MO401

Arquitetura de Computadores I

2006

Prof. Paulo Cesar Centoducatte
ducatte@ic.unicamp.br
www.ic.unicamp.br/~ducatte

MO401

Arquitetura de Computadores I

Sistemas de Armazenagem (IO)

"Computer Architecture: A Quantitative Approach" - (Capítulo 7)

Sistema de Armazenagem Sumário

- Motivação
- Introdução
- Tipos de Dispositivos de Armazenagem
- Discos, Desempenho, Histórico
- Barramentos (busses): Conectando Dispositivos de IO à CPU e Memória
  - Sistemas de Barramentos
  - Arbitragem em Barramentos
- Interface: Processador & I/O
  - Poolling e Interrupção
- RAID, Disponibilidade e Confiabilidade

Motivação

- Desempenho de CPU: 60% por ano
- Desempenho de Sistemas de I/O: Limitado por Delays Mecânicos (disco I/O)
  - 10% por ano (IO por seg)
- Lei de Amdahl: Speed-up Limitado pelo Sub-Sistema mais lento!
  - Se IO é 10% do tempo e melhorarmos 10x a CPU
    - » Desempenho do sistema será ~5x maior (perda de ~50%)
  - Se IO 10% do tempo e melhorarmos 100x CPU
    - » O desempenho do sistema será ~10x maior (perda de ~90%)
- I/O Bottleneck:
  - Reduz a fração do tempo na CPU
  - Reduz o valor de CPUs mais rápidas

Sistema Computacional

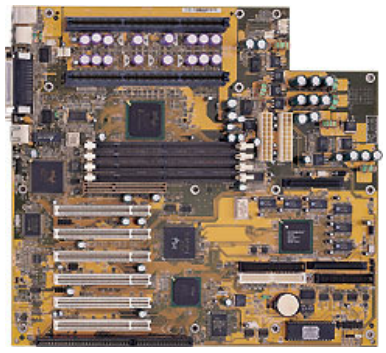

Organização de Sistemas Computacionais (Típico)

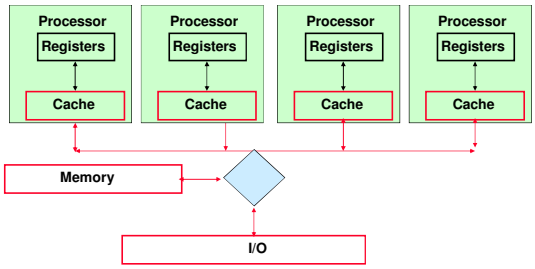

Organização de Sistemas Computacionais (Típico)

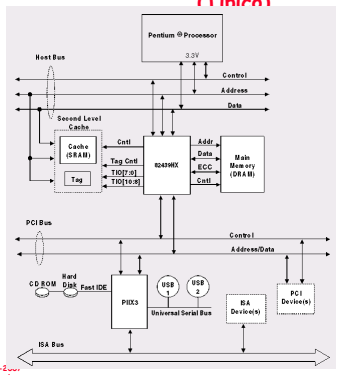

Processor/Memory Bus

PCI Bus

I/O Busses

Sistema de IO

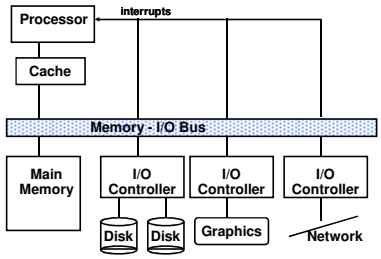

Tecnologia dos Dispositivos

- Dirigidos pelo Paradigma de Computação Vigente
  - 1950s: migração de batch para processamento on-line
  - 1990s: migração para computação ubíquoa (unipresente)
    - » Computação em telefones, livros, carros, vídeo, câmeras, …
    - » Rede de fibra optica internacionais
    - » wireless
- Efeitos na Indústria de Dispositivos de Armazenagem:
  - Embedded storage
    - » pequeno, barato, mais confiável, baixo consumo
  - Dados
    - » Alta capacidade, gerenciamento hierarquico do armazenamento

Tipos de Dispositivos de Armazenamento

- Finalidade:
  - Longa duração, armazenamento não volátil
  - Grande, barato, usado nos níveis mais baixo da hierarquia
- Bus Interface:
  - IDE
  - SCSI – Small Computer System Interface
  - Fibre Channel
  - ….
- Taxa de Transfêrrencia
  - Cerca de 120 Mbyte/second através da Interface de Barramento.
  - Cerca de 5 Mbyte/second por Heads.
  - Dados são movidos em Blocos
- Capacidade
  - Mais de 500 Gigabytes
  - Quadruplica a cada 3 anos
  - Podem ser agrupados para armazenarem Terabytes de Dados.

Disk Drivers:Terminologia

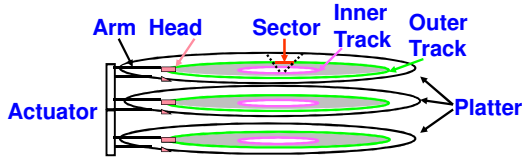

- Vários pratos, com a informação armazenada magneticamente em ambas superfícies (usual)
- Bits armazenados em trilhas, que por sua vez são divididas em setores (e.g., 512 Bytes)
- O Atuador move a cabeça (fim do braço,1/superfície) sobre a trilha ("seek"), seleciona a superfície, espera pelo setor passar sob a cabeça, então lê ou escreve
  - "Cilindro": todas as trilhas sob as cabeças

Foto: Braço, Cabeça, Atuador e Pratos

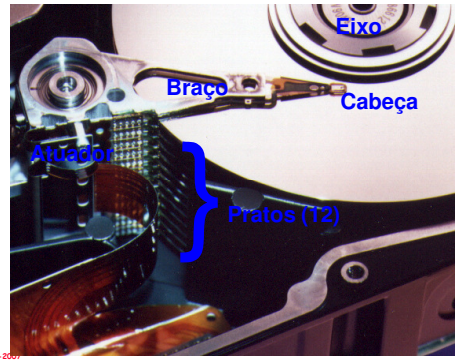

Discos: Exemplos

Seagate Cheetah **ST3146807FC**

147 Gigabytes	4 disks, 8 heads
10,000 RPM	290,000,000 Total Sectors
4.7 ms avg seek time.	50,000 cylinders
Fibre Channel	Average of 6,000 sectors/cylinder or 800 sectors / track (but different amounts on each track.)
$499.00	MTBF = 1,200,000 hours

http://www.seagate.com/cda/products/discsales/marketing/detail/0,1121,355,00.html

Discos: Exemplos

Barracuda Cheetah **ST320822A**

200 Gigabytes	2 disks, 4 heads
7,200 RPM	390,000,000 Total Sectors
8.5 ms avg seek time.	24,000 cylinders
ATA	Average of 16,000 sectors/cylinder or 400 sectors / track (but different amounts on each track.)
$299.00	MTBF = ????????????? hours

http://www.seagate.com/support/disc/manuals/fc/100195490b.pdf

Disk Device: Desempenho

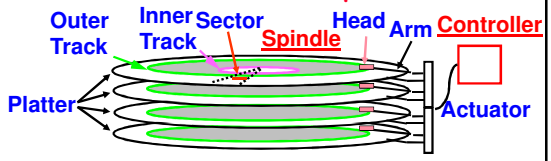

- Disk Latency = Seek Time + Rotation Time + Transfer Time + Controller Overhead
- Seek Time? Depende do no. de trilhas e velocidade de seek do disco
- Rotation Time? depende da velocidade de rotação do disco
- Transfer Time? depende do data rate (bandwidth) do disco (densidade dos bits), tamanho da requisição

Disk Device: Desempenho

- Distância Média do setor à Cabeça?
- 1/2 tempo de uma Rotação
  - 10000 Revoluções Por Minuto ⇒ 166.67 Rev/sec
  - 1 revolução = 1/ 166.67 seg ⇒ 6.00 millisegundos
  - 1/2 rotação (revolução) ⇒ 3.00 ms
- Nº Médio de Trilhas Saltadas pelo Braço?
  - Soma das distâncias de todos seeke possíveis a partir de todas as trilhas possíveis / # possibilidades
    - » Assume-se distribuição randômica
  - Indústria usa benchmark padrão

Data Rate: Trilha Interna vs. Externa

- Por questões de simplicidade, originalmente tem-se o mesmo número de setores por trilha
  - Como as trilhas externas são maiores elas possuem menos bits por polegada
- Competição ⇒ decisão de se ter o mesmo BPI (bit per inch) para todas as trilhas ("densidade de bits constante")
  - ⇒ Maior capacidade por disco
  - ⇒ Mais setores por trilha nas bordas
  - ⇒ Uma vez que a velocidade rotacional é constante, trilhas externas possuem data rate maior (maior velocidade linear)
- Bandwidth da trilha externa é 1.7X a da trilha interna!
  - Trilha interna possui densidade maior, trilha externa possui densidade menor, a densidade não é constante
    (2.1X length of track outer / inner; 1.7X bits outer / inner)

Disco Magnético

- Propósito:
  - Longo tempo, não volátil
  - Grande, barato, baixo nível na hierarquia de memória
- Características:
  - Seek Time (~8 ms avg)
    - » latência posicional
    - » latência rotacional
- Taxa de Transferência
  - 10-40 MByte/sec
  - Blocos
- Capacidade
  - Gigabytes
  - 4X a cada 3 anos

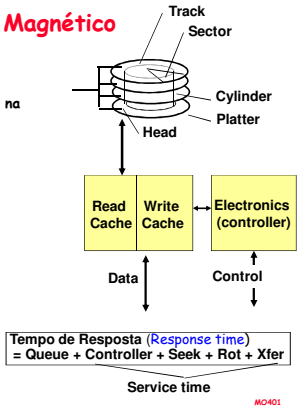

Disco: Modelo de Desempenho

- **Capacidade**
  - + 100%/ano (2X / 1.0 ano)
- **Transfer rate (BW)**
  - + 40%/ano (2X / 2.0 anos)
- **Tempo de Rotação + Seek**
  - – 8%/ ano (1/2 em 10 anos)
- **MB/$**
  - > 100%/ano (2X / 1.0 ano)

Barracuda 180

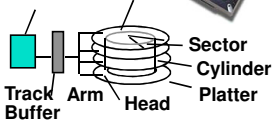

- 181.6 GB, 3.5 inch disk
- 12 platters, 24 surfaces
- 24,247 cylinders
- 7,200 RPM; (4.2 ms avg. latency)
- 7.4/8.2 ms avg. seek (r/w)
- 64 to 35 MB/s (internal)
- 0.1 ms controller time
- 10.3 watts (idle)

Latency = Queuing Time + Controller time + Seek Time + Rotation Time + Size / Bandwidth

por acesso + *por byte*

fonte: www.seagate.com

Desempenho de Disco: Exemplo

- Tempo calculado para ler 64 KB (128 setores) no "Barracuda 180" usando os dados de desempenho informados (os setores estão na trilha externa)

latência = average seek time + average rotational delay + transfer time + controller overhead

= 7.4 ms + 0.5 * 1/(7200 RPM) + 64 KB / (64 MB/s) + 0.1 ms

= 7.4 ms + 0.5 /(7200 RPM/(60000ms/M)) + 64 KB / (64 KB/ms) + 0.1 ms

= 7.4 + 4.2 + 1.0 + 0.1 ms = 12.7 ms

Densidade em Área

- Os Bits estão armazenados ao longo da trilha
  - Métrica: Bits Per Inch (BPI)
- Número de trilhas por superfície
  - Métrica: Tracks Per Inch (TPI)
- Projetistas de Discos falam em densidade de bits por área
  - Métrica: Bits Per Square Inch
  - Denominado: Areal Density
  - Areal Density = BPI x TPI

Densidade por Área

Year	Areal Densit
1973	1.7
1979	7.7
1989	63
1997	3090
2000	17100

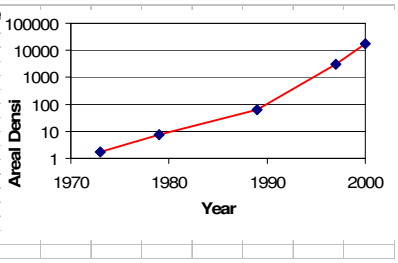

Areal Density = BPI x TPI

MBits per Square Inch: DRAM como % de Disco ao Longo do Tempo

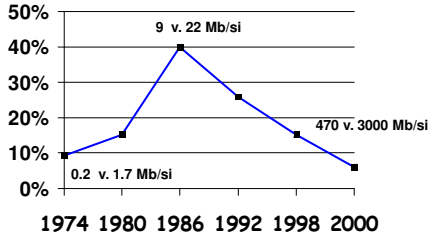

fonte: New York Times, 2/23/98, page C3, "Makers of disk drives crowd even more data into even smaller spaces"

Histórico

- 1956 IBM Ramac — início 1970s Winchester
  - Desenvolvido para computadores mainframe, interface proprietária
  - 27 inch a 14 inch
- Forma e capacidade orientaram o mercado mais que desempenho
- 1970s: Mainframes ⇒ discos de 14 inch de diâmetro
- 1980s: Minicomputadores, Servidores ⇒ 8",5 1/4" de diâmetro
- Fim 1980s/Inicio 1990s: PCs, workstations
  - Começou a se tornar realidade o mercado de discos de alta capacidade
    - » Padrões da industria: SCSI, IPI, IDE
  - Pizzabox PCs ⇒ discos de 3.5 inch de diâmetro
  - Laptops, notebooks ⇒ discos de 2.5 inch
  - Palmtops não usam discos
- 2000s:
  - 1 inch para mobile devices (câmeras, telefone celular)?
  - Seagate: 12GB, 1inch hard drive disk (fev/2006)

História

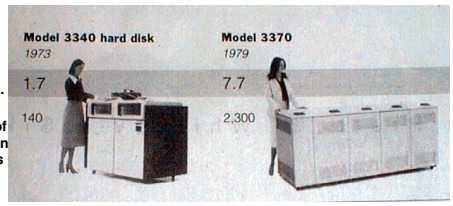

1973:
1. 7 Mbit/sq. in
140 MBytes

1979:
7. 7 Mbit/sq. in
2,300 MBytes

fonte: New York Times, 2/23/98, page C3,
"Makers of disk drives crowd even mroe data into even smaller spaces"

História

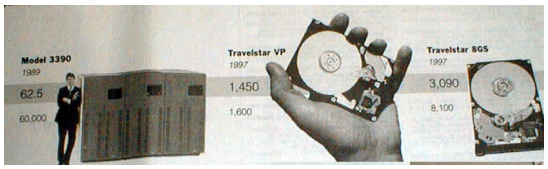

1989:
63 Mbit/sq. in
60,000 MBytes

1997:
1450 Mbit/sq. in
2300 MBytes

1997:
3090 Mbit/sq. in
8100 MBytes

fonte: New York Times, 2/23/98, page C3,
"Makers of disk drives crowd even more data into even smaller spaces"

História

disk drive de 1 inch

- 2000 IBM MicroDrive:
  - 1.7" x 1.4" x 0.2"
  - 1 GB, 3600 RPM, 5 MB/s, 15 ms seek
  - Digital camera, PalmPC?
- 2006 MicroDrive?
- 9 GB, 50 MB/s!
  - Assumindo que tenham encontrado um nicho e o produto é um sucesso
  - Assumindo que as tendências de 2000 continuem

Carcterísticas dos Discos em 2000

	Seagate Cheetah ST173404LC Ultra160 SCSI	IBM Travelstar 32GH DJSA - 232 ATA-4	IBM 1GB Microdrive DSCM-11000
Disk diameter (inches)	3.5	2.5	1.0
Formatted data capacity (GB)	73.4	32.0	1.0
Cylinders	14,100	21,664	7,167
Disks	12	4	1
Recording Surfaces (Heads)	24	8	2
Bytes per sector	512 to 4096	512	512
Avg Sectors per track (512 byte)	~ 424	~ 360	~ 140
Max. areal density(Gbit/sq.in.)	6.0	14.0	15.2
	$828	**$447**	**$435**

Carcterísticas dos Discos em 2000

	Seagate Cheetah ST173404LC Ultra160 SCSI	IBM Travelstar 32GH DJSA - 232 ATA-4	IBM 1GB Microdrive DSCM-11000
Rotation speed (RPM)	10033	5411	3600
Avg. seek ms (read/write)	5.6/6.2	12.0	12.0
Minimum seek ms (read/write)	0.6/0.9	2.5	1.0
Max. seek ms	14.0/15.0	23.0	19.0
Data transfer rate MB/second	27 to 40	11 to 21	2.6 to 4.2
Link speed to buffer MB/s	160	67	13
Power idle/operating Watts	16.4 / 23.5	2.0 / 2.6	0.5 / 0.8

Carcterísticas dos Discos em 2000

	Seagate Cheetah ST173404LC Ultra160 SCSI	IBM Travelstar 32GH DJSA - 232 ATA-4	IBM 1GB Microdrive DSCM-11000
Buffer size in MB	4.0	2.0	0.125
Size: height x width x depth inches	1.6 x 4.0 x 5.8	0.5 x 2.7 x 3.9	0.2 x 1.4 x 1.7
Weight pounds	2.00	0.34	0.035
Rated MTTF in powered-on hours	1,200,000	(300,000?)	(20K/5 yr life?)
% of POH per month	100%	45%	20%
% of POH seeking, reading, writing	90%	20%	20%

Carcterísticas dos Discos em 2000

	Seagate Cheetah ST173404LC Ultra160 SCSI	IBM Travelstar 32GH DJSA - 232 ATA-4	IBM 1GB Microdri DSCM-11000
Load/Unload cycles (disk powered on/off)	250 per year	300,000	300,000
Nonrecoverable read errors per bits read	<1 per 10^{15}	< 1 per 10^{13}	< 1 per 10^{13}
Seek errors	<1 per 10^{7}	not available	not available
Shock tolerance: Operating, Not operating	10 G, 175 G	150 G, 700 G	175 G, 1500 G
Vibration tolerance: Operating, Not operating (sine swept, 0 to peak)	5-400 Hz @ 0.5G, 22-400 Hz @ 2.0G	5-500 Hz @ 1.0G, 2.5-500 Hz @ 5.0G	5-500 Hz @ 1G, 500 Hz @ 5G

Falácia: Use o Tempo "Average Seek" do Fabricante

- Os Fabricantes necessitam de padrões para comparações ("benchmark")
  - Calculam todos os seeks a partir de todas as trilhas, dividem pelo número de seeks => "average"
- A Média Real deve ser baseada em como os dados são armazenados no disco (definindo os seeks em aplicações reais)
  - Usualmente, a tendência é as trilhas acessadas serem próximas e não randômicas
- Rule of Thumb: "average seek time" observado na prática é tipicamente cerca de 1/4 a 1/3 do "average seek time" cotado pelo fabricante (i.é., 3X-4X mais rápido)
  - Barracuda 180 X avg. seek: 7.4 ms ⇒ 2.5 ms

Falácia: Use o "Transfer Rate" do Fabricante

- Os Fabricantes cotam a velocidade dos dados na superfície do disco ("internal media rate")
- Setores contém campos para deteção e correção de erros (pode ser até 20% do tamanho do setor); número do setor e os dados
- Existem gaps entre os setores em uma trilha
- Rule of Thumb: Os discos utilizam cerca de 3/4 da "internal media rate" (1.3X mais lento) para dados
- Por exemplo, Barracuda 180X:

64 a 35 MB/sec para a "internal media rate"
⇒ 48 a 26 MB/sec "external data rate" (74%)

Desempenho de Discos: Exemplo

- Calcular o tempo para ler 64 KB do "Barracuda 180" outra vez, agora use 1/3 do seek time cotado e 3/4 do "internal outer track bandwidth; (Anterior: 12.7 ms)

Latência = average seek time + average rotational delay + transfer time + controller overhead

= (0.33 * 7.4 ms) + 0.5 * 1/(7200 RPM) + 64 KB / (0.75 * 64 MB/s) + 0.1 ms

= 2.5 ms + 0.5 /(7200 RPM/(60000ms/M)) + 64 KB / (48 KB/ms) + 0.1 ms

= 2.5 + 4.2 + 1.33 + 0.1 ms = 8.13 ms (64% de 12.7)

Barramentos (busses): Conectando Dispositivos de IO à CPU e Memória

- De uma forma simples, um barramento (bus) é a conexão entre vários chips/componentes em um computador.
- O barramento é responsável por enviar dados/controle entre esses vários componentes.

Barramentos

- Interconexão = liga as interfaces dos componentes do sistema
- Interfaces de hw de alta velocidade + protocolo lógico
- Networks, channels, backplanes

	Network	Channel	Backplane
Conexão	Máquinas	Devices	Chips
Distância	>1000 m	10 - 100 m	0.1 m
Bandwidth	10 - 1000 Mb/s	40 - 1000 Mb/s	320 - 2000+ Mb/s
Latência	alta (1ms)	média	baixa (Nanosecs.)
Confiabilidade	baixa Extensive CRC	média Byte Parity	alta Byte Parity

message-based
narrow pathways
distributed arbitration

memory-mapped
wide pathways
centralized arbitration

Barramentos
Systemas com Um Barramento - Backplane Bus

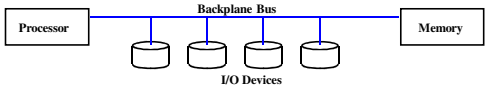

- Single Bus (Backplane Bus) é usado para:
  - Comunicação entre o Processador e a Memória
  - Comunicação entre dispositivos de I/O e memória
- Vantagens: Simples e baixo custo
- Desavantagens: lento e o barramento, em geral, torna-se o maior gargalo
- Exemplo: IBM PC - AT

Barramentos
Systemas com Dois Barramentos

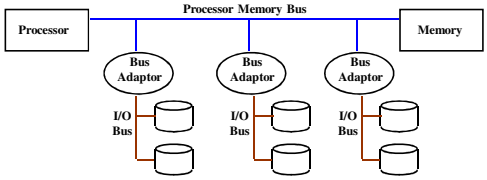

- I/O buses ligados ao barramento processador-memória via adaptadors:
  - Processor-memory Bus: prioridade para o tráfego processador-memória
  - I/O buses: provê slots para expansão para I/O devices
- Apple Macintosh-II
  - NuBus: Processador, memória, e uns poucos (selecionados) dispositivos de I/O
  - SCCI Bus: para os outros dispositivos de I/O

Barramentos
Systemas com Três Barramentos

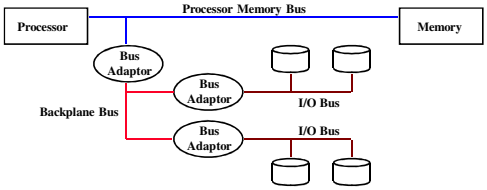

- Um pequeno Backplane Bus é ligado ao Processor-Memory Bus
  - Processor-Memory Bus é dedicado ao tráfego processador-memória
  - I/O buses são conectados ao Backplane Bus
- Vantagem: A carga no Processor-Memory Bus é reduzida

Barramentos
North/South Bridge Architectures: Busses Separados

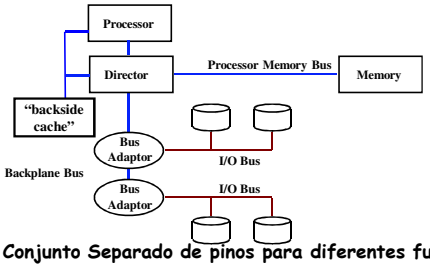

- Conjunto Separado de pinos para diferentes funções
  - Memory bus; Caches; Graphics bus (para fast frame buffer)
  - I/O busses são conectados ao backplane bus
- Vantagens:
  - Os barramentos podem operar em diferentes velocidades
  - Menos sobre-carga nos barramentos; acessos paralelos

Barramentos
O que define um Barramento?

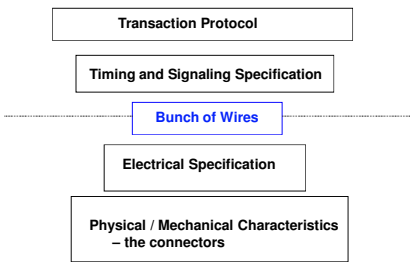

Barramentos
Síncronos e Assíncronos

- Synchronous Bus:
  - Inclui um clock nas linhas de controle
  - Protocolo de comunicação fixo baseado no clock
  - Vantagens: involve muito menos lógica e pode operar em altas velocidades
  - Desvantagens:
    - » Todo dispositivo no barramento deveoperar no mesmo clock rate
    - » Para evitar clock skew, os barramentos não podem ser longos se são rápidos
- Asynchronous Bus:
  - Não usam sinal de clock
  - Podem acomodar uma grande variedade de dispositivos
  - Podem serem longos sem se preocupar com clock skew
  - Requer um protocolo de handshaking

Barramentos

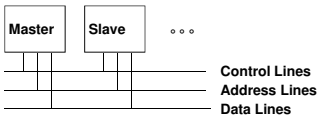

- Bus Master: tem abilidade de controlar o barramento, inicia as transações
- Bus Slave: módulo ativado por uma transação
- Bus Communication Protocol: especificação de uma seqüência de eventos e timing requeridos em uma transferência de informação.
- Asynchronous Bus Transfers: linhas de controle (req, ack) servem para realizar o seqüenciamento.
- Synchronous Bus Transfers: a seqüência é relativa a um clock comum.

Barramentos
Arbitragem: Obtenção de Acesso

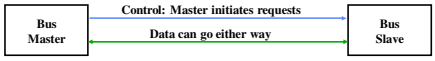

- Uma das questões mais importantes em bus design:
  - Como o barramento é reservado por um dispositivo que o quer usar?
- O Caos pode ser evitado pelo arranjo master-slave :
  - Somente o bus master pode controlar o acesso ao barramento:
    - » Ele inicia e controla todas as requisições do barramento
  - Um bus slave responde a requisições de leitura e/ou escrita
- Sistema mais simples:
  - O Processador é o único bus master
  - Toda bus requests deve ser controlada pelo processador
  - Maior desvantagem: o processador participa em todas as transações

Barramentos
Arbitragem: Daisy Chain

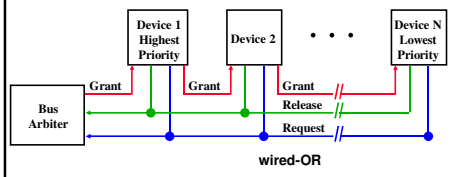

Ordem:
1. Request
2. Grant
3. Release.

- Vantagem: simples
- Desvantagens:
  - Não pode garantir justiça:
    Um dispositivo de baixa prioridade pode ficar bloqueado indefinidamente
  - O uso do sinal daisy chain grant também limita a velocidade do barramento

Barramentos
Um Protocolo Sícrono Simples

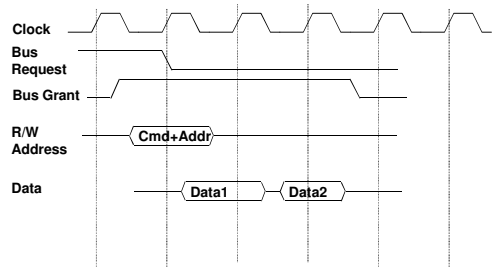

- Os memory busses são mais complexos que isso
  - memória (slave) pode levar um certo tempo para responder
  - Pode necessitar controlar o data rate

Barramentos
Protocolo Handshake Assícrono (4-fases)

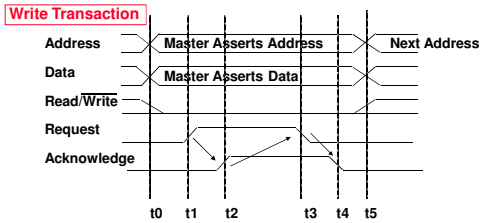

t0: Master tem o controle e asserts o endereço, direção (not read), dado. Espera uma quantidade pré-definida de tempo para o Slave decodificar o alvo

t1: Master asserts a request line

t2: Slave asserts o ack, indicando que recebeu o dado

t3: Master libera o request

t4: Slave libera o acknowledge

Barramentos
Protocolo Handshake Assícrono (4-fases)

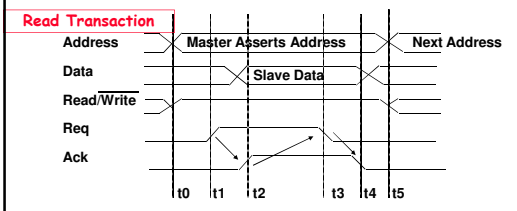

t0: Master obtém o controle e asserts o endereço e a direção. Espera uma quantidade pré-definida de tempo para o Slave decodificar o alvo

t1: Master asserts a request line

t2: Slave asserts o ack, indicando que está pronto para transmitir o dado

t3: Master libera o req, o dado é recebido

t4: Slave libera o ack

Barramentos
Exemplo: PCI Read/Write Transaction

- Todos os Sinais são amostrados na borda de subida (rising edge)
- Arbitragem Centralizada e Paralela
  - Sobreposição com transações prévias
- Todas as transferências são Burst (ilimitada)
- Address phase tem início pelo asserting FRAME#
- Próximo ciclo asserts cmd e address
- A transferência de Dados ocorre quando
  - IRDY# asserted pelo master quando pronto para transferir dados
  - TRDY# asserted pelo target quando pronto para transferir dados
  - Transfere quando ambos asserted e rising edge
- FRAME# de-asserted quando master tem a intenção de completar somente mais uma transferência de dados

Barramentos
Exemplo: PCI Read Transaction

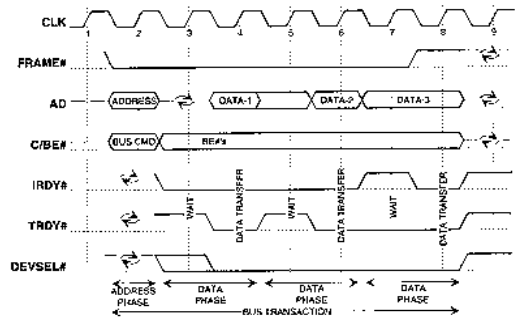

Figure 3-1: Basic Read Operation

The PCI Read transfer burst

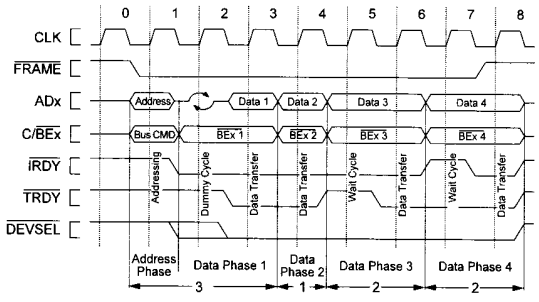

Interface: Processador & I/O

- A interface consiste em informar ao dispositivo como e qual operação será realizada:
  - Read ou Write
  - Tamanho da transferência
  - Localização no dispositivo
  - Localização na memória
- Acionar (triggering) o dispositivo para iniciar a operação
- Quando terminar a operação, o dispositivo interrompe o processador.

Interface: Processador & I/O

Dois tipos de mapeamento:

- Mapeamento em I/O
  - Instruções de I/O especificas
  - Ex.1: LDD R0,D,P <-- Load R0 com o conteúdo do dispositivo D, porta P
  - Ex.2: IN AX,0f1
    OUT AX,0f2
- Mapeamento em Memória
  - Não existem instruções especiais de I/O
  - Ex.1: LD R0,Mem1 <-- Load R0 com o conteúdo do dispositivo D, porta P.

Interface: Processador & I/O

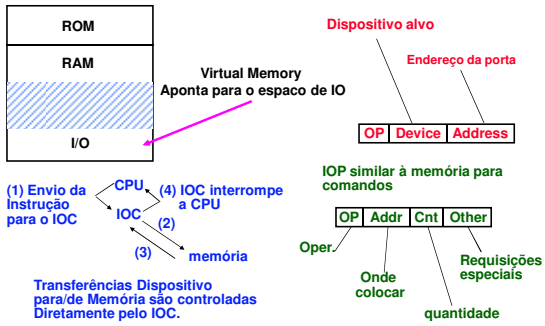

Memory Mapped I/O

Alguns endereços físicos são usados aparte.
Não existe memória real nesses endereços.
No lugar da memória, quando o processador acessa esses endereços, ele envia comandos ao processador de IO.

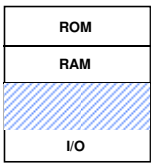

Métodos de Transferências: Programmed I/O (Polling)

busy wait loop
(Não é eficiente)

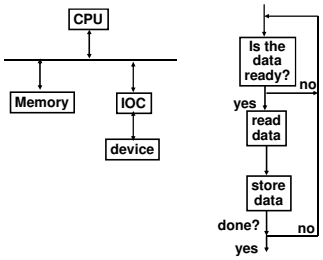

Métodos de Transferências: Interrupção

- Uma interrupção de I/O é similar à uma exceção a menos de:
  - Uma interrupção de I/O é assíncrona
- Uma interrupção de I/O é assíncrona com respeito à execução das instruções:
  - Interrupção de I/O não é associada a alguma instrução
  - Interrupção de I/O não impede que qualquer instrução seja completada
    - » Deve haver um ponto conveniente para aceitar uma interrupção
- Interrupção de I/O é mais complexa que exceção:
  - Necessita identificar o dispositivo que gerou o pedido
  - Pedidos diferentes de interrupções podem ter diferentes prioridades :
    - » Pedidos de Interrupções precisam ser priorizados

Métodos de Transferências: Interrupção

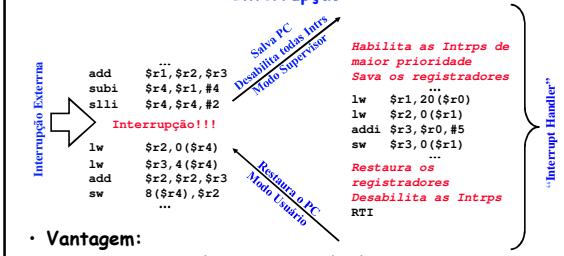

- Vantagem:
  - O programa do usuário em progresso é o único a ser parado
- Desvantagem, é necessário hw especial para:
  - Causar uma interrupção (I/O device)
  - Detetar uma interrupção (processador)
  - Savar o estado para reassumir a execução após a interrupção (processador)

Métodos de Transferências: Interrupt Driven Data Transfer

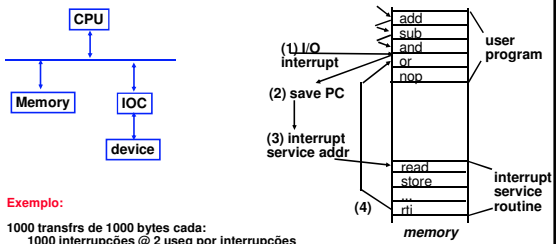

Exemplo:

1000 transfrs de 1000 bytes cada:
1000 interrupções @ 2 µseg por interrupções
1000 transfrs por interp @ 98 µseg cada = 0.1 CPU seg

Taxa Transf. = 10 MBytes/sec => 0 .1 x 10^{-6} seg/byte => 0.1 µseg/byte
=> 1000 bytes = 100 µseg
1000 transfrs x 100 µsecs = 100 ms = 0.1 CPU segs

Métodos de Transferências:
DMA - Direct Memory Access

CPU envia Endereço de início, Direção e Tamanho da transferência para o IOC. Então envia o "start".

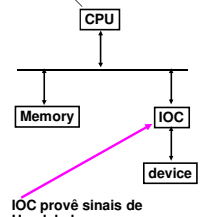

- Direct Memory Access (DMA):
  - Externo à CPU
  - Age como um Master no barramento
  - Transfere blocos de dados para a (da) memória sem "intervenção" da CPU

IOC provê sinais de Handshake para o Controlador do Periférico e Endereços e sinais de Handshake para a Memória.

Métodos de Transferências:
DMA - Direct Memory Access

CPU envia Endereço de início, Direção e Tamanho da Transferência para o IOC. Então envia o "start".

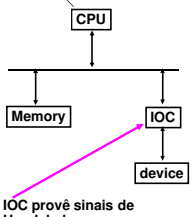

IOC provê sinais de Handshake para o Controlador do Periférico e Endereços e sinais de Handshake para a Memória.

Tempo para transfr. 1000 de 1000 bytes cada:
1 DMA seqüência de controle @ 50 µsec
1 interrupção @ 2 µsec
1 seq. do serviço de interrupção @ 48 µsec

.0001 segundos => tempo de CPU

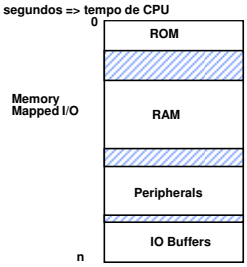

Uso de Arrays de Pequenos Discos?

Projeto de 4 Discos Convencionais:

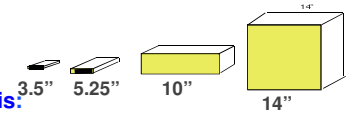

Low End → High End

Disk Array: 1 projeto de disco

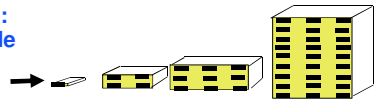

Uso de um pequeno no. de discos grandes vs uso de um no. grande de pequenos discos

	IBM 3390K	IBM 3.5" 0061	x70	
Capacidade	20 GBytes	320 MBytes	23 GBytes	
Volume	97 ft²	0.1 ft²	11 ft²	9X
Power	3 KW	11 W	1 KW	3X
Data Rate	15 MB/s	1.5 MB/s	120 MB/s	8X
I/O Rate	600 I/Os/s	55 I/Os/s	3900 IOs/s	6X
MTTF	250 KHrs	50 KHrs	??? Hrs	
Custo	$250K	$2K	$150K	

Disk Arrays tem potencial para grandes quantidades de dados e I/O rates, alto MB por volume, alto MB por KW, e confiabilidade?

Array: Confiabilidade

- "Reliability" de N discos = "Reliability" de 1 Disco ÷ N

  50,000 Horas ÷ 70 discos = 700 horas

  Disk system MTTF: cai de 6 anos para 1 mês!

- Arrays (sem redundâncias) são pouco confiáveis!

Redundant Arrays com Discos Baratos

- Os Arquivos são divididos e armazenados em múltiplos discos
- Redundância provê alta disponibilidade de dados
  - Disponibilidade: o serviço continua sendo provido mesmo que algum componente falha
- Discos ainda podem falhar
- O Conteúdo pode ser reconstruído a partir dos dados armazenados de forma redundante no array
  - ⇒ Penalidade na capacidade para armazenamento redundante
  - ⇒ Penalidade no Bandwidth para atualizar dados redundantes

Técnicas: Mirroring/Shadowing (high capacity cost); Parity

Redundant Arrays of Disks
RAID 1: Disk Mirroring/Shadowing

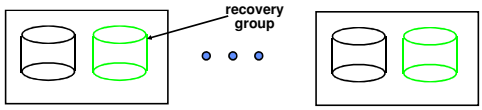

- Cada disco é totalmente duplicado em seu "shadow"
  Proporciona alta disponibilidade
- Bandwidth é sacrificado na escrita:
  Escrita lógica = duas escritas físicas
- Leituras podem ser otimizadas
- Solução mais cara : 100% de overhead na capacidade

High I/O rate , ambientes com alta disponibilidade

Redundant Array of Inexpensive Disks
Independent

Redundant Arrays of Disks
RAID 3: Parity Disk

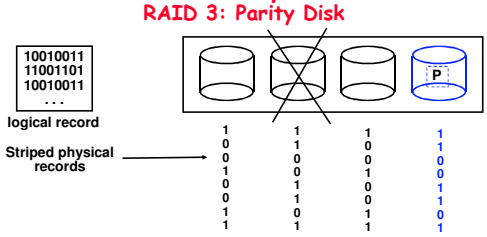

- Paridade calculada para o grupo de recuperação, protegendo contra falhas nos discos
  33% de custo de capacidade para a paridade nesta configuração
  arrays maiores reduzem o custo de capacidade, decresce a disponibilidade esperada, aumenta o tempo de reconstrução

Eixos sincronizados

Aplicações de alto bandwidth: Científicas, Processamento de Imagem

RAID 4
Inspiração:

- RAID 3 utiliza o (confia no) disco de paridade para recuperar erros na leitura
- Porém, todos setores já possuem um campo para deteção de erros
- Utilizar o campo de deteção de erros para capturar erros na leitura, não o disco de paridade
- Permitir leituras independentes simultâneas em discos diferentes

Redundant Arrays of Disks
RAID 4: High I/O Rate Parity

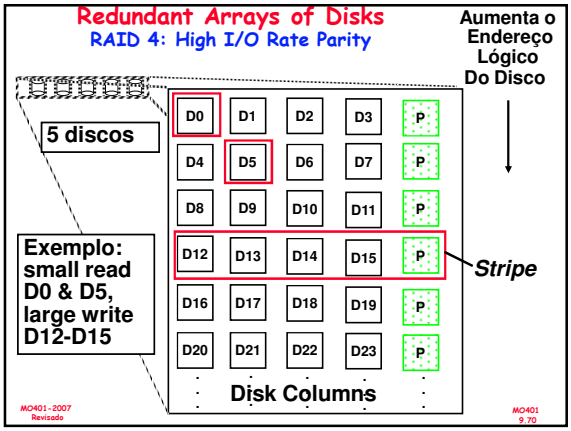

RAID 5: Inspiração

- RAID 4 trabalha bem para leituras pequenas
- Pequenas escritas (escritas em um disco):
  - Opção 1: lêr outro disco de dados, criar nova soma e escrever no Disco de Paridade
  - Opção 2: uma vez que P tem uma soma antiga, compar dado velho com dado novo, adicionar somente a diferença em P
- Pequenas escritas são limitadas pelo Disco de Paridade: escrever em D0, D5 em ambos os casos também se escreve no disco P

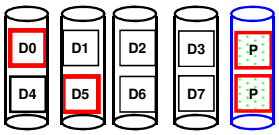

Redundant Arrays of Inexpensive Disks RAID 5: High I/O Rate Interleaved Parity

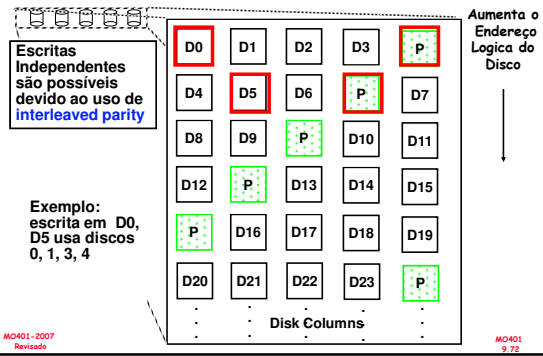

Problemas com Disk Arrays:
Escritas Pequenas

RAID-5: Algoritmo para escritas Pequenas

1 Escrita Lógica = 2 Leituras Físicas + 2 Escritas Físicas

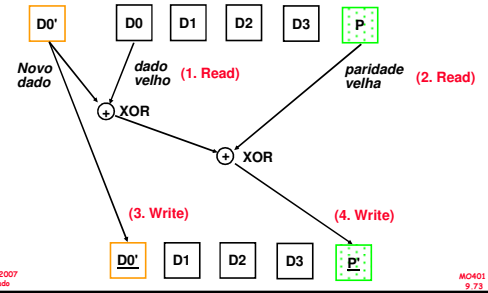

RAID
Organização dos Subsistemas

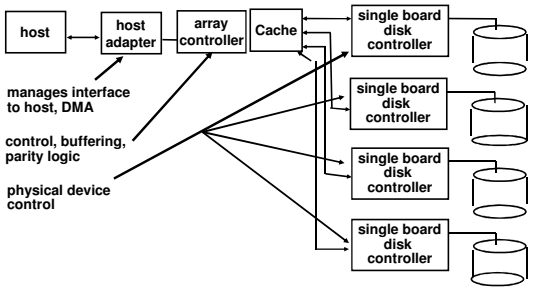

Disponibilidade do Sistema
RAIDs Ortogonais

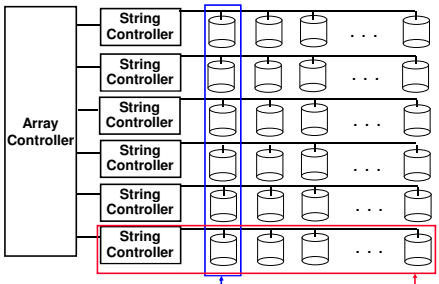

Data Recovery Group: unidade de redundância de dados

Redundant Support Components: fans, power supplies, controller, cables

End to End Data Integrity: paridade interna proteje os data paths

Disponibilidade do Sistema