

基于 FARIMA-GARCH 模型的网络业务预测算法

杨双懋^{1,2}, 郭伟², 唐伟²

(1. 电子信息控制重点实验室, 四川 成都 610036; 2. 电子科技大学 通信抗干扰技术国家级重点实验室, 四川 成都 611731)

摘要: 针对网络流量的波动性与自相似特性为其精确预测提出的挑战, 提出了一种基于 FARIMA-GARCH 模型的预测算法。该算法首先利用分段双向 CUSUM 检测算法对流量序列的均值进行有效检测, 并在此基础上将序列零均值化; 然后采用限定搜索法对分数差分阶数进行精确估计; 在获得模型参数后, 使用 FARIMA-GARCH 模型对网络流量进行预测。仿真实验表明, 限定搜索法能够获得比传统算法更高的估计精度。随后采用真实网络流量验证了预测算法的性能, 在保持与 FARIMA 预测算法等价的时间复杂度下, 其均方根和相对均方根误差与 RBF 神经网络预测算法相当, 而高于 FARIMA 预测算法。同时, 预测算法对突发流量的跟踪和预测性能明显优于对比算法, 且有更好的区间估计性能。

关键词: FARIMA; GARCH; CUSUM; 流量预测

中图分类号: TP393

文献标识码: A

文章编号: 1000-436X(2013)03-0023-09

Network traffic prediction based on FARIMA-GARCH model

YANG Shuang-mao^{1,2}, GUO Wei², TANG Wei²

(1. Science and Technology on Electronic Information Control Laboratory, Chengdu 610036, China;

2. National Key Laboratory of Science and Technology on Communications, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: The volatility and self-similarity features of network traffic poses great challenge to network traffic prediction. For this purpose, a novel network traffic prediction scheme based on FARIMA-GARCH model was formulated. A novel method was used to get a zero-mean traffic series by a piecewise two-way CUSUM detection algorithm. Then the fraction difference order was evaluated with precision by the presented bounded search method. After obtaining the model parameters, the prediction algorithm was conducted by using FARIMA-GARCH model. Compared with the traditional method, the limited search method reduces the evaluated error despite a slight computational cost. Then simulation was carried out to verify the accuracy of proposed algorithm with real network traffic. The proposed prediction method keeps the same time complexity with the FARIMA model prediction method, and the simulation result shows that the root mean-square error and relative root mean-square error, which closely resemble the RBF prediction method, is less than FARIMA model prediction method. And the interval estimation and volatility prediction performance is excellent.

Key words: FARIMA; GARCH; CUSUM; traffic prediction

1 引言

网络业务的流量特性是进行网络协议设计、性能评估、资源管理和设备研究所必须考虑的重要因素, 目前已经有大量文献对此做出了研究。早期对

网络业务的流量特性的研究以泊松模型为主。然而, 通过对真实网络流量的深入分析发现数据交换网络的流量特征不能通过泊松模型描述^[1]。特别是文献[2~4]通过对局域网和广域网的流量特性进行了实际测量与分析, 发现了网络流量具有自相似

收稿日期: 2011-12-13; 修回日期: 2013-01-07

基金项目: 国家自然科学基金资助项目(61271168, 61001085); 国家科技重大专项基金资助项目(2010ZX03005-002); 国家重点基础研究发展计划(“973”计划)基金资助项目(2009CB320405)

Foundation Items: The National Natural Science Foundation of China (6127 168, 61001085); The National Science and Technology Major Project of the Ministry of Science and Technology of China (2010ZX03005-002); The National Basic Research Program of China (973 Program) (2009CB320405)

(self-similarity)和长相关性(long-range dependence)。因此,传统的描述短相关性(short-range dependence)的泊松过程、Markov 过程、AR(autoregressive)、MA(moving average)、ARMA(autoregressive moving average)和 ARIMA(autoregressive integrated moving average)过程等已不适合于描述 LRD 业务流。同时,长相关模型又缺乏刻画业务短相关性的能力,因此必须采用能同时描述 LRD 和 SRD 的数学模型。当前网络流量的建模和预测主要集中于采用时间序列模型的算法^[5]、小波模型^[6~8]以及神经网络模型^[9~16]等。

经典的 ARMA 模型的预测算法^[17]具有较低复杂度,但是不适合于描述 LRD 业务流;基于分数自回归求和滑动平均(FARIMA, fractional autoregressive integrated moving average)模型的预测算法^[18]相对于文献[17]提高了预测精度,但是对于网络业务的剧烈波动性也不太适应。文献[6~8]把小波分析和时间序列模型结合起来,通过时间序列模型预测小波的细节分量或者预测重构后单支分量,再进行总体流量重构,但没有给出如何进行长期预测和区间预测的方法。

基于神经网络的预测模型可以对非线性的序列进行预测,能较好地描述网络流量的不稳定性,但训练复杂度和计算复杂度都较高。BP(back propagation)神经网络采用全局逼近,其训练时间偏长,因此其应用受到限制;而径向基(RBF, radial basis function)神经网络采用局部逼近训练算法,能够以任意精度逼近任意连续函数。文献[15]把 RBF 神经网络应用到网络业务预测算法中,文献[16]用 RBF 神经网络对流量的小波细节分量进行预测,再将

流量进行重构,但是没有考虑业务的长相关性,同时也没有给出如何确定神经网络的嵌入维数和延迟时间。这 2 个参数将在很大程度上决定预测算法的精度^[19],然而目前还没有普适的方法进行确定^[19,20]。

经典的基于 FARIMA 模型的预测算法^[18]分为序列零均值化、分数差分阶数估计、序列建模和预测 3 个关键步骤。其序列零均值化采用了整体去均值法,但是该法无法降低序列的波动性;而采用传统的估计算法^[5]得到的分数差分阶数依然不够精确。同时, FARIMA 模型本身不能对序列的波动性进行有效跟踪。作者在前期研究中提出了一种基于 FARIMA 改进的预测算法^[21],而本文将作进一步扩充,提出一种基于广义自回归条件异方差(FARIMA-GARCH, generalized autoregressive conditional heteroscedasticity)模型的网络业务预测算法。

本文所提算法流程如图 1 所示。首先,提出一种分段双向 CUSUM 检测算法将序列零均值化,以此减小序列的波动性;然后针对分数差分阶数的精确估计提出了一种限定搜索法;接着对序列进行 FARIMA-GARCH 建模;最后进行流量预测和区间估计。

2 基于 FARIMA-GARCH 模型的预测算法

2.1 FARIMA-GARCH 模型

时间序列中的 FARIMA(p, d, q)-GARCH(r, s)模型^[22]是将 FARIMA 与 GARCH 相结合,能同时描述网络业务的长相关性、短相关性和波动性的离散时间序列模型。令 X_t 表示业务的时间序列,则该模型可以表示为

$$F(B)\nabla^d X_t = Q(B)a_t \tag{1}$$

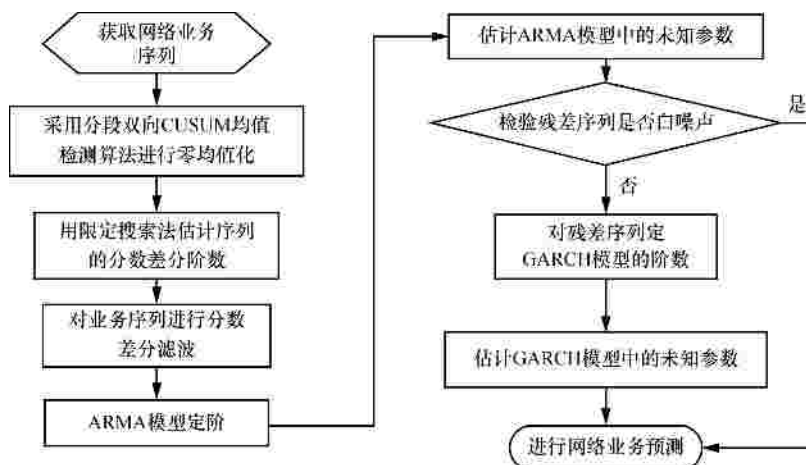


图 1 网络业务建模预测流程

$$a_t = s_t v_t \quad (2)$$

$$W(B)s_t^2 = a_0 + A(B)a_t^2 \quad (3)$$

其中， B 是时延算子，即 $BX_t = X_{t-1}$ 。分数差分阶数 $d \in (-0.5, 0.5)$ ， ∇^d 为分数差分算子。 $F(B)$ 、 $Q(B)$ 、 $W(B)$ 和 $A(B)$ 为复变量多项式^[18,22]。非负整数 p 和 q 是 FARIMA 模型的自回归阶数和滑动平均阶数， $\{a_t\}$ 表示业务序列 X_t 的残差序列， s_t^2 表示条件方差，非负整数 r 和 s 表示 GARCH 模型的阶数， $\{v_t\}$ 为零均值且方差为 1 的高斯白噪声。

当 $d = 0$ 时， X_t 退化成 ARMA(p, q)，只呈现出短相关性。所以，本文将在精确估计出分数差分阶数 d 后，通过分数差分来消弱序列中的长相关性，以利用经典的时间序列理论进行参数估计。

2.2 分段双向 CUSUM 均值检测算法

式(2)中要求输入的序列必须是零均值平稳序列，实际的用户业务序列往往不满足零均值的要求。传统的去均值的方法是整体去均值法^[18]，但是该法不能减小序列的方差；而分段去均值法能够得到更小的方差。因此，本文采用分段去均值法对序列进行零均值化，且有定理 1 成立。

定理 1 分段去均值法获得的方差不大于整体去均值法。

证明 设序列 $\{y_i\} : y_1, y_2, \dots, y_v, y_{v+1}, y_{v+2}, \dots, y_L$ 是具有均值变化点的时间序列，其均值为 m_3 ，其中，时间点 v 为变点；设序列 y_1, y_2, \dots, y_v 满足均值为 m_1 ，方差为 s_1^2 ，长度为 v ；后半部分序列 $y_{v+1}, y_{v+2}, \dots, y_L$ 满足均值为 m_2 ，方差为 s_2^2 ，长度为 $L-v$ ，且有 $m_1 \neq m_2$ 。按照分段去均值法去均值后，得到时间序列 $\{g_i\}$ ；按照整体去均值法，得到 $\{p_i\}$ ，表示为

$$\{g_i\} : g_i = \begin{cases} y_i - m_1, & i = 1, 2, \dots, v \\ y_i - m_2, & i = v + 1, v + 2, \dots, L \end{cases}$$

$$\{p_i\} : p_i = y_i - m_3, i = 1, 2, \dots, L$$

于是，得到 $\{g_i\}$ 的方差 $D(g_i)$ 为

$$D(g_i) = \frac{1}{L} v s_1^2 + (L-v) s_2^2$$

$\{p_i\}$ 的方差 $D(p_i)$ 为

$$D(p_i) = \frac{1}{L} (v s_1^2 + v(m_1 - m_3)^2 +$$

$$(L-v) s_2^2 + (L-v)(m_2 - m_3)^2)$$

又由条件 $m_1 \neq m_2$ ，可得 $D(p_i) > D(g_i)$ 。

由于网络业务呈现出波动率聚类特性，即在较大幅度波动后面伴随着较大幅度的波动，在较小波动幅度后面紧接着较小幅度的波动。为了更好地检测序列均值的变化和在建模时平滑业务序列的波动性，本文提出一种分段双向 CUSUM(cumulative sum)均值检测算法。图 2 是均值检测算法的窗口移动示意，检测窗口中包含 L 个业务序列样本值。图 2(a)是窗口未检测出序列均值的变化示意，此时窗口右移一个样本点，然后继续检测新窗口中的样本。图 2(b)在窗口中检测到时间点为 t_c 的均值变化点，此时窗口右移 $C-1$ 个样本点再继续检测。




图 2 均值检测数据窗口示意

给定检测门限 eh 、序列的期望修正值 d 、窗口起始值和长度 L 。记当前窗口起始时刻为 t_1 ，向上变化决策函数为 ZU_t ，向下变化决策函数为 ZD_t

$$ZU_t(k) = (ZU_t(k-1) + X_t(k) - d)^+, k = t_1, t_2, \dots, t_L$$

$$ZD_t(k) = (ZD_t(k-1) + X_t(k) - d)^-, k = t_1, t_2, \dots, t_L$$

其中， Y^+ 运算含义是：当 $Y > 0$ 时， $Y^+ = Y$ ；当 $Y = 0$ 时， $Y^+ = 0$ 。 Y^- 运算含义是：当 $Y < 0$ 时， $Y^- = Y$ ；当 $Y > 0$ 时， $Y^- = 0$ 。于是，分段双向 CUSUM 均值检测算法步骤可由图 3 的伪代码表示。

```

Init: ZU_t(k) ← 0;
      ZD_t(k) ← 0;
for k = t_1 to t_L
  {if ZU_t(k) ≤ eh
   {t_D ← 0;}
   else {t_U ← k;
         break;}}
for k = t_1 to t_L
  {if ZD_t(k) ≥ -eh
   {t_D ← 0;}
   else {t_U ← k;
         break;}}

if t_U = t_D = 0
  {X_k ← X_k - 1/L ∑_{j=t}^{t+L-1} X_j;}
  t_i ← t_i + 1;
  goto Init;
if t_U ≠ 0 and t_D = 0
  {t_C ← t_U; }
  elseif t_U = 0 and t_D ≠ 0
  {t_C ← t_D; }
  elseif t_U ≠ 0 and t_D ≠ 0
  {t_C ← max(t_U, t_D); }
for k = t_i to t_{i+C-1}
  {X_k ← X_k - 1/(C-1) ∑_{j=t}^{t+C-1} X_j;}
  t_i ← t_C;
  goto Init;
    
```

图 3 分段双向 CUSUM 算法伪代码

由于 CUSUM 检测算法假设序列的均值为负，而本算法的目标检测序列在实际物理系统中都是非负序列，因此需要修正值 d 来改造时间序列，取为 $E(X_t)$ 。而检测门限值 eh 采用 3 倍标准差法，即 $eh = 3 \times std(X_t)$ 。期望修正值 d 、检测门限值 eh 和窗口长度 L 可以根据当前业务特征、精度和灵敏度要求在实际运用中灵活调整。

2.3 限定搜索法

为了获得流量的分数差分阶数 d ，可以通过估计序列的 Hurst 指数，再由关系式 $H = 0.5 + d$ 得到。经典的 Hurst 指数估计方法^[5,23~27]的时间复杂度不尽相同，但对实际的复杂网络流量，这些方法的准确度都不高。由于 Hurst 指数描述了序列整体平均的自相似特性，而这种整体的特性不一定适用于具有时变性的复杂网络流量，因此对真实流量序列进行估计时上述方法都存在误差，采用不同方法对同一序列获得的 Hurst 指数也有所不同^[28]。因此，本文将计算复杂度比较低的 A-V 小波法^[26]和搜索法相结合，提出一种限定搜索法对 d 进行精确估计。

如图 4 所示，限定搜索法先使用 A-V 小波法估计出分数差分阶数 d 的粗估计 \hat{d} ，然后在 \hat{d} 的邻域内按照一定的规律遍历，用 \hat{d} 对序列进行分数差分滤波，计算滤波后序列的自相关函数的平方和^[29]。将平方和达到最小的 \hat{d} 作为分数差分参数 d 。




图 4 限定搜索法

对流量序列 X_t 进行分数差分滤波后获得长度为 N 的序列 W_t ，即 $W_t = \nabla^d X_t$ 。设 W_t 的 K 点协方差函数估计量 $\hat{g}(k)$ ，归一化自相关函数估计量 $\hat{r}(k)$ 和自相关函数序列的平方和 M 用如下公式计算

$$\hat{g}(k) = \frac{1}{N} \sum_{j=1}^{N-k} W_j W_{j+k}, k = 0, 1, 2, \dots, K \quad (4)$$

$$\hat{r}(k) = \hat{g}(k) / \hat{g}(0), k = 0, 1, 2, \dots, K \quad (5)$$

$$M = \sum_{j=1}^K \hat{r}^2(j) \quad (6)$$

给定 d 的邻域大小 ed 、 M 的精度 ef ，搜索步长 $step$ 取为 $ed / 2$ 。用 A-V 小波分析法估计当前序列的粗估计值 \hat{d} ，则当前搜索点 d_c 取为 $\hat{d} - ed$ 。于是，限定搜索法的步骤可图 5 的伪代码所表示。

```

First: compute  $M_1(d_c)$  and  $M_2(d_c + step)$ 
if  $|M_1 - M_2| \geq ef$  and  $M_1 > M_2$ 
  {  $d_c \leftarrow d_c + step$ ;
  goto First; }
elseif  $|M_1 - M_2| \geq ef$  and  $M_1 \leq M_2$ 
  {  $step \leftarrow -step / 2$ ;
  goto First; }
else {  $d \leftarrow d_c$ ;
return; }

```

图 5 限定搜索法伪代码

其中， $M(d_c)$ 表示对序列 X_t 进行分数差分滤波后，再用式(4)~式(6)获得滤波后序列的平方和 M 。

对于精度 K ，可以根据序列的自相关函数估计量是否显著趋于 0 决定。精度需求 ed 和 ef 可以根据数据量和最终精度要求在实际运用中灵活调整。

2.4 模型参数估计和检验

如图 1 所示，在前面的 2 个步骤之后，需要进行模型的参数估计和检验，主要包括模型定阶、估计参数和拟合检验 3 个步骤。本文采用了时间序列中的经典方法^[30,31]进行处理。

2.5 业务序列预测算法

基于上述分析，提出如下算法实现图 1 的流程。

- 1) 对给定业务流依 2.2 节中分段双向 CUSUM 均值检测算法进行去均值，得到零均值序列 X_t 。
 - 2) 采用 2.3 节中限定搜索法得到序列 X_t 的分数差分阶数 d 。
 - 3) 对 X_t 进行分数差分滤波，得到 ARMA 序列 W_t 。
 - 4) 利用 AIC(akaike information criterion)准则^[32,33]对序列 W_t 定阶。
 - 5) 得到序列 W_t 的参数组，利用式(1)迭代获得残差序列 $\{a_t\}$ 。
 - 6) 检测 $\{a_t\}$ 是否为白噪声，如果是，则建模算法停止，转入步骤 9)；否则，则进入下一步骤。
 - 7) 利用 AIC 准则对 $\{a_t\}$ 进行 GARCH(r,s)定阶。
 - 8) 估计得到 GARCH(r,s)模型的参数组，利用式(3)迭代计算出异方差序列 $\{s_t^2\}$ 。
 - 9) 进行业务序列的预报。
- 为了减小预测误差，需要对预测值进行均值补偿。设从时间点 t 后的 W_t 的 1 步预测值 $\hat{W}_t(1)$ 为

表 1 不同方法对自相似序列 Hurst 指数估计结果

H	方差法	R/S 分析法	A-V 小波法	自适应法	限定搜索法
0.55	0.548 5(0.56s)	0.499 7(56.66s)	0.547 0(0.16s)	0.550 2(0.27s)	0.549 4(4.25s)
0.60	0.572 0(0.48s)	0.544 1(58.88s)	0.590 4(0.10s)	0.594 1(0.25s)	0.600 5(5.17s)
0.70	0.708 0(0.52s)	0.693 2(57.17s)	0.689 3(0.07s)	0.694 6(0.25s)	0.699 9(4.74s)
0.80	0.720 2(0.53s)	0.757 9(57.77s)	0.790 2(0.11s)	0.794 2(0.20s)	0.799 6(4.72s)
0.85	0.839 9(0.53s)	0.856 3(58.03s)	0.864 6(0.09s)	0.854 3(0.20s)	0.849 5(5.25s)
0.90	0.858 7(0.52s)	0.914 6(56.75s)	0.926 8(0.11s)	0.913 1(0.26s)	0.900 3(5.66s)
0.95	0.885 9(0.49s)	0.923 5(57.36s)	0.931 9(0.09s)	0.943 3(0.234s)	0.950 8(4.23s)

$$\hat{W}_t(1) = E(W_t) = F_1 W_t + F_2 W_{t-1} + L + F_p W_{t-p+1} - \sum_{q=1}^p a_{t-q+1}$$

利用 2.2 节中的方法，对时刻 $t-L+1 \rightarrow t$ 的长度为 L 的序列进行均值检测，如果没有检测到变点，则按照式(7)获得序列 X_t 的单步预测值 $\hat{X}_t(1)$ ，若检测到变点为 t_c ，则按照式(8)获得序列 X_t 的单步预测值 $\hat{X}_t(1)$

$$\hat{X}_t(1) = \hat{W}_t(1) + \sum_{j=t-L+1}^t X_j / L - \sum_{k=1}^{\infty} g(k) X_{t+1-k} \quad (7)$$

$$\hat{X}_t(1) = \hat{W}_t(1) + \sum_{j=t_c}^t X_j / (t - t_c + 1) - \sum_{k=1}^{\infty} g(k) X_{t+1-k} \quad (8)$$

此时，单步预测的误差为 $X_{t+1} - \hat{X}_t(1) = a_{t+1}$ ，而误差的方差为 $E(X_{t+1} - \hat{X}_t(1))^2 = E(s_{t+1}^2)$ 。在给定置信度 0.95 的条件下，由于序列 $\{v_t\}$ 是满足独立同分布的标准正态过程，则预报误差将不超过区间 $1.96s_t$ 。同理可以得到序列 X_t 的 h 步预测值 $\hat{X}_t(h)$ 。

3 预测算法的性能分析

3.1 算法的复杂度分析

假定业务序列 X_t 的长度为 N ，预测过程的时间复杂度分析如下。在限定搜索法中需要 $O(N)$ 次运算获得 d 的粗估计值 \hat{d} ，而精估计至少需要 $O(-\log(ef)KN)$ 次运算，相比较于 K ， $-\log(ef)$ 很小，因此认为限定搜索法的运算次数为 $O(KN)$ 。

其他步骤的运算时间和传统的 FARIMA 算法相当，需要 $O(N^2)$ 次运算来进行模型定阶和参数估计。由于 K 相较于 N 通常较小，因此整个预测算法并没有显著地增加运算的耗时。

3.2 实验分析

为了在统一的评价体系下评估限定搜索法，采用 Hosking^[34,35]法生成若干不同 Hurst 指数的数据序

列，用来检测算法的性能。选择方差法、R/S 分析法、A-V 小波法以及自适应法^[27]进行比较。数据序列都采用 4 096 点，运行 20 次取平均值。

表 1 给出了对自相似业务序列进行 Hurst 指数估计的结果，同时还给出了相应算法在仿真平台上的耗时。当 Hurst 指数较小时，5 种方法估计结果的精度相差不大；当 Hurst 指数较大时，方差法和 R/S 分析法的精度较差，误差达到了 10%，对后续建模算法的准确度影响较大。R/S 分析法耗时最高，是 A-V 小波法耗时的数百倍，这与 R/S 分析法具有所有算法中最高时间复杂度 $O(N^2)$ 相应。

虽然小波法和自适应法耗时最短，估计误差在 3%~5% 左右，但经常出现无法有效而准确地确定最优尺度区间的现象。在面临不同实际业务流时，2 种算法都没有给出最优尺度区间的选择方法。

限定搜索法建立在小波法和检测序列自相关函数平方和的基础上，估计误差大致为 1‰，时间复杂度为 $O(KN)$ 。该算法在增加少量计算开销的代价下，提供了更优的性能，能够提高后续建模精度。

采用均方根误差(RMSE, root mean-square error)和相对均方根误差(RRMSE, relative root mean-square error)来衡量预测的效果，定义如下。

$$RMSE := \sqrt{\frac{1}{N} \sum_{t=1}^N (X_t - \hat{X}_t)^2}$$

$$RRMSE := \sqrt{\frac{1}{N} \sum_{t=1}^N \left(\frac{X_t - \hat{X}_t}{X_t}\right)^2}$$

使用 GARCH 模型对 $\{a_t\}$ 建模的目的是提高区间预报的准确性，因此需要定义一个统计量来描述区间预报的准确度。可以依序列观测值是否落入当前观测值预测区间获得一个 1-0 值的命中序列 $\{h_t\}$ 。设检测的总次数是 T ，记某个序列观测值

$X_i(k)$ 的 95% 的置信区间是 $D_i(k)$, 有

$$h_i(k) = \begin{cases} 1, & X_i(k) \in D_i(k) \\ 0, & X_i(k) \notin D_i(k) \end{cases} \quad k=1,2,3,\dots,T$$

其中, 置信区间针对不同模型具有不同的表达式。定义区间预测准确度(IFA, interval forecasting accuracy) 为

$$IFA := \frac{1}{T} \sum_{k=1}^T h_i(k)$$

仿真实验中采用来自 ACM SIGCOMM'04 会议的真实网络流^[35]。用 sig04_ver01(如表 2 所示)代表从 SIGCOMM'04 数据流中随机选出的 10 000 个连续的分组到达时间戳。类似地, sig04_ver02 和 sig04_ver03 分别代表了另外 2 组分组到达时间戳。

表 2 仿真业务参数

业务流名称	H 指数	均值	方差
sig04_ver01(10ms)	0.649 2	0.665 1	2.183 4
sig04_ver01(100ms)	0.831 5	6.648 9	31.069 0
sig04_ver02(10ms)	0.717 2	2.034 6	10.545 8
sig04_ver02(100ms)	0.837 5	20.325 2	206.875 7
sig04_ver03(10ms)	0.758 5	1.681 0	8.545 8
sig04_ver03(100ms)	0.853 9	16.806 7	187.432 3

为了考察大时间尺度和小时间尺度下预测算法的性能, 将这 3 组数据按照 10ms(小时间尺度)和 100ms(大时间尺度)的尺度进行聚合, 聚合后的序列样本值代表当前时间尺度内到达的分组个数, 得到表 2 中的 6 条业务序列。然后将业务序列分为前后 2 部分, 前部占总长的 80%, 用于模型辨识和参数估计, 最后用建立好的模型对未来值进行预测, 将预测值和后部的真实值进行比较和分析。

在 RBF 预测算法的仿真中, 由于无法确定时间序列的最佳嵌入维数和延迟时间^[19,20], 因此延迟时间取 1。嵌入维数采用多次训练的方法来确定, 将预测效果最好的神经网络作为 RBF 算法预测网络, 同时限制最大神经元个数是 1 500。

表 3~表 5 分别对比了在小时间尺度下几种算法的预测性能。其中, RMSE 越小说明预测值偏离真实值的幅度越小, 预测精度越高。从结果看出, 本文算法的 RMSE 在单步预测的条件下小于 FARIMA 预测算法, 和 RBF 算法基本相当, 在预测步数明显增加的情况下, 本文算法明显占优。

RRMSE 是归一化的 RMSE 指标, 衡量了预测值与真实值之间归一化的偏离程度。从结果看出,

本文算法的 RRMSE 在单步预测条件下是最优的。在预测步数增加时, 本文算法和 RBF 算法的小幅增加, 而 FARIMA 算法的 RRMSE 快速增加到不合理的状态, 例如表 5 中 FARIMA 算法的 RRMSE 快速增加到 7, 此时预测值的误差已经大致相当于真实值的 7 倍左右, 预测性能已经很不可靠。

表 3 小时间尺度下预测业务流 sig04_ver01 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	1.628 6	5.314 2	7.704 5	9.476 0
RMSE(RBF)	1.998 8	1.980 6	1.958	2.999 6
RMSE(FARIMA-GARCH)	1.568 5	1.874 9	2.757 3	3.302 7
RRMSE(FARIMA)	1.101 3	3.565 7	5.479 1	6.536 1
RRMSE(RBF)	1.062 32	1.573 8	1.804	2.106 3
RRMSE(FARIMA-GARCH)	1.026	2.646 8	4.337 4	5.272 5
IFA(FARIMA)	95.51%	73.90%	55.92%	48.30%
IFA(FARIMA-GARCH)	96.61%	90.59%	80.92%	75.23%

表 4 小时间尺度下预测业务流 sig04_ver02 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	1.791 1	2.630 8	2.865 7	2.879 3
RMSE(RBF)	2.357 5	2.365 7	2.349 8	2.315 8
RMSE(FARIMA-GARCH)	1.702 4	1.753 6	1.960 8	2.285 1
RRMSE(FARIMA)	1.472 8	2.525 7	2.857 5	2.879 6
RRMSE(RBF)	1.031 1	1.119 4	1.306 8	1.295 7
RRMSE(FARIMA-GARCH)	1.114 7	1.400 0	1.697 2	2.569 8
IFA(FARIMA)	95.22%	91.96%	89.93%	84.13%
IFA(FARIMA-GARCH)	97.96%	96.44%	95.73%	95.52%

表 5 小时间尺度下预测业务流 sig04_ver03 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	3.606 4	5.355 3	8.852 6	9.157 4
RMSE(RBF)	5.057 7	5.033 6	4.901 7	4.858 5
RMSE(FARIMA-GARCH)	3.399 4	4.124 1	4.276 9	4.438 0
RRMSE(FARIMA)	1.664 3	4.207 4	7.152 2	7.839 3
RRMSE(RBF)	1.301 0	1.480 1	1.874 8	1.915 3
RRMSE(FARIMA-GARCH)	0.941 1	2.148 2	2.256 5	2.821 9
IFA(FARIMA)	85.73%	67.93%	55.08%	52.56%
IFA(FARIMA-GARCH)	92.53%	91.18%	90.01%	87.15%

IFA 指标衡量了预测算法的区间估计性能, 由于 RBF 算法没有实现区间估计的方式, 因此只对比了 FARIMA 算法。在仿真中采用置信度为

95% 的置信区间，因此平均来看，IFA 不应小于 95%。但从结果来看，当预测步数大于 1 步的时候，FARIMA 算法的 IFA 下降到 50% ~ 60% 左右，这说明一半以上的真实值落在了预测区间的外面，预测性能较差。而由于 GARCH 模型能比较精确和快速地跟踪方差变化，根据历史值来调整预测区间的大小，使得真实值落入预测区间的概率大大提高，IFA 都在 75% 以上。在表 4 中，IFA 基本稳定在 95% 左右。

表 6~表 8 分别对比了在大时间尺度下几种预测算法的性能。由于大时间尺度下时间序列的突发性要相对小一些，3 种算法的性能都相对小时间尺度下有所提高，说明预测大时间尺度网络流量要比预测小时间尺度的网络流量更加可靠和可实现。例如大时间尺度下的 IFA，对比表 3 和表 6，表 4 和表 7、表 5 和表 8，同样条件下 IFA 的性能优于小时间尺度，这说明大时间尺度下的业务流由于方差更大，方差波动程度也更剧烈，GARCH 模型能有效捕捉到这种波动性，因此根据 GARCH 估计出的区间能够以更高的概率覆盖真实值，达到较好的预测性能。

表 6 大时间尺度下预测业务流 sig04_ver01 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	7.706 1	8.410 8	10.471 9	11.411 4
RMSE(RBF)	9.597 6	10.352 5	10.323 7	10.633 8
RMSE(FARIMA-GARCH)	4.792 0	8.238 2	9.914 0	10.413 5
RRMSE(FARIMA)	0.863 6	1.226 4	1.493 5	1.552 4
RRMSE(RBF)	1.803 0	1.965 9	1.925 7	2.005 2
RRMSE(FARIMA-GARCH)	0.697 3	0.949 8	1.139 4	1.389 2
IFA(FARIMA)	92.72%	75.83%	68.94%	62.65%
IFA(FARIMA-GARCH)	93.38%	91.72%	90.07%	87.09%

表 7 大时间尺度下预测业务流 sig04_ver02 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	8.895 8	15.014 6	14.132 2	16.493 7
RMSE(RBF)	12.498 8	12.112 9	12.481 3	11.002 8
RMSE(FARIMA-GARCH)	2.546 4	3.488 1	4.554 8	9.192 1
RRMSE(FARIMA)	0.718 9	1.806 7	1.684 4	2.205 4
RRMSE(RBF)	0.567 8	0.541 0	0.811 0	0.965 5
RRMSE(FARIMA-GARCH)	0.284 8	0.618 0	1.136 2	1.205 3
IFA(FARIMA)	99.15%	88.90%	90.18%	80.56%
IFA(FARIMA-GARCH)	99.24%	96.13%	96.50%	96.20%

表 8 大时间尺度下预测业务流 sig04_ver03 的性能评价

预测算法及其评价指标	单步预测	5 步预测	15 步预测	25 步预测
RMSE(FARIMA)	17.833 7	24.817 0	26.780 0	25.904 8
RMSE(RBF)	19.589 5	19.777 35	20.069 6	19.808 6
RMSE(FARIMA-GARCH)	16.102 7	21.031 8	24.646 7	23.620 8
RRMSE(FARIMA)	0.667 6	0.917 8	1.020 4	0.996 7
RRMSE(RBF)	0.774 4	0.949 2	0.971 2	0.965 5
RRMSE(FARIMA-GARCH)	0.473 1	0.739 2	0.970 6	0.936 4
IFA(FARIMA)	76.47%	68.91%	61.50%	52.94%
IFA(FARIMA-GARCH)	89.08%	75.63%	60.50%	63.87%

同时从仿真结果中看出，随着预测步数的增加，RMSE 和 RRMSE 都出现增加。本文算法增加的趋势要平滑一些，而 FARIMA 算法增加幅度在有些业务流上则快速和明显。而随着步数的增加，IFA 在有些业务流上也出现比较明显的大幅下滑，说明该流量序列是一个随机性和突发性都特别强的时间序列，不太可能进行长期地精确预报，因此在做出短期预报后，需要及时根据后续真实值修正模型，再继续预报。仿真结果表明，单步预测的性能是比较可靠和精确的。

图 6 是业务流 sig04_ver02 在小时间尺度下的一段预测结果，采用单步预测。小时间尺度上网络流量具有很强的突发性，单峰式的流量暴增点随处可见。FARIMA 模型采用同方差假定，不能有效跟踪这种突发性的流量增加点。因此在这些流量突发处，FARIMA 模型预测值与真实值差距较大。而 RBF 算法同样不能有效预测这些突发点，更多是跟踪序列均值的变化。本文算法能先平滑序列波动，再使用 GARCH 跟踪序列的波动性，使得这些突发点处的预测值比较接近真实值，预测效果较好。

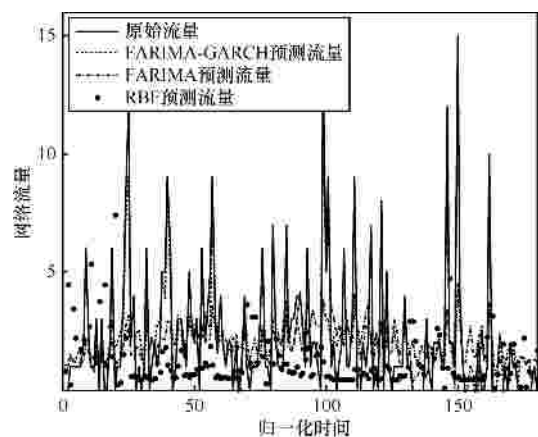


图 6 小时间尺度流量预测仿真结果

图 7 是业务流 sig04_ver01 在大时间尺度下的一段预测结果。由于时间尺度的加大,在一定程度上平滑了序列的突发性,因此流量暴增点的个数明显减少,但是依然存在个别单峰式突发点。从仿真结果看出,在流量比较平稳的阶段,3 种算法预测结果都能有效地逼近真实值。不过与图 6 类似,在单峰式突发点, FARIMA 模型发现了流量突发,而不能较准确地捕捉到突发点的流量, RBF 算法只能预测到序列均值附近,而基于 FARIMA-GARCH 的预测算法明显更能有效预测突发点的流量。

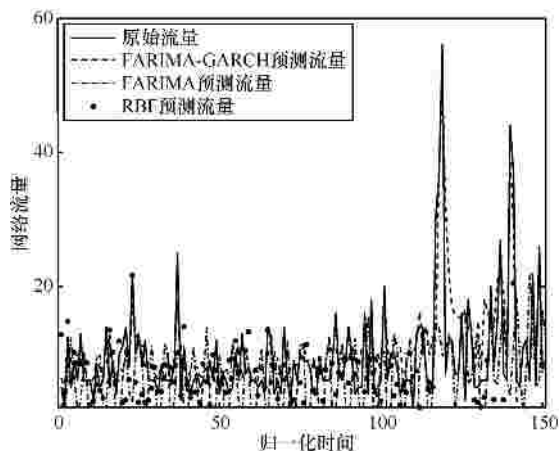


图 7 大时间尺度流量预测仿真结果

4 结束语

本文首先对流量预测中的 2 个关键步骤进行改进,即提出了分段双向 CUSUM 检测算法和限定搜索法,然后在此基础上提出一种基于 FARIMA-GARCH 模型的网络业务预测算法。

仿真实验验证了限定搜索法的性能,在 Hurst 指数较大情况下,其精度高于方差法和 R/S 分析法。虽然比 A-V 小波法增加了少量的计算量,但是估计误差也相应减小,并且该算法的时间复杂度依然维持在 $O(KN)$,该复杂度与 A-V 小波法基本相当。

接着采用真实网络的业务流量对基于 FARIMA-GARCH 预测算法进行了仿真验证。本文算法的 RMSE 和 RRMSE 与 RBF 算法基本相当,而优于传统的 FARIMA 预测算法。同时对突发点的跟踪和预测能力明显优于对比算法,其区间估计的性能也较传统的 FARIMA 预测算法要好。本文算法在保持与 FARIMA 预测算法基本等价的运算时间复杂度下,提供了更好的均值和区间估计性能,可以方便地应用于网络流量预测、接入控制、带宽预留和分配以

及负载均衡等场合。

参考文献:

- [1] PAXSON V, FLOYD S. Wide-area traffic: the failure of poisson modeling[J]. IEEE/ACM Transactions on Networking, 1995, 3(3):226-244.
- [2] LELAND W E, WILLINGER W, TAQQU M S, *et al.* On the self-similar nature of ethernet traffic[J]. Computer Communication Review, 1995, 25(1):202-213.
- [3] LELAND W E, WILLINGER W, TAQQU M S, *et al.* On the self-similar nature of ethernet traffic(extended version)[J]. IEEE/ACM Transactions on Networking, 1994, 2(1):1-15.
- [4] WILLINGER W. Self-similarity in wide-area network traffic[A]. Lasers and Electro-Optics Society Annual Meeting[C]. San Francisco, USA, 1997.462-463.
- [5] HAMILTON J D. Time-Series Analysis[M]. New Jersey: Princeton University Press, 1994.
- [6] 王西锋, 高岭, 张晓李. 基于小波技术的网络流量分析和预测[J]. 计算机应用与软件, 2008, 25(8):70-72.
WANG X F, GAO L, ZHANG X L. A network traffic analysis and forecast based on wavelet technology[J]. Computer Applications and Software, 2008, 25(8):70-72.
- [7] 白翔宇, 叶新铭, 蒋海. 基于小波变换与自回归模型的网络流量预测[J]. 计算机科学, 2007, 34(7):47-49.
BAI X Y, YE X M, JIANG H. Network traffic predicting based on wavelet transform and autoregressive model[J]. Computer Science, 2007, 34(7):47-49.
- [8] 陈晓天, 刘静娴. 改进的基于小波变换和 FARIMA 模型的网络流量预测算法[J]. 通信学报, 2011, 32(4):153-157.
CHEN X T, LIU J X. Network traffic prediction based on wavelet transformation and FARIMA[J]. Journal on Communications, 2011, 32(4):153-157.
- [9] TARRAF A, HABIB W, AHMED A. ATM multimedia traffic prediction using neural networks[A]. Global Data Networking Proceedings[C]. Cairo, Egypt, 1993.77-84.
- [10] WANG F, XIA H B. Network traffic prediction based on grey neural network integrated model[A]. International Conference Computer Science and Software Engineering[C]. Wuhan, China, 2008.915-918.
- [11] JUN L, LI T, LI X. Network traffic prediction algorithm and its practical application in real network[A]. IFIP International Conference on Network and Parallel Computing Workshops[C]. Liaoning, China, 2007.512-517.
- [12] ARDHAN S, SATSRI S, CHUTCHAVONG V, *et al.* Improved model for traffic fluctuation prediction by neural network[A]. International Conference on Control, Automation and Systems[C]. Seoul Korea, 2007.122-125.
- [13] ZHU L, QIN L, XUE K, *et al.* A novel BP neural network model for traffic prediction of next generation network[A]. Fifth International Conference on Natural Computation[C]. Tianjin, China, 2009.32-38.
- [14] LI X Y. Prediction of traffic flow base on neural network[A]. Intelligent Computation Technology and Automation[C]. Changsha, China, 2009.374-377.
- [15] 王俊松, 高志伟. 基于 RBF 神经网络的网络流量建模及预测[J]. 计算机工程与应用, 2008, 44(13):6-11.
WANG J S, GAO Z W. Network traffic modeling and prediction based on RBF neural network[J]. Computer Engineering and Applications,

- 2008,44(13):6-11.
- [16] WEN Y, YANG D Y, ZHAO Y L. Traffic flow prediction based on wavelet transform and radial basis function network[A]. International Conference on Logistics Systems and Intelligent Management[C]. Harbin, China, 2010.969-972.
- [17] 邹伯贤,刘强. 基于 ARMA 模型的网络流量预测[J].计算机研究与发展, 2002, 39(12):1645-1652.
ZOU B X, LIU Q. Arma-based traffic prediction and overload detection of network[J]. Journal of Computer Research and Development, 2002, 39(12):1645-1652.
- [18] 舒炎泰,王雷,张连芳等. 基于 FARIMA 模型的 Internet 网络业务预报[J].计算机学报,2001,24(1):46-54.
SHU Y T, WANG L, ZHANG L F, *et al.* Internet traffic modeling and prediction using FARIMA models[J]. Chinese Journal of Computers, 2001, 24(1):46-54.
- [19] 冯慧芳. IEEE 802.11 无线局域网业务流特性研究及预报[D].天津:天津大学,2006.
FENG H F. Traffic Characterization and Prediction in IEEE 802.11 WLANs[D]. Tianjin: Tianjin University,2006.
- [20] 吕金虎.混沌时间序列分析及其应用[M]. 武汉:武汉大学出版社,2002.
LV J H. Chaos Time Series Analysis and Application[M]. Wuhan: Wuhan University Press, 2002
- [21] 杨双懋,郭伟,唐伟.认知无线网络中基于时间序列预测的冲突分解算法.通信学报,2011,32(11):51-58.
YANG S M, GUO W, TANG W. A collision resolution algorithm based on time-series forecasting for cognitive wireless networks[J]. Journal on Communications, 2011,32(11):51-58.
- [22] WILFREDO P. Long-Memory Time Series : Theory and Methods[M]. Hoboken: John Wiley & Sons, 2007.
- [23] ZHANG H F, SHU Y T, YANG O. Estimation of hurst parameter by variance time plots[A]. IEEE Pacific Rim Conference on Communications, Computers and Signal Processing[C]. Victoria, Canada, 1997. 883-886.
- [24] CLEGG R G. A practical guide to measuring the hurst parameter[J]. International Journal of Simulation: Systems, Science and Technology, 2006,7(2):3-14.
- [25] LAU W C, ERRAMILI A, WANG J L, *et al.* Self-similar traffic parameter estimation: a semi-parametric periodogram-based algorithm[A]. IEEE Global Telecommunications Conference[C]. Singapore, 1995.2225-2231.
- [26] ABRY P, VEITCH D. Wavelet analysis of long range dependent traffic[J]. IEEE Transactions on Information Theory, 1998, 44(1):2-15.
- [27] 洪飞,吴志美. 基于小波的 Hurst 指数自适应估计方法[J]. 软件学报,2005,16(9):1685-1689.
HONG F; WU Z M. Adaptive hurst index estimator based on wavelet[J]. Journal of Software, 2005, 16(9):1685-1689.
- [28] WILLIAM R, LES O, MARCO R, *et al.* Estimators for long range dependence: an empirical study[J]. Electronic Journal of Statistics, 2009.1-16.
- [29] 陈彦辉,谢维信. 随机分形信号参数的分数差分估计[J].电子与信息学报,2001,23(1):9-15.
CHEN Y H, XIE W X. Fractional difference estimation for the parameters of random fractal signal[J]. Journal of Electronics and Information Technology, 2001, 23(1):9-15.
- [30] BROCKWELL P J, DAVIS R A. Time Series: Theory and Methods[M]. New York: Springer,1987.
- [31] GARCH 模型与应用简介[EB/OL]. <http://wenku.baidu.com/view/bd93f636a32d7375a41780b7.html>, 2011.
GARCH model application profile[EB/OL]. <http://wenku.baidu.com/view/bd93f636a32d7375a41780b7.html>, 2011.
- [32] AKAIKE H. A new look at the statistical model identification[J]. IEEE Transactions on Automatic Control, 1974,19(6):716-723.
- [33] SHIBATA R. Selection of the order of an autoregressive model by Akaike's information criterion[J]. Biometrika, 1976,63(1):117-126.
- [34] HOSKING J R M. Modeling persistence in hydrological time series using fractional differencing[J]. Water Resources Research, 1984, 20(12): 1898-1908.
- [35] Sigcomm 2004 trace dataset[EB/OL]. <http://www.crowdad.org/meta.php?name=uw/sigcomm2004>, 2011.

作者简介：



杨双懋(1981-),男,四川都江堰人,博士,电子信息控制重点实验室工程师,主要研究方向为认知网络和通信技术。



郭伟(1964-),男,四川达州人,电子科技大学教授、博士生导师,主要研究方向为移动通信网、信号与信息处理。



唐伟(1980-),男,四川成都人,博士,电子科技大学讲师,主要研究方向为无线多跳网路由算法。