

一种基于小波变换和 FIR 神经网络的广域网网络流量预测模型

田妮莉 喻莉

(华中科技大学电子与信息工程系武汉光电国家实验室 武汉 430074)

摘要: 该文提出了一种基于小波变换和 FIR 神经网络的广域网网络流量预测模型, 首先采用小波分解把网络流量数据分解成小波系数和尺度系数, 即高频系数和低频系数, 将这些不同频率成分的系数单支重构为高频流量分量 and 低频流量分量, 利用 FIR 神经网络对这些分量分别进行预测, 将合成之后的结果作为原始网络流量的预测。实验结果表明: 采用该模型对实际的广域网网络流量数据进行预测, 不仅可以得到较快的收敛效果, 而且预测性能比现有的小波神经网络和 FIR 神经网络要好得多。

关键词: 流量预测; 小波变换; FIR 神经网络(FIRNN)

中图分类号: TP393

文献标识码: A

文章编号: 1009-5896(2008)10-2499-04

A WAN Network Traffic Prediction Model Based on Wavelet Transform and FIR Neural Networks

Tian Ni-li Yu Li

(The Electronics and Information Department, Huazhong University of

Science and Technology / Wuhan National Laboratory for Optoelectronics, Wuhan 430074, China)

Abstract: In this paper, a WAN network traffic prediction model based on wavelet transform and FIR neural networks is proposed. The model employs wavelet transform which decomposes the traffic into high frequency coefficients and low frequency coefficients, then these different frequency coefficients are reconstructed by single branch to the high frequency traffic parts and the low frequency traffic parts which are sent individually into different FIR neural networks for prediction. The synthesized outputs are the predicted results of the original network traffic. The experimental results with the real WAN network traffic show that the proposed model has much better prediction performance compared to the wavelet neural networks and the FIR neural networks.

Key words: Traffic prediction; Wavelet transform; Finite Impulse Response Neural Networks(FIRNN)

1 引言

随着网络通信的迅猛发展, 对网络服务质量的要求越来越高, 如何减少网络拥塞、提高网络的服务性能, 使得网络流量建模与预测在自适应拥塞控制、带宽分配和网络管理中显得至关重要^[1]。实际的广域网网络流量具有更强的自相似性^[2, 3]、高突发性、重尾特性长程相关性和异构性等复杂特性, 对其进行预测还相对困难。

近几年来, 对网络流量进行预测的研究很多。文献[4]根据网络流量的尺度本质和多尺度小波分析, 将网络流量进行小波分解得到信号的小波系数序列, 通过把系数序列送入 ARIMA 模型进行预测。文献[5]提出将网络流量的小波系数作为神经网络的输入从而形成小波神经网络。文献[6]基于下一代网络(NGN)的运行环境, 将神经网络中的转移函数使用小波函数来替代从而构建出另一种小波神经网络(WNN), 同时使用小波多尺度变换方法将原始流量信号分解成不同频率成分的分量信号并将其送到该模型中进行预测。Wan 提出

了一种有限冲激响应神经网络(FIRNN)的时间序列预测方法^[7], 文献[8]将其运用到以太网网络流量预测中。

由于广域网网络流量是非线性, 非平稳, 非高斯的, 包含尖峰和突变现象, 而小波分析是处理非平稳信号最有效的一种方法^[9], 神经网络结构具有很强的自学习能力和逼近任意非线性系统的能力, 而 FIR 滤波器可以存储部分历史信息, 基于以上特点和网络流量理论^[10, 11], 本文提出了一种基于小波变换和 FIRNN 的广域网网络流量预测模型(WFIRNN), 采用实际的广域网网络流量数据进行预测仿真实验, 比较了该模型与现有的小波神经网络和 FIRNN 模型的预测性能。

2 基于小波变换和 FIR 神经网络的预测模型 WFIRNN

基于小波变换和 FIRNN 的预测模型 WFIRNN 如图 1 所示, 网络流量 X 经过多尺度一维小波分解后得到低频系数 cA_k 和高频系数 cD_1, cD_2, \dots, cD_k , 其中 k 为分解尺度, 将这些系数进行单支重构得到网络流量的低频信号分量 A_k 和高频信号分量 D_1, D_2, \dots, D_k , 用这些分量信号来训练各个 FIRNN 以达到预测目的, 其中 $X(n) = A_k(n) + D_1(n) + D_2(n)$




图1 基于小波变换和FIRNN的预测模型
WFIRNN的结构框图(s 表示预测步长)

$+\dots + D_k(n)$ 。

2.1 网络流量的离散小波变换及分析

小波分析具有多尺度特性, 网络流量经过小波变换以后, 将被分解到不同的频带上。分解后的信号在频率成分上比原始信号单一, 在同一尺度下具有短相关的特性^[12], 并且小波分解对信号作了平滑, 因此分解后信号的平稳性比原始信号好得多。而正交小波分解具有自适应的时频局部化功能。在信号的突变部分, 某些小波分量表现幅度大, 它与噪声在高频部分的均匀表现正好形成明显的对比, 因此正交小波分解能有效地区分信号中的突变部分和噪声, 达到消噪预处理的效果。所以, 经过小波变换以后再进行预测可以达到比较快的收敛和较小的预测误差。

Mallat根据多分辨率分析理论, 提出了小波分解与重构的快速算法^[13]。Mallat算法利用构造的两个滤波器: 尺度滤波器(即低通滤波器)和小波滤波器(即高通滤波器), 对信号进行频带划分。尺度滤波器和小波滤波器可以分别表示为 $\{g_l : l=0,1,\dots,L-1\}$ 和 $\{h_l : l=0,1,\dots,L-1\}$, 其中 g_l, h_l 为分解滤波器的系数, L 为滤波器的长度。令 $cA_{k-1} = x(n)$, 这里 $x(n)$ 为 n 时刻的网络流量, 则尺度为 k 时的尺度系数 cA_k 和小波系数 cD_k 分别为

$$cA_k = \sum_l g_l cA_{k-1} \quad (1)$$

$$cD_k = \sum_l h_l cA_{k-1} \quad (2)$$

对尺度系数和小波系数进行重构后得到原始信号的低频和 高频信号分量, 即

$$A_k = \sum_l \bar{g}_l cA_k \quad (3)$$

$$D_k = \sum_l \bar{h}_l cD_k \quad (4)$$


式中 \bar{g}_l, \bar{h}_l 为重构滤波器的系数。

基于以上的分析, n 时刻的信号 $x(n)$ 可以由其低频和高 频信号分量无损的表示出来, 即

$$x(n) = cA_{k-1} = A_k + D_k \quad (5)$$

2.2 FIRNN结构及算法

由于三层神经网络结构可以拟合任意的非线性函数, 所以本文选用如图2(a)所示的三层FIRNN结构, 在神经网络的 输入层和隐含层、隐含层和输出层之间的每个连接中都加入 一个FIR滤波器。其中, 某个连接中的FIR滤波器如图2(b) 所示^[14]。



(a) FIRNN 结构

(b) 和某个连接中的 FIR 滤波器图解

图2

在FIRNN结构中, 连接 $l-1$ 层第 i 节点到 l 层第 j 节点的 FIR滤波器的系数由向量 $\mathbf{W}_{i,j}^l$ 表示, $l-1$ 层第 i 节点的输入向 量由 \mathbf{X}_i^{l-1} 表示, 模型结构间的具体关系表示如下:

$$\mathbf{W}_{i,j}^l = [w_{i,j,0}^l, w_{i,j,1}^l, \dots, w_{i,j,q^l}^l] \quad (6)$$

$$\mathbf{X}_i^{l-1}(n) = [x_i^{l-1}(n), x_i^{l-1}(n-1), \dots, x_i^{l-1}(n-q^l)] \quad (7)$$

$$\text{net}_j^l(n) = \sum_i \mathbf{W}_{i,j}^l \mathbf{X}_i^{l-1}(n) + b_j^l = \sum_i \sum_{k=0}^{q^l} w_{i,j,k}^l(n) x_i^{l-1}(n-k) + b_j^l \quad (8)$$

$$x_j^l(n) = f_j^l(\text{net}_j^l(n)) \quad (9)$$

其中 q^l 表示由 $l-1$ 层连接到 l 层的FIR的阶数。 b_j^l, f_j^l 分别表示 l 层中第 j 个节点的阈值和所采用的节点变换函数, n 为 离散时间指数。在该模型中, 预测低频流量分量的FIRNN结 构中所有节点激活函数都采用含有 α 参数的logsig函数, 即

$$x_j^l(n) = f_j^l(\text{net}_j^l(n)) = \frac{1}{1 + \exp(-\alpha_j^l(n) \text{net}_j^l(n))} \quad (10)$$

预测高频流量分量的FIRNN结构中所有节点激活函数都采用 含有 β 参数的tansig函数, 即

$$x_j^l(n) = f_j^l(\text{net}_j^l(n)) = \frac{1 - \exp(-\beta_j^l(n) \text{net}_j^l(n))}{1 + \exp(-\beta_j^l(n) \text{net}_j^l(n))} \quad (11)$$

训练时采用瞬时误差反传算法, 令 n 时刻的误差为 $E(n) = [d(n) - \bar{d}(n)]^2$, 其中 $d(n)$ 为 n 时刻的期望输出, $\bar{d}(n)$ 为 $d(n)$ 预测值。该模型参数调整学习算法为

$$\mathbf{W}_{i,j}^l(n+1) = \mathbf{W}_{i,j}^l(n) - \Delta \mathbf{W}_{i,j}^l(n) \quad (12)$$

$$\Delta \mathbf{W}_{i,j}^l(n) = \eta_w \Delta \mathbf{W}_{i,j}^l(n-1) + \text{lr}_w \frac{\partial E(n)}{\partial \mathbf{W}_{i,j}^l(n)} \quad (13)$$

$$\alpha_j^l(n+1) = \alpha_j^l(n) - \text{lr}_\alpha \frac{\partial E(n)}{\partial \alpha_j^l(n)} \quad (14)$$

$$\beta_j^l(n+1) = \beta_j^l(n) - \text{lr}_\beta \frac{\partial E(n)}{\partial \beta_j^l(n)} \quad (15)$$

其中 $\text{lr}_w, \text{lr}_\alpha, \text{lr}_\beta$ 为各个参数的学习系数, η_w 为动量系数。

3 仿真结果与分析

本文采用Leland 和Wilson 等人在Bellcore Morristown 研究和工程中心的几个以太网网段上所记录的高分辨率网 络流量数据(<http://ita.ee.lbl.gov/html/contrib/BC.html>)进 行仿真分析, 选用其中的一组广域网数据: 数据集BC- Oct89Ext(其精度达到了 $10 \mu\text{s}$), 对本文所提出的预测模型 WFIRNN的性能进行检测。在仿真过程中, 把以上的流量数

据转换成在0.1 s 的单位时间间隔内到达的字节数。利用其中前1024个样本点的数据来训练该模型,用接下来的256个样本点的数据做预测,同时用相同的样本数据测试现有的WNN模型和FIRNN模型。这里,所有实验采用单步预测,小波尺度为1。

由于样本数据的变化范围较大,容易引起预测精度的波动,在进行小波变换之前,先将流量数据进行预处理,将它们归一化到[0.1,0.9]之间,以便于小波变换后低频流量分量的范围在logsig的值域(0,1)内,而高频流量分量的范围在tansig的值域范围(-1,1)内。

为了更精确的评价预测性能,本文选用相对预测方差 NMSE来衡量预测精度:

$$NMSE = \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (16)$$

其中 x_i 为真实值, \hat{x}_i 为 x_i 的预测值, \bar{x} 为真实数据集的平均值。当NMSE值接近于0,说明 $\hat{x}_i \rightarrow x_i$, 预测效果越好;当NMSE值接近于1,只能说明 $\hat{x}_i \rightarrow \bar{x}$, 预测效果很差。

将1280个样本数据sample经过单尺度一维小波分解和单支重构后得到相应的低频流量分量 A_1 和高频流量分量 D_1 , 如图3所示,其中 $sample=A_1+D_1$, 这里选用db8小波基进行小波分解和重构。

在WFIRNN模型中,当小波基为db8,输入层、隐含层、输出层的节点个数分别取为3,4,1(NN结构记为3×4×1),输入层与隐含层之间的FIR滤波器的阶数取为5、隐含层与输出层之间的FIR滤波器的阶数取为2(FIR结构记为5×2),学习系数 $lr_w=0.2$, $lr_\alpha=lr_\beta=0.005$, 动量系数 $\eta_w=0.1$, 训练300次后,测试样本集的相关预测效果如图4所示,其中对测试样本集的 A_1 分量的预测性能 $NMSE(A_1)=0.1534$, 对 D_1 的预测性能 $NMSE(D_1)=0.0931$, 将 A_1 和 D_1 的合成预测值作为对于总测试样本tested sample的预测,其预测性能 $NMSE(tested\ sample)=0.1126$ 。

表1给出的是基于Haar,db2,db4,db6和db8小波基的WFIRNN预测模型的预测性能值,它们是在相同实验条件下

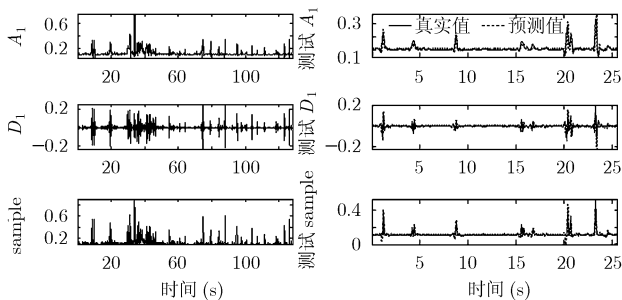


图 3 样本数据 sample 及其经过单尺度小波分解和重构后的高低频率分量 A_1 和 D_1




图 4 WFIRNN 模型的预测效果图

(NN结构: 3×4×1, FIR结构5×2), 经过多次实验得到的。由表1可知:基于db8小波基的WFIRNN预测模型的性能优于其它几个小波基。对于dbN小波基,其N值的不同直接影响到变换后高低频成份的细节部分。由于db8小波在其高低频分量中的细节部分较少,其信号特征较其它几种简单,所以在训练模型时对其学习得更充分,最终的预测性能也更好。

表1 不同小波基下WFIRNN预测模型的性能

小波基	相对方差 NMSE				
	训练		预测		sample
	A_1	D_1	A_1	D_1	
haar	0.5126	0.5332	0.5730	0.5418	0.5828
db2	0.3560	0.3153	0.3336	0.3433	0.3413
db4	0.1438	0.1721	0.1728	0.1929	0.1565
db6	0.1412	0.1053	0.1683	0.1153	0.1382
db8	0.1203	0.0918	0.1394	0.0979	0.1073

图5给出的是对于相同的样本数据,WFIRNN(小波基为db8, NN结构为3×4×1, FIR结构为5×2时),WNN(NN结构为3×4×1, 小波基为db8)和FIRNN(NN结构为3×4×1, FIR结构为5×2时)的学习训练误差曲线。由图5可知:经过小波分解和重构后的分量其数据特性比较集中,所以可以得到较好的学习效果,而加入FIR滤波器后其学习误差得以进一步减小。




图5 WFIRNN,WNN和FIRNN的学习训练误差曲线

为了进一步研究WFIRNN预测模型的性能,我们将它与现有的FIRNN和WNN模型进行了较充分的实验比较。表2给出的是WFIRNN, WNN和FIRNN模型在不同结构下的学习和预测性能,其训练次数分别为1000次,2000次,2000次。由表2可知:WFIRNN模型的预测性能要好于现有的WNN和FIRNN模型。由于WNN预测模型在NN结构为: 3×4×1时其预测性能较好,随着输入结点和相应的隐含层结点的增加,其预测性能反而下降,所以在研究不同数量的FIR滤波器对WFIRNN模型预测性能的影响时,其NN结构选为3×4×1。在表2中,WFIRNN模型的FIR滤波器阶数选为: 13×2时,其预测性能较好,阶数过大预测性能反而下降。因为当FIR滤波器阶数过大即存储的历史数据过多时,输入数据

表2 WFIRNN, WNN和FIRNN模型在不同结构下的学习和预测性能

模型	NN 节点数	FIR 阶数	相对方差 NMSE				
			训练		预测		
			A_1	D_1	A_1	D_1	sample
WFIRNN(db8)	3×4×1	4×2	0.0944	0.0897	0.1339	0.0969	0.1027
		8×2	0.1145	0.0629	0.1299	0.0665	0.0912
		13×2	0.1373	0.0588	0.1387	0.0605	0.0895
		16×2	0.1666	0.0643	0.3207	0.0664	0.1787
WNN(db8)	3×4×1	3×4×1	0.1527	0.3116	0.2124	0.2890	0.2448
		5×9×1	0.1583	0.3899	0.3226	0.3765	0.2885
		8×15×1	0.2007	0.3447	0.3460	0.3633	0.2916
		13×24×1	0.1651	0.3502	0.2918	0.3089	0.2742
FIRNN	3×4×1	4×2		0.8231		1.0548	
		8×2		0.8119		1.0230	
		13×2		0.7431		1.1773	
		16×2		0.6887		1.1638	

值之间的突变就会被平滑掉。

由此可知：对复杂的网络流量进行小波分解和重构后，数据的高低频特性得到了有效分解，再对这些分解后的数据进行学习可以得到令人满意的预测效果，而具有存储功能的FIR滤波器可以使学习和预测的误差进一步减小。

4 结束语

网络流量的建模与预测对于大规模网络的规划设计、网络资源管理以及用户行为的调节等方面都具有积极意义。本文提出的基于小波和FIR神经网络的流量预测模型，对于复杂的广域网的网络流量能取得较好的预测效果，同时与现有的小波神经网络和FIR神经网络模型相比，预测性能要好得多。

参考文献

- [1] Yang Yuekang and Lung Chung-Horng. The role of traffic forecasting in QoS routing—a case study of time-dependent routing. ICC 2005, Seoul Korea, 16–20 May 2005, Vol.1: 224–228.
- [2] Leland W E, Taqqu M S, and Willinger W, *et al.* On the self-similar nature of Ethernet traffic (Extended Version). *IEEE/ACM Trans. on Networking*, 1994, 2(1): 1–15.
- [3] 蔡弘, 陈惠民, 李衍达. 自相似业务模型——通信网络突发业务建模的新方法. *通信学报*, 1997, 18(11): 51–59.
- [4] 洪飞, 吴志美. 基于小波的多尺度网络流量预测模型. *计算机学报*, 2006, 29(1): 166–170.
- [5] 雷霆, 余镇危. 一种网络流量预测的小波神经网络模型. *计算机应用*, 2006, 26(3): 526–528.
- [6] Zhao Qigang, Fang Xuming, and Li Qunzhan, *et al.* WNN-based NGN traffic prediction. Proc. ISADS 2005, Chengdu, China, 4–8 April 2005: 230–234.
- [7] Wan E A. Finite impulse response neural networks with applications in time series prediction. [Ph.D. dissertation], Dept. Elect. Eng., Stanford Univ., Stanford, CA, 1993.
- [8] 林雪纲, 郑成兴, 窦旻等. 基于 FIR 神经网络的以太网网络流量预测. *计算机工程*, 2006, 23(8): 124–130.
- [9] 谭晓玲, 许勇, 张凌等. 网络流量短期预测方法的研究与应用. *计算机工程与设计*, 2006, 27(8): 1341–1345.
- [10] Sarvotham S, Riedi R, and Baraniuk R. Connection-level Analysis and Modeling of Network Traffic. ACM SIGCOMM Internet Measurement Workshop, 2001: 1–5.
- [11] 丛锁, 韩良秀, 刘岩等. 基于离散小波变换的网络流量多重分形模型. *通信学报*, 2003, 24(5): 43–48.
- [12] 王新. 自相似网络流量的建模与预测. [硕士论文], 清华大学, 2003.
- [13] 飞思科技产品研发中心. 小波分析理论与 MATLAB 7 实现. 北京: 电子工业出版社, 2005: 238–258.
- [14] Wan E A. Temporal backpropagation for FIR neural networks. In: Proc Int Joint Conf Neural Networks, San Diego, 1990: 575–580.

田妮莉：女，1982年生，硕士生，研究方向为网络流量预测、计算机网络。

喻莉：女，1970年生，教授，主要研究方向为无线通信、计算机网络、多媒体数据编码。