

Kočírujeme smršť experimentů aneb Unix pro (mírně) programující lingvisty

Ondřej Bojar
bojar@ufal.mff.cuni.cz

25. leden 2006

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Motivace a metodika

Proč se učit něco nového:

- automat šetří čas (naprogramuju jednou, použiju mockrát)
- program je dobrá dokumentace (mám rovnou pečlivě zapsáno, jak jsem pokus prováděl)

Jak se učit Unix:

- po kapkách, praxí, najednou je toho nezvládnutelně moc
- postupným obohacováním repertoáru známých příkazů a přepínačů

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Základem Unixu je roura

```
cat defined-vallex-frames.txt
absolvovat 0 0 1 phase verb absolvovat-1 ACTobl(#nom) PATobl(#aku)
absolvovat 0 0 2 - absolvovat-2 ACTobl(#nom) PATobl(#aku)
akceptovat 0 0 1 - akceptovat-1 ACTobl(#nom) PATobl(#aku,ze)

...
cat defined-vallex-frames.txt | head -2
absolvovat 0 0 1 phase verb absolvovat-1 ACTobl(#nom) PATobl(#aku)
absolvovat 0 0 2 - absolvovat-2 ACTobl(#nom) PATobl(#aku)
cat defined-vallex-frames.txt | cut -f 1
```

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Náš první skript

- Z užitečného úseku roury si udělej skript:
`echo "sort | uniq -c" > suc`
- Nastav mu příznak spustitelnosti:
`chmod +x suc`
- Umísti skript do svého (nově vyrobeného) osobního adresáře skriptů:
`mkdir -p ~/bin; mv suc ~/bin`
- Řekni bashi, ať programy (skripty) hledaj přednostně v tom osobním adresáři:
`export PATH=~/bin:$PATH`

```
cat defined-vallex-frames.txt | cut -f 1 | suc | head -2
2 absolvovat
1 akceptovat
```

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Přehled

- Motivace a metodika
- Výhody řádkového rozhraní (bash)
- Unix je nástroj na práci s textovými soubory (textutils)
- Make pro lepší přehled procesech výroby souborů
- CVS pro lepší přehled o historii i lepší pořádek v součanosti

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Výhody řádkového rozhraní (bash)

- příkazy mohou být přesnější a pestřejší než příkazy udílené myší
- snadno srozumitelné pro počítac → snadno strojově zpracovatelné
 - pohodlně reproducovatelné pouhým copy-paste
 - pohodlně zobecnitelné (nahrad konkrétní jména proměnnými)
- plná síla programovacích jazyků (větvení, cykly)
- pohodlné propojování programů, navazující výpočty

bash = Bourne-Again Shell

⇒ `man bash`

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Ještě roura a ještě roura a přesměrování

```
cat defined-vallex-frames.txt | cut -f 1 | sort | uniq -c
2 absolvovat
1 akceptovat
1 analyzovat
```

Přesměrování na standardní vstup programu a do souboru:

`cat vstop | head a cat vstop > head`

Přesměrování obecně:

`program < standardní-vstup > standardní-výstup 2> chybový-výstup`
`program < standardní-vstup >> prodloužení-existujícího-souboru`
`program1 2> &1 | program2-dostane-na-vstup-spojený-std-a-chyb-výstup`
`program1 `program2-výstup-vygeneruje-přímo-na-příkazovou-řádku``

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Proměnné v bashi a v prostředí

- Nastavit proměnnou pouze v bashi:
`pozdrav=ahoj`
- Nastavit proměnnou v bashi a prostředí pro všechny dále spuštěné programy:
`export pozdrav=ahoj`

Otestujme to:

```
echo 'echo "Zdravím: $pozdrav"' > test-pozdravu
cat test-pozdravu
echo "Zdravím: $pozdrav"
sh test-pozdravu
Zdravím:
pozdrav=ahoj; sh test-pozdravu
Zdravím:
export pozdrav=nazdar; sh test-pozdravu
Zdravím: nazdar
```

Ondřej Bojar Kočírujeme smršť experimentů 25. leden 2006

Souhrn operátorů pro řazení programů v bashi

```
pgm1 | pgm2    výstup pgm1 bude předán jako vstup do pgm2
pgm1 ; pgm2   po ukončení pgm1 bude spuštěn (nezávisle) pgm2,
oběma lze přísměrovat vstup
                    má stejný význam jako nový řádek ve skriptu
pgm1 && pgm2  pokud spuštění pgm1 skončí úspěchem, bude spuštěn i pgm2
pgm1 || pgm2   pokud pgm1 skončí neúspěchem, bude spuštěn pgm2
Kulaté závorky znamenají: spusť sekvenci v podshellu.
```

```
(cat vstup1.txt ; zcat vstup2.txt.gz) | sem-potečou-data-z-obou-souboru
```

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Make: recept, co z čeho vzniká

⇒ info make

- Make je původem nástroj pro programátory: z jakých zdrojových souborů kompiloval pomocí jakých komplikátorů jaké programy.
- Make pro lingvisty poslouží stejně: z jakých dat jakými postupy generovat jaké přehledy, souhrny či jiná data.

Pravidla zapisujte do souboru Makefile. Struktura pravidla pro make:

```
cilovy-soubor: zdrojovy-soubor1 zdrojovy-soubor2
    prikaz1 < zdrojovy-soubor1 > /tmp/pomocny-soubor
    prikaz2 zdrojovy-soubor2 < /tmp/pomocny-soubor < cilovy-soubor
    ↑ tabulátor, nikoli mezery!
```

Každý řádek spuštěn v novém shellu ⇒ nelze předat proměnné, ani přes prostředí, pokud řádky nespojím.

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Proměnné v pravidlech

Pravidlo pracující pro více různých vstupů:

```
entries-version-%.freq: defined-vallex-%-frames.txt
    cat $< | suc > $@

make entries-version-1.0.freq zpracuje defined-vallex-1.0-frames.txt
make entries-version-1.5.freq zpracuje defined-vallex-1.5-frames.txt

Proměnná Význam
$< zastupuje název prvního ze vstupních souborů
$^ zastupuje názvy všech vstupních souborů
$@ zastupuje název výstupního souboru
$* zastupuje tu část, která odpovídala % (např. 1.0)
${(HOME)} proměnná z prostředí (na rozdíl od bashe nutné závorky)
$$ zastupuje prostě znak dolar, $
```

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Postup řešení

- defined-vallex-frames.txt převedeme tak, aby na každé řádce byly všechny rámců daného slovesa, každá řádka tří odpovídá právě jednomu slovesu
- soubor pak rozdělíme na trénovací a testovací řádky
- napišeme malý perlový skript, který vypočítá dostupný recall pro daný trénovací a testovací soubor

```
joined: defined-vallex-frames.txt
# tady nejak spoj řádky odpovídajici jednomu slovesu
training: joined
skip 100 < $< > $@
test: joined
head -100 < $< > $@
vysledek: training testing zmerit-recall.pl
./zmerit-recall.pl training testing > $@
Nakonec vysledek.
```

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Unix je nástroj pro práci s texty

- Přehled základních užitečných programů:
⇒ info coreutil

cat tac nl wc	výpis, obrácený výpis, číslování a počítání řádek
less	prohlížení dlouhého výpisu: cat dlouhy less
cut paste join	výřezávání sloupců a spojování souborů po sloupcích
tee	rozvětvení roury: cat vstup tee stranou ...
grep	výběr zajímavých řádek ze vstupu
sed tr awk	jednodušší i složitější úpravy textů

- Některé užitečnosti ale chybí:
⇒ <http://www.cuni.cz/~obo/textutils>
⇒ ls /home/bojar/tools/{vimtext,shell}/

- A nezapomeňte si vyrábět vaše vlastní!

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Příklad: Makefile pro počítání frekvencí

Takto vypadá připravený Makefile
cat Makefile

```
entries.freq: defined-vallex-frames.txt
    cat $< | suc > $@
```

Takto jej použijeme – necháme vyrobit výstupní soubor a prohlédneme si ho:
make entries.freq
head -2 entries.freq

```
2 absolvovat
1 akceptovat
```

Po změně vstupů:

touch defined-vallex-frames.txt

příkaz make entries.freq přegeneruje i výstupy, bez změn by nedělal nic.

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Složitější příklad: maximální dosažitelné pokrytí při učení se VALLEXových hesel

Úkol je vyhodnotit maximální teoreticky dostupný recall algoritmu:

- Vstup: VALLEXová hesla pro množinu trénovacích sloves, množina testovacích sloves
- Výstup: Algoritmem navržené rámce pro testovací slovesa.
Algoritmus přitom musí brát trénovací rámce jako nedělitelné celky a jen je pro testovací slovesa použít (nebo nepoužít).
- Dostupný recall říká, jak často sloveso z principu nemůže dostat nějaký svůj rámec, protože takový rámec nebyl u žádného trénovacího slovesa vidět.

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Jak spojit řádky pro jedno sloveso

Vstup:

```
absolvovat 0 0 1 phase verb absolvovat-1 ACTobl(#nom) PATobl(#aku)
absolvovat 0 0 2 - absolvovat-2 ACTobl(#nom) PATobl(#aku)
akceptovat 0 0 1 - akceptovat-1 ACTobl(#nom) PATobl(#aku,ze)
```

joined: defined-vallex-frames.txt

```
cut -f1,7 $< \
| split_at_colchange 1 \
| tr '\n' '| \
| sed 's/||/ /g' \
| tr '@' '\n' \
> $@
```

vysknout lemma slovesa a rámcem

můj jednoduchý nástroj přidá volné řádky

nahrád konce řádků speciálním znakem

dvojici řádků nahraď dalším speciálním znakem

ze speciálního znaku udělej zpátky konec řádku

ulož výsledek

Výstup:

```
absolvovat ACTobl(#nom) PATobl(#aku)|absolvovat ACTobl(#nom) PATobl(#aku)
akceptovat ACTobl(#nom) PATobl(#aku,ze)
argumentovat ACTobl(#nom) MEANStyp(#instr,ze) PATopt(pro#dat,pro#aku)
```

Ondřej Bojar Kočírujeme smršť experimentů

25. leden 2006

Jak spočítat dosažitelný recall?

... to je cvičení z Perlu, za domácí úkol :-)

- Načíst dva soubory po řádcích, druhý sloupec vždy rozdělit (split) na znaku '|'.
• Z prvního souboru se naučit množinu známých rámčů.
• U druhého souboru spočítat, kolik rámčů bylo spatřeno v množině známých rámčů.
• Recall = podíl těch spatřených ke všem testovacím.

Než se skript zmerit-recall.pl podaří odladit, budeme opakovat zadávat **make výsledek**, abychom skript spustili:

Nakonec se výsledek dozvídáme takto:
cat výsledek ⇒ 67.5 %

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Lepší práce s daty: n-fold evaluation

- Výsledek předešlého pokusu je nestabilní, záleží na konkrétních vybraných slovesech (vzali jsme slovesa od začátku abecedy!)
- Stabilnější výsledek dostaneme tak, že pokus budeme opakovat desetkrát, vždy jednu desetinu sloves použijeme jako test a ostatní k trénování.

Můj skript nfold právě tohle řeší. Obohaťme Makefile:

stabilni: joined zmerit-recall.pl

nfold "./zmerit-recall.pl %train %test" < \$< > \$@

- nfold načte všechny řádky ze vstupu, zamíchá pořadí, rozdělí na desetiny

- pak spustí daný shellovy skript (program s parametry) celkem desetkrát, přičemž vždy připraví trénovací a testovací soubor a speciální řetězec %train a %test nahradí jmény příslušných souborů

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Jak to dopadlo

make stabilni ; cat stabilni

```
1 85..43
2 91..58
3 90..00
4 93..24
5 90..09
6 88..01
7 94..25
8 92..34
9 92..29
10 90..95
```

- Už prosté promíchání sloves vedlo k podstatně jinému výsledku: 85 místo 67 %
- Je vidět, jak rozptýlené hodnoty jsou: 85 až 94 %

/home/bojar/tools/shell/grp -keys= -items=AVG2,STDDEV2 < stabilni
⇒ 90.82 ± 2.60

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Co když by VALLEX byl menší?

vyvoj: joined

```
rm -f $@
for i in 50 100 200 500 1080; do \
    cat $< \
    | shuffle \
    | head -$((($i+50)) ) \
    | nfold --testsize=50 "./zmerit-recall.pl %train %test" \
    | prefix --tab $i \
    >> $@ ; \
done
```

```
for i in ...; do cmd; done cyklus v bashi, proměnná i
$ i hodnota bashovské proměnné $i
$((1+2)) výpočet výrazu v bashi
dvojí dolar nutno psát kvůli make
shuffle, prefix moje nástroje na promíchání řádek a přidání prefixu
```

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Jak to dopadlo

make vyvoj ; head -5 vyvoj

```
| přidal prefix, velikost trénovací sady
|   | přidal nfold, číslo skupiny
|     | samotný výsledek skriptu zmerit-recall.pl
50   1   30.98
50   2   35.22
100  1   41.67
100  2   50.45
100  3   53.43
...
```

```
grp -keys=1 -items=AVG3,STDDEV3 vyvoj | sort -n
50   33.10  3.00
100  48.52  6.11
200  56.69  2.94
500  76.99  4.10
1080 90.92  2.62
```

... na generování tohoto přehlednejšího výstupu se samozřejmě hodí navazující pravidlo v Makefile.

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Udržet pořádek, sdílet s kolegy / na víc počítačích

CVS = Concurrent Versions System

⇒ **man cvs**

⇒ http://ufal.mff.cuni.cz/~semecky/vallex/documents/navod_cvs/

- Pro všechny účastníky existuje jeden společný depozitář (repository).
- Jednou za život si každý vytváří odštěpek: pracovní adresář (cvs check-out).
- Pravidelně se v pracovním adresáři:
 - zaregistrovávají nové soubory (cvs add),
 - vkládají platné verze do repozitáře, aby byly k dispozici všem (cvs commit),
 - aktualizují pracovní verze podle toho, co udělali jiní (cvs update).

Existují i modernější implementace (Subversion, svn) nebo přístupy (git).

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Výhody CVS

Očividné (proto bylo CVS vyvinuto):

- pohodlné "kopírování" soustav pracovních souborů mezi lidmi či počítači
- pohodlné řešení případných konfliktů
- podrobný přehled o historii souborů (možnost kdykoli se vrátit)

Méně nápadné:

- vede k pečlivě oddělení citlivých souborů (náročné na výrobu, ruční práce ap.) a souborů odvozených pomocí Makefilů
Do CVS přidávám (add) právě ty drahé soubory, neaktuální naopak odstraňuji (cvs remove).
- snadno se otěstuje, že nic základního v CVS nechybí
Uděláme čistý check-out (hraju si na nového uživatele), necháme vše vybudovat od základu.

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Slíbená smršt experimentů

- Každý experiment bude mít svůj podadresář: exp-pokus1, exp-pokus2...
- Budu mít jeden společný Makefile.common s obecnými pravidly a každý experiment bude mít ve svém podadresáři vlastní Makefile:
Takto se jeden Makefile vleže do jiného:
include ..\Makefile
- Každý Makefile bude (po svém) reagovat na dohodnuté cíle:
for e in exp-*; do cd \$e; make results; cd ..; done
- Taktto spojuje výsledky všech experimentů pro komparativní vyhodnocení:
(for e in exp-*; do prefix --tab \$e < \$e/results; done) > all-results
- Navíc si mohu připravit globální Makefile s cíli:
make all-results
make clone-pokus1-novypokus
nejen udělá kopii, ale též vloží standardní výbavu experimentu do CVS

Ondřej Bojar Kočírujeme smršt experimentů 25. leden 2006

Shrnutí

Na Unixu se pohodlně pracuje:

- s textovými soubory (roury, přesměrování)
- se stavebními kamínky, skripty všeho druhu
- s postupným vylepšováním procedury pro vyhodnocení nějakého experimentu včetně možnosti sledovat více variant postupu (různé cíle v jednom Makefile)
- s více pracovními verzemi těchž experimentů, z více počítačů, s více spolupracovníky současně (CVS)

Existuje i pro Windows:

- bash a další nástroje – balík cygwin ⇒ <http://cygwin.com/>
- ikonkové CVS – TortoiseCVS ⇒ <http://www.tortoisecvs.org/>