コンピュータ概論B - ソフトウェアを中心に -

#13 データベース

Yutaka Yasuda

データベース

- 外見

  データを決まった形式（フォーマット）で整理し蓄積したもの

  レコード (Record) の存在

- 目的

  入力・更新

  高速な検索と再利用

蓄積のために

- 一元管理

  あちこちにあるデータを一元管理したい

  多数ユーザに最新で正しいデータを提供する

- 共有

  多くのユーザで参照、更新したい

  一元管理とセットで現れる問題

  クライアント・サーバモデル (p.172 図10.3)

一元管理と共有の間で

- データと処理プログラムの独立性の確保
  項目が一つ増えたらプログラム全部修正？
- 整合性の確保
  複数箇所に同じ値がある
  学費データと履修データの両方に在籍情報がある
  多数利用者の同時更新から生まれる矛盾抑制
- データの保全
  プログラムの中断やシステムダウンからの保護
- アクセス制限
  複数利用者が前提
- 簡易な問い合わせ言語機能の利用

DBMS

- 前出の機能をどうやって実現するか？
- データをプログラムが直接扱えないようにする
  - DBMS の登場

    Database Management System
- 全ての作業はDBMSというプログラムを経由する
- 独立性、整合性、保全、アクセス制限

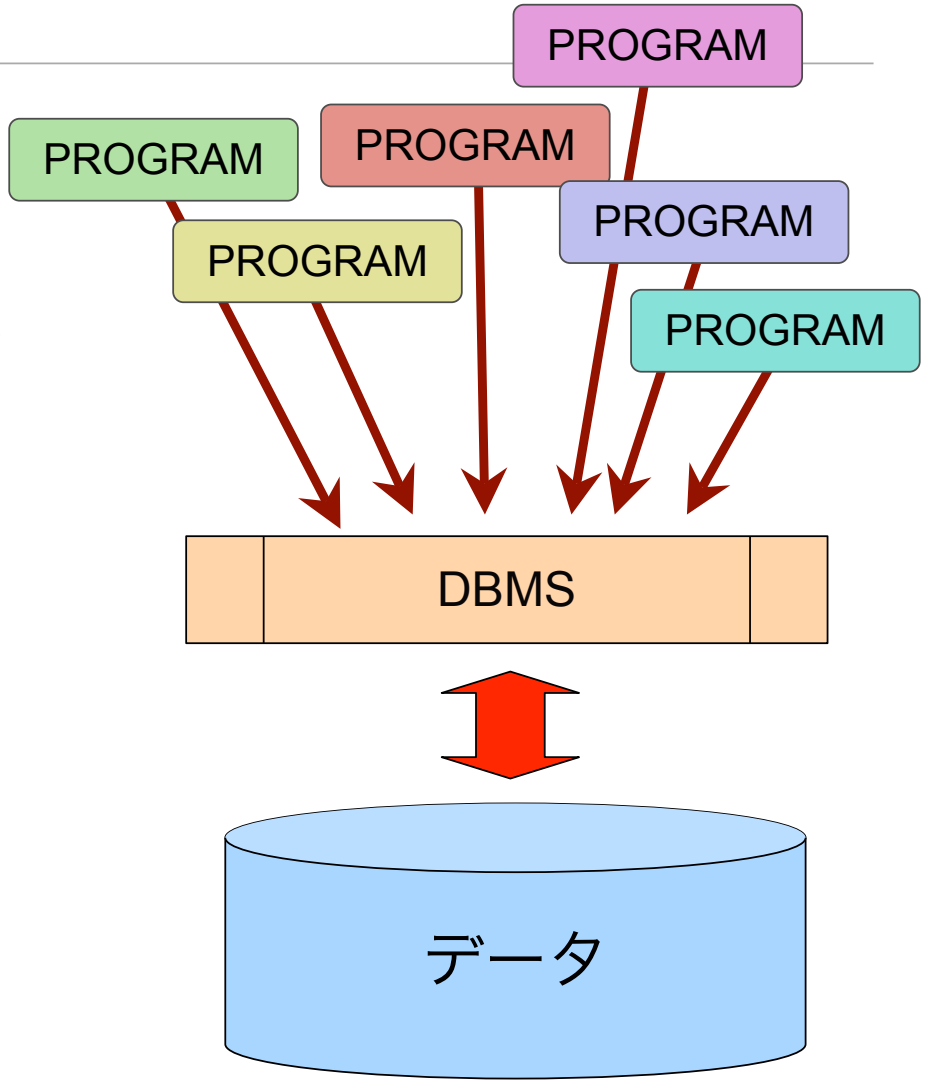

独立性・整合性

- 独立性

  データのフォーマットはDBMSに定義・管理

  処理プログラムはその定義を引用して動作する

- 整合性

  処理プログラムの手続きはすべてDBMSに対する指示として実行される

  DBMS は実行時にデータの正当性管理、アクセス制限管理、排他制御(後述)、データ保全(後述)などを行う

排他制御

例：

あるデータをカウントアップする

- 「読んで」「足して」「書く」

複数の処理リクエストが来た場合、
正しくカウントアップできない

- OK ：読・足・書・読・足・書
- NG ：読・読・足・足・書・書

- 排他制御

  「この処理が終わるまで、
  この資源はロック」

  デッドロックに注意

  DBMSではロールバックの
  必要性につながる

  DBMSに限らず多用されて
  いる

データ保全

- 処理プログラムの中断

  バグ、オペレーションミス、システムダウン

- 一貫性（整合性）の保持

  更新処理途中での停止

  会員資格更新時に会員番号 100 までで止まった

  会員マスターは更新したが支払いデータは未更新

  作業しなかったか、完了したかのどちらかに確定しないといけない

- トランザクションとロールバック

トランザクション

- データの整合性を保つために必要な最小の一連処理

  その途中で終了した場合、データに矛盾が生じる

  大量データの削除処理などもそう

  プログラマにしかトランザクションの存在が分からないケースもある

  明示的なトランザクションもある

- ロールバック

  トランザクションを完了できなかった場合、トランザクション前の状態に巻き戻す

バックアップ・レストア

- DBMS自体の不意の中断
  - バグ、オペレーションミス、システムダウン
  - それでも一貫性を保持しなければならない
  - あるポイントでバックアップを取る
  - そこからは記録された更新情報を元に再現
- ログ管理
  - 更新記録(Log)をトランザクション単位で記録
  - レストアでは最終バックアップから更新作業を再現
  - ログが溢れたらDBMS自体が停止してデータを保護

DBMS のまとめ

- データベースが守るべき要件

  データ独立、整合性管理、データ保全、アクセス管理

  多くはマルチプログラミングからの保護

  排他制御

  バックアップ・レストア、ログ管理

- いずれも一貫性保持のため

  そのためにプログラムとデータの間にDBMSという「仲介人」を入れる

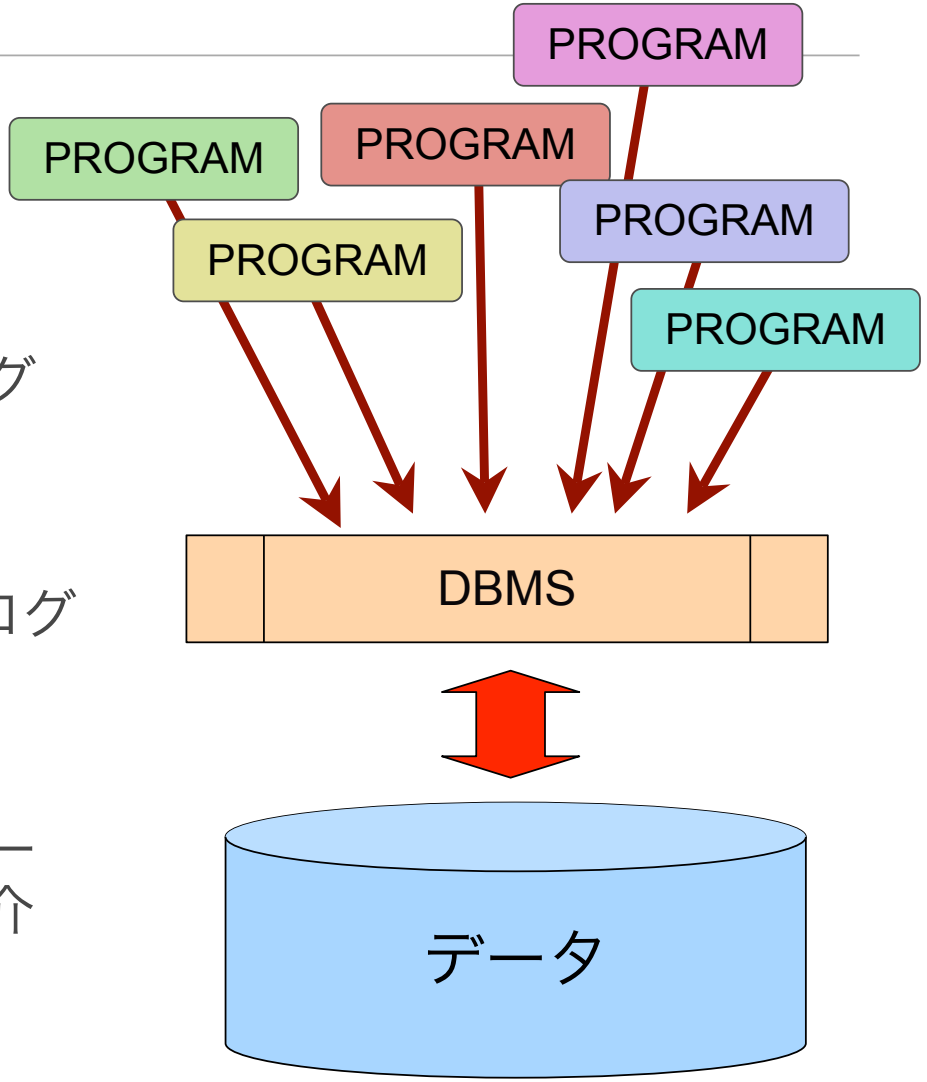

データベースの種類

- データモデルに適したタイプ
- カード型

  図書館蔵書カードのような一件一枚のもの
- ネットワーク(型)データベース

  データの親子関係に注目
- リレーショナル(型)データベース (Relational Database)

  データの関係 (relation) に注目

  現在もっとも良く使われている
- 学生情報データベースを考える

カード型による学生情報データベース

- 一人一件
- 利点

  全ての情報がカードの中にあるのでカードを見つけられればあとの処理が簡単
- 欠点

  柔軟な検索が出来ない

  キー以外の検索は一枚一枚繰ることに？

  通常はキーでソートして検索を容易にする

  インデックス（複数）の利用

探索法

- より高速な検索のために

  高速とは？

  CPU処理量(計算量)が少ない

  ディスクアクセス量が少ない

- 多様な探索手法の存在

  シーケンシャルアクセスとソート、二分探索

  ランダムアクセスとハッシュ、インデクシング

シーケンシャルな探索

- 順次当たる方法 sequential

  単純総当たり：図書カードをキーワードで繰る

- ソート sort

  図書カードをタイトル順で並べておく

  妥当なところまでスキップ（調べるより送るだけの方がCPU処理量が少ない場合に有効）

- シーケンシャルアクセスでは

  何か一通りの方法でのみソート可能

  タイトル順ソートのカードを作者で調べる時は総当たり

ランダムアクセスを利用した探索

- 二分探索 binary search

  sortされているカードの真ん中位置をまずアクセス

  キーの大小から判断して、上下いずれのブロックに含まれるかを判定

  該当ブロックの中央を次にアクセス
- 利点：高速な検索 (log N)
- 欠点：順列のある場合だけ検索可能

  文字列部分マッチなどには使えない

  ランダムアクセス可能なデバイス必須

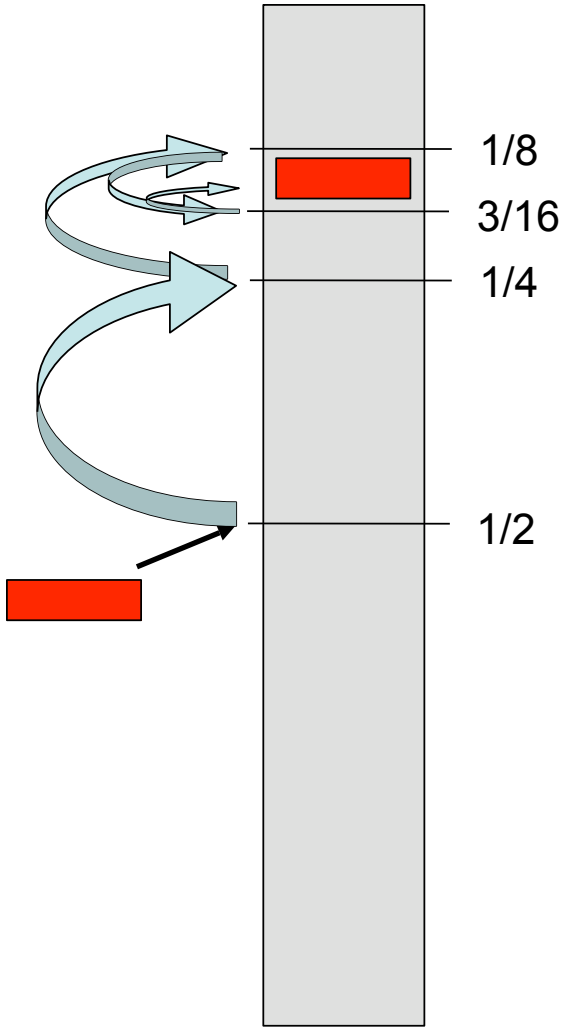

ランダムアクセスを利用した検索

- ハッシュ法 (hash)
  - キーワードなどから何らかの数値を計算
  - 十分に拡散し、衝突が少なくなるように良い計算式を選ぶ（定式なし）
- 利点
  - うまくするとワンクッションだけでヒット
- 欠点
  - 重なったときの処理が面倒
  - ヒット率が入力データと計算式の相性に依存
  - データ領域の充填率が低い
  - 空きが問題でないことが前提

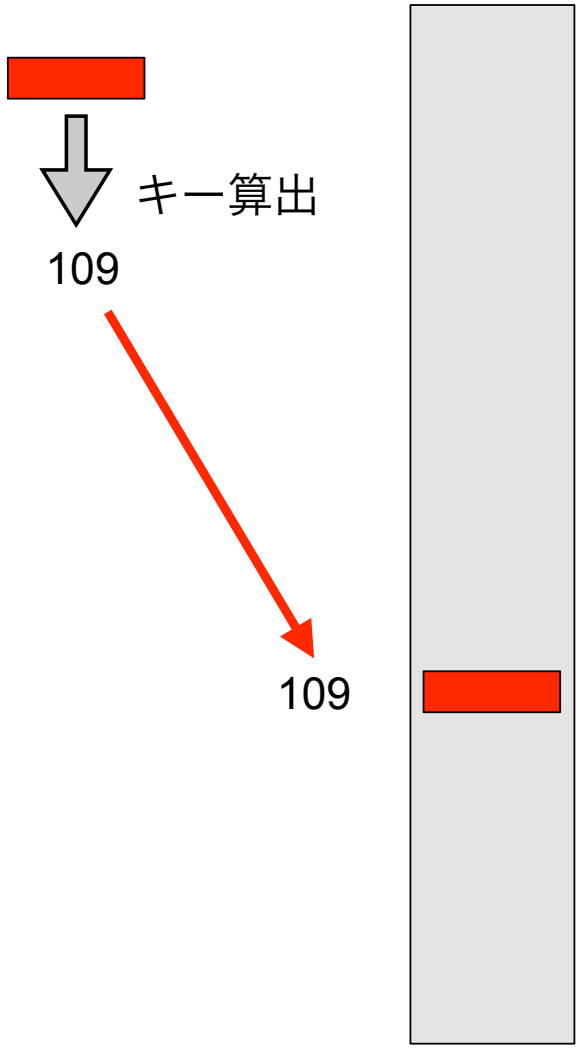

ランダムアクセスを利用した検索

- インデクシング (indexing, 索引)
  - 直接データを検索せずに
  - 検索に必要なデータだけをまとめた index を検索
  - そこにデータ位置が書かれている
- 利点
  - 複数のインデックスを持てる（名前順、学生番号順）
  - データの特性に依らず一般的に有効
- 欠点
  - インデックス作成が遅い（場合がある）
  - 追加より検索が圧倒的に多い場合に事前努力をする方式

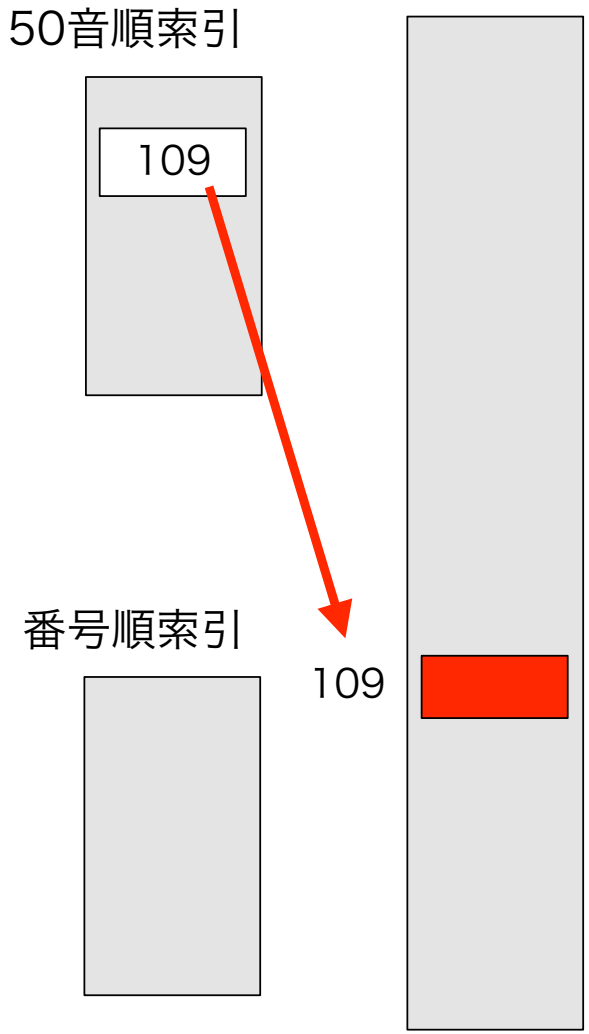

ここまでのまとめ

- データベースの目的
  仲介人としてのDBMSの果たす役割
  データ保護、一貫性の維持
- データベースの種類
  カード型、etc. etc.
- 探索手法
  高速な探索のための手法
  二分探索、インデクシング、ハッシュ
  データベース＝一群の目的のための工夫の集積体
- 用語
  専門用語が多いので注意