

文章编号: 1001-0920(2009)09-1421-04

基于 Haar 小波的队列动态多尺度自适应智能预测

杨月全^{1,2}, 余星火², 姜建妹¹, 张天平¹

(1. 扬州大学 信息工程学院, 江苏 扬州 225009; 2. 皇家墨尔本理工大学
工程技术平台研究院, 维多利亚 3001, 澳大利亚)

摘要: 为降低网络拥塞风险和实现对网络队列缓存资源状态预测, 基于智能控制技术和多尺度表示方法, 通过引进自适应补偿模糊因子, 运用 Haar 小波的优良特性, 构造了一类在线无监督学习实时预测补偿模糊神经网络, 提出了基于 Haar 队列动态多尺度融合自适应智能预测方案. 仿真表明, 该预测策略对于自相似特性数据流在队列缓存动态具有较好的预测能力.

关键词: 多尺度融合; 补偿模糊神经网络; Haar 小波; 自相似

中图分类号: TP273 **文献标识码:** A

Adaptive intelligent prediction of queue dynamics based on Haar wavelet multiscale fusion

YANG Yue-quan^{1,2}, YU Xing-huo², JIANG Jian-mei¹, ZHANG Tian-ping¹

(1. College of Information Engineering, Yangzhou University, Yangzhou 225009, China; 2. Platform Technologies Institute, RMIT University, VIC 3001, Australia. Correspondent: YANG Yue-quan, E-mail: yangyq@yzu.edu.cn)

Abstract: By introducing an adaptive compensated fuzzy factor, an online non-supervised learning real-time prediction compensated fuzzy-neural network (OnSLRPCFNN) is designed. A novel strategy of adaptive intelligent prediction of queue length based on Haar wavelet multiscale fusion of queue dynamics is developed, which can decrease risk of network self-similar data flow congestion and improve the capability for the prediction of queue dynamics. The simulation shows the effectiveness of the proposed approach.

Key words: Multiscale fusion; Compensated fuzzy-neural network; Haar wavelet; Self-similar

1 引言

随着计算机技术、网络技术和通信技术的迅猛发展, 其与自动控制技术的结合越来越受到广泛关注^[1-6]. 由于在网络传输过程中各类业务数据流不可避免地存在网络时延, 如果能够提前对网络中各类队列缓存资源进行较为准确的预报, 则可减低网络拥塞的发生概率, 从而提高整个网络业务数据流传输质量. 网络业务数据流具有复杂自相似传播特质^[7-15], 有的表现为短相关性, 有的表现为长相关性; 当它们传送到网络各中间结点时, 结点的缓冲队列动态特性表现得非常复杂, 有渐变成分, 也有突变部分, 很难用精确的数学模型表示.

通过提供一个灵活可变的时频动态视窗, 将研究对象所表现出的时域和频域空间特征统一地结合

进行分析和研究, 这是小波变换与分析的显著特性. 随着小波理论不断发展, 信息多尺度表示理论和方法引起了人们的关注^[16-20].

本文运用智能控制技术^[21, 22], 基于小波多尺度理论, 对具有自相似性数据流传输网络中间结点的队列缓存资源状态信息进行提前预测, 从而实现对网络数据流的有效控制. 设计了一类在线无监督学习实时预测补偿模糊神经网络 (OnSLRPCFNN), 提出一种基于 Haar 小波的队列动态多尺度融合自适应智能预测策略.

2 基于 Haar 小波队列长度多尺度信息表示

Haar 小波具有特别的优良特性, 不存在边界问题, 其所对应的支撑区间不重叠. 一般在较粗尺度空间上, 可以刻画信号较“粗”的性状特征; 在较细尺度

收稿日期: 2008-10-24; 修回日期: 2009-01-09.

基金项目: 国家自然科学基金项目(60774017, 60874045); 中国科学院复杂系统与智能科学重点实验室开放课题项目(20060101).

作者简介: 杨月全(1971—), 男, 江苏盐城人, 副教授, 博士, 从事智能与复杂系统的研究; 张天平(1964—), 男, 江苏泰兴人, 教授, 博士生导师, 从事非线性系统控制、智能控制等研究.

空间上,可以表达信号更为精细的特质.另外,由于网络业务数据流在传输过程中存在网络时延,如果能够提前对网络中缓存资源进行预报,就可以减低网络拥塞的发生概率,从而提高整个网络业务数据流传输质量,提高网络的同步性能.应用小波在不同尺度上逐步精细表达信息的能力,对队列动态进行不同尺度的信息提取,将具有自相似性随机数据流的队列信息从不同尺度上进行分解,并在此基础上,对队列动态序列信息进行不同尺度融合,实现不同预测长度的队列动态预测.

下面围绕针对队列动态信息序列的多尺度提取,设计基于多尺度信息融合的队列缓存动态预测方案.首先,设某网络结点 Q 缓存空间的队列长度 $q(t)$ 的动态为

$$\dot{q}(t) = \sum_{i=1}^N x_i - c. \quad (1)$$

其中: x_j 表示网络业务数据流 i 的发送速率, c 表示该中间节点服务速率, N 表示网络业务数据流总个数.则队列缓存长度可以表示为

$$q(t) = \int_0^t \left(\sum_{i=1}^N x_i(t) - c \right) dt. \quad (2)$$

由于网络业务数据流流速是随网络状况在不断调整,网络中数据流数量 N 也是一个不确定的随机量,直接运用式(2)获得时刻 $t + j$ 的该 Q 队列长度预测值 $\hat{q}(t + j)$ 是行不通的,其中 j 表示预测长度.

运用小波分析理论和时间序列分析方法,对队列长度进行采样,获得队列动态的时间序列.网络中间节点资源的制约和预测长度的不同,给采样增大了难度.如果采样频率过高,则必然要占用交换机结点大量的时间和空间资源.而且,即使可以采取很高的采样频率,由于网络中业务数据流动态具有时变不确定的特性,受各种噪声干扰的程度就要增大;另外,网络时延一般比采样周期大,预测长度较大时,预测误差也必然增大.因此,为了克服这些不利因素,提出基于多尺度信息融合队列长度预测方案.

假设经过采样得到队列序列长度为 N , 队列序列信息表示为 $\{q_i, i = 0, 1, \dots, N - 1\}$. 为描述方便,记序列为

$$\{x_i, i = 0, 1, \dots, N - 1\}, \quad (3)$$

其中 $x_i = q_i$. 对序列作不同尺度的 j 分解,即

$$j = 2^l, j = 0, 1, \dots, J - 1. \quad (4)$$

为便于讨论,选取4个尺度进行分析,取 $J = 4, N = 16$. 当然也可取更多尺度,这主要取决于网络结点所能承受的时间和空间耗费.由于 Haar 小波支撑区间互不重叠性,可以得到序列多尺度分解,则4尺度信息序列构成的向量 W 为

$$W = M^T X. \quad (5)$$

其中

$$X = [x_0, x_1, \dots, x_{N-1}]^T, \\ W = [w_{00}, w_{01}, \dots, w_{07}, w_{10}, \dots, \\ w_{13}, w_{20}, w_{21}, w_{30}, w_{s,0}]^T. \quad (6)$$

M 多尺度分解矩阵可表示为

$$M = [m_{00} \ m_{01} \ \dots \ w_{07} \ m_{10} \ \dots \\ m_{13} \ m_{20} \ m_{21} \ m_{30} \ m_{s,0}]^T. \quad (7)$$

其中: m_{ji} 表示尺度 j 小波空间 W_j 的第 i 个小波基, $m_{s,0}$ 表示尺度空间 V_j 的尺度基;有

$$m_{00} = [-1/\sqrt{2} \ 1/\sqrt{2} \ 0 \ \dots \ 0]^T, \\ m_{0i} = T^{2i} m_{00}; \\ m_{10} = [-1/2 \ -1/2 \ 1/2 \ 1/2 \ 0 \ \dots \ 0]^T, \\ m_{1k} = T^{4k} m_{10}; \\ m_{20} = [-1/\sqrt{8} \ \dots \ -1/\sqrt{8} \ 1/\sqrt{8} \ \dots \\ 1/\sqrt{8} \ 0 \ \dots \ 0]^T, \ 0 \leq i \leq 7; \\ m_{30} = [-1/4 \ \dots \ -1/4 \ 1/4 \ \dots \ 1/4]^T, \\ 0 \leq k \leq 3; \\ m_{s,0} = [1/4 \ \dots \ 1/4]^T; \\ m_{21} = T^8 m_{20},$$

$$T = \begin{bmatrix} 0 & 0 & \dots & 0 & 1 \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \dots & \dots & \ddots & \dots & \dots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix},$$

T 相当于一个循环算子, T^0 表示单位阵.

3 多尺度融合队列动态自适应预测方案

首先,构造补偿模糊神经网络(CFNN).在CFNN中,第1层为输入层;第2层为模糊化层;第3层为模糊规则层,设模糊规则个数为 L ;第4层为补偿运算层;第5层为去模糊化层.这里增加了补偿运算层,在进行模糊推理时,对规则前件按如下方式处理.设某模糊规则为

$$R: \text{if } x_1 \text{ is } A_1, x_2 \text{ is } A_2, \text{ then } y \text{ is } B. \quad (8)$$

其中: x_1 和 x_2 为前件输入变量,其论域在直积空间 $U_1 \times U_2$ 上; y 为后件部分输出变量,其论域设为 U , 则规则 R 所表示的模糊推理为

$$\mu_B(y) = \sup_{(x_1, x_2)} \{ \mu_{A_1 \times A_2 \rightarrow B}(x_1, x_2, y) \} \circ \\ \mu_{A_1 \times A_2}(x_1, x_2). \quad (9)$$

前件模糊集合直积定义引进补偿模糊因子^[17],为

$$\mu_{A_1 \times A_2}(x_1, x_2) = \mu_{A_1}(x_1)^{1-\alpha} \mu_{A_2}(x_2), \quad (10)$$

其中 $(0, 1)$ 为补偿模糊因子.在进行队列长度预测时,由于各数据流表现出复杂的动态特性,采用该补偿模糊算子比简单取最小或取其积都要优越.当

前件模糊语言变量个数多于 2 个(不妨设 n) 时, 补偿模糊算子可取为

$$\mu_{A_1 \times A_2 \times \dots \times A_n} = \mu_{A_1}^{l_1} \mu_{A_2}^{l_2} \dots \mu_{A_n}^{l_n} \quad (11)$$

对规则后件采取单点模糊化, 式(9) 中模糊蕴含取 Larsen 积运算, 并定义去模糊层的清晰化函数为

$$\hat{q}(X(k)) = \frac{\sum_{l=1}^L d^l \left[\mu_{A_1}^{l_1} \mu_{A_2}^{l_2} \dots \mu_{A_n}^{l_n} \right]}{\sum_{k=1}^L \left[\mu_{A_1}^{l_1} \mu_{A_2}^{l_2} \dots \mu_{A_n}^{l_n} \right]} \quad (12)$$

运用 CFNN 和队列动态的多尺度时间序列信息, 构造在线无监督学习实时预测补偿模糊神经网络, 如图 1 所示. 其中, OnSLRPCFNN 学习队列动态时间序列汇聚流为

$$H^{LRN} = \{q(s) \mid s = t - mT, m = 1, 2, \dots, M\}.$$

预测时队列动态汇聚流为

$$H^{PRD} = \{q(s) \mid s = t - mT, m = 0, 1, \dots, M - 1\},$$

M 为队列长度, W^{LRN} 和 W^{PRD} 分别表示对应于队列动态时间序列的 H^{LRN} 和 H^{PRD} 的 4 尺度信息向量.

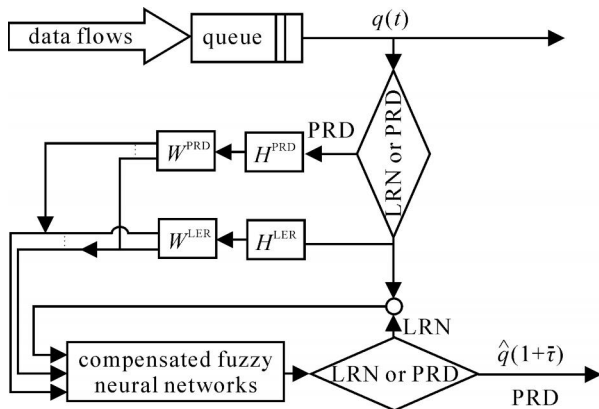


图 1 基于 OnSLRPCFNN 队列预测结构

基于多尺度信息融合的队列动态自适应预测策略有两种方案: 一种方案是先对队列动态序列进行多尺度分解, 获取尺度信息表示序列 $\{w_{ji}\}$; 然后将其作为 OnSLRPCFNN 的输入, 输出信息为队列动态预测值. 可见, 在此方案中 OnSLRPCFNN 具有多尺度融合的功能. 记各尺度下的细节信号为 w_{ji} , 定义其模糊划分为 $\{NL, NS, ZO, PS, PL\}$, 并定义隶属度函数为

$$\mu_{A_{ji}}^l(w_{ji}) = e^{-((w_{ji} - c_{ji}^l)/l_{ji}^l)^2}.$$

由于输入向量维数由预测时具体所提取多尺度序列长度和尺度个数来决定, 设输入向量维数为 P . 定义性能指标为

$$J = 1/2e^2(k). \quad (13)$$

其中: $e(k) = q(k) - \hat{q}(k)$ 为队列 Q 在 t 时刻的学习误差, $\hat{q}(k)$ 为队列长度 $t = kT$ 时刻的预测值, T 为采

样周期. 运用梯度下降算法, 得到参数自适应律为

$$\begin{cases} c_i^l(k+1) = \\ c_i^l(k) - 2\phi^{l-1}(x_i^l - c_i^l(k))/(l_i^l)^2, \\ l_i^l(k+1) = \\ l_i^l(k) - 2\phi^{l-1}(x_i^l - c_i^l(k))^2/(l_i^l)^3, \\ d^l(k+1) = d^l(k) + e^{l-1}, \\ l^l(k+1) = l^l(k) - e(d^l - \hat{q})^{l-1}. \end{cases} \quad (14)$$

其中: $\eta > 0$ 为学习率, ϕ 为补偿模糊因子,

$$l^l = l^l / l^{l-1}, \quad l^l = \mu_{A_i}^{l_1} \mu_{A_i}^{l_2} \dots \mu_{A_i}^{l_{(P-1)}}$$

$$\phi = e(d^l - \hat{q})(1 - \eta / (P - 1)).$$

为提高 OnSLRPCFNN 学习和预报能力, 定义自适应补偿模糊因子为

$$l^l(k) = (1 + 2\arctan(\eta / l^l(k))) / 2. \quad (15)$$

应用梯度下降算法, 可以得到

$$l^l(k+1) = l^l(k) + e(d^l - \hat{q})(1 - \eta / P)^{l-1} \ln(l^l(k)). \quad (16)$$

则得到自适应补偿模糊因子的自适应律为

$$l^l(k+1) = (1 + 2\arctan(\eta / l^l(k+1))) / 2, \quad (17)$$

其中

$$l^l(k) = [(1 + \eta / l^l(k))^2 (1 - \eta / l^l(k) + \eta / P)].$$

另一种方案是在获得队列动态的多尺度信息表示序列 $\{w_{ji}\}$ 后, 先对各尺度下队列动态细节信号序列分别进行预测; 然后将得到的多尺度预测信息再进行融合; 最后得到队列动态的预测值. 在此方案中, 由于等长的队列序列所获得的不同尺度信息序列长度不相等, 可利用历史粗尺度信息对当前粗尺度序列进行增广, 从而使队列动态的粗尺度信息也足够“丰富”. 这里在预测时需要对新获得的队列动态序列进行基于 Haar 小波的多尺度分解, 用所获得的细节信息来训练各 OnSLRPCFNN 补偿模糊神经网络.

该方案计算量大, 较为复杂, 故采用第 1 种方案进行队列动态的自适应预测.

需要说明的是, 单率多点以及多率多点业务数据流网络体系中, 数据流发送结点或接受结点传输时延是动态变化的, 而且对各个业务数据流而言也不尽相同. 因此, 在对队列动态进行基于多尺度信息的长度预测时, 要注意选择合适的多尺度信息序列长度和尺度大小, 这些都与预测长度有着密切的关系. 当尺度分解较多时, 将增大模糊神经网络维数, 增加网络中间结点的工作负载.

4 仿真实验

应用 NS2 和 MatLab 仿真工具, 考虑标准分形

Brown 运动和具有短相关特性的 Poisson 过程中两个数据流作用下某网络节点队列长度的时间序列^[9-12],如图2所示.图3和图4是尺度为 i ($i = 0, 2$) 的队列细节信号序列图.应用文中所设计的 OnSLPRCFNN,选择第1种预测方案,取预测长度为 $i = 4$.可以看出,融合两尺度信息的预测误差较小,精度较高,如图5所示.这里略去了其他尺度间融合预测的结果图.




图2 某网络中间节点队列长度时间序列




图3 队列动态序列细节信号 ($i = 1$)




图4 队列动态序列细节信号 ($i = 2$)




图5 融合尺度 i_0 和 i_2 的预测误差

实验表明,适当选取不同尺度信息进行融合,可以取得较好的预测结果:(1)该方案运用了队列动态在不同尺度空间上的细节信息,根据预测长度进行适当尺度序列进行融合;(2)该方案所构造的无监

督实时补偿模糊神经网络具有较强的在线学习能力.

5 结 论

本文针对网络中自相似随机数据流动态通过队列缓存的不同尺度进行细节表示,根据网络时延的大小在多个尺度上进行融合,实现对队列的动态智能预测.基于 Haar 小波,设计了自适应补偿模糊因子,构造了 OnSLPRCFNN,提出了基于多尺度信息融合网络队列缓存长度自适应智能预测方案.该控制方案可对网络中潜在瓶颈链路、队列缓存资源状态实现提前预报.当然,对队列动态信息分解的尺度大小、尺度融合个数及预测长度之间深层次关系,以及多尺度信息序列融合算法等仍有待进一步研究.

参考文献(References)

- [1] Murry R M, Astrom K J, Boyd S P, et al. Future directions in control in a information-rich world [J]. IEEE Control Systems Magazine, 2003, 23(2): 20-33.
- [2] 王飞跃,王成红.基于网络控制的若干基本问题的思考和分析[J].自动化学报,2002,28(增):171-176. (Wang F Y, Wang C H. On some basic issues in network-based direct control systems [J]. Acta Automatic Sinica, 2002, 28(S): 171-176.)
- [3] Beldiman O, Walsh G C. Predictors for networked control systems [C]. Proc of American Control Conf, Chicago, 2000: 2347-2351.
- [4] Wu F G, Sun F C, Xue D Q, et al. Problems and strategies of networked control systems [C]. Proc of IEEE TENCON '02. Beijing, 2002:1692-1695.
- [5] Tipsuwan Y, Chow M Y. Network-based controller adaptation based on QoS negotiation and deterioration [C]. Proc of the 27th Annual Conf of IEEE Industrial Electronics Society. Denver, 2001: 1794-1799.
- [6] Xi N, Tarn Z J. Action synchronization and control of Internet-based telerobotic systems [C]. Proc IEEE Int Conf on Robotics and Automation. 1999, 1: 219-224.
- [7] Wrege D E, Liebeherr J. Video traffic characterization for multimedia networks with a deterministic service [C]. Proc of INFOCOM '96. San Francisco, 1996: 537-544.
- [8] Daigle J N, Langford J D. Models for analysis of packet voice communication systems [J]. IEEE J on SAC, 1986, 4(6): 847-855.
- [9] Beran J, Sherman R, Taqqu M S, et al. Long-range dependence in variable-bit rate video traffic [J]. IEEE Trans on Communications, 1995, 43(2): 1566-1579.
- [10] Crovella M, Bestavros A. Self-similarity in world wide web traffic: Evidence and possible causes [C]. ACM SIGMETRICS '96, 1996: 160-169.

(下转第1428页)

的分布进行分散模糊推理和加权综合获得加热炉炉温动态补偿量的分布信息,为钢坯温度分布模糊控制提供了一种有效方法.

参考文献(References)

- [1] Anton Jaklic, Franci Vode, Tomaz Kolenko. Online simulation model of the slab-reheating process in a pusher-type furnace[J]. Applied Thermal Engineering, 2007, 27(5/6): 5-6.
- [2] 柴天佑, 王中杰, 张莉. 加热炉的炉温优化设定模型[J]. 自动化学报, 2000, 26(4): 537-541.
(Chai T Y, Wang Z J, Zhang L. Optimal setting model of reheating furnace temperature [J]. Acta Automatic Sinica, 2000, 26(4): 537-541.)
- [3] 毕长春, 李柠, 黄道. 蓄热式加热炉钢温预报与炉温优化设定研究[J]. 自动化学报, 2004, 30(3): 476-480.
(Bi C C, Li N, Huang D. Study on billet temperature prediction and furnace temperature optimal setting of regenerative reheating furnace [J]. Acta Automatic Sinica, 2004, 30(3): 476-480.)
- [4] Man Young Kim. A heat transfer model for the analysis of transient heating of the slab in a direct-fired walking beam type reheating furnace[J]. Int J of Heat and Mass Transfer, 2007, 50(19/20): 3740-3748.
- [5] Wang Z J, Wu Q D, Chai T Y. Optimal-setting control for complicated industrial process and its application study[J]. Control Engineering Practice, 2004, 12(1): 65-74.
- [6] 王中杰, 柴天佑, 邵诚. 加热炉多模式动态优化控制策略[J]. 控制与决策, 1999, 14(5): 465-468.
(Wang Z J, Chai T Y, Shao C. Multimode dynamic optimization control strategy for reheating furnaces[J]. Control and Decision, 1999, 14(5): 465-468.)
- [7] 王锡怀, 李柠, 李少远, 等. 步进式加热炉建模和炉温优化设定策略[J]. 上海交通大学学报, 2001, 35(9): 1306-1309.
(Wang X H, Li N, Li S Y, et al. Modeling and temperature optimal setpoint strategy for walking beam reheating furnace [J]. J of Shanghai Jiaotong University, 2001, 35(9): 1306-1309.)
- [8] 张卫军, 陈海耿, 吴雪琦, 等. 带有前馈修正的炉温智能模糊控制器的开发[J]. 钢铁研究学报, 2006, 18(12): 59-62.
(Zhang W J, Chen H D, Wu X Q, et al. Exploitation of intelligent fuzzy controller for furnace temperature with feed forward correction[J]. J of Iron and Steel Research, 2006, 18(12): 59-62.)
- (上接第 1424 页)
- [11] Thompson K, Miller G J, Wilder R. Wide-area Internet traffic patterns and characteristics[J]. IEEE Network, 1997, 11(6): 10-23.
- [12] Granger C W J, Joyeux R. An introduction to long-memory time series models and fractional Differencing [J]. J of Time Series Analysis, 1980, 1: 15-29.
- [13] Low S. Multipath optimization flow control[C]. Proc of IEEE Conf on Networks. Washington D1, 2000: 39-43.
- [14] Adas A. Traffic models in broadband networks [J]. IEEE Communications Magazine, 1997, 7: 82-89.
- [15] Leland W E, Willinger W, Taqqu M S. On the self-similar nature of Ethernet Traffic [C]. Proc of SIGCOM, California, 1993:183-193.
- [16] 崔锦泰, 程正兴. 小波分析导论[M]. 西安: 西安交通大学出版社, 1995.
(Chui C K, Cheng Z X. An introduction to wavelets [M]. Xi'an: Xi'an Jiaotong University Press, 1995.)
- [17] 文成林, 周东华. 多尺度估计理论及其应用[M]. 北京: 清华大学出版社, 2002.
(Wen C L, Zhou D H. Multiscale estimation theory and application [M]. Beijing: Tsinghua University Press, 2002.)
- [18] Daudi K, Frakt A B, Willsky A S. Multiscale autoregressive models and wavelets[J]. IEEE Trans on Information Theory, 1999, 45(3): 828-845.
- [19] Fieguth P W, Willsky A S. Fractal estimation using models on multiscale trees[J]. IEEE Trans on Signal Processing, 1996, 44(5): 1297-1300.
- [20] Box G E P, Jenkins G M. Time series analysis: Forecasting and control[M]. 2nd ed. San Francisco, 1976.
- [21] 孙增圻. 智能控制理论与技术[M]. 北京: 清华大学出版社, 1997.
(Sun Z Q. Intelligent control theory and technology [M]. Beijing: Tsinghua University Press, 1997.)
- [22] 闻新, 周露, 李翔, 等. Matlab 神经网络仿真与应用[M]. 北京: 科学出版社, 2003.
(Wen X, Zhou L, Li X. et al. Matlab neural networks simulation and application[M]. Beijing: Science Press, 2003.)