

基于离散过程神经网络页岩油气 储层有机碳含量预测

刘志刚¹, 肖佃师², 许少华³

(1. 东北石油大学计算机与信息技术学院, 黑龙江大庆 163318; 2. 中国石油大学非常规油气与新能源研究院, 山东青岛 266580; 3. 山东科技大学信息科学与工程学院, 山东青岛 266590)

摘要:受地层岩性变化影响,传统方法进行有机碳含量(TOC)拟合预测精度偏低。为提高 TOC 拟合精度,减小普通神经网络对连续信号的时间累积误差,提出一种极限学习离散过程神经网络的 TOC 拟合预测模型。模型用向量模拟过程式输入,内部通过抛物插值的数值积分完成离散样本的时域聚合。通过对离散过程神经元的结构分析,提出极限学习训练算法,在隐层相关参数随机赋值后,通过 Moore-Penrose 广义逆求解输出权值,模型学习速度快。最后将该方法应用于 TOC 拟合预测,利用相关性分析,选取对 TOC 响应最敏感的测井曲线作为模型的特征输入。与传统方法和其他神经网络对比,该方法的拟合精度较高,预测 TOC 与实测值有更好的相关性。

关键词:总有机碳; 离散过程神经网络; 网络训练; Moore-Penrose 广义逆

中图分类号:TE 122.1 **文献标志码:**A

引用格式:刘志刚,肖佃师,许少华. 基于离散过程神经网络的页岩油气储层有机碳含量预测[J]. 中国石油大学学报(自然科学版),2017,41(2):80-87.

LIU Zhigang, XIAO Dianshi, XU Shaohua. Total organic carbon content prediction of shale reservoirs based on discrete process neural network[J]. Journal of China University of Petroleum (Edition of Natural Science), 2017,41(2):80-87.

Total organic carbon content prediction of shale reservoirs based on discrete process neural network

LIU Zhigang¹, XIAO Dianshi², XU Shaohua³

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

2. Institute of Unconventional Oil & Gas and New Energy in China University of Petroleum, Qingdao 266580, China;

3. College of Information Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: Traditional methods in TOC fitting generally have low precision due to the effects of lithology change. In order to improve TOC fitting precision and to reduce the time cumulative error for continuous signals in the artificial neuron network, an extreme learning discrete process neural network is proposed. A vector form is used to simulate the process input in the model. The time domain aggregation for discrete data input is controlled by the parabolic interpolation using numerical integration in the discrete process neuron. Through analysis of structure of discrete process neuron, an extreme learning algorithm is proposed. The parameters of the hidden layer are randomly assigned and the Moore-Penrose generalized inverse is used to compute the output weights. The method is applied to TOC fitting and prediction using some logging curves which have most sensitive response for TOC. The TOC fitting results are compared with the traditional methods and other neural network. The results show that the proposed method has higher fitting precision and faster learning speed, and the predicted TOC and actual TOC have better correlations.

Keywords: total organic carbon; discrete process neural network; network training; Moore-Penrose generalized inverse

收稿日期:2016-01-23

基金项目:国家自然科学基金项目(41602141,41402109,41303013)

作者简介:刘志刚(1979-),男,副教授,博士,研究方向为页岩测井评价与神经网络。E-mail:dqpilzg@163.com。

通讯作者:肖佃师(1981-),男,讲师,博士,研究方向为非常规油气储集层岩石物理评价。E-mail:xiaods1024@163.com。

近几年来,随着能源需求不断提升和常规油气资源逐步枯竭,以页岩油气为重点的非常规资源已成为焦点,通过储层评价有效定位页岩油气的“甜点区”变得尤为重要^[1]。总有机碳含量(total organic carbon, TOC)是用来反映页岩油气富集程度及生烃潜力的重要参数^[2]。目前利用 $\Delta\log R$ 法^[3]进行 TOC 预测时,精度偏低且需要人工选定基线,推广受到一定限制。人工神经网络(artificial neural network, ANN)具有较强的非线性逼近能力,解决非均质地层非线性映射问题具有较好的应用效果,正逐渐应用到 TOC 预测中^[4-8],但受同步瞬时输入限制,逼近精度较低。为解决此问题,何新贵^[9]提出一种连续过程神经元网络(continuous process neural network, CPNN),已用于故障诊断^[10]、非线性系统建模^[11]等实际问题中。但 CPNN 存在以下问题:①离散数据拟合时可能得不到合适的解析函数;②解析函数拟合阶次过高,易导致龙格震荡现象。综上所述,受 CPNN 启发,为提高 TOC 的拟合预测精度,笔者提出一种极限学习离散过程神经网络(ELM discrete process neural network, ELM-DPNN),输入是与 TOC 相关性较强的测井曲线离散数据序列,用向量模拟每一个过程输入,内部为体现测井曲线随深度变化的时间累积效应,采用抛物插值数值积分处理离散输入。

1 极限学习机

极限学习机(extreme learning machine, ELM)是由 Huang 等^[12]提出的一种神经网络快速学习算法,文献[13]通过理论分析和实验已证明可极大提高学习速度(通常 10 倍以上),目前 ELM 理论体系虽不尽完善,但处于迅速发展,已成为国内外的研究热点^[14-15]。

对于单隐层前馈神经网络和 N 个任意样本, $\mathbf{X} = (x_1, x_2, \dots, x_N)$ 为输入, $\mathbf{T} = (t_1, t_2, \dots, t_N)$ 为输出,则模型输入输出映射关系为

$$\sum_{i=1}^L \beta_i g(\mathbf{a}_i \cdot \mathbf{x}_j + b_i) = o_j, j = 1, \dots, N. \quad (1)$$

式中, g 为激励函数; $\mathbf{a}_i$ 为隐层输入权值; β_i 为隐层输出权重。模型学习目标是使误差函数 $E(w)$ 最小, $E(w)$ 为目标输出和期望输出的误差平方和,

$$E(w) = \sum_{j=1}^N \|o_j - t_j\|^2 = 0, \quad (2)$$

即存在 $\beta_i, \mathbf{a}_i$ 和 θ_i 使得

$$\sum_{i=1}^L \beta_i g(\mathbf{a}_i \cdot \mathbf{x}_j + b_i) = t_j, j = 1, \dots, n. \quad (3)$$

记 $\mathbf{H}$ 为隐层的输出矩阵, $\boldsymbol{\beta}$ 为隐层输出权重向量,则式(3)可表示为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}. \quad (4)$$

使用传统的梯度下降法训练神经网络,不仅计算量大、训练速度慢,而且对初值选择敏感,易陷入局部最小。为此 Huang 提出以下定理:

引理 1^[12] 对于 N 个不同样本, M 个隐层节点和一个任意区间无限可导的激活函数 g , 则神经网络在 $\mathbf{a}_i \in \mathbf{R}^n$ 和 $b_i \in \mathbf{R}^n$ 任意赋值的情况下, 隐层输出矩阵 $\mathbf{H}$ 可逆, 即方程组有精确解, 代价函数 $E(W) = 0$ 。

引理 2^[12] 给定任意 N 个不同样本, 任意小误差 $\epsilon > 0$, 及在任意区间无限可导的激活函数 g , 总存在一个神经网络, 使 $\mathbf{a}_i \in \mathbf{R}^n$ 和 $b_i \in \mathbf{R}^n$ 任意赋值情况下, 误差 $E(W) \leq \epsilon$ 。

上述定理表明神经网络只要在权值和阈值赋值的情况下, 可完成对系统的逼近, 从而将神经网络的训练过程转化为式(4)的最小二乘解问题, 其中隐层输出权值为

$$\boldsymbol{\beta} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{T}. \quad (5)$$

2 ELM-DPNN 模型

设 $x_1(t_l), x_2(t_l), \dots, x_n(t_l)$ 是离散过程神经元的离散向量输入, $w_1(t_l), w_2(t_l), \dots, w_n(t_l)$ 为隐层输入权值的离散序列, 则 ELM-DPNN 结构如图 1 所示。




图 1 ELM-DPNN 网络结构

Fig. 1 Structure of ELM-DPNN

模型映射关系可以表示为

$$y = \sum_{j=1}^m v_j f \left(\sum_{i=1}^n \int_0^T w_{ij}(t) x_i(t) dt - \theta \right). \quad (6)$$

为完成离散样本输入的时域聚合, 简化连续积分计算, 本文中提出使用抛物插值的数值积分处理离散样本输入。设积分区间 $[a, b]$, $x_k = a + kh$, $y_k = f(x_k)$, $h = \frac{b-a}{n}$, 则 $f(x)$ 在 $[a, b]$ 上抛物插值可以表示为

$$I(f(x)) = \frac{h_0}{6} (3f_0 + 3f_1 - R_0) +$$

$$\frac{1}{6} \sum_{i=1}^{n-2} h_i \left(3f_i + 3f_{i+1} - \frac{L_i + R_i}{2} \right) + \frac{h_{n-1}}{6} (3f_{n-1} + 3f_n - L_{n-1}). \quad (7)$$

其中

$$L_i = \frac{\delta_i^2}{1 + \delta_i} f_{i-1} - \delta_i f_i + \frac{\delta_i}{1 + \delta_i} f_{i+1}, i = 1, 2, \dots, n-1;$$

$$R_i = \frac{\lambda_i}{1 + \lambda_i} f_i - \lambda_i f_{i+1} + \frac{\lambda_i}{1 + \lambda_i} f_{i+2}, i = 0, 1, \dots, n-2;$$

$$\lambda_i = \frac{h_i}{h_{i+1}}, h_i = x_{i+1} - x_i, \delta_i = \frac{h_i}{h_{i-1}}, i = 0, 1, \dots, n-1.$$

根据抛物插值数值积分,式(6)简化为

$$y = \sum_{j=1}^m v_j \left(\sum_{i=1}^n I(w_{ij}(t)x_i(t)\Delta t) - \theta_j \right). \quad (8)$$

3 ELM-DPNN 学习算法

3.1 ELM-DPNN 结构分析

对采用抛物插值数值积分完成离散样本的时域聚合的离散过程神经元进行结构展开,如图2所示。




图2 离散过程神经元的展开结构

Fig. 2 Expanded structure of discrete process neuron

从展开结构中可以看出,离散过程神经元的输入不再是普通ANN的同步瞬时输入(一维向量),而是样本采样时间序列 $x_i(t_l)$ 组成的二维矩阵。同时,为简化时域聚合运算,对 $x_i(t)$ 和 $w_{ij}(t)$ 的内积进行数值积分,体现样本对时间的累积效应。但经过数值积分简化后,展开的隐层离散过程神经元的结构和普通神经网络基本相同,是一个规模较为庞大的普通ANN,若采用传统的梯度下降法,训练速度慢,且不易收敛。根据Huang等^[12]提出的定理1和定理2,在输入权值和隐层阈值随机赋值的情况下,存在一组输出权值使得网络模型逼近非线性系统,即可以使用ELM进行离散过程神经网络的训练。

3.2 ELM-DPNN 学习算法

(1)根据试探法,确定隐层离散过程神经元的数量,并对阈值和输入权值向量进行随机赋值。

(2)计算隐层输出矩阵。设 $(x_1^{(k)}(t_l), x_2^{(k)}(t_l), \dots, x_n^{(k)}(t_l), d_k)$ 是给定的 K 个样本, $k = 1, 2, \dots, K, l = 1, 2, \dots, L$, 为表述方便,记

$$f(w_{ij}, x_i^{(\mu)}, \theta_k) = f\left(\sum_{i=1}^n \sum_{l=1}^T w_{ij}(t_l) x_i^{(\mu)}(t_l) \Delta t_l + \theta_k\right). \quad (9)$$

则ELM-DPNN的隐层输出矩阵 H 如下:

$$H = \begin{bmatrix} f(w_{i1}, x_i^{(1)}, \theta_1) & \cdots & f(w_{im}, x_i^{(1)}, \theta_m) \\ \vdots & \vdots & \vdots \\ f(w_{i1}, x_i^{(K)}, \theta_1) & \cdots & f(w_{im}, x_i^{(K)}, \theta_m) \end{bmatrix}_{K \times m}. \quad (10)$$

H 中第 k 行是第 k 个样本 $x_i^{(k)}(t)$ 在每个隐层离散过程神经元的输出向量;第 j 列是对于输入样本中的每个样本在第 j 个隐层离散过程神经元的输出向量。根据式(4),ELM-DPNN输入输出映射关系可写为

$$\begin{bmatrix} f(w_{ij}, x_i^L, \theta_k) & \cdots & f(w_{ij}, x_i^L, \theta_k) \\ \vdots & \vdots & \vdots \\ f(w_{ij}, x_i^L, \theta_k) & \cdots & f(w_{ij}, x_i^L, \theta_k) \end{bmatrix} \times \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_m \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_k \end{bmatrix}. \quad (11)$$

为方便描述,记 $O = [d_1, d_2, \dots, d_k]_{k \times 1}^T$ 和 $V = [v_1, v_2, \dots, v_m]_{m \times 1}^T$, O 和 V 分别为期望输出向量和隐层输出权值向量。

(3)计算隐层输出权值。根据ELM-DPNN的隐层输出权值向量如下:

$$V = (H^T H)^{-1} H^T O. \quad (12)$$

记 $A = H^T H$, 在求解 $(H^T H)^{-1}$ 时,若 A 为非奇异方阵,则可以根据 $|A|$ 直接求解 A^{-1} 。但 A 如果是奇异方阵,无法根据 $|A|$ 求解 A^{-1} 。本文中提出使用SVD求解 A 的 Moore-Penrose 广义逆矩阵 $A^\dagger$, 适用于 A 为非奇异方阵和奇异方阵的两种情况。按照SVD分解法,将 A 分解如下:

$$A = P \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r, 0, \dots, 0) Q^T. \quad (13)$$

则 Moore-Penrose 广义逆矩阵 $A^\dagger$ 为:

$$A^\dagger = Q \text{diag}(\sigma_1^{-1}, \sigma_2^{-1}, \dots, \sigma_r^{-1}, 0, \dots, 0) P^T. \quad (14)$$

式中, P 为 $m \times m$ 的正交矩阵; Q 为 $n \times n$ 的正交矩阵, 矩阵 A 的秩为 r 。记矩阵 A 的特征值为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > \lambda_{r+1} = \dots = \lambda_n = 0$, 则奇异值 $\sigma_i = \sqrt{\lambda_i}$ ($i = 1, 2, \dots, r$)。

记 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$, $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$, 设 Q_1 和 Q_2 分别为 Q 的前 r 列和后 $n-r$ 列, 即 $Q = (Q_1, Q_2)$, 根据下式求解 Q_1 和 Q_2 :

$$Q_1^T A^T A Q_1 = \Sigma^2, (A Q_2)^T (A Q_2) = O. \quad (15)$$

记 $P = (p_1, p_2, \dots, p_m)$, 其中列向量 p_i 为 $A^T A$ 的正交单位特征向量, 且满足 $p_i = \frac{A V_i}{\sigma_i}$. 最后利用 Q 和 P 求解 $A^\dagger$, 按式 (12) 计算隐层输出权值向量。

4 TOC 预测实例

本文中以 A 地区 B1 井和 B2 井为例, 其中 B1 井在深度 2930 ~ 3098 m 的泥页岩 TOC 值为 2% ~ 15%, 属于 TOC 中高值情况, B2 井在深度 3055 ~ 3140 m 的 TOC 值小于 3%, 属于 TOC 低值情况, 根据这两种情况分别验证所提方法有效性。常规测井资料包括自然电位 SP、自然伽马 GR、深侧向电阻率

RLLD、密度 DEN、补偿中子 CNL、声波时差 AC 等。
实验对比包括两部分: ①模型学习能力对比。与文献[5]的 RBF-ANN、文献[16]的正交基展开连续 PNN(orthogonal basis-based PNN, OBPNN)、BP-DPNN 进行对比, 检验本文的 ELM-DPNN 的学习能力是否提高; ②TOC 的拟合效果和预测能力对比。将 ELM-DPNN 与 $\Delta \log R$ 法和文献[6]的 RBF-ANN 进行对比, 检验 TOC 的拟合预测精度是否提高。

4.1 数据样本选取

利用神经网络进行 TOC 预测, 测井曲线的选择很重要。以 B1 井为例, 图 3 为各条测井曲线和 TOC 的相关性分析, 可以看出 DEN、CNL 和 AC 与 TOC 的相关性要明显优于 SP、GR 和 RLLD, 因此为更好地进行 TOC 和测井曲线的非线性映射, 选择 DEN、CNL、AC 作为模型的输入。同理, 经过相关性分析, B2 井也选取 DEN、CNL、AC 三条测井曲线。




图 3 测井曲线和 TOC 的相关性分析

Fig. 3 Correlation analysis between logging curve and TOC

在样本选择方面, B1 井共选取 180 组代表性样本, 由 DEN、CNL、AC 测井曲线和 TOC 实测值构成, 其中 135 组作为训练样本, 其余 45 组为测试样本, 对神经网络模型和 $\Delta \log R$ 法预测的 TOC 进行效果验证。同理, B2 共选取 46 组样本, 38 组作为训练样本, 8 组为测试样本用来验证。

由于每条测井曲线量纲不同, 数据量级相差较大, 为了让神经网络模型能够有效反映每条测井曲线与 TOC 的非线性映射关系, 在输入模型前必须对每条测井曲线的离散数据进行归一化处理, 如下:

式中, X 为原始的测井曲线数值; X_{min} 和 X_{max} 为该条测井曲线离散数据样本的最小值和最大值; X^* 为归一化后的测井曲线数值, 即 $X^* \in [0, 1]$ 。

4.2 TOC 预测结果对比

4.2.1 模型训练情况对比

实验环境说明: 所有训练实验都在 Intel i7-3520/2.90 GHz 主频、8G 内存、win 7-64 位、Matlab2012 上完成。最大迭代步数 maxGen=5000, 误差

精度 $\varepsilon=0.0005$,模型的拓扑结构为 3-11-1。其中 OBPNN 的正交基展开函数选用勒让德基函数,正交基函数项数 $L=21$,OBPNN 和 BP-DPNN 的学习速度 $\alpha=\beta=\gamma=0.5$,惯性系数 $\eta=0.1$ 。

针对 B1 和 B2 井的训练样本,各独立进行 10 次训练实验,对结果数据进行统计,对比情况如表 1 所示。结果表明,在训练速度方面,ELM-DPNN 的训练速度较 BP-DPNN 和 OBPNN 有了很大的提升,约 5~8 倍,有效解决了过程神经网络学习训练速度较慢的问题。

表 1 四种神经网络训练情况对比

Table 1 Training results comparison for four neuron networks						
井号	模型	平均训练误差	最少步数	平均步数	平均时间/s	收敛次数
B1 井	RBF-ANN	0.006 4	2 276	2 683	19.42	7
	OBPNN	0.007 7	5 391	5 637	86.64	5
	BP-DPNN	0.005 9	4 832	5 184	56.36	8
	ELM-DPNN	0.006 2	671	753	11.28	7
B2 井	RBF-ANN	0.005 6	1 973	2 286	15.73	8
	OBPNN	0.008 2	3 956	4 671	67.36	6
	BP-DPNN	0.005 2	3 631	4 215	44.73	9
	ELM-DPNN	0.006 5	376	513	8.84	6





图 4 ELM-DPNN 的实测 TOC 和计算 TOC 的相关性

Fig. 4 Correlation between actual TOC and predicted TOC for ELM-DPNN model

4.2.3 B2 井 TOC 预测情况

B2 井埋深 3 055~3 140 m 的泥页岩 TOC 值属于 TOC 低值的情况。本次实验的 $\Delta\log R$ 、RBF-ANN、ELM-DPNN 三种方法预测 TOC 的相关系数分别为 0.8563、0.8856、0.8889,均较好地完成 TOC 的预测,ELM-DPNN 比 $\Delta\log R$ 略有提高,约为 3%,其他 TOC 拟合预测指标对比见表 2,三种方法在 B2 井的 TOC 预测情况对比如图 6 所示。

4.2.2 B1 井 TOC 预测情况

B1 井埋深 2 930~3 098 m 的泥页岩 TOC 值属于中高值情况。将训练好的 RBF-ANN、ELM-DPNN 进行 45 组 TOC 测试样本的拟合预测,与 $\Delta\log R$ 法进行对比,结果如表 2 所示,其中 ELM-DPNN 的训练样本和测试样本拟合预测的 TOC 相关性交互图如图 4 所示。

通过均方根误差 RMSE、相关系数 R 等预测指标可发现,对于 B1 井 TOC 拟合预测精度从高到低依次为 ELM-DPNN、RBF-ANN 和 $\Delta\log R$ 法。对于 ELM-DPNN 模型,135 组训练样本的实测 TOC 和预测 TOC 的相关系数可达到 $R=0.9010$ (判定系数 $R^2=0.8119$),45 组测试样本的实测 TOC 和预测 TOC 的相关系数 $R=0.8623$ (判定系数 $R^2=0.7436$),对于 B1 井 2 930~3 098 m 井段的 TOC 预测,ELM-DPNN 的预测精度比 $\Delta\log R$ 有明显提高,相关系数提高约 13%,比文献[5]的 RBF 高出约 6%,更好地体现了 TOC 的整体变化趋势。图 5 为三种方法在 B1 井的 TOC 预测情况对比。

表 2 三种模型的 TOC 预测对比

Table 2 Predicted results comparison for three models

井号	模型	相关系数 R	平均绝对误差 E_{MA}	平均相对误差 E_{MR}	均方根误差 E_{RMS}
B1 井	$\Delta\log R$	0.736 7	1.688 9	0.277 6	2.120 8
	RBF-ANN	0.805 9	1.122 1	0.176 4	1.358 9
	ELM-DPNN	0.862 3	0.931 8	0.144 5	1.196 2
B2 井	$\Delta\log R$	0.856 3	0.116 1	0.280 1	0.222 7
	RBF-ANN	0.885 6	0.095 3	0.270 7	0.164 7
	ELM-DPNN	0.888 9	0.091 4	0.269 6	0.162 8




图 5 B1 井三种模型的 TOC 拟合预测效果对比

Fig. 5 TOC fitting and prediction results comparison for three models for B1

4.3 实验结果分析

4.3.1 方法适用性分析

首先,ΔlogR 法的前提是假定地层岩性基本不变,声波和孔隙度的差异变化仅由有机质含量变化引起,使用声波和电阻率的幅度差计算 TOC,因此该方法本质上是假定 TOC 与电阻率、声波之间存在线性映射关系。但在 A 地区,储层段岩性发生改变,电阻和声波曲线间的差异不能单纯反映地层 TOC 含量的变化。当 TOC 较低时,对声波、电阻率的变化影响较小,使用 ΔlogR 法计算 TOC 存在一定




图 6 B2 井三种模型的 TOC 拟合预测效果对比

Fig. 6 TOC fitting and prediction results comparison for three models for B2

的偏差。当 TOC 较高时,通过对 B1 井进行岩心 TOC 相关性分析,电阻率与 TOC 间的相关性较差,ΔlogR 法的测井响应线性假定与实际不符,导致 TOC 预测精度偏低。

其次,TOC 与测井曲线之间应属于一种非线性映射关系,TOC 的变化在测井曲线上均有一定的响应。由于神经网络具有很强的映射能力,选择与 TOC 相关性较高的多条测井曲线作为神经网络的

特征参数,考虑了多种测井方法对 TOC 的综合响应,避免了由于复杂岩性变化导致的 TOC 预测模型与测井响应不匹配的问题,利用神经网络的特性可完成复杂非线性系统的映射逼近,因此 TOC 的拟合预测精度要优于 $\Delta\log R$ 法。

最后,本文中所提的 ELM-DPNN 模型通过测井曲线的离散数据向量模拟过程式输入,以矩阵作为模型整体输入,隐层利用抛物插值数值积分的时间聚合算子,减小了测井曲线过程信号的时间累积误差,因在非线性系统的逼近能力上优于普通的神经网络,TOC 的拟合预测精度较高。

综合所述理论分析和实验结果数据可知,当电阻率与 TOC 相关性较差时,对于低值、中高值的 TOC 拟合预测问题,ELM-DPNN 具有较好的适用性。

4.3.2 学习速度分析

ELM-DPNN 在学习速度上明显优于 BP-DPNN 和 OBPNN,是因为 ELM-DPNN 对输入权值、阈值进行随机赋值,通过使用 Moore-Penrose 广义逆计算出隐层的输出权值,无需计算梯度信息,学习速度较 BP-DPNN 提升约 5 倍。文献[11]提出的 OBPNN 在训练过程中须对离散输入进行拟合和正交基展开,计算量大,训练时间长,训练时间约为 ELM-DPNN 的 8 倍。同时由于 OBPNN 在拟合过程中可能存在解析函数不存在、项数不易确定等问题,导致模型的训练收敛能力劣于 ELM-DPNN,仅达到约 60%。这些问题在 ELM-DPNN 中有明显改善。

5 结束语

为提高 TOC 拟合预测精度,减小测井曲线随深度变化的时间累积误差,提出 ELM-DPNN 预测模型,并根据极限学习理论完成模型参数求解,最后以 B1 和 B2 井为例进行 TOC 预测。从实验结果可以看出,电阻率与 TOC 的线性关系不明显时,模型预测效果优于 $\Delta\log R$ 法,从而为 TOC 预测提供了一种新的智能方法。但 ELM-DPNN 也存在一定不足,为完成模型训练,所需实测的 TOC 样本较多,否则易导致模型训练欠拟合情况发生,影响预测精度,但在理论上训练后的模型可以用于该地区其他井的 TOC 预测。

参考文献:

[1] 吴伟,刘惟庆,唐玄,等. 川西坳陷富有机质页岩孔隙特征[J]. 中国石油大学学报(自然科学版),2014,38

(4):1-8.

WU Wei, LIU Weiqing, TANG Xuan, et al. Organic rich shale pore characteristics of Western Sichuan Depression[J]. Journal of China University of Petroleum (Edition of Natural Science), 2014,38(4):1-8.

[2] 郝建飞,周灿灿,李霞. 页岩气地球物理测井评价综述[J]. 地球物理学进展,2012,27(4):1624-1632.

HAO Jianfei, ZHOU Cancan, LI Xia. Summary of shale gas evaluation applying geophysical logging[J]. Progress in Geophysics, 2012,27(4):1624-1632.

[3] PASSEY Q R, MORETTI F U, STROUD J D. A practical model for organic richness from porosity and resistivity logs[J]. AAPG Bulletin, 1990,74(12):1777-1794.

[4] 朱振宇,王贵文,朱广宇. 人工神经网络法在烃源岩测井评价中的应用[J]. 地球物理学进展,2002,17(1):137-143.

ZHU Zhenyu, WANG Guiwen, ZHU Guangyu. The application of artificial neural network to the source rock's evaluation [J]. Progress in Geophysics, 2002,17(1):137-143.

[5] 郭龙,陈践发,苗忠英. 一种新的 TOC 含量拟合方法研究与应用[J]. 天然气地球科学,2009,20(6):951-958.

GUO Long, CHEN Jianfa, MIAO Zhongying. Study and application of a new overlay method of the TOC content [J]. Natural Gas Geoscience, 2009,20(6):951-958.

[6] TAN Maojin, LIU Qiong, ZHANG Songyang. A dynamic adaptive radial basis function approach for total organic carbon content prediction in organic shale[J]. Geophysics,2013,78(6):445-459.

[7] 赵兴齐,陈践发,郭望,等. BP 神经网络在西湖凹陷烃源岩评价中的应用[J]. 测井技术,2013,37(5):567-572.

ZHAO Xingqi, CHEN Jianfa, GUO Wang, et al. The application of BP neural network to the source rocks evaluation in Xihu sag[J]. Well Logging Technology, 2013,37(5):567-572.

[8] 熊镭,张超谟,张冲,等. A 地区页岩气储层总有机碳含量测井评价方法研究[J]. 岩性油气藏,2014,26(3):74-80.

XIONG Lei, ZHANG Chaomo, ZHANG Chong, et al. Research on logging evaluation method of TOC content of shale gas reservoir in area A [J]. Engineering Science, 2014,26(3):74-80.

[9] HE X G, LIANG J Z. Procedure neural networks[C/OL]. //Proceedings of Conference on Intelligent Information Proceeding, Beijing, China, August 21-25, 2000 [2003-03-07]. <http://fars.gytec.net/Main.aspx>.

- [10] 王兵,许少华. 基于半监督竞争学习过程神经网络的抽油机故障诊断[J]. 信息与控制,2014,43(2):235-240.
WANG Bing, XU Shaohua. Fault diagnosis of pumping unit based on semi-supervised competitive learning process neural network[J]. Information and Control, 2014,43(2):235-240.
- [11] 肖红,许少华,李盼池. 基于数值积分的多聚合过程神经网络算法[J]. 信息与控制,2013,42(5):608-612.
XIAO Hong, XU Shaohua, LI Panchi. Multi-aggregation process neural networks algorithm based on numerical integration[J]. Information and Control, 2013,42(5):608-612.
- [12] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feed forward neural networks[C/OL]// Proceedings of International Joint Conference on Neural Networks (IJCNN2004), Budapest, Hungary, July 25-29, 2004[2016-01-24]. <http://www.ntu.edu.sg/home/egbhuang/reference.html>.
- [13] HUANG G B. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B, 2012,42(2):513-516.
- [14] L L C K, ZHOU H M, HUANG G B. Representational learning with extreme learning machine for big data[J]. IEEE Intelligent System, 2013,28(6):31-34.
- [15] 贺彦林,王晓,朱群雄. 基于主成分分析—改进的极限学习机方法的精对苯二甲酸醋酸含量软测量[J]. 控制理论与应用,2015,32(1):80-85.
HE Yanlin, WANG Xiao, ZHU Qunxiong. Modeling of acetic acid content in purified terephthalic acid solvent column using principal component analysis based improved extreme learning machine[J]. Control Theory & Application, 2015,32(1):80-85.
- [16] 许少华,何新贵. 基于函数正交基展开的过程神经网络学习算法[J]. 计算机学报,2004,27(5):645-650.
XU Shaohua, HE Xingui. Learning algorithms of process neural networks based on orthogonal function basis expansion[J]. Chinese Journal of Computers, 2004,27(5):645-650.

(编辑 修荣荣)