

# 基于测量的 QoS 参数估计及其应用\*

赵斌, 刘增基, 李晓蒙

(西安电子科技大学 综合业务网国家重点实验室,陕西 西安 710071)

E-mail: zbnew@263.net

http://www.xidian.edu.cn

**摘要:** 提出了一种基于测量的 QoS 参数估计方法,该方法使得用户无须事先为业务源建立相应的业务模型并向网络提交其业务模型参数,而是通过对业务流的统计特性进行实时测量来动态估计相应的 QoS 参数,从而克服了基于模型 QoS 参数估计方法所固有的缺陷,便于网络进行连接允许控制和带宽的动态分配.

**关键词:** QoS; 测量; 连接允许控制

中图法分类号: TP393 文献标识码: A

未来宽带网络的成功在很大程度上依赖于其对各种类型业务(如语音、视频和数据)的统计的复用性能.由于不同类型的业务具有不同的业务特性和服务质量(QoS)要求,这就要求网络能够提供相应的机制,以便在高效地提高资源利用率的同时确保不同类型业务的 QoS,而如何精确地估计 QoS 参数则是其中一个十分重要的问题.

在传统的 QoS 参数估计方法中,通常要求用户提供描述其业务模型(如 ON/OFF 模型、马尔可夫调制泊松过程和马尔可夫调制流体过程等)的参数,网络则根据相应链路上各业务流的模型参数以及链路容量和缓冲区大小来估计相关的 QoS 参数,这种方法通常被称为基于模型的 QoS 参数估计方法.然而,基于模型的 QoS 参数估计方法明显存在着以下一些缺陷:(1) 业务源实际的统计特性很难被一种业务模型精确地进行描述.(2) 受标准化的限制,用户所能提交的业务量描述符不足以用来对其业务模型进行描述.(3) 在网络内部,由于排队的影响,可能会使业务流的统计特性发生变化,从而不再与用户在连接建立阶段所提交的业务量描述符相一致.

本文利用大数量业务源复用渐进分析理论提出了一种基于测量的 QoS 参数估计方法,该方法无须用户事先为业务源建立相应的业务模型并向网络提交其业务模型参数,而是通过对业务流的统计特性进行实时测量来动态估计相应的 QoS 参数,从而克服了基于模型 QoS 参数估计方法所固有的缺陷.本文将针对 ATM 网络进行讨论,并分析如何将其应用于连接允许控制(connection admission control,简称 CAC)和带宽的动态分配.由于信元的最大排队时延通常可以由缓冲区的大小来限定,因此本文主要讨论的是对信元丢失率(cell loss ratio,简称 CLR)的估计.

## 1 大数量业务源复用渐进分析理论

在 ATM 网络中,除非一些非常简单的业务模型,利用传统的排队论进行排队性能分析通常是十分困难的,因此人们开始考虑采用渐进分析的方法,其中大数量业务源复用渐进分析理论则是近年来提出的一种十分有效的方法<sup>[1~3]</sup>.

考虑一个 ATM 复用器,其服务速率为  $C$ ,缓冲区容量为无限,被  $N$  个相互独立的业务源复用.这  $N$  个业务源

\* 收稿日期: 2000-10-16; 修改日期: 2001-03-26

基金项目: 国家 863 高科技发展计划资助项目(863-317-9601-01)

作者简介: 赵斌(1970 - ),男,陕西大荔人,博士生,主要研究领域为综合业务网,ATM 技术;刘增基(1937 - ),男,浙江丽水人,教授,博士生导师,主要研究领域为宽带通信网络技术;李晓蒙(1976 - ),女,浙江宁波人,主要研究领域为综合业务网,ATM 技术.

分成  $J$  类,同类业务源之间服从独立同分布原则,且每类业务源的个数为  $N_j=N^*r_j,j=1,2,\dots,J$ .

令  $X_j[0,t]$  为一个属于第  $j$  类的业务源在时间间隔  $[0,t]$  中所产生的信元数,则其 log 矩母函数为

$$j_j(\mathbf{q}) = \frac{1}{t} \log E[e^{qX_j[0,t]}]. \quad (1)$$

而各业务源相应的累积 log 矩母函数可以表示为

$$j(\mathbf{q}) = \sum_{j=1}^J r_j j_j(\mathbf{q}). \quad (2)$$

令  $L$  为系统稳态队长,且令  $Q[Nc,Nb,N]$  为系统的溢出概率,即

$$Q[Nc,Nb,N] = Pr[L > B], \text{ 其中, } Nc = C, Nb = B,$$

则利用大数量业务源复用渐进分析理论可得:

$$\lim_{N \rightarrow \infty} \frac{1}{N} \log Q(Nc, Nb, N) = -I(b). \quad (3)$$

因此当  $N$  较大时,我们可以得到

$$\log Q(Nc, Nb, N) \approx -NI(b), \quad (4)$$

其中

$$I(b) = \inf_t (tj)^*(b + ct). \quad (5)$$

上式中,  $f^*(x) = \sup_y [xy - f(y)]$ , 称为函数  $f(x)$  的 Legendre-Fenchel 变换.

式(3)成立的条件是,当  $N$  趋于无穷大时,式(2)对于任何  $t$  均存在.由于业务源一般都满足这一条件,因此大数量业务源复用渐进分析理论具有较强的适用性.

## 2 信元丢失率

由于在有限容量缓冲区系统中 CLR 的求解通常十分困难,因此许多文献在分析 ATM 网中的信元丢失率时,常常用无限容量缓冲区系统的队长尾部分布(即溢出概率)来近似有限容量缓冲区(容量为  $B$ )系统中的 CLR,本文中即 CLR  $Q[Nc,Nb,N]$ ,然而这种近似方法有时却会导致较大的误差.

这里我们采用了一种更精确的 CLR 估计方法.考虑一个具有有限容量缓冲区(容量为  $B$ )的排队系统  $S$  和一个具有无限容量缓冲区的排队系统  $S_\infty$ ,  $L$  和  $L_\infty$  分别为  $S$  和  $S_\infty$  的系统队长,则系统  $S_\infty$  的溢出概率为  $Pr(L_\infty > B)$ ,而系统  $S$  中的信元丢失率可以表示为

$$CLR = \frac{E\{[I(t) - C]^+ | L = B\} Pr(L = B)}{E[I(t)]},$$

其中  $(x)^+ = \max(x, 0)$ ,  $I(t)$  为各业务源累积的到达速率,  $C$  为服务速率.

图 1 比较了在同样的信元到达情况下,  $S$  和  $S_\infty$  缓冲区的占用过程.如图 1 所示,由于在有限容量缓冲区排队系统  $S$  中存在着当缓冲区满时便丢弃信元的现象,因此有

$$Pr(L=B) \leq Pr(L_\infty > B).$$

我们可以利用下式来对 CLR 进行估计,即

$$CLR \approx \frac{E\{[I(t) - C]^+ | L_\infty > B\}}{E[I(t)]} Pr(L_\infty > B). \quad (6)$$

由式(4)我们可以得到

$$Pr(L_\infty > B) = Q(Nc, Nb, N) \approx e^{-NI(b)}. \quad (7)$$

在文献[4]中,给出了  $\frac{E\{[I(t) - C]^+ | L_\infty > B\}}{E[I(t)]}$

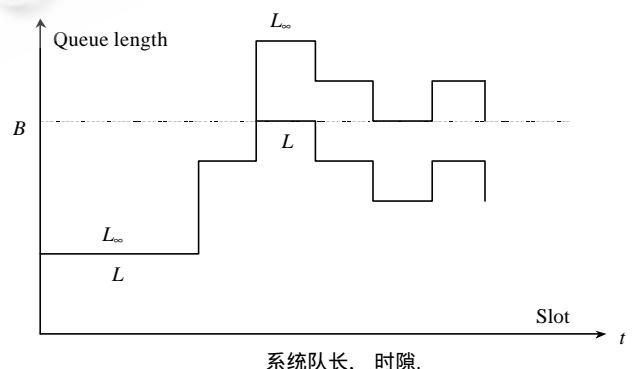


Fig.1 Buffer occupancy in  $S$  and  $S_\infty$

图 1  $S$  和  $S_\infty$  的缓冲区占用过程

的一种近似解,即

$$\frac{E\{\mathbf{I}(t)-C\}^+ | L_\infty > B\}}{E[\mathbf{I}(t)]} \approx \frac{\frac{\mathbf{s}}{\sqrt{2\delta}} e^{\frac{(C-\mathbf{m})^2}{2s^2}} + (\mathbf{m}-C)^+}{\mathbf{m}}, \quad (8)$$

其中  $\mathbf{m} = \sum_i \mathbf{m}_i$ ,  $s^2 = \sum_i s_i^2$ ,  $\mathbf{m}$  和  $s_i^2$  分别为第  $i$  个业务源的平均到达速率和速率方差.

考虑到在一个无限容量缓冲区的排队系统中,为了满足稳态条件,要求各业务源的累积平均到达速率应小于系统的服务速率,即  $\mathbf{m} < C$ ,此时,  $(\mathbf{m}-C)^+ = 0$ .因此,利用式(6)~式(8)可以得到

$$CLR \approx \frac{\mathbf{s}}{\sqrt{2\delta} \mathbf{m}} e^{\frac{(C-\mathbf{m})^2}{2s^2} - NI(b)}. \quad (9)$$

若令  $K = \frac{\mathbf{s}}{\sqrt{2\delta} \mathbf{m}} e^{\frac{(C-\mathbf{m})^2}{2s^2}}$ ,则 CLR 可以表示为

$$CLR \approx K e^{-NI(b)}. \quad (10)$$

对于 VBR(variable bit rate)业务源来说,通常情况下  $K$  的取值远小于 1,我们比较式(10)和式(7)可以发现,信元丢失率 CLR 通常小于溢出概率,因此当我们利用式(10)进行 CLR 估计,并将其应用到相应的流量控制(如连接允许控制 CAC)和带宽分配时,往往能够获得更好的统计复用增益.

### 3 基于测量的 QoS 参数估计

本文通过对业务流的统计特性进行测量,并将测得的统计值代入式(9)来估计相应的 QoS 参数.根据式(9),为了得到相应的 CLR,需要通过测量确定以下一些统计值,即各业务源累积的平均到达速率  $\mathbf{m}$  和速率方差  $s^2$ ,以及各自的 log 矩母函数  $j_j(\mathbf{q})$ ,  $j=1,2,\dots,J$ .

我们把时间轴用固定的时间间隔  $t$ (几十微妙到几百毫秒)等分为连续的时间段,每个时间段为一个测量周期,我们在每个测量周期内测量各业务源到达的信元个数,若测量时间为  $T$ (通常由几百个测量周期组成),则一个第  $j$  类业务源在第  $i$  个时间段内被测量到的信元到达个数可记为  $X_j[(i-1)t, it]$ ,  $i=1, 2, \dots, T/t$ .利用这些测量值,我们可以分别求出相应的  $\mathbf{m}_j$  及  $s_j^2$ ,并最终求得该测量时间内的 CLR.

(1)  $\mathbf{m}_j$  和  $s_j^2$ :令  $\mu_j$  和  $s_j^2$  分别为第  $j$  类业务源的平均到达速率和速率方差,则它们可以利用下式来进行估计,

$$\mathbf{m}_j = \frac{1}{T/t} \sum_{i=1}^{T/t} X_j[(i-1)t, it]. \quad (11)$$

$$s_j^2 = \frac{1}{(T/t)-1} \sum_{i=1}^{T/t} [X_j[(i-1)t, it] - \mathbf{m}_j]^2. \quad (12)$$

由于各业务源是相互独立的,且同类业务源之间服从独立同分布原则,因此可得

$$\mathbf{m} = \sum_{j=1}^J N_j \mathbf{m}_j, \quad s^2 = \sum_{j=1}^J N_j s_j^2. \quad (13)$$

(2)  $j_j(\mathbf{q})$ :由于  $j_j(\mathbf{q}) = \frac{1}{t} \log E[e^{q X_j[(0,t)}]$ ,为了计算  $j_j(\mathbf{q})$ ,我们采用时间平均来替代该式中的统计平均(数学期望),即

$$j_j(\mathbf{q}) = \frac{1}{t} \log \left[ \frac{1}{T/t} \sum_{i=1}^{T/t} e^{q X_j[(i-1)t, it]} \right], \quad j=1, 2, \dots, J. \quad (14)$$

(3) CLR:根据式(9),为了得到 CLR,还需要求解  $I(b)$ .而由式(5)可知,  $I(b)$  是一个求解极小值和极大值的表达式,即

$$I(b) = \inf_t (t \mathbf{j})^*(b + ct) = \inf_t \sup_{\mathbf{q}} [\mathbf{q}(b + ct) - t \sum_{j=1}^J \mathbf{r}_j j_j(\mathbf{q})]. \quad (15)$$

上式的求解包含了两个优化计算的过程,一个是对于固定的  $t$  改变  $\mathbf{q}$ ,求  $\mathbf{q}(b + ct) - t \sum_{j=1}^J \mathbf{r}_j j_j(\mathbf{q})$  的极大值,将其记为

$f^*(t)$ ;另一个是改变  $t$ ,求  $f^*(t)$  的极小值.

#### 4 基于测量的 QoS 参数估计在连接允许控制中的应用

利用上述基于测量的 QoS 参数估计方法,我们可以得到一种基于测量的 CAC 算法.类似地,我们把时间轴用固定的时间间隔  $T$  等分为连续的时间段,每个时间段为一个更新周期.同时,在每个更新周期中又用更小的时间间隔  $t$ (几十微妙到几百毫秒)进行等分,每个时间段即为一个测量周期,一个更新周期通常由几百个测量周期组成.在一个更新周期中,我们测量每个测量周期内各业务源到达的信元个数,如一个第  $j$  类业务源在第  $i$  个测量周期内被测量到的信元到达个数可记为  $X_j((i-1)t, it], i=1, 2, \dots, T/t$ .

假设用户所要求的 QoS 为 CLR< $\epsilon$ ,根据式(9),我们可以估计在任一给定的服务速率  $C$  下的信元丢失率,因此在给定的信元丢失率要求下,为了确保 QoS 所应分配的最小带宽,可定义为

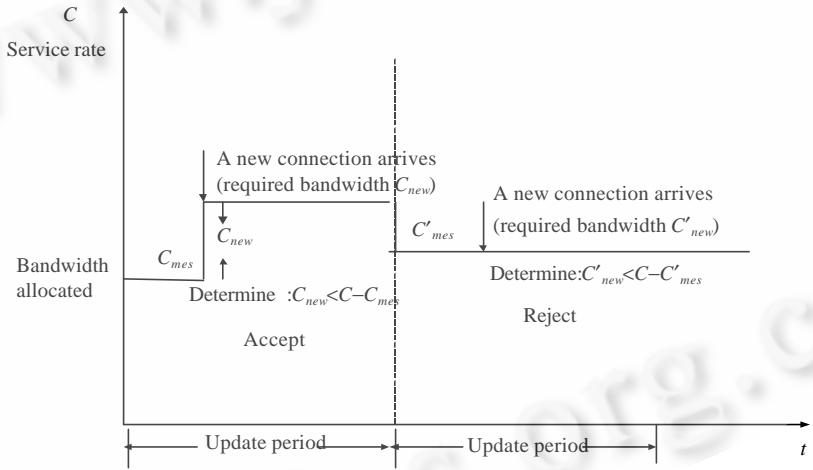
$$C_{mes} = \min\{C : \text{CLR} < \epsilon\}, \quad (16)$$

即

$$C_{mes} = \min\{C : \frac{s}{\sqrt{2\delta m}} e^{\frac{(C-m)^2}{2s^2} - NI(b)} < \epsilon\}.$$

由于该式将利用上述的测量值来进行求解,因此我们称其为测量带宽.

结合以上分析,我们得到如下一种基于测量的 CAC 算法,如图 2 所示.



服务速率, 分配带宽, 到达一个新连接(所需带宽  $C_{new}$ ), 判断, 接纳, 拒绝, 更新周期.

Fig.2 CAC algorithm based on measurement

图 2 基于测量的 CAC 算法

(1) 在每一个更新周期的测量周期内测量各业务源到达的信元个数,并在每一个更新周期的结束时刻利用所测量的结果计算该更新周期的测量带宽.

(2) 在一个更新周期中,当第 1 个新的连接建立请求到达时,利用其业务量描述符计算该连接所需带宽,记为  $C_{new}$ (例如可以使  $C_{new}$  为该新连接的峰值速率).假设系统的服务速率为  $C$ ,上一更新周期的测量带宽为  $C_{mes}$ ,则系统当前剩余带宽  $C_{剩余}=C-C_{mes}$ .此时判断,若  $C_{new} < C_{剩余}$ ,则接纳该连接请求,并更新  $C_{剩余}=C_{剩余}-C_{new}$ ;否则,则拒绝该连接请求.

(3) 在该更新周期中,当又有新的连接建立请求到达时(其所需带宽为  $C'_{new}$ ),判断若  $C'_{new} < C_{剩余}$ ,则接纳该连接请求,并更新  $C_{剩余}=C_{剩余}-C'_{new}$ ;否则,拒绝该连接请求.

(4) 在该更新周期的结束时刻,利用该更新周期的相应测量值计算其测量带宽  $C'_{mes}$ ,在下一个更新周期中,令系统剩余带宽  $C_{剩余}=C-C'_{mes}$ .

如图 2 所示,在上述基于测量的 CAC 算法中,带宽的分配是一种动态的过程,这种动态过程表现为在每一个更新周期的结束时刻,测量带宽被重新计算并用于下一个更新周期的接纳控制,以便获得更好的统计复用增益,提高网络资源利用率。

在上述基于测量的 CAC 算法中,一个关键的问题在于如何利用测量值来计算更新周期的测量带宽,利用第 4 节的方法,我们可以估计在任一给定  $C$  下的信元丢失率,因此根据式(16),我们可以调节式中的  $C$ ,直到恰好满足  $CLR < \epsilon$ ,则此时的  $C$  即为  $C_{mes}$ 。

## 5 数值结果

图 3 给出了在复用多个 VBR 业务源时,利用我们的方法(式(9))得到的缓冲区容量与信元丢失率 CLR 之间的对应关系,并将其与溢出概率(式(7))及 CLR 仿真结果进行了比较,对式(9)中 CLR 和式(7)中溢出概率的求解均采用了我们上面所描述的测量方法来进行,两者的区别是相差了一个系数  $K$ 。我们采用的业务源是一种在 ATM 网络性能分析中被广泛采用的真实的业务源,即星球大战 MPEG-1 视频压缩流序列<sup>[5]</sup>。在图 3(a)中,链路容量  $C=34Mbps$ ,业务强度  $r=0.85$ ;图 3(b)中,链路容量  $C=155Mbps$ ,业务强度  $r=0.95$ 。

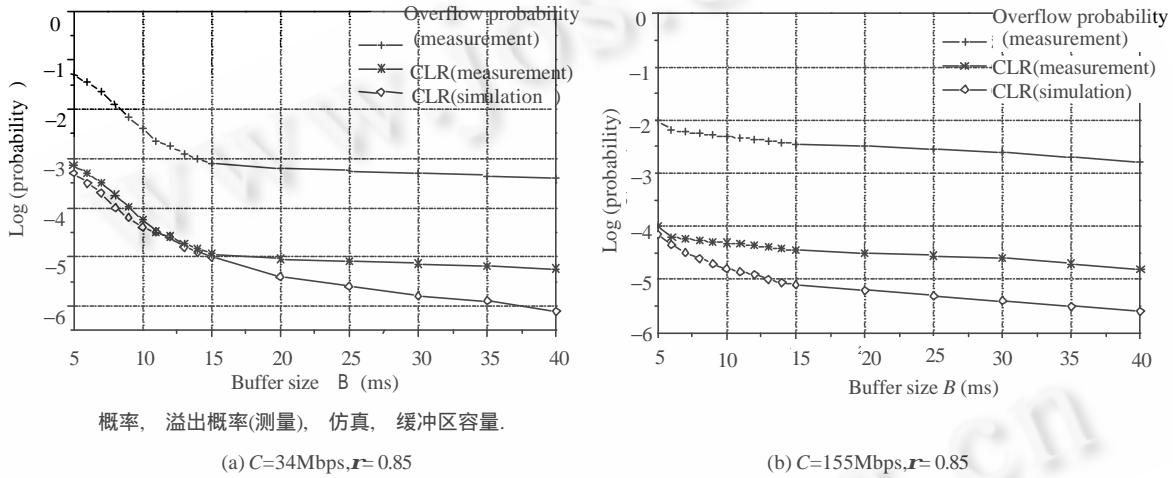


Fig.3

图 3

从图 3 可以看出,测量的溢出概率与实际的 CLR 相比高出了 2~3 个数量级,而测量的 CLR 则与实际的 CLR 十分接近,两者相差不超过一个数量级,因此与溢出概率相比,采用式(9)进行 CLR 估计可以得到更为精确的结果。此外,从图中还可以看出,当缓冲区容量较小时,测量的 CLR 值随着缓冲区的增加而快速下降,但当缓冲区容量增加到一定量之后,进一步增加缓冲区容量只对 CLR 的改善产生较小的影响,这一现象表明,本文的方法能够用来描述信元级和突发级两级的排队行为,便于网络进行相应的流量控制。

我们针对链路利用率比较了两种基于测量的 CAC 算法的性能,一种是本文的 CAC 算法;另一种是利用溢出概率(式(7))来近似 CLR 的 CAC 算法,我们称其为溢出概率近似法。该算法与本文 CAC 算法的不同之处在于,将式(16)中的 CLR 替换为溢出概率,其余不变。在这里,我们使用的 VBR 业务源仍是星球大战 MPEG-1 视频压缩流序列。我们定义链路利用率  $r = \frac{Nm}{C}$ ,其中  $C$  为服务速率,  $m$  为业务源平均速率,  $N$  为 CAC 所允许的最大连接数。假设所要求的 QoS 为  $CLR < 10^{-6}$ ,服务速率  $C$  分别为 34Mbps(见表 1)和 155Mbps(见表 2)。

表 1 和表 2 给出了在不同的缓冲区容量下,各 CAC 算法的链路利用率。本文的 CAC 算法的性能与仿真结果十分接近,它明显优于溢出概率近似法,这是因为本文的 CAC 算法采用了更为精确的信元丢失率的估计方法(式(9)),从而能够获得更好的统计复用增益,提高网络资源的利用率。

**Table 1** Link utilization ( $CLR < 10^{-6}$ ,  $C = 34M$ )**表 1** 链路利用率( $CLR < 10^{-6}$ ,  $C = 34M$ )

		Buffer size $B(\text{ms})$			
	4	8	10	15	20
Overflow probability approximation	0.517	0.588	0.625	0.708	0.760
CAS in this paper	0.616	0.689	0.755	0.805	0.808
Simulation	0.635	0.704	0.763	0.810	0.813

缓冲区容量, 溢出概率近似法, 本文 CAC, 仿真.

**Table 2** Link Utilization ( $CLR < 10^{-6}$ ,  $C = 155M$ )**表 2** 链路利用率( $CLR < 10^{-6}$ ,  $C = 155M$ )

		Buffer size $B(\text{ms})$			
	4	8	10	15	20
Overflow probability approximation	0.800	0.880	0.884	0.889	0.892
CAS in this paper	0.862	0.901	0.908	0.914	0.914
Simulation	0.883	0.919	0.920	0.921	0.921

## References:

- [1] Botvich, D.D., Duffield, N.G. Large deviations, economies of scale, and the shape of the loss curve in large multiple xers. *Queueing Systems*, 1995,20(3):293~320.
- [2] Duffield, N.G. Economies of scale in queues with sources having power-law large deviation scalings. *Journal of Applied Probability*, 1996,33(3):840~857.
- [3] Courcoubetis, C., Weber, R. Buffer overflow asymptotics for a switch handling many traffic sources. *Journal of Applied Probability*, 1996,33(3):886~903.
- [4] Song, J., Boorstin, R. Efficient loss estimation in high speed networks. In: Proceedings of the IEEE ATM Workshop' 98. 1998. 360~367.
- [5] Rose, O. Traffic modeling of variable bit rate MPEG video and its impacts on ATM networks [Ph.D. Thesis]. Institute of Computer Science, Wuerzburg University, 1997.

## Estimation of QoS Parameters Based on Measurement and Its Application\*

ZHAO Bin, LIU Zeng-ji, LI Xiao-meng

(National Key Laboratory of Integrated Service Network, Xidian University, Xi'an 710071, China)

E-mail: zbnnew@263.net

<http://www.xidian.edu.cn>

**Abstract:** A method for estimating QoS parameters based on measurement is presented in this paper. This method does not require the users to establish any models describing the statistics of the traffic and provide model parameters to the network in advance. Instead, network monitors and measures the incoming traffic statistics, and estimates QoS parameters based on the measured statistics, which enable it to overcome the drawbacks of model-based QoS parameters estimation and be convenient for connection admission control and dynamic bandwidth allocation in networks.

**Key words:** QoS; measurement; connection admission control

\* Received October 16, 2000; accepted March 26, 2001

Supported by the National High Technology Development 863 Program of China under Grant No.863-317-9601-01