Algoritmos e Estruturas de Dados II

Prof. Debora M. R. Medeiros

Fundamentos de Arquivos

Adaptado dos Originais de:

Ricardo J. G. B. Campelo
Leandro C. Cintra
Maria Cristina F. de Oliveira

Arquivos

- Informação mantida em memória secundária (externa)
  - HD
  - CD
  - DVD
  - Memórias Flash
  - Fitas magnéticas
  - ...

Memória Secundária x Principal

- Tempo de Acesso
  - Ordem de grandeza da diferença entre os tempos de acesso pode ser de milhares
  - Por exemplo, discos (HDs, ...) podem ser milhares de vezes mais lentos que memória RAM

Discos X Memória Principal

- Capacidade de Armazenamento
  - Disco – alta, a um custo relativamente baixo
  - RAM – limitada pelo custo e espaço
- Tipo de Armazenamento
  - Disco – não volátil
  - RAM – volátil

Memória Secundária x Principal

- Em resumo:
  - acesso a dispositivo secundário é custoso (lento) !
- Logo:
  - número de acessos deve ser minimizado
- Para tanto:
  - Estruturas de organização de informação
    - Estruturas de Arquivos (File Structures)

Organização de Arquivos

- Meta:
  - minimizar as desvantagens do uso da memória externa
- Objetivo:
  - minimizar o tempo total de acesso ao dispositivo de armazenamento externo
  - de forma independente da tecnologia:

Tempo de Acesso = no. de acessos * tempo de 1 acesso

Memória Secundária x Principal

- Estruturas de dados eficientes em memória principal não o são em memória externa
  - Eficiência presume que toda a informação é instantaneamente acessível na memória se o respectivo endereço for conhecido
    - Tempo de acesso desprezível
    - Gargalos são as operações lógicas, aritméticas, ...

Memória Secundária x Principal

- Busca binária $O(\lg n)$
  - Mem. Principal
    - 100 registros → 6 comparações
  - Mem. Secundária
    - 6 acessos ao disco

Dispositivo Externo como Gargalo

- Muitos processos são "disk-bounded", isto é, CPU e rede têm que esperar pelos dados do dispositivo externo:
  - Tais dispositivos (p. ex. discos) tipicamente são muito mais lentos que CPU e rede

Técnicas p/ Minimizar o Problema

- Multi-Programação:
  - CPU trabalha em outro processo enquanto aguarda o dispositivo externo
- Striping:
  - dados repartidos em vários *drives* (paralelismo)
- RAID (*Redundant Array of Inexpensive Disks*):
  - tecnologia baseada em striping
  - http://linas.org/linux/raid.html

Técnicas p/ Minimizar o Problema

- Disk Cache:
  - blocos de memória RAM configurados para conter páginas de dados do dispositivo externo
  - cache é verificado primeiro. Se a informação desejada não é encontrada, um acesso ao dispositivo externo é realizado, e o novo conteúdo é carregado no cache
- Organização de Arquivos !

Arquivo Físico e Arquivo Lógico

- **Arquivo Físico:**
  - seqüência de bytes armazenados no disp. externo
    - armazenamento em geral não é fisicamente seqüencial
- **Arquivo Lógico**:
  - arquivo como visto pelo aplicativo que o acessa
    - freqüentemente visão é seqüencial
- **Associação Arquivos Físico – Lógico**:
  - iniciada pelo aplicativo, gerenciada pelo S.O.

Arquivo Físico e Arquivo Lógico

- **Arquivo Físico**:
  - conjunto de bytes no dispositivo externo
    - geralmente agrupados em setores e clusters de dados
    - gerenciado pelo sistema operacional
- **Arquivo Lógico**:
  - modo como a *linguagem de programação* ou *aplicativo* enxerga os dados
    - seqüência de bytes eventualmente organizados em *registros* ou outra *estrutura lógica*

Associação Arquivo Físico – Lógico

- Em C: (associa e abre – nesse exemplo para escrita)

```
file *pt_arq;
if ( (pt_arq=fopen("meu_arq.dat", "w")) == NULL )
    printf("erro...")   // p. ex. disco cheio ou protegido
else ...
```


Revisão Arquivos em C

- pt_arq = **fopen**("filename","flags")
  - filename: nome do arquivo a ser aberto
  - flags: controla o modo de abertura
    - **r**: abre arquivo texto somente para leitura
    - **w**: cria arq. texto só para escrita (se já existe, é apagado)
    - **a**: anexa (append) ou cria arquivo texto só para escrita
    - **r+**: abre arquivo texto para leitura / escrita
    - **w+**: cria arq. texto para leitura / escrita (se já existe, é apagado)
    - **a+**: anexa ou cria arquivo texto para leitura / escrita

Revisão Arquivos em C

- pt_arq = **fopen**("filename","flags")
  - filename: nome do arquivo a ser aberto
  - flags: controla o modo de abertura
    - **rb**: abre arquivo binário somente para leitura
    - **wb**: cria arq. binário só para escrita (se já existe, é apagado)
    - **ab**: anexa (append) ou cria arquivo binário só para escrita
    - **r+b**: abre arquivo binário para leitura / escrita
    - **w+b**: cria arq. bin. para leitura / escrita (se já existe, é apagado)
    - **a+b**: anexa ou cria arquivo binário para leitura / escrita

Fechamento de Arquivos

- Em C: **fclose**(pt_arq)
  - Descarrega conteúdo do *buffer*, garantindo que todas as informações sejam atualizadas e salvas
  - Encerra a associação entre arquivos lógico e físico
- Notas:
  - Em geral, S.O. fecha o arquivo se o programa não o fizer (prevenindo contra perdas de informação)
  - **fflush**(pt_arq) força descarregar o *buffer* sem precisar fechar o arquivo, prevenindo interrupções

Revisão Arquivos em C

- Funções de Leitura / Escrita
  - **fread**()
  - **fwrite**()
    - dados lidos/escritos como registros ou blocos de bytes
    - exemplo: **fwrite**(&v[0], sizeof(**int**), 10, pt_arq);
  - **fgetc**()
  - **fputc**()
    - dados lidos/escritos um caractere por vez

Revisão Arquivos em C

- Funções de leitura / escrita
  - **fgets**()
  - **fputs**()
    - dados lidos/escritos como *strings*
  - **fscanf**()
  - **fprintf**()
    - dados lidos/escritos de modo formatado

Revisão Arquivos em C

- Controle de final de arquivo:
  - Via retornos de funções de leitura/escrita:
    - **EOF** (tipo especial): **fgetc**, **fscanf**, ...
    - Ponteiro **NULL**: **fgets**
    - No. de *itens* lidos/escritos: **fread**, **fwrite**
  - Via **feof**(ponteiro)
    - função com retorno lógico

O Ponteiro no Arquivo Lógico

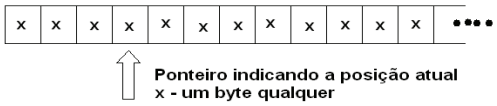

Acesso Seqüencial vs Aleatório

- Leitura Seqüencial:
  - ponteiro de leitura avança byte a byte (ou por blocos), a partir de uma posição inicial
- Acesso Aleatório (Direto - Seeking):
  - acesso envolve o posicionamento do ponteiro em um byte ou registro arbitrário

Revisão Arquivos em C

- Seeking:
  - mover o ponteiro para uma certa posição no arquivo
  - seeking em C
    - bol = **fseek**(pt_arq, byte-offset, origin)
      - bol: retorno lógico (0 ou 1 - mal ou bem sucedido)
      - pt_arq: ponteiro arquivo
      - byte-offset: deslocamento, em bytes, a partir de *origin*
      - origin:
        - **SEEK_SET** (tipo especial – início do arquivo)
        - **SEEK_CUR** (tipo especial – posição atual)
        - **SEEK_END** (tipo especial – fim do arquivo)

Bibliografia

- **M. J. Folk and B. Zoellick, *File Structures: A Conceptual Toolkit*, Addison Wesley, 1987.**
- **Schildt, H. "C Completo e Total", 3a. Edição, Pearson, 1997.**