

Dynamické datové struktury (kontejnery)

Tomáš Pitner, upravil Marek Šabo

Kontejnery

Co jsou kontejnery?

- *dynamické datové struktury* vhodné k ukládání proměnného počtu objektů (přesněji odkazů na objekty)
- kontejnery jsou datové struktury v operační paměti, nejsou automaticky ukládané do trvalé paměti (na disk)
- podle povahy mohou mít různé specifické vlastnosti

Hlavní typy kontejnerů

Seznam (List)

každý prvek v nich uložený má svou *pozici* (číselný index),

- podobně jako u pole, ale prvků lze uložit potenciálně neomezený počet
- počet se může za běhu dynamicky *měnit* (i snižovat)

Množiny (Set)

prvek lze do množiny vložit nejvýš *jedenkrát*

- odpovídá matematické představě množiny,
- při porovnávání rozhoduje rovnost podle výsledku volání equals

Asociativní pole (Map)

v kontejneru jsou *dvojice* (klíč, hodnota),

- při znalosti klíče lze v kontejneru rychle najít hodnotu,
- klíč v mapě přibližně odpovídá databázovému klíči.

K čemu slouží

- Kontejnery slouží k ukládání odkazů na *objekty*, ne přímo hodnot primitivních typů.
- Při ukládání hodnot jako jsou čísla, booleovské hodnoty, znaky apod. se de facto ukládají jejich objektové protějšky, tzn. např. Integer, Char, Boolean, Double apod.
- V Javě byly dříve kontejnery koncipovány jako *beztypové*, to už ale od verze Java 1.5 (tedy Java 5) neplatí!
- Od Javy 5 mají tzv. *typové parametry* vyznačené ve špičatých závorkách (např. List<Person>), jimiž určujeme, jaké položky se do kontejneru smějí dostat.

Proč vůbec

- Kontejnery jsou dynamickými alternativami k poli a mají daleko širší použití.

- Slouží k uchování proměnného počtu objektů.
- Počet prvků se v průběhu existence kontejneru může měnit.
- Oproti polím nabízejí časově efektivnější algoritmy přístupu k prvkům — množiny, mapy.

Co použít

- Většinou se používají kontejnery hotové, vestavěné, tj. ty, jež jsou součástí Java Core API,
- tyto vestavěné kontejnerové třídy jsou definovány v balíku `java.util`,
- je možné vytvořit si vlastní implementace, obvykle ale zachovávající/implementující standardní rozhraní.

Základní kategorie

Kategorie jsou dány tím, které rozhraní příslušný kontejner implementuje. Základní jsou:

Seznam (*List*<*E*>)

lineární struktura, každý prvek má svůj číselný index (pozici)

Množina (*Set*<*E*>)

struktura bez duplicitních hodnot a obecně také bez uspořádání, umožňuje rychlé dotazování na přítomnost prvku

Asociativní pole, mapa (*Map*<*K*,*V*>)

struktura uchovávající dvojice (klíč → hodnota), rychlý přístup přes klíč

Kolekce

- *Kolekce* jsou kontejnery implementující rozhraní [Collection](#)
- Rozhraní kolekce popisuje velmi obecný kontejner, disponující operacemi: *přidávání*, *rušení prvku*, *získání iterátoru*, *zjišťování prázdnosti* atd.
- Mezi kolekce patří mimo mapy všechny ostatní vestavěné kontejnery `List`, `Set`.
- Prvky kolekce nemusí mít svou pozici danou indexem, viz např. `Set`.

Kontejnery — rozhraní, nepovinné metody

- Funkcionalita vestavěných kontejnerů je obvykle předepsána výhradně *rozhraním*, jež implementují.
- Rozhraní vestavěných kontejnerů připouštějí, že některé metody jsou *nepovinné*, třídy je nemusí implementovat.
- Fakticky to v takovém případě vypadá tak, že metoda tam sice je, jinak by to typově nesouhlasilo, ale nelze ji použít, protože volání obvykle *vyhodí výjimku*.

- V praxi se totiž někdy nehodí implementovat typicky zápisové operace, protože některé kontejnery chceme mít read-only.

Iterátory

- *Iterátory* jsou prostředkem, jak sekvenčně procházet prvky kolekce buďto:
- v *neurčeném pořadí* nebo
- v *uspořádání* (u uspořádaných kolekcí)
- Každý iterátor musí implementovat velmi jednoduché rozhraní `Iterator<E>` se třemi metodami:

```
boolean hasNext()  
E next()  
void remove()
```

"Hromadné" operace nad kolekcemi

- Některé operace je vhodné provádět nikoli postupně po prvcích, ale jedním voláním vhodné metody:

boolean c1.addAll(c2)

přidá do c1 všechny prvky z c2

boolean c1.containsAll(c2)

vrátí true, právě když c1 obsahuje všechny prvky z c2, tzn. když c1 je její nadmnožinou

boolean c1.removeAll(c2)

odstraní z c1 všechny prvky, které jsou současně v c2.

boolean c1.removeIf(Predicate filter)

odstraní z kolekce všechny prvky, které splňují predikát (podmínku) filter [až od Java 8]

boolean c1.retainAll(c2)

zachová v c1 jen ty prvky, které jsou současně v c2.

Seznamy

- *Seznamy* jsou lineární struktury,
- implementují rozhraní `List`, což je rozšíření `Collection`.
- Prvky lze adresovat celočíselným nezáporným indexem (typu `int`).
- Poskytují možnost získat dopředný i zpětný *iterátor*.
- Lze pracovat i s *podseznamy*.

Implementace seznamu: ArrayList

ArrayList

- nejpoužívanější implementace seznamu
- využívá vnitřně *pole* pro uchování prvků
- rychlé operace přístupu k prvkům dle indexu
- přičemž o něco pomalejší jsou operace přidávání a odebírání prvků blíže k začátku seznamu (pole, v němž je seznam, se musí realokovat)

Implementace seznamu: LinkedList

LinkedList

- druhá nejpoužívanější implementace seznamu
- využívá vnitřně *zřetězený seznam* pro uchování prvků
- pomalejší operace přístupu k prvkům dle indexu "uvnitř" seznamu
- rychlejší operace přidávání a odebírání prvků na začátku a na konci, resp. blízko nich

Výkonnostní porovnání seznamů

- Výsledek spuštění dema [CollectionsDemo.java](#)

```
List implemented as java.util.ArrayList test done:
  add 100000 elements took 12 ms
  remove all elements from last to first took 5 ms
  add at 0 of 100000 elements took 1025 ms
  remove all elements from 0 took 1014 ms
  add at random position of 100000 elements took 483 ms
  remove all elements at random position took 462 ms
List implemented as java.util.LinkedList test done:
  add 100000 elements took 8 ms
  remove all elements from last to first took 9 ms
  add at 0 of 100000 elements took 18 ms
  remove all elements from 0 took 10 ms
  add at random position of 100000 elements took 34504 ms
  remove all elements at random position took 36867 ms
```

Příklad použití seznamu

```

// declaring and creating list
List<String> ls = new ArrayList<>();
// using method add
ls.add("Ahoj");
ls.add("Cheers");
ls.add("Nazdar");
// using method get
System.out.println(ls.get(0));
// using "add" at specified index
ls.add(0, "Bye");
System.out.println(ls.get(0));
System.out.println("Whole list:");
// using index
for(int i = 0; i < ls.size(); i++) {
    System.out.println(i + ". " + ls.get(i));
}
System.out.println("Whole list without indices:");
// using for-each
for(String s: ls) {
    System.out.println(s);
}

```

Další lineární struktury

Z datových struktur máme v Javě ještě např.:

zásobník

třída Stack, struktura "LIFO" s operacemi

- push — vložení na vrchol zásobníku
- pop — odebrání z vrcholu zásobníku
- peek — přečtení (neodebrání) z vrcholu zásobníku

fronta

třída Queue, struktura "FIFO" s operacemi

- add — přidání prvku do fronty
- remove — vybrání prvku z fronty
- element — přečtení (neodebrání) prvku z fronty
- fronta může případně být *prioritní* (PriorityQueue)

oboustranná fronta

třída Deque (čteme "deck")

- slučuje vlastnosti zásobníku a fronty

- nabízí operace příslušné oběma typům

Množiny

- *Množiny* jsou struktury standardně bez uspořádání prvků (ale existují i uspořádané, viz dále),
- implementují rozhraní `Set` (což je rozšíření `Collection`).
- Cílem množin je mít možnost rychle (se složitostí $O(\log(n))$) provádět atomické operace:
 - vkládání prvku (`add`)
 - odebrání prvku (`remove`)
 - dotaz na přítomnost prvku (`contains`)

Množiny — implementace

Standardní implementace množiny:

hašovací tabulka

třída `HashSet`,

- potenciálně rychlejší (ideálně konstantní, tj. sub-logaritmická složitost),
- ale neumožňuje uspořádání hodnot

vyhledávací strom

konkrétně *černobílý strom* (Red-Black Tree),

- třída `TreeSet`,
- uspořádané hodnoty,
- s garantovanou logaritmickou složitostí

Uspořádané množiny

- Výše uvedená vestavěná implementace `TreeSet`.
- Implementují rozhraní `SortedSet`
- Jednotlivé prvky lze tedy iterátorem procházet v přesně definovaném pořadí — uspořádání podle *hodnot prvků*.
- černobílé stromy (Red-Black Trees)
- Uspořádání je dáno buďto:
 - standardním chováním metody `compareTo` vkládaných objektů — pokud implementují rozhraní `Comparable`
 - nebo je možné uspořádání definovat pomocí tzv. *komparátoru* (objektu impl. rozhraní `Comparator`) poskytnutých při vytvoření množiny.

Výkonnostní srovnání množin

- Výsledek spuštění dema [CollectionsDemo.java](#)

```
Set implemented as java.util.HashSet test done:
  add 100000 elements took 27 ms
  remove all elements from 100000 to 0 took 14 ms
  add 100000 elements took 9 ms
  remove all elements from 0 took 18 ms
  add 100000 random elements took 30 ms
  remove 100000 random elements took 17 ms
Set implemented as java.util.TreeSet test done:
  add 100000 elements took 67 ms
  remove all elements from 100000 to 0 took 50 ms
  add 100000 elements took 58 ms
  remove all elements from 0 took 41 ms
  add 100000 random elements took 84 ms
  remove 100000 random elements took 68 ms
```

Comparable

- Jednoduché rozhraní [Comparable](#) slouží k definování uspořádání na třídě objektů.
- Předepisuje jedinou metodu `int compareTo(T t)`
- Implementuje-li třída toto rozhraní, znamená to, že její objekty jsou vzájemně *uspořádané*.
- Lze tedy o nich říci, který je ve struktuře umístěn dříve a který později pomocí `o1.compareTo(o2)`, která vrací celé číslo, kde rozhoduje jeho znaménko.
- Toto rozhraní definuje tzv. *přirozené uspořádání* (natural ordering).
- Využívá se zejména u uspořádaných kontejnerů (množin a asociativních polí).
- Chování by mělo být konzistentní s `equals`, tzn. pro si rovné objekty by `compareTo` měla vrátit 0.

Comparator

- Jednoduché rozhraní [Comparator](#) slouží k definování uspořádání na třídě objektů *zvnějšku*, tzn. uspořádání pomocí objektu jiné třídy.
- Předepisuje jedinou metodu `int compare(T o1, T o2)`
- Implementuje-li třída toto rozhraní, znamená to, že její objekty umějí definovat *uspořádání* na objektech typu T obdobně jako `Comparable` vrácením celého čísla se znaménkem.
- Toto rozhraní funguje jako alternativa tam, kde nevyhovuje přirozené uspořádání (`Comparable`).
- Využívá se zejména u uspořádaných kontejnerů (množin a asociativních polí), do nichž se dá komparátor nastavit při konstrukci těchto kontejnerů.

Cyklus *for-each*

- Je rozšířenou syntaxí cyklu `for`.
- Umožňuje procházení všech prvků polí a dalších iterovatelných struktur, např. seznamů a množin.

Příklad:

```
Set<String> strings = ...
for(String s: strings) {
    System.out.println(s);
}
```

Mapy

- *Mapy (asociativní pole)* fungují v podstatě na stejných principech a požadavcích jako `Set`:
- Ukládají ovšem dvojice (klíč, hodnota) a umožňují rychlé vyhledání dvojice podle hodnoty klíče.
- Základními metodami jsou:
 - dotazy na přítomnost klíče v mapě (`containsKey`),
 - výběr hodnoty odpovídající zadanému klíči (`get`),
 - možnost získat zvlášť *množiny klíčů*, *hodnot* nebo *dvojic* (klíč, hodnota).
 - možnost iterace po těchto dvojicích (`forEach`)

Mapy — implementace

Mapy mají podobné implementace jako množiny, tj.:

hašovací tabulky

třída `HashMap`

- potenciálně rychlejší,
- ale neuspořádané klíče

černobílé stromy

třída `TreeMap`

- uspořádané klíče,
- s garantovanou logaritmickou složitostí

Mapy — složitosti

- Složitost základních operací (put, remove, containsKey):
 - Mapy implementované jako stromy mají nejvyšší *logaritmickou* složitost základních operací.
 - U map implementovaných hašovací tabulkou složitost v praxi závisí na kvalitě hašovací funkce (metody hashCode) na ukládaných objektech,
 - teoreticky se blíží složitosti *konstantní*.

Uspořádané mapy

- Implementují rozhraní [SortedMap](#)
- Dvojice (klíč, hodnota) jsou v nich *uspořádané podle hodnot klíče*.
- Existuje vestavěná implementace třídou [TreeMap](#)
- Uspořádání lze ovlivnit naprosto stejným postupem jako u uspořádané množiny.

Získání nemodifikovatelných kontejnerů

- Kontejnery jsou standardně modifikovatelné (read/write).
- Nemodifikovatelné kontejnery se často používají při vracení hodnot z metod.
- Dají se získat pomocí volání příslušné metody třídy [Collections](#).

Souběžný přístup

- Moderní kontejnery jsou *nesynchronizované*, nepřipouštějí souběžný přístup z více vláken.
- Standardní, nesynchronizovaný, kontejner lze však *zabalit synchronizovanou obálkou*.

Pomocná třída Collections

- Java Core API nabízí třídu [Collections](#).
- Je to tzv. *utility class*, nabízí jen statické metody a proměnné, nelze od ní vytvářet instance.
- Nabízí škálu užitečných metod pro práci s kontejnery, jako např.:
 - binární vyhledávání v kontejneru
 - vracení nemodifikovatelných kopií
 - rychlé vracení prázdných kontejnerů
 - agregační funkce (maximální, minimální prvek)
 - vyplňování seznamu
 - obracení (reverse) nebo prohazování (shuffle) pořadí
 - uspořádání

Kontejnery a výjimky

- Při práci s kontejnery může vzniknout řada *výjimek*, např. `IllegalStateException` apod.
- Většina má charakter výjimek *běhových*, tudíž není povinností je odchyťovat, pokud věříme, že nevzniknou.

Starší typy kontejnerů

- Existují tyto starší typy kontejnerů (za → uvádíme náhradu):
 - `Hashtable` → `HashMap`, `HashSet` (podle účelu)
 - `Vector` → `List`
 - `Stack` → `List` nebo lépe `Queue` či `Deque`

Enumeration

- Roli iterátoru plnil dříve *výčet* ([Enumeration](#)) se dvěma metodami:
 - `boolean hasMoreElements()`
 - `Object nextElement()`

Srovnání implementací kontejnerů

Seznamy

- na bázi pole (`ArrayList`) - rychlý přímý přístup (přes `index`)
- na bázi lineárního zřetězeného seznamu (`LinkedList`)— rychlý sekvenční přístup (přes iterátor)
- téměř vždy se používá `ArrayList`— stejně rychlý a paměťově efektivnější

Množiny a mapy

- na bázi hašovacích tabulek (`HashMap`, `HashSet`)— rychlejší, ale neuspořádané (lze získat iterátor procházející klíče uspořádaně)
- na bázi vyhledávacích stromů (`TreeMap`, `TreeSet`) - pomalejší, ale uspořádané
- spojení výhod obou — `LinkedHashSet`, `LinkedHashMap`

Odkazy

- Demo efektivity práce kontejnerů [CollectionsDemo](#)
- Velmi podrobné a kvalitní seznámení s kontejnery najdete na Oracle [Trail: Collections](#)