SCC 503 - ALGORITMOS E ESTRUTURAS DE DADOS II

Arquivos - Manutenção

Prof.: Leonardo Tórtoro Pereira
leonardop@usp.br

*Material baseado em aulas dos professores: Elaine Parros Machado de Souza, Gustavo Batista, Robson Cordeiro, Moacir Ponti Jr., Maria Cristina Oliveira e Cristina Ciferri.

Manutenção de Arquivos

- A organização de um arquivo pode deteriorar durante o seu uso.
- Exemplos:
  - O que deve ser feito com o espaço liberado por registros removidos?
  - E quando registros são atualizados em arquivos com registros de tamanho variável?

Manutenção de Arquivos

- ➔ Projetista deve considerar modificações no arquivo
  - ◆ Adição, atualização e remoção de registros
- ➔ Problema é simples quando:
  - ◆ Registros são de tamanho fixo
  - ◆ Apenas adições e atualizações ocorrem
- ➔ Porém, em outras circunstâncias...

Manutenção de Arquivos

➔ Ex: atualizar um registro variável que aumente de tamanho:

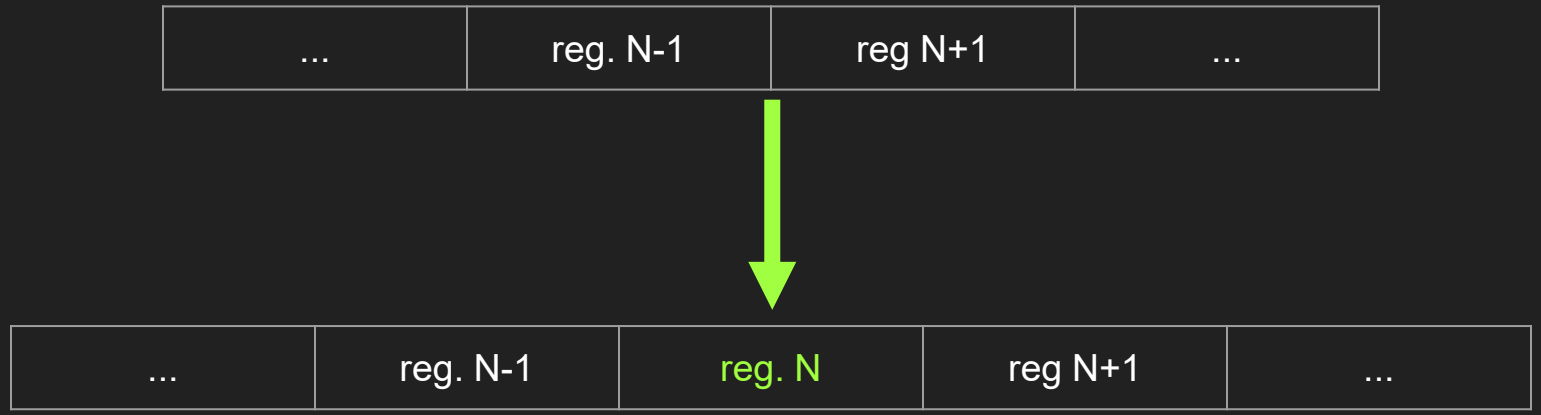

Manutenção de Arquivos

➔ O que fazer com os dados adicionais?

- Anexar ao final do arquivo e ligar as duas partes por "ponteiros" ?
  - Processamento de cada registro (ao longo do arq. todo) fica muito mais complexo
- Apagar o registro original e reescrevê-lo todo no final do arquivo ?
  - Ok, é necessário reutilizar o espaço desocupado

Manutenção de Arquivos

- ➔ Ex: remover um registro (tamanho fixo ou variável):
  - ◆ O que fazer com o espaço remanescente?
    - ● Necessário reutilizar o espaço vago
- ➔ Foco de manutenção de arquivos: reaproveitamento de espaços vagos
- ➔ OBS: uma atualização sempre pode ser vista como:
  - ◆ Atualização = Remoção + Adição

Compactação e Reuso

Compactação e Reuso

- Compactação
  - Busca por regiões do arquivo que não contêm dados
  - Recupera os espaços `perdidos´
- Reuso
  - Insere dados nos espaços vazios
- Duas abordagens
  - Estática
  - Dinâmica

Abordagem Estática

Abordagem Estática

- ➔ Arquivo off-line e sujeito a modificações esporádicas (ex: lista de mala direta)
  - ◆ Espaços podem ser recuperados em `lotes´ (*batch*)

Abordagem Estática

- ➔ Apenas “marcar” os registros no momento da eliminação, e periodicamente eliminá-los todos de uma vez
  - ◆ Demanda um mecanismo que permita reconhecer quando uma área do arquivo corresponde a um registro que foi eliminado
  - ◆ Usual: marcador especial no lugar do registro apagado (ex: "*|" nos primeiros 2 bytes do registro)

Abordagem Estática

➔ Após um certo número de remoções:

- ◆ Aciona-se um procedimento de compactação

Abordagem Estática

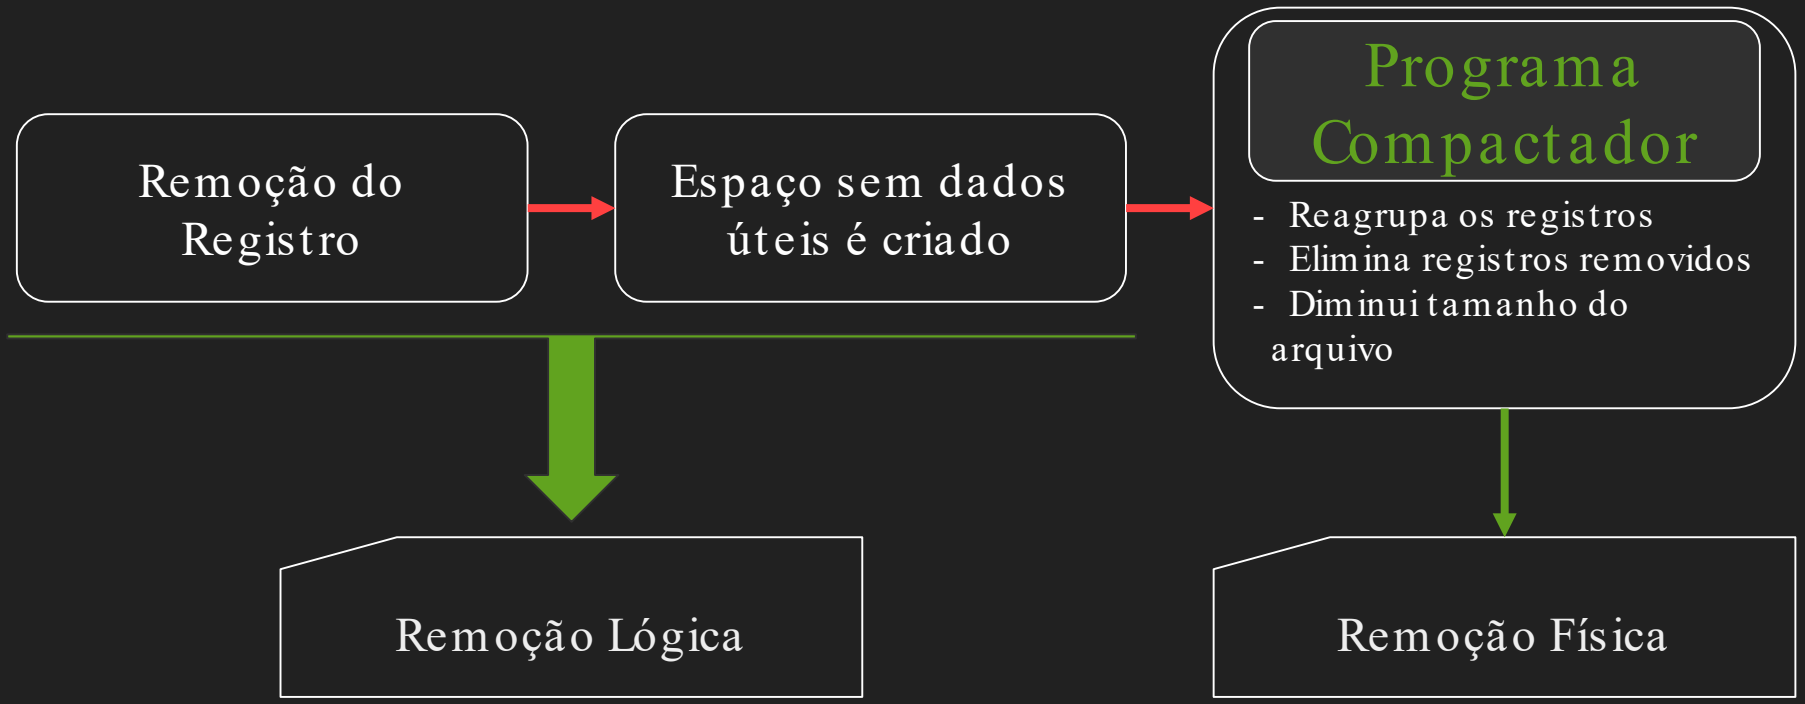

Compactação

Compactação

- ➔ Procedimento de compactação: o espaço de todos os registros marcados é recuperado de uma só vez
  - ◆ Esporádico
    - Espaço não fica disponível imediatamente após remoção de cada registro

Compactação

- ➔ Maneira mais simples de compactar, se existe espaço suficiente no disco
  - ◆ Cópia sequencial:
    - Novo arquivo é gerado copiando o original
    - Substitui bytes dos registros eliminados
- ➔ Alternativa: compactação *in-place*
  - ◆ Mais complexa e computacionalmente custosa

Compactação - Exemplo

➔ Ex: Registros de Tamanho fixo e campo Variável

Ana Silva|22|8,0|.....

Jose Dantas|25|7,0|.....

Luiza Aires|19|5,0|.....

Compactação - Exemplo

➔ Após remoção do 2o registro

Ana Silva|22|8,0|.....

*|se Dantas|25|7,0|.....

Luiza Aires|19|5,0|.....

Compactação - Exemplo

➔ Inserção de um novo registro

Ana Silva|22|8,0|.....

*|se Dantas|25|7,0|.....

Luiza Aires|19|5,0|.....

Marcos Santos|19|5,0|.....

Compactação - Exemplo

➔ Compactação

Ana Silva|22|8,0|.....

Luiza Aires|19|5,0|.....

Marcos Santos|19|5,0|.....

Características da Abordagem Estática

Características da Abordagem Estática

- ➔ Técnica pode ser aplicada a
  - ◆ Registros de tamanho fixo
  - ◆ Registros de tamanho variável
- ➔ Frequência para se aplicar a técnica
  - ◆ Depende da aplicação
  - ◆ Depende da porcentagem de registros marcados como removidos

Abordagem Dinâmica

Abordagem Dinâmica

- Em aplicações on-line, que acessam arquivos altamente voláteis, pode ser necessário um processo dinâmico de recuperação de espaço
  - Marcar registros eliminados (remoção lógica)
  - Localizar os espaços desocupados quando necessário
    - **Sem buscas exaustivas !**

Abordagem Dinâmica

- ➔ Ao adicionar um novo registro:
  - ◆ Saber imediatamente se há *slots*
    - ● *Slot* = espaço disponível de um registro removido
  - ◆ Acessar diretamente um *slot*, se existir
    - ● Diretamente = sem buscas exaustivas !

Registros de Tamanho Fixo

Registros de Tamanho Fixo

- RRN (*relative record number*)
  - Fornece a posição relativa de cada registro dentro do arquivo
  - Permite calcular o *byte offset* no qual cada registro começa

Registros de Tamanho Fixo

- RRN (*relative record number*)
  - Fornece a posição relativa de cada registro dentro do arquivo
  - Permite calcular o *byte offset* no qual cada registro começa

byte offset = RRN x tamanho do registro

Registros de Tamanho Fixo

- ➔ Exemplo - RRN
  - ◆ Registros de tamanho fixo
    - Tamanho de 46 bytes
  - ◆ Campos de tamanho fixo
    - Nome: string de 12 caracteres (12 bytes)
    - Rua: string de 10 caracteres (10 bytes)
    - Número: inteiro (4 bytes)
    - Cidade: string de 20 caracteres (20 bytes)

Registros de Tamanho Fixo

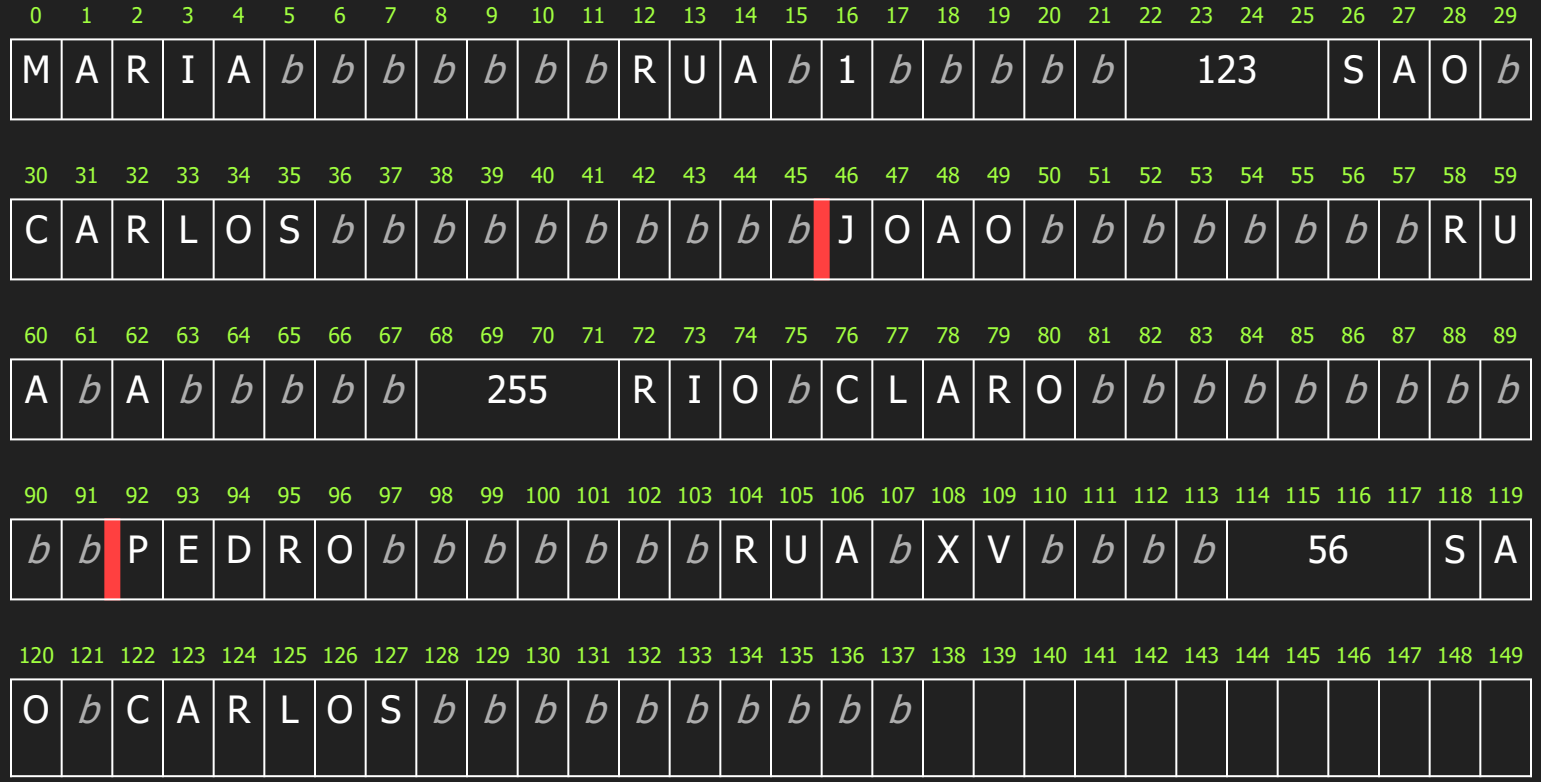

Registros de Tamanho Fixo

Registro	RRN	Byte Offset
primeiro (MARIA)	0	0 x 46 = 0
segundo (JOAO)	1	1 x 46 = 46
terceiro (PEDRO)	2	2 x 46 = 92

Como identificar aonde estão os *slots*?

Registros de Tamanho Fixo

- Lista encadeada de registros eliminados disponíveis
- Cada elemento da lista armazena o RRN do próximo registro vago
- Cabeça da lista está no *header* do arquivo:
  - Cabeçalho (que é um registro) armazena RRN do 1º *slot* (registro vago)

Registros de Tamanho Fixo

- ➔ Inserção e remoção ocorrem sempre no início da lista
  - ◆ Lista encadeada operada como PILHA !
  - ◆ Pilha pode ser mantida no próprio arquivo !

Registros de Tamanho Fixo

- Exemplo:
  - Inserção do registro com RRN 3
- inserção na pilha: registro eliminado do arquivo
- remoção da pilha: registro adicionado ao arquivo

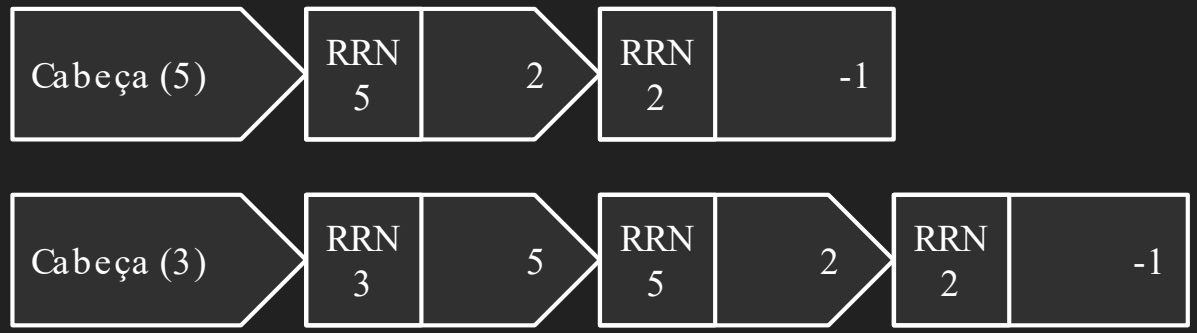

Registros de Tamanho Fixo - Exemplo

➔ Arquivo Original

head = -1

Ana Silva|22|8,0|.....

Jose Dantas|25|7,0|.....

Luiza Aires|19|5,0|.....

Registros de Tamanho Fixo - Exemplo

➔ Após remoção do 3º registro

head = 2

Ana Silva|22|8,0|.....

Jose Dantas|25|7,0|.....

*|-1 Aires|19|5,0|.....

Registros de Tamanho Fixo - Exemplo

➔ Após remoção do 1º registro

head = 0

*|2Iva|22|8,0|.....

Jose Dantas|25|7,0|.....

*|-1Aires|19|5,0|.....

Após uma inserção?

Registros de Tamanho Fixo - Exemplo

➔ Após remoção do 1º registro

head = 2

Marcos Santos|19|5,0|.....

Jose Dantas|25|7,0|.....

*|-1 Aires|19|5,0|.....

Registros de Tamanho Fixo

- ➔ Implementação: o cabeçalho pode ser implementado como uma struct em C:
  - ◆ Um dos campos armazena o RRN do 1º reg. Vago
    - ● ex: int head.first_avail
  - ◆ Demais campos podem armazenar outras infos
- ➔ O arquivo de dados em si começa após os bytes do cabeçalho

Registros de Tamanho Variável

Registros de Tamanho Variável

- ➔ Registros de tamanho variável: um problema adicional...
  - ◆ Registros não são acessíveis por RRN...
    - ● Não se recupera os byte offsets pelos RRNs
- ➔ Solução:
  - ◆ Armazenar os byte offsets na lista encadeada
    - ● ao invés dos RRNs
  - ◆ Utilizar registros com indicador de tamanho
  - ◆ Permite saber o tamanho do slot a partir do byte offset

Registros de Tamanho Fixo - Exemplo

➔ Arquivo Original

head = -1

15 Ana|Sao Carlos|14 Jose|Campinas|16 Luiza|Sao Paulo|

Indicador de Tamanho

Registros de Tamanho Fixo - Exemplo

➔ Após Remoção do 2º registro

head = 18

15 Ana|Sao Carlos|14*|-1 ..... |16 Luiza|Sao Paulo|

Registros de Tamanho Variável

➔ Mas o problema ainda não está resolvido…

- Registros são de tamanho variável => não é qualquer slot da lista que serve para acomodar um novo registro a ser adicionado
  - É preciso encontrar um slot grande o suficiente
    - Se não for encontrado, adiciona-se ao final do arquivo
  - E para isso, é preciso percorrer sequencialmente a lista

Registros de Tamanho Variável

➔ Adicionar registro de 55 bytes

47? Pequeno

38? Pequeno

72? Suficiente!

Registros de Tamanho Variável

➔ Adicionar registro de 55 bytes

Fragmentação Interna

Fragmentação Interna

- ➔ No Exemplo: usamos todos os 72 bytes de um slot para adicionar um registro de apenas 55 bytes
  - ◆ Os 17 bytes extras dentro do registro ficaram inutilizados

Fragmentação Interna!

Fragmentação Interna

- ➔ Tratamento de fragmentação interna
  - ◆ Os bytes não utilizados no registro é mantido como um slot menor na lista de registros eliminados

Registros de Tamanho Variável

➔ No Exemplo (slot de 72 bytes para um registro de 55):

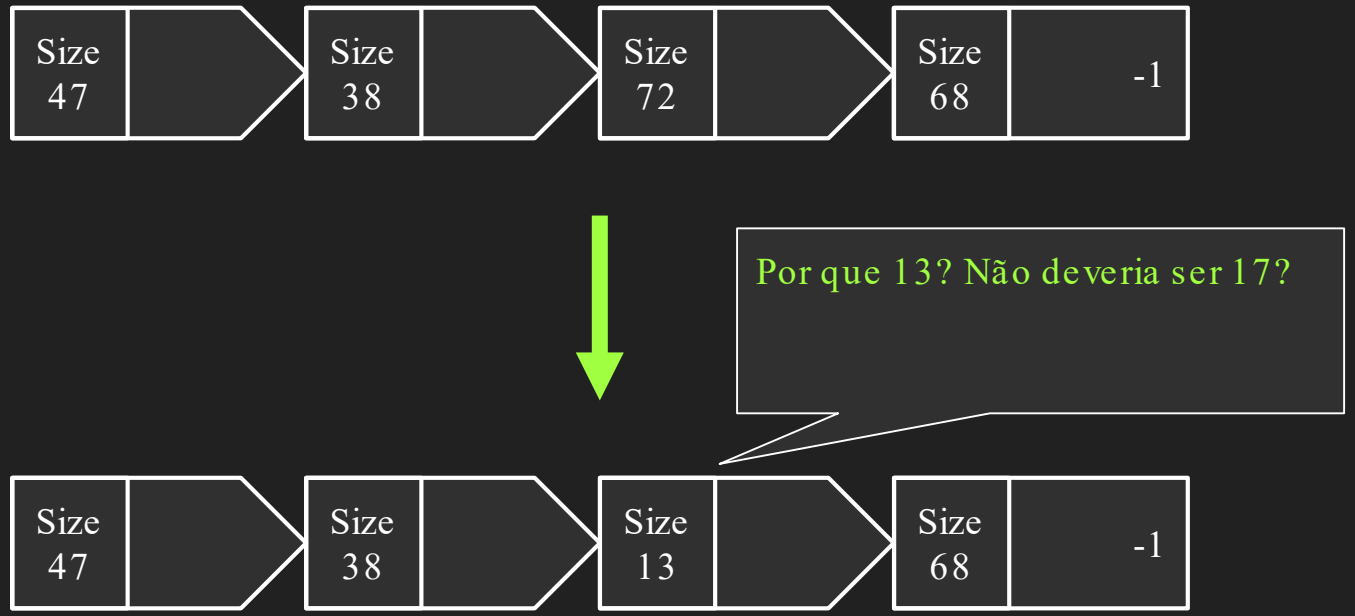

Registros de Tamanho Variável

➔ No Exemplo (slot de 72 bytes para um registro de 55):

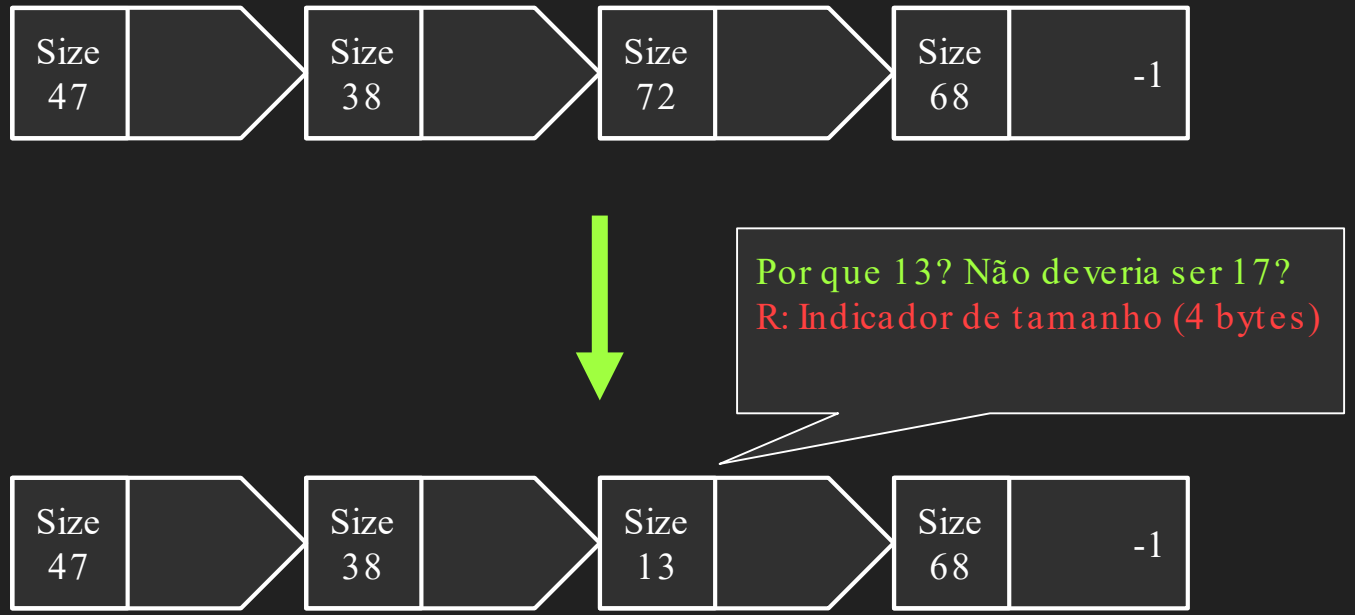

Fragmentação Externa

Fragmentação Externa

- ➔ Após a inserção de um registro de 8 bytes, restam:
  - ◆ 4 bytes para indicador de tamanho
  - ◆ 1 byte para dados
- ➔ No entanto... qual a probabilidade de encontrar um ou mais registros que ocupem o espaço (slot) restante?

Fragmentação Externa!

Fragmentação Externa

- ➔ Estratégias para combater a fragmentação externa
  - ◆ Compactação (off-line)
    - Gerar novamente o arquivo de tempos em tempos
  - ◆ Coalescing
    - Buscar por slots disponíveis que sejam fisicamente adjacentes e uni-los em slots disponíveis maiores
    - Dificuldade?

Fragmentação Externa

- ➔ Estratégias para combater a fragmentação externa
  - ◆ Estratégias de Alocação de slots
    - Tentar evitar a fragmentação antes que ela ocorra por meio de estratégias de alocação de slots para novos registros

Estratégias de Alocação de Slots

Estratégias de Alocação de Slots

- First-Fit
  - Primeiro da lista que seja grande o suficiente
- Best-Fit
  - Aquele com tamanho mais parecido ao do registro
- Worst-Fit
  - Aquele com o maior tamanho de todos

First-Fit

- ➔ Estratégia mais simples de todas
  - ◆ Requer apenas percorrer a lista
  - ◆ Exatamente o que fizemos até agora
- ➔ Na verdade, não tenta prevenir fragmentação
  - ◆ Responsabilidade da compactação e/ou coalescing

Best-Fit

- ➔ Estratégia mais intuitiva de todas
- ➔ Requer manter a lista ordenada
  - ◆ Ordenação ascendente com o tamanho dos slots
  - ◆ Demanda tempo computacional extra: não é mais possível sempre adicionar um slot ao início da lista
- ➔ Mas, na verdade, pode piorar fragmentação
  - ◆ Se slot não for perfeito, sobra é mínima!

Worst-Fit

➔ Estratégia menos intuitiva de todas
- ◆ Requer manter a lista ordenada
  - ● Ordenação descendente com o tamanho dos slots
  - ● Tempo extra é compensado: se 1º slot não acomodar o registro, nenhum outro slot irá!
- ◆ Minimiza fragmentação
  - ● Já que raramente slot é perfeito, sobra é máxima!

Exemplo

➔ Dado os dados do exemplo que já vimos:

➔ Ao inserirmos um registro de 40 bytes, onde ele seria inserido para cada algoritmo?

First-Fit

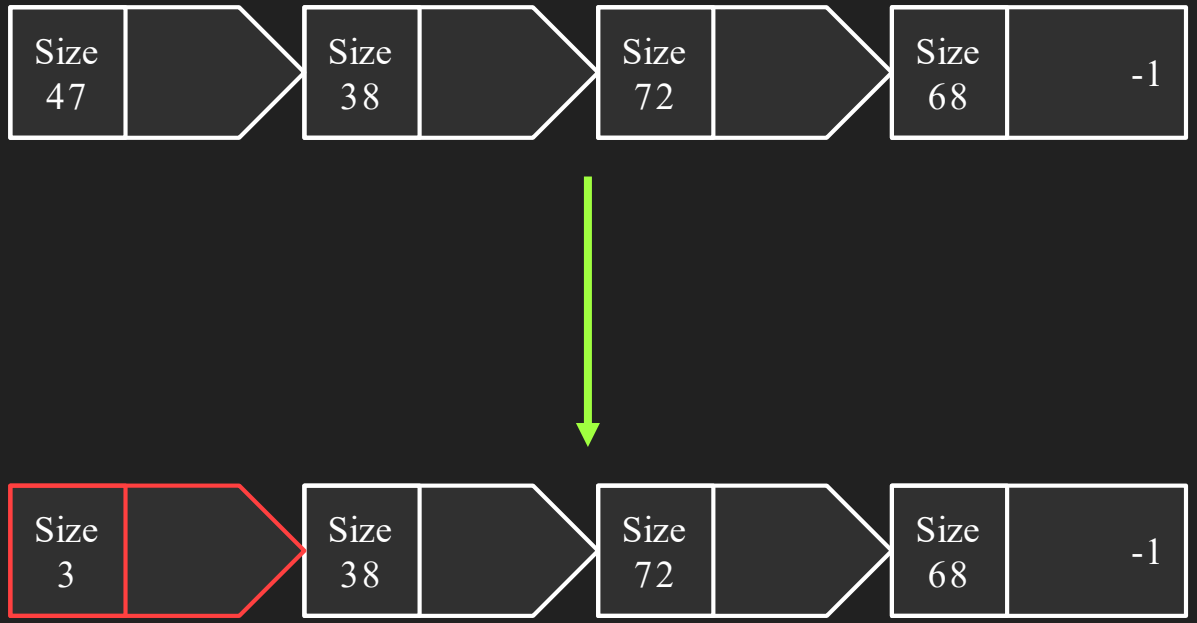

Best-Fit

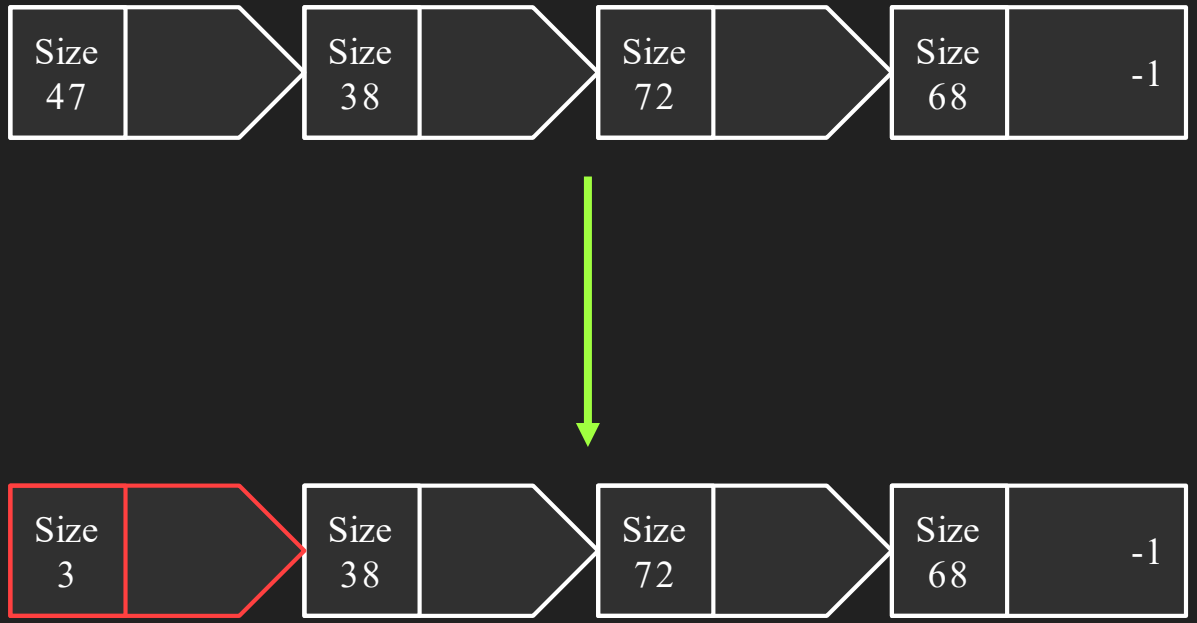

Worst-Fit

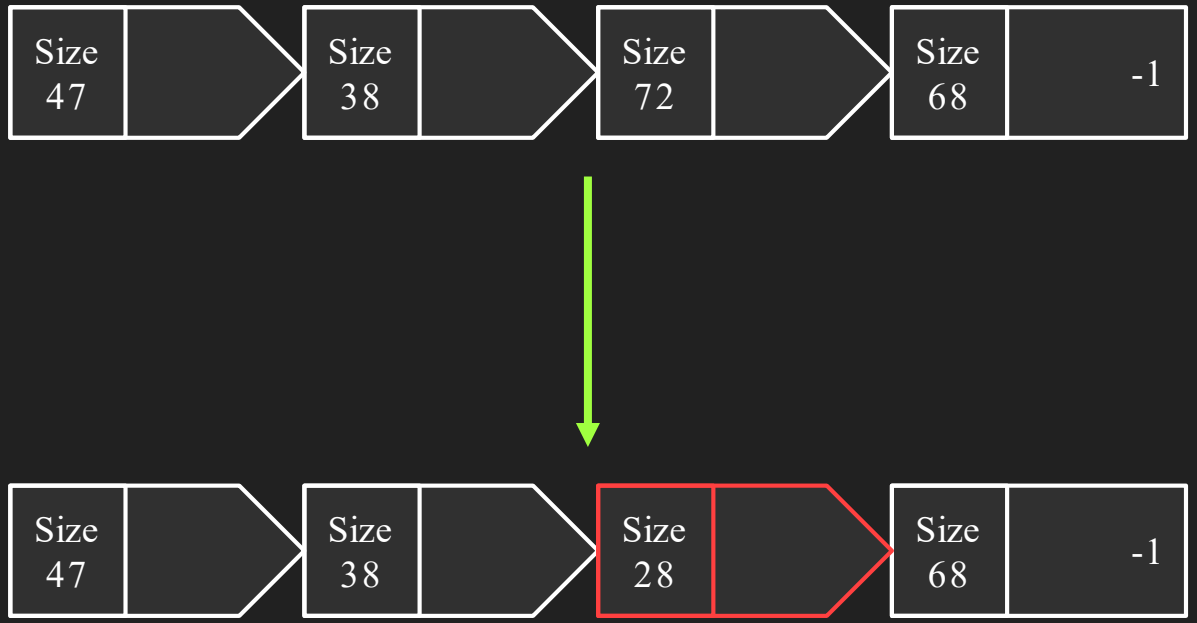
Size
47
Size
38
Size
72
Size
68
-1
Size
47
Size
38
Size
28
Size
68
-1

Compressão

Compressão

- ➔ Reduz arquivos!
  - Diminui armazenamento (e custo)
  - Transmissão mais rápida
    - Diminui tempo de acesso
    - Ou o mesmo tempo de acesso com largura de banda menor
  - Processamento mais rápido

Compressão

- ➔ Envolve codificar informação em um arquivo para que ela ocupe menos espaço
- ➔ Existem várias técnicas
  - ◆ Algumas genéricas
  - ◆ Outras específicas para tipos de dado
    - Voz
    - Imagens
    - Texto
    - ...

Compressão

- ➔ Normalmente, usar ou não uma técnica de compressão é situacional
  - ◆ Compressão requer processamento extra
  - ◆ Aumento da complexidade do código
  - ◆ E muitas vezes perda de legibilidade
- ➔ É preciso analisar cada caso, e cada algoritmo disponível
  - ◆ Somente usar caso o custo-benefício seja positivo

Run-Length

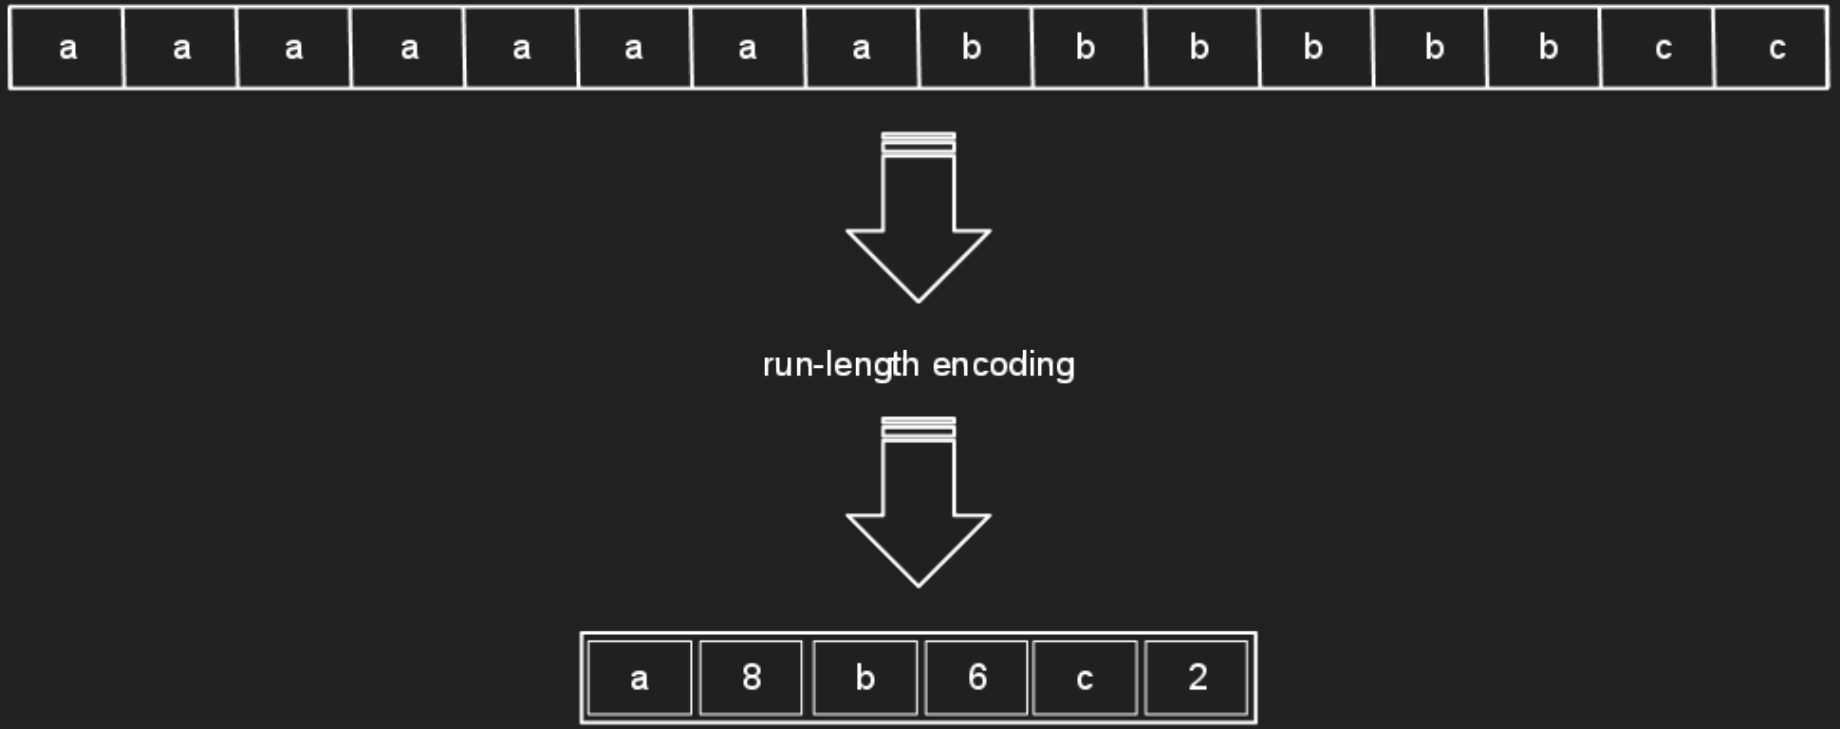

Fonte: https://programmersought.com/article/8100198818/

Codificação de Huffman

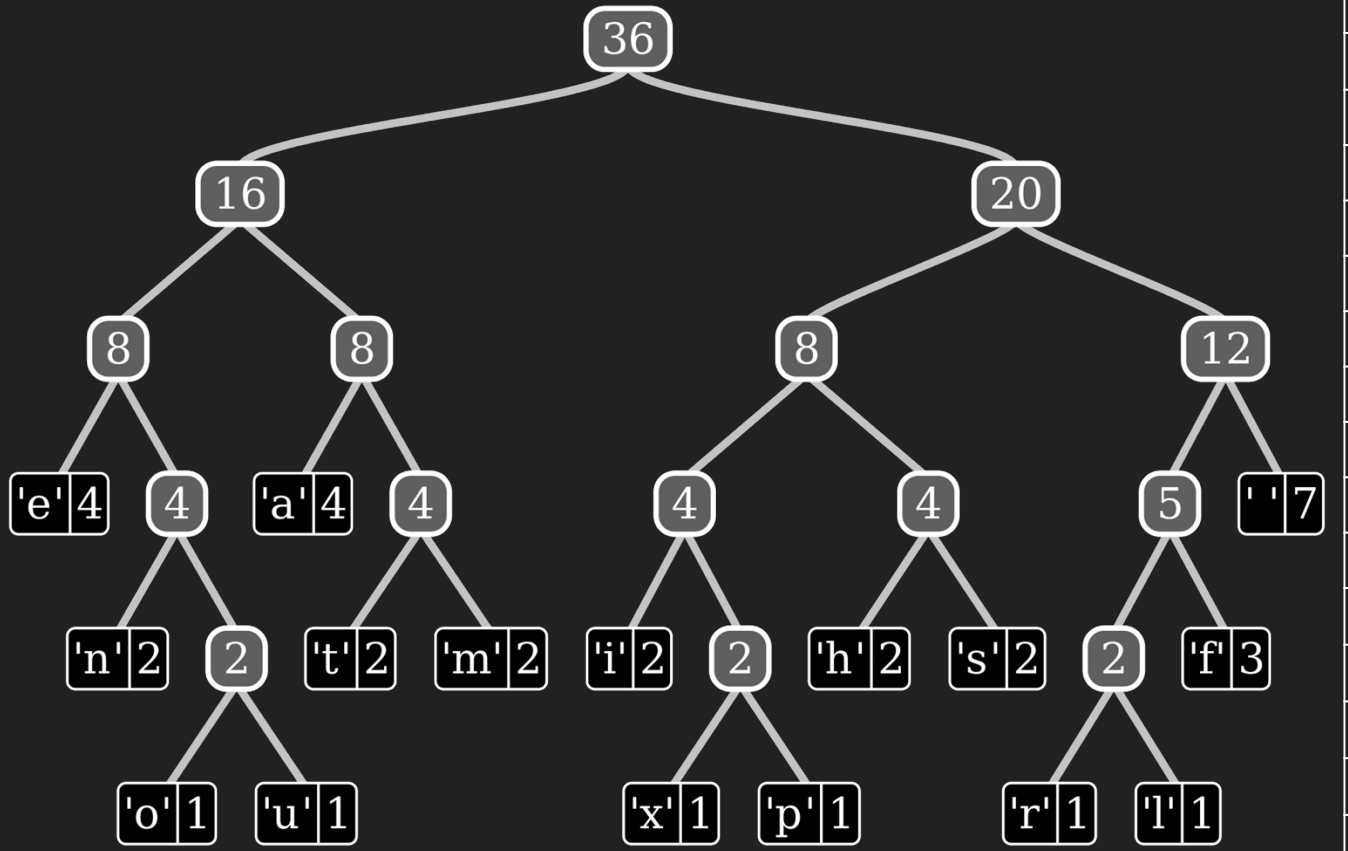

“this is an example of a huffman tree”

Fonte: https://en.wikipedia.org/wiki/Huffman_coding

Char	Freq	Code
space	7	111
a	4	010
e	4	000
f	3	1101
h	2	1010
i	2	1000
m	2	0111
n	2	0010
s	2	1011
t	2	0110
l	1	11001
o	1	00110
p	1	10011
r	1	11000
u	1	00111
x	1	10010

Referências

- M. J. Folk, B. Zoellick and G. Riccardi. File Structures: An object-oriented approach with C++, Addison Wesley, 1998.
- M. J. Folk and B. Zoellick, File Structures, Second Edition, Addison Wesley, 1992.