

Vláknové programování

část VIII

Lukáš Hejtmánek, Petr Holub
{`xhejtman`, `hopet`}@ics.muni.cz



Laboratoř pokročilých síťových technologií

PV192
2010-03-23

Přehled přednášky

Úlohy a vlákna

Ukončování a přerušování

ThreadPoolExecutors Revisited

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)

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

Futures vs. CompletionService

```
2 public static RuntimeException launderThrowable(Throwable t) {  
3     if (t instanceof RuntimeException)  
4         return (RuntimeException) t;  
5     else if (t instanceof Error)  
6         throw (Error) t;  
7     else  
8         throw new IllegalStateException("Not unchecked", t);  
9 }
```

Ukončování a přerušování pro pokročilé

- Kooperativní ukončování vláken
 - příznakem proměnné
 - přerušením – interrupt
 - **Thread.stop** – deprecated
- Důvody ukončení vlákna
 - uživatelem vyvolané (GUI, JMX)
 - časově omezené úlohy
 - události uvnitř – několik vláken hledá řešení paralelně, jedno 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?

Přerušování – interrupt

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

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

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

Omezený běh – Futures

- `Future` má metodu `cancel(boolean mayInterruptIfRunnig)`
 - `mayInterruptIfRunnig = true` znamená, že se má běžící úloha přerušit
 - `mayInterruptIfRunnig = false` znamená, že se pouze nemá spustit, pokud ještě neběží
 - vrací, zda se ukončení povedlo
- Kdy můžeme použít `mayInterruptIfRunnig = true`?
 - pokud známe politiku přerušování 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);
      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
 - ◆ přerušení vyháží u všech zablokovaných vláken `ClosedByInterruptException`, pokud je kanál typu `InterruptibleChannel`
 - ◆ zavření vyháží 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>();
8       this.logger = new LoggerThread(new PrintWriter("mujSoubor"));
       logger.start();
10  }

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

14

16  private LoggerThread(PrintWriter writer) {
       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");  
}
```



- ... 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 {  
3     private final ExecutorService exec;  
4     private final Set<Runnable> tasksCancelledAtShutdown =  
        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`

```
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?

```
2      static ExecutorService exec = Executors.newSingleThreadExecutor();
3
4      public static class RenderPageTask implements Callable<String> {
5          public String call() throws Exception {
6              Future<String> header, footer;
7              header = exec.submit(new LoadFileTask("header.html"));
8              footer = exec.submit(new LoadFileTask("footer.html"));
9              String page = renderBody();
10             return header.get() + page + footer.get();
11         }
12
13         private String renderBody() {
14             return " body ";
15         }
16     }
```


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

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

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()` – nastaruje 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.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 konstrukturu 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

```
ThreadPoolExecutor tpe =  
2     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

```
2 public void submitTask(final Runnable command)
3     throws InterruptedException {
4     semaphore.acquire();
5     try {
6         exec.execute(new Runnable() {
7             public void run() {
8                 try {
9                     command.run();
10                } finally {
11                    semaphore.release();
12                }
13            }
14        });
15    } catch (RejectedExecutionException e) {
16        semaphore.release();
17    }
18 }
```