

基于自适应粒子群算法的轨下基础病害识别^{*}

伍伟嘉 杨 健 袁天辰 邵志慧

(上海工程技术大学城市轨道交通学院, 201620, 上海//第一作者, 助理工程师)

摘要 基于车辆-轨道耦合动力学模型, 对不同轨下基础病害情况下的轨枕振动响应进行仿真分析。提出利用支持向量机算法和粒子群算法对轨下基础病害进行识别。为了提高粒子群算法的收敛速度, 提出一种自适应粒子群算法, 并将所提方法应用于轨下基础病害识别仿真, 分析不同病害条件下的轨枕振动特征。研究表明: 所提算法的病害识别准确率 $\geq 80\%$, 且其算法收敛速度有明显提升。

关键词 轨道交通; 轨下基础; 病害识别

中图分类号 U213.2⁺¹³

DOI: 10.16037/j.1007-869x.2023.01.003

Sub-rail Foundation Disease Identification Based on Adaptive Particle Swarm Optimization Algorithm

WU Weijia, YANG Jian, YUAN Tianchen, SHAO Zhihui

Abstract Based on vehicle-track coupling dynamics model, the simulation analysis of the sleeper vibration response under different sub-rail foundation disease conditions is carried out. It is proposed to adopt SVM (support vector machine) algorithm and PSO (particle swarm optimization) algorithm to identify the sub-rail foundation basic diseases. To improve the convergence speed of PSO, an APSO (adaptive particle swarm optimization) algorithm is proposed, and the proposed method is applied to the identification and simulation of sub-rail foundation basic diseases, so as to analyze the vibration characteristics of sleepers under different disease conditions. The research shows that the disease identification accuracy rate of the proposed algorithm can achieve over 80%, and the convergence speed of the algorithm is significantly improved.

Key words rail transit; sub-rail foundation; disease identification

Author's address School of Urban Railway Transportation, Shanghai University of Engineering Science, 201620, Shanghai, China

轨下基础结构作为轨道系统重要的承载结构, 其作用是将高速列车运行所产生的冲击载荷传递给路基并实现减振效果。随着我国铁路列车运行速度的增加和承载能力的增大, 轨下基础必然会承受更大的冲击载荷, 而轨下基础病害将会随着轨道系统运营时间的推移逐渐显现, 进而威胁行车安全。因此, 实现对轨下基础病害快速且高效的诊断和识别是保障列车安全运行的关键。

轨下基础病害识别的首要问题是如何获取轨下基础结构处于病害状态时的故障特征。近年来, 小波分析因具有多尺度特性而被国内外学者广泛应用于机械结构和大型土木结构故障诊断领域, 特别是故障特征提取方面。文献[1]利用小波变换和奇异值分解提取了水电机组振动的故障特征, 并采用概率神经网络算法对所提取到的特征向量进行分类, 具有较高的分类准确率。文献[2]基于集成经验模态分解和可调 Q -因子小波变换实现了对滚动轴承早期故障的特征提取。由于小波变换没有对振动信号的高中频部分进行分解, 导致提取到的特征可能无法完全反映轨下基础结构病害的故障特征信息。为了避免由于小波分解本身分析频段所带来的问题, 文献[3]将小波包分解运用到了滚动轴承的故障诊断中, 并成功判断出了滚动轴承的故障类型。

在提取故障特征信息后需要对故障模式进行识别, 相较于神经网络算法, SVM(支持向量机)算法在处理高纬度、小样本和非线性数据方面有较大的优势, 且其还具有很强的自学能力和泛化能力。但 SVM 算法中对于参数的选择极大地影响了故障识别分类的准确率, 因此国内外学者采用智能算法优化 SVM 参数, 如 GA(遗传)算法、蚁群算法和网格搜索算法等。但上述这些优化算法存在一些不足之处: GA 算法参数较多且寻优速度慢; 蚁群算法

* 国家自然科学基金项目(11802170); 上海市晨光计划项目(18CG66); 上海市自然科学基金项目(19ZR1421700)

计算量大且不适用于复杂问题;网格搜索算法运算时间会随着搜索步长的减小而陡增。粒子群算法不仅收敛速度较快,且在解决复杂的非线性问题上有较好的表现。针对轨下基础病害识别,本文利用小波包分解对轨下基础病害振动信号进行三层分解,并提取分解后的底层能量作为后续故障分类的输入,利用自适应粒子群算法联合 SVM 算法对病害进行识别,以较好地识别出不同的轨下基础病害。本文研究可为轨枕的故障诊断以及预测提供理论及参考依据。

1 车辆-轨道耦合动力学模型与病害模拟

1.1 车辆-轨道耦合动力学模型

采用如图 1 所示的车辆-轨道垂向耦合动力学模型,其中车辆系统是由车体质量 m_c 、转向架质量 m_T 、轮对质量 m_w 组成的一个多刚体系统,并以速度 v 在轨道模型上运动,考虑车体和前后转向架的沉浮运动自由度 (z_c, z_{T1}, z_{T2}) 与点头运动自由度 ($\beta_c, \beta_{T1}, \beta_{T2}$),以及 4 个轮对的垂向运动自由度 ($z_{W_o}, o = 1, 2, 3, 4$),则车辆系统的运动方程为:

$$m\ddot{z} + C\dot{z} + Kz = P_o \quad (1)$$

式中:

m, C, K ——分别为车辆系统的质量、阻尼和刚度矩阵;

\ddot{z}, \dot{z}, z ——分别为系统的垂向加速度、垂向速度和垂向位移向量;

P_o ——系统力向量。

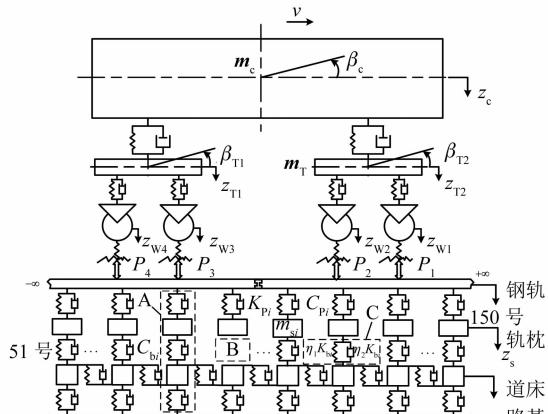


图 1 车辆-轨道耦合动力学模型(含病害)

Fig. 1 Vehicle-track coupling dynamics model (including diseases)

轨道系统由钢轨、轨下基础(包括轨枕和道床)以及路基组成,其中钢轨可以视为连续弹性离散点支撑上的无限长 Euler 梁,轨下基础可模拟为双质量、三层弹簧-阻尼振动模型(见图 1 中的模型 A),并按轨枕间距沿纵向离散。本文不涉及钢轨、道床和路基的振动方程,具体可参考文献[4]。文献[5-6]的研究表明:通过改变模型中的 C_{bi} 和 K_{bi} 可以模拟轨下基础病害,例如:轨枕完全空吊工况(见图 1 中的模型 B)即完全失去工作能力,可设 $K_{bi} = C_{bi} = 0$;对于道床板结或松散工况(见图 1 中的模型 C),则设 $K_{bi,ne} = \eta_1 K_{bi}$, $C_{bi,ne} = \eta_2 C_{bi}$,对于不同程度的病害, η_1, η_2 的取值范围为 [0.1, 10.0]。

1.2 轨下基础病害仿真

采用 Matlab 软件建立车轨耦合模型,时间步长设置为 1×10^{-4} s,取轨道长度 $L = 120$ m,轨枕间距 $L_s = 0.6$ m,选取位于轨道系统中心位置的 51 号—150 号共 100 个轨枕截面单元,以 100 号轨枕为振动响应分析对象。不同工况下的轨下基础模拟参数如表 1 所示。根据表 1 的仿真实况,以列车行驶速度为 200 km/h 为例,轨枕在不同工况下的振动加速度时域谱和功率谱仿真结果如图 2 所示。

表 1 不同工况下的轨下基础模拟参数

Tab. 1 Sub-rail foundation simulation parameters under different working conditions

工况编号	工况状态	K_{bi}	C_{bi}
1	正常	K_{bi}	C_{bi}
2	轨枕空吊	0	0
3	道床板结	$4.50 K_{bi}$	$4.50 C_{bi}$
4	道床松散	$0.35 K_{bi}$	$0.35 C_{bi}$

由图 2 a) 和图 2 b) 可知,轨枕空吊工况下的轨枕振动加速度的幅值比正常工况下要大很多,而从功率谱方面来看,其在 $10^0 \sim 10^2$ Hz 频率范围内有明显的变化;从图 2 c) — 图 2 f) 中可以看出,道床板结和道床松散工况下的轨枕振动加速度较正常工况变化不是特别明显,而从功率谱方面来看,其在频率低频区变化不明显,在频率高频区变化稍有区别。故需要对轨枕振动加速度进行特征提取,且要求特征提取方法既可以反映轨枕振动加速度在时域上的变化,又可以体现轨枕振动加速度在频域高频和低频区域的特征。

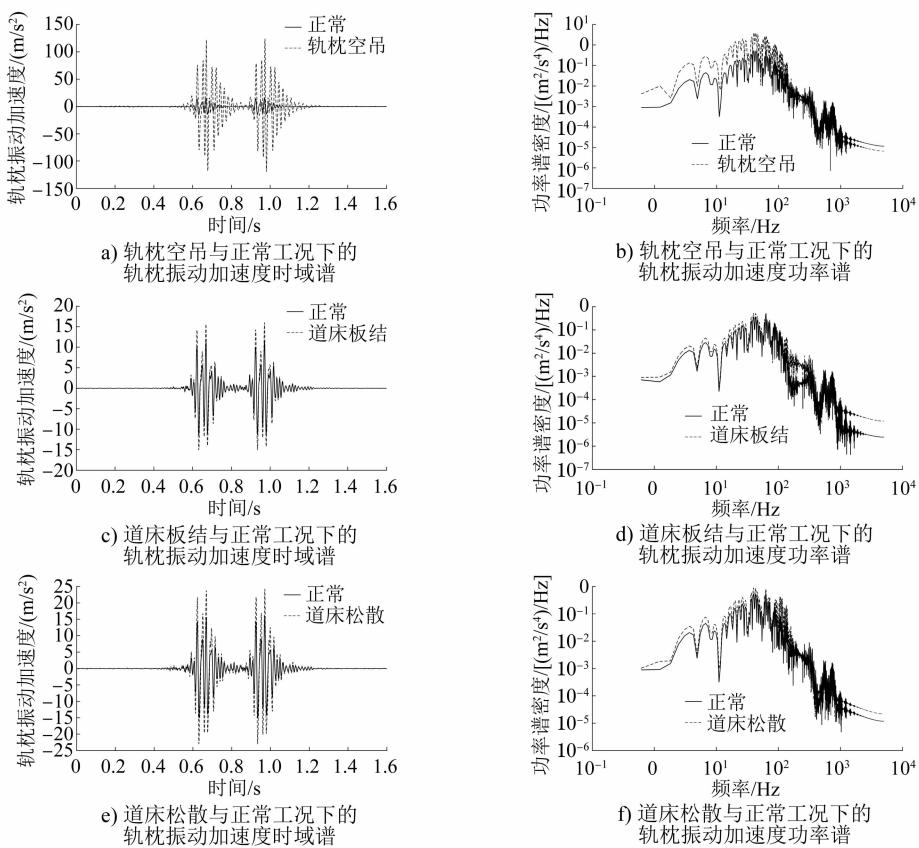


图 2 列车速度为 200 km/h 时轨枕在不同工况下的振动加速度时域谱和功率谱仿真结果

Fig. 2 Time-domain spectrum and power spectrum simulation results of sleeper vibration acceleration under different working conditions with train speed of 200 km/h

2 基于 SVM 的病害特征识别

2.1 基于粒子群算法的 SVM 参数优化

SVM 算法是一种用于解决凸二次优化问题的机器学习算法, 其核心内容是找到一个分类超平面并将其作为决策曲面, 进而最大化正反例之间的隔离边缘。相较于其他人工智能算法, SVM 算法在解决高维度、小样本, 以及非线性模式识别方面有很大的优势。PSO(粒子群优化)算法是一种根据鸟类捕食行为所提出的群体智能算法, 与 GA 算法相比, PSO 的 SVM 参数寻优方法不需要进行选择、交叉、变异等复杂操作, 具有收敛速度快、寻优精度高等特点。因此本文利用 PSO 算法对 SVM 进行参数寻优。

PSO 算法的基本原理为: 在 n 维空间中随机地产生一些粒子, 每个粒子代表了所求优化问题的一个潜在最优解, 每个粒子的特征信息用位置 x 、速度 v 及适应度三项指标描述, 其中适应度指标由目标函数确定, 用于反映某个粒子与其他粒子之间的优劣程度; 每个粒子按照特定的方程以不同的速度和

位置进行移动, 在移动过程中每个粒子都会计算该位置的适应度值, 从而得到该粒子的局部最佳位置; 通过粒子之间的交互协作和信息共享, 可以获得整个粒子群体的最优适应度值和最佳位置, 每个粒子在移动过程中也会根据个体和整个群体的最佳位置及适应度, 动态地调整、更新位置和速度, 通过逐步迭代最终实现最优解的寻找。

设 $\mathbf{x}_J = [x_{J1} \ x_{J2} \ \cdots \ x_{Jm}]$ 为粒子 J 当前的位置信息 (m 为粒子的维度), $\mathbf{v}_J = [v_{J1} \ v_{J2} \ \cdots \ v_{Jm}]$ 为粒子 J 当前的飞行速度; $\mathbf{p}_J = [p_{J1} \ p_{J2} \ \cdots \ p_{Jm}]$ 为粒子 J 所经历的最好位置信息, 又被称为个体极值。在每一次迭代更新中, 粒子的速度、位置会根据个体极值 \mathbf{p}_J 和全局极值 \mathbf{p}_g (g 为种群中的粒子个数) 而改变, 可以表示为:

$$\begin{cases} v_{Jm}(\sigma + 1) = \omega v_{Jm}(\sigma) + c_1 r_1 [p_{Jm}(\sigma) - \\ x_{Jm}(\sigma)] + c_2 r_2 [p_{gm}(\sigma) - x_{Jm}(\sigma)] \\ x_{Jm}(\sigma + 1) = x_{Jm}(\sigma) + v_{Jm}(\sigma + 1) \end{cases} \quad (2)$$

式中:

p_{gm} —— m 维下的种群全局极值；

σ ——种群进化代数；

ω ——惯性因子，通常取为 0.8；

c_1, c_2 ——加速因子，取值范围为 [0, 2]；

r_1, r_2 ——分别为两个相互独立的随机数，取值范围为 [0, 1]。

基于 PSO 算法对 SVM 进行参数寻优的算法流程如图 3 所示。

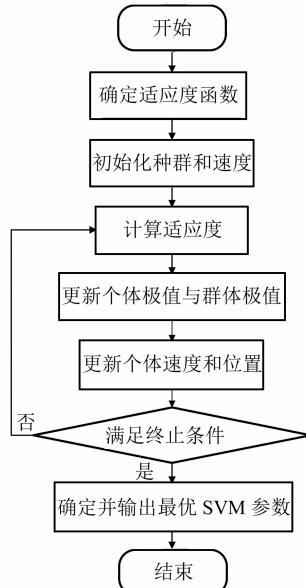


图 3 基于 PSO 算法优化 SVM 参数的算法流程图

Fig. 3 Algorithm flow chart of optimizing SVM parameters based on PSO algorithm

2.2 自适应粒子群算法参数优化

为了进一步加快 PSO 算法的收敛速度，采用一种自适应变化参数为 c_1, c_2, ω 的 PSO 算法，即 APSO（自适应粒子群）算法。APSO 算法主要利用进化状态评估(ESE)将种群的进化细化为搜索、发现、收敛和跳出等 4 个阶段，结合自适应变化参数对 PSO 算法进行改进。

在 PSO 算法中， ω 的取值会影响粒子的搜索能力，其值越大，局部搜索能力越弱；其值越小，全局搜索能力越弱。由此可知，在搜索阶段时需要 ω 的取值较大，而在发现阶段时需要 ω 的取值较小，故 ω 的取值需要随着进化状态的改变而改变，可以表示为：

$$\omega(F) = \frac{1}{1 + 1.5 e^{-2.6F}} \quad (3)$$

式中：

F ——进化因子， $\forall F \in [0, 1]$ 。

c_1, c_2 是调整粒子朝着局部和全局最佳位置运动的步长变量，因此其也需要随着进化状态的改变而改变。在搜索阶段时，需要搜索到尽可能多的个体最优值，即较好的局部搜索能力，此时需要增大 c_1 并减小 c_2 ，以避免算法陷入局部最优；在发现阶段时，粒子利用周围的局部信息使种群向局部最优位置移动，此时需要小幅增大 c_1 并小幅减小 c_2 ，以避免过早收敛；在收敛阶段时，种群已经抵达全局最优位置附近，此时需要同时增大 c_1 和 c_2 ，以引导其他粒子向其聚集；在跳出阶段时，当前区域的局部最优粒子跳出并远离所在的聚类，快速向新的较优区域移动，同时该聚类中的其他粒子也会跟随该局部最优粒子快速移动，此时需要减小 c_1 并增大 c_2 。

2.3 基于 APSO-SVM 算法的轨下基础病害识别

本文基于 APSO-SVM 联合算法对轨下基础病害进行识别。将由 1.2 节仿真获得的不同工况条件下的轨枕振动加速度数据分成训练集和测试集，其中：前 90 组数据作为训练集；后 10 组数据作为测试集。首先对二者进行三层小波包分解并计算最后一层的能量，然后将所得到的特征向量集合进行归一化处理，最后将不同工况的特征向量集合输入 SVM 算法。为了验证 APSO-SVM 联合算法的有效性，采用 PSO 算法优化 SVM 参数，将其作为对照组。利用 APSO-SVM 联合算法和 PSO-SVM 联合算法进行轨下基础病害识别，其适应度曲线和分类识别结果分别如图 4 和图 5 所示。同时，为了验证 APSO-SVM 联合算法的鲁棒性，在车速为 100~140 km/h 条件下，利用 APSO-SVM 算法获得的病害识别准确率结果如表 2 所示。

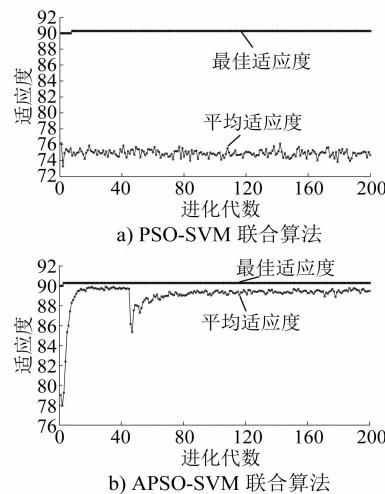


图 4 适应度曲线

Fig. 4 Fitness curve

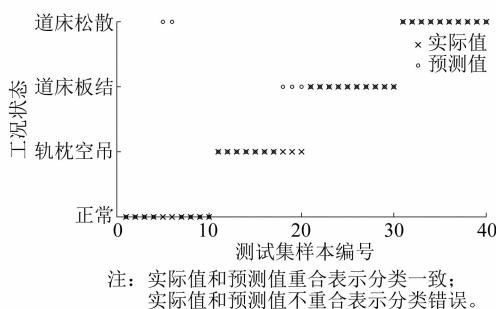


图 5 APSO-SVM 分类识别结果

Fig. 5 APSO-SVM classification and recognition results

表 2 不同车速条件下的病害识别准确率结果

Tab. 2 Results of disease recognition accuracy rates under different vehicle speed conditions

车速/(km/h)	识别准确率/%
100	80.0
110	80.0
120	87.5
130	87.5
140	87.5

由图 4 可知, PSO-SVM 联合算法的种群在第 10~15 代之间就收敛了, 而利用 APSO-SVM 联合算法的种群在第 5 代左右就已经收敛, 并且前者的运算时间为 1 464.8 s, 后者的运算时间为 1 046.92 s, 说明利用 APSO-SVM 联合算法减少了收敛时间。由图 5 可知, 测试样本数量为 40 个, 有 35 个测试样本的预测值与实际值重合, 分类准确率为 87.5% (35/40), 说明 APSO-SVM 联合算法可以较准确地对轨下基础病害进行识别。由表 2 可知, 不同速度条件下, APSO-SVM 算法的识别准确率均大于等于 80.0%, 具有一定的鲁棒性。

3 结语

本文基于时频域分析方法提取了轨下基础不同工况的振动加速度特征, 采用 SVM 算法对轨下基础病害进行了分类, 并利用 APSO-SVM 联合算法优化 SVM 参数。主要获得以下两个结论:

1) 基于车辆-轨道耦合动力学模型对轨下基础病害进行了仿真研究, 并对比了不同病害条件与正常工况条件下, 轨枕振动加速度的时域谱和功率

谱变化情况。研究结果表明: 在轨枕空吊工况下, 轨枕振动加速度的时域幅值出现了较大的变化; 在道床板结和道床松散工况条件下, 其变化不明显; 不同病害工况下, 轨枕振动加速度在高频和低频区域的功率谱有着不同程度的变化。

2) 为了进一步提高 PSO 算法在优化 SVM 参数选优时的收敛速度, 提出一种自适应粒子群算法。识别结果表明: 在保证识别准确率的前提下, 所提算法可以有效提高收敛速度; 对不同车速条件下的轨下基础病害进行识别, 识别准确率 $\geq 80.0\%$, 说明所提算法具有较好的鲁棒性。

参考文献

- [1] 刘东, 王昕, 黄建英, 等. 基于小波变换与 SVD 的水电机组振动信号特征提取研究 [J]. 中国农村水利水电, 2018(12):169.
LIU Dong, WANG Xin, HUANG Jianying, et al. Research on feature extraction of hydropower units vibration signal based on wavelet transform and SVD[J]. China Rural Water and Hydropower, 2018(12):169.
- [2] WANG H, CHEN J, DONG G. Feature extraction of rolling bearing's early weak fault based on EEMD and tunable Q-factor wavelet transform[J]. Mechanical Systems and Signal Processing, 2014, 48(1-2):103.
- [3] 苏建芳, 吴钦木. 基于小波包分析的电机滚动轴承故障诊断 [J]. 测控技术, 2019, 38(4):64.
SU Jianfang, WU Qinmu. Fault diagnosis of motor rolling bearing based on wavelet packet analysis[J]. Measurement & Control Technology, 2019, 38(4):64.
- [4] 翟婉明. 车辆-轨道耦合动力学 [M]. 4 版. 北京: 科学出版社, 2015.
- [5] 韩义涛, 翟婉明, 高建敏. 空吊轨枕对轨道结构的动力影响分析 [J]. 中国科技论文在线, 2006, 1(2):135.
HAN Yitao, ZHAI Wanming, GAO Jianmin. Effect of voided sleepers on track structure dynamics[J]. Sciencepaper Online, 2006, 1(2):135.
- [6] 韩义涛. 考虑轨道刚度不平顺时轮轨系统的动力特性分析 [D]. 成都: 西南交通大学, 2006.
HAN Yitao. Dynamic analysis of wheel/rail system considering track stiffness irregularity[D]. Chengdu: Southwest Jiaotong University, 2006.

(收稿日期: 2020-08-30)