テキスト処理 第3回 (2006-05-09)

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/

今日の内容

- 前回説明を忘れたことを説明する
- テキストから正規表現にマッチした行を取り出すツールを改善する
- それに役に立つRuby特有の要素を学ぶ
- レポート

だいたい任意の 1文字にマッチする正規表現 /./

- . (ドット)は改行 (/n) 以外の任意の 1文字にマッチする
- 例

```
/./ =~ “a”          0
/./ =~ “z”          0
/./ =~ “\n”         nil
/./ =~ “”           nil
```

前回のegrep.rb

```
pattern = ARGV[0]          # 第1引数の取り出し
filename = ARGV[1]         # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
f = open(filename)     # 第1引数のファイルをオープン
while line = f.gets # ファイルの終わりまで一行づつ読む
  if regexp =~ line # 読み込んだ行は正規表現にマッチするか？
    print line          # マッチしてたら表示
  end
end
f.close                # ファイルをクローズ
```

今回のegrep.rb

- Rubyの機能を使うともっと短く書ける

```
pattern = ARGV.shift
regexp = Regexp.compile(pattern)
ARGF.each {|line|
  print line if regexp =~ line
}
```

今回の **egrep.rb** で使用する機能

- Array#shift
- 後置 if
- ブロック
- ARGF

Array#shift

- 配列の先頭を破壊的に取り出すメソッド

```
a = [1,2,3]
p a              #=> [1,2,3]
p a.shift        #=> 1
p a              #=> [2,3]    a の内容が変わっている
```

- 配列のことを Ruby では Array という
- Array に使えるメソッド shift を Array#shift と書く

egrep.rb で Array#shift を使う

```
pattern = ARGV.shift      # 第1引数の取り出し
filename = ARGV[0]        # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
f = open(filename)     # 第1引数のファイルをオープン
while line = f.gets # ファイルの終わりまで一行づつ読む
  if regexp =~ line # 読み込んだ行は正規表現にマッチするか？
    print line          # マッチしてたら表示
  end
end
f.close                 # ファイルをクローズ
```

後置 if

- 英語っぽく「文 if 条件」と書ける

```
print “x exists\n” if /x/ =~ “text process”
```

- 以下とほぼ同じ

```
if 条件                    if /x/ =~ “text process”
  文                         print “x exists\n”
end                        end
```

- 利点
  - 短く記述できる
  - 英語に慣れている人には読みやすいかも
- 注意: 一行で書く

egrep.rb で後置if を使う

```
pattern = ARGV.shift      # 第1引数の取り出し
filename = ARGV[0]        # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
f = open(filename)     # 第1引数のファイルをオープン
while line = f.gets # ファイルの終わりまで一行づつ読む
 print line if regexp =~ line  # 読み込んだ行がマッチしたら表示
end
f.close                  # ファイルをクローズ
```

ブロック

- Ruby の大きな特徴のひとつ
- メソッド引数に加えてブロックを渡せる

```
obj.meth(arg) {
    ...
}
```

```
func {
    ...
}
```

- ブロック内のコードは実行されずに渡される
- 渡されたメソッドはブロックを呼び出せる
  何回呼び出しても、呼び出さなくても良い
- Lisp のクロージャに類似。Cでいえば関数ポインタ

ブロックの例

- egrep.rb で使うもの

```
ARGF.each {|line|
  print line if regexp =~ line
}
```

- 無限ループ

```
loop {
  puts “hello”
}
```

ブロックの用途

- 制御構造の定義
  - 無限ループ loop
  - 配列の各要素の繰り返す Array#each
  - 1行づつ読み込むループ IO#each, ARGF.each
  - 配列内を探索して見付からなかったときの処理を指定する Array#index
- 高階関数の定義
  - 配列の各要素を変換する Array#map
  - 条件にあった要素だけを集める Array#find_all
  - ソートの比較関数を渡す Array#sort
- 他にもさまざまな用途がある

無限ループ

- 標準で loop メソッドがある

```
loop {
  puts “hello”
}
```

- while とかと違って言語に作り付けではない
- このようなものをユーザも定義できる

無限ループなメソッドを定義

- loop2 を定義する

```
def loop2
  while true
    yield   # 与えられたブロックを呼び出す
  end
end
```

yield

- yield はメソッドに与えられたブロックを呼び出す

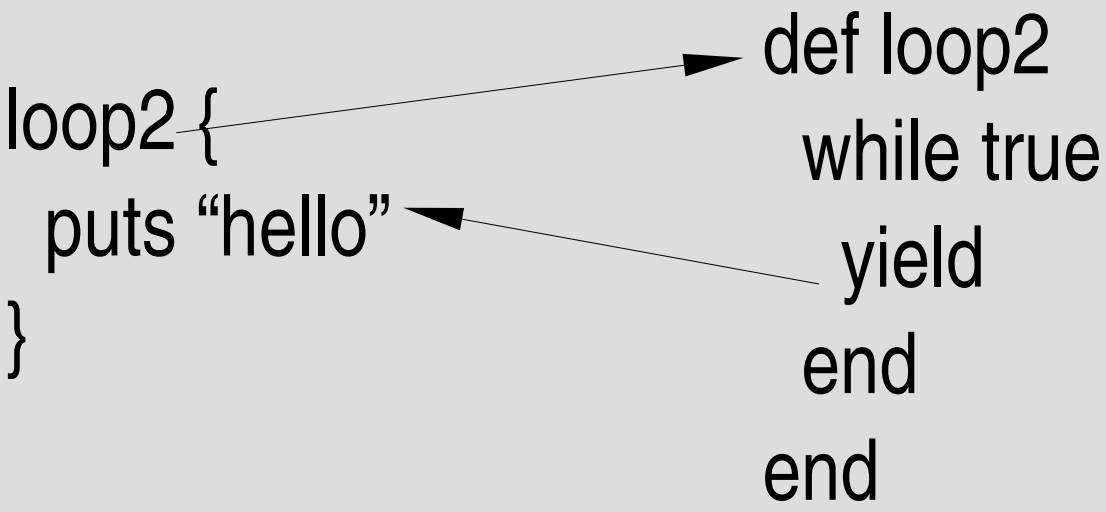

loop2 の制御の流れ

- yield はメソッドに与えられたブロックを呼び出す

```
loop2 {
  puts “hello”
}
```

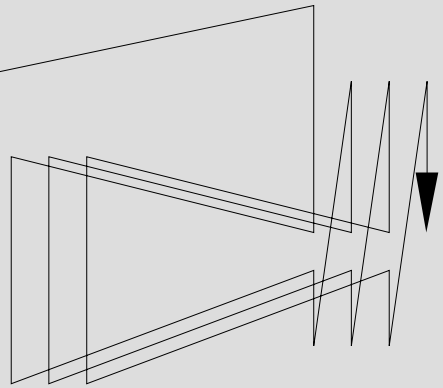

```
def loop2
  while true
    yield
  end
end
```

単純な例: **twotimes**

- yield はメソッドに与えられたブロックを呼び出す

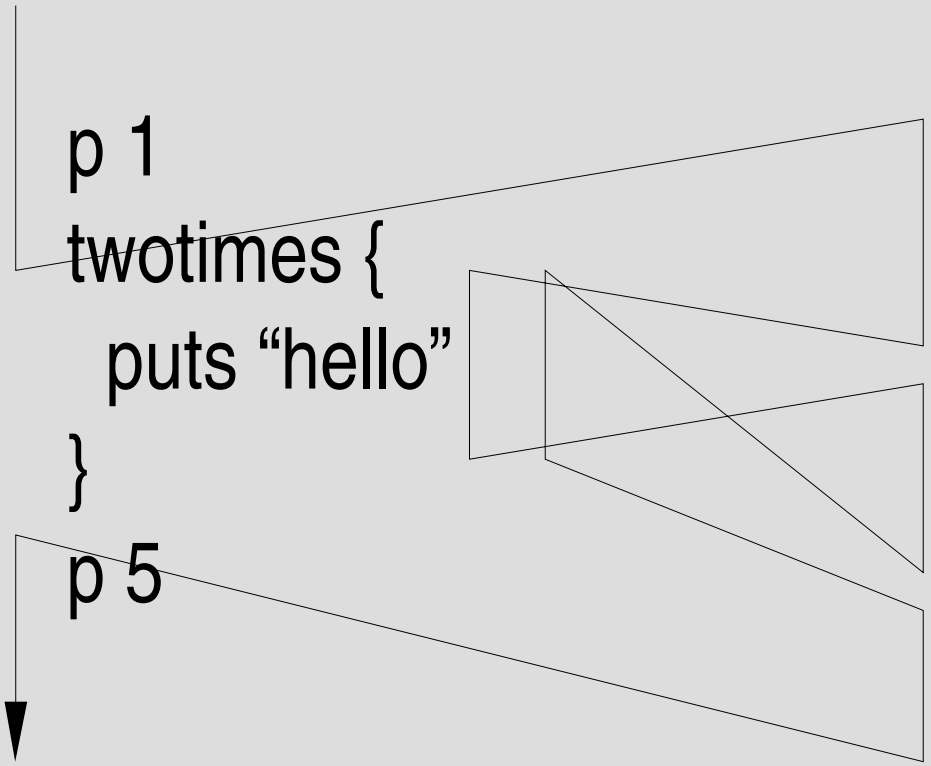

実行結果

```
1
2
hello
3
hello
4
5
```

yield の引数

- yield にはブロックへの引数を渡せる
  yield arg
- ブロックはその引数を受け取れる
  obj.meth {|arg| ... }

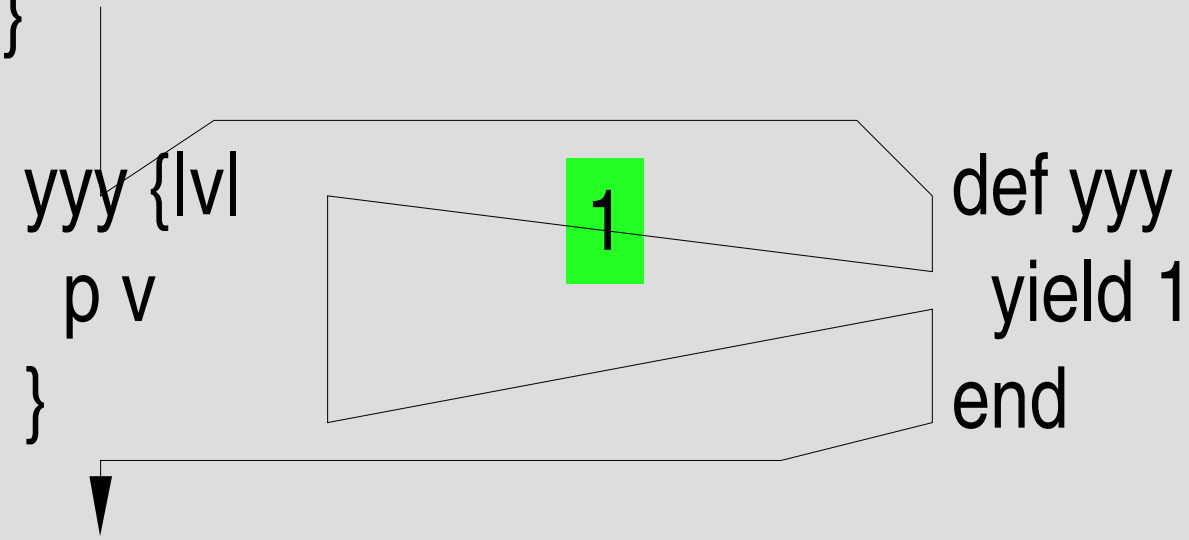

v に 1 が代入された状態で p v が実行される

countup

- countup(first, last) {|var| ... }
- first から始めて last まで順に var に代入してブロックを実行する

```
def countup(first, last)
  i = first
  while i <= last
    yield i
    i += 1
  end
end
```

```
countup(3,5) {|v|
  p v
}
```

実行結果

```
3
4
5
```

countup の実行

- 3 から 5 まで

```
countup(3,5) {|v|
  p v
}
```

```
def countup(first, last)
  i = first
  while i <= last
    yield i
    i += 1
  end
end
```

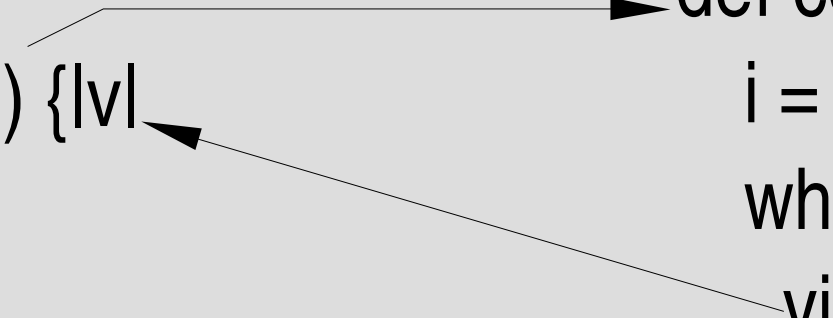

- 実行結果

```
3
4
5
```

Integer#upto

- countup に似たメソッドが標準で整数にある

```
3.upto(5) {|v|
  p v
}
```

- 実行結果

```
3
4
5
```

ブロックへの複数引数

- ブロックと yield は複数の引数をとれる

```
loop2dim(1,1) {|x,y|
  p [x,y]
}
```

- 実行結果

```
[0,0]
[0,1]
[1,0]
[1,1]
```

```
def loop2dim(xmax,ymax)
  0.upto(xmax) {|x|
    0.upto(ymax) {|y|
      yield x, y
    }
  }
end
```

yieldの返り値

- ブロック内の最後の文の値が yield の値になる

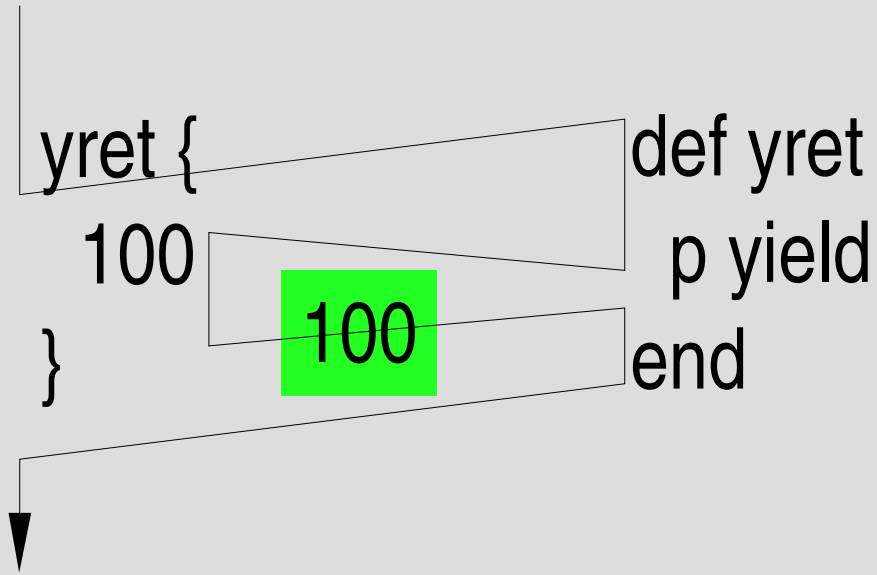

実行結果
100

引数と返り値

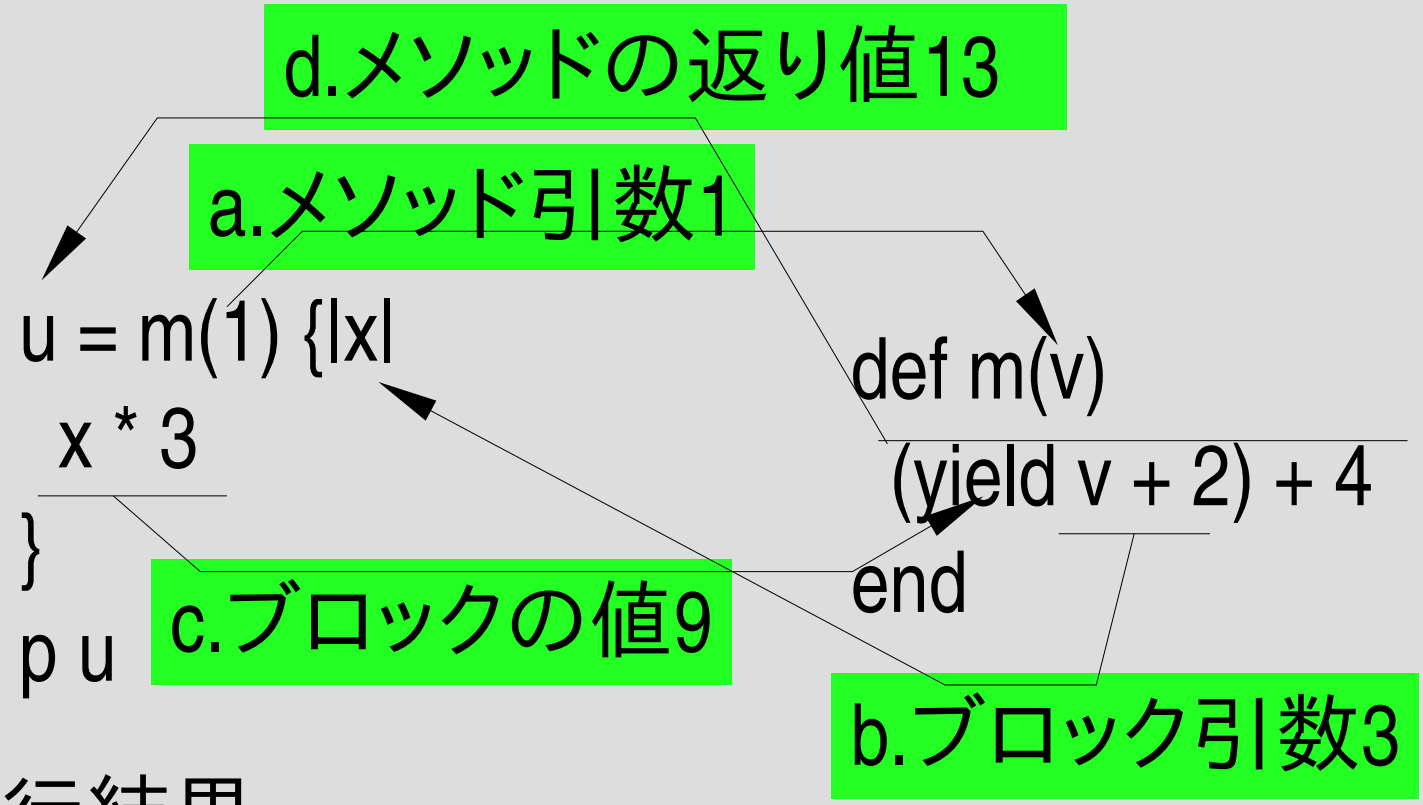

実行結果
13

Array#map

- 配列の各要素にブロックを適用し、結果を集めたあたらしい配列を生成

```
[1,2,3].map {|v| v * 2 }    #=> [2,4,6]
```

Array#find_all

- 配列の各要素にブロックを適用し、結果が真だったものを集めた配列を生成

```
[1,2,3,4,5,6,7].find_all {|v| v % 3 == 0 }
#=> [3,6]        3の倍数だけが取り出される
```

Array#each

- 配列の各要素にブロックを適用する

```
[1,2,3].each {|v|
  p v
}
```

実行結果

```
1
2
3
```

IO#each

- ファイルをオープンして得られる IO オブジェクトの each メソッド
- ファイルの各行にブロックを適用する

```
f = open(“words”)
f.each {|line|
  p line
}
f.close
```

実行結果

“\n”
“A\n”
“A's\n”
“AOL\n”
...

egrep.rb で IO#each を使う

```
pattern = ARGV.shift      # 第1引数の取り出し
filename = ARGV[0]        # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
f = open(filename)     # 第1引数のファイルをオープン
f.each {|line|     # ファイルの終わりまで一行づつ読む
  print line if regexp =~ line    # 読み込んだ行がマッチしたら表示
}
f.close                  # ファイルをクローズ
```

open もブロックを付けられる

- open にブロックをつけると、挙動が変わる
- ファイルオブジェクトを返り値にするのでなく、ブロックに渡す
- ブロックが終了したら、自動的に close される
  呼出側で close しなくていい
- ブロックの返り値が open 自体の返り値になる

```
open(“words”) {|f|
  f.each {|linel p line }
}
```

実行結果

“\n”
“A\n”
“A's\n”
...

egrep.rb で openのブロックを使う

```
pattern = ARGV.shift      # 第1引数の取り出し
filename = ARGV[0]        # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
open(filename) {|f|       # 第1引数のファイルをオープン
  f.each {|line|          # ファイルの終わりまで一行づつ読む
    print line if regexp =~ line    # 読み込んだ行がマッチしたら表示
  }
}                         # ファイルをクローズ
```

File.foreach

- Fileクラスの foreach クラスメソッド
- ファイルをオープンして 1行づつ読みこみ、各行にブロックを適用し、全部終わったらクローズする

```
File.foreach(“words”) {|line|
  p line
}
```

egrep.rb で File.foreachを使う

```
pattern = ARGV.shift      # 第1引数の取り出し
filename = ARGV[0]        # 第2引数の取り出し
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
File.foreach(filename) {|line|      # 第1引数のファイルを一行づつ読む
  print line if regexp =~ line      # 読み込んだ行がマッチしたら表示
}
```

ARGF.each

- ARGF はコマンドライン引数に指定したファイルを示す IOオブジェクトもどき
- ARGVからファイル名を取り出す
- 複数のファイル名を指定すれば連結される
- ひとつも指定されなければ標準入力
- IOオブジェクトとほぼ同じメソッドがある

```
% ruby -e 'ARGF.each {|line| p line }' words
"\n"
"A\n"
...
```

egrep.rb で ARGF を使う

```
pattern = ARGV.shift      # 第1引数の取り出し
                          # ARGV の残りはファイル名
regexp = Regexp.compile(pattern)    # 第2引数の文字列を
                                    # 正規表現オブジェクトに変換
ARGF.each {|line|     # コマンドラインのファイルを一行づつ読む
  print line if regexp =~ line      # 読み込んだ行がマッチしたら表示
}
```

レポート

- Array#map と同様な動作をする map を実装し、動作させ、解説せよ

```
def map(ary)
  ここを埋める
end
```

- 正しく定義すると以下のように動く

```
p map([1,2,3]) {|v| v * 2 }        #=> [2, 4, 6]
p map([]) {|v| v + 1 }             #=> []
p map([2,3,4]) {|v| v * v }    #=> [4, 9, 16]
```

- Array#map を使って ary.map {|v| yield v } などというのは控えるように

レポート (つづき)

- 足りないメソッドはリファレンスマニュアルで探すこと http://www.ruby-lang.org/ja/man/
  (おそらく Array#length が必要になる)
- IT's class で提出すること
- ✍切は次回の授業が始まるまで
  2006-05-16 16:20

まとめ

- egrep もどきを Ruby っぽく書いてみた
- 特にブロックはいろいろ使える
- レポートを出した

次回予定

- コマンドラインオプションの処理
- ライブラリの使いかた
  - コマンドライン処理ライブラリ
  - ユニットテストフレームワーク