文本处理命令（二）

多才多艺的sed命令

Linux命令之翻译家 tr

Linux命令之剪刀手 awk

瘦死的骆驼比马大 perl

多才多艺的sed命令

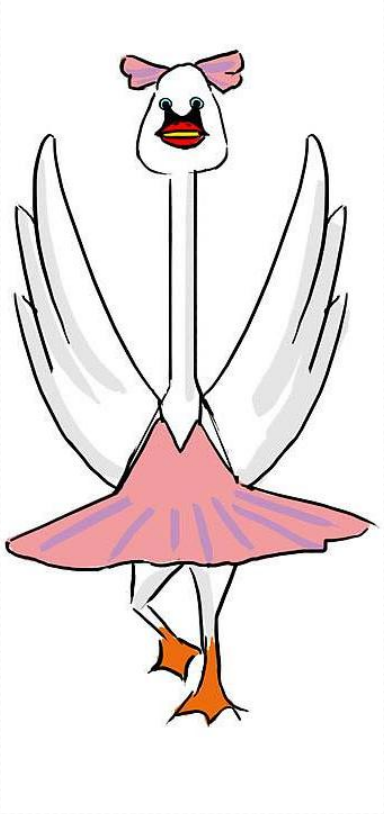

sed命令档案

命令全名： stream editor（流编辑器）

命令用途： 过滤或修改文本

命令格式： sed [option] command file

sed [option] -f script_file file

常用选项：

-f script_file	从脚本文件script_file读取要执行的命令
-n	仅输出command处理后的结果
-i	直接修改原文件

sed命令用法

- 替换文件中部分文本

  $sed '1,3s/cat/CAT/g' animal

- 将包含每个模式的行修改为指定文本

  $cat animal | sed '/dog/c\old dog'

- 取出部分文本

  $cat animal | sed –n '1~2p'

sed命令脚本格式

$sed '1,3s/cat/CAT/g' animal

sed命令脚本=操作范围+操作符：

1,3s/cat/CAT/g

/dog/c\old dog

1~2p

操作范围

- 绝对地址：2　　3,5　　%（或1,$）
- 相对地址：2,+3
- 匹配地址：/dog/　/dog/,/pig/
- 组合地址：1,/pig/　/dog/,+1
- 步进地址：n~m（n为起始行号，m为步长），如：

  1~2（奇数行）

  2~2（偶数行）

  2~3（2,5,8,…行）

操作符

- p操作：2p　　#打印第2行
- =操作：/g/=　　#打印匹配到g的行的行号
- d操作：3,5d　　#删除第3-5行
- s操作：%s/a/A/g　　#替换所有的a为A
- a操作：2a\apple　　#在第2行后面一行添加apple
- i操作：4i\apple　　#在第4行前面插入apple
- c操作：/dog/c\old dog　　#将包含dog的行的内容修改为old dog

Linux命令之翻译家--tr命令

tr命令档案

命令全名： translate

命令用途： 转换或删除字符

命令格式： tr [option] set1[set2]

常用选项：

-d 删除字符集set1指定的字符

tr命令用法

- 转换一个字符，如
  - $tr a A <animal
- 将小写字母转换成大写字母，如
  - $tr [:lower:] [:upper:] <animal 或
  - $tr a-z A-Z <animal
- 删除字符，如
  - $cat animal | tr -d ‘dog’ #删除字符d、o、g

字符集语法

普通字符集：‘abc’‘135’…（任意字符的集合，顺序无关）

字符范围：a-z A-Z 0-9 …（ASCII表顺序）

转义字符：\n \r \t …

字符类：

[:alnum:]	字母和数字
[:alpha:]	字母
[:cntrl:]	控制（非打印）字符
[:digit:]	数字
[:graph:]	图形字符
[:lower:]	小写字母
[:print:]	可打印字符
[:punct:]	标点符号
[:space:]	空白字符
[:upper:]	大写字母
[:xdigit:]	十六进制字符

字符集替换规则

- set1=set2：逐一替换

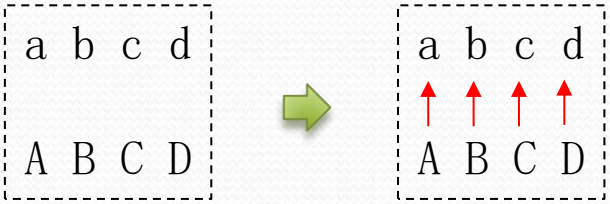

- set1<set2：set2多余的不用

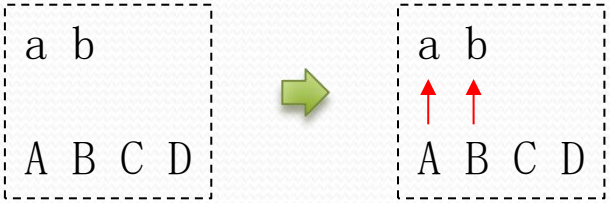

- set1>set2：set2最后一个字符重复使用至set1最后一个字符

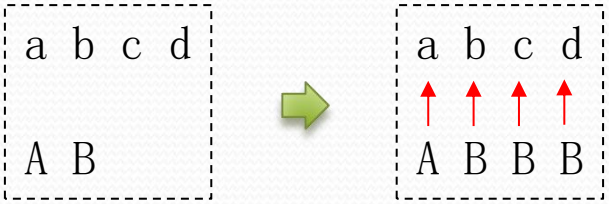

Linux命令之剪刀手--awk命令

awk命令档案

命令全名： Aho-Weinberger-Kernighan

命令用途： 处理并格式化文本

命令格式：

awk [options] 'script' file

awk [options] -f scriptfile file

常用选项：

-F　指定输入文件的字段分隔符，默认是任何空白字符

-f　从脚本文件中读取awk脚本

相关概念

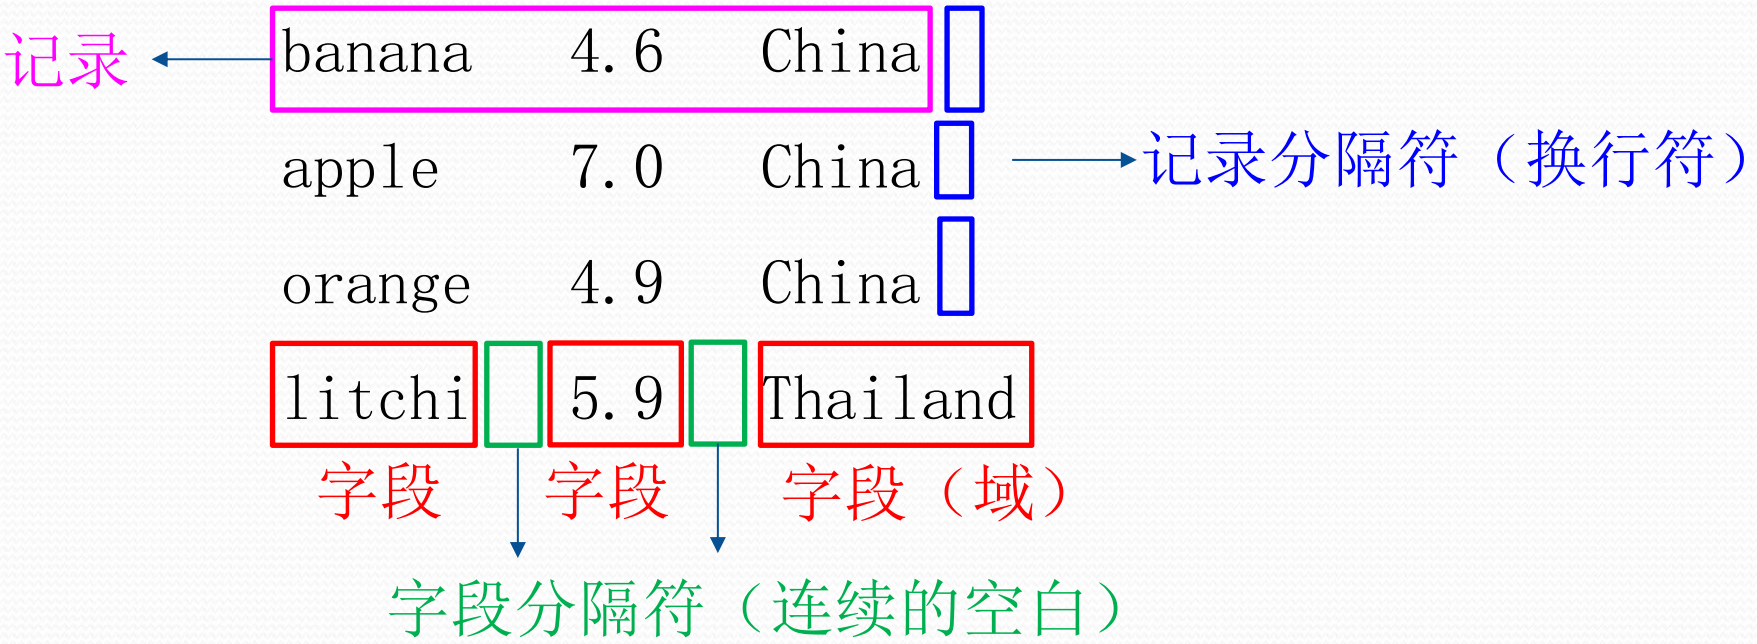
记录
banana 4.6 China
apple 7.0 China
orange 4.9 China
litchi 5.9 Thailand
记录分隔符（换行符）
字段
字段
字段（域）
字段分隔符（连续的空白）

awk脚本基本格式

- ‘BEGIN{ actions } pattern{ actions } END{ actions }’
  - BEGIN{ actions }：在从文件或标准输入读入数据前执行
  - pattern{ actions }：每从文件或标准输入中读取一行就执行一次
  - END{ actions }：处理完从文件或标准输入读入的数据后执行
- pattern（模式）
  - 条件表达式，如：$2>5（第二个字段的值大于5）
  - 正则表达式，如：/apple/（记录中如果包含apple）
  - 模式范围，如：/apple/,/orange/（apple第一次出现至orange第一次出现之间的所有的行）
  - 模式匹配表达式，如：$1~/^a/（第一个字段是a开头的行）
- actions（操作）
  - 打印，如：print $1（打印第1个字段）
  - 变量赋值，如：total=0
  - 算术运算，如：total+=$2
  - ……

实例：表格处理

```
$awk 'BEGIN{OFS="\t";print "Month","Salary"}\
      $1>6{print;total+=$2}\
      END{print "Total",total}' income
```

1	5200
2	5400
3	5400
4	5500
5	6000
6	5700
7	5600
8	5500
9	5400
10	5000
11	5800
12	6800

Month	Salary
7	5600
8	5500
9	5400
10	5000
11	5800
12	6800
Total	34100

处理过程：

添加表头(BEGIN)

打印并累加符合
月份>6的条件的工资

打印工资总额(END)

awk编程

- awk变量
  - 内置变量：$0, $1, NF, FS, OFS, RS, ORS, …
  - 自定义变量：num, total, fruit_price, …
  - 数组：price[1]=3.9（下标形式）, price[“apple”]=4.5（键值形式）
- awk控制结构
  - 判断：if($1>6){print $2}
  - 循环：for(i=1;i<6;i++){…}, for(i in price){…}, while(i<5){…}, do{…}while(i<5)
- awk函数
  - 内置函数：log(), sin(), index(), systime()…
  - 自定义函数：function sum(){…}

awk内置变量

- $n　当前记录的第n个字段
- $0　整个当前记录
- NF　当前记录中的字段数（Number of Fields）
- FS　输入的字段分隔符（默认是任何连续空白字符）（Field Separator）
- OFS　输出字段分隔符（默认是一个空格）（Output Field Separator）
- RS　输入记录分隔符（默认是一个换行符）（Record Separator）
- ORS　输出记录分隔符（默认是一个换行符）（Output Record Separator）
- ……

awk的更多应用

- 打印包含某个模式的记录

  $awk '/^(apple|banana)/' price

  'BEGIN{ actions } pattern{ actions } END{ actions }'

- 打印某个字段符合某条件的记录的部分字段

  $awk '$2>6000{print $1}' income

  'BEGIN{ actions } pattern{ actions } END{ actions }'

- 重排列的位置

  $cat price | awk '{print $1,$3,$2}'

  'BEGIN{ actions } pattern{ actions } END{ actions }'

grep、sed与awk总结

- Linux文本处理三剑客
  - grep　更适合单纯的查找或匹配文本
  - sed　更适合编辑匹配到的文本
  - awk　更适合格式化文本，对文本进行较复杂地格式处理

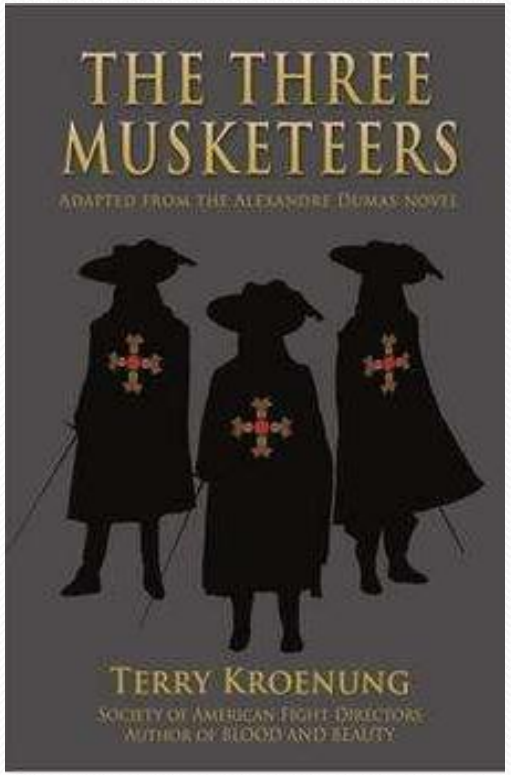

瘦死的骆驼比马大--perl命令

perl命令档案

命令全名： perl

命令用途： 文本处理，类似于sed

命令格式：

perl –pe script file

perl –ne script file

常用选项：

-e 在命令行而不是在脚本中执行perl

-n 使 Perl 隐式地循环遍历指定的文件，并只打印代码里规定输出的行。自动循环， 相当于 while(<>) { 脚本; }

-p 使 Perl 隐式地循环遍历指定的文件，同时打印所有的行。自动循环+自动输出， 相当于 while(<>) { 脚本; print; }

perl命令用法

- 模式替换
  - $ cat plant | perl -pe 's/rose/Rose/g'
- 每行的首字母改成大写
  - $ perl -ne 'print ucfirst()' plant

课堂作业3（CW3）

（1）统计文件/home/pub/seq/TAIR9_pep_20090619.gz文件中蛋白质序列的数目，并把结果保存到本目录下文件at_protein_num中；

（2）取出文件/home/pub/seq/TAIR9_pep_20090619.gz的10237-10242行，并保存到本目录下文件at_ppr中；

（3）取出文件/home/pub/data/animal_num（空白处为制表符）的第1列文本，并保存到本目录下文件animal_name中；

（4）取出文件/home/pub/data/at_NFY_len_format（空白处为连续的空格）的第1列文本，并保存到本目录下文件at_NFY_id中。


CHONGQING UNIVERSITY OF POSTS AND TELECOMMUNICATIONS
重庆邮电大学
1950

The End