

基于矢量空间重构的网络流量预测算法

张涛 张颖江

(湖北工业大学信息技术中心 武汉 430068)

摘要 客户机与服务器之间存在数据存储隐通道,对该通道的网络流量进行准确预测可避免网络拥堵,提高网络流量的调度和管理能力。传统方法采用线性时间序列分析方法进行网络流量预测,没有准确反映流量序列的非线性特征信息,预测精度不高。提出一种基于非线性时间序列分析和矢量空间重构的网络流量预测算法。进行相位随机化处理,使得网络流量数据离散解析化,把网络流量时间序列解析模型分解为含有多个非线性成分的统计量。采用自相关函数法求得矢量空间重构的时间延迟,采用互信息最小嵌入维算法求得网络流量序列的矢量空间嵌入维,实现流量序列的矢量空间重构。在高维矢量空间中,提取网络流量的高阶谱特征,实现网络流量的准确预测。仿真结果表明,采用该算法能有效拟合流量序列的非线性状态特征,对流量状态变化的动态跟踪性能较好,其预测误差比传统方法的低。

关键词 网络流量,预测,矢量空间重构,非线性

中图分类号 TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.7.019

Network Traffic Prediction Algorithm Based on Vector Space Reconstruction

ZHANG Tao ZHANG Ying-jiang

(Information Technology Center, Hubei University of Technology, Wuhan 430068, China)

Abstract There is a data storage covert channel between the client and the server, and the network traffic on the channel needs to be accurately predicted, which can avoid network congestion and improve network traffic scheduling and management ability. In the traditional method, the linear time series analysis method is used to predict the network traffic, which can not accurately reflect the nonlinear characteristic information, and the prediction accuracy is not high. A network traffic prediction algorithm was proposed based on nonlinear time series analysis and vector space reconstruction. The phase randomization process makes the network traffic data discrete analysis, and the network traffic time series analysis model is decomposed into the statistics of multiple nonlinear components. The self correlation function is used to obtain the vector space reconstruction time delay, and the mutual information minimum embedding dimension algorithm is used to obtain vector space embedding dimension of network flow sequence, which realizes the vector space reconstruction of flow sequence. In the high dimensional vector space, the high order spectral characteristics of the network traffic are extracted, the accurate prediction of the network traffic is realized. Simulation results show that the proposed algorithm can effectively simulate the nonlinear state characteristics of the traffic sequence, the dynamic tracking performance of the traffic state is better, and the prediction error is lower than the conventional method.

Keywords Network traffic, Prediction, Vector space reconstruction, Nonlinear

1 引言

在当今计算机网络流量高速增长和海量数据膨胀的信息化网络时代,网络流量数据出现爆炸式增长。在网络终端,用户通过数据通信和传输,终端用户在下载和上传数据信息资源的过程中,大量的信息数据在网络空间中传输从而产生流量数据,这些流量数据就是所谓的网络流量,网络流量就是网络上传输的数据量。大型网络系统中,客户机与服务器之间产生的数据流量限制在同一网段中,形成一个较大的数据存储隐通道,在这个隐通道中通常会出现网络拥堵和数据丢包,

需要对该数据存储隐通道的网络流量进行准确预测,缓解和控制网络拥堵和信息泄露,研究客户机与服务器之间数据存储隐通道的网络流量预测算法具有重要意义。

网络流量是一组非线性时间序列,可以采用非线性时间序列分析方法进行网络流量的特征分析和预测,特别是对于客户机与服务器之间数据存储隐通道的网络流量,由于该数据存储和交换区域的流量存在于连续和离散交换的信息系统之中,具有较强的非线性特征,因此传统方法采用线性时间序列分析进行网络流量预测;但由于数据存储隐通道的流量序列自相关特性较弱,传统的线性时间序列分析方法难以实现

到稿日期:2015-07-22 返修日期:2015-08-24

张涛(1979-),男,硕士,工程师,主要研究方向为计算机网络,E-mail:380412366@qq.com;张颖江(1959-),男,博士,教授,博士生导师,主要研究方向为计算机网络安全。

对网络流量特征的准确提取,预测准确度不高。

对此,相关的学者进行了算法的改进设计研究,关于网络流量预测的算法主要有 Wolf 一步预测法、时频分析算法、AR 模型估计算法、小波分析流量预测算法等^[1,2]。随着现代信号处理技术的发展,采用现代信号处理方法进行网络流量分析成为一种趋势,文献[3]基于高斯过程回归的网络流量预测模型提出一种功率谱分析的方法进行网络流量的短时预测和特征提取,通过建立 Marlov 模型,提取流量序列的功率谱密度函数,实现流量预测,但该算法只对短时流量的预测效果较好,对缓存区的流量预测准确度不高。文献[4]提出一种基于定量递归分析的校园网流量预测算法,采用递归图分析进行流量序列的相空间重建,提高了预测精度,但该算法构建的相空间维数较高,增加了计算的复杂度。文献[5]提出一种基于广域子空间降维的 Web 网络数据流量特征提取和预测算法,通过子空间分解的方法来提取流量数据的深层次特征,但该算法采用的线性分析方法无法有效利用流量序列的非线性特征,影响了预测运算的精度。对此, Benveniste^[6]提出了定量递归分析的方法来分析基站缓冲区流量序列的非线性特性。在此基础上,文献[7]提出一种基于互信息法和延迟时间窗口 C-C 估计算法的流量预测算法,对网络流量的观测时间序列进行平稳性检验,提高了流量预测的准确性;但该方法对流量时间序列中非线性成分的可靠性的提取不全面,难以保证对持续性网络流量预测的准确度。

针对传统方法出现的问题,本文提出一种基于非线性时间序列分析和矢量空间重构的网络流量预测算法。首先构建了客户机与服务器之间数据存储隐通道的网络流量时间序列分析模型;为了实现对网络流量时间序列的矢量空间重构;基于非线性时间序列分析方法采用自相关函数法求得矢量空间重构的时间延迟,采用互信息最小嵌入维算法求得网络流量序列的矢量空间嵌入维,以此为基础实现流量序列的矢量空间重构,在高维矢量空间中,提取网络流量的高阶谱特征,实现网络流量的准确预测。仿真实验对性能进行了验证,展示了本文算法在实现网络流量预测中的优越性能,得出了有效性结论。

2 问题描述及流量时间序列模型构建

2.1 客户机与服务器间的数据存储隐通道流量传输模型

为了实现对客户机与服务器间的数据存储隐通道的网络流量预测,首先构建客户机与服务器间的数据存储隐通道数据传输模型,客户机与服务器间的数据存储隐通道中承载着不同的协议和网络信道,通过云储存实现资源调度和数据通信传输。

客户机与服务器间的数据存储隐通道的流量传输协议主要包括 FDMA, CDMA, TDMA 等。数据存储隐通道的流量转发路由器主要有 3 个组件:流量信息表 FIB、内容存储 CS 和流量付费 PIT 表。网络上客户机与服务器之间产生的数据流量限制在同一网段中,形成一个较大的数据存储通道,产生大量的具有非线性特征的流量,以此进行数据通信和调度,客户机与服务器间的数据存储隐通道的网络数据传输和存储的结构模型如图 1 所示。

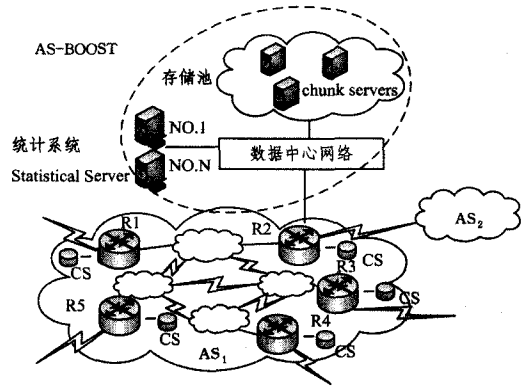


图 1 客户机与服务器间的数据存储隐通道的网络数据流量传输和存储的结构模型

分析图 1 可知,客户机中的网络流量数据信息存在非线性特性,需要对网络流量进行准确预测。假设给定数据存储隐通道的网络数据流量的单变量时间序列为 $\{x_n\}$,由于通常观测到的网络流量时间序列都是标量时间序列,必须使用某种方法来展开这个多维结构。假设数据存储隐通道的网络数据流量是由线性相关的高斯过程所产生,用以下的 ARMA 模型表示:

$$x_n = a_0 + \sum_{i=1}^{M_{AR}} a_i x_{n-i} + \sum_{j=0}^{M_{MA}} b_j \eta_{n-j} \quad (1)$$

其中, a_0 为初始网络流量的幅度值, x_{n-i} 为具有相同的均值、方差的标量时间序列, b_j 为自相关函数的替代数据。网络通信过程中,客户机的局部性交叉项信息链表示为:

$$CUB(i) = \frac{CBT(i)}{T} \times CB \quad (2)$$

其中, CB 表示网络数据传输的总比特数, i 表示采样时间点,对流量数据进行 Fourier 变换,得到 $x(k)$,定义网络流量传输的路径损耗为:

$$A(t) = mt + \sqrt{am} B^H(t) \quad (3)$$

其中, a 为流量的域间方差系数, m 为平均到达速率, $B^H(t)$ 表示的是网络流量预测相关函数。根据上述方法,构建了客户机与服务器间的数据存储隐通道流量传输模型,在此模型中进行数据传输和调度,分析网络流量预测方法。

2.2 流量时间序列模型的构建及相位随机化处理

在上述构建客户机与服务器间的数据存储隐通道流量传输模型的基础上进行流量预测分析。由于该数据存储和交换区域的流量存在于连续和离散交换的信息系统之中,具有较强的非线性特征,本文采用非线性时间序列分析的方法进行流量序列预测和分析,需要构建流量时间序列信号模型。在多个已知干扰中,为了使得网络流量离散数据离散解析化,采用相位随机化处理的方法,给出客户机与服务器间的数据存储隐通道的网络流量预测信号解析模型:

$$z(t) = x(t) + iy(t) = a(t)e^{j\theta(t)} + n(t) \quad (4)$$

式中, $x(t)$ 为流量时间序列的实部, $y(t)$ 为流量时间序列的虚部, $a(t)$ 为信号幅值, $n(t)$ 为干扰向量。采用传统的线性时间序列分析方法拟合上式系数的过程中产生的误差会导致最终迭代结果发散,进导致流量的预测精度不高。本文采用矢量空间重构方法进行相位随机化处理^[8],处理步骤描述如下:

- (1) 对网络流量时间序列进行 Fourier 变换,得到 $x(k)$;
- (2) 测量网络流量的高斯过程随机相位特征,进行相位随机化处理,得到 $x'(k)$;

(3)采用非线性检验方法检验网络流量的非线性成分,对流量序列的非线性成分 $x'(k)$ 进行 Fourier 逆变换,得到 $x'(n)$ 。

通过上述处理,实现对网络流量时间序列的离散化分析和相位随机化处理,生成的网络流量替代数据保留了原始网络流量数据的线性自相关函数^[9]。把网络流量信号的解析模型分解为含有多个非线性成分的统计量,计算网络流量时间序列的三阶自相关特征:

$$C_{\sigma^3} = \frac{\langle (x_n - \bar{x})(x_{n-d} - \bar{x})(x_{n-D} - \bar{x}) \rangle}{\langle (x_n - \bar{x})^3 \rangle} \quad (5)$$

其中, x_n 表示网络流量的非线性时间序列, d 表示传输延迟, $D=2d$, \bar{x} 表示均值, $\langle x(n) \rangle$ 代表对 $x(n)$ 取均值:

$$\langle x(n) \rangle = \frac{1}{N} \sum_{n=1}^N x(n) \quad (6)$$

进一步计算客户机与服务器间的数据存储隐通道中的干扰特征的幅度和相位信息:

$$a(t) = \sqrt{x^2(t) + y^2(t)}, \theta(t) = \arctan \frac{y(t)}{x(t)} \quad (7)$$

通过流量时间序列模型的构建及相位随机化处理,可以定量表征网络流量时间序列某个特性的特征量,为进行流量预测提供了信号模型基础。

3 矢量空间重构及网络流量预测算法改进

3.1 网络流量时间序列的矢量空间重构

分析上述信号模型的构建过程可知,客户机与服务器间的数据存储隐通道中的网络流量时间序列具有非线性特征。本文采用非线性时间序列分析方法进行流量预测算法设计,提出基于矢量空间重构和非线性特征提取的网络流量预测算法。

在非线性时间序列分析理论中,网络流量作为一种标量时间序列,本身不能呈现出动力系统的多维相空间,需要构建一个多维的矢量空间。矢量空间重构作为网络流量非线性分析的基础,基于 F. Takens 和 R. Mane 的延迟嵌入定理^[10],假设采用上述方法进行相位随机化处理后的流量序列为 $\{x_n\}$,重构的矢量空间为:

$$\mathbf{x}_n = (x_n, x_{n-\tau}, \dots, x_{n-(m-1)\tau}) \quad (8)$$

从而形成 m 维状态空间。在重构的 m 维状态空间中,网络流量的矢量状态映射为:

$$\mathbf{x}_{n+1} = F(\mathbf{x}_n) \quad (9)$$

状态空间重构的关键是选择适当的嵌入维数 m 和时间延迟 τ 。矢量状态空间中 $\mathbf{x}_n \rightarrow \mathbf{x}_{n+1}$ 的演化反映了网络流量的非线性差分维数。对时间序列进行平稳化处理,通过统计学方法来实现对网络流量的预测。对于客户机与服务器间的数据存储隐通道网络流量,网络流量的矢量特征时间序列在高维相空间中的轨迹为 $\{x(t_0 + i\Delta t)\}$, $i=0, 1, \dots, N-1$, 其矢量状态空间重构后的 d 维的紧流形矢量场为:

$$X = [s_1, s_2, \dots, s_K]_n = (x_n, x_{n-\tau}, \dots, x_{n-(m-1)\tau}) \quad (10)$$

基于非线性时间序列分析方法,用自相关函数法求取网络流量矢量空间重构的时间延迟 τ 。其基本思想是要考察观测流量的时间序列随机化分类 x 和 $x_{n+\tau}$ 与平均观测量的差之间的线性相关性,对于随机化网络流量 $x(t)$,其自相关函数 $C(\tau)$ 定义为:

$$C(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x(t)x(t+\tau) dt \quad (11)$$

其中, τ 是网络流量的矢量空间的时间延迟窗口,表征 t 和 $t+\tau$ 时刻网络流量变化这个随机过程的相互关联或相似程度。在此,固定流量的采样时间间隔 j ,绘制自相关函数关于时间 τ (取 $\tau=1, 2, \dots$) 的函数图像,得到的时间 t 就是重构矢量空间的最佳时间延迟 τ 。

在求得矢量空间重构的最佳时延 τ 的基础上,求最小嵌入维数 m ,采用互信息最小嵌入维算法求得网络流量序列的矢量空间嵌入维。网络流量时间序列的延迟时间互信息为:

$$I(\tau) = - \sum_{ij} p_{ij}(\tau) \ln \frac{p_{ij}(\tau)}{p_i p_j} \quad (12)$$

重构矢量空间中的任意一点表示为 \mathbf{X}_n ,其在网络流量高维矢量空间中的最近邻点表示为 $\mathbf{X}_{n(m)}$,建立 m 维矢量空间中形成的高维吸引子:

$$\mathbf{X}(n) = \{x(n), x(n+\tau), \dots, x(n+(m-1)\tau)\} \quad (13)$$

其中, $n=1, 2, \dots, N$,结合式(12),选取平均互信息曲线 $I(\tau)$ 的第一个最小值点来确定矢量空间重构的最小嵌入维数,按式(14)确定每个矢量轨迹 \mathbf{X}_n 的最近邻点:

$$\frac{\|\mathbf{X}_{n(m)} - \mathbf{X}_n\|_2^{m+1}}{\sqrt{\frac{1}{N} \sum_{k=1}^N [x_k - \frac{1}{N} \sum_{k=1}^N x_k]^2}} > A_{tol} \quad (14)$$

其中,文献[10]建议阈值 $A_{tol}=2$,计算出虚假最近邻点的比例,让 m 从 1 开始增加,使流量时间序列的矢量状态空间重构的吸引子的几何结构完全打开,由此实现网络流量序列的矢量空间重构。

3.2 网络流量预测的实现

在上述进行矢量空间重构的基础上,在高维矢量空间中提取网络流量的高阶谱特征,实现网络流量的准确预测。在重构的网络流量非线性时间序列的矢量空间中选择低维轨线上形成的高阶谱特征点 B_0' 与高维特征点对应,那么网络流量的初始状态特征 B_0 的邻近点映射到重构的矢量空间中,对应的点也是 B_0' 的邻近点。根据嵌入定理,当嵌入维数低于最小嵌入维数时, B_0 点的邻近点不再投影到 B_0' 的邻域,利用这种思想,构建网络流量时间序列定量递归分析坐标系,提取流量的高阶谱特征 $R^T R$,特征值之间存在大小关系,根据这组大小关系进行流量预测,对高阶谱特征 $R^T R$ 进行酉矩阵分解:

$$R^T R = [V_s, V_n] \begin{bmatrix} \Sigma_s & 0 \\ 0 & \Sigma_n \end{bmatrix} [V_s, V_n]^T \quad (15)$$

在重构的矢量空间中,网络流量高阶谱分布 $N(0, 1)$ 中产生一个初始值 x_0 ,选择一定的基函数与网络流量预测值信号进行匹配,网络流量的预测频率 f 和基底特征 d_{γ_0} 之间的匹配程度为:

$$\lambda^n(d_{\gamma_0}) = \int_{-\infty}^{+\infty} f(t) d_{\gamma_0}^*(t) dt \quad (16)$$

为了提高预测精度,对于 t 时刻到达隐通道的实际流量 t_{n+1} ,计算重构后的矢量空间中第 i 点 \mathbf{x}_i 和第 j 点 \mathbf{x}_j 的高阶谱特征函数,最后得到网络流量的预测值为:

$$x(t_{n+1})' = X_{m+1}(m) \quad (17)$$


改进的方法由于是通过矢量空间轨迹一步预测了下一个时间点的流量状态,因此通过对高阶谱这一非线性特征的提取,能实现对网络流量的一步预测。

4 仿真实验与结果分析


为了测试本文算法对客户机与服务器间的数据存储隐通

道的网络流量进行预测的性能,进行仿真实验。实验仿真环境为: IntelCore3-530 1GB 内存,操作系统为 Windows 7,仿真软件为 Matlab 7。仿真中网络流量在同一网段中传输,其中 20% 的网络流量通过网络主干进入三层交换机,设置客户机与服务器之间隐通道的链路容量为 10 Mbps,数据传输延时为 20ms。流量序列的原始样本数据的采集来源于服务器的中央交换机,网络流量的测试样本集来源于 2015 年 6 月 30 日至 7 月 5 日采集的流量数据,在网络流量数据采集中,采样时间间隔为 30s,每小时为一段数据形成一组时间序列信号波形,网络流量数据来源于客户机与服务器之间进行数据通信和文件传输的实际信息流。

根据上述仿真环境,进行网络流量的预测仿真,参数设计中,预测时间步长为 0.5s,经过 100 次仿真后求得网络流量的高阶谱信息特征。根据实际采样的网络流量序列,采用本文方法进行矢量空间重构,采用自相关函数法求得矢量空间重构的时间延迟,采用互信息最小嵌入维算法求得网络流量序列的矢量空间嵌入维,实验结果如图 2 所示。



(a) 自相关函数法求时间延迟



(b) 互信息最小嵌入维算法嵌入维数

图 2 网络流量序列矢量空间重构的参数确定

通过上述仿真结果和分析,找出其第一个极小值点所对应的时间点作为最佳时间延迟,取时间延迟 $\tau=17$,嵌入维数 $m=4$,以此为基础对网络流量时间序列进行矢量空间重构,得到重构的相轨迹图,如图 3 所示。




图 3 网络流量时间序列的矢量空间重构相轨迹图

由图 3 可见,采用本文方法对网络流量时间序列进行矢量空间重构,吸引子展开效果比较理想,能准确反映流量序列的非线性特征信息。在重构的矢量空间中提取高阶谱特征,对 t 时刻到达隐通道的实际流量 t_{n+1} 计算重构后的矢量空间中相轨迹的高阶谱特征函数,采用一步预测方法实现流量预测,得到流量预测的时域波形,如图 4 所示。




图 4 流量预测的时域波形

由图 4 可见,采用本文算法能有效拟合流量序列的非线性状态特征,对流量状态变化的动态跟踪性能较好,表现了较好的预测能力。为了对比算法性能,采用本文算法和传统算法进行 10000 次蒙特卡洛实验,在不同的预测时间展宽下测试不同算法对网络流量的预测误差,得到的结果如图 5 所示。




图 5 流量预测误差对比

分析图 5 可见,采用小波预测算法,随着预测时长的增大,预测误差越来越大,从 5% 线性上升到 20%,难以实现有效预测;采用时频分析预测算法,预测误差有一定的稳定性,在 8%~20% 之间波动,对预测时长宽度的敏感性不大,但总体来说预测误差较大;采用 Wolf 一步预测算法,预测误差相对较小,随着预测时间的增大,波动性较小,稳定性也较好。将 Wolf 预测算法同本文算法对比,从求得的预测误差均值可见,采用本文算法的预测误差均值为 2.26%,而 Wolf 预测算法的误差均值为 4.38%,因此,从预测精度来讲,本文方法具有优越性,但从对预测时长的敏感性来看,传统的 Wolf 预测算法的波动性较小。总体来说,本文算法的预测误差较传统方法小,具有相对优越的性能。

结束语 本文提出了一种基于非线性时间序列分析和矢量空间重构的网络流量预测算法。构建了客户机与服务器之间数据存储隐通道的网络流量时间序列分析模型,实现了流量序列的矢量空间重构,提取了网络流量的高阶谱特征,通过矢量空间轨迹一步预测了下一个时间点的流量状态,实现了网络流量的准确预测。研究表明,采用该算法能降低流量预测误差,性能优越。

参考文献

- [1] Yang Lei, Li Gui-peng, Zhang Ping. Improvement of Wolf step by step prediction of network anomaly traffic detection [J]. Technology Bulletin, 2014, 30(2): 47-49 (in Chinese)
杨雷,李贵鹏,张萍.改进的 Wolf 一步预测的网络异常流量检测 [J]. 科技通报, 2014, 30(2): 47-49
- [2] Li Zhen-gang. Network traffic forecasting model based on Gaussian process regression [J]. Journal of Computer Applications, 2014, 34(5): 1251-1254 (in Chinese)
李振刚. 基于高斯过程回归的网络流量预测模型 [J]. 计算机应用, 2014, 34(5): 1251-1254

(下转第 135 页)

本文提出的模型提供了分析电子证据可信性的思路,即通过构建电子证据链的方式获取相关证据,判断其一致性,并分析目标证据的可信度,这将成为将来具体产品实现的理论基础。

结束语 本文提出了基于证据链分析主机系统电子证据可信性的模型,依据证据链的理论和现实应用方法以及电子证据的关联性和一致性,通过案例证明该方法是有效的。

目前,判断电子证据可信性主要依赖调查者的人工分析,缺乏有效的技术手段解决自动化问题。本文提出的方法提供了解决这一问题的思路,但模型仍处于初级阶段,还有一些细节问题需要完善,如处理证据链中的缺失证据、给证据链中不同阶段的电子证据赋权值等。

未来的工作将关注模型的具体实现,通过对相关案例的总结和梳理,结合领域专家经验,构建和完善不同类型的涉网案件的证据链,同时,需要确认其他可能的证据关联关系以提高模型的准确度。

参考文献

- [1] Wang Fang. The nature of digital evidence and the related rules [J]. Law Science, 2004, 273(8): 72-79 (in Chinese)
王芳. 数字证据的性质及相关规则[J]. 法学, 2004, 273(8): 72-79
- [2] Caloyannides M A. Forensics Is So "Yesterday" [J]. Security & Privacy IEEE, 2009, 7(2): 18-25
- [3] Anobah M, University S, Saleem S, et al. Testing Framework for Mobile Device Forensics Tools [J]. Journal of Digital Forensics Security & Law, 2014, 9(2): 221-234
- [4] Casey E, Casey E. Error, Uncertainty and Loss in Digital Evidence [J]. International Journal of Digital Evidence, 2002, 1(2): 1-45
- [5] Erbacher R F. Validation for Digital Forensics [C] // 2010 Seventh International Conference on Information Technology; New Generations (ITNG). IEEE, 2010: 756-761
- [6] Jansen A. Digital Records Forensics: Ensuring Authenticity and Trustworthiness of Evidence Over Time [C] // International

Workshop on Systematic Approaches to Digital Forensic Engineering. 2010: 84-88

- [7] Adams R, Hobbs V, Mann G. The Advanced Data Acquisition Model (ADAM): A Process Model For Digital Forensic Practice [J]. Journal of Digital Forensics Security & Law, 2014, 8(4): 25-48
- [8] Horsman G, Laing C, Vickers P. A Case Based Reasoning Framework for Improving the Trustworthiness of Digital Forensic Investigations [C] // 2013 12th IEEE International Conference on Trust, Security and Privacy in Computing and Communications. IEEE, 2012: 682-689
- [9] Tanne A L, Dampie D A. An Approach for Managing Knowledge in Digital Forensic Examinations [J]. International Journal of Computer Science & Security, 2010, 4(5): 451-465
- [10] Kwan M, Chow K P, Law F, et al. Reasoning about e evidence using Bayesian network [J]. Advances in Digital Forensics IV Ch, 2008, 12(3): 263-278
- [11] Cohen F. A method for forensic analysis of control [J]. Computers & Security, 2010, 29(8): 891-902
- [12] Levine B N, Liberatore M. DEX: Digital evidence provenance supporting reproducibility and comparison [J]. Digital Investigation the International Journal of Digital Forensics & Incident Response, 2009, 6: 48-56
- [13] Tian Z H, Yu X Z, Zhang H L, et al. A Real-Time Network Intrusion Forensics Method Based on Evidence Reasoning Network [J]. Chinese Journal of Computers, 2014, 37(5): 1184-1194 (in Chinese)
田志宏, 余翔湛, 张宏莉, 等. 基于证据推理网络的实时网络入侵取证方法 [J]. 计算机学报, 2014, 37(5): 1184-1194
- [14] Casey E. Digital Evidence and Computer Crime-Forensic Science, Computers and the Internet (3rd Edition) [M]. Elsevier, 2011
- [15] Case A, Cristina A, Marziale L, et al. FACE: Automated digital evidence discovery and correlation [J]. Digital Investigation, 2008, 5(Suppl 1): 65-75

(上接第 114 页)

- [3] Chang Y C, Lin Z S, Chen J L. Cluster based self organization management protocols for wireless sensor networks [J]. IEEE Transactions on Consumer Electronics, 2006, 52(1): 75-80
- [4] Kolhe J P, Shaheed M, Chandar T S, et al. Robust control of robot manipulators based on uncertainty and disturbance estimation [J]. International Journal of Robust and Nonlinear Control, 2013, 23(1): 104-122
- [5] Liu Yun-tong. K-pruning algorithm for semantic relevancy calculating model of natural language [J]. Journal of Theoretical and Applied Information Technology, 2013, 48(3): 231-235
- [6] Lu Xing-hua, Chen Ping-hua. Traffic Prediction Algorithm in Buffer Based on Recurrence Quantification Union Entropy Feature Reconstruction [J]. Computer Science, 2015, 42(4): 68-71 (in Chinese)
陆兴华, 陈平华. 基于定量递归联合熵特征重构的缓冲区流量预测算法 [J]. 计算机科学, 2015, 42(4): 68-71
- [7] Zhai Hai-bin, Zhang Hong, Liu Xin-ran, et al. A P2P Cache Capacity Design Method to Minimize the Total Traffic Cost of Access ISPs [J]. Acta Electronica Sinica, 2015, 43(5): 879-887 (in Chinese)

翟海滨, 张鸿, 刘欣然, 等. 最小化出口流量花费的接入级 P2P 缓存容量设计方法 [J]. 电子学报, 2015, 43(5): 879-887

- [8] Ma You-zhong, Meng Xiao-feng. Research on index technology of cloud data management [J]. Journal of Software, 2015, 26(1): 145-166 (in Chinese)
马友忠, 孟小峰. 云数据管理索引技术研究 [J]. 软件学报, 2015, 26(1): 145-166
- [9] Sahu P K, Wu E H K, Sahoo J, et al. BAHG: Back-Bone-Assisted Hop Greedy Routing for VANET's City Environments [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(1): 199-213
- [10] Barrachina J, Garrido P, Fogue M, et al. VEACON: A Vehicular Accident Ontology Designed to Improve Safety on the Roads [J]. Journal of Network and Computer Applications, 2012, 35(6): 1891-1900
- [11] Shi Gui-min, Lin Hong-ji. Research on Network Flow Monitoring Pattern Based on Bypass [J]. Journal of Chongqing University of Technology (Natural Science), 2011, 25(9): 63-69 (in Chinese)
石贵民, 林宏基. 基于旁路的网络流量监控模式 [J]. 重庆理工大学学报(自然科学), 2011, 25(9): 63-69