

テキスト処理 第1回 (2007-04-17)

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-2007/>

今日の内容

- この授業の概要
- Ruby の使いかた
- 正規表現の使いかた
- Rubyのインストール

この授業の概要

- 質問について
- 授業の資料
- 授業の狙い
- テキスト処理とは？
- 授業の構成
- 評価
- 参考書

質問について

- 授業中は講義中いつでも可
- 大学に常駐していないので口頭での質問は授業の後のみ
- メールでの宛先:
`akr@isc.senshu-u.ac.jp`

授業の資料

- なるべく前日までにプレゼン資料を用意する
<http://staff.aist.go.jp/tanaka-akira/textprocess-2007/>

授業の狙い

- 日常生活でテキストを処理するプログラムを書く力を身につける
- テキスト処理の仕組みを理解する
- とくに正規表現の機構と使用法
- 形式言語理論の基礎を学ぶ

テキスト処理とは？

- テキストを処理する (文字どおり)
 - テキスト
 - プレインテキスト
 - HTML
 - XML
 - etc.
 - 処理
 - 検索
 - 集計
 - etc.

授業の構成

- Rubyを使ってみる
- 正規表現を使ってみる
- 正規表現エンジンを作ってみる
- エンジンを作るのに必要な技術を学ぶ
- 正規表現の理論を学ぶ
- 理論にあわないところを学ぶ

評価

- レポート8～9割
基本的に毎回レポートを出す (今日は出さない)
Ruby を使ってプログラムを書く
- 試験も行う予定
- 出席はとらない

参考文献 (Ruby)

- 必要というわけではないが、興味があれば

- たのしいRuby 第2版

<http://www.network.org/sbcr-ruby/>



- Rubyプログラミング基礎講座

<http://www.gihyo.co.jp/books/4-7741-2645-4>

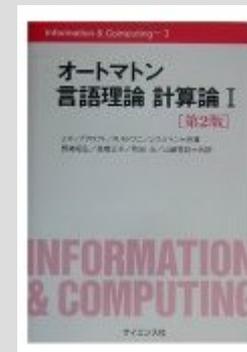


- Rubyリファレンスマニュアル (web)

<http://www.ruby-lang.org/ja/man/>

参考文献 (正規表現)

- 必要というわけではないが、興味があれば
- 詳説 正規表現 第2版
<http://www.oreilly.co.jp/books/4873111307/>
- オートマトン 言語理論 計算論 I
<http://www.saiensu.co.jp/books-htm/ISBN4-7819-0374-6.htm>



Rubyの使いかた

- プログラミング言語Ruby
- Rubyの起動
- データの表示

プログラミング言語Ruby

- オブジェクト指向スクリプト言語
- 正規表現をサポートしている
- 開発元: <http://www.ruby-lang.org/>
- 自由なライセンス

Hello World

- Hello World と表示するプログラム
- `print "Hello World\n"`

Hello World の実行

- プログラム: `print "Hello World¥n"`
- 引数から実行
- ファイルから実行
- irbから実行
- コンパイルは不要

引数から実行

- コマンドプロンプトから ruby コマンドを起動
- ruby コマンドの引数として -e program と書く
- -e はプログラムを直接指定するオプション

```
% ruby -e 'print "Hello World\n"'  
Hello World
```

- シェルの特殊文字を記述するには細工が必要
(上記ではシングルクォートはそのまま書けない)

ファイルから実行

- ファイルにプログラムを書く
- 拡張子は rb にする (必須ではない)
- ファイル名を引数にして ruby コマンドを起動

```
% cat hello.rb
```

```
print "Hello World\n"
```

```
% ruby hello.rb
```

```
Hello World
```

irbから実行

- irb は ruby の対話インターフェース
- コマンドプロンプトから irb を実行する
- irb のプロンプトにプログラムを入力する

```
% irb
```

```
irb(main):001:0> print "Hello World\n"
```

```
Hello World
```

```
=> nil
```

Rubyの実行

- 引数から実行
% ruby -e 'コード'
- ファイルから実行
% ruby コードの入ったファイル名
- irb (対話型Ruby) から実行
% irb
irb(main):001:0> コード

データの表示: p

- p 式
- ruby -e 'p 1' 1 整数
- ruby -e 'p 1+1' 2 整数な式
- ruby -e 'p "a"*3' "aaa" 文字列
- ruby -e 'p [1, 2+3, "z"]' [1,5,"z"] 配列
- ruby -e 'p true' true 真
- ruby -e 'p false' false 偽
- ruby -e 'p nil' nil nil

正規表現

- 文字列照合の道具
- 以下のようなことを調べられる
 - 文字列の中に cde という文字列が含まれているか?
 - 文字列の中に c が3個以上並んでいて、その次に d があるところがあるか?
 - 文字列の中に bc という文字列か、de という文字列か、すくなくともどちらかは含まれているか?
 - 文字列は、abc の繰り返しか?
- このようなことが成立したら、「正規表現がマッチした」という

正規表現マッチの例

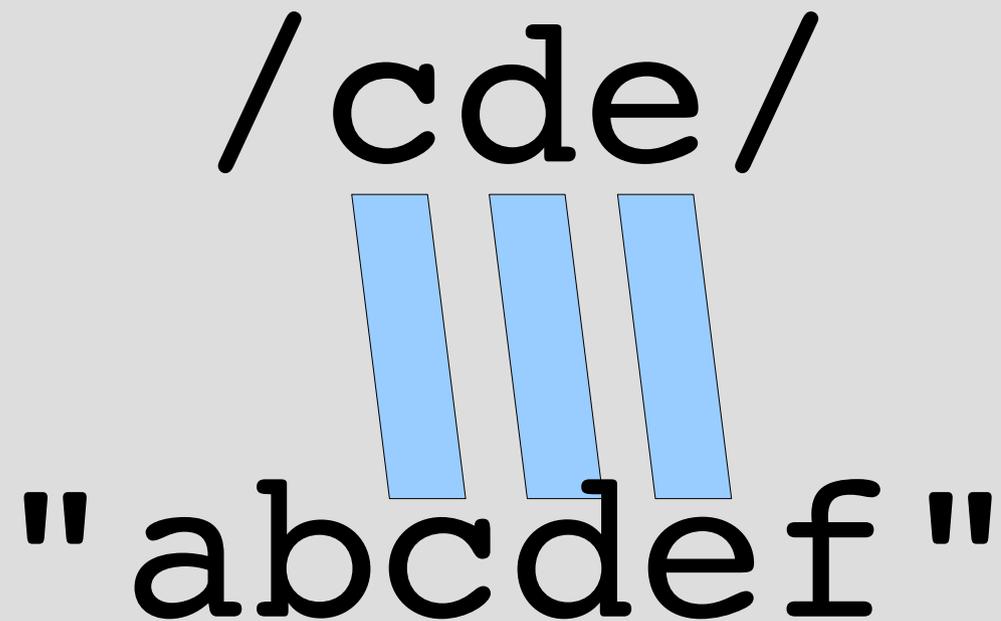
- 文字列 "abcdef" の中に cde が含まれているか?
ruby -e 'p /cde/ =~ "abcdef"'
2 "abcdef" の 2文字目からマッチ
(0-origin なので 3文字目ではない)
cde は含まれている
cde の最初の文字が 2文字目
- 文字列 "abcdef" の中に xyz が含まれているか?
ruby -e 'p /xyz/ =~ "abcdef"'
nil マッチしない
xyz は含まれていない

正規表現マッチ

- /正規表現/ =~ 文字列
- マッチしたらマッチした位置を返す
 - 文字列の先頭からマッチしたら 0 を返す (0文字目)
 - 次の文字からマッチしたら 1 を返す (1文字目)
 - 以下同様
- マッチしなかったら nil を返す

/cde/ = ~ "abcdef"

/cde/
//
"abcdef"

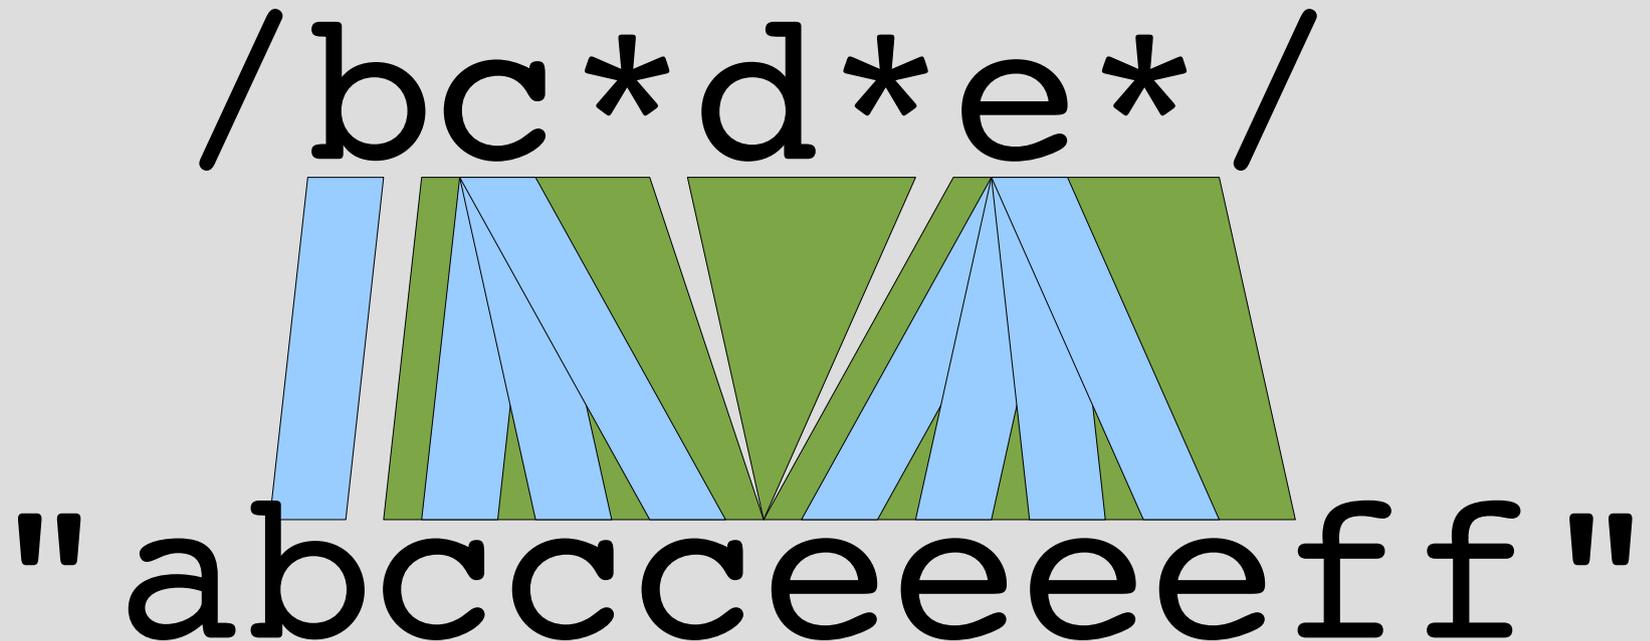


正規表現の要素

- 文字 c
- 接続 rr
- 繰り返し r^*
- 選択 $r|r$
- 文字列の先頭 $\$Ar$
- 文字列の最後 $r\$z$
- グループ化 (r)
- 他にもいろいろな要素がある

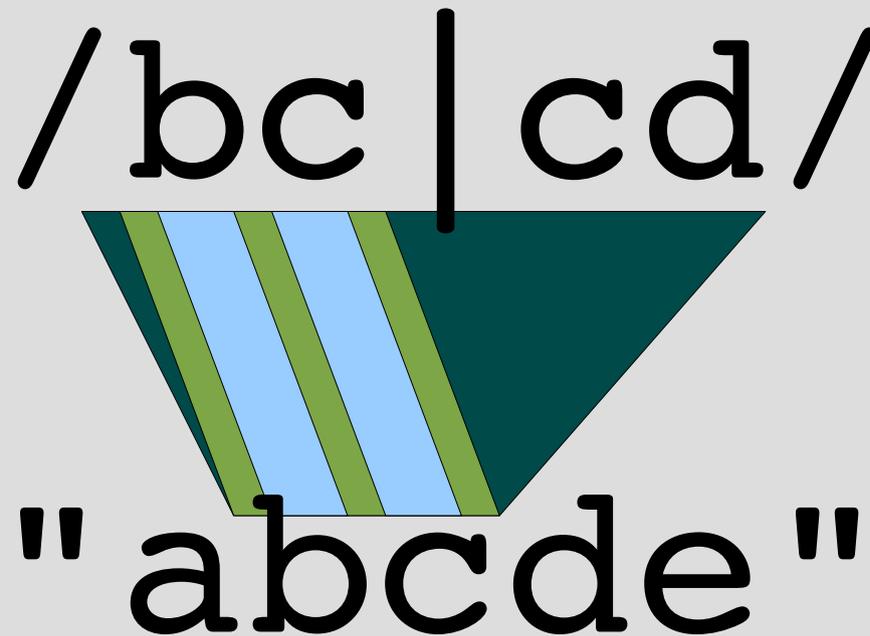
繰り返し /bc*d*e*/ =
"abcccceeeeff"

- r^* は r の 0 回以上の繰り返しにマッチする



選択 `/bc|cd/` \approx "abcde"

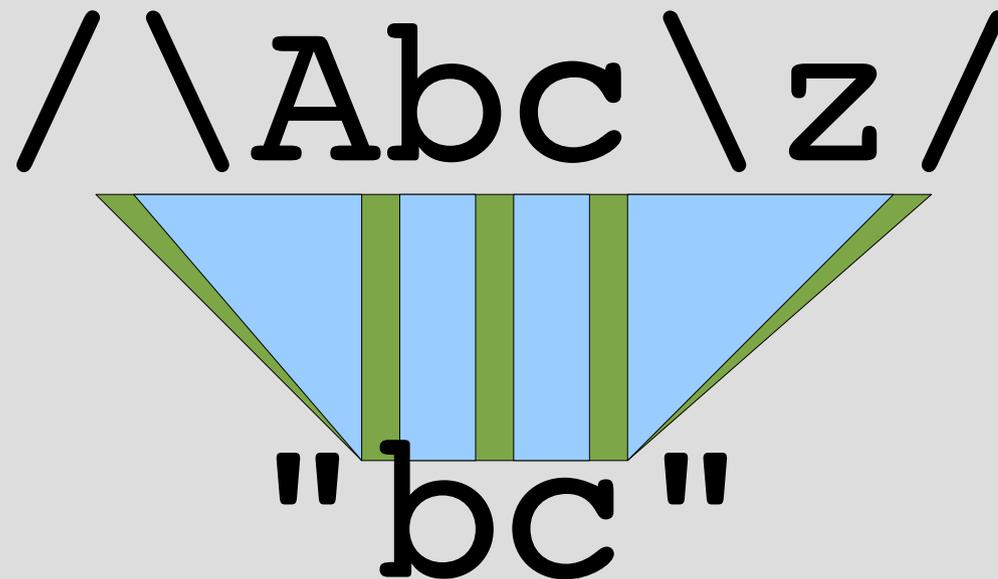
- `r1|r2` は `r1` と `r2` のどちらかにマッチする



- 文字列の左から試していくので `cd` はマッチしない

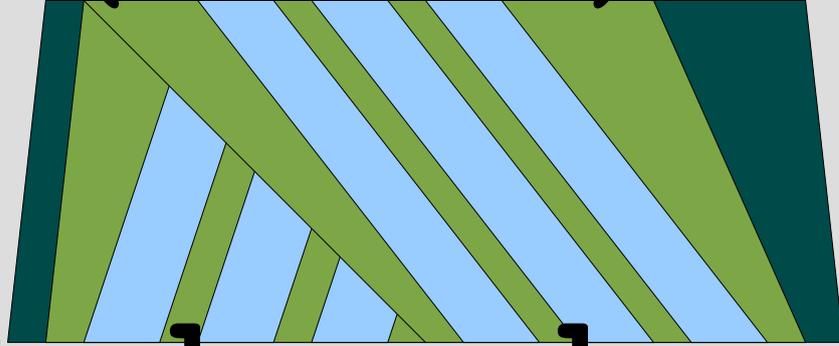
文字列の先頭・最後 /¥Abc¥z/ =~ "bc"

- ¥A は文字列の先頭にしかマッチしない
- ¥z は文字列の最後にしかマッチしない
- /¥Abc¥z/ =~ "bc" はマッチする (0 を返す)
- /¥Abc¥z/ =~ "abcd" はマッチしない (nil を返す)



グループ化 $/(abc)^*/ = \sim "abcabc"$

- (r) は r にマッチする

$/(abc)^*/$

"abcabc"

いくらでも組合せ可能

- $\forall A((a|b)^*|(de|f^*g)^*)$
- $abc(abc)^*\forall z$
- $(\forall Aabc)|(def\forall z)$
- etc.

- 疑問:
表現できないものはあるか?
なにが表現できてなにが表現できないのだろうか?
→形式言語理論が答になる

Rubyのインストール

- この講義では安定版 Ruby 1.8.5 を想定する
- 「Rubyの歩き方」が参考になる
<http://jp.rubyist.net/magazine/?FirstStepRuby>
- Windows 上で ActiveScriptRuby を使用する場
合、インストーラを実行すれば良い
- Unix では、多くの場合パッケージがある
- パッケージがなくても、自分でコンパイルすることは
できる
- それでもできなければ質問すること

まとめ

- この授業の概要
- Ruby の使いかた
- 正規表現の使いかた
- Rubyのインストール