

文章编号:1673-8217(2010)03-0053-03

基于 Levenberg-Marquardt 算法的 油田产量预测模型

翟亮亮¹,王连堂²,王俊杰³

(1. 西安石油大学理学院,陕西西安 710065;2. 西北大学数学系;3. 思茅师范高等专科学校)

摘要:针对标准的 BP 神经网络存在的缺陷,采用基于 Levenberg-Marquardt 算法改进的神经网络,建立了油田产量预测的模型,并分析了各种参数对油田产量的影响。

关键词:油气田产量预测模型;神经网络算法;参数分析

中图分类号:TE318

文献标识码:A

近年来国内外学者应用神经网络方法对各种类型的预测问题开展了大量的研究^[1-3]。文献[4]通过对影响产能的各种因素进行了综合分析,采用多元线性回归得出它们之间的关系式,从而反映了油层的产能情况,但油田产量与其影响因素不是简单的线性关系,而是复杂的非线性随机关系。本文通过对油井初期产量与油层物性实际资料进行分析和取样,对 BP 神经网络算法进行了改进,利用神经网络的非线性映射和泛化能力,通过训练,建立了油田产量预测模型,并为实际计算提供了一条有效的途径。

1 BP 神经网络算法及改进

1.1 标准 BP 神经网络算法

标准 BP 算法是一种有导师指导的学习算法。该算法的学习过程由正向传播和反向传播两部分组成,在正向传播过程中,输入模式从输入层经过隐含层神经元的处理后,传向输出层,每一层神经元的状态只影响下一层神经元状态。如果在输出层得不到期望的输出,则转入反向传播,此时误差信号从输出层向输入层传播并沿途调整各层连接权值和阈值,以使误差不断减小,直至达到精度要求。该算法实际上是求误差函数的极小值,它通过多个样本的反复训练,采用梯度下降法使权值沿着误差函数负梯度方向改变,并收敛于最小点。

1.2 Levenberg-Marquardt 算法

众所周知,梯度下降法最初下降较快,但随着接近最优值,由于梯度趋于零,致使误差函数下降缓慢,而牛顿法则可在最优值附近产生一个理想的搜索

方向。Levenberg-Marquardt,实际上是梯度下降法和高斯牛顿法的结合,它的优点在于网络权值数目较小时收敛非常迅速。它比传统的 BP 及其他改进算法(如共轭梯度法,附加动量法,自适应调整法等)迭代次数少,收敛速度快,精度高^[5]。

其基本思想是使每次迭代不再沿着单一的负梯度方向,而是允许误差沿着恶化的方向进行搜索,同时通过在最速梯度下降法和高斯牛顿法之间自适应调整来优化网络权值,使网络能够有效收敛,这样大大提高了网络的收敛速度和泛化能力。其权值调整公式为

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (1)$$

式中: e ——误差向量, J ——误差对权值微分的雅可比矩阵, μ ——一个标量,当 μ 增加时,它接近于具有较小的学习速率的最速下降法,当 μ 下降到 0 时,该算法就变成高斯-牛顿法了。因此, L-M 算法是在最速下降法和高斯-牛顿法之间的平滑调和。

1.2.1 L-M 算法具体迭代步骤

(1)将所有输入送到网络并计算出结果,另用误差函数计算出所有目标的误差平方和。

(2)计算出误差对权值微分的雅可比矩阵。首先,定义 Marquardt 敏感度:

$$S_i^m = \frac{\partial E}{\partial n_i^m} \quad (2)$$

从(2)式可以看出,敏感度为误差函数 E 对 m 层输入的第 i 个元素变化的敏感性,其中, n 为每层

收稿日期:2009-12-08;改回日期:2010-01-21

作者简介:翟亮亮,讲师,1980年生,2008年毕业于西北大学应用数学专业,主要研究领域为数学物理反问题和测井方法。

网络的加权和。敏感度的递推关系式为

$$S_q^m = E(n_q^m)(w^{m+1})^T S_q^{m+1} \quad (3)$$

可见,敏感度可由最后一层通过网络被反向传播到第一层:

$$S^m \rightarrow S^{m-1} \rightarrow \dots \rightarrow S^2 \rightarrow S^1 \quad (4)$$

然后,用(4)计算雅可比矩阵的元素:

$$[J]_{h,1} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = S_i^m \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = S_i^m a_{j,q}^{m-1} \quad (5)$$

(3)用式(1)求出 Δw 。

(4)用 $w + \Delta w$ 重复计算误差的平方和。如果新的和小于步骤(1)中的和,则用 μ 除以 θ ($\theta > 1$),并有 $w = w + \Delta w$,转向步骤(1),否则,用 μ 乘以 θ ,转向步骤(3)。当误差平方和减小到某一目标误差时,算法即被认为收敛。

2 建立预测模型

(1)输入参数的确定。输入参数的选取主要考虑油井初期产量的影响因素,同时还要考虑这些数据的可采集性。研究中选取了以下4个参数作为神经网络的输入:有效厚度、渗透率、孔隙度、含水饱和度。

(2)输出参数的确定。对于本研究而言,输出参数只有一个,即油井产量。

(3)网络层数的确定。由于只有一个隐含层的三层前向神经网络,且以任意精度逼近任意非线性映射的能力,所以本研究采用三层神经网络。

(4)激励函数的确定。激励函数是神经网络中

极为重要的参数。在应用 BP 算法的多层前向网络中,采用的是 Sigmoid 函数。

(5)隐含层节点数的确定。隐含层神经元数代表网络输入与输出之间的非线性程度,对模型训练速度和预报能力有着重要影响。由于输入向量有4个元素,所以网络的输入层的神经元有4个,根据 Kolmogorov 定理知,网络中间层的神经元可取9个。

3 模型检验

考察安塞油田某区块的20口油井^[4],选取其中15口油井的原始数据作为训练样本,另外选取5口油井作为测试数据。为了消除量纲的影响,对原始数据做归一化处理使其在区间[0,1]之间变化,研究采用的归一化公式为:

$$\hat{x} = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (6)$$

网络训练结束后,须对归一化的数据进行反归一化,得到实际数据。

利用 Matlab 编制程序^[6],建立具有4个输入节点,9个隐层节点,1个输出节点的神经网络,精度选为0.001,训练步数定为2000,并对实际数据进行仿真,两种仿真结果见表1。从中可以看出,采用 BP 神经网络和 L-M 神经网络算法训练时,收敛速度都很快,比较而言,L-M 神经网络算法,在网络训练和网络测试中的相对误差比 BP 神经网络算法误差要小。

表1 油井初期产量的训练与预测

	有效厚度/m	渗透率/ $10^{-3} \mu\text{m}^2$	孔隙度/%	含水饱和度/%	日实际产液/ m^3	BP神经网络 计算值/ m^3	BP神经网络计 算值相对误差	L-M神经网络计 算值/ $(\text{m}^3 \cdot \text{d}^{-1})$	L-M神经网络 计算值相对误差
训练样本	14.6	1.444	11.7	61.1	8.33	8.21	0.0144	8.3612	0.0037
	17.8	3.527	12.2	49.9	8.97	9.01	0.0044	8.9524	0.0002
	7.20	2.552	12.5	58.1	8.77	8.52	0.0285	8.7956	0.0029
	16.2	0.879	12.3	60.5	4.25	4.31	0.0141	4.2174	0.0077
	15.4	1.750	13.5	56.5	5.8	5.69	0.0189	5.8525	0.0091
	9.80	2.446	13.1	51.2	5.56	5.61	0.0089	5.5578	0.0004
	4.60	1.467	12.2	51.0	3.29	3.31	0.0060	3.3146	0.0075
	11.0	1.332	11.5	48.1	7.48	7.51	0.0040	7.4671	0.0017
	8.40	3.211	13.1	52.3	5.71	5.56	0.0262	5.7234	0.0023
	12.4	2.714	12.8	54.9	9.68	9.84	0.0165	9.6812	0.0001
	7.80	2.233	13.4	53.4	4.28	4.52	0.0560	4.2756	0.0001
	10.2	1.452	12.3	55.9	8.09	8.24	0.0185	8.1024	0.0015
	12.4	1.424	11.6	50.5	9.28	9.37	0.0096	9.3125	0.0035
	13.2	1.994	11.8	52.3	6.49	6.61	0.0184	6.5024	0.0019
	11.8	2.015	13.9	49	5.64	5.76	0.0212	5.6213	0.0033
测试样本	11.0	1.559	12.3	55.7	6.27	6.56	0.0462	6.31	0.0063
	8.40	3.036	13.6	53.1	8.84	8.54	0.0339	8.79	0.0056
	8.60	2.161	12.6	55.7	6.07	6.27	0.0329	6.41	0.0056
	12.6	1.833	13	60.1	3.89	3.67	0.0565	4.04	0.0385
	19.8	2.274	11.8	59.3	6	6.41	0.0683	6.26	0.0433

4 预测产量参数分析

选择前 4 个参数进行分析。利用训练好的 L-M 神经网络模型,其他参数不变,只改变一个参数来分析对油井产量的影响^[7]。

4.1 有效厚度对产量的影响

渗透率为 $2.1 \times 10^{-3} \mu\text{m}^2$,孔隙度为 12.6%,含水饱和度为 52.6%,有效厚度分别为 4.6、4.8、5.8、6.4、6.8、7.2、7.6、8.4、9.6 m。利用训练好的 L-M 神经网络计算油井的产量,油井产量和有效厚度的关系曲线如图 1,从中可以看出,在其他参数不变的情况下,有效厚度和产量之间的关系为非线性曲线,产量随着有效厚度的增加而增加。但当有效厚度过大时,它对产量的影响不是很显著。

4.2 渗透率对产量的影响

有效厚度为 11.2 m,孔隙度为 12.3%,含水饱和度为 55.7%,渗透率分别为 1.332 、 1.467 、 1.559 、 1.699 、 1.836 、 2.161 、 2.331 、 2.446 、 $2.795 \times 10^{-3} \mu\text{m}^2$ 。利用训练好的 L-M 神经网络计算油井的产量,油井产量和渗透率的关系曲线如图 2,从中可以看出,在其他参数不变的情况下,有效厚度和产量之间的关系大致为线性的,产量随着渗透率的增加而增加。




图 1 有效厚度对产量的影响




图 2 渗透率对产量的影响




图 3 孔隙度对产量的影响




图 4 含水饱和度对产量的影响

4.3 孔隙度对产量的影响

有效厚度为 10.2 m,渗透率为 $1.559 \times 10^{-3} \mu\text{m}^2$,含水饱和度为 57.9%,孔隙度分别为 11.5%、11.8%、12.2%、12.5%、12.8%、13.1%、13.4%、13.6%、13.8%,利用训练好的 L-M 神经网络计算油井的产量,油井产量和渗透率的关系曲线如图 3,从中可以看出,在其他参数不变的情况下,有效厚度和产量之间的关系大致为线性的。产量随着孔隙度的增加而减少。

4.4 含水饱和度对产量的影响

有效厚度为 11.8 m,渗透率为 $1.476 \times 10^{-3} \mu\text{m}^2$,孔隙度为 13.7%,含水饱和度分别为 50.1%、52.3%、53.1%、54.9%、55.7%、56.2%、58.1%、59.2%、60.5%,利用训练好的 L-M 神经网络计算油井的产量,油井产量和渗透率的关系曲线如图 4,从中可以看出,在其他参数不变的情况下,含水饱和度和产量之间的关系为非线性曲线,产量随着含水饱和度的增加而减少。

5 结论

(1) 采用改进的 BP 神经网络对油井产量进行预测,具有较高的精度。同时,该神经网络具有很好

2006年10月,在全块开展整体部署方案设计,确定正方形井网、180 m井距,对齐37块进行整体部署,并确定了反九点法平稳注水开发模式,共部署油井9口,注水井3口,第二批部署井已经完钻投产11口,先期全部采油,初期平均单井日产油11.6 t,目前日产油47.6 t,累计产油2 3421.7 t。

4 结论

(1)深层低渗透难采区块地质特征研究是实现储量向产量转化的基础,它需要一个反复评价研究的过程。

(2)齐37块评价及实现有效开发难采储量的关键是应用三维地震精细处理、解释技术、井震结合技术重新落实构造;应用储层反演技术预测储层分布;建立完善的试油试采机制,为油层潜力评价提供依

据。

(3)通过评价部署研究,齐37块实现全面开发,在一定程度上缓解了资源紧张的矛盾,为同类型油藏评价提供了借鉴。

参考文献

- [1] 张为民,薛培华. 探明未开发储量的灰色评价方法[J]. 石油学报,1999,20(4):29-33
- [2] 李道品. 低渗透油田高效开发决策论[M]. 北京:石油工业出版社,2003:182-198
- [3] 阴艳芳. 水平井技术在薄层低渗透油藏开发中的应用[J]. 石油地质与工程,2007,21(6):50-52

编辑:彭 刚

.....

(上接第55页)

的泛化性能,能够满足油井产量参数分析的要求。

(2)各种参数对油井产量的影响规律不同。有效厚度、含水饱和度和油井产量的关系为非线性曲线;渗透率、孔隙度和油井产量的关系近似为线性关系。

(3)本研究是在一定的区块和地质背景下建立起来的,实用范围仅仅局限于此区块的勘探开发,而对于其他区块,还必须根据自身的地质背景,物性资料确定相应的神经网络模型,所以该模型的使用有一定的局限性。

参考文献

- [1] Chan W, T, chow Y K, liu L F. Neural network: an alternative to pile driving formulas [J]. Computers and Geotechnics, 1995, 17(2):135-1561

- [2] Lee I M, lee J H. Prediction of pile bearing capacity using artificial neural networks [J]. Computers and Geotechnics, 1996, 18 (3):189-200
- [3] 王光兰. 遗传算法在油田产量预报中的应用[J]. 西南石油学院学报, 2000, 22(2):34-35
- [4] 李栓豹,陈雷. 多元线性回归在安塞油田产量预测中的应用[J]. 承德石油高等专科学校学报, 2004, 4(6):27-31
- [5] 马立平,仁宝生. 油田产量灰色神经网络混合预测模型研究[J]. 石油天然气学报, 2008, 30(5):129-133
- [6] 张德丰. MATLAB神经网络应用设计[M]. 北京:机械工业出版社, 2008:20-30
- [7] 陈铁冰. 基于神经网络的混凝土预制桩单桩竖向极限承载力参数分析[J]. 公路交通科技, 2007, 24(11):87-91

编辑:刘洪树