

doi: 10.7690/bgzdh.2018.07.015

## 基于 LS-SVM 的新机备件需求预测

孙伟奇<sup>1</sup>, 周斌<sup>1</sup>, 史玉敏<sup>1</sup>, 孙吉良<sup>2</sup>

(1. 海军航空大学青岛校区, 山东 青岛 266041; 2. 中国人民解放军 91206 部队, 山东 青岛 266108)

**摘要:** 为解决因新机备件历史消耗数据相对较少而给备件预测工作带来的困难, 提出应用最小二乘支持向量机 (least squares support vector machine, LS-SVM) 回归算法来实现新机备件需求的预测。阐述了最小二乘支持向量机的基本原理, 建立了新机备件需求的预测模型, 选取核函数, 采用 LS-SVM 对训练样本进行学习, 对其网格结构参数进行训练, 通过十字交叉验证 (cross-validation) 和网格搜索 (grid-search) 确定最优参数, 利用训练后的 LS-SVM 对新机备件需求进行预测, 并进行算例仿真。结果表明, LS-SVM 在新机备件需求预测上表现优秀。

**关键词:** 新机; 备件; 历史数据; 需求预测; 最小二乘支持向量机

**中图分类号:** V19    **文献标志码:** A

## Demand Prediction of New Aircraft Spare Parts Based on LS-SVM

Sun Weiqi<sup>1</sup>, Zhou Bin<sup>1</sup>, Shi Yumin<sup>1</sup>, Sun Jiliang<sup>2</sup>

(1. Qingdao Campus, Navy Aeronautical University, Qingdao 266041, China;  
2. No. 91206 Unit of PLA, Qingdao 266041, China)

**Abstract:** Aiming at the difficulties caused by little history consumption data of new aircraft spare parts on spare parts predication, put forward the LS-SVM regression algorithm to realize the new aircraft spare parts demand prediction. Introduce the LS-SVM basic principle, establish the new aircraft demand predication model, select kernel function, use LS-SVM to learn the training sample, and train its network structure parameter. Ascertain the optimal parameter by cross-validation and grid-search. Use trained LS-SVM to predict the new aircraft spare part demand, and carry out example simulation. The results proved the excellent effectiveness of LS-SVM in new aircraft spare parts demand predication.

**Keywords:** new aircraft; spare parts; history data; demand prediction; least squares support vector machines (LS-SVM)

### 0 引言

“备件通常是指为保持或者恢复飞机主机、机载装设备和地面保障设备设计性能指标所需的零配件以及用于修理更换的成品替换件等” (依据 HB7384《军用飞机备件配置要求》)<sup>[1]</sup>。可见, 备件是保证飞机正常飞行的必不可少的物质基础。近几年, 随着军事斗争准备的深入发展, 我军装备建设得到了跨越式发展, 航空兵部队陆续装备了多种型号的新机, 由于列装时间不长, 保障经验不足, 对这些新机备件的保障水平还比较低。究其原因, 主要在于新机备件历史消耗数据不多, 对备件的消耗规律较难把握, 从而影响备件需求预测和计划订货的准确性。在新机备件采购总经费一定的前提下, 某种备件订多了会挤占有限的订货经费甚至造成浪费; 订少了则会直接导致缺件停飞, 影响战备、训练工作的正常开展。当前, 针对备件需求的预测方法很多, 应用比较成熟的有人工神经网络法、指数组平滑法、回归分析法、最小二乘拟合法和时间序列法等<sup>[2]</sup>, 这些方法都是基于长期积累的大量历史数

据样本, 通过构建相应的数学模型, 最终实现对将来一段时间内备件需求的预测; 但是, 对于小样本数据问题, 上述方法的预测效果并不理想。而新机列装时间短的特点决定了其用来参考的历史样本数据必然很少, 导致以往通过大样本的历史数据实现备件需求预测的方法不可行<sup>[3]</sup>。

1995 年, Vapnik 等提出了支持向量机 (support vector machine, SVM) 方法<sup>[4-5]</sup>。它基于统计学的 VC 维理论和结构风险最小化原理, 同时又兼顾学习算法的经验风险和推广能力, 能够基于较少的样本数据, 在模型的复杂性 (即对特定训练样本的学习精度) 和学习能力 (即正确地识别任意样本的能力) 之间寻求最佳平衡点, 从而获得最好的泛化能力, 对解决小样本、非线性、高维数和局部极小点等实际问题效果较好。20 世纪 90 年代末, 美国 Johan A.K.Suykens 等又在标准 SVM 的目标函数中新引入了误差平方和项, 提出了一种改进型支持向量机方法, 即最小二乘支持向量机 (LS-SVM) 方法<sup>[6-7]</sup>, 把标准 SVM 的求解二次规划问题转换为线性方程组求解, 降低了求解的复杂程度, 使运算速度加快。

收稿日期: 2018-03-28; 修回日期: 2018-04-17

基金项目: 海军装备维修课题“航材消耗周转定额” (ZJH/材 2011-1055/D001)

作者简介: 孙伟奇 (1982—), 男, 山东人, 硕士, 讲师, 从事航材管理研究。

笔者阐述了最小二乘支持向量机的基本原理，构建了基于 LS-SVM 的新机备件需求预测模型，并结合某型新机备件的历史消耗数据，通过计算机仿真对模型进行了验证和分析，进而证明了该方法在新机备件需求预测问题上的科学性和有效性。

## 1 LS-SVM 基本原理<sup>[8-10]</sup>

假设训练样本集  $D = \{(x_k, y_k) | k=1, 2, \dots, N\}$ ,  $x_k \in R^n$ ,  $y_k \in R$ ,  $x_k$  是输入的训练样本数据,  $y_k$  是输出的训练样本数据,  $N$  为训练样本集中的样本数量。根据 LS-SVM 理论, 应用非线性函数  $\varphi$ , 将输入空间  $R^n$  映射到一个高维的线性可分的特征空间, 从而解决其在原始空间中线性不可分的问题。

在线性可分的高维特征空间中构造最优决策函数:  $y(x) = \omega^T \varphi(x) + b$ ,  $\omega$  是权向量,  $b$  是偏差量。根据 LS-SVM 结构风险最小化理论, 上述优化问题求解可描述为

$$\min_{\omega, b, e} J(\omega, e) = \frac{1}{2} \omega^T \omega + \frac{\gamma}{2} \sum_{k=1}^N e_k^2,$$

满足约束条件

$$y_k = \omega^T \varphi(x_k) + b + e_k, k=1, 2, \dots, N.$$

式中: 目标函数的第一项  $\frac{1}{2} \omega^T \omega$  用于描述模型的泛化能力, 第二项  $\frac{\gamma}{2} \sum_{k=1}^N e_k^2$  与模型的精确性相对应; 正则化参数  $\gamma$  (可调正常数) 是模型泛化能力与精确性之间可人工调整的折中参数;  $e_k$  则表示第  $k$  个数据的预测输出与实际输出之间的误差。

然后, 对上述优化问题构造 Lagrange 函数  $L(\omega, b, e, \alpha) = J(\omega, e) - \sum_{k=1}^N \alpha_k (\omega^T \varphi(x_k) + b + e_k - y_k)$ 。式中 Lagrange 因子  $\alpha_k \in R (k=1, 2, \dots, N)$ 。在求解给定函数的最优化问题时, 当有等式约束条件时应使用拉格朗日乘子法, 已知约束条件  $y_k = \omega^T \varphi(x_k) + b + e_k, k=1, 2, \dots, N$ ; 因此, 要求得目标函数  $J(\omega, e)$  最优值, 应通过拉格朗日乘子法转化为求解  $L$  对变量  $\omega, b, e_k, \alpha_k$  的偏导方程

$$\frac{\partial L}{\partial \omega} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial e_k} = 0, \frac{\partial L}{\partial \alpha_k} = 0.$$

整理得到:

$$\begin{aligned} \omega &= \sum_{k=1}^N \alpha_k \varphi(x_k); \\ \sum_{k=1}^N \alpha_k &= 0; \end{aligned}$$

$$\alpha_k = \gamma e_k, k=1, 2, \dots, N;$$

$$y_k = \omega^T \varphi(x_k) + b + e_k.$$

整理方程组, 消去  $e_k$  和  $\omega$  后得到线性方程组

$$\begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 & e_1^T \\ e_1 & Q + \frac{1}{\gamma} I \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ Y \end{bmatrix}.$$

其中:  $Y = [y_1, y_2, \dots, y_N]^T$ ;  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$ ;  $e_1 = [1, 1, \dots, 1]^T$ ;  $Q = (\varphi(x_i) \varphi(x_j))_{N \times N}$  为核函数矩阵;  $I$  为  $N \times N$  位矩阵。

依据 Hilbert-Schmidt 原理, 笔者通过引入核函数  $K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$  (满足 Mercer 条件), 将变换空间中的内积计算转化为原空间中某个函数的计算, 从而间接求解输入空间向高维特征空间的映射  $\varphi$ 。最终得到 LS-SVM 回归模型

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b.$$

与标准 SVM 相比, LS-SVM 只需确定核函数的形状参数和惩罚系数, 不需要关注不敏感损失函数的值, 既简化了计算, 又方便了实际应用。

## 2 基于 LS-SVM 的新机备件需求预测建模

基于 LS-SVM 的新机备件需求预测建模基本步骤如下。

1) 确定模型的输入向量和输出向量。寻找与新机备件需求相关的影响因素。影响新机备件需求的影响因素很多, 如飞行时间等。飞行时间越长, 通常备件消耗越多, 需求越多。经专家评议确定飞行小时数、飞行起落数、恶劣飞行天气占当月飞行日的比例和特殊飞行任务占当月飞行目的比例为主要影响因素, 将其作为模型的输入向量, 影响因素作为多维的输入向量可以比较全面地描述备件需求预测模型。备件需求量作为输出向量。

笔者以 2015 年 1 月至 2016 年 2 月作为某型新机备件需求预测建模的时间区间, 采样周期定为 1 月, 每个月的备件消耗数据作为 1 个样本, 共得到 14 个样本。其中, 前 8 个月(新机列装第 1 个月至第 8 个月)的数据作为训练样本, 用于对模型网络结构参数进行训练; 后 6 月(新机列装第 9 个月至第 14 个月)的数据作为测试样本, 利用模型对 2015 年 9 月至 2016 年 2 月某型新机航材的消耗量进行预测和验证, 即对模型泛化能力进行检验。输入和输出数据如表 1 所示。

表 1 某型新机备件统计数据

样本 编号	飞行 数/h	飞行 起落 次数	恶劣飞行		特殊飞行		备注
			天气占当月 飞行日的 比例/%	任务占当月 飞行日的 比例/%	备件实际 消耗数	备注	
1	287	117	0.15	0.16	22	训练样本	
2	316	165	0.25	0.08	29	训练样本	
3	589	234	0.38	0.25	35	训练样本	
4	381	205	0.35	0.12	29	训练样本	
5	188	153	0.08	0.09	20	训练样本	
6	246	182	0.12	0.15	24	训练样本	
7	272	171	0.05	0.08	26	训练样本	
8	459	255	0.29	0.17	31	训练样本	
9	432	276	0.27	0.13	29	测试样本	
10	306	198	0.16	0.23	27	测试样本	
11	421	218	0.14	0.13	28	测试样本	
12	395	236	0.18	0.16	29	测试样本	
13	296	115	0.14	0.16	24	测试样本	
14	305	160	0.22	0.10	26	测试样本	

2) 对训练样本和测试样本进行归一化处理。为尽量消除不同量纲对预测结果的影响, 首先对样本数据作归一化处理, 将其值限制在[0, 1]区间, 以免样本中数值较大的数据控制了训练过程, 进而掩盖数值较小数据的作用, 同时, 也有利于降低模型训练过程中数值计算的复杂度。

3) 选取核函数, 采用 LS-SVM 对训练样本进行学习, 对其网格结构参数进行训练, 通过十字交叉验证(cross-validation) 和网格搜索(grid-search), 确定最优参数。

4) 输入测试样本到训练后的 LS-SVM, 对后 6 个月(即 2015 年 9 月至 2016 年 2 月)备件需求进行预测。

5) 对预测结果进行反归一化处理及误差分析。

### 3 仿真实验及结果分析

笔者选取径向基函数 RBF( $k(x, x_k) = \exp\left[-\frac{\|x - x_k\|^2}{2\sigma^2}\right]$ ) 作为 LS-SVM 的核函数, 应用

LS-SVMLab1.8 工具箱在 Matlab 环境下完成对某型新机备件的需求预测。将表 1 中归一化后的样本数据输入到 LS-SVM 进行学习, 使用十字交叉验证和网格搜索选择最优参数(初始值参数  $\gamma=100$ ,  $\sigma^2=0.01$ , 确定出 LS-SVM 的最优正则化参数  $\gamma=1.7058$ , RBF 核函数的最优参数  $\sigma^2=1.9003$ , 从而确定输入与输出之间的精确映射关系, 然后利用测试样本对建立的模型进行仿真验证, 预测结果如表 2 和图 1 所示。

表 2 某型新机备件预测结果

样本 编号	飞行 数/h	飞行 起落 次数	恶劣飞行		特殊飞行		预测 结果	备件 实际 消耗数	备注
			天气占当月 飞行日的 比例/%	任务占当月 飞行日的 比例/%	备件实际 消耗数	备注			
9	432	276	0.27	0.13	29.3628	29	测试样本		
10	306	198	0.16	0.23	27.2127	27	测试样本		
11	421	218	0.14	0.13	28.2635	28	测试样本		
12	395	236	0.18	0.16	28.8049	29	测试样本		
13	296	115	0.14	0.16	23.7487	24	测试样本		
14	305	160	0.22	0.10	26.2674	26	测试样本		

从表 2 可以看出, 将预测结果四舍五入取整, 与实际消耗数完全一致。

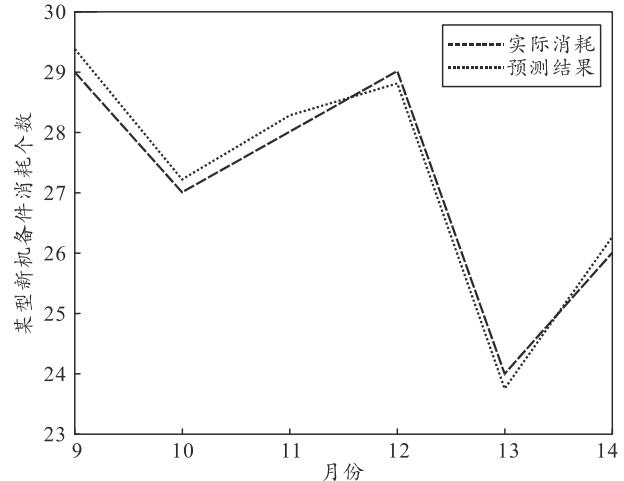


图 1 测试样本预测结果与实际消耗对比

从图 1 可以更直观地看出预测结果非常接近实际消耗数。

最后, 对预测结果进行相对误差分析, 具体见图 2, 平均相对误差  $\text{mean}(RE)=0.9547$ , 最大相对误差  $\text{max}(RE)=1.2511$ 。可以看出: 利用 LS-SVM 进行新机备件预测, 相对误差较小, 能够比较准确地反映新机备件的实际需求。

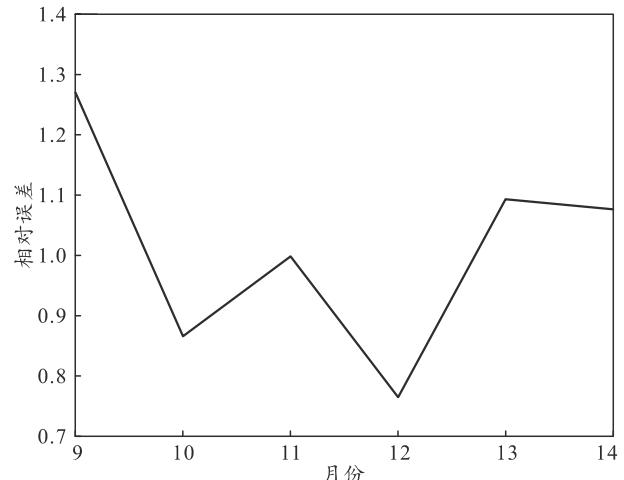


图 2 测试样本预测结果相对误差

赋值方法, 建立导弹武器作战能力评估模型。该方法基于性能需求的视角建立导弹武器作战能力的完整评估框架, 可操作性强。通过该方法得出的评估结果虽然反映了导弹武器作战能力的大小, 但还不能得出该导弹武器对于使命任务的能力满足度, 尚需做进一步研究。

## 参考文献:

- [1] 王征, 朱冰, 余瑞星. HLA 框架构建空战导弹武器作战效能设计[J]. 现代防御技术, 2015, 43(1): 23–27.
- [2] 徐林生. 面向武器装备论证过程的多属性评价方法研究[D]. 南京: 南京理工大学, 2010.
- [3] 杜红梅, 柯宏发. 装备作战能力与作战效能之内涵分析[J]. 兵工自动化, 2015, 34(4): 23–27.
- [4] KOBRYN C, SIBBALD C. 1.3.1 Modeling DoDAF Compliant Architectures The Telelogic Approach for Complying with the DoD Architectural Framework[J].

(上接第 73 页)

## 4 结束语

笔者提出基于 LS-SVM 解决新机备件需求的预测问题, 建立了某型新机备件需求预测模型, 针对新机备件历史消耗数据较少的情况, 较好地解决了备件需求的预测问题。仿真结果表明, LS-SVM 在新机备件需求预测方面效果良好。今后, 笔者还应根据新机的特点, 在影响因素的选取上作进一步完善, 不断改进参数寻优的方法, 完善模型, 提高对不同新机备件需求预测的准确性。

## 参考文献:

- [1] 张嘉华, 刘琪, 宋占成, 等. 军用飞机备件配置要求: HB 7384-1996[S]. 北京: 中国航空工业总公司, 1996.
- [2] 赵建忠, 徐廷学, 甄伟, 等. 基于改进支持向量机的导弹备件消耗预测[J]. 现代防御技术, 2013, 41(2): 177–182.
- [3] 梁佐堂, 祝华远, 王晓钢, 等. 基于飞机故障的特情处

Incose International Symposium, 2005, 15(1): 95–125.

- [5] 韩朝超, 黄树彩. 末端反导作战效能评估模型研究[J]. 电光与控制, 2010, 17(1): 14–17.
- [6] 魏晓童, 陈洪辉, 张萌萌. DODAF2.0 服务系统视图的提出与描述[C]//中国指挥控制大会, 2016.
- [7] 张思滨. 防空导弹武器系统作战能力影响关系分析方法[D]. 长沙: 国防科学技术大学, 2010.
- [8] 李志淮, 谭贤四, 王红, 等. 基于 DoDAF 的武器装备体系指标需求生成方法[J]. 火力与指挥控制, 2013(12): 160–163.
- [9] 张迪, 郭齐胜, 李智国, 等. 基于型号性能指标的武器装备体系作战能力评估方法[J]. 火力与指挥控制, 2015, 40(5): 12–16.
- [10] 薛鹏. 基于 PRINCE2 的设备级武器装备项目管理研究[D]. 济南: 山东大学, 2012.
- [11] 赤尾, 洋二. インタビュ-赤尾洋二氏--「赤尾賞」は QFD が日本生まれのあかし [J]. Nikkei Mechanical, 1996, 21(1): 11–15.

置方法优化[J]. 兵工自动化, 2017, 36(5): 1–3.

- [4] VAPNIC. The Nature of Statistical Learning Theory[M]. New York: Springer, 1995: 62–89.
- [5] Vapnic. An Overview of Statistical Learning Theory[J]. IEEE Transactions on Neural Networks, 1999, 10(5), 988–999.
- [6] SUYKENS J. Least Squares Support Vector Machines[M]. Singapore: World Scientific Publishing Co Pte Ltd, 2002: 71–89.
- [7] SUYKENS J, BARBANTER J D, LUKAS L, et al. Weighted Least Squares Support Vector Machines: Robustness and Squares Approximation[J]. Neurocomputing, 2002, 48(1–4): 85–105.
- [8] 兰瑜洁, 钟舜聪. 基于单类支持向量机的织物瑕疵检测研究[J]. 机电工程, 2016, 33(2): 237–241.
- [9] 邓乃扬, 田英杰. 数据挖掘中的新方法—支持向量机 [M]. 北京: 清华大学出版社, 2006: 27–88.
- [10] 张恒喜, 郭基联, 朱家元, 等. 小样本多元数据分析方法及应用 [M]. 西安: 西北工业大学出版社, 2002: 42–96.