Pair à pair

Pair à pair

- quelques principes
  - les nœuds offrent des fonctionnalités identiques (pair)
  - volatilité importante (apparition/disparition)
  - grande échelle et dispersion géographique
  - dynamicité importante
- applications
  - partage de fichiers
  - messagerie
  - téléphone (Skype)
  - ...

différent du client-serveur

Partage de fichiers

- Communication basée sur deux types de protocoles différents
  - découverte et localisation des fichiers
    - recherche des données
    - mettre en contact deux (ou plusieurs) utilisateurs parmi des millions
  - téléchargement des fichiers

Découverte-localisation

- Base
  - publication des fichiers partagés avec des méta-données
  - découverte des fichiers disponibles
  - localisation des sources à télécharger
  - (En plus
    - identification des doublons
    - détection des fichiers corrompus
    - forums)

Architecture du réseau

- Centralisée: un serveur ou un cluster sur lequel les clients se connectent (Napster)
- Décentralisée: il n'y a que des clients (Gnutella)
- Faiblement centralisée: des clients et des serveurs (Edonkey)
- Hybride: les clients peuvent devenir des serveurs

P2P: problems with centralized directory

- Single point of failure
- Performance bottleneck
- Copyright infringement

file transfer is decentralized, but locating content is highly centralized

Pure P2P architecture

- *no* always-on server
- arbitrary end systems directly communicate
- peers are intermittently connected and change IP addresses

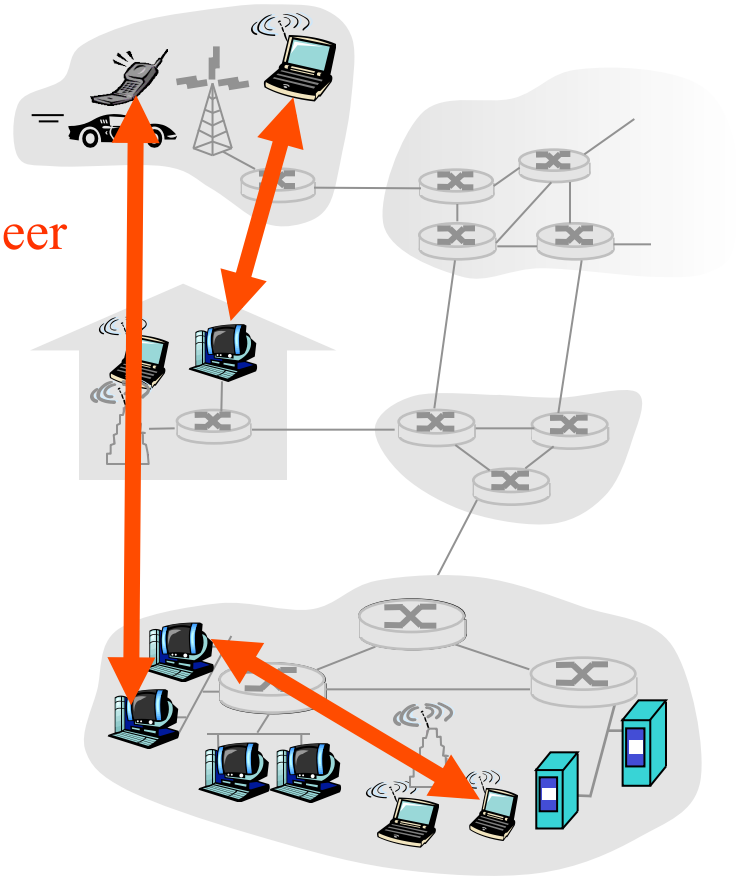

- Three topics:
  - File distribution
  - Searching for information
  - Case Study: Skype

File Distribution: Server-Client vs P2P

Question : How much time to distribute file from one server to *N peers*?

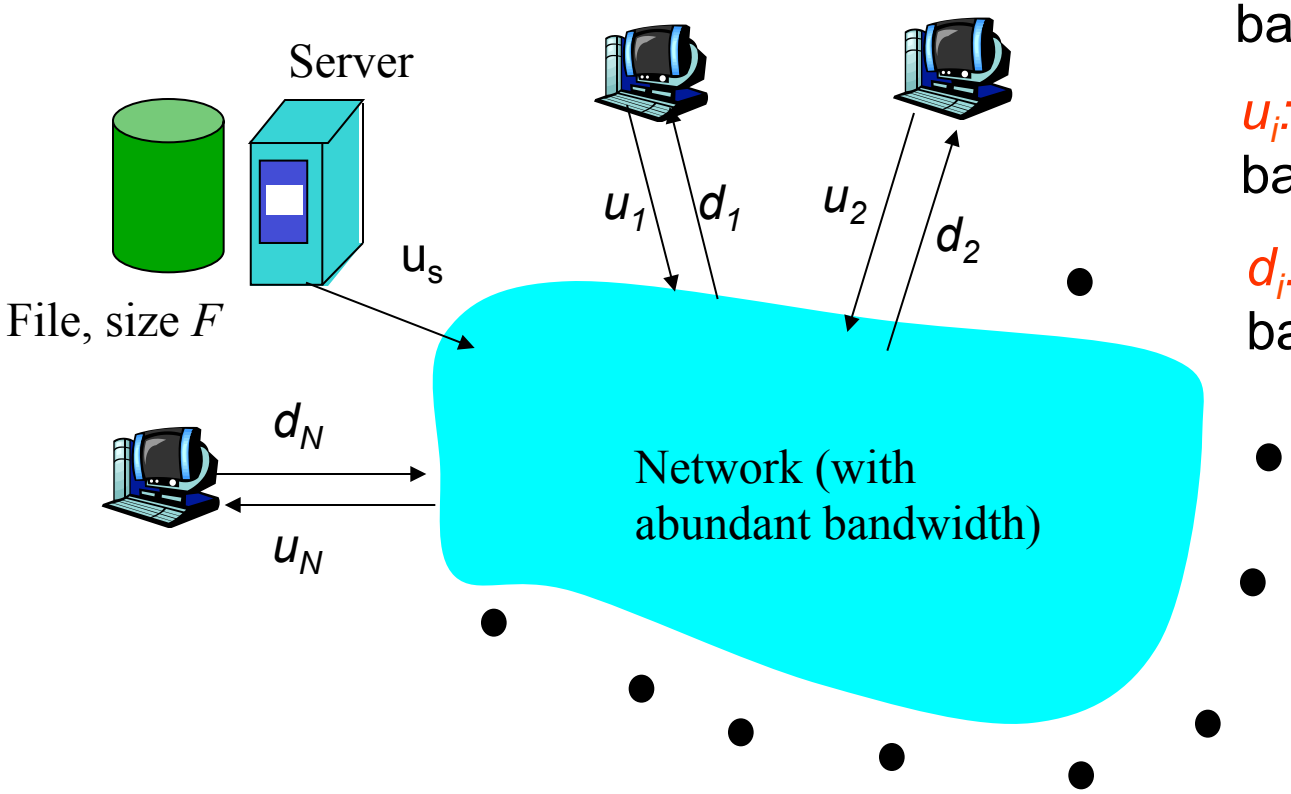

u_s: server upload bandwidth

u_i: peer i upload bandwidth

d_i: peer i download bandwidth

File distribution time: server-client

- server sequentially sends N copies:
  - NF/u_s time
- client i takes F/d_i time to download

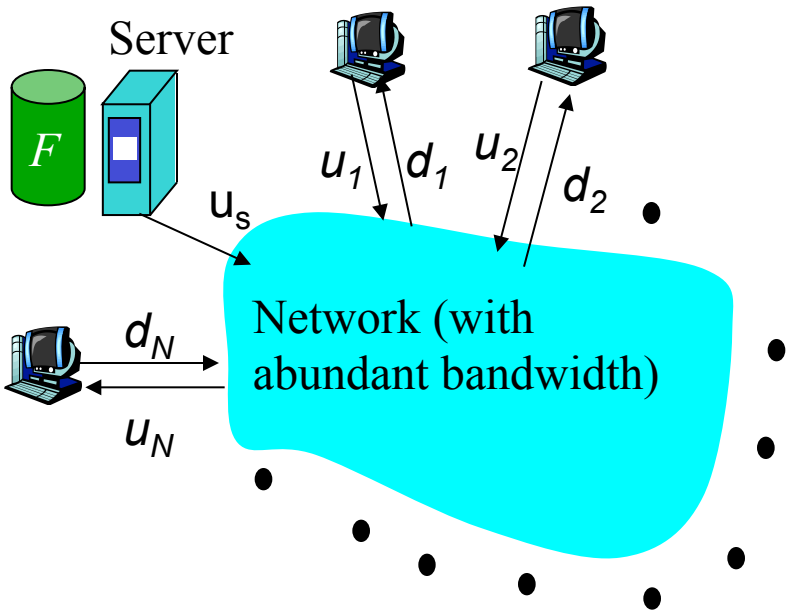

Time to distribute F to N clients using client/server approach $= d_{cs} = \max \{ NF/u_s, F/\min_i(d_i) \}$

increases linearly in N (for large N)

File distribution time: P2P

- server must send one copy: F/u_s time
- client i takes F/d_i time to download
- NF bits must be downloaded (aggregate)
  - fastest possible upload rate: $u_s + Su_i$

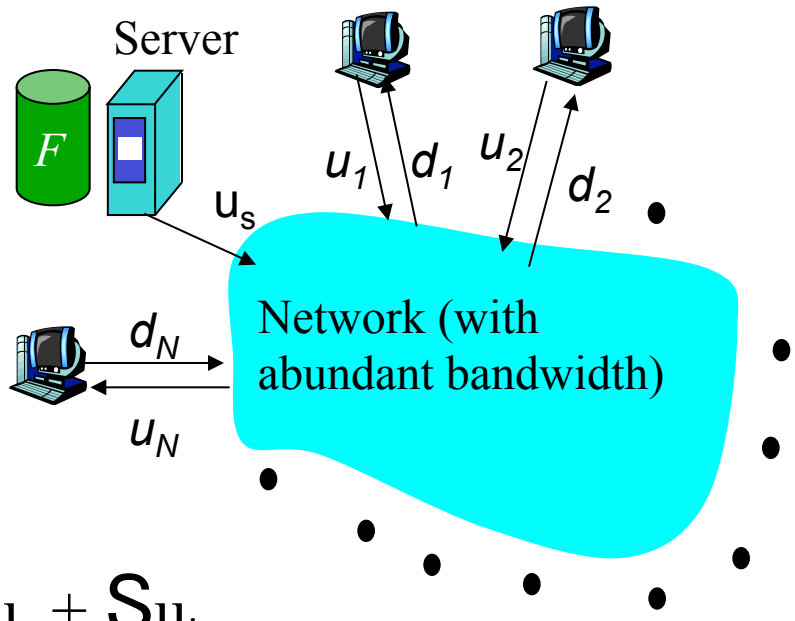

$$d_{P2P} = \max \{ F/u_s, F/min(d_i) , NF/(u_s + Su_i) \}_i$$

Server-client vs. P2P: example

Client upload rate = u, F/u = 1 hour, $u_s = 10u$, $d_{min} \geq u_s$

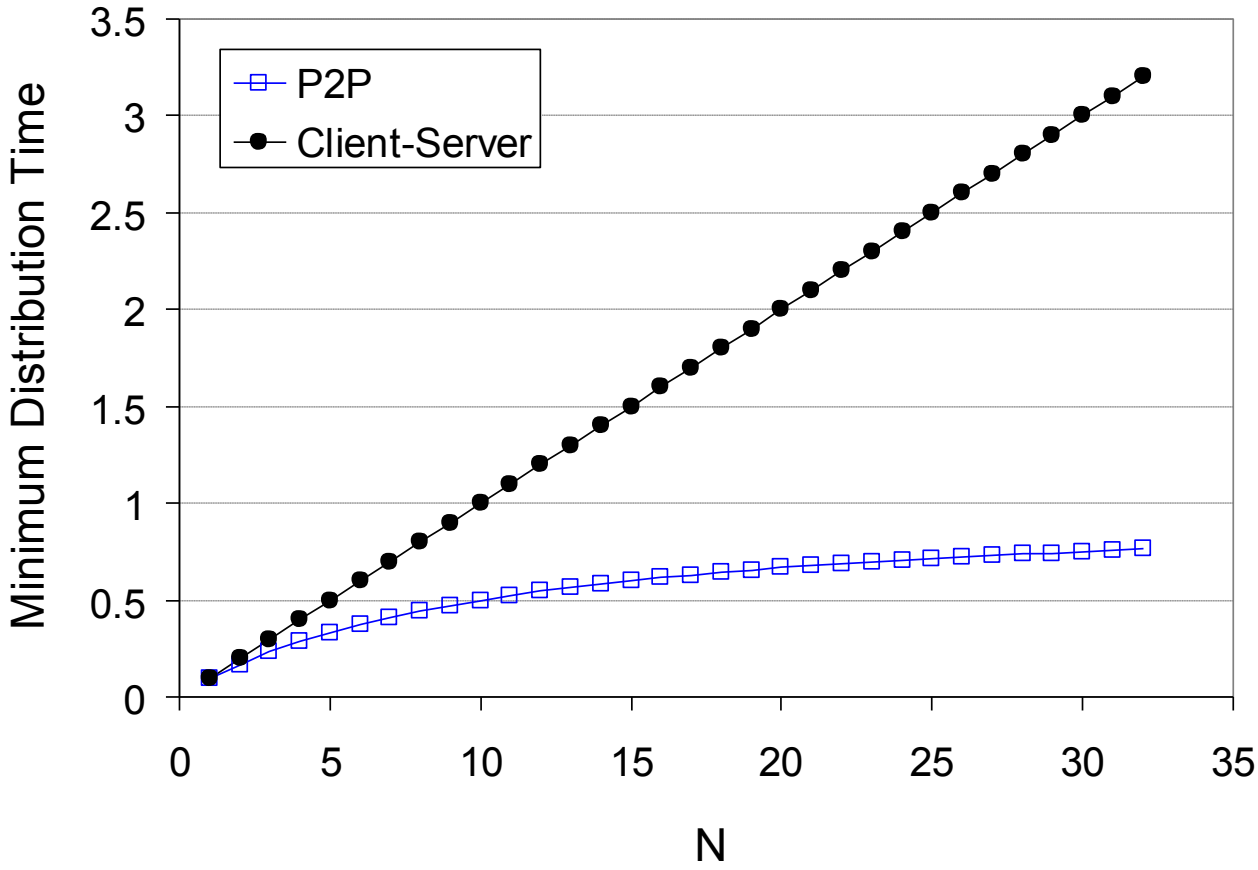

Quelques exemples

Query flooding: Gnutella

- fully distributed
  - no central server
- public domain protocol
- many Gnutella clients implementing protocol

overlay network: graph

- edge between peer X and Y if there's a TCP connection
- all active peers and edges is overlay net
- Edge is not a physical link
- Given peer will typically be connected with < 10 overlay neighbors

Gnutella: protocol

- Query message sent over existing TCP connections
- peers forward Query message
- QueryHit sent over reverse path

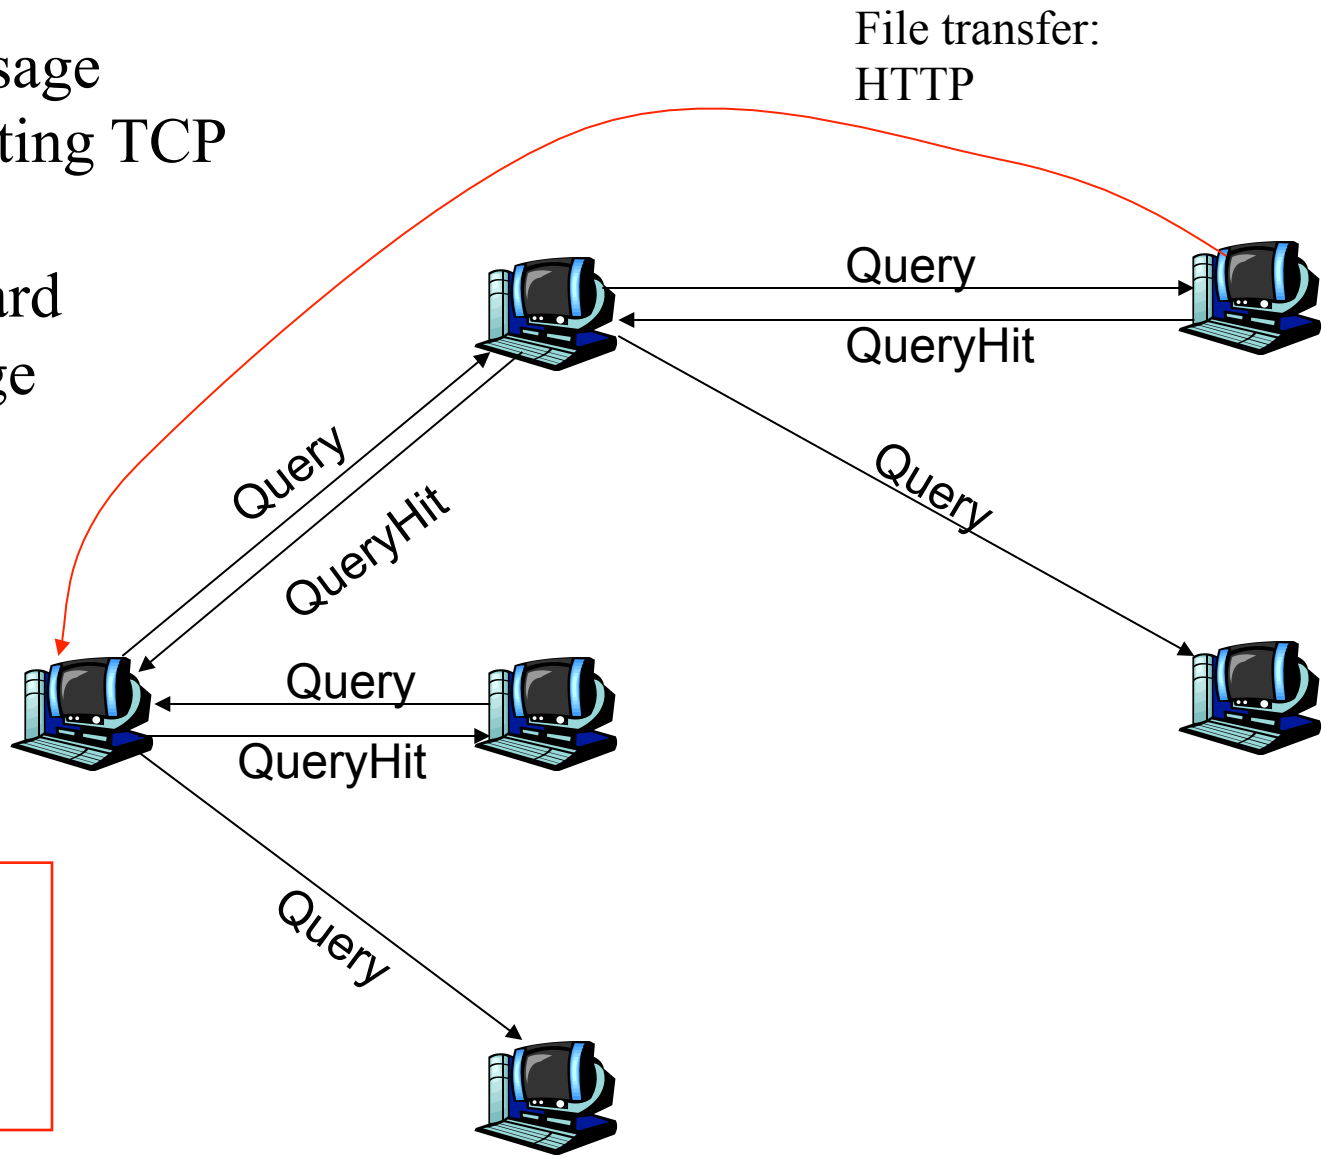

Scalability: limited scope flooding

Gnutella: Peer joining

1. Joining peer X must find some other peer in Gnutella network: use list of candidate peers
2. X sequentially attempts to make TCP with peers on list until connection setup with Y
3. X sends Ping message to Y; Y forwards Ping message.
4. All peers receiving Ping message respond with Pong message
5. X receives many Pong messages. It can then setup additional TCP connections

Exploiting heterogeneity: KaZaA

- Each peer is either a group leader or assigned to a group leader.
  - TCP connection between peer and its group leader.
  - TCP connections between some pairs of group leaders.
- Group leader tracks the content in all its children.

KaZaA: Querying

- Each file has a hash and a descriptor
- Client sends keyword query to its group leader
- Group leader responds with matches:
  - For each match: metadata, hash, IP address
- If group leader forwards query to other group leaders, they respond with matches
- Client then selects files for downloading
  - HTTP requests using hash as identifier sent to peers holding desired file

KaZaA tricks

- Limitations on simultaneous uploads
- Request queuing
- Incentive priorities
- Parallel downloading

File distribution: BitTorrent

- P2P file distribution

tracker: tracks peers participating in torrent

torrent: group of peers exchanging chunks of a file

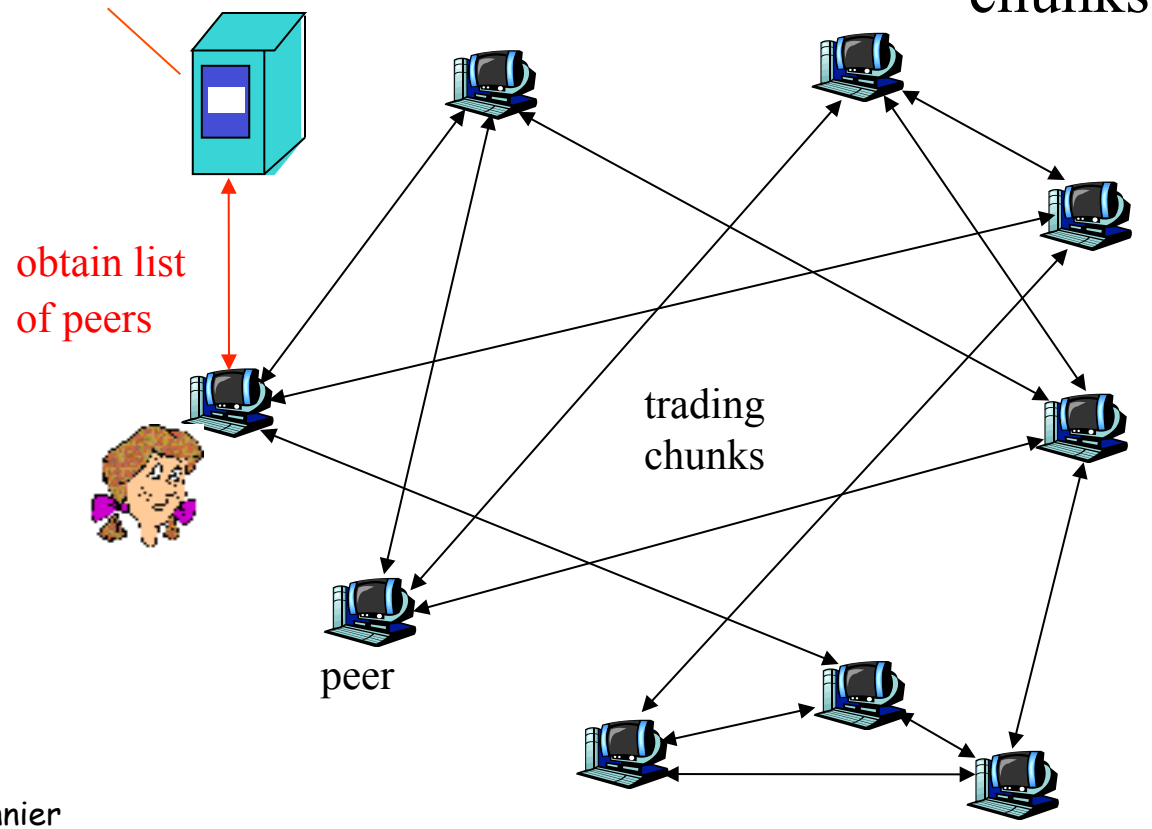

BitTorrent (1)

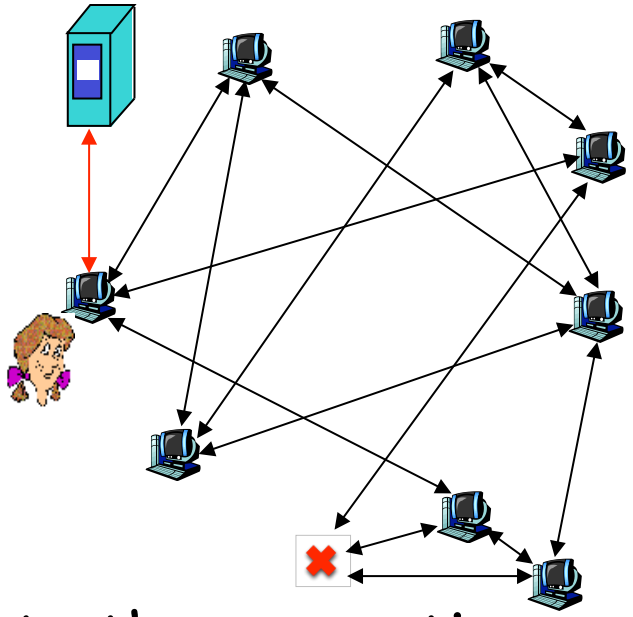

- file divided into 256KB *chunks*.
- peer joining torrent:
  - has no chunks, but will accumulate them over time
  - registers with tracker to get list of peers, connects to subset of peers ("neighbors")
- while downloading, peer uploads chunks to other peers.
- peers may come and go (churn)
- once peer has entire file, it may (selfishly) leave or (altruistically) remain

BitTorrent (2)

Pulling Chunks

- at any given time, different peers have different subsets of file chunks
- periodically, a peer (Alice) asks each neighbor for list of chunks that they have.
- Alice sends requests for her missing chunks
  - rarest first

Sending Chunks: tit-for-tat

- Alice sends chunks to four neighbors currently sending her chunks *at the highest rate*
  - re-evaluate top 4 every 10 secs
- every 30 secs: randomly select another peer, starts sending chunks
  - newly chosen peer may join top 4
  - "optimistically unchoke"

BitTorrent: Tit-for-tat

(1) Alice "optimistically unchokes" Bob

(2) Alice becomes one of Bob's top-four providers; Bob reciprocates

(3) Bob becomes one of Alice's top-four providers

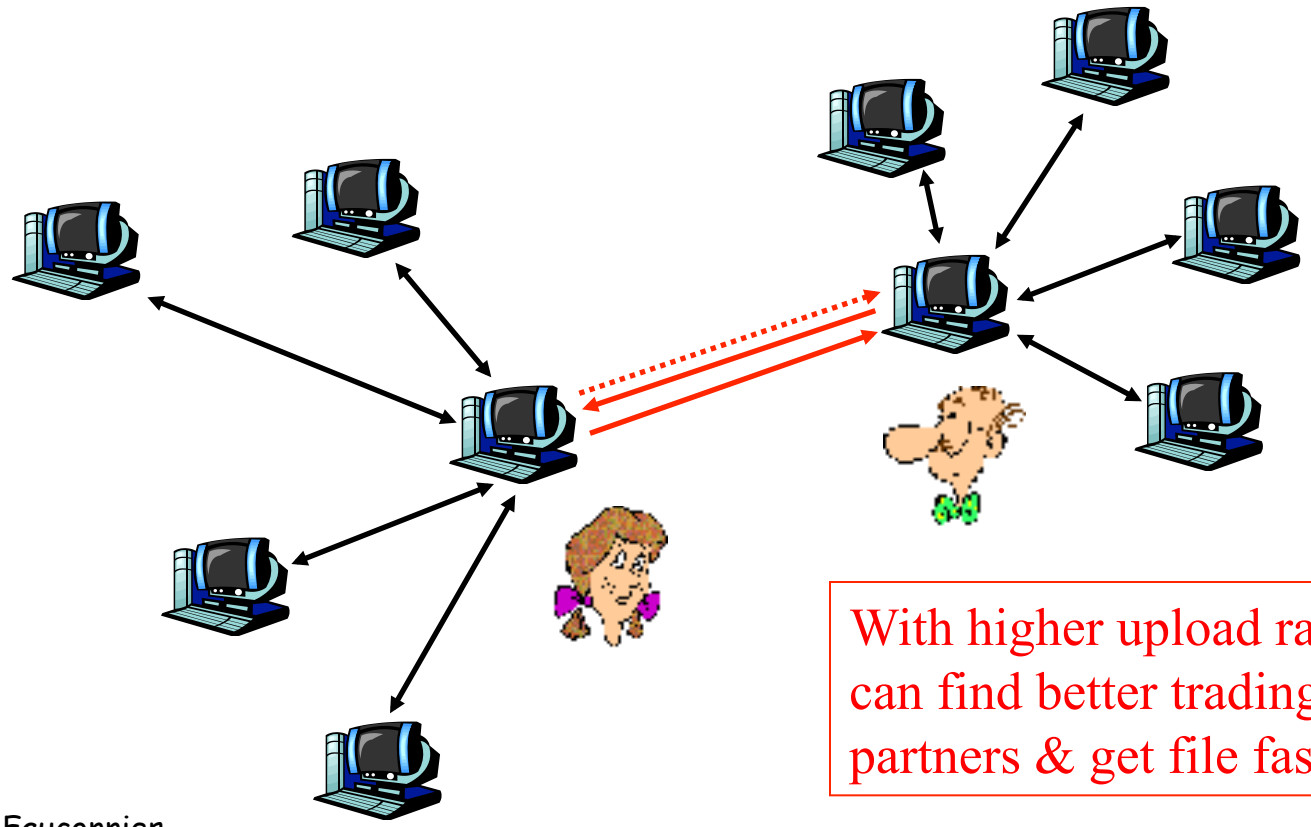

With higher upload rate, can find better trading partners & get file faster!

Rechercher

Recherche par diffusion simple

- les clients ne publient rien et ne font que des requêtes
  - une requête est diffusée à tous les clients:
    - avec une limite de portée (TTL)
    - en évitant les cycles (identification unique de la requête, la requête contient le son chemin …)
    - recherche en profondeur ou en largeur
  - un client répond par le chemin emprunté par la requête

Filtres de Bloom

- Principe:
  - un ensemble E de n éléments
  - k fonctions de hachage h_i de E sur {1,m}
  - un vecteur de m bits (le filtre)
  - tester si x appartient à E si
    - si le bit $h_i(x)=0$ pour un i non
    - si le bit $h_i(x)=1$ pour tout i oui (mais peut être faux-positif)
  - On diminue les faux positifs en utilisant plusieurs fonctions de hachage
    - Pour m et n donné le k optimal est m/n ln 2 et la probabilité de faux-positifs est $(1/2)^k$

Exemple: Filtres de Bloom

- Trois fonctions de hachage
- W n'appartient pas à E

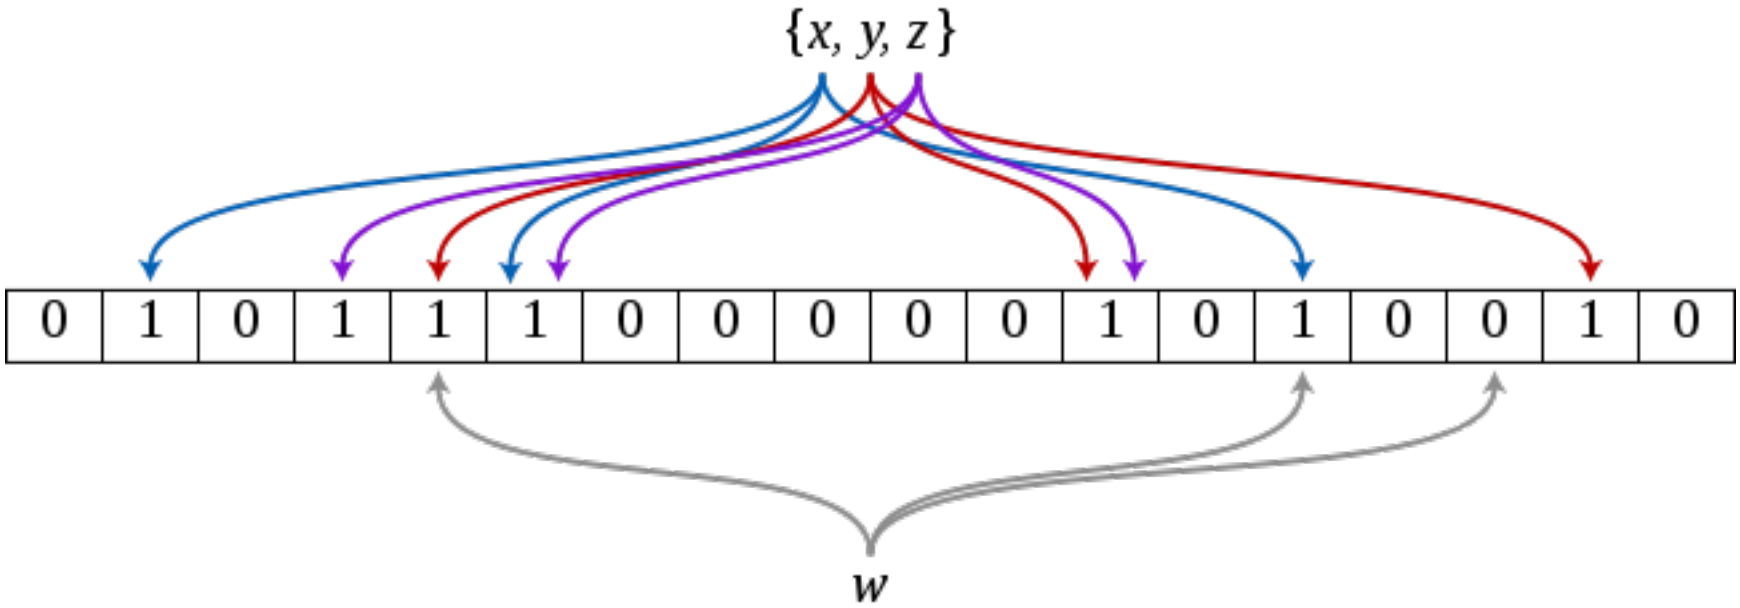

Filtres de Bloom

- Utilisation:
  - Si le client possède le document les bits des mot-clés correspondant sont à 1
  - Les clients s'échangent les filtres
  - Les requêtes ne sont propagées que vers les clients qui ont le bon filtre

Recherche par indexation

- Les clients publient les fichiers qu'ils partagent sur les serveurs sur lesquels ils sont connectés
- Les serveurs indexent les descriptions des fichiers
- Les clients envoient des requêtes aux serveurs pour trouver les fichiers et les localiser

Recherche par DHT

- Distributed Hash Table:
  - Des nœuds et des données
    - Un espace de clés (exemple: clés de 160 bits)
    - Un répartition des clés (qui possède les clés?)
    - Un "overlay" de connexion entre les nœuds pour qui permet de savoir quel nœud possède quelle clé.

Distributed Hash Table (DHT)

- DHT = base de données pour P2P
- Contient des couples (key, value)
  - key: numero SS; value: nom
  - key: content type; value: adresse IP
- Un pair query la DHT par une key
  - retourne les values correspondant à la key
- Un pair peut aussi inserer des couples (key, value)

DHT

- Stocker un fichier f de contenu data:
  - Un hachage (SHA1 par exemple) produit une clé de 160 bits k à partir du nom f
  - Par un put(k, data) sur l'overlay trouver le nœud responsable pour la clé k et lui transférer les données
- Rechercher un fichier f:
  - Par hachage (SHA1) obtenir la clé k associée à f
  - Rechercher sur l'overlay le nœud responsable de k et récupérer les données

DHT: hachage consistant

- On associe à chaque document (ou mot-clé) un identificateur unique (hachage)
- On associe à chaque client un identificateur unique de même taille ID
- On définit une métrique pour définir la distance d entre les clés-ID
- Un nœud ID i possède les clés j telles que d(j,i) est minimal parmi les ID (chaque nœud possède les clés les plus proches)

Le retrait ou l'ajout d'un nœud ne modifie que les voisins

DHT

- notion d'overlay: chaque nœud maintient des liens vers d'autres nœuds, on obtient ainsi un overlay. Comment obtenir un routage efficace
- Un nœud soit possède la clé soit connaît un nœud plus près de la clé: on peut utiliser algorithme glouton basé sur la clé.
- On peut aussi définir d'autres algorithmes de routage sur des overlays (et définir des topologies d'overlays ayant de bonnes propriétés –degré et taille des routes).

DHT

- exemple Chord:
  - points sur un cercle la distance est la longueur de l'arc orienté. L'espace des clés est décomposé en segments. Si i et j sont des nœuds adjacents, i a toutes les clés comprises entre i et j
  - Anneau de taille 2^m (clés de 0 à 2^m-1)
  - Hachage par SHA1 (ID-clés réparties de façon uniforme)
  - Chaque nœud maintient une liste de K successeurs et K prédécesseurs sur l'anneau

DHT Identifiers

- Assign integer identifier to each peer in range $[0,2^n-1]$.
  - Each identifier can be represented by n bits.
- Require each key to be an integer in same range.
- To get integer keys, hash original key.
  - eg, key = h("Led Zeppelin IV")
  - This is why they call it a distributed "hash" table

How to assign keys to peers?

- Central issue:
  - Assigning (key, value) pairs to peers.
- Rule: assign key to the peer that has the closest ID.
- Convention in lecture: closest is the immediate successor of the key.
- Ex: n=4; peers: 1,3,4,5,8,10,12,14;
  - key = 13, then successor peer = 14
  - key = 15, then successor peer = 1

Circular DHT (1)

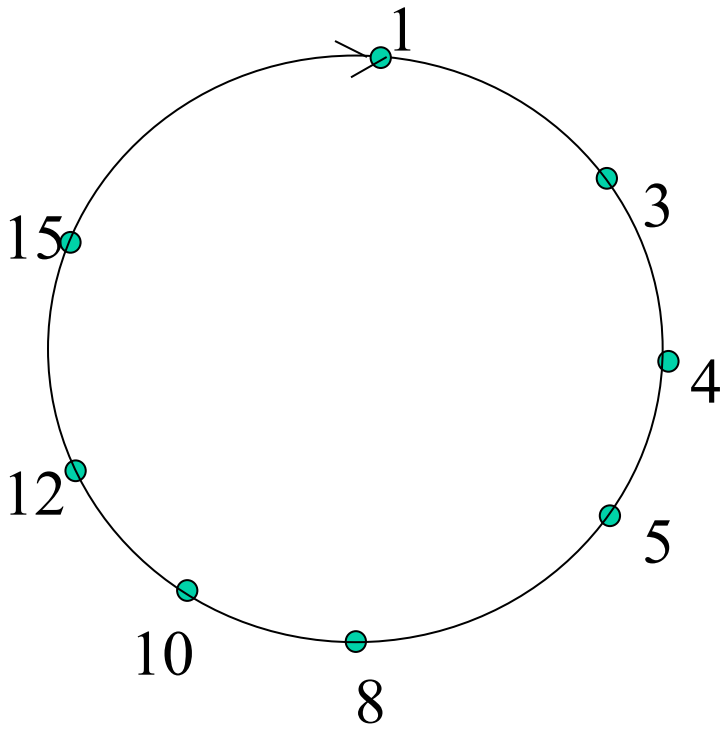

- Each peer *only* aware of immediate successor and predecessor.
- "Overlay network"

Circle DHT (2)

O(N) messages on avg to resolve query, when there are N peers

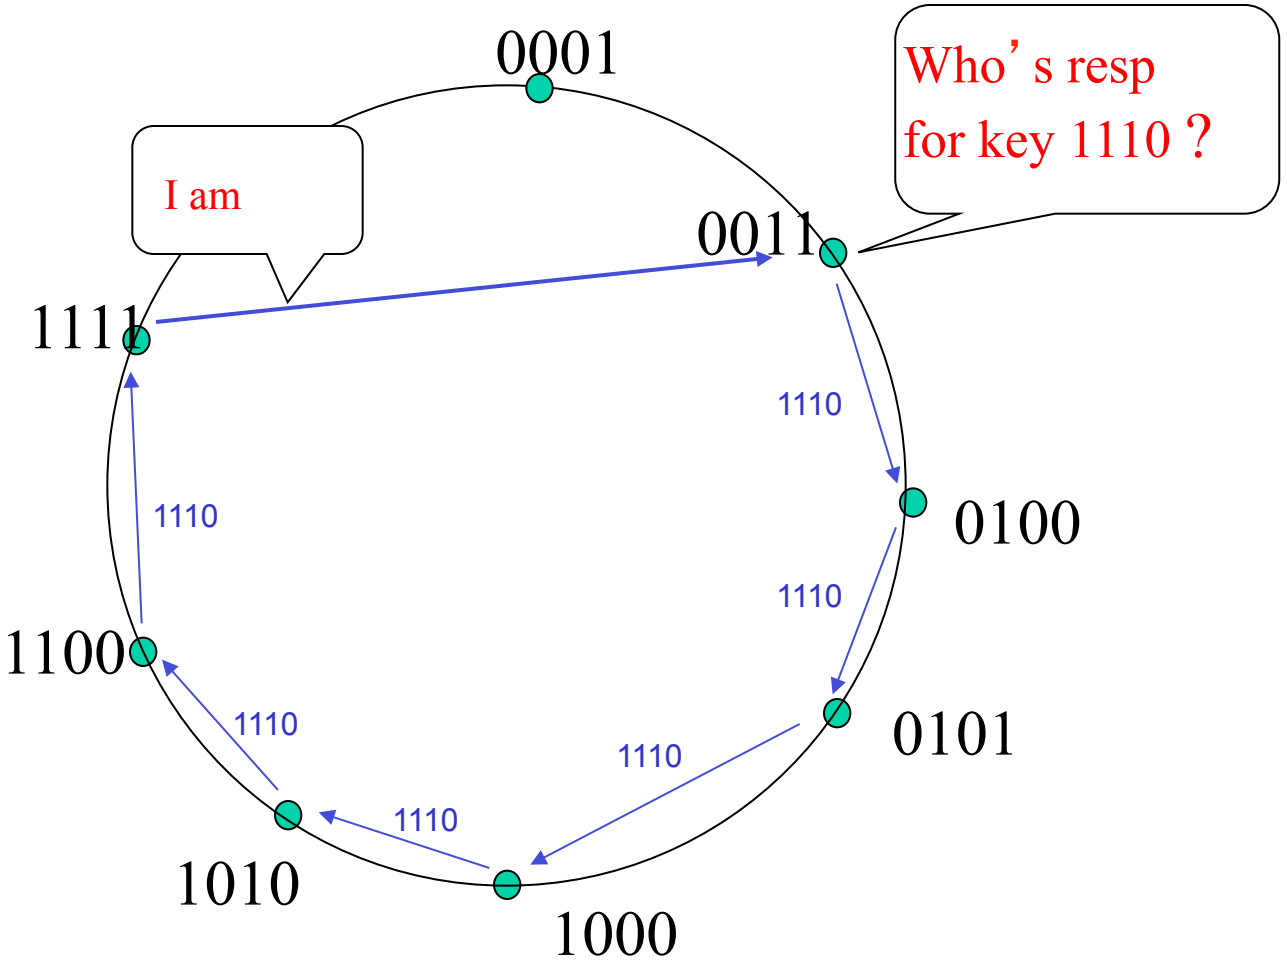

Define closest as closest successor

Peer Churn

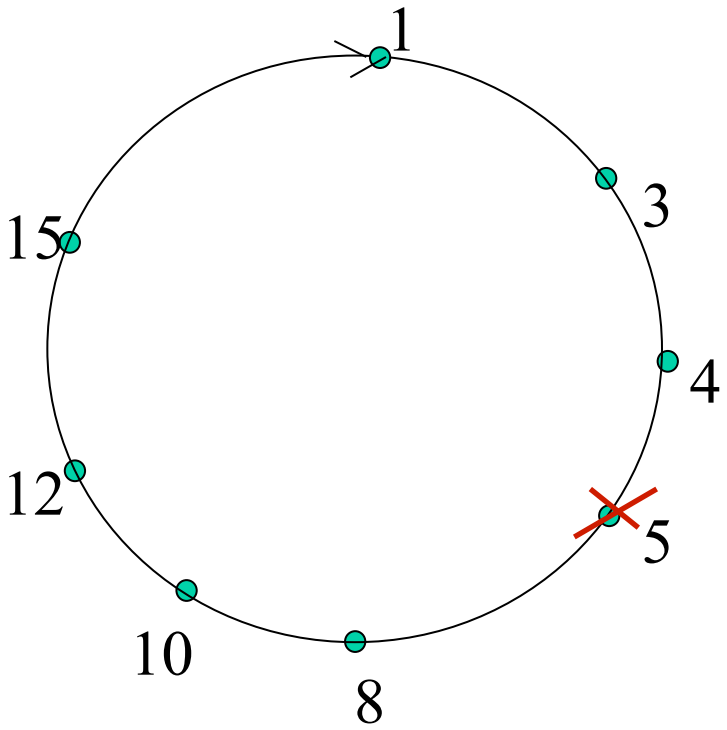

•To handle peer churn, require each peer to know the IP address of its two successors.
• Each peer periodically pings its two successors to see if they are still alive.

- Peer 5 abruptly leaves
- Peer 4 detects; makes 8 its immediate successor; asks 8 who its immediate successor is; makes 8's immediate successor its second successor.
- What if peer 13 wants to join?

Circular DHT with Shortcuts

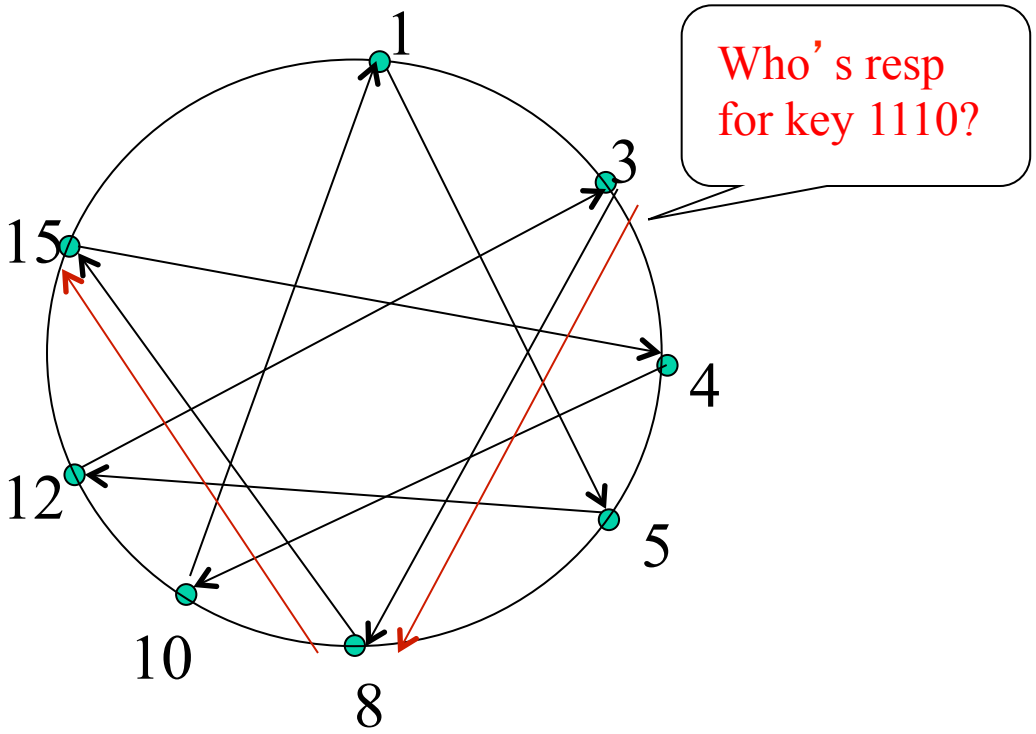

- Each peer keeps track of IP addresses of predecessor, successor, short cuts.
- Reduced from 6 to 2 messages.
- Possible to design shortcuts so O(log N) neighbors, O(log N) messages in query

Chord

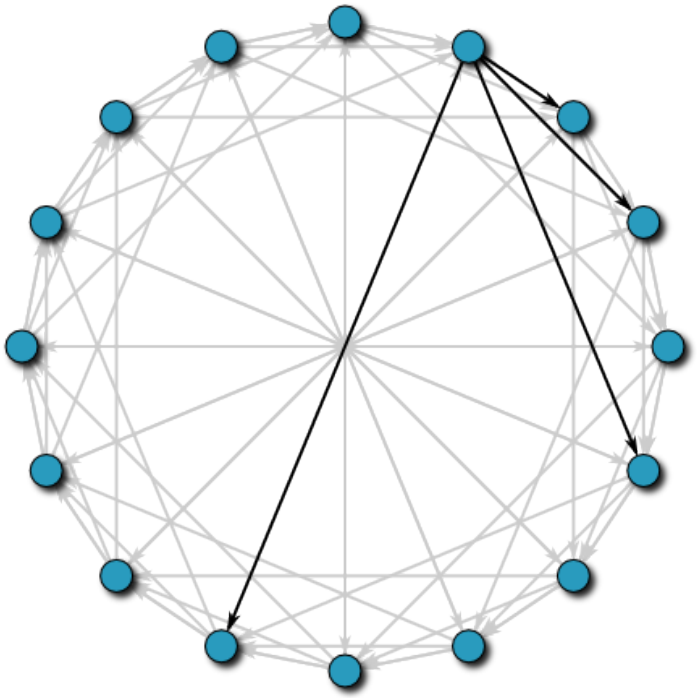

Chaque nœud maintient une table de nœuds à distance $(n + 2^i) \bmod 2^m$

Chord

Chercher le successeur de k pour nœud n:

- Soit C(k) le premier nœud successeur de (n+ 2^{k-1}) mod 2^{m}
  - Si k appartient à]n, successor]: trouvé
  - Sinon transmettre la demande au plus près prédécesseur f de k dans C(k)
  - Si les nœuds sont répartis uniformément on y arrive en m étapes (et donc en log de la taille =(2^m)) à chaque appel la distance entre le nœud et k divisée par 2.

Un autre exemple: CAN

"Content-Addressable Network"

tore de dimension d

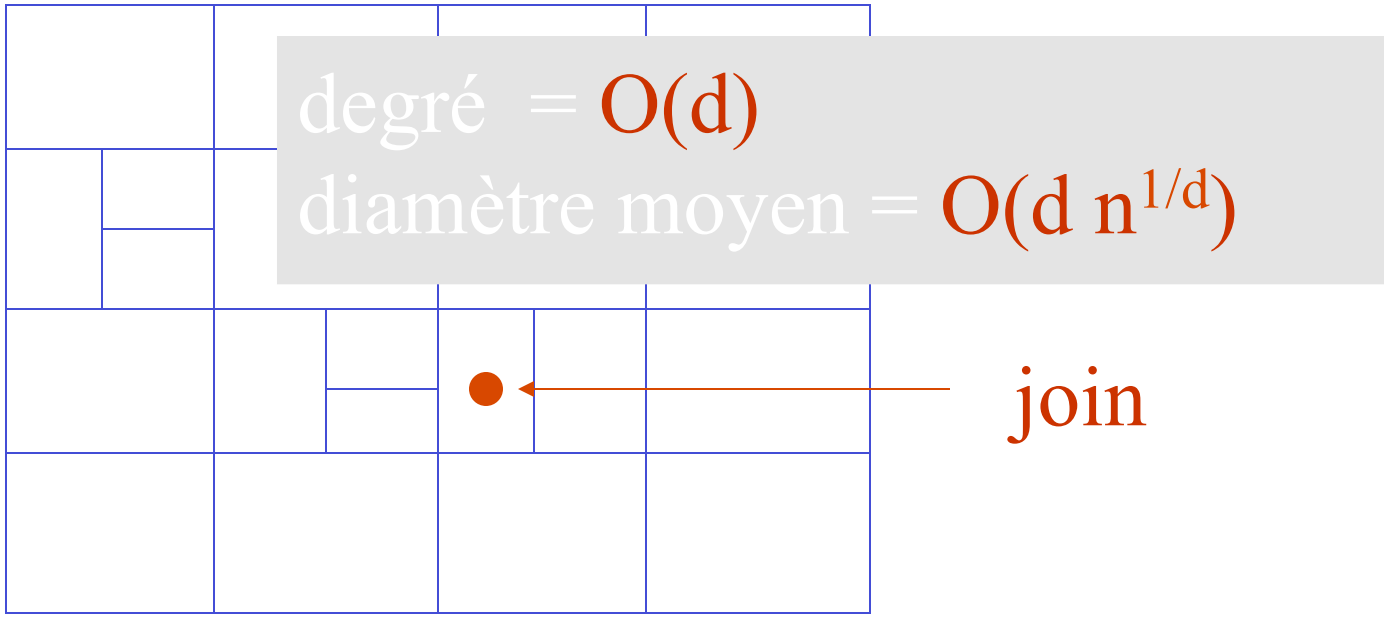

Téléchargement

- protocoles ad-hoc (Edonkey, Bittorrent) ou http
- Swarming (essaim)
  - téléchargement d'un fichier en téléchargeant différentes parties en parallèle depuis plusieurs clients
- téléchargement multiple
  - le fichier est décomposé en n blocs
  - calcul du hachage de chaque bloc
  - fichier est identifié par le hachage des blocs

Succès…

June 19, 2005 - 23:00

Network	Users
eDonkey2K	4,379,883
FastTrack	2,482,130
Gnutella	1,598,329
Overnet	745,472
DirectConnect	294,255
MP2P	251,137
Filetopia	3,455

Quelques réseaux

- Napster
  - (historique)
  - Protocole:
    - architecture centralisée
    - recherche par indexation
- Fasttrack
  - clients: Kazaa Mldonkey
  - architecture hybride
  - recherche par indexation et diffusion entre ultrapeers
  - identification faible des fichiers (MD5 sur 300ko puis hachage sur 32 bits)
  - http (+ swarming)

Quelques réseaux

- Edonkey
  - Clients: Edonkeys, Emule
  - protocole
    - faiblement centralisée
    - recherche par indexation TCP
    - recherche multi-serveurs par UDP
    - téléchargement en duplex avec bitmaps, streaming et swarming (Bittorrent dans les dernières versions)
    - système de crédits pour inciter au partage
- Overnet/Kad
  - télécharement Edonkey
  - décentralisé
  - DHT (Kademlia)

Quelques réseaux

- Gnutella
  - architecture hybride
  - Recherche par diffusion courte (TTL <8) avec filtres de Bloom
  - Gnutella et Gnutella2
  - téléchargement par http avec possibilité de swarming
- Bittorrent
  - pas de découverte, un fichier .torrent contient les infos sur le fichier
  - localisation centralisée pour chaque fichier (tracker)
  - téléchargementavec bitmaps
    - le client commence à forunir du contenu à ses voisins
    - au bout d'un certain temps il bloque les voisins qui ne répondent pas et conserve les quatre meilleurs

Quelques réseaux

- Freenet
  - complètement distribué
  - publication par copie
  - recherche par diffusion en profondeur
  - protocole et contenu cryptés
  - documents signés par signature digitale
  - axé sur l'anonymat