

电容层析成像的电场分布与反演

郭红星¹, 余胜生¹, 保宗悌², 王延平²

(1. 华中科技大学计算机科学与工程系, 湖北武汉 430074; 2. 武汉大学电子信息学院, 湖北武汉 430072)

摘 要: 通过分析等势线及电容敏感场分布, 深入探讨了电容层析成像电场分布的“软场”特性及导致反演问题非线性、不适定的机理. 提出一个基于三层 B-P 神经网络的图像重建算法. 网络的输入是预处理过的电容矢量, 输出直接对应到空间图像. 实验结果表明, 该算法成像速度快且精度高, 较以前的成像算法有很大的改进.

关键词: 电容层析成像; 有限元法; 非线性不适定问题; 神经网络; 图像重建

中图分类号: TP216 TP183 **文献标识码:** A **文章编号:** 0372-2112 (2002) 01-0062-004

Electric Field Distributions and Inversions for Electrical Capacitance Tomography

GUO Hong-xing¹, YU Sheng-sheng¹, BAO Zong-ti², WANG Yan-ping²

(1. Department of Computer Science and Engineering, Huazhong University of Science and Technology, Wuhan, Hubei 430074, China;

2. College of Electronic Information, Wuhan University, Wuhan, Hubei 430072, China)

Abstract: Based on analyzing the distributions of equipotential lines and capacitance sensitivity fields, this paper discusses the “soft fields” characteristics of electric field distributions for electrical capacitance tomography. The mechanism leading their inversions to nonlinear ill-posed problems is also studied. We employ a three-layer B-P neural network to reconstruct images. The input vector of the network is the preprocessed capacitance measurements and the output corresponds to the spatial image. Experimental results illustrate that this method is fast and accurate for image reconstruction.

Key words: electrical capacitance tomography; FEM; nonlinear ill-posed problems; neural networks; image reconstruction

1 引言

电容层析成像 (Electrical Capacitance Tomography, 简称 ECT) 是新发展起来的一种工业过程层析成像技术^[1]. 其在过程工业, 特别是石油和化工工业中具有极其广泛的应用前景. 典型的电容层析成像系统由一组电容传感器, 电容测量电路及一台图像重建计算机三部分组成. 电容传感器一般由沿圆周对称地安装在管道绝缘部分的多电容电极组成, 其截面图见文献[2]. 管内流动着混合介质, 一般为两相流.

与医用层析成像建立在射线基础上不同, 电容层析成像是建立在电场基础之上的, 使其与传统的射线层析成像技术有本质上的区别. 传统的图像重建算法不能直接用于 ECT 图像重建. 已经提出了基于变换和迭代技术的多种算法, 但这些算法不能保证成像精度和速度二者兼顾^[3].

本文以 12 电极系统及气/油流为例进行讨论. 首先从电场分布出发, 探讨“软场”效应, 然后结合电容敏感场, 分析这种“软场”效应对图像重建的影响, 接着提出一种能较好地兼顾成像精度与速度的神经网络图像重建算法, 最后给出图像重建的实验结果.

2 电场分布的软场效应

电容层析成像的目的是利用测量得到的一组数目有限的电容值反演出物体内部的介质分布, 是一个逆问题. 正问题是已知物体内部的介质分布计算出电场分布, 并得到各个电极对之间的电容值. 深入研究正问题是求解逆问题的基础, 只有对介质分布影响电场分布的机理有足够的了解, 才有可能开发出有效、实用的反演算法. 本节以等势线和电容敏感场为工具进行探讨.

2.1 电容传感器的数学模型

因为电容传感器所用的测量频率大约为 1MHz, 12 电极电容传感器的模型可以作为静电场问题对待, 由如下的拉普拉斯方程决定 (假定无自由电荷)

$$\nabla \cdot [\epsilon_0(x, y) \nabla \phi(x, y)] = 0 \quad (1)$$

其相应的边界条件 (迪义赫利边界条件) 由测量技术构成, 即当电极 i ($i = 1, 2, \dots, 11$) 作源电极 (电位为 V_c) 时为:

$$\phi^{(i)} = \begin{cases} V_c & (x, y) \in \Omega_i \\ 0 & (x, y) \in \Omega_k (k = 1, \dots, 12, k \neq i) \quad (x, y) \in (\Omega_s + \Omega_{pg}) \end{cases} \quad (2)$$

其中 $\phi(x, y)$ 和 $\epsilon(x, y)$ 分别是二维连续电势分布和介质的相对介电常数分布, ϵ_0 为真空介电常数, $\epsilon_1, \epsilon_2, \dots, \epsilon_{12}$ 为 12 个电极的空间位置, ϵ_{pg} 表示最外面的屏蔽罩, ϵ_{pg} 为 12 个径向屏蔽板.

对于给定的介电常数分布, 在这里是气 ($\epsilon = \epsilon_{gas} = 1.0$) 和油 ($\epsilon = \epsilon_{oil} = 3.0$) 的分布, 可以求出 66 个电容测量值. 为此, 首先必须解方程 (1) 以得到电势分布 $\phi(x, y)$. 一般来说, 由于 $\epsilon(x, y)$ 的分布非常不规则, 因此方程 (1) 无解析解. 这里采用基于有限元的数值方法^[4].

2.2 等势线

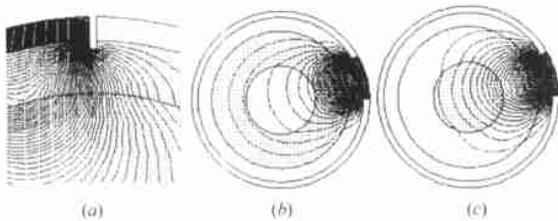


图 1 各种不同流型的等势线分布. (a) 充满气(灰色)时电极附近; (b) 25%中心油(白色)流; (c) 75%环形油(白色)流

图 1 是电极 1 为源电极时各种不同流型的等势线分布. 由图 1 可以看出, 等势线分布具有两个明显的特征: 一是分布极不均匀. 源电极附近相当密集, 离源电极越远越稀疏. 另一个是分布与介质直接相关. 当加入不同介电率的材料时, 等势线分布会产生畸变. 其中最典型的表现就是在两种介质的交界处, 等势线会明显弯折. 另一个有趣的现象是等势线似乎“欺软怕硬”, 在中心油流时, 中心处的等势线分布较充满气时稀疏, 而对环流, 中心处的等势线分布则相对密集. 由图 1(a) 可以看出, 径向屏蔽板旁与源电极相邻的探测电极一侧的等势线分布相对稀疏, 表明径向屏蔽板确实起到了一定的屏蔽作用, 能使相邻电极间的大电容值减小, 但同时也增加了问题的非线性. 由此可知, 这里的电场分布并不均匀, 而且还受介质分布的影响. 有人将这种现象称作“软场”效应, 它使得反演困难得多.

2.3 电容敏感场

2.3.1 电容计算 电极对 $i - j$ 之间的电容值由下式给出

$$C_{i,j} = Q(j) / V_c = \frac{1}{V_c} \int_{(x,y) \in \Omega_j} \epsilon(x,y) \nabla \phi^i(x,y) \cdot d\vec{j} \quad (3)$$

式中 $Q(j)$ 为探测电极 $j(j = i + 1, \dots, 12)$ 上的感应电荷, $\epsilon(x, y)$ 为介电常数分布.

2.3.2 电容敏感场分析 敏感场分布函数 $S_{i,j}(k)$ 的定义是单元 $k(k = 1, 2, \dots, R)$ 中单位面积上的物质介电常数发生变化时引起的电极对 $i - j$ 间电容的变化率. 对气/油系统, 电极对 $i - j$ 之间的敏感场分布定义为^[5]:

$$S_{i,j}(k) = \mu(k) \cdot \frac{C_{i,j}(k) - C_{i,j}^{(gas)}}{(C_{i,j}^{(oil)} - C_{i,j}^{(gas)}) (\epsilon_{oil} - \epsilon_{gas})} \quad (4)$$

$C_{i,j}(k)$ 是当管内(半径为 R_1 内的单元)第 k 个单元材料的介电常数为 ϵ_{oil} 且其余的单元材料的介电常数都为 ϵ_{gas} 时的电容值. $C_{i,j}^{(gas)}$ 和 $C_{i,j}^{(oil)}$ 分别是管内充满空气和充满油时的电容值. $\mu(k)$ 是与管内第 k 单元面积有关的修正因子, 取为管内总

面积与该单元面积之比.

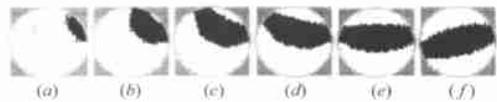


图 2 不同电极对之间敏感场的分布. (a) 1 - 2; (b) 1 - 3; (c) 1 - 4; (d) 1 - 5; (e) 1 - 6; (f) 1 - 7

图 2 中 (a) ~ (f) 分别表示 6 个典型的电极对 1 和 2, 1 和 3, ..., 1 和 7 之间的敏感场分布. 黑颜色代表敏感场为正的区, 白颜色代表敏感场为负的区域. 由图可见, 对不同的电极对, 电容敏感场的正响应处于不同的区域, 剩下的区域则为负响应, 即在这些区域加入高介电率材料不仅不会使相应的电容值增加, 反而使其下降, 即使是在正响应区域, 不同位置的敏感度也不同. 因此电极对之间的电容为最大值时并非满管时的电容, 电容为最小值时并非空管时的电容. 当黑颜色的区域全部为高介电常数的油且白颜色的区域全部为低介电常数的气时, 电极对之间的电容值最大; 当黑颜色的区域全部为低介电常数的气且白颜色的区域全部为高介电常数的油时, 电极对之间的电容值最小. 这进一步说明电容值与介质分布之间是一种极度非线性关系, 使得精确的反演相当困难.

3 介质分布的神经网络反演

3.1 非线性不适定逆问题的解法

在电容层析成像技术中, 测量数据和图像数据都是离散信号. 假设正问题由非线性算子 A 描述, 即:

$$C = A \quad (5)$$

其中 (R^n) 为介质分布矢量, $C(R^m)$ 为测量电容矢量. 在正问题中, A 和 C 已知, 要计算 R , 很容易完成. 而在逆问题中, 却是知道 A 和 C , 要求 R .

对电容层析成像技术而言, 不可能用明确的分析途径来解逆问题. 另外, 由于使用一组数目有限的传感器, 与图像的像素点数目(对应于 C , 本文中 $n = 1200$) 相比, 可采集到的独立测量数目(对应于 A , 本文中 $m = 66$) 很少, 即 $m < n$, 引起信息不足, 这就导致问题是不适定(病态)的, 即具有以下三个特征之一:

(1) 无解, 或; (2) 解不惟一, 或; (3) 解不稳定, 即解对输入中的小变化非常敏感.

一般来说, 要给出逆问题的真解是不可能的. 所希望得到的最好结果是解与实验数据一致而且有用. 克服病态问题的三个坏特性的通用方法是进行正则化. 其基本思想是用先验知识来抑制解的无序行为. 将先验知识以泛函或半泛函的形式投影到解空间. 泛函越小, 从先验知识角度看, 求得的解就越接近真解, 即:

$$\min_{R^m} \|A - C\| + B \quad (6)$$

式(6)中 B 为正定矩阵, 包含先验知识, B 定义了一个泛函, 即 B 泛函. 上式的解肯定存在, 为^[6]

$$= [A^T A + B^T B]^{-1} A^T C \quad (7)$$

先验泛函的权值用正则化参数 (> 0) 表示, 可被看成是正则化重要性的尺度. 如果正则化被正确运用, 则当 $\lambda \rightarrow 0$

且无测量误差时,所得逆问题的解即为真解. 的值没有指定,可以根据经验选取,也可通过约束优化来消除这种不确定性^[6].

最常用的线性反投影(LBP)算法^[5]是建立在电容敏感场分布的基础之上的,其假定逆问题的非线性可用线性关系近似.敏感场分布提供了系统的一些先验信息,被用来对逆问题进行正则化.敏感场分布的合法性是建立在扰动的大小对场分布没有影响这一假定的基础之上的.而从上节的分析中可以看出,在实际的多相流中,扰动将会使场发生严重畸变.这样在上面的假定下,会导致错误的重建图像.

神经计算以自适应为基础,为确定直接进行图像重建所需的敏感场分布(加权矩阵)的一种形式提供了方法.通过合理选择训练模式,网络可以学到系统中固有的非线性,这反映在加权矩阵的动态重组上.学习可以看作是一种正则化过程.训练成功后,即使场产生严重畸变,网络也能快速重建出精确的图像.采用神经网络反演介质分布实际上是以训练模式集为约束条件的优化问题,的不确定性被自然消除.(7)式中 $A^T A + B^T B J^{-1} A^T$ 由训练好的神经网络输入/输出间的非线性映射关系决定.

3.2 基于 B-P 神经网络的层析图像重建算法

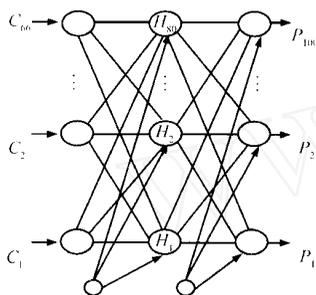


图3 ECT图像重建的神经网络模型

在与ECT相关的过程层析技术中, Nooralahiyan 等提出了用不含隐层的两层 B-P 网络对气/油或水/油两相流进行图像重建^[3]. 由于不带隐层的 B-P 网络的非线性映射能力有限,使得重建结果不甚理想,而且收敛速度过慢也是一大问题. 因此本文选用三层 B-P 网络,并采用新的训练策略,简称为 TBP 算法. 具体方法是将成像区域的 1200 个有限元用 100 个大小一样的小圆覆盖,每个小圆所在的区域为一个成像单元. 训练模式由空管中 100 个小圆位置分别为油滴的 100 个模式,满管中 100 个小圆位置分别为气泡的 100 个模式及空管和满管共计 202 个模式组成. 在开始训练网络时选用较大的学习率和动量因子,使网络快速收敛于某一极小点附近,当观察到收敛曲线经常发生振荡时,及时暂停训练,输入较小的学习率和动量因子后继续训练,以抑制由于参数过大引起的振荡,保证网络收敛于极小点. 网络的结构如图 3 所示.

训练参数如下:

训练算法:在线方式,带动量项

输入节点数 = 66(对应于 66 个电容测量值)

隐层数 = 1; 隐层单元数 = 80; 带偏置单元

输出节点数 = 100(对应于 100 个小圆区域空间位置)

目标值: gas 为 0.1, oil 为 0.9

初始权和阈值 = (-0.5, -0.5) 之间的随机数

学习率: 1-20000 次迭代为 0.7, 20000 次以后为 0.2

动量因子: 1-20000 次迭代为 0.5, 20000 次以后为 0.3

激励函数: Sigmoid 函数

对单输入模式的最大可容忍误差 = 0.01

系统总的可容忍误差: 0.01

训练模式总数 = 202

最大叠代次数 = 100000

输入数据预处理: 归一化到区间 [0.1, 0.9].

迭代到 100000 次时, 系统误差大约为 0.08, 而非 0.01.

3.3 实验结果与讨论

3.3.1 评估指标 空间图像误差 (SIE) 被用作评价成像结果的指标, 定义如下

$$SIE = \frac{1}{M} \sum_{p=1}^M |G_R(p) - G_S(p)| / \sum_{p=1}^M G_S(p) \quad (8)$$

其中 $G_S(p)$, $G_R(p)$ 分别为标准测试图像与重建图像在 p 点的灰度值, M 为总的像素数. SIE 代表总的空间误差信息, 其综合考虑了面积、位置、形态及灰度级的影响. SIE 越小, 则成像效果越好.

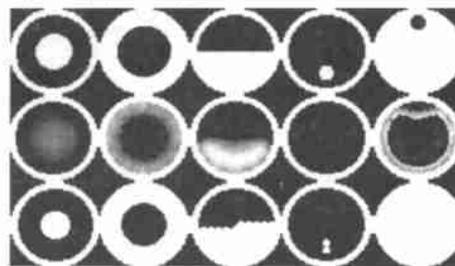


图4 典型流型的成像结果

第一行:原图像;第二行:LBP的重建

图像;第三行:B-P网络的重建图像

3.3.2 图像重建结果 对于气/油两相流,考察了九种不同浓度的中心流,九种不同浓度的环流,九种不同浓度的层流,四种油滴流,五种气泡流共计 36 种流型的图像重建结果,并将其与 LBP 的结果进行了对比^[2]. 限于篇幅,这里只给出其中五种典型流型的成像结果(如图 4 所示,从左至右编号为 1, ..., 5). 当输出层神经元输出大于 0.5 时判为油,否则为气. 图中高亮度代表油相,低亮度代表气相.

由重建结果可以看出,与 LBP 重建算法相比, TBP 最大的优势在于其重建出的图像相当清晰,而由 LBP 算法重建出的图像都存在不同程度的模糊效应和伪影. 在五种流型中,层流和环流的重建结果最好,当浓度增加时,中心流也有较好的重建结果. 可见,不均匀敏感场效应对 TBP 算法的影响还是存在,不过比起对 LBP 的影响要小得多. 对于油滴流,虽然重建误差较大,但是流型的位置和大致形状还是清晰可辨的,相应的 LBP 的重建结果则相当模糊,特别是当油滴靠近中心处时,结果更差. 值得指出的是,对于小的气泡流及位于中心处的油滴流,由 LBP 得到的重建图像完全是错误的伪影,而 TBP 法不会产生这种伪影,但也不能将其有效地分辨出来. 因此,如

何进一步提高成像分辨率,以分辨小气泡流及位于中心处的油滴流仍然是一个有待研究的问题。

表 1 两种图像重建算法的 SIE 值比较

重建算法	图 像				
	1	2	3	4	5
LBP	0.8165	0.4956	0.2806	1.1947	0.6040
TBP	0.3671	0.2593	0.0997	0.5000	0.0495

表 1 给出了两种图像重建算法的 SIE 值。从表 1 可以看出,从整体上看,TBP 算法的 SIE 值比 LBP 算法的相应值小得多。TBP 算法的峰值为 0.5,谷底接近 0.0;而 LBP 算法的峰值达到 1.19,谷底也在 0.25 以上。可见,TBP 算法的重建结果较之 LBP 算法有了很大的改善。同时,在 Pentium MMX166 PC 上用训练好的网络进行图像重建,速度可达 100 帧/秒以上,这完全能够满足对工业过程进行实时监测的要求。总之,在进行两相流重建时,无论是保真度,重建速度,还是分辨率,TBP 算法与 LBP 算法相比均有很大的改进。进一步的研究表明,TBP 算法的抗噪能力也胜过 LBP 算法。



图 5 尼龙聚合过程的成像结果

图 5 为 ECT 用于尼龙聚合过程成像的实例^[7]。聚合过程可分为加热、沸腾、减压及平衡四个阶段,在此过程中,混合物中的水分会逐渐减少。图 5 直观地演示了这一过程。从左至右的 6 个图像中,与混合物中水分相对丰富的高介电率对应的高亮度像素逐渐变少,最后几乎全部变为与干燥的聚合物对应的低亮度像素。而且,离热源较近的四周首先变暗,然后才是容器的中心处。这是因为中心处离热源较远,所以水分挥发也较慢。只有所有水分挥发完毕,聚合过程才算完成。用 ECT 对聚合过程进行动态监测能使操作人员最优时间停止聚合过程。

4 结论

本文深入地探讨了电容层析成像电场分布的“软场”特性及其给反演所造成的困难。在此基础上,提出一个基于三层 B-P 网络的神经计算反演算法,利用神经网络的自学习及非

线性映射能力来求解反演问题。本算法具有成像速度快,保真度高等突出优点,具有较大的实用价值。

参考文献:

- [1] Yang W Q, York T A. New AC-based capacitance tomography system [J]. IEE Proc. - Sci. Meas. Technol., 1999, 146(1): 47 - 53.
- [2] 严杰,郭红星,常鸿森,王延平,保宗悌. 敏感场在电容层析成像中的分析与处理 [J]. 电子学报, 1999, 27(2): 103 - 105.
- [3] Nooralahiyani A Y, Hoyle B S, Bailey N J. Neural network for pattern association in electrical capacitance tomography [J]. IEE Proc. - Circuits Devices Syst., 1994, Dec., 141(6): 517 - 521.
- [4] 郭红星,严杰,保宗悌,王延平. 电容层析成像中传感器的有限元建模分析与设计 [J]. 计算机辅助设计与图形学学报, 1999, 11(4): 345 - 348.
- [5] XIE C G, HUANG S M, HOYLE B S, THORN R, LENN C, SNOWDEN D and BECK M S. Electrical capacitance tomography for flow imaging: system model for development of image reconstruction algorithms and design of primary sensors [J]. IEE Proc. G, 1992, 139(1): 89 - 98.
- [6] A H 吉洪诺夫, B R 阿尔先宁著. 不适问题的解法 [M]. 王秉忱译. 陈恕行校. 北京: 地质出版社, 1979.
- [7] Dyakowski T, York T A, Mikos M, et al. Imaging nylon polymerisation processes by applying electrical tomography. Chemical Engineering Journal, 2000, 77: 105 - 109.

作者简介:



郭红星 男, 1971 年 12 月生于湖北省红安县。分别于 1994, 1996, 1999 年获武汉大学工程学士学位, 电路与系统硕士学位, 理学博士学位。现在华中科技大学计算机科学与技术博士后流动站工作。主要从事工业过程层析成像, 数字视频处理, 计算机视觉等方面的研究。E-mail: harod@263.net

余胜生 教授, 博士生导师。现任外存储系统国家专业实验室主任, 国务院学位委员会计算机学科评议组成员。主要研究方向为计算机系统结构与网络通讯技术。

保宗悌 教授, 博士生导师。主要研究方向为空间物理与信息处理。

王延平 教授, 博士生导师。主要研究方向为信号处理与多媒体计算机技术。