

基于小波包分解和 Kohonen 神经网络的气液两相流流型识别方法

孙 斌¹, 周云龙², 张 玲², 洪文鹏²

(1. 华北电力大学 动力系, 河北 保定 071003; 2. 东北电力学院 动力系, 吉林 132012)

摘 要: 针对传统流型识别方法主观性强和 BP 神经网络训练受病态样本影响较大的缺点, 根据小波包变换能将信号按任意时频分辨率分解到不同频段的特性, 提出一种新的气液两相流流型识别方法。该方法首先利用小波包分解对流型的动态压差波动信号进行分析、提取特征, 然后将小波包能量特征与 Kohonen 神经网络结合进行流型识别。对水平管内空气-水两相流 4 种典型流型的识别结果表明: 该方法能有效克服传统识别方法具有的主观性和 BP 网络的缺陷, 具有很好的识别效果, 从而为流型的在线识别提供一种新的有效的技术选择。

关 键 词: 流型识别; 小波包分解; 神经网络; 压差波动

中图分类号: TQ021.1 文献标识码: A

1 引 言

流型识别一直是两相流中的一个重要课题。目前气液两相流流型的识别方法主要有两种: 一种是人为观察的方法; 另一种是利用已有的流型转变准则或流型图判断的方法。两种方法都不可避免地要受主观因素的影响, 难以实现流型的客观识别。不同的特征提取对神经网络的识别效果有很大影响, 因此, 如何寻找各流型的特征是一个很关键的问题。

气液两相流由于流动的复杂性, 其压差波动信号表现出非平稳性, 使得傅里叶变换不能完全适用。小波包分解是多分辨分析的发展, 它是一种比小波分析更为精细的信号分析方法, 它将频带进行多层次划分, 对小波分析没有细分的高频部分进行了分解, 并能根据被分析信号的特征, 自适应地选择频带, 使之与信号频谱相匹配, 从而提高时-频分辨率, 因而它是一种非常有效的信号处理方法。文献 [1] 将小波包能量特征应用于故障特征的量化分析

上, 但在两相流中还未见应用。

近年来, 测量技术和信息处理技术的发展, 为气液两相流型的客观和智能识别提供了可能。神经网络作为一种智能技术已经在流型识别中得到了应用, 但大多都集中在 BP 神经网络。王妍^[2]等将 BP 神经网络应用于气液两相流流型识别中^[3], 而 BP 神经网络的样本训练过程相当复杂而且极不灵活, BP 网络的另外两个缺点较少为人所注意, 即 BP 网络通常只能给出一个解及 BP 网络的解受训练样本病态影响较大, 而不需要教师的自组织映射模型, 即 Kohonen 网络可以克服这些缺点。Kohonen 网络在模式识别、样本排序和样本分类等方面有广泛应用。本文针对压差波动信号的非平稳特性, 尝试运用小波理论寻找各流型的特征, 再与 Kohonen 网络结合, 形成一种新的流型识别方法。

2 流型特征提取的小波包方法

2.1 小波包理论

小波分析的基本思想是用一族函数去表示或逼近一信号或函数, 这一族函数称为小波函数系; 它是通过满足一定条件的基本小波函数不同尺度的平移和伸缩构成的。用小波函数系表示的特点是它的时宽与频宽的乘积很小, 且在时间和频率轴上都很集中, 因此, 其时-频分辨率在低频处频率分辨率高; 在高频处时间分辨率高, 频率分辨率却降低。这是正交小波基的一大缺陷。而小波包却具有随分辨的增加, 变宽的频谱窗口进一步分割变细的优良品质。

假定共轭滤波器满足^[3]:

$$\sum_h (n-2k)h(n-2l) = \delta_{kl} \quad (1)$$

$$\sum_h (n) = \sqrt{2} \quad (2)$$

收稿日期: 2004-04-26; 修订日期: 2004-08-17

基金项目: 吉林省科技发展计划基金资助项目(20040513)

作者简介: 孙 斌(1972-), 男, 吉林永吉人, 华北电力大学博士研究生。

令 $g(k) = (-1)^k h(1-k)$, 按双尺度关系, 定义一系列递归函数 $\{\mu_k(x)\}$:

$$\mu_{2n}(x) = \sum h_k \mu_n(2x-k) \quad (3)$$

$$\mu_{2n+1}(x) = \sum g_k \mu_n(2x-k) \quad (4)$$

其中: $\mu_0(x)$ 可以定义为尺度函数 $\varphi(x)$; $\mu_1(x)$ 是小波基函数 $\Psi(x)$, 称由标准正交化生成元 $\varphi(x)$ 导出的函数; $\{2^{j/2} \mu_n(2^j x - k); n \in N; 1, k \in Z\}$ 为关于 $\Psi(x)$ 的小波包。小波包的完整性和正交性使原始信号的信息得到完整保留。

对一给定信号, 通过一组低通和高通组合的共轭正交滤波器 H 和 G, 不断将信号划分到不同的频段上。其分解过程如图 1 所示。




图 1 小波包分解示意图

2.2 流型特征提取的小波包方法

实验系统介绍及数据的采集方法见文献[4]。压差波动信号由具有高频响应 ($> 1 \text{ kHz}$)、较高精度 (0.3%) 的压阻式差压变送器测量, 采样频率为 512 Hz, 采样点数为 2048 点。实验参数范围: 表观液速为 $0 \sim 4.5 \text{ m/s}$, 表观气速为 $0 \sim 25 \text{ m/s}$ 。压差波动信号含有不同流型的丰富信息, 流型改变时, 会使某些频带内的信号能量减小, 另外一些频带内信号能量增大。因此, 在各频率成份信号能量中, 包含了丰富的流型信息, 某种或某几种频率成份能量的改变即代表了一种流型向另一种流型的转变。

从上面的分析可知, 压差波动信号的各频率成份能量的变化代表了两相流系统流型的转变。基于这一点, 根据压差波动信号各频率成份能量进行流型识别。

由于小波包分解具有多分辨的特点, 利用它将压差波动信号进行 4 层小波包分解, 以获得压差波动信号在不同频带内的能量, 其分解结构如图 2 所示。其中, (i, j) 表示第 i 层的第 j 个结点, 其中, $i = 0, 1, 2, 3, 4; j = 0, 1, \dots, 15$, 每个结点都代表一定的信号特征, $(0, 0)$ 结点代表原始信号 S 。




图 2 小波包 4 层分解树结构

由小波包分解提取压差波动信号的具体算法如下:

(1) 首先对压差波动信号进行 4 层小波包分解, 分别提取第四层从低频到高频 16 个频率成份的信号能量特征。

(2) 对小波包分解系数进行重构, 提取各频带范围的信号。以 S_{40} 表示 X_{40} 的重构信号, 其它依次类推。在这里, 只对第四层的所有结点进行分析, 则总信号可以表示为:

$$S = S_{40} + S_{41} + \dots + S_{414} + S_{415} \quad (5)$$

假设原始信号 S 中, 最低频率成份为 0, 最高频率成份为 256, 则提取的 $S_{4j} (j = 0, 1, \dots, 15)$ 16 个频率成份所代表的频率范围见表 1。

表 1 各重构信号所代表的频率范围

信号	频率范围 / Hz	信号	频率范围 / Hz
S_{40}	0 ~ 16	S_{41}	16 ~ 32
S_{42}	32 ~ 48	S_{43}	48 ~ 64
S_{44}	64 ~ 80	S_{45}	80 ~ 96
S_{46}	96 ~ 112	S_{47}	112 ~ 128
S_{48}	128 ~ 144	S_{49}	144 ~ 160
S_{410}	160 ~ 176	S_{411}	176 ~ 192
S_{412}	192 ~ 208	S_{413}	208 ~ 224
S_{414}	224 ~ 240	S_{415}	240 ~ 256

(3) 求各频带信号的总能量。设 S_{4j} 对应的能量为 $E_{4j} (j = 0, 1, \dots, 15)$, 则有:

$$E_{4j} = \int |S_{4j}(t)|^2 dt = \sum_{k=1}^n |x_{jk}|^2 \quad (6)$$

其中: $x_{jk} (j = 0, 1, \dots, 15, k = 0, 1, \dots, n)$ 表示重构信号 S_{4j} 的离散点的幅值。

(4) 以能量为元素构造特征向量。特征向量 T 构造如下:

$$T = [E_{40}, E_{41}, \dots, E_{414}, E_{415}] \quad (7)$$

E_{4j} 通常是一个较大的数值, 为避免在数据分析上带来不便, 对特征向量进行归一化处理, 令:

$$E = \left(\sum_{j=0}^{15} |E_{4j}|^2 \right)^{1/2} \quad (8)$$

$$T' = [E_{40}/E, E_{41}/E, \dots, E_{415}/E] \quad (9)$$

向量 T' 即为归一化后的向量。

3 基于 Kohonen 神经网络的流型识别方法

自组织神经网络是由芬兰赫尔辛基大学 Kohonen 教授提出的一种模拟大脑神经系统自组织特征的竞争式学习网络, 它能将任意维输入模式在输出层映射成一维或二维离散图形, 从而将分类结果显示出来。Kohonen 神经网络只有输入和输出两层, 其输出节点按二维点阵排列, 如图 3 所示。关于 Kohonen 神经网络的详细阐述见文献[5]。




图 3 Kohonen 网络结构

输入层神经元个数为 n , 竞争层由 $m \times m$ 个神经元组成, 且构成一个二维平面阵列。输入层和竞争层实行全互连接。设网络由 q 个输入模式: $P_k = (p_1^k, p_2^k, \dots, p_n^k), k = 1, 2, \dots, q$ 。竞争层神经元矢量为 $A_j = (\alpha_{j1}, \alpha_{j2}, \dots, \alpha_{jm}), j = 1, 2, \dots, m$ 。竞争层神经元 j 与输入层神经元之间的连接权矢量为 $W_j = (w_{j1}, w_{j2}, \dots, w_{jn})$, 网络的学习和工作过程满足如下规则:

(1) 将网络的连接权 $\{W_{ij}\}$ 赋予 $[0, 1]$ 之间的随机数。确定学习率 $\eta(t)$ 的初值 $\eta(0)$, 一般 $0 < \eta(0) < 1$ 。确定邻域 $N_g(t)$ 的初值 $N_g(0)$, 确定总学习次数 T 。

(2) 任选 q 个模式中的一个模式 p_k 提供给网络输入层。

(3) 对连接权矢量 $W_j = (w_{j1}, w_{j2}, \dots, w_{jn})$ 进行归一化处理, 计算 \overline{W}_j 与 p_k 的欧氏距离:

$$\overline{W}_j = \frac{W_j}{\|W_j\|} =$$

$$\frac{(w_{j1}, w_{j2}, \dots, w_{jn})}{[(w_{j1})^2 + (w_{j2})^2 + \dots + (w_{jn})^2]^{1/2}} \quad (10)$$

$$d_j = \left[\sum_i (p_i^k - w_{ji})^2 \right]^{1/2}, j = 1, 2, \dots, m \quad (11)$$

(4) 求出最小距离 d_g , 确定获胜神经元 g :

$$d_g = \min[d_j], j = 1, 2, \dots, m \quad (12)$$

(5) 调整邻域内的连接权:

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(d_j) \eta(t) [p_i^k - w_{ji}(t)], j \in N_g(t) \quad (13)$$

其中: t —训练次数; $\alpha(d_j)$ —距离 d_j 的函数; $\alpha(d_j) = e^{-\lambda(d_j/m)^2}$; λ —取 $0.3 \sim 10$; $N_g(t)$ —邻域; $\eta(t)$ —学习率。

(6) 选取另一个学习模式提供给网络输入层, 返回第二步骤, 直至 q 个学习模式全部训练完。

Kohonen 网络训练结束后, 只要把被识别流型的输入模式提供给网络输入层, 按照上述规则予以计算, 竞争层的某一神经元 (获胜神经元) 就会兴奋起来, 从而判断所属流型类别。

4 Kohonen 网络识别流型的实例

Kohonen 神经网络的最大特点是一种无需监督的自组织学习, 标准样本待检测模式的同时在输入层进行计算, 最后在竞争层以二维分布的图形化方式显示分类结果。随着样本个数的增多, Kohonen 网络不断地调节其连接权值, 识别能力将日趋增强。Kohonen 网络在克服病态样本和计算量方面均优于传统的 BP 神经网络。




图 4 流型的识别结果

Kohonen 神经网络进行流型识别的实质就是完成特征向量到流型类别的非线性映射, 选择 Kohonen 网络的输入层由 16 个神经元组成, 竞争层由共 64 个神经元组成, 将提取的小波包能量特征输入到该网络中进行训练, 经过反复调整权值, 训练结

束后在竞争层出现识别的结果, 如图 4(a) 所示。图中 I 为间歇流 (Intermitting Flow), B 为泡状流 (Bubbly Flow), A 为环状流 (Annular Flow), S 为分层流 (Stratified Flow)。

再将一组待识别流型的特征向量输入到已训练好的 Kohonen 网络中, 在竞争层中出现图 4(b) 所示的识别结果。待识别流型特征向量 X 与泡状流样本的欧氏距离最小时, 识别结果为泡状流。实际流型也是泡状流。

以实验工况中的 211 个样本作为训练样本, 网络训练完毕后, 再另外选取 180 组数据 (分层流和泡状流各 30 组、环状流 40 组和间歇流 80 组) 作为测试样本进行仿真, 结果表明: 网络正确识别样本数为

166 例, 误识别样本数为 14 个 (其中间歇流为 8 个, 其它 3 种流型各 2 个), 整体识别率达到 92.2%, 表 2 给出了部分样本的特征值数据和识别结果。

流型误识别的主要原因分析如下: 首先, 间歇流对应的流型参数范围非常广, 易与其它流型产生交叉重叠, 所以在误识别的 14 个流型中有 8 个为间歇流流型; 其次, 训练样本数目的多少也是影响误识别的一个因素, 增加样本数能改善网络的误识别; 最后, 实验过程中各种误差引起的实验数据偏差也直接影响网络的正确分类。综上所述, 网络不可避免地要产生一定的误识别, 不过, 网络 92.2% 的识别率也能够满足工程实际的要求。

表 2 样本数据及识别结果

小波包能量特征																网络识别	实际流型
1~16 / Hz	16~32 / Hz	32~48 / Hz	48~64 / Hz	64~80 / Hz	80~96 / Hz	96~112 / Hz	112~128 / Hz	128~144 / Hz	144~160 / Hz	160~176 / Hz	176~192 / Hz	192~208 / Hz	208~224 / Hz	224~240 / Hz	240~256 / Hz		
0.85584	0.03624	0.01783	0.01188	0.00948	0.00798	0.00485	0.00839	0.00691	0.00651	0.00433	0.00620	0.00479	0.00772	0.00395	0.00707	<i>S</i>	<i>S</i>
0.89827	0.01098	0.00655	0.00608	0.00611	0.00684	0.00425	0.00623	0.00737	0.01013	0.00617	0.00909	0.00507	0.00586	0.00451	0.00647	<i>S</i>	<i>A</i>
0.88507	0.02539	0.01196	0.00906	0.00721	0.00609	0.00508	0.00613	0.00523	0.00540	0.00630	0.00654	0.00451	0.00483	0.00492	0.00559	<i>A</i>	<i>A</i>
0.88821	0.02388	0.01124	0.00934	0.00675	0.00638	0.00485	0.00636	0.00533	0.00500	0.00620	0.00668	0.00438	0.00487	0.00474	0.00571	<i>A</i>	<i>A</i>
0.89808	0.01178	0.00638	0.00572	0.00616	0.00907	0.00897	0.00878	0.00898	0.00686	0.00523	0.00899	0.00563	0.00773	0.00383	0.00774	<i>I</i>	<i>I</i>
0.89902	0.01322	0.00876	0.00767	0.00620	0.00621	0.00501	0.00687	0.00501	0.00880	0.00899	0.00849	0.00518	0.00588	0.00384	0.00574	<i>I</i>	<i>A</i>
0.89643	0.01390	0.00759	0.00613	0.00604	0.00627	0.00441	0.00578	0.00882	0.01070	0.00498	0.00731	0.00573	0.00617	0.00387	0.00581	<i>I</i>	<i>I</i>
0.92185	0.01823	0.00836	0.00711	0.00409	0.00421	0.00815	0.00898	0.00427	0.00444	0.00837	0.00429	0.00281	0.00309	0.00304	0.00308	<i>B</i>	<i>B</i>
0.91734	0.01960	0.01004	0.00798	0.00522	0.00440	0.00802	0.00450	0.00446	0.00404	0.00825	0.00397	0.00304	0.00305	0.00291	0.00313	<i>B</i>	<i>B</i>

注: S 为分层流; A 为环状流; I 为间歇流; B 为泡状流。黑体显示样本为误识别样本。

新的有效的技术选择。

5 结 论

流型识别是两相流中重要的研究课题, 本文结合小波包分解和 Kohonen 神经网络提出一种新的流型识别方法。首先利用小波包分解对压差信号进行精细的划分, 提取流型动态信号的能量特征信息; 然后将这些信息输入 Kohonen 神经网络进行流型识别。这种方法既克服传统识别方法具有主观性的缺点, 又无须建立压差波动信号的数学模型, 能快速、准确地进行流型识别。实验结果说明了该方法的正确性和有效性, 为流型的客观在线识别提供了一种

参考文献:

[1] 贺银芝, 沈 松, 应怀樵, 等. 小波包分解及其能量谱在发动机连杆轴承故障诊断中的应用[J]. 振动工程学报, 2001, 14(1): 72-75.

[2] 王妍, 林宗虎. 改进 BP 神经网络在流型判别中的应用[J]. 热能动力工程, 2001, 16(1): 63-65.

[3] 崔锦泰, 程正兴. 小波分析导论[M]. 西安: 西安交通大学出版社, 1997.

[4] 孙 斌. 水平管气液两相流型压差波动的统计特性[D]. 吉林: 东北电力学院, 2002.

[5] 焦李成. 神经网络系统理论[M]. 西安: 西安电子科技大学出版社, 1990.

Condenser [刊, 汉] / FENG Ming-jie, CHEN Wen-zhong (Institute of Materials and Metallurgy under the Northeastern University, Shenyang, China, Post Code: 110006) // Journal of Engineering for Thermal Energy & Power. — 2005, 20(1). — 45 ~ 47, 60

By adopting a form of condensate return flow an inclined reciprocating condenser completes its steam condensation process. On the basis of tests and by using a two-phase fluid analytical model set up was a flow analysis model for steam-condensate return flow in a reciprocating condenser. A corresponding Matlab computation program was prepared and developed. Moreover, on the basis of the condition of initial values measured and obtained from the tests a numerical simulation was conducted of the relevant flow field along with an analysis of the computation results. The results of the analysis indicate that the share occupied by the cross-section steam phase gradually increases along the tube length direction. Steam-liquid two-phase flow speed decreases gradually along the tube length direction. Under an identical pressure when inclination angle β equals 90° , a liquid film will have the thinnest value, and the variation of the two-phase flow speed along the tube length becomes very conspicuous. With the inclination angle β being 90° the liquid film thickness will gradually decrease with a decrease in pressure. **Key words:** reciprocating condenser, condensate return flow, flow field

基于小波包分解和 Kohonen 神经网络的气液两相流流型识别方法 = **A Method for Identifying Gas-liquid Two-phase Flow Patterns on the Basis of a Wavelet Packet Decomposition and Kohonen Neural Network** [刊, 汉] / SUN Bin (Power Engineering Department, North China University of Electric Power, Baoding, China, Post Code: 071003), ZHOU Yun-long, ZHANG Ling, et al (Power Engineering Department, Northeastern Institute of Electric Power, Jilin, China, Post Code: 132012) // Journal of Engineering for Thermal Energy & Power. — 2005, 20(1). — 48 ~ 51

The traditional method of flow pattern identification suffers from the deficiency of a high subjectivity and BP neural network training is relatively seriously affected by a sickly sample. In view of the above, the authors have, on the basis of the fact that the transformation of a wavelet packet can decompose signals according to arbitrary time-frequency resolution rate into characteristics of different frequency sections, proposed a new method for identifying gas-liquid two-phase flow patterns. Firstly, the method analyzes the dynamic pressure-difference fluctuation signals of a flow pattern by utilizing wavelet packet decomposition and extracts the characteristics. Then, by combining wavelet-packet energy specific features with Kohonen neural network, flow pattern identification can be performed. The successful identification of four typical flow patterns of air-water two-phase flow in a horizontal pipe has shown that the recommended method can effectively overcome the above-mentioned deficiency of the traditional identification method, thus providing a new and highly effective technical alternative for the on-line identification of flow patterns. **Key words:** flow pattern identification, wavelet packet decomposition, neural network, pressure-difference fluctuation

热电(冷)联产系统的优化性能 * = **Optimized Performance of a Combined Heat and Electric Power (Cooling) System** [刊, 汉] / ZHANG Xiao-hui, YANG Mo (College of Power Engineering under the Shanghai University of Science & Technology, Shanghai, China, Post Code: 200093) // Journal of Engineering for Thermal Energy & Power. — 2005, 20(1). — 52 ~ 56

On the basis of a finite-time thermodynamics theory a basic optimization relationship is derived when an irreversible combined heat and electric power system as well as a combined heat and electric power (cooling) system have both attained a maximum system output. The scope of selecting optimized parameters and optimized configuration has been determined for the combined heat, electric power (cooling) system. Characteristics of optimized matching of heat supply (refrigeration) and electric power generation have also been obtained. Through numerical calculation examples identified was the