

I117 (11) CSV パース

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

CSV RFC4180

- CSV (Comma-Separated Values)
 - ◇ コンマで区切ったテキストファイル
 - ◇ スプレッドシートプログラムで良く使われる
- RFC4180
 - ◇ 長年明解な規約がなかったが、2005年にRFCとなる
 - ◇ <http://www.ietf.org/rfc/rfc4180.txt>

例

header つき

```
field1, field2, field3 CRLF  
aaa, bbb, cccc CRLF  
zzz, yyy, xxxx CRLF
```


header なし

```
aaa, bbb, cccc CRLF  
zzz, yyy, xxxx CRLF
```

ひとまず header なしですすめる

用語

- (原則) 行をレコード、コンマで区切られた文字列をフィールドと呼ぶ



- コンマをデータとして扱うには？
 - ◇ ダブルクォート (0x22) で文字列を囲む
 - ◇ 文字列にはコンマや改行を含めて良い

用語 (*cont.*)

- ダブルクォートをデータとして扱うには？
 - ◇ もう一つダブルクォートをつける

難しい例

以下は2フィールドのレコードが3つ

```
"abc, def", ghi CRLF  
abc def, "ghi CRLF  
xyz" CRLF  
"foo""bar", junk dummy CRLF
```

RFC 上の定義

```
file = [header CRLF] record *(CRLF record) [CRLF]  
header = name *(COMMA name)  
record = field *(COMMA field)  
name = field  
field = (escaped / non-escaped)  
escaped = DQUOTE  
          *(TEXTDATA / COMMA / CR / LF / 2DQUOTE)  
          DQUOTE  
non-escaped = *TEXTDATA  
COMMA = %x2C          DQUOTE = %x22  
CR = %x0D          LF = %x0A          CRLF = CR LF  
TEXTDATA = %x20-21 / %x23-2B / %x2D-7E
```

ファイル内容確認 pcrf.c

```
while(fgets(line, BUFSIZ, stdin)) {
    p = line;
    while(*p) {
        if(*p=='\r') {
            if(*(p+1)=='\n') { printf(" CRLF"); p++; }
            else { printf(" CR"); } }
        else if(*p=='\n') { printf(" LF"); }
        else { fputc(*p, stdout); }
        p++;
    }
    fputc('\n', stdout);
}
```

パース csvparse.c

CSV を解釈するプログラムを作る


講義のWWWページに記載

[http://www2.jaist.ac.jp/is/private/lecture/
i117/2008/csvparse.c](http://www2.jaist.ac.jp/is/private/lecture/i117/2008/csvparse.c)

現状では、レコードとフィールド位置、そしてカレントのフィールド内容を格納するだけ

パース csvparse.c (cont.)

定義から入力を想像しながら構造を考える



- escaped, non-escape の切替えには入力が必要
- readfield() で新しい入力をはじめる
 - ◇ readch() 呼び出し

パース csvparse.c (cont.)

escaped 中の 2DQUOTE が難しい


- 2文字読まないと判定できない

それ以外はその場で判定可能

```
#define ISCOMMA (ch==0x2c)
#define ISCR    (ch==0x0d)
#define ISDQUOTE (ch==0x22)
#define ISLF    (ch==0x0A)
#define ISTEXT  ((ch>=0x20&&ch<=0x21)|| \
                (ch>=0x23&&ch<=0x2b)|| (ch>=0x2d&&ch<=0x7e))
```

多文字入力は大変なので1文字入力で設計する

field の状態遷移



2DQUOTE まわり

- escaped の中では DQUOTE の後は DQUOTE か COMMA に限られる
- DQUOTE が二つでてこなかったら escaped が終わったとみなして良い
- 関数の最後に goto 文でジャンプ

```
int readescaped() {
    readch();
    while(ISTEXT || ISCOMMA || ISCR || ISLF || ISDQUOTE) {
        if(ISDQUOTE) {
            readch();
            if(ISDQUOTE) { /* 2DQUOTE */ }
            else { goto shiftS3; }
        }
        addch(); readch();
    }
    if(ISDQUOTE) { readch(); }
shiftS3:
    return 0; }
```

2DQUOTE まわり (*cont.*)

このルーチンは goto を使わないと結構厄介

- 単純に DQUOTE の判定文を抜けると
- escaped を閉じる DQUOTE は読み込んだ後
- つまり読み過ぎていて、閉じる DQUOTE の判定ができない

goto を取り除きたい者は考えてみると良いだろう

ループ — readrecord

素直に作った場合

```
fno = 0;  
do {  
    ck = readfield();  
    if(ISCOMMA) { }  
    else  
        break;  
    fno++;  
} while(1);
```

ループ — readrecord (cont.)

do-while の形のまま簡単化

```
fno = 0;  
do{  
    ck = readfield();  
    fno++;  
} while(COMMA);
```

最後フィールドの後の fno の処理が違うが、今回の範囲では影響はない

ループ — readrecord (cont.)

fno の処理をそのまま維持して簡単化

```
fno = 0;  
while(ck = readfield(), COMMA) {  
    fno++;  
}
```

readheader や readfile も同様に最適化可能

実行例 — 前述の入力

```
% ./a.out < psmplb
0-0 field 'abc,def'
0-1 field 'ghi'
1-0 field 'abc def'
1-1 field 'ghi
xyz'
2-0 field 'foo"bar'
2-1 field 'junk dummy'
EOF
```

想定通り

実行例 — 前述の入力 (*cont.*)

入力を確認 — 各行 CRLF が入っている

```
% ./pcrlf <psmp1b  
"abc,def",ghi CRLF  
abc def,"ghi CRLF  
xyz" CRLF  
"foo""bar",junk dummy CRLF
```

- UNIX の行区切りは LF
- エディタでコントロールM を入力する
 - ◇ emacs: コントロールQ コントロールM
 - ◇ vi: コントロールV コントロールM

実行例 — 前述の入力 (*cont.*)

出力を再確認 — CR が含まれる行がある

```
% ./a.out < psmplb |& ./pcr lf
0-0 field 'abc,def' LF
0-1 field 'ghi' LF
1-0 field 'abc def' LF
1-1 field 'ghi CRLF
xyz' LF
2-0 field 'foo"bar' LF
2-1 field 'junk dummy' LF
EOF LF
```

実行例 — RFC のサンプル

1 番目

```
% ./a.out < smp1
0-0 field 'aaa'
0-1 field 'bbb'
0-2 field 'ccc'
1-0 field 'zzz'
1-1 field 'yyy'
1-2 field 'xxx'
EOF
```

2 番目

```
% ./a.out < smp2
0-0 field 'aaa'
0-1 field 'bbb'
0-2 field 'ccc'
1-0 field 'zzz'
1-1 field 'yyy'
1-2 field 'xxx'
no LF (record separator)
```

実行例 — RFC のサンプル (*cont.*)

6番目

```
% ./a.out < smp6
0-0 field 'aaa'
0-1 field 'b
bb'
0-2 field 'ccc'
1-0 field 'zzz'
1-1 field 'yyy'
1-2 field 'xxx'
no LF (record separator)
```

7番目

```
% ./a.out < smp7
0-0 field 'aaa'
0-1 field 'b"bb'
0-2 field 'ccc'
no LF (record separator)
```

まとめ

- 少々複雑な形式を解析する例を紹介した
- 定義からプログラムを想像できるように訓練せよ
 - ◇ 状態遷移や入力に注意を払う

補足

- RFC に登場する他の例も動作確認済
- 定義上でとりうる全ての組み合わせを試したわけではない
- 行末は CR がない場合も想定して、LF だけでも受け付ける

演習

前述のプログラムに関して

- 1) 定義上存在するにもかかわらず受け付けない入力を探せ★
 - 長さに関する制限は除外する
- 2) 変数 `vused` を使って変数 `value` への代入を監視せよ★
 - 現行は非常に長い文字列を代入して記録を破壊する可能性がある
- 3) `goto` 文を使わず `escaped` をパースするよう変更せよ★★★

演習 (cont.)

新規プログラム

- 1) 行毎に読み込み解析するプログラムを作れ★★
- 2) 多文字入力の状態遷移で解析するプログラムを作れ★★
- 3) lex, yacc 等を使って同等の解析プログラムを作れ★★
- 4) CSV を HTML に変換するプログラムを作れ★
 - フィールド内容は短い文字列とする
 - コンマやダブルクォートも含めた文字列も扱う