Vícevláknové aplikace

Jan Faigl

Katedra počítačů
Fakulta elektrotechnická
České vysoké učení technické v Praze

Přednáška 5

A0B36PR2 – Programování 2

Část 1 – Paralelní programování

Paralelismus a operační systém
- Proces a stavy procesu
- Víceprocesorové systémy

Synchronizace výpočetních toků

Část 2 – Vícevláknové aplikace

Vlákna - terminologie, použití

Vícevláknové aplikace v operačním systému

Vlákna v Javě

Část 3 – Modely vícevláknových aplikací

Modely více-vláknových aplikací

Prostředky ladění

Část I

Část 1 – Paralelní programování

Paralelní programování

Idea pochází z 60-tých let spolu s prvními multiprogramovými a pseudoparalelními systémy.

- Můžeme rozlišit dva případy paralelismu:
  - hardwarový,
  - softwarový - pseudoparalelismus.

I programy s paralelními konstrukcemi mohou běžet v pseudoparalelním prostředí a to i na víceprocesorovém výpočetním systému.

Motivace

„Proč se vůbec paralelním programováním zabývat?"

- Navýšení výpočetního výkonu.
  Paralelním výpočtem nalezneme řešení rychleji.
- Efektivní využívání strojového času.
  Program sice běží, ale čeká na data.
- Zpracování více požadavků najednou.
  Například obsluha více klientů v architektuře klient/server.

Základní výpočetní jednotkou je proces – „program"

Proces

Proces je spuštěný program ve vyhrazeném prostoru paměti. Jedná se o entitu operačního systému, která je plánována pro nezávislé provádění.
Stavy procesu:

- **Executing** - právě běžící na procesoru.
- **Blocked** - čekající na periferie.
- **Waiting** - čekající na procesor.

Proces je identifikován v systému identifikačním číslem PID.
Plánovač procesů řídí efektivní přidělování procesoru procesům na základně jejich vnitřního stavu.

Stavy procesu

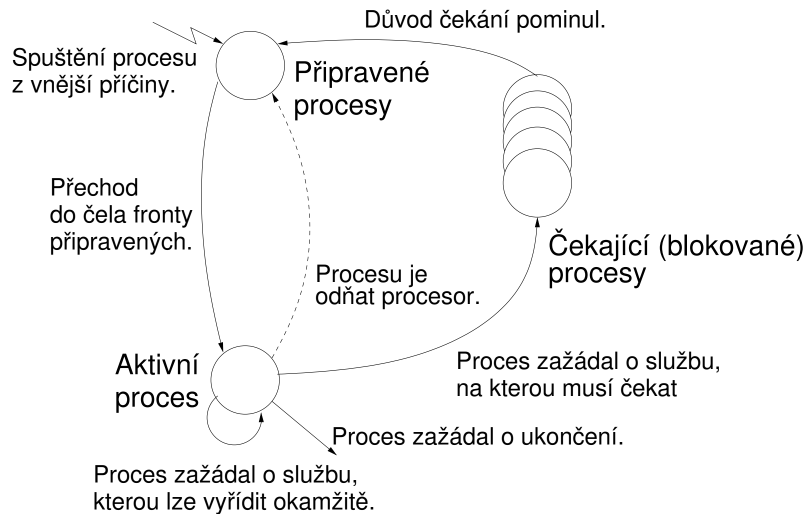

Příklad výpisu procesů

```
TOP
last pid:  1666;  load averages:  2.34,  1.00,  0.56    up 0+00:21:21  20:37:22
87 processes:  1 running, 86 sleeping
CPU: 97.1% user,  1.4% nice,  1.0% system,  0.6% interrupt,  0.0% idle
Mem: 331M Active, 2720M Inact, 714M Wired, 28M Cache, 404M Buf, 23M Free
ARC: 25M Total, 33K MFU, 24M MRU, 48K Anon, 112K Header, 720K Other
Swap: 2048M Total, 2444K Used, 2045M Free

  PID USERNAME    THR PRI NICE   SIZE    RES STATE   C   TIME    WCPU COMMAND
 1612 jf           16  52    0  1058M 21156K uwait   1   2:03 184.42% java
  874 root          1  25    0   919M 45892K select  1   0:16   7.96% Xorg
 1569 jf            5  52    5   315M 89640K kqread  0   0:04   1.37% gimp-2.8
 1125 jf            4  20    0   216M 16104K uwait   0   0:06   0.29% mocp
 1664 root          1  22    0 81508K  8684K select  1   0:00   0.29% xterm
 1666 root          1  21    0 21924K  2584K CPU1    1   0:00   0.29% top
 1023 jf            4  20    0   323M 41148K select  0   0:25   0.20% owncloud
  997 jf            1  20    0   183M 29680K select  1   0:01   0.10% openbox
 1095 jf            1  28    0 61508K  7512K select  1   0:56   0.00% mc
 1088 jf            1  25    5 90424K 13896K select  1   0:15   0.00% xpdf
 1014 jf            1  21    0   201M 33888K select  1   0:06   0.00% gkrellm
 1081 jf            1  20    0   109M 19544K select  0   0:02   0.00% urxvt
 1092 jf            1  20    0 23908K  2800K select  1   0:02   0.00% tmux
 1572 jf            1  52    5   193M 33892K select  1   0:01   0.00% script-fu
 1319 jf            2  22    0 58900K 11036K select  0   0:01   0.00% vim
  867 root          1  20    0   110M  8312K wait    0   0:01   0.00% slim
```

V současných operačních systémech typicky běží celá řada procesů v pseudoparalní/paralelním režimu.

Víceprocesorové systémy

- Víceprocesorové (jádrové) systémy umožňují skutečný paralelismus.
- Musí být řešena synchronizace procesorů (výpočetních toků) a jejich vzájemná datová komunikace
  - Prostředky k **synchronizaci** aktivit procesorů.
  - Prostředky pro komunikaci mezi procesory.

Architektury

Řízení vykonávání jednotlivých instrukcí.

- SIMD (single-instruction, multiple-data) - stejné instrukce jsou vykonávány na více datech. Procesory jsou identické a pracují synchronně. *Příkladem může být vykonávání MMX, SEE, 3dnow! instrukcí, „vektorizace".*
- MIMD (multiple-instruction, multiple-data) - procesory pracují nezávisle a asynchronně.

Řízení přístupu k paměti.

- Systémy se sdílenou pamětí - společná centrální paměť.
- Systémy s distribuovanou pamětí - každý procesor má svou paměť.

Informativní

SIMD

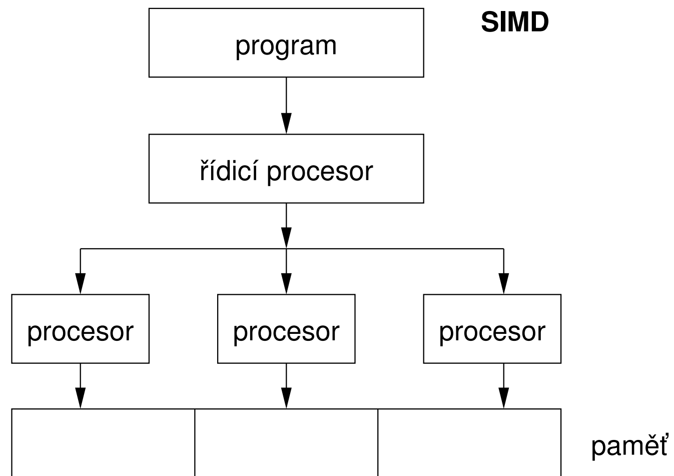

Informativní

MIMD

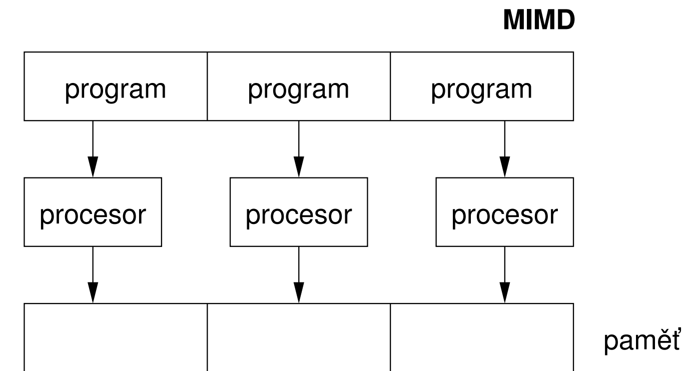

Informativní

Systémy se sdílenou pamětí

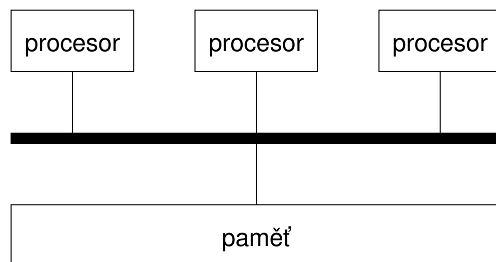

- Procesory komunikují prostřednictvím sdíleného paměťového prostoru.
- Mohou tak také synchronizovat své aktivity → problém exkluzivního přístupu do paměti.

Informativní

Systémy s distribuovanou pamětí

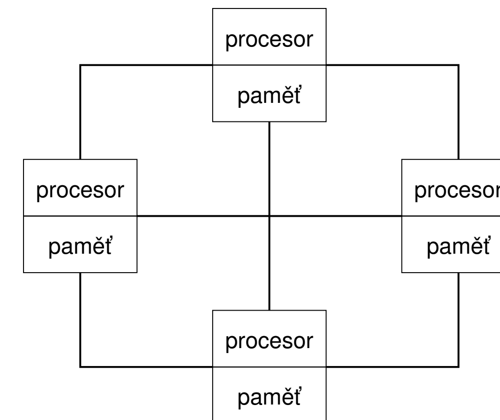

Není problém s exkluzivitou přístupu do paměti, naopak je nutné řešit komunikační problém přímými komunikačními kanály mezi procesory.

Informativní

Úloha operačního systému

- Operační systém integruje a synchronizuje práci procesorů, odděluje uživatele od fyzické architektury.
- Operační systém poskytuje:
  - Prostředky pro tvorbu a rušení procesů.
  - Prostředky pro správu více procesorů a procesů, rozvrhování procesů na procesory.
  - Systém sdílené paměti s mechanismem řízení.
  - Mechanismy mezi-procesní komunikace.
  - Mechanismy synchronizace procesů.
- V rámci spuštěného Java programu plní virtuální stroj **JVM** spolu se základními knihovnami JDK roli operačního systému

  Zapouzdřuje přístup k hw (službám OS)
- To co platí pro procesy na úrovni OS platí analogicky pro samostatné výpočetní toky v rámci **JVM**

  V Javě se jedná o vlákna

Paralelní zpracování a programovací jazyky

- Z pohledu paralelního zpracování lze programovací jazyky rozdělit na dvě skupiny
  1. Jazyky bez explicitní podpory paralelismu
     - Paralelní zpracování ponechat na překladači a operačním systému

       Např. automatická „vektorizace"
     - Paralelní konstrukce explicitně označit pro kompilátor.

       Např. OpenMP
     - Využití služeb operačního systému pro paralelní zpracování.
  2. Jazyky s explicitní podporou paralelismu
     - Nabízejí výrazové prostředky pro vznik nového procesu (výpočetního toku)

Granularita procesů - od paralelismu na úrovni instrukcí až po paralelismus na úrovni programů.

Synchronizace výpočetních toků

- Klíčovým problémem paralelního programování je jak zajistit efektivní sdílení prostředlů a zabránit kolizi
- Je nutné řešení problémů vzniklých z možného paralelního běhu bez ohledu na to zdali se jedná o skutečně paralelní nebo pseudoparalelní prostředí

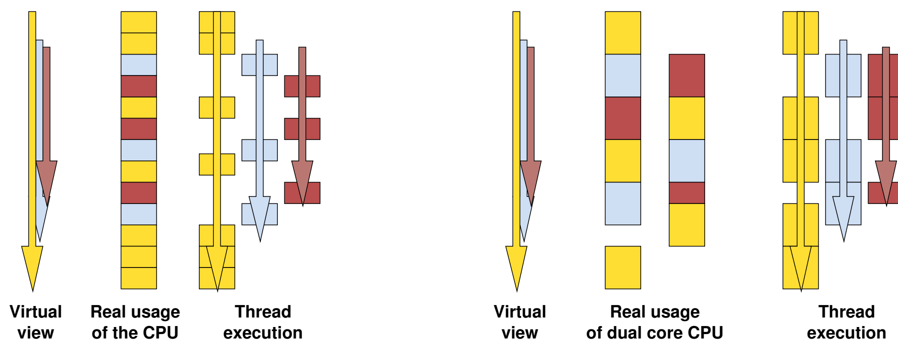

Problém souběhu – příklad

- Současná aktualizace zůstatku na účtě může vést bez exkluzivního přístupu k různým výsledkům

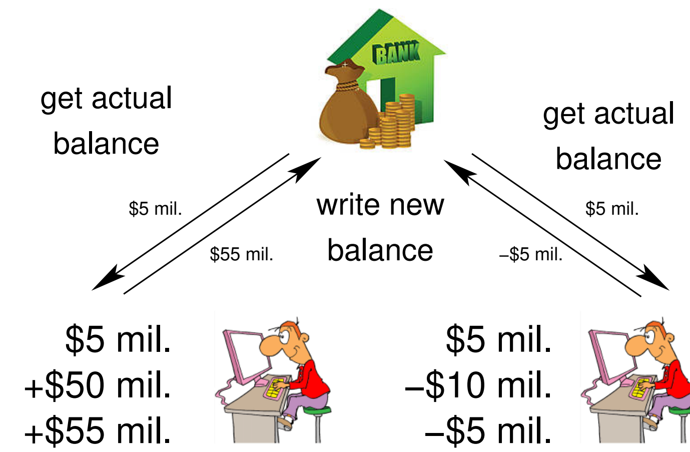

Je nutné zajistit alokování zdrojů a exkluzivní (synchronizovaný) přístup jednotlivých procesů ke sdílenému prostředku (bankovnímu účtu).

Semafory

- Základní prostředkem pro synchronizaci v modelu se sdílenou pamětí je **Semafor** *E. W. Dijkstra*
- Semafor je proměnná typu integer, přístupná operacemi:
  - *InitSem* - inicializace.
  - *Wait* - $\begin{cases} S > 0 - S = S - 1 \\ \text{jinak - pozastavuje činnost volajícího procesu.} \end{cases}$
  - *Signal* - $\begin{cases} \text{probudí nějaký čekající proces pokud existuje} \\ \text{jinak - } S = S + 1. \end{cases}$
- Semafory se používají pro přístup ke sdíleným zdrojům.
  - S $<$ 0 - sdílený prostředek je používán. Proces žádá o přístup a čeká na uvolnění.
  - S $>$ 0 - sdílený prostředek je volný. Proces uvolňuje prostředek.

Implementace semaforů

- Práce se semaforem musí být atomická, procesor nemůže být přerušen.
- Strojová instrukce *TestAndSet* přečte a zapamatuje obsah adresované paměťové lokace a nastaví tuto lokaci na nenulovou hodnotu.
- Během provádění instrukce *TestAndSet* drží procesor sběrnici a přístup do paměti tak není povolen jinému procesoru.

Informativní

Použití semaforů

- Ošetření kritické sekce, tj. části programu vyžadující výhradní přístup ke sdílené paměti (prostředku).

Příklad ošetření kritické sekce semafory

```
InitSem(S,1);
Wait(S);
/* Kód kritické sekce */
Signal(S);
```

- Synchronizace procesů semafory.

Příklad synchronizace procesů

```
/* process p */
...
InitSem(S,0)
Wait(S); ...
exit();
```

```
/* process q */
...
Signal(S); exit();
```

Proces p čeká na ukončení procesu q.

Informativní

Monitory

- Monitor - jazyková konstrukce zapouzdřující data a operace nad daty s exkluzivním přístupem.
- Přístup k funkcím v monitoru má v daném okamžiku pouze jediný proces.

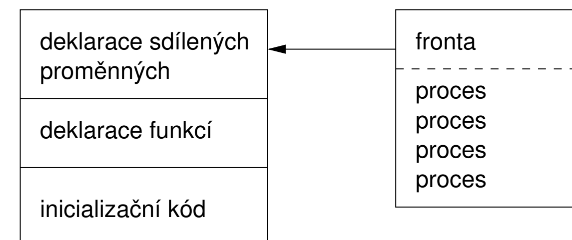

- Přístup k monitoru je realizován podmínkovými proměnnými. Ke každé proměnné existuje fronta čekajících procesů.

  V Javě je synchronizace řešena právě mechanismem monitorů – jako monitor může výstupovat libovolný objekt

Část II

Část 2 – Vícevláknové aplikace

Co jsou vlákna?

- Vlákno - Thread.
- Vlákno je **samostatně** prováděný **výpočetní tok**.
- Vlákna běží v rámci procesu.
- Vlákna jednoho procesu běží v rámci stejného prostoru paměti.
- Každé vlákno má vyhrazený prostor pro specifické proměnné (*runtime prostředí*).

Kdy vlákna použít?

„Vlákna jsou lehčí variantou procesů, navíc sdílejí paměťový prostor."

- Efektivnější využití zdrojů.

Příklad

Čeká-li proces na přístup ke zdroji, předává řízení jinému procesu. Čeká-li vlákno procesu na přístup ke zdroji, může jiné vlákno téhož procesu využít časového kvanta přidělené procesu.

- Reakce na asynchronní události.

Příklad

Během čekání na externí událost (v blokovaném režimu), může proces využít CPU v jiném vlákně.

Příklady použití vláken

- Vstupně výstupní operace.

Příklad

Vstupně výstupní operace mohou trvat relativně dlouhou dobu, která většinou znamená nějaký druh čekání. Během komunikace, lze využít přidělený procesor na výpočetně náročné operace.

- Interakce grafického rozhraní.

Příklad

Grafické rozhraní vyžaduje okamžité reakce pro příjemnou interakci uživatele s naší aplikací. Interakce generují událostí, které ovlivňují běh aplikace. Výpočetně náročné úlohy, nesmí způsobit snížení interakce rozhraní s uživatelem.

Vlákna a procesy

Procesy

- Výpočetní tok.
- Běží ve vlastním paměťovém prostoru.
- Entita OS.
- Synchronizace entitami OS (IPC).
- Přidělení CPU, rozvrhovačem OS.
- Časová náročnost vytvoření procesu.

Vlákna procesu

- Výpočetní tok.
- Běží ve společném paměťovém prostoru.
- Uživatelská nebo OS entita.
- Synchronizace exkluzivním přístupem k proměnným.
- Přidělení CPU, v rámci časového kvanta procesu.
- \+ Vytvoření vlákna je méně časově náročné.

Vícevláknové a víceprocesové aplikace

Vícevláknová aplikace má oproti více procesové aplikaci výhody:

- Aplikace je mnohem interaktivnější.
- Snadnější a rychlejší komunikace mezi vlákny (stejný paměťové prostor).

Nevýhody:

- Distribuce výpočetních vláken na různé výpočetní systémy (počítače).

Na jednoprocesorových systémech vícevláknové aplikace lépe využívají CPU.

Vlákna v operačním systému

- Vlákna běží v rámci výpočetního toku procesu.
- S ohledem na realizaci se mohou nacházet:
  - V uživatelském prostoru procesu. Realizace vláken je na úrovni knihovních funkcí. Vlákna nevyžadují zvláštní podporu OS, jsou rozvrhována uživatelským knihovním rozvrhovačem. Nevyužívají více procesorů.
  - V prostoru jádra OS. Tvoří entitu OS a jsou také rozvrhována systémovým rozvrhovačem. Mohou paralelně běžet na více procesorech.

Vlákna v uživatelském prostoru

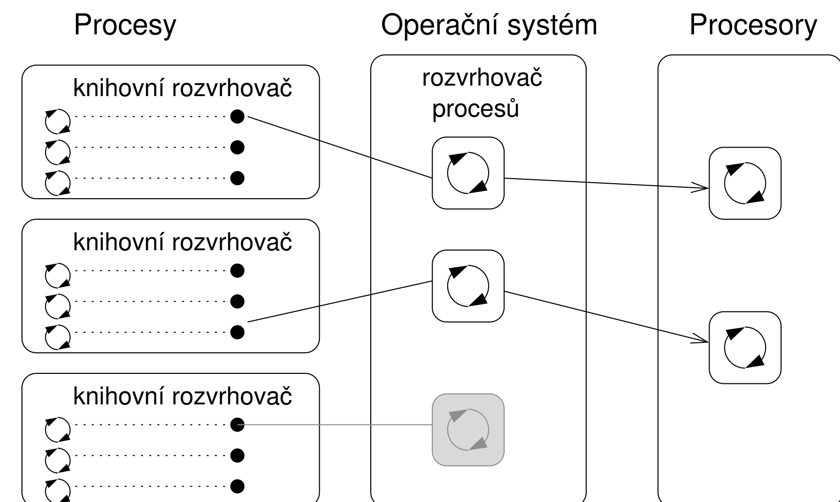

Vlákna v prostoru jádra operačního systému

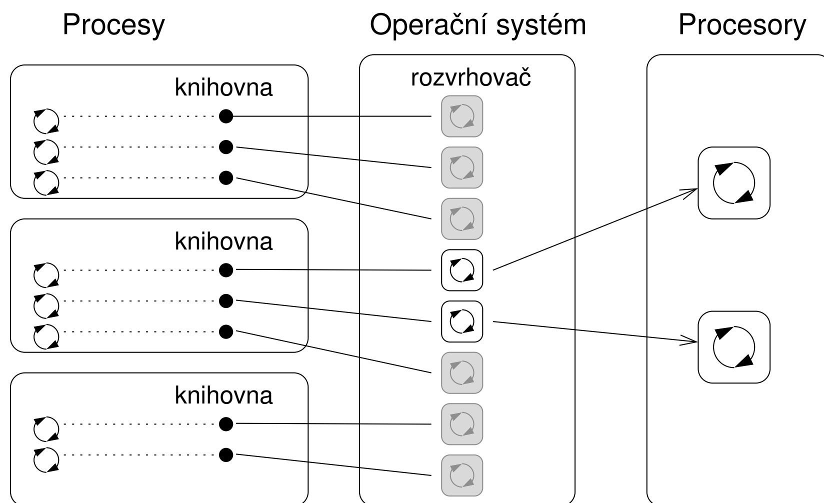

Uživatelský vs jaderný prostor vláken

Uživatelský prostor

+ Není potřeba podpory OS.
+ Vytvoření nepotřebuje náročné systémové volání.
- Priority vláken se uplatňují pouze v rámci přiděleného časového kvanta procesu.
- Nemohou běžet paralelně.

Prostor jádra

+ Vlákna jsou rozvrhována kompetitivně v rámci všech vláken v systému.
+ Vlákna mohou běžet paralelně.
- Vytvoření vláken je časově náročnější.

Vyšší počet vláken, které jsou rozvrhována OS mohou zvyšovat režii. Moderní operační systémy implementují *„O(1) rozvrhovače"*.

Kombinace uživatelského a jaderného prostoru

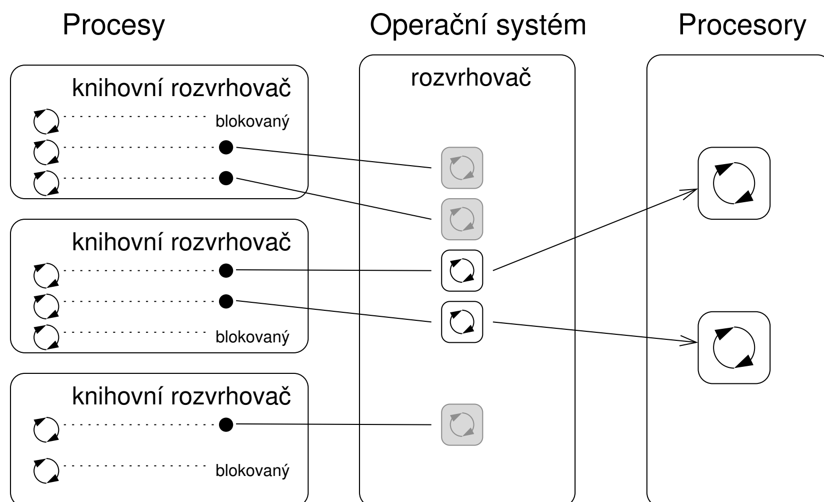

Vlákna v Javě

- Objekt třídy odvozené od třídy **Thread**
- Tělo nezávislého výpočetního toku vlákna definujeme v metodě **public void run()**

Overriding

- Metodu **run** nespouštíme přímo!
- Pro spuštění vlákna slouží metoda start(), která zajistí vytvoření vlákna a jeho rozvrhování
- Vlákno můžeme pojmenovat předáním jména nadřazené třídě v konstruktoru

http://docs.oracle.com/javase/tutorial/essential/concurrency/index.html

Příklad vlákna

```
public class Worker extends Thread {
   private final int numberOfJobs;

   public Worker(int id, int jobs) {
      super("Worker " + id);
      myID = id;
      numberOfJobs = jobs;
      stop = false;
      System.out.println("Worker id: " + id + " has
    been created threadID:" + getId());
   }

   public void run() {
      doWork();
   }
}
```


Příklad vytvoření a spuštění vlákna

- Vlákno vytvoříme novou instancí třídy `Worker`
- Spuštění vlákna provedeme metodou `start()`

```
Worker thread = new Worker(1, 10);
thread.start(); //new thread is created
System.out.println("Program continues here");
```

- Po spuštění vlákna pokračuje program ve vykonávání další instrukce.
- Tělo metody `run()` vlákna `thread` běží v samostatném vlákně.

Vytvoření vlákna implementací rozhraní **Runnable** 1/2

- V případě, že nelze použít dědění od `Thread`, implementujeme rozhraní `Runnable` předepisující metodu `run()`

```
public class WorkerRunnable implements Runnable {
    private final int id;
    private final int numberOfJobs;

    public WorkerRunnable(int id, int jobs) {
        this.id = id;
        numberOfJobs = jobs;
    }
    public String getName() {
        return "WorkerRunnable " + id;
    }
    @Override
    public void run() { ... }
}
```


Vytvoření vlákna implementací rozhraní **Runnable** 2/2

- Vytvoření vlákna a spuštění je přes instanci třídy `Thread`

```
WorkerRunnable worker = new WorkerRunnable(1, 10);
Thread thread = new Thread(worker, worker.getName());
thread.start();
```

- Aktuální výpočetní tok (vlákno) lze zjistit voláním `Thread.currentThread()`

```
public void run() {
   Thread thread = Thread.currentThread();
   for (int i = 0; i < numberOfJobs; ++i) {
      System.out.println("Thread name: " + thread.
    getName());
   }
}
```

lec05/WorkerRunnable

Vlákna v Javě – metody třídy Thread

- String getName() – jméno vlákna
- boolean isAlive() – test zdali vlákno běží
- void join() – pozastaví volající vlákno dokud příslušné vlákno není ukončeno
- static void sleep() – pozastaví vlákno na určenou dobu

- int getPriority() – priorita vlákna
- static void yield() – vynutí předání řízení jinému vláknu

Příklad čekání na ukončení činnosti vlákna – 1/2

- Vytvoříme třídu DemoThreads, která spustí „výpočet" v numberOfThreads paralelně běžících vláknech

```
ArrayList<Worker> threads = new ArrayList();
for (int i = 0; i < numberOfThreads; ++i) {
   threads.add(new Worker(i, 10));
}
// start threads
for (Thread thread : threads) {
   thread.start();
}
```

- Po skončení hlavního vlákna program (JVM) automaticky čeká až jsou ukončeny všechna vlákna
- Tomu můžeme zabránit nastavením vlákna do tzv. Daemon režimu voláním setDaemon(true)

Příklad čekání na ukončení činnosti vlákna – 2/2

- Nastavíme vlákna před spuštěním

```
for (Thread thread : threads) {
   thread.setDaemon(true);
   thread.start();
}
```

V tomto případě se aplikace ihned ukončí.

- Pro čekání na ukončení vláken můžeme explicitně použít metodu join().

```
try {
   for (Thread thread : threads) {
      thread.join();
   }
} catch (InterruptedException e) {
   System.out.println("Waiting for the thread ...");
}
```

lec05/DemoThreads

Ukončení činnosti vlákna

- Činnost vlákna můžeme ukončit „zasláním (vlastní) zprávy" výpočetnímu toku s „žádostí" o přerušení činnosti

V zásadě jediný korektní způsobem

- Ve vlákně **musíme** implementovat mechanismu detekce žádosti o přerušení činnosti, např. nastavení příznakové proměnné stop a rozdělením výpočtu na menší části

```
public class Worker extends Thread {
   ...
   private boolean stop;

   public Worker(int id, int jobs) {
      ...
         stop = false;
   }
   public void run() {
      for (int i = 0; i < numberOfJobs; ++i) {
         if (stop) {
            break;
         }
         doWork();
      }
}
```

Přístup ke „sdílené proměnné" z více vláken

- Žádost o ukončení implementujeme v metodě **shutdown**, kde nastavím proměnnou **stop**

```
public void shutdown() {
   stop = true;
}
```

- Přístup k základní proměnné je atomický a souběh tak „netřeba" řešit
- Překladač a virtuální stroj (JVM) musím informovat, že se hodnota proměnné může nezávisle měnit použitím klíčového slova **volatile**

http://docs.oracle.com/javase/tutorial/essential/concurrency/atomic.html

http://www.root.cz/clanky/pohled-pod-kapotu-jvm-zaklady-optimalizace-aplikaci-naprogramovanych-v-jave-4/

- Například:

```
private volatile boolean stop;
```


Příklad – Odložené ukončení vláken

- Příklad s vlákny `DemoThreads` rozšíříme o explicitní ukončení vláken po definované době
- Vytvoříme třídu `ThreadKiller`, která ukončí vlákna po `timeout` sekundách

```
public class ThreadKiller implements Runnable {
   ArrayList<Worker> threads;
   int timeout;
   public ThreadKiller(ArrayList<Worker> threads, int time) {
    ... }
   @Override
   public void run() {
      try {
         Thread.sleep(timeout * 1000);
         System.out.println("ThreadKiller ...");
         for (Worker thread : threads) {
            thread.shutdown();
         }
         for (Worker thread : threads) {
            thread.join();
         }
      } catch (InterruptedException e) { ... }
} }
```

lec05/ThreadKiller

Synchronizace činnosti vláken – **monitor**

- V případě spolupracující vláken je nutné řešit problém sdílení datového prostoru
  - Řešení problému souběhu – tj. problém současného přístup na datové položky z různých vláken
- Řešením je využít kritické sekce – **monitor**
  - Objekt, který vláknu „zpřístupní" sdílený zdroj
    Můžeme si představit jako zámek.
  - V daném okamžiku aktivně umožní monitor používat jen jedno vlákno
  - Pro daný časový interval vlákno vlastní příslušný monitor – monitor smí „vlastnit" vždy jen jedno vlákno
  - Vlákno běží, jen když vlastní příslušný monitor, jinak čeká
- V Javě mohou mít všechny objekty svůj monitor
- Libovolný objekt tak můžeme použít pro definici **kritické sekce**

Kritická sekce – **synchronized**

- Kritickou sekci deklarujeme příkazem **synchronized** s jediným argumentem objektu (referenční proměnné) definující příslušným monitor

```
Object monitor = new Object();
synchronized(monitor) {
   //Critical section protected
   //by the monitor
}
```

- Vstup do kritické sekce je umožněn pouze jedinému vláknu
  - Vlákno, které první vstoupí do kritické sekce může používat zdroje „chráněné" daným monitorem
  - Ostatní vlákna čekají, dokud aktivní vlákno neopustí kritickou sekci a tím uvolní zámek

Případně zavolá `wait`

Synchronizované metody

- Metody třídy můžeme deklarovat jako synchronizované, např.

```
class MyObject {
   public synchronized void useResources() {
      ...
   }
}
```

- Přístup k nim je pak chráněn monitorem objektu příslušné instance třídy (**this**), což odpovídá definování kritické sekce

```
public void useResources() {
   synchronized(this) {
      ...
   }
}
```

Deklarací metody jako synchronizované informujeme uživatele, že metoda je synchronizovaná bez nutnosti čtení zdrojového kódu.

Komunikace mezi vlákny

- Vlákna jsou objekty a ty si mohou zasílat zprávy (volání metod)
- Každý objekt (monitor) navíc implementuje metody pro explicitní ovládání a komunikaci mezi vlákny:
  - `wait` – dočasně pozastaví vlákno do doby než je probuzeno metodou `notify` nebo `notifyAll`, nebo po určené době
    Uvolňuje příslušný zablokovaný monitor
  - `notify` – probouzí pozastavené vlákno metodou `wait()`, čeká-li více vláken není určeno, které vlákno převezme monitor
  - `notifyAll` – probouzí všechna vlákna pozastavena metodou `wait()`
    Monitoru se zmocní vlákno s nejvyšší prioritou

Část III

Část 3 – Modely vícevláknových aplikací

Kdy použít vlákna?

Vlákna je výhodné použít, pokud aplikace splňuje některé následující kritérium:

- Je složena z nezávislých úloh.
- Může být blokována po dlouho dobu.
- Obsahuje výpočetně náročnou část.
- Musí reagovat na asynchronní události.
- Obsahuje úlohy s nižší nebo vyšší prioritou než zbytek aplikace.

Typické aplikace

- Servery - obsluhují více klientů najednou. Obsluha typicky znamená přístup k několika sdíleným zdrojům a hodně vstupně výstupních operací (I/O).
- Výpočetní aplikace - na víceprocesorovém systému lze výpočet urychlit rozdělením úlohu na více procesorů.
- Aplikace reálného času - lze využít specifických rozvrhovačů. Vícevláknová aplikace je výkonnější než složité asynchronní programování, neboť vlákno čeká na příslušnou událost namísto explicitního přerušování vykonávání kódu a přepínání kontextu.

Modely vícevláknových aplikací

Modely řeší způsob vytváření a rozdělování práce mezi vlákny.

- Boss/Worker - hlavní vlákno řídí rozdělení úlohy jiným vláknům.
- Peer - vlákna běží paralelně bez specifického vedoucího.
- Pipeline - zpracování dat sekvencí operací.
  Předpokládá dlouhý vstupních proud dat.

Boss/Worker model

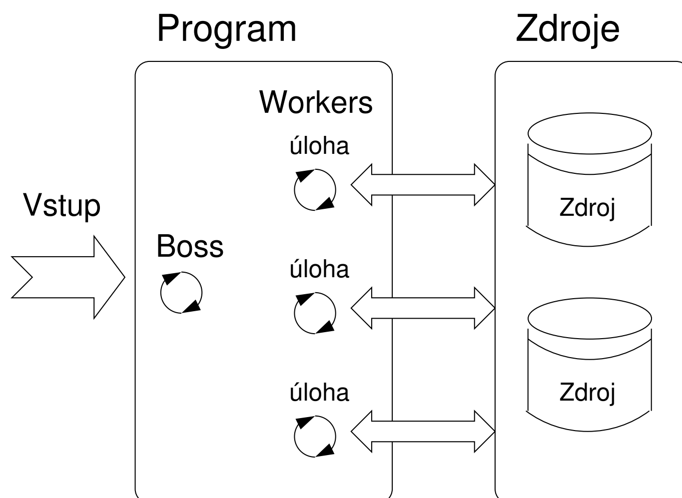

Boss/Worker rozdělení činnosti

Hlavní vlákno je zodpovědné za vyřizování požadavků. Pracuje v cyklu:

1. příchod požadavku,
2. vytvoření vlákna pro řešení příslušného úkolu,
3. návrat na čekání požadavku.

Výstup řešení úkolu je řízen:

- Příslušným vláknem řešícím úkol.
- Hlavním vláknem, předání využívá synchronizační mechanismy.

Boss/Worker příklad

Příklad Boss/Worker model

```
1  //Boss
2  main() {
3   while(1) {
4     switch(getRequest())
        {
5        case taskX :
       create_thread(taskX
       );
6        case taskY :
       create_thread(taskY
       );
7           .
8           .
9     }
10   }
11 }
```

```
1  //Worker
2  taskX() {
3    řešení úlohy,
       synchronizace v
       případě sdílených
       zdrojů;
4    done;
5  }
6
7  taskY() {
8    řešení úlohy,
       synchronizace v
       případě sdílených
       zdrojů;
9    done;
10 }
```


Thread Pool

- Hlavní vlákno vytváří vlákna dynamicky podle příchozích požadavků.
- Režii vytváření lze snížit, vytvořením vláken dopředu (Thread Pool).
- Vytvořená vlákna čekají na přiřazení úkolu.

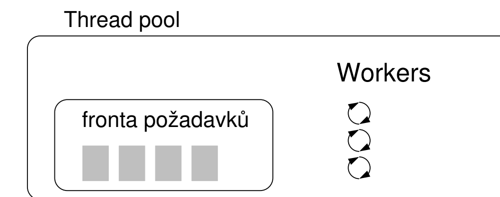

Thread Pool - vlastnosti

- Počet vytvořených vláken.
- Maximální počet požadavků ve frontě požadavků.
- Definice chování v případě plné fronty požadavků a žádného volného vlákna.

  Například blokování příchozích požadavků.

Peer model

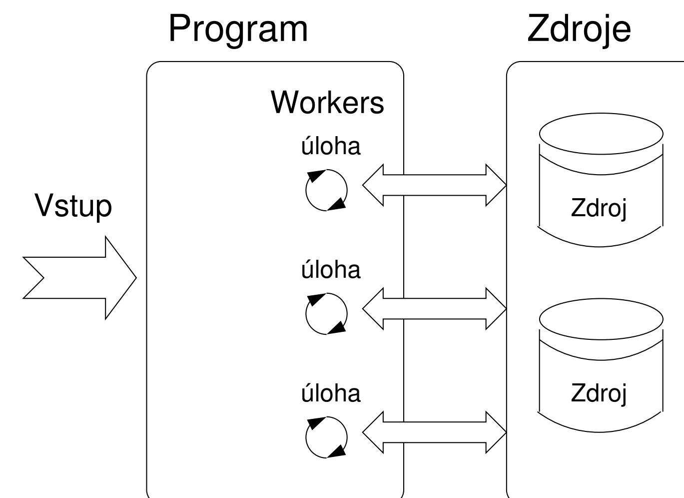

Peer model - vlastnosti

- Neobsahuje hlavní vlákno.
- První vlákno po vytvoření ostatních vláken:
  - se stává jedním z ostatních vláken (rovnocenným),
  - pozastavuje svou činnost do doby než ostatní vlákna končí.
- Každé vlákno je zodpovědné za svůj vstup a výstup.

Peer model - příklad

Příklad Peer model

```
1 //Boss
2 main() {
3   create_thread(task1);
4   create_thread(task2);
5   .
6   .
7   start all threads;
8   wait for all threads;
9 }
```

```
1 //Worker
2 task1() {
3   čekáná na spuštení;
4   řešení úlohy,
      synchronizace v
      případě sdílených
      zdrojů;
5   done;
6 }
7
8 task2() {
9   čekáná na spuštení;
10  řešení úlohy,
      synchronizace v
      případě sdílených
      zdrojů;
11  done;
12 }
```


Zpracování proudu dat - Pipeline

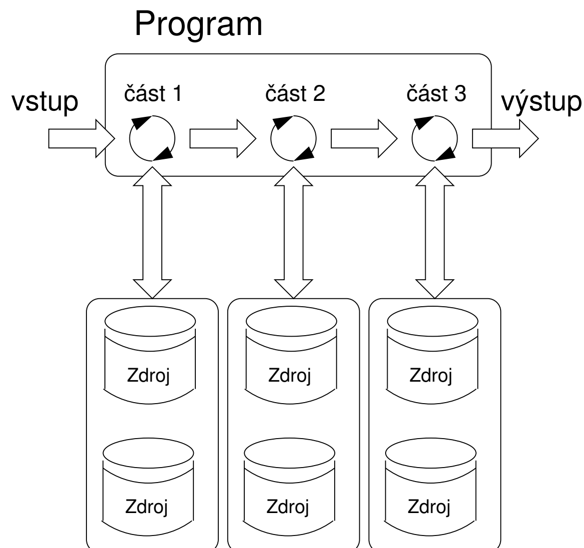

Pipeline

- Dlouhý vstupní proud dat.
- Sekvence operací (částí zpracování), každá vstupní jednotka musí projít všemi částmi zpracování.
- V každé části jsou v daném čase, zpracovávány různé jednotky vstupu (nezávislost jednotek).

Pipeline model - příklad

Příklad Pipeline model

```
1  main() {
2    create_thread(stage1)
       ;
3    create_thread(stage2)
       ;
4    .
5    .
6    wait for all pipeline
       ;
7  }
8  stage1() {
9   while(input) {
10    get next program
       input;
11    process input;
12    pass result to next
       stage;
13  }
14 }
```

```
1  stage2() {
2   while(input) {
3     get next input from
       thread;
4     process input;
5     pass result to next
       stage;
6   }
7  }
8  stageN() {
9   while(input) {
10    get next input from
       thread;
11    process input;
12    pass result to
       output;
13  }
14 }
```


Producent a konzument

Předávání dat mezi vlákny je realizováno vyrovnávací pamětí bufferem.

- Producent - vlákno, které předává data jinému vláknu.
- Konzument - vlákno, které přijímá data od jiného vlákna.

Přístup do vyrovnávací pamětí musí být synchronizovaný (exkluzivní přístup).

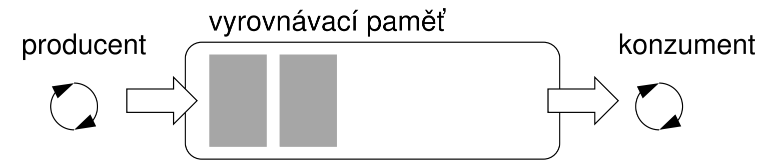

Označení kritické sekce – Mutex

- Mutex představuje „zámek" kritické sekce – analogie **synchronized** monitoru
- Jedná se vlastně o semafor s hodnotou 1 nebo 0
- Základní operace:
  - **Lock** - uzamknutí mutexu (přiřazení mutexu vláknu). Pokud nelze mutex získat, vlákno přechází do blokovaného režimu a čeká na uvolnění zámku.
  - **Unlock** - uvolnění zámku. Pokud jiná vlákna čekají na uvolnění, je vybráno jedno vlákno, které mutex získá.
- Rozšířené modely:
  - Rekursivní - vícenásobné zamykání stejným vláknem.
  - Try - okamžitý návrat pokud není možné mutex získat.
  - Timed - pokus o získání zámku s omezenou dobou čekání.

Informativní

Funkce a paralelismus

Při paralelním běhu programu mohou být funkce volány vícenásobně. Funkce jsou :

- reentrantní - V jediném okamžiku může být stejná funkce vykonávána simultánně.
- thread-safe - Funkce je možné simultánně volat z více vláken.

Dosažení těchto vlastností:

- Reentrantní funkce nezapisují do statických dat, nepracují s globálními daty.
- Thread-safe funkce využívají synchronizačních primitiv při přístupu ke globálním datům.

Vícevláknové aplikace a ladění

Hlavní problémy vícevláknových aplikací souvisí se synchronizací:

- uváznutí - deadlock.
- souběh (race conditions) - přístup více vláken ke sdíleným proměnným a alespoň jedno vlákno nevyužívá synchronizačních mechanismů. Vlákno čte hodnou zatímco jiné vlákno zapisuje. Zápis a čtení nejsou atomické a data mohou být neplatná.

Prostředky ladění

- Nejlepším prostředkem ladění vícevláknových aplikací je

  nepotřebovat ladit.
- Toho lze dosáhnou kázní a obezřetným přístupem ke sdíleným proměnným.
- Nicméně je vhodné využívat ladící prostředí s minimální množinou vlastností.

Podpora ladění

Debugger:

- Výpis běžících vláken.
- Výpis stavu synchronizačních primitiv.
- Přístup k proměnným vláken.
- Pozastavení běhu konkrétního vlákna.

Logování:

- Problém uváznutí souvisí s pořadím událostí, logováním přístupu k zámkům lze odhalit případné špatné pořadí synchronizačních operací.

Poznámky - „problémy souběhu"

Problémy souběhu jsou typicky způsobeny nedostatkem synchronizace.

- Vlákna jsou asynchronní. *Nespoléhat na to, že na jednoprocesorovém systému je vykonávání kódu synchronní.*
- Při psaní vícevláknové aplikace předpokládejte, že vlákno může být kdykoliv přerušeno nebo spuštěno. *Části kódu, u kterých je nutné zajistit pořadí vykonávání jednotlivými vlákny vyžadují synchronizaci.*
- Nikdy nespoléhejte na to, že vlákno po vytvoření počká, může být spuštěno velmi brzy.
- Pokud nespecifikujete pořadí vykonávání vláken, žádné takové neexistuje. „*Vlákna běží v tom nejhorším možném pořadí. Bill Gallmeister*"

Poznámky - „problém uváznutí"

Problémy uváznutí souvisí s mechanismy synchronizace.

- Uváznutí (deadlock) se na rozdíl o souběhu mnohem lépe ladí.
- Častým problém je tzv. *mutex deadlock* způsobený pořadím získávání mutexů.
- Mutex deadlock nemůže nastat, pokud má každé vlákno uzamčený pouze jeden mutex (*chce uzamknout*).
- Není dobré volat funkce s uzamčeným mutexem, obzvláště zamyká-li volaná funkce jiný mutex.
- Je dobré zamykat mutex na co možná nejkratší dobu.

Část IV

Část 4– Využití vláken v GUI

Vlákna v GUI (Swing)

- Vlákna můžeme v libovolné aplikaci a tedy i v aplikaci s GUI.
- Vykreslování komponent Swing se děje v samostatném vlákně vytvořeném při inicializaci toolkitu
- Proto je vhodné aktualizaci rozhraní realizovat notifikací tohoto vlákna z jiného

  Snažíme se pokud možno vyhnout asynchronnímu překreslování z více vláken – race condition
- Zároveň se snažíme oddělit grafickou část od výpočetní (datové) části aplikace (MVC)

http://docs.oracle.com/javase/tutorial/uiswing/concurrency

Samostatné výpočetní vlákno pro model

- Třídu `Model` rozšíříme o rozhraní **Runnable**
- Vytvoříme novou třídu `ThreadModel`
  - Voláním metody `compute` spustíme samostatné vlákno
  - Musíme zabránit opakovanému vytváření vlákna

    Příznak `computing`
  - Metodu uděláme synchronizovanou
- Po stisku tlačítka stop ukončíme vlákno

  Implementujeme třídu `StopListener`
- Ve třídě `ThreadModel` implementuje metodu `stopComputation`

  Nastaví příznak ukončení výpočetní smyčky `end`

lec05/DemoBarComp-simplethread

Po spuštění výpočtu je GUI aktivní, ale neaktualizuje se *progress bar*, je nutné vytvořit vazbu s výpočetního vlákna – použijeme návrhový vzor **Observer**

Návrhový vzor **Observer**

- Realizuje abstraktní vazbu mezi objektem a množinou pozorovatelů
- Pozorovatelé jsou předplatiteli (*subscribers*) změn objektu
- Předplatitelé se musejí registrovat k pozorovanému objektu
- Objekt pak informuje (notifikuje) pozorovatele o změnách
- V Javě je řešen dvojicí třídy **Observable** a **Observer**

Výpočetní model jako **Observable** objekt 1/4

- **Observable** je abstraktní třídy, proto vytvoříme nový **Observable** objekt jako instanci privátní třídy `UpdateNotificator`
- `UpdateNotificator` slouží k notifikaci registrovaných pozorovatelů

```
public class ThreadModel extends Model implements
   Runnable {
   ...
   private class UpdateNotificator extends Observable {
      private void update() {
         setChanged();       // force subject change
         notifyObservers(); // notify registered
 observers
      }
   }
   UpdateNotificator updateNotificator;

   public ThreadModel() {
      updateNotificator = new UpdateNotificator();
      ...
```

lec05/DemoBarComp-observer

Výpočetní model jako **Observable** objekt 2/4

- Musíme zajistit rozhraní pro přihlašování a odhlašování pozorovatelů
- Zároveň nechceme měnit typ výpočetní model ve třídě `MyBarPanel`
- Musíme proto rozšířit původní výpočetní model `Model`

```
public class Model {
 public void unregisterObserver(Observer observer) {...}
 public void registerObserver(Observer observer) {...}
 ...
```

- Ve třídě `ThreadModel` implementujeme přihlašování/odhlašování odběratelů

```
@Override
public void registerObserver(Observer observer) {
   updateNotificator.addObserver(observer);
}
@Override
public void unregisterObserver(Observer observer) {
   updateNotificator.deleteObserver(observer);
}
```

lec05/DemoBarComp-observer

Výpočetní model jako **Observable** objekt 3/4

- Odběratele informujeme po dílčím výpočtu v metodě `run` třídy `ThreadModel`

```
public void run() {
   ...
   while (!computePart() && !finished) {
      updateNotificator.update();
      ...
```

- Panel `MyBarPanel` je jediným odběratelem a implementuje rozhraní **Observer**, tj. metodu **update**

```
public class MyBarPanel extends JPanel implements
    Observer {
    @Override
    public void update(Observable o, Object arg) {
        updateProgress();
    }
    private void updateProgress() {
        if (computation != null) {
            bar.setValue(computation.getProgress());
        }
    }
```

lec05/DemoBarComp-observer

Výpočetní model jako **Observable** objekt 4/4

- Napojení pozorovatele `MyBarPanel` na výpočetní model `Model` provedeme při nastavení výpočetního modelu

```
public class MyBarPanel extends JPanel implements
    Observer {
public void setComputation(Model computation) {
        if (this.computation != null) {
            this.computation.unregisterObserver(this);
        }
        this.computation = computation;
        this.computation.registerObserver(this);
   }
```

- Při změně modelu nesmíme zapomenout na odhlášení od původního modelu

  Nechceme dostávat aktualizace od původního modelu, pokud by dál existoval.

  lec05/DemoBarComp-observer

Výpočetní vlákno ve Swing

- Alternativně můžeme využít třídu **SwingWorker**
- Ta definuje metodu **doInBackground()**, která zapouzdřuje výpočet na „pozadí" v samostatném vláknu
  - V těle metody můžeme publikovat zprávy voláním metody `publish()`
- Automaticky se také „napojuje" na události v „grafickém vlákně" a můžeme předefinovat metody
  - `process()` – definuje reakci na publikované zprávy
  - `done()` – definuje reakci po skočení metody `doInBackground()`

http://docs.oracle.com/javase/tutorial/uiswing/concurrency/worker.html

Příklad použití třídy **SwingWorker** 1/3

- Vlákno třídy `SwingWorker` využijeme pro aktualizaci GUI s frekvencí 25 Hz
- V metodě `doInBackground` tak bude periodicky kontrolovat, zdali výpočetní vlákno stále běží
- Potřebujeme vhodné rozhraní třídy `Model`, proto definujeme metodu `isRunning()`

```
public class Model {
   ...
   public boolean isRunning() { ... }
}
```

Není úplně vhodné, ale vychází z postupného rozšiřování původně nevláknového výpočtu. Lze řešit využitím přímo ThreadModel.

- Metodu `isRunning` implementujeme ve vláknovém modelu `ThreadModel`

```
public class ThreadModel ...
    public synchronized boolean isRunning() {
        return thread.isAlive();
    }
```

lec05/DemoBarComp-swingworker

Příklad použití třídy **SwingWorker** 2/3

- Všechna ostatní rozšíření realizuje pouze v rámci GUI třídy `MyBarPanel`
- Definujeme vnitřní třídy **MySwingWorker** rozšiřující **SwingWorker**

```
public class MyBarPanel extends JPanel {
   public class MySwingWorker extends SwingWorker<Integer
    , Integer> { ... }

   MySwingWorker worker;
```

- Tlačítko **Compute** připojíme instanci `MySwingWorker`

```
private class ComputeListener implements ActionListener {
   @Override
   public void actionPerformed(ActionEvent e) {
      if (!worker.isDone()) { //only single worker
         status.setText("Start computation");
         worker.execute();
      }
   }
}
```

lec05/DemoBarComp-swingworker

Příklad použití třídy SwingWorker 3/3

- Ve MySwingWorker definujeme napojení periodické aktualizace na *progress bar*

```
public class MySwingWorker extends SwingWorker {
   @Override
   protected Integer doInBackground() throws Exception {
      computation.compute();
      while (computation.isRunning()) {
         TimeUnit.MILLISECONDS.sleep(40); //25 Hz
         publish(new Integer(computation.getProgress()));
      }
      return 0;
   }
   protected void process(List<Integer> chunks) {
      updateProgress();
   }
   protected void done() {
      updateProgress();
   }
}
```

lec05/DemoBarComp-swingworker

- S výhodou využíváme přímého přístupu k updateProgress

Shrnutí přednášky

Diskutovaná témata

- Paralelní programování
  - Procesy a role operačního systému
  - Vlákna a operační systém
  - Monitor a problém souběhu
- Vlákna v Javě
  - Vytvoření, synchronizace a komunikace mezi vlákny
- Modely vícevláknových aplikací
- Paralelní programování a ladění
  - Problém uváznutí a problém souběhu
- Příklady vláken v GUI (Swing)
  - Návrhový vzor Observer
  - SwingWorker
- Příště: dokončení a ukázky aplikací