

基于 WA-ELM 的网络流量混沌预测模型

胡 竟 伟

(河套学院 理学系, 内蒙古巴 彦淖尔 015000)

摘 要: 针对当前网络流量预测模型存在的缺陷, 结合网络流量的混沌特性, 提出了小波变换和极限学习机的网络流量预测模型(WA-ELM). 首先采用小波变换对网络流量时间序列进行处理, 得到不同频率特征的分量, 并对各特征分量进行相空间重构, 然后采用极限学习机对网络流量各分量进行建模与预测, 并对网络流量分量的预测值进行小波重构, 得到原始网络流量的预测值, 最后采用具体网络流量预测结果进行了验证, 并与其他模型进行了对照测试. 结果表明, WA-ELM 获得了比其他模型更高的网络流量预测精度, 而且网络流量的预测结果更加稳定, 为网络流量提供了一种新的建模工具.

关键词: 网络流量; 极限学习机; 小波变换; 特征分量; 预测模型

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2017)06-0132-05

Network Traffic Prediction Based on Wavelet Transform and Extreme Learning Machine

HU Jing-wei

(Department of Science, Hetao College, Bayannur 015000, China)

Abstract: Aiming at the defects of the current network traffic prediction model, a novel network traffic prediction model based on wavelet transform and extreme learning machine is proposed. At first, wavelet transform is used to process time series of network traffic to get different frequency components, and each feature is used to be reconstructed by phase space, and secondly extreme learning machine is used to model and predict network traffic of each component, and predicted value of each component are reconstructed by traffic by wavelet transform to get network traffic prediction results, at last, the performance is tested by network traffic data and compared with other models. The results show that the proposed model can get higher accurate prediction results than other models, and the prediction results of network traffic are more stable, it provides modeling tool for network traffic.

Key words: network traffic; extreme learning machine; wavelet transform; feature component; prediction model

1 引言

网络流量可以描述网络拥挤程度, 并能够根据预测结果制定相应的管理方案. 当前网络上的各种类型数据大幅度增加, 网络阻塞越来越普遍, 给人们的生活和工作带来不便, 为此对网络流量进行科学、准确的预测, 对可能发生的网络阻塞提前时间做出科学判断, 具有十分重要的实际研究意义^[1-3].

到目前为止, 出现了大量的网络流量预测模型, 并取得一定的研究结果, 但是由于该问题实际应用

价值高, 网络流量的准确预测仍然一个人们关注的焦点^[4]. 随着机器学习理论的发展, 当前经典的网络流量预测模型主要有灰色模型、神经网络、支持向量机等, 在网络流量预测建模过程中, 学者们发现网络流量受到多种因素的综合作用, 具有一定混沌特性, 具有多层次变化特性, 即还有周期性、趋势性, 采用单一模型难以获得理想的网络流量预测结果^[4-5]. 小波变换可以对时间序列数据进行多层次分解, 提取原始时间序列的局部特征, 被学者应用于网络流量的建模过程中, 如有学者将小波变换和支持向量机

进行融合,建立了相应的网络流量预测模型^[6],网络流量预测精度要远远高于单独的支持向量机预测精度.相对于神经网络,支持向量机的学习性能更优,但如何确定参数十分困难^[7-8].极限学习机(ELM)是一种单隐层的前馈神经网络,训练速度比较传统神经网络快,如 RBF 神经网络,泛化性能更优,而且待确定的参数少^[9].

针对当前网络流量预测模型存在的缺陷,结合网络流量的混沌特性,提出了小变换和极限学习机的网络流量预测模型(WA-ELM).首先采用小波变换对网络流量时间序列进行多特征分解,并对进行相空间重构,然后采用极限学习机进行预测,并对预测值进行小波重构,测试结果表明,WA-ELM 获得高精度的网络流量预测结果,预测结果更加稳定,为网络流量预测探索一种有效的研究方法.

2 网络流量的混沌特性分析

相空间重构是时间序列混沌分析和处理的关键技术,能够从某一分量变化轨迹挖掘非线性动力系统变化特点,对于一维网络流量时间序列 $x_i, i = 1, 2, \dots, n$,通过相空间重构可以得到一个多维的时间序列,即有

$$y_t = \{x_t, x_{t+\tau}, x_{t+2\tau}, \dots, x_{t+(m-1)\tau}\} \quad (1)$$

$$t = 1, 2, \dots, n - (m-1)\tau$$

式中, m 表示网络流量的嵌入维数; τ 表示网络流量的延迟时间^[10].

根据 Takens 嵌入定理,重构的多维网络流量时间序列与原始网络流量时间序列是拓扑等价的,可以描述原始网络流量的变化特点, m 和 τ 值的选择十分关键,由于实验采集的网络流量时间序列存在一定的噪声,再加网络流量时间序列长度有限,通常 τ 为 1.同时相对其他嵌入维估计算法,虚假邻近点算法操作简单,可以获得理想的 m ,因此采用虚假邻近点法确定 m 的值.

由于网络流量是一种混沌系统,对初始值十分敏感,而 Lyapunov 指数可以描述系统的混沌特性,若最大 Lyapunov > 0 ,表示网络流量的时间序列具有混沌特性,为此选择小数据量法计算网络流量时间序列的最大 Lyapunov 指数.

3 小波变换和极限学习机

3.1 小波变换

对于一个网络流量时间序列,通过小波变换进行多尺度解,得到不同的特征分量,它们均表示网络

流量的不同变化趋势.设 y_t 表示网络流量的时间序列,连续小波变换可表示为

$$W(a, b) = \frac{1}{\sqrt{a}} \int y_t \psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

式中, a 表示分解尺度; b 表示位移.

分量可通过小波变换重构得到新的网络流量时间序列,即

$$y_t = \frac{1}{C_\psi} \int_0^{+\infty} \int_{-\infty}^{+\infty} \frac{W(a, b)}{\sqrt{aa^2}} \psi\left(\frac{t-b}{a}\right) da db \quad (3)$$

式中, C_ψ 表示允许条件^[11].

网络流量时间序列实际是一种数字信号,因此需要引入滤波器实现离散小波变换,即有

$$c_{j+1}(m) = \sum_m h(m-2k) c_j(m) \quad (4)$$

$$d_{j+1}(m) = \sum_m g(m-2k) c_j(m) \quad (5)$$

式中, j 表示小波变换的分解尺度, k, m 表示平移系数, $c_{j+1}(m)$ 和 $d_{j+1}(m)$ 表示高频系数和低频系数, $h(m-2k)$ 和 $g(m-2k)$ 表示高通滤波器和低通滤波器.

网络流量时间序列通过离散小波变换的分解后,得到高频部分 d_1 和低频部分 c_1 ,然后可以 c_1 进行细分,以此类推,可以得到描述网络流量变化的细节特征,便于对网络流量进行建模与预测.

3.2 极限学习机

相对于其他人工神经网络,极限学习机只要设置适当的隐含层结点数,通过一次迭代进行回归,就可以得到问题的解,明显加快了训练速度.设训练样本为 $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$,其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]$, $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]$ 表示输入和期望输出,那么极限学习机模型为^[12]

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = y_j, j = 1, 2, \dots, N \quad (6)$$

式中, N 表示极限学习机的隐含层节点数; $g(x)$ 表示激励函数, $W_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ 和 $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 分别表示隐含层与输入层节点、输出层节点间的连接权值; b_i 表示隐含层节点的偏置值.

N 个方程可以写成:

$$H\beta = T \quad (7)$$

式中, H 表示隐含层输出矩阵,其中

$$H(W_1, \dots, W_M, b_1, \dots, b_M, X_1, \dots, X_N) = \begin{bmatrix} g(W_1 \cdot X_1 + b_1) \cdots g(W_M \cdot X_1 + b_M) \\ \vdots \quad \quad \quad \vdots \\ g(W_1 \cdot X_N + b_1) \cdots g(W_M \cdot X_N + b_M) \end{bmatrix}_{N \times M} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_{M-1} \end{bmatrix}_{M \times 1} \quad T = \begin{bmatrix} t_1 \\ \vdots \\ t_N \end{bmatrix}_{N \times 1} \tag{9}$$

输出值和期望值间的误差平方和为 $E(W)$ ，因此极限学习机的求解过程是搜索最优权值 $W = (a, b, \beta)$ ，具体为

$$\underset{W = (a, b, \beta)}{\operatorname{argmin}} E(W) = \underset{W = (a, b, \beta)}{\operatorname{argmin}} \|\epsilon\|^2 \tag{10}$$

$$\sum_{i=1}^N \beta_i g(\omega_i \cdot x_j + b_i) - y_j = \epsilon_j, j = 1, 2, \dots, N \tag{11}$$

式中, $\epsilon_j = [\epsilon_{j1}, \epsilon_{j2}, \dots, \epsilon_{jm}]$ 表示第 j 个样本的预测误差。

随机随定隐含层参数, 极限学习机通过训练确定的权重值, H 变成一个常数矩阵, 采用最小二乘算法得到解为

$$\beta = H^+ Y \tag{12}$$

式中, H^+ 为 H 的 Moore-Penrose 广义逆矩阵。

4 WA-ELM 的网络流量预测模型

基于 WA-ELM 的网络流量建模以混沌原理为基础, 首先估计网络流量时间序列的 τ 和 m , 并对原始网络流量时间序列进行相空间重构, 为预测模型建立提供理论依据, 然后利用小波变换对网络流量时间序列进行多尺度分解, 并对它们进行相空间重构, 最后采用极限学习机对它们进行预测, 并对它们进行叠加得到网络流的最后预测结果, 工作流程如图 1 所示。

5 网络流预测的应用实例

5.1 数据源

选择网络流量标准数据集作为研究对象, 随机选择 500 个数据作为训练集, 200 个数据作为检验集, 它们如图 2 所示。

5.2 网络流量的混沌特性识别

相关研究结果表明^[11], 网络流量时间序列具有弱混沌特性, 为此最优 $\tau=1$, 然后采用虚假邻点算法估计 m , 如图 3 所示。从图 3 可以看出, 当前 $m=5$ 时, 网络流量时间序列的虚假最邻近点的不再随着 m 变化发生改变, 因此最佳 $m=5$ 。

采用小数据量计算网络流量时间序列的最大 Lyapunov 指数, 其变化曲线如图 4 所示, 从图 4 可知, 网络流量时间序列的最大 Lyapunov 指数等




图 1 WA-ELM 的网络流量预测建模流程




图 2 网络流量标准数据集




图 3 网络流量 m 值的确定

0.0913, 远远大于混沌特性判断阈值 0, 因此该网络流量时间序列是一种混沌时间序列。

5.3 网络流量的预测

采用 DSP 2000 软件对网络流量时间序列进行 3 尺度分解, 得到结果如图 5 所示。

各分量的 $\tau = 1$, 采用虚假邻点算法估计各分




图 4 Lyapunov 指数的估计




图 5 网络流量时间序列的小波分解后分量

量的最优 m , 结果表明, 低频分量 c_3 的 $m = 3$, 高频分量的 d_1, d_2, d_3 的 m 分别为 2, 5, 6, 采用相应的最优 τ 和 m 进行分量重构, 最后采用 ELM 对它们进行构建网络流量预测模型, 并得到各分量的预测结果, 对各分量预测结果进行叠加得到网络流量的最后预测结果, 具体如图 6 所示。




图 6 标准网络流量的预测结果对比

选择小波变换和 BP 神经网络的网络流量预测模型(WA-BPNN)和极限学习机(ELM)的网络流量模型进行对比测试, 预测精度如表 1 所示。

表 1 带噪声的网络流量的预测精度对比 %

模型	标准网络流量	含噪网络流量
ELM	84.2	75.80
WA-BPNN	90.73	88.29
WA-ELM	95.14	93.25

为验证 WA-ELM 的鲁棒性, 选择带噪声的网络流量数据建立网络流量预测模型, 选择 500 个样本作为检验集, 其余样本作为测试集, 低频分量 a_4 的 $m=7$, 高频分量的 d_1, d_2, d_3 的 m 分别为 4, 5, 2, 带噪声网络流量预测结果如图 7 所示, 所有模型的网络流量预测精度如表 1 所示。




图 7 带噪声网络流量的预测结果对比

5.4 预测结果分析

- (1)对表 1 的网络流量预测精度标进行分析可以看出, WA-ELM 的预测精度好于 WA-BPNN、ELM, 对比结果表明, 相对于 BP 神经网络, ELM 的泛化能力更优, 克服了传统神经网络存在的缺陷, 因此, 提高了网络流量预测精度;
- (2)ELM 的网络流量预测误差远远高于 WA-ELM, 这表明选择小波变换对网络流量进行不同尺度分解, 可以得到更加细微网络流量变化特性分量, 并通过 ELM 对不同分量进行建模, 可以有效降低网络流量的预测误差。
- (3)对图 6 和图 7 进行对比和分析可以发现, WA-ELM 的网络流量预测值与期望值基本拟合, 而且 ELM、WA-BPNN 的拟合结果差, 尤其对于带噪声的网络流量时间序列, 预测精度很低, 难以以满足网络流量的实际应用需求, 结果表明 WA-ELM 具有更好的鲁棒性和通用性, 网络流量的预测结果更加稳定和可靠。

6 结束语

网络流量变化非常复杂、多变, 结合网络流量混沌特性, 本文对原始网络流量数据进行小波变换, 并

对不同特征的分量进行混沌处理,同时针对分量的非线性变化特点,采用极限学习机进行预测,获得了较高精度的网络流量预测结果,而且具有良好的稳定性.相对于神经网络,极限学习机的训练过程更加简单,同时克服了支持向量机的参数确定难题,降低人为因素风险,结果表明,网络流量预测值与实测值拟合很好,建立的网络流量模型具有一定的实际应用价值.

参考文献:

- [1] Nguyen T T, Armitage G. A survey of techniques for internet traffic classification using machine learning [J]. IEEE Communications Surveys and Tutorials, 2008, 10(4): 56-76.
- [2] 姜明,吴春明,张曼,等. 网络流量预测中的时间序列模型比较研究[J]. 电子学报, 2009, 37(11): 2353-2358.
- [3] 李士宁,闫焱,覃征. 基于 FARIMA 模型的网络流量预测[J]. 计算机工程与应用, 2006, 42(29): 148-150.
- [4] 马华林,李翠凤,张立燕. 基于灰色模型和自适应过滤的网络流量预测[J]. 计算机工程, 2009, 35(1): 130-131.
- [5] Silva C G. Time series forecasting with a nonlinear model and the scatter search met heuristic [J]. Information Sciences, 2008, 178(16): 3288-3299.

- [6] Callado A, Keu R J, Sadok D, et al. Better network traffic identification through the independent combination of techniques [J]. Journal of Network and Computer Applications, 2010, 33(4): 433-446.
- [7] 田妮莉,喻莉. 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[J]. 电子与信息学报, 2008, 30(10): 2549-2555.
- [8] 刘渊,王鹏. 融合小波变换与贝叶斯 LS-SVM 的网络流量预测[J]. 计算机应用研究, 2009, 26(6): 2229-2231.
- [9] 张东娟,丁煜函,刘国海,等. 基于改进极限学习机的软测量建模方法[J]. 计算机工程与应用, 2012, 48(20): 51-54.
- [10] 陈伟,吴介军,段渭军. 基于小波分解和 SVM 的城市大气污染浓度预测[J]. 现代电子技术, 2011, 34(13): 145-148.
- [11] Jin Yi, Zhou Gan. Theoretical mean-variance relationship of IP network traffic based on ON/OFF model [J]. Sci China Inf Sci, 2009, 52(4): 645-655.
- [12] 高光勇,蒋国平. 采用优化极限学习机的多变量混沌时间序列预测[J]. 物理学报, 2012, 61(4): 1-9.

作者简介:

胡竟伟 女(蒙古族), (1981-), 硕士, 讲师. 研究方向为计算机软件与理论. E-mail: 20524787@qq.com.

(上接第 131 页)

参考文献:

- [1] 王佳欣,翟红生. 畸变粘连细胞的高精度图像分割模型仿真[J]. 计算机仿真, 2015, 32(2): 418-422.
- [2] 李文勇,李明,钱建平,等. 基于形状因子和分割点定位的粘连害虫图像分割方法[J]. 农业工程学报, 2015, 31(5): 175-180.
- [3] 谢榕,刘亚文,李翔翔. 大数据环境下卫星对地观测数据集成系统的关键技术[J]. 地球科学进展, 2015, 30(8): 855-862.
- [4] 倪志强,叶明. 基于分水岭变换的粘连颗粒图像分割方法[J]. 计算机系统应用, 2014, 23(6): 93-97.
- [5] 代强玲,张宏伟,林宗坚. 稀少控制的多源卫星影像区域网平差研究[J]. 测绘科学, 2014, 39(9): 34-38.
- [6] 常生鹏,马亿昨,蔡立军,等. 一种基于 Hadoop 的高分辨率遥感图像处理办法[J]. 计算机工程与应用, 2015,

51(11): 167-171.

- [7] 付卓,申文明,熊文成,等. 基于环境一号卫星 CCD 影像的磷石膏识别[J]. 遥感技术与应用, 2014, 29(6): 970-975.
- [8] 段光耀,宫辉力,李小娟,等. 结合特征分量构建和面向对象方法提取高分辨率卫星影像阴影[J]. 遥感学报, 2014, 18(4): 760-770.
- [9] 蔡燕伟,崔红霞. 基于彩色空间的二维 OSTU 的图像分割算法[J]. 电子设计工程, 2014, 22(5): 131-133.
- [10] 陈阳,陈霞,汪军. 基于图像处理的织物覆盖系数检测[J]. 西安工程大学学报, 2016, 30(1): 16-20.

作者简介:

贾润亮 男, (1973-), 硕士, 讲师. 研究方向为人工智能. E-mail: wanghong1975001@sina.com.