DOI: 10. 19650/j. cnki. cjsi. J2107839

# 基于 CEEMDAN 和概率神经网络的 起伏振动气液两相流型识别\*

刘起超,周云龙,陈 聪

(东北电力大学能源与动力工程学院 吉林 132012)

摘 要:起伏振动气液两相流型准确识别对漂浮核动力平台安全稳定运行有重要意义。通过对比静止和起伏振动管道的压差 信号以及对应的频谱图发现,起伏振动管道内的压差信号波动幅度更大且包含更多的频率分量,两种流型均含有主频率,该频 率为起伏振动频率。针对起伏振动状态气液两相流压差信号的复杂性,分别采用自适应白噪声的完备总体经验模态分解 (CEEMDAN)和集合经验模态分解(EEMD)对小波降噪后的压差信号进行模式分解,发现 CEEMDAN 能够在减少模式分量的同 时获得更多有效的分量。通过计算 spearman 相关系数选择具有表征意义的 IMF 分量进行 Hilbert 变换计算能量作为特征值,采 用概率神经网络对流型进行识别。结果表明,采用 CEEMDAN 进行模式分解结合概率神经网络的识别方法准确率达到 95.83%,能够用于起伏振动下气液两相流型识别。

# Flow pattern identification of fluctuating vibration gas liquid two phase flow based on CEEMDAN and probabilistic neural network

Liu Qichao, Zhou Yunlong, Chen Cong

(School of Energy and Power Engineering, Northeast Electric Power University, Jilin 132012, China)

Abstract: Accurate identification of fluctuating vibration gas-liquid two-phase flow pattern is of great significance for the safe and stable operation of nuclear power platform under floating vibration. Through comparing the differential pressure signals and the corresponding spectrums in static and fluctuating vibration pipelines, it is found that the differential pressure signals in fluctuating vibration pipelines have larger fluctuation amplitude and contain more frequency components, and both flow patterns have dominant frequency, which is the fluctuating vibration frequency. Aiming at the complexity of the pressure difference signals of gas-liquid two-phase flow in fluctuating vibration state, complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and ensemble empirical mode decomposition (EEMD) are used to decompose the pressure difference signals after wavelet de-noising. It is found that CEEMDAN can reduce the mode components that have symbolic meaning are selected to perform Hilbert transform, and the energy is calculated and used as the eigenvalue. Probabilistic neural network is used to identify the flow pattern. The results show that using CEEMDAN to perform mode decomposition, combining with probabilistic neural network, the accuracy of the identification method is 95. 83%, and this method can be used to identify the flow pattern of gas-liquid two-phase flow under fluctuating vibration.

Keywords: complete empirical mode decomposition; probabilistic neural network; fluctuating vibration; gas-liquid two-phase flow; flow pattern identification

收稿日期:2021-04-27 Received Date: 2021-04-27

<sup>\*</sup>基金项目:国家自然科学基金(51776033)项目资助

# 0 引 言

随着海上漂浮技术的发展,海上核动力平台逐渐进入能源领域。2019年,由俄罗斯建造的全球首个北极漂 浮核电站的运行标志着该技术已经达到工业化要求。然 而,由于受到海浪载荷的作用,海上漂浮平台会处于起伏 运动状态,此时管内气液两相流动的特征参数波动更加 复杂,非线性非平稳特性更加明显。起伏振动状态管内 气液两相流型的准确识别对保障海上核动力平台的正确 设计和安全运行有重要意义。

气液两相流型识别方法主要有图像处理和信号处 理两大类,图像处理主要以高速摄影仪、电容层析成像 或电阻层析成像得到的图像为原始数据,采用灰度处 理和阈值分割等技术进行图像处理,结合机器学习算 法对流型进行识别<sup>[1-2]</sup>。该方法对图像处理手段要求 较高并且对部分流型不适用。基于信号处理的流型识 别方法是目前流型识别中主要采用的手段,原始数据 主要包括差压信号<sup>[3-8]</sup>、含气率<sup>[9]</sup>、电阻层析成像的阻 值<sup>[10]</sup>和多点压差融合信号<sup>[11]</sup>等,其中压差信号以其方 便测量和区分度大等优点成为流型识别中原始信号首 选。信号处理主要采用现代数学算法对原始信号进行 分析,常见有递归分析<sup>[12]</sup>、熵分析<sup>[13]</sup>、小波分析<sup>[9,14]</sup>和 模式分解[3-8]等。机器学习作为现代智能算法的典型, 被广泛应用于流型识别,多层感知器<sup>[10]</sup>、深度学习<sup>[15]</sup> 和卷积神经网络<sup>[16]</sup>等在流型识别中均取得较好的分类 效果。

相比其它方法,模式分解具有普适性,被广泛应用 于流型识别信号预处理。1998年,Huang等<sup>[17]</sup>提出了 适用于非线性非平稳时域信号分析的希尔伯特黄变换 (Hilbert-Huang transform,HHT)方法。其无需预设基函 数,基于数据的局部特征进行自适应分解,既适用于非 线性非平稳信号的分析,也适用于线性平稳信号的分 析。众多学者采用 HHT 对两相流压力波动信号提取特 征值,在此基础上进行流型识别,取得了较为理想的效 果<sup>[3-8]</sup>。

HHT 主要包括经验模态分解(empirical mode decomposition, EMD)和 Hilbert 谱分析, 其中 EMD 为核心, 能够将非线性非平稳信号分解为多个模式, 但是存在模式混叠问题。Wu 等<sup>[18]</sup>采用加入噪声的方法减小 EMD 的模态效应, 提出了集合经验模态分解(ensemble empirical mode decomposition, EEMD), 但仍存在模式混合、信号叠加高斯白噪声产生噪声残余以及模式过分解问题。Torres 等提出了自适应白噪声的完备总体经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN), 能够有效解决 EMD 分解

过程中的模态混叠问题,同常用的 EEMD 方法相比,迭代 次数减少,增加了重构精度,更适合非线性信号的分 析<sup>[19]</sup>。CEEMDAN 广泛应用于故障诊断、负荷预测、信号 降噪等领域,取得了理想的效果<sup>[20-26]</sup>,但目前尚未应用于 流型识别。

本文采用 EEMD 和 CEEMDAN 对压差信号分解得到 特征值,采用概率神经网络的识别结果进行对比,提出一 种基于 CEEMDAN 和概率神经网络的流型识别新方法, 能够准确识别起伏振动气液两相流型,对漂浮平台的设 计和安全运行有重要意义。

# 1 CEEMDAN-Hilbert 变换

#### 1.1 CEEMDAN 算法

CEEMDAN 算法在 EMD 算法基础上加入了自适应 白噪声,计算步骤如下<sup>[19]</sup>:

定义  $E_j(\cdot)$ 为采用 EMD 方法分解信号得到的第 j 阶 本征模函数(intrinsic mode function, IMF)分量, $\omega^i$  为符合 标准正态分布的白噪声, $\varepsilon$  为噪声标准差,  $IMF_j$  为 EMD 算法得到的第 j 阶 IMF 分量,  $\overline{IMF_j}$  为 EEMD 算法得到的 第 j 阶 IMF 分量,  $\widehat{IMF_j}$  为 CEEMDAN 分解得到的第 j 阶 IMF 分量。

对信号  $x[n] + \varepsilon_0 \omega^i[n]$ 进行 1 次变换,得到第一阶 IMF 分量:

$$\widehat{IMF_{1}[n]} = \frac{1}{I} \sum_{i=1}^{I} IMF_{1}^{i}[n] = \overline{IMF_{1}[n]}$$
(1)

计算一阶残余信号:

$$\mathbf{r}_{1}[n] = \mathbf{x}[n] - \widetilde{\mathbf{IMF}_{1}[n]}$$
(2)

对  $r_i[n] + \varepsilon_1 E_1(\omega^i[n]), i=1, \dots, I$  进行分解,直到 出现 EMD 第一阶分量,定义二阶分量为:

$$\boldsymbol{r}_{k}[n] = \boldsymbol{r}_{k-1}[n] - \widetilde{\boldsymbol{IMF}_{k}[n]}$$

$$\tag{4}$$

对  $r_k[n] + \varepsilon_k E_k(\omega^i[n]), i = 1, \dots, I$  进行分解,直到 出现 EMD 第一阶分量,定义 k+1 阶分量为:

$$\widehat{IMF_{k+1}[n]} = \frac{1}{I} \sum_{i=1}^{I} E_{1}(r_{k}[n] + \varepsilon_{k}E_{k}(\boldsymbol{\omega}^{i}[n]))$$
(5)

重复上述步骤,直到 k=K。

上述步骤一直进行到残余分量的极值点数不超过 2个,分解终止。最终的残余分量为:

$$\boldsymbol{R}[n] = \boldsymbol{x}[n] - \sum_{k=1}^{K} \widetilde{\boldsymbol{I}} \widetilde{\boldsymbol{I}} \widetilde{\boldsymbol{I}} \widetilde{\boldsymbol{F}}_{k}$$
(6)

其中, K 为分解总模式数。原始信号 x [n] 可表示为:

$$\boldsymbol{x}[n] = \sum_{k=1}^{K} \widetilde{\boldsymbol{IMF}_{k}} + \boldsymbol{R}[n]$$
(7)

# 1.2 表征 IMF 选择

原始信号经 CEEMDAN 分解后产生的多个 IMF 分量 与原始信号满足正交性,可以通过两者的相关系数判断 该 IMF 分量是否具有表征意义,从而避免原始信号中虚 假信号和噪声的干扰。目前大多数文献采用经典的皮尔 逊相关系数进行判断,然而 IMF 分量和原始信号之间是 非线性关系,且不呈正态分布,结果会产生一定的偏差。 本文采用能够适用于非线性相关的 spearman 相关系数 进行判别。

原始信号 x[n]和第 j 阶 IMF 分量  $IMF_{j[n]}$  之间的 spearman 相关系数  $\rho_i$  为:

$$\rho_j = 1 - \frac{6\sum_{k=1}^{n} (\boldsymbol{x}[n] - \widehat{\boldsymbol{IMF}_j[n]})}{n(n^2 - 1)}$$
(8)

#### 1.3 Hilbert 变换

对于任意给定的原始信号 x(t),希尔伯特变换的表达式如式(9)所示:

$$H[\mathbf{x}(t)] = \frac{1}{\pi} PV \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} \mathrm{d}\tau$$
(9)

式中:PV表示奇异积分的主值(principal value of singular integral)。

$$\boldsymbol{z}(t) = \boldsymbol{x}(t) + \mathrm{i}\boldsymbol{y}(t) = \boldsymbol{a}(t) \,\mathrm{e}^{\mathrm{i}\boldsymbol{\theta}(t)} \tag{10}$$

式中:a(t)和 $\theta(t)$ 称为瞬时幅值(instantaneous amplitude)和相函数(phase function),定义如式(11) 和(12):

$$\boldsymbol{a}(t) = \sqrt{x^2 + y^2} \tag{11}$$

$$\boldsymbol{\theta}(t) = \arctan\left(\frac{y}{x}\right) \tag{12}$$

则瞬时频率(instantaneous frequency)如式(13):

$$\omega = \frac{\mathrm{d}\theta}{\mathrm{d}t} \tag{13}$$

对分解得到的每一个内模函数进行希尔伯特变换, 原始信号x(t)可由式(14)表示:

$$\mathbf{x}(t) = \Re\left\{\sum_{j=1}^{n} \boldsymbol{a}_{j}(t) \exp\left[\mathrm{i}\int\boldsymbol{\omega}_{j}(t)\,\mathrm{d}t\right]\right\}$$
(14)

$$\boldsymbol{H}(\boldsymbol{\omega},t) = \Re\left\{\sum_{j=1}^{n} \boldsymbol{a}_{j}(t) \exp\left[i\int \boldsymbol{\omega}_{j}(t) dt\right]\right\}$$
(15)

为了便于利用希尔伯特变换识别流型,定义分解后的各模态分量的能量为:

$$E_j = |\boldsymbol{a}_j(t)|^2 \tag{16}$$

#### 1.4 IMF 能量归一化

由于不同信号的 IMF 能量数据范围不同,为了准确 识别不同流型,需要对 IMF 能量进行归一化处理。假设 *m* 为具有表征意义的 IMF 数量,则:

$$E = \left(\sum_{i=1}^{m} |E_i|^2\right)^{1/2}$$
(17)

归一化后的能量 
$$E'_j$$
 为:

$$E_j' = \frac{E_j}{E} \tag{18}$$

# 2 概率神经网络

概率神经网络(probabilistic neural networks, PNN)是 Specht 根据贝叶斯分类规则与 Parzen 的概率密度函数提 出的。借助 Parzen 窗理论获得已知类别数据的结构关系, 建立研究对象的数学模型和统计模型<sup>[27]</sup>,用先验知识预测 新样本类别,渐进达到 Bayes 最优决策边界。概率神经网 络能基于线性学习算法高精度的特点来完成非线性学习 算法所需的工作,被广泛应用于分类问题,是一种能够有 效克服噪声污染并且对大量测试数据进行模式分类的工 具,在模式识别和分类领域得到越来越多的认可<sup>[28]</sup>。

概率神经网络主要包括输入层、模式层、求和层以及 输出层。输入层的传递函数是线性的,在网络工作时,样 本数据 X 由输入层直接传递到模式层,输入层的神经元 个数与样本长度一致。

模式层神经元数目与输入训练样本个数相等<sup>[29]</sup>,在 模式层中计算的是输入样本 X 与训练集中每个训练样本 X<sub>j</sub>的距离,然后通过径向基函数对其进行非线性映射获 得输出量 M,该非线性映射由高斯函数来实现。

$$\boldsymbol{M}_{ij}(\boldsymbol{X}) = \frac{1}{\pi n \sigma^2} \exp\left[\frac{\parallel \boldsymbol{X}_i - \boldsymbol{X}_j \parallel}{2\sigma^2}\right]$$
(19)

式中: σ 是高斯分布的方差(平滑因子), 其值对神经网络的性能有着重要影响。

求和层神经元个数与目标类别数目相同。求和层把 隐含层中属于同一类的隐含神经元的输出做加权平均, 如式(20)所示:

$$\boldsymbol{P}_i = \frac{\boldsymbol{M}_{ij}(\boldsymbol{X})}{L} \tag{20}$$

式中:**P**<sub>i</sub> 为第 i 类类别的输出;L 为第 i 类的神经元个数。 输出层中的节点数等于目标类别数。输出层承接求 和层的输出,并做简单的阈值判别,输出判定的目标模式 概率为1,其余为0,如式(21)所示:

$$y = \max(\boldsymbol{P}_i) \tag{21}$$

# 3 流型识别方法

本文分别采用 EEMD 和 CEEMDAN 算法对压差信号 进行模式分解,结合概率神经网络对不同流型进行识别, 具体步骤如下:

分别选取包含所有振动工况的不同流型压差信号,
 每种流型 80 组,其中 50 组为训练数据,30 组为测试数据;
 2)对原始压差信号进行小波降噪;

3)采用 EEMD 和 CEEMDAN 方法对降噪后的压差 信号进行分解;

4) 计算 EEMD 和 CEEMDAN 分解后各 IMF 分量与 原始信号的 spearman 相关系数,选择相关系数较大的 IMF 分量作为具有表征意义的 IMF 分量;

5) 对筛选出的 IMF 进行 Hilbert 变换, 计算 IMF 能量:

6)将 IMF 能量进行归一化处理;

7) 以归一化后的 IMF 能量为特征值,采用 PNN 进行 流型识别,通过对比识别结果得出最佳识别方法。

#### 4 实验分析

起伏振动气液两相流实验系统主要包括两相流回路 和起伏振动平台。两相流回路见文献[30],实验段为有 机玻璃管,固定在起伏振动实验平台上,采用动态压差传 感器进行测量,量程-50~50 kPa,输出电压 0~5 V,由数 据采集仪传输至计算机,同时采用高速摄影仪记录不同 工况下的流型。实验在常温常压下进行,气相折算速度 0.1~20 m<sup>3</sup>/h,液相折算速度 0.1~2.0 m<sup>3</sup>/h,保证出现典 型的弹状流、搅混流、环状流和泡状流流型。

起伏振动平台为自行设计,结构如图 1 所示,主要包括台架、电动机、减速器、变频器和曲柄连杆机构,能够产 生振幅、频率可变的标准正弦振动,频率为 0~0.98 Hz,振 幅为 0~200 mm。本文实验振动工况如下:振幅 *A* 为 50、 100、150 和 180 mm,频率*f* 为 0.21、0.42、0.7 和 0.98 Hz。



图 1 起伏振动平台结构 Fig. 1 Fluctuating vibration platform structure

#### 4.1 起伏振动气液两相流型

起伏振动会引入附加力,使气-液相间以及管道和流 体微团间作用力更加复杂,导致流型发生改变。改变振 动和流动工况,采用高速摄影仪对实验段流型进行记录。 结果表明,起伏振动下虽然流动结构发生改变,但仍可以 按照传统上升管的流型划分方法,将其分为泡状流、弹状 流、搅混流和环状流,如图2所示。



Fig. 2 Flow patterns of gas liquid two phase flow in vertical pipe with fluctuating vibration

#### 4.2 不同流型压差信号及模式分解

基于 EMD 的经典 HHT 变换已被证实能够用于气液 两相流型识别,并且取得比较理想的效果<sup>[6-8]</sup>。然而起伏 振动下压差信号的波动更加剧烈,与静止管道相比增加 了振动信号以及由振动引起的噪声。相同流动工况静止 和振动管道不同流型的原始压差对应电压波动信号如 图 3 所示。由图可知,与静止管道相比,振动状态下不同 流型的差压信号波动都有所加剧,以弹状流和环状流表 现尤为明显。在相同气相和液相折算速度下,以平均值 为基准,与静止管道相比起伏振动下弹状流的波动范围 由-12.67%~14.34%增至-11.77%~18.8%;环状流的 波动范围由-8.08%~11.89%增至-11.18%~20.98%。 静止管道内除了泡状流外,其他三种流型的电压平均值 差别较小,均在 2.25~2.3 之间,起伏振动下不同流型的 平均值虽有所变化但依然在改范围内,无法通过平均值 和波动范围对流型进行准确区分。

图 3 中不同状态下不同流型的电压信号频谱如图 4 所示。由图可知,静止管道内,弹状流和搅混流具有较为 明显的波动频率,但不存在主频率,而环状流和泡状流无 明显波动频率。起伏振动管道内,所有流型的电压信号 均包含有振动频率分量且该频率为波动的主频率。此 外,弹状流和搅混流具有其特有的波动频率。由于起伏 振动状态下所有流型具有相同的主频率,采用传统的频 域分析法无法对流型做出准确识别。





in static and fluctuating vibration pipelines





.4 Frequency spectrum diagrams of pressure different in static and fluctuating vibration pipelines

采用 EEMD 对其进行分解,结果如图 5 所示。由图 可知,EEMD 对两者的分解均存在模式混叠和过分解现 象,且振动状态下的分解结果从 IMF1~IMF7 的模式混叠 现象更加严重。

分别采用 EEMD 和 CEEMDAN 对泡状流压差信号分解,如图 6 所示。从图中可以看出 EEMD 的分解结果从 IMF10~IMF12 都存在过分解问题,导致引入无关分量,



and fluctuating vibration pipes

而 CEEMDAN 算法采用加入自适应的白噪声结合相互抵 消的处理,可以最大程度降低白噪声对结果的影响,有效 解决过分解和模式混叠问题,分解的结果更具代表性。

计算 EEMD 和 CEEMDAN 分解得到每个 IMF 分量 和原始信号的 spearman 相关系数,部分结果如表 1 和 2 所示。由表可知,虽然采用 EEMD 分解得到的模式有 12 个,但是具有表征意义的 IMF 分量却只有 6 个,而采 用 CEEMDAN 分解得到的模式只有 11 个,但具有表征意 义的 IMF 分量有 7 个,与 EEMD 相比,CEEMDAN 方法能 够在分解层数较少的情况下获得更多有效的 IMF 分量。 如上所述,起伏振动管道内不同流型的电压信号波动规 律比较复杂且含有多个波动频率,导致模式分解出现更 多的模式分量,而本文采用的 CEEMDAN 方法能够减少 模式分量数量的同时获得更多的有效特征值,不仅能够 减少计算资源,而且能提高识别正确率。



Fig. 6 Comparison of EEMD and CEEMDAN decomposition results

表 1 EEMD 分解各 IMF 分量和原始信号相关系数 Table 1 The correlation coefficients of IMF components and original signals for EEMD decomposition

序号	1	2	3	4
IMF1	0.7327	0. 549 4	0.648 0	0.6519
IMF2	0.532 9	0.8512	0. 599 4	0.778 2
IMF3	0.2796	0.5334	0.4961	0.404 6
IMF4	0.3519	0.262 3	0.3407	0.1618
IMF5	0.4307	0.1124	0.205 2	0.1575
IMF6	0.2693	0.061 1	0. 148 9	0.1653
IMF7	0.027 5	0.021 6	0.053 9	0.0204
IMF8	0.035 8	0.006 6	0.020 5	0.0108
IMF9	0.021 9	0.001 2	0.028 5	0.008 2
IMF10	0.017 1	0.002 0	0.013 7	-0.005 8
IMF11	0.017 1	0.002 5	0.013 4	-0.004 8
IMF12	-0.002 7	0.005 3	0.011 6	-0.005 1

表 2 CEEMDAN 分解各 IMF 分量和原始信号相关系数 Table 2 The correlation coefficients of IMF components and original signals for CEEMDAN decomposition

序号	1	2	3	4
IMF1	0.724 6	0.7076	0.648 0	0.6522
IMF2	0.551 0	0.632 6	0. 574 9	0.731 4
IMF3	0.502 0	0.6692	0.582 0	0.6502
IMF4	0.301 6	0.5061	0.4954	0.3202
IMF5	0.2898	0.225 5	0.342 4	0.127 8
IMF6	0.402 6	0.0794	0. 194 3	0.1628
IMF7	0.303 2	0.122 2	0.1474	0.1594
IMF8	-0.013 8	0.0514	0.055 6	0.0001
IMF9	0.0217	0.043 0	-0.000 4	-0.001 5
IMF10	0.019 2	0.025 0	0.027 0	0.009 4
IMF11	0.013 1	0.063 2	0.020 0	-0.011 8

#### 4.3 不同方法识别结果对比

采用上述方法进行流型识别,结果如图 7 所示,识别 准确率如表 3 所示。结果表明,在同样采用 PNN 进行流 型识别时,与 EEMD 方法相比,采用 CEEMDAN 对压差信 号进行模式分解和特征值提取能够获得更好的识别效 果,准确率为 95.83%,并且对每种流型都具有较高的识 别率。在识别错误数据中,弹状流出现 3 个,其中有 2 个 弹状流误识别为环状流,1 个误识别为泡状流;环状流出 现 1 个,误识别为泡状流;搅混流出现 1 个,误识别为环 状流。出现该错误的原因有 3 点,1)振动状态下不同流 型的信号波动都比较剧烈,提取的某些特征值区分度不 太明显;2)选择的部分数据可能处于流型过渡区域; 3)训练样本数量较少,导致神经网络预测结果出现误差。



Fig. 7 Recognition results of different methods

#### 表 3 不同识别方法准确率

Table 3 Accuracies of different recognition methods %

识别正确率	EEMD+PNN	CEEMDAN+PNN
弹状流	83.33	90
环状流	90	96.67
搅混流	93.33	96.67
泡状流	100	100
综合	91.67	95.83

本文提出的基于 CEEMDAN-Hilbert 变换和 PNN 的 流型识别方法可以用于起伏振动状态气液两相流型识 别,并且为基于信号分解的流型识别技术提供了一种高 效可靠的模式分解新方法。

# 5 结 论

起伏振动使得气液两相流压差信号更加复杂,对流 型识别方法提出了更高的要求。通过对比起伏振动和非 振动状态下压差信号频谱分析结果,发现起伏振动管道 内的压差信号波动包含更多的频率分量且以起伏振动频 率为主频率。对同一组信号分别采用 EEMD 和 CEEMDAN 进行分解,发现 CEEMDAN 分解结果中 IMF 分量较少且在一定程度上降低了模式分解中的过分解现 象。计算 EEMD 和 CEEMDAN 分解得到的 IMF 分量和 原始信号的 spearman 相关系数,发现 CEEMDAN 的 IMF 分量与原始信号的相关性更好。选取相关性高的 INF 分 量组成特征向量,采用 PNN 神经网络进行流型识别,结 果表明基于 CEEMDAN 和 PNN 的方法能够准确识别起 伏振动状态气液两相流型,识别准确率达 95.83%,这为 流型识别中特征向量的提取提供了一种新方法,并且为 起伏振动下气液两相流流型识别提供了一种高效可行的 手段。同时需指出,本文研究的振动为低频高振幅,振动 特征能够明显地体现在压差信号中。对于其他形式的振 动,如果振动对压差信号影响不明显,该方法能否适用, 尚需要深入研究。

# 参考文献

 [1] 王小鑫,王博,陈阳正,等.基于电容层析成像技术 重构图像的两相流流型识别[J].计量学报,2020, 41(8):942-946.

> WANG X X, WANG B, CHEN Y ZH, et al. Two-phase flow pattern recognition based on electrical capacitance tomography reconstructed images [J]. Acta Metrologica Sinica, 2020, 41(8): 942-946.

- [2] YAN R, VIUMDAL H, MYLVAGANAM S. Process tomography for model free adaptive control (MFAC) via flow regime identification in multiphase flows [J]. IFAC PapersOnLine, 2020, 53(2): 11753-11760.
- [3] 王晓萍. 气固流化床压力脉动信号的 Hilbert-Huang 变换与流型识别[J]. 高校化学工程学报, 2005, 19(4):474-479.

WANG X P. The Hilbert-Huang transform and flow regimes identification for pressurefluctuation of gas-solid fluidized beds [J]. Journal of Chemical Engineering of Chinese Universities, 2005, 19(4): 474-479.

 [4] 孙斌,张宏建,岳伟挺. HHT 与神经网络在油气两相流流型识别中的应用[J].化工学报,2004,55(10): 1723-1727.

> SUN B, ZHANG H J, YUE W T. Applied study of HHT and neural networks on flow regime identification for oilgas two-phase flow [J]. Journal of Chemical Industry and Engineering(China), 2004, 55(10): 1723-1727.

 [5] 孙斌,王二朋,郑永军. 气液两相流波动信号的时频 谱分析研究[J]. 物理学报, 2011, 60(1): 381-388.
 SUN B, WANG ER P, ZHENG Y J. Time-frequency spectral analysis of gas-liquid two-phase flow's fluctuations [J]. Acta Physica Sinica, 2011, 60(1): 381-388.

[6] 周云龙,王强,杨志行,等.基于子波能量特征的气液两相流流型辨识方法[J].化工学报,2007,58(8):1948-1954.
 ZHOU Y L, WANG Q, YANG ZH H, et al.

Identification of gas-liquid two-phase flow patternbased on wavelet energy feature [J]. Journal of Chemical Industry and Engineering (China), 2007, 58(8): 1948-1954.

- [7] 周云龙,王强,孙斌,等. 基于希尔伯特—黄变换与 Elman 神经网络的气液两相流流型识别方法[J].中 国电机工程学报,2007,27(11):50-56.
  ZHOU Y L, WANG Q, SUN B, et al. Applied study of Hilbert-Huang transform and Elman neural network on flow regime identification for gas-liquid two-phase flow [J]. Proceedings of the CSEE, 2007, 27(11):50-56.
- [8] 马龙博,张宏建,周洪亮,等.基于 Hilbert-Huang 变换 和支持向量机的油水两相流流型识别[J].化工学 报,2007,58(3):617-622.

MA L B, ZHANG H J, ZHOU H L, et al. Flow regime identification of oil-water two-phase flow based on HHT and SVM [J]. Journal of Chemical Industry and Engineering(China), 2007, 58 (3):617-622.

[9] 李爽,李玉星,王东旭. 基于小波变换与神经网络的 上倾管流型识别方法[J]. 油气储运,2020,39(8): 912-918.

LI SH, LI Y X, WANG D X. Identification method for flow pattern in upward pipe based on wavelet transform and neural network[J]. Transportation & Storage, 2020, 39(8): 912-918.

[10] 全卫国,朱赓宏. 基于多层感知器的气液两相流流型 识别方法[J]. 热能动力工程, 2020, 35(6): 116-122.
TONG W G, ZHU G H. Gas-liquid two-phase flow pattern recognition methodbased on multilayer

pattern recognition methodbased on multilayer perceptron[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(6): 116-122.

 [11] 姚添,郭烈锦,徐强,等. 基于压差信号融合特征的 集输立管流型识别研究[J]. 工程热物理学报, 2020, 41(12): 3014-3019.
 YAO T, GUO L J, XU Q, et al. Incestigation on flow

regimes recognition in pipeline-riser based on fusion features of differential pressure signals [J]. Journal of Engineering Thermophysics, 2020, 41 (12): 3014-3019.

- [12] 何永勃,董玉珊,薛荣荣.基于交互式递归分析的两相流流型识别方法[J].系统仿真学报,2019,31(4):720-726
  HE Y B, DONG Y SH, XUE R R. Recognition method on two-phase flow regime based on cross recursive analysis [J]. Journal of System Simulation, 2019,
- 31(4):720-726 [13] 周云龙,尹红梅. 棒束通道气液两相流流型识别及动 力学特性分析[J]. 原子能科学技术,2017,51(5): 851-857.

ZHOU Y L, YIN H M. Flow pattern idectification and dynamics characteristics of gas-liquid two-phase flow in rod bundle channel [J]. Atomic Energy Science and Technology, 2017, 51(5): 851-857.

- [14] 王杰,李爱蓉.小波包分析识别气液固三相流流型[J].石油化工,2020,49(1):62-69.
  WANG J, LI AI R. Identification of gas-liquid-solid three-phase flow patterns by wavelet packet analysis[J]. Petrochemical Technology, 2020, 49(1):62-69.
- [15] 黄正梁,王超,李少硕,等.基于深度学习的气液固
   三相反应器图像分析方法及应用[J].化工学报,
   2020,71(1):274-282.

HUANG ZH L, WANG CH, LI SH SH, et al. Development and application of image analysis method based on deep-learning in gas-liquid-solid three-phase reactor[J]. CIESC Journal, 2020, 71(1): 274-282.

- [16] 全卫国,庞雪纯,朱赓宏.基于卷积神经网络的气液 两相流流型识别方法[J].系统仿真学报,2021, 33(4):883-891.
  TONG W G, PANG X CH, ZHU G H. Gas-liquid twophase flow pattern recognition method based on convolutional neural network [J]. Journal of System
- [17] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society, 1998, 454: 903-995.

Simulation, 2021, 33(4): 883-891.

- [18] WU Z H, HUANG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [19] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [ C ]. IEEE International Conference on Acoustics, 2011.

- [20] 刘兆亮,颜丙生,刘春波,等.基于 CEEMDAN-FastICA 的滚动轴承故障特征提取[J].组合机床与自动化加工技术,2021(3):61-65.
  LIU ZH L, YAN B SH, LIU CH B, et al. Fault feature extraction of rolling bearing based on CEEMDAN-FastICA[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2021 (3):61-65.
- [21] 李亚男,程志友. 基于 CEEMDAN 算法及 NARX 神经 网络的短期负荷预测[J]. 安徽大学学报(自然科学版),2021,45(2):38-46.
  LI Y N, CHENG ZH Y. Short-term load forecasting based on CEEMDAN algorithm and NARX neural network[J]. Journal of Anhui University (Natural Science Edition),2021,45(2):38-46.
- [22] 古莹奎,曾磊,张敏,等.基于 CEEMDAN-SQI-SVD 的 齿轮箱局部故障特征提取[J].仪器仪表学报,2019, 40(5):78-88.
  GU Y K, ZENG L, ZHANG M, et al. Feature extraction method for gearbox local fault based on CEEMDAN-SQI-SVD[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 78-88.
- [23] 蒋玲莉, 谭鸿创, 李学军, 等. 基于 CEEMDAN 排列 熵与 SVM 的螺旋锥齿轮故障识别[J]. 振动. 测试与 诊断, 2021, 41(1): 33-40,198-199.
  JIANG L L, TAN H CH, LI X J, et al. Cutting life model of hollow shaft based on dual-frequency vibration system [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1): 33-40,198-199.
- [24] 赵小惠,张梦洋,石杨斌,等.改进 CEEMDAN 算法的电机轴承振动信号降噪分析[J].电子测量与仪器学报,2020,34(12):159-164.
  ZHAO X H, ZHANG M Y, SHI Y B, et al. Noise reduction analysis of motor bearing vibration signal based on improved CEEMDAN algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12):159-164.
- [25] 杨彦茹,温杰,史元浩,等.基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J].电子测量与仪 器学报,2020,34(12):197-205.
  YANG Y R, WEN J, SHI Y H, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 197-205.
- [26] 耿读艳, 王晨旭, 赵杰, 等. 基于 CEEMDAN-PE 的心 电冲击信号降噪方法研究[J]. 仪器仪表学报, 2019,

#### 40(6): 155-161.

GENG D Y, WANG CH X, ZHAO J, et al. Research on BCG signal de-noising method based on CEEMDAN and PE[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 155-161.

- [27] 汪敏, 王亦红. 神经网络在织物疵点分类识别中的应用[J]. 计算机工程与设计, 2016, 37(1): 221-225.
  WANG M, WANG Y H. Application of neural network in classification of fabric defect recognition [J]. Computer Engineering and Design, 2016, 37(1): 221-225.
- [28] 苗永红,柏国龙. 基于概率神经网络的孔压静力触探的土层界面识别[J]. 济南大学学报(自然科学版), 2017, 31(4): 279-284.

MIAO Y H, BAI G L. Soil layer interface identification using piezocone penetration testbased on probabilistic neural network [J]. Journal of University of Jinan (Science and Technology), 2017, 31(4): 279-284.

- [29] 陈明. MATLAB 神经网络原理与实例精解[M].北京: 清华大学出版社, 2013: 205-207.
  CHEN M. MATLAB neural network principle and examples [M]. Beijing: Tsinghua University Press, 2013: 205-207.
- [30] 周云龙,常赫,刘起超.非线性振动下水平通道气液 两相流动[J]. 化工学报,2019,70(7):2512-2519.
   ZHOU Y L, CHANG H, LIU Q CH. Gas-liquid two-phase flow in horizontal channel under nonlinear

vibration[J]. CIESC Journal, 2019, 70 (7): 2512-2519.

### 作者简介



**刘起超**,2014年于东北电力大学获得学 士学位,2017年于东北电力大学获得硕士学 位,现为东北电力大学助教,主要研究方向 为气液两相流流动特性及参数检测。

Liu Qichao received his B. Sc. degree in 2014 and M. Sc. degree in 2017 both from Northeast Electric Power University. Now, he is a teaching assistant in Northeast Electric Power University. His main research interest includes characteristics and parameter detection of gas-liquid two phase flow.

E-mail:lgcliugichao@126.com



周云龙(通信作者),1991年于西安交 通大学获得博士学位,现为东北电力大学教 授,主要研究方向为多相流流动特性及参数 检测、生物质制氢以及高效燃煤发电技术。 E-mail:neduzyl@163.com

**Zhou Yunlong** (Corresponding author) received his Ph. D. degree in 1991 from Xi' an Jiaotong University. Now, he is a professor in Northeast Electric Power University. His main research interest includes characteristics and parameter detection of gas-liquid two phase flow, hydrogen production from biomass and high efficiency coal-fired power generation technology.