テキスト処理 第3回 (2008-04-29)

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/

今日の内容

- 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
- 関数定義とブロック

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   # 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
- メソッドに普通の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 関数がある
```
loop {
  puts "hello"
}
```
- 実行例
```
% ruby -e 'loop { puts "hello" }'
hello
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

Array#each メソッド

- 配列の各要素にブロックを適用する
- ブロックはブロック引き数をとれる

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

実行結果

```
1
2
3
```

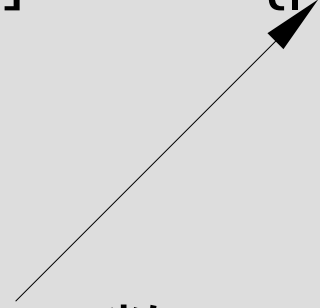

ブロック引数 v

Array#each が
配列の要素をひとつづつ渡してくれる

Array#map メソッド

- 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
- ブロックは値をメソッドに返せる

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

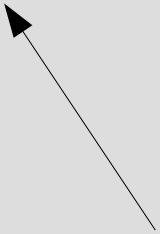

ブロックの中身の elt * 2 の結果は

map メソッドに伝えられる

Array#find_all メソッド

- 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
```

Integer#upto メソッド

- a.upto(b) {|v| ... }
  v を a から b まで昇順に変えながらブロックを実行する

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

- 実行結果
  3
  4
  5

IO#each メソッド

- 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"
...
```

open 関数

- open 関数はブロックも受け付ける
- オープンしたIOオブジェクトをブロックに渡す
- ブロックを抜けたら自動的にクローズする

```
open("words") {|f|
  f.each {|line|
    p line
  }
}
```

実行結果

```
"\n"
"A\n"
"A's\n"
"AOL\n"
...
```

ブロックの機能

- メソッド (関数) 呼び出しにブロックを付けられる
- メソッドはブロックを呼び出せる
- 何回呼び出しても良く、呼び出さなくても良い
- メソッドはブロックに引き数を渡せる
- ブロックはメソッドに値を返せる
- メソッドはブロックが与えられたかどうか判断できる

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    # 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 {|line| 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   # 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   # 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順に処理される
- 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    # 行がマッチしたら表示
}
```

コンパクトに書いた egrep.rb

```
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    # 行がマッチしたら表示
}
```

関数定義

- Rubyの関数定義

```
def 名前(引数, ...)
  式の並び
  返値
end
```

- C の関数定義

```
返値の型 名前(型 引数, ...)
{
  文の並び
  return 返値;
}
```

無限ループな関数を定義

- loop と同じ機能の 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

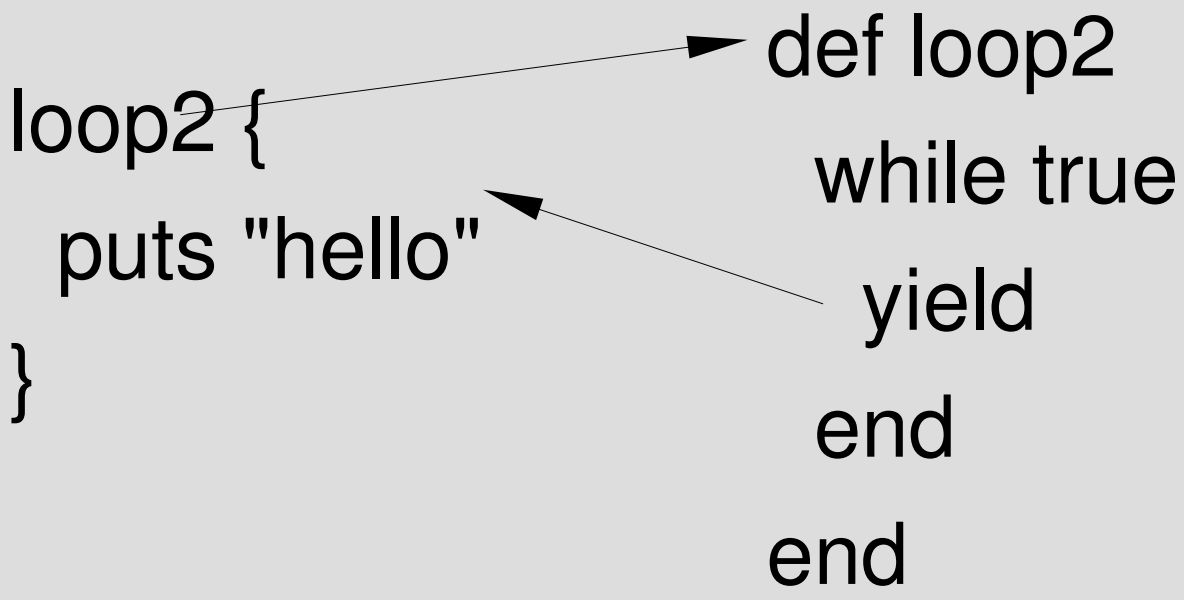

loop2 の制御の流れ

- yield はメソッドに与えられたブロックを呼び出す

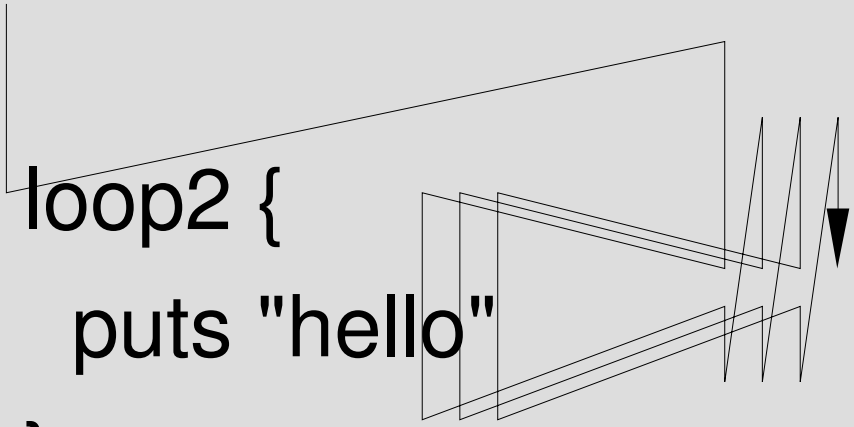

```
loop2 {
  puts "hello"
}
```

```
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

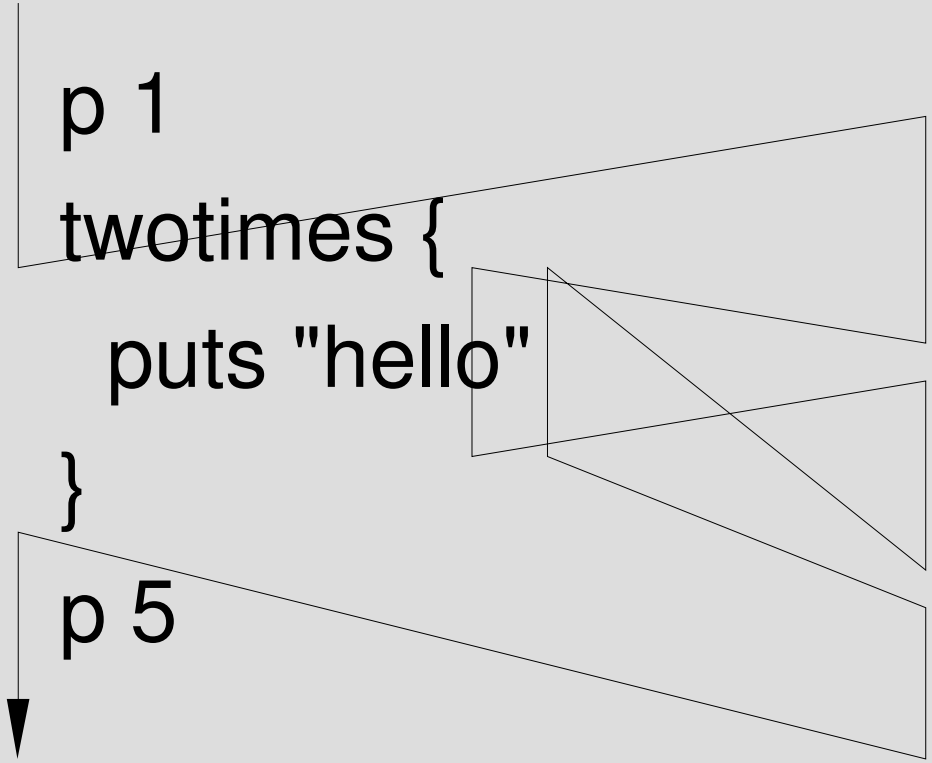

```
p 1
twotimes {
  puts "hello"
}
p 5
```

```
def twotimes
  p 2
  yield
  p 3
  yield
  p 4
end
```

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| ... }

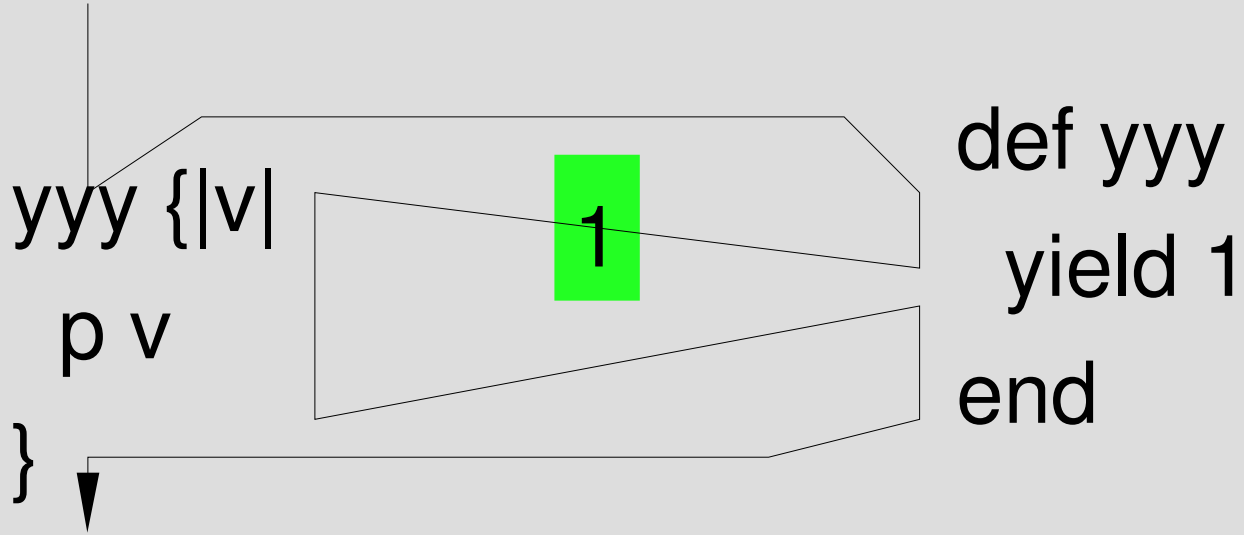

v に 1 が代入された状態で p v が実行される

countup

- countup(first, last) {|var| ... }
- Integer#upto もどき
- 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
}
```

- 実行結果

```
3
4
5
```

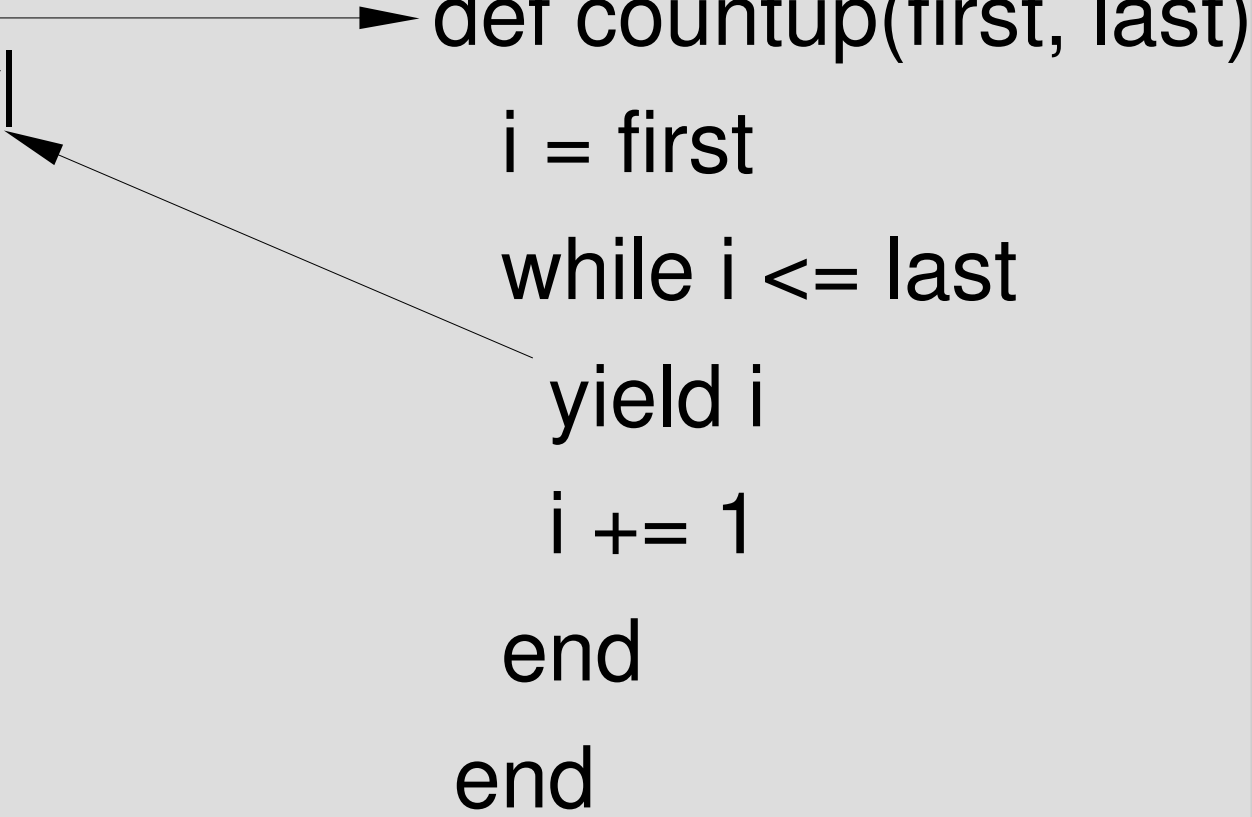

ブロックへの複数引数

- 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式の値が yield の値になる

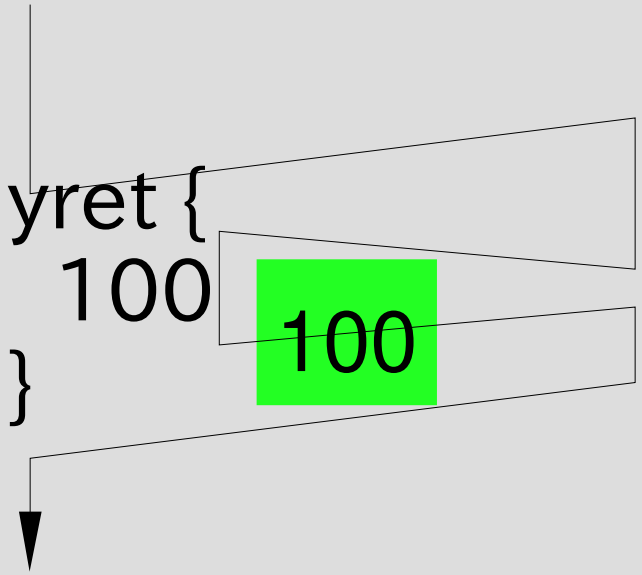


```
def yret
  p yield
end
```

実行結果

```
100
```

引数と返り値

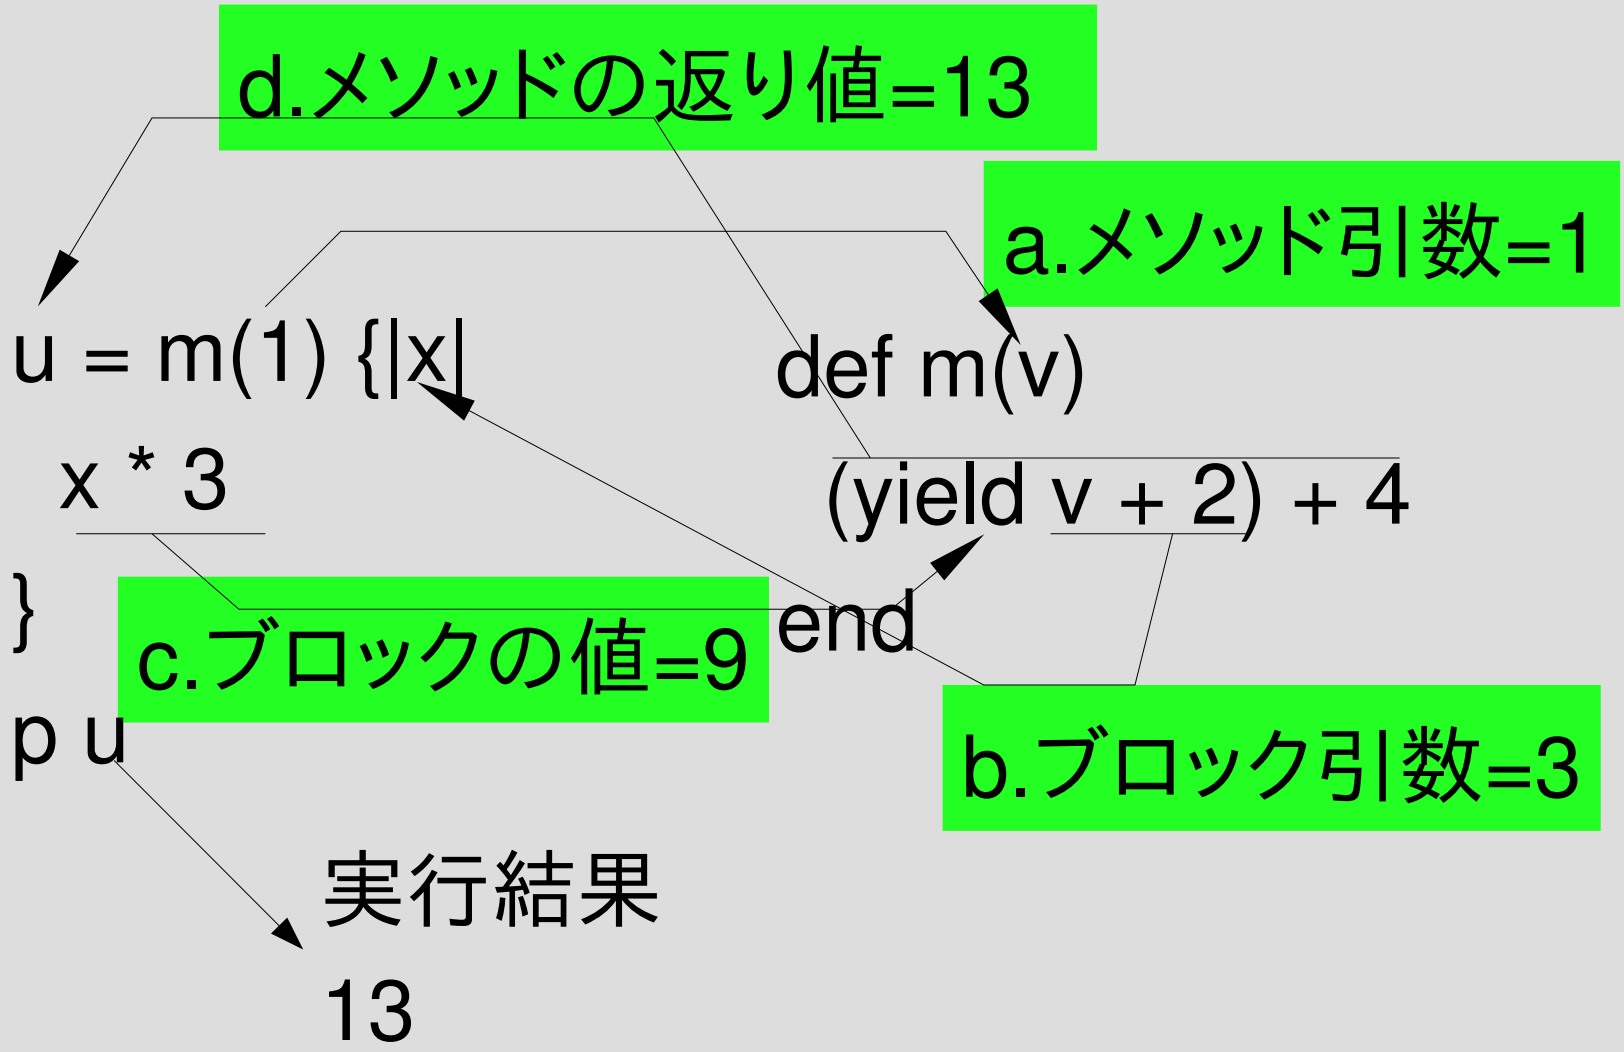
d.メソッドの返り値=13
a.メソッド引数=1
u = m(1) {|x|
x * 3
}
p u
def m(v)
(yield v + 2) + 4
end
c.ブロックの値=9
b.ブロック引数=3
実行結果
13

まとめ

- egrep もどきを Ruby っぽく書いてみた
  10行→5行
- ブロックは多様な用途を持つ
- 関数定義
- 関数定義内でのブロックの扱い