Доктор Регекс или как я перестал бояться и полюбил регулярные выражения

Марат Ахин

18 октября 2016 г.

Санкт-Петербургский политехнический университет

Прелюдия


WHENEVER I LEARN A NEW SKILL I CONCOCT ELABORATE FANTASY SCENARIOS WHERE IT LETS ME SAVE THE DAY.
OH NO! THE KILLER MUST HAVE FOLLOWED HER ON VACATION!
BUT TO FIND THEM WE'D HAVE TO SEARCH THROUGH 200 MB OF EMAILS LOOKING FOR SOMETHING FORMATTED LIKE AN ADDRESS!
IT'S HOPELESS!
EVERYBODY STAND BACK.
I KNOW REGULAR EXPRESSIONS.
PERL!
TAP TAP

Прелюдия

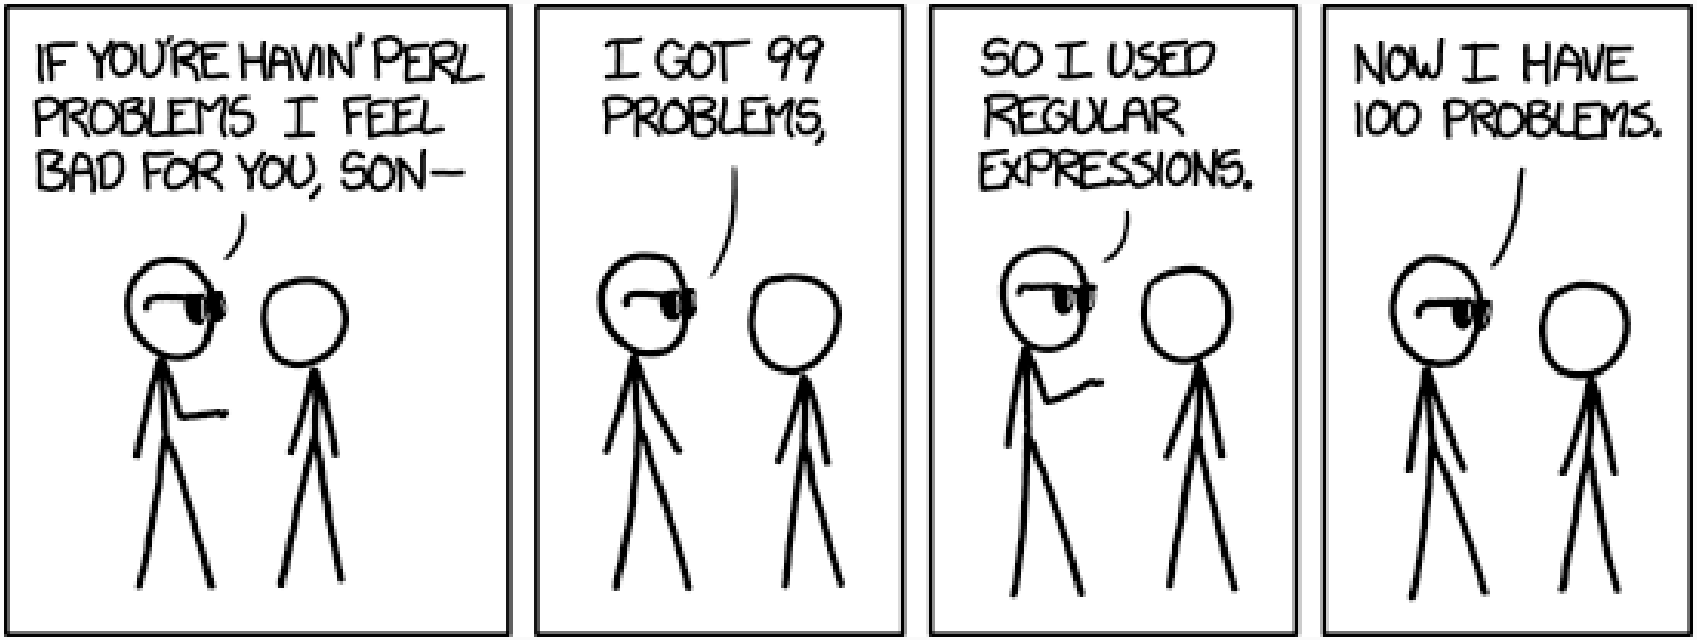

With regular expressions comes great responsibility (c)

Регулярные выражения

- Помогают искать какой-либо текст в другом тексте
- Описывают интересующий нас текст
- Работают достаточно эффективно

Почему бы просто не перечислить все варианты текста?

- `a@a.com`
- `b@a.com`
- `...`
- `a@b.com`
- `...`

Регулярные выражения?

- Регулярные выражения описывают *регулярные* строки
  - `KotlinAsFirst`
  - `[A-Z0-9._%+-]+@[A-Z0-9.-]+\.[A-Z]{2,}`
  - `^4[0-9]{12}(?:[0-9]{3})?$`
  - `[-+]?[0-9]*\.?[0-9]+`
  - `<([a-z]+)([^<]+)*(?:>(.*)<\/\1>|\s+\/>)`

Что такое регулярная строка?

Регулярные выражения!

- Регулярное выражение может быть распознано *конечным автоматом*

`[0-4][5-9]`

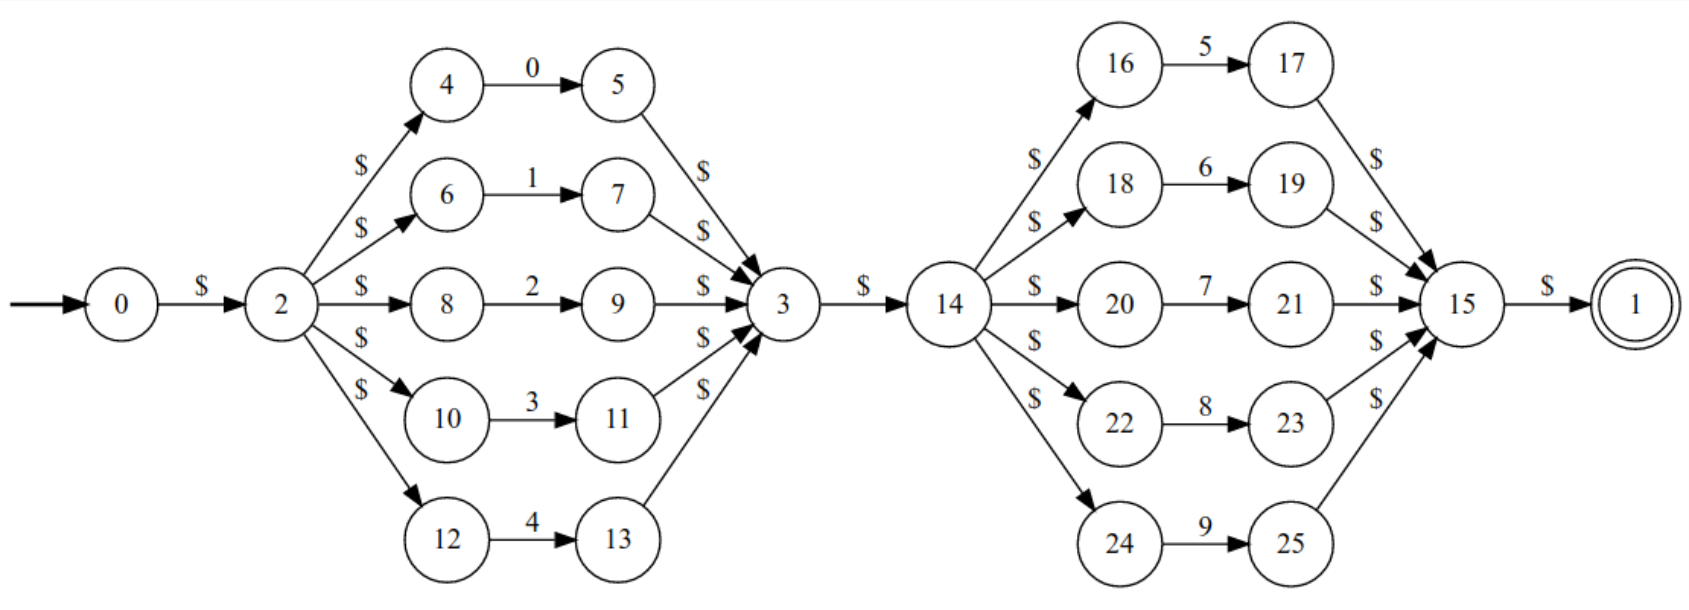

Конечный автомат

- Состояния
- Переходы между состояниями
- Условия переходов

(42)*

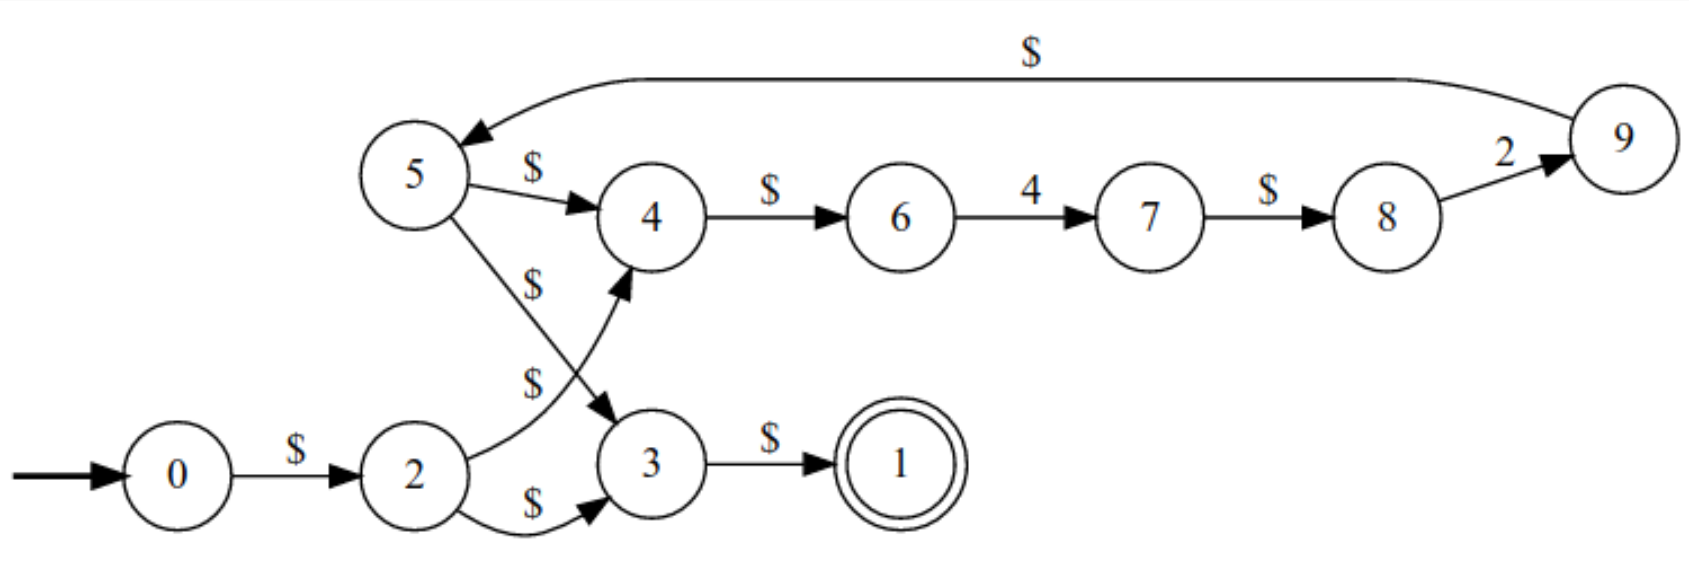

Возможности КА

- Я распознаю эту строку с 7 символов!

$$a\{n\}b\{n\}$$

Возможности КА

- КА не умеют *считать*
- КА не умеют рекурсию
- Нужна память
- Нужна зависимость от памяти

Регулярные выражения не являются универсальным способом анализа строк

Студенты часто думают иначе...

Строка

Обычный символ ищет сам себя...

- `KotlinAsFirst`
- `Трансмогрификация`
- `Мама мыла раму`
- `42`

...кроме ряда специальных символов (stay tuned!)

Классы символов

Класс символов ищет любой символ из определенного множества

- `[0123456789]`
- `[aeiouy]`
- `[~!@#$%^&*+-]`

Отрицание класса символов ищет любой символ НЕ из заданного множества

- `[^0123456789]`
- `[^a-z]`
- `[^-az]`

Якоря

Якоря ищут начало или конец всей строки...

- `^fun`
- `\.$`
- `^Kotlin is great as a first language!$`

...и не учитывают переводы строки

Особые символы

Особые символы ищут символы по специальным правилам

- `.`
- `\t\n\r\f\v`
- `\s\S`
- `\d\D`
- `\w\W`
- `\\`

Экранированные символы

Экранированные символы ищут сами себя

- `\^`
- `\$`
- `\.`
- `\[\]`
- `\|`

Шаблон выбора

Шаблон выбора ищет по ИЛИ

- `Марат|Михаил`
- `^\[|\]$`
- `for.*(val|var).*`

Шаблон количества

Шаблон количества ищет определенное число совпадений

- `.*`
- `(Марат)+`
- `(Михаил)?`
- `([0-9]{4}){4}`
- `\w{8,16}`
- `Kotlin(?:As)+First`

Группы поиска

Группы поиска объединяют несколько элементов вместе...

- `(Kotlin)+AsFirst`
- `(?:\$\$)+`

...и позволяют на них ссылаться

- `(\w+)\s\1`
- `fun\s+(\w+)\s*\{.*\1.*\}`

Группы особого поиска

Группы особого поиска ищут по-особому

- `Марат(?=\sАхин)`
- `(?<=Михаил\s)Глухих`
- `\d+(?![$\d])`
- `(?<!root\s)beer`

Regex в Kotlin

- `Regex("KotlinAsFirst")`
- `"KotlinAsFirst".toRegex()`
- `RegexOption`
  - `IGNORE_CASE`
  - `MULTILINE`
  - `LITERAL`
  - `UNIX_LINES`
  - `COMMENTS`
  - `DOT_MATCHES_ALL`
  - `CANON_EQ`

MatchResult

```
interface MatchResult {
    val groupValues: List<String>
    val groups: MatchGroupCollection
    val range: IntRange
    val value: String
}
```

find

```
fun Regex.find(
    input: CharSequence,
    startIndex: Int = 0
): MatchResult?

fun Regex.findAll(
    input: CharSequence,
    startIndex: Int = 0
): Sequence<MatchResult>
```

replace

```
fun Regex.replace(
    input: CharSequence,
    replacement: String
): String
fun CharSequence.replace(
    regex: Regex,
    replacement: String
): String
```

replace

```
fun Regex.replaceFirst(
    input: CharSequence,
    replacement: String
): String
fun CharSequence.replaceFirst(
    regex: Regex,
    replacement: String
): String
```

match

```
fun Regex.containsMatchIn(input: CharSequence): Boolean
operator fun CharSequence.contains(regex: Regex): Boolean

fun Regex.matches(input: CharSequence): Boolean
fun CharSequence.matches(regex: Regex): Boolean

fun Regex.matchEntire(input: CharSequence): MatchResult?
```

Резюме

- Регулярные выражения хорошо подходят для поиска *регулярных* строк
- Если вам нужно...
    - подсчитать количество скобок
    - учитывать одни группы при поиске других групп
    - делать что-то другое, что не умеет делать КА
- ...то лучше воспользоваться чем-то другим

Что дальше?

- http://regexr.com/
- https://regex101.com/
- ...and many more!

https://docs.oracle.com/javase/tutorial/essential/regex/