite
  - pas nécessairement FIFO
- Que veut-on garantir ?
  - Sûreté (un événement indésirable n'arrivera jamais)
    - interblocage, incohérence des données, violation de protection
  - Vivacité (un événement désirable finira par arriver)
    - un message sera délivré, une ressource sera disponible, un calcul se terminera

Les limites du raisonnement

- De nombreux résultats d'impossibilité
  - liés au système de communication et aux types de défaillances
- Premier exemple : «le paradoxe des généraux» (1975)
  - si l'émetteur ne peut s'assurer de la délivrance d'un message, l'accord entre deux partenaires est impossible

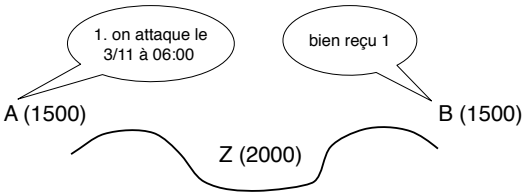

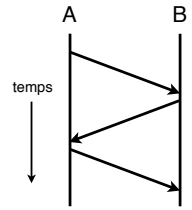

  - en pratique : hypothèse de synchronisme (délai de garde)
  - protocole de l'accord confirmé (chacun voit un aller-retour)

Définir un ordre en univers réparti

- Motivations
  - Synchroniser des activités
  - Maintenir la cohérence de données

définir un ordre entre événements

- Principe
  - Comment définir une relation de précédence pour des événements sur des sites différents ?
  - Utiliser le principe de causalité : la cause précède l'effet
  - Entre deux sites : l'envoi d'un message précède sa réception

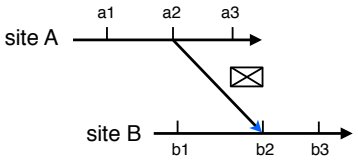

a2→b2 donc a1→b3

Pas de précédence causale entre a1, b1 ou a3, b1 ou a3, b3

On écrit a1 ll b1, a3 ll b1, a3 ll b3

Sur la dépendance causale

- Un exemple

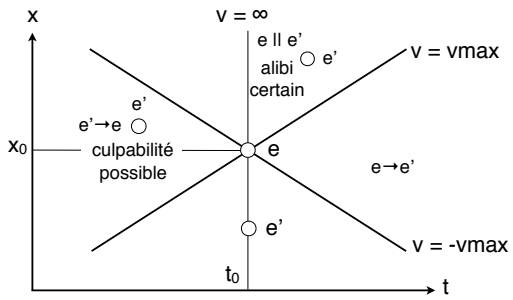

La précédence causale n'indique qu'une dépendance potentielle

Si e1→ e2, alors il est impossible que e2 soit cause de e1, mais il est seulement possible (non certain) que e1 est cause de e2

- Application
  - Recherche de la cause d'une défaillance

Datation en univers réparti

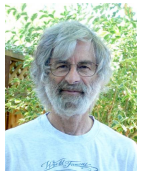

- Les horloges logiques (Lamport, 1978)
  - Un compteur par site, incrémenté à chaque événement
  - Les messages sont estampillés par l'heure d'envoi
  - À la réception d'un message, le compteur local est mis à jour pour respecter la causalité

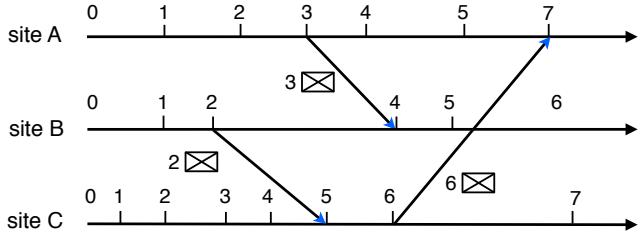

Sur chaque site, l'heure d'un événement est la valeur de son compteur (horloge logique, ou HL)

Les horloges logiques

- Propriétés
  - Les horloges logiques traduisent (faiblement) la dépendance causale

    Si e1→ e2, alors HL(e1) < HL(e2)
  - Mais l'inverse n'est pas vrai

    Si HL(e1) < HL(e2) alors e2 ne précède pas e1 :

    ou bien e1 → e2, ou bien e1 ll e2
  - Pour caractériser fortement la dépendance, il faut des horloges plus raffinées (horloges vectorielles ou matricielles)

- Usage
  - File d'attente répartie
    - Algorithmes de synchronisation (exclusion mutuelle, diffusion)
    - Mise à jour cohérente de données dupliquées
  - Gestion de caches
  - Génération de noms uniques

Cohérence de données réparties

- Définir la cohérence ?
  - un problème en soi…
  - … de nombreuses définitions
- Quelques exemples
  - cohérence stricte
    - une lecture rend le résultat de la «dernière» écriture
  - cohérence à terme
    - en l'absence d'écriture, tous les exemplaires «finiront par» devenir identiques
    - entre temps, une lecture peut renvoyer une valeur «ancienne»
  - cohérence causale
    - si l'événement e1 (écriture ou lecture) précède causalement l'événement e2, alors e1 est vu avant e2 sur tous les sites

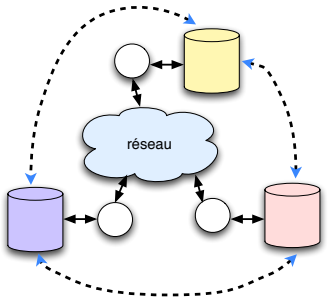

De la synchronisation à la décision concertée

- Motivations
  - De nombreuses situations exigent qu'un ensemble de processus prennent une décision concertée
    - validation de transactions réparties
    - diffusion d'informations dans le même ordre pour tous les récepteurs
    - détermination (unique pour tous) de la composition d'un groupe
  - Le consensus est un des problèmes clé des systèmes répartis
    - très simple en l'absence de pannes
    - très difficile avec pannes et communication asynchrone
- Spécifications du consensus (informelles !)
  - Chaque processus propose une décision (ex : choisir une valeur)
  - Chaque processus décide
    - Tous (sauf ceux défaillants) prennent la même décision (l'une de celles proposées)
    - La décision est prise en temps fini

Réaliser le consensus

- Un résultat d'impossibilité (Fischer, Lynch, Paterson, 1983)
  - Dans un système asynchrone avec pannes franches, le consensus est impossible par un protocole déterministe, dès qu'un processus est en panne
  - Explication sommaire : en asynchrone, impossible de distinguer un processus lent d'un processus défaillant
- Solutions pratiques
  - Détecteurs de pannes (Chandra, Toueg, 1991)
    - Le consensus est possible avec un détecteur de pannes même imparfait ; on essaie d'approcher un tel détecteur
  - Paxos (Lamport, 1989 ; préfiguration par Oki et Liskov, 1988)
    - Utilise un coordinateur, remplacé si défaillant
  - Dans tous les cas, hypothèse de synchronisme (délai de garde), qui peut échouer

Paxos (vue très sommaire)

- Dans un monde parfait…
  - On choisit un processus coordinateur
  - Celui-ci recueille les votes des participants et propose une décision
  - Si tout va bien, la décision proposée est adoptée à la majorité
- … mais les défaillances arrivent
  - Cas d'échec possibles (pas de décision prise)
    - Panne du coordinateur
    - Impossibilité d'obtenir une majorité
      - panne des processus participants
      - communication asynchrone
  - En cas d'échec
    - On choisit un autre coordinateur
    - Si une décision a été proposée antérieurement, elle est préservée
  - Décision si un coordinateur garde une majorité pour le temps de 2 aller-retours

Paxos

- Paxos en pratique
  - Des hypothèses de fonctionnement très faibles
    - pannes avec réinsertion
    - perte de message
  - Une mise en œuvre délicate et complexe
- Extensions
  - Consensus avec pannes «byzantines» (comportement quelconque, y compris malveillant)
  - Une extension de Paxos (Castro, Liskov, 2001), nombreuses améliorations ultérieures, sujet «chaud»
- Exemple d'utilisation
  - Gestion des données réparties dans Google
    - Maintien de la cohérence de données dupliquées en cas de pannes

Quelques tendances actuelles
de la synchronisation répartie

- Nouveaux paradigmes
  - exemple : Map-Reduce (réduire les occasions de synchronisation)
- Retour en grâce des événements
  - stimulé par les nouvelles applications (graphiques, etc.)
  - modèles et outils pour la coordination à grande échelle
- Évolution du modèle de transactions
  - le Web comme grande base de données
    - peu structurée, évoluant en permanence
  - nouvelles visions des transactions
    - transactions longues
    - au delà du schéma ACID
- Vers des applications «réelles» du consensus

X

  - cohérence de données
  - communication de groupe

Le parallélisme dans les premiers supercalculateurs

Les premiers «supercalculateurs»

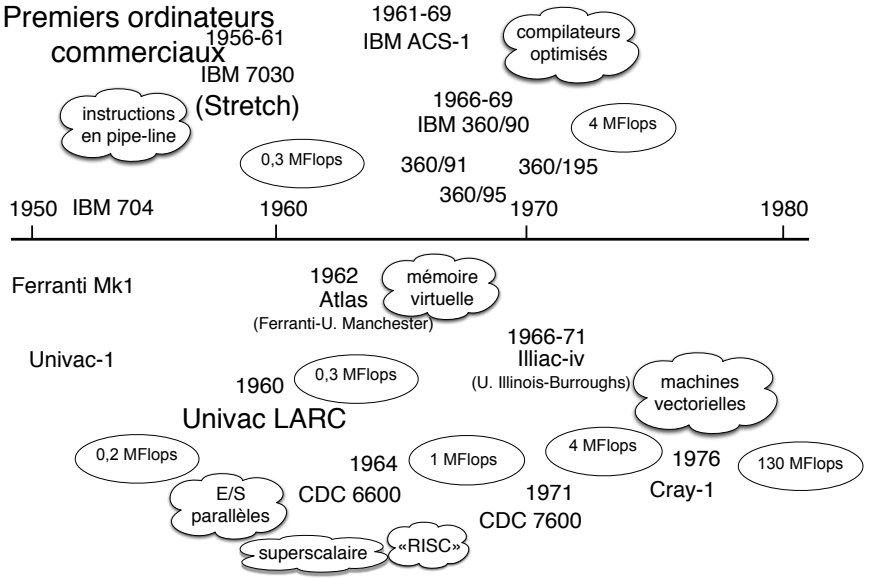

Instructions en pipe-line

- Les étapes d'une instruction (simplifié !)

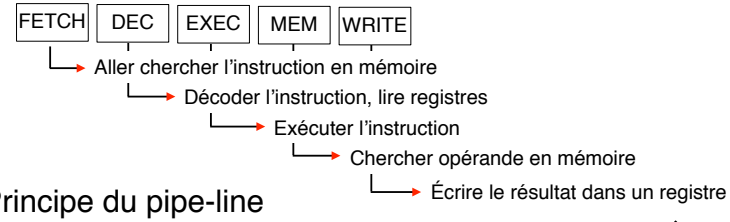

- Principe du pipe-line

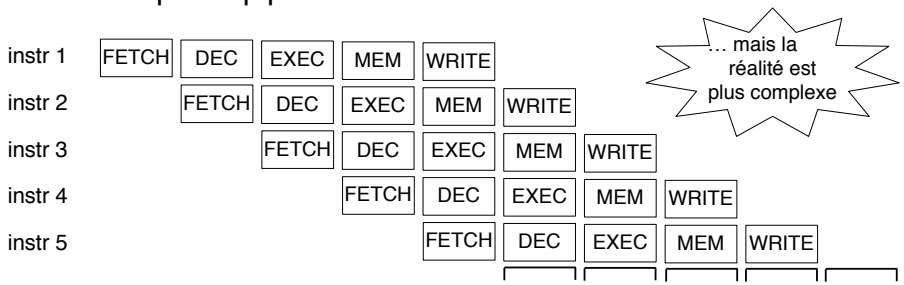

Difficultés du pipe-line (1)

Le fonctionnement du pipe-line peut être perturbé pour diverses raisons, qui empêchent le déroulement continu des instructions.

- Conflits d'accès aux données

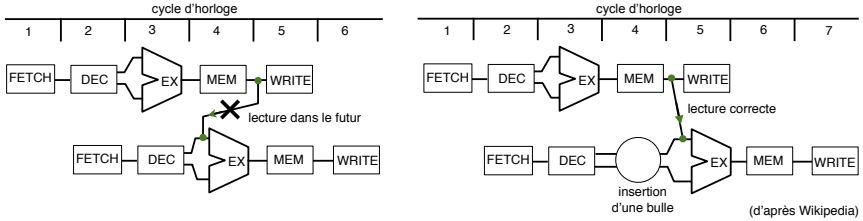

ici : conflit *read after write* (RAW), le plus fréquent
autres conflits possibles : WAW, WAR

Solutions :

insérer des «bulles» (mais retarde l'exécution)
ordonnancer dynamiquement (changer l'ordre d'exécution)
se reposer sur les compilateurs

Difficultés du pipe-line (2)

- Conflits d'accès aux ressources

source d'attente («bulles»)

- Instructions de branchement conditionnel

si on attend l'évaluation de la condition, on retarde l'exécution
une voie d'approche : faire une hypothèse sur le résultat
toujours la même (ex : pas de branchement)
prévision fondée sur l'histoire antérieure
donc :
si l'hypothèse est juste, on ne perd rien
si elle est fausse, il faut annuler le travail fait à tort (bulle)
autre voie :
changer l'ordre des instructions (si c'est possible) pour «avancer» l'évaluation de la condition

Difficultés du pipe-line (3)

- Interruptions

dans une architecture sans pipe-line : «points interruptibles» (en général entre deux instructions)

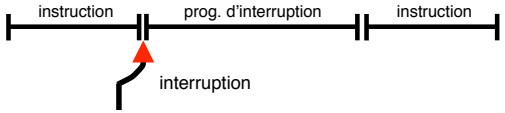

où sont les points interruptibles dans un pipe-line ?

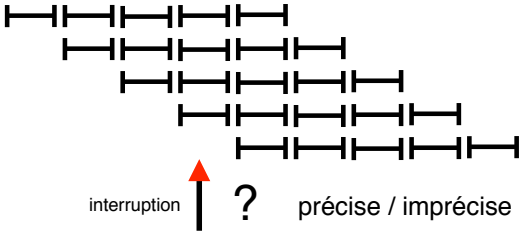

Architectures superscalaires

- Une autre source de parallélisme
  - lancer plusieurs instructions à la fois
  - les ressources doivent permettre leur exécution en parallèle
  - peut être combinée avec un pipe-line

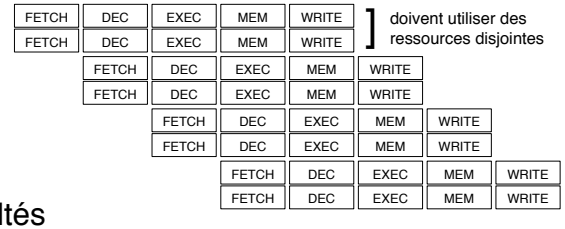

- Difficultés
  - risques accrus de retards dus aux dépendances
  - d'où réorganisation dynamique de l'exécution des instructions

Machines parallèles emblématiques

des années 1960-70

IBM 7030 «Stretch»

(1956-51)

- Un objectif ambitieux
  - 100 fois la vitesse du 704
- Des avancées techniques
  - première machine IBM à transistors
  - une des toutes premières pour les instructions en pipeline
- Une équipe talentueuse
  - Steve Dunwell, Gene Amdahl (au début)
  - «débutants» prometteurs : Fred Brooks, John Cocke
- Un échec commercial…
  - performances limitées (30 x 704 au lieu de 100), 9 exemplaires vendus
- … mais une expérience précieuse pour la suite

Console de maintenance de l'IBM 7030
Musée des Arts et Métiers

CDC 6600

(1962-64)

- Le premier «supercalculateur»
  - 1 MFlops, > 100 exemplaires
- Des avancées décisives
  - entrées-sorties parallèles (10 processeurs périphériques multiplexés)
  - jeu d'instructions «RISC» avant l'heure
  - architecture «superscalaire» avant l'heure
  - ordonnancement dynamique
  - cache d'instructions
- Un architecte de génie
  - Seymour Cray (1925-1996)

CDC 6600

Seymour Cray
Wikipedia Commons

Famille IBM 360/90 (91, 95, 195)

IBM 360/195
© Rutherford Appleton Laboratory-STFC
http://www.chilton-computing.org.uk/

- Une série réussie
  - environ 4 MFlops pour le 195, rival du CDC 7600
  - environ 40 machines construites (dont 25 360/195)
- Avancées techniques
  - mémoire cache (vient du 360/85)
  - pipeline (mais non superscalaire)
  - réordonnancement des instructions pour éviter les conflits de données (Robert Tomasulo)
  - circuits intégrés
  - multiplicateur flottant parallèle

Illiac IV
(1965-1971)

ILLIAC 4
CC BY 2.0 Steve Jurvetson
Menlo Park, USA

- Un objectif ambitieux
  - SIMD (même instruction, données multiples : 256 processeurs,1 GFlops)
- Une histoire mouvementée
  - suite d'un projet avorté (Solomon)
  - Université d'Illinois (Daniel Slotnick) + Burroughs
  - manifestations d'opposants (programme militaire)
- Un semi-échec
  - un seul exemplaire construit, 64 processeurs, utilisé par la NASA
  - budget = 4 x prévision, 100 MFlops
  - nombreux problèmes techniques, 3 ans de mise au point après livraison
  - néanmoins : en 1975, machine la plus rapide

Cray-1
(1972-76)

Cray 1
Wikimedia Commons
Deutsches Museum, Munich

- Cray Research (fondé en 1972)
- Unes architecture novatrice
  - SIMD, processeur vectoriel
  - opère sur jeu de registres (8 x 64)
  - instructions en pipeline (sans conflit)
  - avancées techniques
    - refroidissement
    - longueur de connexion minimales
- Un grand succès
  - > 100 exemplaires sur les différentes versions (objectif initial : 12)
  - 140 MFlops
- Le début d'une série
  - Cray X-MP (1982, 800 MFlops), Cray 2 (1985, 1,9 GFlops), …

Bilan des premières machines parallèles
(1956-1976)

- Parallélisme interne dans les machines SISD
  - instructions en pipeline
  - architectures superscalaires
  - gain de performances, coût élevé en complexité
- Les premières machines vectorielles (SIMD)
  - plus tard supplantées par les MIMD
  - regain actuel dans les processeurs graphiques
- L'importance déterminante du logiciel
  - techniques de compilation
  - systèmes d'exploitation
  - programmation parallèle

X

Remarques finales

- Évolution initiale des problèmes liés au temps
  - Années 1965-75
    - comprendre la concurrence, maîtriser la synchronisation
    - utiliser la concurrence pour l'efficacité
  - Années 1975-80
    - début de la prise en compte des fautes
    - premières réflexion sur les systèmes répartis
  - Années 1980-90
    - poursuite de l'efficacité
    - passage à grande échelle dans les réseaux
    - les langages synchrones
    - importance croissante de la cohérence des données
- Quelques tendances actuelles
  - La concurrence omniprésente mais encore mal comprise …
  - Cohérence et sécurité, préoccupations majeures
  - Importance croissante de la théorie