

Správa paměti

Ing. Marek Běhálek
katedra informatiky FEI VŠB-TUO
A-1018 / 597 324 251
<http://www.cs.vsb.cz/behalek>
marek.behalek@vsb.cz



Motivace

• Statické přidělení paměti

- Známe předem velikost i počet prvků datové struktury
`int pole[10]; // 10 * sizeof(int)`
- Proměnné deklarované na globální úrovni
- Statické proměnné

• Dynamické přidělení paměti

- Neznámý počet prvků
`int* pole = new int[pocet];`
- Rekurze
`int f(int n) {
 return n == 0 ? 1 : n * f(n-1);
}`

Správa paměti

3

Obsah přednášky



- Motivace
- Úrovně správy paměti.
- Manuální a automatická správa paměti.
- Metody přidělování paměti.
- Metody regenerace paměti.
- Správa paměti v konkrétních programovacích jazycích.

Správa paměti

2

Úrovně správy paměti



- **Technické vybavení**
 - registry, cache
- **Operační systém**
 - virtuální paměť
 - segmentace, stránkování
- **Aplikace**
 - Přidělování paměti
 - Regenerace paměti
 - Manuální – delete, dispose, free(), ...
 - Automatická – garbage collection

Správa paměti

4

Omezení na správu paměti



- **Časová režie**
 - Kolik času navíc zabere správa paměti?
- **Doba pozdržení interaktivity**
 - Na jak dlouho se aplikace „zasekne“ během správy paměti?
- **Paměťová režie**
 - Kolik prostoru spotřebuje správa paměti?
 - Interní fragmentace – zaokrouhlování velikosti bloků
 - Externí fragmentace – nevhodné využití paměti

Správa paměti 5

Historie



- 1957 – FORTRAN, statické přidělování
- 1958 – LISP, dynamické přidělování s regenerací
- 1962 – virtuální paměť
- 1965 – vyrovnávací paměti (cache)
- 1969 – Intel – čip 1 kB RAM
- 1974 – Intel 8080 – přístup k 64 kB paměti
- 1975 – Dijkstra - inkrementální regenerace paměti

Správa paměti 7

Problémy správy paměti



- **Předčasné uvolnění paměti**
 - Přístup k paměti, která již byla uvolněna
- **Únik paměti (memory leak)**
 - Neuvolňování nepotřebné paměti
- **Externí fragmentace**
 - Rozdělení volné paměti na mnoho malých bloků
- **Špatná lokalita odkazů**
 - Vliv velikosti cache
- **Chybné předpoklady při návrhu aplikace**

Správa paměti 6

Manuální správa paměti



- Program sám vrací část paměti, kterou nepotřebuje
- **Přidělování z hromady**
 - Volání funkcí pro přidělování a uvolňování paměti
 - Zodpovědnost je na programátorevi
 - Střídání bloků přidělené a volné paměti
- **Přidělování na zásobníku**
 - Pro lokální proměnné a parametry funkcí
 - Uvolňuje se vždy naposledy přidělená paměť

Správa paměti 8

Automatická správa paměti



- **Vyhledání obsazených bloků paměti**
 - Živé bloky – program s nimi dále pracuje (jak to zjistíme??)
 - Dostupné bloky – program s nimi je schopen dále pracovat
 - Globální a lokální proměnné, registry – kořeny dosažitelnosti
- **Regenerace nevyužité paměti**
 - Paměť je k dispozici pro opakování přidělení

Správa paměti 9

Metody přidělování paměti



- Máme k dispozici jistým způsobem organizovanou volnou paměť.
- Dle požadavků aplikace postupně odebíráme a přidělujeme jednotlivým datovým objektům.
- Úkolem přidělování paměti je pro zadанou velikost požadované paměti vyhledat vhodný úsek volné paměti a jeho adresu vrátit.

Správa paměti 11

Automatická správa paměti



- **Výhody**
 - Programátor se může věnovat jiným problémům
 - Přehlednější rozhraní programových modulů (kdo uvolní přidělenou paměť?)
 - Menší množství chyb spojených s přístupem do paměti
 - Mnohem efektivnější správa paměti
- **Nevýhody**
 - Uvolňuje se pouze nedostupná paměť
 - Není k dispozici ve starších jazycích

Správa paměti 10

Přidělování na zásobník



- **Přidělení paměti**
 - Posune ukazatel o velikost přiděleného prostoru
- **Uvolnění paměti**
 - Prázdná operace
 - Vyplnění prostoru spec. vzorem – pro ladění

Správa paměti 12

Přidělování na zásobník

```
class SimpleAllocator {  
public: SimpleAllocator(char* memAddr, unsigned memSize) {  
    m_addr = memAddr;  
    m_size = memSize;  
}  
public: char* alloc(unsigned size) {  
    if( size > m_size ) throw new NoMemoryException();  
    char* addr = m_addr;  
    m_addr += size;  
    return addr;  
}  
public: void free(char* addr, unsigned size) {}  
// Aktuální začátek volné paměti  
protected: char* m_addr;  
// Aktuální velikost volné paměti  
protected: unsigned m_size; }
```

Správa paměti



13

Přidělování ze seznamu volných bloků

- Volné bloky paměti seřazené do seznamu
- Přidělení paměti
 - Vyhledání bloku vhodné velikosti
 - Zařazení nevyužité části volného bloku zpět do seznamu
- Uvolnění paměti
 - Zařazení bloku do seznamu
 - Spojení s navazujícími bloky – snížení fragmentace
 - Přesun volných bloků do jednoho celku (defragmentace paměti) – co s ukazateli?

Správa paměti

15

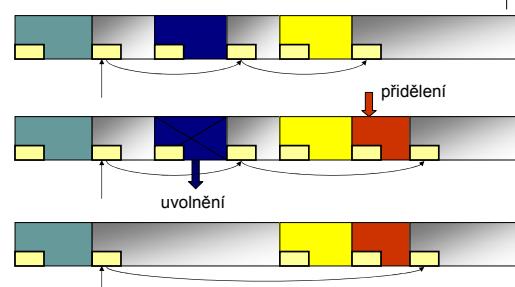
Přidělování na zásobník

- velmi rychlá metoda
- často se požívá v rámci bloku, který získáme jinou metodou – sublokátor
- přidělování paměti pro aktivační záznamy (C/C++/Pascal)
- jednou z modifikací je zavedení operací *mark* a *release*

Správa paměti

14

Přidělování ze seznamu volných bloků



Správa paměti

16

Metody pro přidělování volných bloků



• First fit

- Prochází seznam volných bloků a vybere první, jehož velikost je větší nebo rovna požadované velikosti.
- Blok je rozdělen na přidělenou paměť a zbylé volné místo
- Při uvolňování je potřeba volný blok opět zařadit do seznamu
- Nevýhoda – na začátku seznamu vznikne mnoho malých bloků, jejich sekvenční procházení může podstatně zpomalit operaci přidělování paměti.

Správa paměti

17

Metody pro přidělování volných bloků



• Next fit

- vyhledávání začíná na pozici, kde předchozí vyhledávání skončilo
- zabrání hromadění menších bloků na začátku seznamu
- Nevýhoda – přidělené bloky od sebe mohou být značně vzdálené
- Celkově vede k menší efektivitě

Správa paměti

19

Metody pro přidělování volných bloků



• Různě strukturovaný seznam

- Zařazení uvolněného bloku na začátek/konec seznamu – složitější slévání sousedních volných bloků.
- Použití uspořádaného seznamu podle adres bloku.
- Použití složitějších struktur – například stromy.
- Lze použít u všech prezentovaných metod

Správa paměti

18

Metody pro přidělování volných bloků



• Best fit

- snažíme se najít volný blok, jehož velikost je větší nebo rovna požadované
- Nevýhody
 - pro velké množství objektů bude prohledávání a tedy i přidělování paměti pomalé
 - velké množství nepoužitelných malých zbytků paměti
- Optimalizace
 - více seznamů pro bloky přibližně stejné délky
 - indexace + seřazení bloků podle délky (nebo složitější datové struktury)

Správa paměti

20

Metody pro přidělování volných bloků

- Worst fit
 - Je použit největší volný blok paměti.
 - Nově vzniklý blok (zbytek po přidělení paměti) bude dostatečně velký.

Správa paměti



21

Binární přidělování

- Nejznámější buddy systém.
- Velikost bloků je vždy mocnina dvou.
- Při dělení se blok rozdělí na dvě stejné části.
- Všechny bloky jsou „zarovnané“ na mocninu dvou.
- Přístup k blokům je tedy zajištěn na jednoduchém výpočtu pomocí bitových operací.

Správa paměti

23

Přidělování s omezenou velikostí bloku (buddy system)



- Hierarchické dělení paměti na části podle pevných pravidel
- Spojovat lze pouze sousední bloky v hierarchii (buddies)
- Výsledek pak bude patřit do bezprostředně vyšší úrovně hierarchie.
- Sousedem bloku najdeme jednoduchým výpočtem – nižší režie (1 bit volný/obsazený)
- Pro každou možnou velikost bloků se udržuje samostatný seznam volných bloků.

Správa paměti

22

Example of Buddy System

1 Mbyte block					1 M
Request 100 K	A = 128 K	128 K	256 K		512 K
Request 240 K	A = 128 K	128 K	B = 256 K		512 K
Request 64 K	A = 128 K	64 K	B = 256 K		512 K
Request 256 K	A = 128 K	64 K	B = 256 K	D = 256 K	256 K
Release B	A = 128 K	64 K	256 K	D = 256 K	256 K
Release A	128 K	64 K	256 K	D = 256 K	256 K
Request 75 K	E = 128 K	64 K	256 K	D = 256 K	256 K
Release C	E = 128 K	128 K	256 K	D = 256 K	256 K
Release E		512 K		D = 256 K	256 K
Release D					1 M

Fibonacciho přidělování

- $f(1)=1, f(2)=2, f(n)=f(n-1)+f(n-2)$
 - 1, 2, 3, 5, 8, ...
- Tato varianta se snaží snížit vnitřní fragmentaci bloků využití kompaktnější sady možných velikostí bloků.
- Každý blok lze beze zbytku rozdělit na dva bloky, jejichž velikosti jsou opět prvky řady.
- Problémem je přidělování několika bloků stejné velikosti.

Správa paměti



25

Metoda dvoufázového značkování (mark and sweep)

• Předpoklady:

- Známe kořeny dosažitelnosti
 - Globální a lokální proměnné
 - Registry
- Známe strukturu dat (kde jsou další ukazatele)

• Postup:

- Označujeme všechny bloky dosažitelné z kořenů
- Neoznačené bloky uvolníme

Správa paměti

27



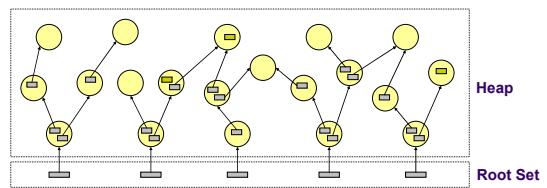
Metody regenerace paměti

- Nepoužité bloky paměti chceme znova využít
- **Jak vyhledat nepoužité bloky?**
 - Čítače odkazů
 - Sledování odkazů – značkování
- **Inkrementální metody**
 - Úklid paměti se střídá s během aplikace
 - Lze využít pro systémy pracující v reálném čase

Správa paměti

26

Metoda dvoufázového značkování (mark and sweep)



Správa paměti

28



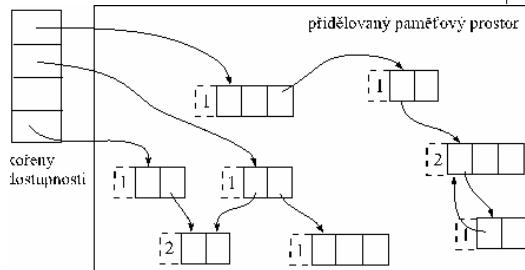
Metoda dvoufázového značkování (mark and sweep)

- Čas potřebný na prozkoumání dostupnosti objektů je závislý na velikosti hromady, ne na množství „smetí“ (garbage).
- Jeden „průchod“ ušetříme, pokud použijeme regeneraci s kopírováním.

Správa paměti

29

Regenerace s počítáním odkazů (reference counting)



Správa paměti

31

Regenerace s kopírováním

- Všechny obsazené bloky zkopírujeme do jiné souvisele oblasti paměti (vyhledáme je stejně jako u metody Mark and Sweep).
- Je třeba přesměrovat odkazy na kopírované objekty
- Při kopírování se snažíme vytvořit jeden kompaktní blok (má-li A odkaz na B, dáme je za sebe...)



Správa paměti

30

Regenerace s počítáním odkazů (reference counting)

• Postup

- Každý objekt obsahuje počitadlo odkazů
- $L := R$ zvýší počet odkazů na R a sníží počet odkazů na předchozí hodnotu L
- Při snížení počitadla na nulu se paměť uvolní

• Problémy

- Nefunguje pro cyklické odkazy
- Nebezpečí tranzitivního uvolňování – odezva
- Velká režie při častých změnách – lok. proměnné

Správa paměti

32

Generační regenerace paměti (Generational)

- Většina objektů má krátkou životnost.
- Objekty rozděleny do několika oblastí dle jejich „stáří“.
- Pokud objekt „přežije“ regeneraci paměti je zvětšena hodnota určující jeho stáří.
- Objekty v oblastech pro „staré“ objekty není nutné tak často testovat.

Správa paměti



33

Správa paměti v jazyce C++

- Součást syntaxe jazyka
 - `T* ptr = new T();`
 - `delete ptr;`
- Přidělování paměti pro pole
 - `long* buffer = new long[40];`
 - `delete[] buffer;`
- Nekombinovat malloc/new a free/delete!

Správa paměti

35

Správa paměti v jazyce C



- Standardní knihovní funkce
 - `void* malloc(size_t size)`
 - `void* calloc(size_t num, size_t size)`
 - `void* realloc(void* ptr, size_t size)`
 - `void free(void* ptr)`
- Implementace obvykle seznamem volných bloků

```
long* buffer;
buffer = (long*)calloc(40, sizeof(long));
buffer = (long*)realloc(buffer,
                       100 * sizeof(long));
```

Správa paměti

34

Správa paměti v jazyce C++

- Vlastní přidělování/uvolňování pro třídu
 - class C {
public:
 C(char* s);
 void* operator new(size_t size, int arg);
 void operator delete(void* ptr, size_t size);
 ...
}
 - C* cp = new(10) C("abc");

Správa paměti

36

Správa paměti v jazyce Java

- **Automatická regenerace paměti**
 - (záleží na výrobci, SUN, IBM - mark & sweep, prázdné bloky spojovány kopírováním, generational GC)
 - Neexistuje destruktur (kdy by se měl volat?)
- **Inkrementální regenerace**
 - Samostatné vlákno s nízkou prioritou
 - Před uvolněním paměti volá metodu: `protected void finalize() throws Throwable`
 - Můžeme přímo volat garbage collector: `System.gc()`
- Pro vyhledání referencí se využívají *metadata*

Správa paměti



37

Správa paměti v jazyce C# (2)

- **Inkrementální regenerace**
 - Dva vlákna běžící na pozadí
 - 1. Používá metodu dvoufázového značkování a identifikuje „garbage“.
 - 2. Volá `finalize` a uvolňuje pamět.
- Můžeme explicitně uvolnit paměť:
`System.GC.Collect` – uvolní všechny
- Pro jednotlivé instance nutno použít rozhraní
`System.IDisposable`

Správa paměti

39

Správa paměti v jazyce C# (1)



- **Automatická regenerace paměti**
 - Používá algoritmus next fit, regenerace s kopírováním, využívá generací.
 - Udržuje pointer na další volné místo: `NextObjPointer`.
 - Při regeneraci paměti jsou objekty na hromadě „seříděny“ dle jejich vzdálenosti od kořenů.
 - Udržuje tři generace.
 - Vytvořené objekty
 - Objekty které přežily jeden průchod GC.
 - Objekty které přežily více průchodů GC.

Správa paměti

38