

<http://membres-liglab.imag.fr/donsez/cours>

Supports Physiques de Stockage



Didier DONSEZ

Université Joseph Fourier (Grenoble 1)

Polytech'Grenoble LIG/ADELE

Didier.Donsez@imag.fr

Didier.Donsez@ieee.fr

Motivations


- Propriété de persistance
 - à garantir
 - dans les systèmes de fichiers
 - dans les SGBDs
 - ...

- en cas de problème
 - Perte de l'alimentation électrique, ...

Mémoires Persistantes vs Mémoires Volatiles

- Mémoire Primaire
 - zone de stockage des données en vue d'un calcul dans le processeur.
- Mémoire Secondaire
 - zone secondaire de stockage des données
 - Généralement de très grande capacité, résistant aux pertes de courant
- Mémoire Volatile
 - les données disparaissent en cas de perte de courant
- Mémoire Persistante ou Non Volatile
 - Une fois écrites, les données sont conservées

Architecture d'un ordinateur



Mémoire volatile

- RAM (Static) RAM
 - On-Chip Cache
 - Processeur 8 et 16bits (et carte à puce)

- Dynamic RAM

- Module

■ Acrononyme	Techno		bits	Mhz
	Go/s			
■ DRAM	(A)synchronous			
■ SDRAM	Synchronous	64b	133*	
■ RDRAM	RamBus	16b	800	1.6
■ DDR DRAM	Double Data Rate	64b	266	2.1

- *100, 133, 266, 333 et 400 MHz (2005)


Disques Mécaniques (i)



■ Organisation

- blocs de mémoire de taille fixe (N octets)
disque organisé en Tête, Cylindre, Secteur

Didier Donsez, 1996-2008, Structures Physiques de Stockage



Disques Mécaniques (ii)

- Accès Aléatoire aux blocs
 - Temps d'accès TA =
Temps de Déplacement du bras (Seek Time)
(positionnement sur la piste= 1-10 ms pour un HD)
 - + Temps de Latence (Rotational Latency)
(positionnement sur le début du secteur)
+ Temps de Transfert (Data Transfer Time)
(parcours du secteur)
 - Temps d'accès moyen
- Facteur de Blocage (blocking factor)
 - accès mémoire primaire : par bloc de 8 octets
 - accès mémoire secondaire : par bloc de N octets (1 secteur)
N=512-1024
- MTBF (Mean Time Before Failure)
 - temps moyen avant une panne (500000-1000000 heures pour les HD)

Disques Mécaniques (iii)

- Type
 - Amovible : Le support peut être retiré du lecteur
 - Solidaire: Le support et le lecteur sont solidaires
- Disquettes (Floppy Disk)
 - 1 plateau de plastique souple recouvert de particules magnétiques
 - Mécanique basse vitesse, Amovible
 - Usage: PC mais en voie d'extinction
 - Remarque : comment faire pour reprendre des documents archivés depuis 10 ans ?

Disques Mécaniques (iv)

- Disques Durs (Hard Disk)
 - Plusieurs plateaux d'aluminium recouverts de particules magnétiques. Les têtes sont très proches des plateaux
 - Mécanique à haute vitesse (5000 à 15000 tours / minute)
 - Facteur encombrement (01/2004)
 - 3 1/2 : <300 Go, 0.8 Go/cm², 1.2€/Go en ATA
 - 2 1/2 : <80 Go, 1.45 Go/cm², 4€/Go en ATA
 - Mais aussi 1.8 pouce, 1 pouce et même 0.85 pouce
 - Disques et Lecteur solidaires
 - Usage : PC, Serveurs, Mass Market (Apple iPod™, ...)
 - Remarque:7% de DD dans le Mass Market en 2003, en augmentation en 2004
 - (Magnétoscope numérique, console de jeux, récepteur iTV, 9

Disques Mécaniques (v)

- Disques Durs (Hard Disk) suite
 - Autres critères
 - Résistance aux accélérations (chocs, ...)
 - Bruit en fonctionnement (critère Windows XP Media Center)
 - ...
 - Acteurs: Western Digital, Maxtor, Hitachi, Toshiba, ...

Disques Mécaniques (vi)

- CD-ROM(Compact Disk) , DVD (Digital Versatile Disk)
 - 1 plateau de plastique recouvert de particules réfléchissantes
 - La tête de lecture est un couple faisceau laser et cellule et l'écriture est unique (Gravage) ou multiple (CD-RW)
 - Usage : PC, Mass Market
- CD Opto Magnétique
 - Un champ magnétique permet d'orienter les particules réfléchissantes à l'écriture

Disques Mécaniques (vii)

- Juke-box ou Robot
 - archive « ternaire » : 3 niveaux de mémoire (DRAM/Disques Durs/Bandes ou CD) fonctionnant en cache
 - Pre-fetching (pré-chargement), ...

- Remarque : Imprimante parfois intégrée pour les robots graveur (CD/DVD)

Mémoire « électronique » non-volatile

- Principaux avantages : compacité et résistance aux chocs
- Inconvénients : faible ratio capacité/prix

■ UPS RAM

- RAM alimentée par une pile (batterie)
- Usage : Serveur
 - (Format : Banc de DRAM alimentée et batterie sur carte fille d' un serveur)
 - rendre les écritures de journalisation asynchrones
 - Performances: 90 % pour les SGF (serveur NFS)
- Usage : Embarqué (TINI, iButton)
 - Temps d'accès uniforme, évite le risque de crash en cas d'écriture en FlashRAM

■ EEPROM

- Cible : Carte à puce, carte mère (Setup BIOS, ...)
- Nombre limité d'écritures (10^5)

Mémoire « électronique » non-volatile

- FlashRAM (NAND)
 - Cibles nomades, mobiles ou embarqués
 - Carte à puce, PC industriel embarqué, PDA, Téléphone portable (handset), Console de Jeux, Appareil Photo Numérique, Lecteur vidéo portable, STB, Passerelle domotique, Récepteur GPS, Voiture, Lecteur MP3, « Clé » USB, ...
 - Grande capacité
mais temps d'écriture lent et grain d'écriture >> grain lecture
 - Nombre de réécritures limitées (1000000 par point mémoire)
 - Inconvenients pour les swap et les journaux (log)
 - algorithmes de « wear levelling » (étalement de l'usure)
 - Plusieurs « form factors » et interfaces
 - SmartMedia, Compact Flash, PCMCIA, Memory Stick, SD
 - USB Memory Key, Disque 2,5 pouce SSD ...
- *Magnetoresistive RAM*
 - Très Grande capacité par unité de surface
 - Encore en laboratoire (à surveiller)

Contrôleur Disque

- Pilote une ou plusieurs unités de stockage reliées par
 - un bus spécialisé parallèle (SCSI, ATA)
 - un bus série (USB, FireWire, SATA,...)
 - un réseau IP (iSCSI sur GigaEthernet)
- Requête Synchrones / Requête Asynchrones
 - un contrôleur asynchrone est capable d'émettre plusieurs requêtes vers les périphériques différents sans attendre la réponse d'une requête précédente.
 - Gain de performance
- Hot Plug
 - Possibilité d'ajouter/de retirer un disque « à chaud » (c.a.d. sans interrompre le fonctionnement des autres disques)

Contrôleur Disque sur Bus parallèle

(i)

- IDE/ATA (Advanced Technology Attachment)
 - ATA 8,3 Mo/s
 - ATA-2 16,6 Mo/s
 - Ultra DMA : 33,3 Mo/s
 - Ultra-DMA2: 66,6Mo/s
 - 100, 133 Mo/s

- Synchrone, Non Hot-Plug
- Destiné les PC et stations d'entrée de gamme
- Domine le marché
 - 172 millions de disques ATA vendus en 2001

Contrôleur Disque sur Bus parallèle

(i)

- SCSI (Small Computer System Interface)
 - SCSI: 5 Mo/s (Macintosh 1984)
 - SCSI2: 10 Mo/s
 - Wide SCSI: 20 Mo/s
 - Ultra Wide SCSI: 40 Mo/s (sur 3 mètres)
 - Ultra2 Wide SCSI: 80 Mo/s (sur 12 mètres)
 - Ultra3 Wide SCSI: 160 Mo/s
- Asynchrone, HotPlug
- Disques hautes performances (swap)
- Niche de marché: serveurs, RAID, SAN

Contrôleur Disque : Les tendances


- SATA (Serial ATA) <http://www.serialata.org>
 - ATA sur bus série
 - Connectique simplifiée (pas de natte parallèle)
 - Allonge la distance entre hôte et équipement
 - Débits: 150Mbps (2001) à 300 Mbps (2007)
 - Mais non hot plug
- eSATA (external SATA)
 - hot plug, disque externe
- Serial Attached SCSI <http://www.scsita.org>
 - SCSI sur bus série
- iSCSI (internet SCSI)
 - Trames SCSI tunnelé sur TCP/IP
 - Les unités de disques et les clients sont reliés par du GigaEthernet par exemple

Bus IO hautes performances

- InfiniBand (www.infinibandta.com)
 - Serveurs Haut de Gamme
 - Réseau commuté jusqu'à 64000 nœuds (hôtes et périphériques)
 - 2.5, 10, 30 Gbits/s
 - 17 m sur cuivre à 10 Kms sur fibre mono-mode
 - Adressage IPv6
 - Interfaces
 - HCA (Host Channel Adapter)
 - TCA (Target Channel Adapter)
- RapidIO (www.rapidio.org)
 - 256 à 65536 périphériques
 - 8 à 64 Gbits/s
 - Serveurs embarqués (switch TelCo, ...)

RAID Redundant Array of Inexpensive Disks [Patterson 88]

- En 1988
- SLED : Single Large Expensive Disk



- **RAID** : Redundant Array of Inexpensive Disks
 - tableau de disques peu coûteux pour améliorer les débits I/O
 - cependant il faut introduit de la redondance à cause de la MTBF qui suit une loi de poisson

Niveaux de fonctionnement des RAID

■ Redondance

- Niveau 1 : Les Disques Mirroirs
 - TANDEM Mirrored Disks
- Niveau 2 : Code de Hamming pour ECC
 - CM2 DataVault
- Niveau 3 : Un Seul Disque de Contrôle par Groupe de Disque
- Niveau 4 : Lectures et Ecritures indépendantes
- Niveau 5 : Contrôle réparti sur les disques du Groupe

■ Sans redondance

- Niveau 0 : Stripping
 - répartition des blocs contigus d'un fichier entre les disques mais pas de redondance (ie AID)

Redondance et Balayage (scan) parallèle

■ RAID 0

- répartit les données sur plusieurs disques pour améliorer les performances.




■ RAID 1

- effectue des copies miroirs de disques pour survivre aux pannes.

■ RAID 5

- utilise la correction d'erreur et la répartition des données pour fournir performance et sécurité de manière économique et efficace.
- La correction est basée sur la propriété du XOR (\otimes) :

$$(X \otimes Y) \otimes Y = X$$



Nouveaux Niveaux de fonctionnement des RAID

■ Redondance

- Niveau 0/1 ou « 10 » : Stripping sur des disques miroirs
- Niveau 0/5 ou « 50 » : Stripping sur des groupes 5
- Niveau 6 : Contrôle redondant
 - Remarque
 - 2,3,4,5 ne résiste qu'à la panne d'un seul disque dans le groupe
 - Le niveau 6 ajoute du contrôle pour la redondance
 - Plusieurs propositions
 - $N+Q$: autre fonction que XOR
 - 2D
 - Soit une matrice de disques
 - les lignes forment des groupes RAID5
 - les colonnes forment des groupes RAID5

Contrôleur RAID

- **Caractéristiques**
 - Niveaux de RAID géré 0, 1, 5, 10 (0/1)
 - Hot Sparing : Secours permutable (disques de réserve)
 - Hot Swapping : Echange à chaud (par un opérateur humain)
- **Contrôleur RAID**
 - Disques SCSI surtout et maintenant ATA
 - De + en + intégré sur la carte mère des PCs
- **Interfaces**
 - Low Cost : PCI + Disques SCSI
 - UW-SCSI
 - FiberChannel (25 Mo/s)
pour des Architectures en Clusters
- **Exemple de Configuration (2002)**
 - disques SCSI de 80 Go 15000 Tr/min
(organisés par groupe de 5 pour RAID 5)



Contrôleur Disque sur bus série

- Principaux avantages
 - intégré à de nombreux ordinateurs (enfouis : TV, Camera, ...)
 - Connectique hotplug, faible coût et « longue » distance
- USB
- FireWire
- FibreChannel
- IrDA
 - sans fil (faisceau infrarouge)
 - débit jusqu 'à 100 Ko/s

Contrôleur Disque sur bus série

USB (Universal Serial Bus)

- Chaîne de périphériques (jusqu'à 127)
- Hot Plug-and-Play (matériel et logiciel système)
 - 1,5 Mb/s et 12 Mb/s (1.1), 480 Mb/s (2.0)
- Exemple de Périphériques :
 - USB1.x : ZIP, LS120, système de fichiers de balladeur MP3, appareil photo, memory key, scanner, webcam, Pointage (Souris, Joystick ...), Bluetooth ...
 - USB2.0 : imprimante, disque dur externe, graveur externe, lecteur DVD, Scanner, WiFi, Appareil photo numérique,, Memory Key, ...
- Parc
 - 1 Milliard en 2005, 3,5 Milliard en 2006
 - 95% des dispositifs de stockage, 95% des webcam, 90% des appareils de photo numérique, ...
- La suite : WUSB (Wireless USB)
 - S'appuiera sur la couche UWB (Ultra Wide Band)
 - 480 Mbits/s à 3 mètres, 110 Mbits/s à 10 mètres

Contrôleur Disque sur bus série Firewire IEEE 1394

- appelé également iLink (Apple), ou DV
- Domaine de la vidéo numérique surtout
- Bus série jusqu'à 63 périphériques
- Isochrone (temps réel)
- Support plusieurs débits simultanés: 100, 200, 400, 800 Mbits/s
- Remarque
 - Disques externes FireWire pour caméscopes numériques
 - 1Go produit par un caméscope numérique pour 5 minutes de vidéo !
- <http://www.1394ta.org>

Contrôleur Disque sur bus série

- FibreChannel <http://www.fibrechannel.org>

Connexions Série (ii)

- Les « plug-and-participate »
 - Simplification de la connexion domotique (home network environnement)
 - HAVi Home Audio/Video Interoperability – www.havi.org
 - GUNDIG A.G., Hitachi, Ltd., Matsushita Electric Industrial Co., Ltd. (Panasonic), Philips Electronics N.V., Sharp Corporation, Sony Corporation, Thomson Multimedia S.A., Toshiba Corporation.)
 - Bluetooth
 - (IBM Corporation, Intel Corporation, Nokia Corporation, Telefon AB L.M. Ericsson, Toshiba Corporation.)
 - JetSend™ (HP)
 - UPnP
 - Universal Play And Play

Pérennité du stockage

- Durée de vie des données
 - 1 an, 10 ans, 50 ans, 100 ans, 1000 ans, 10000 ans, ...
 - Cf perte des dossiers « magnétiques » du FBI
- Différents facteurs
 - Support (Média)
 - *Papier (carte perforée)*
 - Magnétique, Optique, Opto-Magnétique ...
 - Plastique, Métal, Silicium
 - Lecteurs
 - Matériel
 - exercice : retrouver un lecteur disquette 5 ¼ ou 8 et bientôt 3 ½
 - Pilotes pour OS (driver pour lecteur SyQuest sur WinXP)

Pérennité du stockage

A lire : Gordon Bell and Jim Gray, Digital Immortality, 1 October 2000, Technical Report, MSR-TR-2000-101, Microsoft Research

Data-types	Rate (Bytes/hour)	Per day / per 3 year	Lifetime amount
read text, few pictures	200 KB	2 –10 MB / GB	60-300 GB
Email, papers, written text		0.5 MB / GB	15 GB
photos w/voice @100KB	200 K	2 MB / GB	60 GB
photos @200 KB	Ten images/day	2 MB / GB	150 GB
spoken text @120wpm	43 K	0.5 MB / GB	15 GB
spoken text @8Kbps	3.6M	40 MB / GB	1.2 TB
music or high quality sound	60 M	60 MB / GB	5.0 TB
video-lite 50Kb/s POTS	22 M	0.25 GB/TB	25 TB
video 200Kb/s <i>VHS-lite</i>	90 M	1 GB/TB	100 TB
DVD video 4.3Mb/s	1.8 G	20 GB/TB	1 PB 32


Le futur des disques

- Le contrôleur esclave du disque est un processeur de plus en plus puissant avec de plus en plus de RAM (Cache)

- Fonctions de recherche sur le disque
 - Plein texte, structuration en enregistrement (BDR), ...

- Fonctions de filtrage de données sur le disque

Récapitulons : Mémoires Persistantes vs Mémoires Volatiles



Didier Donsez, 1996-2008, Structures Physiques de Stockage

- autres critères .
 - l'encombrement et la résistance aux chocs/températures/bombardement X...

Bibliographie

- John M May, « Parallel io for high perf computing », ed Morgan Kaufmann, 1-55860-664-5, 2001
- Jacques Peping, " Solutions de stockage ", Ed Eyrolles & CMP - 01/1999, 320 pages, ISBN: 2-212-09057-9
 - problématique du stockage des données d'entreprise et aborde les technologies des périphériques et l'évolution des modèles d'architectures de stockage. QA 76.9 A73 PEP
- Chris Date, "Introduction aux Bases de Données", 6ème édition, Ed Intl Thomson Publ. ISBN 2-84180-964-1
 - Voir le chapitre (6ème édition)
- Hector Garcia-Molina, Jeffrey D. Ullman, Jennifer Widom, "Database System Implementation", 2000, Ed Prentice Hall, ISBN 0-13-040264-8

Bibliographie

- A lire absolument
 - J. Gray, G. Graefe, “The 5 minute rule, ten years later,” SIGMOD Record 26(4): 63-68, 1997
 - <http://www.sigmod.org>
 - http://research.microsoft.com/~gray/5_min_rule_SIGMOD.doc

Bibliographie

- W.Ng. Spencer, "Advances in Disk Technology: Performance Issues", IEEE Computer, May 1998, Vol 31 No 5, pp75-81.
 - Des grandeurs pour les DD
- G. Lawton, "Storage Technology Takes Center Stage", IEEE Computer, November 1999, Vol 32 No 11, pp10-12,16.
 - Les tendances 1999 dans le stockage
- "Storage Systems", Special Issue, IEEE Computer, December 2002.
 - Les tendances 2002 dans le stockage
- « Storage », ACM Queue, Volume 1, Issue 4, June 2003
- E. Grochowski and R. D. Halem, Technological Impact of Magnetic Hard Disk Drives on Storage Systems, IBM Systems Journal 42 (2003), no. 2, 338–346.