

一种基于 FNN 的高速网络拥塞控制策略*

何小燕, 吴介一, 顾冠群

(教育部计算机网络和信息集成重点实验室, 江苏南京 210096);

(东南大学计算机科学与工程系, 江苏南京 210096)

E-mail: xyhe@seu.edu.cn

http://www.seu.edu.cn

摘要: 以 ATM(asynchronous transfer mode)为研究对象, 提出一种基于模糊神经网络(fuzzy neural network, 简称 FNN)的流量预测和拥塞控制策略。拥塞控制是高速网络(如 ATM)研究中的关键问题之一。传统的基于 BP 神经网络的流量预测方法因其收敛速度较慢且具有较大的误差, 影响了拥塞控制效果, 而模糊神经网络由于具有处理不确定性问题和很强的学习能力, 能很好地解决这一问题。最后通过仿真, 比较和分析了基于 BP 神经网络和基于 FNN 方法的性能, 证明此方法是有效的。

关键词: 拥塞控制; 流量预测; 模糊神经网络; 高速网络; ATM(asynchronous transfer mode)

中图法分类号: TP393

文献标识码: A

高速网络技术的发展使得许多新的网络应用成为可能, 如视频会议、视频点播、多媒体通信、分布式多媒体等。ATM(asynchronous transfer mode)是一种典型的高速网络技术, 已被 ITU-T 推荐为 B-ISDN 的复用和交换方式^[1], 通过统计复用, ATM 能够提供各类具有不同 QoS(quality of service)需求的信息业务(包括数据、声音、视频、图形和图像等)的综合传输, 具有很高的灵活性, 并能动态地分配信道带宽, 从而有效地利用了网络资源^[2]。但是, ATM 在具有这些灵活性的同时, 也存在着拥塞问题。拥塞导致缓冲区溢出、信元丢失和 QoS 下降, 所以必须提出更为有效的流量管理和拥塞控制策略, 以避免拥塞。

接纳控制作为流量控制机制之一, 在建立连接时将资源分配到连接点, 以达到避免拥塞的目的^[3,4], 但由于流量随机波动, 在实际传输过程中仍可能导致缓冲区溢出和信元丢失, 从而不能保证每一连接的 QoS。拥塞控制机制试图将拥塞时间段降低到最小或避免其发生, 而拥塞控制难以在高速网络(如 ATM)中有效实施, 其主要原因是多媒体流的不确定性和时变性, 导致了流量的不可预测, 难以表征和控制; ATM 信元传输时间短、缓冲区小, 这些特性均要求拥塞控制算法必须具有简单性、适应性和鲁棒性的特点。

常规的拥塞控制方法需要建立数学模型, 而数学模型的复杂性和精确性难以满足高速网络的实时需求; 简化的数学模型又导致实际控制效果不能令人满意。另外, 常规方法需要首先了解流量的一组表征(如峰值比特率、平均比特率、突发长度等), 然而这些表征不能完全描述流的相关性和突发性, 从而难以实施有效的控制, 导致网络性能的严重下降。利用神经网络进行流量预测和拥塞控制具有以下几个特点:(1) 神经网络不需要建立精确的数学模型, 利用其强大的自学习功能, 通

* 收稿日期: 1999-11-15; 修改日期: 2000-01-25

基金项目: 国家重点基础研究发展规划资助项目(G1998030405)

作者简介: 何小燕(1970—), 女, 甘肃兰州人, 博士生, 主要研究领域为计算机网络资源管理; 吴介一(1941—), 男, 江苏无锡人, 教授, 博士生导师, 主要研究领域为计算机网络、集成支撑技术; 顾冠群(1940—), 男, 江苏常州人, 教授, 博士生导师, 中国工程院院士, 主要研究领域为计算机网络、CIMS 技术。

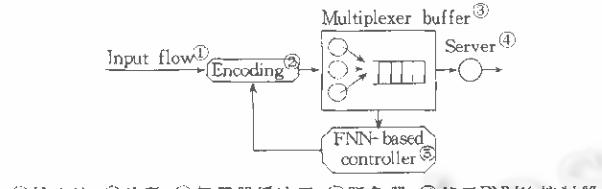
过适当的训练就能准确地获得流量的特征,进行正确的预测;(2) 神经网络所具有的本质上的并行分布式处理结构,适用于多信息融合和多媒体技术,可同时综合定量和定性信息,并且具有鲁棒性;(3) 神经网络可通过 VLSI 硬件实现或用计算机技术模拟实现,一旦网络训练成功,就可达到非常快的响应速度,从而满足高速网络的实时需求.

1 拥塞控制模型和策略

神经网络在高速网络中的应用从许多文献^[2,3,5~8]中都可看到,其中有许多基于神经网络的流量预测模型,它们大多采用 3 层 BP 神经网络(back propagation neural network,简称 BPN). 试验证明,复杂的网络模型并不能明显提高性能,事实上,网络模型越复杂,其泛化能力越弱,同时其实时处理能力也将下降. 但 BPN 有很大的局限性,主要表现在:现有的学习算法收敛速度太慢,不适合在线预测;在多数情况下存在局部优化问题;网络结构不确定,收敛速度慢难以满足实时要求,网络结构的不确定性使得人们很难得到理想的网络模型.

模糊逻辑有很好的处理不确定性信息的能力,易于被人理解. 将模糊逻辑与神经网络相结合,使模型具有处理不确定性问题的能力,同时又具有很强的学习能力. 本文以 ATM 网络传输系统为例,提出了基于模糊神经网络(fuzzy neural network,简称 FNN)进行流量预测的拥塞控制策略.

由于 ATM 网络的高速传输特性以及流量的突发性和相关性,因此必须选择正确的拥塞控制点以获得理想的控制效果. 在网络的交换结点,由于其高速转发的要求,使得协议必须透明、轻型,因而难以施加过多的控制;如果在网络的目的结点施加拥塞控制,由于控制信息反馈至源结点需要较长的传输时间,影响实际的控制效果;而在源端实施拥塞控制,可以避免过长的控制信息传输时间,从而达到实时控制的目的. 因此,本文选择在源结点的 UNI(user network interface: 用户网络接口)实施拥塞控制. 在拥塞控制过程中,我们利用模糊神经网络控制器预测下一个将要到达流的



①输入流, ②编码, ③复用器缓冲区, ④服务器, ⑤基于FNN的控制器.

Fig. 1 The ATM multiplexer with FNN controller
图1 具有FNN控制器的ATM复用器

特征,结合当前缓冲区中的队列信息,预测网络是否会发生拥塞. 一旦预测出拥塞将要发生,控制器就会向源端反馈拥塞信息,编码器根据拥塞信息适当降低编码率,虽然声音、视频质量略为下降,但避免了拥塞的发生,保证了服务质量. 基于 FNN 的拥塞控制模型如图 1 所示.

假定 ATM 复用器的缓冲区大小为 Q , 时间间隔为 T , λ_i 为 T_{i-1} 时刻到 T_i 时刻之间到达的信元(cell)数,其中 $T_i - T_{i-1} = T$ ($i = 1, \dots, n; n \in N$), 队列的恒定服务速率为 $C(\text{cells}/T)$, q_i 为 T_i 时刻的队列长度, q_{i+1} 为 T_{i+1} 时刻的队列长度,则有如下的方程^[2]:

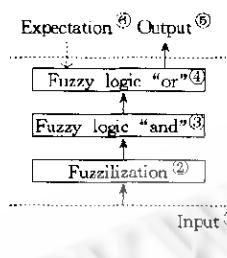
$$q_{i+1} = \min(\max(q_i + \lambda_{i+1} - C, 0), Q). \quad (1)$$

根据此方程,当 $\max(q_i + \lambda_{i+1} - C, 0) > Q$ 时,缓冲区溢出,发生信元丢失. 在式(1)中, λ_{i+1} 可由 FNN 预测得到, q_i 可以通过网络管理信息实际获得,因此由式(1)可以得到预测的 q_{i+1} , 将 q_{i+1} 作为拥塞控制测量,判断是否发生拥塞. 综上所述,预测 λ_{i+1} 是本拥塞控制中最关键的问题.

2 用于流量预测的模糊神经网络

2.1 模糊神经网络及其结构

模糊系统与神经网络相结合进行系统建模的研究,近年来已经获得了很好的应用^[9],本文以FNN作为对声音和视频流进行学习训练和模糊识别的工具。根据“连接主义”结构,图2是我们采用的FNN模型,图3是与图2相对应的两个输入、一个输出情况下FNN的结构。



①输入,②模糊“化”,③模糊逻辑“与”,
④模糊逻辑“或”,⑤输出,⑥期望。

Fig. 2 The model of FNN
图2 模糊神经网络FNN模型

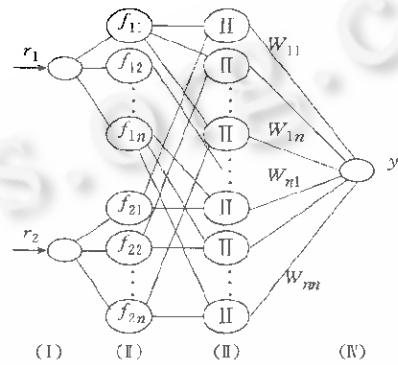


Fig. 3 The FNN structure of two-input-one-output
图3 两个输入、一个输出的FNN结构

在图3中, r_1, r_2 为模糊神经网络的两个输入, y 为网络输出,“ \prod ”表示乘积, $f_{ij}(t=1, 2; j=1, \dots, n; n \in N)$ 为节点的作用函数,具体的表达式见下面的 $f(x)$ 。各层的运算如下所示:

- (I) $I_t^{(1)} = r_t$; $O_t^{(1)} = I_t^{(1)}$;
- (II) $I_n^{(2)} = O_t^{(1)}$; $O_n^{(2)} = f(I_n^{(2)})$; $f(x) = \exp(-(x - a_k)^2)/b_k^2$;
- (III) $O_{ij}^{(3)} = O_n^{(2)} O_{ij}^{(2)}$;
- (IV) $y = \sum_{i=1}^n \sum_{j=1}^n O_{ij}^{(3)} W_{ij} / \sum_{i=1}^n \sum_{j=1}^n O_{ij}^{(3)}$,

其中 t, j, n 含义同前, $i=1, \dots, n, n$ 根据模糊子集确定; k 为迭代次数; $I_t^{(1)}, O_t^{(1)}$ 分别表示对应于 r_1, r_2 两个网络输入情况下第(I)层节点的输入和输出; $I_n^{(2)}, O_n^{(2)}$ 分别表示对应于 r_1, r_2 情况下第(II)层各节点的输入和输出; $f(x)$ 为节点的作用函数, x 为节点输入; $O_{ij}^{(3)}$ 表示第(III)层节点的输出; y 表示第(IV)层即网络的输出; W_{ij} 为需要调整的权值; a_k 表示隶属度函数的中心, b_k 表示隶属度函数的幅度,这二者在网络训练时会发生变化,我们将在第2.2节中加以讨论。

设输出误差为 $E = \frac{1}{2} \sum (y(k) - y'(k))^2$,其中 $y(k)$ 为网络实际输出, $y'(k)$ 为理想输出。由最速下降法知道权值 W_{ij} 的迭代方程为

$$W_{ij}(k+1) = W_{ij}(k) - \alpha \frac{\partial E}{\partial W_{ij}} + \beta \Delta W_{ij}(k),$$

其中 k 的含义同上, α 为加权因子, β 为学习步长。

在图3中,第(I)层为输入层,第(II)层实现输入量的模糊化,第(III)层实现模糊集运算功能,输出每条规则的适用度,第(IV)层用“重心法”实现逆模糊操作。上述模糊神经网络的节点和权值可用隶属度函数和模糊规则来解释,模糊规则的抽取和隶属度函数的改进实质上就是寻找合适的权值。在确定初始隶属度函数之后,用合适的神经网络学习算法,当网络误差小于给定值时,用训练过的网络就可以进行预测。

2.2 基于模糊神经网络的流量预测

在用 FNN 进行单步预测时, 我们选用一个输入变量一个输出变量的结构, 即将图 3 的 FNN 的结构简化为图 4 的情形, 其中 λ_i 为 T_{i-1} 时刻到 T_i 时刻到达的信元数, λ_{i+1} 为预测的 T_i 时刻到 T_{i+1} 时刻到达的信元数。要用神经网络实现模糊控制功能, 首先必须建立一个好的初始模糊模型, 即决定输入和输出变量所对应的模糊集及其隶属度; 然后决定模糊规则, 根据给定输入样本的定义域, 对其进行平均分割。我们将输入变量划分为 7 个模糊子集: {负大, 负中, 负小, 零, 正小, 正中, 正大}, 隶属度函数选为钟形, 初始划分如图 5 所示(图中的 λ 值经过了归一化)。

图 4 中的运算为

$$f(x) = \exp(-(x-a_i)^2/b_i^2); y^{(k)} = \sum_{i=1}^7 W_i O_i / \sum_{i=1}^7 O_i.$$

设输出误差为 $E = \frac{1}{2} \sum (y(k) - y'(k))^2$, 其中 $y(k)$ 为网络实际输出, $y'(k)$ 为理想输出, 则权值 W_i 的迭代方程为

$$\begin{aligned} W_i(k+1) &= W_i(k) - \alpha \frac{\partial E}{\partial W_i} + \beta \Delta W_i(k) = W_i(k) - \alpha(y(k) - y'(k)) \frac{O_i(k)}{\sum O_i(k)} + \beta \Delta W_i(k); \\ a_i(k+1) &= a_i(k) - \alpha \frac{\partial E}{\partial a_i} a_i(k) + \beta \Delta a_i(k) \\ &= a_i(k) - \alpha(y(k) - y'(k))(W_i(k) - y(k)) \frac{O_i(k)}{\sum O_i(k)} + \beta \Delta a_i(k); \\ b_i(k+1) &= b_i(k) - \alpha \frac{\partial E}{\partial b_i} + \beta \Delta b_i(k) \\ &= b_i(k) - \alpha(y(k) - y'(k))(W_i(k) - y(k)) \frac{O_i(k)}{\sum O_i(k)} \cdot \frac{(x(k) - a_i(k))^2}{b_i(k)^3} + \beta \Delta b_i(k). \end{aligned}$$

其中 O_i 为第 2 层各节点的输出 ($i=1, \dots, 7$); k 为迭代次数; a_i 表示隶属度函数中心, b_i 表示隶属度函数的幅度; $y^{(k)}$ 为第 k 次迭代的网络输出, W_i 为权值; 其余各式的含义及符号的含义与第 2.1 节中相关符号的含义相同。

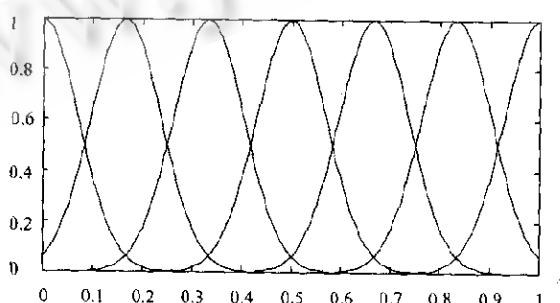


Fig. 5 The subjection function curve before training
图 5 训练前的隶属度函数曲线

3 仿真及分析

3.1 训练和预测

ATM的主要应用之一是提供实时、低丢失率的VBR(variable bit rate)服务,VBR流具有短时间内的高波动性,使得流量具有很高的突发性、不稳定性和相关性。由Gabarit逼近^[10]和文献[2]可知,VBR视频流可用连续状态离散时间自回归马尔可夫(AR Markov)模型来表征,用 $\lambda(n)$ 表示第n帧的信元比特率,则一阶AR Markov方程可用递归关系表示如下:

$$\lambda(n+1)=l \cdot \lambda(n)+m \cdot \omega(n). \quad (2)$$

其中l和m为影响因子,由经验值,可取l=0.8781,m=0.1108;ω(n)是独立高斯白噪声序列,均值为0.572,方差为1^[5],假设帧的产生速率为25帧/s,λ(n)的单位取7.5Mb/s。

在实际应用中,流通常是异构的,即是声音流和视频流等的叠加。我们选用2000个仿真声音和视频流的数据,前1600个数据用于训练,后400个数据用于测试。根据文献[2,3],对于一个声音流,可用两个状态的马尔可夫过程来描述,即活动状态(ON)和静止状态(OFF)。在ON状态下,有声音信元产生,其产生过程服从泊松过程,产生速率为λ;在OFF状态下,无声音信元产生。这两种状态的转移概率服从指数分布。设从ON状态转到OFF状态和从OFF状态转到ON状态的速率分别为β和α。为了确定这个模型,我们假设λ为32Kbps,1/β为352ms,1/α为650ms,取样周期为40ms,根据这些假设和参数,对由一个声音流和一个视频流组成的异构流进行预测,结果见图6。图7为训练后的隶属度函数曲线,与训练前的隶属度函数曲线相比较,可以看出中心和幅度都发生了变化。

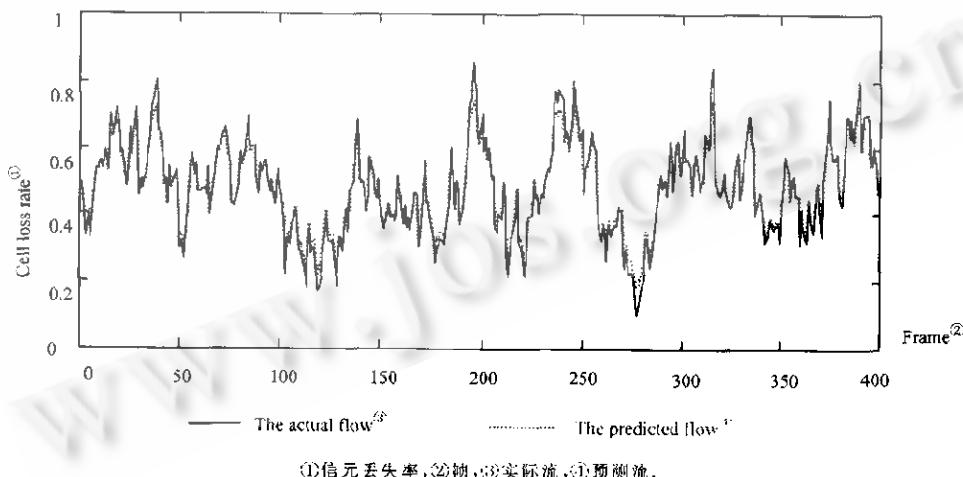


Fig. 6 The results predicted by FNN for the flow composed by one audio and one video

图6 用FNN预测由一个声音流和一个视频流叠加的流的结果

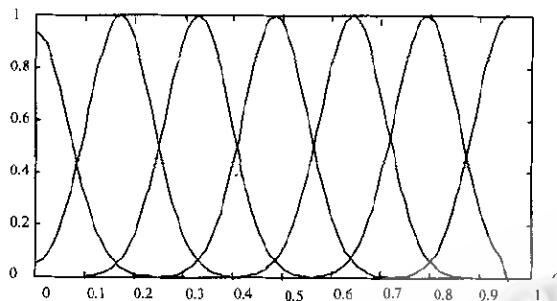


Fig. 7 The subjection function curve after training

图 7 训练后的隶属度函数曲线

表 1 是 BPN 和 FNN 预测结果的比较, 表中第 1 列表示 TSE (total squared error: 误差平方和), 第 2 列和第 3 列分别表示 BPN 和 FNN 达到相应 TSE 时的迭代次数, 由 TSE 可得 MSE (mean squared error: 平均误差平方和, $MSE = TSE/400$). BPN 采用 1-5-1 结构, 如图 8 所示, 节点的作用函数为 Sigmoid 函数 (x_i 为节点输入): $f(x_i) = 1/(1 + e^{-x_i})$. 我们在第 1 节中已经讨论过, 复杂的网络模型并不能明显地提高性能, 故采用此结构^[2]. 从表 1 可以看出, FNN 的收敛速度明显快于 BPN, FNN 能在可容忍的迭代次数内获得很小的 TSE 和 MSE.

Table 1 The iteration times vs. different TSE for BPN and FNN

表 1 BPN 和 FNN 对于不同 TSE 的迭代次数

TSE	BPN	FNN
2.43	248	58
2.33	348	63
2.23	612	69
2.13	1 988	75
2.03	13 249	81
1.93		88
1.83		95
1.73		103
1.63		113
1.53		124
1.43		137
1.33		154
1.23		180
1.13		230
1.03		3 024

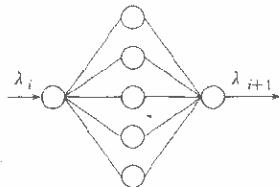


Fig. 8 The structure of 1-5-1 BPN

图 8 1-5-1BPN 的结构

3.2 拥塞控制策略性能比较

考虑一个声音流和一个视频流的情况, 假设缓冲区的阈值(threshold)为 Q_{th} , Q_{th} 为 $0.8Q$, 取样周期为 40ms, 我们比较了 BPN 方法和 FNN 方法, 以信元丢失率(cell loss rate)作为性能评价指标, 结果如图 9 所示.

从图 9 可以看出, 本文提出的基于 FNN 方法的信元丢失率低于 BPN 方法的信元丢失率, 这是因为 FNN 能更准确地捕捉流的特征^[4,9,11]. 通过预测, FNN 控制器能快速而准确地反馈网络的拥塞情况, 从而预防拥塞的发生.

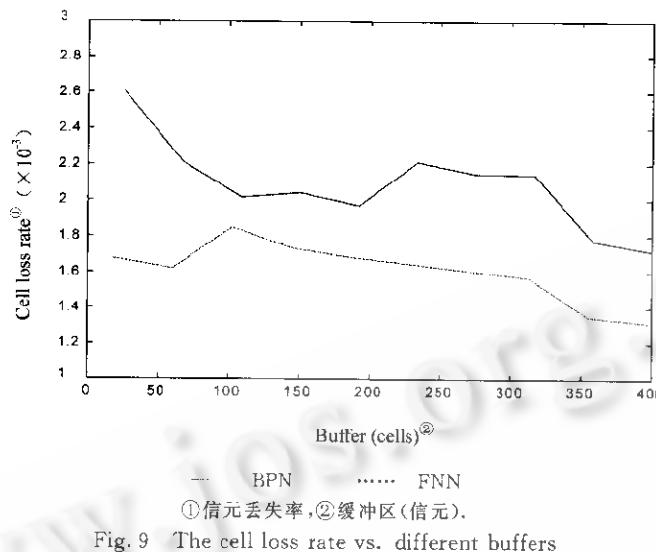


Fig. 9 The cell loss rate vs. different buffers

图 9 不同缓冲区情况下的信元丢失率

4 结束语

FNN 是神经网络和模糊逻辑的有机结合,它能更准确地捕捉流随时间变化的特征。基于 FNN 流量预测实施的拥塞控制策略,对于 ATM 网络的速率调整和降低信元丢失率是非常有效的。本文提出的方法是在源结点执行,不受传输延迟的限制,而传输延迟是高速网络中一个很重要的影响因素。另外,当流量预测与复用、路由、带宽分配相结合时,还能更为有效地改进 ATM 网络的性能。

References:

- [1] ITU Recommendations, I Series (B-ISDN). Ceneva, Switzerland: ITU, 1992.
- [2] Fan Z., Mars P. Access flow control scheme for ATM networks using neural-network-based traffic prediction. In: Newson, P., Rashvand, H. F., eds. IEE Proceedings: Communications. London: IEE Press, 1997, 144(5):295~300.
- [3] Habib I., Tarraf A., Saadawi T. A neural network controller for congestion control in ATM multiplexers. Computer Networks and ISDN Systems, 1997, 29(3):325~334.
- [4] Rugoophuth, H. C. Neural tree call admission controller for ATM networks. In: Lindblad, T., Padget, L. M., Kinser, M. J., eds. Proceedings of the SPIE (The International Society for Optical Engineering Proceedings of the 9th Workshop in Virtual Intelligence/Dynamic Neural Networks). Bellingham WA USA: SPIE, 1999. 455~464.
- [5] Melody, M. W., Chen Min-jia, Chu Nui-ming. Traffic prediction and dynamic bandwidth allocation over ATM: a neural network approach. Computer Communications, 1995, 18(8):563~571.
- [6] Park, Young-Keun, Lee Gyunho. Application of neural networks in high-speed communication networks. IEEE Communications Magazine, 1995, 33(10):68~74.
- [7] Habib I. Special feature topic on neuralcomputing in high speed networks. IEEE Communications Magazine, 1995, 36(10): 30~37.
- [8] Naughton, S., Cunningham, P., Somers, F. Asynchronous transfer mode traffic modeling and dimensioning using artificial neural networks. Engineering Applications of Artificial Intelligence, 1999, 12(3):321~342.
- [9] Liang Yan-chun, Wang Zheng, Zhou Chun-guang. Application of fuzzy neural networks to the prediction of time series. Computer Research & Development, 1998, 35(7):661~665 (in Chinese).
- [10] Wang Wei. The Principal of Artificial Neural Network. Beijing: Beijing University of Aeronautics and Astronautics Press, 1995. 52~74 (in Chinese).
- [11] Kartam, N., Tongthong, T. Potential of artificial neural networks for resource scheduling. Artificial Intelligence for Engineering Design, Analysis and Manufacturing, 1997, 11(3):171~185.

附中文参考文献：

- [9] 梁燕春, 王政, 周春光. 模糊神经网络在时间序列预测中的应用. 计算机研究与发展, 1998, 35(7): 661~665.
- [10] 王伟. 人工神经网络原理. 北京: 北京航空航天大学出版社, 1995. 52~74.

Policy of Fuzzy Neural Network Based Congestion Control in High-Speed Network

HE Xiao-yan, WU Jie-yi, GU Guan-qun

(Key Laboratory for Computer Network and Information Integration, Ministry of Education, Nanjing 210096, China);

(Department of Computer Science and Engineering, Southeast University, Nanjing 210096, China)

E-mail: xyhe@seu.edu.cn

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

Received November 15, 1999; accepted January 25, 2000

Abstract: In this paper, a kind of traffic prediction and congestion control policy based on FNN (fuzzy neural network) is proposed for ATM (asynchronous transfer mode). Congestion control is one of the key problems in high-speed networks, such as ATM. Conventional traffic prediction method for congestion control using BPN (back propagation neural network) has suffered from long convergence time and dissatisfying precision, and it is not effective. The fuzzy neural network scheme presented in this paper can solve these limitations satisfactorily for its good capability of processing inaccurate information and learning. Finally, the performance of the scheme based on BPN is compared with the scheme based on FNN using simulations. The results show that the FNN scheme is effective.

Key words: congestion control; traffic prediction; fuzzy neural network; high-speed network; ATM (asynchronous transfer mode)