

# CRH2型动车组列车信息传输网络流量建模与预测

葛诗春 刘雄飞 周 锋

(中南大学物理与电子学院 长沙 410006)

**摘要** 针对CRH2型动车组列车网络流量数据日益复杂的特性,提出了一种将主成分分析法(PCA)与后馈神经网络(BP网络)相结合的网络流量建模预测思路。基于已搭建好的CRH2型列车通信仿真平台,对该仿真网络各条链路进行流量采集。为了降低分析的复杂度,流量数据先进行PCA降维预处理分析,再将数据输入到BP神经网络模型进行仿真预测。经验证,该思路能有效拟合列车主体网络流量的变化趋势,为CRH2型动车组通信网络的故障诊断分析提供了一定的参考。

**关键词** CRH2型动车组,主成分分析,后馈神经网络,流量预测,故障诊断

**中图分类号** TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.10.017

## Modeling and Prediction on Train Communication Network Traffic of CRH2 EMUs

GE Shi-chun LIU Xiong-fei ZHOU Feng

(School of Physics and Electronics, Central South University, Changsha 410006, China)

**Abstract** Aiming at the increasing complexity of the CRH2 train network traffic data, the method based on principal component analysis (PCA) and back propagation neural network (BP Network) was proposed to model and predict network traffic. Based on the built CRH2 train communication simulation platform, traffic of various links of the network has been collected. In order to reduce the complexity of analysis, the dimension reduction analysis is carried out with the application of PCA, then the data is input to BP network for simulation prediction. It is proved that the method can effectively fit the trend of the train network flow, providing concrete reference for the fault diagnosis of CRH2 train communication network.

**Keywords** CRH2 type EMUs, Principal component analysis, Back propagation neural network, Traffic prediction, Fault diagnose

## 1 引言

随着高速列车工业控制网络的发展,人们对列车信息功能的需求日益增加,进而不可避免地导致信息流量增加和网络规模增大,因此列车通信网络管理工作日益重要。掌握列车网络的运行状态,对于司控人员采取相应的管理策略具有重要的指导意义。正常稳定的工业网络控制系统<sup>[1]</sup>在其运行期间必须保持合理的网络流量水平。一旦网络流量出现长期高负荷运行,或者网络流量出现异常减小,则有可能是网络阻抗的变化引发数据传输不稳定,进而造成多设备接收不到数据包或系统设备发生故障等情况,将会影响系统的正常运行,甚至导致整个系统瘫痪。一旦出现故障且没有及时采取处理措施,将会严重影响列车的安全可靠运行,甚至有可能发生意外事故。因此,研究列车故障预测具有重大意义。

然而经调研发现,CRH2型动车组故障多为事后故障处理形式<sup>[2]</sup>,只有少部分装置利用先进的传感器技术获取系统的物理状态信息,并借助各种推理算法和智能模型(神经网络、数据融合、模糊逻辑、专家系统等),根据系统历史状态和环境因素,对系统进行状态分析和监测、故障诊断及预测,同时评估和预测被监测系统未来的健康状态,提出维修维护建议,为管理决策提供支持,最终实现基于系统状态的维修。目前利用的状态信息主要是物理参数,针对CRH2型列车网络流量状态方面的故障预测研究相对不够成熟。

状态监测系统的广泛应用以及计算机、数据库技术的发展为大规模数据分析提供了可能,因而出现了基于数据驱动流量预测方法。目前网络流量分析的许多研究工作主要集中在单条链路的流量研究上<sup>[3]</sup>。要进行全网络流量分析,仅凭单条链路是不够的,因为网络中不同链路的流量具有一定的相关性,很多异常行为引起的单条链路或单个节点流量的变化微乎其微,很难根据单条链路或单个节点的流量来识别这些流量异常。但对一个网络中的所有链路流量进行分析时,又会呈现出高维多变的特性。

为了降低CRH2型列车网络流量分析的复杂度,本文基于已搭建的CRH2型列车通信网络仿真平台,采集全网络流

到稿日期:2016-09-24 返修日期:2016-12-11 本文受国家自然科学基金资助项目:高速列车信息控制系统故障诊断应用验证平台与故障测试技术(61490702)资助。

葛诗春(1991—),女,硕士生,主要研究方向为测控网络故障诊断研究、网络通信,E-mail:gsc520915@163.com;刘雄飞(1960—),男,硕士,教授,主要研究方向为故障诊断、信号与信息处理;周 锋(1989—),男,硕士生,主要研究方向为测控网络故障诊断研究、网络通信。

量数据进行分析检测。利用主成分分析法(PCA)对链路流量的高维性进行降维预处理;为了解决列车网络流量变化具有的突发性、非线性和非平稳性等问题,采用BP神经网络对网络流量进行建模预测。最后,通过仿真验证证明了该模型的有效性。

## 2 总体方案

整个列车实行两级网络机制,对全列车所有设施设备进行监控。CRH2 动车组列车的通信网络列车级拓扑结构为环形网络拓扑结构<sup>[4]</sup>,采用列车总线和车辆总线将列车连成整体。列车总线由两部分组成:1)采用双重光纤环网结构的列车信息传输线,采用 ARCNET 协议<sup>[5]</sup>连接所有中央装置和终端装置;2)采用 HDLC 作为数据交换协议的双绞线备用总线,即自我诊断传输线,以总线方式连接中央装置和终端装置。为了便于分析,本文主要针对 ARCNET 协议部分流量数据建立预测模型,该系统的结构如图 1 所示。




图 1 系统结构图

采集网络流量序列样本可分为稳定部分和随机部分,可表示为:

$$X(t) = s(t) + v(t) \tag{1}$$

其中,  $s(t)$  表示稳定部分序列,  $v(t)$  表示随机部分序列。

主成分分析(Principal Component Analysis, PCA)降维处理的目的是降低数据冗余复杂度,可表示为:

$$Y = PX \tag{2}$$

其中,  $Y$  代表降维后的序列,  $P$  代表映射空间,  $X$  代表原始序列。

网络流量预测实际是回归分析问题,即根据历史流量信息,采用一定的方法建立恰当的数学分析模型,然后通过该模型对未来数据进行预测,为管理决策者提供一定参考,可表示为:

$$\hat{y} = f(Y_1, Y_2, \dots, Y_m) \tag{3}$$

其中,  $\hat{y}$  表示预测值,  $f()$  表示预测模型。

### 2.1 采集流量

我国典型动车组列车大多数是 8 车厢编组,分为 4 动 4 拖和 6 动 2 拖;16 车厢编组的是大编组,数量较少。另外,还有特殊的更高速度的实验列车,为 6 编组的纯动车组。本文采集的样本主要来源于已搭建的 8 车厢编组(4 动 4 拖)的 CRH2 型列车通信仿真平台。1 号车厢和 8 号车厢为车头,它们各自有 1 个中央装置和 1 个终端装置,中央装置有司控台,其余为终端装置。每个终端装置都连接有车载设备,CRH2 启动时,首先自动为这 2 个中央节点和 8 个终端节点装置分配唯一的逻辑地址作为站号,按照 ARCNET 网络机制构建成拥有 10 个节点的逻辑环网,之后按照 ARCNET 网络通信规范进行司控台与车载设备、司控台与牵引设备之间以及列车长与车载设备之间信息的实时、可靠的交互过程。

该仿真平台基于 OPNET 建模仿真工具实现。为了采集每条链路的流量,在仿真平台的基础上为各个节点的输入和输出端口设备建立一个事件数据服务器进程,该进程可以捕获数据包的到达时间、大小、源地址、目的地址、协议类型等各种信息,然后按照实验需求导出相关信息。CRH2 型动车组的网络拓扑图如图 2 所示。




图 2 CRH2 型动车组的网络拓扑图

系统在开机运行后,各个底层设备控制器通过各自的终端控制器向中央控制面板发送周期性的状态数据,该服务器通过状态数据判断网络系统是否正常。当网络系统正常时,可以通过司机控制器下达各种指令进行实验。各个底层控制器向各自的事件数据服务器发送本次实验采集到的网络流量数据,通过分析处理事件数据服务器捕获的流量来预测整个列车通信网络的流量情况。

节点域模型如图 3 所示,主要由总线收信机、总线发信机、mac 子层、interface 进程模型组成,事件服务器进程主要通过两个 mac 子层实现。




图 3 节点域模型

根据列车通信网络中传递控制指令对时间间隔的要求,本文设定了各节点平均每隔 0.01s 发出一个行车命令,当一个节点持有令牌时,它会把数据发送到总线上进行传递。设定捕获数据包的时间精度为 0.1ms。针对不同的网络协议流量数据或是特定 MAC 地址的网络流量数据,可以对抓取的数据包的协议类型、源地址、目的地址进行过滤,提取出相应的数据包大小和时间信息。数据采集窗口如图 4 所示。

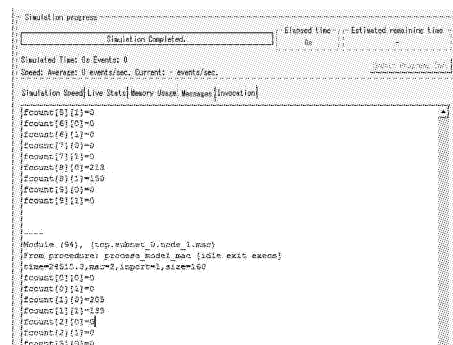


图 4 样本数据采集窗口

### 2.2 流量特性分析

由于铁路具有环境恶劣、流动性大、实时性强和数据可靠性传输的特点,因此列车通信网络所用的 ARCNET 网络与普通的 ARCNET 网络有所区别,具体表现在:列车通信网络的活动节点保存了逻辑邻居节点地址,从而可以构成活动节点地址表;同时设置了空闲区查询帧,减少了不必要的开销。列车数据长期在恶劣条件下传输,受到电磁的强烈干扰,因此具有高突发性。而一般数据通信网络传输数据的条件相对稳定,因此传输数据的突发率较低,大多数类型的流量都具有自相似性,为了建立网络流量模型,根据流量特性分析结果选取适合本系统的网络流量建模方法。通过测量列车通信网络流量发现,这些数据具有自相似性,且是长期相关的。

网络流量的本质特性是流量数据的长相关性或者自相似性,因此,网络流量建模的关键是如何准确且有效地表现流量数据的长相关特性。实验采用归一化自协方差函数和 Hurst 参数作为衡量实验结果的评价标准,根据归一化自协方差的衰减速度和 Hurst 估计值来判断流量是否长相关。

归一化自协方差函数定义为:设  $k$  表示时间间隔变量,  $c(k)$  为某随机过程的自协方差函数,随机过程的方差是  $\sigma^2$ , 则该随机变量的自相关系数为:

$$R(k) = \frac{c(k)}{\sigma^2} \quad (4)$$

Matlab 仿真结果如图 5 所示。




图 5 列车通信网络流量的自相关系数情况

采用方差时间法来估计 Hurst 参数。经 Matlab 仿真得 Hurst 估计值为 0.7215(大于 0.5),表明网络流量具有自相似性。从图 5 可以看出,自相关系数的衰减速度缓慢,说明列车通信网络流量数据的长相关特性较明显。

### 2.3 PCA 降维分析

PCA 是一种可进行线性降维的分析方法<sup>[7]</sup>,主要是将原来的数据空间分为两个正交不相关的主元子空间和残差子空间。具体描述为:用数目更少的  $m$  个特征取代原来的  $n$  个特征,新特征是旧特征的线性组合,这些线性组合最大化样本方差,尽量使新的  $m$  个特征互不相关,从而得出从旧特征到新特征的映射,以捕获数据中的固有变异性。

为了便于讨论,本文定义矩阵  $X$  代表网络中所有链路的时间序列。令  $m$  代表网络的链路数,  $t$  代表采样的点数,即  $X$  为  $t \times m$  的矩阵。 $X$  的第  $i$  列代表第  $i$  条链路的时间序列,第  $j$  行代表所有链路在  $j$  时刻的采样值。 $X_i$  代表第  $i$  条链路,在本文中代表一个列向量。

设对数据矩阵  $X$  进行 PCA 变换,相当于研究  $X^T X$  的特征值问题,每个主成分  $v_i$  就是  $X^T X$  的第  $i$  个特征向量,即:

$$X^T X v_i = \lambda_i v_i, i=1, 2, \dots, m \quad (5)$$

其中,  $\lambda_i$  是  $v_i$  对应的特征值。 $X^T X$  的特征向量是正交的,特征值是非负实数。按特征值从大到小可表示为  $\lambda_1, \lambda_2, \dots, \lambda_r$ ,

其中  $r$  是特征值的个数,  $r < m$ 。计算  $X$  的主成分相当于计算  $X^T X$  的特征向量。令  $v_1$  代表  $X$  的第一主成分,即代表了原测量数据最主要的特征:

$$v_1 = \arg \max_{\|v\|=1} \|X v\| \quad (6)$$

其中,  $\|X v\|$  代表原始数据在  $v$  轴上的能量。

同理,当第  $K-1$  个主成分确定后,第  $K$  个主成分就对应剩余能量中最大的方向。于是,第  $K$  个主成分可表示为:

$$v_K = \arg \max_{\|v\|=1} \|(X - \sum_{i=1}^{K-1} X v_i v_i^T) v\| \quad (7)$$

一旦将高维数据空间映射到主成分空间(用  $X v_i$  来表示主成分空间),就能更加清楚地分析原始数据在某个方向上的变化。当流量数据出现异常时,就能从冗余复杂的数据空间中更加有效地提取出异常空间。每个主轴  $i$  可表示为:

$$\mu_i = X v_i, i=1, 2, \dots, m \quad (8)$$

其中,  $\mu_i$  是  $t$  维向量且相互正交,其以  $v_i$  为系数,重建了原始数据在某个方向上的特征。因此,向量  $\mu_i$  提取了原数据在主轴  $i$  上的特征信息。因为主轴是按照能量贡献率排列的,所以  $\mu_1$  提取了原始数据的最大特征值,  $\mu_2$  提取了第二大特征值,以此类推。我们将  $\{\mu_i\}_{i=1}^r$  定义为原始数据的特征流。 $X$  可近似表示为:

$$Y = \sum_{i=1}^r \mu_i v_i^T \quad (9)$$

其中,  $Y$  是  $X$  的降维近似矩阵,  $r$  是特征值个数且  $r < m$ 。

本文样本数据集的特征维数为 20。采用 PCA 对原始数据进行特征提取,重建链路流后的降维结果如图 6 所示。




图 6 PCA 分析序列图

本文使用 PCA 方法对数据集进行特征选择后,从 20 个特征属性中提取包含 6 个特征属性的最优特征子集。在不丢失数据集所包含的信息量的前提下,对流量贡献率排序,得到的结果如图 7 所示。图 7 中,横坐标代表提取的特征属性,纵坐标代表每个特征属性在数据集所占的比例。




图 7 能量贡献率排序图

从图 7 可看出,前 6 个最大特征值数据集的总贡献率达到了 94.7502%,这说明即使删掉 14 维的信息,通过这 6 维信息也能很好地采集全网络的重要信息,这大大降低了后续各种

分析工作的复杂度。因此,本文提取前6个特征向量作为预测输入。

### 2.4 BP神经网络

#### 2.4.1 BP神经网络结构

BP(Back Propagation)网络<sup>[8]</sup>是一种按误差逆传播算法训练的多层后馈网络,由信息的正向传播和误差的反向传播两个过程组成。输入层各神经元负责接收来自外界输入信息,并传递给中间层各神经元;中间层是内部信息处理层,负责信息变换,根据信息变化能力的需求,中间层可以设计为单隐层或者多隐层结构;输出层各神经元接收来自最后一层隐层单元的输出信息,经进一步处理后,完成一次学习的正向传播处理过程,由输出层向外界输出信息处理结果。当实际输出  $u$  与期望输出  $y$  不符时,进入误差的反向传播阶段。误差通过输出层,按误差梯度下降的方式修正各层权值,向隐层、输入层逐层反传。周而复始的信息正向传播和误差反向传播过程是各层权值不断调整的过程,也是神经网络学习训练的过程,此过程一直进行到网络输出的误差减小到可以接受的程度,或者达到预先设定的学习次数为止。其结构如图8所示。




图8 BP神经网络的结构

其中,  $W$  代表隐层权值,通过改变隐层的权系数可以改变整个多层神经网络的性能。

#### 2.4.2 BP神经网络学习算法

BP神经网络采用误差逆传播算法<sup>[9]</sup>。设输入向量为  $X_k = (x_1^k, x_2^k, \dots, x_n^k)$ ,期望输出向量为  $Y_k = (y_1^k, y_2^k, \dots, y_q^k)$ ,其中,  $k=1, 2, 3, \dots, m$  代表训练模式对数,  $n$  代表输入神经元个数;  $q$  代表输出层神经元个数;隐层各神经元激活函数值  $S_j = \sum_{i=1}^n x_i w_{ij} - \theta_j$ ,  $w_{ij}$  代表输入层至隐含层的连接权值,  $\theta_j$  代表隐含层单元的阈值,  $j=1, 2, 3, \dots, p$ ,  $p$  代表隐含层单元个数。本文选用 s 型激活函数,则隐含层  $j$  的单元输出即为:

$$h_{oj} = f(S_j) = \frac{1}{1 + \exp(-\sum_{i=1}^n x_i w_{ij} + \theta_j)} \quad (10)$$

阈值  $\theta_j$  和权值  $w_{ij}$  在学习过程中不断修正。输出层第  $t$  个单元的激活值为  $out_t = \sum_{j=1}^p w_{jt} h_{oj} - \theta_t$ ,因此输出层第  $t$  个单元的实际输出为:

$$out_{ot} = f(out_t) = \frac{1}{1 + \exp(-\sum_{j=1}^p w_{jt} h_{oj} + \theta_t)} \quad (11)$$

$w_{jt}$  是隐含层至输出层的权值,  $\theta_t$  是输出层单元阈值,  $x_j$  是隐含层第  $j$  个节点的输出值,  $t=1, 2, \dots, q$ ,  $q$  为输出层单元数。

当这些实际的输出值与希望的输出值不一样或者误差大于给定的阈值时,就要对网络进行逆向误差校正。输出层校正误差为:

$$d_t^k = y_t^k out_{ot}^k f'(out_t^k) \quad (12)$$

其中,  $f'(\cdot)$  是对输出函数的导数,  $y_t^k$  是期望输出,  $out_{ot}^k$  是实际输出。由输出层校正误差可推导出隐含层校正误差为:

$$e_j^k = (\sum_{t=1}^q w_{jt} d_t^k) f'(s_j^k) \quad (13)$$

输出层至隐含层的权值和输出层阈值校正量分别为:

$$\Delta w_{jt} = \alpha d_t^k h_{oj} \quad (14)$$

$$\Delta \theta_j = \alpha d_j^k \quad (15)$$

其中,  $\alpha (\alpha > 0)$  代表输出层至隐含层的学习率。同理,可逆推出隐含层至输入层权值及隐含层阈值校验量分别为:

$$\Delta w_{ji} = \beta e_j^k x_i^k \quad (16)$$

$$\Delta \theta_j = \beta e_j^k \quad (17)$$

其中,  $0 < \beta < 1$ ,  $e_j^k$  代表隐含层校正误差,  $x_i^k$  代表标准输入。

最后,进行不断的循环记忆训练以及判别学习,直到满足允许输出误差为止。主要通过以下3个经验公式<sup>[10]</sup>对隐含层节点数进行确定。

$$m = \sqrt{n+l} + \alpha \quad (18)$$

$$m = \log_2^n \quad (19)$$

$$m = \sqrt{nl} \quad (20)$$

其中,  $m$  为设置的隐含层节点数,  $n$  为输入层节点数,  $l$  为输出层节点数,  $\alpha$  为 1~10 之间的常数。

### 3 仿真实验及分析

本文数据采集于 CRH2 型动车组信息传输仿真平台,通过设置过滤器,仅捕获采用 ARCNET 协议传递的列车状态信息。将各节点事件服务器采集的数据包缓存在数据库中,并记录捕获时间、MAC 地址以及收发字节数等。设置捕获时间精度为 0.1ms,采样时间为 150ms。由于状态信息最终会通过总线上传到中央装置,因此可以预测同一时段内各链路总流量的大小。为了使网络收敛并降低分析网络流量的复杂性,先对捕获数据进行归一化处理,并进行主成分分析。由主成分累计贡献率图可知,前6个特征向量的总贡献率超过了90%,因此选取前6个链路总流量作为BP神经网络预测的输入向量来对训练和测试样本进行处理。

#### 3.1 BP神经网络参数的确定

为了便于分析,设网络输入层神经元个数为10,输出层神经元个数为1,根据隐层设计经验确定式(18)~式(20),同时考虑本例实际情况,在相同条件下针对不同隐层神经元个数进行实验,结果如图9所示。




图9 隐层神经元误差曲线

从图9可以看出,并非隐层神经元个数越多网络性能就越好,当神经元个数从5增加到6时,网络误差反而增大了,因此实验将隐层神经元个数设置为5。

对预测模型输出序列的多项式系数残差进行白噪声检验,得到如图 10 所示的拟合残差序列图。





图 10 PCA-BP 模型拟合残差序列图

从图 10 可以看出,经过 PCA-BP 建模后的流量序列的拟合残差是稳定分布的,通过了白噪声检验,说明建模完成。


### 3.2 预测结果分析

为了验证模型的有效性,选择传统的 ARIMA<sup>[11]</sup>(自回归积分滑动平均)模型和 FARIMA<sup>[12]</sup>(差分自回归移动平均)模型进行对比实验,并采用 MRE(平均相对误差)、预测精度以及模型运行时间复杂度<sup>[13]</sup>对预测结果进行评价。

取前 1450 个数据作为训练样本,后 50 个作为预测检验样本,各模型的预测结果分别如图 11—图 13 所示。在相同训练样本条件下,50 个预测样本在 3 个预测模型上的预测平均相对误差和预测精度如表 1 所列。




(a)PCA-BP 模型预测值和真实值




(b)PCA-BP 模型预测绝对误差

图 11 PCA-BP 神经网络模型预测结果




(a)PCA-FARIMA 模型预测值和真实值




(b)PCA-FARIMA 模型预测绝对误差

图 12 PCA-FARIMA 模型预测结果



(a)PCA-ARIMA 模型预测值和真实值



(b)PCA-ARIMA 模型预测绝对误差

图 13 PCA-ARIMA 模型预测结果

从图 11—图 13 的预测结果可以看出,PCA-BP 神经网络模型、PCA-FARIMA 模型和 PCA-ARIMA 模型在一定程度上都能反映 CRH2 型动车组通信系统的网络流量主体变化趋势,但总体上 PCA-BP 模型的预测值更接近检验值。

表 1 3 种模型的仿真预测结果对比

方法	平均相对误差/%	预测精度/%	时间复杂度
PCA-ARIMA	27.12	72.82	$O(n)$
PCA-FARIMA	14.06	81.23	$O(n^2)$
PCA-BP 神经网络	7.23	92.01	$O(n^2)$

从表 1 可以看出,3 个预测模型在相同训练样本条件下对 50 个预测样本进行预测时,PCA-BP 神经网络预测模型的平均相对误差最小,且预测精度最高;从时间复杂度来看,PCA-ARIMA 的时间复杂度是  $O(n)$ ,而 PCA-FARIMA 和 PCA-BP 的时间复杂度是  $O(n^2)$ 。因此,从预测时间效率看,PCA-ARIMA 更具优势;但从列车运行的可靠性角度分析,PCA-BP 模型更适用于和谐 2 号列车通信网络的流量预测。随着预测步长的增加,均方误差以及平均相对误差都有所增加,PCA-BP 的预测精度变差。

表 2 PCA-BP 在不同预测步长下的误差结果

预测步长	平均相对误差/%	均方误差
2	7.23	0.0248
3	14.06	0.0654
4	14.77	0.0662

**结束语** 为了降低和谐 2 号动车组列车全网络流量数据分析的复杂度,本系统先采用主成分分析法进行降维预处理,从流量贡献情况得出该方法确实能有效降低数据的维数。

采用 BP 神经网络对训练样本进行学习训练,从而建立预测模型。从预测结果来看,该模型能有效拟合列车网络流量趋势,说明该系统适用于 CRH2 型列车测控网络的流量预测,具有一定的工程应用价值。

### 参考文献

[1] LIU L,JIANG H H,WANG J,et al. Study On Characteristics and Modling of An Industrial Ethernet Traffic[J]. Microelectronics and Computer,2015,3(5):1-5. (in Chinese)

- ting for data dissemination in mobile social networks[J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 24(4): 734-743.
- [10] LIU X, LI P, LIU J, et al. Centrality for nodes in social networks [J]. Computer Engineering and Applications, 2014, 50(5): 116-120. (in Chinese)  
刘欣, 李鹏, 刘璟, 等. 社交网络节点中心性测度[J]. 计算机工程与应用, 2014(5): 116-120.
- [11] SONG Y P, NI J. Effect of variable network clustering on the accuracy of node centrality [J]. Acta Physica Sinica, 2016, 65(2): 28901. (in Chinese)  
宋玉萍, 倪静. 网络集聚性对节点中心性指标的准确性影响研究[J]. 物理学报, 2016, 65(2): 28901.
- [12] WU D P, JIN J W, LV Y, et al. Similarity Aware Community Detecting Method for Social Intermittently Connected Mobile Network[J]. Journal of Electronics & Information Technology, 2013, 35(1): 141-146. (in Chinese)  
吴大鹏, 靳继伟, 吕翊, 等. 节点相似度感知的社会化间断连接无线网络结构检测机制[J]. 电子与信息学报, 2013, 35(1): 141-146.
- [13] YANG J X, WANG C K, WANG M, et al. Algorithms for Local Betweenness Centrality of Fully Dynamic Multi-Dimensional Networks[J]. Journal of Computers, 2015(9): 1852-1864. (in Chinese)  
杨建祥, 王朝坤, 王萌, 等. 全动态多维网络局部介数中心度算法[J]. 计算机学报, 2015(9): 1852-1864.
- [14] KIM, HYOUNGSHICK, ANDERSON R. Temporal node centrality in complex networks[J]. Physical Review, 2012, E85(2): 605-624.
- [15] KIM H, TANG J, ANDERSON R, et al. Centrality Prediction in Dynamic Human Contact Networks[J]. Computer Networks, 2012, 56(3): 983-996.
- [16] QIN L, YANG Z L, HUANG S G. Synthesis Evaluation Method for Node Importance in Complex Networks[J]. Chinese Journal of Computer Science, 2015, 42(2): 60-64. (in Chinese)  
秦李, 杨子龙, 黄曙光. 复杂网络的节点重要性综合评价[J]. 计算机科学, 2015, 42(2): 60-64.
- [17] EAGLE N, PENTLAND A. Reality mining: sensing complex social systems[J]. Journal of Personal and Ubiquitous Computing, 2006, 10(4): 255-268.
- [18] SCOTT J, HUI P, CROWCROFT J, et al. Hagggle: a Networking Architecture Designed Around Mobile Users[C]// Proceedings of the Third Annual Conference on Wireless On-Demand Network Systems & Services, 2006.
- 
- (上接第 95 页)
- 刘亮, 江汉红, 王洁, 等. 工业以太网网络流量的特性分析与建模研究[J]. 微电子学与计算机, 2015, 3(5): 1-5.
- [2] PENG H D, WANG H. Converter Fault Analysis of CRH2C EMU[J]. Journal of the China Railway Quality Control, 2013, 3(1): 33-35. (in Chinese)  
彭华东, 王慧. CRH2C 型动车组牵引变流器故障分析[J]. 铁道技术监督, 2013, 3(1): 33-35.
- [3] LI Z L, HU G M, YAO X M, et al. Detecting Distributed Network Traffic Anomaly with Network-Wide Correlation Analysis [J]. EURASIP Journal on Advances in Signal Processing, 2009 (1): 135-140.
- [4] 张曙光. CRH2 型动车组[M]. 北京: 中国铁道出版社, 2008: 15-60.
- [5] NIE X B, WANG L D, SHEN P, et al. Real-time Performance Research of the ARCNET control System [J]. Journal of the China Railway Society, 2011, 33(1): 58-62. (in Chinese)  
聂晓波, 王立德, 申萍, 等. ARCNET 网络系统实时性能分析与研究[J]. 铁道学报, 2011, 33(1): 58-62.
- [6] KUANG C H, LI J W, WANG Y S, et al. Modeling and Simulation of Train Communication Network of ARCNET Based on OPNET[J]. Journal of Railway Computer Application, 2008, 5(1): 49-51. (in Chinese)  
况长虹, 李家武, 王玉松, 等. 基于 OPNET 的 ARCNET 列车通信网络的建模与仿真[J]. 铁路计算机应用, 2008, 5(1): 49-51.
- [7] WANG M, LI C X, CHEN C J. Network Traffic Analysis Based on PCA[J]. Journal of Microcomputer Information, 2006, 6(4): 94-97. (in Chinese)  
王敏, 李纯喜, 陈常嘉. 浅谈基于 PCA 的网络流量分析[J]. 微计算机信息, 2006, 6(4): 94-97.
- [8] XIONG S S. The Theory research on Dynamics System Modeling of Neural Network[J]. Journal of Tsinghua University(Natural Science), 1998(8): 25-30. (in Chinese)  
熊沈蜀. 神经网络在动力学系统建模中的理论研究[J]. 清华大学学报(自然科学版), 1998(8): 25-30.
- [9] 范剑青, 姚琦伟. 非线性时间序列: 建模、预报及应用[M]. 北京: 高等教育出版社, 2005: 76-86.
- [10] YUE J, BAO S Y, LI Q Z, et al. The Analysis of BP Network Traffic Accident Serious Level Model Based on Principal Component[J]. Applied Mechanics and Materials, 2014, 3488 (641): 910-915.
- [11] TIAN Z D, LI S J, WANG Y H, et al. Network traffic Forecasting Method of Compensation ELM Based on ARIMA[J]. Journal of Information and Control, 2014, 43(6): 705-710. (in Chinese)  
田中大, 李树江, 王艳红, 等. 基于 ARIMA 补偿 ELM 的网络流量预测方法[J]. 信息与控制, 2014, 43(6): 705-710.
- [12] SUN Y, BAI G W, ZHAO L. Network traffic prediction based on wavelet FARIMA model[J]. Journal of Computer Applications, 2011, 31(4): 901-903. (in Chinese)  
孙勇, 白光伟, 赵露. 基于小波分形自回归整合滑动平均模型的网络流量预测[J]. 计算机应用, 2011, 31(4): 901-903.
- [13] ZHANG B, YANG J H, WU J P. Analysis and Review of Internet Traffic Model [J]. Journal of Software, 2011, 22(1): 115-131. (in Chinese)  
张宾, 杨家海, 吴建平. Internet 流量模型分析与评述[J]. 软件学报, 2011, 22(1): 115-131.