Gerenciamento Automático De Memória

Garbage Collection

Sandro Rigo
sandro@ic.unicamp.br

Introdução

- Alocação dinâmica ocorre no chamado espaço-livre ou *heap*
- Gerenciamento compreende
  - Alocação de novos recursos
  - Recuperação de recursos não mais necessários
- Duas formas de fazer
  - Explícita:
    - Fica a cargo do programador
  - Automática:
    - Coletor de lixo

Introdução

- Explícita:
  - Maior desempenho
  - Maior dificuldade
  - Mais suscetível a erros
- Automático:
  - Facilidade de desenvolvimento
  - Impacto negativo no desempenho

Contagem de Referências

- Cada objeto possui um contador
- Deve ser atualizado a cada operação
  - Nova referência criada
  - Referência antiga destruída
- O compilador gera as instruções para atualizar a contagem
- Contador = 0
  - Objeto é recuperado
  - Atualiza todos os referenciados por ele

Contagem de Referências

- Vantagens
  - Coleta é distribuída ao longo da execução
  - Não tem interrupção para recuperação
  - Pode ser útil para sistemas de tempo real
  - Recuperação de grandes estruturas não precisa ser feito todo de uma vez
  - Localidade de referência
    - Objeto é recuperado sem visitar outras páginas da memória

Contagem de Referências

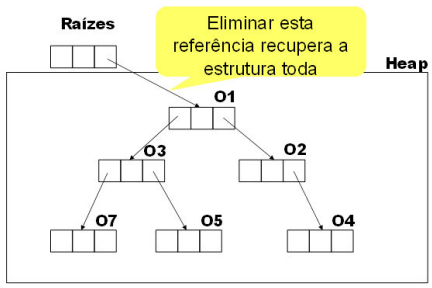

Contagem de Referências

- Desvantagens
  - Alto custo para manter todos os contadores atualizados
- Algum outro problema?
- Veja a estrutura do exemplo a seguir

Contagem de Referências

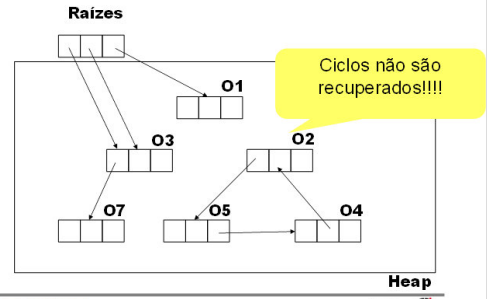

Contagem de Referências

- Desvantagens
  - Alto custo para manter todos os contadores atualizados
  - **Não recupera estruturas cíclicas !!!**
- **Possíveis soluções**
  - **Obrigar programador romper os ciclos**
  - **Alternar com coletas de outro algoritmo**

Coleta de Lixo

- Ponto de vista teórico:
  - O heap é um grafo dirigido G
  - Vértices: objetos
  - Arestas (x,f,y) indica que existe um apontador do campo f em x para y
  - Raizes de G são as variáveis locais do programa
  - Um objeto xn está morto se não existir um caminho r → x1 → x2 → … → xn em G, para qualquer raiz r

Exemplo

```
class list {list link;
            int key; }
class tree {int key;
            tree left;
            tree right; }
class main {
 static tree maketree() { … }
 static void showtree(tree t) { … }
 static void main() {
   {list x = new list(nil,7);
    list y = new list(x,9);
    x.link = y;
   }
   {tree p = maketree();
    tree r = p.right;
    int q = r.key;
    garbage-collect here
    showtree(r);
   }
}
```

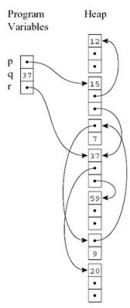

Mark-and-Sweep

- A idéia é marcar os nós vivos do grafo
- Nós vivos são os alcançáveis a partir das raízes
- Isso pode ser feito através de uma busca no grafo (DFS)
- Os nós não marcados são lixo
  - Devem ser recuperados

Mark-and-Sweep

- Varredura (sweep):
  - Varre-se todo o heap
  - Qualquer objeto não marcado é colocado numa lista de objetos livres
  - Desmarcar todos os nós marcados
- Interrompe a execução durante a coleta
- O programa aloca novos objetos da freelist
- Freelist vazia: dispara nova coleta

Mark-and-Sweep

```
function DFS(x)
  if x is a pointer into the heap
    if record x is not marked
      mark x
      for each field fi of record x
        DFS(x. fi)
```


Mark-and-Sweep

Mark phase:

```
for each root v
    DFS(v)
```

function DFS(x)

```
  if x is a pointer into the heap
    if record x is not marked
      mark x
      for each field fi of record x
        DFS(x. fi)
```


Mark-and-Sweep

Sweep phase:

```
p ← first address in heap
while p < last address in heap
    if record p is marked
            unmark p
    else let f1 be the first field in p
            p. f1 ← freelist
            freelist ← p
    p ← p+(size of record p)
```


Custo

- DFS ≈ # nós do grafo
  - Em GC é o # objetos vivos (R)
- Sweep ≈ tamanho do heap (H)
- 1 coleta
  - c1.R + c2.H
    - c1 e c2 constantes
- Recupera H-R palavras
- Amortizando: (c1.R + c2.H) / (H-R)

Custo

- Se torna grande se R é próximo de H
- Recupera muito pouco
- É possível para o GC pedir mais memória ao SO
  - Aumenta H
- Ex.: se R/H >= 0.5

Exemplo

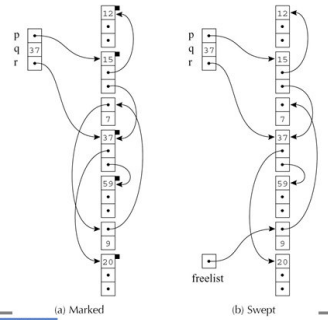

Cuidados com Implementação

- DFS é recursivo
- Máxima profundidade pode ser H
- Pilha de execução teria tamanho maior do que o heap!
- Podemos adotar uma pilha explícita

Pilha Explícita

```
function DFS(x)
 if x is a pointer and record x is not marked
  mark x
  t ← 1
  stack[t] ← x
  while t > 0
      x ← stack[t]; t ← t - 1
      for each field fi of record x
         if x. fi is a pointer and record x. fi is not marked
           mark x. fi
           t ← t + 1; stack[t] ← x. fi
```


Cuidados com Implementação

- Pilha agora pode chegar a tamanho H palavras
  - Ainda assim é inaceitável
- Podemos melhorar?
- Sim
  - Pointer Reversal

Pointer Reversal

- Após coloar x.fi na pilha, DFS não precisa dele novamente
- Podemos usar x.fi para armazenar um elemento da pilha!
- x.fi apontará para o registro do qual x foi alcançado
- Pop restaurará x.fi

Pointer Reversal

```
function DFS(x)
 if x is a pointer and record x is not marked
  t ← nil
  mark x; done[x] ← 0
  while true
      i ← done[x]
      if i < # of fields in record x
        y ← x. fi
        if y is a pointer and record y is not marked
          x. fi ← t; t ← x; x ← y
          mark x; done[x] ← 0
        else
          done[x] ← i + 1
      else
        y ← x; x ← t
        if x = nil then return
        i ← done[x]
        t ← x. fi; x. fi ← y
        done[x] ← i + 1
```

Lista de Objetos Livres

- Chamadas de freelists
- Pode haver objetos de tamanhos diferentes
- Uma lista única não é eficiente
- É comum existir um array de freelists
  - Freelist[i] é uma lista de nós de tamanho 2^i
- Tentativa de alocar de uma lista vazia:
  - Pega o primeiro livre >= tamanho requerido

Fragmentação

- Pode acontecer de haver vários objetos pequenos livres
- Porém não haver objetos grandes
- A soma dos objetos livres seria suficiente para alocar pelo menos um grande
- Isso é fragmentação externa!

Fragmentação

- Um objeto pode ser menor do que o mínimo da lista de livres
- Ele será alocado para um registro maior do que seu tamanho
- Isto é fragmentação interna!

Copy Collection

- Atravessa o heap para encontrar objetos vivos
- Não tem custo nas operações com referências
- Não tem problemas com ciclos
- Divide o heap em dois espaços
  - From-space
  - To-space

Copy Collection

- Atravessa os objetos vivos no from-space
- Cria uma cópia no to-space
- Deixa os mortos no from-space
- Recomeça a execução pelo to-space

Exemplo

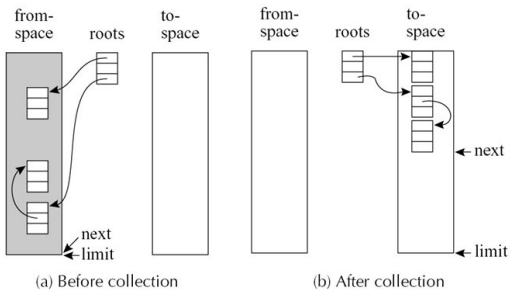

Copy Collection

- Next: próxima posição para alocação
- Limit: final do heap
- Next = limit?
  - Nova coleta iniciada
- Coleta
  - Next vai para o início do to-space
  - Os registros vivos são copiados para a posição apontada por next
  - Forwarding: operação que ajusta os apontadores

Forwarding

- Para cada p apontando para o from-space
  - Altere para p passar a apontar para o to-space

1. p aponta para um registro já copiado
   - P.f1 é um ponteiro especial que mostra para onde foi copiado no to-space
2. p aponta para um registro não copiado
   - Copia o registro para o local indicado por next
   - Armazena o forwarding pointer em p.f1

Forwarding

3. p aponta para fora do from-space ou não é um ponteiro
   - Ignore p

```
function Forward(p)
 if p points to from-space
   then if p. f1 points to to-space
        then return p. f1
        else for each field fi of p
                 next. fi ← p. fi
             p. f1 ← next
             next ← next+ size of record p
             return p. f1
   else return p
```


Algoritmo de Cheney

```
scan ← next ← beginning of to-space
for each root r
    r ← Forward(r)
while scan < next
    for each field fi of record at scan
        scan. fi ← Forward(scan. fi)
    scan ← scan+ size of record at scan
```


Exemplo

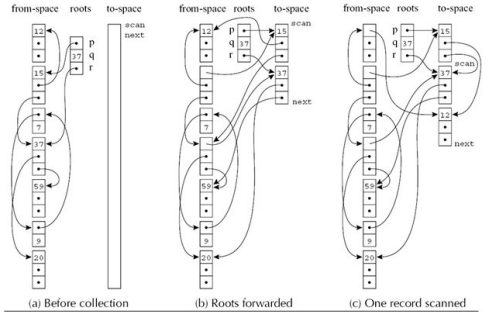

Comparação

- Quais vantagens/desvantagens você vê em relação ao Mark-and-Sweep?
- Quando ambos começam a apresentar problemas de eficiência?
- Qual o principal efeito colateral benéfico de copy-collection?

Custo

- Mark-and-Sweep
  - (c1.R + c2.H) / (H-R)
- Copy-Collection
  - (c3.R)/ (H/2 – R)

Generational Collection

- Observação empírica:
  - Objetos recém criados tedem a morrer logo
  - Objetos que sobreviveram a várias coletas, têm alta probabilidade de sobreviver várias outras coletas
- Coletor concentra esforços nos objetos mais jovens
- O heap é divido em gerações G0, G1, ..., Gn
- A coleta é mais freqüente em G0

Generational Collection

- Coleta de cada geração
  - Usar Mark-Sweep, Copy collection
- Para coletar G0
  - As raizes incluem
    - Variaveis locais
    - Apontadores vindo de gerações mais antigas
- Apontadores de objetos antigos para novos não são comuns!

Generational Collection

- Buscar raízes nas outras gerações seria muito esforço
- Solução
  - Fazer o programa compilador lembrar onde existem ponteiros de objetos velhos para mais novos
- Existem várias alternativas:

Generational Collection

- Remembered List:
  - b.fi ←a coloca b em um vetor de objetos atualizados
  - A cada GC, o vetor é percorrido buscando os b's antigos que apontam para objetos em G0
- Remebered Set:
  - O mesmo que o acima, porém o compilador usa um bit a mais nos objetos b's para indicar que ele já está no vetor
  - Evita duplicar entradas na lista
  - Inicio do GC:
    - Esse conjunto é percorrido em busca de raizes apontando para objetos em G0

Generational Collection

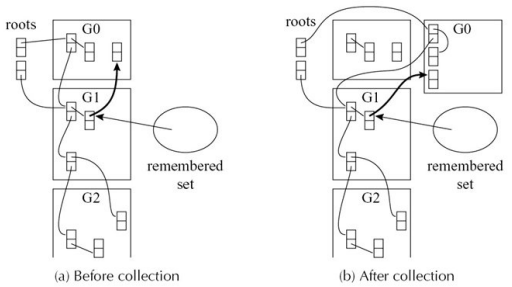

Generational Collection

- Após várias coletas em G0:
  - Coletar G1
  - Mas para isso também devemos coletar G0 junto, pois deve conter vários apontadores para G1
  - Remembered set deve ser percorrido para buscar raizes em G2, G3, ...
- G2 será coletada menos freqüentemente ainda
  - E assim sucessivamente para G3, ...

Generational Collection

- Gerações mais antigas devem ser maiores
- Um objeto passa de Gi para Gi+1 quando sobreviver 2 ou 3 coletas de Gi
- Custo:
  - Supondo G0 com 10% de dados vivos (H/R = 10) e um coletor por cópia: $c3\ R / (10R - R)$
  - Para gerações mais antigas usamos H/R menores
  - Se existem muitos updates em apontadores, pode ser tornar mais cara do que coleta sem gerações

Incremental Collection

- Principal objetivo:
  - Evitar longas interrupções na aplicação
- Coleta é feita de forma incremental
- Aplicado em programas de tempo real ou interativos
- Intercala o trabalho de GC com a execução da aplicação

Incremental Collection

- Aplicação é chamada de *mutator*:
  - Altera o grafo do heap durante a coleta
- Contagem de referências é naturalmente incremental
- Mark-sweep e Copy-collection também podem se tornar incrementais

Marcação por Três Cores

- 3 listas de objetos
  - Brancos:
    - Não alcançados pelo GC
  - Cinzas:
    - Visitados, mas cujos campos ainda não foram percorridos
  - Pretos:
    - Visitados, assim como seus descendentes imediatos.

Marcação por Três Cores

- Todos os objetos iniciam como brancos
- Algoritmo:

```
while there are any grey objects
 select a grey record p
 for each field fi of p
     if record p. fi is white
        color record p. fi grey
 color record p black
```

Marcação por Três Cores

- Ao final:
  - O algoritmo termina quando não houver mais objetos cinzas
  - Todos os objetos vivos devem estar pretos
  - Os brancos que restam devem ser recuperados
- Esse algoritmo pode ser usado com Mark-sweep ou Copy collection
- Invariantes mantidas:
  - Nenhum obj preto aponta para um branco
  - Os cinzas estão na estrutura de dados do GC, pilha ou fila

Marcação por Três Cores

- Mutator pode alterar o grafo durante a coleta
  - Isto pode quebrar uma das invariantes
- Técnicas para preservá-las e permitir que o mutator altere o grafo
  - Write e read barriers

Marcação por Três Cores

- Write-barriers:
  - Djkistra: Se o mutator armazena ou altera um ponteiro em um objeto preto, este se torna cinza
  - Steele: Se o mutator armazena um ponteiro para um objeto branco a em um objeto preto b, b se torna cinza
- Read-barrier:
  - Baker: Sempre que o mutator ler um apontador para um objeto branco, este se torna cinza. O mutator nunca estará manipulando um objeto branco

Algoritmo de Baker

- Baseado em Copy-Collection de Cheney
- Usa read-barrier
- A cópia é intercalada com execução do mutator
- Início atômico:
  - Inversão dos espaços to e from-space
  - Forwarding das raizes

Algoritmo de Baker

- Invariante:
  - Mutator sempre usa apontadores para o to-space
- Principal overhead:
  - Instruções para cada acesso a um apontador
  - Checar se o objeto ainda está no from-space
  - Eventual cópia
- Conservativo
  - Todo objeto alocado durante um ciclo de coleta está vivo em todo o ciclo