

文章编号:0258-8013 (2001) 07-0046-05

气液两相流流型在线智能识别

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, 陕西 西安 710049)

THE TECHNOLOGY AND THEORY OF ONLINE RECOGNITION OF GAS-LIQUID TWO-PHASE FLOW REGIME

BAI Bo-feng, GUO Lie-jin, CHEN Xue-jun

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

ABSTRACT: It has important industrial background and scientific significance to study the online recognition of gas-liquid two-phase flow regime. The key problem of the online recognition is how to map to the space of flow regimes from the space of character of the parameter fluctuations with the shortest time. Counter propagation network (CPN) can train the results of self-organizes mapping with supervising. At the same time, it takes advantage of simple algorithm and doesn't require lots of training samples. Therefore, it meets the online and automatic recognition of gas-liquid two-phase flow regimes. In the present test case, the online criterion was 8.2s with the FFT of pressure fluctuations from the vertical upward section of the U-type tube. The presented technology and theory has some obvious advantages, which provides a feasible solution of online recognition without databank of flow regime and can overcome partially the problems induced by not enough experiments in advance. In addition, the problems to shorten the identification time and to increase the identifying possibility are discussed in the paper.

KEY WORDS: gas-liquid two-phase flow; flow regime; online recognition; neural network

摘要: 在线识别的关键问题在于如何利用最短时间历程的参数波动过程完成由参数波动的特征空间到流型空间的映射。CPN 神经网络能够对自组织映射的结果进行有导师的训练, 因此可以为流型的自动、客观和在线识别提供有效的手段。文中结合压力波动过程的快速傅立叶变换系数, 对 U 形管垂直上升段内空气-水两相流的流型进行自动识别, 在

线性指标达到了 8.2s。对如何提高流型快速识别的在线性指标和识别率等作了相关的探讨。

关键词: 气液两相流; 流型; 在线识别; 神经网络

中图分类号: TK31 **文献标识码:** A

1 引言

多相流流型及其变化对石油天然气钻采与储运过程中工业设备运行的效率、安全可靠性等起着至关重要的作用。此外, 多相流流量计量的准确性与流动结构状态密切相关, Thron 等人^[1]研究后认为解决流动结构的变化对测量结果的影响是解决目前流量计精度偏低的重要途径。因此, 研究多相流流型识别有着极其重要的意义。

目前对管道内气液两相流的流型判断或识别主要有两种途径, 一种是采用观察或测量的方法, 另一种是利用现场的流动参数根据流型转变准则或流型图判断流型。二者都具有一定的主观性, 并且都很难实现流型的在线识别。采用神经网络理论识别流型主要有 3 个步骤^[2, 3]: 信息获取, 根据测量的难易程度和代价选择能够反映流动结构变化的信号, 如压力、压差或压降、含气率等; 特征提取, 从特征信号中提取出不同流型的特征, 信号处理是特征提取最常用的方法; 执行某种运算完成由特征空间到流型类别空间的映射。流型的在线自动识别包括 2 个必须具备的条件: 流型信息的快速获得; 流型判别的快速实现。前者又包含 2 个层次, 即两相流参数的采集时间尽量短以及参数的分析过程尽量简单, 以便在很短的时间内获得参数的内在特征。对后者要求神经网络计算简单有效。

基金项目: 国家重点基础研究发展纲要资助项目 (G1999022308); 国家 863 海洋高技术资助项目 (820-01)。

Project Supported by Foundation of the National Program for Priority Basic Research's Development (G1999022308); The National High Technology Research and Development of China (863 Program) (820-01)。

压力/压差、含气率的波动在一定程度上都能够反映流型及其变化。其中压力/压差的测量最经济可靠,而含气率与流型最直接,但测量设备复杂。随着含气率测量技术的进步,使其测量的代价降低。对垂直上升管,可以用无量纲的压差波动过程近似含气率的波动^[4],但这种近似方法不能应用到水平流动系统。本文采用空气-水两相流系统,研究了如何根据壁面静压力波动过程识别流型的问题,并对如何提高流型快速识别的在线性指标和识别率等作了一些研究和探讨。

2 反传网络无指导-有指导模式分类器

反传网络^[5] Counter Propagation Networks,简称 CPN) 模式分类器由 2 层网络组成,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。

Kohonen 层完全按照自组织原理,来实现输入模式样本在网络输出端的特征映射,可用于特征提取和模式识别等。它的学习算法是建立在一个非监督训练技术的基础上。一旦被训练,从一个给定类中选一个输入矢量应用到网络上,它将在每个神经元产生一个兴奋水平,具有最大兴奋水平的那个神经元就表示了该输入矢量的特征。对于相近的输入,它们的输出响应节点在输出平面上和在拓扑意义下也是相近的,因此 Kohonen 层对输入数据有聚类 and 特征提取的作用。

Grossberg 层的有导师训练算法按修正规则进行。

3 流型的实验观察和信号测量

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,流型的判断结合肉眼观察和信号的特征来实现。壁面静压力用 0.3 级精度、固有频率高于 1 kHz 的压阻式压力变送器测量。在稳定流动条件下进行流型观察和压力波动信号的测量。信号的采样频率 250 Hz。共进行了 3 组实验。

实验参数:折算液速 U_{Ls} (0.54, 1.00, 1.54 m/s), 折算气速 (0~12 m/s)。实验中总共观察到了 4 种流型:泡状流(Bubble Flow),弹状流(Slug Flow),块状流(Churn Flow)和环状流(Annular Flow)。当折算液速很小时(0.54m/s),弹状流包括有球盖形大气

泡的弹状流(Cap Bubble Slug Flow)和有 Taylor 气泡的弹状流 2 种。为了叙述方便,上面各种流型用英文字母缩写:BF,CBSF,SF,CF,AF。

4 流型客观识别

流型的识别与划分必须建立在客观的基础上,因此这里首先研究流型的自动和客观的识别与划分问题。由于 CPN 网络的 Kohonen 层(SOM 模型)能够将输入信息按自组织映射原理实现自动聚类,因此可应用于流型的自动和客观识别,同时由于 SOM 在样本的学习过程中仅对优胜神经元的权值进行调整,而非优胜神经元的权值保持不变,因此学习过程十分简单,计算速度很快。满足引言中讨论的第 2 个条件。

SOM 输出层采用 8 个神经元节点,输入层采用时间历程 8.192 s 压力波动过程的快速傅立叶变换系数作为网络的模式输入样本,快速傅立叶变换系数的长度为 82 点,频率范围 0~10 Hz(频率范围的选取与波动过程的能量分布范围有关)。采用快速傅立叶变换系数较原始波动序列的优点在于两个方面,既更好的特征描述又降低了模式空间的维数。训练网络时,在样本输入网络之前作如下预处理:去均值,归一化。SOM 聚类的结果(即竞争学习的结果)见图 1、图 2 和图 3。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。




图 1 Kohonen 网络的聚类结果($U_{Ls} = 0.54 \text{ m/s}$)

Fig. 1 Clustering results of Kohonen self-organizing map($U_{Ls} = 0.54 \text{ m/s}$)

对折算液速为 0.54 m/s 的 27 个工况,SOM 能够很好地地将各个流型聚类到不同的神经元节点上。泡状流聚类在第 4 个神经元节点;有球盖形气泡的弹状流聚类在第 7 个神经元节点;有 Taylor 气泡的弹状流和块状流共同聚类在第 2 个神经元节点;环状流聚类在第 3 个神经元节点。在以下几种情况下发生聚类错误:临近泡状流与有球盖形气泡弹状

流的转变区时,有2个工况出现聚类错误;临近块状流-环状流转变区的一个环状流工况聚类到块状流区。若将弹状流与块状流统称为间歇流并当作一个流型处理^[6],则发生聚类错误的比例很小,总正确率为86.9%。若再考虑流型过度或转变非跳跃性,Kohonen网络聚类的优越性将十分突出。对块状流与有Taylor气泡弹状流聚类相同的结果,可作如下解释:在低折算液速下,由于实验段很短,弹状流中的Taylor气泡不能充分发展,因此压力波动的周期性不显著,与块状流的压力波动的差别不明显,主要差别在于块状流的傅氏变换系数相对大一些,但样本作归一化处理导致这种差别减小。

对折算液速为1.00m/s压力波动的聚类正确率为95.8%。对折算液速为1.54m/s压力波动的聚类正确率为100%。

比较图1、图2和图3可以得到折算液速对自组织Kohonen网络聚类特性的影响规律。对环状流和间歇流,不同折算液速下的Kohonen网络聚类结果相同,分别为第3和第2神经元兴奋;而对泡状流的影响较大,随折算液速的增加,竞争获胜的神经元节点分别是4、8、7,遗憾的是低折算液速所特有的含球盖形气泡弹状流所对应的获胜神经元节点也是7,与泡状流重合。上述结果同时证明了Kohonen自组织网络在相当大的范围内能够在不同流型的压力波动过程中映射到不同的聚类中心,并且随着折算液速的增加聚类正确率大大提高,在本实验范围内可达100%,因此该网络在流型自动识别中有着特殊的作用和意义。




图2 Kohonen网络的聚类结果($U_{LS} = 1.00$ m/s)

Fig.2 Clustering results of Kohonen self-organizing map ($U_{LS} = 1.00$ m/s)

以0.54 m/s折算液速的工况为例,考察输出层不同的神经元数目对流型聚类结果的影响,计算结果见图4。对有12个神经元的输出层,网络将所有流型聚类到2个神经元节点:间歇流(不含球盖形

气泡的弹状流)聚类到第2个神经元,其它流型聚类到第9个神经元节点,包括泡状流、环状流和有球盖形气泡的弹状流。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,可以使其等于或2倍于流型的种类数。




图3 Kohonen网络的聚类结果($U_{LS} = 1.54$ m/s)

Fig.3 Clustering results of Kohonen self-organizing map ($U_{LS} = 1.54$ m/s)




图4 输出层神经元节点数对聚类结果的影响($U_{LS} = 0.54$ m/s)

Fig.4 Effect of node number of the neural cell at output layer on the clustering results of Kohonen self-organizing map ($U_{LS} = 0.54$ m/s)

5 流型的在线自动识别

SOM能够迅速地将不同流型的压力波动聚类到不同的神经元上,并且正确率很高,基本能够满足工程要求,但是对聚类后的结果仍需要人的知识来判断所对应的是何种流型。此外流型的在线自动识别还要求波动序列的时间历程尽量短,自动判断不同聚类结果代表何种流型。本节采用CPN网络,着重解决这两个问题。

减少压力波动时间历程,取7.5s的压力波动序列,仍采用快速傅立叶变换系数作为SOM的输入,频率范围0~10Hz,SOM的输入层为82个节点,聚类神经元取8个。当折算液速较低时($U_{LS} = 0.54$ m/s),SOM可以部分地将各流型的压力波动聚类到不同的神经元节点,但总体准确率很低。当

折算液速增加后,各流型压力波动的聚类结果更差,所有流型的压力波动都被聚类到相同节点。进一步减少压力波动时间历程,取 4.096 s,快速傅立叶变换系数的长度为 82 点,频率范围不变,在 0~10 Hz。SOM 聚类结果进一步变差,对所有实验工况和不同的 SOM 结构,所有流型都被聚类到第 1 个神经元节点。




图 5 压力波动 FFT 变换

Fig. 5 The fast Fourier transform of the pressure fluctuations with different time history

果得知,如果采用时间历程为 8.192s 的压力波动的快速傅立叶变换系数作为输入特征, Kohonen 网络能够将不同流型聚类到相应的神经元节点上,但如果事先不知道输入样本所对应的流型,人们将无法从某节点处于兴奋状态的神经元预测所代表的是何种流型。此外折算液速对 Kohonen 网络的聚类结果的影响很大,这些缺点可由反传神经网络解决。将本实验的所有工况分成 3 组流型:泡状流,间歇流和环状流。这样,在 Grossberg 层取 3 个节点,(100)、(010)、(001) 分别对应泡状流、间歇流和环状流,将对应的权值置为 1 即可实现从网络输入到流型分类的运算。值得注意的是,当折算液速很低时,如何区别泡状流和有球盖形气泡的弹状流仍不能解决。因此,这种方法对本实验结果的应用存在一定的范围,在折算液速较高的范围内,CPN 的流型识别率非常高,完全能够满足工程的实际要求。流型识别的在线性在本实验结果的基础上达到 8.2 s。

通过以上算例说明, SOM 并不需要许多样本就能获得流型的正确分类,因此 CPN 网络的准确性和有效性并不是以事先建立丰富的数据库为代价。

6 讨论与结论

6.1 如何提高在线指标

本文得到的在线性指标与所采用的实验段和实验参数有关。通过前面的分析可知,若采用参数(包

以上算例证明,当减少波动序列的时间历程时, SOM 流型聚类效果大大降低。根本原因在于减小波动时间,使得不同流型的压力波动之间的差别减小。以时间历程为 4.096 s 的波动过程为例,每个流型各取 1 个工况,快速傅立叶变换系数结果图 5。图中的 FFT 系数经过了去均值、归一化处理。

由 Kohonen 网络的聚类或特征识别计算的结

括压力、压差等)的波动过程来反映流型,波动的的时间历程必须保证能够充分反映流动的变化过程,而对弹状流和块状流这些具有一定周期性的流动,压力波动信号至少应记录一个波动周期,因此当流动速度缓慢时采用单个压力传感器来识别流型的方法在提高在线性指标方面的前景并不乐观。就流型的本质而言,相界面同时在时间和空间内变化,故单独采用一个信号去实现流型的识别缺乏对对象的充分描述,因此这为以后的研究提供了研究方向。即以后的研究重点应在如何根据分布在多位置处传感器的参数波动信息,进行流动特征参数的重构和融合,以提高在线指标和准确率。

6.2 自动识别方法的改进

数据融合技术是分析多传感器数据的有效方法。数据融合起源于现代军事战争,其定义为^[7]:对多源来的数据和信息进行多方面的关联、相关和综合处理,以更好地进行定位、特征估计,并完全和适时地对情况和威胁进行评估。这个概念可以推广到对事件的预测。数据融合的优点是:成本低,增加测量维数,增加了置信度,容错性好,性能稳定,降低了对单个传感器的性能要求等优点。数据融合可以在信息获取层、特征提取层和综合决策层上做工作,用神经网络来解决这样的合成问题有独到的优势。

压力等参数的波动过程存在许多不确定的现象,这种不确定性主要表现在随机性和模糊性 2 个

方面。随机性是由于产生波动现象的因果关系不确定所造成的;模糊性主要指流型发生过渡过程时所呈现的“亦此亦彼”性。它不是由于人的主观认识达不到客观实际造成的,而是气液两相流的一种客观属性。模糊神经网络把神经网络和模糊系统有机的结合成一个整体,不仅增强了神经网络处理信息的可理解性,同时还能自动生成模糊隶属函数,提高模糊规则的精度,使模糊系统具备了自适应性^[8]。

综上所述,引入模糊理论对多传感器数据(参数波动过程)进行融合,具有很好的发展前景。这种方法在军事上和民用领域都取得了许多成功的范例^[9]。

6.3 实际应用需待解决的问题

当将在实验室获得的结果应用到工业现场之前,一个必须考虑的问题是:由于实验条件的限制,实验并不一定能够完全模拟工业现场,例如当现场出现了实验中没有发现的流型时,实验室获得的方法还能否给出正确的识别结果。本文的方法显示出明显的优越性,从前面的算例看出,不同流型的压力波动特性也不同,CPN 神经网络中的 Kohonen 层能够将不同特性(或流型)的压力波动过程聚类到不同的神经元节点,因此当出现了新的流型时, Kohonen 层自组织映射的结果将出现新的兴奋神经元,即应用 CPN 网络中能够发现未知的流型。

7 结论

本文利用气液两相流动时所产生的壁面静压力波动的快速傅立叶变换系数和 CPN 神经网络,实现了对 U 形管垂直上升段内空气-水两相流的流型自动识别,识别的在线性指标达到了 8.2s。折算流速对识别有较大的影响,当流速较高时,网络能够接近 100% 的识别出泡状流、间歇流和环状流。另一方面对于如何利用多传感器系统提高流型在线识别的指

标,是以后研究的重点,需要进一步的努力攻关。

参考文献:

- [1] Thorn R, Johansen G A, Hammer E A. Recent developments in three-phase flow measurement [J]. Meas. Sci. Technol., 1997, 8 (5): 691-701.
- [2] Monji H, Matsui G. Flow pattern identification of gas-liquid two-phase flow using a neural network [A]. Third International Conference on Multiphase Flow [E], Lyon, France, June, 1998: 8-12.
- [3] Mi Y, Ishii M, Tsoukalas L H. Vertical two-phase flow identification using advanced instrumentation and neural networks [J]. Nuclear Engineering and Design, 1998, 184 (2-3): 409-420.
- [4] Matsui G. Identification of flow regimes in vertical gas-liquid two-phase flow using differential pressure fluctuations [J]. Int. J. Multiphase Flow, 1984, 10 (6): 711-720.
- [5] 黄德双 (Huang Deshuang). 神经网络模式识别原理 (Theory of neural network pattern recognition) [M]. 北京: 电子工业出版社 (Beijing: Electronic Industry Publishing), 1996, 92-101.
- [6] Mao Z S, Dukler A E. The Myth of Churn Flow. Int. J. Multiphase Flow, 1993, 19 (2): 377-383.
- [7] 康耀红 (Kang Yaohong). 数据融合理论与应用 (Data fusion and its applications) [M]. 西安: 电子科技大学出版社 (Xi'an: Electronic Science and Technology University Publishing), 1997, 1-10.
- [8] 赵振宇, 徐用懋 (Zhao Zhenyu, Xu Yongmao). 模糊理论和神经网络的基础与应用 (Fuzzy theory, neural network's foundation and application) [M]. 北京: 清华大学出版 (Beijing: Tsinghua University Publishing), 1996, 1-8, 173-181.
- [9] Kuo R J, Cohen P H. Multi-sensor integration for on-line tool wear estimation through radial basis function networks and fuzzy neural network [J]. Neural Network, 1999, 12 (2): 355-370.

收稿日期: 2000-04-25; 改回日期: 2000-07-10。

作者简介:

白博峰 (1971-), 男, 河北省南皮县人, 博士, 从事多相流动与传热领域的科研工作。

(责任编辑 贾瑞君)