

FSO - 29/10/2018

Sumário:

Tecnologia de discos:

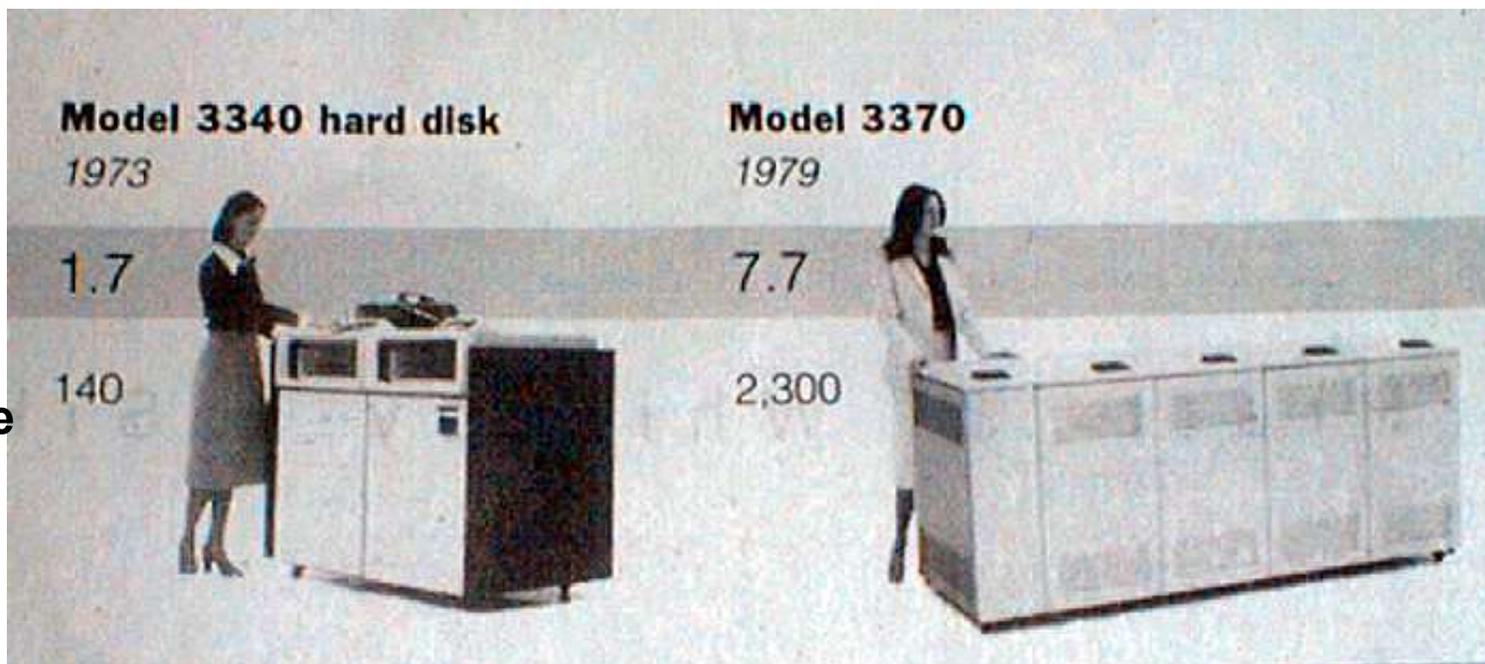
- Discos magnéticos
- RAID

Bibliografia: OSTEP 37, 38

História dos discos

Densidade
Mbit/sq. in.

Capacidade
em
Megabytes



1973:
1.7 Mbit/sq. in
140 MBytes

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

História dos discos



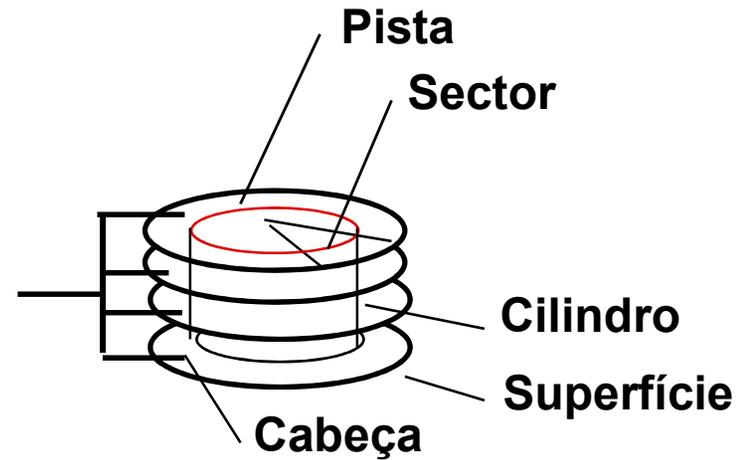
1989:
63 Mbit/sq. in
60,000 MBytes

1997:
1450 Mbit/sq. in
2300 MBytes

1997:
3090 Mbit/sq. in
8100 MBytes

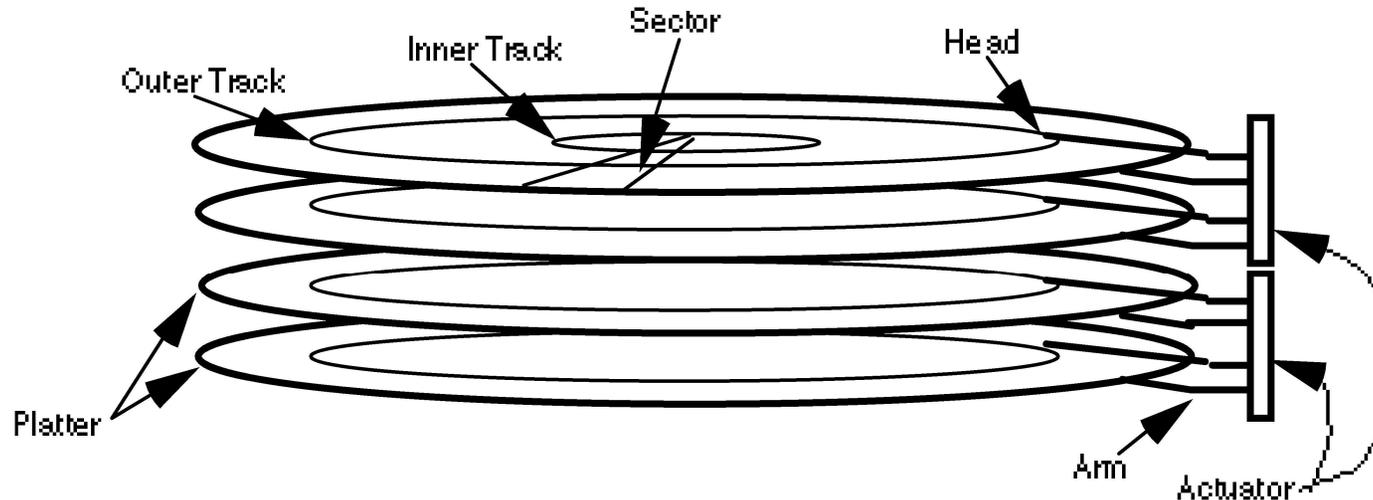
Discos magnéticos

- Características:
 - armazenamento não volátil a longo prazo
 - grande capacidade, nível mais lento na hierarquia de memória
 - Transferência por blocos
- Capacidade: gigabytes e quadruplica de 3 em 3 anos



Terminologia de discos

**Latência do disco = Tempo de espera na fila + Tempo do controlador +
Tempo de Seek + Tempo de Rotação + Tempo de Transferência**



Tempos aproximados para a transferência de um bloco (clusters) de 4K byte :

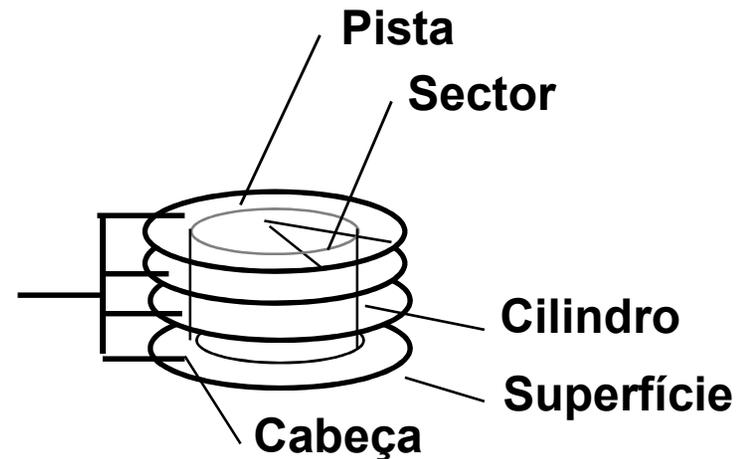
Seek: 8 ms ou menos

Rotação: 4.2 ms @ 7200 rpm

Transferência: 1 ms @ 7200 rpm

Discos magnéticos

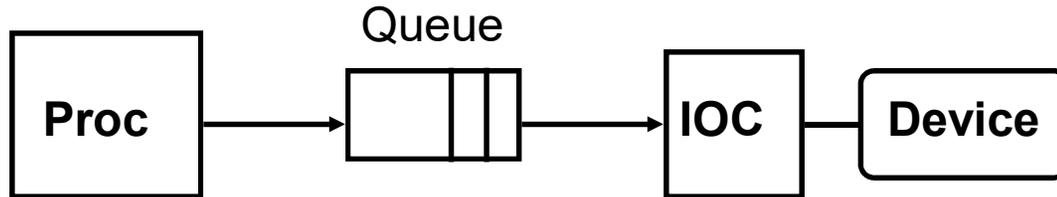
- Seek Time (~8/10 ms fabricante)
 - depende do número de pistas atravessado
 - valor anunciado pelo fabricante corresponde à travessia de um número de pistas fixo (ex. metade das pistas)
- Latência rotacional
 - Metade do tempo de rotação
- Tempo de transferência: aproximado por n° blocos por pista / tempo de rotação
- *Tempo de transferência controlador -> RAM* : tamanho_bloco / vel de transferência do Bus de entrada/saída
- Tempo de transferência *disco-> controlador e controlador-> RAM (DMA)* é desprezável face aos outros



7200 RPM = 120 RPS => 8 ms por rot.
Latência de rotação média = 4 ms
128 sectors por pista => 0.25 ms por sector
1 KB por sector => 16 MB / s

Performance do I/O de disco

Tempo de resposta = Tempo na Fila + Tempo de Serviço do Disco



Teoria das filas de espera

T_r – tempo de resposta

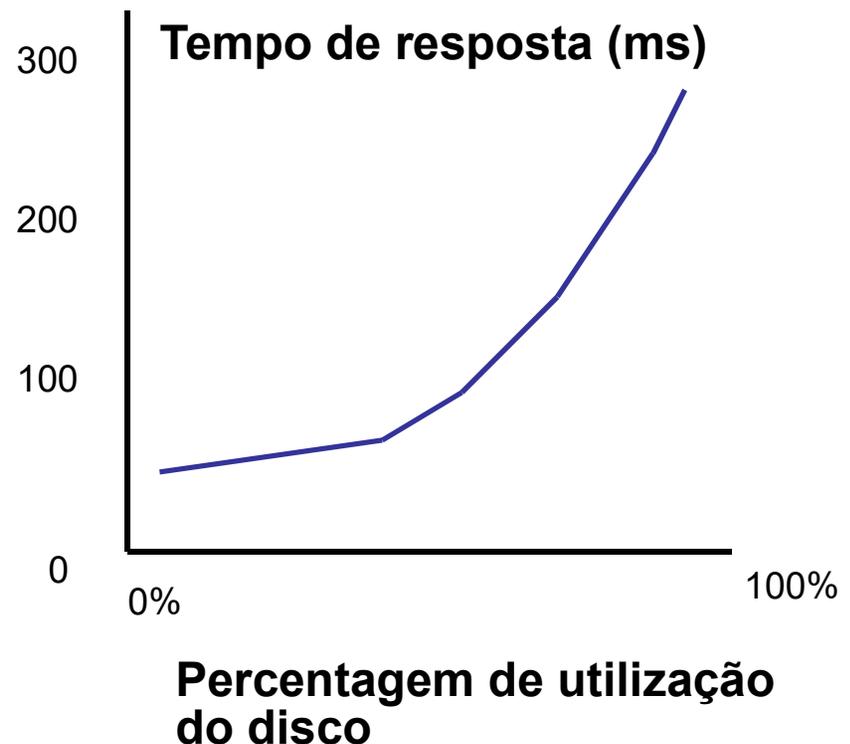
T_s – tempo de serviço

T_q – tempo de espera na fila

U - taxa de utilização

$U = n^\circ \text{ de pedidos/s} * T_s$

$$T_r = T_s / (1 - U)$$



Tempo de resposta de um disco

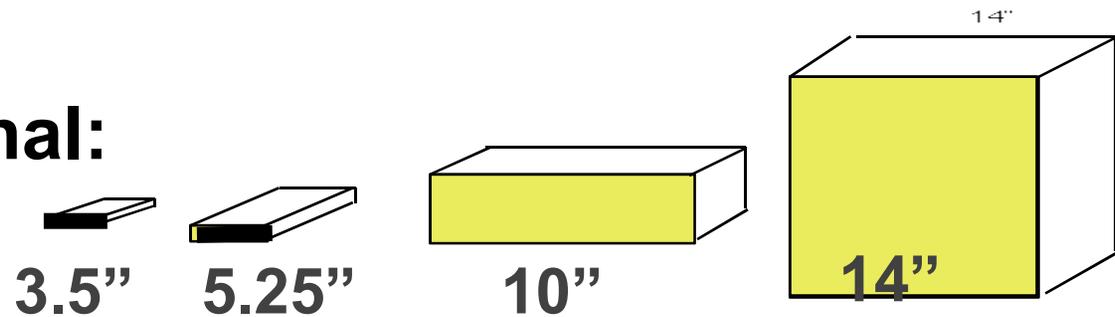
- Parâmetros do disco:
 - Tamanho do bloco é 8K bytes
 - Seek time publicitado é de 12 ms
 - Disco roda a 7200 RPM
 - taxa de transferência é 4 MB/sec
- Overhead no controlador de 2 ms
- Suponhamos que o disco está sempre livre - não há tempo de espera
- Qual é o tempo médio de acesso a um sector?
 - T. seek médio + rot delay médio + tempo transf. + ov. controlador
 - $12 \text{ ms} + 0.5 / (7200 \text{ RPM} / 60) + 8 \text{ KB} / 4 \text{ MB/s} + 2 \text{ ms}$
 - $12 + 4.15 + 2 + 2 = 20 \text{ ms}$
- O seek time assume que não há localidade: o real é tipicamente 1/4 a 1/3 do anunciado: $20 \text{ ms} \Rightarrow 12 \text{ ms}$

Estruturas RAID

- **RAID** – múltiplas unidades de disco suportam elevada **fiabilidade** através de **redundância**.
- Inicialmente foram definidos 6 níveis RAID
 - RAID 0 : só assegura aumento da velocidade de acesso, porque permite acessos em paralelo
 - RAID 1, 2, 3, 4 e 5: permite tolerância a falhas, porque há discos extra que asseguram redundância
- Outros níveis definidos mais recentemente
 - 6, 10 (ou 1+0) ...

Vantagens do fabrico de Disk Arrays

Convencional:
4 tipos de
discos



Baixo de
gama



Alto de
gama

Disk Array:
1 só tipo de
disco



Substituir um grande disco por muitos pequenos discos!

(Patterson 1988)

	IBM 3390 (K)	IBM 3.5" 0061	x70
Capacidade	20 GBytes	320 MBytes	23 GBytes
Volume	97 cu. ft.	0.1 cu. ft.	11 cu. ft.
Potência	3 KW	11 W	1 KW
Ritmo de transf	15 MB/s	1.5 MB/s	120 MB/s
Ritmo de ops I/O	600 I/Os/s	55 I/Os/s	3900 IOs/s
MTTF	250 KHrs	50 KHrs	??? Hrs
Custo	\$250K	\$2K	\$150K

Disk Arrays têm potencial para

- Grandes taxas de transferência
- high MB por cu. ft., high MB por KW
- fiabilidade?

Fiabilidade do Array

- **Fiabilidade de N discos = Fiabilidade de 1 Disco \div N**

50,000 Horas \div 70 discos = 700 horas

MTTF do sistema de discos : Desce de 6 anos para 1 mês!

- **Arrays (sem redundância) demasiado pouco fiáveis para terem utilidade!**

Suporte de “hot swap” com reconstrução em paralelo com a operação normal permite tem uma disponibilidade extremamente elevada

RAID=Redundant Arrays of Disks

- Os ficheiros são distribuídos ("striped") por várias unidades de disco
- Redundância garante alta disponibilidade dos dados

Em caso de falha de um disco, o conteúdo é reconstruído a partir de dados redundantes armazenados no array

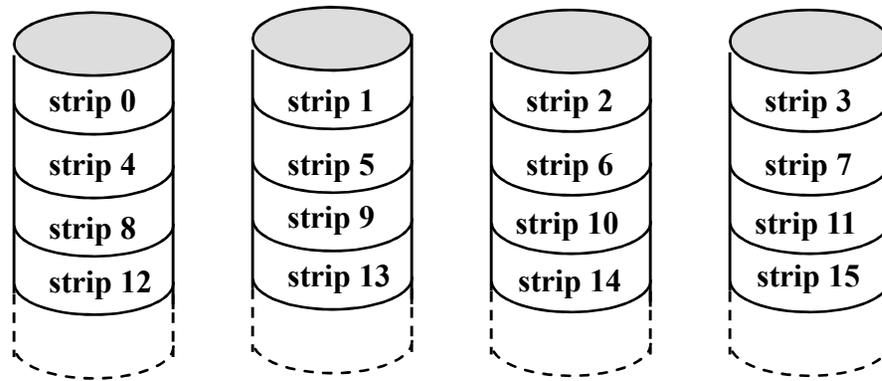
- Perde-se capacidade para os armazenar
- Existe uma penalização em bandwidth para actualização



RAID (cont)

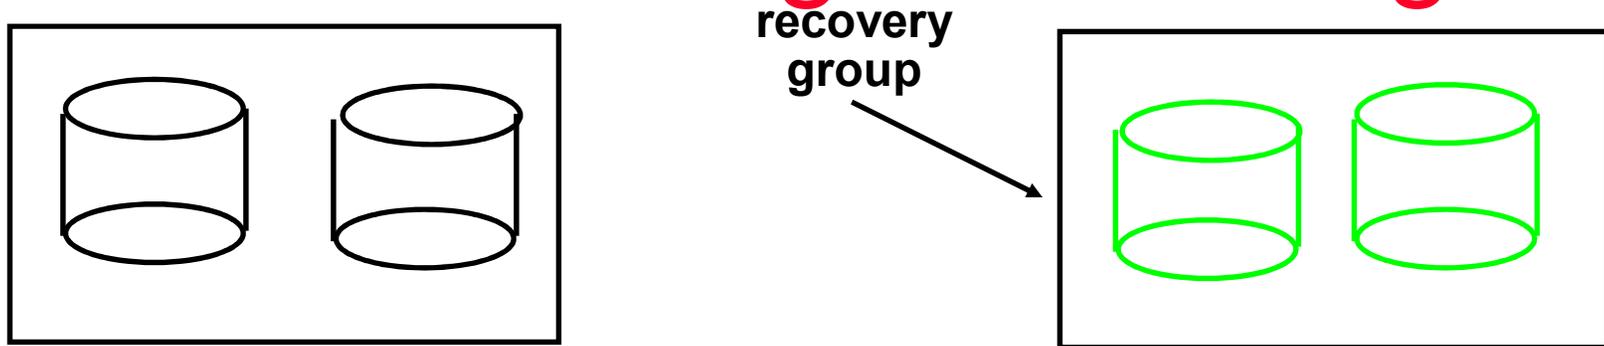
- Duas técnicas usadas:
 - “Disk striping” usa um grupo de discos como uma unidade lógica: diferentes partes dos dados são armazenados em discos diferentes
 - Aumento da velocidade de acesso e da fiabilidade através do armazenamento de dados redundantes.
 - *Mirroring* ou *shadowing* duplica discos inteiros.
 - *Block interleaved parity* usa muito menos redundância.

RAID 0 (não-redundante)



RAID 1

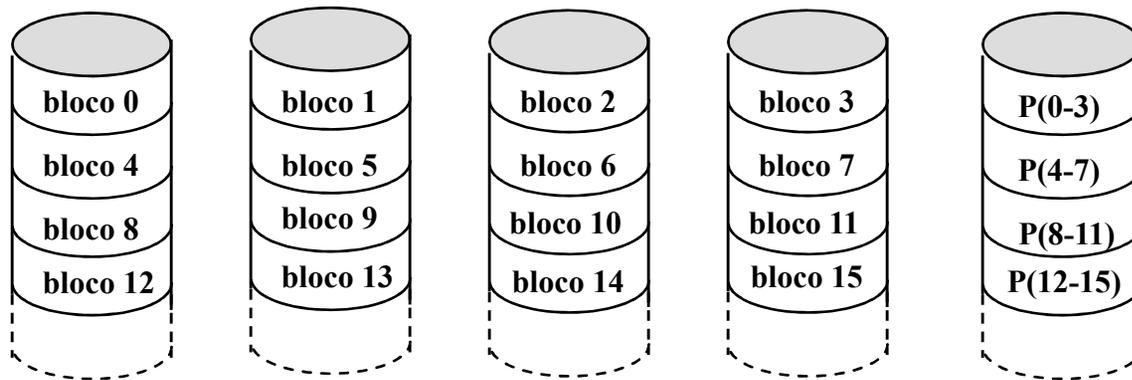
Disk Mirroring/Shadowing



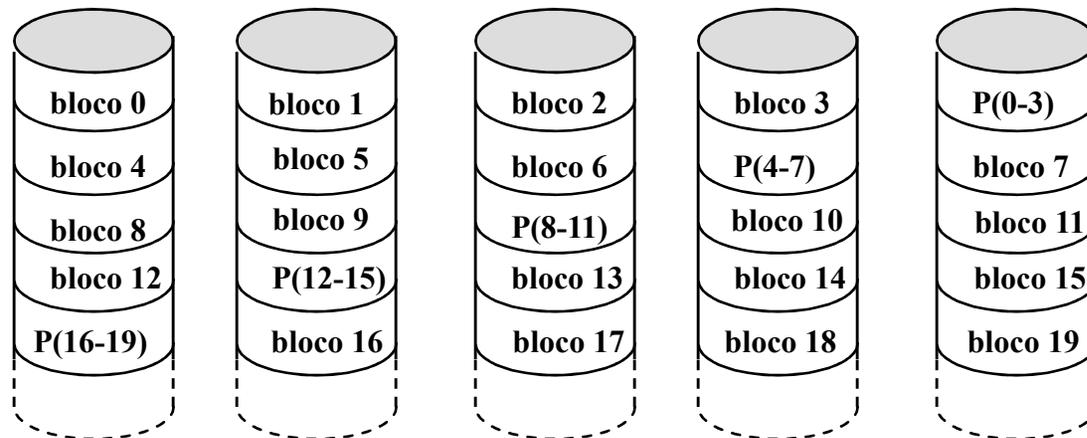
- Cada disco é completamente duplicado no seu "shadow"
Pode ser atingida uma disponibilidade muito elevada
- Sacrifício da largura de banda em escrita:
uma escrita lógica = duas escritas físicas
- As leituras podem ser otimizadas
- A solução mais cara: 100% de custos extra em capacidade

Usado em ambientes em que interessa alta disponibilidade e uma taxa elevada de operações de IO

RAID 4 (paridade a nível do bloco)



RAID 5 (paridade a nível do bloco distribuída)



Escritas em RAID 5

- RAID 5 é um bom compromisso velocidade / espaço desperdiçado para redundância
- Em RAID 5 uma operação de escrita inclui:
 - Escrever um novo conteúdo Y um bloco de dados D que continha X:
 - Ler o bloco D
 - Ler o bloco de paridade correspondente com o conteúdo Z
 - Escrever Y em D
 - Se fizermos $(X \text{ xor } Y)$ temos a 1 os bits diferentes
 - o novo conteúdo do bloco é $Z \text{ xor } (X \text{ xor } Y)$; troca os bits de paridade nas posições em que há diferenças
 - 2 leituras e duas escritas, mas pode haver paralelismo entre as duas leituras e as duas escritas