KIV Operační systémy

Režim jádra a uživatelský režim

Verze 1.0

Chceme, aby…

- ..mohlo zároveň běžet několik procesů
- ..proces nemusel vědět, že zároveň s ním běží další procesy
- ..bylo jedno, kde v paměti běží který proces
- ..proces nemohl přistupovat do paměti jiného procesu či jádra
- ..výsledkem nebylo zpomalení počítače
- ..výsledkem bylo zefektivnění práce na počítači

Memory Management Unit

- Výše uvedené cíle implikují, že procesy budou pracovat se svým formátem (tj. virtuální) adresy do paměti, která bude následně převedena na fyzickou adresu do paměti
- Protože sw implementovaný převod by byl pomalý, převod virtuální na fyzickou adresu obstará hw
  - Konkrétně Memory Management Unit (MMU)
  - Detaily převodu zadá MMU přímo OS

segment:offset

- x86 pracuje s virtuální adresou ve formátu segment:offset
- Z ní je třeba získat tzv. lineární adresu, a teprve tu lze převést na fyzickou adresu v režimu, ve kterém dokážeme od sebe izolovat jednotlivé procesy a jádro

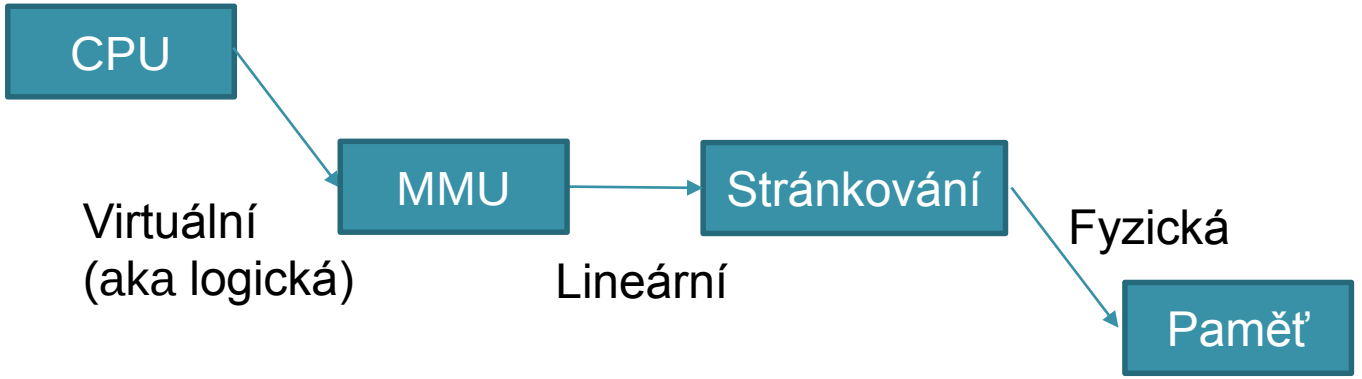

Protected mode

- V prvé řadě musíme zabránit uživatelským procesům, aby nemohly modifikovat kód a data jádra
- Jelikož x86 adresuje pomocí segmentu a offsetu (vůči segmentu), řešením bylo připojit dodatečné informace ke konkrétním segmentům
  - => už nepracujeme se segmentem, ale se segment deskriptorem
  - Procesor běží v tzv. Protected mode

Protected mode - přepnutí

- Poprvé ho implementoval 80286, komplikované přepnutí
- 80386 ho rozšířila a zjednodušila jeho přepnutí

```
EnablePM:
        cli                     ;zamaskování přerušení
        mov eax, cr0
        bts eax, 0              ;přepneme do
        mov cr0, eax            ;chráněného režimu
        lgdt [newGDT]           ;nastavíme selektory
        lidt [newIDT]           ;přerušení a vyjímky
        mov eax, selSS
        mov ss, eax             ;zásobník
        ljmp selCS, @pm         ;nastav segment selektor kódu:EIP
pm:
        ret                     ;a vrátíme se v pm
```

Protected mode – zavedení OS

- Linux

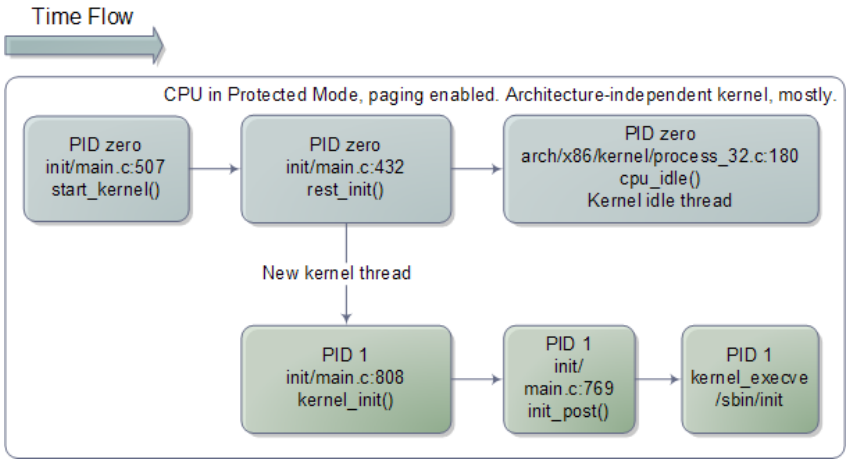

- Windows NT

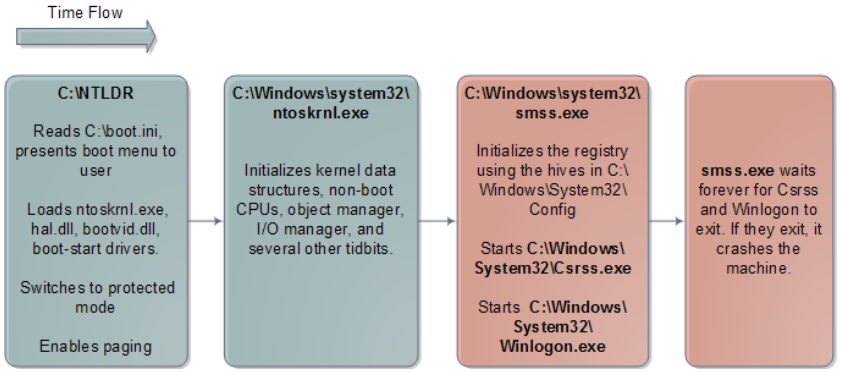

http://duartes.org/gustavo/blog/post/kernel-boot-process/

Segment Descriptor

- Segment má:
  - Základní (base) adresu (lineární adresa)
  - Velikost (limit)
  - Typ (kód, data, atd.)
  - Přístupová práva
  - Další vlajky

Segment Descriptor

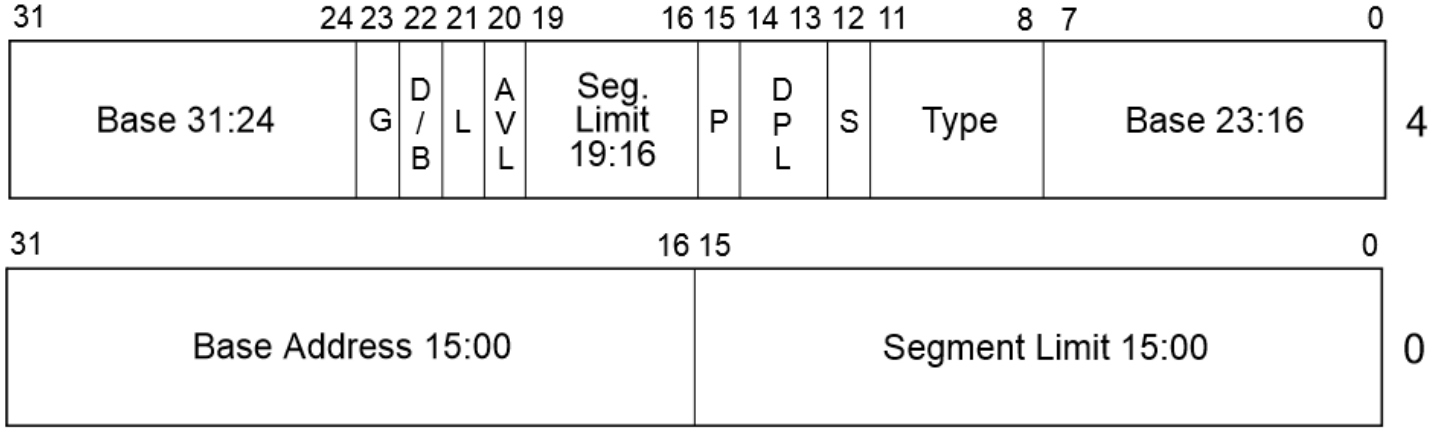

L — 64-bit code segment (IA-32e mode only)
AVL — Available for use by system software
BASE — Segment base address
D/B — Default operation size (0 = 16-bit segment; 1 = 32-bit segment)
DPL — Descriptor privilege level
G — Granularity
LIMIT — Segment Limit
P — Segment present
S — Descriptor type (0 = system; 1 = code or data)
TYPE — Segment type

Intel® 64 and IA-32 Architectures Software Developer's Manual Volume 3A: System Programming Guide, Part 1

Izolace jádra

- Pro izolaci je důležitá hodnota bitů CPL/DPL
- Číslo oprávnění/privilege level aktuálního kódu
  - 00 - většinou jádro
  - 01 –může být jádro, když na 00 poběží hypervizor virtualizace
  - 10 – může být ovladač, který nesmí do jádra
  - 11 – většinou uživatelský proces
- Kód s nižším číslem oprávnění může přistupovat do segmentu s vyšším číslem oprávnění
- Opačně to nelze => izolace jádra od uživ. procesů

Izolace procesů

- Před vlastní inicializací protected mode musí jádro OS vytvořit tabulku deskriptorů segmentů
- Tabulky existují dvě
  - Globální používaná jádrem
    - uložena v registru gdtr privilegovanou instrukcí lgdt
  - Lokální používaná konkrétním jedním procesem
    - Uložena v registru ldtr privilegovanou instrukcí lldt
    - Tj. při přepnutí kontextu může lldt vykonat pouze jádro s CPL=0 a tudíž si uživatelský proces nemůže měnit jemu přidělenou paměť

Segment deskriptory v kódu

- Uživatelský proces může mít až 6 segmentů

  s deskriptory uloženými v cs, ds, ss, es, fs a gs
  - V 64-bitovém long-mode jsou nulové až na fs a gs
- Adresa v paměti má prefix požadovaného segmentu
  - call cs:[adresa_funkce]
  - mov eax, ds:[adresa_retezce]
  - mov ecx, ss:[ebp-offset_parametru_funkce]
    - V ebp bývá hodnota esp při volání funkce, tzv. frame pointer

Výhody segmentace

- Izoluje procesy a jádro
- Lze sdílet segmenty – např. read-only programový kód sdílených knihoven
- Lze relokovat i pouze jeden segment
- Není nutné alokovat nevyužitou paměť
- Tabulka deskriptorů se vejde do MMU

Nevýhody segmentace

- Segmenty mohou mít různou délku => jak je poskládat do paměti?
- Segmenty mohou být velké => fragmentace paměti
- Jak efektivně implementovat sdílenou paměť mezi procesy?
- Jak efektivně odkládat paměť z RAM na disk, abychom zvýšili celkovou dostupnou paměť počítače?

Stránkování

- Odstraňuje nevýhody segmentace
  - x86 umožňuje kombinovat segmentaci a stránkování
  - Nelze povolit stránkování bez protected mode
  - x86 ji umožňuje použít v protected (32-bit) a long (64-bit) mode
- Celá paměť se rozdělí do stránek o pevné velikosti
  - 4kB, 2MB, 4MB a 1GB
  - Virtuální stránka: page (o velikosti frame)
  - Fyzická stránka: frame (o velikosti page)

Page Table

- Jádro OS vytvoří tabulku stránek
  - Řídící registr (x86) cr3 ukazuje na tuto tabulku stránek
  - Pouze jádro s CPL=0 může měnit obsah cr3
    - Tj. dosáhneme stejného efektu jako s GDT a LDT
    - Procesor nastaví cr3 při přepnutí kontextu
- Každá stránka má své vlajky, mj. zahrnující
  - Jádro vs. Uživatelský proces
  - Writeable, NX – do not execute
  - Present (zda je fyzicky v RAM), Dirty a Accessed

Hierarchická Page Table

- Jenom několik málo procesů využije celý dostupný paměťový prostor, např. 2^32
- Řešením je vytvořit vnější/nadřízenou/page directory tabulku stránek, která bude odkazovat na další tabulku stránek
  - Paměťový prostor procesu pak nemusí být spojitý ve smyslu, ale mohou v něm být díry na místech, které program nepoužívá

Stránkování 4kB

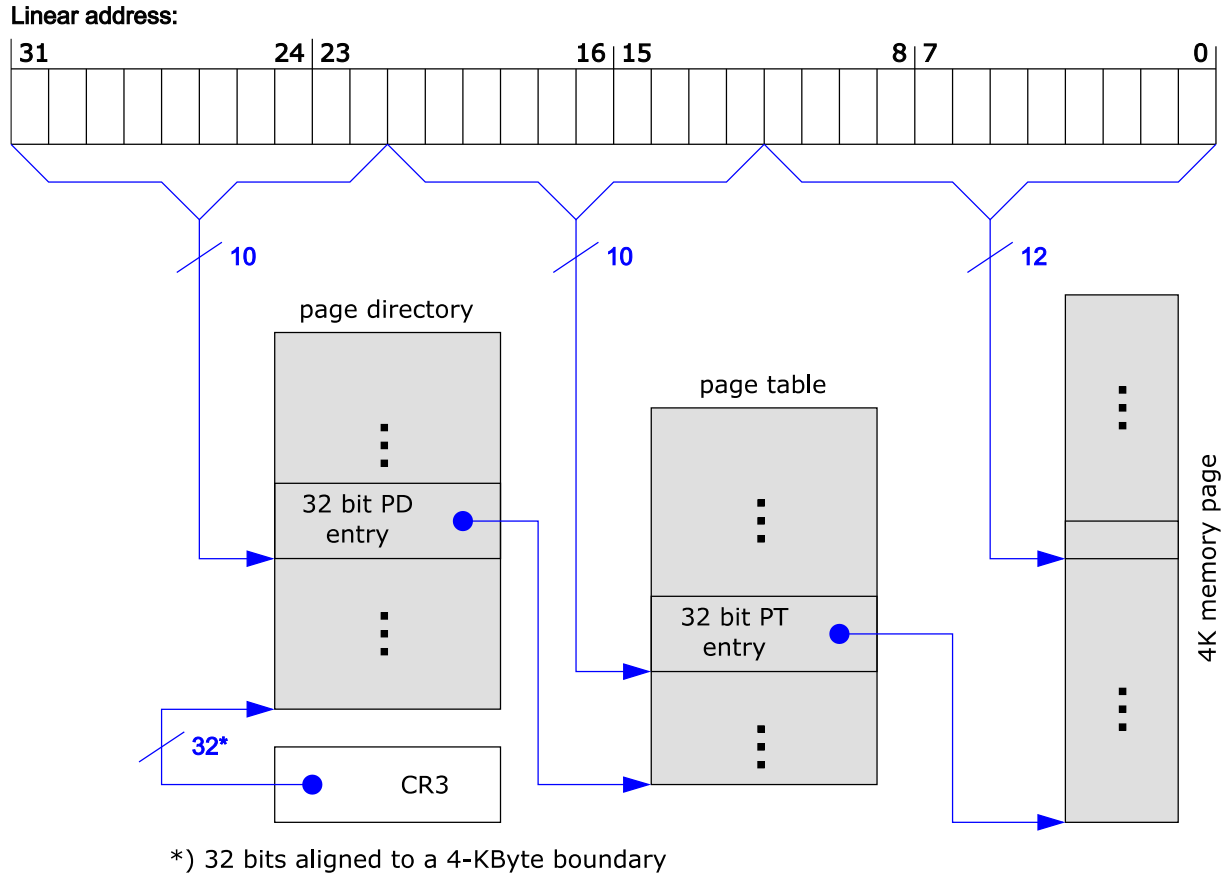

http://en.wikipedia.org/wiki/Physical_Address_Extension

Stránkování 4MB

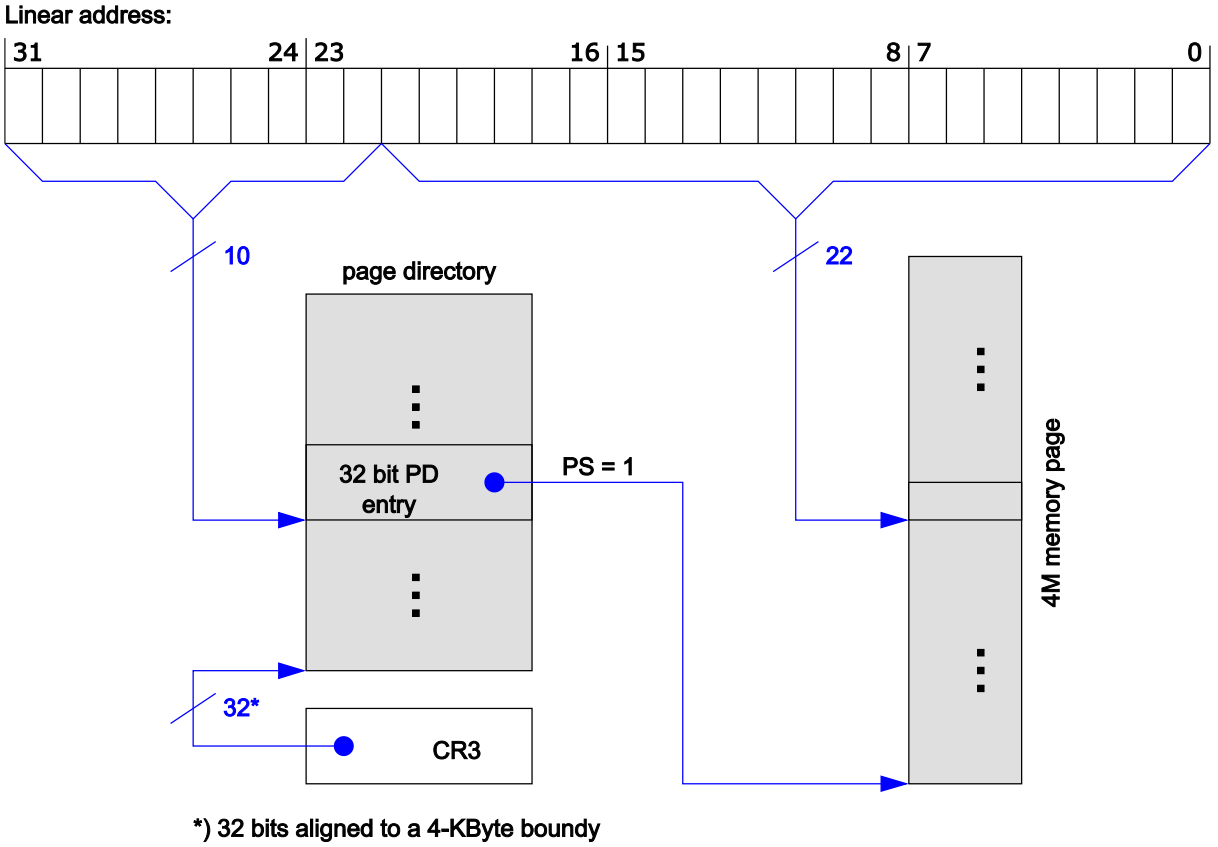

http://en.wikipedia.org/wiki/Physical_Address_Extension

Translation look-aside buffer

- Běžící proces často potřebuje jenom omezené množství stránek
  - Jak tedy zrychlit převod virtuální adresy na fyzickou?
  - Pomocí asociativní pamětí Translation look-aside buffer (TLB)
    - Je rychlá, ale také je malá

Page index	Frame index

Stránkování s TLB

- Běžící proces často potřebuje jenom omezené množství stránek
  - Jak tedy zrychlit převod virtuální adresy na fyzickou?
  - Pomocí asociativní pamětí Translataion look-aside buffer (TLB)
    - Musí se vyprázdnit při změně kontextu
    - Je rychlá, ale také je malá
      - Větší hit rate když je větší, ale také je pak pomalejší
    - Má zásadní vliv na výkon

Page index	Frame index

Sdílená paměť

- Efektivní cesta jak sdílet data mezi různými procesy
- Procesy jsou zodpovědné za konsistenci dat ve sdílené paměti
- OS pouze zajistí sdílení paměti
- Do tabulky stránek procesu OS přidá page entry, která ukazuje na ten samý rámec (fyzická stránka) jako page entries v tabulkách stránek ostatních procesů, které tímto „trikem“ sdílejí tu samou paměť

Sdílení kódu

- Pokud několik procesů používá sdílený programový kód, proč ho do paměti nahrávat vícekrát?
- Příslušné stránky s kódem se označí jako read-only a namapují se do paměťových prostorů příslušných procesů
  - Tj. stále jde o sdílenou paměť
- Příkladem jsou dynamické knihovny
  - dll
  - so

Copy on write

- Co když několik procesů na začátku sdílí stejná data, která považují za privátní, ale mění je jenom zřídka?

1. Příslušná stránka se označí jako read-only
   - Dokud z ní proces jenom čte, nic se neděje
2. Jakmile se proces pokusí zapsat do read-only stránky, procesor vygeneruje vyjímku, kterou zachytí OS
3. OS pak alokuje novou stránku, zkopíruje do ní původní read-only stránku, a aktualizuje tabulku stránek procesu
4. Po návratu z obsluhy proces normálně zapíše data už do nové stránky, aniž by o něčem vůbec věděl

Swapování

- Chceme-li poskytnout procesům více paměti, než kolik máme fyzicky RAM, nezbývá než paměť z RAM dočasně odložit do jiné paměti – flash nebo pevný disk
- Working Set – dynamická množina stránek, které má proces aktuálně ve fyzické paměti
- Chce-li dát OS více paměti některému procesu a není volný rámec, zmenší Working Set jiného procesu odebráním stránky, přičemž uloží obsah rámce na disk

Page Fault

1. Proces chce číst data ze stránky, která není v RAM
2. MMU nedokáže přeložit virtuální adresu na fyzickou adresu
   - => vygeneruje vyjímku PageFault
3. OS uloží rámec některé jiné stránky, třeba i jiného procesu, na disk a načte do něj stránku požadovanou aktuálním procesem
4. OS příslušně upraví tabulky stránek dotčených procesů
5. Po dokončení proces dál normálně pokračuje aniž by něco poznal

Page Fault - následky

- Ve skutečnosti OS nebude měnit working sets při každém Page Fault
  - Namísto toho se požadavky mohou nasbírat a vyřídit později – hromadně
  - Page Fault-ovaný proces se mezitím může pozastavit
- Swapování má extrémně negativní vliv na výkon systému
  - Zaměstnává procesor, disk a příslušnou i/o sběrnici

Mapování souborů

- Chceme-li zrychlit práci se souborem, je možné OS požádat o namapování souboru do paměti
- Proces pak zapisuje a čte přímo z rychlé paměti, namísto práce s pomalejším diskem
- OS namapuje soubor do paměti po stránkách jako u swap souboru
- Při ukončení práce se souborem se pak na disk zapíší pouze ty stránky, které mají nastavený dirty bit
  - Pokud by měl soubor např. několik GB, proč zapisovat vše?

Změna privilege level

- Uživatelský proces běží ve svém paměťovém prostoru
- Pokud volá funkci jádra operačního systému, které vyžaduje vyšší úroveň oprávnění, např. CPL=0, je nutné nějak změnit privilege level
- Dělá to procesor v okamžiku, kdy obsluhuje přerušení ať už int nebo IRQ
  - Úroveň oprávnění určí z adresy/vektoru obsluhy přerušení
  - Obsluha přerušení běží se zvýšeným CPL tak dlouho, dokud neudělá iret

Physical Address Extension (PAE)

- Éra 32-bitových x86 s více než 4GB RAM
- Ačkoliv procesor, tj. i jádro OS, dokázalo adresovat pouze 4GB RAM, tabulky stránek mohly adresovat více než 4GB RAM
- V podstatě šlo první kroky ke 64-bitovým tabulkám stránek – u PAE s 36-bitovou fyzickou adresou
  - Zavedeno s Pentium Pro
  - Nicméně, už 386 by teoreticky zvládnula 64TB virtuální paměti – technická realizace v praxi je ovšem něco jiného

80386 virtuální adresový prostor

- Virtuální adresy mají 48-bitů – dáno MMU
  - 16 bitů segment selektor, 32 bitů offset v rámci segmentu
- 16+32= 48 bitů virtuálního adresy
  - Ale 2 bity selektoru jsou použity na privilege level
  - 1 bit selektoru indikuje globální/lokální tabulku
  - => 46 k adresování použitelných bitů => 2^46=64TB
- Jedná se ale jenom o teoretický limit! V praxi nikdy nebylo použito.

Segmentace a stránkování

- Ačkoliv je segmentace považovaná za historický artefakt, nedá se říci, že by byla nepoužívaná
  - Např. Vx32 user-level sandboxing na x86 ji používá ke spouštění nedůvěryhodných programů na FreeBSD, Linuxu a Mac OS
  - Implementace TLS ve Windows – viz dále

Segmented Paging

- Tabulky stránek jsou segmentovány
- Virtuální adresa je logical_page:offset
- logical_page je segment_number:segment_offset

Paged Segmentation

- Segmenty se skládají ze stránek
- Virtuální adresa je seg:offset
- Offset je page_number:page_offset
- Way to go on x86

HW vs SW

- Proč to zatím vypadá jako specifikace hw?
- Protože ať už je to Linux, UNIX, Mac OS či Windows, všichni nakonec dělají to samé
  - A takhle už víme, co to je, aniž bychom se upnuli na konkrétní implementaci