

# 基于改进BP神经网络的地层划分方法

尚福华<sup>1</sup>, 李金成<sup>1\*</sup>, 原野<sup>2</sup>, 曹茂俊<sup>1</sup>, 杜睿山<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. 中国石油勘探开发研究院测井与遥感技术研究所, 北京 100083)

**摘要:**测井曲线分层是地球物理勘探利用测井资料了解地层情况首先要完成的基础工作。针对测井曲线自动分层问题,提出了一种基于改进BP神经网络的地层划分方法。首先针对三层BP神经网络模型,设计了改进的L-M算法以提升其逼近能力。然后设计了基于BP神经网络的地层划分方法。该方法精选了描述地层岩性类别的六个特征,将这些特征进行数据滤波和归一化后构造训练样本,实施网络训练,训练后的网络即可用于同类地区的地层划分。最后以辽河油田某区块的测井资料为基础数据进行地层划分,实验结果表明,与普通L-M算法比较,基于改进L-M算法的BP神经网络,地层划分结果的准确率大约提升3~5个百分点。因此,提出的基于改进BP神经网络的地层划分方法为测井曲线的自动分层提供了新思路。

**关键词:**地层划分;测井曲线;自动分层;L-M算法;神经网络

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2020)09-0148-06

doi:10.3969/j.issn.1673-629X.2020.09.027

## Stratigraphic Division Method Based on Improved BP Neural Network

SHANG Fu-hua<sup>1</sup>, LI Jin-cheng<sup>1\*</sup>, YUAN Ye<sup>2</sup>, CAO Mao-jun<sup>1</sup>, DU Rui-shan<sup>1</sup>

(1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China;

2. Research Institute of Petroleum Exploration and Development, PetroChina, Beijing 100083, China)

**Abstract:** Well logging curve stratification is the first basic work for geophysical exploration to understand the stratigraphic condition by using well logging data. In view of the problem of logging curves' automatic stratification, a method of stratigraphic division based on improved BP neural network is proposed. Firstly, in the light of the three layer BP neural network model, the improved L-M algorithm is designed to improve its approximation. Then the method of stratigraphic division based on BP neural network is designed. In this method, six features describing the lithologic classification of strata are selected. After constructing training samples out of the filtered and normalized data, the training of the neural network that can be used for stratigraphic classification in similar areas is carried out. Finally, the stratigraphic division based on the logging data of a block in Liaohe Oilfield is carried out. The experiment shows that compared with the common L-M algorithm, the BP neural network based on the improved L-M algorithm improves the accuracy of stratigraphic division by about 3% ~ 5%. Therefore, the proposed method provides a new idea for logging curves' automatic stratification.

**Key words:** stratigraphic division; logging curves; automatic stratification; Levenberg-Marquardt algorithm; neural network

## 0 引言

在地球物理勘探中需要利用测井资料了解地下地质情况,例如测井相分析、储层划分、储层参数研究等,其中测井曲线分层是首先要完成的基础工作<sup>[1]</sup>。测井曲线分层的方法主要包括两种:第一种是人工分层。根据测井曲线的形态以及人工经验来找曲线的半幅点,完成测井曲线分层工作<sup>[2]</sup>。这种方法比较依赖工作人员的经验,避免不了人为因素的影响;第二

种是自动分层,通过计算机技术与测井解释理论相结合,利用计算机自动处理的特性来进行测井曲线的自动分层。目前,通过测井曲线自动划分地层的方法有很多,主要分为三类:数理统计方法、非数理统计方法、人工智能方法<sup>[3]</sup>。其中,数理统计法主要包含层内差异法、极值方差法、有序聚类分析法等;非数理统计的方法主要包含测井曲线活度函数法、小波变换法、Fourier变换、Walsh变换等;人工智能方法则主要包括

收稿日期:2019-11-01

修回日期:2020-03-04

基金项目:国家重大科技专项(2017ZX05019-005);黑龙江省自然科学基金(LH2019F004)

作者简介:尚福华(1962-),男,博士,教授,CCF会员(07338S),从事人工智能、图像处理和油田智能软件等研究工作;李金成(1990-),男,硕士研究生,从事人工智能和油田智能软件等方面的研究工作。

模糊识别、神经网络等。文献[4-8]分别使用测井曲线自动分层方法进行地层的划分。

不论根据哪种资料,使用哪种方法进行地层的划分,都要遵守的原则为:

(1)小层要有一定规模的时空分布,避免把同一小层划分成若干层;

(2)小层划分的结果应使其内部具有相对统一性(或相对均一性),具有实用性;

(3)地层单位的上下界限在纵向上必须稳定,并且易于识别,保证分层的合理性和稳定性。

鉴于上述原则,文中以岩性类别作为地层划分的依据。岩性的突变的采样点为小层的分层点。因此,岩性的识别是文中工作的重点。文献[9-13]上论述的方法,虽然识别率较高,但是在训练速度和识别速度上均一般。

传统的 L-M 算法既有牛顿法的局部收敛性,又有梯度下降法的全局搜索特性。在学习的过程中,传统的 L-M 算法无法兼顾前期的全局探索与后期的局部开发,因此,针对算法的全局探索与局部开发的平衡问题,文中对 L-M 算法做出部分改进,并将改进后的算法应用于神经网络中。

综上所述,将以辽河油田某工区为实验区块,根据研究区块的区域特征建立了神经网络自动分层模型,学习算法使用改进的 L-M 学习算法。利用该模型对该层进行小层的精细划分,并对自动分层模型进行分析评价。

## 1 网络模型及学习算法

### 1.1 BP 网络基本原理

BP(back propagation)网络是1986年由 Rinehart 和 McClelland 为首的科学家小组提出的,是一种按误差反向传播算法训练的多层前馈网络,是目前应用最广泛的神经网络模型之一。它的学习规则是使用梯度下降法,通过反向传播来不断调整网络的权值和阈值,使网络的误差最小。经典型3层BP神经网络结构如图1所示,它是一个包含输入层、隐含层和输出层3层结构的多层前馈型神经网络。通过误差的反向传播及修正误差的方向,不断调整各层权值和阈值,使误差性能函数最小<sup>[14]</sup>。




图1 三层BP神经网络模型

令输入样本  $\mathbf{x}^l = [x_1^l, x_2^l, \dots, x_n^l]$ , 期望输出样本  $\mathbf{y}^l = [y_1^l, y_2^l, \dots, y_m^l]$ ,  $l = 1, 2, \dots, L$ ,  $L$  为学习样本个数, 隐层权值为  $w_{ij}$ , 输出层权值为  $v_{jk}$ 。网络的输入输出关系可描述为

$$y_k^l = f\left(\sum_{j=1}^p v_{jk} f\left(\sum_{i=1}^n w_{ij} x_i^l\right)\right) \quad (1)$$

其中,  $i = 1, 2, \dots, n; j = 1, 2, \dots, p; k = 1, 2, \dots, m; l = 1, 2, \dots, L$ 。

### 1.2 改进的 L-M 学习算法

L-M 算法是一种求解非线性最小二乘问题的有效方法。它是改变形式的牛顿法,既有牛顿法的全局搜索特性,又有梯度下降法的局部收敛性,从而使网络能有效收敛,特别适合于神经网络训练。记  $E = \max_{1 \leq l \leq L} \max_{1 \leq k \leq m} |e_k^l| = \max_{1 \leq l \leq L} \max_{1 \leq k \leq m} |\bar{y}_k^l - y_k^l|$ 。令  $h_j^l$  为第  $l$  个样本第  $j$  个隐层节点的输出,根据梯度下降法,隐含层连接权的梯度计算式为:

$$\frac{\partial e_k^l}{\partial w_{ij}} = - \sum_{k=1}^m y_k^l (1 - y_k^l) v_{jk} h_j^l (1 - h_j^l) x_i^l \quad (2)$$

$$\frac{\partial e_k^l}{\partial v_{jk}} = - y_k^l (1 - y_k^l) h_j^l \quad (3)$$

令  $\mathbf{X}$  表示参数向量,  $\mathbf{V}$  表示误差向量,  $\mathbf{J}$  表示雅可比矩阵,分别定义如下:

$$\mathbf{X}^T = [w_{11}, \dots, w_{np}, v_{11}, \dots, v_{pm}] \quad (4)$$

$$\mathbf{V}^T(\mathbf{X}) = [e_1^1, \dots, e_m^1, e_1^2, \dots, e_m^2, \dots, e_1^L, \dots, e_m^L] \quad (5)$$

$$\mathbf{J}(\mathbf{X}) = \begin{bmatrix} \frac{\partial e_1^1}{\partial w_{11}} & \dots & \frac{\partial e_1^1}{\partial w_{np}} & \frac{\partial e_1^1}{\partial v_{11}} & \dots & \frac{\partial e_1^1}{\partial v_{pm}} \\ \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_m^1}{\partial w_{11}} & \dots & \frac{\partial e_m^1}{\partial w_{np}} & \frac{\partial e_m^1}{\partial v_{11}} & \dots & \frac{\partial e_m^1}{\partial v_{pm}} \\ \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_1^L}{\partial w_{11}} & \dots & \frac{\partial e_1^L}{\partial w_{np}} & \frac{\partial e_1^L}{\partial v_{11}} & \dots & \frac{\partial e_1^L}{\partial v_{pm}} \\ \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_m^L}{\partial w_{11}} & \dots & \frac{\partial e_m^L}{\partial w_{np}} & \frac{\partial e_m^L}{\partial v_{11}} & \dots & \frac{\partial e_m^L}{\partial v_{pm}} \end{bmatrix} \quad (6)$$

根据 L-M 算法,网络参数调整的迭代方程为:

$$\mathbf{X}_{t+1} = \mathbf{X}_t - [\mathbf{J}^T(\mathbf{X}_t)\mathbf{J}(\mathbf{X}_t) + \mu_t \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{X}_t) \mathbf{V}(\mathbf{X}_t) \quad (7)$$

其中,  $t$  为迭代步数,  $\mathbf{I}$  为单位矩阵,  $\mu_t$  为一小正数,以使  $\mathbf{J}^T(\mathbf{X}_t)\mathbf{J}(\mathbf{X}_t) + \mu_t \mathbf{I}$  可逆。若  $E$  小于给定阈值,迭代中止。

为提高 L-M 算法的全局搜索和局部寻优的性能,文中对 L-M 算法做出部分改进。改进思路如下:

将  $\mu_t$  的值由一个固定的小正数改变为随着迭代次数递增变化,即将  $\mu_t$  初始值设置为  $\mu_0$ ,在迭代开始

使 L-M 算法更接近高斯牛顿法,从而进行大步的全局搜索;随着迭代次数的增加, $\mu$  的值也逐渐增大,使 L-M 算法更接近普通梯度下降法,从而进行小步的局部寻优。改进的 L-M 算法的全局探索能力和局部开发能力得到了有效的平衡,提高算法的搜索效率和寻优的准确性。为综合考察改进效果,文中采用如下几种递增模式。

(1) 线性模型。

$$y = ax + b, a > 0 \quad (8)$$

(2) 指数模型。

$$y = a^x, a > 1 \quad (9)$$

(3) 对数模型。

$$y = \log_a x, a > 1 \quad (10)$$

在充分考虑开发和探索阶段的平衡及多次仿真实验的基础上,最终将  $\mu$  的递增方式选择对数型。具体递增公式如下:

$$\mu_t = \mu_0 + \frac{\ln t}{T_{\max}} \quad (11)$$

其中, $\mu_0$  为初始小整数, $T_{\max}$  为最大迭代步数, $t$  为当前迭代次数。

## 2 基于 BP 神经网络小层划分模型

### 2.1 特征参数选择及小层类别确定

文中使用神经网络来研究地层小层的精细划分,以地层岩性作为划分的依据。相邻的岩性一致的采样点即可划分在同一层内,岩性的突变点可以作为小层划分的分层点。在构造地层划分神经网络模型前,需要先确定输入和输出,即特征参数和地层的类别。

根据测井资料集合专家经验解释,进行相关性分析及综合测试,寻求响应特征与地层类别之间的映射关系,从而选取对地层类别反映好的特征来构造特征参数样本<sup>[15]</sup>。一般情况下,自然伽马、自然电位等曲线对砂、泥岩及其粒度的变化反映灵敏,可以作为划分岩性的主要曲线。以辽河油田某区块为例,选取自然电位曲线、自然伽马曲线作为岩性划分的主要曲线,再参考电阻率、声波时差、密度、中子曲线特征,进行小层划分。因此,文中针对研究区块类型选取 AC、CNL、DEN、GR、RT、SP 为地层划分的输入特征参数。

根据神经网络运算特性,在进行地层小层划分之前需要利用所研究区块标准井的小层来进行样本训练。为构造网络训练的输出样本集,首先需要明确研究区块所包含的地层类别,即构造地层类别集合,该集合中的每个元素作为神经网络模型的期望输出。以辽河油田某区块为例,根据专家分析结果,研究区域所包含的地层类别(即岩性类别)可划分为细砂岩、泥岩、粉砂岩三类。

### 2.2 构造样本数据

选择经典的三层神经网络结构,根据上节的讨论,选取 6 个输入神经元对应 6 个特征参数:AC、CNL、DEN、GR、RT、SP,其中每个特征参数均为长度相同的离散数据点。因此,神经网络的输入的特征样本为一个 6 行  $N$  列的矩阵( $N$  为离散点个数)。期望输出样本为 3 维的  $\{0,1\}$  向量分别表示三类地层: $\{1,0,0\}$  表示细砂岩, $\{0,1,0\}$  表示粉砂岩, $\{0,0,1\}$  表示泥岩。

### 2.3 样本数据预处理

不同的测井曲线测量值的量纲不同,因此,需要经过预处理才可以输入神经网络模型使用。具体预处理方法包括:

(1) 无效值处理:具体针对测井曲线每一个采样点,如果该点测井曲线值为空或者是设置好的无效值,则删除掉该条样本。

(2) 各类别样本序列长度统一处理:为了实现各类样本的均衡,采用统计的方法,选取一个适合于绝大多数类别数据点的序列长度,以此为基准,通过插值的方法实施数据点的加密和抽稀,从而使所有地层类别的特征值的序列长度达到统一。

(3) 数据归一化处理:使用最大最小值归一化方法,公式如下

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

其中, $X'$  表示利用归一化方法计算后得到的测井曲线值, $X' \in [0,1]$ , $X$  表示归一化前的原始测井曲线数据, $X_{\max}$  表示原始测井曲线数据中的最大值, $X_{\min}$  表示原始测井曲线数据中的最小值。

### 2.4 基于 BP 神经网络小层划分过程

预处理后的样本数据即可用于 BP 神经网络的训练。基于改进 BP 神经网络地层划分的基本过程如图 2 所示。

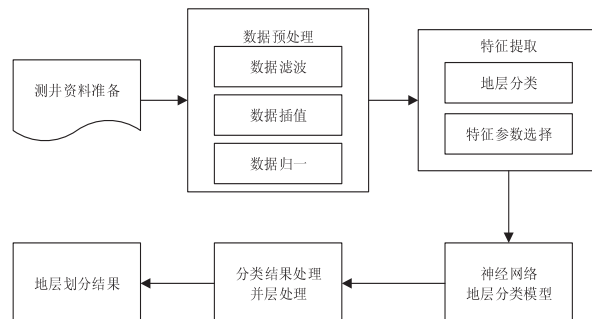


图 2 基于改进 BP 神经网络地层划分的基本过程

关于神经网络地层分类模型:输入节点等于特征数(6 个);由于当前研究区域地层类别分为 3 个类别,输出节点选择 3 个即可。隐含层的节点个数的选择至关重要,如果节点个数太少,则会导致训练结果很差,如果节点个数太多,则会造成训练时间较长,陷入局部

最小值。因此,对于隐含层节点个数的确定,采用经验公式:

$$H_n = \sqrt{I_n + O_i} + \alpha \tag{13}$$

其中,  $H_n$  表示隐含层节点数,  $I_n$  表示输入层节点个数,  $O_i$  表示输出层节点个数,  $\alpha$  表示 1 至 10 之间的整数。

由于在实际应用中网络的输入和输出的映射关系是非线性的,所以隐含层激活函数选择 tansig,输出层激活函数选择 logsig。BP 网络在实际的使用中利用改进的 L-M 算法的学习规则进行迭代训练,将网络的实际输出与期望输出的均方差作为网络的损失函数。训练好的网络即可用于地层的划分。

关于神经网络模型分类结果的处理:对于训练后的神经网络,在预测的过程中输出的可能不是标准型,因此需要对预测输出进行一个判断。文中取输出最接近 1 的数和所在位置,然后判断它和 1 差值的绝对值是否比较小,如果比较小就认为该条样本数据的类别是该类,否则它不属于该类。然后判断相邻的输出,如果相邻的输出属于该类,那说明该条样本数据属于该类<sup>[16]</sup>。如果在输出中,有多个位置的值均与 1 接近,

且与 1 的差值的绝对值都足够小,那么认为它是矛盾输出,对于这个矛盾输出的地层类型判定,采用以下方法:计算各个类别的输入样本的样本中心,将具有矛盾输出的样本的输入与各个类别的样本中心进行距离的计算,即该矛盾输出的地层类型与距离最小的样本中心所代表的地层类别一致。

关于并层处理:对于分好类别的小层的并层处理采用以下规则:(1)将测试的样本数据按照深度进行排序,得到类别的序列;(2)相邻的同一类别归于同一个小层内;(3)单独出现的一个不同于其相邻样本类别的数据样本,将其划分于相邻的上一层中;(4)对于厚度太小的小层,将其划分于其相邻的上一层中。

3 实际应用

采用 Matlab 语言进行 BP 神经网络的编程,对辽河油田某区块的 11 口井的某层组进行小层划分仿真。该区块某标准井的部分特征参数原始样本数据如表 1 所示。

表 1 部分原始样本数据

AC	CNL	DEN	GR	RT	SP
208.701 7	14.965 7	2.620 6	72.354 9	76.544 4	47.524 5
204.909 6	14.137 2	2.635 0	70.217 5	85.869 1	46.993 1
201.916 8	12.824 4	2.657 7	70.136 1	86.216 2	46.521 0
195.603 2	9.425 0	2.695 4	65.632 0	95.224 6	45.931 2
...	...	...	...	...	...
194.557 0	8.521 4	2.693 2	64.520 4	79.103 1	45.805 9
196.479 1	8.536 1	2.677 8	64.865 1	80.022 3	45.472 6
199.808 9	9.659 6	2.645 2	66.137 2	84.670 3	45.169 9
204.235 2	13.956 5	2.564 9	69.152 0	60.972 5	44.675 2

当前研究区域作为训练样本的标准井的部分岩性解释如表 2 所示。

表 2 训练样本部分岩性解释

顶深	底深	岩性
4 656.625	4 657.665	细砂岩
4 657.665	4 657.805	泥岩
4 657.805	4 658.045	细砂岩
4 658.045	4 658.145	泥岩
4 658.145	4 658.495	粉砂岩
4 658.495	4 658.955	细砂岩
4 658.955	4 659.905	粉砂岩
4 659.905	4 660.285	泥岩
...	...	...
4 713.095	4 713.205	细砂岩

续表 2

顶深	底深	岩性
4 713.205	4 713.925	泥岩
4 713.925	4 714.025	粉砂岩
4 714.025	4 714.125	细砂岩
4 714.125	4 714.995	细砂岩
4 714.995	4 715.325	泥岩

3.1 数据预处理

首先,作为训练样本的标准井,根据岩性的解释将作为特征的 6 条测井曲线进行分类,每条曲线均有 1 200 个数据点。分类的结果显示,细砂岩类别包含的数据点多达 765,泥岩类别包含的数据点则少至 156。为了便于神经网络的统一处理,采用三次样条插值将全部类别的数据点均设置为 300 个。然后将数据进行



归一化,每个类别随机选取 60 个数据点作为测试样本。最后,将剩下的样本数据构造成训练样本,用于神经网络的学习。

### 3.2 实验结果对比

隐藏节点个数的选择至关重要,根据经验公式(13)的计算方法,文中取折中的思想,将隐含节点个数分别设置为 6、7、8、9、10 分别进行仿真实验,其中损失函数的计算公式为:

$$MSE = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (y'_{ij} - y_{ij})^2 \quad (14)$$

其中,  $N$  表示样本个数,  $M$  表示地层类别个数,  $y'$  表示神经网络预测输出样本,  $y$  表示真实输出。

神经网络的学习算法分别使用 L-M 算法和改进的 L-M 算法,不同个数隐含节点的神经网络模型的测试集的误差和正确率,每个隐含节点均进行多次实验,准确率取平均值,具体情况如表 3 所示。

表 3 测试集误差和准确率

隐含层节点个数	L-M 误差	改进 L-M 误差	L-M 正确率/%	改进 L-M 正确率/%
6	$1.39 \times 10^{-3}$	$3.48 \times 10^{-4}$	80.25	82.89
7	$4.63 \times 10^{-4}$	$1.89 \times 10^{-4}$	86.23	89.16
8	$1.26 \times 10^{-4}$	$1.05 \times 10^{-4}$	90.20	92.86
9	$1.39 \times 10^{-3}$	$2.32 \times 10^{-4}$	88.32	89.44
10	$4.63 \times 10^{-4}$	$2.67 \times 10^{-4}$	84.22	84.89

下面分析改进的 L-M 算法准确率较高的原因:

(1) 由于一部分的数据样本是根据原始样本使用插值算法获得的,因此在数据质量上会好一点;

(2) 地层类别是根据当前研究区域的特点进行分类的,因此地层类型并不全面,只适用于当前的研究区块。

虽然上述实验有区块的局限性,但是对于当前研究的区块是比较符合的。因此根据上表的统计结果,本次研究的 BP 神经网络模型的隐含节点数最终确定为 8 个,学习算法使用改进的 L-M 算法。

### 3.3 划分结果

神经网络模型性能好坏的重要指标之一就是模型的泛化能力,为此采用同一工区中与训练和测试样本集不同的测井数据对该模型进行验证,验证井的部分结果如表 4 所示。

表 4 验证井部分输出结果

输出 1	输出 2	输出 3	地层类型
$5.2278 \times 10^{-6}$	1.000 0	$3.5527 \times 10^{-15}$	2
0.001 6	1.000 0	$1.7521 \times 10^{-8}$	2
$3.0120 \times 10^{-6}$	0	1.000 0	3
$2.8220 \times 10^{-6}$	0	1.000 0	3
0.074 9	0	1.000 0	3
0.650 7	0	1.000 0	3
1.000 0	$3.1107 \times 10^{-8}$	$2.9421 \times 10^{-14}$	1
$1.3421 \times 10^{-8}$	0.999 3	0.002 4	2
$1.1924 \times 10^{-7}$	0.233 7	0.897 0	3
$7.1856 \times 10^{-9}$	$1.1417 \times 10^{-5}$	0.988 2	3

根据并层处理规则和验证井的分类处理结果,将

验证井进行小层的划分,得到的分层结果如图 3 所示。




图 3 验证井小层划分结果

将分层结果与人工分层的结果进行对比,经过地质专家的分析认为,使用文中研究的自动分层神经网络模型对地层小层自动分层界面与人工分层的界面基本吻合,判断误差小于 1 m,且准确率较高,能够满足现场应用的要求。

利用 BP 神经网络进行地层的划分过程中,划分的依据为地层的类别(即岩性类别),在神经网络的训练中,使用改进的 L-M 算法调整网络参数,与传统的 L-M 算法相比提高了分层的效率和准确率。实验结果表明,使用改进 L-M 算法的 BP 神经网络对地层划分问题的解决,具有很好的适用性。

## 4 结束语

利用神经网络的学习训练能力,成功建立了一个

小层自动划分的BP网络模型,并以辽河油田某工区的测井数据为基础,进行了仿真实验,得到以下结论:

(1)改进的L-M算法网络模型具有良好的泛化能力,网络系统运算稳定,具有较高的精确度与运算效率,有效克服了经典BP网络运算效率慢、计算误差大以及容易陷入局部最优的问题。

(2)所建立的网络模型对地层自动划分的平均正确率较高,将本模型用于地层的小层自动划分,在误差允许的范围内可以代替人工分层。因此,本模型在地层自动划分方面具有良好的适用性与可行,具有一定的推广和使用价值。

#### 参考文献:

- [1] 肖波,韩学辉,周开金,等.测井曲线自动分层方法回顾与展望[J].地球物理学进展,2010,25(5):1802-1810.
- [2] 朱立峰.火山碎屑岩层测井曲线自动分层方法研究[D].长春:吉林大学,2009.
- [3] 韩科龙.测井自动分层方法研究及其在岩性识别中的应用[D].北京:中国地质大学,2011.
- [4] 朱立峰,朱立坤.层内差异法与聚类分析结合法的自动分层方法在煤田中的应用[J].科技创业月刊,2015,28(12):117-118.
- [5] 徐伟,林振洲,潘和平,等.木里水合物测井曲线分层方法[J].物探与化探,2017,41(6):1081-1087.
- [6] 朱常坤,梁杏.多参数层序地层的边缘最优智能划分算法及其应用[J].地球物理学进展,2015,30(1):466-470.
- [7] 周锦程,杨清亮,张伟.基于高斯小波变换的测井曲线自动分层模型[J].黔南民族师范学院学报,2017,37(4):31-39.
- [8] PAN Y, MENG X, GE M, et al. Automatic stratification strategy of well logging curves based on wavelet transform [C]//2017 international conference on smart grid and electrical automation (ICSGEA). Changsha:IEEE,2017.
- [9] 胡嘉良,高玉超,余继峰,等.基于PCA-BP神经网络的非常规储层岩性识别研究[J].山东科技大学学报:自然科学版,2016,35(5):9-16.
- [10] MOU D, WANG Z, HUANG Y, et al. Application of least squares support vector machine to lithology identification: taking intermediate/basaltic rocks of Liaohé Basin as an example[J]. Journal of Jilin University, 2015, 45(2):639-648.
- [11] 仲鸿儒,成育红,林孟雄,等.基于SOM和模糊识别的复杂碳酸盐岩岩性识别[J].岩性油气藏,2019,31(5):84-91.
- [12] 赵倩.基于主成分分析的BP神经网络岩性识别在YD油田中的应用[C]//西安石油大学、陕西省石油学会.2018油气田勘探与开发国际会议(IFEDC 2018)论文集.西安:西安华线网络信息服务有限公司,2018:6.
- [13] WANG X, YANG S, ZHAO Y, et al. Lithology identification using an optimized KNN clustering method based on entropy-weighted cosine distance in Mesozoic strata of Gaoqing field, Jiyang depression[J]. Journal of Petroleum Science and Engineering, 2018, 166:157-174.
- [14] 袁冰清,程功,郑柳刚.BP神经网络基本原理[J].数字通信世界,2018(8):28-29.
- [15] 陈刚,汪凯斌,蒋必辞,等.随钻测井中岩性识别方法的对比及应用[J].煤田地质与勘探,2018,46(1):165-169.
- [16] 刘春桃,李元军.神经网络法在测井曲线自动分层问题中的应用[J].高等函授学报:自然科学版,2011,24(5):63-65.