

テキスト処理 第12回 (2008-07-08)

scanstr レポート解説

田中哲

産業技術総合研究所

情報技術研究部門

akr@isc.senshu-u.ac.jp

[http://staff.aist.go.jp/tanaka-
akira/textprocess-2008/](http://staff.aist.go.jp/tanaka-akira/textprocess-2008/)

レポート

- `scanstr(s, r)` を実装して解説せよ
- 実装したらユニットテストで確認してほしい
- メタ 2008-07-08 12:00
- RENANDI
- 拡張子が `txt` なテキストファイルがよい

scanstr(s, r)

- String#scan を部分的に真似したもの
- 文字列 s 中の r にマッチする部分文字列をすべて調べ、配列として返す
- 実行例
- p scanstr("banana", [:anychar])
#=> ["b", "a", "n", "a", "n", "a"]
- p scanstr("banana", [:alt, "b", "n"])
#=> ["b", "n", "n"]
- p scanstr("banana", [:cat, "n", "a"])
#=> ["na", "na"]

scanstr の実装

```
def scanstr(s, r)
    s = s.split("//")
    beg = 0
    result = []
    while md = cap_include(r, s, beg)
        m = md[:all].begin
        n = md[:all].end
        result << s[m...n].join
        beg = n
    end
    if m == n
        if beg == s.length
            break
        else
            beg += 1
        end
    end
    result
end
```

実装方針

- だいたい gsubst と同じ
- マッチを見つけたら result に追加していく

gsubst

```
def gsubst(s, r)
  s = s.split("//")
  beg = 0
  result = []
  while md = cap_include(r, s, beg)
    m = md[:all].begin
    n = md[:all].end
    h = {}
    md.each { |k,v| h[k] = s[v].join }
    result += s[beg...m]
    result << yield(s[m...n].join, h)
    beg = n
    if m == n
      if beg == s.length
        break
      else
        result << s[beg]
        beg += 1
      end
    end
  end
  result += s[beg..-1]
  result.join
end
```

gsubst から scanstr へ

```
def scanstr(s, r)
  s = s.split("//")
  beg = 0
  result = []
  while md = cap_include(r, s, beg)
    m = md[:all].begin
    n = md[:all].end
```

マッチ情報の準備
マッチ間の追加

```
    result += s[beg...m]
    result << yield(s[m...n].join(h))
    beg = n
```

ブロック呼出し

```
  if m == n
    if beg == s.length
      break
    else
      スキップ部分の追加
      beg += 1
    end
  end
end
```

最後のマッチ後を追加

```
  result 連結
end
```

ざっと眺めた結果

- 簡単だった模様
- gsubst を「使った」実装
 - res = []; gsubst(s, r) {|str, h| res << str }; res
 - たしかに動く
- gsubst を改造して、h を取り除いていないもの
 - 動くけど無駄
- 無限ループ防止が入っていないもの