

DOI: 10.19650/j.cnki.cjsi.J2514783

基于 GWO-VMD-NLM 的钢轨波磨激光检测与特征定量识别方法研究*

赵太飞^{1,2}, 翟新宁^{1,3}, 刘长李¹, 陈娅丽¹, 郑博睿¹

(1. 西安理工大学自动化与信息工程学院 西安 710048; 2. 数学地质四川省重点实验室(成都理工大学) 成都 610059;
3. 西安市无线光通信与网络研究重点实验室 西安 710048)

摘 要:针对现有钢轨波磨激光检测方法存在检测准确率较低的问题,提出了一种基于灰狼算法优化变分模态分解(GWO-VMD)的波磨信号处理方法。该方法联合多尺度排列熵(MPE)与方差贡献率(VCR)构成双阈值准则,以准确筛选噪声分量;进而采用非局部均值(NLM)滤波对噪声分量进行降噪处理,降噪后将其与有效分量重构,进而计算移动峰峰值(PPR)、移动波深幅值有效值(RMS)及超限率,实现波磨波长、位置与磨损程度的定量识别。以襄渝线实测数据为例,将所提算法与多种典型算法进行对比,包括粒子群优化变分模态分解联合非局部均值(PSO-VMD-NLM)、变分模态分解联合非局部均值(VMD-NLM)、集合经验模态分解联合非局部均值(EEMD-NLM)、灰狼优化变分模态分解联合小波阈值(GWO-VMD-WT)、完全自适应噪声集合经验模态分解联合小波阈值(CEEMDAN-WT)、完全自适应噪声集合经验模态分解联合非局部均值(CEEMDAN-NLM),以及传统小波阈值(WT)降噪方法。实验结果表明,相较于上述方法,所提出算法在信噪比(SNR)上分别提升了 3.9%、32.4%、68.4%、8.7%、46.6%、23.6% 和 89.6%;均方根误差(RMSE)分别降低了 15.5%、74.4%、85.9%、13.1%、80.5%、68.8% 和 88.9%。采用多线路实测数据进行泛化能力验证,结果表明所提出的算法在新线路工况下仍保持稳定的降噪性能与识别精度,能够在复杂噪声条件下实现钢轨波磨的多波段分离与多特征量化分析,为轨道状态评估和精准打磨维护提供可靠技术支撑。

关键词: 激光检测;灰狼优化算法;变分模态分解;非局部均值降噪;超限率

中图分类号: TH741 **文献标识码:** A **国家标准学科分类代码:** 460.4035

Research on a laser detection and quantitative characterization method for rail corrugation based on GWO-VMD-NLM

Zhao Taifei^{1,2}, Zhai Xinning^{1,3}, Liu Changli¹, Chen Yali¹, Zheng Borui¹

(1. Faculty of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China;
2. Geomathematics Key Laboratory of Sichuan Province (Chengdu University of Technology), Chengdu 610059, China;
3. Xi'an Key Laboratory of Wireless Optical Communication and Network Research, Xi'an 710048, China)

Abstract: To address the low detection accuracy of existing laser-based rail corrugation inspection methods, a rail corrugation signal processing approach based on grey wolf optimization-variational mode decomposition (GWO-VMD) is proposed. In this method, multi-scale permutation entropy (MPE) and variance contribution rate (VCR) are combined to construct a dual-threshold criterion for accurate identification of noise components. Subsequently, non-local means (NLM) filtering is applied to denoise the identified noise components. The denoised components are then reconstructed together with the effective components, and the moving peak-to-peak value (PPR), moving root mean square of corrugation depth amplitude (RMS), and exceedance rate are calculated to achieve quantitative identification of the corrugation wavelength, location, and wear severity. Using measured data from the Xiangyu Railway as a case study, the proposed algorithm is compared with several representative methods, including particle swarm optimization-variational mode decomposition combined with non-local means (PSO-VMD-NLM), variational mode decomposition combined with non-local means

收稿日期: 2025-12-17 Received Date: 2025-12-17

* 基金项目: 国家自然科学基金(61971345)、陕西省重点研发计划(2021GY-044)、数学地质四川省重点实验室开放基金(scsxdz2026-6)、西安市科技计划(23GXFW0060)项目资助

(VMD-NLM), ensemble empirical mode decomposition combined with non-local means (EEMD-NLM), grey wolf optimization combined with variational mode decomposition combined with wavelet thresholding (GWO-VMD-WT), complete ensemble empirical mode decomposition with adaptive noise combined with wavelet thresholding (CEEMDAN-WT), complete ensemble empirical mode decomposition with adaptive noise combined with non-local means (CEEMDAN-NLM), and the traditional wavelet thresholding (WT) denoising method. Experimental results demonstrate that, compared with the above methods, the proposed algorithm improves the signal-to-noise ratio (SNR) by 3.9%, 32.4%, 68.4%, 8.7%, 46.6%, 23.6%, and 89.6%, respectively, and reduces the root mean square error (RMSE) by 15.5%, 74.4%, 85.9%, 13.1%, 80.5%, 68.8%, and 88.9%, respectively. Furthermore, generalization capability is validated using measured data from multiple railway lines. The results indicate that the proposed algorithm maintains stable denoising performance and identification accuracy under new line conditions. It enables multi-band separation and multi-feature quantitative analysis of rail corrugation under complex noise conditions, providing reliable technical support for track condition assessment and precision grinding maintenance.

Keywords: laser-based measurement; gray wolf optimization algorithm; variational mode decomposition; non-local mean denoising; over-limit rate

0 引言

随着地铁和铁路网络的不断延伸,钢轨波磨问题造成的影响越来越显著。钢轨波磨是一种轨顶处有类似于波浪形磨耗的周期性不平顺现象^[1],严重时会引起列车与轨道之间的异常振动和冲击,从而影响人们出行的舒适度甚至影响列车行驶的安全性和稳定性^[2]。传统由人工检测的方法费时费力,容易误读。为了准确且快速地区别出波磨并通过治理降低波磨造成的影响,近年来,研究人员采用多种检测方法对波磨展开研究。

现有的检测方法主要有弦测法、惯性基准法、信号重构法、机器视觉法与深度学习法这5类^[3-5],文献[6-7]分别提出采用多弦和组合弦测量的方法获取波磨量值、发生位置及波长,但是弦测法缺乏普适性且硬件操作复杂,现场难部署。吴泽宇等^[8]通过建立车辆-轨道耦合动力学模型,结合频域积分法分析车轮踏面粗糙度对惯性基准法检测钢轨波磨结果的影响,但当车轮粗糙度幅值与钢轨波磨特征幅值比大于0.5时,检测结果显著偏大,需依赖车轮镟修以保证精度,此方法对车轮状态敏感,现场应用中需额外维护措施。孙颖等^[9]提出一种基于EWMD-ADTFD (extreme-point weighted mode decomposition-adaptive directional time-frequency distribution)算法的地铁钢轨波磨检测方法,在时频分析和抗噪性能方面表现良好。赵静等^[10]基于单目线结构光与图像处理算法实现了钢轨轮廓与磨耗测量,检测精度达到毫米级。文献[11]提出利用卷积神经网络检测钢轨波磨的智能识别方法,实现波磨的自动分类。然而,此类方法通常依赖大量标记样本,且在不同的线路结构、运行工况及环境条件变化下的检测稳定性和泛化能力仍需进一步验证,同时,其输出结果过多集中于状态判别,在波磨波长、幅值及程度描述方面有待提升。

相比之下,基于信号分割与统计特征分析的方法能够直接作用于现场实测的激光脉冲信号,在不依赖于训

练大规模样本条件下实现多特征提取,并具有较好的物理可解释性。为了减小既有研究方法的缺陷与传统分解方法易引发频谱混叠、端点效应等对波磨检测的定量分析与识别准确率造成的影响,文章融合多种分解、降噪重构的方法对原始波磨数据进行处理,计算了移动平均峰峰值(peak-to-peak average, PPR)、移动波深幅值的有效值(root mean square, RMS)和最大谷深值3个指标来确定波磨发生位置区间以及超限率。采用文章算法对多个现场典型实测信号进行验证,结果表明该方法能够准确地对波磨信号的波长、位置、幅值进行定量识别,具备良好的工程可适应性,可为打磨作业提供有效的指导,提高维修准确率。

1 算法介绍

1.1 灰狼优化算法

灰狼优化算法(grey wolf optimizer, GWO)是一种模拟灰狼群体捕食行为的智能优化算法,在解空间中高效搜索最优解,常用于处理复杂非线性信号的优化问题^[12]。该算法通过将狼群划分为4个等级: α (领头狼)、 β (副领头狼)、 δ (三阶狼)和 ω (从属狼)来模拟灰狼的社会等级制度与协作狩猎机制^[13]。数学模型如式(1)所示。

$$\begin{cases} \mathbf{X}(t+1) = \mathbf{X}_p(t) - \mathbf{A} \cdot \mathbf{D} \\ \mathbf{D} = |\mathbf{C} \cdot \mathbf{X}_p(t) - \mathbf{X}(t)| \\ \mathbf{A} = 2a \cdot \mathbf{r}_1 - a \\ \mathbf{C} = 2 \cdot \mathbf{r}_2 \end{cases} \quad (1)$$

式中: $\mathbf{X}(t+1)$ 表示更新后的灰狼位置; $\mathbf{X}_p(t)$ 代表当前迭代中猎物位置;向量 $\mathbf{A}$ 和 $\mathbf{C}$ 是随机参数; $\mathbf{D}$ 是当前灰狼个体与猎物估计位置之间的距离向量; a 是收敛因子,随迭代次数从2线性减少至0,用于控制范围精度; $\mathbf{r}_1, \mathbf{r}_2$ 的模是 $[0, 1]$ 内的随机数向量。最终灰狼个体更新位置如式(2)所示。

$$X(t+1) = \frac{X_\alpha(t) + X_\beta(t) + X_\delta(t)}{3} \quad (2)$$

式中: $X_\alpha(t)$, $X_\beta(t)$, $X_\delta(t)$ 分别是当前迭代中最优的3个灰狼位置向量。

1.2 变分模态分解算法

变分模态分解 (variational mode decomposition, VMD) 是一种具有自适应、完全非递归特点的信号分解方法, 利用迭代搜索变分模型最优解来确定每个分量的中心频率和带宽, 其核心思想是将信号分解问题转化为一个变分优化问题, 将原始信号 $f(t)$ 分解为一系列本征模态函数 (intrinsic mode function, IMF) [14]。VMD 算法的约束变分模型如式(3)所示。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (3)$$

式中: $u_k(t)$ 表示 K 个模态分量集合; ω_k 表示 K 个模态函数对应的中心频率集合; $\delta(t)$ 为单位脉冲函数。通过引入增广 Lagrange 函数, 将上述的约束变分模型转化为非约束变分模型, 如式(4)所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_k [P_k(t)] \right\|_2^2 + \|f(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (4)$$

式中: α 为二次惩罚系数; λ 为 Lagrange 乘子。对式(4)使用交替方向乘子和 Parseval 定理可求出约束变分模型中的最优的 K 个模态分量。

1.3 适应度函数

在信息论中, 熵被用来衡量信号的随机性和不确定性 [15]。由于对理论概率分布没有任何限制, 熵及其扩展方法是评估时间序列不确定性或复杂度的强有力的工具 [16-20]。能量熵能够用来量化信号能量集中的程度, 在文献 [21] 中的分析结果表明, 当钢轨发生波磨时, 能量会发生突变, 导致信号能量比较集中, 且能量熵会变小。基于 VMD 的能量熵定义式如式(5)所示。

$$H_{EN} = - \sum_{k=1}^K P_k \log P_k \quad (5)$$

式中: P_k 表示第 k 个 IMF 的能量归一化得到的概率分布。

为避免使用能量熵作为单一适应度函数容易过度追求能量集中而导致信号出现过分解的情况, 文章引入峭度来描述信号的波形特征, 用来表征概率分布形状的尖峭程度, 以防止信号分解出现简谐波的现象, 其表达式如式(6)所示。

$$K_u = \frac{E(y - \mu)^4}{\sigma^2} \quad (6)$$

式中: μ 和 σ 分别表示信号的均值和方差; $E(y - \mu)^4$ 表示四阶数学期望。复合适应度函数如式(7)所示, 其权重取值沿用文献 [22] 中的构建原则, 在保证能量集中的同时, 通过提高峭度项权重以抑制过分解现象, 从而获得物理意义更为合理的模态分解结果。

$$Q = 1/K_u + 0.1 \times H_{EN} \quad (7)$$

采用能量熵与峭度构造复合适应度函数, 能够有效保证信号能量集中、避免冗余并保留关键冲击特征, 防止有效信息丢失。通过迭代搜索适应度函数最小值来寻找分解效果最优的参数组合 (K, α)。

1.4 多尺度排列熵结合方差贡献率的噪声分量筛选方法

多尺度排列熵 (multiscale permutation entropy, MPE) 用于分析信号在多个时间尺度上的随机性, 噪声分量因噪声的随机性更大, 通常拥有较大的排列熵。相反, 含真实波磨信息的有效分量较为稳定, 排列熵较低。采用 MPE 区分噪声分量和有效分量有助于提取不同尺度下的钢轨波磨的特征信息。在尺度 s 下的排列熵定义式如式(8)所示 [23]。

$$\begin{cases} H_{PE}^{(s)} = - \sum_{j=1}^k P_j \ln P_j \\ H = \frac{H_{PE}^{(s)}}{\ln(m!)} \end{cases} \quad (8)$$

式中: m 表示向量中的元素个数; P_j 表示第 j 种符号序列的概率; $k = m!$ 为所有可能排列总数, 将 $H_{PE}^{(s)}$ 归一化处理后得到多尺度排列熵 H 。熵值 H 越接近 1, 说明信号随机程度越大, 非平稳性越高。

MPE 虽可刻画随机性, 但单一指标容易将小幅度高频波磨细节误判为噪声。为此引入方差贡献率 (variance contribution rate, VCR), 同时兼顾分量结构复杂度和能量占比, 提高筛选准确率。VCR 计算式如式(9)所示。

$$V_i = \frac{\frac{1}{N} \sum_{t=1}^N [I_i(t)]^2}{\sum_{j=1}^K \frac{1}{N} \sum_{t=1}^N [I_j(t)]^2} \times 100\% \quad (9)$$

式中: N 为信号长度; K 为 IMF 数量; $I_i(t)$ 表示第 i 个分量在 t 处的幅值。 V_i 越小, 说明该分量在总体能量中的占比越低, 越有可能是能量微弱、随机性强的噪声残留。噪声分量往往表现出较低的能量以及更高的无序性, 所以集中于 MPE 分布的高分位和 VCR 分布的低分位区间。基于上述特性, MPE 与 VCR 的阈值采用分位数形式设定, 其取值范围通过阈值敏感性分析进行验证, 表 1 结果表明在合理区间内噪声分量识别结果及去噪性能变化有限, 体现了方法对阈值参数的稳定性。

综合考虑噪声分量识别稳定性与有效信息保留, 文章选取 MPE 的 70% 作为复杂度阈值 T_{mpe} , VCR 的 15%

表 1 阈值敏感性分析
Table 1 Threshold sensitivity analysis

MPE 分位	VCR 分位	噪声 IMF 编号	NRR/dB
60%	10%	14~15	0.029
	15%	14~15	0.029
	20%	12~15	0.030
70%	10%	12~15	0.030
	15%	12~15	0.030
	20%	12~15	0.030
80%	10%	13~15	0.029
	15%	13~15	0.029
	20%	14~15	0.029

作为能量阈值 T_{ver} 。满足式 (10) 的分量被判为噪声分量。

$$\begin{cases} H(i) > T_{\text{mpe}} \\ V(i) < T_{\text{ver}} \end{cases} \quad (10)$$

式中: $H(i)$ 和 $V(i)$ 分别表示第 i 个分量的 MPE 和 VCR。

1.5 非局部均值滤波算法

非局部均值 (non-local means, NLM) 是一种基于图像块相似的去噪算法,它通过对信号进行分块,在一定范围内寻找与当前块相似的块,以这些块的非局部均值作为当前块的估计值,以达到去噪的效果。波磨信号 $y(t)$ 可表示为纯净波磨信号 $x(t)$ 和噪声 $n(t)$ 叠加组成,如式 (11) 所示。

$$y(t) = x(t) + n(t) \quad (11)$$

真实信号 $x(t)$ 在时间上会重复出现相似的形状片段,而噪声 $n(t)$ 无重复结构,所以 NLM 算法可以通过计算 $y(t)$ 中的全部相似块的加权平均值 $K(t)$ 来估计真实信号 $x(t)$,如图 1 所示。




图 1 NLM 算法示意图

Fig. 1 Diagram of the NLM algorithm

图 1 中的 $D(t)$ 表示搜索邻域,来规定样本点 t 的范围, S 是参考样本点,每个 S 有自己的局部搜索块, NLM 会逐个计算 S 的局部搜索块和 t 的局部搜索块的相似度,给每一个 S 打一个权重分 W ,相似度越高的 S ,权重分越高,对 t 去噪结果的贡献就越大,如式 (12) 所示。

$$\begin{cases} K(t) = \frac{1}{Z(t)} \sum_{s \in D(t)} w(t,s) y(s) \\ Z(t) = \sum_{s \in D(t)} w(t,s) \end{cases} \quad (12)$$

式中: $w(t,s)$ 分别是指以 t 和 s 中心的两个搜索块的相似度; $Z(t)$ 为归一化常数,表示搜索域中所有搜索块相似度之和。计算 $w(t,s)$ 如式 (13) 所示。

$$w(t,s) = \exp \left(\frac{- \sum_{\delta \in \Delta} [y(t+\delta) - y(s+\delta)]^2}{2L_{\Delta} \lambda^2} \right) \quad (13)$$

式中: Δ 表示以 t 为中心的搜索块, K 取 Δ 区域的一半; L_{Δ} 是以 s 为中心的邻域块; λ 为滤波器带宽参数^[24]。

1.6 灰狼优化变分模态分解联合非局部均值降噪的钢轨波磨识别算法

文章采用 GWO-VMD-NLM 分解降噪算法对钢轨波磨进行处理,首先对采集到的钢轨波磨信号采用 GWO 优化 VMD 算法,以能量熵和峭度联合构成复合适应度函数,通过迭代寻优,寻找适应度函数最小值对应的 VMD 分解参数组合后对原始信号进行分解。分解后采用 MPE 联合 VCR 策略筛选出噪声分量,对噪声分量采用 NLM 滤波降噪。由于波磨信号在不同波段具有不同的产生机理和治理手段,因此在噪声分量筛选并降噪后,需要将各分量重构到相应的波段内,以便后续开展针对性的养护措施。计算各分量的中心波长的公式如式 (14) 所示。

$$\lambda_{\text{center}} = \frac{v}{f_{\text{main}}} \quad (14)$$

式中: f_{main} 表示幅值谱中最大值对应的频率; v 表示测量仪检测速度。将噪声分量去噪后与有效分量按波段重构到轨道波磨养护规范中不同的波长区间 (10~30 mm、30~100 mm、100~300 mm、300~1 000 mm) 后进行波磨指标的定量分析,文章采用标准 BS EN13213-3:2006 作为检测钢轨波浪形磨耗的评价标准,该标准主要使用 3 个不同的指标来评判钢轨顶面波浪形磨耗程度,分别是 PPR、RMS、一定检测范围内的超限率^[25]。PPR 和 RMS 的计算如式 (15) 所示。

$$\begin{cases} PPR(x,L) = (a_1 + a_2 + \dots + a_n)/n \\ RMS(x,L) = \sqrt{\frac{1}{L} \int_x^{x+L} y^2(x) dx} \end{cases} \quad (15)$$

式中: x 表示采样距离,设置采样距离为 2 mm 等距离采样; L 表示分析窗长; a 表示样本数据的峰峰值; n 表示分析窗长内的样本点数。其中分析窗长根据波长范围进行划分,4 个波段的分析窗长分别设置为 0.15、0.5、1.5 和 5 m。

该研究采用滑动窗口分析法计算超限率,对不同波段设置上文中同样的分析窗长,移动步长设置为窗长的一半以确保连续性同时避免冗余。在每个分析窗口内,基于峰值与谷值关系计算最大谷深值,并从所有谷深值

中选取最大值作为该窗口的最大谷深值。对每个检测到的谷值 v , 谷深如式 (16) 所示。

$$D_v = \frac{P_l + P_r}{2} - V_v \tag{16}$$

式中: P_l 和 P_r 分别为谷值 v 左右两侧相邻的峰值; V_v 为谷值本身。窗口的最大谷深值即为该窗口内所有 D_v 的

最大值。超限率计算如式 (17) 所示。

$$E_b = \left(\frac{W_e}{W_t} \times 100\% \right) - 5\% \tag{17}$$

式中: W_e 表示最大谷深超过限值的窗口数; W_t 表示窗口总数, 5% 为行业标准规定的超限率容许基准。系统的总体工作流程如图 2 所示。




图 2 基于 GWO-VMD-NLM 的轨道波磨激光检测方法
Fig. 2 Laser detection method for rail wave wear based on GWO-VMD-NLM

2 信号分解降噪方法的对比分析

2.1 实验数据与参数设置

采用 HL-G1 型激光位移传感器获取钢轨波磨信号, 测量原理如图 3 所示, 使激光与目标面垂直, 由内置二极管向钢轨表面发射一束集中的激光后发生反射, 反射光经过光学透镜聚焦到互补金属氧化物半导体 (complementary metal oxide semiconductor, CMOS) 感光元件上, 再根据感光元件上光斑的成像位置, 结合三角几何关系^[26], 通过内部处理器计算出钢轨表面的高度信息。选取襄渝普通铁路上行线路 K326+430~K326+530 区段作为实测对象, 于 2025 年 8 月 27 日在小雨天气条件下完成数据采集。实测获得的钢轨表面信号如图 4 所示。




图 3 测量原理
Fig. 3 The measurement principle




图 4 重庆-襄渝线实测信号
Fig. 4 Measured signal diagrams of the Xiangyang-Chongqing railway line

为验证文章算法的分解性能, 引入粒子群 (particle swarm optimization, PSO) 算法优化 VMD、集合经验模态分解 (ensemble empirical mode decomposition, EEMD)^[27]、完全自适应噪声集合经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)、VMD 与 GWO-VMD 算法进行对比。参考相关研究中常用的参数设置, VMD 的参数 K 寻优范围为 (3, 20), α 寻优范围为 (500, 20 000), 以覆盖欠分解与过分解情形; EEMD 算法的高斯白噪声标准差 $\varepsilon_0 = 0.2$, 噪声添加次数 $NE = 100$, CEEMDAN 算法高斯白噪声标准差 $\varepsilon_0 = 0.2$, 噪声添加次数 $NE = 500$, 最大允许迭代次数

$MaxIter=1\ 000$ 。上述参数设置均来源于相关研究中广泛采用的经验区间,已在多种信号分解与去噪任务中得到验证,能够在分解性能与计算复杂度之间取得良好平衡^[28]。文章引入均方根误差 (root mean square error, RMSE)、端点评价指标 θ 和相关系数 γ 这 3 个指标来量化每个算法的重构误差、端点效应和模态混叠的分解效果^[29]。

1) 均方根误差 RMSE

在信号分解领域, RMSE 通过比较实际观测值与模型预测值之间的差异来评价模型精度,可用于衡量重构模型的有效性,其定义如式 (18) 所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n) - \hat{x}(n)]^2}$$
 (18)

其中, $x(n)$ 为原始波磨信号, $\hat{x}(n)$ 为重构波磨信号, N 为信号采样点数。

2) 端点评价指标 θ

端点效应是指信号在分解过程中在起始端和结束端出现的失真现象,会导致信号边缘与中间部分在频域或时域特性上不一致。端点评价指标定义如式 (19) 所示。

$$\theta = \sqrt{\frac{\sum_{i=1}^K R_i^2 - R_0^2}{R_0^2}}$$
 (19)

其中, R_0 和 R_i 分别表示原始信号和各子信号的有效值, K 表示分解的子信号个数。 θ 是非负数,它越接近 0,端点效应对信号分解结果的影响越小。类似地,它越接近 1,端点效应对信号分解的影响就越大。

3) 相关系数 γ

子信号之间的相关系数能够很好地定量评估信号分解的模态混叠现象,其取值范围为 $(-1, 1)$,采用 Pearson 相关系数公式计算,如式 (20) 所示。

$$\gamma_{xy} = \frac{\sum_{n=1}^N [x_i - \bar{x}][y_i - \bar{y}]}{\sqrt{\sum_{n=1}^N [x_i - \bar{x}]^2} \sqrt{\sum_{n=1}^N [y_i - \bar{y}]^2}}$$
 (20)

式中: x_i 和 y_i 是这两个子信号在第 i 个频率点处的幅度; $\bar{x}$ 和 $\bar{y}$ 是这两个子信号的平均幅度; N 为频点总数。计算相关系数的平均值如式 (21) 所示,较高的平均值表示子信号在频域中具有较高的相似性。

$$\bar{\gamma} = \frac{\sum \gamma_{xy}}{K}$$
 (21)

2.2 不同分解方法结果对比与分析

根据评价分解效果的 3 个指标,对 5 种信号分解方法进行了比较,如图 5~9 和表 2 所示。图 5~9 表明,未优化的 VMD 和 GWO-VMD 分解出来的分量之间的相关系数较小,说明模态混叠效应较弱, EEMD 相关系数效果

最差,这通常是存在过分解的问题。根据表 2, GWO-VMD 展现出了较好的性能,其中 RMSE 是 0.001 23,相较于 PSO-VMD、VMD、EEMD、CEEMDAN, GWO-VMD 分别降低了 20.65%、94.05%、87.58%、74.27%。通过采用 GWO 对 VMD 的分解参数进行自适应搜索,有效抑制了传统分解方法中容易出现的端点效应和模态混叠现象,并且有效降低了重构误差,能够为后续波磨分析提供更为可靠的信号分量。从运行时间上看,具有智能算法寻优的方法显著大于传统分解方法,这是因为 GWO 和 PSO 在迭代过程中需要反复调用 VMD 以搜索优化参数, GWO-VMD 的运行时间明显小于 PSO-VMD,说明 GWO 在本实验中具有更高的搜索效率和时间优势。综合来看, GWO-VMD 在保证重构精度的同时,较 PSO-VMD 具备更好的时间优势,更适合作为后续波磨分析的方法选择。




图 5 PSO-VMD 分量间相关系数
Fig. 5 Correlation coefficient diagram between PSO-VMD components



图 6 VMD 分量间相关系数
Fig. 6 Correlation coefficient diagram between VMD components




图 7 GWO-VMD 分量间相关系数

Fig. 7 Correlation coefficient diagram between GWO-VMD components




图 8 EEMD 分量间相关系数

Fig. 8 Correlation coefficient diagram between EEMD components



图 9 CEEMDAN 分量间相关系数

Fig. 9 Correlation coefficient diagram between CEEMDAN components

表 2 分解效应评估指标

Table 2 Evaluation indexes of decomposition performance

评估指标	GWO-VMD	PSO-VMD	VMD	EEMD	CEEMDAN
RMSE	0.001 23	0.001 55	0.020 67	0.009 90	0.004 78
θ	0.465 73	0.472 82	0.513 55	0.705 07	0.374 51
$\bar{\gamma}$	0.041 96	0.042 99	0.018 76	0.163 68	0.159 08
时间/s	2 536. 7	9 627. 9	79. 115	87. 246	65. 668

2.3 不同降噪方法结果对比与分析

为验证算法的降噪性能,引入 PSO-VMD-NLM、VMD-NLM、EEMD-NLM、小波阈值 (wavelet threshold, WT)、GWO-VMD-WT、CEEMDAN-WT、CEEMDAN-NLM 方法与文章算法的去噪效果进行对比,来验证所提 NLM 降噪方法的有效性,其中 WT 采用常用的 Sym6 小波基函数和“Rigrsure”规则进行软阈值降噪。

为了更准确的反映出以上方法的去噪效果,引入信噪比 (signal-to-noise ratio, SNR)、RMSE 作为评价标准,鉴于实测钢轨波磨信号不存在理想纯净真值,传统 SNR、RMSE 仅能反应相对差异,难以量化实际降噪能力,又引入了噪声抑制比 (noise reduction ratio, NRR),与 SNR、RMSE 组成三指标联合评估体系,具有可重复、可对比、无真值依赖的优点,SNR、NRR 公式分别如式 (22) 和 (23) 所示。

$$SNR = 10\lg\left(\frac{\sum_{n=1}^N x^2(n)}{\sum_{n=1}^N [x(n) - \hat{x}(n)]^2}\right) \quad (22)$$

$$NRR = 10\lg\left(\frac{\text{var}(x)}{\text{var}(\hat{x})}\right) \quad (23)$$

式中: x 为原始实测信号; $\hat{x}$ 为去噪后信号,长度为 N ; n 为离散时间索引 ($n = 1, 2, 3, \dots, N$); var 表示方差; NRR 数值越大,抑制噪声能力越强。

最终得到的去噪信号前 500 采样点对比结果如图 10 所示,图 11 是对图 10 进行局部放大后的效果,从图 11 中可以看出,GWO-VMD-NLM 重构后的信号与原始信号曲线更接近,次之是 PSO-VMD-NLM 曲线,说明 GWO-VMD-NLM 在去除噪声的同时保留了更多的原始信号信息。

评估指标结果如表 3 所示,该文章算法在 SNR、RMSE 和 NRR 这 3 个关键指标上均显著优于其他对比算法。其中,GWO-VMD-NLM 的 SNR 较 PSO-VMD-NLM 算法提升约 3.9%,说明在相同去噪策略下,基于 GWO 的参数优化更能提高信号质量,较 GWO-VMD-WT 算法




图 10 不同分解去噪方法前 500 采样点对比图

Fig. 10 Comparison diagram of the first 500 sampling points of different decomposition denoising methods




图 11 不同分解去噪方法前 500 采样点对比放大图

Fig. 11 Enlarged comparison diagram of the first 500 sampling points of different decomposition denoising methods

表 3 不同分解去噪方法的性能比较			
Table 3 Performance comparison of different decomposition and denoising methods			
算法	SNR	RMSE	NRR
GWO-VMD-NLM	32.005 4	0.002 918	0.195 5
PSO-VMD-NLM	30.758 2	0.003 369	0.133 8
VMD-NLM	24.172 2	0.011 396	0.097 0
EEMD-NLM	19.010 3	0.020 647	0.030 3
GWO-VMD-WT	29.446 9	0.003 357	0.113 3
CEEMDAN-WT	21.820 3	0.014 940	0.092 0
CEEMDAN-NLM	25.904 5	0.009 336	0.105 9
WT	16.882 0	0.026 380	0.018 5

提升约 8%,表明 NLM 降噪方法在处理钢轨波磨信号时优于 WT 方法。相比传统 VMD-NLM 方法提升约

24.5%,该算法通过灰狼优化自适应确定 VMD 参数,有效抑制了模态混叠。GWO-VMD-NLM 的 RMSE 较 GWO-VMD-WT 降低 13.1%,通过 NLM 滤波确保了信号的高精度重构。其中 NRR 为 0.195 5,较 PSO-VMD-NLM 提升约 31.6%,表明在去除噪声的同时,该文章算法对信号有效成分的保留能力最强,避免了过度平滑导致的细节丢失。综上,GWO-VMD-NLM 通过 GWO 优化 VMD 分解参数,结合 NLM 滤波的优势,实现了噪声抑制与信号保真的最优平衡。

3 基于 GWO-VMD-NLM 的钢轨波磨识别与验证

3.1 数据分析

对采集到的襄渝线实测信号经过 GWO-VMD 进行分解参数寻优,寻优迭代过程如图 12 所示。在第 11 次迭代后,复合适应度函数值趋于一条直线,说明此时已达到最优,适应度值为 0.025 025,最优参数组合为(570,15)。




图 12 GWO 优化 VMD 迭代图

Fig. 12 Iteration diagram of VMD optimized by GWO

利用上述的参数对信号进行分解,图 13 和 14 分别是分解后得到的 IMF 分量的三维时域图和频域图。图 13 可以看出,各 IMF 分量在三维空间中呈现出清晰的层次结构,不同分量之间没有明显的交叉重叠现象,从 IMF1 到 IMF15,分量频率呈现从低到高的规律性变化,高频分量主要包含信号的细节特征,低频分量则反映信号的趋势成分。为有效展示 GWO-VMD 的分解效果并聚焦于与钢轨波磨最相关的频带,重点对 IMF1~IMF5 进行频域分析,如图 14 所示,各 IMF 分量在频域中占据不同的频带范围,没有出现模态混叠现象。每个 IMF 分量的频谱都呈现出明显的峰值特征,表明该分量存在能量集中,包含特定频带的波磨信息。




图 13 IMF 分量三维时域图

Fig. 13 Three-dimensional time domain diagram of IMF components




图 14 IMF 分量频域图

Fig. 14 Frequency domain diagram of IMF components

3.2 噪声分量识别与 NLM 降噪

由式(8)和(9)计算各 IMF 分量的 MPE 及 VCR,得到的结果如图 15 所示。




图 15 IMF 的 MPE 与 VCR 分布图

Fig. 15 Distribution diagram of MPE and VCR of IMF components

根据式(10),IMF12~IMF15 被判为噪声分量,对噪声主导的分量采用 NLM 算法进行降噪,降噪后的分量与有效信号分量重构为最终的去噪实测钢轨波磨信号。

3.3 信号重构与特征波段提取

将各分量中心波长与 4 个特征波段匹配,即可确定 IMF 分量所属的波长区间,用于后续重构信号与超限率的计算。如表 4 为所提算法得到的信号分量所匹配的特征波段区间,其中 IMF1 未给出波段区间,因为该分量的特征频率集中在 0 Hz 附近,在图 14 中可以得到验证。

表 4 信号分量匹配的特征频带范围


Table 4 Characteristic frequency band ranges for signal component matching (mm)		
分量	中心波长	波段
IMF1	8 333.33	—
IMF2	990.10	300~1 000
IMF3	406.50	
IMF4	224.22	
IMF5	170.94	100~300
IMF6	128.87	
IMF7	106.04	
IMF8	89.13	30~100
IMF9	76.92	
IMF10	61.50	
IMF11	49.12	
IMF12	41.08	
IMF13	34.41	10~30
IMF14	28.69	
IMF15	22.08	

将各波段的分量分别进行重构,图 16(a)和(b)分别是不同波段重构后的信号以及局部放大图,可以看出每个波段内的信号都占据一定的幅值区间,其中 10~30 mm 波段信号幅值较小,大约在-0.03~0.02 mm,30~100 mm 幅值处于-0.4~0.3 mm。100~300 mm 和 300~1 000 mm 波段的幅值较高,在-1.0~0.7 mm,这两个波段需重点关注,可以初步判断存在波磨,还需要进一步作定量分析。


3.4 波磨识别结果与分析

图 17~20 是所提算法与 LGBM4S 测量仪的各波段 PPR 指标对比图。

从图 17~20 中可以看出,文章算法与 LGBM4S 测量仪测得的 PPR 指标数据接近,同时,4 个波段信号的 PPR 都



(a) 不同波段重构信号
(a) Reconstructed signals across frequency bands



(b) 不同波段重构信号局部放大图
(b) Local magnification diagrams of the reconstructed signals from different bands

图 16 不同波段重构信号与局部放大图

Fig. 16 Reconstructed signals from different bands and local magnification diagrams

在 71.5~72.0 m 处取得最大值,根据图 4 也可以看出信号在 72 m 附近出现明显冲激项,验证了所提算法的准确性。




图 17 10~30 mm 波段 PPR 对比

Fig. 17 PPR comparison diagram of the 10~30 mm band

为定量验证文章算法的准确性,采用多种分解降噪方法计算波磨指标,如表 5~6 所示。GWO-VMD-NLM 在




图 18 30~100 mm 波段 PPR 对比

Fig. 18 PPR comparison diagram of the 30~100 mm band




图 19 100~300 mm 波段 PPR 对比

Fig. 19 PPR comparison diagram of the 100~300 mm band




图 20 300~1 000 mm 波段 PPR 对比

Fig. 20 PPR comparison diagram of the 300~1 000 mm band

测量各波段波磨信号的 PPR、RMS 比其他方法所测得的结果都更接近测量标准数值。

表 5 不同方法测得的 PPR 值比较

Table 5 Comparison of PPR values measured by different methods

方法	波段/mm			
	10~30	30~100	100~300	300~1 000
LGBM4S	0.008 0	0.043 8	0.107 7	0.193 9
GWO-VMD-NLM	0.008 4	0.043 2	0.107 5	0.193 3
PSO-VMD-NLM	0.009 1	0.048 7	0.109 8	0.196 4
VMD-NLM	0.004 1	0.020 8	0.071 1	0.149 2
EEMD-NLM	0.017 1	0.063 3	0.066 5	0.217 9
GWO-VMD-WT	0.007 3	0.039 2	0.099 7	0.188 1
CEEMDAN-WT	0.006 6	0.020 4	0.085 2	0.167 7
CEEMDAN-NLM	0.006 9	0.021 6	0.084 4	0.176 4
WT	0.013 0	0.060 2	0.135 0	0.216 4

表 6 不同方法测得的 RMS 值比较

Table 6 Comparison of RMS values measured by different methods

方法	波段/mm			
	10~30	30~100	100~300	300~1 000
LGBM4S	0.000 6	0.005 2	0.011 5	0.018 6
GWO-VMD-NLM	0.000 6	0.005 0	0.011 2	0.018 7
PSO-VMD-NLM	0.000 8	0.005 7	0.011 2	0.019 3
VMD-NLM	0.001 0	0.002 6	0.010 7	0.014 3
EEMD-NLM	0.001 9	0.002 3	0.014 6	0.014 0
GWO-VMD-WT	0.000 5	0.005 0	0.012 4	0.019 8
CEEMDAN-WT	0.001 4	0.004 3	0.018 8	0.017 2
CEEMDAN-NLM	0.000 9	0.005 6	0.018 6	0.017 2
WT	0.004 8	0.003 1	0.026 6	0.034 8

3.5 基于最大谷深值的钢轨波磨超限率的计算方法

在钢轨波磨状态评估中,超限率是衡量波磨严重程度的关键指标,不同波长的波磨对列车运行的影响不同,因此需要分别评估。图 21~24 为 4 个波段对应的最大谷深随里程分布图,其中阴影部分是最大谷深值超过限值的窗口部分,从图中可以看出,波磨主要存在于 100~300 mm 和 300~1 000 mm 波段中,同时也验证了前文分析,此处发生波磨与轨道不平顺有关,需要进行打磨。

根据超限率计算公式,计算出来各波段的超限率如表 7 所示,可以看出,10~30 mm 和 30~100 mm 波段状态良好,100~300 mm 波段超限率 4.85%,处于临界状态需重点关注,300~1 000 mm 波段超限率高达 33.46%,属于严重超标需立即处理。通过分波段计算,可以精准定位问题所在的波段,从而采取针对性的打磨措施。




图 21 10~30 mm 波段最大谷深随里程分布图
Fig. 21 Distribution diagram of maximum valley depth with mileage in the 10~30 mm band




图 22 30~100 mm 波段最大谷深随里程分布图
Fig. 22 Distribution diagram of maximum valley depth with mileage in the 30~100 mm band




图 23 100~300 mm 波段最大谷深随里程分布图
Fig. 23 Distribution diagram of maximum valley depth with mileage in the 100~300 mm band




图 24 300~1 000 mm 波段最大谷深随里程分布图
Fig. 24 Distribution diagram of maximum valley depth with mileage in the 300~1 000 mm band

表 7 各波段超限比例

Table 7 Overrun proportion of each frequency band

波段/mm	超限率/%
10~30	0
30~100	0
100~300	4.85
300~1 000	33.46

3.6 不同线路区段下的波磨特征识别结果分析

为进一步验证所提方法在不同线路工况下的适用性,选取哈齐高速铁路下行线路 K4+642~K4+842 区段作为补充实验数据,于 2025 年 11 月 20 日在晴好天气条件下完成采集。采用与前述实验一致的参数配置,对该线路数据进行处理与对比分析,哈齐线实测信号如图 25 所示。




图 25 哈齐线实测信号图

表 8 给出了该线路条件下各方法的性能指标对比结果。可以看出,GWO-VMD-NLM 在新线路区段仍保持较高的信噪比提升和较低的重构误差,整体性能与主实验线路保持一致。

表 8 哈齐线不同分解去噪方法的性能比较

Table 8 Performance comparison of different decomposition denoising methods

算法	SNR	RMSE	NRR
GWO-VMD-NLM	29.329 6	0.005 831	0.846 7
PSO-VMD-NLM	27.879 8	0.006 608	0.546 3
VMD-NLM	22.291 4	0.016 717	0.077 3
EEMD-NLM	16.010 3	0.022 633	0.052 4
GWO-VMD-WT	26.370 9	0.009 700	0.302 9
CEEMDAN-WT	19.979 4	0.019 754	0.070 1
CEEMDAN-NLM	25.434 2	0.010 463	0.244 8
WT	15.789 0	0.028 321	0.027 7

此外,考虑到波磨指标 PPR 在工程实践中应用更为广泛,由表 9 的 PPR 的对比结果可见,所提方法在哈齐线所测区段条件下同样能够保持较高的准确率,表明该方法具有一定的鲁棒性与工程适用性。

表 9 哈齐线不同方法测得的 PPR 值比较

Table 9 Comparison of PPR values measured by different methods

方法	波段/mm			
	10~30	30~100	100~300	300~1 000
LGBM4S	0.008 0	0.025 7	0.072 3	0.156 7
GWO-VMD-NLM	0.008 2	0.025 0	0.076 2	0.153 3
PSO-VMD-NLM	0.006 8	0.026 3	0.081 3	0.160 7
VMD-NLM	0.003 7	0.020 8	0.091 1	0.189 2
EEMD-NLM	0.016 5	0.047 6	0.102 5	0.209 1
GWO-VMD-WT	0.005 9	0.035 7	0.068 7	0.162 1
CEEMDAN-WT	0.005 6	0.019 4	0.055 9	0.173 3
CEEMDAN-NLM	0.007 3	0.020 6	0.053 4	0.163 4
WT	0.017 1	0.050 2	0.136 0	0.227 8

4 结 论

本研究提出了一种基于 GWO-VMD-NLM 的钢轨波磨特征提取与分析方法。通过对襄渝普通铁路和哈齐高速铁路区段的钢轨表面数据进行处理,结果表明该方法能够有效识别钢轨波磨的多波段特征信息。与几种常见

Fig. 25 Measured signal diagrams of the harbin-qiqihar high-speed railway

的分解方法相比,GWO-VMD 在相关系数、端点效应和重构误差等方面均表现出优越性能,与现有的 VMD-NLM、PSO-VMD-NLM、EEMD-NLM、GWO-VMD-WT、CEEMDAN-WT、CEEMDAN-NLM、WT 分解降噪方法相比,文章所提出的方法在参数寻优准则、噪声分量判别方式以及去噪策略上进行了统一设计。通过构建复合适应度函数,使群体智能算法在参数优化过程中兼顾分解精度与模态结构合理性,从而抑制过分分解现象;同时结合 MPE 与 VCR 建立双阈值噪声识别机制,从随机性和能量分布角度对 IMF 进行联合判别,并仅对判定为噪声的分量实施 NLM 去噪,在保持有效结构信息的同时提升整体降噪效果。定量结果表明,该方法计算出来的 PPR、RMS 等波磨关键指标更接近标准值,验证了算法的准确性,为钢轨状态评估和精准打磨提供可靠的技术支撑。文章所提出的方法不依赖大规模标注数据,能够在不同典型线路条件下实现多波长波磨分量的分离与多特征量化分析,在样本受限或工况多变的检测场景中具有一定优势,在一定程度上能够为有监督深度学习方法提供参考标签或结构化输入。需要说明的是,所提出的方法主要面向波磨离线分析场景,重点关注复杂背景噪声条件下波磨信号的高精度分解与特征定量识别,其核心目标在于为钢轨打磨维护提供可靠的物理量依据,针对长里程数据处理和车载在线检测应用场景,后续研究将围绕优化参数搜索策略、引入自适应参数调整机制以降低计算复杂度,并结合多源干扰开展实验,进一步评估不同环境因素对分解结果和波磨量化指标的影响以增强算法在复杂工况下对异常噪声的抑制能力。同时探索将所提算法的分解降噪结果与深度学习模型相结合,以进一步提升钢轨波磨检测的工程适用性与智能化水平。

参考文献

- [1] 崔晓璐,卜涵,徐晓天,等. 高速铁路车轮多边形和钢轨波磨相关性影响[J]. 振动、测试与诊断, 2025, 45(1): 45-50,199.
- CUI X L, BU H, XU X T, et al. Relevance and influence between wheel polygon and rail corrugation in high-speed railways[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(1): 45-50,199.
- [2] 于耀翔,郭亮,陈再刚,等. 钢轨波磨对城轨车辆轴箱振动特性影响研究[J]. 机械工程学报, 2025, 61(23): 87-95.
- YU Y X, GUO L, CHEN Z G, et al. Investigation on the effect of rail corrugation on dynamic vibration characteristics of urban rail vehicle axle-box bearings[J]. Journal of Mechanical Engineering, 2025, 61(23): 87-95.
- [3] 肖宏,王阳,刘秀波,等. 钢轨波磨检测原理、方法及

装置研究进展[J]. 机械工程学报, 2025, 61(10): 191-214.

XIAO H, WANG Y, LIU X B, et al. Review on detection principle, method, and device of rail corrugation[J]. Journal of Mechanical Engineering, 2025, 61(10): 191-214.

- [4] 汤华,易茜. 激光扫描下混凝土桥梁表面病害机器视觉检测[J]. 电子测量技术, 2024, 47(17): 123-129.

TANG H, YI Q. Machine vision detection of surface defects in concrete bridges under laser scanning[J]. Electronic Measurement Technology, 2024, 47(17): 123-129.

- [5] 赵海丽,狄子隆,景文博,等. 融合动态卷积与可变形注意力的钢材缺陷检测[J]. 仪器仪表学报, 2025, 46(12): 75-86.

ZHAO H L, DI Z L, JING W B, et al. A steel defect detection with fused dynamic convolution and deformable attention[J]. Chinese Journal of Scientific Instrument, 2025, 46(12): 75-86.

- [6] 殷华,朱洪涛,魏晖,等. 基于中点弦测模型的钢轨波磨量值估计[J]. 振动、测试与诊断, 2016, 36(5): 954-959,1027.

YIN H, ZHU H T, WEI H, et al. Discussion on estimate rail corrugation amplitude based upon midpoint chord model[J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(5): 954-959,1027.

- [7] 魏琨,刘宏立,马子骥,等. 基于组合弦测的钢轨波磨广域测量方法[J]. 西北大学学报(自然科学版), 2018, 48(2): 199-208.

WEI H, LIU H L, MA Z J, et al. A wide-area measurement method of rail corrugation based on the combination-chord system[J]. Journal of Northwest University (Natural Science Edition), 2018, 48(2): 199-208.

- [8] 吴泽宇,李明航,王文斌,等. 车轮踏面粗糙度对基于惯性基准法的钢轨波磨检测结果影响分析[J]. 振动与冲击, 2023, 42(15): 241-249.

WU Z Y, LI M H, WANG W B, et al. Influence analysis of wheel tread roughness on rail corrugation detection results based on inertial reference method[J]. Journal of Vibration and Shock, 2023, 42(15): 241-249.

- [9] 孙颖. 基于 EWMD-ADTFD 算法的地铁钢轨波磨检测

- 方法[J]. 铁道建筑, 2025, 65(3): 145-150.
- SUN Y. Detection method for metro rail corrugation based on EWMD-ADTFD [J]. Railway Engineering, 2025, 65(3): 145-150.
- [10] 赵静. 机器视觉下的钢轨廓形提取与磨损测量[J]. 测绘通报, 2023(12): 159-163, 177.
- ZHAO J. Extracting rail profile and measuring wear based on machine vision [J]. Bulletin of Surveying and Mapping, 2023(12): 159-163, 177.
- [11] 王阳, 肖宏, 张智海, 等. 基于一维卷积神经网络的钢轨波磨迁移诊断方法 [J]. 铁道学报, 2025, 47(4): 115-123.
- WANG Y, XIAO H, ZHANG ZH H, et al. Rail corrugation migration diagnosis method based on one-dimensional convolutional neural network [J]. Journal of the China Railway Society, 2025, 47(4): 115-123.
- [12] 刘稳, 贺东京, 谌侨, 等. 基于改进灰狼与多层感知机算法耦合的航空发动机轴承故障诊断方法 [J]. 工程机械, 2025, 56(10): 35-42, 58, 129.
- LIU W, HE D J, CHEN Q, et al. Aeroengine bearing fault diagnosis method based on coupling of improved grey wolf optimization with multilayer perceptron algorithm [J]. Construction Machinery and Equipment, 2025, 56(10): 35-42, 58, 129.
- [13] LI H, LI S S, SUN J, et al. Ultrasound signal processing based on joint GWO-VMD wavelet threshold functions [J]. Measurement, 2024, 226: 114143.
- [14] 夏焰坤, 王宛婷, 黄鹏. 基于 PSO-VMD 的永磁同步电机匝间短路振动信号故障特征提取研究 [J]. 电子测量与仪器学报, 2024, 38(7): 196-207.
- XIA Y K, WANG W T, HUANG P. Fault feature extraction of inter-turn short circuit vibration signals in PMSM based on PSO-VMD [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 196-207.
- [15] SHANNON C E. A mathematical theory of communication [J]. The Bell System Technical Journal, 1948, 27(3): 379-423.
- [16] COSTA M, GOLDBERGER A L, PENG C K. Multiscale entropy analysis of complex physiologic time series [J]. Physical Review Letters, 2002, 89(6): 068102.
- [17] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy [J]. American Journal of Physiology-Heart and Circulatory Physiology, 2000, 278(6): H2039-H2049.
- [18] CHEN W T, WANG ZH ZH, XIE H B, et al. Characterization of surface EMG signal based on fuzzy entropy [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.
- [19] BANDT C, POMPE B. Permutation entropy: A natural complexity measure for time series [J]. Physical Review Letters, 2002, 88(17): 174102.
- [20] ROSTAGHI M, AZAMI H. Dispersion entropy: A measure for time-series analysis [J]. IEEE Signal Process Letters, 2016, 23(5): 610-614.
- [21] YANG J W, HUO J Y, YAO D CH. Rail corrugation detection based on optimal position window and Weighted-bandwidth mode decomposition [J]. Measurement, 2025, 255: 117888.
- [22] 夏焰坤, 寇坚强, 李欣洋. 基于 IWOA-VMD 的永磁同步电机匝间短路故障振动信号去噪方法 [J]. 电子测量与仪器学报, 2024, 38(4): 202-216.
- XIA Y K, KOU J Q, LI X Y. Denoising method for vibration signal of inter-turn short circuit fault in PMSM based on IWOA-VMD [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 202-216.
- [23] ZHAO B W, WANG Y H, ZENG X P, et al. Impact monitoring on complex structure using VMD-MPE feature extraction and transfer learning [J]. Ultrasonics, 2024, 136: 107141.
- [24] LYU Y, ZHU Q L, YUAN R. Fault diagnosis of rolling bearing based on fast nonlocal means and envelop spectrum [J]. Sensors, 2015, 15(1): 1182-1198.
- [25] 黄佩. 便携式钢轨波磨测量仪的设计与实现 [D]. 长沙: 湖南大学, 2021.
- HUANG P. Design and realization of portable rail corrugation measuring instrument [D]. Changsha: Hunan University, 2021.
- [26] 王晓嘉, 高隽, 王磊. 激光三角法综述 [J]. 仪器仪表学报, 2004, 25(S2): 601-604, 608.
- WANG X J, GAO J, WANG L. Survey on the laser triangulation [J]. Chinese Journal of Scientific Instrument, 2004, 25(S2): 601-604, 608.
- [27] 郭森, 赵纪元, 原可义, 等. 激光超声法零件缺陷在线自动检测系统研究 [J]. 电子测量技术, 2025, 48(21): 67-76.

GUO M, ZHAO J Y, YUAN K Y, et al. Research on on-line and automatic measurement system of part defects using laser ultrasonic technique[J]. Electronic Measurement Technology, 2025, 48(21): 67-76.

[28] 王孔贤, 邵英, 王黎明. 基于改进变分模态分解和小波阈值法的单相接地故障电流降噪[J]. 科学技术与工程, 2023, 23(29): 12556-12566.

WANG K X, SHAO Y, WANG L M. Denoising of single-phase grounding fault current based on improved VMD and wavelet threshold[J]. Science Technology and Engineering, 2023, 23(29): 12556-12566.

[29] WANG Q SH, CHEN SH Q, ZENG J, et al. A deep learning fault diagnosis method for metro on-board detection on rail corrugation [J]. Engineering Failure Analysis, 2024, 164: 108662.

作者简介



赵太飞(通信作者),2000 年和 2003 年于成都理工大学分别获得学士学位和硕士学位,2007 年于电子科技大学获得博士学位,现为西安理工大学教授,主要研究方向为网络通信与自组织网络技术。
E-mail:tfz@ xaut. edu. cn

Zhao Taifei (Corresponding author) received his B. Sc. and M. Sc. degrees from Chengdu University of Technology in 2000 and 2003, respectively, his Ph. D. degree from the University of Electronic Science and Technology of China in 2007. He is currently a professor at Xi'an University of Technology. His main research interests include network communications and self-organizing network technologies.



翟新宁,2024 年于河南工程学院获得学士学位,目前正在西安理工大学自动化与信息工程学院攻读硕士学位,主要研究方向为钢轨波磨检测与智能识别。
E-mail:2240321187@ stu. xaut. edu. cn

Zhai Xinning received his B. Sc. degree from Henan University of Engineering in 2024. He is currently pursuing his M. Sc. degree in the School of Automation and Information Engineering at Xi'an University of Technology. His main research interests include rail corrugation detection and intelligent identification.