

コンテナからデータベースへ

組み込みシステムにおける 大容量データの管理技法

街谷 君次

プログラミングにおいて、データの扱いは重要である。適切なアルゴリズムを選択することによって性能が向上し、フットプリントも小さくなる。ここではデータを扱う基本的な手法として、初めにコンテナについて解説する。続いてコンテナよりも強力であるデータベースについて述べる。
(編集部)

1 アルゴリズム+データ構造=プログラム

● データ構造が重要

「アルゴリズム+データ構造=プログラム」ということばがあります。これは N. Wirth の古典的名著“ Algorithms + Data Structures = Programs ”のタイトルからきたことばですが、まさにプログラムの本質を的確に突いているといえるでしょう^{注1}。

プログラムを書いていて感じるのは、「結局、プログラムというのは、入力されたデータを演算して出力する、という単純な機械」ということです。それゆえ、データ構造をどのように定義し、それをどのようなアルゴリズムで処理するのか、といった面に注力することになります。

● どのようにデータをもつか

プログラミングにおいてデータを保持する手法にはいろいろなものがあります。本誌の読者になじみの深い C 言語を前提に考えてみると、データは変数にもたせ、それをまとめた構造体として保持するのが一般的でしょう(リスト1)。

リスト1の構造体をつつ確保しただけでは、一つの情報しか保持することができません。そこで複数の構造体を管理する必

リスト1 構造体

```
/* ディレクトリ情報 */
typedef struct {
    FILELIST *filelist_ptr;
    FILELIST *filelist_top;
    FILELIST *filelist_end;
    FILELIST *disp_top_ptr;
    FILELIST *cursor_ptr;
    char dirpath[256];
    char hostname[48];
    char local;
    char parent;
    int count;
} DIRINFO;
```

要性が生じます。そのような場合、どのような方法を使えば良いのか——これが本特集のテーマです。

2 C 言語レベルのコンテナを使ったデータ管理

● 「コンテナ=データの入れもの」という概念

コンテナということばは、輸送用の箱からきたことばです。プログラミングにおいては、たとえば配列やリスト、二分木、スタックなど、実例を挙げれば「ああ、そのあたりのことね」と納得していただけるかと思います。

復習のために、ここではコンテナについて説明します。

● 配列

図1(a)の配列は、固定長のデータを複数もつためのデータ構造です。それぞれのデータには、インデックス(たとえば $a[i]$ の i)を用いてアクセスすることができます。このアクセスはつねに同じ速度で行える $O(1)$ のアルゴリズムです。最悪値(この場合、データ・アクセスにかかる時間のうち、いちばん遅い場合の時間)の保証も可能なので、リアルタイム処理にはうってつけです。

配列の欠点は、「配列の数を動的に変更できない(ことが多い)」点です。最大 N 個の構造体を管理したい場合、最初に N 個ぶんのデータを確保する必要があります。これは、実際には1個しか使っていない場合でも、最大量のデータを確保する必要があることを意味し、たいへんむだです。そこで現在では、「動的配列」という、最大数を可変にできるものがあります。動的配列はプログラミング言語の Perl などにも実装されています。

動的配列の中身は(実装にもよるが)おそらくリストで、それを配列のように見せかけています。そのため最悪値を保証できるかどうかは、その実装で使われているアルゴリズムを精査し

注1: 筆者としては、これに「インターフェース」ということばを付け加えたいところだが、原著自体が1976年発行ということもあり、さすがにインターフェースの設計が重要というところまではいってなかったのだろう。



イラスト1 さまざまなコンテナ




図1 コンテナの数々

なければなりません。まあ、最悪値が気にならない用途であれば、動的配列は便利に使えるコンテナでしょう。

● キュー

キューは、図1(b)のようないわゆる片方向リストです。または、単にリストとも呼びます。データを末尾にどんどん追加し、いちばん先頭から取り出していくという形式です。組み込み技術者には「バッファ」と言ったほうがすぐにわかるでしょう。FIFO (First In First Out) ともいいます。

これの利点は、つねに同じ速度でデータの追加・取り出しが可能であることです。また、欠点は基本的にデータの追加は末尾からしか行えず、データの取り出しも先頭からしか行えないということです。C言語においては、データの結び付き(図1(b)の矢印)はポインタによって行います。実装するうえでは、動的なメモリ確保/解放(いわゆる `malloc()`/`free()`)が必要になります。

● 双方向リスト

双方向リストは、図1(c)のように矢印が両方向についたリストです。任意の位置に対してデータの追加・削除が可能で、データの最大数にも制限はありません(メモリ容量の許す限り管理できる)。主流といえるコンテナでしょう。

欠点は、任意のデータを検索して取り出すために、リストの先頭から一つずつ検索する必要があるということです。そのため、データ数が多くなればなるほど、検索速度は低下します。みなさんの近くにも、たくさんのデータを入れると処理が遅くなる機器はないでしょうか。このようなときプログラマは、「はーん、データをリストでもっているな」と推測するものです。

● スタック

スタックは、図1(d)のように先頭にデータを入れ、先頭からデータを取り出す方式です。LIFO (Last In First Out) ともいいます。

余談ですが、物だらけの汚い部屋を指して FINO (First In