

电容层析技术中 BP 网络图象重建研究*

肖化 胡广莉 何惠玲 保宗悌

(华南师范大学物理系, 广州 510631)

摘要 介绍了电容层析技术的基本原理,研究了基于 BP 网络的电容层析成像方法,提出了成像的网络模型及其实现步骤,并给出了实验结果。结果表明该方法能够快速和较高精度地重建断层图象。

关键词 电容层析成像, BP 网络, 图象重建, 样本

1 引言

电容层析技术(ECT)使用微电容快速测量技术实现层析成像,是近年发展最快的一种过程层析成像技术。可用于多相流体的流型辨析和过程参数的测量,对工业中(如石油、化工、制药等)的实际应用有重要的意义。ECT 技术自 1989 年由英国 UMIST (曼彻斯特科技研究所)的 M. S. BECK 等人提出以来^[1],赢得广泛注意,得到迅速发展。ECT 技术的关键问题是实时快速、高精度定量的图象重建算法。由于目前 ECT 技术存在的某些缺陷,成像质量较差,计算时间过长等未能很好地解决,使成像结果不甚理想。改进图象重建算法变得至关重要。由于神经网络的并行处理和非线性映射的特性,使之为管道内的截面图象重建提供了一种快速高准确度的处理方法。本文主要讨论利用 BP 网络对管道内两相流进行电容层析成像(ECT)的方法。

2 基本原理和存在问题

电容层析成像的基本原理是当管道中流体流动形态或成分发生变化时,引起管道内空间电介质的介电常数变化,使得电容传感器不同极板间的电容值改变,通过检测电路检测出各电极间的电容值,送至处理机,根据某种算法,重建出流体在断层面的分

布图象。

ECT 系统主要由电容传感装置;测量和控制电路;图象重建装置三部分组成,如图 1 所示。




图 1 ECT 系统构成

Fig. 1 The constitution of ECT system




图 2 传感器模型

Fig. 2 Sensor model

* 广东省自然科学基金资助项目,广东省自然科学基金资助项目(950490)

收稿日期:1997-07-26;1997-09-02

一种 12 电极的电容层析成像传感器装置如图 2 所示。测量时,每次给 1 个极板加某一正电压 V_c ,其余极板接地,分别测量出正电位极板与其它极板间的电容 $C_{n,m}(n=1,2,\dots,11,m=1,2,\dots,12)$,依次给 1 个极板施加正电压 V_c ,测出所有电容值 $C_{n,m}$ 。我们称接正电位 V_c 的电极为源电极,接地的被测电极为检测电极。一般来说,对于 N 个电极的成像系统,由于对称性,可测量的独立电容值为 $N(N-1)/2$ 个。12 个电极之间则有 66 个独立的电容值,层析成像就是利用这 66 个测量电容值 $C_{n,m}$ 来反演出介质的分布图象。

由于管内无空间电荷,域中电势分布可用泊松方程来描述。

$$\nabla \cdot [\epsilon(x,y)\nabla\Phi(x,y)] = 0 \quad (1)$$

式中 $\Phi(x,y)$ 为电势分布函数, $\epsilon(x,y)$ 为介电分布函数。

为实现成像,以往的做法是用有限元法解式(1),得到电势分布的正问题解。再利用式(2)计算传感器的敏感场^[1]

$$S_{n,m}(k) = \frac{C_{n,m}(k) - C_{n,m}^0}{(\epsilon_1 - \epsilon_2) \cdot |C_{n,m}^f - C_{n,m}^0|} \cdot u(k) \quad (2)$$

式中 $\epsilon_1 > \epsilon_2$, 分别代表油/空气的相对介电常数。 k 为有限元中的第 k 个网元。 $C_{n,m}(k)$ 表示:当管内第 k 个单元内的介电常数为 ϵ_1 而其它管内单元为 ϵ_2 时,电极 n,m 之间的电容值。在已知了敏感场分布这一先验知识后,就可根据测量电容值,利用反向投影算法,求出圆管道断层上的灰度图象 $G(k)$ ^[1]

$$G(K) = \left[\sum_{n=1}^{11} \sum_{m=n+1}^{12} C_{n,m}^M S_{n,m}(k) \right] W(k) \quad (3)$$

然而这种算法有以下几个主要缺陷^[2]:(1)该法认为圆管内空间敏感场分布与介质分布无关,而实际是有关联的。所以反投影算法有一定的误差,尤其在管道中心附近更加明显。误差达 10% 以上。(2)空间分辨率较低。(3)需要较长的计算时间,要做到实时动态的成像,就必须采用分布式并行计算,使成本昂贵。

3 多层神经网络模型及算法

在成像系统中,如何利用 66 个测量的电容值,直接反演出断层的图象(即流体分布),这实质上就是一种非线性映射。基于神经网络的图象反演,就是要利用神经网络实现非线性映射的逼近。本研究采用 BP 网络实现图象反演。它是最为广泛应用的一

种神经网络,具有较强的学习能力,在充足的样本情况下,可实现任意精度的非线性映射。本研究采用的 3 层网络结构如图 3 所示。




图 3 神经网络结构模型

Fig. 3 Neural network model




图 4 管道截面网格模型

Fig. 4 Segment of pipe cross-section model

输入层有 66 个输入单元,输入量为 12 电极电容 CT 系统的 66 个电容测量值。隐含层 36 个单元,输出层 36 个单元。为实现图象重建,我们将圆形管道截面也划分为 36 个网格单元,如图 4 所示。其网格编号从左端开始,沿水平方向顺序编号为 1, 2, 3, ..., 36。神经网络的每个输出对应着圆管截面上的一个单元。

当管道内某网格单元填充了 ϵ 的介质(油)时,其相应的 66 个电容值会发生变化,也即 BP 网络的输入发生变化,经网络的非线性映射后,就在其断面上重建出相应的介质分布图象。输出层输出单元与介质分布的关系为:

$$O_k = \begin{cases} 1 & \epsilon_1 \text{ 介质} \\ 0 & \epsilon_2 \text{ 介质} \end{cases}$$

式中 k 表示第 k 个输出单元($k=1,2,\dots,36$)。学习算法主要分为 4 步:

(1) 将取得的 66 个电容值按式(4)作归一化处理。

$$C_{n,m}^N = C_{n,m}^M - C_{n,m}^0 / C_{n,m}^f - C_{n,m}^0 \quad (4)$$

$C_{n,m}^m$ 为第 n 电极与第 m 电极之间的测量电容值。 $C_{n,m}^0$ 为管内充满气体时的电容即空管电容, $C_{n,m}^f$ 为充满油时的满管电容。

经过这样处理,可以使原来大小很不同,甚至相差几个数量级的原始数据的动态范围大大减少,有利于神经网络区分那些差异很小的样本,使学习易

输入层

$$O_i = C_{n,m}^N, \quad (i = 1, 2, \dots, 66)$$

隐含层

$$O_j = \frac{1}{1 + e^{-\sigma_1 \cdot net_j}}, \quad net_j = \sum W_{i,j} O_i, \quad (j = 1, 2, \dots, 36) \quad (5)$$

输出层

$$O_j = \frac{1}{1 + e^{-\sigma_2 \cdot net_k}}, \quad net_k = \sum W_{j,k} O_j, \quad (k = 1, 2, \dots, 36)$$

式中 γ 为输出敏感因子,实验表明,它的引入可改善具有上述那种归一化特征的数据的映射效果,减少输出误差 ($\gamma < 1.0$)。

(3) 根据式(6)进行误差反向传播调整,由输出估计值 O 与教师训练值 T 的误差求得前两层权系数的改变量^[3]。

$$\left. \begin{aligned} \delta_k &= (T_k - O_k) \cdot O_k \cdot (1 - O_k) \\ \delta_j &= O_j \cdot (1 - O_j) \cdot \sum \delta_k W_{k,j} \end{aligned} \right\} \quad (6)$$

(4) 调整权系数

$$\left. \begin{aligned} W_{j,k}(l+1) &= \eta(\delta_k O_j) + \beta W_{j,k}(l) \\ W_{i,j}(l+1) &= \eta(\delta_j O_i) + \beta W_{i,j}(l) \end{aligned} \right\} \quad (7)$$

本研究选取的训练集共有 90 个样本,包括了 36 个网格单元分别单独填充油的样本,以及部分网格分别填充油的样本等。值得一提的是,鉴于神经单元的激励输出函数为 Sigmoid 函数,由于没有无限大的正权值或负权值,故神经元不可能输出 1 或 0。因此,在训练状态下,我们给定教师训练信号以 0.999 表示介质为油(ϵ_1), 0.1 表示介质为气(ϵ_2)。以上(2)至(4)步重复执行,直至网络模型的平均误差 E 达到要求。

$$E = \frac{1}{2p} \sum_p \sum_k (t_{pk} - O_{pk})^2 \quad (8)$$

O_{pk} 为输出层的输出单元 k 的输出估计值。 t_{pk} 为教师训练值。基于式(8)来完成权系数 W 空间的梯度搜索,可获得真实的梯度搜索,最终使系统误差 E 最小。

4 实验仿真研究

利用上面经过训练的网络,就可实现电容层析图象重建。由于本研究对象为两相流的介质分布,只含 ϵ_1 介质或 ϵ_2 介质,故每个输出单元取阈值为 0.5, 大于 0.5 判定为油,小于 0.5 判定为气。图象重建结


于收敛。值得注意的是,归一化后的电容值在 -1 至 $+2$ 区间,之所以出现大于 1 的值,是由于电容层析成像系统是一种非线性系统,为曲线式成像^[2],不同于大家所熟悉的射线式层析成像,如 $X-CT$ 等。

(2) 按式(5)进行前向计算,获得圆管截面上 36 个网格单元的介质分布估算值:

$$(i = 1, 2, \dots, 66)$$

果如图 5 所示。图中 a, b, c, d, e, f 为原始介质分布, a1, b1, c1, d1, e1, f1 为神经网络映射出的图象。

由图 5 可见,基于神经网络的电容层析成像,其



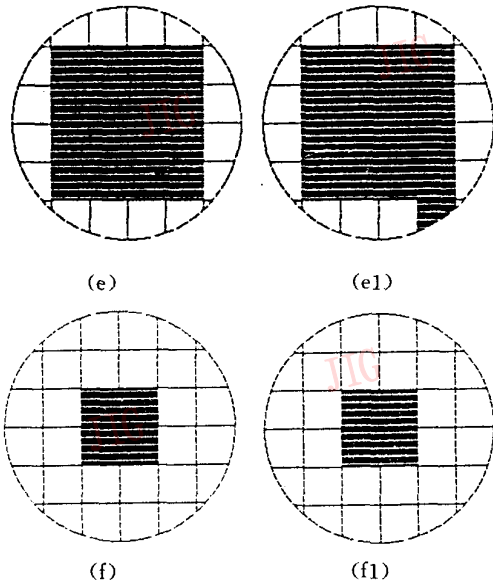


图5 重建图象

Fig. 5 Reconstructed images

重建的图象具有较高的准确度。即使在管道中心,其重建图象也相当准确。在整个截面上误差均匀分布,且误差可小于6%。如果介质分布的变化能被电容

传感器检测出来,则其管道截面内各处的精确度基本上是相同的。而通常的反投影算法如前面指出,难以重建出高质量的断层图象,且管道内各处精度差异较大,尤其在管道中心处,误差很大。

5 结论

将实验结果与文献[1][2]相比较,结果表明采用3层感知机神经网络来实现电容层析成像,图象质量明显优于目前常用的有限元反投影算法。而且由于网络的并行处理能力,使其重建速度大大提高,可实现两相流的动态实时成像。

参考文献

- 1 Xie C G, Plaskowski, Beck M S. 8-electrode capacitance system for two-component flow identification. Part1: Tomographic flow imaging, IEEE Proc. A, 1989, 136(4): 173~190.
- 2 Xie C G, Huang S M, Hoyle B S et al. Electrical capacitance tomography for flow imaging: system model for development of image reconstruction algorithms and design of primary sensors. IEEE Proc. G, 1992, 139(1): 89~98.



肖化,现为华南师范大学物理系副教授,目前主要从事信号处理等方面的研究。

A BP Network Image Reconstruction Method for Electrical Capacitance Tomography

Xiao Hua, Hu Guangli, He Huiling, Bao Zongti

(Dept. of Physics, South China Normal University, Guangzhou 510631)

Abstract This paper discusses the basic theory of electrical capacitance tomograph. A neural network method for electrical capacitance tomography is proposed. A neural network model for image reconstruction and its realization are studied. Experimental results illustrate that the method is effective and accurate for image reconstruction.

Keywords Capacitance tomography, BP network, Image reconstruction, Sample