Systèmes et algorithmes répartis

Modèle standard et principes algorithmiques

http://queinnec.perso.enseeiht.fr/Ens/sar.html

Département Informatique et Mathématiques Appliquées
ENSEEIHT

25 septembre 2018

plan

1. Le modèle standard
   - Approche événementielle
   - Causalité
   - Abstraction d'un calcul
   - Prise de cliché
2. Description des algorithmes
   - Description du comportement des processus
   - Exemple : l'élection

Plan

1. Le modèle standard
   - Approche événementielle
   - Causalité
   - Abstraction d'un calcul
   - Prise de cliché
2. Description des algorithmes
   - Description du comportement des processus
   - Exemple : l'élection

Vision statique : Graphe de processus

Description graphique

- Sommets ≡ processus / sites
- Arcs ≡ liaisons de communication / canaux

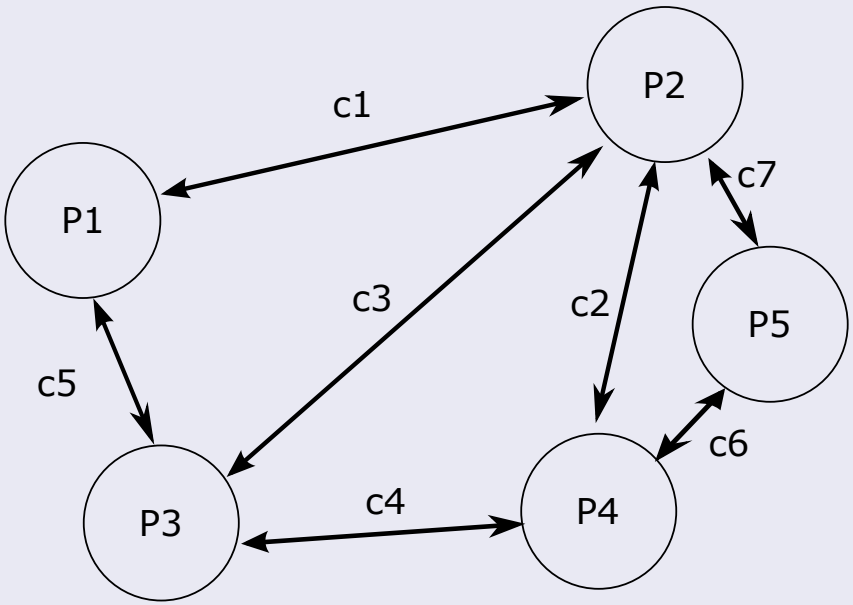

Propriétés

Propriétés des processus / sites

- Un processus possède une identité unique
- Un processus possède un état rémanent
- Un processus exécute un code séquentiellement
- Un processus n'a qu'une connaissance partielle des autres
- Un processus peut communiquer avec un voisinage
- Défaillance : arrêt, comportement byzantin

Propriétés du réseau

- Multiples paramètres : point à point ou diffusion, (a)synchrone, fiable, délais bornés, etc
- Messages : perte, duplication, modification du contenu

Connaissances d'un processus

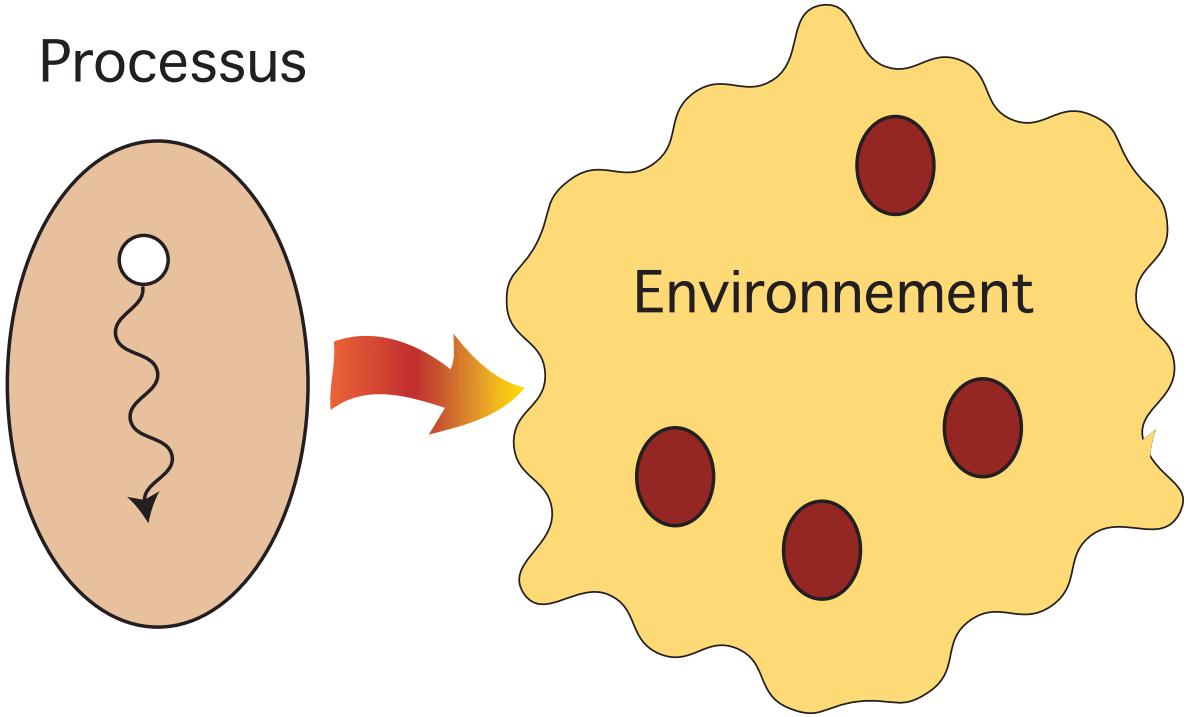

- Nombre de processus ?
- Voisinage de communication ?
- Structure du réseau : maillé, anneau, statique/dynamique, etc

Vision dynamique : Chronogramme

Représentation événementielle

- Trois types d'événements : émission, réception, interne
- Causalité entre événements

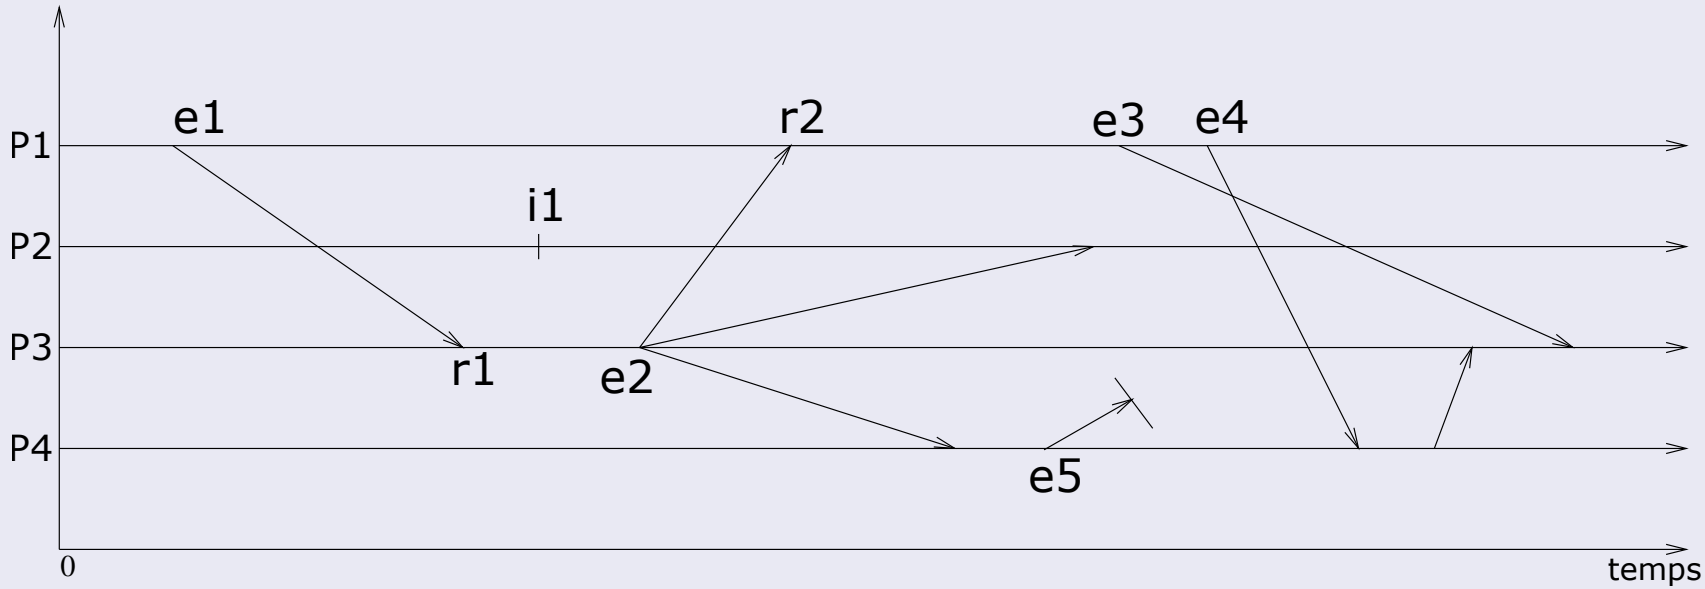

Système asynchrone vs synchrone

Asynchrone

- Pas de temps externe
- Progression de chaque processus à son rythme
- Délai de transmission arbitraire

Synchrone

- Existence de pas de calcul (*round*) globaux
- Un message émis dans un pas est reçu au pas suivant / dans le même pas (selon le modèle)

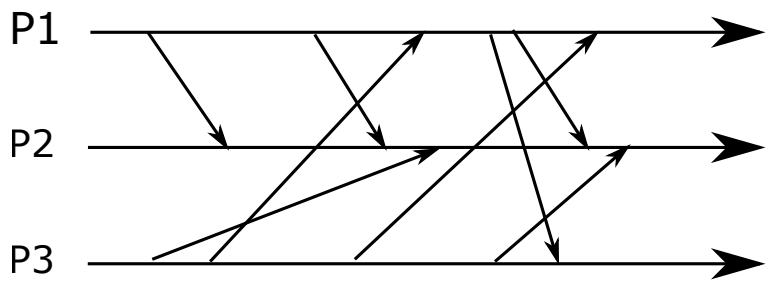

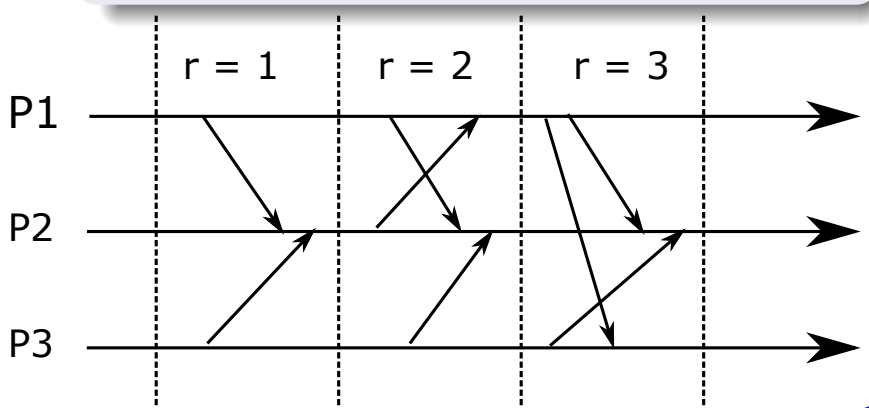

Relation de causalité (Lamport 1978)

Ordre partiel entre événements $\prec$

- Les événements d'un processus sont totalement ordonnés : e et e' sur le même site, et e précède e', alors $e \prec e'$.
- L'émission d'un message précède causalement sa réception : Si $e =$ émission(m) et $e' =$ réception(m), alors $e \prec e'$.
- Transitivité : $\forall e, e', e'' : e \prec e' \prec e'' \Rightarrow e \prec e''$

- La relation $\prec$ est un ordre partiel : $e \parallel e' \stackrel{\Delta}{=} e \not\prec e' \wedge e' \not\prec e$
- Indépendance du temps physique mais consistent avec : $e \prec e' \Rightarrow e$ est survenu avant e' dans le temps absolu

1. *Time, Clocks and the Ordering of Events in a Distributed System*, Leslie Lamport. Communications of the ACM, July 1978.

Relation de causalité (Lamport 1978)

Exemple

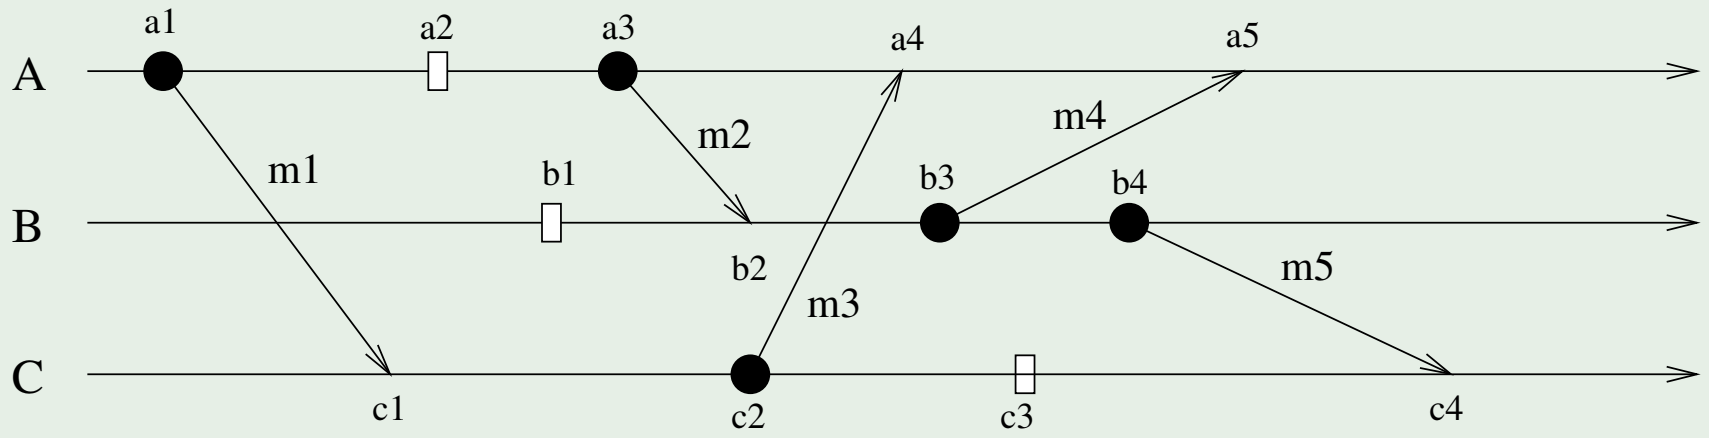

$$a_1 \prec a_2 \prec a_3 \prec a_4 \prec \dots$$
$$a_1 \prec c_1,\ c_2 \prec a_4,\ b_4 \prec c_4$$
$$a_1 \prec c_3 \ (\text{car } a_1 \prec c_1 \prec c_2 \prec c_3)$$
$$a_2 \prec c_4$$
$$a_3 \parallel c_2$$

Abstraction d'un calcul réparti

Exécutions causalement équivalentes

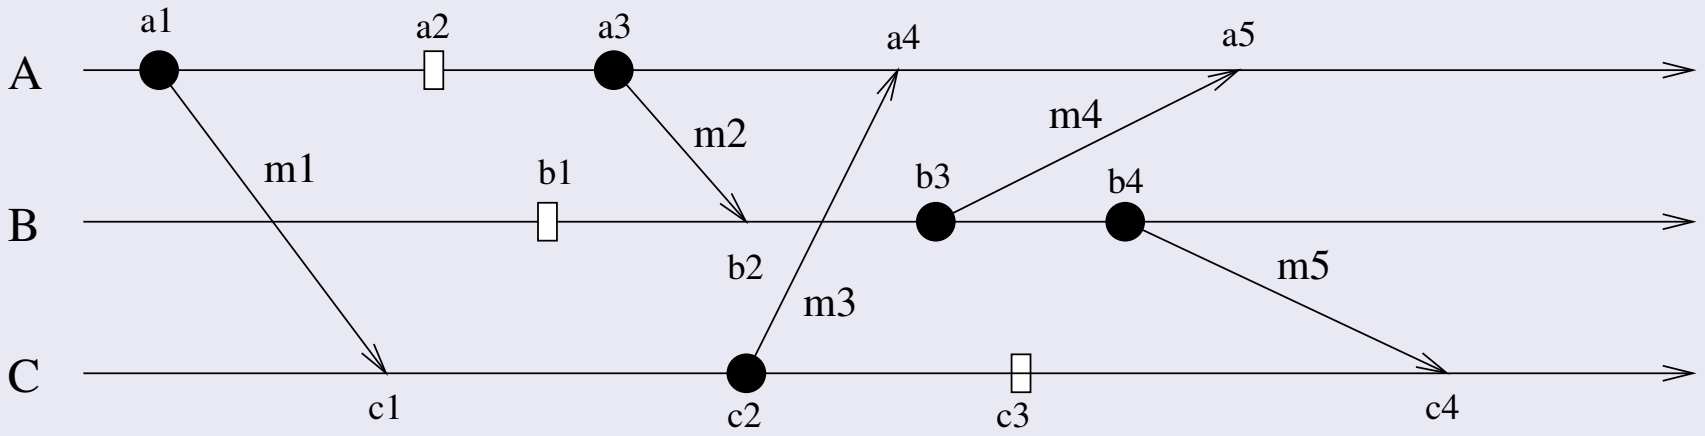

- Ensemble d'événements + relation causale
  $\rightarrow$ ensemble d'exécutions réelles équivalentes

$$a_1; b_1; c_1; a_2; \ldots \equiv a_1; a_2; c_1; b_1; \ldots$$

$$a_1; c_1; a_2; \ldots \not\equiv c_1; a_1; a_2; \ldots \text{ car } a_1 \prec c_1$$

- Le choix des événements fixe un niveau d'observation

Passé / futur causal

Partition des événements

$$\text{passé}(e) \triangleq \{f \mid f \prec e\}$$

$$\text{futur}(e) \triangleq \{f \mid e \prec f\}$$

$$\text{concurrence}(e) \triangleq \{f | f \notin \text{passé}(e) \wedge f \notin \text{futur}(e)\}$$

Exemple

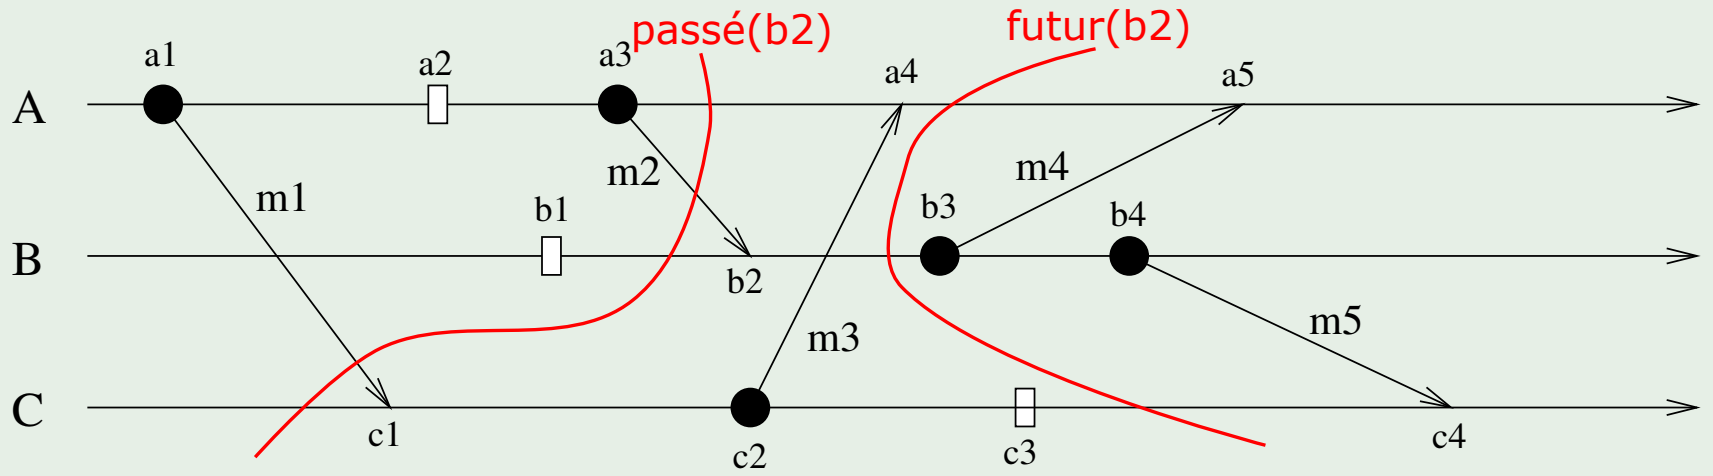

Coupure et coupure cohérente

Coupure

Une coupure est un ensemble d'événements qui forment des préfixes complets des histoires locales.

Coupure cohérente

Une coupure C est cohérente si $\forall e \in C : \forall e' : e' \prec e \Rightarrow e' \in C$

Exemple

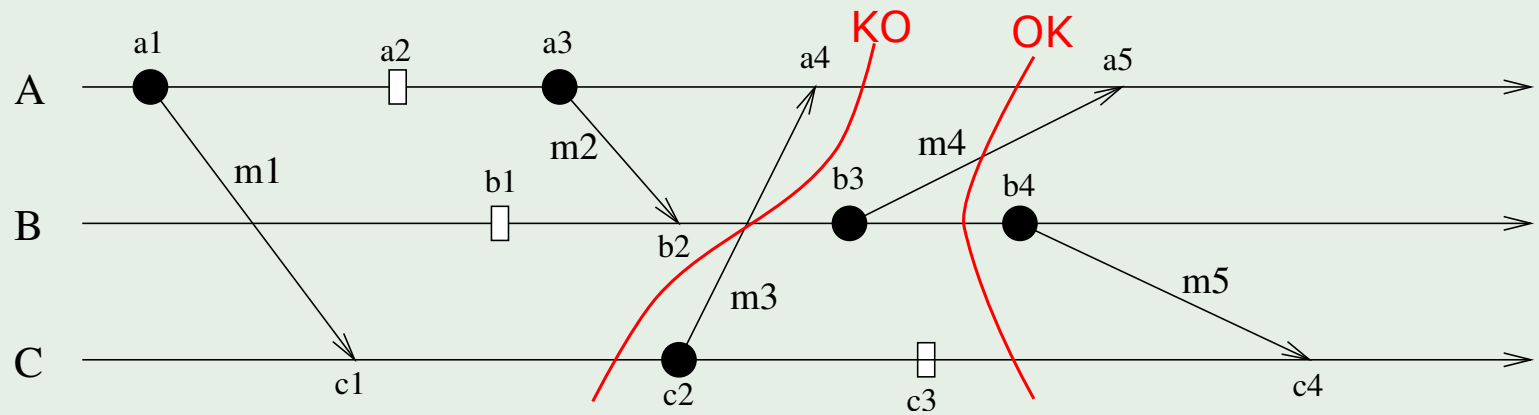

Passé et coupure cohérente

Une coupure C est cohérente ssi $C = \bigcup_{e \in C}(passe(e) \cup \{e\})$:

- Pas de « trou » sur un site
- Une réception n'est pas présente sans son émission

Exemple

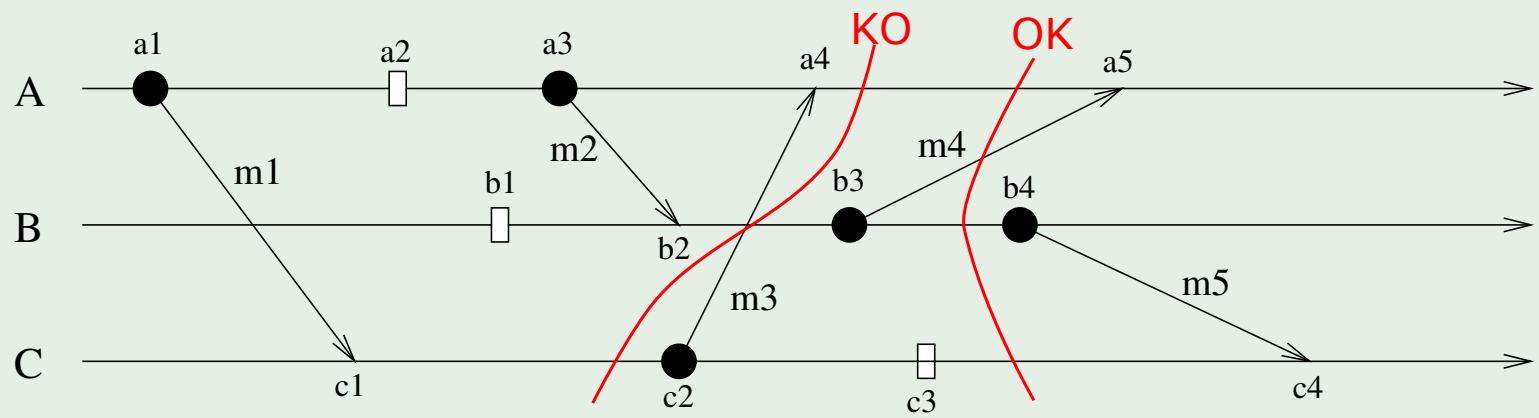

Coupure cohérente et état global

Une coupure cohérente correspond à un état global qui aurait pu exister.

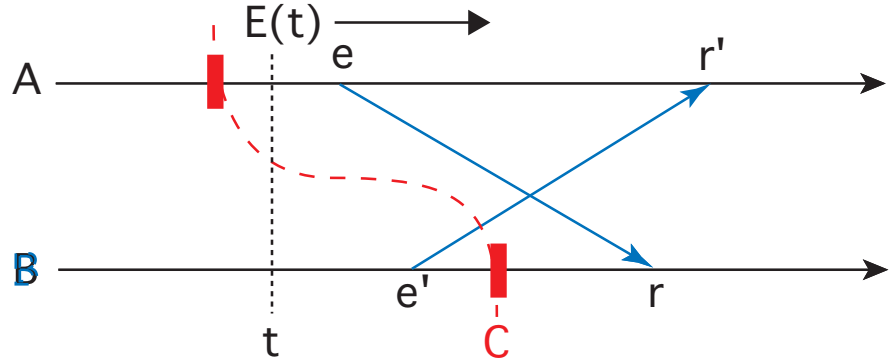

Réalité

La coupure est cohérente mais...

État effectif

L'état n'a pas existé à un instant global

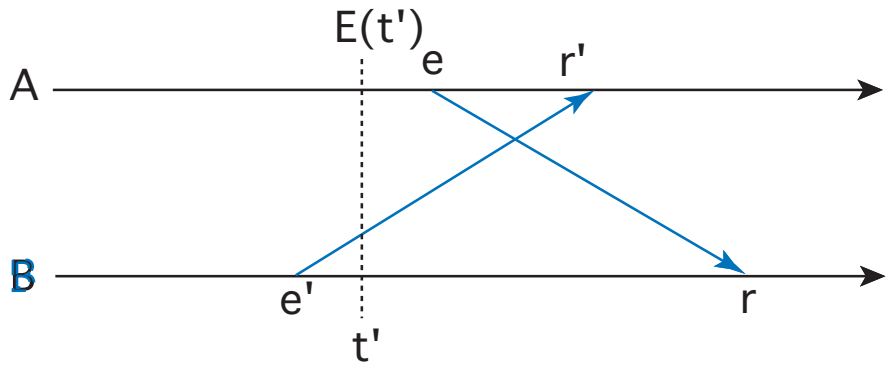

Treillis des coupures (cohérentes)

Treillis des coupures

L'ensemble des coupures forme un treillis pour l'inclusion : si C_1 et C_2 sont deux coupures, alors $C_1 \cup C_2$ et $C_1 \cap C_2$ sont des coupures

Treillis des coupures cohérentes

L'ensemble des coupures cohérentes forme un treillis pour l'inclusion : si C_1 et C_2 sont deux coupures cohérentes, alors $C_1 \cup C_2$ et $C_1 \cap C_2$ sont des coupures cohérentes

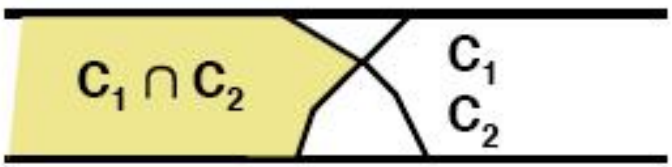

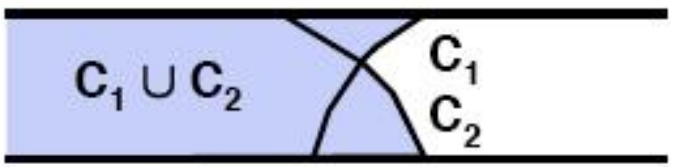

Treillis des coupures cohérentes

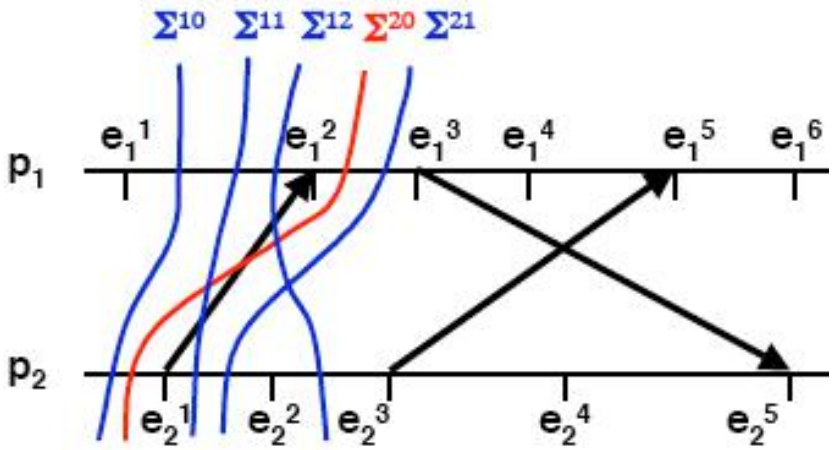

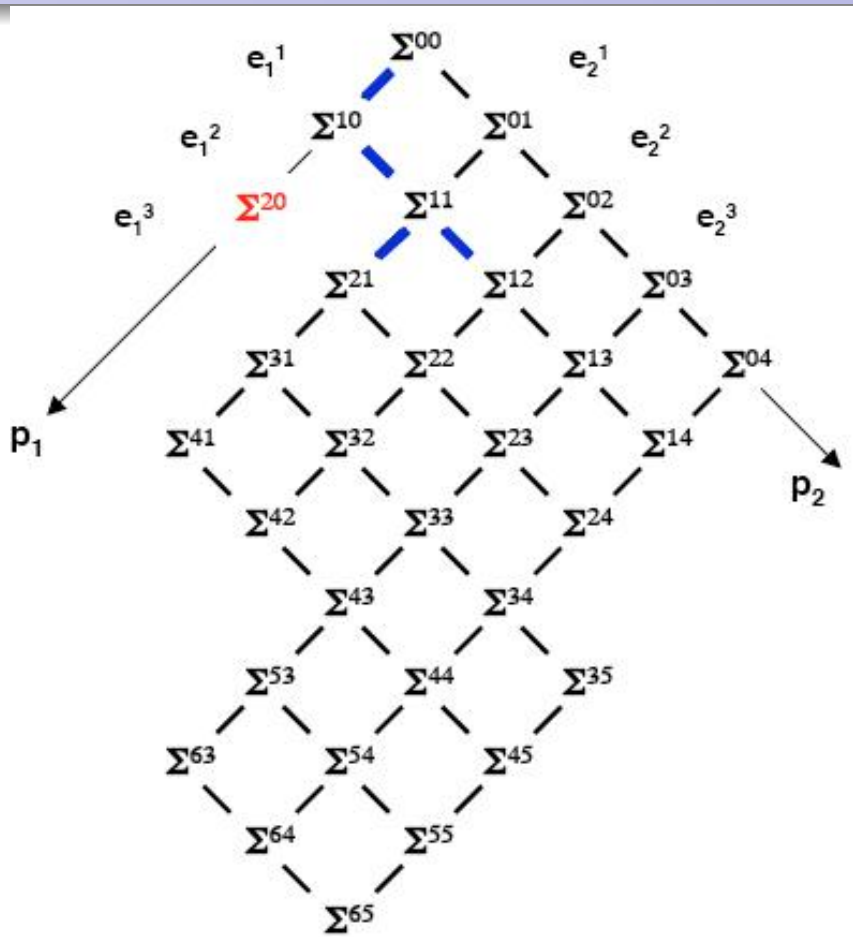

- Arc du treillis = occurrence d'un événement possible
- Une exécution = suite d'états globaux cohérents = chemin dans le treillis

Explosion du nombre d'exécutions causalement équivalentes

(dessins : cours S. Krakowiak)

Treillis des coupures cohérentes

Autre exemple

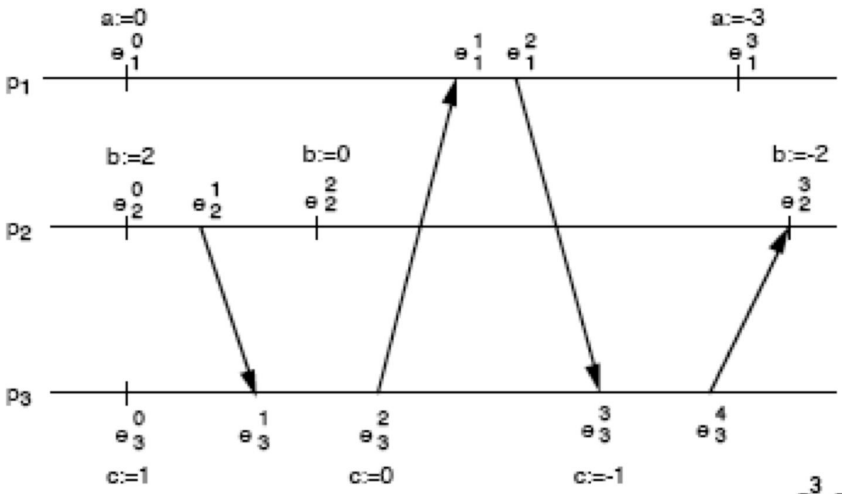

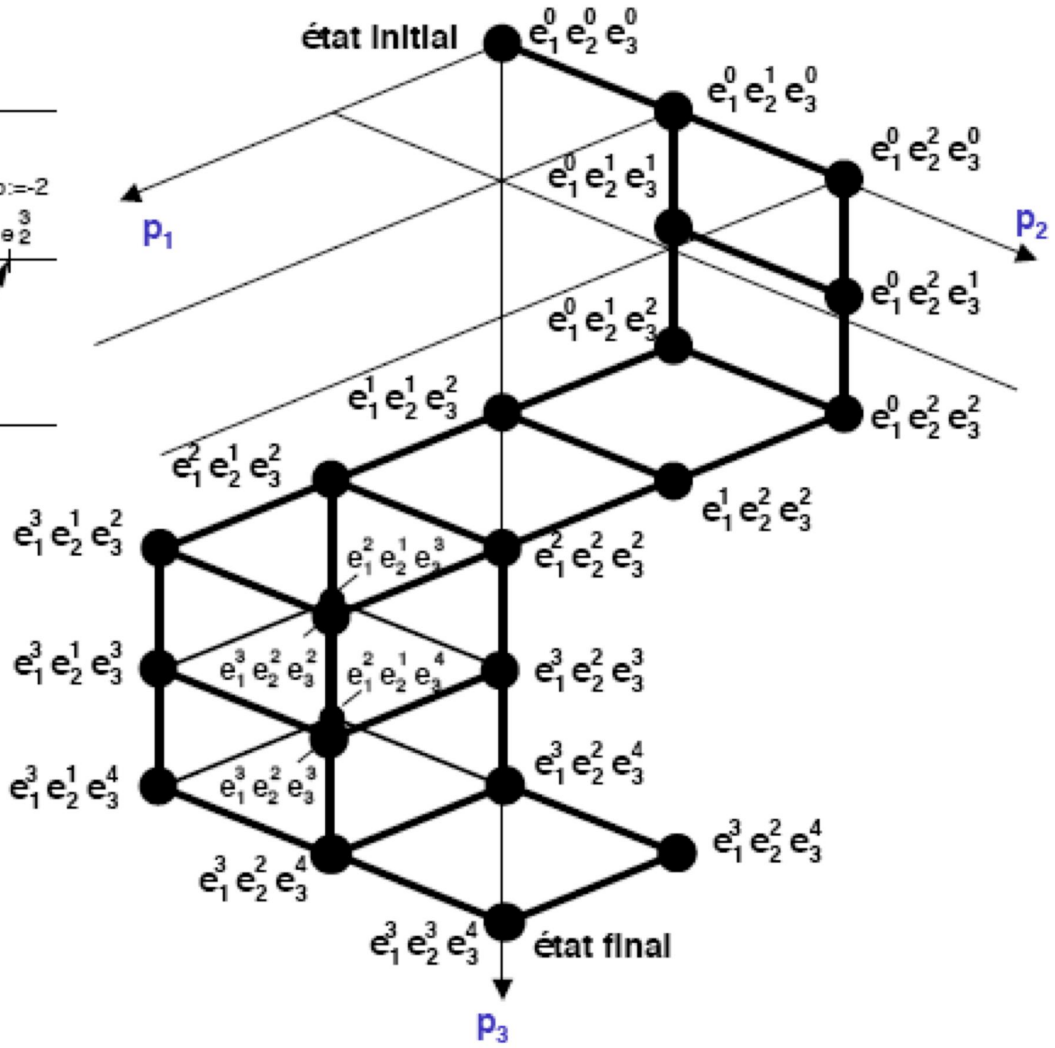

(dessin : cours S. Krakowiak)

Prise de cliché (snapshot)

Définition

Objectif : Capter, centraliser un état global passé des processus

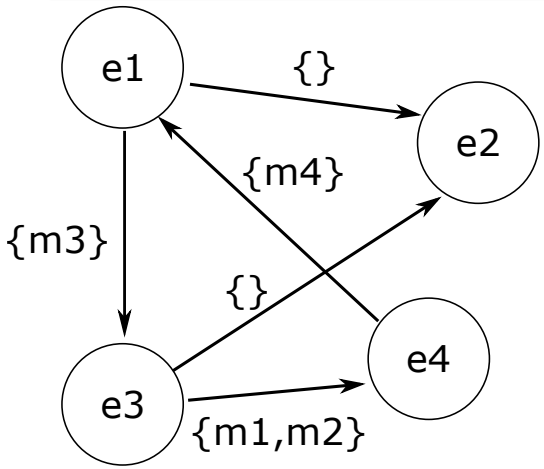

- Prise instantanée impossible
- Un site collecteur accumule
- Prise cohérente de clichés locaux
- Problème des messages en transit

Cliché global instantané

Clichés locaux + Messages en transit

$$\{e_1, e_2, e_3, e_4\} + \{m_1, m_2, m_3, m_4\}$$

Prise de cliché (snapshot)

Schéma temporel de la prise de cliché

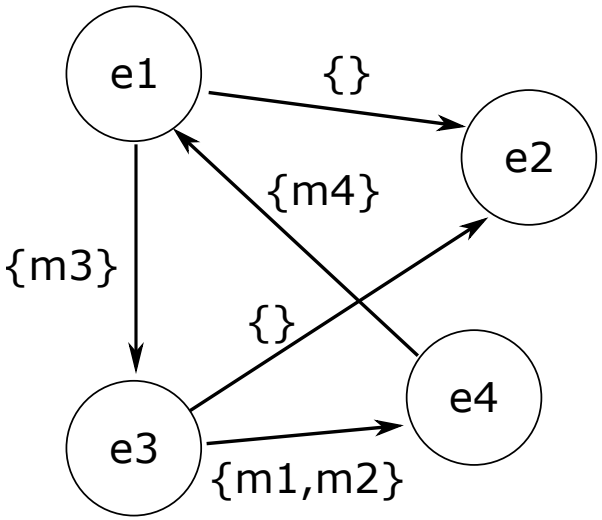

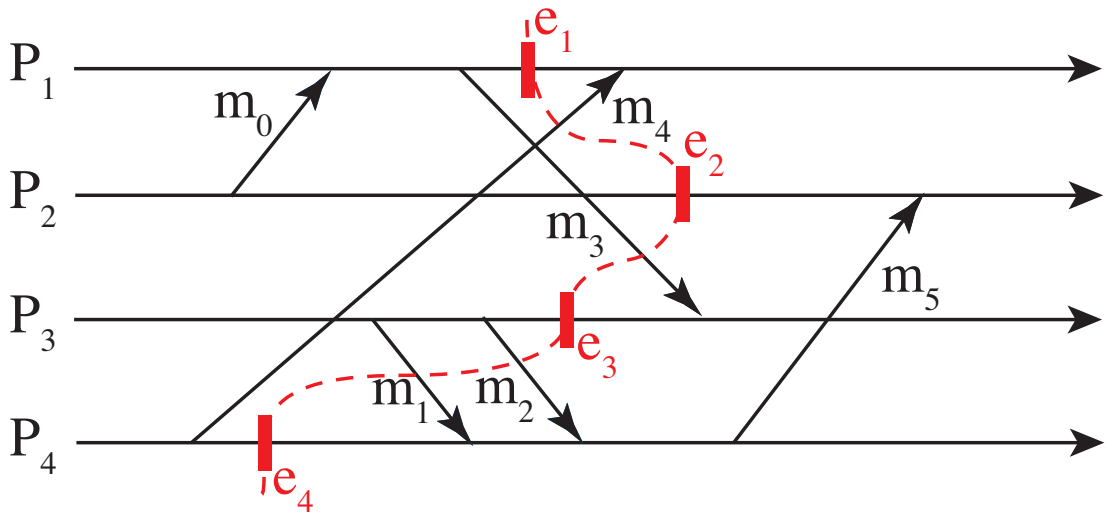

Algorithme de Chandy-Lamport (1985)

- Un système existant échange des messages ;
- On superpose des échanges de messages dédiés pour déclencher des actions locales de sauvegarde de l'état d'un site (= un cliché local + des messages reçus) ;
- Ces états sauvegardés sont collectés pour construire un cliché global.

1. *Distributed Snapshots : Determining Global States of Distributed Systems*, K. Mani Chandy and Leslie Lamport. ACM Transactions on Computer Systems, Feb. 1985

Algorithme de Chandy-Lamport (1985)

Idée

- Matérialiser la coupe par la circulation d'un marqueur visitant les sites
- Les messages émis après le passage du marqueur ne peuvent pas être dans la coupe
- Les messages émis par S_j avant le passage du marqueur sur S_j, et reçus par S_i après le passage du marqueur sur S_i, sont considérés comme les messages en transit de S_j vers S_i

Hypothèse

Canaux FIFO (pas de perte, pas de dépassement)

Algorithme de Chandy-Lamport (1985)

Hypothèses

- Réseau fortement connexe ($\forall s, s' : \exists s \rightarrow^* s'$)
- Canaux unidirectionnels et fifo :
  $\forall s$, $Rc(s)$: canaux en réception
  $Em(s)$: canaux en émission

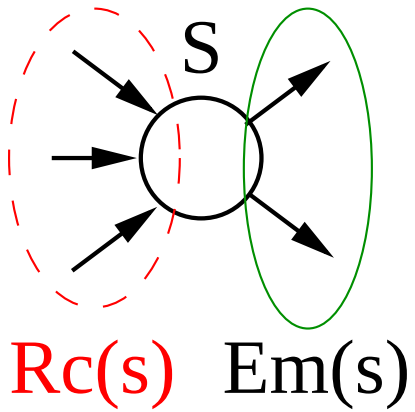

Principes de l'algorithme

- Utilisation de messages marqueurs
- Répartition de l'évaluation : chaque site s évalue :
  - son cliché local ;
  - les messages considérés en transit sur ses canaux en réception $Rc(s)$

Algorithme de Chandy-Lamport

Comportement d'un site

Sur réception d'un PREMIER marqueur ou spontanément :

1. Prendre son cliché local L_s et émettre un marqueur sur chaque canal d'émission $c \in Em(s)$
2. Enregistrer dans une liste $enTransit[c]$ les messages reçus sur chaque canal de réception $c \in Rc(s)$ jusqu'à la réception d'un marqueur sur ce canal
3. Lorsqu'un marqueur a été reçu sur TOUS les canaux de réception, communiquer au collecteur cet état partiel :

$$\langle L_s, \{enTransit[c] \mid c \in Rc(s)\}\rangle$$

Prise de clichés locaux et marqueurs

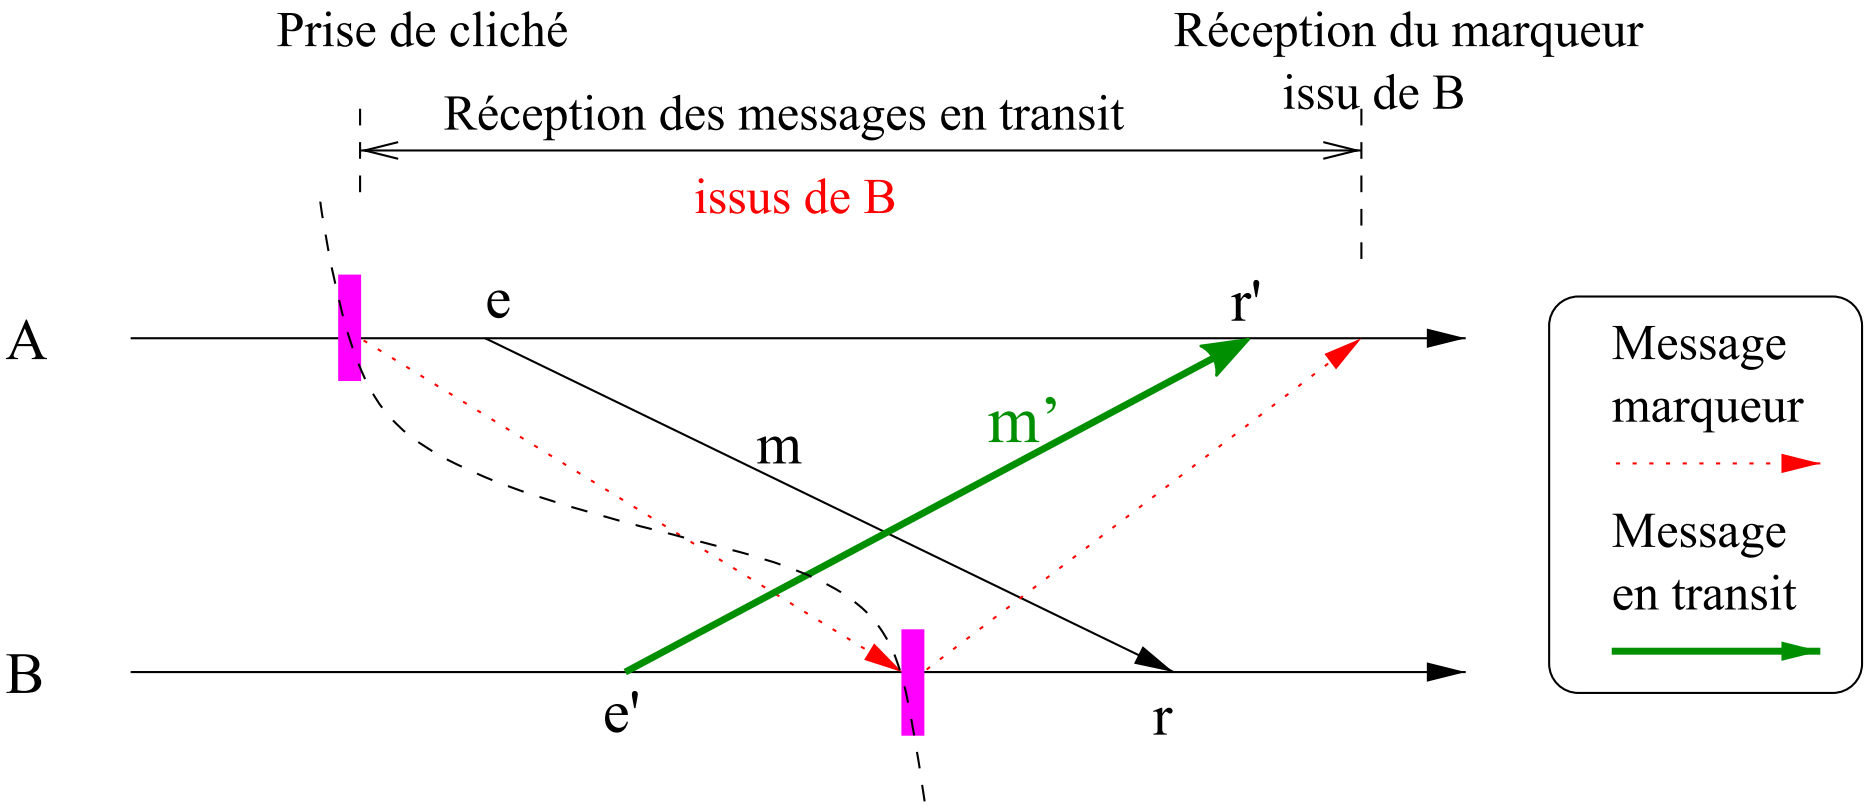

Première arrivée du marqueur => prise de cliché local

Vérifier la correction...

Propriétés

- Sûreté
  - Coupure cohérente
  - Collecte complète des messages en transit
- Vivacité
  - Tout site finit par prendre un cliché local
  - Un marqueur finit par arriver sur chaque canal de réception

Exemple

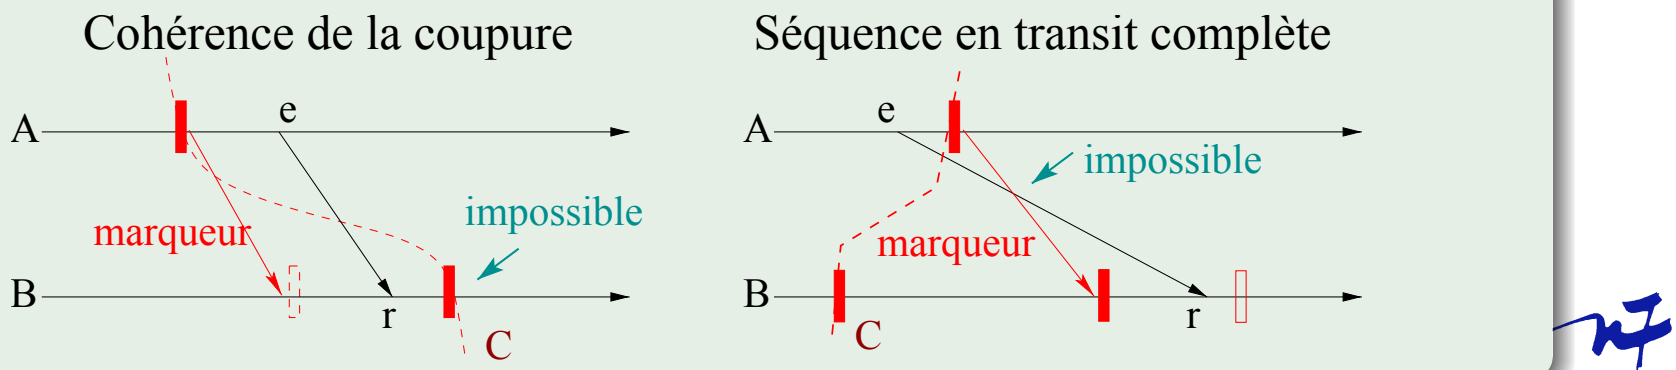

État enregistré = état *possible*

État enregistré

- Σ_{enreg} = cliché enregistré
- Σ_{init} = coupure cohérente contenant l'événement déclencheur du cliché
- Σ_{final} = coupure cohérente dans lequel le protocole de prise de cliché est terminé

Alors $\Sigma_{init} \prec \Sigma_{enreg} \prec \Sigma_{final}$

(il existe un chemin de Σ_{init} à Σ_{final} passant par Σ_{enreg} dans le treillis des coupures cohérentes)

Exemple : sur le treillis page 17, si $\Sigma_{init} = \Sigma^{11}$ et $\Sigma_{final} = \Sigma^{32}$, Σ_{enreg} peut être Σ^{11}, Σ^{21}, Σ^{12}, Σ^{31}, Σ^{22} ou Σ^{32}, et a pu ne pas être traversé dans la réalité.

Utilisation du cliché : propriété stable

Prédicat stable

Un prédicat P sur un état global E d'un système est stable ssi
$\forall E' : E \prec E' \wedge P(E) \Rightarrow P(E')$

(exemples : le calcul est terminé, il y a eu 10 messages reçus. . .)

Vérification de P

Si P est un prédicat stable alors :

- $P(\Sigma_{enreg}) \Rightarrow P(\Sigma_{final})$ (et tout état ultérieur)
- $\neg P(\Sigma_{enreg}) \Rightarrow \neg P(\Sigma_{init})$ (et tout état antérieur)

Utilisation du cliché : propriété possible/certaine

Prédicat possible/certain

Pour un prédicat P :

- $Pos(P)$ (possibly P) : il existe une observation cohérente (= un chemin dans le treillis) qui passe par un état où P est vrai.
- $Def(P)$ (definitely P) : toutes les observations cohérentes (= tous les chemins) passent par un état où P est vrai.

Vérification

- $P(\Sigma_{enreg}) \Rightarrow Pos(P)$ mais pas l'inverse...
- $\neg Pos(P) \Rightarrow Def(\neg P)$ mais pas l'inverse...

Exemple de vérification de propriétés

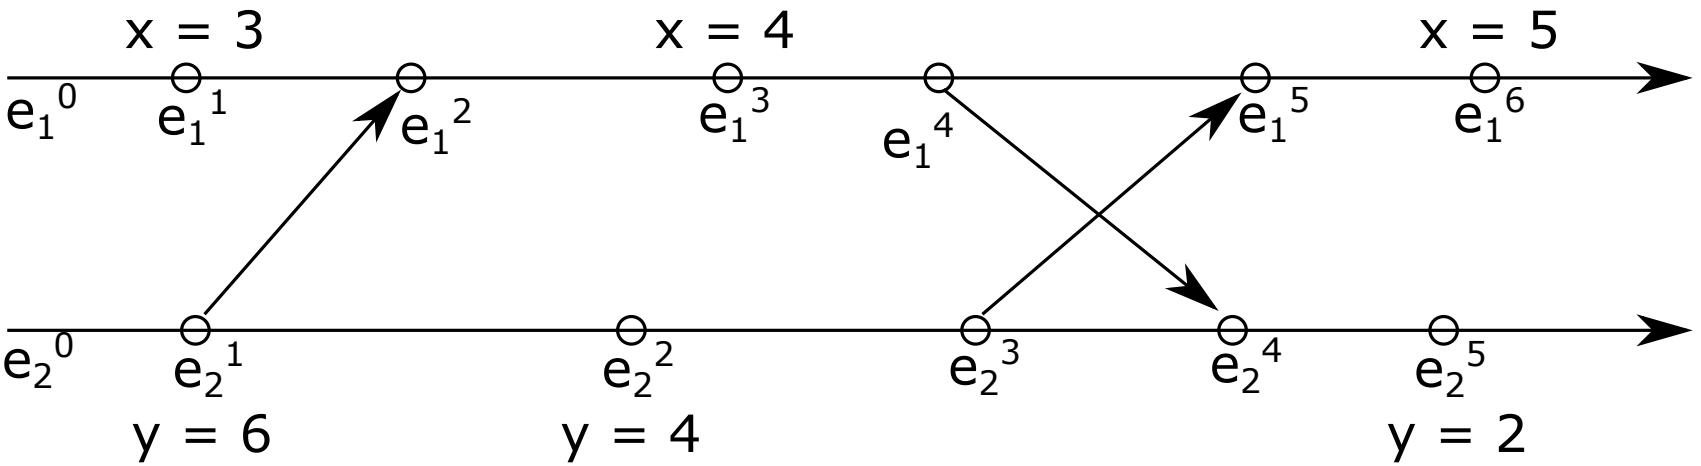

- $x - y \geq 0$?
  (en supposant x croissant, y décroissant $\Rightarrow$ propriété stable)
- $Pos(x = y - 2)$?
- $Def(x = y)$?

(d'après Lorenzo Alvisi)

Exemple de vérification

Propriété stable

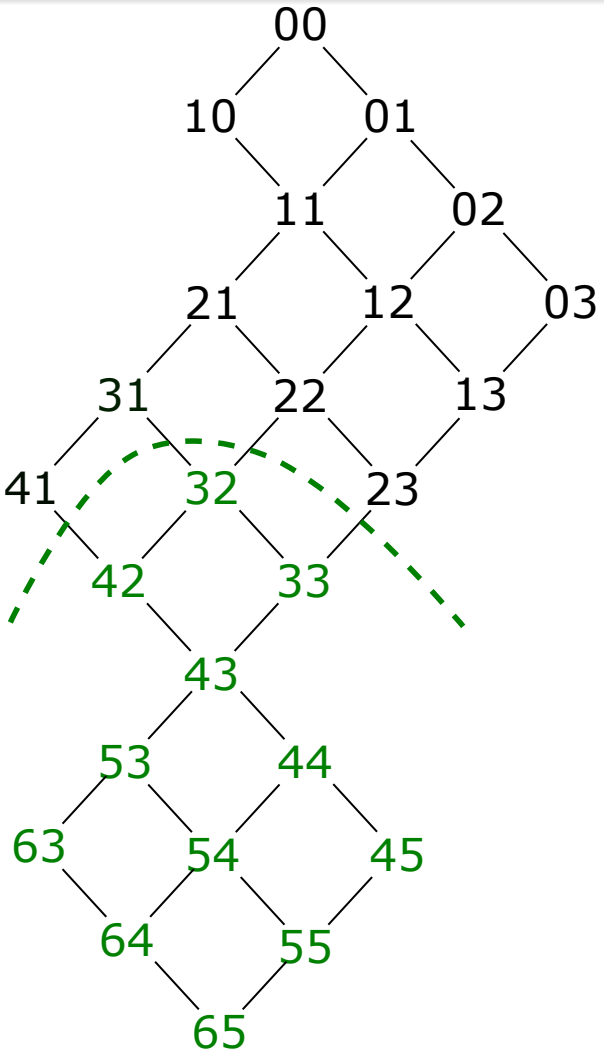

- $x - y \geq 4$?
  (sous l'hypothèse $x \uparrow$, $y \downarrow$)
- N'importe quel cliché Σ_{enreg} obtenu après Σ^{32} permet de le vérifier

Exemple de vérification
Possibilité

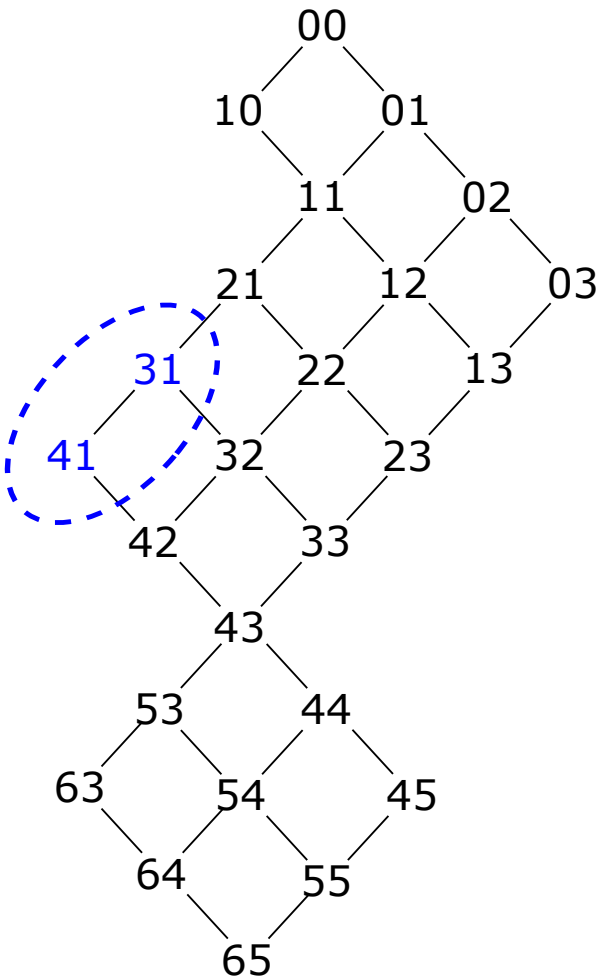

- $Pos(x = y - 2)$?
- $x = y - 2$ est vrai dans les états cohérents Σ^{31} et Σ^{41}
- Détecté uniquement si $\Sigma_{enreg} \in \{\Sigma^{31}, \Sigma^{41}\}$
- Σ_{enreg} pas nécessairement survenu dans la réalité

Exemple de vérification
Certitude

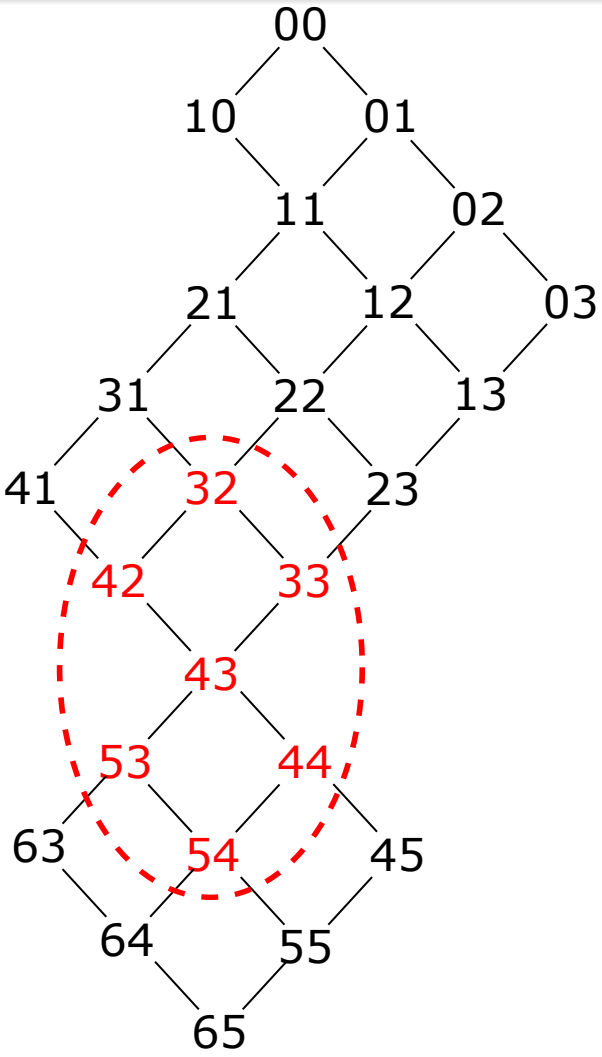

- $Def(x = y)$?
- Vrai
- $Pos(x = y)$ pas détecté si on capture un état antérieur à Σ^{32} ou postérieur à Σ^{54}
- La capture d'un état (p.e. Σ^{42}) ne permet pas de conclure

Utilisation du cliché : propriété possible/certaine

Principe de la vérification

- Un processus moniteur M collecte tous les états locaux
- M construit le treillis des coupures cohérentes (à partir d'un codage complet de la relation de causalité, cf chapitre suivant)
- Pour évaluer $Pos(P)$: parcourir le treillis depuis l'état initial, niveau par niveau, et s'arrêter au premier état où P est vrai. Aucun état $\Rightarrow \neg Pos(P)$.
- Pour évaluer $Def(P)$: parcourir le treillis depuis l'état initial, niveau par niveau, en ne développant que les états vérifiant $\neg P$. Si plus d'état, alors $Def(P)$; si état final atteint (et $\neg P$ dans cet état) alors $\neg Def(P)$.
- Explosion combinatoire : pour N sites ayant chacun au plus m états, possiblement m^N coupures cohérentes.

Plan

1 Le modèle standard
- Approche événementielle
- Causalité
- Abstraction d'un calcul
- Prise de cliché

2 Description des algorithmes
- Description du comportement des processus
- Exemple : l'élection

Principes algorithmiques

- Algorithmes symétriques
  - code répliqué,
  - données initiales propres : identité, voisinage de communication.
- Structurer les échanges de messages :
  - Utilisation de réseaux en anneau
  - Utilisation de la structure d'arbre
- Étudier des problèmes génériques :
  - Les services : datation, exclusion mutuelle, consensus, élection...
  - Les observations de propriétés stables : terminaison, interblocage
  - La tolérance aux fautes : réplication, atomicité

Description des algorithmes

```
Process  P(id : 0..N-1)
  <variables locales>
  on  <condition-logique> :
     <Action>
  on  reception message(arg) [ from P(j) ] :
     <Action>
  on  <condition-logique> ∧ reception message(arg) :
     <Action>
  on start :   // initialement
     <Action>
  ...
```

- Action : modification des variables locales et/ou envoi(s) de message, ou terminaison (terminate)
- Envoi : `send Msg(<args>) to <destinataire(s)>`
- Choix d'un événement à traiter : non déterministe parmi ceux ayant la garde vraie et un message à consommer

Exemple : l'élection

Le problème de l'élection

Objectif : Élire un seul processus

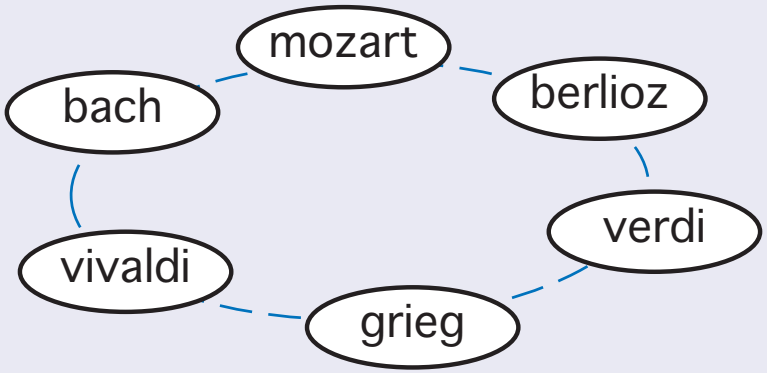

- Un processus a une identité unique qu'il connaît
- Un processus ne connaît pas le nombre global de processus
- Un processus ne connaît pas l'identité des autres
- Communication sur un anneau logique

1. *An improved algorithm for decentralized extrema-finding in circular configurations of processes*, Ernest Chang and Rosemary Roberts. Communications of the ACM, May 1979.

Solution correcte ou fausse ?

On suppose que les processus sont totalement ordonnés (ici par leur indice, en pratique, par leur adresse IP par exemple)

```
Process P(id : 0..N-1)
  //  ⊖ et ⊕ : opérateurs modulo N
  type Etat = {candidat,élu};
  Etat étatCourant ← candidat;
  on reception Candidat(proc) from P[id⊖1] :
      if (proc < id) send Candidat(proc) to P[id⊕1];
      else if (proc = id) étatCourant ← élu;
      else nop;   // ignorer le message
  on (étatCourant = élu) :
      terminate;
```

Pourquoi cela ne marche-t-il pas ?

Solution qui conduit à l'élection du plus petit

```
Process P(id : 0..N-1)
  type Etat = {candidat,élu};
  Etat étatCourant ← candidat;
  on start:
      send Candidat(id) to P[id⊕1]; // chacun candidate
  on reception Candidat(proc) from P[id⊖1]:
      if (proc < id) send Candidat(proc) to P[id⊕1];
      else if (proc = id) étatCourant ← élu;
      else nop;  // ignorer le message
  on (étatCourant = élu) :
      terminate;
```

Pas parfait : un seul processus se termine

Solution plus complète : tous les processus terminent

```
Process P(id :0..N-1) {
  type Etat = {candidat,élu,perdant};
  Etat étatCourant ← candidat;
  on start :
     send Candidat(id) to P[id⊕1]; // chacun candidate
  on reception Candidat(proc) from P[id⊖1]:
      if (proc < id) send Candidat(proc) to P[id⊕1];
      else if (proc = id) étatCourant ← élu;
      else nop;  // ignorer le message
  on (étatCourant = élu) :
     send Elu(id) to P[id⊕1];
  on reception Elu(proc) from P[id⊖1]:
     if (proc ≠ id) then
           étatCourant ← perdant;
           send Elu(proc) to P[id⊕1];
     endif
     terminate
```

Déclenchement spontané individuel

Pas nécessairement tous candidats au départ (mais tous éligibles)

```
Process P(id : 0..N-1)
  type Etat = {candidat,élu,perdant};
  Etat étatCourant ← candidat;
  on random() :
       send Candidat(id) to P[id⊕1];
  on reception Candidat(proc) from P[id⊖1]:
       if (proc < id) send Candidat(proc) to P[id⊕1];
       else if (proc = id) étatCourant ← élu;
       else if (proc > id) send Candidat(id) to P[id⊕1];
  ⋮
```

Conclusion

- Modélisation par des événements locaux
- Relation entre ces événements, en particulier la causalité
- Représentation avec des chronogrammes
- Notion d'état global, de coupure
- Calcul d'un état global