

I117 (6) 整列

知念

北陸先端科学技術大学院大学 情報科学研究科
School of Information Science,
Japan Advanced Institute of Science and Technology

おことわり

- 整列（ソート）各種技術はアルゴリズムの講義で
- ここでは軽く、ソートの利用方法を紹介する
- メインメモリ上のソート関数 `qsort`
 - ◇ 多く場合 `qsort` で事足りる
 - ◇ 例外
 - ★ 高速性が要求される => 関数の形態を変更
 - ★ 特殊なデータ内容 => アルゴリズムを変更
 - ★ 配列では格納されていない

※ 外部メモリを使うソートは扱わない

qsort

- クイックソート (quick sort) の汎用的実装
- 多くの処理系で利用可能

```
void qsort(void *base, size_t nel,  
           size_t width,  
           int (*compar)(const void *,  
                          const void *));
```

- 引数
 - ◇ 場所、要素数、要素サイズ、比較関数
 - ◇ 間違えやすいので注意

比較関数

```
int (*compar)(const void*, const void*);
```

qsort は比較関数で整列順を決める
返り値に前提をおく

- >0 大きい
- $=0$ 同じ
- <0 小さい

比較の詳細は比較関数の実装任せ

比較関数: int の比較

※ Solaris の man から引用

```
static int intcompare(const void *p1,  
                      const void *p2)  
{  
    int i = *((int *)p1);  
    int j = *((int *)p2);  
    if (i > j)    return (1);  
    if (i < j)    return (-1);  
    return (0);  
}
```

比較関数: int の比較 (*cont.*)

実はこの程度で十分

```
static int intcompare(const void *p1,  
                      const void *p2)  
{  
    int i = *((int *)p1);  
    int j = *((int *)p2);  
    return i-j;  
}
```

呼び出し例

```
int ar[] = { 41, 3, 92, 7, 13, 10};
int i;

qsort((void *)ar,
      sizeof(ar)/sizeof(int),
      sizeof(int), intcompare);
for (i = 0; i < sizeof(ar)/sizeof(int);
     i++) {
    printf("%d ", ar[i]);
}
printf("\n");
```

比較関数: int の比較 (*cont.*)

結果 — 昇順 ↗

```
% ./a.out  
3 7 10 13 41 92
```

比較関数の引き算を $j - i$ にすると降順 ↘

```
% ./a.out  
92 41 13 10 7 3
```

比較関数: 文字列

文字列の大小比較に関数 strcmp を使う

```
int  
cmp(const void *x, const void *y)  
{  
    char *xp, *yp;  
    xp = *(char**)x;  
    yp = *(char**)y;  
    return strcmp(xp, yp);  
}
```

呼び出し側

```
char *ar[] = { "41", "3", "92",  
               "7", "13", "10"};  
  
int i;  
qsort((void *)ar,  
      sizeof(ar)/sizeof(char*),  
      sizeof(char*), cmp);  
for (i = 0;  
     i < sizeof(ar)/sizeof(char*); i++) {  
    printf("%s ", ar[i]);  
}  
printf("\n");
```

比較関数: 文字列 (*cont.*)

結果

10	13	3	41	7	92
----	----	---	----	---	----

文字列なので、"13" < "3" "41" < "7"

- strcmp の挙動

- 1) 先頭から文字の大小比較
- 2) 短い文字列が小さい返り値

比較関数: 文字列 (*cont.*)

アルファベットにすると

```
char *ar[] = { "openlog", "syslog",  
               "closelog", "syslogmask"};
```

結果

```
closelog openlog syslog syslogmask
```

降順は -strcmp(xp,yp); か strcmp(yp,xp); に

```
syslogmask syslog openlog closelog
```

比較関数: 文字列 (*cont.*)

空白を含む長い文字列


```
char *ar[] = {"The Beatles", "U2",  
              "Norah Jones", "Johnny Cash",};
```

結果 — 1項目ずつ改行してある

```
Johnny Cash  
Norah Jones  
The Beatles  
U2
```

データ内容に合わせた変更 — The を除いて比較

```
int cmp(const void *x, const void *y) {  
    char *xp, *yp;  
    xp = *(char**)x;  
    if(strncasecmp(xp, "the ", 4)==0) {  
        xp += 4; }  
    yp = *(char**)y;  
    if(strncasecmp(yp, "the ", 4)==0){  
        yp += 4; }  
    return strcasecmp(xp, yp);  
}
```



比較関数: 文字列 (*cont.*)


- The だけでなく空白も含めて比較
 - ◇ There, Them 等の単語を誤処理しないため
- 大文字小文字混在なので `strcasecmp` を使う

結果

```
The Beatles  
Johnny Cash  
Norah Jones  
U2
```

参照配列によるソート

- 対象データ群が大きい
 - ◇ ソートに伴うコピーに時間がかかる
数10MB/件 の画像を名前でソートしたり




`sizeof(filenamees)<<sizeof(pictures)`

- 対象データが線形に格納されていない
 - ◇ qsort が扱えない

=> ソートのために配列を別に設ける


参照配列によるソート (cont.)

大略



ソート結果を使うために参照も設ける

```
typedef struct {  
    char *key;  
    void *value;  
} cell;
```



参照配列によるソート (*cont.*)

こうすると...

- ソート処理中のコピーは参照配列だけ
 - ◇ 小さな領域（8バイト）に押し込められる
- 参照配列のソート後、参照配列をたぐるだけで対象データがソートされたことになる。

ちなみに、参照メンバ value の型を void* にしたのは任意のポインタを扱うため

画像は大変なので、ここでは文字列でサンプルを作る

```
char* pickstr2key(void *src) {  
    char *dst, *p = src, *q;  
    dst = (char*)malloc(strlen(src)+1);  
    if(strncasecmp(src, "the ", 4)==0) {  
        p += 4;  
    }  
    q = dst;  
    while(*p) {  
        *q++ = toupper(*p++);  
    }  
    *q = '\0';  
    return dst; }  

```

conv は pickstr2key を使う

```
int str2cell(cell dst[], void *src[],
             int nlen, char *(conv)(void*))
{
    int i;
    for(i=0; i<nlen; i++) {
        dst[i].key = conv(src[i]);
        dst[i].value = src[i];
    }
    return 0;
}
```

参照配列によるソート (*cont.*)

呼び出し側

- 配列 `ar` の長さ `n` は `sizeof(ar)/sizeof(ar[0])` で算出
- 参照配列 `refar` の長さは `sizeof(cell)*n`

```
char *ar[] = {"The Beatles", "U2",  
             "Norah Jones", "Johnny Cash",};  
cell *refar;  
int n = sizeof(ar)/sizeof(ar[0]);  
refar = (cell*)malloc(sizeof(cell)*n);  
str2cell(refar, (void*)ar, n,  
         pickstr2key);
```

参照配列によるソート (*cont.*)

あとは qsort を適用して、表示する

```
qsort(refar, n, sizeof(refar[0]),
      cellkeycmp);
for(i=0;i<n;i++) {
    printf("%-16s %s\n",
           refar[i].value, refar[i].key);
}
```

- cellkeycmp は単純な strcmp で十分
- refar のソート結果から ar の内容を表示

参照配列によるソート (*cont.*)

pickstr2key で加工("the "除去、大文字化)しているので単純な比較で良い

```
int cellkeycmp(void const *xp,
               void const *yp)
{
    char *x; char *y;
    x = ((cell*)xp)->key;
    y = ((cell*)yp)->key;
    return strcmp(x,y);
}
```

参照配列によるソート (*cont.*)

結果

The Beatles	BEATLES
Johnny Cash	JOHNNY CASH
Norah Jones	NORAH JONES
U2	U2

- 元データ操作なし、ソート中のコピー処理が軽い
- ソート前に加工済、キー比較の処理が軽い
- 参照配列の分だけメモリを消費（デメリット）