Soubory

Jiří Vokřínek

Katedra počítačů
Fakulta elektrotechnická
České vysoké učení technické v Praze

Přednáška 4

B6B36PJV – Programování v JAVA

Část 1 – Příklad - Generické typy, iterátor

Generické typy

Příklad - Spojový seznam a vlastní iterátor

Příklad - Spojový seznam a generický typ

Část 2 – Soubory

Soubory

Práce se soubory

Čtení a zápis souboru v Javě

Binární soubory

Textové soubory

Část I

Příklad - Generické typy, iterátor

Generické typy a nevýhody polymorfismu

- Flexibilita (znovupoužitelnost) tříd je tradičně v Javě řešena dědičností a polymorfismem
- Polymorfismus nám dovoluje vytvořit třídu (např. nějaký kontejner), která umožňuje uložit libovolný objekt (jako referenci na objekt typu **Object**)

Např. **ArrayList** z JFC

- Dynamická vazba polymorfismu však neposkytuje kontrolu správného (nebo očekávaného) typu během kompilace
- Případná chyba v důsledku „špatného" typu se tak projeví až za běhu programu
- Tato forma polymorfismu také vyžaduje explicitní přetypování objektu získaného z obecné kolekce

Například zmiňovaný `ArrayList` pro ukládání objektů typu `Object`.

Generické typy

- Java 5 dovoluje použít generických tříd a metod
- Generický typ umožňuje určit typ instance tříd, které lze do kolekce ukládat
- Generický typ tak poskytuje statickou typovou kontrolu během překladu

- Generické typy představují parametrizované definice třídy typu nějaké datové položky
- Parametr typu se zapisuje mezi <>, například

```
List<Participant> partList = new ArrayList<Participant>();
```

http://docs.oracle.com/javase/tutorial/java/generics/index.html

Příklad – generický a negenerický typ

```
ArrayList participants;
participants = new ArrayList();
participants.push(new PlayerRed());

// vlozit libovolny objekt je mozne
participants.push(new Bet());


ArrayList<Participant> participants2;
participants2 = new ArrayList<Participant>();
participants2.push(new PlayerRed());

// nelze prelozit
// typova kontrola na urovni prekladace
participants2.push(new Bet());
```

Příklad implementace spojového seznamu

- Třída **LinkedList** pro uchování objektů
- Implementujeme metody **push** a **print**

```
public class LinkedList {
    class ListNode {
        ListNode next;
        Object item;
        ListNode(Object item) { ... }
    }

    ListNode start;

    public LinkedList() { ... }
    public LinkedList push(Object obj) { ... }
    public void print() { ... }
}
```

lec04/LinkedList

Příklad použití

- Do seznamu můžeme přidávat libovolné objekty, např. **String**
- Tisk seznamu však realizuje vlastní metodou **print**

```
LinkedList lst = new LinkedList();
lst.push("Joe");
lst.push("Barbara");
lst.push("Charles");
lst.push("Jill");

lst.print();
```

- Využití konstrukce **for-each** vyžaduje, aby třída **LinkedList** implementovala rozhraní **Iterable**

```
for (Object o : lst) {
   System.out.println("Object:" + o);
}
```

Rozhraní Iterable a Iterator

- Rozhraní **Iterable** předepisuje metodu **iterator**, která vrací iterátor instanci třídy implementující rozhraní **Iterator**
- **Iterator** je objekt umožňující postupný přístup na položky seznamu
- Rozšíříme třídu **LinkedList** o implementaci rozhraní **Iterable** a vnitřní třídu `LLIterator` implementující rozhraní **Iterator**

http://docs.oracle.com/javase/tutorial/java/javaOO/innerclasses.html

```
public class LinkedListIterable extends LinkedList
    implements Iterable {

   private class LLIterator implements Iterator { ... }

   @Override
   public Iterator iterator() {
      return new LLIterator(start); //kurzor <- start
} }
```

lec04/LinkedListIterable

Implementace rozhraní **Iterator**

- Rozhraní **Iterator** předepisuje metody **hasNext** a **next**

```
private class LLIterator implements Iterator {
    private ListNode cur;

    private LLIterator(ListNode cur) {
        this.cur = cur; // nastaveni kurzoru
    }

    @Override
    public boolean hasNext() {
        return cur != null;
    }

    @Override
    public Object next() {
        if (cur == null) {
            throw new NoSuchElementException();
        }
        Object ret = cur.item;
        cur = cur.next; //move forward
        return ret;
    }
}
```

lec04/LinkedListIterable

Příklad využití iterátoru v příkazu **for-each**

- Nahradíme implementace **LinkedList** za **LinkedListIterable**

```
// LinkedList lst = new LinkedList();
LinkedListIterable lst = new LinkedListIterable();
lst.push("Joe");
lst.push("Barbara");
lst.push("Charles");
lst.push("Jill");

lst.print();

for (Object o : lst) {
   System.out.println("Object:" + o);
}
```

lec04/LinkedListDemo

Spojový seznam specifických objektů

- Do spojového seznamu **LinkedList** můžeme ukládat libovolné objekty, což má i přes své výhody také nevýhody:
  - Nemáme statickou typovou kontrolu prvků seznamu
  - Musíme objekty explicitně přetypovat, například pro volání metody **toNiceString** objektu **Person**

```
public class Person {

    private final String name;
    private final int age;

    public Person(String name, int age) { ... }
    public String toNiceString() {
        return "Person name: " + name + " age: " + age;
    }
}
```

Příklad přetypování na **Person**

```
LinkedListIterable lst = new LinkedListIterable();
lst.push(new Person("Joe", 30));
lst.push(new Person("Barbara", 40));
lst.push(new Person("Charles", 50));
lst.push(new Person("Jill", 60));

for (Object o : lst) {
    System.out.println("Object: " + ((Person)o).
     toNiceString());
}
```

Generický typ

- Využitím generického typu můžeme předepsat konkrétní typ objektu
- Vytvoříme proto LinkedList přímo jako generický typ deklarací `class LinkedListGeneric<E>` a záměnou **Object** za **E**

```
public class LinkedListGeneric<E> {
    class ListNode {
        ListNode next;
        E item;
        ListNode(E item) { ... }
    }
    ListNode start
    public LinkedListGeneric() { ... }
    public LinkedListGeneric push(E obj) { ... }
    public void print() { ... }
}
```

lec04/LinkedListGeneric

Generický typ – Iterable a Iterator

- Podobně upravíme odvozený iterátor a doplníme typ také v rozhraní **Iterable** a **Iterator**

```
public class LinkedListGenericIterable<E> extends
    LinkedListGeneric<E> implements Iterable<E> {

  // vnitni trida pro iterator
  private class LLIterator implements Iterator<E> { ... }

  @Override
  public Iterator iterator() {
     return new LLIterator(start);
  }
}
```

lec04/LinkedListGenericIterable

Generický typ – Iterator

- Implementace iterátoru je identická jako v případě `LinkedListIterable`

```
private class LLIterator implements Iterator<E> {

    private ListNode cur;

    private LLIterator(ListNode cur) {
        this.cur = cur;
    }
    @Override
    public boolean hasNext() {
        return cur != null;
    }
    @Override
    public E next() {
        if (cur == null) {
            throw new NoSuchElementException();
        }
        E ret = cur.item;
        cur = cur.next; //move forward
        return ret;
    }
}
```

lec04/LinkedListGenericIterable

Příklad použití

```
LinkedListGenericIterable<Person> lst = new
    LinkedListGenericIterable();

lst.push(new Person("Joe", 30));
lst.push(new Person("Barbara", 40));
lst.push(new Person("Charles", 50));
lst.push(new Person("Jill", 60));

lst.print();

for (Person o : lst) {
   System.out.println("Object: " + o.toNiceString());
}
```

lec04/LinkedListGenericDemo

Část II

Soubory

Soubory a organizace dat v souborovém systému

- Soubor je množina údajů uložená ve vnější paměti počítače

  Obvykle na pevném disku

- Typické operace pro soubor jsou:
  1. Otevření souboru
  2. Čtení dat
  3. Zápis dat
  4. Zavření souboru
- Přístup k datům (údajům) v souboru může být
  - Sekvenční (postupný)

    Postupné čtení nebo zápis dat do souboru

  - Náhodný (adresovatelný)

    Umožňuje adresovat libovolné místo v souboru podobně jako při přístupu do pole

- Způsob přístup k údajům v souboru není zakódován v souboru, ale je dán programem

  Podobně také případ, zdali soubor „chápeme" jako textový nebo binární.

Adresa (cesta) k souboru

- Soubory jsou uloženy v souborovém systému
- Soubory organizujeme do složek (adresářů), které tvoří hierarchii adresářů a souborů tvořící stromovou strukturu

  Lze sice vytvořit i cykly, zpravidla je to však speciální případ.
- Souborový systém představuje „adresovatelný" prostor, kde
- ke každému souboru existuje „adresa" identifikující v jakém adresáři (složce) se soubor nachází
- Adresa je složena ze jmen jednotlivých adresářů oddělených znakem /

  Podobně jako URL

  např. **/usr/local/bin/netbeans-8.0** – představuje cestu k
  - **netbeans-8.0** – soubor pro spuštění programu Netbeans
  - **bin** – adresář v adresáři **local**
  - **local** – adresáři v adresáři **usr**
  - / – kořenový adresář

  Umístění souboru tak můžeme jednoznačně určit

Umístění souboru – absolutní a relativní cesta

- Adresa absolutního umístění souboru v systému souborů začíná kořenovým adresářem **/**
- Cesta k souboru může být také relativní vzhledem k nějakému pracovnímu (např. projektovému) adresáři
- Speciální význam mají adresáře
  - **..** – odkazuje do adresáře o úroveň výše
  - **.** – je aktuální adresář
- Příklady
  - **/usr/local/bin/netbeans**
  - Relativní cesta vzhledem k **/usr/local/tmp** je **../bin/netbeans**
  - Relativní cesta vzhledem k **/usr/local/bin** je
    - **netbeans**
    - **./netbeans**

Typy souborů

Podle způsobu kódování informace v souboru rozlišujeme:

- Textové soubory
  - Přímo čitelné a jednoduše editovatelné

    Běžným textovým editorem
- Binární soubory
  - Zpravidla potřebujeme specializovaný program pro čtení, zápis a modifikaci souboru
  - Přístup k souboru tak spíše realizujeme prostřednictvím programového rozhraní

V obou případech je pro výměnu souboru a jejich použitelnost v jiných programech klíčový konkrétní způsob organizace údajů a informací uložených v souborech

Používání standardních formátů a to jak textových (např. XML, HTML, JSON, CSV), tak binárních (např. HDF).

Textové soubory

- Textový soubor je posloupnost znaků členěná na řádky

  Zpravidla členěná na řádky. Není to nutné, ale zvyšuje čitelnost a usnadňuje zpracování souboru (po řádcích).

- EOL (End of Line) – znak konce řádku
- EOL je platformově závislý
  - CR – Carriage Return – Macintosh – "\r" – 0x0d
  - LF – Line Feed – Unix – "\n" – 0x0a
  - CR/LF – MS-DOS, Windows – "\r\n" – 0x0d 0x0a
- Každý znak je reprezentován jedním bajtem, případně 2 nebo více bajty

Viz znakové sady a kódování

Binární soubory

- Binární soubor je posloupnost bajtů
- Informace v binárním souboru je kódována vnitřním kódem počítače
- Do binárního souboru mohou být zapsány
  - bajt (byte)
  - jednoduché proměnné
  - pole
  - data celých objektů

V Javě lze využít tzv. serializace

Informace o typu souboru ani o způsobu kódování informací v něm uložených není v souboru obsažena. Správnou interpretaci přečteného souboru musí zajistit uživatelský program.

Binární soubory

- Binární soubor je posloupnost bajtů
- Informace v binárním souboru je kódována vnitřním kódem počítače
- Do binárního souboru mohou být zapsány
  - bajt (byte)
  - jednoduché proměnné
  - pole
  - data celých objektů

V Javě lze využít tzv. serializace

Informace o typu souboru ani o způsobu kódování informací v něm uložených není v souboru obsažena. Správnou interpretaci přečteného souboru musí zajistit uživatelský program.

Přístup k souborům

- Přenos informace (dat) z/do souboru lze rozdělit do několika vrstev
- Vrstva může poskytovat různý pohled na obsah souboru
- V základním pohledu je každý soubor **posloupnost bytů**
- Čtení ze souboru

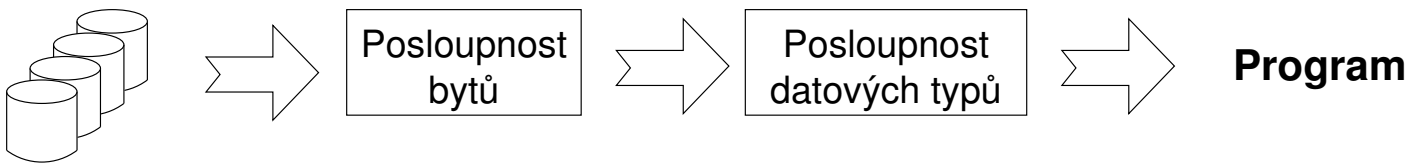

- Zápis do souboru

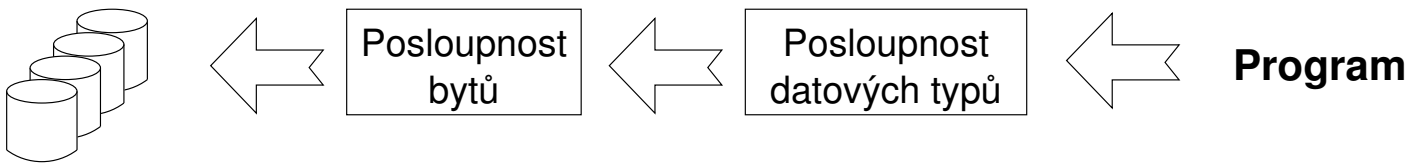

Výhoda vrstveného přístupu je v možnosti jednoduše přidávat nové způsoby zpracování dat.

- K datům v souboru můžeme přistupovat dvěma základními způsoby: **sekvenčně** a **přímým** (náhodným) přístupem

Sekvenční přístup

- Při sekvenčním přístupu jsou jednotlivé byty načítány postupně
- Během načítání bytů mohou být data postupně interpretovaná

  Např. po přečtení 4 bytů je možné interpretovat takovou posloupnost jako celé číslo typu **int**.
- Na aktuální pozici v souboru ukazuje tzv. **kurzor**
- Každé další čtení ze souboru vrací příslušný počet přečtených bytů a o stejný počet bytů je kurzor posunut
- Při načítání se lze "vracet" pouze na začátek, nelze se vrátit např. o několik bytů zpět
- Při zápisu jsou postupně ukládány další byty na konec souboru

  Při otevření souboru rozlišujeme kromě otevření pro čtení také otevření pro zápis nebo přidávání (append).
- Sekvenční přístup načítání / zápisu je možné použít i pro jiné vstupy/výstupy než soubory uložené na disku

  Např. Zpracování dat po sériovém portu, Ethernet nebo obecně data z Internetu

Přímý přístup

- Při práci se soubory v přímém přístupu je možné zapisovat / číst na libovolné místo v souboru
- Práce se souborem se tak podobá přístupu k položkám v poli
- **Kurzor** lze libovolně nastavovat v rozsahu velikosti souboru (v bytech)
- Soubor musí být k dispozici

  Vhodné pro soubory, které jsou přístupné na disku, a které lze "celé" kdykoliv načíst do paměti.
- Vhodné pokud známe vnitřní strukturu souboru a můžeme se přímo odkazovat na příslušné místo pro aktualizaci nebo načtení příslušné datové položky

https://docs.oracle.com/javase/tutorial/essential/io/rafs.html

Soubory a proudy

- Java rozlišuje soubory („*files*") a proudy („*streams*")
  - **Soubor** je množina údajů uložená ve vnější paměti počítače
  - **Proud** je přístup (nástroj) k přenosu informaci z/do souboru, ale také z/do libovolného jiného média, které je schopné generovat nebo pojmout data jako posloupnost bytů

    sítě, sériová linka, paměť, jiný program, atd.
- Informace může mít tvar znaků, bytů, skupin bytů, objektů, ...
- Přenos informace se děje ve více vrstvách v proudech (**streams**)
  1. Otevření přenosového proudu pro byty nebo znaky
  2. Otevření přenosového proudu pro datové typy Javy
  3. Filtrace dat podle dalších požadavků, např. bufferovaní, řádkování, atd.

Proudy v Javě (Standardní třídy)

- Bytové – **FileInputStream** / **FileOutputStream**
  - **DataOutputStream** – přenos primitivních datových typů
  - **ObjectOutputStream** – přenos objektů
  - **BufferedOutputStream** – bufferovaní
- Znakové – **FileReader** / **FileWriter**
  - **BufferedReader** – bufferovaní
  - **StreamTokenizer** – tokenizace

`https://docs.oracle.com/javase/8/docs/api/java/io/StreamTokenizer.html`

- **RandomAccessFile** – práce se soubory s náhodným přístupem
- **File** – zprácování souborů/adresářů: test existence, oddělovač adresářů/souborů, vytvoření, mazání, atd.

Využívá služeb operačního systému

- V Javě jsou příslušné třídy definovány v balíku **java.io** případně **java.nio**

Příklad – Soubor jako posloupnost bytů

Vytvoření kopie vstupního souboru

- Vstupní soubor postupně načítáme byte po bytu a ukládáme do výstupního souboru

```
public void demoStreamCopy(String inputFile,
    String outputFile) throws IOException {
  FileInputStream in = new FileInputStream(inputFile);
  FileOutputStream out = new FileOutputStream(
   outputFile);
  int b = in.read(); // read byte of data
  while (b != -1) {
    out.write(b);
    b = in.read();
  }
  out.close();
  in.close();
}
```

DemoFileStream.java

Příklad ošetření chybových stavů

```
try {
    demo.demoStreamCopy(args[0], args[1]);
} catch (FileNotFoundException e) {
    System.err.println("File not found");
} catch (IOException e) {
    System.err.println("Error occured during copying");
    e.printStackTrace();
}
```

- Příklad spuštění programu

```
java DemoCopyException in2.txt out.txt
File not found

java DemoCopyException in.txt out2.txt
Error occured during copying
java.io.IOException: Stream Closed
  at java.io.FileOutputStream.write(Native Method)
  at java.io.FileOutputStream.write(FileOutputStream.java:295)
  at DemoCopyException.demoStreamCopy(DemoCopyException.java:16)
  at DemoCopyException.main(DemoCopyException.java:24)
```

Proč jsou chyby různé?

Příklad – DemoCopyException

```
public void demoStreamCopy(String inputFile, String
    outputFile) throws IOException {
  FileInputStream in = new FileInputStream(inputFile);
  FileOutputStream out = new FileOutputStream(outputFile);
  if (outputFile.equalsIgnoreCase("out2.txt")) {
    out.close();
  }
  int b = in.read(); // read byte of data
  while (b != -1) {
    out.write(b);
    b = in.read();
  }
}
```

DemoCopyException.java

Soubor jako posloupnost primitivních typů – Zápis

- Pro zápis hodnoty základního datového typu jako posloupnost bytů přidáme další vrstvu **DataOutputStream**

```
String fname = args.length > 0 ? args[0] : "out.bin";

DataOutputStream out = new DataOutputStream(
        new FileOutputStream(fname));

for (int i = 0; i < 10; ++i) {
    double d = (Math.random() % 100) / 10.0;
    out.writeInt(i);
    out.writeDouble(d);
    System.out.println("Write " + i + " " + d);
}
```

DemoFilePrimitiveTypesWrite.java

Soubor jako posloupnost primitivních typů – Čtení

```
String fname = args.length > 0 ? args[0] : "out.bin";
DataInputStream in = new DataInputStream(
      new FileInputStream(fname));

for (int i = 0; i < 10; ++i) {
   int v = in.readInt();
   double d = in.readDouble();
   System.out.println("Read " + v + " " + d);
}
```

DemoFilePrimitiveTypesRead.java

Co se stane když zaměníme pořadí načítání **readInt** a **readDouble**?

Soubor primitivních typů a objektů

- Uvedenými metodami lze zapisovat a číst pouze tzv. **serializovatelné objekty**, mezi které patří
  - Primitivní datové typy
  - Řetězce a pole primitivních typů
  - Složitější objekty, pokud implementují rozhraní **Serializable**
- Rozhraní **Serializable** nepředepisuje žádnou metodu, je značkou, že objekt chceme serializovat

  Pro vytvoření příslušné implementace pro převod hodnot do/z posloupnosti bytů.
- Pro serializaci musí být každá datová položka serializovatelná
- nebo označena, že nebude serializována klíčovým slovem **transient**

`https://docs.oracle.com/javase/8/docs/platform/serialization/spec/serialTOC.html`

Informativní

Příklad serializace 1/3

```
import java.io.Serializable;

public class Customer implements Serializable {

    private String name;
    private String surname;
    private int age;

    public Customer(String name, String surname, int age) {
        this.name = name;
        this.surname = surname;
        this.age = age;
    }
}
```

Customer.java

Příklad serializace 2/3

```
void write(Customer customer, String fname) throws
    IOException {
   try (ObjectOutputStream out = new
    ObjectOutputStream(new FileOutputStream(fname))) {
      out.writeObject(customer);
   }
}

Customer read(String fname) throws IOException,
    ClassNotFoundException {
   ObjectInputStream in = new ObjectInputStream(new
    FileInputStream(fname));
   return (Customer) in.readObject();
}
```

DemoObjectSerialization.java

Příklad serializace 3/3

```
Customer customer = new Customer("AAA", "BBB", 47);
System.out.println("Customer: " + customer);
write(customer, fname);
customer = new Customer("ZZZ", "WWW", 17);
System.out.println("Customer: " + customer);
customer = read(fname);
System.out.println("Customer: " + customer);
```

- Příklad výstupu

```
Customer: AAA BBB age: 47
Customer: ZZZ WWW age: 17
Customer: AAA BBB age: 47
```

Soubory s náhodným přístupem 1/2

- Třída **RandomAccessFile** pro zápis/čtení do/z libovolného místa v souboru

```
public void write(String fname, int n) throws
    IOException {

    RandomAccessFile out =
        new RandomAccessFile(fname, "rw");

    for (int i = 0; i < n; ++i) {
        out.writeInt(i);
        System.out.println("write: " + i);
    }
    out.close();
}
```

Soubory s náhodným přístupem 2/2

- Pro přístup na konkrétní položku je nutné určit „adresu" položky v souboru jako pozici v počtu bytů od začátku souboru

```
final int SIZE = Integer.SIZE / 8;

RandomAccessFile in =
    new RandomAccessFile(fname, "r");

for (int i = 0; i < 5; ++i) {
    in.seek(i * 2 * SIZE);
    int v = in.readInt();
    System.out.println("read: " + v);
}
```

DemoRandomAccess.java

Textově orientované soubory

- Při čtení a zápisu je nutné zajistit konverzi znaků

Kódování

- Příklad zápisu s využitím třídy **PrintWriter**

```
public void write(String fname) throws IOException {
    String months[] = {"jan", "feb", "mar", "apr", "may
    ", "jun", "jul", "aug", "sep", "oct", "nov", "dec"
    };

    PrintWriter out = new PrintWriter(fname, "UTF-8");
    for (int i = 0; i < months.length; ++i) {
        out.println(months[i]);
    }
    out.close();
}
```

Příklad čtení textového souboru

- Pro čtení můžeme využít třídy **Scanner** podobně jako při čtení ze standardního vstupu

```
public void start() throws IOException {
    String fname = "text_file.txt";

    write(fname);

    FileInputStream in = new FileInputStream(fname);
    Scanner scan = new Scanner(in);
    while (scan.hasNext()) {
        String str = scan.next();
        System.out.println("Read: " + str);
    }
    in.close();
}
```

DemoTextFile.java

Shrnutí přednášky

Diskutovaná témata

- Generický typ, Spojový seznam, iterátor

- Soubory a přístup k souborům
- Typy souborů (textový a binární)
- Práce se soubory v Javě
  - Binární soubory
  - Textové soubory

- Příště: GUI v Javě

Diskutovaná témata

- Generický typ, Spojový seznam, iterátor

- Soubory a přístup k souborům
- Typy souborů (textový a binární)
- Práce se soubory v Javě
  - Binární soubory
  - Textové soubory

- Příště: GUI v Javě