

什么是高速缓存参数无关算法？

2007-01-06


张坤龙

zhangkl@tju.edu.cn

目录


- 算法的性能度量
- 三个计算矩阵乘积的算法
- 高速缓存参数无关算法

CPU与DRAM的性能差距



*图片来源: Computer Architecture: A Quantitative Approach, 2nd Edition


典型的存储器层次结构



存储容量越来越大，存取时间越来越长，带宽越来越窄

RAM模型


Random Access Machine Model



- 假设：所有内存访问花费相等的时间
- 性能度量：计算复杂性

EM模型


External Memory Model



- 假设：1) 内存大小为 M ，外存大小为 N ，块的大小为 B ， $1 \leq B \leq M < N$ ；
2) 算法需要负责内外存之间的数据传输，即自己决定替换策略
- 性能度量：I/O复杂性

理想高速缓存模型

Ideal Cache Model



- 假设：1) $z = \Omega(L^2)$ ；2) 采用最佳替换算法；3) 替换自动进行；4) 高速缓存是全关联的
- 性能度量：1) 工作复杂性 $W(n)$ ；2) 高速缓存复杂性 $Q(n;Z,L)$

目录

- 算法的性能度量
- 三个计算矩阵乘积的算法
- 高速缓存参数无关算法

矩阵的存储

$$A_{n \times n} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}$$

以行序为主序的矩阵存储

a_{11}
a_{12}
$\dots$
a_{1n}
a_{21}
a_{22}
$\dots$
a_{2n}
$\dots$
a_{n1}
a_{n2}
$\dots$
a_{nn}


第一个算法

$$C_{n \times n} = A_{n \times n} B_{n \times n}, \quad c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}, \quad n \gg Z/L$$

ORD-MULT (A, B, C, n)

```

1  for  $i \leftarrow 1$  to  $n$  do
2      for  $j \leftarrow 1$  to  $n$  do
3           $c_{ij} \leftarrow 0$ 
4          for  $k \leftarrow 1$  to  $n$  do
5               $c_{ij} \leftarrow c_{ij} + a_{ik} b_{kj}$ 
    
```





第一个算法的性能

$$C_{n \times n} = A_{n \times n} B_{n \times n}, \quad c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}, \quad n \gg Z/L$$

ORD-MULT (A, B, C, n)

```

1  for  $i \leftarrow 1$  to  $n$  do
2      for  $j \leftarrow 1$  to  $n$  do
3           $c_{ij} \leftarrow 0$ 
4          for  $k \leftarrow 1$  to  $n$  do
5               $c_{ij} \leftarrow c_{ij} + a_{ik} b_{kj}$ 
    
```




第二个算法

分块，矩阵块大小为 $s \times s$

BLOCK-MULT (A, B, C, n)

```
1  for  $i \leftarrow 1$  to  $n/s$  do
2      for  $j \leftarrow 1$  to  $n/s$  do
3           $C_{ij} \leftarrow 0$ 
4          for  $k \leftarrow 1$  to  $n/s$  do
5               $C_{ij} \leftarrow C_{ij} + A_{ik}B_{kj}$ 
```





第二个算法的性能

分块，矩阵块大小为 $s \times s$

BLOCK-MULT (A, B, C, n)

```
1  for  $i \leftarrow 1$  to  $n/s$  do
2      for  $j \leftarrow 1$  to  $n/s$  do
3           $C_{ij} \leftarrow 0$ 
4          for  $k \leftarrow 1$  to  $n/s$  do
5               $C_{ij} \leftarrow C_{ij} + A_{ik}B_{kj}$ 
```


$$\Theta(n^3 / Ls)$$



第三个算法

$C_{n \times n} = A_{n \times n} B_{n \times n}$, 若 $n > 1$, 则分四块


$$\begin{pmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{pmatrix} = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \cdot \begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix}$$
$$= \begin{pmatrix} A_{11}B_{11} + A_{12}B_{21} & A_{11}B_{12} + A_{12}B_{22} \\ A_{21}B_{11} + A_{22}B_{21} & A_{21}B_{12} + A_{22}B_{22} \end{pmatrix}$$

第三个算法的性能

$C_{n \times n} = A_{n \times n} B_{n \times n}$, 若 $n > 1$, 则分四块

$$\begin{pmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{pmatrix} = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \cdot \begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix}$$

$$= \begin{pmatrix} A_{11}B_{11} + A_{12}B_{21} & A_{11}B_{12} + A_{12}B_{22} \\ A_{21}B_{11} + A_{22}B_{21} & A_{21}B_{12} + A_{22}B_{22} \end{pmatrix}$$


$$\Theta(n^3 / L\sqrt{Z})$$

$$Q(n) = \begin{cases} \Theta(Z / L) & n \leq \alpha\sqrt{Z}, \\ 8Q(n/2) + \Theta(n^2 / L) & n > \alpha\sqrt{Z}. \end{cases}$$

目录

- 算法的性能度量
- 三个计算矩阵乘积的算法
- 高速缓存参数无关算法

三个计算矩阵乘积算法的比较

- 第一个算法的性能

$$Q(n) = \Theta(n^3)$$

- 第二个算法的性能

$$Q(n) = \Theta(n^3 / Ls)$$

$$W(n) = \Theta(n^3)$$

$$s = \Theta(\sqrt{Z})$$

$$Q(n) = \Theta(n^3 / L\sqrt{z})$$

- 第三个算法的性能

$$Q(n) = \Theta(n^3 / L\sqrt{z})$$

Cache-Oblivious Algorithms

We define an algorithm to be ***cache aware*** if it contains parameters (set at either compile-time or runtime) that can be tuned to optimize the cache complexity for the particular cache size and line length. Otherwise, the algorithm is ***cache oblivious***.

- M. Frigo, C. E. Leiserson, H. Prokop, and S. Ramachandran

几种算法间的关系

- 外存算法是高速缓存参数相关的 → 找出具有渐进最优高速缓存复杂性 $Q(n)$ 的外存算法
- **RAM**算法是高速缓存参数无关的 → 找出具有渐进最优工作复杂性 $W(n)$ 的**RAM**算法
- 高速缓存参数无关算法的设计基于**RAM**模型，性能分析基于理想高速缓存模型 → 找出具有渐进最优高速缓存复杂性 $Q(n)$ 的**RAM**算法

高速缓存参数无关算法的优点

- 可移植
 - 无需考虑高速缓存的参数 Z 和 L
- 自优化
 - 无需考虑内存有多少个层次

一些研究成果

- 高速缓存参数无关算法设计
 - 扫描，分治，Van Emde Boas布局，k-Merger，
- 高速缓存参数无关算法
 - 矩阵的相乘与转置，排序，图算法，
- 高速缓存参数无关数据结构
 - 二叉查找树，优先队列，B树，kd树，

参考文献

- R. D. Blumofe, M. Frigo, C. F. Joerg, C. E. Leiserson, and K. H. Randall. [An analysis of dag-consistent distributed shared-memory algorithms](#). In Proceedings of the Eighth Annual ACM Symposium on Parallel Algorithms and Architectures, 1996.
- M. Frigo, C. E. Leiserson, H. Prokop, and S. Ramachandran. [Cache-oblivious algorithms](#). In *40th Annual IEEE Symposium on Foundations of Computer Science*, 1999.
- Erik D. Demaine. [Cache-Oblivious Algorithms and Data Structures](#). BRICS, University of Aarhus, Denmark, 2002.
- 吴英杰。充分利用高速缓存的高效算法研究。硕士论文，福州大学，2004。