

基于 QPSO-SVR 的火控系统故障预测方法研究

李可奇^{1,2} 杜毛强²

LI Keqi DU Maoqiang

摘要

针对军用装备电气部件系统故障预测问题,以某型火箭炮火控系统为案例,采用基于支持向量机的方法进行预测,并提出利用量子粒子群算法优化支持向量机。实验对比分析表明,所提出的方法预测精度高,对制定装备维修策略具有理论参考价值。

关键词

故障预测;量子粒子群算法;支持向量机;火控系统;装备维修

doi: 10.3969/j.issn.1672-9528.2024.07.006

0 引言

随着科技发展进步,装备信息化程度越来越高,装备维修保障也产生了更高要求。故障预测是新体制下装备差异化维修保障模式的新手段,通过预测可以使维修时机和范围更加精准^[1]。故障失效的机械零部件可以通过形状尺寸、功能要求等具体指标检测出来,而没有明显故障特征电子电气部件则难以判断是否需要维修更换。因此,对此类部件进行故障预测显得尤为必要。本文选取某型火箭炮这一典型新装备,以火控系统故障预测为案例,研究故障预测优化方法。

1 火控系统数据采集

部件的健康状态通常可以通过对应的端口信号值反映出来,为了评估部件未来时刻的状态及剩余寿命,首先要对其未来时刻的性能参数值做出预测。

利用某火控系统检测设备,可以完成对火控系统自动检测,实现针对火控系统的系统巡检、发射流程、调炮控制等多种操作的设置和测试。检测系统能够检测发射流程中发射控制箱输出的发动机点火电流大小,从而判断火控系统输出的脉冲是否符合发射要求。

发动机点火电流正常信号值为5~6A。由于火箭弹热电池阻值相对固定,通过检测火控系统输出的这组数据,可以判断发射控制箱是否出现故障。因此,构建点火电流数据集,可以实现对发射控制箱的故障预测。

2 基于支持向量机的故障预测

常用的故障预测方法有人工神经网络、Kalman滤波模型、模糊模型等,但这些方法在解决小样本问题时适应性较差^[2]。根据装备数据采集样本规模小的特点,选择支持向量

机(support vector machine, SVM)这一算法。SVM是一种机器学习方法,它建立在统计学习理论的基础上,能够有效克服传统算法存在的陷入局部极值、过拟合和维数灾难等问题^[3],对故障样本少的新型装备来说尤为适用。

2.1 支持向量回归机

SVM主要有支持向量回归机(support vector regression, SVR)和支持向量分类机(support vector classification, SVC)两种^[4],利用支持向量回归机建立回归函数可以预测火箭炮发射车性能参数的变化趋势。

现有 k 个数据样本 $\{x_i, y_i\}$, y_i 为期望值,为简化回归问题,引入不敏感系数 ε ,函数 $f(x)$ 的输出即为带有误差 ε 的预测输出 y ,因此SVR的估计函数为:

$$y = f(x) = (\omega, \Phi(x)) + b \quad (1)$$

式中: b 为偏置量。

此时目标是寻找合适的 ω 和 b ,回归估计问题就转化为对一个损失函数风险最小化的问题,即:

$$R_{\text{ref}} = C \sum_{i=1}^s \Gamma(f(x_i) - y_i) + \frac{1}{2} \omega^2 \quad (2)$$

式中: s 为样本容量, $\Gamma(\Phi)$ 是损失函数, C 为惩罚因子。

引入拉格朗日乘数法,可得到估计的回归函数为:

$$\begin{aligned} f(x) &= \sum_{i=1}^s (\alpha_i - \alpha_i^*) (\Phi(x_i) \cdot \Phi(x)) + b \\ &= \sum_{i=1}^s (\alpha_i - \alpha_i^*) k(x_i, x) + b \end{aligned} \quad (3)$$

通过训练样本获得合适的 α_i 、 α_i^* 和 b ,就可以通过上式基于历史数据进行预测。

2.2 SVR的优化

SVR的预测性能优劣直接由两个重要的参数决定,即核函数 k 与惩罚因子 C ^[5]。选择合适的参数,可以提升支持向量机的学习能力和预测精度。

1. 国防科技大学系统工程学院 湖南长沙 410000

2. 32228 部队 21 分队 江苏南京 210000

(1) 核函数的选择

故障预测需要大量样本数据对 SVR 模型进行训练,而高斯径向基核函数的 SVR 在大样本训练时精度较高,性能较为均衡^[6],因此选择高斯径向基核函数作为核函数。这样,就将核函数优化问题转化为核函数参数 σ 的寻优问题。

高斯径向基核函数表达式为:

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma^2}\right) \quad (4)$$

(2) 粒子群算法优化支持向量机

群智能进化算法发展至今,已经逐渐被广泛应用于参数搜索领域。大量实验表明,粒子群优化算法 (particle swarm optimization, PSO) 在参数搜索中较传统算法具有优越性^[7]。

根据 PSO 算法和支持向量机故障预测原理,针对支持向量机参数的选择问题,提出使用 PSO 优化支持向量机参数,而后采用最优参数进行 SVR 预测。其流程如图 1 所示,其基本步骤如下。




图 1 PSO 算法优化 SVR 流程图

步骤 1: 选定训练集与测试集。将实验数据划分为训练数据集和测试数据集。

步骤 2: 将 SVR 参数 σ 和 C 当作粒子, 初始化 PSO 算法基本参数。选择初始的群体数目、迭代次数和学习因子。

步骤 3: 计算每个粒子的适应值。

步骤 4: 按照速度位置更新公式, 更新粒子的位置。

步骤 5: 将粒子适应值与个体最优位置的适应值进行比

较,若更优,则更新其为粒子个体最优值 $pBest$, 将其作为当前的最好位置。

步骤 6: 将粒子群适应值与全局最优位置的适应值进行比较,若更优,则更新其为粒子群全局最优值 $gBest$, 将其作为当前的最好位置, 否则, 进入步骤 7。

步骤 7: 设定一个迭代次数, 若达到迭代次数则进入步骤 8, 否则返回步骤 3。

步骤 8: 获取最优参数组合核函数参数 σ 与惩罚因子 C 。

步骤 9: 利用最优参数训练 SVR。

步骤 10: 输入测试样本集。

步骤 11: 完成输出数据预测, 分析预测结果的准确性。

(3) 量子粒子群算法优化支持向量机

由于 PSO 算法需要设定的参数 (惯性权重 ω , 学习因子 c_1 和 c_2) 太多, 不利于搜寻待优化模型的最优参数。标准的 PSO 算法存在粒子位置变化缺少随机性的缺点^[8], 容易陷入局部最优。针对这些问题, 在标准 PSO 算法基础上, 引入量子粒子群算法 (quantum-behaved particle swarm optimization, QPSO) 进一步优化 SVR 算法。

QPSO 算法取消了粒子的移动方向属性^[9]。相较于标准 PSO, QPSO 算法控制参数只有一个, 即收缩 - 扩张因子 α , 通过调节 α 的值, 可以调节算法的收敛速度。固定的收缩 - 扩张因子会降低算法的鲁棒性^[10]。本文选取线性递减策略自适应的修改收缩 - 扩张因子:

$$\alpha = \alpha_0 + (\alpha_1 - \alpha_0) \frac{K_{max} - k}{K_{max}} \quad (5)$$

式中: K_{max} 为最大迭代次数; α_0 、 α_1 为预设值, 一般取 $\alpha_0=0.5$, $\alpha_1=1$ 。

2.3 基于 SVR 的故障预测模型

建立数据集模型输出预测值, 就是利用 SVR 进行故障预测的本质。如果 x_{t+m} 是预测的目标值, 将先前的目标值 $x_t, x_{t+1}, \dots, x_{t+m-1}$ (其中 $t=1, \dots, n-m$) 作为输入, 建立预测模型, 经过变换, 就可以得到用于 SVR 的学习样本:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_m \\ x_2 & x_3 & \cdots & x_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} \end{bmatrix}$$

$$y = \begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{bmatrix}$$

输入和输出之间是相对应的, 通过对 SVR 的训练, 可以

输出得到第 $n+1$ 点的预测值:

$$y_{n+1} = \sum_{i=1}^{n-m} (\alpha_i - \alpha_i^*) k(x_i, x_{n-m+1}) + b \quad (6)$$

式中: α_i 为拉格朗日乘子, b 为偏置项, k 为核函数。通过训练样本获得合适的 α_i 、 α_i^* 和 b , 并搜寻最优的核函数参数, 就可以实现对输入数据的预测。

3 实验分析

以发射控制箱故障预测为例, 验证单部件故障预测模型的可信性。将发动机点火电流作为实验模型的输入样本集。为提高预测准确率, 本实验采用 SVR、PSO-SVR 和 QPSO-SVR 三种方法对数据进行预测分析, 对比选取最优的预测方法。

3.1 三种方法对比实验

首先建立实验数据集。根据该发射车每周车炮场日检测的历史数据, 从某一时间点开始, 构建发动机点火电流数据集。剔除掉人为因素导致的异常数据后, 本次实验采用 60 组历史数据进行验证, 原始数据见表 1。模型嵌入维数设定为 10, 采用前 10 个数据预测下一个数据, 则可生成 50 组输入输出数据。将前 35 组数据作为训练集, 后 15 组数据作为测试集。设置 SVR 的核函数参数 σ^2 为 0.313, 惩罚因子 C 为 8; 将 PSO-SVR、QPSO-SVR 中的进化次数设置为 300, 种群规模为 100, σ^2 搜索范围为 $[0.001, 100]$, C 的搜索范围为 $[0.1, 100]$, $\alpha=2$ 。以预测值和实际值的平均绝对误差 (mean absolute error, MAE) 作为适应度值, 同时引入均方根误差 (root mean square error, RMSE) 和平均绝对百分误差 (mean absolute percentage error, MAPE) 两个评价指标。

表 1 发动机点火电流原始数据

时间点	电流 /A	时间点	电流 /A	时间点	电流 /A	时间点	电流 /A
1	5.36	16	5.30	31	5.24	46	5.20
2	5.36	17	5.28	32	5.24	47	5.15
3	5.32	18	5.24	33	5.22	48	5.18
4	5.36	19	5.28	34	5.22	49	5.18
5	5.36	20	5.28	35	5.22	50	5.15
6	5.34	21	5.26	36	5.22	51	5.15
7	5.34	22	5.26	37	5.22	52	5.16
8	5.30	23	5.30	38	5.16	53	5.15
9	5.32	24	5.25	39	5.22	54	5.15
10	5.31	25	5.25	40	5.20	55	5.14
11	5.31	26	5.25	41	5.20	56	5.14
12	5.32	27	5.20	42	5.22	57	5.12
13	5.31	28	5.26	43	5.18	58	5.14
14	5.30	29	5.25	44	5.18	59	5.14
15	5.30	30	5.24	45	5.20	60	5.12

MAE 表示真实值与预测值的误差绝对值的平均值, 其公式为:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (7)$$

式中, y_i 是实际值, $\hat{y}_i$ 是预测值。

RMSE 是指真实值与预测值的差值的平方和然后求平均, 其公式:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (8)$$

MAPE 是指真实值与预测值的误差百分比, 其公式为:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (9)$$

针对点火电流数据, 经过样本集训练, PSO-SVR 模型最优参数为 $\sigma^2=0.062\ 5$, $C=8.986\ 87$; QPSO-SVR 模型最优参数为 $\sigma^2=0.024\ 2$, $C=63.969\ 7$ 。得到的预测结果如图 2 所示, 三种预测算法误差对比如图 3 所示, 测试集相对误差对比如图 4 所示, PSO-SVR 与 QPSO-SVR 算法进化曲线对比如图 5 所示, 误差统计见表 2。




图 2 点火电流预测结果对比图




图 3 三种预测算法误差对比




图 4 测试集相对误差对比




图 5 算法进化曲线对比

表 2 三种算法误差统计

算法误差	SVR	PSO-SVR	QPSO-SVR
MAE	0.034 0	0.033 0	0.020 7
RMSE	0.036 3	0.036 0	0.024 7
MAPE	0.006 6	0.006 4	0.004 0

从样本数据的预测结果可以看出，三种算法均可以实现数据预测，说明针对这类小样本、非线性数据具有很好的预测效果。但是 PSO-SVR 较 QPSO-SVR 算法过早地陷入局部最优，在预测精度上 QPSO-SVR 优于 PSO-SVR，均优于 SVR。因此，QPSO-SVR 算法可以作为故障预测的有效方法。

3.2 基于 QPSO-SVR 的故障预测

由于发动机点火电流正常信号值为 5 ~ 6 A，当数据超出正常范围时，可以判定发射控制箱出现故障。利用 3.1 中 QPSO-SVR 寻优的最佳参数，以全部数据作为样本，点火电流的预测值如图 6 所示。




图 6 点火电流预测

可以看出， $t=32$ 时电流数据将超出正常范围，说明发射控制箱在该时间点可能会出现故障，需要进行维修。通过该故障预测方法，可以为单部件维修时机提供参考。需要说明的是，预测出现故障的时间点是基于前序指标参数的变化而

动态变化的，监测数据越多，则样本越大，训练出来的故障预测模型就越准确。

4 结语

随着装备信息化程度越来越高，对装备状态监控以及故障预测的要求也越来越高。本文介绍了利用支持向量回归进行故障预测的方法流程，并以某型火箭炮火控系统发射控制箱故障预测为例，采用 SVR、PSO-SVR 和 QPSO-SVR 三种方法进行了对比预测分析。通过对比实验，验证了利用 QPSO-SVR 方法具有较高的精度，为装备维修策略制定提供了理论参考。

参考文献：

- [1] 郭建, 徐宗昌, 张文俊. 基于状态的装备故障预测技术综述 [J]. 火炮发射与控制学报, 2019, 40 (2):103-108.
- [2] 徐兆平, 郭波. 复杂装备故障预测方法研究综述 [J]. 长沙理工大学学报 (自然科学版), 2023, 20 (2): 10-26.
- [3] 樊泽凯, 贾红丽, 尹承督. 基于 LS-SVM 的装甲装备故障预测模型研究 [J]. 军械工程学院学报, 2017, 29(2):28-32.
- [4] WANG F K, MAMO T. A hybrid model based on support vector regression and differential evolution for remaining useful lifetime prediction of lithium-ion batteries[J]. Journal of power sources, 2018(Oct.15): 401.
- [5] 周通. 基于机器学习的火控系统状态评估与故障预测的研究 [D]. 北京: 北京石油化工学院, 2022.
- [6] 王威, 海占勇, 杨遵. 基于支持向量机的装备故障间隔时间预测研究 [J]. 现代防御技术, 2013, 41(2):183-186+191.
- [7] SHIRGAR M, THAKKAR A. Survey on particle swarm optimization: variants and applications[EB/OL].[2024-03-10].[http:// www. researchgate. net/ publication/ 334946035_ Survey_on_Particle_Swarm_Optimization_Variants_and_Applications](http://www.researchgate.net/publication/334946035_Survey_on_Particle_Swarm_Optimization_Variants_and_Applications).
- [8] 李超. 粒子群优化算法改进策略及其应用研究 [D]. 无锡: 江南大学, 2021.
- [9] CHENG X, LU X, LIU Y, et al. Comparison of differential evolution, particle swarm optimization, quantum-behaved particle swarm optimization, and quantum evolutionary algorithm for preparation of quantum states[J].Chinese physics B, 2023, 32(2):020202.
- [10] 黄俊. 改进量子粒子群算法优化的 SVM 边坡变形预测研究 [D]. 赣州: 江西理工大学, 2020.

【作者简介】

李可奇 (1985—), 男, 甘肃庆阳人, 硕士研究生, 研究方向: 装备维修保障。

(投稿日期: 2024-05-14)