

研究简报

基于反传神经网络和压差波动识别气液两相流流型\*

白博峰 郭烈锦 陈学俊

(西安交通大学动力工程多相流国家重点实验室, 西安 710049)

关键词 反传神经网络 气液两相流 流型 识别 压差  
中图分类号 TQ 021.1

引 言

研究气液两相流流型自动与客观识别具有重要的工程应用价值, 可为相关工业中两相流动自动监测与控制提供技术保障. 因此, 该课题一直受学术界和工业界的重视. 近年来, 随着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<sup>[1]</sup>.

目前有关流型的神经网络模式识别的研究工作正在进行. Embrechts 等<sup>[2]</sup>采用 Kohonen 神经网络模型, 分别将压差波动信号的短时 Fourier 谱和正交小波变换后的小波系数作为网络的输入特征, 对水平管内的两相流流型进行识别. 结果发现 Fourier 谱作为输入特征参数能够识别水平管内的所有流型, 但作者没有用大量样本考验网络的识别率. Mi 等人<sup>[3]</sup>利用 Kohonen 网络和含气率的波动信号识别了管内气液两相流型, 作者将流型过渡区作为单独待识别的流型. Monji 和 Matsui<sup>[4]</sup>采用一层和两层前向网络, 将含气率波动过程的均方根、3 阶矩和 4 阶矩作为网络的输入特征, 网络的识别率可达 91%, 出现误识别的样本多数位于流型转变区. 这种方法需要建立有关流型特征的数据库, 并且对不同应用场合, 需要重新建立或补充大量的相关数据.

本文将从反传神经网络 (Counter Propagation Network, CPN) 的结构及其特点出发, 分析如何根据压差波动过程自动和客观识别流型, 考察流型自动和在线识别的指标, 讨论该方法的优缺点.

1 反传神经网络的基本原理

CPN 由两层网络组成<sup>[5]</sup>. 第 1 层是 Kohonen 自组织特征映射层, 第 2 层是 Grossberg 的外星结构, 它对 Kohonen 层提取的模式特征信息采用有指导的训练算法来实现输入模式的分类. 图 1 为 CPN 模型, 输入层节点数为  $l$ , Kohonen 层有  $n$  个节点, Crossberg 层有  $m$  个节点.




Fig. 1 Structure of Counter Propagation Network

1.1 Kohonen 层自组织映射算法

Kohonen 层按照自组织原理实现输入模式样本在网络输出端的特征映射, 它的学习算法是基于非监督训练技术. 算法如下:

- (1) 初始化权值  $w_{ji}(t)$  为一个小的随机量 ( $j = 1, \dots, n; i = 1, \dots, l$ );
- (2) 加入输入  $x(t) = [x_0(t), x_1(t), \dots, x_{N-1}(t)]$ ,  $x_i(t)$  为在时刻  $t$  对节点  $i$  的输入;
- (3) 计算输入与任何输出节点  $j$  之间的距离  $d_j$

$$d_j = \sum_{i=0}^{N-1} [x_i(t) - w_{ji}(t)]^2 \quad (1)$$

- (4) 选择最小距离  $d_{\min}$  所对应的输出节点  $j^*$ ;
- (5) 调整权值 调整节点  $j^*$  和由其邻域  $NE_{j^*}(t)$  定义的节点的权值, 新的权值为

$$w_{ji}(t+1) = w_{ji}(t) + a(t)[x_i(t) - w_{ji}(t)] \quad (2)$$

- (6) 转 (2), 继续按 Kohonen 自组织特征映射学

1999 - 12 - 28 收到初稿, 2000 - 04 - 28 收到修改稿.

联系人及第一作者: 白博峰, 男, 28 岁, 博士.

\* 国家杰出青年科学基金 (No. 59725616) 和国家重点基础研究发展纲要 G1999022308 联合资助项目.

习算法进行学习和修正,一直进行到该节点所对应的邻域收缩到只有一个节点为止.将信息前馈至 Grossberg 层.

讨论与说明:

(1) 这里的时间可以理解为计算过程中的迭代次数,迭代计算时的样本维持不变;邻域  $NE_j^*(t)$  定义为输出节点  $j^*$  周围范围的大小,目前邻域的选择尚无数学方法,凭经验确定.

(2)  $a(t)$  开始时下降速度较大,然后在较小的基值上缓慢降至 0 值.这样可以精细地调整权值使之符合输入空间的概率分布结构.可选用  $a(t) = 0.4(1 - t/1000)$ .

(3) 权值  $w_{ji}$  归一化为固定长度,这样可以加快训练速度

$$w_{ji} = \frac{w_{ji}}{\left(\sum_i w_{ji}^2\right)^{1/2}} \quad (3)$$

(4) 分类精度可以由增加训练次数来提高.Kohonen<sup>[6]</sup>推荐训练循环的次数应至少在 500 × 输出神经元的个数以上才能获得较好的统计精度.

(5) 对不同的样本,权值  $w_{ji}$  都不相同,但都重新经历上述的聚类过程.

### 1.2 Grossberg 层有导师训练算法

假设 Kohonen 层输出为  $z_1, z_2, \dots, z_n$ , 则 Grossberg 层的第  $k$  个单元  $y_k$  的输出为

$$y_k = \sum_{j=1}^n v_{kj} z_j \quad k = 1, 2, \dots, n \quad (4)$$

式中  $v_{kj}$  为 Grossberg 层中的连接权值.假设使用  $M$  个输入模式  $x_m (m = 1, 2, \dots, M)$  来训练反神经网络,每个模式在 Grossberg 层输出端对应的期望信号为  $d_m (m = 1, 2, \dots, M)$ , 定义如下目标函数(误差代价函数)

$$E = \sum_{m=1}^M \sum_{k=1}^n (d_{mk} - v_{kj}^*)^2 \quad (5)$$

Grossberg 层连接权值的修正规则如下

$$v_{kj}^*(t+1) = v_{kj}^*(t) + \sum_{m=1}^M [d_{mk}(t) - v_{kj}^*(t)] \quad k = 1, 2, \dots, n; j^* = 1, 2, \dots, n \quad (6)$$

上式中  $0 < \alpha < 1$  为权值修正系数,或称学习系数.

经过充分训练后,最终得到固定的权值  $v_{kj}$ .只要对网络输入矢量  $x$ , 则 Kohonen 层产生中间输出,经过竞争后得到获胜节点,然后对获胜节点引用 Grossberg 外层规则使信息前送,就可在输出端得到输出矢量  $y$ .

## 2 流型的实验观察和压差波动测量

实验在空气-水两相流系统下进行,采用 U 形管的垂直上升段为实验段,流型由肉眼观察结合信号的特征来判断.压差波动采用 0.1 级精度、固有频率 5 Hz 的电容式压差变送器测量.压差波动的采样率  $250 \text{ samples s}^{-1}$ .实验共观察到了 4 种流型:泡状流,塞状流,块状流和环状流.当  $U_{LS}$  很小时 ( $0.54 \text{ m s}^{-1}$ ),塞状流包括有球帽形大气泡的塞状流和有 Taylor 气泡的塞状流两种<sup>[7]</sup>.工程上常常把塞状流和块状流统称为间歇流.  $U_{LS} = 0.54 \text{ m s}^{-1}$  下,一组典型流型的压差波动过程及其傅氏变换(FFT)结果分别见图 2 和图 3.




Fig. 2 A set of typical time traces of differential pressure fluctuation for all flow regimes

- UGs/  $\text{m s}^{-1}$ : 1—0.006 (B F);
- 2—0.016 (plug flow with cap bubble);
- 3—0.106 (plug flow with Taylor bubble);
- 4—0.814 (C F); 5—2.530 (A F)

对泡状流,压差波动幅度很小,但波动频率范围较宽;对有球盖形气泡的塞状流,波动过程的周期性成分增加,波动能量与泡状流类似;对有大气泡的塞状流,波动幅度增加,并且波动的周期性十分明显,波动的频率范围变小,在  $0 \sim 1 \text{ Hz}$  之间;对块状流,波动幅度很大;对环状流,波动能量和频率分布范围增加.以上所有流型,难以根据压差的波动曲线或 FFT 变换由人来明确判别,但可以看出压差波动的频谱分布特性与流型有密切的关系.




Fig. 3 FFT of differential pressure fluctuation

### 3 流型的客观和人工智能识别

#### 3.1 流型的自组织客观分类

采用压差波动过程的特征输入 CPN 网络的 Kohonen 层, 通过运算将它们归类为出现概率最大的那类模式, 因此能够对流型实现客观分类. 输入层采用压差波动过程的快速 FFT 谱作为网络的模式输入样本, 压差波动序列长度为 512 点, 时间历程 8.192s, 短时 FFT 谱的长度为 41 点, 频率范围 0~5Hz. 采用 FFT 谱较原始波动序列的优点在于两方面: 更好的特征描述和降低了模式空间的维数. 在样本输入网络之前作如下预处理: 去均值, 归一化. 尽管归一化去掉了幅值信息, 但对算法的收敛速度很有益, 此外, 非归一化在本研究中并没有提高流型聚类的正确率.

首先以  $0.54 \text{ m} \cdot \text{s}^{-1}$  表观液速的 27 个工况为例, 考察输出层不同的神经元数目对流型聚类结果的影响. 输出层神经元数目分别取 8, 计算结果见图 4. 图中  $x$  轴为输出层的神经元节点分布,  $y$  轴为神经元的兴奋状态, 当  $y$  轴的值接近 1 时表明该神经元处于兴奋状态.

由上图可知, 泡状流聚类到节点 7, 塞状流 (包括有球盖形大气泡和 Taylor 气泡两种) 和块状流聚类到节点 8, 环状流被聚类到节点 2 和节点 6. 其中一个塞状流工况被错误地聚类到节点 6. 聚类到节点 6 的环状流所对应的折算气速较聚类到节点

2 的低, 流型的识别率为 96.3%.

输出层神经元数目对聚类有较大影响, 取 4 个神经元的聚类正确率为 96.3%, 而当输出层有 12 个神经元时, 网络将所有流型聚类到两个神经元节点. 此结果说明 SOM 模型的聚类效果同输出层神经元数目的多少有关, 增加神经元数目对提高聚类效果的益处不大.

下面考察表观液速对流型识别的影响. 除上面的  $0.54 \text{ m} \cdot \text{s}^{-1}$  算例外, 增加  $1.00 \text{ m} \cdot \text{s}^{-1}$  和  $1.54 \text{ m} \cdot \text{s}^{-1}$  的实验数据. 对  $U_{LS} = 1.00 \text{ m} \cdot \text{s}^{-1}$  的 24 个工况, 流型的识别率为 91.7%. 对  $U_{LS} = 1.54 \text{ m} \cdot \text{s}^{-1}$  的 19 个工况, 流型的识别率为 94.7%. 不同流型的聚类位置见表 1.

Table 1 Effect of superficial liquid velocity on clustering results with Kohonen self-organizing of map

Flow regime	$U_{LS}/\text{m} \cdot \text{s}^{-1}$		
	0.54	1.00	1.54
bubble flow	7	3	3
intermittent flow	8	8	8
annular flow	6, 2	2	2

以上算例证明, 表观液速对流型自组织 Kohonen 网络聚类特性有一定的影响, 其中对泡状流的影响最大. 当表观液速高时, 不同液速的相同流型都聚类到相同的神经元节点; 但是当表观液速较低时, 泡状流被聚类到其他节点, 并且此时环状流的聚类中心也不唯一, 因此对低液速的流动仍需要实验进行补充.

#### 3.2 流型的自动识别

由于 Kohonen 层自组织映射结果只能对压差波动过程客观地按流型进行分类, 如果仅仅采用 Kohonen 自组织映射图来识别流型, 竞争获胜的神经元属于何种流型仍需要人的先验知识来判断, 采用 CPN 网络后这个工作可以通过有导师的网络训练来自动实现, 这就是 Grossberg 层要完成的工作. 在 Grossberg 层取 3 个节点, 这 3 个节点 (100)、(010)、(001) 分别对应泡状流、间歇流和环状流. 通过网络训练获得稳定的权值  $v_{kj}$ , 然后就可以利用 CPN 网络根据压差波动的 FFT 自动完成流型的客观和自动识别. 对本文所采用实验结果, CPN 的流型识别率非常高, 等同于 Kohonen 层聚类的正确率.

## 4 结 论

压差波动过程及其 FFT 变换谱都和流型有

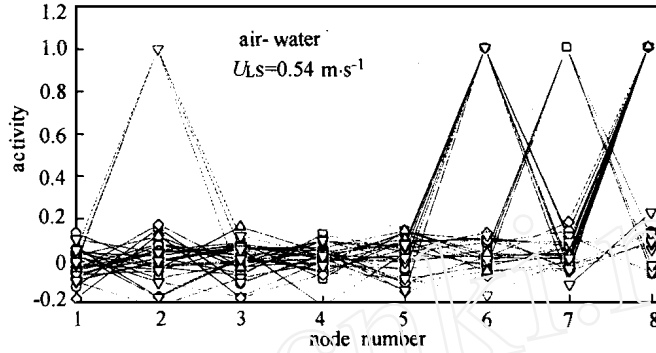


Fig. 4 Results of clustering self - organizing of mapping

0.004 BF, 0.006 BF, 0.011 BF; 0.014 CB, 0.016 CB, 0.017 CB, 0.020 CB, 0.022 CB, 0.035 CB;  
 0.071 TB, 0.106 TB, 0.145 TB, 0.174 TB, 0.219 TB, 0.248 TB, 0.283 TB; 0.349 CF, 0.814 CF,  
 1.514 CF; ▽ 2.045 AF, 2.530 AF, 2.949 AF, 4.177 AF, 5.206AF; ▽ 6.707 AF, 10.22 AF, 12.67AF

密切的关系,但直接根据这些变化轨迹很难准确和有效地识别流型.基于压差波动过程的 FFT 变换谱,本文采用反神经网络,为流型的客观和自动识别提供了一种技术选择.

表观液速较小时对本方法的识别有一定影响,仍需进一步的实验补充和研究.对文中实验工况,所有液速的流型识别率都高于 90%.

符号说明

- AF —— 环状流型
- BF —— 泡状流型
- CB —— 有球盖形气泡的塞状流型
- CF —— 块状流型
- $d_m$  —— 第  $m$  模式在 Grossberg 层的期望输出向量
- $E$  —— 误差代价函数
- TB —— 有 Taylor 气泡的塞状流型
- $U_{GS}$  —— 表观气速,  $m \cdot s^{-1}$
- $U_{LS}$  —— 表观液速,  $m \cdot s^{-1}$
- $v_{kj}$  —— Grossberg 层第  $k$  节点与 Kohonen 输出层第  $j$  节点之间的权值
- $w_{ji}$  —— Kohonen 输出层第  $j$  节点与输入层第  $i$  节点之间的权值

- $x$  —— 网络输入(样本)向量
- $y$  —— Grossberg 层输出向量
- $z$  —— Kohonen 层输出向量
- 权值  $w_{ji}$  的修正系数
- 权值  $v_{kj}$  的修正系数

References

- 1 Bai Bofeng(白博峰), Guo Liejin(郭烈锦), Zhao Liang(赵亮). Journal of Chemical Industry and Engineering (China)(化工学报), 1999, 50(6): 799—805
- 2 Embrechts M J, Lahey R T, Yapo T. Proc. of the American Power Conference. New York: Hemisphere Publishing, 1996. 860—864
- 3 Mi Y, Ishii M, Tsoukalas L H. Nuclear Engineering and Design, 1998, 184: 409—420
- 4 Monji H, Matsui G. In: Third International Conference on Multiphase Flow. Lyon, 1998
- 5 Huang Deshuang(黄德双). Theory of Neural Network Pattern Recognition(神经网络模式识别理论). Beijing: Electrical Industry Publisher, 1996
- 6 Kohonen T. Proceedings of the IEEE, 1990, 78(9): 1464—1480
- 7 Bai Bofeng, Wu Tiejun, Guo Liejin. In: 4th International Symposium on Multiphase Flow and Heat Transfer. Xi an: Xi an Jiaotong University Press, 1999. 187—194

## RECOGNITION OF GAS - LIQUID TWO - PHASE FLOW REGIME BASED ON THE COUNTER PROPAGATION NETWORK AND DIFFERENTIAL PRESSURE FLUCTUATION

Bai Bofeng<sup>\*</sup>, Guo Liejin and Chen Xuejun

(State Key Lab of Multiphase Flow in Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract** The histories of differential pressure fluctuations and their Fast Fourier Transform spectrum have close relation with the flow regimes. Unfortunately, each type of flow regime is very difficult or impossible to be distinguished from the other on the basis of the fluctuations or the spectrum. The present paper provides a feasible solution, which the gas - liquid two - phase flow regimes can be recognized automatically and objectively on the basis of the combination of the Counter Propagation Network (CPN) and the FFT spectrum of the differential pressure fluctuations. The CPN takes advantages of simpler algorithm and fast training processes. Furthermore, it does not require a great deal of samples. The recognition possibility is determined by the clustering results of the Kohonen layer in the CPN. With the presented test cases, the possibility can be higher than 90 percent for different liquid phase velocity.

**Key words** counter propagation network, gas - liquid two - phase flow, flow regime, recognition, differential pressure fluctuation

---

\* To whom correspondence should be addressed.