

Vláknové programování

část VII

Lukáš Hejmánek, Petr Holub
`{xhejtman, hoper}@ics.muni.cz`



Laboratoř pokročilých sítových technologií

PV192
2011–04–07

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 vlákně

```
1  public class PrikladRunnable {  
2      static class RunnableVlakno implements Runnable {  
3          public void run() {  
4              System.out.println("Tu je vlakno.");  
5          }  
6      }  
7  
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("Spustim primo v hlavnim vlakne: ");  
13         new RunnableVlakno().run();  
14     }  
15 }
```

Runnable vs. Callable

- Interface Callable<V>

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

```
1 import java.util.concurrent.Callable;  
2  
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();
15                for(int j = 0; j < max; j++) { j += 2; j--; }
16                System.out.println("Dobehlo vlakno s max = " + max);
                }
            });
18        }
19    try {
20        Thread.sleep(10000);
21        executor.shutdown();
22        executor.awaitTermination(1000, TimeUnit.SECONDS);
23    } catch (InterruptedException e) {
24    }
25}
26}
```

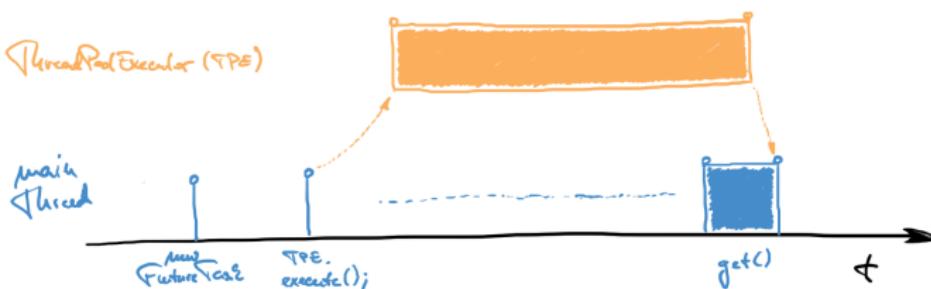
Futures

- Princip:

- někdy v budoucnu bude volající potřebovat výsledek výpočtu X
- v době, kdy si volající řekne o výsledku 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.*;  
2  
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: Pouštím výpočet.");  
17        tpe.execute(ft);  
18        // alternativa: Future ft = tpe.submit(new StringCallable());  
19        try {  
20            System.out.println("main: Chci výsledek.");  
21            String s = (String) ft.get();  
22            System.out.println("main: Mam výsledek: " + s);  
23            tpe.shutdown();  
24            tpe.awaitTermination(1, TimeUnit.MINUTES);  
25        } catch (InterruptedException e) {}  
26        catch (ExecutionException e) {}  
27    }  
}
```

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>();
    3   CompletionService<FileData> completionService =
    4       new ExecutorCompletionService<FileData>(
    5           new ThreadPoolExecutor(1, 10, 60, TimeUnit.SECONDS,
    6               new LinkedBlockingQueue<Runnable>()));
    7   for (final String s : list) {
    8       completionService.submit(new Callable<FileData>() {
    9           public FileData call() throws Exception {
    10              FileData fd = new FileData();
    11              fd.s = s; fd.data = getFile(s);
    12              return fd;
    13          }
    14      });
    15  }
    16  try {
    17      for (int i = 0, size = list.size(); i < size; i++) {
    18          Future<FileData> f = completionService.take();
    19          ald.add(f.get());
    20      }
    21  } catch (InterruptedException e) {
    22      Thread.currentThread().interrupt();
    23  } catch (ExecutionException e) { launderThrowable(e.getCause()); }
    24  return ald;
}
```

Futures vs. CompletionService

```
1  public static RuntimeException launderThrowable(Throwable t) {  
2      if (t instanceof RuntimeException)  
3          return (RuntimeException) t;  
4      else if (t instanceof Error)  
5          throw (Error) t;  
6      else  
7          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 {  
2     public void interrupt() {...}  
3     public boolean isInterrupted() {...}  
4     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 přerušení vlákna
 - 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);
    7     try {
    8       task.get(120, TimeUnit.SECONDS);
    9     } catch (ExecutionException e) {
    10       throw new RuntimeException(e.getMessage());
    11     } catch (TimeoutException e) {
    12       // úloha bude ukoncena nize
    13     }
    14   finally {
    15     // neskedne, pokud úloha skoncila,
    16     // jinak interrupt
    17     task.cancel(true);
    18   }
}
```

Nepřerušitelná blokování

- Existují blokování, která nereagují na `interrupt`
- Příklady:
 - synchronní socketové 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
 - ◆ *obejítí:* explicitní zámky `Lock` podporují metodu `lockInterruptibly`

Nepřerušitelná blokování

- Další vychytávky:

- synchronní I/O v `java.nio`
 - ◆ přerušení 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;
3     private final LoggerThread logger;
4     private volatile boolean shutdownRequested = false;
5
6     public LogWriter() throws FileNotFoundException {
7         this.queue = new LinkedBlockingQueue<String>();
8         this.logger = new LoggerThread(new PrintWriter("mujSoubor"));
9         logger.start();
10    }
11
12    private class LoggerThread extends Thread {
13        private final PrintWriter writer;
14
15        private LoggerThread(PrintWriter writer) {
16            super("Logger Thread");
17            this.writer = writer;
18        }
19
20        public void run() {
21            try {
22                while (true)
23                    writer.println(queue.take());
24            } catch (InterruptedException ignored) {
25            } finally {
26                writer.close();
27            }
28        }
29    }
30}
```

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");
}
```

- 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 ukoncuje");  
}
```



- ... není!
- Race condition
 - složené testování podmínky a volání metod!
- 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);
}
```

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 bežící úlohy a nové už nestartovala
- zapouzdření do vlastního ukončování:

```
exec.shutdown();  
exec.awaitTermination(timeout, unit);
```
- využití i pro jednoduchá vlákna: `newSingleThreadExecutor()`

Zastavování vláknových služeb

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

...

```
2     public List<Runnable> getCancelledTasks() {  
3         if (!exec.isTerminated())  
4             throw new IllegalStateException(/*....*/);  
5         return new ArrayList<Runnable>(tasksCancelledAtShutdown);  
6     }  
7  
8     public void execute(final Runnable runnable) {  
9         exec.execute(new Runnable() {  
10            public void run() {  
11                try {  
12                    runnable.run();  
13                } finally {  
14                    if (isShutdown()  
15                        && Thread.currentThread().isInterrupted())  
16                        tasksCancelledAtShutdown.add(runnable);  
17                }  
18            }  
19        });  
20    }
```

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`

```
1   Throwable thrown = null;
2   try {runTask(getTaskFromQueue());}
3   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 ≥ 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 zaslaných do jednoho TPE
 - ◆ ohraničená velikost TPE
 - jednovlákновý 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?

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

Typy úloh pro TPE

ANO

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

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 zaslaných 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 výpočení úlohy
- Obecněji

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

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()` – nastartuje jedno core vlákno a vrátí `boolean`, zda se povedlo
 - `prestartAllCoreThreads()` – nastartuje 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.newFixedThreadPool`, 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

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

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

```
1 @ThreadSafe
2 public class BoundedExecutor {
3     private final Executor exec;
4     private final Semaphore semaphore;
5
6     public BoundedExecutor(Executor exec, int bound) {
7         this.exec = exec;
8         this.semaphore = new Semaphore(bound);
9     }
}
```

Správa front v TPE

```
1    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               } catch (RejectedExecutionException e) {
14                   semaphore.release();
15               }
16           }
```

Kvízy

1. Zkuste navrhnout a implementovat thread pool, který se bude dynamický 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 vyhýbat zbytečným kopiiím 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

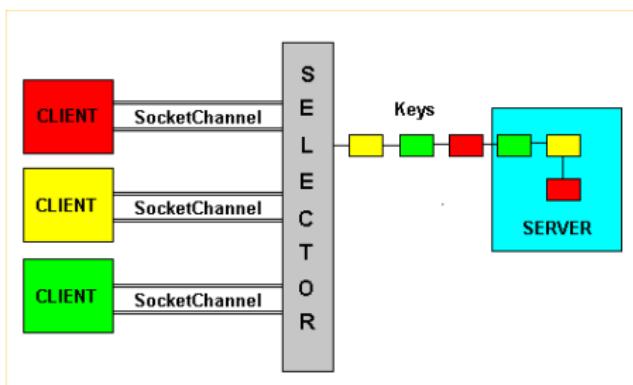
limit umělý limit uvnitř bufferu, využití s metodami `flip`
(nastaví limit na současnou pozici a skočí na pozici 0)
Či `remaining`

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

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

Java NIO

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



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

Java NIO – Server

- Generický postup

```
create SocketChannel;
2 create Selector
associate the SocketChannel to the Selector
4 for(;;) {
    waiting events from the Selector;
6 event arrived; create keys;
    for each key created by Selector {
8     check the type of request;
     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     isWriteable:
19      get the client SocketChannel;
20      write on the socket;
21      continue;
22 }
```

Java NIO – Server

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

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

Java NIO – Server

```
// Infinite server loop
2  for(;;) {
3      // Waiting for events
4      selector.select();
5      // Get keys
6      Set keys = selector.selectedKeys();
7      Iterator i = keys.iterator();

8      // For each keys...
9      while(i.hasNext()) {
10          SelectionKey key = (SelectionKey) i.next();

11          // Remove the current key
12          i.remove();

13          // if isAcceptable = true
14          // then a client required a connection
15          if (key.isAcceptable()) {
16              // get client socket channel
17              SocketChannel client = server.accept();
18              // Non Blocking I/O
19              client.configureBlocking(false);
20              // recording to the selector (reading)
21              client.register(selector, SelectionKey.OP_READ);
22              continue;
23          }
24      }
25  }
```

Java NIO – Server

```
// if isReadable = true
2   // then the server is ready to read
if (key.isReadable()) {

4     SocketChannel client = (SocketChannel) key.channel();

6       // Read byte coming from the client
8       int BUFFER_SIZE = 32;
10      ByteBuffer buffer = ByteBuffer.allocate(BUFFER_SIZE);
12      try {
13        client.read(buffer);
14      }
15      catch (Exception e) {
16        // client is no longer active
17        e.printStackTrace();
18        continue;
19      }

21      // Show bytes on the console
22      buffer.flip();
23      Charset charset=Charset.forName('' ISO-8859-1 '');
24      CharsetDecoder decoder = charset.newDecoder();
25      CharBuffer charBuffer = decoder.decode(buffer);
26      System.out.print(charBuffer.toString());
27      continue;
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
- Vláknové programování
 - + jednodušší
 - + poměrně efektivní do „rozumného“ počtu vláken
 - nativní vlákna nejsou stavěna na (deseti)tišicí vláken a více
- Potenciálně lze kombinovat