Регулярные выражения

История

Кен Томпсон добавил поиск по регулярному выражению в редактор QED в конце 1960-х, позаимствовав нотацию из теоретической статьи Клини

Из QED регулярные выражения перекочевали в ed – стандартный текстовый редактор системы

Стандарты

- Стандарт POSIX:
  - Basic Regular Expressions (BRE)
  - Extended Regular Expressions (ERE)

Поддерживаются в утилитах Unix

- Perl Compatible Regular Expressions

Из Perl синтаксис заимствован в Java, .NET, Python, Ruby, JavaScript, и т.д.

Пример

ls *.txt

Регулярные выражения

Формальный язык поиска и осуществления манипуляций с подстроками в тексте, основанный на использовании метасимволов (wildcard)

По сути это «шаблон», состоящий из символов и метасимволов и задающий правило поиска.

Шаблоны

Символы в шаблонах делятся на два типа:

- Литералы – обычные символы
- Метасимволы – символы, которые используются для замены других символов или их последовательностей

Литералы

Литералы:

- все символы за исключением специальных

  [ ] \ ^ $. | ? * + ( ) { }

- специальные символы предваренные \

  например: \[или \$

Метасимвол .

Обозначает один любой символ

Пример:

– st..d – регулярное выражение

– под его описание подходит:

standard

stand

astddd

Символьные классы

Позволяет указать, что на данном месте в строке может стоять один из перечисленных символов.

[A-Z] – любая заглавная латинская буква

[a-d] – строчная буква от a до d

[A-Za-z0-9] – Латинская буква или цифра

[А-Яа-яЁё] – любая русская буква

Символьные классы

Спецсимвол отрицания в символьных классах:

^ (крышка)

[^abc] - все символы (не буквы, а именно символы) кроме букв латинского алфавита a, b, c.

Перечисление

Вертикальная черта разделяет допустимые варианты. Например, gray|grey соответствует gray или grey

gr(a|e)y описывают строку gray или grey

Позиция внутри строки

Представление	Позиция	Пример	Соответствие
^	Начало строки	^a	aaa aaa
$	Конец строки	a$	aaa aaa
\b	Граница слова	a\b	aaa aaa
		\ba	aaa aaa
\B	Не граница слова	\Ba\B	aaa aaa

Квантификация

Представление	Число повторений	Пример	Соответствие
{n}	Ровно n раз	colou{3}r	colouuur
{m,n}	От m до n включительно	colou{2,4}r	colouur, colouuur, colouuuur
{m,}	Не менее m	colou{2,}r	colouur, colouuur, colouuuuur и т. д.
{,n}	Не более n	colou{,3}r	color, colour, colouur, colouuur
* {0,}	Ноль или более	colou*r	color, colour, colouur и т. д.
+ {1,}	Одно или более	colou+r	colour, colouur и т. д. (но не color)
? {0,1}	Ноль или одно	colou?r	color, colour

Пример

Проверка MAC-адреса

/^(?[0-9A-Fa-f]{2}:){5}[0-9A-Fa-f]{2}$/

Пример

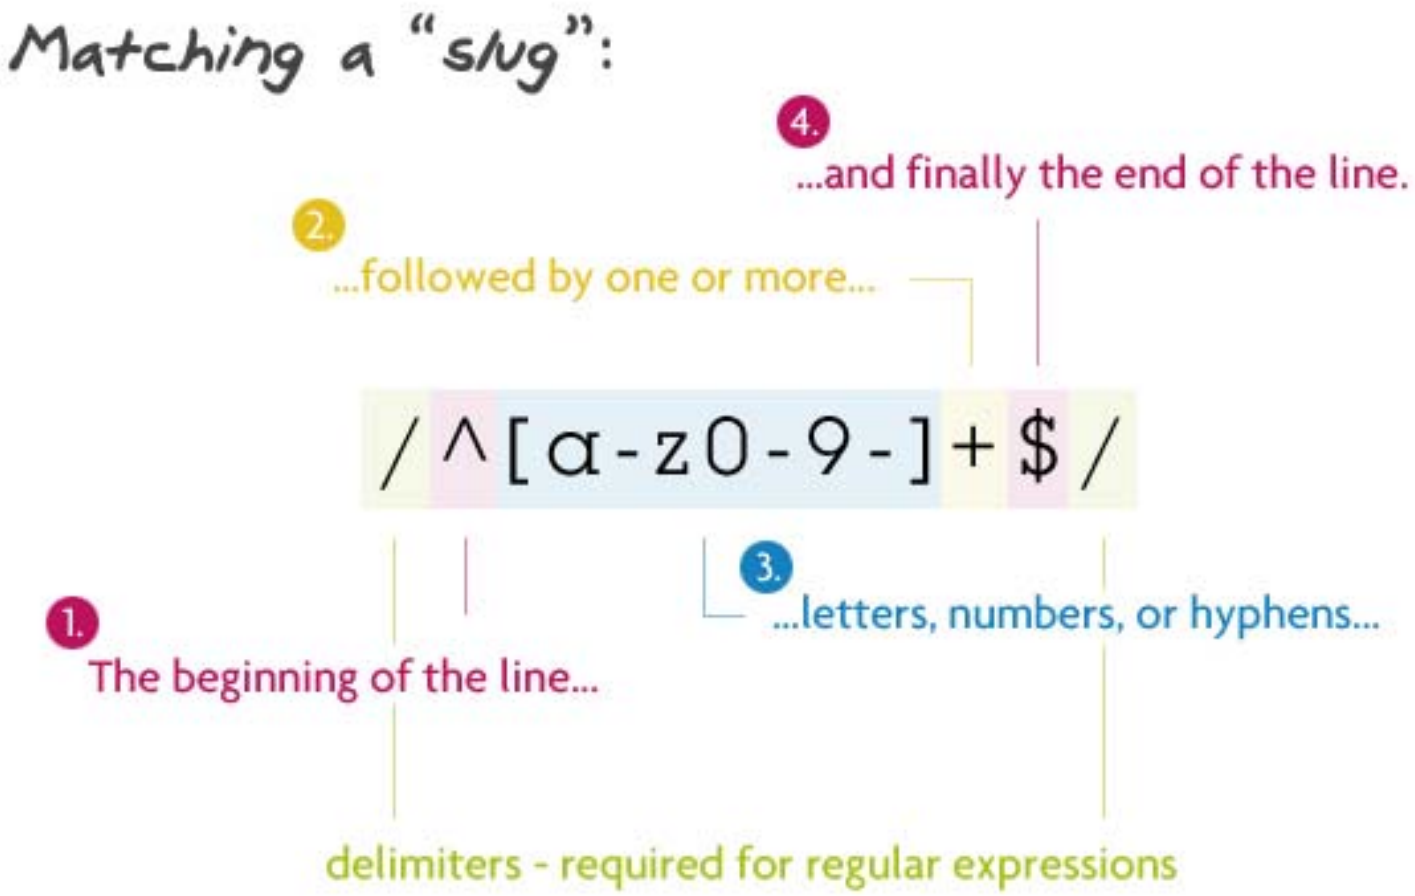
Matching a "slug":
4.
...and finally the end of the line.
2.
...followed by one or more...
/^[a-z0-9-]+$/
3.
...letters, numbers, or hyphens...
1.
The beginning of the line...
delimiters - required for regular expressions

Пример

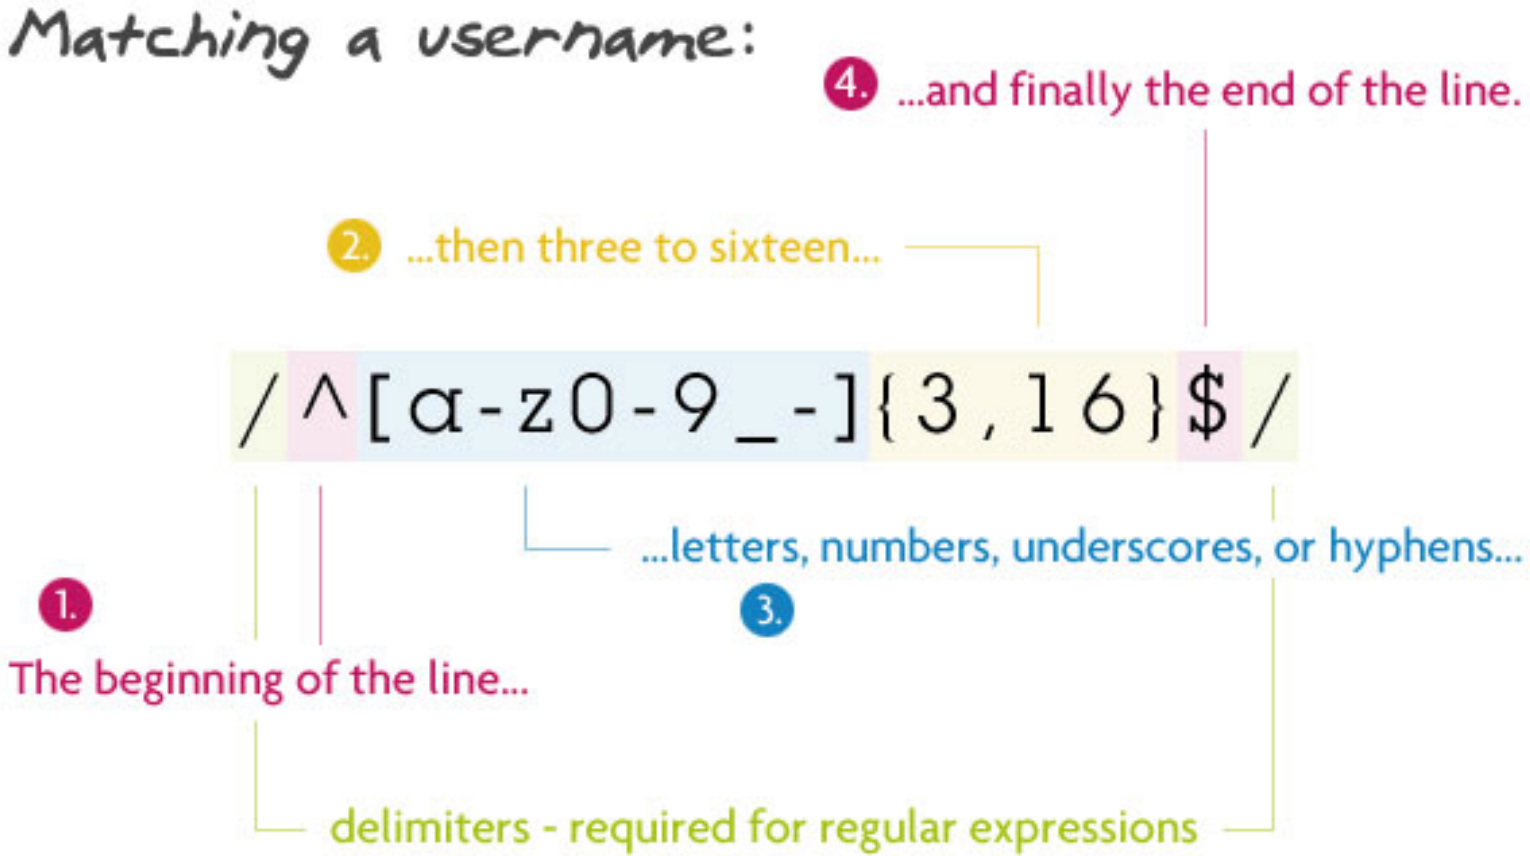
Matching a username:
4. ...and finally the end of the line.
2. ...then three to sixteen...
/^[a-z0-9_-]{3,16}$/
...letters, numbers, underscores, or hyphens...
3.
1.
The beginning of the line...
delimiters - required for regular expressions

Квантификация

«Ленивые» выражения

«Жадные» выражения

«Ревнивые»(сверхжадные) выражения

Жадный	Ленивый	Ревнивый
*	*?	*+
?	??	?+
+	+?	++
{n,}	{n,}?	{n,}+

Жадная квантификация

Выражение (<.*>) соответствует строке, содержащей несколько тегов HTML-разметки, целиком.

- Википедия — свободная энциклопедия, в которой каждый может изменить или дополнить любую статью

Ленивая квантификация

- Чтобы выделить отдельные теги, можно применить ленивую версию этого выражения: (<.*?>) Ей соответствует не вся показанная выше строка, а отдельные теги (выделены цветом):
- Википедия — свободная энциклопедия, в которой каждый может изменить или дополнить любую статью .

Ревнивая (сверхжадная) квантификация

Захватывает самое большое вхождение. В каком-то смысле, ещё «жаднее» жадных и идет дальше них: *один раз что-то «схватив», они никогда не откатываются назад, они не «отдают» кусочки схваченного ими следующим частям регекспа.*

Пример

"one" "two" "three" "test" "me"

- ".*"
- ".*? "
- ".*+"

Пример

"one" "two" "three" "test" "me"

- ".*"

  "one" "two" "three" "test" "me"

- ".*? "

  "one"

- ".*+"

  Ничего!

Группировка

Круглые скобки используются для определения области действия и приоритета операций.

Например, выражение (тр[ау]м-?)* найдёт последовательность вида трам-трам-трумтрам-трум-трамтрум.

Группировка с обратной связью

При обработке выражения подстро́ки, найденные по шаблону внутри группы, сохраняются в отдельной области памяти и получают номер начиная с единицы.

Каждой подстроке соответствует пара скобок в регулярном выражении.

Квантификация группы не влияет на сохранённый результат, то есть сохраняется лишь первое вхождение.

Пример

Пример:

(та|ту)-\1

Найдет:

та-та или ту-ту, но не та-ту

Группировка без обратной связи

(?:*шаблон*)

Под результат такой группировки не выделяется отдельная область памяти и, соответственно, ей не назначается номер.

Это положительно влияет на скорость выполнения выражения .

Атомарная группировка

(?>*шаблон*)

Не создает обратных связей.

Такая группировка запрещает возвращаться назад по строке, если часть шаблона уже найдена.

a(?>bc|b|x)cc	abccaxcc, но не abccaxcc
a(?>x*)xa	не найдётся axxxa

Напоминание

Существуют три типа регулярных выражений:

- BRE
- ERE
- PCRE

Basic Regular Expressions

Все символы трактуются буквально, исключая перечень в таблице

\(.*[.,]\)*

- Точка в [ ] и вне трактуется по-разному
- ( ) и { } в качестве синтаксического элемента необходимо предварять “\”

([0-9]*\.[0-9]*\$)

- Чтобы искать собственно точку, доллар и пр. метасимволы, их нужно предварять “\”
- ( ) и { } без “\” – ищет сами символы скобок!

Extended Regular Expressions

Добавлено:

? + |

Исключено:

\n – из-за высокой вычислительной стоимости

Изменено:

Символы скобок ( ) { } как синтаксические элементы не требуют “\” перед собой, для поиска самих этих символов “\” теперь нужен.

Выражения в стиле Perl

- Ленивые квантификаторы: *?, +?, ??
- Сверхжадные квантификаторы: *+, ++, ?+
- Сокращенные записи символьных классов: \w, \W, \s,\S, …
- Lookaheads и lookbehinds – подсказки алгоритму поиска
- Именованные группы связывания(named capture groups)
- Рекурсивные шаблоны.

GREP

В ed для любой правки нужно ввести команду

Одной командой пользовались часто:

g/регулярное выражение/p – найти и напечатать строки, соответствующие выражению

Для этой задачи сделали отдельную программу – grep.

grep

grep [options] PATTERN [FILE...]

grep 'регулярное выражение' 'файл‘

- grep -E '^(bat|Bat|cat|Cat)' heroes.txt
- grep -i -E '^(bat|cat)' heroes.txt

cat 'файл' | grep 'регулярное выражение‘

- cat heroes.txt | grep -E '^[bcBC]at‘

grep. Примеры

Вывод имен файлов, содержащих строки, соответствующие шаблону:

$ grep **–l** –E ‘^conf' /etc/*

То же самое, но включая подкаталоги:

$ grep **–l –r** –E ‘^conf' /etc/*

sed

sed [OPTION]... {script} [input-file]...

sed – “Stream EDitor”

Читает входной поток строка за строкой, на лету изменяя его в соответствии со скриптом.

Язык sed имеет всего около дюжины команд, но хитрости их применения достойны целой книги

Запуск sed

Для работы sed необходим скрипт. Его можно передать тремя способами:

- sed -e *script* [input-file]
- sed -f *script-file* [input-file]
- sed [options] *script* [input-file]

В последнем случае скриптом считается первый аргумент, не являющийся параметром ключа

Работа sed

- Sed построчно прочитывает весь вход один раз.
- К каждой строке поочередно применяется одна и та же последовательность команд, записанная в скрипте
- Результат направляется в stdout, если sed был запущен с ключом -i, то записывается поверх исходного файла

Работа sed

Sed имеет два буфера для данных:

- Pattern space – основной
- Hold space – дополнительный

Команды оперируют их содержимым.

Каждая вновь прочитанная строка входа автоматически записывается в *pattern space.* На вывод подается то, что в нем оказалось в конце работы скрипта.

Пример

Команда “=” добавляет номер в начало строки

```
$ sed -e '=' helloworld.cpp
1 #include <cstdio>
2 void main() {
3   printf("Hello, world\n");
4 }
```

Пример

Команда “d” очищает *pattern space* и заставляет прочитать следующую строку входа

$ sed -e 'd' helloworld.cpp

(вывод пуст – pattern space каждый раз очищается)

Пример

Можно указать номер строки, к которой применяется команда:

$ sed -e '3d' helloworld.cpp

```
#include <cstdio>
void main() {
}
```

Пример

Диапазон строк:

$ sed -e '2,4d' helloworld.cpp

#include <cstdio>

В файле осталась только первая строка.

Пример

Адресация по регулярному выражению:

$ sed -e '/{/,/}/d' helloworld.cpp

#include <cstdio>

Регулярное выражение должно быть окружено косыми чертами: “/ *regexp* /”

Sed по умолчанию ожидает регулярные выражения в синтаксисе BRE. Если вызвать с ключом -r, sed будет интерпретировать их как ERE.

Замена текста

$ sed -e 's/@/ at /' emails.txt

Было: john.doe@example.com

Стало: john.doe at example.com

Важно! Команда “s” в таком виде применяется к строке только один раз в том месте, где нашлось первое соответствие выражению.

Чтобы заменить все соответствия в строке, нужно добавить “g” (global):

$ sed -e 's/@/ at /g' emails.txt

Замена текста &

$ sed -r -e 's/[0-9]+:[0-9]+:[0-9]+/& UTC/' times.txt

Было: 21:16:15

Стало: 21:16:15 UTC

“&” заменяется найденной подстрокой

Замена текста \1..\9

$ sed -r -e 's/([0-9]+):([0-9]+):([0-9]+)/\1 hours \2 minutes \3 seconds/' times.txt

Было: 21:16:15

Стало: 21 hours 16 minutes 15 seconds

\n заменяется n-ой группой связывания

Вставка строк

a \text
Вставляет text ниже текущей строки (append)
i \text
Вставляет text выше текущей строки (insert)
c \text
Вставляет text вместо текущей строки
Пример:$ sed -e 'a \ \n' readme.txt
Команда вставляет дополнительный перенос строки в конце каждой из строк

Про hold space

$ sed -e '1!G;h;$!d' forward.txt > backward.txt

Команда переставляет строки файла в обратном порядке

1!G – для каждой строки, кроме первой, дописывает содержимое hold space в конец patten space

h – копирует содержимое pattern space в hold space

$!d – применяет “d” ко всем строкам, кроме последней

Итого, по завершении работы, в pattern space содержится “перевернутый” текст

Задания на дом

1. Распознавать MAC-адрес короче, чем было написано в презентации.
2. Написать regexp для разбора ip-адреса. Написать надо именно команду (cat file | grep...)
3. Имя, Фамилия, Телефон -- телефонная книжка в csv. Преобразовать в html, который запустится в браузере. Только с помощью sed!

Задания на дом

5. Файл file.c, вывести все хедеры (только имена самих библиотек).

6. Утилита /sbin/ifconfig, выводит названия интерфейсов и их параметры. Все IP-адреса всех интерфейсов заменить на xxx.x.x.x, каждый икс соответствует одной цифре в IP-адресе. Разделить интерфейсы строкой дефисов.

Задания на сейчас

1. Из файла написанного, на C вытащить все строковые константы.
2. См. выше, но строки не должны входить в комментарии