

目次

- 探索
- scanf の戻り値

★7 探索

この授業の「前半（高橋担当分）の後半」では、「郵便番号簿の探索」をするプログラムの作成を目指す。

★7.1 探索とは

探索（または検索）とは、データ集合の中からデータを探し出す処理のことである。例えば、電話番号と氏名を組にした表の中から、1234567 という電話番号に一致するものを探し出す（一致するものが存在しなければそう知らせる）、というようなことを実現するために必要となる。この例の 1234567 のような、探索の条件となる値のことをキーと言う。

郵便番号データの例

6148062	京都府八幡市八幡清水井
3500263	埼玉県坂戸市堀込
9518142	新潟県新潟市関屋大川前
9401103	新潟県長岡市曲新町
5200533	滋賀県滋賀郡志賀町小野朝日
5190438	三重県度会郡玉城町原
5220353	滋賀県犬上郡多賀町月之木
1057219	東京都港区東新橋汐留メディアタワー（19 階）
:	:

探索プログラムの動作例

121667 件の郵便番号データを読み込みました	
7 桁の郵便番号を入力して下さい (0 で終了)	5202123
[20409] 5202123 滋賀県大津市瀬田大江町	
7 桁の郵便番号を入力して下さい (0 で終了)	0010010
[49628] 0010010 北海道札幌市北区北十条西 (1~4 丁目)	
7 桁の郵便番号を入力して下さい (0 で終了)	9998525
[36801] 9998525 山形県飽海郡遊佐町直世	
7 桁の郵便番号を入力して下さい (0 で終了)	1234567
見つかりませんでした	
7 桁の郵便番号を入力して下さい (0 で終了)	0

探索のやり方としては、「キーの値を区間で指定する」(☆1) などの場合も考えられるが、この授業では単純に「キーと一致するデータを探す」場合のみを考える。また、簡単のためキーと一致するデータは二つ以上は存在しない（もしくは一致するデータが二つ以上複数あっても一つ見つけたら探索を打ち切る）ものとする。

☆1) 例えばキー値が 25 以上 35 未満など

探索の手法は、データの格納にどのようなデータ構造を用いるかによって大まかに二つに分類できる (☆2)。

- 単純に配列を用いるもの 線形探索，二分探索
- データ構造を工夫するもの 二分探索木や連結リストを用いる方法

☆2) 二分探索やハッシュ法といったアルゴリズムについてや、二分探索木や連結リストといったデータ構造については、この授業では解説しない。興味のある人は関係の授業や書籍等で学んでね。

また、データ構造が単純な配列であるか否かとは独立に、データの格納の仕方を工夫して探索の効率を上げる手法として、ハッシュ法と呼ばれるものもある。実際にデータ探索を行うプログラムを作る際には、データの追加・削除の有無、とにかく探索が速ければよいのか他の処理もできる必要があるのか、などを考慮してデータ構造や手法を選ぶことになる。しかし、この授業ではその辺りのことは省略し、自分でプログラムを作成してみるのには、最も単純な探索手法である線形探索のみとする。

★ 7.2 線形探索

線形探索 (☆3) は、データを順番にチェックしていくだけの、最も単純な探索手法である。前述の二分探索やハッシュ法といったアルゴリズムと比べれば探索にかかる計算コストが大きい（ので時間がかかる）けれど、非常に単純なプログラムで実現することができる。

例えば、次のように `int` 型の配列 `x` の先頭から順に `n = 6` 個のデータが格納されている場合を考えてみよう。このとき、線形探索では、単純に配列の先頭から順にキーに一致するデータがないか探していく。

(1) キー 901334 を探索

(2) キー 901234 を探索

i	x[i]
0	901051
1	901002
2	901359
3	901334
4	900555
5	901000
6	
:	

線形探索では、データ数 n に対して、探索成功（キーと一致する値が配列中にあった）の場合、キーと配列の要素との比較を平均 $n/2$ 回（最小 1 回，最大 n 回）行うことになる。一方、探索失敗（キーと一致する値がない）の場合、キーと一致する要素が配列中に存在しないことを確定させるためには配列中の全ての要素との比較（すなわち n 回の比較）が必要となる。したがって、探索に必要な比較回数は、成功の場合も失敗の場合も $O(n)$ ということになる (☆4)。

☆3) 線形探索: linear search, sequential search, 順探索, 逐次探索とも言う。

☆4) [発展] アルゴリズムやデータ構造について学ぶとわかるかもしれない話。データ数 n のときの線形探索の時間計算量が $O(n)$ であるのに対して、二分探索のそれは $O(\log n)$ である。また、ハッシュ法は、「探索に関する時間計算量がデータ数によらない」という興味深い性質をもっている。ただし、いずれの手法にも線形探索と比較して劣っている所もあるので、実用的に線形探索を用いることもある。

補足: scanf の戻り値

いつもお世話になっている関数 `scanf` は、実は整数値を返すように定義されている (☆5)。この戻り値は、

☆5) `fscanf` 等も同様

「`scanf` の引数に指定された書式に従って入力を解釈してみた結果、

」

を表す。例えば、

```
int x, y, rv;
rv = scanf("%d %d", &x, &y);
```

というプログラム (の一部) 実行した場合、「123 -5」というキー入力を与えた
 とすると、変数 `rv` の値は 2 になる。一方、「123 abc」だと `rv` は 1 になる。また、「hoge -5」だと 0 になる。前者の場合、変数 `x` の方には正しく読み込んだ値 (123) が代入される。この性質を利用すると、次のように、入力データの件数をプログラム自身に数えさせることができる。このプログラムでは、浮動小数点数と整数の組を受け取れなかった時点または配列がいっぱいになった時点で入力の繰り返しを終了するようになっている。

☆6) ファイルの終わりに達したなどの理由で入力エラーが発生した場合、EOF が返される (EOF は `stdio.h` で定義された定数)。

scanftest.c	実行例
<pre>1 #include <stdio.h> 2 3 #define N 100 4 5 int main(void) 6 { 7 double x[N]; 8 int y[N], i, n, rv; 9 10 for(n = 0; n < N; n++){ 11 rv = scanf("%lf %d", &x[n], &y[n]); 12 if(rv != 2) break; 13 } 14 printf("%d 件読み込んだで\n", n); 15 for(i = 0; i < n; i++){ 16 printf("[%d] %f %d\n", i, x[i], y[i]); 17 } 18 return 0; 19 }</pre>	<pre>\$./scanftest 1.23 456 7 890 0.1 1026 3.14 hoge 3 件読み込んだで [0] 1.230000 456 [1] 7.000000 890 [2] 0.100000 1026</pre>