

一种网络流量预测的小波神经网络模型

雷 霆^{1,2}, 余镇危¹

(1. 中国矿业大学(北京) 计算机系, 北京 100083; 2. 北京林业大学 理学院, 北京 100083)

(xleiting@sohu.com)

摘 要:结合小波变换和人工神经网络的优势,建立一种网络流量预测的小波神经网络模型。首先对流量时间序列进行小波分解,得到小波变换尺度系数序列和小波系数序列,以系数序列和原来的流量时间序列分别作为模型的输入和输出,构造人工神经网络并且加以训练。用实际网络流量对该模型进行验证,结果表明,该模型具有较高的预测效果。

关键词:网络流量;小波变换;人工神经网络;小波神经网络

中图分类号: TP183; TP393.07 **文献标识码:** A

A wavelet neural network model of network traffic forecast

LEI Ting^{1,2}, YU Zheng-wei¹

(1. Department of Computer, China University of Mining & Technology at Beijing, Beijing 100083, China;

2. School of Science, Beijing Forestry University, Beijing 100083, China)

Abstract: Integrating the merit of wavelet transform with that of artificial neural network, a wavelet neural network (WNN) model for forecasting network traffic was created. First, the traffic time series were decomposed to the scaling coefficient series and wavelet coefficient series. Taking the coefficient series as input while original time traffic series as output, an artificial neural network was established and trained. The simulation results on real network traffic show that WNN model is more successful than traditional methods in network traffic prediction.

Key words: network traffic; wavelet transform; ANN(Artificial Neural Network); WNN(Wavelet Neural Network)

网络流量行为的刻画对于实现数据可靠传输,合理分配网络资源具有重要的指导意义。随着计算机网络规模的扩展和业务种类的不断增长,网络流量时间序列已经成为一个非线性、多时间尺度变化的动力系统。在真实环境中的网络流量呈现出相当明显的多尺度特性,如分形、长程相关、自相似性、突发性等,因此传统的网络流量模型,如 Markov 模型、Poisson 模型、自回归(AR)模型、自回归滑动平均(ARMA)模型等,已经不能有效地刻画流量的这些特性,寻求新的模型方法成为当前网络流量行为研究的一个热点^[1~3]。

小波变换由于其独特的多分辨分析能力,在流量行为的研究领域日益受到广泛关注,而人工神经网络具有很强的自学习自适应和非线性逼近功能。本文将小波分析和人工神经网络结合起来,提出了一种新的网络流量预测模型,即小波神经网络(Wavelet Neural Network, WNN)模型。先对流量时间序列进行小波变换,以变换所得的小波变换尺度系数和小波系数序列作为输入、原流量时间序列作为输出构造人工神经网络,对其加以训练以确定网络参数,最后用该模型对网络流量行为进行分析。

1 小波变换

1.1 小波变换简介

小波分析在时域与频域同时具有良好的局部化性能,有一个灵活的时间-频率窗,这在理论和实用中都具有重要意义,已经成功应用于计算机视觉、人工智能、非线性科学等方面。

下面是小波和小波变换的概念。

已知 $\psi(t) \in L^2(R)$, 其中 $L^2(R)$ 表示平方可积,也就是能量有限的函数空间,如果满足条件: $\int_{-\infty}^{+\infty} |\hat{\psi}(\omega)|^2 |\omega|^{-1} d\omega < +\infty$, 或 $\int_{-\infty}^{+\infty} \psi(t) dt = 0$, 其中 $\hat{\psi}(\omega)$ 为 $\psi(t)$ 的 Fourier 变换,那么称为基本小波或母小波。

将母小波函数做伸缩、平移变换得: $\psi_{a,b}(t) = \sqrt{a}\psi(at - b)$, $b \in R - \{0\}$, 称为小波函数,简称小波。设非线性时间序列(信号)函数 $f(t)$, 定义其小波变换为: $W_f(a, b) = \langle f, \psi_{a,b} \rangle = \sqrt{|a|} \int_{-\infty}^{+\infty} f(t) \bar{\psi}(at - b) dt$, 式中 $\bar{\psi}(t)$ 表示 $\psi(t)$ 的复共轭函数。

可以这样理解上面表达式的意义:打个比喻,用镜头观察分析的信号为 $f(t)$, 则 $\psi(t)$ 代表镜头的作用,比如(滤波或做卷积)。时间平移量 b 相当于镜头相对于目标平行移动,频率分辨率 a 的作用相当于镜头向目标推进或远离,由此可见小波变换有以下特点:

1) $W_f(a, b)$ 同时包含了时域和频域的信息,所以小波变换可以同时做时频域分析。

2) 具有多分辨功能,也叫多尺度的特性。参数 a 的变化不仅改变小波的频谱结构,而且改变其窗口的形状和大小,而窗口位置的改变通过调节参数 b 来实现,保证了小波函数的波形可窄可宽;在时频域上都具有表征局部特征的行为和很强的分辨率,可以由粗到细地逐步观察信号,按照不同的分辨率聚焦到信号的任意细节,有利于观察信号特别是非平稳信号的细节行为,比如瞬态或奇异点。

$W_j(a, b)$ 同时包含了时域和频域信息,所以选择小波函数十分重要,目前常用的有 Haar 小波、Shannon 小波、Daubechies 小波、墨西哥帽子小波、高斯类小波和 Morlet 小波等。

一般的时间序列(本文指网络流量时间序列)是离散的,小波变换的离散形式表示为:

$$D_j(k) = \langle f, \psi_{j,k} \rangle = 2^{-\frac{j}{2}} \int_{-\infty}^{+\infty} f(t) \overline{\psi(2^{-j}t - k)} dt \quad (1)$$

式中的整数 j, k 分别表示频域分辨率和时间平移量。

1.2 小波变换算法

有了小波变换,理论上就可以对时间序列进行展开。

设流量时间序列 $\{f(t), t = 1, 2, \dots\}$ 。 $f(t)$ 小波函数和尺度函数展开可表示为^[5]:

$$f(t) = \sum_{k=-\infty}^{+\infty} A_j(k) \varphi_{j-1,k}(t) + \sum_{k=-\infty}^{+\infty} D_{j-1}(k) \psi_{j-1,k}(t) \quad (2)$$

其中 $\{\varphi_{j,k}(t) = 2^{-\frac{j}{2}} \varphi(2^{-j}t - k)\}_{j,k \in \mathbf{Z}}$ 和 $\{\psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k)\}_{j,k \in \mathbf{Z}}$ (\mathbf{Z} 表示整数集) 分别是尺度空间和小波空间中的正交基。 $A_j(k)$ 和 $D_j(k)$ 分别是尺度系数和小波系数。 $A_j(k)$ 也是通过类似(1)式的尺度变换得到,只需将(1)式中的积分核 $\overline{\psi}$ 改为 $\overline{\varphi}$ 。展开式右边的第一部分和式在小波子空间,是信号的高频部分,显示信号的细节,一般含有噪声。第二部分在尺度空间,表示信号的低频部分,反映了信号的本征特性,比如信号的长期发展趋势、周期性等确定的性质。

为了求 $A_j(k)$ 和 $D_j(k)$,就需要计算尺度变换和小波变换的定积分,每求一个 $A_j(k)$ 或 $D_j(k)$,就需要计算一次与 j 与 k 相对应的定积分,显然这会带来很大的计算量,给小波的展开和应用造成很大的障碍。1989 年 Mallat 提出了一个小波系数的快速分解方法^[4]。Mallat 算法简捷的原因在于它为计算小波系数和尺度系数提供了下面的递推公式:

$$\begin{cases} A_0(k) = f(k) \\ A_j(k) = 2^{-\frac{1}{2}} [A_{j+1}(2k) + A_{j+1}(2k+1)], j = 1, 2, \dots, L(3) \\ D_j(k) = 2^{-\frac{1}{2}} [D_{j+1}(2k) + D_{j+1}(2k+1)] \end{cases}$$

L 为尺度数,即小波分解的层数, L 越大,表明在该层时间的分辨率越小,所能观察到信号的节就越多。 $A_j(k)$ 和 $D_j(k)$ ($j = 1, 2, \dots, L$) 分别称为在尺度 j 下的近似信号和细节信号,称 $\{D_1(k), D_2(k), \dots, D_L(k), A_L(k)\}$ 为在尺度 L 下的小波变换系数序列。利用小波变换的多分辨功能,将复杂的时间序列分别投影到尺度空间和小波空间,得到相应的小波系数序列和尺度系数序列。

2 小波网络模型

2.1 模型的建立

针对计算机网络流量系统多尺度和非线性的特性,综合小波变换的多分辨分析能力和人工神经网络的非线性逼近功能,本文建立一种新的网络流量预测模型。以 k 时刻小波变换系数序列 $\{D_1(k), D_2(k), \dots, D_L(k), A_L(k)\}$ 作为人工神经网络的输入, $k+T$ 时刻的原始流量时间序列 $[f(k+T)]$ 作为网络输出,其中 T 为预测期,构造流量预测的小波神经网络模型。小波变换从时频分析角度出发,将复杂的流量时间序列分解成若干不同频率成分的低频信号序列 $A_j(k)$ 和 高频信号序列 $D_j(k)$,每一频率成分都有自身的制约因素与发展演化规律,在流量时间序列中的地位、作用机制以及对流量时间序列的贡献完全不一样,神经网络的层次结构和权值正好反映了这些区别,刻画了流量时间序列中的近似部分和细节部分相互依赖、

相互制约的非线性关系,使小波神经网络模型具有很好的非线性逼近功能,能拟合复杂的输入输出之间的映射关系,所以可以用该模型对复杂的非线性网络流量进行预测。

WNN 模型预测流量的过程主要包括流量时间序列的小波系数分解与神经网络构造和权值训练这样两个环节。

2.2 流量时间序列的小波系数分解

利用 Mallat 算法,对原来流量时间序列的进行小波分解,本文选用了 Daubechies 小波函数,得到小波变换系数序列 $\{D_1(k), D_2(k), \dots, D_L(k), A_L(k)\}$,其中 L 为分解尺度。

2.3 神经网络的构造和权值的训练

人工神经网络(ANN)是对生物神经进行仿真研究的结果,是基于生物学中的神经网络的基本原理,按照控制工程的思路和数学描述的方法建立起来的数学模型。ANN 能够模拟人脑的结构与功能机制,实现某方面的功能;能自我感知、自主适应,有很强的学习和逼近功能;能比较准确地揭示非线性复杂动力系统的内在关系和演化机理。所以 ANN 可以用来分析和预测网络流量行为和演化趋势^[5~7]。

ANN 有许多类型,一般都采用适当的算法,有针对性地对 ANN 进行训练,以确定模型的参数(如网络连接权值、兴奋阈值),以获得某个特定问题的解。其中 1986 年 Rumelhart 提出的反向传播网络(Back-Propagation Network)算法把正向传播和反向传播时网络中各层权值参数的调整都考虑了,极大改善了网络自适应和非线性逼近功能,是目前广泛应用的神经网络学习算法。

Kolmogorov 定理表明^[5~7]:只要用三层 BP 网络模型就可以实现对一般非线性函数的刻画。考虑到计算的复杂度,本文 BP 网络就采用三层结构,即输入层,输出层,还有中间的隐含层。将小波变换序数序列 $\{D_1(k), D_2(k), \dots, D_L(k), A_L(k)\}$ 作为网络输入,输出节点为原始流量时间序列 $Y = [f(k+T)]$,即网络结构输入和输出节点分别为 L 和 1。隐含层的神经元个数和网络权值是网络性能的关键,可以分别通过逐次修正法和梯度下降算法或附加动量 BP 算法对网络训练后来确定。

3 模型仿真




图1 小波分解的系数序列

本文数据来源于流量文库: <http://newsfeed.ntcu.net/~>

news/2005/, 收集了主节点路由器 NEWS 从 2005 年 6 月 6 日到 8 月 28 日, 共 12 周的每天网络的每小时访问流量, 得到 $24 \times 84 = 2016$ 个数据, 从而形成了一个网络流量时间序列 $\{s(t), t = 1, 2, \dots, 2016\}$, 以每个星期作为 $1d$ 。由前 10 周流量共 $24 \times 70 = 1680$ 个数据建立 WNN 模型, 后 2 周数据预测检验。针对上面的流量时间序列, 取尺度数 $L = 3$ 。用 Mallat 算法对流量时间序列进行分解, 得小波分解的系数序列为 $\{D_1(k), D_2(k), D_3(k), A_3(k)\}$, 如图 1 所示。

取 WNN 模型中的隐层节点数为 4, 输入为 $X = [D_1(k), D_2(k), D_3(k), A_3(k)]$, 输出为 $Y = [s(k+T)]$, 则 WNN 网络为 4-4-1 结构。预测期分别取 T 为 $1d, 2d, 3d$, 目的是为了验证该模型对 $1d, 2d, 3d$ 的预测效果。采用附加动量 BP 算法确定网络权值。本文小波系数分解和 WNN 训练的实现工具均为 Matlab 6.5。




图2 预测期为 1d 的网络流量观测结果




图3 预测期为 2d 的网络流量观测结果




图4 预测期为 3d 的网络流量观测结果

先对 WNN 模型进行训练, 对于上述不同的三个预测期, 经过 3000 步的训练后都取得良好效果, 然后分别将 $Y = [s(k+1d)]$, $Y = [s(k+2d)]$ 和 $Y = [s(k+3d)]$ 作为相应的神

经网络的输入, 所对应的输出序列即为未来预测期网络流量的时间序列。图 2 ~ 图 4 列出了 WNN 模型预测期为 $1d, 2d$ 和 $3d$ 的网络流量预测效果。

图 2 ~ 图 4 说明, 对于不同的预测期, WNN 模型的预测效果都比较理想, 特别是预测期为 $1d$ 和 $2d$ 的时候, 当预测期延长到了 $3d$, 预测精度也还是比较高的。

同时本文也采用了传统的 ARMA 模型对网络流量进行了预测, 得到在 $1d, 2d$ 和 $3d$ 的预测期的平均相对误差分别为 17.9%, 31.7% 和 42.3%, 而同样的预测期, WNN 模型预测的平均相对误差分别是 9.32%, 14.7% 和 20.1%, 这也能够说明 WNN 模型要比传统的预测方法的精度要高。说明了小波网络模型紧紧抓住了网络流量多尺度特征及其各频率成分的发展趋势和对原流量时间序列的作用机制, 在一定程度上克服了传统模型当观测期延长时预测精度差的缺点。可见, WNN 能很好地预测网络日流量发展趋势。WNN 模型建模思路清晰, 实现过程简单, 效果理想, 具有很强的实用性。

参考文献:

- [1] FELDMANN A, GILBERT AC, WILLINGER W, *et al.* Looking behind and beyond self-similarity: Scaling phenomena in measured WAN traffic [A]. Proceedings of 35th Annual Allerton Conference on Communication, Control, and Computing [C], 1997. 269 - 280.
- [2] LELAND WE, TAQQU MS, WILLINGER W, *et al.* On the self-similar nature of ethernet traffic [J]. IEEE/ACM Transaction on Networking, 1994, 2(1): 1 - 15.
- [3] WILLINGER W, TAQQU MS, SHERMAN R, *et al.* Self-Similarity Through High-Variability: Statistical analysis of ethernet LAN traffic at the source level [A]. Proceedings of the ACM SIGCOMM'95 [C], 1995.
- [4] 徐晨, 赵瑞珍, 甘小冰. 小波分析·应用算法 [M]. 北京: 科学出版社, 2004.
- [5] HOMIK KM, STINCHCOME M, WHITE H. Multilayer feedforward network universal approximators [J]. Neural Network, 1989, 2(2): 259 - 366.
- [6] 焦李成. 神经网络系统理论 [M]. 西安: 西安电子科技大学出版社, 1995.
- [7] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用 [M]. 合肥: 中国科学技术大学出版社, 1998.

(上接第 521 页)

- [4] 刘芳, 杨海潮. 参数可调的克隆多播路由算法 [J]. 软件学报, 2005, 16(1): 145 - 150.
- [5] 陈年生, 李腊元, 董武世. 基于混合遗传算法的 QoS 多播路由算法 [J]. 计算机应用, 2005, 25(7): 1485 - 1488.
- [6] FEI X, LUO J, WU J, *et al.* QoS routing based on genetic algorithm [J]. Computer Communications, 1999, 22 (15/16): 1394 - 1399.
- [7] Van VELDHUIZEN DA, LAMONT GB. Multiobjective evolutionary algorithm: analyzing the state-of-the-art [J]. IEEE Transactions on Evolutionary Computation, 2000, 8(2): 125 - 147.
- [8] AHUJA RK, MAGNANTI TL, ORLIN JB. Network Flows: Theory, Algorithms, and Applications [M]. Prentice-Hall, 1993.
- [9] PARK K, SHIN YS, LEE HC. Multicast routing by multiple tree routes [A]. MARSAN MA, BIACO A, ed. QoS-IP 2001, LNCS 1989 [C], 2001. 285 - 297.
- [10] JIA X, WANG L. A group multicast routing algorithm by using multiple minimum Steiner trees [J]. Computer Communications, 1997, 20(9): 750 - 758.
- [11] STEUER RE. Multiple Criteria Optimization: Theory, Computation, and Application [M]. New York: Wiley, 1986.
- [12] TARJAN RE. Finding optimum branchings [J]. Networks, 1977, 7(1): 25 - 35.
- [13] FONSECA CM, FLEMING PJ. Genetic algorithm for multiobjective optimization: formulation, discussion and generalization [A]. Proceedings of the 5th International Conference on Genetic Algorithms [C]. San Mateo, California, 1993. 416 - 423.
- [14] 崔逊学, 李森, 方廷健. 基于免疫原理的多目标进化算法群体多样性研究 [J]. 模式识别与人工智能, 2001, 14(3): 291 - 296.