

第二次作业

Unix 下数据处理练习：

Cut：

cut 一般格式为：

cut [options] file1 file2

下面介绍其可用选项：

-c list 指定剪切字符数。

-f field 指定剪切域数。

-d 指定与空格和 tab 键不同的域分隔符。

-c 用来指定剪切范围，如下所示：

-c1,5-7 剪切第 1 个字符，然后是第 5 到第 7 个字符。

-c1-50 剪切前 50 个字符。

-f 格式与 -c 相同。

-f1,5 剪切第 1 域，第 5 域。

-f1,10-12 剪切第 1 域，第 10 域到第 12 域。

cut -f n inputfile 表示把第 n 个**字符段**剪切出来并显示

cut -f n,m inputfile 表示把第 n 个和第 m 个字符段剪切并显示

cut -f n-m inputfile 表示把第 n 个到第 m 个字符段剪切并显示

cut -f 1,n-m inputfile 表示把第 1 个和第 n 个到第 m 个字符段剪切并显示

cut -c n-m inputfile 表示把第 n 个到第 m 个**字符**剪切出来并显示

同样的练习**-c** 的用法。

Paste：

用 paste 可以将一些数据粘贴起来形成相关文件。

粘贴两个不同来源的数据时，首先需将其分类，并确保两个文件行数相同。paste 将按行将不同文件行信息放在一行。缺省情况下，paste 连接时，用空格或 tab 键分隔新行中不同文

本，除非指定-d 选项，它将成为域分隔符。

paste 格式为：

```
paste -d -s -file1 file2
```

选项含义如下：

-d 指定不同于空格或 tab 键的域分隔符。例如用@分隔域，使用-d @。

-s 将每个文件合并成行而不是按行粘贴。

- 使用标准输入。例如，ls -l |paste 意即只在一列上显示输出。

```
paste inputfile1 inputfile2
```

```
paste -d: inputfile1 inputfile2
```

```
paste -s inputfile1 inputfile2
```

```
ls -l |paste
```

Sed: sed ‘操作的内容’ 文件名

，使用模式和行号进行查询：查找文件中的相应行号的文本 **sed -n ‘行号 p’ 文件名**

查找文件中的包含相应文本行的文本 **sed -n ‘/文本/’ 文件名**

，插入文本：在选定的行的最前面插入目标文本 **sed ‘/文本/i\目标文本’ 文件名**

，附加文本：在选定的行最后面附加目标文本 **sed ‘/文本/a\目标文本’ 文件名**

，修改文本：对选定的行进行修改成目标文本 **sed ‘/文本/c\目标文本’ 文件名**

，删除文本：删除所选的行 **sed ‘/文本/d’ 文件名**

，替换文本：把所选的文本改成目标文本 **sed ‘s/文本/目标文本/’ 文件名**

附：其中/文本/是用来确定所要修改内容所在的行，所以当然其可以直接用行号来代替。

替换文本一项中/文本/确是直接所要修改的内容而非修改行，如果要全文件对某一文本进行修改则用：**sed ‘s/文本/目标文本/g’ 文件名**

Awk：使用 awk 的第一个理由是基于文本的样式扫描和处理是我们经常做的工作，awk 所做的工作有些象数据库，但与数据库不同的是，它处理的是文本文件，这些文件没有专门的存储格式，普通的人们就能编辑、阅读、理解和处理它们。而数据库文件往往具有特殊的存储格式，这使得它们必须用数据库处理程序来处理它们。

awk 提供两种变量，一种是 awk 内置的变量，这前面我们已经讲过，需要着重指出的是，与后面提到的其它变量不同的是，在 awk 程序中引用内置变量不需要使用标志符"\$"（回忆一下前面讲过的 NR 的使用）。awk 提供的另一种变量是自定义变量。awk 允许用户在 awk 程序语句中定义并调用自己的变量。当然这种变量不能与内置变量及其它 awk 保留字相同，在 awk 中引用自定义变量必须在它前面加上标志符"\$"。与 C 语言不同的是，awk 中不需要对变量进行初始化，awk 根据其在 awk 中第一次出现的形式和上下文确定其具体的数据类型。当变量类型不确定时，awk 默认其为字符串类型。这里有一个技巧：如果你要让你的 awk 程序知道你所使用的变量的明确类型，你应当在在程序中给它赋初值

Awk 中内置变量及其含义：

FILENAME 当前输入文件的名字

FS 输入字段分隔符 空格

NF 当前记录中的字段个数

NR 已经读出的记录数

OFMT 数字的输出格式 %.6g

OFS 输出字段分隔符 空格

ORS 输出的记录分隔符 换行

RS 输入的记录他隔符 换行

与其它 UNIX 命令一样，awk 拥有自己的语法：

```
awk [-F re] [parameter...] ['prog'] [-f progfile][in_file...]
```

参数说明：

-F re:允许 awk 更改其字段分隔符。

parameter: 该参数帮助为不同的变量赋值。

'prog': awk 的程序语句段。这个语句段必须用单括号：'和'括起，以防被 shell 解释。这个程序语句段的标准形式为：

```
'pattern {action}'
```

() , {} , “ ” , ‘ ’ 这四个符号的用处要弄明白。

其中 `pattern` 参数可以是 `egrep` 正则表达式中的任何一个，它可以使用语法 `/re/` 再加上一些样式匹配技巧构成。与 `sed` 类似，你也可以使用 `,"` 分开两样式以选择某个范围。关于匹配的细节，你可以参考附录，如果仍不懂的话，找本 UNIX 书学学 `grep` 和 `sed`。`action` 参数总是被大括号包围，它由一系统 `awk` 语句组成，各语句之间用 `;"` 分隔。`awk` 解释它们，并在 `pattern` 给定的样式匹配的记录上执行其操作。与 `shell` 类似，你也可以使用 `#` 作为注释符，它使 `#` 到行尾的内容成为注释，在解释执行时，它们将被忽略。你可以省略 `pattern` 和 `action` 之一，但不能两者同时省略，当省略 `pattern` 时没有样式匹配，表示对所有行（记录）均执行操作，省略 `action` 时执行缺省的操作——在标准输出上显示。

`-f progfile`: 允许 `awk` 调用并执行 `progfile` 指定有程序文件。`progfile` 是一个文本文件，他必须符合 `awk` 的语法。

`in_file`: `awk` 的输入文件，`awk` 允许对多个输入文件进行处理。值得注意的是 `awk` 不修改输入文件。如果未指定输入文件，`awk` 将接受标准输入，并将结果显示在标准输出上。`awk` 支持输入输出重定向。

我们一下面的文本文件来练习上面的 `cut`，`paste`，`sed` 三个命令，已达到认识其功能的目的，把文件一改写成文件二。

第一列表示每一行都是一个原子，

第二列原子的序号

第三列原子在特定的力场数据库下的记号

第四列原子所在的氨基酸的简称

第五列原子所在氨基酸的序号

第六至八时原子的 `x`，`y`，`z` 坐标

第九至十列是其它信息

第十一列表示原子名称

文件一：

ATOM	1	N	PHE	2	1.378	-1.795	-1.043	1.00	0.00	N
ATOM	2	CA	PHE	2	1.893	-0.429	-1.043	1.00	0.00	C
ATOM	3	C	PHE	2	3.403	-0.419	-1.043	1.00	0.00	C
ATOM	4	O	PHE	2	4.076	-1.172	-0.286	1.00	0.00	O
ATOM	5	CB	PHE	2	1.385	0.334	0.218	1.00	0.00	C

ATOM	6	CG	PHE	2	-0.139	0.429	0.393	1.00	0.00	C
ATOM	7	CD1	PHE	2	-0.821	-0.586	1.074	1.00	0.00	C
ATOM	8	CD2	PHE	2	-0.860	1.483	-0.173	1.00	0.00	C
ATOM	9	CE1	PHE	2	-2.208	-0.556	1.171	1.00	0.00	C
ATOM	10	CE2	PHE	2	-2.248	1.518	-0.066	1.00	0.00	C
ATOM	11	CZ	PHE	2	-2.921	0.497	0.603	1.00	0.00	C
ATOM	12	HA	PHE	2	1.547	0.085	-1.960	1.00	0.00	H
ATOM	13	HB2	PHE	2	1.801	1.361	0.219	1.00	0.00	H
ATOM	14	HB1	PHE	2	1.822	-0.122	1.130	1.00	0.00	H
ATOM	15	HD1	PHE	2	-0.276	-1.423	1.490	1.00	0.00	H
ATOM	16	2HD	PHE	2	-0.346	2.267	-0.712	1.00	0.00	H
ATOM	17	HE1	PHE	2	-2.727	-1.360	1.672	1.00	0.00	H
ATOM	18	HE2	PHE	2	-2.802	2.331	-0.512	1.00	0.00	H
ATOM	19	HZ	PHE	2	-3.998	0.515	0.675	1.00	0.00	H
ATOM	20	H	PHE	2	1.259	-2.110	-0.091	1.00	0.00	H
ATOM	21	H	PHE	2	2.030	-2.401	-1.521	1.00	0.00	H
ATOM	22	N	PHE	3	4.111	0.495	-1.952	1.00	0.00	N
ATOM	23	CA	PHE	3	5.536	0.277	-1.725	1.00	0.00	C
ATOM	24	C	PHE	3	6.291	1.585	-1.720	1.00	0.00	C
ATOM	25	O	PHE	3	5.709	2.692	-1.895	1.00	0.00	O
ATOM	26	CB	PHE	3	6.122	-0.638	-2.843	1.00	0.00	C
ATOM	27	CG	PHE	3	5.476	-2.023	-3.002	1.00	0.00	C
ATOM	28	CD1	PHE	3	4.368	-2.176	-3.844	1.00	0.00	C
ATOM	29	CD2	PHE	3	5.941	-3.119	-2.271	1.00	0.00	C
ATOM	30	CE1	PHE	3	3.722	-3.404	-3.937	1.00	0.00	C
ATOM	31	CE2	PHE	3	5.301	-4.351	-2.373	1.00	0.00	C
ATOM	32	CZ	PHE	3	4.190	-4.492	-3.204	1.00	0.00	C
ATOM	33	HA	PHE	3	5.673	-0.201	-0.736	1.00	0.00	H
ATOM	34	HB2	PHE	3	7.208	-0.777	-2.672	1.00	0.00	H
ATOM	35	HB1	PHE	3	6.080	-0.109	-3.817	1.00	0.00	H
ATOM	36	HD1	PHE	3	3.980	-1.328	-4.392	1.00	0.00	H
ATOM	37	HD2	PHE	3	6.789	-3.011	-1.608	1.00	0.00	H
ATOM	38	HE1	PHE	3	2.850	-3.504	-4.566	1.00	0.00	H
ATOM	39	HE2	PHE	3	5.659	-5.193	-1.800	1.00	0.00	H
ATOM	40	HZ	PHE	3	3.684	-5.443	-3.274	1.00	0.00	H
ATOM	41	H	PHE	3	3.694	1.144	-2.604	1.00	0.00	H
END										

文件二:

PHE1 1 N 2.378 0.205 1.957

The fisrt residue

PHE1	2	C	2.893	1.571	1.957
------	---	---	-------	-------	-------

The fisrt residue

PHE1	3	C	4.403	1.581	1.957
------	---	---	-------	-------	-------

The fisrt residue

PHE1	4	O	5.076	0.828	2.714
------	---	---	-------	-------	-------

The fisrt residue

PHE1	5	CB	2.385	2.334	3.218
------	---	----	-------	-------	-------

The fisrt residue

PHE1	6	CG	0.861	2.429	3.393
------	---	----	-------	-------	-------

The fisrt residue

PHE1	7	CD	0.179	1.414	4.074
------	---	----	-------	-------	-------

The fisrt residue

PHE1	8	CD	0.14	3.483	2.827
------	---	----	------	-------	-------

The fisrt residue

PHE1	9	CE	-1.208	1.444	4.171
------	---	----	--------	-------	-------

The fisrt residue

PHE1	10	CE	-1.248	3.518	2.934
------	----	----	--------	-------	-------

The fisrt residue

PHE1	11	CZ	-1.921	2.497	3.603
------	----	----	--------	-------	-------

The fisrt residue

PHE1	12	HA	2.547	2.085	1.04
------	----	----	-------	-------	------

The fisrt residue

PHE1	13	HB2	2.801	3.361	3.219
------	----	-----	-------	-------	-------

The fisrt residue

PHE1	14	HB1	2.822	1.878	4.13
------	----	-----	-------	-------	------

The fisrt residue

PHE1	15	HD1	0.724	0.577	4.49
------	----	-----	-------	-------	------

The fisrt residue

PHE1	16	HD	0.654	4.267	2.288
------	----	----	-------	-------	-------

The fisrt residue

PHE1	17	HE1	-1.727	0.64	4.672
------	----	-----	--------	------	-------

The fisrt residue

PHE1	18	HE2	-1.802	4.331	2.488
------	----	-----	--------	-------	-------

The fisrt residue

PHE1	19	HZ	-2.998	2.515	3.675
------	----	----	--------	-------	-------

The fisrt residue

PHE1	20	H	2.259	-0.11	2.909
------	----	---	-------	-------	-------

The fisrt residue

PHE1	21	H	3.03	-0.401	1.479
------	----	---	------	--------	-------

The fisrt residue

PHE2	22	N	5.111	2.495	1.048
------	----	---	-------	-------	-------

The second residue

PHE2	23	CA	6.536	2.277	1.275
------	----	----	-------	-------	-------

The second residue
PHE2 24 C 7.291 3.585 1.28
The second residue
PHE2 25 O 6.709 4.692 1.105
The second residue
PHE2 26 CB 7.122 1.362 0.157
The second residue
PHE2 27 CG 6.476 -0.023 -0.002
The second residue
PHE2 28 CD 5.368 -0.176 -0.844
The second residue
PHE2 29 CD 6.941 -1.119 0.729
The second residue
PHE2 30 CE 4.722 -1.404 -0.937
The second residue
PHE2 31 CE 6.301 -2.351 0.627
The second residue
PHE2 32 CZ 5.19 -2.492 -0.204
The second residue
PHE2 33 HA 6.673 1.799 2.264
The second residue
PHE2 34 HB2 8.208 1.223 0.328
The second residue
PHE2 35 HB1 7.08 1.891 -0.817
The second residue
PHE2 36 HD1 4.98 0.672 -1.392
The second residue
PHE2 37 HD2 7.789 -1.011 1.392
The second residue
PHE2 38 HE1 3.85 -1.504 -1.566
The second residue
PHE2 39 HE2 6.659 -3.193 1.2
The second residue
PHE2 40 HZ 4.684 -3.443 -0.274
The second residue
PHE2 41 H 4.694 3.144 0.396
The second residue

Awk 的练习，利用上面给的文件进行练习：

`awk -F % 'NR==7,NR==15 {printf $1 $3 $7}'` 显示文本文件 `myfile` 中第七行到第十五行中以字符%分隔的第一字段，第三字段和第七字段：

`awk '/101/' file` 显示文件 `file` 中包含 101 的匹配行。

`awk '{print NR,NF,$1,$NF,}' file` 显示文件 `file` 的当前记录号、域数和每一行的第一个和最后一个域

`awk -F "|" '{print $1}' file` 按照新的分隔符“|”进行操作

`awk 'length($0)>80 {print NR}' myfile` 显示文本 `myfile` 中所有超过 80 个字符的行号，在这里，用 `$0` 表示整个记录（行），同时，内置变量 `NR` 不使用标志符 `$`

`awk 'BEGIN { max=100 ;print "max=" max}'` `BEGIN` 表示在处理任意行之前进行的操作

`awk 'END {print $1}'` `END` 之后列出的操作将在扫描完全部的输入之后执行

`awk '{print length($1)}' inputfile` 调用内置函数 `length()`

`awk 'BEGIN {total=0} {print $2 ;total=total+$2} END{print total} inputfile` 编一小程序对文件的第二列进行统计求和