

Linguagens de Programação

Modelos de Custo

Andrei Rimsa Álvares
andrei@cefetmg.br



Sumário

- Introdução
- Modelo de custo para listas
- Modelo de custo para chamadas de funções
- Modelo de custo para pesquisas em Prolog
- Modelo de custo para arranjos
- Modelos de custo espúrios



CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

INTRODUÇÃO



Linguagens de Programação



Introdução

- Considere uma lista L em Prolog com milhões de elementos; qual das seguintes abordagens você acha que é mais rápida:
 - Adicionar um novo elemento a cabeça de uma lista?

```
?- length(L, 5000000), time(LL = [a|L]).  
% 0 inferences, 0.000 CPU in 0.000 seconds (61% CPU, 0 Lips)  
L = [_A, _B, _C, _D, _E, _F, _G, _H, _I|...],  
LL = [a, _A, _B, _C, _D, _E, _F, _G, _H|...].
```

Esta primeira abordagem
é mais rápida

- Ou adicionar um novo elemento ao final de uma lista?

```
?- length(L, 5000000), time(append(L, [a], LL)).  
% 5,000,000 inferences, 0.346 CPU in 0.369 seconds (94% CPU, 14443478 Lips)  
L = [_A, _B, _C, _D, _E, _F, _G, _H, _I|...],  
LL = [_A, _B, _C, _D, _E, _F, _G, _H, _I|...].
```



Introdução

- Este tipo de informação é raramente explícito na especificação da linguagem, mas é uma parte importante da expertise de um programador competente
- Todo programador experiente possui um modelo de custo de uma linguagem; um modelo mental dos custos relativos de várias operações

Cuidado: modelar precisamente custos absolutos envolveria conhecer o comportamento da linguagem, do sistema operacional, do processador, da memória...


Aqui serão considerados apenas custos relativos



CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

MODELO DE CUSTO PARA LISTAS



Linguagens de Programação



Modelo de Custo para Listas

- Prolog possui duas formas de especificar listas
 - Uma forma mais conveniente usando colchetes

```
?- L = [1,2,3,4].  
L = [1, 2, 3, 4].
```

- E outra mais detalhada usando o predicado ponto

```
?- L = .(1,. (2,. (3,. (4,[ ])))) .  
L = [1, 2, 3, 4].
```

Cuidado: para que o predicado ponto funcione no interpretador swipl, inicialize-o em modo tradicional:

```
$ swipl --traditional
```

Como listas são implementadas internamente em Prolog?





A lista *Cons-Cell*

- Uma lista é implementada como uma cadeia de ponteiros
 - Este tipo de lista é utilizado em várias linguagens, como ML, Prolog, LISP, entre outras

```
?- A = [],  
   | B = .(1, []),  
   | C = .(1, .(2, [])) .  
A = [],  
B = [1],  
C = [1, 2].
```

A:  → []

B:  → []

C:  → []




A lista *Cons-Cell*

- Uma importante consequência desta representação é que listas podem compartilhar estrutura umas com as outras

```
?- D = [2,3],  
   |   E = [1|D],  
   |   E = [F|G].  
D = [2, 3],  
E = [1, 2, 3],  
F = 1,  
G = [2, 3].
```

Como saber que Prolog compartilha estrutura em listas? Ou seja, que $E = [1|D]$ não gera uma cópia de D ?





Length

- Tanto o predicado `length` de Prolog quanto a função `length` de ML devem percorrer a lista para contar a quantidade de elementos
 - Não tem atalho neste caso, o tempo gasto é proporcional ao tamanho da lista

```
length([], 0).  
length([_|L], Y) :- length(L, Y1), Y is Y1 + 1.
```

Em Prolog

```
fun length nil = 0  
|   length (_::tail) = 1 + length tail;
```


Em ML



Append

- O predicado `append` de Prolog também pode ser custoso, já que é preciso fazer uma cópia da primeira lista

```
?- H = [1,2],  
   I = [3,4],  
   append(H, I, J).  
H = [1, 2],  
I = [3, 4],  
J = [1, 2, 3, 4].
```





Append

- O predicado `append` precisa copiar o prefixo
 - O tempo gasto é proporcional ao tamanho da primeira lista

```
append([], L, L).  
append([X|L1], L2, [X|L3]) :- append(L1, L2, L3).
```

Em Prolog

```
fun append nil l = l  
|   append (head::tail) l = head::append tail l;
```


Em ML



Unificação de Listas em Prolog

- Considere a declaração de três listas iguais K, M, N

```
?- K = [1,2],  
   |   M = K,  
   |   N = [1,2].  
K = [1, 2],  
M = [1, 2],  
N = [1, 2].
```



Como funciona a unificação
para $K = M$? E para $K = N$?

- Para verificar se as listas unificam é preciso comparar elemento por elemento

```
&= ([], []).  
&= ([H|L1], [H|L2]) :- &= (L1, L2).
```

Prolog pode usar atalhos se encontrar uma estrutura compartilhada, mas no pior caso é preciso comparar a estrutura completa de ambas as listas

Cuidado: a unificação é ainda menos eficiente que `length` ou `append`, já que também precisa unificar todos os seus elementos



Modelo de Custo de Listas

- Colocar um elemento no começo de uma lista (*consing*) gasta tempo constante
- Extrair a cabeça ou a cauda de uma lista gasta tempo constante
- Computar o resultado do tamanho de uma lista (como uma função) gasta tempo proporcional ao tamanho da lista
- Computar o resultado da concatenação de duas listas (como uma função) gasta tempo proporcional ao tamanho da primeira lista
- Unificar duas listas gasta, no pior caso, tempo proporcional ao seu tamanho



Aplicação

- Considere a função `reverse` para reverter os elementos de uma lista

```
reverse([], []).  
reverse([Head|Tail], Rev) :-  
    reverse(Tail, TailRev),  
    append(TailRev, [Head], Rev).
```

Qual o problema desta implementação? É possível criar uma variação mais eficiente?

- Concatenar ao final da lista é altamente ineficiente; o modelo de custos guia programadores a adicionar elementos à cabeça da lista

```
reverse(X, Y) :- rev(X, [], Y).  
  
rev([], Sofar, Sofar).  
rev([Head|Tail], Sofar, Rev) :-  
    rev(Tail, [Head|Sofar], Rev).
```


Esta implementação é muito mais eficiente: gasta tempo linear ao invés de quadrático



CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

MODELO DE CUSTO PARA CHAMADAS DE FUNÇÕES





Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: ?

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```




Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```





Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
      | rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: ?

head: 2
tail: [3]
sofar: [1]
endereço de retorno
registro de ativação anterior
resultado: ?

head: 3
tail: nil
sofar: [2,1]
endereço de retorno
registro de ativação anterior
resultado: ?



Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: ?

head: 2
tail: [3]
sofar: [1]
endereço de retorno
registro de ativação anterior
resultado: ?

head: 3
tail: nil
sofar: [2,1]
endereço de retorno
registro de ativação anterior
resultado: ?

sofar: [3,2,1]
endereço de retorno
registro de ativação anterior
resultado: [3,2,1]



Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: ?

head: 2
tail: [3]
sofar: [1]
endereço de retorno
registro de ativação anterior
resultado: ?

head: 3
tail: nil
sofar: [2,1]
endereço de retorno
registro de ativação anterior
resultado: [3,2,1]




Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```





Reverse em ML

- Implementação equivalente mais eficiente da função `reverse` em ML

Registro de ativação atual

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: [3,2,1]

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```



Chamada em Cauda (*Tail Call*)

- No exemplo anterior, após a ativação (recursiva) de cada chamada, nenhuma outra computação foi feita
 - A função apenas retornou o valor para seu chamador
- Este tipo de chamada de função tem um nome especial: **chamada em cauda** (*tail call*)

Todas as chamadas do exemplo anterior foram chamadas em cauda



Recursão em Cauda (*Tail Recursive*)

- Uma função recursiva tem recursão de cauda se todas as suas chamadas recursivas forem chamadas de cauda
 - A função `rev` é recursiva de cauda, como pode ser visto pela sua segunda alternativa

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```

Qual a vantagem de se ter recursão de cauda?



Otimização de Chamada em Cauda (*Tail-Call Optimization*)

- Quando uma função faz uma chamada em cauda, ela não precisa mais de seu registro de ativação
- A maioria dos sistemas de linguagens tiram vantagem disto para otimizar chamadas em cauda ao usar o mesmo registro de ativação para a função chamada
 - Não é preciso empilhar/desempilhar um novo registro de ativação
 - Funções chamadas retornam diretamente ao chamador original

Como funciona isto?



Exemplo

- Exemplo da otimização de chamada em cauda ao aproveitar o mesmo registro de ativação

Registro de ativação atual

head: 1
tail: [2,3]
sofar: nil
endereço de retorno
registro de ativação anterior
resultado: ?

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
end;
```



Exemplo

- Exemplo da otimização de chamada em cauda ao aproveitar o mesmo registro de ativação

Registro de ativação atual

head: 2
tail: [3]
sofar: [1]
endereço de retorno
registro de ativação anterior
resultado: ?

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```



Exemplo

- Exemplo da otimização de chamada em cauda ao aproveitar o mesmo registro de ativação

Registro de ativação atual

head: 3
tail: nil
sofar: [2,1]
endereço de retorno
registro de ativação anterior
resultado: ?

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```



Exemplo

- Exemplo da otimização de chamada em cauda ao aproveitar o mesmo registro de ativação

Registro de ativação atual

(sem uso)
sofar: [3,2,1]
endereço de retorno
registro de ativação anterior
resultado: [3,2,1]

```
fun reverse x =  
  let  
    fun rev (nil, sofar) = sofar  
    |   rev (head::tail, sofar) =  
        rev (tail, head::sofar);  
  in  
    rev(x, nil)  
  end;
```



Modelo de Custo de Otimização de Chamadas em Cauda

- Neste modelo, chamadas em cauda são significativamente mais rápida que chamadas que não são em cauda
- Este tipo de chamada consome muito menos espaço (já que aproveita o mesmo registro de ativação)
 - Funções recursivas em cauda gastam espaço constante
 - Funções não-recursivas em cauda gastam espaço, no mínimo, linear na profundidade da recursão



Aplicação

- Considere a função `length` para calcular o tamanho de uma lista

```
fun length nil = 0  
|   length (_::tail) =  
    1 + length tail;
```

Essa função é recursiva em cauda? Como criar uma variação mais eficiente desta função?

- O modelo de custos guia programadores a criar funções recursiva em cauda

```
fun length list =  
  let  
    fun len (nil, sofar) = sofar  
    |   len (_::tail, sofar) = len (tail, sofar+1);  
  in  
    len (list, 0)  
end;
```

Dica: use um parâmetro como acumulador ao fazer a conversão

Embora mais extensa, esta solução executa mais rápido e toma menos espaço



Aplicabilidade

- Implementado em virtualmente todos os sistemas de linguagens funcionais (algumas garantidas explicitamente pela sua especificação)
- Também implementado por bons compiladores para a maioria das linguagens modernas, como C, C++ e outros

Cuidado: atualmente não implementado pelo sistema de linguagens de Java

- Uma otimização similar é feita pela maioria dos sistemas compilados de Prolog
 - Porém, pode ser complicado identificar chamadas recursivas em cauda

$p \text{ :- } q(X), r(X) .$

A chamada do predicado r não é (necessariamente) uma chamada em cauda, por causa da possibilidade de *backtracking*

MODELO DE CUSTO PARA PESQUISAS EM PROLOG



Linguagens de Programação



Pesquisa em Prolog

- O sistema de busca de Prolog resolve as cláusulas de Horn da esquerda para a direita
- O sistema tenta casar regras do banco de dados na ordem em que aparecem tentando unificar a cabeça de cada regra com o termo alvo atual
- Em caso de falha é feito *backtracking*
 - Podem haver mais de uma regra que pode ser unificada a cada termo alvo, o sistema tenta quantas forem necessárias



Aplicação

- Considere o predicado `grandfather` em Prolog

```
grandfather(X,Y) :-  
    parent(X,Z),  
    parent(Z,Y),  
    male(X).
```

Qual o problema deste predicado? Como criar uma variação mais eficiente dele?

- O modelo de custos guia programadores a usar predicados que restringem o espaço de soluções mais cedo

```
grandfather(X,Y) :-  
    male(X) ,  
    parent(X,Z),  
    parent(Z,Y).
```


Embora logicamente idêntica ao predicado anterior, esta solução pode ser muito mais rápida



CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

MODELO DE CUSTO PARA ARRANJOS



Linguagens de Programação



Arranjos Multidimensionais

- Muitas linguagens de programação suportam arranjos multidimensionais

```
#define M 20000  
#define N 10000  
static char matrix[M][N];
```

```
int addup1() {  
    int i, j, sum = 0;  
    for (i = 0; i < M; i++) {  
        for (j = 0; j < N; j++)  
            sum += matrix[i][j];  
    }  
    return sum;  
}
```

```
int addup2() {  
    int i, j, sum = 0;  
    for (j = 0; j < N; j++) {  
        for (i = 0; i < M; i++)  
            sum += matrix[i][j];  
    }  
    return sum;  
}
```

Qual das duas funções em C é mais rápida, addup1 ou addup2?



Acesso Sequencial

- O hardware da memória é geralmente otimizado para acesso sequencial
 - Se um programa acessa a palavra i , o hardware antecipa de várias maneiras que a palavra $i+1$ será necessária em breve também
- Portanto, acessar elementos de um arranjo sequencialmente, na mesma ordem em que são armazenados na memória, é mais rápido que acessá-los não sequencialmente

Em que ordem os elementos de um arranjo são armazenados na memória?



Arranjo Unidimensional (1D) em Memória

- Um layout natural: um arranjo de n elementos pode ser armazenado em um bloco $n \times size$ palavras, tal que $size$ é o número de palavras por elemento

A:

0	1	2	3	4	5
---	---	---	---	---	---

- O endereço de memória $A[i]$ pode ser computado como $base + i \times size$, tal que $base$ é o início do bloco de memória de A (assumindo que índices começam em 0)

O acesso sequencial é natural – difícil de evitar



Arranjo Bidimensional (2D) em Memória

- Normalmente são visualizados como um grid

M:

	coluna 0	coluna 1	coluna 0	coluna 1		
	0, 0	0, 1	0, 2	0, 3	} linha 0	
	1, 0	1, 1	1, 2	1, 3		} linha 1
	2, 0	2, 1	2, 2	2, 3		} linha 2

- O acesso $M[i][j]$ é dado pela linha i e coluna j

Como mapear este grid 3×4 em uma memória que é linear (sequencial)?



Arranjo Bidimensional (2D) em Memória

- Ordem por linhas (*row-major order*)

M:

0,0	0,1	0,2	0,3	1,0	1,1	1,2	1,3	2,0	2,1	2,2	2,3
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

linha 0 linha 1 linha 2

- Uma linha inteira por vez; m por n usa $m \times n \times size$ palavras
- O endereço $M[i][j]$ é $base + (i \times n \times size) + (j \times size)$

- Ordem por colunas (*column-major order*)

M:

0,0	1,0	2,0	0,3	1,0	1,1	1,2	1,3	2,0	2,1	2,2	2,3
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

coluna 0 coluna 1 coluna 2 coluna 3


- Uma coluna inteira por vez; m por n usa $m \times n \times size$ palavras
- O endereço $M[i][j]$ é $base + (i \times size) + (j \times m \times size)$

Qual destas estratégias C usa? Existe outra forma de representação além destas?



Arranjo Bidimensional (2D) em Memória

- Uma outra estratégia comum é tratar um arranjo bidimensional (2D) como um arranjos de ponteiros unidimensionais (1D)



Como fazer
isto em C?

- Cada linha pode ter um tamanho diferente; linhas não utilizadas não precisam ser alocadas
- Acesso sequencial às linhas inteiras é eficiente, como dado pela ordem por linhas



Arranjos Multidimensionais

- Arranjos bidimensionais podem ser generalizados para dimensões superior (3D, 4D, ...)
- Por exemplo, generalização para acesso usando ordem por linhas

```
for each  $i_0$   
  for each  $i_1$   
    ...  
    for each  $i_{n-2}$   
      for each  $i_{n-1}$   
        access  $A[i_0][i_1] \dots [i_{n-2}][i_{n-1}]$ 
```

O índice mais a direita varia mais rápido (for mais interno)




Visibilidade de Arranjos

- Em C, a implementação dos arranjos é visível através de aritmética de ponteiros
 - Se p é o endereço de $M[i][j]$, então $p+1$ é o endereço de $M[i][j+1]$ em ordem por linhas
- Fortran também deixa visível
 - Alocações sobrepostas revelam ordem por colunas
- Ada usualmente usa ordem por linha, mas não é visível
 - Programas em Ada ainda funcionariam se o layout de memória fosse alterado

Porém, para todas estas linguagens, a visibilidade é parte do modelo de custos

MODELOS DE CUSTO ESPÚRIOS



Linguagens de Programação



Modelo de Custo Espúrio

- Considere o programa em C que recebe um tamanho via argumentos `size` (ex.: 10 milhões) e chama a função `max` $size^2$ vezes

```
int max(int i, int j) {  
    return i > j ? i : j;  
}  
  
int main(int argc, char* argv[]) {  
    int i, j;  
    long long sum = 0;  
    int size = atoi(argv[1]);  
  
    for (i = 0; i < size; i++) {  
        for (j = 0; i < size; i++)  
            sum += max(i, j);  
    }  
  
    printf("Sum: %lld\n", sum);  
    return 0;  
}
```

Quão mais rápido este programa seria se usasse a computação direta `sum += (i>j?i:j)?`



Inlining

- Trocar uma chamada de função pelo corpo da função chamada é chamada de ***inlining***
- É útil para evitar o overhead da chamada da função: empilhar, chamar, desempilhar, retornar
- Normalmente é uma otimização pequena, mas para algo simples como `max` o overhead pode dominar o custo da execução do corpo da função



Modelo de Custo

- O custo da chamada da função é comparável ao custo de execução do corpo de uma função pequena
- Isto guia programadores a usar *inlining* em seus códigos (ou macros em C) ao invés de chamada de funções, principalmente para funções pequenas que são chamadas muitas vezes

Cuidado: este modelo de custo normalmente está errado, qualquer compilador de C de respeito faz *inlining* automaticamente (ex.: gcc com `-O2`)

O código anterior executa na mesma velocidade, independente se o *inlining* foi feito manualmente ou pelo compilador



Aplicabilidade

- Não é um fenômeno exclusivo de C, vários sistemas de linguagens para diferentes linguagens fazem *inlining*
 - É especialmente importante, e frequentemente implementado, por linguagens orientadas a objetos
- No geral é um erro tumultuar o programa com cópias manuais de corpos de função (*inlining*)
 - Isto torna o programa difícil de ler e de manter e não o torna mais rápido depois de otimizações

Nos primeiros 10 anos da linguagem, compiladores de C que faziam *inlining* não eram disponíveis: fazia sentido fazer *inlining* manualmente em códigos críticos

Dica: hoje em dia já não faz mais sentido fazer *inlining* manualmente

ISSO É TUDO, PESSOAL!



Linguagens de Programação