

# Soubory

Jan Faigl

Katedra počítačů  
Fakulta elektrotechnická  
České vysoké učení technické v Praze

Přednáška 12

A0B36PR1 – Programování 1

## Část I Soubory

## Část 1 – Soubory

Soubory

Práce se soubory

Čtení a zápis souboru v Javě

Binární soubory

Textové 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*

## Typy souborů

Podle způsobu kódování informace v souboru rozlišujeme:

- Textové soubory
  - Přímě 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).*

## 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`

## 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.

## Sekvenční přístup

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


*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*

## 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

## 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 informací 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 prouděch (**streams**)
  1. **Otevření** přenosového proudu pro **byty** nebo **znaky**
  2. **Otevření** přenosového proudu pro **datové typy Javy**
  3. **Filtrace** dat podle dalších požadavků, např. bufferování, řádkování, atd.

## Příklad – Soubor jako posloupnost bytů

Vytvoření kopie vstupního souboru

- Vstupní soubor postupně načítáme byte po byte 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();
}
```

*lec12/DemoFileStream.java*

## Proudy v Javě (Standardní třídy)

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

<https://docs.oracle.com/javase/8/docs/api/java/io/StreamTokenizer.html>
- **RandomAccessFile** – práce se soubory s náhodným přístupem
- **File** – zpracování 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**

## Výjimky (Exceptions)

- Představují mechanismus ošetření chybových (výjimečných) stavů
 

*Program navrhujeme a implementujeme tak, aby v rámci daných operačních vlastností fungoval správně.*
- Mechanismus výjimek umožňuje se „soustředit“ na funkčnost programu a „odložit“ řešení detekované chyby provedení příkazu (metody) mimo hlavní tělo funkce (metody)
- Chyba nemusí znamenat ukončení programu – chybu je možné ošetřit, zotavit běh programu a pokračovat ve vykonávání dalšího kódu
- Posloupnost příkazů, ve které může vzniknout výjimka, uzavíráme do bloku klíčovými slovy **try**
- Příslušnou výjimku pak „zachytáváme“ prostřednictvím **catch**
- Metodu můžeme deklarovat jako metodu, která může vyvolat výjimku – klíčovými slovy **throws**
- Java ošetření výjimek vynucuje

*Výjimka nikoliv vyjimka – výjimka označuje název děje nebo výsledku děje, je to podstatné jméno odvozené od slovesa.*

## Výjimky – Příklady

- Příklad deklarace funkce, ve které může nastat výjimka

```
public void copy(String in, String out) throws
    IOException {
    ...
}
```

- V těle funkce nemusíme ošetřovat zotavení z chyby
- Řízení programu je předáno do nadřazené funkce, kde můžeme implementovat ošetření chyby, např.

```
try {
    copy("in.txt", "out.txt");
} catch (IOException e) {
    System.err.println("Error in copy");
}
```

## 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?*

## Výjimky a výpočetní tok

- Metoda může skončit standardně nebo může být přerušena vyvoláním výjimky

- Při vyvolání výjimky se řízení předá „nejbližší“ konstrukci ošetřující výjimku daného typu

*Výjimky jsou objekty – instance tříd, které mají svou hierarchii (viz dědičnost a polymorfismus)*

- Pokud taková konstrukce v těle funkce (metody) není, dojde k nestandardnímu ukončení funkce a výjimka se šíří do nadřazené úrovně
- Není-li výjimka ošetřena ani ve funkci **main**, program vypíše výjimku na standardní chybový výstup („stderr“) a skončí

- Výjimka typu **RuntimeException** je výjimečná výjimka, kterou není nutné explicitně ošetřovat nebo deklarovat v hlavičce metody uvedením **throws**

*Typicky se jedná o situace, které lze standardně ošetřit např. větvením programu (použitím if), více viz PR2.*

## 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();
    }
}
```

lec12/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);
}
```

lec12/DemoFilePrimitiveTypesWrite.java

## 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

## 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);
}
```

lec12/DemoFilePrimitiveTypesRead.java

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

## 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;
    }
}
```

lec12/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();
}
```

lec12/DemoObjectSerialization.java

## 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();
}
```

## 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 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);
}
```

lec12/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();
}
```

## Shrnutí přednášky

## 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();
}
```

*lec12/DemoTextFile.java*

## Diskutovaná témata

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