Synchronizace jádra a multiprocesing

problém synchronizace

příklad 1

proměnná **`V`** obsahuje počet volných prostředků, např. vyrovnávacích pamětí diskových bloků

proces **`A`** chce získat volný prostředek a čte **`V`**, přičemž nechť **`V == 1`** a vlákno je přerušeno

proces **`B`** také čte **`V`**, přečte hodnotu **`1`** a sníží hodnotu **`V`** o **`1`**, tedy **`V == 0`** a začne používat prostředek

proces A pokračuje, sníží V o **`1`**, tedy **`V == -1`** a také začne používat prostředek

kdyby však proces **`A`** snížil **`V`** před přerušením, bylo by vše správné

správnost výsledku tedy závisí na plánování procesů, říkáme, že vznikla soutěž, (*race condition*)

správný výsledek by byl zaručen, kdyby čtení a snížení proměnné **`V`** o hodnotu **`1`** bylo nedělitelné, tedy běh procesu by nemohl být mezi čtením a snížením **`V`** přerušen

obecně je přístup ke společným proměnným bezpečný používáme-li atomické operace

v našem příkladě můžeme (pro jednoprocesorový systém) použít obecné instrukce **`dec`**, která nastavuje příznak výsledku v registru příznaků

v případě přerušení procesu i bezprostředně po jejím vykonání je

> registr příznaků uložen v HW kontextu o po obnovení běhu procesu, máme k dispozici příznak výsledku, je-li výsledek nezáporný, prostředek byl získán a další procesy naleznou správnou hodnotu **`V`**

příklad 2

deskriptory procesů jsou (cyklicky) obousměrně spojeny a odstranění deskriptoru procesu B ze seznamu potom znamená vykonat

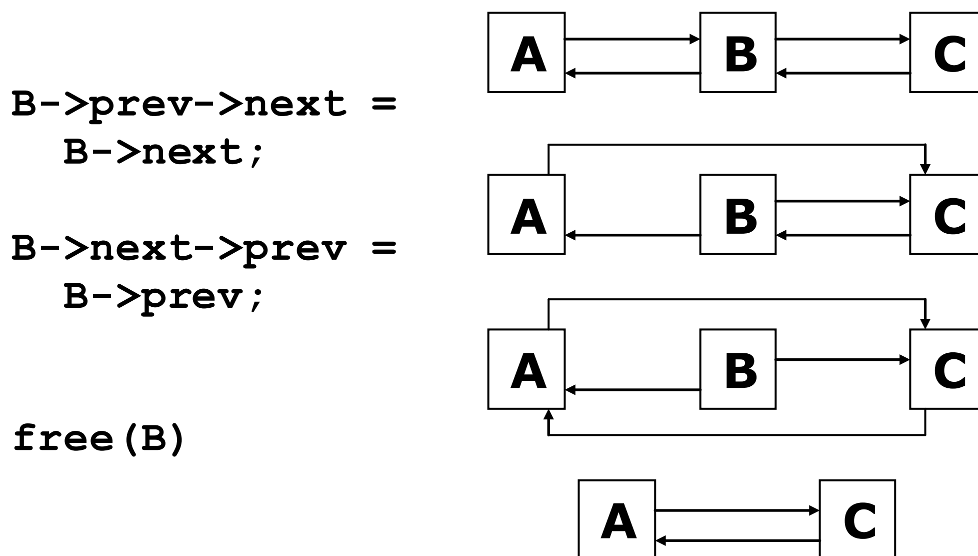

je-li odstraňování B přerušeno po prvním příkazu, údajová struktura zůstane pro další procesy v nekonzistentním stavu

úsek kódu, který může být vykonáván současně nejvíce jedním procesem se nazývá kritická oblast, sekce (*critical region, section*), jinými slovy, každý proces, který začal vykonávat kritickou oblast, musí ji dokončit předtím než ji začne vykonávat jiný proces

jádro

kód jádra je vykonáván

- po volání systému
- při obsluze výjimek
- při obsluze přerušení

přitom se jednotlivá vykonávání jádra můžou přerušovat tak, jak bylo uvedeno v části výpočet v módu jádro

protože sdílejí datové struktury jádra způsobem uvedeným v příkladech, vzniká problém synchronizace výpočtů v jádře

metody synchronizace

při prokládaném vykonávaní systémových volání a obsluh výjimek a přerušení musíme zabránit vzniku soutěže nad sdílenými daty

jádro používá tyto metody:
- nepreemtivnost procesů v módu jádro
- atomické operace
- zákaz přerušení
- zamykání
- další synchronizační prostředky v 2.6

nepreemtivnost procesů v módu jádro

pokud je proces běžící v módu jádro, nemůže se vykonat preempce, tj. nemůže být nahrazen procesem s vyšší prioritou, pokud samotný proces neuvolní procesor

proces v módu jádro může být přerušen obsluhou výjimky nebo přerušení

obsluha přerušení nebo výjimky může být přerušena obsluhou přerušení

neblokující systémová volání jsou atomická vzhledem k ostatním systémovým voláním, mohou bezpečně přistupovat k datům jádra, ke kterým nepřistupují obslužné programy přerušení a výjimek

v blokujícím systémovém volání zanecháme data jádra před přímým voláním funkce `schedule()` v konzistentním stavu, po návratu zkontrolujeme jejich hodnoty

atomické operace

operace nad daty vykonaná jedinou instrukcí jsou na HW úrovni atomické

80x86

- instrukce, které přistupují k paměti nejvíce jednou jsou atomické

- čti-modifikuj-zapiš instrukce, např. `inc` nebo `dec`, které čtou data z paměti, modifikují je a aktualizovaná data zapíšou zpátky do paměti jsou atomické, jestliže sběrnici mezi čtením a zápisem nezískal jiný procesor nenastane na jednoprocesorovém systému

- čti-modifikuj-zapiš instrukce, kterých instrukční kód má prefix `lock` jsou atomické i na multiprocesorových systémech, řídící jednotka zamkne sběrnici dokud instrukce není dokončena

C jazyk

atomické **`int`** operace

datový typ **`atomic_t`**

```
atomic_t v;
atomic_t u = ATOMIC_INIT(0);

atomic_set(&v, 4);
atomic_add(2, &v);
atomic_inc(&v);
```

konverze na **`int`**

```
printk("%d\n", atomic_read(&v));
```

atomické vykonání operace a testování výsledku

```
int atomic_dec_and_test(atomic_t *v)
```

`true` když je výsledek nula, jinak **`false`**

pro specifickou architekturu v <asm/atomic.h>

atomické bitové operace

nevyžadují zvláštní typ

```
unsigned long word = 0;

set_bit(0, &word);
set_bit(1, &word);
printk("%ul\n", word);
```

pro specifickou architekturu v <asm/bitops.h>

maskování přerušení

ne všechny operace nad daty můžeme vykonat atomickými operacemi

data jádra, nad kterými pracují obsluhy přerušení můžeme efektivně zabezpečit tím, že při práci s nimi zakážeme přerušení

maskovatelná přerušení jsou zakázána instrukcí **`cli`**, kterou vykonávají makra **`__cli()`** a **`cli()`** (pro jednoprocesorový systém jsou ekvivalentní)

přerušení jsou povolena instrukcí **`sti`** a odpovídající makra jsou **`__sti()`** a **`sti()`**

uvedené makra nastavují a nulují **`IF`** příznak registru **`eflags`**

jádro při vstupu do kritické oblasti nuluje příznak **`IF`**, na jejím konci ho však nemůžeme obecně přímo nastavit, protože vzhledem na možnost vnoření obsluh přerušení jádro neví jaký byl příznak **`IF`** před okamžitou obsluhou přerušení

uložíme obsah registru **`eflag`** makrem **`__save_flags()`**, respektive **`save_flags()`** a jeho obsah obnovíme makrem **`__restore_flags()`** respektive **`restore_flags()`**

```
__save_flags(old);
__cli();
...
__restore_flags(old);
```

příklady maker zakazujících a povolujících přerušení (parametr lck je pro přerušení ignorován)

```
spin_lock_irqsave(lck, flags)
    __save_flags(flags); __cli()


spin_unlock_irqrestore(lck, flags)
    __restore_flags(flags)


write_lock_irqsave(lck, flags)
    __save_flags(flags); __cli()


write_unlock_irqrestore(lck, flags)
    __restore_flags(flags)
```

například funkce **add_wait_queue()** a **remove_wait_queue()** chrání přístup k frontě čekajících procesů pomocí funkcí **write_lock_irqsave()** a **write_unlock_irqrestore()**

kritické oblasti, vytvořené zákazem přerušení musí být krátké, protože když do nich jádro vstoupí je blokována jakákoli komunikace mezi V/V zařízeními a procesorem

metoda zákazu přerušení není použitelná, když proces se stane spícím, protože je možné, že čeká na událost, která bude oznámená přerušením

řešením v těchto situacích je zamykání

- jádrové semafory
- kruhové blokování (*spin lock*)

jádrové semafory (Linux)

když se jádro pokusí o přístup k prostředku, který je obsazen jiným procesem, odpovídající proces přejde do stavu spící a stane se připravený, když je prostředek uvolněn

jádrové semafory jsou objekty typu
`struct semaphore`, který má položky

`count`

uchovává celočíselnou hodnotu, je-li kladná prostředek je volný, jinak je obsazen a absolutní hodnota udává počet čekajících požadavků jádra

`wait`

uchovává adresu fronty čekajících procesů

`waking`

zabezpečuje, aby jenom jeden proces po uvolnění prostředku mohl tento získat

položka **`count`** je dekrementována, když se proces pokouší získat prostředek a inkrementována, když proces uvolní prostředek

inicializace

`MUTEX` nastaví **`count`** na hodnotu **`1`**
`MUTEX_LOCKED` nastaví na hodnotu **`0`**
může být libovolné celé kladné číslo

operace **P()**, funkce **down()**

```
void down(struct semaphore *sem)
{
    /* začátek kritické sekce */
    --sem->count;
    if (sem->count < 0) {
    /* konec kritické sekce */
        struct wait_queue wait = {běžící,
                                  NULL};
        běžící->state =
              TASK_UNINTERRUPTIBLE;
        add_wait_queue(&sem->wait,&wait);

        for (;;) {
            unsigned long flags;
            spin_lock_irqsave(
              &semaphore_wake_lock,flags);
            if (sem->waking > 0) {
                sem->waking--;
                 break;
            }
            spin_unlock_irqrestore(
               &semaphore_wake_lock,flags);
            schedule();
            běžící->state =
                     TASK_UNINTERRUBTIBLE;
        }
        spin_unlock_irqrestore(
           &semaphore_wake_lock,flags);
        běžící->state = BĚŽÍCÍ;
        remove_wait_queue(&sem->wait,
                                &wait);
    }
}
```

operace **V()**, funkce **up()**

```
void up(struct semaphore *sem)
{
    /* začátek kritické sekce */
    ++sem->count;
    if (sem->count <= 0) {
    /* konec kritické sekce */
        unsigned long flags;
        spin_lock_irqsave(
             &semaphore_wake_lock,flags);
        if (atomic_read(&sem->count)<=0)
             sem->waking++;
        spin_unlock_irqrestore(
          &semaphore_wake_lock,flags);
        wake_up(&sem->wait);
    }
}
```

zabránění vzniku uváznutí

dva procesy **`A`** a **`B`** požadují dva prostředky chráněné semafory **`sem1`** a **`sem2`**

```
MUTEX(sem1);
MUTEX(sem2);
```

```
proces A:

down(sem1);
...
down(sem2);
...
```

```
proces B:

down(sem2);
...
down(sem1);
...
```

může vzniknout uváznutí

požadavky se vykonají v pořadí adres datových struktur **`semaphore`**

Multiprocesing

v jednoprocesorových strojích má paralelizmus procesů tvar prokládání jejich činnosti

na víceprocesorových strojích můžou být činnosti procesů až do počtu procesorů vykonávány současně

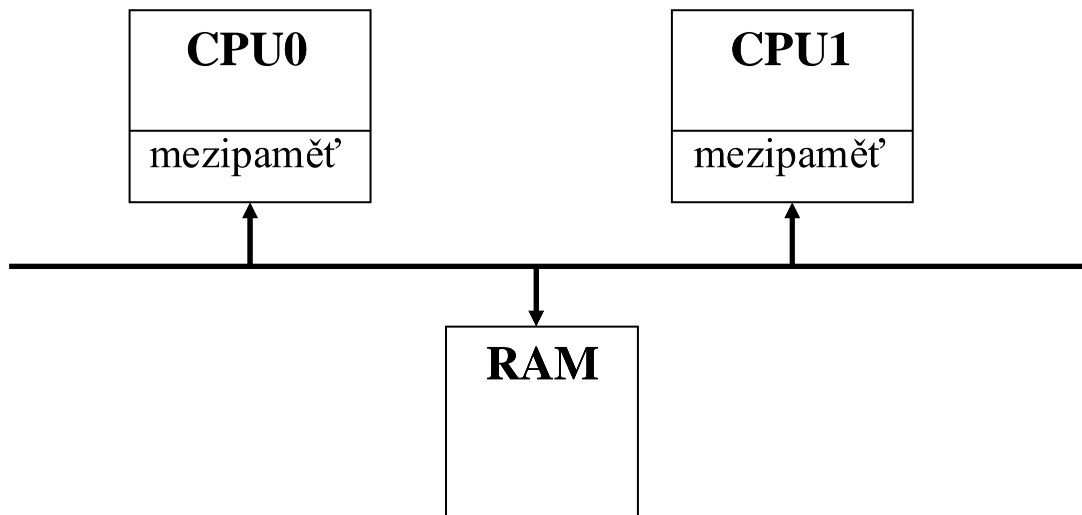

SMP (*symmetrical multiprocessing*) architektura

procesory a sdílená hlavní paměť jsou připojeny ke společné sběrnici

synchronizace mezipaměti (*cache*) procesorů

když procesor modifikuje svou mezipaměť, musí kontrolovat jestli stejná data nejsou v mezipaměti jiného procesoru a když ano, musí je aktualizovat nebo zneplatnit

atomické operace

instrukce čti/modifikuj/zapiš na multiprocesorových systémech nejsou atomické, sběrnice se musí zamknout – **`lock; dec`**

distribuované zpracování přerušení

který procesor obslouží přerušení?
Intel – APIC (*Advanced Programmable Interrupt Controller*)

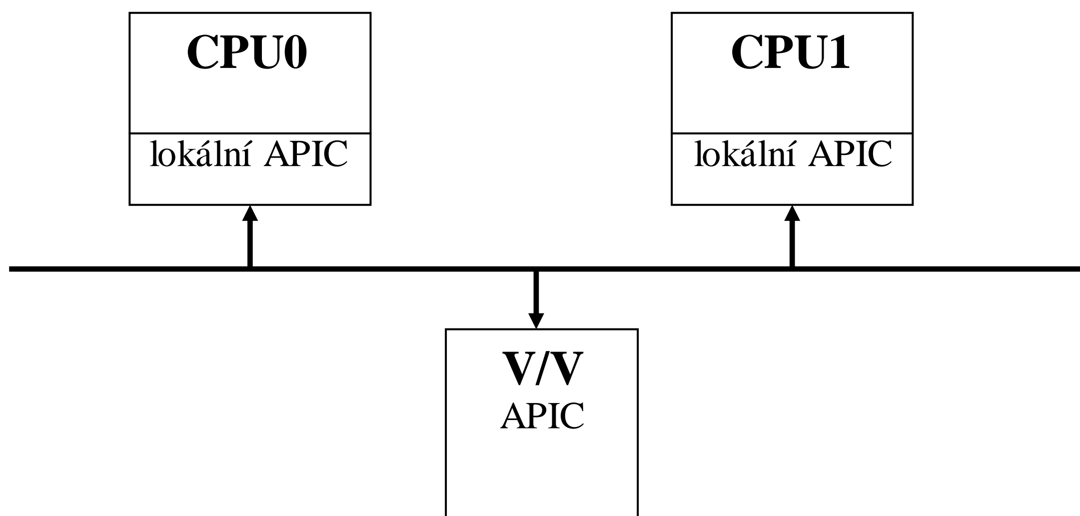

- přerušení může být směrováno na pevný APIC nebo na APIC procesoru vykonávající proce s nejnižší prioritou, APIC má programovatelný registr obsahující prioritu běžícího procesu

SMP jádro

tradiční řešení synchronizace

- neblokující systémová volání jsou atomická vzhledem k ostatním systémovým voláním
- pro synchronizaci prokládání obsluh přerušení při přístupu ke společným datům stačí zakázaní přerušení a semafory

multiprocesorový sytém

- na více procesorech několik procesů může běžet v módu jádro

do verze 2.0 globální zámek

řešení: semafory a kruhové blokování na chránění přístupu ke sdíleným datům, tj. na implementaci kritických sekcí

kruhové blokování

instrukce test-and-set zjistí hodnotu sdílené proměnné, 0 nebo 1, a nastaví ji na hodnotu 1

peudokód

```
spinlock_t TS(spinlock_t *lock) {
   /* začátek kritické sekce */
   spinlock_t loc = *lock;
   *lock = 1;
   return(loc);
   /* konec kritické sekce */
}
```

obvyklá interpretace

`lock == 0`, prostředek je volný, možno vstoupit do kritické oblasti, proces může pokračovat
`lock == 1`, prostředek je obsazen, do kritické oblasti není možno vstoupit, proces musí čekat

```
void spin_lock (spinlock_t *lock) {
   while (TS(lock) != 0)  /*zamčeno*/
    ;                     /*cykluj*/
}

void spin_unlock (spinlock_t *lock) {
   *lock = 0;
}
```

instrukce odpovídající **TS** jsou typu čti-modifikuj-zapiš a sběrnice musí být během jejich vykonávání implicitně nebo explicitně zamčena, navíc pokud hodnota ***lock** byla v mezipaměti jiných procesorů, tyto se při zápisu musely aktualizovat nebo zneplatnit

čekání přepisuje přečtenou hodnotu 1 opět hodnotou 1

spin_lock můžeme zlepšit tím, že jestliže začneme čekat, instrukcí typu čti, která nevyžaduje zamykání sběrnice čekáme v cyklu, než nastane možnost vstoupit do kritické oblasti

```
void spin_lock (spinlock_t *lock) {
    while (TS(lock) != 0)  /*zamčeno*/
        while(*lock != 0)   /*cykluj*/
      ;
}
```

kruhové blokování je neefektivní na jednoprocesorových systémech, protože nemá kdo splnit podmínku, na kterou se čeká

je efektivní na multiprocesorových systémech, protože řešení se semaforem, vyžaduje přepnutí kontextu, což je nákladné

Intel x86 (Linux)

makro **`spin_lock, slp`** je adresa zámku

```
1: lock; btsl $0, slp
   jnc 3f
2: testb $1,slp
   jne 2b
   jmp 1b
3:
```

`btsl` atomicky kopíruje bit 0 z **`*slp`** do příznaku přenosu (*carry flag*) a potom bit 0 nastaví

nebyl-li bit 0 nastaven, bylo odemčeno, pokračuje se na náveští 3:

jinak, cyklujeme na návěští 2: dokud zámek není 0, kdy se vrátíme na návěští 1:

makro **`spin_unlock`**

```
lock; btrl $0, slp
```

`btrl` atomicky nuluje bit 0 v **`*slp`**

spin_lock a **spin_unlock** můžou chránit jenom data jádra, ke kterým nikdy nepřistupují obslužné programy přerušení

pro taková data nutno použít makra s maskováním přerušení

příklady maker s kruhovým blokováním pro multiprocesorové systémy (pro jednoprocesorové systémy byla uvedena jenom s maskováním přerušení)

```
spin_lock_irqsave(slp, flags)

    __save_flags(flags);
    __cli();
    spin_lock(slp)


spin_unlock_irqrestore(slp, flags)

    spin_unlock(slp);
    __restore_flags(flags)
```

kruhové blokování pro čtení/zápis
(*read/write spin locks*)

přístup ke sdíleným datovým strukturám v jádře nemusí být nevyhnutně exklusivní

čtení je možné povolit současně několika výpočtům v jádře

je-li sdílená datová struktura zamčena pro čtení, můžou i další výpočty v jádře tuto strukturu číst, nemůžou však do ní zapisovat

zapisovat však může nejvíce jeden proces, který ji zamkne pro zápis a žádný další proces do ní nemůže zapisovat ani ji číst

možnost současného čtení zvyšuje paralelnost výpočtů jádra

oba zámky jsou realizovány kruhovým blokováním pro čtení/zápis

jsou implementovány jedním 32 bitovým počítadlem **`*rwlp`**, reprezentující okamžitý počet výpočtů jádra, které čtou chráněnou datovou strukturu

bit v nejvyšším řádu slouží pro kruhové blokování zápisu, je nastaven modifikuje-li jádro datovou strukturu
(2 147 483 647 čtenářů ho ovšem také nastaví)

makro **read_lock**

```
1: lock; incl rwlp
   jns 3f
   lock; decl rwlp
2: cmpl $0, rwlp
   js 2b
   jmp 1b
3:
```

po zvýšení o 1 kontrolujeme jestli zámek nemá zápornou hodnotu – je zamčen pro psaní, nemá-li pokračujeme na návěští 3:

jinak, obnovíme původní hodnotu a cyklujemena návěští 2: dokud nejvyšší bit nebude nulový, kdy se vrátíme na začátek

makro **read_unlock**

```
lock; decl rwlp
```

makro write_lock

```
1: lock; btsl $31, rwlp
   jc 2f
   testl $0x7fffffff, rwlp
   je 3f
   lock; btrl $31, rwlp
2: cmp $0, rwlp
   jne 2b
   jmp 1b
3:
```

atomicky se zjistí hodnota nejvyššího bitu a současně se nastaví

byla-li jeho hodnota 1, je zamčeno pro zápis a pokračuje se návěštím 2:, kde čekáme dokud hodnota **`*rwlp`** nebude nula, kdy začneme od začátku

nebylo-li zamčeno pro zápis, zjišťuje se není-li čteno, kdy jsme získali zámek pro zápis a pokračujeme návěštím 3:

jinak se uvolní zámek pro zápis a čeká se na návěští 2: dokud hodnota **`*rwlp`** nebude nula a opět začneme od začátku

makro **`write_unlock`**

```
lock; btrl $31, rwlp
```

příklady maker pro zápis s kruhovým blokováním na multiprocesorovém systému

```
write_lock_irqsave(rwlp, flags)

    __save_flags(flags);
    __cli();
    write_lock(rwlp)


write_unlock_irqrestore(rwlp, flags)

    write_unlock(rwlp);
    __restore_flags(flags)
```

Completions, Completions Variables

synchronizace procesů, když jeden oznamuje druhému výskyt události

obdoba semaforu

`init_completion(struct completion *)`

`wait_for_completion(struct completion *)`

`complete(struct completion *)`

```
struct completion {
    unsigned int done;
    wait_queue_head_t wait;
};
```

`up()`, `down()` se mohou vykonávat souběžně
`complete()`,`wait_for_completion()` ne

využívá například vfork() pro vzbuzení rodiče, když potomek vykoná exec nebo exit

Seqlocks, Sequential Locks

čtení a zápis synchronizované zámky mají stejnou prioritu

seqlocks dávají daleko větší prioritu psaní

`seqlock_t` obsahuje pořadové počítadlo, které musí být čteno každým čtenářem dvakrát

pokud jeho hodnoty nekoincidují, začal nový zápis

zápis:

```
write_seqlock(&seqlock);
...
write_sequnlock(&seqlock);
```

pořadové počítadlo je sudé když se nezapisuje

čtení:

```
unsigned int seq;
do {
    seq = read_seqbegin(&seqlock);
    ...
} while (read_seqretry(&seqlock, seq));
```

Per-CPU proměnné

pole s prvky pro každý procesor

ochrana proti přístupu z jiných procesorů

nutno chránit v případě asynchronních funkcí (přerušení, odložené vykonávání)

pro preemtivní jádro soutěž – zablokování preempce

```
preempt_disable();
...
preempt_enable();
```

Bariéry

překladač nebo procesor můžou změnit pořadí přístupu k paměti

pro synchronizaci nevhodné

optimalizační bariéry:

instrukce odpovídající příkazům jazyka C před a za bariérou nejsou promíchány

paměťové bariéry:

operace před bariérou jsou dokončeny před zahájením vykonávání operací za bariérou