

# Vláknové programování

## část V

**Lukáš Hejtmánek, Petr Holub**

`{xhejtman, hopet}@ics.muni.cz`



Laboratoř pokročilých síťových technologií

PV192  
2012-03-20

# Přehled přednášky

Úlohy a vlákna

Executors, Thread Pools a Futures

Ukončování a přerušování

ThreadPoolExecutors Revisited

Java NIO

# Úlohy a vlákna

- Úloha vs. vlákno
  - úloha – co se vykonává (**Runnable**, **Callable**)
  - vlákno – kdo úlohu vykonává (Executor/Future/TPE/...)
- Oddělení úloh od vláken
  - úloha nesmí předpokládat nic o chování vlákna, které ji vykonává
  - Politika ukončení vs. politika přerušení

(příklady povětšinou převzaty z JCiP, Goetz)



# Executors, Thread Pools

- Koncept vykonavatelů kódu: Executors
  - vykonávají se objekty implementující Runnable
  - různé typy Executors
- ExecutorService přidává
  - schopnost zastavit vykonávání
  - schopnost vykonávat Callable<V>, nikoli pouze Runnable()
  - vracet objekty representované jako Future
- ThreadPoolExecutor
  - všeobecně použitelný executor, jednoduché API
  - minimální i maximální počet vláken
  - recyklace vláken
  - likvidace nepoužívaných vláken

# Runnable vs. Callable

- Interface Runnable

- implementuje úlohu
- lze použít s konstruktorem třídy Thread
  - ◆ konceptuálně čistější přístup: nerozšiřujeme třídu, kterou vlastně rozšiřovat nechceme
- použití i v hlavním vlákne

```
public class PrikladRunnable {
2     static class RunnableVlakno implements Runnable {
3         public void run() {
4             System.out.println("Tu je vlakno.");
5         }
6     }

8     public static void main(String[] args) {
9         System.out.print("Startuji vlakno: ");
10        new Thread(new RunnableVlakno()).start();
11        System.out.println("hotovo.");
12        System.out.println("Spoustim primo v hlavnim vlakne: ");
13        new RunnableVlakno().run();
14    }
}
```

# Runnable vs. Callable

- Interface Callable<V>

- na rozdíl od Runnable může vrátit výsledek (typu V) a vyhodit výjimku

```
1 import java.util.concurrent.Callable;
3 public class PrikladCallable {
4     static class CallableVlakno implements Callable<String> {
5         public String call() throws Exception {
6             return "Retezec z Callable";
7         }
8     }
9
10    public static void main(String[] args) {
11        try {
12            String s = new CallableVlakno().call();
13            System.out.println(s);
14        } catch (Exception e) {
15            System.out.println("Chytil jsem vyjimku");
16        }
17    }
18 }
```

# Executors

- Typy Executorů
  - `SingleThreadExecutor`
    - ◆ sekvenční vykonávání úloh
    - ◆ pokud vlákno selže, pokračuje se vykonáváním následujícího
  - `ScheduledThreadPool`
    - ◆ zpožděné či opakované vykonávání vláken
  - `FixedThreadPool`
    - ◆ používá pevný počet vláken
  - `CachedThreadPool`
    - ◆ vytváří nová vlákna dle potřeby
    - ◆ opakovaně používá existující uvolněná vlákna
  - `ScheduledExecutorService`
    - ◆ implementace spouštění s definovaným zpožděním a opakovaného spouštění
    - ◆ <http://java.sun.com/j2se/1.5.0/docs/api/java/util/concurrent/ScheduledExecutorService.html>
  - Executors factory
    - ◆ implementace vlastních typů Executorů
    - ◆ <http://java.sun.com/j2se/1.5.0/docs/api/java/util/concurrent/Executors.html>

# Executors

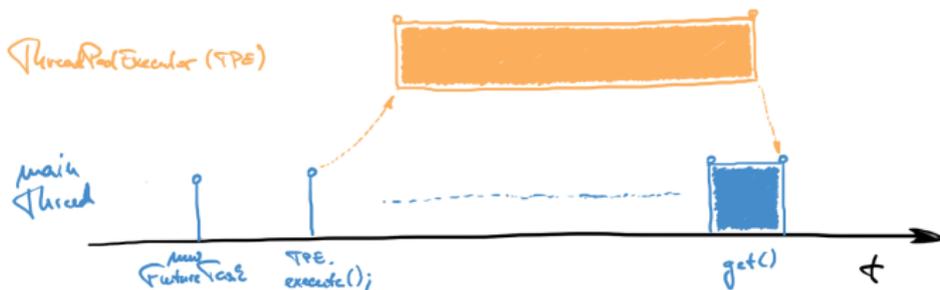
```
import java.util.concurrent.*;
2 import java.util.Random;

4 public class TPE {
    public static void main(String[] args) {
6         final Random random = new Random();
            // forkbomba: ;-)
8         // ExecutorService executor = Executors.newCachedThreadPool();
            ExecutorService executor = Executors.newFixedThreadPool(
10             Runtime.getRuntime().availableProcessors()-1);
            for (int i = 0; i < 100; i++) {
12                 executor.execute(new Runnable() {
                    public void run() {
14                         int max = random.nextInt();
                            for(int j = 0; j < max; j++) { j += 2; j--; }
16                             System.out.println("Dobehlo vlakno s max = " + max);
                                }
18                     });
                }
20            try {
                Thread.sleep(10000);
                executor.shutdown();
                executor.awaitTermination(1000, TimeUnit.SECONDS);
24            } catch (InterruptedException e) {
            }
26        }
    }
```

# Futures

- Princip:

- někdy v budoucnu bude volající potřebovat výsledek výpočtu  $X$
  - v době, kdy si volající řekne o výsledek výpočtu  $X$ : (a) výsledek je okamžitě vrácen, pokud je již k dispozici, nebo (b) volající se zablokuje, výsledek se dopočítá a vrátí, volající se odblokuje
- H. Baker, C. Hewitt, "The Incremental Garbage Collection of Processes". *Proceedings of the Symposium on Artificial Intelligence Programming Languages, SIGPLAN Notices 12*. August 1977. podobný koncept
- D. Friedman. "CONS should not evaluate its arguments". S. Michaelson and R. Milner, editors, *Automata, Languages and Programming*, pages 257-284. Edinburgh University Press, Edinburgh. Also available as *Indiana University Department of Computer Science Technical Report TR44*. 1976



# Futures a ThreadPoolExecutor

```
1 import java.util.concurrent.*;
3 public class Futures {
4     public static class StringCallable implements Callable {
5         public String call() throws Exception {
6             System.out.println("FT: Pocitam.");
7             Thread.sleep(5000);
8             System.out.println("FT: Vypocet hotov.");
9             return "12345";
10        }
11    }
12    public static void main(String[] args) {
13        ThreadPoolExecutor tpe = new ThreadPoolExecutor(2, 8, 60L,
14            TimeUnit.SECONDS, new LinkedBlockingQueue<Runnable>());
15        FutureTask ft = new FutureTask(new StringCallable());
16        System.out.println("main: Poustim vypocet.");
17        tpe.execute(ft);
18        // alternativa: Future ft = tpe.submit(new StringCallable());
19        try {
20            System.out.println("main: Chci vysledek.");
21            String s = (String) ft.get();
22            System.out.println("main: Mam vysledek: " + s);
23            tpe.shutdown();
24            tpe.awaitTermination(1, TimeUnit.MINUTES);
25        } catch (InterruptedException e) {}
26        catch (ExecutionException e) {}
27    }
28 }
```



# Futures vs. CompletionService

- Problém: máme řadu odložených úloh (Future) a potřebujeme je v pořadí dokončení, nikoli zaslání
  1. opakované procházení seznamu a používání `get(0, TimeUnit.SECONDS);`
  2. použijeme `CompletionService`
- `CompletionService`
  - kombinuje `Executor` a `BlockingQueue`
  - `submit()` – vkládáme úlohy pomocí
  - `take()` a `poll()` – vybíráme dokončené úlohy
  - při prázdné frontě dokončných úloh se `take()` blokuje, `poll()` vrací `null`

## Futures vs. CompletionService

```
ArrayList<FileData> stahniSoubory(ArrayList<String> list) {
2   ArrayList<FileData> ald = new ArrayList<FileData>();
   CompletionService<FileData> completionService =
4       new ExecutorCompletionService<FileData>(
           new ThreadPoolExecutor(1, 10, 60, TimeUnit.SECONDS,
6               new LinkedBlockingQueue<Runnable>()));
   for (final String s : list) {
8       completionService.submit(new Callable<FileData>() {
           public FileData call() throws Exception {
10              FileData fd = new FileData();
                fd.s = s; fd.data = getFile(s);
12              return fd;
            }
14          });
   }
16   try {
       for (int i = 0, size = list.size(); i < size; i++) {
18       Future<FileData> f = completionService.take();
           ald.add(f.get());
20       }
   } catch (InterruptedException e) {
22       Thread.currentThread().interrupt();
   } catch (ExecutionException e) { launderThrowable(e.getCause()); }
24   return ald;
}
```



# Futures vs. CompletionService

```
public static RuntimeException launderThrowable(Throwable t) {  
2     if (t instanceof RuntimeException)  
        return (RuntimeException) t;  
4     else if (t instanceof Error)  
        throw (Error) t;  
6     else  
        throw new IllegalStateException("Not unchecked", t);  
8 }
```



# Ukončování a přerušování pro pokročilé

- Kooperativní ukončování úloh a přerušování vláken
  - příznakem proměnné
  - přerušením – interrupt
  - `Thread.stop` – deprecated
- Důvody ukončení úloh
  - uživatelem vyvolané ukončení úlohy (GUI, JMX)
  - časově omezené úlohy
  - události uvnitř – několik úloh hledá řešení paralelně, jedna ho najde
  - externí chyby
  - ukončení aplikace

# Ukončování a přerušování pro pokročilé

- Politika ukončování (cancellation policy)
  - vývojářem specifikováno pro každou **úlohu** (JavaDoc)
  - jak? – jak se vyvolává ukončení?
  - kdy? – kdy je možné vlákno ukončit?
  - co? – co bude třeba udělat před ukončením?
- Ukončování příznakem a/nebo přerušením?

## Přerušení – interrupt

- Mechanismus zasílání zprávy mezi vlákny
  - sémanticky definováno jen jako signalizace mezi vlákny
  - nastavení příznaku

```

1  public class Thread {
      public void interrupt() {...}
3     public boolean isInterrupted() {...}
      public static boolean interrupted() {...}
5  }

```

- Pozor na metodu interrupted()
  - vrátí a *vymaže* stav příznaku
- Zpracování přerušení
  - vyhození výjimky `InterruptedException`
  - předání příznaku dále
  - polknutí příznaku 
- Typické metody na `InterruptedException`
  - `wait`, `sleep`, `join`
  - blokující operace na omezených frontách (`BlockingQueue x.put`)

# Přerušení – interrupt

- Politiky přerušení

- specifikováno vývojářem pro každé vlákno
- standardní chování: uklid', dej vědět vlastníkovi (TPE) a zmiz
- nestandardní chování: není vhodné pro normální úlohy
- vlákno může potřebovat předat stav `interrupted` svému TPE
- úloha by neměla předpokládat nic o politice vlákna, v němž běží
  - ◆ předat stav dál
  - ◆ buď `throw new InterruptedException();`
  - ◆ nebo `Thread.currentThread().interrupt();`  
např. pokud je úloha `Runnable`
- vlákno/TPE může následně `interrupted` příznak potřebovat
- specifikace: kdy?, jak?, další předání?

## Přerušení – interrupt

- Kombinace blokujících operací s politikou přerušení a úlohy s ukončením až na konci

```
1 public Task getNextTask(BlockingQueue<Task> queue) {  
2     boolean interrupted = false;  
3     try {  
4         while (true) {  
5             try {  
6                 return queue.take();  
7             } catch (InterruptedException e) {  
8                 interrupted = true;  
9             }  
10        }  
11    } finally {  
12        if (interrupted) Thread.currentThread().interrupt();  
13    }  
14 }
```

- nesmíme příznak `interrupted` nastavit před voláním `take()`, protože by volání hned skončilo

# Omezený běh – Futures

- **Future** má metodu `cancel` (`boolean mayInterruptIfRunning`)
  - `mayInterruptIfRunning = true` znamená, že se má běžící úloha přerušit
  - `mayInterruptIfRunning = false` znamená, že se pouze nemá spustit, pokud ještě neběží
  - vrací, zda se ukončení povedlo
- Kdy můžeme použít `mayInterruptIfRunning = true`?
  - pokud známe politiku přerušování vlákn
  - pro standardní implementace `Executor` to je známé a bezpečné

## Omezený běh – Futures

```
public class FutureCancel {
2   ThreadPoolExecutor taskExec = new ThreadPoolExecutor(1,10,60,
      TimeUnit.SECONDS, new LinkedBlockingQueue<Runnable>());
4   public void timedRun (Runnable r, long timeout, TimeUnit unit)
      throws InterruptedException {
6       Future<?> task = taskExec.submit(r);
      try {
8           task.get(120, TimeUnit.SECONDS);
        } catch (ExecutionException e) {
10            throw new RuntimeException(e.getMessage());
        } catch (TimeoutException e) {
12            // uloha bude ukoncena nize
        }
14        finally {
            // neskodne, pokud ukloha skončila,
16            // jinak interrupt
            task.cancel(true);
18        }
    }
}
```

# Nepřerušitelná blokování

- Existují blokování, která nereagují na `interrupt`
- Příklady:
  - synchronní soketové I/O v `java.io`
    - ◆ *problém*: metody `read` a `write` na `InputStream` a `OutputStream` nereagují na `interrupt`
    - ◆ *řešení*: zavřít socket, visící čtení/zápis vyhodí `SocketException`
  - čekání na získání monitoru (intrinsic lock)
    - ◆ *problém*: vlákno čekající na monitor (`synchronized`) nereaguje na `interrupt`
    - ◆ *řešení*: neexistuje „násilné“ řešení pro monitory, musí se dočkat
    - ◆ *obejít*: explicitní zámky `Lock` podporují metodu `lockInterruptibly`

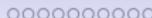


# Nepřerušitelná blokování

- Další vychytávky:
  - synchronní I/O v java.nio
    - ♦ přerušování vyhází u všech zablokovaných vláken `ClosedByInterruptException`, pokud je kanál typu `InterruptibleChannel`
    - ♦ zavření vyhází u všech zablokovaných vláken `AsynchronousCloseException`, pokud je kanál typu `InterruptibleChannel`
  - asynchronní I/O při použití Selector
    - ♦ `Selector.select` vyhodí výjimku `ClosedSelectorException`, pokud obdrží `interrupt`

# Nepřerušitelná blokování

- Využití `ThreadPoolExecutor.newTaskFor(callable)`
    - dostupné od Java 6
    - vrací `RunnableFuture` pro danou úlohu
    - přepsání `newTaskFor` umožňuje vlastní tvorbu `RunnableFuture` a tudíž přepsat metodu `cancel()`
      - ◆ uzavření synchronních socketů pro java.io
      - ◆ statistiky, debugování, atd.
    - lze napsat tak, že si `Callable/Runnable` dodá vlastní implementaci `cancel()`
- <http://www.javaconcurrencyinpractice.com/listings/SocketUsingTask.java>



# Zastavování vláknových služeb

- Problém dlouho běžících vláken
  - vlákna v exekutorech často běží déle, než tvůrce executorů
- Vlákno by měl zastavovat jeho „vlastník“
  - vlastník vláken není definován formálně
  - bere se ten, kdo ho vytvořil
  - vlastnictví není transitivní (jako u objektů – princip zapouzdření)
  - vlastník by měl poskytovat metody na řízení životního cyklu
  - požadavek na ukončení by měl být signalizován vlastníkovi

# Zastavování vláknových služeb

```
public class LogWriter {
2   private final BlockingQueue<String> queue;
   private final LoggerThread logger;
4   private volatile boolean shutdownRequested = false;

6   public LogWriter() throws FileNotFoundException {
       this.queue = new LinkedBlockingQueue<String>();
       this.logger = new LoggerThread(new PrintWriter("mujSoubor"));
       logger.start();
10  }

12  private class LoggerThread extends Thread {
       private final PrintWriter writer;

14         private LoggerThread(PrintWriter writer) {
16             super("Logger Thread");
               this.writer = writer;
18         }

20         public void run() {
               try {
22                 while (true)
                           writer.println(queue.take());
24             } catch (InterruptedException ignored) {
               } finally {
26                 writer.close();
               }
28         }
   }
}
```

# Zastavování vláknových služeb

```
1 public void stop() {  
2     shutdownRequested = true;  
3     logger.interrupt();  
4 }  
5  
6 public void log (String msg) throws InterruptedException {  
7     queue.put (msg);  
8 }
```



- Potřeba ukončovat konzumenty i producenty
  - konzument: `run()`
  - producent: `log(String msg)`

# Zastavování vláknových služeb

```
2 public void logLepe (String msg) throws InterruptedException {  
3     if (!shutdownRequested)  
4         queue.put (msg);  
5     else  
6         throw new IllegalStateException("logger se ukoncuje");  
7 }
```

- Ukončení producenta
  - jakpak zjistíme jeho vlákno?
  - nijak ;-)
  - už je to správně?

# Zastavování vláknových služeb

```
1 public void logLepe (String msg) throws InterruptedException {
2     if (!shutdownRequested)
3         queue.put (msg);
4     else
5         throw new IllegalStateException("logger se ukončuje");
6 }
```



- ... není!
- Race condition
  - složené testování podmínky a volání metody!
- Složené zamykání
  - testování a rezervace v jednom `synchronized` bloku
  - konzument testuje, že zpracoval všechny rezervace

## Zastavování vláknových služeb

```

1 public class SafeLogWriter {
2     private final BlockingQueue<String> queue;
3     private final LoggerThread logger;
4     @GuardedBy("this") private volatile boolean shutdownRequested
5         = false;
6     @GuardedBy("this") private int reservations;

```

...

```

1     public void run() {
2         try {
3             while (true) {
4                 synchronized (this) {
5                     if (shutdownRequested && reservations == 0)
6                         break;
7                 }
8                 String msg = queue.take();
9                 synchronized (this) {--reservations;};
10                writer.println(msg);
11            }
12        } catch (InterruptedException ignored) {
13        } finally {
14            writer.close();
15        }
16    }

```

# Zastavování vláknových služeb

```
2 public void log (String msg) throws InterruptedException {  
3     synchronized (this) {  
4         if (shutdownRequested)  
5             throw new IllegalStateException("logger se ukoncuje");  
6         ++reservations;  
7     }  
8     queue.put (msg);  
9 }
```

# Zastavování vláknových služeb

- **ExecutorService**

- proč nepoužít, co je hotovo?
- **shutdown ()**
  - ◆ pohodové ukončení
  - ◆ dokončí se zařazené úlohy
- **shutdownNow ()**
  - ◆ vrací seznam úloh, které ještě nenastartovaly
  - ◆ problém, jak se dostat k seznamu úloh, které nastartovaly, ale byly ukončeny
- nemá metodu, která by umožnila dokončit běžící úlohy a nové už nestartovala
- zapouzdření do vlastního ukončování:  
`exec.shutdown ();`  
`exec.awaitTermination (timeout, unit);`
- využití i pro jednoduchá vlákna: `newSingleThreadExecutor ()`

## Zastavování vláknových služeb

```

2 public class TrackingExecutor extends AbstractExecutorService {
    private final ExecutorService exec;
4     private final Set<Runnable> tasksCancelledAtShutdown =
        Collections.synchronizedSet(new HashSet<Runnable>());

```

...

```

2     public List<Runnable> getCancelledTasks() {
        if (!exec.isTerminated())
            throw new IllegalStateException("/*...*/");
4         return new ArrayList<Runnable>(tasksCancelledAtShutdown);
    }
6
8     public void execute(final Runnable runnable) {
        exec.execute(new Runnable() {
            public void run() {
10                try {
                    runnable.run();
12                } finally {
                    if (isShutdown()
14                        && Thread.currentThread().isInterrupted())
                        tasksCancelledAtShutdown.add(runnable);
16                }
            }
18        });
    }

```

# Zastavování vláknových služeb

- Vzor – jedovaté sousto
  - ukončování systému producent – konzument
  - jedovaté sousto – jeden konkrétní typ zprávy
  - funguje pro známý počet producentů
    - ◆ konzument umře po požití  $N_{prod}$  otrávených soust
  - lze rozšířit i na více konzumentů
    - ◆ každý producent musí do fronty zapsat  $N_{konz}$  otrávených soust
    - ◆ problém s počtem zpráv  $N_{prod} \cdot N_{konz}$

# Ošetření abnormálního ukončení vlákna

- Zachytávání `RuntimeException`

- normálně se nedělá, měla by vyústit v stacktrace
- potřeba zpracovat, pokud vlákno vykonává úplně cizí kód
- strategie:
  - ◆ zachytit, uložit, pokračovat  
`try {...} catch (...) {...}`  
v případě, že se vlákno o sebe musí postarat samo
  - ◆ ukončit a dát vědět vlastníkovi  
`try {...} finally {...}`  
možnost předat `Throwable`

```
Throwable thrown = null;  
2 try {runTask(getTaskFromQueue());}  
  catch (Throwable e) {thrown = e;}  
4 finally { threadExited (this, thrown);}
```

# Ošetření abnormálního ukončení vlákna

- **UncaughtExceptionHandler**

- aplikace si může nastavit vlastní zpracování nezachycených výjimek
- pokud není nastaven, vypisuje se stacktrace na `System.err`

1. **Thread.setUncaughtExceptionHandler**

- ◆ Java  $\geq$  5.0
- ◆ per vlákno

2. **ThreadGroup**

- ◆ Java  $<$  5.0

- zavolá se pouze první
- pro TPE se nastavuje pomocí vlastní **ThreadFactory** přes konstruktor TPE
  - ◆ standardní TPE nechá po nezachycené výjimce ukončit dané vlákno
  - ◆ bez **UncaughtExceptionHandler** mohou vlákna tiše mizet
  - ◆ možnost task obalit do dalšího Runnable/Callable
  - ◆ vlastní TPE s alternativním **afterExecute**

- Propagace nezachycených výjimek

- do **UncaughtExceptionHandler** se dostanou pouze úlohy zaslané přes `execute()`
- `submit()` vrací výjimku jakou součást návratové hodnoty/stavu – `Future.get()`

# Ukončování JVM

- Normální ukončení (orderly termination)
  - ukončení posledního nedémonického vlákna
  - volání `System.exit()` ;
  - platformově závislé ukončení (SIGINT, Ctrl-C)
- Abnormální ukončení (abrupt termination)
  - volání `Runtime.halt()` ;
  - platformově závislé ukončení (SIGKILL)
- Háčky při ukončení (shutdown hooks)
  - `Runtime.addShutdownHook`
  - předává se implementace vlákna
  - JVM negarantuje pořadí
  - pokud v době ukončování běží jiná vlákna, poběží paralelně s háčky
  - háčky musí být thread-safe: synchronizace
  - např. signalizace ukončení jiným vláknům, mazání dočasných souborů,  
...
  - pokud nějaké vlákno počítá se signalizací ukončení při ukončování JVM, může si samo zaregistrovat háček (ale ne z konstruktoru!)
  - použití jednoho velkého háčku: odpadá problém se synchronizací, možnost zajištění definovaného pořadí ukončování komponent

# Ukončování JVM

- Démonická vlákna

- metoda `setDaemon()`
- démonický stav se dědí
- ukončování JVM: pokud běží jen démonická vlákna, JVM se normálně ukončí
  - ◆ neprovedou se bloky `finally`
  - ◆ neprovede se vyčištění zásobníku
- příklad: garbage collection, čištění dočasné paměťové cache
- **nepoužívat z lenosti!**

- Finalizers

- týká se objektů s netriviální metodou `finalize()`
  - ◆ obtížné napsat správně
  - ◆ musí být synchronizovány
  - ◆ není garantováno pořadí
  - ◆ výkonnostní penalta
  - ◆ obvykle jde nahradit pomocí bloku `finally` a explicitního uvolnění zdrojů
- po doběhnutí háčku se spustí finalizers pokud `runFinalizersOnExit == true`
- **vyhýbat se jim!**

# Typy úloh pro TPE

- Nezávislé úlohy – ideální
- Problémy
  - závislost/komunikace úloh zaslanych do jednoho TPE
    - ◆ ohraničená velikost TPE
  - jednovláknový executor → TPE
  - úlohy citlivé na latenci odpovědi
    - ◆ ohraničená velikost TPE
    - ◆ dlouho běžící úlohy
  - problém s úlohami využívajícími `ThreadLocal`
    - ◆ recyklace vláken
  - nestejně velké úlohy v jednom TPE

## Typy úloh pro TPE

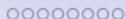
Je tohle správně?

```
1  static ExecutorService exec = Executors.newSingleThreadExecutor();
2
3  public static class RenderPageTask implements Callable<String> {
4      public String call() throws Exception {
5          Future<String> header, footer;
6          header = exec.submit(new LoadFileTask("header.html"));
7          footer = exec.submit(new LoadFileTask("footer.html"));
8          String page = renderBody();
9          return header.get() + page + footer.get();
10     }
11
12     private String renderBody() {
13         return " body ";
14     }
15 }
```

# Typy úloh pro TPE

ANO

```
1      ExecutorService mainExec = Executors.newSingleThreadExecutor();
2      Future<String> task = mainExec.submit(new RenderPageTask());
3      try {
4          System.out.println("Vysledek: " + task.get());
5      } catch (InterruptedException e) {
6          e.printStackTrace();
7      } catch (ExecutionException e) {
8          e.printStackTrace();
9      }
10     exec.shutdown();
11     mainExec.shutdown();
```



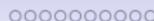
# Typy úloh pro TPE

NE

```
1      Future<String> task = exec.submit(new RenderPageTask());
2      try {
3          System.out.println("Vysledek: " + task.get());
4      } catch (InterruptedException e) {
5          e.printStackTrace();
6      } catch (ExecutionException e) {
7          e.printStackTrace();
8      }
9      exec.shutdown();
```

# Typy úloh pro TPE

- Nezávislé úlohy – ideální
- Problémy
  - závislost/komunikace úloh zaslanych do jednoho TPE
    - ◆ ohraničená velikost TPE
  - jednovláknový executor → TPE
  - úlohy citlivé na latenci odpovědi
    - ◆ ohraničená velikost TPE
    - ◆ dlouho běžící úlohy
  - problém s úlohami využívajícími `ThreadLocal`
    - ◆ recyklace vláken
  - nestejně velké úlohy v jednom TPE



# Velikost TPE

- Doporučení Javy:  $N_{CPU} + 1$  pro výpočetní úlohy
- Obecněji

$$N_{vlaken} = N_{CPU} \cdot U_{CPU} \cdot \left(1 + \frac{W}{C}\right)$$

kde  $U_{CPU}$  je cílové využití CPU,  $W$  je čas čekání,  $C$  je výpočetní čas

- `Runtime.getRuntime().availableProcessors();`

# Vytváření a ukončování vláken v TPE

- **corePoolSize** – cílová velikost zásobárny vláken
  - startují se, až jsou potřeba (default policy)
  - **prestartCoreThread()** – nashoduje jedno core vlákno a vrátí **boolean**, zda se povedlo
  - **prestartAllCoreThreads()** – nashoduje všechna core vlákna a vrátí jejich počet
- **maximumPoolSize** – maximální velikost zásobárny vláken
- **keepAliveTime** – doba lelkujícího života
  - od Javy 6: **allowCoreThreadTimeOut** – dovoluje timeout i core vláknům

## Správa front v TPE

- Kdy se množí vlákna v TPE?
  - pokud je fronta **plná**
  - co se stane, pokud `corePoolSize = 0` a používáme neomezenou frontu?
- Použití synchronní fronty
  - `SynchronousQueue` není fronta v pravém slova smyslu!
  - synchronní předávání dat mezi úlohami
  - pokud žádné vlákno na předání úlohy nečeká, TPE natvoří nové
  - při dosažení limitu se postupuje podle saturační politiky
  - lze použít při neomezeném počtu vláken (`Executors.newCachedThreadPool`) nebo pokud je akceptovatelné použití saturační politiky
  - efektivní (čas i zdroje) – `Executors.newCachedThreadPool` je efektivnější než `Executors.newCachedThreadPool`, který využívá `LinkedBlockingQueue`
  - implementováno pomocí neblokujícího algoritmu v Java 6, 3× větší výkon než Java 5

# Správa front v TPE

- Použití prioritní fronty
  - task musí implementovat `Comparable` (přirozené pořadí) nebo `Comparator`
- Saturační politiky
  - nastupuje v okamžiku zaplnění fronty
  - nastavuje se pomocí `setRejectedExecutionHandler` nebo konstruktoru TPE
  - `AbortPolicy` – default, úloha dostane `RejectedExecutionException`
  - `CallerRunsPolicy` – využití volajícího vlákna
    - ◆ řízení formou zpětné vazby
  - `DiscardPolicy` – vyhodí nově zaslanou úlohu
  - `DiscardOldestPolicy` – vyhodí „nejstarší“ úlohu
    - ◆ vyhazuje z hlavy front  $\implies$  nevhodné pro použití s prioritními frontami
    - ◆ pomáhá vytlačit problém do vnějších vrstev: např. pro web server – nemůže zavolat další `accept` – spojení čekají v TCP stacku

## Správa front v TPE

```

2      ThreadPoolExecutor tpe =
          new ThreadPoolExecutor(1, 10, 60, TimeUnit.SECONDS,
          new LinkedBlockingQueue<Runnable>(100));
4      tpe.setRejectedExecutionHandler
          (new ThreadPoolExecutor.CallerRunsPolicy());
  
```

- Implementace omezení plnění fronty pomocí semaforu
  - semafor se nastaví na požadovanou velikost fronty + počet běžících úloh

```

1  @ThreadSafe
   public class BoundedExecutor {
3      private final Executor exec;
       private final Semaphore semaphore;

5

       public BoundedExecutor(Executor exec, int bound) {
7          this.exec = exec;
           this.semaphore = new Semaphore(bound);
9      }
  
```

## Správa front v TPE

```
public void submitTask(final Runnable command)
2     throws InterruptedException {
3     semaphore.acquire();
4     try {
5         exec.execute(new Runnable() {
6             public void run() {
7                 try {
8                     command.run();
9                 } finally {
10                    semaphore.release();
11                }
12            }
13        });
14    } catch (RejectedExecutionException e) {
15        semaphore.release();
16    }
}
```

# Kvízy

1. Zkuste navrhnout a implementovat thread pool, který se bude dynamicky zvětšovat/zmenšovat podle počtu čekajících požadavků ve frontě.
2. Zkuste rozmyslet a navrhnout, jak by bylo možno implementovat afinitu k procesoru u Javovských vláken a za jakých okolností by tato konstrukce fungovala.

# Java NIO

- Zavedeno v Javě 1.4 (JSR 51)
- Abstraktní třída **Buffer**
  - umožňuje držet pouze primitivní typy

```
ByteBuffer  
CharBuffer  
DoubleBuffer  
FloatBuffer  
IntBuffer  
LongBuffer  
ShortBuffer
```

- direct vs. non-direct buffery
  - přímé buffery se snaží vyhnout zbytečným kopiím mezi JVM a systémem
- vytváření pomocí metod
  - `allocate` – alokace požadované velikosti
  - `allocateDirect` – alokace požadované velikosti typu `direct`
  - `wrap` – zabalí existující pole bytů (`bytearray`)



# Java NIO

- **ByteBuffer**

- <http://download.oracle.com/javase/6/docs/api/java/nio/ByteBuffer.html>
- přístup k binárním datům, např.

```
float getFloat()  
float getFloat(int index)  
void putFloat(float f)  
void putFloat(int index, float f)
```

- mapování souborů do paměti (`FileChannel`, metoda `map`)
- čtení/vložení z/do bufferu bez parametru `index` (`get/put`) inkrementuje pozici
- pokud není řečeno jinak, metody vrací odkaz na buffer – řetězení volání

```
buffer.putShort(10).putInt(0x00ABBCCD).putShort(11);
```

# Java NIO

- Vlastnosti bufferů

**capacity** celková kapacita bufferu

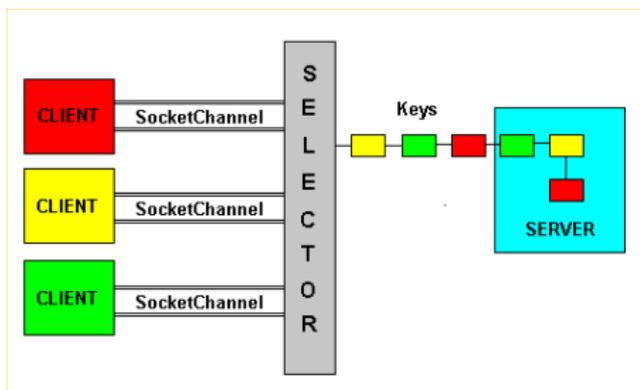
**limit** umělý limit uvnitř bufferu, využití s metodami `flip`  
(nastaví limit na současnou pozici a skočí na pozici 0)  
Či `remaining`

**mark** pomocná značka, využití např. s metodou `reset` (skočí na označovanou pozici)

```
buffer.position(10);  
2 buffer.flip();  
while (buffer.hasRemaining()) {  
4 byte b = buffer.get();  
  // neco  
6 }
```

# Java NIO

- Selektor
  - serializace požadavků
  - výběr požadavků
- Klíč
  - identifikace konkrétního spojení



Zdroj: <http://onjava.com/lpt/a/2672>

# Java NIO – Server

- Generický postup

```
1 create SocketChannel;
2 create Selector
3 associate the SocketChannel to the Selector
4 for(;;) {
5     waiting events from the Selector;
6     event arrived; create keys;
7     for each key created by Selector {
8         check the type of request;
9         isAcceptable:
10            get the client SocketChannel;
11            associate that SocketChannel to the Selector;
12            record it for read/write operations
13            continue;
14        isReadable:
15            get the client SocketChannel;
16            read from the socket;
17            continue;
18        isWritable:
19            get the client SocketChannel;
20            write on the socket;
21            continue;
22    }
23 }
```



## Java NIO – Server

```
1 // Create the server socket channel
  ServerSocketChannel server = ServerSocketChannel.open();
3 // nonblocking I/O
  server.configureBlocking(false);
5 // host-port 8000
  server.socket().bind(new java.net.InetSocketAddress(host, 8000));
7 // Create the selector
  Selector selector = Selector.open();
9 // Recording server to selector (type OP_ACCEPT)
  server.register(selector, SelectionKey.OP_ACCEPT);
```

Zdroj: <http://onjava.com/lpt/a/2672>

## Java NIO – Server

```
2 // Infinite server loop
3 for(;;) {
4     // Waiting for events
5     selector.select();
6     // Get keys
7     Set keys = selector.selectedKeys();
8     Iterator i = keys.iterator();
9
10    // For each keys...
11    while(i.hasNext()) {
12        SelectionKey key = (SelectionKey) i.next();
13
14        // Remove the current key
15        i.remove();
16
17        // if isAcettable = true
18        // then a client required a connection
19        if (key.isAcceptable()) {
20            // get client socket channel
21            SocketChannel client = server.accept();
22            // Non Blocking I/O
23            client.configureBlocking(false);
24            // recording to the selector (reading)
25            client.register(selector, SelectionKey.OP_READ);
26            continue;
27        }
28    }
29 }
```

## Java NIO – Server

```
2 // if isReadable = true
3 // then the server is ready to read
4 if (key.isReadable()) {
5
6     SocketChannel client = (SocketChannel) key.channel();
7
8     // Read byte coming from the client
9     int BUFFER_SIZE = 32;
10    ByteBuffer buffer = ByteBuffer.allocate(BUFFER_SIZE);
11    try {
12        client.read(buffer);
13    }
14    catch (Exception e) {
15        // client is no longer active
16        e.printStackTrace();
17        continue;
18    }
19
20    // Show bytes on the console
21    buffer.flip();
22    Charset charset=Charset.forName('' ISO-8859-1'' );
23    CharsetDecoder decoder = charset.newDecoder();
24    CharBuffer charBuffer = decoder.decode(buffer);
25    System.out.print(charBuffer.toString());
26    continue;
27 }
28 }
```

# Java NIO

- Další čtení:
  - <http://onjava.com/lpt/a/2672>
  - <http://onjava.com/lpt/a/5127>
  - <http://download.oracle.com/javase/6/docs/api/java/nio/channels/Selector.html>
  - <http://download.oracle.com/javase/6/docs/api/java/nio/channels/SelectionKey.html>

# Asynchronní programování versus vlákna

- Asynchronní programování
  - + umožňuje obsluhovat řádově větší množství klientů
  - za cenu zvýšení latence
  - složitější, náchylnější na chyby
- Vlákňové programování
  - + jednodušší
  - + poměrně efektivní do „rozumného“ počtu vláken
  - nativní vlákna nejsou stavěna na (deseti)tisíce vláken a více
- Potenciálně lze kombinovat