Fouille de données, analyse d'évènements

Christophe Cérin

cerin@laria.u-picardie.fr

- placement, ordonnancement ;

- Placement, ordonnancement ;
- Représentation information ;

- Placement, ordonnancement ;
- Représentation information ;
- Algorithmes de fouilles ;

- Placement, ordonnancement ;
- Représentation information ;
- Algorithmes de fouilles ;
- Quelques résultats ;

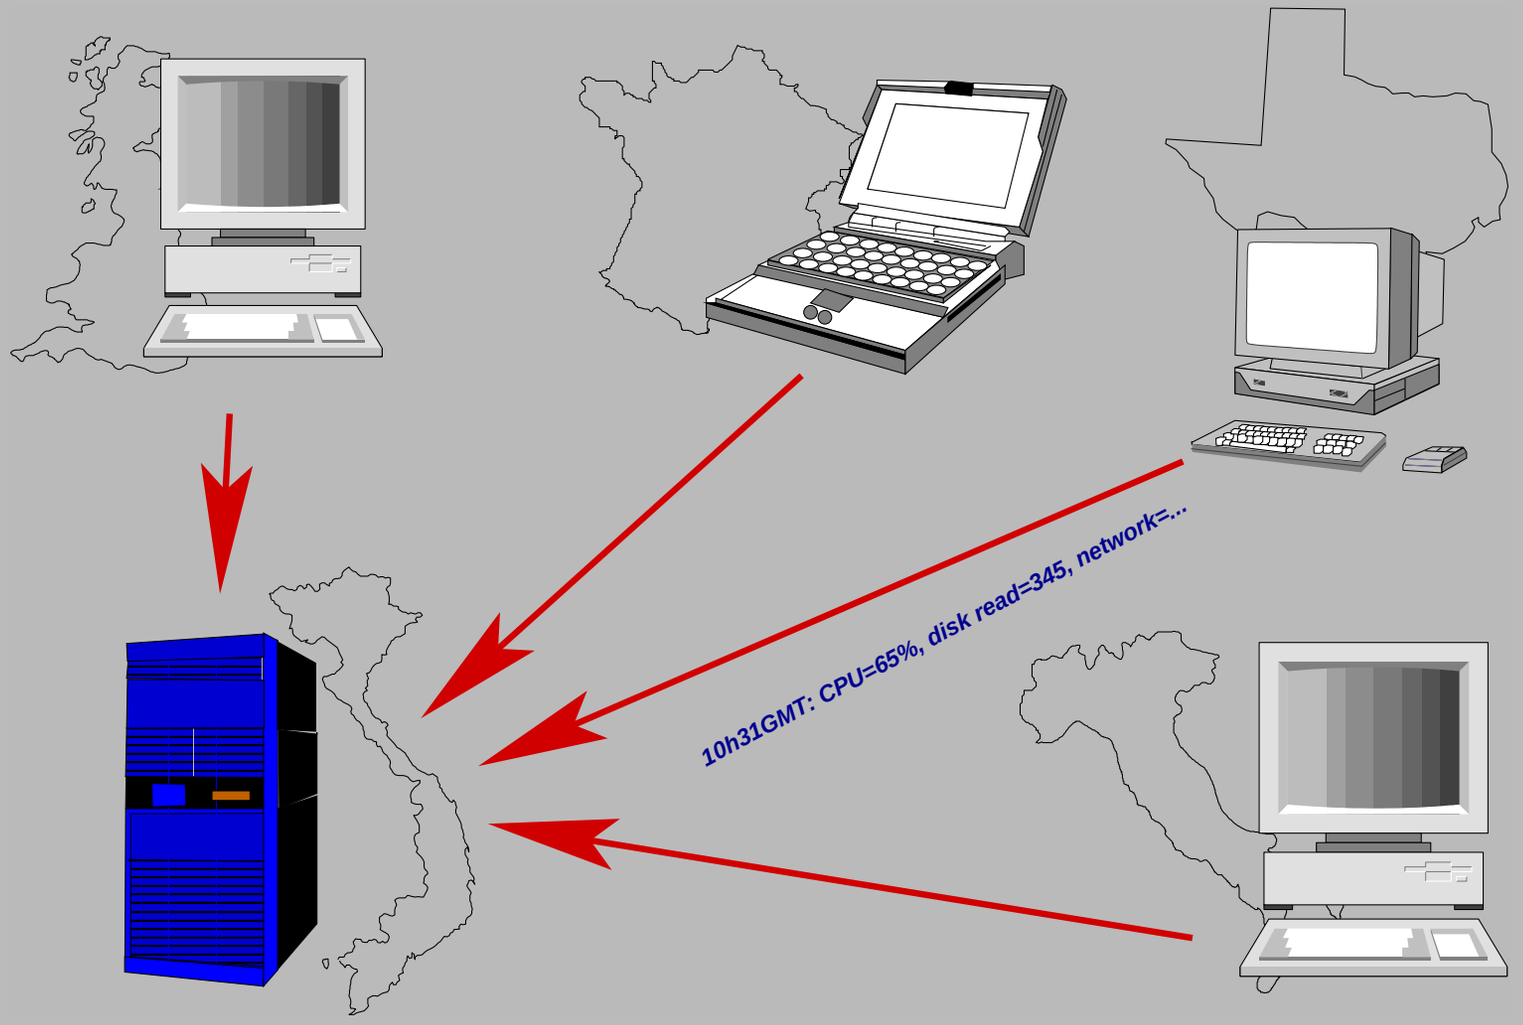
10h31GMT: CPU=65%, disk read=345, network=...

- Network Time Protocol (NTP) synchronise le temps d'un client ;
- Organisation hiérarchique ;

```
[root@m24 etc]# crontab -e
5 * * * * /usr/local/bin/ntpdate ntp.obspm.fr
```

  Serveurs secondaire de temps de l'Observatoire de Paris.

- NTP assure une précision de 10ms ;
- http://www.ntp.org/

- ✘ Trace utilisée : 15 évènements, prise toutes les 15min, 100 machines ;
- ✘ 78,2Mo décompressé ;
- ⇨ 11Go pour 1000 machines échantillonnées toutes les minutes (pessimiste) ;

↓

Doit-on stocker à plat les données ?

Structures arborescentes ?

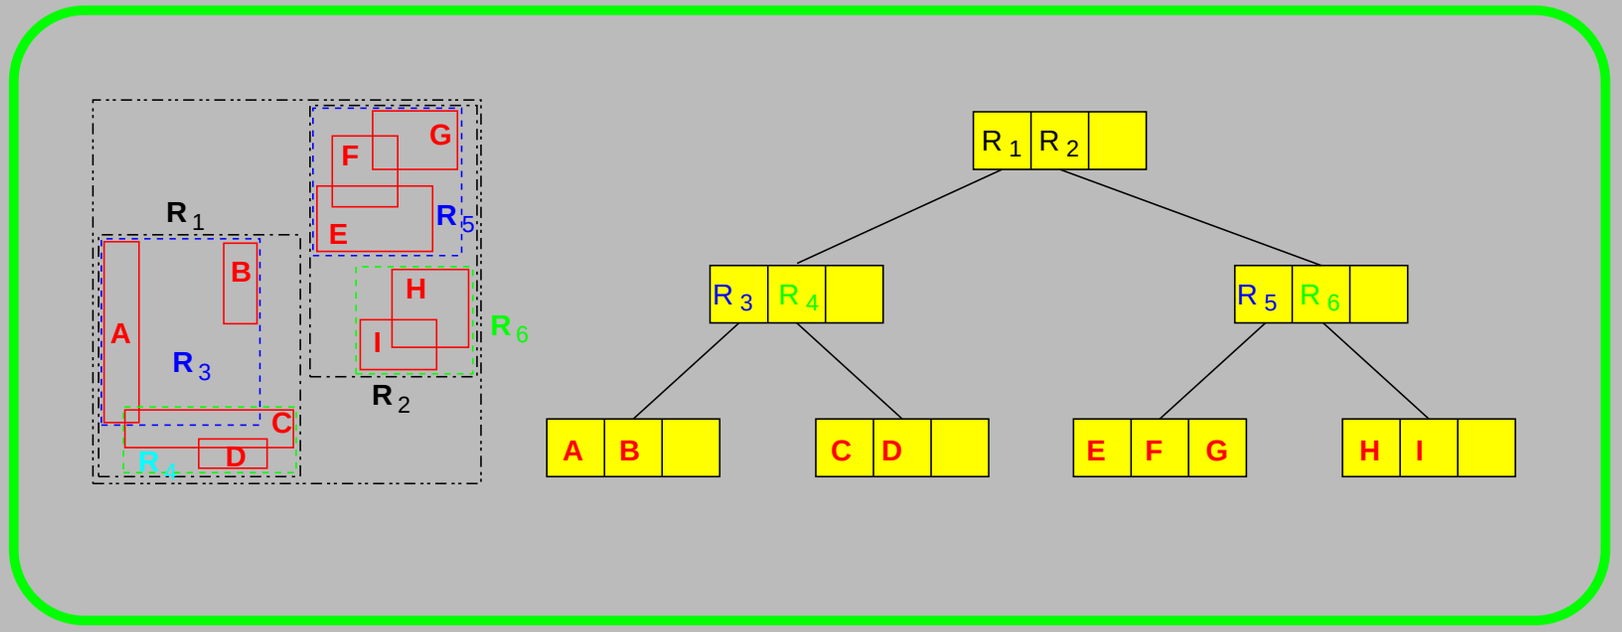

Indexation : Contient, Est Contenu, Est Egal.

- **Placement : pb difficile**
- **Fouille : produire des règles qui décrivent les relations entre différentes séquences ;**

↓

Ex: si (BF) arrive 4 fois tandis que (ABF) arrive 3 fois on produit la règle “si BF arrive alors il y a 75% de chance de voir arriver A”

- **Algo génération règles :**

```
for all frequent sequences β do
   for all subsequences α < β do
      conf = fr(α) / fr(β)
      if conf > min_conf then
         output α ⇒ β
         output conf
```

- **Le problème est celui de la découverte des épisodes fréquents.**

- Discovery and Monitoring Event Description (DAMED) Working Group.
- “The aim of this WG is to develop standard representations of the most widely used measurement values (the "top N".)”
- RIEN DE FAIT SUR LE THEME “DISCOVERY” !

- **on recherche les** *relations séquentielles* **entre les événements ;**

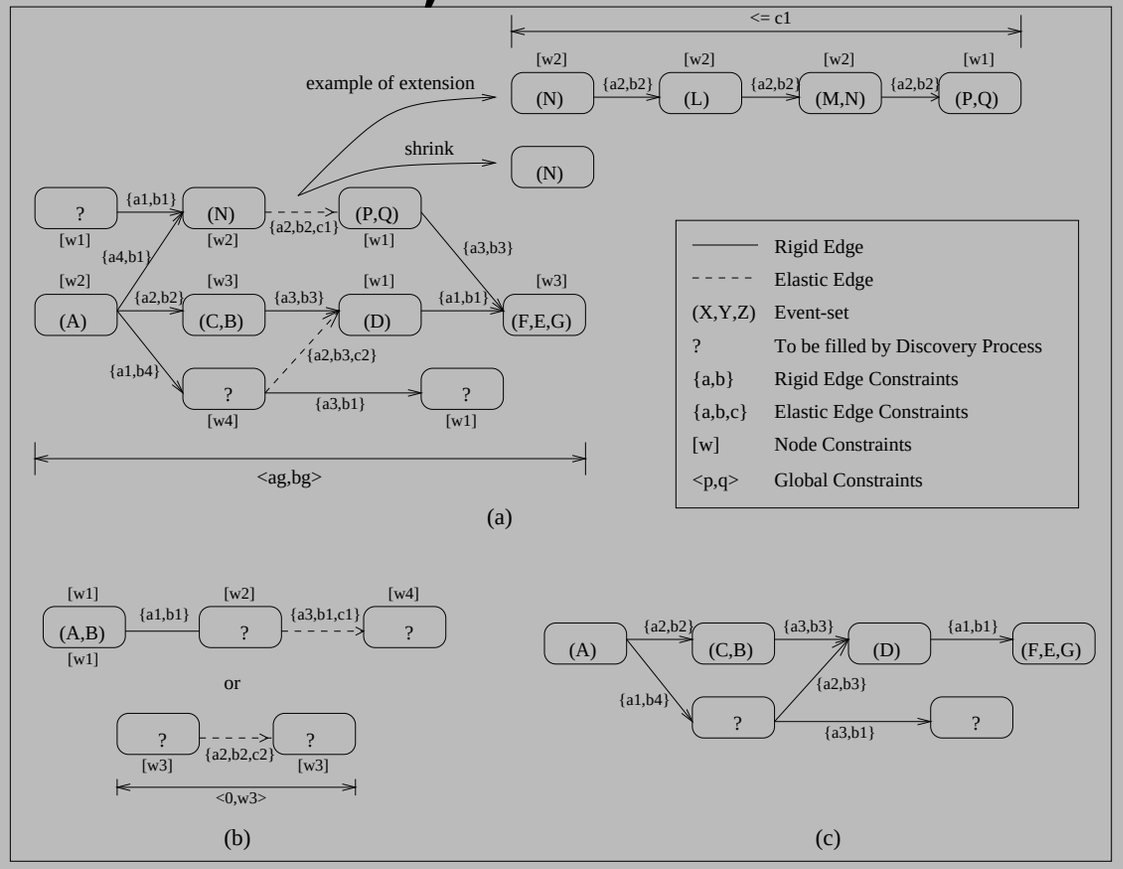

- Une séquence est intéressante si elle apparaît suffisamment de fois ;
- Différentes méthodes de comptage (>8) ;

(a)

	Count All	Count Minimal
Count Windows	CWIN	CMINWIN
Count Occurrences	CDIST_O	CDIST

(b)

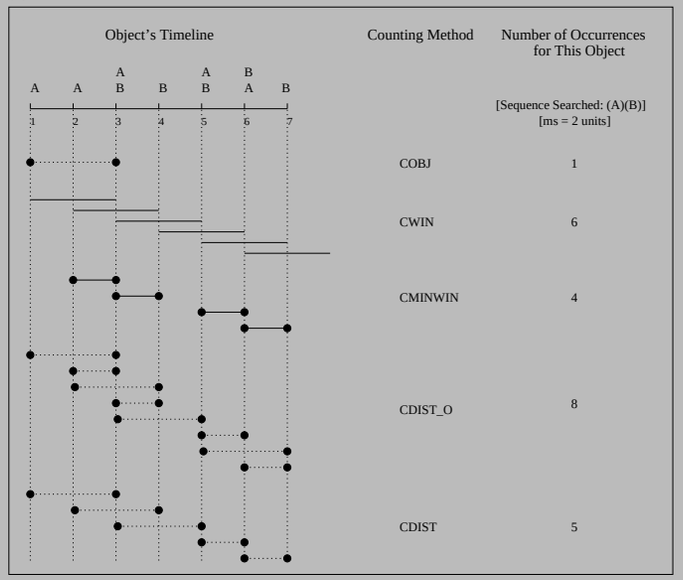

- Déterminer Algo(R-arbre,séquence,seuil)
- Explosion combinatoire : le nombre maximum de sequences est $\mathcal{O}(m^k.2^{k-1})$.
  Ex: m=k=15 : 7174453500000000000000 séquences !
- Utiliser des techniques d'élagage ;
- Deux techniques d'élagage ;

- Règle d'antimonotonie : pour qu'une séquence soit fréquente il faut que toutes les sous-séquences le soient
- on génère les séquences fréquentes de longueur i à partir de séquences candidates de longueur k-1 ;
- Utilisation du seuil ;
- WINEPI & Co

- Exprimer des contraintes au niveau des motifs ;
- SPIRIT [VLDB 1999] : introduit un langage souple de spécification des contraintes ;
- cSPADE [Zaki, 2001] : reconnu comme le plus performant...mais problème avec le format d’entrée ;

- nrgrep-1.1.1/ (Gonzalo Navarro at the University of Chile)
- version améliorée de grep ; "approximate string matching" : insert, del, substitution.

↓

Candidat potentiel pour la fouille.

- bit-parallélisme : structure de donnée permettant un gain > 2 vis à vis de KMP
- Bug trouvé !!!

- Charge CPU :

  00% - 09% 45932.0 observations
  10% - 19% 5994.0 observations
  20% - 29% 1801.0 observations
  30% - 39% 838.0 observations
  40% - 49% 1350.0 observations
  50% - 59% 789.0 observations
  60% - 69% 635.0 observations
  70% - 79% 850.0 observations
  80% - 90% 327.0 observations
  90% - 99% 591.0 observations

- ✘ Étude statistique disponible ;
- ✘ Les choix des outils de fouille et de représentation des données se précisent;
- ✘ Défi : fouille multi-dimensionnelle ;
- ✘ Problématiques sous-étudiées dans le Grid-Forum ;