Coherencia de caché

Problema de la coherencia de caché

- Un procesador multicore tiene varios procesadores en un mismo chip.
- Los procesadores tienen su propio caché pero comparten la memoria principal.
- Es posible que dos procesadores diferentes tengan en sus cachés dos valores diferentes de la misma dirección.
- A esto se le llama **problema de coherencia de caché**.

Intel Core i7

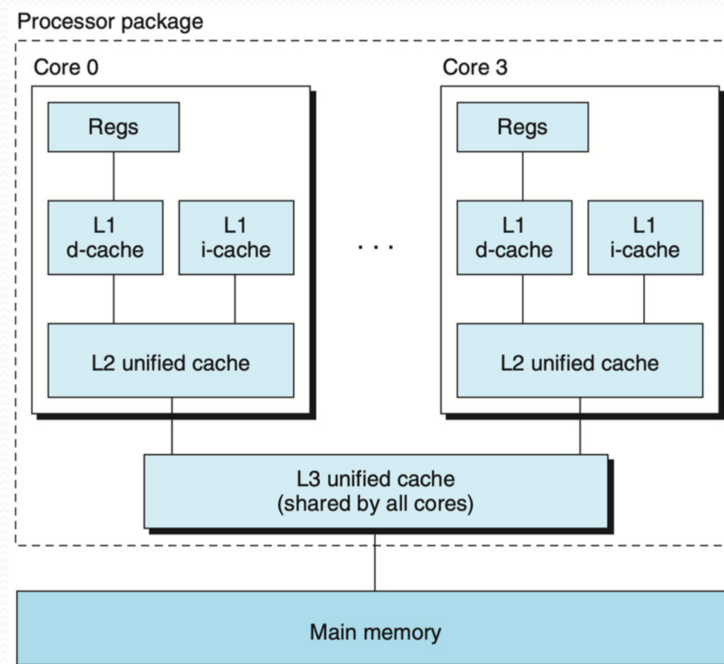

Fuente: CS-APP, p. 668

Problema de la coherencia de caché

Time step	Event	Cache contents for CPU A	Cache contents for CPU B	Memory contents for location X
0				0
1	CPU A reads X	0		0
2	CPU B reads X	0	0	0
3	CPU A stores 1 into X	1	0	1

- Si B lee de nuevo el valor de X va a recibir 0.

Definición informal de coherencia

- Un sistema de memoria es coherente si cualquier lectura de un dato devuelve el valor escrito más reciente de ese dato.

Memoria compartida

- Hay dos aspectos que son críticos para escribir correctamente programas con memoria compartida.
- **Coherencia**. *Qué valores* pueden ser regresados por una lectura.
- **Consistencia**. *Cuándo* un valor escrito va a ser regresado por una lectura.

Coherencia

- Definición formal:
- P escribe X; P lee X (sin escrituras intermedias) la lectura devuelve el valor escrito.
- P1 escribe X; P2 lee X (suficientemente más tarde) la lectura devuelve el valor escrito por P1.
- P1 escribe X, P2 escribe X, todos los procesadores ven las escrituras en el mismo orden. Todos terminan con el mismo valor final para X.

Protocolo de invalidación de escritura

- Es un método para hacer cumplir la coherencia.
- Al ocurrir una escritura se invalidan todas las copias en los cachés.

Processor activity	Bus activity	Contents of CPU A's cache	Contents of CPU B's cache	Contents of memory location X
				0
CPU A reads X	Cache miss for X	0		0
CPU B reads X	Cache miss for X	0	0	0
CPU A writes a 1 to X	Invalidation for X	1		0
CPU B reads X	Cache miss for X	1	1	1

Protocolo de invalidación de escritura

- ¿Qué sucede si dos procesadores intentan escribir el mismo dato simultaneamente?
- Uno de ellos gana y al otro se le invalida su copia.
- El otro procesador tiene que volver a leer el dato antes de escribirlo.
- A esto se le llama tener *acceso exclusivo* al dato.

Ejemplo

- Suponer lo siguiente:
- X vale 0 en la memoria.
- Las CPUs P1 y P2 tienen una copia de X = 0 en sus caches.
- P1 quiere incrementar a X en 1 y al mismo tiempo P2 quiere incrementar a X en 2.
- Si P2 gana, X se actualiza a 2 y se invalida la copia de X en P1.
- Esto obliga a P1 a volver a leer el valor de X y ahora lee X = 2.
- P1 actualiza X a 3 y ahora se invalida la copia de X en P2.

Problema de la consistencia

- ¿Cuánto tiempo debe pasar para un valor escrito pueda ser regresado por una lectura?
- Para garantizar la consistencia, una escritura no se completa (ni se permite que ocurra la siguiente escritura) hasta que todos los procesadores hayan visto el efecto de esa escritura.
- Las lecturas se pueden reordenar, pero las escrituras se terminan en orden del programa.

Ejemplo en Java

- Hacer un programa que cree un hilo.

Solución

```
public static void main(String[] args)
{
    Runnable runnable = () -> {
        for (int i = 0; i < 10; i++) {
            System.out.println("Saludos " + i +
            " de: " + Thread.currentThread().getName());
        }
    };
    Thread thread = new Thread(runnable);
    thread.start();
}
```

Detener un hilo

- Suponer que se desea detener el hilo después de 1 segundo.
- El método Thread.stop() es obsoleto (deprecated) por ser inseguro.
- Ver https://docs.oracle.com/en/java/javase/16/docs/api/java.base/java/lang/doc-files/threadPrimitiveDeprecation.html
- Una forma de detener un hilo es mediante una variable que sea revisada en el método run().

Esto no debe funcionar

```
// Broken! - How long would you expect this program to run?
public class StopThread {
    private static boolean stopRequested = false;
    public static void main(String[] args) throws InterruptedException {
        Runnable runnable = () -> {
            int i = 0;
            while (!stopRequested) {
                i++;
            }};
```

Esto no debe funcionar

```
        Thread thread = new Thread(runnable);
        thread.start();
        TimeUnit.SECONDS.sleep(1);     // 1 second
        stopRequested = true;
    }
}
```

Explicación

- Explicación de *Effective Java, 3rd edition* por Joshua Bloch, p. 313.
- El problema es que, en ausencia de sincronización, no hay garantía de cuándo, si es que alguna vez, el hilo en segundo plano verá el cambio en el valor de stopRequested realizado por el hilo principal.
- Una solución es usar el keyword volatile.

Keyword volatile

- El keyword volatile garantiza que cualquier hilo que lea una variable verá el último valor escrito.
- volatile asegura dos cosas:

1. Cada vez que se actualice la variable, se escribe en la memoria principal.
2. Cada vez que se lea la variable, se lee de la memoria principal.

- Si solo un hilo actualiza la variable y los demás solo leen el valor, volatile es suficiente.

Solución con volatile

```
// Cooperative thread termination with a volatile field
public class StopThread {
    private static volatile boolean stopRequested;
    public static void main(String[] args) throws InterruptedException {
    Runnable runnable = () -> {
        int i = 0;
        while (!stopRequested) {
            i++;
        }};
```

Solución con volatile

```
        Thread thread = new Thread(runnable);
        thread.start();
        TimeUnit.SECONDS.sleep(1);    // 1 second
        stopRequested = true;
    }
}
```