

文章编号:1001-9081(2006)06-1492-04

## 读请求的空间与时间特征建模

魏文国<sup>1,2</sup>, 罗俊<sup>3</sup>, 向军<sup>2</sup>

(1. 华南理工大学 广东省计算机网络重点实验室, 广东 广州 510641;  
2. 广东技术师范学院 计算机科学系, 广东 广州 510665;  
3. 广东技术师范学院 计算机与网络中心, 广东 广州 510665)  
(wgwei@21cn.com)

**摘要:**为了改善并行应用程序和并行文件系统的 I/O 性能, 对读请求的空间与时间特征进行建模。使用自相关函数分析和 Haar 小波变换来自动识别自回归、集成的移动平均的模型结构, 通过该模型来预测读请求的时间特征; 使用马尔可夫模型对读请求的空间特征进行建模、预测。该模型可以将自回归、集成的移动平均时间预测模型与马尔可夫空间预测模型结合, 并自适应地预测什么时间、取哪些数据块、取多少数据块。

**关键词:**并行文件系统; 读请求建模; 预测; 自回归、集成的移动平均模型; 马尔可夫模型

中图分类号: TP302 文献标识码:A

## Automatic temporal and spatial modeling of read request

WEI Wen-guo<sup>1,2</sup>, LUO Jun<sup>3</sup>, XIANG Jun<sup>1</sup>

(1. Guangdong Key Laboratory of Computer Network, South China University of Technology, Guangzhou Guangdong 510641, China;  
2. Department of Computer Science, Guangdong Polytechnic Normal University, Guangzhou Guangdong 510665, China;  
3. Computer and Net Center, Guangdong Polytechnic Normal University, Guangzhou Guangdong 510665, China)

**Abstract:** In order to improve I/O performance of parallel applications and parallel file systems, an automatic modeler was presented to model and predict for read request temporal and spatial series. It used autocorrelation function and Haar wavelet transform technology to automatically identify and build Autoregressive Integrated Moving Average (ARIMA) models of interarrival times. It used Markov modeler to model and forecast spatial series. Our prefetching method can combine ARIMA time series predictions and Markov model spatial predictions to adaptively determine when, what, and how many data blocks to be prefetched.

**Key words:** parallel file system; modeling of read request; predict; autoregressive integrated moving average model; Markov model

## 0 引言

很多缓存和预取系统通过在计算的同时进行磁盘访问来改进读写性能, 读预取和延迟写是两个标准技术。但读预取可能与应用程序的读请求不一致, 太早太多的预取可能淹没文件缓存, 将马上要使用的数据块挤出缓冲区。延迟写是缓存 I/O 活动处于高峰时的写请求到缓冲区并在应用程序计算时刷新到磁盘中。因为处理器负载的波动和操作系统队列延迟, 加上应用程序周期性地检查点和嵌套的循环结构, 使得 I/O 请求到达具有突发性。这种突发性使得系统缓冲区和网络过载, 导致 I/O 的时间较长。并行程序文件访问的时间与空间特性比通常的、串行的程序更复杂, 因为多级别的 I/O 库的原因, 不仅 I/O 模式具有突发性, 时间模型也不规则。为了有效地预取, 需要考虑这些变化的条件, 因为这些条件在程序执行过程中变化很大, 传统的离线建模预测不能自动适应不可再生的程序行为和执行环境的动态变化。

为了改善并行程序和并行文件系统的 I/O 访问性能, 我们对读请求的空间与时间特征进行建模、预测。

## 1 在线读请求的空间和时间建模

### 1.1 马尔可夫模型

马尔可夫模型通过状态模型来描述复杂的 I/O 行为, 该模型中“状态”代表固定大小的文件块, “边”的权值表示相关文件块被相继访问的概率。基于最近最多访问的块和模型转换概率, 人们可以预测将来的块访问。

文件系统和 I/O 库通过线索来感知 I/O 行为, 简单、顺序 I/O 的预取不适合并行程序。应用程序的 I/O 访问可能是数据依赖的, 或者因为用户的交互而改变; 进一步, 对复杂的、不规则的访问模式, 枚举所有的请求流需要多级别的指令来捕捉 I/O 模式, 从而指导将来的 I/O 访问。我们的方法不是准确地描述复杂的 I/O 模式, 而是依据相关数据块先后被访问的概率关系来潜在地捕获它们的空间访问特征。

与向量机上串行的 I/O 序列不同, 并行 I/O 通常是条带化分布在多个磁盘, 访问模式不规则并且访问大小差异较大。通过分析一个并行的、非结构化的网状代码程序 CONTINUUM<sup>[1]</sup>我们知道, 只有不到一半的 I/O 请求保持以前

收稿日期:2006-01-04 修订日期:2006-03-11 基金项目:广东省中职校长资源网项目(04003)

作者简介:魏文国(1968-),男,湖北公安人,副教授,博士,主要研究方向:集群、计算机网络、高性能计算; 罗俊(1959-),男,河南焦作人,高级工程师,硕士,主要研究方向:计算机网络; 向军(1970-),男(土家族),湖北恩施人,讲师,硕士,主要研究方向:计算机网络、高性能计算。

的顺序关系。这些复杂的访问模式不能用简单的规则(例如顺序关系或者条带)描述,并且对具有多级别的I/O库的应用程序来说很普遍。




图1 马尔可夫模型的文件块

为了捕捉非顺序的I/O模式,我们使用马尔可夫模型来描述应用程序的I/O访问的空间流,具有 $M$ 个状态的马尔可夫模型可用状态转换矩阵 $P = (p_{ij})_{M \times M}$ 表示,其中每个元素 $p_{ij}$ 表示从状态*i*转换到状态*j*的概率,并且转换的概率仅与当前的状态*i*有关。图1的状态转换矩阵为:

$$P = \begin{bmatrix} 0 & 0.6 & 0.4 & 0 & 0 \\ 0 & 0.4 & 0 & 0.6 & 0 \\ 0 & 0 & 0.1 & 0 & 0.9 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

上述矩阵的每个元素 $p_{ij}$ 对应图1从点*i*到点*j*的有向边的权值,并且矩阵的每一行之和为1。

对文件系统给定的数据块大小,为每个文件的每个数据块建立一个状态,因为应用程序的I/O请求是用字节偏移量而不是块偏移量表示,我们将每个I/O请求转换成数据块形式。除了最复杂、不规则的模式外,绝大部分I/O访问的马尔可夫模型的状态转换矩阵是稀疏矩阵。

读请求的马尔可夫空间模型预测主要包括:

**贪婪预测策略** 对每个当前状态,预测总是取最大可能的下一个状态,预测 $N$ 步就是重复 $N$ 次前面的步骤。

**路径预测策略** 对 $N$ 步预测,从当前状态开始取长度为 $N$ 的所有路径对应的状态转换概率之和,其中最大值对应的路径作为 $N$ 步预测的最有可能路径。该预测策略比贪婪预测更有“远见”,并且对 $N$ 步预测较准确,但是计算量比较大。

如图1所示,当系统访问标号为“0”的块之后,按照马尔可夫模型作2步预测,若采用贪婪预测算法,则预取的顺序为:{块“1”,块“3”};若采用路径预测算法,则预取的顺序为:{块“2”,块“4”}。

## 1.2 读请求的时间序列模型

时间序列预测模型使用统计方法分析按时间排序的观测值序列的依赖关系。基于“将来的I/O是过去的延伸”的假设,通过分析观测值序列内在的依赖关系来预测将来的I/O行为。通过观测值之间的相关度来识别I/O处理的结构。

自回归、集成的移动平均时间序列预测模型为I/O处理提供复杂的统计建模方法,包括平稳的、变化的和具有周期(季节)的三类时间序列。直观上说,平稳的时间序列是指其观测值的时间间隔序列围绕一个恒定的平均值变化;变化/非平稳的时间序列则不围绕平均值变化,而是呈现出增加或者减少的时间间隔趋势;若其观测值序列有规律地以特定的模式重复就称为周期/季节性时间序列。我们通过分析观测值的相关度来导出模型:模型假设、参数估计和诊断检测模型的不适应性。随后用合适的模型来预测将来的读请求到达时间。

### 1.2.1 平稳时间序列的自回归、集成的移动平均模型

为了刻画I/O请求的平稳时间序列 $\{f(t)\}_{t=1,2,\dots}$ ,我们使用自回归、集成的移动平均ARMA( $p, q$ )模型,即第*t*步读

操作发生的时刻 $f(t)$ 可以根据前*p*个观测值和过去的*q*个扰动值等的线性组合来预测:

$$f(t) = a_0 + a_1 f(t-1) + a_2 f(t-2) + \dots + a_p f(t-p) + e(t) + b_1 e(t-1) + b_2 e(t-2) + \dots + b_q e(t-q) \quad (1)$$

自回归部分(AR,即式(1)的第1行)是过去的*p*个观测值 $f(t-1), f(t-2), \dots, f(t-p)$ 的线性组合,权重为系数 $a_1, \dots, a_p$ (表示相应的观测值与预测值的相关度),加上常数项 $a_0$ 和当前的扰动 $e(t)$ 。

移动平均部分(MA,即等式(1)的第2行)是过去的*q*个扰动值 $e(t-1), \dots, e(t-q)$ 的线性组合,权重为系数 $b_1, \dots, b_q$ 。扰动项代表噪声和不确定因素,并假设服从高斯分布,这种正态性分布的假设是基于这样的理论:如果样本数足够多,则大致服从正态分布。

### 1.2.2 一般的自回归、集成的移动平均模型

对时间序列的相邻观测值依次相减形成的新序列称为差分间距为1的差分序列;间距>1的差分序列称为季节性/周期性差分。进一步,若一阶差分形成的序列还不能稳定(即相邻值之间差距普遍较大),则要进行多阶差分直到到达均衡状态为止。经过这种方式的变换之后,周期性和非平稳的时间序列都可归结到平稳的时间序列。

**非平稳序列的ARMA( $p, d, q$ )模型:**对时间序列经过*d*阶正常的差分之后,最后的时间序列有*p*项自回归部分和*q*项移动平均部分。

**季节性序列的ARMA( $p, d, q$ ) $\times$ ( $P, D, Q$ )<sub>s</sub>模型:**在ARMA( $p, d, q$ )模型的基础上添加了季节性部分( $P, D, Q$ )<sub>s</sub>,该部分经过*D*阶跨距为*S*的差分后,再经过*d*阶正常的差分,观测值的相关度结构是*p*项自回归部分和*q*项移动平均部分。ARMA( $p, d, q$ )描述一个特定的季节之内的非平稳部分( $p, d, q$ )的观测值的相关度;( $P, D, Q$ )<sub>s</sub>指定相邻的季节之间的观测值的相关度。

模型ARMA( $p, d, q$ ) $\times$ ( $P, D, Q$ )<sub>s</sub>称为一般的自回归、集成的移动平均模型,因为它包括所有的三类时间序列(平稳、非平稳和季节性)及其组合。这里假设*d*和*D*是整数,特别的,ARMA( $p, 0, q$ ) $\times$ ( $0, 0, 0$ )表示平稳的模型ARMA( $p, 0, q$ )。

自回归、集成的移动平均模型允许任意阶( $d \geq 1$ )正常差分和任意阶( $D \geq 1$ )季节性差分,原始的时间序列可通过*d*+*D*次差分变换得到平稳时间序列的模型ARMA( $p, q$ ),并通过反向逆序的集成算法恢复成原始的一般时间序列模型ARMA( $p, d, q$ ) $\times$ ( $P, D, Q$ )<sub>s</sub>。

## 2 自动模型识别

传统的方法使用离线的方式识别模型,对新的应用程序必须预先识别它的模型,然后才能预测它的I/O请求的时间序列。因为程序在执行过程中其行为动态改变,这类方法不是十分有效;并且科学程序的I/O行为表现为阶段性:初始化、读、计算和写,因此通过初始化阶段收集的I/O请求的时间序列来识别的模型很可能不适合后续阶段。比较常见的是用Box-Jenkins离线自相关度分析来识别模型<sup>[2]</sup>。我们的方法是自动的自相关度分析,使用一个基于Haar小波变换来自检测I/O行为的突然变化<sup>[3]</sup>。自回归、集成的移动平均模型使用自相关度函数(autocorrelation function, ACF)和部分自相关度函数(partial autocorrelation function, PACF)来识别模型,它们用协方差来表明观测值的时间序列彼此的差异性。因为度量单位改变协方差也会改变,因此协方差通常被方差

标准化来得到自相关度。

## 2.1 ACF 和 PACF 的概念

自相关度衡量第  $t$  步和第  $t+k$  步的观测值对  $(f(t), f(t+k))$  的线性依赖关系, 其中  $k$  是步长。对给定的步长  $k$ , 观测值对是随机变量  $F_t$  和  $F_{t+k}$  的实例, 步长  $k$  的自相关度定义  $r_k$  为变量与均值的偏差的期望值, 并由方差标准化。即:

$$r_k \triangleq \frac{\text{步长 } k \text{ 的协方差}}{\text{方差}} = \frac{E(F_t - \mu)(F_{t+k} - \mu)}{\sigma^2} \quad (2)$$

定义假设平稳序列的随机变量的均值为  $\mu$ 、方差是  $\sigma^2$ , 不同步长的自相关度不同。

步长为  $k$  的自相关度实际的计算取所有观测值对的平均差异。例如对样本均值  $\hat{\mu}$  和样本方差  $\hat{\sigma}^2$ , 给定  $N$  个样本数据,

$$\text{自相关度 } r_k = \frac{\frac{1}{N-6} \sum_{t=1}^{N-6} (f_t - \hat{\mu})(f_{t+6} - \hat{\mu})}{\hat{\sigma}^2}。其中: \hat{\mu} = \frac{1}{N} \sum_{t=1}^N f_t, \hat{\sigma}^2 = \frac{1}{N} \sum_{t=1}^N (f_t - \hat{\mu})^2。$$

部分自相关度考虑  $f(t)$  影响观测值  $f(t+1), \dots, f(t+k-1)$  的程度, 它是度量线性依赖关系的因素。

若  $f(t+k) = C_{k1}f(t+k-1) + C_{k2}f(t+k-2) + \dots + C_{kk-1}f(t+1) + C_{kk}f(t) + e(t)$ , 其中衰减系数  $C_{kk}$  代表  $f(t)$  对  $f(t+k)$  整体的贡献。通常的最小平方法估计这些系数是计算密集的。由 Durbin 开发的方法<sup>[3]</sup> 递归地近似计算自回归、集成的移动平均平稳序列的衰减系数。该方法举例如下:

第 1 轮衰减 (Lag 1) 开始时, 部分自相关度与自相关度相同, 因为它们之间没有其他中间值:  $C_{11} = r_1$ 。

第 2 轮衰减 (Lag 2) 系数  $C_{22}$  和  $C_{21}$  基于自相关度  $r_2, r_1$  和以前的部分自相关度  $C_{11}$  被计算:

$$C_{22} = \frac{r_2 - C_{11}r_1}{1 - C_{11}r_1}, C_{21} = C_{11} - C_{22}C_{11}$$

第 3 轮衰减 (Lag 3) 类似的有:

$$C_{33} = \frac{r_3 - C_{21}r_2 - C_{22}r_1}{1 - C_{22}r_2 - C_{21}r_1},$$

$$C_{32} = C_{21} - C_{33}C_{22}, C_{31} = C_{22} - C_{33}C_{21}$$

当衰减继续时, 系数也增加。幸运的是, Durbin 的方法允许递归地利用以前的结果计算。对样本数至少是 50 的时间序列, Box 和 Jenkins 建议使用  $N/4$  的步长计算自相关度和部分自相关度。

直观上说, 时间相近的观测值的依赖性比时间相距较远的观测值的依赖性更强。对平稳的时间序列的自相关度和部分自相关度当步长足够大时会减少到 0。Barlett<sup>[4]</sup> 用如下的等式近似描述样本数是  $N$  的平稳时间序列的自相关度和部分自相关度的标准方差。

$$\hat{\sigma}[r_k] = \sqrt{\frac{1}{N} \times \left(1 + 2 \times \sum_{j=1}^{k-1} r_j^2\right)},$$

$$\hat{\sigma}[C_{kk}] = \sqrt{\frac{1}{N}}$$

我们可以选择超出置信区间(例如两倍的最大标准方差的 95% 的置信度的置信区间)的显著相关的 ACF 和 PACF。

## 2.2 自动区分 ACF 和 PACF 的衰减类型

当衰减具有单调性时, 主要分为缓慢衰减、指数衰减和突然衰减三类。识别信号的衰减类型的算法主要有两种: 衰减计数测试法和平均变化率  $\Delta$  测试法。

其中衰减计数测试法的判断依据是: 差分 ACF 或者

PACF 序列并找到高频信号的位置, 若高频信号单调递减, 并且高频信号的次数小于等于 2 则为“突然衰减”; 否则若高频信号的次数大于等于 10 则为“缓慢衰减”或者“指数衰减”。因为最通常的模式为  $AR(1), AR(2), MA(1), MA(2)$  和  $ARMA(1, 1)$ , 但是当偶然出现非单调时则采用其他方法。

平均变化率  $\Delta$  测试法: 该方法在捕捉整体模式时更加灵活, 不受少数突变影响。计算  $\Delta = \frac{1}{M} \sum_{k=0}^M \frac{|r_k| - |r_{k+1}|}{|r_k|}$ , 其中

$M$  是显著相关的最新的衰减次数, 则判断的规则<sup>[5]</sup> 是:

```
if  $\Delta > 65\%$  then 突然衰减类型
else if  $\Delta < 10\%$  then 缓慢衰减类型
else 指数衰减类型
```

## 2.3 通过 ACF 和 PACF 来识别时间序列的模型结构

自回归、集成的移动平均方法利用自相关度和部分自相关度来识别时间序列的模型结构。经验表明大多数模式主要有两类行为: 呈指数函数衰减或者显著地突然下降。例如: 自回归  $AR(p)$  的自相关度呈指数函数衰减, 同时它的部分自相关度显著地突然下降, 长钉有  $p$  个; 移动平均模型  $MA(q)$  的特征刚好相反, 它的自相关度显著地突然下降, 有  $q$  个长钉, 部分自相关度以指数函数方式衰减到 0; 混合的  $ARIMA(p, q)$  的衰减特征是前两者的组合。

根据经验, Box 和 Jenkin 认为对大多数读请求到达的时间序列的  $p, q$  值仅限于 0, 1, 2。我们据此对 5 种最通常的模型:  $AR(1), AR(2), MA(1), MA(2)$  和  $ARMA(1, 1)$  的自相关度和部分自相关度进行评估。

模式识别过程包括 4 步:

1) 通过正常的差分来消除非平稳的部分。当时间序列的自相关度衰减很缓慢时, 则对它重复差分直到衰减不是很缓慢。通常的差分阶数  $d$  不超过 2<sup>[1]</sup>。

2) 通过季节性差分来消除季节性。使用上一步发现的季节的长度来差分  $D$  次(通常 1 次即可), 变换后的自相关度应该消除了明显的季节性。

3) 发现季节的模式。在最后的平稳序列中, 季节的边界的自相关度和部分自相关度应该具有  $AR(p), MA(q)$ , 或者  $ARIMA(p, q)$  之一的特征。

4) 发现非平稳部分的模式。在一个周期内应用前一步的方法找到非平稳部分的模式。

通过 ACF 自动检测季节性的具体方法是: 找出显著相关性(高频信号)的位置, 并从正常的差分序列中自动萃取它, 称为级别 1 (Level-1) 的距离测试方法。

当级别 1 的距离测试方法失效时, 我们使用级别 2 (Level-2) 的距离测试方法来检测增量的季节, 即对前面正常的差分再进行差分。

当级别 1、级别 2 的距离测试方法都失效时, 则认为该模型不具有季节性。

组合衰减计数和平均变化率测试法来识别 ACF 和 PACF 的衰减类型, 根据衰减类型决定模式的算法如下:

```
if (ACF 或者 PACF 中存在高频信号)
{
    if (ACF 中高频信号的衰减是突然衰减) then
        模式 = MA (q)
    else if (PACF 中高频信号的衰减是突然衰减) then
        模式 = AR (p)
    else if (ACF 和 PACF 中高频信号的衰减都是突然衰减) then
```

```

模式 = ARMA(1, 1)
end if
}
else
p = q = 0
end if

```

## 2.4 通过 Haar 小波变换自动检测突变

I/O 模式的突然改变是预测不准确的潜在原因,因此需要检测 I/O 行为的突变。虽然自相关度分析能很好地识别平稳序列、非平稳序列和周期性的访问模式,但是不能识别不规则的变化。因此我们使用 Haar 小波变换在 I/O 访问突变时有效地检测这种变化,Haar 小波变换的计算时间是线性的。

Haar 小波变换将时间序列分解成平均值序列(称为平均系数)和差分序列(称为详细系数),这种分解由对连续的观测值非重叠的计算得到。平均操作是低通滤波器,平均值代表信号的一般行为。相反的,差分操作揭示高频信号并消除平均值。递归地分解这些系数直到只有一个平均值为止,最后的 Haar 小波变换包含该平均值和所有的详细系数。

当时间序列的变化不大时,详细系数会比较小。可以使用详细系数来表示相邻数据的相关性:如果相关度高,则彼此相邻项的差别较小;反之,相邻值是弱相关的,则它们的差别较大。

### 2.4.1 折叠刀(Jackknife)方法的置信区间计算

为详细系数的均值构造一个置信区间比较困难。折叠刀方法是一种对任何给定的样本在不知道分布的情况下估计参数的置信区间的统计技术<sup>[6]</sup>。其基本原理是将样本分为随机的子样本(子样本从随机试验中得到并认为它们是独立的随机样本)。对多个子样本,其中每个子样本有大量的观测值,使得子样本足够分散来最小化统计的依赖性。可以通过计算所有样本的置信区间(例如 95% 的置信区间),并且统计推断如下:在置信区间之外的详细系数最有可能是一个 I/O

请求模式的变化/转换点(一般来说,还有可能是季节性的时间序列的边界,需要通过相应的变换例如级别 1 和级别 2 的测试等方法来验证)。

### 2.4.2 伪折叠刀方法

如果样本足够大,则折叠刀方法是计算密集的。一个不很成熟,但是计算量少的方法是将样本划分成子样本(即每个观测值只出现在一个子样本中),并不加调整地进行折叠刀方法<sup>[6]</sup>,称为伪折叠刀方法。

## 3 结语

为了改善并行应用程序和并行文件系统的 I/O 性能,我们对读请求的空间与时间特征进行建模;并可以将两者结合自适应地预测什么时间、取哪些数据块、取多少数据块。将来的工作包括:模型的参数被实时递归地估计,并根据应用程序本身和运行环境自适应改变;然后根据更新后的模型参数来在线预测随后的请求到达的时间。

### 参考文献:

- [1] BELADY LA. A Study of Replacement Algorithms for Virtual Storage Computers[J]. IBM Systems Journal, 1966, 5(2): 78 - 101.
- [2] BOX J. Methodology [EB / OL]. www. bath. ac. uk / ~ masar / math0118/forecasting/node14. html, 2005 - 06.
- [3] STRANG G, NGUYEN T. Wavelets and Filter Banks[M]. Wellesley-Cambridge Press, 2002.
- [4] LANNE M, SAIKKONEN P. Threshold Autoregression for Strongly Autocorrelated Time Series[Z]. Department of Economics, University of Helsinki, 2000.
- [5] TRAN N, REED DA. Automatic ARIMA Time Series Modeling for Adaptive I/O Prefetching[J]. IEEE Transactions on Parallel and Distributed Systems, 2004, 15(4): 362 - 377.
- [6] WONNACOTT RJ, WONNACOTT TH. Introductory Statistics[M]. John Wiley & Sons, 2001.

(上接第 1491 页)

## 3 PC 机驱动及应用程序

本系统驱动是用 Windows DDK 编写的,PC 机应用程序基于固件和驱动程序基础上编写,可以方便灵活地与硬件设备进行数据交换,并且以 VC++6.0 作为辅助开发环境,在原有生成的驱动向导框架中增加了标准设备请求和批量传输的接口控制代码。Windows 中应用程序实现与外部设备通信,首先利用一个中断请求来启动设备,检测到设备后开始初始化设备,中断响应准备数据传输时,需要考虑在发送方如何把一个或者几个文件的内容读出并组织成数据包,为了在接收方生成相应的文件,发送方还需要考虑待发送文件的类型、名称、大小等特征;在接收方,根据收到的文件的各个特征在指定路径生成相应的文件,判断文件是否传输完。中断响应请求后,在 PC 机中开辟一定大小的缓冲区,而驱动程序读缓冲区的速度需要和设备发送数据的速度相当,如果驱动程序读取数据较慢,则有可能造成 Windows 系统分配给设备的缓冲区被充满,而这时如果设备再向主机发送数据就会发生数据的丢失。设计通过改变系统分配的缓冲区大小来解决这一问题,经过反复的测试,缓冲区越大,传输速率越大,大于 10K 后变化不明显,因此本方案选择 10K 作为系统缓冲区大小。

## 4 结语

系统软件设计中,需注意 CY7C68013 与 IDT71V30 的时序匹配,程序的操作流程,以及中断的优先级的设定,以保证数据传输的正确性、可靠性。本设计将发送端 PC 主机和接收端 PC 主机读/写函数的数据缓冲区大小都设置为 10K,通过测试,实测最高速率可达到 3.5MB/s,实现了两台 PC 主机间单向、准快速、准确的数据传输,数据传输的不可逆性可满足在特定的场合,不同网络安全域之间网络数据通讯的单向性。

### 参考文献:

- [1] 许永和. USB 外围设备设计与应用[M]. 北京: 中国电力出版社, 2002.
- [2] 胡晓军, 张爱成. USB 接口开发技术[M]. 西安: 西安电子科技大学出版社, 2005. 121 - 152.
- [3] Integrated Device Technology Inc. Data Book[Z], 2001.
- [4] 徐爱钧. 单片机高级语言 C51 Windows 环境编程与应用[M]. 北京: 电子工业出版社, 2001.
- [5] 马忠梅, 马岩, 张凯, 等. 单片机的 C 语言应用程序设计[M]. 北京: 北京航空航天大学出版社, 1997.
- [6] EZ-USB FX2 Technical Reference Manual. v2. 1. Cypress Semiconductor[Z], 2001.