

Spineless Tagless G-machine

Pedro Vasconcelos

19 de Maio de 2020

Spineless Tagless G-Machine


- Uma máquina abstracta para linguagens funcionais com semântica não-estrita (*lazy evaluation*)
- Evolução da *G-machine* e da *Spineless G-machine*

Bibliografia: *Implementing lazy functional languages on stock hardware: the Spineless Tagless G-machine, Version 2.5.*
Simon L. Peyton Jones, 1992.

O que é a STG?

- É uma **linguagem funcional** muito restricta
- Com uma **semântica operacional** passo-a-passo
- Pode ser **facilmente implementada** numa máquina convencional
- Possibilita muitas **otimizações** como transformações de programa
- Utilizada no *backend* do Glasgow Haskell Compiler (GHC)

Visão global do GHC



Concepção geral

- Abstracções- λ e aplicações com **vários argumentos**

$$\lambda x_1. \lambda x_2. \dots \lambda x_n. e \simeq \lambda \{x_1, x_2, \dots, x_n\}. e$$

- Mais eficiente do que aplicação unária
- Aplicação parcial é permitida (*currying*)
- Argumentos de aplicações devem ser **atômicos** (variáveis ou literais)
 - Expressões complexas devem ser nomeadas usando *let*
 - Os argumentos são construídos *antes* de invocar a função
 - Torna explícita a ordem de avaliação

Concepção geral (cont.)

- Representação uniforme na *heap*: **closures**
 - Abstracções- λ , *thunks* e dados algébricos
 - Evita a necessidade de *tags*
- Construtores e operações primitivas **saturados**: número fixo de argumentos
- **Tratamento uniforme** de estruturas de dados:
 - Não há casos especiais para booleanos, listas ou tuplos
 - Decomposição usando apenas **expressões-case** simples
 - Suporta **representações optimizadas** (*unboxed*)

- 1 Linguagem STG
- 2 Semântica operacional
- 3 Observações

Linguagem STG

$expr ::= \text{let } binds \text{ in } expr$
| $\text{letrec } binds \text{ in } expr$
| $\text{case } expr \text{ of } alts$
| $var \ atoms$
| $constr \ atoms$
| $prim \ atoms$
| $literal$

definições locais
definições recursivas
discriminação
aplicação de função
aplicação de construtor
aplicação de primitiva
inteiro primitivo

$binds ::= var_1 = lf_1; \dots; var_n = lf_n \quad (n \geq 1)$

$lf ::= vars_f \setminus \pi \ vars_a \rightarrow expr$

$\pi ::= u \mid n$

lambda-form
update-flag

$vars ::= \{var_1, \dots, var_n\} \quad (n \geq 0)$

$atoms ::= \{atom_1, \dots, atom_n\} \quad (n \geq 0)$

$atom ::= var \mid literal$

Lambda-forms

Abstracções- λ são representadas por *lambda-forms*:

$$\underbrace{\{v_1, \dots, v_m\}}_{\text{variáveis livres}} \setminus \pi \underbrace{\{x_1, \dots, x_n\}}_{\text{variáveis ligadas}} \rightarrow \text{expr} \quad \text{onde } n \geq 0, m \geq 0$$

Denotacionalmente:

$$\lambda x_1. \dots \lambda x_n. \text{expr}$$

Operacionalmente:

- π indica se deve fazer ou não *update* após redução
- variáveis livre indicam o tamanho da *closure*

Expressões-case

```
case expr0 of
  constr1 vars1 -> expr1;
  ⋮
  constrn varsn -> exprn
```

- Mecanismo único para decompor valores estruturados
- Restrito a padrões simples (i.e. um nível de construtor)
- Também usado sobre valores primitivos (e.g. inteiros)

Programa

- Programa é uma sequência de definições globais
- Ponto de entrada: expressão *main*

$$g_1 = \{\dots\} \setminus \pi_1 \{\dots\} \rightarrow \mathit{expr}_1 ;$$
$$g_2 = \{\dots\} \setminus \pi_2 \{\dots\} \rightarrow \mathit{expr}_2 ;$$
$$\vdots$$
$$g_n = \{\dots\} \setminus \pi_n \{\dots\} \rightarrow \mathit{expr}_n ;$$
$$\mathit{main} = \{\dots\} \setminus \pi_{n+1} \{\} \rightarrow \mathit{expr}_{n+1}$$

Exemplo

Código fonte Haskell:

```
map f [] = []  
map f (y:ys) = (f y) : (map f ys)
```

Tradução para STG:

```
map = {} \n {f,xs} ->  
  case xs of  
    Nil{} -> Nil {};  
    Cons{y,ys} ->  
      let fy = {f,y} \u {} -> f{y};  
          mfy= {f,ys} \u {} -> map{f,ys}  
      in Cons{fy,mfy}
```

Transformações necessárias

- 1 Substituir aplicações binárias por multi-aplicação:

$$(\dots((f e_1) e_2) \dots e_n) \implies f\{e_1, e_2, \dots, e_n\}$$

- 2 Saturar construtores e operadores primitivos usando expansão- η :

$$c\{e_1, \dots, e_n\} \implies \lambda y_1 \dots y_m. c\{e_1, \dots, e_n, y_1, \dots, y_m\}$$

- 3 Introduzir nomes temporários para argumentos não-atômicos e abstrações- λ :

$$f\{\dots, \underbrace{expr}_{\text{complexa}}, \dots\} \implies \text{let } t = expr \text{ in } f\{\dots, t, \dots\}$$

- 4 Converter os lados direitos de *lets* em *lambda-forms* acrescentando variáveis livres e *updates*

Onde fazer *updates*?

Non-updatable: ① Abstracções- λ

$vs \setminus n xs \rightarrow expr \quad (|xs| > 0)$

② Aplicações parciais

$vs \setminus n \{ \} \rightarrow f\{x_1, \dots, x_m\} \quad \dots$

③ Construtores

$vs \setminus n \{ \} \rightarrow c\{x_1, \dots, x_m\} \quad \dots$

Updatable: tudo o resto (*thunks*)

$vs \setminus u \{ \} \rightarrow expr$

Mas: análise estática pode fazer melhor (ver bibliografia).

Operações aritméticas

```
foo x = let y = 1/x  
        in if x==0 then ... else y
```

- Podemos necessitar de construir *thunks* para inteiros
- A redução de grafos *naive*: representar inteiros como valores na *heap* (*boxed*)
- Torna as operações aritméticas muito ineficientes...

Inteiros *boxed* vs. *unboxed*

```
data Int = I# Int#
-- Int : inteiro "boxed"
-- Int# : inteiro "unboxed"

plusInt :: Int -> Int -> Int
plusInt = {} \n {bx,by} ->
  case bx of
    I# x -> case by of
      I# y -> case (x +# y) of
        z -> I# z
```


Representações *boxed* e *unboxed* na STG

- A STG opera directamente apenas sobre valores primitivos (*unboxed*)
- Valores *boxed* são obtidos com construtores algébricos
- Permite expor optimizações como transformações de programa
- Permite expor valores *unboxed* ao programador

Limitações:

- Valores *unboxed* não podem ser usados em funções polimorfas
- Nomes ligados usando *case* em vez de *let*

Exemplo: factorial otimizado

```
{-# LANGUAGE MagicHash #-}
module Main where
import GHC.Exts

-- função "wrapper"
fact :: Int -> Int
fact (I# n) = I# (factAux n)

-- função "worker"
-- usa inteiros "unboxed"
factAux :: Int# -> Int#
factAux n
    = case n of 0# -> 1#
                _ -> n *# factAux (n -# 1#)

main = print (fact 10)
```

- 1 Linguagem STG
- 2 Semântica operacional**
- 3 Observações

Semântica operacional

Cada construção sintática tem uma interpretação operacional:

let alocação de *thunks/closures*;

case avaliação e selecção;

aplicação de funções salto incondicional;

aplicação de construtores retorno a uma continuação.

Estado da máquina abstracta

Code próxima ação a executar

Argument stack sequência de valores

Return stack sequência de continuações

Update stack sequência de *update frames*

Heap tabela de endereços para *closures*

Globals endereços de *closures* globais (não mudam)

Valores

Dois tipos:

Addr a endereço de um objecto na *heap*

Int n inteiro primitivo

NB: as etiquetas *Addr* e *Int* são apenas para a exposição — não são necessárias durante a execução.

Ambientes

Um **ambiente** ρ associa valores a variáveis:

$$\rho = [x_1 \mapsto v_1, \dots, x_n \mapsto v_n]$$

Usamos σ para o ambiente de **globais**:

$$\sigma = [g_1 \mapsto \text{Addr } a_1, \dots, g_m \mapsto \text{Addr } a_m]$$

Valor de um átomo

Função auxiliar:

$\text{val } \rho \ \sigma \ n = \text{Int } n$

$\text{val } \rho \ \sigma \ x = \rho \ x \quad (x \in \text{dom } \rho)$

$\text{val } \rho \ \sigma \ x = \sigma \ x \quad (x \in \text{dom } \sigma)$

Heap

A heap associa *endereços* a *closures*:

$$h = \left[\begin{array}{l} a_1 \mapsto \text{closure}_1 \\ \vdots \\ a_n \mapsto \text{closure}_n \end{array} \right]$$

Cada closure é um par com uma *lambda-form* e um ambiente

$$\text{closure} = \left(\underbrace{vs \ \backslash \ \pi \ xs \rightarrow \text{expr}}_{\text{lambda-form}}, \underbrace{ws}_{\text{ambiente}} \right)$$

onde $|vs| = |ws|$.

Code

Quatro estados:

`Eval e ρ` avaliar `e` no ambiente `ρ` ;

`Enter a` avaliar a *closure* no endereço `a`;

`ReturnCon c ws` retornar um construtor;


`ReturnInt k` retornar um inteiro.

Estado inicial

Code	ArgStk	ReturnStk	UpdateStk	Heap	Globs
Eval (<i>main</i> {}) []	{}	{}	{}	h_0	σ

$$\sigma = [g_1 \mapsto \text{Addr } a_1, \dots, g_n \mapsto \text{Addr } a_n]$$
$$h_0 = \begin{bmatrix} a_1 \mapsto (vs_1 \setminus \pi \ xs_1 \rightarrow e_1) (\sigma \ vs_1) \\ \vdots \\ a_n \mapsto (vs_n \setminus \pi \ xs_n \rightarrow e_n) (\sigma \ vs_n) \end{bmatrix}$$

Aplicação de funções



Enter (non-updatable thunk)

Code	ArgStk	ReturnStk	UpdateStk	Heap
Enter a	as	rs	us	h
tal que $h a = (vs \setminus n xs \rightarrow e, ws_f)$				
length $as \geq$ length xs				
\Downarrow				
Eval $e \rho$	as'	rs	us	h
onde $ws_a ++ as' = as$				
length $ws_a =$ length xs				
$\rho = [vs \mapsto ws_f, xs \mapsto ws_a]$				

Expressões-let

$$\text{Eval} \left(\begin{array}{l} \text{let } x_1 = \text{vs}_1 \setminus \pi_1 \text{ys}_1 \rightarrow e_1 \\ \vdots \\ x_n = \text{vs}_n \setminus \pi_n \text{ys}_n \rightarrow e_n \\ \text{in } e \end{array} \right) \rho \left| \begin{array}{c} \dots \\ as \\ rs \\ us \\ h \end{array} \right.$$

\Downarrow

$$\text{Eval } e \rho' \left| \begin{array}{c} as \\ rs \\ us \\ h' \end{array} \right.$$

onde

$$\rho' = \rho[x_1 \mapsto \text{Addr } a_1, \dots, x_n \mapsto \text{Addr } a_n]$$
$$h' = h \left[\begin{array}{l} a_1 \mapsto (\text{vs}_1 \setminus \pi_1 \text{ys}_1 \rightarrow e_1, \rho \text{ vs}_1) \\ \vdots \\ a_n \mapsto (\text{vs}_n \setminus \pi_n \text{ys}_n \rightarrow e_n, \rho \text{ vs}_n) \end{array} \right]$$


Expressões-letrec

- Análogo ao caso anterior
- ρ' em vez de ρ na definição de de h'
- Ver a bibliografia

Expressões-case

Code	ArgStk	ReturnStk	UpdateStk	Heap
Eval (case e of $alts$) ρ	as	rs	us	h
		↓		
Eval e ρ	as	$(alts, \rho) : rs$	us	h

Construtores



Construtores

Code		ArgStk		ReturnStk		UpdateStk		Heap
ReturnCon c ws		as		$(alts, \rho) : rs$		us		h
tal que $alts = \{\dots; c\ xs \rightarrow e; \dots\}$								

⇓

Eval e $\rho[xs \mapsto ws]$		as		rs		us		h
--------------------------------	--	------	--	------	--	------	--	-----

Enter (updatable thunk)

Code	ArgStk	ReturnStk	UpdateStk	Heap
Enter a	as	rs	us	h
tal que $h a = (vs \setminus u \{\} \rightarrow e, ws_f)$				

⇓

Eval $e \rho$	$\{\}$	$\{\}$	$(as, rs, a) : us$	h
onde $\rho = [vs \mapsto ws_f]$				

Update de um constructor

Code	ArgStk	ReturnStk	UpdateStk	Heap
ReturnCon c ws	$\{\}$	$\{\}$	$(as_u, rs_u, a_u) : us$	h
		\Downarrow		
ReturnCon c ws	as_u	rs_u	us	h_u

onde vs variáveis arbitrárias


$\text{length } vs = \text{length } ws$

$h_u = h[a_u \mapsto (vs \setminus n \{\} \rightarrow c \text{ } vs, ws)]$


Inteiros (Eval)

Code	ArgStk	ReturnStk	UpdateStk	Heap
Eval $k \rho$	as	rs	us	h
		↓		
ReturnInt k	as	rs	us	h

Operações aritméticas



Inteiros (return)



Inteiros (default return)

Code	ArgStk	ReturnStk	UpdateStk	Heap
ReturnInt k	as	$\left(\begin{array}{l} k_1 \rightarrow e_1; \\ \vdots \\ k_n \rightarrow e_n; \\ x \rightarrow e \end{array} \right), \rho : rs$	us	h
se $k \neq k_i \quad (1 \leq i \leq n)$				

\Downarrow

Eval $e \rho'$	as	rs	us	h
----------------	------	------	------	-----

onde $\rho' = \rho[x \mapsto \text{Int } k]$.

Observações

- O modelo de execução de funções da STG original (1992) é “*push-enter*”
- É uma forma elegante para implementar *lazy evaluation*
- As versões mais recentes do GHC usam “*eval-apply*” convencional porque é mais eficiente na prática
- As alterações são descritas no artigo de 2004: *How to make a fast curry*

Mais informação

- Um simulador da STG em Haskell:
`https://github.com/quchen/stgi`
- *How to make a fast curry*, S. Peyton-Jones, 2004.
`https://www.microsoft.com/en-us/research/publication/make-fast-curry-pushenter-vs-evalapply`