Buffer Management

金培权（jpq@ustc.edu.cn）

Idea: Minimize the count of disk I/Os by keeping likely-to-be-requested pages in memory (buffer frames)

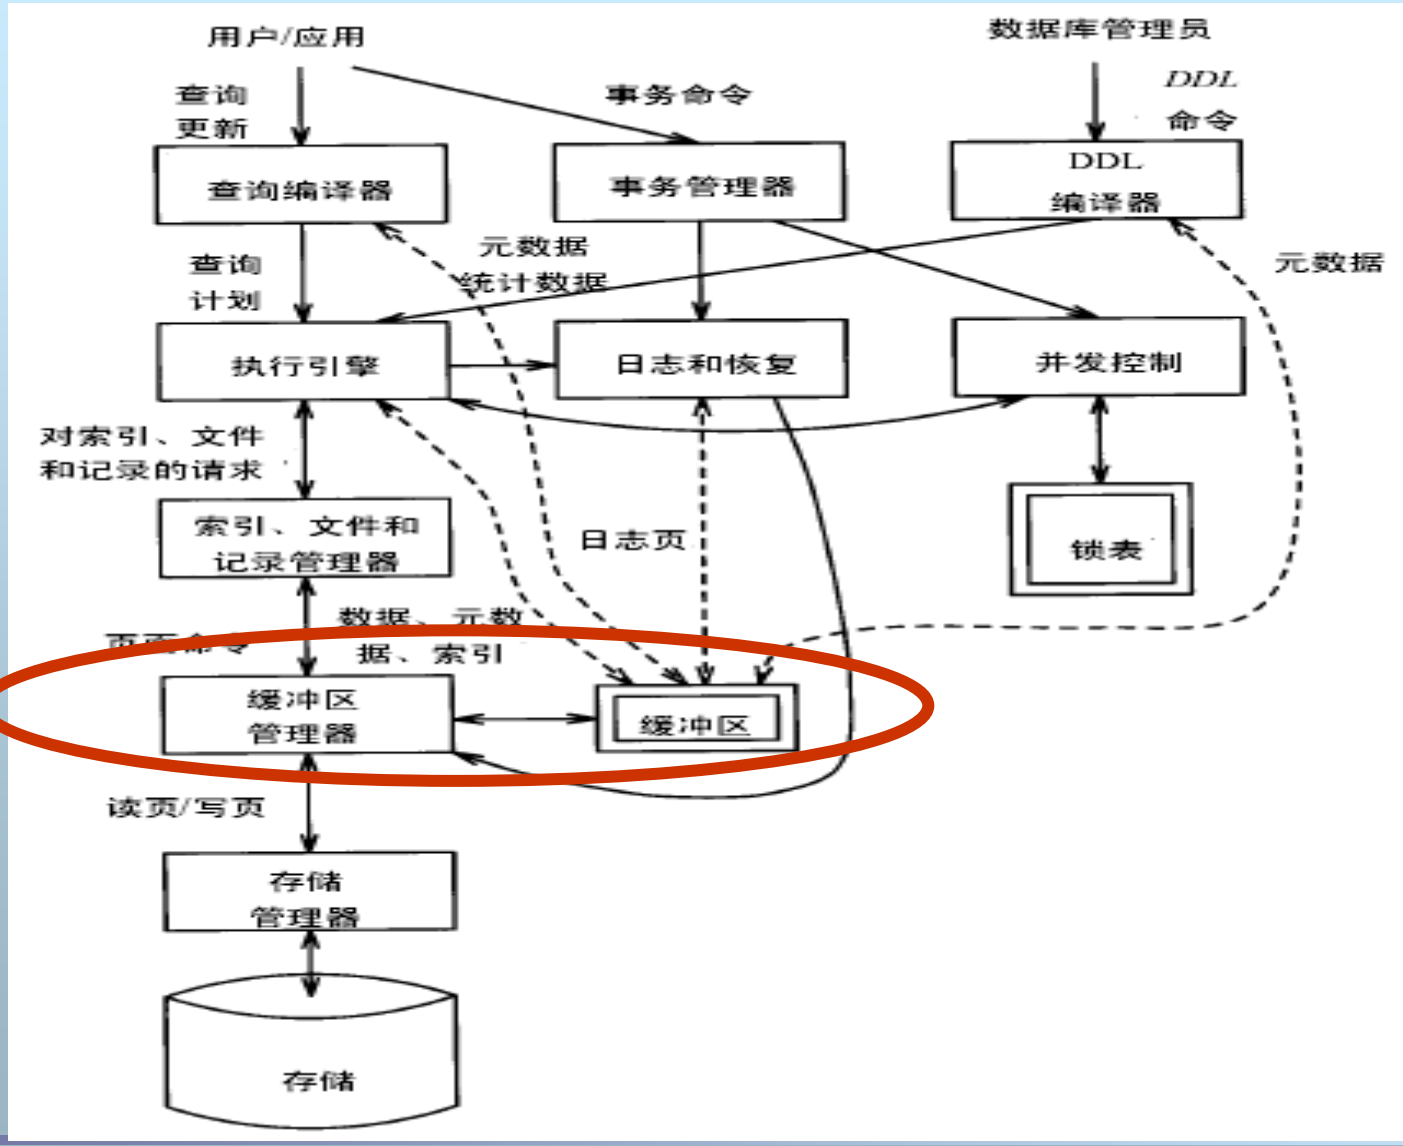

主要内容

- 缓冲区结构
- 缓冲区置换算法
- 缓冲区管理的实现

一、缓冲区结构

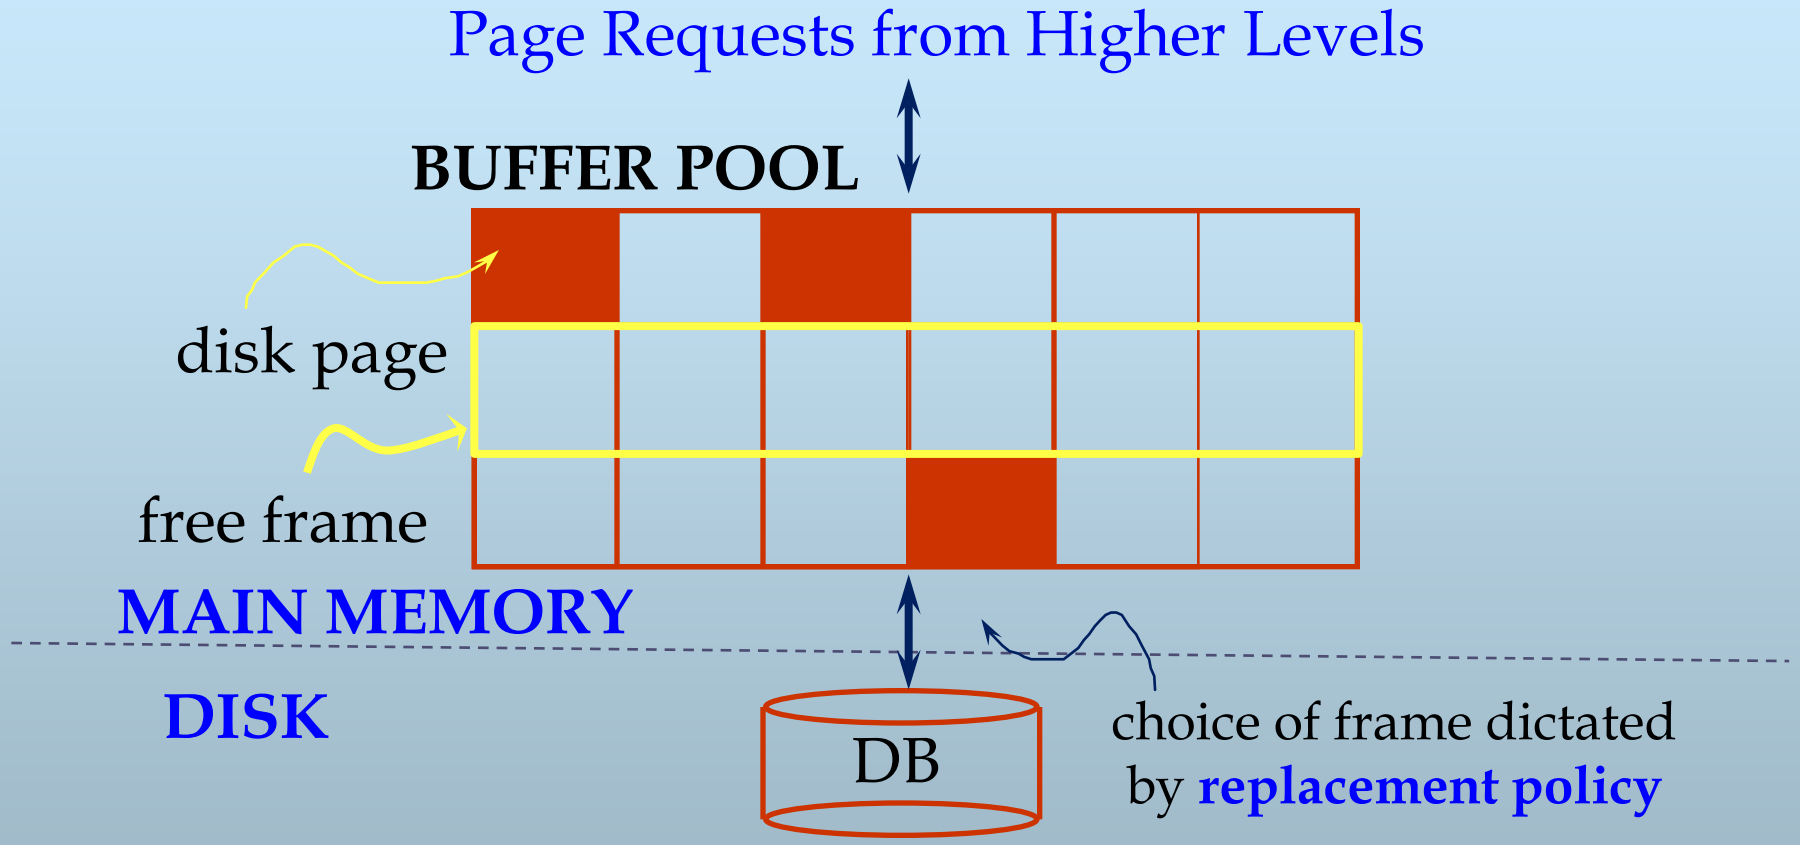

- ***Data must be in RAM for DBMS to operate on it!***
- ***Buffer Mgr hides the fact that not all data is in RAM***

1、frame的参数

- Dirty
  - Frame中的块是否已经被修改
- Pin-count
  - Frame的块的已经被请求并且还未释放的计数，即当前的用户数
- *Others
  - Latch: 是否加锁

2、当请求块时

- If the requested block is not in the pool:
  - Choose a frame for replacement
  - If the frame is *dirty (some blocks are modified and haven't been written to the disk)*, write it to the disk
  - Read the requested block into the chosen frame
- *Pin (increment the pin-count* of the frame*)* the block and return its address.

2、当释放块时

- Requestor must *unpin* the frame containing the block
- Requestor must indicate whether block has been modified:
  - *dirty* bit is used for this.

二、缓冲区替换策略

- **Frame is chosen for replacement by a *replacement policy:***
  - **Least-recently-used (LRU), Clock, FIFO, MRU (Most-recently-used) etc.**
- **Only frames whose pin-count=0 are candidates**
- **Policy can have big impact on # of I/O's; depends on the *access pattern*.**

二、缓冲区替换策略

- 理论最优算法：OPT算法
  - 也称为Belady's算法
  - 理论上最佳的页面置换算法。它每次都置换以后永远也用不到的页面，如果没有则淘汰最久以后再用到的页面。
  - OPT算法必须预先知道全部的页面访问序列，而这在实际DBMS/OS中是无法实现的，因此仅有理论意义。
- 但OPT算法可以在实验中作为算法性能上界加以对比

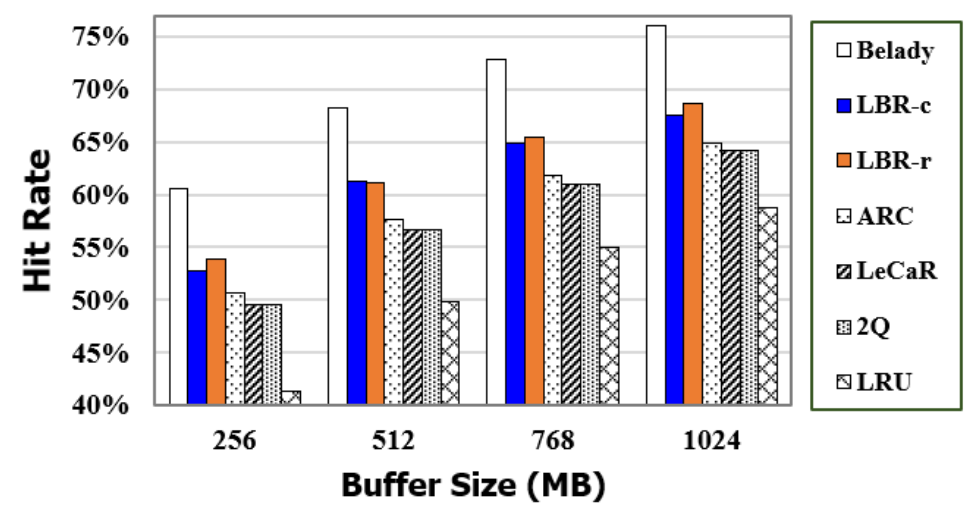

1、LRU

- LRU (Oracle, Sybase, Informix)
  - 所有frame按照最近一次访问时间排列成一个链表

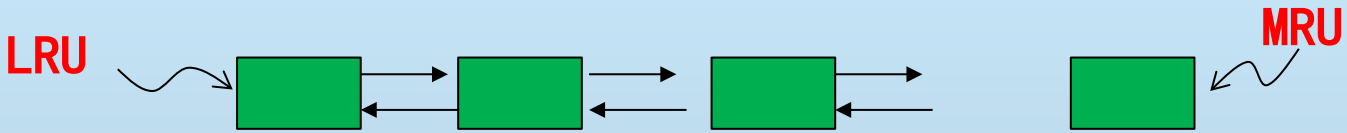

  - 基于时间局部性(Temporal Locality) 假设：越是最近访问的在未来被访问的概率越高. 总是替换LRU端的frame
- Pros
  - Works well for repeated access to popular pages
  - O(1) complexity for victim selection
- Cons:
  - 缓存污染(Sequential flooding)： LRU + repeated sequential scans.
  - 每次访问都需要修改LRU链表，并发性能差
  - 如果访问不满足时间局部性，则性能较差
  - 只考虑最近一次访问，不考虑访问频率

2、LRU-K

- LRU不考虑frame的访问频率，不合理
- LRU-K：如果某个frame的访问次数达到了K次以上，则应当尽量不置换
  - 维护2个LRU链表
    - 1个是访问次数小于K次的
    - 1个是访问次数K次以上的
  - 优先按照LRU策略置换小于K次的链表
  - 保证高频访问的页能够尽量在buffer中
  - 实验表明
    - K并非越大越好，LRU-2 性能较好
  - 缺点：需要额外记录访问次数

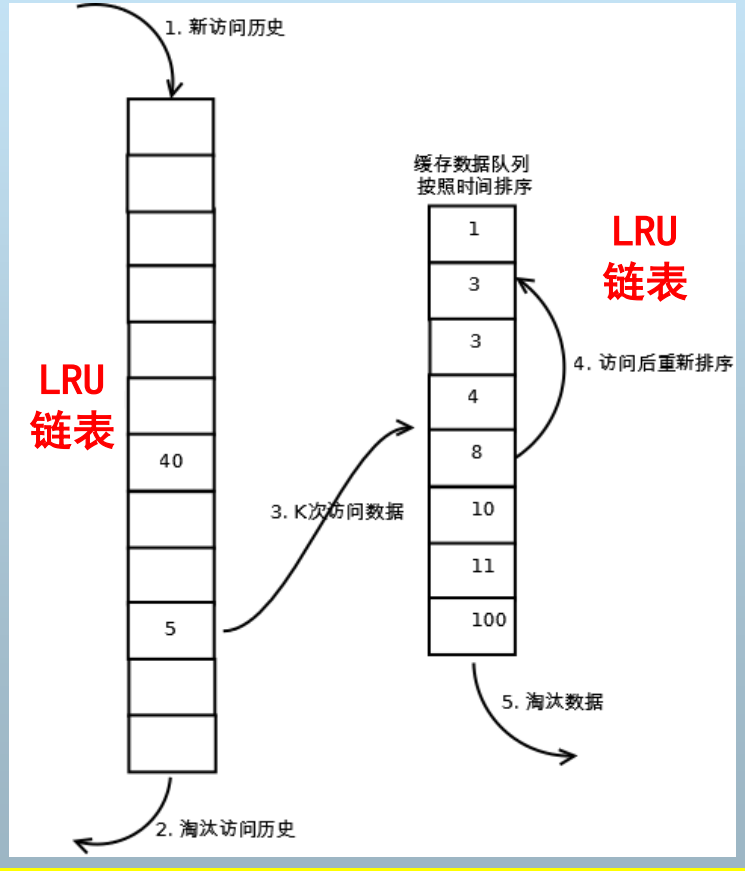

E. O'Neil, P. O'Neil, G. Weikum: The LRU-K Page Replacement Algorithm for Database Disk Buffering, SIGMOD 1993, pp. 297-306

3、2Q

- 与LRU-2类似，不同之处在于访问1次的队列采用FIFO，而不是LRU

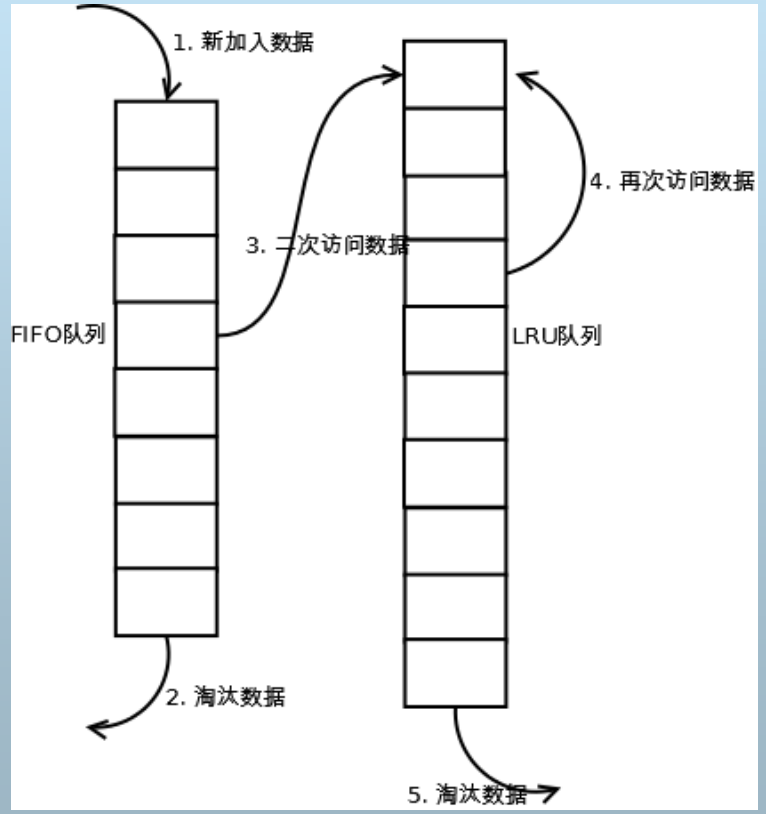

T. Johnson, D. E. Shasha: 2Q: A Low Overhead High Performance Buffer Management Replacement Algorithm. VLDB 1994: 439-450

4、Second-Chance FIFO

- 所有frame组成FIFO链表，每个frame附加一个bit位，初始为0。当FO页第一次被选中置换时置为1，并移到FI端。只有bit位为1的FO端的页才被选中置换。

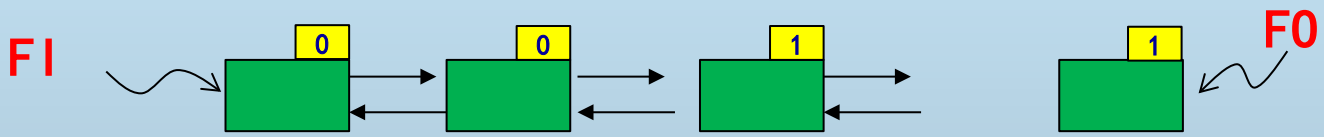

- 相当于每个frame给了两次置换机会，避免高频访问但最近一轮没有被访问的frame被置换出buffer
- 每个frame只需要1个额外bit，空间代价很低
- 缺点：置换时需要移动多个元素，理论性能比LRU差

5、CLOCK

- 如何避免每次访问时的链表调整代价？
- Second-Chance FIFO

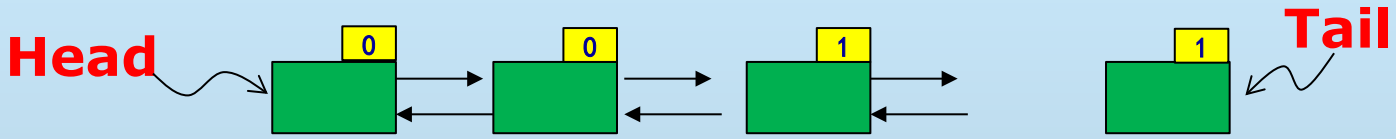

- Clock (MS SQL Server, PostgreSQL, GaussDB)
  - 把Second-Chance FIFO组织成环形
  - N个frame组成环形，current指针指向当前frame；每个frame有一个referenced位，初始为1；
  - 当需要置换页时，从current开始检查，若pin-count>0，current增加1；若referenced已启动（=1），则关闭它（=0）并增加current（保证最近的不被替换）；若pin-count=0并且referenced关闭（=0），则替换该frame，同时current加1
  - 注意：Current指针只在置换时更新，访问命中时不改变Current指针

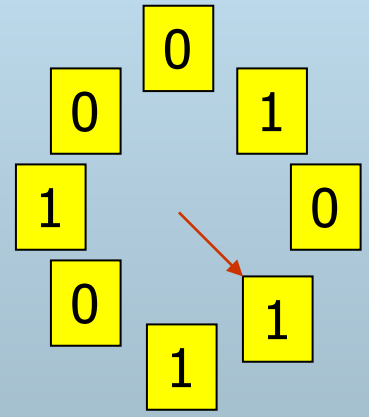

6、SSD上的置换算法

- 闪存：读快写慢，写次数有限
  - 减少缓存置换中对闪存的写是一个重要指标
- SSD-aware缓存算法
  - **CFLRU** (CASES'06，CASES'21 Test of Time Award)
    - Clean-first
  - **LRU-WSR** (IEEE Trans CE'08)
    - Clean-first + cold flag
    - 置换：clean>cold dirty>hot dirty
  - **AD-LRU** (DKE'10)
    - cold LRU list + hot LRU list
    - Dynamically adjust two LRUs
  - ……

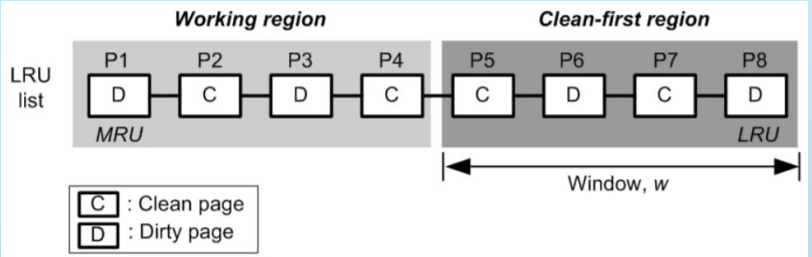

Figure 1. Example of CFLRU algorithm

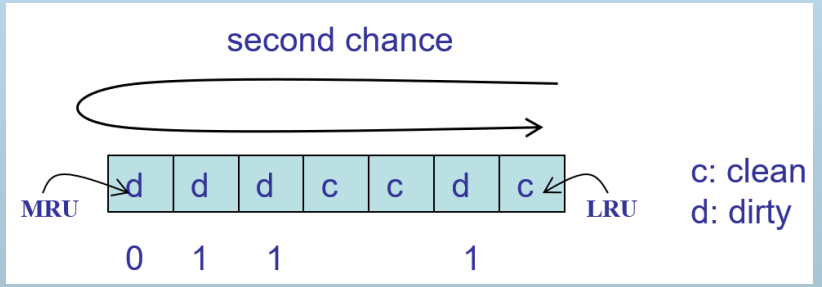

	LRU	CF-LRU	LRU-WSR	AD-LRU
Recency	√	√	√	√
Cleanness*	×	√	√	√
Frequency	×	×	×	√

7、为何不使用OS缓冲区管理？

- DBMS经常能预测访问模式(Access Pattern)
  - 可以使用更专门的缓冲区替换策略
  - 有利于pre-fetch策略的有效使用
- DBMS需要强制写回磁盘能力（如WAL），OS的缓冲写回一般通过记录写请求来实现（来自不同应用），实际的磁盘修改推迟，因此不能保证写顺序

三、缓冲区管理器的实现

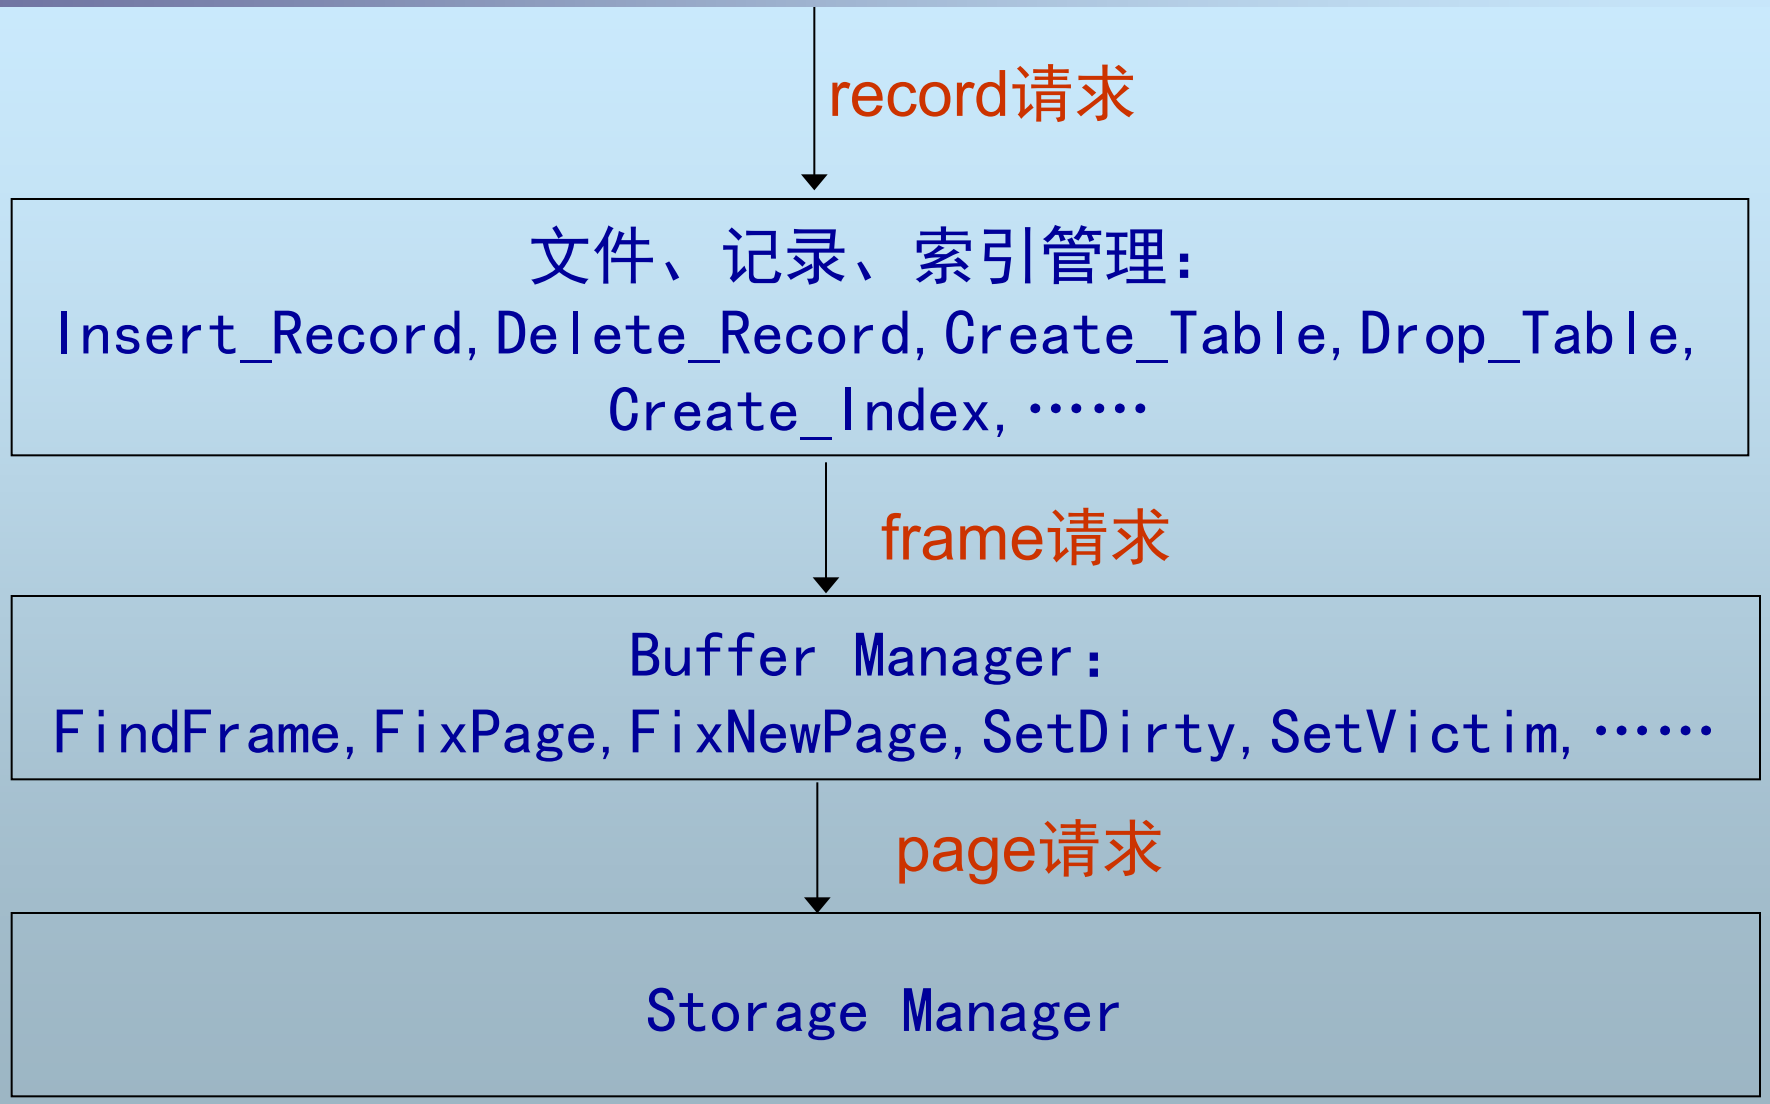
record请求
文件、记录、索引管理：
Insert_Record, Delete_Record, Create_Table, Drop_Table,
Create_Index, ……
frame请求
Buffer Manager：
FindFrame, FixPage, FixNewPage, SetDirty, SetVictim, ……
page请求
Storage Manager

1、错误的记录操作实现例子

- 例如，插入记录
  int insert_record(DBFILE*, DBRECORD)
  - ……
  - fopen()
  - fseek()
  - fwrite()
  - ……
- 没有DBMS自己的缓冲区管理和存储管理
- 直接基于文件系统，使用了FS的缓冲管理
  - 不能保证WAL
  - 不利于查询优化
  - 不适应应用需求

2、Block vs. Disk File

- **Disk File**

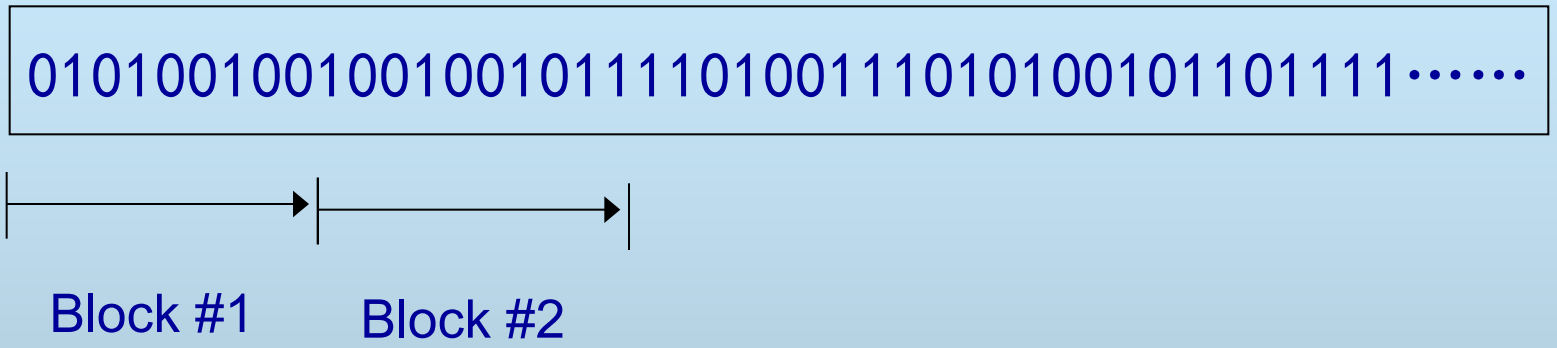

文件存储在磁盘上的物理形式是bits/bytes，block是由OS或DBMS软件对文件所做的抽象，这一抽象是通过控制数据在文件中的起止offset来实现的

3、Buffer vs. Disk File

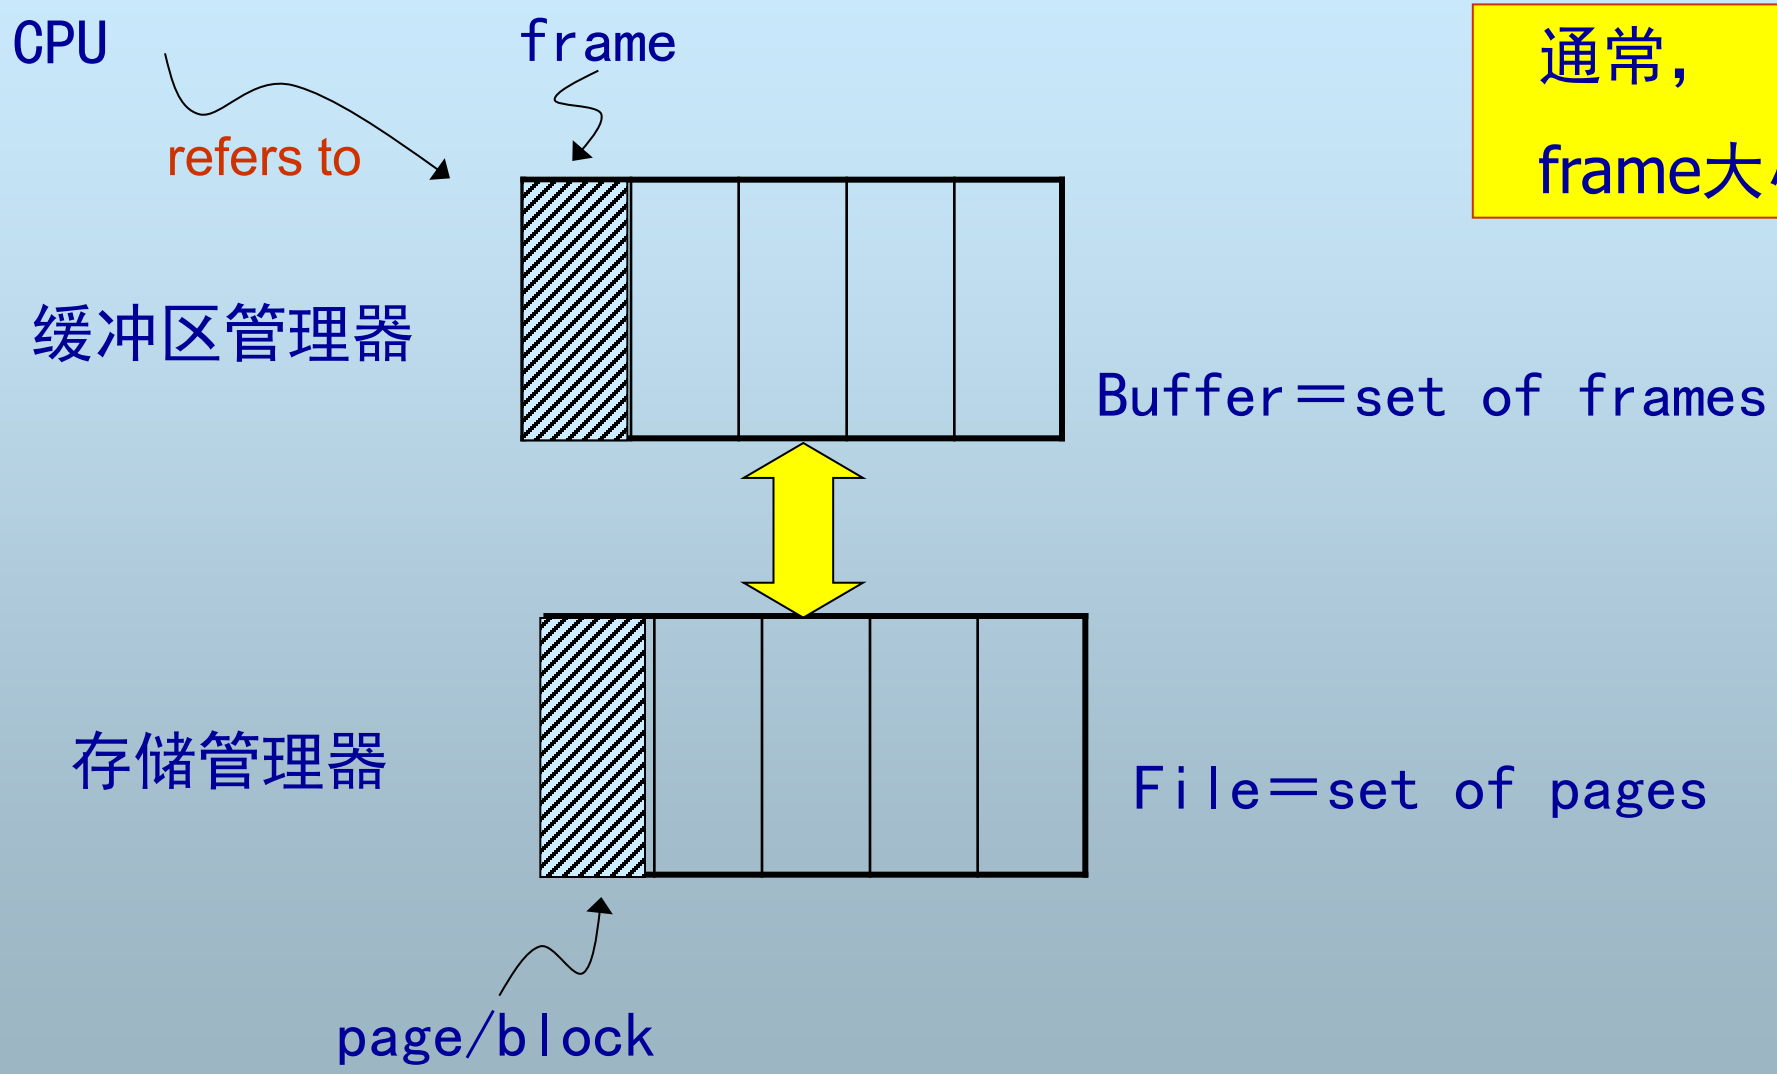

通常，

frame大小＝page大小

4、Buffer的存储结构

- **Buffer是一个frame的列表，每个frame用于表示和存放一个磁盘块**

Buffer的存储结构定义示例

```
#define FRAMESIZE  4096
struct bFrame
{
  Char field [FRAMESIZE ];
};
```

```
#define BUFSIZE  1024 // frame数目

bFrame buf[BUFSIZE];
//也可以是用户配置的值
```

5、Buffer中Frame的查找

- 读磁盘块时：根据page_id确定在Buffer中是否已经存在frame
- 写磁盘块时：要根据frame_id快速找到文件中对应的page_id

5、Buffer中Frame的查找

- 首先，要维护Buffer中所有frame的维护信息（Buffer Control Blocks），如

```
struct BCB
 {
  BCB();
  int page_id;
  int frame_id;
  int count;
  int time;
  /* int latch; */
  int dirty;
  BCB * next;
};
```

5、Buffer中Frame的查找

- 建立frame-page之间的索引
- 若用Hash Table，需要建立2个
  - BCB hTable[BufferSize] //page 2 frame
  - int hTable[BufferSize] //frame 2 page

一个简单的Hash Function例子

H(k)=(page_id)%(buffersize)

6、Buffer Manager的基本功能

- FixPage(int page_id)
  - 将对应page_id的page读入到buffer中。如果buffer已满，则需要选择换出的frame。
- FixNewPage()
  - 在插入数据时申请一个新page并将其放在buffer中
- SelectVictim()
  - 选择换出的frame_id
- FindFrame(int page_id)
  - 查找给定的page是否已经在某个frame中了
- SetDirty(int frame_id)

7、数据库文件的一般组成

- 数据文件
  - 首块在Insert_Record时创建（调用Buffer Manager的FixNewPage），一般块号从0开始
- 系统目录文件
  - 首块一般Create_Table时创建（调用Buffer Manager的FixNewPage）

Note:

所有数据和元数据操作都唯一通过Buffer Manager来请求page

8、文件记录操作与Buffer Manager

9、存储管理器

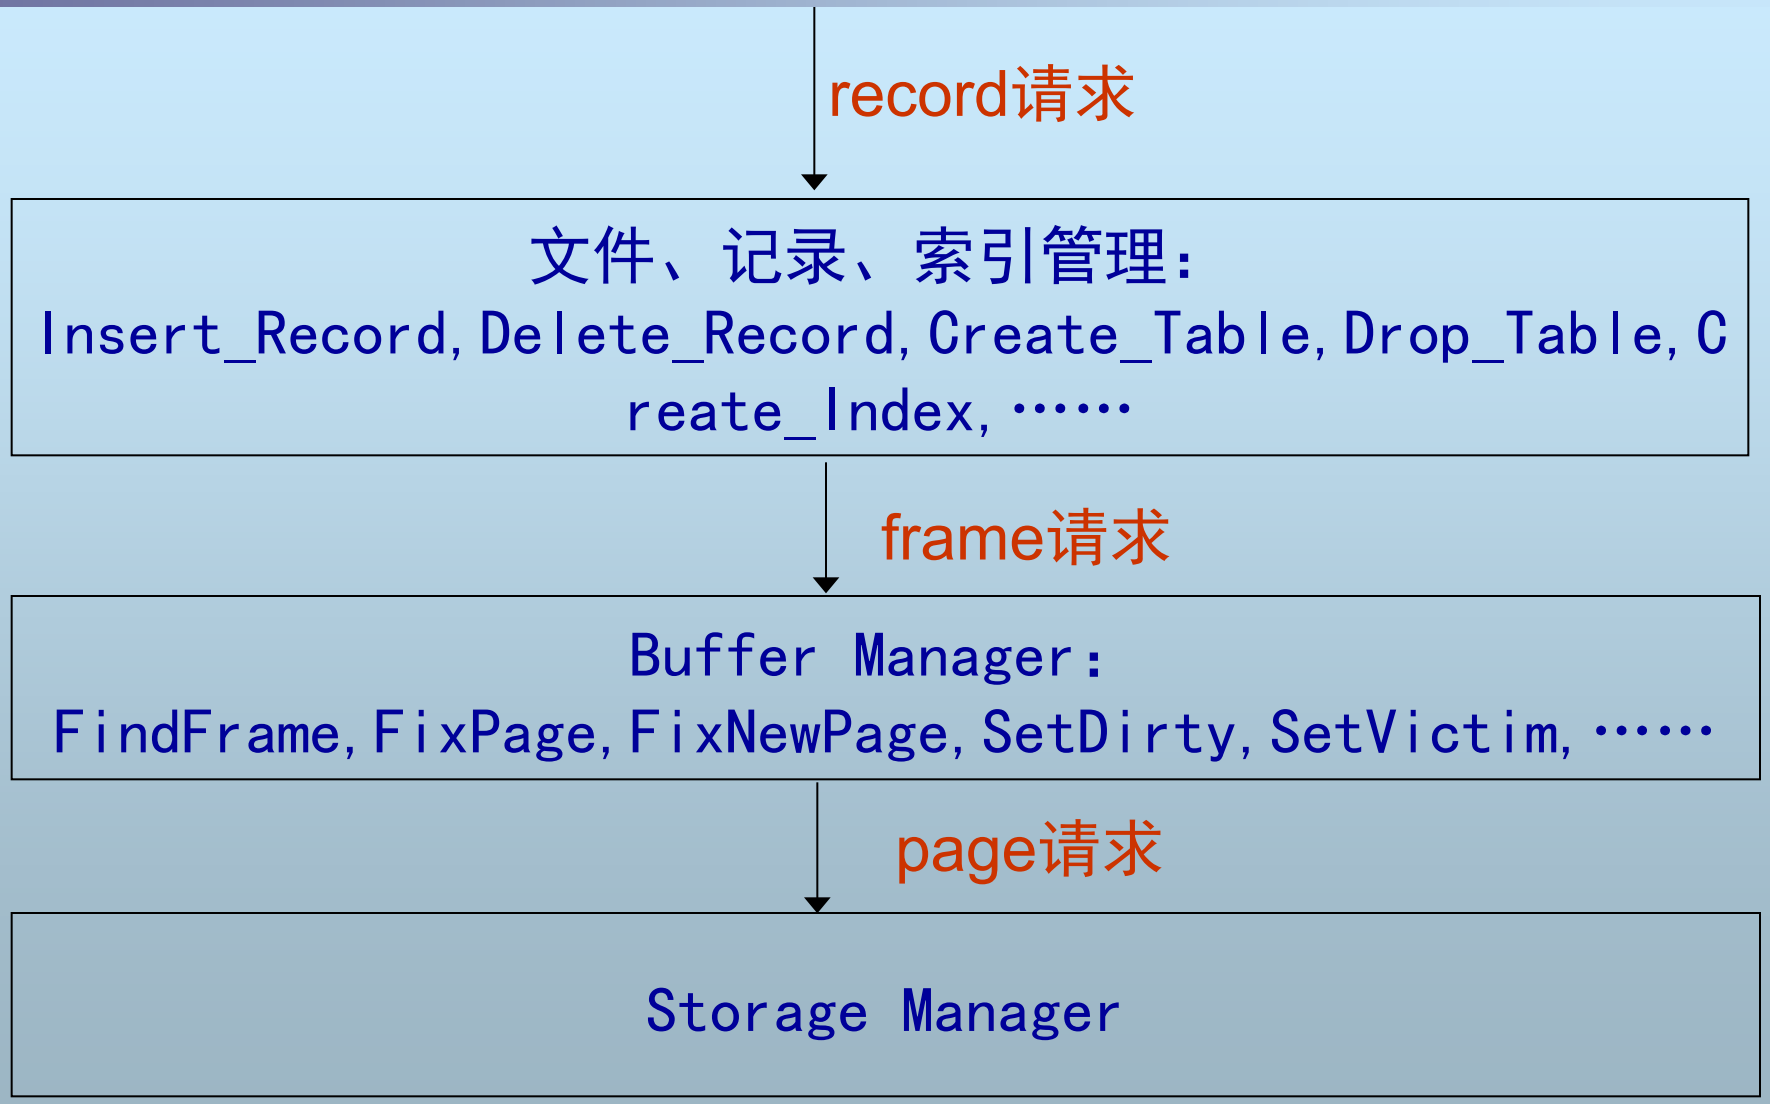
record请求
文件、记录、索引管理：
Insert_Record,Delete_Record,Create_Table,Drop_Table,C
reate_Index,……
frame请求
Buffer Manager：
FindFrame,FixPage,FixNewPage,SetDirty,SetVictim,……
page请求
Storage Manager

9、存储管理器

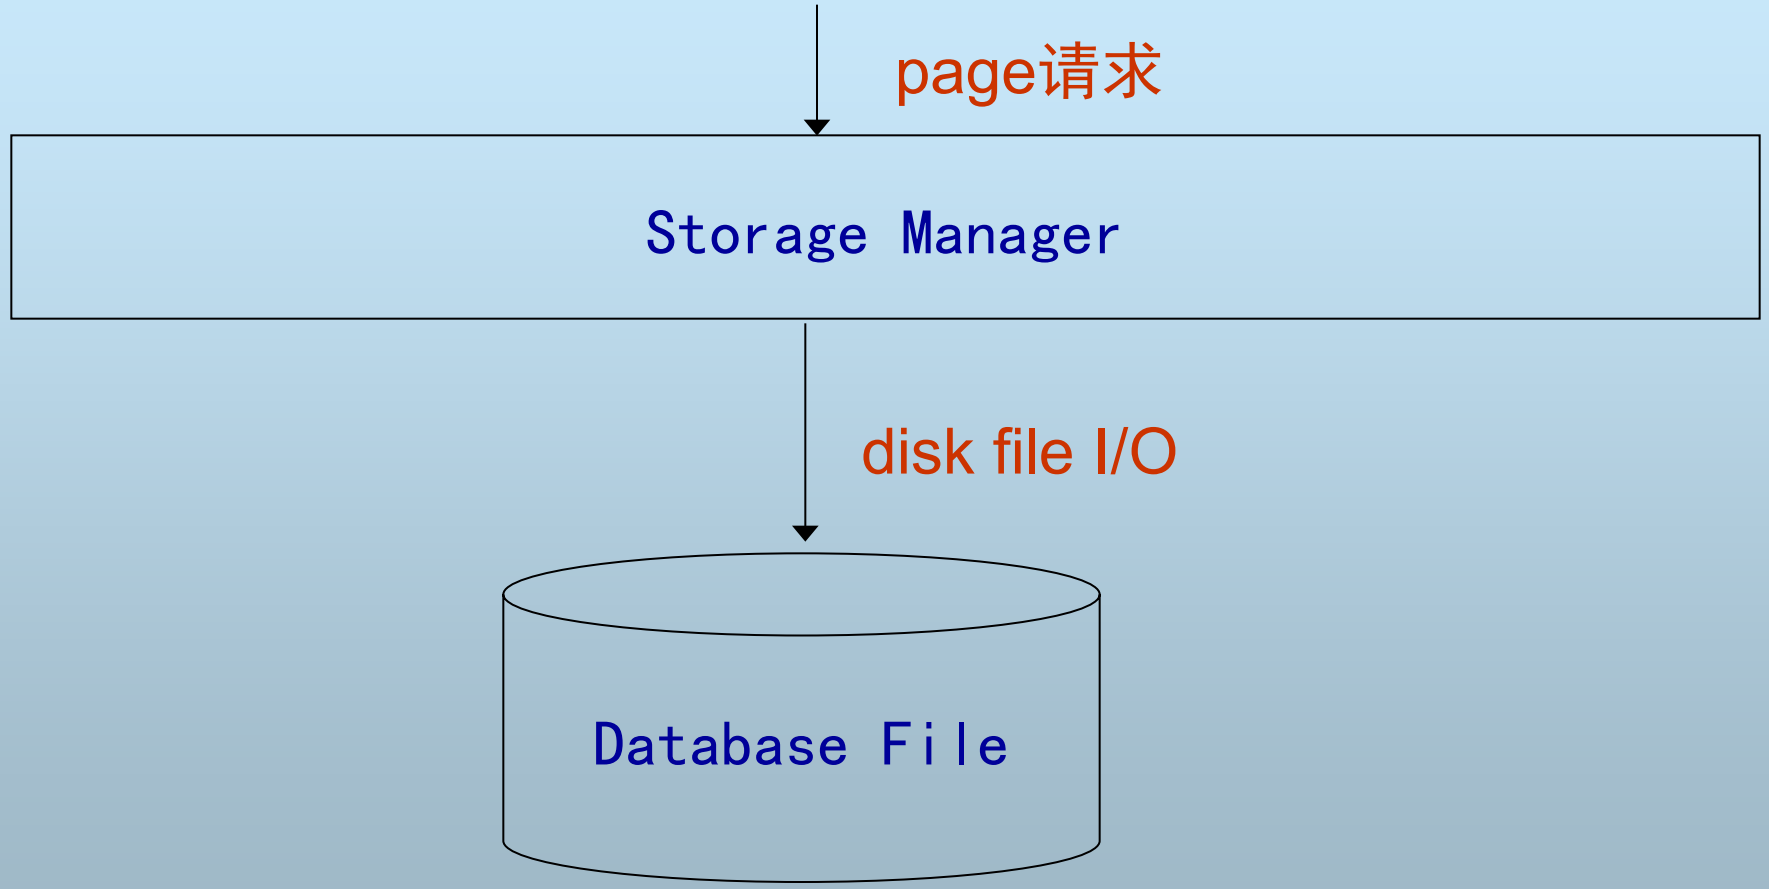

10、存储管理器功能

- 从磁盘读写物理数据，为Buffer Manager提供Page抽象
  - OpenFile/CloseFile
  - ReadPage/WritePage
  - FileSeek
  - GetNumPages
  - IncreaseNumPages
  - ……

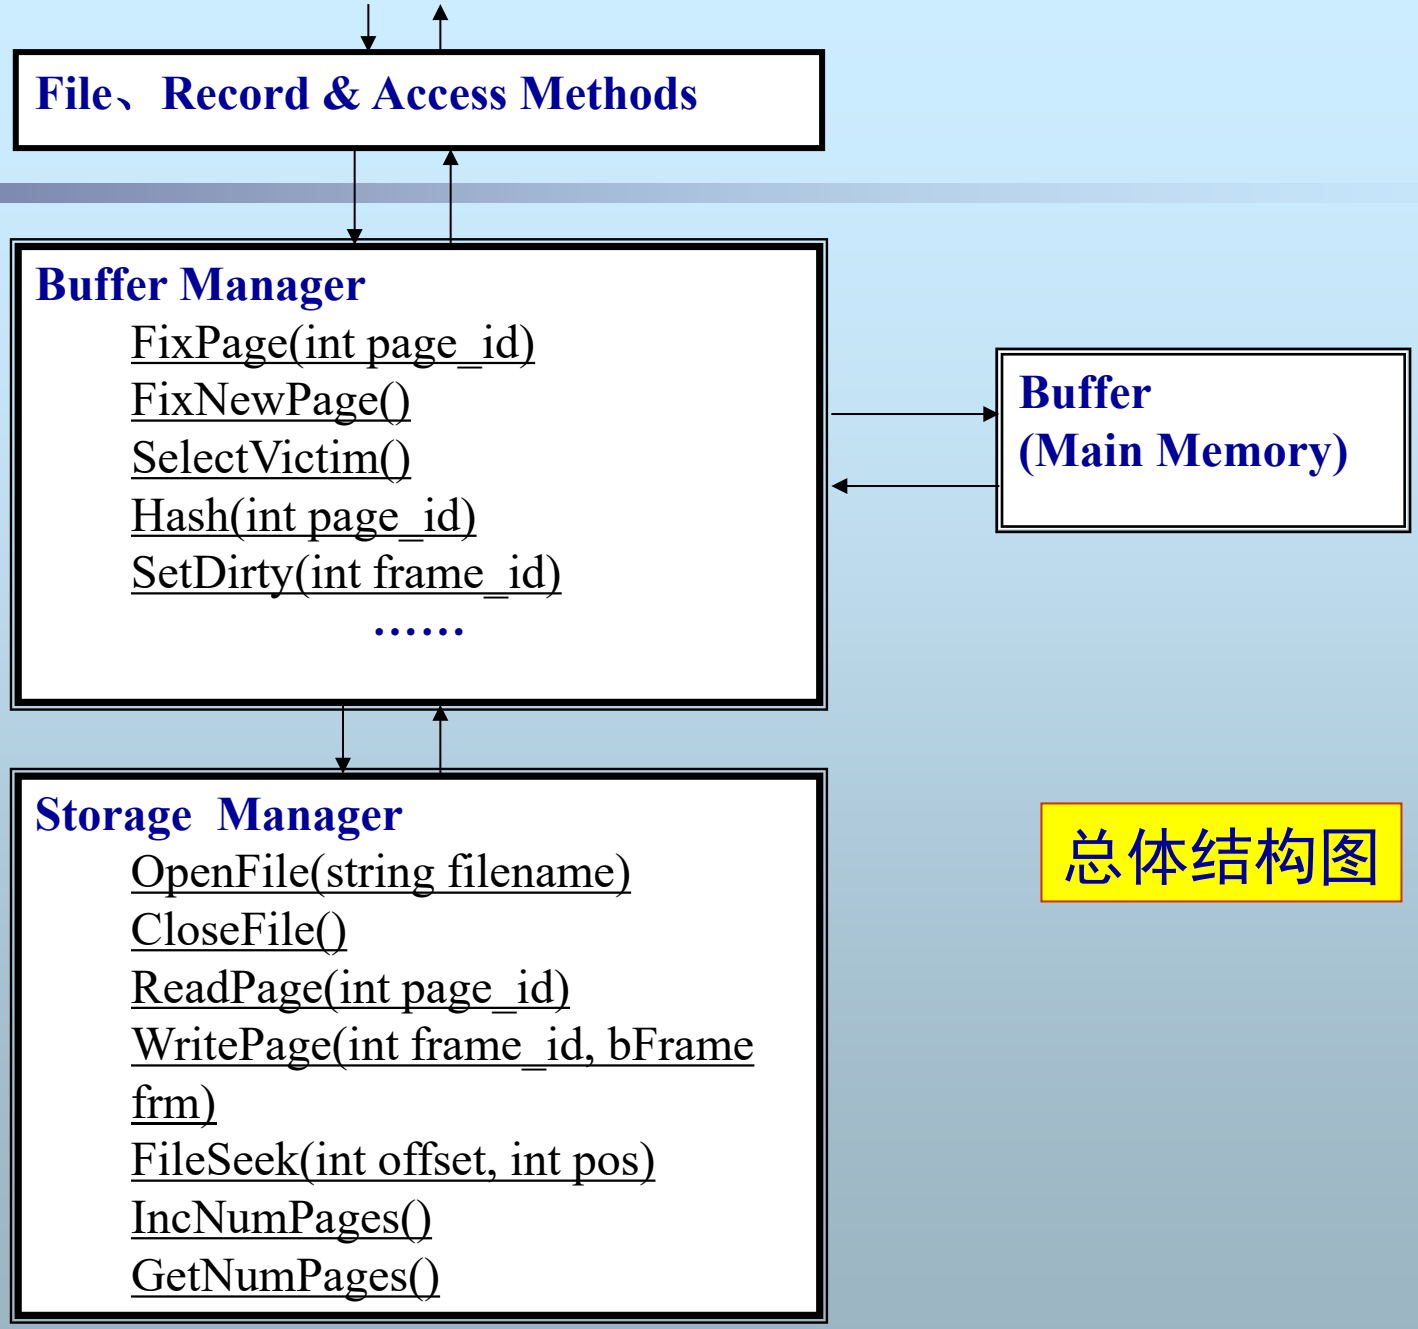
File、Record & Access Methods
Buffer Manager
FixPage(int page_id)
FixNewPage()
SelectVictim()
Hash(int page_id)
SetDirty(int frame_id)
……
Buffer
(Main Memory)
Storage Manager
OpenFile(string filename)
CloseFile()
ReadPage(int page_id)
WritePage(int frame_id, bFrame frm)
FileSeek(int offset, int pos)
IncNumPages()
GetNumPages()

总体结构图

总结

- 缓冲区结构
- 缓冲区置换算法
- 缓冲区管理的实现