

Unixové systémy a shell

(KMI/XUNIXS)

verze z 13. února 2026

CO JE OPERAČNÍ SYSTÉM?

Základní komponenty operačního systému

- *jádro*
základní softwarové vybavení počítače, které se stará o správu systémových zdrojů (např. hardware, ovladače, procesy, paměť, filesystém). Uživatelským programům poskytuje API.
- *základní programy*
uživatelská správa hardware, dat a procesů, ovládání počítače, základní uživatelské programy

Předchozí označováno jako *base systém*.

Termín OS někdy zahrnuje i další uživatelské programy (mailový klient, web browser, kancelářský balík, multimediální programy), které jsou nainstalovány současně s base systémem.

KDY JE OS UNIXOVÝ

Existuje certifikát, po jehož získání je OS možno obsahovat jako “unix”. Vyžadováno určitý tvar uživatelského a programátorského rozhraní (např. jsou vyžadována existence některých hlavičkových souborů, shellu a základních utilit atd. (viz *base systém*)).


Obecně ale libovolný OS, který koncepčně a technicky vychází z původního unixu a přibližně se drží *unixové filozofie*, např.

- příkazový interpret (shell)
- jeden program dělá jednu věc, ale pořádně
- programy jdou skládat dohromady: výstup jednoho programu je vstupem jiného programu (převážně textový formát)
- všechno je soubor: například zařízení jsou v systému reprezentována soubory

VZNIK UNIXU A JEHO VÝVOJ


- 60. léta. Bellovy laboratoře: CTSS, Multics
- konec 60. let již UNIX, DEC PDP 7 (velká část napsána K. Thomsonem za 3. týdny) poté DEC PDP 11
- zlom je vznik programovacího jazyka C a přepsání unixu do C. To spolu s přenositelným překladačem jazyka C zajistilo přenositelnost unixu.
- 6. verze (cca 9000 řádků kódu), *Lion's commentary on Unix 6th edition*
- od té doby bouřlivý vývoj v komerčních, akademických i svobodných/open-source verzích (unix wars)
- IEEE POSIX standard (systémové rozhraní atd).
- Od 80. let projekt GNU, FSF, R. M. Stallman (GPL licence a copyleft ...)
- 1983 — Turingova cena pro K. Thomsona a D. Ritchieho za Unix/C
- Od 1991, Linus Torvalds, linuxové jádro, později linuxové distribuce





GRAFICKÁ ROZHRANÍ

- X server (protokol a implementace), Wayland
- Desktop Environment vs okenní manažer
- nejznámější velké DE: KDE, GNOME, XFCE
- obrovské možnosti konfigurace (pro vlastní workflow)



LINUXOVÉ DISTRIBUCE

- base system (linuxové jádro a utility, často GNU)
- balíčky, balíčkovací systém, repozitáře
- vybrané a předkonfigurované DE, vybrané programy (např. webový prohlížeč, terminál, etc)
- provedená technická rozhodnutí: filesystem, start systému, kde je konfigurace
- updatování: rolling release, nová verze každých x měsíců
- cílová skupina
- příklady: Fedora, OpenSuse, Ubuntu, Debian, Arch, Gentoo, , Mint,

příkazová řádka, interpretuje a provádí příkazy, tiskne výsledek

bash (rozšířený, budeme jej používat), další: zsh, fish, kornshell, ...

Základy ovládání

zápis příkazu

spuštění příkazu

doplňování

skok na začátek řádku






skok na konec řádku

vyjmutí (od kurzoru do konce řádku)

vyjmutí (celého řádku)

vložení

zápis z klávesnice



Příklady příkazů

<code>pwd</code>	<code># vytiskne (abs. cestu) aktuálního adresáře</code>
<code>ls</code>	<code># vylistuje obsah aktuálního adresáře</code>
<code>echo</code>	<code># tiskne argumenty na standardní vstup</code>
<code>exit</code>	<code># ukončí aktuální shell</code>
<code>whoami</code>	<code># vytiskne aktuálního uživatele</code>
<code>hostname</code>	<code># vytiskne jméno počítače</code>
<code>uname</code>	<code># tiskne systémové informace</code>
<code>who</code>	<code># tiskne seznam přihlášených uživatelů</code>

Obecný tvar příkazu

```
cmd [přepínače] [arguments]
```

(Hranaté závorky v dokumentaci příkazů značí, že danou věc lze vynechat)

Syntax přepínačů (obvykle)

```
-l          # krátký  
--slovo     # dlouhý
```

Například

```
ls -l --color
```

Typ příkazu

- vestavěný příkaz shellu (*builtin*), manuál: `help`
- samostatný spustitelný program, manuál: `man`, `info`

Zjišťování toho, kde hledat informace

<code>type</code>	<code># zjistí typ příkazu</code>
<code>apropos</code>	<code># prohledá jména a popisy manuálových stránek</code>
<code>whatis</code>	<code># najde manuálové stránky</code>
<code>which</code>	<code># najde umístění binárního souboru</code>
<code>whereis</code>	<code># najde umístění binárního souboru a dokumentace</code>

Program `man` je přepne terminál do celoobrazovkového režimu. Podobným programům, které tak činí za účelem zobrazení nějakého obsahu, říkáme pagery (z angličtiny, zobrazují po stránkách). Má specifické ovládání (část je společná všem pagerům, často nápověda `h`, ukončení `q`, vyhledávání `/`)

Příkladem dalšího pageru je program `less`, který zobrazuje obsah souboru nebo svůj standardní vstup.

UŽIVATELSKÉ NASTAVENÍ BASH

Pro nás postačuje soubor `.bashrc` v domovském adresáři.

Příklad: konfigurace promptu

- proměnná `PS1`

<code>\d</code>	Date	<code>\h</code>	Host
<code>\n</code>	Newline	<code>\t</code>	Time
<code>\u</code>	Username	<code>\W</code>	Current working directory
<code>\w</code>	Full path to current directory		

- `PS1='\n[ \u@\h: \w ]\n$ '`

PROMĚNNÉ PROSTŘEDÍ

bez typu, bere se jako posloupnost znaků

Tisk proměnné

```
echo $var
```

(Toto je první příklad expanze: procesu, kterým shell mění zadaný příkaz. Nejdříve \$var nahradí hodnotou proměnné var a až poté spustí echo.)

Zajímavé (systémové) proměnné

PS1	# prompt první úrovně
HOME	# domovský adresář aktuálního uživatele
PWD	# aktuální adresář
OLDPWD	# předchozí adresář
SHELL	# defaultní shell
PATH	# adresáře pro vyhledávání spustitelných souborů

ALIAS

```
alias name=command
```

- méně psaní
- kratší jména pro komplikované instrukce
- bez překlepů (`alias sl=ls`)
- bezpečné příkazy (`alias rm='rm -i'`)
- verze bez alias (`\prikaz`)

```
unalias      # zrusi alias  
alias        # vypise aktualni alias
```

HISTORIE PŘÍKAZŮ

history

```
-c          # vyprazdni historii
-d n        # smaze n-tou položku z historie
-w          # zapisou současnou historii do souboru
-r          # načte historii ze souboru
```

:parametr

n zobrazí posledních n položek v historii

V shellu

```
!n          n-ta instrukce v historii
!!          poslední instrukce v historii
!string     poslední instrukce, která začíná string
```

Procházení pomocí šipek (**Ctrl** + **p**, **Ctrl** + **n**).

Prohledávání historie (**Ctrl** + **r**), potom **↵** je provedení nalezeného příkazu a **Ctrl** + **g** ukončení prohledávání.

PŘESMĚROVÁNÍ VSTUPU A VÝSTUPU

Programy mají následující vstup a výstup (mimo soubory aj., které si otevřou sami)

- standardní vstup (`stdin`)
- standardní výstup (`stdout`)
- standardní chybový výstup (`stderr`)

Tyto jsou typicky klávesnice a terminál. Lze je přesměrovat do/ze souboru, případně jinému programu.

Přesměrování `stdout`

> file	do souboru, existující soubor je přepsán
>> file	do souboru, obsah přidán na konec souboru
program-A program-B	stdout programu A je přesměrován na stdin programu B.

PŘÍKLADY

```
# vytvoří (nebo přepíše, pokud existuje) soubor foo.txt,  
# jeho obsahem je hodnota proměnné PATH  
echo $PATH > foo.txt  
  
# připojí k souboru další řádek obsahující xxxxx  
echo xxxxx >> foo.txt  
  
# co je po provedení následujícího řádků obsahem souborů foo.txt a files.txt?  
echo foo.txt > files.txt  
  
# program cat (od concatenate) tiskne obsah souborů za sebe na stdout  
cat files.txt foo.txt
```

FILTRY

Programy často umí zpracovat obsah souboru nebo standardní vstup, pokud není soubor zadán. Takové program svůj vstup nějak transformuje, výsledek vypisuje na stdout. Dá se na to dívat tak, že svůj vstup filtruje.

Příklad: program `wc`

```
# vytiskne počet řádků v souboru foo.txt  
wc -l foo.txt
```

```
# také vytiskne počet řádků v souboru foo.txt s použitím přesměrování  
cat foo.txt | wc -l
```

```
# vytiskne počet položek v aktuálním adresáři  
ls -l | wc -l
```

Přesměrování stdin

< file	obsah souboru je dán na stdin programu
<< END	načítám více řádků na stdin, končím řádkem s obsahem END

```
# spočítá počet řádků v souboru file.txt
```

```
wc -l < file.txt
```

```
# vytiskne dva řádky
```

```
cat << END      # enter, na každém novém řádku se zobrazí druhotný prompt $$
```

```
$$ ahoj        # enter
```

```
$$ svete       # enter
```

```
$$ END         # enter
```

```
# s přesměrováním do souboru
```

```
cat << DONE > fruit.txt
```

```
$$ apple
```

```
$$ orange
```

```
$$ DONE
```

- pro přesměrování stderr použijeme `2>`, např. `cmd 2> /dev/null` přesměruje stderr cmd do souboru `/dev/null`.
- přesměrování stderr na stdout: `2>&1`
- přesměrování stderr a stdout do stejného souboru: `&> file`
- přesměrování stdout a stderr do roury: `|&`

ÚKOLY Z PRVNÍ PŘEDNÁŠKY

- 1 Získejte přístup k fungující instalaci některé Linuxové distribuce. (Třeba nainstalovat do *VirtualBoxu*; odkaz ke stažení a návod na instalaci jsou na webu předmětu.) Distribuce může být libovolná, jako distribuce pro začátečníky bývají označovány: *Linux Mint*, *Ubuntu*, *Pop!_OS*, *Zorin OS*, *Fedora XFCE spin*.
- 2 Spust'te emulátor terminálu. Projděte si slajdy a vyzkoušejte uvedené příkazy a příklady. Experimentujte s vlastními příkazy (nezapoměňte, že máte k dispozici manuálové stránky).
- 3 Volitelně se v systému zorientujte, vyzkoušejte si nainstalovat nějaký program, nastavit barvy a font v emulátoru terminálu.

Souborový systém

CO JE SOUBOROVÝ SYSTÉM

Logický způsob uspořádání uložení dat na (částech) ukládacích zařízení do jedné stromové struktury,

Hlavní objekty

- soubor: atomický kus uložených dat (z logického pohledu)
- adresář: kolekce souborů a jiných adresářů (lze chápat jako speciální soubor obsahující tuto kolekci).
- vztah rodič a potomek (je-li A v adresáři B, pak je jeho potomkem)

Vše je v jednom adresáři, je to kořenový adresář, jeho jméno je /.

Cesta

- relativní (cesta stromem mezi dvěma obecnými uzly)
- absolutní (cesta stromem od kořene do nějakého uzlu),
- jednotlivé uzly odděleny lomítkem (znakem /),
- aktuální adresář ., nadřazený adresář ..

Příklady


```
# viz obrázek na dalším slajdu
```

```
# absolutní cesta
```

```
/usr/local/bin
```

```
# relativní cesta z adresáře /home/tux do adresáře /home/yxz/bin
```

```
../yxz/bin
```



Další význam pojmu souborový systém: implementační pohled

- konkrétní způsob správy uložení dat na médiu
- EXT[2,3,4], (V)FAT, NTFS, ZFS, Btrfs atd.

INODE, LINKY

- *inode*

Struktura reprezentující soubor, obsahuje metainformace (typ souboru, práva, data změny atd.) a ukazatel na data. Každý inode má číslo.

- *hardlink*

Jméno a inode číslo

- *symlink, symbolický link*

Soubor obsahující absolutní cestu (i k adresáři)

Ve stromové hierarchii jsou vlastně hardlinky a symlinky. Inode pro soubor může mít více hardlinků, má-li 0 hardlinků, je odstraněn. Inode pro adresář má pouze jeden hardlink (kvůli acykličnosti grafu souborů). Pokud neexistuje objekt, na který odkazuje cesta v symlinku, není symlink smazán. Adresář je soubor obsahující jména a inode čísla svých položek.

```
# zobrazení inode čísel jednotlivých položek
```

```
ls -i
```

```
# vytváření linků: ln [option] TARGET LINK_NAME
```

```
# vytvoření hardlinku
```

```
ln /home/osicka/foo.txt blah.txt
```

```
# vytvoření symlinku
```

```
ln -s /home/osicka/foo.txt sym-blah.txt
```

GLOBBING

Shell provádí expanze výrazů. Pro teď si expanzi představme jako náhradu části textu v příkazové řádce něčím jiným. Expanze tak transformuje obsah příkazové řádky. Samotný příkaz je spustěn až po této transformaci.

Nahrazování se někdy provádí tak, abychom po nahrazení dostali platné cesty (typicky v případech, kdy shellu necháváme v nahrazování větší volnost).

Nahrazovaný výraz	Význam
*	0 nebo více libovolných znaků
?	jeden libovolný znak
[chars]	jeden ze znaků v řetězci chars
[c1-c2]	jeden ze znaků v rozsahu c1-c2, např. [0-9], [a-z]
{word1,word2,...}	jedno ze slov, plná expanze, nemusí být cesta!
[^chars]	jákýkoliv znak, který není v chars
~	zkratka domovského adresáře

Když není expanze nalezena, je znak chápán doslovně.

Expanze se neprovádí v části mezi apostrofy. V části mezi uvozovkami se expandují pouze jména proměnných.

Lze hezky testovat pomocí echo, které tiskne na stdout přesně takový řetězec, který dostane na argument.

# příkaz	# co vytiskne (v aktuálním adresáři)
# -----	
echo *	# obsah adresáře
echo *.txt	# soubory (a adresáře) s koncovkou .txt
echo [abc]*	# soubory a adresáře začínající jedním z a,b,c
echo /home/osicka/{doc,bin}	# /home/osicka/doc /home/osicka/bin

ZÁKLADNÍ PŘÍKAZY

<code>cd</code>	změna aktuálního adresáře
<code>mv</code>	přejmenování, přesun
<code>cp</code>	kopie
<code>rm</code>	smazání
<code>mkdir, rmdir</code>	vytvoření, smazání prázdného adresáře
<code>ls</code>	výpis obsahu adresáře
<code>ln</code>	vytváření linků (hardlinků i symlinků)
<code>du</code>	velikosti adresářů a souborů
<code>file</code>	zjištění typu souboru
<code>touch</code>	vytvoření/změna času modifikace souboru
<code>df</code>	informace o volném/obsazeném místě

- cíl: ochrana před zneužitím systémových prostředků
- pro soubory a adresáře: kdo přistupuje vs co dělá
- *kdo přistupuje*: vlastník (u), skupina (g), zbytek (o)
- *co dělá*: čtení (r), zápis (w), spuštění (x). Existuje 8 typů přístupu odpovídající podmnožinám $\{r, w, x\}$.
- Význam práv

	soubor	adresář
r	prohlížení, kopie	vidí obsah, např. ls
w	přepsání	může přidávat soubory
x	může spustit	může do něj vstoupit, např. cd

ZOBRAZENÍ PRÁV

```
ls -l filename # níže je vysvětlen výstup
```

```
-rw-r--r-- 1 osicka osicka 74815 Sep  9 13:40 slides.tex
|[-][-][-]  [----] [----]
| | | |      |      |
| | | |      |      +-----> skupina
| | | |      +-----> vlastník
| | | |
| | | +-----> práva ostatních
| | +-----> práva skupiny
| +-----> práva vlastníka
+-----> filetype: - file
                        d dir
                        l link
```

```
# alternativně pomocí utility stat
```

```
stat filename          # kompletní info o souboru
stat -c "%A" filename  # práva jako u ls -l
stat -c "%a" filename  # práva jako číslo
```

```
chmod permissions files
```

Zadání permissions, první verze

```
xyz
```

- x řetězec ze znaků u, g, o, určuje, komu budou práva změněna. (Lze použít znak a s významem všichni.)
- y je změna práv: + je přidání, - je odebrání a = je nastavení práva,
- z je řetězec ze znaků r, w, x, označuje, o která práva se jedná.

```
chmod g-w,o-r file.txt      # skupine odebere zápis, ostatním čtení  
chmod u=rwx,g=r,o=  file.txt # vlastníku nastavíme vše, skupině čtení,  
                             # ostatním nic
```

Zadání permissions pomocí čísla

- Typům práv přiřadíme trojbitová čísla $r \rightarrow 4$ (100), $w \rightarrow 2$ (010), $x \rightarrow 1$ (001).
- Práva vyjádříme číslicí, která vznikne součtem $\{r, w, x\}$ je 5 (101). Součet lze dělat i po bitech. Argument parameters jsou tři číslice, v pořadí ugr.

```
chmod 750 file.txt      # vlastník vše, skupina čtení a spuštění, ostatní nic
```

Sticky bit

- pro adresáře, do kterého je povolen zápis
- o může do adresáře zapisovat. Editovat soubory (včetně mazání) může pouze jejich vlastník.

```
chmod o+t dir           # nastavení sticky bit 1. způsobem  
chmod 1722 dir          # nastavení sticky bit 2. způsobem
```

DEFAULTNÍ PRÁVA

Pro nově vytvořené soubory 666, pro nově vytvořené adresáře 777. Lze změnit pomocí masky, kterou lze zjistit a nastavit pomocí utility umask.

Maska je číslo, které vyjadřuje *neudělená práva* (nelze jí tedy práva přidávat). Když odečteme masku od 666 dostaneme defaultní práva pro soubory, když ji odečteme od 777, dostaneme defaultní práva pro adresáře.

je-li maska 022, potom jsou defaultní práva

soubor	$666 - 022 = 644$	tj. <code>rw-r--r--</code>
adresář	$777 - 022 = 755$	tj. <code>rw-r-xr-x</code>

potřebnou masku pro soubory tak spočítáme pomocí $666 - \text{cílená práva}$
v našem příkladu tedy

$\text{maska} = 666 - 644 = 022$

HLEDÁNÍ SOUBORŮ - PROGRAM FIND

```
find [options] [where] [pattern]
```

```
# options - různá nastavení, např. jak se chovat k linkům  
# where   - v jakém adresáři hledat, hledá se v celém podstromu  
# pattern - výraz, kterým určíme, jaké soubory hledat a co s nimi dělat
```

Je-li prázdné where, bereme aktuální adresář. Pokud pattern neobsahuje podmínky pro hledání, vyhovuje podmínkám celý obsah where (celý podstrom). Není-li specifikováno, co s výsledky dělat, jsou vytištěny. Přitom výsledek je cesta k souboru nebo adresáři vyhovujícímu podmínkám.

```
# vytiskne obsah podstromu, jehož kořenem je aktuální adresář;  
# pro každý soubor a adresář jeden řádek obsahující relativní cestu k němu  
find
```

příklady vyhledávacích podmínek

soubory s koncovkou .conf

```
find /etc/ -name "*.conf"
```

soubory větší než 400 MB; + znamená větší, - menší, nic přesně.

```
find ~ -size +400M
```

typ souboru: soubor f, adresář d, další v manuálu

```
find ~ -type f
```

soubory změněné v posledních pěti dnech

```
find ~ -type f -mtime 5
```

soubory, jejichž vlastníkem je uživatel osicka

```
find ~ -user osicka
```

soubory, které nekončí koncovkou .conf

```
find ~ -type f -not -name "*.conf"
```

Co dělat s výsledky

```
-delete  
-exec command          # pro každou shodu spustí command  
-ok    command          # jako exec, ptá se na potvrzení  
-print format           # formátovaný výstup
```

```
# v command je nalezena cesta značena pomocí {}, navíc musí končit středníkem,  
# který nezpracuje shell (napíšeme \; nebo ';' )
```

```
# přesune všechny .jpg soubory z posledních pěti dnů do adresáře ~/pictures  
find -name "*.jpg" -mtime 5 -exec mv {} ~/pictures/ \;
```

```
# vytiskne k nalezeným souborům i velikosti v kilobajtech  
find . -type f -printf '%p\t%k KB\n'
```

DALŠÍ UŽITEČNÉ OPTIONS A PODMÍNKY

```
# options
-L          # při vyhledávání se vnořujeme symbolických linků
-D          # zobrazuje pomocné informace

# podmínky
-maxdepth n # strom je prohledáván pouze do hloubky n
-mindepth n # strom je prohledáván od hloubky n
```

/bin	uživatelské spustitelné soubory
/etc	konfigurační soubory
/home	domovské adresáře uživatelů
/lib	sdílené knihovny
/root	domovský adresář správce
/sbin	systémové spustitelné soubory
/usr	aplikace atd
/var	cache, mail, log, spool
/dev	zařízení, /dev/null, /dev/zero

ÚKOLY Z DRUHÉ PŘEDNÁŠKY

Obecný úkol: Vyzkoušejte si základní práci s příkazy z přednášky. Konzultujte manuálové stránky (nebo jinou dokumentaci, např. online).

Pomocné úkoly (některé převzaty z prezenčního studia od doc. Outraty).

- Zobrazte cestu k domovskému adresáři (už to umíte 2 způsoby).
- Zobrazte velikost aktuálního adresáře.
- Vytvořte adresář `test` a do něj textový soubor `test.txt` obsahující nějaký text (např. pomocí textového editoru, případně pomocí přesměrování). Obsah souboru zobrazte v konzoli.
- Vytvořte adresář `test2` a soubor `test/test.txt` do něj přesuňte.
- Do adresáře `test` vytvořte symbolický link na soubor `test2/test.txt`. Pomocí tohoto linku zobrazte jeho obsah.
- Soubor `test2/test.txt` smažte a pomocí linku v adresáři `test` zobrazte jeho obsah. Co se stalo?

- Vyhledejte soubory v adresáři `/etc/` větší než 1 kB a a současně nekončící koncovkou `.conf`.
- Napište příkaz, který dá na stdout cesty ke všem souborům (ne adresářům) se jménem začínajícím `IMG` a koncovkou `.jpg`
- Napište příkaz, který dá na standardní výstup cesty ke všem souborům (nikoliv adresářům), rekurzivně v domovském adresáři, modifikovaným ne dříve než před 10 dny.
- Napište příkaz, který všechny soubory z adresáře `foo`, ale nikoliv z jeho podadresářů, obsahující ve jméně `xx`, přesune do adresáře `bar`.
- Vytvořte soubor `test.txt`. Odeberte vlastníkově právo zápisu a poté do něj zkuste zapsat. Práva souboru vraťte.
- Vytvořte adresář `foo`. Nastavte všechna práva vlastníkově a pouze právo vstupu skupině a ostatním uživatelům.

Procesy

Proces je aktivní entita zhruba odpovídající běžícímu programu

- má přiděleny zdroje: procesorový čas, paměť, otevřené soubory, síťová spojení.
- OS udržuje jeho stav, rozhoduje a rozhoduje přidělování jiných zdrojů.
- Existují ještě vlákna.

Strom procesů, pid

- pid - jednoznačný identifikátor procesu (zkratka *process id*)
- proces spouští uživatel (technicky ale jiný proces)
 - kopie spouštěcího procesu (`fork`)
 - spustí se program, který nahradí kopii (`exec`)
- mezi procesy je tedy vztah rodič a potomek
- existuje proces, který se spouští jako první a je předkem všech ostatních: klasicky `init`, má pid rovno 1.

Přístupová práva procesů

- Proces má vlastníka a skupinu, od kterého dědí přístupová práva. Obvykle je to uživatel, který jej spustil.
- Speciální bit v přístupových právech spustitelného souboru: je-li nastaven, je vlastníkem procesu vlastník spustitelného souboru, nikoliv uživatel, který jej spustil: to umožňuje přístup takového procesu do filesystému tam, kam uživatel nemá přístup (některé systémové procesy mají vlastní účty, např. `lpd` pro tisk).
Lze nastavit pomocí `chmod`, kde se `x` pro `u` nebo `g` nastaví na `s`.

Priorita procesů (jak je důležité mu přidělovat prostředky OS)

- číslo v rozsahu -20 až 19, čím menší tím je priorita vyšší
- standardně s prioritou 0, lze změnit pomocí `nice`, `renice`. Obyčejní uživatelé mají jenom kladné priority, mohou měnit jenom na vyšší číslo.

MONITOROVÁNÍ PROCESŮ

ps

```
# nejchaotictější systém přepínačů všech dob (z historických důvodů)
# -o pid,ppid,cmd ...
# a (bsd styl, vsichni uzivatele)
# x (process nemusí mít navazan terminal)
# -U user1,user2 ... (uzivatel, který vytvořil proces)
# -u user1,user2 ... (uzivatel, jeho práva proces má)
# bez argumentů pouze potomci aktuálního shellu
```

```
top      # pager, vlákna: n*[{command}]
htop     # pager, novější (proces ~ task)
pstree   # strom procesů na stdout
pgrep    # vyhledání podle vzoru (např. jména, více později).
```

SPOUŠTĚNÍ PROCESŮ ZE SHELLU

- jménem spustitelného souboru, pokud je umístěn někdy v adresáři v PATH.
- cestou (relativní nebo absolutní) ke spustitelnému souboru (např. ./filename)
- procesy na pozadí (bez interakce s uživatelem, shellu zůstane standardní vstup, standardní výstup je sdílený) a na popředí (proces má standardní vstup i výstup), výpis job number a pid.
- spuštění na pozadí: & za příkazem; může být nutné přesměrovat výstup
- výpis procesů (spuštěných z aktuálního terminálu)

jobs

- přesun z popředí do pozadí/na popředí:

```
ctrl-z      # pozastavení, (SIGTSTP)
bg job-number # rozbehnutí na pozadí
fg job-number # přesun do popředí
```

když vynecháno job-number, bereme poslední úlohou (na popředí, spuštěnou).

UKONČENÍ PROCESU

```
kill -NAME pids  # NAME je jméno signálu, jde bez SIG
```

- obecný mechanismus posílání signalů procesům, některé proces může zpracovat podle svého
- signál SIGKILL: okamžité ukončení procesu, proces nemůže reagovat (až na `init` proces), signál SIGTERM žádost o terminaci, proces může reagovat, signál SIGINT přerušení procesu (velmi podobné SIGTERM), často navázáno na `ctrl` + `c` (v shellu).

Po konci procesu

- process vrací rodiči návratovou hodnotu (0 ok, jinak kód chyby)
- jsou ukončeni i potomci, pokud to není zařízeno jinak
- některé procesy to zařídí sami (např. shell)
- `nohup`: proces běží i po odhlášení uživatele, `disown`. Za obojím je změna rodiče.
- *zombie proces* - potomek, který skončil, ale OS jej udržuje v záznamech, aby si rodič mohl vyzvednout návratovou hodnotu.

ÚKOLY ZE TŘETÍ PŘEDNÁŠKY

- Vyzkoušejte si monitoring procesů.
- Zjistěte všechny procesy aktuálního uživatele.
- Spust'te proces, např. `sleep`, zastavte jej, převed'te jej na pozadí, a poté opět na popředí.
- Spust'te proces, a ukončete jej pomocí příkazu `kill`, spust'te jej znovu a ukončete jej z programu `htop`.

```
/*  
 * compile, run, and then search for the undead with  
 * > ps axo stat,ppid,pid,comm | grep '^Z'  
 */  
  
#include <stdlib.h>  
#include <sys/types.h>  
#include <unistd.h>  
  
int main()  
{  
    pid_t child_pid = fork();  
    if (child_pid > 0)  
    {  
        sleep(60);  
    }  
    else  
    {  
        exit(0);  
    }  
    return 0;  
}
```

Práce s textem

KÓDOVÁNÍ ZNAKŮ

- Tradičně (před Unicode): 1 znak = 1 bajt
- ascii tabulka, prvních 128 znaků společných (cca anglická abeceda), zbytek národní abecedy: různorodé. Např. čeština: windows-1250, ISO 8859-2.
- Unicode (32 bitů), UTF-32, UTF-16, UTF-8
- převody pomocí `recode` nebo `iconv`

Konce řádků

- unix: bajt s hodnotou 13 (CR, Carriage Return)
- windows: 2 bajty s hodnotami 10 13 (LF, Line Feed)
- převody: např. pomocí `dos2unix` a `unix2dos`

Obvykle je všude nainstalován.

Pracuje v režimech (tj. je modální). Dva základní režimy

① *Command mode* - příkazový režim

- vi se v něm spouští
- pro pohyb v textu, mazání, kopírování, ukládání a ukončení.
- návrat z jiného módu pomocí Esc.

② *Insert mode* - vkládací režim

- pro psaní.
- Aktivuje se stiskem i, a nebo o.

ZÁKLADNÍ PŘÍKAZY

Pohyb

- h, j, k, l – vlevo, dolů, nahoru, vpravo
- 0 – začátek řádku
- \$ – konec řádku
- gg/G – začátek/konec souboru

Úpravy

- x – smazat znak
- dd – smazat řádek
- yy – kopírovat řádek
- p – vložit

Ukládání a hledání

- Uložit změny: :w
- Ukončit editor: :q
- Uložit a ukončit: :wq
- Ukončit bez uložení: :q!
- Hledání slova: /slovo

TEXTOVÉ EDITORY - EMACS

Spuštění v terminálu: `emacs -nw file`

Otevření a uložení

- `ctrl` + `x` `ctrl` + `f` – otevřít soubor (find file)
- `ctrl` + `x` `ctrl` + `s` – uložit soubor (save)
- `ctrl` + `x` `ctrl` + `c` – ukončit Emacs

Pohyb v textu

- `ctrl` + `f` – vpřed (forward)
- `ctrl` + `b` – vzad (back)
- `ctrl` + `n` – dolů (next)
- `ctrl` + `p` – nahoru (previous)

Úpravy textu

- `ctrl` + `d` – smazat znak pod kurzorem
- `meta` + `d` – smazat slovo (na současné klávesnici je Meta = Alt)
- `ctrl` + `k` – smazat zbytek řádku
- `ctrl` + `y` – vložit poslední smazaný text (yank)
- `ctrl` + `/` nebo `ctrl` + `x` `u` – zpět (undo)

Hledání a nahrazování

- `ctrl` + `s` – hledat dopředu (incremental search)
- `ctrl` + `r` – hledat dozadu
- `meta-%` – nahradit text (query replace)
- `!` v režimu nahrazování – potvrdit všechny výskyty

TEXTOVÉ EDITORY - DALŠÍ

- nano
- jed
- joe
- pico

Regulární výrazy

Uvažujeme abecedu znaků Σ neobsahující rezervované znaky.

Slovo nad Σ je konečná posloupnost znaků ze Σ . Jazyk nad Σ je množina slov nad Σ . Pro slova u a v pomocí uv značíme slovo vzniklé jejich zřetězením (zapojením za sebe). Prázdné slovo (posloupnost 0 znaků) označujeme ϵ .

Příklad: Abeceda $\Sigma = \{a, b, c\}$, $aaabc$ je slovo nad Σ . Množina $\{abc, aa, aaab, abc\}$ nebo množina všech slov začínajících znakem a jsou jazyky.

Regulární výraz je slovo nad abecedou obsahující Σ obohacenou o rezervované znaky, vytvořené podle následujících pravidel.

- Jeden znak $a \in \Sigma$ je regex.
- Speciální znak $.$ (tečka) je regex. ($.$ je speciální znak)
- Jsou-li e, f regulární výrazy, je jimi i ef a $e|f$. ($|$ je speciální znak.)
- Je-li e regulární výraz, jsou jimi i e^+ , e^* , $e^?$. ($+$, $*$, $?$ jsou speciální znaky.)

Dále za speciální znaky považujeme závorky, do nichž lze regulární výraz vložit.

Uvažujme jazyky L, M . S jazyky lze dělat standardní množinové operace (Jazyk je množina slov.)

Další operace

- *Zřetězení jazyků.* $LM = \{uv \mid u \in L, v \in M\}$.

Příklad: $L = \{aa, bb, cc\}$, $M = \{ab, c\}$, $LM = \{aaab, aac, bbab, bbc, ccab, ccc\}$.

- *Mocnina.* $L^0 = \{\epsilon\}$, $L^n = L^{n-1}L$

Příklad: $L = \{a, bc\}$, $L^2 = \{aa, abc, bca, bcbc\}$

$L^3 = \{aaa, aabc, abca, abcbc, bcaa, bcbc, bcbca, bcbcbc\}$

- *Uzávěry.* $L^* = \bigcup_{i=0}^{\infty} L^i$, $L^+ = \bigcup_{i=1}^{\infty} L^i$.

Příklad: $L = \{aa, b\}$,

$L^* = \{\epsilon, aa, b, aaaa, aab, baa, bb, aaaaaa, \dots\}$

$L^+ = L^* - \{\epsilon\}$

SÉMANTIKA REGULÁRNÍCH VÝRAZŮ

Regulární výraz indukuje jazyk. Jazyk indukovaný regulárním výrazem r značíme $L(r)$. Je definován následovně.

- Pro $a \in \Sigma$ máme $L(a) = a$.
- $L(.) = \Sigma$.
- Pro regulární výrazy e, f máme

$$L(ef) = L(e)L(f) \text{ a}$$

$$L(e|f) = L(e) \cup L(f).$$

- Pro regulární výraz e máme

$$L(e^+) = L(e)^+,$$

$$L(e^*) = L(e)^*,$$

$$L(e?) = L(e) \cup \{\epsilon\}$$

$*$, $+$, $?$ mají vyšší priority než $|$ a zřetězení.

reg. výraz	jazyk

a	a
ab	ab
$a b$	a, b
$a b^+$	$a, b, bb, bbb \dots$
$(a b)^*$	prazdny retez, $a, b, bb, \dots$
$.$	$a, b, c, d, \dots$
$(.)^?$	prazdny retez, $a, b, c, d, ..$
$(.)^+$	vsechny retezce mimo prazdneho
$(.)^*$	vsechny retezce

ROZŠÍŘENÍ

V unixových systémech (i jinde) existují rozšíření regulárních výrazů (details často závisí na konkrétním programu, programovacím jazyku). Níže jsou některé příklady, details lze nalézt v manuálu ke konkrétnímu programu (např. grep).

- spec. znaky pro začátek a konec řádku,

```
^    # zacatek radku
$    # konec radku
```

- třídy znaků (příklady)

```
[retezec]    # libovolny znak ze slova retezec
[^retezec]   # libovolny znak, který není ve slove retezec
[:alnum:]    # libovolny alfanumericky znak
[:digit:]    # libovolna cislice
[:lower:]    # mala pismena
```

- specifické počty opakování

```
{n}      # presne n krat  
{n,}    # n nebo vicekrat  
{,m}    # maximalne m krat  
{n,m}   # najmene n krat, nejvyse m krat
```

- Zpětné reference. Výraz `\n`, kde `n` je nenulové celá číslice, představuje slovo, které odpovídá slovu vyhovujícimu `n`-tému uzávorkovanému podregexu.

regex	jazyk

<code>(ab)\1</code>	abab
<code>(.)\1</code>	aa, bb, cc, dd,
<code>(.)(.)\2\1</code>	aaaa,abba, acca, ...

VYHLEDÁVÁNÍ PODLE REGULÁRNÍHO VÝRAZU

Vyhledáváme části textu, která jsou slovy v jazyce indukovaném regulárním výrazem.

Shoda nemusí být jednoznačná (kvůli opakovačům), programy pro vyhledávání obvykle hledají co nejdelší (vůči opakovačům) shodu. Často také vyhledávají shody, které se nepřekrývají.

Program grep

```
grep [options] regex [files]
```

Prohledá soubory, vybere řádky z těchto souborů, které odpovídají regexu, a vytiskne je na standardní výstup.

- varianta `egrep` má povoluje více metaznaků (pro ty, které jsme si uvedli, už potřebujeme `egrep`), totéž jako `grep -E`. *[doporučuji používat]*
- `regex` se obvykle píše mezi apostrofy (`'`) nebo uvozovky `"`, aby se zabránilo shellu interpretovat některé metaznaky při expanzi.

Procvičit a testovat regulární výrazy lze pomocí

```
grep -E --color=auto 'regex'
```

Poté lze zadávat řetězec. Po  grep vypíše a barevně zvýrazní shody, které v řetězci našel a očekává další vstup. (Konec pomocí  + .)

Pokud chceme použít metaznak, jako obyčejný znak, musíme jej *backquotovat* (tj. napsat před něj zpětné lomítko). Například \. je obyčejný znak tečka.

-s	nevypisuje chyby o nepřístupnosti, argument je adresář atd.
-I	vynechá binární soubory
-c	počty výskytů v souborech
-n	vypíše čísla řádků
-i	nerozlišuje velká a malá písmena
-v	vypisuje řádky nevyhovující regexu
-m k	umožňuje skončit po nalezení k-té shody
-R	rekurzivně se zanořuje do podadresářů
-h, -H	nevypisuje/vypisuje jména souborů u shod
-l, -L	vypisuje pouze jména souborů, které (ne)obsahují shodu
-o	vypisuje na samostatné řádky řetězce, které vedli ke shodě

Další příklady

čísla (s volitelnou desetinnou částí s tečkou)

```
[0-9]*\.[0-9]+
```

povolíme i desetinnou čárku

```
[0-9]*(\.|,)?[0-9]+
```

#formát telefonního čísla v ČR

```
(\+?420)? ?[0-9]{3} ?[0-9]{3} ?[0-9]{3}
```

#identifikátor v C

```
[_[:alpha:]][_[:alnum:]]*
```

ÚKOLY ZE ČTVRTÉ PŘEDNÁŠKY

- 1 Napište příkaz, který vypíše čísla prázdných řádků v souboru.
- 2 Napište příkaz, který na standardní vstup vypíše počet řádků v souboru, které neobsahují číslíci.
- 3 Napište příkaz, který vytiskne řádky textového souboru, které obsahují dvě stejná přirozená čísla oddělená mezerou (a už nic jiného).

Základní programy pro zpracování textu

Zobrazení/spojení/výběr části

```
cat, tac, split, head, tail, cut, paste,
```

Filtry

```
rev, sort, uniq, tr
```

Rozdíly v souborech

```
diff, patch
```

```
cat [options] [files]
```

- vytiskne soubory `files` na standardní výstup, po řádcích od začátků souborů
- jsou-li `files` vynechány, použije standardní vstup
- užitečné přepínače
 - `-n` čísluje řádky
 - `-b` čísluje neprázdné řádky
 - `-s` vynechává opakující se prázdné řádky
- varianta `tac` tiskne řádky od posledního

Typická použití

```
cat file.txt file.txt > concatenated.txt  
cat -s file.txt > no_blanks.txt  
cat file.txt |
```

Program `split` je v jistém smyslu inverzní, dělí jeden soubor na více souborů.

```
head [options] [files]
tail [options] [files]
```

- tiskne začátky/konce souborů (defaultně prvních/posledních 10 řádků)
- bez parametru bere standardní vstup
- přepínače
 - -n num tiskne prvních/posledních num řádků
 - head — num záporné, tiskne vše mimo num posledních řádků
 - tail — je-li před num znak +, vytisne řádky počínající řádkem num

Příklad

```
head -n 1 countries.csv
tail -n +2 countries.csv > headless.csv
```

```
cut [options] [files]
```

- Vytiskne vybrané části z každého řádku v souborech `files`, nejsou-li specifikovány žádné soubory, dělá to pro standardní vstup
- řádek lze chápat i jako řádek tabulky, kde jsou sloupce odděleny oddělovačem
- užitečné přepínače
 - `-d delim` určí oddělovač sloupců, defaultně je `TAB`
 - `-f list` vytiskne pouze sloupce z `list`, který je čárkami oddělený seznam čísel sloupců. Pokud řádek neobsahuje oddělovač, je vytištěn celý: toto lze potlačit přepínačem `-s`.
 - `--output-delimiter=string` nastavení oddělovače sloupců ve výstupu (defaultně je vstupní oddělovač)
 - `-b list`, `-c list` tiskne jenom dané bajty či znaky (které jsou opět dány pořadím).

Příklad

```
cut -f 1,2 -d, --output-delimiter=$'\t' countries.csv
```

Pozn: `$'\t'` shell expanduje na znak tabulátoru, `cut` neumí expandovat `'\t'` sám.

```
paste [options] [files]
```

- spojí jednotlivé řádky (oddělené `TAB`) z jednotlivých souborů z `files` a vytiskne je na standardní výstup (je to *opačný* program k `cut`)
- přepínač `-d list` specifikuje oddělovače, které se postupně použijí místo `TAB`.

Příklad

```
cut -f 1 -d, countries.csv > names.txt  
cut -f 2 -d, countries.csv > regions.txt  
cut -f 3 -d, countries.csv > population.txt  
paste names.txt regions.txt population.txt
```

```
rev [options] [files]
```

Pro každý soubor z `files` vytiskne jeho řádky odzadu, bez specifikace `files` zpracuje standardní vstup.

Příklad

```
rev names.txt  
rev names.txt | rev
```

```
tr string1 [string2]
```

Čte `stdio`, zapisuje `stdout`. Při nejjednodušším použití zamění symboly ze `string1` za symboly na stejných pozicích ve `string2`. (Nebo je smaže). Umí také smrsknout posloupnosti tvořené jedním symbolem na jeho jedno opakování a komplikovanější zadání transformace.

```
sort [options] [files]
```

- Setřídí řádky ze všech souborů z `files` a v tomto pořadí je vytiskne na standardní výstup. Bez `files` zpracovává standardní vstup. Defaultně lexikální porovnávání.
- přepínače
 - `-m` slítí už setříděných souborů
 - `-r` opačné pořadí
 - `-m -H -n -R` typ řazení (měsíce, human-readable velikosti, numerický, náhodný)
 - `-t` znak oddělovač
 - `-k` `keydef` definice klíče, např. sloupce od,do (ale lze komplikovaněji, například pozice znaků od do, atd.)
 - `-u` vynechává řádky obsahující klíče, které už v souboru byly.

Příklad

```
sort -k 3,3 -t, -n -r headless.csv    # setříděno podle třetího sloupce  
sort -k 2,2 -t, -u headles.csv        # unikátní hodnoty v druhém sloupci
```

```
comm [-123i] file1 file2
```

- Čte soubory (předpokládá lexikální uspořádání) a produkuje tři sloupce jako výstup: řádky pouze ve file1, řádky pouze ve file2, řádky v obou souborech.
- Přepínače -1, -2 a -3 potlačují tisk příslušných řádků

Příklad

```
sort countries.csv | head -n -10 > file1.txt
sort countries.csv | tail -n +10 > file2.txt
comm -23 file1.txt file2.txt      # pouze radky unikatni pro file1.txt
comm -13 file1.txt file2.txt     # pouze radky unikatni pro file2.txt
comm -3 file1.txt file2.txt      # ve dvou sloupcich
```

```
uniq [options] [files]
```

- vynechává nebo reportuje opakující se řádky (pouze sousední)
- lze vynechat některé sloupce (chápány jako obsah oddělený bílými znaky)
- není flexibilní, co se týče oddělovačů
- přepínač -u vytiskne jenom unikátní řádky, přepínač -d vytiskne jenom opakující se řádky (každý jenom jednou)

Příklad

```
tail -n +2 regions.txt | sort | uniq
```

```
diff file1 file2
```

- vyhledá rozdíly mezi dvěma soubory (případně soubory uloženými v adresářových hierarchiích) a vypíše je na standardní výstup (tzv. záplata, v souboru typicky koncovka `.diff`). Záplatu lze potom strojově použít pro přepis `file1` na `file2`.
- záplata v několika formátech (přepínače `-u`, `-y`)
- tichý chod přepínačem `-q` (návratovou hodnotou oznámí, jestli jsou soubory shodné)
- pro rekurní použití (= na adresářové struktury) přepínače `-r` `-N`

```
patch file
```

- aplikuje záplatu na soubor `file`, záplata je očekávána na standardním vstupu, nebo ji lze předat ze souboru pomocí přepínače `-i`

Příklady

```
diff numbers.txt numbers.txt  
diff numbers.txt numbers2.txt  
diff -y numbers.txt numbers2.txt  
diff -u numbers.txt numbers2.txt > z.diff  
patch numbers.txt < z.diff  
diff numbers.txt numbers2.txt
```

SLOŽITĚJŠÍ PŘÍKLADY

Vypište 20tý až 11tý řádek souboru s čísly řádků (v tomto pořadí)

```
cat -n names.txt | tail -n +11 | head | sort -r
```

Vypište první a třetí sloupec pro řádky obsahující země z Evropy, seříděný sestupně podle třetího sloupce, s čísly označujícími pořadí.

```
grep 'EUROPE' headless.csv | cut -f 1,3 -d, --output-delimiter=$'\t' |  
sort -n -k 2 -t $'\t' | cat -n
```

(pozn. předchozí je celé jeden příkaz)

ÚKOLY Z PÁTÉ PŘEDNÁŠKY

- 1 Vyextrahujte druhý sloupec ze souboru `data.csv`, kde jsou sloupce odděleny čárkou.
- 2 Zobrazte řádky, které jsou společné pro dva soubory.
- 3 Spočítejte výskyt jednotlivých slov v souboru (ignoruj velikost písmen). *Nápověda: nahrazení nealfabetických znaků znakem nového řádku.*
- 4 Získejte všechny IP adresy ze souboru `access.log` (předpoklad: IP je na začátku řádku, oddělené od zbytku řádku mezerou).
- 5 Vypište 5 nejčastěji se vyskytujících e-mailových domén v souboru, kde je na každém řádku jedna mailová adresa (a už nic jiného).

sed & awk

- Opakovaně provádí
 - načte řádek do bufferu, tzv. *pattern space*, vynechá přitom znaky konce řádku
 - test jestli vykonat a vykonání editovacích příkazů nad bufferem
 - buffer se vypíše (včetně odřádkování), lze potlačit přepínačem -n
 - vymaz bufferu
- ovlivněné řádky i transformace určujeme při spuštění, potom už editace není interaktivní
- <https://www.gnu.org/software/sed/manual/sed.html>

Ukážeme si princip a nejdůležitější editační příkaz.

```
sed [options] script files
```

- script jsou editační příkazy (podrobnosti viz dále)
- files jsou editované soubory, jsou-li vynechány, zpracováváme stdin.

Dále lze script předat

- jeden přímo z promptu
- více přímo z promptu pomocí přepínače -e, pro každý příkaz jeden přepínač
- načtení ze souboru pomocí přepínače -f, každý příkaz na novém řádku nebo příkazy odděleny znakem ; (to může záležet na konkrétním příkazu).

JEDEN PŘÍKAZ

```
[addr] command [options]
```

- `addr` určuje, na které řádky se má příkaz aplikovat, jeli vynecháno, bereme automaticky všechny řádky
- `command` jsou akce, které chceme aplikovat

```
sed -n '4p' names.txt
```

- `-n` potlačí tisk řádků
- `4p`: adresa 4 vybíráme 4. řádek, příkaz `p` řádek pouze vytiskne
- `script` se píše v apostrofech, abychom zabránili shellu v expanzi jmen.

VÝBĚR ŘÁDKŮ

- číslem řádku (poslední řádek \$)

```
sed -n '4p' names.txt
```

- regexem /regex/ (pro extended regex přepínač -E)

```
sed -n '/Republic/p' names.txt
```

- intervalem řádků: dvě adresy oddělené čárkou, interval je od prvního řádku odpovídajícího první adrese do prvního řádku odpovídajícího druhé adrese. Alternativa druhé adresy: počtem řádků za adresou +, do čísla řádku dělitelného číslem ~.

```
sed -n '4,17 p' names.txt  
sed -n '4,/Republic/ p' names.txt  
sed -n '4,+10 p' names.txt  
sed -n '4,~2 p' names.txt
```

- znak ! za adresou je negace (adresa tak označuje řádky, na které příkaz neaplikovat)

```
sed -n '4,17! p' names.txt
```

Základní jednopísmenné funkce

- q vytiskne pattern space a skončí (celý sed)
- p vytiskne pattern space a pokračuje ve vykonávání (i v aktuálním command)
- d vymaže pattern space a pokračuje další iterací (na dalším řádku)
- n vytiskne pattern space, načte do pattern space nový obsah, pokračuje ve vykonávání (aktuálního příkazu).
- y/str1/str2/ - v pattern space nahradí znaky z str1 znaky ze str2 (na stejných pozicích)
- e interpretuje pattern space jako příkaz shellu a spustí jej, nahradí pattern space jeho výstupem

SUBSTITUTE

s/regex/replacement/flags

- nahradí výskyt části odpovídající regex pomocí replacement, po prvním nahrazení končí (lze změnit pomocí flagu)

```
sed 's/Canada/BearLand/' names.txt  
sed -E 's/[A].+ /nothing/' names.txt
```

- flag g: nekončíme po prvním nahrazení
- flag number: nahradíme number-tou shodu
- flag p: vytiskni pattern space, pokud nastala substituce
- flag w filename: po substituci zapiš pattern space do souboru
- flag e: po substituci interpretuj obsah pattern space jako příkaz pro shell, ten spust' a jeho výstup použij jako obsah pattern space

```
sed 's/Canada/echo BearLand/e' names.txt
```

POKROČILÉ SUBSTITUCE

- placeholder & pro obsah nalezeného vzoru, lze jej modifikovat pomocí \U, \u, \L, \l (změna velikosti prvního/všech písmen)

```
sed -E 's/[A-Z]+/(&)/g' names.txt  
sed -E 's/.*/\U &/g' names.txt
```

- zapamatování si částí nalezeného vzoru pomocí (a), napíšeme mezi ně části regexu a poté se odkazujeme pomocí \1 až \9.

```
sed -E 's/([A-Z][a-z]*) ([A-Z][a-z]*)/\2 \1/g' names.txt
```

AWK

Jazyk pro zpracování a analýzu textových dat. Ta lze chápat i jako tabulková data (např. csv soubory apod.)

Jméno je zkratkou jmen autorů: A. Aho, P. Weinberger, B. Kernighan.

Jazyk je dán specifikací (POSIX standard), existuje několik implementací, i komerčních. Některé implementace (např. gawk) přidaly svoje rozšíření.

O jazyku existuje několik knih, například

- Herold H., awk & sed: Příručka pro dávkové zpracování textu. Computer Press, 2004. ISBN 9788025103098.
- D. Dougherty, A. Robbins, sed & awk. O'Reilly Media, 1990.

Dále je dokumentace například `man awk`, případně

<https://www.gnu.org/software/gawk/manual/gawk.html>

Interpret načítá záznamy (angl. *records*, v základu řádky), ty může rozdělit na políčka (angl. *fields*).

Pro každý záznam aplikuje postupně pravidla. Pravidlo se sestává z

- kontroly, jestli záznam vyhovuje,
- programu, který se provede, pokud záznam při kontrole vyhověl.

Akce lze provést i před spuštěním aplikace pravidel na záznamy, a po zpracování všech záznamů.

```
pattern { action }
```

- pattern vynecháno -> bereme vždy shodu
- action vynecháno -> tiskneme celý záznam

Spuštění

```
awk [code] [files]
```

```
awk -f script_file [files]
```

ÚVODNÍ PŘÍKLADY

```
awk '{ print }'
```

```
awk 'length($0) > 30'
```

```
awk '{ if (length($0) > max) max = length($0) }  
     END { print max }'
```

```
awk 'NF > 0' data/data.txt
```

```
awk 'BEGIN { for (i = 1; i <= 7; i++) print int(101 * rand()) }'
```

```
awk '{ x += $2 }  
     END { print "total " x }'
```

```
awk -F: '{ print $1 }' /etc/passwd | sort
```

```
awk 'END { print NR }' data/data.txt
```

ZÁZNAMY A POLÍČKA

awk nejdříve načte záznam. To dělá tak, že čte znaky ze vstupu, dokud nenarazí na znak konce záznamu. To je defaultně znak nového řádku, lze to ovšem změnit (argumentem utility awk nebo v samotném programu pomocí proměnné RS).

Potom awk rozdělí záznam na políčka, opět pomocí oddělovačů. V základu je oddělovačem libovolná posloupnost bílých znaků. Opět to lze nastavit (i komplikovaně, např. pomocí regexů) z příkazového řádku, nebo s pomocí proměnné FS.

Ve skriptu máme k načtenému záznamu a políčkům přístup a to

- pomocí \$1, \$2, ... k jednotlivým políčkům
- pomocí \$0 k celému záznamu
- pomocí proměnné NR k počtu zpracovaných záznamů (včetně aktuálního) (FNR v rámci aktuálního souboru)
- pomocí proměnné NF k počtu políček aktuálního záznamu

Předpokládejme, že máme v souboru `data.txt` údaje ve formátu

```
Franta Votloukal; Kruta 14; Olomouc; 734092004; Votloukal a syn, a.s.
```

a chceme je převést do hezčí formy. K tomu použijeme skript

```
BEGIN {FS=";"}
{
    print $1
    print $5
    print $2 ", " $3
    print "tel: " $4
}
```

Skript použijeme

```
awk -f adres.awk data/data.txt
```

SHODA SE VZOREM

Pomocí podmínek a pomocí regulárních výrazů.

Shoda hledána v celém záznamu

```
/regex/ { akce }
```

Jinak lze použít výraz `expr ~ /regex/`, který hledá shodu `regex` v `expr`, například

```
$3 ~ /regex/ { akce }
```

hledá shodu v třetím políčku

Pokud bychom v předchozím příkladu dali na začátek druhého řádku

```
$1 ~ /^F.*/
```

vypsali bychom pouze lidi, jejichž křestní začínají na F.

PROMĚNNÉ A ARITMETIKA

Identifikátory: alfanumerické znaky a podtržítko, první znak nesmí být číslo

Hodnota proměnné je číslo a řetězec, používá se podle kontextu (řetězcové hodnoty, které netvoří číslo, mají číselnou hodnotu 0).

Proměnné není nutné deklarovat ani inicializovat, automaticky jsou inicializovány na 0 a prázdný řetězec.

Operátor přiřazení a aritmetické operátory se chovají přirozeně.

+, -, *, /	základní aritmetika
%	zbytek po celočíselném dělení
^	mocnina
=	přiřazení
op=	zkratka přiřazení a operátoru op

PŘÍKLADY

1. Počet prázdných řádků v souboru

```
/^$/ {  
    x += 1  
}  
END { print x }
```

2. Pro data typu

```
jarda  10 78 56 34 89
```

vypočtu a vytisknu průměrný zisk bodů

```
{  
    total = $2 + $3 + $4 + $5 + $6  
    avg   = total / 5  
    print $1 " " avg  
}
```

RELAČNÍ VÝRAZY A BOOLEOVSKÉ OPERÁTORY

Výraz, který se vyhodnotí na pravdu/nepravdu pomocí vyhodnocení toho, jestli operandy splňují požadovanou relaci.

<, >, <=, >=	menší/větší (nebo rovno)
==	rovnost
!=	nerovnost
~	shoda s regexem
!~	neshoda s regexem

Kombinace výrazů do složitějších podmínek

&&	konjunkce
	disjunkce
!	negace

Lze použít místo kontroly shody se vzorem.

Tisk prvního a šestého políčka u záznamů s přesně 6 políčky. Ostatní jsou vynechány.

```
NF == 6 { print $1 ", " $6 }
```

Navíc chceme, aby se třetí políčko shodovalo s regexem

```
NF == 6 && $3 ~ /MA/ { print $1 ", " $6 }
```

U booleovských operátorů je potřeba dávat pozor na prioritu, pro určení priority doporučuji závorky.

Větvení

```
if (podmínka) {  
    #pravda  
}  
else {  
    #nepravda  
}
```

else část nepovinná.

Příklad: k výpočtu průměrného počtu bodů přidáme sloupec s informací, jestli student prospěl.

```
BEGIN { limit = 50 }  
{  
    total = $2 + $3 + $4 + $5 + $6  
    avg   = total / 5  
    if (avg > limit) {  
        grade = "pass"  
    }  
    else {  
        grade = "fail"  
    }  
    print $1 "\t" avg "\t" grade  
}
```

Cyklus

```
while (podminka) {  
    # telo cyklu  
}
```

Příklad: výpis čísel od 1 do 10

```
BEGIN {  
    i = 1  
    while(i < 11) {  
        print i  
        i += 1  
    }  
}
```

Úprava výpočtu průměru pro proměnlivý počet písemek

```
BEGIN { limit = 50 }  
{  
    total = 0  
    i = 2  
    while(i <= NF) {  
        total += $i  
        i += 1  
    }  
  
    avg = total / ( NF - 1)  
    if (avg > limit) {  
        grade = "pass"  
    }  
    else {  
        grade = "fail"  
    }  
    print $1 "\t" avg "\t" grade  
}
```

ASOCIATIVNÍ POLE

Ukládá vztah klíč a hodnoty (jako dict v jazyce Python)

Přístup k poli

```
array[key] = value  
array[key]
```

Procházení

```
for (key in array) {  
    # tady máme přístup pomocí array[key]  
}
```

Test existence klíče

```
key in array
```

Úprava výpočtu průměru

```
BEGIN { limit = 50 }
{
    total = 0
    i = 2
    while(i <= NF) {
        total += $i
        i += 1
    }
    avg    = total / (NF - 1)

    # vlozime prumer do pole s klicem, který rovna jménu
    array[$1] = avg
}
END {
    # projdem výsledky a vypíšeme tabulku
    for (name in array) {
        print name "\t" array[name]
    }
}
```

```
BEGIN {  
    n    = 6  
    max  = 49  
    srand()  
    j = 0  
    while (j < 6) {  
        select = 1 + int(rand() * max)  
        while (select in pick) {  
            select = 1 + int(rand() * max)  
        }  
        pick[select] = select  
        j += 1  
    }  
  
    for (x in pick) {  
        print x  
    }  
}
```

FUNKCE

Řada zabudovaných funkcí + možnost definovat uživatelské funkce

Některé funkce už jsme viděli např. `srand()`, `rand()`, `length()`, `int()`.

Vybrané zajímavé funkce (na řetězcích)

<code>gsub(r,s,t)</code>	v řetězci <code>t</code> nahradí každou shodu s regexem <code>r</code> řetězcem <code>s</code> . Je-li <code>t</code> vynecháno, bereme <code>\$0</code> .
<code>match(s,r)</code>	vrátí pozici v <code>s</code> , kde nastala shoda s regexem <code>r</code> nebo 0, pokud k žádné shodě nedojde. Nastaví globální proměnné <code>RSTART</code> <code>RLENGTH</code>
<code>split(s,a,sep)</code>	rozdělí řetězec <code>s</code> na části podle separátoru <code>sep</code> a vloží je do pole <code>a</code> . Vrací počet vzniklých řetězců. Defaultní hodnota <code>sep</code> je <code>FS</code> .

UŽIVATELSKY DEFINOVANÉ FUNKCE

```
function name (parameter-list) {  
    body  
}
```

Hodnota se vrací pomocí

```
return value
```

Jediné lokální proměnné jsou parametry funkce, proměnné vytvořené v těle funkce jsou globální! Proto se lokální proměnné přidávají do seznamu parametrů, při volání funkce lze některé parametry vynechat.

PŘÍKLAD: BUBBLE SORT

```
function bubble_sort(array, elements,      temp, i, j) {  
  i = 0  
  while (i < elements) {  
    j = 0  
    while (j < elements - i - 1) {  
      if (array[j] > array[j+1]) {  
        tmp      = array[j]  
        array[j]  = array[j+1]  
        array[j+1] = tmp  
      }  
      j += 1  
    }  
    i += 1  
  }  
}
```

```

function print_array(array, element, i) {
    i = 0
    while(i < els) {
        printf("%i ", ar[i])
        i += 1
    }
    print " "
}

```

```

BEGIN {
    els = 10
    k = 0
    while(k < els) {
        ar[k] = els - k
        k += 1
    }

    print_array(ar,els)
    bubble_sort(ar,els)
    print_array(ar,els)
}

```

ÚKOLY Z ŠESTÉ PŘEDNÁŠKY

- 1 Změňte všechna slova "foo" na "bar".
- 2 Nahraďte druhý výskyt slova "error" v každém řádku za "warning".
- 3 Odstraňte znak ; na konci řádku (pokud tam je).
- 4 Uvažte soubor s následujícím obsahem

Alice	95	1200
Bob	78	800
Charlie	105	1500
David	67	950
Eve	88	1100
ERROR	0	0
Frank	101	2000
Grace	75	600

- 1 Vypište průměr hodnot třetího sloupce, u řádků kde je hodnota v druhém sloupci větší než 80.
- 2 Odstraňte řádky, kde je první sloupec ERROR.
- 3 Přidejte sloupec s rozdílem mezi třetím a druhým řádkem.