

I filtri

Opzioni di sort

Un **filtro** è un comando che manipola la sua standard input e invia il risultato sulla standard output.

Un filtro comune è sort. Usiamolo per leggere dalla tastiera:

```
/home/user1> sort  
Marco 347898  
Antonio 050 76564
```

Quando avete finito di inserire nomi, battete **Ctrl-D** e sort ordinerà alfabeticamente le righe di input:

```
^D  
Antonio 050 76564  
Marco 347898
```

Ovviamente, salvo che per un breve test, è più comune ordinare i dati memorizzati in un file e salvare i risultati su un altro file, p. es.

```
/home/user1> sort < telefoni > telefoni.ord
```

Esercizio: create un file telefoni di almeno 40 numeri di telefono, nella forma mostrata sopra, e ordinate la come detto.

sort viene usato spesso in pipe con altri comandi, P. es. per ordinare gli utenti presenti sul sistema

```
/home/user1> who | sort  
/home/user1> who | sort | lpr  
/home/user1> who | sort | tee users.save | lpr
```

Secondo il solito meccanismo, sort ammette una lista di input file, inoltre può mandare output su un file con l'opzione -o:

```
/home/user1> sort -otelefoni telef.1 telef.2
```

cioè equivale a (qui sort comunica solo con standard I/O):

```
/home/user1> (cat telef.1 telef.2 | sort) > telefoni
```

sort -r rovescia l'ordine

sort -n Ordina numericamente (e tiene conto di -e . decimale):

```
/home/user1> echo ' -1  
> 19  
> 123' > numeri  
/home/user1> sort < numeri  
-1  
-80  
123  
19  
/home/user1> sort -n < numeri  
-80  
-1  
19  
123
```

sort -u elimina i duplicati:

```
/home/user1> sort -u  
aa  
aa  
bb  
^D  
aa  
bb  
/home/user1> sort  
aa  
aa  
bb  
^D  
aa  
aa  
bb
```

Altre opzioni di sort

Gli spazi hanno codice ascii 32 e le maiuscole hanno un codice più basso di tutti quelli delle minuscole.

Per provare, usate `od -hc` che legge un file o la standard input, mostrandone ogni byte come **hexadecimal e char**:

```
/home/user1> od -hc  
a A 0000000000 61 20 41 0d 0a  
a A \r \n  
^D 0000000005
```

`sort -n` (ordina numericamente) e ignora spazi e tab iniziali:

```
/home/user1> sort  
b  
a  
^D  
b  
a /home/user1> sort -n  
b  
a  
^D  
a  
b
```

`sort -f` ignora la differenza tra maiuscole e minuscole

```
/home/user1> sort  
a  
B  
^D  
B  
a /home/user1> sort -f  
a  
B  
^D  
a  
B
```

Altre opzioni di sort

`sort -d` ignora i segni di interpunkzione, come un dizionario:

```
/home/user1> sort -d  
D'Ernesto  
DAVIDE  
^D  
DAVIDE  
D'Ernesto  
/home/user1> sort  
D'Ernesto  
DAVIDE  
^D  
D'Ernesto  
DAVIDE
```

`sort -m f1 f2 ...` fonde in maniera ordinata i file *f1 f2 ...* ma non li ordina all'interno (è più veloce di `sort f1 f2`, ma il risultato è ordinato solo se *f1* e *f2* sono già ordinati):

```
$ echo 'b'  
> a' > f1  
$ echo 'z'  
> v' > f2  
$ cat f1 f2  
b  
a  
z  
v  
$ sort -m f2 f1  
b  
a  
z  
v  
$ sort f2 f1  
b  
a  
z  
v
```

Ordinamento a chiave o per campi

L'informazione contenuta in un file testo è suddivisa in righe.

Spesso anche le righe sono suddivise in **campi**.

sort riconosce i campi in quanto separati da spazi:

7689	Benso	Camillo	TO	011	1860-61	
9854	Verdi	Giuseppe,		via	Rossini,	Parma
3687	Vialli	Gian Luca		via	Dalla Samp	GE 010 878787

In quest'esempio, che mostra alcune righe del file agenda:

- le righe 1 e 2 contengono 6 campi, la 3 contiene 10 campi.
 - i campi 1 (num d'ordine) e 2 (cognome) hanno lo stesso significato in ogni riga, ma quello degli altri campi varia.
- sort ordina tenendo conto di tutta la riga e non dei campi:

/home/user1> sort agenda						
3687	Vialli	Gian Luca	via	Dalla Samp	GE	010 878787
7689	Benso	Camillo	TO	011	1860-61	
9854	Verdi	Giuseppe,		via	Rossini,	Parma

Invece sort +**m** -**n** ordina su una **chiave** cosiffatta:

- l'**inizio** della chiave si determina saltando **m** campi
- la **fine** della chiave si determina saltando **n** campi

Dunque l'ordinamento sul campo 2 (cognome) si fa con:

/home/user1> sort +1 -2 agenda						
9854	Verdi	Giuseppe,		via	Rossini,	Parma
3687	Vialli	Gian Luca	via	Dalla Samp	GE	010 878787
7689	Benso	Camillo	TO	011	1860-61	

Gli spazi che precedono Verdi sono parte del campo.

Per evitare che Verdi sia il primo: opzione -b

/home/user1> sort -b +1 -2 agenda						
7689	Benso	Camillo	TO	011	1860-61	
9854	Verdi	Giuseppe,		via	Rossini,	Parma
3687	Vialli	Gian Luca	via	Dalla Samp	GE	010 878787

Se un file contiene campi in numero e di natura variabile, usare spazi per separare i campi crea problemi:

7689	Benso	Camillo	TO	011	1860-61	
9854	Verdi	Giuseppe,		via	Rossini,	Parma
3687	Vialli	Gian Luca	via	Dalla Samp	GE	010 878787

P.es. il 3° o il 5° campo contengono informazione eterogenea, quindi usare la via o la città come chiave è impossibile.

- meglio usare p.es. virgole come separatori di campo.
- es. nel file agenda1:

/home/user1> cat agenda1	
9854,Verdi,Giuseppe,'via Rossini,'Parma,	
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787	
3688,Vialli,Gian Luca, via Cerea ,TO ,011 777777	
7689,Benso,Camillo ,TO ,011 1860-61	

“Sort -tC” ordina usando c come separatore di campi.

/home/user1> sort -t, +1 -2 agenda1	
7689,Benso,Camillo ,TO ,011 1860-61	
9854,Verdi,Giuseppe,'via Rossini,'Parma,	
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787	
3688,Vialli,Gian Luca, via Cerea ,TO ,011 777777	

Si può anche ordinare su più campi contemporaneamente. P.es. per ordinare sul nome e, a parità di nome, sulla città:

/home/user1> sort -t, +1 -2 +4 -5 agenda1	
7689,Benso,Camillo ,TO ,011 1860-61	
9854,Verdi,Giuseppe,'via Rossini,'Parma,	
3688,Vialli,Gian Luca, via Cerea ,TO ,011 777777	
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787	

Per ogni campo preceduto da -b si ignorano gli spazi (es. ‘ TO’).

/home/user1> sort -b +1 -2 agenda	
7689,Benso,Camillo ,TO ,011 1860-61	
9854,Verdi,Giuseppe,'via Rossini,'Parma,	
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787	
3688,Vialli,Gian Luca, via Cerea ,TO ,011 777777	

Ordinamento a chiave (cont.)

Si può raffinare una specifica di campo usando il punto decimale:
la chiave di sort +5 . 4 inizia dopo 5 campi e 4 caratteri (del 6°).

```
/home/user1> cat agenda1
9854,Verdi ,Giuseppe ,via Rossini ,Parma,
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787
3688,Vialli,Gian Luca, via Cerea , TO ,011 777777
7689,Benso ,Camillo ,
/home/user1> sort -t, +5 -6 agenda1 ordina su num. di tel.
9854,Verdi ,Giuseppe ,via Rossini ,Parma,
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787
7689,Benso ,Camillo ,
3688,Vialli,Gian Luca, via Cerea , TO ,011 1860-61
/home/user1> sort -t, +5.4 -6 agenda1 ignora il prefisso
9854,Verdi ,Giuseppe ,via Rossini ,Parma,
3689,Benso ,Camillo ,
3688,Vialli,Gian Luca, via Cerea , TO ,011 777777
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787
```

La chiave di sort -5 . 3 finisce dopo 5 campi e 3 caratteri (del 6°)
(confrontare il seguente esempio con sort +5 -6 più sopra):

```
/home/user1> sort -t, +5 -5.3 agenda1
9854,Verdi ,Giuseppe ,via Rossini ,Parma,
3687,Vialli,Gian Luca, via Dalla Samp,GE ,010 878787
3688,Vialli,Gian Luca, via Cerea , TO ,011 777777
7689,Benso ,Camillo , ,TO ,011 1860-61
```

Attenzione: certe implementazioni di sort interpretano le
specifiche di chiave sort +m -n diversamente:
vengono considerati i campi da m fino a n-1.

Esercizio: creare un'agenda di 100 nomi con campi come sopra:
identificatore, cognome, nome, indirizzo, città, telefono
e ordinare:

- per cognome e, insieme, per città, su un file agenda. 1
- per città e, insieme, per nome, trascurando la differenza tra
maiuscole e minuscole, su un file agenda. 2

uniq

uniq f g elimina le righe **adiacenti** ripetute dal file f e salva il
risultato in g. Se g manca, uniq scrive sulla standard output.

```
/home/user1> cat nomi
Tiberio Gracco
Tiberio Gracco
Caio Gracco
Tiberio Gracco
/home/user1> uniq nomi
Tiberio Gracco
Caio Gracco
Tiberio Gracco
```

L'opzione -d dà solo le righe ripetute, -u elimina ogni ripetizione e
-c conta le righe ripetute adiacenti:

```
/home/user1> uniq -d nomi
Tiberio Gracco
/home/user1> uniq -u nomi
Caio Gracco
Tiberio Gracco
/home/user1> uniq -c nomi
2 Tiberio Gracco
1 Caio Gracco
1 Tiberio Gracco
```

uniq -n trascura i primi n campi nel confrontare le righe

```
/home/user1> uniq -1 nomi
Tiberio Gracco
```

comm e diff

comm seleziona le righe comuni a due file ordinati:

```
/home/user1> cat fornit.90
fiat
ibm
olivetti
/home/user1> cat fornit.91
fiat
nissan
olivetti
/home/user1> comm fornit.90 fornit.91
ibm
nissan
olivetti
solo    solo    righe
file1   file2   comuni
```

Le opzioni -1 -2 -3 sopprimono la colonna corrispondente.

Il comando diff f1 f2 trova le differenze tra f1 e f2:

```
/home/user1> diff fornit.90 fornit.91
2c2
< ibm
---> nissan
```

NB: < precede i riferimenti a f1, > quelli a f2, e:
c indica le righe da cambiare,
d le righe da cancellare,
a le righe da aggiungere
per rendere i file f1 uguale a f2.

Esercizio: creare un file di fornitori forniti.90, quindi eliminare i fornitori stranieri, sostituendoli, in parte, con italiani.
Applicare comm e diff ai due file.

tr string1 string2 copia la standard input sulla standard output, traducendo i caratteri in string1 in quelli in string2:

```
/etc> tr a-e 12
abcdeF^D
12222f
/etc> tr a-z A-Z
abcdef^D
ABCDEF
```

tr -c traduce i caratteri **non in** string1 in quelli in string2:

```
/etc> tr -c a-z +
casa, dolce casa^D
casa++dolce+casa+
```

tr -s elimina i caratteri tradotti duplicati:

```
/etc> tr -cs a-z +
casa, dolce casa^D
casa+dolce+casa+
```

Il seguente comando cerca le 10 parole più comuni nel file f

```
$ (tr -sc A-Za-z '\012' | sort | uniq -c | sort -n | tail) < f
trudi ogni non-lettera in newline (10)
ordina
elimina duplicati e conta occorrenze
ordina secondo contatore occorrenze
prendi ultime 10 righe
```

Si noti come la pipe | consenta di continuare l'input a capo, e come le parentesi tonde siano necessarie.

Esercizio: eliminare le parentesi tonde nell'esempio precedente. (suggerimento: si usi cat).

tr

tr string1 string2 copia la standard input sulla standard output, traducendo i caratteri in string1 in quelli in string2:

```
/etc> tr a-e 12
abcdeF^D
12222f
/etc> tr a-z A-Z
abcdef^D
ABCDEF
```

tr -c traduce i caratteri **non in** string1 in quelli in string2:

```
/etc> tr -c a-z +
casa, dolce casa^D
casa++dolce+casa+
```

tr -s elimina i caratteri tradotti duplicati:

```
/etc> tr -cs a-z +
casa, dolce casa^D
casa+dolce+casa+
```

Il seguente comando cerca le 10 parole più comuni nel file f

```
$ (tr -sc A-Za-z '\012' | sort | uniq -c | sort -n | tail) < f
trudi ogni non-lettera in newline (10)
ordina
elimina duplicati e conta occorrenze
ordina secondo contatore occorrenze
prendi ultime 10 righe
```

Si noti come la pipe | consenta di continuare l'input a capo, e come le parentesi tonde siano necessarie.

Esercizio: eliminare le parentesi tonde nell'esempio precedente. (suggerimento: si usi cat).

Altri filtri: **fmt**, **fold**, **nl**

fmt -1 n elimina gli 'a capo' dal suo input e ne inserisce di nuovi, per produrre in standard output righe di lunghezza quanto più vicina per difetto a *n*.

fold -n spezza le righe di input ogni *n* caratteri, ma non modifica gli 'a capo' preesistenti.

```
$ cat leap
Sempre caro mi fu quest'ermo colle
e questa siepe che da tanta parte
$ fmt -15 leap
Sempre caro mi
fu quest'ermo
colle e questa
siepe che da
tanta parte
$ fold -15 < leap
Sempre caro mi
fu quest'ermo c
olle
e questa siepe
che da tanta pa
rte
```

nl legge la standard input e numera le righe:

```
/home/user1> cat leap
Sempre caro mi fu quest'ermo colle
e questa siepe che da tanta parte
/home/user1> nl leap
1 Sempre caro mi fu quest'ermo colle
2 e questa siepe che da tanta parte
```

grep

Una **stringa** è una sequenza di caratteri.
Un **pattern** è una notazione per specificare un insieme di stringhe. grep pattern file cerca una stringa che si accoppi (**match**) con pattern in file e stampa le righe in cui la ricerca ha avuto successo.

grep pattern usa la standard input per default, p. es.:

```
/home/user1> ls | grep affari
affari
```

Per specificare pattern, la notazione è simile a quella della shell, anzi spesso il pattern di grep va protetto dall'interpretazione della shell, racchiudendolo tra apici.

```
c il carattere c sta per se stesso (se non è un metacarattere)
\c lo \ elimina ogni significato speciale di c
^ e $ inizio e fine riga
. ogni singolo carattere
[...] uno qualsiasi dei caratteri ...; si possono usare range come a-z
[^...] uno qualsiasi dei caratteri non in ...; si possono usare range
p* zero o più occorrenze del pattern p
p1 p2 pattern p1 seguito da p2
```

Esempi: [^0-9] è ogni carattere non numerico,

```
[ [-] ] è: [ o - o ] ([-] non sono metacaratteri se racchiusi tra [])
1s -1 | grep '^d' mostra le subdirectory (righe inizianti per d)
[a-zA-Z]* è la stringa vuota o una qualsiasi stringa alfabetica
.* sta per ogni stringa (*) va preceduto da un pattern, da solo è un errore
.*x è ogni stringa che finisce per x
xy* non è xyxyxy... ma yyyy... perché * lega più forte della concatenazione.
grep '^[:]*::' /etc/passwd cerca gli utenti senza password,
infatti le righe di /etc/passwd hanno la forma:
nomeutente:passwordcodificata:....
```

e il pattern è: inizio riga, 0 o più caratteri diversi da :, seguiti da ::

egrep

egrep - fgrep

egrep è una versione estesa di grep, i pattern si formano come quelli di grep e in più con:

- p+ una o più occorrenze del pattern *p*
- p? zero o una sola occorrenza del pattern *p*
- p1/p2 pattern *p1* oppure pattern *p2*
- (*p*) pattern *p* (le parentesi servono per raggruppare più pattern)

Questo consente di specificare più patterns che con grep, p. es.:

(xy)* sta per: la stringa vuota, xy, xxyy, xyxyxy, ...
chiessa|chiave e chi (esa|ave) stanno entrambi per chi esa o chi ave

egrep -f pat può cercare i pattern specificati in un file pat, pat può contenere pattern multipli, ognuno su una riga.

NB: quando il pattern è sulla riga di comando è spesso tra ' e ', per evitare che la shell interpreti i metacaratteri del pattern; nei pattern su file ciò non è necessario:

```
/etc> cat aeiou
^ [aeiou]*a[^aeiou]*e[^aeiou]*i[^aeiou]*o[^aeiou]*u[^aeiou]*$
```

Il pattern del file aeiou è: inizio riga (^), una sequenza di 0 o più non vocali, una a, una sequenza di 0 o più non vocali, una e, ... in altre parole: una riga contenente solo le vocali aeiou nell'ordine Cerchiamo il pattern di aeiou nel dizionario /etc/words.

NB: il comando c incolonna l'output, ma non ogni UNIX ce l'ha:

```
/etc> egrep -f aeiou words | c
/etc> egrep -f aeiou words | c
abstemious      abstemiously    arsenious    caesious
facetious      facetiously
```

Sul vostro sistema dovrebbe esserci pure un dizionario, spesso è in /usr/dict/words o nella dir /usr/lib

Per cercare parole con le lettere in ordine e con almeno 6 lettere:

```
/etc> cat ord
^a?b?c?d?e?f?g?h?i?j?k?l?m?n?o?p?q?r?s?t?u?v?w?x?y?z?$
/etc> egrep -f ord words | grep '.....' | c
abhors almost begins bijoux biopsy chinos chintz
```

fgrep è una versione veloce (*fast*) di grep che cerca solo stringhe semplici, non pattern complessi

Leggendo i pattern da un file, fgrep ne può cercare diversi "in parallelo", più velocemente.

Principali opzioni per la famiglia grep:

- n dà i numeri delle righe in cui il pattern è stato trovato
- c conta solo le righe che contengono il pattern
- v mostra tutte le righe che **non** contengono il pattern
- i ignore case: accoppia minuscole in pattern anche a maiuscole
- h non visualizza i nomi dei file in una ricerca su più file.

P. es., se non si usa -h:

```
/home/user1> cat f1
Sempre caro mi fu quest'ermo colle
/home/user1> cat f2
e questa siepe che da tanta parte
/home/user1> egrep 'r[mrt]' f1 f2
f1: Sempre caro mi fu quest'ermo colle
f2: e questa siepe che da tanta parte
```

Esercizio su grep

Dato un file agenda:

- visualizzare le righe contenenti m
- visualizzare le righe contenenti s o S
- visualizzare le righe che non contengono a o e
- contare le righe che contengono la stringa and
- in /etc/passwd, trovare gli utenti che non usano /bin/sh
- scelte 4 parole, si trovi un pattern comune ad esse.
- spiegare la differenza tra fgrep ed egrep

Dire cosa individuano i seguenti:

Pattern	Risposte
^\$	riga vuota
:	ogni riga non vuota
^thing	ogni riga
thing\$	thing a inizio di riga
^thing\$	thing in fine di riga
thing.\$	riga che contiene solo thing
thing\.\$	thing seguito da un carattere qualiasi a fine riga
[tT]hing	thing seguito da un punto a fine riga
thing[^0-9]	thing seguito da qualsiasi stringa
thing[0-9][^0-9]	thing seguito da qualsiasi stringa e da thing2
thing1.*thing2	thing1 seguito da qualsiasi stringa e da thing2 come sopra, ma è tutta la riga
^thing1.*thing2\$	come sopra, ma è tutta la riga

sed: uno stream editor

La forma di base di sed è:

```
$ sed 'lista di comandi di ed' f1 f2 ...
```

- sed legge le righe f1 f2 ... e applica a ognuna i comandi di ed.
- sed -f cmdfile prende i comandi da cmdfile

Esempi (NB: sotto → sta per il tasto Tab):

```
sed 's/UNIX/UNIX(TM)/g'
```

- gli ' ' servono a quotare i metacaratteri di shell

```
/home/user1> du -a ch*
1          ch.1
1          ch.2
/home/user1> du -a ch* | sed 's/.*///'
sed 's/ .*/ /' sostituisce tutto ciò che sta tra il primo e
l'ultimo spazio bianco con un solo spazio bianco.
```

```
sed 's/^/ /' rientra le righe di un tab
sed ' / ./s/^/ /' fa lo stesso; inoltre il pattern precedente s
restringe le righe considerate a quelle che contengono almeno
un carattere ( . )
```

```
sed ' / ^$/ !s/^/ /' fa lo stesso, perché ! nega il pattern che
lo precede e / ^$/ prende le righe vuote
```

```
sed -n elimina la stampa per default di tutte le righe.
```

La stampa esplicita si fa con p, preceduto da un **pattern**

selettore:

```
/home/user1> sed -n /a/p
cosa
casa
casa
```

sed (cont.)

Per convertire ogni sequenza di almeno uno spazio bianco o tab in un ritorno a capo, si deve andare a capo sulla riga di comando:

```
/home/user1> sed 's/\t\rightarrow\t*\n/g'  
> casa dolce casa  
casa  
dolce  
casa
```

Il comando d cancella: sed 'pattern/d' stampa tutto, ma cancella ogni riga contenente pattern.

Il comando q esce: sed 'pattern/q' stampa finché trova una riga contenente pattern, poi esce.

I pattern selettori si possono usare a coppie, come in ed.

P.es.:

```
sed -n '20,30p' stampa le righe da 20 a 30  
sed '1,10d' stampa cancellando le righe da 1 a 10  
sed '1,/^$/d' stampa cancellando le righe dalla 1 alla  
prima vuota (tutte se nessuna è vuota)  
sed $d cancella la riga $ cioè l'ultima  
(NB $ ha due usi: fine riga in un pattern,  
ultima riga in un contatore di riga).
```