

状态时间序列预测的贝叶斯最小二乘支持向量机方法

张弦¹, 王宏力¹, 张金生², 孙渊²

(1. 第二炮兵工程学院自动控制工程系, 710025, 西安; 2. 第二炮兵工程学院精确制导与仿真实验室, 710025, 西安)

摘要: 为对电子系统状态时间序列的有效预测, 提出一种基于贝叶斯证据框架的最小二乘支持向量机在线预测方法. 该方法以逐次增加最新状态数据并剔除最旧状态数据的方式更新最小二乘支持向量机预测模型, 利用分块矩阵求逆运算简化了新旧状态数据交替增减所带来的预测模型重训问题, 通过贝叶斯证据框架实现预测模型超参数的在线动态优化. 应用于雷达发射机中高压电源与多注速调管的状态时间序列预测实例表明, 该方法的预测精度与计算效率比自适应灰色模型方法分别高 9.52% 与 73.26%, 具有预测精度高、预测稳定性高与计算效率高的优点, 适用于电子系统在线状态时间序列预测.

关键词: 最小二乘支持向量机; 贝叶斯证据框架; 电子系统; 雷达发射机; 状态时间序列预测
中图分类号: TP277 **文献标志码:** A **文章编号:** 0253-987X(2010)10-0042-05

A Least Squares Support Vector Machine for Condition Time Series Prediction Based on Bayesian Evidence Framework

ZHANG Xian¹, WANG Hongli¹, ZHANG Jinsheng², SUN Yuan²

(1. Department of Automatic Control Engineering, The Second Artillery Engineering College, Xi'an 710025, China;
2. Laboratory of Accurate Guidance and Simulation, The Second Artillery Engineering Collage, Xi'an 710025, China)

Abstract: A method using Bayesian evidence framework (BEF) and least squares support vector machine (LSSVM) is proposed to predict electronic system condition time series accurately. A LSSVM model for prediction is trained with all the current condition time series data. Then, the LSSVM model is iteratively updated by adopting the latest data and pruning the oldest data. Matrix transform is applied to reduce the computational cost of retraining the LSSVM model. Finally, the updated LSSVM model is dynamically optimized by BEF. Numerical experiments on radar transmitter condition time series prediction are carried out to test the effectiveness of the proposed method. The experimental results and comparisons with the conventional adaptive grey model show that the proposed method has better performance in prediction accuracy, prediction stability and computational efficiency, and that the prediction accuracy and the computational efficiency for electronic system condition time series prediction are raised by 9.52% and 73.26% respectively.

Keywords: least squares support vector machine; Bayesian evidence framework; electronic system; radar transmitter; condition time series prediction

在各类具有复杂结构与功能的电子系统中, 渐退化而不可避免. 这类故障在电子系统故障中占有较大比重, 相对于突发性故障, 具有明显的规律性, 发性故障往往在使用过程中因其组成部件性能逐渐

可通过监测其早期状态时间序列进行预测^[1-4]. 因此,在对电子系统进行状态时间序列监测的基础上,预测系统未来时刻状态并评估其健康状况,根据系统的健康状况预知电子系统发生渐发性故障的概率,则可对渐发性故障的传播与发展做出早期预测,从而实现电子系统的视情维修. 文献[1]提出了一种基于粒子群优化(PSO)的自适应灰色模型预测方法,并应用于电子系统状态时间序列预测,但该方法需利用 PSO 逐次迭代优化以确定灰色模型的最佳预测维数,而迭代过程中则需利用 20 个代表预测维数的粒子建立 20 个不同的灰色模型,经过 10 次以上的比较才可确定最佳预测维数,因此计算效率有待提高.

作为一种基于统计学习理论的机器学习机制,最小二乘支持向量机^[5] (LSSVM) 根据结构风险最小原则,在模型复杂性与学习能力之间寻求最佳折中,有效地避免了传统机器学习方法中存在的局部极值、过学习与维数灾难等缺陷. LSSVM 以误差平方和损失函数作为训练样本集的经验损失,在等式约束条件下,将支持向量机(SVM)中求解凸二次规划问题转化为线性矩阵求解问题,大为缩减了模型训练时间,且算法简捷,已在解决高维、非线性、有限样本的模式识别与回归估计等问题中表现出超越经典机器学习机制的独特优势^[6-7].

超参数是决定 LSSVM 学习精度与推广能力的关键因素,其优化估计方法包括 k 折交叉验证(CV)^[8-9] 与贝叶斯证据框架(BEF)^[10-12] 等. 相比于 k 折交叉验证,贝叶斯证据框架建立在贝叶斯理论之上,以最大化超参数分布后验概率方式获得其最佳解,而不需反复对训练样本集进行交叉验证,具有计算效率高与优化效果显著的特点^[10-12]. 本文针对电子系统状态时间序列动态变化的特点,提出一种基于贝叶斯证据框架的 LSSVM 在线预测方法(BLSSVM),从而实现了电子系统在线状态时间序列预测,最终通过对雷达发射机中高压电源与多注速调管的在线状态时间序列预测实例证明了上述方法的有效性.

1 贝叶斯证据框架

在 LSSVM 回归方法中,贝叶斯证据框架通过最大化超参数分布后验概率方式获得其最佳解,包括 3 个层次的推断:Level1 推断权值参数 $\mathbf{w}$; Level2 推断正则化参数 $\mathbf{c}$; Level3 推断核参数.

1.1 Level1 推断

假设 H 为模型空间, D 为训练样本集,对于给

定的超参数 $\lambda=1/c$,由贝叶斯准则可得 $\mathbf{w}$ 的后验概率为^[10]

$$p(\mathbf{w} | D, \lambda, H) \propto p(D | \mathbf{w}, \lambda, H) p(\mathbf{w} | \lambda, H) \quad (1)$$

假设训练样本独立同分布,且参数 $\mathbf{w}$ 的先验分布 $p(\mathbf{w} | \lambda, H)$ 服从高斯分布,可得 $\mathbf{w}$ 的后验概率

$$p(\mathbf{w} | D, \lambda, H) \propto \exp\left(-\frac{\lambda}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N e_i^2\right) \quad (2)$$

式中: N 为训练样本数目; e_i 为 LSSVM 对每个训练样本的回归误差. 通过最大化式(2)可得 $\mathbf{w}$ 的最佳值 $\mathbf{w}^b$.

1.2 Level2 推断

通过最大化 λ 的后验概率 $p(\lambda | D, H)$ 可得 λ 的最佳值 λ^b , 令 $E_1 = \frac{1}{2} \mathbf{w}^T \mathbf{w}$, $E_2 = \frac{1}{2} \sum_{i=1}^N e_i^2$, 则可得

$$p(\lambda | D, H) \propto \frac{(2\pi\lambda)^{k/2} \exp(-\lambda E_1^b - E_2^b)}{(\det A)^{1/2}} \quad (3)$$

式中: E_1^b 、 E_2^b 分别为 E_1 、 E_2 在 $\mathbf{w}^b$ 处的值; $A = \frac{\partial^2 (\lambda E_1 + E_2)}{\partial \mathbf{w}^2} = \lambda \nabla^2 E_1 + \nabla^2 E_2$. 通过最大化 $\ln p(\lambda | D, H)$ 可得 λ^b .

1.3 Level3 推断

以 $k(x, y) = \exp\left(-\frac{\|x-y\|^2}{r}\right)$ 为核函数(r 为核参数),通过最大化后验概率 $p(H | D)$ 选择 r 的最佳值 r^b . 假设 $p(H)$ 在所有训练样本上服从平坦分布,可得^[10]

$$p(H | D) \propto \int p(D | \lambda, H) p(\lambda | H) d\lambda \propto \frac{p(D | \lambda^b, H)}{r^{1/2}} \quad (4)$$

通过最大化 $\ln p(H | D)$ 可得 r^b .

2 基于贝叶斯证据框架的 LSSVM 在线训练

传统的 LSSVM 训练算法利用全部训练样本建立所需的 LSSVM,是一种针对固定训练样本集的离线训练算法. 当有新训练样本加入时,无法在原 LSSVM 基础上自适应地更新而需重新训练. LSSVM 在线训练算法使 LSSVM 的训练过程可随训练样本的增减变化而自适应地调整,以跟踪被模拟系统的当前动态特性. 已有 LSSVM 在线训练算法中^[13], LSSVM 的超参数在进入在线训练过程后一直保持不变,而当存在新旧训练样本交替增减时, LSSVM 的超参数也应随之不断变化,同一组超参

数将难以使 LSSVM 始终保持所需预测精度. 因此, 本文提出一种基于贝叶斯证据框架的在线 LSSVM 预测方法, 使每次 LSSVM 在训练样本的增减变化后, 超参数随预测精度而动态调整, 从而使当前 LSSVM 模型始终保持所需预测精度.

假设利用训练样本集 $\{(x_i, y_i)\}_{i=t}^{m+t-1}$ (m 为训练样本集容量) 训练 LSSVM, 计算所得增减训练样本前的回归矩阵 $\boldsymbol{Q}(t)$ 与 $\boldsymbol{Q}^{-1}(t)$, 在此基础上对当前 LSSVM 预测模型 $M(t)$ 进行在线训练.

2.1 增样训练

由 $\boldsymbol{Q}(t)$ 的构成可知, 当有新训练样本 (x_{m+t}, y_{m+t}) 加入时, 相应的回归矩阵变化为

$$\tilde{\boldsymbol{Q}}(t) = \begin{bmatrix} \boldsymbol{Q}(t) & \boldsymbol{P}(t) \\ \boldsymbol{P}^T(t) & S(t) \end{bmatrix} \quad (5)$$

式中: $\boldsymbol{P}(t) = [k(x_t, x_{m+t}), \dots, k(x_{m+t-1}, x_{m+t})]^T$; $S(t) = k(x_{m+t}, x_{m+t}) + \frac{1}{c}$. 根据分块矩阵求逆引理可得^[13]

$$\begin{aligned} \tilde{\boldsymbol{Q}}^{-1}(t) = & \\ \begin{bmatrix} \boldsymbol{Q}^{-1}(t) + \boldsymbol{Q}^{-1}(t)\boldsymbol{P}(t)F(t)\boldsymbol{P}^T(t)\boldsymbol{Q}^{-1}(t) & -\boldsymbol{Q}^{-1}(t)\boldsymbol{P}(t)F(t) \\ -F(t)\boldsymbol{P}^T(t)\boldsymbol{Q}^{-1}(t) & F(t) \end{bmatrix} & \end{aligned} \quad (6)$$

式中: $F(t) = (S(t) - \boldsymbol{P}^T(t)\boldsymbol{Q}^{-1}(t)\boldsymbol{P}(t))^{-1}$.

2.2 减样训练

当加入新训练样本 (x_{m+t}, y_{m+t}) 后, 通过剔除旧训练样本 (x_i, y_i) 以缩减 $M(t)$ 规模, 同时提高建模效率. 相应的回归矩阵 $\boldsymbol{Q}(t+1)$ 与 $\tilde{\boldsymbol{Q}}(t)$ 间存在如下关系

$$\tilde{\boldsymbol{Q}}(t) = \begin{bmatrix} \tilde{\boldsymbol{S}}(t) & \tilde{\boldsymbol{P}}^T(t) \\ \tilde{\boldsymbol{P}}(t) & \boldsymbol{Q}(t+1) \end{bmatrix} \quad (7)$$

式中: $\tilde{\boldsymbol{P}}(t) = [k(x_{t+1}, x_t), \dots, k(x_{m+t}, x_t)]^T$; $\tilde{\boldsymbol{S}}(t) = k(x_t, x_t) + \frac{1}{c}$. 假设 $\tilde{\boldsymbol{Q}}^{-1}(t) = \begin{bmatrix} \boldsymbol{Q}_{11} & \boldsymbol{Q}_{12} \\ \boldsymbol{Q}_{21} & \boldsymbol{Q}_{22} \end{bmatrix}$, $\boldsymbol{Q}_{12} = \boldsymbol{Q}_{21}^T$, 根据分块矩阵求逆引理可得^[13]

$$\boldsymbol{Q}^{-1}(t+1) = \boldsymbol{Q}_{22} - \boldsymbol{Q}_{21}\boldsymbol{Q}_{12}/\boldsymbol{Q}_{11} \quad (8)$$

表 1 3 种预测方法离线预测结果比较

预测方法	纹波电压平均 绝对误差/V	阴极电流平均 绝对误差/mA	纹波电压平均 相对误差/%	阴极电流平均 相对误差/%	纹波电压预测 耗费时间/s	阴极电流预测 耗费时间/s
BLSSVM	1.591 1	3.609 9	2.093 7	0.472 5	0.607 8	0.392 2
CVLSSVM	2.420 3	1.834 6	3.122 1	0.242 5	8.875 0	8.921 9
PSOAGM	5.189 6	13.954 4	6.779 6	1.809 4	0.237 7	0.239 0

2.3 在线训练与预测

基于贝叶斯证据框架的 LSSVM 在线训练与预测过程描述如下:

(1) 设定初始 $c = c^{\text{ini}}$, $r = r^{\text{ini}}$, $\{(x_i, y_i)\}_{i=t}^{m+t-1}$ 的容量为 m , 并置 $t=1$;

(2) 在初始 $c = c^b(t-1)$ ($c^b(0) = c^{\text{ini}}$) 与 $r = r^b(t-1)$ ($r^b(0) = r^{\text{ini}}$) 条件下, 推断其适用于 $\{(x_i, y_i)\}_{i=t}^{m+t-1}$ 的最佳值 $c^b(t)$ 与 $r^b(t)$;

(3) 计算 $c^b(t)$ 与 $r^b(t)$ 条件下的最佳 $M^b(t)$, 利用 $M^b(t)$ 对 y_{m+t} 进行一步预测, 得到其预测值 $\tilde{y}_{m+t}$;

(4) 增加 (x_{m+t}, y_{m+t}) 并剔除 (x_t, y_t) , $t=t+1$ 后转至步骤(2).

3 电子系统状态时间序列预测

作为雷达发射机的核心部件, 高压电源与多注速调管的状态直接关系到雷达发射机的可靠性. 以某型雷达发射机^[1]的高压电源与多注速调管在等时间间隔采样条件下采集的 40 个纹波电压数据与阴极电流数据为例, 分别采用离线预测与在线预测方式测试本文方法的预测精度与计算效率.

(1) 离线预测. 选择嵌入维数 5, 分别构成 35 组样本用于预测模型训练与测试. 利用前 25 组样本训练预测模型, 利用后 10 组样本测试, 预测结果如表 1 所示. 本文 BLSSVM 方法为基于贝叶斯框架的 LSSVM, 初始 $c = 100$, $r = 10$. CVLSSVM 为基于 PSO 的 5 折交叉验证的 LSSVM 方法, 其中 PSO 设置的粒子群规模为 10, 最大进化代数为 10, 惯性权值范围为 $[0.4, 0.9]$, $c \in [100, 100\ 000]$, $r \in [10, 10\ 000]$. PSOAGM 为文献[1]中基于 PSO 的自适应灰色模型(参数设置可参见文献[1]).

在离线预测情况下, BLSSVM 与 CVLSSVM 方法可准确跟踪纹波电压与阴极电流的变化状况, 预测精度并未随预测步数的增多而显著下降. PSO-AGM 方法则只在外推 1 步至 3 步时较好保持了预测精度, 随预测步数的增多, 其预测精度显著增大. 从表 1 可见, 在预测精度方面, BLSSVM 与 CVLSSVM 的平均绝对误差与平均相对误差相近, 且

显著小于 PSOAGM 的误差,因此预测精度更高。

(2)在线预测. 以离线预测中相同的构成方式构成在线预测训练与测试样本. 将前 5 组样本作为预测模型的初始训练样本集,在线预测剩余 30 组样本. LSSVM 为文献[13]提出的 c 与 r 不随新旧训练样本交替增减而变化的在线 LSSVM. 表 2 与表 3 为 BLSSVM 与 LSSVM 在不同初始 c 与 r 情况下的预测结果与 PSOAGM 结果的比较. 在预测精度方面,BLSSVM 优于 PSOAGM 与 LSSVM. 在预测稳定性方面,BLSSVM 根据贝叶斯证据框架可自适

应计算出适用于当前训练样本集的最佳 c^b 与 r^b ,即使在初始 c 与 r 变化 1 000 倍的范围内,平均绝对误差与平均相对误差的变化也较小. LSSVM 的平均绝对误差与平均相对误差随初始 c 与 r 的增长,变化超过 20 倍,预测精度严重依赖于初始 c 与 r ,预测稳定性较差. 在计算效率方面,PSOAGM 需利用 PSO 逐次迭代优化以确定灰色模型的最佳预测维数,预测耗费时间显著多于 BLSSVM,因此相比于 LSSVM 与 PSOAGM,BLSSVM 更适于电子系统在线状态时间序列预测。

表 2 纹波电压的 3 种预测方法在线预测结果比较

c	r	电压平均绝对误差/V			电压平均相对误差/%			预测耗费时间/s		
		BLSSVM	LSSVM	PSOAGM	BLSSVM	LSSVM	PSOAGM	BLSSVM	LSSVM	PSOAGM
10	1	0.207 2	5.510 9	0.227 1	0.365 5	10.916 1	0.408 9	2.609 4	0.515 6	6.091 2
100	10	0.211 7	2.340 6	0.227 1	0.372 3	4.510 3	0.408 9	2.390 6	0.503 8	6.091 2
1 000	100	0.203 1	0.639 3	0.227 1	0.359 9	1.262 6	0.408 9	1.796 9	0.547 3	6.091 2
10 000	1 000	0.200 7	0.234 5	0.227 1	0.354 3	0.419 9	0.408 9	1.453 1	0.586 1	6.091 2

表 3 阴极电流的 3 种预测方法在线预测结果比较

c	r	电流平均绝对误差/mA			电流平均相对误差/%			预测耗费时间/s		
		BLSSVM	LSSVM	PSOAGM	BLSSVM	LSSVM	PSOAGM	BLSSVM	LSSVM	PSOAGM
10	1	1.469 1	18.816 7	1.608 1	0.218 7	2.764 5	0.240 6	1.562 5	0.531 3	6.170 6
100	10	1.469 1	6.478 9	1.608 1	0.218 7	0.953 5	0.240 6	1.453 1	0.546 9	6.170 6
1 000	100	1.482 2	1.984 3	1.608 1	0.222 0	0.292 2	0.240 6	1.156 3	0.578 1	6.170 6
10 000	1 000	1.525 8	1.572 2	1.608 1	0.227 7	0.235 2	0.240 6	0.671 9	0.562 5	6.170 6

4 结 论

状态时间序列预测作为增强电子系统故障早期发现能力的一种重要手段,通过对潜在劣化趋势的早期预测,既可减少因维修过剩而引起的维护费用上升,也可防止因维修不足而导致事故的发生. 将状态时间序列预测有效应用于工程实践的关键在于所采用预测方法的优劣. 本文提出的 BLSSVM 方法集合了统计学习理论与贝叶斯证据框架的优势,具有坚实的理论基础、简洁的数学形式与优良的泛化能力,在纹波电压与阴极电流的离线预测与在线预测实例中,表现出预测精度高、预测稳定性高与计算效率高的优点,因此可望为电子系统的状态时间序

列预测提供一条有效的解决途径。

参考文献:

[1] 许丽佳. 电子系统的故障预测与健康管理技术研究 [D]. 成都: 电子科技大学自动化工程学院, 2009.

[2] 孙博, 康锐, 张叔农. 基于特征参数趋势进化的故障诊断和预测方法[J]. 航空学报, 2008, 29(2): 393-398.

SUN Bo, KANG Rui, ZHANG Shunong. An approach to diagnostics and prognostics based on evolutionary feature parameters [J]. Acta Aeronautica et Astronautica Sinica, 2008, 29(2): 393-398.

[3] GOEL A, GRAVES R J. Electronic system reliability: collating prediction models [J]. IEEE Transactions on Device and Materials Reliability, 2006, 6(2): 258-265.

- [4] PARRY J D, RANTALA J, LASANCE C J M. Enhanced electronic system reliability challenges for temperature prediction [J]. IEEE Transactions on Components and Packaging Technologies, 2002, 25(4): 533-538.
- [5] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [6] PENG Xinjun, WANG Yifei. A normal least squares support vector machine (NLS-SVM) and its learning algorithm [J]. Neurocomputing, 2009, 72(16/17/18): 3734-3741.
- [7] CHOI Y S. Least squares one-class support vector machine [J]. Pattern Recognition Letters, 2009, 30(13): 1236-1240.
- [8] HAO Peiyi, CHIANG Jung-hsien. Fuzzy regression analysis by support vector learning approach [J]. IEEE Transactions on Fuzzy Systems, 2008, 16(2): 428-441.
- [9] SLOIN A, BURSHTEN D. Support vector machine training for improved hidden markov modeling [J]. IEEE Transactions on Signal Processing, 2008, 56(1): 172-188.
- [10] KOWK J T. The evidence framework applied to support vector machines [J]. IEEE Transactions on Neural Network, 2000, 11(5): 1162-1173.
- [11] GESTEL T V, SUYKENS J A K, BAESTAENS D K, et al. Financial time series prediction using least squares support vector machines within the evidence framework [J]. IEEE Transactions on Neural Network, 2001, 12(4): 809-821.
- [12] 陆晓峰, 郑南宁, 袁泽剑. 证据框架与自由能框架 [J]. 西安交通大学学报, 2003, 37(2): 167-170.
LU Xiaofeng, ZHENG Nanning, YUAN Zejian. Evidence framework and free energy framework [J]. Journal of Xi'an Jiaotong University, 2003, 37(2): 167-170.
- [13] 张浩然, 汪晓东. 回归最小二乘支持向量机的增量和在线式学习算法 [J]. 计算机学报, 2006, 29(3): 400-406.
ZHANG Haoran, WANG Xiaodong. Incremental and online learning algorithm for regression least squares support vector machine [J]. Chinese Journal of Computers, 2006, 29(3): 400-406.

[本刊相关文献链接]

具有小世界特性的复杂液压系统故障源搜索方法. 西安交通大学学报, 2010, 44(7): 79-84.

采用遗传算法的自适应随机共振系统弱信号检测方法研究. 西安交通大学学报, 2010, 44(3): 32-36.

利用非线性流形学习的轴承早期故障特征提取方法. 西安交通大学学报, 2010, 44(5): 45-49.

一类支持向量机的设备状态自适应报警方法. 西安交通大学学报, 2009, 43(11): 61-65.

基于非线性流形学习的喘振监测技术研究. 西安交通大学学报, 2009, 43(7): 44-48.

一种基于密度加权的最小二乘支持向量机稀疏化算法. 西安交通大学学报, 2009, 43(10): 11-15.

具有模糊隶属度的模糊支持向量机算法. 西安交通大学学报, 2009, 43(7): 40-42.

一种新的选择性支持向量机集成学习算法. 西安交通大学学报, 2008, 42(10): 1221-1225.

加权支持向量机求解路径算法研究. 西安交通大学学报, 2008, 42(10): 1226-1229.

一类具有未知干扰的 Markov 跳变系统故障检测. 西安交通大学学报, 2007, 41(4): 458-462.

面向分类去噪问题的模糊支持向量机新算法. 西安交通大学学报, 2007, 41(12): 1414-1418.

ϵ 不敏感损失函数支持向量机分类性能研究. 西安交通大学学报, 2007, 41(11): 1315-1320.

基于支持向量机的发动机故障诊断. 西安交通大学学报, 2007, 41(9): 1124-1126.

采用支持向量机评估老年人步态对称性的研究. 西安交通大学学报, 2007, 41(8): 995-999.

支持向量机在电力变压器故障诊断中的应用. 西安交通大学学报, 2007, 41(6): 722-726.

基于改进的加权最小二乘支持向量机的空间桁架建模. 西安交通大学学报, 2007, 41(1): 119-121.

基于喘振频域特性的失稳预警技术研究. 西安交通大学学报, 2007, 41(11): 1321-1325.

一类基于模糊系统的非线性鲁棒自适应预测控制. 西安交通大学学报, 2008, 42(6): 669-673.

自适应移频变尺度随机共振在故障诊断中的应用. 西安交通大学学报, 2009, 43(7): 69-73.

(编辑 刘杨)