

## IMPLEMENTAÇÃO DE ESTRUTURAS HASH CONCORRENTES EM HASKELL

RODRIGO M. DUARTE; MAURÍCIO L. PILLA; RENATA H. S. REISER;  
ANDRÉ R. DU BOIS

UFPEL – UNIVERSIDADE FEDERAL DE PELOTAS  
LUPS – Laboratory of Ubiquitous and Parallel Systems  
{rmduarte, pilla, reiser, dubois}@inf.ufpel.edu.br

### 1. INTRODUÇÃO

Algoritmos de tabela *hash* são naturalmente paralelizáveis, o motivo disso se dá ao fato que o acesso aos dados da tabela são suscetíveis de serem disjuntos. Porém a implementação de um algoritmo que explore de forma otimizada esta característica esta longe de ser trivial (HERLIHY, 2012). Implementar um algoritmo usando um *lock* global é simples porém ineficiente, e proteger cada posição da tabela com um *lock* é eficiente porém torna o crescimento da tabela complexo.

A linguagem de programação Haskell é uma linguagem funcional pura de alto nível que apresenta várias abstrações de sincronização para a programação concorrente, e.g., variáveis de sincronização (*MVars*), memórias transacionais e acesso a instruções de baixo nível para sincronização – CAS (*compare and swap*) (MARLOW, 2013).

Este trabalho apresenta a implementação de três diferentes algoritmos de tabela *hash* concorrente em Haskell, utilizando diferentes métodos de sincronismo. Também é feita a comparação do desempenho entre elas e os resultados mostram que, a implementação utilizando a técnica de granularidade fina usando memórias transacionais, apresentou os melhores resultados.

### 2. METODOLOGIA

#### Tipos de algoritmos de hash concorrente

Os algoritmos estudados para implementação (HERLIHY, 2012), possuem três operações básicas de acesso a tabela *hash* que são inserção, consulta e remoção. Todos os algoritmos utilizam endereçamento fechado, i.e., cada posição da tabela pode conter um conjunto de itens geralmente implementado usando uma lista encadeada. O crescimento da tabela *hash* depende do número de inserções, se o número de inserções alcança certo limite pré-estabelecido, o tamanho da tabela deverá dobrar (LEISERSON, 2012). Cada algoritmo possui uma forma diferente de tratar o crescimento da tabela e esta é a operação de maior complexidade na implementação dos algoritmos.

#### **Hash com lock global:**

Neste algoritmo um único *lock* protege a tabela *hash* inteira. Cada função adquire o *lock*, realiza sua operação e depois o libera. Na necessidade de crescimento da tabela, como a função de inserção já possui o *lock*, ela pode simplesmente aumentar a tabela, sem se preocupar com conflitos. Este algoritmo é extremamente simples de ser implementado, porém não explora nenhum paralelismo devido ao gargalo gerado pelo *lock*.

### **Hash de blocos:**

A implementação deste algoritmo utiliza dois *arrays* distintos, um para as entradas da tabela *hash* e outro de *locks*. Quando a tabela *hash* é iniciada, ambos os *arrays* possuem o mesmo tamanho. Ao realizar um crescimento na tabela, dobra-se o *array* de entradas da *hash* mas se mantém o tamanho do *array* de *locks*, assim cada *lock* passa a proteger duas posições da tabela. Como crescimentos na tabela *hash* são raros, existem dois motivos para evitar o crescimento do *array* de *locks* que são (HERLIHY,2012):

- Associar um *lock* para cada *slot* da tabela ocupa muito espaço, especialmente quando as tabelas são grandes e a contenção é baixa.
- Aumentar o *array* de *slots* é simples, porém aumentar o *array* de *locks* (quando estão em uso), é mais complicado.

### **Hash de granularidade fina:**

No algoritmo usando granularidade fina, a tabela *hash* possui uma *flag* que serve para indicar se está em um processo de crescimento ou não, e tanto o *array* de *locks* quanto o de entradas é duplicado. Esta *flag* possui um valor booleano e é alterada atomicamente pela *thread* que está realizando um crescimento da tabela. Quando o valor desta *flag* é verdadeiro, isso indica que alguma *thread* está realizando um crescimento da tabela, informando as outras *threads* que os *locks* não podem ser adquiridos porque não são mais válidos, e que devem esperar até que a *flag* torne-se falsa para poderem prosseguir.

Apesar de parecer simples, este processo envolve certa complexidade, pois durante o processo de crescimento, temos de verificar se todas as *threads* terminaram suas operações, caso contrário não se pode prosseguir com a operação de crescimento.

### **Métodos de sincronização em Haskell**

A linguagem funcional Haskell fornece alguns modelos para sincronismo entre *threads*, os estudados aqui são *MVar*, *IORef* + *atomicModifyIORef* e *STM Haskell*, que são modelos de sincronismo já utilizados em outros trabalhos envolvendo estrutura de dados em Haskell (SULZMANN2009).

#### ***MVar*:**

É o mecanismo básico de comunicação entre *threads* de Haskell. Uma *MVar* é uma espécie de variável que pode assumir duas situações: cheia ou vazia. (MARLOW, 2013). *MVars* operam como os tradicionais *mutex*. Neste trabalho usaremos uma *MVar* como um *lock* para realizar a sincronização das *threads* no acesso a *hash*.

#### ***IORef* + *atomicModifyIORef*:**

Este método pode ser comparado ao CAS (*compare and swap*) de outras linguagens de programação. Um *IORef* é uma referência a uma posição de memória. Haskell fornece uma função (*atomicModifyIORef*) que assim como a operação CAS, permite a modificação atômica da referência, podendo assim uma *IORef* ser utilizada para implementar algoritmos não bloqueantes.

#### **STM Haskell (*Software Transactional Memory*):**

*Software transactional Memory (STM)* é um novo modelo de sincronização entre *threads* que simplifica a programação concorrente, permitindo que operações possam ser compostas em uma simples operação atômica. A ideia é fazer com que as operações sejam realizadas como transações parecidas com as

transações de bancos de dados (RIGO, 2007). Neste modelo, todo o sincronismo é realizado pelo sistema transacional, evitando assim problemas como *deadlocks*.

STM Haskell é uma extensão da linguagem Haskell que fornece primitivas para a programação usando STM (HARRIS,2005). Nela é definida um tipo de variável transacional *TVar*. *STM Haskell* garante que operações que modificam uma *TVar*, sejam somente realizadas dentro de uma transação. Assim, o programador não precisa se preocupar com o sincronismo, pois o sistema de tipos de Haskell garante que nenhuma variável *TVar* seja alterada fora de um bloco protegido, garantindo assim consistência e facilidade no desenvolvimento de programas paralelos.

### 3. RESULTADOS E DISCUSSÃO

Foram implementadas tabelas *hash* usando as três primitivas apresentadas usando os algoritmos estudados. Entre as implementações foram duas de *lock* global e granularidade fina, usando *MVar* e *TVar* e uma em bloco usando *MVars*.

Os testes foram realizados em uma máquina core i7 de 3.0Ghz com 8 cores (4 físicos e 4 lógicos) e 8Gb de RAM. Foram feitas 30 execuções de cada implementação, realizando 1 milhão de operações sobre a tabela, sendo 10% inserções, 10% deleções e 80% consultas, conforme estatísticas em (HERLIHY, 2012). Os gráficos das Figura 1 e 2 mostra os resultados dos testes.

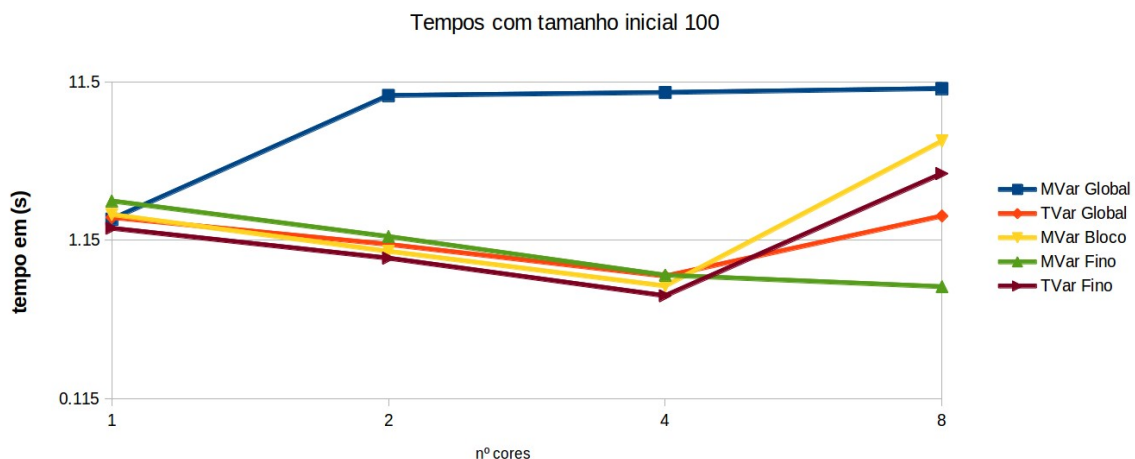


Figura 1

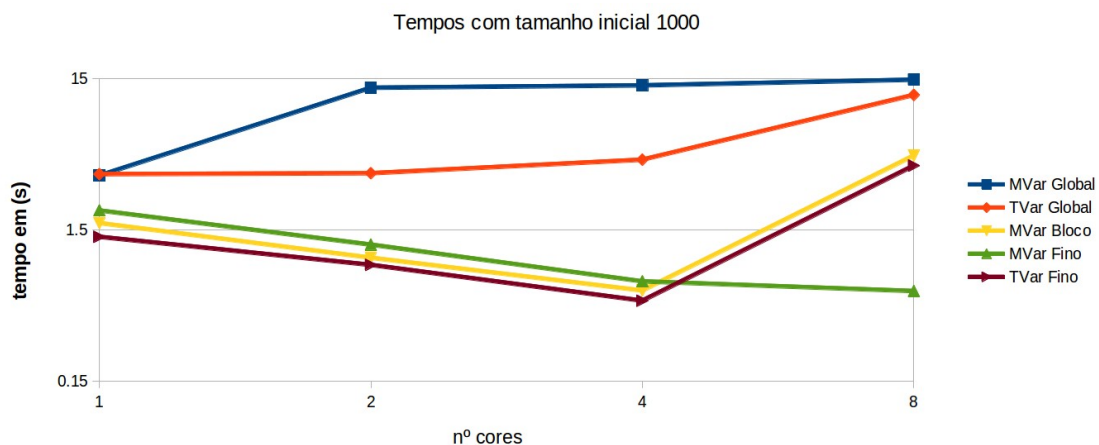


Figura 2

Podemos perceber que conforme o esperado, a tabela usando *lock* global com *MVar* teve perda de desempenho conforme se aumentou o número de *threads* utilizadas, porém o mesmo não se observa utilizando *TVars*, ao contrário do esperado, obtiveram desempenho, porém quando se aumentou o tamanho inicial da tabela de 10 para 10 mil elementos, ambas perderam desempenho devido ao número de operações sobre a tabela ter aumentado muito.

Nas implementações de *hash* em bloco e fina obteve-se desempenho conforme se aumentou o número de *threads*. Isso se deve ao fato de neste tipo de algoritmo podemos ter mais de uma *thread* acessando a tabela ao mesmo tempo, conseguindo assim maior desempenho. A diferença de tempo vista entre a implementação usando blocos da usando granularidade fina se da devido ao fato da maior complexidade para a aquisição dos locks na tabela com granularidade fina.

A implementação de granularidade fina usando *TVar* obteve maior desempenho se comparada a todas as outras, isso se dá devido a baixa quantidade de conflitos existentes na tabela.

#### 4. CONCLUSÕES

A implementação usando granularidade fina com *TVar* foi a que obteve maior desempenho. Isso se deve ao fato de que em transações o nível de contenção é menor. Outra coisa importante ao se utilizar transações é que o sistema transacional garante todo o sincronismo de forma automática, eximindo o programador desta tarefa, tornando a programação paralela mais simples, evitando assim problemas comuns como a ocorrência de *deadlocks*.

Como trabalhos futuros, pretendesse implementar uma biblioteca para Haskell afim de fornecer a implementação para uso da comunidade em geral, visto que não existem implementações deste tipo de estrutura de dados em Haskell.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

HERLIHY, M. e Shavit, N. *The Art of Multiprocessor Programming*, USA: Elsevier, 2012.

MARLOW, S. *Parallel and Concurrent Programming in Haskell*, USA: O'Reilly, 2013.

LEISERSON, C. E., Rivest, R. L., Stein, C., e Cormen, T.H. *Introduction to algorithms*, USA: MIT Press, 2012.

RIGO, S., Centoducatte, P., and Baldassin, A. Memórias transacionais: Uma nova alternativa para programação concorrente. **Minicursos do VIII Workshop em Sistemas Computacionais de Alto Desempenho**, 2007 .

HARRIS, T., Marlow, S., Jones, S. P., and Herlihy, M. **Composable memory transactions**. Commun. ACM, 51:91–100. (2008).

SULZMANN, M., Lam, E. S., and Marlow, S. Comparing the performance of concurrent linked-list implementations in haskell. **Anais do 4th workshop on Declarative aspects of multicore programming**, pages 37–46. ACM. (2009).