

Linux-programmer som bruker
regulæruttrykk:

grep, sed, awk

grep* – søking i tekstlige data

```
grep [OPTIONS] REGEX [FILE...]
```

- Verktøy som finnes i alle Unix-lignende OS
- Leser en eller flere tekstfiler, eller standard input hvis ingen filer er angitt, linje for linje
- Hver linje sammenlignes med et søkemønster som angis som et *regulæruttrykk*
- Hvis en linje *matcher* skrives den ut til standard output
- Linjer som *ikke* matcher, skrives ikke ut

*: Navnet kommer fra **tidlig Unix-historie**

Bruk av grep

- Brukes typisk til å «redusere en stor mengde informasjon til en liten mengde nyttig informasjon»
- Ofte som del av «pipelines» på kommandolinjen
- Bruk av grep er så vanlig at det har blitt til et eget verb* i det engelske (og norske?) språket – "to grep"

*: På samme måte som "å google"

Varianter av grep

- grep
 - Basic Regular Expressions
- egrep *
 - Extended Regular Expressions (grep -E)
- fgrep
 - Fixed, bare konstante mønstre (grep -F)
- rgrep
 - Recursive, søker i et helt katalogtre (grep -r)

«Quoting» av regulæruttrykk i `grep`

- Skriver ofte regulæruttrykk i `' '` (single quotes)
- Unngår da at shellet selv håndterer metategn som er del av regulæruttrykket:
 - F.eks. kan et regulæruttrykk med `*` få shellet til å gjøre «file name expansion» og erstatte `*` med en liste av filer
- Kan i stedet bruke `" "` (double quotes) hvis vi f.eks. trenger å hente ut verdier fra shellvariabler med `$` inne i regulæruttrykket

egrep – eksempler (1)

- Søk i alle tekstfiler etter "beløp i amerikanske dollar":

```
egrep '\$[0-9]+\.[0-9]{2}' *.txt
```

- Linjer som starter med ordene "Vi", "We" eller "Wir":

```
egrep '^Vi|^We|^Wir' *.txt
```

- Alle "gamle" Linux / Unix-kommandoer med bare to tegn:

```
ls /bin | egrep '^[a-z][a-z]$'
```

egrep – eksempler (2)

- Linjer med tekst inne i firkant-paranteser (brackets):

```
cat brackets.txt | egrep '\[[A-Za-z]*\]'
```

- Alle som er logget på systemet, unntatt meg selv:

```
who | grep -v "^$USER" | cut -f1 -d' '
```

Noen nyttige opsjoner til `egrep`

- `-w` Let bare etter hele *ord*
- `-c` Skriv bare ut *antall linjer* i input som matcher
- `-o` Skriv bare ut de *delene* av en linjene som matcher
- `-i` Ikke forskjell på store og små bokstaver i regex
- `-v` Bare linjer som *ikke* matcher (ofte bedre enn `[ ^ ]`)
- `-l` Skriv bare ut *navn på file(r)* med minst én match
- `-L` Skriv bare ut navn på file(r) som *ikke* matcher
- `-n` Skriv også ut linjenummere i filen(e)
- `-m` Stopp søk i en fil etter et gitt antall (typisk 1) matcher
- `-q` Ingen output, stopp (med *exit-kode* 0) hvis match

Søking i ordlisten i `/usr/share/dict/words` (1)

- Ord med 20 eller flere bokstaver:

```
egrep '[[ :alpha: ]]{20,}'
```

- Antall ord med 15 eller flere bokstaver:

```
egrep -c '[[ :alpha: ]]{15,}'
```

- Ord på tre bokstaver med bare vokaler:

```
egrep -i '^[aeiouy]{3}$'
```

- Ord på tre bokstaver med bare konsonanter:

```
egrep '^[[ :alpha: ]]{3}$' | egrep -iv '[aeiouy]'
```

Søking i ordlisten i `/usr/share/dict/words` (2)

- Ord som begynner med qu og slutter med y:

```
egrep -i '^qu[a-z]*y$'
```

- Ord som inneholder alle vokalene i alfabetisk rekkefølge:

```
egrep -i 'a[a-z]*e[a-z]*i[a-z]*o[a-z]*u[a-z]*y'
```

sed – stream editor

- sed utfører redigering av en *tekststrøm*
- Redigeringen angis med enkle kommandoer
- Argumenter til kommandoene er ofte regulæruttrykk
- sed leser tekst linje for linje, ett tegn om gangen
- Teksten leses fra standard input eller fra en angitt fil
- Etter at en linje er lest inn og redigert, skriver sed den redigerte linjen ut til standard output

Hva brukes sed til?

- Enkle oppdateringer av mange tekstfiler:
 - Effektivt, sparer manuell editering
 - Lett å automatisere med shellprogrammer
 - Raskt, sed leser gjennom en tekstfil bare *en* gang
 - Men også begrenset funksjonalitet
- Alternativer til sed :
 - For enklere jobber: grep, head, tail, tr
 - For mer kompliserte jobber: awk, perl

Enkel bruk av sed*

- Bytte strengen Jan med Harald i standard input:

```
sed 's/Jan/Harald/'
```

- Flere kommandoer kan angis på samme linje:

```
sed -e 's/Christian/en raring/' -e 's/Robert/en  
raring til/' innfil > utfil
```

- I eksemplet over leser og skriver sed tekst fra/til filer
- Kommandoer kan også leses fra fil – et *sedscript*:

```
sed -f kommandofil < inputfil > outputfil
```

*: Vi skal begrense oss til bare å se på redigeringskommandoen s – "search and replace"

sed og regulæruttrykk

- Syntaks for kommandoen `s` :

```
sed 's/pattern/replacement/'
```

- `pattern` kan angis som et regulæruttrykk
- *Første* tekststreng som matcher `pattern` på hver linje, vil bli byttet ut med `replacement`
- For å bytte *alle* forekomster av `pattern` på linjen:

```
sed 's/pattern/replacement/g'
```
- Opsjonen `-r` for Extended Regular Expressions

Eksempel (fra læreboken)

- En fil inneholder linjer med adresser, der en adresse kan innholde en angivelse av leilighet, som:

Apt 5	apt 5	Number 5
number 5	#5	

- Ønsker å bytte ut alle disse variantene med:

Apartment 5

- Løsning:

```
sed -r -e 's/[Aa]pt|[Nn]umber/Apartment/'  
-e 's/#/Apartment /' innfil > utfil
```

Sletting av tekststrenger

- Kan gjøres enkelt ved å angi en tom "replacement string" i kommandoen `s`
- Eksempel: Fjerne alle (norske) kontonummere:

1111.22.33333

- Kommando:

```
sed -r 's/[0-9]{4}\.[0-9]{2}\.[0-9]{5}//'
```

Redigering av strengen som matcher

- `sed` tilbyr også mulighet for å *redigere* strengen som er funnet som match til *pattern*, i stedet for bare å bytte den ut med en fast *replacement*
- Siste streng som er funnet som match ligger alltid lagret i en *placeholder*
- Vi kan referere til innholdet i placeholder med tegnet `&`
- Eksempel: Sette matchende tekststreng i anførselstegn:

```
sed -r 's/ekspert(er|en|ene)?/"&"/'
```

Innebygd editering av placeholder *

- Funksjoner for å endre teksten i placeholder:

\u upper case the first letter of the string

\l lower case the first letter of the string

\U upper case the entire string

\L lower case the entire string

- Gjør om alle ord til små bokstaver:

```
sed -r 's/[A-Za-z]+/\L&/g'
```

- Gjør om første tegn i alle ord til stor bokstav:

```
sed -r 's/\<[a-z]/\u&/g'
```

*: Placeholder kan også deles i «items» som redigeres separat, se lærebokens avsnitt 6.5.3

awk – et språk for å håndtere tekstdata

- Interpretert programmeringsspråk laget for tekstbehandling
- Brukes typisk for å ekstrahere data og lage rapporter
- Er standard verktøy på Linux- og Unix-systemer
- Virkemåte:
 - Leser linjer med tekst, oppdelt i *felt*
 - Utfører operasjoner for linjer som har *matchende* felt
 - Matching spesifiseres med *regulæruttrykk*
 - Operasjonene som skal utføres kan programmeres med bl.a. if-tester, løkker og kall på funksjoner
- Se man awk og lærebokens avsnitt 6.6 for mer info.