Systèmes et algorithmes répartis

Simulation répartie

Gérard Padiou, Philippe Quéinnec

Département Informatique et Mathématiques Appliquées
ENSEEIHT

29 août 2017

plan

Plan

Simulation

Simulation à événement discret (DES)

- Simulation basée sur des événements
- Exécution au plus vite
- Analyse de systèmes, du futur
- Domaine : réseaux, système de transport, système de fabrication

Simulation d'environnement virtuel

- Environnement interactif
- Simulation temps réel
- Domaine : apprentissage, jeux

Simulation répartie

Objectif : Simulation exploitant des architectures réparties

- Plusieurs simulateurs peuvent communiquer, coopérer
- Exploiter le parallélisme offert par l'architecture
- Difficulté : coût des communications et synchronisation des simulateurs

Quel heure est-il ?

Trois référentiels temporels

- Temps physique : temps dans le système physique que l'on simule
- Temps de la simulation : représentation du temps physique dans la simulation (offset par rapport au début de la simulation)
- Temps externe (*wallclock time*) : temps au cours duquel a lieu l'exécution de la simulation

Avancement du temps

- Temps externe : autonome
- Temps de la simulation : par le(s) simulateur(s).
  Identique au temps externe (jeu), proportionnel au temps externe, ou le plus vite possible.
- Temps physique : par correspondance avec la simulation

Hypothèses générales

- Simulation à événements : chaque événement est daté dans un temps global propre à la simulation ($\Rightarrow$ horloge)
- Ordre total sur les événements (simultanéité possible)
- Variables d'états globales des entités simulées
- Principes proches d'un calcul diffusant :
  - Étape initiale produisant un ou plusieurs événements
  - Chaque événement entraîne un traitement
  - Chaque traitement peut engendrer de nouveaux événements
  - Tout nouvel événement est futur
- Terminaison : l'horloge de la simulation avance jusqu'à :
  - soit plus d'événement à traiter
  - soit au bout d'une durée fixée

Un exemple : simulation de trafic aérien

Exemple

- Variables d'état : les vols
- Traitements :
  - Planification périodique des vols (toutes les x minutes)
  - Envol et Atterrissage
- Événements significatifs :
  - Date de planification
  - Décollage
  - Atterrissage
- Événement datés dans un temps global
- Terminaison : Simulation d'une journée de trafic

Algorithme centralisé

Structures de données

- Les variables d'états
- Une file ordonnée des événements à traiter $E = \langle e_1, e_2, \ldots \rangle$
- Ordre total des événements $\equiv$ Datation
$$\forall e_i, e_j \in E : d(e_i) \leq d(e_j) \vee d(e_j) \leq d(e_i)$$
- La date courante $\equiv$ date du dernier événement traité
- Prochain événement à traiter $\equiv$ tête de la file E
- $step(e) \stackrel{\Delta}{=}$ traitement de e + événements engendrés

Hypothèse

- Une étape ne produit que des événements futurs
$$\forall e \in E : \forall e' \in step(e) = \{e_1, \ldots, e_p\} :: d(e) < d(e')$$
- Mais : $\forall e, e' \in E \; d(e) < d(e') \not\Rightarrow step(e)$ *before* $step(e')$

Algorithme centralisé

```
// Étapes de traitement
Set<Event> initial_step() {... }
Set<Event> step(Event e) {... }
process Simulation { // Processus de simulation
  Date debut = new Date();
  Date hc = debut;
  Date fin = new Date(debut.getTime()+durée);
  SortedSet<Event> EVL = initial_step();    // triée par date
  while (!EVL.isEmpty()) {
    Event next = EVL.first();
    hc = next.getDate();
    if (hc.after(fin)) exit;
    EVL.addAll(step(next));
    EVL.remove(next);
  }
  // Enregistrer les résultats
}
```

Répartition d'une simulation

Coopération de plusieurs simulateurs

Deux contextes possibles :

- par partitionnement des traitements : tous participent aux mêmes tâches mais interagissent
  $\Rightarrow$ Plusieurs simulateurs : chacun simule un aéroport
- par complémentarité : simulations dédiées qui se complètent
  $\Rightarrow$ Un simulateur de trafic et un simulateur météo

Cohérence globale de la simulation

- Chaque simulateur a une date courante
- Comment assurer une synchronisation des simulateurs ?

Le problème de la synchronisation des simulateurs

Une tentative : un état possible . . .

Exemple

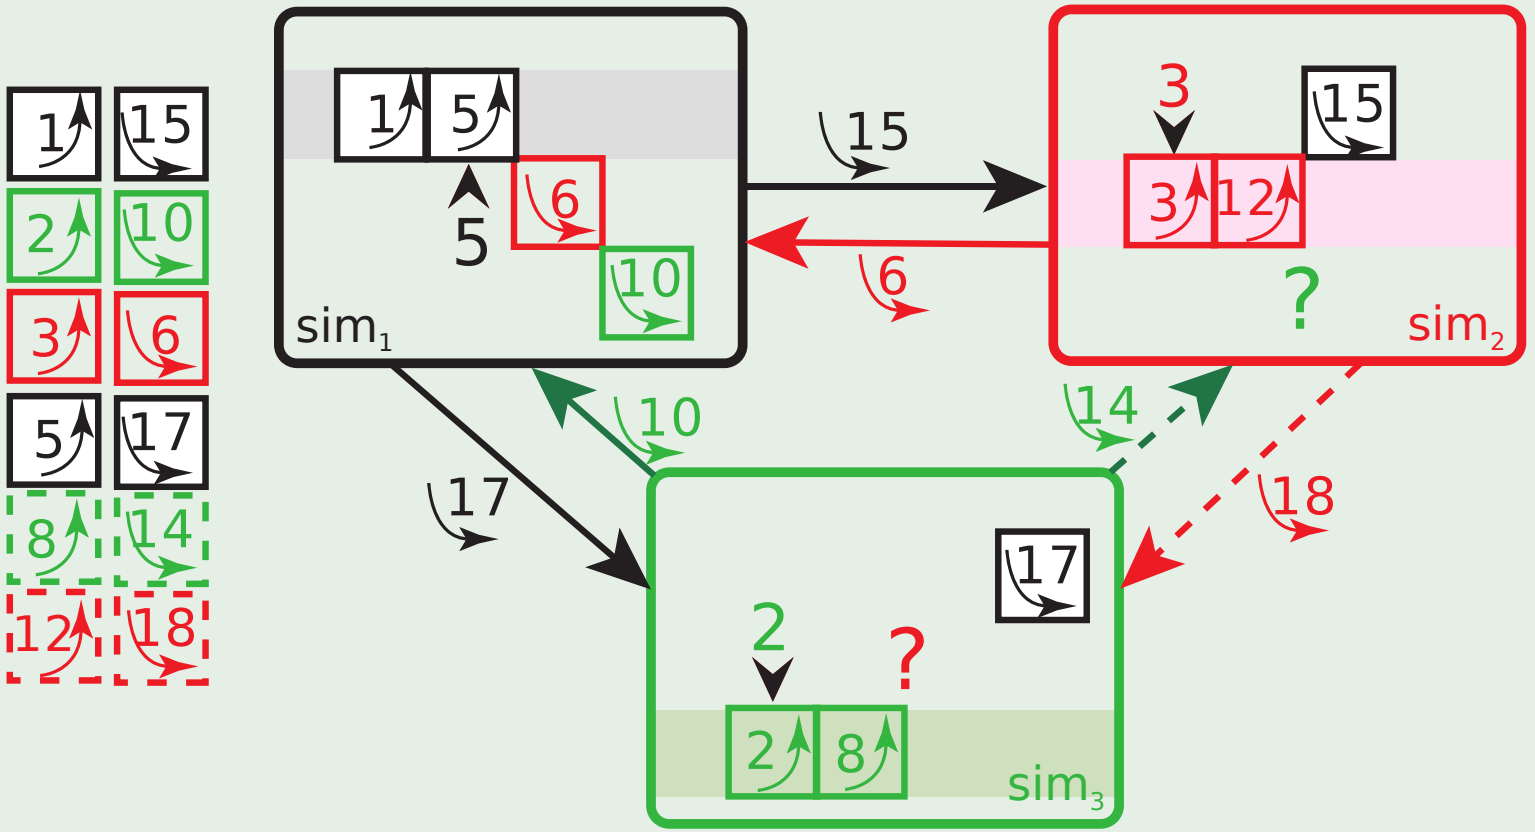

(hypothèse : chaque simulation d'aéroport commence par un envol)

Le problème de la synchronisation des simulateurs

Point de vue temporel

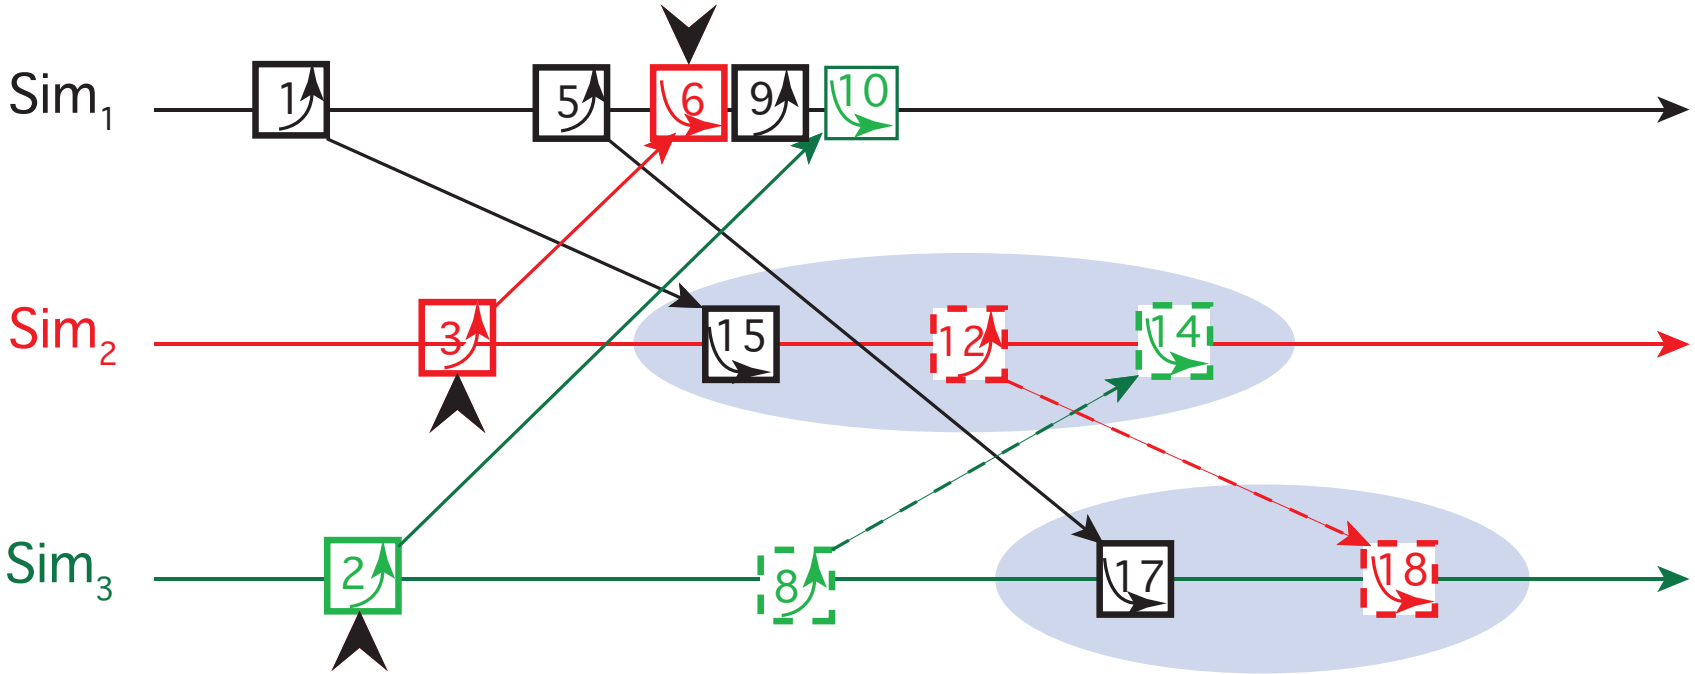

- Le simulateur 1 peut avancer de 1 à 6 dès qu'il connaît les événements d'arrivée issus des simulateurs 2 et 3
- Sim_2 ne connaît pas le prochain événement issu de Sim_3
- Sim_3 ne connaît pas le prochain événement issu de Sim_2

Critère de synchronisation

Contrainte locale

Sur chaque simulateur, les événements doivent être traités par ordre croissant de leur estampille temporelle

Cette propriété suffit à ce que la simulation distribuée soit équivalente à une simulation centralisée

Principes

- Chaque simulateur a son horloge (sa date) courante
- Chaque simulateur doit savoir où en sont les autres
  - Éviter les oublis, les retours en arrière
  - Éviter l'interblocage

Deux approches

- Pessimiste : garantir le respect de la contrainte, attendre qu'il soit sûr d'avancer
- Optimiste : laisser faire et revenir en arrière si nécessaire

Approche pessimiste

Critère d'avancement

Soit un simulateur s avec une suite ordonnée d'événements non traités locaux ou issus des autres simulateurs :

$$E^s = \langle e_1, e_2, e_3, \ldots \rangle \text{ avec } d(e_1) \leq d(e_2) \leq d(e_3), \ldots$$

On note $sim(e_i)$ le numéro du simulateur origine de l'événement e_i. L'horloge locale du simulateur s peut être incrémentée pour traiter l'événement de tête e_1 de la liste E^s ssi :

$$\forall s' \in \mathcal{S} : \exists e_i \in E^s : sim(e_i) = s'$$

$\equiv \exists$ dans E^s un événement issu de chaque simulateur participant

Hypothèse

Hypothèse

- configuration statique, pas de création dynamique de simulateur
- réseau fiable, FIFO

$\Rightarrow$ l'estampille du dernier message reçu depuis un simulateur est une borne inférieure (LBTS *lower bound on time stamp*) des messages ultérieurement reçus depuis ce même simulateur

Le risque d'interblocage

Exemple

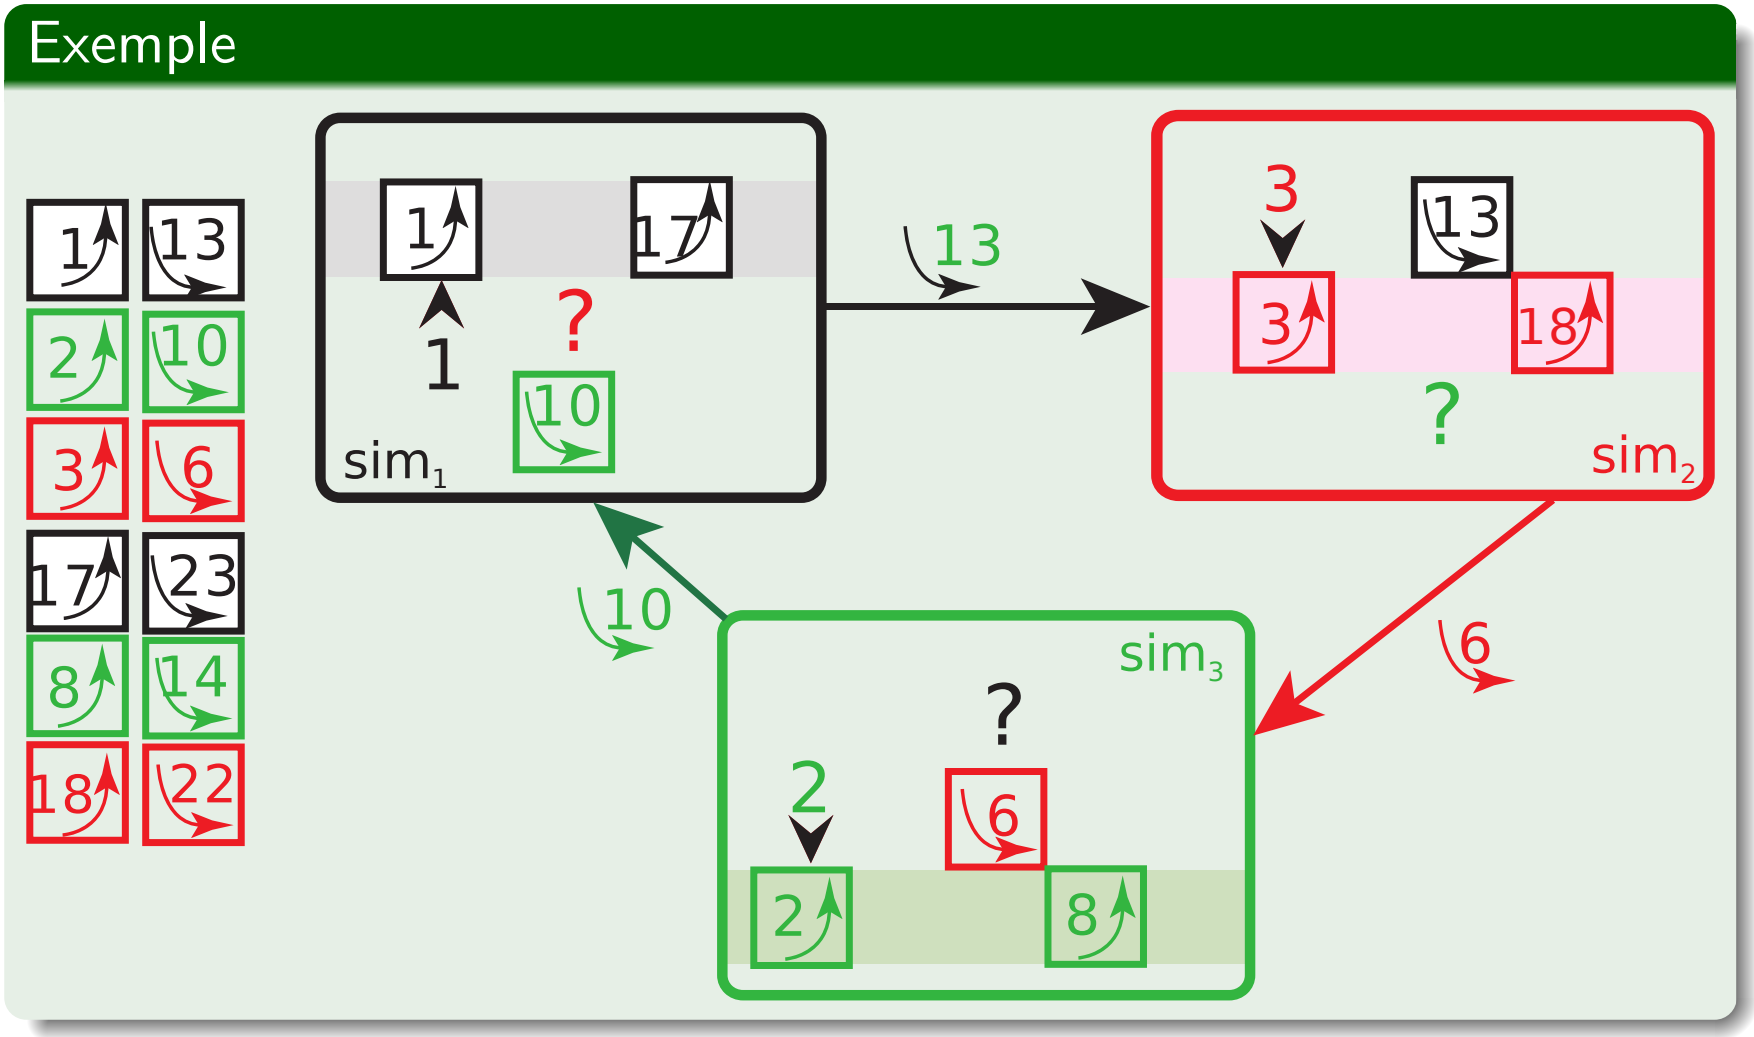

Le risque d'interblocage

L'idée d'anticipation (lookahead)

Exemple

Les simulateurs sim_2 et sim_3 s'échangent jusqu'à quand ils ne produiront pas de nouvel événement → débloque sim_3

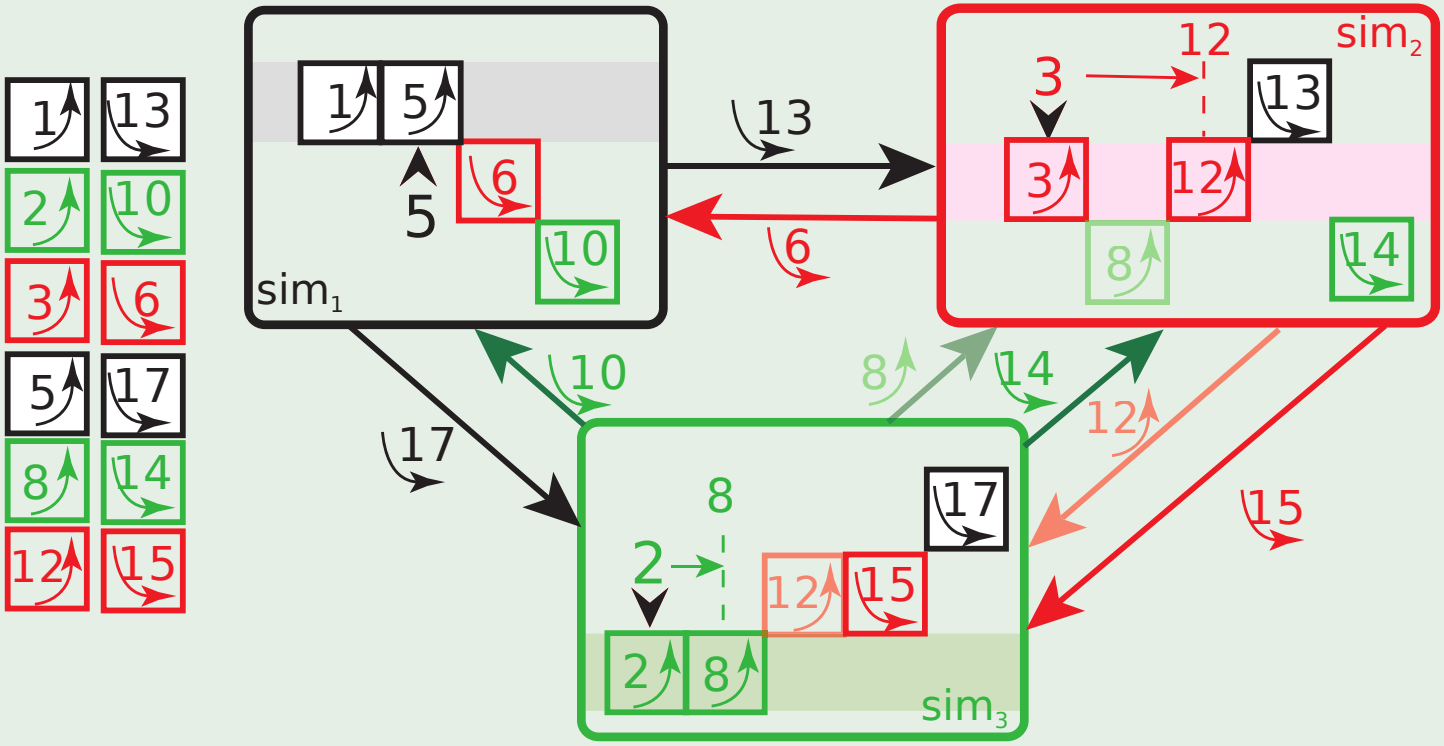

Principe d'un algorithme réparti

Usage de files ordonnées d'événements issus de chaque simulateur

```
Process Simulation[s : 1..N] {
 // Files ordonnées d'évts issus de chaque simulateur
 SortedSet<Event> E[1..N] = new SortedSet<Event>[N];
 for (int i=1; i<=N; i++) E[i] = new SortedSet<Event>();
 E[s].addAll(initial_step());
 while (true) {
  int ss = attendre_critere(E);  // choix de la file
  Event next = E[ss].first(); hc = next.getDate();
  if (hc.after(fin)) exit;
  for (Event e : step(next)) // événements futurs
    if (sim(e)==s) E[s].add(e) else send(e,sim(e));
  E[ss].remove(next);
 } // while
}
```

Principe d'un algorithme réparti (suite)

```
// renvoie le n° de la file du prochain évt à traiter
int attendre_critere(SortedSet<Event>[] E) {
  boolean vide = true; // au moins l'un des E[s] est-il vide ?
  while (vide) { // risque de boucle infinie → deadlock
    vide = false;
    for (int s=1; s <= N; s++)
         vide = vide || E[s].isEmpty();
  }
  Date min = E[N].getDate();
  int smin = N;
  for (int s=1; s < N; s++)) {
    if (E[s].first().getDate().before(min)) {
        smin = s;
        min = E[s].first().getDate();
    }
  }
  return smin;
}
```

Algorithme évitant l'interblocage (Chandy-Misra-Bryant)

Introduction de messages vides

- Lookahead (anticipation) : durée du prochain intervalle sans événement local nouveau
- Utilisation de messages vides datés par :

  date courante + lookahead
- Deux possibilités de propagation
  - Par diffusion de messages vides datés après chaque traitement
  - Sur demande explicite d'un simulateur ayant une file vide

Évitement de l'interblocage par message nul

```
loop {
  int ss = attendre_critere(E);
  Event next = E[ss].first();
  for (Event e : step(next)) // événements futurs
      if (sim(e)==s) E[s].add(e) else send(e,sim(e));
  E[ss].remove(next);

  for (int s=1; s <= N; s++) {
     int lookahead = borne_inf_du_prochain_evt_local;
     int h = current_time + lookahead;
     send(null(h), s);
  }
}
```

Limitations de l'algorithme

Résolution de l'interblocage par message vide

- Estimation du lookahead ? (délai minimal entre 2 sites)
- Possibilité de chaînes de messages vides

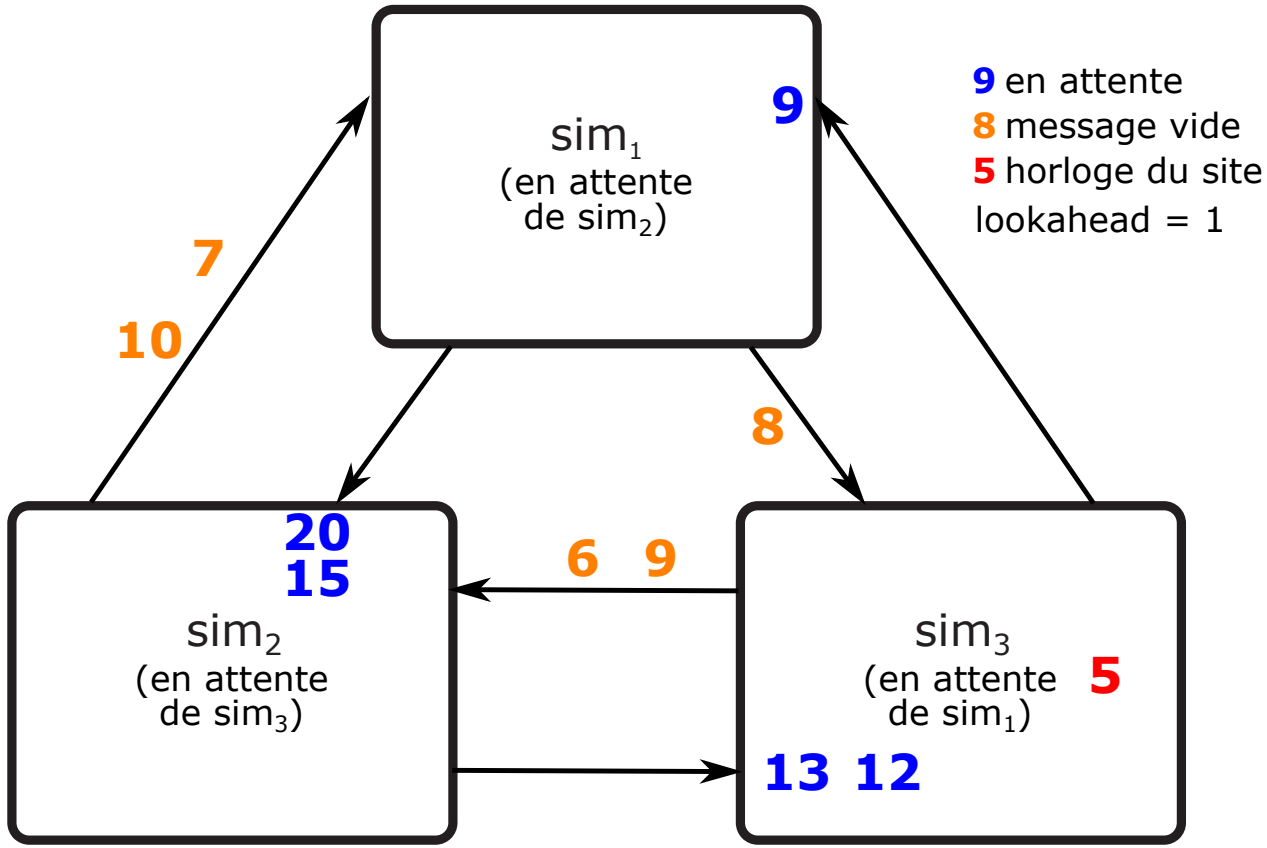

Amélioration 1 : correction de l'interblocage

Observation

Si tous les simulateurs sont bloqués (interblocage), ils peuvent immédiatement avancer à la date du plus proche événement du système.

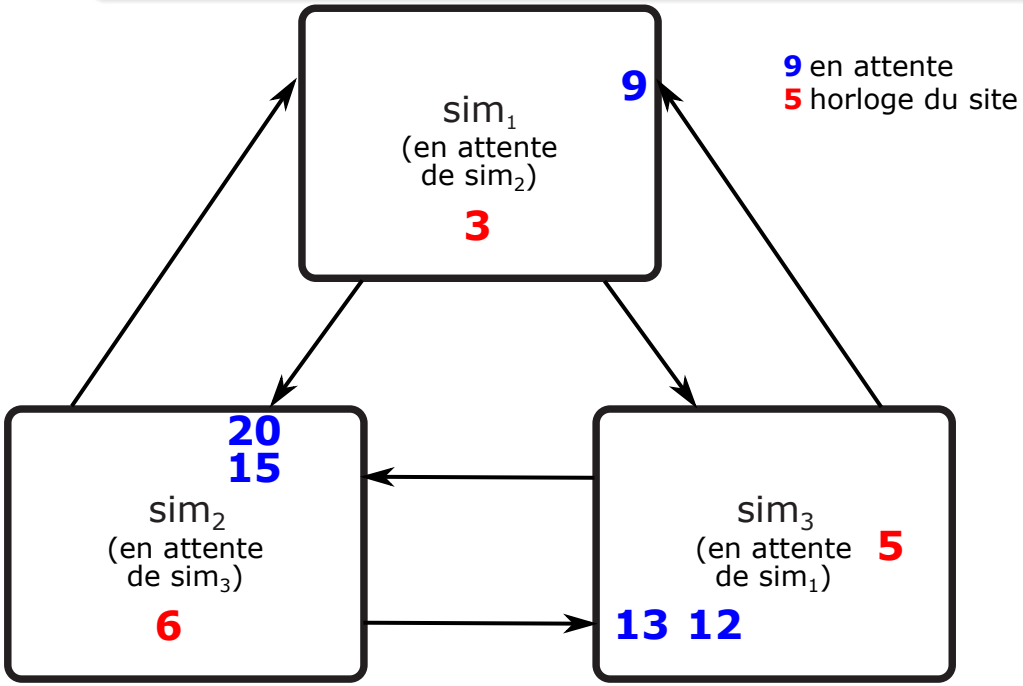

Tous peuvent passer à 9.

Solution

1. Détection de l'interblocage
2. Calcul du min (une vague)
3. Diffusion du min

Amélioration 2 : calcul du LBTS

LBTS = lower bound on time stamp = borne inférieure des messages ultérieurement reçus.
Tous les événements de date $<$ LBTS peuvent être traités.

Calcul du LBTS

Pour un cliché (snapshot / état global passé), le LBTS est le minimum de :

- des estampilles des messages en transit,
- pour les simulateurs non bloqués, de leur date courante (+ lookahead si connu)
- pour les simulateurs bloqués, de la date de leur prochain événement (+ lookahead si connu)

$\Rightarrow$ calcul asynchrone (en arrière-plan) du LBTS + diffusion du résultat

Plan

Réplication, temps réel et simulation

Contexte d'étude

- Domaine : simulation (jeux, réalité virtuelle)
- Réplication : problème de cohérence
- Deux méthodes complémentaires
  - Retard local (local lag)
  - Timewarp (≪ distorsion du temps ≫)
- Comparaison avec le dead reckoning (estimation)

d'après : Local Lag and Timewarp : providing consistency for replicated continuous applications, Martin Moore, Jürgen Vogel, Volker Hilt

Domaine : simulation d'un univers *actif*

Hypothèses

- Évolution continue dans le temps d'un état global répliqué
- État global vu par tous les participants
- Chaque opération d'un participant doit être diffusée aux autres
- Les opérations sont datées (horloges locales)

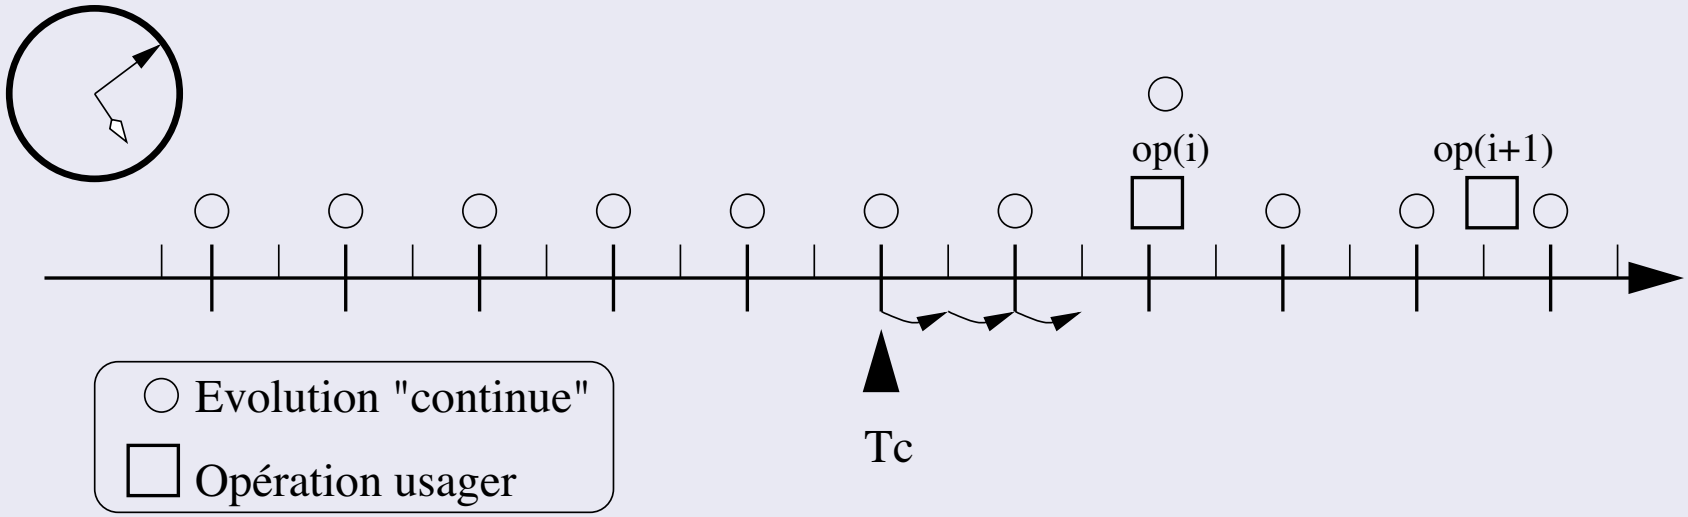

Mouvement continu et événement local

Idéal (impossible) : Opération connue instantanément par les autres

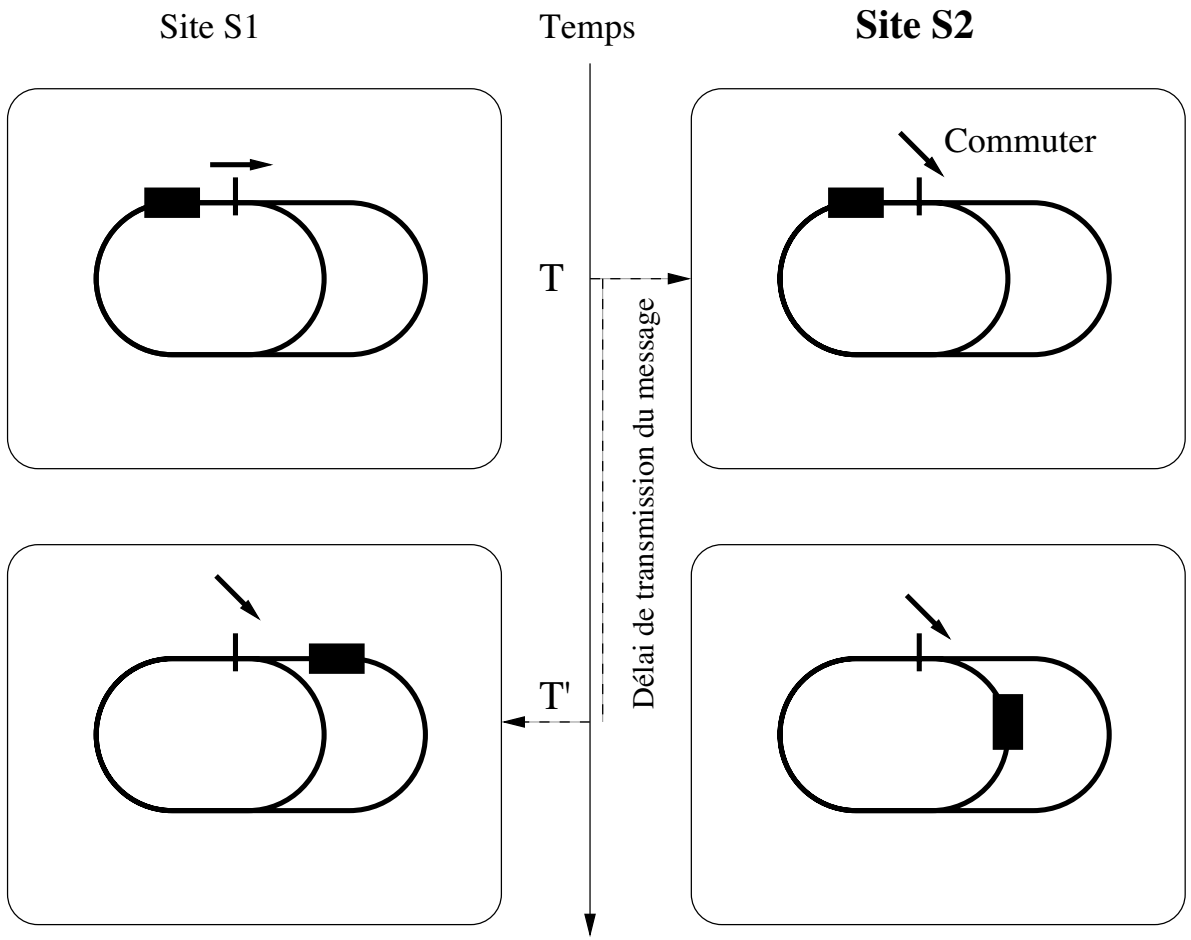

Technique de maintien de la cohérence

Principes de base

Datation des opérations par l'horloge locale du demandeur et synchronisation des horloges locales (réelles)

Problème : Corriger les incohérences dues à l'arrivée trop tardive d'une opération

- Réagir avec retard : notion de local lag
- Traiter par paquets et corriger si nécessaire : Timewarp
- Calculer le futur probable et corriger si besoin : Dead reckoning

Point clé : Compromis risque d'incohérence et temps de réponse

Critère de cohérence de l'état global répliqué

Principe

Toute opération est diffusée à tous les autres sites

Prédicat $R_i(\ldots)$: « une opération est arrivée à temps » sur i

$$R_i(t, OP(j, T^0, T^*)) = \begin{cases} false & si\ r_i(OP(j, T^0, T^*)) > t \\ true & sinon \end{cases}$$

avec :

T^0 : date de requête et T^* : date d'exécution

$r_i(OP(\ldots))$: date de l'événement de réception de OP sur le site i

Critère de cohérence de l'état global répliqué (suite)

Cohérence globale

Si à l'instant t toutes les opérations sont connues de chaque site, alors l'état de chaque site doit être identique

$$\forall t, i, j, k : \forall OP(k, T^0, T^*) : T^* < t ::$$
$$R_i(t, OP(k, T^0, T^*)) \wedge R_j(t, OP(k, T^0, T^*))$$
$$\Rightarrow E(i, t) \equiv E(j, t)$$

Correction de l'état global répliqué

Principe

Un site idéal virtuel P ordonne totalement toutes les opérations instantanément

Critère de correction : si à t, toutes les opérations sont connues par le site i, l'état du site i doit être identique à celui du site idéal P

$$\forall t, ink : \forall OP(k, T^0, T^*) \in OPE : T^* < t :: R_i(t, OP(k, T^0, T^*)) \Rightarrow E(i,t) \equiv E(P,t)$$

Correction $\Rightarrow$ Cohérence

Cohérence et correction

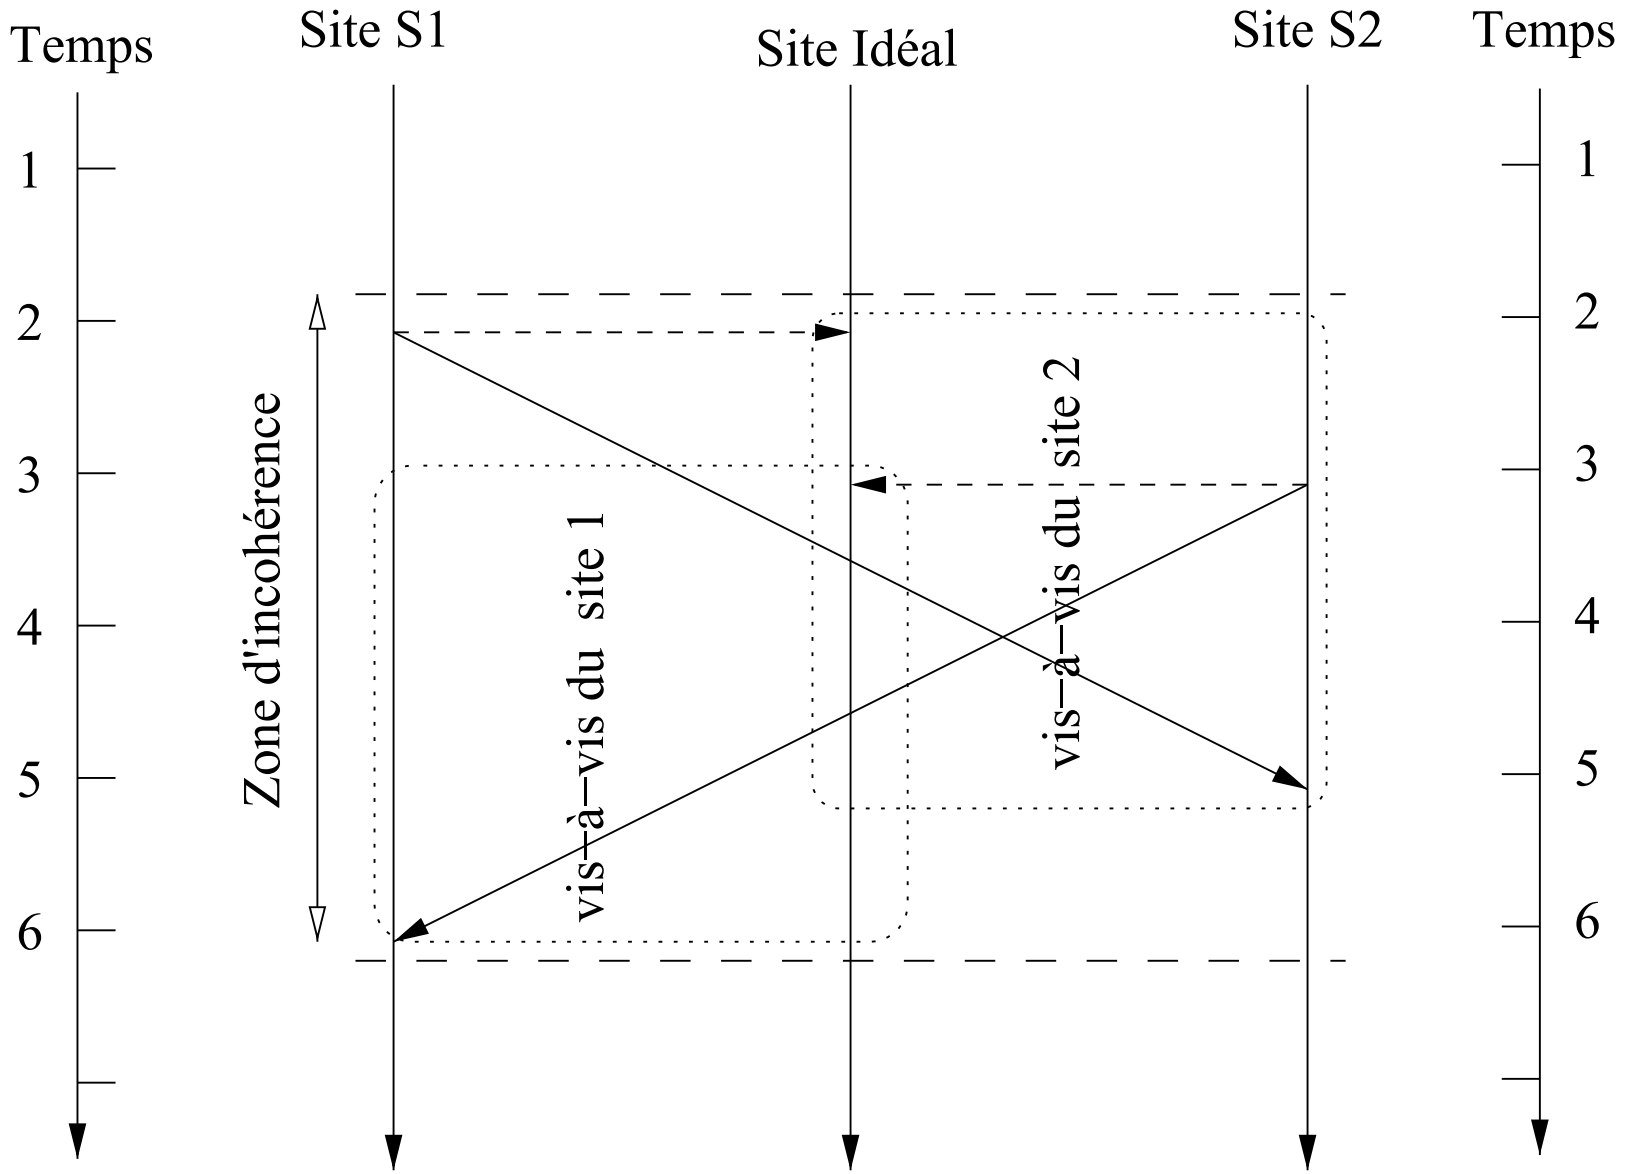

Première stratégie : Local lag

Introduction d'un temps de réponse local minimal

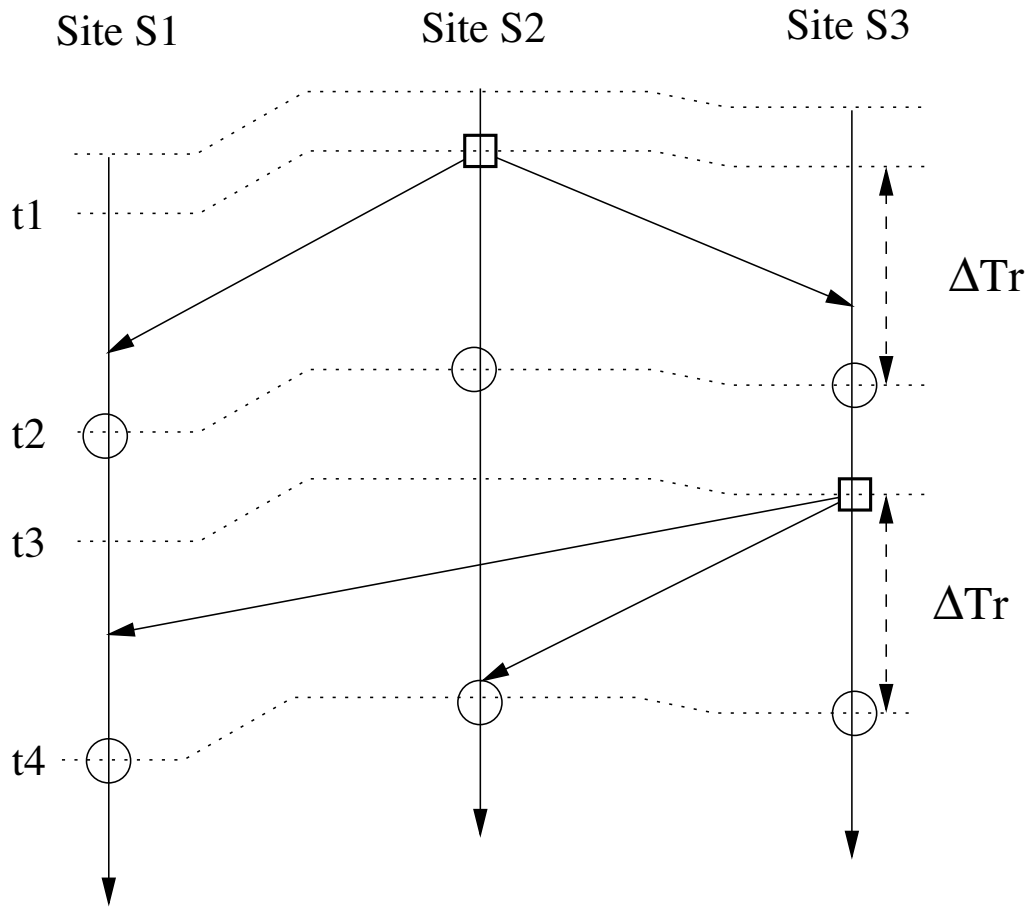

Un lag > délai max de communication garantirait la cohérence

Seconde stratégie : Timewarp

Chaque simulateur fonctionne comme précédemment : il exécute les événements qu'il connaît dans l'ordre des estampilles, plus :

- conservation des événements traités,
- mécanisme de sauvegarde de son état (*checkpointing*).

Quand un message en retard arrive (= dans le passé du simulateur), retour en arrière (*rollback*) = annulation des effets des événements traités à tort :

- restauration des variables d'état à la date précédant ce message
- élimination des messages envoyés : anti-messages

puis le message en retard est traité.

Timewarp : anti-messages

- Un anti-message correspond à un vrai message (message applicatif) envoyé précédemment
- Quand un anti-message se retrouve dans une file d'attente avec son message correspondant, ils s'annulent
- Quand un anti-message arrive avant son message correspondant, il est mis en attente de ce message
- Quand un anti-message arrive et que son message correspondant a déjà été traité ⇒ retour en arrière
- Risque de cascade de retours en arrière (effet domino)

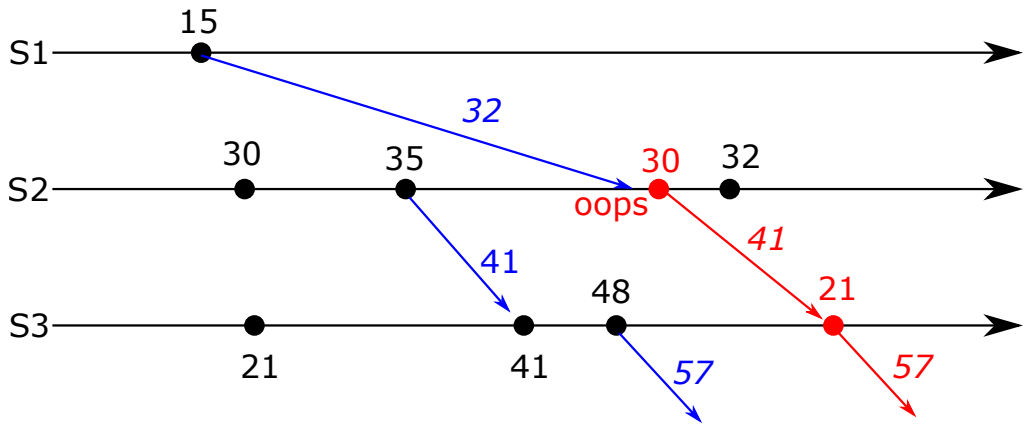

Dead reckoning (navigation à l'estime)

- Transmission des états (au lieu des opérations)
- Objets au comportement prédictible ⇒ estimation de leur évolution
- Unicité du contrôleur d'un objet
- Diffusion des états imprévus aux abonnés (résultats d'opérations appliquées à l'objet)
- Diffusion périodique (sans action usager) pour palier les pertes de messages

Remarque Même technique de local lag applicable à la mise à jour de l'état d'un objet

Conclusion – simulation temps réel

- Principe de base : retarder l'exécution des opérations
- Estimer l'évolution en absence d'informations
- Corriger "en retard" si nécessaire $\Rightarrow$ problèmes éventuels de réalisme
- Problème : conserver un temps de réponse acceptable :
  $\rightarrow$ réseau à qualité de service garantie

Conclusion générale

- Deux types d'applications
  - simulation d'un système pour étudier son comportement
  - simulation d'un environnement virtuel, complémentaire à l'environnement réel
- Système complexe $\Rightarrow$ plusieurs simulateurs interconnectés
- Exemple d'application répartie