SO2
kernel crunch

Cursul 7

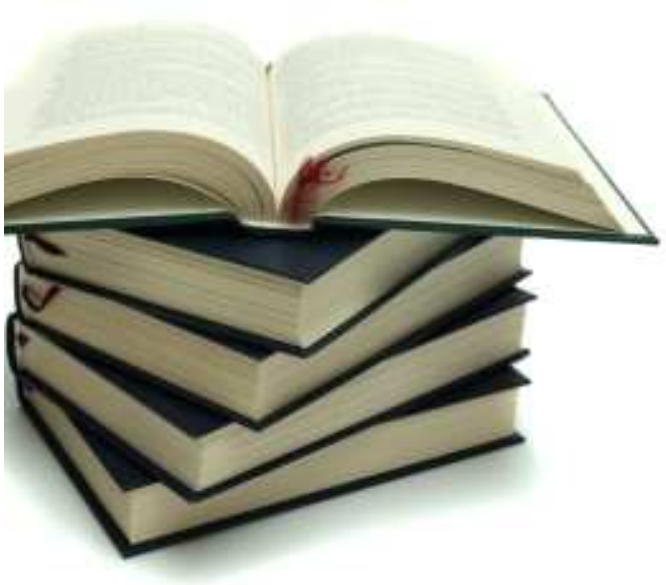

7

Sincronzare

9 aprilie 2009

Test Curs 6

- Cum se previne starvation-ul proceselor utilizator cauzat de rularea actiunilor amânabile în Linux?
- Dar în Windows?
- Care din următoarele funcții kernel nu se pot apela dintr-un tasklet:
  - memcpy
  - copy_from_user
  - spin_lock
  - sem_down
  - sleep_on
  - wake_up

- Concurență în kernel
- Operații atomice
- Spinlock-uri
- Cache trashing
- Primitive de sincronizare blocante
- Per-cpu data
- Bariere
- RCU (Read-Copy-Update)

Bibliografie

- UTLK: capitolul 5
- LKD: capitolele 8, 9
- WI: capitolul 3 (Synchronization)

Sincronizare

- Avem nevoie de sincronizare atunci când
  - Există concurență
  - „Concurenții” accesează aceaşi zonă de memorie
  - Se fac atât accese RO cât şi RW
- Lipsa sincronizării produce condiții de cursă

Condiții de cursă

- Două fire de execuție decrementează variabila V până la 0

```
while (v>0)
    v--;
```

Thread A

```
while (v>0)
    v--;
```

Thread B

- Ce valoare va avea variabila V după terminarea execuției celor două fire de execuție?

Condiții de cursă (2)

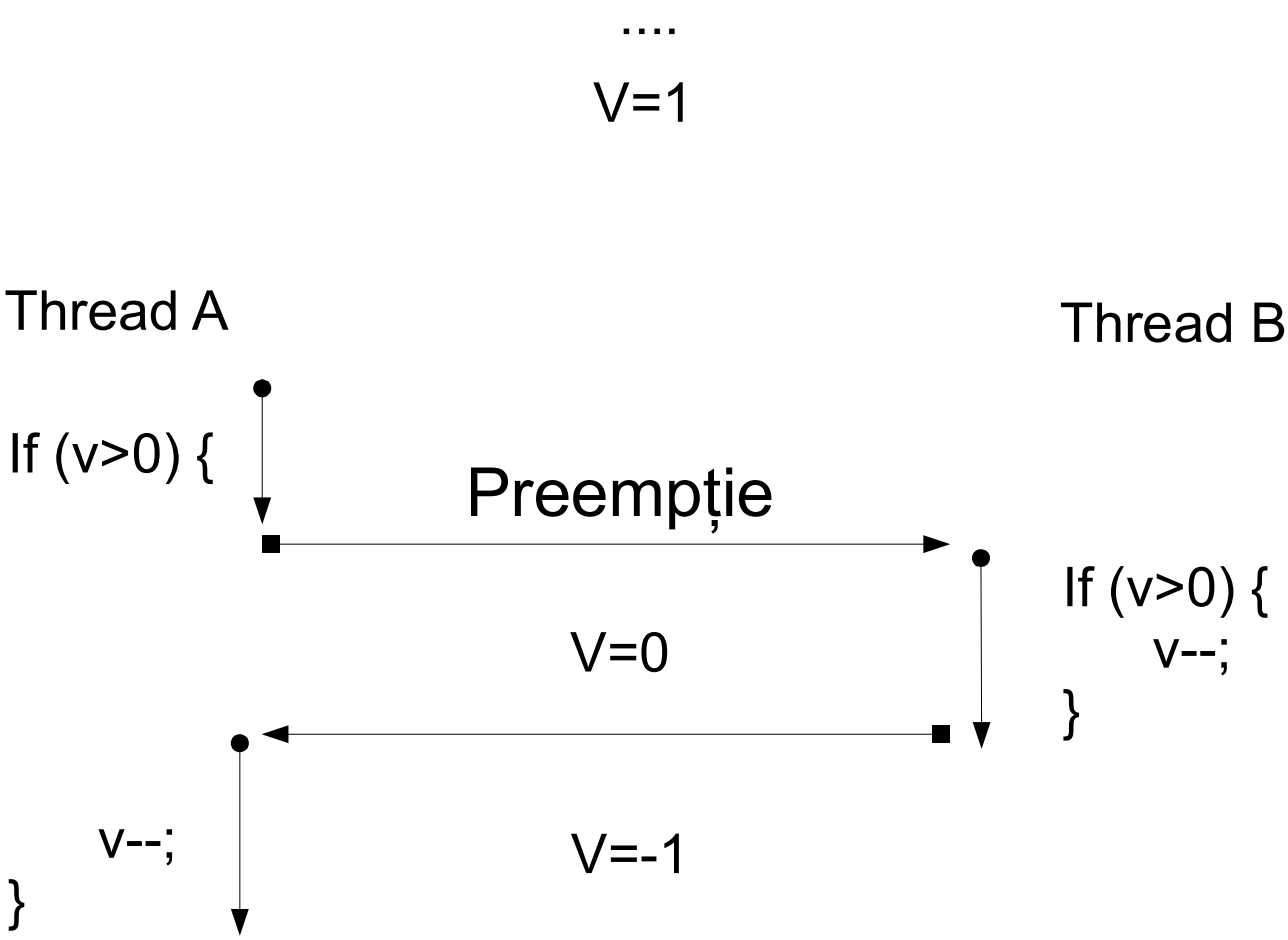

Rezolvarea condițiilor de cursă

- Zona critică = zona de cod ce accesează datele partajate din mai multe contexte de execuție
- Accesul la date în zona critică făcut într-un mod ordonat, astfel încât rezultatele să fie predictibile
  - În exemplul precedent, thread-ul B ar trebui sa aştepte până thread-ul A iese din if
- Soluție: atomicizarea zonei critice, dezactivarea preempției în zona critică, secvențializarea accesului la zona critică

Concurență în kernel

- Sisteme uniprocesor, kernel nepreemptiv: procesul curent poate fi preemptat de către întreruperi
- Sisteme uniprocesor, kernel preemptiv: procesul curent poate fi preemptat de către alte procese
- Sisteme multiprocesor: procesul curent se poate executa în paralel cu un alt proces sau întrerupere ce rulează pe alt procesor

Operații atomice

- Operații cu întregi:
  - incrementare, decrementare, adunare, scădere
  - add_and_test, sub_and_test, dec_and_test, inc_and_test: efectuează operație şi întoarce valoarea după operație
- Operații cu biți:
  - test/set/clear/change bit
  - test_and_set/clear/change bit: efecutează operația şi întoarce valoarea dinaintea operației

Operații atomice în sisteme multiprocesor

- Chiar dacă procesoarele pot rula cod concurent, memoria este partajată, deci accesul este secvențializat
- Dar, operațiile atomice la nivel de procesor nu mai sunt atomice la nivel de sistem

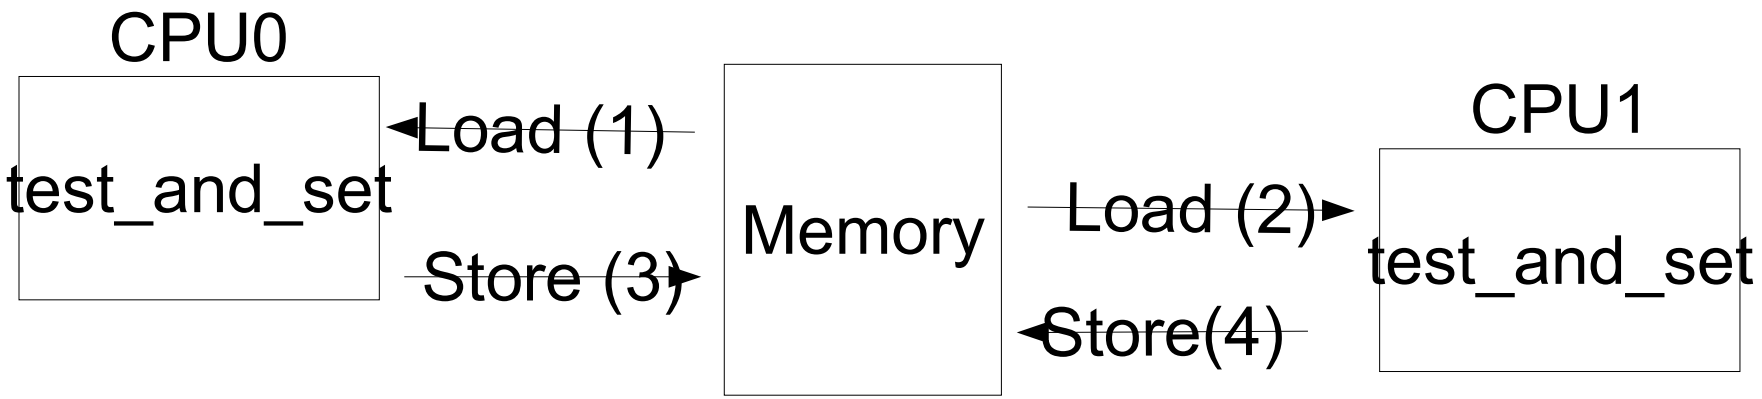

Operații atomice în sisteme multiprocesor (2)

- Soluția: lock pe magistrală pe durata execuție instrucțiunii

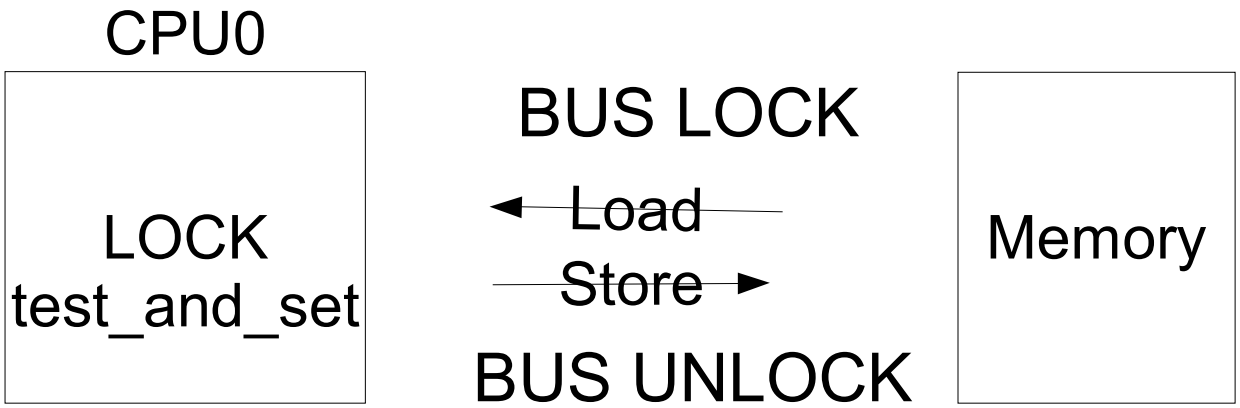

Dezactivarea întreruperilor

- Pe sistemele uniprocesor, dezactivarea întreruperilor elimină sursa de concurență
- Operația e suficientă pentru a proteja zonele critice
- Funcționează atât pentru kernel preemptive cât şi pentru kernel nepreemptive

Exemplu: Linux x86

```
local_irq_disable() \
   asm volatile („cli” : : : „memory”);

local_irq_enable() \
   asm volatile („cli” : : : „memory”);

local_irq_save(flags) \
   asm volatile ("pushf ; pop
     %0"                    :"=g" (flags): /* no
     input */: "memory")

local_irq_restore(flags) \
   asm volatile ("push %0 ; popf"
      : /* no output */
      : "g" (flags) :"memory", "cc");
```

Spinlock-uri

- Necesare pe sisteme multiprocesor
- Sunt folosite pentru a secvențializa accesul la zona critică
- Implementare tipică

```
spin_lock:
   LOCK BTS [LOCK],0
   JC spin_lock
```

```
unlock:
   MOV LOCK, 0
```

(x86) BTS - Bit Test and Set

- Usage: BTS dest,src
- Modifies Flags: CF
- The destination bit indexed by the source value is copied into the Carry Flag and then set in the destination.

Lock contention

- Există lock contention atunci când avem cel puțin un procesor care aşteaptă să între într-o zonă critică
- Cu cât zona critică este mai mare, cu atât creşte probabilitatea şi timpul petrecut în lock contention
- Cu cât avem un număr mai mare de procesoare cu atât creşte probabilitatea şi timpul petrecut în lock contention

Cache trashing

- Datorită faptului că spinlock-urile accesează foarte des memoria atunci când există contention, există o probabilitatea crescută pentru a induce fenomenul de cache trashing
- Fenomenul de cache trashing apare la sistemele multiprocesor atunci când o line de cache se „plimbă de la un procesor la altul”
- Consecință a modului în care e implementată sincronizarea cache-urilor (L1) în sisteme multiprocesor

De ce trebuie să sincronizăm cache-urile?

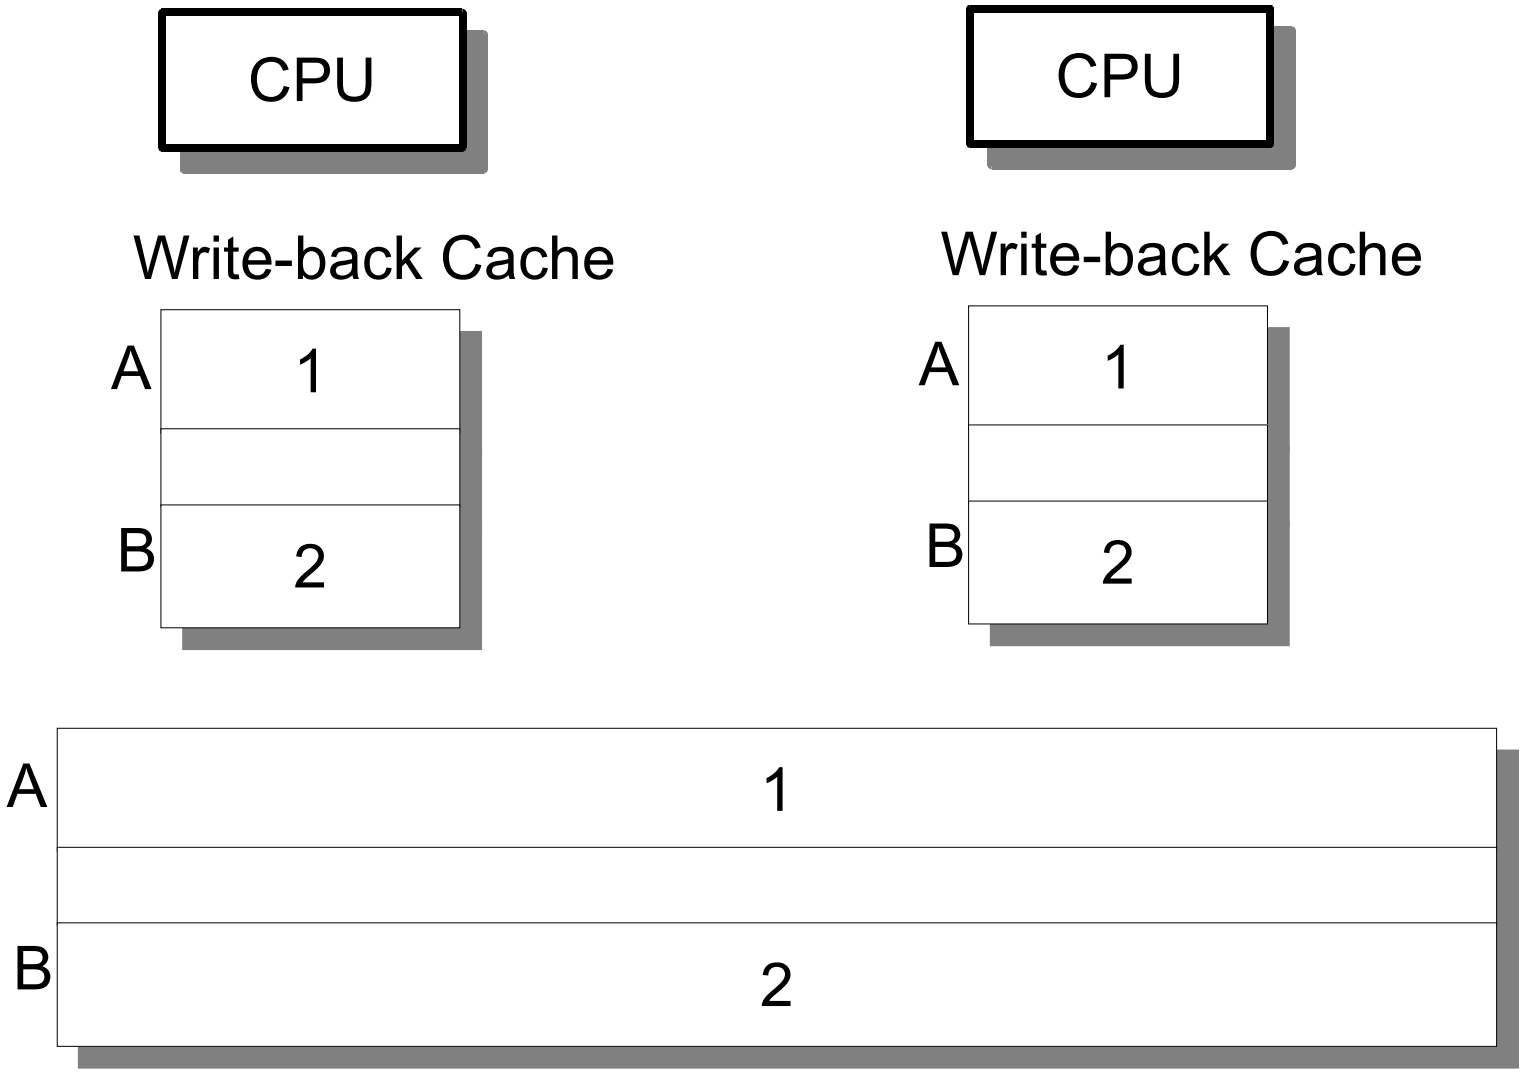

De ce trebuie să sincronizăm cache-urile? (2)

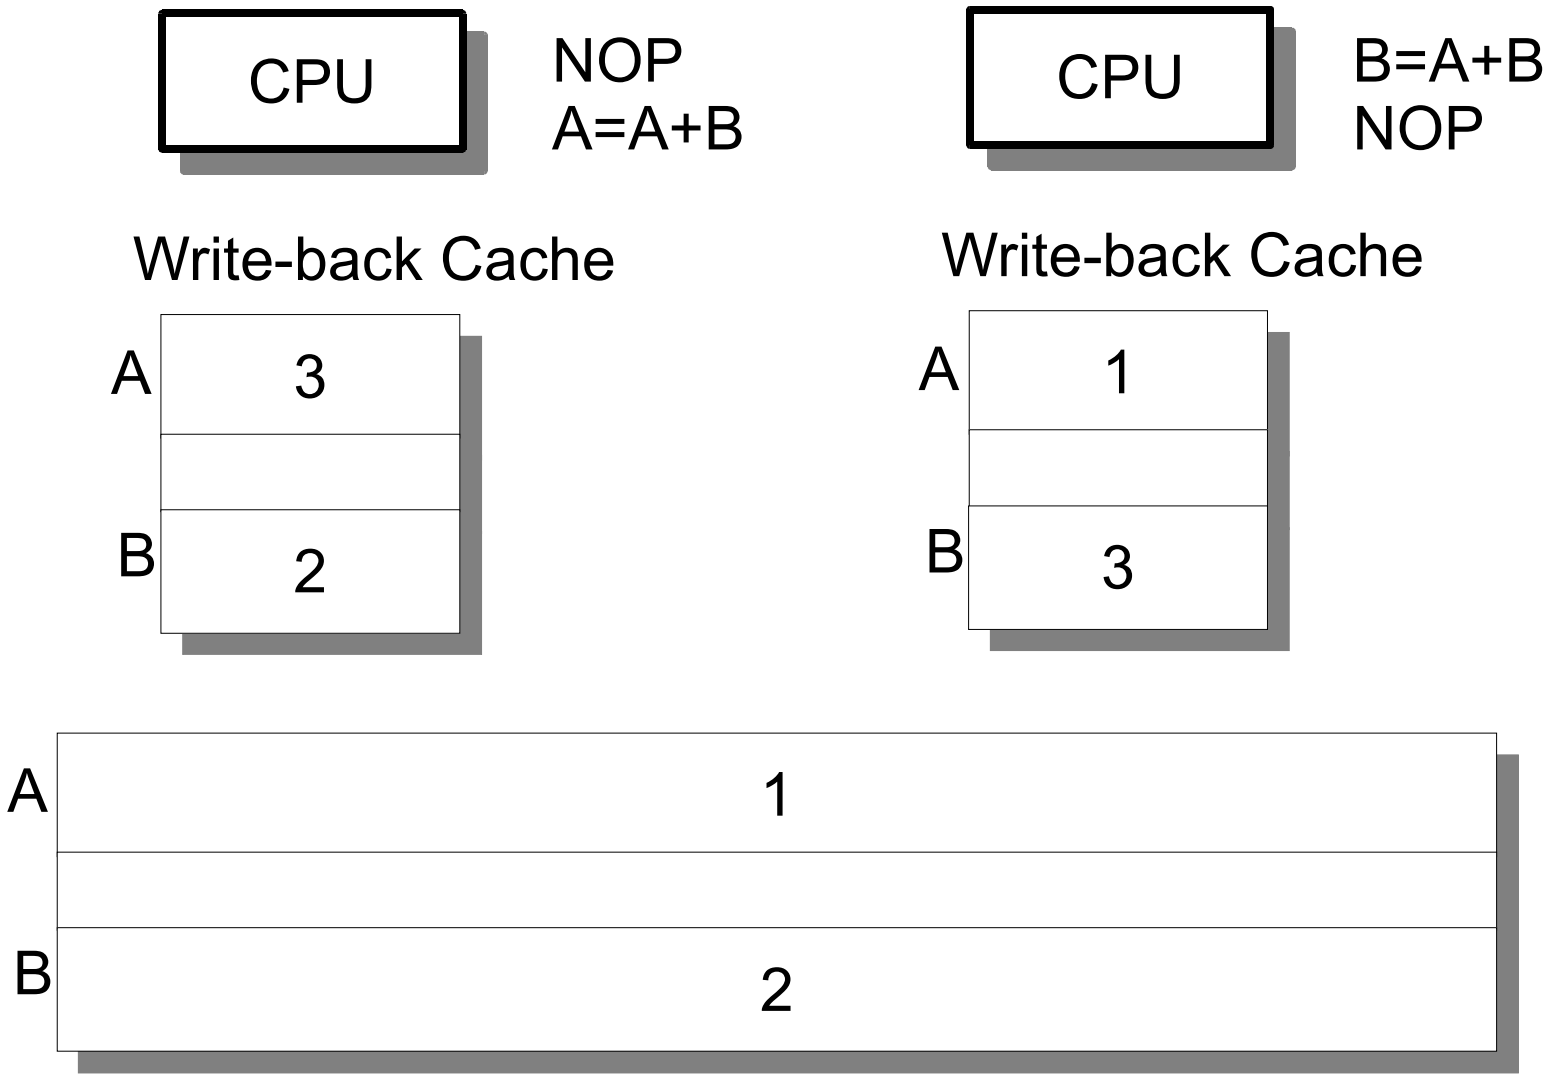

Cum se sincronizează cache-urile?

- În hardware, cu protocoale de sincronizare
- Snooping: cache-ul monitorizează accesul la memorie şi în cazul în care se detectează o operație de scriere se invalidează linia de cache
- Directory: se mențin global informații despre unde (în ce cache) se găsesc cele mai actuale modificări
- Snooping vs Directory: directory scalează mai bine (este folosit pentru >= 64 procesoare), snooping are latență mai mică

MESI

- Politica de caching: write-back
- O linie de cache are 4 stări: Modified, Exclusive, Shared, Invalid
- Operațiile de citire pot fi servite din orice stare, mai puțin Invalid
- Operațiile de scriere pot fi servite doar din stările Modified şi Exclusive
- Dacă linia este în starea Shared, un Write va determina un cache Invalidate pe toate celelalte procesoare
- Procesorul care ține linia în Modified, trebuie să intercepteze toate operațiile de citire (snoop) şi să:
  - Pună pe hold operația de citire
  - Să facă flush la linie modifică
  - Să reia operația de citire

Cache trashing (2)

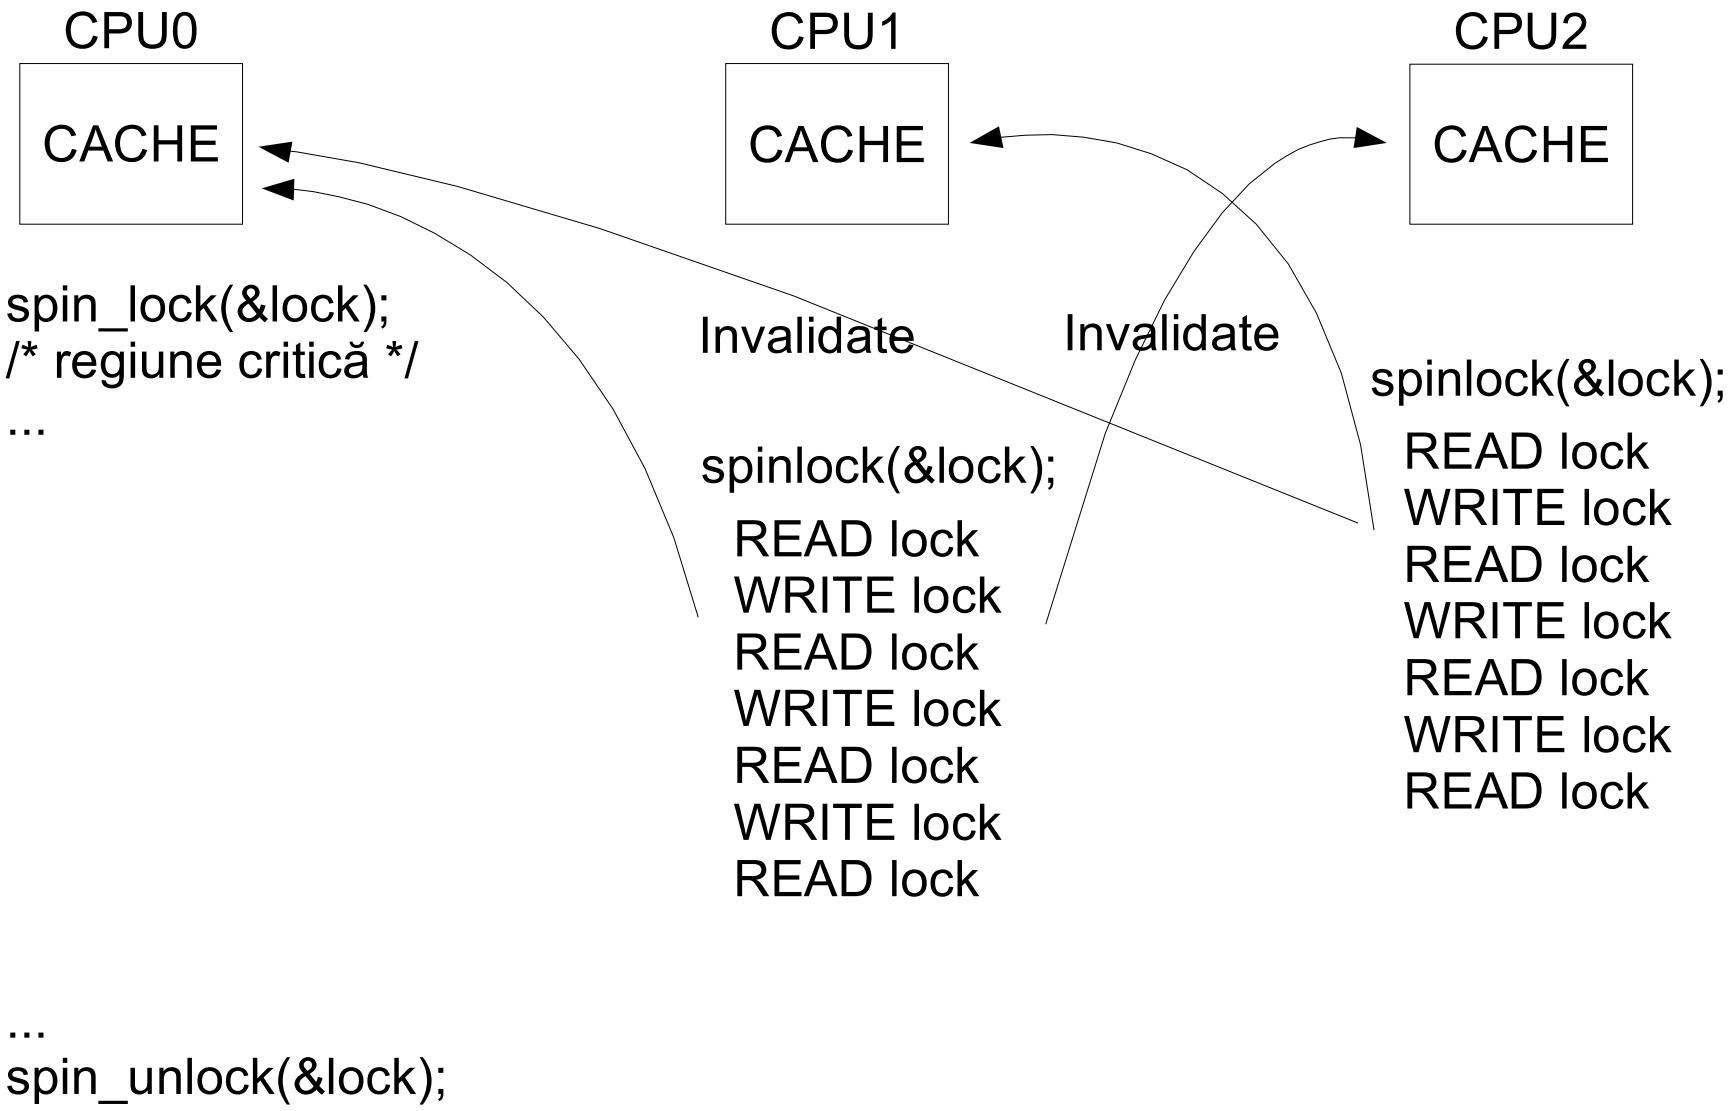

Evitare cache trashing

```
;
; implementarea
; KeAcquireSpinLock
;
spin_lock:
   rep ; nop
   test lock_addr, 1
   jnz spin_lock
   lock bts lock_addr
   jc spin_lock
```

- Majoritatea acceselor vor fi de tip READ astfel încât se va reduce frecvența invalidărilor cacheului
- Rep; nop delay proporțional cu viteza memoriei

Spinlock-uri înlănțuite

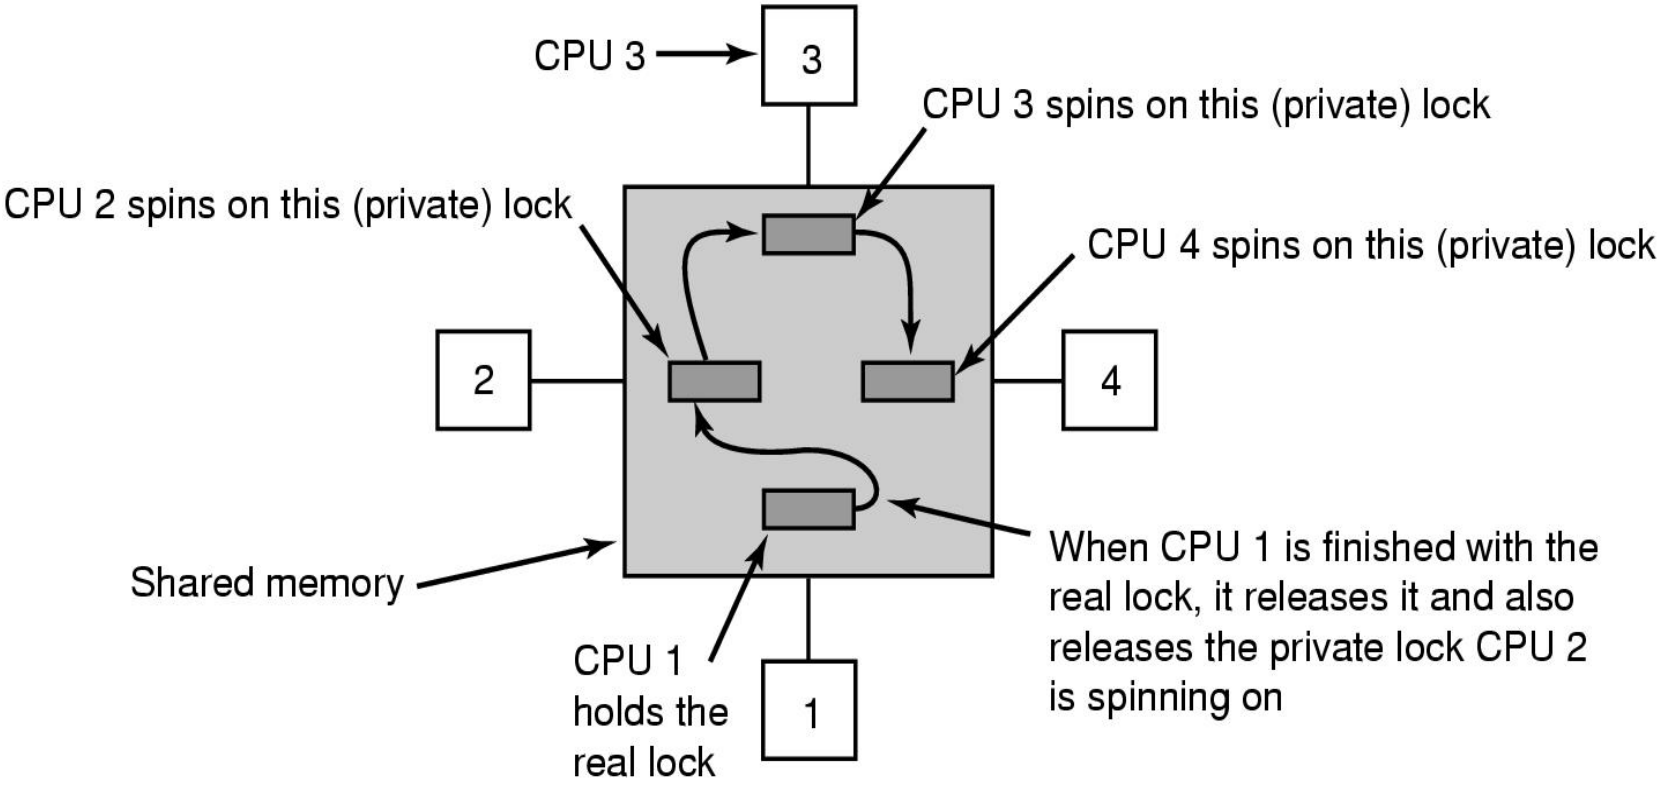

Sincronizarea cu întreruperile

- Scenariu: date partajate între cod ce rulează în process context şi cod ce rulează într-o întrerupere
- În context proces, se ia spinlock-ul
- Pe acelaşi procesor vine întreruperea, şi se rulează rutina de tratare
- Rutine de tratare încearcă să ia spinlock-ul
- Deadlock

Sincronizarea cu întreruperile (2)

- Context process:
  - dezactivare întreruperi: ne protejează împotriva preempției pe procesorul curent +
  - luare spinlock: ne protejează împotriva rulării codului din al proces context sau întrerupere, pe alt procesor
- Context întrerupere:
  - luare spinlock: ne protejează împotriva rulării codului în context proces pe alt procesor
- Linux:
  - spin_lock_irqsave
  - spin_unlock_irqrestore
- Windows
  - KeSynchronizeExecution
  - KeAcquireInterruptSpinLock

Sincronizarea cu bottom-half handlerele

- Acelaşi scenariu se aplică şi la BH-uri, pentru că BH-urile pot preempta contextul process
- Linux:
  - spin_lock_bh: local_bh_disable + spin_lock
  - spin_unlock_bh: spin_unlock + local_bh_enable
- Windows
  - KeAcquireSpinLock ridică automat nivelul IRQL la DISPATCH_LEVEL

```
#define local_bh_disable() \
   add_preempt_count(SOFTIRQ_OFFSET); \
   barrier();

#define local_bh_enable() \
   sub_preempt_count(SOFTIRQ_OFFSET);

#define irq_count() \
   (preempt_count() & (HARDIRQ_MASK | SOFTIRQ_MASK))

#define in_interrupt() irq_count()

asmlinkage void do_softirq(void)
{
        if (in_interrupt()) return;
...
```

Linux kernel preemption

- Poate fi configurat
  - Activat – timp de răspuns mai bun
  - Dezactivat – throughput mai bun
- Este deazactivat la luarea unui spinlock, nu avem nevoie de protecție specială
- Dezactivarea poate fi imbricată, se ține un contor de preempție în current_thread_info()

Primitive de sincronizare non busy waiting

- Dacă regiunea critică este protejată, se pune procesul curent în aşteptare
- Nu pot fi chemate din context întrerupere
- Latența mai mare decât spinlock-urile
- Throughput mai bun dacă overhead-ul schimbării de context e mai mic decât timpul de aşteptare mediu
- Semafoare, Mutex-uri

Linux: semafoare

```
static inline void down(struct semaphore * sem)
{
   might_sleep();
   __asm__ __volatile__(
      "LOCK decl %0\n\t"
      "jns 2f\n"
      "lea %0,%%eax\n\t"
      "call __down_failed\n"
      "2:"
      :"+m" (sem->count): :"memory","ax");
}
```

Linux: semafoare (2)

```
void __sched __down(struct semaphore *sem)
{
        struct task_struct *tsk = current;
        DECLARE_WAITQUEUE(wait, tsk);
        unsigned long flags;

        tsk->state = TASK_UNINTERRUPTIBLE;
        spin_lock_irqsave(&sem->wait.lock, flags);
        add_wait_queue_exclusive_locked(&sem->wait, &wait);

        sem->sleepers++;
        for (;;) {
                int sleepers = sem->sleepers;
                if (!atomic_add_negative(sleepers - 1, &sem->count)) {
                        sem->sleepers = 0;
                        break;
                }
                sem->sleepers = 1;      /* us - see -1 above */
                spin_unlock_irqrestore(&sem->wait.lock, flags);
```

Linux: semafoare (2)

```
            schedule();

            spin_lock_irqsave(&sem->wait.lock, flags);
            tsk->state = TASK_UNINTERRUPTIBLE;
        }

        remove_wait_queue_locked(&sem->wait, &wait);
        wake_up_locked(&sem->wait);
        spin_unlock_irqrestore(&sem->wait.lock, flags);

        tsk->state = TASK_RUNNING;
}
```

Scalabilitate

- Primitivele de sincronizarea serializează codul
- Scalabilitatea sistemului este dată de cât de fină este serializarea
  - De exemplu, în Linux 2.0 tot kernelul era protejat de un singur lock
- Chiar dacă granularitatea locking-ului este fină, în anumite workload-uri poate apărea contention
- Chiar şi operațiile atomice pot cauza probleme de performanța (cache trashing)

RW spinlocks/semafoare

- Două tipuri de lock-uri: pentru readeri şi pentru writeri
- Într-o zonă critică pot intra oricât de mulți readeri dar un singur writer
- Reduce contention-ul dacă majoritatea operațiilor efectuate sunt de read

Per-cpu data

- Metoda ideală de „sincronizare”
- Datele se țin distribuit, per procesor
- Nu avem nevoie de sincronizare
- Nu există contention, creşte scalabilitatea
- Scade probabilitatea de cache trashing
- Abordare hibridă: folosirea per-cpu-data most of the time cu agregarea per-cpu-data some of the time

Bariere

- Procesoarele si/sau compilatoarele pot genera cod out of order
- Exemplu:

```
a=1;
b=2;
```

```
MOV R10, 1
MOV R11, 2
STORE R11, b
STORE R10, a
```

Bariere (2)

- Barierele forțează compilatorul şi procesorul să ordoneze operațiile de citire / scriere
- Read memory barrier – operațiile de citire nu sunt reordonate „peste” barieră
- Write memory barrier – operațiile de scriere nu sunt reordonate „peste” barieră

RCU

- Read-Copy-Update
- Acces read-only fără locking la structuri modificate concurent
- Nu necesită lock-uri sau instrucțiuni atomice
- Este folosit de obicei cu structurile de date înlănțuite (liste, cozi) traversate unidirecțional cu operații dese de citire (read-mostly)

RCU (2)

- Actualizările (modificările) se împart în două faze
  - eliminare (removal)
  - reclamarea spațiului eliberat (reclamation)
- Faza de eliminare are loc imediat
- Faza de reclamare este amânată până când toți cititorii prezenți în faza de eliminare şi-au încheiat activitatea
  - se înregistrează o funcție tip callback

RCU (3)

- eliminare
  - eliminarea tuturor referințelor către structura curentă
  - referințele pot fi înlocuite cu referințe către o versiune nouă a structurii (elementul următor dintr-o listă)
  - cititorii care refereau structura vor lucra în continuare pe această versiune
  - noii cititori vor referi structura nouă
- reclamare
  - eliberarea spațiului ocupat de structura eliminată
  - începe doar după ce nu mai există cititori cu referință la structură

Ştergerea unui element dintr-o listă înlănţuită

(1) – parcurgere,

(2) – eliminare (B este încă referit)

(3) – nu se mai referă

(4) – eliminare efectivă

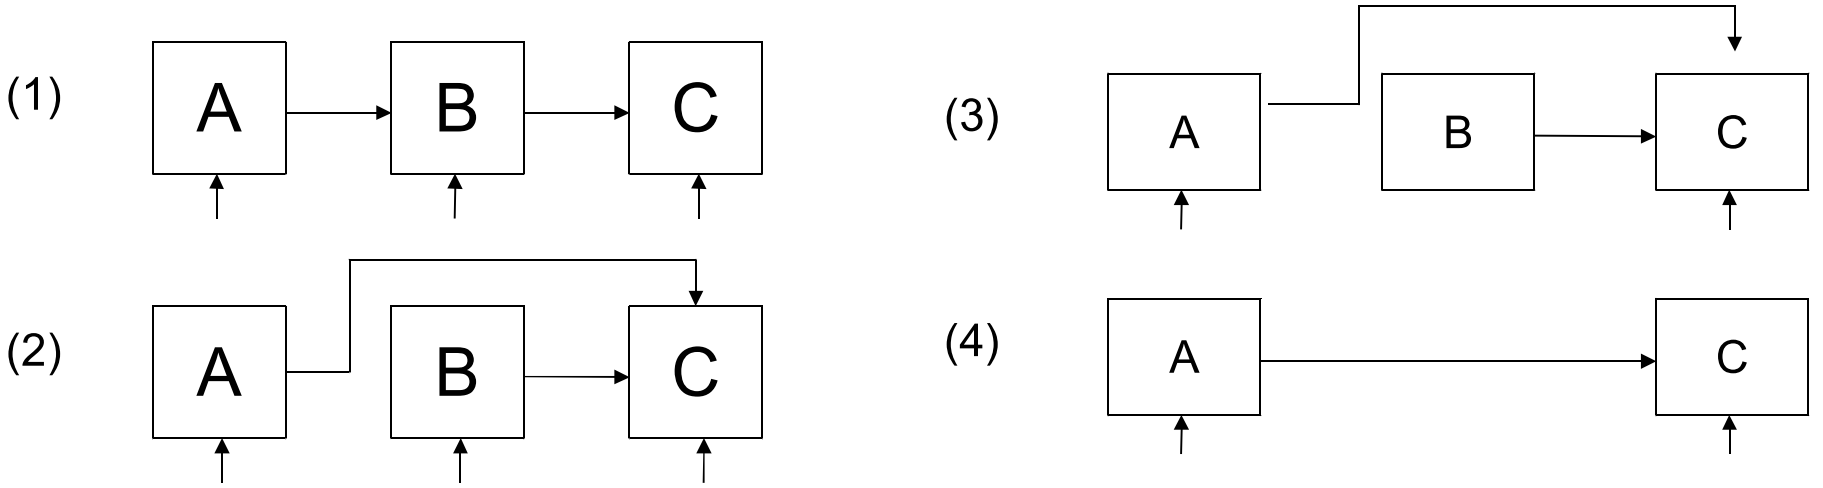

Constrângeri RCU

- pentru o regiune critică RCU costrângerile sunt asemănătoare cu cele pentru utilizarea unui spinlock
  - nu se poate realiza schimbare de context (nu se poate dormi, nu se poate folosi un lock blocant, etc.)
- dacă pe un procesor se realizează o schimbare de context, procesul asociat nu mai deține nici o referință la un element eliminat -> se poate reclama
- aşteptarea tuturor cititorilor (pasul 2 din secvența tipică) înseamnă rularea pe fiecare procesor până la o schimbare de context

Intrebări

?