

# 基于改进BP算法的摩阻因数预测方法研究

申静波<sup>1</sup>, 闫铁<sup>2</sup>, 李井辉<sup>1,2</sup>, 孙丽娜<sup>1</sup>

(1. 东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318;  
2. 东北石油大学 油气钻井技术国家工程实验室, 黑龙江 大庆 163318)

**摘要:**在钻井工程设计与实钻过程中,恰当指定摩阻因数是准确预测摩阻、扭矩的前提条件,摩阻因数受众多因素影响且具有不确定性,很难利用普适的数学公式明确表达摩阻因数及其影响因素之间的关系。针对摩阻因素的特点,提出了采用改进的BP神经网络对钻柱力学分析中的摩阻因数进行计算的方法。首先研究BP算法的原理和数学表示,然后结合预测实际将增加动量项、自适应学习率等方法对其进行改进,最后根据摩阻因数的内涵建立以改进BP算法为基础的摩阻因数预测模型。实验结果表明,利用改进BP神经网络能够有效实现摩阻因数的准确预测,解决了钻井过程中普遍存在的摩阻因数个体差异问题。

**关键词:**神经网络;摩阻因数;BP算法;摩阻扭矩

中图分类号:TP391.9

文献标识码:A

文章编号:1673-629X(2018)01-0164-05

doi:10.3969/j.issn.1673-629X.2018.01.035

## Research on Friction Coefficient Prediction Based on Improved BP Algorithm

SHEN Jing-bo<sup>1</sup>, YAN Tie<sup>2</sup>, LI Jing-hui<sup>1,2</sup>, SUN Li-na<sup>1</sup>

(1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China;  
2. National Engineering Laboratory of Oil and Gas Drilling Technology, Northeast Petroleum University, Daqing 163318, China)

**Abstract:** In the process of drilling engineering design and drilling, the reliable friction coefficient should be provided to predict the drag and torque accurately. The friction coefficient is influenced by many factors with uncertainty, so it is difficult to express the relationship between friction coefficient and its factors. According to the characteristics of friction coefficient, we propose a method for computing friction coefficient in drilling string mechanics analysis by BP neural network. Firstly, we research the principle and mathematical representation of BP algorithm, and then improve it with addition of momentum and adaptive learning rate combined with the actual situation. Finally, the friction coefficient prediction model based on improved BP algorithm is established under the connotation of friction coefficient. The simulation shows that the improved BP neural network can be used to improve the prediction accuracy of friction coefficient, which solves the individual difference of friction coefficient in the drilling process.

**Key words:** neural network; friction coefficient; improved BP algorithm; drag and torque

## 0 引言

钻柱摩阻扭矩是油气井钻柱力学分析的核心问题,随着钻井技术的发展和井型的不断增加,对钻柱力学分析和计算要求逐渐增高。人们对钻柱摩阻扭矩问题进行研究,建立了相应的力学分析模型<sup>[1-3]</sup>。然而,无论是哪一种理论模型,都是在一定的假设条件下建立起来的,都不能十分精确地描述钻柱的受力。一般来说,在摩阻力计算中,不同模型之间的计算误差要比

由于摩阻因数不准确引起的误差小得多,因此,切合实际地提供摩阻因数是十分关键的问题<sup>[4]</sup>。在钻井工程领域,室内实验直接测定井眼摩阻因数因难于模拟井眼真实状况造成所获取的摩阻因数存在实用性问题,而采取实钻数据迭代反算摩阻因数方式或依据经验不能精确获取摩阻因数及反映井型与实钻过程<sup>[5-6]</sup>,不可避免地带来了实际应用问题。摩阻因数受井壁表面形貌、钻柱的局部弯曲、井眼迂曲度、钻井液性能、地层

收稿日期:2017-01-02

修回日期:2017-05-17

网络出版时间:2017-10-19

基金项目:国家科技重大专项(2016ZX05020-006);国家自然科学基金(51374077)

作者简介:申静波(1974-),女,硕士,副教授,研究方向为人工智能、机器学习、图像处理等。

网络出版地址: <http://jns.cnki.net/kcms/detail/61.1450.TP.20171019.1559.016.html>

孔隙压力、井眼形状等重要因素的综合作用、影响,反算出的摩阻因数的大小不仅反映了钻柱和井壁的表面状况,也含有泥浆粘滞作用、井眼异常情况(如岩屑床、缩径、键槽等)、钻具台肩的阻挡作用、钻头泥包等的影响。因此,该摩阻因数实际为一个以摩擦为主的综合阻力因数<sup>[4]</sup>。摩阻因数与其影响因素之间的关系是非线性的,且各因素之间相互影响和制约,因此摩阻因数的获取成为一个复杂的非线性多因子问题。

人工神经网络具有的并行处理、自适应自组织、联想记忆、较强容错性和鲁棒性、良好的逼近任意复杂非线性系统能力等优点,使其在钻井领域大量应用,很多学者对此也展开了深入的研究和探讨,这在一定程度上摆脱了建立精确数学模型和数据来源局限性的困扰,为研究工作开辟新的思路<sup>[7-11]</sup>。神经网络的处理结果以权值的形式分布存储在矩阵中,权值矩阵描述了输入—输出模式映射关系,通过联想记忆和推广能力获取所需数据模式,实现人脑的学习、概括、推广能力,因此非常适合处理影响因素众多且作用机理复杂的数据处理<sup>[12]</sup>。人工神经网络在钻井工程领域是应用较为广泛的预测方法,其中以BP网络最为普遍<sup>[13]</sup>。摩擦系数的非稳定随机特征很难用具体的数学关系来进行描述,所以,在考虑力学分析模型及软件的输入参数获取的条件下,利用人工神经网络进行井眼综合摩擦因素的预测,充分利用神经网络方法在研究复杂问题方面的优势。其不只是一个理论公式的简单求解,特点在于模拟的大脑功能,对输入信息进行分析、判断和综合,从而得到了正确的分析和预测结果。

为此,文中在研究典型BP算法的原理、主要缺陷及改进方法的基础上,结合摩阻因数的特点和分析影响因素构成,基于具有单隐层的BP神经网络建立了以钻井液、井眼轨迹、工况、井身结构等为主体的参数体系与摩阻因数的多输入目标预测模型。改进的BP神经网络具有寻优能力强、收敛速度快等优点,且充分利用了钻井设计与施工过程中已积累的大量与此相关的数据,通过对钻井过程中蕴含于指定样本的表示状态特征的钻井状态参数的记忆、学习,就可使其本身具有对预测对象及其影响因素间变化关系的动态识别能力,实现了摩阻因数快速准确的计算和预测。

## 1 基于改进BP算法的神经网络模型的建立

### 1.1 Sigmoid 激发函数下的BP算法

BP神经网络(即采用BP算法的前馈神经网络)能够学习和存储输入—输出模式映射关系,且无需事前揭示描述该映射关系的数学方程。基本原理是输入信号通过隐含层传递于输出节点而产生实际输出信号,

根据网络输出与期望输出间的偏差反向逐步调整神经网络各层节点间的连接强度及阈值,使误差沿梯度方向下降。通过数据流前向计算和误差信号反向传播过程的交替进行,在权向量空间执行误差函数梯度下降策略,动态迭代搜索一组权向量,使网络误差函数达到最小值,从而完成信息提取和记忆过程<sup>[14]</sup>。

假设有 $P$ 个训练样本,对应的输入输出对为 $(X_k, T_k)$ ,网络实际输出向量为 $O_k$ , $\omega_{ji}$ 为前一层第 $i$ 个神经单元输入到后一层第 $j$ 个神经单元的权重,其中输入向量与输出向量维数分别为 $M$ 、 $N$ 。文中采用的单隐层BP神经网络结构模型的构成为:

(1)作用函数模型:反映了BP网络中下层输入对上层节点的刺激脉冲强度,可采用为 $(0,1)$ 内有一定阈值特性的连续可微的Sigmoid函数:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

(2)节点输出模型:用于计算隐层及输出层单元的激活值。

$$O_{kj} = f_j(\sum_i w_{ji} O_{ki} - \theta_j) \quad (2)$$

(3)误差计算模型:反映神经网络期望输出与计算输出之间误差大小的函数。

①输出层的计算训练误差为:

$$\delta_{kj} = O_{kj}(1 - O_{kj})(t_{kj} - O_{kj}) \quad (3)$$

②隐含层的计算训练误差为:

$$\delta_{kj} = O_{kj}(1 - O_{kj}) \sum_m \delta_{km} w_{mj} \quad (4)$$

(4)自学习模型:即神经网络的学习过程,调节连接下层节点与上层节点之间的权重矩阵和阈值的修正过程。

①权值调整为:

$$\omega_{kj}(t+1) = \eta \delta_{kj} O_{ki} = \omega_{ji}(t) + \eta \delta_j O_{ki} \quad (5)$$

②阈值修正为:

$$\theta_j(t+1) = \theta_j(t) + \eta \delta_j \quad (6)$$

BP神经网络学习与计算过程如下:

(1)初始化:对权值矩阵 $\omega$ 赋随机数,将样本模式计数器 $p$ 和训练次数计数器 $q$ 置1,误差 $E$ 置0,学习率 $\eta$ 设为 $(0,1]$ 区间内的小数,网络训练后达到的精度 $E_{\min}$ 设为一个正的小数。

(2)提供训练样本:输入训练样本对 $(X_k, T_k)$ ,按步骤(3)~(5)进行迭代。

(3)计算网络的实际输出及隐层单元的状态 $O_{kj}$ 。

(4)计算各层误差信号:利用三层感知器的BP算法权值调整量计算公式计算各层误差信号 $\delta_{kj}$ ,采用均

方根误差 $\delta_{\text{RME}} = \sqrt{\frac{1}{P} \sum_p (\delta_p)^2}$ 作为网络的总误差。

(5)调整各层权值:应用三层感知器的BP算法自

学习模型计算并调整各层权值中的各分量。

(6) 检查是否对所有样本完成一次轮训: 若  $p < P$ , 计数器  $p$ 、 $q$  加 1, 返回步骤(2), 否则转步骤(7)。

(7) 检查网络总误差是否达到精度要求: 如果采用  $E_{\text{RME}}$  作为网络的总误差, 若满足  $E_{\text{RME}} < E_{\text{min}}$ , 训练过程结束, 否则  $E$  置 0,  $p$  置 1, 返回步骤(2)。

## 1.2 BP 神经网络的改进方法

标准 BP 算法的改进可以从增加动量项、自适应调整学习速率等方面入手, 以缩短训练时间, 提高学习效率, 增加学习算法的可靠性<sup>[15-17]</sup>。

(1) 增加动量项的 BP 网络。

标准 BP 算法在调整网络权值时, 只考虑了本次调整时的误差梯度下降方向, 而没有考虑前一次调整时的误差梯度方向, 因而经常使训练过程发生振荡, 收敛缓慢。因此, 为了减小振荡, 提高网络的训练速度, 可以在对连接权值进行调整时, 按一定比例加上前一次学习时的调整量, 即动量项。带有动量项的连接权值调整是在传统 BP 算法误差调整的基础上引入动量项, 公式如下:

$$\Delta w_{kj}(t+1) = -\eta \frac{\partial E}{\partial w_{kj}} + \alpha \Delta w_{kj}(t) = \omega_{ji}(t) + \eta \delta_j O_{ki} + \alpha [\omega_{ji}(t) - \omega_{ji}(t-1)] \quad (7)$$

其中,  $\alpha \Delta w_{kj}(t)$  为动量项;  $t$  为学习次数;  $\alpha$  为动量系数,  $\alpha \in (0, 1)$ , 动量系数的典型取值为 0.95。

动量项总是力图使连接权值向着同一个方向进行, 可保证网络的平滑稳定, 抑制可能出现的振荡。同时, 动量项还避免了出现权值为零的情况, 有助于网络从误差曲面的局部极小值中脱离出来。

(2) 学习速率的自适应调整。

学习速率  $\eta$  是影响 BP 网络的关键因素之一。如果学习速率过大, 学习过程可能产生振荡, 导致网络不收敛; 如果学习速率过小, 学习算法的收敛速度慢, 导致网络训练时间过长。因此, 需要为 BP 算法选择一个“最佳”的学习速率。但是在实际应用中, 很难确定一个自始至终都合适的最佳学习速率。因此, 为了使学习速率达到“最佳”, 必须在训练过程中不断地调整。

自适应学习速率调整过程中总是在保证学习过程稳定性的基础上使学习速率  $\eta$  尽可能最大且每一步都在不断调整。在学习速率自适应调整算法中, 如果误差不断减小并趋向目标时, 说明误差修正方向正确, 此时可以增加学习速率; 如果误差不断增加并超过预先设定值, 说明误差修正方向错误, 此时应减小学习速率, 即: 万方数据

$$\eta(t+1) = \begin{cases} k_{\text{inc}} \eta(t) & E(t+1) < E(t) \\ k_{\text{dec}} \eta(t) & E(t+1) \geq kE(t) \\ \eta(t) & \text{other case} \end{cases} \quad (8)$$

其中,  $k_{\text{inc}}$  为学习速率增量因子, 用于增加学习速率;  $k_{\text{dec}}$  为学习速率减量因子, 用于减小学习速率。

文中结合附加动量项和自适应调整学习速率两种方法, 得到带动量项的自适应学习速率 BP 网络模型, 并利用该网络进行摩阻因数的预测。

## 2 基于改进 BP 算法的摩阻因数预测模型

摩阻产生的原因和影响因素的多面性决定了钻井摩阻系统的复杂性。影响摩阻因数的因素与构件的材料、表面的加工精度、润滑条件、工作环境各方面都有关系。摩阻因数受井壁表面形貌、钻柱的局部弯曲、井眼迂曲度、钻井液性能、地层孔隙压力、井眼形状等重要因素的综合作用、影响, 在诸多数据中确定并提取能够表征目标参数的特征参数, 是进行正确预测的关键一步。从钻井实际出发(考虑实用性和可操作性), 以相关摩阻力分析、极限延伸计算模型为基础, 综合分析钻井过程的影响因素, 遵循特征参数选用的敏感度高、稳定性好、对应性强、计算量小、易获取等原则, 确定影响因素并对影响因素进行合理表示, 以发现因素与目标参数的内在隐含关系和合理的表达。利用 BP 神经网络进行井眼摩阻因数预测的关键是正确选取输入特征向量和目标输出, 输入特征向量的选取应根据影响摩阻因数的具体因素来确定, 同时考虑影响因素之间的联系和参数的易获取性; 输出层节点数则依据实际情况设置为已钻井眼条件对带钻和正在施工的井眼的摩阻因数进行评价预测, 其节点数目为一个节点即可。

摩阻计算的准确性与钻柱单元的摩阻因数、几何形状、钻具的物理指标等因素密切相关, 影响摩阻扭矩的主要因素包括管柱与井壁和套管间的摩阻因数和正压力、井眼的水平长度和钻柱的每米重量、狗腿角和管柱中的轴向力、井眼曲率、管柱刚度和井眼与管柱的直径差、井眼清洁状况、粘卡、刮削等。解决摩阻扭矩问题的主要对策包括采用顶驱系统、优化经验轨道形状、提高泥浆润滑性能、严格控制实钻井眼轨迹以保证井眼光滑、采用强大的地面固相控制系统及短起下钻等各种措施保持井眼清洁、提高钻杆抗扭能力等。综合摩阻因数作为模型、钻具组合、井深结构、钻井液密度、井眼形状、地层因素、井眼清洁程度的综合反映, 形成了分析摩阻因数影响因素构成的基础。根据摩阻因数参数获取输入、输出特点和钻井实际要求, 经反复测试分析, 选取 7 个参数作为神经网络的输入: 工况、钻井液类型、造斜段井斜与方位变化率、套管段与裸眼段井

眼间隙、水平段长度。输入参数的选取充分反映了钻井过程中摩阻因数所具有的非稳定的随机特征。

确定的样本数据如表 1 所示。表中各参数采用公式  $x_{ki} = \frac{x_{ki} - x_{\min}}{x_{\max} - x_{\min}}$  进行归一化处理,归一化为 0~1.0 之间的有理数,用以消除量纲不同对网络学习过程造成

的影响<sup>[18]</sup>。动量系数的取值为 0.95,  $k_{inc}$ 、 $k_{dec}$  和  $k$  的参数值分别为 1.05、0.7 和 1.04。

3 预测结果及讨论

用训练好的改进 BP 网络对给定的检测样本数据进行检验,预测结果如表 2 所示。

表 1 基础样本数据

序号	工况	钻井液类型	造斜段参数		井眼间隙		水平段长度/m	摩擦系数(裸眼)	摩擦系数(套管)
			井斜变化率/(°/30 m)	方位变化率/(°/30m)	套管/mm	裸眼/mm			
1	上提	水基	6.52	4.696	64.47	31.75	—	0.29	0.22
2	下放	水基	7.85	1.526	131.88	44.45	150	0.35	0.30
3	旋转	水基	6.25	2.437	131.88	44.45	170	0.30	0.25
4	上提	油基	7.85	2.437	44.45	44.45	—	0.25	0.20
5	下放	油基	6.52	4.696	64.47	31.75	170	0.30	0.27
6	旋转	油基	6.52	4.696	64.47	31.75	150	0.25	0.22
7	上提	水基	6.52	4.696	64.47	31.75	170	0.27	0.21
8	下放	油基	7.85	1.526	64.47	44.45	—	0.25	0.26
9	旋转	油基	7.85	1.526	44.45	44.45	—	0.22	0.18
10	上提	水基	7.85	1.526	44.45	44.45	150	0.26	0.20
11	下放	水基	6.52	1.526	44.45	31.75	150	0.33	0.28
12	旋转	水基	6.52	4.696	131.88	31.75	150	0.30	0.25
13	上提	油基	6.52	4.696	64.47	31.75	—	0.18	0.15
14	下放	油基	7.85	1.526	131.88	44.45	150	0.20	0.15
15	旋转	水基	7.85	1.526	64.47	31.75	—	0.28	0.22
16	上提	水基	6.52	1.526	44.45	44.45	170	0.27	0.21
17	下放	水基	7.85	2.437	64.47	44.45	170	0.35	0.29
18	旋转	油基	6.25	2.437	131.88	44.45	170	0.25	0.20

表 2 改进 BP 算法预测结果

编号	摩阻因数(裸眼)	预测值(裸眼)	摩阻因数(套管)	预测值(套管)	编号	摩阻因数(裸眼)	预测值(裸眼)	摩阻因数(套管)	预测值(套管)
1	0.29	0.290 2	0.22	0.220 9	10	0.26	0.259 7	0.20	0.200 2
2	0.35	0.354 3	0.30	0.298 1	11	0.33	0.329 8	0.28	0.280 4
3	0.30	0.301 6	0.25	0.250 8	12	0.30	0.301 8	0.25	0.251 8
4	0.25	0.253 4	0.20	0.202 0	13	0.18	0.180 4	0.15	0.150 7
5	0.30	0.297 7	0.27	0.272 1	14	0.20	0.199 1	0.15	0.152 1
6	0.25	0.249 9	0.22	0.223 0	15	0.28	0.280 2	0.22	0.220 8
7	0.27	0.269 8	0.21	0.211 8	16	0.27	0.270 3	0.21	0.211 1
8	0.25	0.246 5	0.26	0.260 5	17	0.35	0.345 2	0.29	0.290 2
9	0.22	0.221 1	0.18	0.180 8	18	0.25	0.249 9	0.20	0.201 3

对于带动量项的自适应学习速率 BP 网络对给定样本的训练次数为 634,套管段摩阻因数的最大绝对误差为 0.003 9;裸眼段的最大绝对误差为 0.004 7;套管段数据

管段摩阻因数的最大绝对误差为 0.001 3,裸眼段的最大绝对误差为 0.004 8。

图 1 分别为套管摩阻因数和裸眼摩阻因数的计算



值和预测值的对比。根据结果对比可以看出,利用改进的 BP 网络进行摩阻因数的预测,具有较快的收敛速度和令人满意的预测精度,且改进了算法的全局收敛效果;实际值和预测值均有较好的吻合,能够很好地满足钻井现场施工作业要求。




图 1 套管与裸眼部分结果对比

#### 4 结束语

钻井过程是一个复杂非线性动态工作过程,存在着大量复杂和不确定的影响因素,很难用精确建模的方式建立适用于实际钻井过程的数学模型。文中在分析和探讨影响摩阻系数的组成要素及各要素的特点的基础上,利用改进的 BP 神经网络方法挖掘影响要素之间的作用方式,把各要素的工作特性与整体特性联系起来,建立摩阻因数及其影响要素之间不严重依赖于钻井系统内在机理的隐含关系模型,实现了摩阻因数的快速统计和预测,输出结果与实验结果之间误差较小,可满足钻井实际需求。预测模型不需要复杂的数学公式,能够与力学模型实现良好融合和有益补充,其应用可以扩展到钻井动力学及其以外的钻井控制和优化领域,能为钻井参数的优化等提供实时的咨询和主要钻井控制参数的量化修正建议。

#### 参考文献:

[1] LUBINSKI A, WOODS H B. Factors affecting the angle of inclination and dog-legging in rotary bore holes [J]. Drilling and Production Practice, 1953, 165(1): 222-242.

[2] JOHANCSEK C A, FRIESEN D B, DAWSON R. Torque and drag in directional wells prediction and measurement [J]. Journal of Petroleum Technology, 1984, 36(6): 987-992.

[3] 李子丰. 油气井杆管柱力学及应用[M]. 北京:石油工业出版社, 2008.

[4] 章浩炯, 刘运荣, 石晓兵, 等. 钻井摩阻因数分形预测模型研究[J]. 长江大学学报:自然科学版, 2012, 9(6): 55-57.

[5] 代奎, 阎铁. 水平井井眼摩阻因数的确定方法[J]. 大庆石油学院学报, 1995, 19(3): 5-8.

[6] 张建群, 孙学增, 赵俊平. 定向井中摩擦阻力模式及其应用的初步研究[J]. 大庆石油学院学报, 1989, 13(4): 23-28.

[7] 王江萍, 鲍泽富, 孟祥芹. 应用神经网络专家系统的钻井事故诊断[J]. 计算机应用, 2009, 29(1): 277-280.

[8] 刘天时, 赵越, 马刚. 基于 BP 神经网络的油气钻井成本预测[J]. 西安石油大学学报:自然科学版, 2010, 25(1): 87-90.

[9] 袁姝, 胡宏涛, 赵越. 贝叶斯正则化 BP 神经网络在油气钻井成本预测的应用[J]. 软件导刊, 2010, 9(12): 130-132.

[10] 阎铁, 毕雪亮, 刘春天, 等. 一种预测深井钻井速度的人工神经网络法[J]. 石油钻探技术, 2001, 29(6): 9-10.

[11] 陈潮. 钻井模拟中地层特征参数预测方法研究[D]. 北京:中国石油大学, 2007.

[12] 周启超. BP 算法改进及在软件成本估算中的应用[J]. 计算机技术与发展, 2016, 26(2): 195-198.

[13] 邢红杰, 哈明虎. 前馈神经网络及其应用[M]. 北京:科学出版社, 2016.

[14] 周开利, 康耀红. 神经网络程序及其 MATLAB 仿真程序设计[M]. 北京:清华大学出版社, 2011.

[15] 马永强, 霍振宇, 杨珠. 一种采用增加动量项的改进 BP 算法实现[J]. 科技情报开发与经济, 2006, 16(8): 157-158.

[16] 张景璐, 赵妍. 基于改进神经网络的光纤故障监测优化[J]. 激光杂志, 2016, 37(6): 131-134.

[17] 何文河, 李陶深, 黄汝维. 云环境下基于改进 BP 算法的入侵检测模型[J]. 计算机技术与发展, 2016, 26(2): 87-90.

[18] 王萍, 郭晶, 万凯, 等. 基于改进 BP 算法的纱线混纺比检测[J]. 天津工业大学学报, 2014, 33(6): 62-64.