UNIX
Programování a správa systému II

Jan Kasprzak
<kas@fi.muni.cz>
https://www.fi.muni.cz/~kas/

Motto: UNIX je user-friendly,
ale své přátele si vybírá.

Kapitola 1

Úvod

Předpoklady

- C a POSIX.1 – na úrovni PV065
- UNIX z uživatelského hlediska – shell, základní příkazy
- Síť TCP/IP z uživatelského hlediska

Cíle kursu

- Správa systému (subsystémy, adresářový strom, ...)
- Architektura TCP/IP
- Programování síťových aplikací
- Konfigurace síťových protokolů a služeb

Ukončení předmětu

- Průběžné odpovědníky
  - 4 otázky, +2 body/–1 bod 4 body = splněno
  - 12 dní na splnění nebo neschopenka na 7 dní
  - nejvýše tři nesplněné
- Závěrečný test výběr právě jedné správné možnosti
- Bodové hranice
  - výborné průběžné testy: zápočet,
  - špatné průběžné a výborný závěrečný: stačí na E.
- Zkontrolujte si zapsané ukončení

Upozornění:

Naučit se zpaměti slidy nestačí!

Ukončení předmětu

- Průběžné odpovědníky
  - 4 otázky, +2 body/–1 bod 4 body = splněno
  - 12 dní na splnění nebo neschopenka na 7 dní
  - nejvýše tři nesplněné
- Závěrečný test výběr právě jedné správné možnosti
- Bodové hranice
  - výborné průběžné testy: zápočet,
  - špatné průběžné a výborný závěrečný: stačí na E.
- Zkontrolujte si zapsané ukončení

⚠ Upozornění:

Naučit se zpaměti slidy nestačí!

Obsah: Správa systému

- Instalace, zálohování, disky
- Systém souborů a adresářů – rozložení v systému
- Start systému – `init`, inicializační skripty
- Uživatelé a skupiny – data, PAM, nsswitch, programování
- X Window System – architektura, programování a správa
- Linux a desktop – když nechceme statický `/dev` 
- Lokální subsystémy – `syslog`, `cron`, tiskárny, diskové kvóty
- Virtualizace – virtuální stroje, kontejnery

Obsah: Sítě TCP/IP

- Architektura sítě TCP/IP – vrstvy sítě, formáty packetů
- Programování síťových aplikací – rozhraní BSD sockets

Obsah: Síťové aplikace

- Konfigurace sítě – ARP, přidělení adres, směrování
- DNS – architektura, typy záznamů, konfigurace
- RPC služby – RPC a XDR, portmapper, NFS, NIS/YP
- Uživatelské informace po síti – LDAP, Kerberos
- Elektronická pošta – formát zpráv, SMTP, POP-3, IMAP
- Firewally – packetové filtry, aplikační brány, netfilter 

Typografické konvence

- Specifická vlastnost pro Linux: 
- ... pro BSD  , Solaris 
- ... pro IRIX  , Red Hat/Fedoru 
- ... pro GNU nástroje: 

Úkol:

Doma se zkuste zamyslet a vyřešit.

Příklad: Tohle rozhodně nezkoušejte ^_~

```
root@eva01# rm -rf /
```

Další zdroje informací

- Tato prezentace: https://www.fi.muni.cz/~kas/pv077/
- PV090 UNIX – Seminář ze správy systému
- Linux Weekly – https://lwn.net/
- Experimentujte! – fakultní linuxové počítače, vlastní stroj s Linuxem, https://stratus.fi.muni.cz/, ...

Další zdroje informací

- Tato prezentace: `https://www.fi.muni.cz/~kas/pv077/`
- PV090 UNIX – Seminář ze správy systému
- Linux Weekly – `https://lwn.net/`
- Experimentujte! – fakultní linuxové počítače, vlastní stroj s Linuxem, `https://stratus.fi.muni.cz/`, ...

Další zdroje informací

- Tato prezentace: `https://www.fi.muni.cz/~kas/pv077/`
- PV090 UNIX – Seminář ze správy systému
- Linux Weekly – `https://lwn.net/`
- Experimentujte! – fakultní linuxové počítače, vlastní stroj s Linuxem, `https://stratus.fi.muni.cz/`, ...

Další zdroje informací

- Tato prezentace: `https://www.fi.muni.cz/~kas/pv077/`
- PV090 UNIX – Seminář ze správy systému
- Linux Weekly – `https://lwn.net/`
- Experimentujte! – fakultní linuxové počítače, vlastní stroj s Linuxem, `https://stratus.fi.muni.cz/`, ...

Kapitola 2

Administrace systému

Instalace systému – I.

Není standardizováno, jen obecná fakta:

- Start jádra z instalačního média
- Kořenový svazek: ramdisk, instalační médium, miniroot  , NFS
- Rozdělení disků na oblasti – `fdisk(8)`, `parted(8)`  , `gdisk(8)`, `divvy(8)`, `disklabel(8)` 
- Vytvoření souborových systémů – `mkfs(8)`, `newfs(8)` 
- Inicializace odkládacího prostoru – `mkswap(8)` 

Otázka:

Co vlastně `mkswap(8)` na disk zapisuje?

Instalace systému – I.

Není standardizováno, jen obecná fakta:

- Start jádra z instalačního média
- Kořenový svazek: ramdisk, instalační médium, miniroot  , NFS
- Rozdělení disků na oblasti – `fdisk(8)`, `parted(8)`  , `gdisk(8)`, `divvy(8)`, `disklabel(8)` 
- Vytvoření souborových systémů – `mkfs(8)`, `newfs(8)` 
- Inicializace odkládacího prostoru – `mkswap(8)` 

Otázka:

Co vlastně `mkswap(8)` na disk zapisuje?

Instalace systému – II.

- Počáteční konfigurace hardware – vytvoření jádra pro nový systém (nebo *initial ramdisk* )
- Instalace jednotlivých částí systému
- Post-instalační konfigurace systému – doménové jméno, konfigurace sítě, časové zóny, systémového hesla a podobně
- Restart nainstalovaného systému
- Post-instalační konfigurace – další nastavení na živém systému (`firstboot` )

Rotační magnetické disky

- Geometrie: sektory, stopy, povrchy
- Latence:
  - rotační
  - změna pozice hlavy
- Zónový zápis
  - vnější stopy jsou rychlejší!
- Sekvenční vs. náhodný přístup
  - stovky MB/s
  - stovky IOPS
- Mechanická životnost
  - ložiska, uložení hlavy

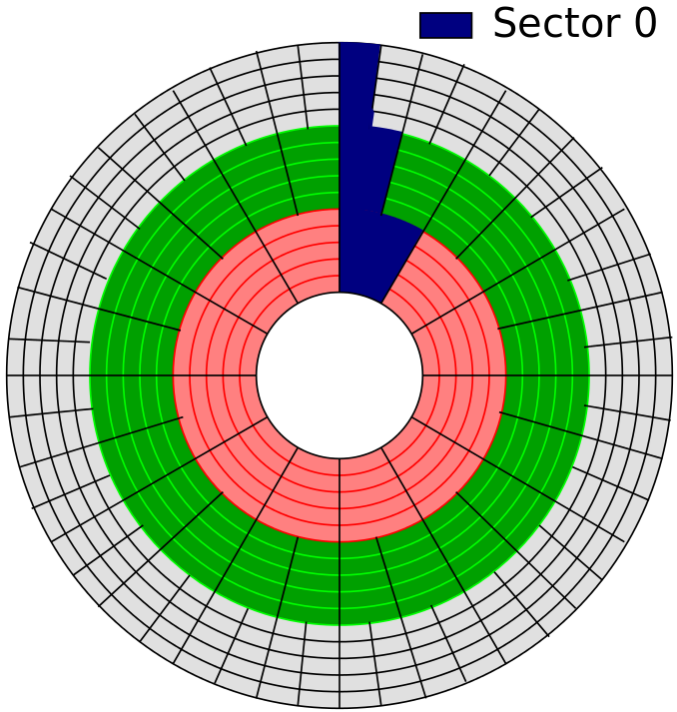

Rotační magnetické disky

- Geometrie: sektory, stopy, povrchy
- Latence:
  - rotační
  - změna pozice hlavy
- Zónový zápis
  - vnější stopy jsou rychlejší!
- Sekvenční vs. náhodný přístup
  - stovky MB/s
  - stovky IOPS
- Mechanická životnost
  - ložiska, uložení hlavy

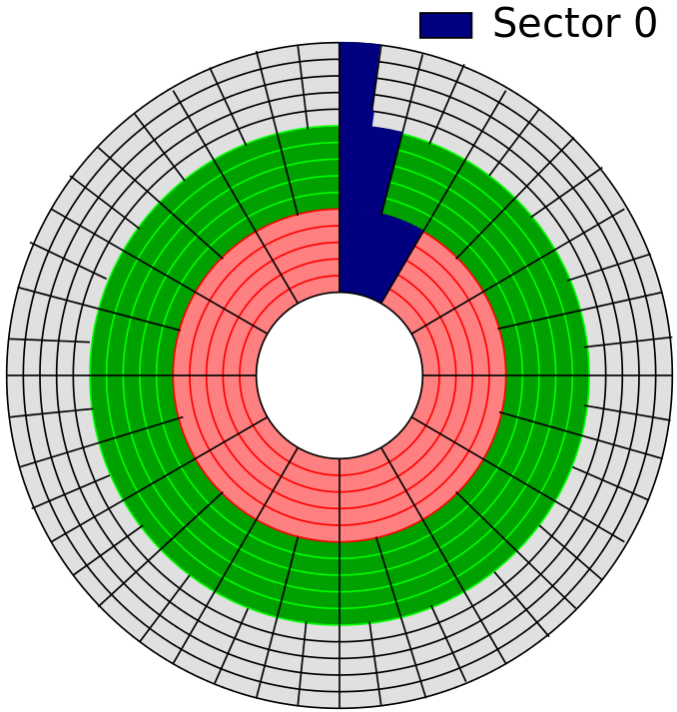

Rotační magnetické disky

- Geometrie: sektory, stopy, povrchy
- Latence:
  - rotační
  - změna pozice hlavy
- Zónový zápis
  - vnější stopy jsou rychlejší!
- Sekvenční vs. náhodný přístup
  - stovky MB/s
  - stovky IOPS
- Mechanická životnost
  - ložiska, uložení hlavy

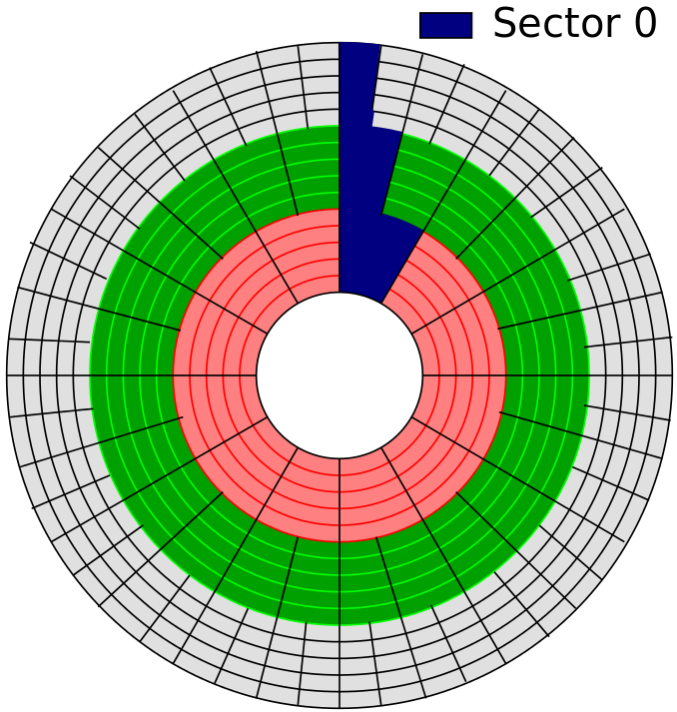

Rotační magnetické disky

- Geometrie: sektory, stopy, povrchy
- Latence:
  - rotační
  - změna pozice hlavy
- Zónový zápis
  - vnější stopy jsou rychlejší!
- Sekvenční vs. náhodný přístup
  - stovky MB/s
  - stovky IOPS
- Mechanická životnost
  - ložiska, uložení hlavy

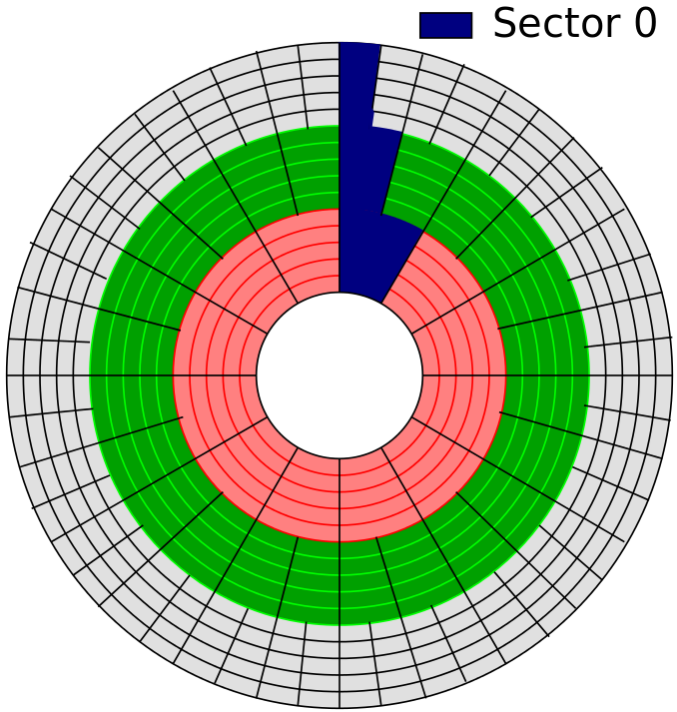

Rotační magnetické disky

- Geometrie: sektory, stopy, povrchy
- Latence:
  - rotační
  - změna pozice hlavy
- Zónový zápis
  - vnější stopy jsou rychlejší!
- Sekvenční vs. náhodný přístup
  - stovky MB/s
  - stovky IOPS
- Mechanická životnost
  - ložiska, uložení hlavy

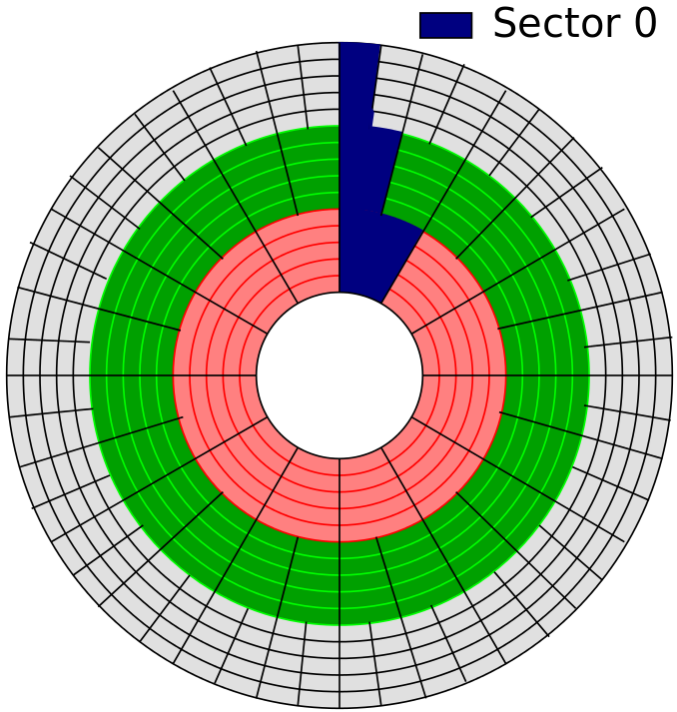

Solid-state disky

- Flash paměti (NOR, NAND)
- Větší bloky než u disků (i 64 KB); erase-blocks
- Operace: čtení, mazání, zápis
- Omezená životnost: počet zápisových operací
  - SW nebo HW vyrovnávání opotřebení
  - dodatečné bity v erase-blocku
  - někdy dost primitivní
- Rychlý náhodný i sekvenční přístup
- Nelze zápis části erase-blocku
- Speciální souborové systémy
- Podpora trim?

Další typy úložišť

- NVMe disky (XIP?)
- Non-volatile RAM (memristory, ...)
- SMR disky

Další typy úložišť

- NVMe disky (XIP?)
- Non-volatile RAM (memristory, ...)
- SMR disky

Další typy úložišť

- NVMe disky (XIP?)
- Non-volatile RAM (memristory, ...)
- SMR disky

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Diskové oddíly (partition)

- Disk – blokové zařízení
- Využití disků – souborový systém, swapovací oblast, databáze, ...
- Disková oblast – souvislá část disku. Blokové zařízení.
- BIOS/DOS MBR – 4 oblasti, 2 TB, extended oblast, 8 bitů identifikátor
- BSD disklabel – rozdělení jedné MBR oblasti
- GPT – 128 oblastí, 64-bitové ID bloku, UUID identifikátor

Správa logických svazků

- Logical Volume Manager (lvm)
- Spojení více fyzických zařízení do jednoho

Struktura LVM

- Physical volume (pv) – disk, disková oblast. Skládá se z
- Physical extent (pe) – část diskové oblasti, pevná délka (např. 4 MB).
- Volume group (vg) – obsahuje několik PV, jejichž PE jsou v ní zpřístupněny jako
- Logical extent (le) – odpovídá příslušnému PE.
- Logical volume (lv) – odpovídá blokovému zařízení. Skládá se z několika LE v rámci jedné VG. Na LV se vytvoří souborový systém a používá se.

Další služby LVM

- Změna velikosti VG – přidání/odebrání několika PV.
- Změna velikosti LV – přidání/odebrání několika LE. Musí navazovat změna velikosti souborového systému.
- Odebrání PV – transparentní.
- Klon LV – atomický snímek, nezabírá mnoho místa, copy-on-write.
- Thin provisioning – alokace až při zápisu. Trim?

Device mapper

- Vrstva v jádře – přemapování blokových zařízení
- LVM – user-space detekce VG, konfigurace jaderného DM
- dm-crypt – šifrování disku (userspace: LUKS)
- dm-verity – ochrana proti *evil maid attack*
- dm-flakey, dm-dust, dm-delay
- dm-raid

RAID-0

Disk1	Disk2	Disk3
1	2	3
4	5	6
...	...	...

- Prokládání disků
- Dva nebo více disků
- Stejně velké disky
- Není redundantní!

RAID-1

Disk1	Disk2	Disk3
1	1	1
2	2	2
...	...	...

- Zrcadlení disků.
- Dva nebo více disků
  - Trik: mít všechny disky bootovatelné
- Větší propustnost čtení.

Otázka:

Jaká je náročnost zápisu na RAID-1?

RAID-1

Disk1	Disk2	Disk3
1	1	1
2	2	2
...	...	...

- Zrcadlení disků.
- Dva nebo více disků
  - Trik: mít všechny disky bootovatelné
- Větší propustnost čtení.

Otázka:

Jaká je náročnost zápisu na RAID-1?

RAID-5

Disk1	Disk2	Disk3
1	2	P12
3	P34	4
P56	5	6
...	...	...

- Paritní bloky
  - RAID-4 – paritní disk
- Tři nebo více disků
- Větší náročnost zápisu

Otázka:

Jaký má vliv velikost bloku RAID-5 na jeho výkonnost?

RAID-5

Disk1	Disk2	Disk3
1	2	P12
3	P34	4
P56	5	6
...	...	...

- Paritní bloky
  - RAID-4 – paritní disk
- Tři nebo více disků
- Větší náročnost zápisu

Otázka:

Jaký má vliv velikost bloku RAID-5 na jeho výkonnost?

RAID-6

Disk1	Disk2	Disk3	Disk4
1	2	P12	Q12
3	P34	Q34	4
P56	Q56	5	6
Q78	7	8	P78
...	...	...	...

- Dva paritní bloky
  - Různé funkce P a Q
- Čtyři nebo více disků
- Redundance i při rekonstrukci

Otázka:

Porovnejte výkon degradovaného RAID-5 a RAID-6

RAID-6

Disk1	Disk2	Disk3	Disk4
1	2	P12	Q12
3	P34	Q34	4
P56	Q56	5	6
Q78	7	8	P78
...	...	...	...

- Dva paritní bloky
  - Různé funkce P a Q
- Čtyři nebo více disků
- Redundance i při rekonstrukci

Otázka:

Porovnejte výkon degradovaného RAID-5 a RAID-6

RAID-10

Disk1	Disk2	Disk3	Disk4
1	1	2	2
3	3	4	4
5	5	6	6
...	...	...	...

- RAID-0 nad RAID-1 částmi

Otázka:

Lze mít RAID-10 nad lichým počtem disků?

RAID-10

Disk1	Disk2	Disk3	Disk4
1	1	2	2
3	3	4	4
5	5	6	6
...	...	...	...

- RAID-0 nad RAID-1 částmi

Otázka:

Lze mít RAID-10 nad lichým počtem disků?

RAID-10 near/far

- Alternativní rozložení RAID-10

Disk1	Disk2	Disk3	Disk4
1	1	2	2
3	3	4	4
5	5	6	6
...	...	...	...

Disk1	Disk2	Disk3	Disk4
1	2	3	4
5	6	7	8
...	...	...	...
3	4	1	2
7	8	5	6
...	...	...	...

SW RAID nebo HW RAID?

- RAID write hole
  - Write-intent-bitmap 
- Cache, scheduling
  - Bufferbloat?
- Disaster recovery
  - Chyby ve firmwaru?

Doporučení:

V Linuxu Použijte SW RAID (md).

SW RAID nebo HW RAID?

- RAID write hole
  - Write-intent-bitmap 
- Cache, scheduling
  - Bufferbloat?
- Disaster recovery
  - Chyby ve firmwaru?

Doporučení:

V Linuxu Použijte SW RAID (md).

SW RAID nebo HW RAID?

- RAID write hole
  - Write-intent-bitmap 
- Cache, scheduling
  - Bufferbloat?
- Disaster recovery
  - Chyby ve firmwaru?

Doporučení:

V Linuxu Použijte SW RAID (md).

SW RAID nebo HW RAID?

- RAID write hole
  - Write-intent-bitmap 
- Cache, scheduling
  - Bufferbloat?
- Disaster recovery
  - Chyby ve firmwaru?

Doporučení:

V Linuxu Použijte SW RAID (md). 

Vlastnosti souborových systémů

Systém souborů musí zajišťovat:

- Efektivní práce s metadaty – adresářové operace (vyhledání souboru, přejmenování, mnoho souborů v adresáři, atd.).
- Efektivní operace s daty – čtení/zápis (malá fragmentace etc.)
- Spolehlivé zotavení po havárii.
- Co nejmenší prostor na režii – velikost metadat.

Svazky

- Svazek: systém souborů, volume.
- Uložen na blokovém zařízení (disková oblast).
  - Ale: síťové svazky nemají blokové zařízení
- Připojení svazku – na existující adresář.
  - ztotožnění s kořenem připojovaného svazku
  - mountpoint

Struktura souborového systému

- Boot block je první blok svazku. Zavádí se z něj operační systém, nebo je prázdný.
- Super block – další blok svazku. Obsahuje sumární informace o svazku.
- Tabulka i-uzlů – informace o souborech.
- Datové bloky

Zotavení po havárii

- Možné nekonzistence:
  - pořadí zápisových operací
  - write-back cache
  - změny dat/metadat
  - chyby HW nebo OS
- Kontrola konzistence `fsck(8)`. Časově náročné.
- Synchronní zápis metadat? – problémy se starými daty v souborech (bezpečnost!).

BSD Soft updates

- Závislosti mezi diskovými operacemi.
- Omezení počtu typů nekonzistencí (rychlejší `fsck(8)`).
- Ale: problém pořadí data versus metadata.
- Neřeší se chyba OS nebo HW.
- Komplikovaná implementace.

Žurnálované souborové systémy

- Transakční přístup.
- Změny nejprve zapsány do logu (žurnálu) a pak provedeny.
- Po havárii – přehrání celých transakcí.
- Některé operace – i rychlejší než nežurnálovaný FS.
- Celkově o něco pomalejší.
- Žurnál jen metadat nebo i dat.
- Chyba OS nebo HW se řeší pomocí `fsck(8)`.
- Jen transakce z jádra (ne user-space).

FAT

- Nemá i-uzly (nelze mít soubor ve více adresářích, nemá UNIXová přístupová práva).
- Pomalý přímý přístup k souboru (sekvenční procházení přes FAT).
- Fragmentace už při současném zápisu do dvou souborů.
- Fragmentace při rušení souboru.
- Na větších FS velká délka bloku $\longrightarrow$ špatné využití místa.
- Výhody – na menších FS malá režie, jednoduchá implementace.

UFS

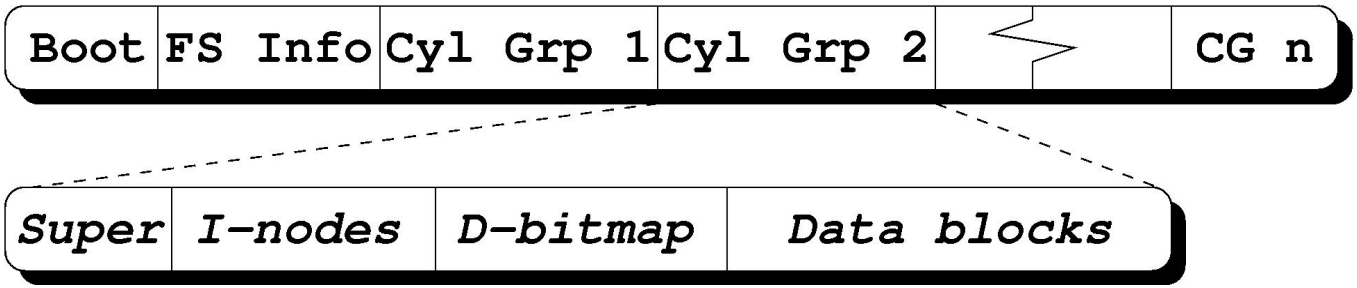

- FFS, EFS, UFS – původně v 4.x BSD.
- Cylinder groups. Nutná znalost geometrie disku.
- Snížení fragmentace, 4–8 KB bloky.
- Fragmenty – lepší využití místa na disku.
- Kopie superbloku.
- Rezervované místo pro superuživatele
- Původně: synchronní zápis metadat.
- FreeBSD: soft updates.
- Kontrola disku na pozadí.
- *BSD, Solaris (+ žurnálování), Linux.

Ext2 filesystem

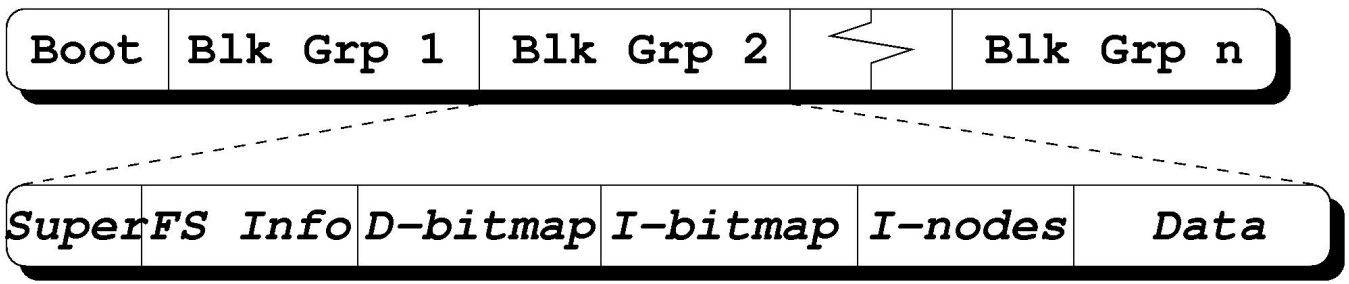

- Skupiny bloků (block groups). Není nutná znalost geometrie disku. Jednodušší implementace, využití celých bloků.
- Alokační strategie: Předalokované bloky, alokace dat poblíž příslušných metadat, zamezení zaplnění jedné skupiny bloků.
- Obvykle 1 KB (až 4 KB) bloky – rychlejší než FFS s 4 KB bloky.
- Bitmapa volných i-uzlů.

Ext2FS – pokračování

- Asynchronní zápis metadat; na požádání umí i synchronní.
- Velikost až do 4 TB dat.
- Rychlé symbolické linky.
- No-atime, relatime.
- Maximum mount count. `tune2fs(8)`.
- Možnosti při chybě – panic, remount r-only, ignore.
- `libe2fs` – knihovna pro přístup k e2fs. `e2defrag`.

Ext3 filesystem

- Struktury na disku – zpětně kompatibilní s ext2.
- Žurnálování – změny zapisovány přes transakční log.
- Žurnálování dat – `journal`, `ordered`, `writeback`.
  - `O_PONIES`
- Rozšířené atributy – další metadata (např. security context).
- Access control lists
- Adresáře – lineární struktura nebo strom (HTree; bezpečnost!)

Ext4 filesystem

- Limit velikosti 1 EiB
- Extent-based adresace
- Předalokace místa – `fallocate(2)`
- Časová razítka – rozlišení 1 ns, `statx(2)`
- Allocate on flush (viz XFS)
- Kvóty na projekty (32-bitové ID)
- Zápisové bariéry (`barrier=0`, viz `O_PONIES`)

ReiserFS

- Všechna data v jednom B+ stromu.
- Alokace místa – i menší kousky než jeden sektor.
- I-uzly – alokace podle potřeby.
- Efektivní i při velkém množství souborů v adresáři nebo velkém množství malých souborů.

Reiser4

- Plug-iny souborového systému (např. vyhledávání/indexace).
- Soubory s více proudy dat (např. metadata) – každý soubor je také adresář.
- Transakce – více datových operací může být spojeno do jedné atomické transakce.

SGI XFS

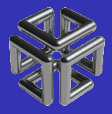

- Rozdělení svazku – allocation groups velikosti 0.5 až 4 GB.
- Organizace dat – B+ strom
- DMAPI – data manipulation API – zpřístupnění vlastností B-stromu (vkládání/rušení dat uprostřed souboru).
- Real-time extenze – možnost alokace šířky pásma; garantovaná propustnost.
- O_DIRECT – přístup bez cachování.
- Allocate on flush – další snížení fragmentace.
- XFS on RAID – podpora paralelizace.

Sun ZFS

- Zettabyte File System
- Interně podobný jako Slab alokátor v paměti.
- RAID-Z – jednotlivé slaby s různou úrovní redundance.
- Kontrolní součty dat
- Self-healing (automatické opravy chyb).
- Copy-on-write: sjednocení duplicitních bloků

BTRFS

- Copy-on-write B-stromy
  - top-down B-tree
  - závislosti operací jen v jedné datové struktuře (na rozdíl od soft-updates)
  - evidence volného místa
- Zapisovatelné snímky FS.
- Subvolumes
- Kontrolní součty metadat (volitelně i dat).
- Interní RAID
- In-place konverze z ext4
- Deduplikace

Další služby FS

- Komprese dat – celý FS nebo jen určité soubory.
- Obnova smazaných souborů.
- Nepřemistitelné soubory – ext[234]fs.
- Soubory, umožňující pouze přidávat data – append-only.
- Změna velikosti svazku za běhu – AIX jfs, Tru64 advfs, ext[34]fs, BTRFS, ...
- Transparentní šifrování
- Steganografie – StegFS  , Rubberhose 

Virtual file system

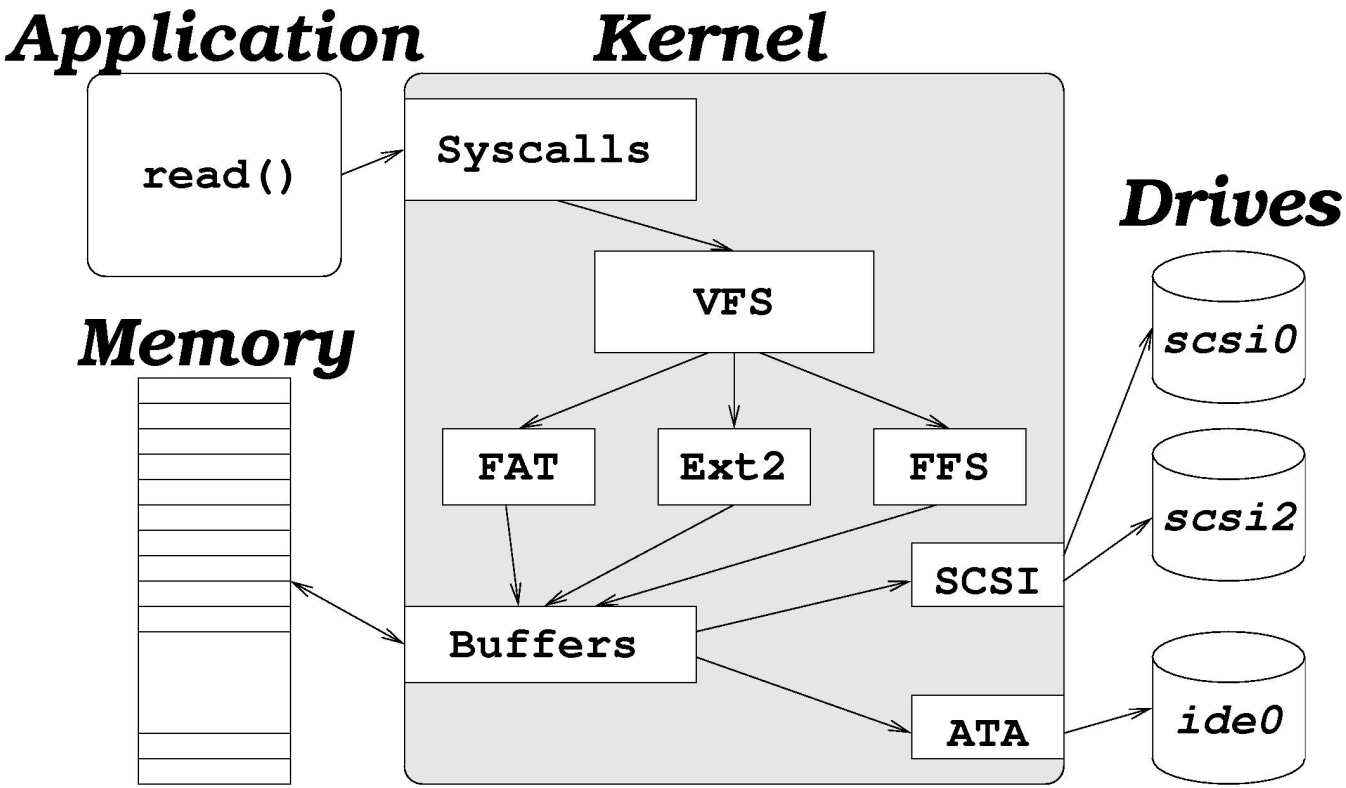

Zálohování

Proč zálohovat?

- Ochrana dat před nechtěným smazáním
- Ochrana dat před výpadkem hardwaru
- Sledování změn v datech
- Obnovení dat po bezpečnostním incidentu

Problémy zálohování

- Nízká rychlost zálohovacích médií – nejde o snímek systému
- Malá kapacita médií – nelze každý den zálohovat všechno
- Nespolehlivost médií – je nutno mít několik sad záloh

Víceúrovňové zálohování

- Řeší problém rychlosti a velikosti zálohovacího média
- Záloha úrovně 0 – kompletní svazek nebo adresář
- Záloha úrovně *n+1* – soubory a adresáře, modifikované od *začátku* zálohy úrovně *n*
- Rozpoznat i smazané soubory
- Čas vytvoření zálohy musí být uložen na zálohovacím médiu, nikoli na disku

Víceúrovňové zálohování

- Řeší problém rychlosti a velikosti zálohovacího média
- Záloha úrovně 0 – kompletní svazek nebo adresář
- Záloha úrovně *n+1* – soubory a adresáře, modifikované od *začátku* zálohy úrovně *n*
- Rozpoznat i smazané soubory
- Čas vytvoření zálohy musí být uložen na zálohovacím médiu, nikoli na disku

Víceúrovňové zálohování

- Řeší problém rychlosti a velikosti zálohovacího média
- Záloha úrovně 0 – kompletní svazek nebo adresář
- Záloha úrovně *n+1* – soubory a adresáře, modifikované od *začátku* zálohy úrovně *n*
- Rozpoznat i smazané soubory
- Čas vytvoření zálohy musí být uložen na zálohovacím médiu, nikoli na disku

Formát záloh

- Vlastnický formát – nevýhoda – nelze zálohu rozbalit kdekoli
- `tar(1)` – neumožňuje zabalit jen některé soubory (GNU `tar` ano )
- `cpio(1)` – pozor na zabalení s absolutní cestou
- `dump(8)` – formát příslušný určitému typu souborového systému. Odpovídající `restore(8)` obvykle umí běžet nad libovolným FS
- Zálohy databází – nutná spolupráce DB stroje

Co vzít v úvahu

- On-line replika – standby databáze, zrcadlení přes DRBD, atd.
- Off-site backup – proti živelným pohromám a krádeži
- Zabezpečení – šifrovaná nebo zamčená záloha
- Uchovávat i hodně staré zálohy

DRBD

Distributed Replicated Block Device

`http://www.drbd.org/` 

Upozornění:

RAID není záloha!

Co vzít v úvahu

- On-line replika – standby databáze, zrcadlení přes DRBD, atd.
- Off-site backup – proti živelným pohromám a krádeži
- Zabezpečení – šifrovaná nebo zamčená záloha
- Uchovávat i hodně staré zálohy

DRBD

Distributed Replicated Block Device

`http://www.drbd.org/` 

Upozornění:

RAID není záloha!

Zálohování na disk

- Rychlejší – přímý přístup versus převíjení pásky
- Nebezpečnější – `rm -rf`, elektrický výboj
- Cenově dostupnější – není třeba zvláštní mechaniku a řadič
- `rsync(1)` – synchronizace dvou adresářů; přenáší se jen rozdíly
- `cp -l` – kopie podstromu, běžné soubory jen hardlinkované .
- Lze vylepšovat – odmontování a uspání disku, šifrování, atd.

Zálohování na disk

- Rychlejší – přímý přístup versus převíjení pásky
- Nebezpečnější – `rm -rf`, elektrický výboj
- Cenově dostupnější – není třeba zvláštní mechaniku a řadič
- `rsync(1)` – synchronizace dvou adresářů; přenáší se jen rozdíly
- `cp -l` – kopie podstromu, běžné soubory jen hardlinkované  .
- Lze vylepšovat – odmontování a uspání disku, šifrování, atd.

Rozložení adresářů v systému

- Tradiční – není specifikováno žádnou de iure normou
- Rozdíly – BSD versus System V, modifikace od jednotlivých výrobců
- Linux – FileSystem Hierarchy standard (FHS) 

Kořenový svazek – I.

- Malý svazek, není sdílen mezi více stroji.
- Programy by neměly vyžadovat vytváření dalších souborů nebo adresářů přímo pod `/`.

  `/bin` – uživatelské programy, nezbytné k jednouživatelskému běhu systému a k nastartování sítě

  `/boot` – soubory zavaděče systému a jádro (někdy samostatný svazek; měl by být dostupný firmwaru počítače)

  `/dev` – speciální soubory. Obvykle obsahuje program `MAKEDEV(8)`

Kořenový svazek – II.

`/etc` – konfigurační soubory. Nelze sdílet mezi počítači. Na systémech blízkých SVR3 navíc spustitelné soubory pro správce systému (např. `mount(8)`; jinak viz `/sbin`).

`/home` – domovské adresáře uživatelů. Obvykle samostatný svazek. Někdy `/usr`, `/usr/home` nebo jiný.

`/lib` – sdílené knihovny, nezbytné pro jednouživatelský běh systému. Plug-iny, moduly jádra a další data.

`/lib32, /lib64` – alternativní adresáře pro multilib systémy.

Kořenový svazek – III.

`/mnt` – pro dočasně připojované svazky.

`/media` – pro automaticky připojované svazky.

`/opt` – přidané větší softwarové balíky. Obvykle samostatný svazek.

`/root` – domovský adresář superuživatele. Někdy též `/`.

`/sbin` – systémové programy (programy, které používá jen systém sám nebo správce systému). Na některých systémech chybí a tyto programy jsou v `/etc`.

`/tmp` – dočasné soubory. Adresář, přístupný všem užívatelům (vyžaduje sticky bit). Některé systémy promazávají `/tmp` při startu systému.

Adresář /usr – I.

- Sdílitelná data, přístupná v běžném případě pouze pro čtení.
- Subsystémy by neměly vytvářet další adresáře pod /usr – historickou výjimkou je X11.

  X11 – X Window System (často též X11R6). Obsahuje mj. i podadresáře bin, lib a include s odkazy z adresářů /usr/bin, /usr/lib a /usr/include.

  bin – uživatelské programy, které nejsou nezbytné v jednouživatelském režimu. Také zde jsou interpretery.

  doc – dokumentace (někdy share/doc).

Adresář /usr – II.

`games` – hry a vzdělávací programy ^_~

`include` – hlavičkové soubory pro jazyk C.

`lib` – knihovny, které nejsou nezbytně nutné pro jednouživatelský běh systému. Read-only data aplikací, závislá na platformě (například moduly pro Perl a podobně).

`lib32, lib64` – podobně jako `/lib32`, `/lib64`.

`libexec` – programy, které nejsou určené ke spouštění uživatelem.

`local` – adresář pro lokálně instalovaný software. Obsahuje podadresáře `bin`, `games`, `include`, `lib`, `sbin`, `share` a `src`.
BSD sem dává i porty  .

Adresář /usr – III.

`man` – manuálové stránky (někdy `share/man`).

`sbin` – systémové programy, které nejsou nezbytně nutné pro běh systému (síťové služby, tiskový démon a podobně).

`share` – data nezávislá na architektuře (informace o časových zónách, `terminfo` a podobně).

`src` – zdrojové texty od systémových komponent.

`spool, tmp` – symbolické linky do `/var` z důvodu zpětné kompatibility.

Adresář /var – I.

- Data, která se mohou měnit (tiskové fronty, mailboxy, různé cache).
- Není sdílitelný mezi počítači.

`adm` – administrativní data. Často obsahuje systémové logy  .

`cache` – generovaná data (cache) subsystémů.

`lock` – aplikační zámky – například zámky na sériové linky.

`log` – systémové logy.

`mail` – poštovní schránky uživatelů (někdy ve `spool/mail`).

Adresář /var – II.

`opt` – modifikovatelná data pro balíky v `/opt`.

`run` – soubory, vztahující se k běžícím programům.

`spool` – fronty (tiskové, poštovní a další).

`tmp` – dočasné soubory.

Otázka:

Do kterého adresáře byste umístili PID soubor běžícího procesu?
A kam pomocný program, který je spouštěn z vámi implementovaného démona?

Adresář /var – II.

`opt` – modifikovatelná data pro balíky v `/opt`.

`run` – soubory, vztahující se k běžícím programům.

`spool` – fronty (tiskové, poštovní a další).

`tmp` – dočasné soubory.

Otázka:

Do kterého adresáře byste umístili PID soubor běžícího procesu?
A kam pomocný program, který je spouštěn z vámi implementovaného démona?

Aktuální vývoj

- usrmove – přesun read-mostly dat z `/` do `/usr`.

Otázka:

Proč ne naopak `/usr/bin` do `/bin`?

- Stateless systémy – pro cloud, bez lokálních dat (CoreOS, Project Atomic, `etcd`).
- `/run` – pokud možno před připojením `/var`.

Aktuální vývoj

- usrmove – přesun read-mostly dat z `/` do `/usr`.

Otázka:

Proč ne naopak `/usr/bin` do `/bin`?

- Stateless systémy – pro cloud, bez lokálních dat (CoreOS, Project Atomic, `etcd`).
- `/run` – pokud možno před připojením `/var`.

Aktuální vývoj

- usrmove – přesun read-mostly dat z `/` do `/usr`.

Otázka:

Proč ne naopak `/usr/bin` do `/bin`?

- Stateless systémy – pro cloud, bez lokálních dat (CoreOS, Project Atomic, `etcd`).
- `/run` – pokud možno před připojením `/var`.

Aktuální vývoj

- usrmove – přesun read-mostly dat z `/` do `/usr`.

Otázka:

Proč ne naopak `/usr/bin` do `/bin`?

- Stateless systémy – pro cloud, bez lokálních dat (CoreOS, Project Atomic, `etcd`).
- `/run` – pokud možno před připojením `/var`.

Start systému – init

- Program – `/sbin/init`
- Proces číslo 1.

Varianty:

- BSD init – soubory `/etc/gettytab` a `/etc/rc`  .
- System V init – řídící soubor `/etc/inittab`
- Systemd 
- Další – `upstart`, SMF  , OpenRC, ...

Hard-coded paths

`/sbin/init`, někdy ještě `/bin/sh`.
Ostatní je nezávislé na kernelu.

SystemV init: Úrovně běhu systému

- Runlevels – číslo od 0 do 6.
- Určuje, které subsystémy jsou aktivní.
- 0 – Halt – zastavení systému
- 1 – Single – jednouživatelský běh systému
- 2 – Multi – víceuživatelský běh systému
- 3 – Remote FS – obvykle 2 + sdílení disků
- 4 – Free
- 5 – Free – Red Hat zde má 3 + X-Window system 
- 6 – Reboot – restart systému

System V init

init(8), telinit(8)

```
# init [0123456aAbBcCsSqQ]
```

- `0-6` Přechod na příslušnou úroveň chodu systému.
- `a-c,A-C` Nastartování jednorázových činností, stav se neeviduje.
- `sS` Totéž co `init 1`, jen konzolou se stane současný terminál.
- `qQ` Způsobí znovunačtení souboru `/etc/inittab`.

System V startovací skripty

- Startovací skripty v `/etc/init.d` – pro každý subsystém.
- Adresáře `/etc/rc[0-6].d`:
- Symbolické linky `[SK][0-9][0-9]`*skript* (například `K56syslog` nebo `S60sshd`) do `../init.d`.
- Startovací skripty se spouštějí s parametrem `start` nebo `stop`.

Red Hat/Fedora: 

- Adresář `/etc/sysconfig`.
- Další parametry: `restart`, `reload`, `condrestart` a `status`.
- Program `chkconfig(8)`. Také na IRIXu  .

Příklad: Soubor /etc/inittab

```
id:5:initdefault:
si::sysinit:/etc/rc.d/rc.sysinit
l0:0:wait:/etc/rc.d/rc 0
l1:1:wait:/etc/rc.d/rc 1
...
l6:6:wait:/etc/rc.d/rc 6
ud::once:/sbin/update
ca::ctrlaltdel:/sbin/shutdown -t3 -r now
pf::powerfail:/sbin/shutdown -h 'Power fail'
pr:12345:powerokwait:/sbin/shutdown -c \
    'Power restored'
1:12345:respawn:/sbin/mingetty tty1
2:2345:respawn:/sbin/mingetty tty2
4:2345:off:/sbin/mingetty tty4
x:5:respawn:/usr/bin/X11/xdm -nodaemon
```

/etc/inittab

Příklad: Syntaxe inittab

```
id:2345:respawn:/sbin/mingetty tty1
```

- Identifikace úlohy – pozor, v některých systémech může být nejvýše dvouznaková.
- Runlevel
- Způsob spouštění:
  - sysinit
  - once, wait
  - powerfail, powerok, powerokwait
  - respawn
  - off
- Příkaz + argumenty

/etc/inittab

Příklad: Syntaxe inittab

```
id:2345:respawn:/sbin/mingetty tty1
```

- Identifikace úlohy – pozor, v některých systémech může být nejvýše dvouznaková.
- Runlevel
- Způsob spouštění:
  - sysinit
  - once, wait
  - powerfail, powerok, powerokwait
  - respawn
  - off
- Příkaz + argumenty

/etc/inittab

Příklad: Syntaxe inittab

```
id:2345:respawn:/sbin/mingetty tty1
```

- Identifikace úlohy – pozor, v některých systémech může být nejvýše dvouznaková.
- Runlevel
- Způsob spouštění:
  - `sysinit`
  - `once, wait`
  - `powerfail, powerok, powerokwait`
  - `respawn`
  - `off`
- Příkaz + argumenty

/etc/inittab

Příklad: Syntaxe inittab

```
id:2345:respawn:/sbin/mingetty tty1
```

- Identifikace úlohy – pozor, v některých systémech může být nejvýše dvouznaková.
- Runlevel
- Způsob spouštění:
  - `sysinit`
  - `once, wait`
  - `powerfail, powerok, powerokwait`
  - `respawn`
  - `off`
- Příkaz + argumenty

Identifikace úlohy v souboru inittab

Otázka:

K čemu slouží první sloupec v souboru inittab?

```
id:5:initdefault:
si::sysinit:/etc/rc.d/rc.sysinit
l0:0:wait:/etc/rc.d/rc 0
l1:1:wait:/etc/rc.d/rc 1
...
l6:6:wait:/etc/rc.d/rc 6
ud::once:/sbin/update
1:12345:respawn:/sbin/mingetty tty1
2:2345:respawn:/sbin/mingetty tty2
4:2345:off:/sbin/mingetty tty4
x:5:respawn:/usr/bin/X11/xdm -nodaemon
```

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart , SMF , Systemd

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart , SMF , Systemd

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart , SMF , Systemd

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart , SMF , Systemd

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart , SMF , Systemd

Problémy System V initu

- Přístup k mnoha souborům (zpomaluje boot).
- Možné nekonzistence linků v `/etc/rc.d`.
- Jen priority, ne závislosti:
  - *„Když restartuji X, mělo by se automaticky restartovat Y.“*
- Nemožnost paralelizace.
- Chybí podrobnější konfigurace
  - respawn interval apod.

Alternativy SystemV initu

Upstart  , SMF  , Systemd 

Systemd

- Start úloh podle potřeby
- Předem otevřené sockety, automount body, atd.
- Aktivace/serializace až při použití
- Periodické spouštění úloh
- Sledování procesů přes control groups
- Snaha vyhnout se shellu
  - Ale: zpětně kompatibilní se SystemV skripty

Čtení na dobrou noc

Lennart Poettering: Rethinking PID 1
http://0pointer.de/blog/projects/systemd.html

Systemd

- Start úloh podle potřeby
- Předem otevřené sockety, automount body, atd.
- Aktivace/serializace až při použití
- Periodické spouštění úloh
- Sledování procesů přes control groups
- Snaha vyhnout se shellu
  - Ale: zpětně kompatibilní se SystemV skripty

Čtení na dobrou noc

Lennart Poettering: Rethinking PID 1
`http://0pointer.de/blog/projects/systemd.html`

Příklad: sshd.service

```
[Unit]
Description=OpenSSH server daemon
After=network.target sshd-keygen.service
Wants=sshd-keygen.service
[Service]
Type=forking
PIDFile=/var/run/sshd.pid
EnvironmentFile=-/etc/sysconfig/sshd
ExecStart=/usr/sbin/sshd $OPTIONS
ExecReload=/bin/kill -HUP $MAINPID
KillMode=process
Restart=on-failure
RestartSec=42s
[Install]
WantedBy=multi-user.target
```

Systemd: ovládání

- systemctl enable sshd.service
  - systemctl enable getty@ttyS1.service
  - /usr/lib/systemd/system/getty@.service
  - /etc/systemd/system/multi-user.target.wants/
- systemctl daemon-reload
- systemctl disable sshd.service
- systemctl start sshd.service
- systemctl stop sshd.service
- systemctl status sshd.service
- systemctl list-units
- systemctl reset-failed sshd.service

Systemd: ovládání

- `systemctl enable sshd.service`
  - `systemctl enable getty@ttyS1.service`
  - `/usr/lib/systemd/system/getty@.service`
  - `/etc/systemd/system/multi-user.target.wants/`
- `systemctl daemon-reload`
- `systemctl disable sshd.service`
- `systemctl start sshd.service`
- `systemctl stop sshd.service`
- `systemctl status sshd.service`
- `systemctl list-units`
- `systemctl reset-failed sshd.service`

Systemd: ovládání

- `systemctl enable sshd.service`
  - `systemctl enable getty@ttyS1.service`
  - `/usr/lib/systemd/system/getty@.service`
  - `/etc/systemd/system/multi-user.target.wants/`
- `systemctl daemon-reload`
- `systemctl disable sshd.service`
- `systemctl start sshd.service`
- `systemctl stop sshd.service`
- `systemctl status sshd.service`
- `systemctl list-units`
- `systemctl reset-failed sshd.service`

Systemd: ovládání

- systemctl enable sshd.service
  - systemctl enable getty@ttyS1.service
  - /usr/lib/systemd/system/getty@.service
  - /etc/systemd/system/multi-user.target.wants/
- systemctl daemon-reload
- systemctl disable sshd.service
- systemctl start sshd.service
- systemctl stop sshd.service
- systemctl status sshd.service
- systemctl list-units
- systemctl reset-failed sshd.service

Systemd: ovládání

- systemctl enable sshd.service
  - systemctl enable getty@ttyS1.service
  - /usr/lib/systemd/system/getty@.service
  - /etc/systemd/system/multi-user.target.wants/
- systemctl daemon-reload
- systemctl disable sshd.service
- systemctl start sshd.service
- systemctl stop sshd.service
- systemctl status sshd.service
- systemctl list-units
- systemctl reset-failed sshd.service

Systemd: ovládání

- `systemctl enable sshd.service`
  - `systemctl enable getty@ttyS1.service`
  - `/usr/lib/systemd/system/getty@.service`
  - `/etc/systemd/system/multi-user.target.wants/`
- `systemctl daemon-reload`
- `systemctl disable sshd.service`
- `systemctl start sshd.service`
- `systemctl stop sshd.service`
- `systemctl status sshd.service`
- `systemctl list-units`
- `systemctl reset-failed sshd.service`

Systemd: ovládání

- `systemctl enable sshd.service`
  - `systemctl enable getty@ttyS1.service`
  - `/usr/lib/systemd/system/getty@.service`
  - `/etc/systemd/system/multi-user.target.wants/`
- `systemctl daemon-reload`
- `systemctl disable sshd.service`
- `systemctl start sshd.service`
- `systemctl stop sshd.service`
- `systemctl status sshd.service`
- `systemctl list-units`
- `systemctl reset-failed sshd.service`

Systemd: ovládání

- `systemctl enable sshd.service`
  - `systemctl enable getty@ttyS1.service`
  - `/usr/lib/systemd/system/getty@.service`
  - `/etc/systemd/system/multi-user.target.wants/`
- `systemctl daemon-reload`
- `systemctl disable sshd.service`
- `systemctl start sshd.service`
- `systemctl stop sshd.service`
- `systemctl status sshd.service`
- `systemctl list-units`
- `systemctl reset-failed sshd.service`

Svazky – I.

- /etc/fstab
  - automaticky připojované svazky
  - swapovací oblasti 
  - manuálně připojované svazky

Příklad: /etc/fstab

```
/dev/sda1 /         ext3   defaults          1 1
tmpfs     /dev/shm  tmpfs  defaults          0 0
devpts    /dev/pts  devpts gid=5,mode=620  0 0
sysfs     /sys      sysfs  defaults          0 0
proc      /proc     proc   defaults          0 0
/dev/sda2 none      swap   pri=10            0 0
```

Svazky – I.

- /etc/fstab
  - automaticky připojované svazky
  - swapovací oblasti 
  - manuálně připojované svazky

Příklad: /etc/fstab

```
/dev/sda1 /         ext3   defaults          1 1
tmpfs     /dev/shm  tmpfs  defaults          0 0
devpts    /dev/pts  devpts gid=5,mode=620  0 0
sysfs     /sys      sysfs  defaults          0 0
proc      /proc     proc   defaults          0 0
/dev/sda2 none      swap   pri=10            0 0
```

Svazky – II.

- `/etc/mtab` – aktuálně připojené svazky (také v `/proc/mounts` ).
- Program `mount(8)` – připojení svazku.
- Program `umount(8)` – odpojení svazku.
- Bind-mount – připojení existujícího adresáře jako svazku 
- Vícenásobné připojení téhož svazku 
- Loop device – vytvoření blokového zařízení ze souboru. Možnost připojení souboru jako svazku (např. ISO 9660 obraz CD).  

Odkládací prostor

- Disková oblast. Někdy možnost swapovat do souboru.
- Vzdálený odkládací prostor – těžké implementovat (out-of-memory deadlock).
- Seznam – obvykle v `/etc/fstab`
- Aktivace/deaktivace – `swapon(8)`, `swapoff(8)`.
- Další informace – `swap(8)`, `/proc/swaps` 

Automounter

- Závislosti mezi počítači
  - např. při výpadku napájení
  - vzájemné sdílení svazků: problematické
- Řešení: připojování svazků podle potřeby
- Implementace: virtuální souborový systém
  - Automount point – detekce přístupu k adresáři
  - Mapování podadresářů na souborové systémy
  - Příklad: `aisa:/home`
  - Nebo přímá náhrada automount pointu
- Implementace:
  - autofs
  - automount
  - amd(8) – user-space

Automounter

- Závislosti mezi počítači
  - např. při výpadku napájení
  - vzájemné sdílení svazků: problematické
- Řešení: připojování svazků podle potřeby
- Implementace: virtuální souborový systém
  - Automount point – detekce přístupu k adresáři
  - Mapování podadresářů na souborové systémy
  - Příklad: `aisa:/home`
  - Nebo přímá náhrada automount pointu
- Implementace:
  - autofs
  - automount
  - amd(8) – user-space

Automounter

- Závislosti mezi počítači
  - např. při výpadku napájení
  - vzájemné sdílení svazků: problematické
- Řešení: připojování svazků podle potřeby
- Implementace: virtuální souborový systém
  - Automount point – detekce přístupu k adresáři
  - Mapování podadresářů na souborové systémy
  - Příklad: `aisa:/home`
  - Nebo přímá náhrada automount pointu
- Implementace:
  - autofs
  - automount
  - amd(8) – user-space

Automounter

- Závislosti mezi počítači
  - např. při výpadku napájení
  - vzájemné sdílení svazků: problematické
- Řešení: připojování svazků podle potřeby
- Implementace: virtuální souborový systém
  - Automount point – detekce přístupu k adresáři
  - Mapování podadresářů na souborové systémy
  - Příklad: `aisa:/home`
  - Nebo přímá náhrada automount pointu
- Implementace:
  - autofs 
  - automount 
  - amd(8) – user-space

Příklad: Konfigurace autofs

/etc/auto.master:

```
/ftp    /etc/auto.ftp
/home   /etc/auto.home
```

/etc/auto.ftp:

```
pub ftp.fi.muni.cz:/export/ftp/ftp/pub
```

/etc/auto.home:

```
*    home.fi.muni.cz:/export/home/&
```

Uživatelé a skupiny

- UID/GID – identifikace uživatele/skupiny z hlediska jádra systému.
- Jméno uživatele – používá se při přihlašování a u logování do souborů.
- Základní databáze – `/etc/passwd`, `/etc/group`.

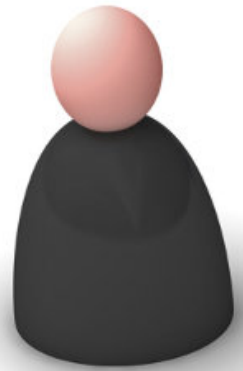

Soubor /etc/passwd

Příklad: Řádek z /etc/passwd

```
ayanami:x:1999:2014:Rei Ayanami:/home/ayanami\
    :/bin/bash
```

- Jméno uživatele – klíč v `/etc/passwd`.
- Heslo – v zašifrované podobě.
- UID – ne nutně jedinečné.
- GID – reálné/efektivní GID, které mají procesy po přihlášení.
- GCOS – komentář, obvykle celé jméno uživatele.
- Domovský adresář – pracovní adresář shellu po přihlášení.
- Shell – je spuštěn po přihlášení.

Pole GCOS v /etc/passwd

- Některé systémy – strukturované pole GCOS.
- Několik záznamů oddělených čárkou (místnost, tel. číslo, atd).
- Využívá např. `finger(1)`.
- GCOS - General Electric Comprehensive Operating System

Dennis Ritchie píše:

„Sometimes we sent printer output or batch jobs to the GCOS machine. The GCOS field in the password file was a place to stash the information for the `$IDENTcard`*. Not elegant.“*

Šifrování hesel

- Standardně – 25–krokový DES, 2 znaky sůl, zbytek heslo.
- Knihovní funkce – `crypt(3)`.
- Jiné metody – MD5, SHA-1, SHA-512, ... (+ sůl)

Příklad: Standardní šifrování hesla

```
$ perl -e 'print crypt("jezek", "42"), "\n"'
42uresi6Z/E/w
```

Příklad: SHA-512 heslo

```
$6$pQ5OiSwS$OWAzrqjlC4rkfafAsPohh/6HvmieN6\
jcYxEiAotx84wpaG1Wrgvj/CJbGfRXGzlG48zErbYE\
DIWvFzDi7UxxZ/
```

Šifrování hesel

- Standardně – 25–krokový DES, 2 znaky sůl, zbytek heslo.
- Knihovní funkce – `crypt(3)`.
- Jiné metody – MD5, SHA-1, SHA-512, ... (+ sůl)

Příklad: Standardní šifrování hesla

```
$ perl -e 'print crypt("jezek", "42"), "\n"'
42uresi6Z/E/w
```

Příklad: SHA-512 heslo

```
$6$pQ5OiSwS$OWAzrqjlC4rkfafAsPohh/6HvmieN6\
jcYxEiAotx84wpaG1Wrgvj/CJbGfRXGzlG48zErbYE\
DIWvFzDi7UxxZ/
```

Šifrování hesel

- Standardně – 25–krokový DES, 2 znaky sůl, zbytek heslo.
- Knihovní funkce – `crypt(3)`.
- Jiné metody – MD5, SHA-1, SHA-512, ... (+ sůl)

Příklad: Standardní šifrování hesla

```
$ perl -e 'print crypt("jezek", "42"), "\n"'
42uresi6Z/E/w
```

Příklad: SHA-512 heslo

```
$6$pQ5OiSwS$OWAzrqjlC4rkfafAsPohh/6HvmieN6\
jcYxEiAotx84wpaG1Wrgvj/CJbGfRXGzlG48zErbYE\
DIWvFzDi7UxxZ/
```

Ukládání hesel

- Standardní UNIX – hesla jsou vystavena útoku hrubou silou (John the Ripper) a slovníkovému útoku (`crack(8)`).
- Shadow passwords – hesla a další údaje jsou uloženy v souboru `/etc/shadow`. Omezení hesla na určitý čas, omezení frekvence změny hesla. Nutnost set-uid/gid u programů, pracujících s hesly.

Příklad: Záznam v `/etc/shadow`

```
ayanami:$6$p...xZ/:14224:0:99999:7:::
```

- BSD – `/etc/master.passwd` – analogie shadow 
- Trusted control base: umožňuje zakázat recyklaci hesla, změnu hesla, volbu vlastního hesla, atd.

Formát souboru /etc/group

Příklad: Záznam v /etc/group

```
nerv:x:2014:ayanami,asuka,shinji
```

- Jméno skupiny – identifikace pro logování do souboru a pro přepínání GID pomocí `newgrp(1)`.
- Heslo skupiny – obvykle nepoužito. Případně i v `/etc/gshadow`. Skupiny bez hesla přidány při přihlášení.
- Číslo skupiny – identifikace pro systém.
- Seznam uživatelů – jména oddělená čárkami. Primární skupina je implicitně, uživatel zde nemusí být uveden.

Modifikace tabulky uživatelů

- Speciální programy – `vipw(8)` – je-li databáze uživatelů uložena i jinde (`shadow`, `master.passwd`).
- Změna uživatelských informací – `chfn(8)`.
- Dávkové přidávání – `useradd`, `groupadd`, `userdel`, `groupdel` – vytváří domovský adresář, alokuje volné UID, kopíruje soubory z `/etc/skel`.
- `pwconv(8)` – převod hesel do `shadow`.

Otázka:

K čemu je dobré mít i skupinu pro každého uživatele?

Modifikace tabulky uživatelů

- Speciální programy – `vipw(8)` – je-li databáze uživatelů uložena i jinde (`shadow`, `master.passwd`).
- Změna uživatelských informací – `chfn(8)`.
- Dávkové přidávání – `useradd`, `groupadd`, `userdel`, `groupdel` – vytváří domovský adresář, alokuje volné UID, kopíruje soubory z `/etc/skel`.
- `pwconv(8)` – převod hesel do `shadow`.

Otázka:

K čemu je dobré mít i skupinu pro každého uživatele?

Soubor /etc/shells

Příklad: Soubor /etc/shells

```
/bin/sh
/bin/bash
/bin/tcsh
```

- Změna shellu pomocí chsh(1).
- Některé služby jen pro uživatele s platným shellem.
- /sbin/nologin – shell pro pseudouživatele.

Name Service Switch

- Alternativní zdroje dat pro systémové tabulky (`passwd`, `group`, `hosts`, ...).
- Implementace – plug-iny do `libc`.
  - `/lib/libnss_`*`služba`*`.so.X`

Příklad: Soubor `/etc/nsswitch.conf`

```
passwd:    compat
group:     compat
hosts:     dns [!UNAVAIL=return] files
networks:  nis [NOTFOUND=return] files
```

NSSwitch – konfigurace

- Formát souboru – databáze, mezera, popis služeb.
- Podrobnější specifikace – [[!]*STATUS=AKCE* …]

Akce:

`RETURN` – vrácení právě nalezené hodnoty nebo chyby.

`CONTINUE` – pokračovaní použitím další služby.

NSSwitch – návratové stavy

`SUCCESS` – záznam nalezen, nedošlo k chybě. Implicitní akce je `RETURN`.

`NOTFOUND` – vyhledávání proběhlo bez chyby, ale záznam se nenašel. Implicitní akce je `CONTINUE`.

`UNAVAIL` – služba není trvale dostupná (např. nezkonfigurovaná). Implicitně `CONTINUE`.

`TRYAGAIN` – dočasná chyba (timeout, vyčerpání prostředků, atd.). Implicitně `CONTINUE`.

Uživatelé a skupiny – programování

getpwnam(3), getpwuid(3) Databáze uživatelů

```
#include <pwd.h>
#include <sys/types.h>
struct passwd *getpwnam(const char *name);
struct passwd *getpwuid(uid_t uid);

struct passwd {
    char *pw_name;
    char *pw_passwd;
    uid_t pw_uid;
    gid_t pw_gid;
    char *pw_gecos;
    char *pw_dir;
    char *pw_shell;
};
```

Poznámky k getpw*()

- Vrací ukazatel na strukturu, popisující záznam daného uživatele.
- Pozor – funkce nejsou reentrantní.
- Seznam všech uživatelů:
  - `getpwent(3)`, `setpwent(3)`, `endpwent(3)`
- NSSwitch a příkazová řádka:
  - `getent(1)`
  - `$ getent passwd ayanami`

Poznámky k getpw*()

- Vrací ukazatel na strukturu, popisující záznam daného uživatele.
- Pozor – funkce nejsou reentrantní.
- Seznam všech uživatelů:
  - `getpwent(3)`, `setpwent(3)`, `endpwent(3)`
- NSSwitch a příkazová řádka:
  - `getent(1)`
  - `$ getent passwd ayanami`

Poznámky k getpw*()

- Vrací ukazatel na strukturu, popisující záznam daného uživatele.
- Pozor – funkce nejsou reentrantní.
- Seznam všech uživatelů:
  - `getpwent(3)`, `setpwent(3)`, `endpwent(3)`
- NSSwitch a příkazová řádka:
  - `getent(1)`
  - `$ getent passwd ayanami`

Poznámky k getpw*()

- Vrací ukazatel na strukturu, popisující záznam daného uživatele.
- Pozor – funkce nejsou reentrantní.
- Seznam všech uživatelů:
  - `getpwent(3)`, `setpwent(3)`, `endpwent(3)`
- NSSwitch a příkazová řádka:
  - `getent(1)`
  - `$ getent passwd ayanami`

Databáze skupin

getgrnam(3), getgrgid(3)

```
#include <grp.h>
#include <sys/types.h>
struct group *getgrnam(const char *name);
struct group *getgrgid(gid_t gid);

struct group {
    char *gr_name;
    char *gr_passwd;
    gid_t gr_gid;
    char **gr_mem;
};
```

Seznam všech skupin – getgrent(3), setgrent(3), endgrent(3).

Pluggable Authentication Modules

- PAM – Sun Microsystems, nyní GPL nebo BSD. Hlavní vývoj nyní Red Hat.
- Téměř všechny UNIXy – distribuce Linuxu, Solaris, HP-UX. IRIX a některé BSD nikoliv. Různé stupně vývoje.
- Modulární přístup k autentizaci – čipové karty, hesla, biometriky, síťové databáze (Kerberos, LDAP, NIS), atd.
- Architektura – knihovna `libpam`, plug-iny v `/lib/security`, konfigurace v `/etc/pam.conf` a `/etc/pam.d/*`.

PAM – fáze autentizace

`account` – jestli vůbec člověk má účet, nevyexpirované heslo, může k dané službě přistupovat?

`auth` – vlastní autentizace – ověření identity žadatele (heslo, jednorázové heslo, biometriky, čipové karty + PIN, atd.).

`password` – změny autentizačních mechanismů (změna hesla apod.).

`session` – akce před zpřístupněním služby a po ukončení (audit, připojení domovského adresáře, nastavení uživatelských limitů, atd).

Příklad: PAM – formát konfigurace

```
auth     required   pam_securetty.so
auth     required   pam_env.so
auth     required   pam_nologin.so
auth     sufficient pam_unix.so nullok
auth     required   pam_deny.so
account  required   pam_unix.so
password required   pam_cracklib.so retry=3
password sufficient pam_unix.so nullok shadow
password required   pam_deny.so
session  required   pam_limits.so
session  required   pam_unix.so
session  optional   pam_console.so
```

PAM - řídící hodnoty

`required` – pokud selže, selže i celý autentizační proces.

`requisite` – totéž, ale skončí se hned.

`sufficient` – stačí k autentizaci bez ohledu na výsledek následujících modulů.

`optional` – spustí se, ale výsledek se použije pouze pokud jde o jediný modul daného typu.

Soubor utmp

- /var/run/utmp
- Seznam právě přihlášených uživatelů.
- Pole struktur utmp.
- POSIX.1 rozhraní utmpx.
- Programy – who(1), w(1).

Rozhraní utmpx

getutxent(3) — Práce s utmpx

```
#include <utmpx.h>

struct utmpx *getutxent(void);
struct utmpx *getutxid(struct utmpx *);
struct utmpx *getutxline(struct utmpx *);
struct utmpx *pututxline(struct utmpx *);
void setutxent(void);
void endutxent(void);
```

Soubor wtmp

- /var/log/wtmp
- Záznam o přihlášeních a odhlášeních uživatelů.
- Stejný formát jako u utmp, uživatel NULL značí odhlášení na daném terminálu.
- Speciální záznamy – start a ukončení systému, změna úrovně běhu systému. Změna systémového data.
- Neexistující wtmp – zákaz vedení záznamů. Při rotování wtmp nutno vždy vytvořit nový soubor.
- Soubor btmp – záznamy o chybných přihlášeních.
- Programy – last(8), lastb(8).

Terminálové procesy

`getty` – inicializace linky, výpis zprávy, čekání na vstup.

`login` – načtení hesla, zápis do `wtmp` a `utmp`.

`shell` – uživatelský program.

Zařízení v UNIXu

```
$ ls -l /dev
brw-r----- 1 root disk 8, 16\
    Oct 15 20:56 /dev/sdb
...
crw-rw---- 1 kas  root 5, 1 \
    Oct 15 20:58 /dev/console
```

- zařízení – speciální soubor v /dev
- typ: bloková, znaková
- hlavní číslo – číslo ovladače v jádře
- vedlejší číslo – interní ID pro ovladač

Zařízení v UNIXu

```
$ ls -l /dev
brw-r----- 1 root disk 8, 16\
    Oct 15 20:56 /dev/sdb
...
crw-rw---- 1 kas  root 5, 1 \
    Oct 15 20:58 /dev/console
```

- zařízení – speciální soubor v /dev
- typ: bloková, znaková
- hlavní číslo – číslo ovladače v jádře
- vedlejší číslo – interní ID pro ovladač

Zařízení v UNIXu

```
$ ls -l /dev
brw-r----- 1 root disk 8, 16\
    Oct 15 20:56 /dev/sdb
...
crw-rw---- 1 kas  root 5, 1 \
    Oct 15 20:58 /dev/console
```

- zařízení – speciální soubor v /dev
- typ: bloková, znaková
- hlavní číslo – číslo ovladače v jádře
- vedlejší číslo – interní ID pro ovladač

Zařízení v UNIXu

```
$ ls -l /dev
brw-r----- 1 root disk 8, 16\
    Oct 15 20:56 /dev/sdb
...
crw-rw---- 1 kas  root 5, 1 \
    Oct 15 20:58 /dev/console
```

- zařízení – speciální soubor v /dev
- typ: bloková, znaková
- hlavní číslo – číslo ovladače v jádře
- vedlejší číslo – interní ID pro ovladač

Zařízení v C

- Datový typ `dev_t`:
  - `dev_t makedev(unsigned maj, unsigned min);`
  - `unsigned major(dev_t dev);`
  - `unsigned minor(dev_t dev);`
- `dev_t` musí být numerický typ!
- Použití: `stat(2)`, `mknod(2)`, ...

Zařízení v C

- Datový typ dev_t:
  - `dev_t makedev(unsigned maj, unsigned min);`
  - `unsigned major(dev_t dev);`
  - `unsigned minor(dev_t dev);`
- dev_t musí být numerický typ!
- Použití: `stat(2)`, `mknod(2)`, ...

Zařízení v C

- Datový typ dev_t:
  - `dev_t makedev(unsigned maj, unsigned min);`
  - `unsigned major(dev_t dev);`
  - `unsigned minor(dev_t dev);`
- dev_t musí být numerický typ!
- Použití: `stat(2)`, `mknod(2)`, ...

Problémy

Kolik bitů na vedlejší číslo? SCSI: kanál, target, LUN, partition.

Příliš velké /dev:

```
$ ls /dev | wc -l
1431
```

Dynamicky vznikající zařízení

A v neposlední řadě ...

Problémy

Kolik bitů na vedlejší číslo? SCSI: kanál, target, LUN, partition.

Příliš velké /dev:

```
$ ls /dev | wc -l
1431
```

Dynamicky vznikající zařízení

A v neposlední řadě ...

Problémy

Kolik bitů na vedlejší číslo? SCSI: kanál, target, LUN, partition.

Příliš velké /dev:

```
$ ls /dev | wc -l
1431
```

Dynamicky vznikající zařízení

A v neposlední řadě ...

Problémy

Kolik bitů na vedlejší číslo? SCSI: kanál, target, LUN, partition.

Příliš velké /dev:

```
$ ls /dev | wc -l
1431
```

Dynamicky vznikající zařízení

A v neposlední řadě ...

… pojmenování zařízení:

Podle topologie (`/dev/dsk/c0t3d1s8`)

- přesun disku na jiný řadič
- přesun disku na jiný *ovladač*

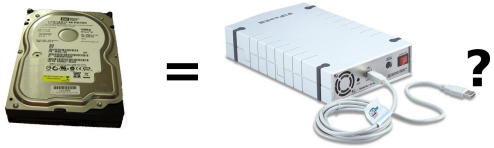

Podle ovladače a pořadí (`/dev/sda1`)

- výpadek disku: ostatní se přejmenují

… pojmenování zařízení:

Podle topologie (`/dev/dsk/c0t3d1s8`)

- přesun disku na jiný řadič
- přesun disku na jiný *ovladač*


=

?

Podle ovladače a pořadí (`/dev/sda1`)

- výpadek disku: ostatní se přejmenují

Jak pojmenovávat?

Podle topopologie: `eth0` je ta v tomto PCI slotu.

Podle výrobce: tento fotoaparát vždy jako `/dev/fotak`

Podle pořadí: nějaká myš jako `/dev/mouse0`.

Podle výrobního čísla: pouze můj mobil jako `/dev/mobil`.

Nebo úplně jinak: label filesystému, UUID, ...

Jak pojmenovávat?

Podle topopologie: `eth0` je ta v tomto PCI slotu.

Podle výrobce: tento fotoaparát vždy jako `/dev/fotak`

Podle pořadí: nějaká myš jako `/dev/mouse0`.

Podle výrobního čísla: pouze můj mobil jako `/dev/mobil`.

Nebo úplně jinak: label filesystému, UUID, ...

Jak pojmenovávat?

Podle topopologie: `eth0` je ta v tomto PCI slotu.

Podle výrobce: tento fotoaparát vždy jako `/dev/fotak`

Podle pořadí: nějaká myš jako `/dev/mouse0`.

Podle výrobního čísla: pouze můj mobil jako `/dev/mobil`.

Nebo úplně jinak: label filesystému, UUID, ...

Jak pojmenovávat?

Podle topopologie: `eth0` je ta v tomto PCI slotu.

Podle výrobce: tento fotoaparát vždy jako `/dev/fotak`

Podle pořadí: nějaká myš jako `/dev/mouse0`.

Podle výrobního čísla: pouze můj mobil jako `/dev/mobil`.

Nebo úplně jinak: label filesystému, UUID, ...

Jak pojmenovávat?

Podle topopologie: `eth0` je ta v tomto PCI slotu.

Podle výrobce: tento fotoaparát vždy jako `/dev/fotak`

Podle pořadí: nějaká myš jako `/dev/mouse0`.

Podle výrobního čísla: pouze můj mobil jako `/dev/mobil`.

Nebo úplně jinak: label filesystému, UUID, ...

DevFS

- virtuální souborový systém
- idea ze Solarisu
- ovladače samy registrují soubory
- „nějaká“ výchozí přístupová práva
- pojmenování: jako na Solarisu, symlinky pro kompatibilitu

Problémy DevFS

- politika uvnitř jádra
- není perzistentní nastavení
- race conditions

DevFS

- virtuální souborový systém
- idea ze Solarisu
- ovladače samy registrují soubory
- „nějaká“ výchozí přístupová práva
- pojmenování: jako na Solarisu, symlinky pro kompatibilitu

Problémy DevFS

- politika uvnitř jádra
- není perzistentní nastavení
- race conditions

SysFS

- virtuální souborový systém
- obvykle jako /sys
- Linux 2.6
- Greg Kroah-Hartmann
- obraz subsystému ovladačů v jádře
- adresáře podle topologie, tříd zařízení, ovladačů, ...
- inventář hardwaru
- dynamická alokace hlavních čísel

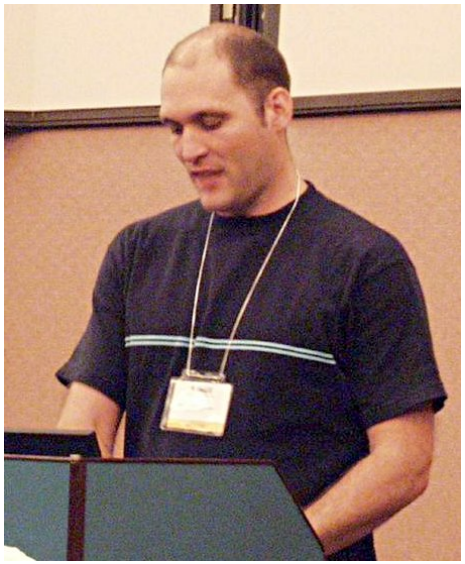

Příklad: SysFS

```
# echo 0 0 0 > /sys/class/scsi_host/host0/scan

# echo 1 > /sys/block/sdb/device/delete

# echo 45 > /sys/devices/platform/\
    w83627hf/temp_max

# cat /sys/class/input/input0/name
Power Button (FF)

# cat /sys/bus/pci/devices/0000:00:1b.0/vendor
0x8086
```

Příklad: SysFS

```
# echo 0 0 0 > /sys/class/scsi_host/host0/scan

# echo 1 > /sys/block/sdb/device/delete

# echo 45 > /sys/devices/platform/\
    w83627hf/temp_max

# cat /sys/class/input/input0/name
Power Button (FF)

# cat /sys/bus/pci/devices/0000:00:1b.0/vendor
0x8086
```

Příklad: SysFS

```
# echo 0 0 0 > /sys/class/scsi_host/host0/scan

# echo 1 > /sys/block/sdb/device/delete

# echo 45 > /sys/devices/platform/\
    w83627hf/temp_max

# cat /sys/class/input/input0/name
Power Button (FF)

# cat /sys/bus/pci/devices/0000\:00\:1b.0/vendor
0x8086
```

Příklad: SysFS

```
# echo 0 0 0 > /sys/class/scsi_host/host0/scan

# echo 1 > /sys/block/sdb/device/delete

# echo 45 > /sys/devices/platform/\
    w83627hf/temp_max

# cat /sys/class/input/input0/name
Power Button (FF)

# cat /sys/bus/pci/devices/0000:00:1b.0/vendor
0x8086
```

Příklad: SysFS

```
# echo 0 0 0 > /sys/class/scsi_host/host0/scan

# echo 1 > /sys/block/sdb/device/delete

# echo 45 > /sys/devices/platform/\
    w83627hf/temp_max

# cat /sys/class/input/input0/name
Power Button (FF)

# cat /sys/bus/pci/devices/0000:00:1b.0/vendor
0x8086
```

Hotplug

- Reakce na události ovladačů, sběrnic, ...
- `/sbin/hotplug` – notifikace spuštěním programu 
- `AF_NETLINK` – notifikační socket 
- *Coldplug* – inventarizace po startu

udev

- Správa /dev v uživatelském prostoru
- Politika mimo jádro
- Využívá SysFS a hotplug notifikaci
- /dev na disku nebo na ramdisku
- démon udevd(8)

Konfigurace udev

- adresář /etc/udev
- pravidla v /etc/udev/rules.d
- příkaz udevadm(8)
  - udevadm trigger
  - udevadm info

udev

- Správa /dev v uživatelském prostoru
- Politika mimo jádro
- Využívá SysFS a hotplug notifikaci
- /dev na disku nebo na ramdisku
- démon udevd(8)

Konfigurace udev

- adresář /etc/udev
- pravidla v /etc/udev/rules.d
- příkaz udevadm(8)
  - udevadm trigger
  - udevadm info

Příklad: Teploměr


```
KERNEL==”ttyUSB*”, \
   ATTRS{product}==”Papouch TMU Thermometer”, \
   ATTRS{serial}==”PPQ3NTMG”, \
   SYMLINK+=”tmu0”
```

Příklad: Spuštění programu

```
KERNEL==”sd*1”, \
   SYSFS{model}==”G3                  ”, \
   SYSFS{vendor}==”M-System”, \
   RUN+=”/usr/local/sbin/podcast-to-player”
```

Psaní vlastních pravidel

Příklad: Výpis atributů

```
$ udevadm info -q path -n /dev/ttyACM0
/devices/pci0000:00/0000:00:13.2/usb2/2-3/\
    /2-3.2/2-3.2:1.0/tty/ttyACM0
$ udevadm info -q all -a -n /dev/sda
```

Podrobnější návod

http://reactivated.net/\
writing_udev_rules.html

Psaní vlastních pravidel

Příklad: Výpis atributů

```
$ udevadm info -q path -n /dev/ttyACM0
/devices/pci0000:00/0000:00:13.2/usb2/2-3/\
    /2-3.2/2-3.2:1.0/tty/ttyACM0
$ udevadm info -q all -a -n /dev/sda
```

Podrobnější návod

```
http://reactivated.net/\
   /writing_udev_rules.html
```

udev a disky

Podle výrobního čísla

```
/dev/disk/by-id/scsi-SATA_HDS724040KLAT80_
```

Podle topologie

```
/dev/disk/by-path/pci-0000:00:0f.0-scsi-0:
```

Podle UUID filesystému

```
/dev/disk/by-uuid/1ffe43cc-5ca6-45d5-80df-
```

udev a disky

Podle výrobního čísla

```
/dev/disk/by-id/scsi-SATA_HDS724040KLAT80_
```

Podle topologie

```
/dev/disk/by-path/pci-0000:00:0f.0-scsi-0:
```

Podle UUID filesystému

```
/dev/disk/by-uuid/1ffe43cc-5ca6-45d5-80df-
```

udev a disky

Podle výrobního čísla

```
/dev/disk/by-id/scsi-SATA_HDS724040KLAT80_
```

Podle topologie

```
/dev/disk/by-path/pci-0000:00:0f.0-scsi-0:
```

Podle UUID filesystému

```
/dev/disk/by-uuid/1ffe43cc-5ca6-45d5-80df-
```

Jádro versus aplikace

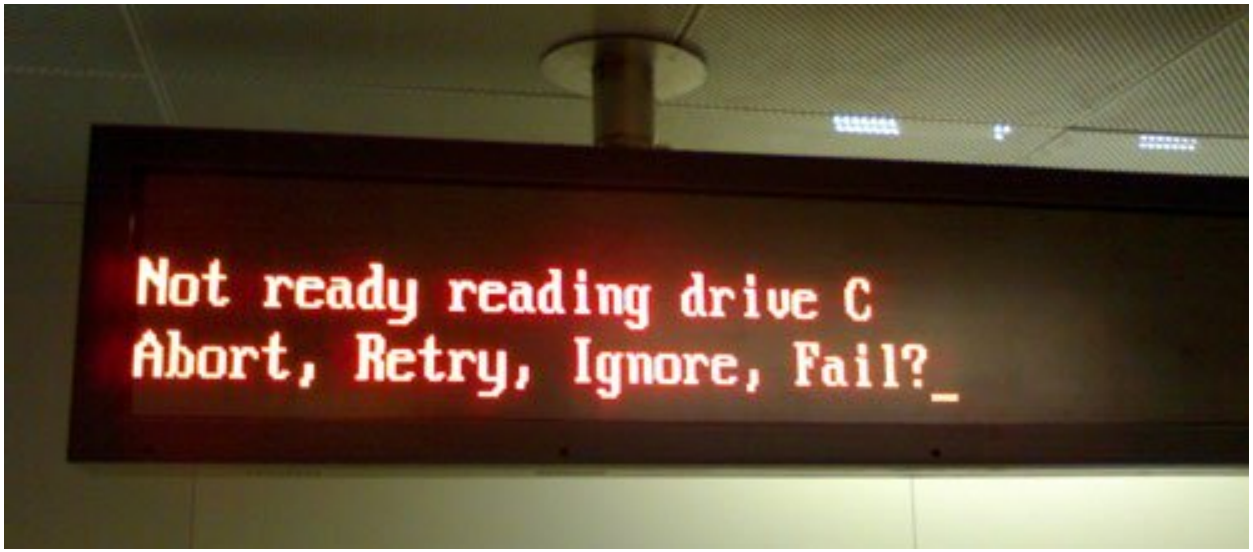

- Modularita UNIXu – jádro je daleko od aplikací
- Není jak se dovědět: vznik zařízení, plný disk, aktivace síťové karty, ...
- I na desktopu: příchod VoIP volání, full-screen aplikace, ...

Jádro versus aplikace

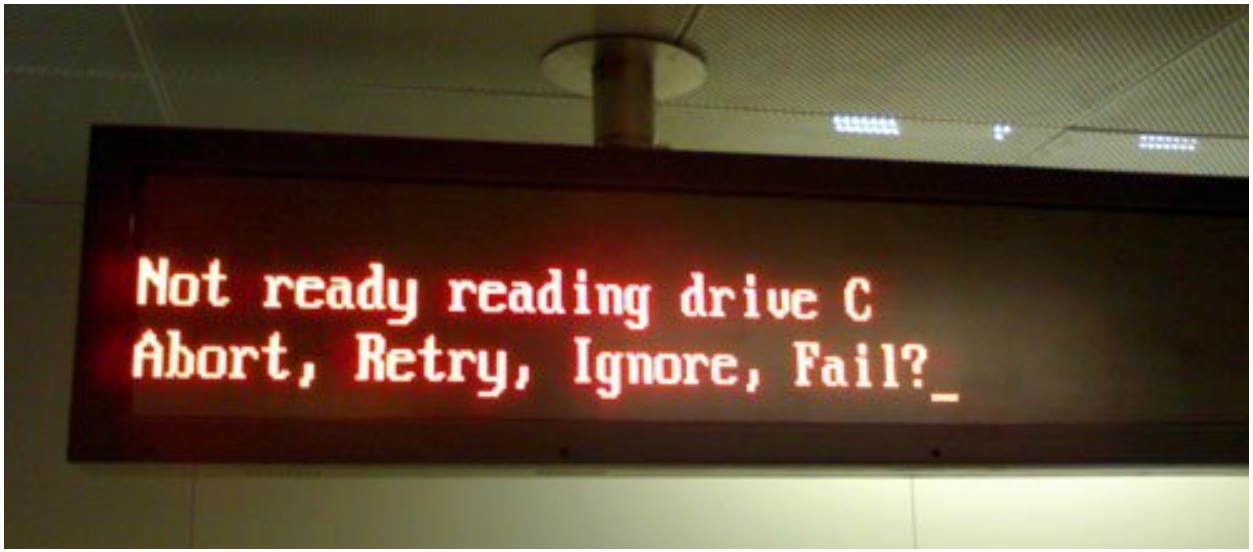

- Modularita UNIXu – jádro je daleko od aplikací
- Není jak se dovědět: vznik zařízení, plný disk, aktivace síťové karty, ...
- I na desktopu: příchod VoIP volání, full-screen aplikace, ...

Jádro versus aplikace

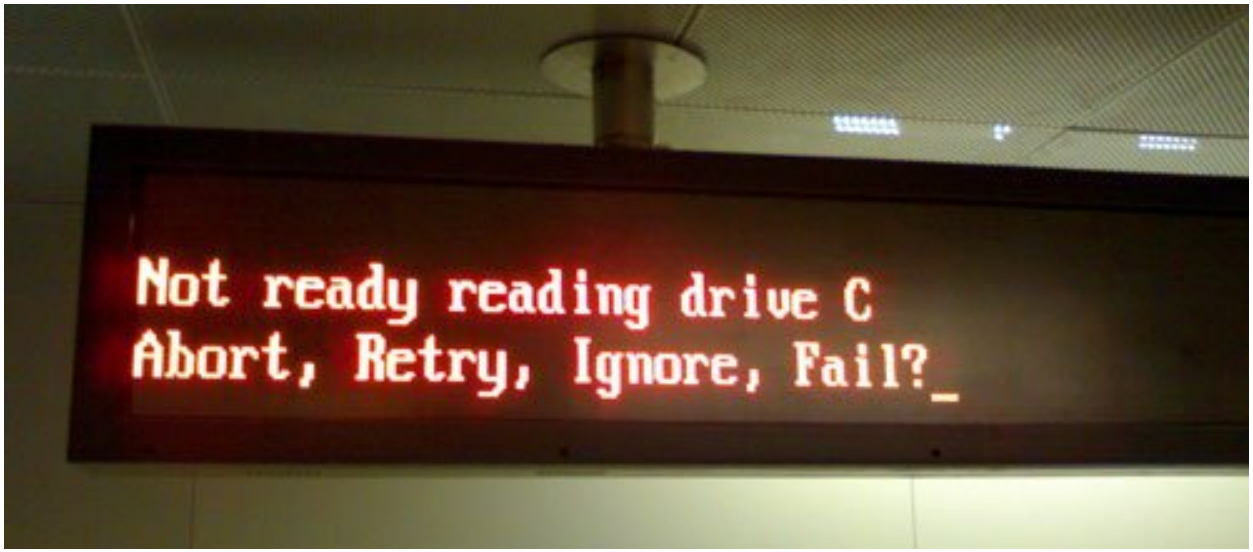

- Modularita UNIXu – jádro je daleko od aplikací
- Není jak se dovědět: vznik zařízení, plný disk, aktivace síťové karty, ...
- I na desktopu: příchod VoIP volání, full-screen aplikace, ...

Jádro versus aplikace

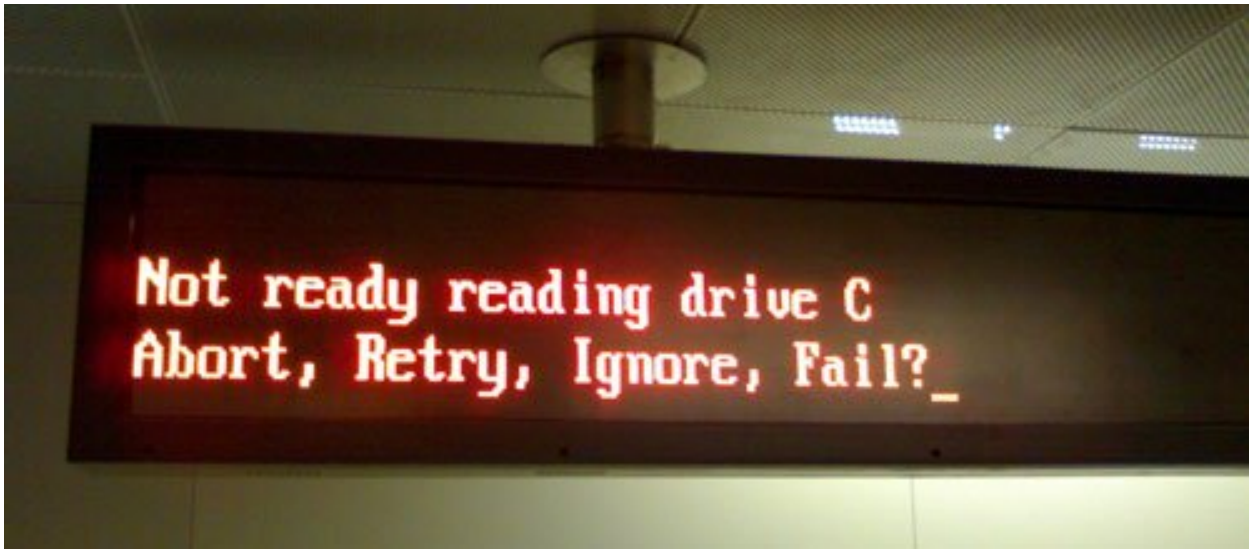

- Modularita UNIXu – jádro je daleko od aplikací
- Není jak se dovědět: vznik zařízení, plný disk, aktivace síťové karty, ...
- I na desktopu: příchod VoIP volání, full-screen aplikace, ...

D-Bus

- Desktop Bus
- Zasílání zpráv
- Broadcast – subscribe
- System bus, session bus
- Vzdálené volání objektů
- `dbus-monitor(8)`

X Window System

- Názvy – X, X Window System, X Version 11, X Window System Version 11, X11.

Nesprávný název

X Windows

- Historie – DEC 1983–1986. Hlavní architekt Jim Gettys.
- X Consortium – řídilo další vývoj (pak The Open Group, pak X.org).

X Window System

- Názvy – X, X Window System, X Version 11, X Window System Version 11, X11.

Nesprávný název

X Windows

- Historie – DEC 1983–1986. Hlavní architekt Jim Gettys.
- X Consortium – řídilo další vývoj (pak The Open Group, pak X.org).

X Window System

- Názvy – X, X Window System, X Version 11, X Window System Version 11, X11.

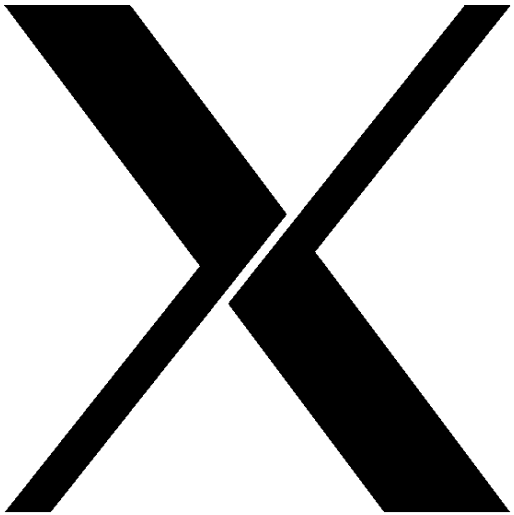

Nesprávný název

X Windows

- Historie – DEC 1983–1986. Hlavní architekt Jim Gettys.
- X Consortium – řídilo další vývoj (pak The Open Group, pak X.org).

Architektura

- X server – proces nebo zařízení, které zobrazuje okna. XF86_SVGA, XSun.
- X klient – aplikace, která vyžaduje zobrazování. `xterm`.
- Spojení – socket (nezávislé na nižší vrstvě).
- X protokol – odděluje server a klienta.
- Extenze protokolu – pro speciální případy. Mit-SHM, XKB, Shape.

X Server

- Poslouchá na socketech, obsluhuje klienty.
- Implementace – proces, X terminál.
- Display – X server.
- Screen – obrazovka.
- Pojmenování – `[`*stroj*`]:`*displej*`[.`*obrazovka*`]`
- Příklad – `:0`, `aisa:12.0`, `unix:0.0`.
- Klient – proměnná `DISPLAY`, přepínač `-display`.
- Informace – `xdpyinfo`.
- Autentizace klienta.
- X Klient – obvykle se zobrazuje na jednom displeji.
- xrandr – nastavení obrazovek a jejich rozlišení.

Okna

- Hierarchie – strom v rámci obrazovky (kořenové okno, podokna).
- Oříznutí potomků na velikost rodiče.
- Visual – způsob zobrazení.
- Další atributy – pozadí, barva popředí, okraj, kurzor, gravitace, maska událostí.
- Obsah okna – nemusí být uchováván.
- Saveunder – pro pop-up menu.

Kurzory

- Okno – svůj typ kurzoru.
- Bitmapy – tvar a vzhled.
- Kurzorový font – předdefinované kurzory.
- Extenze – barevné, poloprůhledné a animované kurzory.
- Focus – on-click, enter-exit.

Příklad: Kurzorový font

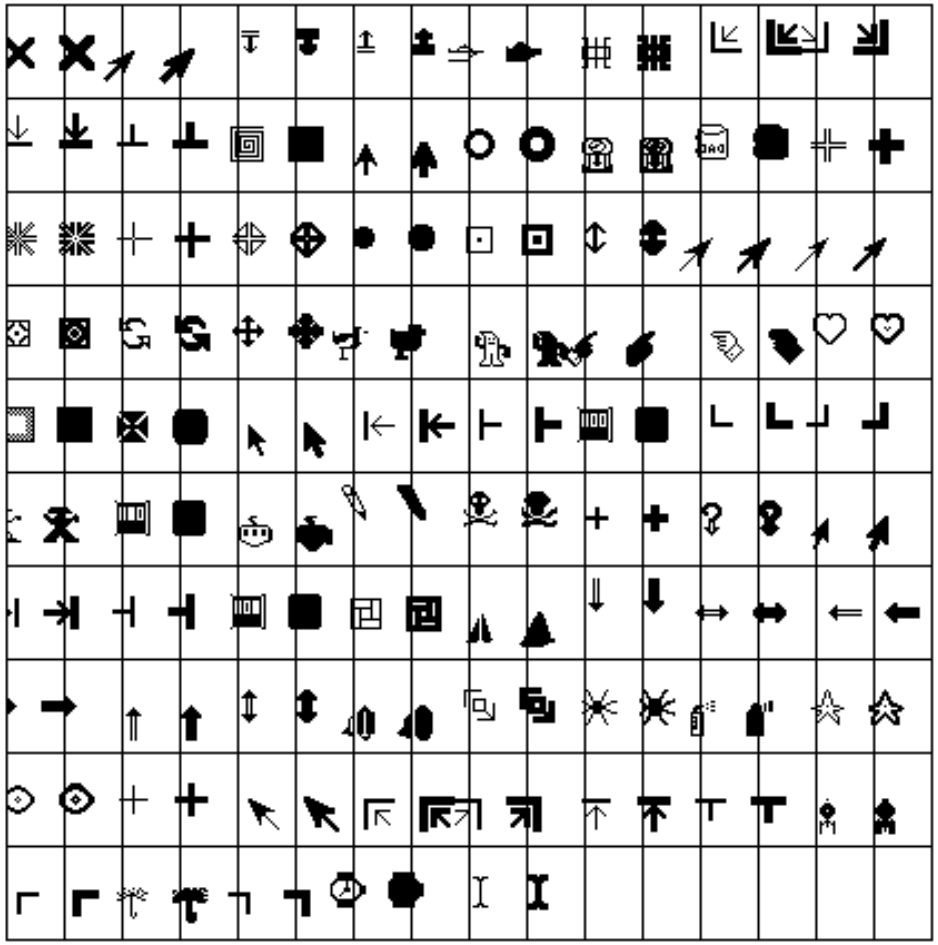

Barvy

- RGB
- Pojmenování – `showrgb`.
- Konverze mezi barevnými prostory.
- Barevné palety (colormap) – každé okno může mít svoji, přepne se při fokusu.

Serverové fonty (starší)

- Typy – bitmapové, vektorové.
- Uložení – u X serveru, font server.
- Adresa font serveru – `tcp/aisa:7100`.
- Nastavení – příkaz `xset`.
- XLFD – řetězec, popisující font.
- Příkazy – `xlsfonts`, `fslsfonts`, `xfontsel`.

Příklad: XLFD název fontu

```
-b&h-lucidatypewriter-medium-r-normal-sans-\
    24-240-75-75-m-140-iso8859-1
```

Klientské fonty (novější)

- Balík `fontconfig`.
- Uživatelský adresář `~/.fonts`.
- Příkazy `fc-list(1)`, `fc-cache(1)`.

Příklad: Výpis `fc-list : family`

```
DejaVu LGC Sans Mono
DejaVu LGC Serif
Century Schoolbook L
MiscFixed
Luxi Sans
Luxi Mono
```

Obrázky

- Pixmap, Bitmap
- Datové formáty – XPM, XBM.
- Uložení – na X serveru.
- Obsah – uchováván X serverem.
- Okno, bitmapa nebo pixmapa = *drawable*.

Události

- Význam – informace o změně stavu.
- Atributy – čas, okno, souřadnice, případně další.
- Typy – stisk klávesy, pohyb myši, změna geometrie okna, změna mapování okna, změna viditelnosti, žádost o překreslení a další.
- xev(1)

Window manager

- Správce oken
- Dekorace oken – potomků kořenového okna.
- Komunikace – seznam vlastností (properties) okna.
- Spravovaná okna – přímí potomci kořenového okna.

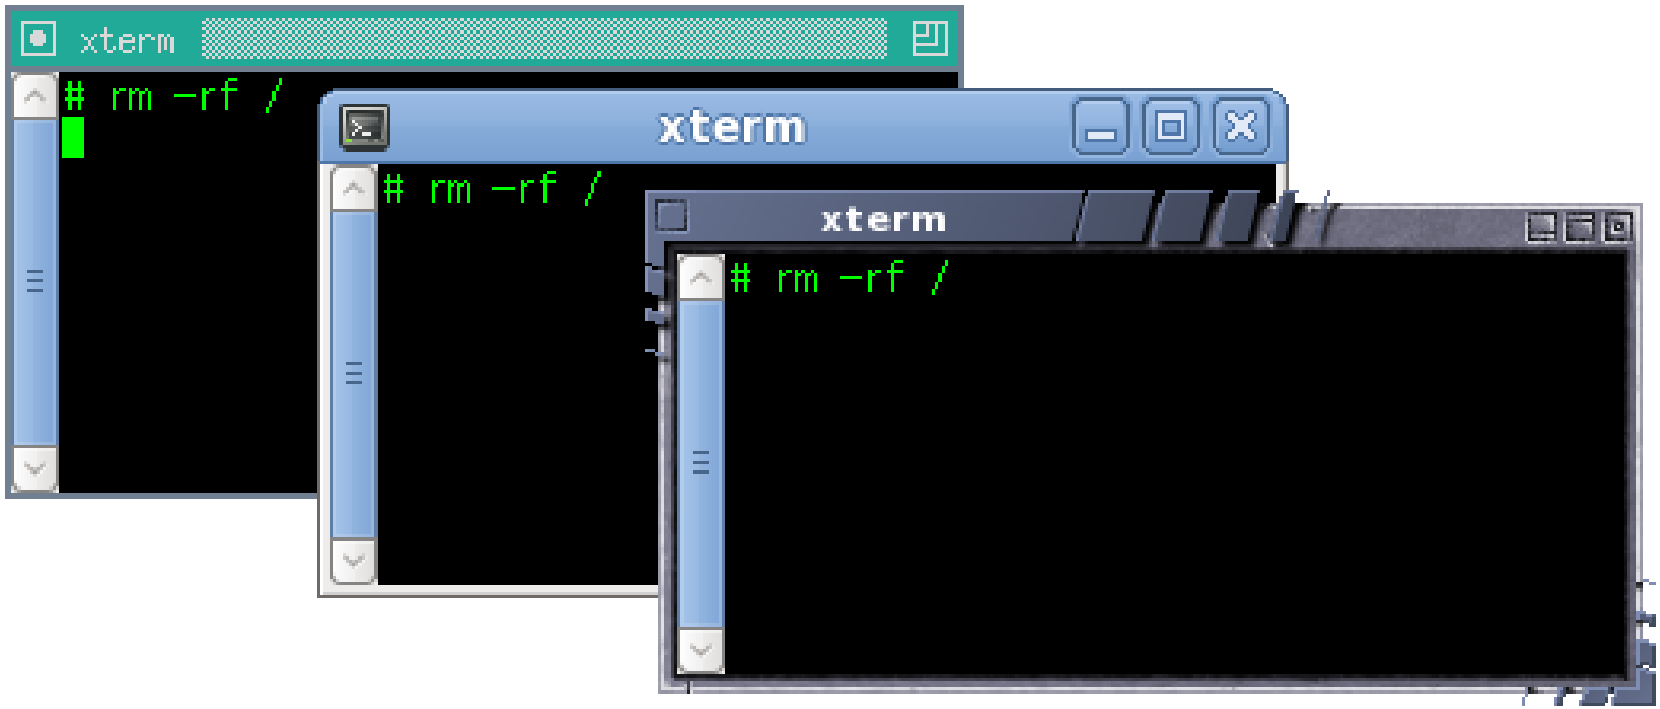

Programování

- X protokol
- Xlib – v podstatě C rozhraní k X protokolu.
- XCB – novější lehčí náhrada Xlib.
- Toolkity – knihovny objektů. Xt, Xaw, Motif, Gtk+, Qt, XForms, Tk.
- Desktopová prostředí – aplikace a knihovny, postavené nad nějakým toolkitem (GNOME, KDE, CDE, XFCE).

Spuštění X

- Z konzoly – `startx`, `xinit`.
- Startovací skripty – `~/.xinitrc`.
- Přihlášení do grafického prostředí – Display manager (`xdm`, `gdm`, `kdm`).
- XDMCP – komunikace mezi X serverem a display managerem.
- Startovací skripty – `~/.xsession`.

Syslog

- Démon `syslogd(8)`.
- Zpracovává hlášení o událostech.
- Socket `/dev/log` (`AF_UNIX`, `SOCK_DGRAM`).
- Typ zprávy (facility): `kern`, `user`, `mail`, `daemon`, `auth`, `syslog`, `lpr`, `news`, `uucp`, `cron`, `authpriv`, `local0` – `local7`.
- Priorita zprávy (priority): `emerg`, `alert`, `crit`, `err`, `warning`, `notice`, `info`, `debug`.

Příklad: Zprávy v syslogu

```
Mar 11 20:16:42 yurika ntpd[1314]: \
    synchronized to 147.251.48.140, stratum 2
Mar 11 20:20:55 yurika ntpd[1314]: \
    time reset -2.348625 s
```

Syslog

- Démon `syslogd(8)`.
- Zpracovává hlášení o událostech.
- Socket `/dev/log` (`AF_UNIX`, `SOCK_DGRAM`).
- Typ zprávy (facility): `kern`, `user`, `mail`, `daemon`, `auth`, `syslog`, `lpr`, `news`, `uucp`, `cron`, `authpriv`, `local0` – `local7`.
- Priorita zprávy (priority): `emerg`, `alert`, `crit`, `err`, `warning`, `notice`, `info`, `debug`.

Příklad: Zprávy v syslogu

```
Mar 11 20:16:42 yurika ntpd[1314]: \
    synchronized to 147.251.48.140, stratum 2
Mar 11 20:20:55 yurika ntpd[1314]: \
    time reset -2.348625 s
```

Syslog z programu v C – I.

openlog(3) Otevření systémového logu

```
#include <syslog.h>
void openlog(char *id, int option, int facility);
```

- Řetězec `id` je připojen před každou zprávou.
- Parametr `option` je logický součet z následujících konstant:

`LOG_CONS` – pokud se nepodaří odeslat zprávu, píše přímo na systémovou konzolu.

`LOG_NDELAY` – otevřít spojení ihned (jinak až při první zprávě).

`LOG_PERROR` – psát také na `stderr`.

`LOG_PID` – do zprávy zahrnout PID procesu.

Syslog z programu v C – II.

closelog(3) — Uzavření logu

```
#include <syslog.h>
void closelog();
```

Ukončí zasílání zpráv (uvolní deskriptor).

syslog(3) — Zápis zprávy do logu

```
#include <syslog.h>
void syslog(int priority, char *fmt, ...);
```

Řetězec `fmt` má podobný význam jako v `printf(3)`.

Syslog z programu v C – II.

closelog(3) Uzavření logu

```
#include <syslog.h>
void closelog();
```

Ukončí zasílání zpráv (uvolní deskriptor).

syslog(3) Zápis zprávy do logu

```
#include <syslog.h>
void syslog(int priority, char *fmt, ...);
```

Řetězec `fmt` má podobný význam jako v `printf(3)`.

Syslog z příkazové řádky

logger(1) — Zápis do syslogu

```
$ logger [-is] [-p pri] [message ...]
```

Příklad: logger(1)

```
$ logger -p lpr.notice -i Printer lp0 on fire!
```

Konfigurace syslogu

- Konfigurace – `/etc/syslog.conf`.
- Syntaxe: *typ/priorita zprávy tabulátor soubor*.

Poslední položka se rozlišuje podle prvního znaku:

- `/` – běžný soubor
- `-` – totéž, nevolá se `fsync(2)`.
- `|` – logování rourou do programu.
- `*` – všem nalogovaným uživatelům.
- `@` – logování po síti na jiný stroj.
- *ostatní* – seznam uživatelů.

Příklad: /etc/syslog.conf

```
kern.*                                  /dev/console
*.info;mail.none;authpriv.none \
                                        /var/log/messages
authpriv.*                              /var/log/secure
mail.*                                  /var/log/maillog
*.emerg                                 *
uucp,news.crit                          /var/log/spooler
#*.debug                                -/var/log/debug
local0.info                             /var/log/ppp
local2.=info                            |/usr/bin/log-parser
*.notice                                @loghost.domena.cz
```

Syslog – alternativy

- Společné vlastnosti – stejné rozhraní pro C, stejný síťový protokol.

rsyslog

- Modulární
- Vstupní moduly – socket, kernel , TCP, ...
- Výstupní moduly – např. MySQL.
- Filtrovací pravidla
- Zpětně kompatibilní `syslog.conf(5)`.

syslog-ng

- Podepisované zprávy, časová razítka.
- Šifrovaný přenos zpráv (TLS).
- Filtrovací a třídící pravidla.

Syslog – alternativy

- Společné vlastnosti – stejné rozhraní pro C, stejný síťový protokol.

rsyslog

- Modulární
- Vstupní moduly – socket, kernel  , TCP, ...
- Výstupní moduly – např. MySQL.
- Filtrovací pravidla
- Zpětně kompatibilní `syslog.conf(5)`.

syslog-ng

- Podepisované zprávy, časová razítka.
- Šifrovaný přenos zpráv (TLS).
- Filtrovací a třídící pravidla.

Syslog – alternativy

- Společné vlastnosti – stejné rozhraní pro C, stejný síťový protokol.

rsyslog

- Modulární
- Vstupní moduly – socket, kernel  , TCP, ...
- Výstupní moduly – např. MySQL.
- Filtrovací pravidla
- Zpětně kompatibilní `syslog.conf(5)`.

syslog-ng

- Podepisované zprávy, časová razítka.
- Šifrovaný přenos zpráv (TLS).
- Filtrovací a třídící pravidla.

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Journal

- Logovací subsystém v `systemd`.
- Indexované ukládání zpráv.
- Rozšířená množina metadat.
- Důvěryhodné atributy.
- Ochrana před manipulováním logu.
- Viz též `journalctl(8)`, `sd_journal_print(3)`.

Čtení na dobrou noc

http://0pointer.de/blog/projects/the-journal.html

Příklad: Journal – atributy zprávy

```
_SERVICE=systemd-logind.service
MESSAGE=User ayanami logged in
MESSAGE_ID=422bc3d271414bc8bc9570f222f24a9
_EXE=/lib/systemd/systemd-logind
_COMM=systemd-logind
_CMDLINE=/lib/systemd/systemd-logind
_PID=1999 _UID=0 _GID=0
_SYSTEMD_CGROUP=/system/systemd-logind.service
_CGROUPS=cpu:/system/systemd-logind.service
PRIORITY=6
_BOOT_ID=422bc3d271414bc8bc95870f222f24a9
_MACHINE_ID=c686f3b205dd48e0b43ceb6eda479721
_HOSTNAME=eva00.nerv.gov.jp
LOGIN_USER=2014
```

Odstraňování chyb

[...] phenomena like heisenbugs (errors that vanish when you try to debug them), schrödingbugs (errors that manifest only when you're trying to debug something else), and mandelbugs (complex errors that seem to fluctuate more and more chaotically, the closer you look at them).
[...] If there's anything less enjoyable than beating your head against a bug for several hours, it's finally discovering that your debugging print statement was itself buggy, and the problem isn't anywhere near where you thought it was. This is presumably a Homerbug.

–Damian Conway: Perl Best Practices

Odstraňování chyb

- Modularita UNIXu – zjednodušuje určení místa výskytu problému.
- Kde chyba vzniká? – najít konkrétní program/knihovnu.
- Čas přístupu k souboru (ale: pozor na `noatime`/`relatime`).

- Spouští se vůbec tento program?
- Načítá se vůbec tento konfigurační soubor?

Odstraňování chyb

- Modularita UNIXu – zjednodušuje určení místa výskytu problému.
- Kde chyba vzniká? – najít konkrétní program/knihovnu.
- Čas přístupu k souboru (ale: pozor na `noatime`/`relatime`).

- Spouští se vůbec tento program?
- Načítá se vůbec tento konfigurační soubor?

Odstraňování chyb

- Modularita UNIXu – zjednodušuje určení místa výskytu problému.
- Kde chyba vzniká? – najít konkrétní program/knihovnu.
- Čas přístupu k souboru (ale: pozor na `noatime/relatime`).

- Spouští se vůbec tento program?
- Načítá se vůbec tento konfigurační soubor?

Odstraňování chyb

- Modularita UNIXu – zjednodušuje určení místa výskytu problému.
- Kde chyba vzniká? – najít konkrétní program/knihovnu.
- Čas přístupu k souboru (ale: pozor na `noatime`/`relatime`).

- Spouští se vůbec tento program?
- Načítá se vůbec tento konfigurační soubor?

Chybová hlášení

- Zjistit, co chybové hlášení znamená
- Není-li to jasné – přečíst dokumentaci, případně zdrojové texty programu.
- Pokud není chybové hlášení – zjistit, do kterého logovacího souboru se zapisuje.
- Vyžádat si podrobnější informace – zapnout podrobné výpisy v konfiguračním souboru nebo na příkazové řádce.
- Zachytit podrobnější informace – zapnout sledování zpráv priority debug v `syslog.conf`.

Chybová hlášení

- Zjistit, co chybové hlášení znamená
- Není-li to jasné – přečíst dokumentaci, případně zdrojové texty programu.
- Pokud není chybové hlášení – zjistit, do kterého logovacího souboru se zapisuje.
- Vyžádat si podrobnější informace – zapnout podrobné výpisy v konfiguračním souboru nebo na příkazové řádce.
- Zachytit podrobnější informace – zapnout sledování zpráv priority debug v `syslog.conf`.

Chybová hlášení

- Zjistit, co chybové hlášení znamená
- Není-li to jasné – přečíst dokumentaci, případně zdrojové texty programu.
- Pokud není chybové hlášení – zjistit, do kterého logovacího souboru se zapisuje.
- Vyžádat si podrobnější informace – zapnout podrobné výpisy v konfiguračním souboru nebo na příkazové řádce.
- Zachytit podrobnější informace – zapnout sledování zpráv priority debug v `syslog.conf`.

Sledování procesu

- Služby jádra, které proces postupně vykonává.
- `strace(1)` – Linux a další systémy 
- `par(1)` – IRIX 
- `truss(1)` – Solaris/SunOS 
- Zjištění chyby služby jádra, která vedla k ukončení procesu.
- Podobné nástroje – `ltrace(1)`, `valgrind(1)`.

Trace toolkits

- Sledování systému jako celku.
- Na živém produkčním systému.
- Nemělo by ovlivnit systém (ale heisenbugs).
- Nemělo by zpomalit systém, není-li zapnuto.

Příklady:

- DTrace
- SystemTap
- BPFTrace, BCC

Trace toolkits

- Sledování systému jako celku.
- Na živém produkčním systému.
- Nemělo by ovlivnit systém (ale heisenbugs).
- Nemělo by zpomalit systém, není-li zapnuto.

Příklady:

- DTrace  
- SystemTap 
- BPFTrace, BCC 

Sondy

- Sonda (probe) – místo v programu, které lze sledovat (např. vstup do jisté funkce).
- Atributy – např. parametry funkce, PID procesu, ...
- Implementace – prázdné instrukce, v případě potřeby se doplní odskok na ladící kód.
- Dynamické sondy – umístit odskok kamkoli do kódu.

Sondy

- Sonda (probe) – místo v programu, které lze sledovat (např. vstup do jisté funkce).
- Atributy – např. parametry funkce, PID procesu, ...
- Implementace – prázdné instrukce, v případě potřeby se doplní odskok na ladící kód.
- Dynamické sondy – umístit odskok kamkoli do kódu.

Trasovací nástroje v Linuxu

- Statické, předdefinované
  - Definované člověkem
  - Stabilnější v čase
  - Možnost vyšší úrovně abstrakce (TCP spojení, SQL příkaz)
  - Linux kernel: tracepoints (ftrace)
  - Linux userland: USDT probes, kompatibilní s DTrace probes
- Dynamické
  - Složitější (co když instrukci zrovna někdo vykonává?)
  - Linux kernel: kprobes
  - Linux userland: uprobes

Trasovací nástroje v Linuxu

- Statické, předdefinované
  - Definované člověkem
  - Stabilnější v čase
  - Možnost vyšší úrovně abstrakce (TCP spojení, SQL příkaz)
  - Linux kernel: tracepoints (ftrace)
  - Linux userland: USDT probes, kompatibilní s DTrace probes
- Dynamické
  - Složitější (co když instrukci zrovna někdo vykonává?)
  - Linux kernel: kprobes
  - Linux userland: uprobes

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Berkeley Packet Filter


- Původně nástroj pro urychlení `tcpdump(8)`, `pcap(3)`

- Bytekód pro spuštění uvnitř jádra
- Není turingovsky kompletní
- Verifikovatelný; nelze zacyklit
- Ukládání dat do asociativních polí
  - Histogramy, per-proces statistiky, ...
- JIT kompilace v kernelu
- Linux eBPF: nástroj na vymístění politiky z jádra
  - Alternativní přístupová práva
  - Bezpečnostní moduly
  - Programy pro trasování
  - ... (programování Linuxu v BPF ^_~)

Programovací jazyky pro trasování

- Popis toho, co chceme sledovat.
- DTrace – jazyk D, podobný AWK.
- Kompilace do mezikódu.
- Jádro kontroluje korektnost.
- bpf-tools – nad BCC.
  - Kód v Pythonu + C
  - Relativně komplikované
- `bpftrace(8)`  : kompilace do eBPF
  - Jazyk podobný D-Trace (a AWK)
  - Název sondy, podmínka, programový kód

Příklad: BPF-Tools

```
# /usr/share/bcc/tools/tcpconnect
# /usr/share/bcc/tools/hardirqs
# /usr/share/bcc/tools/perlcalls
```

BPFTrace

Příklad: Velikost read(2)

```
kr:vfs_read { @ = hist(retval); }
```

Příklad: Doba trvání read(2)

```
kprobe:vfs_read { @start[tid] = nsecs; }
kretprobe:vfs_read /@start[tid]/ {
   @ns[comm] = hist(nsecs - @start[tid]);
   delete(@start[tid]);
}
```

Příklad: Volání readline(3)

```
uretprobe:bash:readline {
   printf("%s\n", str(retval))
}
```

BPFTrace

Příklad: Velikost read(2)

```
kr:vfs_read { @ = hist(retval); }
```

Příklad: Doba trvání read(2)

```
kprobe:vfs_read { @start[tid] = nsecs; }
kretprobe:vfs_read /@start[tid]/ {
   @ns[comm] = hist(nsecs - @start[tid]);
   delete(@start[tid]);
}
```

Příklad: Volání readline(3)

```
uretprobe:bash:readline {
   printf("%s\n", str(retval))
}
```

BPFTrace

Příklad: Velikost read(2)

```
kr:vfs_read { @ = hist(retval); }
```

Příklad: Doba trvání read(2)

```
kprobe:vfs_read { @start[tid] = nsecs; }
kretprobe:vfs_read /@start[tid]/ {
   @ns[comm] = hist(nsecs - @start[tid]);
   delete(@start[tid]);
}
```

Příklad: Volání readline(3)

```
uretprobe:bash:readline {
   printf("%s\n", str(retval))
}
```

Trasování: další odkazy

- http://www.brendangregg.com/linuxperf.html
- https://www.youtube.com/watch?v=16slh29iN1g
- https://github.com/mmisono/bpftrace-tetris

Dobrá rada na závěr

Rada nad zlato :–)

Po nějaké době řešení problému je dobré si znovu přečíst chybové hlášení a dokumentaci.

Cron

- Vykonávání prací v zadaném čase.
- Úlohy běží pod UID/GID toho, kdo tuto úlohu požadoval.
- Standardní výstup a chybový výstup je zaslán uživateli e-mailem.
- Typy úloh: jednorázové, pravidelné, dávkové.
- Implementace: `vixie-cron`  , `cronie`  .

Cron – pravidelné úlohy

crontab(1) Pravidelně vykonávané úlohy

```
$ crontab [-u user] soubor.crontab
$ crontab [-u user] [-l|-r|-e]
```

- `-l` vypíše tabulku.
- `-e` editace ($EDITOR, $VISUAL).
- `-r` smaže tabulku.

`-u login` – nastavení pro jiného uživatele.

bez parametru – bere tabulku ze std. vstupu.

Formát crontabulky

Příklad: řádek crontabulky

```
SHELL=/bin/bash
PATH=/sbin:/bin:/usr/sbin:/usr/bin
MAILTO=root
HOME=/
*/5 8-16 * * 1-5   /usr/bin/kdo-zrovna-pracuje
2,22,42 * * * *    /usr/local/bin/20mins
```

- Položky – minuta, hodina, den v měsíci, měsíc, den v týdnu, příkaz + argumenty.
- Logický součin podmínek.
- Pokud den v měsíci a v týdnu není *, bere se jejich logický součet.

Systémové pravidelné úlohy

- „Rozumné“ periody (jak často, nikoliv kdy přesně):
  - `/etc/cron.hourly`
  - `/etc/cron.daily`
  - `/etc/cron.weekly`
  - `/etc/cron.monthly`
- `run-parts(1)` – spouštění všech skriptů v adresáři.
- Crontabulky systémovych služeb: `/etc/cron.d`
  - Navíc identifikace uživatele.
- Někdy také `/etc/crontab`.

Příklad: `/etc/cron.d/0hourly`

```
PATH=/sbin:/bin:/usr/sbin:/usr/bin
MAILTO=root
01 * * * * root run-parts /etc/cron.hourly
```

Systémové pravidelné úlohy

- „Rozumné“ periody (jak často, nikoliv kdy přesně):
  - `/etc/cron.hourly`
  - `/etc/cron.daily`
  - `/etc/cron.weekly`
  - `/etc/cron.monthly`
- `run-parts(1)` – spouštění všech skriptů v adresáři.
- Crontabulky systémovych služeb: `/etc/cron.d`
  - Navíc identifikace uživatele.
- Někdy také `/etc/crontab`.

Příklad: /etc/cron.d/0hourly

```
PATH=/sbin:/bin:/usr/sbin:/usr/bin
MAILTO=root
01 * * * * root run-parts /etc/cron.hourly
```

Systémové pravidelné úlohy

- „Rozumné“ periody (jak často, nikoliv kdy přesně):
  - `/etc/cron.hourly`
  - `/etc/cron.daily`
  - `/etc/cron.weekly`
  - `/etc/cron.monthly`
- `run-parts(1)` – spouštění všech skriptů v adresáři.
- Crontabulky systémovych služeb: `/etc/cron.d`
  - Navíc identifikace uživatele.
- Někdy také `/etc/crontab`.

Příklad: /etc/cron.d/0hourly

```
PATH=/sbin:/bin:/usr/sbin:/usr/bin
MAILTO=root
01 * * * * root run-parts /etc/cron.hourly
```

Anacron

Problémy nočních úloh:

- Co dělat, když je počítač přes noc vypnutý?
- Jak nevyčerpat baterii laptopu?
- Jak nepřetížit virtualizační server?

- `anacron(8)` – pravidelné úlohy s denní a delší periodou.
- `/etc/anacrontab`
- Časové razítko každé úlohy.

Anacron

Problémy nočních úloh:

- Co dělat, když je počítač přes noc vypnutý?
- Jak nevyčerpat baterii laptopu?
- Jak nepřetížit virtualizační server?

- `anacron(8)` – pravidelné úlohy s denní a delší periodou.
- `/etc/anacrontab`
- Časové razítko každé úlohy.

Anacron

Problémy nočních úloh:

- Co dělat, když je počítač přes noc vypnutý?
- Jak nevyčerpat baterii laptopu?
- Jak nepřetížit virtualizační server?

- `anacron(8)` – pravidelné úlohy s denní a delší periodou.
- `/etc/anacrontab`
- Časové razítko každé úlohy.

Anacron

Problémy nočních úloh:

- Co dělat, když je počítač přes noc vypnutý?
- Jak nevyčerpat baterii laptopu?
- Jak nepřetížit virtualizační server?

- `anacron(8)` – pravidelné úlohy s denní a delší periodou.
- `/etc/anacrontab`
- Časové razítko každé úlohy.

Příklad: /etc/anacrontab

```
RANDOM_DELAY=45
START_HOURS_RANGE=3-22

# period[days] delay[mins] job-id command
1             5   cron.daily   nice run-parts \
                                /etc/cron.daily
7            25   cron.weekly  nice run-parts \
                                /etc/cron.weekly
@monthly     45   cron.monthly nice run-parts \
                                /etc/cron.monthly
```

Otázka:

K čemu je omezení pomocí START_HOURS_RANGE?

Příklad: /etc/anacrontab

```
RANDOM_DELAY=45
START_HOURS_RANGE=3-22

# period[days] delay[mins] job-id command
1             5   cron.daily   nice run-parts \
                                /etc/cron.daily
7            25   cron.weekly  nice run-parts \
                                /etc/cron.weekly
@monthly     45   cron.monthly nice run-parts \
                                /etc/cron.monthly
```

Otázka:

K čemu je omezení pomocí START_HOURS_RANGE?

Jednorázové úlohy

- `at(1)` – vykonání práce v zadaném čase.
  - Pamatuje si proměnné prostředí.
- `atq(1)` – výpis fronty příkazů `at(1)`.
- `atrm(1)` – smazání úlohy z fronty.
- `batch(1)` – odložené vykonávání (např. až load average klesne pod 1).

Dávkové zpracování

Lépe použít samostatné dávkové frontové systémy.

- Implementace – `crond(8)` nebo samostatný `atd(8)`.

Recyklace logovacích souborů

- Problém – logovací soubory mohou zaplnit disk.
- Rotování logovacích souborů – přejmenování, komprese, zachovat několik posledních.
- Notifikace zapisujícímu procesu (např. SIGHUP pro `syslogd(8)`).

`logrotate(8)`

```
# logrotate soubor
# logrotate /etc/logrotate.conf
```

- Spouštět například z `/etc/cron.daily`.

Recyklace logovacích souborů

- Problém – logovací soubory mohou zaplnit disk.
- Rotování logovacích souborů – přejmenování, komprese, zachovat několik posledních.
- Notifikace zapisujícímu procesu (např. SIGHUP pro `syslogd(8)`).

`logrotate(8)`

```
# logrotate soubor
# logrotate /etc/logrotate.conf
```

- Spouštět například z `/etc/cron.daily`.

Příklad: /etc/logrotate.conf

```
weekly
rotate 4
create
dateext
compress

include /etc/logrotate.d

/var/log/wtmp {
    monthly
    create 0664 root utmp
        minsize 1M
    rotate 1
}
```

Příklad: /etc/logrotate.d/syslog

```
/var/log/messages /var/log/secure \
        /var/log/maillog /var/log/spooler \
        /var/log/boot.log /var/log/cron {
    sharedscripts
    postrotate
        /bin/kill -HUP \
            ‘cat /var/run/syslogd.pid‘
    endscript
}
```

Otázka:

Jaký problém by způsobilo uvedení cesty ve tvaru „/var/log/*“?

Příklad: /etc/logrotate.d/syslog

```
/var/log/messages /var/log/secure \
        /var/log/maillog /var/log/spooler \
        /var/log/boot.log /var/log/cron {
    sharedscripts
    postrotate
        /bin/kill -HUP \
            ‘cat /var/run/syslogd.pid‘
    endscript
}
```

Otázka:

Jaký problém by způsobilo uvedení cesty ve tvaru „/var/log/*“?

Promazávání dočasných souborů

- Možnost přeplnění `/tmp`.
- Pozor na symbolické linky!

tmpwatch(8)

```
# tmpwatch [-u|-m|-c] [-x soubor] [-X glob] \
    [-f] čas adresář
```

Příklad: /etc/cron.daily/tmpwatch

```
/usr/sbin/tmpwatch -umc -x /tmp/.X11-unix \
    -x /tmp/.XIM-unix  -x /tmp/.font-unix \
    -x /tmp/.ICE-unix  -x /tmp/.Test-unix \
    -X '/tmp/hsperfdata_*' 10d /tmp
/usr/sbin/tmpwatch -umc 30d /var/tmp
```

Promazávání dočasných souborů

- Možnost přeplnění /tmp.
- Pozor na symbolické linky!

tmpwatch(8)

```
# tmpwatch [-u|-m|-c] [-x soubor] [-X glob] \
    [-f] čas adresář
```

Příklad: /etc/cron.daily/tmpwatch

```
/usr/sbin/tmpwatch -umc -x /tmp/.X11-unix \
    -x /tmp/.XIM-unix  -x /tmp/.font-unix \
    -x /tmp/.ICE-unix  -x /tmp/.Test-unix \
    -X '/tmp/hsperfdata_*' 10d /tmp
/usr/sbin/tmpwatch -umc 30d /var/tmp
```

Tiskárny

- Spooling – tisková fronta.
- Více front na jednu tiskárnu (např. oboustranný tisk).
- Filtry – konverze do jazyka tiskárny.

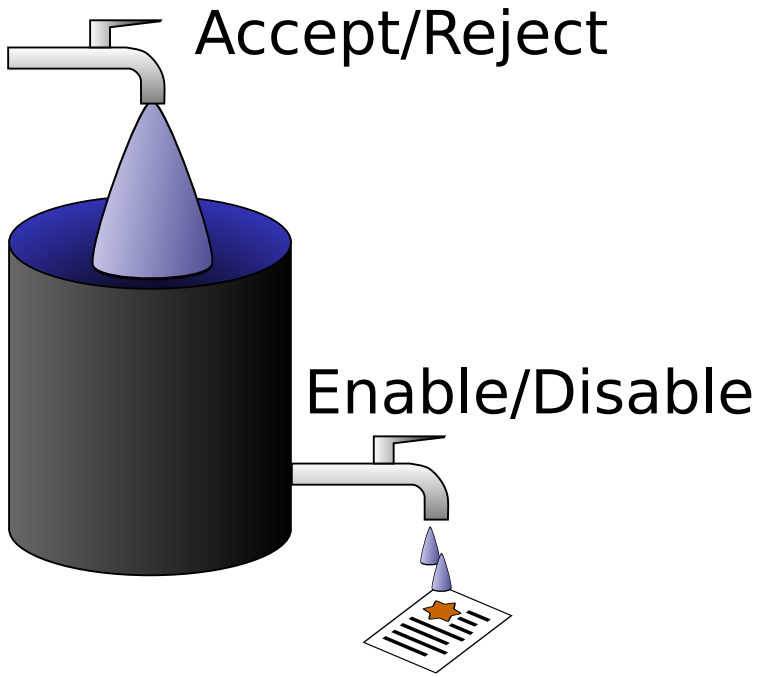

BSD tiskový subsystém

- Konfigurace: `/etc/printcap`.
- Server: `lpd(8)`, `/etc/hosts.lpd`.
- Filtry: vstupní, datový, výstupní.
- Řízení – příkaz `lpc(8)`.
- Uživatelé: `lpr(1)`, `lpq(1)`, `lprm(1)`.

Příklad: /etc/printcap

```
dj|lp|HP DeskJet 540 – raw device:\
    :sd=/var/spool/lpd/dj:\
    :sh:\
    :sf:\
    :mx#10000:\
    :lf=/var/log/lpd-errs:\
    :pl#60:\
    :lp=/dev/lp1:
```

nebo

```
    :rm=geofront.nervhq.com:\
    :rp=lj4:
```

System V Tiskárny

- Démon `lpsched(8)`.
- Administrace: `lpadmin(8)`, `lpshut(8)`.
- Řízení přístupu – `accept(8)`, `reject(8)`, `enable(8)`, `disable(8)`.
- `lpmove(8)`.
- Uživatelé: `lp(1)`, `cancel(1)`, `lpstat(1)`.

Common UNIX Printing System

- Nový síťový protokol (nad HTTP, port 631).
- Administrace – WWW rozhraní.
- Rozšiřitelné atributy tiskáren:
  - duplex
  - ekonomický režim
  - zásobníky papíru
- Autokonfigurace klientů – nemusí být tiskové fronty i na klientech.
- Popis tiskárny – soubor PPD. Obsahuje PostScriptové příkazy pro příslušné atributy.

Diskové kvóty

- Sledování místa, obsazeného uživatelem.
- V rámci jednoho svazku.
- Kvóta na počet i-uzlů a bloků.
- Měkká/tvrdá kvóta.
- Časový limit.
- Soubor `/quota`, `/quota.user`, `/quota.group` nebo přímo v metadatech FS.

Získání informací o kvótách

quota(1)

```
$ quota [-v] [-u user]
```

- `-v` – informace o všech kvótách (jinak jen o překročených).
- `-u` – jen superuživatel.

Příklad: Formát výpisu kvót

```
#  quota -v -u fordprefect
Disk quotas for user fordprefect (uid 42):
Filesystem  blocks    quota    limit grace \
/theguide  8570400 10000000 12000000       \
             files    quota    limit grace
             66980   180000   200000
```

Získání informací o kvótách

quota(1)

```
$ quota [-v] [-u user]
```

- `-v` – informace o všech kvótách (jinak jen o překročených).
- `-u` – jen superuživatel.

Příklad: Formát výpisu kvót

```
#  quota -v -u fordprefect
Disk quotas for user fordprefect (uid 42):
Filesystem  blocks    quota    limit grace \
/theguide  8570400 10000000 12000000       \
             files    quota    limit grace
             66980   180000   200000
```

Kvóty – administrace

quotaon(8) Administrace kvót

```
# quotaon [-a] [filesystem]
# quotaoff [-a] [filesystem]
# quotacheck [-a] [filesystem]
```

Konzistence kvót

Je-li souborový systém používán s vypnutými kvótami, je nutné před víceuživatelským použitím znovu přepočítat obsazení disku.

Nastavení kvót uživatelům

edquota(8) — Editace kvót

```
# edquota uživatel ...
# edquota [-p vzor] uživatel ...
```

setquota(8) — Nastavení kvót

```
# setquota [-u|g] uživatel \
    block-soft block-hard \
    inode-soft inode-hard \
    -a|filesystem
# setquota -t \
    block-grace inode-grace \
    -a|filesystem
# setquota -b -a|filesystem
```

Nastavení kvót uživatelům

edquota(8) — Editace kvót

```
# edquota uživatel ...
# edquota [-p vzor] uživatel ...
```

setquota(8) — Nastavení kvót

```
# setquota [-u|g] uživatel \
    block-soft block-hard \
    inode-soft inode-hard \
    -a|filesystem
# setquota -t \
    block-grace inode-grace \
    -a|filesystem
# setquota -b -a|filesystem
```

Hlášení překročených kvót

repquota(8), warnquota(8)

```
# repquota -a|filesystem
# warnquota [-c configfile]
```

Příklad: repquota(8)

```
*** Report for user quotas on device /theguide
Block grace time: 7days; Inode grace time: 7days
                        Block limits                ...
User            used    soft    hard grace          ...
----------------------------------------------------...
root      --  443708       0       0                ...
zaphod    +-  217614  200000  300000  none          ...
fordprefect --  61028  500000  600000                ...
arthurdent  +-  175334  150000  180000 5days        ...
```

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Virtualizace

Co je virtualizace?

- Zapouzdření SW
  - bez vyhrazeného HW
  - procesu, aplikace, celého OS
  - hypervizor/hostitel: poskytuje virtuální HW
  - host (ang. guest), instance, virtuální stroj: klient
- Virtualizace je také
  - UNIXový proces
  - `chroot(2)`
  - `jail(2)`
  - SELinux sandbox

Co virtualizujeme?

- Virtualizace OS
- Virtualizace CPU
- Virtualizace RAM
- Virtualizace periferií

Upozornění:

UNIX je vlastně také virtualizační prostředí!

Co virtualizujeme?

- Virtualizace OS
- Virtualizace CPU
- Virtualizace RAM
- Virtualizace periferií

⚠ Upozornění:

UNIX je vlastně také virtualizační prostředí!

Emulace

- Interpretace instrukcí virtuálním procesorem
- JIT kompilace
- Interpretace I/O příkazů hardwaru
- Cíl: virtualizovat HW, který nemám

Nativní virtualizace

- Přímé spouštění nativních instrukcí
- Musí podporovat HW
- Vnořená virtualizace?
  - IBM VM/OS, cca 1970

Paravirtualizace

- Přizpůsobení virtualizovaného SW
- Např. samostatná CPU platforma
- Jiné operace pro změnu mapování stránek, přerušení, ...
- Paravirtualizované periferie

Otázka:

Který typ virtualizace je nejrychlejší?

Paravirtualizace

- Přizpůsobení virtualizovaného SW
- Např. samostatná CPU platforma
- Jiné operace pro změnu mapování stránek, přerušení, ...
- Paravirtualizované periferie

Otázka:

Který typ virtualizace je nejrychlejší?

Virtualizace periferií

- Emulace
  - Zachycování I/O instrukcí
  - Generování virtuálních přerušení
  - Virtuální DMA
- HW virtualizace
  - Síťové karty: samostatné HW fronty
  - Disky: samostatné LUN
  - Hypervizor je jen arbitr
- Paravirtualizace
  - Přizpůsobit komunikaci: SW – SW
  - Virtio
  - VMware tools, ...
  - *Jak si tvůrci OS představují, že by měl HW komunikovat*

Virtualizace periferií

- Emulace
  - Zachycování I/O instrukcí
  - Generování virtuálních přerušení
  - Virtuální DMA
- HW virtualizace
  - Síťové karty: samostatné HW fronty
  - Disky: samostatné LUN
  - Hypervizor je jen arbitr
- Paravirtualizace
  - Přizpůsobit komunikaci: SW – SW
  - Virtio
  - VMware tools, ...
  - *Jak si tvůrci OS představují, že by měl HW komunikovat*

Virtualizace periferií

- Emulace
  - Zachycování I/O instrukcí
  - Generování virtuálních přerušení
  - Virtuální DMA
- HW virtualizace
  - Síťové karty: samostatné HW fronty
  - Disky: samostatné LUN
  - Hypervizor je jen arbitr
- Paravirtualizace
  - Přizpůsobit komunikaci: SW – SW
  - Virtio 
  - VMware tools, ...
  - *Jak si tvůrci OS představují, že by měl HW komunikovat*

Virtualizace v Linuxu

- QEMU
  - emulátor (x86, x86-64, ARM, ARM64, celé PC, ...)
- KVM
  - virtualizace CPU (+ QEMU na virtualizaci celého PC)
  - hypervizor = kernel Linuxu
- XEN
  - původně paravirtualizace
  - nyní i plná virtualizace CPU
  - malý hypervizor
  - Dom0 Linux pro správu většiny HW
  - DomU virtuální stroje
- VirtualBox
  - nativní běh user-space
  - původně emulace a JIT kompilace privilegovaných instrukcí
  - nyní HW virtualizace CPU

Virtualizace v Linuxu

- QEMU
  - emulátor (x86, x86-64, ARM, ARM64, celé PC, ...)
- KVM 
  - virtualizace CPU (+ QEMU na virtualizaci celého PC)
  - hypervizor = kernel Linuxu
- XEN
  - původně paravirtualizace
  - nyní i plná virtualizace CPU
  - malý hypervizor
  - Dom0 Linux pro správu většiny HW
  - DomU virtuální stroje
- VirtualBox
  - nativní běh user-space
  - původně emulace a JIT kompilace privilegovaných instrukcí
  - nyní HW virtualizace CPU

Virtualizace v Linuxu

- QEMU
  - emulátor (x86, x86-64, ARM, ARM64, celé PC, ...)
- KVM 
  - virtualizace CPU (+ QEMU na virtualizaci celého PC)
  - hypervizor = kernel Linuxu
- XEN
  - původně paravirtualizace
  - nyní i plná virtualizace CPU
  - malý hypervizor
  - Dom0 Linux pro správu většiny HW
  - DomU virtuální stroje
- VirtualBox
  - nativní běh user-space
  - původně emulace a JIT kompilace privilegovaných instrukcí
  - nyní HW virtualizace CPU

Virtualizace v Linuxu

- QEMU
  - emulátor (x86, x86-64, ARM, ARM64, celé PC, ...)
- KVM 
  - virtualizace CPU (+ QEMU na virtualizaci celého PC)
  - hypervizor = kernel Linuxu
- XEN
  - původně paravirtualizace
  - nyní i plná virtualizace CPU
  - malý hypervizor
  - Dom0 Linux pro správu většiny HW
  - DomU virtuální stroje
- VirtualBox
  - nativní běh user-space
  - původně emulace a JIT kompilace privilegovaných instrukcí
  - nyní HW virtualizace CPU

Virtualizace disků

- Soubor/blokové zařízení: disk uvnitř VM
- Formáty souborů (image)
  - RAW
    - Například LV
  - QCOW2: thin provisioning, snímky
  - VMDK: z VMware
- Další vlastnosti
  - Někdy možnost uložit i stav RAM
  - Snímek živého OS
  - Migrace na jiný HW: distribuované úložiště?
    - CEPH, GlusterFS, ...

Virtualizace disků

- Soubor/blokové zařízení: disk uvnitř VM
- Formáty souborů (image)
  - RAW
    - Například LV
  - QCOW2: thin provisioning, snímky
  - VMDK: z VMware
- Další vlastnosti
  - Někdy možnost uložit i stav RAM
  - Snímek živého OS
  - Migrace na jiný HW: distribuované úložiště?
    - CEPH, GlusterFS, ...

Virtualizace disků

- Soubor/blokové zařízení: disk uvnitř VM
- Formáty souborů (image)
  - RAW
    - Například LV
  - QCOW2: thin provisioning, snímky
  - VMDK: z VMware
- Další vlastnosti
  - Někdy možnost uložit i stav RAM
  - Snímek živého OS
  - Migrace na jiný HW: distribuované úložiště?
    - CEPH, GlusterFS, ...

Virtualizace sítě

- TUN/TAP device 
- Čtení/zápis řídícího souboru = vysílání/příjem packetů
- Hypervizor překládá I/O operace TUN/TAP souboru
  - virtuální síťová karta
- Připojení VM do sítě
  - TUN/TAP je běžné rozhraní
  - Standardní směrování
  - + NAT
  - Bridge
  - SDN/VXLAN

Virtualizace sítě

- TUN/TAP device 
- Čtení/zápis řídícího souboru = vysílání/příjem packetů
- Hypervizor překládá I/O operace TUN/TAP souboru
  - virtuální síťová karta
- Připojení VM do sítě
  - TUN/TAP je běžné rozhraní
  - Standardní směrování
  - + NAT
  - Bridge
  - SDN/VXLAN

Virtualizace sítě

- TUN/TAP device 
- Čtení/zápis řídícího souboru = vysílání/příjem packetů
- Hypervizor překládá I/O operace TUN/TAP souboru
  - virtuální síťová karta
- Připojení VM do sítě
  - TUN/TAP je běžné rozhraní
  - Standardní směrování
  - + NAT
  - Bridge
  - SDN/VXLAN

Virtualizace sítě

- TUN/TAP device 
- Čtení/zápis řídícího souboru = vysílání/příjem packetů
- Hypervizor překládá I/O operace TUN/TAP souboru
  - virtuální síťová karta
- Připojení VM do sítě
  - TUN/TAP je běžné rozhraní
  - Standardní směrování
  - + NAT
  - Bridge
  - SDN/VXLAN

Libvirt

- Správce virtuálních strojů
- Nezávislý na hypervizoru
  - XEN
  - KVM
  - LXC
  - ...
- XML definice VM, VNet, disku, ...
- Z příkazové řádky: `virsh(8)`
- GUI: `virt-manager(1)`
  - včetně vzdáleného připojení
  - nad SSH

Libvirt

- Správce virtuálních strojů
- Nezávislý na hypervizoru
  - XEN
  - KVM
  - LXC
  - ...
- XML definice VM, VNet, disku, ...
- Z příkazové řádky: `virsh(8)`
- GUI: `virt-manager(1)`
  - včetně vzdáleného připojení
  - nad SSH

Libvirt

- Správce virtuálních strojů
- Nezávislý na hypervizoru
  - XEN
  - KVM
  - LXC
  - ...
- XML definice VM, VNet, disku, ...
- Z příkazové řádky: `virsh(8)`
- GUI: `virt-manager(1)`
  - včetně vzdáleného připojení
  - nad SSH

Libvirt

- Správce virtuálních strojů
- Nezávislý na hypervizoru
  - XEN
  - KVM
  - LXC
  - ...
- XML definice VM, VNet, disku, ...
- Z příkazové řádky: `virsh(8)`
- GUI: `virt-manager(1)`
  - včetně vzdáleného připojení
  - nad SSH

Libvirt

- Správce virtuálních strojů
- Nezávislý na hypervizoru
  - XEN
  - KVM
  - LXC
  - ...
- XML definice VM, VNet, disku, ...
- Z příkazové řádky: `virsh(8)`
- GUI: `virt-manager(1)`
  - včetně vzdáleného připojení
  - nad SSH

Privátní cloud

- OpenNebula
- OpenStack
- oVirt
- Kubernetes

Hybridní cloud?

Vyzkoušejte `https://stratus.fi.muni.cz/`.

Privátní cloud

- OpenNebula
- OpenStack
- oVirt
- Kubernetes

Hybridní cloud?

Vyzkoušejte `https://stratus.fi.muni.cz/`.

Privátní cloud

- OpenNebula
- OpenStack
- oVirt
- Kubernetes

Hybridní cloud?

Vyzkoušejte `https://stratus.fi.muni.cz/`.

Kontejnery

- Virtualizace SW prostředí
- Bez virtualizace OS
- Minimální HW režie
- Vzájemné oddělení aplikací

Kontejnery

- Virtualizace SW prostředí
- Bez virtualizace OS
- Minimální HW režie
- Vzájemné oddělení aplikací

Kontejnery

- Virtualizace SW prostředí
- Bez virtualizace OS
- Minimální HW režie
- Vzájemné oddělení aplikací

Kontejnery

- Virtualizace SW prostředí
- Bez virtualizace OS
- Minimální HW režie
- Vzájemné oddělení aplikací

Co je kontejner?

- Samostatný strom adresářů
  - `chroot(2)`?
  - ale: procfs, sysfs
- Prostor UID/GID
  - Mapování dovnitř
  - UID=0 není venku root
  - ale: `mount(2)`, `bind(2)`, ...
- Prostor PID
  - nevidět cizí PID
  - umožnit PID 1
- Prostor síťových zařízení
  - `bind(2)` jen na jednu adresu
  - `INADDR_ANY/IP6_ANY`
  - komunikovat i s jinými adresami téhož počítače
  - filtrovat packety
- Prostor systémových zdrojů
  - omezení na CPU, paměť, ...
  - CGroups

Co je kontejner?

- Samostatný strom adresářů
  - `chroot(2)`?
  - ale: procfs, sysfs
- Prostor UID/GID
  - Mapování dovnitř
  - UID=0 není venku root
  - ale: `mount(2)`, `bind(2)`, ...
- Prostor PID
  - nevidět cizí PID
  - umožnit PID 1
- Prostor síťových zařízení
  - `bind(2)` jen na jednu adresu
  - `INADDR_ANY`/`IP6_ANY`
  - komunikovat i s jinými adresami téhož počítače
  - filtrovat packety
- Prostor systémových zdrojů
  - omezení na CPU, paměť, ...
  - CGroups

Co je kontejner?

- Samostatný strom adresářů
  - `chroot(2)`?
  - ale: procfs, sysfs
- Prostor UID/GID
  - Mapování dovnitř
  - UID=0 není venku root
  - ale: `mount(2)`, `bind(2)`, ...
- Prostor PID
  - nevidět cizí PID
  - umožnit PID 1
- Prostor síťových zařízení
  - `bind(2)` jen na jednu adresu
  - `INADDR_ANY/IP6_ANY`
  - komunikovat i s jinými adresami téhož počítače
  - filtrovat packety
- Prostor systémových zdrojů
  - omezení na CPU, paměť, ...
  - CGroups

Co je kontejner?

- Samostatný strom adresářů
  - `chroot(2)`?
  - ale: procfs, sysfs
- Prostor UID/GID
  - Mapování dovnitř
  - UID=0 není venku root
  - ale: `mount(2)`, `bind(2)`, ...
- Prostor PID
  - nevidět cizí PID
  - umožnit PID 1
- Prostor síťových zařízení
  - `bind(2)` jen na jednu adresu
  - `INADDR_ANY`/`IP6_ANY`
  - komunikovat i s jinými adresami téhož počítače
  - filtrovat packety
- Prostor systémových zdrojů
  - omezení na CPU, paměť, ...
  - CGroups

Co je kontejner?

- Samostatný strom adresářů
  - `chroot(2)`?
  - ale: procfs, sysfs
- Prostor UID/GID
  - Mapování dovnitř
  - UID=0 není venku root
  - ale: `mount(2)`, `bind(2)`, ...
- Prostor PID
  - nevidět cizí PID
  - umožnit PID 1
- Prostor síťových zařízení
  - `bind(2)` jen na jednu adresu
  - `INADDR_ANY`/`IP6_ANY`
  - komunikovat i s jinými adresami téhož počítače
  - filtrovat packety
- Prostor systémových zdrojů
  - omezení na CPU, paměť, ...
  - CGroups

Kontejnery v Linuxu

- Linux: neví, co je kontejner
  - všechny jmenné prostory nastavované samostatně
- Správce kontejnerů
  - LXC/LXD
  - `systemd-nspawn(8)`
  - libvirt
  - Dockerd
  - rkt
  - CRI-O
  - Podman
- Kontejnerové cloudy
  - Kubernetes

Kontejnery v Linuxu

- Linux: neví, co je kontejner
  - všechny jmenné prostory nastavované samostatně
- Správce kontejnerů
  - LXC/LXD
  - `systemd-nspawn(8)`
  - libvirt
  - Dockerd
  - rkt
  - CRI-O
  - Podman
- Kontejnerové cloudy
  - Kubernetes

Kontejnery v Linuxu

- Linux: neví, co je kontejner
  - všechny jmenné prostory nastavované samostatně
- Správce kontejnerů
  - LXC/LXD
  - `systemd-nspawn(8)`
  - libvirt
  - Dockerd
  - rkt
  - CRI-O
  - Podman
- Kontejnerové cloudy
  - Kubernetes

Příklad: systemd-nspawn(8)

```
# dnf -y --releasever=31 \
    --installroot /var/lib/machines/f31 \
    install fedora-release bash
# systemd-nspawn -D /var/lib/machines/f31 bash
# dnf -y --releasever=31 \
    --installroot /var/lib/machines/f31 \
    install procps systemd vim
# systemd-nspawn -b -D /var/lib/machines/f31
```

Kapitola 3

Sítě TCP/IP

Sítě TCP/IP

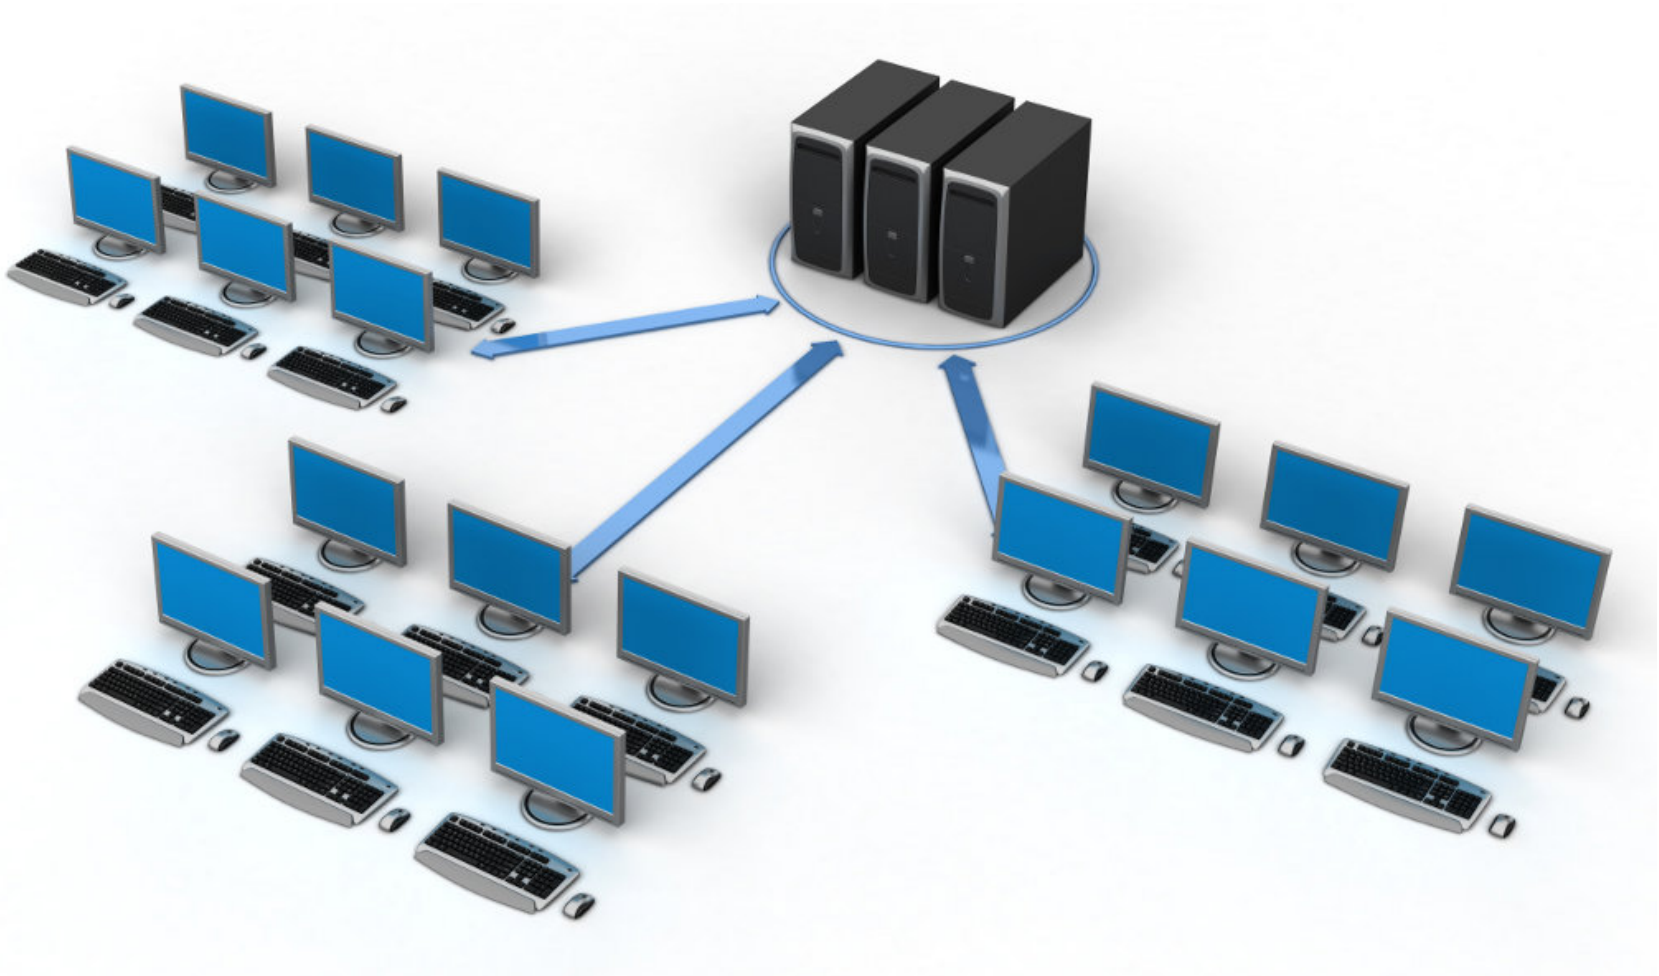

Sítě TCP/IP

- internet – několik sítí propojených dohromady.
- Internet – celosvětová síť s protokolem TCP/IP.
- Transmission Control Protocol/Internet Protocol
- IETF – Internet Engineering Task Force.
- RFC – Request For Comments – dokumenty, popisující jednotlivé protokoly. `http://ftp.fi.muni.cz/pub/rfc`.
- Internet drafts – navrhy protokolu. `http://ftp.fi.muni.cz/pub/internet-drafts`. Omezená časová platnost.

Historie Internetu

- 1969 ARPANET – první síť s přepojováním packetů – 4 uzly.
- 1977 Začíná vývoj protokolů TCP/IP (Stanford, BBN, University College London).
- 1980 Provoz TCP/IP v ARPANETu. UCB implementuje TCP/IP pro BSD.
- 1983 TCP/IP se stává standardem v ARPANETu. Sun Microsystems – TCP/IP v komerční sféře.
- 1985 NSFnet – jádro současného Internetu.

Charakteristiky TCP/IP

- Síť s přepojováním packetů (opozitum k přepojování okruhů; kombinace obou je např. ATM).
- Stejné protokoly pro všechny sítě a druhy sítí.
- Směrování na základě cílové sítě, nikoli cílové adresy.

Vrstvy protokolů TCP/IP

Nižší vrstvy přibližně podle ISO OSI:

- 1: fyzická – například UTP kabel, optické vlákno, metalický okruh.
- 2: linková – síťové rozhraní (Ethernet, ATM LANE, PPP, HDLC, FDDI, RFC 1149 ^_~.
- 3: síťová – IPv4, IPv6 (datagramy), ARP (získání HW adresy), RARP (získání vlastní IP adresy).
- 4: transportní – ICMP, ICMPv6 (řídící zprávy), IGMP (skupinová adresace), TCP (proudy dat), UDP (datagramy).
- 5+: aplikační – např. SMTP, FTP, telnet, NTP, SNMP, SSH, XMPP, ...

Vrstvy protokolů TCP/IP

Nižší vrstvy přibližně podle ISO OSI:

- 1: fyzická – například UTP kabel, optické vlákno, metalický okruh.
- 2: linková – síťové rozhraní (Ethernet, ATM LANE, PPP, HDLC, FDDI, RFC 1149 ^_~.
- 3: síťová – IPv4, IPv6 (datagramy), ARP (získání HW adresy), RARP (získání vlastní IP adresy).
- 4: transportní – ICMP, ICMPv6 (řídící zprávy), IGMP (skupinová adresace), TCP (proudy dat), UDP (datagramy).
- 5+: aplikační – např. SMTP, FTP, telnet, NTP, SNMP, SSH, XMPP, ...

Vrstvy protokolů TCP/IP

Nižší vrstvy přibližně podle ISO OSI:

- 1: fyzická – například UTP kabel, optické vlákno, metalický okruh.
- 2: linková – síťové rozhraní (Ethernet, ATM LANE, PPP, HDLC, FDDI, RFC 1149 ^_~.
- 3: síťová – IPv4, IPv6 (datagramy), ARP (získání HW adresy), RARP (získání vlastní IP adresy).
- 4: transportní – ICMP, ICMPv6 (řídící zprávy), IGMP (skupinová adresace), TCP (proudy dat), UDP (datagramy).
- 5+: aplikační – např. SMTP, FTP, telnet, NTP, SNMP, SSH, XMPP, ...

Vrstvy protokolů TCP/IP

Nižší vrstvy přibližně podle ISO OSI:

- 1: fyzická – například UTP kabel, optické vlákno, metalický okruh.
- 2: linková – síťové rozhraní (Ethernet, ATM LANE, PPP, HDLC, FDDI, RFC 1149 ^_~.
- 3: síťová – IPv4, IPv6 (datagramy), ARP (získání HW adresy), RARP (získání vlastní IP adresy).
- 4: transportní – ICMP, ICMPv6 (řídící zprávy), IGMP (skupinová adresace), TCP (proudy dat), UDP (datagramy).
- 5+: aplikační – např. SMTP, FTP, telnet, NTP, SNMP, SSH, XMPP, ...

Vrstvy protokolů TCP/IP

Nižší vrstvy přibližně podle ISO OSI:

- 1: fyzická – například UTP kabel, optické vlákno, metalický okruh.
- 2: linková – síťové rozhraní (Ethernet, ATM LANE, PPP, HDLC, FDDI, RFC 1149 ^_~.
- 3: síťová – IPv4, IPv6 (datagramy), ARP (získání HW adresy), RARP (získání vlastní IP adresy).
- 4: transportní – ICMP, ICMPv6 (řídící zprávy), IGMP (skupinová adresace), TCP (proudy dat), UDP (datagramy).
- 5+: aplikační – např. SMTP, FTP, telnet, NTP, SNMP, SSH, XMPP, ...

Způsoby propojení sítí

- Repeater – v podstatě propojení na fyzické úrovni.
- Bridge/Switch – propojení na linkové úrovni.
- Router – propojení na síťové úrovni. Pro každou třídu protokolů může být zvláštní router. Nezávislost na 2. vrstvě.

Adresování v IPv4

- Internet Protocol – verze 4, RFC 791.
- IP adresa – 4 bajty. Zapisuje se jako 4 dekadická čísla, oddělená tečkami.
- Adresa přidělována rozhraní, nikoli počítači.
- Adresa sítě vs. adresa v rámci sítě.
- Typy vysílání: unicast, broadcast, multicast.

Třídní adresace

- Typ A – `0.x.x.x–127.x.x.x`.
- Typ B – `128.0.x.x–191.255.x.x`.
- Typ C – `192.0.0.x–223.255.255.x`.
- Typ D – `224.0.0.0–239.255.255.255` – multicast.
- Typ E – `240.0.0.0–255.255.255.255` – rezerva.

Beztřídní adresace

- Nedostatek adres, vyčerpání adresního prostoru.
- CIDR: prefix adresy (adresa, maska). RFC 1518.
- Zápis: podobně jako adresa nebo jen délka prefixu.

Příklad: CIDR adresa

```
147.251.48.1/255.255.255.0
147.251.48.1/24
```

- Adresa sítě: *interface* and *netmask* – `147.251.48.0`.
- Všesměrové vysílání – *interface* `or not` *netmask* – `147.251.48.255`.

Beztřídní adresace

- Nedostatek adres, vyčerpání adresního prostoru.
- CIDR: prefix adresy (adresa, maska). RFC 1518.
- Zápis: podobně jako adresa nebo jen délka prefixu.

Příklad: CIDR adresa

```
147.251.48.1/255.255.255.0
147.251.48.1/24
```

- Adresa sítě: *interface* and *netmask* – `147.251.48.0`.
- Všesměrové vysílání – *interface* `or not` *netmask* – `147.251.48.255`.

Beztřídní adresace

- Nedostatek adres, vyčerpání adresního prostoru.
- CIDR: prefix adresy (adresa, maska). RFC 1518.
- Zápis: podobně jako adresa nebo jen délka prefixu.

Příklad: CIDR adresa

```
147.251.48.1/255.255.255.0
147.251.48.1/24
```

- Adresa sítě: *interface* and *netmask* – `147.251.48.0`.
- Všesměrové vysílání – *interface* `or not` *netmask* – `147.251.48.255`.

Speciální IPv4 adresy

- Moje adresa – nezná-li odesílatel svoji adresu – `0.0.0.0`.
- Omezené všesměrové vysílání (jen pro tuto síť, neprochází přes routery) – `255.255.255.255`.
- Loopback address – pro adresování sebe sama – `127.0.0.1`.
- Privátní sítě – RFC 1918. Nesmí se objevit v Internetu:
  - `10.0.0.0/8`
  - `172.16.0.0/12`
  - `192.168.0.0/16`

Úkol:

Jaká je numericky nejvyšší adresa v bloku `172.16.0.0/12`?

Speciální IPv4 adresy

- Moje adresa – nezná-li odesílatel svoji adresu – `0.0.0.0`.
- Omezené všesměrové vysílání (jen pro tuto síť, neprochází přes routery) – `255.255.255.255`.
- Loopback address – pro adresování sebe sama – `127.0.0.1`.
- Privátní sítě – RFC 1918. Nesmí se objevit v Internetu:
  - `10.0.0.0/8`
  - `172.16.0.0/12`
  - `192.168.0.0/16`

Úkol:

Jaká je numericky nejvyšší adresa v bloku `172.16.0.0/12`?

Internet Protocol

- Datagram (packet) – balík dat omezené velikosti.
- Směrování – každý packet je směrován nezávisle na ostatních.
- Nespolehlivost – datagram může dojít vícekrát nebo se ztratit. datagramy mohou změnit pořadí.
- Fragmentace packetů – při průchodu do sítě s menší maximální velikostí datagramu (MTU).

Formát IP packetu – I.

- Verze protokolu – 4 bity.
- Header length – 4 bity, značí počet 32-bitových jednotek.
- Type of service – 3 bity priorita, 1 bit latence, 1 bit propustnost, 1 bit bezeztrátovost. Zarovnáno na 8 bitů.
- Total length – 16 bitů.
- Identification – 16 bitů – k fragmentaci.
- Flags – 3 bity – Don’t fragment, More fragments, 1 bit rezervovaný (ale: RFC 3514)
- Fragment offset – 13 bitů, značí násobek osmi bajtů.

Úkol:

Nastudujte RFC 3514 ^_~

Formát IP packetu – I.

- Verze protokolu – 4 bity.
- Header length – 4 bity, značí počet 32-bitových jednotek.
- Type of service – 3 bity priorita, 1 bit latence, 1 bit propustnost, 1 bit bezeztrátovost. Zarovnáno na 8 bitů.
- Total length – 16 bitů.
- Identification – 16 bitů – k fragmentaci.
- Flags – 3 bity – Don’t fragment, More fragments, 1 bit rezervovaný (ale: RFC 3514)
- Fragment offset – 13 bitů, značí násobek osmi bajtů.

Úkol:

Nastudujte RFC 3514 ^_~

Formát IP packetu – II.

- Time to live – TTL, 8 bitů. Životnost datagramu. Každý směrovač sníží aspoň o 1.
- Protocol – 8 bitů. Označení vyšší vrstvy, které datagram patří.
- Header checksum – 16 bitů.
- Source IP address – 32 bitů.
- Destination IP address – 32 bitů.
- Options – délka je násobek 32 bitů.
- Data – délka je násobek 32 bitů, max. 65536 bajtů.

Fragmentace packetů

- Prochází-li datagram do sítě s menší MTU.
- Minimální MTU je 576 bajtů.
- Všechny fragmenty mají stejné *identification*.
- Fragmenty mají *more fragments* flag nastaven na 1.
- Poslední fragment a nefragmentované packety mají tento flag nastavený na 0.
- Fragmenty (kromě prvního) mají nenulový *fragment offset*.

Otázka:

Jak se pozná první fragment packetu?

Úkol:

Promyslete, jestli fragmenty mohou být dále fragmentovány.

Fragmentace packetů

- Prochází-li datagram do sítě s menší MTU.
- Minimální MTU je 576 bajtů.
- Všechny fragmenty mají stejné *identification*.
- Fragmenty mají *more fragments* flag nastaven na 1.
- Poslední fragment a nefragmentované packety mají tento flag nastavený na 0.
- Fragmenty (kromě prvního) mají nenulový *fragment offset*.

Otázka:

Jak se pozná první fragment packetu?

Úkol:

Promyslete, jestli fragmenty mohou být dále fragmentovány.

Fragmentace packetů

- Prochází-li datagram do sítě s menší MTU.
- Minimální MTU je 576 bajtů.
- Všechny fragmenty mají stejné *identification*.
- Fragmenty mají *more fragments* flag nastaven na 1.
- Poslední fragment a nefragmentované packety mají tento flag nastavený na 0.
- Fragmenty (kromě prvního) mají nenulový *fragment offset*.

Otázka:

Jak se pozná první fragment packetu?

Úkol:

Promyslete, jestli fragmenty mohou být dále fragmentovány.

Fragmentace – poznámky

- Znovusestavení datagramu – smí provádět pouze cílový počítač. Někdy je též prováděno hraničním routerem nebo firewallem privátní sítě.
- Path MTU discovery – zjištění MTU cesty – posílá se nefragmentovatelný packet, sledují se odpovědi.

Úkol:

V jakém pořadí je výhodné odesílat právě vygenerované fragmenty (a proč)?

Fragmentace – poznámky

- Znovusestavení datagramu – smí provádět pouze cílový počítač. Někdy je též prováděno hraničním routerem nebo firewallem privátní sítě.
- Path MTU discovery – zjištění MTU cesty – posílá se nefragmentovatelný packet, sledují se odpovědi.

Úkol:

V jakém pořadí je výhodné odesílat právě vygenerované fragmenty (a proč)?

Volitelné položky v IP datagramu

- Record route – trasování cesty datagramu.
- Timestamp – trasování s časovým razítkem.
- Loose source route – minimální cesta datagramu.
- Strict source route – úplná cesta datagramu.
- Security – stupeň utajení datagramu.

IPv4 nad Ethernetem

Formát rámce Ethernet v2:

- Cílová adresa – 6 bajtů.
- Zdrojová adresa – 6 bajtů.
- Typ (protokol vyšší vrstvy) – 2 bajty.
- Data – 46–1500 bajtů.
- CRC – 4 bajty.

ARP/RARP – formát packetů

- Převod L2 adres na L3 adresy a naopak
- HW type – 2 bajty (1 = Ethernet).
- Protocol type – 2 bajty (0x0800 = IP).
- HW length – 1 bajt (Ethernet = 6).
- Protocol length – 1 bajt (IP = 4).
- Operation – 2 bajty (1 = ARP request, 2 = ARP response, 3 = RARP request, 4 = RARP response).
- Sender layer 2 addr
- Sender layer 3 addr
- Target layer 2 addr
- Target layer 3 addr

Příklad: Použití ARP

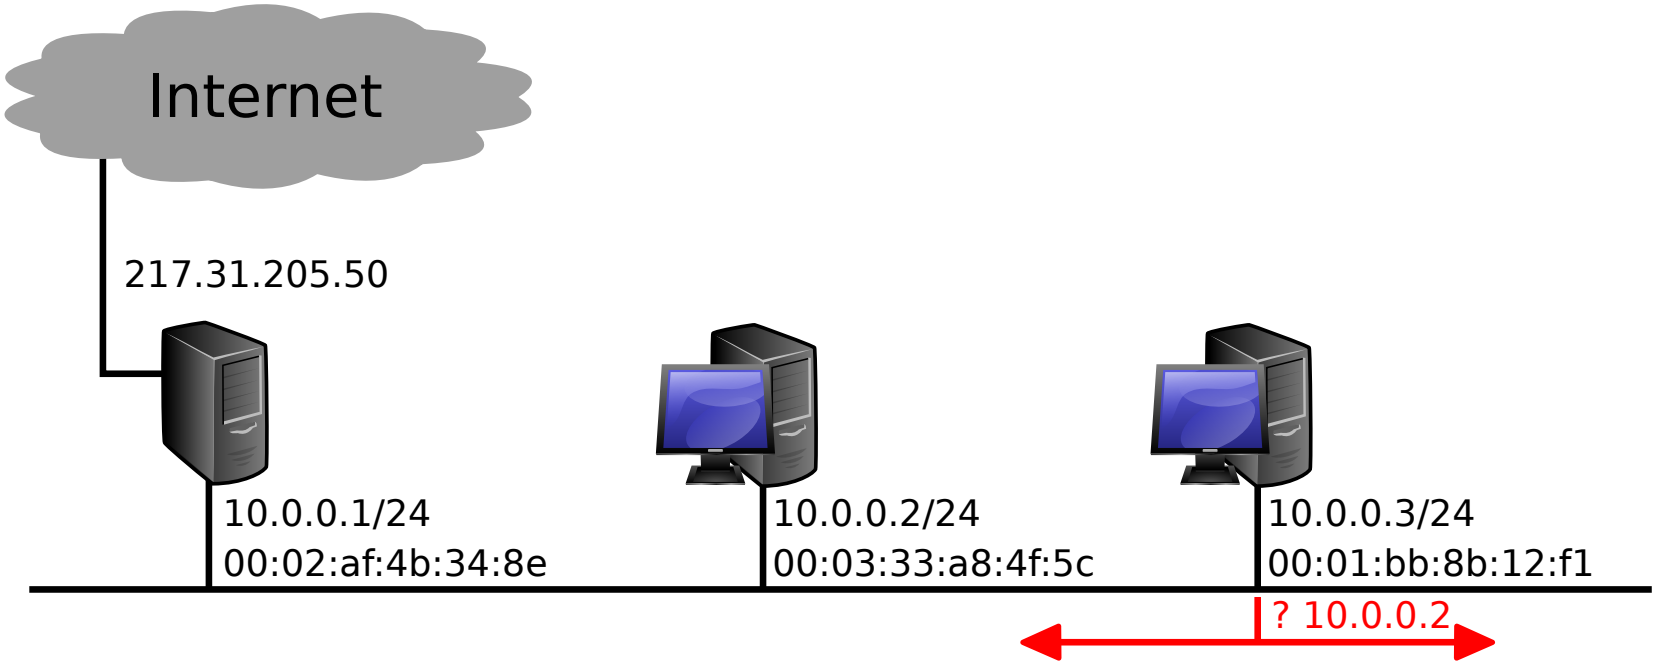

Příklad: Použití ARP

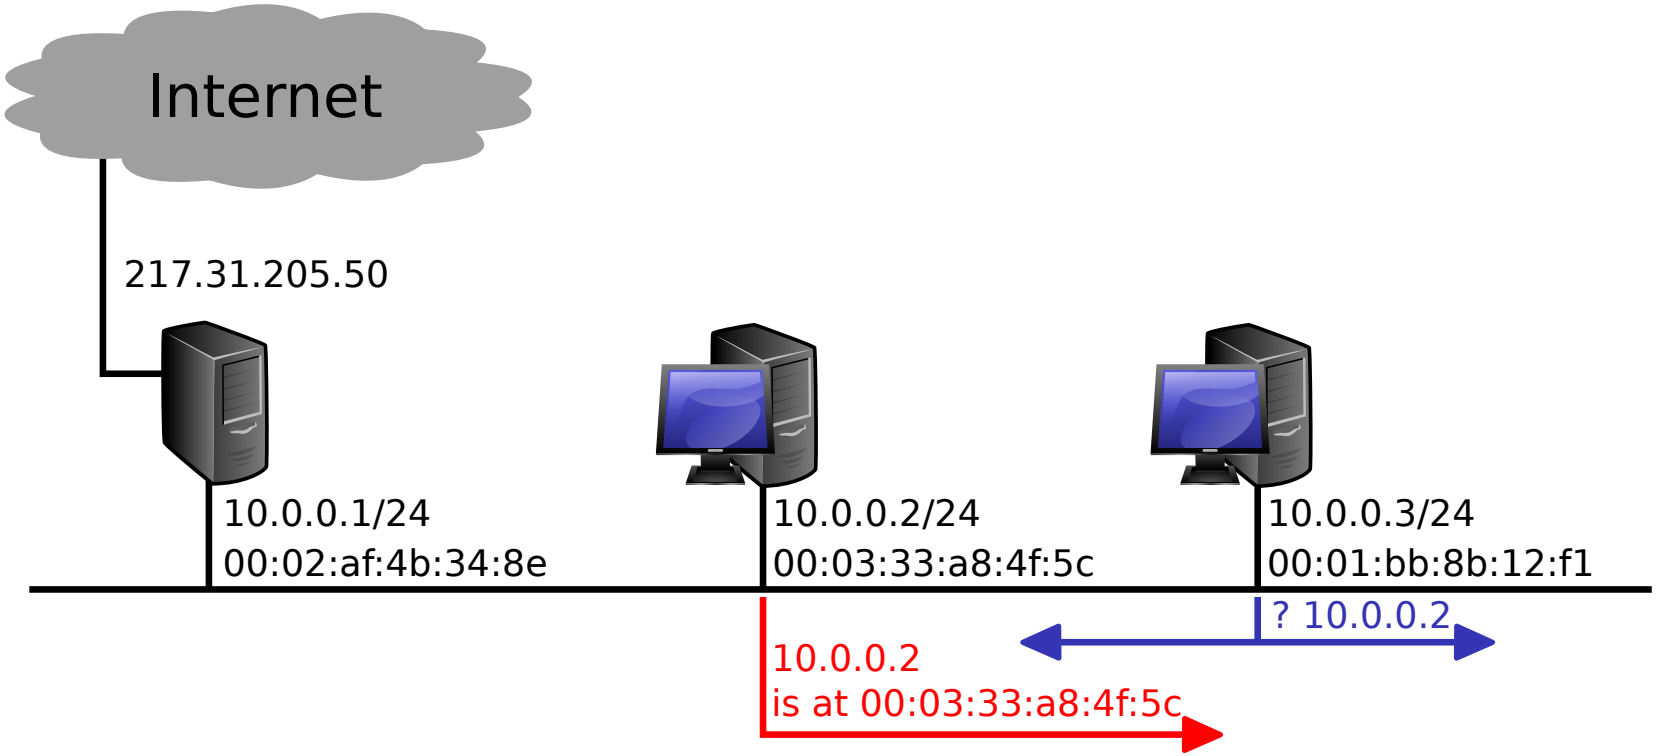

Příklad: Použití ARP

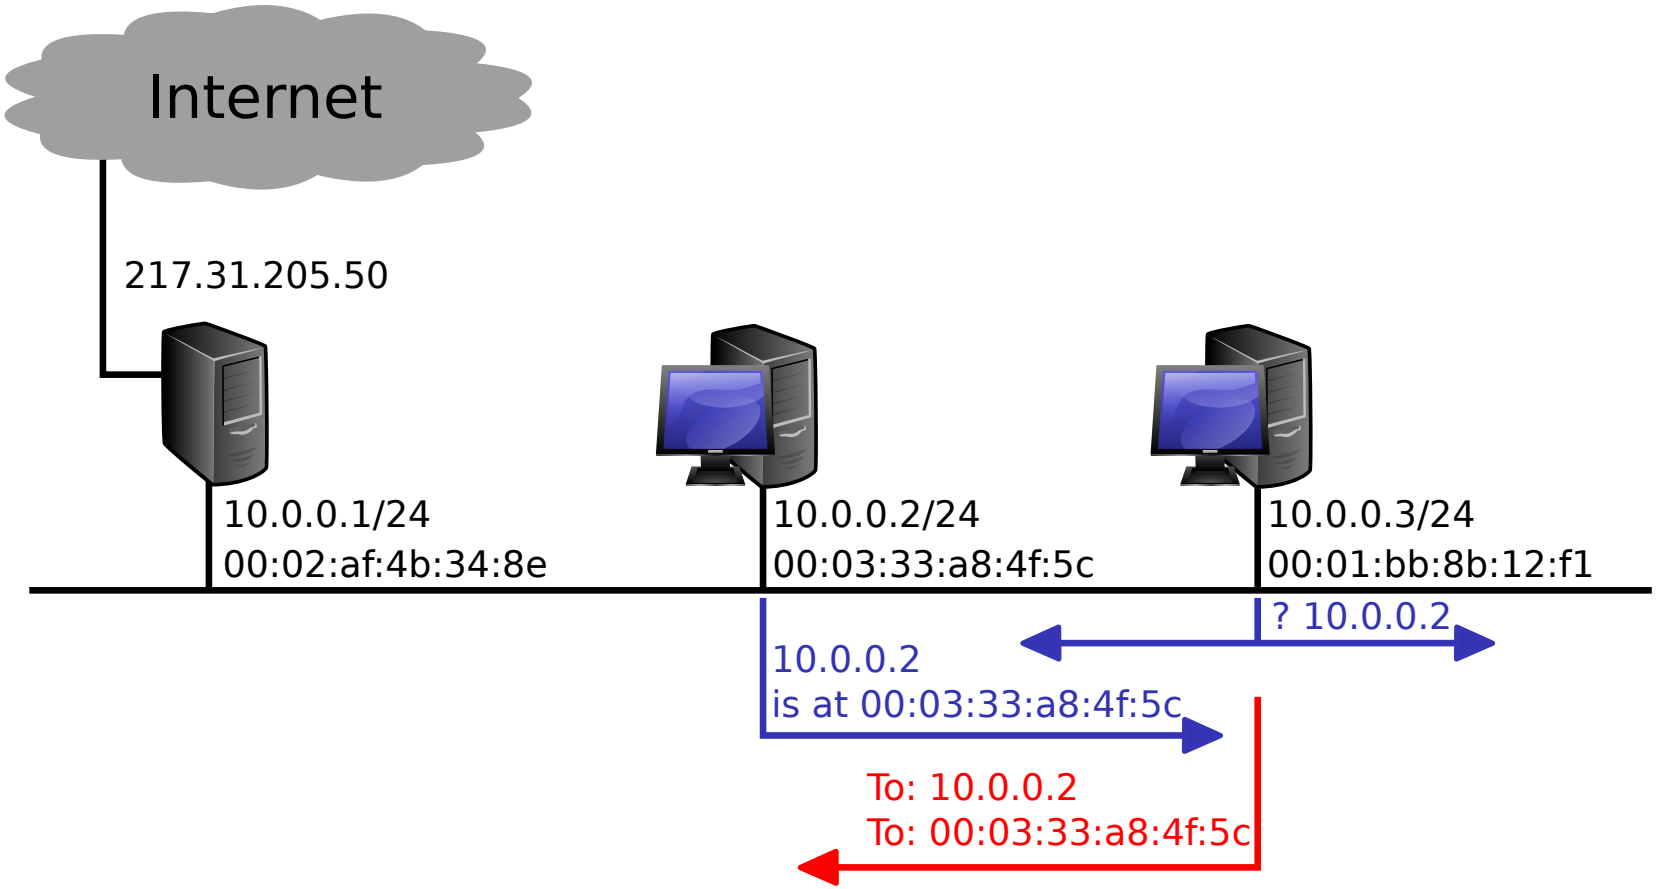

Příklad: ARP u nelokální adresy

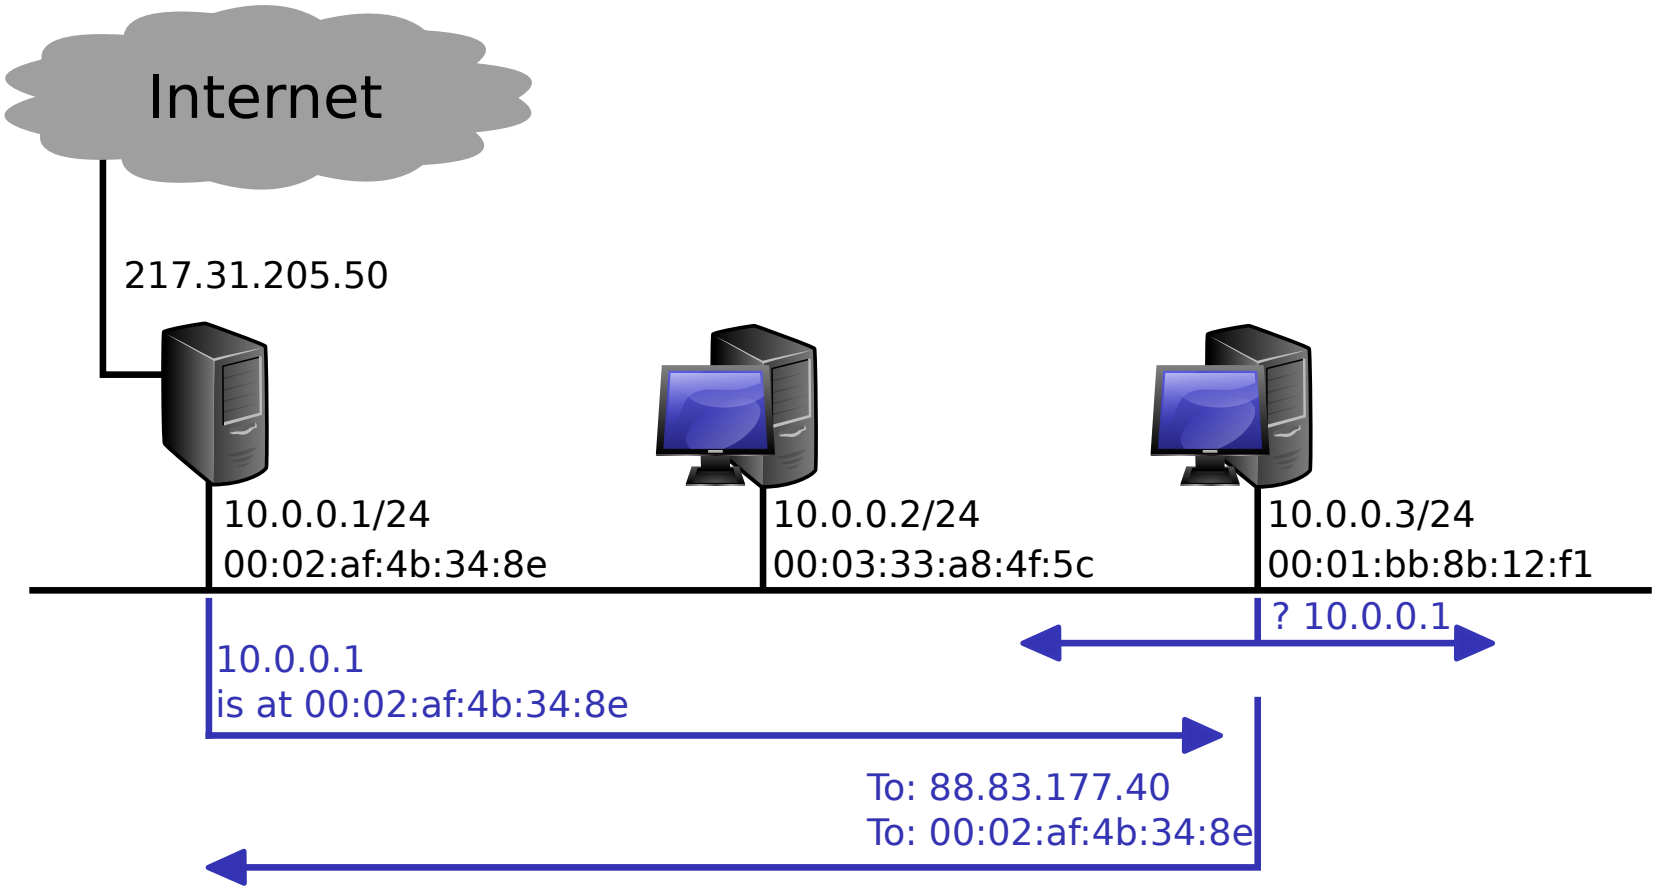

ARP – poznámky

- ARP cache – není třeba ARP dotaz s každým packetem.
- Proxy ARP – náhrada/zjednodušení směrování.

Příklad: Proxy ARP

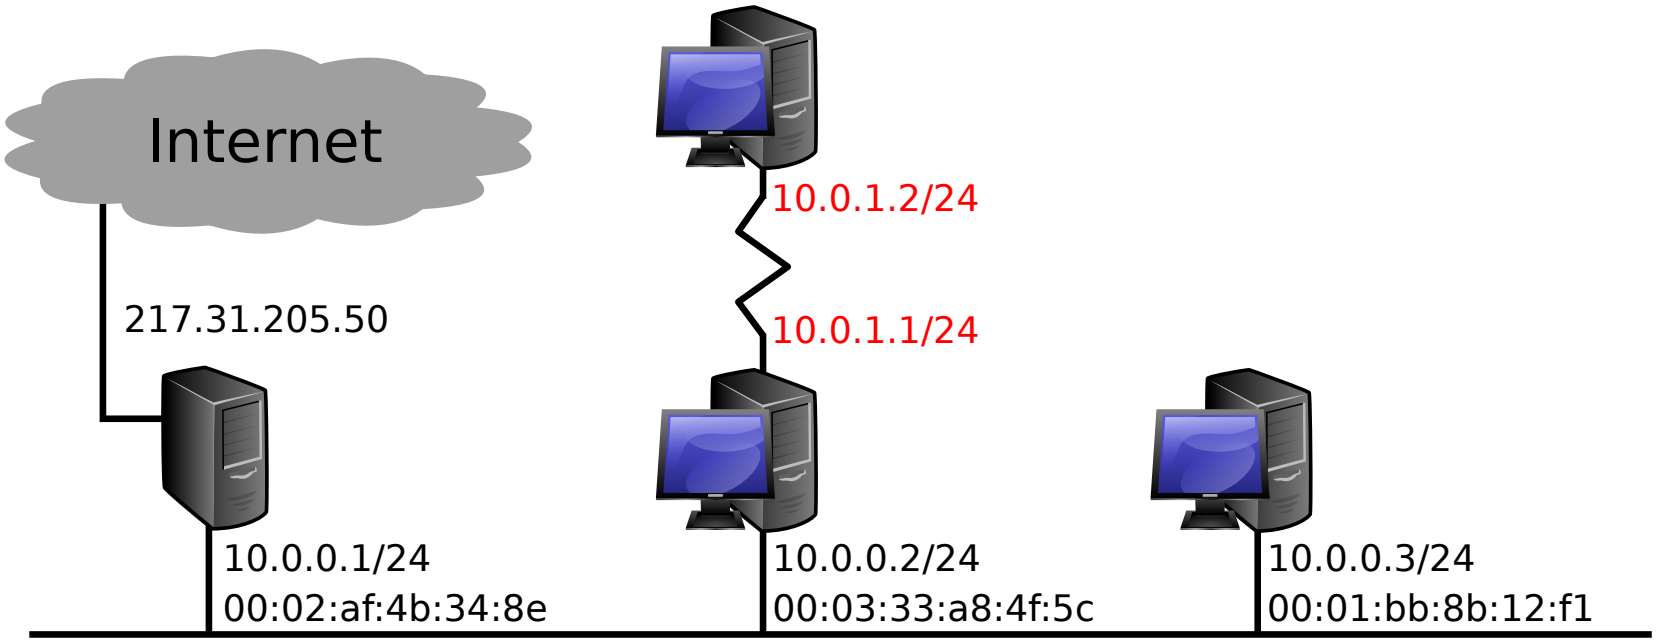

Příklad: Proxy ARP

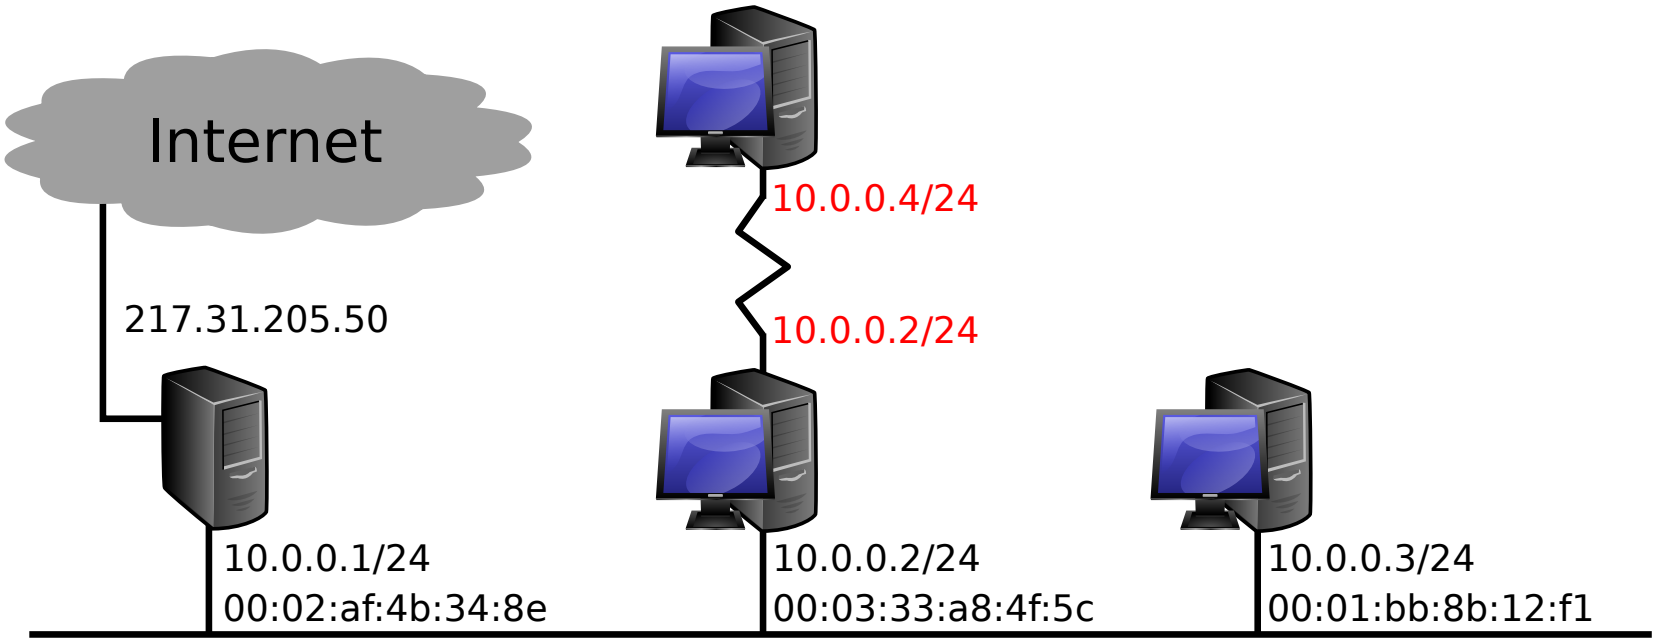

Příklad: Proxy ARP

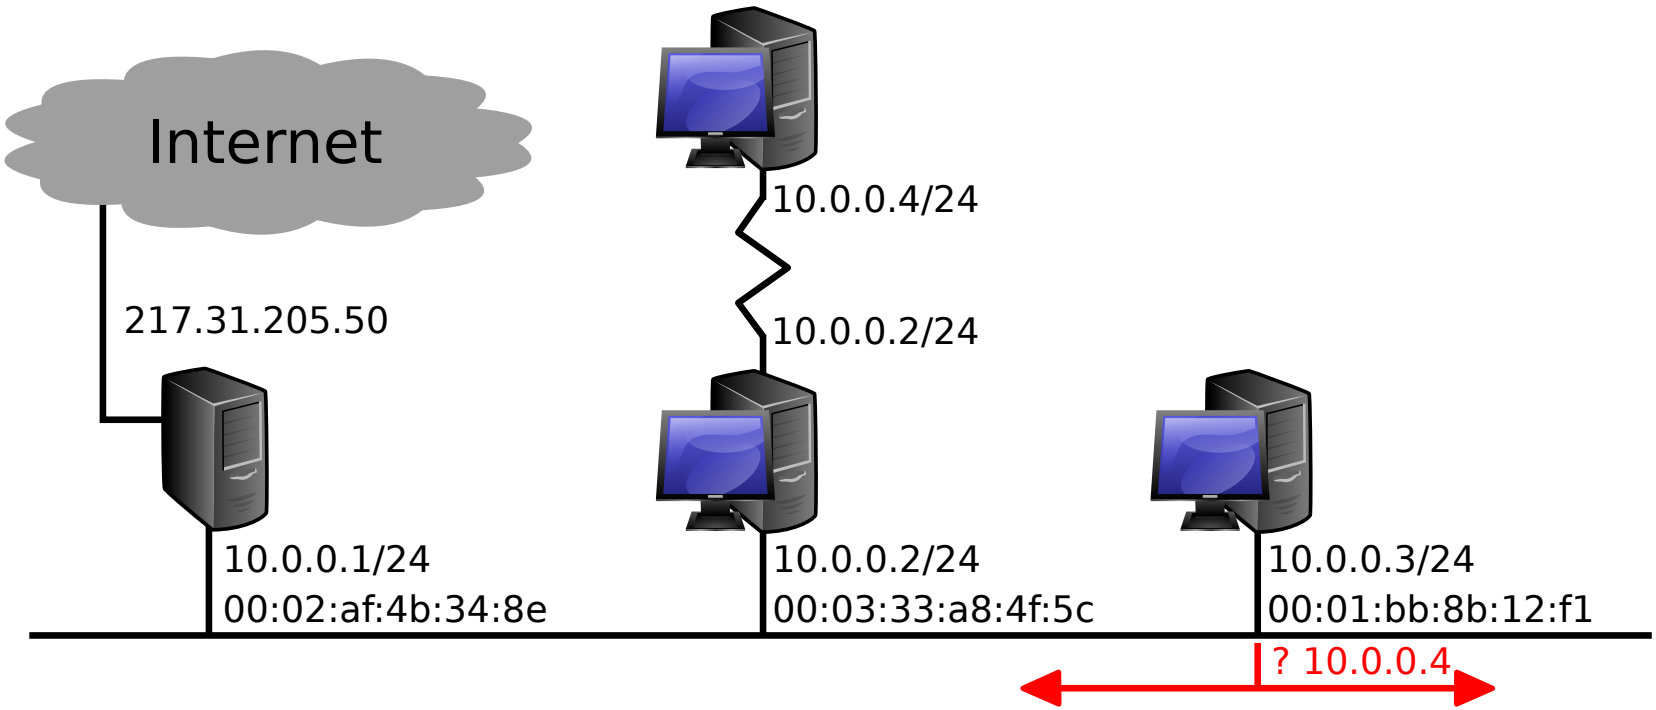

Příklad: Proxy ARP

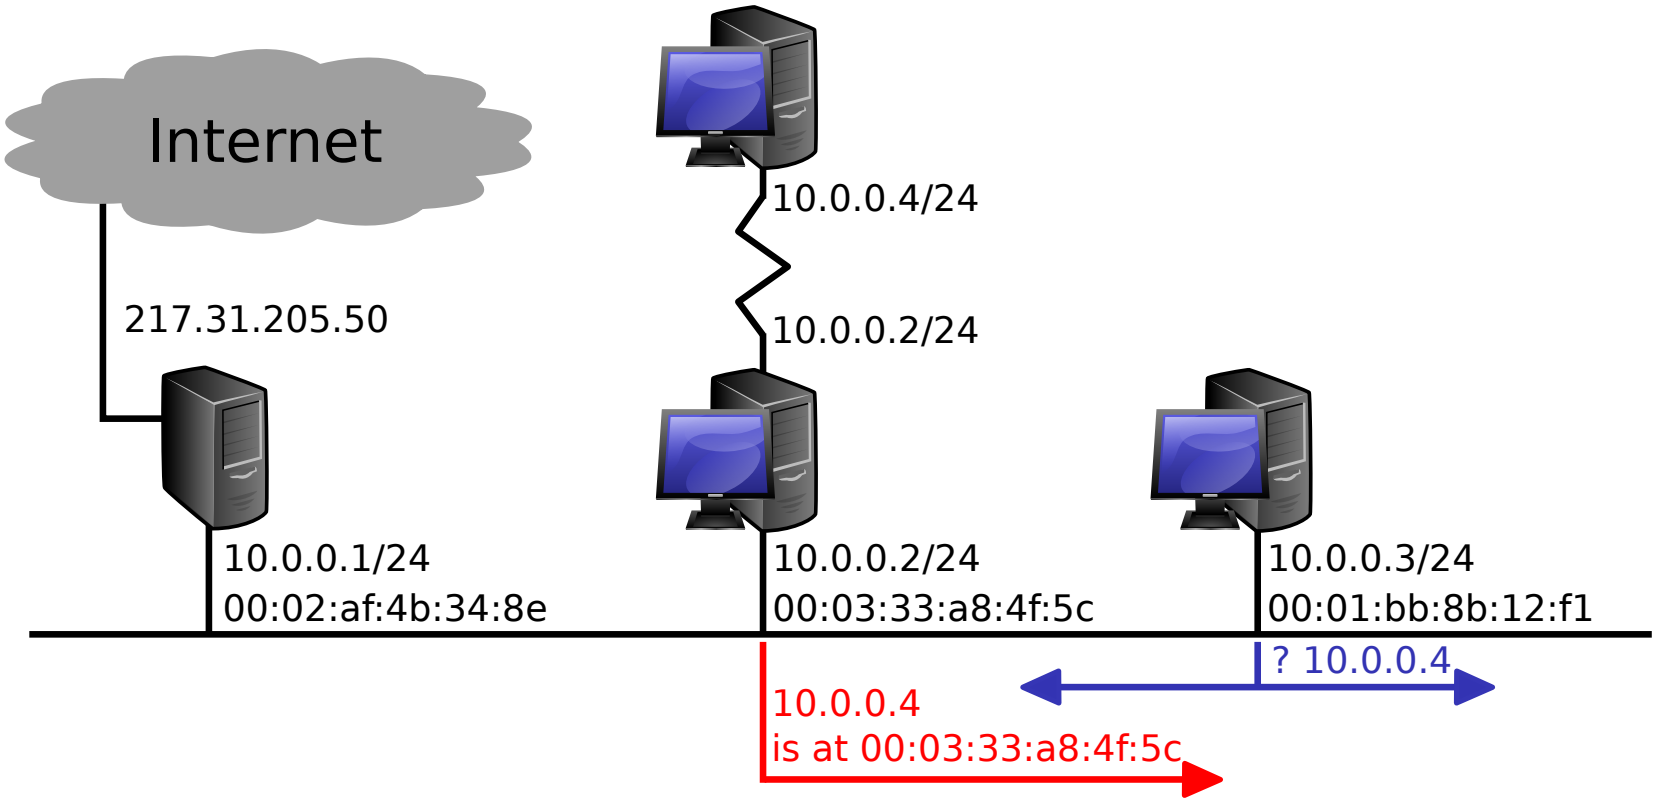

Příklad: Proxy ARP

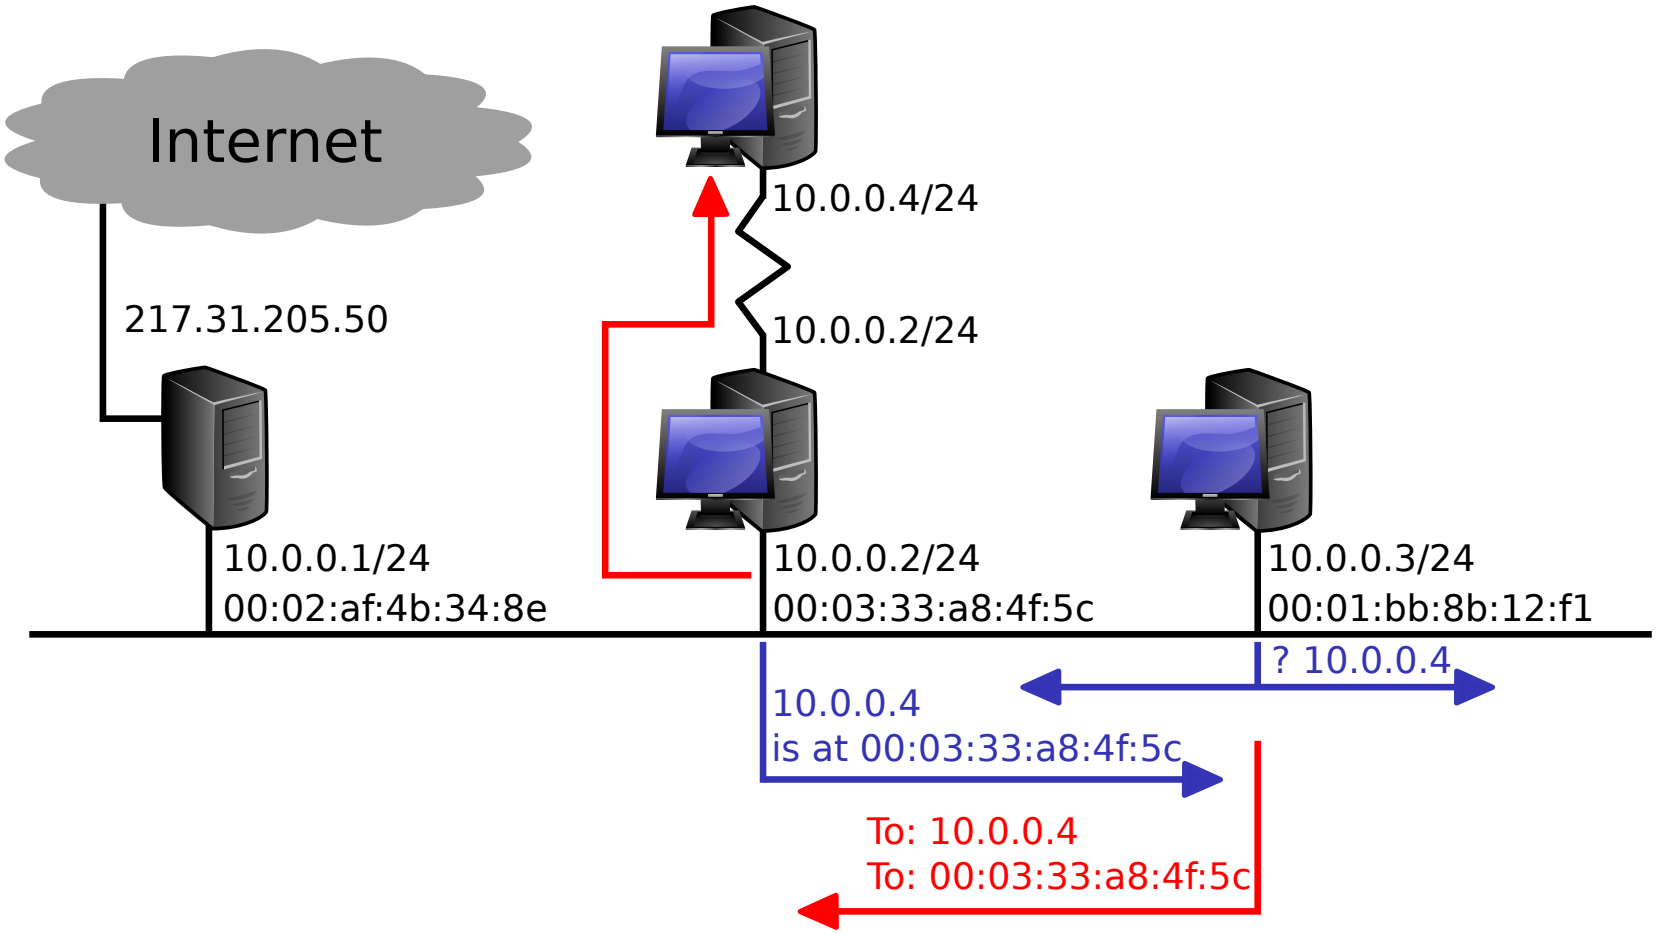

IPv6 – Motivace

- Větší adresní prostor.
- Mobilita – práce ve více sítích, přechod mezi sítěmi za běhu aplikací, domovský agent.
- Zabezpečení – šifrované a podepisované packety – protokol IPSEC.
- Autokonfigurace – zjištění informací o síti přímo ze sítě.
- Způsoby přenosu – unicast, multicast, anycast.
- Více IPv6 adres na jedno rozhraní.

Adresace v IPv6

- 128-bitová adresa
- Zápis – čtveřice šestnástkových čísel.
- Příklad:
  `3ffe:ffff:0000:f101:0210:a4ff:fee3:9562`
- Vypuštění úvodních nul:
  `3ffe:ffff:0:f101:210:a4ff:fee3:9562`
- Vypuštění sekvence `0000`:
  `3ffe:ffff::f101:210:a4ff:fee3:9562`.
- Prefix – podobně jako v IPv4 (např.:
  `3ffe:ffff::12/64`).

Otázka:

Která IPv6 adresa je zapsatelná na nejméně znaků?

Adresace v IPv6

- 128-bitová adresa
- Zápis – čtveřice šestnástkových čísel.
- Příklad:
  `3ffe:ffff:0000:f101:0210:a4ff:fee3:9562`
- Vypuštění úvodních nul:
  `3ffe:ffff:0:f101:210:a4ff:fee3:9562`
- Vypuštění sekvence `0000`:
  `3ffe:ffff::f101:210:a4ff:fee3:9562`.
- Prefix – podobně jako v IPv4 (např.:
  `3ffe:ffff::12/64`).

Otázka:

Která IPv6 adresa je zapsatelná na nejméně znaků?

Formát IPv6 packetů

- Hlavička pevné délky, řetězení hlaviček.
- Verze protokolu – 4 bity, hodnota vždy 6.
- Priorita – 8 bitů, třída provozu.
- Identifikace toku – 20 bitů.
- Délka packetu – 16 bitů.
- Next header – 8 bitů (identifikace další hlavičky, např. vyšší vrstvy).
- Hop limit – 8 bitů (ekvivalent TTL u IPv4).
- Zdrojová adresa – 128 bitů.
- Cílová adresa – 128 bitů.

Speciální IPv6 adresy

- Loopback – `::1` (ekvivalent `127.0.0.1` v IPv4).
- Nespecifikovaná adresa – `::` (ekvivalent `0.0.0.0` v IPv4).
- Lokální adresa linky – `fe80::/10`
- Adresy pro příklady – `3ffe:ffff::/32`.
- IPv4 kompatibilní adresy – `::/96`.
- IPv4 mapované adresy – `::ffff:0:0/96`.

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky
- `fe?f:ffff:ffff:ffff:ffff:ffff:ffff:ffff`

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky
- `fe?f:ffff:ffff:ffff:ffff:ffff:ffff:ffff`
- ? = 8, z toho 2 nejvyšší bity zachovat, zbytek 1

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky
- `fe?f:ffff:ffff:ffff:ffff:ffff:ffff:ffff`
- ? = 8, z toho 2 nejvyšší bity zachovat, zbytek 1
- 8 = `1000`, z toho 2 nejvyšší bity zachovat, zbytek 1

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky
- `fe?f:ffff:ffff:ffff:ffff:ffff:ffff:ffff`
- `?` = 8, z toho 2 nejvyšší bity zachovat, zbytek 1
- 8 = `1000`, z toho 2 nejvyšší bity zachovat, zbytek 1
- `1011` = `b`

Interpretace prefixu adresy

Úkol:

Link-local adresy jsou určeny prefixem `fe80::/10`. Jaká je numericky nejvyšší link-local adresa?

- 10 nejvyšších bitů stejných, zbytek jedničky
- `fe?f:ffff:ffff:ffff:ffff:ffff:ffff:ffff`
- `?` = 8, z toho 2 nejvyšší bity zachovat, zbytek 1
- 8 = `1000`, z toho 2 nejvyšší bity zachovat, zbytek 1
- `1011` = `b`
- `febf:ffff:ffff:ffff:ffff:ffff:ffff:ffff`

Privátní IPv6 adresy

- Site-local address – `fec0::/10`
  - ekvivalent privátních IPv4 adres dle RFC1918
  - nyní zastaralé (RFC 3879)
- Unique Local Address – RFC 4193.
  - prefix `fc00::/7`
  - 8. bit = 1 pro lokální přidělení, 0 pro globální.
  - 40 bitů: globální ID
  - 80 bitů: pro lokální přidělování (65 536 sítí /64)

Privátní IPv6 adresy

- Site-local address – `fec0::/10`
  - ekvivalent privátních IPv4 adres dle RFC1918
  - nyní zastaralé (RFC 3879)
- Unique Local Address – RFC 4193.
  - prefix `fc00::/7`
  - 8. bit = 1 pro lokální přidělení, 0 pro globální.
  - 40 bitů: globální ID
  - 80 bitů: pro lokální přidělování (65 536 sítí /64)

EUI-64 formát adresy

- EUI-64 formát adresy – lokální část se odvozuje z fyzické adresy.
- EUI-64 pro ethernet – MAC adresa, uprostřed vloženo `fffe`, 7. nejvyšší bit nastaven na 1 pro globálně přidělený identifikátor (MAC adresu) RFC 4291, sekce 2.5.1.

Příklad: EUI-64

MAC adresa `00:D0:B7:6B:4A:B2`
Prefix sítě `fe80::/10`
EUI-64 adresa je `fe80::2d0:b7ff:fe6b:4ab2`

- Autokonfigurace – směrovač vysílá *router advertisement*, kde je uveden `/64` prefix lokální sítě. Viz též `radvd(8)`.

EUI-64 formát adresy

- EUI-64 formát adresy – lokální část se odvozuje z fyzické adresy.
- EUI-64 pro ethernet – MAC adresa, uprostřed vloženo `fffe`, 7. nejvyšší bit nastaven na 1 pro globálně přidělený identifikátor (MAC adresu) RFC 4291, sekce 2.5.1.

Příklad: EUI-64

MAC adresa `00:D0:B7:6B:4A:B2`
Prefix sítě `fe80::/10`
EUI-64 adresa je `fe80::2d0:b7ff:fe6b:4ab2`

- Autokonfigurace – směrovač vysílá *router advertisement*, kde je uveden /64 prefix lokální sítě. Viz též `radvd(8)`.

Výpočet EUI-64 adresy

Úkol:

Jaká by byla EUI-64 adresa počítače `aisa.fi.muni.cz` (MAC adresa `00:25:B3:D7:D0:6A`) je-li adresní prefix `2001:718:801:230::/64`?

Specifické vlastnosti IPv6

- Fragmentace packetů – na směrovačích není. Vysílající musí dělat *path MTU discovery*. Fragmentace popsána v samostatné *next header*.
- Spolupráce s linkovou vrstvou – NDP (neighbour discovery protocol). Náhrada ARP. Zjišťování adresního prefixu sítě, směrovacích informací, atd.

Přechodové mechanismy

- Dual stack – podpora IPv4 a IPv6 v jednom počítači.
- Tunelování – zapouzdření IPv6 packetů do IPv4 (protokol SIT, 41).
- Autotunelování – (6to4):
  - adresy `2002:xxxx:yyyy:/48` vytvořené z IPv4 adresy
  - schování bloku /48 IPv6 adres za jednu IPv4 adresu
  - komunikace do nativního IPv6 internetu přes 6to4 relay
  - adresa relay: 192.88.99.1 (2002:c058:6301::).
- 6rd – spolupráce ISP, nemá-li klient veřejnou IPv4 adresu.

Autotunelování 6to4

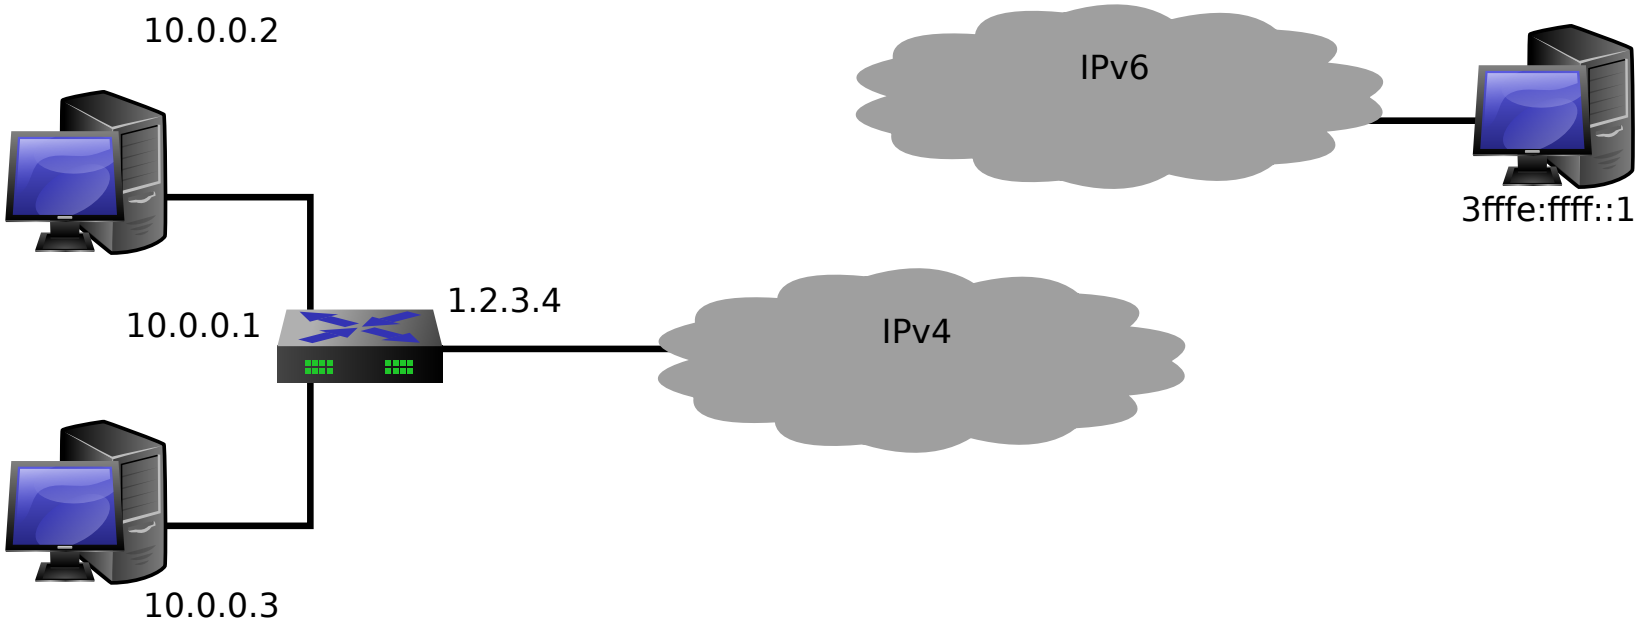

Autotunelování 6to4

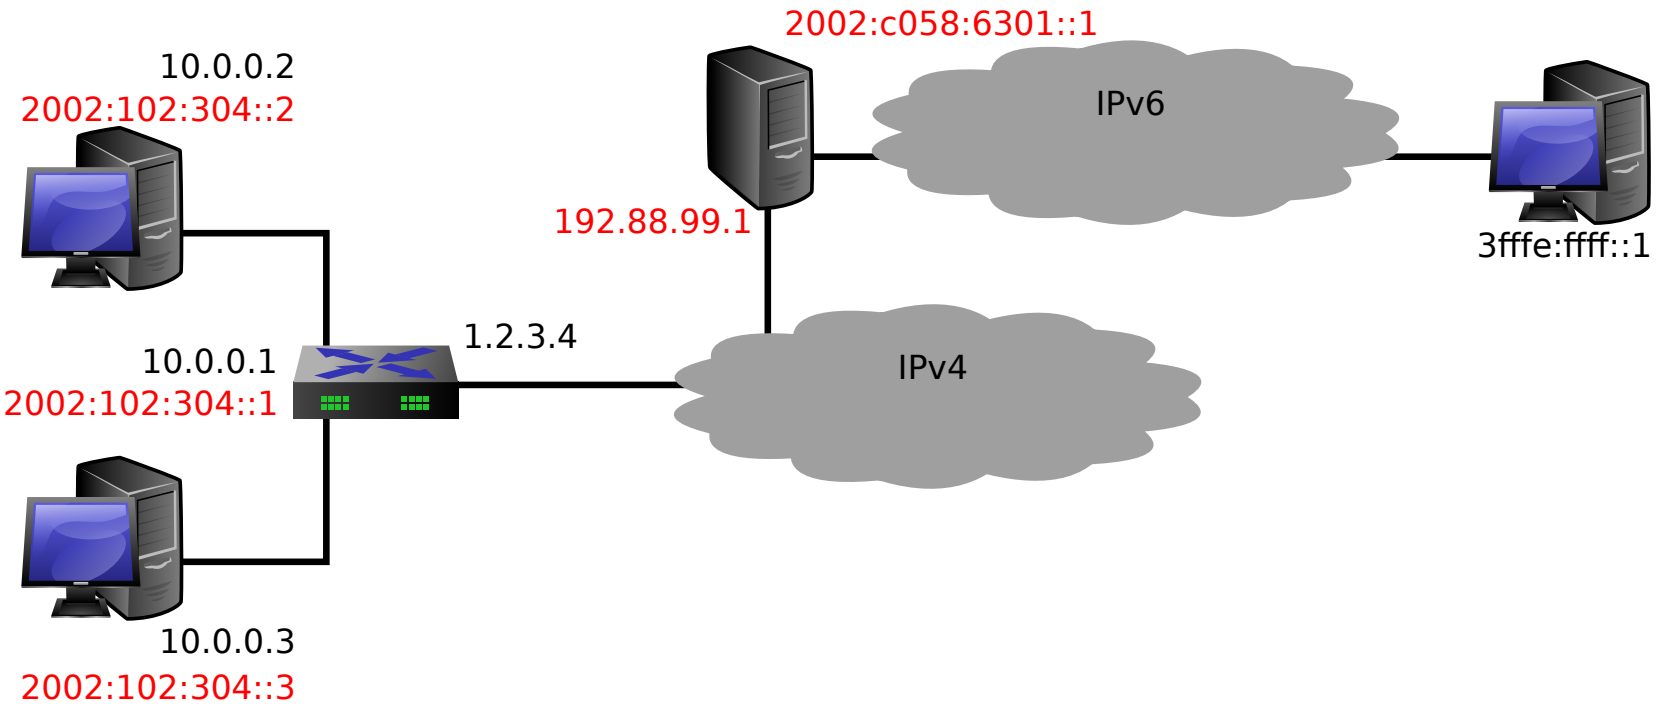

Autotunelování 6to4

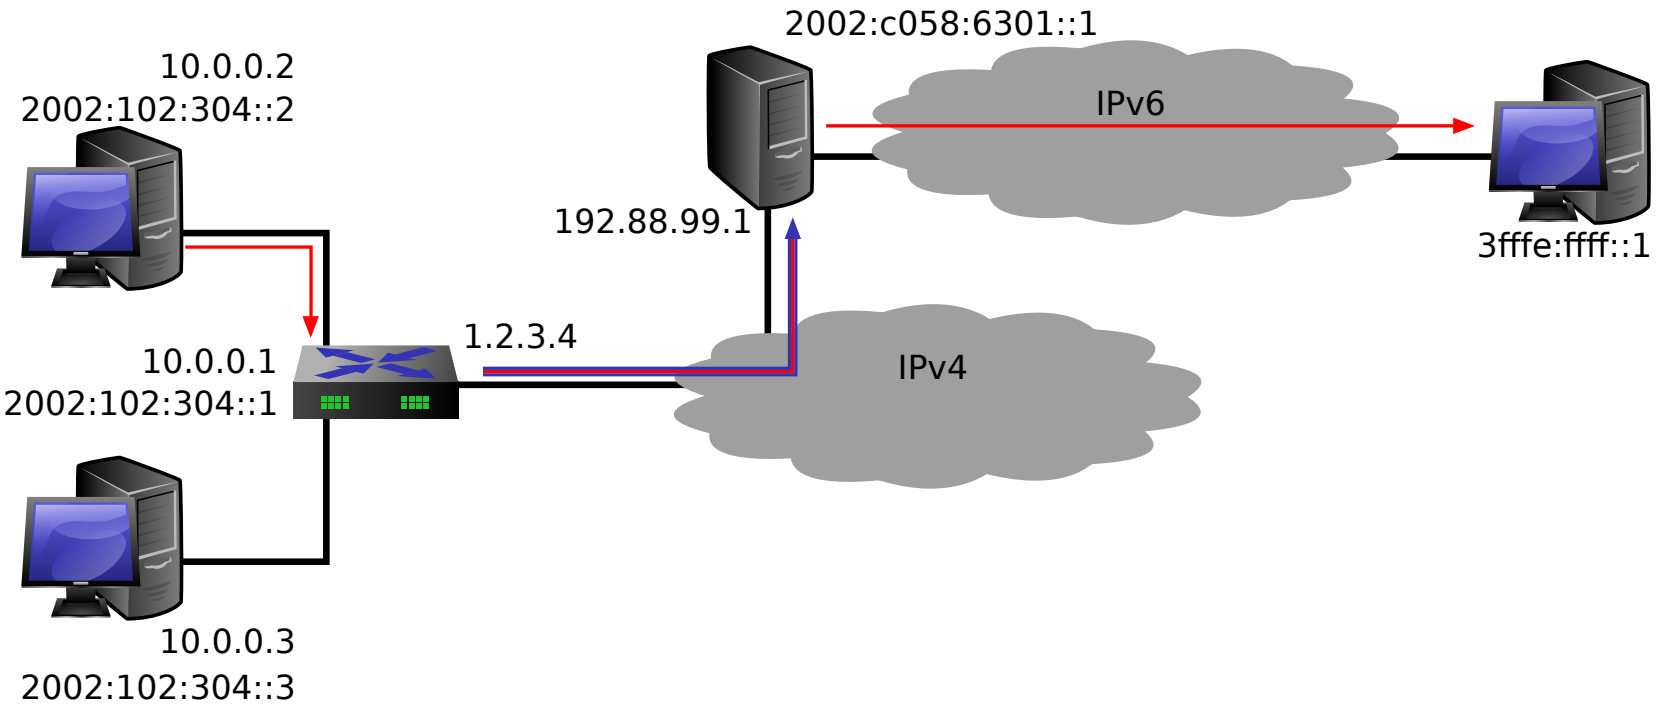

Autotunelování 6to4

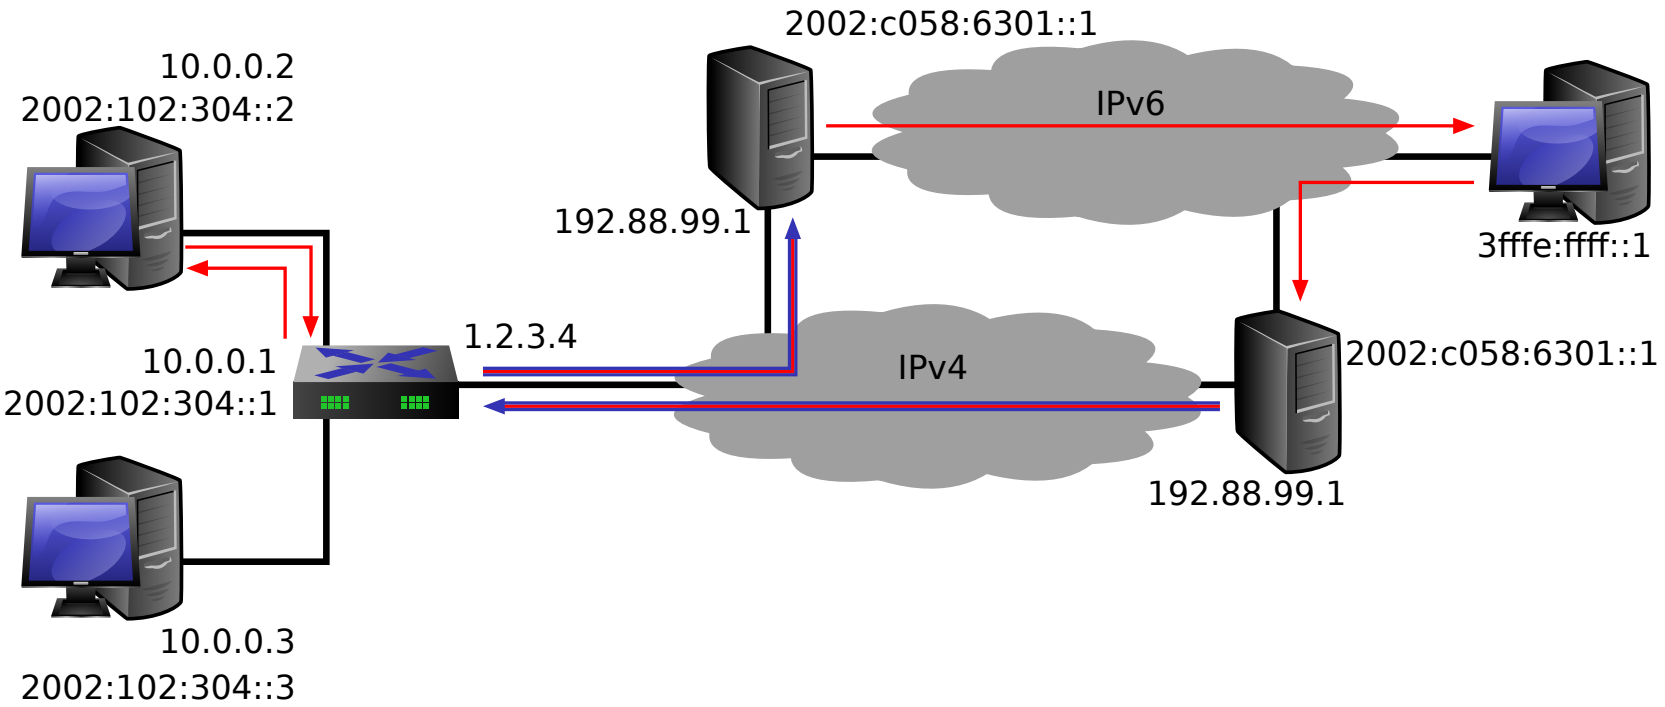

Odkazy

- Linux and IPv6 howto – http://www.tldp.org/HOWTO/Linux+IPv6-HOWTO/
- Pavel Satrapa: IPv6 – https://knihy.nic.cz/files/edice/IPv6-2019.pdf

Čtení na dobrou noc

Zamyšlení s odstupem

The world in which IPv6 was a good design
`https://apenwarr.ca/log/20170810`

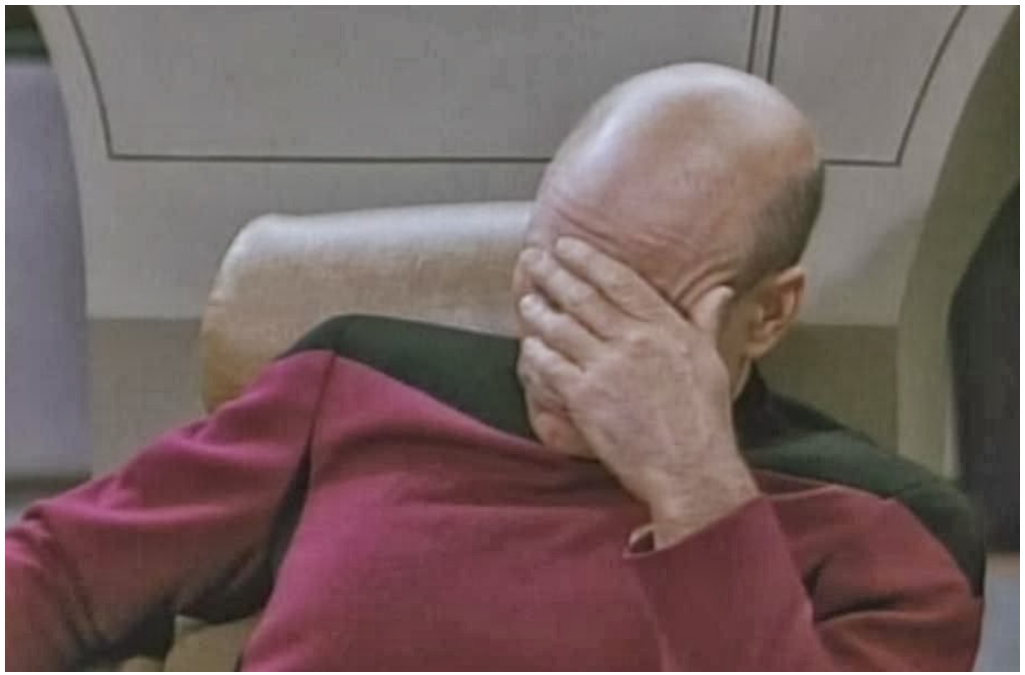

ICMP

- Internet Control Message Protocol.
- Chybové a řídící zprávy IPv4.
- ICMP zpráva – uvnitř IPv4 datagramu.
- Podává se původnímu odesílateli příslušného datagramu.
- RFC 792.

Formát ICMP zpráv

- Type – 8 bitů – typ ICMP zprávy.
- Code – 8 bitů – přídavný kód.
- Checksum – 16 bitů – kontrolní součet ICMP zprávy.

ICMP Echo Request/Echo

- Pro testování dostupnosti počítače.
- Každý počítač v síti je povinen na ICMP echo request (*type* = 8) odpovědět ICMP echo (*type* = 0) se stejnou datovou částí (RFC 1122, sekce 3.2.2.6).
- Další položky: 16 bitů identifikace, 16 bitů číslo sekvence.

Otázka:

K čemu je vlastně pole „identifikace“?

ICMP Echo Request/Echo

- Pro testování dostupnosti počítače.
- Každý počítač v síti je povinen na ICMP echo request (*type* = 8) odpovědět ICMP echo (*type* = 0) se stejnou datovou částí (RFC 1122, sekce 3.2.2.6).
- Další položky: 16 bitů identifikace, 16 bitů číslo sekvence.

Otázka:

K čemu je vlastně pole „identifikace“?

Neodsažitelnost adresáta

- ICMP destination unreachable – type 3.
- Code obsahuje bližší informace:
  - Network unreachable
  - Host unreachable
  - Protocol unreachable
  - Port unreachable
  - Fragmentation needed
  - Source route failed
- Data – IP hlavička a prvních 64 bitů původního packetu.

Otázka:

Kdy přesně se posílá host unreachable?

Neodsažitelnost adresáta

- ICMP destination unreachable – type 3.
- Code obsahuje bližší informace:
  - Network unreachable
  - Host unreachable
  - Protocol unreachable
  - Port unreachable
  - Fragmentation needed
  - Source route failed
- Data – IP hlavička a prvních 64 bitů původního packetu.

Otázka:

Kdy přesně se posílá host unreachable?

Zahlcení routeru

- ICMP source quench
- Type = 4, code = 0, dále hlavička a 64 bitů ze začátku IP datagramu.
- Vysílající strana má reagovat snížením toku dat.
- Nemusí znamenat zahození datagramu.

Protokoly vyšších vrstev mají svoje řízení toku. Source quench téměř vždy znamená problém v konfiguraci sítě.

Přesměrování datagramů

- ICMP redirect – type = 5.
- Žádost o přesměrování dalších packetů na jiný router.
- Code určuje typ přesměrování:
  - Redirect for the network
  - Redirect for the host
  - Redirect for the ToS and network
  - Redirect for the ToS and host
- Data – adresa nového routeru, IP hlavička a prvních 64 bitů dat IP datagramu.

Úkol:

Jak pozná router, že má poslat ICMP redirect?

Přesměrování datagramů

- ICMP redirect – type = 5.
- Žádost o přesměrování dalších packetů na jiný router.
- Code určuje typ přesměrování:
  - Redirect for the network
  - Redirect for the host
  - Redirect for the ToS and network
  - Redirect for the ToS and host
- Data – adresa nového routeru, IP hlavička a prvních 64 bitů dat IP datagramu.

Úkol:

Jak pozná router, že má poslat ICMP redirect?

Překročení času

- ICMP time limit exceeded – type = 11.
- Code:
  - TTL dosáhlo nuly
  - Překročen čas znovusestavení z fragmentů
- Data – IP hlavička a prvních 64 bitů dat IP datagramu.

Chyba v datagramu

- ICMP parameter problem – type = 12.
- Code:
  - 0: položka „pointer“ není platná.
  - 1: položka „pointer“ je platná.
- Pointer – 8 bitů, zarovnáno na 32 bitů. Odkaz na místo, kde je problém.
- Data – IP hlavička a prvních 64 bitů dat IP datagramu.

Další ICMP zprávy

- Timestamp request (type = 13).
- Timestamp reply (type = 14).
- Information request (type = 15) – žádost o adresu sítě.
- Information reply (type = 16).
- Address mask request (type = 17).
- Address mask reply (type = 18).

ICMPv6

- Analogie ICMP pro IPv6
- Protokol (next header) číslo 58

Formát packetů:

- Type – 8 bitů, nejvyšší bit odlišuje chybové a informativní zprávy.
- Code – 8 bitů, bližší určení.
- Checksum – 16 bitů.

Chybové zprávy ICMPv6

- 1 Destination unreachable.
- 2 Packet too big.
- 3 Time exceeded.
- 4 Parameter problem.

Informativní zprávy – I.

- 128 Echo request.
- 129 Echo reply.
- 130 Group Membership Query.
- 131 Group Membership Report.
- 132 Group Membership Reduction.
- 133 Router Solicitation.
- 134 Router Advertisement.
- 135 Neighbor Solicitation.
- 136 Neighbor Advertisement.
- 137 Redirect.
- 138 Router Renumbering.

Informativní zprávy – II.

- 139 ICMP Node Information Query.
- 140 ICMP Node Information Response.
- 141 Inverse Neighbor Discovery Solicitation Message.
- 142 Inverse Neighbor Discovery Advertisement Message.
- 143 MLDv2 Multicast Listener Report.
- 144 Home Agent Address Discovery Request Message.
- 145 Home Agent Address Discovery Reply Message
- 146 Mobile Prefix Solicitation.
- 147 Mobile Prefix Advertisement

Informativní zprávy – III.

- 148 Certification Path Solicitation.
- 149 Certification Path Advertisement.
- 150 Experimental mobility protocols.
- 151 Multicast Router Advertisement.
- 152 Multicast Router Solicitation.
- 153 Multicast Router Termination.

Neigbour dicovery versus ARP

Multicast versus broadcast.

Protokol UDP

- User Datagram Protocol
- Nespojovaná transportní služba
- Porty – rozlišení mezi více adresáty (a zdroji) v rámci jednoho počítače. 16-bitové celé číslo.
- Well-known ports – porty, na kterých lze očekávat obecně známé služby.

Formát UDP rámce

- Source port – 16 bitů.
- Destination port – 16 bitů.
- Length – 16 bitů.
- Checksum – 16 bitů. Nepovinný. Součet UDP hlavičky a IP pseudohlavičky.

IP pseudohlavička

- Zdrojová IP adresa, cílová IP adresa.
- Zarovnání – 8 nulových bitů.
- Protokol – 8 bitů.
- Délka packetu – 16 bitů.

Formát UDP rámce

- Source port – 16 bitů.
- Destination port – 16 bitů.
- Length – 16 bitů.
- Checksum – 16 bitů. Nepovinný. Součet UDP hlavičky a IP pseudohlavičky.

IP pseudohlavička

- Zdrojová IP adresa, cílová IP adresa.
- Zarovnání – 8 nulových bitů.
- Protokol – 8 bitů.
- Délka packetu – 16 bitů.

Protokol TCP

- Transmission Control Protocol
- Spojovaná služba
- Spolehlivá služba
- Duplexní proud dat
- Buffering
- Porty – podobně jako v UDP

Garance protokolu TCP

- Správné pořadí datagramů.
- Duplicitní datagramy jsou vyřazeny.
- Potvrzování přenosu dat.
- Opakování přenosu, nedojde-li potvrzení.

TCP spojení

- Klient-server
  - Server – *poslouchá* (listen) na portu a *přijme* (accept) spojení.
  - Klient – *spojuje* se (connect) na port cílového stroje. Může navazovat i z konkrétního zdrojového portu.
  - Navázání spojení – *three-way handshake*

Identifikace TCP spojení

Celá čtveřice:

- Zdrojová IP adresa, TCP port
- Cílová IP adresa, TCP port

TCP spojení

- Klient-server
- Server – *poslouchá* (listen) na portu a *přijme* (accept) spojení.
- Klient – *spojuje* se (connect) na port cílového stroje. Může navazovat i z konkrétního zdrojového portu.
- Navázání spojení – *three-way handshake*

Identifikace TCP spojení

Celá čtveřice:

- Zdrojová IP adresa, TCP port
- Cílová IP adresa, TCP port

TCP spojení

- Klient-server
- Server – *poslouchá* (listen) na portu a *přijme* (accept) spojení.
- Klient – *spojuje* se (connect) na port cílového stroje. Může navazovat i z konkrétního zdrojového portu.
- Navázání spojení – *three-way handshake*

Identifikace TCP spojení

Celá čtveřice:

- Zdrojová IP adresa, TCP port
- Cílová IP adresa, TCP port

TCP spojení

- Klient-server
- Server – *poslouchá* (listen) na portu a *přijme* (accept) spojení.
- Klient – *spojuje* se (connect) na port cílového stroje. Může navazovat i z konkrétního zdrojového portu.
- Navázání spojení – *three-way handshake*

Identifikace TCP spojení

Celá čtveřice:

- Zdrojová IP adresa, TCP port
- Cílová IP adresa, TCP port

TCP spojení

- Klient-server
- Server – *poslouchá* (listen) na portu a *přijme* (accept) spojení.
- Klient – *spojuje* se (connect) na port cílového stroje. Může navazovat i z konkrétního zdrojového portu.
- Navázání spojení – *three-way handshake*

Identifikace TCP spojení

Celá čtveřice:

- Zdrojová IP adresa, TCP port
- Cílová IP adresa, TCP port

Vytvoření TCP spojení

Three-way handshake

- Klient $\longrightarrow$ Server: SYN (seq = x)
- Server $\longrightarrow$ Klient: SYN-ACK (seq = y, ack = x+1)
- Klient $\longrightarrow$ Server: ACK (ack = y+1)

- Číslo sekvence – 32 bitů
- Pořadí dat rámci v TCP spojení
- Bezpečnost!

Vytvoření TCP spojení

Three-way handshake

- Klient $\longrightarrow$ Server: SYN (seq = x)
- Server $\longrightarrow$ Klient: SYN-ACK (seq = y, ack = x+1)
- Klient $\longrightarrow$ Server: ACK (ack = y+1)

- Číslo sekvence – 32 bitů
- Pořadí dat rámci v TCP spojení
- Bezpečnost!

Vytvoření TCP spojení

Three-way handshake

- Klient $\longrightarrow$ Server: SYN (seq = x)
- Server $\longrightarrow$ Klient: SYN-ACK (seq = y, ack = x+1)
- Klient $\longrightarrow$ Server: ACK (ack = y+1)

- Číslo sekvence – 32 bitů
- Pořadí dat rámci v TCP spojení
- Bezpečnost!

Vytvoření TCP spojení

Three-way handshake

- Klient $\longrightarrow$ Server: SYN (seq = x)
- Server $\longrightarrow$ Klient: SYN-ACK (seq = y, ack = x+1)
- Klient $\longrightarrow$ Server: ACK (ack = y+1)

- Číslo sekvence – 32 bitů
- Pořadí dat rámci v TCP spojení
- Bezpečnost!

Vytvoření TCP spojení

Three-way handshake

- Klient $\longrightarrow$ Server: SYN (seq = x)
- Server $\longrightarrow$ Klient: SYN-ACK (seq = y, ack = x+1)
- Klient $\longrightarrow$ Server: ACK (ack = y+1)

- Číslo sekvence – 32 bitů
- Pořadí dat rámci v TCP spojení
- Bezpečnost!

Útok na sekvenční čísla

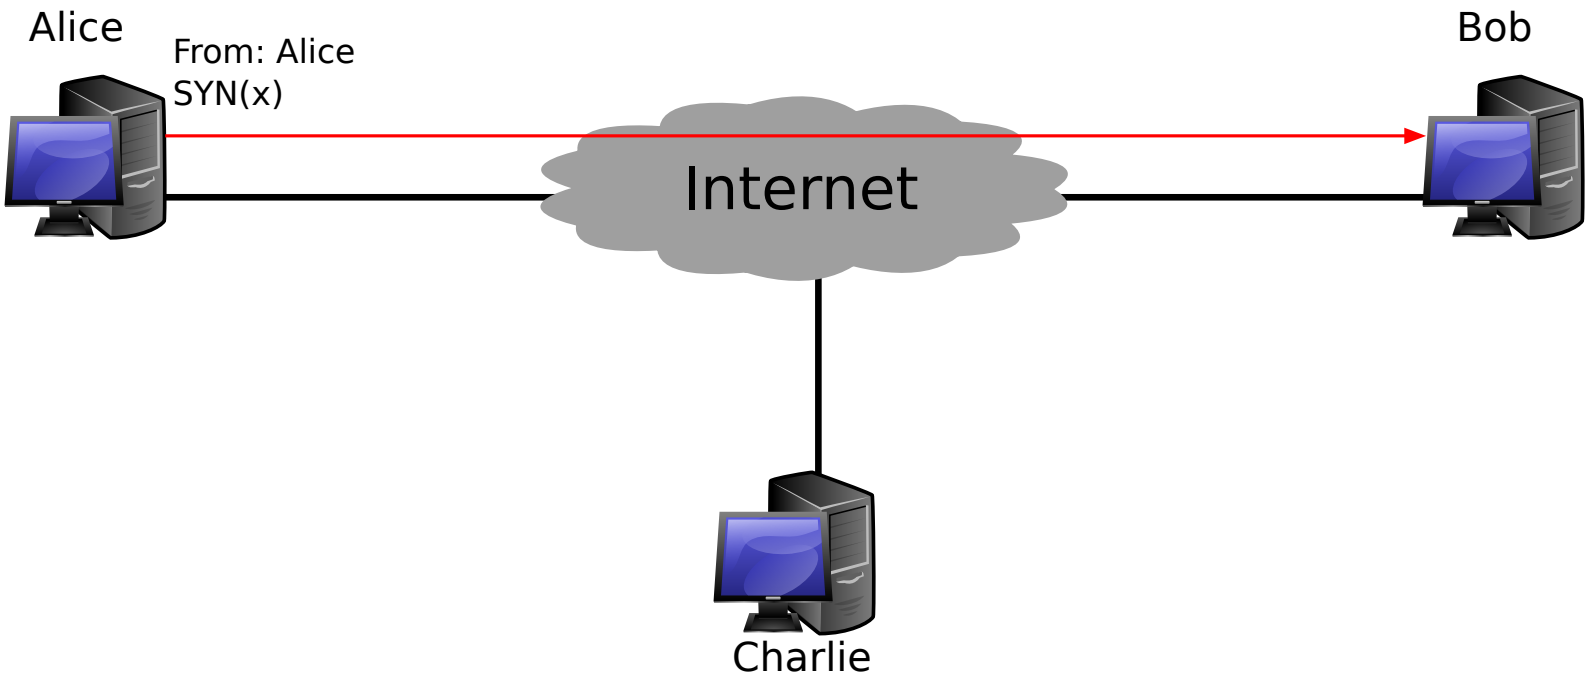

Útok na sekvenční čísla

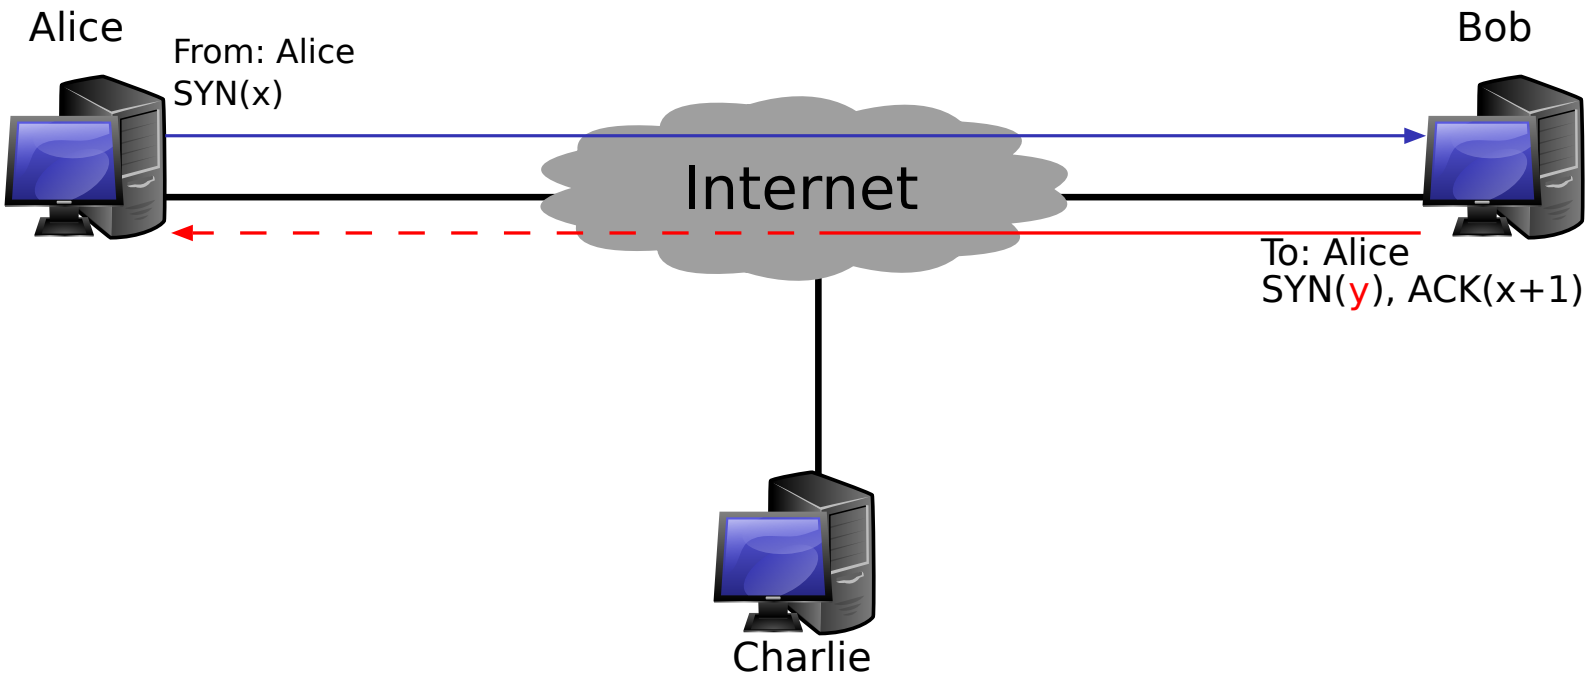

Útok na sekvenční čísla

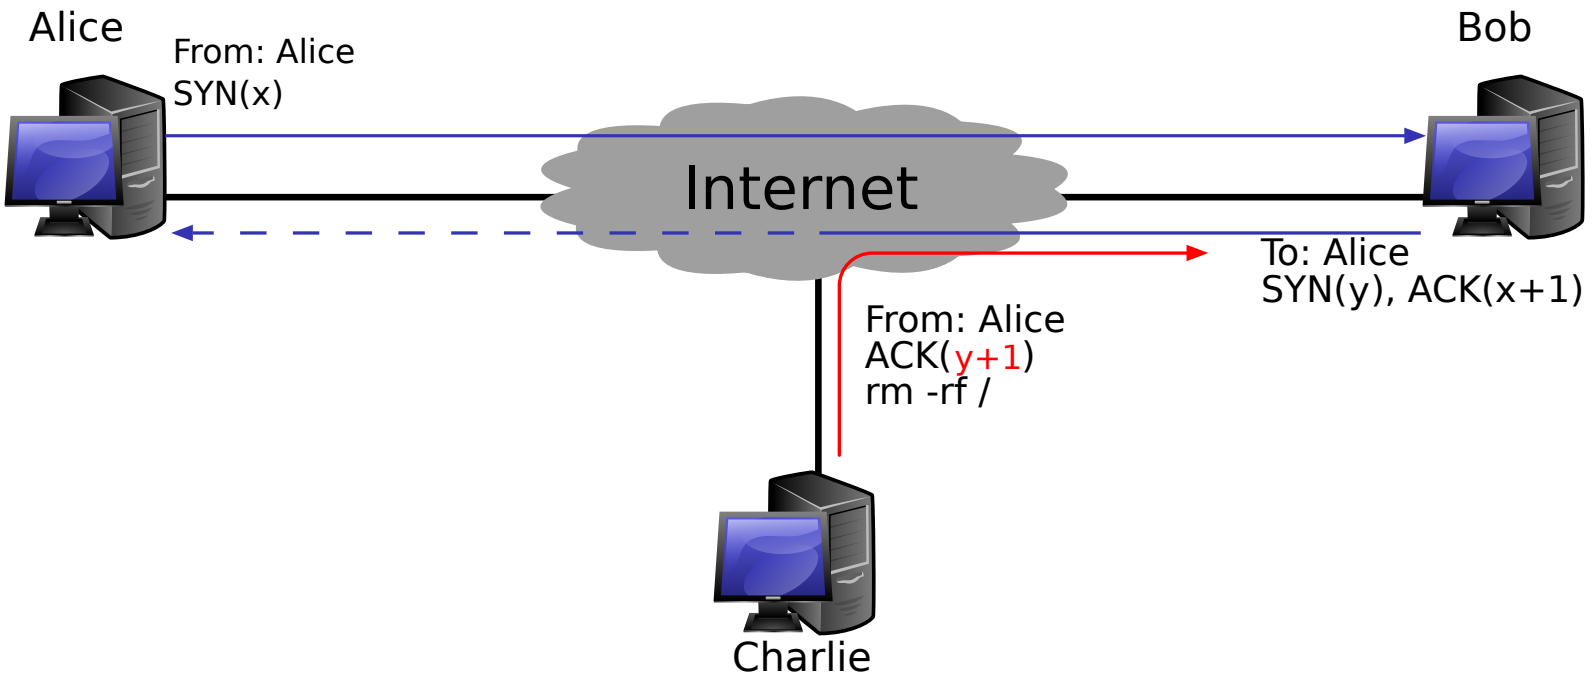

Uzavření TCP spojení

- Uzavření spojení – každý směr zvlášť nebo simultánně.
- Ukončovací rámec – příznak FIN.
- Robustnost – i FIN se potvrzuje.

Potvrzování packetů

- Problém: potvrzovat každý packet?

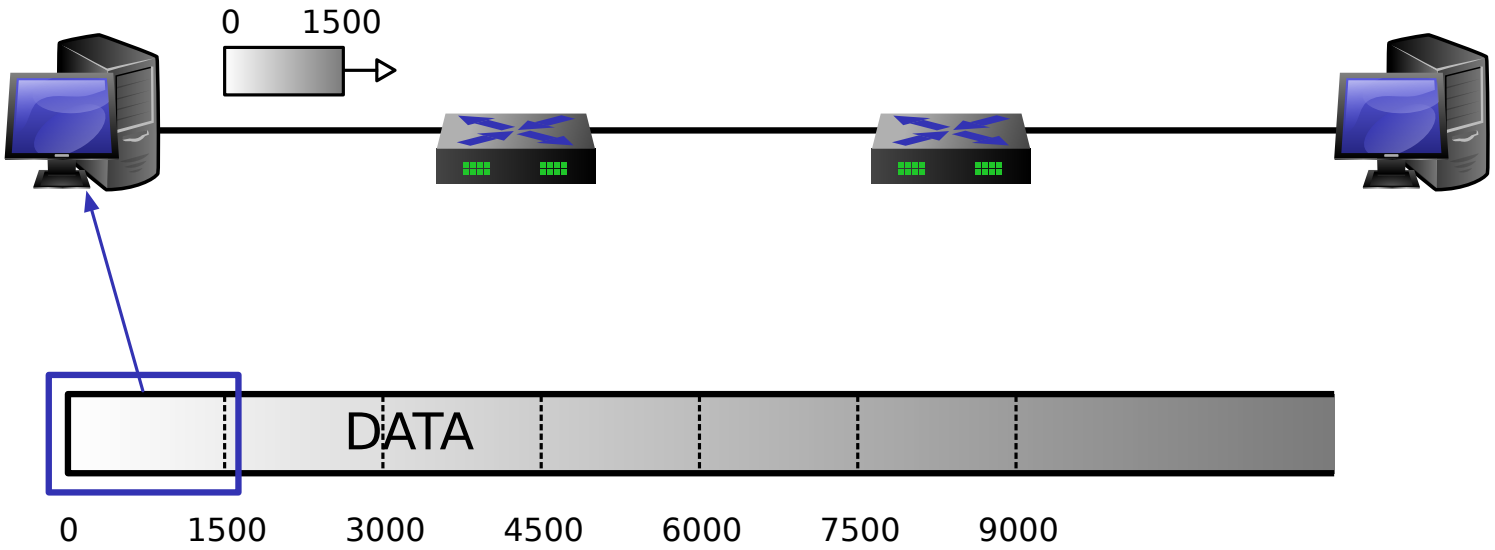

Potvrzování packetů

- Problém: potvrzovat každý packet?

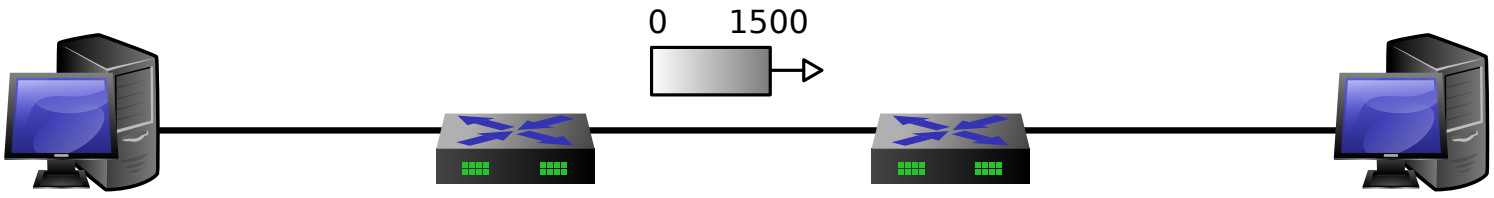

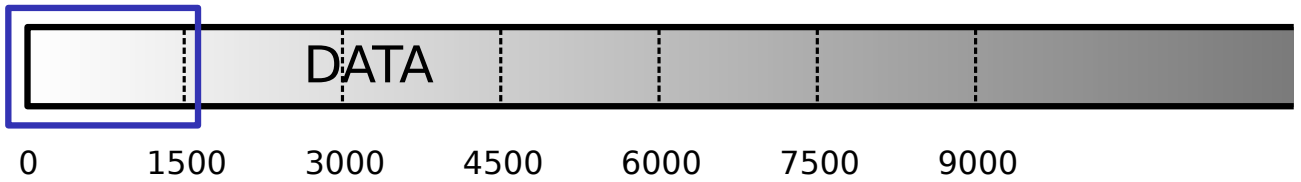

Potvrzování packetů

- Problém: potvrzovat každý packet?

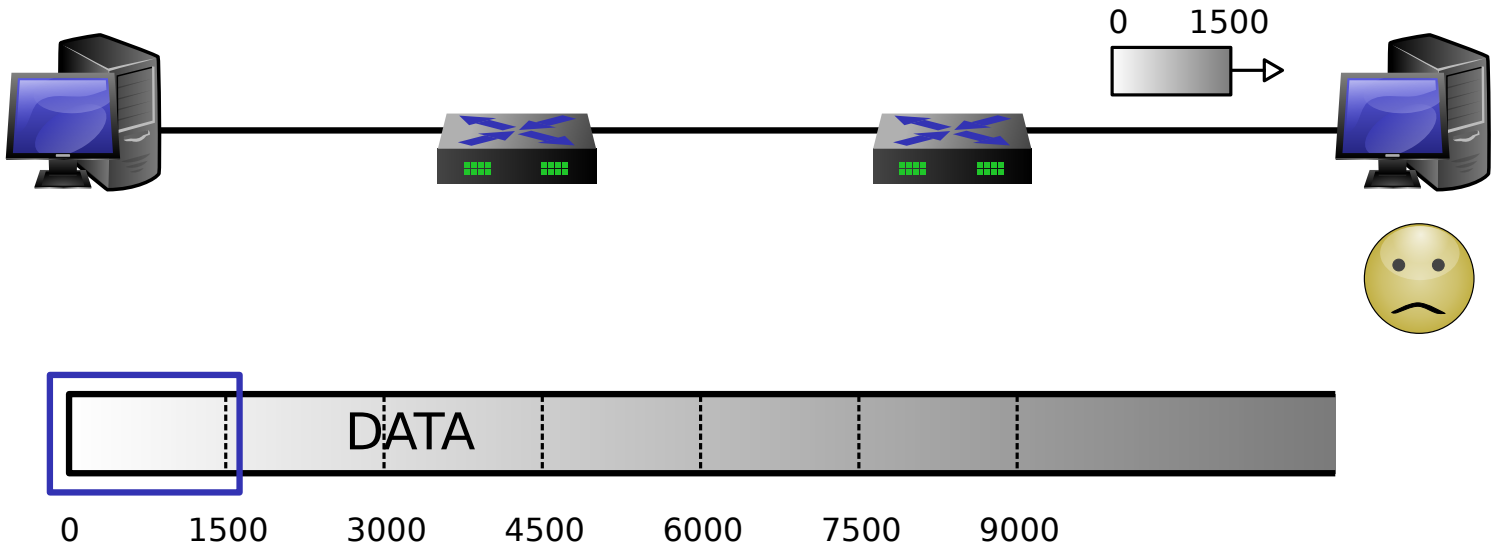

Klouzající okno

- Velikost – dohodnuta při vytváření spojení.

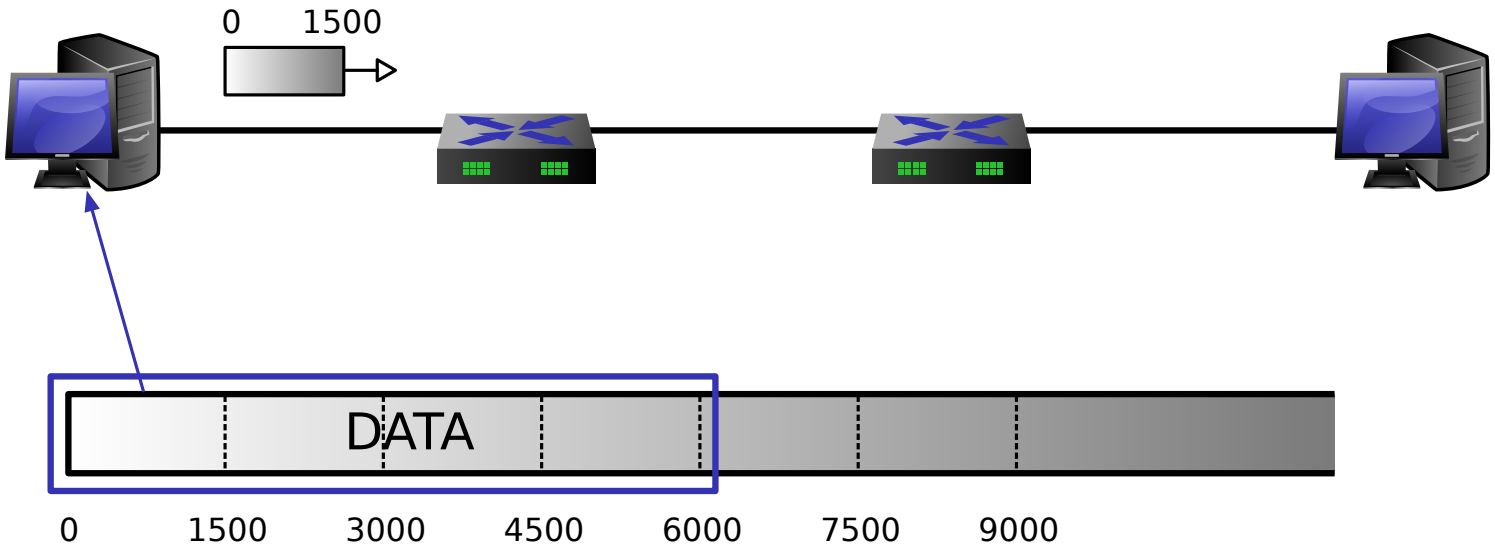

Klouzající okno

- Velikost – dohodnuta při vytváření spojení.

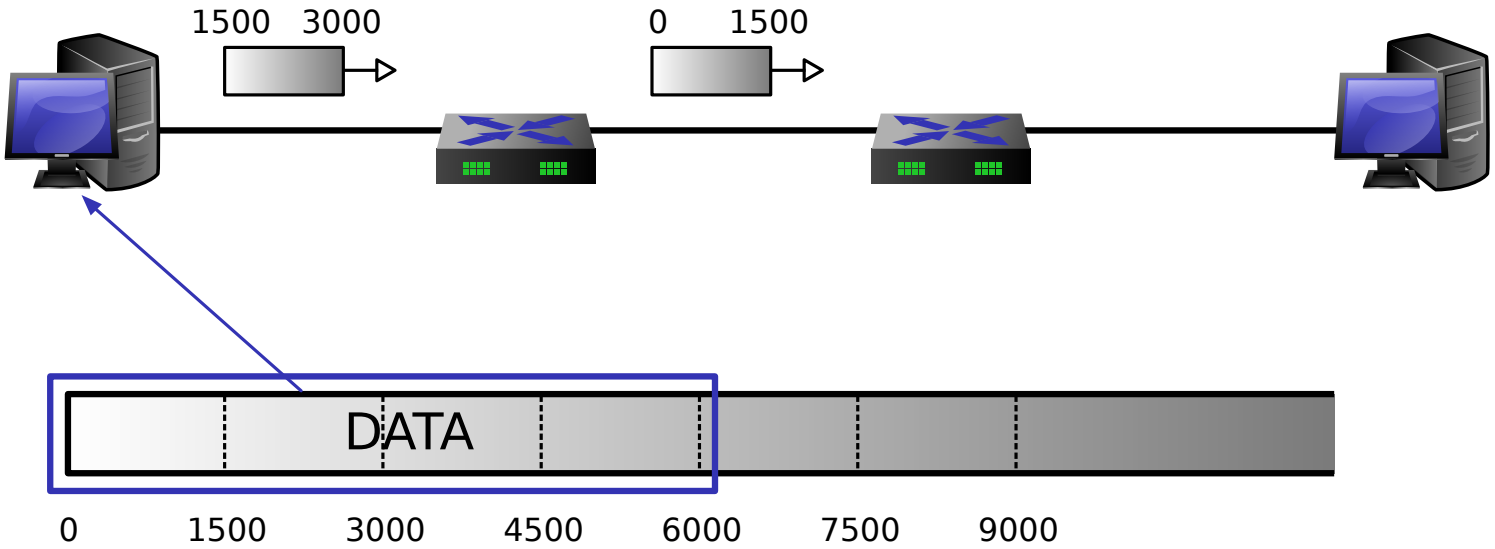

Klouzající okno

- Velikost – dohodnuta při vytváření spojení.

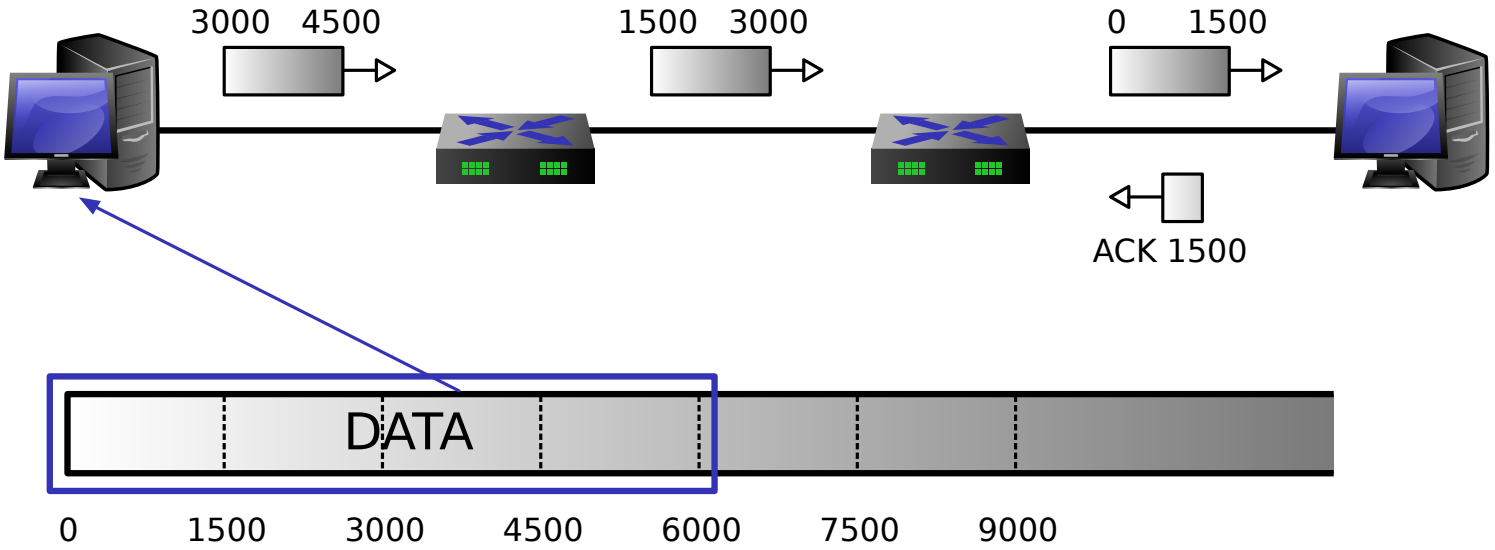

Klouzající okno

- Velikost – dohodnuta při vytváření spojení.

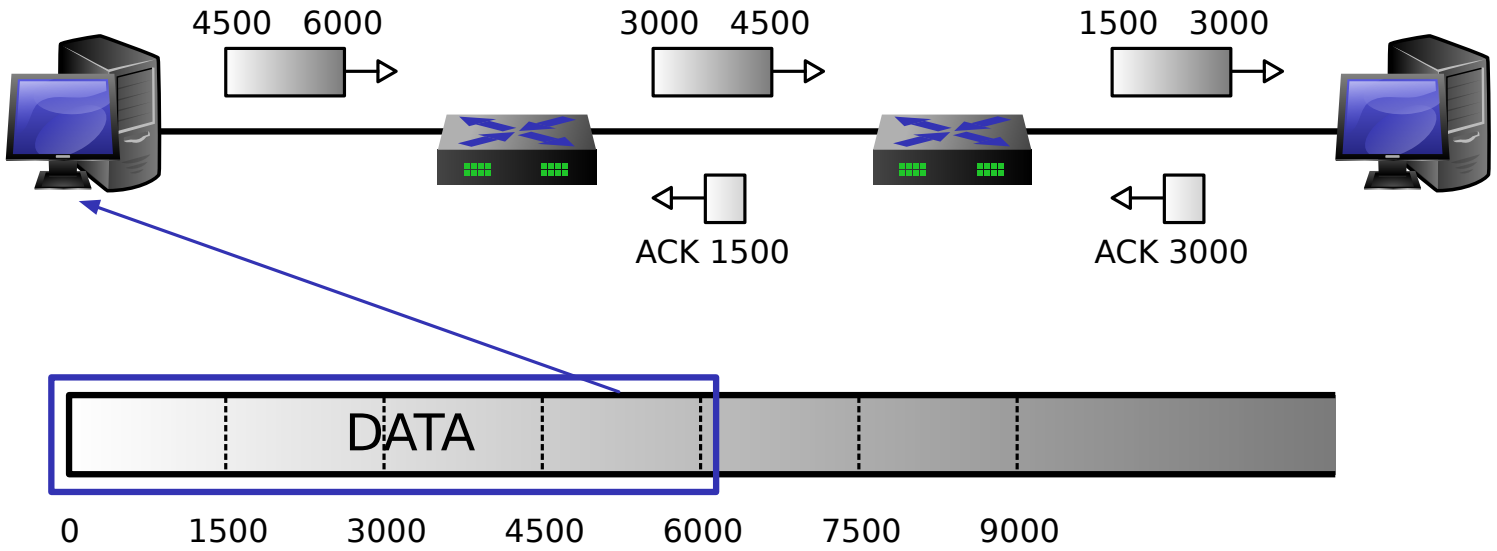

Klouzající okno

- Velikost – dohodnuta při vytváření spojení.

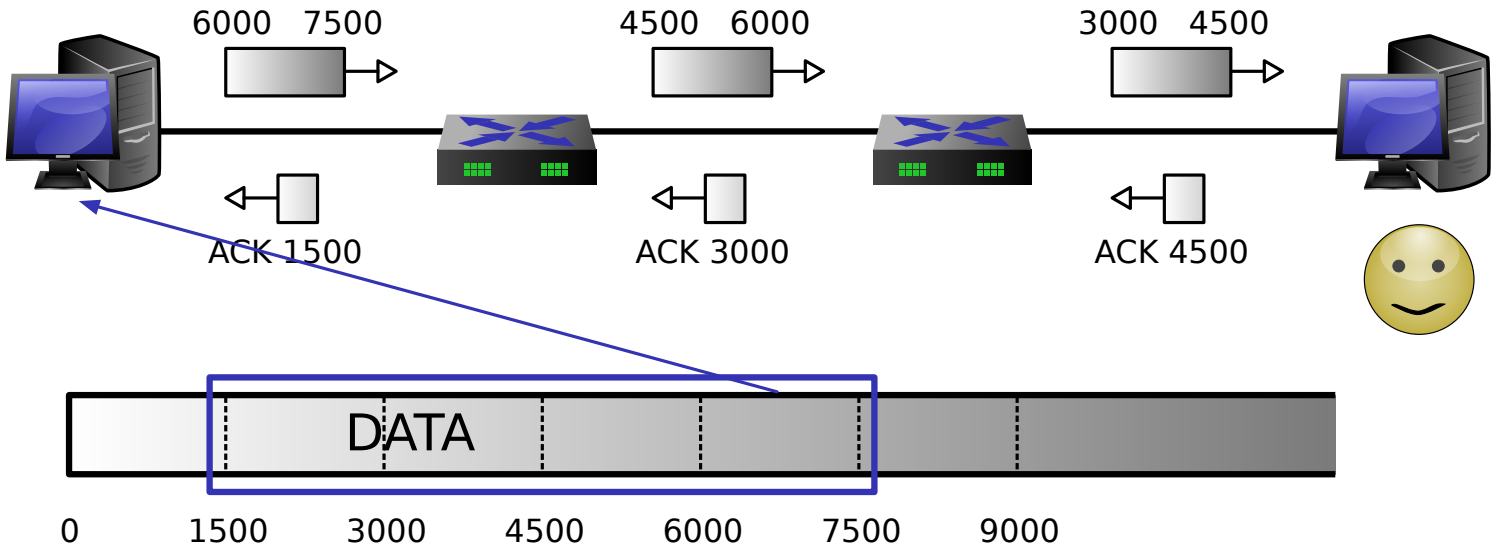

Vlastnosti TCP

- Potvrzování – ACK packet, piggybacking při duplexním spojení.
- Změna velikosti okna – každý ACK packet obsahuje počet slov, který je druhá strana ochotna přijmout.
- Exponential back-off – v případě ztráty datagramu.
- Out-of-band data – urgentní data, zasílaná mimo pořadí.

Formát TCP rámce

- Source port – 16 bitů.
- Destination port – 16 bitů.
- Sequence number – 32 bitů.
- Acknowledgement number – 32 bitů.
- Header length – 4 bity – počet 32-bitových slov, velikost hlavičky včetně volitelných položek.
- Window – 16 bitů. Počet slov, které je odesílatel schopen přijmout.
- Checksum – 16 bitů – kontrolní součet včetně pseudozáhlaví (viz UDP).
- Urgent pointer – poslední bajt urgentních dat.
- Options – zarovnáno na 32 bitů – volitelné položky (např. MSS, SACK, MD5, ...).

Příznaky TCP rámce

- URG – 1 bit. Doručit tento segment co nejrychleji. Položka *Urgent pointer* je platná.
- SYN – 1 bit. Synchronizace sekvenčních čísel; žádost o zřízení spojení.
- ACK – 1 bit. Položka *Acknowledgement number* je platná.
- RST – 1 bit. Požadavek na reset spojení („Connection reset by peer“) – posílá se jako odpověď na packet bez SYN flagu, který nepřísluší žádnému existujícímu spojení.
- PSH – 1 bit (push). Požadavek na rychlé doručení tohoto segmentu vyšší vrstvě sítě.
- FIN – 1 bit. Ukončení spojení – odesílatel vyslal všechna data.

Bufferbloat

- Jak TCP řídí tok dat?
  - Slow start, exponential back-off.
  - `https://vimeo.com/14439742`
- K čemu jsou buffery v routerech?
  - `http://guido.appenzeller.net/anims/`

Bufferbloat

- Jak TCP řídí tok dat?
  - Slow start, exponential back-off.
  - `https://vimeo.com/14439742`
- K čemu jsou buffery v routerech?
  - `http://guido.appenzeller.net/anims/`

SCTP

- Stream Control Transmission Protocol
- Spojovaný protokol
- Více datových proudů v jednom spojení
- Multihoming
- Multipath
- Zachování hranice zpráv
- Volitelné zachování pořadí
- Spolehlivý přenos uspořádaných i neuspořádaných zpráv

DCCP

- Datagram Congestion Control Protocol
- Spojovaný protokol
- Nespolehlivý
- Zachování hranice zpráv
- Congestion control

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
https://lwn.net/Articles/814522/

Protocol Ossification

- NATy, middleboxy, firewally, ...
- TCP Early Congestion Notification
- Problematické nasazování nových protokolů
- Přesun z kernelu do user-space?
- QUIC: nad UDP + TLS, více streamů

Čtení na dobrou noc

A QUIC Look at HTTP/3
`https://lwn.net/Articles/814522/`

Programování síťových aplikací

- Několik druhů API
- BSD Sockets – de facto standard, nejpoužívanější.
- Streams – pochází z UNIXu System V.

BSD Sockets API

- API pro meziprocesovou komunikaci – někdy nazývané BSD IPC (oproti SysV IPC = semafory, fronty zpráv a sdílená paměť).
- Nezávislé na síťovém protokolu – je možné provozovat nad různými *rodinami protokolů*.

Příklad: Rodiny protokolů v Linuxu

```
PF_UNIX      PF_IPX        PF_BRIDGE   PF_AX25
PF_INET      PF_APPLETALK  PF_NETROM   PF_NETLINK
PF_INET6     PF_AAL5       PF_X25      ...
```

BSD Sockets API

- API pro meziprocesovou komunikaci – někdy nazývané BSD IPC (oproti SysV IPC = semafory, fronty zpráv a sdílená paměť).
- Nezávislé na síťovém protokolu – je možné provozovat nad různými *rodinami protokolů*.

Příklad: Rodiny protokolů v Linuxu

```
PF_UNIX      PF_IPX        PF_BRIDGE   PF_AX25
PF_INET      PF_APPLETALK  PF_NETROM   PF_NETLINK
PF_INET6     PF_AAL5       PF_X25      ...
```

Co je socket?

- Socket = schránka, zásuvka
- Jeden konec síťového spojení
- Deskriptor
- Rozšíření abstrakce souboru
  - Běžné souborové operace – `read(2)`, `write(2)`, `close(2)`
  - Speciální socketové služby – `sendmsg(2)`, `recvmsg(2)`, ...

Vytvoření socketu

socket(2)

```
#include <sys/types.h>
#include <sys/socket.h>

int socket(int domain, int type, int proto);
```

Vytvoří socket a vrátí jeho deskriptor.

- `domain` – rodina adres – způsob komunikace přes socket. Odpovídá rodině protokolů. `AF_UNIX`, `AF_INET`, atd.
- `type` – sémantika komunikace. Viz dále.
- `proto` – protokol. Obvykle existuje pro každou kombinaci (`domain`, `type`) nejvýše jeden. Pak zde může být 0. Viz `/etc/protocols`.

Typy socketů

Položka `type` určuje chování socketu a jeho schopnosti.

- `SOCK_STREAM` – plně duplexní spolehlivý uspořádaný proud dat, případně podporuje i posílání dat mimo pořadí (out-of-band data).
- `SOCK_DGRAM` – datagramová služba.
- `SOCK_RAW` – přímý přístup na síťové zařízení. Povoleno jen superuživateli.
- `SOCK_SEQPACKET` – uspořádané spolehlivé duplexní spojení pro přenost packetů do jisté maximální délky. Může být požadováno načtení packetu jedním `read(2)` nebo podobnou službou.

Sockety jako roura

socketpair(2) — Dvojice socketů

```
#include <sys/types.h>
#include <sys/socket.h>

int socketpair(int domain, int type, int proto,
    int sd[2]);
```

- Nepojmenovaná dvojice propojených socketů.
- `sd[0]` a `sd[1]` jsou ekvivaletní.

Úkol:

Vysvětlete rozdíl mezi `sd[0]`, `sd[1]` ze `socketpair(2)` a `pd[0]`, `pd[1]` z `pipe(2)`.

Sockety jako roura

socketpair(2) — Dvojice socketů

```
#include <sys/types.h>
#include <sys/socket.h>

int socketpair(int domain, int type, int proto,
    int sd[2]);
```

- Nepojmenovaná dvojice propojených socketů.
- `sd[0]` a `sd[1]` jsou ekvivaletní.

Úkol:

Vysvětlete rozdíl mezi `sd[0]`, `sd[1]` ze `socketpair(2)` a `pd[0]`, `pd[1]` z `pipe(2)`.

Příklad: /etc/protocols

```
ip   0   IP   # internet protocol
icmp 1   ICMP # internet control message p.
igmp 2   IGMP # internet group multicast p.
ggp  3   GGP  # gateway-gateway p.
tcp  6   TCP  # transmission control p.
pup  12  PUP  # PARC universal packet p.
udp  17  UDP  # user datagram p.
raw  255 RAW  # RAW IP interface
```

Tabulka protokolů

getprotoent(3), getprotoby*(2)

```
#include <netdb.h>

struct protoent *getprotoent();
struct protoent *getprotobyname(char *name);
struct protoent *getprotobynumber(int proto);
void setprotoent(int stayopen);
void endprotoent();

struct protoent {
    char  *p_name;
    char **p_aliases;
    int    p_proto;
}
```

Tabulka protokolů

- Funkce nejsou reentrantní
- Reentrantní verze: `getprotoent_r(3)`

Úkol:

Napište programy `getprotobyname` a `getprotobynumber`, které na standardní vstup vypíší číslo protokolu na základě jména a naopak.

Vzorová řešení programovacích úkolů

`http://www.fi.muni.cz/~kas/pv077/`

Tabulka protokolů

- Funkce nejsou reentrantní
- Reentrantní verze: `getprotoent_r(3)`

Úkol:

Napište programy `getprotobyname` a `getprotobynumber`, které na standardní vstup vypíší číslo protokolu na základě jména a naopak.

Vzorová řešení programovacích úkolů

http://www.fi.muni.cz/~kas/pv077/

Tabulka protokolů

- Funkce nejsou reentrantní
- Reentrantní verze: `getprotoent_r(3)`

Úkol:

Napište programy `getprotobyname` a `getprotobynumber`, které na standardní vstup vypíší číslo protokolu na základě jména a naopak.

Vzorová řešení programovacích úkolů

`http://www.fi.muni.cz/~kas/pv077/`

Adresace socketů

- Adresa socketu – „Jak se se socketem spojit?“
- Adresace – závisí na rodině protokolů.

struct sockaddr **Obecná adresa socketu**

```
#include <sys/socket.h>

struct sockaddr {
    sa_family_t sa_family;
    char        sa_data[14];
};
```

Adresa socketu AF_UNIX

- Adresace cestou v souborovém systému

struct sockaddr_un

```
#include <sys/socket.h>
#include <sys/un.h>

struct sockaddr_un {
    sa_family_t sun_family;
    char        sun_path[UNIX_PATH_MAX];
};
```

Speciality UNIXových socketů

- Zjištění práv protistrany
- Zasílání deskriptorů 
- Abstraktní sockety 

Adresa socketu AF_INET

- Adresace IPv4 adresou a portem

struct sockaddr_in

```
#include <sys/socket.h>
#include <netinet/in.h>

struct sockaddr_in {
    sa_family_t    sin_family;
    in_port_t      sin_port; /* net order */
    struct in_addr sin_addr;
};

struct in_addr {
    uint32_t s_addr; /* net order */
};
```

Síťový formát dat

- Komunikace mezi různými stroji – nutnost stanovit pořadí bajtů v 16-bitovém a 32-bitovém čísle.
- Síťový formát dat – big endian.
- Nativní formát dat
  - little-endian: ia32, ia64, x86-64, AXP, ARM
  - big-endian: SPARC, HP-PA, Power
  - Některé platformy: podpora obojí endianity (Power/PPC, MIPS).

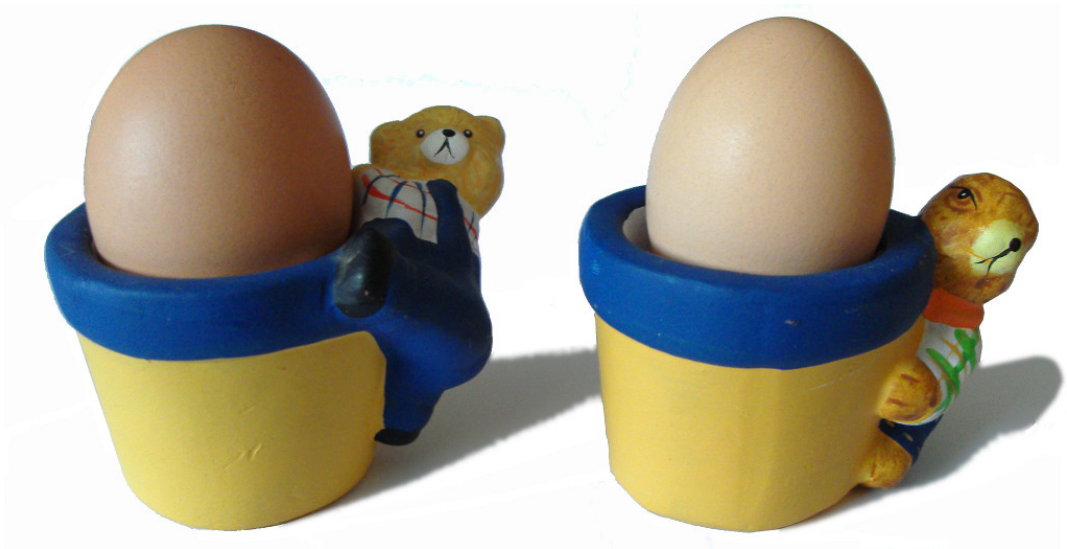

Práce se síťovým formátem dat

ntohl(3) — Síťový formát dat

```
#include <arpa/inet.h>

uint32_t htonl(uint32_t hostl);
uint32_t ntohl(uint32_t netl);
uint16_t htons(uint16_t hosts);
uint16_t ntohs(uint16_t nets);
```

Adresa socketu AF_INET6

struct sockaddr_in6

```
#include <sys/socket.h>
#include <netinet/in.h>

struct sockaddr_in6 {
    sa_family_t     sin6_family;
    in_port_t       sin6_port; /* net order */
    uint32_t        sin6_flowinfo;
    struct in6_addr sin6_addr;
    uint32_t        sin6_scope_id;
};

struct in6_addr {
    unsigned char s6_addr[16];
};
```

Práce s IP adresami

inet_pton(3), inet_aton(3)

```
#include <sys/socket.h>
#include <netinet/in.h>
#include <arpa/inet.h>

int inet_pton(int af, char *cp, void *dst);
char *inet_ntop(int af, void *src, char *dst,
    socklen_t size);

int inet_aton(char *src, struct in_addr *dst);
char *inet_ntoa(struct in_addr in);
```

- inet_pton(3) – třetí parametr musí mít dost místa pro příslušnou strukturu.
- Zastaralé: inet_addr(3).

Pojmenování socketu

bind(2) Pojmenování socketu

```
#include <sys/types.h>
#include <sys/socket.h>

int bind(int fd, struct sockaddr *addr,
    int addrlen);
```

Přístupová práva k adresám:

- AF_UNIX: práva do adresáře.
- AF_INET, AF_INET6: privilegované porty (0–1023).

Upozornění:

Nezaměňovat privilegované a well-known porty!

Pojmenování socketu

bind(2) Pojmenování socketu

```
#include <sys/types.h>
#include <sys/socket.h>

int bind(int fd, struct sockaddr *addr,
    int addrlen);
```

Přístupová práva k adresám:

- AF_UNIX: práva do adresáře.
- AF_INET, AF_INET6: privilegované porty (0–1023).

⚠ Upozornění:

Nezaměňovat privilegované a well-known porty!

Poznámky k bind(2)

- Všechna lokální rozhraní – INADDR_ANY.
- ... v IPv6 – globální proměnná in6addr_any, inicializátor IN6ADDR_ANY_INIT.
- Jen loopback v IPv6 – in6addr_loopback, IN6ADDR_LOOPBACK_INIT.
- Po uzavření socketu – nelze jistou dobu další bind(2) (čekání na FIN packety atd.). Flag SO_REUSEADDR.

Well-known porty

getservbyname(3) — Získání čísla služby

```
#include <netdb.h>

struct servent *getservbyname(char *name,
    char *proto);
struct servent *getservbyport(int port,
    char *proto);
void setservent(int stayopen);
struct servent *getservent();
void endservent();
```

Struktura servent

struct servent

```
struct servent {
    char  *s_name;
    char **s_aliases;
    int    s_port;
    char  *s_proto;
};
```

Příklad: Soubor /etc/services

```
discard     9/tcp   sink null
discard     9/udp   sink null
chargen    19/tcp   ttytst source
chargen    19/udp   ttytst source
ftp-data   20/tcp
ftp        21/tcp
fsp        21/udp   fspd
telnet     23/tcp
smtp       25/tcp   mail
time       37/tcp   timserver
```

Jména a adresy

- Jednomu jménu může být přiřazeno více adres.
- Jeden počítač (rozhraní, adresa) může mít více jmen.
- Resolver – mechanismus převodu jmen na IP adresy a naopak.

Převod jmen na IPv4 adresy

gethostbyname(3)

```
#include <netdb.h>
extern int h_errno;

struct hostent *gethostbyname(char *name);
struct hostent *gethostbyaddr(char *addr,
    int len, int type);
void sethostent(int stayopen);
struct hostent *gethostent();
void endhostent();
void herror(char *s);
```

Struktura hostent

struct hostent

```
struct hostent {
    char  *h_name;
    char **h_aliases;
    int    h_addrtype;
    int    h_length;
    char **h_addr_list;
};
```

Příklad: Soubor /etc/hosts

```
127.0.0.1       localhost localhost.localdomain
147.251.50.60   pyrrha pyrrha.fi.muni.cz
```

Úkol:

Napište program, který pomocí `gethostbyname(3)` vypíše IP adresy a všechny aliasy k zadanému jménu.

Příklad: Soubor /etc/hosts

```
127.0.0.1       localhost localhost.localdomain
147.251.50.60   pyrrha pyrrha.fi.muni.cz
```

Úkol:

Napište program, který pomocí `gethostbyname(3)` vypíše IP adresy a všechny aliasy k zadanému jménu.

Zjištění jména socketu

getsockname(2)

```
#include <sys/types.h>
#include <sys/socket.h>

int getsockname(int s, struct sockaddr *name,
    int *namelen);
```

Úkol:

Napište program, který zjistí, je-li na jeho standardním vstupu socket. Pokud ano, vypíše jeho adresu.
Napište program, který vytvoří pojmenovaný socket (AF_UNIX) a výše uvedenému programu jej předá jako standardní vstup.

Zjištění jména socketu

getsockname(2)

```
#include <sys/types.h>
#include <sys/socket.h>

int getsockname(int s, struct sockaddr *name,
    int *namelen);
```

Úkol:

Napište program, který zjistí, je-li na jeho standardním vstupu socket. Pokud ano, vypíše jeho adresu.
Napište program, který vytvoří pojmenovaný socket (AF_UNIX) a výše uvedenému programu jej předá jako standardní vstup.

Socket ve stavu LISTEN

listen(2) Čekání na spojení

```
#include <sys/socket.h>

int listen(int sock, int backlog);
```

- backlog – max. počet příchozích spojení ve frontě. Další jsou odmítnuta s ECONNREFUSED.
- listen(2) lze volat pouze na sockety typu SOCK_SEQPACKET a SOCK_STREAM.

Příjem příchozího spojení

accept(2) Přijetí spojení na socketu

```
#include <sys/types.h>
#include <sys/socket.h>

int accept(int sock, struct sockaddr *addr,
    int *addrlen);
```

- Přijme spojení, čekající ve frontě.
- Vrátí nový deskriptor, odpovídající tomuto spojení.
- Pouze pro SOCK_STREAM a SOCK_SEQPACKET.
- Neblokující accept(2): na poslouchacím socketu vrací select(2) připravenost pro čtení.
- addr: adresa druhého konce socketu.

TCP server

Úkol:

Napište program `netread`, který dostane jako parametr jméno nebo číslo protokolu a jméno nebo číslo portu, otevře příslušný port a přijme na něm spojení.
Na standardní výstup vypíše adresu a port, ze které obdržel spojení, dále vše co přečte ze socketu a pak skončí.
Vyzkoušejte funkčnost příkazem `telnet` *`stroj port`*.

Žádost o vytvoření spojení

connect(2) — Navázání spojení

```
#include <sys/types.h>
#include <sys/socket.h>

int connect(int sock, struct sockaddr *server,
    int addrlen);
```

connect(2) a SOCK_DGRAM

Pro SOCK_DGRAM určuje, ze které adresy je ochoten socket přijímat data a na kterou adresu posílá data. Žádné další akce nejsou v nižších vrstvách protokolu provedeny.

Žádost o vytvoření spojení

connect(2) — Navázání spojení

```
#include <sys/types.h>
#include <sys/socket.h>

int connect(int sock, struct sockaddr *server,
    int addrlen);
```

connect(2) a SOCK_DGRAM

Pro SOCK_DGRAM určuje, ze které adresy je ochoten socket přijímat data a na kterou adresu posílá data. Žádné další akce nejsou v nižších vrstvách protokolu provedeny.

TCP klient

Úkol:

Napište program `netwrite`, který si otevře socket a spojí se protokolem TCP na zadanou adresu a port. Po ustavení spojení zapíše vše co přečte ze standardního vstupu do socketu a pak uzavře spojení.

Zrušení spojení

shutdown(2) — Zrušení spojení

```
#include <sys/socket.h>

int shutdown(int sock, int how);
```

Parametr how může být jedno z následujících:

- 0 následující operace čtení jsou zakázány.
- 1 následující operace zápisu jsou zakázány.
- 2 všechny následující I/O operace jsou zakázány.

Adresa protistrany spojení

getpeername(2)

```
#include <sys/socket.h>

int getpeername(int sock, struct sockaddr *name,
    socklen_t *namelen);
```

- Není-li socket spojený, vrátí –1 a `errno = ENOTCONN`.

Nezávislost na síťovém protokolu

- `gethostbyname(3)` – vrací IPv4 adresy.
- Jak poznat z doménového jména IPv4 nebo IPv6 adresu?
- Jak mít aplikaci nezávislou na konkrétní `struct sockaddr_...`?
- Jak si ušetřit práci s `gethostbyname(3)`, `getprotobyname(3)` a `getservbyname(3)`?

Resolvování nezávislé na L3 protokolu

getaddrinfo(3)

```
#include <sys/types.h>
#include <sys/socket.h>
#include <netdb.h>

int getaddrinfo(const char *node,
     const char                *service,
     const struct addrinfo *hints,
     struct addrinfo      **result);
void freeaddrinfo(struct addrinfo *result);
const char *gai_strerror(int retval);
```

- Reentrantní – vrací dynamicky alokovanou strukturu.

Struktura addrinfo

struct addrinfo

```
struct addrinfo {
    int              ai_flags;
    int              ai_family;
    int              ai_socktype;
    int              ai_protocol;
    size_t           ai_addrlen;
    struct sockaddr *ai_addr;
    char            **ai_canonname;
    struct addrinfo *ai_next;
};
```

Poznámky ke getaddrinfo(3)

- Vrací zřetězený seznam struktur `addrinfo`.
- Pořadí prvků: RFC 3484.
- Místní preference: `gai.conf(5)`.
- V parametru `hints` si lze upřesnit
  - rodinu protokolů (`ai_family` – může být i `AF_UNSPEC`)
  - typ socketu (`ai_socktype`)
  - protokol (`ai_protocol`)
  - další příznaky (`ai_flags`) – viz dále.

Příklad: Soubor /etc/gai.conf

```
label           ::1/128         0
label           ::/0            1
label           2002::/16       2
label           ::/96           3
label           ::ffff:0:0/96   4

precedence      ::1/128         50
precedence      ::/0            40
precedence      2002::/16       30
precedence      ::/96           20
precedence      ::ffff:0:0/96   10
```

Příznaky ai_flags

`AI_NUMERIC` – parametr `node` obsahuje adresu, nikoli DNS jméno.

`AI_NUMERICSERV` – položka `service` obsahuje číslo.

`AI_CANONNAME` – dohledat do `ai_canonname` oficiální jméno.

`AI_PASSIVE` – je-li `node == NULL`, dát do `ai_addr` nespecifikovanou adresu (`INADDR_ANY`), jinak zpětnovazebnou adresu.

`AI_ADDRCONFIG` – vrací rodinu protokolů podle toho, které protokoly jsou aktuálně na stroji konfigurované.

`AI_V4MAPPED` – je-li `ai_family == AF_INET6` a nenajde-li se žádná IPv6 adresa, vrací IPv4 adresy jako IPv6 mapované. Je-li navíc `AI_ALL`, vrací IPv4 jako v6-mapované vždy.

Využití getaddrinfo(3)

Úkol:

Napište program `getaddrinfo`, který zavolá funkci `getaddrinfo(3)` se zadaným jménem stroje a služby, a vypíše seznam vrácených struktur `addrinfo`. Vyzkoušejte jeho funkci na jménech jako je `www.kame.net`.

I/O operace nad sockety

recv*(2) — Čtení ze socketu

```
#include <sys/types.h>
#include <sys/socket.h>

int recv(int s, void *msg, int len,
    unsigned flags);
int recvfrom(int s, void *msg, int len,
    unsigned flags, struct sockaddr *from,
    int *fromlen);
int recvmsg(int s, struct msghdr *msg,
    unsigned flags);
```

- recv(2) se používá obvykle nad spojenými sockety.

Příznaky pro recv*(2)

- `MSG_DONTWAIT`: neblokující operace.
- `MSG_OOB`: zpracování out-of-band dat.
- `MSG_PEEK`: přečtení dat bez vymazání ze vstupní fronty.
- `MSG_WAITALL`: načtení přesně `len` bajtů dat.

Struktura msghdr

struct msghdr

```
struct msghdr {
    void         *msg_name;
    unsigned      msg_namelen;
    struct iovec *msg_iov; /* viz readv(2) */
    unsigned      msg_iovlen;
    void         *msg_control;
    unsigned      msg_controllen;
    int           msg_flags;
};
```

Řídící zprávy

struct cmsghdr

```
struct cmsghdr {
    socklen_t cmsg_len;   /* včetně hlavičky */
    int       cmsg_level; /* protokol */
    int       cmsg_type;
/*  unsigned char cmsg_data[]; */
};
```

Odesílání dat do socketu

send*(2) Zaslání zprávy do socketu

```
#include <sys/types.h>
#include <sys/socket.h>

int send(int s, void *msg, int len,
    unsigned flags);
int sendto(int s, void *msg, int len,
    unsigned flags, struct sockaddr *to,
    int tolen);
int sendmsg(int s, struct msghdr *msg,
    unsigned flags);
```

- send(2) funguje pouze na spojené sockety.
- Pokud je zpráva příliš dlouhá na atomický přenos, vrátí funkce chybu a errno nastaví na EMSGSIZE.

Příznaky pro send*(2)

- MSG_OOB – posílání out-of-band dat.
- MSG_DONTROUTE – pouze pro přímo připojené sítě.
- MSG_DONTWAIT – neblokující operace.
- MSG_NOSIGNAL – nesignalizuje SIGPIPE v případě chyby.

UDP klient a server

Úkol:

Napište program `udpread`, který bude přijímat zprávy na zadaném UDP portu. Pro každou zprávu vypíše, odkud ji obdržel (IP adresu a port) a obsah zprávy.

Úkol:

Napište program `udpwrite`, který otevře UDP socket a bude posílat řádky standardního vstupu na daný UDP port a danou IP adresu.

UDP klient a server

Úkol:

Napište program `udpread`, který bude přijímat zprávy na zadaném UDP portu. Pro každou zprávu vypíše, odkud ji obdržel (IP adresu a port) a obsah zprávy.

Úkol:

Napište program `udpwrite`, který otevře UDP socket a bude posílat řádky standardního vstupu na daný UDP port a danou IP adresu.

Parametry socketu

getsockopt(2), setsockopt(2)

```
#include <sys/types.h>
#include <sys/socket.h>

int getsockopt(int s, int level, int optname,
    void *optval, int *optlen);
int setsockopt(int s, int level, int optname,
    void *optval, int optlen);
```

- `level` je číslo protokolu (viz `getprotoent(3)`) nebo `SOL_SOCKET`.
- Viz `ip(7)`, `ipv6(7)`, `tcp(7)`, `udp(7)`, `socket(7)`.

Parametry pro SOL_SOCKET – I.

- SO_DEBUG – nastaví zapisování ladící informace (superuser).
- SO_REUSEADDR – povolí nové použití lokální adresy při `bind(2)`.
- SO_KEEPALIVE – povolí posílání keep-alive packetů.
- SO_DONTROUTE – obchází směrování pro odcházející zprávy.
- SO_LINGER – nastavuje chování při uzavírání socketu.
- SO_BROADCAST – získání práv na posílání broadcast packetů (může pouze superuživatel).
- SO_OOBINLINE – OOB data jsou čtena v normální datové frontě.
- SO_SNDBUF, SO_RCVBUF – nastavení velikosti čtecího a zápisového bufferu.

Parametry pro SOL_SOCKET – II.

- SO_SNDLOWAT – low-water mark pro posílání dat.
- SO_RCVLOWAT – low-water mark pro čtení dat.
- SO_SNDTIMEO – timeout pro výstupní operace. Maximální doba, po kterou je proces blokovaný ve službě jádra `send(2)`.
- SO_RCVTIMEO – timeout pro vstupní operace.
- SO_TYPE – vrací typ socketu (například SOCK_STREAM).
- SO_ERROR – zkoumá, došlo-li na socketu k chybě.

TCP/IP aplikace

- Klient-server přístup.
- Jednoprocesový server – vše v jednom procesu; I/O operace multiplexovány pomocí `select(2)` nebo `poll(2)` nebo přes asynchronní I/O.
- Víceprocesový server – hlavní proces obvykle pouze přijme spojení přes `accept(2)`, předá potomkovi k vyřízení. Na každého klienta je jeden proces na serveru.
- Stavový server – výsledek předchozích operací ovlivňuje následující operace (FTP - změna adresáře).
- Bezstavový server – nezáleží na zopakování požadavku (NFS).

Schéma TCP serveru

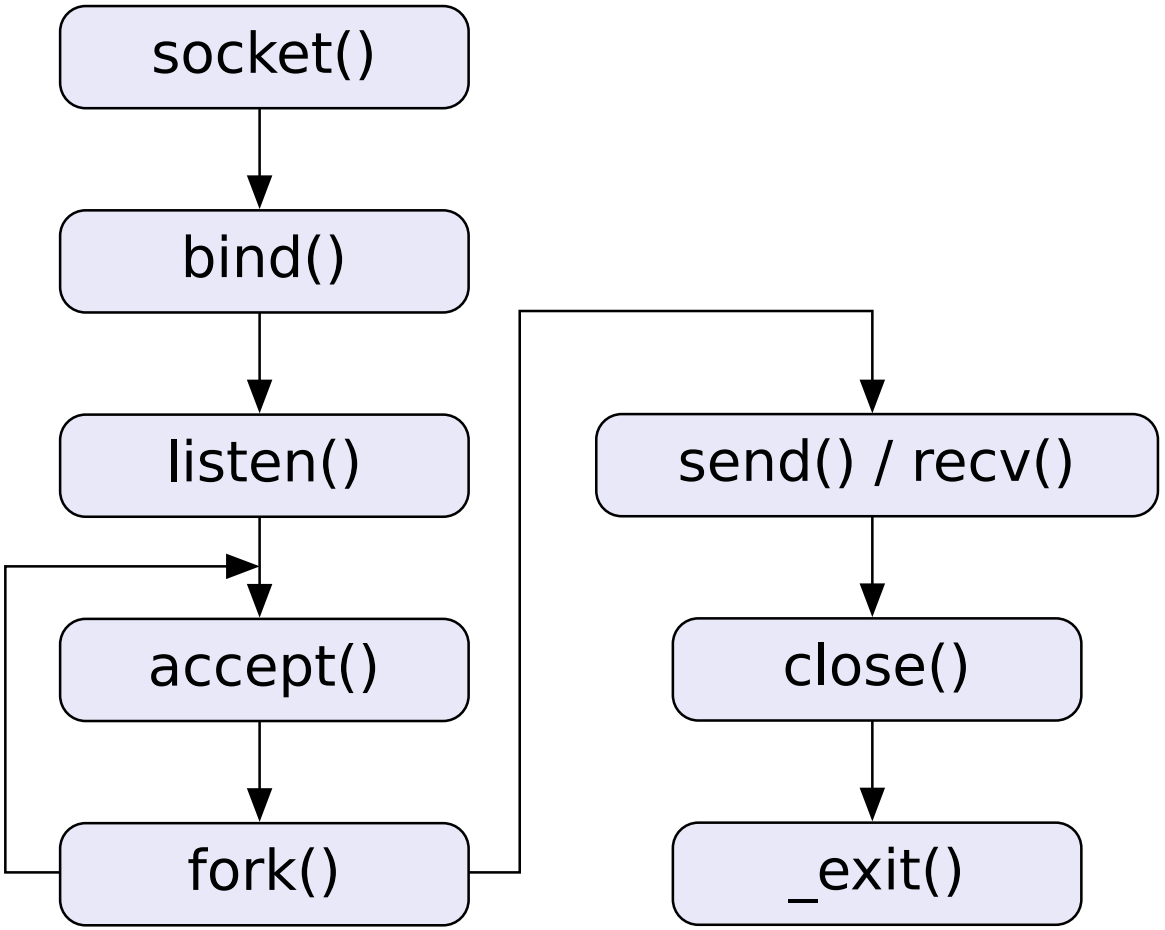

Schéma TCP klienta

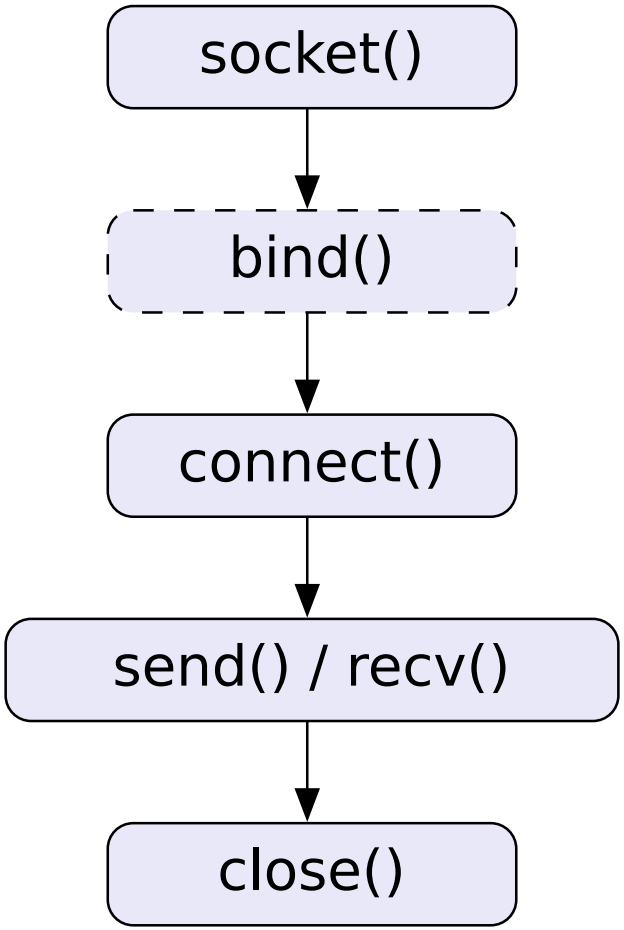

Schéma UDP aplikace

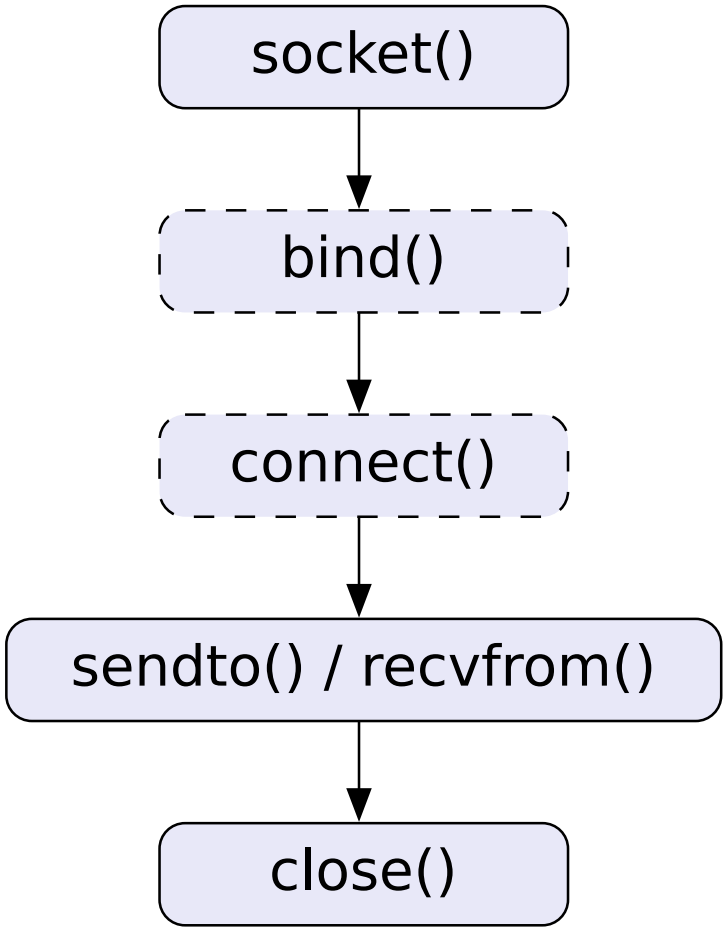

Kapitola 4

Administrace sítě

Konfigurace sítě

- Přidělení jména stroje.
- Přidělení IP adresy na interface.
- Směrovací tabulky.
  - Statické versus dynamické směrování.

Nastavení jména stroje

hostname(1) — Jméno stroje

```
# hostname jméno
$ hostname
```

- Jméno může být FQDN  nebo jen jméno bez domény (SysV).

gethostname(2)

```
#include <unistd.h>

int gethostname(char *name, size_t len);
int sethostname(const char *name, size_t len);
```

Nastavení jména stroje

hostname(1) — Jméno stroje

```
# hostname jméno
$ hostname
```

- Jméno může být FQDN  nebo jen jméno bez domény (SysV).

gethostname(2)

```
#include <unistd.h>

int gethostname(char *name, size_t len);
int sethostname(const char *name, size_t len);
```

Informace o operačním systému

uname(1) Jméno systému

```
$ uname [-snrvma]
```

- `-m` – machine (hardware) type.
- `-n` – node name (host name).
- `-r` – operating system release.
- `-s` – operating system name.
- `-v` – operating system version.
- `-a` – all of the above.

Konfigurace síťového rozhraní

ifconfig(8)

```
$ ifconfig [interface|-a]
# ifconfig interface options …
```

Příklad: ifconfig eth0

```
eth0 Link encap:Ether HWaddr 00:24:1D:71:A7:7A
 inet addr:147.251.48.204 Bcast:147.251.48.255\
     Mask:255.255.255.0
 inet6 addr: 2001:718:801:230::cc/64 Scope:Glob
 inet6 addr: fe80::224:1dff:fe71:a77a/64 \
     Scope:Link
 UP BROADCAST RUNNING MULTICAST MTU:1500 Metric:1
 RX packets:114326910 errors:0 dropped:0 ...
 ...
```

Konfigurace síťového rozhraní

ifconfig(8)

```
$ ifconfig [interface|-a]
# ifconfig interface options …
```

Příklad: ifconfig eth0

```
eth0 Link encap:Ether HWaddr 00:24:1D:71:A7:7A
 inet addr:147.251.48.204 Bcast:147.251.48.255\
     Mask:255.255.255.0
 inet6 addr: 2001:718:801:230::cc/64 Scope:Glob
 inet6 addr: fe80::224:1dff:fe71:a77a/64 \
     Scope:Link
 UP BROADCAST RUNNING MULTICAST MTU:1500 Metric:1
 RX packets:114326910 errors:0 dropped:0 ...
 ...
```

Parametry pro ifconfig(8) – I.

`up` – aktivace rozhraní. Implicitně pokud se specifikuje nová adresa.

`down` – deaktivace rozhraní.

`[-]arp` – zapíná/vypíná použití ARP nad daným rozhraním.

`[-]promisc` – přijímá všechny packety na dané síti.

`mtu` *`N`* – Maximum Transfer Unit.

`hw` *`hw-adresa`* – nastavení hardwarové adresy, pokud to daný interface podporuje.

Parametry pro ifconfig(8) – II.

adresa – nastavuje adresu rozhraní.

dstaddr *adresa* (nebo pointopoint *adresa*) – cílová adresa pro point-to-point rozhraní.

netmask *netmask* – síťová maska rozhraní.

[-]broadcast [*adresa*] – nastavuje adresu pro všesměrové vysílání.

Příklad: Konfigurace síťového rozhraní

```
#  ifconfig lo 127.0.0.1 netmask 255.0.0.0

#  ifconfig eth0 147.251.50.60 \
     netmask 255.255.255.0 broadcast 147.251.50.255

#  ifconfig ppp0 down
```

Směrovací tabulka

- Adresování na základě sítě – adresa sítě, maska (adresní prefix).
- Položky: adresní prefix, adresa routeru nebo jméno rozhraní, metrika.

route(8) Práce s IP směrovací tabulkou

```
$ route [-n]
# route add|del [-net|-host] target \
    [metric metric] [dev interface]
```

- Síť `default` je totéž co `0.0.0.0/0`.
- Směruje se podle nejdelšího prefixu a pak podle metriky.
- Program `ifconfig(8)` přidává automaticky cestu k lokálně připojené síti.

Příklad: Směrovací tabulka

```
#  route add 127.0.0.2 dev lo

#  route add -net 147.251.48.0 \
     netmask 255.255.255.0 gw 147.251.1.13

#  route add default gw 147.251.48.14
```

Další konfigurační nástroje

ip(8) — Obecná konfigurace sítě

```
# ip link ...
# ip addr ...
# ip route ...
# ip tunnel ...
```

- NetworkManager (a nmcli(8))
- systemd-networkd(8)

Směrovací protokoly

- Dynamická modifikace směrovacích tabulek.
- Tolerantnost k výpadku sítě.
- Zamezení vzniku směrovacích kruhů.
- Rozdělení zátěže.

Druhy směrovacích protokolů

Link-state protokol

- Routery si posílají informace o svých sousedech.
- Každý konstruuje mapu sítě.
- Každý počítá nejkratší cesty v mapě (Dijkstra).

Distance-vector protocol

- Routery si posílají svoje směrovací tabulky s metrikami.
- Každý vybírá cestu s nejnižší metrikou (Bellman-Ford).

Druhy směrovacích protokolů

Link-state protokol

- Routery si posílají informace o svých sousedech.
- Každý konstruuje mapu sítě.
- Každý počítá nejkratší cesty v mapě (Dijkstra).

Distance-vector protocol

- Routery si posílají svoje směrovací tabulky s metrikami.
- Každý vybírá cestu s nejnižší metrikou (Bellman-Ford).

Směrování v Internetu

- Autonomní systémy – sítě jednotlivých poskytovatelů.
- Vnitřní a vnější směrování – v rámci nebo přes hranice AS.

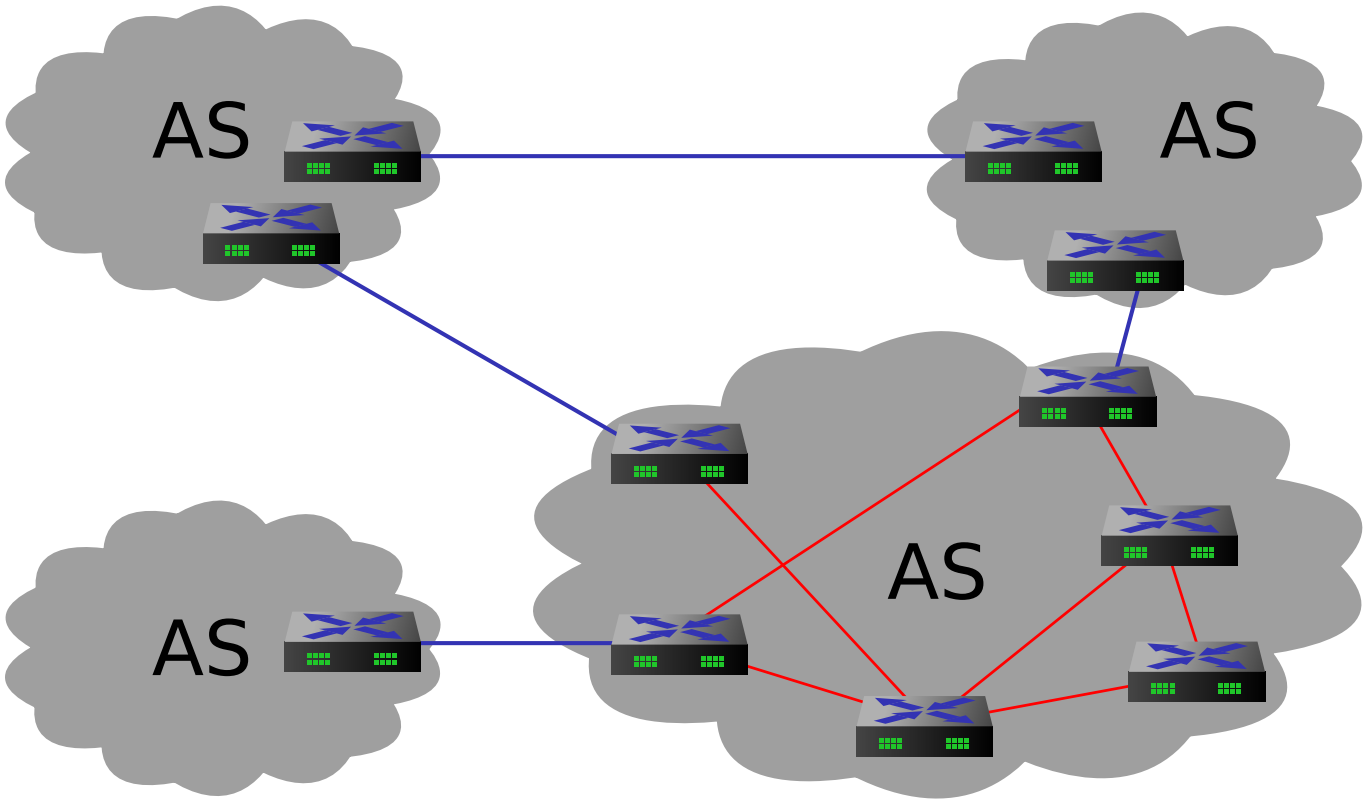

Směrovací protokoly

- RIP – DV protokol. Trigger update. Maximální průměr sítě 16 uzlů.
- RIPv2 – odstraňuje některé nevýhody RIPu.
- OSPF – LS protokol. Open shortest paths first. Oblasti. Autentizace.
- BGP – DV protokol. Border gateway protocol. Externí směrovací protokol.
- IS-IS – LS protokol. Zvlášť topologie a zvlášť prefixy různých L3 protokolů.

OSPF oblasti

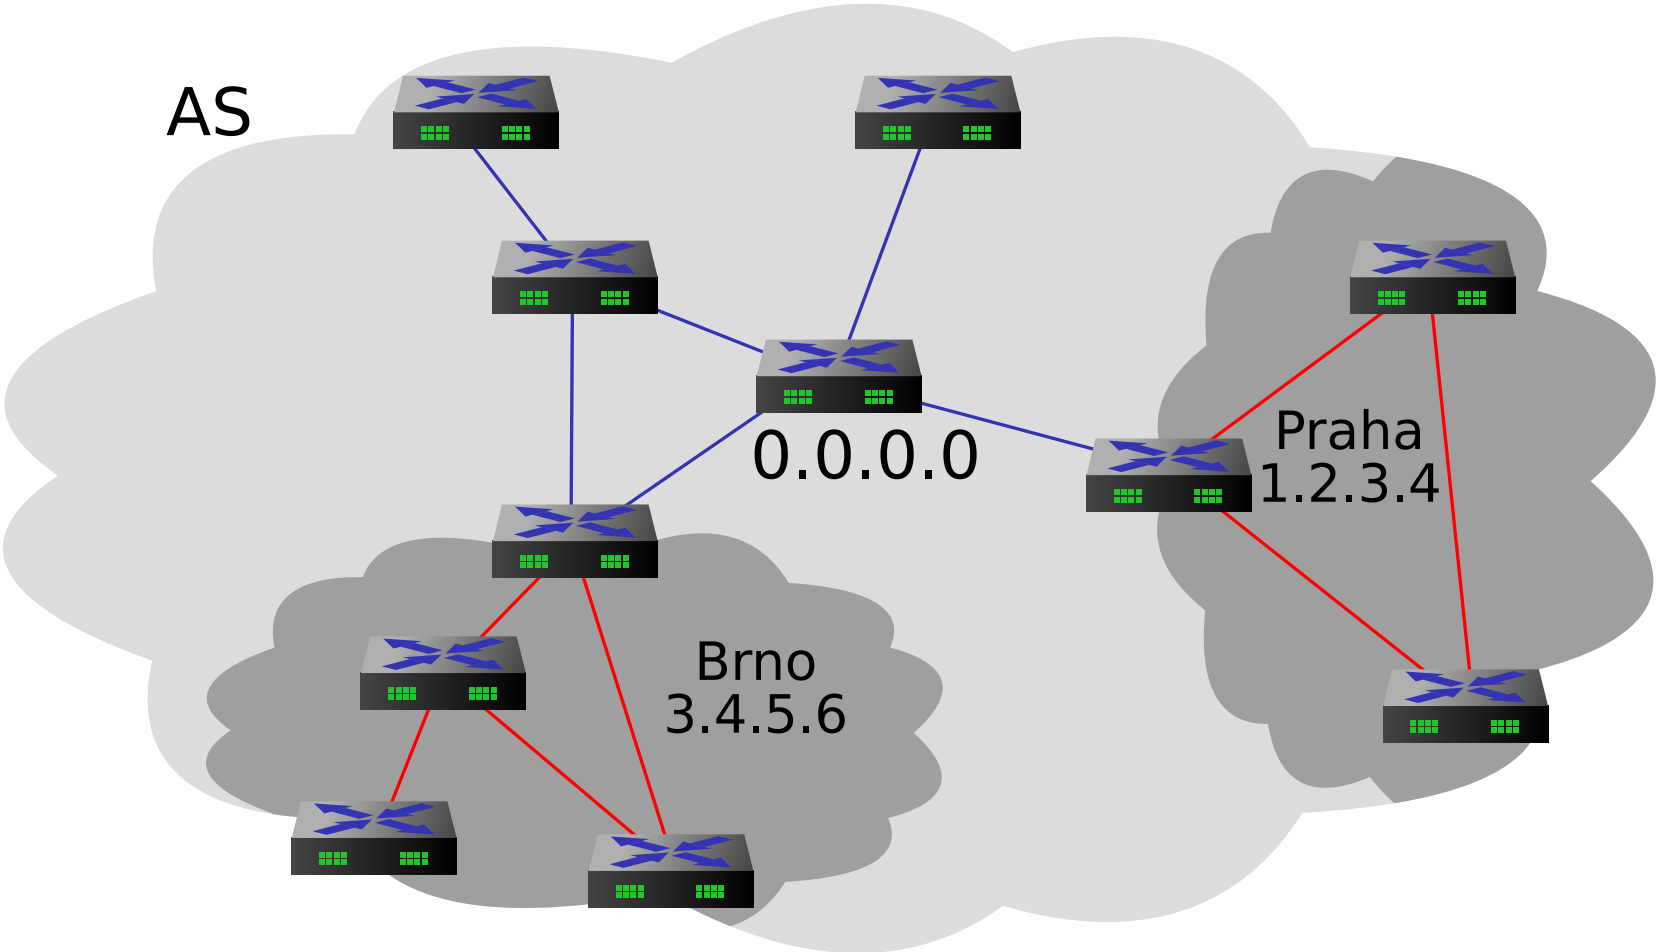

Směrovací protokoly v UNIXu

- RouteD – RIP.
- GateD – `www.gated.org`  .
- Zebra, Quagga – `www.quagga.net` – GPL, portabilní, včetně IPv6.
- BIRD – `bird.network.cz` 

Policy routing

- Policy routing – směrování podle jiného klíče, než je adresní prefix (například podle zdrojové adresy, TOS, atd.)
- Linux – ovládání programem `ip(8)` – nahrazuje `ifconfig(8)`, `route(8)` a několik dalších.

Příklad: Použití policy routingu

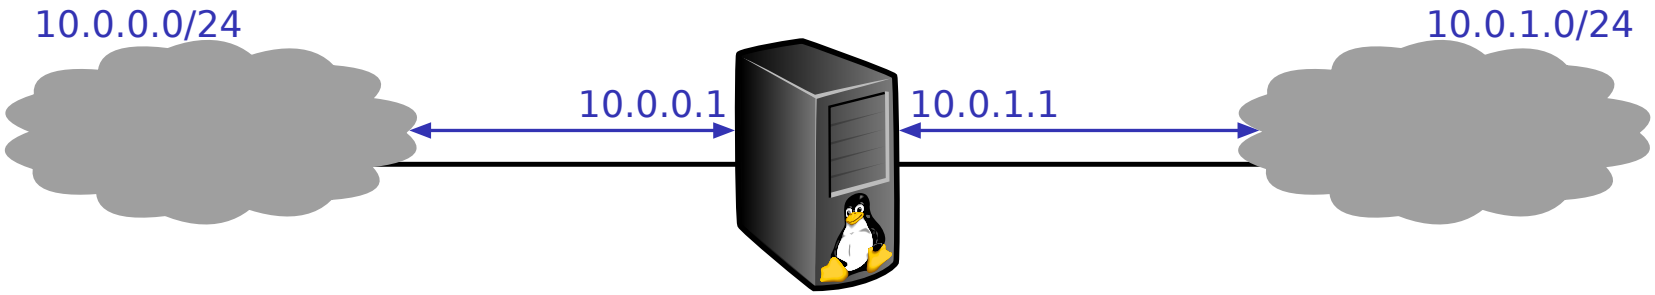

Příklad: Použití policy routingu

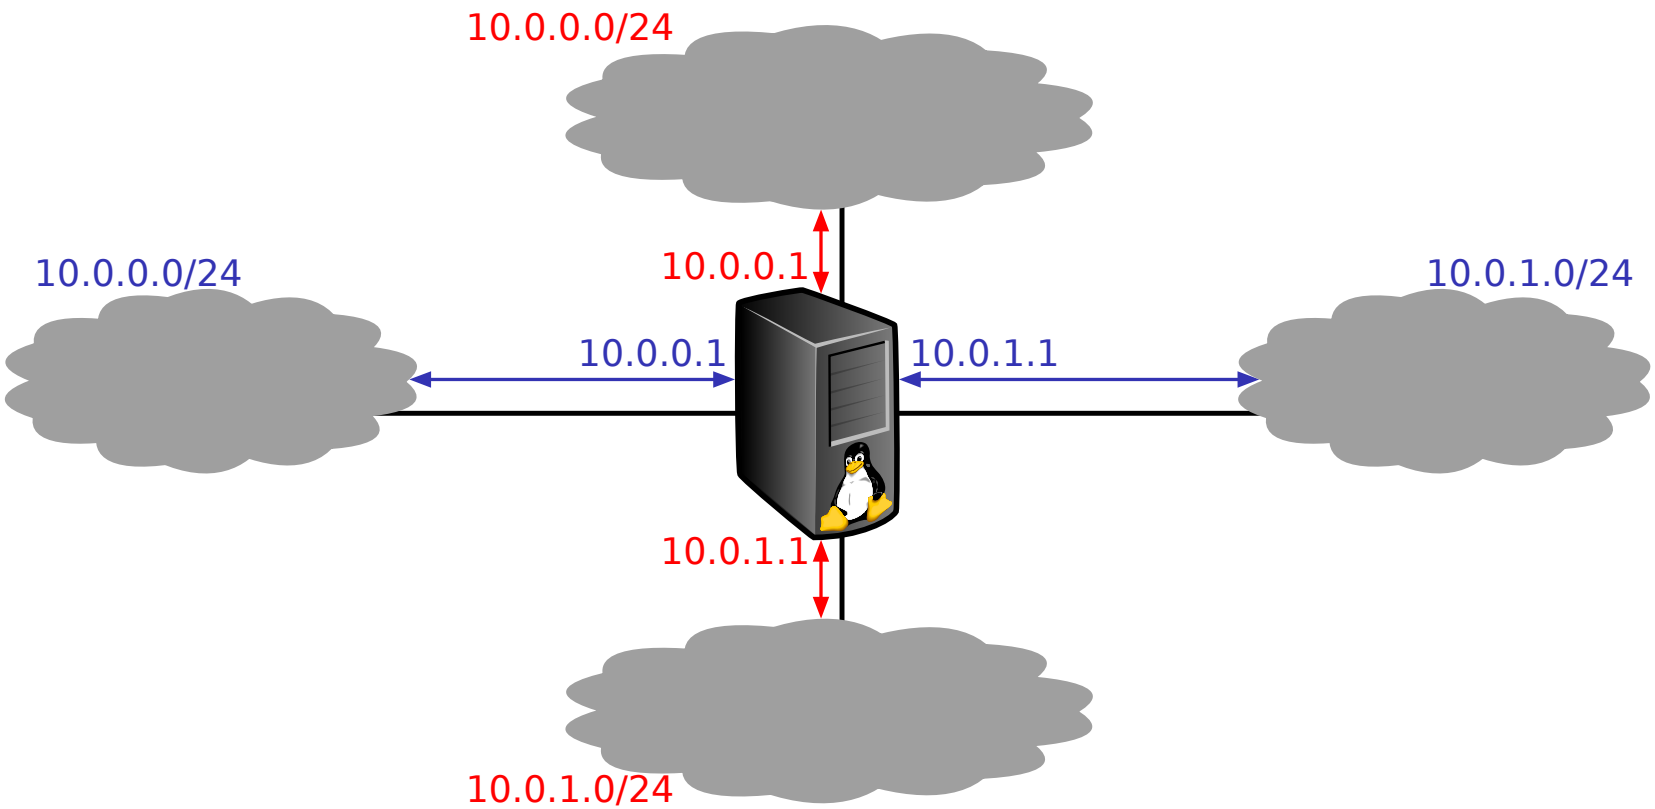

Routing engine v Linuxu

- Směrovací tabulky – více než jedna směrovací tabulka v jádře; předdefinované tabulky `local` a `main`.
- Pravidla – priorita, popis packetu, akce.
- Levá strana pravidla – zdrojový prefix, cílový prefix, TOS, fwmark, zařízení.
- Pravá strana – číslo tabulky, nebo jedno z `prohibit`, `blackhole`, `unreachable`, dále zdrojový a cílový realm (doména).
- Cílová doména (realm) může být nastavena i směrovací tabulkou.

Informace o nastavení sítě

netstat(8)

```
$ netstat [-vncturi]
```

Bez parametrů vypíše seznam otevřených socketů.
Možné parametry:

- `-v` podrobnější výpis.
- `-n` číselný výpis bez převodu na doménová jména.
- `-c` periodický výpis podobně jako u `top(1)`.
- `-t` TCP sockety.
- `-u` UDP sockety.
- `-r` vypíše směrovací tabulku jádra.
- `-i` vypíše seznam všech síťových rozhraní.

Příklad: netstat(8)

```
$  netstat -rn
Destination     Gateway         Mask Flg Iface
147.251.48.18   0.0.0.0         32   UH  eth0
147.251.48.0    0.0.0.0         24   U   eth0
127.0.0.0       0.0.0.0         8    U   lo
0.0.0.0         147.251.48.14 0    UG  eth0
```

Výpis síťových packetů

tcpdump(8)

```
# tcpdump [-exnp] [-c count]
    [-i interface] expression
```

- `-n` nepřevádí adresy na doménová jména.
- `-x` podrobnější výpis.
- `-e` vypisuje také hlavičky linkové úrovně (například MAC adresy).
- `-p` nepřepne rozhraní do promiskuitního režimu.

`-c count` vypíše prvních *count* packetů.

`-i interface` jiné než implicitní rozhraní.

Příklad: tcpdump(8)

```
#  tcpdump -i eth0 -p port domain
tcpdump: verbose output suppressed, \
    use -v or -vv for full protocol decode
listening on eth0, link-type EN10MB (Ethernet),\
    capture size 65535 bytes
15:15:33.277318 IP calypso.fi.muni.cz.36075 \
    > ares.fi.muni.cz.domain: 5129+ A? \
    aisa.fi.muni.cz. (33)
15:15:33.280797 IP ares.fi.muni.cz.domain \
    > calypso.fi.muni.cz.36075: 5129 1/3/2 A\
    147.251.48.1 (132)
```

Program ping(8)

ping(8) — ICMP Echo Request

```
# ping [-nfqR] [-c count] [-s size] host
```

- `-n` nepřevádí IP adresy na doménová jména.
- `-f` flood ping.
- `-q` bez výstupu o jednotlivých packetech.
- `-R` record route.

Příklad: ping(8)

```
$  ping -c 2 pyrrha.fi.muni.cz
PING pyrrha.fi.muni.cz (147.251.50.60):
    56 data bytes
64 bytes from 147.251.50.60: icmp_seq=0
    ttl=57 time=318.2 ms
64 bytes from 147.251.50.60: icmp_seq=1
    ttl=57 time=535.2 ms
— pyrrha.fi.muni.cz ping statistics —
2 pkts transmitted, 2 pkts received, 0% pkt loss
round-trip min/avg/max = 261.4/371.6/535.2 ms
```

IP nad Ethernetem

arp(8) Manipulace s ARP tabulkou

```
$ arp -a
# arp -d ipaddr
# arp -s ipaddr hwaddr [netmask netmask] \
    [pub|temp]
```

Příklad: ARP tabulka

```
$ arp -a
pyrrha.fi.muni.cz (147.251.48.140) \
    at 00:e0:81:45:90:e2 [ether] on eth0
anxur.fi.muni.cz (147.251.48.3) \
    at 18:a9:05:e9:3b:10 [ether] on eth0
? (10.0.0.11) at 00:16:3e:01:12:34 [ether] \
    on brvm
```

IP nad Ethernetem

arp(8) Manipulace s ARP tabulkou

```
$ arp -a
# arp -d ipaddr
# arp -s ipaddr hwaddr [netmask netmask] \
    [pub|temp]
```

Příklad: ARP tabulka

```
$  arp -a
pyrrha.fi.muni.cz (147.251.48.140) \
    at 00:e0:81:45:90:e2 [ether] on eth0
anxur.fi.muni.cz (147.251.48.3) \
    at 18:a9:05:e9:3b:10 [ether] on eth0
? (10.0.0.11) at 00:16:3e:01:12:34 [ether] \
    on brvm
```

Point-to-point protocol

- Přenos datagramů po sériových linkách.
- Protokol je symetrický – není role master a slave (neexistuje PPP server a klient).
- IP, IPX, IPv6 a další L3 protokoly.
- Komprese packetů, šifrování a další transformace.
- Van Jacobsonova komprese IP hlaviček.
- Většina vlastností protokolu (escape znaky, atd.) je vyjednána při začátku spojení.
- Link Control Protocol (LCP) – vyjednávání o parametrech spojení.
- IP Control Protocol (IPCP) – vyjednávání o IP spojení.
- Autentizace – PAP, CHAP.

Jména a adresy

- IP adresy – těžko zapamatovatelné.
- Jména počítačů.
- Dříve: soubor `hosts.txt` distribuovaný přes InterNIC (mechanismus stále používaný – `/etc/hosts`).
- Centrální registrace jmen počítačů.
- Těžkopádné – nutnost rozdělení pravomoci přidělování jmen.

Vznik DNS

- Hierarchický systém jmen a adres.
- Systém domén, tečková notace *doménové adresy* (`pyrrha.fi.muni.cz`).
- FQDN – řetězec jmen oddělených tečkami.
- Doména – samostatný jmenný prostor.
- Subdoména – další jmenný prostor uvnitř domény.
- Delegace autority spravovat subdoménu.
- Kořenová doména – značí se tečkou (`.`).

Co může obsahovat doménové jméno?

- Písmena (a-z bez rozlišení velikosti)
- Číslice (0-9)
- Pomlčka (-)
- Nic jiného (RFC 1034).

Domain Name System

- Definice – RFC 1033–1035.
- RFC 1912 – Common DNS Operational and Configuration Errors.
- BIND – referenční implementace DNS (démon `named(8)`)
- Name Server Operations Guide for BIND (v distribuci BINDu).

Nameservery

- Autoritativní nameserver pro doménu – data o doméně ví „přímo“.
- Cache-only nameserver – není autoritativní pro žádnou doménu, slouží pouze k přeposílání dotazů.

Autoritativní nameservery – delegace

- Registrovaný nameserver – na něj jsou delegována práva spravovat subdoménu.
- Neregistrovaný nameserver – není odkaz z nadřazené domény, přesto zná informace o své doméně.

Autoritativní nameservery – data

- Primární nameserver pro určitou doménu (zónu) – informace má uloženy obvykle v souboru.
- Sekundární nameserver pro určitou doménu – data o této zóně si stahuje periodicky z primárního nebo nadřazeného sekundárního nameserveru této zóny.

Kořenové nameservery

- nameservery pro doménu „.“
- v Internetu mají doménové jméno pod `ROOT-SERVERS.NET.`
- seznam je zveřejňován spolu s jejich IP adresami na `ftp.internic.net`.
- Interní kořenový nameserver – kořenový nameserver v síti s protokolem TCP/IP, která není připojena do Internetu.

Zpracování DNS dotazů

- Nameserver ví, koho se ptát, když on sám neví
  - *forwarders* (například DNS servery poskytovatele připojení)
  - nebo zná kořenové nameservery.
- Rekurzivní chování – DNS server přeposílá dotazy sám.
- Iterativní chování – DNS server vrací „nevím, ale zeptejte se támhle“.

Data v DNS

- Dopředné mapování – převod jména na IP adresu.
- Reverzní mapování – převod IP adres na jména.
- Služební data – adresy nameserverů, delegace subdomény, metadata domény, atd.
- Další údaje – textové popisy, adresy služeb, směrování pošty, zeměpisné souřadnice, aliasy, atd.

Reverzní mapování

- Reverzní dotaz – dohledání FQDN na základě IP adresy.
- DNS – překlad FQDN na *nějaká* data (adresa, souřadnice, ...).
- ... možná i na jiné FQDN?
- Jak udělat z IP adresy FQDN?

IPv4

- pseudodoména `in-addr.arpa`.
- subdomény po bajtech IPv4 adresy (od nejvýznamnějšího).
- Příklad: `147.251.48.14` $\longrightarrow$ `14.48.251.147.in-addr.arpa`.

Reverzní mapování

- Reverzní dotaz – dohledání FQDN na základě IP adresy.
- DNS – překlad FQDN na *nějaká* data (adresa, souřadnice, ...).
- ... možná i na jiné FQDN?
- Jak udělat z IP adresy FQDN?

IPv4

- pseudodoména `in-addr.arpa`.
- subdomény po bajtech IPv4 adresy (od nejvýznamnějšího).
- Příklad: `147.251.48.14` $\longrightarrow$ `14.48.251.147.in-addr.arpa`.

Reverzní DNS v IPv6

- Analogické k IPv4.
- Pseudodoména `ip6.arpa.`
- Subdomény po půlbajtech (od nejvýznamnějšího).

Příklad: Záznam v `ip6.arpa`

`fec0::1` ⟶
`1.0.0.0. ... 24× 0 ... .0.c.e.f.ip6.arpa.`

Reverzní DNS v IPv6

- Analogické k IPv4.
- Pseudodoména `ip6.arpa.`
- Subdomény po půlbajtech (od nejvýznamnějšího).

Příklad: Záznam v `ip6.arpa`

`fec0::1` $\longrightarrow$
`1.0.0.0. ... 24× 0 ... .0.c.e.f.ip6.arpa.`

Konfigurace BINDu

named(8) Domain Name Server

```
# named [-d debuglevel] [-p port[/localport]] \
    [-c configfile] [-u user] [-g group] \
    [-t rootdir]
```

- Konfigurační soubor: `/etc/named.conf`
- Nespouštět pod rootem (použít `-u` a `-g`)
- Použít chroot (`-t`) nebo SELinux.

Signály pro named(8)

`SIGHUP` – způsobí znovunačtení konfigurace

`SIGINT` – uloží aktuální databázi a cache do souboru `/var/tmp/named_dump.db`.

`SIGUSR1` – Zvýší *debuglevel* o jedničku.

`SIGUSR2` – Vypne ladění (*debuglevel* 0).

Viz též `rndc(8)`.

Příklad: Soubor named.conf

```
options {
        directory ”/var/named”;
        forwarders {
                147.251.48.3; 147.251.4.33;
                3ffe:ffff::1;
        };
        forward only;
};
zone ”.” {
        type hint;
        file ”named.root”;
};
```

Příklad: named.conf – pokračování

```
zone ”localhost” {
        type master;
        file ”master/localhost”;
};
zone ”0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.\
      0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.ip6.arpa” {
        type master;
        file ”master/ip6-loopback”;
};
zone ”0.0.127.in-addr.arpa” {
        type master;
        file ”master/127.0.0”;
};
```

Příklad: named.conf – pokračování

```
zone ”fi.muni.cz” {
        type master;
        file ”master/fi.muni.cz”;
        also-notify {
                147.251.48.140;
                3ffe:ffff::1;
        };
        allow-transfer { any; };
};
zone ”muni.cz” {
        type slave;
        file ”slave/muni.cz”;
        masters { 147.251.4.33; };
        allow-transfer { any; };
};
```

Příklad: named.conf – pokračování

```
zone ”48.251.147.in-addr.arpa” {
        type master;
        file ”master/147.251.48”;
        also-notify { 147.251.48.140; };
};
zone ”f.f.f.f.e.f.f.3.ip6.arpa” {
        type master;
        file ”master/3.f.f.e.f.f.f.f”;
        also-notify { 3ffe:ffff::1; };
};
```

Příklad: Dopředný překlad

Příklad souboru `master/fi.muni.cz`:

```
$TTL 1D
@           IN SOA  anxur.fi.muni.cz. \
                    postmaster.fi.muni.cz. (
                    2010041701  ; Serial
                    3H          ; Refresh
                    15M         ; Retry
                    2W          ; Expire
                    1D    )     ; Min/neg TTL
```

Příklad: Dopředný překlad

Příklad souboru master/fi.muni.cz:

```
$TTL 1D
@           IN SOA  anxur.fi.muni.cz. \
                    ...
            IN NS   anxur
            IN NS   aisa
            IN MX   50 relay.muni.cz.
            IN MX   100 relay
            IN TXT  ”Faculty of Informatics”
            IN TXT  ”Masaryk University Brno”
```

Příklad: Zóna fi.muni.cz – pokračování

```
ns          IN CNAME anxur
ftp         IN CNAME odysseus
news        IN CNAME nimloth.ics.muni.cz.
time        IN CNAME pyrrha
relay       IN A     147.251.48.3
anxur       IN A     147.251.48.3
            IN HINFO ”Big Iron” ”Linux”
            IN TXT   ”Umisteni: Dolni sal”
calypso     IN A     147.251.50.61
            IN AAAA  3ffe:ffff::3d
            IN HINFO ”PC” ”Linux”
            IN TXT   ”Umisteni: Jan Kasprzak”
            IN MX    50 relay.muni.cz.
            IN MX    100 relay
```

Příklad: Root cache – named.root

```
; formerly NS.INTERNIC.NET
.                        3600000 IN NS A.ROOT-SERVERS.NET.
A.ROOT-SERVERS.NET. 3600000 IN A   198.41.0.4
; formerly NS1.ISI.EDU
.                        3600000 IN NS B.ROOT-SERVERS.NET.
B.ROOT-SERVERS.NET. 3600000 IN A   128.9.0.107
; formerly C.PSI.NET
.                        3600000 IN NS C.ROOT-SERVERS.NET.
C.ROOT-SERVERS.NET. 3600000 IN A   192.33.4.12
; formerly TERP.UMD.EDU
.                        3600000 IN NS D.ROOT-SERVERS.NET.
...
```

Příklad: Reverzní mapování IPv4

```
$TTL 1D
48.251.147.in-addr.arpa. IN SOA anxur.fi.muni.cz.\
                    postmaster.fi.muni.cz. (
                    2001041700 ; Serial
                    3H         ; Refresh
                    15m        ; Retry
                    2W         ; Expire
                    1D    )    ; Minimum
            IN NS   anxur.fi.muni.cz.
            IN NS   aisa.fi.muni.cz.
1           IN PTR  aisa.fi.muni.cz.
3           IN PTR  anxur.fi.muni.cz.
            IN PTR  relay.fi.muni.cz.
5           IN PTR  thetis.fi.muni.cz.
...
```

Příklad: Reverzní mapování IPv6

```
$TTL 1D
f.f.f.f.e.f.f.3.ip6.arpa. IN SOA \
                    anxur.fi.muni.cz.\
                    postmaster.fi.muni.cz. (
                    2001041700 ; Serial
                    3H         ; Refresh
                    15m        ; Retry
                    2W         ; Expire
                    1D    )    ; Minimum
            IN NS   anxur.fi.muni.cz.
            IN NS   aisa.fi.muni.cz.
d.3.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0.0 \
            IN PTR  calypso.fi.muni.cz.
...
```

Další typy DNS záznamů

- SRV – server služby pro doménu
  - `_kerberos._udp IN SRV 0 0 88 thetis`
- LOC – zeměpisné souřadnice
  - ```
    aisa IN LOC 49 12 35.943 N \
            16 35 56.099 E \
            215 1 1 1
    ```
- SSHFP – otisk veřejného SSH klíče
  - `aisa IN SSHFP 2 1 123456789ab...890`
    ```

Konfigurace DNS klienta

- Resolvovací mechanismy – např. přes NSswitch.
- DNS servery: `/etc/resolv.conf`
- Seznam nejvýše čtyř nameserverů (má vliv na velikost timeoutu).

Příklad: Soubor resolv.conf

```
domain fi.muni.cz          nebo:
search fi.muni.cz ics.muni.cz muni.cz
nameserver 147.251.48.14
nameserver 147.251.4.33
```

Konfigurace DNS klienta

- Resolvovací mechanismy – např. přes NSswitch.
- DNS servery: `/etc/resolv.conf`
- Seznam nejvýše čtyř nameserverů (má vliv na velikost timeoutu).

Příklad: Soubor `resolv.conf`

```
domain fi.muni.cz          nebo:
search fi.muni.cz ics.muni.cz muni.cz
nameserver 147.251.48.14
nameserver 147.251.4.33
```

File Transfer Protocol

- Protokol pro přenos souborů
- Možnost přenosu i mezi dvěma vzdálenými počítači.
- Řídící spojení – `21/tcp`, iniciováno klientem.
- Datové spojení – zdrojový port (obvykle) `20/tcp`, iniciováno serverem.
- Pasivní FTP – i datové spojení otevírá klient na server. Někdy lepší průchod přes proxy-servery a firewally.
- Anonymní FTP – obvykle přihlášení na dohodnutý účet `ftp` nebo `anonymous`. Povoluje se pouze čtení určitého podstromu (a FTP-démon pro tento strom zavolá `chroot(2)`).

Otázka:

Proč má FTP problém s překladem adres?

File Transfer Protocol

- Protokol pro přenos souborů
- Možnost přenosu i mezi dvěma vzdálenými počítači.
- Řídící spojení – `21/tcp`, iniciováno klientem.
- Datové spojení – zdrojový port (obvykle) `20/tcp`, iniciováno serverem.
- Pasivní FTP – i datové spojení otevírá klient na server. Někdy lepší průchod přes proxy-servery a firewally.
- Anonymní FTP – obvykle přihlášení na dohodnutý účet `ftp` nebo `anonymous`. Povoluje se pouze čtení určitého podstromu (a FTP-démon pro tento strom zavolá `chroot(2)`).

Otázka:

Proč má FTP problém s překladem adres?

Vzdálené volání procedury

- RPC – remote procedure call.
- Vykonání procedury asynchronně na vzdáleném stroji.
- ONC RPC – dříve Sun RPC  .
- Jednoznačné číslo *balíku procedur* (= služby), verze balíku.
- Formát dat nezávislý na platformě.
- XDR – external data representation (serializace dat).
- Podobné služby: OSF DCE, CORBA, SOAP.

Port mapper

- Jmenná služba pro RPC.
- Nejsou vyhrazené porty pro balíky procedur.
- Port mapper – RPC služba na pevném portu (111/tcp, 111/udp).
- Převod *čísla balíku a verze* na číslo portu.
- Forwardování požadavků.
- Vzdálená registrace služeb.
- Implementace – `rpc.portmap(8)` nebo `rpcbind(8)`  .

Výpis informací z portmapperu

rpcinfo(8) Informace od portmapperu

```
$ rpcinfo -p
   program vers proto   port
    100000    2   tcp    111  rpcbind
    100000    2   udp    111  rpcbind
    100005    1   udp    766  mountd
    100005    1   tcp    768  mountd
    100005    2   udp    771  mountd
    100005    2   tcp    773  mountd
    100003    2   udp   2049  nfs
```

Network File System

- Sdílení souborů po síti.
- Bezestavová služba – tolerance k restartu serveru, ale jiné problémy.
- Sdílený prostor UID/GID nebo jmen uživatelů. Jiná autentizace až ve verzi 4.

NFS klient

Příklad: Připojení NFS svazku

```
# mount -t nfs aisa:/export/home /home
```

- Přístup je podobný jako k lokálním diskům.
- Nemožnost zamykání existencí souboru.
- Zamykání části souboru – démon `rpc.lockd(8)` a `rpc.statd(8)`.
- Asynchronní zápis/čtení – démoni `biod(8)` nebo `nfsiod(8)` uvnitř jádra.

NFS server

- Démoni `rpc.mountd(8)`, `rpc.nfsd(8)`, případně `rpc.ugidd(8)` pro mapování UID a GID a `rpc.gssd(8)`.
- Někdy je `nfsd(8)` uvnitř jádra a běží v několika instancích pro urychlení paralelního přístupu.
- `nfsd(8)` má pevně vyhrazený port 2049.
- Seznam sdílených adresářů: `/etc/exports`, `/etc/dfs/dfstab`  .
- `showmount(8)` – výpis informací z mount-démona (export-list, seznam připojených adresářů).
- User-space NFS server – alternativní implementace mimo jádro.

Kerberos

- Centrální autentizační systém
- Třístranná autentizace:
  - uživatel
  - služba/server
  - Kerberos server (KDC) – důvěryhodná třetí strana
- Bez zasílání hesla po síti.

Kerberos – základní pojmy

- Key Distribution Center – služba, která má databázi všech hesel.
- Realm – doména; oblast spravovaná jedním KDC.
- Principal – jméno uživatele nebo služby.
- Heslo (tajemství/secret) – pro uživatele i pro služby.
- Lístky (tickets) – vydává KDC, používají se pro prokazování totožnosti klienta vůči službě.

Příklad: Principal

```
1885@IS.MUNI.CZ
krbtgt/FI.MUNI.CZ@FI.MUNI.CZ
```

Kerberos – základní pojmy

- Key Distribution Center – služba, která má databázi všech hesel.
- Realm – doména; oblast spravovaná jedním KDC.
- Principal – jméno uživatele nebo služby.
- Heslo (tajemství/secret) – pro uživatele i pro služby.
- Lístky (tickets) – vydává KDC, používají se pro prokazování totožnosti klienta vůči službě.

Příklad: Principal

```
1885@IS.MUNI.CZ
krbtgt/FI.MUNI.CZ@FI.MUNI.CZ
```

Získání lístku

- Žádost o lístek – principal uživatele, adresa, principal služby, časové informace, další parametry.
- Odpověď KDC
  - (session key, jméno klienta, jméno serveru) zašifrováno heslem uživatele.
  - lístek (neprůhledný pro uživatele).
- Uživatel – zadáním hesla získá session key.

Získání lístku

- Žádost o lístek – principal uživatele, adresa, principal služby, časové informace, další parametry.
- Odpověď KDC
  - (session key, jméno klienta, jméno serveru) zašifrováno heslem uživatele.
  - lístek (neprůhledný pro uživatele).
- Uživatel – zadáním hesla získá session key.

Získání lístku

- Žádost o lístek – principal uživatele, adresa, principal služby, časové informace, další parametry.
- Odpověď KDC
  - (session key, jméno klienta, jméno serveru) zašifrováno heslem uživatele.
  - lístek (neprůhledný pro uživatele).
- Uživatel – zadáním hesla získá session key.

Použití lístku

- Obsah lístku – (session key, jméno a adresa klienta, jméno serveru, čas, doba platnosti) zašifrováno heslem služby.
- Autentizace – klient vytvoří *autentizátor* a pošle i s lístkem službě.
  - Autentizátor – (jméno a adresa klienta) zašifrováno session key.
- Ověření službou:
  - rozšifruje lístek,
  - získá session key,
  - rozšifruje autentizátor
  - ověří, že jméno a adresa klienta odpovídá v autentizátoru i v lístku.

Použití lístku

- Obsah lístku – (session key, jméno a adresa klienta, jméno serveru, čas, doba platnosti) zašifrováno heslem služby.
- Autentizace – klient vytvoří *autentizátor* a pošle i s lístkem službě.
  - Autentizátor – (jméno a adresa klienta) zašifrováno session key.
- Ověření službou:
  - rozšifruje lístek,
  - získá session key,
  - rozšifruje autentizátor
  - ověří, že jméno a adresa klienta odpovídá v autentizátoru i v lístku.

Použití lístku

- Obsah lístku – (session key, jméno a adresa klienta, jméno serveru, čas, doba platnosti) zašifrováno heslem služby.
- Autentizace – klient vytvoří *autentizátor* a pošle i s lístkem službě.
  - Autentizátor – (jméno a adresa klienta) zašifrováno session key.
- Ověření službou:
  - rozšifruje lístek,
  - získá session key,
  - rozšifruje autentizátor
  - ověří, že jméno a adresa klienta odpovídá v autentizátoru i v lístku.

Další vlastnosti

- Ticket granting service je také služba.
- Ticket granting ticket – TGT – lístek pro získávání dalších lístků.
- Získání TGT – program `kinit(1)` nebo `pam_krb5(8)`. Dále `klist(1)`, `kdestroy(1)`.
- Replay cache – proti odposlechnutí.
- Autentizace služby vůči klientovi.
- Forwardovatelné lístky – nejsou vázané na adresu.
- Proxy lístky – delegace části pravomocí na službu.
- Interakce mezi realmy – například cross-realm trust.
- Záložní KDC – replikace.

Implementace

- MIT Kerberos V – referenční implementace.
- Heimdal – evropská implementace.
- Klientské aplikace – nutnost kerberizace (mj. rozšíření protokolu).
- Konfigurace klientů – `/etc/krb5.conf`.
- Klíče služeb – `/etc/krb5.keytab`, `ktutil(8)`.

Přečtěte si ^_~

Designing an Authentication System
(rozhovor ve čtyřech scénách).
http://web.mit.edu/kerberos/www/dialogue.html.

Implementace

- MIT Kerberos V – referenční implementace.
- Heimdal – evropská implementace.
- Klientské aplikace – nutnost kerberizace (mj. rozšíření protokolu).
- Konfigurace klientů – `/etc/krb5.conf`.
- Klíče služeb – `/etc/krb5.keytab`, `ktutil(8)`.

Přečtěte si ^_~

Designing an Authentication System
(rozhovor ve čtyřech scénách).
`http://web.mit.edu/kerberos/www/dialogue.html`.

LDAP

- Light-weight Directory Access Protocol
- Původ – odlehčená varianta DAP pro přístup k X.500 adresářům.
- Adresář
  - ne jako ve filesystému,
  - analogie telefonního seznamu (kartičky).
- Adresářová služba – databáze pro rychlé vyhledávání a občasné modifikace dat.

LDAP – vlastnosti

- Celosvětový distribuovaný adresář – i odkazy mezi LDAP servery.
- Vyhledávání – v daném podstromu, objekt určitých atributů.
- Odkazy – referrals – něco jako symbolické linky.
- Read-mostly databáze – nejsou transakce, rychlé vyhledávání.

LDAP strom

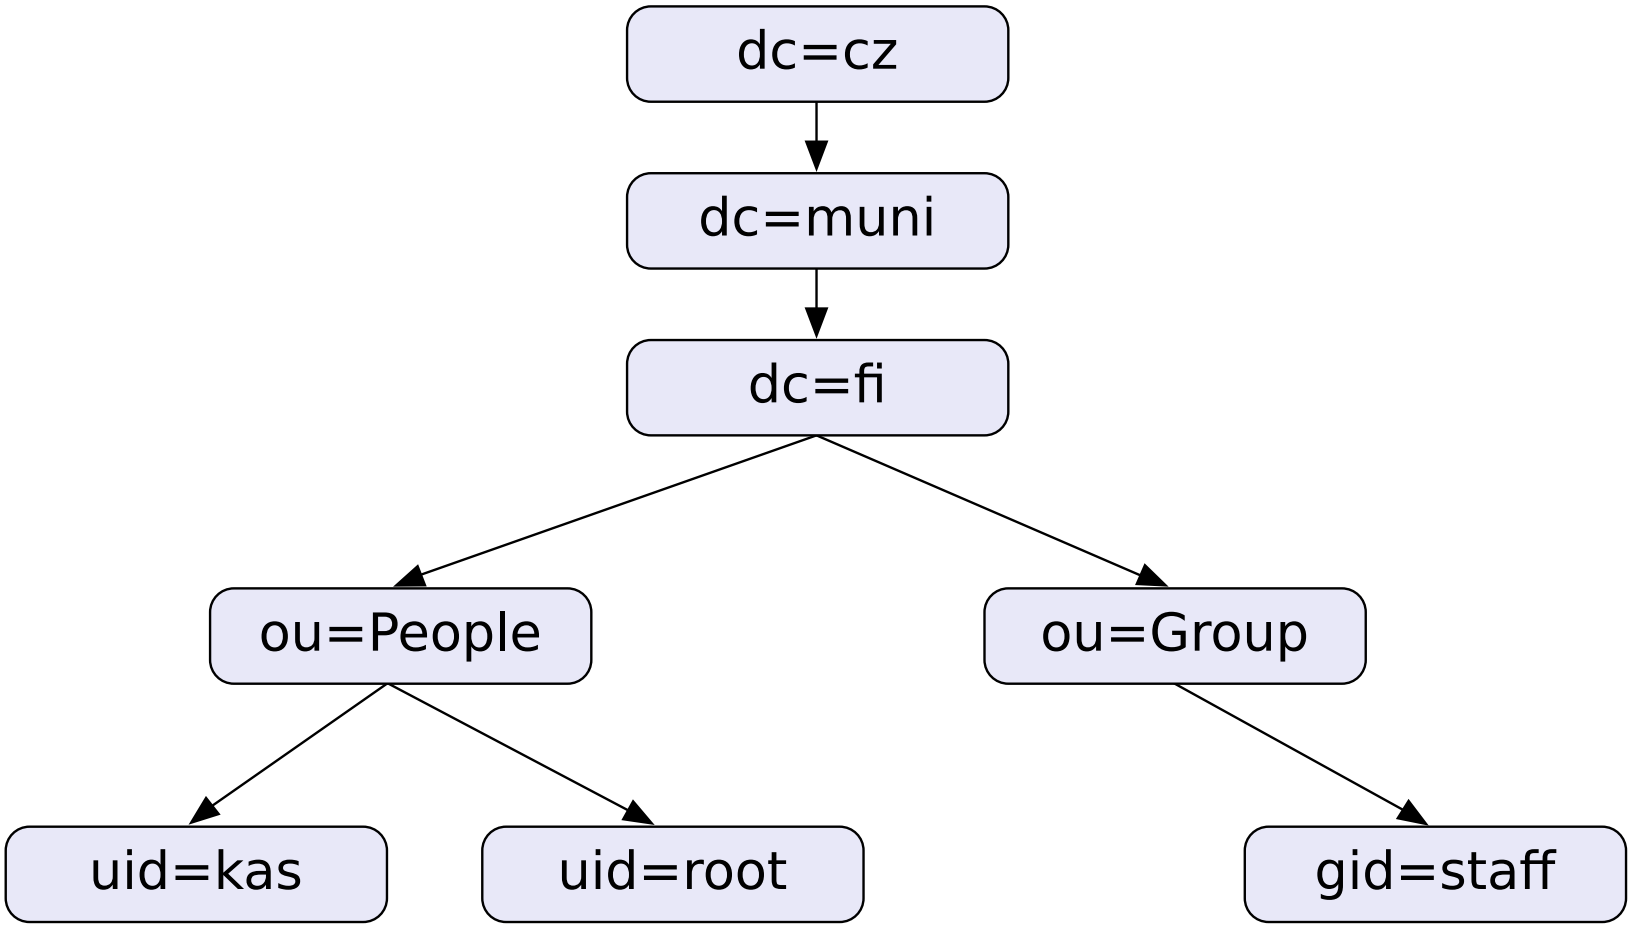
dc=cz
dc=muni
dc=fi
ou=People
ou=Group
uid=kas
uid=root
gid=staff

LDAP – organizace dat

- Uzly stromu – objekty.
- Distinguished name (DN) poloha ve stromu (cesta ke kořeni) – např.: `uid=kas,ou=People,dc=fi,dc=muni,dc=cz`
- Relativní DN – v rámci jedné úrovně (`uid=kas`).
- Objekty – patří do tříd (i více), mají různé atributy.
- Schéma – definice tříd (názvy atributů, typy hodnot, povinné/nepovinné atributy). Definice ve formátu ASN.1.

Autentizace v LDAPu

- Autentizace proti LDAP serveru – externí (SASL), simple (heslo je součástí objektu), anonymní.
- Subjekt práv – obecné DN. Není zvlášť databáze uživatelů.
- Objekt práv – podstrom, jednotlivá DN, *self*, jednotlivé atributy.
- Přístupová práva – *authenticate*, *compare*, *read*, *search*, *write*.

Příklad: Formát LDIF

```
$  ldapsearch -H ldap://ldap.fi.muni.cz/ \
     -b ou=People,dc=fi,dc=muni,dc=cz uid=kas -x
# kas, People, fi.muni.cz
dn: uid=kas,ou=People,dc=fi,dc=muni,dc=cz
uid: kas
objectClass: account
objectClass: posixAccount
userPassword:: e2NyeXB0fXg=
loginShell: /bin/bash
uidNumber: 11561
gidNumber: 10100
homeDirectory: /home/kas
gecos: Jan Kasprzak
host: aisa
host: anxur
```

LDAP v UNIXu

- Napojení na nsswitch – možnost uložení tabulek uživatelů, skupin, služeb, protokolů ...
- Modul `nss_ldap` – konfigurace v `/etc/ldap.conf`.
- Mapování podstromu LDAP objektů a jejich atributů na záznamy v tabulce uživatelů.
- Automatický převod – MigrationTools – `www.padl.com`.
- Uživatelé – třídy `account`, `posixAccount` a `shadowAccount`.
- Zabezpečení – možnost použít LDAP nad SSL (`nss_ldap` umí kontrolovat i certifikát serveru).

Ukládání hesel v LDAPu

- Několik algoritmů ukládání.
- Formát hesla – např.: `{SMD5}F92mezjPoWxSE`.
- Hashovací metody – `CRYPT`, `SMD5`, `MD5`, `SSHA`, `SHA`.
- Generování hashované podoby hesla – `slappasswd(8)`.
- Heslo v LDIF formátu – často kódované base64. Oddělovač `::` v LDIF. Podobně se kódují binární data.

Úkol: Jaké mám heslo? ^_~

```
dn: uid=kas,ou=People,dc=fi,dc=muni,dc=cz
...
userPassword:: e2NyeXB0fXg=
```

Ukládání hesel v LDAPu

- Několik algoritmů ukládání.
- Formát hesla – např.: `{SMD5}F92mezjPoWxSE`.
- Hashovací metody – `CRYPT`, `SMD5`, `MD5`, `SSHA`, `SHA`.
- Generování hashované podoby hesla – `slappasswd(8)`.
- Heslo v LDIF formátu – často kódované base64. Oddělovač `::` v LDIF. Podobně se kódují binární data.

Úkol: Jaké mám heslo? ^_~

```
dn: uid=kas,ou=People,dc=fi,dc=muni,dc=cz
...
userPassword:: e2NyeXB0fXg=
```

Implementace LDAPu

- Řádkoví klienti – `ldapsearch(1)`, `ldapadd(1)`, `ldapdelete(1)`, man `ldapmodify(1)`.
- Ostatní klienti – `GQ(1)`, nss_ldap, Mozilla.
- Servery – OpenLDAP, iPlanet/SunONE  , Oracle Internet Directory, Fedora Directory Server  , ...

Elektronická pošta

- Off-line komunikace.
- Textová komunikace (později i další druhy dat).

Komponenty poštovního systému

- MTA – program pro přenos zpráv po síti (`sendmail`, `qmail`, `exim`).
- MUA – uživatelský program pro čtení a posílání zpráv (`elm`, `exmh`, `mutt`).
- MDA – program pro lokální doručení do schránky (`mail(1)`, `procmail(1)`, `deliver(1)`).

Obálka zprávy

- Obálkový odesílatel – kam poslat chybovou zprávu.
- Obálkový adresát – skutečný příjemce zprávy.

Otázka:

Kdo je obálkovým odesílatelem chybové zprávy?

Upozornění:

Obálka $\neq$ hlavičky!

Obálka zprávy

- Obálkový odesílatel – kam poslat chybovou zprávu.
- Obálkový adresát – skutečný příjemce zprávy.

Otázka:

Kdo je obálkovým odesílatelem chybové zprávy?

Upozornění:

Obálka $\neq$ hlavičky!

Obálka zprávy

- Obálkový odesílatel – kam poslat chybovou zprávu.
- Obálkový adresát – skutečný příjemce zprávy.

Otázka:

Kdo je obálkovým odesílatelem chybové zprávy?

Upozornění:

Obálka $\neq$ hlavičky!

Formát zpráv

- RFC 2822 „Internet Message Format“ (dříve RFC 822).
- Hlavička – obsahuje řídící informace zprávy a má pevnou strukturu.
- Tělo zprávy oddělené prázdným řádkem.

Hlavičky zprávy

- řádky tvaru *klíč*: *hodnota*
- řádky tvaru *bílý znak hodnota* – pokračování hodnoty z předchozího řádku.

Formát zpráv

- RFC 2822 „Internet Message Format“ (dříve RFC 822).
- Hlavička – obsahuje řídící informace zprávy a má pevnou strukturu.
- Tělo zprávy oddělené prázdným řádkem.

Hlavičky zprávy

- řádky tvaru *klíč*: *hodnota*
- řádky tvaru *bílý znak hodnota* – pokračování hodnoty z předchozího řádku.

Původce zprávy

`From:` mailbox autora/autorů zprávy.

`Sender:` skutečný odesílatel zprávy, je-li ve `From:` více mailboxů.

`Reply-To:` na jakou adresu se má poslat odpověď.

Adresát zprávy

`To:` adresa hlavního příjemce.

`Cc:` carbon copy – další příjemci.

`Bcc:` blind carbon copy – totéž, ale tato hlavička se při odesílání ze zprávy odstraní.

Identifikace

`Message-Id:` jednoznačná identifikace zprávy. Používá se například k detekci zacyklení pošty.

`In-Reply-To:` „v odpovědi na“ – identifikátor předchozí zprávy (na kterou tato zpráva odpovídá).

`References:` identifikátory předchozích zpráv.

Trasování zprávy

`Received:` každý MTA po cestě přidá jeden takovýto řádek se služebními informacemi.

`Return-Path:` u doručené zprávy cesta k odesílateli.

Ostatní položky

`Date:` datum vzniku zprávy.

`Subject:` předmět, věc.

`Keywords:` klíčová slova.

`X-`*`cokoli`*`:` nestandardní hlavičky (`X-Face:`).

MIME

- Multipurpose Internet Mail Extensions – RFC 1521, 2045–2049 a 2231.
- Původně – jen ASCII znaky.
- Je-li MIME – ASCII v hlavičkách, v těle libovolné (je-li uvedeno).

Povinné hlavičky MIME

```
Mime-Version: 1.0
Content-Type: typ[podtyp[; parametry ...]]
Content-Transfer-Encoding: přenosové kódování
```

MIME

- Multipurpose Internet Mail Extensions – RFC 1521, 2045–2049 a 2231.
- Původně – jen ASCII znaky.
- Je-li MIME – ASCII v hlavičkách, v těle libovolné (je-li uvedeno).

Povinné hlavičky MIME

```
Mime-Version: 1.0
Content-Type: typ[podtyp[; parametry ...]]
Content-Transfer-Encoding: přenosové kódování
```

Jednoduché typy/podtypy:

text / plain, html, richtext, ...
image / gif, jpeg, g3fax, ...
audio / basic, ...
video / mpeg, quicktime, ...
application / octet-stream, postscript, pdf, ...
x-*nestandardní*

Složené typy/podtypy

`multipart/mixed` – více objektů různých typů.

`multipart/parallel` – paralelně prezentovatelné části (například text a zvuk).

`multipart/alternative` – MUA má zobrazit jednu z částí (například `text/plain` a `text/html`).

Přenosová kódování

- Přenosové kódování (např. hlavička `Content-Transfer-Encoding:`).
- Nespecifikují znakovou sadu.

`7bit` – jen ASCII.

`base64` – úsporné kódování (3 bajty na 4 znaky).

`quoted-printable` – ne-ASCII bajty a rovnítko kódovány jako =*hexa kód*.

`8bit` – přímé použití libovolných bajtů.

Příklad: Zápis slova „ježek“ v UTF-8

```
QP:     je=C5=BEek
Base64: amXFvmVr
```

Přenosová kódování

- Přenosové kódování (např. hlavička `Content-Transfer-Encoding:`).
- Nespecifikují znakovou sadu.

`7bit` – jen ASCII.

`base64` – úsporné kódování (3 bajty na 4 znaky).

`quoted-printable` – ne-ASCII bajty a rovnítko kódovány jako =*hexa kód*.

`8bit` – přímé použití libovolných bajtů.

Příklad: Zápis slova „ježek“ v UTF-8

```
QP:     je=C5=BEek
Base64: amXFvmVr
```

Přenosová kódování

- Přenosové kódování (např. hlavička `Content-Transfer-Encoding:`).
- Nespecifikují znakovou sadu.

`7bit` – jen ASCII.

`base64` – úsporné kódování (3 bajty na 4 znaky).

`quoted-printable` – ne-ASCII bajty a rovnítko kódovány jako =*hexa kód*.

`8bit` – přímé použití libovolných bajtů.

Příklad: Zápis slova „ježek“ v UTF-8

```
QP:     je=C5=B5ek
Base64: amXFvmVr
```

Kódování MIME Words

- Hlavičky – jen ASCII znaky.
- RFC 2047 – kódování ne-ASCII znaků v hlavičkách.
- Formát =?*přenosové kódování*?*charset*?*text*?=

Příklad: „Křemílek a Vochomůrka“

```
=?Q?UTF-8?K=C5Tem=C3=ADlek=20a=20?=
=?Q?UTF-8?Vochom=C5=AFrka?=
```

Kódování MIME Words

- Hlavičky – jen ASCII znaky.
- RFC 2047 – kódování ne-ASCII znaků v hlavičkách.
- Formát =?*přenosové kódování*?*charset*?*text*?=

Příklad: „Křemílek a Vochomůrka“

```
=?Q?UTF-8?K=C5Tem=C3=ADlek=20a=20?=
=?Q?UTF-8?Vochom=C5=AFrka?=
```

SMTP

- Simple Mail Transfer Protocol – protokol pro přenos pošty nad TCP/IP.
- RFC 2821 – RFC 821.
- Rozšiřitelnost – ESMTP (8-bitový přenos, ETRN, atd).
- Inicializace – `HELO`, `EHLO`.
- Předání obálky:

  `MAIL FROM:<`*odesílatel*`>`
  `RCPT TO:<`*adresát*`>`
- Předání zprávy – `DATA`; zakončeno tečkou na samostatném řádku.
- Ukončení relace – `QUIT`.

SMTP – další možnosti

- Vynucený přenos – `ETRN`.
- Kontrola odesilatele – `VRFY`.
- Expanze aliasů – `EXPN`.
- Dotaz na velikost – `SIZE`.
- Zvýšení propustnosti – `PIPELINING`.
- Přenos 8-bitových dat – `8BITMIME`.

Formát mailboxů v UNIXu

- `mbox` – jeden soubor.
  - Zprávy začínají „`From` *`mezera`*“ na začátku řádku.
  - Následuje adresa odesílatele a datum přijetí.
  - Zbytek je vlastní zpráva (hlavičky, tělo).
  - Odsazení „`From` *`mezera`*“ většítkem.
- Maildir – Podadresáře: `tmp`, `new`, `cur`. Odstraňuje problémy se zamykáním.
- MMDF folder – podobné jako mailbox, ale zprávy jsou odděleny čtyřmi znaky `Ctrl-A`.
- MH-folder – adresář; jednotlivé zprávy jsou uloženy v souborech s číselnými názvy. Soubory označené ke smazání mají název začínající čárkou.

Lokální klienti

- Přímý přístup k mailboxu (zamykání). Někdy set-gid pro skupinu `mail`.
- Odesílání – na vstup `/usr/sbin/sendmail -t`.

Síťoví klienti

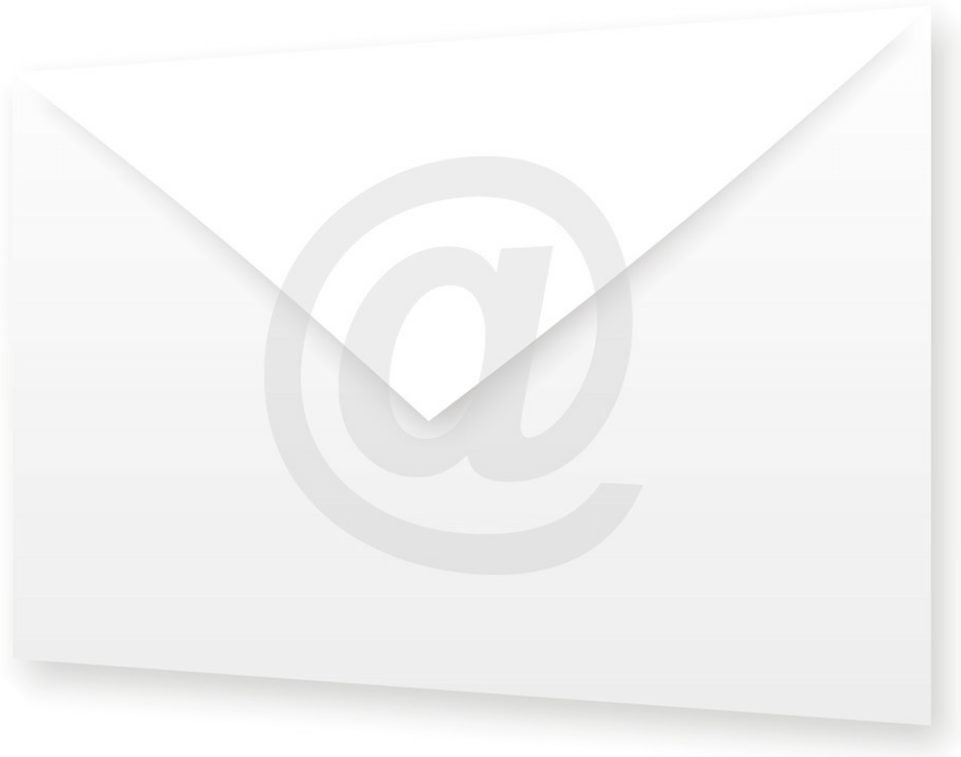

- Čtení pošty – POP-3 nebo IMAP.
- Odesílání – SMTP přes relay.

POP-3

- Post Office Protocol
- Výlučný přístup k mailboxu.
- Atomická operace během celé session.
- Nelze více schránek v rámci jednoho účtu.

IMAP

- Internet Mail Access Protocol.
- Sdílený přístup k mailboxu.
- Práce s více schránkami v rámci jednoho účtu.
- Možnost čtení pošty z více počítačů.

Kapitola 5

Zdroje

Zdroje obrázků

- Strany 48, 49, 54, 80, 144, 153, 154, 404: http://www.sxc.hu
- Strana 21: https://static.zerochan.net/Andou.Mahoro.full.114965.jpg
- Strana 3: http://cm.bell-labs.com/cm/cs/who/dmr/otherunix.html
- Strana 191: http://all-free-download.com/
- Ostatní obrázky: Servisní středisko pro e-learning na MU http://is.muni.cz/stech/