

具体的な講義の項目

- イン트로ダクション
- データベースのモデル
- 関係データベース(関係代数、関係論理)
- 正規化
- 問い合わせ言語
- トランザクション処理
- データベースの内部構造
- データベースの問い合わせ処理
- その他(オブジェクト指向DB、アクティブDB等々)

2020/5/14

データベース (©横田)

177

本日の内容

- データの格納
 - 内部スキーマ
 - 磁気ディスク
 - ページの格納
 - レコードの構成
- 索引
 - Btree
 - ハッシング
 - スーパーインポーズドコード


2020/5/14

データベース (©横田)

178

データの格納

- 内部スキーマ
 - システムに依存して変る
- 記憶素子
 - 不揮発性(Non-Volatile)
 - システムが停止(電源を遮断)しても内容を記憶
 - Flash Memory、FeRAM(強誘電体メモリ)、MRAM、PRAM(相変化メモリ)
→ SCM (Storage Class Memory)
 - 記憶容量とコスト(bit 単価)
 - 記憶容量とコストおよび性能のピラミッド




2020/5/14

データベース (©横田)

磁気ディスク

- 不揮発性で記憶容量が大きい
- bit 単価が低い
- 磁気テープ(MT)に比べて性能面で優れる
 - セクタ単位のランダムアクセス
 - シーク時間と回転待ち時間(msオーダー)
 - セクタ内データの順アクセス(転送)



2020/5/14

データベース (©横田)

180

最初の磁気ディスク

□ RAMAC

- Random Access Method of Accounting and Control
- IBM製 (1957年)
- サイズ
 - 直径24インチ(61センチ)
 - アルミ板50枚
- 容量
 - 5 MB
- 記憶密度
 - 0.2 Kb/inch²

一般的なディスクの特性

- 回転速度: 3,000 rpm ~ 15,000 rpm
 - (平均待時間: 10ms ~ 2 ms)
- シーク時間: 0.3 ms (隣接)
~ 5 ms (最内←→最外)
- セクタのサイズ: 512B
- ディスクのサイズ: 3.5, 2.5, 1 inch
 - (昔は 14、10.5、8、5.25)
- シリンダ数: 6,000 ~ 10,000
- ディスク枚数: 1 ~ 9

ちょっと考えてみよう(9-1)

- 平均回転待ち時間2ms、平均シーク時間1msで、データ転送性能が10MB/s (512Bのデータに要する転送時間が0.05ms)の性能のHDDを想定します。
 - 512B毎にトラックが異なるセクタに4096Bのデータが蓄積されていた場合のアクセス時間を算出してみましょう。
 - 4096Bのデータを連続したセクタにデータが蓄積されていた場合のアクセス時間を算出してみましょう。


ページへの格納

- ページ: 論理的なアクセスの固まり
 - 普通 4KB [8 セクタ] 程度
 - (場合によって 512B ~ 1MB)
- ページ内のアクセス
 - スロット番号からオフセットを得る
 - 相対レコード番号: Tuple ID (TID) = Page# + Slot#
 - ページ内の有効利用
 - ヘッダ情報とデータを逆から詰める
 - でないとレコードのサイズが変わった時に有効利用不可

レコードサイズとページへの配置



□ レコードはSlot番号でアクセス: ヘッダを持つ

- ディスクページのサイズは一定
- 関係データベースのタプル長(レコード長)は変わる



ページの構成


次のスロットのアドレス




レコードの構成

□ 固定長フィールドと可変長フィールドに別けられる

- 属性の位置と物理的な位置は独立
- 固定長フィールドの情報(個数、長さ)は別に持つ



データの構造




索引(Index)

- 内容から格納場所を知ることによる高速アクセス
 - 書籍の最後にある索引を思い浮かべる
 - キーワードから書かれているページを示す
 - キーワードはソートされている
 - 索引がなければ全ページをアクセスする必要がある
 - 時間がかかる
 - 索引は、内容から TID を示す
 - TID により位置を特定(ページ番号とオフセット)


索引の構造

- 転置ファイル(Inverted File)／転置表(Inverted Table)
 - 内容からアドレスと言う意味で逆引き
 - cf. CAM (Content Addressable Memory)
 - 表はソートされ、バイナリサーチ: $\log(n)$
- 転置ファイルもディスクに格納される
 - 転置表自身のサーチコストを減らす
 - 木構造 → バランス木 → Btree (B 氏木)
 - ハッシング
- 多数のキーワードによる検索に対する索引
 - シグニチャードファイル

転置ファイル



転置リストと木構造



Btree

- Bayer によって 1970 年に提案された
 - Bayer's Tree (B 氏木)であって、Balanced Tree ではない
- 条件
 - どのノードの子の個数も $k+1$ 以上である。
 - ただし、根と葉はこの限りでない。
 - どのノードの子の個数も高々 $2k+1$ である。
 - 根は 2 以上の子を持つ。
 - ただし、根自身が葉である場合はこの限りでない。
 - 根から葉に至る経路の長さは、どの葉でも同じである。

2020/5/14

データベース (©横田)

193

Btreeの特徴

- 木のノードをページに対応
 - どの葉まで行くにも同じ回数のディスクアクセス
- ページの利用効率を規定
 - k レコードないし $2k$ レコードを含む
 - 利用効率が半分以下にはならない
- 上の条件を満たすために、木の高さが変わる
 - $2k$ を越えるとノードを分割し、中間の値を親のノードに入れる
 - 親のノードも再帰的に同じ処理をし、根まで行くと高さが増える


2020/5/14

データベース (©横田)

194

Btree の例 ($k = 2$ の場合)

- 簡単化のため、キーのみ示す。




2020/5/14

データベース (©横田)

195

Btree への挿入




2020/5/14

データベース (©横田)

196

Btree 挿入後のBtree



2020/5/14

データベース (©横田)

197

Btree の改良(1)

□ B* tree

- ノードの分割時、自分自身だけでなく、兄弟のノードを見る
- 兄弟がいっぱいになったら、親と2ノードの分($4K+1+1$)を3ノードと2つの親に分る
- 各ノードは $4k/3$ のレコードを含むから、効率は $2/3$ 以上

□ 二次索引

- レコードの代わりに TID を格納する

2020/5/14

データベース (©横田)

198

Btree の改良(2)

□ 実際のデータベースでは隣接するデータを連続してアクセスすることが多い

- Btreeでは上のノードまで戻る必要がある

□ B⁺tree


- データの順アクセスが可能なように改良
 - レコードは葉ノードのみに格納
 - 葉ノードの間をリンクで結合
- VSAM (Virtual Storage Access Method) : IBM

2020/5/14

データベース (©横田)

199

B⁺treeの例



2020/5/14

データベース (©横田)

200

ちょっと考えてみよう(9-2)

- 平均回転待ち時間2ms、平均シーク時間1msで、データ転送性能が10MB/s (512Bのデータに要する転送時間が0.05ms)の性能のHDDを想定します。
 - 高さ3のBtree (あるいはB+tree)の各ノードが512Bのセクタ格納されたとして、ルートから葉までたどる時間はどのくらいでしょうか
 - 実際は、ルート、ルート直下のノードはメモリ上に置かれるので、もっと高速にアクセスされます。

2020/5/14

データベース (©横田)

201

ハッシング (Hashing)


- 格納時と検索時に同じハッシュ関数を用いることで、アクセス先を特定
 - ハッシュ表をつくり、TID等の情報を格納
 - ハッシュ関数の例
 - $h(X) = X \bmod n$: n はハッシュ表のサイズ
 - X を m 乗したもののビット列の適当な $\log_2(n)$ ビットを使う
 - フォールディング(畳み込み)
 - 衝突(Hash Collision)が発生しない限りは検索コストは $O(1)$
 - 衝突の対処
 - リストで TID をつなげる / 空いてるハッシュエントリーを使う
 - bitmap を使う
 - 拡張ハッシュ (Extendible Hash)

2020/5/14

データベース (©横田)

202

ハッシングのイメージ



2020/5/14

データベース (©横田)

203


拡張ハッシュ(1)

- ハッシュ表のサイズを動的に変化させる(拡張)
 - 2のべき乗で変化(bit 数に対応) (リニアハッシュもある)
 - Depth : ハッシュ値の何 bit 見るかを示す
 - Global Depth と Local Depth の差を d とすると 2^d 分の矢印が集まる

例:

目黒区 1001
渋谷区 0100
新宿区 0011
江東区 1101
品川区 0101

ビット列のLSBもしくはMSBから




2020/5/14

データベース (©横田)

204


拡張ハッシュ(1')



ちょっと考えてみよう(9-3)

- 次に来るデータが新宿区と同じブロックに入るとすると、そのデータに対するハッシュ値はどのような値が想定されるでしょう。

拡張ハッシュ(2)



- 長所: 衝突は発生しない
- 短所: コピーのコストが問題

スーパーインポーズドコードによる索引

- テキストデータベースのキーワード検索等に使われる

キーワード	シグニチャ
目黒区	00010001
渋谷区	01001000
新宿区	00000101
江東区	11000000
品川区	01100100

検索対象事に
シグニチャのORを取る


検索要求(AND)

渋谷区	01001000
新宿区	00000101

問い合わせシグニチャ

論理和 01001101

シグニチャファイル



2020/5/14

209

ちょっと考えてみよう(9-4)

- フォールスドロップを減らすにはどうするとよいでしょう。

2020/5/14

データベース (©横田)

210