OS MMXXIV

MIT ;)

https://pdos.csail.mit.edu/6.828

Výpadky stránok

Téma

- Implementácia rôznych trikov pomocou VM
- Špeciálne zameranie na výpadky stránok
  - Oneskorená (lenivá) alokácia – *lazy allocation*
  - Alokácia pri zápise – *fork COW (copy-on-write)*
  - Mapovanie súboru do pamäte – *memory mapping*

Téma

- Načo sú tieto triky dobré
- Zlepšenie výkonu/efektivity
- Nová funkcionalita systému

Téma

- Načo sú tieto triky dobré
- Zlepšenie výkonu/efektivity
  - Oneskorená alokácia
  - Jedna nulová stránka pre celý systém
  - COW fork
- Nová funkcionalita systému
  - Mapovanie pamäte (`mmap`)

Reakcia xv6 na výpadok stránky

- Ako reaguje xv6 na výpadky stránok

Reakcia xv6 na výpadok stránky

- Ako reaguje xv6 na výpadky stránok

- `usertrap(): unexpected scause …`
- Viď príklad `user/echo.c`
- Ukončenie procesu

Reackcia xv6 na výpadok stránky

Opakovanie

- Výhody VM

1. Izolácia – každý proces má svoj vlastný adresný priestor
2. Nepriamočiarosť (*level-of-indirection*) – preklad VA na FA umožňuje triky
   - Zdieľanie dát v ramke (trampolína)
   - Strážeenie pretečenia zásobníka (*guard page*)
   - …

Statické / dynamické mapovanie

- Jadro OS má kontrolu nad prekladom VA→FA

- Doteraz sme sa venovali pevne nastavenému mapovaniu (v zmysle, že mapovanie musí byť nastavené PRED prístupom k VA)
- VM však umožňuje aj mapovanie „za chodu”

Statické / dynamické mapovanie

- Jadro OS má kontrolu nad prekladom VA→FA
- Doteraz sme sa venovali pevne nastavenému mapovaniu (v zmysle, že mapovanie musí byť nastavené PRED prístupom k VA)
- VM však umožňuje aj mapovanie „za chodu”
  - Pri pokuse o prístup na VA sa generuje výnimka
  - Jadro OS pre danú VA vytvorí mapovanie a reštartuje proces od inštrukcie, ktorá spôsobila výnimku (proces platne pristúpi k údajom na VA)

Terminológia RISC-V

- SiFive Interrupt Cookbook

- https://sifive.cdn.prismic.io/sifive/0d163928-2128-42be-a75a-464df65e04e0_sifive-interrupt-cookbook.pdf

Terminológia RISC-V

- *Exception* (výnimka)
- *Trap* (presun riadenia)
- *Interrupt* (prerušenie)

Terminológia RISC-V

- *Exception* (výnimka) – výnimočný stav vyvolaný inštrukciou vykonávaného programu

- *Trap* (presun riadenia) – **synchrónny** prenos riadenia do kódu obsluhy spôsobený výnimočným stavom, ktorý zapríčinil vykonávaný program

- *Interrupt* (prerušenie) – externá udalosť, ktorá sa vyskytne **asynchrónne** voči vykonávanému kódu

The RISC-V Instruction Set ManualVolume II: Privileged ArchitectureDocument Version 1.12-draft, 2020, Table 4.2, p.66

Supervisor Cause (scause) register

Interrupt	Exception Code	Description
1	0	*Reserved*
1	1	Supervisor software interrupt
1	2–4	*Reserved*
1	5	Supervisor timer interrupt
1	6–8	*Reserved*
1	9	Supervisor external interrupt
1	10–15	*Reserved*
1	≥16	*Available for platform use*
0	0	Instruction address misaligned
0	1	Instruction access fault
0	2	Illegal instruction
0	3	Breakpoint
0	4	Load address misaligned
0	5	Load access fault
0	6	Store/AMO address misaligned
0	7	Store/AMO access fault
0	8	Environment call from U-mode
0	9	Environment call from S-mode
0	10–11	*Reserved*
0	12	Instruction page fault
0	13	Load page fault
0	14	*Reserved*
0	15	Store/AMO page fault
0	16–23	*Reserved*
0	24–31	*Available for custom use*
0	32–47	*Reserved*
0	48–63	*Available for custom use*
0	≥64	*Reserved*

Cieľ tohto týždňa

- Pri výpadku stránky v používateľskom programe

- Zistiť, či sa jedná o legitímnu adresu programu
- Zistiť, či sa jedná o legitímny nárok prístupu
- Ak áno, aktualizovať tabuľku stránok procesu
- A napokon reštartovať proces od inštrukcie, ktorá spôsobila výpadok stránky (vykonanie inštrukcie sa musí zopakovať)

Čo potrebujeme

1. VA, ktorá spôsobila výpadok (*faulting VA*) (na RISC-V je táto hodnota uložená v registri `$stval`)

2. Typ výpadku stránky (pre RISC-V viď tabuľku 4.2 v „RISC-V privileged.pdf”, hodnota registra `$scause` – *read*, *write*, *instruction*)

The RISC-V Instruction Set ManualVolume II: Privileged ArchitectureDocument Version 1.12-draft, 2020, Table 4.2, p.66

Supervisor Cause (scause) register

Interrupt	Exception Code	Description
1	0	*Reserved*
1	1	Supervisor software interrupt
1	2–4	*Reserved*
1	5	Supervisor timer interrupt
1	6–8	*Reserved*
1	9	Supervisor external interrupt
1	10–15	*Reserved*
1	≥16	*Available for platform use*
0	0	Instruction address misaligned
0	1	Instruction access fault
0	2	Illegal instruction
0	3	Breakpoint
0	4	Load address misaligned
0	5	Load access fault
0	6	Store/AMO address misaligned
0	7	Store/AMO access fault
0	8	Environment call from U-mode
0	9	Environment call from S-mode
0	10–11	*Reserved*
0	12	Instruction page fault
0	13	Load page fault
0	14	*Reserved*
0	15	Store/AMO page fault
0	16–23	*Reserved*
0	24–31	*Available for custom use*
0	32–47	*Reserved*
0	48–63	*Available for custom use*
0	≥64	*Reserved*

Čo potrebujeme

1. VA, ktorá spôsobila výpadok (`$stval`)

2. Typ výpadku stránky (`$scause`)

3. Mód CPU a inštrukciu, kde k výpadku prišlo
   - U/S mód: implicitne sa vyvolá `usertrap` alebo `kerneltrap`
   - PC: `$sepc`, hodnota uložená v `tf`→`epc` pri móde U

Zdroj informácií

- pre RISC-V viď tabuľka 4.2 v „RISC-V privileged.pdf” na strane 66
- https://uim.fei.stuba.sk/wp-content/uploads/2018/02/riscv-privileged.pdf

- https://uim.fei.stuba.sk/predmet/b-os/
- záložka Literatúra

Čo potrebujeme

- Načo nám treba register PC?

- Aby kód jadra vedel reštartovať používateľský program presne od tej inštrukcie, ktorá vyvolala výpadok
- Inštrukcia sa musí zopakovať (jej vykonanie)
- Ak jadro všetko dobre nastavilo, pri opakovaní inštrukcie sa už výnimka neobjaví

Zoznam trikov s VM

- alokácia pamäte na žiadosť (*lazy/on-demand*)
- jedna stránka núl (*zero-filled page*)
- COW fork (*copy-on-write*)
- VA väčšia než RAM (*swap*)
- mapovanie súborov do pamäte (*mmap*)
- zdieľanie pamäte medzi procesmi (*shared*)

sbrk, fork a exec

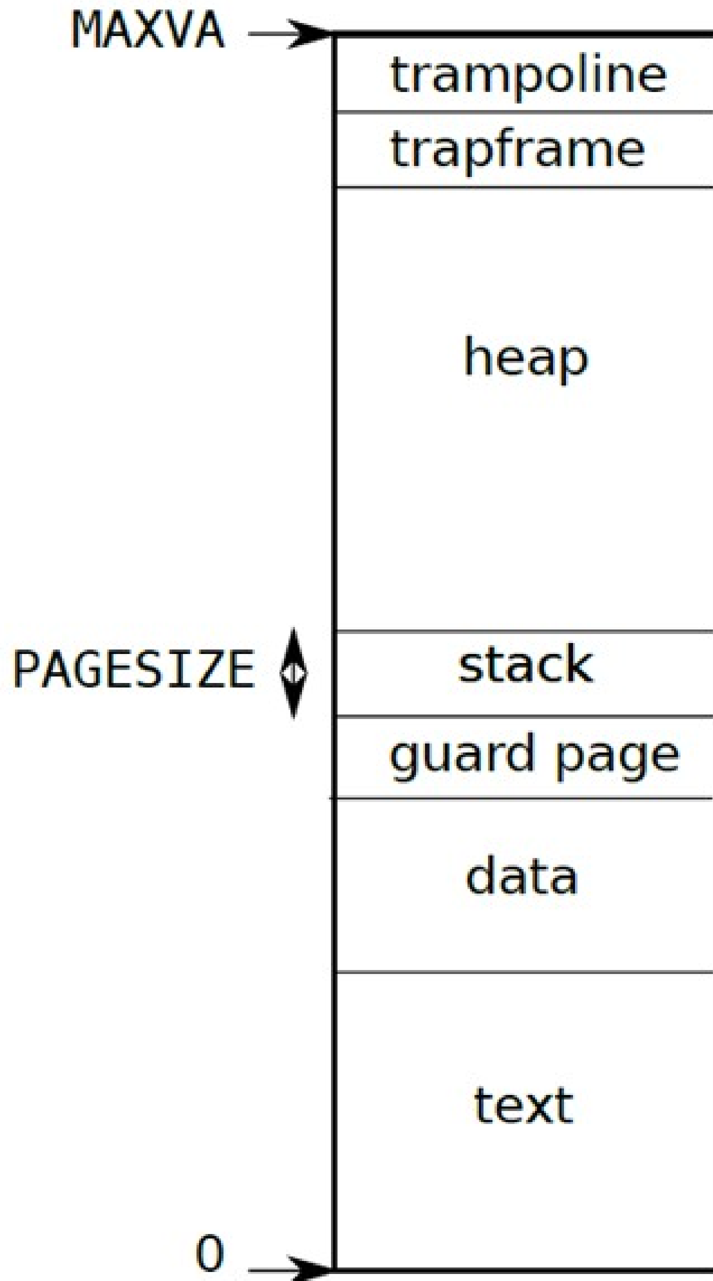

Lazy alokácia v1 (pre `sbrk`)

- `sbrk()` v xv6 je primitívny – vždy procesu dá, čo chce
- Aplikácia často nevyužije všetku pridelenú pamäť
  - Napr. alokuje *buffer* na načítanie vstupu, ale väčšinou sa využije iba prvých pár bajtov
- `sbrk()` tak často alokuje pamäť, ktorá sa NIKDY v procese nevyužije, ale nikto iný ju nemôže využívať!

Lazy alokácia v1 (pre `sbrk`)

- Moderné OS alokujú pamäť oneskorene (lenivo, angl. *lazy*)
- Ako:
  - Fyzická ram sa alokuje až vtedy, keď je treba
  - Pri volaní `sbrk()` sa zväčší `p->sz`, ale nerobí sa žiadna alokácia (mapovanie)
  - Keď sa proces pokúsi pristúpiť k „alokovanej" pamäti, nastane výpadok stránky!!!
  - Jadro v obsluhe výpadku alokuje a namapuje potrebnú pamäť
  - Aplikácia sa reštartuje od miesta výpadku

Lazy alokácia v1 (pre `sbrk`)

- Aké sú výhody takéhoto prístupu?

- Alokuje sa menej fyzickej pamäte (ak sa k pamäti z *user* programu nepristúpi, nepríde k žiadnemu výpadku, žiadna pamäť sa nebude alokovať)
- Cenou tohto prístupu je strata istej efektivity – pamäť sa musí alokovať nie pri jednom systémovom volaní (`sbrk`), ale pri každom výpadku stránky

Lazy alokácia v1 (pre `sbrk`)

- Ako na to prakticky v xv6?

1. sbrk(): p→sz = p→sz+n
2. pgfault():
   - Kontrola VA v intervale <……………; …………..)
   - Alokuj rámec v ram-ke
   - Vynuluj rámec (prečo?)
   - Namapuj príslušnú stránku VA na rámec
   - Reštartuj *user* program od inštrukcie, ktorá spôsobila výpadok

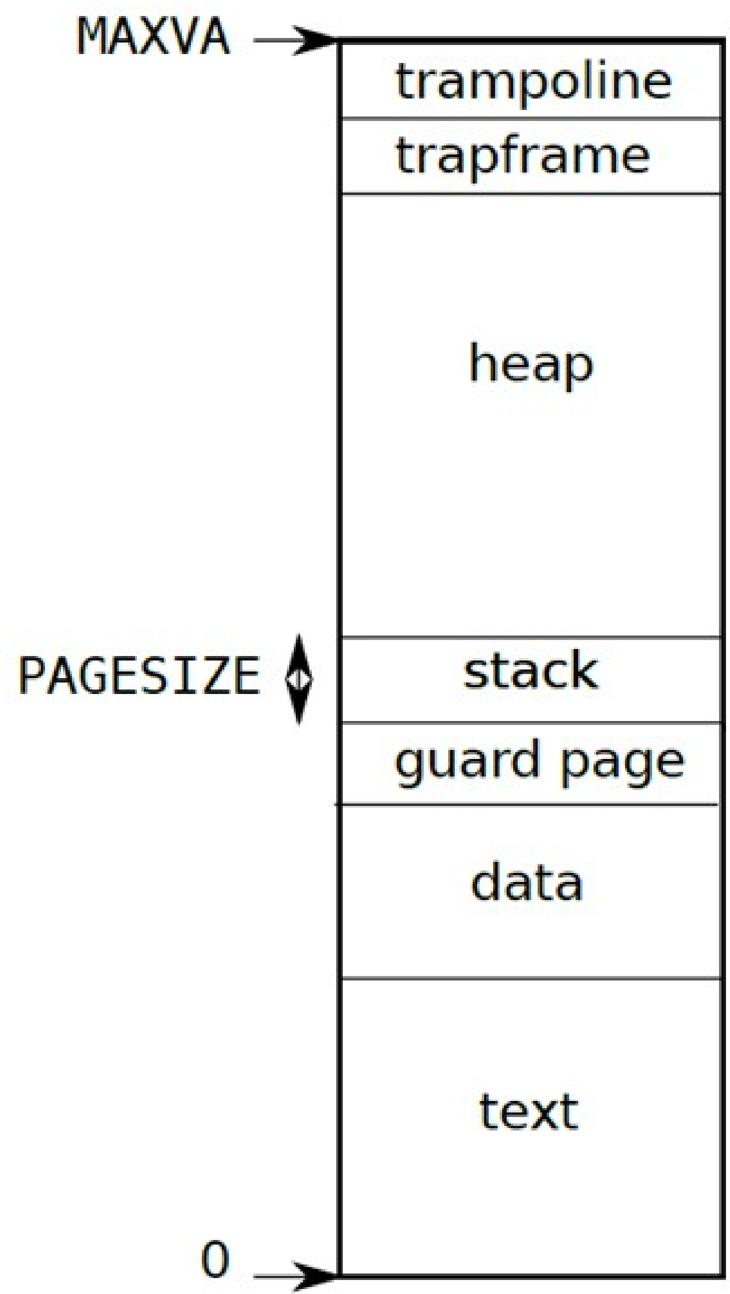
MAXVA
trampoline
trapframe
heap
PAGESIZE
stack
guard page
data
text
0

Lazy alokácia v1 (pre `sbrk`)

- Ošetrenie chýb alokácie RAM pri štandardnom (nie *lazy*) `sbrk()` je triviálne
- Ako je to v prípade oneskorenej alokácie?

pgfault():

- Kontrola VA v intervale <……………; …………..)
- Alokuj rámec v ram-ke
- Vynuluj rámec (prečo?)
- Namapuj príslušnú stránku VA na rámec
- Reštartuj *user* program od inštrukcie, ktorá spôsobila výpadok

Stránka núl na požiadanie

- *Zero-fill on demand*

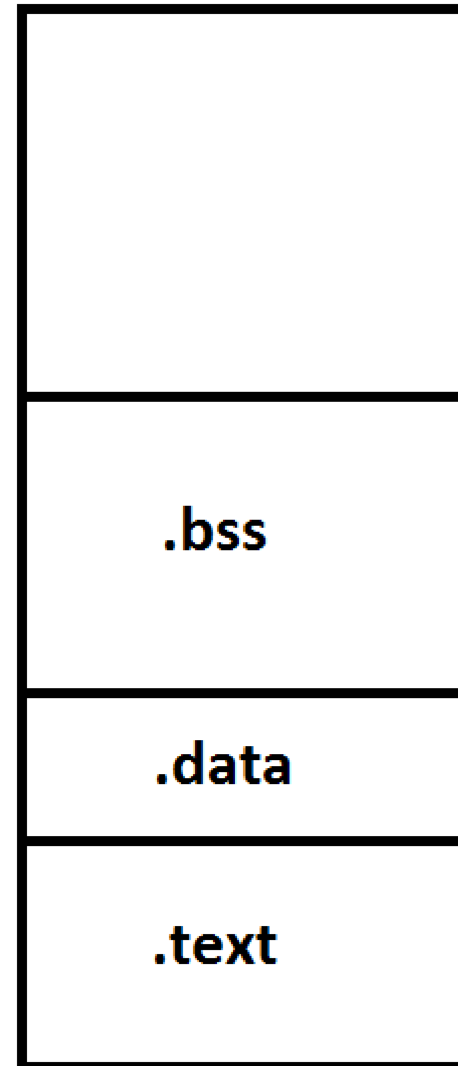

VAP

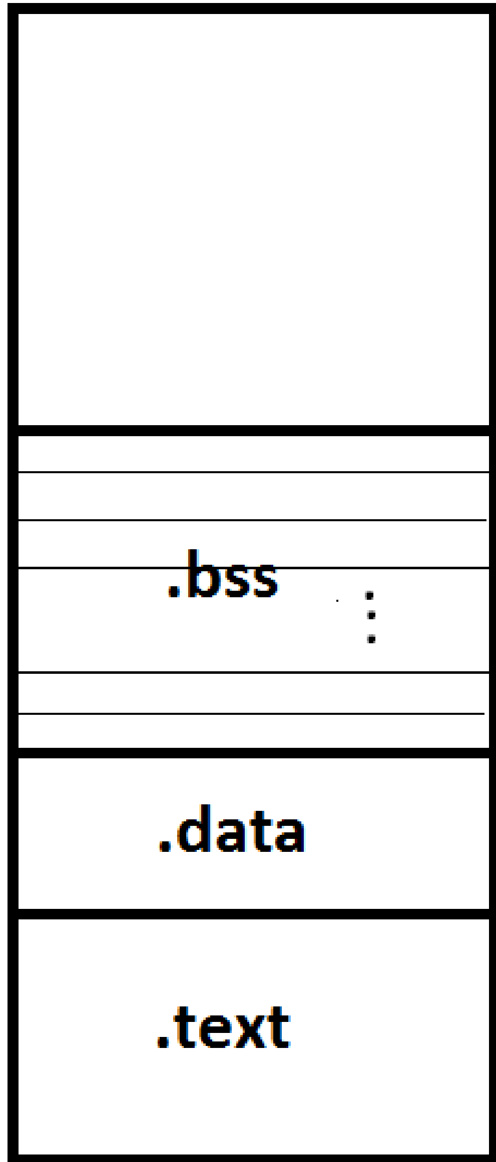

FAP

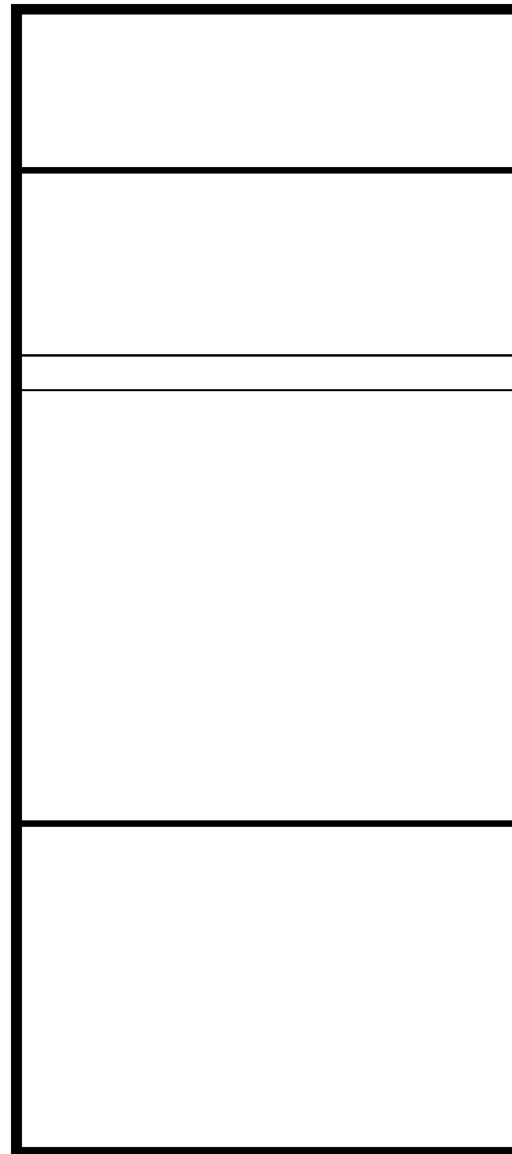

RAM

Stránka núl na požiadanie

- Čo má robiť obsluha `pgfault()`

- Overiť, či VA ukazuje do *zero-page*
- Alokovať nový rámec
- Vynulovať ho / skopírovať nulovú stránku
- Vytvoriť mapovanie do rámca pre VA (s oprávnením `PTE_W`)
- Reštartovať inštrukciu používateľského programu

Stránka núl na požiadanie

- Načo je to dobré?

1. Program využíva iba toľko pamäte, koľko aktuálne potrebuje – podobne ako pri *lazy* alokácii
2. `exec()` je efektívnejší – netrvá tak dlho (žiadna nulová stránka sa reálne nealokuje)

Copy-on-write fork

Copy-on-write fork

- Implementácia je predmetom cvičení nasledujúcich dvoch týždňov
- Ako funguje spustenie príkazu v sh?

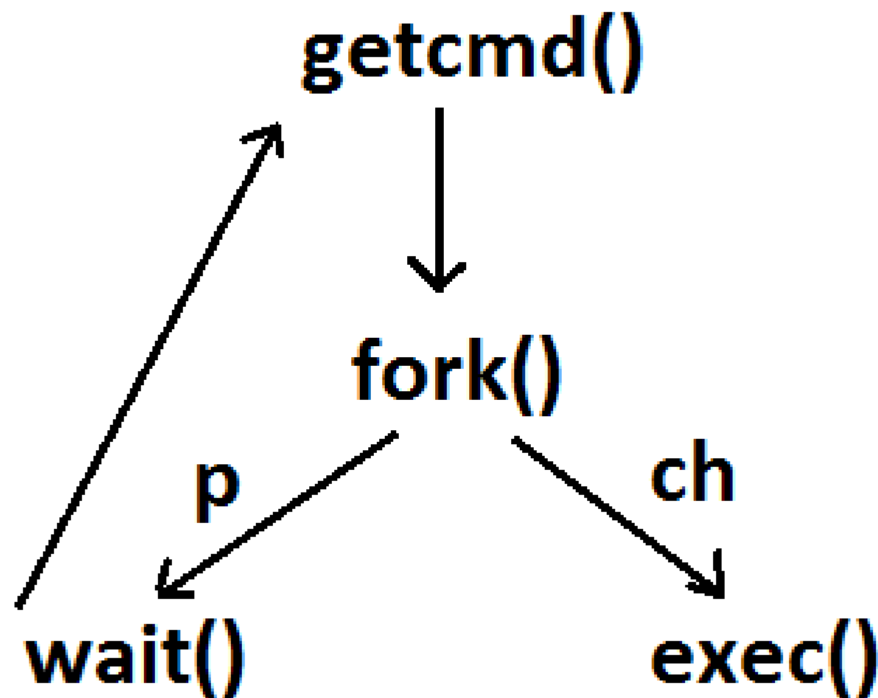

Copy-on-write fork

- `fork()` skopíruje celý VAP rodiča
- `exec()` celý VAP procesu zruší a nahradí ho VAP nového procesu

- Brutálny obrázok

VAP P1

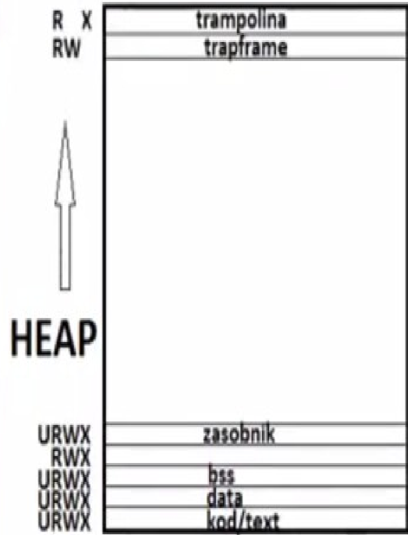

RAM

VAP P3

VAP P4

VAP P5

VAP P2

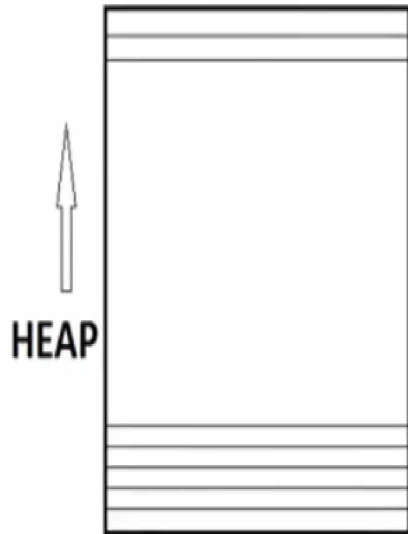

VAP kernel

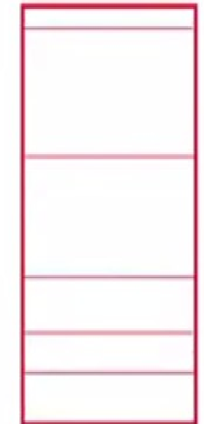

0x80 00 00 00

Copy-on-write fork

- Cieľ COW forku – všetky VA detského procesu (totožné s VA rodiča) budú ukazovať na tie isté údaje v RAM

- Pozor na stránky, ktoré majú PTE_W!
  – Aj v rodičovi, aj v potomkovi musíme odstrániť PTE_W
  – Dôsledok: pri pokuse o zápis sa vygeneruje výnimka

Copy-on-write fork

- Čo má urobiť `pgfault()`

- Skontroluj, či stránka zodpovedajúca VA má „nárok" byť zapisovateľná
- Alokuj rámec v RAM
- Skopíruj do neho údaje z PTE_R stránky
- Vytvor do neho mapovanie pre VA (PTE_W)
- Reštartuj inštrukciu

Copy-on-write fork

- Skontroluj, či stránka zodpovedajúca VA má „nárok” byť zapisovateľná. Ako?
- Využijeme jeden z RSW bitov PTE záznamu

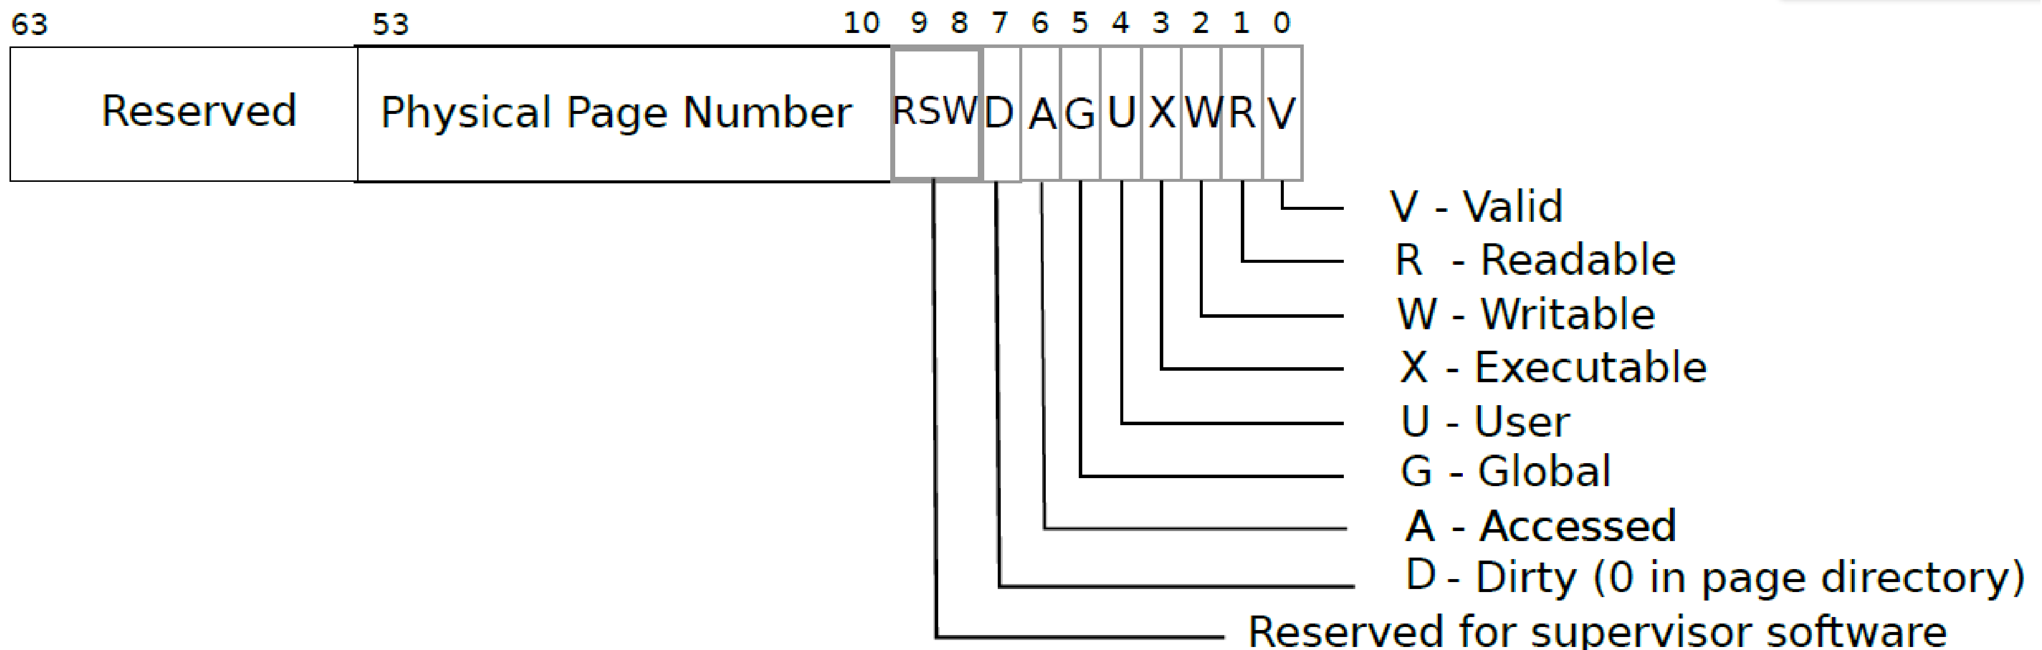

Copy-on-write fork

- Skontroluj, či stránka zodpovedajúca VA má „nárok” byť zapisovateľná. Ako?
- Využijeme jeden z RSW bitov PTE záznamu
  - Pri kopírovaní VAP rodiča vo `fork()` všetkým mapovaniam `PTE_W` odstránime `PTE_W` a pridáme nami využitý bit (označme ho napr. `PTE_COW`)
  - V obsluhe `pgfault()` skontrolujeme, či mapovanie danej VA obsahuje `PTE_COW`: ak áno, `pgfault()` urobí, čo má (alokácia, kópia, mapovanie, reštart inštrukcie)

Copy-on-write fork

- Prečo musíme robiť zbytočnú operáciu alokácie/kopírovania/mapovania v prípade, že po poslednom `pgfault()` nám ostane iba jeden jediný proces, ktorý ukazuje na pôvodné data vo FAP? Viď obrázok…

- Nedá sa to urobiť nejako tak, aby sme túto situáciu vyriešili?

Copy-on-write fork

- Pri COW musíme byť opatrní na viacerých miestach, zvlášť pri uvoľňovaní stránok

- Napríklad systémové volanie `exit()`
  - Môže jadro uvoľniť stránky procesu?
  - Ani pri PTE_COW, ani pri PTE_R nevieme, koľko procesov má rámec FAP namapovaný do svojho VAP!

Copy-on-write fork

- Ako vyriešiť uvoľňovanie stránok?

- Počítadlo počtu referencií na rámec FAP
- Pri každom namapovaní sa počítadlo zvýši
- Pri každom odmapovaní sa počítadlo zníži

- Keď hodnota počítadla klesne na 0, rámec sa uvoľní

Stránkovanie na žiadosť v2

- *On-demand paging* (exec)

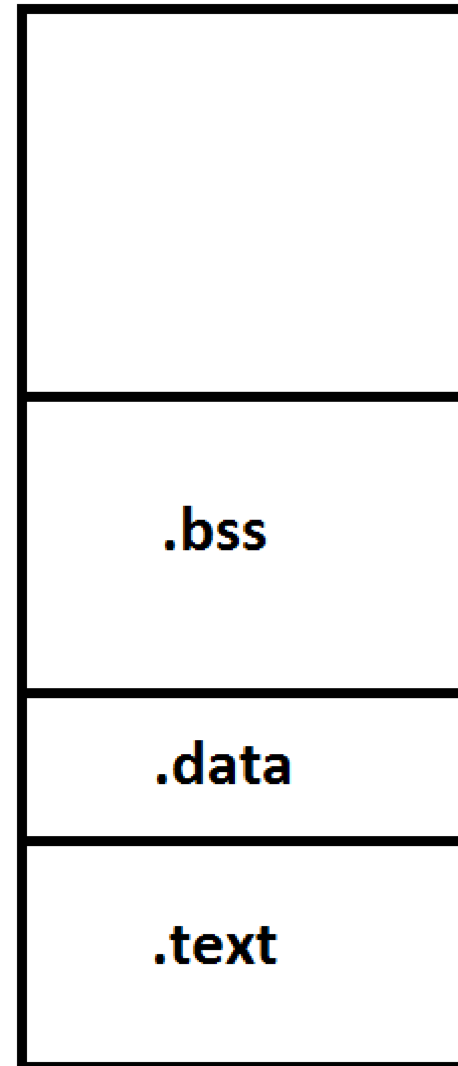

Stránkovanie na žiadosť v2

- *On-demand paging* (`exec`)
- `exec()` nahráva kompletne celý súbor do pamäte (viď `kernel/exec.c`), čo je extrémne náročná operácia
- Disk je totiž o dosť rádov pomalší než CPU, takže CPU nemôže efektívne využiť čas na činnosť

Stránkovanie na žiadosť v2

- Cieľom je pri sys. volaní `exec()` načítať iba najnutnejšie údaje z disku, alokovať štruktúru stránok, ale nenahrávať údaje do RAM

- príslušné záznamy PTE nebudú obsahovať PTE_V

Stránkovanie na žiadosť v2

- Čo má robiť `pgfault()`
- Skontroluje, či má ísť o mapovanie do súboru
- Ak áno, alokuje rámec, načíta príslušné údaje do rámca, upraví PTE záznam pre VA, reštartuje inštrukciu

Stránkovanie na žiadosť v2

- Činnosť `pgfault()` vyžaduje nejaké metadáta o tom, kde sa stránka na disku nachádza

- Tieto informácie sú zvyčajne uložené v štruktúre nazývanej VMA (*Virtual Memory Area*)

swap

- Využitie väčšieho VAP než je RAM

swap

- Využitie väčšieho VAP než je RAM
- Cieľom je umožniť aplikáciám zdanie takej veľkej RAM, ako potrebujú (bez ohľadu na veľkosť samotnej RAM)

swap

- Ako to urobiť?

- Málo frekventované stránky procesu odložiť na disk, a toto miesto použiť na nové stránky, ktoré chce proces používať
- Odloženie stránky na disk a jej nahratie pri ďalšom prístupe musí byť pre proces transparentné

swap

- Ako vybrať „obeť” (*victim*), ktorá bude odložená na disk?

- Rôzne algoritmy, najčastejšie sa používa LRU (*Least Recently Used*)
- Jednoduchá verzia tohto algoritmu sa implementuje s podporou hw
  - Bit „A” v PTE zázname
  - Bit „D” v PTE zázname

swap

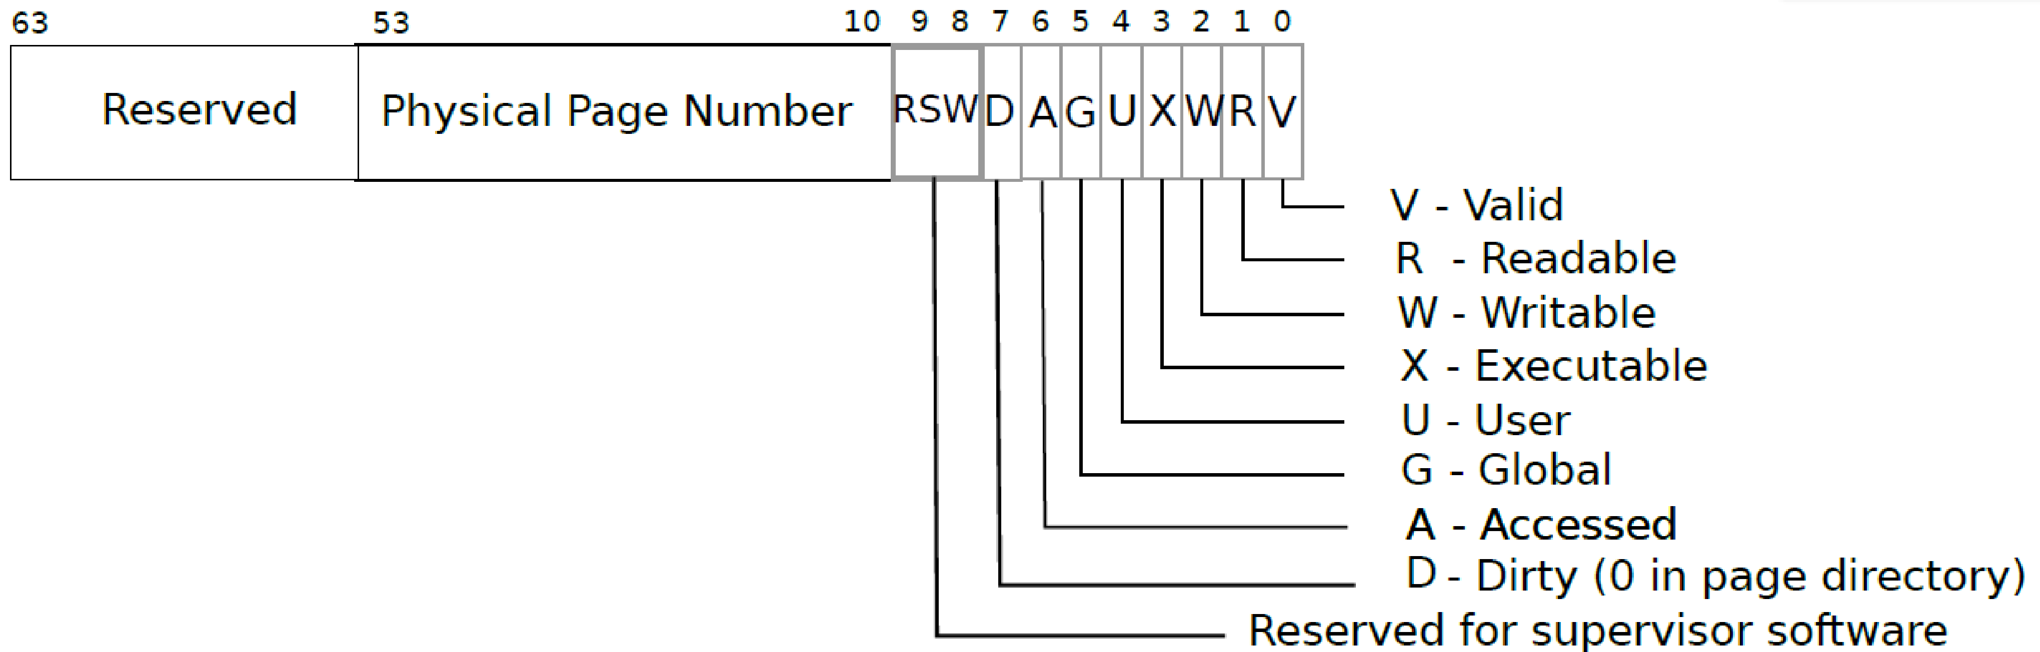

- Jednoduchá verzia tohto algoritmu sa implementuje s podporou hw
  - Bit „A” v PTE zázname
  - Bit „D” v PTE zázname

swap

- Bit „A” v PTE zázname
- Pri každom prístupe MMU ku stránke sa tento bit nastaví (to už vieme)

- Algoritmus výberu obete
  - Každých N tikov vynuluje bit A
  - V procese výberu obete prehľadáva stránky, a tú, ktorá nemá nastavený bit A, označí za obeť
  - Algoritmus môže zohľadňovať aj bit D

swap

- Podobne ako pri „*on-demand*” stránkovaní sú potrebné pomocné dátové štruktúry, aj v tomto prípade treba vedieť, ktoré údaje na disku zodpovedajú ktorej stránke vo VAP

- Kedy sa hľadá obeť?
- Keď nie je voľný rámec RAM, t.j. keď `kalloc()` vráti 0 (*null*)

swap

- Ako vyzerá náčrt fungovania?

- Ak nie je voľná RAM
  - Nájdi kandidáta na vyhodenie z RAM (napr. LRU algoritmus)
  - Ulož dáta „*victim*” stránky na disk
  - Zneplatni mapovanie „*victim*” stránky
  - Použi voľný rámec

Mapovanie súboru do pamäte

- `mmap()` – *memory mapped files*

Mapovanie súboru do pamäte

- `mmap()` – *memory mapped files*

- Cieľom je manipulovať s obsahom súboru nie pomocu explicitných volaní `read()`, `seek()`, `write()`
- ale pomocou inštrukcií `ld` (*load*), `st` (*store*), ktoré manipulujú s pamäťou RAM

- `mmap(va, len, protection, flags, fd, offset)`

Mapovanie súboru do pamäte

- Jadro načítava údaje zo súboru do pamäte technikou „*on-demand*” (v obsluhe `pgfault()`)

- Ak je RAM plná, napr. algoritmom LRU môže nepoužívané časti súboru uvoľniť

- Systémové volanie `unmap(va, len)` zapíše do súboru iba pozmenené (využije sa „D” bit v PTE zázname) časti súboru

Mapovanie súboru do pamäte

- Na činnosť mapovania sa znovu využívajú pomocné údaje VMA (*virtual memory area*)
- Čo v prípade, že viacero procesov chce manipulovať súčasne s obsahom súboru?
- Podobne, ako keď viacero procesov súčasne používa systémové volania `read()` alebo `write()` nad tým istým súborom

Zdieľaná virtuálna pamäť

- Cieľom je umožniť procesom na rôznych uzloch siete zdieľať virtuálnu pamäť
- Vytvoriť zdanie zdieľania fyzickej pamäte

Domáce čítanie

- Chapter 4: Operating system organization knižky „xv6: a simple, Unix-like teaching operating system”
- So zameraním na časť 4.6: „Page-fault exceptions”