B4B35OSY: Operační systémy

Lekce 9: Vstup/výstup, ovladače

Michal Sojka
michal.sojka@cvut.cz

January 25, 2024

Osnova

Vstup a výstup v OS

Input/Output (I/O)

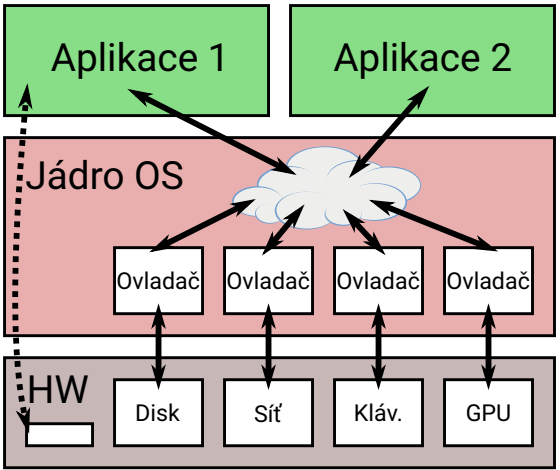

- Takto to vypadá v OS s monolitickým jádrem (Linux, Windows)
  - Pro přístup k I/O HW musí aplikace využívat služby jádra
  - Privilegované aplikace (např. už. root v Linuxu) mohou přistupovat k některému I/O HW přímo (viz sekci Ovladače v uživatelském prostoru)
- V OS s μ-jádry jsou ovladače většinou samostatné procesy mimo jádro, tedy také v uživatelském prostoru

Vstup a výstup

Input/Output (I/O)

- Způsob, jak počítač komunikuje s okolním světem
  - Datová úložiště (disky)
  - Sítě
  - Klávesnice, monitor, …
- Uživatelská aplikace nemá přímý přístup k periferiím (HW)
  - Aplikace, která nepoužívá služby jádra OS může pouze číst a zapisovat do (virtuální) paměti a vykonávat některé instrukce na CPU
- Pro přístup k periferiím musí používat služby OS, které
  - zajišťují „bezpečné“ **sdílení** periferií mezi aplikacemi a
  - **abstrahují** hardwarové detaily a poskytují jednotné API pro všechny periferie stejné třídy.
  - K tomu využívají služeb **ovladačů zařízení**, které naopak řeší všechny detaily práce s konkrétním hardwarem.

Úložiště

- HW pro ukládání velkého množství dat
- Není možné číst data po jednotlivých bytech, ale po tzv. blocích či sektorech
- Pevný disk – velikost bloku 512 B, 4 kB, …
  - Rotační (HDD), pomalé, ale spolehlivé s velkou kapacitou
  - Solid-state (SSD), rychlé, menší kapacita
- Flash paměť – někdy lze číst po bytech, ale mazat jde jen po blocích – typicky 128 kB
  - Typicky v embedded zařízeních
  - Základem pro SSD disky

Model HW

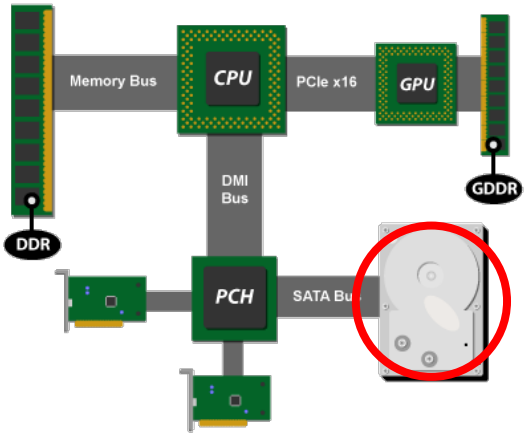

Platforma Intel's P55. Zdroj: ArsTechnica

- Pevný disk (HDD či SSD) je malý počítač, který komunikuje s hlavním CPU pomocí sběrnice.
- Přístup k disku je řádové pomalejší než přístup k paměti
- CPU posílá příkazy, disk je autonomně vykonává
- Disk využívá tzv. *Direct Memory Access* (DMA), také označovaný jako *Bus Master*.
  - Data proudí do paměti bez zásahu software v CPU

Model HW

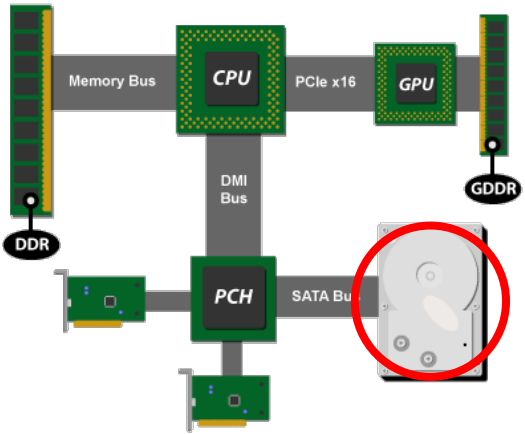

Platforma Intel's P55. Zdroj: ArsTechnica

- Typické příkazy:
  - Ulož do sektorů 123456–123460 data z paměti na adrese 0x2f003200
  - Načti 32 sektorů počínaje č. 7654 a ulož je do paměti na adresu 0x302f1200
- Disky umí zpracovávat víc příkazů najednou (typicky 32)
  - Interně provádí optimalizace (např. změna pořadí vykonávání či slučování požadavků).
  - O dokončení operace je CPU (přesněji ovladač běžící na CPU) informován přerušením.

Přístup aplikací k úložišti

- Aplikace typický nepřistupují k úložišti přímo, ale skrze **souborový systém** (viz příští přednášku)
- OS optimalizuje přístup k úložišti:
  - Spravuje vyrovnávací paměť pro rychlejší přístup k datům na disku
  - OS sám předem načítá data, o kterých předpokládá, že budou brzy potřeba
  - Pro pomalé rotační disky:
    - Slučuje požadavky aplikací do větších
    - Rozvrhuje, kdy který požadavek vykonat – optimalizace přejezdů hlaviček – tzv. IO scheduler.
  - U rychlých SSD nemá přílišná optimalizace moc smysl, protože by tím OS jen zdržoval

Disková vyrovnávací paměť

Page cache – název používaný Linuxem pro vyrovnávací paměť disku

- Data čtená z disku resp. zapisovaná na disk jsou uchovávána v paměti RAM pro případné další použití
- OS se snaží využít veškerou volnou paměť jako diskovou cache
- Spravována po stránkách (4 kB)
  - I když starší disky používaly 512 B sektory, OS (téměř) vždy načítá celé 4 kB.

Čtení a zápis

- Čtení z disku:
  1. Aplikace zavolá read()
  2. Pokud už jsou data v page cache, pokračuje se krokem 6
  3. Jádro OS (JOS) přepošle požadavek správnému ovladači
  4. Ovladač disku pošle příkaz pro načtení dat a uložení do page cache
  5. Disk sám o sobě posílá data do paměti (DMA) a o dokončení informuje přerušením (interrupt request, IRQ)
  6. V reakci na IRQ, JOS zkopíruje data z page cache do paměti aplikace

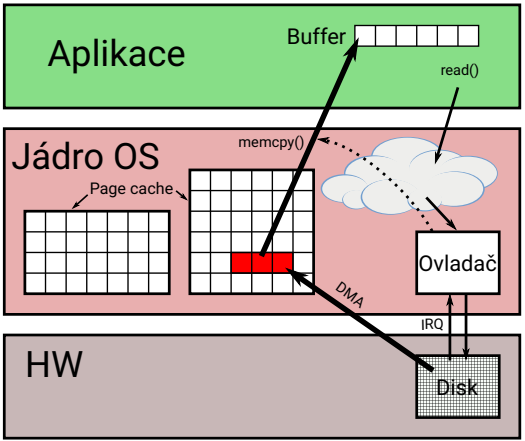

Čtení a zápis

- Zápis na disk:
  1. Aplikace zavolá write()
  2. JOS data zkopíruje z aplikace do page cache a write() se vrátí.
  3. Čas od času JOS zapisuje „špinavé stránky“ na disk. V Linuxu označováno jako „writeback“.
     - Zápis se dá vynutit systémovým voláním fsync() (Linux)

Pozn.: *fsync()* vs. *fflush()*
fsync() ukládá data z page cache na disk, *fflush()* posílá data z bufferu aplikace (schovaný v libc) do jádra (page cache v případě práce se soubory soubory).

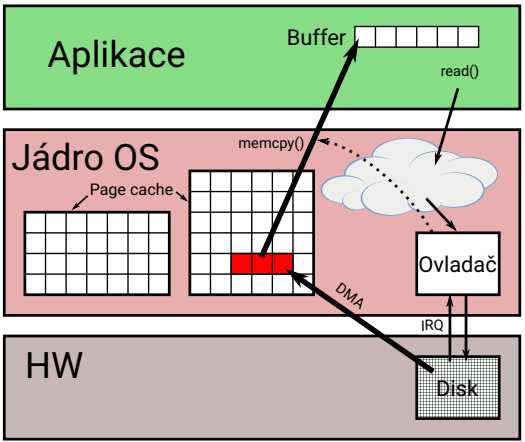

Anketa

Jaký je rozdíl mezi `fsync` a `fflush`?

A Různá jména pro stejnou funkcionalitu.

B `fsync` synchronizuje „stdio“ buffery v aplikaci s buffery v jádře
`fflush` posílá obsah bufferů v jádře (page cache) hardwaru

C `fsync` posílá obsah bufferů v jádře (page cache) hardwaru
`fflush` synchronizuje „stdio“ buffery v aplikaci s buffery v jádře

Čtení a zápis bez zbytečného kopírování dat

- Aplikace může požádat JOS, aby „namapovalo“ stránky diskové cache do jejího adresního prostoru (v UNIXu systémové volání `mmap()`)
- Při prvním přístupu k paměti vrácené funkcí mmap dojde k výjimce (výpadku stránky), protože žádná data nejsou v paměti načtena
  1. JOS se podívá do tabulky mapování (pro Vás viditelná v /proc/<PID>/maps), aby zjistil, jaký soubor je potřeba načíst a načte data z disku do stránkové cache
  2. Poté modifikuje stránkovací tabulku procesu a vrátí se z obsluhy výjimky na instrukci, která výjimku způsobila
  3. Tentokrát se instrukce provede úspěšně a aplikace pokračuje
- Zápis se provádí stejně jako čtení – prostým přístupem (zápisem) k namapované paměti
- Čas od času JOS zapisuje „špinavé stránky“ na disk.
- Může aplikace zjistit (nebo zajistit), že jsou data bezpečně uložena na disku?

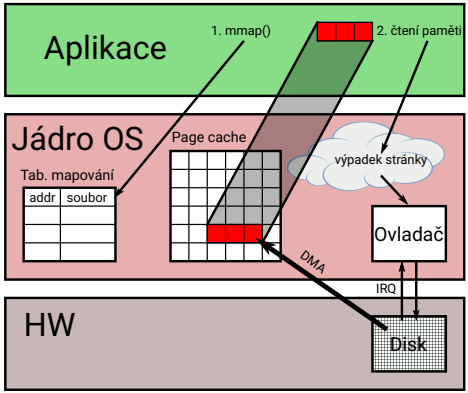

- Pouze při použití *msync()* máme jistotu, že jsou data uložena na disku (pro případ výpadku napájení)
- Sdílení dat jednoho souboru mezi procesy se uskutečňuje prostřednictvím page-cache a není vázáno na uložení na disk

Disková pole

RAID – Redundant Array of Independent Disks

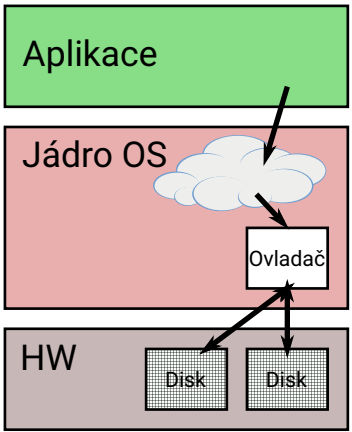

- Pokud se disk porouchá, přijdeme o (cenná) data
- Redundance – data jsou uložená na více místech najednou
- Možnost implementace v HW nebo v SW (OS)
- Rychlost SW implementace – čtení typicky rychlejší (paralelní čtení z více disků), zápis o něco pomalejší.
- Nahradí RAID zálohování dat?
  - Požár v serverovně – záloha na jiném místě
  - Administrátor omylem smaže data

Typy diskových polí

- RAID0 – spojení více disků do jednoho virtuálního (bez redundance)
- RAID1 – zrcadlení, efektivita: 50%
- RAID5 – prokládání dat a parita, min. 3 disky, toleruje ztrátu jednoho disku, efektivita $\frac{n-1}{n}$
  $Ap = A1 \oplus A2 \oplus A3$ (xor)
  Při poruše 1. disku:
  $A1 = Ap \oplus A2 \oplus A3$
- RAID6 – toleruje ztrátu dvou disků

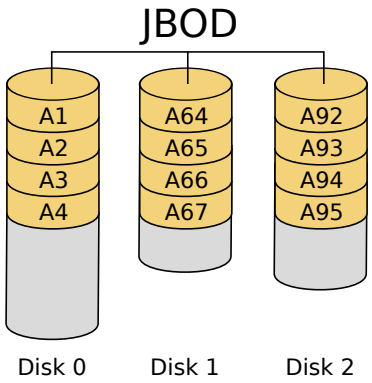

Typy diskových polí

- RAID0 – spojení více disků do jednoho virtuálního (bez redundance)
- RAID1 – zrcadlení, efektivita: 50%
- RAID5 – prokládání dat a parita, min. 3 disky, toleruje ztrátu jednoho disku, efektivita $\frac{n-1}{n}$
  $Ap = A1 \oplus A2 \oplus A3$ (xor)
  Při poruše 1. disku:
  $A1 = Ap \oplus A2 \oplus A3$
- RAID6 – toleruje ztrátu dvou disků

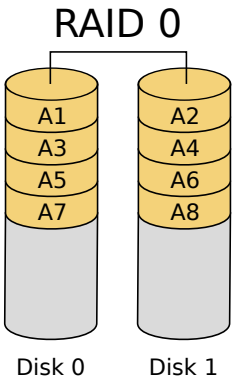

Typy diskových polí

- RAID0 – spojení více disků do jednoho virtuálního (bez redundance)
- RAID1 – zrcadlení, efektivita: 50%
- RAID5 – prokládání dat a parita, min. 3 disky, toleruje ztrátu jednoho disku, efektivita $\frac{n-1}{n}$
  $Ap = A1 \oplus A2 \oplus A3$ (xor)
  Při poruše 1. disku:
  $A1 = Ap \oplus A2 \oplus A3$
- RAID6 – toleruje ztrátu dvou disků

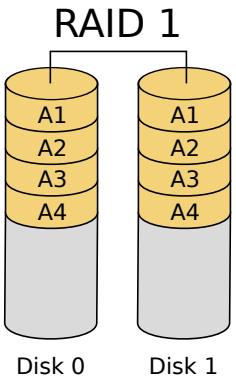

Typy diskových polí

- RAID0 – spojení více disků do jednoho virtuálního (bez redundance)
- RAID1 – zrcadlení, efektivita: 50%
- RAID5 – prokládání dat a parita, min. 3 disky, toleruje ztrátu jednoho disku, efektivita $\frac{n-1}{n}$
  $Ap = A1 \oplus A2 \oplus A3$ (xor)
  Při poruše 1. disku:
  $A1 = Ap \oplus A2 \oplus A3$
- RAID6 – toleruje ztrátu dvou disků

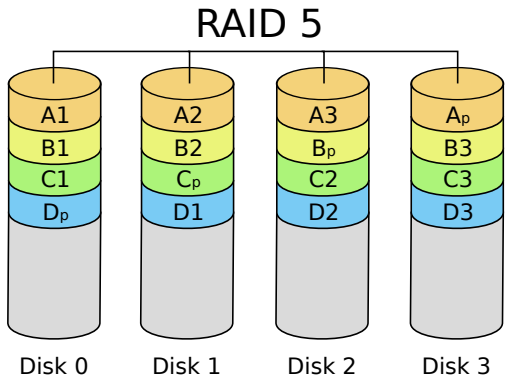

Typy diskových polí

- RAID0 – spojení více disků do jednoho virtuálního (bez redundance)
- RAID1 – zrcadlení, efektivita: 50%
- RAID5 – prokládání dat a parita, min. 3 disky, toleruje ztrátu jednoho disku, efektivita $\frac{n-1}{n}$
  $Ap = A1 \oplus A2 \oplus A3$ (xor)
  Při poruše 1. disku:
  $A1 = Ap \oplus A2 \oplus A3$
- RAID6 – toleruje ztrátu dvou disků

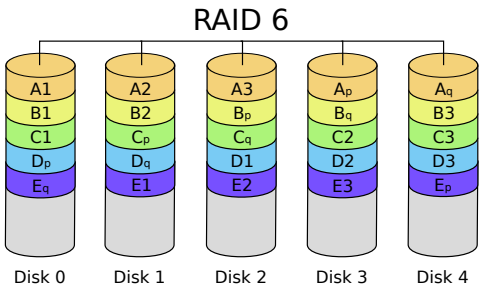

Sítě

- Síťový subsystém OS řeší mnoho různých aspektů:
  - Ethernet, Wi-Fi, Bluetooth, CAN, …
  - Routování
  - Virtuální sítě – VPN, …
- Ethernet představuje základní model sítě používaný OS
  - Základní funkce všech technologií jsou stejné: **posílání a příjem rámců**
  - Jednotlivé síťové technologie se liší především nastavováním parametrů (WiFi: SSID, Ethernet: bitrate,
- OS reprezentuje síťový HW pomocí tzv. síťových rozhraní
- Sítě jsou velmi rychlé – dnes až 100 Gbps
- Síťový subsystém OS musí být velmi efektivní, aby OS nebyl úzkým hrdlem
- Úložiště a sítě mají z pohledu OS mnoho společného
  - Do nedávna nebyla efektivita diskového subsystému důležitá, ale s nástupem rychlých SSD disků nabývá na důležitosti a síťování je zde inspirací

Síťový hardware

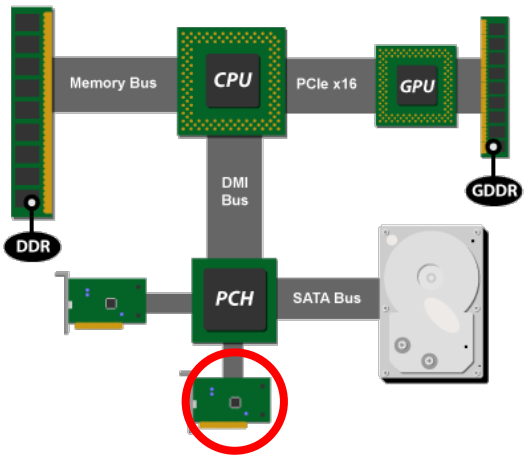

Platforma Intel's P55. Zdroj: ArsTechnica

- Sítové rozhraní je malý počítač, který komunikuje s hlavním CPU pomocí sběrnice.
- CPU posílá příkazy, síťové rozhraní je autonomně vykonává
- Používá se tzv. *Direct Memory Access* (DMA), také označovaný jako *Bus Master*.
  - Data proudí z/do paměti bez zásahu software v CPU

Síťový hardware

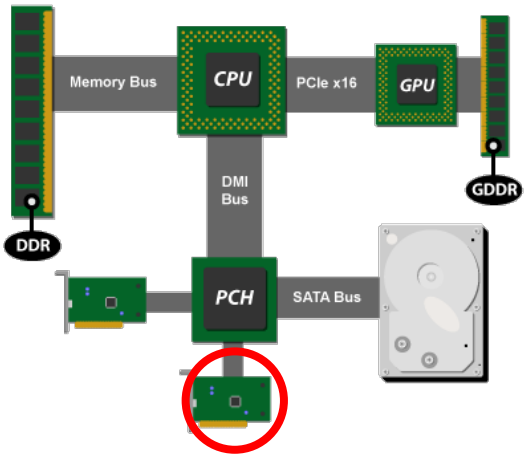

Platforma Intel's P55. Zdroj: ArsTechnica

- Typické „příkazy“:
  - Pošli rámec, který je uložený na adrese 0x2f003200.
  - Pokud přijmeš rámec, ulož ho na adresu 0x302f1200.
  - Implementováno pomocí tabulky popisovačů rámců (packet descriptor table) – ovladač vytvoří v paměti tabulku ukazatelů na rámce a síťové rozhraní se do ní „kouká“ při příjmu či odesílání rámce.

Socket

- Většina OS nabízí aplikacím rozhraní *BSD Sockets*.
- Socket je datová struktura v jádře reprezentující jeden koncový bod síťové komunikace
- Socket ukládá informace o použitém komunikačním protokolu (např. zda se jedná o TCP či UDP a jaké zdrojové či cílové adresy a porty se mají používat)
- V aplikaci jsou sockety reprezentovány pomocí „file descriptorů“, podobě jako soubory

```c
#define CHECK(call) ({ int ret = (call); \\
  if (ret == -1) { perror(#call); exit(1); }; ret; })
int fd;
struct sockaddr_in addr;
char buf[MAX_BUF];

/* Create a UDP socket */
fd = CHECK(socket(AF_INET, SOCK_DGRAM, 0));
/* Configure server address (any) and port */
addr.sin_family = AF_INET;
addr.sin_addr.s_addr = INADDR_ANY;
addr.sin_port = htons(1234);
CHECK(bind(fd, (struct sockaddr*)&addr, sizeof(addr)));
CHECK(recv(fd, buf, MAX_BUF, 0));
// ...
close(fd);
```

Odesílání dat aplikacemi

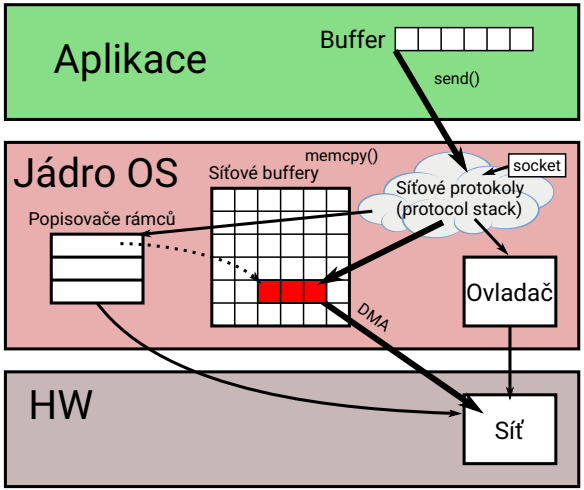

1. Aplikace zavolá send()/write() na otevřený socket
2. JOS si zkopíruje odesílaná data do síťových bufferů
3. Na základě informací ze socketu a dalších zdrojů přidá JOS (tzv. protocol stack) k aplikačním datům potřebné hlavičky a vyvolá patřičnou metodu ovladače
4. Ovladač upraví tabulku popisovačů rámců, a dá vědět síťovému HW (zápisem do registru v síťovém HW), že se tabulka popisovačů změnila.
5. Síťový HW začne číst data z paměti (DMA) a odešle je.

Anketa

Jak ovladač upozorní HW, že data v paměti může začít odesílat na síť?

A Zasláním přerušení do HW.

B Zápisem do registru daného HW.

C Nijak. HW sám časem zjistí, že se v paměti objevila nová data k odeslání.

Pozor: Registry v síťovém (či jiném) HW jsou něco jiného než registry CPU.

Příjem dat aplikacemi

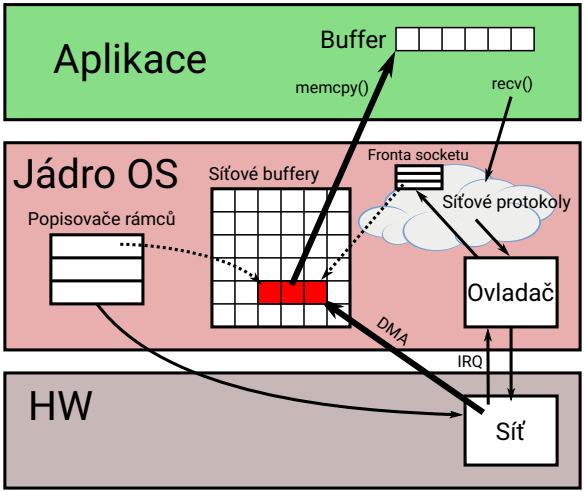

1. Po otevření socketu a jeho nastavení pro příjem operací `bind` se v jádře alokují buffery pro příjem a ovladač nastaví HW, aby tam ukládal přijímané rámce.
2. Aplikace zavolá recv()/read().
3. JOS zkontroluje, zda fronta socketu obsahuje nějaká přijatá data. Pokud ano, pokračuje se krokem 7, v opačném případě se volající vlákno zablokuje a čeká.
4. Síťové rozhraní autonomně ukládá přijímané rámce do paměti (DMA).
5. Po dokončení příjmu je upozorněn ovladač (přerušení – IRQ) a ten pak aktivuje zpracování rámce síťovými protokoly.
6. Poté JOS zařadí rámec do fronty patřičného soketu.
7. JOS přijatá data nakopíruje ze síťových bufferů v jádře do aplikačního bufferu a systémové volání se vrátí do aplikace.

Síťové protokoly

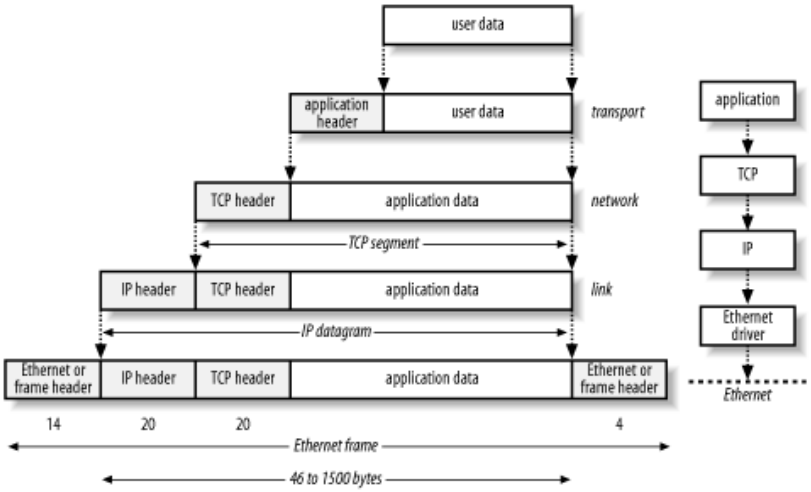

Datová struktura pro práci se síťovými rámci

struct skbuff v Linuxu

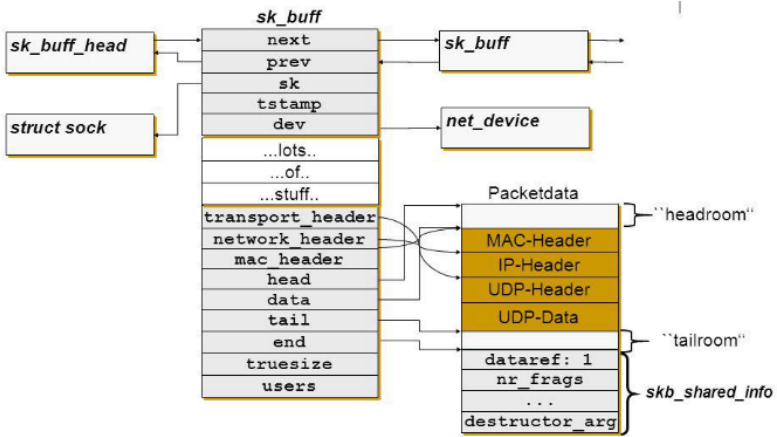

- Možnost přidávat hlavičky před data, bez nutnosti jejich kopírování
- Scatter-gatter DMA – hardware si umí sestavit rámec „za běhu“ z více částí

Příjem a odesílání dat bez kopírování

Zero-copy networking

- Podobný „trik“, jako s diskovou vyrovnávací pamětí
- `socket(AF_PACKET, ...)` + `mmap()`
- Síťový HW přijímá/odesílá rámce rovnou do/z paměti kontrolované aplikací
- Nevýhody:
  - Aplikace si musí sama řešit přidávání a odebírání hlaviček
  - Aplikace nesmí modifikovat rámce (např. kvůli chybě v programu) , které jsou v procesu odesílání.

Rozvrhování rámců při odesílání

Traffic scheduling/control

- Další z činností, kterou řeší síťový stack OS
- Prioritizace interaktivní komunikace
- Spravedlivé rozdělení šířky pásma mezi uživatele (zákazníky)
- Problém zvaný „buffer-bloat“
  - Ovladač může do odesílací fronty (popisovač rámců k odeslání) uložit velké množství rámců.
  - Síťový HW odesílá rámce v pořadí, v jakém jsou tam uvedeny.
  - Pokud je na konci fronty rámec, který by měl být odeslán přednostně, musí dlouho čekat.
  - Řešení:
    - Fronta ovladače se udržuje krátká, aby kritické rámce mohly „předbíhat“
- Moderní síťový hardware implementuje více front pro odesílání (i příjem)
  - Rámce jsou rozvrhovány (i) v hardwaru – výběr fronty
  - Využívá se ve vícejádrových systémech, kde má každé jádro samostatnou frontu a není potřeba v ovladači ztrácet čas synchronizací (mutex) mezi různými CPU
  - Někdy lze využít i k prioritizaci rámců – každá fronta má jinou prioritu

Ovladač zařízení

Device driver

- Software, který
  1. **ovládá konkrétní zařízení** (disk, síťová karta, GPU, …) a
  2. zbytku OS **nabízí jednotné rozhraní (API)**
- Se zařízením typicky komunikuje pomocí do paměti mapovaných registrů
  - V Linuxu viz příkaz `lspci -v`

```
01:00.0 Network controller: Intel Corporation Wireless 8260 (rev 3a)
        Subsystem: Intel Corporation Wireless 8260
        Flags: bus master, fast devsel, latency 0, IRQ 129
        Memory at ef100000 (64-bit, non-prefetchable) [size=8K]
        Capabilities: <access denied>
        Kernel driver in use: iwlwifi
        Kernel modules: iwlwifi
```

- Obsluhuje přerušení od zařízení (IRQ)

Spolehlivost ovladačů

- Ovladače bývají nejméně spolehlivou částí jádra OS
  - Chyba kdekoli v jádře OS (tedy i v ovladači) může způsobit nestabilitu celého systému
  - Ne každý programátor ovladačů rozumí všem potřebným detailům
  - Ovladače se nedají testovat, pokud není k dispozici konkrétní HW
  - Velmi špatně se testuje obsluha chybových stavů, protože je potřeba donutit HW, aby signalizoval chybu
  - Microsoft zavedl povinné digitální podepisování ovladačů, aby měl částečnou kontrolu nad jejich kvalitou
- Dnešní OS umožňují, aby některé ovladače běžely v uživatelském prostoru (jako aplikace), podobně jako je to běžné u µ-jader (viz např. UIO dále)

Příklad – ovladač klávesnice

1. Aplikace zavolá **getch()**/scanf()/… na standardní vstup
2. libc vyvolá systémové volání **read()** na deskriptoru souboru 0 (stdin)
3. Standardní vstup je připojen k terminálu (klávesnice + obrazovka) – JOS tedy předá požadavek na vstup **ovladači** klávesnice
   - Ovladač klávesnice spravuje frontu stisknutých znaků (kláves)
4. Pokud je fronta prázdná, ovladač **uspí volající vlákno**, jinak se pokračuje krokem 7
   - Interně k tomu použije semafor – vlákno přidá do fronty semaforu
   - Poté zavolá plánovač, aby vybral jiné vlákno, které poběží
5. Po stisku klávesy HW vyvolá **přerušení**
6. Ovladač klávesnice přerušení obslouží:
   - Přečte z HW (registru) jaká byla stisknuta klávesa a uloží ji do fronty
   - Zavolá operaci up/post na semafor
7. Uspané vlákno aplikace se **probudí** (je stále v jádře), vyčte z fronty ovladače stisknuté znaky a zkopíruje je do bufferu v aplikaci.
8. Provede se **návrat** ze systémového volání zpět do aplikace, funkce getch/scanf se dokončí.

Variabilita a složitost HW

- Dnešní hardware je složitý, zařízení mohou obsahovat stovky či tisíce registrů
- I vývojáři HW mají v oblibě „Ctrl-C, Ctrl-V“ – jeden čip existuje v mnoha variantách, ale všechny mají téměř stejné registry
  - Např. Wi-Fi čip – jedna verze se připojuje k PCIe, jiná k USB
- Struktura ovladačů je modulární – chceme ovladač napsat jednou a používat pro všechny varianty čipu

Příklad:

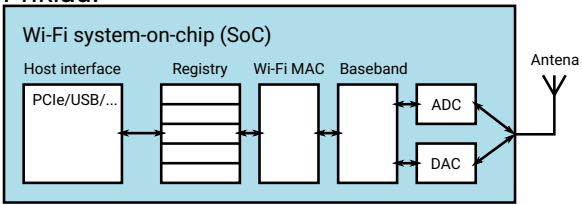

Hierarchie ovladačů

Topologie hardwaru

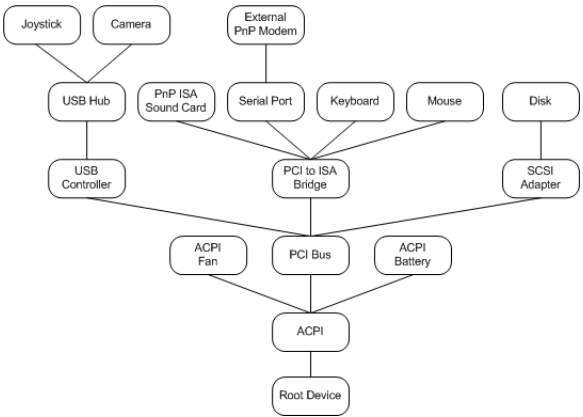

Source: Microsoft

- Ovladače reflektují topologii HW
- Každý uzel má vlastní ovladač nezávislý na okolí
- Plug-and-Play (PnP)
  - Ovladač sběrnice (USB, PCI) detekuje připojená zařízení a automaticky načte potřebný ovladač zařízení

Ovladače v Linuxu

- Aplikace mohou s ovladači komunikovat různými způsoby:
  - **Nepřímo** – např. přes síťové **API**, práci se soubory, stdin/out
  - **Přímo** – většina zařízení je reprezentována jako speciální soubor v adresáři **/dev** (např. sériová linka /dev/ttyUSB0).
  - **Pomocí knihoven** – aplikace často k souborům v /dev přistupují pomocí knihoven (např. libusb), které nabízejí vyšší úroveň abstrakce, než API OS.
- Ovladač poskytuje aplikacím následující operace (nízkoúrovňové API) pro přímý přístup k ovladačům:
  - **open** – slouží pro „navázání spojení“ aplikace s ovladačem
  - **read** – čtení dat ze zařízení (např. zkuste si spustit *hexdump /dev/input/mice*)
  - **write** – zápis dat do zařízení (např. *tty; echo XXX > /dev/pts/3*),
  - **ioctl** – vše ostatní, co není čtení či zápis, často nastavování (man ioctl_list, ioctl_tty, …)
  - **close** – ukončení komunikace s ovladačem

Nejjednodušší ovladač

Ovladač virtuálního zařízení /dev/null

```
#define NULL_MAJOR 1            /* dev major number */
#define NULL_MINOR 3            /* dev minor number */

ssize_t read_null(struct file *file, char *buf, size_t count, loff_t *ppos)
{
        return 0;
}

ssize_t write_null(struct file *file, const char *buf, size_t count, loff_t *ppos)
{
        return count;
}

const struct file_operations null_fops = {
        .read  = read_null,
        .write = write_null,
};

void init()
{
        register_chrdev(NULL_MAJOR, NULL_MINOR, "null", &null_fops))
}
```

Trochu zjednodušeno; skutečná implementace ovladače /dev/null: `https://elixir.bootlin.com/linux/v5.9.10/source/drivers/char/mem.c#L673`

Druhý nejjednodušší ovladač

Ovladač virtuálního zařízení /dev/zero

```
#define ZERO_MAJOR 1            /* dev major number */
#define ZERO_MINOR 5            /* dev minor number */

ssize_t read_zero(struct file *file, char *buf, size_t count, loff_t *ppos)
{
        memset(buf, 0, count);
        return count;
}

ssize_t write_zero(struct file *file, const char *buf, size_t count, loff_t *ppos)
{
        return count;
}

const struct file_operations zero_fops = {
        .read  = read_zero,
        .write = write_zero,
};

void init()
{
        register_chrdev(ZERO_MAJOR, ZERO_MINOR, "zero", &zero_fops))
}
```

Komunikace mezi ovladači (Linux)

- Linux je monolitické jádro.
- Jednotlivé ovladače se volají vzájemně úplně stejně, jako se volají funkce v uživatelských aplikacích.
- Často se funkce nevolá přímo, ale přes ukazatel
  - Např. Každý ovladač si registruje ukazatel na funkci, která se má vyvolat, když aplikace zavolá read() (viz `struct file_operations` na předchozích slidech).
- Data se předávají skrze argumenty funkcí (buď přímo nebo pomocí ukazatelů).

Přístup k ovladačům ve Windows

- Z pohledu aplikace konceptuálně podobné Linuxu:

	Linux	**Windows**
Otevření ovladače	open	CreateFile
Operace s ovladačem	read, write, ioctl	ReadFile, DeviceIoControl, …
Uzavření ovladače	close	CloseHandle
Jmenný prostor	/dev/	\\.\
Příklad	/dev/ttyUSB0	\\.\COM6

Přístup k ovladačům ve Windows

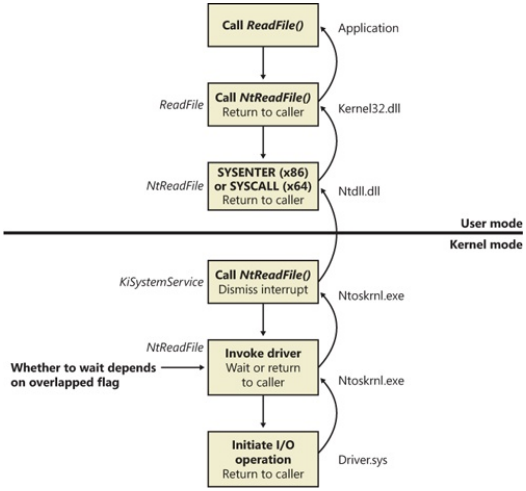

Source: Microsoft

Komunikace mezi ovladači v jádře Windows

- Ovladače ve Windows nepoužívají přímé volání funkcí, ale komunikují pomocí předávání zpráv
- Windows Driver Model je navržen tak, aby bylo teoreticky možné pouštět ovladače v oddělených adresních prostorech
- Kvůli rychlosti ale běží většina ovladačů v jednom monolitickém adresním prostoru jádra.
- Zprávy, které si ovladače vyměňují, se nazývají **I/O request packet (IRP)**

Cesta IRP jádrem

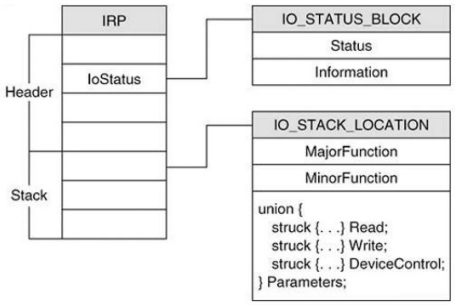

- IRP se alokuje jen jednou
- Každý ovladač „po cestě“ má svůj slot
- File system vyplní slot pro volume manager a pošle IRP dál.
- Po dokončení požadavku IRP „cestuje“ zpět (obr. vpravo).

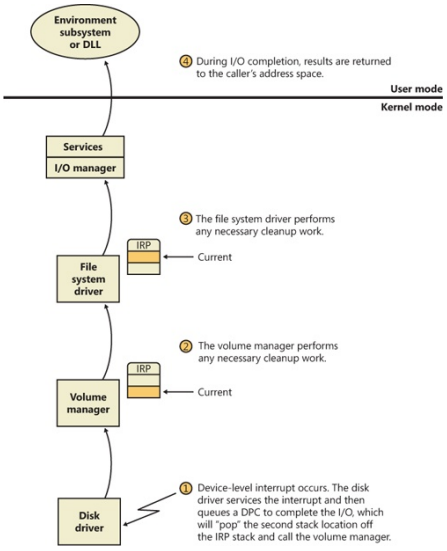

Ovladače v uživatelském prostoru

- Chyba v ovladači může způsobit pád systému
- Nekvalitní ovladače jsou také zdrojem mnoha bezpečnostních problémů
- Ovladače v uživatelském prostoru:
  - Podporovány jak Linuxem (UIO), tak Windows
  - Spouštěny jako běžná aplikace
  - Přístup k registrům HW: Pomocí volání *mmap()*
  - Obsluha přerušení – OS upozorní aplikaci, pokud nastalo přerušení
    - UIO subsystém v Linuxu:

```
int uio = open("/dev/uio0", ...);
read(uio, ...); // waits for interrupt
handle_interrupt();
```

    - Při chybě ovladače ho lze jednoduše restartovat
    - Ostatní aplikace nevolají ovladač pomocí systémových volání, ale pomocí meziprocesní komunikace (např. fronty zpráv)
- OS založené na mikrojádře mají (téměř) všechny ovladače v uživatelském prostoru