

文章编号: 2095-4980(2014)06-0858-07

基于 BP 神经网络的剩余油形态识别

毛国庆¹, 滕奇志¹, 吴 拥¹, 何海波²

(1.四川大学 电子信息学院, 四川 成都 610064; 2.四川成都西图科技有限公司, 四川 成都 610064)

摘 要: 随着油田开发的不断深入, 储集层孔喉内形成剩余油, 这些剩余油在一定程度上影响驱油效率。目前, 对剩余油的研究主要是通过可视化的玻璃刻蚀模型进行微观动态驱替实验。对于模型中的剩余油形态进行研究分析, 可以为油田的二次采油以及三次采油提供重要参考依据。本文使用剩余油形态的几何特征参数作为 BP 神经网络的输入对其进行分类识别。通过对该 BP 神经网络的训练测试, 其具有良好的识别率, 能达到快速准确分类识别剩余油形态的目的。

关键词: BP 神经网络; 剩余油; 形态; 特征识别

中图分类号: TN915.43; TP391.41 **文献标识码:** A **doi:** 10.11805/TKYDA201406.0858

Shape recognition of remained oil based on BP neural network

MAO Guo-qing¹, TENG Qi-zhi¹, WU Yong¹, HE Hai-bo²

(1.College of Electronics and Information Engineering, Sichuan University, Chengdu Sichuan 610064, China;

2.Chengdu Sichuan Xitu Technology Co., Ltd., Chengdu Sichuan 610064, China)

Abstract: With the deepening of oilfield development, the remained oil which shows some effects on oil displacement efficiency is formed in the reservoir pore-throat. At present, the study on the remained oil is almost performed by doing microscopic displacement experiments with the visual glass etching model. Research on remained oil shape in the model can provide important reference for secondary oil recovery and tertiary oil recovery of oilfield. In this work, the geometric feature parameters of remained oil are taken as the input of neural network for classification. Through the training and testing of the BP(Back-Propagation) neural network, good recognition rates can be achieved, which enables fast and accurate classification and identification for remained oil shape.

Key words: BP neural network; residual oil; shape; feature recognition

在油田开发领域中, 油田的开发方式决定了油气的采收率高低。油田的开发方式主要分为: 一次采油、二次采油和三次采油^[1]。由于储集层孔喉结构特性、岩石物性以及原油的粘度等原因, 经过某一采油方式开采后, 仍不能采出的地下残余石油称作剩余油。为了进一步研究剩余油, 石油地质研究人员将剩余油分为不同的形态, 针对不同形态的剩余油研究合适的驱替方法, 从而充分挖掘油气藏潜力, 提高油田驱油效率^[2]。在实验室中, 对驱油效率的研究主要是利用玻璃刻蚀模型和可视化的微观驱替实验平台, 进行微观驱替实验, 来模拟二次采油以及三次采油的过程, 从而获得微观驱替实验中油水运移的动态实验过程^[3-4]。常见的微观驱替实验过程如图 1 所示。在驱替过程中, 模型孔隙中剩余油形态会发生较大的变化。水驱替结束后, 剩余油形态分布也会呈现多样性。由于孔隙壁的作用力与模型内部压力达到平衡状态, 如果仅仅通过继续水驱的方式, 模型中的剩余油很难被驱替出来。此时, 需要根据剩余油形态分布选择合适的驱替方式进行实验, 来提高驱油效率^[5]。因此, 对于微观驱替实验中剩余油形态分类识别的研究, 能够为油田二次采油、三次采油开发方案的正确制定提供重要理论依据, 从而提高油田采收率。




Fig.1 Process of micro displacement

图 1 微观驱替过程

收稿日期: 2014-07-23; 修回日期: 2014-08-14

基金项目: 国家自然科学基金资助项目(61372174)

1 剩余油形态识别流程

剩余油形态的正确识别是建立在良好的图像处理和分割基础上。在识别前，对于剩余油的目标与玻璃刻蚀模型的背景进行分割等图像预处理，有利于后期的剩余油形态识别的研究。

常见的剩余油形态主要分为 6 类^[6-7]，如图 2 所示。由于微观驱替实验中的剩余油的颜色单一，没有明显的纹理特征，因此，基于纹理图像识别的方法不适用于剩余油形态识别。同时，同一类形态的剩余油呈现出多样性，因此，传统的基于模版匹配的图像识别算法也不适用于剩余油的形态识别。而剩余油的形态都有一定几何特征，利用合适的特征参数容易实现形态的分类识别。




Fig.2 Common shapes of remained oil

图 2 常见剩余油形态

在提取的形态特征参数基础上，对驱替模型图像中每个剩余油目标进行逐一识别，便能得到整个模型具体的剩余油分布情况。但是，在实验分析阶段，由于数据量较大，因而使用能够智能学习和快速准确的分类器对剩余油形态分类识别工作具有重要的意义。

人工神经网络具有很强的自适应、学习和容错的能力。它以类似于人类思维的方式，通过分析预先提供的一系列输入输出数据之间潜在的规律，然后根据这些规律对新的输入参数进行推算，得到输出结果。这为解决非线性的剩余油形态识别问题提供了新思路。BP 神经网络是一种具有输入层、隐含层和输出层的前馈神经网络。它利用非线性规划中的快速下降法，使网络权值和阈值参数沿着误差函数的负梯度方向变化，以使网络的实际输出值与期望输出值的均方差值达到最小，得到合适的神经网络结构参数，最后通过已训练好的网络参数对新的形态特征参数进行计算判别，得到识别结果^[8]。

基于以上多方面因素，设计出基于 BP 神经网络的剩余油形态识别流程。该流程具体组成如图 3 所示。




Fig.3 Flow diagram of remained oil shape recognition

图 3 剩余油形态识别流程框图

2 剩余油形态特征提取

在微观驱替图像预处理以及剩余油目标提取完成以后,目标几何特征参数的选取直接关系着后续形态的识别^[9]。常见的几何形态特征参数主要有:面积、周长、凹度、圆形度、长宽比、矩形度、偏心率以及欧拉数等。通过分析比较,发现不同形态的剩余油在凹度、圆形度、长宽比、矩形度、偏心率以及半径比上有良好的区分度。因此,选定该 6 种形态特征量,作为后续 BP 神经网络的训练输入量。

2.1 圆形度

圆形度是用来表示剩余油目标圆形近似程度,也反映了连通区域的紧凑性和目标边界的复杂程度。圆形度对于孤岛状的识别度较高。计算公式如式(1)所示。

$$C = \frac{\mu_R}{\delta_R} \quad (1)$$

式中: μ_R 是从目标区域重心到边界点的平均距离, δ_R 是从目标区域重心到边界点上的距离均方差值。计算公式分别如式(2)、式(3)所示。

$$\mu_R = \frac{1}{K} \sum_{k=0}^{K-1} \|(x_k, y_k) - (\bar{x}, \bar{y})\| \quad (2)$$

$$\delta_R = \frac{1}{K} \sum_{k=0}^{K-1} [\|(x_k, y_k) - (\bar{x}, \bar{y})\| - \mu_R]^2 \quad (3)$$

式中: $(\bar{x}, \bar{y})$ 为目标区域重心坐标; (x_k, y_k) 为目标区域边界点坐标; K 为边界点数。当目标区域 R 趋向于圆形时, C 值单调递增并且趋向于无穷大。当 C 值越小,它与圆的近似度越低,其形态结构越复杂。

2.2 矩形度及长宽比

对于柱状和塞状的剩余油,仅通过依靠圆形度来识别的方式是不够的。本文采用目标区域矩形度和最小外接矩形的长宽比,可以达到较好的辨识效果。

矩形度是以剩余油目标连通区域面积与目标的最小外接矩形面积作比例运算,它可以体现目标对其最小外接矩形的充满程度,计算公式如式(4)所示。长宽比是由最小外接矩形的长度和宽度作比例运算,计算公式,如式(5)所示。

$$P_r = A_s / A_{MER} \quad (4)$$

式中: A_s 为目标连通区域的面积, A_{MER} 为包围目标连通区域最小外界矩形的面积。

$$P_{lw} = L_{MER} / W_{MER} \quad (5)$$

式中: L_{MER} 为连通区域最小外接矩形的长度, W_{MER} 为连通区域最小外接矩形的宽度。

2.3 凹度

凹度可以反映目标区域边界轮廓的凹陷程度,计算公式如式(6)所示。

$$Concavity = P / P_x \quad (6)$$

式中: $Concavity$ 为凹度; P 为目标连通区域边界的凸周长; P_x 为目标连通区域边界的周长。

2.4 偏心率

偏心率在一定程度上反映了目标区域的紧凑性和伸长度。常用主轴与辅轴的长度作比例运算的方法受目标的形状和噪声影响较大。而利用整个剩余油目标区域的所有像素,可使噪声影响大大减少。本文采用由惯量椭圆法求目标偏心率的方法,该方法具有抗噪声干扰能力强的特点^[10]。

在刚体力学中,通常采用刚体的转动惯量来度量刚体转动时的惯性。设一个刚体目标具有 N 个质点,质量分别是 $m_1, m_2, \dots, m_N$, 其坐标分别 $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, 那么该刚体绕轴线的转动惯量 I 表示为:

$$I = \sum_{i=1}^N m_i d_i^2 \quad (7)$$

式中 d_i 为第 i 个质点与轴线之间的垂直距离。如果该轴线通过坐标系原点,并且方向余弦分别为 α, β , 则公式(7)写成:

$$I = A\alpha^2 + B\beta^2 - 2H\alpha\beta \quad (8)$$

式中： $A = \sum m_i y_i^2$, $B = \sum m_i x_i^2$ 分别为刚体绕 X, Y 轴的转动惯量； $H = \sum m_i x_i y_i$ 为惯性积。

式(8)可以用简单的几何方式表示为：

$$Ax^2 + By^2 - 2Hxy = 1 \quad (9)$$

该等式表示一个中心在坐标原点的二阶曲面。如果用 $\vec{r}$ 表示原点到该二阶曲面的矢量，并且该矢量的方向余弦为 α, β ，模为 r ，那么将式(8)代入式(9)得：

$$r^2(A\alpha^2 + B\beta^2 - 2H\alpha\beta) = r^2 I = 1 \quad (10)$$

由式(10)可得一个惯量椭圆，它反映了目标连通区域上各个点的分布。该椭圆 2 个主轴的斜率 k 和 l 为：

$$k = \frac{1}{2H}[(A-B) - \sqrt{(A-B)^2 + 4H^2}] \quad (11)$$

$$l = \frac{1}{2H}[(A-B) + \sqrt{(A-B)^2 + 4H^2}] \quad (12)$$

解得惯量椭圆的 2 个半轴长分别为：

$$p = \sqrt{2[(A+B) - \sqrt{(A-B)^2 + 4H^2}]} \quad (13)$$

$$q = \sqrt{2[(A+B) + \sqrt{(A-B)^2 + 4H^2}]} \quad (14)$$

综上可以得到偏心率 E 计算公式：

$$E = \frac{p}{q} \quad (15)$$

2.5 内外半径比

以上 5 种参数，对于网状与膜状的区分度均较低。而目标区域的最大内切圆与最小外切圆的半径比例对网状与膜状具有较高的辨识度。计算公式：

$$IORate = IR / OR \quad (16)$$

式中： $IORate$ 为内外半径比； IR 为目标连通区域最大内切圆的半径； OR 为目标连通区域最小外切圆的半径。

3 BP 神经网络分类器设计

本文采用具有输入层、隐含层和输出层 3 层结构的前馈神经网络模型。其中，输入层包含 6 个神经元，对应于剩余油的 6 个形态特征参数，隐含层包含 6 个神经元，输出层包含 6 个神经元，对应于 6 种不同的形态分类。该网络模型拓扑结构如图 4 所示，其中，圆形态、长宽比、矩形态、凹度、偏心率、半径比为输入层的向量；孤岛状、网络状、条带状、柱状、塞状、膜状为输出层的向量； W_{ij} 为网络输入层与隐含层之间的权值； B_j 为隐含层各个神经元的阈值； T_{jk} 为网络隐含层与输出层之间的权值； Q_k 为输出层各个神经元的阈值； $f(\bullet)$ 为激活函数，该网络的激活函数使用 Sigmoid 型函数^[11-12]。




Fig.4 Topology of remained oil shape classifier
图 4 剩余油形态分类器拓扑结构

在上述神经网络拓扑结构的前向传播过程中, 隐含层第 j 个节点的输出 y_j , 以及输出层第 k 个节点的输出 O_k 的计算公式如式(17)、式(18)所示:

$$y_j = f(\sum_{i=1}^M w_{ij}x_i + B_j) \quad (17)$$

$$O_k = f(\sum_{j=1}^N T_{jk}y_j + Q_k) \quad (18)$$

误差反向传播过程中, 首先从输出层开始逐层计算各层各节点的输出误差, 然后根据输出误差梯度下降法来调整各层之间的权值和阈值, 以使输出能够接近于期望输出值。其中, 误差函数 E_p 计算公式如式(19)所示。

$$E_p = \frac{1}{2} \times \sum_{i=0}^L (t_{pi} - O_{pi})^2 \quad (19)$$

式中: t_{pi} 为第 i 个节点的期望输出值; O_{pi} 为第 i 个节点计算输出值。

由式(19)可知误差函数是 2 层权值的函数, 因此通过调整权值可以使误差不断减小。输出层权值变化如式(20)所示, 隐含层权值变化如式(21)所示。

$$\Delta T_{jk} = -\eta \frac{\partial E}{\partial T_{jk}} \quad (20)$$

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (21)$$

式中: $\eta \in (0,1)$ 为比例系数, 反应训练中的学习效率。

利用输出层权值变化值和隐含层各神经元的输出来修正权值 T_{jk} , 再利用隐含层权值变化值和输入层各神经元的输出修正权值 w_{ij} 。最后判断误差函数是否满足要求。当误差达到预设值的精确度或者学习次数大于设定的最大次数, 则算法结束。否则, 选取下一个学习样本及对应的期望输出, 进入下一次学习。

基于以上分类器拓扑结构, 本文设定分类器系统精确度为 10^{-6} , 最大学习次数为 10 000, 使用了 30 个样本对网络进行训练。将样本库中 30 组样本的形态特征向量输入到 BP 神经网络中, 然后自适应训练学习。当该神经网络的误差值小于提前设定好的系统精确度值或训练次数达到最大学习次数时, 训练结束。最后, 得到训练好的 BP 神经网络结构参数值。

4 剩余油形态识别实验结果

在样本训练完成之后, 该神经网络的连接权值和阈值都已确立, 可以对未知剩余油形态进行分类识别。将未知样本的形状特征向量作为网络输入值, 通过该网络的前向传播过程可以得到输出向量, 该输出向量各分量对应于事先设定的各个形态类别的期望值, 根据输出结果与每类的期望值进行对比, 将其归为误差最小的一类。实验使用了 $4\text{ cm} \times 4\text{ cm}$ 的玻璃刻蚀模型, 先后通过饱和油、水驱油以及氮气驱油进行驱替实验。当驱替实验进行到水驱后期阶段, 此时采收率基本不变。通过继续水驱替的方式, 孔喉中的残余油较难被驱替出来。为了提高驱油效率, 此时将水驱替更换为氮气驱替, 一直驱替到采收率基本保持不变。选取水驱后和氮气驱后的残余油图像进行形态识别。形态识别结果如图 5 所示。

对形态识别实验结果进行样本统计, 得到统计结果, 如表 1 所示。

表 1 实验结果统计表
Tabel 1 Results of experiment

shape category of residual oil	number of test samples	number of correct identification	recognition rate/%
island	60	57	95.0
network	35	30	85.7
strip	28	22	78.6
column	25	23	92.0
plug	26	21	80.8
membrane	10	7	70.0
total	184	160	86.9

将表中的测试样本数与正确识别数量进行对比, 该网络对于孤岛状、柱状基本能正确识别, 对于网络状、条带状及塞状具有较高的识别率, 对于膜状具有良好的识别率。从以上结果可以看出, BP 神经网络对于剩余油的形态能做出正确的识别。




Fig.5 Original image and the classification result diagram
图 5 实验原始图像和分类识别结果图

5 结论

剩余油形态分布，具有较强的模糊性和不确定性，而 BP 神经网络具有自学习、自适应、联想和模糊判断识别的能力。通过实验，BP 神经网络对剩余油的分类识别结果与其实形态基本一致。这说明 BP 神经网络在剩余油分布的分类识别上具有一定的可靠性。因此，利用 BP 神经网络对剩余油的形态进行快速正确判别，为油田制定出合理的继续开采方式提供重要的理论依据，提高油田驱油效率，具有很大的实际应用意义。

参考文献：

- [1] 陈淦. 发展三次采油的战略意义及政策要求[J]. 油气采收率技术, 1997,4(4):1-6. (CHEN Gan. The strategic significance of developing tertiary oil recovery and policy requirements[J]. Oil & Gas Recovery Technology, 1997,4(4):1-6.)
- [2] 蔡忠. 储集层孔隙结构与驱油效率关系研究[J]. 石油勘探与开发, 2000,27(6):45-49. (CAI Zhong. Study on the relationship between the reservoir pore structure and oil displacement efficiency[J]. Petroleum Exploration and Development, 2000,27(6):45-49.)
- [3] Benyamin Yadali Jamaloei, Riyaz Kharrat, Koorosh Asghari, et al. The influence of pore wettability on the microstructure of residual oil in surfactant-enhanced water flooding in heavy oil reservoirs: implications for pore-scale flow characterization[J]. Journal of Petroleum Science and Engineering, 2011,77(1):121-134.

- [4] 杨珂. 微观剩余油仿真模型研究[D]. 北京:中国石油大学, 2009. (YANG Ke. The simulation model study of microcosmic remaining oil[D]. Beijing:China University of Petroleum, 2009.)
- [5] Qren P E. Pore-scale network modeling of waterflood residual oil recovery by immiscible gas flooding[C]// Proceedings of the 9th Symposium on Improved Oil Recovery. Paris,France:European Association of Geoscientists and Engineers, 1994: 345-359.
- [6] 张伟. 聚驱后剩余油分布及影响因素分析[D]. 大庆:大庆石油学院, 2010. (ZHANG Wei. Distribution of remaining oil after polymer flooding and analysis of the influencing factors[D]. Daqing,Heilongjiang,China:Daqing Petroleum Institute, 2010.)
- [7] 李阳. 储层流动单元模式及剩余油分布规律[J]. 石油学报, 2003,5(3):52-55. (LI Yang. Flow unit mode and remaining oil distribution in reservoir[J]. Acta Petrolei Sinica, 2003,5(3):52-55.)
- [8] 李祥飞,邹恩,邹莉华. 前馈神经网络的混沌 BP 混合学习算法[J]. 控制与决策, 2004,19(4):462-464. (LI Xiang-fei, ZOU En,ZOU Li-hua. Chaos BP hybrid learning algorithm for feed forward neural network[J]. Control and Decision, 2004, 19(4):462-464.)
- [9] 周正杰. 基于形状的目标识别方法研究[D]. 长沙:国防科学技术大学, 2005. (ZHOU Zheng-jie. Study on object recognition based on shape[D]. Changsha,Hunan,China:National University of Defense Technology, 2005.)
- [10] 彭晓东,周泗忠,刘波,等. 惯量椭圆法在单站光测目标三维姿态测量中的应用[J]. 光子学报, 2007,36(3):568-573. (PENG Xiao-dong,ZHOU Si-zhong,LIU Bo,et al. Application of ellipse of inertia in measuring the objects 3D pose from mono-view[J]. Acta Photonica Sinica, 2007,36(3):568-573.)
- [11] 杨建刚. 人工神经网络实用教程[M]. 杭州:浙江大学出版社, 2001. (YANG Jian-gang. Practical course in artificial neural network[M]. Hangzhou,Zhejiang, China:Zhejiang University Press, 2001.)
- [12] LIN Ying-jian,CHEN Xiao-ji. BP neural network learning algorithm and its software implementation[J]. Applied Mechanics and Materials, 2014,513-517:738-741.

作者简介:



毛国庆(1987-), 男, 四川省绵阳市人, 在读硕士研究生, 主要研究方向为数字图像处理. email:maoguoqing@qq.com.

滕奇志(1961-), 女, 成都市人, 博士, 教授, 博士生导师, 主要研究方向为图像处理、模式识别.

吴 拥(1986-), 男, 四川省阆中市人, 在读硕士研究生, 主要研究方向为图像处理与图像通信.

何海波(1968-), 男, 成都市人, 高级工程师, 主要研究方向为图像处理与计算机应用.