Systèmes de fichiers partagés

Samuel Tardieu

sam@enst.fr

Pourquoi partager des fichiers?

- Travail en équipe
  - Projets à plusieurs développeurs
  - Mise à jour de base de connaissances
- Travail personnel
  - Utilisation de machines banalisées
  - Utilisation de machines différentes
    - Station de travail avec un large disque et sauvegardée
    - Ordinateur portable

Ce problème n'est pas récent

- En 1985, DEC fournit VAXClusters
  - Partage de périphériques de mémoire de masse comme s'ils étaient locaux (notion de cluster)
  - Basé sur une politique de droits rigide, à la VMS
- Au même moment, Sun livre NFS
  - Distinction entre fichier local et fichier distant
  - Plus souple à administrer, plus orienté Unix

NFS: le système le plus basique

- NFS a été prévu pour ressembler au système de fichiers Unix
- NFS utilise les RPC de Sun
- Le protocole ne stocke pas l'état du serveur
- Le client n'utilise pas (ou peu) de cache
  - Impossibilité de savoir si une donnée a changé sur le serveur
  - Certains clients utilisent un cache à sémantique douteuse (exemple: « réutilise un bloc de données s'il date d'il y a moins de 30 secondes »)

NFS: un protocole simple

- Opérations en lecture
  - getattr, lookup, readdir, read, readlink, statfs, mount
- Modifications de la hiérarchie de fichiers
  - mkdir, link, symlink, rename, unlink, rmdir
- Modifications de fichiers
  - setattr, write
- Ces opérations ressemblent à celles accessibles sur un système de fichiers local

NFS: adapté aux clients sans disque

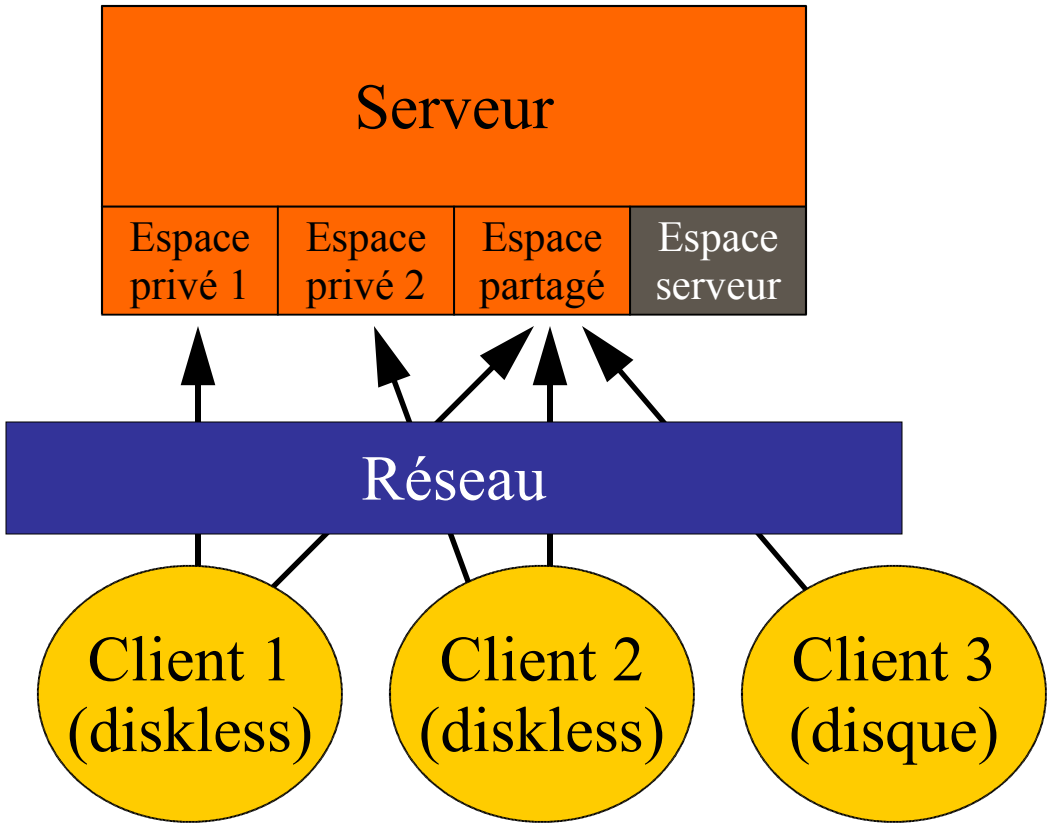

NFS: exemple de scénario

- Le client charge un fichier dans son éditeur
  - Le fichier est demandé au serveur et récupéré
- Le serveur tombe en panne
- Le client modifie le fichier dans son éditeur
  - Il ne remarque pas la « disparition » du serveur
- Le serveur redémarre
- Le client sauve le fichier
  - Tout se passe bien, le serveur ne conserve pas d'état, les identificateurs restent valables

NFS: quel environnement?

- Aucune donnée n'est cachée localement
  - La vitesse du réseau influence le débit des données disponibles
  - Le temps d'aller/retour influence la durée de chaque opération
- NFS n'est adapté qu'aux réseaux locaux rapides
- NFS v3 et v4 réduisent ces problèmes
  - Certaines opérations sont asynchrones
  - Il est possible de lire plusieurs entrées de répertoire en une seule opération

NFS: répliquer les données est possible, mais...

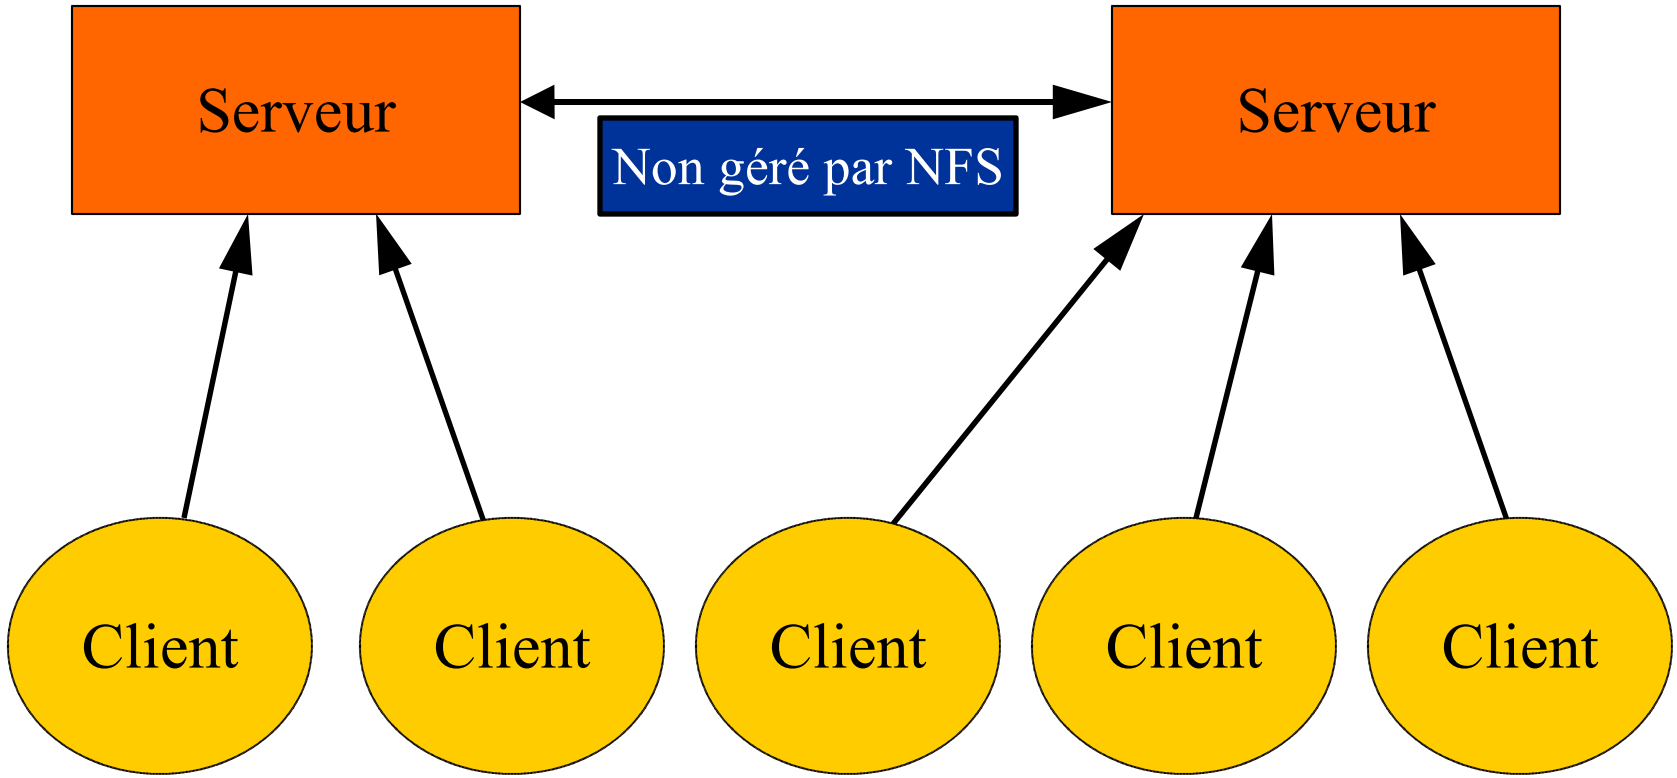

...pas de cohérence forte

Nouveautés de NFS v4

- Un client peut informer le serveur de ses intentions (lock, lecture, écriture, ...) et savoir ce que prévoient les autres clients
- En v4, possibilité d'utiliser des callbacks (cf. plus loin dans le cours) et d'utiliser un cache
- Streams privilégiés (lien avec le serveur), datagrammes obsolescents
- Cache en mode « close-to-open consistency »

NFS: disponibilité

- Conçu à l'origine par Sun Microsystems
- Disponible pour tous les clones d'Unix
- Implémentations commerciales disponibles pour Windows NT et VMS
- Disponible pour les systèmes embarqués (robot SPIF de l'ENST par exemple)
- v1 et v2 obsolescents
- v3 très utilisé, v4 en cours de déploiement

NFS: inconvénients

- Il n'y a quasiment plus de stations sans disque
- On a toujours besoin de fichiers partagés

  → On souhaiterait utiliser le disque local

- NFS ne permet pas cela

AFS: utilisation d'un cache local

- AFS: Andrew File System
- Utilisation d'un cache côté client
  - Stocke les fichiers
  - Stocke les données de répertoire
- Utilisation d'un système de « callbacks »
  - Le client peut utiliser sa copie locale en la considérant valide
  - Le serveur le prévient lorsque les données cachées sont modifiées

AFS: propriétés du cache

- Le cache est persistant
  - Résiste au redémarrage de la machine
  - Stocke un numéro de version associé à chaque donnée
- Accès concurrents
  - Accès en lecture
    - Ne nécessite par défaut aucune opération réseau
  - Accès en écriture
    - Provoque un demande d'invalidation de cache par le serveur à tous les autres clients pour les données modifiées

AFS: illustration du cache

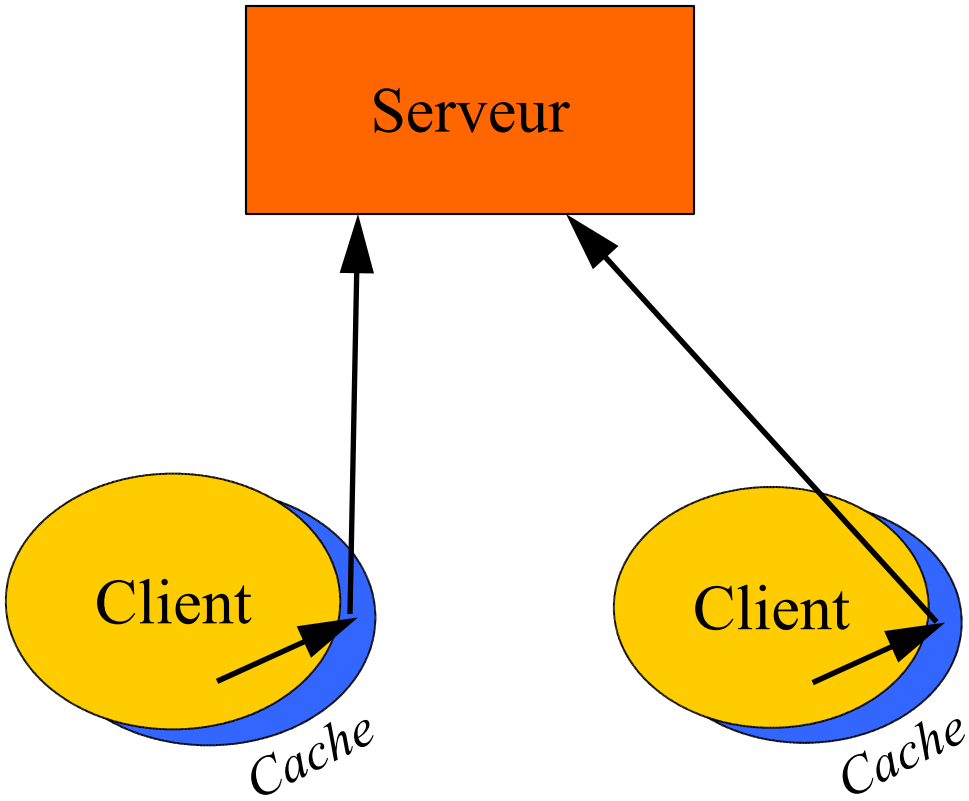

AFS: organisation

- Espace de nommage unique: /afs
- La cellule est un domaine administratif
  - Un ou plusieurs serveurs
  - Zéro ou plusieurs clients accédant à ces données
  - Chaque cellule exporte des volumes montés sous /afs
- Administration du client minimale
  - Nom des cellules AFS accédées
  - Le client contactera de lui-même la cellule pour trouver un serveur offrant le volume demandé

AFS: réplication illustrée

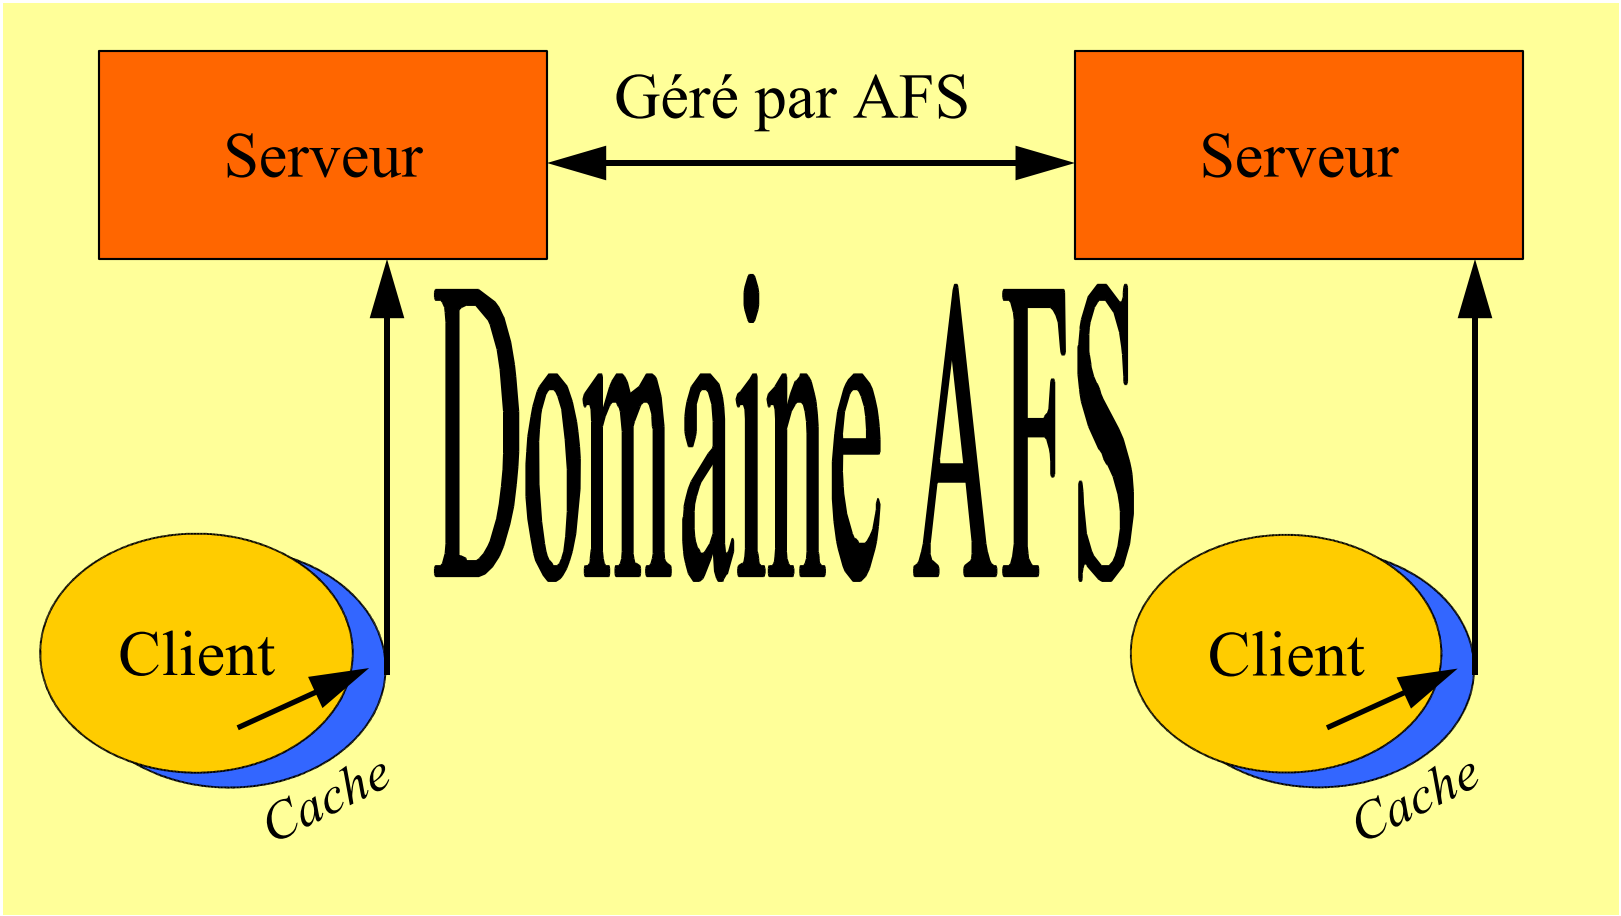

AFS: protocole simple mais puissant

- Client -> Serveur
  - Lecture des données
    - FetchData, FetchACL, FetchStatus
  - Ecriture de données
    - StoreData, StoreACL, StoreStatus
  - Modification de la hiérarchie de fichiers
    - RemoveFile, CreateFile, Rename, Link, Symlink, MakeDir, RemoveDir
  - Gestion des volumes
    - GetVolumeStatus, SetVolumeStatus, GetRootVolume

AFS: protocole... (suite)

- Vivacité et semantique
  - GetTime, BulkStatus, GiveUpCallbacks
- Verrouillage
  - SetLock, ExtendLock, ReleaseLock
- Serveur -> Client
  - Sémantique
    - Probe, Callback, InitCallbackState
- Sécurité prise en compte
  - Gestion de jetons par Kerberos
  - ACL (Access Control List) par répertoire

AFS: disponibilité

- Premières implémentations développées par CMU (Carnegie Mellon University)
- Implémentation commerciale développée par TransArc
- Implémentation libre, ARLA, en cours de développement
- Très utilisé dans les universités américaines

Comparaison NFS/AFS

- Authentification et confidentialité des données
  - NFS fait confiance au client
  - AFS impose une vérification d'identité externe
- Gestion du cache
  - NFS ne gère aucun cache
  - AFS gère un cache local persistant
- Architecture
  - NFS: le client appelle le serveur
  - AFS: le serveur peut également appeler le client

Comparaison NFS/AFS (suite)

- Sémantique
  - NFS: la dernière écriture gagne (comme Unix)
  - AFS: la dernière fermeture de fichier gagne
- Performances
  - NFS: nécessite un réseau local rapide
  - AFS: nécessite un réseau local
    - local: beaucoup d'opérations synchrones
    - rapide: uniquement pour les lectures après modification, ou la première lecture

Coda: la souplesse en action

- Développé par CMU
- Dérive de AFS version 2
- Un volume peut être fourni par plusieurs serveurs
- Synchronisation des réplicas
- Adaptation à la bande passante disponible
- Support des opérations en mode déconnecté

Coda en une image

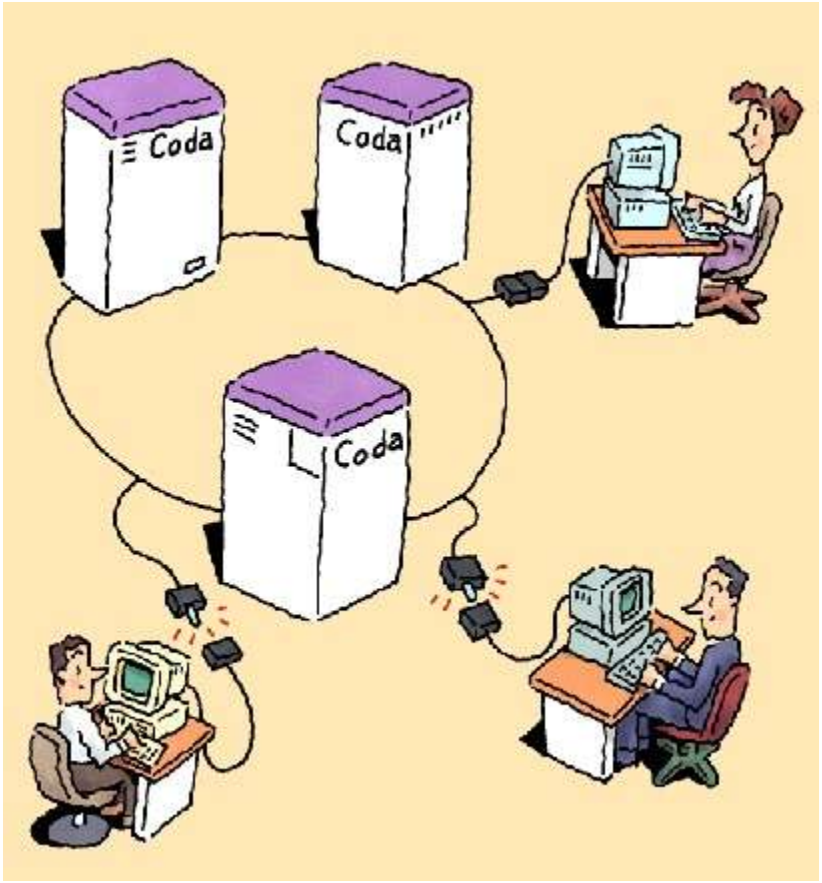

Coda: scénario typique

- Un portable est préchargé avec les fichiers utilisateurs
- L'utilisateur travaille sur ses fichiers dans l'avion
- Il se connecte à bas débit (PPP) depuis son hôtel pour synchroniser son portable
- Il arrive sur le site de la filiale, où les fichiers sont répliqués, d'où un accès rapide

Le mode déconnecté est amené à devenir de plus en plus populaire (informatique nomade)

Coda: réintégration des changements

- Le client récupère le fichier de changement du client
- Le serveur intègre les changements dans l'existence des fichiers et leurs attributs
- Le serveur demande au client de lui envoyer (backfetch) les modifications effectuées dans le fichier
- Que se passe-t-il si plusieurs clients ont fait des changements contradictoires?

Coda: fonctionnement d'un client

- Si le client est bien connecté à un serveur
  - Les écritures sont synchrones
  - Le client est averti des modifications sur les fichiers qu'il possède en copie (callbacks)
- Si le client n'est pas (ou est mal) connecté
  - Les écritures se font à l'aide d'un fichier de modifications locales
  - Ces modifications sont réintégrées de manière asynchrone si le client est mal connecté, plus tard s'il n'est pas connecté
  - Les fichiers demandés sont prioritaires

Coda: configuration possibles d'un client

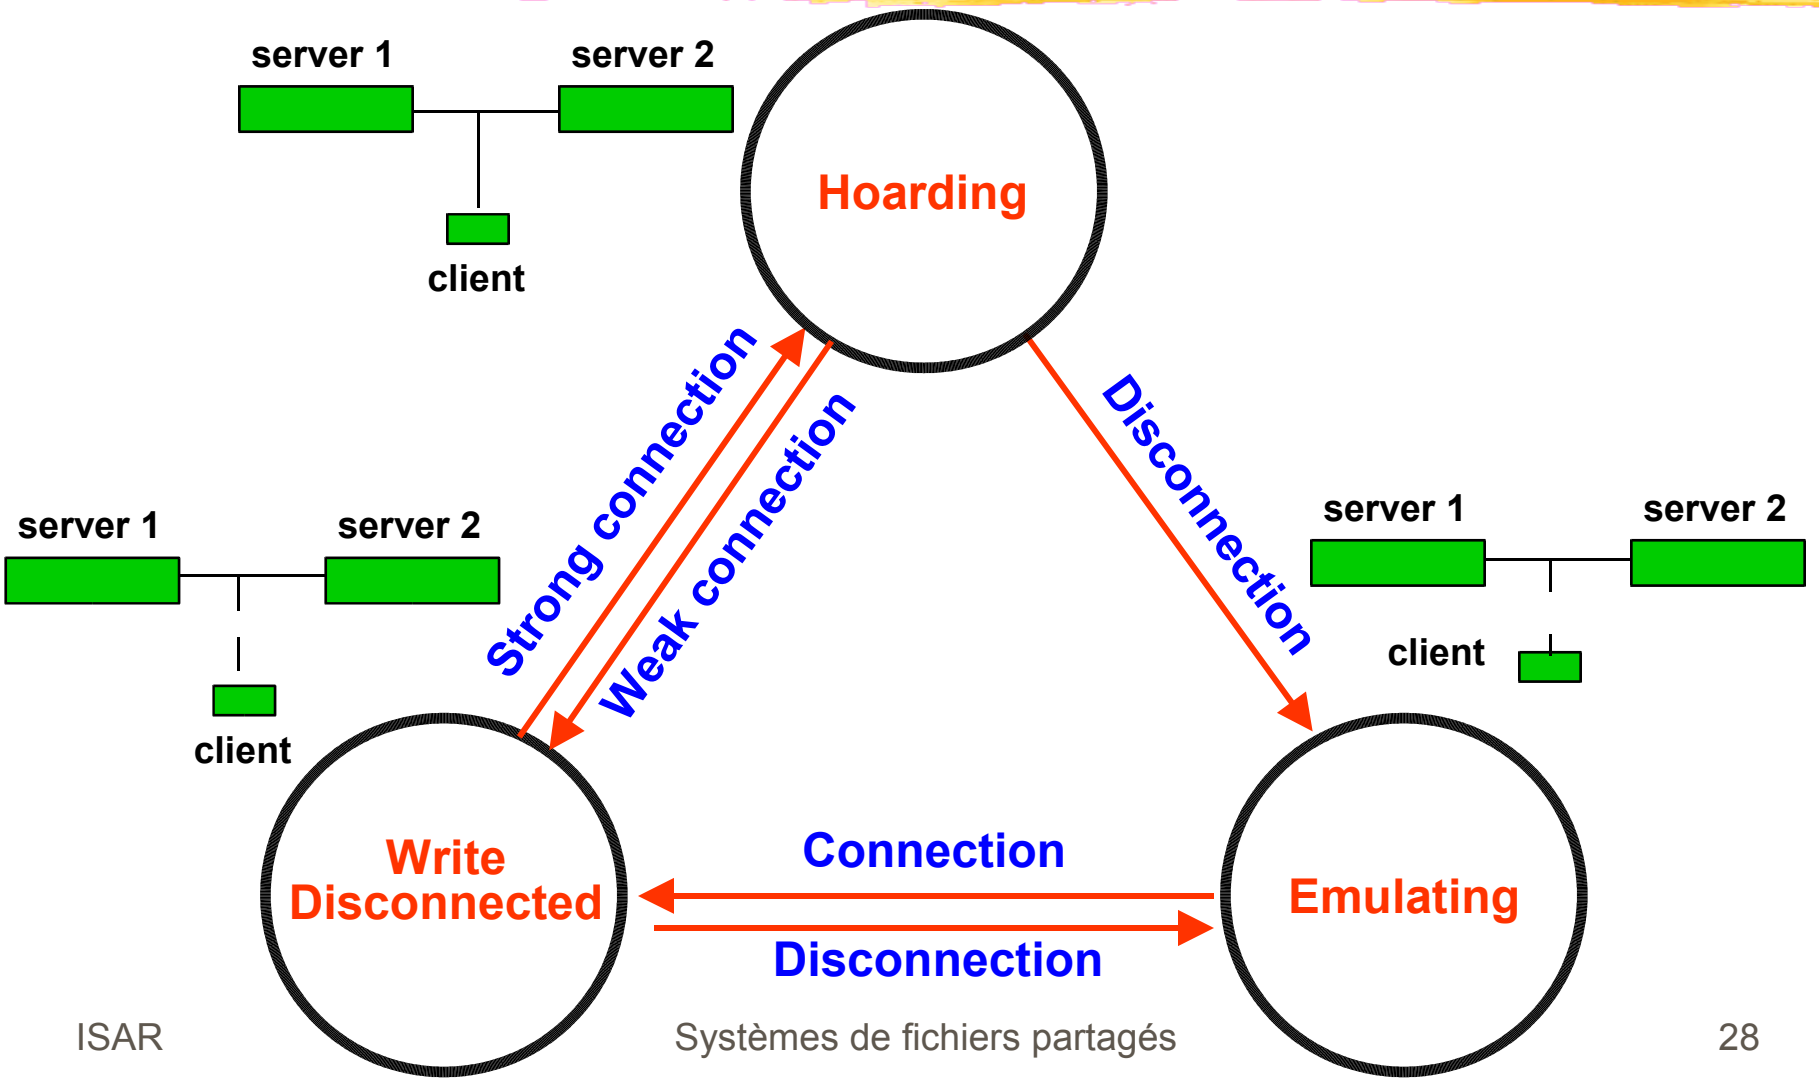

Coda: modifications locales

- Le fichier de modification locale...
  - ...enregistre la création, la modification, l'effacement et le changement des attributs d'un fichier
  - ...n 'enregistre pas le contenu de la modification
  - ...subit un nettoyage permanent
    - Une création de fichier suivi d'un effacement
    - Deux modifications successives du même fichier
    - Des modifications suivies d'un effacement
- Ce fichier sera transmis plus tard au serveur

Coda: gestion des conflits

- Dans le cadre d'écritures synchrones
  - Chaque écriture est précédée d'une demande vérification de la version courante
  - Cette demande est réalisée auprès de tous les serveurs
  - Tous les réplicas effectuent les mêmes opérations
- Dans le cadre d'écritures asynchrones
  - Coda essaye de résoudre les faux conflits
  - L'utilisateur doit résoudre les autres à la main

Coda: réplication des serveurs

- Le modèle est « write all, read one »
- Chaque volume possède un Volume Storage Group (VSG)
- Chaque fichier ou répertoire possède un « version-stamp », permettant de différencier les versions
- Un client accédant à une ressource vérifie l'égalité des version-stamp des serveurs disponibles (AVSG, A pour Available)

Coda: fonctionnement en groupe partiel

- Pour modifier une ressource, un client
  - demande à chaque serveur (multi-RPC) s'il accepte la modification à partir de la version connue
  - valide ou invalide la demande, selon les réponses, par le même mécanisme
  - en cas d'invalidation, le client déclenche une résolution de conflit entre serveurs
- Si AVSG != VSG, les modifications sont enregistrées par les serveurs, comme s'ils étaient des clients déconnectés

Coda: résolution des conflits entre serveurs

- Résolution basique
  - Comptage du nombre de modifications par serveur dans un « version-vector » pour chaque ressource
  - Identification éventuelle d'un réplica dominant
  - Permet surtout d'importer un objet sur un réplica qui ne le possède pas
- Résolution complexe
  - Lorsque des modifications concurrentes ont vraiment eu lieu
  - Nécessite un protocole en 5 étapes

Coda: résolution complexe

- Etape 1
  - Election d'un coordinateur parmi les réplicas
- Etape 2
  - Le coordinateur collecte les fichiers d'historique et les version-stamp de tous les réplicas, les structure et les renvoie à tous les réplicas
- Etape 3
  - Chaque réplica utilise cet historique structuré, effectue les opérations qu'il a manqué et renvoie au coordinateur les incohérences résultantes

Coda: résolution complexe (suite)

- Etape 4
  - L'assistance d'un utilisateur est requise afin de pouvoir résoudre les conflits
- Etape 5
  - Lorsqu'il n'y a plus d'incohérence, chaque serveur installe le même version-vector
  - Les fichiers d'historique sont
    - remis à zéro si AVSG = VSG
    - conservés sinon, car de nouveaux conflits pourront apparaître entre ce groupe (AVSG) et les autres serveurs (VSG-AVSG)

Coda: disponibilité

- Disponible à l'origine sur Linux
- Fonctionne maintenant sur Solaris et FreeBSD
- A été récemment porté sur Windows 2000/XP
- Est peu utilisé actuellement
  - projet universitaire, au rythme de développement irrégulier (version 6.0.8 en décembre 2004)
  - aucune garantie de constructeur n'est apportée quant à la robustesse du système de fichiers

Comparaison AFS/Coda

- Authentification et sécurité
  - Modèles comparables, basés sur des jetons d'authentification
- Accès aux données
  - Vitesse d'accès comparables
  - Possible en mode déconnecté avec Coda
  - Coda supporte un réseau à faible débit par intermittence

InterMezzo: les idées de Coda, la robustesse en +

- Système de fichier au stade de prototype
- Utilise les mécanismes de Coda
  - pour la réintégration des données
  - pour les opérations en mode déconnecté
- Utilise le système de fichiers sous-jacent
  - vitesse d'accès aux données similaire à un accès local traditionnel
  - outils de réparation en cas de problèmes physiques ou de crash du système

InterMezzo: gestion des fichiers

- InterMezzo s'insère dans la gestion des fichiers entre l'utilisateur et le disque
  - module noyau sous Linux
  - service système sous NT
- Principe de « permis de modifier »
  - un serveur négocie un permis avec les autres et l'accorde à un client
  - le client doit rendre ses modifications lorsqu'on lui retire le permis

InterMezzo: filtrage des requêtes

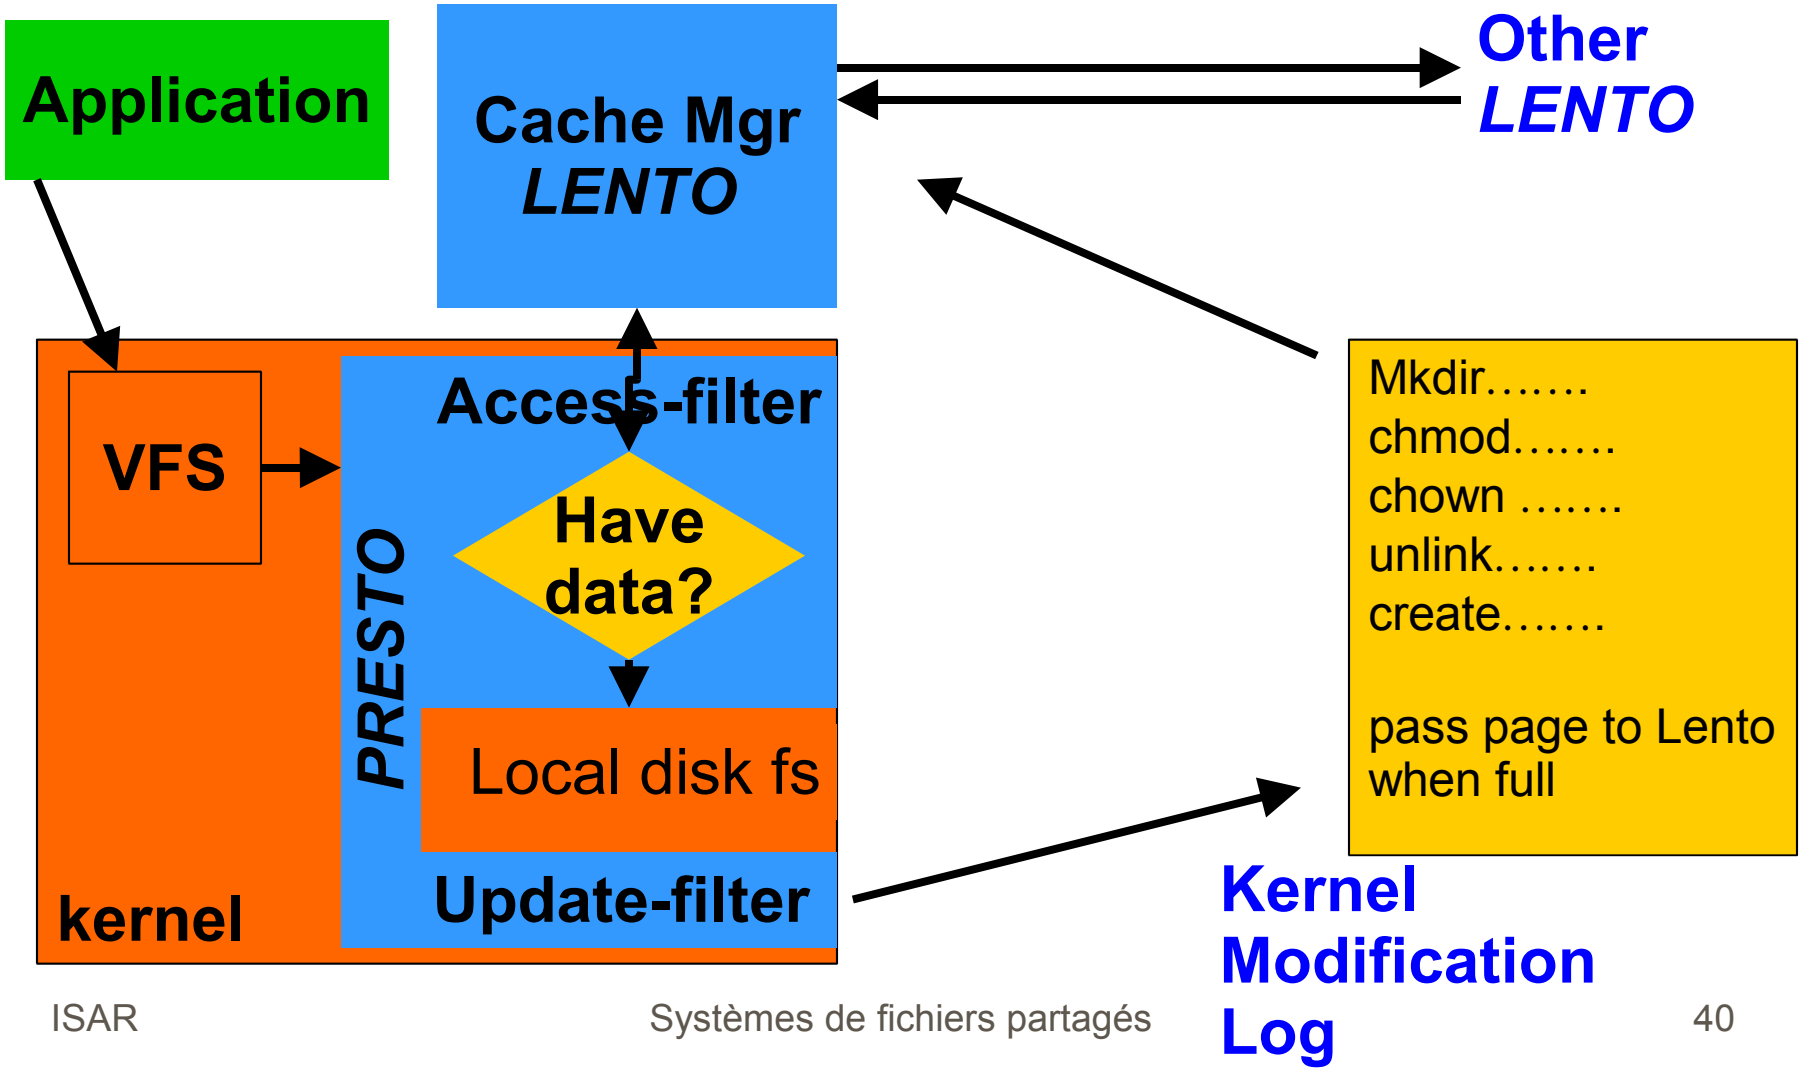

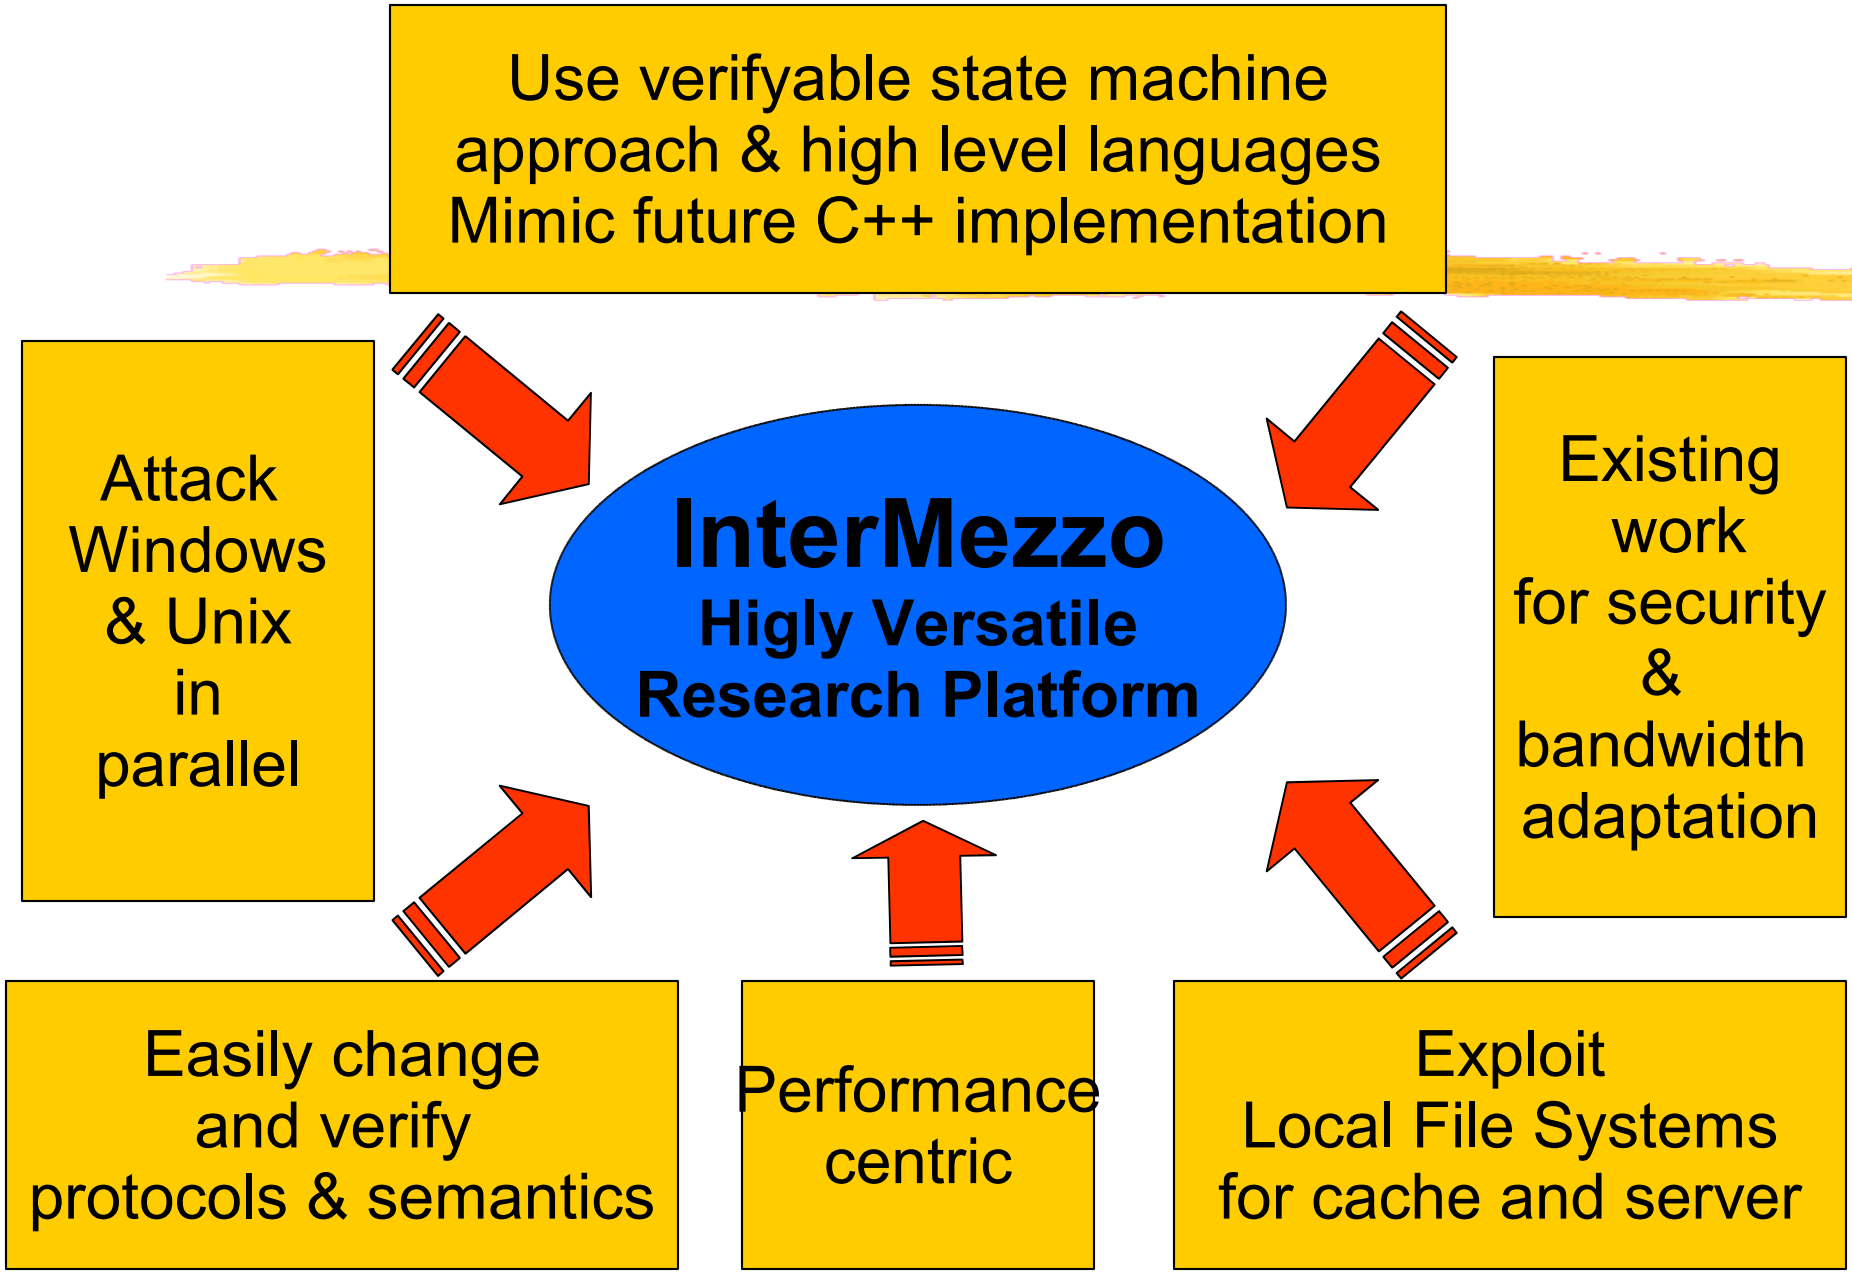
Use verifyable state machine approach & high level languages Mimic future C++ implementation
Attack Windows & Unix in parallel
InterMezzo
Higly Versatile Research Platform
Existing work for security & bandwidth adaptation
Easily change and verify protocols & semantics
Performance centric
Exploit Local File Systems for cache and server

InterMezzo: un modèle simple

- Module noyau pour Linux (Presto)
  - 2500 lignes de code C
  - Facile à intégrer dans le noyau, sources disponibles
- Programme Lento
  - 4000 lignes de Perl
  - Très hautement configurable
  - Très pratique pour tester de nouveaux prototypes
  - Sera réécrit plus tard en C++

Passé, présent et avenir

- Hier: NFS et AFS
  - Partage de fichiers, mais inefficace en cas de déconnexion
- Aujourd'hui: Coda
  - Partage de fichiers en mode déconnecté
- Demain: InterMezzo
  - Partage de fichiers en mode déconnecté en utilisant le système de fichiers sous-jacent
- Et après-demain?

Quels systèmes pour l'avenir?

- Constat de la situation actuelle
  - Les systèmes de fichiers vus précédemment
    - ne reviennent pas cher, grâce à la baisse du prix des disques
    - sont robustes et portables
    - prennent en compte la tolérance aux pannes
  - mais...
    - ne tiennent pas compte de la topologie des réseaux
    - sont limités par la vitesse des réseaux
    - ne tirent pas parti des progrès en informatique embarquée

Problème 1
Trop d'intermédiaires

- Chaque « hop » représente
  - un parcours sur un brin physique
    - rapide, de plus en plus rapide
  - une opération de stockage sur disque
    - ralentissement minime
  - la traversée d'une couche logicielle
    - conversion entre les protocoles utilisés sur les différents média physiques
    - couche logicielle appartenant à un système d'exploitation

Ce dernier point est très coûteux

Problème 2
Architecture mal équilibrées

- Les serveurs sont impliqués dans
  - la gestion de la propriété des données
  - la synchronisation des accès aux données
  - la répartition de charge entre disques
  - la résistance aux pannes
- Cela limite
  - le redimensionnement
  - les performances
  - la disponibilité

Solution 1
Utiliser des canaux rapides

- Performance
  - Bande passante: 1Gbps (ethernet)
  - Latence: très faible (périphérique à périphérique)
- Disponibilité
  - Accrue grâce au « zoned switching », aux branchements faits à chaud
- Redimensionnement
  - Nécessite d'ajouter des périphériques et d'augmenter la distance

Cette architecture n'est pas optimale

Solution 2
Des périphériques intelligents

- NASD (Network-Attached Secure Devices) ou disques actifs
- Principes
  - Rendre les disques « intelligents »
  - Relier directement les clients et les données
- Défis
  - Conserver la sécurité des données
  - Utiliser l'intelligence des disques le plus intelligemment possible

NASD: les idées fondatrices

- Les permissions d'accès existent toujours
  - Un serveur vérifie l'identité du client
  - Ce serveur lui donne des jetons lui donnant certains droits
  - Le schéma d'authentification n'est pas figé
- Les transferts n'utilisent pas le serveur
  - Le client utilise ses jetons pour accéder aux données
  - Le client et le disque communiquent directement

NASD: sécurité des données

- Le serveur et NASD partagent un secret
- Le serveur renvoie au client des droits chiffrés avec ce secret
- NASD utilise ce secret pour déchiffrer les droits accordés au client
- Le serveur et NASD ne communiquent pas ensemble pour autoriser l'accès à un client
  - Economie de bande passante allant vers le disque

NASD: avantages

- Chemins de données plus courts
  - Les données sont échangées directement entre le disque et le client
  - Les transferts de périphérique à périphérique sont possibles sans intervention extérieure
- Possibilité d'optimisation intelligente
  - Répartition des données (performances)
  - Duplication des données pour résister aux pannes
  - Protection des données sensibles en cas d'attaque détectée

NASD: exemples d'utilisation

- Exploitation de données gigantesques
  - Recherche simultanée sur des milliers de disque
- Base de données à haute disponibilité
  - Des milliers de moteurs transactionnels fonctionnant en parallèle pour équilibrer la charge
- Protection automatique des données
  - Chaque disque sait quelles données doivent être répliquées, déplacées ou sauvegardées
- Les applications restent à inventer

Mais de quoi sera fait l'avenir?

- Si rien ne change
  - InterMezzo ou un système similaire se déploiera
- Si la technologie évolue
  - Les disques deviendront intelligents
  - De nouvelles classes d'application apparaîtront
  - Ce point se combine avec le précédent
- Et si elle évolue encore plus
  - Le modèle du disque dur est-il viable?
  - De nouveaux moyens de stockage existent