30. Vlákna, jejich atributy, metody, organizace a stavy. Možnosti synchronizace. (A7B36PVJ)

Procesy a vlákna

Proces

Každá aplikace je vlastně běžící proces. Pokud je aplikace spuštěna vícekrát, vytvoří se více procesů (instancí programu). Jeho vytvoření je vcelku náročné a má nezanedbatelnou režii.

Stav procesu zahrnuje přidělené místo v paměťi, zásobník, proces ID (PID), proces group ID, user ID, group ID, environment, pracovní adresář, heap, descriptory souborů, sdílené knihovny, atd.

Procesy nemohou přistupovat do paměti jiných procesů, ale mohou si navzájem data posílat.

Vlákno

Každý proces má alespoň jedno vlákno. Oproti procesu má o mnoho nižší režii při vytváření (až o několik řádů). Vlákna sdílejí zdroje procesu (především paměťový prostor), který je vytvořil. Mohou tedy přistupovat ke stejným datům současně. Každé vlákno má vlastní zásobník, plánovací vlastnosti (prioritu), identifikační ID. Každé vlákno je zodpovědné za správný přístup ke sdíleným zdrojům v rámci procesu (např. paměti).

Vlákna

Vlákna slouží pro souběžné provádění více částí jediného programu. Jejich použití je někdy nezbytné, např. u serverového programu, který musí komunikovat s více klienty. Na jednoprocesorovém počítači v jednu chvíli samozřejmě nemůže běžet více než jeden výpočet, můžou se ale časově překrývat I/O operace se zpracováním (např. práce se soubory, databází apod.). Dále lze např. vlákna použít v animacích, kdy je kód provádějící vykreslování řízen časovačem, aby se prováděl např. 20krát za sekundu. Pokud má běžet v jednu chvíli více animací, potom každá běží ve svém vlastním vláknu.

Příklad:

Program, který dělá tři aktivity:

1. Čte nějaké bloky dat ze souboru.
2. Provádí nějaké výpočty s každým blokem z těchto dat.
3. Zapisuje výsledek výpočtu do dalšího souboru.

Pokud by provádění probíhalo postupně 1-2-3-1-2-3 atd., tak by celkový čas provádění byl jednoduše součet časů všech jednotlivých kroků. Rozdělením programu na tři samostatná vlákna jsme schopni dosáhnout rychlejšího dokončení úlohy. Čtení ze souboru a zápis do souboru jsou časově náročné operace a velmi málo zatěžují CPU. Tento volný čas CPU je vhodné využít, např. pro provádění výpočtu ve chvíli, kdy dochází k I/O operaci.

Vytvoření vláken

Každý program v Javě má alespoň jedno vlákno. To je vytvořené při spuštění programu a začíná od metody main(). U apletu je hlavním vláknem prohlížeč. Když náš program vytvoří vlákno, je toto vlákno vytvořené navíc k vláknu, které jej vytvořilo

Nové vlákno se spustí metodou **start()** objektu typu Thread. Kód, který se v novém vláknu provádí, je vždy public metoda zvaná **run().** Aby vlákno něco dělalo je tedy třeba metodu run() implementovat. V těle této metody lze volat jakékoli jiné metody. Metoda run() se nevolá přímo, ale používá se již zmíněná metoda start(). Tím se vlákno dostane do stavu runnable, tzn. že je připraveno k běhu. Běžet začne až ve chvíli, kdy operační systém vybere nějaké vlákno ve stavu runnable a začne ho provádět. Pokud je nějaké vlákno prováděno má stav running. K zastavení vlákna stačí ukončit metodu run().

V praxi se pak použije např. kód:

```
private boolean stop = false;
public void stop()
 {
            stop = true;
}

public void run()
{
          while (!stop)
          {
             // kod provadejici se za behu vlakna
          }
}
```

While cyklus běží ve smyčce, dokud není zavolaná metoda stop(), která nastaví proměnou stop na true a tak se while cyklus ukončí a metoda run() skončí. Vlákno je doběhnutím metody run() ukončeno a dostane se do stavu dead.

Spouštění vláken je řízeno operačním systémem. Pokud by se metoda run() zavolala přímo, tak by se chovala jako jakákoli jiná metoda a běžela by ve stejném vláknu jako program, který ji zavolal.

Třídu, která bude představovat vlákno lze definovat dvěma způsoby. Buď nová třída bude podtřídou třídy Thread (Vlakno extends Thread) nebo bude implementovat rozhraní Runnable (Vlakno implements Runnable).

V prvním případě se pak nové vlákno spustí např. takto:

```
Thread vlakno1 = new Vlakno();
vlakno1.start();
```

Druhá možnost je většinou lepší, než odvozování od Thread. Třidu v Javě lze odvodit (extends) pouze od jediné třídy. Pokud se implementuje rozhraní Runnable, může třída vlákna stále odvozovat od třídy, kterou potřebujeme. V podstatě jsou si obě varianty velice podobné, protože samotná třída Thread již toto rozhraní implementuje.

Spuštění vlákna Vlakno implementujici Runnable

```
Thread vlakno1 = new Thread(new Vlakno());
vlakno1.start();
```

Atributy vláken

Jméno vlákna

Každé vlákno má implicitní jméno sestávající z řetězce „Thread*“, kde na konci je pořadové číslo. Konstruktor typu Thread umožňuje vlákno pojmenovat svým názvem. Tento název se použije jen při zobrazování informací o vláknu nebo při zavolání metody getName() a nemá žádný vztah k identifikátoru typu Thread. Explicitní pojmenování vláken se hodí například při debugování a logování.

Priority vláken

Všechna vlákna mají nějakou prioritu, která určuje, které z vláken bude prováděno, pokud jich několik čeká, až na ně dojde řada. To umožňuje dát jednomu vláknu více přístupu ke zdroji procesoru než druhému. Například, když existuje více vláken a jedno z nich provádí náročný výpočet, tak je možné mu dát menší prioritu, aby méně zatěžoval procesor a ostatní vlákna měla větší prostor k provádění.

Možné hodnoty priority vláken jsou definovány ve statických datových členech třídy Thread. Jsou typu int a jsou deklarovány jako final. Maxim. hodnota je definována členem MAX_PRIORITY, který má hodnotu 10. Minimální priorita je MIN_PRIORITY, která je 0. Když se vytvoří nějaké vlákno, jeho priorita bude stejná jako priorita vlákna, které ho vytvořilo. Hlavní vlákno main() má prioritu 5.

Prioritu lze měnit metodou setPriority() a zjistit se dá metodou getPriority().

Vlákno démona a vlákno uživatele

Metoda setDaemon(boolean b) třídy Thread nastavuje vlákno jako vlákno démona. Musí být zavolána před spuštěním vlákna. Vlákno démona je prosté vlákno v pozadí a je podřízené vláknu, které ho vytvořilo, takže když vlákno, které vytvořilo vlákno démona skončí, zanikne toto vlákno démona také.

Vlákno, které není vlákno démonů, se nazývá vlákno uživatele. Vlákno uživatele není závislé na vláknu, které jej vytvořilo. Implicitní vlákno, které obsahuje metodu main(), je uživatelské vlákno a jiná další uživ. vlákna běží i po skončení metody main().

Metody

sleep()

Metoda sleep() objektu Thread slouží k pozdržení provádění vlákna na počet milisekund, které jsou zadány v argumentu. Když je vlákno pozdrženo, dostanou prostor k provádění jiná vlákna. Jaké vlákno dostane prostor, resp. jaké z čekajících vláken se začne provádět, záleží na časovém plánovači JVM, takže se může stroj od stroje lišit.

interrupt()

Vlákno může signalizovat jinému vláknu, aby zastavilo provádění, voláním metody interrupt() objektu typu Thread. To samo o sobě příslušné vlákno nezastaví, jen mu nastaví příznak tak, aby ukazoval na požadavek na přerušení. Aby tento příznak měl nějaký smysl, tak musí být kontrolován. To zajišťuje např. metoda sleep(), která kontroluje, jestli byl požadavek na přerušení nastaven, a pokud ano, tak vyvolá výjimku **InterruptedException**. Tuto kontrolu provádí i např. metoda wait(). Tuto kontrolu lze provést i ručně voláním metody isInterrupted() pro odpovídající vlákno. To vrací true, pokud byla metoda interrupt() na tomto vlákně volána. Vyvoláním výjimky InterruptedException se zruší požadavek na přerušení a metoda isInterrupted() vrací false.

isAlive()

Protože samotným voláním metody interrupt() nedojde k ukončení běhu vlákna, lze jeho ukončení zjistit voláním metody isAlive(). To vrací true, pokud vlákno běží.

join()

Pokud je potřeba v jednom vlákně čekat, až zanikne (doběhne) nějaké jiné vlákno, tak lze použít metodu join() pro vlákno, které má zaniknout. Volání join() bez argumentu zadrží aktuální vlákno na tak dlouho, dokud určené vlákno nezanikne.

```
vlakno1.join();  // Zadrzi aktualni vlakno, dokud nezanikne vlakno1
```

Metodě join() lze předat hodnotu typu long, která určí počet milisekund, jak maximálně dlouho se má čekat na zánik vlákna.

```
vlakno1.join(1000);
```

yield()

Tato metoda umožňuje provádění jiným vláknům. Použije se, pokud chceme povolit běh jiným vláknům, pokud čekají, ale nechceme pozastavit provádění aktuálního vlákna na určitý časový interval. Zavoláním metody sleep() se vlákno pozastaví na určenou dobu, i když žádná ostatní vlákna nečekají. Implementace této metody se liší v závislosti na verzi Javy a systému. V některých situacích bývá implementována pomocí sleep(0).

Možnosti synchronizace

JVM scheduler přiděluje CPU čas nespecifikovaným způsobem některému vláknu ve stavu runnable s nejvyšší prioritou. Vlákna se tedy vykonávají v náhodném pořadí. V určitých situacích (např. při přístupu ke sdílené paměti) je však potřeba vykonávání vláken řídit, abychom zamezili chybám, které jinak mohou nastat (deadlock, race condition – viz níže).

Běh vlákna může být na nějakou dobu přerušen kdykoli během jeho provádění. Pak se může stát, že nějaká data, se kterými jsme pracovali, se mohla změnit vlivem jiného vlákna. Protože my o tom nevíme, pracujeme pak nad neplatnými daty. To samozřejmě může způsobit velmi vážné problémy.

Například se může stát něco takového:

1. Úředník zkontroluje stav účtu zákazníka, který je 500 Kč.
2. Zákazník si ve stejnou dobu vybírá z bankomatu. Bankomat si také zjistí stav účtu.
3. Úředník připíše částku 100 na účet a navýší ho na 600 Kč.
4. Z bankomatu se vybere 100 Kč, takže změní účet na 400 Kč.
5. Úředník zapíše stav účtu na 600 Kč.
6. Bankomat zapíše stav účtu na 400 Kč.

Každý bod představuje nějakou dobu běhu vlákna Úředník nebo vlákna Bankomat. Problém je zřejmý. Dotaz na aktuální stav a zápis nového stavu účtu jsou dvě rozdílné operace. Dokud tomu tak je, nelze zaručit, že k uvedenému problému nedojde.

Proto je třeba pro sdílené zdroje (zde to byl účet), ke kterým má přístup více vláken, zavést opatření, aby jiné vlákno neměnilo zdroj, během doby, co se zdrojem pracuje aktuální vlákno. K tomu slouží synchronizace vláken.

Synchronizace

Synchronizace řeší, aby v případě, že několik vláken přistupuje k jednomu zdroji, byl tento přístup bezpečný. Obvykle musíme zařídit, aby pouze jedno vlákno mělo přistup ke zdroji pro zápis i čtení. Existují ale i situace, kdy stačí omezit přístup pouze během zápisu. Samotná synchronizace bývá implementována operačním systémem. V programování existuje mnoho prostředků k dosažení synchronizace. Mezi jedny z nejvíce používaných patří monitor, semafor, reader-writer lock, mutex, synchronizační události atd..

Monitor

Java tento typ synchronizace implementuje pomocí klíčového slova synchronized.

Synchronizaci lze provést dvěma způsoby:

1. synchronizovat metody
2. synchronizovat bloky kódu

Synchronizování metod

Jakékoli metody nějakého objektu lze nastavit tak, aby v daném časovém bodu mohla běžet jen jedna z nich. Toho se dosáhne použitím klíčového slova synchronized.

```
public synchronized void metoda1() {
}

public synchronized void metoda2() {
}
```

Synchronizace bloků kódu

Možnosti synchronizace bloku kódu nebo příkazu jsou mnohem větší, protože lze nejenom přesněji určit důležitou část, která vyžaduje synchronizaci (čím menší část kódu je synchronizována, tím méně dochází k blokování ostatních vláken), ale lze také určit objekt, který se má k synchronizaci použit. Synchronizovaný blok tedy můžeme uzamknout pomocí zámku, kteréhokoli objektu. Tím je zajištěno, že žádný jiný blok nebo metoda, synchronizované zámkem stejného objektu se nemůžou provádět.

```
synchronized(nejakyObjekt) {
  // synchr. blok
}
```

Velkým používáním synchronized bloků nebo metod je program značně omezován, protože jsou ostatní vlákna nucena čekat. Mělo by se tedy používat jen v nezbytné míře.

Reentrant synchronization

Vlákno nemůže získat zámek, který vlastní jiný vlákno. Může ale získat zámek, který již vlastní. Tomuto se říká "reentrant synchronization".

Semafor

Omezuje počet vláken, které smí přistupovat ke zdroji. V Javě je tento typ implementován ve třídě java.util.concurrent.Semaphore.

ReaderWriter lock

Umožňuje konkuretní čtení a exkluzivní zápis (v daný okamžík smí více vláken číst, ale pouze jedno vlákno zapisovat). V Javě lze použít například java.util.concurrent.locks.ReentrantReadWriteLock.

Mutex

Tento typ není v Javě přímo zastoupen. Ve Windows API jej lze vytvořit například pomocí funkce CreateMutex. V C# je reprezentován třídou System.Threading.Mutex.

Mutex zabraňuje více vláknum současně přistupovat ke zdroji. Ve skutečnosti je Mutex zkratkou pro "mutually exclusive". Na rozdíl od monitoru lze využít k synchronizaci napříč více procesy.

Atomicita

Atomicita operace neboli nedělitelnost znamená, že daná činnost (operace) se provede najednou. Nemůže tedy být přerušena nějakou jinou operací a později dokončena. V Javě je zajištěna atomicita zápisu a čtení 32-bitových či menších proměnných. Proto operace s long a double nejsou atomické.

V následujícím kódu Java zajišťuje atomicitu přiřazení b = a;:

```
int a = 5;
int b;
b = a;
```

Pozor, celý blok není atomický! Atomické jsou pouze jednotlivé operace.

Následná ukázka inkrementace a++; však již atomickou operací není. Inkrementace se skládá ze tří operací – přečtení hodnoty proměnné a, inkrementace o jedna a zápisu zpět do proměnné a.

```
int a = 5;
a++;
```

Pro zajištění atomicity proměnných a polí lze využít klíčového slova volatile nebo balíček java.util.concurrent.atomic, který obsahuje třídy AtomicBoolean, AtomicLong, AtomicIntegerArray apod. Každá z těchto tříd poskytuje běžné operace, u kterých je zajištěna jejich atomicita.

Komunikace mezi vlákny

Komunikace mezi vlákny je jednou z dalších možností synchronizace. Tímto způsobem obvykle řešíme situace, kdy jedno vlákno musí čekat, dokud jiné vlákno něco nedopočítá, aby mohlo pokračovat.

Používat cyklus čekání

```
while(!somethingDone)
{
    sleep(someAmountOfTime)
}
```

je neefektivní. Jsou efektivnější způsoby. Třída **Object** definuje metody **wait()**, **notify(), notifyAll()**. Tyto metody lze volat pouze zevnitř synchronizovaných metod nebo bloků. Pokud jsou zavolány odjinud, bude vyvolána výjimka **IllegalMonitorStateException**.

wait()

Existují tři přetížené verze této metody. Tato metoda pozastaví aktuální vlákno až do volání metody notify() nebo notifyAll() pro objekt, ke kterému patří zmíněná metoda wait(). Když se zavolá jakákoli verze metody wait(), vlákno uvolní synchronizační zámek, který má na objektu, takže se může provádět jakákoli jiná metoda nebo blok kódu, které jsou synchronizovány stejným objektem. Umožní se tak nejen volání metod notify() nebo notifyAll() jiným vláknem, ale jiné vlákno může také volat wait() pro tentýž objekt. Wait() může volat InteruptedException, musí být tedy v bloku try-catch.

wait(long timeMs)

Pozastaví vlákno, dokud neuplyne počet milisekund v argumentu nebo pokud není dříve volána metoda notify() nebo notifyAll() objektu, ke kterému wait() patří.

wait(long timeMs, int nano)

Funguje stejně jako předešlá metoda. Navíc umožňuje určit čas v nanosekundách.

notify()

Tímto se znovu spustí vlákno, které volalo metodu wait() objektu, kterému patří metoda notify(). Pokud pro tento objekt volalo wait() více objektů, není žádná kontrola nad tím, kterému z těchto vláken bude notify() určeno, a v takovém případě bude lepší použít notifyAll(). Pokud neexistují žádná čekající vlákna, metoda nedělá nic.

Jak to funguje

Jeden blok může volat wait() k pozastavení svých operací, dokud nějaká jiná metoda nebo blok kódu, synchronizovaný stejným objektem, jej nějakým způsobem nezmění a nezavolá notify(), čímž naznačí

dokončení změny. Typicky bude wait() vláknem voláno, protože není nastavena nějaká vlastnost objektu, kterým je toto vlákno synchronizováno, nebo není splněna nějaká podmínka závisející na akci nějakého jiného vlákna.

Hlavním rozdílem mezi sleep() a wait() je, že wait() uvolňuje všechny objekty, které jsou aktuálním vláknem uzamknuty, zatímco sleep() tak nečiní. Navíc u sleep specifikuje přesně, jak dlouho budeme čekat.

Pokud existují více než dvě vlákna synchronizovaná jedním objektem, je obecně lepší používat metodu notifyAll(). Kdyby se volalo jen notify(), tak je otevřena možnost, že vlákno, které bylo spuštěno, zavolá opět wait() a tak budou všechna vlákna čekat jedno na druhé bez možnosti dalšího pokračování.

Alternativou k wait a notify je tzv. "busy waiting". Thread může přejít do stavu čekání pouze, pokud zavolá do kernelu. Přechod z user mode do kernel mode je časově náročná operace. Pokud tedy víme, že budeme čekat menší dobu, než je čas potřebný na tento přechod, vyplatí se počkat.

Stavy vláken

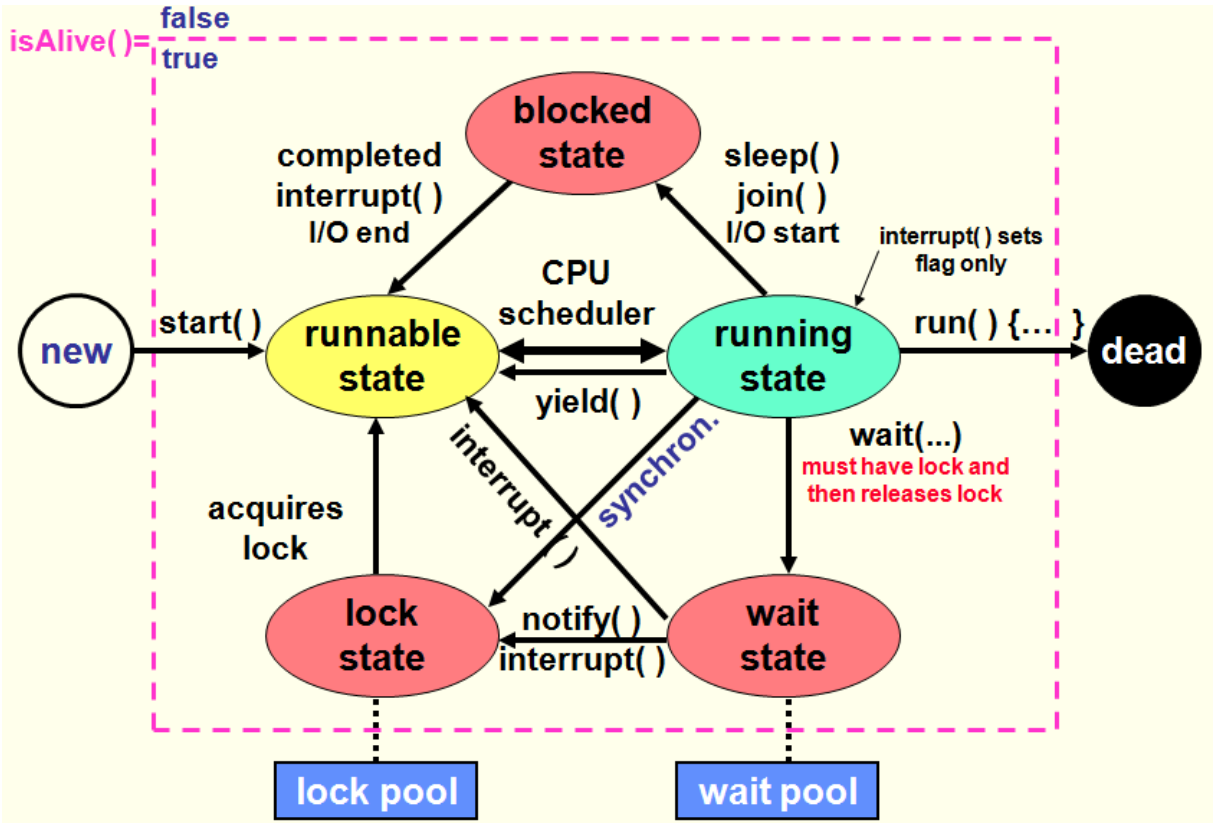

Vlákno si musí dynamicky pamatovat:

- v které metodě se právě nalézá a kam se pak vrátit
- své lokální proměnné
- adresu aktuálního příkazu v aktuální metodě

Chyby v synchronizaci

Při špatném použití synchronizace může dojít k tzv. deadlocku nebo race condition.

Deadlock (uváznutí)

Deadlock je situace, když dvě (nebo více vláken) uvázne a žádné nemůže pokračovat, protože navzájem čekají až to druhé (nebo ta ostatní) uvolní zámky na společně synchronizovaném objektu.

Viz příklad:

Dva chudí lešetínští kováři v mají jedno společné nářadí: kladivo a kleště. Nedohodnou-li se, dojde časem k zlobně umrtvujícímu nicnedělání, tzv. deadlocku čili smrtelnému zaklesnutí.

Přihodí se to takto:

1. První uchopil kladivo a potřebuje ještě kleště.
2. Mezitím však druhý uchopil kleště a čeká až bude kladivo volné.
3. Nikdo to za ně nevyřeší a tak oba čekají a čekají … čímž živnosti uvíznou

Přitom stačí rozumná dohoda - budeš-li potřebovat oba nástroje:

1. Nejdříve uchop kladivo a teprve pak sháněj kleště.
2. Pracuj.
3. Pak nejdříve pusť kleště, potom kladivo.

Ta zaručuje momentálnímu držiteli kladiva, že kleště budou časem volné. Kovářů může být ve městě i více.

Přepsaným řešením je:

```
synchronized ( kladivo ) {
  synchronized ( kleste ) {
    //  work
  }
}
```

Deadlock je vážný problém a u složitých programů je velmi složité zajistit, aby k jeho docházení nedocházelo, proto je důležitý správný návrh aplikace.

Race condition (souběh)

Race condition (souběh) je situace, kdy při přístupu dvou nebo více vláken/procesů ke sdíleným datům (soubor nebo proměnná) dojde k chybě, přestože každé z vláken/procesů se samostatně chová korektně.

Problémy se souběhem mohou být rozděleny do dvou kategorií:

Zásah, který byl způsoben důvěryhodným procesem či vláknem, tj. procesem či vláknem, které je součástí naší aplikace.

Zásah, který byl způsoben nedůvěryhodným procesem, tj. procesem který není součástí naší aplikace. Tímto procesem může být např. jiná aplikace zapisující do stejného souboru nebo útočný program, který chce souběh vyvolat.

Chybné chování je způsobeno kritickou závislostí na relativním načasování událostí v jednotlivých procesech. Data jsou modifikována některým procesem v době, kdy s nimi jiný proces provádí několik operací, o kterých se předpokládalo, že budou provedeny jako jeden nedělitelný celek – atomicky.