


БАНКИ ДАННЫХ

Автор: Емельянов Н. Е

Правка: Тригуб Н.А.


4. Организация хранения и доступа (физический уровень)

4.1. Виртуальная память



Осуществляет вызов страниц с магнитных носителей в оперативную память. Реализует механизм виртуальной памяти.

Буфер ввода/вывода



Страница БД - 2–8 Кб

Пусть БД – 100 Гб = 50 млн. страниц

Буфер ввода/вывода – 1 Гб = 500 тыс. страниц

Для эффективной работы текущий рабочий комплект страниц должен помещаться в буфер. Cash память (Cash – наличные деньги в кармане).

Справочная буфера ввода/вывода

№ стр. в / в	Идент. Стр. в БД	Время посл. обращения	Ф л а г и		
			1	2	3
1					
2					
3					

Флаги : 1 – свободна ли страница,
2 – идет ли обмен,
3 – была ли запись.


4.2. Массивы и списки

4.2.1. Однородные массивы

Массив называется однородным, если длина и формат всех элементов одинаковы

Такие массивы замечательны тем, что легко определяется адрес любого элемента

Пример двумерного массива



Адрес $a_{ij} = \text{Адрес } a_{11} + ((i - 1)n + (j - 1)) d$

где d – длина элементов.

4.2.2. Неоднородные массивы

Массив называется неоднородным, если длина и формат элементов могут быть разными.

Пусть элементы a_1, \dots, a_n имеют описатели $\underline{a}_1, \dots, \underline{a}_n$

Тогда данные можно представить $(\underline{a}_1 a_1, \dots, \underline{a}_n a_n)$

Или $(n \underline{a}_1 \dots \underline{a}_n a_1 \dots a_n)$, если все описатели \underline{a}_i

одинаковой длины и содержат длину данного a_i

4.2.2. dbf - формат

Если нужно описать таблицу из m строк с

n атрибутами a_1, \dots, a_n в каждой строке, то в

dbf -формате это будет представлено так

$$n \quad m \quad \underbrace{a_1 \dots a_n}_n \quad (a_1 \dots a_n)_1 \dots (a_1 \dots a_n)_m$$

Такой формат применил Рэтлифф в СУБД dBASE,

которая быстро получила распространение, а

dbf-формат стал всемирным стандартом на ~ 20 лет.

4.2.3. Языки разметки

Стандарт ISO с 1996 г.

- SGML (*Standard Generalized Markup Language*)
- XML (*Extensible Markup Language*)
- HTML (*Hypertext Markup Language*)

SGML \supseteq XML \supseteq HTML

- HTML - стандарт для описания страниц в интернет
- В XML есть секция DTD (*Document Type Definition*), которая описывает структуру данных – аналог схемы БД
- В HTML заданный набор объектов, в XML можно создавать свои объекты

Общий стиль описания:

```
<имя объекта1>  
  <имя подоб1.1>  
    <имя данного 1> данное 1 </имя данного 1>  
    <имя данного 2> данное 2 </имя данного 2>  
    .....  
  </имя подоб1.1>  
  .....  
</имя объекта1>
```

4.3. Стеки, очереди, деки

Стек – список с включением и исключением на одном конце. Метод LIFO (Last In First Out)

Очередь – список, включение на одном конце, а исключение на другом. Метод FIFO (First In First Out)

Дек – включение и исключение на обоих концах, сокращение от Double Ended Que.

4.4. Корневые деревья

Дерево – это граф, у которого есть выделенная вершина – корень. Если его убрать, все остальные вершины распадутся на $m > 0$ поддеревьев

4.5. Графы

Граф – множество вершин, соединенных дугами (ребрами).

Графы задаются при помощи ссылок или матрицами

Матрица инцидентности

Матрица смежности

Р е б р а

В е р ш и н ы

Р
е
б
р
а


	1	2		n	1	2	
			В				
1	1	1/0	е	1	1/0	1	1/0
2	1/0	1	р	2	1/0	1/0	1
			ш				
			и				
			н				
			ы				
	1/0	1/0		1	1/0	1/0	1/0

Теорема Уитни. Матрицы инцидентности и смежности однозначно определяют граф, кроме одного случая.

Матрица инцидентности


Р е б р а

	1	2	3
Р е б р а	1	1	1
2	1	1	1
3	1	1	1




4.6. Сплетения

Сплетение – совокупность деревьев, связанных между собой ребрами.



4.6. Сплетения

Сплетение – совокупность деревьев, связанных между собой ребрами.



Раскрашенный граф –
выделенных иерархий

5. Индексирование. Поиск по ключу

Индекс – единственный способ быстрого доступа.

Построение индекса – предварительная обработка информации или online поддержка при вводе данных.

5.1. Плотный индекс

Используется для неоднородных и несортированных массивов.

Массив: Идентификатор 1, данное 1; Ид 2, дан 2;
Ид 3, дан 3; Ид n, дан n.

Плотный индекс: Ид 1, адрес 1; Ид 2, адр 2; Ид 3,
адр 3; Ид n, адр n.

5.1. Плотный индекс

Используется для неоднородных и несортированных массивов.

Массив: Идентификатор 1, данное 1; Ид 2, дан 2; Ид 3, дан 3; Ид n, дан n.

Плотный индекс: Ид 1, адрес 1; Ид 2, адр 2; Ид 3, адр 3; Ид n, адр n.

Плотный индекс – однородный массив, который можно отсортировать и потом искать делением пополам.

5.2. Разреженный индекс

Используется для сортированных массивов.

Массив:

Ид 1^1 , дан 1^1 ; Ид 2^1 , дан 2^1 ; Ид n^1 , дан n^1

Страница 1

.....

Ид 1^N , дан 1^N ; Ид 2^N , дан 2^N ; Ид n^N , дан n^N

Страница N

Индекс:

Ид 1^1 , адрес стр 1; Ид 1^2 , адрес стр 2; Ид 1^N , адрес стр N


В индекс помещаются Идентификаторы первых данных всех страниц.

Область переполнения

Если при наполнении массива новое данное Ид k^i , дан k^i не помещается на страницу i , то заводится новая страница и часть страницы переносится в новую (область переполнения).

Ид 1^i , дан 1^i ; Ид k^i , дан k^i ; Ид n^i , дан n^i

Страница i



Ид 1^i , дан 1^i ; Ид k^i , дан k^i ;

Страница i

Ид $(k+1)^i$, дан $(k+1)^i$; Ид n^i , дан n^i

Страница $N+m$ (область переполнения страницы i)

Область переполнения


И на странице i заводится ссылка на область ее переполнения.

Ид 1^i , дан 1^i ; Ид k^i , дан k^i ; Адрес Страницы $N+m$


Страница i

Ид $(k+1)^i$, дан $(k+1)^i$; Ид n^i , дан n^i

Страница $N+m$ (область переполнения страницы i)



5.3. В – дерево



При записи данного x
в В – дерево проверяем,
если $x < a_1$ – *налево*
 $x \geq a_1$ – *направо*,
и так во всех узлах

Обозначим

N – общее количество данных

l – количество данных на одной странице

k – глубина дерева

Тогда

N/l – число страниц


$2^k \geq N/l$. Если ветви одной длины, то $k = \log_2 (N/l)$

Сбалансированные деревья

Определение. В – дерево называется сбалансированным по вертикали, если длины всех его ветвей отличаются не более чем на 1.

Тогда $k = \lceil \log_2 (N/l) \rceil + 1$. Это число необходимых сравнений, в больших массивах оно обычно равно числу обменов с внешней памятью.

Определение. Дерево называется сбалансированным по горизонтали, если все веера подчиненных вершин отличаются не более чем на 1, $|n - n^l| \leq 1$.



Если n -арное дерево сбалансировано по вертикали и горизонтали, то

$$k = \lceil \log_n (N/l) \rceil + 1$$

Поэтому вместо бинарных деревьев обычно используются n -арные деревья.

n - максимальное число ссылок на странице.

5.4. Хеширование

Хеш – функция

$F(\text{ключ}) = \text{идентификатор}$

Если из длинного ключа сделать короткий идентификатор, то возможна коллизия: $F(\text{ключ1}) = F(\text{ключ2})$

На странице, определяемой идентификатором, записываются

Ключ 1, дан 1; Ключ 2, дан 2; Ключ n, дан n и м. б.
ссылка на страницу переполнения

Сравнение методов индексирования

Метод	Число обменов	Плюсы	Минусы
Плотный индекс	Время обработки индекса + 1	Работа с несорт. и разнородными массивами	Медленно
Разреженный индекс	$N/(l*n) + 1$	Сравнительно быстро	Блоки переполнения
В – дерево	$[\log_n(N/l)] + 1$	Быстро	Поддержка балансировки
Хеш	1 обмен, < = 3 обмена	Самый быстрый	Нет упорядоченности

N – общее число данных

l – количество данных на одной странице

n – количество ключей на одной странице