Gestion répartie de données - 2

Sacha Krakowiak
Université Joseph Fourier
Projet Sardes (INRIA et IMAG-LSR)

http://sardes.inrialpes.fr/~krakowia

Systèmes “pair à pair” (*peer to peer*, P2P)

- **Idée de base**
  - utiliser la capacité globale de l’ensemble des clients potentiels comme support des fichiers
  - ne garder aux “serveurs” que le rôle de répertoire (et fonctions de gestion, distribution de logiciel), et non plus la fonction de stockage - à la limite faire disparaître la notion de serveur séparé
    - chaque nœud devient alors client et serveur
- **Réalisations**
  - des systèmes d’échange de fichiers dans une communauté large
    - Napster, Gnutella, Freenet, etc.
  - des systèmes à base de groupes restreints (dynamiques)
    - Groove
  - des algorithmes efficaces de hachage distribué : Chord, CAN, etc.
  - extension vers le calcul sur grilles (mise en commun de ressources de calcul)

Systèmes P2P : classification (1)

- **Selon le degré de centralisation**
  - **Contrôle centralisé**
    - Un serveur central permet la mise en correspondance des pairs
      - Avantage : structure simple
      - Inconvénients : maîtrise centrale, capacité de croissance limitée, point unique de défaillance
  - **Totalement décentralisé**
    - Tous les nœuds jouent un rôle symétrique (clients et serveurs)
      - Avantage : pas de maîtrise centrale (confidentialité) ; disponibilité
      - Inconvénients : peu gérable ; performances non garanties
  - **Partiellement décentralisé**
    - Un ensemble (dynamiquement variable) de nœuds joue un rôle privilégié
      - Avantages et inconvénients : essaient de concilier les 2 précédents

Systèmes P2P : classification (2)

- **Selon l'organisation du réseau (virtuel)**
  - Non structuré
    - Le placement des données n'est pas lié à la topologie du réseau
      - Avantage : adapté à un ensemble de nœuds très dynamique
      - Inconvénient (si pas de contrôle central) : recherche aléatoire (donc aussi temps de réponse) ; gaspillage de bande passante -> capacité de croissance ?
  - Structuré
    - Les données sont placées en des points prédéterminés pour rendre la recherche déterministe
      - Avantage : recherche rapide, temps d'accès borné
      - Inconvénients : peu adapté à une population dynamique
  - Faiblement structuré
    - Solution intermédiaire ; recherche partiellement déterministe

Systèmes P2P : classification (3)

	•Non structurés	•Faiblement structurés	•Structurés
•Contrôle centralisé	•Napster		
•Partiellement •décentralisé	•Kazaa, Gnutella		
•Totalement •décentralisé	•Gnutella (initialement)	•Freenet	•Chord, Can, Tapestry

Gnutella : http://www.gnutella.com
Freenet : http://www.freenetproject.org
Chord : http://www.pdos.lcs.mit.edu/chord/

Un article de synthèse : A survey of peer to peer file sharing technologies
http://www.eltrun.aueb.gr/whitepapers/p2p_2002.gr
Le tableau ci-dessus en est extrait

Exemple de système pair à pair : Napster

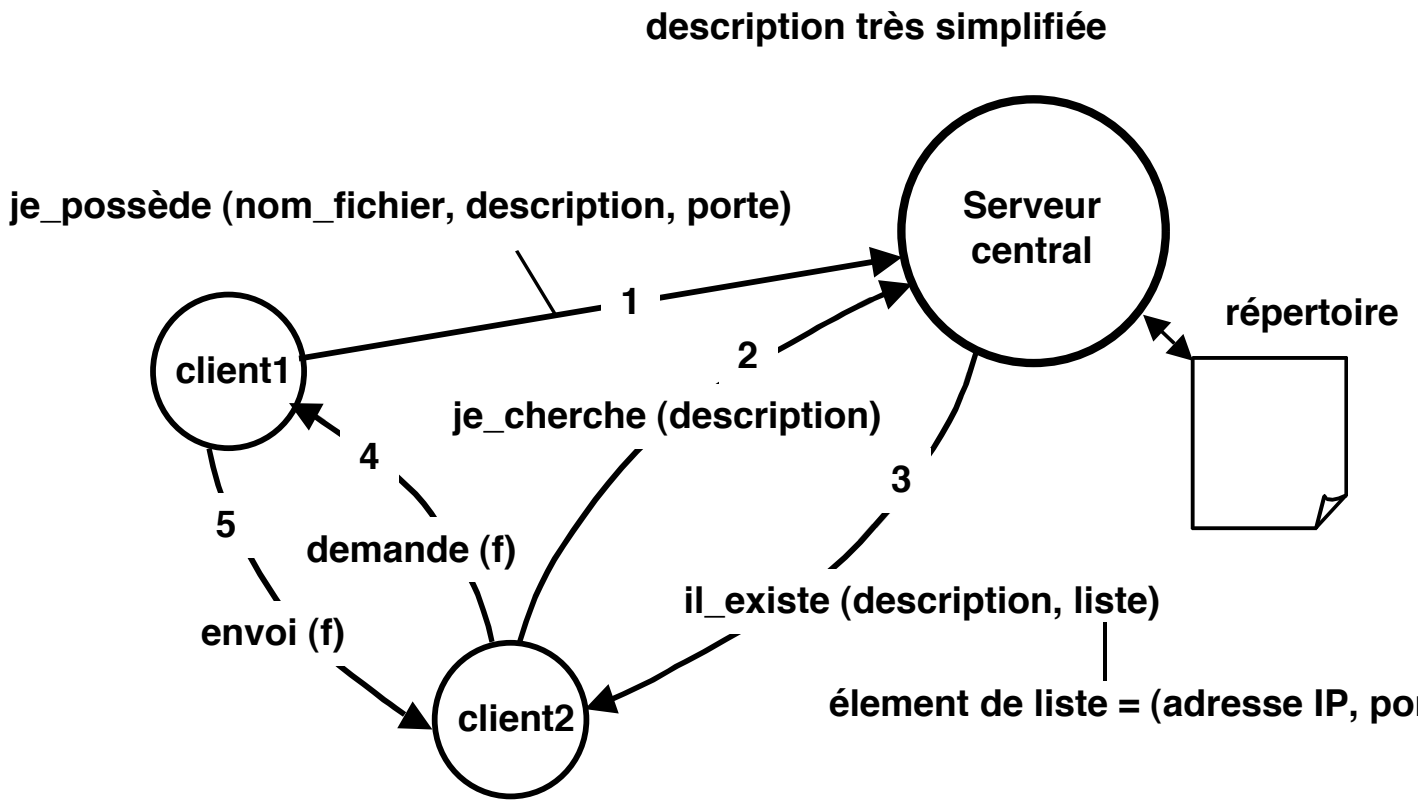

A existé de janvier 1999 à juillet 2001

Nombre d'utilisateurs :

Jan. 2000 : 1 000 000

Nov. 2000 : 23 000 000

Fev. 2001 : 50 000 000

si porte = 0, le détenteur du fichier est derrière un pare-feu. Le fichier sera envoyé en mode *push* (son détenteur est averti par le serveur)

Optimisation : le client mesure la qualité de la connexion (ping) pour plusieurs sites de la liste et choisit celui qui a les meilleures performances à ce moment

Exemple de système pair à pair : Gnutella

Structure

- Contrôle décentralisé, réseau non structuré
- Chaque nœud est à la fois client, serveur et routeur

Protocole

- Construit sur IP - 4 types de messages
- Ping : Un hôte sonde le réseau pour acquérir des correspondants
  - utilisé lors d'une connexion initiale ou d'une réinsertion
- Pong : Réponse à Ping - indique (adr. IP, porte), nb et taille des fichiers de celui qui répond
- Query : Recherche - indique clé de recherche (par ex. mots clés), et débit mini requis
- Query Hit : Réponse à Query- indique (adr. IP, porte), débit, nb de fichiers trouvés.
- Quand un hôte a reçu Query Hit, il peut directement communiquer avec le correspondant indiqué.

Gnutella : technique de recherche

Principe de base

- Fonctionne par inondation (*flooding*)
- Une requête (Query) est transmise à un certain nombre de voisins, qui eux-mêmes la retransmettent à leurs voisins, etc.
- Les requêtes ont une identification unique, pour éviter les retransmissions en boucle
- Le nombre de retransmissions (TTL) est limité
- Malgré ces précautions, il y a beaucoup de messages superflus…

Améliorations

- Remplacer inondation par envoi aléatoire, effectué en parallèle (diminue le nombre de messages)
- Utiliser des "Super Serveurs" (un nœud ayant beaucoup de connexions et une puissance importante). Ces Super Serveurs changent dynamiquement et sont connectés entre eux

Gnutella : exemple de recherche

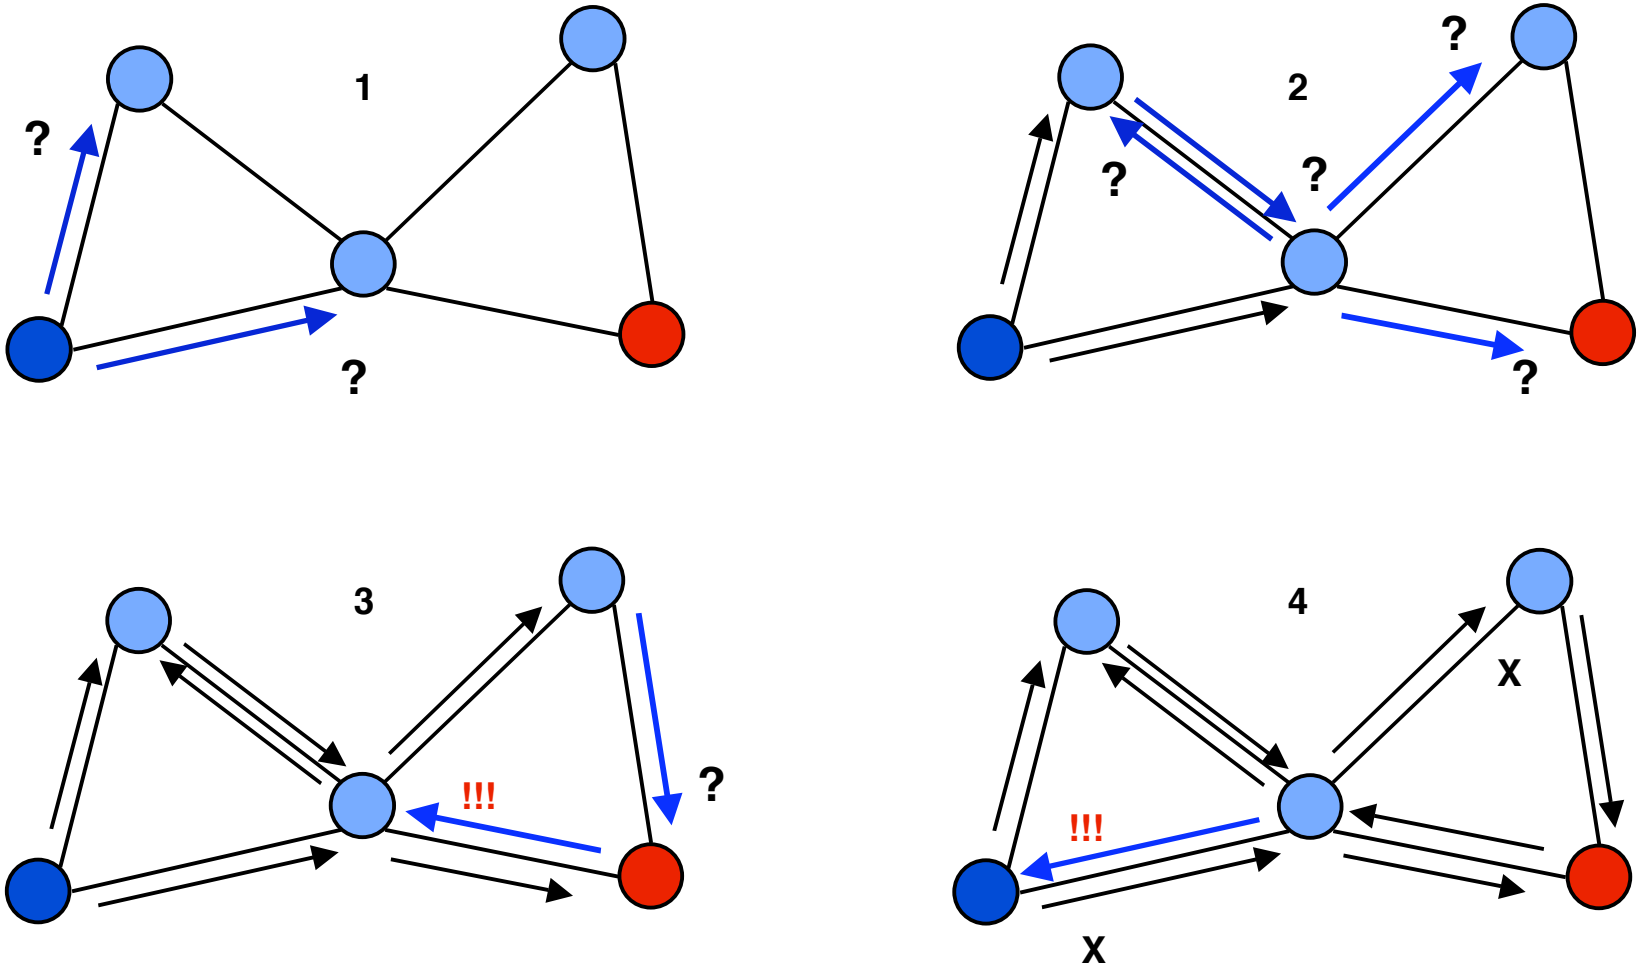

Gnutella : quelques problèmes

- **Problème de croissance**
  - Le TTL (limite au nombre de retransmissions) est nécessaire pour limiter le nombre de messages mais il limite aussi l'"horizon"
- **Problèmes des "parasites"**
  - Il est possible d'utiliser Gnutella comme "consommateur uniquement", sans apporter de fichiers (*freeloading*)
  - Remède : interdire les connexions via HTTP (navigateur) ; donner priorité aux clients qui apportent beaucoup
- **Problème des connexions interrompues**
  - En particulier clients/serveurs ayant des connexions lentes (modem)
  - Remède : mieux annoncer charge courante ; privilégier les connexions via super-serveurs
  - Fonctionnement encore imparfait (une fraction élevée des chargements est interrompue)

Exemple de système pair à pair : Freenet

- **Système expérimental**
  - Déploiement initial en cours : http://www.freenetproject.org
- **Structure**
  - Totalement décentralisé, faiblement structuré
  - Les nœuds ont une table de routage (contrairement à Gnutella)
- **Propriétés**
  - Meilleure capacité de croissance que Gnutella
  - Anonymat des clients et des serveurs
- **Protocole**
  - 4 types de messages
  - Data request - clé
  - Data Reply - Fichier
  - Data failed - Adresse, cause de l'échec
  - Data insert - clé, Fichier

Freenet : principe d'organisation

- **Stockage des données**
  - Un fichier est stockée en plusieurs exemplaires, à des emplacements déterminés par sa clé
  - Chaque nœud posssède une table de routage contenant les adresses d'un ensemble d'autres nœuds et une liste (indicative) des clés détenues par chacun de ces nœuds
  - La recherche se fait de proche en proche : si un nœud ne détient pas le fichier cherché, il transmet la requête à un successeur : celui qui possède (dans la table de routage) la clé "la plus proche" de la clé recherchée
- **Clés**
  - 2 sortes de clés
    - De bas niveau, pour le stockage - créées par hash-code sur contenu
    - De haut niveau, pour l'usage humain - pointent vers clés de bas niveau
    - Les clés de haut niveau sont créées à partir de descriptifs des fichiers à rechercher (ex : mots-clés)

Freenet : fonctionnement des clés

- **Clés de bas niveau (*Content Hash Key* : CHK)**
  - Utilisées pour stocker les fichiers
  - Clé = SHA-1 (contenu du fichier)
- **Clés de haut niveau (*Signed Subspace Key* - SSK)**
  - Utilisées pour stocker des descripteurs (listes de CHK)
  - Une SSK est relative à un espace de noms (sous-ensemble de fichiers).
    - Cet espace a un propriétaire et est protégé par un couple (clé publique, clé privée) construit depuis le descriptif
  - H1=SHA(clé publique) ; H2=SHA(descriptif) ;
  - SSK=SHA(H1 concaténé à H2)
  - Le fichier est signé avec la clé privée (fichier + $\{SHA(contenu\}_{clé\ privée}$)
  - Un client peut recréer une SSK avec le couple (clé publique, descriptif), mais seul le propriétaire peut créer un fichier (puisqu'il faut la clé privée)

Freenet : stockage

Insertion d'un fichier

- Le propriétaire envoie à un nœud la clé (CHK ou SSK) et un TTL (nombre maximum de sauts, également nb max de copies)
- Le nœud vérifie si la clé existe déjà
  - Si oui, collision (le fichier ou le descripteur est déjà présent)
  - Si non, le nœud retransmet au nœud possédant la clé la plus proche dans la table de routage
  - Si le TTL est atteint sans collision, un message OK est renvoyé
  - Si OK, le propriétaire envoie le fichier, qui est stocké sur tous les nœuds du parcours précédent
- Le système est auto-adaptatif : à partir d'un état initial, les clés vont tendre à se regrouper

Freenet : recherche

- **Recherche d'un fichier à partir de sa clé**
  - Envoi (clé + TTL) à un nœud
    - Si la clé est présente, le nœud renvoie le fichier
    - Si la clé n'est pas présente, le nœud transmet la clé à celui possédant la clé la plus proche dans la table de routage
  - On continue jusqu'à ce que le fichier soit trouvé ou le TTL atteint
    - En cas de "cul de sac" (pas de successeur), on revient en arrière
    - Idem en cas de détection de boucle
  - Il n'y a pas de garantie de trouver un fichier, même s'il existe, car la localisation n'est qu'approximative…
    - … mais la probabilité augmente grâce à l'auto-apprentissage du système

Systèmes structurés

Principe

- Table de hachage répartie (DHT : *Distributed Hash Table*)
- L'emplacement du stockage est entièrement déterminé
- Une seule opération de base : clé => emplacement

Exemples

- Chord, Can, Tapestry
- Utilisent des tables de routage, avec un algorithme pour une recherche efficace (coût de recherche : Log N pour N nœuds)

Caractéristiques

- Bonne capacité de croissance
- Mais peu dynamique (insertion, suppression, déplacement coûteux)
- Doivent faire leurs preuves sur applications en vraie grandeur

Tables de hachage réparties (DHT)

Chaque site gère une partie de l'espace de hachage : il est responsable d'un certain intervalle de clés

- pas de connaissance globale centralisée
- pas de point unique de défaillance
- passage à l'échelle
- répartition uniforme des ressources

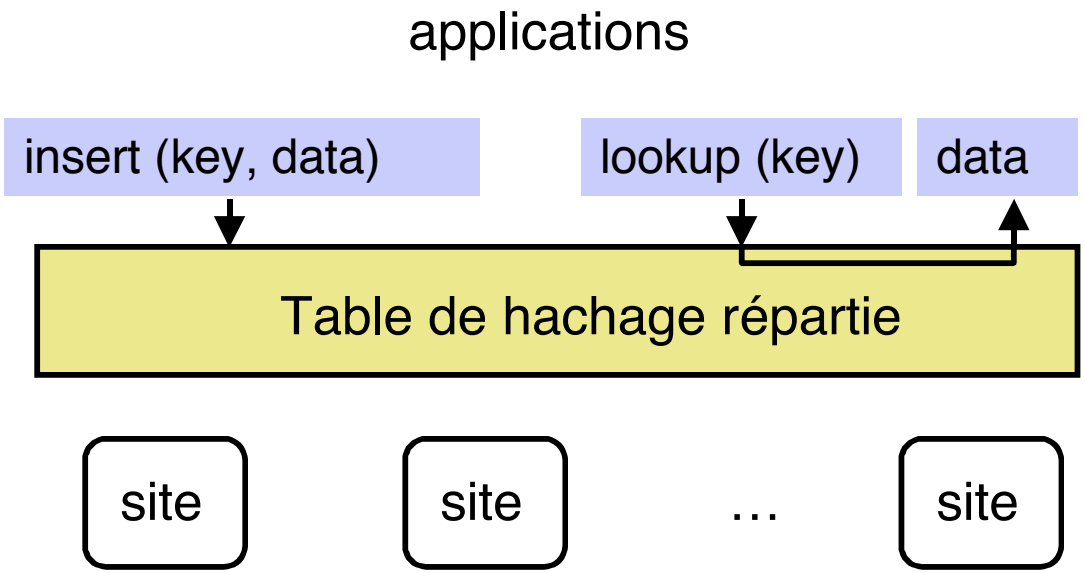

Un exemple de DHT : Chord

Algorithme de base : trouver le nœud responsable d'une clé donnée

fonction : key → node

Les clés et les noeuds reçoivent un identificateur de m bits

identificateur nœud = hachage de son adresse IP

identificateur clé = hachage de la clé

La fonction de hachage doit avoir les "bonnes" propriétés (faible risque de collision, inversion impossible). Exemplel : SHA-1

Les identificateurs sont ordonnés modulo 2^m (ordre circulaire)

Correspondance entre nœud et clé : la clé k est associée au premier nœud dont l'identificateur est égal ou supérieur à celui de la clé k

Informations : http://www.pdos.lcs.mit.edu/chord/

Chord : exemple

m = 6, 2^m = 64
10 nœuds, 5 clés

L'association évolue dynamiquement en cas d'addition ou de retrait des nœuds et des clés

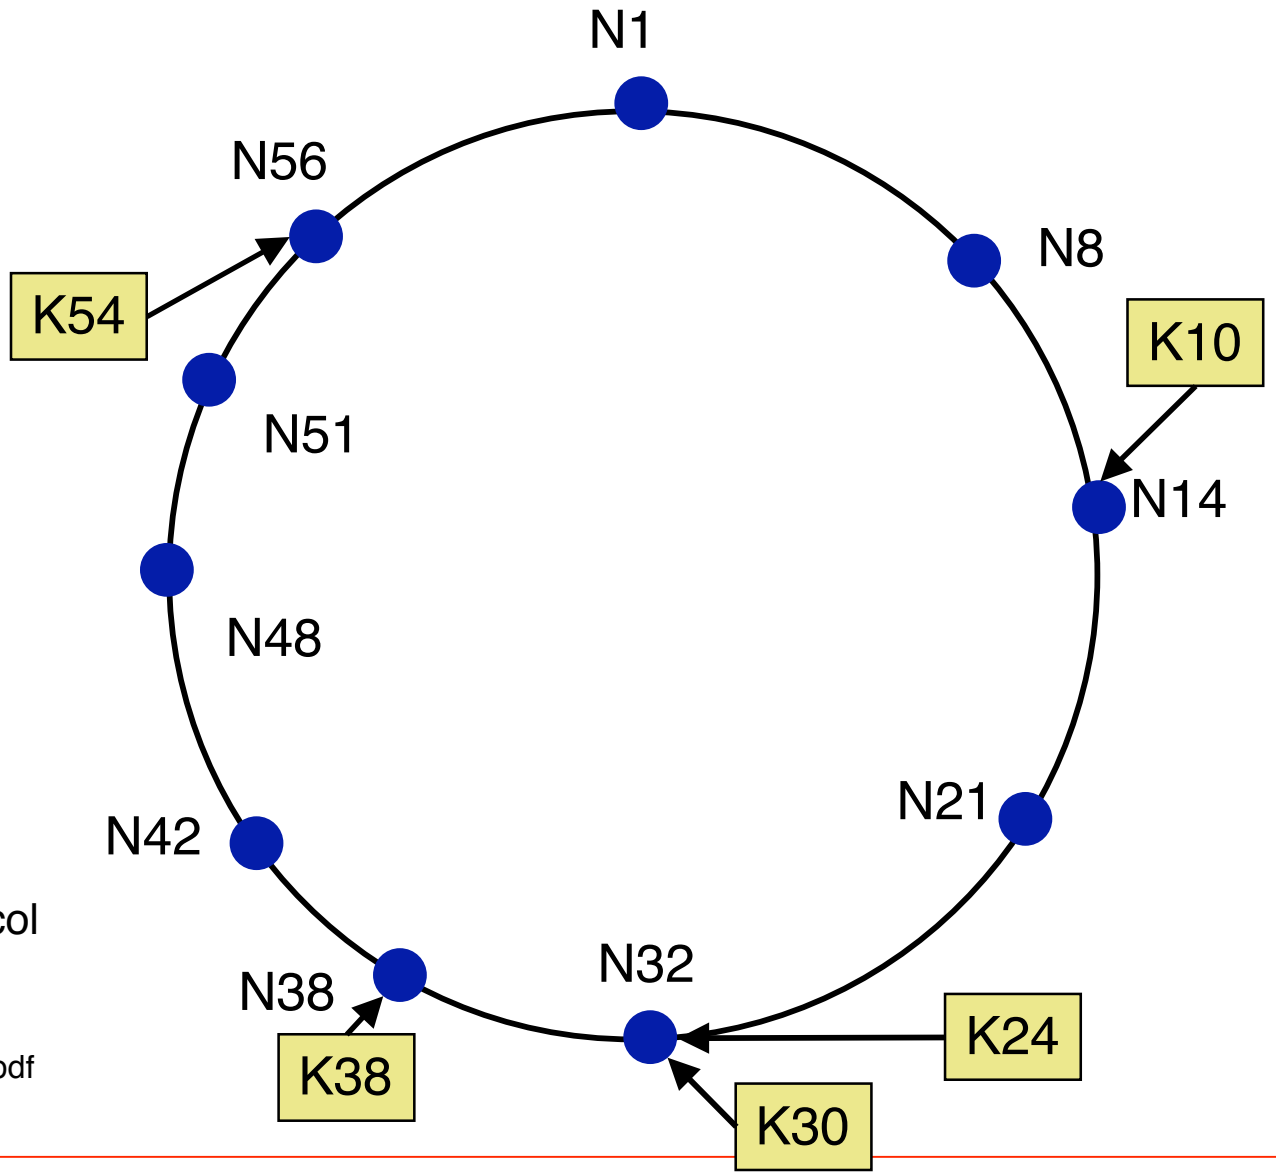

I. Stoica, R. Morris, D. Liben-Nowell, D. R. Karger,M. F. Kaashoek, F. Dabek, H. Balakrishnan. Chord: A Scalable Peer-to-peer Lookup Protocol for Internet Applications,
IEEE-ACM Trans. On Networking
http://pdos.csail.mit.edu/chord/papers/paper-ton.pdf

Chord : propriétés

Soit N le nombre de nœuds et K le nombre de clés. On peut montrer que, avec une probabilité élevée :

Chaque nœud est responsable d'au plus (1 + O(log N))K/N clés

Quand un nœud rejoint ou quitte le réseau, les modifications touchent O(K/N) clés (associées au nœud considéré)

Le terme de "probabilité élévée" signifie que ces résultats sont valables pour une distribution de la fonction de hachage sans anomalie majeures (pas de concentration de collisions).

Chord : recherche d'une clé (1)

Méthode simple, peu rapide : recherche séquentielle
Chaque nœud doit connaître son successeur. Étant donné une clé, on parcourt la suite des nœuds jusqu'à trouver une paire de nœuds qui "encadre" la clé. Le dernier est le nœud cherché.

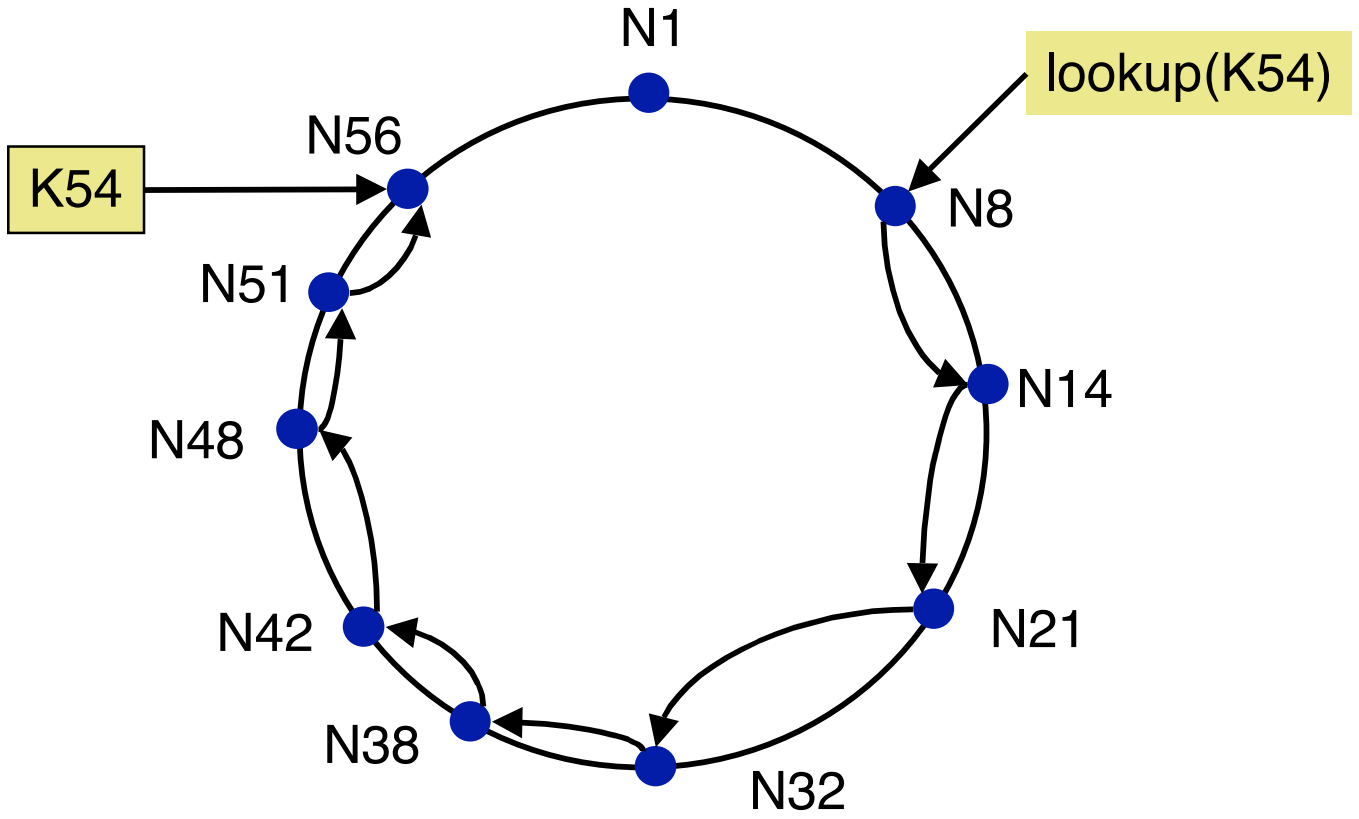

Chord : recherche d'une clé (2)

Chaque nœud a une table des pointeurs (*finger*)

finger[k] = premier nœud qui suit $(n + 2^{k-1})$ **mod** 2^m, $1 \le k \le m$

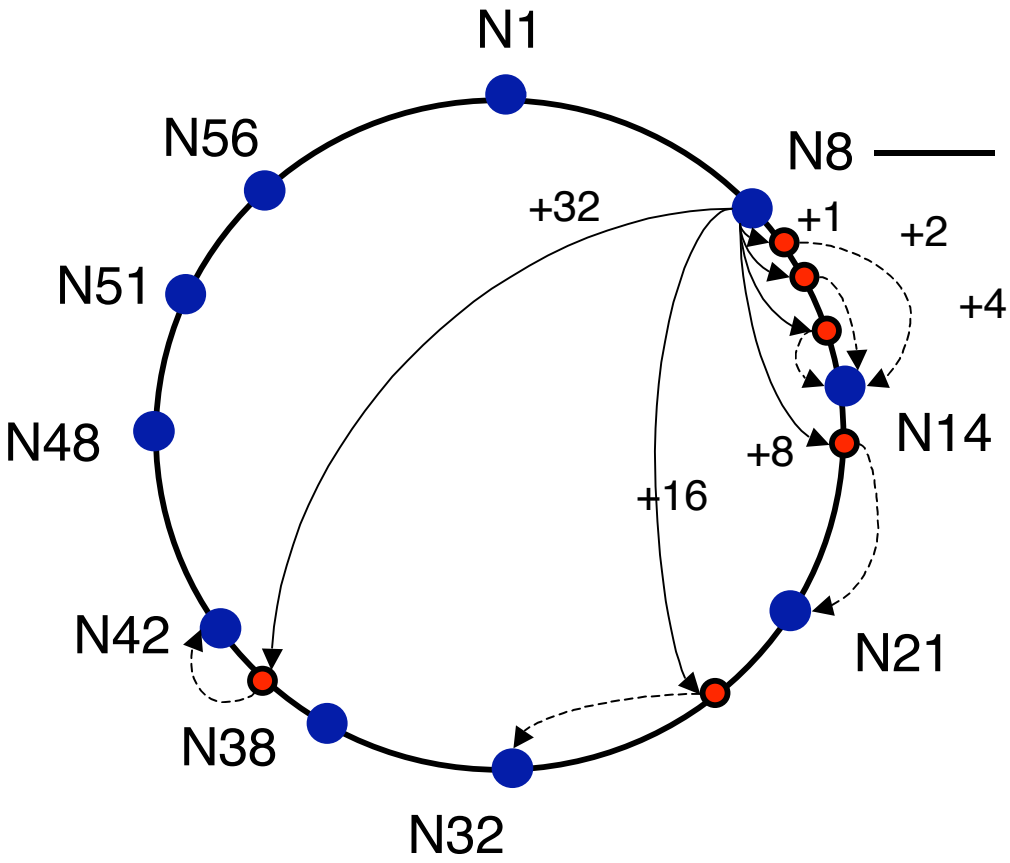

Table des pointeurs du nœud N8

1	N8+1	N14
2	N8+2	N14
3	N8+4	N14
4	N8+8	N21
5	N8+16	N32
6	N8+32	N42

Chord : recherche d'une clé (3)

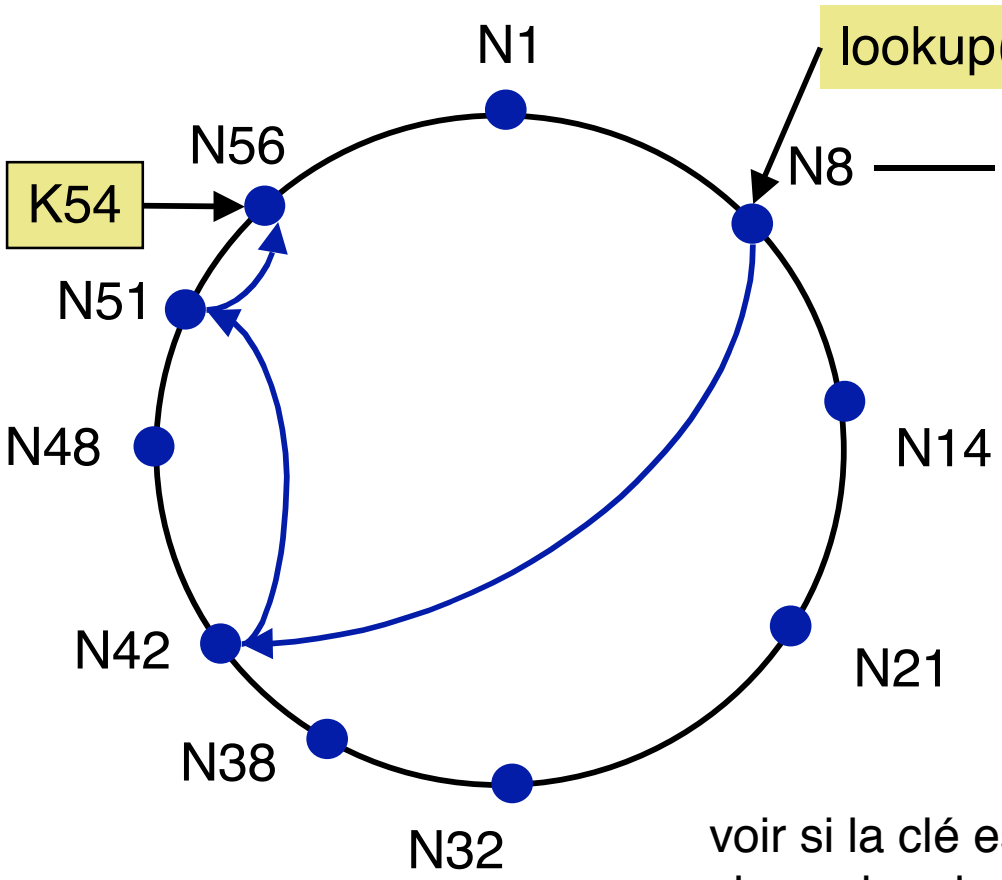

Table des pointeurs (*finger*) du nœud N8

1	N8+1	N14
2	N8+2	N14
3	N8+4	N14
4	N8+8	N21
5	N8+16	N32
6	N8+32	N42

voir si la clé est entre le nœud de départ et son successeur
sinon chercher dans la table des pointeurs le nœud le plus proche précédant la clé (ici 42)
rappeler la procédure de recherche à partir de ce nœud

Chord : performances de la recherche

Avec une probabilité élevée (i.e. si la fonction de hachage réalise une dispersion aléatoire des clés et nœuds), le nombre de nœuds à interroger pour la recherche du nœud successeur d'une clé dans un réseau de N nœuds est O(log N)

Le nombre d'entrées dans les tables de pointeurs peut être réduit à O(log N) (au lieu de m, nombre de bits des clés)

Le nombre moyen de messages pour réaliser une recherche est de l'ordre de 0,5 log N

Chord : compléments

Aspects dynamiques

insertion / départ de nœeuds

Tolérance qux fautes

techniques de redondance

Seront vus en TD

Conclusion sur Chord

Technique de structuration de l'espace des informations utilisable dans un système P2P

Performances en log N (N nombre de nœuds du réseau), donc bonne capacité de croissance.
Dépend néanmoins des qualités de la fonction de hachage

Permet l'insertion et le départ de nœuds en cours de fonctionnement

Résiste bien aux défaillances de nœuds

Il reste à valider ces principes sur de grandes applications réelles

Conclusion sur systèmes P2P

- **Systèmes non structurés**
  - Ex : Gnutella
  - Problème : capacité de croissance, anonymat
- **Systèmes structurés**
  - Freenet (faiblement), Chord etc. (fortement)
  - Problème : insertion dynamique
- **Pour tous les systèmes**
  - Difficile d'assurer la qualité de service (qui la garantit ?)
    - Sécurité
    - Disponibilité - différente de celle du client-serveur (une partie du réseau est en général en état de marche)
  - Pas de standard pour le moment
- **Domaine de recherche très actif**

Références sur systèmes P2P

Gnutella : http://www.gnutella.com
Freenet : http://www.freenetproject.org
Chord : http://www.pdos.lcs.mit.edu/chord/

Un article de synthèse : A survey of peer to peer file sharing technologies
http://www.eltrun.aueb.gr/whitepapers/p2p_2002.gr

Mémoire virtuelle partagée répartie

- **Idée**
  - Généraliser la notion de mémoire virtuelle à un système réparti
    - mémoire partagée par un ensemble de stations, répartition invisible
  - Avantages attendus
    - simplicité d'utilisation (s'oppose à une programmation par échange explicite de messages)
  - Difficultés
    - nécessité de spécifier de manière précise les contraintes de cohérence (nombreuses possibilités)
    - plus la cohérence est stricte, plus le coût est élevé
    - capacité de croissance difficile à assurer
  - En pratique
    - non entré dans la pratique courante
    - domaine d'application : grappes homogènes (*clusters*)

Quelques développements récents

- **Diffusion à grande échelle**
- **Découverte dynamique de services**

Motivations :

Développement de systèmes et d'application à grande échelle (nombre d'objets, nombre d'utilsateurs, taille, étendue géographique).

Développement de l'accès vers ou à partir de mobiles

Diffusion à grande échelle (1)

- **Limites des algorithmes “classiques” de diffusion**
  - Les algorithmes de diffusion vus jusqu’ici s’appliquent à un ensemble bien identifié de processus
  - Les contraintes fortes sur leurs spécifications font que ces algorithmes passent très mal à grande échelle
- **Nouveaux problèmes**
  - On souhaite utiliser la diffusion pour des applications dans lesquelles
    - le nombre de processus (ou sites) est inconnu et variable, ainsi que la topologie d’interconnexion
    - le nombre de sites est potentiellement très grand (taille de l’Internet)
    - les sites jouent un rôle symétrique (chacun est client et serveur)

Diffusion à grande échelle (2)

Champs d'application

- Découverte et observation de ressources
- Collecte de données (surveillance d'installations)
- Détection de pannes
- Mise à jour de bases de données à grande échelle

Voies d'approche

- On utilise des algorithmes probabilistes (un site a une probabilité élevée de recevoir l'information)
- Le principe utilisé est la propagation aléatoire ; analogies : propagation d'une rumeur *(gossip)* ou d'une épidémie (algorithmes dits "épidémiques")

Bref historique

La diffusion épidémique a été introduite en 1987 (Demers et al.) pour la mise à jour de bases de données.
Deux idées : diffusion à un sous-ensemble de destinataires choisis au hasard ; anti-entropie (échange mutuel), comme complément

Elle a trouvé récemment (2000) un regain d'intérêt avec le développement des systèmes de grande taille, des systèmes pair à pair et des réseaux de capteurs
Exemple récent d'application : Astrolabe

A. Demers, et al. Epidemic Algorithms for Replicated Database Maintenance, *Proc. 6th ACM Symp. on Principles of Distributed Computing*, Vancouver, pp. 1-12, 1987

R. van Renesse, K. P. Birman, W. Vogels. Astrolabe: A Robust and Scalable Technology for Distributed Systems Monitoring, Management and Data Mining. *ACM Trans. on Computer Systems*, 21(2), May 2003

Diffusion épidémique

Principe

Chaque processus participe à la diffusion. Les paramètres sont :

- capacité b : nombre de messages qu'un processus peut stocker
- nombre de retransmissions t : nombre de phases de rediffusion
- nombre de destinataires f : à chaque phase, le processus transmet le message à f destinaires choisis aléatoirement

Les paramètres b, t, f caractérisent un algorithme de diffusion épidémique. Ils peuvent être fixés indépendamment du nombre total n de processus, ou être fonction de n.

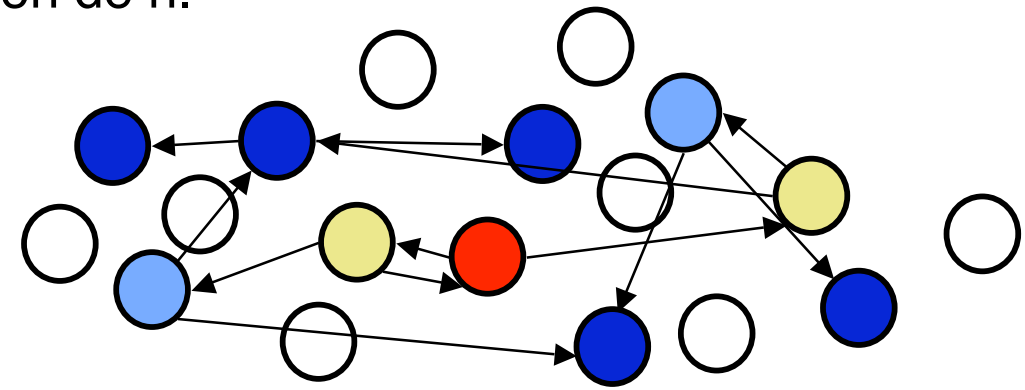

n = 18
f = 2
situation après 3 retransmissions

émetteur
après 1 retransmission
après 2 retransmission
après 3 retransmission

Diffusion épidémique : aspects mathématiques

Les algorithmes épidémiques comportent une succession de tours. Soit n la taille de la population, Y(r) le nombre d'individus touchés ("infectés") après le r-ième tour. Alors, si un individu infecté continue la propagation à tous les tours, on a

$$p = Y(r)/n \approx 1/(1 + n \exp(-fr))$$ (f = fanout, taille de l'ensemble de diffusion)

Donc la proportion d'individus touchés augmente exponentiellement avec le nombre de tours, et avec f.

Si un individu touché ne propage l'infection que pendant un tour ("infect and die"), alors la proportion p satisfait l'équation

$$p = 1 - \exp(-pf)$$

Dans ce modèle, supposons que f = log(n) + c (c est un paramètre)
Alors la probabilité que tous les processus soient touchés à terme est

$$P = \exp(-\exp(-c))$$

Il y a un changement de comportement quand c change de signe, donc quand f dépasse log(n)

Diffusion épidémique : comportement

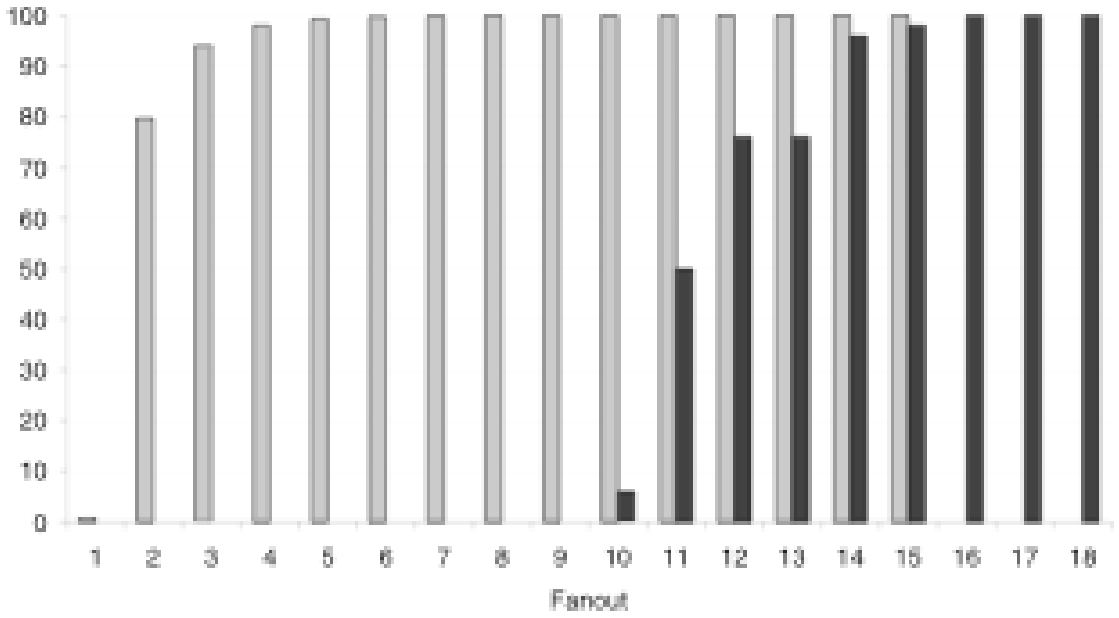

Comportement bimodal : le comportement change à partir d'une certaine valeur du nombre f de processus destinataires d'une retransmission (*fanout*). Une diffusion est dite atomique (dans ce contexte) si elle touche l'ensemble des processus. On constate que la proportion de diffusions atomiques croît rapidement à partir d'une certaine valeur de f, et qu'elle est de 100% pour une valeur de f suffisamment élevée.

Source : P. T Eugster, R. Guerraoui, A.-M. Kermarrec, L. Massoulié. From Epidemics to Distributed Computing, *IEEE Computer*, 37(5), 60-67, May 2004

Algorithmes de diffusion épidémique : exemple (1)

```
// Initially:
      events, eventIds := ∅
every T ms:
      // Update ages
      for all e ∈ events do
            e.age := e.age +1
      for all e ∈ events: e.age > k do
            events := events \ {e}
// Gossip
      gossip.events:=events
      Choose f random members target_1…target_f
      for all j ∈ [1…f] do
            send(target_j, gossip)
```

k = nombre max propagations

f = “fanout”

```
upon receive(gossip):
      // Update events and ages
      for all e ∈ gossip.events
            if not (e.id ∈ eventIds) then
                  events := events ∪ {e}
                  eventIds := eventIds ∪ {e.id}
                  deliver(e)
            if e' ∈ events such that
            e.id = e'.id and e'.age < e.age then
                  e'.age := e.age
      // Garbage collect eventIds
      while |eventIds| > |eventIds|_m do
            remove oldest element from eventIds
      // Garbage collect events
      while |events| > |eventIds|_m do
            remove oldest element from events
```

constantes

P. Th. Eugster, R. Guerraoui, S. B. Handurukande, A.-M. Kermarrec, P. Kouznetsov, Lightweight Probabilistic Broadcast, *Proc. IEEE Int. Conf. on Dependable Systems and Networks (DSN’01)*, 2001

Algorithmes de diffusion épidémique : exemple (2)

Commentaires sur l'algorithme

Le paramètre sensible est la **taille des tampons** pouvant contenir les messages. Un processus doit pouvoir conserver les messages suffisamment longtemps pour pouvoir les retransmettre.

Si la fréquence d'émission augmente (la taille des tampons restant fixe), les tampons se remplissent plus vite et les messages sont éliminés avant d'être retransmis suffisamment de fois pour être largement diffusés

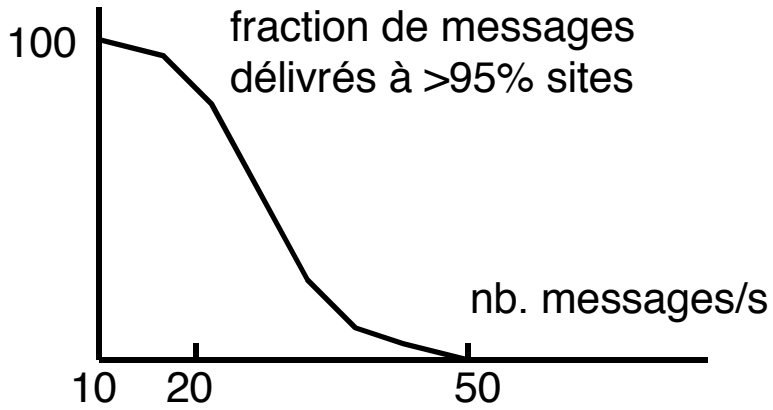

D'où l'idée d'un algorithme adaptatif : régler la fréquence d'émission en fonction des ressources et de la charge

L. Rodrigues, S. Handurukande, J. Pereira, R. Guerraoui, A.-M. Kermarrec, Adaptive Gossip-based Broadcast, *Proc. IEEE Int. Conf. on Dependable Systems and Networks (DSN'03)*, 2003

Conclusion sur la diffusion épidémique (1)

Champ d'application

- Systèmes de grande taille, avec évolution dynamique
- Connaissance mutuelle limitée entre les membres
- Rôles symétriques (pair à pair)

Avantages de la diffusion épidémique

- Facilité de réalisation et de mise en place
- Robustesse (vis-à-vis des modifications de l'environnement)
- Grande tolérance aux défaillances
  - Pas de reconfiguration pour la reprise
- Réalisation possible d'une large gamme de comportements
  - Ajustement via un petit nombre de paramètres

Limitations

- Nécessite des ressources en mémoire
- Pas de garanties strictes (seulement probabilistes)

Conclusion sur la diffusion épidémique (2)

Expérience acquise

- Expérience encore réduite, pour le moment

Quelques problèmes ouverts

- Connaissance mutuelle des membres
- Gestion des tampons de stockage de messages
  - ces deux aspects conditionnent notamment le passage à l'échelle
- Structuration du réseau et utilisation de ses caractéristiques
- Diffusion sélective (filtrage)

Découverte dynamique de services

Problème

Dans un système de grande taille, avec des éléments mobiles, les services sont nombreux ; ils sont souvent créés, détruits, modifiés, déplacés.

Il se pose alors le problème de trouver (efficacement) un service répondant à des conditions données.

Sera vu en TD