Systèmes et algorithmes répartis

Systèmes à grande échelle, pair à pair

Philippe Quéinnec

Département Informatique et Mathématiques Appliquées
ENSEEIHT

4 octobre 2016

plan

Plan

Passage à grande échelle

Grande échelle

- Grand nombre de sites, d'objets...
- Grand nombre d'interactions
- Grande taille (géographique)

Grand = ? (ça dépend !)

Scalability

La capacité de croissance (*scalability*) est la propriété pour un système de conserver ses qualités (performance, robustesse...) lorsque sa taille change d'échelle

taille 4 $\rightarrow$ 128, 32 $\rightarrow$ 1024, 1000 $\rightarrow$ 100 000

Champs d'application

- Découverte, observation et accès à des ressources nombreuses
- Collecte de données (surveillance d'installations, capteurs)
- Détection de pannes
- Base de données à grande échelle (SIG – système d'information géographique)
- Absence d'infrastructure « officielle » : rôle symétrique des sites (tous client et serveur)

Fiasco pour le passage à grande échelle

- Algorithmes centralisés, point de contrôle unique
  $\Rightarrow$ véritables algorithmes répartis
- Algorithmes linéaires ($O(n)$) en le nombre de sites, ou pires
  $\Rightarrow$ $O(\log n)$
- Hypothèse sur la structure statique du système
  $\Rightarrow$ ajout et retrait de sites, reconfiguration du réseau, partitionnement
- Considérer que la défaillance de site est un événement exceptionnel
  $\Rightarrow$ il existe des sites défaillants en permanence
- S'adresser à l'ensemble des sites (diffusion générale)
  $\Rightarrow$ propagation (par inondation, arborescente, probabiliste)

Outil : les réseaux de recouvrement

Réseau de recouvrement ou *overlay*

Réseau logique, virtuel, au-dessus d'un réseau physique existant

- Couche applicative :
  - Réimplantation du routage
  - Ajout de fonctionnalité : nommage, stockage
- Intérêt :
  - Indépendance par rapport au(x) réseau(x) physique(s) sous-jacent(s)
  - Souplesse et évolutivité (niveau applicatif)

Plan

Diffusion à grande échelle

Limites des approches classiques

- Ensemble bien identifié de sites (notion de groupe)
- Propriétés fortes (fiabilité, ordre, atomicité) néfastes au passage à l'échelle

Besoins

- Nombre de sites inconnu
- Grand nombre de sites
- Nombre et identité des sites variables

Diffusion par inondation

Cf chapitre IV « problèmes génériques »

Diffuser(m), sur p

```
-- p = émetteur, m = message
∀ s ∈ voisins(p) ∪ {p} faire
    envoyer(⟨p,m⟩) à s
fin pour
```

Réception(⟨p,m⟩), sur q

```
si q n'a pas déjà délivré m alors
    si p ≠ q alors                    -- propagation
        ∀ s ∈ voisins(q) faire
            envoyer(⟨p,m⟩) à s
        fin pour
    fin si
    délivrer(m)
fin si
```

Groupes et diffusion

Notion de groupe

Cf chapitre V « Tolérance aux fautes »

Limites

- Vision synchrone des arrivées et départs
- Propriétés fortes (fiabilité, ordre), coûteuses et non indispensables
- Taille d'un groupe limitée

Arbre de recouvrement

- Construire un arbre issu du site de diffusion et contenant tous les sites
- Approximation : graphe orienté acyclique avec détection de messages en doublon
- Difficulté : construire l'arbre. . .
- . . . mais c'est simple quand on a une table de routage hiérarchique, cf transparent 38

Algorithmes épidémiques (Demers et al., 1987)

Diffusion à grande échelle

- Grand nombre de sites (> 100), voire très grand (> 10000)
- Nombre inconnu et variable de sites
- Rôle symétrique de tous les sites
- Présence de sites en panne
- Topologie d'interconnexion inconnue (a priori non directement maillée)

Exemples : Internet (DNS), peer-to-peer

Approche

- Algorithmes probabilistes
- Propagation aléatoire

Algorithme épidémique : Rumeur

Rumeur (*Gossip*)

Contamination d'autres sites choisis aléatoirement avec une information supposée nouvelle.
États d'un site :

- Infectable : ne possède pas l'information
- Contagieux : apte à contaminer des sites infectables
- Immunisé : a cessé d'être contagieux
  - Immunisation en aveugle ou avec rétroaction (échec d'une tentative de contamination)
  - Compteur (de tentatives ou d'échecs)
  - Probabilité d'abandon après chaque tentative / échec

Rumeur : exemple

20 sites, nombre de sites contactés à chaque tour = 2, immunisation en aveugle à 1 tour

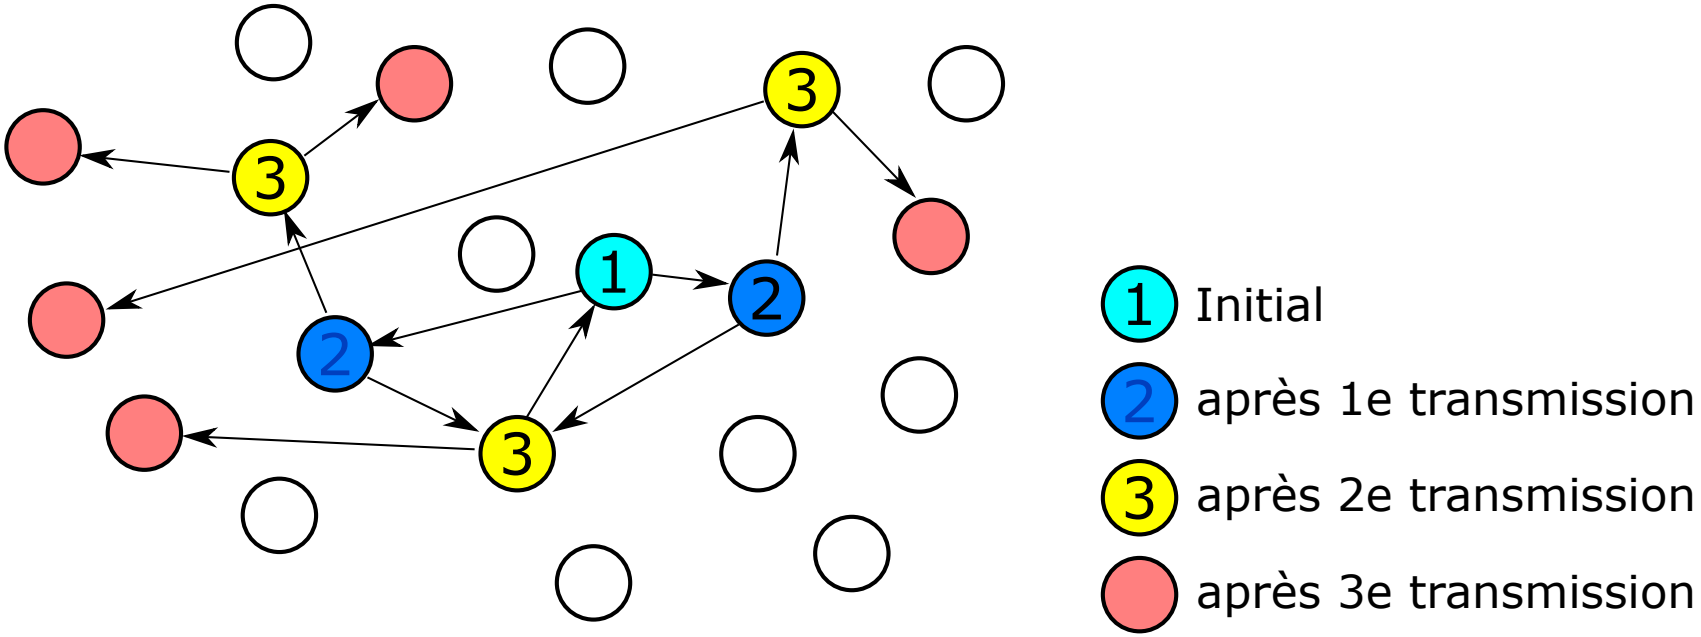

Rumeur : performance

Modèle simple : *infect forever* = pas d'immunisation

- N = nombre de sites
- f = nombre de sites contactés à chaque tour par chaque site
- $I(t)$ = nombre de sites infectés (contagieux ou immunisés) après le t-ième tour
- $p(t) = I(t)/N$ = proportion de sites infectés au t-ième tour

Alors $p(t) = \frac{1}{1+(N-1)*e^{-f*t}}$

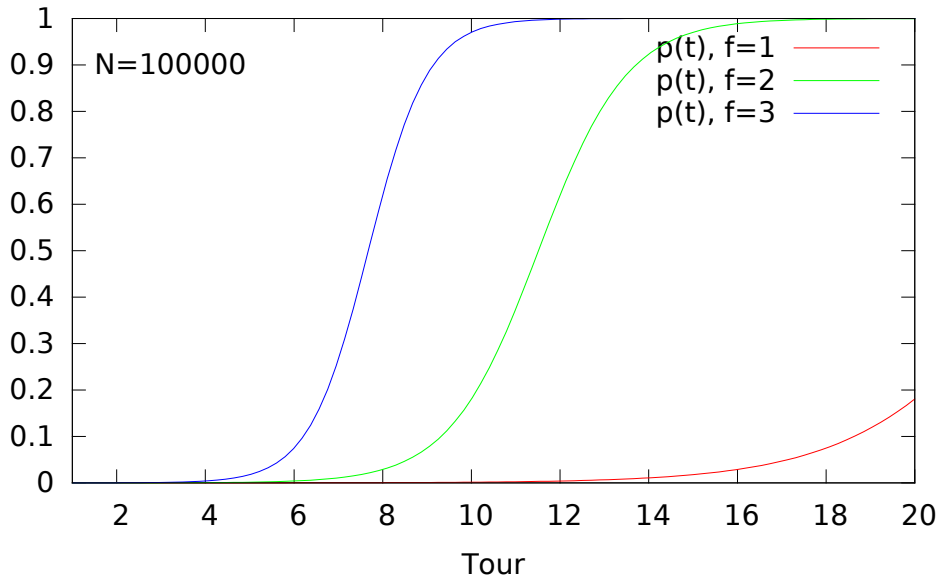

Rumeur : performance

Modèle simple : *infect and die* = immunisation après un seul tour

- N = nombre de sites
- f = nombre de sites contactés par chaque site
- P = probabilité que tous les sites finissent par être infectés (à l'∞)

Alors $P \approx e^{-e^{\log N - f}}$

Inversion autour de $f = \log N$

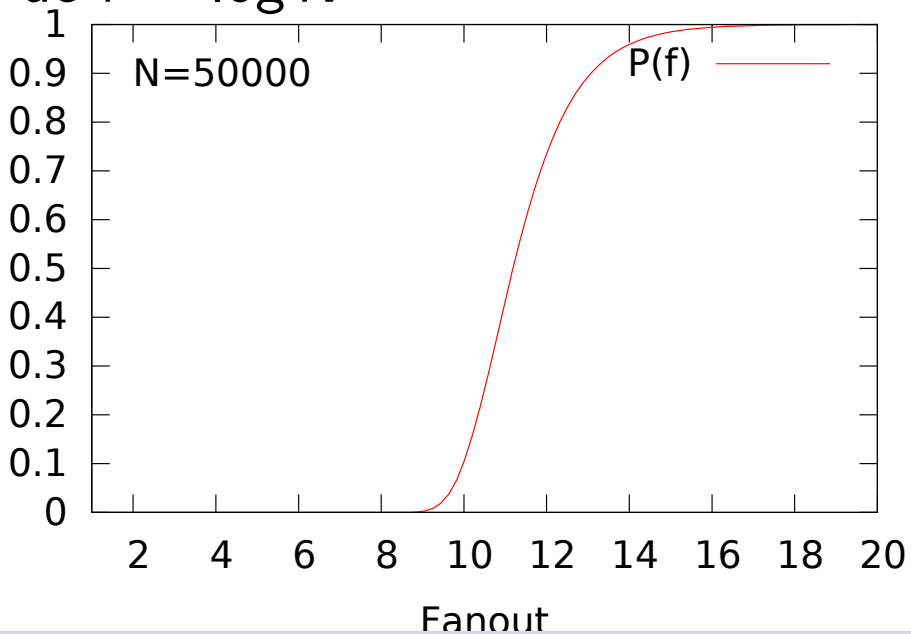

Rumeur : performance

Nombre de tours pour tout contaminer :

- Modèle sans immunisation (*infect forever*) :

$$R = \log_{f+1} n + \frac{1}{f} \log n + O(1)$$

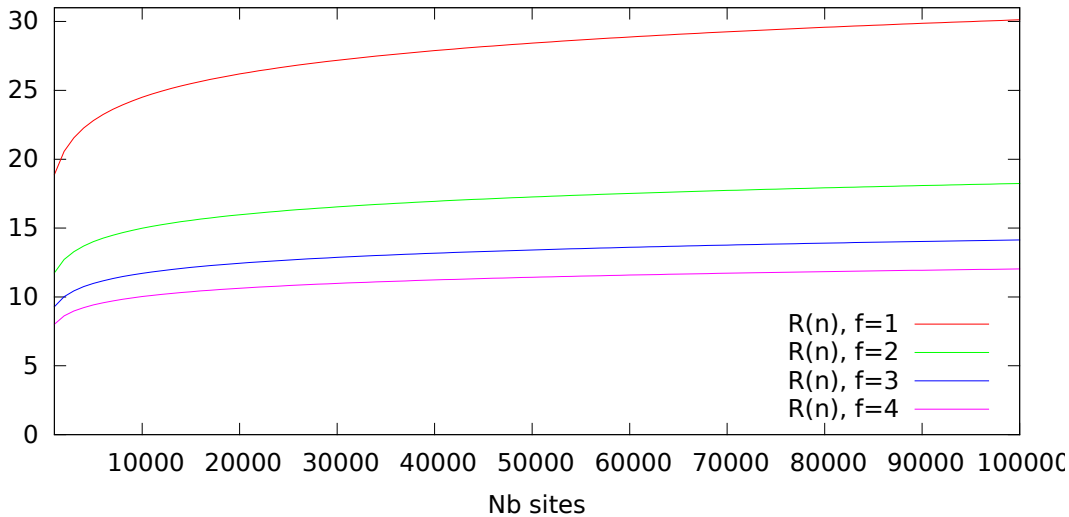

- Modèle immunisation immédiate (*infect and die*) :
  (fin de l'épidémie avec tous contaminés)

$$R = \frac{\log n}{\log \log n} + O(1)$$

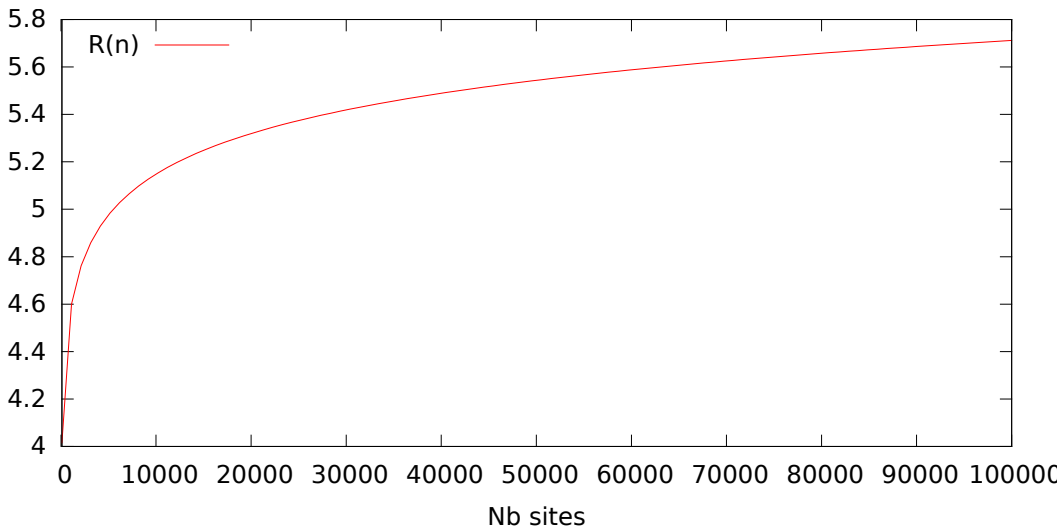

Rumeur : coût

- Diffusion probabiliste
- Existence de sites non informés (poches d'ignorance si le choix des sites est plutôt local)
- Nombre de messages élevés (échecs de contamination)

Algorithme épidémique : Anti-entropie

Anti-entropie

Périodiquement, chaque site contacte aléatoirement un autre site. Les deux sites échangent alors des informations, et leurs objets sont mis en cohérence.

L'algorithme converge vers l'égalité des copies : cohérence à terme.
Nombre de tours pour tout contaminer $= O(\log N)$

Graphes petit monde

Les algorithmes précédents n'ont pas de notion de voisinage : choix arbitraire d'un site quelconque (graphe complet).

Graphe petit monde *(small-world graphs)*

Graphe connexe vérifiant :

- Grand nombre de nœuds ($N > 10000$)
- Faible connectivité des nœuds (de l'ordre de 5 à 10)
- Distance entre deux nœuds quelconques $\approx \log N$

- Remarquablement adapté aux algorithmes épidémiques, résistant aux pannes (de sites et de liens)
- Apparaît spontanément (ex : réseau routier : maillage local, rocade, autoroutes)
- . . . ou pas (ex : réseau aérien avec quelques gros hubs à forte connectivité)

Plan

Problème à résoudre

- Stocker de l'information
- Trouver de l'information

$\Rightarrow$

- Utiliser l'ensemble des participants comme serveurs de stockage distribué
- Utiliser une partie des participants comme répertoire de nommage

Chaque nœud est à la fois client et serveur

Domaine d'application

Partage

- informations/fichiers
- ressources de calcul (grid computing)
- ressources de stockage (réplication)
- bande passante (CDN *Content delivery network*)
- interactions (jeux massivement multijoueur)

Réseaux de recouvrement

Réseau de recouvrement ou *overlay*

Réseau logique, virtuel, au-dessus d'un réseau physique existant

- Couche applicative
  - Réimplantation du routage
  - Ajout de fonctionnalité : nommage, stockage
- Pairs : réseau formé par les participants, tous (à peu près) égaux

Difficultés (1)

Maintenance du réseau de recouvrement

- Démarrage
  - Création du réseau ? (premier site : cas particulier)
  - Insertion/retrait d'un pair dans le réseau
- Maintenance continue
  - Faute, retrait involontaire, expulsion
- Terminaison : arrêt du réseau ?

Passage à l'échelle

- Éviter un (ou quelques) serveurs centralisés
- Distribuer la charge sur les pairs
- Borner la charge sur chaque pair (CPU, bande passante, stockage)

Difficultés (2)

Équité

- Équilibrer la charge : égalitairement ? proportionnellement ?
- Utilisateurs égoïstes : contrôles et incitations à l'équité

Défaillances

- Maintenance de l'overlay à tout prix
- Défaillances de pairs, de liens de communication
- Partition temporaire du réseau, réinsertion ?

Difficultés (3)

Adaptabilité

- Ajout/retrait de sites par vagues (heures ouvrables)
- Ajout/retrait d'informations
  parfois massif (plusieurs milliers d'un coup)

Performance

- Efficacité : localisation, accès
- Latence du réseau (localité d'accès)
- Parallélisation

Classification : contrôle

- Contrôle centralisé : un serveur central met en correspondance les pairs
  - \+ simple
  - – fragile
  - – faible capacité de croissance
- Contrôle totalement décentralisé : tous les nœuds jouent un rôle symétrique (client et serveur)
  - \+ pas de point central, confidentialité
  - \+ disponibilité élevée
  - – complexe, gestion hasardeuse
  - – performance indéterminée
- Contrôle partiellement décentralisé : un ensemble dynamique de nœuds jouent un rôle privilégié

Classification : réseau virtuel

- Non structuré : le placement des données n'est pas lié à la topologie du réseau
  - \+ bonne adaptabilité avec un ensemble de nœuds très dynamique
  - − recherche inefficace en absence de contrôle centralisé
- Structuré : les données sont placées en des points prédéterminées $\Rightarrow$ recherche déterministe
  - \+ recherche rapide, en temps borné
  - − ensemble de nœuds dynamique ?
- Faiblement structuré : partiellement déterministe

Classification

	Réseau virtuel		
	non structuré	faiblement structuré	structuré
contrôle centralisé	Napster		
partiellement décentralisé	eMule, FastTrack, Gnutella		
totalement décentralisé	BitTorrent	Freenet	Chord, Pastry

Contrôle centralisé – Napster simplifié

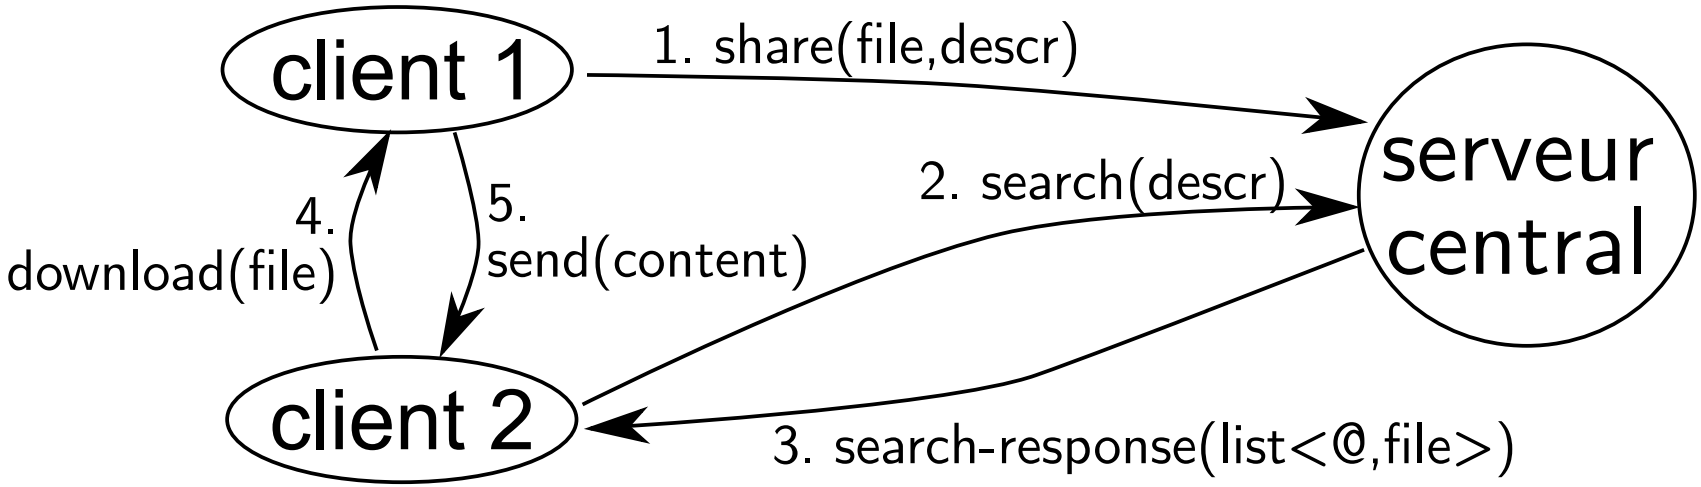

- Un serveur central : l'annuaire
- Des clients pairs : stockage

Contrôle décentralisé – Gnutella

Chaque nœud est client, serveur et routeur
Messages

- `ping` : pour découvrir des correspondants
  bootstrap : *gnutella caches* notoires puis par rebond
- `pong` : en réponse (+ informations : nb/taille des fichiers possédés)
- `query` : recherche (mots clefs)
- `query-hit` : en réponse (@ IP, id fichiers)

Gnutella : recherche

- Recherche par inondation : requête `query` transmise de voisin en voisin
- Id unique : éviter les retransmissions en boucle
- nombre de retransmissions (hops) limité

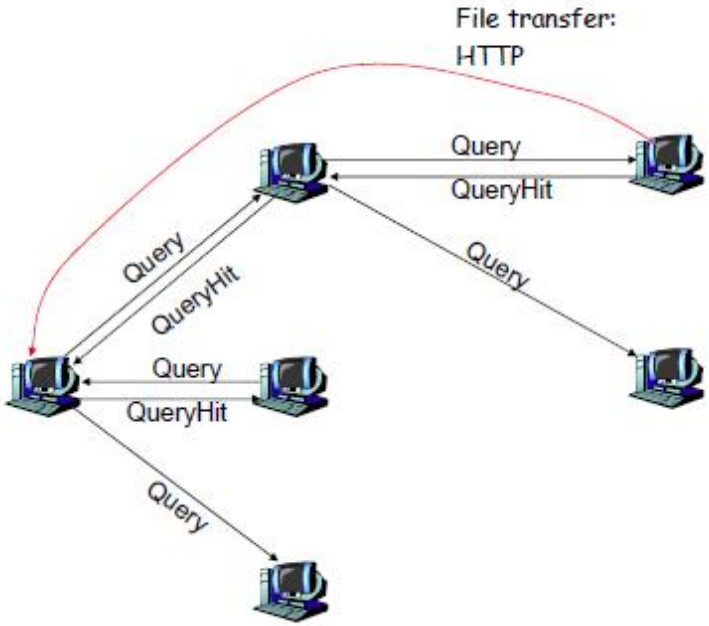

Améliorations :

- Envoi aléatoire, effectué en parallèle
- Distinction entre nœuds feuilles (connectés à 2 ou 3 ultranœuds) et ultranœuds (puissants, fortement interconnectés) $\Rightarrow$ nombre réduit de hops

(source : Original uploader was ACNS at en.wikipedia – Commons CC BY-SA 3.0)

Table de hachage répartie (DHT)

Table de hachage répartie = *distributed hash table*

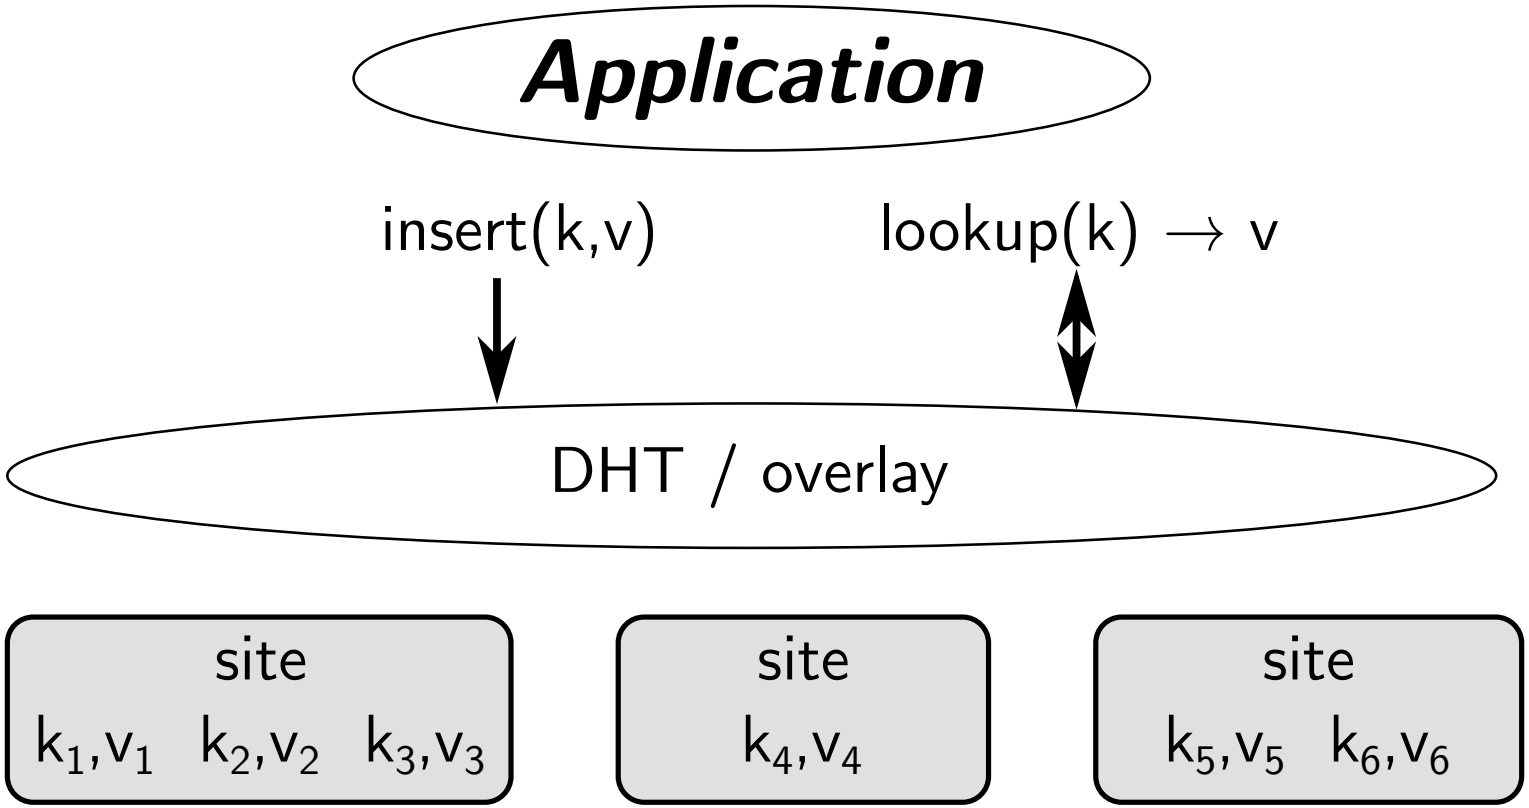

Table de hachage répartie (DHT)

L'infrastructure P2P établit le lien entre clef et site :

- Chaque site possède une ID : p.e. hachage de son adresse IP
- Chaque objet possède une clef et une valeur
- La clef d'un objet est p.e. le hachage de sa valeur, ou de son nom, ou de sa description...
- Chaque site est responsable d'une partie de l'espace de hachage, p.e. des clefs qui sont proches de son ID

$\Rightarrow$

- Pas de connaissance globale centralisée
- Pas de point unique de défaillance
- Passage à l'échelle
- Répartition de la responsabilité

Exemple de DHT : Pastry

- Les sites sont organisés en anneau virtuel (rangé par ID)
- Chaque site connaît le suivant et le précédent
- L'espace des clefs est partagé : le site le plus proche est responsable d'une clef

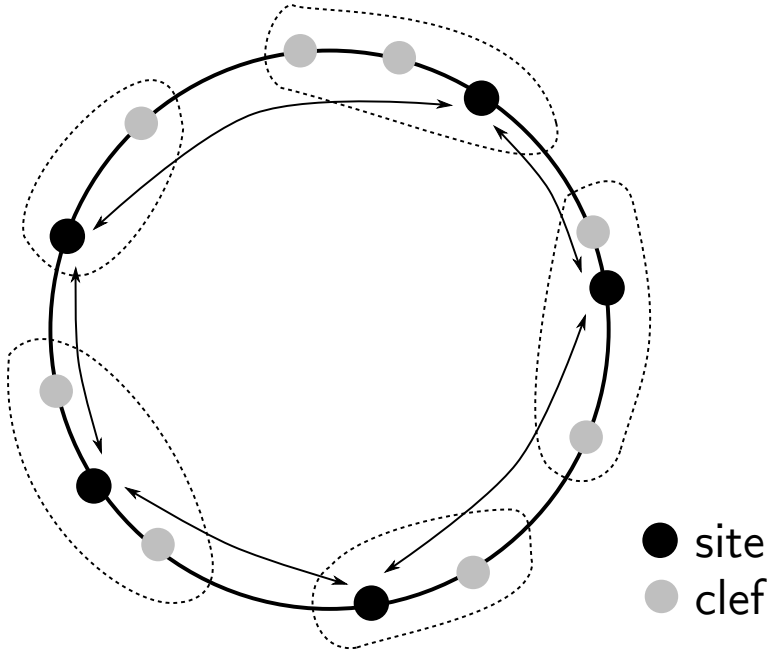

Routage : trouver le nœud responsable d'une clef

route(key, msg) : acheminer le message (spécifique à l'application) au site en charge de la clef

Pastry : routage

Routage en suivant les liens suivants/précédents inefficace ⇒ table de routage

- N sites ($N = 16$ millions)
- Chaque site possède une ID : P digits sur B bits (B = 16, $P = \lceil \log_B N \rceil$). ex : 65a1fc
- Chaque site a une table de routage à P lignes, B colonnes
- La case (i, j) est l'adresse d'un site ayant les i premiers digits identiques au site, et j en $i + 1$ digit.
  ex : sur le site 65a1fc, ligne 3, col 4 = site 65a4xx

$L0$	0	1	2	3	4	5	6	7	8	9	a	b	c	d	e	f
$L1$	60	61	62	63	64	65	66	67	68	69	6a	6b	6c	6d	6e	6f
$L2$	650	651	652	653	654	665	656	657	658	659	65a	65b	65c	65d	65e	65f
$L3$	65a0	65a1	65a2	65a3	65a4	65a5	65a6	65a7	65a8	65a9	65aa	65ab	65ac	65ad	65ae	65af
...																

- Trouver une clef = chercher le premier digit distinct et transmettre à ce site, qui poursuit le routage

Pastry : Routage

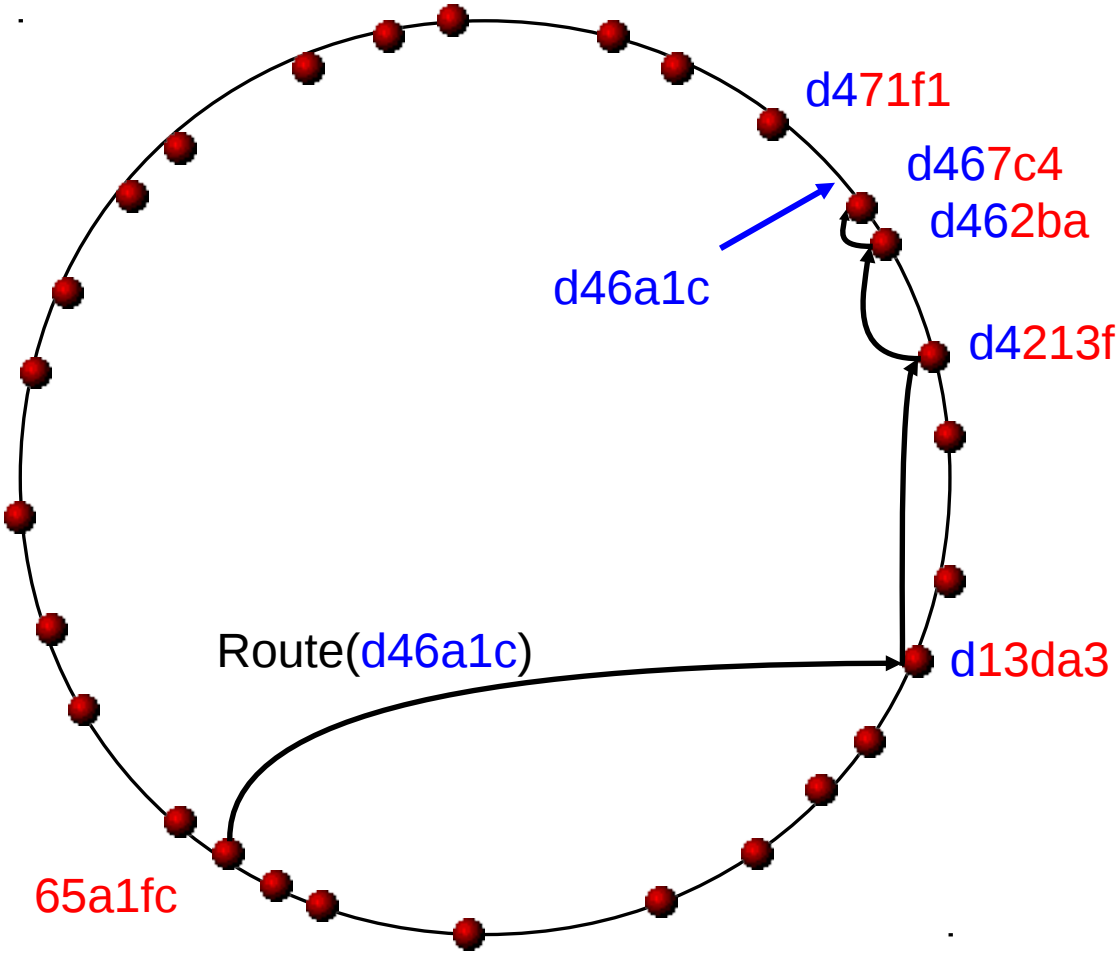

Dessin : Peter Druschel

- max $\log_{16} N$ hops
- table de routage (par site) : $O(\log N)$

Pastry : voisinage (*Leaf sets*)

Chaque site maintient les $L/2$ plus proches sites en deçà et en delà

- efficacité du routage
- résistance du routage
- détection de fautes (ping périodique)

Pastry : algorithme de routage

```
if (destination ∈ voisinage) then
    transmettre le message au membre concerné
else
    let l ≜ longueur du préfix commun entre ce site
                                        et la destination
    let d ≜ valeur du l-ième digit
    if routage[l,d] est défini et répond then
        transmettre le message à routage[l,d]
    else
        transmettre à un site qui
            - a au moins un préfixe commun de taille l
            - est numériquement plus proche que ce site
```

Pastry : jonction

1. Le site d'id i veut s'insérer
2. Il envoie un message *join* à n'importe quel site
3. Ce message est routé comme précédemment au site j, actuellement responsable de i. Le site j sera inséré entre j et k (précédent ou suivant de j selon la valeur de i)
4. Le site j transmet à i son voisinage pour que i construise son voisinage initial
5. La table de routage de i est établie à partir des tables de j et k
6. Le site i interroge tous les sites de son voisinage initial :
   - i établit son voisinage définitif en gardant les $L/2$ plus proches dans chaque sens
   - Les sites du voisinage apprennent i et mettent à jour leurs propres table de routage et voisinage
7. Le site i devient actif

Seule difficulté : 2 insertions simultanées entre 2 même nœuds !

Pastry : départ (défaillance)

Les membres d'un voisinage s'échangent périodiquement des messages de vie
Absence de réponse sur un message de vie ou un message de routage $\Rightarrow$ considéré défaillant, enlevé du voisinage + de la table de routage si présent

- Réparation du voisinage : augmenter son voisinage en demandant au site le plus loin dans son voisinage actuel
- Réparation du routage : obtenir la table des sites sur la même rangée que le site supprimé, puis en remontant

Pastry : bilan

Points positifs

- Passe à l'échelle, résistant à $L/2$ fautes simultanées (et en pratique bien plus), non centralisé (auto-organisation)
- Routage efficace $O(\log N)$ hops et messages en situation normale, $O(N)$ en cas pire (improbable)
- Information par site modeste $O(\log N)$

Améliorations

- Routage : prendre en compte la distance (en temps) pour établir la table de routage
- Réplication : un même objet clef/valeur est répliqué sur plusieurs nœuds voisins
- Sécurité : hachage non inversible avec peu de collision (SHA)

Conclusion

- Systèmes non structurés : performant si contrôle assez centralisé $\Rightarrow$ capacité de croissance ? anonymat ?
- Systèmes structurés : dynamicité ?
- Contrôle décentralisé $\Rightarrow$ qualité de service ?
  - sécurité, confiance ?
  - disponibilité non garantie (mais plutôt bonne)
  - site parasite ?
- Aucun standard, même architecturellement