



# Компьютерные технологии в научных исследованиях

Лабораторная работа №2

Основы регулярных выражений в Tcl

```
1 #!/bin/bash
2 #INPUT_SAMPLE_LIST=$1
3 cd /Volumes/PhilDrive_EMS/TestDec7/snv_postp
4
11 . paths.txt
12
30
31 echo "Debug level set for $DEBUG_LEVEL"
32 echo "log found in scripts directory"
33
50 cp $HIGH_SNP_OUT ./
51 cp $LOW_SNP_OUT ./
52 cp $GERM_SNP_OUT ./
53 # echo "${SCRIPT_DIR}/run_somatic_mu
54 if [ $DEBUG_LEVEL
55 then
56 echo "INFO: ${SCR
57 `basename ${LOW_S
58 ${D_BAM_FILE} ${G
59
60 fi
61 ${SCRIPT_DIR}run_somatic_mutation_ana
62
```



## Регулярные выражения

Регулярные выражения позволяют производить поиск подстрок в строке не на основании точного соответствия, а на основе некоторого шаблона.

```
regexp ?switches? template string ?matchVar? ?subMatchVar1? ...
```

```
regexp {[Y|y][E|e][S|s]} "Yes"
```



Шаблон

Строка, в которой ищется соответствие

Возвращаемое значение: 0 - если нет соответствия

1 – если соответствие есть

```
set a [regexp {[Y|y][E|e][S|s]} "String has yes in the middle"]
```

## Что может входить в состав регулярного выражения?

В состав регулярного выражения могут входить:

1. литеральные символы,
2. наборы и классы символов,
3. итераторы,
4. операторы выбора,
5. вложенные шаблоны.

## Литеральные символы

Простые символы – точное соответствие шаблону.

`regexp {ab} "a"` → 0

`regexp {ab} "b"` → 0

`regexp {ab} "ab"` → 1

`regexp {ab} "abba"` → 1

`regexp {ab} "12ab34"` → 1

Универсальный заменитель – символ «.»

`regexp {ab} "ab"` → 1

`regexp {a.} "ar"` → 1

## Наборы символов (1)

Конкретный выбор символа:

```
regex {[Hh]ello} "A hello string" → 1
```

```
regex {[Hh]ello} "A Hello string" → 1
```

```
regex {[Hh]ello} "A hellO string" → 0
```

```
regex {[Hh]ello} "A hell string" → 0
```

Допустимый диапазон символов:

```
regex {[a-z]ello} "A mello string" → 1
```

```
regex {[a-z]ello} "A Hello string" → 0
```

## Наборы символов (2)

Объединение групп символов:

```
regex { [a-z]ello } "A Hello string" → 0
```

```
regex { [a-zA-Z]ello } "A Hello string" → 1
```

```
regex { [a-z0-9]ello } "A 234ellostr" → 1
```

Исключение отдельных символов или групп символов:

```
regex { [^a-z]ello } "A Hello string" → 1
```

```
regex { [^a-z]ello } "A hello string" → 0
```

```
regex { [^a-z]ello } "A 234ellostr" → 1
```

## Классы символов (1)

Классом называется именованный набор символов

[ :идентификатор: ]

[a-zA-Z] → [[:alpha:]]

[0-9] → [[:digit:]]

[ \b\n\r\t ] → [[:space:]]

regexp { [[:alpha:]][[:digit:]][[:alpha:]] } "a8a" → 1

## Классы символов (2)

Имя класса	Значение	Сокращение
<code>alnum</code>	Буквы верхнего и нижнего регистра, цифры	<code>\w</code>
<code>alpha</code>	Буквы верхнего и нижнего регистра	
<code>blank</code>	Пробелы и знаки табуляции	<code>\s</code>
<code>digit</code>	Цифры от 0 до 9	<code>\d</code>
<code>lower</code>	Буквы нижнего регистра	
<code>print</code>	То же, что и класс <code>alnum</code>	<code>\w</code>
<code>punct</code>	Знаки пунктуации	
<code>space</code>	Пробел, перевод строки, <code>\n</code> , <code>\t</code> и т.д.	<code>\s</code>
<code>upper</code>	Буквы верхнего регистра	
<code>xdigit</code>	Шестнадцатеричные цифры 0-9,a-f,A-F	

## Итераторы

"\*" - любое число вхождений предыдущего компонента

"+" – одно или более повторение

"?" – нулевое или единичное повторение

```
regexp ?switches? template string ?matchVar? ?subMatchVar1? ...
```

```
regexp {\w} "This is sample" var → 1, var = "T"
```

```
regexp {\w*} "This is sample" var → 1, var = "This"
```

```
regexp {\w+} "This is sample" var → 1, var = "This"
```

## Наиболее часто использующиеся ключи команды `regexp`

`regexp` ?switches? template string ?matchVar? ?subMatcVar1? ...

**-nocase** - делает сравнение без учёта регистра, формально переводя строку в нижний регистр

**-expanded** – позволяет добавлять комментарий к регулярному выражению в виде:

```
regexp -expanded {  
    ^                # beginning of string  
    [^: ]+          # all characters to the first colon  
    (?=             # begin positive lookahead  
    .*\.com$       # for a trailing .com  
    )               # end positive lookahead  
} $x match
```

## Якоря

Якорь `"^"` - признак начала строки

Якорь `"$"` - признак конца строки

```
regexp {[0-9]+} "123 456 789" v      → 1, v = "123"
```

```
regexp {^d+} "123 456 789" v
```

```
regexp {[0-9]+$} "123 456 789" v    → 1, v = "789"
```

```
regexp {d+$} "123 456 789" v
```

## Использование скобок

```
regexp template string ?matchVar? ?subMatchVar1? ...
```

```
regexp {\w+(\d)\w+(\d)} "a1b2" v1 v2 v3
```

```
v1 = "a1b2"
```

```
v2 = "1"
```

```
v3 = "2"
```

```
regexp {^module\s(\w+)} "module inverter (in, out);" a b
```

```
a = "module inverter"
```

```
b = "inverter"
```

## Квантификаторы

```
set ret [regexp {(ab){3}} "pababababf" a]  
puts $ret  
if {$ret} {  
    puts stdout $a  
}
```

```
set ret [regexp {(ab){3,}} "pababababf" a]  
puts $ret  
if {$ret} {  
    puts stdout $a  
}
```

```
set ret [regexp {(ab){2,4}} "pababababf" a]  
puts $ret  
if {$ret} {  
    puts stdout $a  
}
```

## Домашнее задание

Скрипту передаётся в качестве аргументов командной строки перечень файлов. Нужно для каждого из них (при условии, что файлы существуют и являются файлами формата HSPICE - .sp или .cir) выполнить действие согласно варианту.

### **Для нечётных номеров вариантов:**

С помощью регулярных выражений из входного нетлиста HSPICE вывести имена всех моделей и их уровень (level), для которых какой-либо параметр (выбрать) задаётся в единицах микрометров (с помощью U или u) (не 0.1u и не 12u).

### **Для чётных номеров вариантов:**

С помощью регулярных выражений из входного файла моделей HSPICE вывести имена транзисторов и их моделей, для которых какой-либо параметр (выбрать) задаётся в единицах микрометров (с помощью U или u) (не 0.1u и не 12u).