

基于 KPCA 与 LSSVM 的网络控制系统 时延预测方法

田中大, 高宪文, 李 琨

(东北大学信息科学与工程学院, 辽宁 沈阳 110819)

摘要: 针对网络控制系统中随机时延很难精确预测的问题, 首次将核主成分分析(kernel principal component analysis, KPCA)与最小二乘支持向量机(least squares support vector machine, LSSVM)结合对随机时延进行预测, KPCA 对输入随机时延序列降维, 消除重复性与噪声, 减少 LSSVM 的运算量, 降维后的时延序列通过 LSSVM 算法预测时延值。仿真结果表明, 基于 KPCA 与 LSSVM 的时延预测方法的预测精度高于其他的预测方法。

关键词: 网络控制系统; 时延预测; 核主成分分析; 最小二乘支持向量机

中图分类号: TP 273

文献标志码: A

DOI: 10.3969/j.issn.1001-506X.2013.06.25

Networked control system time-delay prediction method based on KPCA and LSSVM

TIAN Zhong-da, GAO Xian-wen, LI Kun

(School of Information Science & Engineering, Northeastern University, Shenyang 110819, China)

Abstract: The random delay of networked control system is difficult to predict accurately. Firstly the kernel principal component analysis (KPCA) and the least squares support vector machine (LSSVM) algorithm are combined to predict the random time-delay. The KPCA can reduce dimensionality of input random time-delay sequence, eliminate the noise and interference and reduce the amount of computation of the LSSVM algorithm. The time-delay is predicted by the LSSVM algorithm through the time-delay sequence after dimensionality reduction. The simulation results show that the prediction accuracy of the time-delay prediction based on the KPCA and LSSVM algorithm is higher than the other prediction methods.

Keywords: networked control system (NCS); time-delay prediction; kernel principal component analysis (KPCA); least squares support vector machine (LSSVM)

0 引言

在具有随机时延的网络控制系统(networked control system, NCS)中, 由于时延具有时变和随机的特性, 因此, 时延是影响系统性能的一个重要的因素。如何准确地对 NCS 中的时延进行预测是影响系统性能的重要问题, 通过时延的预测可以使控制系统提前做出反应和控制。

网络时延序列在一定的观测范围内具有平稳的序列特性, 因此对时延可通过自回归(auto-regressive, AR)方法建模预测。文献[1-2]中针对 NCS 的随机时延, 利用 AR 模型建模, 对 NCS 系统中的随机时延进行预测。文献[3]利用离线矢量化(vector quantization, VQ)方法建立 AR 模型来预测时延。文献[4]通过参数自整定模型对网络时延进

行预测。采用 AR 方法的预测需要对时延模型精确建模, 其模型的参数求解过程复杂, 很难在线递推, 不适合网络时延动态变化范围很大的情况。

神经网络具有非线性辨识能力, 且运算速度快, 因此, 很多文献利用神经网络来进行时延的预测。文献[5]采用自适应线性神经网络模型预测不确定性时延, 仿真表明预测效果很好。文献[6]通过扩展 Elman 神经网络结构来预测网络时延。文献[7]通过多层感知器神经网络进行时延预测, 仿真指出该方法较其他方法更精确且实时性更好。文献[8]在每个采样时刻利用一个前馈(feed forward)多层神经网络对时延进行预测, 将这个时延作为当前和未来采样时刻的时延。基于神经网络的时延预测方法存在的问题是易于限于局部最优值以及过分依赖输入时延序列的自相关系数。

支持向量机(support vector machine, SVM)算法对于非线性、小样本以及高维模式的识别问题具有一定的优势,可以用于具有强烈非线性的网络随机时延的预测。文献[9]提出了采用混沌-SVM模型对互联网时延进行预测,仿真验证其短期预测更为准确。文献[10]利用最小二乘SVM(least squares SVM, LSSVM)对网络时延进行预测,将径自基函数(radical basis function, RBF)作为LSSVM的核函数,仿真表明对随机时延有较高的精度,但文章没给出LSSVM具体的实时性如何。文献[11]针对Internet时延,利用LSSVM对时延进行预测,仿真结果表明准确率高。但是基于SVM的算法普遍存在参数不好确定,运算时间长等缺点,对于在线应用存在一定问题。

对网络时延数据进行分析,研究其数学分布规律,进而对时延进行预测也是研究的方向之一。文献[12-14]分析指出网络时延的抖动与网络数据流量存在一定的联系,网络数据流量的长相关自相似特性影响网络时延大小,网络时延在一定观测尺度内同样具有长相关自相似的特点。文献[15]通过测试指出Internet时延符合平移gamma分布,通过对样本概率密度曲线拟合方法估计平移gamma分布的参数对时延进行预测。文献[16]通过对大量测试数据分析,发现网络时延符合平行移位gamma分布(parallel shift gamma distributing, PSGD),确定PSGD的参数即可对时延进行预测。基于统计分析的预测存在的问题为数学分布的参数难以确定,同时由于时延的随机性,参数确定后其预测精度很难保证。

目前对于NCS的时延预测研究成果虽然很多,但大多存在预测精度低、实时性差或者算法过于复杂的问题。本文利用核主成分分析(kernel principal component analysis, KPCA)与LSSVM结合方法对时延进行预测,减少了LSSVM算法的运算量,提高了预测精度。

1 LSSVM 算法

SVM是以有限样本统计学习理论发展起来的新型机器学习方法,已在模式识别、时间序列预测等方面取得了很大进展。设 $d(t)$ 为 t 时刻的网络时延, m 代表过去 m 个时刻,基于SVM预测模型的输入向量可表示为

$$\mathbf{D}_t = [d(t), d(t-1), \dots, d(t-m)] \quad (1)$$

$(t+1)$ 时刻网络时延可预测为

$$d(t+1) = F(\mathbf{D}_t) \quad (2)$$

式中, $F(\cdot)$ 是SVM拟合的非线性函数,利用过去 t 到 $(t-m)$ 时刻的时延数据来预测 $(t+1)$ 时刻的时延。根据基于SVM时间序列,该拟合函数可定义为

$$F(\mathbf{D}) = \sum_{i=1}^N a_i k(\mathbf{D}_i, \mathbf{D}_j) + b \quad (3)$$

式中, a_i 为支持向量的加权系数; b 为偏差; $k(\mathbf{D}_i, \mathbf{D}_j)$ 为核函数,对于时间序列预测多采用径向基函数(radial basic function, RBF)作为核函数

$$k(\mathbf{D}_i, \mathbf{D}_j) = \exp(-\|\mathbf{D}_i - \mathbf{D}_j\|^2 / 2\sigma^2) \quad (4)$$

因此,可通过当前时刻与过去 m 时刻的网络时延序列

作为输入向量,下一时刻的网络时延作为输出向量来进行学习,获取模型中的 a_i 和 b ,学习结束后,即可通过式(3)来预测网络的时延。

标准SVM算法需要求解凸二次规划问题,计算量大、计算时间长,因此文献[17]提出了LSSVM方法,在标准SVM的目标函数中增加误差平方和项,将不等式约束变为等式约束,简化解决过程,提高运算速度,LSSVM通过式(5)对未知系统进行估计^[18]。

$$\mathbf{y} = \mathbf{w}^T \Phi(\mathbf{x}) + b \quad (5)$$

非线性函数 $\Phi(\cdot)$ 作用是将输入的非线性样本数映射到高维特征空间的线性输出。对于给定的样本训练集 $\{x_i, y_i\} (i=1, 2, \dots, N)$,根据风险最小化原理,回归问题可以表示为约束优化问题

$$\begin{cases} \min J(\mathbf{w}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2, \gamma > 0 \\ y_i = \mathbf{w}^T \Phi(x_i) + b + e_i \end{cases} \quad (6)$$

式中, λ 为可调参数; b 为常值偏差参数。上述优化问题可通过Lagrangian函数求解。

$$L(\mathbf{w}, b, \mathbf{e}, \mathbf{a}) = J(\mathbf{w}, \mathbf{e}) - \sum_{i=1}^N a_i (\mathbf{w}^T \Phi(x_i) + b + e_i - y_i) \quad (7)$$

式中, a_i 是拉格朗日乘子。分别对 $\mathbf{w}, b, \mathbf{e}, \mathbf{a}$ 求取偏微分并化简可得到

$$\begin{bmatrix} 0 & \mathbf{l}^T \\ \mathbf{l} & \mathbf{\Omega} + \gamma^{-1} \mathbf{l} \end{bmatrix} \begin{bmatrix} b \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (8)$$

式中, $\mathbf{y} = \{y_1, \dots, y_N\}$; $\mathbf{l} = [1, \dots, 1]^T$; $\mathbf{a} = [a_1, \dots, a_N]$; $\mathbf{\Omega}_{ij} = \phi(x_i)^T \phi(x_j) = K(x_i, x_j) (i, j = 1, 2, \dots, N)$, $K(x_i, x_j)$ 是核函数。对于已知的训练集 $\{x_i, y_i\}$,利用式(8)即可求出参数 \mathbf{a} 与 b ,同时利用训练样本集合通过式(9)可求出系统实际输出 y 。

$$y = \sum_{i=1}^N a_i K(x, x_i) + b \quad (9)$$

2 KPCA 算法

KPCA算法作为一种非线性的PCA方法^[19],在非线性特征提取、分类和模式识别中得到了广泛应用,但是目前还未应用到在时延预测中。利用KPCA针对LSSVM输入的时延序列的特征,去除序列的重复性与噪声,弥补LSSVM算法的不足,发挥两种算法各自的优点。

KPCA算法通过求解核矩阵的特征值与特征向量,避免了特征空间中求解特征向量的复杂问题。对于给定的式(1)的时延样本序列,将其映射到特征空间 $\phi(\mathbf{D}_t) (t=m+1, m+2, \dots, N)$,其中, $\phi(\cdot)$ 为非线性映射, N 为输入时延序列长度, m 为嵌入维数。计算协方差矩阵 \mathbf{C}

$$\mathbf{C} = \frac{1}{N-m} \sum_{t=1+m}^N \phi(\mathbf{D}_t) \phi(\mathbf{D}_t)^T \quad (10)$$

主成分的计算可通过解特征值实现,找到满足式(11)的特征值与特征向量。

$$\lambda \mathbf{V} = \mathbf{C}\mathbf{V} \quad (11)$$

对于 \mathbf{V} 可映射到特征空间的样本矢量线性表示为

$$\mathbf{V} = \sum_{t=1+m}^N \alpha_t \phi(\mathbf{D}_t) \quad (12)$$

式中, α_t 为方程系数。

式(11)左乘 $\phi(\mathbf{D}_i)$ 变为

$$\lambda(\phi(\mathbf{D}_i), \mathbf{V}) = (\phi(\mathbf{D}_i), \mathbf{C}\mathbf{V}) \quad (13)$$

定义一个 $(N-m) \times (N-m)$ 的矩阵 \mathbf{K}_{ij}

$$\mathbf{K}_{ij} = K(\mathbf{D}_i, \mathbf{D}_j) = (\phi(\mathbf{D}_i), \phi(\mathbf{D}_j)) \quad (14)$$

$i, j = 1+m, \dots, N$

计算 α_t 方程系数可转变为求矩阵 \mathbf{K} 的特征向量和特征值

$$(N-m)\lambda \mathbf{a} = \mathbf{K}\mathbf{a} \quad (15)$$

式中, \mathbf{a} 为 $\alpha_t (t=1, 2, \dots, N-m)$ 所组成的列向量。对 \mathbf{V} 归一化, 此时时延序列 $\phi(\mathbf{D}_i)$ 在 V 上的映射为

$$\begin{cases} h_i(\mathbf{D}) = (\mathbf{V}, \phi(\mathbf{D})) = \sum_{t=1+m}^N \alpha_t' \phi(\mathbf{D}_t) \\ \phi(\mathbf{D}) = \sum_{t=1+m}^N \alpha_t' K(\mathbf{D}_t, \mathbf{D}) \end{cases} \quad (16)$$

式中, $h_i(\mathbf{D})$ 为非线性主成分分量。特征值 λ_i 小成分 h_i 一般情况下可视为噪声引起的, 比值 $\lambda_i / \sum_{i=1}^m \lambda_i$ 表示分量 h_i 在整体方差中的贡献程度。主成分按式(17)选取。

$$\left[\sum_{i=1}^k \lambda_i / \sum_{i=1}^m \lambda_i \right] > E \quad (17)$$

式中, k 为选取的主成分数量; E 为选取百分比阈值; m 为输入时延序列所有的成分数量。

以上推导假设 $\sum_{t=1+m}^N \phi(\mathbf{D}_t) = 0$, 而实际样本数据不一定为 0, 因此式(15)中的 \mathbf{K} 为

$$\bar{\mathbf{K}} = \mathbf{K} + \mathbf{L}\mathbf{K} = \mathbf{K}\mathbf{L} + \mathbf{L}\mathbf{K}\mathbf{L} \quad (18)$$

式中, \mathbf{L} 为系数, 是 $1/(N-m)$ 的 $(N-m) \times (N-m)$ 的单位矩阵。

3 KPCA 与 LSSVM 结合时延预测方法

基于 KPCA 与 LSSVM 结合的时延预测方法结构如图 1 所示。




图 1 基于 KPCA 与 LSSVM 的时延预测结构

设输入的时延序列为 \mathbf{D}_t , 将 \mathbf{D}_t 转化为矩阵形式为

$$\mathbf{D} = \begin{bmatrix} d_1 & d_2 & d_3 & \cdots & d_m \\ d_2 & d_3 & d_4 & \cdots & d_{m+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ d_{N-m} & d_{N-m+1} & d_{N-m+2} & \cdots & d_{N-1} \end{bmatrix} \quad (19)$$

式中, d_t 代表 t 时刻的时延值; N 为输入时延序列的总长度; m 为嵌入维数。矩阵式(19)相当于把输入的 $(1 \times N)$ 的时延序列转换为 $(N-m) \times m$ 的矩阵, 而输出的预测时延可

表示为 $(N-m) \times 1$ 矩阵 \mathbf{Y} 。

$$\mathbf{Y} = \begin{bmatrix} d_{m+1} \\ d_{m+2} \\ d_{m+3} \\ \vdots \\ d_N \end{bmatrix} \quad (20)$$

\mathbf{D} 与 \mathbf{Y} 的关系相当于用当前时刻时延与过去 m 个时刻的时延来预测下一时刻的时延, 如果将 \mathbf{D} 与 \mathbf{Y} 直接用于 LSSVM 的训练相当于输入矩阵的列数为 m , 而输入 \mathbf{D} 经过 KPCA 提取主成分之后的时延序列 \mathbf{Z} 的维数是式(17)中的 $k (k < m)$, 因此, 将会减少 LSSVM 运算的复杂程度, 提高了时延预测算法的实时性。

基于 KPCA 与 LSSVM 的方法可总结为如下步骤:

模型训练过程:

步骤 1 将样本时延序列 \mathbf{D}_t 归一化, 转化为式(19)的矩阵 \mathbf{D} 。

步骤 2 将矩阵输入 KPCA 进行主成分提取, 输出为提取后的矩阵 \mathbf{Z} 。

步骤 3 将 \mathbf{Z} 作为输入, \mathbf{Y} 归一化后作为输出对 LSSVM 进行训练, 确定 LSSVM 的参数 γ, σ^2 。

时延在线预测过程:

步骤 1 将新时刻实际时延放入时延序列 \mathbf{D}_t , 将最早 m 时刻时延数据剔除, 数据移位形成新时延序列, 同时更新输出矩阵 \mathbf{Y} 。

步骤 2 将更新后新时延序列 \mathbf{D} 归一化, 转化为式(19)的矩阵。

步骤 3 矩阵 \mathbf{D} 输入 KPCA 降维, \mathbf{Z} 输入 LSSVM 计算未来输出矩阵 \mathbf{Y} , 即为预测时延。

步骤 4 累计时延预测值与实际值之间的误差, 当大于门限 ϵ 时, 认为模型失稳, 按照训练过程重新进行训练求取 LSSVM 模型参数, 保证预测的可靠性。

步骤 5 重复步骤 1~步骤 4。

4 时延样本测量

预测算法的精确度与时延样本的准确是密切相关的, 如何准确获得时延是一个非常重要的问题。单向时延测量需要网络两侧时钟严格同步, 成本比较高, 而往返时延 (round-trip delay time, RTT) 不需要时钟同步, 因此目前测量算法的样本都为 RTT。为了获取准确的时延样本, 本文利用 Visual Basic 软件开发了一套时延测试软件, 该软件通过调用操作系统应用编程接口 (application programming interface, API) 函数 QueryPerformanceCounter 和 QueryPerformanceFrequency 来实现毫秒级的定时精度, 数据传输可选择传输控制协议 (transmission control protocol, TCP) 或是用户数据报协议 (user datagram protocol, UDP) 协议, 同时可以指定发送数据长度。软件定时发送数据包, 远端收到数据包

后即将包返回给发送端,发送时间与接收时间的差值即为网络的 RTT 时延。软件界面如图 2 所示。

算法的 MSE 为 30.011 1。



图 2 时延测量软件

图 3 为某时刻测试出的 500 组数据大小为 64 字节的时延数据,从图 3 可看出网络时延是随机非线性的。




图 4 KPCA 与 LSSVM 预测时延与样本时延比较




图 5 PSO 优化 LSSVM 预测时延与样本比较




图 6 LSSVM 预测时延与样本时延比较




图 7 AR 预测时延与样本时延比较




图 3 时延数据样本

5 仿真与结果分析

利用时延测试软件获得了 310 组的网络随机时延数据,利用前 160 组用于训练,后 150 组用于验证,其中嵌入维数 $m=10$,KPCA 的核函数参数 $\sigma^2=10\ 000$, $E=85\%$,输入时延序列 D ,按式(19)转化为 150×10 的矩阵,经 KPCA 主成分提取后, Z 为 150×6 的矩阵,减少了输入时延序列矩阵的维数,将 Z 用于 LSSVM 的训练,可得 LSSVM 的 $\gamma=3\ 742.59$, $\sigma^2=1\ 394.52$,其中门限 $\epsilon=20$ 。

图 4 给出了利用 KPCA 与 LSSVM 结合方法预测的时延与样本时延的对比图,其均方误差(mean squared error, MSE) 为 0.807。图 5~图 7 为采用粒子群优化(particle swarm optimization, PSO)LSSVM 方法、基本 LSSVM 以及 AR 方法对同一组数据的预测时延与样本时延的比较图。3 种算法嵌入维数都取为 $m=10$,PSO 的种群数量 20,迭代次数为 200, $c1=1.5$, $c2=1.7$,经过 PSO 优化的 LSSVM 的 γ 与 σ^2 分别为 19.263 7 和 0.01,未经 PSO 优化的普通 LSSVM 算法的 γ 与 σ^2 分别为 12.056 6 和 5.309 1。经 PSO 优化 LSSVM 的 MSE 为 2.449 8,基本 LSSVM 的 MSE 为 23.325 1,AR

仿真结果表明,采用 KPCA 与 LSSVM 结合的 NCS 时延预测方法相对于其他方法预测精度更高,同时由于减少了主成分数量,因此具有更好的实时性。

6 结 论

本文针对 NCS 中的随机时延无法准确预测的问题,采用 KPCA 与 LSSVM 结合预测方法对时延进行预测,通过 KPCA 提取时延序列的主成分分量,降低时延序列矩阵的维数,继而通过 LSSVM 训练模型预测未来时刻的时延。仿真结果表明,该方法预测精度更高,且由于运算量降低提高了算法的实时性,为将来利用时延计算未来时刻的控制量打下了良好的基础。

参考文献:

- [1] George B, Nikolaos A, Leonidas D. Feedback stabilization of networked control systems[C]// *Proc. of the 18th IEEE International Conference on Control Applications Part of IEEE Multi-conference on Systems and Control*, 2009:1 - 6.
- [2] Shi W G, Shao C, Sun Z Y. Improved GPC network-control algorithm based on AR model time-delay predication[J]. *Control and Decision*, 2012, 27(3): 477 - 480. (时为国, 邵成, 孙正阳. 基于 AR 模型时延预测的改进 GPC 网络控制算法[J]. 控制与决策, 2012, 27(3): 477 - 480.)
- [3] Yang M, Ru J, Li X R, et al. Predicting Internet end-to-end delay: a multiple-model approach[C]// *Proc. of the IEEE International Conference on Computer Communications*, 2005: 2815 - 2819.
- [4] Shi W G, Sun Z Y. Study of network time delay estimation based on parameter self-adjusting AR model[J]. *Journal of Dalian Jiaotong University*, 2010, 31(4): 83 - 86. (时为国, 孙正阳. 基于参数自校正 AR 模型的网络时延估计[J]. 大连交通大学学报, 2010, 31(4): 83 - 86.)
- [5] Li H Y, Wang H, Gui C. Internet time-delay prediction based on autoregressive and neural network model[C]// *Proc. of the International Conference on Communications, Circuits and Systems*, 2006: 1758 - 1761.
- [6] Liu D, Du J H, Zhao Y, et al. Study on the time-delay of Internet-based industry process control system[C]// *Proc. of the 5th World Conference on Intelligent Control and Automation*, 2002: 1376 - 1380.
- [7] Rahmani B, Markazi A H D, Mozayani N. Real time prediction of time delays in a networked control system[C]// *Proc. of the 3rd International Symposium on Communications, Control and Signal Processing*, 2008: 1242 - 1245.
- [8] Sadeghzaedh N, Afshar A, Menhaj M B. An MLP neural network for time delay prediction in networked control systems[C]// *Proc. of the Chinese Control and Decision Conference*, 2008: 5314 - 5318.
- [9] Cao Q P, Dong S F, Luo Y Q. Chaotic analysis and predication of Internet time-delay[J]. *Computer Technology and Development*, 2010, 20(4): 43 - 46. (曹庆璞, 董淑福, 罗赞骞. 网络时延的混沌特性分析及预测[J]. 计算机技术与发展, 2010, 20(4): 43 - 46.)
- [10] Li C M, Xiao J, Zhang Y. Time delay estimation and adaptive control of networked control systems[J]. *Journal of Southwest Jiaotong University*, 2007, 42(2): 175 - 180. (李春茂, 肖建, 张玥. 网络控制系统的时延估计和自适应预测控制[J]. 西南交通大学学报, 2007, 42(2): 175 - 180.)
- [11] Li X X, Fu X H. A predictive algorithm for time delay Internet based network control [J]. *Chinese Journal of Scientific Instrument*, 2008, 29(4): 590 - 595. (李小明, 符秀辉. 基于 Internet 网络控制的一种时延预测算法[J]. 仪器仪表学报, 2008, 29(4): 590 - 595.)
- [12] Karagiannis T, Molle M, Faloutsos M. Long-range dependence: ten years of Internet traffic modeling[J]. *IEEE Internet Computing*, 2004, 8(5): 57 - 64.
- [13] Erramilli A, Roughtan M, Veitch D, et al. Self-similar traffic and network dynamics[J]. *Processing of the IEEE*, 2002, 90(5): 800 - 819.
- [14] Wang S H, Xu B G, Wang Q Y. Delays analysis for teleportation over Internet and Smith predictor with adaptive time-delay control[C]// *Proc. of the IEEE International Conference on Robotics and Biomimetics*, 2005: 664 - 669.
- [15] Fu X H, Fu X. A predictive algorithm for time delay Internet network[C]// *Proc. of the International Conference on Electronics, Communications and Control*, 2011: 666 - 669.
- [16] Zhao J P, Gao X W. Time-delay analysis and estimation of Internet-based robot teleoperation system[C]// *Proc. of the Chinese Control and Decision Conference*, 2009: 4643 - 4646.
- [17] Suykens J A K, Lukas L, Vandewalle J. Sparse approximation using least squares support vector machines[C]// *Proc. of the IEEE International Symposium on Circuits and Systems*, 2000: 757 - 760.
- [18] Lei B C, Wang W L, Li Z X. Networked predictive control system based on online LS-SVM[J]. *Information and Control*, 2009, 38(2): 163 - 169. (雷必成, 王万良, 李祖欣. 基于在线 LS-SVM 的网络预测控制系统[J]. 信息与控制, 2009, 38(2): 163 - 169.)
- [19] Twining C J, Taylor C J. The use of kernel principal component analysis to model data distributions[J]. *Pattern Recognition*, 2003, 36(1): 217 - 227.

作者简介:

田中大(1978 -), 男, 博士研究生, 主要研究方向为网络控制系统。

E-mail: tianzhongda@126.com

高宪文(1955 -), 男, 教授, 博士研究生导师, 主要研究方向为复杂工业过程建模与智能优化控制。

E-mail: gaoxianwen@ise.neu.edu.cn

李 琨(1983 -), 男, 博士研究生, 主要研究方向为工业过程故障诊断与优化。

E-mail: tubiekun@163.com