

用神经网络实现 VBR 视频通信量的在线预测

苏晓星², 常胜江¹, 熊 涛¹, 郜洪云¹, 申金媛³, 张延¹

(1. 南开大学现代光学研究所, 教育部光电信息技术重点实验室, 天津 300071;

2. 中国科学院声学研究所, 声场声信息国家重点实验室, 北京 100080;

3. 郑州大学, 河南省激光与光电信息技术重点实验室, 河南郑州 450052)

摘要: VBR(Variable Bit Rate) 视频信号具有时变性、非线性和突发性等特点, 实现该信号通信量的高精度预测难度较大. 针对以上问题, 本文提出了一种用于 VBR 视频通信量预测的自适应神经网络模型, 网络训练采用离线与在线相结合的方式, 同时通过删除不重要的权重, 以优化网络的拓扑结构, 提高网络的推广能力, 降低网络在线学习的计算复杂度; 对 VBR 视频通信量预测的模拟结果表明该模型具有高的预测精度, 并能满足通信系统对预测实时性的要求.

关键词: 视频通信; 时延神经网络; 广义卡尔曼滤波; 递归最小方差

中图分类号: TN919.8 文献标识码: A 文章编号: 0372-2112(2005)07-1163-05

On-Line VBR Video Traffic Prediction Using Neural Network

SU Xiaoxing², CHANG Sheng-jiang¹, XIONG Tao¹, GAO Hongyun¹, SHEN Jinyuan³, ZHANG Yanyan¹

(1. Key Laboratory of Optoelectronics Information Technical Science, CME, Institute of Modern Optics, Nankai University, Tianjin 300071, China;

2. State Key Laboratory of Acoustics, Institute of Acoustics, Academic Sinica, Beijing 100080, China;

3. Zhengzhou University, Henan Key Laboratory of Laser and Optoelectronics Information Technology, Zhengzhou 450052, China)

Abstract: An adaptive neural network model for VBR video traffic prediction is proposed in this paper. Firstly, adaptive training and pruning algorithm based on Extended Kalman Filtering (EKF) approach is used to train the Time Delay Neural Network (TDNN). By pruning the unimportant hidden weights, the corresponding redundant hidden neurons can be deleted, as a result a compact TDNN architecture can be obtained. The pruning process results in better generalization ability and lower computational complexity for the online stage. During online training stage, the TDNN's weights will be updated using Recursive Least Square (RLS) algorithm according to current prediction error. Since EKF and RLS are second order algorithms, they can estimate the learning step automatically, faster convergence speed and more precise prediction can be obtained. By simulation and comparison, the adaptive neural network model proposed in this paper is shown to be promising and practically feasible in obtaining the best adaptive prediction of real-time VBR video traffic.

Key words: video communication; time delay neural network; extended Kalman filtering; recursive least square.

1 引言

ATM (Asynchronous Transfer Mode), 即异步传输模式, 在 1988 年被 ITU-T 确定为宽带综合业务数字网 (Broadband Integrated Services Digital Network, B-ISDN) 的支撑技术, 它能够支持包括语音、数据、图像和视频在内的各种多媒体业务. 经视频压缩产生的 VBR 视频业务在 ATM 网络中占据大量的带宽, 实现 VBR 视频的高效传输是提高网络传输服务质量 (Quality of Service, QoS) 的重要环节. ATM 网络是一个基于连接的通信网络, 若要建立一个连接, 就需要为这个新的连接分配所需要的带宽资源. 最简单的带宽分配方法是一次到位的静态分配方

法, 由于 VBR 视频通信量具有时变、非线性、突发性等特征, 静态方法很难分配合适的带宽资源, 在保证服务质量的前提下, 网络的带宽资源利用率很低. 为提高网络在多连接条件下的利用率, 要求动态分配带宽, 从而合理地利用资源, 提高网络的传输效率. 由于 VBR 信源统计特性的复杂性, 依赖有明确数学关系的算法解决带宽的动态分配是非常困难的, 最有效的一类方法是通过通信量特征在线测量与学习, 预测未来的带宽要求, 从而根据预测值动态分配带宽. 线性预测方法^[1-3]是其中最常用的方法, 由于它的计算复杂度较低, 适用于在线学习方式, 即预测器的参数在预测过程中根据当前预测误差进行更新, 但用线性模型预测非线性的 VBR 视频通信

量在理论上就存在不足,它的预测精度不高。

人工神经网络是一种仿脑信息处理模型,由于它具有不依赖先验知识或规则为前提的自适应学习能力,因而在那些实时性要求很高且又无法用确切数学模型描述的智能信息处理问题的求解上,用神经网络方法具有其他方法无法比拟的优势,人们已经尝试使用神经网络方法^[4-8]解决 VBR 视频通信量的预测。文献[4]采用多层前馈神经网络对随机模拟产生的自回归型视频通信量进行了预测,其输出神经元采用非线性激活函数,我们在一篇文章中^[5]已经分析了非线性的输出激活函数并不适合作时间序列预测,因此这类前馈神经网络并不能给出精确的预测;文献[6]采用输出为线性激活函数的 TDNN 网络对 MPEG 信源通信量进行了预测,虽然提高了预测精度,但由于网络训练完成之后其权重参数不再发生改变,属于离线预测模型,而实际的 VBR 视频通信量序列的统计性质是时变的,因此用离线模型实现长时间的 VBR 视频通信量的高精度预测是非常困难的,必须采用在线预测模型。文献[7,8]采用的管线循环神经网络(Pipelined Recurrent Neural Network, PRNN)模型对于较为平滑的 VBR 视频通信量(如场景变化不大的视频会议)能给出较高的预测精度,但对突发性很强的复杂通信量序列(如电影、MTV 等),其性能有所下降,主要原因是 PRNN 采用实时循环学习(Real Time Recurrent Learning, RTRL)算法来在线修改权重,算法要求在视频采样间隔内完成多次迭代,对于突发性很强的通信量序列,网络很难在采样间隔内收敛到很高的精度,因此预测精度不高。

为了实现 VBR 视频通信量的高精度预测,本文提出了一种自适应神经网络模型,网络的训练分为离线学习和在线二次学习两个阶段,离线阶段网络训练采用基于 EKF 的自适应学习及删剪算法以获取先验知识,同时通过删除不重要的隐层权重,以删除相应的冗余隐层神经元,从而获得最佳的网络拓扑结构,提高网络的推广能力,降低网络在线二次学习的计算复杂度;在线预测过程中,网络根据当前预测误差,采用 RLS 算法进行二次学习,使网络能够在兼顾先验知识的前提下适应当前通信量的变化情况,提高网络的预测精度。由于神经网络经离线学习后具有了先验知识,同时由于 RLS 算法是二阶学习算法,能在学习过程中自动估算出每次迭代的最佳学习步长,因此网络在线二次学习的收敛速度很快,能满足实时快速的预测要求。

2 VBR 视频通信量序列的非线性自回归模型

VBR 视频是根据视频序列图像本身的信息量冗余,经过各种图像/视频压缩算法压缩后所产生的图像帧序列,其图像帧中的数据量就是 VBR 视频通信量。图像/视频的压缩编码已被制定出几个国际标准,如静止图像压缩标准 JPEG,电话/电视会议的视频压缩标准 H. 261、H. 263,活动图像压缩标准 MPEG-1、MPEG-2、MPEG-4 等。为了对 VBR 视频进行合理的带宽分配,需要对 VBR 视频信源进行建模^[9-11]。利用前馈神经网络进行通信量预测是基于非线性自回归(Nonlinear Autoregressive, NAR)模型,即:

$$x(n) = f(x(n-1), \dots, x(n-p)) + e(n) \quad (1)$$

其中, $\{x(n)\}$ 表示通信量时间序列, $f(\cdot)$ 是一非线性函数, $\{e(n)\}$ 是 n 时刻的系统误差,一般认为 $\{e(n)\}$ 是一个均值为 0、独立、有确定分布的随机过程。式(1)表明,当前时刻流量 $\{x(n)\}$ 是过去流量 $x(n-1), x(n-2) \dots$ 的一个函数,因此,如果函数 $f(\cdot)$ 已知,就可以通过已有的通信量数据预知将来的通信量,但困难在于式(1)中的非线性函数是未知的,这一函数的映射过程可以通过 TDNN 神经网络模型的学习得到。

3 神经网络模型及算法

虽然离线 TDNN 模型能够映射出一个非线性函数关系,但其函数形式却是静态的,而实际上,即使是同一 VBR 视频业务,其统计性质亦会随时间发生变化,表现出非平稳特性,即(1)式中的函数 f 是个随时间变化的函数,所以离线 TDNN 方法的预测效果并不理想。针对以上问题,本文把 TDNN 网络的训练分为离线和在线两个阶段,并采用 EKF 和 RLS 算法训练网络,使其具有在线预测的能力。

3.1 TDNN 神经网络的拓扑结构和符号说明

TDNN 模型的拓扑结构如图 1 所示,它是一个三层前馈神经网络,与一般的前馈网络模型不同的是,TDNN 模型的输出神经元采用线性激活函数,网络的输入是经过延迟的时间序列值,其输入、输出函数关系是:

$$\hat{x}(n) = \sum_i w_i^T X(n-1) - \theta \quad (2)$$




图 1 TDNN 网络结构

对照上面的 TDNN 网络模型,为了方便起见,我们将本文所用到的符号列在下面:

$X(n)$: 第 n 时刻的输入矢量,

$$X(n) = [x(n) x(n-1) \dots x(n-p)]^T$$

$w_{i,j}^n(t)$: 神经元 (n, j) (第 n 层第 j 个神经元)与 $(n+1, i)$ 之间的互连权重;

$$w^n = [(w_1^n)^T, (w_2^n)^T, \dots, (w_{n_{n+1}-1}^n)^T]^T$$

可以把所有的权重排列成一维列矢量的形式:

$$w = [(w^1)^T, (w^2)^T]^T$$

θ : 输出神经元的偏置;

3.2 基于 EKF 的神经网络训练及自适应删剪算法

互连权重矢量 w 可以被看作一个稳定非线性动力学系统的状态,假定第 n 个训练模式送入网络,对于 TDNN 网络模型,权重矢量 $w(n)$ 的估算值 $\hat{w}(n)$ 可用广义卡尔曼滤波递归公式计算^[12]:

$$\hat{w}(n) = \hat{w}(n-1) + K(n)[d(n) - h(w(n), X(n))] \quad (3)$$

$$K(n) = [P(n-1) + Q(n-1)]H^T(n)\{H(n)[P(n-1) + Q(n-1)]H^T(n) + R(n)\}^{-1} \quad (4)$$

$$P(n) = P(n-1) + Q(n-1) - K(n)H^T(n)[P(n-1) + Q(n-1)] \quad (5)$$

以上算法称为神经网络的 EKF 训练算法, 其中 $d(n)$ 是网络的理想输出矢量, $h(w(n), X(n))$ 是网络的输出矢量, $K(n)$ 为卡尔曼增益, $P(n)$ 为估算权重的协方差矩阵, $H(n)$ 是梯度矢量, 由网络输出对权重的偏导数构成, 即:

$$H(n) = \left. \frac{\partial h[X(n), w]}{\partial w} \right|_{w=\hat{w}(n-1)} \quad (6)$$

经过充分迭代即当 n 充分大时, 经 EKF 算法学习后的均方误差降至规定值以下. 最终所得协方差矩阵 $P(\infty)$ 可用来估算每个权重的重要性, 从而删除那些不重要的权重, 这里的删除指的是将其值置为 0. 对于权重 w_j , 设其重要性的度量为 ΔE_j , 若在训练过程中规定:

$$Q(n) = qI \quad (7)$$

$$R(n) = I \quad (8)$$

其中, $0 < q \ll 1$, 则有^[13]:

$$\Delta E_j = q[P(\infty)^{-2}]_{jj}(w_j)^2 \quad (9)$$

$P(\infty)^{-2}$ 表示它的第 j 个对角元素. 式(9) 给出了删掉 w_j 所引起网络输出误差变化的估算, 根据此估算可以判断权重 w_j 的重要性, 基于以上公式, 删剪过程如下:

(1) 利用 EKF 训练所得的权重与协方差矩阵, 根据式(9) 对所有权重的重要性进行估算, 对所有权重的按重要性从小到大进行排列, 设排列的序号为 $\{S_1, S_2, \dots, S_{N_w}\}$, 满足: $\Delta E_{S_m} \leq \Delta E_{S_m}, (m < k)$;

(2) 按照 $\{S_1, S_2, \dots, S_{N_w}\}$ 的顺序将这些权重依次置为 0, 则进行第 k 次删剪时网络权重矢量中已有 k 个权重被置为 0, 则可根据原来的训练样本集估算删掉这前 k 个权重所引起的均方误差的变化序列 $\{\Delta E_{S_1}, \Delta E_{S_1-S_2}, \dots, \Delta E_{S_1-S_{N_w}}\}$;

(3) 规定由于删掉权重所引起的均方误差的变化不超过 ΔE , 则删掉权重的数目 m_p 满足: $m_p = \max\{m | \Delta E_{S_1-S_m} < \Delta E\}$, 则最终删掉权重的序号为 $\{S_1, S_2, \dots, S_{N_{m_p}}\}$.

值得指出的是, 对于三层前馈神经网络, 若只含有一个输出单元, 则删掉一个隐层到输出层的权重, 则等于删掉了一个隐层神经元, 从输入层到该隐层单元的权重也将全部被删除, 在这种情况下, 删剪算法起到了删除隐层神经元的作用.

通过删除隐层神经元, 可使在线二次学习的 RLS 算法的计算复杂度降低. 对于多层前馈神经网络, 假设神经元的数目为 M , 连接到每个神经元的权重数目平均为 S , 根据文献[14], 算法的时间、空间复杂度都为 $O[(MS)^2]$. 对于单输出的三层网络, 若输入维数较大, 则易看出该计算复杂度可近似为 $O[(HS)^2]$, 其中 H 为隐层单元数目. 设删剪前后隐层单元的数目分别为 $H_0, H_1 (H_0 > H_1)$, 则计算复杂度降低了 $(H_0/H_1)^2$ 倍.

3.3 在线预测中的二次学习 RLS 算法

神经网络在离线学习阶段获得的知识是 VBR 视频通信

量的基本统计特征, 由于 VBR 视频的不确定性和突发性, 导致 NAR 模型(1)式中的非线性函数关系是时变的, 用离线学习获得的知识来预测较长时间后的 VBR 视频通信量无法达到 QoS 所要求的精度. 因此, 网络在离线知识的基础上, 不断地进行二次学习是提高网络预测精度的最可靠的方法. 本文中, 我们把 EKF 和 RLS 算法有机地结合起来, 并通过在 RLS 中引入遗忘因子, 使神经网络能够不断地根据当前的通信量变化情况进行权重更新, 提高网络的预测精度, 重要的是, 由于 RLS 算法的收敛速度很快, 能满足实时快速的预测要求.

RLS 算法^[15]源于线性时间序列分析与预测, 对于非线性预测系统, 通过一级近似, RLS 算法同样适用. 类似于广义卡尔曼滤波的推导过程, 对于 TDNN 神经网络模型, 系统的静态方程可以写为:

$$w_R(n) = w_R(n-1) = w_{R0} \quad (10)$$

$$d(n) = h(w_R(n)) + e(n) \quad (11)$$

估算的权重 $\hat{w}_R(n)$ 应使下列能量函数为最小,

$$\xi(n) = \sum_{j=1}^n \lambda^j |d(j) - h(w_R(n))|^2 \quad (12)$$

这里, λ 是遗忘因子, 满足 $0 < \lambda < 1$ 且接近于 1. 可将 $h(w_R(n))$ 在 $\hat{w}_R(n-1)$ 附近做泰勒展开, 得到

$$h(w_R(n)) = h(\hat{w}_R(n-1)) + H_R(n)(w_R(n) - \hat{w}_R(n-1)) + \dots \quad (13)$$

其中,

$$H_R(n) = \left. \frac{\partial h(w_R)}{\partial w_R} \right|_{w_R=\hat{w}_R(n-1)} \quad (14)$$

采用一级近似, 系统的静态方程(10)、(11) 可以近似为线性系统:

$$w_R(n) = w_R(n-1) = w_{R0} \quad (15)$$

$$d(n) = H_R^T(n)w_R(n) + \zeta(n) + e(n) \quad (16)$$

这里,

$$\zeta(n) = h(\hat{w}_R(n-1)) - H_R^T(n)\hat{w}_R(n-1) \quad (17)$$

假设将 $\zeta(n)$ 与 $w_R(n)$ 无关, 最小化能量函数式(12) 可以得到估算 $\hat{w}_R(n)$ 的 RLS 的递归方程^[14]:

$$\hat{w}_R(n) = \hat{w}_R(n-1) + K(n)(d(n) - h(\hat{w}_R(n-1))) \quad (18)$$

$$K(n) = \lambda^{-1}P_R(n-1)H_R(n)[I + \lambda^{-1}H_R^T(n)P_R(n-1) \cdot H_R(n)]^{-1} \quad (19)$$

$$P_R(n) = \lambda^{-1}P_R(n-1) - \lambda^{-1}K(n)H_R^T(n)P_R(n-1) \quad (20)$$

这里 $P_R(n)$ 是 RLS 算法中的协方差矩阵, 满足:

$$P_R(n) = [\Phi(n)]^{-1} \quad (21)$$

$$\Phi(n) = \lambda\Phi(n-1) + H_R^T(n)H_R(n) \quad (22)$$

引入遗忘因子 λ 的重要意义在于, 神经网络在兼顾离线学习获得的先验知识的基础上, 能够遗忘部分在线学习过程中得到的 VBR 视频通信量的局部统计特征, 避免网络出现学习饱和而无法根据当前通信量统计特征进行权重更新的情况出现.

3.4 EKF 与 RLS 算法的衔接

为提高在线二次学习中的 RLS 算法的预测精度, 初始权重与协方差矩阵的初始值应根据一定的先验知识选取, RLS

初始权重只需选取经 EKF 算法删剪后的权重作为初始权重即可,但由于 RLS 算法中的协方差矩阵与 EKF 算法中的协方差矩阵的意义不同,因此需要进一步推导找到两者明确的衔接关系.由(21)(22)式,根据文献[15],对于我们提出的自适应神经网络模型,在线二次学习中的 RLS 算法的协方差矩阵的初始值 $P_R(0)$ 可取为:

$$P_R(0) = \left[\sum_{n=-n_0}^{-1} \lambda^{-n} H^T(n) H(n) \right]^{-1} \quad (23)$$

式中的 n_0 为离线样本数目.在离线学习收敛后,我们已经在 EKF 算法中推导得到^[13]:

$$E[H^T(n)H(n)] \approx qP(\infty)^{-2} \quad (24)$$

对于式(23),假设离线学习的样本集足够完备,则可取 $\lambda=1$,则协方差矩阵的初始值满足

$$P_R(0) = \left\{ n_0 \left[\sum_{n=-n_0}^{-1} H^T(n)H(n) \setminus n_0 \right] \right\}^{-1} \approx \{ n_0 E[H^T(n)H(n)] \}^{-1} \approx \frac{P^2(\infty)}{n_0 q} \quad (25)$$

4 计算机模拟结果

4.1 离线学习

在计算机模拟中,我们采用的数据是 Bell 实验室提供的电影“Star Wars”经过压缩编码的帧数据量序列^[11],它的时间长度约为两个小时,速度为 24 帧/秒,共计 171000 帧,只采用了帧内压缩方式,每帧的压缩算法类似于 JPEG 标准.从前 10000 个数据中随机抽取连续的 1000 个数据作为离线学习样本. TDNN 网络的输入层神经元数目与预测序列的相关性有关,根据采用数据的特点我们取为 12,至于隐藏层可以由 EKF 方法删剪得到合适的规模,因此我们选取一个较大规模的 TDNN 作为初始网络,具体结构为 12-8-1.在多组实验中,网络基本都在 10 个循环学习之内收敛.网络收敛以后,利用得到的网络权重和协方差矩阵对权重的重要性进行评价,并按重要性进行排列之后,依次将它们置为 0,从而得到一个针对训练样本集的均方误差变化曲线,如图 2 所示.我们最终删除了 42 个不重要的权重,其中 3 个权重为隐藏层到输出层的权重,由于输出层为一个神经元,删掉 3 个隐层到输出层权重就意味着三个隐藏层单元被删掉,因此网络的规模变成 12-5-1,删掉三个隐层单元后能使在线二次学习阶段的 RLS 算




图 2 均方误差变化与权重删剪数目关系图

法的计算复杂度下降约 $(8/5)^2 = 2.56$ 倍,这说明基于卡尔曼滤波的自适应删剪算法能有效删除不重要的权重,进而删除隐层神经元,实现网络拓扑结构的优化.需要说明的是,权重的删剪处理会导致网络训练误差上升,但对测试样本的误差会下降,即网络的推广性变好,这一特性可以在 4.2 节中的实验数据里看到.

TDNN 结构优化完成后,重新组合权重向量和协方差矩阵使之与网络的拓扑结构相对应,组合后的权重向量与协方差矩阵分别记为 \hat{w}_∞, P_∞ .根据 3.4 中提出的 EKF 与 RLS 的衔接方式,在线二次学习的 RLS 算法的权重向量与协方差矩阵的迭代初值取为:

$$w_R(0) = \hat{w}_\infty \quad (27)$$

$$P_R(0) = \frac{P_\infty^2}{1000 * q} \quad (28)$$

4.2 在线二次学习

二次学习阶段选取通信量序列中 20000~40000 区间的 20000 个数据作为检验样本,采用 RLS 算法进行在线预测与在线二次学习,遗忘因子取为 0.999.最终所得的预测曲线如图 3 所示,得到的平均相对预测误差为 0.0014704,这里的相对均方预测误差(RMSE)定义为:

$$RMSE = \frac{\sum_n e^2(n)}{\sum_n x^2(n)} \quad (29)$$




图 3 预测曲线

表 1 预测的相对均方误差比较:

预测算法	平均相对预测误差
Adaptive TDNN (12-5-1)	0.0014704
Adaptive TDNN (without pruning: 12-8-1)	0.0017889
PRNN	0.0029000
Linear LMS(12-1)	0.0167640
Linear RLS(12-1)	0.0018033
Offline TDNN(12-8-1)	0.0500600

为了同其他方法比较,表 1 中同时列出了其他 5 种网络对同一数据的模拟结果,可以看到对同样的 VBR 通信量序列,相对于表中所列的两种线性方法,离线 TDNN 模型和 PRNN 模型,我们提出的自适应 TDNN 模型的预测精度有了较大幅度的提高.表中第二项为离线学习阶段没有经删剪处理的结构(即 12-8-1 结构)作为在线二次学习的初始网络结构所得

到的相对均方误差,与第一项结果的比较可以看出,自适应删剪算法优化了网络的拓扑结构,提高了网络的推广能力.

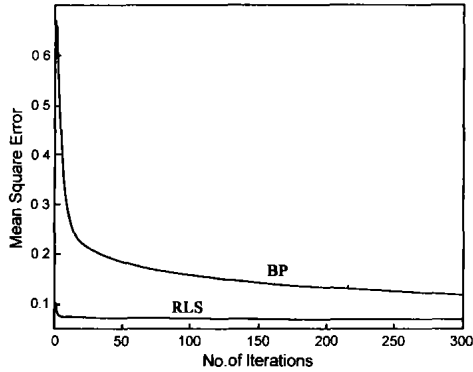


图 4 用 RLS 与 BP 算法训练 TDNN 的收敛曲线

为了对比说明我们提出的自适应算法的实时性能,我们用 RLS 和 BP 算法分别训练结构为 12-8-1 的 TDNN 网络,网络的收敛曲线如图 4 所示,可以看到,同 BP 算法相比,RLS 算法的收敛速度大大加快.在二次学习阶段,RLS 算法只需执行一遍(18)~(20)几步固定的矩阵运算就可以完成权重的在线修改,在 P4/1.8G 计算机上完成上述几步矩阵运算只需 12ms,完全能够满足速度为 24 帧/秒数据的实时性处理的要求.而表中的 PRNN 模型每一次在线修改权重时需要进行多次迭代,本模拟实验中的平均迭代次数约为 57 次,需要时间约为 228ms,通过对比可以看到,我们提出的算法的实时性能得到明显增强.

5 结论

本文提出一种用于 VBR 视频通信量预测的自适应神经网络模型.该模型分为离线学习、在线二次学习两个阶段;离线学习采用基于卡尔曼滤波的自适应训练及删剪算法,通过删除隐层神经元,得到一个结构紧凑的网络作为下一步在线预测与二次学习的先验知识;在线预测过程中,网络根据当前预测误差,采用 RLS 算法进行二次学习,使网络能够在兼顾先验知识的前提下适应当前通信量的变化情况,提高预测精度.VBR 通信量预测的计算机模拟结果表明,我们提出的模型能够对 VBR 视频通信量进行实时、精确的预测.

参考文献:

- [1] A Adas. Using adaptive linear prediction to support real-time VBR video under RCBP network service model[J]. IEEE/ACM Trans. Networking, 1998, 6(5): 635-644.
- [2] 侯纪周,刘建明,奚宏生. ATM 基于预测的动态带宽分配及仿真[J]. 通信技术, 2001, 9: 55-58.
Hou J Z, Liu J M, Xi H S. Dynamic bandwidth allocation over ATM based on variable forgetting factor RLS prediction: simulation[J]. Communication Technology, 2001, 9: 55-58 (in Chinese).
- [3] S J Yoo. Efficient traffic prediction scheme for Real Time VBR MPEG video transmission over High Speed networks[J]. IEEE Trans. Broadcasting, 2002, 48(1): 10-18.

- [4] W M Moh, M J Chen, N M Chu, C D Liao. Traffic prediction and dynamic bandwidth allocation over ATM: A neural network approach[J]. Computer Communications, 1995, 18(8): 563-571.
- [5] 苏晓星,常胜江,马天兵,等.一种用于 ATM 业务量预测的神经网络模型[J]. 光电子·激光, 2003, 14(8): 842-850.
Su X X, Chang S J, Ma T B, et al. A neural network model for traffic prediction in ATM networks[J]. Journal of Optoelectronics · Laser, 2003, 14(8): 842-850 (in Chinese).
- [6] S Chong, S Q Li, J Ghosh. Predictive dynamic bandwidth allocation for efficient transport of Real Time VBR video over ATM[J]. IEEE Journal on Selected Areas in Communications, 1995, 13(1): 12-23.
- [7] P R Chong, J T Hu. Optimal nonlinear adaptive prediction and modeling of MPEG video in ATM networks using pipelined recurrent neural networks[J]. IEEE Journal on Selected Areas in Communications, 1997, 15(6): 1087-1100.
- [8] 林刚,刘泽明. ATM 网中视频码流的非线性自适应预测[J]. 电子学报, 1999, 27(10): 1-3.
Lin G, Liu Z M. Nonlinear adaptive prediction of video traffic in ATM networks[J]. Acta Electronica Sinica, 1999, 27(10): 1-3 (in Chinese).
- [9] B Maglaris, D Anastassiou, P Sen, et al. Performance models of statistical multiplexing in packet video communication[J]. IEEE Trans. Commun, 1988, 36(7): 834-843.
- [10] M W Garrett, W Willinger. Analysis modeling and generation of self similar VBR video traffic[J]. ACM SIGCOMM Computer Communication Review, 1994, 24(4): 269-280.
- [11] M Grossglauser, J C Bolot. On the relevance of Long Range dependence in network traffic[J]. IEEE/ACM Trans. Networking, 1999, 7(5): 629-620.
- [12] S Singhal, L Wu. Training Feed-Forward networks with the extended Kalman algorithm[A]. IEEE Int Conf Acoustics, Speech and Signal Processing[C]. 1989, 1187-1190.
- [13] 陈戎,常胜江,袁景和,等.神经网络的自适应删剪学习算法及其应用[J]. 物理学报, 2001, 50(4): 674-681.
Chen S, Chang S J, Yuan J H, et al. Adaptive training and pruning for neural networks: algorithms and application[J]. Acta Physica Sinica, 2001, 50(4): 674-681 (in Chinese).
- [14] S Shah, F Palmieri, M Datum. Optimal filtering algorithms for fast learning in feedforward neural networks[J]. Neural Networks, 1992, 5(5): 779-787.
- [15] Simon Haykin. Adaptive Filtering Theory[M]. New Jersey: Prentice Hall, 1989.

作者简介:

苏晓星 男, 1978 年出生于安徽安庆, 2003 年毕业于南开大学现代光学研究所, 获工学硕士学位, 现在中国科学院声学研究所攻读博士学位, 研究方向为数字信号处理. E-mail: sxx@mail.ioa.ac.cn.

常胜江 男, 1965 年出生于辽宁本溪, 1996 年毕业于南开大学现代光学研究所, 获博士学位, 1999 至 2000 年在香港城市大学作博士后研究工作, 现为南开大学教授、博导, 主要研究方向为神经网络及其应用. E-mail: sjchang@nankai.edu.cn.