

文章编号: 1006-6616 (2006) 04-0485-07

影响水力压裂效果的因素及人工神经网络评价

孙东生¹, 王红才^{1,2}, 侯 默³, 赵卫华¹, 宋清新², 刘振华², 牛淑芳²

(1. 中国地质科学院地质力学研究所, 北京 100081; 2. 胜利油田滨南采油厂, 山东 滨州 256606;

3. 武警沈阳指挥学院, 辽宁 沈阳 110113)

摘要: 水力压裂是低渗透油气田提高开采效益的主要技术手段之一, 但是影响水力压裂效果的因素较多, 如地质特征、储层物性和地层能量等。为了达到理想的压裂效果, 就要综合考虑各个影响因素之间的相互关系, 找出影响压裂效果的主要因素。本文利用人工神经网络方法建立了数学评估模型并对已有的大量生产数据进行了网络训练和方法验证。结果证明所建立的压裂井潜能评估模型稳定性好, 预测精度较高, 对油田水力压裂的选井评层及产能预测具有一定的指导意义。

关键词: 水力压裂; 影响因素; 人工神经网络; 压裂潜能评估

中图分类号: TE357.1

文献标识码: A

1 方法介绍

1.1 水力压裂

水力压裂是利用地面的高压泵组将高粘度压裂液泵入井中, 当压裂层段的液体压力达到一定值后, 裂缝开启, 随着支撑剂的(一般为陶粒)的添加, 逐渐形成一条高导流能力的添砂裂缝, 从而达到提高产量的目的。国内外对低渗透油藏水力压裂改造的研究最早可以追溯到20世纪50年代, 但是理论和应用上有所突破是在90年代以后^[1]。近些年来, 随着水力压裂技术成为重要的油气开采措施, 尤其是国内各大油田随着开采量和开采时间的不断增加, 很多老井都处于停产或半停产状态, 都进行了大量的压裂生产, 积累了大量的生产数据。又由于影响压裂效果的因素较多, 且其间关系及其复杂, 各影响因素与压裂效果之间不存在简单的线性函数关系, 而是复杂的非线性函数关系, 所以利用已有生产数据建立科学的压裂选井评价方法迫在眉睫。

人们对水力压裂效果预测方面做了一些研究, 如文[2]利用模糊神经网络对蒙古林砾岩油藏压裂效果进行了预测; 文[3]利用人工神经网络进行了压裂效果的经济效益评价; 文[4]利用神经网络专家系统设计压裂施工参数等。本文利用带动量的前馈神经网络对某油田大量的压裂生产数据进行训练, 并对部分压裂效果进行了预测。

收稿日期: 2006-05-10

基金项目: 胜利油田滨南采油厂项目《地应力在重复压裂中的应用研究》(项目编号: YKB0508) 资助。

作者简介: 孙东生(1980-), 男, 在读硕士, 主要从事岩石力学、地应力、油田水力压裂等方面的研究。

1.2 人工神经网络

人工神经网络理论是 20 世纪 40 年代末诞生、80 年代中后期在世界范围内迅速发展起来的一个前沿研究领域,是模仿人脑智能、思维等功能的非线性自适应系统^[1-2]。它类似于生物系统,以神经元为基本运算单元,组成了一种互连的分布式存贮信息的计算智能信息处理系统,具有很强的自学习性和自组织性。尤其是基于误差反向传播算法的多层前馈神经网络可以以任意精度逼近任意的连续函数,对于水力压裂复杂的地质情况也表现出了极大的灵活性和自适应性^[5-6]。

1.2.1 网络模型

神经网络是由输入层、隐含层和输出层组成的,其中隐含层可以是一层或多层。网络结构中各层内神经元相互独立,相邻层之间的神经元完全连接,如图 1 所示。

对于神经网络而言,前一层的输出是后一层的输入,各层之间没有什么本质的差别,只是先后顺序的不同。由多个神经元组成的信息处理网络具有并行分布结构,每个神经元具有单一输出,并能通过连接权系数与其他神经元连接,一般来说,每个神经元的结构形式都是一样的,如图 2 所示^[2]:

- ① 对于每个节点 i 存在一个状态变量 X_i , 它所对应的输出变量为 T ;
- ② 在节点 i, j 之间存在一个连接权系数 W_{ij} ;
- ③ 每个神经元都存在一个阈值 θ_i ;
- ④ 输出是输入的加权经非线性函数 f 作用后得到的, 关系如下:

$$T = f\left(\sum_{i=1}^n X_i W_{ij} - \theta_i\right) \quad (1)$$




图 1 多层神经网络模型图
Fig.1 Multilayer neural network model




图 2 神经元结构图
Fig.2 Neural element structure

1.2.2 学习算法

人工神经网络与传统数学方法不同之处在于它的非线性,而神经网络的非线性能力主要来自于它的非线性作用函数,常用的函数有: sigmoid、arctan、sin、Gaussian 和 Cauchy,其中最常用的为 sigmoid 函数,它具有一定的阈值特性并连续可微。Sigmoid 函数为^[7]:

$$f(X) = \frac{1}{1 + \exp(-X)} \quad (2)$$

1.2.3 数据处理

数据处理包括数据单位和标准的统一及数据的归一化处理。由于压裂生产数据记录标准

和背景不同，因此很多数据不能作为神经网络的数据样本直接使用，必须进行单位和标准的统一。如不同压裂厚度对应着不同的加砂量，如果将加砂量直接应用将有失数据的真实性。同时为了防止“大数吃小数”的现象发生，在进行神经网络训练之前，首先对参与神经网络训练和预测的各个影响因素进行归一化处理，把所有数据都归一化到[0, 1]区间，即：

$$X_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \tag{3}$$

其中 $i = 1, 2, \dots, N$ ， N 为某个影响因素的数量， X_{\min} 和 X_{\max} 分别为某个影响因素的最小值和最大值。

2 影响因素

本文收集了某油田从 1970~2005 年间的油井压裂的生产数据，整理出影响水力压裂效果的因素主要有：有效厚度、孔隙度、渗透率、含油饱和度、含水率、加砂量和压裂前的产量。通过人工神经网络方法预测的结果为：有效增油量和有效期。其中压裂前产量是指压裂前一个月的平均日产量；有效增油量是指在有效期内的总产量；有效期是根据生产的动态数据画出的动态曲线决定的，如果油井压裂投产后产量很快就降下来，这时有效期就是从投产到停产的时间差；如果油井压裂投产后产量平稳，这时有效期就是从投产开始到产量下降到压裂前产量的时间。

生产上的数据受多种因素影响，包括压裂施工工艺、油田开发过程等。因此为了消除干扰因素的影响，对所收集的近 200 组样本进行了分析研究，最后筛选出了 61 组压裂数据样本。数据筛选的原则是^[8-9]：

- (1) 去掉压裂施工失败或压裂过程中出现施工问题的样本点；
- (2) 去掉样本特征量数据不全的样本点；
- (3) 去掉专家认为不合理的样本点；
- (4) 去掉两两影响因素交会图上偏远离散的样本点；
- (5) 去掉井距很小而压裂效果相差较大和井距很大而压裂效果相差很小的样本点。

经过数据的筛选和归一化处理，保证了各个影响因素之间有一定的相关性，如图 3 和图 4 所示。分别画出了有效厚度、加砂量与有效增油量之间的关系曲线，图中横坐标表示不同的压裂井。从图上可以看出，没有了离散较大的数据，而且从总体上看有效厚度、加砂量与有效增油量有着相同的趋势，即随着有效厚度和加砂量的增加，有效增油量也相应地增加，即保证了样本数据的有效性。另外，为了说明油田压裂效果预测中数据复杂的非线性关系，这里给出了与图 3、图 4 相




图 3 不同压裂井的有效厚度和有效增油量的统计
Fig.3 Statistics of the effective thickness and increased oil production in different hydrofracturing wells

对应的有效厚度、加砂量与有效增油量之间的关系图(图5、图6)。从图5和图6可以看出,有效厚度、加砂量与有效增油量之间的关系比较复杂,相关系数仅在0.1~0.4之间,所以根据传统的数学方法无法建立压裂影响因素和压裂效果之间的函数关系^[10]。

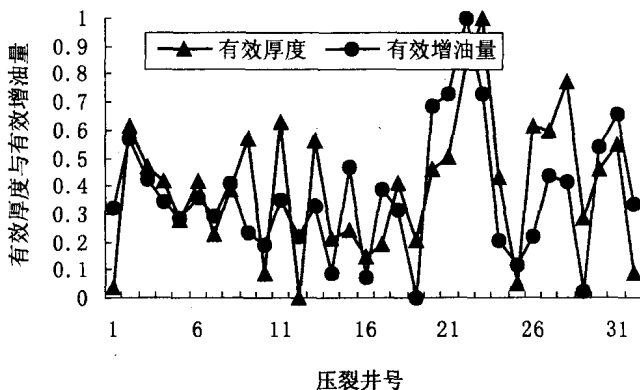


图4 不同压裂井的加砂量和有效增油量的统计

Fig.4 Statistics of added sand amount and effective increased oil production in different hydrofracturing wells




图5 有效厚度与有效增油量的关系

Fig.5 Relationship between effective thickness and effective increased oil production




图6 加砂量与有效增油量的关系

Fig.6 Relationship between added sand quantity and effective increased oil production

3 压裂潜能评估

3.1 网络构成

利用建立的压裂潜能人工神经网络模型,对整理出的数据样本进行网络训练和效果验证。对神经网络的训练来说,首先是输入层数、输出层数、隐含层节点数和隐含层个数的选取。文中所选用的网络输入层是:有效厚度、孔隙度、渗透率、含油饱和度、含水率和加砂量;输出层是:有效增油量、有效时间。隐含层节点数根据经验公式 $M = \text{Sqrt}(N + T) + a$ 选取,其中 M 为隐含层节点数, N 为输入层节点数, T 为输出节点数, a 为1~10之间的常数。网络中选择了两个隐含层并对算法进行了改进,这样可以加速学习速率和避免陷入局部最小。

3.2 网络训练

人工神经网络的训练是基于一组数据样本进行的，数据样本包括输入层数据和输出层数据，其中输入层和输出层具体多少个分量由具体应用情况而定，有多少个分量就有多少神经元与之对应。最初神经网络的权值（Weight）和阈值（Threshold）是随机给定的，网络的




图7 网络训练误差

Fig.7 Errors of network training

训练过程就是逐渐调整权值和阈值使网络的实际输出与期望输出一致。

下面利用整理好的数据样本进行压裂潜能评估系统的网络训练，通过调整隐含层的层数、学习率、训练方法和训练次数，经过多次的反复训练，最后使误差达到了预测的要求。图7是经过50000次的网络训练，网络的误差下降到了0.1022，达到了误差精度要求，可以进行网络预测。

3.3 应用实例

网络评估系统训练完成后，下面利用3组未参与训练的样本对该系统进行检验。表1为参与网络训练的部分压裂井数据，表2为压裂潜能评估系统的预测结果与实际结果的对比表。从表2可以看出，虽然预测的结果与实际结果有一定误差，但误差都小于19%，基本达到了人工神经网络预测的精度要求。

表1 部分压裂井数据

Table 1 Part of data of hydrofracturing wells and forecast results

| 样本类型 | 井号 | 有效厚度 /m | 孔隙度 /% | 渗透率 /10 ⁻³ μm ² | 含油饱和度 /% | 含水率 /% | 加砂量 /m ³ | 有效增油量 /t | 有效时间 /月 |
|------|-------|---------|--------|---------------------------------------|----------|--------|---------------------|----------|---------|
| 训练样本 | B-17 | 17.4 | 15.2 | 15.7 | 59 | 88 | 20 | 3124 | 13 |
| | B-21 | 21.8 | 20 | 45.4 | 54 | 15.7 | 29 | 2020 | 10 |
| | B-27 | 10 | 12.8 | 12.1 | 53.2 | 40.7 | 19.1 | 1138 | 5 |
| | B-31 | 31.1 | 15.2 | 11.7 | 62 | 98.5 | 23 | 1248 | 11 |
| | B-X22 | 14.7 | 21.7 | 11.2 | 27 | 94.8 | 15 | 706 | 11 |
| | B-27 | 14 | 7.381 | 1.24 | 55.5 | 96.4 | 16 | 1924 | 15 |
| | B-36 | 22.5 | 16.9 | 25.5 | 49 | 97 | 28.2 | 1625 | 11 |
| | B-X31 | 24.6 | 13.5 | 34.2 | 62 | 95 | 20 | 3121 | 17 |
| | B-X33 | 26.5 | 13.4 | 15.6 | 54 | 83.3 | 16.5 | 3298 | 16 |
| | L-7 | 24.8 | 8.76 | 3.6 | 74 | 41 | 20 | 2529 | 13 |
| | L-9 | 28 | 8.5 | 5.66 | 80 | 12.2 | 15.9 | 3004 | 21 |
| | L-13 | 23.5 | 4.5 | 1.7 | 69.2 | 72 | 8.8 | 1184 | 13 |
| | L-21 | 30.8 | 8.4 | 8.5 | 60 | 41 | 30 | 1237 | 10 |
| | L-25 | 37.2 | 8 | 8.4 | 63 | 43.1 | 26.3 | 2047 | 13 |

表2 压裂效果预测

Table 2 Forecast of hydrofracturing results

| 样本类型 | 井号 | 有效厚度 /m | 孔隙度 /% | 渗透率/ $10^{-3} \mu\text{m}^2$ | 含油饱和度 /% | 含水率 /% | 加砂量 / m^3 | 有效增油量/t | | 有效时间/月 | |
|------|-------|---------|--------|---------------------------------|----------|--------|--------------------|---------|------|--------|------|
| | | | | | | | | 实际 | 预测 | 实际 | 预测 |
| 测试样本 | B-16 | 24.9 | 15.2 | 11.7 | 59 | 87 | 20 | 2870 | 2369 | 12 | 9.7 |
| | B5-26 | 12.2 | 11.17 | 5.406 | 55.5 | 90 | 12 | 648 | 726 | 6 | 6.7 |
| | L-23 | 30.3 | 11 | 10 | 60 | 20.2 | 23.5 | 2125 | 1898 | 12 | 10.6 |

4 结论

(1) 压裂效果受多因素影响, 认真分析各因素之间的关系, 建立一个具有良好正交性和完备性的数据样本集是潜能评估网络模型具有通用性的基础和关键。

(2) 对于具有一定数量的压裂生产数据的油田来说, 利用人工神经网络方法可以最大范围地充分考虑各种影响压裂效果的因素, 为压裂施工设计的优化和优选井位提供依据。

(3) 人工神经网络方法是比较成熟的非线性数学方法, 在应用它进行水力压裂结果预测时, 关键是要提高收敛速度和防止陷入局部最小。本模型采用改进的 BP 算法, 有效地提高了运算速度和防止陷入局部最小。

参 考 文 献

- [1] 张士诚, 张劲. 压裂开发理论与应用 [M]. 北京: 石油工业出版社, 2003.
- [2] 刘洪, 赵金洲, 胡永全, 等. 用 T-S 模型模糊神经网络进行压裂效果预测 [J]. 断块油气田, 2002, 9 (3): 35~38.
- [3] 位云生, 胡永全, 赵金洲, 等. 人工神经网络方法在水力压裂选井评层中的应用 [J]. 断块油气田, 2005, 12 (4): 42~44.
- [4] 范学平, 徐向荣, 李西林. 用神经网络专家系统设计压裂施工参数 [J]. 钻采工艺, 1999, 22 (6): 26~28.
- [5] 袁曾任. 人工神经网络及其应用 [M]. 北京: 清华大学出版社, 1999.
- [6] 朱明程, 徐健, 李昆华. 采用 MCU 多层神经网络模型设计探讨 [J]. 东南大学学报, 2000, (2): 21~26.
- [7] Al-Fattah SM, Startzman RA. Neural Network Approach Predicts U. S. Natural Gas Production [R]. SPE82411, 2003, 84~91.
- [8] 杜卫平. 重复压裂选井选层人工神经网络方法 [J]. 钻采工艺, 2003, 5 (4): 106~108.
- [9] 曾顺鹏, 范学平, 杨秀文. 神经网络专家系统在压裂选井选层中的应用 [J]. 特种油气田, 1997, 4 (3): 42~46.
- [10] 王大力, 陈玉英. 前馈神经网络用于压裂效果预测 [J]. 石油物探, 2000, 39 (3): 121~126.

FACTORS INFLUENCING THE EFFECTS OF HYDROFRACTURING IN A LOW-PERMEABILITY OILFIELD AND POTENTIAL EVALUATION USING ARTIFICIAL NEURAL NETWORK

SUN Dong-sheng¹, WANG Hong-cai^{1,2}, HOU Mo³, ZHAO Wei-hua¹

SONG Qing-xin², LIU Zhen-hua², NIU Shu-fang²

(1. *Institute of Geomechanics, Chinese Academy of Geological Science, Beijing 100081, China;*

2. *Binnan Oil Production Plant, Shengli Oilfield, Binzhou 256606, Binzhou 256606, Shandong, China;*

3. *Shenyang Command College of the Chinese Armed Police Forces, Shenyang 110113, Liaoning, China)*

Abstract: Hydrofracturing is one of the main technical means for improving the recovery efficiency in low-permeability oil/gas fields. However, there are many factors that influence the hydrofracturing effects, including geological characteristics, physical properties of reservoirs and energy of strata. In order to obtain ideal hydrofracturing results, it is necessary to give a comprehensive consideration of the relationships between various influence factors and find out the main factors that influence the hydrofracturing effects. The authors constructed a mathematic evaluation model by using the artificial neural network method and performed net training and method check and verification of a wealth of available production data. The results prove that the constructed potential evaluation model using hydrofracturing wells has good stability and a high precision of prediction. It has certain guiding significance for choosing wells and evaluating layers for hydrofracturing and forecasting of the production capacity.

Key words: hydrofracturing; influence factor; artificial neural network; potential evaluation