Sistemas Operacionais

Gestão de arquivos - sistemas de arquivos

Prof. Carlos Maziero

DInf UFPR, Curitiba PR

Fevereiro de 2025

Conteúdo

1. Arquitetura da gerência de arquivos
2. Espaços de armazenamento
3. Gestão de blocos
4. Alocação de arquivos
   - Alocação contígua
   - Alocação encadeada
   - Alocação indexada
   - Alocação por extensões
   - Comparação entre estratégias
5. Gestão do espaço livre
6. Falhas e recuperação
   - Verificação
   - Journaling
   - Copy-on-Write
7. Um exemplo: Ext4

Gerência de arquivos

Funções da gerência de arquivos:

- Armazenar arquivos nos dispositivos de armazenamento
- Implementar diretórios e atalhos
- Implementar controle de acesso e travas
- Oferecer interfaces abstratas e padronizadas

Gerência de arquivos

- No hardware:
  - **Dispositivos**: armazenam os dados dos arquivos
  - **Controladores**: circuitos de controle e interface
- No núcleo:
  - **Drivers**: acessam os controladores para ler/escrever
  - **Gerência de blocos**: organiza os acessos aos blocos
  - **Alocação de arquivos**: aloca os arquivos nos blocos
  - **Virtual File System**: visão abstrata dos arquivos
  - **Chamadas de sistema**: interface de acesso ao VFS
- Na aplicação:
  - **Bibliotecas de E/S**: funções padronizadas de acesso

Gerência de arquivos

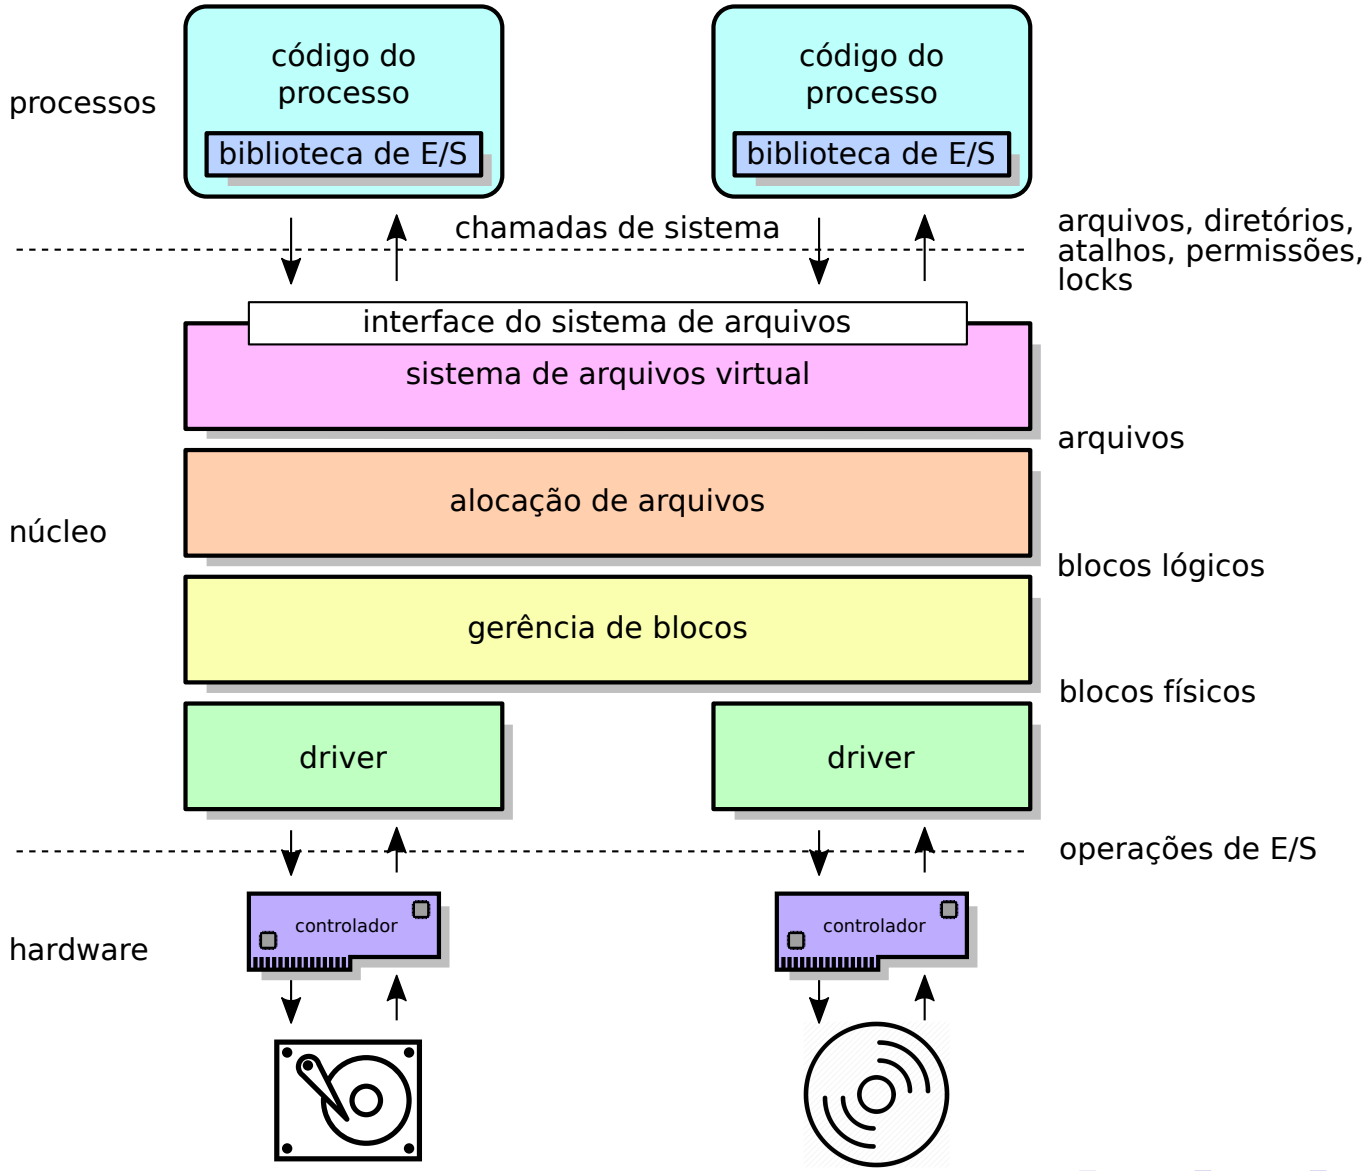

Organização do disco

Disco:

- Vetor de blocos com 512 bytes ou 4096 bytes
- Estruturado em **partições**
- MBR (*Master Boot Record*): tabela de partições + código

Partição:

- Cada uma das áreas do disco
- Possui um VBR (*Volume Boot Record*) no início
- Organizada com um *filesystem* específico

Formatação: estruturas de dados para armazenar arquivos

Organização do disco

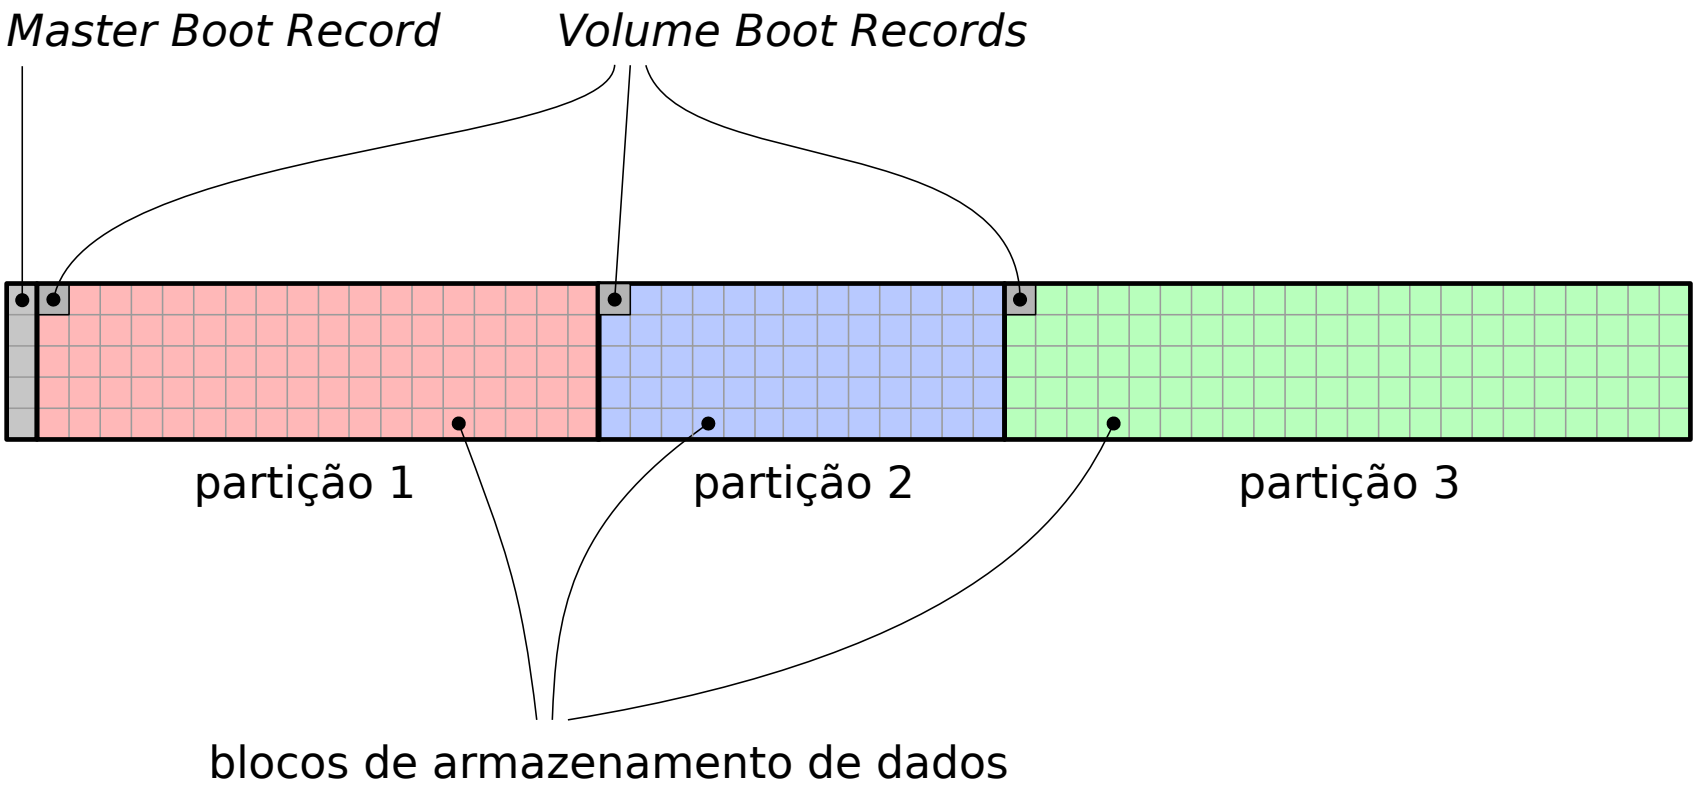

No Linux: comando `fdisk /dev/<disco>`

Montagem de volumes

Montagem: preparar volume/partição para ser usado

1. Acessar a tabela de partições (MBR do dispositivo)
2. Acessar o VBR e ler dados do volume
3. escolher *ponto de montagem* (árvore ou floresta)
4. Criar estruturas de memória para representar o volume

Feito durante o *boot* para os dispositivos fixos

Frequente em mídias removíveis (pendrive, CD, etc)

Montagem de volumes em UNIX

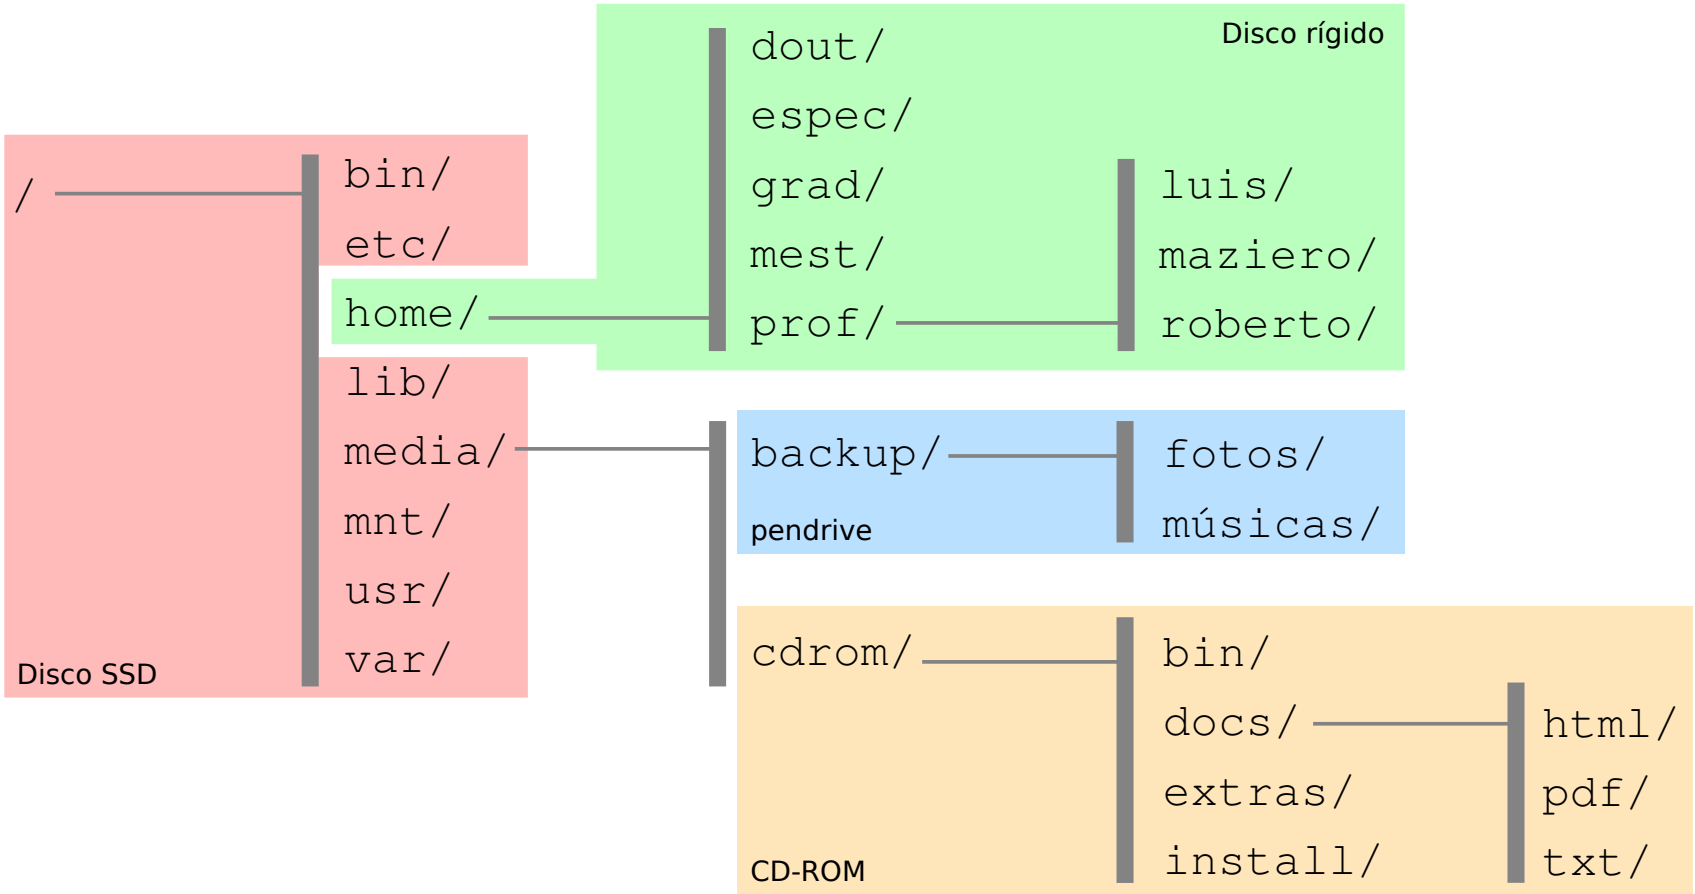

No Linux: comandos `df` e `mount`

Blocos físicos e lógicos

- Discos usam blocos físicos de 512 bytes ou 4.096 bytes
- SOs usam *blocos lógicos* ou *clusters*
- Cada bloco lógico usa 2^n blocos físicos consecutivos
- Blocos lógicos de 4K a 32 KBytes são típicos
- Clusters oferecem:
  - ☺ mais desempenho de E/S
  - ☹ mais fragmentação
- Sistemas modernos implementam *sub-block allocation*

Políticas de caching

Caching de blocos de disco:

- Discos são dispositivos lentos!
- *Caching* melhora o desempenho
- Existe *caching* de leitura e de escrita

Políticas de *caching*:

- *Read-Through*
- *Read-Ahead*
- *Write-Through*
- *Write-Back*

Políticas de **gestão do cache**: LRU, segunda-chance, etc

Política *Read-Through*

- O cache é consultado a cada leitura
- Se o bloco não estiver no cache, ele é lido do disco
- Blocos lidos são armazenados no cache

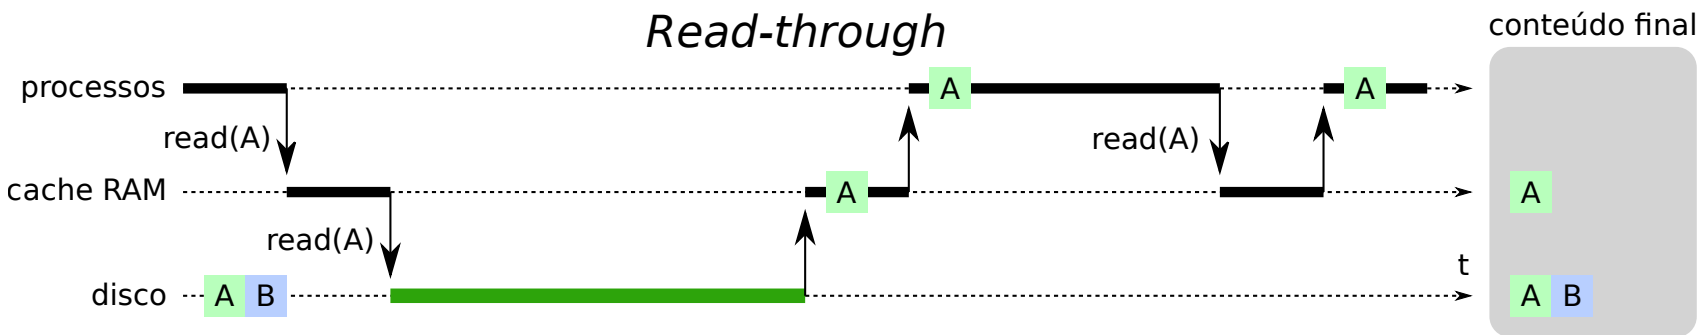

Política *Read-Ahead*

- Ao ler um bloco do disco, traz mais blocos que o requerido
- Blocos adicionais são lidos se o disco estiver ocioso
- Benéfica em acessos sequenciais e com boa localidade

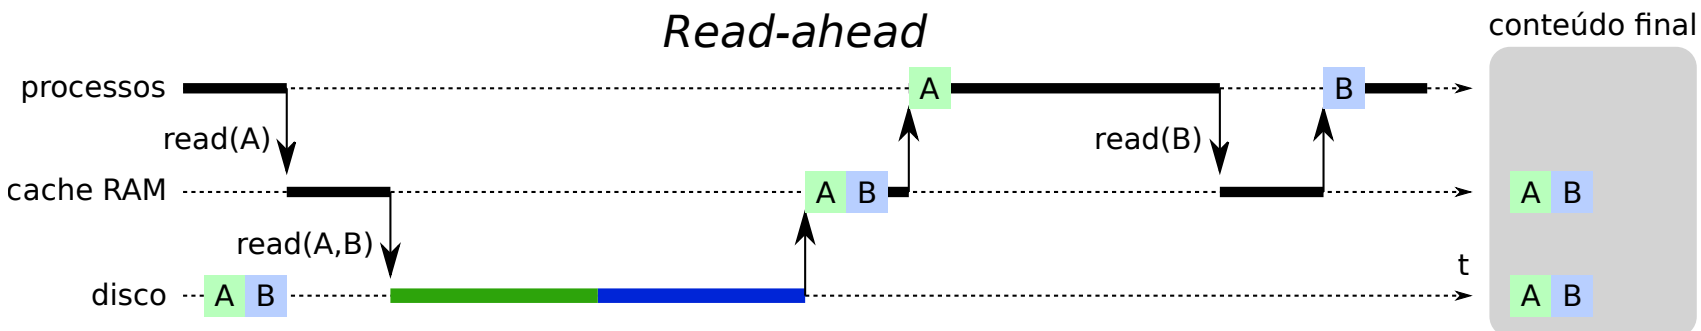

Política *Write-Through*

- As escritas são encaminhadas diretamente ao *driver*
- O processo solicitante é suspenso
- Uma cópia dos dados é mantida em cache para leitura
- Usual ao escrever metadados dos arquivos

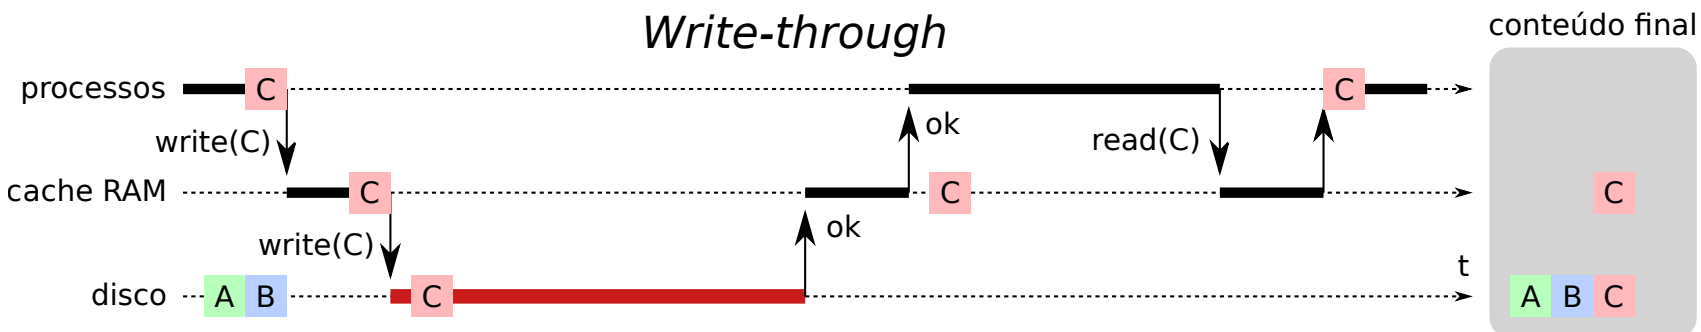

Política *Write-back* ou *write-behind*

- As escritas são feitas só no cache
- O processo é liberado imediatamente
- A escrita efetiva no disco é feita mais tarde
- Melhora o desempenho de escrita
- Risco de perda de dados (queda de energia)

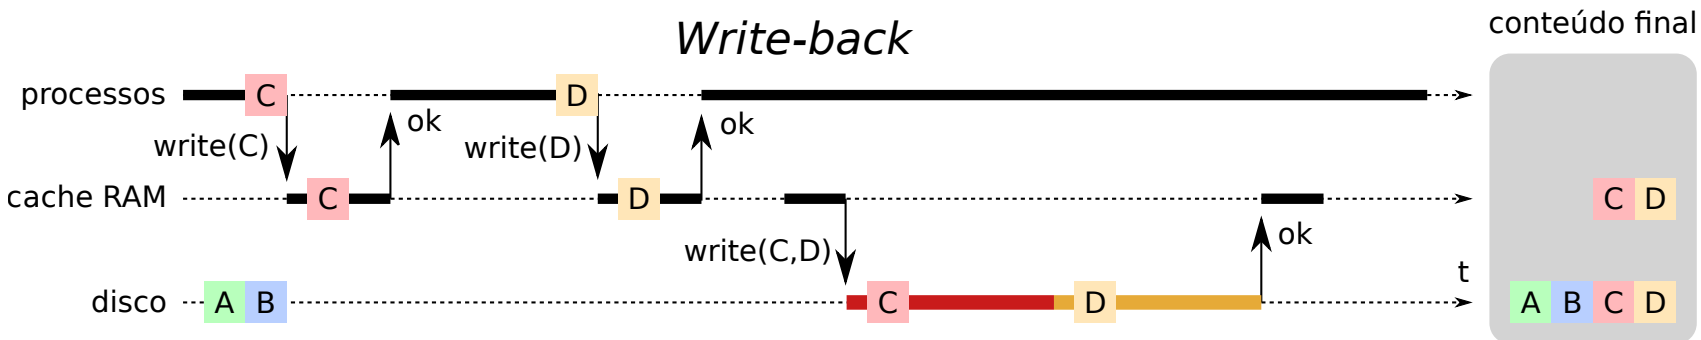

Alocação de arquivos

Um arquivo é definido por:

- Conteúdo: vetor de bytes
- Metadados:
  - Atributos: nome, data(s), permissões, etc.
  - Controles: localização dos dados no disco, etc.

FCB – *File Control Block*:

- Um descritor para cada arquivo armazenado
- Contém os **metadados** do arquivo
- Também deve ser armazenado no disco
- **Diretório**: tabela de FCBs

Alocação de arquivos

- Dispositivos físicos são vetores de blocos
- Arquivos têm **conteúdo** e **metadados**
- Como armazenar os arquivos nos blocos do disco?

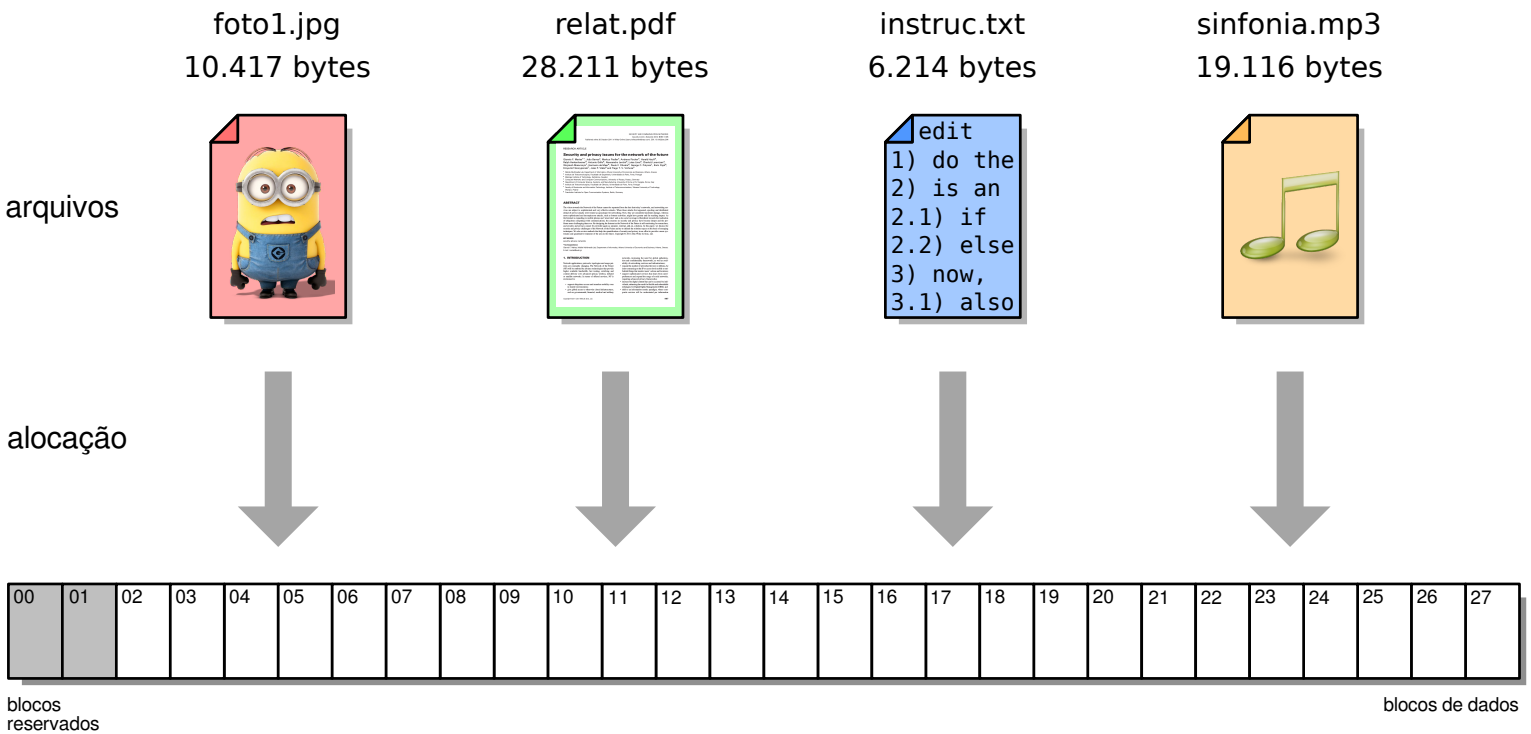

Alocação de arquivos

Estratégias de alocação:

- Alocação **contígua**
- Alocação **encadeada** simples e FAT
- Alocação **indexada** simples e multinível
- Alocação por **extensões**

Critérios de avaliação:

- **Rapidez** na leitura e escrita de arquivos
- **Robustez** em relação a erros no disco
- **Flexibilidade** na alocação e modificação de arquivos

Alocação contígua

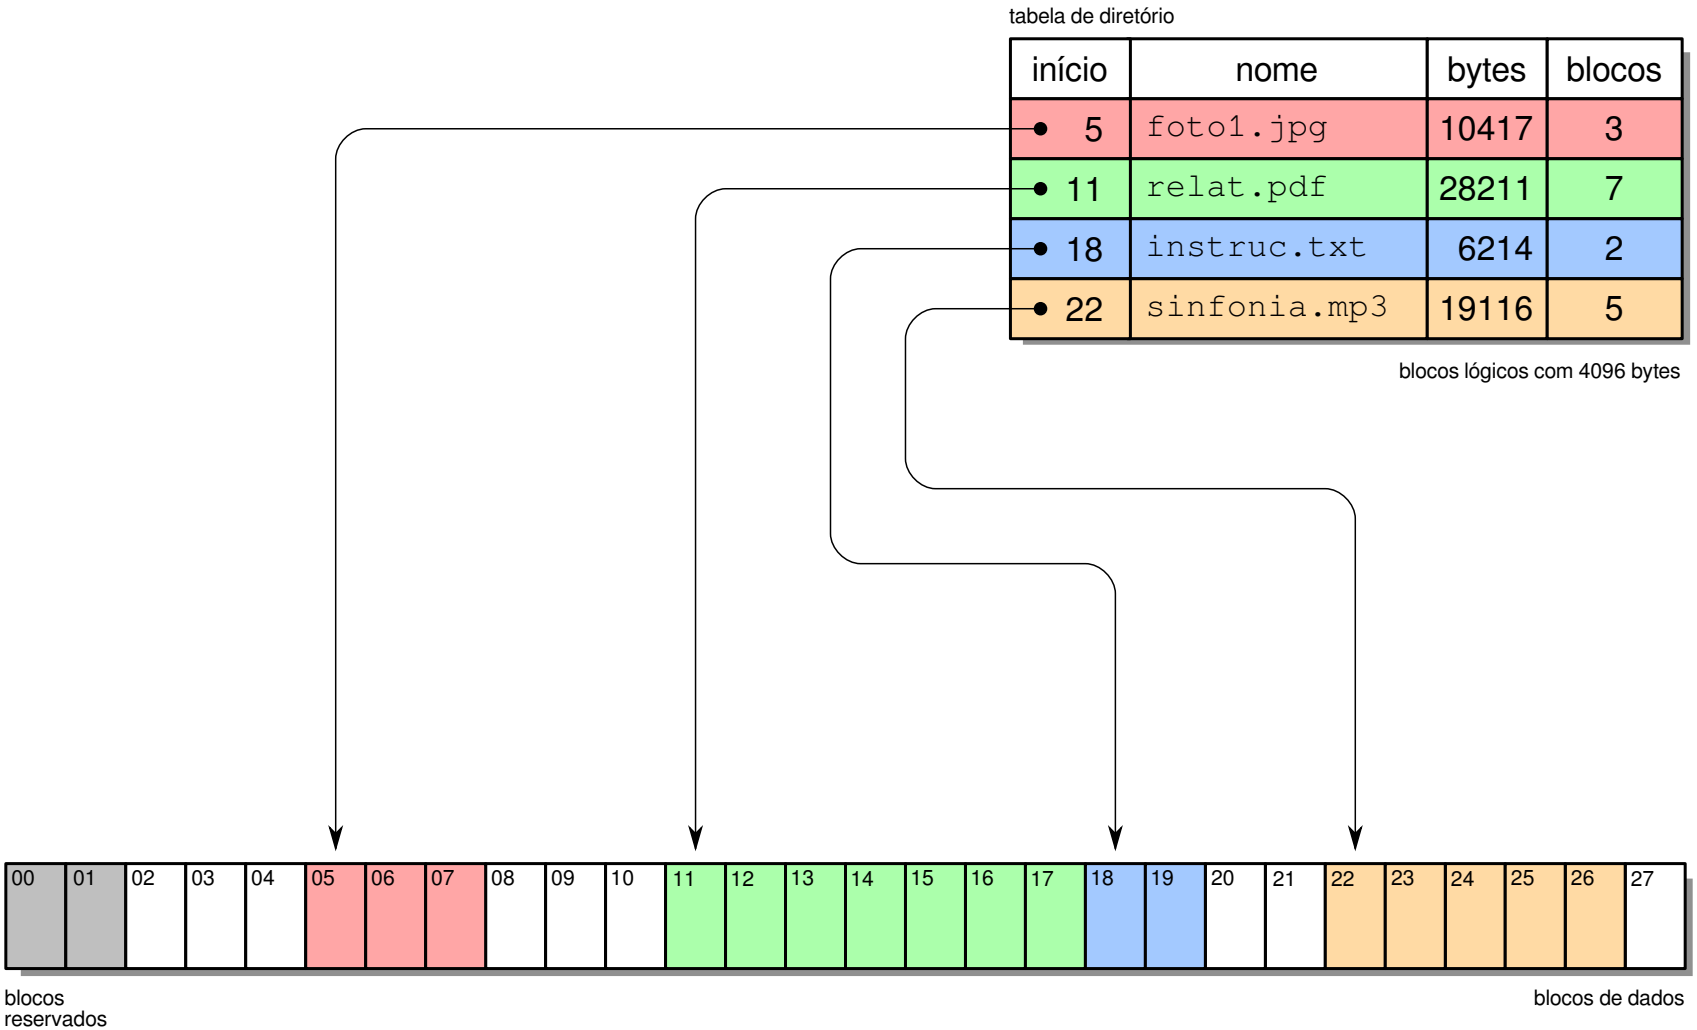

Alocação contígua

Um arquivo é um grupo de **blocos consecutivos**:

- Acessos sequencial e direto aos dados são rápidos
- Boa robustez a falhas de disco
- Baixa flexibilidade (conhecer o tamanho final do arquivo)
- Forte risco de fragmentação externa
- Estratégia pouco usada
- Usada em CD-ROMs no padrão ISO-9660

Alocação contígua - acesso direto

Entrada:
i: número do byte a localizar no arquivo
B: tamanho dos blocos lógicos, em bytes
b_0: número do bloco do disco onde o arquivo inicia

Saída:
(b_i, o_i): bloco do disco e *offset* onde está o byte i

$b_i = b_0 + i \div B$ ▷ *divisão inteira*
$o_i = i \bmod B$ ▷ *resto da divisão*
return (b_i, o_i)

Alocação encadeada simples

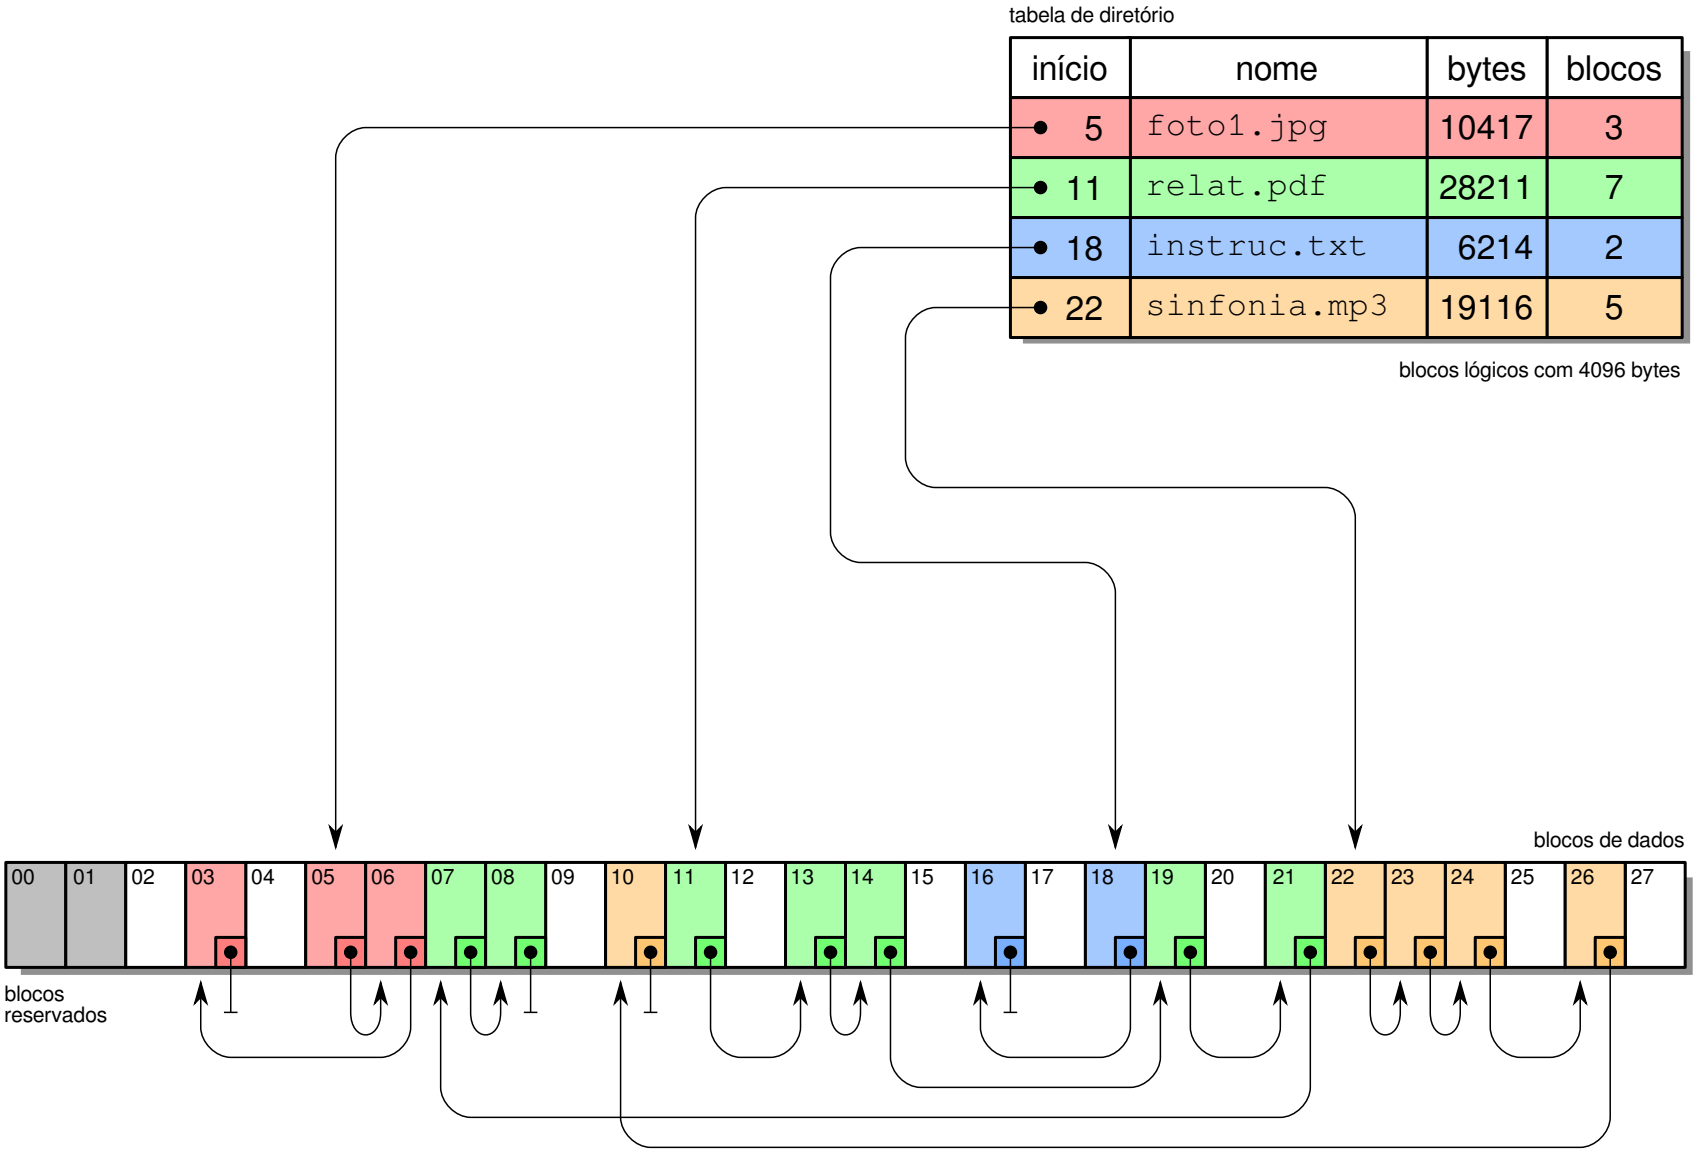

Alocação encadeada simples

Um arquivo é uma lista encadeada de blocos:

- Bloco contém dados e o **número do próximo bloco**
- Mais flexibilidade na criação de arquivos
- Elimina a fragmentação externa
- Acesso sequencial é usualmente rápido
- Acesso direto é lento (percorrer a lista de blocos)
- Pouco robusto: blocos corrompidos "quebram" os arquivos

Alocação encadeada simples - acesso direto

Entrada:

P: tamanho dos ponteiros de blocos, em bytes

$b_{aux} = b_0$ ▷ *define bloco inicial do percurso*

$b = i \div (B - P)$ ▷ *calcula número de blocos a percorrer*

while $b > 0$ **do**

  $block = read_block\ (b_{aux})$ ▷ *lê bloco do disco*

  b_{aux} = núm. próximo bloco (extraído de *block*)

  $b = b - 1$

end while

$b_i = b_{aux}$

$o_i = i \bmod (B - P)$

return(b_i, o_i)

Alocação encadeada FAT

Armazenar ponteiros nos blocos é um problema:

- Diminui tamanho útil dos blocos
- Precisa ler blocos para percorrer lista

Solução: criar uma **tabela de ponteiros**:

- FAT - *File Allocation Table*
- Tabela de ponteiros armazenada nos blocos iniciais
- Mantida em cache na memória RAM
- Base dos sistemas FAT12, FAT16, FAT32, VFAT, ...

Alocação encadeada FAT

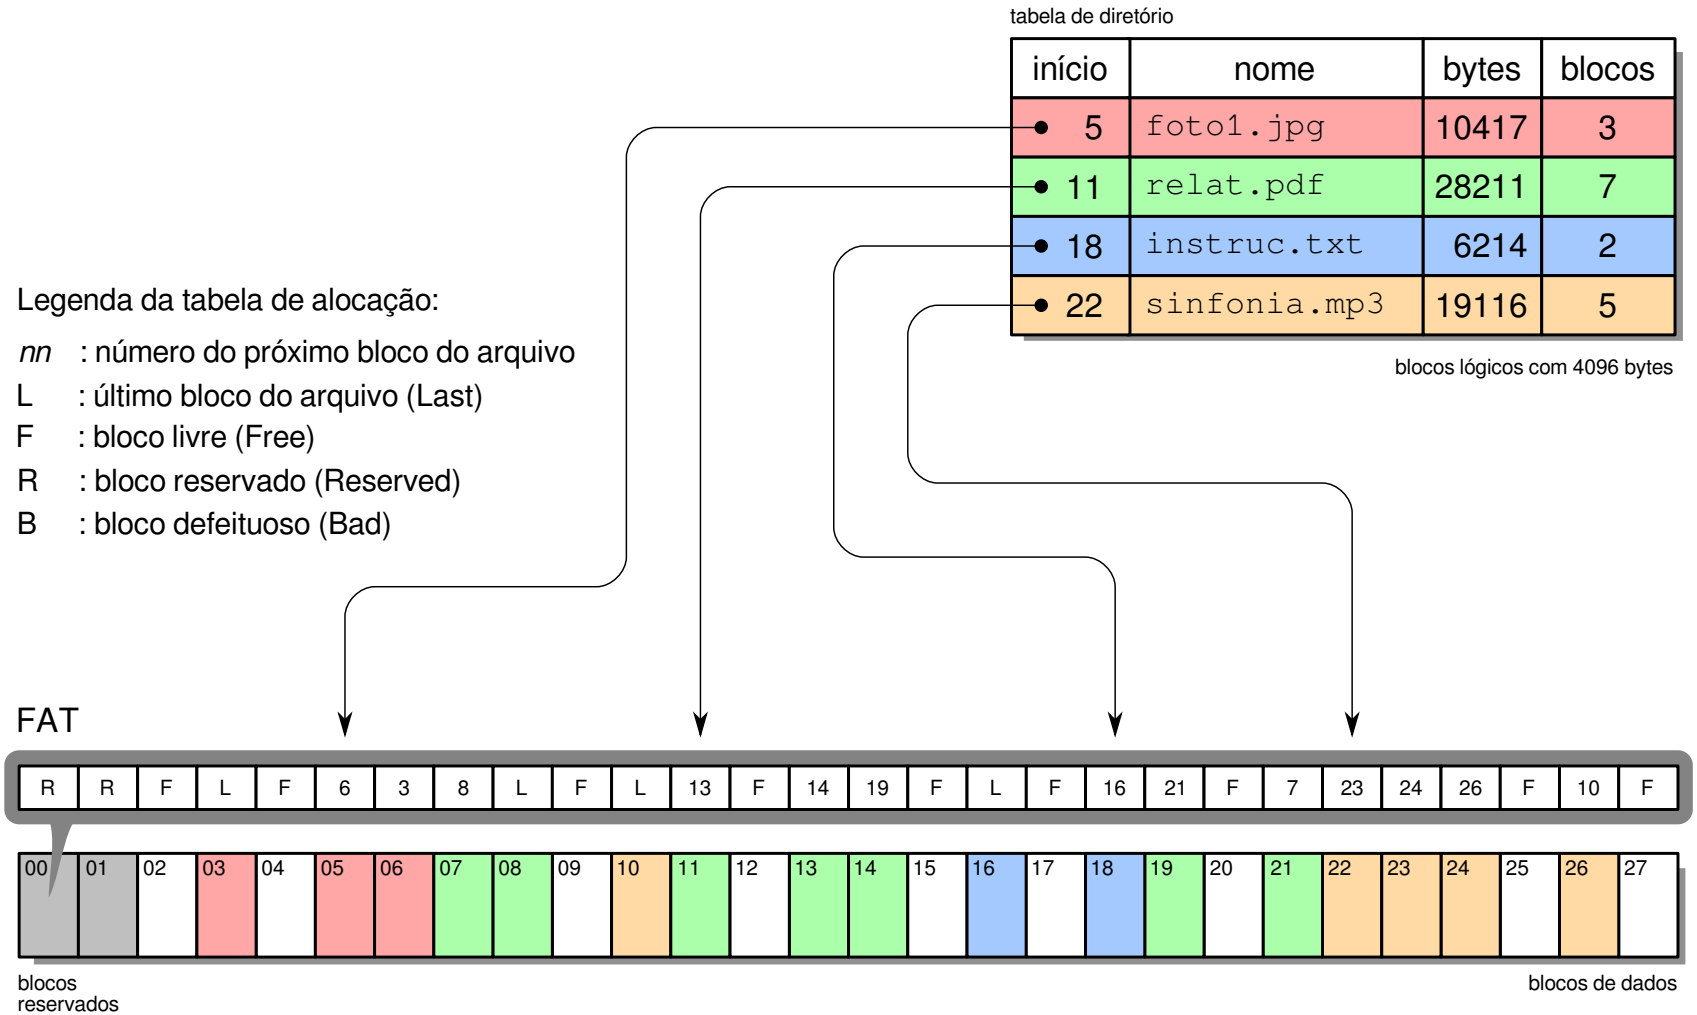

Alocação indexada simples

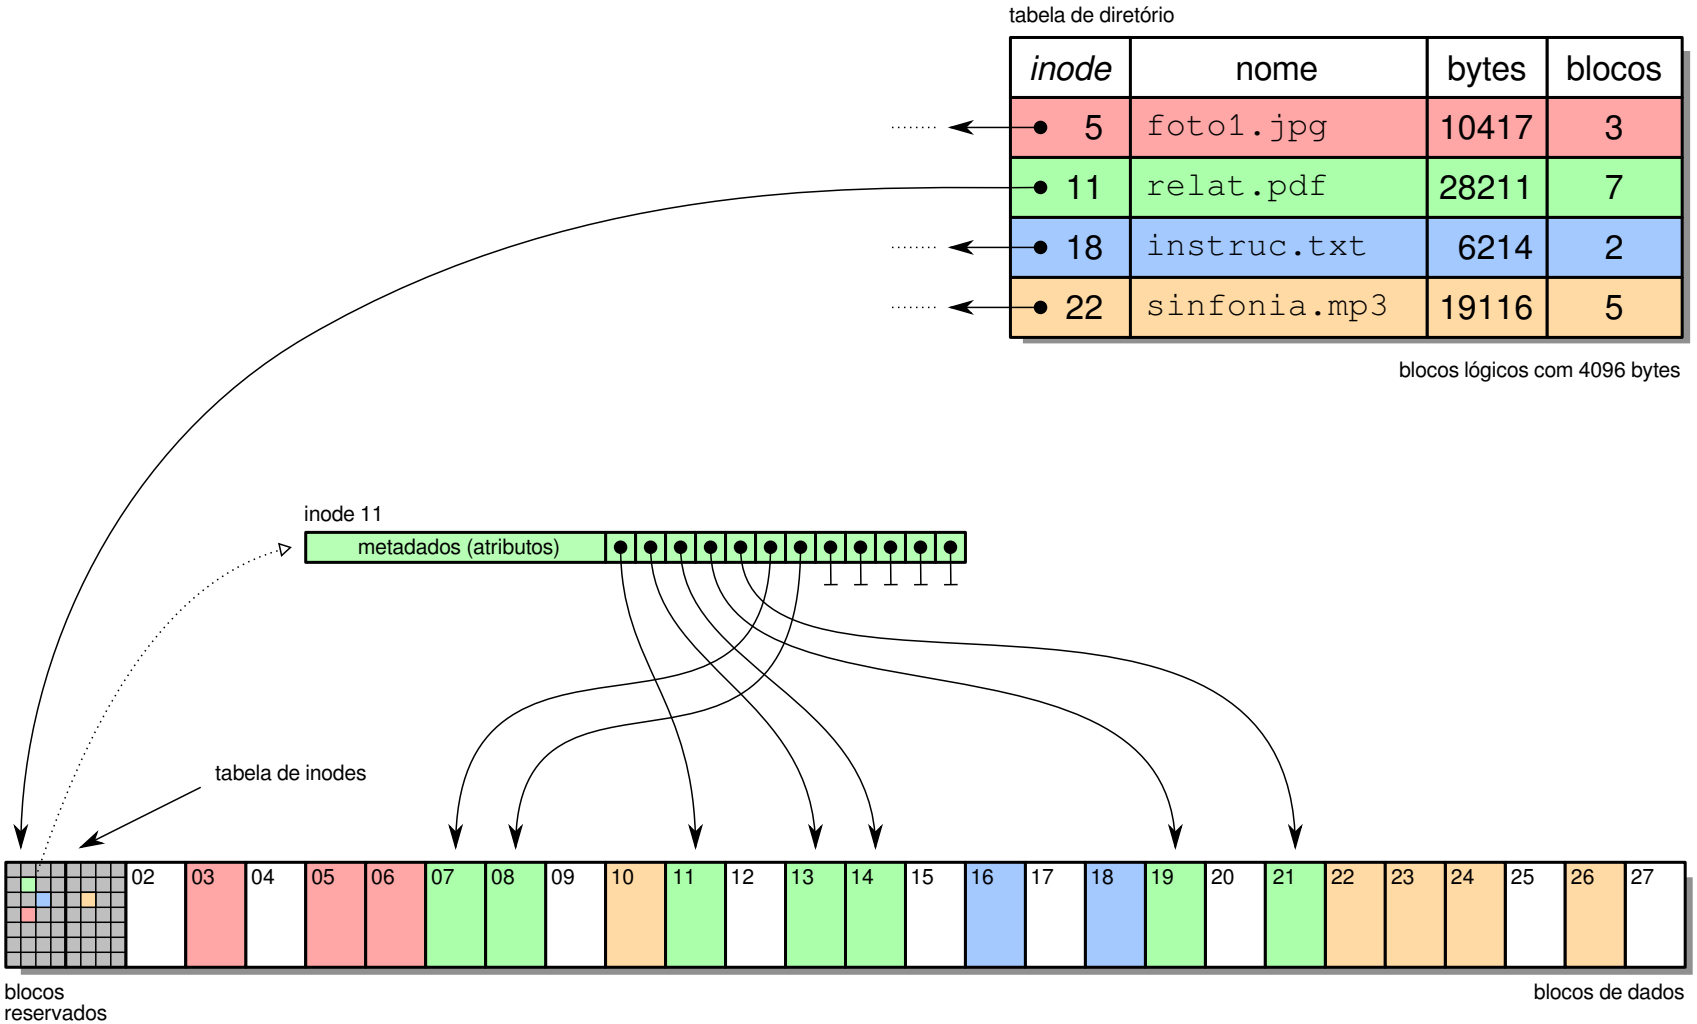

Alocação indexada simples

Ideia: um índice de blocos separado para cada arquivo

- *Index node* (*inode*): estrutura com índice e metadados
- Tabela de *inodes* mantida na área reservada do disco

Características:

- Rápida para acessos sequenciais e diretos
- Robusta para erros em blocos de dados
- *Inodes* são pontos frágeis
- Cópias da tabela de *inodes* espalhadas no disco

Alocação indexada multinível

Problema:

- *inode* tem tamanho fixo
- Número de ponteiros limita o tamanho do arquivo

Exemplo:

- *inode* com 64 ponteiros de blocos
- Blocos de 4 Kbytes
- Permite armazenar arquivos até $64 \times 4 = 256$ KBytes

Solução: Transformar o vetor de blocos em uma árvore

Alocação indexada multinível

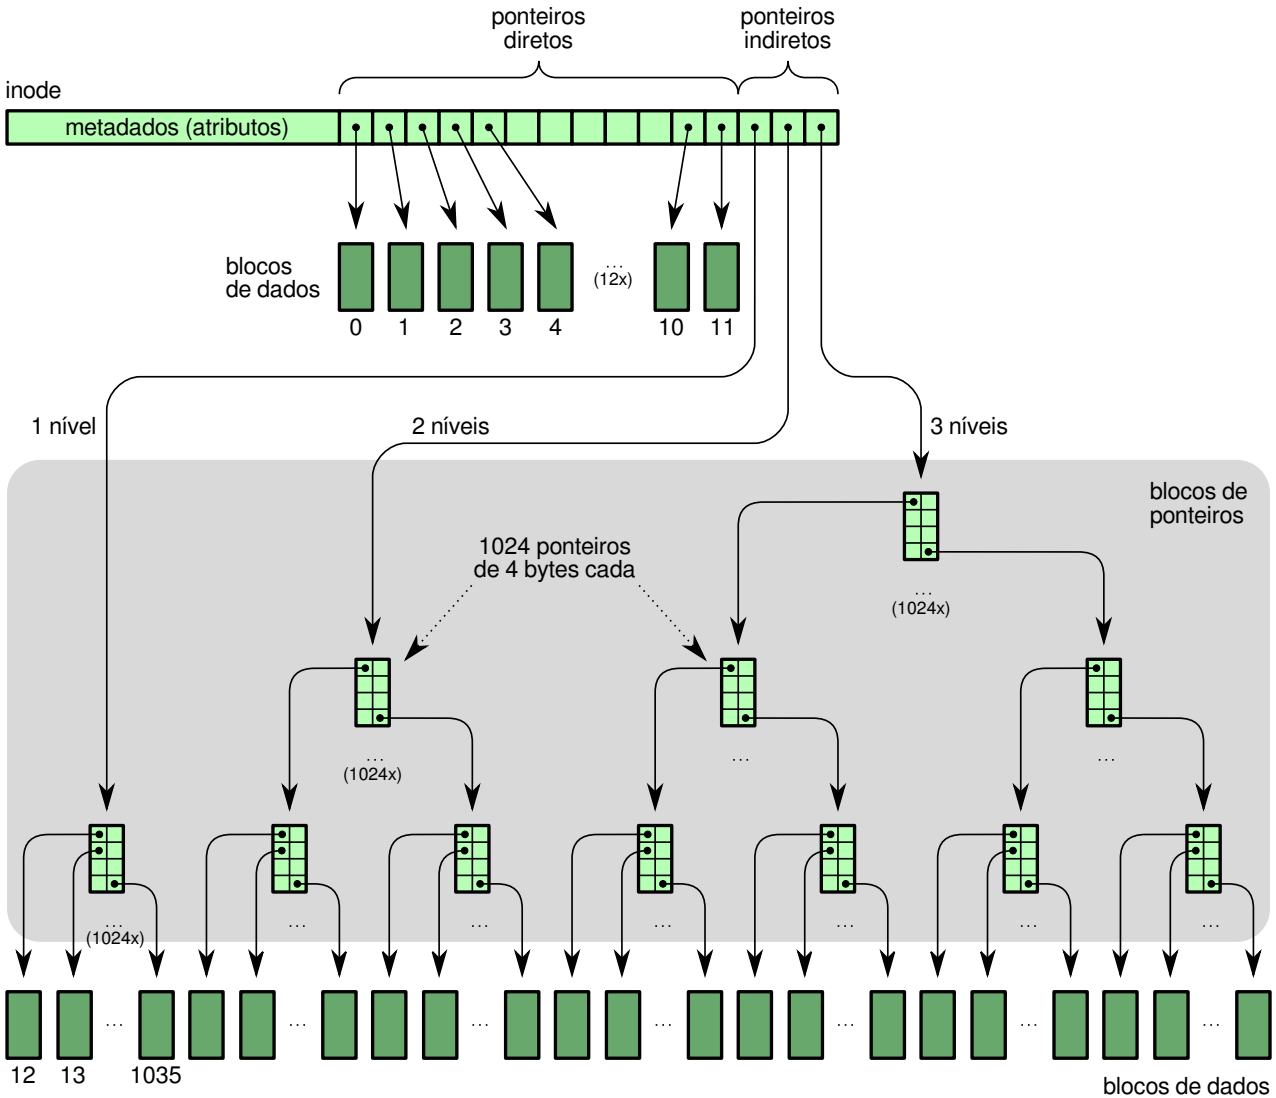

Tamanho máximo de arquivo

Considerando um sistema indexado com:

- blocos lógicos de 4 Kbytes
- ponteiros de blocos com 4 bytes
- $\longrightarrow$ cada bloco de ponteiros contém 1.024 ponteiros

Cálculo do tamanho máximo de um arquivo:

$$
\begin{aligned}
max &= 4.096 \times 12 && \text{(ponteiros diretos)} \\
&+ 4.096 \times 1.024 && \text{(ponteiro 1-indireto)} \\
&+ 4.096 \times 1.024^2 && \text{(ponteiro 2-indireto)} \\
&+ 4.096 \times 1.024^3 && \text{(ponteiro 3-indireto)} \\
&= 4.402.345.721.856 \ \textit{bytes} \\
max &\approx 4 \ \textit{Tbytes}
\end{aligned}
$$

Alocação indexada multinível - acesso direto I

1: **Entrada:**
2: $ptr[0...14]$: vetor de ponteiros contido no *i-node*
3: $block[0...1023]$: bloco de ponteiros para outros blocos (1.024 ponteiros de 4 bytes)

4: $o_i = i \bmod B$
5: $pos = i \div B$
6: **if** $pos < 12$ **then** ▷ *usar ponteiros diretos*
7: $b_i = ptr[pos]$ ▷ *o ponteiro é o número do bloco* b_i
8: **else**
9: $pos = pos - 12$
10: **if** $pos < 1024$ **then** ▷ *usar ponteiro 1-indireto*
11: $block_1 = read_block\ (ptr[12])$
12: $b_i = block_1[pos]$
13: **else**

Alocação indexada multinível - acesso direto II

14: $pos = pos - 1024$
15: **if** $pos < 1024^2$ **then** ▷ *usar ponteiro 2-indireto*
16: $block_1 = read_block\ (ptr[13])$
17: $block_2 = read_block\ (block_1[pos \div 1024])$
18: $b_i = block_2[pos \bmod 1024]$
19: **else** ▷ *usar ponteiro 3-indireto*
20: $pos = pos - 1024^2$
21: $block_1 = read_block\ (ptr[14])$
22: $block_2 = read_block\ (block_1[pos \div (1024^2)])$
23: $block_3 = read_block\ (block_2[(pos \div 1024) \bmod 1024])$
24: $b_i = block_3[pos \bmod 1024]$
25: **end if**
26: **end if**
27: **end if**
28: **return**(b_i, o_i)

Estrutura do *Inode* do Ext4 (simplificado)

Offset	Size	Name	Description
0x00	2	`i_mode`	entry type and permissions
0x02	2	`i_uid`	user ID
0x04	4	`i_size_lo`	size (bytes)
0x08	4	`i_atime`	data access time
...	...	...	...
0x18	2	`i_gid`	group ID
0x1A	2	`i_links_count`	hard links counter
0x1C	2	`i_blocks_lo`	number of blocks
0x20	4	`i_flags`	several flag bits
...	...	...	...
0x28	60	`i_block[15]`	block map (pointers)
...	...	...	...

Alocação por extensões

Problema:

- Alocação indexada é ruim para arquivos muito grandes
- Muitos metadados: um ponteiro para cada bloco
- Ineficiência e custo de gestão

Observações:

- Alocação contígua é rápida mas inflexível
- Alocação contígua usa poucos metadados

Ideia: combinar alocação indexada e contígua

Alocação por extensões

Alocação por extensões:

- Extensão: grupo de blocos contíguos no disco
- Arquivo é alocado em uma ou mais extensões

Cada extensão usa um pequeno *descritor de extensão*:

- Quantidade de blocos
- Número do bloco lógico inicial
- Número do bloco físico inicial

Cada *i-node* guarda poucos descritores de extensão e aponta para **árvore de descritores de extensão** em blocos adicionais

Alocação por extensões

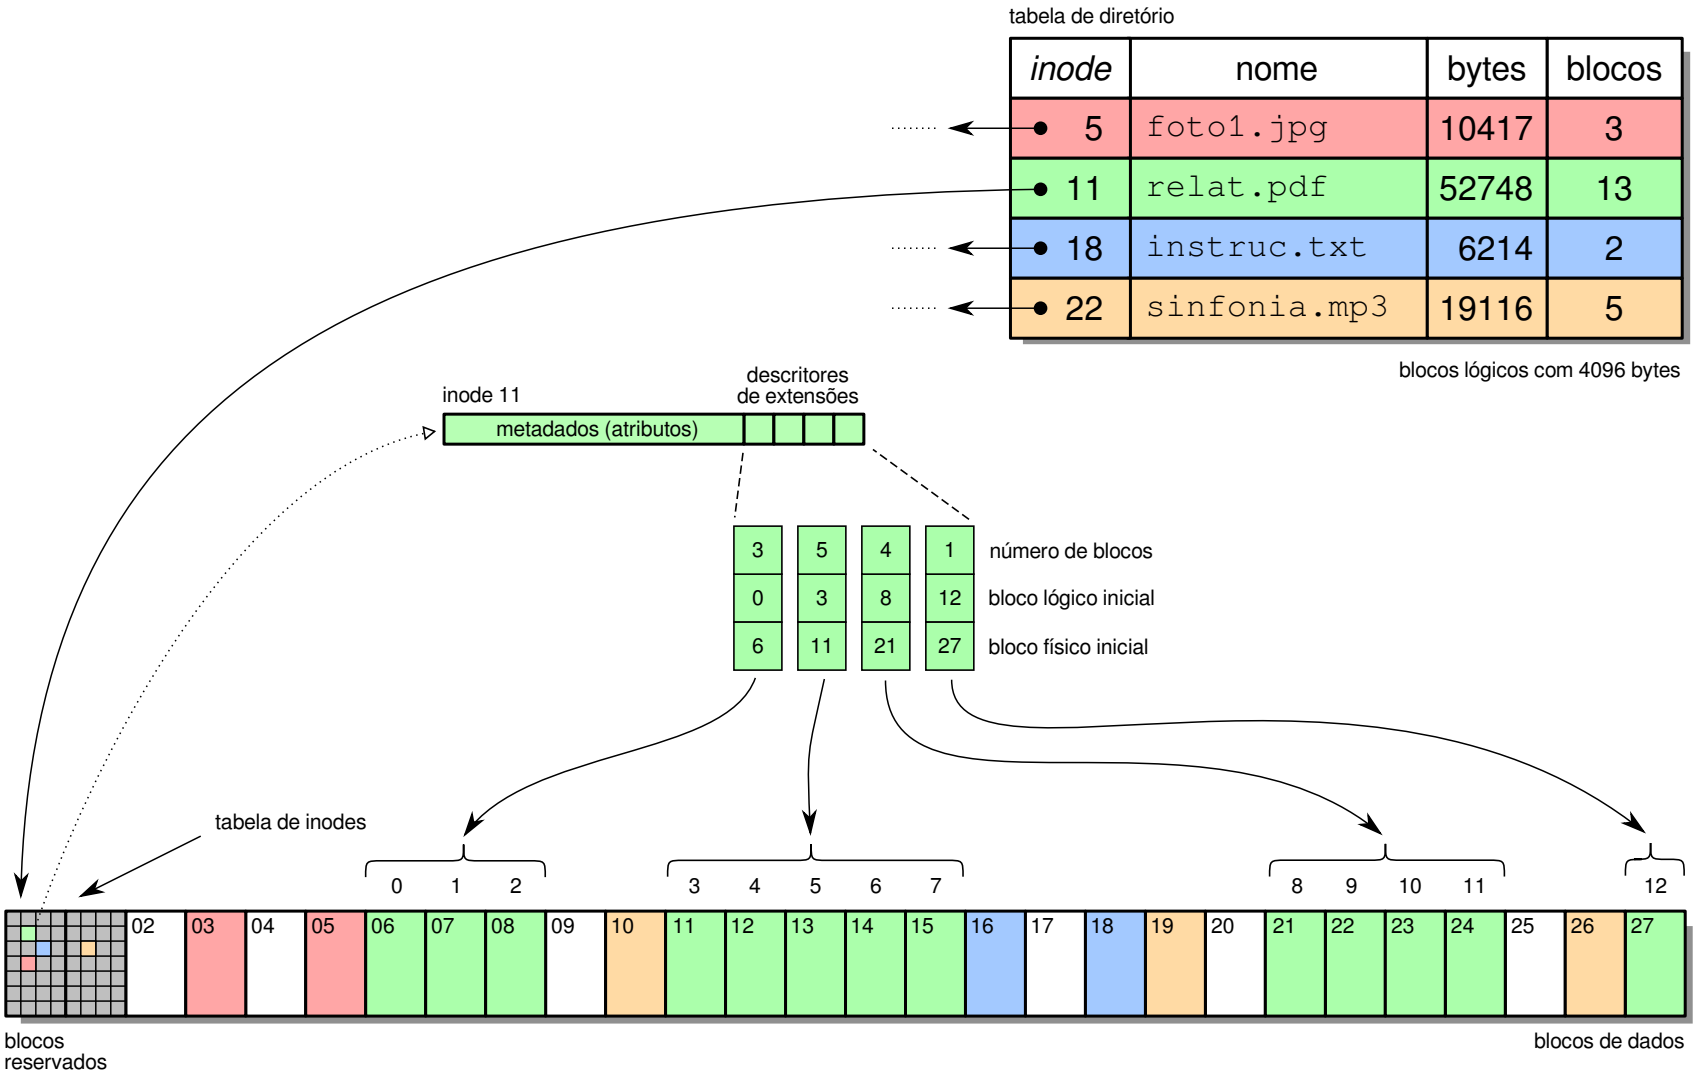

Comparação entre estratégias

Estratégia	rapidez sequencial	rapidez aleatória	robusta	flexível	impõe limites
Contígua	✓	✓	✓		
Encadeada	✓			✓	✓ (3)
FAT	✓	✓	✓ (1)	✓	✓ (3)
Indexada	✓	✓	✓ (2)	✓	✓ (4)
Extensões	✓	✓	✓ (2)	✓	

1. Tabela FAT é ponto sensível (replicada)
2. Tabela de inodes é ponto sensível (replicada)
3. Tamanho dos ponteiros limita número de blocos
4. Limites no tamanho de arquivo e número de arquivos

Gestão do espaço livre

Registro dos blocos livres:

- Importante ao criar ou aumentar arquivos
- Atualizado a cada operação no disco

Estratégias:

- Mapa de bits na área reservada
- Listas/árvores de blocos livres
- Tabela de extensões livres
- FAT

Falhas e recuperação

Conteúdo de um sistema de arquivos:

Dados: conteúdo dos arquivos em si (dados do usuário, programas, bibliotecas, arquivos do sistema, etc)

Metadados: estrutura dos diretórios, alocação dos blocos de dados dos arquivos, atributos dos arquivos, etc.

Metadados definem uma imensa estrutura de dados no disco, atualizada a cada alteração no disco.

Falhas e recuperação

Alterações no sistema de arquivos envolvem várias operações.

Exemplo: criar o arquivo "`/home/user/novo.txt`":

1. Encontrar um *inode* livre e marcá-lo como ocupado no mapa de *inodes*
2. Preencher esse *inode* c/ os atributos de "`novo.txt`"
3. Localizar o *inode* de "`/home/user/`"
4. Incluir em "`/home/user/`" uma entrada com o nome e o *inode* de "`novo.txt`"

O disco só realiza uma operação por vez (sequencial).

Falhas e recuperação

Falha por *crash*: queda de energia ou travamento

Se ocorrer um crash ao criar o arquivo "`novo.txt`" ?

- Entre as operações 1 e 2: um *inode* marcado como ocupado, mas não será usado nem referenciado.
- Entre as operações 2 e 4: um *inode* marcado como ocupado e preenchido, mas não aparece em diretório e não poderá ser localizado.

Resultado: sistema de arquivos pode ficar **inconsistente**.

Falhas e recuperação

Inconsistências podem levar a perda de dados:

- Perda de conteúdo de arquivos
- Perda de arquivos
- Perda de diretórios

Estratégias para minimizar as consequências das falhas:

- Escrita síncrona dos metadados
- Verificação do sistema de arquivos
- Sistemas de arquivos com *Journaling*
- Sistemas de arquivos com *Copy-on-Write*

Verificação do sistema de arquivos

Ao iniciar, percorrer as estruturas de dados do FS:

- Mapas de blocos e *inodes*
- Entradas dos *inodes*
- Tabelas de diretórios
- *Checksums* dos metadados

Verificar e corrigir inconsistências:

- Blocos ocupados, mas não apontados por inodes
- Blocos livres, mas apontados por inodes
- Blocos apontados por mais de um inode
- Inodes ocupados mas não referenciados em diretórios
- ...

Verificação do sistema de arquivos

A verificação:

- Deve ser feita na inicialização
- Ao retornar de um *crash* (como detectar?)
- Antes do sistema ser usado por aplicações
- Necessita ferramentas específicas (exemplo: "`fsck.ext4`")
- Processo lento (pode demorar horas)

Sistemas de arquivos com *Journaling*

Ideia:

- Registrar previamente as alterações nos metadados
- Registro prévio: antes de fazer as alterações
- Incluir dados suficientes para poder repeti-las
- Área de registro separada: *journal*

No caso de um crash:

- Ao reiniciar, consulta o journal
- Analisa as operações pendentes e completa-as

Similar à gestão de transações em BDs (*write-ahead logging*)

Sistemas de arquivos com *Journaling*

1. Antes de alterar o FS, registrar no *journal* as escritas realizadas; para criar "`/home/user/novo.txt`" serão necessárias estas operações (*inode* livre 317):
   1. Marcar o *inode* 317 como ocupado no mapa de *inodes*
   2. Preencher o *inode* 317 com os atributos de "`novo.txt`"
   3. Incluir no diretório "`/home/user/`" uma entrada com o nome "`novo.txt`" apontando para o *inode* 317
2. Realizar as operações no sistema de arquivos
3. Caso tenha sucesso, descartar o registro
4. Caso ocorra uma falha de *crash*, analisar o registro ao reiniciar, completar as operações pendentes e descartar o registro

Sistemas de arquivos com *Journaling*

Implementação do registro:

- Buffer circular de tamanho fixo
- Escritas sequenciais (bom desempenho)
- Escrita síncrona (minimizar risco ao journal)
- Somas de verificação (*checksums*) para consistência

Journaling é muito usado: NTFS (Windows), HFS (MacOS), Ext4 (Linux), JFS (IBM).

Geralmente só se aplica aos metadados (desempenho)

Sistemas de arquivos *Copy-on-Write*

Também denominados *Versioning File Systems*

Ao atualizar o conteúdo de um bloco:

- FS convencional: escreve o conteúdo na posição do próprio bloco, **sobrescrevendo** o conteúdo anterior
- FS *copy-on-write*: escreve o conteúdo em um bloco livre, **preservando** o conteúdo anterior

Conceito similar a "*Time Machine*" e GIT

Implementado no ZFS, BTRFS e ReFS (Windows)

Sistemas de arquivos *Copy-on-Write*

Funcionamento:

- Usar espaço livre para versões anteriores dos blocos
- Aplicável a dados e de metadados
- Construir “snapshots” dos estados anteriores do disco
- Retornar a um estado anterior em caso de crash
- Versões velhas podem ser removidas para abrir espaço

Snapshot:

- Conjunto de blocos com versão anterior do FS
- Usuário pode ver versões anteriores dos arquivos
- FS pode retornar a ele em caso de crash

O sistema Ext4

- Sistema de arquivos mais usado em Linux
- Deriva dos sistemas de arquivos anteriores Ext, Ext2 e Ext3
- Suporta partições com 64 ZBytes e arquivos com 16 TBytes
- Usa *journaling* e *checksum* de metadados
- Suporta quotas, controle de acesso avançado e criptografia
- Suporta alocação indexada multinível e alocação por extensões
- Gestão de espaço livre por bitmaps de blocos livres e bitmaps de *inodes* livres

Exemplo: o sistema Ext4

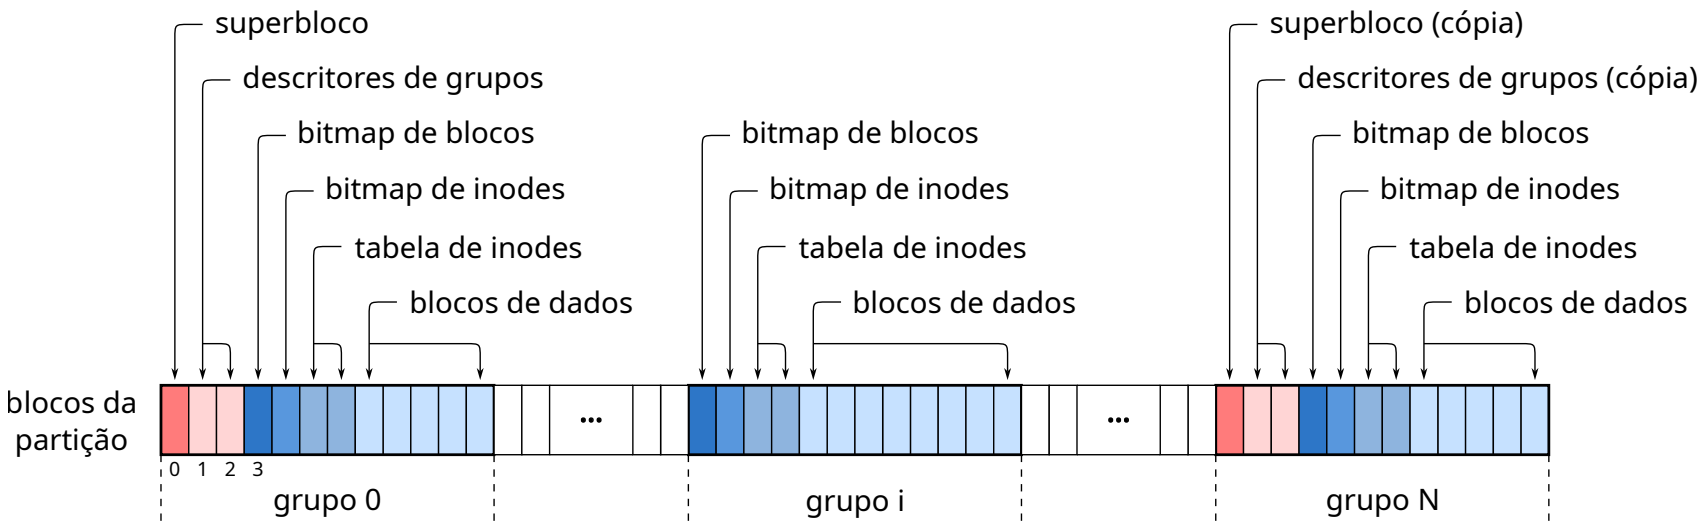

Blocos de 4 KBytes organizados em grupos de blocos contíguos

Grupo: geralmente 32.768 blocos ou 128 Mbytes

Exemplo: o sistema Ext4

O grupo 0:

- Superbloco (1 bloco): dados do FS (núm. blocos, grupos, *inodes*, etc); 1.024 bytes iniciais p/ código de boot.
- Tabela de descritores de grupos
- Bitmap de blocos (1 bloco)
- Bitmap de *inodes* (1 bloco)
- Tabela de *inodes* (alguns blocos)
- Blocos de dados (todos os demais blocos do grupo)

Os demais grupos: bitmaps de blocos e de *inodes*, tabela de *inodes*, blocos de dados.

Alguns grupos: cópias superbloco e descritores de grupos

Exemplo: o sistema Ext4

Inodes especiais no grupo 0:

Inode	**Uso**
0	não usado
1	lista de blocos defeituosos na partição
2	diretório raiz
3	controle de quota de uso por usuários
4	controle de quota de uso por grupos de usuários
5	inicializador (*Boot loader*)
6, 7, 9, 10	reservados
8	arquivo de registro (*journal*)
11	primeiro *inode* disponível para arquivos