

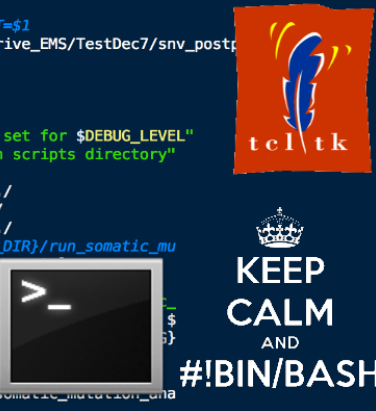


Компьютерные технологии в научных исследованиях

Лабораторная работа №2

Регулярные выражения 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_SN
58 ${D_BAM_FILE} ${G
59
60 fi
61 ${SCRIPT_DIR}run_somatic_mu
62
```





Регулярные выражения

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

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

```
regex { [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 [regex { [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.

regex {ab} "a" → 0

regex {ab} "b" → 0

regex {ab} "ab" → 1

regex {ab} "abba" → 1

regex {ab} "12ab34" → 1

Универсальный заменитель – символ «.»

regex {a.} "a" → 0

regex {a.} "ar" → 1

Наборы символов

Конкретный выбор символа:

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

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

```
regexp {[Hh]ello} "A hello string" → 0
```

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

Допустимый диапазон символов:

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

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

Наборы символов

Объединение групп символов:

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

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

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

Исключение отдельных символов или групп символов:

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

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

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



Некоторые классы символов и их сокращения

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



Итераторы, квантификаторы

"*" - любое число вхождений предыдущего компонента

"+" – одно или более повторение

"?" – нулевое или единичное повторение

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

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

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

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




Наиболее часто используемые ключи команды `regexp`

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

-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? ?subMatcVar1? ...
```

```
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"
```