Proces a jádro

co je jádro?
je jádro proces?

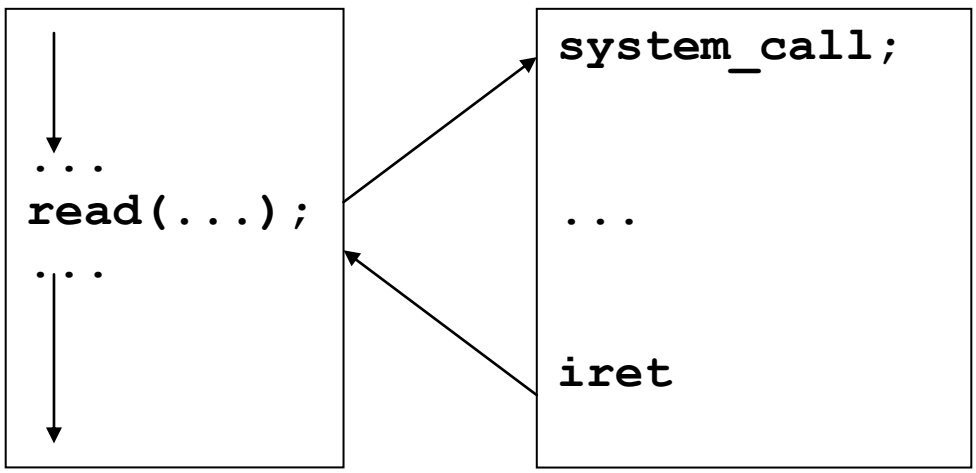

vykonávaný program – proces = posloupnost instrukcí aplikačního (uživatelského) programu a jádra

jádro – speciální program zavedený do hlavní paměti při startu systému přímo vykonávaný HW

virtuální adresový prostor procesu
- adresový prostor procesu (uživatelský)
- systémový prostor (jádra)

proces v uživatelském módu má přístup ke svému adresovému prostoru, k systémovému prostoru voláním system_call() (Linux int $0x80, eax číslo služby)

jádro má přístup k adresovému prostoru procesů

proces používá dva zásobníky

- uživatelský
- jádra

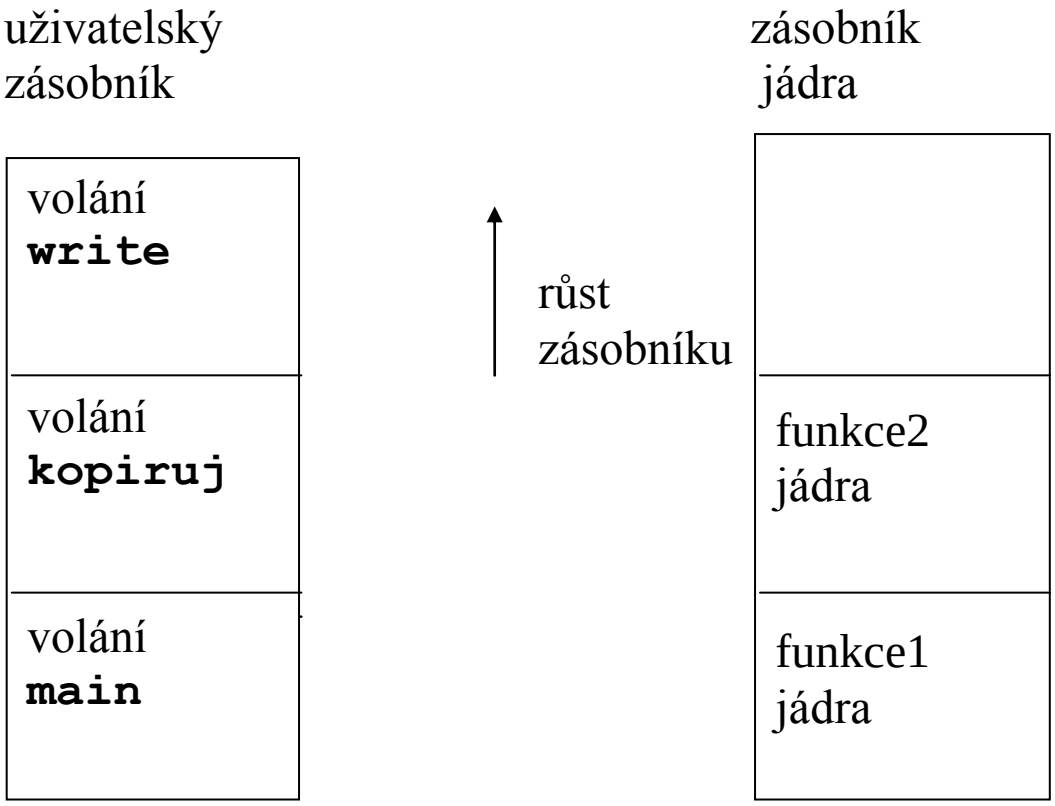

více procesů

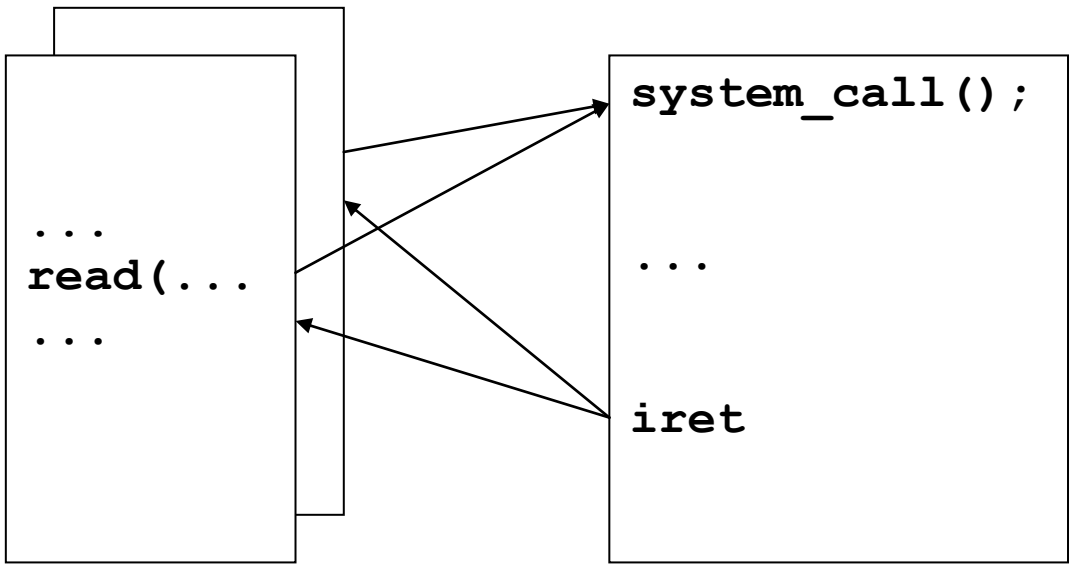

jádro je reentrantní

každý proces má svůj zásobník jádra, často v adresovém prostoru procesu – chráněný, spravovaný jádrem

každý proces má položku v tabulce procesů **`proc`** záznam a u (*user*) oblast

u oblast – údaje potřebné když je proces vykonávaný

- tabulku deskriptorů souborů otevřených souborů
- okamžitý adresář
- kořenový adresář
- často zásobník jádra procesu

...

v adresovém prostoru procesu – chráněná, spravovaná jádrem

`proc` záznam

- tabulka oblastí (*region*) procesu

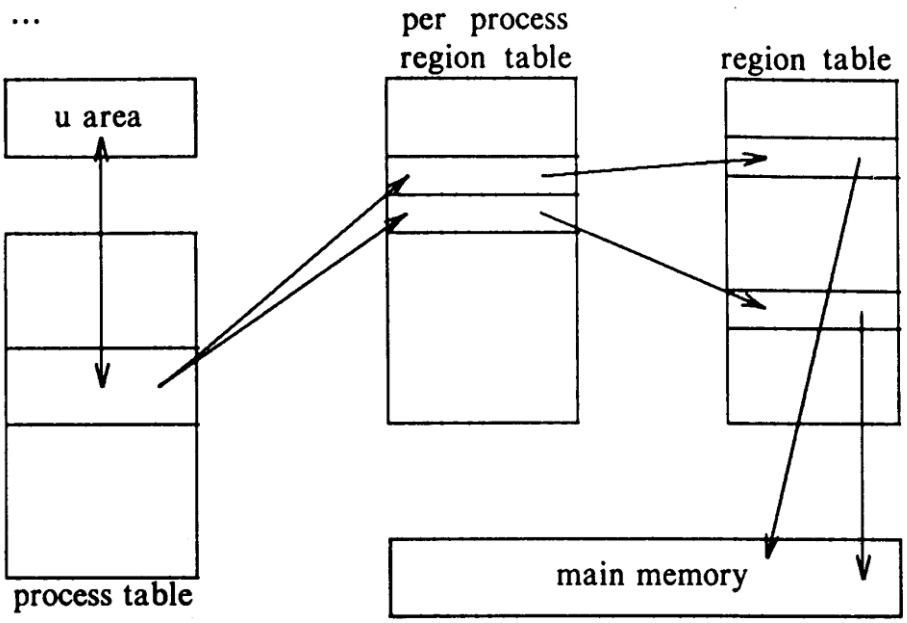
...
per process
region table
region table
u area
process table
main memory

[Bach 86]

vykonání **`fork`**

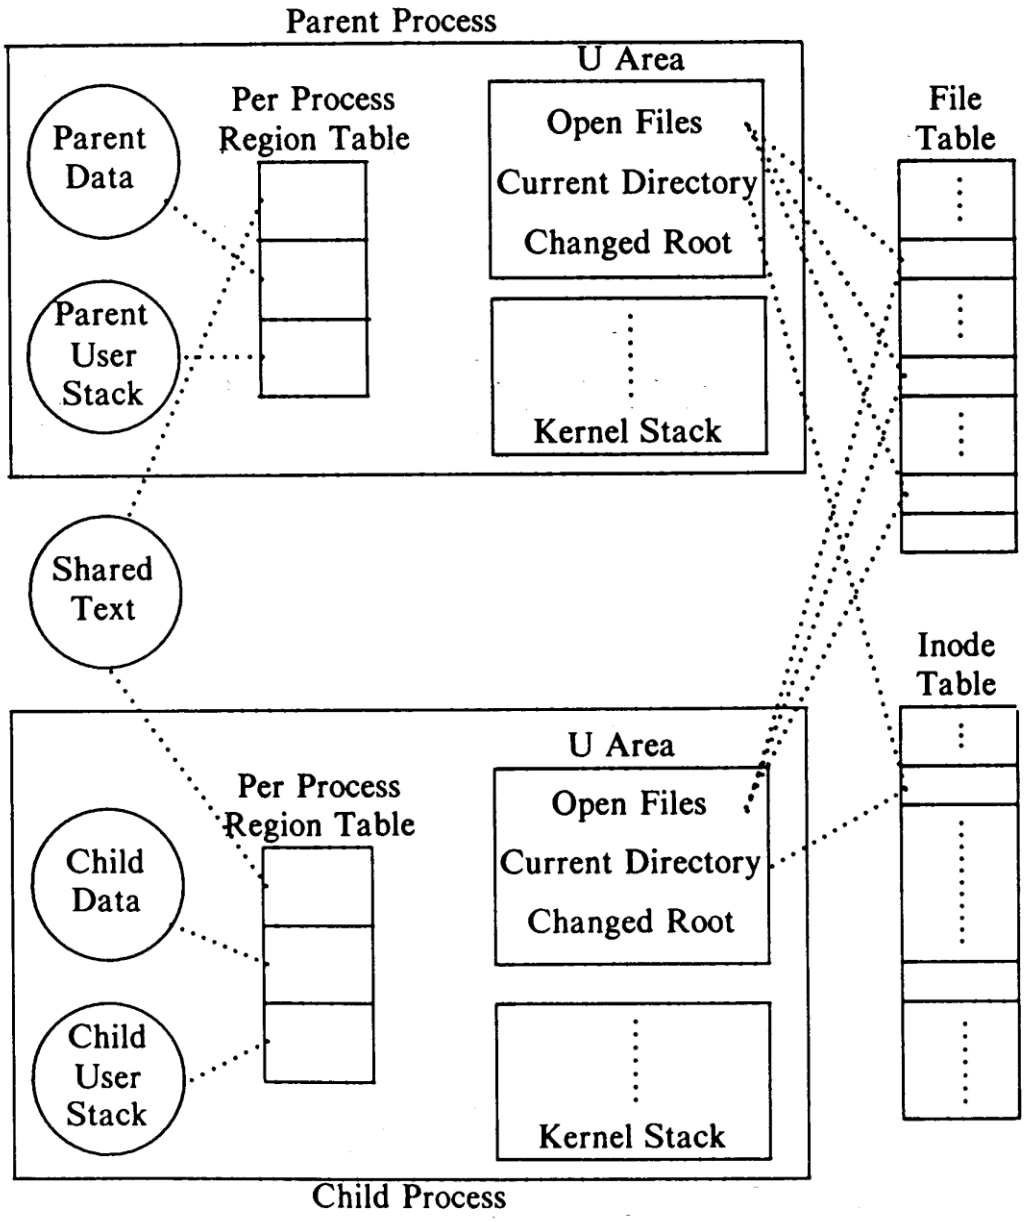

Fork Creating a New Process Context

[Bach 86]

Kontext procesu - jeho stav

- uživatelský adresový prostor
  - text (vykonatelný kód)
  - data
  - uživatelský zásobník
- řídící informace
  - u oblast
  - **`proc`** záznam
  - zásobník jádra
- registry (HW kontext)
  - počítadlo instrukcí
  - ukazatel zásobníku
  - stavové slovo procesoru
    - mód
    - úroveň přerušovací priority
    - přetečení

    ...
  - registry pro správu paměti
  - registry jednotky pohyblivé čárky

jádro
- vykonává služby
- zpracovává výjimky (pokus dělit nulou, přetečení uživatelského zásobníku, ...)
- zpracovává přerušení od periferních zařízení
- vykonává systémové procesy (správa paměti, přepočítávaní priorit procesů

jádro pracuje
- v kontextu procesu
- v procesu v systémovém kontextu

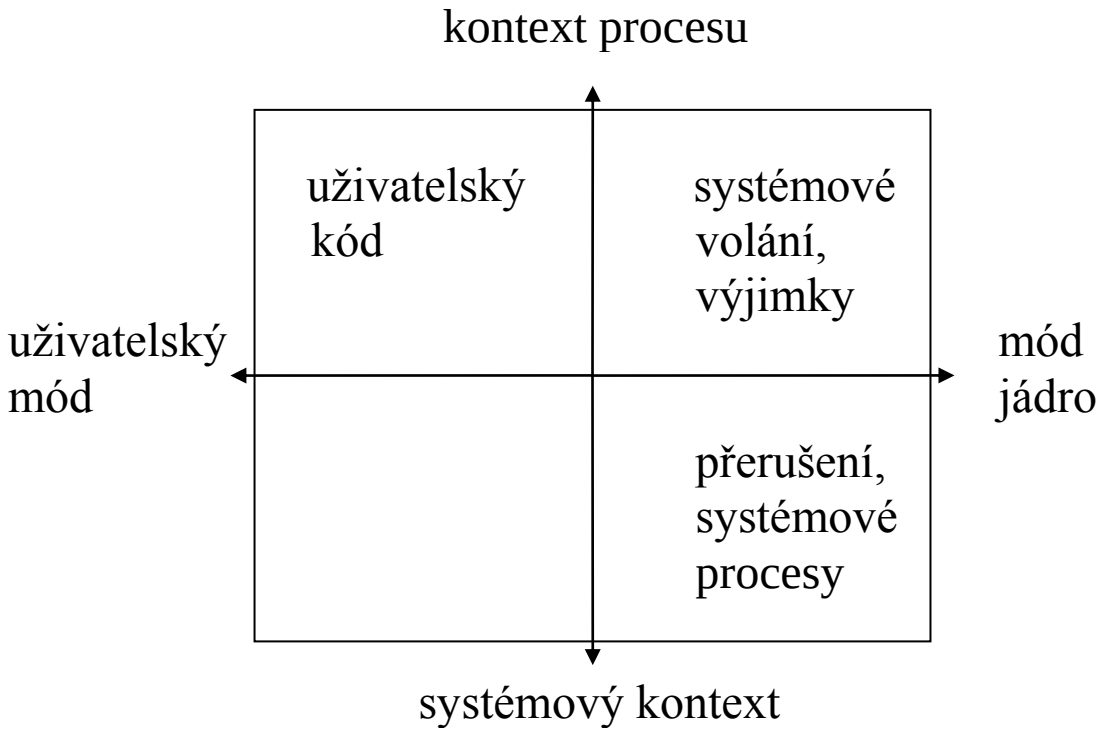

uživatelský kód – přístup jenom k (uživatelskému) adresovému prostoru procesu

systémové volání, výjimky – přístup k uživatelskému i systémovému adresovému prostoru

přerušení, systémové procesy – přístup jenom k systémovému adresovému prostoru

Stavy procesu

v každém okamžiku se proces nachází v nějakém definovaném stavu

přechody mezi jednotlivými stavy znázorňuje diagram stavových přechodů

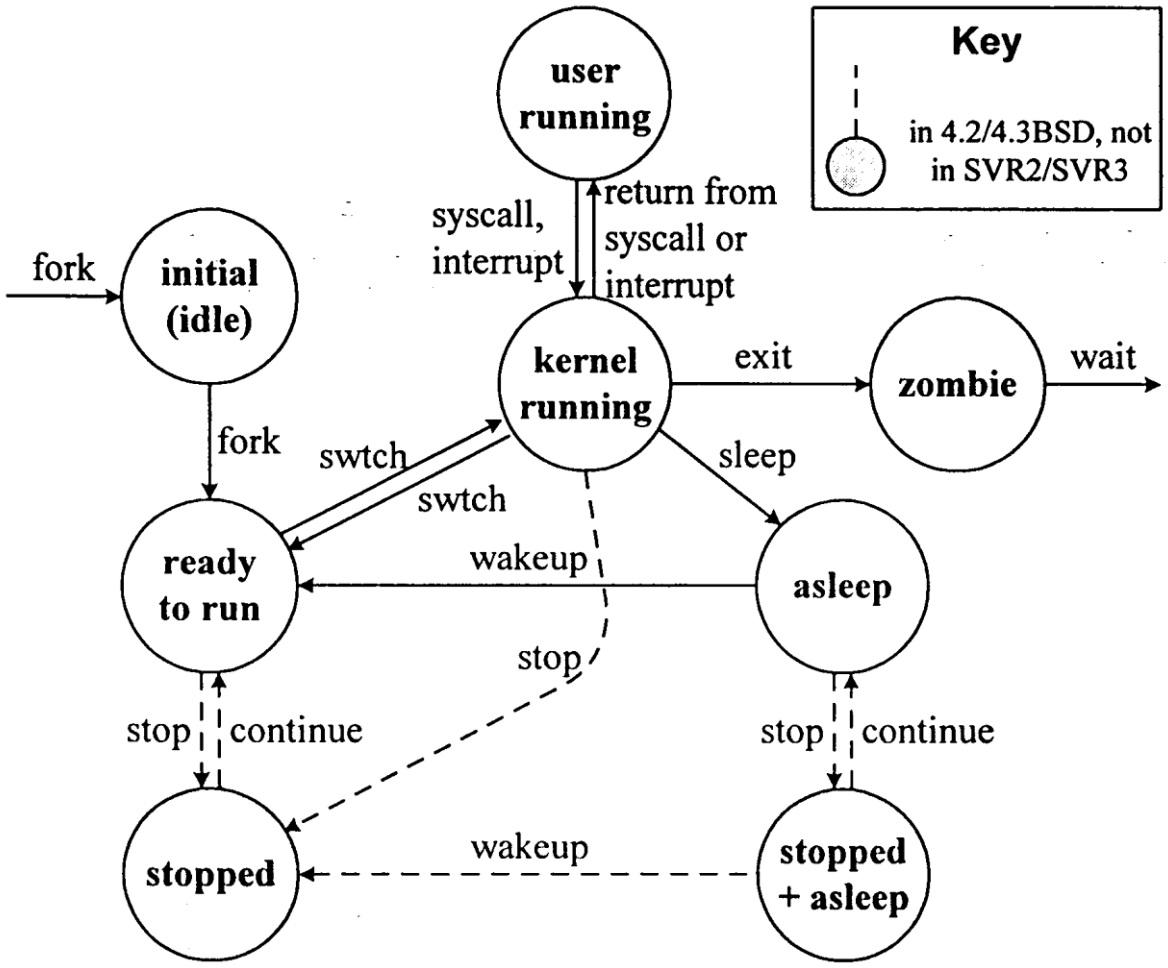

Process states and state transitions.

[Vahalia 96]

začáteční (*initial/idle*) – **`fork`** začal vytváření procesu

připraven na vykonání (ready to run) – proces čeká až bude naplánován na přidělení procesoru

běžící v jádře (*kernel running*) – byl naplánován, vykoná se přepnutí kontextu, procedura jádra **`swtch()`** uloží HW kontext do registrů

běžící uživatelsky (*user running*) – může přejít do stavu ěžící v jádře v důsledku volání služby jádra nebo přerušení, po skončení obsluhy se vrátí

spící (*asleep*) – při vykonávání systémového volání se může stát, že je nutno čekat na nějakou událost nebo prostředek, proces (v jádře) zavolá proceduru **`sleep()`**, když událost nastane, jádro vzbudí proces a proces se stane **připraven na vykonání** a po naplánování pokračuje obsluha systémového volání ve stavu **běžící v jádře**

připraven na vykonání se může stát je-li běžící po uplynutí přiděleného časového kvanta, vykoná se preempce běžícího procesu a to ve stavu **běžící uživatelsky** nebo při návratu do něj, když je jádro nepreemptivní

Main Entry: **pre·emp·tion**
Pronunciation: `-'em(p)-sh&n`
Function: *noun*
Etymology: Medieval Latin *praeemption-*, *praeemptio* previous purchase, from *praeemere* to buy before, from Latin *prae-* pre- + *emere* to buy -- more at REDEEM
Date: 1602

1 a : the right of purchasing before others; *especially* **:** one given by the government to the actual settler upon a tract of public land **b :** the purchase of something under this right
2 : a prior seizure or appropriation **:** a taking possession before others

[m-w.com]

přerušení se může vyskytnout i ve stavu **běžící v jádře,** kdy po skončení obsluhy proces zůstane ve stavu **běžící v jádře**

proces končí voláním **`exit`** anebo v důsledku signálu, přechází do stavu **mátoha** (zombie), dokud rodič nevykoná **`wait`**

do stavu **zastaven** (**stopped**) nebo **spící a zastaven** přejde proces po stop signálech

- SIGSTOP zastav proces
- SIGTSTP CTRL-Z
- SIGTTIN tty čtení procesu v pozadí
- SIGTTOU tty psaní procesu v pozadí

signál SIGCONT převede proces do stavu **připraven na vykonání** nebo do stavu **spící**

Linux

TASK_RUNNING	běžící nebo připraven
TASK_INTERRUPTIBLE	čekající (spící)
TASK_UNINTERRUBIBLE	signál jeho stav nemění (driver zkoumá zařízení)
TASK_STOPPED	jako předtím
TASK_ZOMBIE	jako předtím

Oprávnění uživatele (*user credentials*)

každý uživatel má v systému identifikován číslem, identifikátor uživatele (user identifier) UID a obdobně identifikátor skupiny (group identifier) GID

identifikátory ovlivňují vlastnictví vytvářených souborů, používají se na kontrolu přístupových práv a kontrolu zasílaní signálů jiným procesům

procesy dědí oprávnění

privilegovaný uživatel *superuser*
UID 0, GID 1

nově, rozdělení privilegií (Linux zatím v jádře)

IEEE Std 1003.1-2001

každý proces má

reálný UID (*real UID)*
efektivní UID *(effective UID)*
uložený nastavovací UID *(saved set UID)*

reálný UID identifikuje reálného uživatele a ovlivňují právo posílat signály

efektivní UID ovlivňují vlastnictví souborů a přístup k souborům

proces změní efektivní UID

- vykoná-li **`exec`** programu s nastaveným bitem SUID
- systémovým voláním **`setuid`**

bit SUID, nastavení UID (set UID), je jeden z bitů „přístupových“ práv k souboru

- je-li nastaven, efektivní UID a uložený nastavený UID se nastaví na ID vlastníka souboru

`setuid(uid)`

- je-li okamžitý efektivní UID procesu privilegovaný uživatel, potom reálný UID, efektivní UID a uložený nastavovací UID se nastaví na **`uid`**
- jinak **`setuid(uid)`** nastaví efektivní UID na hodnotu **`uid`**, je-li **`uid`** rovno reálnému UID nebo uloženému nastavovacímu UID, reálný UID a uložený nastavovací UID se nezmění

	`setuid(e)`	
	`euid==0`	**`euid!=0`**
reálný UID	**`e`**	nezměněn
efektivní UID	**`e`**	**`e`**
uložený nastavovací UID	**`e`**	nezměněn

- následující program po přeložení vlastní „on“, UID == 800, má nastavený bit SUID, právo vykonávat mají všichni
- uživatel „on“ vlastní soubor „on“ s právem čtení jenom pro vlastníka
- uživatel „já“ , UID == 500 vlastní soubor „ja“ s právem čtení jenom pro vlastníka

```
main()
{
    int uid, euid, fdja, fdon;

    uid = getuid();   /*reálný*/
    euid = geteuid(); /*efektivní*/
    printf("uid %d euid %d\n",
              uid,euid);

    fdja = open("ja",O_RDONLY);
    fdon = open("on",O_RDONLY);
    printf("fdja %d fdon %d\n",
              fdja, fdon);

    setuid(uid);
    printf("uid %d euid %d\n",
              uid,euid);

    fdja = open("ja",O_RDONLY);
    fdon = open("on",O_RDONLY);
    printf("fdja %d fdon %d\n",
              fdja, fdon);

    setuid(euid);
    printf("uid %d euid %d\n",
              uid,euid);
}
```

vykonání uživatelem „ja“:

```
uid 500 euid 800
fdja -1 fdon 3
uid 500 euid 500
fdja 4  fdon -1
uid 500 euid 800
```

vykonání uživatelem „on“:

```
uid 800 euid 800
fdja -1 fdon 3
uid 800 euid 800
fdja -1 fdon 4
uid 800 euid 800
```

Je-li euid == 0 změní se reálný UID, efektivní UID i uložený nastavovací UID.

- **`login`** po úspěšném přihlášení uživatele nastaví reálný UID, efektivní UID i uložený nastavovací UID na UID uživatele a vykoná **`exec shell`**

Chce-li uživatel změnit své heslo, nemůže tak učinit přímo. Vykoná program **`passwd`**, který má nastavený bit SUID, a který vlastní superuser.

Obdobně s GID

Rodina volání:
getegid() , *geteuid*() , *getgid*() , *getuid*() , *setegid*() , *seteuid(), setgid*() , *setregid*() , *setreuid*() , *setuid*()

u oblast a `proc` záznam

datové struktury obsahující řídící informace pro procesy

často tabulka procesů s položkami **`proc`** záznam má pevnou velikost v adresovém prostoru jádra

nověji pole ukazatelů, na dynamicky vytvářené **`proc`** záznamy, ale pole pevné velikosti, SVR4

u oblast je mapovaná do uživatelského adresového procesu →
je viditelná, když je proces běžící, často mapovaná na pevnou virtuální adresu, proměnná u v jádře

`proc` záznam procesu je přímo přístupný i když proces není běžící

u oblast

- ukazatel na **`proc`** záznam
- reálný a efektivní UID a GID
- argumenty a návratové hodnoty systémových volání
- ošetření signálů
- tabulka deskriptorů otevřených souborů
- okamžitý adresář a řídící terminál
- využití CPU a kvóty
- v mnoha implementacích zásobník jádra

`proc` záznam

- identifikaci PID
- umístnění u oblasti
- stav
- ukazatele na vytvoření seznamů všech procesů, čekajících procesů, ...
- událost, na kterou proces čeká
- informace pro plánování
- pole neošetřených signálů
- informace pro správu paměti
- propojení na PID v rozptýlené (hash) tabulce
- informace pro hierarchii procesů

Linux

jedna údajová struktura – deskriptor procesu, **`task_struct`**

položky obsahují ukazatele, např. na informace o prostředcích

`tty_struct`	terminál sdružený s procesem
`fs_struct`	okamžitý adresář
`files_struct`	ukazatele na deskriptory souborů
`mm_struct`	ukazatele na deskriptory oblastí paměti
`signal_struct`	přijaté signály

deskriptor procesu a zásobník jádra v jedné oblasti paměti o velikosti 8KB

```
union task_union {
    struct task_struct task;
    unsigned long stack[1024];
};
```

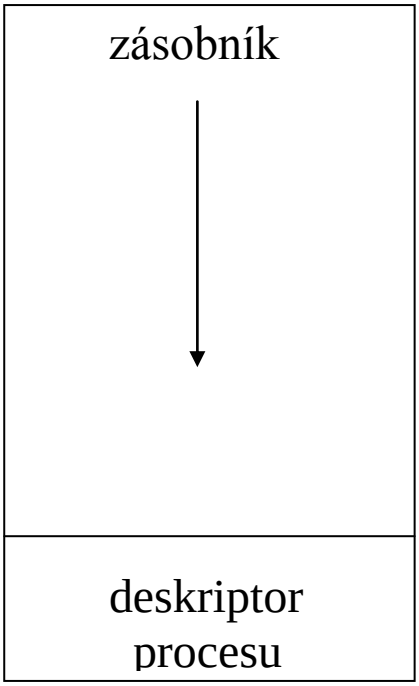

po přepnutí z uživatelského módu do módu jádro, ukazatel zásobníku ukazuje na vrchol

kdykoliv získáme adresu deskriptoru běžícího procesu maskováním nejnižších 13 bitů (8KB = 2^{13})

```
movl $0xffffe000, %ecx
andl %esp, %ecx
movl %ecx, p
```

výhodné pro multiprocesorové systémy

pro efektivní hledání, např. všech připravených procesů,
deskriptory procesů jsou kruhově obousměrně spojeny –
kruhový obousměrný spojový seznam
ukazatelé jsou položky **`task_struct`**

seznam procesů (*process list*)

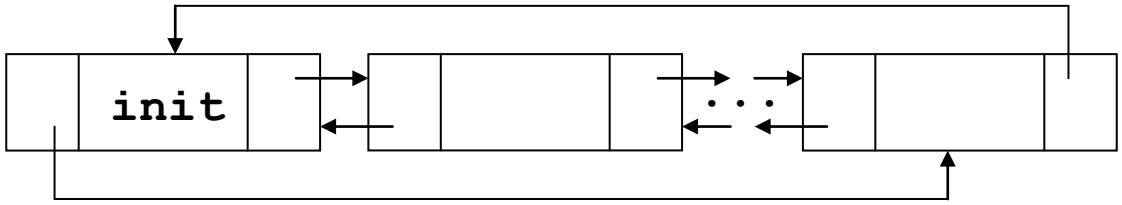

procesy mohou být ve více seznamech
seznam připravených (r*unqueue*)
seznamy čekajících na nějakou událost (*wait queues*)

seznamy umožní nalézt všechny nebo všechny procesy
s nějakou vlastností

jádro někdy musí určit deskriptor procesu z jeho PID
zaslání signálu procesu systémovým voláním

`kill(pid, sig)`

řešení

- projít seznam všech procesů a zjišťovat shodu **`pid`** a PID v deskriptoru procesu ?
- vytvořit pole, kterého prvek s indexem **`pid`** obsahuje ukazatel na deskriptor procesu ?

rozptýlená tabulka (*hash table*)

- položka obsahuje ukazatel na deskriptor procesů se zadaným PID
- v případě kolize jsou odpovídající deskriptory zřetězeny
- ukazatele jsou součástí

```
#define pid_hashfn(x) \
      ((((x) >> 8 ^ (x)) & (PIDHASH_SZ-1))
```

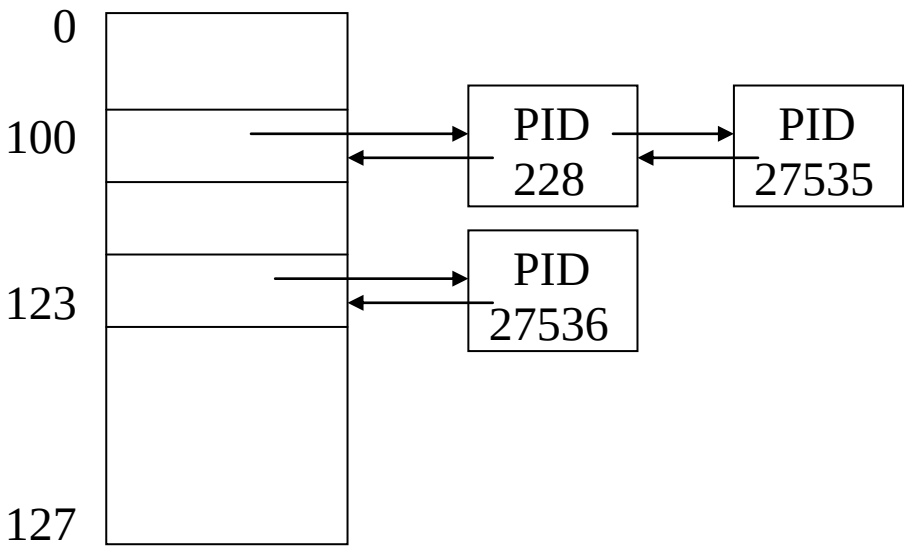

hierarchie procesů – vztahy rodič/potomek se vytváří položkami v deskriptoru procesů

p_opptr	originální rodič nebo init (1), sirotci
p_pptr	rodič, rozdíl např. po ptrace()
p_cptr	nejmladší potomek
p_ysptr	mladší sourozenec
p_osptr	starší sourozenec

proces P0 vytvořil postupně procesy P1, P2, P3 a proces P3 vytvořil proces P4

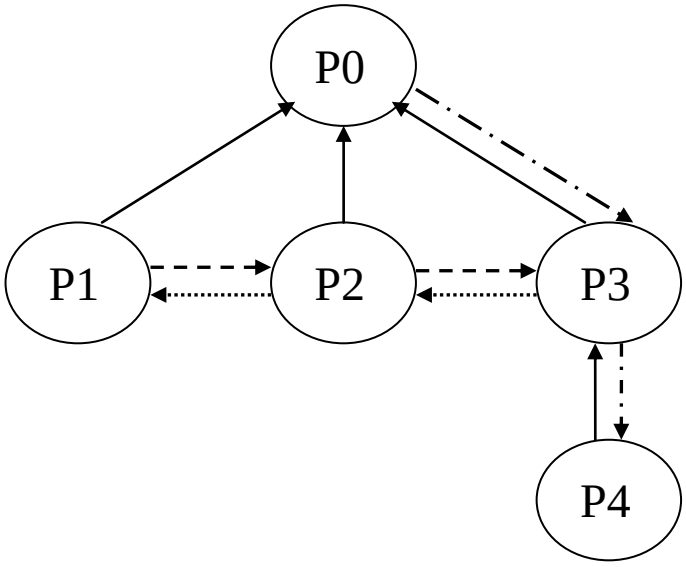

p_pptr ——→
p_ysptr - - - - - →
p_osptr ..... →
p_cptr - · - - · - →