

DOI:10.13382/j.jemi.B2508494

基于改进复杂度追踪的轮轨力鲁棒检测方法*

何 静 闫思峰 张昌凡

(湖南工业大学交通与电气工程学院 株洲 412007)

摘要: 轮轨力是衡量铁路安全性的核心指标,获取轮轨力数据最直接且有效的方式是利用巡检车上的测力轮对,但是,从测力轮对采集到的数据往往包含多种干扰因素,这使得准确评估铁路状况变得复杂,而现有的算法难以从现实的复杂干扰中分离出所需的轮轨力信号。为此,本文提出了一种融合改进型复杂度追踪算法与信号特征提取一体化的轮轨力鲁棒检测方法。首先,采用新型小批量迭代策略从轮轨力总数据集抽取子集作为小批量样本,提升了算法的全局寻优能力,避免了陷入局部极值;其次,使用基于自适应学习率调度器的梯度下降算法进行复杂度追踪,有效地优化了模型的收敛速度和整体性能,更适用于实际工程;然后,利用 Hilbert-Huang 变换方法对分离得到的轮轨力源信号提取特征参数。最后,经过实际轮轨力数据实验验证,结果表明该检测方法能够有效地从混杂信号中分离出轮轨力信号,并准确地提取特征参数,为铁路安全状态监测提供了有力的数据支撑。

关键词: 复杂度追踪;盲源分离;梯度下降;轮轨力

中图分类号: TN911.7

文献标识码: A

国家标准学科分类代码: 470.40

Robust wheel-rail force detection method based on improved complexity pursuit

He Jing Yan Sifeng Zhang Changfan

(College of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: Wheel-rail force is a core indicator for measuring railway safety. The most direct and effective way to obtain wheel-rail force data is to use the force-measuring wheel pairs on inspection vehicles. However, the data collected from the force-measuring wheel pairs often contains multiple interference factors, which makes the accurate assessment of railway conditions complex. Moreover, existing algorithms are difficult to separate the required wheel-rail force signals from the complex interferences in reality. To this end, this paper proposes a robust wheel-rail force detection method that integrates an improved complexity tracking algorithm with signal feature extraction. Firstly, a new small-batch iterative strategy is adopted to extract subsets from the total wheel-rail force data set as small-batch samples, which enhances the global optimization ability of the algorithm and avoids getting trapped in local extremum. Secondly, the gradient descent algorithm based on the adaptive learning rate scheduler is used for complexity tracking, which effectively optimizes the convergence speed and overall performance of the model, making it more suitable for practical engineering. Then, the Hilbert-Huang transform method is utilized to extract the characteristic parameters of the separated wheel-rail force source signals. Finally, through the experimental verification of actual wheel-rail force data, the results show that this detection method can effectively separate the wheel-rail force signals from the mixed signals and accurately extract the characteristic parameters, providing strong data support for the monitoring of railway safety conditions.

Keywords: complexity pursuit; blind source separation; gradient descent; wheel-rail force

收稿日期: 2025-06-24 Received Date: 2025-06-24

* 基金项目: 国家自然科学基金(52572375, 52172403, 62303178)、湖南省自然科学基金(2025JJ70058)、湖南省教育厅科学研究项目(25A0798)项目资助

0 引言

随着中国铁路的快速发展,路网规模持续扩大,列车开行密度和运载量显著增加,对铁路系统的安全运维提出了更高要求。在列车运行过程中,车轮与轨道间的动态相互作用力(简称轮轨力)是衡量列车运行状态的核心指标^[1],其高精度检测对车辆安全监测意义重大,目前主要采用测力轮对方法获取轮轨力信号数据,异常的轮轨力数据可能代表了轮轨损伤,但受硬件条件制约,直接检测到的应变信号混杂着各种复杂干扰,不易区分实际情况,影响了通过轮轨力信号数据判断线路钢轨损伤的准确度,需要从中获取轮轨力源信号数据,才能满足铁路安全监测的实际需求。

盲源分离(blind source separation, BSS)是一种在未知源信号及传输通道参数的条件下,依据观测信号的统计特性,恢复源信号的技术。经过几十年的发展,已成为信号处理领域的重要方法,其在生物医学信号分析、语音增强、图像处理及结构健康监测等^[2]领域具有广泛的应用价值,传统 BSS 方法(如独立分量分析)通常仅利用信号的非高斯性,而忽略了时序特性,对具有时间结构的信号(如语音、振动及生物电信号)分离效果受限,复杂度追踪(complexity pursuit, CP)算法为解决上述问题提供了新思路,该算法由 Hyvärinen 等^[3]提出,其核心思想是结合信号的非高斯性与时序结构,通过最小化编码复杂度实现信号分离。将 CP 算法应用于提取轮轨力信号能够有效提升判断轮轨损伤的准确度,但面临以下难题:1)传统 CP 算法计算最优值时采取的是全批量的固定梯度下降,当迭代数据量过大时,导致实际效率较低,稳定性差,还易陷入局部最优^[4];2)由于硬件限制,分离出来的某一方向的力,可能由不同因素同时作用产生,需要进一步对数据处理,才能有效分析轮轨损伤情况。

针对计算问题,首先,轮轨力的数据量很大(通常为百万级样本点起步),对硬件性能要求十分高,单次迭代的计算时间和内存消耗不符合工程实际。为此,研究者们通常聚焦在数据集选择策略和学习率来提高算法的适用性。1)在数据集选择策略方面,其关键是通过数据采样策略平衡计算效率和收敛速度,Thomdapu 等^[5]提出一种通过跟踪内部函数求值来构建近似梯度,从而得到准梯度鞍点的随机梯度下降算法。然而通过 Watanabe^[6]的实验验证,当高估部分函数的平均梯度时,随机梯度下降这种方法并不能收敛到一个好的解。Alsadi 等^[7]提出了一种采用小批量梯度下降(mini-batch gradient descent, MBGD)的方法,以自适应方式选择迭代模式,取得了良好的结果,小批量梯度下降算法平衡了全批量梯度下降和随机梯度下降的弊端,但其收敛结果依赖于学习率的

值。2)在学习率方面,越来越多的学者通过训练数据集时的参数变化自动调整学习率。Yang 等^[8]提出了一种基于自适应动量梯度下降算法的快速数字自干扰消除,该算法自适应更新滤波器的权重系数,加快了收敛速度。John 等^[9]提出了一种基于余弦退火调度器的学习模型,其会随着时间的推移优化学习率,以获得更大的稳定性。

其次,一个方向的轮轨力信号数据可能是由车辆本身故障、轨道表面故障和轨下结构故障等不同激扰共同产生^[10],盲源分离处理后的数据并不完全精准地反映轮轨实际数据,无法有效地分析轮轨损伤,希尔伯特-黄变换(Hilbert-Huang Transform, HHT)可以对信号分解处理进而提取出不同激扰的特征参数。闫中奎等^[11]提出了一种基于经验模态分解(empirical mode decomposition, EMD)和神经网络的车轮多边形识别方法,能够识别、诊断车轮磨损信号。张绪景等^[12]提出了一种小波包降噪算法与 EMD 分解相关算法相结合的数据处理方法,能够同时有效抑制轮轨力应变信号的模态混叠现象和消除噪声干扰。刘行谋等^[13]提出一种改进的完全自适应噪声集合经验模态分解法,对汽车电控齿轮泵工况数据进行处理,为齿轮泵状态监测和故障诊断技术提供了工程参考。Jiang 等^[14]提出一种基于变模态分解的信号提取方法,验证了对管道泄漏检测和泄漏定位的准确性。Han 等^[15]提出了一种基于自适应噪声集合经验模态分解方法和正则化粒子滤波器的故障提取方法,有效抑制了传统 EMD 的端点效应问题难以获得准确的本征模态函数。

基于以上工作,本文针对复杂干扰环境下轮轨力信号分离难度大、现有算法工程适应性和鲁棒性不足的问题,提出了一种面向大规模轮轨力信号的高效自适应盲源分离与特征提取一体化检测方法,该方法融合了高效数据处理、动态参数优化和自适应信号特征提取等多项技术:

1) 高效数据处理:采用新型 Mini-Batch 策略,实现大规模轮轨力信号的高效分批处理,提升了算法的收敛速度和全局寻优能力;

2) 动态参数优化:引入余弦退火学习率调度器,根据数据特性动态调整学习率,在算法的目标函数寻优时可以有效地优化模型的收敛速度和稳定性;

3) 自适应特征提取:使用改进 HHT 分析方法,该方法可以将任意非线性、非平稳信号自适应地分解为一组本征模态函数,实现轮轨力信号的特征频率提取。

1 轮轨力信号分离原理

当前,以测力轮对为基础的研究已较为深入^[16],通过将应变片固定在被测轮对上,利用各个方向电桥的形变将其转换为应变信号,再输入到轮轨力解算软件,就得

到了相关轮轨力信号数据,然后使用盲源分离算法对其处理,下面是基本数学模型^[17]:

$$\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{N}(t) \quad (1)$$

式中: $\mathbf{X}(t)$ 是由观测器获取的源信号与噪声混合形成的观测信号; \mathbf{A} 是轮轨应力信号混杂系统所形成的混合矩阵。

基于复杂度追踪的盲源分离算法的目标就是寻找一个投影方向 \mathbf{W} (解混矩阵) 使得从观测信号 \mathbf{X} 中分离出的轮轨力信号复杂度最小, 即 $\mathbf{Y} = \mathbf{W}\mathbf{X} = \mathbf{W}\mathbf{A}\mathbf{S}$, 复杂度可以通过计算源信号预测误差的编码长度表示, 其编码长度可以用预测误差的熵的和近似, 那么就得到了基本的目标函数^[4]:

$$\hat{J}(y_i) = \sum_t H[\varepsilon_{y_i}(t)] \quad (2)$$

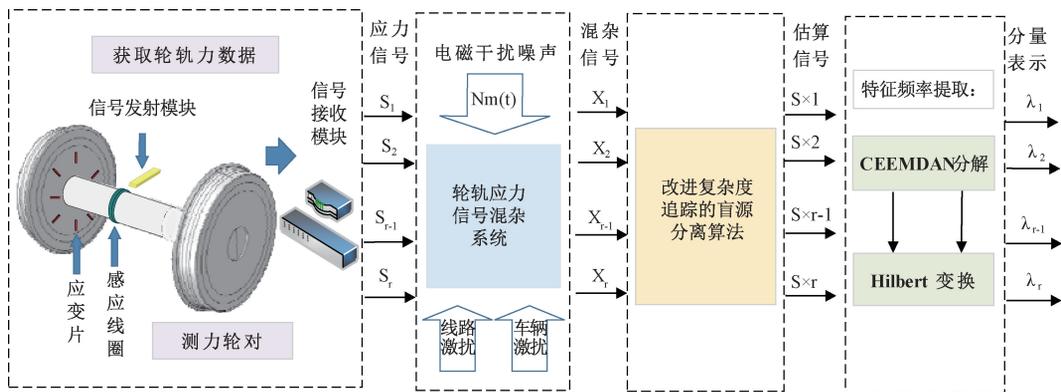


图 1 轮轨力鲁棒检测流程图

Fig. 1 Flow chart of wheel rail force robust detection

2.1 改进复杂度追踪的盲源分离算法

传统的基于全批量梯度下降法的 CP 算法在进行目标函数寻优时, 其必须一次性加载全部数据, 由于轮轨力数据量十分庞大, 导致了对内存容量要求高, 而且采用的是固定学习率, 迭代过程十分繁琐, 随着干扰的增加, 还有易陷入局部极值等缺点^[18], 这些会降低传统 CP 算法的性能和实用性, 需要对其进行改进, 提高后续对轮轨力信号数据判断的准确性, 可以更好地应用于线路维护。

通过采取小批量 (Mini-Batch) 策略, 可以让算法在全局搜索最优值, 如果模型参数落入了一个较差的局部极值点, 其经过 Mini-Batch 策略的优化过程可以找到一个更好的极值点, 使得计算结果更精确。

使用余弦退火调度器优化学习率问题, 在算法迭代初期, 学习率相对较高, 算法能够以较大的步长进行迭代, 迭代后期, 学习率平缓地降低, 使得迭代出更精确的解能力增强, 并且在迭代期间不需要调参。

针对实际工程中轮轨力信号受多种复杂干扰影响、传统分离算法鲁棒性不足的问题, 通过小批量迭代与自

将预测误差 $\bar{y}_i(t)$ 和它的近似嫡代入式 (2), 对 w_i 求导得到目标函数的梯度, 使用梯度下降算法对其迭代得到解混矩阵进行分离, 再从分离出的轮轨力源信号中提取固有模态函数分量, 然后计算得到特征参数。

2 轮轨力鲁棒检测方法

本文提出的方法采用基于改进复杂度追踪的盲源分离算法, 从轮轨力检测信号中分离出轮轨力源信号, 再使用改进 HHT 分析方法提取特征频率, 后续可以更清晰、准确地识别和分析不同激励, 轮轨力处理流程如图 1 所示, 其主要包含获取轮轨力数据、改进复杂度追踪算法分离信号、特征频率提取 3 个关键步骤。

适应学习率调度等改进, 可以提升算法在复杂干扰下的分离能力和工程适用性, 分离算法流程如图 2 所示。

1) Mini-Batch 策略

全批量梯度下降 (batch gradient descent, BGD) 是梯度下降算法的一种经典实现方式, 其核心特点是每次迭代时使用整个训练集的数据计算损失函数的梯度, 并更新模型参数。由于每次迭代需遍历全部数据, 当数据集样本规模极大 (如百万级样本) 时, 单次迭代的计算时间和内存消耗可能超过硬件限制, 进而无法得出结果。BGD 容易收敛到局部极值或鞍点, 其还无法在实时新增样本场景中应用, 必须一次性加载所有数据, 对初始参数和学习率敏感, 设置不当可能导致收敛缓慢甚至发散^[18]。

为克服传统的使用全批量梯度下降的复杂度追踪算法的弊端, 采用 Mini-Batch 策略, 其通过在每次迭代抽取总数据集的子集作为小批量样本, 如图 3 所示, 这些子集被称为 “Mini-Batches”, 与全批量梯度下降相比, Mini-Batch 策略优势很明显, 不需要一次性加载全部数据, 这

样计算就可以快速得到实际梯度的估算值,降低了内存需求,加快了收敛速度,进而加速了迭代过程,可以避免算法运行时因数据过大无法进行初步迭代^[7]。由于策略优势,有可能跳出局部极值,继续迭代搜索全局最值,避免了陷入局部极值而得不到最优值。

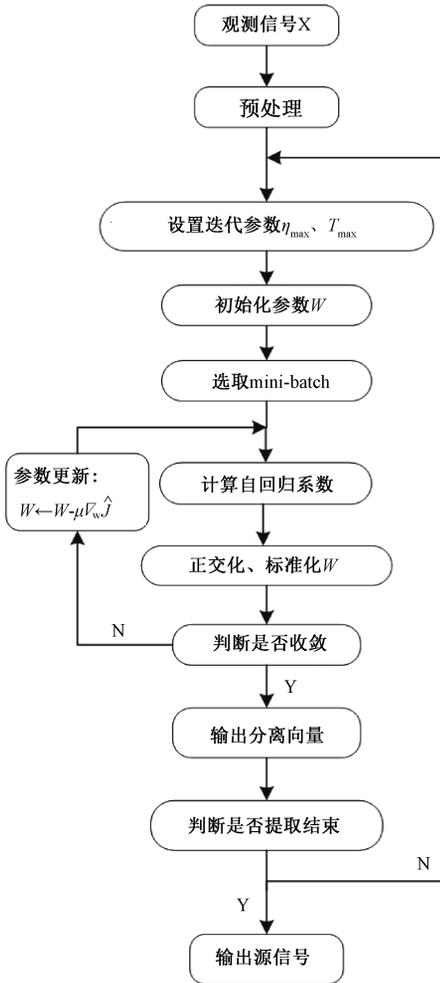


图 2 改进复杂度追踪算法流程图

Fig. 2 Flow chart of improved complexity tracking algorithm

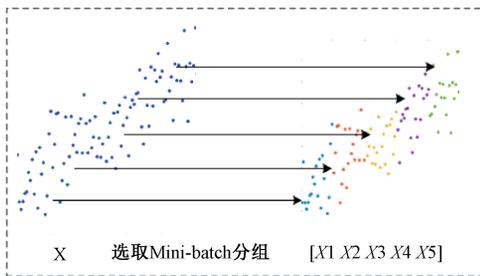


图 3 Mini-Batch 策略示意图

Fig. 3 Mini-batch strategy diagram

前所有样本的平均梯度,然后将其代入下一次迭代,对于当前第 j 个 Mini-Batch 表示为 \mathcal{D}_j , 则 \mathcal{D}_j 的平均梯度可以表示为:

$$m_j(\theta) = \frac{1}{|\mathcal{D}_j|} \sum_{i \in \mathcal{D}_j} \nabla_{\theta} L(f(x^{(i)}; \theta), y^{(i)}) \quad (3)$$

模型参数 θ 的更新公式表示为:

$$\theta = \theta - \eta \cdot m_j(\theta) \quad (4)$$

其中, θ 是模型要寻求的目标参数, η 是学习率。 \mathcal{D}_j 是第 j 个 Mini-Batch。 $|\mathcal{D}_j|$ 是当前 Mini-Batch 中的样本数量。 $x^{(i)}$ 和 $y^{(i)}$ 分别是其中第 i 个样本的特征和标签, $L(f(x^{(i)}; \theta), y^{(i)})$ 是单个样本的损失函数,一般根据模型数据进行选择, $\nabla_{\theta} L(\cdot)$ 是损失函数 L 对参数 θ 的梯度。

$$m_j(w) = \frac{\partial}{\partial w} \left(-\frac{1}{N} \sum_{i=1}^N G(w^T x_i) \right) \quad (5)$$

这里并不采取显式损失函数 L , 而是在每次处理完一个 Mini-Batch 样本后,计算目标函数的负熵近似值获取平均梯度,其中的 G 函数根据信号类型进行选取。

2) 自适应学习率调度器

传统的基于梯度下降的复杂度追踪算法进行迭代时,使用的是固定学习率 (fixed learning rate),即在参数更新过程中始终保持学习率不变,代码逻辑简单。但是,一个固定的学习率往往难以适应复杂的优化过程,如果设置的学习率过大,迭代过程中可能会导致震荡 (在最优值附近徘徊) 甚至发散。学习率过小,收敛速度极慢,可能陷入局部最优或鞍点^[4]。在训练初期,梯度较大时可能需要较大的学习率快速下降,在后期接近最优值,固定学习率可能因步长过大而错过最优解。如果要得到最优的学习率,需要反复尝试,尤其对于复杂模型或新数据集,耗时耗力,而轮轨力数据是十分庞大的,固定学习率显然不适合,其核心在于平衡收敛速度和稳定性,需要权衡选择合理策略。

自适应学习率调度器能够根据训练数据集时的数据变化 (如梯度、损失变化量、参数更新幅度等) 自动调整学习率,在对目标函数寻优时,可以有效地优化模型的收敛速度、稳定性和整体性能,在梯度下降算法的迭代过程中,学习率的调整对最终结果和整体的性能非常重要。本文采用了余弦退火学习率调度方法,余弦退火 (cosine annealing)^[9] 是一种兼容性高且效果良好的学习率调度方法,其核心思想是让学习率按设定的值随着余弦函数平滑调整,在迭代初期,学习率较大,帮助快速跳出初始点或局部最优,后期学习率逐渐减小,避免在最优解附近震荡或“过冲”,从而更稳定地收敛到更精确的极值点。

下面是余弦退火的学习率公式^[19]:

$$\eta_i = \eta_{\min} + \frac{1}{2} (\eta_{\max} - \eta_{\min}) \left(1 + \cos \left(\frac{T_{\text{cur}}}{T_{\text{max}}} \pi \right) \right) \quad (6)$$

在每次参数更新时,Mini-Batch 策略算法会计算当

式(6)中 η_t 是当前训练周期 t 的学习率, η_{\max} 为学习率的最大值, 是训练的初始学习率。 η_{\min} 为学习率的最小值, 是结束时学习率将达到的目标值, 一般设置为 0 或一个非常小的正数。 T_{cur} 表示当前已经进行的训练周期数(当前迭代数), 它的范围是从 0 到 T_{max} 。 T_{max} 是单个退火周期的总迭代次数, 根据实际数据进行设置。当 T_{cur} 达到 T_{max} 时, 表示一个完整的余弦退火周期结束。

余弦退火分为 3 个阶段, 周期开始时 ($T_{\text{cur}} = 0$), 此时, 后面的分数项的值为:

$$\frac{T_{\text{cur}}}{T_{\text{max}}}\pi = \frac{0}{T_{\text{max}}}\pi = 0 \quad (7)$$

代入 \cos 项中得到 $\cos(0) = 1$ 并将其代入学习率式(6)得:

$$\eta_0 = \eta_{\min} + \frac{1}{2}(\eta_{\max} - \eta_{\min})(1 + 1) \quad (8)$$

最终得到 $\eta_0 = \eta_{\max}$, 因此, 在退火周期的开始阶段, 学习率为设定的最大值 η_{\max} 。

当处于 $0 < T_{\text{cur}} < T_{\text{max}}$ 期间, 随着 T_{cur} 从 0 增加到 T_{max} , $\frac{T_{\text{cur}}}{T_{\text{max}}}\pi$ 的值从 0 增加到 π , 接着 $\cos\left(\frac{T_{\text{cur}}}{T_{\text{max}}}\pi\right)$ 的值从 1 平滑地减小到 -1, 这样学习率 η 从 η_{\max} 、平滑地调整至 η_{\min} 。

当 T_{cur} 达到设定的 T_{max} , 此时 $\cos(\pi) = -1$ 并将其代入学习率公式:

$$\frac{T_{\text{cur}}}{T_{\text{max}}}\pi = \frac{T_{\text{max}}}{T_{\text{max}}}\pi = \pi \quad (9)$$

最后得到 $\eta_{\text{max}} = \eta_{\min}$, 退火周期结束, 学习率减小到设定的最小值 η_{\min} 。

2.2 特征频率提取

使用 HHT 方法提取特征频率, 先对分离出的信号使用经验模态分解(empirical mode decomposition, EMD)获得分量, 再对其进行 Hilbert 变换提取特征频率。

EMD 是一种基于信号局部特征的信号分解方法, 该方法可以将任意非线性、非平稳信号自适应地分解为一组固有模态函数(intrinsic mode function, IMF), 再通过 Hilbert-Huang 变换可获得有物理意义的瞬时频率和幅值, 但传统 EMD 方法存在模态混叠, 信号两端包络拟合发散, 导致边界失真等问题^[20]。

本文选择完全自适应噪声集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN), 其根据信号的频率特征自适应地添加高斯白噪声 w_i , 通过噪声的频谱填充作用, 强制分离相近频率成分, 使得信号分解更加准确和稳定^[15]。首先设置噪声幅值 ϵ_k 、分解层数 K 和集合次数 N , 一般是 0.2 倍的信号标准差 $std(x)$, 使用式(10)~(13)提取分量:

$$IMF_1 = \frac{1}{N} \sum_{i=1}^N E_1(x(t) + \epsilon_0 w_i) \quad (10)$$

再进行残差计算:

$$r_k = r_{k-1} - IMF_k \quad (11)$$

自适应添加噪声:

$$IMF_{k+1} = \frac{1}{N} \sum_{i=1}^N E_1(r_k + \epsilon_k E_k(w_i)) \quad (12)$$

重复上面步骤, 达到终止条件后, 信号分解为 K 个分量和 1 个残余量:

$$x(t) = \sum_{k=1}^K IMF_k(t) + r_K(t) \quad (13)$$

在获得 IMF 分量的基础上, 使用公式(14)对其进行 Hilbert-Huang 变换:

$$H[IMF_k(t)] = \frac{1}{\pi} p. v. \int_{-\infty}^{\infty} \frac{IMF_k(\tau)}{t - \tau} d\tau \quad (14)$$

使用式(15)计算得到相位 $\theta(t)$:

$$\theta(t) = \arctan\left(\frac{H[x(t)]}{x(t)}\right) \quad (15)$$

然后对相应分量的相位 $\theta(t)$ 求导, 即可得到具有实际物理意义的特征频率, 可以直观地反映信号随时间的变化情况, 便于后续对轮轨伤损情况进行判定。

3 实验结果与分析

本节首先介绍实验数据的来源、性能评价指标和实际数据实验, 再进行消融实验对改进方案性能进行评判, 并绘制实验图。

3.1 实验数据说明

实验数据是使用轨检车轮轨力采集系统对轨道实地检测, 将采集的数据输入到轮轨力解算软件就得到了轮轨力应变信号的检测数据, 共有 6 组应变片, 用来测试 3 种力, 每种力由 2 组应变片测出。

3.2 分离性能评价指标

评价指标需要考虑分离速度和分离效果两个方面, 因为实际工程运用中可能会根据需求不同采取不同的方式, 分离速度过慢则可能影响工程效率, 在不影响分离效果的情况下, 分离速度越快越好。分离效果评价有信号失真比、相关系数、均方误差、Amari 距离、重构信噪比、独立性度量这些方法。本文采用重构信噪比评价算法性能, 重构信噪比越大, 算法的分离效果越好, 下式为计算公式:

$$RSNR = -10 \lg \left(\frac{\sum_{n=1}^N |s(n)|^2}{\sum_{n=1}^N |s(n) - \hat{s}(n)|^2} \right) \quad (16)$$

式中, N 是样本点数量, $\hat{s}[n]$ 表示分离出的源信号的能量, $s[n]$ 是初始信号的能量。

3.3 实验验证与分析

本实验的系统环境为 Windows10 系统,软件为 MATLAB R2024a,CPU 为 12th Gen Intel (R) Core(TM) i5-12400F@2.50 GHz,使用不同分离算法对部分实际信号数据进行分离实验,再对其提取特征参数,并绘制部分波形图进行效果对比,要注意的是算法本身并不对信号进行排序,所以并不是一一对应的。

1) 实际数据分离实验

本研究基于包神朔铁路实测轮轨力信号数据开展实验验证,通过安装在检测车上的轮轨力检测系统实现,如图 4 所示,轨检车是由 GTC-80 II 型钢轨探伤车加装测力轮对改装构成,该系统采用连续式测力轮对设计,将高精度应变片阵列紧密贴附于被测轮对辐板表面,利用各个方向电桥的形变将其转换为应变信号,通过解算软件对应变信号数据处理得到轮轨横向力、轮轨垂向力、轮轨纵向力等参数的测量值。



图 4 测力轮对及其安装过程

Fig. 4 Force measuring wheelset and its installation process

采用改进 CP 算法方法对轮轨力应变电桥信号进行分离,并与传统 CP 算法和经典的 Fast ica 算法^[21]进行对比,再使用 CEEMDAN 算法获得分量并提取信号特征参数。经过本文提出的轮轨力鲁棒检测方法处理后的轮轨力信号数据,能够更精确地反映线路伤损状态,为线路运行维护提供可靠的数据支持。图 5 是采集的轮轨力信号实际数据中的一部分,图 6(a)~(c)图是不同算法的实际数据分离实验对比图。

使用 3.2 章节的分离性能评价指标,表 1 是使用 3 种方法分离出的信号经多次取平均值的重构信噪比数值表,本文提出的改进 CP 算法的重构信噪比数值最高,所以效果最好。

为验证本文改进点的有效性,选取不同组合方式和部分实验数据进行消融实验对比,用时和 RSNR 的数值是多次实验取平均值,从表 2 数据可知改变迭代策略可以减少算法用时,并且使用全批量策略进行实验时出现了迭代不出结果的现象,再结合分离效果的指标对比,本文提出的改进方法是有效的。

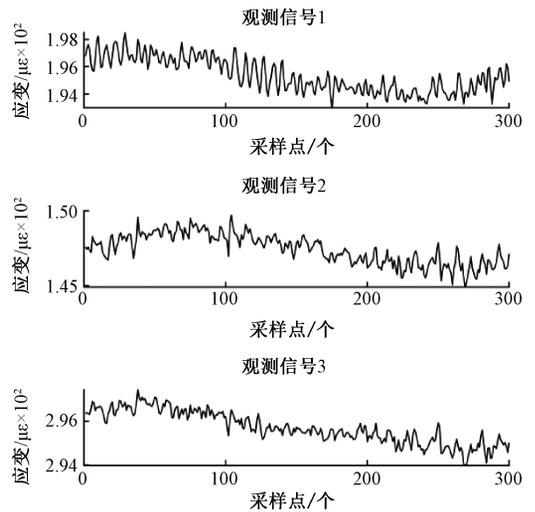


图 5 采集的实际数据

Fig. 5 Actual data collected

表 1 重构信噪比数值表 (dB)

Table 1 Table of reconstructed signal-to-noise ratio values (dB)

算法	信号 1	信号 2	信号 3	用时/s
Fast ica	42.71	51.48	26.89	24.18
传统 CP 算法	37.44	25.36	36.92	45.73
本文	46.44	47.31	34.92	17.87

表 2 不同改进点实验对比

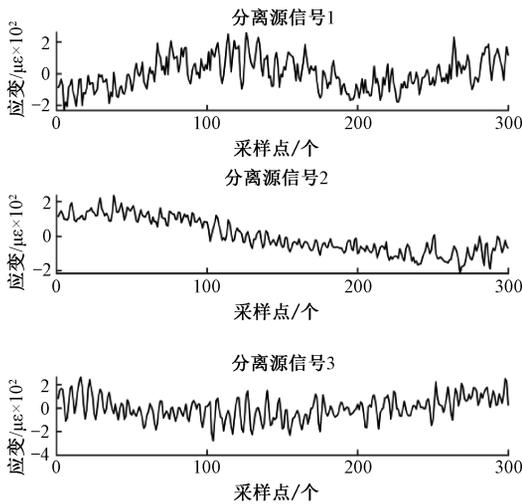
Table 2 Experimental comparison of different improvement points

实验组	用时/s	RSNR/dB
全批量+固定学习率	45.73	33.24
全批量+余弦退火调度器	38.56	35.87
随机梯度下降+固定学习率	30.15	36.42
Mini-Batch+固定学习率	23.92	38.15
Mini-Batch+Adam 调度器	19.64	40.03
本文	17.87	42.89

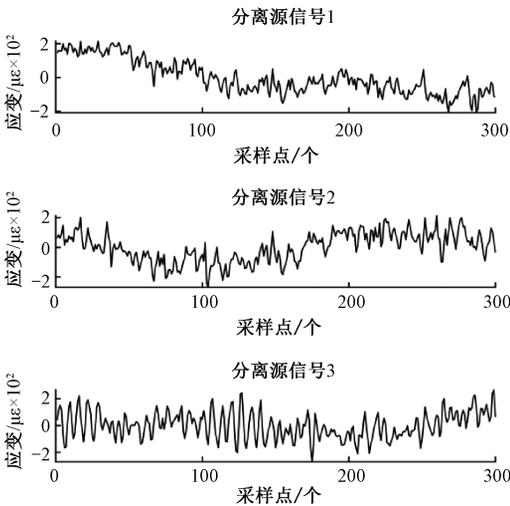
分离算法对比评估结果如下:

(1) 从分离后的源信号的整体数值来看,本文提出的改进 CP 算法分离效果相比传统 CP 算法提高 29.1%,与经典的 Fast ica 算法相比也提高了 6.3%,根据性能指标分析,本文方法更有效地从检测信号中分离出了有效成分,增强了信号的可判读性和后续分析价值。

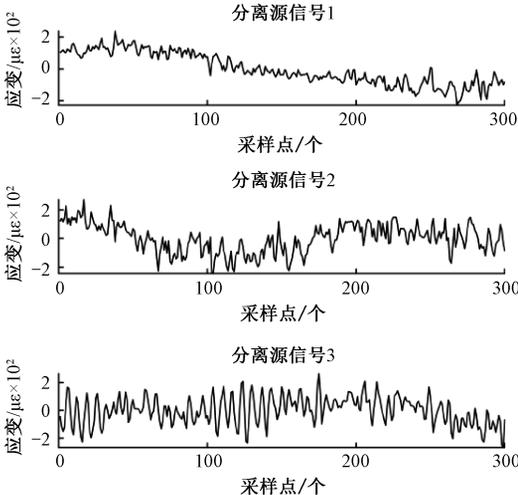
(2) 从分离用时来看,Fast ica 算法用时 24.18 s,传统 CP 算法用时 45.73 s,且多次实验过程中存在无法收敛或无分离结果的现象。相比之下,本文提出的改进 CP 算法用时仅为 17.87 s,且多次实验均能稳定收敛,未出现上述问题。结合分离效果分析,改进 CP 算法不仅显著缩短了迭代用时,还大幅提升了算法的稳定性和工程适用性。



(a) Fast ica算法分离实际数据
(a) Fast ICA algorithm separates actual data



(b) 传统CP算法分离实际数据
(b) Traditional CP algorithm separates actual data



(c) 改进CP算法分离实际数据
(c) Improving CP algorithm to separate actual data

图 6 实际数据分离实验图

Fig. 6 Experimental diagram of actual data separation

2) 特征提取实验

使用 2.2 节的特征参数提取方法, 获得源信号 1 的 IMF 分量, 并计算得到特征参数, 从图 7 可知, 其有效地提取出了信号的本征模态函数的特征频率。为评估不同经验模态分解方法的性能差异, 对多种变体算法进行了实验, 使用误差平方和 (sum of squared errors, SSE) 用于衡量 IMF 分量重构信号的质量, 数值越小说明重构信号与原始信号越接近, 分解过程中信息损失越小, 从表 3 可知 CEEMDAN 的分解效果最好, SSE 的计算公式为:

$$SSE = \sum_{n=1}^N (x(n) - \hat{x}(n))^2 \quad (17)$$

式 (17) 中 $x(n)$ 是原始信号第 n 个采样点, $\hat{x}(n)$ 重构信号第 n 个采样点, N 是信号总采样点数。

表 3 不同 EMD 分解效果对比

Table 3 Comparison of different EMD decomposition effects

分解方法	误差平方和 (SSE)
EMD	0.027
EEMD	0.015
本文	0.012

4 结 论

本文针对轮轨力检测信号中存在多种复杂干扰, 严重影响铁路状态评估的准确性这一难题, 开展了系统的研究与方法创新。基于信号特性和分离难点, 提出一种基于改进复杂度追踪的轮轨力鲁棒检测方法, 并通过实际轮轨力数据实验验证了其有效性, 优化了传统方法在实际工程应用中的效果和鲁棒性瓶颈, 经分析得出结论:

1) 针对传统 CP 算法在迭代过程中易陷入较差的局部极值的问题, 通过采取新型 Mini-Batch 策略, 其可以在全局选取最优的极值, 避免了迭代出不理想的极值, 显著提高收敛至最优解的概率。

2) 针对复杂度追踪时, 传统方法迭代过程繁琐, 而且鲁棒性差等问题, 使用自适应学习率调度器, 其能够根据初始设定的迭代参数, 随迭代进程调整学习率, 经过实验对比, 可以大幅度精简迭代步骤, 更稳定地收敛到更精确的极值点。

3) 针对分离后的信号往往存在复杂的频率成分交织、非平稳特性显著等问题, 传统的频率分析方法难以准确捕捉其特征参数变化, 采用完全自适应噪声集合经验模态分解方法, 有效地避免了模态混叠问题, 使得信号分解更加准确和稳定。

由于算法本身限制, 其具体的源信号并不是一一对应的, 只能从整体数值来判断其分离效果, 未来工作可以尝试设定匹配算法, 以便更直观地分析轮轨力数据, 随着更好的寻优算法提出, 也可以将其融入其中, 达到更好的分离效果。

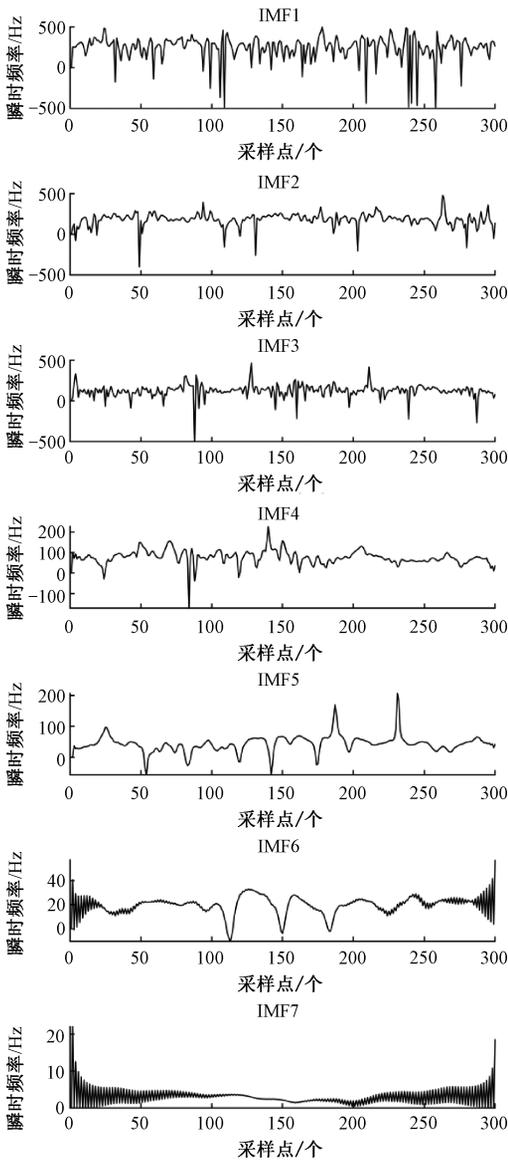


图 7 IMF 瞬时频率图

Fig. 7 IMF instantaneous frequency diagram

参考文献

[1] 翟婉明. 车辆-轨道耦合动力学理论的发展与工程实践[J]. 科学通报, 2022, 67(32):3794-3807.
ZHAI W M. The Development and engineering practice of vehicle track coupling dynamics theory [J]. Scientific Bulletin, 2022, 67(32):3794-3807.

[2] 朱江艳, 马军, 杨创艳, 等. 基于 FastICA-BAS-MCKD 的滚动轴承复合故障特征提取方法[J]. 电子测量与仪器学报, 2021(8):107-117.
ZHU J Y, MA J, YANG CH Y, et al. Feature extraction method for composite faults of rolling bearings based on FastICA-BAS-MCKD [J]. Journal of Electronic Measurement and Instrumentation, 2021(8):107-117.

[3] HYVÄRINEN A. Complexity pursuit: Separating interesting components from time series [J]. Neural Computation, 2001, 13(4):883-898.

[4] 胡志祥, 黄磊, 邳伦海, 等. 基于复杂度追踪的模式参数识别方法对比研究[J]. 振动与冲击, 2024, 43(15):22-31.
HU ZH X, HUANG L, ZHI L H, et al. Comparative study on modal parameter identification methods based on complexity tracking [J]. Vibration and Shock, 2024, 43(15):22-31.

[5] THOMDAPU S T, VARDHAN H, RAJAWAT K. Stochastic compositional gradient descent under compositional constraints [J]. IEEE Transactions on Signal Processing, 2023, 71:1115-1127.

[6] WATANABE T, IIMA H. Nonlinear optimization method based on stochastic gradient descent for fast convergence[C]. 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2018:4198-4203.

[7] ALSADI M S, GHNEMAT R, AWAJAN A. Accelerating stochastic gradient descent using adaptive mini-batch size[C]. 2019 2nd International Conference on New Trends in Computing Sciences (ICTCS). IEEE, 2019:1-7.

[8] YANG Q, DU Y, YAN X, et al. Fast digital self-interference cancellation based on adaptive momentum gradient descent algorithm [C]. 2023 5th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP). IEEE, 2023:1075-1078.

[9] JOHN B, MENON V G, ADHIKARI M. FedCosA: Optimised federated learning model using cosine annealing[C]. 2025 Emerging Technologies for Intelligent Systems (ETIS). IEEE, 2025:1-6.

[10] 何静, 黄聪聪, 张昌凡, 等. 基于改进 SNN 的列车轮对踏面缺陷识别方法[J]. 铁道学报, 2025, 47(1):91-100.
HE J, HUANG C C, ZHANG CH F, et al. A method for identifying defects on train wheel tread based on improved SNN [J]. Journal of Railway, 2025, 47(1):91-100.

[11] 闫中奎, 李春超, 马丽英, 等. 基于 EMD 和神经网络的车轮多边形识别方法研究[J]. 铁道车辆, 2025, 63(3):71-76.
YAN ZH K, LI CH CH, MA L Y, et al. Research on wheel polygon recognition method based on EMD and neural network [J]. Railway Vehicles, 2025, 63(3):71-76.

[12] 张绪景, 雷晓燕, 刘庆杰. 基于小波包与改进 EMD 的轮轨力信号降噪[J]. 噪声与振动控制, 2016, 36(5):104-107, 143.
ZHANG X J, LEI X Y, LIU Q J. Noise reduction of

- wheel rail force signal based on wavelet packet and improved EMD[J]. *Noise and Vibration Control*, 2016, 36(5):104-107,143.
- [13] 刘行谋,魏钞,杨辉,等. 汽车电控齿轮泵车载工况故障诊断方法研究_刘行谋[J]. *电子测量与仪器学报*, 2025, 39(5), 227-240.
- LIU X M, WEI CH, YANG H, et al. Research on fault diagnosis method for automotive electronic control gear pump in vehicle operating conditions [J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(5):227-240.
- [14] JIANG Z, WANG Y, YANG Y, et al. Research on noise reduction method for leakage signal of water supply pipeline[J]. *IEEE Access*, 2024, 12:71406-71418.
- [15] HAN N, XIE G, JIN Y, et al. Remaining useful life prediction of the rolling bearing based on CEEMDAN and regularized particle filter [C]. 2022 37th Youth Academic Annual Conference of Chinese Association of Automation (YAC). *IEEE*, 2022:522-527.
- [16] 杜佳,陈建政,吴越,等. 基于测力轮对的纵向轮轨力测量方法研究[J]. *电子测量技术*, 2024, 47(21):53-61.
- DU J, CHEN J ZH, WU Y, et al. Research on longitudinal wheel rail force measurement method based on force measuring wheelsets [J]. *Electronic Measurement Technology*, 2024, 47(21):53-61.
- [17] 高全明,张瀚文,侯宇丹,等. 基于 CS-FastICA 的超导电磁数据消噪方法研究[J]. *仪器仪表学报*, 2023, 44(8):109-117.
- GAO Q M, ZHANG H W, HOU Y D, et al. Research on superconducting electromagnetic data denoising method based on CS FastICA [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(8):109-117.
- [18] 史加荣,王丹,尚凡华,等. 随机梯度下降算法研究进展[J]. *自动化学报*, 2021, 47(9):2103-2119.
- SHI J R, WANG D, SHANG F H, et al. Research progress on stochastic gradient descent algorithm [J]. *Journal of Automation*, 2021, 47(9):2103-2119.
- [19] WANG J, HE L, ZHOU X. Optimizing inception-V3 for brain tumor classification using hybrid precision training and cosine annealing learning rate [C]. 2024 7th International Conference on Advanced Algorithms and Control Engineering (ICAACE). *IEEE*, 2024:528-532.
- [20] 李楠楠,杨铎,王珍,等. 采用 TVFEMD 和瞬时能量比

的轧辊磨床颤振在线监测方法[J]. *电子测量与仪器学报*, 2024, 38(1):228-236.

LI N N, YANG D, WANG ZH, et al. A method for online monitoring of rolling mill chatter using TVFEMD and instantaneous energy ratio [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38 (1): 228-236.

- [21] 李奕璠,林建辉,王开云,等. 测力钢轨轮轨力解耦研究[J]. *机械工程学报*, 2013, 49(4):96-101.

LI Y F, LIN J H, WANG K Y, et al. Research on decoupling of force measurement rail wheel rail force[J]. *Journal of Mechanical Engineering*, 2013, 49 (4): 96-101.

作者简介



何静,2002 年于中南林业科技大学获得硕士学位,2009 年于国防科技大学获得博士学位,现为湖南工业大学教授,主要研究方向为机电系统故障诊断等。

E-mail:hejing@ 263. net

He Jing received her M. Sc. degree from Central South University of Forestry and Technology in 2002 and her Ph. D. degree from National University of Defense Technology in 2009. She is now a professor in Hunan University of Technology. Her main research interest includes electro-mechanical system fault diagnosis.



闫思峰,2023 年于皖西学院获得学士学位,现为湖南工业大学研究生,主要研究方向为重载铁路轮轨损伤诊断等。

E-mail:1925677715@ qq. com

Yan Sifeng received his B. Sc. degree from West Anhui University in 2023. He is now a M. Sc. candidate at Hunan University of Technology. His main research interests include the diagnosis of wheel rail damage in heavy-duty railways.



张昌凡(通信作者),1989 年于西南交通大学获得硕士学位,2001 年于湖南大学获得博士学位,现为湖南工业大学教授,博士生导师,主要研究方向为非线性控制及应用等。

E-mail:zhangchangfan@ 263. net

Zhang Changfan (Corresponding author) received his M. Sc. from Southwest Jiaotong University in 1989, and Ph. D. from Hunan University in 2001, respectively. He is now a professor in Hunan University of Technology. His main research interests include nonlinear control and application.