



基于RIME-VMD算法的弓网谐振特征参数辨识

起家琦, 常军超, 李志川, 陈冬艳, 杨光润, 杨森
(云南电网有限责任公司计量中心, 云南 昆明 650500)

摘要: 针对电气化铁路受电弓-接触网系统中的高次谐波检测问题, 文章提出一种基于霜冰算法优化(rime optimization algorithm, RIME)的变分模态分解(variational mode decomposition, VMD)并与Prony算法相结合的谐振信号辨识方法。首先, 以最小包络熵为适应度函数, 利用RIME优化VMD中的模态个数 K 和惩罚因子 α , 得到最优参数组合, 进而对谐振信号进行VMD分解, 获得各模态分量(IMFs); 其次, 设定IMF能量熵增量阈值以提取有效模态分量, 重构得到降噪信号, 并通过均方根误差(rootmean square error, RMSE)和信噪比(signal-noise ratio, SNR)评价降噪效果; 然后, 采用Prony算法对降噪后的谐振信号进行特征参数辨识; 最后, 通过仿真与实测信号验证表明, 该方法在强噪声环境下能准确提取弓网谐振特征参数, 具有良好的抗噪性能。

关键词: 受弓网与接触网系统; 霜冰算法; 能量熵增量; Prony算法

中图分类号: U233.5

文献标志码: A

文章编号: 1000-128X(2025)05-0063-10

0 引言

随着“交-直-交”型电力机车的广泛运用, 牵引网中的谐波含量显著降低, 但电力机车脉宽调制控制方式会向牵引网注入高次谐波。若高次谐波频率接近系统固有谐振频率, 可能引发高次谐波谐振, 对牵引供电系统安全运行构成威胁^[1-2]。因此, 准确辨识谐振信号的各项参数, 实现弓网系统谐振现象的快速检测, 有助于有效监测并抑制谐振波的传播, 从而显著降低弓网谐振带来的危害与风险。

目前, 国内外学者对弓网系统谐波谐振现象的分析与检测方法主要包括模态分析法和频谱分析法。模态分析法通过施加激励, 利用矩阵计算网络结构的变形与振动响应, 从而提取模态频率、振型等动态特性。文献[3]提出了一种利用模态分析的谐波谐振评估方法, 得到有关谐振产生的机理和特性, 为弓网谐振分析提

供了新思路。文献[4]基于模态分析法对运动负荷牵引电网的谐波谐振进行分析, 研究牵引网络节点导纳矩阵的特征根与谐波频率的耦合关系, 验证了谐波与频率间的关联性。然而, 模态分析法通常设定系统响应为线性, 与弓网系统实际非线性特性存在差异, 因此其适用性有限。频谱分析法可用于辨识弓网谐振的特征参数。文献[5]利用改进的经验模态分解(empirical mode decomposition, EMD)自适应地将车辆-轨道系统信号分解为本征模态, 并详细分析了各分量的变化规律。文献[6]结合集合经验模态分解和希尔伯特-黄变换, 对弓网运行中产生的振动数据进行分解, 获取频率与其他变量之间的关系。尽管EMD方法具有较强的自适应能力和抗噪性强, 但分解结果可能包含虚假分量, 且存在模态混叠问题, 导致特征提取和模态识别困难。为克服模态混叠, 文献[7]提出了变分模态分解法, 通过迭代搜索变化模式, 可自适应地将非平稳信号分解为一组固有模态分量。然而, VMD通常在分解前需人

基金项目: 云南电网公司科技项目 (YNKJXM20230455)

通信作者: 杨光润, 男, 高级工程师, 研究方向为电能质量管理与分析、计量专业管理; E-mail: 81382972@qq.com

引用格式: 起家琦, 常军超, 李志川, 等. 基于RIME-VMD算法的弓网谐振特征参数辨识[J]. 机车电传动, 2025(5): 63-72. DOI:10.13890/j.issn.1000-128X.2025.05.007.

Citation: QI Jiaqi, CHANG Junchao, LI Zhichuan, et al. Identification of pantograph-catenary resonance characteristic parameters based on RIME-VMD algorithm[J]. Electric drive for locomotives, 2025(5): 63-72. DOI:10.13890/j.issn.1000-128X.2025.05.007.

为设定模态个数和惩罚因子,容易形成参数局部最优,导致信号分解不充分或过分解,产生较多虚假分量。此外,单一惩罚因子可能引起不同频率的模态分量失真,频率差异越大,失真越严重^[8]。

针对VMD中存在的参数局部最优问题,近年来出现了多种改进算法。文献[9]提出了一种基于蜣螂优化算法(DBO)的VMD参数自适应选取方法,通过同时优化最优模态个数和惩罚因子参数,解决了传统VMD依赖人工设定参数所导致的分解效果不确定问题。文献[10]面向高速列车故障诊断场景,将RIME算法与最小包络熵适应度函数相结合,有效提升了VMD对多工况的适应性,增强了解析结果的鲁棒性,有效解决了局部参数最优问题。

为此,本文提出一种基于RIME-VMD的弓网谐振特征参数辨识方法。首先,以最小包络熵为适应度函数,采用霜冰算法对VMD中的模态个数和惩罚因子进行全局寻优,从而抑制高频噪声干扰,提升信号分解的适应性与稳定性;然后,利用Prony算法对各谐振参数辨识的准确性,提取弓网谐振信号的特征参数;最后,通过仿真与实测信号对比,验证了本文所提方法在弓网谐振特征参数辨识中的可行性与优越性,且具有良好的抗噪性能和辨识精度。

1 弓网谐振的产生机理与特征

1.1 弓网谐振产生机理

弓网谐振现象是指列车运行过程中产生的特定次谐波电流注入牵引网,与牵引网及牵引变电所的阻抗共同形成谐振回路,导致牵引变电所或列车侧的阻抗在某频率处达到极大值,从而引发电网电压畸变与电压幅值明显升高。该谐振频率由牵引网和牵引变电所的阻抗参数共同决定,其邻近频段的阻抗值也明显高于其他频率。为分析弓网谐振机理,可采用牵引网与列车的简化等效电路,构建耦合谐波谐振电路模型,如图1所示。




图1 耦合谐波谐振电路模型

Fig. 1 Coupled harmonic resonance circuit model

图1中, Z_{in} 、 Z_{2n} 分别为列车两侧牵引网线路阻抗; Y_{in} 、 Y_{2n} 分别为列车两侧牵引网线路导纳; Z_{sn} 为牵引变

电所等效阻抗; Z_n 为列车等效阻抗; I_n 为等效谐波电流源; U_n 为等效谐波电压源; Z_1 和 Z_2 分别为列车两侧牵引网等效阻抗。

由于列车为感性负荷,当牵引网的输入阻抗 $Z_{in}=Z_1//Z_2$ 呈现容性时,在特定频率 ω_n 下,负荷侧的谐波电流可能激励系统产生并联谐振^[11],此时系统并联导纳最小,并联阻抗最大。谐振电压幅值取决于谐波电流和特征阻抗的幅值,当输入阻抗为最大值时,谐波电流被显著放大,从而可能引发谐振过电压现象。

1.2 弓网谐振特征

弓网系统在正常运行状态下,电压、电流波形通常呈现为平滑的正弦波,无明显非线性失真或衰减。当系统发生谐振时,会在某一基频下产生显著的振动分量。随着系统激励的增大或非线性效应的显现,还会产生频率为基频整数倍的高次谐波,这些谐波在系统振荡过程中幅值增大,表现出更强的振动响应。受高次谐波影响,电压和电流波形会发生明显畸变^[12],表现为在正弦波信号上叠加高频振荡分量,整体波形呈现复杂、不对称或不规则的形态,常伴有周期性尖峰或偏移。谐振主要出现在17~75次谐波范围内(对应850~3 750 Hz),呈现宽频带谐振特征,并且在该频段内容易引发严重的谐振过电压。当特定高次谐波与系统参数发生共振时,其电压有效值可达千伏级,极端情况下甚至超过数千伏。这种高幅值谐波电压与基波电压的叠加作用,导致接触网电压有效值超过31 kV^[13]。

在高次谐波谐振状态下,弓网系统的振动幅度往往会发生非线性增长,可能出现振幅调制现象,表现为特定频率成分的振幅随时间变化而周期性增减;同时,基频与各高次谐波之间往往存在相位差异,特别是在多种谐波耦合的情况下,不同谐波间的相位关系会引起波形干涉,进一步增加振动的复杂性。

2 算法基本原理

2.1 变分模态分解

变分模态分解法是一种高度自适应的信号分解处理算法,其核心思想是将原始信号分解为多个模态,通过多轮迭代逐步分离信号中不同频率的成分,最终使每个模态分离呈现独特的频谱特征和振幅特性^[14]。设置如式(1)所示的约束表达式。

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\text{s.t. } \sum_{k=1}^K u_k = f(t)$$

式中: K 为分解模态个数; u_k 为第 k 个模态分量; ω_k 为对应的中心频率; $\delta(t)$ 为狄拉克函数; $f(t)$ 为原始信号; ∂_t 表示求偏导;*表示卷积运算;s.t.表示约束表达

式对应的约束条件。

通过引入拉格朗日乘子 λ 和二次惩罚项将约束问题转化成扩展拉格朗日函数, 如式(2)所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (2)$$

式中: $L(x)$ 为拉格朗日函数, 其中三项式的三项分别对应梯度函数 L_2 的范数、二次惩罚项以及拉格朗日乘子项。

该优化问题通过式(2)交替乘子法迭代求解, 最终得到满足物理约束的模式分量。

2.2 霜冰优化算法

霜冰优化算法是通过模拟霜冰粒子的动态行为实现寻优。本文引入了软霜搜索策略, 利用软霜粒子较强的随机性与空间覆盖能力, 可实现对搜索空间的快速覆盖, 有效避免算法陷入局部最优。为进一步改善收敛性能, 算法还结合了硬霜穿刺机制, 以增强局部开发效率。此外, 通过设置积极贪婪选择机制, 在每次迭代中依据适应度值等指标, 动态筛选并保留更优个体, 从而引导种群整体向更优方向演进, 提升算法的全局寻优能力与收敛速度^[15]。

霜冰种群 R 包含 i 个霜冰 S_i 个体, 每个霜冰 S_i 由 d 个霜冰粒子 x_{ij} 构成。基于此, 霜冰种群 R 位置可通过霜冰粒子直接表征, 如下式所示:

$$R = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1j} \\ x_{21} & x_{22} & \cdots & x_{2j} \\ \vdots & \vdots & & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} \end{bmatrix} \quad (3)$$

式中: i, j 分别表示霜粒的序号和霜冰的序号。

每个霜冰的生长状态由霜冰粒子的适应度函数 $F(S_i)$ 表示, 表达式如下式所示:

$$F(S_i) = \begin{bmatrix} f([x_{11}, x_{12}, \cdots, x_{1j}]) \\ f([x_{21}, x_{22}, \cdots, x_{2j}]) \\ \vdots \\ f([x_{i1}, x_{i2}, \cdots, x_{ij}]) \end{bmatrix} \quad (4)$$

式中: f 表示霜冰粒子的适应度。

环境因素对霜冰生成形态具有显著影响。在凝结发生前, 每个粒子遵循特定的运动规律, 处于自由状态时, 粒子会向软霜区域移动并完成凝结。若两者距离超出特定范围, 凝结过程便会中断。随着软霜的持续生成, 霜粒进入稳定阶段, 其凝结面积逐步扩张。综上所述, 根据霜冰粒子的运动规律, 其位置可由下式表示:

$$\left. \begin{aligned} R_{ij}^{\text{new}} &= R_{\text{best}, j} + r_1 \cdot \cos \theta \cdot \beta \cdot h (Ub_{ij} - Lb_{ij}) + Lb_{ij} \\ r_2 &< E \end{aligned} \right\} \quad (5)$$

式中: R_{ij}^{new} 为霜粒更新后的位置; $R_{\text{best}, j}$ 对应霜冰种群 R 中最优霜冰的第 j 个粒子; r_1 为区间 $(-1, 1)$ 的任意数值, 其值随迭代次数和 $\cos \theta$ 同步改变; β 为环境因子, 用于表征外部环境的影响要素; E 为粘附系数, 用于表征霜粒凝结概率; r_2 为区间 $(0, 1)$ 内的任意数值, 与 E 共同决定霜粒是否凝结, 即判断霜粒位置是否需要更新; h 为区间 $(0, 1)$ 内的任意数值; Ub_{ij} 、 Lb_{ij} 分别对应上/下界。

方向角 θ 、环境因子 β 以及粘附系数 E 的具体设定如下式所示:

$$\theta = \pi \cdot \frac{t}{10 \cdot T} \quad (6)$$

$$\beta = 1 - \left[\frac{\omega \cdot t}{T} \right] / \omega \quad (7)$$

$$E = \sqrt{(t/T)} \quad (8)$$

式中: t 为当前的迭代次数; T 为最大迭代次数; $[\cdot]$ 为四舍五入; ω 的核心功能是控制阶跃函数的分段数量, 避免算法过早收敛。

硬霜的生长相较于软霜更简单、更规则, 在外界环境影响下倾向于沿固定方向凝结, 易形成穿刺现象。基于此特性, RIME算法设计了硬霜穿刺机制, 通过交换普通霜冰和最优霜冰之间的霜粒, 增强算法在深度搜索阶段的精度与局部开发能力。霜粒之间的替换公式为:

$$\left. \begin{aligned} R_{ij}^{\text{new}} &= R_{\text{best}, j} \\ r_3 &< F^{\text{normr}}(S_i) \end{aligned} \right\} \quad (9)$$

式中: $F^{\text{normr}}(S_i)$ 为归一化后的当前适应度函数值, 代表选中第 i 个粒子的概率; r_3 是区间 $[-1, 1]$ 内的任意数值。

2.3 IMF能量熵增量

在模态分解过程中, 受插值误差、端点效应及伪分解等因素影响, 易产生与原始信号相关性较低的虚假分量。这类分量会造成后续特征参数辨识结果出现偏差, 因此需在分析前予以识别和剔除。在模态分解所得的IMF内, 有效IMF分量为能量主体, 虚假IMF分量占比相对较小^[16], 因此可借助能量分布特性进行甄别。通过计算各模态的能量谱并构建基于信息熵的能量熵增量指标, 能够有效量化各分量的能量贡献与随机性程度, 进而依据能量熵增量实现对虚假分量的筛选与去除。

基于能量熵识别虚假分量的具体计算步骤如下:

①计算第 t 个IMF分量的信号能量 $E_{i(t)}$ 及分解信号能量的总和 $E_{\text{总}}$, 如下式所示:

$$\left. \begin{aligned} E_{i(t)} &= i(t)^2 \\ E_{\text{总}} &= \sum_{t=1}^n [i(t)]^2 \end{aligned} \right\} \quad (10)$$

式中: $i(t)$ 为第 t 个IMF分量

②分别对各个IMF分量进行归一化处理和能量谱求取, 具体如下:

$$\left. \begin{aligned} P(i) &= E_{i(t)} / E_{\text{总}} \\ Q(i) &= \log[P(i)] \end{aligned} \right\} \quad (11)$$

式中: $P(i)$ 为各模态分量归一化处理后的值; $Q(i)$ 为各模态分量的能量谱。

③对各 IMF 分量的能量熵增量 $\Delta Q(i)$ 进行计算, 具体如下:

$$\Delta Q(i) = -P(i) Q(i) \quad (12)$$

式(12)中 $\Delta Q(i)$ 值越大, 表明 IMF 分量的真实程度越高; 反之, 其值越小真实性越低, 则判定为虚假分量^[17]。

2.4 Prony 算法

Prony 算法的核心思想是利用一组指数项的线性组合拟合等间距的采样数据^[18], 其数学模型可表示为

$$x(t) = \sum_{i=1}^N A_i e^{\alpha_i t} \cos(2\pi f_i t + \theta_i) \quad (13)$$

式中: N 为采样点个数; A_i 为幅值; α_i 为衰减因子; t 为采样时间; f_i 为频率; θ_i 为相位。

式(13)中包含了 p_1 个衰减的直流分量和 p_2 个衰减的余弦分量, 令 $p = p_1 + 2p_2$, 利用欧拉公式对式(13)进行展开, 得到如式(14)所示的离散形式函数。

$$\hat{x}(n) = \sum_{i=1}^p A_i e^{j\theta_i} e^{(\alpha_i + j2\pi f_i) \Delta t} \quad (14)$$

式中: Δt 为采样时间间隔; p 为信号分量的总数; j 为虚数单位。

为降低拟合信号的误差, 采用平方误差最小原则构造了如式(15)所示的目标函数。

$$\min \left[\varepsilon = \sum_{n=0}^{N-1} |x(n) - \hat{x}(n)|^2 \right] \quad (15)$$

通过式(15)可以求出幅值 A_i 、相位 θ_i 、衰减因子 α_i 以及频率 f_i 。然而, Prony 算法本质上是非线性最小二乘问题, 其求解通常依赖复杂的迭代过程。本文仅讨论其线性估计部分, 为推导相应的线性微分方程, 需对特征多项式 $\Psi(z)$ 进行定义, 如式(16)所示。

$$\Psi(z) = \prod_{i=1}^p (z - z_i) = \sum_{i=0}^p a_i z^{p-i}, a_0 = 1 \quad (16)$$

式中: z 为特征多项式的复变量; z_i 为特征多项式 $\Psi(z)$ 的第 i 个复特征根。

由式(14)可得到

$$\hat{x}(n-k) = \sum_{i=1}^p b_i z_i^{n-k}, 0 \leq n-k \leq N-1 \quad (17)$$

式中: n 为当前离散时间索引; k 为离散时间延迟步长, 是非负整数; $\hat{x}(n-k)$ 表示 n 时刻往前延迟 k 步对应的信号估计值; b_i 为第 i 个信号分量的复系数。

对式(17)的两边同时乘特征多项式系数 a_k 并求和, 如式(18)所示。

$$\sum_{k=0}^p a_k \hat{x}(n-k) = \sum_{i=1}^p b_i \sum_{k=0}^p a_k z_i^{n-k}, p \leq n \leq N-1 \quad (18)$$

为建立 Prony 算法, 定义真实值 $x(n)$ 与 Prony 算法估计值 $\hat{x}(n)$ 之间的误差为 $e(n)$, 如式(19)。

$$e(n) = x(n) - \hat{x}(n) \quad (19)$$

由式(18)和式(19)可得

$$x(n) = - \sum_{i=1}^p a_i x(n-i) + \sum_{i=0}^p a_i e(n-i), n = 0, 1, \dots, N-1 \quad (20)$$

对式(20)构造扩展阶的样本矩阵 R_e , 如式(21)所示。

$$R_e = \begin{bmatrix} r(1,0) & r(1,1) & \cdots & r(1,p_n) \\ r(2,0) & r(2,1) & \cdots & r(2,p_n) \\ \vdots & \vdots & & \vdots \\ r(p_n,0) & r(p_n,1) & \cdots & r(p_n,p_n) \end{bmatrix} \quad (21)$$

通过奇异值分解和最小二乘法对式(21)求解, 明确有效秩 p 和特征方程系数 α , 并代入式(22)求解 z 。

$$\sum_n a_p z^{p-n} = 0 \quad (22)$$

将由式(22)得到的结果代入式(13)中, 可将其表示为如下矩阵形式:

$$\begin{bmatrix} \hat{x}(0) \\ \hat{x}(1) \\ \vdots \\ \hat{x}(N-1) \end{bmatrix} = \begin{bmatrix} z_1^0 & z_2^0 & \cdots & z_n^0 \\ z_1^1 & z_2^1 & \cdots & z_n^1 \\ \vdots & \vdots & & \vdots \\ z_1^{N-1} & z_2^{N-1} & \cdots & z_n^{N-1} \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_p \end{bmatrix} \quad (23)$$

根据最小二乘法确定 b_i , 通过计算得到幅值 A_i 、相位 θ_i 、频率 f_i 、衰减因子 α_i , 如式(24)所示。

$$\left. \begin{aligned} A_i &= |b_i| \\ \theta_i &= \arctan[\text{Im}(b_i) / \text{Re}(b_i)] \\ f_i &= \arctan[\text{Im}(z_i) / \text{Re}(z_i)] / (2\pi \Delta t) \\ \alpha_i &= \ln |z_i| / \Delta t \end{aligned} \right\} \quad (24)$$

3 基于RIME-VMD与Prony的弓网谐振信号分析

3.1 算法流程

针对弓网谐振信号特征参数提取问题, 本文提出一种融合 RIME-VMD 和 Prony 算法的弓网谐振分析与检测方法。在实际应用中, 弓网谐振信号常含有各类噪声, 会影响信号的分析及检测的准确性。为此, 首先引入 RIME-VMD 结合能量熵增量对信号进行预处理: 利用 RIME 算法自适应搜索最优参数组合的能力, 以最小包络熵为适应度函数, 确定变分模态分解(VMD)中的模态个数 K 与惩罚因子 α , 从而实现对弓网谐振信号的噪声抑制与有效分量提取。在此基础上, 采用 Prony 算法对预处理后的信号进行特征参数辨识。该方法通过 RIME-VMD 自适应优化分解参数, 提升了 Prony 算法对弓网谐振特征参数辨识的精度与可靠性。

算法流程图如图2所示, 具骤如下:

①初始化 RIME 算法和 VMD 模型的各项参数, 设置霜冰算法的种群数量、迭代次数, 并指定模态个数 K

和惩罚因子 α 的取值区间——上界 Ub_{ij} 与下界 Lb_{ij} 。

②输入待处理的原始信号。

③确定当前迭代次数 t 和最大迭代次数 T , 利用式(8)计算出霜粒的粘附系数 E , 当粘附系数 E 满足 $r_2 \leq E$ 条件时, 根据式(5)计算更新后霜粒的新位置。

④根据式(9)中的适应度函数的归一化值 $F^{\text{normr}}(\mathbf{S}_i)$ 确定霜粒的位置更新, 如满足式(9)中 $r_3 < F^{\text{normr}}(\mathbf{S}_i)$, 则更新霜粒的位置 $\mathbf{R}_{ij}^{\text{new}}$ 。

⑤通过比较各霜粒更新后和当前位置对应的适应度值, 确定最优霜粒的新位置 $\mathbf{R}_{ij}^{\text{new}}$ 和最优适应度值 $F^{\text{normr}}(\mathbf{S}_i)$ 。

⑥进入迭代循环, 若满足循环条件, 且当 $t < T$ 时为最优参数组合时输出结果, 将得到的模态个数 K 和惩罚因子 α 输入至VMD中进行分解; 若不满足条件, 则更新迭代次数 t , 继续下一轮迭代直至满足条件后退出循环。

⑦计算经过RIME-VMD分解得到的各IMF分量的能量熵增量, 若该分量的能量熵增量大于等于某阈值时, 则认定其为有效分量, 反之则认定其为无效分量; 将有效分量重新组合构成降噪重构后的信号。

⑧对降噪重构后的信号应用Prony算法, 辨识其幅值、频率等特征参数。




图2 算法流程图

Fig. 2 Flow diagram of the algorithm

3.2 降噪效果评价方法

为评估重构信号的降噪效果, 本文采用均方根误差RMSE值 A_{RMSE} 和信噪比SNR值 A_{SNR} 两种指标进行量化评价, 其计算公式如下式所示:

$$A_{\text{RMSE}} = \sqrt{\sum_{m=1}^i \left(\frac{x(m) - x'(m)}{m} \right)^2} \quad (25)$$

式中: m 为降噪的数据量; $x(m)$ 和 $x'(m)$ 分别为未添加噪声的原始信号和降噪后的信号。

RMSE值 A_{RMSE} 越小, 表示重构信号与原始信号的误差越小, 重组精度越高, 即降噪效果越显著^[19]。

SNR值的计算如下式所示:

$$A_{\text{SNR}} = 10 \lg \left(\frac{P_m}{P_n} \right) \quad (26)$$

式中: P_m 为有效信号分量的功率; P_n 为噪声成分的功率。

若SNR值 A_{SNR} 越高, 则表明降噪性能越优, 反之, 则说明降噪效果有限^[20]。

4 仿真与验证分析

4.1 弓网谐振信号数学模型

为模拟弓网谐振的波形特性, 构造了一个非平稳、非线性的仿真信号, 其数学表达式如下:

$$\left. \begin{aligned} x_i(t) &= A_i \cos(2\pi f_i t + \theta_i) \\ x(t) &= \sum_{i=1}^4 x_i(t) + \delta(t) \end{aligned} \right\} \quad (27)$$

式中: $x_i(t)$ 为各分量的仿真信号, 其参数设置如表1所示; $\delta(t)$ 为信噪比为0 dB的高斯白噪声信号; $x(t)$ 为添加噪声后的仿真信号。

表1 仿真谐振信号各参数设置
Table 1 Parameter settings for simulation of resonance signals

仿真信号	电压幅值/kV	f/Hz	θ/rad
$x_1(t)$	36.0	50	0.8
$x_2(t)$	2.5	1 050	0.5
$x_3(t)$	3.0	1 500	1.5
$x_4(t)$	5.0	2 100	0.5

本文设置采样频率为8 400Hz, 采样点数为5 000。添加高斯白噪声的仿真信号如图3所示。对图3观察可




图3 添加噪声后信号的时域图及包络谱

Fig. 3 Time-domain plot and envelope spectrum of signals after noise addition

知时域波形存在一定的畸变现象，包络谱也受到噪声干扰，这对 2 100 Hz 高频分量的参数辨识造成了一定影响。

4.2 谐振信号的RIME-VMD分解与重构

上述基于传统包络谱的分析效果欠佳，为此，本文采用RIME-VMD方法对谐振信号进行分解处理。在应用该方法时，需合理设定模态个数 K 的取值边界：若 K 值过大时，会产生过多虚假分量；反之， K 值过小则可能导致分解不足，引发模态混叠问题^[17]。具体参数设置如表2所示。

表2 RIME-VMD与DBO-VMD算法参数设置
Table 2 Parameter settings of the RIME-VMD and DBO-VMD algorithms

参数	值
种群数量	5
迭代次数	50
模态个数	[3,6]
惩罚因子	[2 000,10 000]

蜣螂优化算法 DBO 作为一种新兴的优化算法，其独特的滚球、舞蹈及繁殖机制使其在求解复杂问题时展现出良好的全局搜索能力与收敛性。为客观评估 RIME 算法的性能，本文选取 DBO 优化 VMD 作为对比方法。图 4 展示了两 种算法在谐振信号参数优化中的迭代收敛曲线，对比可知，RIME 算法在较少迭代次数内即可收敛至全局最优或近似最优解，收敛速度与稳定性均优于 DBO 算法。具体而言，RIME 算法在约 15 次迭代后，适应度值在最小值附近且趋于稳定；而 DBO 算法在优化过程中共 5 次陷入局部最优，分别出现在第 7、10、16、26 及 37 次迭代，最终在第 43 次迭代时达到最小值 3.630 5。在避免局部最优、收敛速度及迭代效率方面，RIME 算法均表现出更优的综合性能。





图4 RIME-VMD和DBO-VMD的迭代曲线


Fig. 4 Iterative curves of RIME-VMD and DBO-VMD

确定 RIME 和 DBO 的最优参数组合后，分别采用 RIME-VMD、DBO-VMD 以及传统 VMD 对谐振信号进行分解，结果如图 5 所示。从图 5(a)可见，RIME-VMD 分解后的各模态分量未出现模态混叠现象，分解充分且清晰，基频与高频分量分离效果明显；从图 5(b)可知，DBO-VMD 所得 IMF1-IMF3 虽无模态混叠，但仍


存在分解不彻底的问题，表明该方法在参数寻优过程中可能陷入局部最优；而在图 5(c)中，传统 VMD 方法则同时表现出分解不完全与虚假分量的问题。



(a) RIME-VMD 分析结果



(b) DBO-VMD 分析结果



(c) VMD 分析结果

图5 RIME-VMD、DBO-VMD和传统VMD对谐振信号的分解结果

Fig. 5 Decomposition results of resonant signals from RIME-VMD, DBO-VMD, and conventional VMD

通过对比图 5(a)、图 5(b)、图 5(c) 的分解结果可知，本文所提 RIME-VMD 方法有效优化了传统 VMD 的分解性能，谐振信号的伪分解现象及模态分解不彻底问题得到抑制，同时也在分解过程中显著削弱了信噪比为 0 dB 的噪声干扰。直观上，与 DBO-VMD 相比，RIME-

VMD分解得到的各IMF分量能更清晰地刻画谐振信号的振荡结构,且所含有效振荡信息更为完整充足。

为定量评估分解效果,本文利用IMF能量熵增量计算了RIME-VMD、DBO-VMD和传统VMD所得分解结果中各IMF分量的信号能量熵增值 $\Delta Q(i)$,并计算 $\Delta Q(i)/\mu$ 值,根据该值提取出有效分量。不同方法对应的各IMF能量熵增量 $\Delta Q(i)$ 和 $\Delta Q(i)/\mu$ 如表3所示。

表3 不同方法的IMF能量熵增量

Table 3 IMF energy entropy increments under different methods

分解方法	参数	IMF1	IMF2	IMF3	IMF4	IMF5
RIME-VMD	$\Delta Q(i)$	0.054	0.037	0.049	0.106	0.005
	$\Delta Q(i)/\mu$	0.257	0.187	0.233	0.532	0.023
DBO-VMD	$\Delta Q(i)$	0.053	0.034	0.105	—	—
	$\Delta Q(i)/\mu$	0.252	0.172	0.499	—	—
传统VMD	$\Delta Q(i)$	0.051	0.038	0.110	0.004	—
	$\Delta Q(i)/\mu$	0.243	0.191	0.548	0.020	—

为保证谐振信号在降噪过程中不失真,重构时选取 $\Delta Q(i)/\mu$ 较大的IMF分量作为有效分量。由表3可知,在RIME-VMD分解得到的子序列中,IMF1和IMF4的 $\Delta Q(i)/\mu$ 值分别为0.257和0.532,均大于0.25,故IMF1和IMF4为有效分量。同理可得,DBO-VMD的有效分量是IMF1和IMF3, $\Delta Q(i)/\mu$ 值分别为0.252和0.499;传统VMD的有效分量是IMF1和IMF3, $\Delta Q(i)/\mu$ 值分别为0.243和0.548。由此可知,基于IMF能量熵增量的筛选机制可有效剔除无效分量,在完成降噪处理的同时显著提升信号的质量与清晰度。因此,提取RIME-VMD对应的IMF1和IMF4分量进行重构,其时域图及包络谱如图6所示,与图3的加噪信号相比,该方法有效抑制了噪声干扰,提升了信号的可用性,从而为参数辨识提供了更可靠的分析基础。




图6 降噪重构后信号的时域图及包络谱
Fig. 6 Time-domain plot and envelope spectrum of signals after denoising

为评估本文所提方法的降噪性能,采用RMSE和SNR评价指标对RIME-VMD、DBO-VMD及传统VMD3种方法处理后的降噪信号进行定量分析。表4

为各方法对应的谐振信号降噪效果。

表4 不同方法下谐振信号的降噪效果对比
Table 4 Comparison of denoising effect on resonant signals under different methods

评价指标	RIME-VMD	DBO-VMD	VMD
RMSE	0.026	0.027 7	0.030 8
SNR	45.604	43.276	42.961

由表4可知,在添加0 dB的高斯白噪声的情况下,RIME-VMD的RMSE和SNR指标均优于DBO-VMD及传统VMD,表明其具有更优的降噪性能与信号重构质量。这主要得益于RIME-VMD能够更有效地进行全局参数寻优,从而缓解了传统VMD中常见的模态分解不彻底和虚假分量产生的问题,提升了分解的准确性与可靠性。

4.3 Prony算法对谐振信号的参数情况

仿真谐振信号经过RIME-VMD分解及IMF能量熵增量的重构处理后,对所得降噪信号分别采用希尔伯特变换和Prony算法进行参数辨识。两种方法对谐振信号基频分量和高频分量的频率 f_i 、幅值 A_i 和相位 θ_i 的辨识结果对比如表5、表6所示。表5中的设定值:频率50 Hz,电压幅值36 kV,相位0.8 rad;表6中的设定值:频率2 100 Hz,电压幅值5 kV,相位0.5 rad。

表5 Prony算法及HT对50 Hz基频分量辨识结果对比
Table 5 Comparison of Prony algorithm and HT for identification result of fundamental component (50 Hz)

算法	频率/ Hz	频率 误差/%	电压幅 值/kV	电压幅值 误差/%	相位/ rad	相位 误差/%
Prony	49.993	0.014%	36.439	1.22%	0.816	2.00%
希尔伯特	50.934	0.019%	35.314	1.91%	0.817	2.13%

表6 Prony算法及HT对2 100 Hz高频分量辨识结果对比
Table 6 Comparison of Prony algorithm and HT for identification result of high-frequency component (2,100 Hz)

算法	频率/ Hz	频率 误差/%	电压幅 值/kV	电压幅值 误差/%	相位/ rad	相位 误差/%
Prony	2 100	0.00%	4.930	1.40%	0.492	1.60%
希尔伯特	2 100	0.00%	5.102	2.04%	0.516	3.20%

从表5和表6的误差结果分析,Prony算法在弓网谐振信号的参数辨识中具有较高的准确性,尽管其最大误差出现在相位辨识环节,但仍满足工程实际误差要求。与希尔伯特变换相比,无论是50 Hz基频分量还是2 100 Hz高频分量,Prony算法在频率、幅值及相位各参数上的辨识误差均更低。结果表明,Prony算法的辨识结果更接近真实参数,尤其在频率检测方面优势显著,有效提升了谐振参数辨识的准确度。因此,本文所提的将RIME-VMD和Prony算法相结合的方法,在弓网谐振参数辨识中具有有效性与较好的抗噪性能。

4.4 实测信号的验证

为验证本文所提RIME-VMD算法与Prony算法在

实测弓网谐振信号中的适用性，选取了某牵引变电站 2024 年 3 月 23 日 15 时 14 分记录的谐波谐振数据，其原始信号波形如图 7 所示。

如图 7 所示，该谐波谐振信号在 2 100 Hz 附近发生了谐振，同时受到噪声干扰。本文采用 RIME-VMD 方法对实测信号进行分解，所得结果如图 8 所示。

由图 8 可知，实测信号经 RIME-VMD 分解后得到 4 个 IMF 分量。通过 IMF 能量熵增量计算分解结果中各 IMF 信号的 $\Delta Q(i)$ 值和 $\Delta Q(i)/\mu$ 值，并根据该值提取出有效分量，得到 IMF1 和 IMF4 的 $\Delta Q(i)/\mu$ 值分别为 0.294 和 0.641，均大于设定阈值 0.25，故 IMF1 和 IMF4 为有效分量，将 IMF1 和 IMF4 进行重构后得到降噪后的信号如图 9 所示。

对降噪重构后的实测信号进行 Prony 参数辨识，并基于辨识结果重构出如图 10 所示的拟合信号。通过对比该拟合信号与原始实测信号的波形与特征，进一步




图 7 实测信号的时域图及包络谱
Fig. 7 Time-domain plot and envelope spectrum of measured signals

验证了本文方法在实测弓网谐振信号处理中的可行性和有效性。




图 8 实测信号 RIME-VMD 分解结果
Fig. 8 Decomposition results of measured signals from RIME-VMD




图 9 实测信号降噪后的时域图及包络谱
Fig. 9 Time-domain plot and envelope spectrum of measured signals after denoising




图 10 参数辨识后拟合信号的时域图及包络谱
Fig. 10 Time-domain plot and envelope spectrum of fitting signals after parameter identification

5 结论

本文提出了一种基于RIME-VMD与Prony算法相结合的弓网谐振信号辨识方法, 并通过仿真与试验验证了其有效性, 主要结论如下:

①在信号分解与降噪方面, RIME-VMD方法能自适应搜寻最优参数组合, 有效抑制了模态混叠和过分解问题。与VMD及DBO-VMD相比, 该方法在信噪比与均方根误差上表现更优。结合能量熵增量准则, 可准确提取有效IMF分量并消除虚假分量, 显著提升了谐振信号的降噪与重构质量。

②在参数辨识精度方面, 采用Prony算法对降噪重构后的信号进行辨识, 对各项参数的估计误差均低于希尔伯特变换。结果表明, 所提方法能够更准确地辨识出谐振信号的各项参数, 有利于弓网谐振现象的可靠检测。

③通过弓网谐振仿真信号和实测信号的分析, 验证了RIME-VMD结合能量熵增量的预处理环节后, Prony算法能够准确地检测出弓网谐振, 提升了复杂噪声环境下弓网谐振参数辨识的鲁棒性与准确性, 为工程实际中的谐振检测提供了可行的技术思路。

参考文献:

- [1] 杨佳澎. 牵引供电网高次谐波监测及评估系统开发[D]. 北京: 北京交通大学, 2021.
YANG Jiapeng. Development of high-harmonic monitoring and evaluation system for traction power supply grid[D]. Beijing: Beijing Jiaotong University, 2021.
- [2] 初曦, 林飞, 杨中平, 等. 高速列车与牵引供电网高次谐波谐振分析[J]. 电工技术学报, 2013(增刊2): 354-359.
CHU Xi, LIN Fei, YANG Zhongping, et al. Analysis of high harmonic resonance of high-speed train and traction power supply grid[J]. Transactions of China electrotechnical society, 2013(Suppl 2): 354-359.
- [3] 徐文远, 张大海. 基于模态分析的谐波谐振评估方法[J]. 中国电机工程学报, 2005, 25(22): 89-93.
XU Wenyuan, ZHANG Dahai. A modal analysis method for harmonic resonance assessment[J]. Proceedings of the Chinese society for electrical engineering, 2005, 25(22): 89-93.
- [4] 徐志强, 李冰, 周田华, 等. 基于模态分析的运动负荷牵引电网谐波谐振分析[J]. 电力系统保护与控制, 2010, 38(19): 76-80.
XU Zhiqiang, LI Bing, ZHOU Tianhua, et al. Harmonic resonance assessment of traction system with moving load based on modal analysis[J]. Power system protection and control, 2010, 38(19): 76-80.
- [5] 陈双喜, 林建辉, 陈建政. 基于改进的EMD方法提取车辆-轨道垂向耦合系统动态特性[J]. 振动与冲击, 2011, 30(8): 212-216.
CHEN Shuangxi, LIN Jianhui, CHEN Jianzheng. Dynamic characteristics extraction of vehicle-track vertically coupling system based on improved EMD[J]. Journal of vibration and shock, 2011, 30(8): 212-216.
- [6] 闫转芳, 张会杰, 季元进. 基于集合经验模态分解与希尔伯特-黄变换的有轨电车异常振动分析[J]. 科技创新与应用, 2022, 12(32): 11-15.
YAN Zhuanfang, ZHANG Huijie, JI Yuanjin. Analysis of anomalous vibration based on ensemble empirical mode decomposition and Hilbert-yellow transformation[J]. Technology innovation and application, 2022, 12(32): 11-15.
- [7] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE transactions on signal processing, 2014, 62(3): 531-544.
- [8] 王泊淳, 王启明, 朱瑞虎, 等. 基于波浪激励响应自适应变分模态分解的高桩码头桩基损伤识别[J]. 振动与冲击, 2024, 43(21): 147-155.
WANG Bochun, WANG Qiming, ZHU Ruihu, et al. Damage identification of high-piled wharf pile foundation based on IAVMD under wave excitation[J]. Journal of vibration and shock, 2024, 43(21): 147-155.
- [9] 刘迪洋, 张清华, 朱冠华. 基于优化VMD参数与VGG模型的轴承故障诊断[J]. 机床与液压, 2024, 52(18): 195-202.
LIU Diyang, ZHANG Qinghua, ZHU Guanhu. Bearing fault diagnosis based on optimized VMD parameters and VGG models[J]. Machine tool & hydraulics, 2024, 52(18): 195-202.
- [10] 秦永峰, 李刚, 齐金平, 等. 基于RIME-VMD的高速列车横向减振器故障诊断[J]. 铁道科学与工程学报, 2025, 22(3): 942-953.
QIN Yongfeng, LI Gang, QI Jinping, et al. Fault diagnosis of transverse damper for high-speed trains based on RIME-VMD[J]. Journal of railway science and engineering, 2025, 22(3): 942-953.
- [11] 张天毓. 高速铁路牵引供电系统建模及高次谐波谐振抑制策略研究[D]. 兰州: 兰州交通大学, 2022.
ZHANG Tianyu. Modeling of high-speed railway traction power supply system and research on resonance suppression strategy[D]. Lanzhou: Lanzhou Jiaotong University, 2022.
- [12] 樊运新, 邹焕青. 车网系统高频谐振特性分析[J]. 电力机车与城轨车辆, 2014, 37(5): 10-15.
FAN Yunxin, ZOU Huanqing. Analysis of high-frequency resonance characteristics of locomotive-network system[J]. Electric locomotives & mass transit vehicles, 2014, 37(5): 10-15.
- [13] 宋可荐, 吴命利, 杨少兵, 等. 我国电气化铁路高次谐波谐振问题研究综述[J]. 铁道学报, 2021, 43(1): 64-76.
SONG Kejian, WU Mingli, YANG Shaobing, et al. Review of high-order harmonic resonances of electric railways in China[J]. Journal of the China railway society, 2021, 43(1): 64-76.

- 64-76.
- [14] 施瑶, 王雅静, 崔京楷, 等. 基于 VMD-WPT 和 Prony 算法的谐波间谐波检测[J]. 电气传动, 2021, 51(22): 3-7.
SHI Yao, WANG Yajing, CUI Jingkai, et al. Harmonic and inter-harmonic detection method based on VMD-WPT and Prony algorithm[J]. Electric drive, 2021, 51(22): 3-7.
- [15] 孙京哲, 魏文智, 严天一. 基于霜冰优化算法的半主动悬架控制策略研究[J]. 青岛大学学报(工程技术版), 2024, 39(3): 68-77.
SUN Jingzhe, WEI Wenzhi, YAN Tianyi. Research on Semi-active suspension control strategy based on rime-ice optimization algorithm[J]. Journal of Qingdao university(engineering & technology edition), 2024, 39(3): 68-77.
- [16] 柴凯, 张梅军, 黄杰, 等. 基于 SVD-SGWT 和 IMF 能量熵增量的液压故障特征提取[J]. 机械设计与制造, 2015(3): 51-54.
CHAI Kai, ZHANG Meijun, HUANG Jie, et al. Hydraulic system fault feature extraction based on SVD-SGWT and IMF energy entropy increment[J]. Machinery design & manufacture, 2015(3): 51-54.
- [17] 骆钊, 张涛, 阮彦俊, 等. 基于 APSO-SSD-SVD 的特高压换流站 OLTC 振动信号降噪方法[J]. 电力系统保护与控制, 2024, 52(21): 13-23.
LUO Zhao, ZHANG Tao, RUAN Yanjun, et al. Noise reduction method for the OLTC vibration signal of a UHV converter station based on APSO-SSD-SVD[J]. Power system protection and control, 2024, 52(21): 13-23.
- [18] 李磊, 都成刚, 王维兵, 等. 基于改进 Prony 算法的新能源配网谐波和振荡复合扰动参数提取[J]. 电力系统及其自动化学报, 2023, 35(11): 152-158.
LI Lei, DU Chenggang, WANG Weibing, et al. Harmonic and oscillation compound disturbance parameter extraction of the new energy distribution network based on the modified Prony algorithm[J]. Proceedings of the CSU-EPSCA, 2023, 35(11): 152-158.
- [19] 吴雪梅, 刘志强, 张天龙, 等. 双模型结合进一步降低预测均方根误差和均方根相对误差的方法[J]. 分析化学, 2015, 43(5): 754-758.
WU Xuemei, LIU Zhiqiang, ZHANG Tianlong, et al. A method based on double models combination to further reduce root-mean-square error and relative error of prediction[J]. Chinese journal of analytical chemistry, 2015, 43(5): 754-758.
- [20] 胡光锐, 韦晓东. 基于倒谱特征的带噪语音端点检测[J]. 电子学报, 2000, 28(10): 95-97.
HU Guangrui, WEI Xiaodong. Endpoint detection of noisy speech based on cepstrum[J]. Acta electronica sinica, 2000, 28(10): 95-97.

Identification of pantograph-catenary resonance characteristic parameters based on RIME-VMD algorithm

QI Jiaqi, CHANG Junchao, LI Zhichuan, CHEN Dongyan, YANG Guangrun, YANG Sen

(Metering Center, Yunnan Power Grid Co., Ltd., Kunming, Yunnan 650500, China)

Abstract: To improve high-order resonance detection for pantograph-catenary systems on electrified railways, this paper proposes a resonance signal identification method that combines variational mode decomposition (VMD) optimized by the rime optimization algorithm (RIME) with the Prony algorithm. Using the minimum envelope entropy as the fitness function, the RIME-based VMD optimization determined the optimal parameter combination of the number of modes (K) and the penalty factor (α), and the subsequent decomposition of resonance signals by VMD yielded intrinsic mode functions (IMFs). An IMF energy entropy increment threshold was then applied to extract effective IMFs, and denoised signals were reconstructed. The denoising effect was evaluated using the root mean square error (RMSE) and signal-to-noise ratio (SNR). Finally, the Prony algorithm identified the characteristic parameters of the denoised resonance signals. Verification through simulation and measurement shows that the method can accurately identify pantograph-catenary resonance characteristic parameters in strong noise environments, exhibiting good noise resistance.

Keywords: pantograph-catenary system; RIME algorithm; energy entropy increment; Prony algorithm